

# IBM SPSS Modeler

## 도움말 4

### (소장용)

원문:

<https://www.ibm.com/docs/ko/spss-modeler/SaaS?topic=started-how-use-spss-modeler>

2022. 05.

국제개발연구소

## <목차>

7. In-Database 마이닝 .....	27
1) In-Database 마이닝 .....	27
(1) 데이터베이스 모델링 개요 .....	27
① 필요사항 .....	28
② 모델 작성 .....	28
③ 데이터 준비 .....	28
④ 모델 스코어링 .....	29
⑤ 데이터베이스 모델 내보내기 및 저장 .....	29
⑥ 모델 일관성 .....	30
⑦ 생성된 SQL 보기 및 내보내기 .....	30
2) Microsoft Analysis Services 를 사용한 데이터베이스 모델링 .....	30
(1) IBM SPSS Modeler 및 Microsoft Analysis Services .....	30
① Microsoft Analysis Services 와의 통합을 위한 요구사항 .....	32
② Analysis Services 와의 통합 사용 .....	33
(2) Analysis Services 를 사용하여 모델 작성 .....	36
① Analysis Services 모델 관리 .....	36
② 모든 알고리즘 노드에 공통인 설정 .....	38
가. 서버 옵션 .....	38
나. 모델 옵션 .....	38
③ MS 의사결정 트리 고급 옵션 .....	39
④ MS 군집화 고급 옵션 .....	39
⑤ MS Naive Bayes 고급 옵션 .....	39
⑥ MS 선형 회귀 고급 옵션 .....	39
⑦ MS 신경망 고급 옵션 .....	39
⑧ MS 로지스틱 회귀분석 고급 옵션 .....	40

⑨ MS 연관 규칙 노드 .....	40
가. MS 연관 규칙 고급 옵션 .....	40
⑩ MS 시계열 노드 .....	41
가. MS 시계열 모델 옵션 .....	41
나. MS 시계열 고급 옵션 .....	42
다. MS 시계열 설정 옵션 .....	42
⑪ MS 시퀀스 군집화 노드 .....	43
가. MS 시퀀스 군집화 필드 옵션 .....	43
나. MS 시퀀스 군집화 고급 옵션 .....	44
(3) Analysis Services 모델 스코어링 .....	44
① 모든 Analysis Services 모델에 공통인 설정 .....	44
가. Analysis Services 모델 너깃 서버 탭 .....	44
나. Analysis Services 모델 너깃 요약 탭 .....	45
② MS 시계열 모델 너깃 .....	45
가. MS 시계열 모델 너깃 서버 탭 .....	46
나. MS 시계열 모델 너깃 설정 탭 .....	47
③ MS 시퀀스 군집화 모델 너깃 .....	47
④ 모델 내보내기 및 노드 생성 .....	47
(4) Analysis Services 마이닝 예제 .....	48
① 예제 스트림: 의사결정 트리 .....	48
가. 예제 스트림: 데이터 업로드 .....	49
나. 예제 스트림: 데이터 탐색 .....	49
다. 예제 스트림: 모델 작성 .....	49
라. 예제 스트림: 모델 평가 .....	50
마. 예제 스트림: 모델 배포 .....	50
3) Oracle Data Mining 을 사용한 데이터베이스 모델링 .....	52
(1) Oracle Data Mining 정보 .....	52

(2) Oracle 과의 통합을 위한 요구사항 .....	52
(3) Oracle 과의 통합 사용 .....	53
(4) Oracle Data Mining 을 사용하여 모델 작성 .....	55
① Oracle 모형 서버 옵션 .....	56
② 오분류 비용 .....	57
(5) Oracle Naive Bayes .....	57
① Naive Bayes 모형 옵션 .....	58
② Naive Bayes 고급 옵션 .....	58
(6) Oracle 적응형 베이스 .....	59
① 적응형 Bayes 모델 옵션 .....	59
② 적응형 Bayes 고급 옵션 .....	60
(7) Oracle 지원 벡터 머신(SVM) .....	60
① Oracle SVM 모형 옵션 .....	61
② Oracle SVM 고급 옵션 .....	61
③ Oracle SVM 가중치 옵션 .....	62
(8) Oracle 일반화 선형 모형(GLM) .....	63
① Oracle GLM 모형 옵션 .....	63
② Oracle GLM 고급 옵션 .....	64
③ Oracle GLM 가중치 옵션 .....	64
(9) Oracle 의사결정 트리 .....	65
① 의사결정 트리 모형 옵션 .....	65
② 의사결정 트리 고급 옵션 .....	66
(10) Oracle O-Cluster .....	67
① O-Cluster 모형 옵션 .....	67
② O-Cluster 고급 옵션 .....	67
(11) Oracle K-평균 .....	68
① K-평균 모형 옵션 .....	68

② K-평균 고급 옵션 .....	69
(12) Oracle 비음수 교차표 분해(NMF) .....	69
① NMF 모형 옵션 .....	69
② NMF 고급 옵션 .....	70
(13) Oracle Apriori .....	70
① Apriori 필드 옵션 .....	71
② Apriori 모형 옵션 .....	72
(14) Oracle 최소 설명 길이(MDL) .....	72
① MDL 모형 옵션 .....	73
(15) Oracle 속성 중요도(AI) .....	73
① AI 모델 옵션 .....	74
② AI 선택 옵션 .....	74
③ AI 모델 너깃 모델 탭 .....	74
(16) Oracle 모델 관리 .....	75
① Oracle 모델 너깃 서버 탭 .....	75
② Oracle 모델 너깃 요약 탭 .....	75
③ Oracle 모델 너깃 설정 탭 .....	76
④ Oracle 모델 나열 .....	76
⑤ Oracle Data Miner .....	77
(17) 데이터 준비 .....	77
(18) Oracle 데이터 마이닝 예 .....	78
① 예제 스트림: 데이터 업로드 .....	79
② 예제 스트림: 데이터 탐색 .....	79
③ 예제 스트림: 모델 작성 .....	79
④ 예제 스트림: 모델 평가 .....	80
⑤ 예제 스트림: 모델 배포 .....	80
4) IBM® Netezza® 및 IBM Netezza Analytics 를 사용한 데이터베이스 모델링 ....	80

(1) IBM Data Warehouse 및 IBM Netezza Analytics 가 포함된 SPSS Modeler ..	80
(2) 통합 요구사항 .....	81
(3) 통합 사용 .....	82
① IBM Netezza Analytics 또는 IBM Data Warehouse 구성 .....	83
② IBM Netezza® Analytics 에 대한 ODBC 소스 작성 .....	83
③ SPSS Modeler 에서 통합 사용 .....	85
④ SQL 생성 및 최적화 사용 .....	85
(4) IBM Netezza® Analytics 및 IBM Data Warehouse 를 사용한 모델 작성 .....	86
① 필드 옵션 .....	87
② 서버 옵션 .....	88
③ 모델 옵션 .....	88
④ 모델 관리 .....	89
⑤ 데이터베이스 모델 나열 .....	89
(5) IBM Data WH 회귀분석 트리 .....	90
① IBM Data WH 회귀분석 트리 작성 옵션 - 트리 성장 .....	90
② IBM Data WH 트리 작성 옵션 - 트리 가지치기 .....	91
(6) Netezza 분열 군집 .....	91
① Netezza 분열 군집 필드 옵션 .....	92
② Netezza 분열 군집 작성 옵션 .....	93
(7) IBM Data WH 일반화 선형 .....	93
① IBM Data WH 일반화 선형 모델 필드 옵션 .....	94
② IBM Data WH 일반화 선형 모델 옵션 - 일반 .....	95
③ IBM Data WH 일반화 선형 모델 옵션 - 상호작용 .....	96
가. 사용자 정의 항 추가 .....	96
④ IBM Data WH 일반화 선형 모델 옵션 - 스코어링 옵션 .....	97
(8) IBM Data WH 의사결정 트리 .....	97
① 인스턴스 가중치 및 클래스 가중치 .....	97

② Netezza 의사결정 트리 필드 옵션 .....	98
③ IBM Data WH 의사결정 트리 작성 옵션 .....	99
가. IBM Data WH 의사결정 트리 노드 - 클래스 가중치 .....	100
나. IBM Data WH 의사결정 트리 노드 - 트리 가지치기 .....	100
(9) IBM Data WH 선형 회귀 .....	101
① IBM Data WH 선형 회귀 작성 옵션 .....	101
(10) IBM Data WH KNN .....	101
① IBM Data WH KNN 모델 옵션 - 일반 .....	102
② IBM Data WH KNN 모델 옵션 - 스코어링 옵션 .....	103
(11) IBM Data WH K-평균 .....	104
① IBM Data WH K-평균 필드 옵션 .....	104
② IBM Data WH K-평균 작성 옵션 탭 .....	104
(12) IBM Data WH Naive Bayes .....	105
(13) Netezza Bayes Net .....	105
① Netezza Bayes 넷 필드 옵션 .....	106
② Netezza Bayes 넷 작성 옵션 .....	106
(14) Netezza 시계열 .....	107
① Netezza 시계열에서 값의 보간법 .....	108
② Netezza 시계열 필드 옵션 .....	110
③ Netezza 시계열 작성 옵션 .....	110
가. ARIMA 구조 .....	112
나. Netezza 시계열 작성 옵션 - 고급 .....	113
④ Netezza 시계열 모델 옵션 .....	113
(15) IBM Data WH TwoStep .....	114
① IBM Data WH TwoStep 필드 옵션 .....	114
② IBM Data WH TwoStep 작성 옵션 .....	115
(16) IBM Data WH PCA .....	115

① IBM Data WH PCA 필드 옵션 .....	116
② IBM Data WH PCA 작성 옵션 .....	116
(17) IBM Data WH 및 Netezza 모델 관리 .....	117
① IBM Data Warehouse 및 IBM® Netezza® Analytics 모델 스코어링 .....	117
② IBM Data WH 및 Netezza 모델 너깃 서버 탭 .....	117
③ IBM Data WH 의사결정 트리 모델 너깃 .....	118
가. IBM Data WH 의사결정 트리 너깃 - 모델 탭 .....	119
나. IBM Data WH 의사결정 트리 너깃 - 설정 탭 .....	119
다. IBM Data WH 의사결정 트리 너깃 - 뷰어 탭 .....	119
④ IBM Data WH K-평균 모델 너깃 .....	120
가. IBM Data WH K-평균 너깃 - 모델 탭 .....	120
나. IBM Data WH K-평균 너깃 - 설정 탭 .....	120
⑤ Netezza Bayes 넷 모델 너깃 .....	121
가. Netezza Bayes 넷 너깃 - 설정 탭 .....	121
⑥ IBM Data WH Naive Bayes 모델 너깃 .....	121
가. IBM Data WH Naive Bayes 너깃 - 설정 탭 .....	122
⑦ IBM Data WH KNN 모델 너깃 .....	123
가. IBM Data WH KNN 너깃 - 설정 탭 .....	123
⑧ Netezza 분열 군집 모델 너깃 .....	124
가. Netezza 분열 군집 너깃 - 설정 탭 .....	124
⑨ IBM Data WH PCA 모델 너깃 .....	124
가. IBM Data WH PCA 너깃 - 설정 탭 .....	125
⑩ Netezza 회귀 트리 모델 너깃 .....	125
가. Netezza 회귀 트리 너깃 - 모델 탭 .....	126
나. Netezza 회귀 트리 너깃 - 설정 탭 .....	126
다. Netezza 회귀 트리 너깃 - 뷰어 탭 .....	126
⑪ IBM Data WH 선형 회귀 모델 너깃 .....	127

가. IBM Data WH 선형 회귀 너깃 - 설정 탭 .....	127
⑫ Netezza 시계열 모델 너깃 .....	127
가. Netezza 시계열 너깃 - 설정 탭 .....	128
⑬ IBM Data WH 일반화 선형 모델 너깃 .....	128
가. IBM Data WH 일반화 선형 모형 너깃 - 설정 탭 .....	129
⑭ IBM Data WH TwoStep 모델 너깃 .....	129
가. IBM Data WH TwoStep 너깃 - 모델 탭 .....	129
5) z/OS®용 IBM® Db2®를 사용한 데이터베이스 모델링 .....	130
(1) IBM SPSS Modeler 및 z/OS 용 IBM Db2 .....	130
(2) z/OS 용 IBM Db2 와의 통합을 위한 요구사항 .....	130
(3) z/OS 용 IBM Db2 Analytics Accelerator 와의 통합 사용 .....	130
① z/OS 용 IBM® Db2 및 z/OS 용 IBM Analytics Accelerator 구성 .....	131
② z/OS 용 IBM Db2 및 IBM Db2 Analytics Accelerator 에 대한 ODBC 소스 작성 .....	131
③ IBM® SPSS Modeler 에서 z/OS®용 IBM Db2 의 통합 사용 .....	131
④ SQL 생성 및 최적화 사용 .....	132
⑤ IBM® SPSS Modeler 에서 IBM Db2 클라이언트를 사용하여 DSN 구성 .....	133
(4) z/OS 용 IBM® Db2 를 사용한 모델 작성 .....	133
① z/OS®용 IBM® Db2® 모델 - 필드 옵션 .....	135
② z/OS 용 IBM Db2 모델 - 서버 옵션 .....	135
③ z/OS®용 IBM® Db2® 모델 - 모델 옵션 .....	136
(5) z/OS®용 IBM® Db2® 모델 - K-평균 .....	136
① z/OS®용 IBM® Db2® 모델 - K-평균 필드 옵션 .....	136
② z/OS®용 IBM® Db2® 모델 - K-평균 작성 옵션 .....	137
(6) z/OS®용 IBM® Db2® 모델 - Naive Bayes .....	137
(7) z/OS®용 IBM® Db2® 모델 - 의사결정 트리 .....	138
① z/OS®용 IBM® Db2® 모델 - 의사결정 트리 필드 옵션 .....	138
② z/OS®용 IBM® Db2® 모델 - 의사결정 트리 작성 옵션 .....	139

③ z/OS®용 IBM® Db2® 모델 - 의사결정 트리 노드 - 클래스 가중치 .....	140
④ z/OS®용 IBM® Db2® 모델 - 의사결정 트리 노드 - 트리 가지치기 .....	140
(8) z/OS®용 IBM® Db2® 모델 - 회귀 트리 .....	141
(9) z/OS®용 IBM® Db2® 모델 - 회귀 트리 작성 옵션 - 트리 성장 .....	141
(10) z/OS®용 IBM® Db2® 모델 - 회귀분석 트리 작성 옵션 - 트리 가지치기 .....	142
(11) z/OS®용 IBM® Db2® 모델 - 이단계 .....	142
① z/OS®용 IBM® Db2® 모델 - 이단계 필드 옵션 .....	143
② z/OS®용 IBM® Db2® 모델 - 이단계 작성 옵션 .....	143
③ z/OS®용 IBM® Db2® 모델 - 이단계 너깃 - 모델 탭 .....	144
(12) IBM Db2 for z/OS 모델 관리 .....	144
① IBM® Db2® for z/OS® 모델 스코어링 .....	144
② z/OS 용 IBM® Db2 의사결정 트리 모형 너깃 .....	145
가. z/OS®용 IBM® Db2® 의사결정 트리 너깃 - 모델 탭 .....	145
나. z/OS®용 IBM® Db2® 의사결정 트리 너깃 - 뷰어 탭 .....	146
③ z/OS 용 IBM® Db2 K-평균 모델 너깃 .....	146
가. z/OS®용 IBM® Db2® K-평균 너깃 - 모델 탭 .....	146
④ z/OS 용 IBM® Db2 Naive Bayes 모델 너깃 .....	146
⑤ z/OS 용 IBM® Db2 회귀 트리 모델 너깃 .....	146
가. z/OS®용 IBM® Db2® 회귀 트리 너깃 - 모델 탭 .....	147
나. z/OS®용 IBM® Db2® 회귀 트리 너깃 - 뷰어 탭 .....	147
⑥ z/OS®용 IBM® Db2® 이단계 모델 너깃 .....	147
IV. IBM SPSS Modeler 확장 도움말 .....	148
1. 지원되는 언어 .....	148
1) R .....	148
2) Python for Spark .....	149
(1) Python for Spark 를 사용한 스크립팅 .....	149
① Analytic Server 컨텍스트 .....	153

② 데이터 메타데이터 .....	156
③ 날짜, 시간, 시간소인 .....	158
④ 예외 .....	158
⑤ 예제 .....	160
3) 확장 노드 .....	163
(1) 확장 내보내기 노드 .....	163
① 확장 내보내기 노드 - 명령문 탭 .....	163
② 확장 내보내기 노드 - 콘솔 출력 탭 .....	164
③ 스트림 출판 .....	165
(2) 확장 출력 노드 .....	166
① 확장 출력 노드 - 구문 탭 .....	166
② 확장 출력 노드 - 콘솔 출력 탭 .....	167
③ 확장 출력 노드 - 출력 탭 .....	168
④ 확장 출력 브라우저 .....	168
가. 확장 출력 브라우저 - 텍스트 출력 탭 .....	169
나. 확장 출력 브라우저 - 그래프 출력 탭 .....	169
(3) 확장 모델 노드 .....	169
① 확장 모델 노드 - 명령문 탭 .....	169
② 확장 모델 노드 - 모델 옵션 탭 .....	170
③ 확장 모델 노드 - 콘솔 출력 탭 .....	170
④ 확장 모델 노드 - 텍스트 출력 탭 .....	170
(4) 확장 모델 너깃 .....	171
① 확장 모델 너깃 - 명령문 탭 .....	171
② 확장 모델 너깃 - 모델 옵션 탭 .....	172
③ 확장 모델 너깃 - 그래프 출력 탭 .....	173
④ 확장 모델 너깃 - 텍스트 출력 탭 .....	173
⑤ 확장 모델 너깃 - 콘솔 출력 탭 .....	173

(5) 확장 변환 노드 .....	174
① 확장 변환 노드 - 명령문 탭 .....	174
② 확장 변환 노드 - 콘솔 출력 탭 .....	175
(6) 확장 가져오기 노드 .....	175
① 확장 가져오기 노드 - 명령문 탭 .....	175
② 확장 가져오기 노드 - 콘솔 출력 탭 .....	176
③ 필드 필터링 또는 이름 바꾸기 .....	176
④ 유형에 대한 정보 보기 및 설정 .....	176
2. 확장 .....	177
1) 확장 허브 .....	177
(1) 탐색 탭 (확장 허브) .....	178
① 플러그인 통합 방법 .....	179
(2) 설치됨 탭 (확장 허브) .....	180
(3) 설정(확장 허브) .....	181
(4) 확장 세부사항 .....	181
2) 로컬 확장 번들 설치 .....	182
(1) 확장의 설치 위치 .....	182
(2) 필수 R 패키지 .....	183
3) 사용자 정의 노드 작성 및 관리 .....	183
(1) 사용자 정의 대화 상자 작성기 레이아웃 .....	185
(2) 사용자 정의 노드 대화 상자 작성 .....	186
(3) 대화 상자 특성 .....	186
(4) 대화 상자 캔버스에서 제어의 레이아웃 .....	187
(5) 스크립트 템플릿 작성 .....	188
(6) 사용자 정의 노드 대화 상자 미리보기 .....	190
(7) 제어 유형 .....	190
① 필드 선택기 .....	191

가. 필드 선택기의 필드 소스 지정 .....	192
② 필드 목록 필터링 .....	192
③ 선택란 .....	193
④ 콤보 상자 .....	193
가. 콤보 상자 및 목록 상자의 항목 목록 지정 .....	195
⑤ 목록 상자 .....	196
⑥ 텍스트 제어 .....	197
⑦ 숫자 제어 .....	199
⑧ 날짜 제어 .....	200
⑨ 보안 텍스트 .....	201
⑩ 정적 텍스트 제어 .....	203
⑪ 색상 선택도구 .....	203
⑫ 테이블 제어 .....	204
가. 테이블 제어의 열 지정 .....	205
⑬ 항목 그룹 .....	207
⑭ 라디오 그룹 .....	208
가. 단일 선택 단추 정의 .....	209
⑮ 선택란 그룹 .....	210
⑯ 파일 브라우저 .....	211
가. 파일 유형 필터 .....	212
⑰ 탭 .....	212
⑱ 하위 대화 상자 단추 .....	213
가. 하위 대화 상자의 대화 상자 특성 .....	214
⑲ 제어의 사용 규칙 지정 .....	214
(8) 확장 특성 .....	215
① 확장의 필수 특성 .....	216
② 확장의 선택적 특성 .....	216

(9) 사용자 정의 노드 대화 상자 관리 .....	219
(10) 사용자 정의 노드 대화 상자의 현지화된 버전 생성 .....	222
(11) Python for Spark 를 사용하여 데이터 가져오기 및 내보내기 .....	224
(12) R 을 사용하여 데이터 가져오기 및 내보내기 .....	224
V. IBM SPSS Modeler CRISP-DM 안내서 .....	226
1. CRISP-DM 소개 .....	226
1) CRISP-DM 도움말 개요 .....	226
(1) IBM SPSS Modeler 의 CRISP-DM .....	227
① CRISP-DM 프로젝트 도구 .....	227
② CRISP-DM 에 대한 도움말 .....	228
(2) 추가 자원 .....	228
2. 비즈니스 이해 .....	228
1) 비즈니스 이해 개요 .....	228
2) 비즈니스 목표 결정 .....	229
(1) E-소매 예제--비즈니스 목표 찾기 .....	229
(2) 비즈니스 배경 컴파일 .....	230
(3) 비즈니스 목표 정의 .....	230
(4) 비즈니스 성공 기준 .....	231
3) 상황 평가 .....	231
(1) E-소매 예제--상황 평가 .....	232
(2) 자원 명세 .....	232
(3) 요구사항, 가정 및 제약조건 .....	233
(4) 위험 및 비상사태 .....	234
(5) 용어 .....	234
(6) 비용/혜택 분석 .....	234
4) 데이터 마이닝 목적 결정 .....	235
(1) 데이터 마이닝 목적 .....	235

(2) E-소매 예제--데이터 마이닝 목적 .....	236
(3) 데이터 마이닝 성공 기준 .....	236
5) 프로젝트 계획 생성 .....	236
(1) 프로젝트 계획 작성 .....	237
(2) 샘플 프로젝트 계획 .....	237
(3) 도구 및 기법 평가 .....	238
6) 다음 단계에 대한 준비 여부 .....	238
3. 데이터 이해 .....	239
1) 데이터 이해 개요 .....	239
2) 초기 데이터 수집 .....	239
(1) E-소매 예제--초기 데이터 수집 .....	240
(2) 데이터 수집 보고서 작성 .....	240
3) 데이터 설명 .....	240
(1) E-소매 예제--데이터 설명 .....	241
(2) 데이터 설명 보고서 작성 .....	241
4) 데이터 탐색 .....	242
(1) E-소매 예제--데이터 탐색 .....	242
(2) 데이터 탐색 보고서 작성 .....	243
5) 데이터 품질 확인 .....	243
(1) E-소매 예제--데이터 품질 확인 .....	244
(2) 데이터 품질 보고서 작성 .....	244
6) 다음 단계에 대한 준비 여부 .....	245
4. 데이터 준비 .....	245
1) 데이터 준비 개요 .....	245
2) 데이터 선택 .....	246
(1) E-소매 예제--데이터 선택 .....	246
(2) 데이터 포함 또는 제외 .....	246

3) 데이터 정리 .....	247
(1) E-소매 예제--데이터 정리 .....	247
(2) 데이터 정리 보고서 작성 .....	248
4) 새 데이터 구축 .....	248
(1) E-소매 예제--데이터 구축 .....	249
(2) 속성 파생 .....	249
5) 데이터 통합 .....	250
(1) E-소매 예제--데이터 통합 .....	250
(2) 통합 태스크 .....	250
6) 데이터 형식화 .....	251
7) 모델링 준비 여부 .....	251
5. 모델링 .....	252
1) 모델링 개요 .....	252
2) 모델링 기법 선택 .....	252
(1) E-소매 예제--모델링 기법 .....	252
(2) 올바른 모델링 기법 선택 .....	253
(3) 모델링 가정 .....	253
3) 테스트 설계 생성 .....	254
(1) 테스트 설계 작성 .....	254
(2) E-소매 예제--테스트 설계 .....	255
4) 모델 작성 .....	255
(1) E-소매 예제--모델 작성 .....	255
(2) 모수 설정 .....	256
(3) 모델 실행 .....	256
(4) 모델 설명 .....	256
5) 모델 평가 .....	257
(1) 포괄적 모델 평가 .....	257

(2) E-소매 예제--모델 평가 .....	258
(3) 수정된 모수 추적 .....	258
6) 다음 단계에 대한 준비 여부 .....	258
6. 평가 .....	259
1) 평가 개요 .....	259
2) 결과 평가 .....	259
(1) E-소매 예제--결과 평가 .....	260
3) 프로세스 검토 .....	261
(1) E-소매 예제--검토 보고서 .....	261
4) 다음 단계 결정 .....	262
(1) E-소매 예제--다음 단계 .....	262
7. 배포 .....	262
1) 배포 개요 .....	262
2) 배포 계획 .....	263
(1) E-소매 예제--배포 계획 .....	263
3) 모니터링 및 유지보수 계획 .....	264
(1) E-소매 예제--모니터링 및 유지보수 .....	265
4) 최종 보고서 생성 .....	265
(1) 최종 프리젠테이션 준비 .....	266
(2) E-소매 예제--최종 보고서 .....	266
5) 최종 프로젝트 검토 수행 .....	266
(1) E-소매 예제--최종 검토 .....	267
VI. IBM SPSS Modeler Text Analytics 도움말 .....	268
1. IBM SPSS Modeler Text Analytics 정보 .....	268
1) IBM SPSS Modeler Text Analytics 업그레이드 .....	269
2) 텍스트 마이닝 정보 .....	269
(1) 추출 작동 방법 .....	273

(2) 범주화 작동 방법 .....	276
3) IBM SPSS Modeler Text Analytics 노드 .....	277
4) 애플리케이션 .....	278
2. 소스 텍스트에서 읽기 .....	279
1) 파일 목록 노드 .....	279
(1) 파일 목록 노드: 설정 탭 .....	280
(2) 파일 목록 노드: 기타 탭 .....	281
(3) 텍스트 마이닝에서 파일 목록 노드 사용 .....	281
2) 웹 피드 노드 .....	281
(1) 웹 피드 노드: 입력 탭 .....	282
(2) 웹 피드 노드: 레코드 탭 .....	283
(3) 웹 피드 노드: 내용 필터 탭 .....	285
(4) 텍스트 마이닝에서 웹 피드 노드 사용 .....	286
3) 언어 노드 .....	287
(1) 언어 노드: 설정 탭 .....	287
3. 개념 및 범주 마이닝 .....	288
1) 텍스트 마이닝 모델링 노드 .....	290
(1) 텍스트 마이닝 노드: 필드 탭 .....	290
① 필드 탭의 문서 설정 .....	292
(2) 텍스트 마이닝 노드: 모델 탭 .....	294
① 대화형 작성 .....	295
② 직접 생성 .....	297
③ 템플릿 및 TAP 에서 자원 복사 .....	297
(3) 텍스트 마이닝 노드: 전문가 탭 .....	299
(4) 시간 절약을 위한 업스트림 표본추출 .....	301
(5) 스트림에서 텍스트 마이닝 노드 사용 .....	302
2) 텍스트 마이닝 너짓: 개념 모델 .....	303

(1) 개념 모델: 모델 탭 .....	303
① 스코어링에 개념 포함을 위한 옵션 .....	305
② 개념 모델의 기본 용어 .....	306
(2) 개념 모델: 설정 탭 .....	306
(3) 개념 모델: 필드 탭 .....	308
(4) 개념 모델: 요약 탭 .....	309
(5) 스트림에서 개념 모델 너깃 사용 .....	309
3) 텍스트 마이닝 너깃: 범주 모델 .....	312
(1) 범주 모델 너깃: 모델 탭 .....	313
(2) 범주 모델 너깃: 설정 탭 .....	315
(3) 범주 모델 너깃: 기타 탭 .....	317
(4) 스트림에서 범주 모델 너깃 사용 .....	317
4. 텍스트 링크 마이닝 .....	320
1) 텍스트 링크 분석 노드 .....	320
(1) 텍스트 링크 분석 노드: 필드 탭 .....	321
(2) 텍스트 링크 분석 노드: 전문가 탭 .....	323
(3) TLA 노드 출력 .....	325
(4) TLA 결과 캐싱 .....	325
(5) 스트림에서 텍스트 링크 분석 노드 사용 .....	326
5. 외부 소스 텍스트 찾아보기 .....	328
1) 파일 뷰어 노드 .....	328
(1) 파일 뷰어 노드 설정 .....	329
(2) 파일 뷰어 노드 사용 .....	329
6. 스크립팅을 위한 노드 특성 .....	331
1) 파일 목록 노드: filelistnode .....	331
2) 웹 피드 노드: webfeednode .....	331
3) 언어 노드: languageidentifier .....	333

4) 텍스트 마이닝 노드: TextMiningWorkbench .....	333
5) 텍스트 마이닝 모델 너깃: TMWBModelApplier .....	335
6) 텍스트 링크 분석 노드: textlinkanalysis .....	337
7. 대화형 워크벤치 모드 .....	338
1) 범주 및 개념 보기 .....	339
2) 군집 보기 .....	342
3) 텍스트 링크 분석 보기 .....	344
4) 자원 편집기 보기 .....	347
5) 옵션 설정 .....	348
(1) 옵션: 세션 탭 .....	348
(2) 옵션: 표시 탭 .....	349
(3) 옵션: 사운드 탭 .....	350
6) 도움말에 대한 Microsoft Internet Explorer 설정 .....	350
7) 모델 너깃 및 모델링 노드 생성 .....	350
8) 모델링 노드 업데이트 및 저장 .....	351
9) 세션 닫기 및 종료 .....	351
10) 내게 필요한 옵션의 키보드 기능 .....	352
(1) 대화 상자의 단축키 .....	353
8. 개념 및 유형 추출 .....	354
1) 추출 결과: 개념 및 유형 .....	354
2) 데이터 추출 .....	356
3) 추출 결과 필터링 .....	359
4) 개념 맵 탐색 .....	361
(1) 개념 맵 지수 작성 .....	363
5) 추출 결과 세분화 .....	364
(1) 동의어 추가 .....	365
(2) 유형에 개념 추가 .....	366

(3) 추출에서 개념 제외 .....	368
(4) 단어 강제 추출 .....	368
9. 텍스트 데이터 범주화 .....	369
1) 범주 분할창 .....	370
2) 범주 작성을 위한 방법 및 전략 .....	372
(1) 범주 작성 방법 .....	373
(2) 범주 작성 전략 .....	373
(3) 범주 작성을 위한 팁 .....	374
(4) 최상의 디스크립터 선택 .....	375
3) 범주 정보 .....	378
(1) 범주 특성 .....	379
4) 데이터 분할창 .....	380
(1) 범주 관련성 .....	381
(2) 반응에 플래그 지정 .....	382
5) 범주 작성 .....	383
(1) 고급 언어학적 설정 .....	386
① 링크 예외 쌍 관리 .....	388
(2) 언어학적 기술 정보 .....	388
① 개념 루트 파생 .....	389
② 개념 포함 .....	391
③ 시맨틱 네트워크 .....	392
④ 동시 발생 규칙 .....	393
(3) 고급 빈도 설정 .....	394
6) 범주 확장 .....	396
7) 수동으로 범주 작성 .....	399
(1) 범주 새로 작성 또는 이름 변경 .....	400
(2) 끌어서 놓기로 범주 작성 .....	400

8) 범주 규칙 사용 .....	401
(1) 범주 규칙 구문 .....	402
(2) 범주 규칙에서 TLA 패턴 사용 .....	404
(3) 범주 규칙에서 와일드카드 사용 .....	407
(4) 범주 규칙 예제 .....	409
(5) 범주 규칙 작성 .....	411
(6) 규칙 편집 및 삭제 .....	412
9) 사전 정의된 범주 가져오기 및 내보내기 .....	413
(1) 사전 정의된 범주 가져오기 .....	413
① 평면 목록 형식 .....	415
② 최소 형식 .....	415
③ 들여쓰기 형식 .....	416
(2) 범주 내보내기 .....	418
10) 텍스트 분석 패키지 사용 .....	419
(1) 텍스트 분석 패키지 작성 .....	420
(2) 텍스트 분석 패키지 로드 .....	421
(3) 텍스트 분석 패키지 업데이트 .....	421
11) 범주 편집 및 세분화 .....	423
(1) 디스크립터를 범주에 추가 .....	423
(2) 범주 디스크립터 편집 .....	423
(3) 범주 이동 .....	424
(4) 범주 평면화 .....	424
(5) 범주 병합 또는 결합 .....	425
(6) 범주에 문서 강제 적용/해제 .....	425
(7) 범주 삭제 .....	426
10. 군집 분석 .....	427
1) 군집 작성 .....	428

(1) 유사성 링크 값 계산 .....	430
2) 군집 탐색 .....	431
(1) 군집 정의 .....	432
11. 텍스트 링크 분석 탐색 .....	433
1) TLA 패턴 결과 추출 .....	434
2) 유형 및 개념 패턴 .....	435
3) TLA 결과 필터링 .....	436
4) 데이터 분할창 .....	438
(1) 반응에 플래그 지정 .....	440
5) 유형 재할당 규칙 .....	440
12. 그래프 시각화 .....	444
1) 범주 그래프 및 도표 .....	444
(1) 범주 막대형 차트 .....	445
(2) 범주 웹 그래프 .....	446
(3) 범주 웹 테이블 .....	446
(4) 오류 수정 .....	446
2) 군집 그래프 .....	447
(1) 개념 웹 그래프 .....	447
(2) 군집 웹 그래프 .....	448
3) 텍스트 링크 분석 그래프 .....	448
(1) 개념 웹 그래프 .....	449
(2) 유형 웹 그래프 .....	449
4) 그래프 도구 모음 및 팔레트 사용 .....	450
13. 세션 자원 편집기 .....	451
1) 자원 편집기에서 자원 편집 .....	452
2) 템플릿 작성 및 업데이트 .....	453
3) 자원 템플릿 전환 .....	454

14. 템플리트 및 자원 .....	455
1) 템플리트 편집기 vs. 자원 편집기 .....	456
2) 편집기 인터페이스 .....	457
3) 템플리트 열기 .....	460
4) 템플리트 저장 .....	460
5) 로드 후 노드 자원 업데이트 .....	461
6) 템플리트 관리 .....	462
7) 템플리트 가져오기 및 내보내기 .....	463
8) 템플리트 편집기 종료 .....	463
9) 자원 백업 .....	464
10) 자원 파일 가져오기 .....	464
15. 라이브러리에 대한 작업 .....	465
1) 제공된 라이브러리 .....	466
2) 라이브러리 작성 .....	467
3) 공용 라이브러리 추가 .....	468
4) 용어 및 유형 찾기 .....	468
5) 라이브러리 보기 .....	469
6) 로컬 라이브러리 관리 .....	470
(1) 로컬 라이브러리 이름 변경 .....	470
(2) 로컬 라이브러리 사용 안함 .....	470
(3) 로컬 라이브러리 삭제 .....	471
7) 공용 라이브러리 관리 .....	471
8) 라이브러리 공유 .....	472
(1) 라이브러리 출판 .....	474
(2) 라이브러리 업데이트 .....	474
9) 충돌 해결 .....	475
16. 라이브러리 사전 정보 .....	476

1) 유형 사전 .....	477
(1) 내장 유형 .....	478
(2) 유형 작성 .....	478
(3) 용어 추가 .....	480
(4) 용어 강제 실행 .....	483
(5) 유형 이름 변경 .....	484
(6) 유형 이동 .....	484
(7) 유형 사용 안함 및 삭제 .....	485
2) 대체/동의어 사전 .....	485
(1) 동의어 정의 .....	486
(2) 선택적 요소 정의 .....	488
(3) 대체 사용 안함 및 삭제 .....	489
3) 제외 사전 .....	489
17. 고급 자원에 대한 정보 .....	491
1) 찾기 .....	492
2) 바꾸기 .....	493
3) 자원의 대상 언어 .....	494
4) 퍼지 그룹화 .....	494
5) 비언어 엔티티 .....	495
(1) 정규식 정의 .....	496
(2) 정규화 .....	499
(3) 구성 .....	500
6) 언어 처리 .....	501
(1) 추출 패턴 .....	502
(2) 강제 실행된 정의 .....	505
(3) 약어 .....	506
18. 텍스트 링크 규칙에 대한 정보 .....	506

1) 텍스트 링크 규칙에 대해 작업할 위치 .....	507
2) 시작 위치 .....	508
3) 규칙 편집 또는 작성 시기 .....	508
4) 텍스트 링크 분석 결과 시뮬레이션 .....	509
(1) 시뮬레이션에 대한 데이터 정의 .....	510
(2) 시뮬레이션 결과 이해 .....	511
5) 트리에서 규칙 및 매크로 탐색 .....	512
6) 매크로에 대한 작업 .....	513
(1) 매크로 작성 및 편집 .....	514
(2) 매크로 사용 안함 및 삭제 .....	515
(3) 오류 확인, 저장 및 취소 .....	515
(4) 특수 매크로: mTopic, mNonLingEntities, SEP .....	516
7) 텍스트 링크 규칙에 대한 작업 .....	517
(1) 규칙 작성 및 편집 .....	521
(2) 규칙 사용 안함 및 삭제 .....	522
(3) 오류 확인, 저장 및 취소 .....	522
8) 규칙 순서 처리 .....	523
9) 규칙 세트에 대한 작업(다중 전달) .....	525
10) 규칙 및 매크로에 대해 지원되는 요소 .....	526
11) 소스 모드에서 보기 및 작업 .....	528

## 7. In-Database 마이닝

### 1) In-Database 마이닝

#### (1) 데이터베이스 모델링 개요

IBM® SPSS® Modeler Server는 IBM Netezza, Oracle Data Miner, Microsoft Analysis Services를 포함한 데이터베이스 벤더로부터 사용할 수 있는 데이터 마이닝 및 모델링 도구와의 통합을 지원합니다. 모두 IBM SPSS Modeler 애플리케이션 내에서 시작하여 데이터베이스 내에 모델을 작성하고, 스코어링하고, 저장할 수 있습니다. 이를 통해 이 벤더가 제공하는 데이터베이스 원시 알고리즘을 활용하면서 데이터베이스의 성능과 IBM SPSS Modeler의 분석 기능 및 편리한 사용을 결합할 수 있습니다. 모델은 데이터베이스 내부에서 작성되므로 필요한 경우 일반적인 방식으로 IBM SPSS Modeler 인터페이스를 통해 찾아서 스코어링한 후 IBM SPSS Modeler Solution Publisher를 사용하여 배포할 수 있습니다. 지원되는 알고리즘은 IBM SPSS Modeler의 데이터베이스 모델링 팔레트에 있습니다.

IBM SPSS Modeler를 사용하여 데이터베이스 원시 알고리즘에 액세스하면 다음과 같은 여러 가지 장점이 있습니다.

- In-Database 알고리즘은 종종 데이터베이스 서버와 밀접하게 통합되어 향상된 성능을 제공할 수 있습니다.
- "데이터베이스에서" 작성되고 스코어링된 모델은 데이터베이스에 액세스할 수 있는 애플리케이션에 쉽게 배치하고 이 애플리케이션과 공유할 수 있습니다.

**SQL 생성.** In-Database 모델링은 "SQL 푸시백"이라고도 알려져 있는 SQL 생성과 구별됩니다. 이 기능을 사용하면 성능 향상을 위해 데이터베이스에 "푸시백"(즉, 데이터베이스에서 실행)할 수 있는 원시 IBM SPSS Modeler 조작에 대한 SQL문을 생성할 수 있습니다. 예를 들어, 병합, 통합 및 선택 노드는 모두 이 방식으로 데이터베이스에 푸시백할 수 있는 SQL 코드를 생성합니다. 데이터베이스 모델링과 함께 SQL 생성을 사용하면 데이터베이스의 시작부터 끝까지 실행될 수 있는 스트림이 생성되어 IBM SPSS Modeler에서 실행되는 스트림보다 상당히 성능이 향상됩니다.

 **참고:** 데이터베이스 모델링 및 SQL 최적화를 위해서는 IBM SPSS Modeler 컴퓨터에서 IBM SPSS Modeler Server 연결성이 설정되어 있어야 합니다. 이 설정이 사용 가능하면 데이터베이스 알고리즘에 액세스하고, SQL을 IBM SPSS Modeler에서 직접 푸시백하고, IBM SPSS Modeler Server에 액세스할 수 있습니다. 현재 라이선스 상태를 검증하려면 IBM SPSS Modeler 메뉴에서 다음을 선택하십시오.

도움말 > 정보 > 추가 세부사항

연결성이 사용 가능으로 설정되면 라이선스 상태 탭에 **서버 사용 가능** 옵션이 표시됩니다.

지원되는 알고리즘에 대한 정보는 특정 벤더에 대한 후속 절을 참조하십시오.

### ① 필요사항

데이터베이스 모델링을 수행하려면 다음의 설정이 필요합니다.

- 필수 분석 구성요소(Microsoft Analysis Services, Oracle Data Miner)가 설치된 적절한 데이터베이스에 대한 ODBC 연결
- IBM® SPSS® Modeler에서는 헬퍼 애플리케이션 대화 상자(도구 > **헬퍼 애플리케이션**)에서 데이터베이스 모델링을 사용으로 설정해야 합니다.
- IBM SPSS Modeler 및 IBM SPSS Modeler Server(사용된 경우)의 사용자 옵션 대화 상자에서 **SQL 생성 및 SQL 최적화** 설정을 사용으로 설정해야 합니다. SQL 최적화는 데이터베이스 모델링이 작동하기 위해 엄격하게 요구되지 않지만 성능상 이유로 강력하게 권장됩니다.

**참고:** 데이터베이스 모델링 및 SQL 최적화를 위해서는 IBM SPSS Modeler 컴퓨터에서 IBM SPSS Modeler Server 연결성이 설정되어 있어야 합니다. 이 설정이 사용 가능하면 데이터베이스 알고리즘에 액세스하고, SQL을 IBM SPSS Modeler에서 직접 푸시백하고, IBM SPSS Modeler Server에 액세스할 수 있습니다. 현재 라이선스 상태를 검증하려면 IBM SPSS Modeler 메뉴에서 다음을 선택하십시오.

도움말 > 정보 > 추가 세부사항

연결성이 사용 가능으로 설정되면 라이선스 상태 탭에 **서버 사용 가능** 옵션이 표시됩니다.

자세한 정보는 특정 벤더에 대한 후속 절을 참조하십시오.

### ② 모델 작성

데이터베이스 알고리즘을 사용하여 모델을 작성하고 스코어링하는 프로세스는 IBM® SPSS® Modeler에서 다른 유형의 데이터 마이닝과 비슷합니다. 노드에 대해 작업하고 "너깃"을 모델링하는 일반적인 프로세스는 IBM SPSS Modeler에서 작업할 때의 다른 스트림과 비슷합니다. 유일한 차이점은 실제 처리 및 모델 작성이 데이터베이스에 푸시백되는 것입니다.

데이터베이스 모델링 스트림은 개념적으로 IBM SPSS Modeler의 다른 데이터 스트림과 동일하지만 이 스트림은 Microsoft 의사결정 트리 노드를 사용한 모델 작성 등을 포함한 모든 조작을 데이터베이스에서 수행합니다. 스트림을 실행하면 IBM SPSS Modeler가 결과 모델을 작성하고 저장하도록 데이터베이스에 지시하며 세부사항이 IBM SPSS Modeler에 다운로드됩니다. In-Database 실행은 스트림에서 보라색 음영 처리된 노드를 사용하여 표시됩니다.

### ③ 데이터 준비

데이터베이스 원시 알고리즘이 사용되는지 여부에 관계없이 성능을 향상시키기 위해 가능할 때마다 데이터 준비를 데이터베이스에 푸시백해야 합니다.

- 원래 데이터가 데이터베이스에 저장되는 경우 목표는 모든 필수 업스트림 조작을 SQL로 변환될 수 있게 하여 해당 데이터를 데이터베이스에서 유지하는 것입니다. 그러면 데이터가 IBM® SPSS® Modeler에 다운로드되는 것을 방지하여 성능 향상을 무효화하는 병목 현상을 피하고 전체 스트림을 데이터베이스에서 실행할 수 있습니다.
- 원래 데이터가 데이터베이스에 저장되지 않는 경우에는 데이터베이스 모델링을 계속 사용할 수 있습니다. 이 경우 데이터 준비는 IBM SPSS Modeler에서 수행되며 준비된 데이터 세트는 모델 작성을 위해 자동으로 데이터베이스에 업로드됩니다.

#### ④ 모델 스코어링

In-Database 마이닝을 사용하여 IBM® SPSS® Modeler에서 생성된 모델은 일반적인 IBM SPSS Modeler 모델과 다릅니다. 해당 모델은 생성된 모델 "너깃"으로 모델 관리자에 표시되지만 실제로는 원격 데이터 마이닝 또는 데이터베이스 서버에 보유되는 원격 모델입니다. IBM SPSS Modeler에 표시되는 것은 단순히 이 원격 모델에 대한 참조입니다. 즉, 표시되는 IBM SPSS Modeler 모델은 데이터베이스 서버 호스트 이름, 데이터베이스 이름, 모델 이름 등의 정보가 포함된 "비어 있는" 모델입니다. 이는 데이터베이스 원시 알고리즘을 사용하여 작성되는 모델을 찾아보고 스코어링할 때 이해할 중요한 차이입니다.

모델을 작성한 후에는 IBM SPSS Modeler의 생성된 다른 모델과 마찬가지로 스코어링을 위해 스트림에 해당 모델을 추가할 수 있습니다. 업스트림 조작은 제외하고 모든 스코어링이 데이터베이스 내에서 수행됩니다. (가능한 경우 성능 향상을 위해 업스트림 조작은 여전히 데이터베이스로 푸시백할 수 있지만 이는 스코어링 수행을 위한 요구사항은 아닙니다.) 또한 데이터베이스 벤더가 제공하는 표준 브라우저를 사용하여 대부분의 경우 생성된 모델을 찾아볼 수 있습니다.

찾아보기와 스코어링 모두에 대해 Oracle Data Miner 또는 Microsoft Analysis Services를 실행 중인 서버에 대한 활성 연결이 필요합니다.

#### 결과 보기 및 설정 지정

결과를 보고 스코어링에 대한 설정을 지정하려면 스트림 캔버스에서 모델을 두 번 클릭하십시오. 또는 모델을 마우스 오른쪽 단추로 클릭한 후 **찾아보기** 또는 **편집**을 선택할 수 있습니다. 구체적인 설정은 모델 유형에 따라 다릅니다.

#### ⑤ 데이터베이스 모델 내보내기 및 저장

데이터베이스 모델 및 요약은 파일 메뉴의 옵션을 사용하여 IBM® SPSS® Modeler에서 작성된 기타 모델과 동일한 방식으로 모델 브라우저에서 내보낼 수 있습니다.

1. 모델 브라우저의 파일 메뉴에 있는 다음 옵션 중에서 선택하십시오.

- 텍스트 내보내기 - 모델 요약을 텍스트 파일로 내보냄
- HTML 내보내기 - 모델 요약을 HTML 파일로 내보냄
- PMML 내보내기(IBM Db2 IM 모델의 경우에만 지원됨) - 모델을 PMML(Predictive Model Markup Language)로 내보내어 다른 PMML 호환 소프트웨어와 함께 사용할 수 있게 함

 참고: 파일 메뉴에서 **노드 저장**을 선택하여 생성된 모델을 저장할 수도 있습니다.

## ⑥ 모델 일관성

생성되는 각각의 데이터베이스 모델에 대해 IBM® SPSS® Modeler는 데이터베이스에 저장되는 동일한 이름의 모델에 대한 참조와 함께 모델 구조에 대한 설명을 저장합니다. 생성된 모델의 서버 탭에는 데이터베이스에서 실제 모델과 일치하는 해당 모델에 대해 생성된 고유 키가 표시됩니다.

IBM SPSS Modeler는 이 무작위로 생성된 키를 사용하여 모델이 일관성을 계속 유지하는지 확인합니다. 이 키는 작성될 때 모델의 설명에 저장됩니다. 배포 스트림을 실행하기 전에 키가 일치하는지 확인하는 것이 좋습니다.

1. 해당 설명을 IBM SPSS Modeler가 저장한 무작위 키와 비교하여 데이터베이스에 저장된 모델의 일관성을 확인하려면 **확인** 단추를 클릭하십시오. 데이터베이스 모델을 찾을 수 없거나 키가 일치하지 않으면 오류가 보고됩니다.

## ⑦ 생성된 SQL 보기 및 내보내기

생성된 SQL 코드는 실행 전에 미리 볼 수 있어서 디버깅을 위해 유용할 수 있습니다.

## 2) Microsoft Analysis Services를 사용한 데이터베이스 모델링

### (1) IBM SPSS Modeler 및 Microsoft Analysis Services

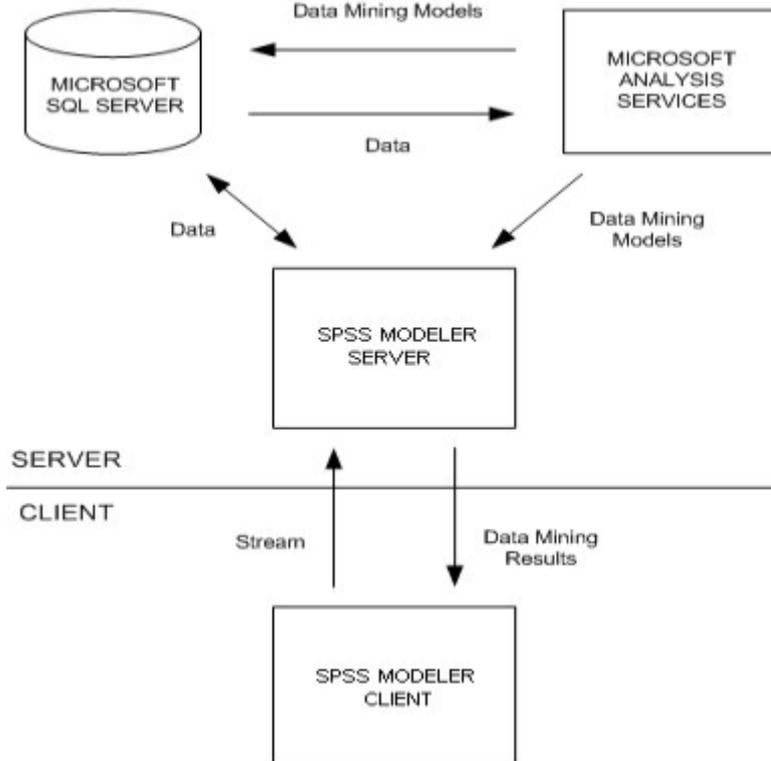
IBM® SPSS® Modeler는 Microsoft SQL Server Analysis Services와의 통합을 지원합니다. 이 기능은 IBM SPSS Modeler에서 모델링 노드로 구현되며 데이터베이스 모델링 팔레트에서 사용할 수 있습니다. 해당 팔레트가 표시되지 않으면 헬퍼 애플리케이션 대화 상자에서 Microsoft 탭에 있는 MS Analysis Services 통합을 사용으로 설정하여 이 기능을 활성화할 수 있습니다. 자세한 정보는 Analysis Services와의 통합 사용의 내용을 참조하십시오.

IBM SPSS Modeler는 다음과 같은 Analysis Services 알고리즘의 통합을 지원합니다.

- 의사결정 트리
- 군집화
- 연관 규칙
- Naive Bayes
- 선형 회귀
- 신경망
- 로지스틱 회귀분석
- 시계열
- 시퀀스 군집화

다음 다이어그램에서는 클라이언트로부터 IBM SPSS Modeler Server에 의해 In-Database 마이닝이 관리되는 서버로의 데이터 흐름을 보여줍니다. 모델 작성은 Analysis Services를 사용하여 수행됩니다. 결과 모델은 Analysis Services에 의해 저장됩니다. 이 모델에 대한 참조는 IBM SPSS Modeler 스트림 내에서 유지됩니다. 그런 다음 해당 모델은 스코어링을 위해 Analysis Services로부터 Microsoft SQL Server 또는 IBM SPSS Modeler로 다운로드됩니다.

그림 1. 모델 작성 중 IBM SPSS Modeler, Microsoft SQL Server 및 Microsoft Analysis Services 간 데이터 흐름



참고: IBM SPSS Modeler Server는 필수는 아니지만 사용할 수는 있습니다. IBM SPSS Modeler 클라이언트는 In-Database 마이닝 계산을 자체적으로 처리할 수 있습니다.

## ① Microsoft Analysis Services와의 통합을 위한 요구사항

IBM® SPSS® Modeler와 함께 Analysis Services 알고리즘을 사용하여 In-Database 모델링을 수행하려면 다음과 같은 전제조건이 있습니다. 데이터베이스 관리자에게 문의하여 이 조건이 충족되는지 확인해야 할 수 있습니다.

- Windows의 IBM SPSS Modeler Server 설치(분산 모드)에 대해 실행 중인 IBM SPSS Modeler. UNIX 플랫폼은 Analysis Services와의 이 통합에서 지원되지 않습니다.

❖ **중요사항:** IBM SPSS Modeler 사용자는 추가 IBM SPSS Modeler Server 요구사항에 나열된 URL에서 Microsoft로부터 얻을 수 있는 SQL 원시 클라이언트 드라이버를 사용하여 ODBC 연결을 구성해야 합니다. IBM SPSS Data Access Pack과 함께 제공되고 일반적으로 IBM SPSS Modeler의 기타 사용에 대해 권장되는 드라이버는 이 용도에는 권장되지 않습니다. IBM SPSS Modeler는 SQL Server 인증을 지원하지 않으므로 **통합된 Windows 인증 사용**이 사용으로 설정된 SQL Server를 사용하기 위해 이 드라이버를 구성해야 합니다. ODBC 데이터 소스에 대한 작성 및 설정에 관한 문의사항이 있으면 데이터베이스 관리자에게 문의하십시오.

- SQL Server는 설치되어 있어야 하지만, 반드시 IBM SPSS Modeler와 동일한 호스트에 설치할 필요는 없습니다. IBM SPSS Modeler 사용자는 데이터를 읽고 쓰고 테이블 및 보기를 삭제하고 작성하는 데 필요한 충분한 권한을 가지고 있어야 합니다.

❗ **참고:** SQL Server Enterprise Edition이 권장됩니다. Enterprise Edition은 알고리즘 결과를 조정하는 고급 모수를 제공하여 추가적인 유연성을 제공합니다. Standard Edition 버전은 동일한 모수를 제공하지만 사용자에게 고급 모수 중 일부의 편집을 허용하지 않습니다.

- Microsoft SQL Server Analysis Services가 SQL Server와 동일한 호스트에 설치되어 있어야 합니다.

## 추가 IBM SPSS Modeler Server 요구 사항

Analysis Services 알고리즘을 IBM SPSS Modeler Server와 함께 사용하려면 다음과 같은 구성 요소가 IBM SPSS Modeler Server 호스트 시스템에 설치되어 있어야 합니다.

❗ **참고:** SQL Server가 IBM SPSS Modeler Server와 동일한 호스트에 설치되어 있는 경우에는 이들 구성요소가 이미 설치되어 있습니다.

- Microsoft SQL Server Analysis Services 10.0 OLE DB Provider(사용자의 운영 체제에 맞는 올바른 변형을 선택해야 함)
- Microsoft SQL Server Native Client(사용자의 운영 체제에 맞는 올바른 변형을 선택해야 함)
- Microsoft SQL Server 2008 또는 2012를 사용하고 있는 경우에는 Microsoft Core XML Services(MSXML) 6.0도 필요할 수 있습니다.

이 구성요소를 다운로드하려면 [www.microsoft.com/downloads](http://www.microsoft.com/downloads)로 이동하여 **.NET Framework** 또는 **SQL Server Feature Pack**(다른 모든 구성요소의 경우)을 검색한 후 사용자의 SQL Server 버전에 맞는 최신 팩을 선택하십시오.

이를 위해서는 다른 패키지를 먼저 설치해야 할 수 있습니다(해당 패키지도 Microsoft 다운로드 웹 사이트에서 얻을 수 있음).

### 추가 IBM SPSS Modeler 요구 사항

Analysis Services 알고리즘을 IBM SPSS Modeler와 함께 사용하려면 위와 동일한 구성요소를 설치해야 하며 클라이언트에서 다음을 추가해야 합니다.

- Microsoft SQL Server Datamining Viewer Controls(사용자의 운영 체제에 맞는 올바른 변형을 선택해야 함) - 이 구성요소에는 다음 구성요소도 필요합니다.
- Microsoft ADOMD.NET

이 구성요소를 다운로드하려면 [www.microsoft.com/downloads](http://www.microsoft.com/downloads)로 이동하여 **SQL Server Feature Pack**을 검색한 후 사용자의 SQL Server 버전에 맞는 최신 팩을 선택하십시오.

**참고:** 데이터베이스 모델링 및 SQL 최적화를 위해서는 IBM SPSS Modeler 컴퓨터에서 IBM SPSS Modeler Server 연결성이 설정되어 있어야 합니다. 이 설정이 사용 가능하면 데이터베이스 알고리즘에 액세스하고, SQL을 IBM SPSS Modeler에서 직접 푸시백하고, IBM SPSS Modeler Server에 액세스할 수 있습니다. 현재 라이선스 상태를 검증하려면 IBM SPSS Modeler 메뉴에서 다음을 선택하십시오.

### 다음말 > 정보 > 추가 세부사항

연결성이 사용 가능으로 설정되면 라이선스 상태 탭에 **서버 사용 가능 옵션**이 표시됩니다.

### ② Analysis Services와의 통합 사용

Analysis Services와 IBM® SPSS® Modeler의 통합을 사용하려면 SQL Server 및 Analysis Services를 구성하고 ODBC 소스를 작성하고 IBM SPSS Modeler 헬퍼 애플리케이션 대화 상자에서 통합을 사용으로 설정하고 SQL 생성 및 최적화를 사용으로 설정해야 합니다.

**참고:** Microsoft SQL Server 및 Microsoft Analysis Services를 사용할 수 있어야 합니다. 자세한 정보는 Microsoft Analysis Services와의 통합을 위한 요구사항의 내용을 참조하십시오.

### SQL Server 구성

데이터베이스 내에서 스코어링이 수행될 수 있도록 SQL Server를 구성하십시오.

1. SQL Server 호스트 시스템에서 다음 레지스트리 키를 작성하십시오.

```
HKEY_LOCAL_MACHINE\SOFTWARE\Microsoft\MSSQLServer\Providers\MSOLAP
```

2. 다음 DWORD 값을 이 키에 추가하십시오.

```
AllowInProcess 1
```

3. 이 변경사항을 작성한 후 SQL Server를 다시 시작하십시오.

### Analysis Services 구성

IBM SPSS Modeler가 Analysis Services와 통신하려면 먼저 분석 서버 특성 대화 상자에서 두 가지 설정을 수동으로 구성해야 합니다.

1. MS SQL Server Management Studio를 통해 분석 서버에 로그인하십시오.
2. 서버 이름을 마우스 오른쪽 단추로 클릭한 후 특성을 선택하여 특성 대화 상자에 액세스하십시오.
3. **고급(모든) 특성 표시** 선택란을 선택하십시오.
4. 다음과 같은 특성을 변경하십시오.

- DataMining\AllowAdHocOpenRowsetQueries의 값을 True로 변경하십시오(기본값은 False임).
- DataMining\AllowProvidersInOpenRowset의 값을 [all]로 변경하십시오(기본값이 없음).

### SQL Server에 대한 ODBC DSN 작성

데이터베이스를 읽거나 데이터베이스에 쓰려면 필요에 따라 읽기 또는 쓰기 권한을 가지고 관련 데이터베이스에 대해 ODBC 데이터 소스가 설치 및 구성되어 있어야 합니다. Microsoft SQL 원시 클라이언트 ODBC 드라이버는 필수이며 SQL Server와 함께 자동으로 설치됩니다. *IBM SPSS Data Access Pack*과 함께 제공되고 일반적으로 *IBM SPSS Modeler의 기타 사용에 대해 권장되는 드라이버는 이 용도에는 권장되지 않습니다.* IBM SPSS Modeler와 SQL Server가 서로 다른 호스트에 상주하는 경우에는 Microsoft SQL 원시 클라이언트 ODBC 드라이버를 다운로드할 수 있습니다. 자세한 정보는 Microsoft Analysis Services와의 통합을 위한 요구사항의 내용을 참조하십시오.

ODBC 데이터 소스에 대한 작성 및 설정에 관한 문의사항이 있으면 데이터베이스 관리자에게 문의하십시오.

1. Microsoft SQL 원시 클라이언트 ODBC 드라이버를 사용하여 데이터 마이닝 프로세스에서 사용되는 SQL Server 데이터베이스를 가리키는 ODBC DSN을 작성하십시오. 나머지 기본 드라이버 설정을 사용해야 합니다.
2. 이 DSN의 경우 **통합된 Windows 인증 사용**이 선택되어 있는지 확인하십시오.

- IBM SPSS Modeler와 IBM SPSS Modeler Server가 서로 다른 호스트에서 실행 중인 경우

에는 각각의 호스트에서 동일한 ODBC DSN을 작성하십시오. 각 호스트에서 동일한 DSN 이름이 사용되는지 확인하십시오.

## IBM SPSS Modeler에서 Analysis Services 통합 사용

IBM SPSS Modeler가 Analysis Services를 사용할 수 있게 하려면 먼저 헬퍼 애플리케이션 대화 상자에서 서버 사양을 제공해야 합니다.

1. IBM SPSS Modeler 메뉴에서 다음을 선택하십시오.

도구 > 옵션 > 헬퍼 애플리케이션

2. **Microsoft** 탭을 클릭하십시오.

- **Microsoft Analysis Services 통합을 사용으로 설정하십시오.** IBM SPSS Modeler 창의 맨 아래에서 데이터베이스 모델링 팔레트를 사용으로 설정하고(아직 표시되지 않은 경우) Analysis Services 알고리즘에 대한 노드를 추가합니다.
- **분석 서버 호스트.** Analysis Services가 실행 중인 시스템의 이름을 지정하십시오.
- **분석 서버 데이터베이스.** 생략 기호(...) 단추를 클릭하여 사용 가능한 데이터베이스 중에서 선택할 수 있는 하위 대화 상자를 열어 원하는 데이터베이스를 선택하십시오. 목록은 지정된 분석 서버에 사용 가능한 데이터베이스로 채워져 있습니다. Microsoft Analysis Services는 데이터 마이닝 모델을 이름 지정된 데이터베이스에 저장하므로 IBM SPSS Modeler에 의해 작성된 Microsoft 모델이 저장되는 적절한 데이터베이스를 선택해야 합니다.
- **SQL Server 연결.** 분석 서버에 전달되는 데이터를 저장하기 위해 SQL Server 데이터베이스가 사용하는 DSN 정보를 지정하십시오. Analysis Services 데이터 마이닝 모델 작성을 위해 데이터를 제공하는 데 사용될 ODBC 데이터 소스를 선택하십시오. 플랫폼 파일 또는 ODBC 데이터 소스에서 제공된 데이터에서 Analysis Services 모델을 작성하는 경우 해당 데이터는 이 ODBC 데이터 소스가 가리키는 SQL Server 데이터베이스에서 작성된 임시 테이블에 자동으로 업로드됩니다.
- **데이터 마이닝 모델을 겹쳐쓰려고 할 때 경고.** 데이터베이스에 저장된 모델이 경고 없이 IBM SPSS Modeler에 의해 겹쳐써지지 않게 하려면 선택하십시오.

**참고:** 헬퍼 애플리케이션 대화 상자에서 작성된 설정은 다양한 Analysis Services 노드 내부에서 대체될 수 있습니다.

## SQL 생성 및 최적화 사용

1. IBM SPSS Modeler 메뉴에서 다음을 선택하십시오.

도구 > 스트림 특성 > 옵션

2. 탐색 분할창에서 **최적화** 옵션을 클릭하십시오.

3. **SQL 생성** 옵션이 사용으로 설정되어 있는지 확인하십시오. 이 설정은 데이터베이스 모델링이 작동하기 위해 필수입니다.

4. SQL 생성 최적화 및 기타 실행 최적화를 선택하십시오(엄격하게 요구되지 않지만 최적화된 성능을 위해서는 강력하게 권장됨).

## (2) Analysis Services를 사용하여 모델 작성

Analysis Services 모델 작성을 수행하려면 훈련 데이터 세트가 SQL Server 데이터베이스 내 테이블 또는 보기에 있어야 합니다. 데이터가 SQL Server에 있지 않거나 IBM® SPSS® Modeler에서 SQL Server에서 수행할 수 없는 데이터 준비의 일부로 처리되어야 하는 경우 해당 데이터는 모델을 작성하기 전에 SQL Server의 임시 테이블에 자동으로 업로드됩니다.

### ① Analysis Services 모델 관리

IBM® SPSS® Modeler를 통해 Analysis Services 모델을 작성하면 IBM SPSS Modeler에서 모델이 작성되고 SQL Server 데이터베이스에서 모델이 작성되거나 바뀝니다. IBM SPSS Modeler 모델은 데이터베이스 서버에 저장된 데이터베이스 모델의 콘텐츠를 참조합니다. IBM SPSS Modeler는 IBM SPSS Modeler 모델과 SQL Server 모델 모두에서 동일한 생성된 모델 키 문자열을 저장하여 일관성 확인을 수행할 수 있습니다.



**MS 의사결정 트리** 모델링 노드는 범주형 속성과 연속형 속성 모두의 예측 모델링에서 사용됩니다. 범주형 속성의 경우 이 노드는 데이터 세트의 입력 열 간 관계를 기반으로 예측을 작성합니다. 예를 들어, 자전거를 구매할 가능성이 있는 고객을 예측하는 시나리오에서 젊은 고객은 10명 중 9명이 자전거를 구입하지만 나이가 많은 고객은 10명 중 2명만 자전거를 구입하는 경우 이 노드는 연령이 자전거 구매의 좋은 예측변수라고 추론합니다. 의사결정 트리는 특정 결과에 대한 이 경향을 기반으로 예측을 작성합니다. 연속형 속성의 경우 이 알고리즘은 선형 회귀를 사용하여 의사결정 트리가 분할되는 위치를 결정합니다. 둘 이상의 열이 예측 가능으로 설정되거나 입력 데이터에 예측 가능으로 설정된 중첩된 테이블이 포함되어 있는 경우 노드는 각각의 예측 가능한 열에 대해 별도의 의사결정 트리를 작성합니다.



**MS 군집화** 모델링 노드는 반복 기법을 사용하여 데이터 세트의 케이스를 비슷한 특성을 포함하는 군집으로 그룹화합니다. 이 그룹화는 데이터 탐색, 데이터에서 이상 항목 식별 및 예측 작성을 위해 유용합니다. 군집화 모델은 데이터 세트에서 일상적인 관측을 통해 논리적으로 파생시킬 수 없는 관계를 식별합니다. 예를 들어, 자전거로 통근하는 사람들은 일반적으로 직장에서 먼 거리에 살지 않는다고 논리적으로 인식할 수 있습니다. 하지만 이 알고리즘은 명백하지 않은 자전거 통근자에 대한 기타 특성을 찾을 수 있습니다. 군집화 노드는 대상 필드가 지정되지 않은 기타 데이터 마이닝 노드와 다릅니다. 군집화 노드는 데이터가 존재하는 관계와 노드가 식별하는 군집에서 엄격하게 모델을 학습시킵니다.



**MS 연관 규칙** 모델링 노드는 추천 엔진에 유용합니다. 추천 엔진은 고객이 이미 구매했거나 관심을 표시한 항목을 기반으로 고객에게 제품을 추천합니다. 연관 모델은 개별 케이스와 케이스에 포함된 항목 둘 다에 대한 식별자가 포함된 데이터 세트에서 작성됩니다. 케이스의 항목 그룹을 항목 세트라고 합니다. 연관 모델은 일련의 항목 세트와 케이스 내에서 해당 항목이 그룹화되는 방식에 대해 설명하는 규칙으로 구성됩니다. 이 알고리즘이 식별하는 규칙은 고객의 장바구니에 이미 있는 항목을 기반으로 고객의 향후 구매 가능성을 예측하는 데 사용할 수 있습니다.



**MS Naive Bayes** 모델링 노드는 대상 필드와 예측변수 필드 간 조건부 확률을 계산하며 열이 독립적이라고 가정합니다. 이 모델은 제안된 모든 예측변수를 서로 독립된 것으로 취급하므로 naïve라는 이름이 사용됩니다. 이 방법은 다른 Analysis Services 알고리즘보다 계산상 덜 집중되므로 모델링의 예비 단계 동안 관계를 신속하게 발견하는 데 유용합니다. 이 노드를 사용하여 데이터의 초기 탐색을 수행한 후 결과를 적용하여 계산 시간이 더 걸리지만 더 정확한 결과를 제공할 수 있는 다른 노드로 추가적인 모델을 작성할 수 있습니다.



**MS 선형 회귀** 모델링 노드는 의사결정 트리 노드의 변형이며 여기서 MINIMUM\_LEAF\_CASES 모수는 노드가 마이닝 모델을 학습시키기 위해 사용하는 데이터 세트에 있는 케이스의 총 수 이상으로 설정됩니다. 이 방식으로 모수가 설정되면 노드는 분할을 작성하지 않으므로 선형 회귀를 수행합니다.



**MS 신경망** 모델링 노드는 예측 가능한 속성의 각 상태가 지정된 경우 입력 속성의 가능한 각각의 상태에 대한 확률을 계산한다는 점에서 MS 의사결정 트리 노드와 비슷합니다. 나중에 이 확률을 사용하여 입력 속성을 기반으로 예측된 속성의 결과를 예측할 수 있습니다.



**MS 로지스틱 회귀분석** 모델링 노드는 MS 신경망 노드의 변형이며 여기서 HIDDEN\_NODE\_RATIO 모수는 0(영)으로 설정됩니다. 이 설정은 은닉층이 포함되지 않은 신경망 모델을 작성하므로 로지스틱 회귀분석과 동등합니다.



**MS 시계열** 모델링 노드는 시간 경과에 따른 연속 값(예: 제품 판매)의 예측을 위해 최적화된 회귀분석 알고리즘을 제공합니다. 의사결정 트리 등의 다른 Microsoft 알고리즘에는 추세를 예측하기 위해 새 정보의 추가적인 열이 입력으로 필요하지만 시계열 모델에는 필요하지 않습니다. 시계열 모델은 모델을 작성하는 데 사용되는 원래 데이터 세트만 기반으로 추세를 예측할 수 있습니다. 또한 예측을 작성할 때 새 데이터를 모델에 추가하고 추세 분석에서 새 데이터를 자동으로 통합할 수 있습니다. 자세한 정보는 MS 시계열 노드의 내용을 참조하십시오.



**MS 시퀀스 군집화** 모델링 노드는 데이터에서 정렬된 시퀀스를 식별하고 이 분석의 결과를 군집화 기술과 결합하여 시퀀스 및 기타 속성을 기반으로 군집을 생성합니다. 자세한 정보는 MS 시퀀스 군집화 노드의 내용을 참조하십시오.

IBM SPSS Modeler 창의 맨 아래에 있는 데이터베이스 모델링 팔레트에서 각각의 노드에 액세스할 수 있습니다.

## ② 모든 알고리즘 노드에 공통인 설정

다음의 설정은 모든 Analysis Services 알고리즘에 공통입니다.

### 가. 서버 옵션

서버 탭에서는 분석 서버 호스트, 데이터베이스 및 SQL Server 데이터 소스를 구성할 수 있습니다. 여기서 지정된 옵션은 헬퍼 애플리케이션 대화 상자의 Microsoft 탭에서 지정된 옵션을 겹쳐 씁니다. 자세한 정보는 Analysis Services와의 통합 사용 주제를 참조하십시오.

*참고:* Analysis Services 모델을 스코어링할 때 이 탭의 변형도 사용할 수 있습니다. 자세한 정보는 Analysis Services 모델 너깃 서버 탭 주제를 참조하십시오.

### 나. 모델 옵션

가장 기본적인 모델을 작성하려면 진행하기 전에 모델 탭에서 옵션을 지정해야 합니다. 스코어링 방법 및 기타 고급 옵션을 고급 탭에서 사용할 수 있습니다.

다음과 같은 기본 모델링 옵션을 사용할 수 있습니다.

**모델 이름.** 노드가 실행될 때 작성되는 모델에 지정된 이름을 지정합니다.

- **자동.** 목표 또는 ID 필드 이름이나 목표가 지정되지 않은 경우(예: 군집 모델) 모델 유형 이름에 따라 모델 이름을 자동으로 생성합니다.
- **사용자 정의.** 작성된 모델에 대한 사용자 정의 이름을 지정할 수 있게 합니다.

**파티션된 데이터 사용.** 현재 파티션 필드를 기반으로 훈련, 검정 및 검증을 위한 개별 서브세트 또는 표본으로 데이터를 분할합니다. 하나의 표본을 사용하여 모델을 작성하고 개별 표본을 사용하여 해당 모델을 검정하면 현재 데이터와 비슷한 더 큰 데이터 세트로 모델이 일반화되는 정도를 표시할 수 있습니다. 스트림에 지정된 파티션 필드가 없으면 이 옵션은 무시됩니다.

**드릴스루 사용.** 표시된 경우 이 옵션을 사용하면 모델을 쿼리하여 모델에 포함된 케이스에 대한 세부사항을 학습할 수 있습니다.

**고유 필드.** 드롭 다운 목록에서 각각의 케이스를 고유하게 식별하는 필드를 선택하십시오. 일반적으로 이 필드는 ID 필드(예: **CustomerID**)입니다.

### ③ MS 의사결정 트리 고급 옵션

고급 탭에서 사용할 수 있는 옵션은 선택된 스트림의 구조에 따라 다를 수 있습니다. 선택된 Analysis Services 모델 노드에 대한 고급 옵션과 관련된 전체 세부사항은 사용자 인터페이스 필드 수준 도움말을 참조하십시오.

### ④ MS 군집화 고급 옵션

고급 탭에서 사용할 수 있는 옵션은 선택된 스트림의 구조에 따라 다를 수 있습니다. 선택된 Analysis Services 모델 노드에 대한 고급 옵션과 관련된 전체 세부사항은 사용자 인터페이스 필드 수준 도움말을 참조하십시오.

### ⑤ MS Naive Bayes 고급 옵션

고급 탭에서 사용할 수 있는 옵션은 선택된 스트림의 구조에 따라 다를 수 있습니다. 선택된 Analysis Services 모델 노드에 대한 고급 옵션과 관련된 전체 세부사항은 사용자 인터페이스 필드 수준 도움말을 참조하십시오.

### ⑥ MS 선형 회귀 고급 옵션

고급 탭에서 사용할 수 있는 옵션은 선택된 스트림의 구조에 따라 다를 수 있습니다. 선택된 Analysis Services 모델 노드에 대한 고급 옵션과 관련된 전체 세부사항은 사용자 인터페이스 필드 수준 도움말을 참조하십시오.

### ⑦ MS 신경망 고급 옵션

고급 탭에서 사용할 수 있는 옵션은 선택된 스트림의 구조에 따라 다를 수 있습니다. 선택된 Analysis Services 모델 노드에 대한 고급 옵션과 관련된 전체 세부사항은 사용자 인터페이스 필드 수준 도움말을 참조하십시오.

## ⑧ MS 로지스틱 회귀분석 고급 옵션

고급 탭에서 사용할 수 있는 옵션은 선택된 스트림의 구조에 따라 다를 수 있습니다. 선택된 Analysis Services 모델 노드에 대한 고급 옵션과 관련된 전체 세부사항은 사용자 인터페이스 필드 수준 도움말을 참조하십시오.

## ⑨ MS 연관 규칙 노드

MS 연관 규칙 모델링 노드는 추천 엔진에 유용합니다. 추천 엔진은 고객이 이미 구매했거나 관심을 표시한 항목을 기반으로 고객에게 제품을 추천합니다. 연관 모델은 개별 케이스와 케이스에 포함된 항목 둘 다에 대한 식별자가 포함된 데이터 세트에서 작성됩니다. 케이스의 항목 그룹을 **항목 세트**라고 합니다.

연관 모델은 일련의 항목 세트와 케이스 내에서 해당 항목이 그룹화되는 방식에 대해 설명하는 규칙으로 구성됩니다. 이 알고리즘이 식별하는 규칙은 고객의 장바구니에 이미 있는 항목을 기반으로 고객의 향후 구매 가능성을 예측하는 데 사용할 수 있습니다.

표 형식 데이터의 경우 이 알고리즘은 각각의 생성된 추천(\$M-field)에 대한 확률(\$MP-field)을 나타내는 스코어를 작성합니다. 트랜잭션 형식 데이터의 경우 각각의 생성된 추천(\$M-field)에 대해 지원(\$MS-field), 확률(\$MP-field) 및 조정된 확률(\$MAP-field)에 대한 스코어가 작성됩니다.

### 요구사항

트랜잭션 연관 모델에 대한 요구사항은 다음과 같습니다.

- **고유 필드.** 연관 규칙 모델에는 레코드를 고유하게 식별하는 키가 필요합니다.
- **ID 필드.** 트랜잭션 형식 데이터를 사용하여 MS 연관 규칙 모델을 작성하는 경우에는 각 트랜잭션을 식별하는 ID 필드가 필요합니다. ID 필드는 고유 필드와 동일하게 설정할 수 있습니다.
- **하나 이상의 입력 필드.** 연관 규칙 알고리즘에는 하나 이상의 입력 필드가 필요합니다.
- **대상 필드.** 트랜잭션 데이터를 사용하여 MS 연관 모델을 작성하는 경우에는 목표 필드가 트랜잭션 필드여야 합니다(예: 사용자가 구입한 제품).

### 가. MS 연관 규칙 고급 옵션

고급 탭에서 사용할 수 있는 옵션은 선택된 스트림의 구조에 따라 다를 수 있습니다. 선택된 Analysis Services 모델 노드에 대한 고급 옵션과 관련된 전체 세부사항은 사용자 인터페이스 필드 수준 도움말을 참조하십시오.

## ⑩ MS 시계열 노드

MS 시계열 모델링 노드는 두 가지 유형의 예측을 지원합니다.

- 미래
- 히스토리

**미래 예측**은 히스토리 데이터의 끝을 넘어선 지정된 수의 기간에 대한 목표 필드 값을 추정하며 항상 수행됩니다. **히스토리 예측**은 히스토리 데이터에 실제 값을 가진 지정된 수의 기간에 대한 목표 필드 값을 추정합니다. 히스토리 예측을 통해 실제 히스토리 값과 예측값을 비교하여 모델의 품질을 평가할 수 있습니다. 예측 시작점의 값은 히스토리 예측이 수행되는지 여부를 판별합니다.

IBM® SPSS® Modeler 시계열 노드와는 달리 MS 시계열 노드에는 선행 시간 구간 노드가 필요하지 않습니다. 추가적인 차이점은 기본적으로 시계열 데이터의 모든 히스토리 행이 아니라 예측된 행에 대해서만 스코어가 생성된다는 점입니다.

### 요구사항

MS 시계열 모델에 대한 요구사항은 다음과 같습니다.

- **단일 키 시간 필드.** 각각의 모델에는 모델이 사용할 시간 조각을 정의하는 케이스 시리즈로 사용되는 하나의 숫자 또는 날짜 필드가 포함되어 있어야 합니다. 키 시간 필드에 대한 데이터 유형은 날짜/시간 데이터 유형 또는 숫자 데이터 유형일 수 있습니다. 하지만 이 필드에는 연속형 값이 포함되어 있어야 하며 값은 각각의 시리즈에 대해 고유해야 합니다.
- **단일 목표 필드.** 각각의 모델에서 하나의 목표 필드만 지정할 수 있습니다. 목표 필드의 데이터 유형은 연속형 값을 가져야 합니다. 예를 들어, 수입, 판매 또는 온도 등의 숫자 속성이 시간 경과에 따라 어떻게 변하는지 예측할 수 있습니다. 하지만 범주형 값(예: 구매 상태 또는 교육 수준)을 목표 필드로 포함하는 필드는 사용할 수 없습니다.
- **하나 이상의 입력 필드.** MS 시계열 알고리즘에는 하나 이상의 입력 필드가 필요합니다. 입력 필드의 데이터 유형은 연속형 값을 가져야 합니다. 비연속형 입력 필드는 모델 작성 시 무시됩니다.
- **데이터 세트가 정렬되어야 함.** 입력 데이터 세트는 키 시간 필드에서 정렬되어야 합니다. 그렇지 않으면 모델 작성이 중단되고 오류가 생성됩니다.

### 가. MS 시계열 모델 옵션

**모델 이름.** 노드가 실행될 때 작성되는 모델에 지정된 이름을 지정합니다.

- **자동.** 목표 또는 ID 필드 이름이나 목표가 지정되지 않은 경우(예: 군집 모델) 모델 유형 이름에 따라 모델 이름을 자동으로 생성합니다.
- **사용자 정의.** 작성된 모델에 대한 사용자 정의 이름을 지정할 수 있게 합니다.

**파티션된 데이터 사용.** 파티션 필드가 정의된 경우 이 옵션을 사용하면 훈련 파티션의 데이터만 사용하여 모델을 작성합니다.

**드릴스루 사용.** 표시된 경우 이 옵션을 사용하면 모델을 쿼리하여 모델에 포함된 케이스에 대한 세부사항을 학습할 수 있습니다.

**고유 필드.** 드롭 다운 목록에서 시계열 모델을 작성하는 데 사용되는 키 시간 필드를 선택하십시오.

#### 나. MS 시계열 고급 옵션

고급 탭에서 사용할 수 있는 옵션은 선택된 스트림의 구조에 따라 다를 수 있습니다. 선택된 Analysis Services 모델 노드에 대한 고급 옵션과 관련된 전체 세부사항은 사용자 인터페이스 필드 수준 도움말을 참조하십시오.

히스토리 예측을 작성하는 경우 스코어링 결과에 포함할 수 있는 히스토리 단계의 수는  $(\text{HISTORIC\_MODEL\_COUNT} * \text{HISTORIC\_MODEL\_GAP})$ 의 값에 의해 결정됩니다. 기본적으로 이 제한은 10이며 이는 10개의 히스토리 예측만 작성됨을 의미합니다. 예를 들어, 이 경우 모델 너깃의 설정 탭에서 **히스토리 예측**에 대해 -10 미만의 값을 입력하면 오류가 발생합니다(MS 시계열 모델 너깃 설정 탭 참조). 더 많은 히스토리 예측을 보려는 경우 HISTORIC\_MODEL\_COUNT 또는 HISTORIC\_MODEL\_GAP의 값을 늘릴 수 있습니다. 하지만 이를 수행하면 모델의 작성 시간이 증가합니다.

#### 다. MS 시계열 설정 옵션

**추정 시작.** 예측을 시작할 기간을 지정하십시오.

- **시작 위치: 새 예측.** 향후 예측을 시작할 기간입니다(히스토리 데이터의 마지막 기간으로부터의 오프셋으로 표현됨). 예를 들어, 히스토리 데이터가 12/99에서 종료된 경우 01/00에서 예측을 시작하려면 값으로 1을 사용합니다. 하지만 03/00에서 예측을 시작하려면 값으로 3을 사용합니다.
- **시작 위치: 히스토리 예측.** 히스토리 예측을 시작할 기간입니다(히스토리 데이터의 마지막 기간으로부터의 음수 오프셋으로 표현됨). 예를 들어, 히스토리 데이터가 12/99에서 종료된 경우 데이터의 마지막 5개 기간에 대한 히스토리 예측을 작성하려면 값으로 -5를 사용합니다.

**추정 종료.** 예측을 중지할 기간을 지정하십시오.

- **예측 단계 종료.** 예측을 중지할 기간입니다(히스토리 데이터의 마지막 기간으로부터의 오프셋으로 표현됨). 예를 들어, 히스토리 데이터가 12/99에서 종료되는 경우 6/00에서 예측을 중지하려면 여기서 값으로 6을 사용합니다. 향후 예측의 경우 값은 항상 **시작 위치** 값 이상이어야 합니다.

## ⑪ MS 시퀀스 군집화 노드

MS 시퀀스 군집화 노드는 다음과 같은 경로(또는 시퀀스)를 사용하여 링크할 수 있는 이벤트가 포함된 데이터를 탐색하는 시퀀스 분석 알고리즘을 사용합니다. 이에 대한 예제로는 사용자가 웹 사이트를 탐색하거나 찾아볼 때 작성된 클릭 경로, 온라인 소매업체에서 고객이 장바구니에 항목을 추가하는 순서 등이 있습니다. 이 알고리즘은 동일한 시퀀스를 그룹화(또는 군집화)하여 가장 일반적인 시퀀스를 찾습니다.

### 요구사항

Microsoft 시퀀스 군집화 모델에 대한 요구사항은 다음과 같습니다.

- **ID 필드.** Microsoft 시퀀스 군집화 알고리즘을 사용하려면 시퀀스 정보를 트랜잭션 형식으로 저장해야 합니다. 이를 위해 각 트랜잭션을 식별하는 ID 필드가 필요합니다.
- **하나 이상의 입력 필드.** 이 알고리즘에는 하나 이상의 입력 필드가 필요합니다.
- **시퀀스 필드.** 이 알고리즘에는 연속형 측정 수준을 가져야 하는 시퀀스 식별자 필드도 필요합니다. 예를 들어, 필드가 시퀀스에서 이벤트를 식별하는 경우 웹 페이지 식별자, 정수 또는 텍스트 문자열을 사용할 수 있습니다. 각 시퀀스에 대해 하나의 시퀀스 식별자만 허용되고 각 모델에서 한 유형의 시퀀스만 허용됩니다. 시퀀스 필드는 ID 및 고유 필드와 달라야 합니다.
- **대상 필드.** 목표 필드는 시퀀스 군집화 모델 작성 시 필수입니다.
- **고유 필드.** 시퀀스 군집화 모델에는 레코드를 고유하게 식별하는 키 필드가 필요합니다. ID 필드와 동일하도록 고유 필드를 설정할 수 있습니다.

### 가. MS 시퀀스 군집화 필드 옵션

모든 모델링 노드에는 필드 탭이 있으며 이 탭에서는 모델 작성 시 사용할 필드를 지정합니다.

시퀀스 군집화 모델을 작성하려면 먼저 목표 및 입력으로 사용할 필드를 지정해야 합니다. MS 시퀀스 군집화 노드의 경우 업스트림 유형 노드의 필드 정보는 사용할 수 없으므로 여기서 필드 설정을 지정해야 합니다.

**ID.** 목록에서 ID 필드를 선택합니다. 숫자 또는 기호 필드를 ID 필드로 사용할 수 있습니다. 이 필드의 각 고유한 값은 분석의 특정 단위를 표시해야 합니다. 예를 들어, 장바구니 애플리케이션에서 각 ID는 단일 고객을 나타낼 수 있습니다. 웹 로그 분석 애플리케이션의 경우 각 ID는 컴퓨터(IP 주소별) 또는 사용자(로그인 데이터별)를 나타낼 수 있습니다.

**입력.** 모델에 대한 입력 필드를 선택하십시오. 이 필드는 시퀀스 모델링에 관심 있는 이벤트가 포함된 필드입니다.

**시퀀스.** 시퀀스 식별자 필드로 사용할 필드를 목록에서 선택하십시오. 예를 들어, 필드가 시퀀스에서 이벤트를 식별하는 경우 웹 페이지 식별자, 정수 또는 텍스트 문자열을 사용할 수 있습니다. 각

시퀀스에 대해 하나의 시퀀스 식별자만 허용되고 각 모델에서 한 유형의 시퀀스만 허용됩니다. 시퀀스 필드는 ID 필드(이 탭에서 지정됨) 및 고유 필드(모델 탭에서 지정됨)와 달라야 합니다.

**목표.** 목표 필드(즉, 시퀀스 데이터를 기반으로 값을 예측하는 필드)로 사용할 필드를 선택하십시오.

#### 나. MS 시퀀스 군집화 고급 옵션

고급 탭에서 사용할 수 있는 옵션은 선택된 스트림의 구조에 따라 다를 수 있습니다. 선택된 Analysis Services 모델 노드에 대한 고급 옵션과 관련된 전체 세부사항은 사용자 인터페이스 필드 수준 도움말을 참조하십시오.

### (3) Analysis Services 모델 스코어링

모델 스코어링은 SQL Server에서 발생하며 Analysis Services에 의해 수행됩니다. 데이터를 IBM® SPSS® Modeler에서 제공하거나 IBM SPSS Modeler에서 준비해야 하는 경우에는 데이터 세트를 임시 테이블에 업로드해야 할 수 있습니다. In-Database 마이닝을 사용하여 IBM SPSS Modeler에서 작성하는 모델은 실제로 원격 데이터 마이닝 또는 데이터베이스 서버에서 보유되는 원격 모델입니다. 이는 Microsoft Analysis Services 알고리즘을 사용하여 작성된 모델을 찾아서 스코어링할 때 이해할 중요한 차이입니다.

IBM SPSS Modeler에서는 일반적으로 하나의 예측 및 연관된 확률 또는 신뢰도가 전달됩니다.

모델 스코어링 예제는 Analysis Services 마이닝 예제의 내용을 참조하십시오.

#### ① 모든 Analysis Services 모델에 공통인 설정

다음의 설정은 모든 Analysis Services 모델에 공통입니다.

#### 가. Analysis Services 모델 너깃 서버 탭

서버 탭은 In-Database 마이닝에 대한 연결을 지정하는 데 사용됩니다. 이 탭은 고유 모델 키도 제공합니다. 이 키는 모델이 작성될 때 무작위로 생성되며 IBM® SPSS® Modeler의 모델과 Analysis Services 데이터베이스에 저장된 모델 오브젝트의 설명에도 저장됩니다.

서버 탭에서는 스코어링 조작을 위해 SQL Server 데이터 소스와 분석 서버 호스트 및 데이터베이스를 구성할 수 있습니다. 여기서 지정된 옵션은 IBM SPSS Modeler의 헬퍼 애플리케이션 또는 모델 작성 대화 상자에서 지정된 옵션을 겹쳐씹니다. 자세한 정보는 Analysis Services와의 통합 사용의 내용을 참조하십시오.

**모델 GUID.** 모델 키가 여기에 표시됩니다. 이 키는 모델이 작성될 때 무작위로 생성되며 IBM SPSS Modeler의 모델과 Analysis Services 데이터베이스에 저장된 모델 오브젝트의 설명에도 저장됩니다.

**검사.** Analysis Services 데이터베이스에 저장된 모델의 키에 대해 모델 키를 확인하려면 이 단추를 클릭하십시오. 이는 모델이 분석 서버에 여전히 존재하는지 확인할 수 있게 하며 모델의 구조가 변경되지 않았음을 나타냅니다.

 **참고:** 확인 단추는 스코어링에 대비해 스트림 캔버스에 추가된 모델의 경우에만 사용할 수 있습니다. 확인에 실패하는 경우에는 모델이 삭제되었거나 서버의 다른 모델로 바뀌었는지 조사하십시오.

**보기.** 의사결정 트리 모형의 그래픽 보기를 위해 클릭하십시오. 의사결정 트리 뷰어는 IBM SPSS Modeler의 기타 의사결정 트리 알고리즘에 의해 공유되며 기능은 동일합니다.

#### 나. Analysis Services 모델 너깃 요약 탭

모델 너깃의 요약 탭에서는 모델 자체(분석), 모델에 사용된 필드(필드), 모델 작성 시 사용된 설정(작성 설정), 모델 훈련(훈련 요약)에 대한 정보를 표시합니다.

먼저 노드를 찾아볼 때 요약 탭 결과를 접습니다. 관심이 있는 결과를 보려면 항목 왼쪽에 있는 펼치기 제어를 사용하여 펼치거나 **모두 펼치기** 단추를 클릭하여 모든 결과를 표시합니다. 결과 보기를 완료한 경우 결과를 숨기려면 펼치기 제어를 사용하여 숨기려는 특정 결과를 접거나 **모두 접기** 단추를 클릭하여 모든 결과를 접으십시오.

**분석.** 특정 모델에 대한 정보를 표시합니다. 이 모델 너깃에 연결된 분석 노드를 실행한 경우에는 해당 분석의 정보도 이 섹션에 표시됩니다.

**필드.** 모델을 작성할 때 목표로 사용되는 필드와 입력을 나열합니다.

**작성 설정.** 모델을 작성할 때 사용되는 설정에 대한 정보를 포함합니다.

**훈련 요약.** 모델 유형, 이를 작성하는 데 사용된 스트림, 이를 작성한 사용자, 작성 시점, 모델 작성 시 경과 시간을 표시합니다.

#### ② MS 시계열 모델 너깃

MS 시계열 모델은 히스토리 데이터가 아니라 예측된 기간에 대한 스코어만 생성합니다.

다음 표에는 모델에 추가되는 필드가 표시됩니다.

표 1. 모델에 추가되는 필드

필드이름	설명
\$M-필드	필드의 예측값입니다.
\$Var-필드	필드의 계산된 분산
\$Stdev-필드	필드의 표준 편차

### 가. MS 시계열 모델 너깃 서버 탭

서버 탭은 In-Database 마이닝에 대한 연결을 지정하는 데 사용됩니다. 이 탭은 고유 모델 키도 제공합니다. 이 키는 모델이 작성될 때 무작위로 생성되며 IBM® SPSS® Modeler의 모델과 Analysis Services 데이터베이스에 저장된 모델 오브젝트의 설명에도 저장됩니다.

서버 탭에서는 스코어링 작업을 위해 SQL Server 데이터 소스와 분석 서버 호스트 및 데이터베이스를 구성할 수 있습니다. 여기서 지정된 옵션은 IBM SPSS Modeler의 헬퍼 애플리케이션 또는 모델 작성 대화 상자에서 지정된 옵션을 겹쳐씹니다. 자세한 정보는 Analysis Services와의 통합 사용의 내용을 참조하십시오.

**모델 GUID.** 모델 키가 여기에 표시됩니다. 이 키는 모델이 작성될 때 무작위로 생성되며 IBM SPSS Modeler의 모델과 Analysis Services 데이터베이스에 저장된 모델 오브젝트의 설명에도 저장됩니다.

**검사.** Analysis Services 데이터베이스에 저장된 모델의 키에 대해 모델 키를 확인하려면 이 단추를 클릭하십시오. 이는 모델이 분석 서버에 여전히 존재하는지 확인할 수 있게 하며 모델의 구조가 변경되지 않았음을 나타냅니다.

 **참고:** 확인 단추는 스코어링에 대비해 스트림 캔버스에 추가된 모델의 경우에만 사용할 수 있습니다. 확인에 실패하는 경우에는 모델이 삭제되었거나 서버의 다른 모델로 바뀌었는지 조사하십시오.

**보기.** 시계열 모델의 그래픽 보기를 위해 클릭하십시오. Analysis Services는 완료된 모델을 트리로 표시합니다. 예측된 미래 값과 함께 시간 경과에 따른 목표 필드의 히스토리 값을 표시하는 그래프도 볼 수 있습니다.

자세한 정보는 MSDN 라이브러리에서 시계열 뷰어에 대한 설명을 참조하십시오 (<http://msdn.microsoft.com/en-us/library/ms175331.aspx>).

## 나. MS 시계열 모델 너짓 설정 탭

추정 시작. 예측을 시작할 기간을 지정하십시오.

- **시작 위치: 새 예측.** 향후 예측을 시작할 기간입니다(히스토리 데이터의 마지막 기간으로부터의 오프셋으로 표현됨). 예를 들어, 히스토리 데이터가 12/99에서 종료된 경우 01/00에서 예측을 시작하려면 값으로 1을 사용합니다. 하지만 03/00에서 예측을 시작하려면 값으로 3을 사용합니다.
- **시작 위치: 히스토리 예측.** 히스토리 예측을 시작할 기간입니다(히스토리 데이터의 마지막 기간으로부터의 음수 오프셋으로 표현됨). 예를 들어, 히스토리 데이터가 12/99에서 종료된 경우 데이터의 마지막 5개 기간에 대한 히스토리 예측을 작성하려면 값으로 -5를 사용합니다.

추정 종료. 예측을 중지할 기간을 지정하십시오.

- **예측 단계 종료.** 예측을 중지할 기간입니다(히스토리 데이터의 마지막 기간으로부터의 오프셋으로 표현됨). 예를 들어, 히스토리 데이터가 12/99에서 종료되는 경우 6/00에서 예측을 중지하려면 여기서 값으로 6을 사용합니다. 향후 예측의 경우 값은 항상 **시작 위치** 값 이상이어야 합니다.

### ③ MS 시퀀스 군집화 모델 너짓

다음 표에는 MS 시퀀스 군집화 모델에 추가되는 필드가 표시됩니다(여기서 필드는 대상 필드의 이름임).

필드 이름	설명
\$MC-필드	이 시퀀스가 속하는 군집에 대한 예측입니다.
\$MCP-필드	이 시퀀스가 예측된 군집에 속하는 확률입니다.
\$MS-필드	필드의 예측값입니다.
\$MSP-필드	\$MS-필드 값이 올바른 확률입니다.

### ④ 모델 내보내기 및 노드 생성

모델 요약 및 구조를 텍스트 및 HTML 형식 파일로 내보낼 수 있습니다. 해당되는 경우 적절한 선택 및 필터 노드를 생성할 수 있습니다.

IBM® SPSS® Modeler의 기타 모델 너깃과 마찬가지로 Microsoft Analysis Services 모델 너깃은 레코드 및 필드 조작 노드의 직접 생성을 지원합니다. 모델 너깃 메뉴 생성 옵션을 사용하면 다음과 같은 노드를 생성할 수 있습니다.

- 선택 노드(모델 탭에서 항목이 선택되는 경우에만)
- 필터 노드

#### (4) Analysis Services 마이닝 예제

IBM® SPSS® Modeler와 함께 MS Analysis Services 데이터 마이닝을 사용하는 것을 보여주는 다수의 샘플 스트림이 포함되어 있습니다. 이 스트림은 다음 위치에 있는 IBM SPSS Modeler 설치 폴더에서 찾을 수 있습니다.

`₩Demos₩Database_Modelling₩Microsoft`

참고: Demos 폴더는 Windows 시작 메뉴의 IBM SPSS Modeler 프로그램 그룹에서 액세스할 수 있습니다.

##### ① 예제 스트림: 의사결정 트리

다음의 스트림은 MS Analysis Services에서 제공하는 의사결정 트리 알고리즘을 사용하여 데이터베이스 마이닝 프로세스의 예로 순차적으로 함께 사용될 수 있습니다.

표 1. 의사결정 트리 - 예제 스트림

스트림	설명
<code>1_upload_data.str</code>	플랫 파일에서 데이터베이스로 데이터를 정리하고 업로드하는 데 사용됩니다.
<code>2_explore_data.str</code>	IBM® SPSS® Modeler를 사용한 데이터 탐색의 예를 제공합니다.
<code>3_build_model.str</code>	데이터베이스의 원래 알고리즘을 사용하여 모델을 작성합니다.
<code>4_evaluate_model.str</code>	IBM SPSS Modeler를 사용하여 모형을 평가하는 예로 사용됩니다.
<code>5_deploy_model.str</code>	In-Database 스코어링에 대한 모델을 배포합니다.

참고: 예를 실행하려면 스트림이 순서대로 실행되어야 합니다. 또한 사용할 데이터베이스에 대한 유효한 데이터 소스를 참조하기 위해 각 스트림의 소스 및 모델링 노드가 업데이트되어야 합니다.

예제 스트림에서 사용된 데이터 세트는 신용카드 애플리케이션과 관련되며 분류 문제점에 범주형 예측변수와 연속형 예측변수의 혼합을 제공합니다. 이 데이터 세트에 대한 자세한 정보는 샘플 스트림과 동일한 폴더의 `crx.names` 파일을 참조하십시오.

이 데이터 세트는 UCI Machine Learning Repository  
<ftp://ftp.ics.uci.edu/pub/machine-learning-databases/credit-screening/>에서 사용 가능합니다.

#### 가. 예제 스트림: 데이터 업로드

첫 번째 예제 스트림인 *1\_upload\_data.str*은 플랫폼 파일의 데이터를 정리하고 SQL Server로 업로드하는 데 사용됩니다.

Analysis Services 데이터 마이닝에는 키 필드가 필요하므로 이 초기 스트림에서는 파생 노드를 사용하여 IBM® SPSS® Modeler @INDEX 함수로 고유 값 1,2,3을 가진 KEY라는 새 필드를 데이터 세트에 추가합니다.

후속 채움 노드는 결측값 처리에 사용되며 텍스트 파일 *crx.data*에서 읽어온 비어 있는 필드를 NULL 값으로 바꿉니다.

#### 나. 예제 스트림: 데이터 탐색

두 번째 예제 스트림인 *2\_explore\_data.str*은 요약 통계 및 그래프를 포함하여 데이터의 일반적인 개요를 얻기 위해 데이터 검토 노드를 사용하는 방법을 보여주는 데 사용됩니다.

데이터 검토 보고서에서 그래프를 두 번 클릭하면 지정된 필드를 더 깊게 탐색할 수 있도록 자세한 그래프가 생성됩니다.

#### 다. 예제 스트림: 모델 작성

세 번째 예제 스트림인 *3\_build\_model.str*은 IBM® SPSS® Modeler에서 모델 작성을 보여줍니다. 데이터베이스 모델을 스트림에 연결한 후 두 번 클릭하여 작성 설정을 지정할 수 있습니다.

대화 상자의 모델 탭에서는 다음을 지정할 수 있습니다.

1. 키 필드를 고유 ID 필드로 선택하십시오.

고급 탭에서는 모델 작성을 위한 설정을 미세 조정할 수 있습니다.

실행하기 전에 모델 작성을 위해 올바른 데이터베이스를 지정했는지 확인하십시오. 서버 탭을 사용하여 설정을 조정하십시오.

## 라. 예제 스트림: 모델 평가

네 번째 예제 스트림인 *4\_evaluate\_model.str*은 In-Database 모델링에 대해 IBM® SPSS® Modeler를 사용할 때의 장점을 보여줍니다. 모델을 실행하고 나면 해당 모델을 다시 데이터 스트림에 추가하고 IBM SPSS Modeler에서 제공된 여러 도구를 사용하여 해당 모델을 평가할 수 있습니다.

### 모델링 결과 보기

모델 너깃을 두 번 클릭하여 결과를 탐색할 수 있습니다. 요약 탭은 결과의 규칙-트리 보기를 제공합니다. 의사결정 트리 모형의 그래픽 보기에 대한 **보기** 단추(서버 탭에 있음)를 클릭할 수도 있습니다.

### 모델 결과 평가

샘플 스트림의 분석 노드는 각 예측 필드 및 해당 목표 필드 간 일치 패턴을 보여주는 일치 교차표를 작성합니다. 분석 노드를 실행하여 결과를 확인하십시오.

샘플 스트림의 평가 노드는 모델에 의해 작성된 정확도 개선사항을 표시하도록 설계된 Gains 차트를 작성할 수 있습니다. 평가 노드를 실행하여 결과를 확인하십시오.

## 마. 예제 스트림: 모델 배포

모델의 정확도에 만족한 경우에는 외부 애플리케이션과 함께 사용하거나 데이터베이스에 다시 게시하기 위해 해당 모델을 배포할 수 있습니다. 최종 예제 스트림인 *5\_deploy\_model.str*에서는 데이터를 CREDIT 테이블에서 읽어온 후 데이터베이스 내보내기 노드를 사용하여 스코어링하여 CREDITSCORES 테이블에 게시합니다.

스트림을 실행하면 다음의 SQL이 생성됩니다.

```
DROP TABLE CREDITSCORES

CREATE TABLE CREDITSCORES ( "field1" varchar(1),"field2" varchar(255),"field3" float,"field4" varchar(1),"field5" varchar(2),"field6" varchar(2),"field7" varchar(2),"field8" float,"field9" varchar(1),"field10" varchar(1),"field11" int,"field12" varchar(1),"field13" varchar(1),"field14" int,"field15" int,"field16" varchar(1),"KEY" int,"$M-field16" varchar(9),"$MC-field16" float )

INSERT INTO CREDITSCORES ("field1","field2","field3","field4","field5","field6","field7","field8",
"field9","field10","field11","field12","field13","field14","field15","field16",
"KEY","$M-field16","$MC-field16")
SELECT T0.C0 AS C0,T0.C1 AS C1,T0.C2 AS C2,T0.C3 AS C3,T0.C4 AS C4,T0.C5 AS C5,
T0.C6 AS C6,T0.C7 AS C7,T0.C8 AS C8,T0.C9 AS C9,T0.C10 AS C10,
T0.C11 AS C11,T0.C12 AS C12,T0.C13 AS C13,T0.C14 AS C14,
```

```

T0.C15 AS C15,T0.C16 AS C16,T0.C17 AS C17,T0.C18 AS C18
FROM (
    SELECT      CONVERT(NVARCHAR,[TA].[field1])          AS      C0,
    CONVERT(NVARCHAR,[TA].[field2]) AS C1,
               [TA].[field3] AS C2, CONVERT(NVARCHAR,[TA].[field4]) AS C3,
               CONVERT(NVARCHAR,[TA].[field5])          AS      C4,
    CONVERT(NVARCHAR,[TA].[field6]) AS C5,
               CONVERT(NVARCHAR,[TA].[field7]) AS C6, [TA].[field8] AS C7,
               CONVERT(NVARCHAR,[TA].[field9])          AS      C8,
    CONVERT(NVARCHAR,[TA].[field10]) AS C9,
               [TA].[field11] AS C10, CONVERT(NVARCHAR,[TA].[field12]) AS C11,
               CONVERT(NVARCHAR,[TA].[field13]) AS C12, [TA].[field14] AS C13,
               [TA].[field15] AS C14, CONVERT(NVARCHAR,[TA].[field16]) AS C15,
               [TA].[KEY] AS C16, CONVERT(NVARCHAR,[TA].[$M-field16]) AS C17,
               [TA].[$MC-field16] AS C18
    FROM openrowset('MSOLAP',
                   'Datasource=localhost;Initial catalog=FoodMart 2000',
                   'SELECT [T].[C0] AS [field1],[T].[C1] AS [field2],[T].[C2] AS [field3],
                       [T].[C3] AS [field4],[T].[C4] AS [field5],[T].[C5] AS [field6],
                       [T].[C6] AS [field7],[T].[C7] AS [field8],[T].[C8] AS [field9],
                       [T].[C9] AS [field10],[T].[C10] AS [field11],[T].[C11] AS [field12],
                       [T].[C12] AS [field13],[T].[C13] AS [field14],[T].[C14] AS [field15],
                       [T].[C15] AS [field16],[T].[C16] AS [KEY],[CREDIT1].[field16] AS
    [$M-field16],
                       PredictProbability([CREDIT1].[field16]) AS [$MC-field16]
                   FROM [CREDIT1] PREDICTION JOIN
                       openrowset('MSDASQL',
                                   ''Dsn=LocalServer;Uid=;pwd='','SELECT      T0."field1"          AS
    C0,T0."field2" AS C1,
                                   T0."field3" AS C2,T0."field4" AS C3,T0."field5" AS C4,T0."field6"
    AS C5,
                                   T0."field7" AS C6,T0."field8" AS C7,T0."field9" AS C8,T0."field10"
    AS C9,
                                   T0."field11" AS C10,T0."field12" AS C11,T0."field13" AS C12,
                                   T0."field14" AS C13,T0."field15" AS C14,T0."field16" AS C15,
                                   T0."KEY" AS C16 FROM "dbo".CREDITDATA T0') AS [T]
                   ON [T].[C2] = [CREDIT1].[field3] and [T].[C7] = [CREDIT1].[field8]
                       and [T].[C8] = [CREDIT1].[field9] and [T].[C9] =
    [CREDIT1].[field10]
                       and [T].[C10] = [CREDIT1].[field11] and [T].[C11] =
    [CREDIT1].[field12]
                       and [T].[C14] = [CREDIT1].[field15]') AS [TA]
    ) TO

```

상위 주제:

### 3) Oracle Data Mining을 사용한 데이터베이스 모델링

#### (1) Oracle Data Mining 정보

IBM® SPSS® Modeler는 Oracle RDBMS 내에서 단단하게 임베드된 데이터 마이닝 알고리즘 패밀리를 제공하는 Oracle 데이터 마이닝(ODM)과의 통합을 지원합니다. 이 기능은 IBM SPSS Modeler 그래픽 사용자 인터페이스 및 워크플로우 중심 개발 환경을 통해 액세스할 수 있으며 이를 통해 고객이 ODM이 제공하는 데이터 마이닝 알고리즘을 사용할 수 있습니다.

IBM SPSS Modeler는 Oracle 데이터 마이닝에서 제공하는 다음 알고리즘의 통합을 지원합니다.

- Naive Bayes
- 적응형 베이스
- SVM(Support Vector Machine)
- GLM(Generalized Linear Model)\*
- 의사결정 트리
- O-Cluster
- K-평균
- NMF(Nonnegative Matrix Factorization)
- Apriori
- MDL(Minimum Descriptor Length)
- 속성 중요도(AI)

\* 11g R1 전용

#### (2) Oracle과의 통합을 위한 요구사항

Oracle Data Mining을 사용하여 In-Database 모델링을 수행하기 위해서는 다음과 같은 조건이 충족되어야 합니다. 데이터베이스 관리자에게 문의하여 이 조건이 충족되는지 확인해야 할 수 있습니다.

- Windows 또는 UNIX에서 IBM® SPSS® Modeler Server 설치에 대해 또는 로컬 모드로 실행 중인 IBM SPSS Modeler
- Oracle Data Mining 옵션이 설치된 Oracle 10gR2 또는 11gR1(10.2 데이터베이스 이상)

**참고:** 10gR2는 일반화 선형 모형(11gR1이 필요함)을 제외한 모든 데이터베이스 모델링 알고리즘에 대한 지원을 제공합니다.

- Oracle에 연결하는 데 필요한 ODBC 데이터 소스. 자세한 정보는 Oracle과의 통합 사용 주제를 참조하십시오.

**참고:** 데이터베이스 모델링 및 SQL 최적화를 위해서는 IBM SPSS Modeler 컴퓨터에서 IBM SPSS Modeler Server 연결성이 설정되어 있어야 합니다. 이 설정이 사용 가능하면 데이터베이스 알고리즘에 액세스하고, SQL을 IBM SPSS Modeler에서 직접 푸시백하고, IBM SPSS Modeler Server에 액세스할 수 있습니다. 현재 라이선스 상태를 검증하려면 IBM SPSS Modeler 메뉴에서 다음을 선택하십시오.

도움말 > 정보 > 추가 세부사항

연결성이 사용 가능으로 설정되면 라이선스 상태 탭에 **서버 사용 가능** 옵션이 표시됩니다.

### (3) Oracle과의 통합 사용

Oracle Data Mining과의 IBM® SPSS® Modeler 통합을 사용하려면 Oracle을 구성하고 ODBC 소스를 작성하고 IBM SPSS Modeler 헬퍼 애플리케이션에서 통합을 사용으로 설정하고 SQL 생성 및 최적화를 사용으로 설정해야 합니다.

Oracle 구성

Oracle Data Mining을 설치하고 구성하려면 Oracle 문서(특히 *Oracle 관리자 안내서*)에서 자세한 내용을 참조하십시오.

Oracle에 대한 ODBC 소스 작성

Oracle과 IBM SPSS Modeler 간 연결을 사용하려면 ODBC 시스템 데이터 소스 이름(DSN)을 작성해야 합니다.

DSN을 작성하기 전에 ODBC 데이터 소스 및 드라이버와 IBM SPSS Modeler에서의 데이터베이스 지원에 대한 기본적인 이해가 필요합니다.

IBM SPSS Modeler Server에 대해 분산 모드에서 실행 중인 경우에는 서버 컴퓨터에서 DSN을 작성하십시오. 로컬(클라이언트) 모드에서 실행 중인 경우에는 클라이언트 컴퓨터에서 DSN을 작성하십시오.

1. ODBC 드라이버를 설치하십시오. 이 드라이버는 이 릴리스와 함께 제공된 IBM SPSS Data Access Pack 설치 디스크에 있습니다. setup.exe 파일을 실행하여 설치 프로그램을 시작하고 모든 관련 드라이버를 선택하십시오. 화면에 표시되는 지시사항에 따라 드라이버를 설치하십시오.
  - a. DSN 작성.

**참고:** 메뉴 순서는 Windows 버전에 따라 다릅니다.

- **Windows XP.** 시작 메뉴에서 **제어판**을 선택하십시오. **관리 도구**를 두 번 클릭한 후 **데이터 소스(ODBC)**를 두 번 클릭하십시오.
- **Windows Vista.** 시작 메뉴에서 **제어판**을 선택한 후 **시스템 유지보수**를 선택하십시오. **관리 도구**를 두 번 클릭하고 **데이터 소스(ODBC)**를 선택한 후 **열기**를 클릭하십시오.
- **Windows 7.** 시작 메뉴에서 **제어판**, **시스템 & 보안**, **관리 도구**를 차례로 선택하십시오. **데이터 소스(ODBC)**를 선택한 후 **열기**를 클릭하십시오.

b. **시스템 DSN** 탭으로 이동한 후 **추가**를 클릭하십시오.

2. **SPSS OEM 6.0 Oracle Wire Protocol** 드라이버를 선택하십시오.
3. **완료**를 클릭하십시오.
4. ODBC Oracle Wire Protocol 드라이버 설정 화면에서 선택한 데이터 소스 이름, Oracle 서버의 호스트 이름, 연결의 포트 번호 및 사용 중인 Oracle 인스턴스의 SID를 입력하십시오. *tnsnames.ora* 파일을 사용하여 TNS를 구현한 경우에는 서버 시스템의 *tnsnames.ora* 파일에서 이 호스트 이름, 포트 및 SID를 얻을 수 있습니다. 자세한 정보를 얻으려면 Oracle 관리자에게 문의하십시오.
5. **테스트** 단추를 클릭하여 연결을 테스트하십시오.

IBM SPSS Modeler에서 Oracle Data Mining Integration 사용

1. IBM SPSS Modeler 메뉴에서 다음을 선택하십시오.  
**도구 > 옵션 > 헬퍼 애플리케이션**
2. **Oracle** 탭을 클릭하십시오.

**Oracle Data Mining Integration 사용.** IBM SPSS Modeler 창의 맨 아래에서 데이터베이스 모델링 팔레트를 사용하여 설정(아직 표시되지 않은 경우)하고 Oracle Data Mining 알고리즘에 대한 노드를 추가합니다.

**Oracle 연결.** 유효한 사용자 이름 및 비밀번호와 함께 모델 작성 및 저장에 사용되는 기본 Oracle ODBC 데이터 소스를 지정하십시오. 이 설정은 개별 모델링 노드 및 모델 너깅에서 대체될 수 있습니다.

**참고:** 모델링을 위해 사용되는 데이터베이스 연결은 데이터에 액세스하는 데 사용되는 연결과 동일하거나 동일하지 않을 수 있습니다. 예를 들어, Oracle 데이터베이스에서 데이터에 액세스하는 스트림이 있는 경우, 정리 또는 기타 작업을 위해 데이터를 IBM SPSS Modeler에 다운로드한 다음 모델링 목적으로 데이터를 다른 Oracle 데이터베이스에 업로드할 수 있습니다. 또는 원래 데이터가 플랫폼 파일 또는 다른(비Oracle) 소스에 상주할 수 있으며 이 경우에는 모델링을 위해 데이터를 Oracle에 업로드해야 합니다. 모든 경우에 데이터는 모델링에 사용되는 데이터베이스에서 작성된 임시 테이블에 자동으로 업로드됩니다.

**Oracle Data Mining 모델을 겹쳐쓰려고 할 때 경고.** 데이터베이스에 저장된 모델이 경고 없이 IBM SPSS Modeler에 의해 겹쳐써지지 않게 하려면 이 옵션을 선택하십시오.

**Oracle Data Mining 모델 나열.** 사용 가능한 데이터 마이닝 모델을 표시합니다.

**Oracle Data Miner의 시작 사용(선택사항).** 사용으로 설정되면 IBM SPSS Modeler가 Oracle Data Miner 애플리케이션을 시작하도록 허용합니다. 자세한 정보는 Oracle Data Miner의 내용을 참조하십시오.

**Oracle Data Miner 실행 파일의 경로(선택사항).** Windows용 Oracle Data Miner 실행 파일의 실제 위치를 지정합니다(예: `C:\#odm\bin\#odminerw.exe`). Oracle Data Miner는 IBM SPSS Modeler와 함께 설치되지 않으므로 Oracle 웹 사이트(<http://www.oracle.com/technology/products/bi/odm/odminer.html>)에서 올바른 버전을 다운로드하여 클라이언트에서 설치해야 합니다.

SQL 생성 및 최적화 사용

1. IBM SPSS Modeler 메뉴에서 다음을 선택하십시오.  
도구 > 스트림 특성 > 옵션
2. 탐색 분할창에서 **최적화** 옵션을 클릭하십시오.
3. **SQL 생성** 옵션이 사용으로 설정되어 있는지 확인하십시오. 이 설정은 데이터베이스 모델링이 작동하기 위해 필수입니다.
4. **SQL 생성 최적화** 및 기타 **실행 최적화**를 선택하십시오(엄격하게 요구되지 않지만 최적화된 성능을 위해서는 강력하게 권장됨).

#### (4) Oracle Data Mining을 사용하여 모델 작성

Oracle 모델 작성 노드는 IBM® SPSS® Modeler의 기타 모델링 노드와 마찬가지로 작동하며 몇 가지 예외가 있습니다. IBM SPSS Modeler 창의 맨 아래에 있는 데이터베이스 모델링 팔레트에서 이 노드에 액세스할 수 있습니다.

데이터 고려사항

Oracle을 사용하려면 범주형 데이터를 문자열 형식(CHAR 또는 VARCHAR2)으로 저장해야 합니다. 결과적으로 IBM SPSS Modeler에서는 측정 수준이 **플래그** 또는 **명목(범주형)**인 숫자 저장 영역 필드를 ODM 모델에 대한 입력으로 지정할 수 없습니다. 필요한 경우에는 재분류 노드를 사용하여 IBM SPSS Modeler에서 숫자를 문자열로 변환할 수 있습니다.

**대상 필드.** 하나의 필드만 ODM 분류 모델의 출력(목표) 필드로 선택할 수 있습니다.

**모델 이름.** Oracle 11gR1부터 unique라는 이름은 키워드이므로 사용자 정의 모델 이름으로 사용할 수 없습니다.

**고유 필드.** 각각의 케이스를 고유하게 식별하는 데 사용되는 필드를 지정합니다. 예를 들어, ID 필드(예: *CustomerID*)가 될 수 있습니다. IBM SPSS Modeler는 이 키 필드가 숫자여야 한다는 제한사항을 부과합니다.

 **참고:** 이 필드는 모든 Oracle 노드에 대해 선택적입니다(Oracle Adaptive Bayes, Oracle O-Cluster 및 Oracle Apriori 제외).

#### 일반 주석

- PMML 내보내기/가져오기는 Oracle Data Mining에 의해 작성된 모델에 대해 IBM SPSS Modeler에서 제공되지 않습니다.
- 모델 스코어링은 항상 ODM 내에서 발생합니다. 데이터가 IBM SPSS Modeler 내에서 시작되거나 준비되어야 하는 경우에는 데이터 세트를 임시 테이블에 업로드해야 할 수 있습니다.
- IBM SPSS Modeler에서는 일반적으로 하나의 예측 및 연관된 확률 또는 신뢰도가 전달됩니다.
- IBM SPSS Modeler는 모델 작성 및 스코어링에서 사용할 수 있는 필드 수를 1,000으로 제한합니다.
- IBM SPSS Modeler는 IBM SPSS Modeler Solution Publisher를 사용하여 실행을 위해 계 시된 스트림 내에서 ODM 모델을 스코어링할 수 있습니다.

#### ① Oracle 모형 서버 옵션

모델링에 대한 데이터를 업로드하는 데 사용되는 Oracle 연결을 지정하십시오. 필요한 경우, 각 모델링 노드에 대한 서버 탭에서 연결을 선택하여 헬퍼 애플리케이션 대화 상자에서 지정된 기본 Oracle 연결을 대체할 수 있습니다. 자세한 정보는 Oracle과의 통합 사용 주제를 참조하십시오.

#### 설명

- 모델링에 사용되는 연결은 스트림에 대한 소스 노드에 사용되는 연결과 동일하거나 동일하지 않을 수 있습니다. 예를 들어, Oracle 데이터베이스에서 데이터에 액세스하는 스트림이 있는 경우, 정리 또는 기타 조작을 위해 데이터를 IBM® SPSS® Modeler에 다운로드한 다음 모델링 목적으로 데이터를 다른 Oracle 데이터베이스에 업로드할 수 있습니다.
- ODBC 데이터 소스 이름이 각 IBM SPSS Modeler 스트림에 효과적으로 임베드됩니다. 한 호스트에서 작성된 스트림이 다른 호스트에서 실행되는 경우 데이터 소스의 이름이 각 호스트에서 동일해야 합니다. 또는 각 소스 또는 모델링 노드의 서버 탭에서 다른 데이터 소스를 선택할 수 있습니다.

## ② 오분류 비용

일부 컨텍스트에서는 특정 오차 유형이 다른 유형에 비해 더 값비쌉니다. 예를 들어, 고위험 신용 거래 신청자를 저위험(오차의 한 유형)으로 분류하는 것이 저위험 신청자를 고위험(다른 유형의 오차)으로 분류하는 것보다 비용이 더 나갈 수 있습니다. 오분류 비용을 통해 여러 다른 유형의 예측 오차의 상대적 중요도를 지정할 수 있습니다.

오분류 비용은 기본적으로 특정 결과에 적용된 가중값입니다. 이 가중값은 모델에 영향을 미치는 요인이 되어 실제로 예측변수를 변경합니다(값비싼 실수에 대비하는 보호의 한 방법으로).

C5.0 모델을 제외하고, 오분류 비용은 모델을 스코어링할 때 적용되지 않으며 자동 분류자 노드, 평가 노드 또는 분석 노드를 사용하여 모델을 순위화하거나 비교할 때 고려되지 않습니다. 비용을 포함한 모델은 포함하지 않은 모델보다 적은 오차를 생성하지 않고 전체 정확도 측면에서 더 높게 순위화되지 않을 수는 있지만, *보다 저렴* 오차를 선호하는 편향이 내재되어 있어서 실제적으로 성능이 더 좋을 수 있습니다.

비용 교차표는 예측 범주와 실제 범주의 가능한 각 조합의 비용을 표시합니다. 기본적으로 모든 오분류 비용은 1.0으로 설정됩니다. 사용자 정의 비용 값을 입력하려면 **오분류 비용 사용**을 선택하고 비용 교차표에 사용자 정의 값을 입력하십시오.

오분류 비용을 변경하려면 예측 및 실제 값의 원하는 조합에 해당하는 셀을 선택하고 셀의 기존 콘텐츠를 삭제한 후 셀의 원하는 비용을 입력하십시오. 비용은 자동으로 대칭되지 않습니다. 예를 들어, A를 B로 오분류한 비용을 2.0으로 설정할 경우 이 설정을 명시적으로 변경하지 않으면 B를 A로 오분류하는 비용의 기본값은 여전히 1.0입니다.

**참고:** 의사결정 트리 모형에서만 작성 시 비용을 지정할 수 있습니다.

## (5) Oracle Naive Bayes

Naive Bayes는 분류 문제점을 위한 잘 알려진 알고리즘입니다. 모델은 제안된 모든 예측 변수를 서로 독립된 것으로 처리하기 때문에 *naive*라고 합니다. Naive Bayes는 속성과 목표 속성의 조합에 대한 조건부 확률을 계산하는 빠르고 확장 가능한 알고리즘입니다. 훈련 데이터에서 독립된 확률이 설정됩니다. 각 입력 변수에서 각 값 범주가 주어지는 경우, 이 확률은 각 대상 클래스의 우도를 제공합니다.

- 교차 검증은 모형을 작성하는 데 사용된 동일한 데이터에 대한 모형 정확도를 검증하는 데 사용됩니다. 이는 모형을 작성하는 데 사용할 수 있는 케이스 수가 적은 경우에 특히 유용합니다.
- 모델 출력은 교차표 형식으로 찾을 수 있습니다. 교차표 내의 수는 예측 클래스(열)과 예측자 값 조합(행)을 연관시키는 조건부 확률입니다.

## ① Naive Bayes 모형 옵션

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**파티션된 데이터 사용.** 파티션 필드가 정의된 경우 이 옵션을 사용하면 훈련 파티션의 데이터만 사용하여 모델을 작성합니다.

**고유 필드.** 각각의 케이스를 고유하게 식별하는 데 사용되는 필드를 지정합니다. 예를 들어, ID 필드(예: *CustomerID*)가 될 수 있습니다. IBM® SPSS® Modeler는 이 키 필드가 숫자여야 한다는 제한사항을 부과합니다.

 **참고:** 이 필드는 모든 Oracle 노드에 대해 선택적입니다(Oracle Adaptive Bayes, Oracle O-Cluster 및 Oracle Apriori 제외).

**자동 데이터 준비.** (11g 전용) Oracle Data Mining의 자동화된 데이터 준비 모드를 사용(기본 값) 또는 사용 안함으로 설정합니다. 이 선택란이 선택되면 ODM이 알고리즘에 필요한 데이터 변환을 자동으로 수행합니다. 자세한 정보는 *Oracle Data Mining 개념*을 참조하십시오.

## ② Naive Bayes 고급 옵션

모델이 작성될 때 학습 데이터에서 지정된 값 또는 쌍이 충분히 발생하지 않으면 개별 예측자 속성 값 또는 값 쌍은 무시됩니다. 값을 무시하는 임계값은 학습 데이터의 레코드 수를 기준으로 하여 분수로 지정됩니다. 이러한 임계값을 조정하면 잡음이 줄어들고 모델이 기타 데이터 세트에 일반화될 수 있는 기능이 개선됩니다.

- **싱글톤 임계값.** 지정된 예측자 속성 값에 대한 임계값을 지정합니다. 지정된 값의 발생 수는 지정된 분수 이상이어야 합니다. 그렇지 않으면 값이 무시됩니다.
- **대응별 임계값.** 지정된 속성 및 예측자 값 쌍에 대한 임계값을 지정합니다. 지정된 값 쌍의 발생 수는 지정된 분수 이상이어야 합니다. 그렇지 않으면 쌍이 무시됩니다.

**예측 확률.** 모델이 대상 필드의 가능한 결과에 대한 올바른 예측의 확률을 포함할 수 있게 합니다. 이 기능을 사용하려면 **선택**을 선택하고 **지정** 단추를 클릭하고 가능한 결과 중 하나를 선택한 후 **삽입**을 클릭하십시오.

**예측 세트 사용.** 대상 필드의 가능한 모든 결과에 대한 가능한 모든 결과의 테이블을 생성합니다.

## (6) Oracle 적응형 베이스

적응형 Bayes 네트워크(ABN)는 최소 설명 길이(MDL) 및 자동 필드선택을 사용하여 베이저안

네트워크 분류자를 구성합니다. ABN은 Naive Bayes가 적합하지 않은 몇 가지 상황에 더 적합하며 대부분의 기타 상황에서도 성능은 느려질 수 있으나 어느 정도의 성과를 냅니다. ABN 알고리즘은 단순화된 의사결정 트리(단일-필드), 가지치기를 한 Naive Bayes 및 증폭된 다기능 모형을 포함하는 세 가지 유형의 고급 베이지안 기반 모델을 작성하기 위한 기능을 제공합니다.

**참고:** Oracle 적합 Bayes 알고리즘은 Oracle 12C에서 삭제되었으며 Oracle 12C를 사용할 때 IBM® SPSS® Modeler에서 지원되지 않습니다.  
[http://docs.oracle.com/database/121/DMPRG/release\\_changes.htm#DMPRG726](http://docs.oracle.com/database/121/DMPRG/release_changes.htm#DMPRG726)의 내용을 참조하십시오.

## 생성된 모델

단일 필드 작성 모드에서 ABN은 사람이 읽을 수 있는 규칙 세트를 기반으로 하여 단순화된 의사결정 트리를 작성하며 이를 사용하여 비즈니스 사용자 또는 분석가가 모델의 예측값 및 실제값의 기초를 이해하고 이에 따라 행동하거나 다른 사용자에게 설명할 수 있습니다. 이는 Naive Bayes 및 다기능 모형에 대한 유의적인 장점입니다. 이러한 규칙은 IBM SPSS Modeler에서 표준 규칙 세트처럼 찾을 수 있습니다. 규칙의 단순 세트는 다음과 같이 표시됩니다.

```
IF MARITAL_STATUS = "Married"  
AND EDUCATION_NUM = "13-16"  
THEN CHURN= "TRUE"  
Confidence = .78, Support = 570 cases
```

가지치기된 Naive Bayes 및 다기능 모형은 IBM SPSS Modeler에서 찾을 수 없습니다.

### ① 적응형 Bayes 모델 옵션

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**파티션된 데이터 사용.** 파티션 필드가 정의된 경우 이 옵션을 사용하면 훈련 파티션의 데이터만 사용하여 모델을 작성합니다.

**고유 필드.** 각각의 케이스를 고유하게 식별하는 데 사용되는 필드를 지정합니다. 예를 들어, ID 필드(예: *CustomerID*)가 될 수 있습니다. IBM® SPSS® Modeler는 이 키 필드가 숫자여야 한다는 제한사항을 부과합니다.

**참고:** 이 필드는 모든 Oracle 노드에 대해 선택적입니다(Oracle Adaptive Bayes, Oracle O-Cluster 및 Oracle Apriori 제외).

## 모델 유형

세 가지 다른 모드의 모델 작성을 선택할 수 있습니다.

- **다기능.** NB 모델, 단일 및 다기능 곱 확률 모델을 포함하여 수많은 모델을 작성하고 비교합니다. 이 모드는 가장 철저한 모드이며 그에 따라 일반적으로 계산에 가장 긴 시간이 걸립니다. 규칙은 단일 필드 모델이 가장 적합한 것으로 판명되는 경우에만 생성됩니다. 다기능 또는 NB 모델이 선택되면, 어떠한 규칙도 생성되지 않습니다.
- **단일 필드.** 규칙 세트를 기준으로 하여 단순한 의사결정 트리를 작성합니다. 각 규칙에는 각 결과와 연관된 확률과 함께 조건이 포함됩니다. 규칙은 상호 배타적이며 사람이 읽을 수 있는 형식으로 제공됩니다. 이는 Naive Bayes 및 다기능 모형에 비해 큰 장점입니다.
- **Naive Bayes.** 단일 NB 모델을 작성하고 글로벌 표본 사전확률(글로벌 표본에서 목표 값의 분포)과 비교합니다. NB 모델은 글로벌 사전확률보다 더 나은 목표 값의 예측자인 것으로 판명된 경우에만 출력으로 생성됩니다. 그렇지 않으면 어떠한 모델도 출력으로 생성되지 않습니다.

### ② 적응형 Bayes 고급 옵션

**실행 시간 제한.** 분 단위로 최대 작성 시간을 지정하려면 이 옵션을 선택하십시오. 그러면 결과 모델이 덜 정확하더라도 더 짧은 시간에 모델을 작성할 수 있습니다. 모델링 프로세스의 각 마일스톤에서 계속 진행하기 전에 알고리즘이 지정된 시간 동안 다음 마일스톤을 완료할 수 있는지 여부를 검사하여 한계에 도달하면 가장 적합한 모델을 리턴합니다.

**최대 예측자.** 이 옵션을 사용하면 모델의 복잡도를 제한하고 사용되는 예측자 수를 제한하여 성능을 개선할 수 있습니다. 예측자는 모델에 포함된 우도 측도로서 목표에 대한 상관관계의 MDL 측도를 기반으로 하여 순위가 결정됩니다.

**최대 Naive Bayes 예측자.** 이 옵션은 Naive Bayes 모델에서 사용할 예측자의 최대수를 지정합니다.

## (7) Oracle 지원 벡터 머신(SVM)

지원 벡터 머신(SVM)은 데이터 과적합 없이도 예측 정확도를 최대화하기 위해 시스템 학습 이론을 사용하는 분류 및 회귀 알고리즘입니다. SVM은 학습 데이터의 선택적 비선형 변환을 사용하며 변환된 데이터에서 회귀분석 방정식을 검색하여 범주형 대상의 경우 클래스를 분할하고 연속형 대상의 경우 목표를 적합하게 만듭니다. Oracle의 SVM 구현을 사용하면 두 가지 사용할 수 있는 커널, 즉, 선형 또는 Gaussian 중 하나를 사용하여 모델을 작성할 수 있습니다. 선형 커널은 비선형 변환을 모두 생략하므로 결과 모형은 본질적으로 회귀 모형입니다.

자세한 정보는 *Oracle 데이터 마이닝 애플리케이션 개발자 안내서* 및 *Oracle 데이터 마이닝 개념*을 참조하십시오.

## ① Oracle SVM 모형 옵션

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**고유 필드.** 각각의 케이스를 고유하게 식별하는 데 사용되는 필드를 지정합니다. 예를 들어, ID 필드(예: *CustomerID*)가 될 수 있습니다. IBM® SPSS® Modeler는 이 키 필드가 숫자여야 한다는 제한사항을 부과합니다.

 **참고:** 이 필드는 모든 Oracle 노드에 대해 선택적입니다(Oracle Adaptive Bayes, Oracle O-Cluster 및 Oracle Apriori 제외).

**자동 데이터 준비.** (11g 전용) Oracle Data Mining의 자동화된 데이터 준비 모드를 사용(기본값) 또는 사용 안함으로 설정합니다. 이 선택란이 선택되면 ODM이 알고리즘에 필요한 데이터 변환을 자동으로 수행합니다. 자세한 정보는 *Oracle Data Mining 개념*을 참조하십시오.

**활성 학습.** 큰 작성 세트를 다루는 방법을 제공합니다. 이 알고리즘은 활성 학습을 함께 사용하여 작은 표본을 기반으로 하는 초기 모델을 작성한 다음 이를 완전한 학습 데이터 세트에 적용하고 결과를 기반으로 하여 표본 및 모델을 점증적으로 적용하십시오. 학습 데이터에 대한 모델이 수렴되거나 허용되는 지원 벡터의 최대 수에 도달할 때까지 순환이 반복됩니다.

**커널 함수.** 선형 또는 Gaussian을 선택하거나 시스템이 가장 적합한 커널을 선택할 수 있도록 기본값인 시스템 정의를 사용하십시오. Gaussian kernel은 더 복잡한 관계를 학습할 수 있으나 일반적으로 계산에 시간이 더 오래 걸립니다. 선형 커널로 시작하여 선형 커널이 적합하지 않은 경우에만 Gaussian kernel을 시도해 볼 수 있습니다. 커널 선택이 더 중요한 회귀 모형에서 이런 경우가 더 빈번합니다. 또한 Gaussian kernel을 사용하여 작성된 SVM 모형은 IBM SPSS Modeler에서 찾아 볼 수 없습니다. 선형 커널을 사용하여 작성된 모형은 표준 회귀 모형과 동일한 방법으로 IBM SPSS Modeler에서 찾아볼 수 있습니다.

**정규화 방법.** 연속형 입력 및 목표 필드에 대한 정규화 방법을 지정합니다. Z-스코어, 최소-최대 또는 지정없음을 선택할 수 있습니다. 자동 데이터 준비 선택란이 선택된 경우 Oracle은 자동으로 정규화를 수행합니다. 수동으로 정규화 방법을 선택하려면 이 선택란을 선택 취소하십시오.

## ② Oracle SVM 고급 옵션

**커널 캐시 크기.** 작성 작업 동안 계산된 커널을 저장하는 데 사용할 캐시의 크기를 바이트 단위로 지정합니다. 예상대로 일반적으로 캐시가 크면 빨리 작성됩니다. 기본값은 50MB입니다.

**수렴허용.** 모델 작성 종료 전에 허용되는 공차 값을 지정합니다. 값은 0 - 1 사이여야 하며 기본값은 0.001입니다. 값이 크면 더 빨리 작성되는 경향이 있으나 덜 정확한 모형이 작성될 수 있습니다.

**표준 편차 지정.** Gaussian kernel에 의해 사용되는 표준 편차 모수를 지정합니다. 이 모수는 모델 복잡도 사이의 균형 및 기타 데이터 세트로 일반화하는 기능(데이터 과적합 및 과소적합)에 영향을 미칩니다. 표준 편차 값이 높으면 과소적합되는 경향이 있습니다. 기본적으로 이 모수는 학습 데이터에서 추정됩니다.

**엡실론 지정.** 회귀 모형에 대해서만 엡실론 집중 모형을 작성할 때 허용되는 오류 구간 값을 지정합니다. 즉, 큰 오류(무시되지 않음)에서 작은 오류(무시됨)를 구분합니다. 값은 0 - 1 사이여야 하며 기본적으로 학습 데이터에서 추정됩니다.

**복잡도 요인 지정.** 학습 데이터에서 측정된 모델 오류 및 데이터 과적합 또는 과소적합을 방지하기 위한 모델 복잡도의 균형을 유지하는 복잡도 요인을 지정합니다. 높은 값은 데이터 과적합의 위험도를 높이면서 오류에 높은 페널티를 부여하며 낮은 값은 오류에 낮은 페널티를 부여하며 과소적합 발생 가능성이 있습니다.

**이상치 비율 지정.** 학습 데이터에서 원하는 이상치 비율을 지정합니다. 단일 클래스 SVM 모형에 대해서만 유효합니다. **복잡도 요인 지정** 설정과 함께 사용할 수 없습니다.

**예측 확률.** 모델이 대상 필드의 가능한 결과에 대한 올바른 예측의 확률을 포함할 수 있게 합니다. 이 기능을 사용하려면 **선택**을 선택하고 **지정** 단추를 클릭하고 가능한 결과 중 하나를 선택한 후 **삽입**을 클릭하십시오.

**예측 세트 사용.** 대상 필드의 가능한 모든 결과에 대한 가능한 모든 결과의 테이블을 생성합니다.

### ③ Oracle SVM 가중치 옵션

분류 모델에서 가중치를 사용하면 가능한 다양한 목표값의 상대적 중요도를 지정할 수 있습니다. 학습 데이터의 데이터 점이 범주 사이에 현실적으로 분배되지 않은 경우에 유용합니다. 가중치를 사용하면 모델을 편향시켜 데이터에서 잘 표현되지 않는 해당 범주에 대한 보안을 수행할 수 있습니다. 대상 값에 대한 가중치 증가는 해당 범주에 대한 올바른 예측의 퍼센트를 증가시켜야 합니다.

세 가지 방법으로 가중치를 설정할 수 있습니다.

- **훈련 데이터 기준.** 이는 기본값입니다. 가중치는 훈련 데이터에 있는 범주의 상대적 빈도를 기반으로 합니다.
- **모든 클래스에 대해 동등함.** 모든 범주에 대한 가중치는  $1/k$ 로 정의됩니다. 여기서  $k$ 는 목표 범주의 수입니다.
- **사용자 정의 자체 가중치를 지정할 수 있습니다.** 가중치의 시작 값은 모든 클래스에 대해 동일하게 설정됩니다. 개별 범주에 대한 가중치를 사용자 정의 값으로 조정할 수 있습니다. 특정 범주의 가중치를 조정하려면 원하는 범주에 해당하는 테이블의 가중치 셀을 선택한 후 셀의 콘텐츠를 삭제하고 원하는 값을 입력하십시오.

모든 범주에 대한 가중치의 합계는 1.0이어야 합니다. 합계가 1.0이 아니면 값을 자동으로 표준화하는 옵션과 함께 경고 메시지가 표시됩니다. 이 자동 조정은 가중치 제한조건을 적용하면서 범주에서 비율을 유지합니다. 언제든지 **표준화** 단추를 클릭해서 이 조정을 수행할 수 있습니다. 모든 범주에 동일한 값으로 테이블을 재설정하려면 **평균화** 단추를 클릭하십시오.

## (8) Oracle 일반화 선형 모형(GLM)

(11g 전용) 일반화 선형 모형은 선형 모형에 의해 작성된 제한적인 가정을 완화시킵니다. 여기에는 목표변수가 정규 분포를 가지며 목표변수에 대한 예측자의 영향이 본질적으로 선형이라는 가정 등이 포함됩니다. 일반화 선형 모형은 다항분포 또는 포아송 분포와 같이 목표의 분포가 비명목 분포를 갖기 쉬운 예측에 적합합니다. 이와 유사하게 일반화 선형 모형은 예측자 및 목표 사이의 관계 또는 링크가 비선형이 되기 쉬운 경우에 유용합니다.

자세한 정보는 *Oracle 데이터 마이닝 애플리케이션 개발자 안내서* 및 *Oracle 데이터 마이닝 개념*을 참조하십시오.

### ① Oracle GLM 모형 옵션

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**고유 필드.** 각각의 케이스를 고유하게 식별하는 데 사용되는 필드를 지정합니다. 예를 들어, ID 필드(예: *CustomerID*)가 될 수 있습니다. IBM® SPSS® Modeler는 이 키 필드가 숫자여야 한다는 제한사항을 부과합니다.

 **참고:** 이 필드는 모든 Oracle 노드에 대해 선택적입니다(Oracle Adaptive Bayes, Oracle O-Cluster 및 Oracle Apriori 제외).

**자동 데이터 준비.** (11g 전용) Oracle Data Mining의 자동화된 데이터 준비 모드를 사용(기본 값) 또는 사용 안함으로 설정합니다. 이 선택란이 선택되면 ODM이 알고리즘에 필요한 데이터 변환을 자동으로 수행합니다. 자세한 정보는 *Oracle Data Mining 개념*을 참조하십시오.

**정규화 방법.** 연속형 입력 및 목표 필드에 대한 정규화 방법을 지정합니다. **Z-스코어**, **최소-최대** 또는 **지정없음**을 선택할 수 있습니다. **자동 데이터 준비** 선택란이 선택된 경우 Oracle은 자동으로 정규화를 수행합니다. 수동으로 정규화 방법을 선택하려면 이 선택란을 선택 취소하십시오.

**결측값 처리.** 입력 데이터에서 결측값을 처리하는 방법을 지정합니다.

- **평균 또는 최빈값으로 바꾸기**는 수치 속성의 결측값을 평균 값으로 대체하고 범주형 속성의 결측값을 최빈값으로 대체합니다.
- **완전한 레코드만 사용**은 결측값이 있는 레코드를 무시합니다.

## ② Oracle GLM 고급 옵션

**행 가중치 사용.** 행에 대한 가중치 요인을 포함하는 열을 선택할 수 있는 인접 드롭 다운 목록을 활성화하려면 이 선택란을 선택하십시오.

**행 진단을 테이블에 저장.** 행 수준의 진단을 포함하는 테이블의 이름을 입력할 수 있는 인접 텍스트 필드를 활성화하려면 이 선택란을 선택하십시오.

**계수 신뢰수준.** 목표에 대해 예측되는 값이 모델에 의해 계산된 신뢰구간 내에 있게 되는 0.0에서 1.0까지의 정확도입니다. 신뢰한계는 계수 통계량과 함께 리턴됩니다.

**목표에 대한 참조범주.** 사용자 정의를 선택하여 참조범주로 사용할 목표 필드에 대한 값을 선택하거나 기본값인 자동으로 두십시오.

**능선 회귀.** 능선 회귀는 변수의 상관관계 차수가 너무 높은 상황을 보완하는 기술입니다. 자동 옵션을 사용하여 알고리즘이 이 기술 사용을 제어하도록 하거나 **사용할 수 없음** 및 **사용** 옵션을 사용하여 수동으로 제어할 수 있습니다. 수동으로 능선 회귀를 사용하도록 선택한 경우, 인접 필드에 값을 입력하여 능선 모수에 대한 시스템 기본값을 대체할 수 있습니다.

**능선 회귀에 대한 VIF 생성.** 선형 회귀에 능선이 사용되는 경우 분산 팽창 계수(VIF) 통계를 생성하려면 이 상자를 선택하십시오.

**예측 확률.** 모델이 대상 필드의 가능한 결과에 대한 올바른 예측의 확률을 포함할 수 있게 합니다. 이 기능을 사용하려면 **선택**을 선택하고 **지정** 단추를 클릭하고 가능한 결과 중 하나를 선택한 후 **삽입**을 클릭하십시오.

**예측 세트 사용.** 대상 필드의 가능한 모든 결과에 대한 가능한 모든 결과의 테이블을 생성합니다.

## ③ Oracle GLM 가중치 옵션

분류 모델에서 가중치를 사용하면 가능한 다양한 목표값의 상대적 중요도를 지정할 수 있습니다. 학습 데이터의 데이터 점이 범주 사이에 현실적으로 분배되지 않은 경우에 유용합니다. 가중치를 사용하면 모델을 편향시켜 데이터에서 잘 표현되지 않는 해당 범주에 대한 보완을 수행할 수 있습니다. 대상 값에 대한 가중치 증가는 해당 범주에 대한 올바른 예측의 퍼센트를 증가시켜야 합니다.

세 가지 방법으로 가중치를 설정할 수 있습니다.

- **훈련 데이터 기준.** 이는 기본값입니다. 가중치는 훈련 데이터에 있는 범주의 상대적 빈도를 기반으로 합니다.

- 모든 클래스에 대해 동등함. 모든 범주에 대한 가중치는  $1/k$ 로 정의됩니다. 여기서  $k$ 는 목표 범주의 수입니다.
- 사용자 정의 자체 가중치를 지정할 수 있습니다. 가중치의 시작 값은 모든 클래스에 대해 동일하게 설정됩니다. 개별 범주에 대한 가중치를 사용자 정의 값으로 조정할 수 있습니다. 특정 범주의 가중치를 조정하려면 원하는 범주에 해당하는 테이블의 가중치 셀을 선택한 후 셀의 콘텐츠를 삭제하고 원하는 값을 입력하십시오.

모든 범주에 대한 가중치의 합계는 1.0이어야 합니다. 합계가 1.0이 아니면 값을 자동으로 표준화하는 옵션과 함께 경고 메시지가 표시됩니다. 이 자동 조정은 가중치 제한조건을 적용하면서 범주에서 비율을 유지합니다. 언제든지 **표준화** 단추를 클릭해서 이 조정을 수행할 수 있습니다. 모든 범주에 동일한 값으로 테이블을 재설정하려면 **평준화** 단추를 클릭하십시오.

## (9) Oracle 의사결정 트리

Oracle 데이터 마이닝은 일반적인 분류 및 회귀 트리 알고리즘을 기반으로 하여 클래식 의사결정 트리 기능을 제공합니다. ODM 의사결정 트리 모형에는 신뢰도, 지원 및 분할 기준을 포함하여 각 노드에 대한 완전한 정보가 포함됩니다. 각 노드에 대한 전체 규칙이 표시될 수 있으며 결측값이 있는 케이스에 모델을 적용할 때 대체하여 사용할 수 있도록 각 노드에 대한 대응 속성이 제공됩니다.

의사결정 트리는 광범위하게 적용될 수 있으며 적용 및 이해가 쉽기 때문에 널리 사용됩니다. 의사결정 트리는 가장 적합한 "분할자", 즉, 다운스트림 데이터 레코드를 더 동일한 모집단으로 분할하는 속성 절단점(AGE > 55 등)을 검색하여 각각의 잠재적인 입력 속성을 조사합니다. 각 분할 의사결정 후에는 ODM이 전체 트리까지 확장하면서 유사한 레코드, 항목 또는 사람 모집단을 나타내는 터미널 "리프"를 작성하면서 프로세스를 반복합니다. 루트 트리 노드(총계 모집단 등)에서 아래로 검색하면서 의사결정 트리가 사람이 읽을 수 있는 IF A, then B 문 규칙을 제공합니다. 이러한 의사결정 트리 규칙은 각 트리 노드에 대한 지원 및 신뢰도도 제공합니다.

적응형 Bayes 네트워크는 각 예측에 대한 설명을 제공하는 데 유용한 짧고 단순한 규칙을 제공할 수 있는 반면에 의사결정 트리는 각 분할 의사결정에 대한 전체 Oracle 데이터 마이닝 규칙을 제공합니다. 의사결정 트리는 최고의 고객, 건강한 환자, 사기와 연관된 요소 등에 대한 세부 사항 프로파일을 개발하는 데도 유용합니다.

### ① 의사결정 트리 모형 옵션

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**고유 필드.** 각각의 케이스를 고유하게 식별하는 데 사용되는 필드를 지정합니다. 예를 들어, ID

필드(예: *CustomerID*)가 될 수 있습니다. IBM® SPSS® Modeler는 이 키 필드가 숫자여야 한다는 제한사항을 부과합니다.

 **참고:** 이 필드는 모든 Oracle 노드에 대해 선택적입니다(Oracle Adaptive Bayes, Oracle O-Cluster 및 Oracle Apriori 제외).

**자동 데이터 준비.** (11g 전용) Oracle Data Mining의 자동화된 데이터 준비 모드를 사용(기본 값) 또는 사용 안함으로 설정합니다. 이 선택란이 선택되면 ODM이 알고리즘에 필요한 데이터 변환을 자동으로 수행합니다. 자세한 정보는 *Oracle Data Mining 개념*을 참조하십시오.

**불순도 메트릭.** 각 노드에서 데이터를 분할하기 위한 최고의 검정 질문을 찾기 위해 사용할 메트릭을 지정합니다. 최고의 분할자 및 분할 값은 노드 내의 엔티티에 대해 목표 값 동질성에서 가장 큰 증가를 발생시키는 분할자 및 분할 값입니다. 동질성은 메트릭에 따라 측정됩니다. 지원되는 메트릭은 지니 및 엔트로피입니다.

## ② 의사결정 트리 고급 옵션

**최대 깊이.** 작성할 트리 모델의 최대 깊이를 설정합니다.

**노드 내의 레코드의 최소 퍼센트.** 노드당 최소 레코드 수의 퍼센트를 설정합니다.

**분할에 대한 레코드의 최소 퍼센트.** 모델을 훈련하기 위해 사용되는 레코드의 총 수의 퍼센트로 표시되는 상위 노드 내의 최소 레코드 수를 설정합니다. 레코드 수가 이 퍼센트 미만이면 분할이 시도되지 않습니다.

**노드 내의 최소 레코드.** 리턴되는 최소 레코드 수를 설정합니다.

**분할에 대한 최소 레코드 수.** 값으로 표시되는 상위 노드 내의 최소 레코드 수를 설정합니다. 레코드 수가 이 값 미만이면 분할이 시도되지 않습니다.

**규칙 식별자.** 선택하면 특정 분할이 작성되는 트리 내의 노드를 식별하기 위한 문자열이 모델에 포함됩니다.

**예측 확률.** 모델이 대상 필드의 가능한 결과에 대한 올바른 예측의 확률을 포함할 수 있게 합니다. 이 기능을 사용하려면 **선택**을 선택하고 **지정** 단추를 클릭하고 가능한 결과 중 하나를 선택한 후 **삽입**을 클릭하십시오.

**예측 세트 사용.** 대상 필드의 가능한 모든 결과에 대한 가능한 모든 결과의 테이블을 생성합니다.

## (10) Oracle O-Cluster

Oracle O-Cluster 알고리즘은 데이터 모그룹 내에서 자연적으로 발생하는 그룹을 식별합니다. 직교 파티셔닝 군집(O-Cluster)은 계층 구조 눈금 기반의 군집 모델을 작성하는 Oracle 독점 군집 알고리즘입니다. 즉, 입력 속성 공간에 축 병렬(직교) 파티션을 작성합니다. 알고리즘은 회귀적으로 작동합니다. 결과 계층 구조는 군집에 속성 공간을 바둑판 모양으로 배열하는 불규칙적인 눈금을 표시합니다.

O-Cluster 알고리즘은 수치 및 범주형 속성을 둘 다 처리하며 ODM는 자동으로 가장 적합한 군집 정의를 선택합니다. ODM은 군집 세부사항 정보, 군집 규칙, 군집 중심값을 제공하며 소속군집에 대한 모집단을 스코어링하는 데 사용될 수 있습니다.

### ① O-Cluster 모형 옵션

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**고유 필드.** 각각의 케이스를 고유하게 식별하는 데 사용되는 필드를 지정합니다. 예를 들어, ID 필드(예: *CustomerID*)가 될 수 있습니다. IBM® SPSS® Modeler는 이 키 필드가 숫자여야 한다는 제한사항을 부과합니다.

 **참고:** 이 필드는 모든 Oracle 노드에 대해 선택적입니다(Oracle Adaptive Bayes, Oracle O-Cluster 및 Oracle Apriori 제외).

**자동 데이터 준비.** (11g 전용) Oracle Data Mining의 자동화된 데이터 준비 모드를 사용(기본값) 또는 사용 안함으로 설정합니다. 이 선택란이 선택되면 ODM이 알고리즘에 필요한 데이터 변환을 자동으로 수행합니다. 자세한 정보는 *Oracle Data Mining 개념*을 참조하십시오.

**최대 군집 수.** 생성되는 군집의 최대 수를 설정합니다.

### ② O-Cluster 고급 옵션

**최대 버퍼.** 최대 버퍼 크기를 설정합니다.

**민감도.** 새 군집을 분할하는 데 필요한 최대 밀도를 지정하는 분수를 설정합니다. 이 분수는 글로벌 균일 밀도와 연관됩니다.

## (11) Oracle K-평균

Oracle K-평균 알고리즘은 데이터 모그룹 내에서 자연적으로 발생하는 그룹을 식별합니다. K-평균 알고리즘은 데이터를 미리 결정된 군집 수로 분할하는 거리 기반의 군집 알고리즘입니다. 단, 충분한 구분 케이스가 있어야 합니다. 거리 기반의 알고리즘은 데이터 점 사이의 유사성을 측정하기 위해 거리 메트릭(함수)에 의존합니다. 데이터 점은 사용된 거리 메트릭에 따라 가장 가까운 군집에 지정됩니다. ODM은 K-평균의 개선된 버전을 제공합니다.

K-평균 알고리즘은 계층적 군집을 지원하며 수치 및 범주형 속성을 처리하며 모집단을 사용자가 지정한 군집 수로 분할합니다. ODM은 군집 세부사항 정보, 군집 규칙, 군집 중심값을 제공하며 소속군집에 대한 모집단을 스코어링하는 데 사용될 수 있습니다.

### ① K-평균 모형 옵션

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**고유 필드.** 각각의 케이스를 고유하게 식별하는 데 사용되는 필드를 지정합니다. 예를 들어, ID 필드(예: *CustomerID*)가 될 수 있습니다. IBM® SPSS® Modeler는 이 키 필드가 숫자여야 한다는 제한사항을 부과합니다.

 **참고:** 이 필드는 모든 Oracle 노드에 대해 선택적입니다(Oracle Adaptive Bayes, Oracle O-Cluster 및 Oracle Apriori 제외).

**자동 데이터 준비.** (11g 전용) Oracle Data Mining의 자동화된 데이터 준비 모드를 사용(기본값) 또는 사용 안함으로 설정합니다. 이 선택란이 선택되면 ODM이 알고리즘에 필요한 데이터 변환을 자동으로 수행합니다. 자세한 정보는 *Oracle Data Mining 개념*을 참조하십시오.

**군집 수.** 생성되는 군집의 수를 설정합니다.

**거리 함수.** K-평균 군집에 사용할 거리 함수를 지정합니다.

**분할 기준.** K-평균 군집에 사용할 분할 기준을 지정합니다.

**정규화 방법.** 연속형 입력 및 목표 필드에 대한 정규화 방법을 지정합니다. Z-스코어, 최소-최대 또는 지정없음을 선택할 수 있습니다.

### ② K-평균 고급 옵션

**반복.** K-평균 알고리즘에 대한 반복계산 수를 설정합니다.

**수렴허용.** K-평균 알고리즘에 대한 수렴허용을 설정합니다.

**구간 수.** K-평균에 의해 설정된 속성 히스토그램 내의 구간 수를 지정합니다. 각 속성에 대한 구간 경계는 전체 학습 데이터 세트에 대해 글로벌 형식으로 계산됩니다. 구간화 방법은 동등 간격입니다. 모든 속성이 동일한 구간 수를 가지나 구간이 하나뿐인 단일값이 있는 속성은 예외입니다.

**블록 성장.** 군집 데이터를 보유하기 위해 할당된 메모리에 대한 성장 요인을 설정합니다.

**최소 퍼센트 속성 지원.** 속성이 군집에 대한 규칙 설명에 포함되기 위해 널이 아니어야 하는 속성 값의 분수를 설정합니다. 결측값이 있는 데이터에서 모수값을 너무 높게 설정하면 매우 짧거나 심지어 비어 있는 규칙이 생성될 수 있습니다.

## (12) Oracle 비음수 교차표 분해(NMF)

비음수 교차표 분해(NMF)는 큰 데이터 세트를 대표적인 속성으로 축소하는 데 유용합니다. NMF는 비선형 주성분분석(PCA)과 개념은 유사하나 많은 수의 속성을 처리할 수 있으며 다양한 유스 케이스에 대해 사용할 수 있는 강력한 최신 기술의 데이터 마이닝 알고리즘입니다.

NMF는 많은 양의 데이터를 축소하는 데 사용할 수 있습니다. 예를 들어, 텍스트 데이터를 데이터의 차원을 축소하는 더 작고 더 희박한 표시로 축소할 수 있습니다. 즉, 훨씬 적은 수의 변수를 사용하여 동일한 정보를 보유할 수 있습니다. NMF 모델의 출력은 SVM과 같은 감독되는 학습 기술 또는 군집 기술과 같이 감독되지 않는 학습 기술을 사용하여 분석할 수 있습니다. Oracle 데이터 마이닝은 NMF 및 SVM 알고리즘을 사용하여 비정형 텍스트 데이터를 마이닝합니다.

### ① NMF 모형 옵션

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**고유 필드.** 각각의 케이스를 고유하게 식별하는 데 사용되는 필드를 지정합니다. 예를 들어, ID 필드(예: *CustomerID*)가 될 수 있습니다. IBM® SPSS® Modeler는 이 키 필드가 숫자여야 한다는 제한사항을 부과합니다.

 **참고:** 이 필드는 모든 Oracle 노드에 대해 선택적입니다(Oracle Adaptive Bayes, Oracle O-Cluster 및 Oracle Apriori 제외).

**자동 데이터 준비.** (11g 전용) Oracle Data Mining의 자동화된 데이터 준비 모드를 사용(기본 값) 또는 사용 안함으로 설정합니다. 이 선택란이 선택되면 ODM이 알고리즘에 필요한 데이터 변환을 자동으로 수행합니다. 자세한 정보는 *Oracle Data Mining 개념*을 참조하십시오.

**정규화 방법.** 연속형 입력 및 목표 필드에 대한 정규화 방법을 지정합니다. Z-스코어, 최소-최대 또는 지정없음을 선택할 수 있습니다. 자동 데이터 준비 선택란이 선택된 경우 Oracle은 자동으로 정규화를 수행합니다. 수동으로 정규화 방법을 선택하려면 이 선택란을 선택 취소하십시오.

## ② NMF 고급 옵션

**변수의 수 지정.** 내보낼 변수 수를 지정합니다.

**난수 시드.** NMF 알고리즘에 대한 난수 시드를 설정합니다.

**반복계산 수.** NMF 알고리즘에 대한 반복계산 수를 설정합니다.

**수렴허용.** NMF 알고리즘에 대한 수렴허용을 설정합니다.

**모든 기능 표시.** 최고 기능에 대한 값만 표시되지 않고 모든 기능에 대한 기능 ID 및 신뢰도가 표시됩니다.

## (13) Oracle Apriori

Apriori 알고리즘은 데이터의 연관 규칙을 검색합니다. 예를 들어, "면도기와 애프터셰이브 로션을 구매하는 고객은 다음 번 구매 시에 면도용 크림을 구매할 수 있습니다." 연관 마이닝 문제점은 두 개의 하위 문제점으로 분해할 수 있습니다.

- 지원이 최소 지원보다 큰 항목의 모든 조합(빈번 항목 세트)을 발견합니다.
- 빈번 항목 세트를 사용하여 원하는 규칙을 생성합니다. 예를 들어, ABC 및 BC가 빈번한 경우에 support(ABC) 대 support(BC)의 비율이 최소한 최소 신뢰도만큼 크면 "A가 BC를 암시한다"라는 규칙이 유지됩니다. ABCD가 빈번하므로 규칙이 최소한의 지원을 가집니다. ODM 연관은 단일 후향 규칙(ABC가 D를 암시함)만 지원합니다.

빈번한 항목 세트의 수는 최소 지원 모수에 의해 제어됩니다. 생성되는 규칙의 수는 빈번한 항목 세트의 수 및 신뢰도 모수에 의해 제어됩니다. 신뢰도 모수가 너무 높게 설정되면 연관 모델에 빈번한 항목 세트는 있으나 규칙이 없을 수 있습니다.

ODM은 Apriori 알고리즘의 SQL 기반 구현을 사용합니다. 후보 생성 및 지원 개수 단계가 SQL 쿼리를 사용하여 구현됩니다. 특화된 인메모리 데이터 구조는 사용되지 않습니다. SQL 쿼리는 미세하게 조정되어 다양한 힌트를 사용하여 데이터베이스 서버에서 효과적으로 실행됩니다.

## ① Apriori 필드 옵션

모든 모델링 노드에는 필드 탭이 있으며, 여기에서 모델 작성 시 사용할 필드를 지정할 수 있습니다.

Apriori 모형을 작성하려면 먼저 연관 모델링에 관련 항목으로 사용할 필드를 지정해야 합니다.

**유형 노드 설정 사용.** 이 옵션은 업스트림 유형 노드의 필드 정보를 사용하도록 노드에 지시합니다. 이는 기본값입니다.

**사용자 정의 설정 사용.** 이 옵션에서는 업스트림 유형 노드에 지정된 항목 대신, 여기에 지정된 필드 정보를 사용하도록 노드에 지시합니다. 이 옵션을 선택한 후 트랜잭션 형식을 사용 중인지 여부에 따라 대화 상자에서 나머지 필드를 지정하십시오.

트랜잭션 형식을 사용하지 않는 경우 다음을 지정하십시오.

- **입력.** 입력 필드를 선택합니다. 유형 노드에서 필드 역할을 *입력*으로 설정하는 것과 유사합니다.
- **파티션.** 이 필드에서는 모델 작성에 대한 훈련, 검정, 검증 단계에 대한 별도의 샘플로 데이터를 파티션하는 데 사용되는 필드를 지정할 수 있습니다.

트랜잭션 형식을 *사용*하는 경우 다음을 지정하십시오.

**트랜잭션 형식 사용.** 데이터를 항목당 행에서 케이스당 행으로 변환하려면 이 옵션을 사용하십시오.

이 옵션을 선택하면 이 대화 상자의 아래 부분에서 필드 제어가 변경됩니다.

트랜잭션 형식의 경우 다음을 지정하십시오.

- **ID.** 목록에서 ID 필드를 선택합니다. 숫자 또는 기호 필드를 ID 필드로 사용할 수 있습니다. 이 필드의 각 고유한 값은 분석의 특정 단위를 표시해야 합니다. 예를 들어, 장바구니 애플리케이션에서 각 ID는 단일 고객을 나타낼 수 있습니다. 웹 로그 분석 애플리케이션의 경우 각 ID는 컴퓨터(IP 주소별) 또는 사용자(로그인 데이터별)를 나타낼 수 있습니다.
- **컨텐츠.** 모델에 대한 컨텐츠 필드를 지정하십시오. 이 필드는 연관 모델링에서 관심이 있는 항목을 포함합니다.
- **파티션.** 이 필드에서는 모델 작성에 대한 훈련, 검정, 검증 단계에 대한 별도의 샘플로 데이터를 파티션하는 데 사용되는 필드를 지정할 수 있습니다. 하나의 샘플을 사용하여 모델을 생성하고, 다른 샘플로 검정하면, 현재 데이터와 유사한 더 큰 데이터 세트에 대해 모델을 일반화할 때 효율성을 효과적으로 표시할 수 있습니다. 유형 또는 파티션 노드를 사용하여 다중 파티션 필드를 정의한 경우 파티셔닝을 사용하는 각 모델링 노드에 있는 필드 탭에서 단일 파티션 필드를 선택해야 합니다. (하나의 파티션만 존재하는 경우 파티션이 사용될 때마다 자동으로 사용됩니다.) 또한 분석에서 선택한 파티션을 적용하려면 노드의 모델 옵션 탭에서 파티셔닝을 사용 가능하게 해야 합니다. (이 옵션을 선택 취소하면 필드 설정을 변경하지 않고도, 파티셔닝을 사용하지 않을 수 있습니다.)

## ② Apriori 모형 옵션

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**고유 필드.** 각각의 케이스를 고유하게 식별하는 데 사용되는 필드를 지정합니다. 예를 들어, ID 필드(예: *CustomerID*)가 될 수 있습니다. IBM® SPSS® Modeler는 이 키 필드가 숫자여야 한다는 제한사항을 부과합니다.

 **참고:** 이 필드는 모든 Oracle 노드에 대해 선택적입니다(Oracle Adaptive Bayes, Oracle O-Cluster 및 Oracle Apriori 제외).

**자동 데이터 준비.** (11g 전용) Oracle Data Mining의 자동화된 데이터 준비 모드를 사용(기본값) 또는 사용 안함으로 설정합니다. 이 선택란이 선택되면 ODM이 알고리즘에 필요한 데이터 변환을 자동으로 수행합니다. 자세한 정보는 *Oracle Data Mining 개념*을 참조하십시오.

**최대 규칙 길이.** 규칙의 최대 전제조건 수를 2에서 20까지의 정수로 설정하십시오. 이는 규칙의 복잡도를 제한하기 위한 방법입니다. 규칙이 너무 복잡하거나 너무 세밀하거나 규칙 세트의 훈련 시간이 너무 오래 걸리면 이 설정을 줄여 보십시오.

**최소 신뢰도.** 최소 신뢰수준을 0에서 1 사이로 설정하십시오. 신뢰도가 지정된 기준보다 낮은 규칙은 삭제됩니다.

**최소 지원.** 최소 지원 임계값을 0에서 1 사이의 값으로 설정하십시오. Apriori는 빈도가 최소 지원 임계값을 초과하는 패턴을 검색합니다.

## (14) Oracle 최소 설명 길이(MDL)

Oracle 최소 설명 길이(MDL) 알고리즘은 대상 속성에 대해 가장 큰 영향을 가진 속성을 식별하는 데 도움을 줍니다. 가장 큰 영향을 가진 속성을 알면 비즈니스를 더 잘 이해하고 관리하는 데 도움이 되며 모델링 활동을 단순화하는 데 도움이 되는 경우가 많습니다. 또한 이러한 속성은 모델을 강화하기 위해 추가하고자 하는 데이터 유형을 표시할 수 있습니다. 예를 들어, MDL은 제조업체 파트의 품질 예측, 이탈과 연관된 요인 또는 특정 질병의 처치와 가장 밀접하게 연관된 세균 등과 관련된 프로세스 속성을 찾는 데 사용될 수 있습니다.

Oracle MDL은 목표를 예측하는 데 중요하지 않은 것으로 간주되는 입력 필드를 삭제합니다. 그런 다음 나머지 입력 필드를 사용하여 Oracle Data Miner에서 볼 수 있는 Oracle 모델과 연관된 세분화되지 않은 모델 너깃을 작성합니다. Oracle Data Miner에서 모델을 찾아보면 나머지 입력 필드를 표시하는 차트가 표시되고 목표 예측에 중요한 순서대로 순위가 매겨집니다.

음수 순위화는 잡음을 표시합니다. 0 또는 그 미만의 값으로 순위가 지정된 입력 필드는 예측에 기여하지 않으며 데이터에서 제거되어야 합니다.

차트를 표시하려면 다음을 수행하십시오.

1. 모델 팔레트에서 세분화되지 않은 모델 너깃을 마우스 오른쪽 단추로 클릭하고 **찾아보기**를 선택하십시오.
2. 모델 창에서 단추를 클릭하여 Oracle Data Miner를 실행하십시오.
3. Oracle Data Miner에 연결하십시오. 자세한 정보는 Oracle Data Miner 주제를 참조하십시오.
4. Oracle Data Miner 네비게이터 패널에서 **모델**을 확장한 다음 **속성 중요도**를 선택하십시오.
5. 관련된 Oracle 모델을 선택하십시오. IBM® SPSS® Modeler에서 지정한 목표 필드와 이름이 동일합니다. 올바른 것인지 확인할 수 없으면 속성 중요도 폴더를 선택하고 작성 날짜별로 모델을 검색하십시오.

### ① MDL 모형 옵션

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**고유 필드.** 각각의 케이스를 고유하게 식별하는 데 사용되는 필드를 지정합니다. 예를 들어, ID 필드(예: *CustomerID*)가 될 수 있습니다. IBM® SPSS® Modeler는 이 키 필드가 숫자여야 한다는 제한사항을 부과합니다.

 **참고:** 이 필드는 모든 Oracle 노드에 대해 선택적입니다(Oracle Adaptive Bayes, Oracle O-Cluster 및 Oracle Apriori 제외).

**자동 데이터 준비.** (11g 전용) Oracle Data Mining의 자동화된 데이터 준비 모드를 사용(기본 값) 또는 사용 안함으로 설정합니다. 이 선택란이 선택되면 ODM이 알고리즘에 필요한 데이터 변환을 자동으로 수행합니다. 자세한 정보는 *Oracle Data Mining 개념*을 참조하십시오.

## (15) Oracle 속성 중요도(AI)

속성 중요도의 목적은 데이터 세트 내의 어떤 속성이 결과와 연관되는지, 최종 결과에 어느 정도로 영향을 미치는지 알아내는 것입니다. Oracle 속성 중요도 노드는 데이터를 분석하고 패턴을 찾고 연관된 신뢰도 수준의 결과를 예측합니다.

### ① AI 모델 옵션

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**파티션된 데이터 사용.** 파티션 필드가 정의된 경우 이 옵션을 사용하면 훈련 파티션의 데이터만 사용하여 모델을 작성합니다.

**자동 데이터 준비.** (11g 전용) Oracle Data Mining의 자동화된 데이터 준비 모드를 사용(기본 값) 또는 사용 안함으로 설정합니다. 이 선택란이 선택되면 ODM이 알고리즘에 필요한 데이터 변환을 자동으로 수행합니다. 자세한 정보는 *Oracle Data Mining 개념*을 참조하십시오.

## ② AI 선택 옵션

옵션 탭으로 모델 너깃에 입력 필드를 선택하거나 제외시키기 위한 기본 설정을 지정할 수 있습니다. 그런 다음 모델을 스트림에 추가하여 후속 모델 작성 노력에 사용할 필드의 서브세트를 선택할 수 있습니다. 또는 모델을 생성한 후 모델 브라우저에서 추가 필드를 선택 또는 선택 취소하여 이 설정을 대체할 수 있습니다. 하지만 기본 설정은 추가로 변경하지 않고도 모델 너깃을 적용할 수 있어서 특히 스크립팅 용도에 유용할 수 있습니다.

다음 옵션을 사용할 수 있습니다.

**순위 지정된 모든 필드.** 중요, 보통 또는 중요하지 않음과 같은 순위를 기준으로 하여 필드를 선택합니다. 한 순위 또는 또 다른 순위에 레코드를 지정하는 데 사용하는 절사 값 외에 각 순위의 레이블을 편집할 수 있습니다.

**최대 필드 수.** 중요도에 따라 상위  $n$ 개의 필드를 선택합니다.

**다음보다 큰 중요도.** 중요도가 지정된 값보다 큰 모든 필드를 선택합니다.

목표 필드는 선택과 상관 없이 항상 보존됩니다.

## ③ AI 모델 너깃 모델 탭

Oracle AI 모델 너깃의 모델 탭에서는 모든 입력의 순위 및 중요도를 표시하고, 왼쪽에 있는 열의 선택란을 사용하여 필터링을 위해 필드를 선택할 수 있습니다. 스트림을 실행할 때 목표 예측과 함께 선택된 필드만 유지됩니다. 기타 입력 필드는 삭제됩니다. 기본 선택은 모델링 노드에 지정된 옵션에 기반하지만, 필요에 따라 추가 필드를 선택하거나 선택 취소할 수 있습니다.

- 순위, 필드 이름, 중요도 또는 기타 표시된 열로 목록을 정렬하려면 열 헤더를 클릭하십시오. 또는 정렬기준 단추 옆의 목록에서 원하는 항목을 선택하고 위로 및 아래로 화살표를 사용하여 정렬 방향을 변경하십시오.
- 도구 모음을 사용하여 모든 필드를 선택 또는 선택 취소하고 필드 확인 대화 상자에 액세스할 수 있습니다. 이 대화 상자에서는 순위 또는 중요도를 기준으로 필드를 선택할 수 있습니다. 또한 Shift 또는 Ctrl 키를 누른 상태로 필드를 클릭하여 선택을 확장할 수 있습니다.
- 중요, 주변 또는 중요하지 않음으로 입력을 순위화할 때 임계값은 테이블 아래 범례에 표시됩니다. 이러한 값은 모델링 노드에 지정됩니다.

## (16) Oracle 모델 관리

Oracle 모델은 기타 IBM® SPSS® Modeler 모델과 동일한 방법으로 모델 팔레트에 추가될 수 있으며 매우 유사한 방법으로 사용될 수 있습니다. 단, IBM SPSS Modeler에서 작성된 각 Oracle 모델이 데이터베이스 서버에 저장된 모델을 실제로 참조하는 경우, 몇 가지 중요한 차이가 있습니다.

### ① Oracle 모델 너깃 서버 탭

IBM® SPSS® Modeler를 통해 ODM 모델을 작성하면 IBM SPSS Modeler에서 모델이 작성되고 Oracle 데이터베이스에서 모델이 작성되거나 교체됩니다. 이런 종류의 IBM SPSS Modeler 모델은 데이터베이스 서버에 저장된 데이터베이스 모델의 콘텐츠를 참조합니다. IBM SPSS Modeler는 동일하게 작성된 **모델 키** 문자열을 IBM SPSS Modeler 모델 및 Oracle 모델 둘 다에 저장하여 일치도 검사를 수행할 수 있습니다.

각 Oracle 모델에 대한 키 문자열은 모델 목록 대화 상자의 **모형정보** 열 아래에 표시됩니다. IBM SPSS Modeler 모델에 대한 키 문자열은 스트림에 배치될 때 IBM SPSS Modeler 모델의 서버 탭의 **모델 키**로 표시됩니다.

모델 너깃의 서버 탭에 있는 확인 단추를 사용하여 IBM SPSS Modeler 모델 및 Oracle 모델의 모델 키가 일치하는지 확인할 수 있습니다. 동일한 이름의 모델을 Oracle에서 발견할 수 없거나 모델 키가 일치하지 않으면 IBM SPSS Modeler 모델이 작성된 후에 Oracle 모델이 삭제되었거나 다시 작성된 것입니다.

### ② Oracle 모델 너깃 요약 탭

모델 너깃의 요약 탭에서는 모델 자체(**분석**), 모델에 사용된 필드(**필드**), 모델 작성 시 사용된 설정(**작성 설정**), 모델 훈련(**훈련 요약**)에 대한 정보를 표시합니다.

먼저 노드를 찾아볼 때 요약 탭 결과를 접습니다. 관심이 있는 결과를 보려면 항목 왼쪽에 있는 펼치기 제어를 사용하여 펼치거나 **모두 펼치기** 단추를 클릭하여 모든 결과를 표시합니다. 결과 보기를 완료한 경우 결과를 숨기려면 펼치기 제어를 사용하여 숨기려는 특정 결과를 접거나 **모두 접기** 단추를 클릭하여 모든 결과를 접으십시오.

**분석.** 특정 모델에 대한 정보를 표시합니다. 이 모델 너깃에 연결된 분석 노드를 실행한 경우에는 해당 분석의 정보도 이 섹션에 표시됩니다.

**필드.** 모델을 작성할 때 목표로 사용되는 필드와 입력을 나열합니다.

**작성 설정.** 모델을 작성할 때 사용되는 설정에 대한 정보를 포함합니다.

**훈련 요약.** 모델 유형, 이를 작성하는 데 사용된 스트림, 이를 작성한 사용자, 작성 시점, 모델 작성 시 경과 시간을 표시합니다.

### ③ Oracle 모델 너깃 설정 탭

모델 너깃의 설정 탭을 사용하면 스코어링 목적의 모델링 노드에서 특정 옵션의 설정을 대체할 수 있습니다.

Oracle 의사결정 트리

**오분류 비용 사용.** Oracle 의사결정 트리 모형에서 오분류 비용을 사용할 것인지 여부를 결정합니다. 자세한 정보는 오분류 비용 주제를 참조하십시오.

**규칙 식별자.** 선택하면(체크하면) Oracle 의사결정 트리 모형에 규칙 식별자 열이 추가됩니다. 규칙 식별자는 특정 분할이 작성되는 트리 내의 노드를 식별합니다.

Oracle NMF

**모든 기능 표시.** 선택하면(체크하면) Oracle NMF 모델 내의 최고 기능에 대한 값만 표시되지 않고 모든 기능에 대한 기능 ID 및 신뢰도가 표시됩니다.

### ④ Oracle 모델 나열

Oracle Data Mining 모델 나열 단추는 기존 데이터베이스 모델을 나열하고 모델을 제거할 수 있게 하는 대화 상자를 시작합니다. 이 대화 상자는 헬퍼 애플리케이션 대화 상자와 ODM 관련 노드에 대한 작성, 찾아보기 및 적용 대화 상자에서 시작할 수 있습니다.

각각의 모델에 대해 다음과 같은 정보가 표시됩니다.

- **모델 이름.** 목록을 정렬하는 데 사용되는 모델의 이름
- **모델 정보.** 작성 날짜/시간 및 목표 열 이름으로 구성된 모델 키 정보
- **모델 유형.** 이 모델을 작성한 알고리즘의 이름

### ⑤ Oracle Data Miner

Oracle Data Miner는 Oracle 데이터 마이닝(ODM)에 대한 사용자 인터페이스이며 ODM에 대한 이전의 IBM® SPSS® Modeler 사용자 인터페이스를 대체합니다. Oracle Data Miner는 ODM 알고리즘을 적절히 활용하여 분석가의 성공 비율을 높이도록 계획되었습니다. 이러한 목적은 여러 가지 방법으로 달성할 수 있습니다.

- 사용자가 데이터 준비 및 알고리즘 선택을 모두 다루는 방법을 적용하려면 더 많은 도움이 필요합니다. Oracle Data Miner는 적절한 방법을 통해 사용자를 안내하도록 데이터 마이닝 활동을 제공함으로써 이러한 요구를 충족합니다.
- Oracle Data Miner는 모델 작성 분야의 개선되고 확장된 휴리스틱을 포함하며 모델 및 변환 설정을 지정할 때 오류 발생 확률을 줄이기 위한 변환 마법사를 포함합니다.

## Oracle Data Miner 연결 정의

1. Oracle Data Miner는 모든 Oracle 작성, 적용 노드 및 출력 대화 상자에서 **Oracle Data Miner 시작**을 통해 시작할 수 있습니다.

그림 1. Oracle Data Miner 시작 단추



2. Oracle Data Miner 외부 애플리케이션이 시작되기 전에 Oracle Data Miner **연결 편집** 대화 상자가 표시됩니다. 단, 헬퍼 애플리케이션 옵션이 적절히 정의되어 있어야 합니다.

참고: 이 대화 상자는 정의된 연결 이름이 없는 경우에만 표시됩니다.

- 데이터 마이너 연결 이름을 제공하고 적절한 Oracle 10gR1 또는 10gR2 서버 정보를 입력하십시오. Oracle 서버가 IBM SPSS Modeler에서 지정된 서버와 동일해야 합니다.

3. Oracle Data Miner **연결 선택** 대화 상자는 위 단계에서 정의한 연결 이름 중 사용할 이름을 지정하기 위한 옵션을 제공합니다.

Oracle Data Miner 요구 사항, 설치 및 사용법에 대한 자세한 정보는 Oracle 웹 사이트에서 Oracle Data Miner를 참조하십시오.

## (17) 데이터 준비

모델링에서 Oracle Data Mining 알고리즘과 함께 제공된 Naive Bayes, 적응형 베이스 및 지원 벡터 머신을 사용하는 경우 두 가지 유형의 데이터 준비가 유용할 수 있습니다.

- **구간화**(연속형 숫자 범위 필드를 연속형 데이터를 승인할 수 없는 알고리즘에 대한 범주로 변환)
- **정규화**(비슷한 평균 및 표준 편차를 가지도록 숫자 범위에 적용된 변환)

### 구간화

IBM® SPSS® Modeler의 구간화 노드는 구간화 조작을 수행하는 데 필요한 다수의 기술을 제공합니다. 구간화 조작은 하나 이상의 필드에 적용할 수 있도록 정의됩니다. 데이터 세트에 대해 구간화 조작을 실행하면 임계값이 작성되고 IBM SPSS Modeler 파생 노드가 작성될 수 있습니다. 모델 작성 및 스코어링 전에 파생 조작을 SQL로 변환하여 적용할 수 있습니다. 이 접근 방

식에서는 구간화를 수행하지만 다중 모델 작업에서 구간화 사양을 재사용할 수 있게 하는 파생 노드와 모델 간 종속성을 작성할 수 있습니다.

## 정규화

지원 벡터 머신 모델에 대한 입력으로 사용되는 연속형(숫자 범위) 필드는 모델 작성 전에 정규화해야 합니다. 회귀 모델의 경우에는 모델 출력에서 스코어를 재구성하기 위해 정규화를 되돌리기도 해야 합니다. SVM 모델 설정을 사용하면 **Z-스코어**, **최소-최대** 또는 **없음**을 선택할 수 있습니다. 정규화 계수는 모델 작성 프로세스의 한 단계로 Oracle에 의해 구성되며 이 계수는 IBM SPSS Modeler에 업로드되고 모델과 함께 저장됩니다. 적용 시 이 계수는 IBM SPSS Modeler 파생 표현식으로 변환되고 데이터를 모델에 전달하기 전에 스코어링을 위해 데이터를 준비하는 데 사용됩니다. 이 경우 정규화는 모델링 작업과 밀접하게 연관되어 있습니다.

## (18) Oracle 데이터 마이닝 예

IBM® SPSS® Modeler와 함께 ODM을 사용하는 방법을 나타내는 여러 표본 스트림이 포함됩니다. 이러한 스트림은 `₩Demos₩Database_Modelling₩Oracle Data Mining₩` 아래의 IBM SPSS Modeler 설치 폴더에 있습니다.

**참고:** Demos 폴더는 Windows 시작 메뉴의 IBM SPSS Modeler 프로그램 그룹에서 액세스할 수 있습니다.

다음 표의 스트림은 Oracle 데이터 마이닝과 함께 제공되는 지원 벡터 머신(SVM)을 사용하여 데이터베이스 마이닝 프로세스의 예로서 순서대로 함께 사용될 수 있습니다.

표 1. 데이터베이스 마이닝 - 예 스트림	
스트림	설명
<code>1_upload_data.str</code>	플랫 파일에서 데이터베이스로 데이터를 정리하고 업로드하는 데 사용됩니다.
<code>2_explore_data.str</code>	IBM SPSS Modeler를 사용한 데이터 탐색의 예를 제공합니다.
<code>3_build_model.str</code>	데이터베이스의 원래 알고리즘을 사용하여 모델을 작성합니다.
<code>4_evaluate_model.str</code>	IBM SPSS Modeler를 사용하여 모형을 평가하는 예로 사용됩니다.
<code>5_deploy_model.str</code>	In-Database 스코어링에 대한 모델을 배포합니다.

**참고:** 예를 실행하려면 스트림이 순서대로 실행되어야 합니다. 또한 사용할 데이터베이스에 대한 유효한 데이터 소스를 참조하기 위해 각 스트림의 소스 및 모델링 노드가 업데이트되어야 합니다.

예제 스트림에서 사용된 데이터 세트는 신용카드 애플리케이션과 관련되며 분류 문제점에 범주형 예측변수와 연속형 예측변수의 혼합을 제공합니다. 이 데이터 세트에 대한 자세한 정보는 샘플 스트림과 동일한 폴더의 *crx.names* 파일을 참조하십시오.

이 데이터 세트는 UCI Machine Learning Repository <ftp://ftp.ics.uci.edu/pub/machine-learning-databases/credit-screening/>에서 사용 가능합니다.

### ① 예제 스트림: 데이터 업로드

첫 번째 예제 스트림인 *1\_upload\_data.str*은 플랫폼 파일의 데이터를 정리하고 Oracle로 업로드하는 데 사용됩니다.

Oracle Data Mining을 사용하려면 고유 ID 필드가 필요하므로 이 초기 스트림에서는 파생 노드를 통해 IBM® SPSS® Modeler @INDEX 함수를 사용하여 새 필드를 고유 값 1,2,3을 가진 *ID*라는 데이터 세트에 추가합니다.

채움 노드는 결측값 처리에 사용되며 텍스트 파일 *crx.data*로부터 읽어오는 비어 있는 필드를 *NULL* 값으로 바꿉니다.

### ② 예제 스트림: 데이터 탐색

두 번째 예제 스트림인 *2\_explore\_data.str*은 요약 통계 및 그래프를 포함하여 데이터의 일반적인 개요를 얻기 위해 데이터 검토 노드를 사용하는 방법을 보여주는 데 사용됩니다.

데이터 검토 보고서에서 그래프를 두 번 클릭하면 지정된 필드를 더 깊게 탐색할 수 있도록 자세한 그래프가 생성됩니다.

### ③ 예제 스트림: 모델 작성

세 번째 예제 스트림인 *3\_build\_model.str*은 IBM® SPSS® Modeler에서 모델 작성을 보여줍니다. 데이터베이스 소스 노드(CREDIT로 레이블 지정됨)를 두 번 클릭하여 데이터 소스를 지정하십시오. 작성 설정을 지정하려면 작성 노드를 두 번 클릭하십시오(이 노드는 처음에는 CLASS로 레이블 지정되어 있지만 데이터 소스가 지정될 때 FIELD16으로 변경됨).

대화 상자의 모델 탭에서:

1. ID가 고유 필드로 선택되어 있는지 확인하십시오.
2. 선형이 커널 함수로 선택되어 있고 Z-스코어가 정규화 방법인지 확인하십시오.

#### ④ 예제 스트림: 모델 평가

네 번째 예제 스트림인 *4\_evaluate\_model.str*은 In-Database 모델링에 대해 IBM® SPSS® Modeler를 사용할 때의 장점을 보여줍니다. 모델을 실행하고 나면 해당 모델을 다시 데이터 스트림에 추가하고 IBM SPSS Modeler에서 제공된 여러 도구를 사용하여 해당 모델을 평가할 수 있습니다.

##### 모델링 결과 보기

테이블 노드를 모델 너깃에 연결하여 결과를 탐색하십시오. **\$O-field16** 필드에는 각 케이스의 *field16*에 대한 예측값이 표시되고 **\$OC-field16** 필드에는 이 예측에 대한 신뢰도가 표시됩니다.

##### 모델 결과 평가

분석 노드를 사용하여 각 예측 필드와 해당 목표 필드 간 일치의 패턴을 보여주는 일치 교차표를 작성할 수 있습니다. 분석 노드를 실행하여 결과를 확인하십시오.

평가 노드를 사용하여 모델에 의해 작성된 정확도 개선사항을 표시하도록 설계된 Gains 차트를 작성할 수 있습니다. 평가 노드를 실행하여 결과를 확인하십시오.

#### ⑤ 예제 스트림: 모델 배포

모델의 정확도에 만족한 경우에는 외부 애플리케이션과 함께 사용하거나 데이터베이스에 다시 게시하기 위해 해당 모델을 배포할 수 있습니다. 최종 예제 스트림인 *5\_deploy\_model.str*에서는 데이터를 CREDITDATA 테이블에서 읽어온 후 *배포 솔루션*이라는 발행자 노드를 사용하여 스코어링하여 CREDITSCORES 테이블에 게시합니다.

## 4) IBM® Netezza® 및 IBM Netezza Analytics를 사용한 데이터베이스 모델링

### (1) IBM Data Warehouse 및 IBM Netezza Analytics가 포함된 SPSS Modeler

IBM® SPSS® Modeler는 IBM Data Warehouse 및 IBM Netezza® Analytics와의 통합을 지원하며 이를 통해 이러한 IBM 서버에서 고급 분석을 실행하는 기능을 제공합니다. 이 기능은 IBM SPSS Modeler 그래픽 사용자 인터페이스 및 워크플로우 지향 개발 환경을 통해 액세스할 수 있으며 이를 통해 IBM Netezza 또는 IBM Data Warehouse 환경에서 직접 데이터 마이닝 알고리즘을 실행할 수 있습니다.

SPSS Modeler는 IBM Netezza Analytics에서 제공하는 다음과 같은 알고리즘의 통합을 지원합니다.

- 의사결정 트리
- K-평균
- TwoStep
- Bayes Net
- Naive Bayes
- KNN
- 분열 군집
- PCA
- 회귀분석 트리
- 선형 회귀
- 시계열
- 일반화 선형

이러한 알고리즘에 대한 자세한 정보는 *IBM Netezza Analytics 개발자 안내서* 및 *IBM Netezza Analytics 참조서*를 참조하십시오.

SPSS Modeler는 **IBM Data Warehouse**에서 제공하는 다음과 같은 알고리즘의 통합을 지원합니다. 단, Bayes Net, 분열 군집 및 시계열은 지원되지 않습니다.

- 의사결정 트리
- K-평균
- TwoStep
- Naive Bayes
- KNN
- PCA
- 회귀분석 트리
- 선형 회귀
- 일반화 선형

 **참고:** AIX는 지원되지 않습니다.

## (2) 통합 요구사항

다음 조건은 IBM® Netezza® Analytics 또는 IBM Data Warehouse를 사용하여 In-Database 모델링을 수행하기 위한 전제조건입니다. 데이터베이스 관리자에게 문의하여 이 조건이 충족되는지 확인해야 할 수 있습니다.

- Windows 또는 UNIX(IBM Netezza ODBC 드라이버를 사용할 수 없는 zLinux 제외)의 IBM SPSS® Modeler Server 설치에 대해 실행 중인 IBM SPSS Modeler
- IBM Netezza Analytics 패키지를 실행 중인 IBM Netezza Performance Server

**참고:** 필요한 Netezza Performance Server(NPS)의 최소 버전은 필요한 INZA의 버전에 따라 다르며 다음과 같습니다.

- NPS 6.0.0 P8 이상의 버전은 2.0 이전의 INZA 버전을 지원합니다.
- INZA 2.0 이상을 사용하려면 NPS 6.0.5 P5 이상이 필요합니다.

Netezza 일반화 선형 및 Netezza 시계열이 작동하려면 INZA 2.0 이상이 필요합니다. 기타 모든 Netezza In-Database 노드에는 INZA 1.1 이상이 필요합니다.

- IBM Netezza 데이터베이스에 연결하기 위한 ODBC 데이터 소스. 자세한 정보는 통합 사용의 내용을 참조하십시오.
- IBM Data Warehouse 데이터베이스에 연결하기 위한 ODBC 데이터 소스
- IBM SPSS Modeler에서 사용으로 설정된 SQL 생성 및 최적화. 자세한 정보는 통합 사용의 내용을 참조하십시오.

**참고:** 데이터베이스 모델링 및 SQL 최적화를 위해서는 IBM SPSS Modeler 컴퓨터에서 IBM SPSS Modeler Server 연결성이 설정되어 있어야 합니다. 이 설정이 사용 가능하면 데이터베이스 알고리즘에 액세스하고, SQL을 IBM SPSS Modeler에서 직접 푸시백하고, IBM SPSS Modeler Server에 액세스할 수 있습니다. 현재 라이선스 상태를 검증하려면 IBM SPSS Modeler 메뉴에서 다음을 선택하십시오.

도움말 > 정보 > 추가 세부사항

연결성이 사용 가능으로 설정되면 라이선스 상태 탭에 **서버 사용 가능** 옵션이 표시됩니다.

### (3) 통합 사용

IBM® Netezza® Analytics 또는 IBM Data Warehouse와의 통합을 사용으로 설정하려면 다음 단계를 수행해야 합니다.

- IBM Netezza Analytics 또는 IBM Data Warehouse 구성
- ODBC 소스 작성
- IBM SPSS® Modeler에서 통합을 사용으로 설정
- IBM SPSS Modeler에서 SQL 생성 및 최적화를 사용으로 설정

이에 대해서는 아래의 절에 설명되어 있습니다.

#### ① IBM Netezza Analytics 또는 IBM Data Warehouse 구성

IBM® Netezza® Analytics 또는 IBM Data Warehouse를 설치하고 구성하려면 해당 IBM 문서를 참조하십시오. 예를 들어, IBM Netezza Analytics의 경우 해당 제품과 함께 제공되는 *IBM*

*Netezza Analytics 설치 안내서*를 참조하십시오. 이 안내서의 *데이터베이스 권한 설정* 절에는 IBM SPSS® Modeler 스트림이 데이터베이스에 쓸 수 있도록 하기 위해 실행해야 하는 스크립트의 세부사항이 포함되어 있습니다.

**참고:** 교차표 계산에 의존하는 노드를 사용하려는 경우에는 CALL NZM.INITIALIZE();를 실행하여 교차표 엔진을 초기화해야 합니다. 그렇지 않으면 스토어드 프로시저 실행이 실패합니다. 초기화는 각 데이터베이스에 대한 일회성 설정 단계입니다.

## ② IBM Netezza® Analytics에 대한 ODBC 소스 작성

IBM Netezza 데이터베이스와 IBM® SPSS® Modeler 사이에 연결을 사용하려면 ODBC 시스템 데이터 소스 이름(DSN)을 작성해야 합니다.

DSN을 작성하기 전에 ODBC 데이터 소스 및 드라이버와 IBM SPSS Modeler에서의 데이터베이스 지원에 대한 기본적인 이해가 필요합니다.

IBM SPSS Modeler Server에 대해 분산 모드에서 실행 중인 경우에는 서버 컴퓨터에서 DSN을 작성하십시오. 로컬(클라이언트) 모드에서 실행 중인 경우에는 클라이언트 컴퓨터에서 DSN을 작성하십시오.

## Windows 클라이언트

1. *Netezza 클라이언트* CD에서 *nzodbcsetup.exe* 파일을 실행하여 설치 프로그램을 시작하십시오. 화면에 표시되는 지시사항에 따라 드라이버를 설치하십시오. 전체 지시사항을 보려면 IBM Netezza ODBC, JDBC 및 OLE DB 설치 및 구성 안내서를 참조하십시오.

a. DSN 작성.

**참고:** 메뉴 순서는 Windows 버전에 따라 다릅니다.

- **Windows XP.** 시작 메뉴에서 **제어판**을 선택하십시오. **관리 도구**를 두 번 클릭한 후 **데이터 소스(ODBC)**를 두 번 클릭하십시오.
- **Windows Vista.** 시작 메뉴에서 **제어판**을 선택한 후 **시스템 유지보수**를 선택하십시오. **관리 도구**를 두 번 클릭하고 **데이터 소스(ODBC)**를 선택한 후 **열기**를 클릭하십시오.
- **Windows 7.** 시작 메뉴에서 **제어판**, **시스템 & 보안**, **관리 도구**를 차례로 선택하십시오. **데이터 소스(ODBC)**를 선택한 후 **열기**를 클릭하십시오.

b. 시스템 DSN 탭으로 이동한 후 **추가**를 클릭하십시오.

2. 목록에서 **NetezzaSQL**을 선택한 후 **완료**를 클릭하십시오.

3. Netezza ODBC 드라이버 설정 화면의 **DSN 옵션** 탭에서 선택한 데이터 소스 이름, IBM Netezza 서버의 호스트 이름 또는 IP 주소, 연결의 포트 번호, 사용 중인 IBM Netezza 인스턴스의 데이터베이스 및 데이터베이스 연결에 대한 사용자 이름 및 비밀번호 세부사항을 입력하십시오. 필드에 대한 설명을 보려면 **도움말** 단추를 클릭하십시오.
4. **연결 테스트** 단추를 클릭하여 데이터베이스에 연결할 수 있는지 확인하십시오.
5. 성공적으로 연결되어 있으면 **확인**을 반복적으로 클릭하여 ODBC 데이터 소스 관리자 화면을 종료하십시오.

## Windows Server

Windows Server에 대한 프로시저는 Windows XP에 대한 클라이언트 프로시저와 동일합니다.

## UNIX 또는 Linux 서버

다음의 프로시저가 UNIX 또는 Linux 서버에 적용됩니다(IBM Netezza ODBC 드라이버를 사용할 수 없는 zLinux는 제외).

1. Netezza 클라이언트 CD/DVD에서 관련 <platform>cli.package.tar.gz 파일을 서버의 임시 위치에 복사하십시오.
2. **gunzip** 및 **untar** 명령을 사용하여 아카이브 콘텐츠를 추출하십시오.
3. 추출되는 *unpack* 스크립트에 실행 권한을 추가하십시오.
4. 스크립트를 실행하여 화면에 표시되는 프롬프트에 응답하십시오.
5. modelersrv.sh 파일을 편집하여 다음의 행을 포함하십시오.

```
. <SDAP Install Path>/odbc.sh
LD_LIBRARY_PATH_64=$LD_LIBRARY_PATH:/usr/local/nz/lib64; export
LD_LIBRARY_PATH_64
NZ_ODBC_INI_PATH=<SDAP Install Path>; export NZ_ODBC_INI_PATH
```

예:

```
. /usr/IBM/SPSS/SDAP/odbc.sh
LD_LIBRARY_PATH_64=$LD_LIBRARY_PATH:/usr/local/nz/lib64; export
LD_LIBRARY_PATH_64
NZ_ODBC_INI_PATH=/usr/IBM/SPSS/SDAP; export NZ_ODBC_INI_PATH
```

6. /usr/local/nz/lib64/odbc.ini 파일을 찾아서 해당 콘텐츠를 SDAP과 함께 설치되는 odbc.ini 파일(\$ODBCINI 환경 변수에 의해 정의된 파일)에 복사하십시오.

**참고:** 64비트 Linux 시스템의 경우 **Driver** 모수는 32비트 드라이버를 잘못 참조합니다. 이전 단계의 odbc.ini 콘텐츠를 복사하는 경우에는 이 모수 내에서 적절하게 경로를 편집하십시오. 예를 들어, 다음과 같습니다.

```
/usr/local/nz/lib64/libnzodbc.so
```

7. Netezza DSN 정의를 편집하여 사용될 데이터베이스를 반영하십시오.
8. IBM SPSS Modeler Server를 다시 시작한 후 클라이언트에서 Netezza In-Database 마이닝 노드의 사용을 테스트하십시오.

### ③ SPSS Modeler에서 통합 사용

1. IBM® SPSS® Modeler 기본 메뉴에서 다음을 선택하십시오.  
**도구 > 옵션 > 헬퍼 애플리케이션**

2. IBM Data Warehouse 탭을 클릭하십시오.

**IBM Data Warehouse Analytics 통합 사용:** IBM SPSS Modeler 창의 맨 아래에 있는 데이터베이스 모델링 팔레트를 사용으로 설정(아직 표시되지 않은 경우)하고 IBM Data Warehouse 및 Netezza Data Mining 알고리즘에 대한 노드를 추가합니다.

**IBM Data Warehouse 연결:** 편집 단추를 클릭한 후 ODBC 소스를 작성할 때 설정한 IBM Data Warehouse 연결 문자열을 선택하십시오. 자세한 정보는 IBM Data Warehouse 관리 콘솔을 참조하십시오.

### ④ SQL 생성 및 최적화 사용

매우 큰 데이터 세트에 대해 작업할 수도 있기 때문에 성능을 위해 IBM® SPSS® Modeler에서 SQL 생성 및 최적화 옵션을 사용으로 설정해야 합니다.

1. IBM SPSS Modeler 메뉴에서 다음을 선택하십시오.  
**도구 > 스트림 특성 > 옵션**
2. 탐색 분할창에서 **최적화** 옵션을 클릭하십시오.
3. **SQL 생성** 옵션이 사용으로 설정되어 있는지 확인하십시오. 이 설정은 데이터베이스 모델링이 작동하기 위해 필수입니다.
4. **SQL 생성 최적화 및 기타 실행 최적화**를 선택하십시오(엄격하게 요구되지 않지만 최적화된 성능을 위해서는 강력하게 권장됨).

## (4) IBM Netezza® Analytics 및 IBM Data Warehouse를 사용한 모델 작성

각각의 지원되는 알고리즘에는 해당 모델링 노드가 있습니다. 노드 팔레트의 **데이터베이스 모델링** 탭에서 IBM Data Warehouse 및 IBM Netezza 모델링 노드에 액세스할 수 있습니다.

## 데이터 고려사항

데이터 소스에 있는 필드는 모델링 노드에 따라 다양한 데이터 유형의 변수를 포함할 수 있습니다. IBM® SPSS® Modeler에서는 데이터 유형이 측정 수준으로 알려져 있습니다. 모델링 노드의 필드 탭에서는 아이콘을 사용하여 해당 입력 및 대상 필드에 대해 허용되는 측정 수준 유형을 표시합니다.

**대상 필드** - 대상 필드는 예측하려는 값이 있는 필드입니다. 목표를 지정할 수 있는 경우 소스 데이터 필드 중 하나만 대상 필드로 선택할 수 있습니다.

**레코드 ID 필드** - 각각의 케이스를 고유하게 식별하는 데 사용되는 필드를 지정합니다. 예를 들어, ID 필드(예: *CustomerID*)가 될 수 있습니다. 소스 데이터가 ID 필드를 포함하지 않는 경우에는 다음 프로시저에 표시된 대로 파생 노드를 사용하여 이 필드를 작성할 수 있습니다.

1. 소스 노드를 선택하십시오.
2. 노드 팔레트의 필드 조작 탭에서 파생 노드를 두 번 클릭하십시오.
3. 캔버스에서 해당 아이콘을 두 번 클릭하여 파생 노드를 여십시오.
4. **파생 필드** 필드에 예를 들어, ID를 입력하십시오.
5. **수식** 필드에서 @INDEX를 입력한 후 **확인**을 클릭하십시오.
6. 파생 노드를 나머지 스트림에 연결하십시오.

**참고:** NUMERIC(18,0) 데이터 유형을 사용하여 Netezza 데이터베이스에서 긴 숫자 데이터를 검색하는 경우 SPSS Modeler는 가져오는 동안 데이터를 반올림할 수 있습니다. 이 문제를 방지하기 위해 BIGINT 또는 NUMERIC(36,0) 데이터 유형을 사용하여 데이터를 저장하십시오.

**참고:** 사용 가능한 필드 유형에 제한이 있으므로 측정 수준이 유형 없음이고 역할이 레코드 ID인 필드는 Netezza In-Database 모델링 노드(예: K-평균)에 표시되지 않습니다.

## 널값 처리

입력 데이터에 널값이 포함되어 있는 경우 일부 Netezza 노드를 사용하면 오류 메시지가 표시되거나 장기 실행 스트림이 발생할 수 있으므로 널값이 포함된 레코드는 제거하는 것이 좋습니다. 다음의 방법을 사용하십시오.

1. 선택 노드를 소스 노드에 연결하십시오.
2. 선택 노드의 **모드** 옵션을 **삭제**로 설정하십시오.
3. **조건** 필드에서 다음을 입력하십시오.

```
@NULL(field1) [or @NULL(field2)[... or @NULL(fieldN)]]
```

모든 입력 필드를 포함해야 합니다.

4. 선택 노드를 나머지 스트림에 연결하십시오.

## 모델 출력

IBM Data Warehouse 또는 Netezza 모델링 노드가 포함된 스트림은 실행될 때마다 약간 다른 결과를 생성할 수 있습니다. 이는 모델 작성 전에 데이터를 임시 테이블로 읽어오므로 노드가 소스 데이터를 읽는 순서가 항상 동일하지 않기 때문입니다. 하지만 이 영향에 의해 생성된 차이는 무시할 수 있습니다.

## 일반 주석

- IBM SPSS Collaboration and Deployment Services에서는 IBM Data Warehouse 또는 IBM Netezza 데이터베이스 모델링 노드가 포함된 스트림을 사용하여 스코어링 구성을 작성할 수 없습니다.
- Data Warehouse 또는 Netezza 노드에서 작성된 모델에 대해서는 PMML 내보내기 또는 가져오기를 수행할 수 없습니다.

### ① 필드 옵션

필드 탭에서는 업스트림 노드에 이미 정의된 필드 역할 설정을 사용하거나 수동으로 필드 할당을 할 수 있습니다.

**사전 정의된 역할 사용.** 이 옵션은 업스트림 유형 노드(또는 업스트림 소스 노드의 유형 탭)의 역할 설정(목표 및 예측자 등)을 사용합니다.

**사용자 정의 필드 할당 사용.** 이 화면에서 수동으로 목표, 예측자 및 기타 역할을 지정하려면 이 옵션을 선택하십시오.

**필드.** 화살표 단추를 사용하여 수동으로 이 목록의 항목을 화면 오른쪽의 다양한 역할 필드에 할당하십시오. 아이콘은 각 역할 필드에 대한 유효한 측정 수준을 나타냅니다.

**모두** 단추를 클릭하여 목록의 모든 필드를 선택하거나 개별 측정 수준 단추를 클릭하여 해당 측정 수준의 모든 필드를 선택합니다.

**목표.** 하나의 필드를 예측 목표로 선택하십시오. 일반화 선형 모형의 경우 이 화면에서 **시행** 필드도 참조하십시오.

**레코드 ID.** 고유 레코드 식별자로 사용할 필드입니다.

**예측자(입력).** 예측에 대한 입력으로 하나 이상의 필드를 선택합니다.

## ② 서버 옵션

서버 탭에서 모델을 작성할 IBM Data Warehouse 데이터베이스를 지정합니다.

**IBM Data Warehouse 서버 세부사항.** 여기서는 모델에 사용할 데이터베이스에 대한 연결 세부 사항을 지정합니다.

- **업스트림 연결 사용.** (기본값) 업스트림 노드(예: 데이터베이스 소스 노드)에 지정된 연결 세부 사항을 사용합니다. 이 옵션은 모든 업스트림 노드가 SQL 푸시백을 사용할 수 있는 경우에만 작동합니다. 이 경우에는 SQL이 모든 업스트림 노드를 완전하게 구현하므로 데이터를 데이터베이스 밖으로 이동하지 않아도 됩니다.
- **데이터를 연결로 이동.** 여기에서 지정하는 데이터베이스로 데이터를 이동합니다. 이를 수행하면 데이터가 다른 IBM Data Warehouse 데이터베이스 또는 다른 벤더의 데이터베이스에 있거나 데이터가 플랫폼 파일인 경우에도 모델링이 작동할 수 있습니다. 또한, 노드가 SQL 푸시백을 수행하지 않아 데이터가 추출된 경우에는 여기에 지정된 데이터베이스로 데이터가 다시 이동합니다. 편집 단추를 클릭하여 연결을 찾아서 선택할 수 있습니다.

### ⊘ 경고:

IBM® Netezza® Analytics 및 IBM Data Warehouse는 일반적으로 매우 큰 데이터 세트와 함께 사용됩니다. 데이터베이스 사이에서 또는 데이터베이스 안팎으로 많은 양의 데이터를 전송하면 시간이 많이 걸릴 수 있으므로 가능하면 피해야 합니다.

**ℹ 참고:** ODBC 데이터 소스 이름이 각 IBM SPSS® Modeler 스트림에 효과적으로 임베드됩니다. 한 호스트에서 작성된 스트림이 다른 호스트에서 실행되는 경우 데이터 소스의 이름이 각 호스트에서 동일해야 합니다. 또는 각 소스 또는 모델링 노드의 서버 탭에서 다른 데이터 소스를 선택할 수 있습니다.

## ③ 모델 옵션

모델 옵션 탭에서는 모델 이름을 지정할 것인지, 이름을 자동으로 생성할 것인지 선택할 수 있습니다. 스코어링 옵션에 대한 기본값을 설정할 수 있습니다.

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**이름이 사용된 경우 기존 이름 바꾸기.** 이 선택란을 선택하면 동일한 이름을 가진 모든 기존 모델을 덮어씁니다.

**스코어링에 사용 가능.** 모델 너깃에 대한 대화 상자에 표시될 스코어링 옵션에 대한 기본값을 여기서 설정할 수 있습니다. 이 옵션에 대한 세부사항은 특정 너깃의 설정 탭에 대한 도움말 항목을 참조하십시오.

#### ④ 모델 관리

SPSS® Modeler를 통해 IBM Netezza 또는 IBM Data Warehouse 모델을 작성하면 SPSS Modeler에서는 모델이 작성되고 IBM Data Warehouse 데이터베이스에서는 모델이 작성되거나 바뀝니다. 이 유형의 SPSS Modeler 모델은 데이터베이스 서버에 저장된 데이터베이스 모델의 콘텐츠를 참조합니다. SPSS Modeler는 SPSS Modeler 모델과 Netezza 또는 Data Warehouse 모델 모두에서 동일한 생성된 모델 키 문자열을 저장하여 일관성 검사를 수행할 수 있습니다.

각 Netezza 또는 Data Warehouse 모델에 대한 모델 이름은 데이터베이스 모델 나열 대화 상자의 *모델 정보* 열 아래에 표시됩니다. SPSS Modeler 모델에 대한 모델 이름은 SPSS Modeler 모델(스트림에 배치된 경우)의 서버 탭에서 모델 키로 표시됩니다.

확인 단추는 Netezza 또는 Data Warehouse 모델 및 SPSS Modeler 모델의 모델 키가 일치하는지 확인하는 데 사용할 수 있습니다. 동일한 이름의 모델을 Netezza 또는 Data Warehouse에서 찾을 수 없거나 모델 키가 일치하지 않으면 SPSS Modeler 모델이 작성된 후 Netezza 또는 Data Warehouse 모델이 삭제되었거나 다시 작성된 것입니다.

#### ⑤ 데이터베이스 모델 나열

SPSS® Modeler는 IBM Data Warehouse에 저장된 모델을 나열하는 대화 상자를 제공하고 모델을 삭제할 수 있게 합니다. 이 대화 상자는 IBM 헬퍼 애플리케이션 대화 상자와 IBM Data Warehouse 및 IBM Netezza 데이터 마이닝 관련 노드에 대한 작성, 찾아보기 및 적용 대화 상자에서 액세스할 수 있습니다. 각각의 모델에 대해 다음과 같은 정보가 표시됩니다.

- 모델 이름(목록을 정렬하는 데 사용되는 모델의 이름)
- 소유자 이름
- 모델에서 사용되는 알고리즘
- 모델의 현재 상태(예: 완전)
- 모델이 작성된 날짜

#### (5) IBM Data WH 회귀분석 트리

회귀분석 트리는 케이스 표본을 반복적으로 분할하여 숫자 대상 필드의 값을 기반으로 동일한 종류의 서브세트를 파생하는 트리 기반 알고리즘입니다. 의사결정 트리와 마찬가지로, 회귀분석 트리는 트리의 리프가 충분히 작거나 충분히 균일한 서브세트에 해당되는 여러 서브세트로 데이터를 분해합니다. 분할은 목표 속성 값의 산포도를 줄이기 위해 선택합니다. 그러면 리프에서의 해당 평균 값을 사용하여 목표 속성 값을 상당히 잘 예측할 수 있습니다.

### ① IBM Data WH 회귀분석 트리 작성 옵션 - 트리 성장

트리 성장 및 트리 가지치기를 위한 작성 옵션을 설정할 수 있습니다.

다음 작성 옵션을 트리 성장에 사용할 수 있습니다.

**최대 트리 깊이.** 루트 노드 아래에서 트리가 확장될 수 있는 최대 수준 수, 즉 표본이 반복적으로 분할되는 횟수입니다. 기본값은 62이며, 이 값은 모델링을 위한 최대 트리 깊이입니다.

**참고:** 모델 너트의 뷰어가 모델을 텍스트 형식으로 표현하는 경우 최대 12수준의 트리가 표시됩니다.

**분할 기준.** 이 옵션은 트리 분할 중지 시점을 제어합니다. 기본값을 사용하지 않으려면 사용자 정의를 클릭하고 값을 변경하십시오.

- **분할 평가 척도.** 이 클래스 평가 척도는 트리를 분할하기에 가장 적합한 위치를 평가합니다.

**참고:** 현재, 분산이 사용 가능한 유일한 옵션입니다.

- **분할할 최소 개선도.** 트리에서 새 분할이 작성되기 전에 제거되어야 하는 불순도의 최소 양입니다. 트리 작성의 목표는 유사한 출력 값을 가진 하위 그룹을 작성하여 각 노드 내의 불순도를 최소화하는 것입니다. 분기에 대한 최상의 분할이 분할 기준에 의해 지정된 수치 미만으로 불순도를 감소시키는 경우 분기가 분할되지 않습니다.

- **분할할 인스턴스의 최소수.** 분할할 수 있는 최소 레코드 수입니다. 분할되지 않은 레코드가 이 수 미만으로 남아 있는 경우, 추가 분할이 수행되지 않습니다. 이 필드를 사용하여 트리에서 작은 하위 그룹이 작성되는 것을 방지할 수 있습니다.

**통계량.** 이 매개변수는 모델에 포함되는 통계 수를 정의합니다. 다음 옵션 중 하나를 선택하십시오.

- **모두.** 모든 열 관련 통계량 및 모든 값 관련 통계량이 포함됩니다.

**참고:** 이 매개변수는 통계 최대 수를 포함하므로 시스템 성능에 영향을 줄 수도 있습니다. 모델을 그래픽 형식으로 보지 않으려면 **없음**을 지정하십시오.

- **열.** 열 관련 통계가 포함됩니다.

- **없음.** 모델을 스코어링하는 데 필요한 통계량만 포함됩니다.

### ② IBM Data WH 트리 작성 옵션 - 트리 가지치기

가지치기 옵션을 사용하여 회귀분석 트리의 가지치기 기준을 지정할 수 있습니다. 가지치기의 목적은 새 데이터에 대한 예상 정확도를 향상시키지 않는 지나치게 확장된 하위 그룹을 제거하여 과적합 위험을 줄이기 위한 것입니다.

**가지치기 속도.** 가지치기 속도를 사용하면 트리에서 리프를 제거한 후에 모델의 추정 정확도가 허용 가능한 한계 내로 유지될 수 있습니다. 다음 속도 중 하나를 선택할 수 있습니다.

- **mse.** 평균 제곱 오차 - (기본값) 맞춤선이 데이터 점에 어느 정도 가까운지 측정합니다.
- **r2.** R-제곱 - 회귀 모형에 의해 설명되는 종속변수에서 편차의 비율을 측정합니다.
- **Pearson.** Pearson 상관 계수 - 정규적으로 분포된 선형 종속 변수 간의 관계 강도를 측정합니다.
- **Spearman.** Spearman 상관 계수 - Pearson 상관에 따라 약해 보이지만 실제로는 강할 수 있는 비선형 관계를 발견합니다.

**가지치기를 위한 데이터.** 훈련 데이터의 일부 또는 모두를 사용하여 새 데이터에 대한 예상 정확도를 추정할 수 있습니다. 또는 이 용도로 지정된 테이블에서 별도의 가지치기 데이터 세트를 사용할 수 있습니다.

- **모든 훈련 데이터 사용.** 이 옵션(기본값)은 모든 훈련 데이터를 사용하여 모형 정확도를 추정합니다.
- **가지치기를 위해 훈련 데이터의 % 사용.** 가지치기 데이터에 대해 지정된 백분율을 사용하여 데이터를 두 개의 세트, 즉 훈련을 위한 세트와 가지치기를 위한 세트로 분할하려면 이 옵션을 사용하십시오.  
난수 시드를 지정하여 스트림을 실행할 때마다 데이터가 동일한 방식으로 파티셔닝되도록 하려면 **결과 복제**를 선택하십시오. **가지치기에 사용되는 시드 필드**에 정수를 지정하거나 **생성**을 클릭하여 의사 랜덤 정수를 작성할 수 있습니다.
- **기존 테이블의 데이터 사용.** 모형 정확도를 추정하기 위한 별도의 가지치기 데이터 세트의 테이블 이름을 지정하십시오. 이 방법은 훈련 데이터를 사용하는 것보다 신뢰성이 높은 것으로 간주됩니다. 하지만 이 옵션을 사용하면 훈련 세트에서 데이터의 큰 서브세트가 제거되어 의사결정 트리의 품질이 저하될 수 있습니다.

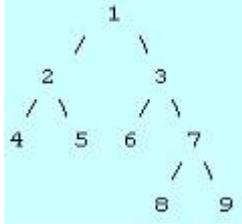
## (6) Netezza 분열 군집

분열 군집은 지정된 중지 포인트에 도달할 때까지 군집을 부군집으로 분열하기 위해 알고리즘이 반복적으로 실행되는 군집분석 방법입니다.

군집 구조는 모든 학습 인스턴스(레코드)를 포함하는 단일 군집으로 시작합니다. 알고리즘의 처음 반복은 데이터 세트를 두 개의 부군집으로 분열하고 후속 반복은 이러한 부군집을 더 작은 부군집으로 분열합니다. 중지 기준은 데이터 세트가 분열되는 최대 수준 수인 최대반복수 및 추가 파티셔닝에 대한 인스턴스의 최소 필요 수로 지정됩니다.

결과적으로 발생하는 계층적 군집 트리는 다음 예에서 보듯이 루트 군집에서 아래로 전파하여 인스턴스를 분류하는 데 사용할 수 있습니다.

그림 1. 분열 균집 트리의 예



부균집 중심에서부터 인스턴스의 거리를 고려하여 각 수준에서 가장 많이 일치하는 부균집이 선택됩니다.

인스턴스가 -1(기본값)이라는 계층 수준이 적용되어 스코어링되는 경우, 리프가 음수로 지정되므로 스코어링이 리프 균집만 리턴합니다. 예에서는 균집 4, 5, 6, 8 또는 9 중 하나가 될 수 있습니다. 그러나 예를 들어, 계층 수준이 2로 설정되면 스코어링이 루트 균집 아래의 두 번째 수준에서 균집 중 하나, 즉 4, 5, 6 또는 7을 리턴합니다.

#### ① Netezza 분열 균집 필드 옵션

필드 탭에서는 업스트림 노드에 이미 정의된 필드 역할 설정을 사용하거나 수동으로 필드 할당을 할 수 있습니다.

**사전 정의된 역할 사용:** 이 옵션은 업스트림 유형 노드(또는 업스트림 소스 노드의 유형 탭)의 역할 설정(목표 및 예측자 등)을 사용합니다.

**사용자 정의 필드 할당 사용:** 이 화면에서 수동으로 목표, 예측자 및 기타 역할을 지정하려면 이 옵션을 선택하십시오.

**필드.** 화살표 단추를 사용하여 수동으로 이 목록의 항목을 화면 오른쪽의 다양한 역할 필드에 할당하십시오. 아이콘은 각 역할 필드에 대한 유효한 측정 수준을 나타냅니다.

**모두** 단추를 클릭하여 목록의 모든 필드를 선택하거나 개별 측정 수준 단추를 클릭하여 해당 측정 수준의 모든 필드를 선택합니다.

**레코드 ID.** 고유 레코드 식별자로 사용할 필드입니다.

**예측자(입력).** 예측에 대한 입력으로 하나 이상의 필드를 선택합니다.

#### ② Netezza 분열 균집 작성 옵션

작성 옵션 탭은 모델을 작성하기 위한 모든 옵션을 설정하는 위치입니다. 물론, **실행** 단추를 클릭하여 모든 기본 옵션으로 모델을 작성할 수도 있지만, 보통 사용자는 고유한 목적을 위해 작성을 사용자 정의하려고 합니다.

**거리 척도.** 데이터 점 사이의 거리를 측정하는 데 사용할 방법입니다. 거리가 클수록 상이성도 커집니다. 옵션은 다음과 같습니다.

- **유클리디안.** (기본값) 두 점 사이의 거리는 두 점을 직선으로 결합하여 계산됩니다.
- **맨해튼.** 두 점 사이의 거리는 해당 좌표 간 절대 차이의 합계로 계산됩니다.
- **캔버라.** 맨해튼 거리와 비슷하지만 원점에 더 가까운 데이터 점에 더 민감합니다.
- **최대.** 두 점 사이의 거리가 좌표 차원을 따라 해당 차이 중 가장 큰 값으로 계산됩니다.

**최대 반복 수.** 동일한 프로세스를 여러 번 반복하여 작업하는 알고리즘입니다. 이 옵션을 사용하면 지정된 반복 수 이후에 모델 훈련을 중지할 수 있습니다.

**군집 트리의 최대 깊이.** 데이터 세트가 소분열될 수 있는 최대 수준 수입니다.

**결과 복제.** 분석을 복제할 수 있도록 해주는 난수 시드를 설정하려면 이 선택란을 선택하십시오. 정수를 지정하거나 **생성**을 클릭하여 유사 난수 정수를 작성할 수 있습니다.

**분할할 인스턴스의 최소수.** 분할할 수 있는 최소 레코드 수입니다. 분할되지 않은 레코드가 이 수 미만으로 남아 있는 경우, 추가 분할이 수행되지 않습니다. 이 필드를 사용하여 군집 트리에서 너무 작은 하위 그룹이 작성되는 것을 방지할 수 있습니다.

## (7) IBM Data WH 일반화 선형

선형 회귀는 숫자 입력 필드 값에 기반하여 레코드를 분류하는 오랫동안 행해진 통계 기법입니다. 선형 회귀는 예측 및 실제 출력 값 사이의 차이를 최소화하는 직선 또는 곡선에 적합합니다. 선형 모형은 학습 및 모델 애플리케이션 둘 다에서 단순성을 가지므로 광범위한 현실 세계의 현상을 모델링하는 데 유용합니다. 단, 선형 모형은 종속(목표)변수에서 정규 분포를 가정하고 독립(예측변수)변수가 종속변수에 선형 영향을 미친다고 가정합니다.

선형 회귀는 유용하나 위의 가정이 적용되지 않는 상황이 많이 있습니다. 예를 들어, 이산형 수의 곱 사이에서 소비자 선택을 모델링하는 경우, 종속변수가 다항분포를 이룰 수 있습니다. 이와 유사하게 나이에 대한 수입을 모델링하는 경우, 일반적으로 나이가 증가하면 수입도 증가하나 둘 사이의 연결이 직선처럼 단순하지는 않습니다.

이러한 상황에 대해 일반화 선형 모형을 사용할 수 있습니다. 일반화 선형 모형은 적합한 함수라는 선택이 있는 경우에 지정된 연결함수를 사용하여 종속변수가 예측자 변수와 관련되도록 선형 회귀를 펼칩니다. 더욱이 이 모델을 사용하면 포아송과 같이 종속변수가 비정규 분포를 가질 수 있습니다.

알고리즘은 지정된 반복계산 수까지 반복적으로 최적 맞춤 모델을 찾습니다. 최적 맞춤을 계산하는 동안 종속변수의 예측값 및 실제 값의 차이의 제곱합으로 오차가 표시됩니다.

## ① IBM Data WH 일반화 선형 모델 필드 옵션

필드 탭에서, 이미 업스트림 노드에 정의된 필드 역할 설정을 사용할 것인지 여부를 선택하거나 필드에 수동으로 할당합니다.

**사전 정의된 역할 사용.** 이 옵션은 업스트림 유형 노드 또는 업스트림 소스 노드의 유형 탭의 역할 설정(예: 목표 또는 예측자)을 사용합니다.

**사용자 정의 필드 할당 사용.** 이 화면에서 수동으로 목표, 예측변수 및 기타 역할을 할당하려면 이 옵션을 선택하십시오.

**필드.** 화살표 단추를 사용하여 수동으로 이 목록의 항목을 화면 오른쪽의 다양한 역할 필드에 할당하십시오. 아이콘은 각 역할 필드에 대한 유효한 측정 수준을 나타냅니다.

**모두** 단추를 클릭하여 목록의 모든 필드를 선택하거나 개별 측정 수준 단추를 클릭하여 해당 측정 수준의 모든 필드를 선택합니다.

**목표.** 예측에 대한 목표로 하나의 필드를 선택하십시오.

**레코드 ID.** 고유 레코드 식별자로 사용할 필드입니다. 이 필드의 값은 고객 ID 번호 등과 같은 각 레코드에 대해 고유해야 합니다.

**인스턴스 가중치.** 인스턴스 가중치를 사용할 필드를 지정하십시오. 인스턴스 가중치는 입력 데이터의 해당 가중치입니다. 기본적으로, 모든 입력 레코드는 동일한 상대값 중요도를 갖고 있으므로 간주됩니다. 입력 레코드에 개별 가중치를 지정하여 중요도를 변경할 수 있습니다. 사용자가 지정하는 필드에는 입력 데이터의 각 행에 대한 숫자 가중치가 포함되어야 합니다.

**예측변수(입력).** 하나 이상의 입력 필드를 선택합니다. 이 동작은 유형 노드에서 필드 역할을 입력으로 설정하는 것과 유사합니다.

## ② IBM Data WH 일반화 선형 모델 옵션 - 일반

모델 옵션 탭에서는 모델 이름을 지정할 것인지, 이름을 자동으로 생성할 것인지 선택할 수 있습니다. 또한 모델에 대한 여러 가지 설정, 연결함수, 입력 필드 상호작용(있는 경우에 한함) 및 스코어링 옵션에 대한 기본값을 작성할 수 있습니다.

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**필드 옵션.** 모델을 작성하기 위한 입력 필드의 역할을 지정할 수 있습니다.

**일반 설정.** 이러한 설정은 알고리즘에 대한 중지 기준과 관계가 있습니다.

- **반복 최대 수.** 알고리즘을 수행할 최대 반복 수입니다. 최소값은 1이며 기본값은 20입니다.
- **최대 오차(1e).** 알고리즘이 최적 맞춤 모델 찾기를 중지해야 하는 최대 오차 값(지수 표기법으로 표현)입니다. 최소값은 0이며 기본값은 -3으로, 1E-3 또는 0.001을 의미합니다.
- **무의미 오차 값 임계값(1e).** 그 이하에서 오류가 0의 값을 갖는 것으로 처리되는 값(지수 표기법으로 표현)입니다. 최소값은 -1이며 기본값은 -7로, 1E-7(또는 0.0000001) 아래의 오류 값은 무의미한 것으로 계수됨을 의미합니다.

**분포 설정.** 이러한 설정은 종속(목표) 변수의 분포와 연관됩니다.

- **반응 변수의 분포.** 분포 유형: 베르누이(기본값), 가우스, 포아송, 이항, 음이항, Wald(역가우스) 및 감마 중 하나입니다.
- **모수.** (포아송 또는 이항 분포 전용) 모수 지정 필드에서 다음 옵션 중 하나를 지정해야 합니다.
  - 데이터에서 자동으로 모수 추정값을 갖도록 하려면 기본값을 선택하십시오.
  - 분포 유사 우도의 최적화를 허용하려면 유사를 선택하십시오.
  - 모수값을 명시적으로 지정하려면 명시를 선택하십시오.

(이항 분포 전용) 이항 분포에 필요하므로 시행 필드로 사용할 입력 테이블 열을 지정해야 합니다. 이 열은 이항 분포에 대한 시행 수를 포함합니다.

(음이항 분포 전용) -1이라는 기본값을 사용하거나 다른 모수값을 지정할 수 있습니다.

**연결함수 설정.** 이러한 설정은 연결함수와 연관이 있으며 종속변수를 예측자 변수와 연관시킵니다.

- **연결함수.** 사용할 함수이며 항등, 역, Invnegative, Invsquare, Sqrt, 거듭제곱, 오즈 거듭제곱, 로그, C로그, 로그로그, C로그로그, 로짓(기본값), 프로빗, Gaussit, Cauchit, Canbinom, Cangeom, Cannegbinom 중 하나입니다.
- **모수.** (거듭제곱 또는 오즈 거듭제곱 연결함수 전용) 연결함수가 거듭제곱 또는 오즈 거듭제곱이면 모수값을 지정할 수 있습니다. 값을 지정하거나 기본값인 1을 사용하려면 선택하십시오.

### ③ IBM Data WH 일반화 선형 모델 옵션 - 상호작용

상호작용 패널은 상호작용(입력 필드 사이의 승법 효과)을 지정하기 위한 옵션을 포함합니다.

**열 상호작용.** 입력 필드 사이의 상호작용을 지정하려면 이 확인 상자를 선택하십시오. 상호작용이 없으면 선택란을 그대로 두십시오.

소스 목록에서 하나 이상의 필드를 선택하고 상호작용은 목록으로 끌어 모델에 상호작용을 입력하십시오. 생성되는 상호작용의 유형은 선택을 놓는 핫스팟에 따라 다릅니다.

- 주. 끌어 놓은 필드가 상호작용 목록 아래쪽에 별도의 주 상호작용으로 표시됩니다.
- 이원. 끌어 놓은 필드의 모든 가능한 쌍이 상호작용 목록 아래쪽에 이원 상호작용으로 표시됩니다.
- 삼원. 끌어 놓은 필드의 모든 가능한 세 개로 구성된 세트가 효과 목록 아래쪽에 삼원 상호작용으로 표시됩니다.
- \*. 끌어 놓은 모든 필드의 조합은 상호작용 목록 아래쪽에 단일 상호작용으로 표시됩니다.

**절편 포함.** 이 모델에는 대개 절편이 포함됩니다. 데이터가 원점을 통과하여 전달된다고 가정할 수 있는 경우 절편을 제외할 수 있습니다.

#### 대화 상자 단추

표시 오른쪽의 단추를 사용하면 모델에서 사용되는 항을 변경할 수 있습니다.

그림 1. 삭제 단추



삭제할 항을 선택하고 삭제 단추를 클릭하여 모델에서 항목을 삭제할 수 있습니다.

그림 2. 다시 정렬 단추



다시 정렬할 항을 선택하고 위로 또는 아래로 화살표를 클릭하여 모델에서 항목을 다시 정렬할 수 있습니다.

그림 3. 사용자 정의 상호작용 단추



#### 가. 사용자 정의 항 추가

$n \times x_1 \times x_1 \times x_1 \dots$  양식으로 사용자 정의 상호작용을 지정할 수 있습니다. 필드 목록에서 필드를 선택하고 오른쪽 화살표 단추를 클릭하여 필드를 사용자 정의 항에 추가한 다음 **곱\***을 클릭하고 다시 다음 필드를 선택한 다음 오른쪽 화살표 단추를 클릭하는 방법으로 계속 진행합니다. 사용자 정의 상호작용을 작성한 다음 **항 추가**를 클릭하여 상호작용 패널로 다시 돌아가십시오.

#### ④ IBM Data WH 일반화 선형 모델 옵션 - 스코어링 옵션

**스코어링에 사용 가능.** 모델 너깃에 대한 대화 상자에 표시될 스코어링 옵션에 대한 기본값을 여기서 설정할 수 있습니다. 자세한 정보는 IBM Data WH 일반화 선형 모형 너깃 - 설정 탭의 내용을 참조하십시오.

- **입력 필드 포함.** 예측 및 모델 출력에 입력 필드를 표시하려면 이 선택란을 선택하십시오.

## (8) IBM Data WH 의사결정 트리

의사결정 트리는 분류 모델을 나타내는 계층 구조입니다. 의사결정 트리 모형을 사용하면 학습 데이터 세트에서 미래 관측을 예측하거나 분류하는 분류 시스템을 개발할 수 있습니다. 분류는 분류의 분할 포인트를 표시하는 가지가 있는 트리 구조 형식을 사용합니다. 분할은 중지 포인트에 도달할 때까지 반복적으로 데이터를 하위 그룹으로 분류합니다. 중지 포인트의 트리 노드를 리프라고 합니다. 각 리프는 하위 그룹 또는 클래스의 멤버에 클래스 레이블로 알려진 레이블을 지정합니다.

### ① 인스턴스 가중치 및 클래스 가중치

기본적으로, 모든 입력 레코드와 클래스는 동일한 상대값 중요도를 갖고 있는 것으로 간주됩니다. 이러한 항목 중 하나 또는 둘 다의 멤버에 개별 가중치를 지정하여 이를 변경할 수 있습니다. 학습 데이터의 데이터 점이 범주 사이에 현실적으로 분배되지 않은 경우에 유용합니다. 가중치를 사용하면 데이터에서 제대로 표시되지 않는 범주에 대해 보완할 수 있도록 모델을 편향시킬 수 있습니다. 목표 값에 대한 가중치를 늘리는 경우에는 해당 범주에 대한 올바른 예측의 백분율을 늘려야 합니다.

의사결정 트리 모델링 노드에서는 두 가지 유형의 가중치를 지정할 수 있습니다. **인스턴스 가중치**는 입력 데이터의 각 행에 가중치를 지정합니다. 다음 표에서 보듯이 가중치는 일반적으로 대부분의 케이스에 1.0으로 지정되고 대다수에 비해 중요도가 높거나 낮은 해당 케이스에 대해서만 더 높거나 낮은 값이 지정됩니다.

표 1. 인스턴스 가중치 예

레코드 ID	목표	인스턴스 가중치
1	drugA	1.1
2	drugB	1
3	drugA	1
4	drugB	0.3

**클래스 가중치**는 다음 표에서 보듯이 대상 필드의 각 범주에 가중치를 지정합니다.

표 2. 클래스 가중치 예

클래스	클래스가중치
drugA	1
drugB	1.5

함께 곱하여 인스턴스 가중치로 사용하는 경우에 두 가지 유형의 가중치를 동시에 사용할 수 있습니다. 따라서 앞의 두 예가 함께 사용되는 경우에 다음 표에서 보듯이 알고리즘에 인스턴스 가중치가 사용될 수 있습니다.

표 3. 인스턴스 가중치 계산 예

레코드ID	계산	인스턴스가중치
1	1.1*1.0	1.1
2	1.0*1.5	1.5
3	1.0*1.0	1
4	0.3*1.5	0.45

## ② Netezza 의사결정 트리 필드 옵션

필드 탭에서는 업스트림 노드에 이미 정의된 필드 역할 설정을 사용하거나 수동으로 필드 할당을 할 수 있습니다.

**사전 정의된 역할 사용** 이 옵션은 업스트림 유형 노드(또는 업스트림 소스 노드의 유형 탭)에서 역할 설정(목표, 예측자 등)을 사용합니다.

**사용자 정의 필드 할당 사용:** 수동으로 대상, 예측자 및 기타 역할을 할당하려면 이 옵션을 선택하십시오.

**필드.** 화살표 단추를 사용하여 수동으로 이 목록의 항목을 화면 오른쪽의 다양한 역할 필드에 할당하십시오. 아이콘은 각 역할 필드에 대한 유효한 측정 수준을 나타냅니다.

목록의 모든 필드를 선택하려면 **모두** 단추를 클릭하거나 개별 측정 수준 단추를 클릭하여 이 측정 수준의 모든 필드를 선택하십시오.

**목표:** 예측에 대한 목표로 하나의 필드를 선택합니다.

**레코드 ID.** 고유 레코드 식별자로 사용할 필드입니다. 이 필드의 값은 각 레코드(고객 ID 번호 등)에 대해 고유해야 합니다.

**인스턴스 가중치.** 여기에 필드를 지정하면 기본값인 클래스 가중치(목표 필드에 대한 범주당 가중치) 대신, 또는 이와 더불어, 인스턴스 가중치(입력 데이터의 행당 가중치)를 사용할 수 있습니다. 여기서 지정하는 필드는 입력 데이터의 각 행에 대한 숫자 가중치를 포함하는 필드여야 합니다. 자세한 정보는 인스턴스 가중치 및 클래스 가중치의 내용을 참조하십시오.

**예측변수(입력).** 하나 이상의 입력 필드를 선택합니다. 유형 노드에서 필드 역할을 **입력**으로 설정하는 것과 유사합니다.

### ③ IBM Data WH 의사결정 트리 작성 옵션

다음 작성 옵션을 트리 성장에 사용할 수 있습니다.

**확장 속도.** 이 옵션은 트리 성장이 측정되는 방법을 제어합니다.

- **불순도 속도.** 이 속도는 트리를 분할하기에 가장 적합한 위치를 평가합니다. 데이터 하위 그룹 또는 세그먼트에서의 변동 측정치입니다. 낮은 불순도 측정치는 대부분의 멤버가 기준 또는 대상 필드에 대해 유사한 값을 갖는 그룹을 나타냅니다. 지원되는 측정치는 **엔트로피** 및 **지니(Gini)**입니다. 이러한 측정은 분기에 대한 범주 소속 확률을 기반으로 합니다.
- **최대 트리 깊이.** 루트 노드 아래에서 트리가 확장될 수 있는 최대 수준 수, 즉 표본이 반복적으로 분할되는 횟수입니다. 이 특성의 기본값은 10이며 이 특성에 대해 설정할 수 있는 최대 값은 62입니다.

**참고:** 모델 너깃의 뷰어가 모델을 텍스트 형식으로 표현하는 경우 최대 12수준의 트리가 표시됩니다.

**분할 기준.** 이 옵션은 트리 분할 중지 시점을 제어합니다.

- **분할할 최소 개선도.** 트리에서 새 분할이 작성되기 전에 제거되어야 하는 불순도의 최소 양입니다. 트리 작성의 목표는 유사한 출력 값을 가진 하위 그룹을 작성하여 각 노드 내의 불순도를 최소화하는 것입니다. 분기에 대한 최상의 분할이 분할 기준에 의해 지정된 수치 미만으로 불순도를 감소시키는 경우 분기가 분할되지 않습니다.
- **분할할 인스턴스의 최소수.** 분할할 수 있는 최소 레코드 수입니다. 분할되지 않은 레코드가 이 수 미만으로 남아 있는 경우, 추가 분할이 수행되지 않습니다. 이 필드를 사용하여 트리에서 작은 하위 그룹이 작성되는 것을 방지할 수 있습니다.

**통계량.** 이 매개변수는 모델에 포함되는 통계 수를 정의합니다. 다음 옵션 중 하나를 선택하십시오.

- **모두.** 모든 열 관련 통계량 및 모든 값 관련 통계량이 포함됩니다.

**참고:** 이 매개변수는 통계 최대 수를 포함하므로 시스템 성능에 영향을 줄 수도 있습니다. 모델을 그래픽 형식으로 보지 않으려면 **없음**을 지정하십시오.

- **열.** 열 관련 통계가 포함됩니다.
- **없음.** 모델을 스코어링하는 데 필요한 통계량만 포함됩니다.

#### 가. IBM Data WH 의사결정 트리 노드 - 클래스 가중치

여기서는 개별 클래스에 가중치를 지정할 수 있습니다. 기본값은 모든 클래스에 동일한 가중치가 부여되도록 모든 클래스에 1 값을 지정하는 것입니다. 서로 다른 클래스 레이블에 대해 서로 다른 숫자 가중치를 지정함으로써 알고리즘이 그에 따라 특정 클래스의 학습 세트에 가중치를 주도록 합니다.

가중치를 변경하려면 **가중치** 열에서 가중치를 두 번 클릭한 후 원하는 변경사항을 작성하십시오.

**값.** 목표 필드의 가능한 값에서 파생된 클래스 레이블 세트입니다.

**가중치.** 특정 클래스에 지정할 가중치입니다. 클래스에 지정하는 가중치가 높을수록 모델이 해당 클래스에 대해 다른 클래스보다 더 민감하게 반응합니다.

클래스 가중치와 인스턴스 가중치를 조합하여 사용할 수 있습니다. 자세한 정보는 인스턴스 가중치 및 클래스 가중치의 내용을 참조하십시오.

#### 나. IBM Data WH 의사결정 트리 노드 - 트리 가지치기

가지치기 옵션을 사용하여 의사결정 트리의 가지치기 기준을 지정할 수 있습니다. 가지치기의 목적은 새 데이터에 대한 예상 정확도를 향상시키지 않는 지나치게 확장된 하위 그룹을 제거하여 과적합 위험을 줄이기 위한 것입니다.

**가지치기 속도.** 기본 가지치기 속도인 **정확도**는 트리에서 리프를 제거한 후 모델의 추정 정확도가 허용 가능한 한계 내로 유지되도록 합니다. 가지치기를 적용하는 동안 클래스 가중치를 고려하려면 대안인 **가중 정확도**를 사용하십시오.

**가지치기를 위한 데이터.** 훈련 데이터의 일부 또는 모두를 사용하여 새 데이터에 대한 예상 정확도를 추정할 수 있습니다. 또는 이 용도로 지정된 테이블에서 별도의 가지치기 데이터 세트를 사용할 수 있습니다.

- **모든 훈련 데이터 사용.** 이 옵션(기본값)은 모든 훈련 데이터를 사용하여 모형 정확도를 추정합니다.
- **가지치기를 위해 훈련 데이터의 % 사용.** 가지치기 데이터에 대해 지정된 백분율을 사용하여 데이터를 두 개의 세트, 즉 훈련을 위한 세트와 가지치기를 위한 세트로 분할하려면 이 옵션을 사용하십시오.  
난수 시드를 지정하여 스트림을 실행할 때마다 데이터가 동일한 방식으로 파티셔닝되도록 하려면 **결과 복제**를 선택하십시오. **가지치기에 사용되는 시드 필드**에 정수를 지정하거나 **생성**을 클릭하여 의사 랜덤 정수를 작성할 수 있습니다.
- **기존 테이블의 데이터 사용.** 모형 정확도를 추정하기 위한 별도의 가지치기 데이터 세트의 테이블 이름을 지정하십시오. 이 방법은 훈련 데이터를 사용하는 것보다 신뢰성이 높은 것으로 간주됩니다. 하지만 이 옵션을 사용하면 훈련 세트에서 데이터의 큰 서브세트가 제거되어 의사결정 트리의 품질이 저하될 수 있습니다.

## (9) IBM Data WH 선형 회귀

선형 모델은 목표와 하나 이상의 예측변수 사이의 선형 관계를 기반으로 연속형 목표를 예측합니다. 선형 관계를 직접 모델링하는 경우에 제한되기는 하나, 선형 회귀 모형은 비교적 단순하며 스코어링에 대해 쉽게 해석되는 수식을 제공합니다. 선형 모형은 신속하고 효율적이며 사용하기 쉽습니다. 단, 더 세분화된 회귀분석 알고리즘에 의해 생성된 모형에 비하면 적용성이 제한됩니다.

### ① IBM Data WH 선형 회귀 작성 옵션

작성 옵션 탭은 모델을 작성하기 위한 모든 옵션을 설정하는 위치입니다. 물론, **실행** 단추를 클릭하여 모든 기본 옵션으로 모델을 작성할 수도 있지만, 보통 사용자는 고유한 목적을 위해 작성을 사용자 정의하려고 합니다.

**방정식을 푸는 데 비정칙값 분해를 사용.** 원래 교차표 대신 비정칙값 분해 교차표를 사용하면 수치 오류에 대해 더 강력하다는 이점이 있으며 계산 속도가 빨라집니다.

**모델에 절편 포함.** 절편을 포함하면 솔루션의 전체 정확도가 높아집니다.

**모델 진단 계산.** 이 옵션을 사용하면 모델에서 수많은 진단이 계산됩니다. 결과는 행렬 또는 표에 저장됩니다. for later review. 진단에는 R 제곱, 잔차 제곱합, 분산 추정, 표준 편차,  $\rho$  값 및  $t$  값이 포함됩니다.

이러한 진단은 모델의 타당성 및 유용성과 관련됩니다. 선형성 가정을 충족하는지 확인하려면 기본 데이터에서 별도로 진단을 실행해야 합니다.

## (10) IBM Data WH KNN

최근접 이웃 분석은 다른 케이스와의 유사성을 기준으로 케이스를 분류하는 방법입니다. 머신 훈련에서 이 분석 방법은 저장된 모든 패턴이나 케이스와 정확히 일치할 필요가 없는 데이터 패턴을 인식하는 방법으로 개발되었습니다. 유사한 케이스는 서로 가까이에 있고 유사하지 않은 케이스는 서로 멀리 떨어져 있습니다. 따라서 두 케이스 사이의 거리는 두 케이스의 상이성 측도가 됩니다.

서로 인접한 케이스를 "이웃"이라고 합니다. 새 케이스(검증용)가 있는 경우, 해당 모델에서 각 케이스와의 거리가 계산됩니다. 가장 유사한 케이스(최근접 이웃)의 분류가 기록되고 새 케이스가 최근접 이웃의 수가 가장 많은 범주에 배치됩니다.

탐색할 최근접 이웃 수를 지정할 수 있으며, 이 값을  $k$ 라고 합니다. 그림은 새 케이스가 두 개의 다른  $k$  값을 사용하여 분류되는 방법을 보여줍니다.  $k = 5$ 일 경우, 대부분의 최근접 이웃이 범주 1에 속하기 때문에 새 케이스는 범주 1에 위치합니다. 그러나  $k = 9$ 일 경우, 대부분의 최근접 이웃이 범주 0에 속하기 때문에 새 케이스는 범주 0에 위치합니다.

또한 최근접 이웃 분석은 연속적인 목표 값을 계산하는 데 사용할 수 있습니다. 이 경우, 가장 가까운 이웃의 평균 또는 중앙값 목표 값이 사용되어 새 케이스의 예측값을 가져옵니다.

### ① IBM Data WH KNN 모델 옵션 - 일반

모형 옵션 - 일반 탭에서는 모델 이름을 지정할 것인지, 이름을 자동으로 생성할 것인지 선택할 수 있습니다. 또한 최근접 이웃 수를 계산하는 방법을 제어하는 옵션을 설정하고 강화된 성능 및 모델의 정확도에 대한 옵션을 설정할 수 있습니다.

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**이웃**

**거리 척도.** 데이터 점 사이의 거리를 측정하는 데 사용할 방법입니다. 거리가 클수록 상이성도 커집니다. 옵션은 다음과 같습니다.

- **유클리디안.** (기본값) 두 점 사이의 거리는 두 점을 직선으로 결합하여 계산됩니다.
- **맨해튼.** 두 점 사이의 거리는 해당 좌표 간 절대 차이의 합계로 계산됩니다.
- **캔버라.** 맨해튼 거리와 비슷하지만 원점에 더 가까운 데이터 점에 더 민감합니다.
- **최대.** 두 점 사이의 거리가 좌표 차원을 따라 해당 차이 중 가장 큰 값으로 계산됩니다.

**최근접 이웃 수(k).** 특정 케이스에 대한 최근접 이웃 수입니다. 많은 수의 이웃을 사용한다고 해서 반드시 더 정확한 모델을 얻을 수 있는 것은 아님에 유의하십시오.

$k$ 를 선택하면 과적합 방지("불량" 데이터의 경우 특히 중요할 수 있음)와 해결(비슷한 인스턴스에 대해 다양한 예측을 생성함) 사이의 균형이 제어됩니다. 일반적으로 1부터 수십까지의 일반적인 값 범위를 사용하여 각 데이터 세트에 대해  $k$ 의 값을 조정해야 합니다.

**성능 및 정확성 강화**

**거리를 계산하기 전에 측정 표준화.** 선택된 경우 이 옵션은 거리 값을 계산하기 전에 연속 입력 필드에 대한 측정을 표준화합니다.

**코어 세트를 사용하여 큰 데이터 세트의 성능 향상.** 선택된 경우 이 옵션은 코어 세트 표본 추출을 사용하여 큰 데이터 세트가 관련된 경우 계산 속도를 높입니다.

## ② IBM Data WH KNN 모델 옵션 - 스코어링 옵션

모델 옵션 - 스코어링 옵션 탭에서 스코어링 옵션에 대한 기본값을 설정하고 개별 클래스에 상대 가중치를 지정할 수 있습니다.

### 점수에 사용 가능

입력 필드 포함. 입력 필드가 기본적으로 스코어링에 포함되는지 여부를 지정합니다.

### 클래스 가중치

모델 작성에서 개별 클래스의 상대적 중요도를 변경하려면 이 옵션을 사용하십시오.

**참고:** 이 옵션은 분류에 KNN을 사용 중인 경우에만 사용 가능합니다. 회귀분석을 수행 중인 경우, 즉, 대상 필드 유형이 연속형인 경우에는 이 옵션을 사용할 수 없습니다.

기본값은 모든 클래스에 동일한 가중치가 부여되도록 모든 클래스에 1 값을 지정하는 것입니다. 서로 다른 클래스 레이블에 대해 서로 다른 숫자 가중치를 지정함으로써 알고리즘이 그에 따라 특정 클래스의 학습 세트에 가중치를 주도록 합니다.

가중치를 변경하려면 **가중치** 열에서 가중치를 두 번 클릭한 후 원하는 변경사항을 작성하십시오.

**값.** 목표 필드의 가능한 값에서 파생된 클래스 레이블 세트입니다.

**가중치.** 특정 클래스에 지정할 가중치입니다. 클래스에 지정하는 가중치가 높을수록 모델이 해당 클래스에 대해 다른 클래스보다 더 민감하게 반응합니다.

## (11) IBM Data WH K-평균

K-평균 노드는 군집분석 방법을 제공하는 K-평균 알고리즘을 구현합니다. 이 노드를 사용하여 데이터 세트를 별개의 그룹으로 군집화할 수 있습니다.

이 알고리즘은 거리 메트릭(함수)을 기반으로 데이터 점 사이의 유사성을 측정하는 거리 기반 군집화 알고리즘입니다. 데이터 점은 사용되는 거리 메트릭에 따라 가장 가까운 군집에 지정됩니다.

각 학습 인스턴스가 가장 가까운 군집에 지정되는 동일한 기본 프로세스를 여러 번 반복 수행함으로써 이 알고리즘이 작동합니다(지정된 거리 함수와 관련하여 해당 인스턴스 및 군집 중심에 적용됨). 그러면 모든 군집 중심이 특정 군집에 지정된 인스턴스의 평균 속성 값 벡터로서 다시 계산됩니다.

### ① IBM Data WH K-평균 필드 옵션

필드 탭에서는 업스트림 노드에 이미 정의된 필드 역할 설정을 사용하거나 수동으로 필드 할당을 할 수 있습니다.

**사전 정의된 역할 사용:** 이 옵션은 업스트림 유형 노드(또는 업스트림 소스 노드의 유형 탭)의 역할 설정(목표 및 예측자 등)을 사용합니다.

**사용자 정의 필드 할당 사용:** 이 화면에서 수동으로 목표, 예측자 및 기타 역할을 지정하려면 이 옵션을 선택하십시오.

**필드.** 화살표 단추를 사용하여 수동으로 이 목록의 항목을 화면 오른쪽의 다양한 역할 필드에 할당하십시오. 아이콘은 각 역할 필드에 대한 유효한 측정 수준을 나타냅니다.

**모두 단추**를 클릭하여 목록의 모든 필드를 선택하거나 **개별 측정 수준 단추**를 클릭하여 해당 측정 수준의 모든 필드를 선택합니다.

**레코드 ID.** 고유 레코드 식별자로 사용할 필드입니다.

**예측자(입력).** 예측에 대한 입력으로 하나 이상의 필드를 선택합니다.

### ② IBM Data WH K-평균 작성 옵션 탭

작성 옵션을 설정하여 고유의 목적에 맞게 모델 작성을 사용자 정의할 수 있습니다.

기본 옵션을 사용하여 모델을 작성하려면 **실행**을 클릭하십시오.

**거리 척도.** 이 매개변수는 데이터 점 사이의 거리를 측정하는 방법을 정의합니다. 거리가 멀수록 유사성이 떨어집니다. 다음 옵션 중 하나를 선택하십시오.

- **유클리디안.** 유클리디안 척도는 두 데이터 점 사이의 직선 거리입니다.
- **정규화 유클리디안.** 정규화 유클리디안 척도는 유클리디안 척도와 유사하지만 제공 표준 편차에 의해 정규화됩니다. 유클리디안 척도와 달리, 정규화 유클리디안 척도는 척도 불변성(scale-invariant)을 가집니다.
- **Mahalanobis의 거리.** Mahalanobis의 거리 척도는 입력 데이터의 상관계수를 고려하는 일반화 유클리디안 척도입니다. Mahalanobis의 거리 척도는 정규화 유클리디안 척도와 같이 규모 불변성을 갖습니다.
- **Manhattan의 거리.** Manhattan의 거리 척도는 좌표 간의 절대 차이의 합으로 계산되는 두 데이터 점 사이의 거리입니다.
- **Canberra의 거리.** Canberra의 거리 척도는 Manhattan의 거리 척도와 유사하나 원점에서 더 가까운 데이터 점에 대해 더 예민합니다.
- **최대값.** 최대값 척도는 좌표 차원을 따라 가장 큰 차이로 계산되는 두 데이터 점 사이의 거리입니다.

**군집 수.** 이 매개변수는 작성할 군집 수를 정의합니다.

**반복 최대 수.** 알고리즘이 동일한 프로세스를 여러 번 반복합니다. 이 매개변수는 모델 학습이 중지하는 반복 수를 정의합니다.

**통계량.** 이 매개변수는 모델에 포함되는 통계 수를 정의합니다. 다음 옵션 중 하나를 선택하십시오.

- **모두.** 모든 열 관련 통계량 및 모든 값 관련 통계량이 포함됩니다.

 **참고:** 이 매개변수는 통계 최대 수를 포함하므로 시스템 성능에 영향을 줄 수도 있습니다. 모델을 그래픽 형식으로 보지 않으려면 **없음**을 지정하십시오.

- **열.** 열 관련 통계가 포함됩니다.

- **없음.** 모델을 스코어링하는 데 필요한 통계량만 포함됩니다.

**결과 복제.** 분석을 복제하기 위한 난수 시드를 설정하려면 이 선택란을 선택하십시오. 정수를 지정하거나 **생성**을 클릭하여 의사 난수 정수를 작성할 수 있습니다.

## (12) IBM Data WH Naive Bayes

Naive Bayes는 분류 문제점을 위한 잘 알려진 알고리즘입니다. 모델은 제안된 모든 예측 변수를 서로 독립된 것으로 처리하기 때문에 *naive*라고 합니다. Naive Bayes는 속성과 목표 속성의 조합에 대한 조건부 확률을 계산하는 빠르고 확장 가능한 알고리즘입니다. 훈련 데이터에서 독립된 확률이 설정됩니다. 각 입력 변수에서 각 값 범주가 주어지는 경우, 이 확률은 각 대상 클래스의 우도를 제공합니다.

## (13) Netezza Bayes Net

베이지안 네트워크는 데이터 세트의 변수와 이 변수 사이의 확률적 또는 조건부 독립성을 표시하는 모델입니다. Netezza Bayes Net 노드를 사용하면 관측 및 기록한 증거를 상식적인 실세계 지식과 결합해서 겉보기에 링크되지 않은 속성을 사용하여 발생 우도를 설정함으로써 확률 모델을 작성할 수 있습니다.

### ① Netezza Bayes 넷 필드 옵션

필드 탭에서는 업스트림 노드에 이미 정의된 필드 역할 설정을 사용하거나 수동으로 필드 할당을 할 수 있습니다.

이 노드의 경우, 스코어링에만 목표 필드가 필요하므로 이 탭에 표시되지 않습니다. 유형 노드,

이 노드의 모델 옵션 탭 또는 모델 너깃의 설정 탭에서 목표를 설정 또는 변경할 수 있습니다. 자세한 정보는 Netezza Bayes 넷 너깃 - 설정 탭 주제를 참조하십시오.

**사전 정의된 역할 사용.** 이 옵션은 업스트림 유형 노드(또는 업스트림 소스 노드의 유형 탭)의 역할 설정(목표 및 예측자 등)을 사용합니다.

**사용자 정의 필드 할당 사용.** 이 화면에서 수동으로 목표, 예측자 및 기타 역할을 지정하려면 이 옵션을 선택하십시오.

**필드.** 화살표 단추를 사용하여 수동으로 이 목록의 항목을 화면 오른쪽의 다양한 역할 필드에 할당하십시오. 아이콘은 각 역할 필드에 대한 유효한 측정 수준을 나타냅니다.

**모두 단추를 클릭하여 목록의 모든 필드를 선택하거나 개별 측정 수준 단추를 클릭하여 해당 측정 수준의 모든 필드를 선택합니다.**

**예측변수(입력).** 예측에 대한 입력으로 하나 이상의 필드를 선택합니다.

## ② Netezza Bayes 넷 작성 옵션

작성 옵션 탭은 모델을 작성하기 위한 모든 옵션을 설정하는 위치입니다. 물론, **실행** 단추를 클릭하여 모든 기본 옵션으로 모델을 작성할 수도 있지만, 보통 사용자는 고유한 목적을 위해 작성을 사용자 정의하려고 합니다.

**기준 지수.** 내부 관리를 더 쉽게 수행할 수 있도록 처음 속성(입력 필드)에 지정되는 숫자 식별자입니다.

**표본 크기.** 속성의 수가 너무 많아서 처리 시간이 너무 길어서 수용할 수 없는 경우에 사용하는 표본 크기입니다.

**실행 도중 추가 정보 표시.** 이 선택란을 선택하면(기본값), 메시지 대화 상자에 추가 진행률 정보가 표시됩니다.

## (14) Netezza 시계열

**시계열**은 시간의 연속적이나 반드시 정기적이지는 않은 지점에서 측정되는 수치 데이터 값의 시퀀스입니다. 예를 들어, 매일 주가 또는 매주 판매 데이터 등이 있습니다. 추세 및 계절성(반복 패턴) 등의 동작을 강조하고 과거 이벤트로부터 미래 동작을 예측할 때 이러한 데이터 분석이 유용할 수 있습니다.

Netezza 시계열은 다음과 같은 시계열 알고리즘을 지원합니다.

- 스펙트럼 분석
- 지수평활
- 자기회귀 통합 이동 평균(ARIMA)
- 계절 추세 분해

이러한 알고리즘은 시계열을 추세 및 계절 성분으로 분해합니다. 그러면 예측에 사용할 수 있는 모델을 작성하기 위해 해당 성분을 분석할 수 있습니다.

**스펙트럼 분석**은 시계열에서 주기적 동작을 식별하는 데 사용됩니다. 다중 기본 주기성으로 구성된 시계열인 경우 또는 데이터에 상당한 양의 변량 잡음이 있는 경우, 스펙트럼 분석이 주기적 성분을 식별하는 가장 근접한 평균을 제공합니다. 이 방법은 계절을 시간 도메인에서 빈도 도메인 계열로 변환하여 주기적 동작의 빈도를 발견합니다.

**지수평활**은 향후 값을 예측하기 위해 이전 계열 관측의 가중된 값을 사용하는 시계열 분석 방법입니다. 지수평활과 함께 사용하면 지수 방법에서 지수평활의 영향력이 시간 경과에 따라 감소합니다. 이 방법은 덧셈, 추세 및 계절성을 고려하여 새 데이터가 들어오면 해당 예측을 조정하여 한 번에 하나의 포인트를 예측합니다.

**ARIMA** 모델은 지수평활 모델을 수행하는 모델링 추세 및 계절 성분에 대해 보다 정교한 방법을 제공합니다. 이 방법에는 차이 정도와 함께 자기회귀 및 이동 평균 순서를 명시적으로 지정하는 작업이 포함됩니다.

**참고:** 실제로 메일로 보내는 카탈로그 수 또는 회사 웹 페이지의 적중 수와 같은 예측할 계열의 동작을 설명하는 데 도움이 될 수 있는 예측자를 포함하려는 경우에 ARIMA 모델이 가장 유용합니다. 지수평활 모델에서는 왜 원래대로 작동하는지 이유를 설명하지 않고도 시계열 동작을 설명합니다.

**계절 추세 분해**는 추세 분석을 수행한 다음 추세에 대한 기본 모양(2차 함수 등)을 수행하기 위해 시계열에서 정기적 동작을 제거합니다. 이러한 기본 모양에서는 잔차의 평균 제곱 오차(시계열의 맞춤값 및 관측값 사이의 차이)를 최소화하기 위한 모수의 수가 결정됩니다.

### ① Netezza 시계열에서 값의 보간법

**보간법**이란 시계열 데이터에서 결측값을 추정하고 삽입하는 프로세스입니다.

시계열의 구간이 규칙적이거나 단순히 일부 값이 존재하지 않으면 선형 보간법을 사용하여 결측값을 추정할 수 있습니다. 매일 공항 터미널에 도착하는 승객의 계열을 생각해 보십시오.

표 1. 승객 터미널의 월별 도착

월	승객
3	3,500,000
4	3,900,000
5	-
6	3,400,000
7	4,500,000
8	3,900,000
9	5,800,000
10	6,000,000

이 경우, 선형 보간법은 5월에 대한 결측값을 3,650,000(4월 및 6월 사이의 중심점)으로 추정합니다.

불규칙한 구간은 다르게 처리됩니다. 다음 온도 읽기 계열을 생각해 보십시오.

표 2. 온도 읽기

날짜	시간	온도
2011-07-24	7:00	57
2011-07-24	14:00	75
2011-07-24	21:00	72
2011-07-25	7:15	59
2011-07-25	14:00	77
2011-07-25	20:55	74
2011-07-27	7:00	60
2011-07-27	14:00	78
2011-07-27	22:00	74

사흘 동안 세 시점에서 온도를 읽었으나 시간이 다르며 그 중 일부만 공통됩니다. 또한 이틀만 연속적입니다.

이 상황은 두 가지 방법(통합 계산 또는 단계 크기 결정) 중 하나로 처리할 수 있습니다.

통합은 데이터에 대한 시맨틱 이해를 기반으로 하여 수식에 따라 계산되는 일일 통합입니다. 그러면 다음과 같은 데이터 세트가 작성될 수 있습니다.

표 3. 온도 읽기(통합)

날짜	시간	온도
2011-07-24	24:00	69
2011-07-25	24:00	71
2011-07-26	24:00	null
2011-07-27	24:00	72

또는 알고리즘이 계열을 구분 계열로 처리하고 적합한 단계 크기를 판별할 수 있습니다. 이 경우, 알고리즘에 의해 결정되는 단계 크기가 8시간이 되어 다음과 같은 결과가 발생할 수 있습니다.

표 4. 계산된 단계 크기로 온도 읽기

날짜	시간	온도
2011-07-24	6:00	
2011-07-24	14:00	75
2011-07-24	22:00	
2011-07-25	6:00	
2011-07-25	14:00	77
2011-07-25	22:00	
2011-07-26	6:00	
2011-07-26	14:00	
2011-07-26	22:00	
2011-07-27	6:00	
2011-07-27	14:00	78
2011-07-27	22:00	74

여기서는 원래 측정에 대해 네 개의 읽기만 해당되나 원래 계열의 다른 알려진 값의 도움을 받아 결측값이 보간법에 의해 다시 계산될 수 있습니다.

## ② Netezza 시계열 필드 옵션

필드 탭에서 소스 데이터의 입력 필드에 대한 역할을 지정하십시오.

**필드.** 화살표 단추를 사용하여 수동으로 이 목록의 항목을 화면 오른쪽의 다양한 역할 필드에 할당하십시오. 아이콘은 각 역할 필드에 대한 유효한 측정 수준을 나타냅니다.

**목표.** 하나의 필드를 예측 목표로 선택하십시오. 이 필드의 측정 수준이 연속형이어야 합니다.

**(예측자) 시점.** (필수) 시계열의 날짜 또는 시간 값을 포함하는 입력 필드입니다. 필드의 측정 수준이 연속형 또는 범주형이어야 하며 데이터 저장 공간 유형이 날짜, 시간, 시간소인 또는 숫자여야 합니다. 여기서 지정하는 필드의 데이터 저장 공간 유형은 이 모델링 노드의 기타 탭의 일부 필드에 대한 입력 유형도 정의합니다.

**(예측자) 시계열 ID(By).** 시계열 ID를 포함하는 필드로서, 입력이 둘 이상의 시계열을 포함하는 경우에 사용하십시오.

## ③ Netezza 시계열 작성 옵션

두 가지 수준의 작성 옵션이 있습니다.

- 기본 - 알고리즘 선택, 보간법 및 사용할 시간 범위에 대한 설정입니다.
- 고급 - 시계열 분석에 대한 설정입니다.

이 절에서는 기본 옵션에 대해 설명합니다.

작성 옵션 탭은 모델을 작성하기 위한 모든 옵션을 설정하는 위치입니다. 물론, **실행** 단추를 클릭하여 모든 기본 옵션으로 모델을 작성할 수도 있지만, 보통 사용자는 고유한 목적을 위해 작성을 사용자 정의하려고 합니다.

### 알고리즘

사용할 시계열 알고리즘과 관련된 설정입니다.

**알고리즘 이름.** 사용할 시계열 알고리즘을 선택하십시오. 사용 가능한 알고리즘은 **스펙트럼 분석**, **지수평활(기본값)**, **ARIMA** 또는 **계절 추세 분해**입니다. 자세한 정보는 Netezza 시계열 주제를 참조하십시오.

**추세.** (지수평활 전용) 시계열이 추세를 나타내면 단순 지수평활이 잘 수행되지 않습니다. 지수가 있으면 알고리즘이 지수를 고려할 수 있도록 이 필드를 사용하여 지수를 지정하십시오.

- **결정된 시스템**. (기본값) 시스템이 이 모수에 대한 최적 값을 찾으려고 시도합니다.
- **없음(N)**. 시계열이 추세를 나타내지 않습니다.
- **가법(A)**. 시간 경과에 따라 서서히 증가하는 추세입니다.
- **진폭감소 가법(DA)**. 결국 사라지는 가법 추세입니다.
- **승법(M)**. 시간 경과에 따라 증가하는 추세이며 일반적으로 점진적인 가법 추세보다 더 빠릅니다.
- **진폭감소 승법(DM)**. 결국 사라지는 승법 추세입니다.

**계절성**. (지수평활 전용) 시계열이 데이터에서 계절 패턴을 나타내는지 여부를 지정하려면 이 필드를 사용하십시오.

- **결정된 시스템**. (기본값) 시스템이 이 모수에 대한 최적 값을 찾으려고 시도합니다.
- **없음(N)**. 시계열이 계절 패턴을 나타내지 않습니다.
- **가법(A)**. 계절 변동 패턴이 시간 경과에 따라 점진적 상승 추세를 나타냅니다.
- **승법(M)**. 가법 계절성과 동일하나 추가적으로 계절 변동의 진폭(높은 점 및 낮은 점 사이의 거리)이 변동의 전체 상승 추세에 비해 증가합니다.

**ARIMA에 대해 시스템 결정 설정 사용**. (ARIMA 전용) 시스템이 ARIMA 알고리즘에 대한 설정을 결정하도록 하려면 이 옵션을 선택하십시오.

**지정**. (ARIMA 전용) ARIMA 설정을 수동으로 지정하려면 이 옵션을 선택하고 단추를 클릭하십시오.

#### 보간법

시계열 소스 데이터에 결측값이 있으면 값 추정을 삽입하는 방법을 선택하여 데이터 사이의 갭을 채우십시오. 자세한 정보는 Netezza 시계열에서 값의 보간법 주제를 참조하십시오.

- **선형**. 시계열의 구간이 규칙적이거나 단순히 일부 값이 존재하지 않으면 이 방법을 선택하십시오.
- **지수 스플라인**. 알려진 데이터 점 값이 높은 비율로 증가하거나 감소하는 평활 곡선을 맞춥니다.
- **삼차 스플라인**. 결측값을 추정하기 위해 알려진 데이터 점으로 평활 곡선을 맞춥니다.

#### 시간 범위

시계열에서 전체 범위의 데이터를 사용할 것인지 또는 근접 데이터 서브세트를 사용하여 모델을 작성할 것인지 선택할 수 있습니다. 이러한 필드에 대한 유효한 입력은 필드 탭의 시점에 대해 지정된 필드의 데이터 저장 공간 유형에 의해 정의됩니다. 자세한 정보는 Netezza 시계열 필드 옵션의 내용을 참조하십시오.

- **데이터에서 사용가능한 가장 이른 시간 및 가장 최근의 시간 사용**. 전체 범위의 시계열 데이터를 사용하려면 이 옵션을 선택하십시오.
- **시간 창 지정**. 시계열의 일부만을 사용하려면 이 옵션을 선택하십시오. 경계를 지정하려면 가장 이른 시간(시작) 및 최근의 시간(종료) 필드를 사용하십시오.

## 가. ARIMA 구조

ARIMA 모델에서 다양한 비계절 및 계절 성분의 값을 지정하십시오. 각 케이스에서 연산자를 =(같은) 또는 <=(이하)로 설정한 다음 인접 필드에서 값을 지정하십시오. 값은 차수를 지정하는 음이 아닌 정수여야 합니다.

**비계절.** 모델의 다양한 비계절 성분의 값입니다.

- **자기상관 차수(p).** 모델의 자기회귀 차수 수입니다. 자기회귀 차수는 계열의 이전 값 중 현재 값 예측에 사용될 값을 지정합니다. 예를 들어, 자기회귀 차수 2는 과거 2개 시간 주기의 계열 값을 현재 값 예측에 사용하도록 지정합니다.
- **파생(d).** 모델을 추정하기 전 계열에 적용할 차이 차수를 지정합니다. 추세가 존재하며(추세가 있는 계열은 일반적으로 비정상이며 ARIMA 모델링은 정상성을 가정) 해당 효과 제거를 위해 사용되는 경우 차이가 필요합니다. 차이 차수는 계열 추세 수준에 해당합니다. 1차 차이는 선형 추세, 2차 차이는 2차 추세 등을 나타냅니다.
- **이동 평균(q).** 모델의 이동 평균 차수 수입니다. 이동 평균 차수는 이전 값에 대한 계열 평균 편차를 사용하여 현재 값을 예측하는 방법을 지정합니다. 예를 들어, 이동 평균 차수 1과 2는 계열의 현재 값을 예측하는 경우 지난 2개 시간 주기 각각의 계열 평균값 편차를 고려하도록 지정합니다.

**계절.** 계절적 자기상관(SP), 파생(SD) 및 이동 평균(SQ) 성분이 비계절 상대로 동일한 역할을 수행합니다. 그러나 계절 차수의 경우 현재 계열 값이 한 개 이상의 계절 주기에 의해 구분된 이전 계열 값의 영향을 받습니다. 예를 들어, 월별 데이터(계절 주기 12)의 경우 계절 차수 1은 현재 계열 값이 현재 계열 이전의 계열 값 12 주기의 영향을 받는다는 것을 의미합니다. 월별 데이터의 경우 계절 차수 1은 비계절 차수 12를 지정하는 것과 동일합니다.

계절 설정은 데이터에서 계절성이 발견된 경우 또는 고급 탭에서 주기 설정을 지정한 경우에만 고려됩니다.

## 나. Netezza 시계열 작성 옵션 - 고급

고급 설정을 사용하여 시계열 분석에 대한 옵션을 지정할 수 있습니다.

**모델 작성 옵션에 대해 시스템 결정 설정 사용.** 시스템이 고급 설정을 결정하도록 하려면 이 옵션을 선택하십시오.

**지정.** 고급 옵션을 수동으로 지정하려면 이 옵션을 선택하십시오. 알고리즘이 스펙트럼 분석이면 이 옵션을 사용할 수 없습니다.

- **추가/주기 단위.** 시계열의 몇 가지 공정특성 변수 작동이 반복된 후의 주기입니다. 예를 들어, 주말 세일 시계열에 대해 주기로 1을 지정하고 단위로 주를 지정할 수 있습니다. 주기는 음수

가 아닌 정수여야 하며 주기 단위는 밀리초, 초, 분, 시, 일, 주, 분기 또는 년 중 하나여야 합니다. 주기가 설정되지 않았거나 시간 유형이 숫자가 아니면 주기 단위를 설정하지 마십시오. 단, 주기를 지정한 경우에는 반드시 주기 단위를 지정해야 합니다.

**시계열 분석 설정.** 특정 시점까지 또는 특정 시점에 예측값을 작성하도록 선택할 수 있습니다. 이러한 필드에 대한 유효한 입력은 필드 탭의 시점에 대해 지정된 필드의 데이터 저장 공간 유형에 의해 정의됩니다. 자세한 정보는 Netezza 시계열 필드 옵션의 내용을 참조하십시오.

- **예측 범위.** 시계열 분석의 끝점만 지정하려면 이 옵션을 선택하십시오. 이 시점까지의 예측값이 작성됩니다.
- **예측 시간.** 예측값을 작성할 시점을 하나 이상 지정하려면 이 옵션을 선택하십시오. 시점 테이블에 새 행을 추가하려면 **추가**를 클릭하십시오. 행을 삭제하려면 행을 선택하고 **삭제**를 클릭하십시오.

#### ④ Netezza 시계열 모델 옵션

모델 옵션 탭에서는 모델 이름을 지정할 것인지, 이름을 자동으로 생성할 것인지 선택할 수 있습니다. 모델 출력 옵션에 대한 기본값을 설정할 수 있습니다.

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**스코어링에 사용 가능.** 모델 너깃에 대한 대화 상자에 표시될 스코어링 옵션에 대한 기본값을 여기서 설정할 수 있습니다.

- **결과에 히스토리 값 포함** 기본적으로 모델 출력은 히스토리 데이터 값(예측 작성에 사용된 값)을 포함하지 않습니다. 해당 값을 포함하려면 이 선택란을 선택하십시오.
- **결과에 보간값 포함.** 결과에 히스토리 값을 포함하도록 선택한 경우, 보간값이 있으면 보간값도 포함하려면 이 선택란을 선택하십시오. 보간법은 히스토리 데이터에 대해서만 적용되므로 **결과에 히스토리 값 포함**을 선택하지 않은 경우에는 이 선택란을 사용할 수 없습니다. 자세한 정보는 Netezza 시계열에서 값의 보간법 주제를 참조하십시오.

### (15) IBM Data WH TwoStep

TwoStep 노드는 큰 데이터 세트의 데이터를 군집화하는 방법을 제공하는 TwoStep 알고리즘을 구현합니다.

이 노드를 사용하면 사용 가능한 자원(예: 메모리 및 시간 제한조건)을 고려하면서 데이터를 군집화할 수 있습니다.

TwoStep 알고리즘은 다음과 같은 방법으로 데이터를 군집화하는 데이터베이스 마이닝 알고리즘입니다.

1. 군집화 기능(CF) 트리가 작성됩니다. 균형도가 높은 이 트리는 유사한 입력 레코드가 동일한 트리 노드의 일부가 되는 계층별 군집화를 위한 군집화 기능을 저장합니다.
2. CF 트리의 리프는 인메모리로 계층적으로 군집화되어 최종 군집 결과를 생성합니다. 최상의 군집 수는 자동으로 결정됩니다. 최대 군집 수를 지정하면 지정된 한계 내에서 최상의 군집 수가 결정됩니다.
3. 군집 결과는 K-평균 알고리즘과 유사한 알고리즘이 데이터에 적용되는 두 번째 단계에서 세분화됩니다.

### ① IBM Data WH TwoStep 필드 옵션

필드 옵션을 설정하여 업스트림 노드에 정의된 필드 역할 설정을 사용하도록 지정할 수 있습니다. 수동으로 필드 할당을 수행할 수도 있습니다.

**항목 선택.** 업스트림 소스 노드의 유형 탭 또는 업스트림 유형 노드의 역할 설정을 사용하려면 이 옵션을 선택하십시오. 역할 설정은, 예를 들면, 목표 및 예측변수입니다.

**사용자 정의 필드 할당 사용.** 수동으로 목표, 예측변수 및 기타 역할을 할당하려면 이 옵션을 선택하십시오.

**필드.** 화살표를 사용하여 수동으로 이 목록의 항목을 화면의 오른쪽에 있는 역할 필드에 지정하십시오. 아이콘은 각 역할 필드에 대한 유효한 측정 수준을 나타냅니다.

**레코드 ID.** 고유 레코드 식별자로 사용할 필드입니다.

**예측변수(입력).** 예측에 대한 입력으로 하나 이상의 필드를 선택합니다.

### ② IBM Data WH TwoStep 작성 옵션

작성 옵션을 설정하여 고유의 목적에 맞게 모델 작성을 사용자 정의할 수 있습니다.

기본 옵션을 사용하여 모델을 작성하려면 **실행**을 클릭하십시오.

**거리 척도.** 이 매개변수는 데이터 점 사이의 거리를 측정하는 방법을 정의합니다. 거리가 멀수록 유사성이 떨어집니다. 옵션은 다음과 같습니다.

- **로그-우도.** 우도 척도는 변수에 확률 분포를 둡니다. 연속형 변수는 정규 분포로, 범주형 변수는 다항분포로 가정됩니다. 모든 변수를 독립변수로 가정합니다.

- **유클리디안.** 유클리디안 측도는 두 데이터 점 사이의 직선 거리입니다.
- **정규화 유클리디안.** 정규화 유클리디안 측도는 유클리디안 측도와 유사하지만 제곱 표준 편차에 의해 정규화됩니다. 유클리디안 측도와 달리, 정규화 유클리디안 측도는 척도 불변성(scale-invariant)을 가집니다.

**군집 수.** 이 매개변수는 작성할 군집 수를 정의합니다. 옵션은 다음과 같습니다.

- **자동으로 군집 수 계산.** 군집 수가 자동으로 계산됩니다. **최대값** 필드에 군집 최대 수를 지정할 수 있습니다.
- **군집 수 지정.** 작성할 군집 수를 지정하십시오.

**통계량.** 이 매개변수는 모델에 포함되는 통계 수를 정의합니다. 옵션은 다음과 같습니다.

- **모두.** 모든 열 관련 통계량 및 모든 값 관련 통계량이 포함됩니다.

**참고:** 이 매개변수는 통계 최대 수를 포함하므로 시스템 성능에 영향을 줄 수도 있습니다. 모델을 그래픽 형식으로 보지 않으려면 **없음**을 지정하십시오.

- **열.** 열 관련 통계가 포함됩니다.
- **없음.** 모델을 스코어링하는 데 필요한 통계량만 포함됩니다.

**결과 복제.** 분석을 복제하기 위한 난수 시드를 설정하려면 이 선택란을 선택하십시오. 정수를 지정하거나 **생성**을 클릭하여 의사 난수 정수를 작성할 수 있습니다.

## (16) IBM Data WH PCA

비선형 주성분분석(PRINCALS)(PCA)는 데이터의 복잡도를 줄이기 위해 디자인된 강력한 데이터 축소 기법입니다. PCA는 전체 필드 세트에서 최상의 분산 캡처 작업을 수행하는 입력 필드의 선형 조합을 찾습니다. 이 때 성분은 서로 직교하며 상관분석되지 않습니다. 목표는 원래 입력 필드 세트의 정보를 효과적으로 요약하는 소수의 파생된 필드(주성분)를 찾는 것입니다.

**참고:** 소문자 필드 이름을 사용할 경우 모델을 스코어링할 때 오류가 발생할 수 있습니다. 이것은 알려진 Db2 Data Warehouse 결함으로, 임시 해결책은 스코어링하기 전에 모든 필드의 이름을 대문자로 변경하는 것입니다.

### ① IBM Data WH PCA 필드 옵션

필드 탭에서는 업스트림 노드에 이미 정의된 필드 역할 설정을 사용하거나 수동으로 필드 할당을 할 수 있습니다.

**사전 정의된 역할 사용:** 이 옵션은 업스트림 유형 노드(또는 업스트림 소스 노드의 유형 탭)의 역할 설정(목표 및 예측자 등)을 사용합니다.

**사용자 정의 필드 할당 사용:** 이 화면에서 수동으로 목표, 예측자 및 기타 역할을 지정하려면 이 옵션을 선택하십시오.

**필드.** 화살표 단추를 사용하여 수동으로 이 목록의 항목을 화면 오른쪽의 다양한 역할 필드에 할당하십시오. 아이콘은 각 역할 필드에 대한 유효한 측정 수준을 나타냅니다.

**모두** 단추를 클릭하여 목록의 모든 필드를 선택하거나 개별 측정 수준 단추를 클릭하여 해당 측정 수준의 모든 필드를 선택합니다.

**레코드 ID.** 고유 레코드 식별자로 사용할 필드입니다.

**예측자(입력).** 예측에 대한 입력으로 하나 이상의 필드를 선택합니다.

## ② IBM Data WH PCA 작성 옵션

작성 옵션 탭은 모델을 작성하기 위한 모든 옵션을 설정하는 위치입니다. 물론, **실행** 단추를 클릭하여 모든 기본 옵션으로 모델을 작성할 수도 있지만, 보통 사용자는 고유한 목적을 위해 작성을 사용자 정의하려고 합니다.

**PCA를 계산하기 전에 데이터 가운데 맞춤.** 이 옵션을 선택하면(기본값), 분석 전에 데이터 가운데 맞춤("평균 뺀셈"이라고도 함)을 수행합니다. 데이터 가운데 맞춤은 처음 주성분이 최대 분산의 방향을 설명하도록 하기 위해 꼭 필요합니다. 그렇지 않으면 성분이 데이터의 평균에 더 가까이 대응할 수 있습니다. 데이터가 이미 이 방법으로 준비된 경우에만 일반적으로 성능 향상을 위해 이 옵션을 선택 취소합니다.

**PCA를 계산하기 전에 데이터 배율 조정.** 이 옵션은 분석 전에 데이터 배율 조정을 수행합니다. 그렇게 하면 다른 변수가 다른 장치에서 측정될 때 분석을 덜 임의적으로 만들 수 있습니다. 가장 단순한 양식의 데이터 배율 조정은 각 변수를 표준 편차로 나누는 것입니다.

**PCA를 계산하기 위해 덜 정확하지만 더 빠른 방법 사용.** 이 옵션을 사용하면 알고리즘이 덜 정확하나 더 빠른 방법(forceEigensolve)을 사용하여 주성분을 찾습니다.

## (17) IBM Data WH 및 Netezza 모델 관리

IBM Data Warehouse 및 IBM® Netezza® Analytics 모델은 다른 IBM SPSS® Modeler 모델과 동일한 방식으로 캔버스 및 모델 팔레트에 추가되며 거의 동일한 방식으로 사용할 수 있습니다. 하지만 IBM SPSS Modeler에서 작성된 IBM Data Warehouse 또는 IBM Netezza Analytics 모델이 각각 실제로 데이터베이스 서버에 저장된 모델을 참조하는 경우에는 몇 가지 중요한 차이가 있습니다. 따라서 스트림이 올바르게 작동하려면 모델이 작성된 데이터베이스에 연결해야 하며 외부 프로세스에 의해 모델 테이블이 변경되지 않아야 합니다.

## ① IBM Data Warehouse 및 IBM® Netezza® Analytics 모델 스코어링

모델은 금색 모델 너깃 아이콘에 의해 캔버스에 표시됩니다. 너깃의 주 용도는 데이터를 스코어링하여 예측을 생성하거나 모델 특성의 추가 분석을 허용하는 것입니다. 나중에 이 절에서 설명되는 대로 테이블 노드를 너깃에 연결하고 스트림의 해당 분기를 실행하여 표시될 수 있는 하나 이상의 추가 데이터 필드 형식으로 스코어가 추가됩니다. 의사결정 트리 또는 회귀분석 트리에 대한 대화 상자 등의 일부 너깃 대화 상자에는 모델의 시각적 표시를 제공하는 모델 탭이 추가로 제공됩니다.

추가 필드는 대상 필드의 이름에 추가된  $\langle id \rangle$ - 접두부에 의해 구별됩니다. 여기서  $\langle id \rangle$ 는 모델에 따라 다르며 추가 중인 정보의 유형을 식별합니다. 각각의 모델 너깃에 대한 주제에 다양한 식별자가 설명되어 있습니다.

스코어를 보려면 다음의 단계를 완료하십시오.

1. 테이블 노드를 모델 너깃에 연결하십시오.
2. 테이블 노드를 여십시오.
3. 실행을 클릭하십시오.
4. 테이블 출력 창의 오른쪽으로 스크롤하여 추가 필드 및 해당 스코어를 보십시오.

## ② IBM Data WH 및 Netezza 모델 너깃 서버 탭

서버 탭에서는 모델 스코어링을 위한 서버 옵션을 설정할 수 있습니다. 업스트림으로 지정된 서버 연결을 계속 사용하거나 여기서 지정하는 다른 데이터베이스로 데이터를 이동할 수 있습니다.

**IBM Data Warehouse 서버 세부사항.** 여기서는 모델에 사용할 데이터베이스에 대한 연결 세부사항을 지정합니다.

- **업스트림 연결 사용.** (기본값) 업스트림 노드(예: 데이터베이스 소스 노드)에 지정된 연결 세부사항을 사용합니다. 이 옵션은 모든 업스트림 노드가 SQL 푸시백을 사용할 수 있는 경우에만 작동합니다. 이 경우에는 SQL이 모든 업스트림 노드를 완전하게 구현하므로 데이터를 데이터베이스 밖으로 이동하지 않아도 됩니다.
- **데이터를 연결로 이동.** 여기에서 지정하는 데이터베이스로 데이터를 이동합니다. 이를 수행하면 데이터가 다른 IBM Data Warehouse 데이터베이스 또는 다른 벤더의 데이터베이스에 있거나 데이터가 플랫폼 파일인 경우에도 모델링이 작동할 수 있습니다. 또한, 노드가 SQL 푸시백을 수행하지 않아 데이터가 추출된 경우에는 여기에 지정된 데이터베이스로 데이터가 다시 이동합니다. 편집 단추를 클릭하여 연결을 찾아서 선택할 수 있습니다.

### ⊘ 경고:

IBM® Netezza® Analytics 및 IBM Data Warehouse는 일반적으로 매우 큰 데이터 세트와 함께 사용됩니다. 데이터베이스 사이에서 또는 데이터베이스 안팎으로 많은 양의 데이터를 전송하면 시간이 많이 걸릴 수 있으므로 가능하면 피해야 합니다.

**모델 이름.** 모델의 이름입니다. 이 이름은 정보용으로만 표시되며 여기서 변경할 수 없습니다.

### ③ IBM Data WH 의사결정 트리 모델 너깃

의사결정 트리 모형 너깃은 모델링 작업의 출력을 표시하며 사용자가 모델 스코어링에 대한 일부 옵션을 설정할 수 있도록 해줍니다.

의사결정 트리 모형 너깃을 포함한 스트림을 실행하면 노드는 목표 이름에서 이름이 파생된 한 개의 새 필드를 추가합니다.

표 1. 의사결정 트리의 모델 스코어링 필드

추가되는 필드의 이름	의미
<code>!-target_name</code>	현재 레코드의 예측값입니다.

모델링 노드 또는 모델 너깃에서 **스코어 레코드에 할당된 클래스의 확률 계산** 옵션을 선택하고 스트림을 실행한 경우 추가적 필드가 추가됩니다.

표 2. 의사결정 트리에 대한 모델 스코어링 필드 - 추가적

추가되는 필드의 이름	의미
<code>!P-target_name</code>	예측 신뢰도(0.0 - 1.0)입니다.

#### 가. IBM Data WH 의사결정 트리 너깃 - 모델 탭

**모델 탭**은 의사결정 트리 모형의 예측변수 중요도를 그래픽 형식으로 표시합니다. 막대의 길이는 예측변수의 중요도를 나타냅니다.

**참고:** IBM® Netezza® Analytics 2.x 이전 버전으로 작업 중인 경우에는 의사결정 트리 모형의 내용이 텍스트 형식으로만 표시됩니다. 이러한 버전에 대해서는 다음 정보가 표시됩니다.

- 노드 또는 리프에 해당하는 텍스트의 각 줄
- 트리 수준을 반영하는 들여쓰기
- 노드의 경우, 분할 조건이 표시됩니다.
- 리프의 경우, 지정된 클래스 레이블이 표시됩니다.

#### 나. IBM Data WH 의사결정 트리 너짓 - 설정 탭

설정 탭에서 모델 스코어링에 필요한 옵션을 설정할 수 있습니다.

**입력 필드 포함.** 선택된 경우 이 옵션은 모든 원래 입력 필드 다운스트림을 전달하여 추가 모델링 필드를 각 데이터 행에 추가합니다. 이 선택란을 선택 취소하면 레코드 ID 필드 및 추가 모델링 필드만 전달되므로 스트림이 더 신속하게 실행됩니다.

**스코어링 레코드에 대해 지정된 클래스의 확률 계산.** (의사결정 트리 및 Naive Bayes 전용) 선택된 경우 이 옵션은 추가 모델링 필드에 신뢰도(즉, 확률) 필드 및 예측 필드가 포함됨을 의미합니다. 이 선택란을 선택 취소하면 예측 필드만 생성됩니다.

**결정적 입력 데이터 사용.** 이 옵션을 선택하면 동일한 보기의 다중 패스를 실행하는 Netezza 알고리즘이 각 패스에 대해 동일한 데이터 세트를 사용합니다. 비결정적 데이터가 사용되고 있음을 표시하기 위해 이 선택란을 지우면 파티션 노드에 의해 생성되는 것과 같이 처리에 필요한 데이터 출력을 보유하기 위해 임시 테이블이 작성되고 모델이 작성된 후에 이 테이블이 삭제됩니다.

#### 다. IBM Data WH 의사결정 트리 너짓 - 뷰어 탭

뷰어 탭은 SPSS® Modeler가 해당 의사결정 트리 모형의 트리 프리젠테이션을 표시하는 것과 동일한 방식으로 트리 모형의 트리 프리젠테이션을 표시합니다.

**참고:** IBM® Netezza® Analytics 2.x 이전 버전으로 모델이 작성된 경우 뷰어 탭이 비어 있습니다.

#### ④ IBM Data WH K-평균 모델 너짓

K-평균 모델 너짓은 학습 데이터 및 추정 프로세스에 대한 정보와 함께, 군집 모델에서 캡처한 모든 정보를 포함합니다.

K-평균 모델 너짓을 포함하는 스트림을 실행하는 경우 노드는 해당 레코드의 지정된 군집 중심과의 거리 및 소속군집을 포함하는 새 2개 필드를 추가합니다. 이름이 \$KM-K-Means인 새 필드는 소속군집용이며 이름이 \$KMD-K-Means인 새 필드는 군집 중심으로부터의 거리용입니다.

#### 가. IBM Data WH K-평균 너짓 - 모델 탭

모델 탭에는 군집 필드에 대한 분포 및 요약 통계를 표시하는 다양한 그래픽 보기가 있습니다. 모델에서 데이터를 내보내거나 보기를 그래픽으로 내보낼 수 있습니다.

IBM® Netezza® Analytics 2.x 이전 버전으로 작업 중이거나 거리 측도가 Mahalanobis의 거리인 모델을 작성하는 경우에는 의사결정 트리 모형의 내용이 텍스트 형식으로만 표시됩니다.

이러한 버전에 대해서는 다음 정보가 표시됩니다.

- **요약 통계량.** 가장 작은 군집 및 가장 큰 군집에 대해 요약 통계량이 레코드 수를 표시합니다. 또한 요약 통계량은 이러한 군집에 의해 사용된 데이터 세트의 퍼센트를 표시합니다. 또한 목록은 가장 큰 군집 대 가장 작은 군집의 크기 비율을 표시합니다.
- **군집 요약.** 군집 요약은 알고리즘에 의해 작성된 군집을 나열합니다. 테이블에는 각 군집에 대한 해당 군집 내의 레코드 수가 표시되며 해당 레코드에 대한 군집 중심으로부터의 평균 거리가 함께 표시됩니다.

#### 나. IBM Data WH K-평균 너깃 - 설정 탭

설정 탭에서 모델 스코어링에 필요한 옵션을 설정할 수 있습니다.

**입력 필드 포함.** 선택된 경우 이 옵션은 모든 원래 입력 필드 다운스트림을 전달하여 추가 모델링 필드를 각 데이터 행에 추가합니다. 이 선택란을 선택 취소하면 레코드 ID 필드 및 추가 모델링 필드만 전달되므로 스트림이 더 신속하게 실행됩니다.

**거리 측도.** 데이터 점 사이의 거리를 측정하는 데 사용할 방법입니다. 거리가 클수록 상이성도 커집니다. 옵션은 다음과 같습니다.

- **유클리디안.** (기본값) 두 점 사이의 거리는 두 점을 직선으로 결합하여 계산됩니다.
- **맨해튼.** 두 점 사이의 거리는 해당 좌표 간 절대 차이의 합계로 계산됩니다.
- **캔버라.** 맨해튼 거리와 비슷하지만 원점에 더 가까운 데이터 점에 더 민감합니다.
- **최대.** 두 점 사이의 거리가 좌표 차원을 따라 해당 차이 중 가장 큰 값으로 계산됩니다.

#### ⑤ Netezza Bayes 넷 모델 너깃

Bayes 넷 모델 너깃은 모델 스코어링에 필요한 옵션을 설정하는 방법을 제공합니다.

Bayes 넷 모델 너깃을 포함한 스트림을 실행하면 노드는 목표 이름에서 이름이 파생된 한 개의 새 필드를 추가합니다.

표 1. Bayes 넷에 대한 필드 모델 스코어링

추가되는 필드의 이름	의미
<code>\$BN-target_name</code>	현재 레코드의 예측값입니다.

테이블 노드를 모델 너깃에 첨부하고 테이블 노드를 실행하여 추가 필드를 볼 수 있습니다.

#### 가. Netezza Bayes 넷 너깃 - 설정 탭

설정 탭에서 모델 스코어링에 필요한 옵션을 설정할 수 있습니다.

**목표.** 현재 목표와 다른 목표 필드를 스코어링하려면 여기서 새 목표를 선택하십시오.

**레코드 ID.** 레코드 ID 필드가 지정되지 않은 경우 사용할 필드를 여기서 선택하십시오.

**예측 유형.** 사용할 예측 알고리즘의 변형입니다.

- **최적(상관관계가 가장 밀접한 이웃 항목).** (기본값) 상관관계가 가장 밀접한 이웃 항목 노드를 사용합니다.
- **이웃 항목(이웃 항목의 가중된 예측).** 모든 이웃 항목 노드의 가중된 예측을 사용합니다.
- **NN-이웃 항목(null이 아닌 이웃 항목).** 널값인 노드(예측을 계산하는 대상이 되는 인스턴스에 대한 값이 누락된 속성에 해당하는 노드)를 무시하는 점만 제외하면 이전 옵션과 동일합니다.

**입력 필드 포함.** 선택된 경우 이 옵션은 모든 원래 입력 필드 다운스트림을 전달하여 추가 모델링 필드를 각 데이터 행에 추가합니다. 이 선택란을 선택 취소하면 레코드 ID 필드 및 추가 모델링 필드만 전달되므로 스트림이 더 신속하게 실행됩니다.

#### ⑥ IBM Data WH Naive Bayes 모델 너깃

Naive Bayes 모델 너깃은 모델 스코어링에 필요한 옵션을 설정하는 방법을 제공합니다.

Naive Bayes 모델 너깃을 포함한 스트림을 실행하면 노드는 목표 이름에서 이름이 파생된 한 개의 새 필드를 추가합니다.

표 1. Naive Bayes에 대한 모델 스코어링 필드 - 기본값

추가되는 필드의 이름	의미
<code>\$\$-target_name</code>	현재 레코드의 예측값입니다.

모델링 노드 또는 모델 너깃에서 **스코어 레코드에 할당된 클래스의 확률 계산** 옵션을 선택하고 스트림을 실행한 경우 두 개의 추가적 필드가 추가됩니다.

표 2. Naive Bayes에 대한 모델 스코어링 필드 - 추가적

추가되는 필드의 이름	의미
\$IP-target_name	인스턴스에 대한 계층의 베이지안 분자입니다. 즉 사전 계층 확률 및 조건부 인스턴스 속성 값 확률의 곱입니다.
\$ILP-target_name	후자의 자연로그입니다.

모델 너깃에 테이블 노드를 연결하고 테이블 노드를 실행하여 추가 필드를 볼 수 있습니다.

### 가. IBM Data WH Naive Bayes 너깃 - 설정 탭

설정 탭에서 모델 스코어링에 필요한 옵션을 설정할 수 있습니다.

**입력 필드 포함.** 선택된 경우 이 옵션은 모든 원래 입력 필드 다운스트림을 전달하여 추가 모델링 필드를 각 데이터 행에 추가합니다. 이 선택란을 선택 취소하면 레코드 ID 필드 및 추가 모델링 필드만 전달되므로 스트림이 더 신속하게 실행됩니다.

**스코어링 레코드에 대해 지정된 클래스의 확률 계산.** (의사결정 트리 및 Naive Bayes 전용) 선택된 경우 이 옵션은 추가 모델링 필드에 신뢰도(즉, 확률) 필드 및 예측 필드가 포함됨을 의미합니다. 이 선택란을 선택 취소하면 예측 필드만 생성됩니다.

**적거나 심한 비균형 데이터 세트의 확률 정확성을 향상시킵니다.** 확률을 계산할 때 이 옵션이 추정 중에 0값 확률을 피하기 위한  $m$ -추정 기법을 사용합니다. 이런 종류의 확률 추정은 느릴 수는 있으나 적거나 심한 비균형 데이터 세트에 대해 더 나은 결과를 제공합니다.

### ㉞ IBM Data WH KNN 모델 너깃

KNN 모델 너깃은 모델 스코어링에 필요한 옵션을 설정하는 방법을 제공합니다.

KNN 모델 너깃을 포함한 스트림을 실행하면 노드는 목표 이름에서 이름이 파생된 한 개의 새 필드를 추가합니다.

표 1. KNN에 대한 모델 스코어링 필드

추가되는 필드의 이름	의미
\$KNN-target_name	현재 레코드의 예측값입니다.

테이블 노드를 모델 너깃에 첨부하고 테이블 노드를 실행하여 추가 필드를 볼 수 있습니다.

## 가. IBM Data WH KNN 너깃 - 설정 탭

설정 탭에서 모델 스코어링에 필요한 옵션을 설정할 수 있습니다.

**거리 척도.** 데이터 점 사이의 거리를 측정하는 데 사용할 방법입니다. 거리가 클수록 상이성도 커집니다. 옵션은 다음과 같습니다.

- **유클리디안.** (기본값) 두 점 사이의 거리는 두 점을 직선으로 결합하여 계산됩니다.
- **맨해튼.** 두 점 사이의 거리는 해당 좌표 간 절대 차이의 합계로 계산됩니다.
- **캔버라.** 맨해튼 거리와 비슷하지만 원점에 더 가까운 데이터 점에 더 민감합니다.
- **최대.** 두 점 사이의 거리가 좌표 차원을 따라 해당 차이 중 가장 큰 값으로 계산됩니다.

**최근접 이웃 수(k).** 특정 케이스에 대한 최근접 이웃 수입니다. 많은 수의 이웃을 사용한다고 해서 반드시 더 정확한 모델을 얻을 수 있는 것은 아님에 유의하십시오.

$k$ 를 선택하면 과적합 방지("불량" 데이터의 경우 특히 중요할 수 있음)와 해결(비슷한 인스턴스에 대해 다양한 예측을 생성함) 사이의 균형이 제어됩니다. 일반적으로 1부터 수십까지의 일반적인 값 범위를 사용하여 각 데이터 세트에 대해  $k$ 의 값을 조정해야 합니다.

**입력 필드 포함.** 선택된 경우 이 옵션은 모든 원래 입력 필드 다운스트림을 전달하여 추가 모델링 필드를 각 데이터 행에 추가합니다. 이 선택란을 선택 취소하면 레코드 ID 필드 및 추가 모델링 필드만 전달되므로 스트림이 더 신속하게 실행됩니다.

**거리를 계산하기 전에 측정 표준화.** 선택된 경우 이 옵션은 거리 값을 계산하기 전에 연속 입력 필드에 대한 측정을 표준화합니다.

**코어 세트를 사용하여 큰 데이터 세트의 성능 향상.** 선택된 경우 이 옵션은 코어 세트 표본 추출을 사용하여 큰 데이터 세트가 관련된 경우 계산 속도를 높입니다.

## ⑧ Netezza 분열 군집 모델 너깃

분열 군집 모델 너깃은 모델 스코어링에 필요한 옵션을 설정하는 방법을 제공합니다.

분열 군집 모델 너깃을 포함한 스트림을 실행하면 노드는 목표 이름에서 이름이 파생된 두 개의 새 필드를 추가합니다.

표 1. 분할 군집에 대한 모델 스코어링 필드

추가되는 필드의 이름	의미
<code>\$DC-target_name</code>	현재 레코드가 지정되는 부군집의 식별자입니다.
<code>\$DCD-target_name</code>	현재 레코드에 대한 부군집 중심으로부터의 거리입니다.

모델 너깃에 테이블 노드를 연결하고 테이블 노드를 실행하여 추가 필드를 볼 수 있습니다.

### 가. Netezza 분열 군집 너깃 - 설정 탭

설정 탭에서 모델 스코어링에 필요한 옵션을 설정할 수 있습니다.

**입력 필드 포함.** 선택된 경우 이 옵션은 모든 원래 입력 필드 다운스트림을 전달하여 추가 모델링 필드를 각 데이터 행에 추가합니다. 이 선택란을 선택 취소하면 레코드 ID 필드 및 추가 모델링 필드만 전달되므로 스트림이 더 신속하게 실행됩니다.

**거리 척도.** 데이터 점 사이의 거리를 측정하는 데 사용할 방법입니다. 거리가 클수록 상이성도 커집니다. 옵션은 다음과 같습니다.

- **유클리디안.** (기본값) 두 점 사이의 거리는 두 점을 직선으로 결합하여 계산됩니다.
- **맨해튼.** 두 점 사이의 거리는 해당 좌표 간 절대 차이의 합계로 계산됩니다.
- **캔버라.** 맨해튼 거리와 비슷하지만 원점에 더 가까운 데이터 점에 더 민감합니다.
- **최대.** 두 점 사이의 거리가 좌표 차원을 따라 해당 차이 중 가장 큰 값으로 계산됩니다.

**적용되는 계층 수준.** 데이터에 적용되어야 하는 계층 구조의 수준입니다.

### ⑨ IBM Data WH PCA 모델 너깃

PCA 모델 너깃은 모델 스코어링에 필요한 옵션을 설정하는 방법을 제공합니다.

PCA 모델 너깃을 포함한 스트림을 실행하면 노드는 목표 이름에서 이름이 파생된 한 개의 새 필드를 추가합니다.

표 1. PCA에 대한 모델 스코어링 필드

추가되는 필드의 이름	의미
$\$F\text{-target\_name}$	현재 레코드의 예측값입니다.

모델링 노드 또는 모델 너깃의 **주성분 수...** 필드에서 1보다 큰 값을 지정하고 스트림을 실행하면 노드가 각 성분에 대해 새 필드를 추가합니다. 이 경우, 필드 이름에 n 접미문자가 추가되며 n은 성분의 번호입니다. 예를 들어, 모델 이름이 *pca*이며 세 개의 성분이 있는 경우, 새 필드 이름이  $\$F\text{-pca-1}$ ,  $\$F\text{-pca-2}$  및  $\$F\text{-pca-3}$ 이 됩니다.

모델 너깃에 테이블 노드를 연결하고 테이블 노드를 실행하여 추가 필드를 볼 수 있습니다.

**참고:** 소문자 필드 이름을 사용할 경우 모델을 스코어링할 때 오류가 발생할 수 있습니다. 이것은 알려진 Db2 Data Warehouse 결함으로, 임시 해결책은 스코어링하기 전에 모든 필드의 이름을 대문자로 변경하는 것입니다.

### 가. IBM Data WH PCA 너깃 - 설정 탭

설정 탭에서 모델 스코어링에 필요한 옵션을 설정할 수 있습니다.

**투영에 사용될 주성분의 수.** 데이터 세트를 줄일 주성분의 수입니다. 이 값은 속성의 수(입력 필드)를 초과할 수 없습니다.

**입력 필드 포함.** 선택된 경우 이 옵션은 모든 원래 입력 필드 다운스트림을 전달하여 추가 모델링 필드를 각 데이터 행에 추가합니다. 이 선택란을 선택 취소하면 레코드 ID 필드 및 추가 모델링 필드만 전달되므로 스트림이 더 신속하게 실행됩니다.

### ⑩ Netezza 회귀 트리 모델 너깃

회귀 트리 모델 너깃은 모델 스코어링에 필요한 옵션을 설정하는 방법을 제공합니다.

회귀 트리 모델 너깃을 포함한 스트림을 실행하면 노드는 목표 이름에서 이름이 파생된 한 개의 새 필드를 추가합니다.

표 1. 회귀 트리의 모델 스코어링 필드

추가되는 필드의 이름	의미
<code>\$I-target_name</code>	현재 레코드의 예측값입니다.

모델링 노드 또는 모델 너깃에서 **추정 분산 계산** 옵션을 선택하고 스트림을 실행한 경우 추가적 필드가 추가됩니다.

표 2. 회귀 트리에 대한 모델 스코어링 필드 - 추가적

추가되는 필드의 이름	의미
<code>\$IV-target_name</code>	예측값의 추정 분산입니다.

모델 너깃에 테이블 노드를 연결하고 테이블 노드를 실행하여 추가 필드를 볼 수 있습니다.

### 가. Netezza 회귀 트리 너짓 - 모델 탭

모델 탭은 회귀 트리 모형의 예측자 중요도를 그래픽 형식으로 표시합니다. 막대의 길이는 예측 변수의 중요도를 나타냅니다.

**참고:** IBM® Netezza® Analytics 2.x 이전 버전으로 작업 중인 경우에는 회귀 트리 모형의 콘텐츠가 텍스트 형식으로만 표시됩니다.

이러한 버전에 대해서는 다음 정보가 표시됩니다.

- 노드 또는 리프에 해당하는 텍스트의 각 줄
- 트리 수준을 반영하는 들여쓰기
- 노드의 경우, 분할 조건이 표시됩니다.
- 리프의 경우, 지정된 클래스 레이블이 표시됩니다.

### 나. Netezza 회귀 트리 너짓 - 설정 탭

설정 탭에서 모델 스코어링에 필요한 옵션을 설정할 수 있습니다.

**입력 필드 포함.** 선택된 경우 이 옵션은 모든 원래 입력 필드 다운스트림을 전달하여 추가 모델링 필드를 각 데이터 행에 추가합니다. 이 선택란을 선택 취소하면 레코드 ID 필드 및 추가 모델링 필드만 전달되므로 스트림이 더 신속하게 실행됩니다.

**추정 분산 계산.** 지정된 클래스의 분산이 출력에 포함되어야 하는지 여부를 표시합니다.

### 다. Netezza 회귀 트리 너짓 - 뷰어 탭

뷰어 탭은 SPSS® Modeler가 해당 회귀 트리 모형의 트리 프리젠테이션을 표시하는 것과 동일한 방식으로 트리 모형의 트리 프리젠테이션을 표시합니다.

**참고:** IBM® Netezza® Analytics 2.x 이전 버전으로 모델이 작성된 경우 뷰어 탭이 비어 있습니다.

### ⑪ IBM Data WH 선형 회귀 모델 너짓

선형 회귀 모형 너짓은 모형 스코어링에 필요한 옵션을 설정하는 방법을 제공합니다.

선형 회귀 모형 너짓을 포함한 스트림을 실행하면 노드는 목표 이름에서 이름이 파생된 한 개의 새 필드를 추가합니다.

표 1. 선형 회귀에 대한 모델 스코어링 필드

추가되는 필드의 이름	의미
\$LR-target_name	현재 레코드의 예측값입니다.

### 가. IBM Data WH 선형 회귀 너깃 - 설정 탭

설정 탭에서 모델 스코어링에 필요한 옵션을 설정할 수 있습니다.

**입력 필드 포함.** 선택된 경우 이 옵션은 모든 원래 입력 필드 다운스트림을 전달하여 추가 모델링 필드를 각 데이터 행에 추가합니다. 이 선택란을 선택 취소하면 레코드 ID 필드 및 추가 모델링 필드만 전달되므로 스트림이 더 신속하게 실행됩니다.

### ㉓ Netezza 시계열 모델 너깃

모델 너깃은 시계열 모델링 작업의 출력에 대한 액세스를 제공합니다. 출력은 다음 필드로 구성됩니다.

표 1. 시계열 모델 출력 필드

필드	설명
TSID	시계열의 식별자이며 모델링 노드의 필드 탭의 시계열 ID에 대해 지정되는 콘텐츠입니다. 자세한 정보는 Netezza 시계열 필드 옵션의 내용을 참조하십시오.
시간	현재 시계열 내의 시간 주기입니다.
히스토리	히스토리 데이터 값(예측 작성에 사용된 값)입니다. 이 필드는 모델 너깃의 설정 탭에서 <b>결과에 히스토리 값 포함</b> 옵션이 선택된 경우에만 포함됩니다.
\$TS-INTERPOLATED	보간법이 적용된 값이며 사용된 경우에 한합니다. 이 필드는 모델 너깃의 설정 탭에서 <b>결과에 보간값 포함</b> 옵션이 선택된 경우에만 포함됩니다. 보간법은 모델링 노드의 작성 옵션 탭의 옵션입니다.
\$TS-FORECAST	시계열의 예측값입니다.

시계열의 식별자이며 모델링 노드의 필드 탭의 시계열 ID에 대해 지정되는 콘텐츠입니다. 자세한 정보는 Netezza 시계열 필드 옵션의 내용을 참조하십시오.

### 가. Netezza 시계열 너깃 - 설정 탭

설정 탭에서 모델 출력 사용자 정의에 필요한 옵션을 설정할 수 있습니다.

**모델 이름.** 모델링 노드의 모델 옵션 탭에서 지정된 모델의 이름입니다.

기타 옵션은 모델링 노드의 모델링 옵션 탭과 동일합니다.

### ㉓ IBM Data WH 일반화 선형 모델 너깃

모델 너깃은 모델링 작업의 출력에 대한 액세스를 제공합니다.

일반화 선형 모형 너깃을 포함한 스트림을 실행하면 노드는 목표 이름에서 이름이 파생된 새 필드를 추가합니다.

표 1. 일반화 선형에 대한 모델 스코어링 필드

추가되는 필드의 이름	의미
<code>\$GLM-target_name</code>	현재 레코드의 예측값입니다.

모델 탭에는 모델과 연관된 다양한 통계량이 표시됩니다.

출력은 다음 필드로 구성됩니다.

표 2. 일반화 선형 모형의 출력 필드

출력필드	설명
매개변수	모델에서 사용되는 모수(예측자 변수)입니다. 절편(회귀 모형의 상수항)과 같이 수치 및 명목형 열입니다.
베타	상관계수(모델의 선형 성분)입니다.
표준오차	베타에 대한 표준 편차입니다.
검정	모수의 타당성을 평가하는 데 사용되는 검정 통계량입니다.
P-값	모수가 유의적이라고 가정할 때 오차의 확률입니다.
<b>잔차 요약</b>	
잔차 유형	요약 값이 표시되는 예측의 잔차 유형입니다.
RSS	잔차 값입니다.
자유도	잔차에 대한 자유도입니다.

출력필드	설명
P-값	오차의 확률입니다. 높은 값은 적합도가 낮은 모델을 나타내며 낮은 값은 적합도가 높은 모델을 나타냅니다.

### 가. IBM Data WH 일반화 선형 모형 너짓 - 설정 탭

설정 탭에서 모델 출력을 사용자 정의할 수 있습니다.

이 옵션은 모델링 노드의 스코어링 옵션에 대해 표시된 것과 동일합니다. 자세한 정보는 IBM Data WH 일반화 선형 모델 옵션 - 스코어링 옵션의 내용을 참조하십시오.

### ⑭ IBM Data WH TwoStep 모델 너짓

TwoStep 모델 너짓을 포함하는 스트림을 실행하는 경우, 노드는 소속군집 및 해당 레코드에 대해 지정된 군집 중심으로부터의 거리를 포함하는 두 개의 새 필드를 추가합니다. 이름이 \$TS-Twostep인 새 필드는 소속군집용이며 이름이 \$TSP-Twostep인 새 필드는 군집 중심으로부터의 거리용입니다.

### 가. IBM Data WH TwoStep 너짓 - 모델 탭

모델 탭에는 군집 필드에 대한 분포 및 요약 통계를 표시하는 다양한 그래픽 보기가 있습니다. 모델에서 데이터를 내보내거나 보기를 그래픽으로 내보낼 수 있습니다.

## 5) z/OS®용 IBM® Db2®를 사용한 데이터베이스 모델링

### (1) IBM SPSS Modeler 및 z/OS용 IBM Db2

SPSS Modeler는 z/OS용 Db2와의 통합을 지원하여 z/OS용 Db2 서버에서 고급 분석을 실행하는 기능을 제공합니다. SPSS Modeler 그래픽 사용자 인터페이스 및 워크플로우 중심 개발 환경을 통해 이 기능에 액세스할 수 있습니다. 이 방식으로, IBM Db2 Analytics Accelerator를 활용하여 z/OS용 Db2 환경에서 직접 데이터 마이닝 알고리즘을 실행할 수 있습니다.

SPSS Modeler는 z/OS용 Db2로부터 다음과 같은 알고리즘의 통합을 지원합니다.

- 의사결정 트리
- K-평균
- Naive Bayes
- 회귀분석 트리
- TwoStep

## (2) z/OS용 IBM Db2와의 통합을 위한 요구사항

다음 조건은 z/OS®용 Db2® 및 z/OS용 IBM® Db2 Analytics Accelerator를 사용하여 In-Database 모델링을 수행하기 위한 전제조건입니다. 이러한 조건이 충족되었는지 확인하기 위해 데이터베이스 관리자와 상의할 필요가 있습니다. 지원되는 버전을 포함하는 자세한 요구사항은 소프트웨어 제품 호환성 보고서를 참조하십시오.

- Windows 또는 UNIX에서 SPSS® Modeler Server 설치에 대해 또는 로컬 모드로 실행 중인 IBM SPSS Modeler
- z/OS용 Db2 Analytics Accelerator가 있는 z/OS용 Db2
- IBM SPSS Data Access Pack
- SPSS Modeler Server를 실행 중인 서버에서, 다음 시스템 중 하나:
  - IBM Db2 Data Server Driver for ODBC and CLI
  - Linux®, UNIX 및 Windows용 Db2 버전과 z/OS용 Db2에 맞게 구성된 ODBC 데이터 소스
- Db2 Connect for System z®에 대한 라이선스
- SPSS Modeler에서 SQL 생성 및 최적화 사용
- Db2 z/OS In-Database 마이닝에는 액셀러레이터 전용 테이블(AOT) 또는 가속화된 테이블 및 INZA 지원이 필요합니다. IDAA INZA는 IDAA 5.1에서 도입되었습니다. 즉, Db2 z/OS In-Database 마이닝 노드는 이전 버전의 IDAA에서는 작동하지 않습니다. Modeler에서 IDAA 사용 가능 DSN을 사용하는 경우, 해당 DSN을 사용하는 데이터베이스 소스 노드에서 리턴되는 테이블의 목록에 표시될 유일한 테이블은 AOT 또는 가속화된 테이블입니다.

## (3) z/OS용 IBM Db2 Analytics Accelerator와의 통합 사용

z/OS®용 Db2® Analytics Accelerator와의 통합을 사용하기 위한 단계는 다음과 같이 구성됩니다.

- z/OS용 Db2 및 z/OS용 Db2 Analytics Accelerator 구성
- ODBC 소스 작성
- IBM® SPSS® Modeler에서 z/OS용 IBM Db2의 통합 사용
- SPSS Modeler에서 SQL 생성 및 최적화 사용
- z/OS용 Db2에 대해 IBM SPSS Modeler Server Scoring Adapter 사용
- IBM SPSS Modeler에서 IBM Db2 클라이언트를 사용하여 DSN 구성

### ① z/OS용 IBM® Db2 및 z/OS용 IBM Analytics Accelerator 구성

z/OS®용 Db2® 및 z/OS용 Analytics Accelerator를 구성하는 방법은 다음 웹 사이트에 설명되어 있습니다.

## ② z/OS용 IBM Db2 및 IBM Db2 Analytics Accelerator에 대한 ODBC 소스 작성

z/OS®용 Db2®와 IBM® Db2 Analytics Accelerator 사이의 연결 활성화 방법에 대한 정보는 다음 웹 사이트를 참조하십시오.

- 버전 4의 경우: Db2 Analytics Accelerator for z/OS 4.1.0
- 버전 3의 경우: Db2 Analytics Accelerator for z/OS 3.1.0
- 애플리케이션에 대한 수정 없이 ODBC 및 JDBC 애플리케이션에서 IBM Db2 Analytics Accelerator로 쿼리 가속화 사용
- z/OS용 Db2 Analytics Accelerator에서 쿼리를 실행할 때 ODBC 드라이버의 SQL 오류

## ③ IBM® SPSS Modeler에서 z/OS®용 IBM Db2의 통합 사용

SPSS® Modeler에서 Db2®용 Db2의 통합을 사용하려면 다음 단계를 수행하십시오.

1. SPSS Modeler config 디렉토리에서 odbc-db2-accelerator-names.cfg 파일을 여십시오. 파일이 존재하지 않으면 파일을 작성해야 합니다.

2. 모든 데이터 소스 이름과 모든 액셀러레이터 이름을 추가하십시오. 예:

```
dsn1, acceleratorname1  
dsn2, acceleratorname2
```

3. 액셀러레이터 전용 테이블(AOT)의 기본 CCSID는 유니코드입니다. 이를 대체하려면 액셀러레이터 이름에 인코딩 문자열을 추가하여 항목을 수정하십시오. 예:

```
dsn1, acceleratorname1, EBCDIC  
dsn2, acceleratorname2, UNICODE
```

4. odbc-db2-accelerator-names.cfg 파일을 저장하고 닫은 후, 동일한 디렉토리에서 odbc-db2-custom-properties.cfg 파일을 여십시오.
5. SPSS Modeler는 SQL을 사용하여 IDAA 레지스터를 설정합니다. 필요한 경우에는 SQL을 필요한 값으로 변경하여 이러한 항목을 대체할 수 있습니다. 예:

```
current_query_sql_acc, "SET CURRENT QUERY ACCELERATION = ELIGIBLE"  
current_get_archive_acc, "SET CURRENT GET_ACCEL_ARCHIVE = NO"
```

6. 기본적으로 SPSS Modeler는 SQL을 사용하여 데이터베이스 캐시용 임시 테이블을 작성합니다. 필요한 경우에는 원하는 데이터베이스 이름을 지정하여 이를 대체할 수 있습니다. 예:

```
[OSZ]  
table_create_temp_sql_acc, 'CREATE TABLE <table-name> <<(table-columns)>> IN DATABASE  
NAME_OF_DATABASE_FOR_AOT'
```

7. 기본적으로 SPSS Modeler는 ODBC 소스 노드에 작성된 SQL 쿼리를 재실행 불가능으로 간주하며, 이는 해당 쿼리가 여러 번 실행되는 경우 서로 다른 결과를 리턴할 것으로 예상됨을 의미합니다. 그러나 일부 시나리오에서는 이로 인해 Modeler가 다운스트림 노드에 대해 SQL을 생성하지 못할 수 있으며 이는 관련 값을 Y로 변경하여 대체할 수 있습니다. 예:

```
assume_custom_sql_replayable, Y
```

8. SPSS Modeler 주메뉴에서 **도구 > 옵션 > 헬퍼 애플리케이션**을 클릭하십시오.
9. **z/OS용 IBM Db2** 탭을 클릭하십시오.
10. **z/OS용 IBM Db2 데이터 마이닝 통합 사용**을 선택한 후 확인을 클릭하십시오.

 **참고:** Modeler에서 IDAA 테이블과 비IDAA 테이블을 동시에 볼 수 없습니다.

#### ④ SQL 생성 및 최적화 사용

매우 큰 데이터 세트에 대해 작업할 수도 있기 때문에 성능을 위해 IBM® SPSS® Modeler에서 SQL 생성 및 최적화 옵션을 사용으로 설정해야 합니다.

SPSS Modeler를 구성하려면 다음의 단계를 수행하십시오.

1. IBM SPSS Modeler 메뉴에서 **도구 > 스트림 특성 > 옵션**을 선택하십시오.
2. 탐색 분할창에서 **최적화** 옵션을 클릭하십시오.
3. **SQL 생성** 옵션이 사용으로 설정되어 있는지 확인하십시오. 이 설정은 데이터베이스 모델링이 작동하기 위해 필수입니다.
4. **SQL 생성 최적화 및 기타 실행 최적화**를 선택하십시오(엄격하게 요구되지 않지만 최적화된 성능을 위해서는 강력하게 권장됨).

#### ⑤ IBM® SPSS Modeler에서 IBM Db2 클라이언트를 사용하여 DSN 구성

필요한 경우, SPSS® Modeler에서 Db2®용 Db2 클라이언트를 사용하여 데이터 소스 이름(DSN)을 구성하려면 다음 단계를 완료하십시오.

1. 아직 설치되지 않은 경우, Modeler Server가 설치된 운영 체제에 Db2 클라이언트를 설치하십시오.
2. **db2 catalog** 명령을 사용하여 데이터베이스를 카탈로그화하고 새 데이터 소스를 Db2 클라이언트 내의 db2cli.ini 파일에 추가하십시오. 정의된 데이터베이스 별명을 지정하는지 확인하십시오.
3. 데이터 액세스를 구성하십시오. 자세한 단계는 Modeler 문서에 있습니다. 추가 정보는 데이터 액세스의 내용을 참조하십시오.

4. 2단계에서 정의된 데이터베이스 별명을 참조하여 odbc.ini에 새 ODBC 데이터 소스를 작성하십시오.
5. Linux 또는 UNIX 사용자의 경우:
  - a. 드라이버 라이브러리 libdb2o.so가 libdb2.so 대신 사용되었으며 새 데이터 소스에 대해 'DriverUnicodeType=1'이 정의되었는지 확인하십시오.
  - b. IBM SPSS Data Access Pack 설치에서 Db2 클라이언트의 라이브러리 경로가 odbc.sh에 추가되었는지 확인하십시오.
  - c. Modeler Server가 UTF-16 인코딩을 사용하는 ODBC 드라이버 래퍼 라이브러리 ('libspssodbc\_datadirect\_utf16.so')를 사용하는지 확인하십시오.
6. Db2에 연결하는 사용자가 다음 쿼리를 실행할 수 있는 권한을 갖고 있는지 확인하십시오.

```
SELECT ACCELERATORNAME FROM SYSACCEL.SYSACCELERATORS
```

#### (4) z/OS용 IBM® Db2를 사용한 모델 작성

각각의 지원되는 알고리즘에는 해당 모델링 노드가 있습니다. 노드 팔레트의 데이터베이스 모델링 탭에서 z/OS®용 Db2® 모델링 노드에 액세스할 수 있습니다.

### 데이터 고려사항

데이터 소스에 있는 필드는 모델링 노드에 따라 다양한 데이터 유형의 변수를 포함할 수 있습니다. SPSS® Modeler에서는 데이터 유형이 측정 수준으로 알려져 있습니다. 모델링 노드의 필드 탭에서는 아이콘을 사용하여 해당 입력 및 목표 필드에 대해 허용되는 측정 수준 유형을 표시합니다.

**목표 필드.** 목표 필드는 값을 예측하는 필드입니다. 목표를 지정할 수 있는 경우 소스 데이터 필드 중 하나만 목표 필드로 선택할 수 있습니다.

**레코드 ID 필드.** 각각의 케이스를 고유하게 식별하는 데 사용되는 필드를 지정합니다. 예를 들어, ID 필드(예: *CustomerID*)가 될 수 있습니다. 소스 데이터가 ID 필드를 포함하지 않는 경우에는 다음 프로시저에 표시된 대로 파생 노드를 사용하여 이 필드를 작성할 수 있습니다.

1. 소스 노드를 선택하십시오.
2. 노드 팔레트의 필드 조작 탭에서 파생 노드를 두 번 클릭하십시오.
3. 캔버스에서 해당 아이콘을 두 번 클릭하여 파생 노드를 여십시오.
4. 파생 필드 필드에 예를 들어, ID를 입력하십시오.
5. 수식 필드에서 @INDEX를 입력한 후 확인을 클릭하십시오.
6. 파생 노드를 나머지 스트림에 연결하십시오.

## 널값 처리

입력 데이터에 널값이 포함되어 있는 경우 일부 z/OS용 Db2 노드를 사용하면 오류 메시지가 표시되거나 장기 실행 스트림이 발생할 수 있으므로 널값이 포함된 레코드는 제거하는 것이 좋습니다. 다음의 방법을 사용하십시오.

1. 선택 노드를 소스 노드에 연결하십시오.
2. 선택 노드의 **모드** 옵션을 **삭제**로 설정하십시오.
3. **조건** 필드에서 다음을 입력하십시오.

```
@NULL(field1) [or @NULL(field2)[... or @NULL(fieldN)]]
```

모든 입력 필드를 포함해야 합니다.

4. 선택 노드를 나머지 스트림에 연결하십시오.

## 모델 출력

z/OS용 Db2 모델링 노드가 포함된 스트림이 실행될 때마다 약간 다른 결과를 생성할 수 있습니다. 이는 모델 작성 전에 데이터를 임시 테이블로 읽어오므로 노드가 소스 데이터를 읽는 순서가 항상 동일하지 않기 때문입니다. 하지만 이 영향에 의해 생성된 차이는 무시할 수 있습니다.

## 일반 주석

- SPSS Collaboration and Deployment Services에서는 z/OS용 Db2 모델링 노드가 포함된 스트림을 사용하여 스코어링 구성을 작성할 수 없습니다.
- z/OS용 Db2 노드에 의해 작성된 모델에 대해서는 PMML 내보내기 또는 가져오기를 수행할 수 없습니다.

### ① z/OS®용 IBM® Db2® 모델 - 필드 옵션

필드 탭에서는 업스트림 노드에 이미 정의된 필드 역할 설정을 사용하거나 수동으로 필드를 지정할 수 있습니다.

**사전 정의된 역할 사용:** 이 옵션은 업스트림 유형 노드(또는 업스트림 소스 노드의 유형 탭)의 역할 설정(목표 및 예측자 등)을 사용합니다.

**사용자 정의 필드 할당 사용:** 이 화면에서 수동으로 목표, 예측자 및 기타 역할을 지정하려면 이 옵션을 선택하십시오.

**필드.** 화살표 단추를 사용하여 수동으로 이 목록의 항목을 화면 오른쪽의 다양한 역할 필드에 할당하십시오. 아이콘은 각 역할 필드에 대한 유효한 측정 수준을 나타냅니다.

**모두** 단추를 클릭하여 목록의 모든 필드를 선택하거나 개별 측정 수준 단추를 클릭하여 해당 측정 수준의 모든 필드를 선택합니다.

**목표:** 하나의 필드를 예측 목표로 선택하십시오. 일반화 선형 모형의 경우 이 화면의 **시행** 필드도 참조하십시오.

**레코드 ID.** 고유 레코드 식별자로 사용할 필드입니다.

**예측자(입력).** 예측에 대한 입력으로 하나 이상의 필드를 선택합니다.

## ② z/OS용 IBM Db2 모델 - 서버 옵션

서버 탭에서 모델을 작성할 z/OS®용 Db2® 시스템을 지정할 수 있습니다.

- **업스트림 연결 사용.** (기본값) 업스트림 노드(예: 데이터베이스 소스 노드)에 지정된 연결 세부 사항을 사용합니다. **참고:** 이 옵션은 모든 업스트림 노드가 SQL 푸시백을 사용할 수 있는 경우에만 작동합니다. 이 경우, SQL은 모든 업스트림 노드를 완전히 구현하므로 데이터베이스 밖으로 데이터를 이동시키지 않아도 됩니다.
- **데이터를 연결로 이동.** 여기에 지정하는 데이터베이스로 데이터를 이동시킵니다. 그러면 데이터가 다른 IBM® 데이터베이스 또는 다른 벤더의 데이터베이스에 있거나 데이터가 플랫폼 파일에 있는 경우에도 모델링이 작동할 수 있습니다. 또한, 노드가 SQL 푸시백을 수행하지 않아 데이터가 추출된 경우에는 여기에 지정된 데이터베이스로 데이터가 다시 이동합니다. **편집** 단추를 클릭하여 연결을 찾아보고 선택할 수 있습니다.

**참고:** ODBC 데이터 소스 이름은 각 SPSS® Modeler 스트림에 효과적으로 임베드됩니다. 하나의 호스트에서 작성된 스트림이 다른 호스트에서 실행되는 경우, 해당 데이터 소스의 이름은 각 호스트에서 동일해야 합니다. 선택적으로, 각 소스 또는 모델링 노드의 서버 탭에서 다른 데이터 소스를 선택할 수 있습니다.

## ③ z/OS®용 IBM® Db2® 모델 - 모델 옵션

모델 옵션 탭에서는 모델 이름을 지정할 것인지, 이름을 자동으로 생성할 것인지 선택할 수 있습니다.

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**이름이 사용된 경우 기존 대체.** 이 선택란을 선택하면 이름이 동일한 기존 모델을 겹쳐씹니다.

## (5) z/OS®용 IBM® Db2® 모델 - K-평균

K-평균 노드는 군집 분석 방법을 제공하는 K-평균 알고리즘을 구현합니다. 이 노드를 사용하여 데이터 세트를 고유한 그룹으로 군집화할 수 있습니다.

이 알고리즘은 거리 메트릭(함수)을 기반으로 데이터 점 사이의 유사성을 측정하는 거리 기반 군집화 알고리즘입니다. 데이터 점은 사용되는 거리 메트릭에 따라 가장 가까운 군집에 지정됩니다.

각 훈련 인스턴스가 가장 가까운 군집에 지정되는 동일한 기본 프로세스를 여러 번 반복 수행함으로써 이 알고리즘이 작동합니다(지정된 거리 함수와 관련하여 해당 인스턴스 및 군집 중심에 적용됨). 그러면 모든 군집 중심이 특정 군집에 지정된 인스턴스의 평균 속성 값 벡터로서 다시 계산됩니다.

### ① z/OS®용 IBM® Db2® 모델 - K-평균 필드 옵션

필드 탭에서는 업스트림 노드에 이미 정의된 필드 역할 설정을 사용하거나 수동으로 필드를 지정할 수 있습니다.

**사전 정의된 역할 사용:** 이 옵션은 업스트림 유형 노드(또는 업스트림 소스 노드의 유형 탭)의 역할 설정(목표 및 예측자 등)을 사용합니다.

**사용자 정의 필드 할당 사용:** 이 화면에서 수동으로 목표, 예측자 및 기타 역할을 지정하려면 이 옵션을 선택하십시오.

**필드.** 화살표 단추를 사용하여 수동으로 이 목록의 항목을 화면 오른쪽의 다양한 역할 필드에 할당하십시오. 아이콘은 각 역할 필드에 대한 유효한 측정 수준을 나타냅니다.

**모두** 단추를 클릭하여 목록의 모든 필드를 선택하거나 개별 측정 수준 단추를 클릭하여 해당 측정 수준의 모든 필드를 선택합니다.

**레코드 ID.** 고유 레코드 식별자로 사용할 필드입니다.

**예측자(입력).** 예측에 대한 입력으로 하나 이상의 필드를 선택합니다.

### ② z/OS®용 IBM® Db2® 모델 - K-평균 작성 옵션

작성 옵션을 설정하여 고유의 목적에 맞게 모델 작성을 사용자 정의할 수 있습니다.

기본 옵션을 사용하여 모델을 작성하려면 **실행**을 클릭하십시오.

**거리 척도.** 이 매개변수는 데이터 점 사이의 거리를 측정하는 방법을 정의합니다. 거리가 멀수록 유사성이 떨어집니다. 다음 옵션 중 하나를 선택하십시오.

- **유클리디안.** 유클리디안 척도는 두 데이터 점 사이의 직선 거리입니다.
- **정규화 유클리디안.** 정규화 유클리디안 척도는 유클리디안 척도와 유사하지만 제곱 표준 편차에 의해 정규화됩니다. 유클리디안 척도와 달리, 정규화 유클리디안 척도는 척도 불변성(scale-invariant)을 가집니다.

**군집 수.** 이 매개변수는 작성할 군집 수를 정의합니다.

**반복 최대 수.** 알고리즘이 동일한 프로세스를 여러 번 반복합니다. 이 매개변수는 모델 훈련이 중지하는 반복 수를 정의합니다.

**통계량.** 이 매개변수는 모델에 포함되는 통계 수를 정의합니다. 다음 옵션 중 하나를 선택하십시오.

- **모두.** 모든 열 관련 통계 및 모든 값 관련 통계가 포함됩니다.

 **참고:** 이 매개변수는 통계 최대 수를 포함하므로 시스템 성능에 영향을 줄 수도 있습니다. 모델을 그래픽 형식으로 보지 않으려면 **없음**을 지정하십시오.

- **열.** 열 관련 통계가 포함됩니다.
- **없음.** 모델을 스코어링하는 데 필요한 통계량만 포함됩니다.

**결과 복제.** 분석을 복제하기 위한 난수 시드를 설정하려면 이 선택란을 선택하십시오. 정수를 지정하거나 **생성**을 클릭하여 의사 난수 정수를 작성할 수 있습니다.

## (6) z/OS®용 IBM® Db2® 모델 - Naive Bayes

Naive Bayes는 분류 문제점을 위한 잘 알려진 알고리즘입니다. 모델은 제안된 모든 예측 변수를 서로 독립된 것으로 처리하기 때문에 naïve라고 합니다. Naive Bayes는 속성과 목표 속성의 조합에 대한 조건부 확률을 계산하는 빠르고 확장 가능한 알고리즘입니다. 학습 데이터로부터 독립적인 확률이 설정됩니다. 이 확률은 각 입력 변수에서 각각의 값 범주가 발생하는 경우 각 목표 클래스의 우도를 제공합니다.

## (7) z/OS®용 IBM® Db2® 모델 - 의사결정 트리

의사결정 트리는 분류 모델을 나타내는 계층 구조입니다. 의사결정 트리 모형을 사용하여 훈련 데이터 세트에서 미래 관측을 예측하거나 분류하는 분류 시스템을 개발할 수 있습니다. 분류는 분류의 분할 포인트를 표시하는 가지가 있는 트리 구조 형식을 사용합니다. 분할은 중지 포인트에 도달할 때까지 반복적으로 데이터를 하위 그룹으로 분류합니다. 중지 포인트의 트리 노드를 리프라고 합니다. 각 리프는 해당 하위 그룹의 멤버, 즉 클래스에 **클래스 레이블**이라는 레이블을 지정합니다.

## ① z/OS®용 IBM® Db2® 모델 - 의사결정 트리 필드 옵션

필드 탭에서는 업스트림 노드에 이미 정의된 필드 역할 설정을 사용하거나 수동으로 필드를 지정할 수 있습니다.

**사전 정의된 역할 사용:** 이 옵션은 업스트림 유형 노드(또는 업스트림 소스 노드의 유형 탭)의 역할 설정(목표 및 예측자 등)을 사용합니다.

**사용자 정의 필드 할당 사용:** 이 화면에서 수동으로 목표, 예측자 및 기타 역할을 지정하려면 이 옵션을 선택하십시오.

**필드.** 화살표 단추를 사용하여 수동으로 이 목록의 항목을 화면 오른쪽의 다양한 역할 필드에 할당하십시오. 아이콘은 각 역할 필드에 대한 유효한 측정 수준을 나타냅니다.

**모두** 단추를 클릭하여 목록의 모든 필드를 선택하거나 개별 측정 수준 단추를 클릭하여 해당 측정 수준의 모든 필드를 선택합니다.

**목표:** 예측에 대한 목표로 하나의 필드를 선택하십시오.

**레코드 ID.** 고유 레코드 식별자로 사용할 필드입니다. 이 필드의 값은 레코드마다 고유해야 합니다(예: 고객 ID 번호).

**인스턴스 가중치.** 여기에 필드를 지정하면 기본값인 클래스 가중치(목표 필드에 대한 범주당 가중치) 대신, 또는 이와 더불어, 인스턴스 가중치(입력 데이터의 행당 가중치)를 사용할 수 있습니다. 여기에 지정하는 필드는 입력 데이터의 행마다 숫자 가중치를 포함하는 필드여야 합니다.

**예측자(입력).** 하나 이상의 입력 필드를 선택합니다. 유형 노드에서 필드 역할을 **입력**으로 설정하는 것과 유사합니다.

## ② z/OS®용 IBM® Db2® 모델 - 의사결정 트리 작성 옵션

다음 작성 옵션을 트리 성장에 사용할 수 있습니다.

**성장 속도.** 이러한 옵션은 트리 성장이 측정되는 방법을 제어합니다.

- **불순도 속도.** 이 속도는 트리를 분할하기에 가장 적합한 위치를 평가합니다. 데이터 하위 그룹 또는 세그먼트에서의 변동 측정치입니다. 낮은 불순도 측정치는 대부분의 멤버가 기준 또는 대상 필드에 대해 유사한 값을 갖는 그룹을 나타냅니다. 지원되는 측정치는 **엔트로피** 및 **지니(Gini)**입니다. 이러한 측정은 분기에 대한 범주 소속 확률을 기반으로 합니다.

- **최대 트리 깊이.** 루트 노드 아래에서 트리가 확장될 수 있는 최대 수준 수, 즉 표본이 반복적으로 분할되는 횟수입니다. 이 특성의 기본값은 10이고 이 특성에 대해 설정할 수 있는 최대 값은 62입니다.

**참고:** 모델 너깃의 뷰어가 모델을 텍스트 형식으로 표현하는 경우 최대 12수준의 트리가 표시됩니다.

**분할 기준.** 이 옵션은 트리 분할 중지 시점을 제어합니다.

- **분할을 위한 최소 개선도.** 트리에서 새 분할이 작성되기 전 줄여야 하는 불순도 최소량입니다. 트리 작성의 목표는 유사한 출력 값을 가진 하위 그룹을 작성하여 각 노드 내의 불순도를 최소화하는 것입니다. 분기에 대한 최상의 분할이 분할 기준에 의해 지정된 수치 미만으로 불순도를 감소시키는 경우 분기가 분할되지 않습니다.
- **분할을 위한 인스턴스 최소 수.** 분할할 수 있는 최소 레코드 수입니다. 남아 있는 분할되지 않은 레코드의 수가 이 수보다 적으면 분할이 추가로 수행되지 않습니다. 이 필드를 사용하여 트리에서 작은 하위 그룹이 작성되는 것을 방지할 수 있습니다.

**통계량.** 이 매개변수는 모델에 포함되는 통계 수를 정의합니다. 다음 옵션 중 하나를 선택하십시오.

- **모두.** 모든 열 관련 통계 및 모든 값 관련 통계가 포함됩니다.

**참고:** 이 매개변수는 통계 최대 수를 포함하므로 시스템 성능에 영향을 줄 수도 있습니다. 모델을 그래픽 형식으로 보지 않으려면 없음을 지정하십시오.

- **열.** 열 관련 통계가 포함됩니다.
- **없음.** 모델을 스코어링하는 데 필요한 통계량만 포함됩니다.

### ③ z/OS®용 IBM® Db2® 모델 - 의사결정 트리 노드 - 클래스 가중치

여기서는 개별 클래스에 가중치를 지정할 수 있습니다. 기본값은 모든 클래스에 동일한 가중치가 부여되도록 모든 클래스에 1 값을 지정하는 것입니다. 서로 다른 클래스 레이블에 대해 서로 다른 숫자 가중치를 지정함으로써 알고리즘이 그에 따라 특정 클래스의 훈련 세트에 가중치를 주도록 합니다.

가중치를 변경하려면 **가중치** 열에서 가중치를 두 번 클릭하고 원하는 대로 변경하십시오.

**값** 목표 필드의 가능한 값에서 파생된 클래스 레이블 세트입니다.

**가중치.** 특정 클래스에 지정할 가중치입니다. 클래스에 지정하는 가중치가 높을수록 모델이 해당 클래스에 대해 다른 클래스보다 더 민감하게 반응합니다.

클래스 가중치와 인스턴스 가중치를 조합하여 사용할 수 있습니다.

#### ④ z/OS®용 IBM® Db2® 모델 - 의사결정 트리 노드 - 트리 가지치기

가지치기 옵션을 사용하여 의사결정 트리의 가지치기 기준을 지정할 수 있습니다. 가지치기의 목적은 새 데이터에 대한 예상 정확도를 향상시키지 않는 지나치게 확장된 하위 그룹을 제거하여 과적합 위험을 줄이기 위한 것입니다.

**가지치기 속도.** 기본 가지치기 속도인 **정확도**는 트리에서 리프를 제거한 후 모델의 추정 정확도가 허용 가능한 한계 내에 유지되도록 합니다. 가지치기를 적용하는 동안 클래스 가중치를 고려하려면 대안인 **가중 정확도**를 사용하십시오.

**가지치기를 위한 데이터.** 학습 데이터의 일부 또는 모두를 사용하여 새 데이터에 대한 예상 정확도를 추정할 수 있습니다. 또는 이 용도로 지정된 테이블에서 별도의 가지치기 데이터 세트를 사용할 수 있습니다.

- **모든 훈련 데이터 사용.** 이 옵션(기본값)은 모든 훈련 데이터를 사용하여 모형 정확도를 추정합니다.
- **가지치기에 훈련 데이터의 % 사용.** 가지치기 데이터에 대해 지정된 백분율을 사용하여 데이터를 두 개의 세트, 즉 훈련을 위한 세트와 가지치기를 위한 세트로 분할하려면 이 옵션을 사용하십시오.
- **난수 시드를 지정하여 스트림을 실행할 때마다 데이터가 동일한 방식으로 파티셔닝되도록 하려면 결과 복제를 선택하십시오.** 가지치기에 사용되는 시드 필드에 정수를 지정하거나 생성을 클릭하여 의사 랜덤 정수를 작성할 수 있습니다.
- **기존 테이블의 데이터 사용.** 모형 정확도를 추정하기 위한 별도의 가지치기 데이터 세트의 테이블 이름을 지정하십시오. 이는 훈련 데이터를 사용하는 것보다 신뢰성이 높은 것으로 간주됩니다.

#### (8) z/OS®용 IBM® Db2® 모델 - 회귀 트리

회귀 트리는 케이스 표본을 반복적으로 분할하여 숫자 목표 필드의 값을 기반으로 동일한 종류의 서브세트를 파생하는 트리 기반 알고리즘입니다. 의사결정 트리과 마찬가지로, 회귀 트리는 트리의 리프가 충분히 작거나 충분히 균일한 서브세트에 해당되는 여러 서브세트로 데이터를 분해합니다. 분할은 목표 속성 값의 산포도를 줄이기 위해 선택합니다. 그러면 리프에서의 해당 평균 값을 사용하여 목표 속성 값을 상당히 잘 예측할 수 있습니다.

#### (9) z/OS®용 IBM® Db2® 모델 - 회귀 트리 작성 옵션 - 트리 성장

트리 성장 및 트리 가지치기를 위한 작성 옵션을 설정할 수 있습니다.

다음 작성 옵션을 트리 성장에 사용할 수 있습니다.

**최대 트리 깊이.** 루트 노드 아래에서 트리가 확장될 수 있는 최대 수준 수, 즉 표본이 반복적으로 분할되는 횟수입니다. 기본값은 62이며, 이 값은 모델링을 위한 최대 트리 깊이입니다.

**참고:** 모델 너트의 뷰어가 모델을 텍스트 형식으로 표현하는 경우 최대 12수준의 트리가 표시됩니다.

**분할 기준.** 이 옵션은 트리 분할 중지 시점을 제어합니다.

- **분할 평가 속도.** 이 클래스 평가 속도는 트리를 분할하기에 가장 적합한 위치를 평가합니다.

**참고:** 현재, 분산이 사용 가능한 유일한 옵션입니다.

- **분할을 위한 최소 개선도.** 트리에서 새 분할이 작성되기 전 줄여야 하는 불순도 최소량입니다. 트리 작성의 목표는 유사한 출력 값을 가진 하위 그룹을 작성하여 각 노드 내의 불순도를 최소화하는 것입니다. 분기에 대한 최상의 분할이 분할 기준에 의해 지정된 수치 미만으로 불순도를 감소시키는 경우 분기가 분할되지 않습니다.

- **분할을 위한 인스턴스 최소 수.** 분할할 수 있는 최소 레코드 수입니다. 남아 있는 분할되지 않은 레코드의 수가 이 수보다 적으면 분할이 추가로 수행되지 않습니다. 이 필드를 사용하여 트리에서 작은 하위 그룹이 작성되는 것을 방지할 수 있습니다.

**통계량.** 이 매개변수는 모델에 포함되는 통계 수를 정의합니다. 다음 옵션 중 하나를 선택하십시오.

- **모두.** 모든 열 관련 통계 및 모든 값 관련 통계가 포함됩니다.

**참고:** 이 매개변수는 통계 최대 수를 포함하므로 시스템 성능에 영향을 줄 수도 있습니다. 모델을 그래픽 형식으로 보지 않으려면 **없음**을 지정하십시오.

- **열.** 열 관련 통계가 포함됩니다.

- **없음.** 모델을 스코어링하는 데 필요한 통계량만 포함됩니다.

## (10) z/OS®용 IBM® Db2® 모델 - 회귀분석 트리 작성 옵션 - 트리 가지치기

가지치기 옵션을 사용하여 회귀분석 트리의 가지치기 기준을 지정할 수 있습니다. 가지치기의 목적은 새 데이터에 대한 예상 정확도를 향상시키지 않는 지나치게 확장된 하위 그룹을 제거하여 과적합 위험을 줄이기 위한 것입니다.

**가지치기 속도.** 가지치기 속도를 사용하면 트리에서 리프를 제거한 후에 모델의 추정 정확도가 허용 가능한 한계 내로 유지될 수 있습니다. 다음 속도 중 하나를 선택할 수 있습니다.

- **mse.** 평균 제곱 오차 - (기본값) 맞춤선이 데이터 점에 어느 정도 가까운지 측정합니다.

- **r2.** R-제곱 - 회귀 모형에 의해 설명되는 종속변수에서 편차의 비율을 측정합니다.

- **Pearson.** Pearson 상관 계수 - 정규적으로 분포된 선형 종속 변수 간의 관계 강도를 측정합니다.

- **Spearman.** Spearman 상관 계수 - Pearson 상관에 따라 약해 보이지만 실제로는 강할 수 있는 비선형 관계를 발견합니다.

가지치기를 위한 데이터. 학습 데이터의 일부 또는 모두를 사용하여 새 데이터에 대한 예상 정확도를 추정할 수 있습니다. 또는 이 용도로 지정된 테이블에서 별도의 가지치기 데이터 세트를 사용할 수 있습니다.

- **모든 학습 데이터 사용.** 이 옵션(기본값)은 모든 학습 데이터를 사용하여 모형 정확도를 추정합니다.
- **가지치기를 위해 학습 데이터의 % 사용.** 가지치기 데이터에 대해 여기서 지정된 백분율을 사용하여 데이터를 두 개의 세트(학습에 대한 세트 하나와 가지치기에 대한 세트 하나)로 분할하려면 이 옵션을 사용하십시오.  
난수 시드를 지정하여 스트림을 실행할 때마다 데이터가 동일한 방식으로 파티셔닝되도록 하려면 **결과 복제**를 선택하십시오. **가지치기에 사용되는 시드 필드**에 정수를 지정하거나 **생성**을 클릭하여 의사 난수 정수를 작성할 수 있습니다.
- **기존 테이블의 데이터 사용.** 모형 정확도 추정을 위한 별도의 가지치기 데이터 세트의 테이블 이름을 지정하십시오. 이 방법은 학습 데이터를 사용하는 것보다 신뢰성이 높은 것으로 간주됩니다.

### (11) z/OS®용 IBM® Db2® 모델 - 이단계

이단계 노드는 대형 데이터 세트의 데이터를 군집화하는 방법을 제공하는 이단계 알고리즘을 구현합니다.

이 노드를 사용하면 사용 가능한 자원(예: 메모리 및 시간 제한조건)을 고려하면서 데이터를 군집화할 수 있습니다.

이단계 알고리즘은 다음과 같은 방법으로 데이터를 군집화하는 데이터베이스 마이닝 알고리즘입니다.

1. 군집화 기능(CF) 트리가 작성됩니다. 균형도가 높은 이 트리는 유사한 입력 레코드가 동일한 트리 노드의 일부가 되는 계층 구조 군집화를 위한 군집화 기능을 저장합니다.
2. CF 트리의 리프가 메모리에 계층적으로 군집화되어 최종 군집화 결과를 생성합니다. 가장 적합한 군집 수가 자동으로 결정됩니다. 최대 군집 수를 지정하는 경우 지정된 한계 내의 가장 적합한 군집 수가 결정됩니다.
3. 데이터에 K-평균 알고리즘과 유사한 알고리즘이 적용되는 두 번째 단계에서 군집화 결과가 세분화됩니다.

#### ① z/OS®용 IBM® Db2® 모델 - 이단계 필드 옵션

필드 옵션을 설정하여 업스트림 노드에 정의된 필드 역할 설정을 사용하도록 지정할 수 있습니다. 수동으로 필드 할당을 수행할 수도 있습니다.

**항목 선택.** 업스트림 소스 노드의 유형 탭 또는 업스트림 유형 노드의 역할 설정을 사용하려면 이 옵션을 선택하십시오. 역할 설정은, 예를 들면, 목표 및 예측자입니다.

**사용자 정의 필드 할당 사용:** 수동으로 목표, 예측자 및 기타 역할을 지정하려면 이 옵션을 선택하십시오.

**필드.** 화살표를 사용하여 수동으로 이 목록의 항목을 화면의 오른쪽에 있는 역할 필드에 지정하십시오. 아이콘은 각 역할 필드에 대한 유효한 측정 수준을 나타냅니다.

레코드 ID. 고유 레코드 식별자로 사용할 필드입니다.

**예측자(입력).** 예측에 대한 입력으로 하나 이상의 필드를 선택합니다.

## ② z/OS®용 IBM® Db2® 모델 - 이단계 작성 옵션

작성 옵션을 설정하여 고유의 목적에 맞게 모델 작성을 사용자 정의할 수 있습니다.

기본 옵션을 사용하여 모델을 작성하려면 **실행**을 클릭하십시오.

**거리 척도.** 이 매개변수는 데이터 점 사이의 거리를 측정하는 방법을 정의합니다. 거리가 멀수록 유사성이 떨어집니다. 옵션은 다음과 같습니다.

- **로그-우도.** 우도 척도는 변수에 확률 분포를 둡니다. 연속형 변수는 정규 분포로, 범주형 변수는 다항분포로 가정됩니다. 모든 변수를 독립변수로 가정합니다.

**군집 수.** 이 모수는 작성될 군집 수를 정의합니다. 옵션은 다음과 같습니다.

- **자동으로 군집 수 계산.** 군집 수가 자동으로 계산됩니다. **최대값** 필드에 군집 최대 수를 지정할 수 있습니다.
- **군집 수 지정.** 작성할 군집 수를 지정하십시오.

**통계량.** 이 매개변수는 모델에 포함되는 통계 수를 정의합니다. 옵션은 다음과 같습니다.

- **모두.** 모든 열 관련 통계 및 모든 값 관련 통계가 포함됩니다.

 **참고:** 이 매개변수는 통계 최대 수를 포함하므로 시스템 성능에 영향을 줄 수도 있습니다. 모델을 그래픽 형식으로 보지 않으려면 **없음**을 지정하십시오.

- **열.** 열 관련 통계가 포함됩니다.
- **없음.** 모델을 스코어링하는 데 필요한 통계량만 포함됩니다.

**결과 복제.** 분석을 복제하기 위한 난수 시드를 설정하려면 이 선택란을 선택하십시오. 정수를 지정하거나 **생성**을 클릭하여 의사 난수 정수를 작성할 수 있습니다.

### ③ z/OS®용 IBM® Db2® 모델 - 이단계 너깃 - 모델 탭

모델 탭에는 군집 필드에 대한 분포 및 요약 통계를 표시하는 다양한 그래픽 보기가 있습니다. 모델에서 데이터를 내보내거나 보기를 그래픽으로 내보낼 수 있습니다.

## (12) IBM Db2 for z/OS 모델 관리

z/OS®용 Db2® 모델은 다른 IBM® SPSS® Modeler 모델과 동일한 방식으로 캔버스 및 모델 팔레트에 추가되며 거의 동일한 방식으로 사용할 수 있습니다.

z/OS용 Db2에서 직접 데이터를 스코어링하려면 다음 단계를 수행하십시오.

1. 데이터가 위치한 z/OS용 Db2 데이터베이스에 SPSS Scoring Adapter를 설치하십시오.
2. 데이터가 위치한 z/OS용 Db2 데이터베이스에 스트림이 연결되게 하십시오.

### ① IBM® Db2® for z/OS® 모델 스코어링

모델은 금색 모델 너깃 아이콘에 의해 캔버스에 표시됩니다. 너깃의 주 용도는 데이터를 스코어링하여 예측을 생성하거나 모델 특성의 추가 분석을 허용하는 것입니다. 나중에 이 절에서 설명되는 대로 테이블 노드를 너깃에 연결하고 스트림의 해당 분기를 실행하여 표시될 수 있는 하나 이상의 추가 데이터 필드 형식으로 스코어가 추가됩니다. 의사결정 트리 또는 회귀 트리에 대한 대화 상자 등의 일부 너깃 대화 상자에는 모델의 시각적 표시를 제공하는 모델 탭이 추가로 제공됩니다.

추가 필드는 목표 필드의 이름에 추가된 \$<id>- 접두부에 의해 구별됩니다. 여기서 <id>는 모델에 따라 다르며 추가 중인 정보의 유형을 식별합니다. 각각의 모델 너깃에 대한 주제에 다양한 식별자가 설명되어 있습니다.

스코어를 보려면 다음의 단계를 완료하십시오.

1. 테이블 노드를 모델 너깃에 연결하십시오.
2. 테이블 노드를 여십시오.
3. 실행을 클릭하십시오.
4. 테이블 출력 창의 오른쪽으로 스크롤하여 추가 필드 및 해당 스코어를 보십시오.

**참고:** 스코어링 프로세스는 액셀러레이터에서 실행되지 않고 Db2에서 실행되므로 스코어링의 입력 테이블은 물리적으로 Db2에 위치해야 합니다. 따라서 스코어링 입력으로는 Db2 기반 테이블 또는 가속화된 테이블만 사용될 수 있습니다. 스트림이 액셀러레이터 전용 테이블을 사용하는 경우 "THE STATEMENT CANNOT BE EXECUTED BY DB2 OR IN THE ACCELERATOR"와 같은 오류가 발생합니다.

## ② z/OS용 IBM® Db2 의사결정 트리 모형 너깃

의사결정 트리 모형 너깃은 모델링 조작의 출력을 표시하므로 모델 스코어링을 위한 일부 옵션을 설정하는 데에도 사용될 수 있습니다.

의사결정 트리 모형 너깃이 포함된 스트림을 실행할 때, 노드는 두 개의 새 필드를 추가하며 이 필드의 이름은 목표에서 파생됩니다.

표 1. 의사결정 트리의 모델 스코어링 필드

추가되는 필드의 이름	의미
<code>\$I-target_name</code>	현재 레코드의 예측값입니다.
<code>\$IP-target_name</code>	예측 신뢰도(0.0 - 1.0)입니다.

 **참고:** z/OS®용 Db2®의 제한사항으로 인해 열 이름은 잘릴 수 있습니다.

### 가. z/OS®용 IBM® Db2® 의사결정 트리 너깃 - 모델 탭

모델 탭은 의사결정 트리 모형의 예측자 중요도를 그래픽 형식으로 표시합니다. 막대의 길이는 예측자의 중요도를 나타냅니다.

### 나. z/OS®용 IBM® Db2® 의사결정 트리 너깃 - 뷰어 탭

뷰어 탭은 SPSS® Modeler가 해당 의사결정 트리 모형의 트리 프리젠테이션을 표시하는 것과 동일한 방식으로 트리 모형의 트리 프리젠테이션을 표시합니다.

## ③ z/OS용 IBM® Db2 K-평균 모델 너깃

K-평균 모델 너깃은 훈련 데이터 및 추정 프로세스에 대한 정보와 함께, 군집 모델에서 캡처한 모든 정보를 포함합니다.

K-평균 모델 너깃을 포함하는 스트림을 실행하는 경우 노드는 해당 레코드의 지정된 군집 중심과의 거리 및 소속군집을 포함하는 2개의 새 필드를 추가합니다. 새 필드 이름은 모델 이름(접두문자가 소속군집에서는 \$KM-이고 군집 중심과의 거리에서는 \$KMD-임)에서 파생됩니다. 예를 들어, 모델 이름이 Kmeans인 경우 새 필드 이름은 \$KM-Kmeans 및 \$KMD-Kmeans로 지정됩니다.

 **참고:** z/OS®용 Db2®의 제한사항으로 인해 열 이름은 잘릴 수 있습니다.

## 가. z/OS®용 IBM® Db2® K-평균 너깃 - 모델 탭

모델 탭에는 군집 필드에 대한 분포 및 요약 통계를 표시하는 다양한 그래픽 보기가 있습니다. 모델에서 데이터를 내보내거나 보기를 그래픽으로 내보낼 수 있습니다.

### ④ z/OS용 IBM® Db2 Naive Bayes 모델 너깃

Naive Bayes 모델 너깃이 포함된 스트림을 실행할 때, 노드는 두 개의 새 필드를 추가하며 이 필드의 이름은 목표 이름에서 파생됩니다.

표 1. Naive Bayes의 모델 스코어링 필드

추가되는 필드의 이름	의미
<code>\$I-target_name</code>	현재 레코드의 예측값입니다.
<code>\$IP-target_name</code>	예측 신뢰도(0.0 - 1.0)입니다.

 **참고:** z/OS®용 Db2®의 제한사항으로 인해 열 이름은 잘릴 수 있습니다.

모델 너깃에 테이블 노드를 연결하고 테이블 노드를 실행하여 추가 필드를 볼 수 있습니다.

### ⑤ z/OS용 IBM® Db2 회귀 트리 모델 너깃

회귀 트리 모델 너깃이 포함된 스트림을 실행할 때, 노드는 두 개의 새 필드를 추가하며 이 필드의 이름은 목표 이름에서 파생됩니다.

표 1. 회귀 트리의 모델 스코어링 필드

추가되는 필드의 이름	의미
<code>\$I-target_name</code>	현재 레코드의 예측값입니다.
<code>\$IS-target_name</code>	예측값의 추정 표준 편차입니다.

 **참고:** z/OS®용 Db2®의 제한사항으로 인해 열 이름은 잘릴 수 있습니다.

모델 너깃에 테이블 노드를 연결하고 테이블 노드를 실행하여 추가 필드를 볼 수 있습니다.

### 가. z/OS®용 IBM® Db2® 회귀 트리 너짓 - 모델 탭

모델 탭은 회귀 트리 모형의 예측자 중요도를 그래픽 형식으로 표시합니다. 막대의 길이는 예측자의 중요도를 나타냅니다.

### 나. z/OS®용 IBM® Db2® 회귀 트리 너짓 - 뷰어 탭

뷰어 탭은 SPSS® Modeler가 해당 회귀 트리 모형의 트리 프리젠테이션을 표시하는 것과 동일한 방식으로 트리 모형의 트리 프리젠테이션을 표시합니다.

### ㉔ z/OS®용 IBM® Db2® 이단계 모델 너짓

이단계 모델 너짓을 포함하는 스트림을 실행하는 경우 노드는 해당 레코드의 지정된 군집 중심과의 거리 및 소속군집을 포함하는 2개의 새 필드를 추가합니다. 새 필드 이름은 모델 이름에서 파생되며, 소속군집의 경우 \$TS- 접두부가 붙고 군집 중심과의 거리는 \$TSD- 접두부가 붙습니다. 예를 들어, 모델의 이름이 MDL인 경우, 새 필드의 이름은 \$TS-MDL 및 \$TSD-MDL이 됩니다.

## IV. IBM SPSS Modeler 확장 도움말

### 1. 지원되는 언어

IBM® SPSS® Modeler는 R 및 Apache Spark를 지원합니다(Python을 통해). 자세한 정보는 다음 절을 참조하십시오.

#### 1) R

IBM® SPSS® Modeler는 R을 지원합니다.

#### 허용 가능한 명령문

- 다양한 확장 노드의 **명령문** 탭에 있는 명령문 필드 내에는 R에 의해 인식되는 명령문 및 함수만 허용됩니다.
- 확장 변환 노드 및 확장 모델 너깃의 경우, R 스크립트를 통해 배치 형식으로 데이터가 전달됩니다. 이러한 이유로 모델 스코어링 및 프로세스 노드에 대한 R 스크립트에는 정렬 또는 통합과 같이 데이터의 행 범위에 걸치거나 행을 조합하는 조작이 포함될 수 없습니다. 이 제한 사항은 데이터가 Hadoop 환경 및 In-Database 마이닝 동안 분할될 수 있도록 하기 위해 적용됩니다. 확장 출력 및 확장 모델 작성 노드에는 이러한 제한사항이 적용되지 않습니다.
- 확장 변환 노드 및 확장 모델 너깃에서 비일괄처리 데이터 전송 모드가 추가되어 SPSS Modeler Server에서 데이터 행을 확장하거나 결합할 수 있습니다.
- 모든 R 노드는 독립적 글로벌 환경에서 표시될 수 있습니다. 따라서 두 개의 별도의 R 노드에서 library 함수를 사용하려면 R 라이브러리를 두 R 스크립트 모두에 로드해야 합니다.
- R 스크립트에서 정의된 R 개체의 값을 표시하려면 인쇄 함수에 대한 호출을 포함시켜야 합니다. 예를 들어, data라는 호출된 R 개체의 값을 표시하려면 R 스크립트에 다음 행을 포함하십시오.

```
print(data)
```

- 이 함수는 IBM SPSS Modeler에서 R 스크립트 출력 파일의 파일 경로를 제어하기 위해 사용되므로 사용자의 R 스크립트에 R setwd 함수에 대한 호출을 포함해야 합니다.
- CLEM 표현식 및 스크립팅에서 사용하도록 정의된 스트림 매개변수는 R 스크립트에서 사용하면 인식되지 않습니다.
- IBM SPSS Modeler의 경우, R에서 대화형 도표를 지원하지 않습니다.

## 2) Python for Spark

IBM® SPSS® Modeler에서는 Apache Spark에 대해 Python 스크립트를 지원합니다.

### 참고:

Python 노드는 Spark 환경에 따라 다릅니다.

데이터가 Spark DataFrame 양식으로 표시되므로 Python 스크립트는 Spark API를 사용해야 합니다.

버전 17.1에서 작성된 이전 노드는 IBM SPSS Analytic Server에 대해서만 여전히 실행됩니다(해당 데이터는 IBM SPSS Analytic Server 소스 노드에서 가져오고 IBM SPSS Modeler로 추출되지는 않음). 버전 18.0 이상에서 작성된 새로운 Python 및 사용자 정의 대화 상자 작성기 노드는 IBM SPSS Modeler Server에 대해 실행될 수 있습니다.

Python을 설치할 때 모든 사용자가 Python 설치에 액세스할 수 있는 권한이 있는지 확인하십시오.

MLlib(Machine Learning Library)를 사용하려면 NumPy를 포함하는 Python 버전을 설치해야 합니다. 그런 다음 Python 설치를 사용하도록 IBM SPSS Modeler Server(또는 IBM SPSS Modeler Client의 로컬 서버)를 구성해야 합니다. 자세한 내용은 Python for Spark를 사용한 스크립팅의 내용을 참조하십시오.

### (1) Python for Spark를 사용한 스크립팅

IBM® SPSS® Modeler는 Apache Spark 프레임워크를 사용하여 데이터를 처리하면서 Python 스크립트를 실행할 수 있습니다. 이 문서는 제공된 인터페이스에 대해 Python API 설명을 제공합니다.

IBM SPSS Modeler 설치에는 Spark 배포가 포함됩니다. 예를 들어 IBM SPSS Modeler 18.3에는 Spark 2.4.6이 포함됩니다.

### 선행 조건

- IBM SPSS Analytic Server에서 Python/Spark 스크립트를 실행하려면 Analytic Server에 연결되어 있어야 하고, Analytic Server가 호환 가능한 Apache Spark 설치에 액세스할 수 있어야 합니다. 실행 엔진으로 Apache Spark 사용에 대한 세부사항은 IBM SPSS Analytic Server 문서를 참조하십시오.
- IBM SPSS Modeler Server(또는 IBM SPSS Modeler 클라이언트에 포함된 로컬 서버 - Windows 64 또는 Mac64가 필요함)에 대해 Python/Spark 스크립트를 실행하려는 경우, Python을 설치하고 Python을 설치를 사용하도록 options.cfg를 편집할 필요가 없습니다. 버전 18.1부터 IBM SPSS Modeler에 이제 Python 배포가 포함됩니다. 그러나 기본 IBM SPSS Modeler Python 배포에 포함되지 않은 특정 모듈이 필요한 경우에는

<Modeler\_installation\_directory>/python으로 이동하여 추가 패키지를 설치할 수 있습니다. Python 배포가 이제 IBM SPSS Modeler에 포함되었지만, 원하는 경우 다음 옵션을 options.cfg에 추가하여 이전 릴리스에서처럼 Python 설치를 가리킬 수 있습니다.

```
# Set to the full path to the python executable
(including the executable name) to enable use of PySpark.
eas_pyspark_python_path, ""
```

Windows 예제:

```
eas_pyspark_python_path, "C:\wwYour_Python_Install\wwpython.exe"
```

Linux 예제:

```
eas_pyspark_python_path, "/Your_Python_Install/bin/python"
```

 **참고:** 고유 Python 설치를 가리키는 경우 버전 3.7.x여야 합니다. IBM SPSS Modeler는 Anaconda 3 및 Python 3.7.6을 사용하여 테스트되었습니다.

## IBM SPSS Analytic Server 컨텍스트 개체

Python/Spark 컨텍스트에 대한 실행 스크립트는 Analytic Server 컨텍스트 개체에서 정의합니다. IBM SPSS Modeler Server에 대해 실행할 때, 컨텍스트 오브젝트는 IBM SPSS Modeler Server 설치와 함께 포함된 Analytic Server의 임베드된 버전용입니다. 컨텍스트 개체를 가져오려면 스크립트에 다음이 포함되어야 합니다.

```
import spss.pyspark.runtime
asContext = spss.pyspark.runtime.getContext()
```

Analytic Server 컨텍스트에서 Spark 컨텍스트와 SQL 컨텍스트를 가져올 수 있습니다.

```
sparkContext = asc.getSparkContext()
sqlContext = asc.getSparkSQLContext()
```

Spark 컨텍스트와 SQL 컨텍스트에 대한 자세한 내용은 Apache Spark 문서를 참조하십시오

## 데이터 액세스

데이터는 SQL DataFrame 형식으로 Python/Spark 스크립트와 실행 컨텍스트 간에 전송됩니다. 데이터를 사용하는 스크립트(즉, 소스 노드를 제외한 모든 노드)는 컨텍스트에서 데이터 프레임 을 검색해야 합니다.

```
inputData = asContext.getSparkInputData()
```

데이터를 생성하는 스크립트(즉, 터미널 노드를 제외한 모든 노드)는 데이터 프레임을 컨텍스트로 리턴해야 합니다.

```
asContext.setSparkOutputData(outputData)
```

SQL 컨텍스트를 사용하여 필요한 RDD에서 출력 데이터 프레임을 생성할 수 있습니다.

```
outputData = sqlContext.createDataFrame(rdd)
```

## 데이터 모델 정의

데이터를 생성하는 노드는 노드의 필드 표시 다운스트림을 설명하는 데이터 모델도 정의해야 합니다. Spark SQL 용어에서는 데이터 모델이 스키마입니다.

Python/Spark 스크립트는 `pyspark.sql.types.StructType` 개체의 형식으로 출력 데이터 모델을 정의합니다. `StructType`은 출력 데이터 프레임의 행을 설명하며, `StructField` 개체 목록에서 구성됩니다. 각 `StructField`는 출력 데이터 모델의 단일 필드를 설명합니다.

입력 데이터에 대한 데이터 모델은 입력 데이터 프레임의 `:schema` 속성을 사용하여 가져올 수 있습니다.

```
inputSchema = inputData.schema
```

변경되지 않은 정보를 통해 전달되는 필드는 입력 데이터 모델에서 출력 데이터 모델로 복사할 수 있습니다. 출력 데이터 모델에서 새로 추가되거나 수정된 필드는 `StructField` 생성자를 사용하여 작성할 수 있습니다.

```
field = StructField(name, dataType, nullable=True, metadata=None)
```

생성자에 대한 자세한 내용은 Spark 문서를 참조하십시오.

최소한 필드 이름과 데이터 유형은 제공해야 합니다. 선택적으로, 메타데이터를 지정하여 필드에 대한 속도, 역할 및 설명을 제공할 수 있습니다(데이터 메타데이터 참조).

## DataModelOnly 모드

IBM SPSS Modeler는 노드가 실행되기 전에 출력 데이터 모델을 알고 있어야 다운스트림 편집이 가능합니다. Python/Spark 노드에 대한 출력 데이터 모델을 가져오려면 IBM SPSS Modeler는 사용 가능한 데이터가 없는 특수한 "데이터 모델 전용" 모드에서 스크립트를 실행합니다. 스크립트는 Analytic Server 컨텍스트 개체에서 `isComputeDataModelOnly` 메소드를 사용하여 이 모드를 식별할 수 있습니다.

변환 노드에 대한 스크립트는 이 일반 패턴을 따를 수 있습니다.

```
if asContext.isComputeDataModelOnly():
    inputSchema = asContext.getSparkInputSchema()
    outputSchema = ... # construct the output data model
    asContext.setSparkOutputSchema(outputSchema)
else:
    inputData = asContext.getSparkInputData()
    outputData = ... # construct the output data frame
    asContext.setSparkOutputData(outputData)
```

## 모델 작성

모델을 작성하는 노드는 모델을 적용하는 노드가 이를 나중에 정확하게 다시 작성할 수 있도록 모델을 충분히 설명하는 일부 콘텐츠를 실행 컨텍스트에 리턴해야 합니다.

모델 콘텐츠는 키/값 쌍의 관점에서 정의됩니다. 이 경우 키와 값의 의미를 작성 노드와 스코어 노드에서만 알 수 있고 Modeler에서 어떤 방법으로도 이 의미를 해석하지 않습니다. Modeler가 모델 너깅에서 사용자에게 알려진 유형을 갖는 값만 표시할 수 있도록 선택적으로 노드가 MIME 유형을 값에 지정할 수 있습니다.

이 컨텍스트의 값은 PMML, HTML, 이미지 등일 수 있습니다. 모델 콘텐츠에 값을 추가하려는 경우(작성 스크립트):

```
asContext.setModelContentFromString(key, value, mimeType=None)
```

모델 콘텐츠에서 값을 검색하려는 경우(스코어 스크립트):

```
value = asContext.getModelContentToString(key)
```

모델 또는 모델의 일부가 파일 시스템의 파일 또는 폴더에 저장된 바로 가기로, 해당 위치에 저장된 모든 콘텐츠를 하나의 호출로 번들링할 수 있습니다(작성 스크립트).

```
asContext.setModelContentFromPath(key, path)
```

이 경우 번들에 다양한 콘텐츠 유형이 포함되어 있으므로 MIME 유형을 지정하는 옵션이 없습니다.

모델 작성 중에 콘텐츠를 저장할 임시 위치가 필요한 경우 컨텍스트에서 적합한 위치를 가져올 수 있습니다.

```
path = asContext.createTemporaryFolder()
```

파일 시스템의 임시 위치로 기존 콘텐츠를 검색하려는 경우(스코어 스크립트):

```
path = asContext.getModelContentToPath(key)
```

## 오류 처리

오류가 발생하게 하려면 스크립트에서 예외 처리(throw)를 하여 예외를 IBM SPSS Modeler 사용자에게 표시하십시오. 일부 예외는 `spss.pyspark.exceptions` 모듈에 정의되어 있습니다. 예:

```
from spss.pyspark.exceptions import ASContextException
if ... some error condition ...:
    raise ASContextException("message to display to user")
```

### ① Analytic Server 컨텍스트

해당 컨텍스트는 IBM® SPSS® Analytic Server와 상호작용하기 위해 Analytic Server 컨텍스트 인터페이스에 대한 지원을 제공합니다.

### AnalyticServerContext 개체

AnalyticServerContext 개체는 IBM SPSS Analytic Server와 상호작용하기 위한 여러 가지 인터페이스를 제공하는 컨텍스트 환경을 설정합니다. 이 컨텍스트 인스턴스를 구성하고자 하는 애플리케이션은 인터페이스를 직접 구현하는 대신 `spss.pyspark.runtime.getContext()` 인터페이스를 사용하여 이러한 환경을 설정합니다.

Pyspark python SparkContext 인스턴스를 리턴합니다.

```
cxt.getSparkContext() : SparkContext
```

Pyspark python SQLContext 인스턴스를 리턴합니다.

```
cxt.getSparkSQLContext() : SQLContext
```

출력 데이터 모델을 계산하기 위해서만 실행할지의 여부를 설명하려면 True를 리턴합니다. 그렇지 않은 경우 False를 리턴합니다.

```
cxt.isComputeDataModelOnly() : Boolean
```

스크립트가 Spark 환경에서 실행 중인 경우 True를 리턴합니다. 현재는 항상 True를 리턴합니다.

```
cxt.isSparkExecution() : Boolean
```

업스트림 임시 파일에서 입력 데이터를 로드하고 `pyspark.sql.DataFrame` 인스턴스를 생성합니다.

```
cxt.getSparkInputData() : DataFrame
```

입력 데이터 모델에서 생성된 `pyspark.sql.StructType` 인스턴스를 리턴합니다. 입력 데이터 모델이 없을 경우 `None`을 리턴합니다.

```
cxt.getSparkInputSchema() : StructType
```

출력 데이터 프레임을 Analytic Server 컨텍스트로 직렬화하고 컨텍스트를 리턴합니다.

```
cxt.setSparkOutputData( outDF ) : AnalyticServerContext
```

매개변수:

- outDF (DataFrame) : 출력 데이터 프레임 값

예외:

- DataOutputNotSupported: 이 인터페이스가 `pyspark:buildmodel` 함수에서 호출된 경우
- ASContextException : 출력 데이터 프레임이 `None`인 경우
- InconsistentOutputDataModel : 두 개체에 공통인 필드 이름과 저장 유형 정보가 일치하지 않습니다.

outSchema StructType 인스턴스를 데이터 모델로 변환하여 Analytic Server 컨텍스트로 직렬화한 후 컨텍스트를 리턴합니다.

```
cxt.setSparkOutputSchema(outSchema) : AnalyticServerContext
```

매개변수:

- outSchema(StructType) : 출력 StructType 개체

예외:

- ASContextException : 출력 스키마 인스턴스가 `None`인 경우
- InconsistentOutputDataModel : 두 개체에 공통인 필드 이름과 저장 유형 정보가 일치하지 않습니다.

모델 작성 출력의 위치를 Analytic Server 컨텍스트에 저장하고 컨텍스트를 리턴합니다.

```
cxt.setModelContentFromPath(key, path, mimetype=None) : AnalyticServerContext
```

경로는 디렉토리 경로여야 합니다. 이 경로는 디렉토리 아래에 있는 모든 항목이 모델 콘텐츠로 패키징될 때 `cxt.createTemporaryFolder()` API를 사용하여 생성해야 합니다.

매개변수 :

- key (string) : 키 문자열 값
- path (string) : 모델 작성 출력 문자열 경로의 위치
- mimetype (string, optional) : 콘텐츠의 MIME 유형

예외:

- ModelOutputNotSupported : 이 API를 pyspark:buildmodel 함수에서 호출하지 않는 경우
- KeyError : 키 속성이 None이거나 문자열이 비어 있는 경우

모델 작성 콘텐츠, 메타데이터 또는 기타 속성을 Analytic Server 컨텍스트에 저장하고 컨텍스트를 리턴합니다.

```
cxt.setModelContentFromString(key, value, mimetype=None) : AnalyticServerContext
```

매개변수 :

- key (string) : 키 문자열 값
- value (string) : 모델 메타데이터 문자열 값
- mimetype (string, optional) : 콘텐츠의 MIME 유형

예외:

- ModelOutputNotSupported : 이 API를 pyspark:buildmodel 함수에서 호출하지 않는 경우
- KeyError : 키 속성이 None이거나 문자열이 비어 있는 경우

Analytic Server에서 관리하는 임시 폴더 위치를 리턴하며, 모델 콘텐츠를 저장하는 데 사용할 수 있습니다.

```
cxt.createTemporaryFolder() : string
```

예외:

- ModelOutputNotSupported : 이 API를 pyspark:buildmodel 함수에서 호출하지 않는 경우

입력 키와 일치하는 모델의 위치를 리턴합니다.

```
cxt.getModelContentToPath(key) : string
```

매개변수:

- key (string) : 키 문자열 값

예외:

- ModelInputNotSupported : 이 API를 pyspark:applymodel 함수에서 호출하지 않는 경우
- KeyError : 키 속성이 None이거나 문자열이 비어 있는 경우
- IncompatibleModelContentType: 모델 콘텐츠 유형이 컨테이너가 아닌 경우

모델 콘텐츠, 모델의 메타데이터 또는 입력 키와 일치하는 기타 모델 속성을 리턴합니다.

```
cxt.getModelContentToString(key) : string
```

매개변수:

- key (string) : 키 문자열 값

예외:

- ModelInputNotSupported : 이 API를 pyspark:applymodel 함수에서 호출하지 않는 경우
- KeyError : 키 속성이 None이거나, 문자열이 비어 있거나, 키가 없는 경우
- IncompatibleModelContentType: 모델 콘텐츠 유형이 일치하지 않는 경우

입력 키에 지정된 MIME 유형을 리턴합니다. 지정된 콘텐츠에 MIME 유형이 없는 경우 None을 리턴합니다.

```
cxt.getModelContentType(key) : string
```

매개변수:

- key (string) : 키 문자열 값

예외:

- ModelInputNotSupported : 이 API를 pyspark:applymodel 함수에서 호출하지 않는 경우
- KeyError : 키 속성이 None이거나 문자열이 비어 있는 경우

## ② 데이터 메타데이터

이 절에서는 pyspark.sql.StructField를 기반으로 데이터 모델 속성을 설정하는 방법에 대해 설명합니다.

### spss.datamodel.Role 개체

이 클래스는 데이터 모델의 각 필드에 대해 유효한 역할을 열거합니다.

BOTH: 이 필드가 전향 또는 후향임을 나타냅니다.

FREQWEIGHT: 이 필드가 빈도 가중치로 사용됨을 나타내며, 사용자에게 표시되지는 않습니다.

INPUT: 이 필드가 예측변수 또는 전향임을 나타냅니다.

NONE: 이 필드가 모델링 중 직접 사용되지 않음을 나타냅니다.

TARGET: 이 필드가 예측 또는 후향임을 나타냅니다.

PARTITION: 이 필드가 데이터 파티션을 식별하는 데 사용됨을 나타냅니다.

RECORDID: 이 필드가 레코드 ID를 식별하는 데 사용됨을 나타냅니다.

SPLIT: 이 필드가 데이터 분할에 사용됨을 나타냅니다.

### **spss.datamodel.Measure 개체**

이 클래스는 데이터 모델의 필드에 대한 측정 수준을 열거합니다.

UNKNOWN: 측도 유형이 알 수 없음임을 나타냅니다.

CONTINUOUS: 측도 유형이 연속임을 나타냅니다.

NOMINAL: 측도 유형이 명목임을 나타냅니다.

FLAG: 필드 값이 두 값 중 하나임을 나타냅니다.

DISCRETE: 필드 값이 값 컬렉션으로 해석되어야 함을 나타냅니다.

ORDINAL: 측도 유형이 순서임을 나타냅니다.

TYPELESS: 필드가 저장 공간과 호환되는 값을 가질 수 있음을 나타냅니다.

### **pyspark.sql.StructField 개체**

StructType의 필드를 나타냅니다. StructField 개체는 다음 4개의 필드로 구성됩니다.

- name (string): StructField의 이름
- dataType (pyspark.sql.DataType): 특정 데이터 유형
- nullable (bool): StructField 값에 None 값이 포함될 수 있는지 여부입니다.
- metadata (dictionary): 옵션 속성을 저장하는 데 사용되는 Python 사전입니다.

메타데이터 사전 인스턴스를 사용하여 특정 필드에 대한 측도, 역할 또는 레이블 속성을 사용할 수 있습니다. 이러한 속성의 키워드는 다음과 같습니다.

- measure: measure 속성의 키워드
- role: role 속성의 키워드
- displayLabel: label 속성의 키워드

예:

```
from spss.datamodel.Role import Role
from spss.datamodel.Measure import Measure
_metadata = {}
_metadata['measure'] = Measure.TYPELESS
_metadata['role'] = Role.NONE
_metadata['displayLabel'] = "field label description"
StructField("userName", StringType(), nullable=False,
metadata=_metadata)
```

### ③ 날짜, 시간, 시간소인

날짜, 시간 또는 시간소인 유형 데이터를 사용하는 작업의 경우 1970-01-01:00:00:00(협정 세계시(UTC) 사용) 값을 기준으로 값이 실제 값으로 변환됩니다.

날짜의 경우 값은 1970-01-01 값(협정 세계시(UTC) 사용)을 기준으로 일 수를 나타냅니다.

시간의 경우 값은 24시간의 초 수를 나타냅니다.

시간소인의 경우 1970-01-01:00:00:00 값(협정 세계시(UTC) 사용)을 기준으로 초 수를 나타냅니다.

### ④ 예외

이 절에서는 가능한 예외 인스턴스에 대해 설명합니다.

#### **MetadataException 개체**

Python 예외의 서브클래스입니다.

이 예외는 메타데이터 개체 작동 중 오류가 발생할 경우에 발생합니다.

#### **UnsupportedOperationException 개체**

Python 예외의 서브클래스입니다.

이 예외는 특정 작업이 실행을 허용하지 않을 경우에 발생합니다.

## InconsistentOutputDataModel 개체

Python 예외의 서브클래스입니다.

이 예외는 `setSparkOutputSchema` 및 `setSparkOutputData`가 호출되었지만, 두 개체에 공통인 필드 이름과 저장 유형 정보가 일치하지 않을 경우에 발생합니다.

## IncompatibleModelContentType 개체

Python 예외의 서브클래스입니다.

이 예외는 다음과 같은 상황에서 발생합니다.

- `setModelContentFormString`을 사용하여 모델을 설정하지만 `getModelContentToPath`를 사용하여 값을 가져옵니다.
- `setModelContentFormPath`을 사용하여 모델을 설정하지만 `getModelContentToString`를 사용하여 값을 가져옵니다.

## DataOutputNotSupported 개체

Python 예외의 서브클래스입니다.

이 예외는 `pyspark:buildmodel` 함수에서 처리하는 실행의 `setSparkOutputData`에서 발생합니다.

## ModelInputNotSupported 개체

Python 예외의 서브클래스입니다.

이 예외는 스크립트가 `pyspark:applymodel` 함수에서 `getModelContentPathByKey` 및 `getModelContentToString` API를 호출하지 않을 경우에만 발생합니다.

## ModelOutputNotSupported 개체

Python 예외의 서브클래스입니다.

이 예외는 스크립트가 `pyspark:buildmodel` 함수에서 `setModelContentFromPath` 및 `setModelContentFromString` API를 호출하지 않을 경우에만 발생합니다.

## ASContextException 개체

Python 예외의 서브클래스입니다.

이 예외는 예기치 않은 런타임 예외가 발생할 경우에 발생합니다.

### ⑤ 예제

이 절에는 Python for Spark 스크립트 예가 포함되어 있습니다.

## 데이터 처리를 위한 기본 스크립팅 예

```
import spss.pyspark.runtime
from pyspark.sql.types import *

cxt = spss.pyspark.runtime.getContext()

if cxt.isComputeDataModelOnly():
    _schema = cxt.getSparkInputSchema()
    cxt.setSparkOutputSchema(_schema)
else:
    _structType = cxt.getSparkInputSchema()
    df = cxt.getSparkInputData()
    _newDF = df.sample(False, 0.01, 1)
    cxt.setSparkOutputData(_newDF)
```

## LinearRegressionWithSGD 알고리즘을 사용하는 모델 작성 스크립트 예

```
from pyspark.context import SparkContext
from pyspark.sql.context import SQLContext
from pyspark.sql import Row
from pyspark.mllib.regression import
LabeledPoint, LinearRegressionWithSGD, LinearRegressionModel
from pyspark.mllib.linalg import DenseVector
import numpy
import json

import spss.pyspark.runtime
from spss.pyspark.exceptions import ASContextException

ascontext = spss.pyspark.runtime.getContext()
sc = ascontext.getSparkContext()
df = ascontext.getSparkInputData()

# field settings amd algorithm parameters
target = '%%target_field%%'
```

```

predictors = [%%predictor_fields%%]
num_iterations=%%num_iterations%%
prediction_field = "$LR-" + target

# save linear regression model to a filesystem path

def save(model, sc, path):
    data =
sc.parallelize([json.dumps({"intercept":model.intercept,"weights":model.weights.tolist()})])
    data.saveAsTextFile(path)

# print model details to stdout

def dump(model,predictors):
    print(prediction_field+" = " + str(model.intercept))
    weights = model.weights.tolist()
    for i in range(0,len(predictors)):
        print("%t+ "+predictors[i]+"*"+ str(weights[i]))

# check that required fields exist in the input data

input_field_names = [ty[0] for ty in df.dtypes[:]]
if target not in input_field_names:
    raise ASContextException("target field "+target+" not found") for predictor in predictors:
        if predictor not in input_field_names:
            raise ASContextException("predictor field "+predictor+" not found")

# define map function to convert from dataframe Row objects to mllib LabeledPoint

def row2LabeledPoint(target,predictors,row):
    pvals = []
    for predictor in predictors:
        pval = getattr(row,predictor)
        pvals.append(float(pval))
    tval = getattr(row,target)
    return LabeledPoint(float(tval),DenseVector(pvals))

# convert dataframe to an RDD containing LabeledPoint

training_points = df.rdd.map(lambda row:
row2LabeledPoint(target,predictors,row))

# build the model

model = LinearRegressionWithSGD.train(training_points,num_iterations,intercept=True)

# write a text description of the model to stdout

dump(model,predictors)

# save the model to the filesystem and store into the output model content

modelpath = ascontext.createTemporaryFolder()
save(model,sc,modelpath)
ascontext.setModelContentFromPath("model",modelpath)

```

## LinearRegressionWithSGD 알고리즘을 사용하는 모델 스코어링 스크립트 예

```
from pyspark.context import SparkContext
from pyspark.sql.context import SQLContext
from pyspark.sql import Row
from pyspark.mllib.regression import
LabeledPoint, LinearRegressionWithSGD, LinearRegressionModel
from pyspark.mllib.linalg import DenseVector
import numpy
import json

import spss.pyspark.runtime
from spss.pyspark.exceptions import ASContextException

ascontext = spss.pyspark.runtime.getContext()
sc = ascontext.getSparkContext()
df = ascontext.getSparkInputData()

# field settings amd algorithm parameters

target = '%%target_field%%'
predictors = [%%predictor_fields%%]
num_iterations=%%num_iterations%%
prediction_field = "$LR-" + target

# save linear regression model to a filesystem path

def save(model, sc, path):
    data =
sc.parallelize([json.dumps({"intercept":model.intercept,"weights":model.weights.tolist()})])
    data.saveAsTextFile(path)

# print model details to stdout

def dump(model,predictors):
    print(prediction_field+" = " + str(model.intercept))
    weights = model.weights.tolist()
    for i in range(0,len(predictors)):
        print("\wt+ "+predictors[i]+"*"+ str(weights[i]))

# check that required fields exist in the input data

input_field_names = [ty[0] for ty in df.dtypes[:]]
if target not in input_field_names:
    raise ASContextException("target field "+target+" not found") for predictor in
predictors:
    if predictor not in input_field_names:
        raise ASContextException("predictor field "+predictor+" not found")

# define map function to convert from dataframe Row objects to mllib LabeledPoint

def row2LabeledPoint(target,predictors,row):
    pvals = []
    for predictor in predictors:
```

```

        pval = getattr(row,predictor)
        pvals.append(float(pval))
    tval = getattr(row,target)
    return LabeledPoint(float(tval),DenseVector(pvals))

# convert dataframe to an RDD containing LabeledPoint

training_points = df.rdd.map(lambda row:
row2LabeledPoint(target,predictors,row))

# build the model

model = LinearRegressionWithSGD.train(training_points,num_iterations,intercept=True)

# write a text description of the model to stdout

dump(model,predictors)

# save the model to the filesystem and store into the output model content

modelpath = ascontext.createTemporaryFolder()
save(model,sc,modelpath)
ascontext.setModelContentFromPath("model",modelpath)

```

### 3) 확장 노드

IBM® SPSS® Modeler 및 데이터 마이닝 기능을 보완하기 위해 전문적인 사용자가 확장 노드를 사용하여 자신의 R 스크립트 또는 Python for Spark 스크립트를 입력하고 데이터 처리, 모델 작성 및 모델 스코어링을 수행할 수 있습니다.

#### (1) 확장 내보내기 노드

확장 내보내기 노드를 사용하면 R 또는 Python for Spark 스크립트를 실행하여 데이터를 내보낼 수 있습니다.

##### ① 확장 내보내기 노드 - 명령문 탭

구문 유형(R 또는 Python for Spark)을 선택하십시오. 자세한 정보는 다음 섹션을 참조하십시오. 명령문이 준비되면 실행을 클릭하여 확장 내보내기 노드를 실행할 수 있습니다.

## R 구문

**R 구문.** 데이터 분석을 위해 R 스크립트 구문을 이 필드에 입력, 붙여넣기 또는 사용자 정의할 수 있습니다.

**플래그 필드 변환.** 플래그 필드를 처리하는 방법을 지정합니다. 문자열에서 요인으로, 정수 및 실수에서 double로 및 논리 값(True, False)이라는 두 가지 옵션이 있습니다. 논리 값(True, False)을 선택하면 플래그 필드의 원래 값이 손실됩니다. 예를 들어, 필드에 남성 및 여성 값이 있는 경우, 해당 값이 True 및 False로 변경됩니다.

**결측값을 R '사용할 수 없음' 값(NA)으로 변환.** 선택하면 모든 결측값이 R NA 값으로 변환됩니다. NA 값은 결측값을 식별하기 위해 R에서 사용됩니다. 사용하는 일부 R 함수에는 데이터에 NA가 포함된 경우에 함수가 작동하는 방식을 제어하는 데 사용되는 인수가 있습니다. 예를 들어, 함수에서 NA를 포함하는 레코드를 자동으로 제외하도록 선택할 수 있습니다. 이 옵션을 선택하지 않으면 모든 결측값이 변경되지 않은 상태로 R에 전달되고 R 스크립트가 실행될 때 오류가 발생할 수 있습니다.

**날짜/시간 필드를 시간대의 특수 제어가 있는 R 클래스로 변환.** 이 옵션을 선택하면 날짜 또는 날짜/시간 형식의 변수가 R 날짜/시간 개체로 변환됩니다. 다음 옵션 중 하나를 선택해야 합니다.

- R POSIXct. 날짜 또는 날짜/시간 형식의 변수가 R POSIXct 개체로 변환됩니다.
- R POSIXlt (목록). 날짜 또는 날짜/시간 형식의 변수가 R POSIXlt 개체로 변환됩니다.

 **참고:** POSIX 형식은 고급 옵션입니다. R 스크립트에서 날짜/시간 필드가 해당 형식이 필요한 방식으로 처리되도록 지정된 경우에만 이 옵션을 사용하십시오. POSIX 형식은 시간 형식이 있는 변수에 적용되지 않습니다.

## Python 구문(S)

**Python 구문.** 이 필드에 데이터 분석을 위한 Python 스크립팅 구문을 입력하거나 붙여넣거나 사용자 정의할 수 있습니다. Python for Spark에 대한 자세한 정보는 Python for Spark 및 Python for Spark로 스크립팅의 내용을 참조하십시오.

### ② 확장 내보내기 노드 - 콘솔 출력 탭

**콘솔 출력 탭**에는 명령문 탭에서 R 스크립트 또는 Python for Spark 스크립트가 실행될 때 수신된 모든 출력이 포함됩니다. 예를 들어, R 스크립트를 사용하는 경우, 명령문 탭의 R 명령문 필드의 R 스크립트가 실행될 때 R 콘솔에서 수신된 출력을 표시합니다. 이 출력에는 R 또는 Python 스크립트가 실행될 때 생성되는 R 또는 Python 오류 메시지 또는 경고가 포함됩니다.

출력은 주로 스크립트를 디버그하는 데 사용될 수 있습니다. 콘솔 출력 탭에는 R 명령문 또는 Python 명령문 필드의 스크립트도 포함됩니다.

확장 내보내기 스크립트가 실행될 때마다 R 콘솔 또는 Python for Spark에서 수신된 출력이 콘솔 출력 탭의 내용을 덮어씁니다. 출력은 편집할 수 없습니다.

### ③ 스트림 출판

스트림 출판은 데이터베이스, 플랫폼 파일, Statistics 내보내기, 확장 내보내기, 데이터 컬렉션 내보내기, SAS 내보내기, Excel 및 XML 내보내기 노드 등의 표준 내보내기 노드를 사용하여 IBM® SPSS® Modeler에서 직접 수행됩니다. 내보내기 노드의 유형에 따라 출판된 스트림이 IBM SPSS Modeler Solution Publisher Runtime 또는 외부 애플리케이션을 사용하여 실행될 때마다 기록될 결과의 형식이 결정됩니다. 예를 들어, 출판된 스트림이 실행될 때마다 결과를 데이터베이스에 기록하려면 데이터베이스 내보내기 노드를 사용하십시오.

## 스트림 출판

1. 일반 방식으로 스트림을 열거나 작성하고 내보내기 노드를 끝에 첨부하십시오.
2. 내보내기 노드의 출판 탭에서, 출판된 파일의 루트 이름(즉, .pim, .par, .xml 등의 다양한 확장자를 붙여쓸 파일 이름)을 지정하십시오.
3. 스트림을 출판하려면 출판을 클릭하고, 노드가 실행될 때마다 스트림을 출판하려면 스트림 출판을 선택하십시오.

**출판된 이름** - 출판된 이미지 및 모수 파일에 대한 루트 이름을 지정하십시오.

- **이미지 파일(\*.pim)**은 Runtime이 내보내기 당시와 똑같이 출판된 스트림을 실행하는 데 필요한 모든 정보를 제공합니다. 스트림의 설정(예: 입력 데이터 소스 또는 출력 데이터 파일)을 변경하지 않아도 된다면 이미지 파일만 배포할 수 있습니다.
- **모수 파일(\*.par)**에는 데이터 소스, 출력 파일 및 실행 옵션에 대한 구성 가능 정보가 포함되어 있습니다. 스트림을 다시 출판하지 않고도 스트림의 입력 또는 출력을 제어할 수 있으려면 이미지 파일뿐 아니라 모수 파일도 필요합니다.
- **메타데이터 파일(\*.xml)**은 이미지 및 해당 데이터 모델의 입력 및 출력을 설명합니다. 이 파일은 런타임 라이브러리를 임베드하고 입력 및 출력 데이터의 구조를 알아야 하는 애플리케이션에서 사용하도록 설계되었습니다.

 **참고:** 이 파일은 메타데이터 출판 옵션을 선택한 경우에만 생성됩니다.

**모수 출판** - 필요한 경우, 스트림 모수를 \*.par 파일에 포함시킬 수 있습니다. \*.par 파일을 편집하거나 런타임 API를 통해, 이미지를 실행할 때 이러한 스트림 모수값을 변경할 수 있습니다.

이 옵션을 선택하면 모수 단추가 활성화됩니다. 이 단추를 클릭하면 모수 출판 대화 상자가 표시됩니다.

출판 열에서 관련 옵션을 선택하여, 출판된 이미지에 포함될 모수를 선택하십시오.

**스트림 실행 시** - 노드가 실행될 때 스트림이 자동으로 출판되는지 여부를 지정합니다.

- **데이터 내보내기** - 스트림을 출판하지 않고 표준 방식으로 내보내기 노드를 실행합니다. (기본적으로 이 노드는 IBM SPSS Modeler Solution Publisher를 사용할 수 없는 경우와 동일한 방식으로 IBM SPSS Modeler에서 실행됩니다.) 이 옵션을 선택하면 내보내기 노드 대화 상자에서 출판을 클릭하여 명시적으로 출판하지 않는 한 스트림이 출판되지 않습니다. 또는 도구 모음의 출판 도구를 사용하거나 스크립트를 사용하여 현재 스트림을 출판할 수도 있습니다.
- **스트림 출판** - IBM SPSS Modeler Solution Publisher를 사용하여 배포할 스트림을 출판합니다. 스트림이 실행될 때마다 스트림을 자동으로 출판하려면 이 옵션을 선택하십시오.

**참고:**

- 출판된 스트림을 새 데이터 또는 업데이트된 데이터로 실행할 계획인 경우, 입력 파일의 필드 순서는 출판된 스트림에 지정된 소스 노드 입력 파일의 필드 순서와 동일해야 합니다.
- 외부 애플리케이션에 출판할 때는 관계없는 필드를 필터링하거나 입력 요구사항에 맞게 필드 이름을 변경할 것을 고려하십시오. 두 작업 모두, 내보내기 노드 전에 필터 노드를 사용하여 수행할 수 있습니다.

## (2) 확장 출력 노드

확장 출력 노드 대화 상자의 출력 탭에서 화면에 출력을 선택하면 화면 출력이 출력 브라우저 창에 표시됩니다. 또한 출력이 출력 관리자에 추가됩니다. 출력 브라우저 창에는 출력을 인쇄 또는 저장하거나 다른 형식으로 내보낼 수 있는 메뉴 세트가 있습니다. 편집 메뉴에는 복사 옵션만 있습니다. 확장 출력 노드의 출력 브라우저에는 두 개의 탭, 즉, 텍스트 출력을 표시하는 텍스트 출력 탭과 그래프 및 차트를 표시하는 그래프 출력 탭이 있습니다.

확장 출력 노드 대화 상자의 출력 탭에서 파일에 출력을 선택하면 확장 출력 노드가 성공적으로 실행될 때 출력 브라우저 창이 표시되지 않습니다.

### ① 확장 출력 노드 - 구문 탭

구문 유형(R 또는 Python for Spark)을 선택하십시오. 자세한 정보는 다음 섹션을 참조하십시오. 구문이 준비되면 실행을 클릭하여 확장 출력 노드를 실행할 수 있습니다. 출력 개체가 출력 관리자에 추가되거나 선택적으로 출력 탭의 파일 이름 필드에서 지정된 파일에 추가됩니다.

## R 구문

R 구문. 데이터 분석을 위해 R 스크립트 구문을 이 필드에 입력, 붙여넣기 또는 사용자 정의할 수 있습니다.

**플래그 필드 변환.** 플래그 필드를 처리하는 방법을 지정합니다. 문자열에서 요인으로, 정수 및 실수에서 double로 및 논리 값(True, False)이라는 두 가지 옵션이 있습니다. 논리 값(True, False)을 선택하면 플래그 필드의 원래 값이 손실됩니다. 예를 들어, 필드에 남성 및 여성 값이 있는 경우, 해당 값이 True 및 False로 변경됩니다.

**결측값을 R '사용할 수 없음' 값(NA)으로 변환.** 선택하면 모든 결측값이 R NA 값으로 변환됩니다. NA 값은 결측값을 식별하기 위해 R에서 사용됩니다. 사용하는 일부 R 함수에는 데이터에 NA가 포함된 경우에 함수가 작동하는 방식을 제어하는 데 사용되는 인수가 있습니다. 예를 들어, 함수에서 NA를 포함하는 레코드를 자동으로 제외하도록 선택할 수 있습니다. 이 옵션을 선택하지 않으면 모든 결측값이 변경되지 않은 상태로 R에 전달되고 R 스크립트가 실행될 때 오류가 발생할 수 있습니다.

**날짜/시간 필드를 시간대의 특수 제어가 있는 R 클래스로 변환.** 이 옵션을 선택하면 날짜 또는 날짜/시간 형식의 변수가 R 날짜/시간 개체로 변환됩니다. 다음 옵션 중 하나를 선택해야 합니다.

- R POSIXct. 날짜 또는 날짜/시간 형식의 변수가 R POSIXct 개체로 변환됩니다.
- R POSIXlt (목록). 날짜 또는 날짜/시간 형식의 변수가 R POSIXlt 개체로 변환됩니다.

 **참고:** POSIX 형식은 고급 옵션입니다. R 스크립트에서 날짜/시간 필드가 해당 형식이 필요한 방식으로 처리되도록 지정된 경우에만 이 옵션을 사용하십시오. POSIX 형식은 시간 형식이 있는 변수에 적용되지 않습니다.

## Python 구문(S)

Python 구문. 이 필드에 데이터 분석을 위한 Python 스크립팅 구문을 입력하거나 붙여넣거나 사용자 정의할 수 있습니다. Python for Spark에 대한 자세한 정보는 Python for Spark 및 Python for Spark로 스크립팅의 내용을 참조하십시오.

### ② 확장 출력 노드 - 콘솔 출력 탭

콘솔 출력 탭에는 명령문 탭에서 R 스크립트 또는 Python for Spark 스크립트가 실행될 때 수신된 모든 출력이 포함됩니다. 예를 들어, R 스크립트를 사용하는 경우, 명령문 탭의 R 명령문 필드의 R 스크립트가 실행될 때 R 콘솔에서 수신된 출력을 표시합니다. 이 출력에는 R 또는 Python 스크립트가 실행될 때 생성되는 R 또는 Python 오류 메시지 또는 경고가 포함됩니다. 출력은 주로 스크립트를 디버그하는 데 사용될 수 있습니다. 콘솔 출력 탭에는 R 명령문 또는 Python 명령문 필드의 스크립트도 포함됩니다.

확장 출력 스크립트가 실행될 때마다 R 콘솔 또는 Python for Spark에서 수신된 출력이 **콘솔 출력** 탭의 내용을 덮어씁니다. 출력은 편집할 수 없습니다.

### ③ 확장 출력 노드 - 출력 탭

**출력 이름.** 노드가 실행될 때 생성되는 출력의 이름을 지정합니다. **자동**을 선택하면 출력의 이름이 스크립트 유형에 따라 자동으로 "R Output" 또는 "Python Output"으로 설정됩니다. 선택적으로 **사용자 정의**를 선택하여 다른 이름을 지정할 수 있습니다.

**화면으로 출력.** 새 창에서 출력을 생성하고 표시하려면 이 옵션을 선택하십시오. 또한 출력이 출력 관리자에 추가됩니다.

**파일로 출력.** 출력을 파일에 저장하려면 이 옵션을 선택하십시오. 이 옵션을 선택하면 **출력 그래프** 및 **출력 파일** 단일 선택 단추를 사용할 수 있습니다.

**그래프 출력.** **파일로 출력**이 선택된 경우에만 사용 가능합니다. 확장 출력 노드를 실행하여 발생한 모든 그래프를 파일에 저장하려면 이 옵션을 선택하십시오. 생성된 출력에 대해 사용할 파일 이름을 **파일 이름** 필드에서 지정하십시오. 생략 기호(...)를 클릭하여 특정 파일 및 위치를 선택하십시오. **파일 유형** 드롭 다운 목록에서 파일 유형을 지정하십시오. 다음 파일 유형이 사용 가능합니다.

- 출력 오브젝트(.cou)
- HTML(.html)

**출력 텍스트.** **파일로 출력**이 선택된 경우에만 사용 가능합니다. 확장 출력 노드를 실행하여 발생한 모든 텍스트 출력을 파일에 저장하려면 이 옵션을 선택하십시오. 생성된 출력에 대해 사용할 파일 이름을 **파일 이름** 필드에서 지정하십시오. 생략 기호(...)를 클릭하여 특정 파일 및 위치를 지정하십시오. **파일 유형** 드롭 다운 목록에서 파일 유형을 지정하십시오. 다음 파일 유형이 사용 가능합니다.

- HTML(.html)
- 출력 오브젝트(.cou)
- 텍스트 문서(.txt)

### ④ 확장 출력 브라우저

확장 출력 노드 대화 상자의 **출력** 탭에서 **화면에 출력**을 선택하면 화면 출력이 출력 브라우저 창에 표시됩니다. 또한 출력이 출력 관리자에 추가됩니다. 출력 브라우저 창에는 출력을 인쇄 또는 저장하거나 다른 형식으로 내보낼 수 있는 메뉴 세트가 있습니다. **편집** 메뉴에는 **복사** 옵션만 있습니다. 확장 출력 노드의 출력 브라우저에는 두 개의 탭이 있습니다.

- 텍스트 출력 탭은 텍스트 출력을 표시합니다.
- 그래프 출력 탭은 그래프 및 도표를 표시합니다.

화면에 출력 대신 확장 출력 노드 대화 상자의 출력 탭에서 **파일에 출력**을 선택하면 확장 출력 노드가 성공적으로 실행될 때 출력 브라우저 창이 표시되지 않습니다.

#### 가. 확장 출력 브라우저 - 텍스트 출력 탭

텍스트 출력 탭에는 확장 출력 노드의 명령문 탭에 있는 R 스크립트 또는 Python for Spark 스크립트를 실행할 때 생성되는 모든 텍스트 출력이 표시됩니다.

**참고:** 확장 출력 스크립트를 실행하여 그 결과로 발생하는 R 또는 Python for Spark 오류 메시지 또는 경고 또한 항상 확장 출력 노드의 **콘솔 출력** 탭에 표시됩니다.

#### 나. 확장 출력 브라우저 - 그래프 출력 탭

그래프 출력 탭에는 확장 출력 노드의 명령문 탭에 있는 R 스크립트 또는 Python for Spark 스크립트를 실행할 때 생성되는 모든 그래프 또는 차트가 표시됩니다. 예를 들어, R 스크립트에 R plot 함수에 대한 호출이 포함된 경우, 결과 그래프가 이 탭에 표시됩니다.

### (3) 확장 모델 노드

확장 모델 노드를 사용하면 R 또는 Python for Spark 스크립트를 실행하여 모델을 작성하고 스코어링할 수 있습니다.

#### ① 확장 모델 노드 - 명령문 탭

명령문의 유형(R 또는 Python for Spark)을 선택하십시오. 다음 필드 중 하나에 사용자 정의 스크립트 명령문을 입력하거나 붙여넣으십시오. 명령문이 준비되면 **실행**을 클릭하여 확장 모델 노드를 실행할 수 있습니다.

#### R 명령문

**R 모델 작성 명령문.** 모델 작성에 필요한 사용자 정의 R 스크립팅 명령문을 이 필드에 입력하거나 붙여넣을 수 있습니다.

**R 모델 스코어링 구문.** 모델 스코어링에 필요한 사용자 정의 R 스크립팅 명령문을 이 필드에 입력하거나 붙여넣을 수 있습니다.

## Python for Spark 명령문

**Python 모델 작성 명령문.** 모델 작성에 필요한 사용자 정의 Python 스크립팅 명령문을 이 필드에 입력하거나 붙여넣을 수 있습니다.

**Python 모델 스코어링 명령문.** 모델 스코어링에 필요한 사용자 정의 Python 스크립팅 명령문을 이 필드에 입력하거나 붙여넣을 수 있습니다.

Python for Spark에 대한 자세한 정보는 Python for Spark 및 Python for Spark를 사용한 스크립팅의 내용을 참조하십시오.

### ② 확장 모델 노드 - 모델 옵션 탭

**모델 이름.** 목표나 ID 필드(또는 이러한 필드가 지정되지 않은 경우에는 모델 유형)를 기준으로 하여 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

### ③ 확장 모델 노드 - 콘솔 출력 탭

콘솔 출력 탭에는 명령문 탭에서 R 스크립트 또는 Python for Spark 스크립트가 실행될 때 수신된 모든 출력이 포함됩니다. 예를 들어, R 스크립트를 사용하는 경우, **명령문** 탭의 **R 명령문** 필드의 R 스크립트가 실행될 때 R 콘솔에서 수신된 출력을 표시합니다. 이 출력에는 R 또는 Python 스크립트가 실행될 때 생성되는 R 또는 Python 오류 메시지 또는 경고가 포함됩니다. 출력은 주로 스크립트를 디버그하는 데 사용될 수 있습니다. **콘솔 출력** 탭에는 **R 명령문** 또는 **Python 명령문** 필드의 스크립트도 포함됩니다.

확장 모델 스크립트가 실행될 때마다 R 콘솔 또는 Python for Spark에서 수신된 출력이 **콘솔 출력** 탭의 내용을 덮어씁니다. 출력은 편집할 수 없습니다.

### ④ 확장 모델 노드 - 텍스트 출력 탭

확장 모델 노드 대화 상자의 **모델 옵션** 탭에서 **R 텍스트 출력 표시** 선택란을 선택하여 요청한 경우, 확장 모델 노드에 텍스트 출력 탭이 있습니다. 이 탭은 텍스트 출력만 표시할 수 있습니다. R 모델 작성 스크립트를 실행하여 생성된 모든 텍스트 출력이 이 탭에 표시됩니다. 모델에 대해 먼저 다른 이름을 지정하지 않고 모델 작성 스크립트를 다시 실행하면 이전 실행의 **텍스트 출력** 탭 내용을 덮어씁니다. 텍스트 출력은 편집할 수 없습니다.

스크립트에 R sink 함수에 대한 호출이 포함된 경우, 이 함수 이후에 생성된 모든 출력은 지정된 파일에 저장되고 **텍스트 출력** 탭에 표시되지 않습니다.

 **참고:** 모델 작성 스크립트를 실행하여 그 결과로 발생하는 R 또는 Python for Spark 오류 메시지 또는 경고 또한 항상 확장 모델 노드의 **콘솔 출력** 탭에 표시됩니다.

#### (4) 확장 모델 너깃

확장 모델 노드를 실행한 후에 확장 모델 너깃이 생성되고 모델 팔레트에 배치됩니다. 여기에는 모델 작성 및 모델 스코어링을 정의하는 R 또는 Python for Spark 스크립트가 포함됩니다. 기본적으로 확장 모델 너깃에는 모델 스코어링에 사용되는 스크립트, 데이터 읽기에 필요한 옵션 및 R 콘솔 또는 Python for Spark의 모든 출력이 포함됩니다. 필요에 따라 확장 모델 너깃에 다양한 기타 형식의 모델 출력(그래프 및 텍스트 출력 등)이 포함될 수 있습니다. 확장 모델 너깃이 생성되어 스트림 캔버스에 추가된 후에 출력 노드가 이에 연결될 수 있습니다. 그런 다음 IBM® SPSS® Modeler 스트림에서 출력 노드가 데이터 및 모델에 대한 정보를 얻고 데이터를 다양한 형식으로 내보내기 위한 일반적인 방법으로 사용될 수 있습니다.

이 노드를 R과 함께 사용하려면 IBM SPSS Modeler - Essentials for R을 설치해야 합니다. *IBM SPSS Modeler - Essentials for R: 설치 지시사항*에서 설치 지시사항 및 호환성 정보를 참조하십시오. 또한 R의 호환 가능한 버전이 컴퓨터에 설치되어 있어야 합니다.

##### ① 확장 모델 너깃 - 명령문 탭

명령문 탭은 항상 확장 모델 너깃에 있습니다.

**R 모델 스코어링 구문.** R을 사용하는 경우, 모델 스코어링에 사용되는 R 스크립트가 이 필드에 표시됩니다. 기본적으로 이 필드는 사용 가능하도록 설정되거나 편집할 수는 없습니다. R 모델 스코어링 스크립트를 편집하려면 **편집**을 클릭하십시오.

**Python 모델 스코어링 명령문.** Python for Spark를 사용하는 경우, 모델 스코어링에 사용되는 Python 스크립트가 이 필드에 표시됩니다. 기본적으로 이 필드는 사용 가능하도록 설정되거나 편집할 수는 없습니다. Python 모델 스코어링 스크립트를 편집하려면 **편집**을 클릭하십시오.

**편집.** 스코어링 구문 필드를 편집 가능하도록 설정하려면 **편집**을 클릭하십시오. 그런 다음 스코어링 구문 필드에 입력하여 모델 스코어링 스크립트를 편집할 수 있습니다. 예를 들어, 확장 모델 너깃을 실행한 후에 모델 스코어링 스크립트에 오류가 있음을 식별한 경우, 모델 스코어링 스크립트를 편집해야 합니다. 확장 모델 노드를 실행하여 모델을 다시 생성하면 확장 모델 너깃에서 모델 스코어링 스크립트에 대해 수행한 모든 변경사항이 손실됩니다.

## ② 확장 모델 너깃 - 모델 옵션 탭

모델 옵션 탭은 항상 확장 모델 너깃에 있습니다.

**데이터 읽기 옵션.** 이러한 옵션은 Python for Spark이 아니라 R에만 적용됩니다. 이 옵션을 사용하면 날짜 또는 날짜/시간 형식의 결측값, 플래그 필드 및 변수를 처리하는 방법을 지정할 수 있습니다.

- **배치에서 데이터 읽기.** 많은 양의 데이터를 처리할 때(예를 들어, R 엔진의 메모리에 맞추기에 너무 큰 경우), 이 옵션을 사용하여 데이터를 개별적으로 전송하고 처리할 수 있는 배치로 나누십시오. 각 배치에 포함할 데이터 레코드의 최대 수를 지정하십시오.

확장 변환 노드 및 확장 스코어링 너깃의 경우, R 스크립트를 통해 배치 형식으로 데이터가 전달됩니다. 이러한 이유로 Hadoop 또는 데이터베이스 환경에서 실행되는 모델 스코어링 및 프로세스 노드에 대한 스크립트에는 정렬 또는 통합과 같이 데이터의 행 범위에 걸치거나 행을 조합하는 조작이 포함될 수 없습니다. 이 제한사항은 데이터가 Hadoop 환경 및 In-Database 마이닝 동안 분할될 수 있도록 하기 위해 적용됩니다. 모델 스코어링에 대한 스크립트가 SPSS® Modeler Server에서 실행되는 경우에는 이 제한사항이 적용되지 않습니다. 확장 출력 및 확장 모델 노드에는 이러한 제한사항이 적용되지 않습니다.

- **플래그 필드 변환.** 플래그 필드를 변환하는 방법을 지정합니다. **문자열에서 요인으로, 정수 및 실수에서 double로 및 논리 값(True, False)**이라는 두 가지 옵션이 있습니다. **논리 값(True, False)**을 선택하면 플래그 필드의 원래 값이 손실됩니다. 예를 들어, 필드에 남성 및 여성 값이 있는 경우, 해당 값이 True 및 False로 변경됩니다.

- **누락된 값을 R '사용할 수 없음' 값(NA)으로 변환.** 선택하면 모든 결측값이 R NA 값으로 변환됩니다. NA 값은 결측값을 식별하기 위해 R에서 사용됩니다. 사용하는 일부 R 함수에는 데이터에 NA가 포함된 경우에 함수가 작동하는 방식을 제어하는 데 사용되는 인수가 있습니다. 예를 들어, 함수에서 NA를 포함하는 레코드를 자동으로 제외하도록 선택할 수 있습니다. 이 옵션을 선택하지 않으면 모든 결측값이 변경되지 않은 상태로 R에 전달되고 R 스크립트가 실행될 때 오류가 발생할 수 있습니다.

- **날짜/시간 필드를 시간대의 특수 제어가 있는 R 클래스로 변환** 이 옵션을 선택하면 날짜 또는 날짜/시간 형식의 변수가 R 날짜/시간 형식으로 변환됩니다. 다음 옵션 중 하나를 선택해야 합니다.

- **R POSIXct.** 날짜 또는 날짜/시간 형식의 변수가 R POSIXct 개체로 변환됩니다.
- **R POSIXlt (목록).** 날짜 또는 날짜/시간 형식의 변수가 R POSIXlt 개체로 변환됩니다.

 **참고:** POSIX 형식은 고급 옵션입니다. R 스크립트에서 날짜/시간 필드가 해당 형식이 필요한 방식으로 처리되도록 지정된 경우에만 이 옵션을 사용하십시오. POSIX 형식은 시간 형식이 있는 변수에 적용되지 않습니다.

확장 모델 너깃이 데이터베이스에 대해 실행되는 경우에는 **플래그 필드 변환, 누락된 값을 R '사용할 수 없음' 값(NA)으로 변환 및 날짜/시간 필드를 시간대의 특수 제어가 있는 R 클래스로 변환** 제어에 대해 선택된 옵션이 인식되지 않습니다. 노드가 데이터베이스에 대해 실행되는 경우에는 이러한 제어에 대한 기본값이 대신 사용됩니다.

- 플래그 필드 변환이 문자열에서 요인으로, 정수 및 실수에서 double로 설정됩니다.
- 누락된 값을 R '사용할 수 없음' 값(NA)으로 변환이 선택됩니다.
- 날짜/시간 필드를 시간대의 특수 제어가 있는 R 클래스로 변환이 선택되지 않습니다.

### ③ 확장 모델 너깃 - 그래프 출력 탭

확장 모델 노드 대화 상자의 **모델 옵션** 탭에서 **HTML로 R 그래프 표시** 선택란을 선택하여 요청한 경우, 확장 모델 너깃에 **그래프 출력** 탭이 있습니다. 모델 작성 R 스크립트를 실행하여 발생하는 그래프가 이 탭에 표시될 수 있습니다. 예를 들어, R 스크립트에 R plot 함수에 대한 호출이 포함된 경우, 결과 그래프가 이 탭에 표시됩니다. 모델에 대해 먼저 다른 이름을 지정하지 않고 모델 작성 스크립트를 다시 실행하면 이전 실행의 **그래프 출력** 탭 내용을 덮어씁니다.

### ④ 확장 모델 너깃 - 텍스트 출력 탭

확장 모델 노드 대화 상자의 **모델 옵션** 탭에서 **R 텍스트 출력 표시** 선택란을 선택하여 요청한 경우, 확장 모델 너깃에 **텍스트 출력** 탭이 있습니다. 이 탭은 텍스트 출력만 표시할 수 있습니다. 확장 모델 스크립트를 실행하여 생성된 모든 텍스트 출력이 이 탭에 표시됩니다. 모델에 대해 먼저 다른 이름을 지정하지 않고 확장 모델 스크립트를 다시 실행하면 이전 실행의 **텍스트 출력** 탭 내용을 덮어씁니다. 텍스트 출력은 편집할 수 없습니다.

#### 참고:

- 스크립트에 R sink 함수에 대한 호출이 포함된 경우, 이 함수 이후에 생성된 모든 출력은 지정된 파일에 저장되고 **텍스트 출력** 탭에 표시되지 않습니다.
- 확장 모델 스크립트를 실행하여 그 결과로 발생하는 오류 메시지 또는 경고 또한 항상 확장 모델 노드의 **콘솔 출력** 탭에 표시됩니다.

### ⑤ 확장 모델 너깃 - 콘솔 출력 탭

**콘솔 출력** 탭은 항상 확장 모델 너깃에 있습니다. 여기에는 명령문 탭에서 R 스크립트 또는 Python for Spark 스크립트가 실행될 때 수신된 모든 출력이 포함됩니다. 예를 들어, R 스크립트를 사용하는 경우, 확장 모델 너깃의 **명령문** 탭의 **R 모델 스코어링 명령문** 필드의 R 스크립트가 실행될 때 R 콘솔에서 수신된 출력을 표시합니다. 이 출력에는 R 또는 Python 스크립트가 실행될 때 생성되는 모든 R 또는 Python 오류 메시지 또는 경고 및 R 콘솔의 모든 텍스트 출력이 포함됩니다. 출력은 주로 스크립트를 디버그하는 데 사용될 수 있습니다.

모델 스코어링 스크립트가 실행될 때마다 R 콘솔 또는 Python for Spark에서 수신된 출력이 **콘솔 출력** 탭의 내용을 덮어씁니다. 콘솔 출력은 편집할 수 없습니다.

## (5) 확장 변환 노드

확장 변환 노드를 사용하면 IBM® SPSS® Modeler 스트림에서 데이터를 가져와서 R 스크립팅 또는 Python for Spark 스크립팅을 사용하여 변환을 데이터에 적용할 수 있습니다. 데이터가 수정되면 추가 처리, 모델 작성 및 모델 스코어링을 위해 스트림에 리턴됩니다. 확장 변환 노드를 사용하면 R 또는 Python for Spark로 작성된 알고리즘을 사용하여 데이터를 변환할 수 있으며 사용자가 특정 문제점에 적합한 데이터 변환 방법을 개발할 수 있습니다.

이 노드를 R과 함께 사용하려면 IBM SPSS Modeler - Essentials for R을 설치해야 합니다. *IBM SPSS Modeler - Essentials for R: 설치 지시사항*에서 설치 지시사항 및 호환성 정보를 참조하십시오. 또한 R의 호환 가능한 버전이 컴퓨터에 설치되어 있어야 합니다.

### ① 확장 변환 노드 - 명령문 탭

구문 유형(R 또는 Python for Spark)을 선택하십시오. 자세한 정보는 다음 섹션을 참조하십시오. 명령문이 준비되면 **실행**을 클릭하여 확장 변환 노드를 실행할 수 있습니다.

## R 구문

**R 구문.** 데이터 분석을 위해 R 스크립트 구문을 이 필드에 입력, 붙여넣기 또는 사용자 정의할 수 있습니다.

**플래그 필드 변환.** 플래그 필드를 처리하는 방법을 지정합니다. **문자열에서 요인으로**, **정수 및 실수에서 double로** 및 **논리 값(True, False)**이라는 두 가지 옵션이 있습니다. **논리 값(True, False)**을 선택하면 플래그 필드의 원래 값이 손실됩니다. 예를 들어, 필드에 남성 및 여성 값이 있는 경우, 해당 값이 True 및 False로 변경됩니다.

**결측값을 R '사용할 수 없음' 값(NA)으로 변환.** 선택하면 모든 결측값이 R NA 값으로 변환됩니다. NA 값은 결측값을 식별하기 위해 R에서 사용됩니다. 사용하는 일부 R 함수에는 데이터에 NA가 포함된 경우에 함수가 작동하는 방식을 제어하는 데 사용되는 인수 있습니다. 예를 들어, 함수에서 NA를 포함하는 레코드를 자동으로 제외하도록 선택할 수 있습니다. 이 옵션을 선택하지 않으면 모든 결측값이 변경되지 않은 상태로 R에 전달되고 R 스크립트가 실행될 때 오류가 발생할 수 있습니다.

**날짜/시간 필드를 시간대의 특수 제어가 있는 R 클래스로 변환.** 이 옵션을 선택하면 날짜 또는 날짜/시간 형식의 변수가 R 날짜/시간 개체로 변환됩니다. 다음 옵션 중 하나를 선택해야 합니다.

- R POSIXct. 날짜 또는 날짜/시간 형식의 변수가 R POSIXct 개체로 변환됩니다.
- R POSIXlt (목록). 날짜 또는 날짜/시간 형식의 변수가 R POSIXlt 개체로 변환됩니다.

**참고:** POSIX 형식은 고급 옵션입니다. R 스크립트에서 날짜/시간 필드가 해당 형식이 필요한 방식으로 처리되도록 지정된 경우에만 이 옵션을 사용하십시오. POSIX 형식은 시간 형식이 있는 변수에 적용되지 않습니다.

## Python 구문(S)

**Python 구문.** 이 필드에 데이터 분석을 위한 Python 스크립팅 구문을 입력하거나 붙여넣거나 사용자 정의할 수 있습니다. Python for Spark에 대한 자세한 정보는 Python for Spark 및 Python for Spark로 스크립팅의 내용을 참조하십시오.

### ② 확장 변환 노드 - 콘솔 출력 탭

**콘솔 출력 탭**에는 명령문 탭에서 R 스크립트 또는 Python for Spark 스크립트가 실행될 때 수신된 모든 출력이 포함됩니다. 예를 들어, R 스크립트를 사용하는 경우, **명령문** 탭의 **R 명령문** 필드의 R 스크립트가 실행될 때 R 콘솔에서 수신된 출력을 표시합니다. 이 출력에는 R 또는 Python 스크립트가 실행될 때 생성되는 R 또는 Python 오류 메시지 또는 경고가 포함됩니다. 출력은 주로 스크립트를 디버그하는 데 사용될 수 있습니다. **콘솔 출력** 탭에는 **R 명령문** 또는 **Python 명령문** 필드의 스크립트도 포함됩니다.

확장 변환 스크립트가 실행될 때마다 R 콘솔 또는 Python for Spark에서 수신된 출력이 **콘솔 출력** 탭의 내용을 덮어씁니다. 출력은 편집할 수 없습니다.

## (6) 확장 가져오기 노드

확장 가져오기 노드를 사용하면 R 또는 Python for Spark 스크립트를 실행하여 데이터를 가져올 수 있습니다.

### ① 확장 가져오기 노드 - 명령문 탭

구문 유형(R 또는 **Python for Spark**)을 선택하십시오. 데이터를 가져오기 위한 사용자 정의 스크립트를 입력하거나 붙여넣으십시오. 명령문이 준비되면 **실행**을 클릭하여 확장 가져오기 노드를 실행할 수 있습니다.

## ② 확장 가져오기 노드 - 콘솔 출력 탭

콘솔 출력 탭에는 명령문 탭에서 R 스크립트 또는 Python for Spark 스크립트가 실행될 때 수신된 모든 출력이 포함됩니다. 예를 들어, R 스크립트를 사용하는 경우, 명령문 탭의 R 명령문 필드의 R 스크립트가 실행될 때 R 콘솔에서 수신된 출력을 표시합니다. 이 출력에는 R 또는 Python 스크립트가 실행될 때 생성되는 R 또는 Python 오류 메시지 또는 경고가 포함됩니다. 출력은 주로 스크립트를 디버그하는 데 사용될 수 있습니다. 콘솔 출력 탭에는 R 명령문 또는 Python 명령문 필드의 스크립트도 포함됩니다.

확장 가져오기 스크립트가 실행될 때마다 R 콘솔 또는 Python for Spark에서 수신된 출력이 콘솔 출력 탭의 내용을 덮어씁니다. 출력은 편집할 수 없습니다.

## ③ 필드 필터링 또는 이름 바꾸기

스트림의 어느 지점에서나 필드의 이름을 바꾸고 필드를 제외할 수 있습니다. 예를 들어, 의학 연구자로서 환자(레코드 수준 데이터)의 칼럼 수준(필드 수준 데이터)에 대해 관심이 없을 수 있으므로 K(칼럼) 필드를 필터링할 수 있습니다. 이는 소스 또는 출력 노드의 필터 탭을 사용하거나 별도의 필터 노드를 사용하여 수행할 수 있습니다. 액세스되는 노드에 관계없이 기능은 동일합니다.

- 가변파일, 고정 파일, Statistics 파일, XML 또는 확장 가져오기 등의 소스 노드에서 데이터를 IBM® SPSS® Modeler로 읽어올 때 필드의 이름을 바꾸거나 필드를 필터링할 수 있습니다.
- 필터 노드를 사용하면 스트림의 어느 지점에서나 필드의 이름을 바꾸거나 필드를 필터링할 수 있습니다.
- Statistics 내보내기, Statistics 변환, Statistics 모델 및 Statistics 출력 노드에서 IBM SPSS Statistics 이름 지정 표준을 준수하도록 필드를 필터링하거나 필드의 이름을 바꿀 수 있습니다.
- 위 노드의 필터 탭을 사용하여 다중 응답 세트를 정의하거나 편집할 수 있습니다. 자세한 정보는 다중 응답 세트 편집 주제를 참조하십시오.
- 최종적으로 필터 노드를 사용하여 한 소스 노드에서 다른 소스 노드로 필드를 맵핑할 수 있습니다.

## ④ 유형에 대한 정보 보기 및 설정

다양한 소스 노드 및 유형 노드에서 IBM® SPSS® Modeler의 모델링 및 기타 작업에 대해 유용한 필드 메타데이터 및 특성을 지정할 수 있습니다. 이러한 특성에는 다음이 포함됩니다.

- 데이터 세트 내의 각 필드에 대해 범위, 변수군, 정렬된 변수군 또는 플래그 등의 사용 유형을 지정합니다.

- 결측값 및 시스템 널값을 처리하기 위한 옵션을 설정합니다.
- 모델링 목적으로 필드 역할을 설정합니다.
- 데이터 세트에서 자동으로 값을 읽기 위해 사용되는 옵션 및 필드에 대한 값을 지정합니다.
- 필드 및 값 레이블을 지정합니다.

아래 목록에서 사용자의 상황에 맞는 도움말을 선택하십시오.

## 2. 확장

확장은 IBM® SPSS® Modeler의 기능을 확장하는 사용자 정의 구성요소입니다. 확장은 확장 번들(.mpe 파일)에 패키징되고 IBM SPSS Modeler에 설치됩니다. 확장은 임의의 사용자에게 의해 작성되고 연관된 확장 번들을 공유하여 기타 사용자와 공유될 수 있습니다.

다음은 확장과 함께 사용할 수 있도록 제공되는 유틸리티입니다.

- 확장 허브(확장 > 확장 허브에서 액세스)는 GitHub의 IBM SPSS Predictive Analytics 컬렉션에서 확장을 검색, 다운로드 및 설치하기 위한 인터페이스입니다. 확장 허브 대화 상자에서 컴퓨터에 설치된 확장의 세부사항을 보고 설치된 확장의 업데이트를 얻고 확장을 제거할 수 있습니다.
- 확장 > 로컬 확장 번들 설치에서 로컬 컴퓨터에 저장된 확장 번들을 설치할 수 있습니다.
- 확장에 대한 사용자 정의 대화 상자 작성기를 사용하여 사용자 인터페이스(사용자 정의 노드 대화 상자라고 함)를 포함하는 확장을 작성할 수 있습니다. 사용자 정의 노드 대화 상자는 확장과 연관된 태스크를 수행하는 R 스크립트 또는 Python for Spark 스크립트(를) 생성합니다. 사용자 정의 대화 상자 설계의 일부로 생성된 스크립트 설계를 수행합니다.

### 1) 확장 허브

확장 허브 대화 상자에서 다음을 수행할 수 있습니다.

- GitHub의 IBM® SPSS® Predictive Analytics 컬렉션에서 사용 가능한 확장을 탐색합니다. 확장을 선택하여 지금 설치하거나 선택된 확장을 다운로드하여 나중에 설치할 수 있습니다.
- 사용자의 컴퓨터에 이미 설치된 확장의 업데이트 버전을 얻을 수 있습니다.
- 사용자의 컴퓨터에 이미 설치된 확장에 대한 세부사항을 볼 수 있습니다.
- 사용자의 컴퓨터에 설치된 확장을 제거할 수 있습니다.

확장을 다운로드하거나 제거하려면 다음을 수행하십시오.

1. 메뉴에서 **확장 > 확장 허브**를 선택하십시오.

2. 다운로드하거나 제거할 확장을 선택하고 **확인**을 클릭하십시오. 사용자가 **확인**을 클릭하면 탐색에 대해 수행된 모든 선택 및 설치된 탭이 처리됩니다.

기본적으로 다운로드하도록 선택한 확장이 사용자의 컴퓨터에 다운로드되고 설치됩니다. 설정 탭에서 선택된 확장을 설치하지 않고 지정된 위치에 다운로드하도록 선택할 수 있습니다. 그런 다음 **확장 > 로컬 확장 번들 설치**를 클릭하여 나중에 설치할 수 있습니다. Windows의 경우 확장 번들 파일을 두 번 클릭하여 확장을 설치할 수 있습니다.

❖ **중요사항:**

- Windows 7 이상의 경우, 기존 확장 번들의 업데이트 버전을 설치하면 관리자 권한을 사용하여 IBM SPSS Modeler를 실행해야 할 수 있습니다. 마우스 오른쪽 단추로 IBM SPSS Modeler에 대한 아이콘을 클릭하고 **관리자로 실행**을 선택하여 관리자 권한으로 IBM SPSS Modeler를 시작할 수 있습니다. 특히 하나 이상의 확장 번들을 설치할 수 없음을 명시하는 오류 메시지를 수신한 경우, 관리자 권한으로 실행해 보십시오.
- 프록시를 통해 인터넷에 연결하는 경우, **확장 > 확장 허브** 메뉴 옵션을 통해 확장 허브를 열려고 시도할 때 "인터넷 연결이 발견되지 않아 일부 기능을 사용할 수 없음"과 같은 오류를 수신할 수 있습니다. 이 문제를 해결하려면, jvm.cfg 파일(SPSS Modeler 설치 위치의 config 디렉토리에 있음)의 # JVM 옵션에 다음 매개변수를 추가해야 합니다. 파일을 저장한 후 SPSS Modeler를 다시 시작하십시오.

```
options, "-DproxyHost=proxyIP"  
options, "-DproxyPort=proxyPort"
```

🔗 **참고:** 설치된 탭의 확장에 대한 자세한 정보...를 클릭하면 나중에 언제든지 확장을 설치할 때 동의한 라이선스를 볼 수 있습니다.

## (1) 탐색 탭 (확장 허브)

탐색 탭에는 GitHub의 IBM® SPSS® Predictive Analytics 컬렉션 (<https://ibmpredictiveanalytics.github.io/>)에서 사용 가능한 모든 확장이 표시됩니다. 탐색 탭에서 다운로드 및 설치할 새 확장을 선택할 수 있으며 컴퓨터에 이미 설치된 확장에 대한 업데이트를 선택할 수 있습니다. 탐색 탭을 사용하려면 인터넷이 연결되어 있어야 합니다.

- 확장마다 최신 버전의 번호와 해당 버전의 연관된 날짜가 표시됩니다. 확장에 대한 간단한 요약도 제공됩니다. 컴퓨터에 이미 설치된 확장에 대해서는 설치된 버전 번호도 표시됩니다.
- **자세한 정보**를 클릭하여 확장에 대한 세부사항 정보를 볼 수 있습니다. 업데이트가 사용 가능하면 **자세한 정보**에 업데이트에 대한 정보가 표시됩니다.
- **필수조건**을 클릭하면 확장 실행에 필요한 필수조건(예: IBM SPSS Modeler - Integration Plug-in for R이 필수인지 여부 등)을 볼 수 있습니다. 업데이트가 사용 가능하면 **필수조건**에 업데이트에 대한 정보가 표시됩니다.

## 세분화 기준

표시되는 확장 세트를 세분화할 수 있습니다. 확장의 일반 범주, 확장이 구현된 언어, 확장을 제공한 조직의 유형 또는 확장 상태로 세분화할 수 있습니다. 범주 등의 각 그룹에 대해 표시되는 확장 목록을 세분화하는 다중 항목을 선택할 수 있습니다. 또한 검색어로 세분화할 수 있습니다. 검색은 대소문자를 구분하지 않으며 별표(\*)는 기타 문자로 처리되고 와일드카드 검색을 표시하지 않습니다.

- 표시되는 확장 목록을 세분화하려면 **적용**을 클릭하십시오. 커서가 **검색** 선택란에 있을 때 Enter 키를 누르는 것은 **적용**을 클릭하는 것과 같은 효과가 있습니다.
- 사용 가능한 모든 확장을 표시하도록 목록을 재설정하려면 **검색** 선택란에서 모든 텍스트를 삭제하고 **적용**을 클릭하십시오.

### ① 플러그인 통합 방법

IBM® SPSS® Modeler - Integration Plug-in for R을 가져오는 방법:

[https://github.com/IBMPredictiveAnalytics/R\\_Essentials\\_Modeler/releases/](https://github.com/IBMPredictiveAnalytics/R_Essentials_Modeler/releases/) 또는 IBM SPSS Statistics 커뮤니티(<https://www.ibm.com/products/spss-statistics/support>)에서 사용 가능한 IBM SPSS Modeler - Essentials for R을 설치하십시오. IBM SPSS Modeler - Essentials for R에는 IBM SPSS Modeler - Integration Plug-in for R가 포함됩니다. Essentials for R에는 R 프로그래밍 언어는 포함되지 않습니다. IBM SPSS Modeler - Essentials for R을 설치하기 전에 아직 설치되지 않았으면 R 버전 4.0을 설치해야 합니다. 해당 제품은 <https://cran.r-project.org/> 에서 사용 가능합니다. R 4.0.x을(를) 다운로드하여 설치하는 것이 좋습니다.

① **참고:** 인터넷 액세스가 없는 컴퓨터에 Essentials for R을 설치하는 경우에 Essentials for R과 함께 포함된 R 스크립트를 사용할 계획인 경우, 해당 스크립트에 필요한 모든 R 패키지를 획득해야 하며 이를 수동으로 R에 설치해야 합니다. 특정 R 스크립트에 필요한 R 패키지를 판별하려면 확장 허브 대화 상자를 열고(**확장 > 확장 허브**), **설치됨** 탭을 클릭한 다음 원하는 확장에 대한 **자세한 정보**를 클릭하십시오. 필수 R 패키지가 확장 세부 사항 대화 상자에 나열됩니다. R 패키지는 <http://www.r-project.org/>에서 액세스하는 R CRAN 미러 사이트에서 얻을 수 있습니다. 사용 중인 R 버전과 일치하는 패키지 버전을 확보해야 합니다. 버전별 패키지는 CRAN 미러 사이트의 "기여 패키지" 페이지에 있는 링크에서 사용할 수 있습니다.

## (2) 설치된 탭 (확장 허브)

설치된 탭에는 사용하는 컴퓨터에 설치된 모든 확장이 표시됩니다. 설치된 탭에서 (GitHub 허브의 IBM® SPSS® Predictive Analytics 컬렉션에서 사용 가능한) 설치된 확장의 업데이트를 선택하거나 확장을 제거할 수 있습니다. 설치된 확장에 대한 업데이트를 얻으려면 인터넷이 연결되어 있어야 합니다.

- 각 확장에 대해 설치된 버전 번호가 표시됩니다. 인터넷 연결이 사용 가능하면 최신 버전의 번호와 해당 버전의 연관된 날짜가 표시됩니다. 확장에 대한 간단한 요약도 제공됩니다.
- **자세한 정보**를 클릭하여 확장에 대한 세부사항 정보를 볼 수 있습니다. 업데이트가 사용 가능하면 **자세한 정보**에 업데이트에 대한 정보가 표시됩니다.
- **필수조건**을 클릭하면 확장 실행에 필요한 필수조건(예: IBM SPSS Modeler - Integration Plug-in for R이 필수인지 여부 등)을 볼 수 있습니다. 업데이트가 사용 가능하면 **필수조건**에 업데이트에 대한 정보가 표시됩니다.

## 세분화 기준

표시되는 확장 세트를 세분화할 수 있습니다. 확장의 일반 범주, 확장이 구현된 언어, 확장을 제공한 조직의 유형 또는 확장 상태로 세분화할 수 있습니다. 범주 등의 각 그룹에 대해 표시되는 확장 목록을 세분화하는 다중 항목을 선택할 수 있습니다. 또한 검색어로 세분화할 수 있습니다. 검색은 대소문자를 구분하지 않으며 별표(\*)는 기타 문자로 처리되고 와일드카드 검색을 표시하지 않습니다.

- 표시되는 확장 목록을 세분화하려면 **적용**을 클릭하십시오. 커서가 **검색** 선택란에 있을 때 Enter 키를 누르는 것은 **적용**을 클릭하는 것과 같은 효과가 있습니다.
- 사용 가능한 모든 확장을 표시하도록 목록을 재설정하려면 **검색** 선택란에서 모든 텍스트를 삭제하고 **적용**을 클릭하십시오.

## 개인용 확장

개인용 확장은 사용자의 컴퓨터에 설치되어 있지만 GitHub의 IBM SPSS Predictive Analytics 컬렉션에는 없는 확장입니다. 표시되는 확장 세트를 세분화하거나 확장을 실행하기 위한 필수 소프트웨어를 확인하는 기능은 개인용 확장에서 사용할 수 없습니다.

 **참고:** 인터넷 연결 없이 확장 허브를 사용할 경우 설치된 탭의 일부 기능을 사용할 수 없습니다.

### (3) 설정(확장 허브)

설정 탭은 다운로드하도록 선택된 확장이 다운로드되고 설치되는지 또는 다운로드되거나 설치되는 않는지를 지정합니다. 이 설정은 새 확장 및 기존 확장에 대한 업데이트에 적용됩니다. 조직의 다른 사용자에게 분배하려고 확장을 다운로드하는 경우에는 확장을 설치하지 않고 다운로드하도록 선택할 수 있습니다. 또한 확장을 실행하는 데 필요한 필수조건이 없으나 필수조건을 확보할 계획인 경우, 확장을 다운로드하나 설치하지 않도록 선택할 수 있습니다.

확장을 설치하지 않고 다운로드하도록 선택하는 경우, 나중에 **확장 > 로컬 확장 번들 설치**를 선택하여 설치할 수 있습니다. Windows의 경우 확장 번들 파일을 두 번 클릭하여 확장을 설치할 수 있습니다.

### (4) 확장 세부사항

확장 세부사항 대화 상자는 확장의 작성자가 제공한 정보를 표시합니다. 필수 정보(예: 요약) 및 버전 외에 작성자는 관련된 위치(예: 작성자의 홈 페이지)에 대한 URL을 포함할 수 있습니다. 확장 허브에서 확장을 다운로드한 경우에는 **라이선스 보기**를 클릭하면 볼 수 있는 라이선스가 포함되어 있습니다.

**사용자 정의 노드.** 사용자 정의 노드 테이블에는 확장에 포함된 사용자 정의 노드 대화 상자가 나열됩니다.

 **참고:** 사용자 정의 노드 대화 상자가 있는 확장을 설치하는 경우 사용자 정의 노드 테이블에서 노드 대화 상자의 항목을 보려면 IBM® SPSS® Modeler의 재시작이 필요할 수 있습니다.

**종속성.** 종속성 그룹은 확장에 포함된 구성요소를 실행하는 데 필요한 추가 기능을 나열합니다.

- **R의 통합 플러그인.** 확장의 구성요소에서 Integration Plug-in for R.
- **R 패키지.** 확장에 필요한 모든 R 패키지를 나열합니다. 자세한 정보는 필수 R 패키지 주제를 참조하십시오.

설치된 확장에 대한 세부사항에 액세스하는 방법

1. 메뉴에서 다음을 선택하십시오.  
**확장 > 확장 허브**
2. 확장 허브 대화 상자의 **설치됨** 탭을 클릭하십시오.
3. 원하는 확장에 대한 **자세한 정보**를 클릭하십시오.

## 2) 로컬 확장 번들 설치

로컬 컴퓨터에 저장된 확장 번들을 설치하려면 다음을 수행하십시오.

1. 메뉴에서 다음을 선택하십시오.  
**확장 > 로컬 확장 번들 설치...**
2. 확장 번들을 선택하십시오. 확장 번들은 mpe의 파일 유형을 가집니다.

❖ **중요사항:** Windows 7 및 이후 버전의 Windows 사용자인 경우, 기존 확장 번들의 업데이트된 버전을 설치하려면 관리자 권한을 사용하여 IBM® SPSS® Modeler를 실행해야 하는 경우도 있습니다. 마우스 오른쪽 단추로 IBM SPSS Modeler에 대한 아이콘을 클릭하고 **관리자로 실행**을 선택하여 관리자 권한으로 IBM SPSS Modeler를 시작할 수 있습니다. 특히 하나 이상의 확장 번들을 설치할 수 없음을 명시하는 오류 메시지를 수신한 경우, 관리자 권한으로 실행해 보십시오.

### (1) 확장의 설치 위치

기본적으로 확장은 운영 체제의 일반 사용자 쓰기 가능 위치에 설치됩니다.

IBM\_SPSS\_MODELER\_EXTENSIONS\_PATH 환경 변수로 경로를 정의하여 기본 위치를 대체할 수 있습니다.

지정된 위치가 대상 컴퓨터에 있어야 합니다. IBM\_SPSS\_MODELER\_EXTENSIONS\_PATH를 설정한 후 변경사항을 적용하려면 IBM® SPSS® Modeler를 다시 시작해야 합니다.

Windows에서 환경 변수를 작성하려면 제어판에서 다음을 수행합니다.

### Windows 7

1. 사용자 계정을 선택합니다.
2. **내 환경 변수 변경**을 선택합니다.
3. **새로 만들기**를 클릭하고 **변수 이름** 필드에 환경 변수의 이름(예: IBM\_SPSS\_MODELER\_EXTENSIONS\_PATH)을 입력한 다음 **변수값** 필드에 경로를 입력합니다

## Windows 8 이후

1. 시스템을 선택하십시오.
2. 고급 탭을 선택하고 **환경 변수**를 클릭하십시오. 고급 시스템 설정에서 고급 탭에 액세스할 수 있습니다.
3. 사용자 변수 섹션에서 **새로 만들기**를 클릭하고 **변수 이름** 필드에 환경 변수의 이름(예: IBM\_SPSS\_MODELER\_EXTENSIONS\_PATH)을 입력한 다음 변수값 필드에 경로를 입력합니다.

❖ **중요사항:** Windows 7 및 이후 버전의 Windows 사용자인 경우, 기존 확장 번들의 업데이트된 버전을 설치하려면 관리자 권한을 사용하여 IBM SPSS Modeler를 실행해야 하는 경우도 있습니다. 마우스 오른쪽 단추로 IBM SPSS Modeler에 대한 아이콘을 클릭하고 **관리자로 실행**을 선택하여 관리자 권한으로 IBM SPSS Modeler를 시작할 수 있습니다. 특히 하나 이상의 확장 번들을 설치할 수 없음을 명시하는 오류 메시지를 수신한 경우, 관리자 권한으로 실행해 보십시오.

### (2) 필수 R 패키지

인터넷에 연결되어 있지 않은 경우 사용자의 컴퓨터에 없는 특정 확장의 필수 R 패키지를 다른 사용자에게서 얻어야 합니다. 확장이 설치되면 확장 세부사항 대화 상자에서 필수 R 패키지 목록을 볼 수 있습니다. 자세한 정보는 확장 세부사항 주제를 참조하십시오.

<http://www.r-project.org/>에서 패키지를 다운로드하여 R 내에서 설치할 수 있습니다. 자세한 내용은 R과 함께 제공되는 *R 설치 및 관리* 설명서를 참조하십시오.

❗ **참고:** UNIX(Linux 포함) 사용자의 경우, 패키지가 소스 양식으로 다운로드된 다음 컴파일됩니다. 이 경우, 시스템에 적절한 도구가 설치되어 있어야 합니다. 세부사항은 R 설치 및 관리 안내서를 참조하십시오. 특히, Debian 사용자는 apt-get install r-base-dev에서 r-base-dev 패키지를 설치해야 합니다.

### 3) 사용자 정의 노드 작성 및 관리

확장에 대한 사용자 정의 대화 상자 작성기에서는 SPSS® Modeler스트림 내에서 사용할 노드를 작성합니다.

확장에 대한 사용자 정의 대화 상자 작성기를 사용하면 다음을 수행할 수 있습니다.

- R에서 또는 Apache Spark에서(Python을 통해) 구현된 노드를 실행하기 위한 사용자 정의 노드 대화 상자를 작성하십시오. 자세한 정보는 스크립트 템플릿 작성의 내용을 참조하십시오.

- 사용자 정의 노드 대화상자--또 다른 사용자에게 의해 작성되었을 수 있음--에 대한 지정 사항을 포함하는 파일을 열고 IBM® SPSS Modeler의 설치에 대해 대화 상자를 추가하십시오. 필요에 따라 수정할 수 있습니다.
- 다른 사용자가 이를 자신의 IBM SPSS Modeler 설치에 추가할 수 있도록 사용자 정의 노드 대화 상자에 대한 지정 사항을 저장하십시오.
- 사용자 정의 노드를 작성하고 Python for Spark 스크립트를 작성하여 데이터 소스가 있는 임의의 위치에서 데이터를 읽고 Apache Spark가 지원하는 임의의 데이터 형식으로 데이터를 쓸 수 있습니다. 자세한 정보는 Python for Spark를 사용하여 데이터 가져오기 및 내보내기의 내용을 참조하십시오.
- 사용자 정의 노드를 작성하고 R 스크립트를 작성하여 데이터 소스가 있는 임의의 위치에서 데이터를 읽고 R이 지원하는 임의의 데이터 형식으로 데이터를 쓸 수 있습니다. 자세한 정보는 R을 사용하여 데이터 가져오기 및 내보내기의 내용을 참조하십시오.

확장에 대한 사용자 정의 대화 상자 작성기에서는 확장 내의 사용자 정의 노드 대화 상자를 작성 또는 수정합니다. 확장에 대한 사용자 정의 대화 상자 작성기를 열면 비어 있는 사용자 정의 노드 대화 상자가 포함된 새로운 확장이 작성됩니다. 확장에 대한 사용자 정의 대화 상자 작성기에서 사용자 정의 노드 대화 상자를 저장 또는 설치하면 이 대화 상자가 확장의 일부로 저장 또는 설치됩니다.

**참고:**

- 표준 IBM SPSS Modeler 노드에 대한 노드 대화 상자의 사용자 자체 버전을 작성할 수 없습니다.
- 스크립트는 사용자 정의 대화 상자 작성기를 사용하여 작성되는 노드(사용자 정의 대화 상자 작성기 R 노드 및 사용자 정의 대화 상자 작성기 Python 노드 포함)에 대해 지원되지 않습니다.

## 확장에 대한 사용자 정의 대화 상자 작성기 시작 방법

메뉴에서 **확장 > 사용자 정의 노드 대화 상자 작성기**를 선택하십시오.

**참고:**

- Python 노드는 Spark 환경에 따라 다릅니다.
- 데이터가 Spark DataFrame 양식으로 표시되므로 Python 스크립트는 Spark API를 사용해야 합니다.
- 버전 17.1에서 작성된 이전 노드는 IBM SPSS Analytic Server에 대해서만 여전히 실행됩니다(해당 데이터는 IBM SPSS Analytic Server 소스 노드에서 가져오고 IBM SPSS Modeler로 추출되지는 않음). 버전 18.0 이상에서 작성된 새로운 Python 및 사용자 정의 대화 상자 작성기 노드는 IBM SPSS Modeler Server에 대해 실행될 수 있습니다.

- Python을 설치할 때 모든 사용자가 Python 설치에 액세스할 수 있는 권한이 있는지 확인하십시오.
- MLlib(Machine Learning Library)를 사용하려면 NumPy를 포함하는 Python 버전을 설치해야 합니다. 그런 다음 Python 설치를 사용하도록 IBM SPSS Modeler Server (또는 IBM SPSS Modeler Client의 로컬 서버)를 구성해야 합니다. 자세한 내용은 Python for Spark를 사용한 스크립팅의 내용을 참조하십시오.

## (1) 사용자 정의 대화 상자 작성기 레이아웃

### 대화 상자 캔버스

대화 상자 캔버스는 사용자가 노드 대화 상자의 레이아웃을 계획할 수 있는 사용자 정의 대화 상자 작성기의 영역입니다.

### 특성 분할창

특성 분할창은 사용자가 노드 유형 등의 대화 상자 자체의 특성뿐만 아니라 노드 대화 상자를 구성하는 제어의 특성도 지정하는 사용자 정의 대화 상자 작성기의 영역입니다.

### 도구 팔레트

도구 팔레트는 사용자 정의 노드 대화 상자에 추가할 수 있는 일련의 제어를 제공합니다. **보기** 메뉴에서 도구 팔레트를 선택하여 도구 팔레트를 표시하거나 숨길 수 있습니다.

### 스크립트 템플릿

스크립트 템플릿은 사용자 정의 노드 대화 상자에서 생성하는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다. **새 창으로 이동**을 클릭하여 스크립트 템플릿 분할창을 별도의 창으로 이동할 수 있습니다. 별도의 스크립트 템플릿 창을 다시 사용자 정의 대화 상자 작성기로 이동하려면 **기본 창으로 복원**을 클릭하십시오.

## (2) 사용자 정의 노드 대화 상자 작성

사용자 정의 노드 대화 상자 작성과 연관된 기본 단계는 다음과 같습니다.

1. 노드 대화 상자가 실행될 때 표시되는 제목 및 IBM® SPSS® Modeler 팔레트 내의 새 노드의 위치와 같이 노드 대화 상자 자체의 특성을 지정합니다. 자세한 정보는 대화 상자 특성 주제를 참조하십시오.
2. 노드 대화 상자 및 모든 하위 대화 상자를 구성하는 제어(필드 선택기 및 선택란 등)를 지정합니다. 자세한 정보는 제어 유형 주제를 참조하십시오.
3. 노드 대화 상자에서 생성하는 R 코드 또는 Python for Spark 코드를 지정하는 스크립트 템플릿을 작성하십시오. 자세한 정보는 스크립트 템플릿 작성 주제를 참조하십시오.
4. 노드 대화 상자가 포함된 확장의 특성을 지정하십시오. 자세한 정보는 확장 특성 주제를 참조하십시오.
5. 노드 대화 상자를 포함하는 확장을 IBM SPSS Modeler에 설치하거나 확장을 확장 번들(.mpe) 파일에 저장하십시오. 자세한 정보는 사용자 정의 노드 대화 상자 관리 주제를 참조하십시오.

노드 대화 상자를 작성할 때 미리 볼 수 있습니다. 자세한 정보는 사용자 정의 노드 대화 상자 미리보기 주제를 참조하십시오.

## (3) 대화 상자 특성

사용자 정의 대화 상자 작성기 창은 노드 대화 상자 및 선택된 사용자 인터페이스 제어에 대한 특성을 표시합니다. 대화 상자 특성을 보고 설정하려면 제어를 벗어난 영역에 있는 캔버스를 클릭하십시오. 제어가 없는 캔버스에서는 대화 상자 특성이 항상 표시되어 있습니다.

**대화 상자 이름.** 대화 상자 이름 특성이 필요하며 노드 대화 상자과 연관된 고유 이름을 지정합니다. 이름 충돌 가능성을 최소화하기 위해 이름에 사용자의 조직에 대한 식별자를 붙일 수 있습니다(예: URL).

**제목.** 제목 특성은 노드 대화 상자의 제목 표시줄에 표시되는 텍스트를 지정합니다.

**도움말 파일.** 도움말 파일 특성은 선택적이며 노드 대화 상자에 대한 도움말 파일의 경로를 지정합니다. 도움말 파일은 사용자가 대화 상자의 **도움말** 단추를 클릭하면 시작되는 파일입니다. 도움말 파일은 HTML 형식이어야 합니다. 노드 대화 상자가 설치 또는 저장되면 지정된 도움말 파일의 사본이 노드 대화 상자의 스펙에 포함됩니다. 연관된 도움말 파일이 없는 경우 런타임 대화 상자의 도움말 단추가 숨겨져 있습니다.

- 도움말 파일과 동일한 디렉토리에 있는 도움말 파일의 현지화된 버전은 도움말 파일을 추가할 때 자동으로 노드 대화 상자에 추가됩니다. 도움말 파일의 현지화된 버전은 <Help File>\_<language identifier>.htm으로 명명됩니다. 자세한 정보는 사용자 정의 노드 대화 상자의 현지화된 버전 생성 주제를 참조하십시오.

- 노드 대화 상자를 먼저 저장하여 이미지 파일, 스타일시트 등의 지원 파일을 노드 대화 상자에 추가할 수 있습니다. 그런 다음 지원 파일을 노드 대화 상자 파일(.cfe)에 수동으로 추가합니다. 사용자 정의 노드 대화 상자 파일의 액세스 및 수동 수정 방법에 대한 정보는 사용자 정의 노드 대화 상자의 현지화된 버전 생성 주제의 "대화 상자 문자열을 현지화하려면" 섹션을 참조하십시오.

**스크립트 유형.** 스크립트 템플릿을 작성하는 데 사용할 수 있는 스크립트 유형을 지정합니다. IBM® SPSS® Modeler에서는 R 스크립팅 또는 Python for Spark 스크립팅을 사용할 수 있습니다.

**모델에서 점수화.** 모델 작성 스크립트를 사용하여 작성된 모델이 스코어링에 사용되는지 여부를 지정합니다.

**노드 유형.** 노드 대화 상자를 설치할 때 작성되는 노드의 유형을 지정합니다.

**팔레트.** 사용자가 노드 대화 상자를 설치할 때 새로 작성된 노드가 추가될 팔레트를 지정합니다.

**노드 아이콘.** 새로 작성된 노드에 대한 노드 아이콘으로 사용할 이미지를 선택하려면 생략 기호 (...) 단추를 클릭하십시오. 선택하는 이미지는 .gif 파일이어야 합니다.

#### (4) 대화 상자 캔버스에서 제어의 레이아웃

제어를 도구 팔레트에서 대화 상자 캔버스로 끌어오는 방법으로 사용자 정의 노드 대화 상자에 제어를 추가할 수 있습니다. 내장 노드 대화 상자와의 일관성을 보장하기 위해 대화 상자 캔버스가 제어를 배치할 수 있는 세 개의 기능 열로 나누어집니다.

- 첫 번째(가장 왼쪽) 열은 주로 필드 선택기 제어용입니다.
- 하위 대화 상자 단추는 가장 오른쪽 열(예: 3개의 열만 사용된 경우 세 번째 열)에 있어야 하며, 다른 제어는 하위 대화 상자 단추와 동일한 열에 있을 수 없습니다. 따라서 네 번째 열에는 하위 대화 상자 단추만 있을 수 있습니다.

대화 상자 캔버스에 표시되지 않은 경우에도 노드 대화 상자가 IBM® SPSS® Modeler에 설치될 때 적절한 단추가 대화 상자에 추가됩니다(예: **확인**, **취소**, **적용**, **다시 설정**, 그리고 해당되는 경우에는 **도움말** 및 **실행**). 이 단추의 존재와 위치는 자동입니다. 그러나 노드 대화 상자와 연관된 도움말 파일(대화 상자 특성의 도움말 파일 특성에 따라 지정됨)이 없으면 **도움말** 단추가 표시되지 않습니다.

제어를 위로 또는 아래로 끌어서 열 안에서 제어의 수직 위치를 변경할 수 있지만, 제어의 정확한 위치는 사용자를 위해 자동으로 결정됩니다. 런타임 시 대화 상자 자체의 크기가 조정될 때 제어의 크기도 적절한 방식으로 조정됩니다. 필드 선택기 등의 제어는 아래의 사용 가능한 공백을 채우도록 자동으로 확장됩니다.

## (5) 스크립트 템플릿 작성

스크립트 템플릿은 사용자 정의 노드 대화 상자에서 생성할 R 스크립트 또는 Python for Spark 스크립트를 지정합니다. 단일 사용자 정의 노드 대화 상자를 사용하면 순서대로 실행될 하나 이상의 작업을 지정할 수 있습니다.

스크립트 템플릿은 정적 텍스트로 구성될 수 있습니다. 정적 텍스트는 정적 텍스트 제어와 다르며, 노드가 실행될 때 항상 생성되는 R 코드 또는 Python for Spark 코드입니다. 예를 들어, 사용자 입력에 의존하지 않는 명령어 이름 및 하위 명령어 스펙은 정적 텍스트입니다. 스크립트 템플릿은 런타임 시에 연관된 사용자 정의 노드 대화 상자 제어의 값으로 대체되는 제어 식별자로 구성될 수도 있습니다. 예를 들어, 필드 선택기에서 지정된 필드의 세트는 필드 선택기 제어에 대한 제어 식별자와 함께 표시됩니다.

### 스크립트 템플릿 작성

1. 사용자가 지정한 값에 의존하지 않는 정적 텍스트의 경우에는 예를 들어 R 작성 노드의 R 모델 작성 구문 필드에서와 같이 R 스크립트 또는 Python for Spark 스크립트를 입력하십시오.
2. 제어를 통해 생성된 R 스크립트 또는 Python for Spark 스크립트를 삽입할 위치에 `%%Identifier%%` 형식의 제어 식별자를 추가하십시오. 여기서, Identifier는 제어에 대한 식별자 특성 값입니다.
  - 식별자 테이블에서 행을 선택하고 마우스 오른쪽 단추를 클릭하여 **스크립트 템플릿에 추가**를 선택하면 제어 식별자를 삽입할 수 있습니다. 또한 캔버스에서 제어를 마우스 오른쪽 단추로 클릭하고 **스크립트 템플릿에 추가**를 선택하여 제어 식별자를 삽입할 수도 있습니다.
  - Ctrl+스페이스바를 눌러 사용 가능한 제어 식별자 목록에서 선택할 수도 있습니다. 목록에는 제어 식별자가 있으며 해당 제어 식별자 뒤에는 스크립트 자동-완성 기능을 사용할 수 있는 항목이 있습니다.

식별자를 직접 입력하면 식별자에 있는 모든 공백은 중요한 의미를 가지기 때문에 모든 공백이 그대로 유지됩니다.

런타임 시에, 그리고 선택란, 선택란 그룹 및 정적 텍스트 제어 외의 모든 제어에 대해 각 식별자가 연관된 제어의 스크립트 특성의 현재 값으로 대체됩니다. 런타임 시에 제어가 비어 있으면 이는 스크립트를 생성하지 않습니다. 선택란 및 선택란 그룹의 경우, 제어의 현재 상태(선택됨 또는 선택 해제됨)에 따라 식별자가 연관된 제어의 선택된 R 스크립트 또는 선택 해제된 R 스크립트 특성의 값으로 대체됩니다. 자세한 정보는 제어 유형 주제를 참조하십시오.

## 예: R 스크립트 템플릿에 런타임 값 포함

이 예에서 사용자 정의 노드 대화 상자는 R 스크립트를 생성하고 실행하여 여기서 표시된 시그니처가 있는 R `lm` 함수에 대한 호출을 사용하여 선형 회귀분석 모델을 빌드하고 스코어링합니다.

```
lm(formula,data)
```

- `formula`는 `Na~Age` 등의 표현식을 지정합니다. 여기서, `Na`는 모델의 대상 필드이며 모델의 입력 필드는 `Age`입니다.
- `data`는 수식에서 지정된 필드의 값을 포함하는 데이터 프레임입니다.

사용자가 선형 모형의 입력 필드를 선택할 수 있도록 허용하는 단일 필드 선택기 제어가 있는 사용자 정의 노드 대화 상자를 고려하십시오. 모델을 작성하는 R 스크립트를 생성하고 실행할 수 있는 스크립트 템플릿은 스크립트 탭에 입력되고 다음과 같이 표시될 수 있습니다.

```
modelerModel <- lm(Na~%%input%%,data=modelerData)
```

- `%%input%%`은 필드 선택기 제어에 대한 식별자 특성의 값입니다. 런타임 시에 이는 제어의 스크립트 특성의 현재 값으로 대체됩니다.
- 필드 선택기 제어의 스크립트 특성이 `%%ThisValue%%`가 되도록 정의하면 런타임 시에 특성의 현재 값이 필드 선택기에서 선택된 필드인 제어의 값이 되도록 지정됩니다.

사용자 정의 노드 대화 상자의 사용자가 모델의 입력 필드로 나이 필드를 선택한 경우를 가정해 보십시오. 그러면 노드 대화 상자에 의해 다음 R 스크립트가 생성됩니다

```
modelerModel <- lm(Na~Age,data=modelerData)
```

모델을 스코어링하는 R 스크립트를 생성하고 실행하기 위한 스크립트 템플릿은 **점수 스크립트** 탭에 입력되고 다음과 같이 표시될 수 있습니다.

```
result<-predict(modelerModel,newdata=modelerData)
var1 <-c(fieldName="predicted",
fieldLabel="",fieldStorage="real",fieldMeasure="",fieldFormat="",
fieldRole="")
modelerDataModel<-data.frame(modelerDataModel,var1)
```

이 R 스크립트는 어떠한 사용자 지정 값에도 종속되지 않으며 모델 작성 R 스크립트를 사용하여 작성된 모델에만 종속됩니다. 따라서 모델 스코어링 R 스크립트는 R 작성 노드의 R 모델 스코어링 구문 필드에서와 같이 입력됩니다.

## (6) 사용자 정의 노드 대화 상자 미리보기

현재 사용자 정의 대화 상자 작성기에서 열려 있는 노드 대화 상자를 미리 볼 수 있습니다. 대화 상자는 IBM® SPSS® Modeler의 노드에서 실행될 때와 같이 표시되고 작동합니다.

- 필드 선택기는 더미 필드로 채워집니다.
- **확인** 단추를 클릭하면 미리보기가 닫힙니다.
- 도움말 파일이 지정되어 있으면 **도움말** 단추를 사용하여 지정된 파일을 열 수 있습니다. 지정된 도움말 파일이 없으면 미리 볼 때 도움말 단추를 사용할 수 없으며 실제 대화 상자가 실행될 때 도움말 단추가 표시되지 않습니다.

사용자 정의 노드 대화 상자를 미리 보려면 사용자 정의 대화 상자 작성기의 메뉴에서 **파일 > 대화 상자 미리 보기**를 선택하십시오.

## (7) 제어 유형

도구 팔레트는 사용자 정의 노드 대화 상자에 필요한 모든 표준 제어를 제공합니다.

- **필드 선택기**: 활성 데이터 세트의 모든 필드 목록입니다. 자세한 정보는 필드 선택기 주제를 참조하십시오.
- **선택란**: 단일 선택란입니다. 자세한 정보는 선택란 주제를 참조하십시오.
- **콤보 상자**: 드롭 다운 목록을 생성하기 위한 콤보 상자입니다. 자세한 정보는 콤보 상자 주제를 참조하십시오.
- **목록 상자**: 단일 선택 또는 다중 선택 목록을 작성하기 위한 목록 상자입니다. 자세한 정보는 콤보 상자 주제를 참조하십시오.
- **텍스트 제어**: 임의의 텍스트를 입력으로 허용하는 텍스트 상자입니다. 자세한 정보는 텍스트 제어 주제를 참조하십시오.
- **숫자 제어**: 입력이 숫자 값으로 제한되는 텍스트 상자입니다. 자세한 정보는 숫자 제어 주제를 참조하십시오.
- **날짜 제어**: 날짜, 시간, 날짜/시간을 포함한 날짜/시간 값을 지정하는 스피너 제어입니다. 자세한 정보는 날짜 제어 주제를 참조하십시오.
- **보안 텍스트**: 사용자가 입력한 내용을 별표로 마스킹하는 텍스트 상자입니다. 자세한 정보는 보안 텍스트 주제를 참조하십시오.
- **정적 텍스트 제어**: 정적 텍스트를 표시하기 위한 제어입니다. 자세한 정보는 정적 텍스트 제어 주제를 참조하십시오.
- **색상 선택도구**: 색상을 지정하고 연관된 RGB 값을 생성하는 제어입니다. 자세한 정보는 색상 선택도구 주제를 참조하십시오.
- **테이블 제어**: 런타임 시 추가되는 다양한 수의 행과 고정된 수의 열을 포함하는 테이블입니다. 자세한 정보는 테이블 제어 주제를 참조하십시오.
- **항목 그룹**: 선택란 세트와 같이 제어 세트를 그룹화하기 위한 컨테이너입니다. 자세한 정보는 항목 그룹 주제를 참조하십시오.

- **라디오 그룹:** 단일 선택 단추 그룹입니다. 자세한 정보는 라디오 그룹 주제를 참조하십시오.
- **선택란 그룹:** 활성 또는 비활성 제어 세트를 하나의 그룹(단일 선택란)으로 만드는 컨테이너입니다. 자세한 정보는 선택란 그룹 주제를 참조하십시오.
- **파일 브라우저:** 파일을 열거나 저장하기 위해 파일 시스템을 찾기 위한 제어입니다. 자세한 정보는 파일 브라우저 주제를 참조하십시오.
- **탭:** 단일 탭입니다. 자세한 정보는 탭 주제를 참조하십시오.
- **하위 대화 상자 단추:** 하위 대화 상자를 시작하기 위한 단추입니다. 자세한 정보는 하위 대화 상자 단추 주제를 참조하십시오.

### ① 필드 선택기

필드 선택기 제어는 노드 대화 상자의 일반 사용자가 사용할 수 있는 필드 목록을 표시합니다. 활성 데이터 세트의 모든 필드를 표시(기본값)하거나 유형 및 측정 수준을 기준으로 목록을 필터링할 수 있습니다. 예를 들어, 측정 수준이 척도인 숫자 필드만 필터링할 수 있습니다. 또한 다른 필드 선택기를 현재 필드 선택기의 필드 소스로 지정할 수도 있습니다. 필드 선택기 제어에는 다음과 같은 특성이 있습니다.

**식별자.** 고유 제어용 식별자.

**제목.** 제어 위에 나타나는 선택적 제목입니다. 복수 행 제목의 경우  $w_n$ 을 사용하여 줄 바꿈을 지정하십시오.

**제목 위치.** 제어와 관련된 제목의 위치를 지정합니다. 값은 위쪽(기본값) 및 왼쪽입니다. 이 특성은 선택기 유형이 단일 필드를 선택하도록 설정된 경우에만 적용됩니다.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다. 제어의 제목 영역 위로 마우스를 이동하면 지정된 텍스트만 표시됩니다. 나열된 필드 중 하나 위로 마우스를 이동하면 필드 이름 및 레이블이 표시됩니다.

**기억용 키.** 제목에 있는 선택적 문자로, 제어에 대한 키보드 단축키로 사용합니다. 문자는 밑줄이 그어져 제목에 표시됩니다. Alt+[기억용 키]를 누르면 단축키가 활성화됩니다.

**선택기 유형.** 사용자 정의 노드 대화 상자 내의 필드 선택기를 사용하여 필드 목록에서 단일 필드 또는 복수 필드를 선택할 수 있는지 여부를 지정합니다.

**구분 문자 유형.** 생성된 스크립트에서 선택된 필드를 구분하는 구분자를 지정합니다. 허용되는 구분 문자는 공백, 쉼표, 더하기 부호(+)입니다. 구분 문자로 사용할 임의의 문자 하나를 입력할 수도 있습니다.

**최소 필드.** 제어에 지정해야 하는 필드 최소 수입니다(있는 경우).

**최대 필드.** 제어에 지정할 수 있는 필드 최대 수입니다(있는 경우).

**실행에 필수.** 이 제어를 실행하는 데 값이 필요한지 여부를 지정합니다. **true**가 지정되면 노드 대화 상자의 사용자가 제어에 대한 값을 지정해야 합니다. 그렇지 않으면 **확인** 단추를 클릭할 때 오류가 생성됩니다. **false**가 지정되면 이 제어의 값이 없어도 **확인** 단추의 상태에 영향을 미치지 않습니다.

**변수 필터.** 제어에 표시되는 필드 세트를 필터링할 수 있습니다. 필드 유형 및 측정 수준을 필터링할 수 있으며 필드 목록에 다중 응답 세트가 포함되도록 지정할 수 있습니다. 생략 기호(...) 단추를 클릭하여 필터 대화 상자를 엽니다. 또한 캔버스에서 필드 선택기 제어를 두 번 클릭하여 필터 대화 상자를 열 수도 있습니다. 자세한 정보는 필드 목록 필터링 주제를 참조하십시오.

**필드 소스.** 다른 필드 선택기를 현재 필드 선택기에 대한 필드의 소스로 지정합니다. 필드 소스 특성이 설정되지 않은 경우 필드 소스는 활성 데이터 세트입니다. 필드 소스 대화 상자를 열고 필드 소스를 지정하려면 생략 기호(...) 단추를 클릭하십시오.

**스크립트.** 런타임 시 이 제어를 통해 생성 및 실행하고 스크립트 템플릿에 삽입할 수 있는 스크립트를 지정합니다.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.
- %%ThisValue%% 값은 제어의 런타임 값(필드 목록)을 지정합니다. 이는 기본값입니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

### 가. 필드 선택기의 필드 소스 지정

필드 소스 대화 상자는 필드 선택기에 표시되는 필드의 소스를 지정합니다. 소스는 다른 필드 선택기일 수 있습니다. 선택된 제어에 있는 필드를 표시하거나 선택된 제어에 없는 활성 데이터 세트의 필드를 표시하도록 선택할 수 있습니다.

### ② 필드 목록 필터링

필드 선택기 제어와 연관된 필터 대화 상자를 사용하여 목록에 표시될 수 있는 활성 데이터 세트의 필드 유형을 필터링할 수 있습니다. 또한 활성 데이터 세트와 관련된 다중 반응 세트를 포함할지 여부를 지정할 수 있습니다. 숫자 필드에는 날짜 및 시간 형식을 제외한 모든 숫자 형식이 포함됩니다.

### ③ 선택란

선택란 제어는 선택한 상태 및 선택 해제 상태에 대해 서로 다른 R 스크립트 또는 Python for Spark 스크립트를 생성 및 실행할 수 있는 단순 선택란입니다. 선택란 제어에는 다음과 같은 특성이 있습니다.

**식별자.** 고유 제어용 식별자.

**제목.** 제어 위에 나타나는 선택적 제목입니다. 복수 행 제목의 경우 `wn`을 사용하여 줄 바꿈을 지정하십시오.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**기억용 키.** 제목에 있는 선택적 문자로, 제어에 대한 키보드 단축키로 사용합니다. 문자는 밑줄이 그어져 제목에 표시됩니다. `Alt+[기억용 키]`를 누르면 단축키가 활성화됩니다.

**기본값.** 선택란의 기본 설정 상태(선택 또는 선택 해제)입니다.

**선택/선택 해제스크립트.** 제어를 선택 및 선택 해제될 때 생성 및 실행되는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다. 스크립트 템플릿에 스크립트를 포함시키려면 식별자 특성의 값을 사용하십시오. 생성된 스크립트가 선택된 스크립트 또는 선택 해제된 스크립트 특성에서 생성되었는지에 상관없이 식별자의 지정된 위치에 삽입됩니다. 예를 들어, 식별자가 `checkbox1`이면 런타임 시 스크립트 템플릿의 `%%checkbox1%%`의 인스턴스가 선택된 스크립트 특성의 값(상자가 선택된 경우) 또는 선택 해제된 스크립트 특성의 값(상자가 선택 해제된 경우)으로 대체됩니다.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

### ④ 콤보 상자

콤보 상자 제어를 사용하여 선택된 항목 목록에만 적용되는 R 스크립트 또는 Python for Spark 스크립트를 생성 및 실행할 수 있는 드롭 다운 목록을 작성할 수 있습니다. 단일 선택으로 제한됩니다. 콤보 상자 제어는 다음과 같은 특성을 갖습니다.

**식별자.** 고유 제어용 식별자. 스크립트 양식에서 제어를 참조할 때 사용할 식별자입니다.

**제목.** 제어 위에 나타나는 선택적 제목입니다. 복수 행 제목의 경우 `wn`을 사용하여 줄 바꿈을 지정하십시오.

**제목 위치.** 제어와 관련된 제목의 위치를 지정합니다. 값은 위쪽(기본값) 및 왼쪽입니다.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**항목 목록.** 생략 기호(...) 단추를 클릭하여 목록 항목 특성 대화 상자를 연 다음 제어의 목록 항목을 지정합니다. 캔버스에서 콤보 상자 제어를 두 번 클릭하여 목록 항목 특성 대화 상자를 열 수도 있습니다.

**기억용 키.** 제목에 있는 선택적 문자로, 제어에 대한 키보드 단축키로 사용합니다. 문자는 밑줄이 그어져 제목에 표시됩니다. `Alt+[기억용 키]`를 누르면 단축키가 활성화됩니다.

**편집 가능.** 콤보 상자 제어를 편집할 수 있는지 여부를 지정합니다. 편집 가능한 제어일 경우 런타임 시 사용자 정의 값을 입력할 수 있습니다.

**스크립트.** 런타임 시 이 제어에서 생성되고 스크립트 템플릿에 삽입될 수 있는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.

- `%%ThisValue%%` 값은 제어의 런타임 값(기본값)을 지정합니다. 항목 목록이 수동으로 정의된 경우, 런타임 값은 선택된 목록 항목의 스크립트 특성 값입니다. 목록 항목이 목표 목록 제어를 기반으로 하는 경우 런타임 값은 선택된 목록 항목의 값입니다. 다중 선택 목록 상자 제어의 경우, 런타임 값은 선택한 항목을 공백으로 구분한 목록입니다. 자세한 정보는 콤보 상자 및 목록 상자의 항목 목록 지정 주제를 참조하십시오.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.

**따옴표 처리.** 스크립트 특성에 `%%ThisValue%%`가 인용 문자열의 일부로 포함될 때 `%%ThisValue%%`의 런타임 값에 있는 따옴표의 처리를 지정합니다. 이 컨텍스트에서 따옴표가 있는 문자열은 작은따옴표 또는 큰따옴표로 묶은 문자열입니다. 따옴표 처리는 `%%ThisValue%%`를 둘러싼 따옴표와 동일한 유형의 따옴표에만 적용됩니다. 다음과 같은 유형의 따옴표 처리를 사용할 수 있습니다.

### Python

둘러싼 따옴표와 일치하는 `%%ThisValue%%`의 런타임 값에 있는 따옴표가 백슬래시 문자(`\`)를 사용하여 이스케이프 처리됩니다. 예를 들어, 스크립트 특성이

'%%ThisValue%%'이고 콤보 상자의 런타임 값이 Combo box's value인 경우 생성되는 스크립트는 'Combo boxW's value'입니다. %%ThisValue%%가 3중 따옴표로 묶인 경우 따옴표 처리가 수행되지 않습니다.

#### R

둘러싼 따옴표와 일치하는 %%ThisValue%%의 런타임 값에 있는 따옴표가 백슬래시 문자(\)를 사용하여 이스케이프 처리됩니다. 예를 들어, 스크립트 특성이 '%%ThisValue%%'이고 콤보 상자의 런타임 값이 Combo box's value인 경우 생성되는 스크립트는 'Combo boxW's value'입니다.

#### 없음

둘러싼 따옴표와 일치하는 %%ThisValue%%의 런타임 값에 있는 따옴표가 수정 없이 유지됩니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

### 가. 콤보 상자 및 목록 상자의 항목 목록 지정

항목 특성 목록 대화 상자를 사용하면 콤보 상자 또는 목록 상자 제어의 항목 목록을 지정할 수 있습니다.

**수동으로 정의된 값.** 각 항목 목록을 명시적으로 지정할 수 있습니다.

- **식별자.** 항목 목록에 대한 고유 식별자입니다.
- **이름.** 이 항목의 목록에 나타나는 이름입니다. 이 이름은 필수 필드입니다.
- **기본값.** 콤보 상자의 경우, 항목 목록이 콤보 상자에 표시되는 기본 항목인지를 지정합니다. 목록 상자의 경우, 항목 목록이 기본적으로 선택되는지를 지정합니다.
- **스크립트.** 항목 목록을 선택할 때 생성되는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.
- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.

 **참고:** 기존 목록 아래의 빈 줄에 새 목록 항목을 추가할 수 있습니다. 식별자를 제외한 다른 특성을 입력하면 고유 식별자가 생성되며 이를 저장 또는 수정할 수 있습니다. 해당 항목의 식별자 셀을 클릭한 다음 삭제를 눌러 항목 목록을 삭제할 수 있습니다.

## ⑤ 목록 상자

목록 상자 제어를 사용하여 단일 또는 복수 선택을 지원하는 항목의 목록을 표시하고, 선택된 항목에만 적용되는 R 스크립트 또는 Python for Spark 스크립트를 생성할 수 있습니다. 목록 상자 제어에는 다음과 같은 특성이 있습니다.

**식별자.** 고유 제어용 식별자. 스크립트 양식에서 제어를 참조할 때 사용할 식별자입니다.

**제목.** 제어 위에 나타나는 선택적 제목입니다. 복수 행 제목의 경우 `wn`을 사용하여 줄 바꿈을 지정하십시오.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**항목 목록.** 생략 기호(...) 단추를 클릭하여 목록 항목 특성 대화 상자를 연 다음 제어의 목록 항목을 지정합니다. 캔버스에서 목록 상자 제어를 두 번 클릭하여 목록 항목 특성 대화 상자를 열 수도 있습니다.

**기억용 키.** 제목에 있는 선택적 문자로, 제어에 대한 키보드 단축키로 사용합니다. 문자는 밑줄이 그어져 제목에 표시됩니다. `Alt+[기억용 키]`를 누르면 단축키가 활성화됩니다.

**목록 상자 유형.** 목록 상자가 단일 선택만 지원하는지 또는 다중 선택을 지원하는지 지정합니다. 항목이 선택된 목록으로 표시되도록 지정할 수도 있습니다.

**구분 문자 유형.** 생성된 스크립트에서 선택된 목록 항목 사이의 구분자를 지정합니다. 허용되는 구분 문자는 공백, 쉼표, 더하기 부호(+)입니다. 구분 문자로 사용할 임의의 문자 하나를 입력할 수도 있습니다.

**선택 최소값.** 제어에서 선택해야 하는 항목 최소 수입니다(있는 경우).

**선택 최대값.** 제어에서 선택할 수 있는 항목 최대 수입니다(있는 경우).

**스크립트.** 런타임 시 이 제어에서 생성되고 스크립트 템플릿에 삽입될 수 있는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.

- `%%ThisValue%%` 값은 제어의 런타임 값(기본값)을 지정합니다. 항목 목록이 수동으로 정의된 경우, 런타임 값은 선택된 목록 항목의 스크립트 특성 값입니다. 목록 항목이 목표 목록 제어를 기반으로 하는 경우 런타임 값은 선택된 목록 항목의 값입니다. 다중 선택 목록 상자 제어의 경우, 런타임 값은 지정된 구분 문자 유형(기본값은 공백으로 구분)으로 구분된 선택된 항목의 목록입니다. 자세한 정보는 콤보 상자 및 목록 상자의 항목 목록 지정 주제를 참조하십시오.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.

**따옴표 처리.** 스크립트 특성에 `%%ThisValue%%`가 인용 문자열의 일부로 포함될 때 `%%ThisValue%%`의 런타임 값에 있는 따옴표의 처리를 지정합니다. 이 컨텍스트에서 따옴표가 있는 문자열은 작은따옴표 또는 큰따옴표로 묶은 문자열입니다. 따옴표 처리는 `%%ThisValue%%`를 둘러싼 따옴표와 동일한 유형의 따옴표에만 적용됩니다. 다음과 같은 유형의 따옴표 처리를 사용할 수 있습니다.

#### Python

둘러싼 따옴표와 일치하는 `%%ThisValue%%`의 런타임 값에 있는 따옴표가 백슬래시 문자(`\`)를 사용하여 이스케이프 처리됩니다. 예를 들어, 스크립트 특성이 `'%%ThisValue%%'`이고 선택된 목록 항목이 List item's value인 경우 생성되는 스크립트는 `'List item\'s value'`입니다. `%%ThisValue%%`가 3중 따옴표로 묶인 경우 따옴표 처리가 수행되지 않습니다.

#### R

둘러싼 따옴표와 일치하는 `%%ThisValue%%`의 런타임 값에 있는 따옴표가 백슬래시 문자(`\`)를 사용하여 이스케이프 처리됩니다. 예를 들어, 스크립트 특성이 `'%%ThisValue%%'`이고 선택된 목록 항목이 List item's value인 경우 생성되는 스크립트는 `'List item\'s value'`입니다.

#### 없음

둘러싼 따옴표와 일치하는 `%%ThisValue%%`의 런타임 값에 있는 따옴표가 수정 없이 유지됩니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

### ⑥ 텍스트 제어

텍스트 제어는 임의의 입력 값을 허용하는 단순 텍스트 선택란으로 다음과 같은 특성이 있습니다.

**식별자.** 고유 제어용 식별자. 스크립트 양식에서 제어를 참조할 때 사용할 식별자입니다.

**제목.** 제어 위에 나타나는 선택적 제목입니다. 복수 행 제목의 경우 `wn`을 사용하여 줄 바꿈을 지정하십시오.

**제목 위치.** 제어와 관련된 제목의 위치를 지정합니다. 값은 위쪽(기본값) 및 왼쪽입니다.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**기억용 키.** 제목에 있는 선택적 문자로, 제어에 대한 키보드 단축키로 사용합니다. 문자는 밑줄이 그어져 제목에 표시됩니다. Alt+[기억용 키]를 누르면 단축키가 활성화됩니다.

**텍스트 내용.** 내용이 임의적인지 아니면 텍스트 상자에 IBM® SPSS® Modeler 필드 이름에 대한 규칙을 준수하는 문자열이 포함되어야 하는지 여부를 지정합니다.

**기본값.** 텍스트 상자의 기본 설정 내용입니다.

**너비.** 제어 텍스트 영역의 너비를 문자 수로 지정합니다. 허용되는 값은 양의 정수입니다. 빈 값은 너비가 자동으로 결정됨을 의미합니다.

**실행에 필수.** 이 제어를 실행하는 데 값이 필요한지 여부를 지정합니다. **true**가 지정되면 노드 대화 상자의 사용자가 제어에 대한 값을 지정해야 합니다. 그렇지 않으면 **확인** 단추를 클릭할 때 오류가 생성됩니다. **false**가 지정되면 이 제어의 값이 없어도 **확인** 단추의 상태에 영향을 미치지 않습니다. 기본값은 **false**입니다.

**스크립트.** 런타임 시 이 제어를 통해 생성 및 실행되며 스크립트 템플릿에 삽입할 수 있는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.
- %%ThisValue%% 값은 제어의 런타임 값(텍스트 상자의 내용)을 지정합니다. 이는 기본값입니다.
- 스크립트 특성에 %%ThisValue%%가 포함되어 있고 텍스트 상자의 런타임 값이 비어 있을 경우, 텍스트 상자 제어가 어떠한 스크립트도 생성하지 않습니다.

**따옴표 처리.** 스크립트 특성에 %%ThisValue%%가 인용 문자열의 일부로 포함될 때 %%ThisValue%%의 런타임 값에 있는 따옴표의 처리를 지정합니다. 이 컨텍스트에서 따옴표가 있는 문자열은 작은따옴표 또는 큰따옴표로 묶은 문자열입니다. 따옴표 처리는 %%ThisValue%%를 둘러싼 따옴표와 동일한 유형의 따옴표에만 적용됩니다. 다음과 같은 유형의 따옴표 처리를 사용할 수 있습니다.

#### Python

둘러싼 따옴표와 일치하는 %%ThisValue%%의 런타임 값에 있는 따옴표가 백슬래시 문자(\)를 사용하여 이스케이프 처리됩니다. 예를 들어, 스크립트 특성이 '%ThisValue%'이고 텍스트 제어의 런타임 값이 Text box's value인 경우 생성되는

스크립트는 'Text box $\mathbb{W}$ 's value'입니다. `%%ThisValue%%`가 3중 따옴표로 묶인 경우 따옴표 처리가 수행되지 않습니다.

#### R

둘러싼 따옴표와 일치하는 `%%ThisValue%%`의 런타임 값에 있는 따옴표가 백슬래시 문자( $\mathbb{W}$ )를 사용하여 이스케이프 처리됩니다. 예를 들어, 스크립트 특성이 `'%%ThisValue%%'`이고 텍스트 제어의 런타임 값이 Text box's value인 경우 생성되는 스크립트는 'Text box $\mathbb{W}$ 's value'입니다.

#### 없음

둘러싼 따옴표와 일치하는 `%%ThisValue%%`의 런타임 값에 있는 따옴표가 수정 없이 유지됩니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

### ⑦ 숫자 제어

**숫자 제어**는 숫자 값을 입력하는 텍스트 상자이며 다음과 같은 특성이 있습니다.

**식별자.** 고유 제어용 식별자. 스크립트 양식에서 제어를 참조할 때 사용할 식별자입니다.

**제목.** 제어 위에 나타나는 선택적 제목입니다. 복수 행 제목의 경우  $\mathbb{W}\mathbb{n}$ 을 사용하여 줄 바꿈을 지정하십시오.

**제목 위치.** 제어와 관련된 제목의 위치를 지정합니다. 값은 위쪽(기본값) 및 왼쪽입니다.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**기억용 키.** 제목에 있는 선택적 문자로, 제어에 대한 키보드 단축키로 사용합니다. 문자는 밑줄이 그어져 제목에 표시됩니다. Alt+[기억용 키]를 누르면 단축키가 활성화됩니다.

**숫자 유형.** 입력 내용의 제한 사항을 지정합니다. 입력 값에 아무런 제한이 없는 실수 값 또는 숫자가 되도록 지정합니다. 입력 값이 반드시 정수가 되도록 지정합니다.

**스핀 입력.** 제어를 스피너로 표시할지 여부를 지정합니다. 기본값은 False입니다.

**증분.** 제어를 스피너로 표시할 경우 증분입니다.

**기본값.** 기본 값입니다(있을 경우).

**최소값.** 허용되는 최소값입니다(있을 경우).

**최대값.** 허용되는 최대값입니다(있을 경우).

**너비.** 제어 텍스트 영역의 너비를 문자 수로 지정합니다. 허용되는 값은 양의 정수입니다. 빈 값은 너비가 자동으로 결정됨을 의미합니다.

**실행에 필수.** 이 제어를 실행하는 데 값이 필요한지 여부를 지정합니다. **true**가 지정되면 노드 대화 상자의 사용자가 제어에 대한 값을 지정해야 합니다. 그렇지 않으면 **확인** 단추를 클릭할 때 오류가 생성됩니다. **false**가 지정되면 이 제어의 값이 없어도 **확인** 단추의 상태에 영향을 미치지 않습니다. 기본값은 **false**입니다.

**스크립트.** 런타임 시 이 제어를 통해 생성 및 실행되며 스크립트 템플릿에 삽입할 수 있는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.
- %%ThisValue%% 값은 제어의 런타임 값(숫자 값)을 지정합니다. 이는 기본값입니다.
- 스크립트 특성에 %%ThisValue%%가 포함되어 있고 숫자 제어의 런타임 값이 비어 있을 경우, 숫자 제어는 어떠한 스크립트도 생성하지 않습니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

## ⑧ 날짜 제어

날짜 제어는 날짜, 시간, 날짜/시간을 포함한 날짜/시간 값을 지정하는 스피너 제어입니다. 날짜 제어는 다음과 같은 특성을 갖습니다.

**식별자.** 고유 제어용 식별자. 스크립트 양식에서 제어를 참조할 때 사용할 식별자입니다.

**제목.** 제어 위에 나타나는 선택적 제목입니다. 복수 행 제목의 경우  $w_n$ 을 사용하여 줄 바꿈을 지정하십시오.

**제목 위치.** 제어와 관련된 제목의 위치를 지정합니다. 값은 위쪽(기본값) 및 왼쪽입니다.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**기억용 키.** 제목에 있는 선택적 문자로, 제어에 대한 키보드 단축키로 사용합니다. 문자는 밑줄이 그어져 제목에 표시됩니다. Alt+[기억용 키]를 누르면 단축키가 활성화됩니다.

**유형.** 날짜, 시간 또는 날짜/시간 값에 대한 제어인지 여부를 지정합니다.

#### **날짜**

제어가 달력 날짜를 yyyy-mm-dd 형식으로 지정합니다. 기본 런타임 값은 기본값 특성으로 지정됩니다.

#### **시간**

제어가 시간을 hh:mm:ss 형식으로 지정합니다. 기본 런타임 값은 현재 시간입니다.

#### **날짜/시간**

제어가 날짜 및 시간을 yyyy-mm-dd hh:mm:ss 형식으로 지정합니다. 기본 런타임 값은 현재 날짜 및 시간입니다.

**기본값.** 유형이 날짜일 경우 제어의 기본 런타임 값입니다. 현재 날짜 또는 특정 날짜를 표시하도록 지정할 수 있습니다.

**스크립트.** 런타임 시 이 제어를 통해 생성 및 실행되며 스크립트 템플릿에 삽입할 수 있는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.
- %%ThisValue%% 값은 제어의 런타임 값을 지정합니다. 이는 기본값입니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

 **참고:** 릴리스 18 이전의 IBM® SPSS® Modeler 릴리스에서는 날짜 제어가 지원되지 않습니다.

### **⑨ 보안 텍스트**

보안 텍스트 제어는 사용자가 입력한 내용을 별표로 마스킹하는 텍스트 상자입니다.

**식별자.** 고유 제어용 식별자. 스크립트 양식에서 제어를 참조할 때 사용할 식별자입니다.

**제목.** 제어 위에 나타나는 선택적 제목입니다. 복수 행 제목의 경우 wN을 사용하여 줄 바꿈을 지정하십시오.

**제목 위치.** 제어와 관련된 제목의 위치를 지정합니다. 값은 위쪽(기본값) 및 왼쪽입니다.

**도구 팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**기억용 키.** 제목에 있는 선택적 문자로, 제어에 대한 키보드 단축키로 사용합니다. 문자는 밑줄이 그어져 제목에 표시됩니다. Alt+[기억용 키]를 누르면 단축키가 활성화됩니다.

**너비.** 제어 텍스트 영역의 너비를 문자 수로 지정합니다. 허용되는 값은 양의 정수입니다. 빈 값은 너비가 자동으로 결정됨을 의미합니다.

**실행에 필수.** 이 제어를 실행하는 데 값이 필요한지 여부를 지정합니다. **true**가 지정되면 노드 대화 상자의 사용자가 제어에 대한 값을 지정해야 합니다. 그렇지 않으면 **확인** 단추를 클릭할 때 오류가 생성됩니다. **false**가 지정되면 이 제어의 값이 없어도 확인 단추의 상태에 영향을 미치지 않습니다. 기본값은 **false**입니다.

**스크립트.** 런타임 시 이 제어를 통해 생성 및 실행되며 스크립트 템플릿에 삽입할 수 있는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.
- %%ThisValue%% 값은 제어의 런타임 값(텍스트 상자의 내용)을 지정합니다. 이는 기본값입니다.
- 스크립트 특성에 %%ThisValue%%가 포함되어 있고 보안 텍스트 제어의 런타임 값이 비어 있을 경우, 보안 텍스트 제어가 어떠한 R 스크립트 또는 Python for Spark 스크립트도 생성하지 않습니다.

**따옴표 처리.** 스크립트 특성에 %%ThisValue%%가 인용 문자열의 일부로 포함될 때 %%ThisValue%%의 런타임 값에 있는 따옴표의 처리를 지정합니다. 이 컨텍스트에서 따옴표가 있는 문자열은 작은따옴표 또는 큰따옴표로 묶은 문자열입니다. 따옴표 처리는 %%ThisValue%%를 둘러싼 따옴표와 동일한 유형의 따옴표에만 적용되고, Encrypt passed value=False일 경우에만 적용됩니다. 다음과 같은 유형의 따옴표 처리를 사용할 수 있습니다.

#### Python

둘러싼 따옴표와 일치하는 %%ThisValue%%의 런타임 값에 있는 따옴표가 백슬래시 문자(\)를 사용하여 이스케이프 처리됩니다. 예를 들어, 스크립트 특성이 '%ThisValue%'이고 제어의 런타임 값이 Secured Text's value인 경우 생성되는 스크립트는 'Secured Text\'s value'입니다. %%ThisValue%%가 3중 따옴표로 묶인 경우 따옴표 처리가 수행되지 않습니다.

## R

둘러싼 따옴표와 일치하는 %%ThisValue%%의 런타임 값에 있는 따옴표가 백슬래시 문자(\)를 사용하여 이스케이프 처리됩니다. 예를 들어, 스크립트 특성이 '%ThisValue%'이고 제어의 런타임 값이 Secured Text's value인 경우 생성되는 스크립트는 'Secured Text\'s value'입니다.

## 없음

둘러싼 따옴표와 일치하는 %%ThisValue%%의 런타임 값에 있는 따옴표가 수정 없이 유지됩니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

 **참고:** 릴리스 18 이전의 IBM® SPSS® Modeler 릴리스에서는 보안 텍스트 제어가 지원되지 않습니다.

## ⑩ 정적 텍스트 제어

정적 텍스트 제어를 사용하면 사용자의 노드 대화 상자에 텍스트를 추가할 수 있습니다. 정적 텍스트의 특성은 다음과 같습니다.

**식별자.** 고유 제어용 식별자.

**제목.** 텍스트 상자의 내용입니다. 복수 행 내용의 경우 \n을 사용하여 줄 바꿈을 지정합니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

## ⑪ 색상 선택도구

색상 선택도구 제어는 색상을 지정하고 연관된 RGB 값을 생성하는 사용자 인터페이스입니다. 색상 선택도구 제어는 다음과 같은 특성을 갖습니다.

**식별자.** 고유 제어용 식별자. 스크립트 양식에서 제어를 참조할 때 사용할 식별자입니다.

**제목.** 제어 위에 나타나는 선택적 제목입니다. 복수 행 제목의 경우 \n을 사용하여 줄 바꿈을 지정하십시오.

**제목 위치.** 제어와 관련된 제목의 위치를 지정합니다. 값은 위쪽(기본값) 및 왼쪽입니다.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**기억용 키.** 제목에 있는 선택적 문자로, 제어에 대한 키보드 단축키로 사용합니다. 문자는 밑줄이 그어져 제목에 표시됩니다. Alt+[기억용 키]를 누르면 단축키가 활성화됩니다.

**스크립트.** 런타임 시 이 제어를 통해 생성 및 실행되며 스크립트 템플릿에 삽입할 수 있는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.
- %%ThisValue%% 값은 제어의 런타임 값(선택한 색상의 RGB 값)을 지정합니다. RGB 값은 R 값, G 값, B 값 순서의 정수를 공백으로 구분한 목록으로 표시됩니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

 **참고:** 릴리스 18 이전의 IBM® SPSS® Modeler 릴리스에서는 색상 선택도구 제어가 지원되지 않습니다.

## ⑫ 테이블 제어

테이블 제어는 런타임 시 추가되는 다양한 수의 행과 고정된 수의 열을 포함하는 테이블을 작성합니다. 테이블 제어는 다음과 같은 특성을 갖습니다.

**식별자.** 고유 제어용 식별자. 스크립트 양식에서 제어를 참조할 때 사용할 식별자입니다.

**제목.** 제어 위에 나타나는 선택적 제목입니다. 복수 행 제목의 경우 Wn을 사용하여 줄 바꿈을 지정하십시오.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**기억용 키.** 제목에 있는 선택적 문자로, 제어에 대한 키보드 단축키로 사용합니다. 문자는 밑줄이 그어져 제목에 표시됩니다. Alt+[기억용 키]를 누르면 단축키가 활성화됩니다.

**재정렬 단추.** 위로 이동 및 아래로 이동 단추를 테이블에 추가할지 여부를 지정합니다. 이러한 단추는 런타임 시 테이블 행을 다시 정렬하는 데 사용됩니다.

**테이블 열.** 생략 기호(...) 단추를 클릭하면 테이블 열을 지정할 수 있는 테이블 열 대화 상자가 열립니다.

**최소 행.** 테이블에 있어야 하는 최소 행 수입니다.

**최대 행.** 테이블에 있을 수 있는 최대 행 수입니다.

**실행에 필수.** 이 제어를 실행하는 데 값이 필요한지 여부를 지정합니다. **true**가 지정되면 노드 대화 상자의 사용자가 제어에 대한 값을 지정해야 합니다. 그렇지 않으면 **확인** 단추를 클릭할 때 오류가 생성됩니다. **false**가 지정되면 이 제어의 값이 없어도 **확인** 단추의 상태에 영향을 미치지 않습니다.

**스크립트.** 런타임 시 이 제어에서 생성되고 스크립트 템플릿에 삽입될 수 있는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.

- **%%ThisValue%%** 값은 제어의 런타임 값(기본값)을 지정합니다. 런타임 값은 테이블의 각 열(가장 왼쪽 열부터)에서 생성한 스크립트를 공백으로 구분한 목록입니다. 스크립트 특성에 **%%ThisValue%%**가 포함되어 있고 어떠한 열도 스크립트를 생성하지 않을 경우, 전체적으로 테이블이 스크립트를 생성하지 않습니다.
- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

 **참고:** 릴리스 18 이전의 IBM® SPSS® Modeler 릴리스에서는 테이블 제어가 지원되지 않습니다.

### 가. 테이블 제어의 열 지정

테이블 열 대화 상자는 테이블 제어 열의 특성을 지정합니다.

**식별자.** 열의 고유 식별자입니다.

**열 이름.** 테이블에 표시되는 열의 이름입니다.

**컨텐츠.** 열의 데이터 유형을 지정합니다. **실수** 값은 숫자가 아닌 한 입력하는 값에 아무런 제한

이 없음을 지정합니다. 정수 값은 값이 정수여야 함을 지정합니다. 임의 값은 입력하는 값에 아무런 제한이 없음을 지정합니다. 변수 이름 값은 값이 IBM® SPSS® Statistics의 유효한 변수 이름에 대한 요구사항을 충족해야 함을 지정합니다.

**기본값.** 런타임 시 테이블에 새 행이 추가될 때 이 열의 기본값(있는 경우)입니다.

**구분 문자 유형.** 생성된 스크립트에서 열 값 사이의 구분자를 지정합니다. 허용되는 구분 문자는 공백, 쉼표, 더하기 부호(+)입니다. 구분 문자로 사용할 임의의 문자 하나를 입력할 수도 있습니다.

**따옴표 사용.** 생성된 스크립트에서 열의 각 값이 큰따옴표로 묶이는지 여부를 지정합니다.

**따옴표 처리.** 따옴표 사용 특성이 true일 때 열의 셀 항목에서 따옴표의 처리를 지정합니다. 따옴표 처리는 셀 값에 사용된 큰따옴표에만 적용됩니다. 다음과 같은 유형의 따옴표 처리를 사용할 수 있습니다.

#### Python

셀 값의 큰따옴표가 백슬래시 문자(\)로 이스케이프됩니다. 예를 들어, 셀 값이 This "quoted" value인 경우 생성되는 스크립트는 "This \\"quoted\\" value"입니다.

#### R

셀 값의 큰따옴표가 백슬래시 문자(\)로 이스케이프됩니다. 예를 들어, 셀 값이 This "quoted" value인 경우 생성되는 스크립트는 "This \\"quoted\\" value"입니다.

#### 없음

셀 값의 큰따옴표가 수정 없이 그대로 유지됩니다.

**너비(문자 수).** 열의 너비를 문자 수로 지정합니다. 허용되는 값은 양의 정수입니다.

**스크립트.** 런타임 시 이 열에 의해 생성되는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다. 테이블 전체에 대해 생성되는 스크립트는 테이블의 각 열(가장 왼쪽 열부터)에서 생성하는 스크립트의 공백으로 구분한 목록입니다.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.
- %%ThisValue%% 값은 열의 런타임 값을 지정하며, 이 값은 열의 값 목록(지정된 구분 문자로 구분)입니다.
- 열의 스크립트 특성에 %%ThisValue%%가 포함되고 열의 런타임 값이 비어 있는 경우 해당 열은 스크립트를 생성하지 않습니다

**참고:** 테이블 열 대화 상자에서 기존 목록 맨 아래에 있는 빈 줄에 새 테이블 열의 행을 추가할 수 있습니다. 식별자를 제외한 다른 특성을 입력하면 고유 식별자가 생성되며 이를 저장 또는 수정할 수 있습니다. 테이블 열의 식별자 셀을 클릭하고 삭제를 눌러 테이블 열을 삭제할 수 있습니다.

## 컨트롤에 연결

테이블 제어를 필드 선택기 제어에 링크할 수 있습니다. 테이블 제어가 필드 선택기에 링크되면 테이블에 필드 선택기의 각 필드에 대한 행이 있습니다. 필드 선택기에 필드를 추가하면 테이블에 행이 추가됩니다. 필드 선택기에서 필드를 제거하면 테이블에서 행이 삭제됩니다. 링크된 테이블 제어를 사용하면 필드 선택기에서 선택한 필드의 특성 등을 지정할 수 있습니다.

링크를 사용할 수 있으려면 콘텐츠의 변수 이름 특성을 가진 열이 테이블에 있어야 하고 캔버스에 필드 선택기 제어가 하나 이상 있어야 합니다.

테이블 제어를 필드 선택기에 링크하려면 사용 가능 제어 목록에서 필드 선택기를 테이블 열 대화 상자의 컨트롤에 연결 그룹에 지정합니다. 그런 다음 링크를 정의하는 테이블 열(링크된 열이라고 함)을 선택합니다. 테이블이 렌더링되면 링크된 열에 필드 선택기의 현재 필드가 표시됩니다. 다중 필드 필드 선택기에만 링크할 수 있습니다.

### ⑬ 항목 그룹

항목 그룹 제어란 사용자가 다중 제어로부터 생성된 스크립트를 그룹화하고 제어할 수 있도록 하는 기타 제어에 대한 컨테이너입니다. 예를 들어, 하위 명령에 대한 선택적 설정을 지정하는 선택란 세트가 있지만 하나 이상의 선택란이 선택된 경우에만 하위 명령에 대한 스크립트를 생성하고자 할 수 있습니다. 이 경우 항목 그룹 제어를 선택란 제어에 대한 컨테이너로 사용하여 해결할 수 있습니다. 필드 선택기, 선택란, 콤보 상자, 목록 상자, 텍스트 제어, 숫자 제어, 정적 텍스트, 라디오 그룹 및 파일 브라우저 유형의 제어가 항목 그룹에 포함될 수 있습니다. 항목 그룹에는 다음과 같은 특성이 있습니다.

**식별자.** 고유 제어용 식별자. 스크립트 양식에서 제어를 참조할 때 사용할 식별자입니다.

**제목.** 선택적 그룹 제목입니다. 복수 행 제목의 경우  $w_n$ 을 사용하여 줄 바꿈을 지정하십시오.

**스크립트.** 런타임 시 이 제어를 통해 생성 및 실행되며 스크립트 템플릿에 삽입할 수 있는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.
- 항목 그룹에 있는 모든 제어에 대한 식별자를 포함할 수 있습니다. 런타임 시 식별자가 제어를 통해 생성된 R 스크립트 또는 Python 스크립트로 대체됩니다.
- %%ThisValue%% 값은 항목 그룹의 각 제어에 의해 생성되는 R 스크립트 또는 Python 스크립트의 공백으로 구분한 목록을 그룹에 표시되는 순서(위쪽에서 아래쪽으로)대로 생성합니다.

다. 이는 기본값입니다. 스크립트 특성에 `%%ThisValue%%`가 포함되며 어떠한 스크립트도 항목 그룹의 제어에 의해서 생성되지 않으면 항목 그룹이 전체적으로 어떠한 스크립트도 생성하지 않습니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

#### ⑭ 라디오 그룹

라디오 그룹 제어는 단일 선택 단추 세트의 컨테이너로서 각 제어에 중첩된 제어 세트가 포함될 수 있습니다. 라디오 그룹에는 다음과 같은 특성이 있습니다.

**식별자.** 고유 제어용 식별자. 스크립트 양식에서 제어를 참조할 때 사용할 식별자입니다.

**제목.** 선택적 그룹 제목입니다. 복수 행 제목의 경우 `wn`을 사용하여 줄 바꿈을 지정하십시오.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**단일 선택 단추.** 생략 기호(...) 단추를 클릭하여 라디오 그룹 특성 대화 상자를 엽니다. 이렇게 하면 단일 선택 단추의 특성을 지정할 수 있으며 그룹에서 단추를 추가하거나 제거할 수 있습니다. 지정된 단일 선택 단추 아래 제어를 중첩할 수 있는 기능은 단일 선택 단추의 특성이며 라디오 그룹 특성 대화 상자에서 설정됩니다. 참고로, 캔버스에서 라디오 그룹 제어를 두 번 클릭하여 라디오 그룹 특성 대화 상자를 열 수도 있습니다.

**스크립트.** 런타임 시 이 제어를 통해 생성되며 스크립트 템플릿에 삽입할 수 있는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.
- `%%ThisValue%%` 값은 선택된 단일 선택 단추에 대한 스크립트 특성의 값인 단일 선택 단추 그룹의 런타임 값을 지정합니다. 이는 기본값입니다. 스크립트 특성에 `%%ThisValue%%`가 포함되며 어떠한 스크립트도 선택된 단일 선택 단추에 의해 생성되지 않은 경우, 단일 선택 단추 그룹은 어떠한 스크립트도 생성하지 않습니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

### 가. 단일 선택 단추 정의

단일 선택 단추 그룹 특성 대화 상자를 사용하여 단일 선택 단추의 그룹을 지정할 수 있습니다.

**식별자.** 단일 선택 단추에 대한 고유 식별자입니다.

**열 이름.** 단일 선택 단추 옆에 나타나는 이름입니다. 이 이름은 필수 필드입니다.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**기억용 키.** 이름에서 선택적 문자이며, 니모닉으로 사용됩니다. 지정된 문자가 이름에 존재해야 합니다.

**중첩된 그룹.** 기타 제어가 이 단일 선택 단추 아래 중첩될 수 있는지 여부를 지정합니다. 기본값은 false입니다. 중첩된 그룹 특성이 true로 설정되면, 연관된 단일 선택 단추 아래에 중첩되고 움푹 들어간 상태로 직사각형의 끌어놓기 영역이 표시됩니다. 필드 선택기, 선택란, 텍스트 제어, 정적 텍스트, 숫자 제어, 콤보 상자, 목록 상자 및 파일 브라우저 제어는 단일 선택 단추 아래에 중첩할 수 있습니다.

**기본값.** 단일 선택 단추를 기본 선택으로 할지 여부를 지정합니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

**스크립트.** 단일 선택 단추를 선택할 때 생성되는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.
- 중첩된 제어가 포함된 단일 선택 단추의 경우, %%ThisValue%% 값은 각 중첩 제어를 통해 생성되는 R 스크립트 또는 Python for Spark 스크립트를 공백으로 구분한 목록을 단일 선택 단추 아래에 표시되는 순서(위쪽에서 아래쪽으로)로 생성합니다.

기존 목록 아래에 있는 공백 행에 새 단일 선택 단추를 추가할 수 있습니다. 식별자를 제외한 다른 특성을 입력하면 고유 식별자가 생성되며 이를 저장 또는 수정할 수 있습니다. 단추의 식별자 셀을 클릭한 다음 삭제를 눌러 단일 선택 단추를 삭제할 수 있습니다.

## ⑮ 선택란 그룹

선택란 그룹 제어는 활성 또는 비활성 제어 세트를 하나의 그룹(단일 선택란)으로 만드는 컨테이너입니다. 필드 선택기, 선택란, 콤보 상자, 목록 상자, 텍스트 제어, 숫자 제어, 정적 텍스트, 라디오 그룹 및 파일 브라우저 유형의 제어가 선택란 그룹에 포함될 수 있습니다. 선택란 그룹에는 다음과 같은 특성이 있습니다.

**식별자.** 고유 제어용 식별자. 스크립트 양식에서 제어를 참조할 때 사용할 식별자입니다.

**제목.** 선택적 그룹 제목입니다. 복수 행 제목의 경우 `wn`을 사용하여 줄 바꿈을 지정하십시오.

**선택란 제목.** 선택란 제어에 표시되는 선택적 레이블입니다. 줄 바꿈을 지정하는 `wn`을 지원합니다.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**기억용 키.** 제목에 있는 선택적 문자로, 제어에 대한 키보드 단축키로 사용합니다. 문자는 밑줄이 그어져 제목에 표시됩니다. `Alt+[기억용 키]`를 누르면 단축키가 활성화됩니다.

**기본값.** 제어 선택란의 기본 설정 상태(선택 또는 선택 해제)입니다.

**선택된/선택 해제된 R 스크립트.** 제어를 선택하고 선택 해제할 때 생성되는 R 스크립트를 지정합니다. R 스크립트를 스크립트 템플릿에 포함하려면 식별자 특성의 값을 사용하십시오. 생성된 R 스크립트가 선택된 R 스크립트 또는 선택 해제된 R 스크립트 특성에서 생성되었는지에 상관없이 식별자의 지정된 위치에 삽입됩니다. 예를 들어, 식별자가 `checkboxgroup1`이면 런타임 시 스크립트 템플릿의 `%%checkboxgroup1%%`의 인스턴스가 선택된 R 스크립트 특성의 값(상자가 선택된 경우) 또는 선택 해제된 R 스크립트 특성의 값(상자가 선택 해제된 경우)으로 대체됩니다.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.
- 선택란 그룹에 있는 모든 제어에 대한 식별자를 포함할 수 있습니다. 런타임 시 식별자가 제어를 통해 생성된 R 스크립트로 대체됩니다.
- `%%ThisValue%%` 값은 선택된 R 스크립트 또는 선택 해제된 R 스크립트 특성에서 사용될 수 있습니다. 이는 선택란 그룹 내의 각 제어에 의해 생성되는 R 스크립트의 공백으로 구분한 목록을 그룹에 표시되는 순서(위쪽에서 아래쪽으로)대로 만듭니다.
- 기본적으로 선택된 R 스크립트 특성에는 `%%ThisValue%%` 값이 있으며 선택 해제된 R 스크립트 특성은 공백입니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

## ⑩ 파일 브라우저

파일 브라우저 제어는 파일 경로에 대한 텍스트 상자와 표준 IBM® SPSS® Modeler 대화 상자를 열어 파일을 열거나 저장하는 찾아보기 단추로 구성됩니다. 파일 브라우저 제어에는 다음과 같은 특성이 있습니다.

**식별자.** 고유 제어용 식별자. 스크립트 양식에서 제어를 참조할 때 사용할 식별자입니다.

**제목.** 제어 위에 나타나는 선택적 제목입니다. 복수 행 제목의 경우  $w_n$ 을 사용하여 줄 바꿈을 지정하십시오.

**제목 위치.** 제어와 관련된 제목의 위치를 지정합니다. 값은 위쪽(기본값) 및 왼쪽입니다.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**기억용 키.** 제목에 있는 선택적 문자로, 제어에 대한 키보드 단축키로 사용합니다. 문자는 밑줄이 그어져 제목에 표시됩니다. Alt+[기억용 키]를 누르면 단축키가 활성화됩니다.

**파일 시스템 작업.** 찾아보기 단추로 시작하는 대화 상자가 파일을 열거나 저장하는 데 적절한지 여부를 지정합니다. 열기 값은 찾아보기 대화 상자가 지정된 파일의 존재 여부를 검증하는 것을 나타냅니다. 저장 값은 찾아보기 대화 상자가 지정된 파일의 존재 여부를 검증하지 않는다는 것을 나타냅니다.

**브라우저 유형.** 찾아보기 대화 상자가 파일(파일 찾기) 또는 폴더(폴더 찾기)를 선택하는 데 사용되는지 여부를 지정합니다.

**파일 필터.** 생략 기호(...) 단추를 클릭하여 파일 필터 대화 상자를 여십시오. 대화 상자를 사용하여 열기 또는 저장 대화 상자에 대해 사용 가능한 파일 유형을 지정할 수 있습니다. 기본적으로 모든 파일 유형이 허용됩니다. 참고로, 캔버스에서 파일 브라우저 제어를 두 번 클릭하여 파일 필터 대화 상자를 열 수도 있습니다.

**파일 시스템 유형.** 분산 분석 모드에서, 이 옵션은 열기 대화 상자 또는 저장 대화 상자가 IBM SPSS Modeler Server가 실행되는 파일 시스템 또는 로컬 컴퓨터의 파일 시스템을 찾을지 여부를 지정합니다. 서버를 선택하여 서버의 파일 시스템을 찾아보거나 클라이언트를 선택하여 로컬 컴퓨터의 파일 시스템을 찾아봅니다. 특성은 로컬 분석 모드에 아무런 영향을 미치지 않습니다.

**실행에 필수.** 이 제어를 실행하는 데 값이 필요한지 여부를 지정합니다. **true**가 지정되면 노드 대화 상자의 사용자가 제어에 대한 값을 지정해야 합니다. 그렇지 않으면 **확인** 단추를 클릭할 때 오류가 생성됩니다. **false**가 지정되면 이 제어의 값이 없어도 **확인** 단추의 상태에 영향을 미치지 않습니다. 기본값은 **false**입니다.

**기본값.** 제어의 기본값입니다.

**스크립트.** 런타임 시 이 제어를 통해 생성되며 스크립트 템플릿에 삽입할 수 있는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.

- 유효한 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있습니다. 복수 행 스크립트 또는 긴 스크립트의 경우 생략 기호(...) 단추를 클릭하고 스크립트 특성 대화 상자에 스크립트를 입력하십시오.
- %%ThisValue%% 값은 수동으로 지정되거나 찾아보기 대화 상자에서 채운 큰따옴표로 묶은 파일 경로인 텍스트 상자의 런타임 값을 지정합니다. 이는 기본값입니다.
- 스크립트 특성에 %%ThisValue%%가 포함되어 있고 텍스트 상자의 런타임 값이 비어 있을 경우, 파일 브라우저 제어가 어떠한 스크립트도 생성하지 않습니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

#### 가. 파일 유형 필터

파일 필터 대화 상자를 사용하여 유형에 대한 파일에 표시되는 파일 유형과 파일 시스템 브라우저 제어에서 액세스하는 열기 및 저장 대화 상자에 대한 다른 이름으로 저장 유형의 드롭 다운 목록을 지정할 수 있습니다. 기본적으로 모든 파일 유형이 허용됩니다.

대화 상자에 명시적으로 표시되지 않은 파일 유형을 지정하려면 다음을 수행하십시오.

1. 기타를 선택합니다.
2. 파일 유형에 대한 이름을 입력합니다.
3. \*.suffix(예: \*.xls) 형식을 사용하여 파일 유형을 입력합니다. 여러 파일 유형을 지정하여 세미콜론(;)으로 각각의 파일 유형을 구분할 수 있습니다.

#### ⑰ 탭

탭 제어는 노드 대화 상자에 탭을 추가합니다. 기타 제어는 새 탭에 추가될 수 있습니다. 탭 제어에는 다음과 같은 특성이 있습니다.

**식별자.** 고유 제어용 식별자.

**제목.** 탭 제목입니다.

**위치.** 노드 대화 상자의 다른 탭과 비교하여 노드 대화 상자의 탭 위치를 지정합니다.

**스크립트.** 런타임 시 이 제어로 생성 및 실행하고 스크립트 템플릿에 삽입할 수 있는 R 스크립트 또는 Python for Spark 스크립트를 지정합니다.

- 유효한 모든 R 스크립트 또는 Python for Spark 스크립트를 지정할 수 있으며  $w_n$ 을 줄 바꿈기로 사용할 수 있습니다.
- `%%ThisValue%%` 값은 탭의 각 제어를 통해 생성된 R 스크립트 또는 Python for Spark 스크립트를 공백으로 구분한 목록을 탭에 표시되는 순서(위쪽에서 아래쪽으로, 왼쪽에서 오른쪽으로)로 생성합니다. 이는 기본값입니다.
- 스크립트 특성에 `%%ThisValue%%`이 포함되어 있고 탭의 제어를 통해 R 스크립트 또는 Python for Spark 스크립트가 생성되지 않는 경우, 전체적으로 탭이 스크립트를 생성하지 않습니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다.

### ⑩ 하위 대화 상자 단추

하위 대화 상자 단추 제어를 사용하여 하위 대화 상자 시작 단추를 지정하고 하위 대화 상자의 대화 상자 작성기에 액세스할 수 있습니다. 하위 대화 상자 단추에는 다음과 같은 특성이 있습니다.

**식별자.** 고유 제어용 식별자.

**제목.** 단추에 표시되는 텍스트입니다.

**도구팁.** 사용자를 제어 위에 두면 선택적 도구 팁이 나타납니다.

**하위 대화 상자.** 생략 기호(...) 단추를 클릭하여 하위 대화 상자에 대한 사용자 정의 대화 상자 작성기를 엽니다. 또한 하위 대화 상자 단추를 두 번 클릭하여 작성기를 열 수 있습니다.

**기억용 키.** 제목에 있는 선택적 문자로, 제어에 대한 키보드 단축키로 사용합니다. 문자는 밑줄이 그어져 제목에 표시됩니다. Alt+[기억용 키]를 누르면 단축키가 활성화됩니다.

**사용 규칙.** 현재 제어가 사용 가능할 때 결정되는 규칙을 지정합니다. 생략 기호(...) 단추를 클

릭하여 사용 규칙 대화 상자를 열고 규칙을 지정하십시오. 사용 규칙 특성은 사용 규칙을 지정하는 데 사용할 수 있는 다른 제어가 캔버스에 존재하는 경우에만 표시됩니다

 **참고:** 하위 대화 상자 단추 제어는 하위 대화 상자에 추가될 수 없습니다.

### 가. 하위 대화 상자의 대화 상자 특성

하위 대화 상자를 보고 특성을 설정하려면 다음을 수행하십시오.

1. 기본 대화 상자에 있는 하위 대화 상자의 단추를 두 번 클릭하여 하위 대화 상자를 열거나 하위 대화 상자 단추를 한 번 클릭하고 생략 기호(...) 단추를 클릭하여 하위 대화 상자 특성을 엽니다.
2. 하위 대화 상자에서 제어를 벗어난 영역에 있는 캔버스를 클릭합니다. 제어가 없는 캔버스에서는 하위 대화 상자 특성이 항상 표시됩니다.

**하위 대화 상자 이름.** 하위 대화 상자의 고유 식별자입니다. 하위 대화 상자 이름 특성이 필요합니다.

 **참고:** %%My Sub-dialog Name%%에서와 같이 스크립트 템플릿에서 식별자로서 하위 대화 상자 이름을 지정하는 경우, 이는 런타임 시에 하위 대화 상자의 각 제어에 의해 생성되는 스크립트의 공백으로 구분한 목록으로 표시되는 순서(위쪽에서 아래쪽으로 및 왼쪽에서 오른쪽으로)대로 대체됩니다.

**제목.** 하위 대화 상자의 제목 표시줄에 표시되는 텍스트를 지정합니다. 제목 특성은 선택 사항이지만 지정하는 것이 좋습니다.

**도움말 파일.** 하위 대화 상자의 선택적 도움말 파일에 대한 경로를 지정합니다. 도움말 파일은 사용자가 하위 대화 상자의 도움말 단추를 클릭하면 시작되는 파일로, 기본 대화 상자에 지정된 도움말 파일과 같을 수 있습니다. 도움말 파일은 HTML 형식이어야 합니다. 자세한 정보는 대화 상자 특성의 도움말 파일 특성에 대한 설명을 참조하십시오.

### ⑨ 제어의 사용 규칙 지정

제어가 사용되는 시점을 결정하는 규칙을 지정할 수 있습니다. 예를 들어, 필드 선택기(가) 채워져 있을 때 라디오 그룹이 사용되도록 지정할 수 있습니다. 사용 규칙을 지정하는 데 사용할 수 있는 옵션은 규칙을 정의하는 제어 유형에 따라 다릅니다.

#### 필드 선택기

필드 선택기가 하나 이상의 필드로 채워져 있을 때(비어 있지 않음) 현재 제어가 사용되도록 지정할 수 있습니다. 필드 선택기가 채워져 있지 않을 때(비어 있음) 현재 제어가 사용되도록 지정할 수도 있습니다.

### 선택란 또는 선택란 그룹

선택란 또는 선택란 그룹이 선택되었을 때 현재 제어가 사용되도록 지정할 수 있습니다. 또는 선택란 또는 선택란 그룹이 선택되지 않았을 때 현재 제어가 사용되도록 지정할 수 있습니다.

### 콤보 상자 또는 단일 선택 목록 상자

콤보 상자 또는 단일 선택 목록 상자에 특정 값이 선택되었을 때 현재 제어가 사용되도록 지정할 수 있습니다. 또는 콤보 상자 또는 단일 선택 목록 상자에 특정 값이 선택되어 있지 않을 때 현재 제어가 사용되도록 지정할 수 있습니다.

### 다중 선택 목록 상자

특정 값이 다중 선택 목록 상자에 선택된 값 중 하나일 때 현재 제어가 사용되도록 지정할 수 있습니다. 또는 특정 값이 다중 선택 목록 상자에 선택된 값 중 하나가 아닐 때 현재 제어가 사용되도록 지정할 수 있습니다.

### 라디오 그룹

특정 단일 선택 단추가 선택되었을 때 현재 제어가 사용되도록 지정할 수 있습니다. 또는 특정 단일 선택 단추가 선택되지 않았을 때 현재 제어가 사용되도록 지정할 수 있습니다.

사용 규칙을 지정할 수 있는 제어는 사용 규칙 특성과 연관됩니다.

#### 참고:

- 사용 규칙은 해당 규칙을 정의하는 제어가 사용되는지 여부와 관계 없이 적용됩니다. 예를 들어, 필드 선택기(가) 채워져 있을 때 라디오 그룹이 사용되도록 지정하는 규칙을 고려하십시오. 이 규칙에 따르면 필드 선택기의 사용 여부와 관계 없이 필드 선택기(가) 채워져 있으면 언제든지 라디오 그룹이 사용됩니다.
- 탭 제어가 사용되지 않으면, 해당 탭의 제어 중 임의 제어에 조건이 충족되는 사용 규칙이 있는지 여부와 관계 없이 탭의 모든 제어가 사용되지 않습니다.
- 선택란 그룹이 사용되지 않으면, 제어 역할을 하는 선택란의 선택 여부와 무관하게 해당 그룹의 모든 제어가 사용되지 않습니다.

## (8) 확장 특성

확장 특성 대화 상자는 확장에 대한 사용자 정의 대화 상자 작성기 내에서 현재 확장에 대한 정보(예: 확장 이름, 확장 내의 파일)를 지정합니다.

- 확장에 대한 사용자 정의 대화 상자 작성기에서 작성된 모든 사용자 정의 노드 대화 상자는 확장의 일부입니다.
- 확장 및 확장에 포함된 사용자 정의 노드 대화 상자를 설치할 수 있으려면 먼저 확장 특성 대화 상자의 필수 탭에 있는 필드를 지정해야 합니다.

확장의 특성을 지정하려면 확장에 대한 사용자 정의 대화 상자 작성기의 메뉴에서 다음을 선택하십시오.

확장 > 특성

## ① 확장의 필수 특성

### 이름

확장과 연관될 고유한 이름입니다. 최대 3개 단어로 구성되며 대소문자는 구분하지 않습니다. 7비트 ASCII 문자로 제한됩니다. 이름 충돌 가능성을 최소화하기 위해 여러 단어로 된 이름을 사용할 수 있습니다. 첫 번째 단어는 사용자 조직에 대한 식별자를 붙일 수 있습니다(예: URL). 확장을 저장할 때 기본적으로 해당 이름이 확장 번들(.mpe) 파일 이름에도 사용됩니다. 저장할 때 기본 이름을 사용할 것을 권장합니다. 다른 이름으로 저장하면 나중에 확장을 설치 제거할 수 없습니다.

### 요약

한 행으로 표시되는 확장에 대한 짧은 설명.

### 버전

x.x.x 형식의 버전 식별자입니다. 식별자의 각 구성요소는 정수여야 합니다(예: 1.0.0). 제공하지 않을 경우 0을 의미합니다. 예를 들어 버전 식별자 3.1은 3.1.0을 의미합니다. 버전 식별자는 IBM® SPSS® Modeler 버전과 별개입니다.

### 최소 SPSS Modeler 버전

확장을 실행하는 데 필요한 최소 SPSS Modeler 버전.

### 파일

파일 목록에는 확장에 현재 포함되어 있는 파일이 표시됩니다. 확장에 파일을 추가하려면 추가를 클릭합니다. 확장에서 파일을 제거하거나 파일을 지정된 폴더에 추출할 수도 있습니다.

- 사용자 정의 노드 대화 상자는 .cfe의 파일 유형을 가집니다.
- 확장의 구성요소에 대한 번역 파일이 선택사항 탭의 현지화 설정에서 추가됩니다.
- 확장에 readme 파일을 추가할 수 있습니다. 파일 이름을 ReadMe.txt로 지정하십시오. 사용자는 확장에 대한 세부사항을 표시하는 대화 상자에서 readme 파일에 액세스할 수 있습니다. ReadMe\_<language identifier>.txt(프랑스어 버전의 경우 ReadMe\_fr.txt)로 지정된 readme 파일의 현지화된 버전을 포함시킬 수 있습니다.

## ② 확장의 선택적 특성

### 일반 특성

#### 설명

확장에 대해 요약 필드보다 자세하게 제공되는 설명. 예를 들어, 확장에서 사용 가능한 주요 기능을 나열할 수 있습니다.

#### 날짜

확장의 현재 버전에 대한 선택적 날짜. 형식은 제공되지 않습니다.

#### 작성자

확장의 작성자. 이메일 주소를 포함시킬 수 있습니다.

## 링크

확장과 연결되는 일련의 URL(예: 작성자의 홈 페이지). 이 필드의 형식은 임의대로 지정할 수 있으므로 공백, 심표 또는 기타 적합한 구분자를 사용하여 여러 URL을 구분해야 합니다.

## 키워드

확장과 연결되는 일련의 키워드.

## 플랫폼

특정 운영 체제 플랫폼에서 확장을 사용할 때 적용할 제한사항에 대한 정보.

## 종속성

### Maximum SPSS Modeler 버전

확장이 실행될 수 있는 IBM® SPSS® Modeler의 최대 버전.

### Integration Plug-in for R 필수

Integration Plug-in for R의 필수 여부를 지정합니다.

확장에서 CRAN 패키지 저장소의 R 패키지가 필요한 경우 해당 패키지의 이름을 '필수 R 패키지' 제어에 입력하십시오. 이름은 대소문자를 구분합니다. 첫 번째 패키지를 추가하려면 필수 R 패키지 제어에서 아무 곳이나 클릭하여 입력 필드를 강조표시합니다. 지정된 행에 커서를 놓은 상태에서 **Enter**를 누르면 새 행이 만들어집니다. 행을 선택하고 **Delete**를 누르면 행을 삭제할 수 있습니다.

## 현지화

### 사용자 정의 노드

확장 내의 사용자 정의 노드 대화 상자에 대해 번역된 버전의 특성 파일(노드 대화 상자에 표시되는 모든 문자열을 지정)을 추가할 수 있습니다. 특정 노드 대화 상자에 대한 번역을 추가하려면 번역 추가를 클릭하고 번역된 버전이 포함된 폴더를 선택합니다. 특정 노드 대화 상자의 모든 번역된 파일은 동일한 폴더에 있어야 합니다. 번역 파일 작성에 대한 지시사항은 사용자 정의 노드 대화 상자의 현지화된 버전 생성 주제를 참조하십시오.

### 번역 카탈로그 폴더

일반 사용자가 확장 허브에서 확장 세부사항을 볼 때 표시되는 확장에 대해 현지화된 버전의 **요약** 및 **설명** 필드를 제공할 수 있습니다. 확장의 현지화된 모든 파일 세트는 lang이라는 폴더에 있어야 합니다. 현지화된 파일이 포함된 lang 폴더를 찾아 해당 폴더를 선택하십시오.

**요약** 및 **설명** 필드의 현지화된 버전을 제공하려면 번역이 제공되는 언어마다 <extension name>\_<language-identifier>.properties라는 파일을 작성하십시오. 런타임 시 현재 사용자 인터페이스 언어의 .properties 파일이 없으면 필수 및 선택사항 탭에 지정된 요약 및 설명 필드의 값을 사용합니다.

- <extension name>은 확장의 이름 필드 값이며 공백은 밑줄 문자로 대체됩니다.
- <language-identifier>는 특정 언어의 ID입니다. IBM SPSS Modeler가 지원하는 언어의 ID에 대해서는 뒤에서 설명합니다.

예를 들어, MYORG MYSTAT라는 확장어 프랑수어 번역은 MYORG\_MYSTAT\_fr.properties 파일에 저장되어 있습니다.

.properties 파일에는 두 필드의 현지화된 텍스트를 지정하는 다음 두 행이 포함되어 있어야 합니다.

```
Summary=<localized text for Summary field>  
Description=<localized text for Description field>
```

- 요약 및 설명 키워드는 영어로 되어 있어야 하며, 현지화된 텍스트는 키워드와 동일한 행에 있어야 하고 줄 바꿈이 없어야 합니다.
- 파일은 ISO 8859-1 인코딩이어야 합니다. 이 인코딩에서 직접 표시할 수 없는 문자는 유니코드 이스케이프("\u")로 작성해야 합니다.

현지화된 파일이 포함된 lang 폴더에는 특정 언어의 현지화된 .properties 파일이 포함된 <language-identifier>라는 하위 폴더가 있어야 합니다. 예를 들어, 프랑수어 .properties 파일은 lang/fr 폴더에 있어야 합니다.

언어 식별자

de. 독일어

en. 영어

es. 스페인어

fr. 프랑수어

it. 이탈리아어

ja. 일본어

ko. 한국어

pl. 폴란드어

pt\_BR. 브라질 포르투갈어

ru. 러시아어

zh\_CN. 중국어

zh\_TW. 대만어

## (9) 사용자 정의 노드 대화 상자 관리

확장에 대한 사용자 정의 대화 상자 작성기를 사용하여 사용자 또는 다른 사용자가 만든 확장 내에서 사용자 정의 노드 대화 상자를 관리할 수 있습니다. 사용자 정의 노드 대화 상자를 사용하려면 필요한 SPSS® Modeler 클라이언트 또는 SPSS Modeler Batch의 모든 인스턴스에 먼저 이를 설치해야 합니다. 서버 모드에서 사용자 정의 대화 상자 노드를 사용하려면 SPSS Modeler Server에 설치할 필요가 없습니다.

 **참고:** IBM® SPSS Modeler에서 작성된 사용자 정의 노드 대화 상자만 수정할 수 있습니다.

### 사용자 정의 노드 대화 상자를 포함하는 확장 열기

사용자 정의 노드 대화 상자에 대한 스펙을 포함하는 확장 번들 파일(.mpe)을 열거나 설치된 확장을 열 수 있습니다. 확장에서 노드 대화 상자를 수정한 후 저장하거나 확장을 설치할 수 있습니다. 확장을 설치하면 확장에 포함된 노드 대화 상자도 설치됩니다. 확장을 저장하면 확장 내의 노드 대화 상자에 수행된 변경사항도 저장됩니다.

확장 번들 파일을 열려면 확장에 대한 사용자 정의 대화 상자 작성기의 메뉴에서 다음을 선택합니다.

#### 파일 > 열기

설치된 확장을 열려면 확장에 대한 사용자 정의 대화 상자 작성기의 메뉴에서 다음을 선택합니다.

#### 파일 > 설치한 대화 상자 열기

 **참고:** 설치한 확장을 열어 이를 수정할 경우 **파일 > 설치**를 선택하면 확장이 다시 설치되어 기존 버전을 대체하게 됩니다. 사용자 정의 대화 상자 작성기를 사용하여 작성된 노드의 컨텍스트 메뉴에서 **편집**을 사용하면 노드 대화 상자가 사용자 정의 대화 상자 작성기에서 열리지 않습니다.

### 확장 번들 파일에 저장

'확장에 대한 사용자 정의 대화 상자 작성기'에 열려 있는 확장을 저장하면 확장에 포함된 사용자 정의 노드 대화 상자도 저장됩니다. 확장은 확장 번들 파일(.mpe)에 저장됩니다. 확장 특성 대화 상자의 **이름** 필드에서 지정된 이름과 일치하는 기본 이름을 유지할 것을 권장합니다.

확장에 대한 사용자 정의 대화 상자 작성기의 메뉴에서 다음을 선택합니다.

#### 파일 > 저장

## 확장 설치

'확장에 대한 사용자 정의 대화 상자 작성기'에 열려 있는 확장을 설치하면 확장에 포함된 사용자 정의 노드 대화 상자도 설치됩니다. 기존 확장을 설치하면 이미 설치된 확장의 모든 사용자 정의 노드 대화 상자를 포함하는 기존 버전이 대체됩니다.

현재 열려 있는 확장을 설치하려면 확장에 대한 사용자 정의 대화 상자 작성기의 메뉴에서 다음을 선택합니다.

### 파일 > 설치

기본적으로 확장은 운영 체제의 일반 사용자 쓰기 가능 위치에 설치됩니다. 자세한 정보는 확장의 설치 위치 주제를 참조하십시오.

**참고:** 오픈 스트림에서는 확장에 포함된 노드 대화 상자의 기존 버전이 대체되지 않습니다. 다시 설치된 사용자 정의 대화 상자 작성기 노드가 있는 시스템을 열면 경고 메시지를 받습니다.

## 확장 설치 제거

확장에 대한 사용자 정의 대화 상자 작성기의 메뉴에서 다음을 선택합니다.

### 파일 > 제거

확장을 설치 제거하면 확장에 포함된 모든 사용자 정의 노드 대화 상자도 설치 제거됩니다. 확장 허브에서 확장을 설치 제거할 수도 있습니다.

**참고:** 확장을 설치 제거하려면 확장 번들 .mpe 파일 이름이 확장 특성 대화 상자에서 지정된 이름과 일치해야 합니다. 이것이 기본 파일 이름입니다. 파일 이름을 수정한 경우, 이름 필드와 일치하도록 이름을 변경하고 설치를 다시 시도하십시오.

## 사용자 정의 대화 상자 패키지 파일 가져오기

사용자 정의 대화 상자 패키지(.cfd) 파일을 '확장에 대한 사용자 정의 대화 상자 작성기'에 가져올 수 있습니다. .cfd 파일은 .cfe 파일로 변환되어 새 확장에 추가됩니다.

확장에 대한 사용자 정의 대화 상자 작성기의 메뉴에서 다음을 선택합니다.

### 파일 > 가져오기

확장 특성 대화 상자에서 .cfe 파일을 확장에 추가할 수도 있으며 이 대화 상자는 '확장에 대한 사용자 정의 대화 상자 작성기' 내의 **확장 > 특성**에서 액세스합니다.

## 사용자 정의 노드 대화 상자를 확장에 추가

새로운 사용자 정의 노드 대화 상자를 확장에 추가할 수 있습니다.

확장에 대한 사용자 정의 대화 상자 작성기의 메뉴에서 다음을 선택합니다.

**확장 > 새 대화 상자**

## 확장에서 여러 사용자 정의 노드 대화 상자 간에 전환

현재 확장에 여러 사용자 정의 노드 대화 상자가 있는 경우 이 대화 상자 간에 전환할 수 있습니다.

확장에 대한 사용자 정의 대화 상자 작성기의 메뉴에서 다음을 선택합니다.

**확장 > 대화 상자 편집**을 선택하고, 작업하려는 사용자 정의 노드 대화 상자를 선택합니다.

## 새 확장 작성

'확장에 대한 사용자 정의 대화 상자 작성기'에서 새 확장을 작성하면 비어 있는 새로운 사용자 정의 노드 대화 상자가 확장에 추가됩니다.

새 확장을 작성하려면 확장에 대한 사용자 정의 대화 상자 작성기의 메뉴에서 다음을 선택합니다.

**파일 > 새로 만들기**

## SPSS Modeler Batch 또는 IBM SPSS Collaboration and Deployment Services의 확장

SPSS Modeler Batch 또는 IBM SPSS Collaboration and Deployment Services 설치에서 확장을 사용하려면 대상 환경에 환경 변수 *IBM\_SPSS\_MODELER\_EXTENSION\_PATH*가 정의되어 있고 이 변수가 확장이 포함된 위치를 가리켜야 합니다.

*IBM\_SPSS\_MODELER\_EXTENSION\_PATH* 환경 변수가 정의되기 전에 사용자 정의 노드가 포함된 스트림이 IBM SPSS Collaboration and Deployment Services Repository에 저장된 경우, 성공적으로 실행되기 전에 우선 스트림을 리포지토리로 복원해야 합니다.

 **참고:** SPSS Modeler용 SPSS Modeler Batch 또는 IBM SPSS Collaboration and Deployment Services 어댑터의 버전이 확장이 작성된 SPSS Modeler 클라이언트의 버전과 일치하는지 확인하십시오.

## (10) 사용자 정의 노드 대화 상자의 현지화된 버전 생성

IBM® SPSS® Modeler에 의해 지원되는 모든 언어에 대해 사용자 정의 노드 대화 상자의 현지화된 버전을 작성할 수 있습니다. 사용자 정의 노드 대화 상자에 표시되는 모든 문자열을 현지화할 수 있으며 선택적 도움말 파일을 현지화할 수 있습니다.

### 대화 상자 문자열 현지화

배포하려는 언어마다 사용자 정의 노드 대화 상자와 연관된 특성 파일의 사본을 만들어야 합니다. 특성 파일에는 노드 대화 상자와 연관된 현지화할 수 있는 모든 문자열이 포함됩니다.

(확장에 대한 사용자 정의 대화 상자 작성기 내의) 확장 특성 대화 상자에서 파일을 선택하고 **추출**을 클릭하여 확장에서 사용자 정의 노드 대화 상자 파일(.cfe)을 추출합니다. 그런 다음 .cfe 파일의 콘텐츠를 추출합니다. .cfe 파일은 단지 .zip 파일입니다. .cfe 파일의 추출된 콘텐츠는 지원되는 각 언어의 특성 파일을 포함하며, 여기서 특정 언어의 파일 이름은 <Dialog Name>\_<language identifier>.properties 형식을 따릅니다(뒤에 나오는 언어 식별자 참조).

1. Windows의 메모장과 같이 UTF-8을 지원하는 텍스트 편집기로, 번역하려는 각 특성 파일을 엽니다. 현지화할 모든 특성과 관련된 값을 수정합니다. 단, 특성 이름은 수정하지 않습니다. 특정 제어와 관련된 특성은 제어의 식별자가 앞에 옵니다. 예를 들어, 식별자 options\_button을 포함한 제어의 도구 팁 특성은 options\_button\_tooltip\_LABEL입니다. 제목 특성의 이름은 options\_button\_LABEL과 같이 간단한 <identifier>\_LABEL로 지정됩니다.
2. 확장 특성 대화 상자의 선택사항 탭에 있는 현지화 설정에서 사용자 정의 노드 대화 상자 파일(.cfe)에 현지화된 버전의 특성 파일을 다시 추가합니다. 자세한 정보는 확장의 선택적 특성 주제를 참조하십시오.

노드 대화 상자가 시작되면 IBM SPSS Modeler는 옵션 대화 상자에 있는 일반 탭의 언어 드롭다운으로 지정된 대로 현재 언어에 맞는 언어 식별자의 특성 파일을 검색합니다. 이러한 특성 파일이 없는 경우 기본 파일 <Dialog Name>.properties가 사용됩니다.

### 도움말 파일 현지화

1. 사용자 정의 노드 대화 상자와 연관된 도움말 파일의 사본을 작성하고 원하는 언어에 대한 텍스트를 현지화합니다.

2. 아래 테이블에 있는 언어 식별자를 사용하여 복사본의 이름을 <Help File>\_<language identifier>.htm으로 바꿉니다. 예를 들어, 도움말 파일이 myhelp.htm이고 파일의 독일어 버전을 작성하려면 현지화된 도움말 파일의 이름을 myhelp\_de.htm으로 다시 지정해야 합니다.

현지화된 모든 버전의 도움말 파일을 현지화되지 않은 버전과 동일한 디렉토리에 저장합니다. 대화 상자 특성의 도움말 파일 특성에서 현지화되지 않은 파일을 추가하면 현지화된 버전이 자동으로 노드 대화 상자에 추가됩니다.

현지화해야 하는 보조 파일(예: 이미지 파일)이 있는 경우 현지화된 버전을 가리키는 기본 도움말 파일의 해당 경로를 직접 수정해야 합니다. 현지화된 버전 등의 보조 파일은 사용자 정의 노드 대화 상자(.cfe) 파일에 수동으로 추가되어야 합니다. 사용자 정의 노드 대화 상자 파일의 액세스 및 수동 수정 방법에 대한 정보는 앞의 "대화 상자 문자열을 현지화하려면" 섹션을 참조하십시오.

노드 대화 상자가 시작되면 IBM SPSS Modeler는 옵션 대화 상자에 있는 일반 탭의 언어 드롭 다운으로 지정된 대로 현재 언어에 맞는 언어 식별자의 도움말 파일을 검색합니다. 해당 도움말 파일을 찾을 수 없으면 노드 대화 상자에 대해 지정된 도움말 파일(대화 상자 특성의 도움말 파일 특성에서 지정된 파일)이 사용됩니다.

언어 식별자

de. 독일어

en. 영어

es. 스페인어

fr. 프랑스어

it. 이탈리아어

ja. 일본어

ko. 한국어

pl. 폴란드어

pt\_BR. 브라질 포르투갈어

ru. 러시아어

zh\_CN. 중국어

zh\_TW. 대만어

**참고:** 사용자 정의 노드 대화 상자 및 연관된 도움말 파일 내의 텍스트는 IBM SPSS Modeler에 의해 지원되는 언어로 제한되지 않습니다. 언어별 특성 및 도움말 파일을 작성하지 않고 모든 언어로 자유롭게 노드 대화 상자 및 도움말 텍스트를 작성할 수 있습니다. 그러면 노드 대화 상자의 모든 사용자가 해당 언어로 텍스트를 볼 수 있습니다.

## (11) Python for Spark를 사용하여 데이터 가져오기 및 내보내기

확장에 대해 사용자 정의 대화 상자 작성기를 사용하여 사용자 정의 노드를 작성하고 Python for Spark 스크립트를 작성하여 데이터 소스가 있는 임의의 위치에서 데이터를 읽고 Apache Spark가 지원하는 임의의 데이터 형식으로 데이터를 쓸 수 있습니다.

예를 들어, 사용자가 자신의 데이터를 데이터베이스에 쓰려는 경우를 가정합니다. 확장에 대한 사용자 정의 대화 상자 작성기 및 Python for Spark를 사용하여 사용자 정의 내보내기 JDBC 노드를 작성한 다음 모델을 실행하여 데이터를 데이터베이스에 쓸 수 있습니다. 데이터베이스에서 데이터를 읽기 위해서 사용자 정의 가져오기 노드를 작성할 수도 있습니다. 이 경우에도 동일한 방법을 사용하여 데이터를 JSON 파일에서 SPSS® Modeler로 읽어옵니다. 예를 들어, 다음과 같습니다. 그런 다음 데이터를 SPSS Modeler로 읽어온 후에 모든 사용 가능한 SPSS Modeler 노드를 사용하여 비즈니스 문제점에 대해 작업할 수 있습니다.

**i 참고:** Python for Spark 가져오기 및 내보내기 기능과 함께 JDBC를 사용하려는 경우, JDBC 드라이버 파일을 IBM® SPSS Modeler 설치 디렉토리 내의 as/lib 디렉토리로 복사해야 합니다.

## Python for Spark를 사용하여 데이터 가져오기 및 내보내기

1. **확장** > **사용자 정의 노드 대화 상자 작성기**로 이동하십시오.
2. 대화 상자 특성 아래에서 스크립트 유형에 대해 **Python for Spark**를 선택하고 노드 유형에 대해 **가져오기** 또는 **내보내기**를 선택하십시오.
3. 대화 상자 이름과 같이 필요한 기타 특성을 입력하십시오.
4. 스크립트 섹션에 데이터를 가져오거나 내보내는 데 필요한 Python for Spark 스크립트를 입력하거나 붙여넣으십시오.
5. **설치**를 클릭하여 Python for Spark 스크립트를 설치하십시오. 새 사용자 정의 가져오기 노드가 소스 팔레트에 추가되고 새 사용자 정의 내보내기 노드가 내보내기 팔레트에 추가됩니다.

## (12) R을 사용하여 데이터 가져오기 및 내보내기

확장에 대해 사용자 정의 대화 상자 작성기를 사용하여 사용자 정의 노드를 작성하고 R 스크립트를 작성하여 데이터 소스가 있는 임의의 위치에서 데이터를 읽고 R이 지원하는 임의의 데이터 형식으로 데이터를 쓸 수 있습니다.

예를 들어, 사용자가 자신의 데이터를 데이터베이스에 쓰려는 경우를 가정합니다. 확장에 대한 사용자 정의 대화 상자 작성기 및 R 스크립팅을 사용하여 사용자 정의 내보내기 JDBC 노드를 작성한 다음 모델을 실행하여 데이터를 데이터베이스에 쓸 수 있습니다. 데이터베이스에서 데이터를 읽기 위해서 사용자 정의 가져오기 노드를 작성할 수도 있습니다. 이 경우에도 동일한 방법을 사용하여 데이터를 JSON 파일에서 SPSS® Modeler로 읽어옵니다. 예를 들어, 다음과 같습니다. 그런 다음 데이터를 SPSS Modeler로 읽어온 후에 모든 사용 가능한 SPSS Modeler 노드를 사용하여 비즈니스 문제점에 대해 작업할 수 있습니다.

R을 사용하여 데이터 가져오기 및 내보내기

1. **확장 > 사용자 정의 노드 대화 상자 작성기**로 이동하십시오.
2. 대화 상자 특성 아래에서 스크립트 유형에 대해 **R**을 선택하고 노드 유형에 대해 **가져오기** 또는 **내보내기**를 선택하십시오.
3. 대화 상자 이름과 같이 필요한 기타 특성을 입력하십시오.
4. 스크립트 섹션에 데이터를 가져오거나 내보내는 데 필요한 R 스크립트를 입력하거나 붙여넣으십시오.
5. **설치**를 클릭하여 R 스크립트를 설치하십시오. 새 사용자 정의 가져오기 노드가 소스 팔레트에 추가되고 새 사용자 정의 내보내기 노드가 내보내기 팔레트에 추가됩니다.

## V. IBM SPSS Modeler CRISP-DM 안내서

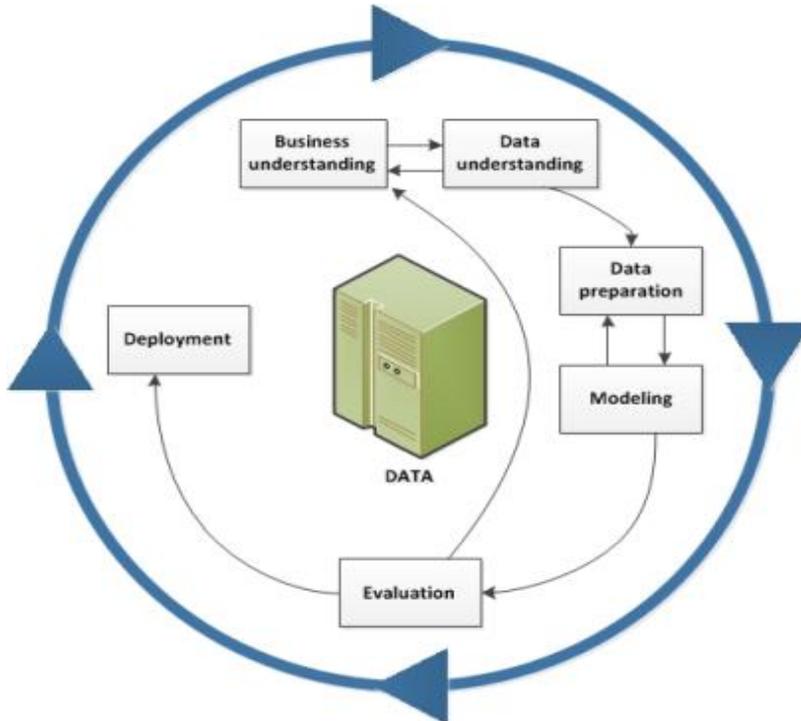
### 1. CRISP-DM 소개

#### 1) CRISP-DM 도움말 개요

CRISP-DM(Cross-Industry Standard Process for Data Mining의 약자)은 데이터 마이닝 작업을 안내하기 위해 업계에서 검증된 방법입니다.

- **방법론**으로서, 이 방법은 프로젝트의 일반적 단계에 대한 설명, 각 단계와 관련된 작업 및 이러한 작업 사이의 관계 설명을 포함합니다.
- **프로세스 모델**로서, CRISP-DM은 데이터 마이닝 라이프사이클의 개요를 제공합니다.

그림 1. 데이터 마이닝 라이프사이클



라이프사이클 모델은 6개의 단계로 구성되며 단계 사이에는 가장 중요하고 빈번한 종속 항목을 표시하는 화살표가 있습니다. 단계의 순서는 엄격하지 않습니다. 결국, 대부분의 프로젝트는 필요에 따라 단계 사이를 앞뒤로 이동합니다.

CRISP-DM 모델은 유연하므로 쉽게 사용자 정의할 수 있습니다. 예를 들어, 조직에서 자금 세탁을 감지하는 것이 목표라면 특정 모델링 목적 없이 대량의 데이터를 조사하게 될 것입니다. 모델링 대신에, 사용자의 작업은 재무 데이터에서 의심스러운 패턴을 밝히기 위해 데이터 탐색 및 시각화에 초점을 맞출 것입니다. CRISP-DM을 사용하면 특정 요구사항에 맞는 데이터 마이닝 모델을 작성할 수 있습니다.

이러한 상황에서 모델링, 평가 및 배포 단계는 데이터 이해 및 준비 단계보다 관련성이 부족할 수 있습니다. 그러나 장기 계획 및 이후의 데이터 마이닝 목적을 위해 이러한 이후 단계 동안 제기된 일부 질문을 고려하는 것은 여전히 중요합니다.

### (1) IBM SPSS Modeler의 CRISP-DM

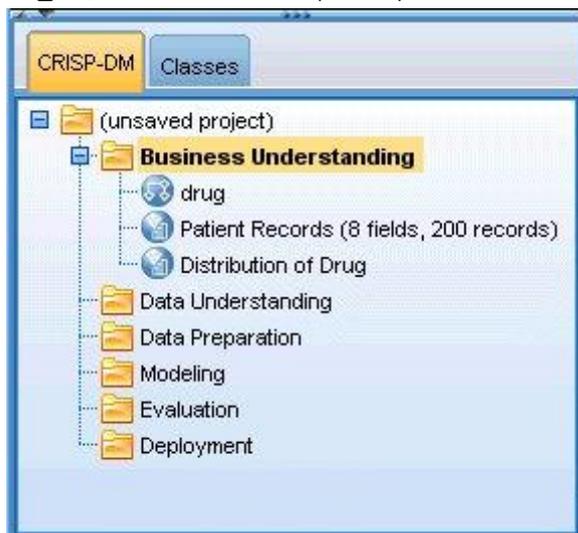
IBM® SPSS® Modeler는 두 가지 방법으로 CRISP-DM 방법론을 통합하여 효과적 데이터 마이닝을 위한 특색 있는 지원을 제공합니다.

- CRISP-DM 프로젝트 도구는 일반적 데이터 마이닝 프로젝트의 단계에 따라 프로젝트 스트림, 출력 및 주석을 구성하도록 돕습니다. 스트림 및 CRISP-DM 단계에 대한 설명을 기반으로 프로젝트 동안 언제든지 보고서를 생성할 수 있습니다.
- CRISP-DM의 도움말은 데이터 마이닝 프로젝트를 수행하는 프로세스를 안내합니다. 도움말 시스템에는 각 단계의 작업 목록뿐만 아니라 CRISP-DM이 실제 세계에서 어떻게 동작하는지에 예제도 포함되어 있습니다. 기본 창 도움말 메뉴에서 **CRISP-DM 도움말**을 선택하여 CRISP-DM 도움말에 액세스할 수 있습니다.

#### ① CRISP-DM 프로젝트 도구

CRISP-DM 프로젝트 도구는 프로젝트의 성공을 도울 수 있는 데이터 마이닝의 조직화된 접근법을 제공합니다. 이것은 본질적으로 표준 IBM® SPSS® Modeler 프로젝트 도구의 확장입니다. 결국, CRISP-DM 보기와 표준 클래스 보기 간에 전환하여 CRISP-DM의 유형 또는 단계별로 구성된 스트림 및 출력을 볼 수 있습니다.

그림 1. CRISP-DM 프로젝트 도구



프로젝트 도구의 CRISP-DM 보기를 사용하여 다음을 수행할 수 있습니다.

- 데이터 마이닝 단계에 따라 프로젝트의 스트림 및 출력을 구성합니다.
- 각 단계에 대해 조직의 목적에 관한 설명을 작성합니다.
- 각 단계에 대한 사용자 정의 도구 팁을 작성합니다.
- 특별한 그래프 또는 모델로부터 도출된 결론에 관한 설명을 작성합니다.
- 프로젝트 팀에 배포하기 위한 HTML 보고서 또는 업데이트를 생성합니다.

## ② CRISP-DM에 대한 도움말

IBM® SPSS® Modeler는 일반 CRISP-DM 프로세스 모델에 대한 온라인 안내서를 제공합니다. 이 안내서는 프로젝트 단계에 따라 구성되며 다음과 같은 지원을 제공합니다.

- CRISP-DM의 각 단계에 대한 개요 및 태스크 목록
- 다양한 이정표에 대한 보고서 생성을 위한 도움말
- 프로젝트 팀이 CRISP-DM을 사용하여 데이터 마이닝을 어떻게 활용할 수 있을지 보여주는 실제 예제
- CRISP-DM에 대한 추가 자원의 링크

기본 창 도움말 메뉴에서 **CRISP-DM 도움말**을 선택하여 CRISP-DM 도움말에 액세스할 수 있습니다.

## (2) 추가 자원

CRISP-DM에 대한 IBM® SPSS® Modeler 지원뿐만 아니라, 데이터 마이닝 프로세스의 이해를 넓히기 위한 몇 가지 방법이 있습니다.

- CRISP-DM 컨소시엄에서 작성하고 이 릴리스에서 제공한 CRISP-DM 매뉴얼을 읽으십시오.
- SPSS Inc.에서 제공하는 *Data Mining with Confidence*(ISBN 1-56827-287-1, copyright 2002) 문서를 읽으십시오.

## 2. 비즈니스 이해

### 1) 비즈니스 이해 개요

IBM® SPSS® Modeler에서 작업하기 전에도 조직이 데이터 마이닝에서 무엇을 얻고자 하는지에 대해 탐색할 시간을 가져야 합니다. 이러한 토론에 가능한 한 많은 핵심 인사를 참여시키고 결과를 문서화합니다. 이 CRISP-DM 단계의 최종 단계는 여기서 수집된 정보를 사용하여 프로젝트 계획 생성 방법을 토론하는 것입니다.

이 연구가 불필요해 보일 수도 있지만 그렇지 않습니다. 데이터 마이닝 작업에 대한 사업적 이  
유를 파악함으로써 귀중한 자원을 소비하기 전에 모든 사람이 동일한 배경 정보를 가질 수 있게  
됩니다.

## 2) 비즈니스 목표 결정

첫 번째 태스크는 데이터 마이닝을 위한 비즈니스 목적에 맞게 가능한 한 많은 통찰력을 얻는  
것입니다. 이는 보기만큼 쉽지 않을 수도 있지만 문제점, 목적 및 자원을 명료화하여 이후의 위  
험을 최소화할 수 있습니다.

CRISP-DM 방법론은 이를 달성하기 위해 조직화된 방식을 제공합니다.

태스크 목록

- 현재 비즈니스 상황에 대한 배경 정보 수집을 시작합니다.
- 핵심 의사결정자에 의해 결정된 특정 비즈니스 목표를 문서화합니다.
- 특정 비즈니스 관점에서 데이터 마이닝 성공을 판단하는 데 사용되는 기준을 절충합니다.

### (1) E-소매 예제--비즈니스 목표 찾기

CRISP-DM을 사용하는 웹 마이닝 시나리오

많은 회사에서 인터넷 쇼핑으로의 전환을 시도함에 따라 컴퓨터/전자제품의 기존 e-소매업자는  
새로운 사이트에 의한 경쟁 심화에 직면하고 있습니다. 고객이 인터넷으로 이전하는 것만큼 빨리  
(또는 그보다 빨리) 인터넷 매장이 생기는 현실에 직면해서, 기업은 고객 획득의 비용 상승에도  
불구하고 수익성을 유지하는 방법을 모색해야 합니다. 제안되는 솔루션 중 하나는 각 회사가 보  
유한 현재 고객의 가치를 극대화하기 위해 기존 고객 관계를 돈독하게 하는 것입니다.

따라서 다음과 같은 연구 목표가 수반됩니다.

- 더 나은 추천을 통해 교차 판매를 개선합니다.
- 보다 개인화된 서비스를 통해 고객 충성도를 높입니다.

시험적으로, 연구는 다음과 같은 경우 성공으로 판단합니다.

- 교차 판매가 10% 증가합니다.
- 고객이 사이트 방문 시 더 많은 시간을 보내고 더 많은 페이지를 봅니다.
- 연구를 제 시간에 예산 내에서 마칩니다.

## (2) 비즈니스 배경 컴파일

조직의 비즈니스 상황을 이해함으로써 다음의 관점에서 현재 처리 중인 사항을 쉽게 파악할 수 있습니다.

- 사용 가능한 자원(인원 및 자재)
- 문제점
- 목적

데이터 마이닝 프로젝트의 결과에 영향을 미칠 수 있는 질문에 대한 실제적 해답을 찾기 위해 현재 비즈니스 상황에 대해 약간의 연구가 필요할 것입니다.

### 태스크 1--조직 구조 결정

- 기업 부문, 부서 및 프로젝트 그룹을 보여주는 조직 차트를 개발합니다. 관리자의 이름 및 책무를 포함해야 합니다.
- 조직 내 핵심 인사들을 식별합니다.
- 재정 지원 및/또는 도메인 전문지식을 제공할 내부 스폰서를 식별합니다.
- 운영 위원회가 있는지 판별하고, 멤버 목록을 획득합니다.
- 데이터 마이닝 프로젝트에 의해 영향을 받을 비즈니스 단위를 식별합니다.

### 태스크 2--문제점 영역 설명

- 마케팅, 고객 관리, 비즈니스 개발 등의 문제점 영역을 식별합니다.
- 일반적인 관점에서 문제점을 설명합니다.
- 프로젝트의 필수조건을 명시합니다. 프로젝트 이면의 동기는 무엇입니까? 비즈니스에서 데이터 마이닝을 이미 사용하고 있습니까?
- 비즈니스 그룹에서 데이터 마이닝 프로젝트의 상태를 확인합니다. 관련 업무가 승인되었습니까? 아니면 데이터 마이닝이 비즈니스 그룹에 대한 핵심 기술로 "광고"되어야 합니까?
- 필요한 경우, 조직에 발표할 데이터 마이닝 관련 정보 프리젠테이션을 준비합니다.

### 태스크 3--현재 솔루션 설명

- 비즈니스 문제점을 처리하기 위해 현재 사용되는 솔루션을 설명합니다.
- 현재 솔루션의 장점과 단점을 설명합니다. 또한 조직 내에서 이 솔루션이 받아들여지는 수준을 설명합니다.

## (3) 비즈니스 목표 정의

여기서 관련 항목을 구체화합니다. 연구 및 회의의 결과로서, 프로젝트 스폰서와 해당 결과에 영

향을 받는 기타 비즈니스 단위가 합의한 구체적인 기본 목표를 구축해야 합니다. 이 목적은 결국 "고객 이탈 감소" 같은 막연한 것에서 분석의 가이드가 될 구체적인 데이터 마이닝 목표로 바뀌게 됩니다.

#### 태스크 목록

나중에 프로젝트 계획에 통합할 수 있도록 다음 사항을 기록해 두십시오. 목적을 현실에 맞게 유지하십시오.

- 데이터 마이닝을 사용하여 해결하려는 문제점을 설명합니다.
- 모든 비즈니스 질문을 가능한 한 정확히 지정합니다.
- 다른 비즈니스 요구사항(예: 교차 판매 기회를 증가시키면서 기존 고객을 잃지 않음)을 판별합니다.
- 예상되는 혜택을 비즈니스 용어로 지정합니다(예: 우수 고객의 이탈률을 10% 줄임).

### (4) 비즈니스 성공 기준

앞에 있는 목적은 분명할 수 있지만 목적을 달성하게 되면 아시겠습니까? 추가적으로 나아가기 전에 데이터 마이닝 프로젝트에 대한 비즈니스 성공의 성질을 정의하는 것은 중요합니다. 성공 기준은 다음 두 개의 범주로 분류됩니다.

- **객관적.** 이러한 기준은 감사 정확도 또는 합의된 이탈 감소율의 구체적인 증가처럼 단순할 수 있습니다.
- **주관적.** "유효 처리의 군집 찾기"와 같은 주관적 기준은 특정하기가 더 어렵지만 누가 최종 결정을 하느냐는 합의할 수 있습니다.

#### 태스크 목록

- 가능한 한 정확하게, 이 프로젝트에 대한 성공 기준을 문서화하십시오.
- 각 비즈니스 목표가 성공을 위한 상관성 있는 기준을 가지는지 확인하십시오.
- 주관적 성공 측정의 결정자를 배정하십시오. 가능한 경우, 해당 기대치에 대한 설명을 작성하십시오.

### 3) 상황 평가

이제 분명히 정의된 목적이 있으므로 현재 자신의 위치에 대해 평가할 때입니다. 이 단계에서는 다음과 같은 질문을 제기하는 것이 포함됩니다.

- 어떤 종류의 데이터를 분석에 사용할 수 있습니까?
- 프로젝트를 완료하는 데 필요한 인원이 있습니까?
- 관련된 가장 큰 위험 요인은 무엇입니까?
- 각 위험에 대한 비상 계획을 가지고 있습니까?

## (1) E-소매 예제--상황 평가

CRISP-DM을 사용하는 웹 마이닝 시나리오

이것은 전자제품 e-소매업자의 첫 번째 웹 마이닝 시도이며 회사는 데이터 마이닝 시작을 돕기 위해 데이터 마이닝 전문가를 초빙하기로 결정했습니다. 컨설턴트가 마주하는 첫 번째 태스크 중 하나는 데이터 마이닝을 위한 회사의 자원을 평가하는 것입니다.

**직원.** 서버 로그와 제품 및 구매 데이터베이스를 관리하는 사내 전문가는 있지만 분석을 위한 데이터 웨어하우징 및 데이터 정리에 대한 경험은 거의 없다는 것은 분명합니다. 그러므로 데이터베이스 전문가도 초빙할 수 있습니다. 회사는 연구 결과가 지속적인 웹 마이닝 프로세스의 일부가 되기를 희망하므로 경영진은 현재 업무 중에 생성된 직위가 영구적 직위가 될 것인지 여부도 고려해야 합니다.

**데이터.** 이 회사는 저명한 회사이므로 끌어다 쓸 웹 로그 및 구매 데이터가 많이 있습니다. 사실이 초기 연구의 경우 회사는 분석을 사이트에 등록된 고객으로 제한할 것입니다. 연구가 성공적이라면 프로그램을 확장할 수 있습니다.

**위험.** 컨설턴트에 대한 금전적 경비 및 직원이 연구에 소요하는 시간을 제외하면 이 모험에서 즉각적인 위험은 그리 많지 않습니다. 그러나 시간은 항상 중요하므로 이 초기 프로젝트는 하나의 회계 분기에 대해서만 스케줄링됩니다.

또한 현재는 추가 현금 흐름이 많지 않으므로 예산에 맞게 연구를 진행해야 합니다. 이러한 목적 중에 달성하기 어려운 목적이 있으면 비즈니스 관리자는 프로젝트의 범위를 줄여야 한다고 제안했습니다.

## (2) 자원 명세

사용자의 자원에 대한 정확한 자원 명세를 기록하는 것이 꼭 필요합니다. 하드웨어, 데이터 소스 및 직원 관련 사항을 꼼꼼히 확인함으로써 많은 시간을 절약하고 골치아픈 문제를 피할 수 있습니다.

태스크 1--하드웨어 자원 조사

- 어떤 하드웨어를 지원해야 합니까?

## 태스크 2--데이터 소스 및 지식 저장소 식별

- 어느 데이터 소스가 데이터 마이닝에 사용 가능합니까? 데이터 유형 및 형식에 대한 설명을 작성하십시오.
- 데이터는 어떻게 저장됩니까? 데이터 웨어하우스 또는 운영 데이터베이스에 액세스할 수 있습니까?
- 외부 데이터(예: 인구 통계 정보)를 구매할 계획입니까?
- 필요한 데이터의 액세스를 막는 보안 문제가 있습니까?

## 태스크 3--인적 자원 식별

- 비즈니스 및 데이터 전문가에게 액세스할 수 있습니까?
- 필요할지도 모르는 데이터베이스 관리자 및 기타 지원 담당자를 식별했습니까?

이와 같은 질문을 했으면 단계 보고서에 대해 담당자 및 자원 목록을 포함시키십시오.

### (3) 요구사항, 가정 및 제약조건

프로젝트에 대한 책임을 정직하게 평가하면 노력의 성과를 거둘 가능성이 더 높아집니다. 이러한 관심사를 가능한 한 명확하게 해두면 이후의 문제를 피하는 데 도움이 됩니다.

## 태스크 1--요구사항 결정

기본적인 요구사항은 앞에서 논의한 비즈니스 목적이지만 다음을 고려하십시오.

- 데이터 또는 프로젝트 결과에 대한 보안 및 법적 제한사항이 있습니까?
- 모든 사람이 프로젝트 스케줄링 요구사항에 맞춰져 있습니까?
- 결과 배포에 대한 요구사항(예: 웹에 게시 또는 스코어를 데이터베이스에 읽어들이기)이 있습니까?

## 태스크 2--가정 명시

- 프로젝트에 영향을 미칠 수 있는 경제적 요인(예: 자문료 또는 경쟁사 제품)이 있습니까?
- 데이터 품질 가정이 있습니까?
- 프로젝트 스폰서/관리 팀은 어떤 결과를 볼 것으로 기대합니까? 즉, 모델 자체를 이해하고 싶습니다, 아니면 단순히 결과를 보고 싶습니까?

## 태스크 3--제약조건 확인

- 데이터 액세스에 필요한 모든 비밀번호가 있습니까?
- 데이터 사용에 대한 모든 법적 제약조건을 확인했습니까?
- 모든 재정적 제약조건을 프로젝트 예산에서 다루었습니까?

#### (4) 위험 및 비상사태

프로젝트 과정에서 가능한 위험을 고려하는 것도 현명합니다. 위험의 유형은 다음과 같습니다.

- 스케줄링(프로젝트가 예상보다 오래 걸리면 어떨까?)
- 재정(프로젝트 스폰서가 예산 문제에 부딪치면 어떨까?)
- 데이터(데이터의 품질 또는 범위가 올바르지 않다면 어떨까?)
- 결과(초기 결과가 기대한 것보다 인상적이지 않다면 어떨까?)

다양한 위험을 고려한 후, 재해를 피하는 데 도움이 될 비상 계획을 수립하십시오.

태스크 목록

- 가능한 각 위험을 문서화합니다.
- 각 위험에 대한 비상 계획을 문서화합니다.

#### (5) 용어

비즈니스 및 데이터 마이닝 팀이 "동일한 언어로 말하게" 하려면 설명이 필요한 기술 용어 및 전문어의 용어집 컴파일을 고려해야 합니다. 예를 들어, 비즈니스에 대한 "이탈"이 특별하고 고유한 의미를 가지고 있다면 전체 팀을 위해 이에 대해 명시적으로 설명할 가치가 있습니다. 마찬가지로, 팀에서는 Gains 차트의 사용법에 대한 명확한 설명이 필요할 수 있습니다.

태스크 목록

- 팀 멤버에게 혼동되는 용어 또는 전문어 목록을 작성해 둡니다. 비즈니스 용어와 데이터 마이닝 용어를 모두 포함시키십시오.
- 인트라넷 또는 기타 프로젝트 문서에 목록을 공개하는 것을 고려하십시오.

#### (6) 비용/혜택 분석

이 단계에서는 **최종 결과가 어떻습니까?**라는 질문에 응답합니다. 최종 평가의 일부로서, 프로젝트의 비용을 성공의 잠재적 혜택과 비교하는 것이 중요합니다.

태스크 목록

다음에 대한 예상 비용을 분석에 포함시키십시오.

- 데이터 수집 및 사용된 외부 데이터

- 결과 배포
- 운영 비용

그리고 나서 다음과 같은 혜택을 고려하십시오.

- 기본 목표 충족
- 데이터 탐색에서 얻은 추가 통찰력
- 데이터 이해 증진을 통한 잠재적 혜택

#### 4) 데이터 마이닝 목적 결정

이제 비즈니스 목적이 분명하므로 이를 데이터 마이닝으로 실현할 때입니다. 예를 들어, "이탈을 줄이는" 비즈니스 목표는 다음을 포함하는 데이터 마이닝 목적으로 변환될 수 있습니다.

- 최근의 구매 데이터를 기반으로 우수 고객 식별
- 각 고객의 이탈 가능성을 예측하기 위해 가용 고객 데이터를 사용하여 모델 작성
- 이탈 성향 및 고객 가치를 기반으로 각 고객에게 순위 지정

이러한 데이터 마이닝 목적은 충족될 경우 업체에서 우수 고객 중에 이탈을 줄이는 데 사용될 수 있습니다.

이와 같이, 업체와 기술은 효과적인 데이터 마이닝을 위해 함께 협력해야 합니다. 데이터 마이닝 목적을 결정하는 방법에 대한 구체적인 팁을 계속 읽어보십시오.

##### (1) 데이터 마이닝 목적

비즈니스 문제점에 대한 기술적 솔루션을 정의하기 위해 비즈니스 및 데이터 분석가와 작업을 진행할 때처럼, 항목들을 구체적으로 정의해 두십시오.

태스크 목록

- 데이터 마이닝 문제점의 유형(군집, 예측, 분류 등)을 설명합니다.
- 특정 시간 단위를 사용하여 기술적 목적을 문서화합니다(예: 유효 기간이 3개월인 예측).
- 가능한 경우, 바람직한 결과의 실제 수치(예: 기존 고객의 80%에 대한 이탈 점수 생성)를 제공하십시오.

## (2) E-소매 예제--데이터 마이닝 목적

CRISP-DM을 사용하는 웹 마이닝 시나리오

해당 데이터 마이닝 컨설턴트의 도움으로, e-소매업자는 회사의 비즈니스 목표를 데이터 마이닝 용어로 변환할 수 있었습니다. 이 분기에 완료할 초기 연구의 목적은 다음과 같습니다.

- 이전 구매에 대한 히스토리 정보를 사용하여 "관련" 항목들을 링크하는 모델을 생성합니다. 사용자가 항목 설명을 볼 때, 관련 그룹(장바구니 분석)의 다른 항목에 대한 링크를 제공합니다.
- 웹 로그를 사용하여 서로 다른 고객들이 무엇을 찾고 있는지 판별하고 이러한 항목을 강조 표시하도록 사이트를 재설계합니다. 서로 다른 각 고객 "유형"마다 사이트의 메인 페이지가 다르게 표시됩니다(프로파일링).
- 웹 로그를 사용하여 사용자가 어디에서 왔고 사이트의 어디에 있었는지를 감안해서 사용자가 다음에 어디로 이동할지를 예측합니다(시퀀스 분석).

## (3) 데이터 마이닝 성공 기준

데이터 마이닝 작업이 순조롭게 진행되려면 성공을 기술적인 용어로도 정의해야 합니다. 이전에 결정된 데이터 마이닝 목적을 사용하여 성공에 대한 벤치마크를 공식화합니다. IBM® SPSS® Modeler는 평가 노드 및 분석 노드 등의 도구를 제공하여 결과의 정확도와 타당성을 분석할 수 있게 합니다.

태스크 목록

- 모델 평가 방법을 설명합니다(예: 정확도, 성과 등).
- 성공을 평가하기 위한 벤치마크를 정의합니다. 특정 수치를 제공합니다.
- 최선의 주관적 측정을 정의하고 성공의 결정자를 결정합니다.
- 모델 결과의 성공적인 배포가 데이터 마이닝 성공의 일부인지 여부를 고려합니다. 배포 계획을 지금 시작합니다.

## 5) 프로젝트 계획 생성

이 시점에서 데이터 마이닝 프로젝트의 계획을 생성할 준비가 되었습니다. 지금까지 제기한 질문과, 공식화한 비즈니스 및 데이터 마이닝 목적은 이 로드맵의 기반이 될 것입니다.

## (1) 프로젝트 계획 작성

프로젝트 계획은 모든 데이터 마이닝 작업에 대한 마스터 문서입니다. 제대로 작성되면 프로젝트와 연관된 모든 사람들에게 모든 데이터 마이닝 단계에 대한 목적, 자원, 위험 및 스케줄을 알려 줄 수 있습니다. 이 계획뿐 아니라 이 단계에서 수집된 문서를 회사의 인트라넷에 게시할 수도 있습니다.

태스크 목록

계획을 작성할 때는 다음과 같은 질문에 응답해야 합니다.

- 프로젝트 태스크 및 제안된 계획을 관련된 모든 사람과 논의했습니까?
- 모든 단계 또는 태스크에 대한 시간 추정값이 포함되었습니까?
- 결과 또는 비즈니스 솔루션을 배포하는 데 필요한 작업 및 자원을 포함시켰습니까?
- 의사결정 사항과 검토 요청이 계획에 강조표시되었습니까?
- 다중 반복이 일반적으로 발생하는 단계(예: 모델링)를 식별 표시했습니까?

## (2) 샘플 프로젝트 계획

연구에 대한 개요 계획은 아래 표와 같습니다.

단계	시간	자원	위험
비즈니스 이해	1주	모든 분석가	경제 변화
데이터 이해	3주	모든 분석가	데이터 문제점, 기술 문제점
데이터 준비	5주	데이터 마이닝 컨설턴트, 일부 데이터베이스 분석가 시간	데이터 문제점, 기술 문제점
모델링	2주	데이터 마이닝 컨설턴트, 일부 데이터베이스 분석가 시간	기술 문제점, 적절한 모델을 찾을 수 없음
평가	1주	모든 분석가	경제 변화, 결과를 구현할 수 없음
배포	1주	데이터 마이닝 컨설턴트, 일부 데이터베이스 분석가 시간	경제 변화, 결과를 구현할 수 없음

### (3) 도구 및 기법 평가

IBM® SPSS® Modeler를 이미 데이터 마이닝 성공을 위한 도구로 사용하도록 선택했으므로 이 단계를 사용하여 어느 데이터 마이닝 기법이 비즈니스 요구사항에 가장 적절한지 조사할 수 있습니다. IBM SPSS Modeler는 데이터 마이닝의 각 단계에 대한 전체적인 도구를 제공합니다. 다양한 기법을 언제 사용할지에 대해서는 온라인 도움말의 모델링 섹션을 참고하십시오.

### 6) 다음 단계에 대한 준비 여부

IBM® SPSS® Modeler에서 데이터 탐색과 작업 시작 전에 다음 질문에 대한 응답을 해야 합니다.

비즈니스 관점에서:

- 해당 사업체가 이 프로젝트로부터 무엇을 얻고자 합니까?
- 관련 업무의 성공적인 완료를 어떻게 정의하시겠습니까?
- 목적을 달성하는 데 필요한 예산과 자원이 있습니까?
- 이 프로젝트에 필요한 모든 데이터에 액세스할 수 있습니까?
- 이 프로젝트와 연관된 위험 및 비상 계획을 팀과 논의했습니까?
- 비용과 혜택 분석의 결과가 이 프로젝트의 가치를 증명했습니까?

위의 질문에 응답한 후, 그 응답을 데이터 마이닝 목적으로 변환했습니까?

데이터 마이닝 관점에서:

- 얼마나 구체적으로 데이터 마이닝이 비즈니스 목적의 달성에 도움을 줄 수 있습니까?
- 어떤 데이터 마이닝 기법이 최상의 결과를 산출할지에 대한 아이디어가 있습니까?
- 언제 결과가 정확하거나 충분히 효과적인지 어떻게 알 수 있습니까? (*데이터 마이닝 성공에 대한 측정 기준을 설정했습니까?*)
- 어떻게 모델링 결과가 배포될 것입니까? 사용자의 프로젝트 계획에서 배포를 고려했습니까?
- 프로젝트 계획에 CRISP-DM의 모든 단계가 포함됩니까?
- 위험 및 종속 항목을 계획에서 다릅니까?

위의 질문에 "예"라고 응답할 수 있다면 데이터를 더 자세히 살펴볼 준비가 된 것입니다.

### 3. 데이터 이해

#### 1) 데이터 이해 개요

CRISP-DM의 데이터 이해 단계에서는 마이닝에 사용 가능한 데이터를 자세히 살펴봐야 합니다. 이 단계는 다음 단계(데이터 준비) 동안 예기치 못한 문제를 피하는 데 있어서 중요하며, 일반적으로 프로젝트의 가장 긴 부분입니다.

데이터 이해를 위해서는 데이터에 액세스하고 테이블 및 그래픽(IBM® SPSS® Modeler에서 CRISP-DM 프로젝트 도구를 사용하여 구성 가능)을 사용하여 데이터를 탐색해야 합니다. 이렇게 하면 데이터의 품질을 판별하고 프로젝트 문서에서 이러한 단계의 결과를 설명할 수 있습니다.

#### 2) 초기 데이터 수집

CRISP-DM의 이 시점에서는, 데이터에 액세스하여 데이터를 IBM® SPSS® Modeler로 가져올 준비가 되었습니다. 데이터는 다음과 같은 다양한 소스에서 가져옵니다.

- **기존 데이터.** 이 데이터는 트랜잭션 데이터, 설문조사 데이터, 웹 로그 등의 매우 다양한 데이터를 포함합니다. 기존 데이터가 해당 요구사항을 충족하기에 충분한지 여부를 고려하십시오.
- **구매한 데이터.** 조직에서 인구 통계 등의 보충 데이터를 사용합니까? 그렇지 않다면 해당 데이터가 필요할지 여부를 고려하십시오.
- **추가 데이터.** 위의 소스가 해당 요구사항을 충족시키지 못하면 설문조사를 수행하거나 추가 추적을 시작하여 기존 데이터 저장소를 보충할 수 있습니다.

#### 태스크 목록

IBM SPSS Modeler에서 데이터를 살펴보고 다음과 같은 질문을 고려하십시오. 결과물에 대한 설명을 작성하십시오. 자세한 정보는 데이터 수집 보고서 작성의 내용을 참조하십시오.

- 데이터베이스의 어느 속성(열)이 가장 유망해 보입니까?
- 무관해 보여서 제외할 수 있는 속성은 무엇입니까?
- 일반화 가능한 결론을 도출하거나 정확한 예측을 하기에 충분한 데이터가 있습니까?
- 선택할 모델링 방법의 속성이 너무 많이 있습니까?
- 다양한 데이터 소스를 병합할 것입니까? 그렇다면, 병합할 때 문제를 일으킬지도 모르는 영역이 있습니까?
- 각 데이터 소스에서 결측값을 어떻게 처리할지에 대해 고려했습니까?

## (1) E-소매 예제--초기 데이터 수집

CRISP-DM을 사용하는 웹 마이닝 시나리오

이 예제에서 e-소매업자는 다음을 비롯하여 몇 가지 중요한 데이터 소스를 사용합니다.

**웹 로그.** 원시 액세스 로그에는 고객이 웹 사이트를 탐색하는 방식에 대한 모든 정보가 있습니다. 웹 로그에서 이미지 파일에 대한 참조와 기타 비정보 엔트리는 데이터 준비 과정에서 제거되어야 합니다.

**구매 데이터.** 고객이 주문을 제출하면 해당 주문에 속한 모든 정보가 저장됩니다. 구매 데이터베이스에 있는 주문은 웹 로그의 해당 세션에 매핑되어야 합니다.

**제품 데이터베이스.** 제품 속성은 "관련" 제품을 결정할 때 유용할 수 있습니다. 제품 정보는 해당 주문에 매핑되어야 합니다.

**고객 데이터베이스.** 이 데이터베이스는 등록된 고객에게서 수집된 추가 정보를 포함합니다. 많은 고객이 질문지를 채우지 않기 때문에, 전체 레코드는 완성되지 않습니다. 고객 정보는 웹 로그의 해당 구매 및 세션에 매핑되어야 합니다.

현재, 회사에서는 해당 분석가가 현재 가진 데이터를 관리하느라 바쁘기 때문에 외부 데이터베이스를 구매하거나 설문조사 수행에 자금을 지출할 계획이 없습니다. 그러나 언젠가 데이터 마이닝 결과의 확장 배포를 고려할 필요가 있는 경우 미등록 고객의 추가 인구 통계 데이터를 구매하는 것이 상당히 유용할 수 있습니다. 또한 e-소매업자의 고객 데이터베이스가 평균 인터넷 쇼핑객과 어떻게 다른지를 보기 위해 인구 통계 정보를 확보하는 것이 유용할 수 있습니다.

## (2) 데이터 수집 보고서 작성

이전 단계에서 수집된 자료를 사용하여 데이터 수집 보고서 작성을 시작할 수 있습니다. 작성이 완료되면 이 보고서는 프로젝트 웹 사이트에 추가되거나 팀에게 배포될 수 있습니다. 이 보고서는 다음 단계(데이터 설명, 탐색 및 품질 확인)에서 준비된 보고서와 결합될 수도 있습니다. 이러한 보고서는 데이터 준비 단계에서 사용자의 작업을 안내할 것입니다.

## 3) 데이터 설명

데이터를 설명하는 방법은 여러 가지가 있지만 대부분의 설명은 데이터의 수량 및 품질(얼마나 많은 데이터가 사용 가능하며 데이터의 상태는 어떠한가)에 초점을 맞춥니다. 아래에는 데이터를 설명할 때 다루어야 하는 몇 가지 핵심 특성이 나열되어 있습니다.

- **데이터의 양.** 대부분의 모델링 기법에는 데이터 크기와 연관된 장단점이 있습니다. 큰 데이터 세트는 더 정확한 모델을 생성할 수 있지만 처리 시간이 늘어날 수 있습니다. 데이터의 서브 세트를 사용하는 것이 적절한지 여부를 고려하십시오. 최종 보고서에 대한 설명을 작성할 때, 모든 데이터 세트의 크기 통계를 포함해야 하고 데이터를 설명할 때 레코드 수 뿐만 아니라 필드(속성)도 고려해야 하는 것을 명심하십시오.
- **값 유형.** 데이터는 숫자 또는 범주형(문자열) 또는 부울(true/false)와 같은 다양한 형식을 가질 수 있습니다. 값 유형에 주의하면 이후 모델링 중에 문제를 피할 수 있습니다.
- **코딩 체계.** 데이터베이스의 값은 성별 또는 제품 유형과 같은 특성의 표현인 경우가 빈번합니다. 예를 들어, 한 데이터 세트는 남성 및 여성을 나타내기 위해 M 및 F를 사용하고 다른 데이터 세트는 숫자 값 1 및 2를 사용할 수 있습니다. 데이터 보고서에서 충돌하는 체계를 확인하십시오.

이 지식을 갖췄으므로 이제 데이터 설명 보고서를 작성하고 결과물을 더 많은 대상과 공유할 준비가 되었습니다.

## (1) E-소매 예제--데이터 설명

CRISP-DM을 사용하는 웹 마이닝 시나리오

웹 마이닝 애플리케이션에는 처리할 레코드 및 속성이 많이 있습니다. 이 데이터 마이닝 프로젝트를 수행하는 e-소매업자가 초기 연구를 사이트에 등록한 30,000여 명의 고객으로 제한했을지라도 웹 로그에는 여전히 수백 만 개의 레코드가 있습니다.

이러한 데이터 소스에 있는 대부분의 값 유형은 (날짜 및 시간이든, 액세스한 웹 페이지 수이든, 등록 질문지의 다중 선택 질문에 대한 응답이든 간에) 기호입니다. 이러한 변수의 일부는 수치인 새 변수(예: 방문한 웹 페이지 수, 웹 사이트에서 보낸 시간)를 작성하는데 사용됩니다. 데이터 소스 내의 몇 가지 기존 숫자 변수로는 주문한 각 제품 수, 구매 중에 지출한 금액, 제품 데이터베이스의 제품 중량과 치수 내역 등이 있습니다.

데이터 소스는 매우 다른 속성들을 포함하기 때문에 다양한 데이터 소스에 대한 코딩 체계에는 중복되는 것이 거의 없습니다. 중복되는 유일한 변수는 고객 ID, 제품 코드 등의 "키"입니다. 이러한 변수는 데이터 소스 간에 동일한 코딩 체계를 가져야 합니다. 그렇지 않으면 데이터 소스를 병합할 수 없습니다. 병합을 위해 이러한 키 필드를 다시 코딩하려면 약간의 추가 데이터 준비가 필요할 것입니다.

## (2) 데이터 설명 보고서 작성

데이터 마이닝 프로젝트를 효과적으로 진행하려면 다음과 같은 메트릭을 사용하여 정확한 데이터 설명 보고서 생성의 의미를 고려하십시오.

## 데이터 양

- 데이터의 형식은 무엇입니까?
- 데이터를 캡처하는 데 사용되는 방법(예: ODBC)을 식별합니다.
- (행 및 열 수 면에서) 데이터베이스가 얼마나 큼니까?

## 데이터 품질

- 데이터는 비즈니스 질문과 관련된 특성을 포함합니까?
- 어떤 데이터 유형(기호, 숫자 등)이 존재합니까?
- 핵심 속성의 기본 통계를 계산했습니까? 이것은 비즈니스 질문에 대해 어떤 통찰력을 제공했습니까?
- 관련 속성의 우선순위를 지정할 수 있습니까? 그럴 수 없다면 추가 통찰력을 제공할 비즈니스 분석가가 있습니까?

## 4) 데이터 탐색

IBM® SPSS® Modeler에서 사용 가능한 테이블, 차트 및 기타 시각화 도구를 사용하여 데이터를 탐색하려면 CRISP-DM의 이 단계를 사용하십시오. 이러한 분석은 비즈니스 이해 단계 동안 구축된 데이터 마이닝 목적을 달성하는 데 도움이 될 수 있습니다. 또한 이를 통해 가설을 공식화하고 데이터 준비 동안 발생하는 데이터 변환 작업을 구체화할 수 있습니다.

### (1) E-소매 예제--데이터 탐색

CRISP-DM을 사용하는 웹 마이닝 시나리오

CRISP-DM은 이 시점에서 초기 탐색의 수행을 제안하지만 e-소매업자가 발견한 바와 같이 원시 웹 로그에서 데이터 탐색은 불가능하지는 않지만 어렵습니다. 일반적으로 웹 로그 데이터는 의미 있게 탐색 가능한 데이터를 생성하도록 데이터 준비 단계에서 먼저 처리되어야 합니다. CRISP-DM에서의 이 출발은 프로세스가 사용자의 특별한 데이터 마이닝 요구사항에 맞게 사용자 정의될 수 있으며 사용자 정의되어야 한다는 사실을 강조합니다. CRISP-DM은 주기적이며, 일반적으로 데이터 마이너가 단계 사이에 앞뒤로 이동합니다.

웹 로그는 탐색 전에 처리되어야 하지만 e-소매업자가 사용 가능한 다른 데이터 소스는 탐색에 더 용이합니다. 구매 데이터베이스를 탐색에 사용할 경우 고객에 대한 흥미로운 요약값(예: 고객의 지출 금액, 구매당 구입하는 물품 수, 고객 출신지)을 찾을 수 있습니다. 고객 데이터베이스의 요약값은 등록 질문지의 문항에 대한 응답의 분포를 보여줍니다.

탐색은 데이터의 오류를 찾는 데에도 유용합니다. 대부분의 데이터 소스는 자동으로 생성되는 반면, 제품 데이터베이스의 정보는 수동으로 입력되었습니다. 나열된 제품 치수의 몇 가지 빠른 요약값을 통해 "119인치"("19인치"의 오타)와 같은 오타를 발견할 수 있습니다.

## (2) 데이터 탐색 보고서 작성

그래프를 만들고 사용 가능 데이터에 대한 통계를 실행하면서, 데이터가 어떻게 기술적 및 비즈니스 목적에 해답을 제공할 수 있는지에 대한 가설 형성을 시작하십시오.

태스크 목록

데이터 탐색 보고서에 포함할 결과물에 대한 설명을 작성하십시오. 다음 질문에 응답하십시오.

- 데이터에 대해 어떤 종류의 가설을 형성했습니까?
- 어느 속성이 추가 분석에 유망해 보입니까?
- 탐색을 통해 데이터에 대한 새 특성이 밝혀졌습니까?
- 이러한 탐색이 초기 가설을 어떻게 변경했습니까?
- 나중에 사용하기 위해 데이터의 특정 서브세트를 식별할 수 있습니까?
- 데이터 마이닝 목적을 다시 살펴보십시오. 이 탐색으로 인해 목적이 변경되었습니까?

## 5) 데이터 품질 확인

데이터는 완전한 경우가 거의 없습니다. 결국, 대부분의 데이터는 때때로 분석을 까다롭게 하는 코딩 오류, 결측값 또는 기타 유형의 불일치를 포함합니다. 잠재적 위험을 피하기 위한 한 가지 방법은 모델링 전에 사용 가능 데이터의 철저한 품질 분석을 수행하는 것입니다.

IBM® SPSS® Modeler의 보고서 작성 도구(예: 데이터 검토, 테이블 및 기타 출력 노드)는 다음과 같은 유형의 문제점을 찾는 데 도움이 될 수 있습니다.

- **누락된 데이터.** 무응답(예:  $\$null$ , ? 또는 999)으로 코딩되었거나 비어 있는 값이 포함됩니다.
- **데이터 오류.** 일반적으로 데이터를 입력할 때 생기는 오타 오류입니다.
- **측정 오류.** 올바르게 입력되었지만 부정확한 측정 체계를 기반으로 하는 데이터가 포함됩니다.
- **코딩 불일치.** 일반적으로 비표준 측정 단위 또는 값 불일치(예: 성별에 대해 *M*과 *남성*을 모두 사용)이 포함됩니다.
- **잘못된 메타데이터.** 필드의 분명한 의미와, 필드 이름 또는 정의에 명시된 의미 사이의 불일치가 포함됩니다.

이러한 품질 문제에 대한 설명을 작성하십시오. 자세한 정보는 데이터 품질 보고서 작성의 내용을 참조하십시오.

## (1) E-소매 예제--데이터 품질 확인

CRISP-DM을 사용하는 웹 마이닝 시나리오

데이터 품질의 확인은 설명 및 탐색 프로세스 과정에서 이루어집니다. e-소매업자가 마주치게 되는 몇 가지 문제는 다음과 같습니다.

**누락된 데이터.** 알려진 누락 데이터는 등록된 일부 사용자가 질문에 응답하지 않은 경우를 포함합니다. 질문에 의해 제공된 추가 정보가 없으면, 이러한 고객은 일부 후속 모델에서 배제되어야 할 것입니다.

**데이터 오류.** 대부분의 데이터 소스는 자동으로 생성되므로 이것은 큰 문제가 아닙니다. 제품 데이터베이스의 오타 오류는 탐색 프로세스에서 발견될 수 있습니다.

**측정 오류.** 측정 오류의 가능성이 가장 큰 소스는 질문지입니다. 문항이 신중하지 못하거나 적절하게 표현되지 않으면 e-소매업자가 얻고자 하는 정보를 제공하지 못할 수 있습니다. 역시, 탐색 프로세스에서 특별한 응답 분포를 가지는 문항에 특별한 주의를 기울이는 것이 중요합니다.

## (2) 데이터 품질 보고서 작성

데이터 품질에 대한 탐색 및 확인을 기반으로, 이제 CRISP-DM의 다음 단계를 안내할 보고서를 준비할 준비가 되었습니다. 자세한 정보는 데이터 품질 확인의 내용을 참조하십시오.

태스크 목록

앞에서 논의했듯이, 몇 가지 유형의 데이터 품질 문제점이 있습니다. 다음 단계로 이동하기 전에, 다음과 같은 품질 문제를 고려하고 솔루션을 계획하십시오. 모든 응답을 데이터 품질 보고서에서 문서화하십시오.

- 누락된 속성 및 비어 있는 필드를 식별했습니까? 그렇다면, 이러한 결측값 속에 숨은 의미가 있습니까?
- 이후의 병합 또는 변환에서 문제를 일으킬 수 있는 맞춤법 불일치가 있습니까?
- 편차를 탐색하여, 편차가 "잡음"인지 또는 추가적으로 분석할 가치가 있는 현상인지 판별했습니까?
- 값에 대해 타당성 검사를 수행했습니까? 분명하게 모순적인 사항(예: 소득 수준이 높은 청소년)에 대해 설명을 작성하십시오.
- 가설에 아무 영향을 미치지 않는 데이터를 제외하는 것을 고려했습니까?
- 데이터가 플랫폼 파일에 저장됩니까? 그렇다면, 구분자가 파일 간에 일치합니까? 각 레코드는 동일한 수의 필드를 포함합니까?

## 6) 다음 단계에 대한 준비 여부

IBM® SPSS® Modeler에서 모델링 데이터를 준비하기 전에 다음 사항을 고려하십시오.

데이터를 얼마나 잘 이해하고 있습니까?

- 모든 데이터 소스가 분명히 식별되고 액세스됩니까? 문제점 또는 제한사항을 알고 있습니까?
- 사용 가능 데이터로부터 핵심 속성을 식별했습니까?
- 이러한 속성은 가설을 공식화하도록 도왔습니까?
- 모든 데이터 소스의 크기를 기재했습니까?
- 적당한 곳에서 데이터의 서브셋을 사용할 수 있습니까?
- 각 관심 속성의 기본 통계를 계산했습니까? 의미 있는 정보가 나타났습니까?
- 핵심 속성에 대한 추가 통찰력을 얻기 위해 탐색 그래픽을 사용했습니까? 이 통찰력을 통해 가설이 변동되었습니까?
- 이 프로젝트에 대한 데이터 품질 문제는 무엇입니까? 이 문제를 해결할 계획이 있습니까?
- 데이터 준비 단계가 분명합니까? 예를 들면, 어느 데이터 소스를 병합시키고 어느 속성을 필터링하거나 선택할지 압니까?

이제 비즈니스와 데이터 이해를 모두 갖췄으므로 IBM SPSS Modeler를 사용하여 모델링에 대한 데이터를 준비할 때입니다.

## 4. 데이터 준비

### 1) 데이터 준비 개요

데이터 준비는 데이터 마이닝에서 가장 중요하면서 시간이 많이 걸리는 측면 중 하나입니다. 결국, 데이터 준비는 일반적으로 프로젝트에 대한 시간 및 작업량의 50-70%를 차지하는 것으로 추정됩니다. 앞선 비즈니스 이해 및 데이터 이해 단계에 적당한 에너지를 쏟으면 이 오버헤드를 최소화할 수 있지만, 여전히 마이닝 데이터를 준비하고 패키징하는 데 상당한 노력을 기울여야 합니다.

조직과 해당 목적에 따라, 데이터 준비는 일반적으로 다음과 같은 작업을 포함합니다.

- 데이터 세트 및/또는 레코드 병합
- 데이터의 표본 서브셋 선택
- 레코드 통합
- 새 속성 파생

- 모델링 데이터 정렬
- 공백 또는 결측값을 제거하거나 대체
- 학습 및 테스트 데이터 세트로 분할

## 2) 데이터 선택

이전 CRISP-DM 단계에서 수행된 초기 데이터 수집을 기반으로, 데이터 마이닝 목적과 관련된 데이터 선택을 시작할 준비가 되었습니다. 일반적으로 데이터를 선택하는 방법은 두 가지가 있습니다.

- **항목(행) 선택.** 어느 계정, 제품 또는 고객을 포함시킬까 등에 관한 의사결정이 포함됩니다.
- **속성 또는 특성(열) 선택.** 트랜잭션 금액 또는 가계 소득 등의 특성 사용에 관한 의사결정이 포함됩니다.

### (1) E-소매 예제--데이터 선택

CRISP-DM을 사용하는 웹 마이닝 시나리오

어느 데이터를 선택할지에 대한 e-소매업자의 의사결정 다수는 이미 데이터 마이닝 프로세스의 초기 단계에서 수행되었습니다.

**항목 선택.** 초기 연구는 사이트에 등록된 30,000여 명의 고객으로 제한될 것이므로 비등록 고객의 구매 및 웹 로그를 제외하기 위해 필터를 설정해야 합니다. 웹 로그의 이미지 파일 및 기타 비정보 엔트리를 제거하기 위해 기타 필터가 설정되어야 합니다.

**속성 선택.** 구매 데이터베이스는 e-소매업자의 고객과 관련된 민감한 정보를 포함할 것이므로 고객 이름, 주소, 전화번호, 신용카드 번호 등의 속성을 필터링하는 것이 중요합니다.

### (2) 데이터 포함 또는 제외

포함하거나 제외할 데이터의 서브세트를 결정할 때는 의사결정 이면의 근본적 이유를 문서화하십시오.

고려할 질문

- 지정된 속성이 데이터 마이닝 목적과 관련되어 있습니까?
- 특정 데이터 세트 또는 속성의 품질이 결과의 타당성에 방해가 됩니까?
- 이러한 데이터를 구제할 수 있습니까?
- **성별** 또는 **인종**과 같은 특수 필드를 사용하는 것에 대한 제약조건이 있습니까?

여기서의 의사결정이 데이터 이해 단계에서 공식화된 가설과 다른니까? 그렇다면 프로젝트 보고서에서 해당 추론을 문서화하십시오.

### 3) 데이터 정리

데이터를 정리하려면 분석을 위해 포함하도록 선택한 데이터에서 문제점을 자세히 살펴봐야 합니다. IBM® SPSS® Modeler에서 레코드 및 필드 작업 노드를 사용하여 데이터를 정리하는 방법이 몇 가지 있습니다.

표 1. 데이터 정리	
데이터 문제점	가능한 솔루션
누락된 데이터	행 또는 특성을 제외합니다. 또는 공백을 예상 값으로 채웁니다.
데이터 오류	로직을 사용하여 오류를 수동으로 찾아서 대체합니다. 또는 특성을 제외합니다.
코딩 불일치	하나의 코딩 체계를 결정한 후 값을 변환해서 대체합니다.
누락되었거나 잘못된 메타데이터	의심스런 필드를 수동으로 탐색하고 올바른 의미를 추적합니다.

데이터 이해 단계 동안 준비된 데이터 품질 보고서에는 해당 데이터의 특정 문제점 유형에 대한 세부사항이 포함되어 있습니다. IBM SPSS Modeler에서 이 보고서를 데이터 조작에 대한 시작점으로 사용할 수 있습니다.

#### (1) E-소매 예제--데이터 정리

CRISP-DM을 사용하는 웹 마이닝 시나리오

e-소매업자는 데이터 품질 보고서에서 지적된 문제점을 해결하기 위해 데이터 정리 프로세스를 사용합니다.

**누락된 데이터.** 온라인 질문지를 완성하지 않은 고객은 이후의 일부 모델에서 배제되어야 할 것입니다. 이러한 고객에게 질문지를 작성하도록 다시 요청할 수도 있지만 e-소매업자가 지출하기에 부담스런 시간과 비용이 소요될 것입니다. e-소매업자가 할 수 있는 것은 질문지에 응답한 고객과 응답하지 않은 고객 사이의 구매 차이를 모델링하는 것입니다. 이러한 두 고객 집합이 유사한 구매 습관을 가지는 경우, 누락된 질문지는 큰 문제가 되지 않습니다.

**데이터 오류.** 탐색 프로세스 중에 발견된 오류는 여기에서 수정될 수 있습니다. 그러나 대부분은 고객이 페이지를 백엔드 데이터베이스에 제출하기 전에 적절한 데이터 입력이 웹 사이트에서 시행됩니다.

**측정 오류.** 질문지의 문항이 적절하게 표현되지 않으면 데이터의 품질에 크게 영향을 미칠 수 있습니다. 누락된 질문지와 마찬가지로, 새 대체 질문에 대한 응답을 수집할 시간이나 비용이 없을 수 있으므로 이것은 어려운 문제입니다. 문제가 되는 문항에 대해 최적의 솔루션은 선택 프로세스로 돌아가서 해당 문항을 추가 분석에서 배제하는 것일 수 있습니다.

## (2) 데이터 정리 보고서 작성

데이터 정리 작업에 대해 보고서를 작성하는 것은 데이터 변경사항 추적에 필수적입니다. 작업 세부사항이 준비되어 있으면 이후의 데이터 마이닝 프로젝트에 도움이 될 것입니다.

태스크 목록

보고서를 작성할 때 다음과 같은 질문을 고려하는 것이 좋습니다.

- 데이터에서 어떤 유형의 잡음이 발생했습니까?
- 잡음을 제거하기 위해 어떤 접근법을 사용했습니까? 어떤 기법이 성공적이었습니까?
- 구제할 수 없는 케이스 또는 속성이 있습니까? 잡음으로 인해 제외된 데이터를 기록하십시오.

## 4) 새 데이터 구축

새 데이터를 구축해야 하는 경우가 빈번합니다. 예를 들어, 각 트랜잭션에서 보증기간 연장 구매에 플래그를 지정하는 새 열을 작성하는 것이 유용할 수 있습니다. 이 새 필드 (*purchased\_warranty*)는 IBM® SPSS® Modeler에서 '플래그로 설정' 노드를 사용하여 쉽게 생성할 수 있습니다.

새 데이터를 구축하는 방법은 두 가지가 있습니다.

- 속성(열 또는 특성) 파생
- 레코드(행) 생성

IBM SPSS Modeler는 해당 '레코드 및 필드 작업' 노드를 사용하여 여러 가지 데이터 구축 방법을 제공합니다.

## (1) E-소매 예제--데이터 구축

CRISP-DM을 사용하는 웹 마이닝 시나리오

웹 로그의 처리는 많은 새 속성을 만들어낼 수 있습니다. 로그에 기록된 이벤트의 경우, e-소매업자는 시간소인을 작성하고 방문자 및 세션을 식별하며 액세스된 페이지와 이벤트가 나타내는 활동의 유형을 기재할 수 있습니다. 이러한 변수의 일부는 추가 속성(예: 세션 내에서 이벤트 사이의 시간)을 작성하는데 사용됩니다.

추가 속성은 병합 또는 기타 데이터 구조변환의 결과로서 작성될 수 있습니다. 예를 들어, 각 행이 세션이 되도록 행별 이벤트 웹 로그가 "롤업"되면 총 동작 수, 총 소요 시간 및 세션 중에 수행된 총 구매 수를 기록하는 새 속성이 작성됩니다. 각 행이 고객이 되도록 웹 로그가 고객 데이터베이스와 병합되면 세션 수, 총 동작 수, 총 소요 시간 및 각 고객의 총 구매 수를 기록하는 새 속성이 작성됩니다.

새 데이터를 구축한 후에, e-소매업자는 탐색 과정을 거쳐 데이터 작성이 올바르게 수행되었는지 확인합니다.

## (2) 속성 파생

IBM® SPSS® Modeler에서 다음과 같은 필드 작업 노드를 사용하여 새 속성을 파생시킬 수 있습니다.

- 파생 노드를 사용하여 기존 필드에서 파생된 새 필드를 작성합니다.
- 플래그로 설정 노드를 사용하여 플래그 필드를 작성합니다.

태스크 목록

- 속성을 파생시킬 때 모델링에 대한 데이터 요구사항을 고려하십시오. 모델링 알고리즘에서 특정 데이터 유형(예: 숫자)을 기대합니까? 그렇다면 필요한 변환을 수행하십시오.
- 모델링 전에 데이터를 표준화해야 합니까?
- 통합, 평균화 또는 귀납을 사용하여 누락된 속성을 구축할 수 있습니까?
- 사용자의 배경 지식을 기반으로, 기존 필드에서 파생될 수 있는 중요한 사실(예: 웹 사이트에서 보낸 시간의 길이)이 있습니까?

## 5) 데이터 통합

동일한 비즈니스 질문 세트에 대해 여러 데이터 소스를 가지는 것은 드물지 않습니다. 예를 들어, 동일한 클라이언트 세트에 대해 주택 담보 대출 데이터뿐 아니라 구매한 인구 통계 데이터에도 액세스할 수 있습니다. 이러한 데이터 세트가 동일한 고유 식별자(예: 주민등록번호)를 포함하는 경우, 이 키 필드를 사용하여 IBM® SPSS® Modeler에서 데이터 세트를 병합할 수 있습니다.

기본적인 데이터 통합 방법이 두 가지 있습니다.

- 데이터 **병합**의 경우, 유사한 레코드를 가지지만 속성이 다른 두 데이터 세트를 병합합니다. 데이터는 각 레코드의 동일한 키 식별자(예: 고객 ID)를 사용하여 병합됩니다. 열 또는 특성에서 결과 데이터가 증가합니다.
- 데이터 **추가**의 경우, 유사한 속성을 가지지만 레코드가 다른 두 개 이상의 데이터 세트를 통합합니다. 데이터는 유사한 필드(예: 제품 이름 또는 계약 기간)를 기반으로 통합됩니다.

### (1) E-소매 예제--데이터 통합

CRISP-DM을 사용하는 웹 마이닝 시나리오

다중 데이터 소스를 사용하는 경우, e-소매업자가 데이터를 통합할 수 있는 여러 가지 방법이 있습니다.

- **이벤트 데이터에 고객 및 제품 속성 추가.** 다른 데이터베이스의 속성을 사용하여 웹 로그 이벤트를 모델링하려면 각 이벤트와 연관된 고객 ID, 제품 번호 및 구매 주문 번호가 올바르게 식별되어야 하고 해당 속성이 처리된 웹 로그에 병합되어야 합니다. 고객 또는 제품이 이벤트와 연관될 때마다 병합 파일이 고객 및 제품 정보를 복제한다는 점을 참고하십시오.
- **고객 데이터에 구매 및 웹 로그 정보 추가.** 고객의 가치를 모델링하려면 고객의 구매 및 세션 정보를 적절한 데이터베이스에서 골라서 합산하여 고객 데이터베이스와 병합해야 합니다. 여기에는 데이터 구축 프로세스에서 논의된 새 속성의 작성이 포함됩니다.

데이터베이스를 통합한 후에, e-소매업자는 탐색 과정을 거쳐 데이터 병합이 올바르게 수행되었는지 확인합니다.

### (2) 통합 태스크

데이터의 이해를 높이기 위해 적절한 노력을 기울이지 않으면 데이터 통합이 복잡해질 수 있습니다. 데이터 마이닝 목적에 가장 관련성 있다고 보이는 항목 및 속성에 대해 숙고한 후 데이터의 통합을 시작하십시오.

## 태스크 목록

- IBM® SPSS® Modeler에서 병합 또는 붙여쓰기 노드를 사용하여, 모델링에 유용하다고 생각 되는 데이터 세트를 통합합니다.
- 모델링을 진행하기 전에 출력 결과의 저장을 고려하십시오.
- 병합 후에, 데이터는 **통합된** 값에 의해 단순화될 수 있습니다. 통합이란 다중 레코드 및/또는 테이블로부터 정보를 요약하여 새로운 값이 계산된다는 의미입니다.
- 새 레코드(예: 수년간의 결합된 납세 신고의 평균 공제)를 생성해야 할 수도 있습니다.

## 6) 데이터 형식화

모델 작성 전의 최종 단계로서, 특정 기법에서 데이터에 특정 형식 또는 순서가 필요한지 여부를 확인하는 것이 유용합니다. 예를 들어, 시퀀스 알고리즘에서 모델 실행 전에 데이터를 예비 정렬해야 하는 경우가 드물지 않습니다. 모델이 정렬을 수행할 수 있더라도, 모델링 전에 정렬 노드를 사용하면 처리 시간을 절약할 수 있습니다.

## 태스크 목록

데이터를 형식화할 때 다음과 같은 질문을 고려하십시오.

- 어느 모델을 사용할 계획입니까?
- 이러한 모델에서는 특정 데이터 형식 또는 순서가 필요합니까?

변경이 권장되는 경우, IBM® SPSS® Modeler의 처리 도구가 필요한 데이터 조작을 적용하도록 도와줄 수 있습니다.

## 7) 모델링 준비 여부

IBM® SPSS® Modeler에서 모델 빌드 전에 다음 질문에 대한 응답을 해야 합니다.

- IBM SPSS Modeler 내에서 모든 데이터가 액세스 가능합니까?
- 초기 탐색 및 이해를 기반으로 데이터의 관련 서브세트를 선택할 수 있었습니까?
- 데이터를 효과적으로 정리했거나 구제할 수 없는 항목을 제거했습니까? 의사결정 사항을 최종 보고서에서 문서화하십시오.
- 다중 데이터 세트가 적절하게 통합되었습니까? 문서화해야 하는 병합 문제점이 있었습니까?
- 사용할 계획인 모델링 도구의 요구사항을 조사했습니까?
- 모델링 전에 해결 가능한 형식화 문제가 있습니까? 여기에는 요구되는 형식화 문제와 함께 모델링 시간을 줄일 수 있는 태스크가 포함됩니다.

위의 질문에 응답할 수 있다면 데이터 마이닝의 핵심인 모델링의 준비가 된 것입니다.

## 5. 모델링

### 1) 모델링 개요

이것은 사용자의 힘든 작업이 성과를 거두기 시작하는 지점입니다. 준비하느라 노력한 데이터가 IBM® SPSS® Modeler의 분석 도구에 입력되고, 해당 결과가 비즈니스 이해 단계 동안 제기된 비즈니스 문제점에 대한 해결의 실마리를 제공하기 시작합니다.

일반적으로 모델링은 여러 번 반복해서 수행됩니다. 일반적으로 데이터 마이닝은 기본 매개변수를 사용하여 몇 가지 모델을 실행한 후 모수를 미세 조정하거나, 선택한 모델에서 요구되는 조작을 위해 데이터 준비 단계로 되돌아갑니다. 단일 모델과 단일 실행으로 조직의 데이터 마이닝 질문이 만족스럽게 응답되는 경우는 드뭅니다. 이로 인해 데이터 마이닝이 매우 흥미로워집니다. 지정된 문제점을 살펴보는 방법은 여러 가지가 있으며 IBM SPSS Modeler는 이 작업을 도울 수 있는 매우 다양한 도구를 제공합니다.

### 2) 모델링 기법 선택

어느 유형의 모델링이 조직의 요구사항에 가장 적절한지에 대한 아이디어가 이미 있을 수 있지만 이제 어느 모델링을 사용할 것인지에 대해 확고한 결정을 할 때입니다. 가장 적절한 모델을 결정하는 것은 일반적으로 다음 고려사항을 기반으로 할 것입니다.

- **마이닝에 사용 가능한 데이터 유형.** 예를 들어, 관심 필드가 범주형(기호)입니까?
- **사용자의 데이터 마이닝 목적.** 단순히 트랜잭션 데이터 저장소에 대한 통찰력을 얻고 흥미로운 구매 패턴을 알아내고 싶습니까? 아니면 학자금 대출의 연체 성향 등을 나타내는 스코어를 생성해야 합니까?
- **특정 모델링 요구사항.** 모델이 특정 데이터 크기 또는 유형을 요구합니까? 쉽게 발표 가능한 결과가 있는 모델이 필요합니까?

IBM® SPSS® Modeler의 모델 유형 및 해당 요구사항에 대한 자세한 정보는 IBM SPSS Modeler 문서 또는 온라인 도움말을 참조하십시오.

#### (1) E-소매 예제--모델링 기법

e-소매업자가 채택하는 모델링 기법은 회사의 데이터 마이닝 목적에 따라 좌우됩니다.

**권장사항 개선.** 가장 간단한 형태로, 함께 구입하는 횟수가 가장 빈번한 제품을 판별하기 위해 구매 주문을 군집시키는 작업이 포함됩니다. 고객 데이터를 비롯하여 방문 레코드까지도 풍부한

결과를 위해 추가될 수 있습니다. 이단계 또는 코호넨 네트워크 군집 기법이 이 모델링 유형에 적합합니다. 이 후에는, 고객 방문 중 어느 시점에서 가장 적절한 권장사항을 판별하기 위해 C5.0 규칙 세트를 사용하여 군집을 프로파일링할 수 있습니다.

**사이트 탐색 개선.** 우선, e-소매업자는 자주 사용되지만 사용자가 페이지를 찾기 위해 여러 번 클릭해야 하는 페이지를 식별하는 데 초점을 맞출 것입니다. 여기에는 고객이 웹 사이트에서 선택하는 "고유 경로"를 생성하기 위해 순서 지정 알고리즘을 웹 로그에 적용한 후 수행한 동작 없이(또는 전에) 많은 페이지 방문을 가지는 세션을 구체적으로 찾는 과정이 포함됩니다. 나중에, 더 심층적인 분석에서 군집 기법을 사용하여 다른 "유형"의 방문 및 방문자를 식별할 수 있고 유형에 따라 사이트 콘텐츠를 조직하고 표시할 수 있습니다.

## (2) 올바른 모델링 기법 선택

IBM® SPSS® Modeler에서 여러 모델링 기법을 사용할 수 있습니다. 데이터 마이너는 둘 이상의 기법을 사용하여 여러 방향에서 문제점에 접근할 수 있는 경우가 빈번합니다.

태스크 목록

어떤 모델을 사용할지 결정할 때는 다음과 같은 문제가 선택에 영향을 미치는지 여부를 고려하십시오.

- 모델에서 데이터를 테스트 및 학습 세트로 분할해야 합니까?
- 지정된 모델에 대해 신뢰성 있는 결과를 생성하기에 충분한 데이터가 있습니까?
- 모델이 특정 수준의 데이터 품질을 요구합니까? 현재 데이터로 이 수준을 충족할 수 있습니까?
- 데이터가 특정 모델에 적절한 유형입니까? 그렇지 않은 경우, 데이터 조작 노드를 사용하여 필요한 변환을 수행할 수 있습니까?

IBM SPSS Modeler의 모델 유형 및 해당 요구사항에 대한 자세한 정보는 IBM SPSS Modeler 문서 또는 온라인 도움말을 참조하십시오.

## (3) 모델링 가정

선택할 모델링 도구를 좁혀가기 시작하면서 의사결정 프로세스에 대한 설명을 작성하십시오. 데이터 가정뿐 아니라 모델의 요구사항 충족을 위해 이루어진 데이터 조작에 대해 문서화하십시오.

예를 들어, 로지스틱 회귀분석 노드와 신경망 노드는 실행 전에 데이터 유형을 완전히 **인스턴스화**(데이터 유형이 알려짐)해야 합니다. 즉, 모델 빌드 및 실행 전에 유형 노드를 스트림에 추가하고 이를 실행하여 데이터를 시연해야 합니다. 마찬가지로, 예측 모형(예: C5.0)은 회귀 이벤트

에 대한 규칙을 예측할 때 데이터를 재조정하는 것이 좋습니다. 이런 유형의 예측을 할 때, 균형 노드를 스트림에 삽입하고 더 균형 잡힌 서브셋을 모델에 공급하면 종종 더 좋은 결과를 얻을 수 있습니다.

이런 유형의 의사결정을 문서화하십시오.

### 3) 테스트 설계 생성

모델을 실제로 작성하기 전의 최종 단계로서, 모델의 결과를 어떻게 테스트할지에 대해 다시 고려해야 합니다. 두 가지 부분에서 포괄적 테스트 설계를 생성합니다.

- 모델의 "우수성"에 대한 위한 기준 설명
- 이러한 기준을 테스트하기 위한 데이터 정의

모델의 **우수성**은 여러 방법으로 측정될 수 있습니다. 감독된 모델(예: C5.0 및 C&R 트리)의 경우, 우수성의 측정은 일반적으로 특정 모델의 오차율을 추정합니다. 감독되지 않은 모델(예: 코호넨 군집 넷)의 경우, 측정은 해석 또는 배포의 용이성이나 필요한 처리 시간 등의 기준을 포함할 수 있습니다.

모델 작성은 반복적 프로세스라는 것을 기억하십시오. 즉, 사용 및 배포할 모델을 결정하기 전에 일반적으로 여러 모델의 결과를 테스트하게 됩니다.

#### (1) 테스트 설계 작성

테스트 설계는 생성된 모델을 테스트하기 위해 수행할 단계에 대한 설명입니다. 모델링은 반복적 프로세스이기 때문에, 언제 모수 조정을 중지하고 다른 방법 또는 모델을 시도할지를 아는 것이 중요합니다.

태스크 목록

테스트 설계를 작성할 때는 다음과 같은 질문을 고려하십시오.

- 모델을 테스트하기 위해 어떤 데이터가 사용되니까? 데이터를 학습/테스트 세트로 파티션 분할했습니까? (이는 일반적으로 사용되는 모델링 접근법입니다.)
- 감독된 모델(예: C5.0)의 성공을 어떻게 측정할 수 있습니까?
- 감독되지 않은 모델(예: 코호넨 군집 넷)의 성공을 어떻게 측정할 수 있습니까?
- 다른 모델 유형을 시도하기 전에, 몇 회까지 설정을 조정하여 모델을 재실행하시겠습니까?

## (2) E-소매 예제--테스트 설계

CRISP-DM을 사용하는 웹 마이닝 시나리오

모델이 평가되는 기준은 고려 중인 모델 및 데이터 마이닝 목적에 따라 달라집니다.

**권장사항 개선.** 개선된 권장사항이 현재 고객에게 제시될 때까지는 이를 평가할 객관적 방법이 없습니다. 그러나 e-소매업자에게는 비즈니스 관점에서 타당하도록 충분히 단순한 권장사항을 생성하는 규칙이 필요할 수 있습니다. 마찬가지로, 규칙은 서로 다른 고객 및 세션에 대해 서로 다른 권장사항을 생성할 만큼 충분히 복잡해야 합니다.

**사이트 탐색 개선.** 고객이 웹 사이트의 어느 페이지에 액세스하는지에 대한 증거가 주어지면 e-소매업자는 중요한 페이지에 대한 액세스 용이성의 관점에서 업데이트된 사이트 디자인을 객관적으로 평가할 수 있습니다. 그러나 권장사항과 마찬가지로, 재구성된 사이트에 고객이 얼마나 잘 적응할 것인지를 미리 평가하기는 어렵습니다. 시간 및 재정이 허락할 경우, 일부 유용성 테스트는 적절할 수 있습니다.

## 4) 모델 작성

이 시점에서는 오랫동안 고려해 온 모델의 작성 준비가 잘 되어 있어야 합니다. 최종 결론을 내리기 전에 여러 가지 모델을 사용하여 실험할 시간 및 공간을 확보하십시오. 일반적으로 대부분의 데이터 마이닝은 여러 모델을 작성해서, 모델을 배포하거나 통합하기 전에 결과를 비교합니다.

다양한 모델을 사용한 진행상황을 추적하기 위해, 각 모델에 사용된 설정 및 데이터에 대한 설명을 기록해 두십시오. 이렇게 하면 결과를 다른 사람들과 논의하고 필요한 경우 해당 단계를 재추적할 수 있습니다. 모델 작성 프로세스가 완료되면 데이터 마이닝 의사결정에 사용할 세 가지 정보가 준비될 것입니다.

- **모수 설정**(최상의 결과를 생성할 모수에 대해 사용자가 작성하는 설명이 포함되어 있음)
- 생성된 실제 **모델**
- **모델 결과에 대한 설명**(모델의 실행 및 해당 결과의 탐색 동안 발생한 성능 및 데이터 문제 포함)

## (1) E-소매 예제--모델 작성

CRISP-DM을 사용하는 웹 마이닝 시나리오

**권장사항 개선.** 단순한 구매 데이터베이스부터 시작해서 관련 고객 및 세션 정보를 포함하는 데이터 통합의 다양한 수준에 대해 군집이 생성됩니다. 통합의 각 수준마다, 이단계 및 코호넨 네

트위크 알고리즘에 대한 다양한 모수 설정에 따라 군집이 생성됩니다. 이러한 각각의 군집마다, 몇 개의 C5.0 규칙 세트가 서로 다른 모수 설정으로 생성됩니다.

**사이트 탐색 개선.** 시퀀스 모델링 노드는 고객 경로를 생성하는 데 사용됩니다. 알고리즘을 통해 최소 지원 기준을 지정할 수 있으며, 이는 가장 일반적인 고객 경로에 초점을 맞추는 데 유용합니다. 모수에 대한 다양한 설정이 시도됩니다.

## (2) 모수 설정

대부분의 모델링 기법은 모델링 프로세스를 제어하기 위해 조정할 수 있는 다양한 모수 또는 설정을 가지고 있습니다. 예를 들어, 의사결정 트리는 트리 깊이, 분할 및 기타 여러 설정을 조정하여 제어할 수 있습니다. 일반적으로 대부분의 사람들은 기본 옵션을 우선 사용하여 모델을 작성한 후 후속 세션에서 모수를 세분화합니다.

가장 정확한 결과를 생성하는 모수를 판별했으면 스트림 및 생성된 모델 노드를 저장하십시오. 또한 최적 설정에 대한 설명을 작성해 두면 새 데이터로 모델을 자동화하거나 다시 작성할 때 도움이 될 수 있습니다.

## (3) 모델 실행

IBM® SPSS® Modeler에서 모델 실행은 간단한 작업입니다. 모델 노드를 스트림에 삽입하고 모수를 편집했으면 간단히 모델을 실행하여 조회 가능 결과를 생성합니다. 결과는 작업공간의 오른쪽에 있는 '생성된 모델' 네비게이터에 나타납니다. 모델을 마우스 오른쪽 단추로 클릭하여 결과를 찾아볼 수 있습니다. 대부분의 모델에서, 생성된 모델을 스트림에 삽입하여 결과를 추가적으로 평가하고 배포할 수 있습니다. 또한 모델은 쉽게 재사용할 수 있도록 IBM SPSS Modeler에 저장할 수 있습니다.

## (4) 모델 설명

모델의 결과를 검사할 때 모델링 경험에 대한 설명을 작성해야 합니다. 노드 주석 대화 상자 또는 프로젝트 도구를 사용하여 모델 자체에 설명을 저장할 수 있습니다.

## 태스크 목록

각 모델에 대해 다음과 같은 정보를 기록하십시오.

- 이 모델로부터 의미 있는 결론을 끌어낼 수 있습니까?

- 이 모델에 의해 새로운 통찰력 또는 특별한 패턴이 밝혀졌습니까?
- 이 모델에 대한 실행 문제점이 있었습니까? 처리 시간은 얼마나 합리적이었습니까?
- 이 모델은 데이터 품질 문제(예: 결측값 수가 많음)로 어려움이 있었습니까?
- 주목해야 하는 계산 불일치도 있었습니까?

## 5) 모델 평가

이제 일련의 초기 모델을 가지고 있으므로, 이들을 자세히 살펴보고 어느 모델이 최종이 될 만큼 정확하거나 효과적인지 판별하십시오. 최종이란 "배포될 준비가 된" 또는 "흥미로운 패턴을 보여주는"과 같은 여러 의미를 가질 수 있습니다. 이전에 작성한 테스트 계획을 컨설팅하면 조직의 관점에서 이 평가를 수행하는 데 도움이 될 수 있습니다.

### (1) 포괄적 모델 평가

고려 중인 각 모델에 대해, 테스트 계획에서 생성된 기준을 기반으로 조직적 평가를 수행하는 것이 좋습니다. 여기서는 생성된 모델을 스트림에 추가하고 평가 차트 또는 분석 노드를 사용하여 결과의 유효성을 분석할 수 있습니다. 또한 결과가 논리적으로 합당하지 또는 사용자의 비즈니스 목적과 관련하여 너무 단순한지(예: 와인 > 와인 > 와인과 같은 구매 시퀀스) 고려해야 합니다.

평가를 수행했다면 객관적(모델 정확도) 및 주관적(사용의 용이성 또는 결과의 해석) 기준 모두를 기반으로 모델 순위를 순서대로 지정합니다.

#### 태스크 목록

- IBM® SPSS® Modeler의 데이터 마이닝 도구(예: 평가 차트, 분석 노드 또는 교차 검증 차트)를 사용하여 모델의 결과를 평가합니다.
- 비즈니스 문제점의 이해를 기반으로 결과의 검토를 수행합니다. 특정 결과의 관련성을 간파할 수 있는 데이터 분석가 또는 기타 전문가와 상의합니다.
- 모델의 결과를 쉽게 배포할 수 있는지 여부를 고려합니다. 결과를 인터넷에서 배포할지 또는 데이터 웨어하우스로 돌려보낼지에 대해 해당 조직과 상의합니다.
- 결과가 성공 기준에 미치는 영향을 분석합니다. 비즈니스 이해 단계 중에 설정된 목적을 충족합니까?

위의 문제를 성공적으로 해결할 수 있었으며 현재 모델이 관련 목적을 충족한다고 판단되면 이제 모델의 보다 철저한 평가와 최종 배포를 진행할 때입니다. 그렇지 않다면 지금까지 배운 것을 바탕으로 모수 설정을 조정하여 모델을 재실행합니다.

## (2) E-소매 예제--모델 평가

CRISP-DM을 사용하는 웹 마이닝 시나리오

**권장사항 개선.** 코호넨 네트워크 중 하나와 이단계 군집은 각각 적절한 결과를 생성하므로 e-소매업자는 이들 중에 선택하기가 어렵다는 것을 발견합니다. 조만간 회사에서는 두 기법을 모두 사용하여 두 기법이 공통적으로 제시하는 권장사항을 수용하고 두 기법에서 차이가 나는 상황을 보다 면밀하게 연구하기를 희망합니다. 적은 노력과 적용된 비즈니스 지식을 통해, e-소매업자는 두 가지 기법 사이의 차이를 해소하기 위한 추가 규칙을 개발할 수 있습니다.

또한 e-소매업자는 세션 정보를 포함하는 결과가 놀랍게도 좋다는 것을 발견합니다. 권장사항을 사이트 탐색에 연결할 수 있다는 것을 암시하는 증거가 있습니다. 고객이 다음에 어디로 갈 수 있을지를 정의하는 규칙 집합을 실시간으로 사용하여 고객이 브라우징 중일 때 사이트 콘텐츠에 직접 영향을 미칠 수 있습니다.

**사이트 탐색 개선.** 시퀀스 모델은 특정 고객 경로를 예측할 수 있다는 높은 수준의 자신감을 e-소매업자에게 심어주고 사이트 계획에 대해 관리 가능한 수의 변경사항을 제시하는 결과를 생성합니다.

## (3) 수정된 모수 추적

모델 평가 중에 배웠던 내용을 기반으로, 모델을 다른 방식으로 살펴볼 때입니다. 여기서는 두 가지 옵션이 있습니다.

- 기존 모델의 모수를 조정합니다.
- 다른 모델을 선택하여 데이터 마이닝 문제점을 해결합니다.

두 경우 모두, 모델 작성 태스크로 돌아가서 결과가 성공적이 될 때까지 반복됩니다. 이 단계의 반복에 대해 염려하지 마십시오. 데이터 마이너가 해당 요구사항을 충족하는 모델을 찾기 전에 모델을 여러 번 평가하고 재실행하는 것은 매우 흔한 일입니다. 이것은 동시에 여러 모델을 작성하고 결과를 비교한 후 각각의 모수를 조정하기 위한 좋은 논거입니다.

## 6) 다음 단계에 대한 준비 여부

모델의 최종 평가를 진행하기 전에 초기 평가가 충분히 철저했는지 여부를 고려하십시오.

## 태스크 목록

- 모델의 결과를 이해할 수 있습니까?
- 순수하게 논리적 관점에서 모델 결과가 합당합니까? 추가 탐색을 필요로 하는 분명한 불일치가 있습니까?
- 언뜻 보기에, 해당 결과가 조직의 비즈니스 문제를 해결할 수 있겠습니까?
- 모델 정확도를 비교하고 평가하기 위해 분석 노트와 리프트 또는 Gains 차트를 사용했습니까?
- 둘 이상의 모델 유형을 탐색하고 결과를 비교했습니까?
- 모델의 결과가 배포 가능합니까?

데이터 모델링의 결과가 정확하고 관련성이 있다고 판단되면 최종 배포 전에 더 철저한 평가를 수행할 때입니다.

## 6. 평가

### 1) 평가 개요

이 시점에서는 대부분의 데이터 마이닝 프로젝트를 완료했습니다. 또한 작성된 모델이 이전에 정의한 **데이터 마이닝 성공 기준**에 따라 기술적으로 올바르고 유효한지를 모델링 단계에서 판별했습니다.

그러나 계속하기 전에 프로젝트 초기에 설정된 **비즈니스 성공 기준**을 사용하여 작업의 결과를 평가해야 합니다. 이는 획득한 결과를 조직에서 충분히 이용할 수 있게 하기 위한 열쇠입니다. 두 가지 결과 유형이 데이터 마이닝에 의해 생성됩니다.

- CRISP-DM의 이전 단계에서 선택된 최종 **모델**
- 모델 자체에서만 아니라 데이터 마이닝 프로세스에서 도출한 결론 또는 추론. 이들을 **결과물**이라고 합니다.

### 2) 결과 평가

이 단계에서는 프로젝트 결과가 비즈니스 성공 기준을 충족하는지 여부의 평가 내용을 정식화합니다. 이 단계에서는 명시된 비즈니스 목적의 분명한 이해가 필요하므로 핵심 의사결정자를 프로젝트 평가에 포함시키십시오.

## 태스크 목록

먼저, 데이터 마이닝 결과가 비즈니스 성공 기준을 충족하는지 여부의 평가 내용을 문서화해야 합니다. 보고서에서 다음과 같은 질문을 고려하십시오.

- 결과가 분명하고 쉽게 발표할 수 있는 양식으로 명시되어 있습니까?
- 강조표시해야 하는 특별히 기발하거나 독특한 결과물이 있습니까?
- 비즈니스 목적에 적용 가능한 순서대로 모델 및 결과물의 순위를 지정할 수 있습니까?
- 일반적으로, 이러한 결과가 조직의 비즈니스 목적에 얼마나 잘 부응합니까?
- 결과로 인해 어떤 추가 질문이 발생했습니까? 이러한 질문을 비즈니스 용어로 어떻게 표현할 수 있습니까?

결과를 평가한 후, 최종 보고서에 포함할 승인된 모델 목록을 컴파일하십시오. 이 목록은 데이터 마이닝과 조직의 비즈니스 목적 모두를 충족하는 모델을 포함해야 합니다.

### (1) E-소매 예제--결과 평가

CRISP-DM을 사용하는 웹 마이닝 시나리오

e-소매업자가 수행하는 첫 번째 데이터 마이닝의 전체 결과는 비즈니스 관점에서 의사 전달이 다소 용이합니다. 연구에서는 더 나은 제품이 되기 위해 바라는 권장사항과 사이트 디자인 개선 사항을 산출했습니다. 사이트 디자인 개선사항은 고객의 브라우징 순서를 기반으로 하며, 이는 고객이 원하지만 도달하기 위해 몇 가지 단계가 필요한 사이트 기능을 보여줍니다. 제품 권장사항이 더 나은지에 대한 증거는 의사결정 규칙이 복잡해질 수 있기 때문에 전달하기가 더 어렵습니다. 최종 보고서를 생성하기 위해, 분석가는 더 쉽게 설명할 수 있는 규칙 세트에서 몇 가지 일반적 추세를 식별하려고 할 것입니다.

**모델 순위화.** 몇 가지 초기 모델은 비즈니스 타당성이 있다고 보였으므로 해당 그룹 내의 순위는 통계 기준, 해석의 용이성 및 다양성을 기반으로 했습니다. 그러므로 모델은 서로 다른 상황에 대해 서로 다른 권장사항을 제공했습니다.

**새로운 질문.** 연구에서 도출할 가장 중요한 질문은 "어떻게 e-소매업자가 해당 고객에 대해 더 많이 알 수 있을까"에 대한 질문입니다. 고객 데이터베이스의 정보는 권장사항에 대한 군집을 형성함에 있어 중요한 역할을 합니다. 특별 규칙은 해당 정보가 손실된 고객에게 권장사항을 제공하기 위해 사용 가능한 반면, 권장사항은 등록된 고객에게 제공될 수 있는 특별 규칙보다 속성상 더 일반적입니다.

### 3) 프로세스 검토

일반적으로 효과적 방법론은 방금 완료된 프로세스의 성공 및 약점에 대해 숙고하기 위한 시간을 포함합니다. 데이터 마이닝은 다르지 않습니다. CRISP-DM의 일부는 이후의 데이터 마이닝 프로젝트가 보다 효과적이 되도록 사용자의 경험으로부터 배우고 있습니다.

#### 태스크 목록

먼저 데이터 준비 단계, 모델 작성 등의 각 단계에 대한 활동 및 의사결정을 요약해야 합니다. 그런 다음 각 단계에 대해 다음과 같은 질문을 고려하고 개선을 위한 제안을 해야 합니다.

- 이 단계는 최종 결과의 가치에 기여했습니까?
- 이 특정 단계 또는 작업을 합리화하거나 개선할 방법이 있습니까?
- 이 단계의 실패 또는 실수가 무엇이었습니까? 다음 번에는 어떻게 회피할 수 있습니까?
- 결실이 없는 특정 모델과 같은 교착 상황이 있었습니까? 작업을 보다 생산적으로 진행할 수 있도록 이러한 교착 상황을 예측할 방법이 있습니까?
- 이 단계에서 의외의 (좋은 또는 나쁜) 상황이 발생했습니까? 되돌아 봤을 때, 이러한 상황을 예측할 수 있는 분명한 방법이 있습니까?
- 해당 단계에서 사용되었을 수 있는 대체 의사결정 또는 처리 방법이 있습니까? 이후의 데이터 마이닝 프로젝트를 위해 해당 대안을 기록하십시오.

#### (1) E-소매 예제--검토 보고서

##### CRISP-DM을 사용하는 웹 마이닝 시나리오

초기 데이터 마이닝 프로젝트의 프로세스를 검토함으로써, e-소매업자는 프로세스 단계 사이의 상호관계를 잘 이해하게 되었습니다. 처음에는 CRISP-DM 프로세스를 역추적하는 것이 내키지 않았던 e-소매업자는 이제 프로세스의 순환성이 그 힘을 증강시킨다는 사실을 이해합니다. 또한 프로세스 검토는 e-소매업자가 다음과 같은 사실을 이해하도록 도왔습니다.

- 특별한 상황이 CRISP-DM 프로세스의 다른 단계에서 나타나는 경우 탐색 프로세스로의 회귀가 항상 보장됩니다.
- 데이터 준비(특히 웹 로그의 경우)는 매우 오랜 시간이 걸릴 수 있으므로 인내심이 필요합니다.
- 일단 데이터의 분석 준비가 되면 더 큰 그림과 상관없이 모델 구축을 시작하기가 너무 쉽기 때문에 당면한 비즈니스 문제점에 계속 초점을 맞추는 것이 중요합니다.
- 모델링 단계가 끝나면, 결과 구현 방식을 결정하고 어떠한 추가 연구가 보장되는지 판별함에 있어서 비즈니스 이해가 훨씬 더 중요합니다.

#### 4) 다음 단계 결정

지금까지, 결과를 생성했고 데이터 마이닝 경험을 평가했는데 **다음은 어디로?**라고 궁금해 할지도 모릅니다. 이 단계는 데이터 마이닝을 위한 비즈니스 목적에 비추어 해당 질문에 응답하도록 돕습니다. 본질적으로, 이 시점에서는 두 가지 선택이 있습니다.

- **배포 단계를 진행합니다.** 다음 단계에서는 모델 결과를 비즈니스 프로세스에 통합하고 최종 보고서를 생성하도록 도울 것입니다. 데이터 마이닝 작업이 성공하지 못했을지라도, CRISP-DM의 배포 단계를 사용하여 프로젝트 스폰서에게 배포할 최종 보고서를 작성해야 합니다.
- **뒤로 돌아가서 모델을 세분화하거나 대체합니다.** 해당 결과가 거의 최적이지만 아주 최적은 아니라면 다른 모델링 라운드를 고려하십시오. 이 단계에서 배운 내용을 사용하여 모델을 세분화하고 더 나은 결과를 생성할 수 있습니다.

이 시점에서의 의사결정은 모델링 결과의 정확도 및 관련성을 고려합니다. 결과가 데이터 마이닝 및 비즈니스 목적에 합당하면 배포 단계 준비가 된 것입니다. 어떤 의사결정을 하더라도 평가 프로세스를 철저하게 문서화하십시오.

##### (1) E-소매 예제--다음 단계

CRISP-DM을 사용하는 웹 마이닝 시나리오

e-소매업자는 프로젝트 결과의 정확도와 연관성을 상당히 신뢰하므로 배포 단계를 진행합니다.

동시에, 프로젝트 팀은 뒤로 돌아가서 예측 기술을 포함하도록 일부 모델을 보완할 준비가 되어 있습니다. 이 시점에서 그들은 최종 보고서의 전달과 의사결정자의 승인을 기다리고 있습니다.

## 7. 배포

### 1) 배포 개요

배포는 새로운 통찰력을 사용하여 조직 내에서 개선을 수행하는 프로세스입니다. 이는 정식 통합 (예: 데이터 웨어하우스에 읽혀질 이탈 스코어를 생성하는 IBM® SPSS® Modeler 모델의 구현)을 의미할 수 있습니다. 또는 배포가 데이터 마이닝에서 얻은 통찰력을 사용하여 조직 내에서 변화를 이끌어내는 것을 의미할 수도 있습니다. 예를 들어, 데이터에서 30살이 넘는 고객의 행동 변화를 나타내는 놀라운 패턴을 발견했을 수 있습니다. 이러한 결과는 정보 시스템에 정식으로 통합되지 않을지도 모르지만 확실히 계획 및 마케팅 의사결정에 유용할 것입니다.

일반적으로, CRISP-DM의 배포 단계는 두 가지 유형의 활동을 포함합니다.

- 결과 배포의 계획 및 모니터링
- 결론 태스크(예: 최종 보고서 생성 및 프로젝트 검토 수행) 완료

조직의 요구사항에 따라, 이러한 단계 중 하나 또는 모두를 완료해야 할 수도 있습니다.

## 2) 배포 계획

데이터 마이닝 작업의 과실을 공유하고자 조급할지라도, 원활하고 포괄적인 결과 배포를 계획할 시간을 가지십시오.

태스크 목록

- 첫 번째 단계는 결과(모델과 결과물)를 요약하는 것입니다. 이렇게 하면 어느 모델이 데이터베이스 시스템 내에 통합될 수 있으며 어느 결과물을 동료에게 발표할지 판별할 수 있습니다.
- 배포 가능한 각 모델에 대해, 사용자 시스템에서의 배포 및 통합을 위한 단계별 계획을 작성하십시오. 모델 출력에 대한 데이터베이스 요구사항 등의 기술적 세부사항을 참고하십시오. 예를 들어, 사용자 시스템에서는 모델링 출력을 탭 구분 데이터 형식으로 배포해야 할 수도 있습니다.
- 결론적인 각 결과물에 대해, 이 정보를 전략결정자에게 전달하기 위한 계획을 작성하십시오.
- 언급할 가치가 있는 두 결과 유형 모두에 대한 대체 배포 계획이 있습니까?
- 배포가 모니터링되는 방식을 고려하십시오. 예를 들어, IBM® SPSS® Modeler Solution Publisher를 사용하여 배포된 모델을 어떻게 업데이트합니까? 모델을 더 이상 적용하지 못하는 시기를 어떻게 결정하시겠습니까?
- 배포 문제점을 식별하고 비상 계획을 마련하십시오. 예를 들어, 의사결정자는 모델링 결과에 대한 자세한 정보를 원할 수 있고 더 많은 기술적 세부사항을 제공하도록 요구할 수 있습니다.

### (1) E-소매 예제--배포 계획

CRISP-DM을 사용하는 웹 마이닝 시나리오

e-소매업자의 데이터 마이닝 결과가 성공적으로 배포되려면 올바른 정보가 올바른 사람에게 전달되어야 합니다.

**의사결정자.** 의사결정자는 사이트에 대한 권장사항 및 변경 제안을 통지받아야 하고 이러한 변경이 어떻게 도움이 될지에 대한 간단한 설명을 제공받아야 합니다. 의사결정자가 해당 연구 결과를 승인할 경우, 변경을 구현할 사람들에게 통지되어야 합니다.

**웹 개발자.** 웹 사이트를 유지보수하는 사람들은 새 권장사항과 사이트 콘텐츠의 조직을 통합해야 할 것입니다. 미래 연구로 인해 어떤 변화가 발생할 수 있는지 알려서 지금 기초를 놓을 수 있게 하십시오. 팀에게 실시간 시퀀스 분석을 기반으로 한 동적 사이트 구축을 준비시키면 나중에 도움이 될 수 있습니다.

**데이터베이스 전문가.** 고객, 구매 및 제품 데이터베이스를 유지보수하는 사람들은 데이터베이스의 정보가 어떻게 사용되고 있으며 어떤 속성이 이후 프로젝트에 추가될 수 있는지에 대해 지속적인 통지를 받아야 합니다.

무엇보다도 프로젝트 팀은 결과의 배포 및 이후 프로젝트의 계획을 조정하기 위해 각각의 해당 그룹과 지속적으로 의견을 나누어야 합니다.

### 3) 모니터링 및 유지보수 계획

모델링 결과의 완전한 배포 및 통합에서, 데이터 마이닝 작업은 진행 중일 수 있습니다. 예를 들어, 장바구니 구매의 순서를 예측하기 위해 모델이 배포된 경우 이 모델은 해당 유효성을 보장하고 지속적인 개선을 수행하기 위해 정기적으로 평가할 필요가 있습니다. 마찬가지로, 우수 고객 중에 고객 유지를 증가시키기 위해 배포된 모델은 특정 유지 수준에 도달하게 되면 개조할 필요가 있습니다. 그런 다음 이 모델을 수정 후 재사용하여 더 낮은 수준이지만 가치 피라미드에서 여전히 수익성 있는 수준에서 고객을 유지할 수 있습니다.

#### 태스크 목록

다음 문제에 대한 설명을 작성하고 최종 보고서에 이를 포함시키십시오.

- 각 모델 또는 결과물에 대해, 어느 요인 또는 영향력(예: 시장 가치 또는 계절적 변화)을 추적해야 합니까?
- 각 모델의 타당성 및 정확도를 어떻게 측정하고 모니터링할 수 있습니까?
- 모델이 "만료"되는 시기를 어떻게 판별할 수 있습니까? 정확도 임계값 또는 예상되는 데이터 변화 등에 대한 세부적인 사항을 제공합니다.
- 모델이 만료되면 어떤 상황이 발생할 것입니까? 단순히 최신 데이터로 모델을 다시 빌드하거나 약간의 조정을 할 수 있습니까? 아니면 새로운 데이터 마이닝 프로젝트가 필요할 만큼 변경사항이 광범위하겠습니까?
- 이 모델이 만료된 후 유사한 비즈니스 문제에 이 모델을 사용할 수 있습니까? 각 데이터 마이닝 프로젝트에 대한 비즈니스 목적을 평가하기 위해 충실한 문서화가 중요한 이유가 바로 이것입니다.

## (1) E-소매 예제--모니터링 및 유지보수

CRISP-DM을 사용하는 웹 마이닝 시나리오

모니터링의 당면 과제는 새 사이트 조직과 개선된 권장사항이 실제로 효과가 있는지를 판별하는 것입니다. 즉, 사용자가 그들이 찾는 페이지에 더 직접적으로 이동할 수 있습니까? 권장 품목의 교차 판매가 증가했습니까? 모니터링의 몇 주 후에, e-소매업자는 연구의 성공을 판별할 수 있습니다.

자동으로 처리될 수 있는 것은 새로 등록된 사용자의 포함입니다. 고객이 사이트에 등록하면 현재 규칙 세트가 고객의 정보에 적용되어 어떤 권장사항을 제공해야 하는지 결정할 수 있습니다.

권장사항을 결정하는 규칙 세트를 언제 업데이트할지를 결정하는 것은 보다 까다로운 작업입니다. 군집 작성을 위해서는 해당 군집 솔루션의 적절성에 관한 사용자 입력이 필요하기 때문에 규칙 세트의 업데이트는 자동 프로세스가 아닙니다.

이후 프로젝트는 더 복잡한 모델을 생성할 것이므로 모니터링의 필요성과 그 양은 거의 확실히 증가할 것입니다. 가능하면 대부분의 모니터링은 자동이어야 하며 정기적으로 스케줄링된 보고서로 검토 가능해야 합니다. 또는 동적으로 예측을 제공하는 모델의 작성이 회사가 추구하는 방향일 수 있습니다. 이를 위해서는 처음 데이터 마이닝 프로젝트보다 팀의 정교한 작업이 더 필요합니다.

## 4) 최종 보고서 생성

최종 보고서 작성은 선행 문서의 부족한 면을 보완할 뿐만 아니라 결과를 서로 전달하는 용도로도 사용할 수 있습니다. 당연해 보일 수도 있지만, 결과에 지분을 가진 다양한 사람들에게 결과를 발표하는 것은 중요합니다. 모델링 결과의 구현을 담당하는 기술적 관리자뿐만 아니라 결과를 기반으로 의사결정을 수행할 마케팅 및 관리 스폰서가 관련 대상이 될 수 있습니다.

태스크 목록

먼저, 보고서의 청중을 고려하십시오. 이들은 기술적 개발자 또는 시장 집중 관리자입니까? 해당 요구사항이 서로 다르면 각 청중에 대해 별도의 보고서를 작성해야 할 수도 있습니다. 어느 경우이든, 보고서는 다음 사항을 대부분 포함시켜야 합니다.

- 원래 비즈니스 문제점에 대한 철저한 설명
- 데이터 마이닝을 수행하는 데 사용되는 프로세스
- 프로젝트의 비용
- 원래 프로젝트 계획에서 벗어나는 것에 대한 설명

- 데이터 마이닝 결과(모델 및 결과물)의 요약
- 배포에 대해 제안된 계획의 개요
- 탐색 및 모델링 동안 발견된 흥미로운 리드를 비롯하여 추가 데이터 마이닝 작업에 대한 권장사항

### (1) 최종 프리젠테이션 준비

프로젝트 보고서 외에, 프로젝트 결과물을 스폰서 또는 관련 부서의 팀에게 발표해야 할 수도 있습니다. 이 경우, 보고서의 정보와 거의 동일한 정보를 사용하지만 더 넓은 관점에서 발표할 수 있습니다. IBM® SPSS® Modeler의 차트 및 그래프는 이 프리젠테이션 유형을 위해 쉽게 내보낼 수 있습니다.

### (2) E-소매 예제--최종 보고서

CRISP-DM을 사용하는 웹 마이닝 시나리오

원래 프로젝트 계획에서 편차가 많이 나는 것은 추가 데이터 마이닝 작업을 위한 흥미로운 리드이기도 합니다. 원래 계획의 목적은 고객이 사이트 방문 시 더 많은 시간을 보내고 더 많은 페이지를 보도록 할 방법을 찾아내는 것이었습니다.

결과적으로, 고객 만족은 단지 고객이 온라인에서 오래 머무르게 하는 문제가 아닙니다. (세션이 구매로 이어졌는지 여부에 따라 분할된) 세션당 소요된 시간의 빈도 분포는 구매로 이어진 대부분의 세션에 대한 세션 시간이 비구매 세션의 두 군집에 대한 세션 시간 사이에 있다는 것을 알아내었습니다.

이것을 알아냈으므로 이제 문제는 구매 없이 사이트에서 오래 머무르는 고객이 단지 아이쇼핑 중인지 또는 찾고 있는 상품이 없는 것인지 알아내는 것입니다. 그 다음 단계는 구매를 촉진하도록 그들이 찾고 있는 상품을 조달할 방법을 알아내는 것입니다.

## 5) 최종 프로젝트 검토 수행

이것은 CRISP-DM 방법론의 최종 단계이며, 사용자의 최종 인상을 공식화하고 데이터 마이닝 프로세스 동안에 배운 교훈을 대조할 기회를 제공합니다.

태스크 목록

데이터 마이닝 프로세스에 상당히 참여한 사람들과 간단한 인터뷰를 수행해야 합니다. 이러한 인터뷰 동안 고려할 질문은 다음과 같습니다.

- 프로젝트에 대한 전체적인 인상은 어떻습니까?
- 일반적인 데이터 마이닝 및 사용 가능한 데이터와 관련해서 이 프로세스 동안 무엇을 배웠습니까?
- 프로젝트의 어떤 부분이 잘 진행되었습니까? 어디서 어려움이 발생했습니까? 혼란을 완화하는데 도움이 된 정보가 있었습니까?

데이터 마이닝 결과가 배포된 후, 해당 결과에 의해 영향을 받은 사람들(예: 고객 또는 비즈니스 파트너)과도 인터뷰할 수 있습니다. 여기서의 목적은 프로젝트를 수행할 가치가 있었고 프로젝트를 기획할 때 설정한 혜택이 제공되었는지 판별하는 것이어야 합니다.

이러한 인터뷰의 결과는 데이터 저장소 마이닝 경험에서 배운 교훈에 초점을 맞춰야 하는 최종 보고서에서 프로젝트에 대한 자신의 인상과 함께 요약될 수 있습니다.

### (1) E-소매 예제--최종 검토

CRISP-DM을 사용하는 웹 마이닝 시나리오

**프로젝트 멤버 인터뷰.** 가장 밀접하게 시종일관 연구와 연관된 프로젝트 멤버가 대부분 결과에 열중하고 이후 프로젝트를 고대한다는 것을 e-소매업자는 발견합니다. 데이터베이스 그룹은 조심스럽게 낙관적인 것 같습니다. 이들은 연구의 유용성을 인정하지만 데이터베이스 자원에 대한 추가 부담을 지적합니다. 연구 중에는 컨설턴트가 사용 가능했지만, 상황이 진행되면서 프로젝트 범위가 확장됨에 따라 데이터베이스 유지보수 전담 직원이 필요할 것입니다.

**고객 인터뷰.** 고객 피드백은 지금까지 주로 긍정적이었습니다. 심사숙고하지 않았던 한 가지 문제는 기존 고객이 사이트 디자인 변경에 대해 어떻게 생각할 것이냐는 것이었습니다. 몇 년 후에, 등록된 고객은 사이트가 조직되는 방식에 대한 특정 기대치를 발전시켰습니다. 등록된 사용자의 피드백은 등록되지 않은 고객의 피드백만큼 그리 긍정적이지 않으며 소수 사람들은 변경을 매우 싫어합니다. e-소매업자는 이 문제를 숙지하고 있어야 하며 변경으로 인해 기존 고객을 잃을 위험을 감수하고 새 고객을 충분히 불러올 수 있을지에 대해 신중히 고려해야 합니다.

## VI. IBM SPSS Modeler Text Analytics 도움말

### 1. IBM SPSS Modeler Text Analytics 정보

IBM® SPSS® Modeler Text Analytics는 고급 언어학적 기술 및 자연어 처리(NLP)를 사용하여 다양한 비정형 텍스트 데이터를 빠르게 처리하고, 이 텍스트에서 주요 개념을 추출 및 구성하는 강력한 텍스트 분석 기능을 제공합니다. 게다가, IBM SPSS Modeler Text Analytics는 이러한 개념을 범주로 그룹화할 수 있습니다.

조직 내에 보유한 데이터의 약 80%는 텍스트 문서 양식(예: 보고서, 웹 페이지, 이메일 및 콜센터 노트)으로 되어 있습니다. 텍스트는 조직이 해당 고객의 행동을 잘 이해할 수 있도록 할 때 핵심 요인입니다. NLP를 통합하는 시스템은 복합 구문을 포함하여 개념을 지능적으로 추출할 수 있습니다. 또한 의미와 컨텍스트를 사용하여, 기본적인 언어에 대한 지식을 통해 제품, 조직, 또는 사람과 같은, 관련 그룹으로 용어를 분류할 수 있습니다. 결과적으로, 신속하게 필요성에 대한 정보의 관련성을 판별할 수 있습니다. 추출된 개념과 범주는 인구 통계와 같은 기존의 구조화된 데이터와 결합할 수 있고 보다 나은 집중적인 의사결정을 내리기 위해 전체 IBM SPSS Modeler 데이터 마이닝 도구 세트에서 모델링에 적용할 수 있습니다.

언어학적 시스템은 지식에 민감하며 사전에 더 많은 정보가 포함될수록 결과의 품질이 높아집니다. IBM SPSS Modeler Text Analytics는 용어 및 동의어, 라이브러리 및 템플릿과 같은 언어학적 자원 세트와 함께 전달됩니다. 이 제품은 추가적으로 컨텍스트에 대해 이러한 언어학적 자원을 개발하고 세분화할 수 있도록 합니다. 언어학적 자원의 미세한 조정은 종종 반복적 프로세스로, 정확한 개념 검색 및 범주화에 필요합니다. CRM 및 유전체학과 같은, 사용자 정의 템플릿, 라이브러리 및 특정 도메인용 사전도 포함됩니다.

**배포.** 비정형 데이터의 실시간 스코어링을 위해 IBM SPSS Modeler Solution Publisher를 사용하여 텍스트 마이닝 스트림을 배치할 수 있습니다. 이들 스트림을 배치하는 기능은 성공적인 페쇄 루프 텍스트 마이닝 구현을 보장합니다. 예를 들어, 사용자 조직이 이제 예측 모델을 적용하여 마케팅 메시지의 정확도를 실시간으로 늘려서 인바운드 또는 아웃바운드 호출자의 메모철을 분석할 수 있습니다.

IBM SPSS Modeler Solution Publisher와 함께 IBM SPSS Modeler Text Analytics를 실행하려면 <install\_directory>/ext/bin/spss.TMWBServer 디렉토리를 \$LD\_LIBRARY\_PATH 환경 변수에 추가하십시오.

 **참고:** IBM SPSS Modeler Text Analytics의 일본어 어댑터가 버전 18.1부터 더 이상 사용되지 않습니다.

## 1) IBM SPSS Modeler Text Analytics 업그레이드

IBM® SPSS® Modeler Text Analytics를 설치하기 전에 새 버전에서 사용할 TAP, 템플릿 및 라이브러리를 저장하고 현재 버전에서 내보내야 합니다. 이러한 파일은 최신 버전을 설치할 때 삭제되거나 덮어쓰지 않는 디렉토리에 저장하는 것이 좋습니다.

최신 버전의 IBM SPSS Modeler Text Analytics를 설치한 후에는 저장한 TAP 파일을 로드하거나, 저장한 라이브러리를 추가하거나, 저장한 템플릿을 가져와서 로드하여 최신 버전에서 사용할 수 있습니다.

❖ **중요사항:** 먼저 필요한 파일을 저장한 후 내보내지 않고 현재 버전을 제거할 경우 이전 버전에서 수행한 모든 TAP, 템플릿 및 공용 라이브러리 작업은 손실되어 IBM SPSS Modeler Text Analytics에서 사용할 수 없습니다.

## 2) 텍스트 마이닝 정보

오늘날 점점 늘어나는 정보의 양이 구조화되지 않은 준구조화된 형식으로 보존되어 있습니다. 예를 들어, 고객 이메일, 콜 센터 메모, 개방형 설문 반응, 뉴스 피드, 웹 양식 등입니다. 이러한 정보의 풍요는 많은 조직에게 다음과 같은 질문을 던지는 문제점을 야기합니다. "이 정보를 어떻게 수집, 탐색하고 활용할 수 있습니까?"

텍스트 마이닝은 작성자가 개념을 표현하기 위해 사용한 정확한 단어와 용어를 모르더라도 주요 개념과 테마를 캡처하고 숨겨진 관계와 경향을 발견하기 위해 텍스트 자료 컬렉션을 분석하는 프로세스입니다. 텍스트 마이닝은 정보 검색과는 상당히 다르기는 하지만 종종 혼동되기도 합니다. 정확한 검색과 정보 저장은 엄청난 도전인 반면에 이러한 정보에 포함된 품질 콘텐츠, 용어 및 관계의 추출과 관리는 결정적이고 중요한 프로세스입니다.

### 텍스트 마이닝 및 데이터 마이닝

텍스트의 각 기사마다 언어학적 기반 텍스트 마이닝은 개념 지수뿐만 아니라 이러한 개념에 대한 정보를 리턴합니다. 이 순화된 구조화된 정보는 다른 데이터 소스와 결합되어 다음과 같은 질문을 처리할 수 있습니다.

- 어떤 개념이 함께 발생합니까?
- 그 밖에 어디에 링크되어 있습니까?
- 추출된 정보로부터 어떤 상위 수준 범주를 작성할 수 있습니까?
- 개념 또는 범주가 예상하는 것은 무엇입니까?
- 개념 또는 범주가 작동을 어떻게 예상합니까?

텍스트 마이닝을 데이터 마이닝과 결합하면 구조화된 또는 구조화되지 않은 데이터에서만 사용 가능한 것보다 더 많은 통찰력을 제공합니다. 이 프로세스는 일반적으로 다음 단계를 포함합니다.

1. **마이닝할 텍스트를 식별하십시오.** 텍스트 마이닝을 준비하십시오. 텍스트가 여러 파일에 존재하면 파일을 한 위치에 저장하십시오. 데이터베이스의 경우 텍스트를 포함하는 필드를 판별하십시오.
2. **텍스트를 마이닝하고 구조화된 데이터를 추출하십시오.** 텍스트 마이닝 알고리즘을 소스 텍스트에 적용하십시오.
3. **개념 및 범주 모델을 작성하십시오.** 주요 개념을 식별하고 범주를 작성하십시오. 구조화되지 않은 데이터로부터 리턴된 개념 수는 일반적으로 매우 큼니다. 스코어링을 위해 최상의 개념과 범주를 식별하십시오.
4. **구조화된 데이터를 분석하십시오.** 군집, 분류 및 예측 모델링과 같은 일반적인 데이터 마이닝 기술을 사용하여 개념 간의 관계를 발견하십시오. 추출된 개념을 다른 구조화된 데이터와 병합하여 개념을 기반으로 추가로 동작을 예측하십시오.

## 텍스트 분석 및 범주화

질적 분석의 양식으로 된 텍스트 분석은 이 텍스트에 포함된 주요 아이디어와 개념이 적합한 개수의 범주로 그룹화될 수 있도록 텍스트로부터의 유용한 정보의 추출입니다. 텍스트 분석은 분석의 접근 방법은 다소 다르더라도 모든 유형과 텍스트 길이에서 수행될 수 있습니다.

짧은 레코드 또는 문서가 가장 쉽게 범주화됩니다. 이들은 복잡하지 않고 일반적으로 애매한 단어나 반응이 적기 때문입니다. 예를 들어, 짧은 개방형 설문 질문에서 사람들에게 좋아하는 세 가지의 휴가 활동을 꼽으라고 물으면 해변에 가기, 국립공원 방문 또는 아무것도 안하기 등과 같은 짧은 답변을 여러 개 예상할 수 있습니다. 반면 더 긴 개방형 반응은 복잡하고 길 수 있으며 반응자가 교육을 많이 받았고, 동기가 있고, 설문지를 작성할 시간이 충분한 경우에는 특히 그렇습니다. 설문에서 사람들에게 자신의 정치적 신념에 대해 얘기해 달라고 묻거나 정치에 대한 블로그 피드를 가지도록 요청하면 모든 종류의 문제와 위치에 대해 다소 긴 설명을 예측할 수 있습니다.

단시간에 주요 개념을 추출하고 이러한 긴 텍스트 소스로부터 통찰력있는 범주를 작성하는 기능은 IBM® SPSS® Modeler Text Analytics 사용의 주요 장점입니다. 이 장점은 텍스트 분석 프로세스의 각 단계마다 가장 안정적인 결과를 내기 위해 자동화된 언어학적 및 통계적 기술의 결합을 통해 획득됩니다.

## 언어학적 처리와 NLP

이 구조화되지 않은 모든 텍스트 데이터 관리의 주요 문제점은 컴퓨터가 이해할 수 있도록 텍스트를 쓰기 위한 표준 규칙이 없다는 점입니다. 언어, 따라서 의미는 모든 문서 및 모든 텍스트마다 다릅니다. 이러한 구조화되지 않은 데이터를 정확하게 검색하고 조직하는 유일한 방법은 언어를 분석하고 해당 의미를 발견하는 것입니다. 구조화되지 않은 정보로부터 개념 추출을 위한 여러 개의 자동화된 방법이 있습니다. 이러한 접근 방법은 언어학적 및 비언어학적인 두 가지 종류로 구분할 수 있습니다.

몇몇 조직에서는 통계 및 신경망을 기반으로 자동화된 비언어학적 솔루션을 사용하려고 시도했습니다. 컴퓨터 기술을 사용하면 이러한 솔루션은 사람보다 더 빨리 주요 개념을 스캔하고 범주화할 수 있습니다. 불행하게도 이러한 솔루션의 정확도는 매우 낮습니다. 대부분의 통계 기반 시스템은 단순히 단어가 발생한 횟수를 세고 관련 개념에 대한 통계적 인접성을 계산합니다. 이는 관련되지 않은 결과 또는 잡음을 생성하고, 반드시 있어야 하는 결과가 누락되고 침묵으로 처리됩니다.

정확도의 한계를 보충하기 위해서 몇몇 솔루션은 관련 결과와 비관련 결과를 구분하는 데 도움이 되는 복잡한 비언어 규칙을 사용합니다. 이를 규칙 기반 텍스트 마이닝이라고 부릅니다.

반면, 언어학적 기반 텍스트 마이닝은 자연어 처리(NLP)-인간 언어의 컴퓨터 지원 분석-의 원칙을 텍스트의 단어, 구문 및 명령문 또는 구조에 적용합니다. NLP를 통합하는 시스템은 복합 구문을 포함하여 개념을 지능적으로 추출할 수 있습니다. 게다가, 기본 언어 지식을 사용하면 의미 및 컨텍스트를 사용하여 개념을 제품, 조직 또는 사람 등과 같은 관련 그룹으로 분류할 수 있습니다.

언어학적 기반 텍스트 마이닝은 방대한 단어 양식을 유사한 의미가 있는 것으로 인식하고 문장 구조를 분석하여 텍스트 이해를 위한 프레임워크를 제공하여 사람들이 하는 방법으로 텍스트에서 많은 의미를 찾아냅니다. 이 방법은 통계 기반 시스템의 속도와 비용 효율성을 제공하지만 사람의 개입은 덜 요구하면서 훨씬 더 높은 수준의 정확도를 제공합니다.

추출 프로세스 중에 통계 기반과 언어학적 기반 접근 방식 간의 차이를 설명하려면 reproduction of documents에 대한 쿼리에 대해 반응하는 방법을 고려하십시오. 통계 기반 및 언어학적 기반 솔루션 둘 모두는 reproduction 단어를 copy 및 duplication 등과 같은 동의어를 포함하기 위해 확장해야 합니다. 그렇지 않으면 관련 정보를 빠뜨리게 됩니다. 그러나 통계 기반 솔루션이 의미가 같은 다른 용어에 대해 이 유형의 동의어 검색을 하려고 시도하면 birth 용어 또한 포함하려고 하므로 관련이 없는 결과가 많이 생성됩니다. 다시 말해서 언어의 이해는 텍스트의 모호성을 극복하여 언어학적 기반 텍스트 마이닝을 보다 믿을 만한 방법으로 만들어 줍니다.

추출 프로세스의 작동 방법을 이해하면 언어학적 자원(라이브러리, 유형, 동의어 등)을 세부 조정할 때 중요한 결정을 내리는 데 도움이 됩니다. 추출 프로세스의 단계는 다음을 포함합니다.

- 소스 데이터를 표준 형식으로 변환
- 후보 항 식별
- 동의어의 동등 클래스 및 통합 식별
- 유형 지정
- 색인화 및 요청 시에 2차 분석기와 패턴 매치

## 1단계. 소스 데이터를 표준 형식으로 변환

이 첫 번째 단계에서, 사용자가 가져오는 데이터가 추가 분석에 사용될 수 있는 균일한 형식으로 변환됩니다. 이 변환은 내부적으로 수행되므로 원래 데이터를 변경하지 않습니다.

## 2단계. 후보 항 식별

언어학적 추출 중에 후보 항의 식별에서 언어학적 자원의 역할을 이해하는 것이 중요합니다. 언어학적 자원은 추출이 실행될 때마다 사용됩니다. 이들은 템플릿, 라이브러리 및 컴파일된 자원의 양식으로 존재합니다. 라이브러리에는 단어 목록, 관계 및 추출을 지정하거나 조정하는 데 사용되는 기타 정보가 포함됩니다. 컴파일된 자원은 보거나 편집할 수 없습니다. 그러나 나머지 자원은 템플릿 편집기에서나 대화식 워크벤치 세션에 있는 경우에는 자원 편집기에서 편집할 수 있습니다.

컴파일된 자원은 IBM SPSS Modeler Text Analytics 내에서 추출 엔진의 핵심적인 내부 구성 요소입니다. 이러한 자원에는 품사 코드(명사, 동사, 형용사 등)가 있는 기본 양식 목록을 포함하는 일반 사전이 포함됩니다.

컴파일된 자원 외에, 여러 개의 라이브러리가 제품과 함께 제공되며 컴파일된 자원에서 유형 및 개념 정의를 보완하고 동의어를 제공하는 데 사용될 수 있습니다. 이러한 라이브러리 및 사용자가 작성하는 사용자 정의 라이브러리는 몇몇 사전으로 구성됩니다. 여기에는 유형 사전, 동의어 사전 및 제외 사전이 포함됩니다.

데이터를 가져와서 변환한 후 추출 엔진이 추출을 위한 후보 항 식별을 시작합니다. 후보 항은 텍스트에서 개념을 식별하는 데 사용되는 단어나 단어 그룹입니다. 텍스트를 처리하는 동안 단일 단어(단일어) 및 복합어(다항어)가 품사 패턴 추출기를 사용하여 식별됩니다. 그런 다음, 후보 정서 키워드는 정서 텍스트 링크 분석을 사용하여 식별됩니다.

**참고:** 앞서 언급한 컴파일된 일반 사전에 있는 용어는 관심이 없거나 언어학적으로 단일어로서는 애매한 모든 단어 목록을 나타냅니다. 이러한 단어는 단일어를 식별할 때 추출에서 제외됩니다. 그러나, 품사를 판별할 때나 더 긴 후보 복합 단어(다항어)를 찾을 때 다시 평가됩니다.

### 3단계. 동의어의 동등 클래스 및 통합 식별

후보 단일어 및 다항어가 식별된 후 소프트웨어는 정규화 사전을 사용하여 동등 클래스를 식별합니다. 동등 클래스는 한 구문의 기본 양식이거나 동일 구문에 대한 두 개의 변형이 있는 단일 양식입니다. 구문을 동등 클래스에 지정하기 위한 목적은 예를 들어, side effect 및 副作用이 별개의 개념으로 처리되지 않도록 하기 위한 것입니다. 동등 클래스에 사용할 개념(즉, side effect 또는 副作用이 리드 용어로 사용되는지 여부)을 판별하기 위해 추출 엔진은 다음 규칙을 나열된 순서대로 적용합니다.

- 라이브러리의 사용자 지정 양식.
- 사전에 컴파일된 자원으로 정의되는 최대 빈도 양식.

### 4단계. 유형 지정

다음으로 유형은 추출된 개념에 지정됩니다. 유형은 개념의 시맨틱 그룹입니다. 이 단계에서는 컴파일된 자원과 라이브러리 둘 모두가 사용됩니다. 유형은 상위 레벨 개념, 긍정적 및 부정적 단어, 이름, 장소, 조직 등과 같은 것을 포함합니다. 자세한 정보는 유형 사전의 내용을 참조하십시오.

언어학적 시스템은 지식에 민감하며 사전에 더 많은 정보가 포함될수록 결과의 품질이 높아집니다. 동의어 정의 등과 같이 사전 콘텐츠의 수정은 결과로 나오는 정보를 단순화할 수 있습니다. 이는 종종 반복적인 프로세스이며 정확한 개념 검색을 위해 필요합니다. NLP는 IBM SPSS Modeler Text Analytics의 코어 요소입니다.

#### (1) 추출 작동 방법

반응으로부터 핵심 개념 및 아이디어의 추출 중에 IBM® SPSS® Modeler Text Analytics 는 언어 기반 텍스트 분석에 의존합니다. 이 접근 방법은 통계 기반 시스템의 속도와 비용 효율성을 제공합니다. 그러나 인간의 개입은 덜 요구하면서 훨씬 더 높은 수준의 정확도를 제공합니다. 언어 기반 텍스트 분석은 자연어 처리로 알려지고 계산 언어학으로도 알려진 연구 분야를 기반으로 합니다.

추출 프로세스의 작동 방법을 이해하면 언어학적 자원(라이브러리, 유형, 동의어 등)을 세부 조정할 때 중요한 결정을 내리는 데 도움이 됩니다. 추출 프로세스의 단계는 다음을 포함합니다.

- 소스 데이터를 표준 형식으로 변환
- 후보 항 식별
- 동의어의 동등 클래스 및 통합 식별
- 유형 지정
- 색인화
- 패턴 및 이벤트 추출 매치

## 1단계. 소스 데이터를 표준 형식으로 변환

이 첫 번째 단계에서, 사용자가 가져오는 데이터가 추가 분석에 사용될 수 있는 균일한 형식으로 변환됩니다. 이 변환은 내부적으로 수행되므로 원래 데이터를 변경하지 않습니다.

## 2단계. 후보 항 식별

언어학적 추출 중에 후보 항의 식별에서 언어학적 자원의 역할을 이해하는 것이 중요합니다. 언어학적 자원은 추출이 실행될 때마다 사용됩니다. 이들은 템플릿, 라이브러리 및 컴파일된 자원의 양식으로 존재합니다. 라이브러리에는 단어 목록, 관계 및 추출을 지정하거나 조정하는 데 사용되는 기타 정보가 포함됩니다. 컴파일된 자원은 보거나 편집할 수 없습니다. 그러나 나머지 자원(템플릿)은 템플릿 편집기에서나 대화식 워크벤치 세션에 있는 경우에는 자원 편집기에서 편집할 수 있습니다.

컴파일된 자원은 IBM SPSS Modeler Text Analytics 내에서 추출 엔진의 핵심 내부 구성요소입니다. 이러한 자원에는 품사 코드(명사, 동사, 형용사, 부사, 분사, 등위 접속사, 관사 또는 전치사)의 기본 양식 목록을 포함하는 일반 사전을 포함합니다. 자원은 또한 다음과 같은 <Location>, <Organization> 또는 <Person> 유형에 많은 추출 항을 지정하는 데 사용되는 예약된 내장된 유형을 포함합니다. 자세한 정보는 내장 유형의 내용을 참조하십시오.

컴파일된 자원 외에, 여러 개의 라이브러리가 제품과 함께 제공되며 컴파일된 자원에서 유형 및 개념 정의를 보완하고 동의어를 제공하는 데 사용될 수 있습니다. 이러한 라이브러리 및 사용자가 작성하는 사용자 정의 라이브러리는 몇몇 사전으로 구성됩니다. 여기에는 유형 사전, 대체 사전(동의어 및 선택적 요소) 및 제외 사전이 포함됩니다. 자세한 정보는 라이브러리에 대한 작업의 내용을 참조하십시오.

데이터를 가져와서 변환한 후 추출 엔진이 추출을 위한 후보 항 식별을 시작합니다. 후보 항은 텍스트에서 개념을 식별하는 데 사용되는 단어나 단어 그룹입니다. 텍스트 처리 동안에는 컴파일된 자원에 있지 않은 단일 단어(단일어)는 후보 항 추출로 간주됩니다. 후보 복합어(다항어)는 품사 패턴 추출기를 사용하여 식별됩니다. 예를 들어, "형용사 명사" 품사 패턴을 따르는 다항어 sports car에는 두 개의 구성요소가 있습니다. "형용사 형용사 명사" 품사 패턴을 따르는 다항어 fast sports car에는 세 개의 구성요소가 있습니다.

**참고:** 앞서 언급한 컴파일된 일반 사전에 있는 용어는 관심이 없거나 언어학적으로 단일어로서는 애매한 모든 단어 목록을 나타냅니다. 이러한 단어는 단일어를 식별할 때 추출에서 제외됩니다. 그러나, 품사를 판별할 때나 더 긴 후보 복합 단어(다항어)를 찾을 때 다시 평가됩니다.

마지막으로, 작업 제목 등과 같은 대문자 글자 문자열을 처리할 때는 이러한 특수 패턴을 추출할 수 있도록 특수 알고리즘이 사용됩니다.

### 3단계. 동의어의 동등 클래스 및 통합 식별

후보 단일어 및 다항어가 식별된 후에는 소프트웨어는 알고리즘 세트를 사용하여 이를 비교하고 동등 클래스를 식별합니다. 동등 클래스는 한 구문으로 된 기본 양식이거나 동일한 구문의 두 개의 변형이 있는 단일 양식입니다. 구문을 동등 클래스에 지정하는 목적은 예를 들어, president of the company 및 company president가 별개의 개념으로 처리되지 않도록 하기 위한 것입니다. 동등 클래스에 사용할 개념을 판별하기 위해서 즉, president of the company 또는 company president가 리드 용어로 사용되는지 여부를 판별하기 위해서 추출 엔진은 다음 규칙을 나열된 순서대로 적용합니다.

- 라이브러리의 사용자 지정 양식.
- 텍스트의 전체 본문에서 가장 자주 사용되는 양식.
- 텍스트의 전체 본문에서 가장 짧은 양식(일반적으로 기본 양식에 해당함).

### 4단계. 유형 지정

다음으로 유형은 추출된 개념에 지정됩니다. 유형은 개념의 시맨틱 그룹입니다. 이 단계에서는 컴파일된 자원과 라이브러리 둘 모두가 사용됩니다. 유형은 상위 레벨 개념, 긍정적 및 부정적 단어, 이름, 장소, 조직 등과 같은 것을 포함합니다. 추가 유형은 사용자가 정의할 수 있습니다. 자세한 정보는 유형 사전의 내용을 참조하십시오.

### 5단계. 색인화

레코드 또는 문서의 전체 세트는 텍스트 위치와 각 동등 클래스의 대표 용어 간에 포인터를 설정하여 색인화됩니다. 여기에서는 후보 개념의 모든 굴절된 양식 인스턴스가 후보 기본 양식으로 색인화되는 것으로 가정합니다. 각 기본 양식에 대해 글로벌 빈도가 계산됩니다.

### 6단계. 패턴 및 이벤트 추출 매치

IBM SPSS Modeler Text Analytics에서는 유형과 개념뿐만 아니라 이들 간의 관계를 찾아낼 수 있습니다. 이 제품에서는 몇몇 알고리즘과 라이브러리를 사용할 수 있고 유형과 개념 간의 관계 패턴을 추출하는 기능을 제공합니다. 이들은 특정 의견(예: 제품 반응) 또는 사람이나 개체 간의 관계 링크(예: 정치적 그룹과 계층 사이의 링크)를 찾아내려고 시도할 때 특히 유용합니다.

## (2) 범주화 작동 방법

IBM® SPSS® Modeler Text Analytics에서 범주 모델을 작성할 때, 범주를 작성하기 위해 선택할 수 있는 여러 가지 기법이 있습니다. 모든 데이터 세트는 고유하므로 기술의 수와 이를 적용하는 순서는 변경될 수 있습니다. 사용자의 결과 해석이 다른 사람의 해석과 다를 수 있으므로 어떤 기술이 텍스트 데이터에 대해 최상의 결과를 내는지를 보려면 여러 기술을 실험해야 할 수도 있습니다. IBM SPSS Modeler Text Analytics에서는 범주를 탐색하고 추가로 미세 조정할 수 있는 대화형 워크벤치 세션에서 범주 모델을 작성할 수 있습니다.

이 안내서에서 **범주 작성**은 하나 이상의 내장된 기술을 사용하여 범주 정의 및 분류의 생성을 가리키고, **범주화**는 각 레코드 또는 문서마다 고유 식별자(이름/ID/값)를 범주 정의에 지정하는 기준이 되는 스코어링 또는 레이블, 프로세스를 가리킵니다.

범주 작성 동안에 추출된 개념 및 유형은 범주의 구성 요소로서 사용됩니다. 범주를 작성할 때 레코드 또는 문서는 범주의 정의 요소와 매치하는 텍스트를 포함하는 경우 자동으로 범주에 지정됩니다.

IBM SPSS Modeler Text Analytics에서는 문서 또는 레코드를 빠르게 범주화할 수 있도록 몇몇 자동화된 범주 작성 기술을 제공합니다.

### 그룹화 기술

사용 가능한 각 기술은 특정 데이터 유형과 상황에 잘 맞지만, 종종 문서 또는 레코드의 전체 범위를 캡처하기 위해 동일한 분석으로 기술을 결합하는 것이 유용합니다. 다중 범주에서 개념을 확인하거나 중복 범주를 찾을 수 있습니다.

**개념 루트 파생.** 이 기술은 개념을 취하고 개념 구성요소가 형태소 분석으로 관련되거나 루트를 공유하는지 여부를 분석하여 관련되는 다른 개념을 찾아서 범주를 작성합니다. 이 기술은 동의 복합어 개념 식별에 아주 유용합니다. 생성된 각 범주의 개념은 동의어이거나 의미에서 거의 관련되기 때문입니다. 이는 다양한 길이의 데이터에 대해 작동하여 더 적은 수의 최소 범주를 생성합니다. 예를 들어, opportunities to advance 개념은 opportunity for advancement 및 advancement opportunity 개념을 사용하여 그룹화됩니다. 자세한 정보는 개념 루트 파생의 내용을 참조하십시오.

**시맨틱 네트워크.** 이 기술은 광범위한 단어 색인 관계에서 각 개념의 가능한 의미를 식별하여 시작한 다음 관련된 개념을 그룹화하여 범주를 작성합니다. 이 기술은 개념이 시맨틱 네트워크에 알려져 있고 너무 애매하지 않을 경우에 가장 좋습니다. 텍스트에 네트워크에 알려지지 않은 용어나 특수화된 전문용어가 포함된 경우에는 덜 유용합니다. 하나의 예에서, 개념 granny smith apple은 gala apple 및 winesap apple과 그룹화될 수 있습니다. 이들은 granny smith의 형제어이기 때문입니다. 다른 예에서, 개념 animal은 cat 및 kangaroo와 그룹화될 수 있습니다. 이들은 animal의 하위어이기 때문입니다. 이 기술은 이 릴리스에서 영어 텍스트에만 사용할 수 있습니다. 자세한 정보는 시맨틱 네트워크의 내용을 참조하십시오.

**개념 포함.** 이 기술은 다른 개념에서 단어의 서브세트 또는 수퍼세트인 단어를 포함하는지 여부를 기초로 다항어 개념(복합어)을 그룹화하여 범주를 작성합니다. 예를 들어, 개념 seat는 safety seat, seat belt 및 seat belt buckle과 함께 그룹화됩니다. 자세한 정보는 개념 포함의 내용을 참조하십시오.

**동시 발생.** 이 기술은 텍스트에서 발견된 동시 발생에서 범주를 작성합니다. 개념 또는 개념 패턴이 종종 함께 문서 및 레코드에서 발견될 때, 동시 발생은 사용자 범주 정의의 값일 수 있는 기본적인 관계를 반영합니다. 단어가 현저하게 동시 발생하는 경우, 동시 발생 규칙이 작성되고 새 하위 범주에 대한 범주 디스크립터로 사용할 수 있습니다. 예를 들어, 많은 레코드에 단어 price 및 availability가 포함되어 있는 경우(그러나 몇 개의 레코드는 다른 하나 없이 하나만 포함함), 이 개념은 동시 발생 규칙으로 그룹화될 수 있고(price & available), 예를 들어 범주 price의 하위 범주에 지정됩니다. 자세한 정보는 동시 발생 규칙의 내용을 참조하십시오.

**최소 문서.** 동시 발생 흥미 정도를 판별하기 위해, 범주에서 디스크립터로 사용되도록 지정된 동시 발생을 포함해야 하는 최소 문서 또는 레코드 수를 정의하십시오.

### 3) IBM SPSS Modeler Text Analytics 노드

IBM® SPSS® Modeler와 함께 제공되는 많은 표준 노드와 함께, 텍스트 마이닝 노드에 대해 작업하여 텍스트 분석의 능력을 스트림에 통합할 수 있습니다. IBM SPSS Modeler Text Analytics는 바로 그것을 수행하기 위한 여러 가지 텍스트 마이닝을 제공합니다. 이들 노드는 노드 팔레트의 IBM SPSS Modeler Text Analytics 탭에 저장됩니다.

다음 노드가 포함됩니다.

- **파일 목록 소스 노드**는 텍스트 마이닝 프로세스에 대한 입력으로 문서 이름의 목록을 생성합니다. 이것은 텍스트가 데이터베이스나 다른 구조화된 파일이 아니라 외부 문서에 상주할 때 유용합니다. 노드는 나열된 각 문서나 폴더에 대해 하나의 레코드를 갖는 단일 필드를 출력하는데, 이것을 후속 텍스트 마이닝 노드의 입력으로 선택할 수 있습니다. 자세한 정보는 파일 목록 노드의 내용을 참조하십시오.
- **웹 피드 소스 노드**는 RSS 또는 HTML 형식의 블로그 또는 뉴스 피드 같은 웹 피드에서 텍스트를 읽고 이 데이터를 텍스트 마이닝 프로세스에서 사용할 수 있게 합니다. 노드는 피드에서 발견되는 각 레코드에 대한 하나 이상의 필드를 출력하는데, 이것은 후속 텍스트 마이닝 노드에서 출력으로 선택할 수 있습니다. 자세한 정보는 웹 피드 노드의 내용을 참조하십시오.
- **언어 식별자 노드**는 소스 텍스트를 스캔하여 텍스트가 작성된 인간 언어를 식별한 다음 새 필드에 마크업하는 프로세스 노드입니다. 이 노드는 주로 많은 양의 데이터와 함께 사용되도록 디자인되었으며 데이터 소스에 두 언어 이상 사용된 경우에 하나의 언어로만 처리하고자 할 때 특히 유용합니다. 자세한 정보는 언어 노드의 내용을 참조하십시오.

- **텍스트 마이닝 노드**는 언어 방법을 사용하여 텍스트에서 핵심 개념을 추출하고, 이들 개념 및 기타 데이터로 범주를 작성할 수 있게 하고, 알려진 패턴을 바탕으로 개념 사이의 관계 및 연관을 식별하는 기능(텍스트 링크 분석이라고 부름)을 제공합니다. 이 노드를 사용하여 텍스트 데이터 내용을 탐색하거나 개념 모델 또는 범주 모델을 생성할 수 있습니다. 개념 및 범주를 인구 통계 같은 기존의 구조화된 데이터와 결합하고 모델링에 적용할 수 있습니다. 자세한 정보는 텍스트 마이닝 모델링 노드의 내용을 참조하십시오.
- **텍스트 링크 분석 노드**는 개념을 추출하며 텍스트 내에서 알려진 패턴을 바탕으로 개념 사이의 관계를 식별합니다. 패턴 추출은 개념 사이의 관계뿐 아니라 이들 개념에 첨부된 모든 의견이나 규정자를 발견하는 데 사용할 수 있습니다. 텍스트 링크 분석 노드는 텍스트에서 패턴을 식별 및 추출한 후 스트림의 데이터 세트에 패턴 결과를 추가하는 보다 직접적인 방법을 제공합니다. 그러나 텍스트 마이닝 모델링 노드에서 대화형 워크벤치 세션을 사용하여 TLA를 수행할 수도 있습니다. 자세한 정보는 텍스트 링크 분석 노드의 내용을 참조하십시오.
- 외부 문서에서 텍스트를 마이닝할 때, **텍스트 마이닝 출력 노드**를 사용하여 개념이 추출된 문서에 대한 링크를 포함하는 HTML 페이지를 생성할 수 있습니다. 자세한 정보는 파일 뷰어 노드의 내용을 참조하십시오.

#### 4) 애플리케이션

일반적으로, 일상적으로 큰 볼륨의 문서를 검토하여 추가 탐색을 위한 핵심 요소를 식별해야 하는 사람은 IBM® SPSS® Modeler Text Analytics를 활용할 수 있습니다.

일부 특정 애플리케이션은 다음을 포함합니다.

- **과학 및 의학 연구.** 특허 보고서, 저널 기사, 프로토콜 서적 같은 보조 연구 자료를 탐색하십시오. 이전에 알려진 연관(예: 특정 제품과 연관된 의사)을 식별하여 추가 탐색을 위한 길을 표시하십시오. 약 발견 프로세스에서 소비되는 시간을 최소화하십시오. 유전자 연구에서의 도움으로 사용하십시오.
- **투자 연구.** 일일 분석 보고서, 뉴스 기사 및 회사 보도 자료를 검토하여 핵심 전략 포인트 또는 시장 변동을 식별하십시오. 그런 정보의 추세 분석은 기간 동안 회사 또는 산업에 대한 새로운 이슈나 기회를 드러냅니다.
- **사기 발견.** 비정상을 발견하고 많은 양의 텍스트에서 위험 신호를 발견하려면 금융 및 건강 관리 사기에서 사용하십시오.
- **시장 조사.** 개방형 설문조사 응답에서 핵심 주제를 식별하기 위해 시장 조사 시도에서 사용하십시오.
- **블로그 및 웹 피드 분석.** 뉴스 피드, 블로그 등에서 발견된 핵심 아이디어를 사용하여 모델을 탐색 및 작성하십시오.
- **CRM.** 이메일, 트랜잭션, 설문조사 같은 모든 고객 접촉 지점의 데이터를 사용하여 모델을 작성하십시오.

## 2. 소스 텍스트에서 읽기

텍스트 마이닝을 위한 데이터는 데이터베이스를 포함하여 IBM® SPSS® Modeler가 사용하는 표준 형식 중 하나 또는 데이터를 행과 열로 나타내는 다른 "직사각형" 형식 또는 이 구조를 따르지 않는 Microsoft Word, Adobe PDF, HTML 같은 문서 형식일 수 있습니다.

- Adobe PDF, XML, HTML 외에 Microsoft Word, Microsoft Excel, Microsoft PowerPoint 등을 포함하여 표준 데이터 구조를 따르지 않는 문서에서 텍스트를 읽으려면 파일 목록 노드를 사용하여 텍스트 마이닝 프로세스에 대한 입력으로 문서 또는 폴더의 목록을 생성할 수 있습니다. 자세한 정보는 파일 목록 노드의 내용을 참조하십시오.
- 블로그 또는 RSS나 HTML 형식의 뉴스 피드 같은 웹 피드에서 텍스트를 읽기 위해 웹 피드 노드를 사용하여 웹 피드 데이터를 텍스트 마이닝 프로세스에 대한 입력으로 형식화할 수 있습니다. 자세한 정보는 웹 피드 노드의 내용을 참조하십시오.
- 고객 의견을 위한 하나 이상의 텍스트 필드를 갖는 데이터베이스 같이 SPSS Modeler가 사용하는 표준 데이터 형식 중 하나로부터 텍스트를 읽기 위해 SPSS Modeler 소스 노드 중 하나를 사용할 수 있습니다. 자세한 정보는 SPSS Modeler 노드 문서를 참조하십시오.
- 여러 가지 다른 언어의 텍스트를 포함할 가능성이 있는 많은 양의 데이터를 처리하는 경우, 언어 노드를 사용하여 특정 필드에서 사용되는 언어를 식별하십시오. 추가 정보는 언어 노드의 내용을 참조하십시오.

### 1) 파일 목록 노드

Microsoft Word, Microsoft Excel, Microsoft PowerPoint뿐 아니라 Adobe PDF, XML, HTML 및 기타와 같은 형식으로 저장된 비정형 문서로부터 텍스트를 읽기 위해, 파일 목록 노드를 사용하여 텍스트 마이닝 프로세스에 대한 입력으로 문서 또는 폴더의 목록을 생성할 수 있습니다. 이것은 비정형 텍스트 문서는 IBM® SPSS® Modeler가 사용하는 다른 데이터와 동일한 방식으로 필드 및 레코드(행과 열)에 의해 표시될 수 없기 때문에 필요합니다.

파일 목록 노드는 소스 노드 역할을 수행합니다.

IBM SPSS Modeler 창의 맨 아래에 있는 노드 팔레트의 IBM SPSS Modeler Text Analytics 탭에서 이 노드를 찾을 수 있습니다. 자세한 정보는 IBM SPSS Modeler Text Analytics 노드의 내용을 참조하십시오.

❖ **중요사항:** 머신 로컬 인코딩에 포함되지 않는 문자를 포함한 디렉토리 이름과 파일 이름은 지원되지 않습니다. 파일 목록 노드를 포함하는 스트림을 실행하려고 할 때, 이러한 문자를 포함하는 파일 또는 디렉토리 이름을 사용하면 스트림 실행에 실패합니다. 프랑스어 로케일의 독일어 파일 이름과 같이, 외부 언어 디렉토리 이름 또는 파일 이름을 사용하는 경우에 이러한 상황이 발생할 수 있습니다.

**로컬 데이터지원.** 원격 IBM SPSS Modeler Text Analytics Server에 연결되어 있고 파일 목록 노드와의 스트림이 있는 경우, 데이터는 IBM SPSS Modeler Text Analytics Server와 동일한 머신에 상주해야 하거나 서버 머신이 파일 목록 노드의 소스 데이터가 저장되는 폴더에 액세스할 수 있어야 합니다.

**참고:** IBM SPSS Collaboration and Deployment Services - Scoring 구성 내에서 스코어링을 위해 파일 목록 노드를 사용할 수 없습니다.

### (1) 파일 목록 노드: 설정 탭

이 탭에서 이 노드에 대한 디렉토리, 파일 확장자 및 입력을 정의할 수 있습니다.

**참고:** 텍스트 마이닝 추출은 비Microsoft Windows 플랫폼에서 Microsoft Office 및 Adobe PDF 파일을 처리할 수 없습니다. 그러나, XML, HTML 또는 텍스트 파일은 항상 처리할 수 있습니다.

머신 로컬 인코딩에 포함되지 않는 문자를 포함한 디렉토리 이름과 파일 이름은 지원되지 않습니다. 파일 목록 노드를 포함하는 스트림을 실행하려고 할 때, 이러한 문자를 포함하는 파일 또는 디렉토리 이름을 사용하면 스트림 실행에 실패합니다. 프랑스어 로케일의 독일어 파일 이름과 같이, 외부 언어 디렉토리 이름 또는 파일 이름을 사용하는 경우에 이러한 상황이 발생할 수 있습니다.

**디렉토리.** 나열하려는 문서를 포함하는 루트 폴더를 지정합니다.

- **하위 디렉토리 포함.** 하위 디렉토리도 스캔하도록 지정합니다.

**목록에 포함할 파일 유형:** 사용하려는 파일 유형 및 확장자를 선택 또는 선택 취소할 수 있습니다. 파일 확장자를 선택 취소하면 해당 확장자를 갖는 파일은 무시됩니다. 다음 확장자로 필터링할 수 있습니다.

표 1. 파일 확장자별 파일 유형 필터

- .rtf,.doc,.docx,.docm	- .xls,.xlsx,.xlsm	- .ppt,.pptx,.pptm
- .htm,.html,.shtml	- .xml	- .pdf

**참고:** 자세한 정보는 파일 목록 노드의 내용을 참조하십시오.

확장자가 없거나 후미 도트 확장자를 갖는 파일이 있는 경우(예: File01 또는 File01.), **확장자 없음** 옵션을 사용하여 선택하십시오.

문서 경로 이름만 출력. 출력 필드가 문서가 상주하는 위치에 대한 하나 이상의 경로 이름이 포함된 경우 이 옵션을 선택하십시오.

입력 인코딩. 출력 필드가 정확한 텍스트를 포함하는 경우, 다음 목록에서 관련 값을 선택하십시오.

- 자동(유럽)
- UTF-8
- UTF-16
- ISO-8859-1
- ISO-8859-2
- Windows-1250
- US ascii

출력은 UTF-8 문서 텍스트로 표시됩니다.

## (2) 파일 목록 노드: 기타 탭

유형 탭은 주석(Annotation) 탭과 마찬가지로 IBM® SPSS® Modeler 노드의 표준 탭입니다.

## (3) 텍스트 마이닝에서 파일 목록 노드 사용

파일 목록 노드는 텍스트 데이터가 Microsoft Word, Microsoft Excel, Microsoft PowerPoint 뿐 아니라 Adobe PDF, XML, HTML 등과 같은 형식으로 된 외부 비정형 문서에 상주할 때 사용됩니다.

예를 들어, 외부 문서에 상주하는 텍스트를 제공하기 위해 파일 목록 노드를 텍스트 마이닝 노드에 연결했다고 가정하십시오.

1. **파일 목록 노드(설정 탭).** 먼저, 이 노드를 스트림에 추가하여 텍스트 문서가 저장되는 장소를 지정했습니다. 텍스트 마이닝을 수행하려는 모든 문서를 포함하는 디렉토리를 선택했습니다.
2. **텍스트 마이닝 노드(필드 탭).** 다음으로, 파일 목록 노드에 텍스트 마이닝 노드를 추가하고 연결했습니다. 이 노드에서, 입력 형식, 자원 템플릿 및 출력 형식을 정의했습니다. 파일 목록 노드에서 생성된 필드 이름, 텍스트 필드 및 기타 설정을 선택했습니다. 자세한 정보는 스트림에서 텍스트 마이닝 노드 사용의 내용을 참조하십시오.

## 2) 웹 피드 노드

웹 피드 노드는 텍스트 마이닝 프로세스에 대해 웹 피드의 텍스트 데이터를 준비하기 위해 사용됩니다. 이 노드는 두 가지 형식의 웹 피드를 승인합니다.

- RSS 형식. RSS는 웹 내용에 대한 단순한 XML 기반 표준화된 형식입니다. 이 형식의 URL은 신디케이트된 뉴스 소스 및 블로그와 같은 링크된 기사 세트가 있는 페이지를 가리킵니다. RSS는 표준화된 형식이므로, 링크된 각 기사는 결과 데이터 스트림에서 별도의 레코드로 식별되고 처리됩니다. 필터링 기술을 텍스트에 적용하지 않으면 피드에서 중요한 텍스트 데이터와 레코드를 식별할 수 있도록 추가 입력이 필요한 것은 아닙니다.
- HTML 형식. 입력 탭에서 HTML 페이지에 대한 하나 이상의 URL을 정의할 수 있습니다. 그런 다음 레코드 탭에서 레코드 시작 태그를 정의하고 대상 내용을 구분하는 태그를 식별한 후 선택하는 출력 필드(설명, 제목, 수정된 날짜 등)에 해당 태그를 지정하십시오. 자세한 정보는 웹 피드 노드: 레코드 탭의 내용을 참조하십시오.

**중요!** 프록시 서버를 통해 웹에서 정보를 검색하려고 시도하는 경우에는 IBM® SPSS® Modeler Text Analytics 클라이언트와 서버 둘 모두에 대해 net.properties 파일에서 프록시 서버를 사용으로 설정해야 합니다. 이 파일 내부에 설명된 지시사항을 따르십시오. 이는 웹 피드 노드를 통해 웹에 액세스할 때나 SDL SaaS(Software as a Service) 라이선스를 검색할 때 적용됩니다. 이러한 연결은 Java™를 통과하기 때문입니다. 이 파일은 기본적으로 *C:\Program Files\IBM\SPSS\Modeler\18.3.0\jre\lib\net.properties*에 있습니다.

이 노드의 출력은 레코드를 설명하기 위해 사용되는 필드 세트입니다. **설명** 필드는 대부분의 텍스트 내용을 포함하므로 가장 일반적으로 사용됩니다. 그러나 레코드의 간단한 설명(**간단한 설명** 필드)이나 레코드의 제목(**제목** 필드)과 같은 다른 필드에 관심이 있을 수도 있습니다. 출력 필드는 후속 텍스트 마이닝 노드의 입력을 선택할 수 있습니다.

 **참고:** IBM SPSS Collaboration and Deployment Services - Scoring 구성 내에서 스코어링에 대해 웹 피드 노드를 사용할 수 없습니다.

IBM SPSS Modeler 창의 맨 아래에 있는 노드 팔레트의 IBM SPSS Modeler Text Analytics 탭에서 이 노드를 찾을 수 있습니다. 자세한 정보는 IBM SPSS Modeler Text Analytics 노드의 내용을 참조하십시오.

### (1) 웹 피드 노드: 입력 탭

입력 탭은 텍스트 데이터를 캡처하기 위해 하나 이상의 웹 주소나 URL을 지정하기 위해 사용됩니다. 텍스트 마이닝의 컨텍스트에서, 텍스트 데이터를 포함하는 피드에 대한 URL을 지정할 수 있습니다.

 **중요사항:** RSS 이외 데이터에 대해 작업할 때, 내용 수집 후 다른 소스 노드를 사용하여 해당 도구에서 출력을 참조하는 것을 자동화하기 위해 WebQL®과 같은 웹 스크래핑 도구를 사용하는 것을 선호할 수 있습니다.

다음 매개변수를 설정할 수 있습니다.

**URL 입력 또는 붙여넣기.** 이 필드에서, 하나 이상의 URL을 입력하거나 붙여넣을 수 있습니다. 두 개 이상을 입력하는 경우, 해당 하나만 입력하며 **Enter/Return** 키를 사용하여 행을 구분하십시오. 파일의 전체 URL 경로를 입력하십시오. 이 URL은 두 형식 중 하나로 된 피드 URL일 수 있습니다.

- RSS 형식. RSS는 웹 내용에 대한 단순한 XML 기반 표준화된 형식입니다. 이 형식의 URL은 신디케이트된 뉴스 소스 및 블로그와 같은 링크된 기사 세트가 있는 페이지를 가리킵니다. RSS는 표준화된 형식이므로, 링크된 각 기사는 결과 데이터 스트림에서 별도의 레코드로 식별되고 처리됩니다. 필터링 기술을 텍스트에 적용하지 않으면 피드에서 중요한 텍스트 데이터와 레코드를 식별할 수 있도록 추가 입력이 필요한 것은 아닙니다.
- HTML 형식. 입력 탭에서 HTML 페이지에 대한 하나 이상의 URL을 정의할 수 있습니다. 그런 다음 레코드 탭에서 레코드 시작 태그를 정의하고 대상 내용을 구분하는 태그를 식별한 후 선택하는 출력 필드(설명, 제목, 수정된 날짜 등)에 해당 태그를 지정하십시오. RSS 이외 데이터에 대해 작업할 때, 내용 수집 후 다른 소스 노드를 사용하여 해당 도구에서 출력을 참조하는 것을 자동화하기 위해 WebQL®과 같은 웹 스크래핑 도구를 사용하는 것을 선호할 수 있습니다. 자세한 정보는 웹 피드 노드: 레코드 탭의 내용을 참조하십시오.

**URL마다 읽을 최근 항목 수.** 이 필드는 피드에서 발견된 첫 번째 레코드에서 시작하여 필드에 나열된 각 URL에 대해 읽을 최대 레코드 수를 지정합니다. 텍스트 양은 텍스트 마이닝 노드 또는 텍스트 링크 분석 노드에서 추출 다운스트림 동안 처리 속도에 영향을 줍니다.

**가능할 때 이전 웹 피드를 저장하고 재사용하십시오.** 이 옵션을 사용하면, 웹 피드가 스캔되고 처리 결과가 캐시됩니다. 그런 다음 후속 스트림 실행 시, 지정된 피드의 내용이 변경되지 않았거나 피드에 액세스할 수 없는 경우(예: 인터넷 가동 중단), 캐시된 버전이 사용되어 처리 시간을 가속화합니다. 이 피드에서 발견되는 새 내용은 다음에 노드를 실행할 때도 캐시됩니다.

- 레이블. 가능할 때 이전 웹 피드 저장 및 재사용을 선택하는 경우, 결과의 레이블 이름을 지정해야 합니다. 이 레이블은 서버에서 캐시된 피드를 설명하기 위해 사용됩니다. 지정된 레이블이 없거나 레이블이 인식되지 않는 경우, 재사용이 가능하지 않습니다.

## (2) 웹 피드 노드: 레코드 탭

레코드 탭은 각각의 새 레코드가 시작하는 위치와 각 레코드에 관한 다른 관련 정보를 식별하여 비RSS 피드의 텍스트 내용을 지정하기 위해 사용됩니다. 비RSS 피드(HTML)에 여러 레코드에 있는 텍스트가 포함되어 있는 것을 알면, 여기에서 레코드 시작 태그를 식별해야 합니다. 그렇지 않으면 텍스트는 하나의 레코드로 처리됩니다. RSS 피드가 표준화되어 이 탭에서 태그를 지정하지 않아도 되지만, 미리보기 탭에서 내용을 미리볼 수 있습니다.

❖ **중요사항:** RSS 이외 데이터에 대해 작업할 때, 내용 수집 후 다른 소스 노드를 사용하여 해당 도구에서 출력을 참조하는 것을 자동화하기 위해 WebQL®과 같은 웹 스크래핑 도구를 사용하는 것을 선호할 수 있습니다.

**URL.** 이 드롭 다운 목록에는 입력 탭에 입력된 URL의 목록이 포함됩니다. HTML 및 RSS 형식화 피드 모두가 제시됩니다. URL 주소가 드롭 다운 목록에 대해 너무 길면, 잘린 텍스트를 바꾸기 위해 생략 기호를 사용하여 중간에서 자동으로 잘립니다(예:

*http://www.ibm.com/example/start-of-address...rest-of-address/path.htm*).

- **HTML 형식화 피드**를 사용할 때 피드에 두 개 이상의 레코드(또는 항목)가 있는 경우, 테이블에 표시된 필드에 해당되는 데이터를 포함하는 HTML 태그를 정의할 수 있습니다. 예를 들어, 새 레코드가 시작되었음을 표시하는 시작 태그, 수정된 날짜 태그 또는 작성자 이름을 정의할 수 있습니다.
- **RSS 형식화 피드**를 사용하는 경우에는 RSS가 표준화 형식이므로 태그를 입력하도록 요청하는 프롬프트가 표시되지 않습니다. 그러나 원하면 미리보기 탭에서 표본 결과를 볼 수 있습니다. 인식되는 모든 RSS 피드 앞에는 RSS 로고 이미지가 붙습니다.

**소스 탭.** 이 탭에서, HTML 피드에 대한 소스 코드를 볼 수 있습니다. 이 코드는 편집할 수 없습니다. 찾기 필드를 사용하여 특정 태그나 정보를 이 페이지에서 찾을 수 있습니다. 그런 다음 아래 테이블로 복사하여 붙여넣을 수 있습니다. 찾기 필드에서는 대소문자가 구분되지 않으므로 부분 문자열을 매치합니다.

**미리보기 탭.** 이 탭에서는, 웹 피드 노드에서 레코드가 읽혀지는 방법을 미리볼 수 있습니다. 이는 HTML 피드의 경우 특히 유용합니다. 미리보기 탭 아래의 테이블에서 HTML 태그를 정의하여 레코드를 읽을 방법을 변경할 수 있기 때문입니다.

**비RSS 레코드 시작 태그.** 이 옵션은 비RSS 피드에만 적용됩니다. HTML 피드에 여러 레코드로 분리하려고 하는 다중 텍스트가 있는 경우, 레코드(예: 기사 또는 블로그 항목) 시작을 알리는 HTML 태그를 여기에 지정하십시오. 비RSS 피드에 대해 태그를 정의하지 않은 경우 Modeler가 XML 형식으로 추측하고 해당 레코드를 리턴합니다. Modeler가 XML 형식으로 추측할 수 없는 경우 아무것도 리턴되지 않습니다. 페이지의 전체 내용을 가져와서 나중에 처리하는 것이 목적인 경우 보다 강력한 기능을 제공하는 별도의 XML 리더를 사용하여 결과를 Modeler Text Analytics로 가져오는 것이 좋습니다.

**필드 표.** 이 옵션은 비RSS 피드에만 적용됩니다. 이 표에서, 사전정의된 출력 필드 중 하나에 대해 시작 태그를 입력하여 특정 출력 필드로 텍스트 내용을 분리할 수 있습니다. 시작 태그만 입력하십시오. HTML을 구문 분석하고 표 내용을 HTML에서 발견된 속성과 태그 이름에 매치하여 모든 매치가 수행됩니다. 정의한 태그를 복사하고 다른 피드에 재사용하기 위해 맨 아래에 있는 단추를 사용할 수 있습니다.

표 1. 비RSS 피드에 가능한 출력 필드(HTML 형식)

출력 필드 이름	예상된 태그 내용
제목	레코드 제목을 구분하는 태그. (선택사항)

출력 필드 이름	예상된 태그 내용
간단한 설명	간단한 설명 또는 레이블을 구분하는 태그. (선택사항)
설명	주 텍스트를 구분하는 태그. 공백으로 남겨둘 경우, 이 필드는 <body> 태그(단일 레코드가 있는 경우)의 다른 모든 내용이나 현재 레코드에서 발견된 내용(레코드 구분자가 지정된 경우)을 포함합니다.
작성자	텍스트 작성자를 구분하는 태그. (선택사항)
기여자	기여자의 이름을 구분하는 태그. (선택사항)
출판된 날짜	텍스트가 출판된 날짜를 구분하는 태그. 공백으로 남겨두면, 이 필드는 노드가 데이터를 읽을 때 날짜를 포함합니다.
수정된 날짜	텍스트가 수정된 날짜를 구분하는 태그. 공백으로 남겨두면, 이 필드는 노드가 데이터를 읽을 때 날짜를 포함합니다.

테이블에 태그를 입력할 때, 피드는 정확히 일치보다 매치시킬 최소 태그로 이 태그를 사용하여 스캔됩니다. 즉, 제목 필드에 대해 <div>를 입력한 경우, 이는 지정된 속성(예: <div class="post three">)을 가지고 있는 태그를 비롯하여 피드에서 <div> 태그를 매치하고(<div>가 루트 태그 (<div>)와 같도록) 속성을 포함하는 파생어를 매치한 후 제목 출력 필드에 대해 해당 내용을 사용합니다. 루트 태그를 입력하면, 추가 속성도 포함됩니다.

표 2. 출력 필드에 대해 텍스트 식별에 사용되는 HTML 태그의 예

다음은 입력하는 경우:	다음은 매치함:	다음도 매치함:	다음은 매치하지 않음:
<div>	<div>	<div class="post">	기타 태그
<p class="auth">	<p class="auth">	<p color="black" class="auth" id="85643">	<p color="black">

### (3) 웹 피드 노드: 내용 필터 탭

내용 필터 탭은 RSS 피드 내용에 필터 기술을 적용하기 위해 사용됩니다. 이 탭은 HTML 피드에 적용되지 않습니다. 필드에 헤더, 꼬리말, 메뉴, 광고 등의 양식으로 많은 텍스트를 포함하는 경우 필터를 원할 수 있습니다. 이 탭을 사용하여 원하지 않는 HTML 태그, JavaScript 그리고 내용의 간단한 단어 또는 행을 완전히 제거할 수 있습니다.

**내용 필터.** 정리 기술을 적용하지 않으려면, **없음**을 선택하십시오. 그렇지 않으면, **RSS 내용 정리를** 선택하십시오.

**RSS 내용 정리기 옵션.** RSS 내용 정리기를 선택하는 경우, 특정 기준을 기초로 행을 삭제할 것을 선택할 수 있습니다. 행은 <p> 및 <li>와 같은 HTML 태그(<span>, <b> 및 <font>와 같은 인라인 태그 제외)로 구분됩니다. <br> 태그는 행 바꿈으로 처리됩니다.

- **짧은 행 삭제.** 이 옵션은 여기에서 정의되는 **최소 단어 수**를 포함하지 않는 행을 무시합니다.
- **짧은 단어가 있는 행 삭제.** 이 옵션은 여기에서 정의되는 **최소 평균 단어 길이**보다 긴 행을 무시합니다.
- **많은 단일 문자 단어가 있는 행 삭제.** 이 옵션은 특정의 **단일 문자 단어 비율**보다 더 포함하는 행을 무시합니다.
- **특정 태그 포함 행 삭제.** 이 옵션은 필드에 지정된 태그를 포함하는 행에서 텍스트를 무시합니다.
- **특정 텍스트를 포함하는 행 삭제.** 이 옵션은 필드에 지정된 텍스트를 포함하는 행을 무시합니다.

#### (4) 텍스트 마이닝에서 웹 피드 노드 사용

웹 피드 노드는 텍스트 마이닝 프로세스에 대해 인터넷 웹 피드의 텍스트 데이터를 준비하기 위해 사용됩니다. 이 노드는 HTML 또는 RSS 형식의 웹 피드를 승인합니다. 이 피드는 텍스트 마이닝 프로세스의 입력 역할을 합니다(후속 텍스트 마이닝 또는 텍스트 링크 분석 노드).

웹 피드 노드를 사용하는 경우, 해당 피드가 각 기사 또는 블로그 항목에 직접 링크됨을 표시하기 위해 텍스트 필드가 텍스트 마이닝 또는 텍스트 링크 분석 노드에서 **실제 텍스트**를 나타냄을 지정하도록 해야 합니다.

**중요!** 프록시 서버를 통해 웹에서 정보를 검색하려고 시도하는 경우에는 IBM® SPSS® Modeler Text Analytics 클라이언트와 서버 둘 모두에 대해 net.properties 파일에서 프록시 서버를 사용으로 설정해야 합니다. 이 파일 내부에 설명된 지시사항을 따르십시오. 이는 웹 피드 노드를 통해 웹에 액세스할 때나 SDL SaaS(Software as a Service) 라이선스를 검색할 때 적용됩니다. 이러한 연결은 Java™를 통과하기 때문입니다. 이 파일은 기본적으로 *C:\Program Files\IBM\SPSS\Modeler\18.3.0\jre\lib\net.properties*에 있습니다.

예: 텍스트 마이닝 모델링 노드가 있는 웹 피드 노드(RSS 피드)

예로서, RSS 피드의 텍스트를 텍스트 마이닝 프로세스에 제공하기 위해 텍스트 마이닝 노드에 웹 피드 노드를 연결한다고 가정해 보십시오.

1. **웹 피드 노드(입력 탭).** 먼저, 피드 내용이 위치되는 곳을 지정하고 내용 구조를 확인하기 위해 스트림에 이 노드를 추가했습니다. 첫 번째 탭에서, URL을 RSS 피드에 제공했습니다. 이 예는 RSS 피드에 대한 것이므로, 형식화가 이미 정의되어 있어서 레코드 탭에서 변경할 필요는 없습니다. 그러나 적용되지 않은 경우에는 RSS 피드에 대해 선택적 내용 필터링 알고리즘을 사용할 수 있습니다.

2. **텍스트 마이닝 노드(필드 탭).** 다음으로, 웹 피드 노드에 텍스트 마이닝 노드를 추가하고 연결했습니다. 이 탭에서는 웹 피드 노드에 의해 출력된 텍스트 필드를 정의했습니다. 이 경우에, **설명** 필드를 사용하려고 했습니다. 또한 텍스트 필드가 실제 텍스트를 나타내는 옵션과 다른 설정을 선택했습니다.
3. **텍스트 마이닝 노드(모델 탭).** 다음으로, 모델 탭에서 작성 모드 및 자원을 선택했습니다. 이 예에서는, 기본 자원 템플릿을 사용하여 노드에서 직접 개념 모델을 작성할 것을 선택했습니다.

텍스트 마이닝 노드 사용에 대한 자세한 정보는 텍스트 마이닝 모델링 노드의 내용을 참조하십시오.

### 3) 언어 노드

언어 노드를 사용하여 소스 데이터 내의 텍스트 필드의 자연어를 식별할 수 있습니다.

이 노드의 출력은 발견된 언어 코드를 포함하는 파생 필드입니다.

 **참고:** IBM® SPSS® Collaboration and Deployment Services - Scoring 구성 안에서 스코어링을 위해 언어 노드를 사용할 수 없습니다.

IBM SPSS Modeler 창의 맨 아래에 있는 노드 팔레트의 IBM SPSS Modeler Text Analytics 탭에서 이 노드를 찾을 수 있습니다. 자세한 정보는 IBM SPSS Modeler Text Analytics 노드의 내용을 참조하십시오.

#### (1) 언어 노드: 설정 탭

이 탭에서 선택된 텍스트 필드에 대한 언어 세부사항을 출력하는 방법을 지정합니다.

**텍스트 필드 언어를 식별할 텍스트 필드를 선택하십시오.**

**파생된 필드 이름** 발견된 언어 코드를 포함할 파생 필드의 이름을 입력하십시오. 기본값은 Language입니다.

**언어를 식별할 수 없는 경우에 사용되는 기본값** 언어를 식별할 수 없는 경우에 작성되는 필드의 이름을 지정하십시오. 사용 가능한 선택 사항은 다음과 같습니다.

- **Undefined** 이를 선택하면 파생 필드가 널값을 포함합니다.
- **Supported** 이를 선택하면 지원되는 다음 ISO 언어 중 하나를 선택할 수 있습니다.
  - 영어(EN)
  - 프랑스어(FR)
  - 포르투갈어(PT)
  - 독일어(DE)
  - 이탈리아어(IT)
  - 스페인어(ES)
  - 네델란드어(NL)

- 사용자 정의 지원되는 언어가 적합하지 않으면 이 옵션을 사용하여 사용자 정의 값이 사용되도록 지정하십시오. 일반적으로 이는 두 문자로 구성된 ISO 언어 코드이나 사용자에게 필요한 임의의 텍스트 문자열일 수 있습니다.

### 3. 개념 및 범주 마이닝

텍스트 마이닝 모델링 노드는 다음 두 개의 텍스트 마이닝 모델 너깃 중 하나를 생성하는 데 사용됩니다.

- *개념 모델 너깃*은 구조화 또는 비정형 텍스트 데이터에서 핵심적인 개념을 드러내서 추출합니다.
- *범주 모델 너깃*은 문서 및 레코드를 스코어링하고 범주에 지정합니다. 범주는 추출된 개념(및 패턴)으로 구성됩니다.

추출된 개념 및 패턴뿐 아니라 모델 너깃의 범주가 모든 인구 통계 같은 기존의 구조화된 데이터와 결합되고 IBM® SPSS® Modeler의 전체 도구 모음을 사용하여 적용되어 더 좋고 더욱 집중된 의사결정을 내릴 수 있습니다. 예를 들어, 고객이 온라인 계정 관리 태스크를 완료하기 위한 1차적인 장애로 로그인 문제를 자주 나열하는 경우, "로그인 문제"를 모델에 통합하기 원할 수 있습니다.

또한, 텍스트 마이닝 모델링 노드는 IBM SPSS Modeler와 완전히 통합되므로 PredictiveCallCenter 같은 애플리케이션에서 비정형 데이터의 실시간 스코어링을 위해 IBM SPSS Modeler Solution Publisher를 통해 텍스트 마이닝 스트림을 배치할 수 있습니다. 이들 스트림을 배치하는 기능은 성공적인 폐쇄 루프 텍스트 마이닝 구현을 보장합니다. 예를 들어, 사용자 조직이 이제 예측 모형을 적용하여 마케팅 메시지의 정확도를 실시간으로 늘려서 인바운드 또는 아웃바운드 호출자의 메모철을 분석할 수 있습니다. 스트림에서 텍스트 마이닝 모델 결과 사용은 예측 데이터 모델의 정확도를 개선하기 위해 표시되었습니다.

IBM SPSS Modeler Solution Publisher와 함께 IBM SPSS Modeler Text Analytics를 실행하려면 <install\_directory>/ext/bin/spss.TMWBServer 디렉토리를 \$LD\_LIBRARY\_PATH 환경 변수에 추가하십시오.

IBM SPSS Modeler Text Analytics에서 종종 추출된 개념 및 범주를 참조합니다. 개념 및 범주는 예비 작업 및 모델 작성 중에 더 많은 정보가 제공된 결정을 내리는 데 도움이 될 수 있으므로 개념 및 범주의 의미를 이해하는 것이 중요합니다.

#### 개념 및 개념 모델 너깃

추출 프로세스 중에 텍스트 데이터가 스캔되고 election 또는 peace 및 presidential election, election of the president 또는 peace treaties 같은 단어 구 같이 관심이 있거나 관련 단일 단어를 식별하기 위해 분석됩니다. 이러한 단어와 구문을 집합적으로 용어라고 부릅니다. 언어학적 자원을 사용하여 관련 용어가 추출되고, 비슷한 용어가 **개념**이라는 리드 용어 아래에 함께 그룹화됩니다.

이런 방식으로, 개념은 텍스트와 사용 중인 언어학적 자원 세트에 따라 많은 기초적인 용어를 표시할 수 있습니다. 예를 들어, 직원 만족도 설문 조사가 있고 개념 salary가 추출되었다고 가정합니다. 또한 salary와 연관된 레코드를 볼 때 salary가 항상 텍스트에 표시되지 않고 wage, wages 및 salaries 등과 유사한 것을 포함하는 특정 레코드에 표시된다고 해 봅시다. 이러한 용어는 salary 아래에 그룹화됩니다. 추출 엔진이 이들을 유사한 것으로 간주하거나 처리 규칙이나 언어학적 자원을 기반으로 이들이 동의어라고 판별했기 때문입니다. 이 경우, 이러한 용어를 포함하는 모든 문서 또는 레코드는 이들이 단어 salary를 포함하는 것처럼 처리됩니다.

어떤 용어가 개념 아래에 그룹화되는지 보려는 경우, 대화형 워크벤치 내에서 개념을 탐색하거나 개념 모델에 표시되는 동의어를 조사할 수 있습니다. 자세한 정보는 개념 모델의 기본 용어의 내용을 참조하십시오.

**개념 모델 너깃**은 개념을(그의 모든 동의어 또는 그룹화된 용어 포함) 포함하는 레코드 또는 문서를 식별하는 데 사용할 수 있는 개념 세트를 포함합니다. 개념 모델은 두 가지 방법으로 사용할 수 있습니다. 첫 번째는 원래 소스 텍스트에서 발견된 개념을 탐색 및 분석하거나 관심있는 문서를 빨리 식별하는 것입니다. 두 번째는 이 모델을 새 텍스트 레코드나 문서에 적용하여 콜센터의 메모철 데이터에 있는 핵심 개념의 실시간 발견 같이 새 문서/레코드에서 동일한 핵심 개념을 빨리 식별하는 것입니다.

자세한 정보는 텍스트 마이닝 너깃: 개념 모델의 내용을 참조하십시오.

#### 범주 및 범주 모델 너깃

본질적으로 상위 레벨 개념이나 주제를 나타내는 **범주**를 작성하여 텍스트에서 표현되는 주요 아이디어, 지식 및 태도를 캡처할 수 있습니다. 범주는 *개념*, *유형*, *규칙* 같은 디스크립터의 세트로 구성됩니다. 이들 디스크립터는 함께 사용되어 레코드나 문서가 주어진 범주에 속하는지 여부를 식별합니다. 문서나 레코드를 스캔하여 그의 텍스트 중 하나가 디스크립터와 매치하는지 확인할 수 있습니다. 매치가 발견되면 문서/레코드가 해당 범주에 지정됩니다. 이 프로세스를 **범주화**라고 부릅니다.

범주는 제품의 강력한 자동화 기법 세트를 사용하여 자동으로, 사용자가 데이터에 관하여 가질 수 있는 추가 직관력을 사용하여 수동으로 또는 둘의 조합으로 작성될 수 있습니다. 또한 이 노드의 모델 탭을 통해 텍스트 분석 패키지로부터 사전 작성된 범주 세트를 로드할 수 있습니다. 범주의 수동 작성이나 범주 세분화는 대화형 워크벤치를 통해서만 수행될 수 있습니다. 자세한 정보는 텍스트 마이닝 노드: 모델 탭의 내용을 참조하십시오.

**범주 모델 너깃**은 범주 세트를 해당 디스크립터와 함께 포함하고 있습니다. 이 모델을 사용하면 각 문서/레코드에 있는 텍스트를 기반으로 문서 또는 레코드의 세트를 범주화할 수 있습니다. 모든 문서나 레코드를 읽고 디스크립터 매치가 발견된 각 범주에 지정합니다. 이 방법으로 문서나 레코드가 둘 이상의 범주에 지정될 수 있습니다. 범주 모델 너깃을 사용하여 개방형 설문조사 응답이나 예를 들어 블로그 항목 세트에서 본질적인 아이디어를 볼 수 있습니다.

자세한 정보는 텍스트 마이닝 너깃: 범주 모델의 내용을 참조하십시오.

## 1) 텍스트 마이닝 모델링 노드

텍스트 마이닝 노드는 언어 및 빈도 기법을 사용하여 텍스트에서 핵심 개념을 추출하고 이들 개념과 다른 데이터로 범주를 작성합니다. 이 노드를 사용하여 텍스트 데이터 콘텐츠를 탐색하거나 개념 모델 너깃이나 범주 모델 너깃을 생성할 수 있습니다. 이 모델링 노드를 실행할 때, 내부 언어학적 추출 엔진이 자연어 처리 방법을 사용하여 개념, 패턴 및/또는 범주를 추출하고 구성합니다.

텍스트 마이닝 노드를 실행하고 **직접 생성** 옵션을 사용하여 자동으로 개념 또는 범주 모델 너깃을 생성할 수 있습니다. 또는 개념을 추출하고 범주를 작성하고 언어학적 자원을 세분화할 뿐 아니라 텍스트 링크 분석을 수행하고 군집을 탐색할 수도 있는 **대화형 작성** 모드를 사용하여 더 실무적이고 예비적인 방식을 사용할 수 있습니다. 자세한 정보는 텍스트 마이닝 노드: 모델 탭의 내용을 참조하십시오.

IBM® SPSS® Modeler 창의 맨 아래에 있는 노드 팔레트의 IBM SPSS Modeler Text Analytics 탭에서 이 노드를 찾을 수 있습니다. 자세한 정보는 IBM SPSS Modeler Text Analytics 노드의 내용을 참조하십시오.

**요구사항.** 텍스트 마이닝 모델링 노드는 웹 피드 노드, 파일 목록 노드 또는 표준 소스 노드 중 하나의 텍스트 데이터를 수락합니다. 이 노드는 IBM SPSS Modeler Text Analytics와 함께 설치되며 IBM SPSS Modeler Text Analytics 팔레트에서 액세스할 수 있습니다.

 **참고:** 이 노드는 제품의 이전 버전에서 제공되던 텍스트 추출 노드를 대체합니다. 이전 노드나 모델 너깃을 사용하는 이전 스트림이 있는 경우, 텍스트 마이닝 노드를 사용하여 스트림을 다시 작성해야 합니다.

### (1) 텍스트 마이닝 노드: 필드 탭

개념을 추출 중인 데이터에 대한 필드 설정을 지정하려면 필드 탭을 사용하십시오. 처리 시간을 가속화하기 위해 더 큰 데이터 세트에 대해 작업할 때 이 노드에서 표본 노드 업스트림 사용을 고려하십시오. 자세한 정보는 시간 절약을 위한 업스트림 표본추출의 내용을 참조하십시오.

다음 매개변수를 설정할 수 있습니다.

**ID 필드** 텍스트 레코드의 식별자를 포함하는 필드를 선택하십시오. 식별자는 정수여야 합니다. ID 필드는 개별 텍스트 레코드에 대한 색인 역할을 수행합니다. 텍스트 필드가 마이닝될 텍스트를 나타내는 경우 ID 필드를 사용하십시오.

**텍스트 필드.** 마이닝할 텍스트를 포함하는 필드를 선택하십시오. 이 필드는 데이터 소스에 따라 다릅니다.

**언어 필드** 두 문자로 구성된 ISO 언어 식별자를 포함하는 필드를 선택하십시오. 필드를 선택하지 않으면 각 문서의 언어가 제공되는 템플릿의 언어인 것으로 간주됩니다.

**문서 유형.** 문서 유형은 텍스트의 구조를 지정합니다. 다음 유형 중 하나를 선택하십시오.

- **전체 텍스트.** 대부분의 문서 또는 텍스트 소스에 대해 사용합니다. 추출을 위해 전체 텍스트 세트가 스캔됩니다. 다른 옵션과 달리, 이 옵션의 추가 설정은 없습니다.
- **구조화된 텍스트.** 식별하고 분석할 수 있는 일반 구조를 포함하는 파일, 서지 목록 양식 및 특허에 사용됩니다. 이 문서 유형은 추출 프로세스의 일부 또는 전체를 건너뛰기 위해 사용됩니다. 이 문서 유형을 사용하여 항 구분 문자를 정의하고, 유형을 지정하며, 최소 빈도 값을 부과할 수 있습니다. 이 옵션을 선택하면, **설정** 단추를 클릭하고 문서 설정 대화 상자의 **구조화된 텍스트 형식** 영역에서 텍스트 구분 문자를 입력해야 합니다. 자세한 정보는 필드 탭의 문서 설정의 내용을 참조하십시오.

**텍스트 통합.** 다음에서 추출 모드를 선택하십시오.

- **문서 모드.** 간단하고 의미적으로 동일한 문서(예: 통신사의 기사)에 사용하십시오.
- **단락 모드.** 웹 페이지와 태그가 없는 문서에 사용하십시오. 추출 프로세스는 내부 태그 및 구문과 같은 특성을 이용하여 문서를 의미적으로 나눕니다. 이 모드가 선택되는 경우, 스코어링은 단락별로 적용됩니다. 따라서, 예를 들어 apple 및 orange가 동일한 단락에서 발견되는 경우에만 apple & orange 규칙은 true입니다.

 **참고:** 텍스트가 PDF 문서에서 추출되는 방식으로 인해, **단락 모드**는 이러한 문서에 대해 작동하지 않습니다. 이는 추출이 캐리지 리턴 표식을 억제하기 때문입니다.

**단락 모드 설정.** 이 옵션은 텍스트 통합 옵션을 **단락 모드**로 설정한 경우에만 사용할 수 있습니다. 추출에서 사용할 문자 임계값을 지정하십시오. 실제 크기는 가장 가까운 마침표로 반올림 또는 반내림됩니다. 문서 컬렉션의 텍스트에서 생성되는 단어 연관이 대표적이 되도록 하려면 너무 작은 추출 크기를 지정하지 않도록 하십시오.

- **최소.** 추출에서 사용될 최소 문자 수를 지정하십시오.
- **최대값.** 추출에서 사용될 최대 문자 수를 지정하십시오.

**파티션 모드** 유형 노드 설정을 바탕으로 파티션하거나 또 다른 파티션을 선택할지 여부를 선택하려면 파티션 모드를 사용하십시오. 파티션화는 데이터를 학습 및 테스트 샘플로 분리합니다.

## ① 필드 탭의 문서 설정

### 구조화된 텍스트 형식

데이터를 구조화하였거나 텍스트 처리 방법에 대해 규칙을 부과하기 위해 추출 프로세스의 일부 또는 전체를 건너뛰려는 경우, **구조화된 텍스트** 문서 유형 옵션을 사용하고 문서 설정 대화 상자의 **구조화된 텍스트 형식** 섹션에서 텍스트를 포함하는 태그 또는 필드를 선언하십시오. 추출된 용어는 선언된 필드 또는 태그(및 하위 태그) 내에 포함된 텍스트에서만 파생됩니다. 선언되지 않은 필드 또는 태그는 무시됩니다.

특정 컨텍스트에서, 언어 처리는 필요하지 않으므로 언어적 추출 엔진이 명시적 선언에 의해 대체될 수 있습니다. 키워드 필드가 세미콜론(;) 또는 콤마(,)와 같은 구분 문자로 분리되는 도서 목록 파일에서는, 두 개의 구분 문자 사이에서 문자열을 추출하는 것으로 충분합니다. 이러한 이유로, 전체 추출 프로세스를 일시중단시키고 대신 용어 구분 문자를 선언하거나, 유형을 추출된 텍스트에 지정하거나, 추출에 대해 최소 빈도 수를 부과하기 위해 특수 처리 규칙을 정의할 수 있습니다.

구조화된 텍스트 요소를 선언할 때 다음 규칙을 사용하십시오.

- 행마다 단 하나의 필드, 태그 또는 요소를 선언할 수 있습니다. 데이터에는 존재하지 않아도 됩니다.
- 선언에서는 대소문자가 구분됩니다.
- <title id="1234">와 같은 속성을 가지고 있는 태그를 선언하고 있고 모든 변동 또는 이 경우, 모든 ID를 포함하도록 하려면, 속성이나 닫는 꺾쇠괄호(>) 없이 태그를 추가하십시오(예: <title>).
- 필드 또는 태그 이름 뒤에 콜론을 추가하여 구조화된 텍스트임을 표시하십시오. 필드 또는 태그 바로 뒤에 그리고 구분 문자, 유형 또는 빈도 값 이전에 이 콜론을 추가하십시오(예: author: 또는 <place>:).
- 여러 용어가 필드 또는 태그에 포함되고 구분 문자가 개별 용어를 지정하기 위해 사용됨을 표시하려면 콜론 다음에 구분 문자를 선언하십시오(예: author:, 또는 <section>:).
- 태그에서 발견된 내용에 유형을 지정하려면, 콜론 및 구분 문자 다음에 유형 이름을 선언하십시오(예: author:,Person 또는 <place>::Location). 자원 편집기에 표시되는 대로 이름을 사용하여 유형을 선언하십시오.
- 필드 또는 태그에 대한 최소 빈도 수를 정의하려면, 행의 끝에서 수를 선언하십시오(예: author:,Person1 또는 <place>::Location5). 여기서 n은 사용자가 정의한 빈도 수이고, 필드 또는 태그에서 발견되는 용어는 추출할 전체 문서 또는 레코드 세트에서 최소 n번 발생해야 합니다. 또한 구분 문자도 정의해야 합니다.
- 콜론을 포함하는 태그가 있으면, 선언이 무시되지 않도록 백슬래시 문자를 콜론 앞에 붙여야 합니다. 예를 들어, <topic:source> 필드가 있으면, <topic\W:source>로 입력하십시오.

명령문을 설명하기 위해, 다음과 같은 반복되는 도서 목록 필드가 있다고 가정합니다.

```
author:Morel, Kawashima
abstract:This article describes how fields are declared.
publication:Text Mining Documentation
datepub:March 2010
```

이 예에 대해, 추출 프로세스가 작성자 및 요약에 초점을 맞추고 내용의 나머지는 무시하기를 원하는 경우, 다음 필드만 선언합니다.

```
author:Person1
abstract:
```

이 예에서, author:Person1 필드 선언에서는 언어 처리가 필드 내용에서 일시중단되었음을 알려줍니다. 그 대신, 작성자 필드에 두 개 이상 이름이 포함되고(콤마 구분 문자에 의해 다음 이름과 구분되어서) 이 이름은 사람 유형에 지정되어야 한다고 알려주고, 이름이 전체 문서 또는 레코드 세트에서 최소 한 번 발생하는 경우 이를 추출하도록 알립니다. 필드 abstract:는 다른 선언 없이 나열되어 있으므로, 필드는 추출 및 표준 언어 처리 동안 스캔되고 유형 지정이 적용됩니다.

#### XML 텍스트 형식

특정 XML 태그 내의 텍스트로만 추출 프로세스를 제한하려면, **XML 텍스트** 문서 유형 옵션을 사용하고 문서 설정 대화 상자의 **XML 텍스트 형식** 섹션에서 텍스트를 포함하는 태그를 선언하십시오. 추출된 용어는 이 태그 또는 해당되는 하위 태그 내에 포함된 텍스트에서만 파생됩니다.

**중요!** 추출 프로세스를 건너뛰고 용어 구분 문자에 대해 규칙을 부과하거나, 추출된 텍스트에 유형을 지정하거나, 추출된 용어에 대해 빈도 수를 부과하려면, 다음에 설명되는 **구조화된 텍스트** 옵션을 사용하십시오.

XML 텍스트 형식에 대해 태그를 선언할 때 다음 규칙을 사용하십시오.

- 행마다 하나의 XML 태그만 선언할 수 있습니다.
- 태그 요소에서는 대소문자가 구분됩니다.
- 태그에 <title id="1234">와 같은 속성이 있고 모든 변동 또는 이 경우, 모든 ID를 포함하도록 하려면, 속성이나 닫는 꺾쇠괄호(>) 없이 태그를 추가하십시오(예: <title>).

명령문을 설명하기 위해, 다음과 같은 XML 문서를 가지고 있다고 가정합니다.

```
<section>Rules of the Road
  <title id="01234">Traffic Signals</title>
  <p>Road signs are helpful.</p>
</section>
<p>Learning the rules is important.</p>
```

이 예의 경우 다음 태그를 선언합니다.

```
<section>
<title
```

이 예에서, 태그 <section>을 선언했기 때문에, 이 태그 및 해당되는 중첩 태그의 텍스트 Traffic Signals 및 Road signs are helpful은 추출 프로세스 동안 스캔됩니다. 그러나 태그 <p>가 명시적으로 선언되지 않았고 선언된 태그 내에 중첩된 태그도 아니므로 Learning the rules is important는 무시됩니다.

## (2) 텍스트 마이닝 노드: 모델 탭

모델 탭에서는 노드 출력에 대한 작성 방법 및 일반 모델 설정을 지정할 수 있습니다.

다음 매개변수를 설정할 수 있습니다.

**모델 이름.** 목표 또는 ID 필드(또는 이와 같은 필드가 지정되지 않은 경우 모델 유형)를 기준으로 모델 이름을 자동으로 생성하거나 사용자 정의 이름을 지정할 수 있습니다.

**파티션된 데이터 사용.** 파티션 필드가 정의된 경우 이 옵션을 사용하면 훈련 파티션의 데이터만 사용하여 모델을 작성합니다.

**작성 모드.** 이 텍스트 마이닝 노드와의 스트림이 실행될 때 모델 너깃이 생성되는 방법을 지정합니다. 또는 개념을 추출하고 범주를 작성하고 언어학적 자원을 세분화할 뿐 아니라 텍스트 링크 분석을 수행하고 군집을 탐색할 수도 있는 **대화형 작성** 모드를 사용하여 더 실무적이고 예비적인 방식을 사용할 수 있습니다.

- **대화형 작성.** 스트림이 실행될 때 이 옵션은 개념 및 패턴을 추출하고 추출한 결과를 탐색 및 미세 조정하며 범주를 작성 및 세분화하고 언어학적 자원(템플릿, 동의어, 유형, 라이브러리 등)을 세분화하고 범주 모델 너깃을 작성할 수 있는 대화형 인터페이스를 시작합니다. 자세한 정보는 대화형 작성의 내용을 참조하십시오.
- **직접 생성.** 이 옵션은 스트림이 실행될 때 모델이 자동으로 작성되어 모델 팔레트에 추가됨을 나타냅니다. 대화형 워크벤치와 달리, 노드에 정의된 설정 외에 실행 시에 사용자의 추가 조작이 필요하지 않습니다. 이 옵션을 선택하는 경우, 생성하려는 모델의 유형을 정의할 수 있는 모델 특정 옵션이 나타납니다. 자세한 정보는 직접 생성의 내용을 참조하십시오.

**AS에 대형 모델 저장.** IBM® SPSS® Analytic Server에 연결되어 있는 경우, 모델을 원격으로 서버에 저장하려면 이 옵션을 선택하십시오.

 **참고:** 서버에 빌드되고 저장되는 모든 모델은 해당 서버에서만 스코어링될 수 있습니다. 해당 모델을 포함하는 대화형 워크벤치 세션을 다시 실행하려면 세션을 생성하는 데 사용된 원래 서버에 연결해야 합니다.

**자원 복사 출처.** 텍스트를 마이닝할 때, 추출은 전문가 탭의 설정뿐 아니라 언어학적 자원도 기반으로 합니다. 이들 자원은 개념, 유형 및 가끔은 패턴을 얻기 위해 추출 중에 텍스트를 처리

및 취급하는 방법의 기초로 작용합니다. 자원을 자원 템플리트, 텍스트 분석 패키지(.tap) 또는 SPSS Text Analytics for Surveys 프로젝트 파일(.tas)에서 이 노드로 복사할 수 있습니다. 이 중 하나를 선택한 후 **로드**를 클릭하여 자원을 복사해 올 템플리트, 패키지 또는 프로젝트를 정의하십시오. 로드하는 순간에 자원의 사본이 노드에 저장됩니다. 그러므로 업데이트된 자원을 사용하려는 경우 여기서 또는 대화형 워크벤치 세션에서 재로드해야 합니다. 사용자 편의를 위해 자원이 복사 및 로드된 날짜 및 시간이 노드에 표시됩니다. 자세한 정보는 템플리트 및 TAP에서 자원 복사의 내용을 참조하십시오.

**텍스트 언어.** 마이닝할 텍스트의 언어를 식별합니다. 노드에서 복사된 자원은 제시된 언어 옵션을 제어합니다. 자원이 조정된 언어를 선택하십시오.

- 대화형 작성
- 직접 생성
- 템플리트 및 TAP에서 자원 복사

### ① 대화형 작성

텍스트 마이닝 모델링 노드의 모델 탭에서 모델 너깃에 대한 작성 모드를 선택할 수 있습니다. **대화형 작성**을 선택하는 경우, 스트림을 실행할 때 대화형 인터페이스가 열립니다. 이 대화형 워크벤치에서 다음을 수행할 수 있습니다.

- 개념을 포함하고 텍스트 데이터에서 핵심적인 아이디어를 발견하기 위해 노력하여 추출하고 추출 결과를 탐색합니다.
- 다양한 방법을 사용하여 개념, 유형, TLA 패턴 및 규칙에서 범주를 작성 및 확장함으로써 문서 및 레코드를 이들 범주로 스코어링할 수 있습니다.
- 언어학적 자원(자원 템플리트, 라이브러리, 사전, 동의어 등)을 세분화함으로써 개념이 추출, 검사 및 세분화되는 반복적 프로세스를 통해 결과를 개선할 수 있습니다.
- 텍스트 링크 분석(TLA)을 수행하고 발견된 TLA 패턴을 사용하여 더 좋은 범주 모델 너깃을 작성합니다. 텍스트 링크 분석 노드는 동일한 예비 옵션이나 모델링 기능을 제공하지 않습니다.
- 새 관계를 발견하기 위한 군집을 생성하고 시각화 분할창에서 개념, 유형, 패턴 및 범주 사이의 관계를 탐색합니다.
- 세분화된 범주 모델 너깃을 IBM® SPSS® Modeler의 모델 팔레트에 생성하고 이들을 다른 스트림에서 사용합니다.

 **참고:** IBM SPSS Collaboration and Deployment Services 작업을 작성 중인 경우 대화형 모델을 작성할 수 없습니다.

**최신 노드 업데이트로부터 세션 작업(범주, TLA, 자원 등)을 사용하십시오.** 대화형 워크벤치 세션에서 작업할 때, 세션 데이터(추출 매개변수, 자원, 범주 정의 등)로 노드를 업데이트할 수 있습니다. **세션 작업 사용 옵션**으로 저장된 세션 데이터를 사용하여 대화형 워크벤치를 다시 시작할 수 있습니다. 이 옵션은 세션 데이터가 저장될 수 없었으므로 이 노드를 처음 사용할 때는

사용 불가능합니다. 이 옵션을 사용할 수 있도록 세션 데이터로 노드를 업데이트하는 방법을 알려면 모델링 노드 업데이트 및 저장의 내용을 참조하십시오.

이 옵션을 사용하여 세션을 시작하는 경우, 대화형 워크벤치 세션으로부터 수행한 마지막 노드 업데이트의 추출 설정, 범주, 자원 및 다른 모든 작업이 다음에 세션을 시작할 때 사용 가능합니다. 저장된 세션 데이터가 이 옵션에서 사용되므로, 아래 템플릿으로부터 복사된 자원 같은 특정 콘텐츠 및 기타 탭은 사용 불가능하고 무시됩니다. 그러나 이 옵션 없이 세션을 시작하는 경우 노드가 현재 정의되는 그대로의 노드 콘텐츠만 사용되며, 사용자가 워크벤치에서 수행한 모든 이전 작업이 사용 불가능함을 의미합니다.

**참고:** 추출 결과가 **세션 작업 사용...** 옵션으로 캐싱된 후 스트림에 대한 소스 노드를 변경하는 경우, 추출 결과가 업데이트되기 원하는 경우에 대화형 워크벤치 세션이 시작된 후 새 추출을 실행해야 합니다.

**추출을 건너뛰고 캐시된 데이터 및 결과를 재사용하십시오.** 대화형 워크벤치 세션에서 모든 캐시된 추출 결과 및 데이터를 재사용할 수 있습니다. 이 옵션은 특히 시간을 절약하고 세션이 시작될 때 완전히 새로운 추출이 수행되기를 기다리기 보다는 추출 결과를 재사용하기 원할 때 유용합니다. 이 옵션을 사용하려면 이전에 대화형 워크벤치 세션 안에서 이 노드를 업데이트했고 **세션 작업 보존 및 재사용을 위해 추출 결과와 함께 텍스트 데이터 캐시** 옵션을 선택했어야 합니다. 이 옵션을 사용할 수 있도록 세션 데이터로 노드를 업데이트하는 방법을 알려면 모델링 노드 업데이트 및 저장의 내용을 참조하십시오.

**세션 시작 방법.** 대화형 워크벤치 세션을 시작할 때 처음 발생하기 원하는 보기 및 조치를 표시하는 옵션을 선택하십시오. 시작하는 보기와 상관없이, 세션에 있는 동안은 임의의 보기로 전환할 수 있습니다.

- **추출 결과를 사용한 범주 작성.** 이 옵션은 범주 및 개념 보기에서 대화형 워크벤치를 시작하고 적용 가능한 경우 추출을 수행합니다. 이 보기에서 범주를 작성하고 범주 모델을 생성할 수 있습니다. 또한 다른 보기로 전환할 수도 있습니다. 자세한 정보는 대화형 워크벤치 모드의 내용을 참조하십시오.
- **텍스트 링크 분석(TLA) 결과 탐색.** 이 옵션은 의견이나 텍스트 링크 분석 보기의 다른 링크 같은 텍스트 내의 개념 사이의 관계를 추출 및 식별하여 실행하고 시작합니다. 이 옵션을 사용하고 결과를 얻기 위해서는 TLA 패턴 규칙을 포함하는 템플릿 또는 텍스트 분석 패키지를 선택해야 합니다. 더 큰 데이터 세트에 대해 작업 중인 경우 TLA 추출에 다소 시간이 걸릴 수 있습니다. 이 경우에는 표본 노드 업스트림의 사용을 고려할 수도 있습니다. 자세한 정보는 텍스트 링크 분석 탐색의 내용을 참조하십시오.
- **상관 단어 군집 분석.** 이 옵션은 군집 보기에서 시작하고 모든 오래된 추출 결과를 업데이트합니다. 이 보기에서 상관 단어 군집 분석을 수행할 수 있는데 이것은 군집 세트를 생성합니다. 상관 단어 군집화는 주어진 레코드나 문서에서 동시 발생을 기반으로 두 개념 사이의 링크 값의 강도를 평가하여 시작하고 강하게 링크된 개념을 군집으로 그룹화하여 종료하는 프로세스입니다. 자세한 정보는 대화형 워크벤치 모드의 내용을 참조하십시오.

## ② 직접 생성

텍스트 마이닝 모델링 노드의 모델 탭에서 모델 너깃에 대한 작성 모드를 선택할 수 있습니다. 직접 생성을 선택하는 경우 노드에서 옵션을 설정한 후 스트림을 바로 실행할 수 있습니다. 출력은 개념 모델 너깃으로, 모델 팔레트에 바로 배치되었습니다. 대화형 워크벤치와는 달리, 노드에서 이 옵션에 대해 정의되는 빈도 설정 외에는 실행 시에 추가 조작이 필요하지 않습니다.

**모델에 포함시킬 개념의 최대 수.** 자동으로(비대화형) 모델을 작성할 때만 적용되는 이 옵션은 개념 모델을 작성하기 원함을 표시합니다. 또한 이 모델이 지정된 개념 수보다 많지 않은 개념을 포함해야 함을 말합니다.

- **최고 빈도를 바탕으로 개념 선택. 최상위 개념 수.** 최고 빈도를 갖는 개념으로 시작할 때 이것은 검사할 개념의 수입입니다. 여기에서 빈도는 문서/레코드의 전체 세트에서 개념(및 그날 수 있는 모든 기본 용어)이 나타나는 횟수를 의미합니다. 한 개념이 한 레코드에서 여러 번 나타나므로 이 숫자는 레코드 개수보다 더 높을 수 있습니다.
- **너무 많은 레코드에서 발생하는 개념 선택 취소. 레코드 백분율.** 사용자가 지정한 숫자보다 더 높은 레코드 수 백분율을 갖는 개념을 선택 취소합니다. 이 옵션은 텍스트나 모든 레코드에서 자주 발생하지만 분석에서 의미가 없는 개념을 제외하는 데 유용합니다.

**스코어링 속도에 최적화.** 기본적으로 선택되는 이 옵션은 작성되는 모델이 최소이며 높은 속도로 스코어링되도록 보장합니다. 이 옵션을 선택 취소하면 더 느리게 스코어링하는 훨씬 더 큰 모델이 작성됩니다. 그러나 더 큰 모델은 생성된 개념 모델에서 초기에 표시되는 스코어가 모델 너깃을 사용하여 동일한 텍스트를 스코어링할 때 얻는 스코어와 동일하도록 보장합니다.

## ③ 템플릿 및 TAP에서 자원 복사

텍스트를 마이닝할 때, 추출은 전문가 탭의 설정뿐 아니라 언어학적 자원도 기반으로 합니다. 이들 자원은 개념, 유형 및 가끔은 패턴을 얻기 위해 추출 중에 텍스트를 처리 및 취급하는 방법의 기초로 작용합니다. *자원 템플릿*에서 이 노드로 자원을 복사할 수 있으며, 텍스트 마이닝 노드에 있는 경우 *텍스트 분석 패키지(TAP)* 또는 SPSS® Text Analytics for Surveys 프로젝트(.tas)를 선택할 수도 있습니다.

기본적으로, 자원은 노드를 캔버스에 추가할 때 제품의 라이선스 언어로 된 기본 템플릿에서 노드로 복사됩니다. 여러 언어에 대한 라이선스가 있는 경우 첫 번째로 선택한 언어가 자동으로 로드할 템플릿을 판별하는 데 사용됩니다.

로드하는 순간에 선택된 자원의 사본이 노드에 저장됩니다. 템플릿, TAP 또는 SPSS Text Analytics for Surveys 의 콘텐츠만 복사되고, 템플릿, TAP 또는 SPSS Text Analytics for Surveys 자체는 노드에 링크되지 않습니다. 즉, 자원이 나중에 업데이트되는 경우 업데이트 사항을 노드에서 자동으로 사용할 수 없습니다. 요약하면, 자원의 새 사본을 재로드하지 않는 한 또

는 텍스트 마이닝 노드를 업데이트하고 **세션 작업 사용** 옵션을 선택하지 않는 한 노드로 로드된 자원이 항상 사용됩니다. **세션 작업 사용**에 대한 자세한 정보는 이 절에서 추가로 확인하십시오.

자원을 선택할 때 텍스트 데이터와 동일한 언어를 사용하는 자원을 선택하십시오. 라이선스가 있는 언어로 된 자원만 사용할 수 있습니다. 텍스트 링크 분석을 수행하려는 경우 TLA 패턴을 포함하는 템플릿을 선택해야 합니다. 템플릿이 TLA 패턴을 포함하는 경우, 자원 템플릿 로드 대화 상자의 TLA 옆에 아이콘이 나타납니다.

**참고:** TAP 또는 SPSS Text Analytics for Surveys 프로젝트는 텍스트 분석 노드로 로드할 수 없습니다.

## 자원 템플릿

자원 템플릿은 라이브러리 및 특정 도메인이나 사용법을 위해 미세 조정된 고급 언어 및 비언어학적 자원의 사전 정의된 세트입니다. 텍스트 마이닝 모델링 노드에서, 노드를 스트림에 추가할 때 기본 템플릿의 자원 사본이 이미 노드에 로드되었지만, **자원 템플릿** 또는 **텍스트 분석 패키지** 중 하나를 선택한 후 **로드**를 클릭하여 템플릿을 변경하거나 텍스트 분석 패키지를 로드할 수 있습니다. 템플릿의 경우 자원 템플릿 로드 대화 상자에서 템플릿을 선택할 수 있습니다.

**참고:** 목록에서 원하는 템플릿을 보지 않지만 사용자 머신에 내보내진 사본이 있는 경우 지금 가져올 수 있습니다. 또한 이 대화 상자에서 내보내어 다른 사용자와 공유할 수도 있습니다. 자세한 정보는 템플릿 가져오기 및 내보내기의 내용을 참조하십시오.

## 텍스트 분석 패키지(TAP) 및 TAS(Text Analysis for Surveys) 프로젝트

텍스트 분석 패키지(TAP)는 하나 이상의 사전 정의된 범주 세트와 함께 번들로 제공되는 라이브러리 및 고급 언어 및 비언어학적 자원의 사전 정의된 세트입니다. IBM® SPSS Modeler Text Analytics는 특정 도메인에 대해 미세 조정되는 사전 작성된 TAP를 여러 개 제공합니다. TAP를 편집한 후 다른 디렉토리에 저장하면 이러한 TAP를 사용하여 범주 모델 작성을 시작할 수 있습니다. 또한 대화형 세션에서 사용자 자신의 TAP를 작성할 수도 있습니다. 자세한 정보는 텍스트 분석 패키지 로드의 내용을 참조하십시오.

SPSS Text Analytics for Surveys 프로젝트(.tas)를 가져오도록 선택한 경우 이 프로젝트는 TAP로 변환됩니다.

**참고:** TAP 또는 SPSS Text Analytics for Surveys 프로젝트는 텍스트 분석 노드로 로드할 수 없습니다.

## "세션 작업 사용" 옵션 사용(모델 탭)

자원이 모델 탭의 노드에 복사되는 동안, 나중에 대화형 세션에서 자원을 변경할 수도 있으며 이런 최종 변경으로 텍스트 마이닝 모델링 노드를 업데이트하기 원할 수도 있습니다. 이 경우 텍스트 마이닝 모델링 노드의 모델 탭에서 **세션 작업 사용** 옵션을 선택할 수 있습니다.

**세션 작업 사용**을 선택하는 경우, 로드 단추가 노드에서 사용 안함으로 설정되어 대화형 워크벤치에서 온 자원이 이전에 여기에 로드된 자원 대신에 사용됨을 표시합니다.

**세션 작업 사용** 옵션을 선택한 후 자원을 변경하기 위해 자원 편집기 보기를 통해 자원을 대화형 워크벤치 세션 안에서 직접 편집 또는 전환할 수 있습니다. 자세한 정보는 로드 후 노드 자원 업데이트의 내용을 참조하십시오.

### (3) 텍스트 마이닝 노드: 전문가 탭

전문가 탭에는 텍스트가 추출 및 처리되는 방법에 영향을 주는 특정 고급 매개변수가 들어 있습니다. 이 대화 상자의 매개변수는 추출 프로세스의 기본 작동뿐 아니라 몇 가지 고급 작동을 제어합니다. 그러나 이들은 사용 가능한 옵션의 일부만 표시합니다. 또한 추출 결과에 영향을 미치는 많은 언어학적 자원 및 옵션이 있는데, 이것은 모델 탭에서 선택하는 자원 템플릿에 의해 제어됩니다. 자세한 정보는 텍스트 마이닝 노드: 모델 탭의 내용을 참조하십시오.

**참고:** 이 전체 탭은 모델 탭에서 저장된 대화형 워크벤치 정보를 사용하여 **대화형 작성** 모드를 선택한 경우 사용 불가능하며, 이 경우 추출 설정은 마지막 저장된 워크벤치 세션에서 가져옵니다.

추출할 때마다 다음 매개변수를 설정할 수 있습니다.

**최소한 [n] 전역 빈도를 사용하는 개념으로 추출 제한.** 텍스트의 단어 또는 구문이 추출되기 위해 최소한 발생해야 하는 횟수를 지정합니다. 이 방식에서, 값 5는 전체 레코드 또는 문서 세트에서 최소 5번 발생하는 단어 또는 구문으로 추출을 제한합니다.

일부 경우에, 이 한계를 변경하여 추출 결과와 결국 범주에 큰 차이가 발생할 수 있습니다. 식당 데이터에 대해 작업할 때 이 옵션에 대해 1 이상으로 한계를 증가시키지 마십시오. 이러한 경우, 추출 결과에서 *피자(1)*, *썬 피자(2)*, *시금치 피자(2)*, *즐거먹는 피자(2)*를 볼 수 있습니다. 그러나 추출을 전역 빈도 5 이상으로 제한하고 다시 추출하면, 더 이상 이 세 개의 개념을 얻을 수 없습니다. 대신 *피자(7)*를 얻게 됩니다. *피자*는 가장 단순한 양식이고 이 단어는 이미 가능한 후보로 존재하고 있기 때문입니다. 텍스트의 나머지에 따라서, 텍스트에 피자가 있는 다른 구문이 계속 있는지 여부에 따라 실제로 8 이상의 빈도를 가질 수 있습니다. 또한 *시금치 피자*가 이미 범주 디스크립터인 경우, 모든 레코드를 캡처하는 대신 *피자*를 디스크립터로 추가해야 할 수 있습니다. 이러한 이유로, 범주가 이미 작성된 경우에는 항상 주의하여 이 한계를 변경하십시오.

이는 추출 전용 기능입니다. 템플릿에 용어(보통 수행되는)가 있고 템플릿에 대한 용어가 텍스트에서 발견되는 경우, 용어는 해당 빈도에 관계없이 색인화됩니다.

예를 들어, 코어 라이브러리에서 <Location> 유형 아래에 "los angeles"를 포함하는 기본 자원 템플릿을 사용한다고 가정하십시오. 문서에 Los Angeles가 한 번만 포함되면, Los Angeles는 개념 목록의 일부가 됩니다. 이를 방지하기 위해서는 **최소한 [n] 전역 빈도를 사용하는 개념으로 추출 제한** 필드에 입력한 값과 동일한 횟수만큼 발생하는 개념을 표시하도록 필터를 설정해야 합니다.

**구두점 오류를 조정하십시오.** 이 옵션은 추출 중에 구두점 오류가 있는 텍스트(예를 들어, 부적절한 사용법)를 일시적으로 표준화하여 개념의 추출 가능성을 향상시킵니다. 이 옵션은 텍스트가 짧고 품질이 저조한 경우(예를 들어, 개방형 설문조사 반응, 이메일 및 CRM 데이터) 또는 텍스트에 많은 약어가 포함된 경우에 특히 유용합니다.

**최소 단어 문자 길이([n])에 대한 맞춤법 수용** 이 옵션은 맞춤법이 자주 틀리는 단어나 맞춤법이 유사한 단어를 하나의 개념으로 그룹화하는 퍼지 그룹화 기술을 적용합니다. 퍼지 그룹화 알고리즘은 일시적으로 모든 모음(맨 처음 것은 제외)을 지우고 추출된 단어에서 이중/삼중 자음을 지운 다음 modeling과 modelling이 함께 그룹화될 수 있도록 이들이 동일하지 비교합니다. 그러나 각 용어가 <Unknown> 유형을 제외하고 서로 다른 유형에 지정된 경우에는 퍼지 그룹화 기술은 적용되지 않습니다.

퍼지 그룹화를 사용하기 전에 필요한 루트 문자의 최소 수를 정의할 수도 있습니다. 용어에서 루트 문자의 수는 모든 문자를 합한 후 굴절접사를 형성하는 문자와 복합어의 경우에는 한정사 및 전치사를 형성하는 문자를 빼서 계산합니다. 예를 들어, exercises 용어는 "exercise" 양식의 8개 루트 문자가 있는 것으로 간주됩니다. 단어 끝의 s자는 굴절(복수형)이기 때문입니다. 마찬가지로, apple sauce는 10개의 루트 문자로 간주되고("apple sauce") manufacturing of cars는 16개의 루트 문자("manufacturing car")로 간주됩니다. 이 계산 방법은 퍼지 그룹화를 적용해야 하는지 여부를 확인하는 데에만 사용되고 단어가 매치하는 방법에는 영향을 미치지 않습니다.

**참고:** 특정 단어가 나중에 잘못 그룹화되는 경우에는 이를 고급 자원 탭의 **퍼지 그룹화: 예외** 섹션에 명시적으로 선언하여 이 기술에서 단어 쌍을 제외할 수 있습니다. 자세한 정보는 퍼지 그룹화의 내용을 참조하십시오.

**단일어 추출** 이 옵션은 단어가 복합어의 일부가 아니거나 명사이거나 인식되지 않은 품사인 경우에만 단일어를 추출합니다.

**비언어 엔티티 추출** 이 옵션은 전화 번호, 주민등록번호, 시간, 날짜, 통화, 숫자, 백분율, 이메일 주소 및 HTTP 주소 등과 같은 비언어 엔티티를 추출합니다. 고급 자원 탭의 **비언어 엔티티: 구성** 섹션에서 비언어 엔티티의 특정 유형을 포함하거나 제외할 수 있습니다. 불필요한 엔티티를 사용 안함으로 설정하면 추출 엔진은 처리 시간을 낭비하지 않습니다. 자세한 정보는 구성의 내용을 참조하십시오.

**대문자 알고리즘** 이 옵션은 용어의 첫 글자가 대문자인 한 내장된 사전에 없는 단순 및 복합어를 추출합니다. 이 옵션은 가장 적합한 명사를 추출하기 위한 좋은 방법을 제공합니다.

**가능한 경우 부분 및 전체 사람 이름을 함께 그룹화** 이 옵션은 텍스트에 다르게 나타나는 이름을 그룹화합니다. 이름은 종종 시작부에는 전체 이름이 언급되고 나중에는 약어로만 표시되기 때문에 이 기능이 유용합니다. 이 옵션은 <Unknown> 유형의 단일어를 <Person>으로 입력되는 복합어와 매치시키려고 시도합니다. 예를 들어, doe가 있고 처음에는 <Unknown>으로 입력되는 경우에는, 추출 엔진은 <Person> 유형에 있는 복합어가 doe를 마지막 단어로 포함하는지 여부를 확인합니다(예: john doe). 이 옵션은 이름에는 적용되지 않습니다. 이름의 대부분은 단일어로 추출되지 않기 때문입니다.

**최대 비기능 단어 순열** 이 옵션은 순열 기술을 적용할 때 존재할 수 있는 비기능 단어 최대 수를 지정합니다. 이 순열 기술은 서로 굴절과는 관계없이 포함된 비기능 단어(예: of 및 the)만 다른 유사한 구를 그룹화합니다. 예를 들어, 이 값을 최소 두 개의 단어로 설정하고 company officials 및 officials of the company 둘 모두가 추출되었다고 해 봅시다. 이 경우, 추출된 두 용어는 모두 마지막 개념 목록에 그룹화됩니다. 두 용어 모두 of the가 무시될 때 동일한 것으로 간주되기 때문입니다.

**다항어를 그룹화할 때 파생 사용** 빅 데이터를 처리할 때 파생 규칙을 사용하여 다항어를 그룹화하려면 이 옵션을 선택하십시오.

 **참고:** 텍스트 링크 분석 결과의 추출이 가능하게 하려면 **텍스트 링크 분석 결과 탐색** 옵션으로 세션을 시작하고 TLA 정의를 포함하는 자원을 선택해야 합니다. 항상 추출 설정 대화 상자를 통해 대화형 워크벤치 세션 중에 나중에 TLA 결과를 추출할 수 있습니다. 자세한 정보는 데이터 추출의 내용을 참조하십시오.

#### (4) 시간 절약을 위한 업스트림 표본추출

많은 양의 데이터가 있을 때 처리 시간은 특히 대화형 워크벤치 세션을 사용할 때 몇 분에서 몇 시간까지 걸릴 수 있습니다. 데이터의 크기가 클수록, 추출 및 범주화 프로세스에 시간이 더 걸립니다. 효율적으로 작업하기 위해 텍스트 마이닝 노드에서 IBM® SPSS® Modeler 표본 노드 업스트림을 추가할 수 있습니다. 이 표본 노드를 사용하여 문서 또는 레코드의 더 작은 서브세트를 사용하는 임의 표본을 취하여 처음 몇 번의 패스를 수행하십시오.

더 작은 표본이 종종 자원을 편집하고 모든 범주가 아닌 대부분을 작성하는 방법을 결정하기에 완벽하게 충분합니다. 그리고 더 작은 데이터 세트에 대해 실행하고 결과에 만족한 후에 동일한 기법을 전체 데이터 세트에 대한 범주를 작성하는 데 적용할 수 있습니다. 그런 다음 사용자가 작성한 범주에 맞지 않는 문서나 레코드를 찾고 필요에 따라 조정할 수 있습니다.

 **참고:** 표본 노드는 표준 IBM SPSS Modeler 노드입니다.

## (5) 스트림에서 텍스트 마이닝 노드 사용

텍스트 마이닝 모델링 노드는 데이터에 액세스하고 스트림에서 개념을 추출하는 데 사용됩니다. 데이터베이스 노드, 변수 파일 노드, 웹 피드 노드 또는 고정 파일 노드 같은 모든 소스 노드를 사용하여 데이터에 액세스할 수 있습니다. 외부 문서에 상주하는 텍스트의 경우 파일 목록 노드를 사용할 수 있습니다.

### 예 1: 개념 모델 너깃을 직접 작성하기 위한 파일 목록 노드 및 텍스트 마이닝 노드

다음 예는 파일 목록 노드를 텍스트 마이닝 모델링 노드와 함께 사용하여 개념 모델 너깃을 생성하는 방법을 보여줍니다. 파일 목록 노드 사용에 대한 자세한 정보는 파일 목록 노드를 참조하십시오.

1. **파일 목록 노드(설정 탭).** 먼저, 이 노드를 스트림에 추가하여 텍스트 문서가 저장되는 장소를 지정했습니다. 텍스트 마이닝을 수행하려는 모든 문서를 포함하는 디렉토리를 선택했습니다.
2. **텍스트 마이닝 노드(필드 탭).** 다음으로, 파일 목록 노드에 텍스트 마이닝 노드를 추가하고 연결했습니다. 이 노드에서, 입력 형식, 자원 템플릿 및 출력 형식을 정의했습니다. 파일 목록 노드에서 생성된 필드 이름을 선택하고 기타 설정뿐만 아니라 텍스트 필드도 선택했습니다. 자세한 정보는 스트림에서 텍스트 마이닝 노드 사용의 내용을 참조하십시오.
3. **텍스트 마이닝 노드(모델 탭).** 다음, 모델 탭에서 이 노드에서 직접 개념 모델 너깃을 생성하는 작성 모드를 선택했습니다. 다른 자원 템플릿을 선택하거나 기본 자원을 유지할 수 있습니다.

### 예 2: 범주 노드를 대화식으로 작성하기 위한 Excel 파일 및 텍스트 마이닝 노드

이 예는 텍스트 마이닝 노드가 대화형 워크벤치 세션을 시작할 수 있는 방법을 보여줍니다. 대화형 워크벤치에 대한 자세한 정보는 대화형 워크벤치 모드를 참조하십시오.

1. **Excel 소스 노드(데이터 탭).** 먼저, 이 노드를 스트림에 추가하여 텍스트가 저장되는 위치를 지정했습니다.
2. **텍스트 마이닝 노드(필드 탭).** 다음, 텍스트 마이닝 노드를 추가하고 연결했습니다. 이 첫 번째 탭에서 입력 형식을 정의했습니다. 소스 노드에서 필드 이름을 선택했습니다.
3. **텍스트 마이닝 노드(모델 탭).** 다음, 모델 탭에서 범주 모델 너깃을 대화식으로 작성하고 추출 결과를 사용하여 범주를 자동으로 작성할 것을 선택했습니다. 이 예에서 텍스트 분석 패키지로부터 자원 사본 및 범주 세트를 로드했습니다.
4. **대화형 워크벤치 세션.** 다음, 스트림을 실행했으며 대화형 워크벤치 인터페이스가 열렸습니다. 추출이 수행된 후 데이터 탐색 및 범주 개선을 시작했습니다.

## 2) 텍스트 마이닝 너깃: 개념 모델

텍스트 마이닝 개념 모델 너깃은 모델 탭에서 **모델을 직접 생성** 옵션을 선택한 텍스트 마이닝 모델 노드를 성공적으로 실행할 때마다 작성됩니다. 텍스트 마이닝 개념 모델 너깃은 콜센터의 메모철 데이터 같은 다른 텍스트 데이터에서 핵심 개념의 실시간 발견에 사용됩니다.

개념 모델 너깃 자체는 개념의 목록으로 구성되는데, 이들은 유형에 지정되었습니다. 다른 데이터에 대한 스코어링을 위해 해당 모델에 있는 데이터의 일부 또는 전부를 선택할 수 있습니다. 텍스트 마이닝 모델 너깃을 포함하는 스트림을 실행할 때, 모델을 작성하기 전에 텍스트 마이닝 모델링 노드의 모델 탭에서 선택된 작성 모드에 따라서 새 필드가 데이터에 추가됩니다. 자세한 정보는 개념 모델: 모델 탭의 내용을 참조하십시오.

모델 너깃이 변환된 문서를 사용하여 생성된 경우, 스코어링은 변환된 언어로 수행됩니다. 마찬가지로, 모델 너깃이 언어로 영어를 사용하여 생성된 경우, 문서가 영어로 변환되므로 모델 너깃에서 변환 언어를 지정할 수 있습니다.

텍스트 마이닝 모델 너깃은 생성될 때 모델 너깃 팔레트(IBM® SPSS® Modeler 창의 상단 오른쪽에 있는 모델 탭에 있는)에 위치됩니다.

### 결과 보기

모델 너깃에 대한 정보를 보려면, 모델 너깃 팔레트를 마우스 오른쪽 단추로 클릭하고 컨텍스트 메뉴에서 **찾아보기**를(또는 스트림의 노드의 경우 **편집**)을 선택하십시오.

### 스트림에 모델 추가

모델 너깃을 스트림에 추가하려면, 모델 너깃 팔레트에서 아이콘을 클릭하고 노드를 위치시키려는 스트림 캔버스를 클릭하십시오. 또는 아이콘을 마우스 오른쪽 단추로 클릭하고 컨텍스트 메뉴로부터 **스트림에 추가**를 선택하십시오. 그리고 나서 노드에 스트림을 연결하십시오. 그러면 예측을 생성하기 위해 데이터를 전달할 준비가 됩니다.

**주의:** 스코어링 너깃을 사용하여 범주 모델 및 사용된 템플릿을 둘 다 포함하는 모델링 노드를 다시 생성하려는 경우, 스코어링 너깃을 생성하기 전에 TAP를 작성하고 이를 모델링 노드 대신 대화형 세션에서 사용할 것을 권장합니다.

### (1) 개념 모델: 모델 탭

개념 모델에서 모델 탭은 추출된 개념의 세트를 표시합니다. 개념은 각 개념에 대해 하나의 행을 갖는 테이블 형식으로 제공됩니다. 이 탭의 목적은 스코어링에 사용될 개념을 선택하는 것입니다.

**참고:** 범주 모델 너깃을 대신 생성한 경우, 이 탭은 다른 정보를 표시합니다. 자세한 정보는 범주 모델 너깃: 모델 탭의 내용을 참조하십시오.

가장 왼쪽 열의 선택란에 표시되는 것처럼 기본적으로 모든 개념이 스코어링을 위해 선택됩니다. 선택된 상자는 개념이 스코어링에 사용될 것임을 의미합니다. 선택되지 않은 상자는 개념이 스코어링에서 제외될 것임을 의미합니다. 복수 행을 선택하고 선택에 있는 선택란 중 하나를 클릭하여 다중 행을 선택할 수 있습니다.

각 개념에 대해 자세히 알기 위해 다음 열의 각각에서 제공되는 추가 정보를 찾을 수 있습니다.

**개념.** 이것은 추출된 리드 단어 또는 구입니다. 어떤 경우에는 이 개념이 개념 이름뿐 아니라 이 개념과 연관된 다른 어떤 기본 용어를 나타냅니다. 어떤 기본 용어가 개념의 일부인지 알려면, 이 탭 안에서 기본 용어 분할창을 표시하고 개념을 선택하여 대화 상자의 맨 아래에 있는 대응하는 용어를 보십시오. 자세한 정보는 개념 모델의 기본 용어의 내용을 참조하십시오.

**글로벌.** 여기에서, 글로벌(빈도)은 개념(및 그의 모든 기본 용어)이 문서/레코드의 전체 세트에서 나타나는 횟수를 의미합니다.

- **막대형 차트.** 텍스트 데이터에서 이 개념의 글로벌 빈도가 막대형 차트로 제공됩니다. 막대는 유형을 시각적으로 구별하기 위해 개념이 지정되는 유형의 색상을 갖습니다.
- **%.** 텍스트 데이터에서 이 개념의 글로벌 빈도가 퍼센트로 제공됩니다.
- **N.** 텍스트 데이터에서 이 개념의 실제 발생 수입입니다.

**문서.** 여기에서 문서는 문서 개수를 말하며, 개념(및 그의 모든 기본 용어)이 나타나는 문서 또는 레코드의 수를 의미합니다.

- **막대형 차트.** 이 개념의 문서 개수가 막대형 차트로 제공됩니다. 막대는 유형을 시각적으로 구별하기 위해 개념이 지정되는 유형의 색상을 갖습니다.
- **%.** 이 개념의 문서 개수가 퍼센트로 제공됩니다.
- **N.** 이 개념을 포함하는 문서 또는 레코드의 실제 수입입니다.

**유형.** 개념이 지정된 유형입니다. 각 개념에 대해 글로벌 및 문서 열이 이 개념이 지정된 유형을 표시하기 위해 색상으로 나타냅니다. 유형은 개념의 시맨틱 그룹입니다. 자세한 정보는 유형 사전의 내용을 참조하십시오.

개념에 대한 작업

테이블에서 셀을 마우스 오른쪽 단추로 클릭하여 다음을 수행할 수 있는 컨텍스트 메뉴를 표시할 수 있습니다.

- **모두 선택.** 테이블의 모든 행이 선택됩니다.

- **복사.** 선택된 개념이 클립보드에 복사됩니다.
- **필드 포함 복사** 선택된 개념이 열 머리말과 함께 클립보드에 복사됩니다.
- **선택 확인.** 테이블에서 선택된 행에 대한 모든 선택란을 선택하므로 해당 개념을 스코어링에 포함시킵니다.
- **선택 취소.** 테이블에서 선택된 행에 대한 모든 선택란을 선택 취소합니다.
- **모두 선택.** 테이블의 모든 선택란을 선택합니다. 그러면 모든 개념이 최종 출력에서 사용됩니다.
- **모두 선택 취소.** 테이블의 모든 선택란을 선택 취소합니다. 개념을 선택 취소하는 것은 개념이 최종 출력에서 사용되지 않음을 의미합니다.
- **개념 포함.** 개념 포함 대화 상자를 표시합니다. 자세한 정보는 스코어링에 개념 포함을 위한 옵션의 내용을 참조하십시오.

### ① 스코어링에 개념 포함을 위한 옵션

스코어링에 사용될 개념을 빨리 선택 또는 선택 취소하려면 개념 포함에 대한 도구 모음 단추를 클릭하십시오.

그림 1. 개념 포함 도구 모음 단추



이 도구 모음 단추를 클릭하면 규칙을 기반으로 개념을 선택할 수 있는 개념 포함 대화 상자가 열립니다. 모델 탭에서 선택 표시를 갖는 모든 개념이 스코어링에 포함됩니다. 이 하위 대화 상자의 규칙을 적용하여 스코어링에 사용될 개념을 변경하십시오.

다음 옵션 중에서 선택할 수 있습니다.

**최고 빈도를 바탕으로 개념 선택.** **최상위 개념 수.** 최고 글로벌 빈도를 갖는 개념으로 시작할 때 이것은 검사할 개념의 수입니다. 여기에서 빈도는 문서/레코드의 전체 세트에서 개념(및 그의 모든 기본 용어)이 나타나는 횟수를 의미합니다. 한 개념이 한 레코드에서 여러 번 나타날 수 있으므로 이 숫자는 레코드 개수보다 더 높을 수 있습니다.

**문서 개수를 기반으로 개념 선택.** **최소 빈도.** 이것은 개념이 선택되기 위해 필요한 최저 문서 개수입니다. 여기에서 문서 개수는 개념(및 그의 모든 기본 용어)이 나타나는 문서/레코드의 수를 의미합니다.

**유형에 지정된 개념 선택.** 드롭 다운 목록에서 유형을 선택하여 이 유형에 지정된 모든 개념을 선택하십시오. 개념이 추출 프로세스 중에 자동으로 유형에 지정됩니다. 유형은 개념의 시맨틱 그룹입니다. 유형은 상위 레벨 개념, 긍정적 및 부정적 단어와 규정자, 이름, 장소, 조직 등과 같은 것을 포함합니다. 자세한 정보는 유형 사전의 내용을 참조하십시오.

**너무 많은 레코드에서 발생하는 개념 선택 취소.** **레코드 백분율.** 사용자가 지정한 숫자보다 더 높은 레코드 수 백분율을 갖는 개념을 선택 취소합니다. 이 옵션은 텍스트나 모든 레코드에서 자주 발생하지만 분석에서 의미가 없는 개념을 제외하는 데 유용합니다.

유형에 지정된 개념 선택 취소. 드롭 다운 목록에서 선택하는 유형과 매치하는 개념을 선택 취소합니다.

## ② 개념 모델의 기본 용어

테이블에서 선택한 개념에 대해 정의되는 기본 용어를 볼 수 있습니다. 도구 모음의 기본 용어 전환 단추를 클릭하여 대화 상자의 맨 아래에 있는 분할된 분할창에서 기본 용어 테이블을 표시할 수 있습니다.

이런 기본 용어는 언어학적 자원에서 정의되는 동의어(텍스트에서 발견되었는지 여부는 상관없음) 및 모델 너깃, 순열된 용어, 퍼지 그룹화로부터의 용어 등을 생성하는 데 사용된 텍스트에서 발견되는 모든 추출된 복수형/단수형 용어를 포함합니다.

### 그림 1. 기본 용어 도구 모음 단추 표시



**참고:** 기본 용어의 목록을 편집할 수 없습니다. 이 목록은 대체, 동의어 정의(대체 사전에서), 퍼지 그룹화 등을 통해 생성되는데, 이들은 모두 언어학적 자원에서 정의됩니다. 용어가 개념 아래에 그룹화되는 방법이나 용어가 처리되는 방법을 변경하려면, 자원(대화형 워크벤치의 자원 편집기 또는 템플릿 편집기에서 편집 가능하며 노드에 재로드)에서 직접 변경한 후 스트림을 재실행하여 업데이트된 결과를 갖는 새 모델 너깃을 확보해야 합니다.

기본 용어나 개념을 포함하는 셀을 마우스 오른쪽 단추로 클릭하여 다음을 수행할 수 있는 컨텍스트 메뉴를 표시할 수 있습니다.

- **복사.** 선택된 셀이 클립보드에 복사됩니다.
- **필드 포함 복사.** 선택된 셀이 열 머리말과 함께 클립보드에 복사됩니다.
- **모두 선택.** 테이블의 모든 셀이 선택됩니다.

## (2) 개념 모델: 설정 탭

설정 탭은 필요한 경우 새 입력 데이터에 대한 텍스트 필드 값을 정의하는 데 사용됩니다. 또한 출력을 위한 데이터 모델을 정의하는 장소입니다(스코어링 모드).

**참고:** 이 탭은 모델 너깃이 캔버스에 배치될 때만 나타납니다. 모델 팔레트에서 직접 이 대화 상자에 액세스 중일 때는 존재하지 않습니다.

## 스코어링 모드: 레코드로서의 개념

이 스코어링 모드를 사용하면 각 개념/문서 쌍에 대해 새 레코드가 작성됩니다. 일반적으로 출력에는 입력에 있는 것보다 더 많은 레코드가 있습니다.

입력 필드 외에, 다음의 새 필드가 데이터에 추가됩니다.

표 1. "레코드로서의 개념"에 대한 출력 필드

필드	설명
Concept	텍스트 데이터 필드에서 발견되는 추출된 개념 이름을 포함합니다.
Type	위치 또는 사용자 같은 전체 유형 이름으로 개념의 유형을 저장합니다. 유형은 개념의 시맨틱 그룹입니다. 자세한 정보는 유형 사전의 내용을 참조하십시오.
Count	텍스트 본문(레코드/문서)에서 해당 개념(및 그의 기본 용어)에 대한 발생 수를 표시합니다.

이 옵션을 선택할 때, 구두점 오류 수용을 제외한 다른 모든 옵션이 표시됩니다.

## 스코어링 모드: 필드로서의 개념

개념 모델에서 각 입력 레코드에 대해, 주어진 문서에서 발견되는 모든 개념에 대해 새 레코드가 작성됩니다. 그러므로 입력에 있는 경우 만큼의 출력 레코드가 있습니다. 그러나 각 레코드(행)는 이제 모델 탭에서(선택 표시를 사용하여) 선택된 각 개념에 대한 하나의 새 필드(열)를 포함합니다. 각 개념 필드에 대한 값은 이 탭에서 플래그 또는 개수를 필드 값으로 선택하는지 여부에 따라 다릅니다.

**참고:** 예를 들어 Db2 데이터베이스에서 매우 큰 데이터 세트를 사용 중인 경우, 필드로서의 개념을 사용하면 데이터량으로 인해 처리 문제가 발생할 수 있습니다. 이 경우 레코드로서의 개념을 대신 사용할 것을 권장합니다.

**필드 값.** 각 개념에 대한 새 필드가 개수 또는 플래그 값을 포함할지 여부를 선택하십시오.

- **플래그.** 이 옵션은 *Yes/No, True/False, T/F* 또는 1과 2 같이 출력에서 두 개의 고유한 값을 갖는 플래그를 얻는 데 사용됩니다. 저장 유형이 선택된 값을 반영하도록 자동으로 설정됩니다. 예를 들어, 플래그에 대해 숫자 값을 입력하는 경우 자동으로 정수 값으로 처리됩니다. 플래그의 저장 유형은 문자열, 정수, 실수 또는 날짜/시간입니다. **True** 및 **False**에 대한 플래그 값을 입력하십시오.
- **개수.** 개념이 주어진 레코드에서 발생한 빈도를 얻는 데 사용됩니다.

**필드 이름 확장.** 필드 이름의 확장을 지정하십시오. 필드 이름은 개념 이름에 이 확장을 더해서 사용하여 생성됩니다.

- **추가 위치.** 확장이 필드 이름에 추가될 위치를 지정하십시오. 확장을 문자열의 시작에 추가하려면 **접두문자**를 선택하십시오. 확장을 문자열의 끝에 추가하려면 **접미문자**를 선택하십시오.

**구두점 오류를 조정하십시오.** 이 옵션은 추출 중에 구두점 오류가 있는 텍스트(예를 들어, 부적절한 사용법)를 일시적으로 표준화하여 개념의 추출 가능성을 향상시킵니다. 이 옵션은 텍스트가 짧고 품질이 저조한 경우(예를 들어, 개방형 설문조사 반응, 이메일 및 CRM 데이터) 또는 텍스트에 많은 약어가 포함된 경우에 특히 유용합니다.

### (3) 개념 모델: 필드 탭

필드 탭은 필요한 경우 새 입력 데이터에 대한 텍스트 필드 값을 정의합니다.

 **참고:** 이 탭은 모델 너깃이 스트림에 배치될 때만 나타납니다. 모델 팔레트에서 직접 이 출력에 액세스 중일 때는 존재하지 않습니다.

**텍스트 필드.** 마이닝할 텍스트를 포함하는 필드를 선택하십시오. 이 필드는 데이터 소스에 따라 다릅니다.

**문서 유형.** 문서 유형은 텍스트의 구조를 지정합니다. 다음 유형 중 하나를 선택하십시오.

- **전체 텍스트.** 대부분의 문서 또는 텍스트 소스에 대해 사용합니다. 추출을 위해 전체 텍스트 세트가 스캔됩니다. 다른 옵션과 달리, 이 옵션의 추가 설정은 없습니다.
- **구조화된 텍스트.** 식별하고 분석할 수 있는 일반 구조를 포함하는 파일, 서지 목록 양식 및 특허에 사용됩니다. 이 문서 유형은 추출 프로세스의 일부 또는 전체를 건너뛰기 위해 사용됩니다. 이 문서 유형을 사용하여 항 구분 문자를 정의하고, 유형을 지정하며, 최소 빈도 값을 부과할 수 있습니다. 이 옵션을 선택하면, **설정** 단추를 클릭하고 문서 설정 대화 상자의 **구조화된 텍스트 형식** 영역에서 텍스트 구분 문자를 입력해야 합니다. 자세한 정보는 필드 탭의 문서 설정의 내용을 참조하십시오.

**입력 인코딩.** 이 옵션은 텍스트 필드가 **문서의 경로명**을 나타냄을 표시한 경우에만 사용 가능합니다. 기본 텍스트 인코딩을 지정합니다. 모든 언어의 경우, 변환은 지정되거나 인식되는 인코딩에서 ISO-8859-1로 수행됩니다. 따라서 다른 인코딩을 지정하는 경우에도, 추출 엔진은 이 인코딩을 처리 전에 ISO-8859-1로 변환합니다. ISO-8859-1 인코딩 정의에 맞지 않는 문자는 공백으로 변환됩니다.

**텍스트 언어.** 마이닝될 텍스트의 언어를 식별합니다. 이것은 추출 중에 발견되는 기본 언어입니다. 현재 액세스 권한이 없는 지원되는 언어에 대한 라이선스 구매에 관심이 있는 경우 영업 담당자에게 문의하십시오.

#### (4) 개념 모델: 요약 탭

요약 탭은 모델 자체(분석 폴더), 모델에서 사용되는 필드(필드 폴더), 모델을 작성할 때 사용된 설정(작성 설정 폴더), 모델 학습(학습 요약 폴더)에 관한 정보를 제공합니다.

처음 모델링 노드를 찾아볼 때 요약 탭의 폴더는 접혀있습니다. 관심있는 결과를 보려면 폴더 왼쪽에 있는 펼치기 제어를 사용하여 결과를 표시하거나 **모두 확장** 단추를 클릭하여 모든 결과를 표시하십시오. 결과를 본 후에 결과를 숨기려면 펼치기 제어를 사용하여 숨기려는 특정 폴더를 접거나 **모두 접기** 단추를 클릭하여 모든 폴더를 접으십시오.

#### (5) 스트림에서 개념 모델 너깃 사용

텍스트 마이닝 모델링 노드를 사용할 때, 개념 모델 너깃 또는 범주 모델 너깃(대화형 워크벤치 세션을 통해) 중 하나를 생성할 수 있습니다. 다음 예는 단순 스트림에서 개념 모델을 사용하는 방법을 보여줍니다.

##### 예: 개념 모델 너깃을 갖는 통계량 파일 노드

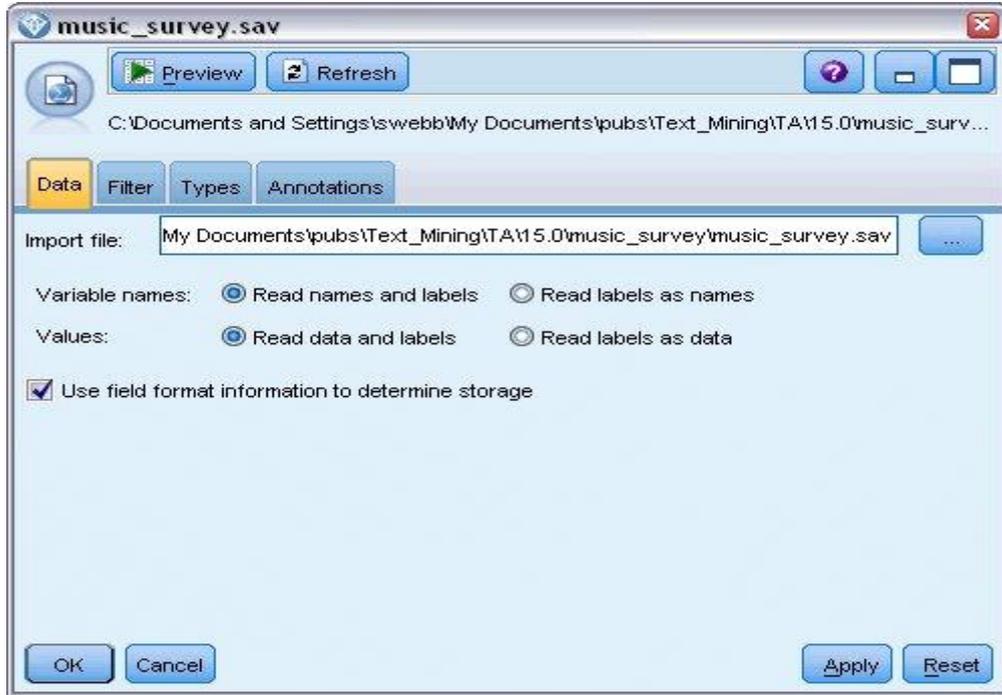
다음 예는 텍스트 마이닝 개념 모델 너깃 사용 방법을 보여줍니다.

그림 1. 예제 스트림: 텍스트 마이닝 개념 모델 너깃을 갖는 통계량 파일 노드



1. 통계량 파일 노드(데이터 탭). 먼저, 이 노드를 스트림에 추가하여 텍스트 문서가 저장되는 장소를 지정했습니다.

그림 2. 통계량 파일 노드 대화 상자: 데이터 탭



2. 텍스트 마이닝 개념 모델 너깃(모델 탭). 다음, 통계량 파일 노드에 개념 모델 너깃을 추가하고 연결했습니다. 데이터를 스코어링하는 데 사용하려는 개념을 선택했습니다.

그림 3. 텍스트 마이닝 모델 너깃 대화 상자: 모델 탭



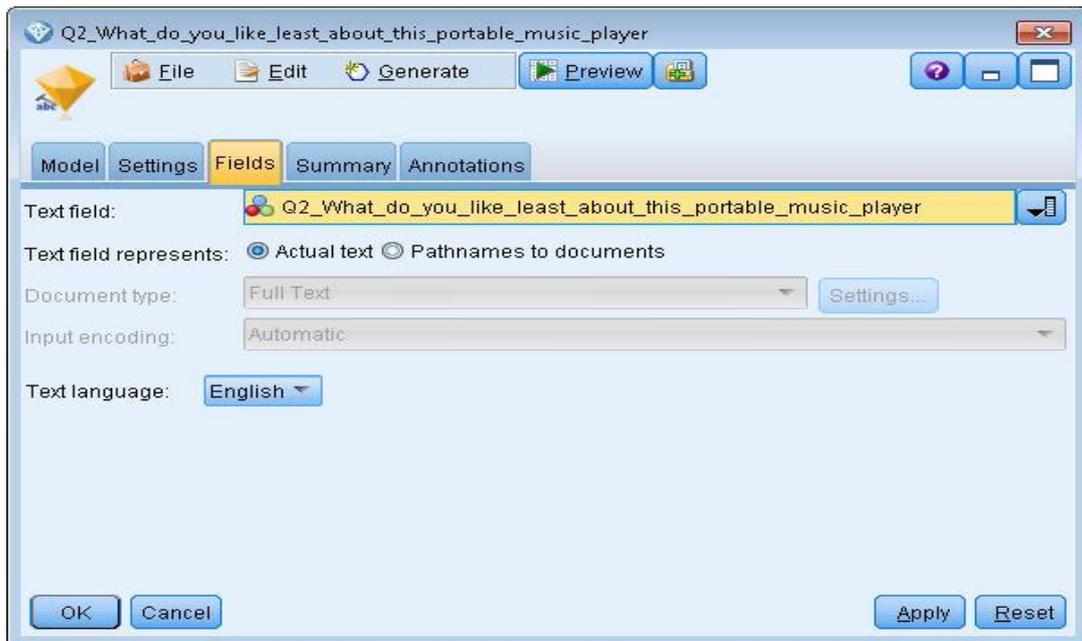
3. 텍스트 마이닝 개념 모델 너깃(설정 탭). 다음, 출력 형식을 정의하고 필드로서의 개념을 선택했습니다. 모델 탭에서 선택되는 각 개념에 대해 하나의 새 필드가 출력에 작성됩니다. 각 필드 이름은 개념 이름과 접두문자 "Concept\_"으로 구성됩니다.

그림 4. 텍스트 마이닝 개념 모델 너깃 대화 상자: 설정 탭



4. 텍스트 마이닝 개념 모델 너깃(필드 탭). 다음, 텍스트 필드 Q2\_What\_do\_you\_like\_least\_about\_this\_portable\_music\_player를 선택했는데, 이것은 통계량 파일 노드에서 온 필드 이름입니다. 또한 텍스트 필드 표시: 실제 텍스트 옵션을 선택했습니다.

그림 5. 텍스트 마이닝 개념 모델 너깃 대화 상자: 필드 탭



5. 테이블 노드. 다음, 테이블 노드를 첨부하여 결과를 보고 스트림을 실행했습니다. 테이블 출력이 화면에 열립니다.

그림 6. 개념 플래그를 표시하기 위해 화면 이동된 테이블 출력

Respondent_ID	Q1	Q2	Concept_reliable	Concept_downloading...	Concept_white color	Concept_limited
1	little, li... expensive		F	F	F	F
2	The ba...	The screen is hard to see when outside.	F	F	F	F
3	cost a...	difficult software	F	F	F	F
4	Having...	Nothing, I love it!	F	F	F	F
5	The sh...	Battery life seems shorter than advertised.	F	F	F	F
6	Batter...	Ubiquitousness; everyone has one.	F	F	F	F
7	I like it...	I wish the 40GB model was still available. I have a 20GB model and need more memory.	F	F	F	F
8	portabi...	it doesn't have a light.	F	F	F	F
9	Small...	Nothing, I love it.	F	F	F	F
10	Able t...	it is in the shop due to a hardware failure.	F	F	F	F
11	It's por...	smudges on the display	F	F	F	F
12	Living i...	Battery life	F	F	F	F
13	mobility	Technical difficulties setting it up initially and managing the library of songs on my PC.	F	F	F	F
14	I like th...	it is a little heavy, and the battery life isn't long enough.	F	F	F	F
15	It hold...	Battery life.	F	F	F	F
16	It's fun...	nothing	F	F	F	F
17	its cool	battery	F	F	F	F
18	lots of ...	it was very expensive	F	F	F	F
19	Others...	I find the controls hard to use.	F	F	F	F
20	lightw...	so small afraid I'll lose it easily	F	F	F	F

### 3) 텍스트 마이닝 너깃: 범주 모델

텍스트 마이닝 범주 모델 너깃은 대화형 워크벤치 안에서 범주 모델을 생성할 때마다 작성됩니다. 이 모델링 너깃은 범주 세트를 포함하고 있는데, 그의 정의는 개념, 유형, TLA 패턴 및/또는 범주 규칙으로 구성됩니다. 너깃은 설문조사 반응, 블로그 항목, 기타 웹 피드, 다른 모든 텍스트 데이터를 범주화하는 데 사용됩니다.

모델링 노드에서 대화형 워크벤치 세션을 시작하는 경우, 범주 모델을 생성하기 전에 추출 결과를 탐색하고 자원을 세분화하고 범주를 미세 조정할 수 있습니다. 텍스트 마이닝 모델 너깃을 포함하는 스트림을 실행할 때, 모델을 작성하기 전에 텍스트 마이닝 모델링 노드의 모델 탭에서 선택된 작성 모드에 따라서 새 필드가 데이터에 추가됩니다. 자세한 정보는 범주 모델 너깃: 모델 탭의 내용을 참조하십시오.

모델 너깃이 변환된 문서를 사용하여 생성된 경우, 스코어링은 변환된 언어로 수행됩니다. 마찬가지로, 모델 너깃이 언어로 영어를 사용하여 생성된 경우, 문서가 영어로 변환되므로 모델 너깃에서 변환 언어를 지정할 수 있습니다.

텍스트 마이닝 모델 너깃은 생성될 때 모델 너깃 팔레트(IBM® SPSS® Modeler 창의 상단 오른쪽에 있는 모델 탭에 있는)에 위치됩니다.

## 결과 보기

모델 너깃에 대한 정보를 보려면, 모델 너깃 팔레트를 마우스 오른쪽 단추로 클릭하고 컨텍스트 메뉴에서 **찾아보기**를(또는 스트림의 노드의 경우 **편집**) 선택하십시오.

## 스트림에 모델 추가

모델 너깃을 스트림에 추가하려면, 모델 너깃 팔레트에서 아이콘을 클릭하고 노드를 위치시키려는 스트림 캔버스를 클릭하십시오. 또는 아이콘을 마우스 오른쪽 단추로 클릭하고 컨텍스트 메뉴로부터 **스트림에 추가**를 선택하십시오. 그리고 나서 노드에 스트림을 연결하십시오. 그러면 예측을 생성하기 위해 데이터를 전달할 준비가 됩니다.

**주의:** 스코어링 너깃을 사용하여 범주 모델 및 사용된 템플릿을 둘 다 포함하는 모델링 노드를 다시 생성하려는 경우, 스코어링 너깃을 생성하기 전에 TAP를 작성하고 이를 모델링 노드 대신 대화형 세션에서 사용할 것을 권장합니다.

### (1) 범주 모델 너깃: 모델 탭

범주 모델의 경우, 모델 탭이 왼쪽에 범주 모델에 있는 범주의 목록을 표시하고 오른쪽에 선택된 범주에 대한 디스크립터를 표시합니다. 각 범주는 많은 디스크립터로 구성됩니다. 사용자가 선택하는 각 범주에 대해, 연관된 디스크립터가 테이블에 나타납니다. 이들 디스크립터는 개념, 범주 규칙, 유형 및 TLA 패턴을 포함할 수 있습니다. 각 디스크립터의 유형뿐 아니라 각 디스크립터가 나타내는 것의 예도 표시됩니다.

이 탭에서 목적은 스코어링에 사용하려는 범주를 선택하는 것입니다. 범주 모델의 경우 문서 및 레코드가 범주로 스코어링됩니다. 문서나 레코드가 텍스트나 임의의 기본 용어에 하나 이상의 디스크립터를 포함하는 경우, 해당 문서나 레코드는 디스크립터가 속하는 범주에 지정됩니다. 이런 기본 용어는 언어학적 자원에서 정의되는 동의어(텍스트에서 발견되었는지 여부는 상관없음) 및 모델 너깃, 순열된 용어, 퍼지 그룹화로부터의 용어 등을 생성하는 데 사용된 텍스트에서 발견되는 모든 추출된 복수형/단수형 용어를 포함합니다.

**참고:** 개념 모델 너깃을 대신 생성한 경우 이 탭은 다른 결과를 포함합니다. 자세한 정보는 개념 모델: 모델 탭의 내용을 참조하십시오.

## 범주 트리

각 범주에 대해 자세히 알려면 해당 범주를 선택하고 해당 범주에 있는 디스크립터에 대해 나타나는 정보를 검토하십시오. 각 디스크립터에 대해 다음 정보를 검토할 수 있습니다.

- **디스크립터 이름.** 이 필드에는 디스크립터의 종류가 무엇인지를 나타내는 아이콘뿐 아니라 디스크립터 이름이 들어 있습니다.

표 1. 디스크립터 아이콘

개념	TLA 패턴
유형	범주 규칙

- **유형.** 이 필드에는 디스크립터의 유형 이름이 들어 있습니다. 유형은 조직 이름, 제품 또는 긍정적인 의견 같이 비슷한 개념의 콜렉션(시맨틱 그룹화)입니다. 규칙은 유형에 지정되지 않습니다.
- **세부사항.** 이 필드에는 해당 디스크립터에 포함되는 것의 목록이 들어 있습니다. 매치의 수에 따라서, 대화 상자에서의 크기 한계로 인해 각 디스크립터에 대한 전체 목록을 보지 못할 수 있습니다.

#### 범주 선택 및 복사

왼쪽 분할창의 선택란에 표시되는 것처럼 기본적으로 모든 최상위 범주가 스코어링을 위해 선택됩니다. 선택된 상자는 범주가 스코어링에 사용될 것임을 의미합니다. 선택되지 않은 상자는 해당 범주가 스코어링에서 제외될 것임을 의미합니다. 복수 행을 선택하고 선택에 있는 선택란 중 하나를 클릭하여 다중 행을 선택할 수 있습니다. 또한, 범주 또는 하위 범주가 선택되지만 그의 하위 범주 중 하나가 선택되지 않은 경우, 선택란은 파란색 배경을 표시하여 선택된 범주의 하위에서 부분 선택만 있음을 표시합니다.

트리에서 범주를 마우스 오른쪽 단추로 클릭하면 다음을 수행할 수 있는 컨텍스트 메뉴를 표시할 수 있습니다.

- **선택 확인.** 테이블에서 선택된 행에 대한 모든 선택란을 선택합니다.
- **선택 취소.** 테이블에서 선택된 행에 대한 모든 선택란을 선택 취소합니다.
- **모두 선택.** 테이블의 모든 선택란을 선택합니다. 그러면 모든 범주가 최종 출력에서 사용됩니다. 또한 도구 모음의 대응하는 선택란 아이콘을 사용할 수도 있습니다.
- **모두 선택 취소.** 테이블의 모든 선택란을 선택 취소합니다. 범주를 선택 취소하는 것은 범주가 최종 출력에서 사용되지 않음을 의미합니다. 도구 모음의 대응하는 빈 선택란 아이콘을 사용할 수도 있습니다.

디스크립터 테이블에서 셀을 마우스 오른쪽 단추로 클릭하여 다음을 수행할 수 있는 컨텍스트 메뉴를 표시할 수 있습니다.

- **복사.** 선택된 개념이 클립보드에 복사됩니다.
- **필드 포함 복사.** 선택된 디스크립터가 열 머리말과 함께 클립보드에 복사됩니다.
- **모두 선택.** 테이블의 모든 행이 선택됩니다.

## (2) 범주 모델 너깃: 설정 탭

설정 탭은 필요한 경우 새 입력 데이터에 대한 텍스트 필드 값을 정의하는 데 사용됩니다. 또한 출력을 위한 데이터 모델을 정의하는 장소입니다(스코어링 모드).

**참고:** 이 탭은 모델 너깃이 캔버스나 스트림에 위치할 때만 노드 대화 상자에 나타납니다. 모델 팔레트에서 직접 이 너깃에 액세스 중일 때는 존재하지 않습니다.

### 스코어링 모드: 필드로서의 범주

이 옵션을 사용하면 입력에 있는 경우 만큼의 출력 레코드가 있습니다. 그러나 각 레코드는 이제 모델 탭에서(선택 표시를 사용하여) 선택된 모든 범주에 대한 하나의 새 필드를 포함합니다. 각 필드에 대해 *Yes/No*, *True/False*, *T/F* 또는 *1* 및 *2* 같이 **True** 및 **False**에 대한 플래그 값을 입력하십시오. 저장 유형은 선택된 값을 반영하도록 자동으로 설정됩니다. 예를 들어, 플래그에 대해 숫자 값을 입력하는 경우 자동으로 정수 값으로 처리됩니다. 플래그의 저장 유형은 문자열, 정수, 실수 또는 날짜/시간입니다.

**참고:** 예를 들어 Db2 데이터베이스에서 매우 큰 데이터 세트를 사용 중인 경우, **필드로서의 범주**를 사용하면 데이터량으로 인해 처리 문제가 발생할 수 있습니다. 이 경우 **레코드로서의 범주**를 대신 사용할 것을 권장합니다.

**필드 이름 확장.** 필드 이름에 대해 확장 접두문자/접미문자를 지정하거나 범주 코드를 사용할 것을 선택할 수 있습니다. 필드 이름은 범주 이름에 이 확장을 더해서 사용하여 생성됩니다.

- **추가 위치.** 확장이 필드 이름에 추가될 위치를 지정하십시오. 확장을 문자열의 시작에 추가하려면 **접두문자**를 선택하십시오. 확장을 문자열의 끝에 추가하려면 **접미문자**를 선택하십시오.

**하위 범주가 선택되지 않은 경우.** 이 옵션으로 스코어링을 위해 선택되지 않은 하위 범주에 속하는 디스크립터가 처리되는 방법을 지정할 수 있습니다. 두 가지 옵션이 있습니다.

- **해당 디스크립터를 스코어링에서 완전히 제외** 옵션은 체크 표시가 없는(선택되지 않은) 하위 범주의 디스크립터가 무시되어 스코어링에서 사용되지 않도록 합니다.
- **디스크립터를 상위 범주에 있는 것과 통합** 옵션은 체크 표시가 없는(선택되지 않은) 하위 범주의 디스크립터가 상위 범주(해당 하위 범주 위의 범주)의 디스크립터로 사용되도록 합니다. 몇 개의 하위 범주 레벨이 선택되지 않은 경우 디스크립터는 첫 번째 사용 가능한 상위 범주 아래에서 롤업됩니다.

**가장 낮은 수준의 일치하는 범주만 스코어.** 범주를 한 개의 단일 행에 출력하려면 이 옵션을 사용하십시오. 예를 들어 범주가 *GeneralSatisfaction/Pos*일 경우 이 옵션을 선택하면 *GeneralSatisfaction/Pos*가 출력됩니다. 이 옵션을 사용하지 않을 경우 *GeneralSatisfaction* 및 *GeneralSatisfaction/Pos*의 두 개 행이 출력됩니다.

구두점 오류를 조정하십시오. 이 옵션은 추출 중에 구두점 오류가 있는 텍스트(예를 들어, 부적절한 사용법)를 일시적으로 표준화하여 개념의 추출 가능성을 향상시킵니다. 이 옵션은 텍스트가 짧고 품질이 저조한 경우(예를 들어, 개방형 설문조사 반응, 이메일 및 CRM 데이터) 또는 텍스트에 많은 약어가 포함된 경우에 특히 유용합니다.

## 스코어링 모드: 레코드로서의 범주

이 옵션을 사용하면 각 범주, 문서 쌍에 대해 새 레코드가 작성됩니다. 일반적으로 출력에는 입력에 있는 것보다 더 많은 레코드가 있습니다. 입력 필드 외에, 모델의 종류에 따라서 데이터에 새 필드도 추가됩니다.

표 1. "레코드로서의 범주"에 대한 출력 필드

새 출력 필드	설명
범주(Category)	텍스트 문서가 지정된 범주 이름이 들어 있습니다. 범주가 다른 범주의 하위 범주인 경우, 범주 이름에 대한 전체 경로는 이 대화 상자에서 선택한 값에 의해 제어됩니다.

**계층 구조 범주의 값.** 이 옵션은 하위 범주의 이름이 출력에 표시되는 방법을 제어합니다.

- **전체 범주 경로.** 이 옵션은 적용 가능한 경우 슬래시를 사용하여 범주 이름을 하위 범주 이름과 구분하여 범주의 이름 및 상위 범주의 전체 경로를 출력합니다.
- **짧은 범주 경로.** 이 옵션은 범주의 이름만 출력하지만 생략 기호를 사용하여 문제가 되는 범주에 대한 상위 범주의 수를 표시합니다.
- **최하위 레벨 범주.** 이 옵션은 전체 경로 또는 상위 범주가 표시되지 않으면서 범주의 이름만 출력합니다.

**하위 범주가 선택되지 않은 경우.** 이 옵션으로 스코어링을 위해 선택되지 않은 하위 범주에 속하는 디스크립터가 처리되는 방법을 지정할 수 있습니다. 두 가지 옵션이 있습니다.

- **해당 디스크립터를 스코어링에서 완전히 제외** 옵션은 체크 표시가 없는(선택되지 않은) 하위 범주의 디스크립터가 무시되어 스코어링에서 사용되지 않도록 합니다.
- **디스크립터를 상위 범주에 있는 것과 통합** 옵션은 체크 표시가 없는(선택되지 않은) 하위 범주의 디스크립터가 상위 범주(해당 하위 범주 위의 범주)의 디스크립터로 사용되도록 합니다. 몇 개의 하위 범주 레벨이 선택되지 않은 경우 디스크립터는 첫 번째 사용 가능한 상위 범주 아래에서 롤업됩니다.

구두점 오류를 조정하십시오. 이 옵션은 추출 중에 구두점 오류가 있는 텍스트(예를 들어, 부적절한 사용법)를 일시적으로 표준화하여 개념의 추출 가능성을 향상시킵니다. 이 옵션은 텍스트가 짧고 품질이 저조한 경우(예를 들어, 개방형 설문조사 반응, 이메일 및 CRM 데이터) 또는 텍스트에 많은 약어가 포함된 경우에 특히 유용합니다.

### (3) 범주 모델 너깃: 기타 탭

범주 모델 너깃에 대한 필드 탭과 설정 탭은 개념 모델 너깃의 경우와 동일합니다.

- 필드 탭. 자세한 정보는 개념 모델: 필드 탭의 내용을 참조하십시오.
- 요약 탭. 자세한 정보는 개념 모델: 요약 탭의 내용을 참조하십시오.

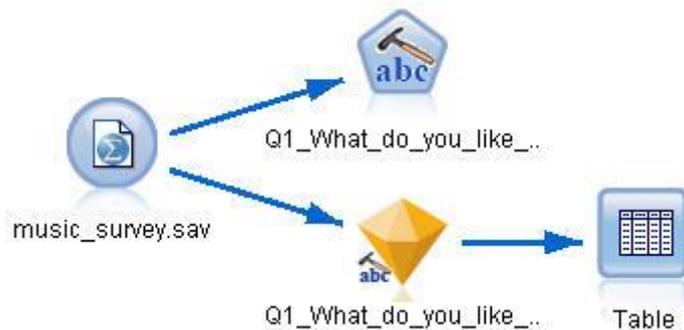
### (4) 스트림에서 범주 모델 너깃 사용

텍스트 마이닝 범주 모델 너깃은 대화형 워크벤치 세션에서 생성됩니다. 스트림에서 이 모델 너깃을 사용할 수 있습니다.

#### 예: 범주 모델 너깃을 갖는 통계량 파일 노드

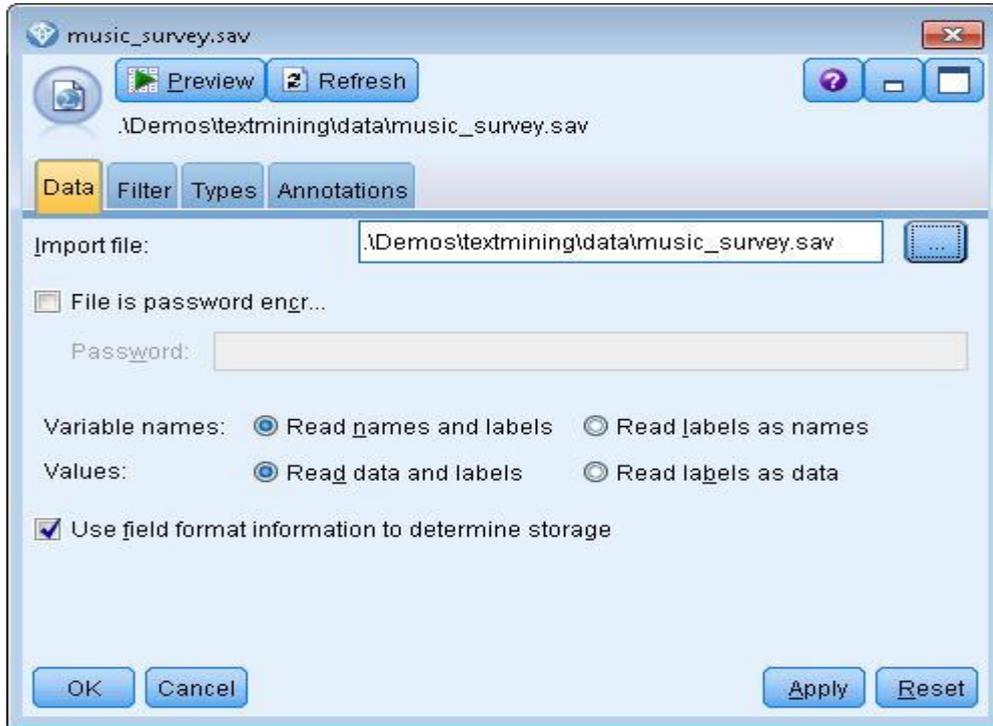
다음 예는 텍스트 마이닝 모델 너깃 사용 방법을 보여줍니다.

그림 1. 예제 스트림: 텍스트 마이닝 범주 모델 너깃을 갖는 통계량 파일 노드



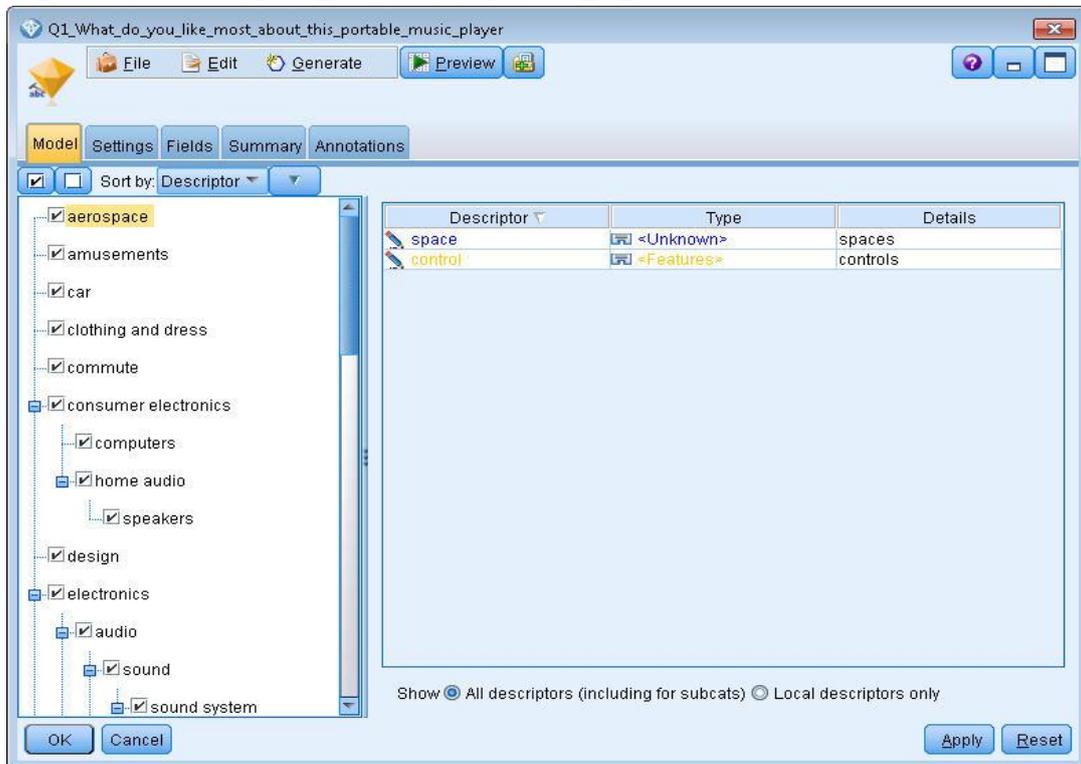
1. 통계량 파일 노드(데이터 탭). 먼저, 이 노드를 스트림에 추가하여 텍스트 문서가 저장되는 장소를 지정했습니다.

그림 2. 통계량 파일 노드 대화 상자: 데이터 탭



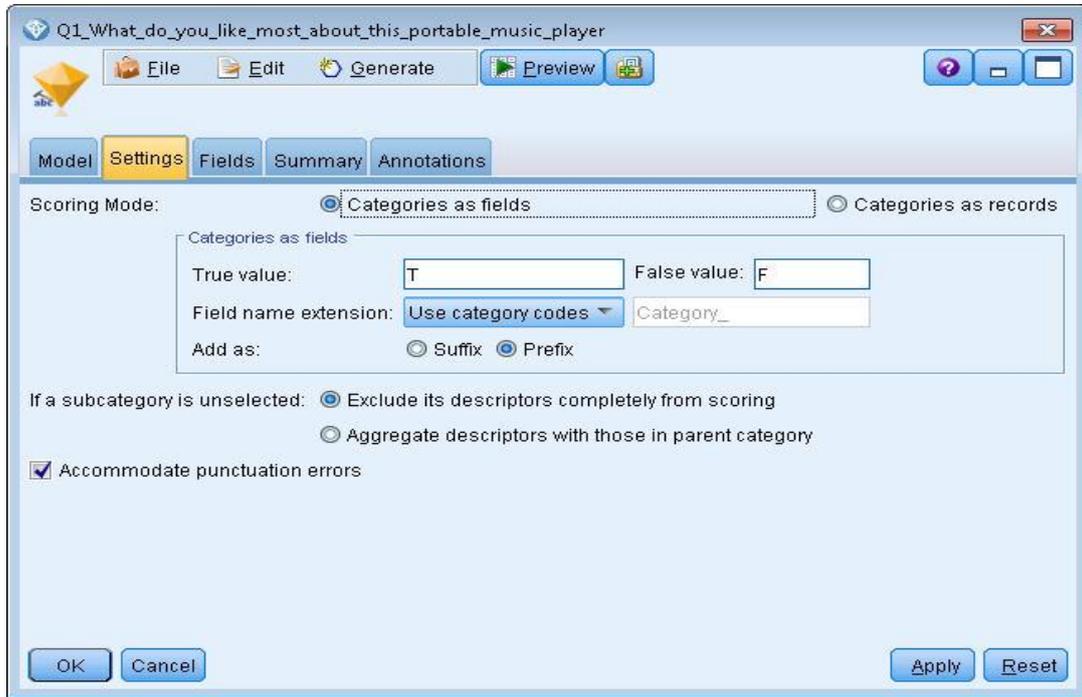
2. 텍스트 마이닝 범주 모델 너깃(모델 탭). 다음, 통계량 파일 노드에 범주 모델 너깃을 추가하고 연결했습니다. 데이터를 스코어링하는 데 사용하려는 범주를 선택했습니다.

그림 3. 텍스트 마이닝 모델 너깃 대화 상자: 모델 탭



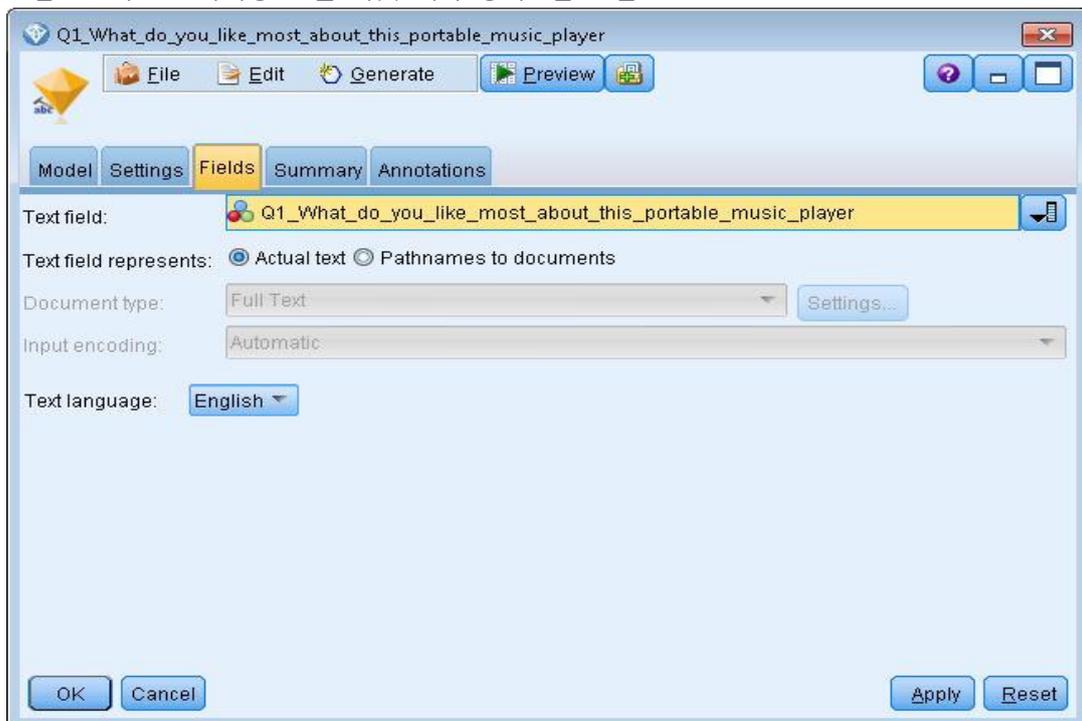
3. 텍스트 마이닝 모델 너깃(설정 탭). 다음, 출력 형식 필드로서의 범주를 정의했습니다.

그림 4. 범주 모델 너깃 대화 상자: 설정 탭



4. 텍스트 마이닝 범주 모델 너깃(필드 탭). 다음, 통계량 파일 노드로부터 오는 필드 이름인 텍스트 필드 변수를 선택했고 옵션 '텍스트 필드가 실제 텍스트를 나타냄' 및 기타 설정을 선택했습니다.

그림 5. 텍스트 마이닝 모델 너깃 대화 상자: 필드 탭



5. 테이블 노드. 다음, 테이블 노드를 첨부하여 결과를 보고 스트림을 실행했습니다.

그림 6. 테이블 출력

ID	Q1_What_do_you_like_most_about_this_portable_music_player	Category
1	little, light	light
2	The battery power is great.	light
3	The battery power is great.	electronics/battery
4	The battery power is great.	electronics
5	cost and size	size
6	Battery life. Portability. Accessories. Style.	light
7	Battery life. Portability. Accessories. Style.	electronics/battery
8	Battery life. Portability. Accessories. Style.	electronics
9	I like its ability to store all of my music. I also like the ability to create playlists.	playlists
10	I like its ability to store all of my music. I also like the ability to create playlists.	light
11	I like its ability to store all of my music. I also like the ability to create playlists.	music
12	portability, capacity, sound quality, durability	light
13	portability, capacity, sound quality, durability	electronics/audio/sound
14	portability, capacity, sound quality, durability	electronics/audio

## 4. 텍스트 링크 마이닝

### 1) 텍스트 링크 분석 노드

텍스트 링크 분석(TLA) 노드는 알려진 패턴을 바탕으로 텍스트에 있는 개념 사이의 관계를 식별하기 위해 텍스트 마이닝의 개념 추출에 패턴 매치 기술을 추가합니다. 이들 관계는 고객이 제품에 대해 어떻게 느끼는지, 어떤 회사가 함께 비즈니스를 수행 중인지, 또는 유전자 또는 약품 사이의 관계를 설명할 수 있습니다.

예를 들어, 경쟁자의 제품 이름을 추출하는 것은 사용자에게 충분히 흥미롭지 않을 수 있습니다. 이 노드를 사용하면 해당 의견이 데이터에 존재하는 경우 사람들이 이 제품에 대해 어떻게 느끼는지를 알 수도 있습니다. 관계 및 연관은 알려진 패턴을 텍스트 데이터에 매치시켜서 식별 및 추출됩니다.

IBM® SPSS® Modeler Text Analytics와 함께 제공되는 특정 자원 템플릿 안에서 TLA 패턴 규칙을 사용하거나 사용자 자신의 규칙을 작성/편집할 수 있습니다. 패턴 규칙은 매크로, 단어 목록 및 단어 간격으로 구성되어 입력 텍스트에 대해 비교되는 부울 쿼리 또는 규칙을 형성합니다. TLA 패턴 규칙이 텍스트와 매치할 때마다, 이 텍스트를 TLA 결과로 추출하고 출력 데이터로 재구성할 수 있습니다. 자세한 정보는 텍스트 링크 규칙에 대한 정보의 내용을 참조하십시오.

텍스트 링크 분석 노드는 텍스트에서 TLA 패턴 결과를 식별 및 추출한 후 스트림의 데이터 세트에 결과를 추가하는 보다 직접적인 방법을 제공합니다. 그러나 텍스트 링크 분석 노드가 텍스트 링크 분석을 수행할 수 있는 유일한 방법은 아닙니다. 또한 텍스트 마이닝 모델링 노드에서 대화형 워크벤치 세션을 사용할 수도 있습니다.

대화형 워크벤치에서, TLA 패턴 결과를 탐색하고 이들을 범주 디스크립터로 사용하거나 드릴다운 및 그래프를 사용하여 결과에 대해 자세히 배울 수 있습니다. 자세한 정보는 텍스트 링크 분석 탐색의 내용을 참조하십시오. 사실, 텍스트 마이닝 노드를 사용하여 TLA 결과를 추출하는 것은 나중에 TLA 노드에서 직접 사용하기 위해 템플릿을 탐색하고 데이터에 대해 미세 조정하는 좋은 방법입니다.

출력은 최대 6개의 슬롯 또는 패턴으로 표현될 수 있습니다. 자세한 정보는 TLA 노드 출력의 내용을 참조하십시오.

IBM SPSS Modeler 창의 맨 아래에 있는 노드 팔레트의 IBM SPSS Modeler Text Analytics 탭에서 이 노드를 찾을 수 있습니다. 자세한 정보는 IBM SPSS Modeler Text Analytics 노드의 내용을 참조하십시오.

**요구사항.** 텍스트 링크 분석 노드는 표준 소스 노드(데이터베이스 노드, 플랫폼 파일 노드 등) 중 하나를 사용하여 필드로 읽어들이거나 파일 목록 노드나 웹 피드 노드에 의해 생성된 외부 문서에 대한 경로를 나열하는 필드로 읽어들이는 텍스트 데이터를 수락합니다.

**강도.** 텍스트 링크 분석 노드는 개념 *사이*의 관계뿐 아니라 데이터에서 드러날 수 있는 관련된 의견이나 규정자에 관한 정보를 제공하기 위해 기본 개념 추출을 초과합니다.

### (1) 텍스트 링크 분석 노드: 필드 탭

개념을 추출 중인 데이터에 대한 필드 설정을 지정하려면 필드 탭을 사용하십시오. 다음 매개변수를 설정할 수 있습니다.

**ID 필드.** 텍스트 레코드의 식별자를 포함하는 필드를 선택하십시오. 식별자는 정수여야 합니다. ID 필드는 개별 텍스트 레코드에 대한 색인 역할을 수행합니다. 텍스트 필드가 마이닝될 텍스트를 나타내는 경우 ID 필드를 사용하십시오.

**텍스트 필드.** 마이닝할 텍스트를 포함하는 필드를 선택하십시오. 이 필드는 데이터 소스에 따라 다릅니다.

**언어 필드.** 두 문자로 구성된 ISO 언어 식별자를 포함하는 필드를 선택하십시오. 필드를 선택하지 않으면 각 문서의 언어가 제공되는 템플릿의 언어인 것으로 간주됩니다.

**문서 유형.** 문서 유형은 텍스트의 구조를 지정합니다. 다음 유형 중 하나를 선택하십시오.

- **전체 텍스트.** 대부분의 문서 또는 텍스트 소스에 대해 사용합니다. 추출을 위해 전체 텍스트 세트가 스캔됩니다. 다른 옵션과 달리, 이 옵션의 추가 설정은 없습니다.
- **구조화된 텍스트.** 식별하고 분석할 수 있는 일반 구조를 포함하는 파일, 서지 목록 양식 및 특허에 사용됩니다. 이 문서 유형은 추출 프로세스의 일부 또는 전체를 건너뛰기 위해 사용됩니다. 이 문서 유형을 사용하여 항 구분 문자를 정의하고, 유형을 지정하며, 최소 빈도 값을 부과할 수 있습니다. 이 옵션을 선택하면, 설정 단추를 클릭하고 문서 설정 대화 상자의 구조화된 텍스트 형식 영역에서 텍스트 구분 문자를 입력해야 합니다. 자세한 정보는 필드 탭의 문서 설정의 내용을 참조하십시오.

**텍스트 통합.** 다음에서 추출 모드를 선택하십시오.

- **문서 모드.** 간단하고 의미적으로 동일한 문서(예: 통신사의 기사)에 사용합니다.
- **단락 모드.** 웹 페이지와 태그가 없는 문서에 사용합니다. 추출 프로세스는 내부 태그 및 구문과 같은 특성을 이용하여 문서를 의미적으로 나눕니다. 이 모드가 선택되는 경우, 스코어링은 단락별로 적용됩니다. 따라서, 예를 들어 apple 및 orange가 동일한 단락에서 발견되는 경우에만 apple & orange 규칙은 true입니다.

 **참고:** 텍스트가 PDF 문서에서 추출되는 방식으로 인해, 단락 모드는 이러한 문서에 대해 작동하지 않습니다. 이는 추출이 캐리지 리턴 표식을 억제하기 때문입니다.

**단락 모드 설정.** 이 옵션은 텍스트 통합 옵션을 단락 모드로 설정한 경우에만 사용할 수 있습니다. 추출에서 사용할 문자 임계값을 지정하십시오. 실제 크기는 가장 가까운 마침표로 반올림 또는 반내림됩니다. 문서 컬렉션의 텍스트에서 생성되는 단어 연관이 대표적이 되도록 하려면 너무 작은 추출 크기를 지정하지 않도록 하십시오.

- **최소.** 추출에서 사용될 최소 문자 수를 지정하십시오.
- **최대값.** 추출에서 사용될 최대 문자 수를 지정하십시오.

**자원 복사 출처.** 텍스트를 마이닝할 때, 추출은 전문가 탭의 설정뿐 아니라 언어학적 자원도 기반으로 합니다. 이들 자원은 개념, 유형 및 TLA 패턴을 얻기 위해 추출 중에 텍스트를 처리 및 취급하는 방법의 기초로 작용합니다. 자원 템플릿으로부터 이 노드로 자원을 복사할 수 있습니다.

자원 템플릿은 라이브러리 및 특정 도메인이나 사용법을 위해 미세 조정된 고급 언어 및 비언어학적 자원의 사전 정의된 세트입니다. 이들 자원은 추출 중에 데이터를 취급 및 처리하는 방법에 대한 기초로 작용합니다. 로드를 클릭하고 자원을 복사할 템플릿을 선택하십시오.

템플릿은 스트림이 실행될 때가 아니라 사용자가 템플릿을 선택할 때 로드됩니다. 로드하는 순간에 자원의 사본이 노드에 저장됩니다. 그러므로 업데이트된 템플릿을 사용하기 위한 경우 여기에서 재로드할 필요가 있습니다. 자세한 정보는 템플릿 및 TAP에서 자원 복사의 내용을 참조하십시오.

**텍스트 언어.** 마이닝할 텍스트의 언어를 식별합니다. 노드에서 복사된 자원은 제시된 언어 옵션을 제어합니다. 자원이 조정된 언어를 선택하십시오.

## (2) 텍스트 링크 분석 노드: 전문가 탭

이 노드에서 텍스트 링크 분석(TLA) 패턴 결과의 추출이 자동으로 사용 가능합니다. 전문가 탭에는 텍스트가 추출되고 처리되는 방법에 영향을 주는 특정한 추가 매개변수가 들어 있습니다. 이 대화 상자의 매개변수는 추출 프로세스의 기본 작동뿐 아니라 몇 가지 고급 작동을 제어합니다. 또한 추출 결과에 영향을 미치는 많은 언어학적 자원 및 옵션이 있는데, 이것은 사용자가 선택하는 자원 템플릿에 의해 제어됩니다.

**최소한 [n] 전역 빈도를 사용하는 개념으로 추출 제한.** 텍스트의 단어 또는 구문이 추출되기 위해 최소한 발생해야 하는 횟수를 지정합니다. 이 방식에서, 값 5는 전체 레코드 또는 문서 세트에서 최소 5번 발생하는 단어 또는 구문으로 추출을 제한합니다.

일부 경우에, 이 한계를 변경하여 추출 결과와 결국 범주에 큰 차이가 발생할 수 있습니다. 식당 데이터에 대해 작업할 때 이 옵션에 대해 1 이상으로 한계를 증가시키지 마십시오. 이러한 경우, 추출 결과에서 *피자(1)*, *썸 피자(2)*, *시금치 피자(2)*, *즐거먹는 피자(2)*를 볼 수 있습니다. 그러나 추출을 전역 빈도 5 이상으로 제한하고 다시 추출하면, 더 이상 이 세 개의 개념을 얻을 수 없습니다. 대신 *피자(7)*를 얻게 됩니다. *피자*는 가장 단순한 양식이고 이 단어는 이미 가능한 후보로 존재하고 있기 때문입니다. 텍스트의 나머지에 따라서, 텍스트에 피자가 있는 다른 구문이 계속 있는지 여부에 따라 실제로 8 이상의 빈도를 가질 수 있습니다. 또한 *시금치 피자*가 이미 범주 디스크립터인 경우, 모든 레코드를 캡처하는 대신 *피자*를 디스크립터로 추가해야 할 수 있습니다. 이러한 이유로, 범주가 이미 작성된 경우에는 항상 주의하여 이 한계를 변경하십시오.

이는 추출 전용 기능입니다. 템플릿에 용어(보통 수행되는)가 있고 템플릿에 대한 용어가 텍스트에서 발견되는 경우, 용어는 해당 빈도에 관계없이 색인화됩니다.

예를 들어, 코어 라이브러리에서 <Location> 유형 아래에 "los angeles"를 포함하는 기본 자원 템플릿을 사용한다고 가정하십시오. 문서에 Los Angeles가 한 번만 포함되면, Los Angeles는 개념 목록의 일부가 됩니다. 이를 방지하기 위해서는 **최소한 [n] 전역 빈도를 사용하는 개념으로 추출 제한** 필드에 입력한 값과 동일한 횟수만큼 발생하는 개념을 표시하도록 필터를 설정해야 합니다.

**구두점 오류를 조정하십시오.** 이 옵션은 추출 중에 구두점 오류가 있는 텍스트(예를 들어, 부적절한 사용법)를 일시적으로 표준화하여 개념의 추출 가능성을 향상시킵니다. 이 옵션은 텍스트가 짧고 품질이 저조한 경우(예를 들어, 개방형 설문조사 반응, 이메일 및 CRM 데이터) 또는 텍스트에 많은 약어가 포함된 경우에 특히 유용합니다.

**최소 단어 문자 길이([n])에 대한 맞춤법 수용** 이 옵션은 맞춤법이 자주 틀리는 단어나 맞춤법이

유사한 단어를 하나의 개념으로 그룹화하는 퍼지 그룹화 기술을 적용합니다. 퍼지 그룹화 알고리즘은 일시적으로 모든 모음(맨 처음 것은 제외)을 지우고 추출된 단어에서 이중/삼중 자음을 지운 다음 modeling과 modelling이 함께 그룹화될 수 있도록 이들이 동일하지 비교합니다. 그러나 각 용어가 <Unknown> 유형을 제외하고 서로 다른 유형에 지정된 경우에는 퍼지 그룹화 기술은 적용되지 않습니다.

퍼지 그룹화를 사용하기 전에 필요한 루트 문자의 최소 수를 정의할 수도 있습니다. 용어에서 루트 문자의 수는 모든 문자를 합한 후 굴절접사를 형성하는 문자와 복합어의 경우에는 한정사 및 전치사를 형성하는 문자를 빼서 계산합니다. 예를 들어, exercises 용어는 "exercise" 양식의 8개 루트 문자가 있는 것으로 간주됩니다. 단어 끝의 s자는 굴절(복수형)이기 때문입니다. 마찬가지로, apple sauce는 10개의 루트 문자로 간주되고("apple sauce") manufacturing of cars는 16개의 루트 문자("manufacturing car")로 간주됩니다. 이 계산 방법은 퍼지 그룹화를 적용해야 하는지 여부를 확인하는 데에만 사용되고 단어가 매치하는 방법에는 영향을 미치지 않습니다.

**참고:** 특정 단어가 나중에 잘못 그룹화되는 경우에는 이를 고급 자원 탭의 **퍼지 그룹화: 예외** 섹션에 명시적으로 선언하여 이 기술에서 단어 쌍을 제외할 수 있습니다. 자세한 정보는 퍼지 그룹화의 내용을 참조하십시오.

**단일어 추출** 이 옵션은 단어가 복합어의 일부가 아니거나 명사이거나 인식되지 않은 품사인 경우에만 단일어를 추출합니다.

**비언어 엔티티 추출** 이 옵션은 전화 번호, 주민등록번호, 시간, 날짜, 통화, 숫자, 백분율, 이메일 주소 및 HTTP 주소 등과 같은 비언어 엔티티를 추출합니다. 고급 자원 탭의 **비언어 엔티티: 구성** 섹션에서 비언어 엔티티의 특정 유형을 포함하거나 제외할 수 있습니다. 불필요한 엔티티를 사용 안함으로 설정하면 추출 엔진은 처리 시간을 낭비하지 않습니다. 자세한 정보는 구성의 내용을 참조하십시오.

**대문자 알고리즘** 이 옵션은 용어의 첫 글자가 대문자인 한 내장된 사전에 없는 단순 및 복합어를 추출합니다. 이 옵션은 가장 적합한 명사를 추출하기 위한 좋은 방법을 제공합니다.

**가능한 경우 부분 및 전체 사람 이름을 함께 그룹화** 이 옵션은 텍스트에 다르게 나타나는 이름을 그룹화합니다. 이름은 종종 시작부에는 전체 이름이 언급되고 나중에는 약어로만 표시되기 때문에 이 기능이 유용합니다. 이 옵션은 <Unknown> 유형의 단일어를 <Person>으로 입력되는 복합어와 매치시키려고 시도합니다. 예를 들어, doe가 있고 처음에는 <Unknown>으로 입력되는 경우에는, 추출 엔진은 <Person> 유형에 있는 복합어가 doe를 마지막 단어로 포함하는지 여부를 확인합니다(예: john doe). 이 옵션은 이름에는 적용되지 않습니다. 이름의 대부분은 단일어로 추출되지 않기 때문입니다.

**최대 비기능 단어 순열** 이 옵션은 순열 기술을 적용할 때 존재할 수 있는 비기능 단어 최대 수를 지정합니다. 이 순열 기술은 서로 굴절과는 관계없이 포함된 비기능 단어(예: of 및 the)만 다른 유사한 구를 그룹화합니다. 예를 들어, 이 값을 최소 두 개의 단어로 설정하고 company officials 및 officials of the company 둘 모두가 추출되었다고 해 봅시다. 이 경우, 추출된 두

용어는 모두 마지막 개념 목록에 그룹화됩니다. 두 용어 모두 of the가 무시될 때 동일한 것으로 간주되기 때문입니다.

다항어를 그룹화할 때 파생 사용 빅 데이터를 처리할 때 파생 규칙을 사용하여 다항어를 그룹화하려면 이 옵션을 선택하십시오.

### (3) TLA 노드 출력

텍스트 링크 분석 노드를 실행한 후 데이터가 구조변환됩니다. 텍스트 마이닝이 데이터를 구조변환하는 방법을 이해하는 것이 중요합니다. 데이터 마이닝을 위해 다른 구조를 원하는 경우, 필드 작업 팔레트의 노드를 사용하여 이를 수행할 수 있습니다. 예를 들어, 각 행이 텍스트 레코드를 나타낸 데이터에 대해 작업 중인 경우, 소스 텍스트 데이터에서 발견되는 각 패턴에 대해 한 행이 작성됩니다. 출력의 각 행에 대해 15개의 필드가 있습니다.

- 6개 필드(Concept1, Concept2, ..., Concept6 같은 Concept#)는 패턴 매치에서 발견되는 모든 개념을 나타냅니다.
- 6개 필드(Type1, Type2, ..., Type6 같은 Type#)는 각 개념에 대한 유형을 나타냅니다.
- 규칙 이름은 텍스트와 매치하고 출력을 생성하는 데 사용되는 텍스트 링크 규칙의 이름을 나타냅니다.
- 노드에서 사용자가 지정한 ID 필드의 이름을 사용하고 레코드 또는 문서 ID를 입력 데이터에 있었던 대로 나타내는 필드
- 매치된 텍스트는 TLA 패턴에 매치된 원래 레코드나 문서에 있는 텍스트 데이터의 부분을 나타냅니다.

**참고:** 5.0 이전 릴리스의 텍스트 링크 분석 노드를 포함하는 미리 존재하는 모든 스트림은 사용자가 노드를 업데이트할 때까지 완전히 실행 가능하지 않을 수 있습니다. IBM® SPSS® Modeler의 최신 버전에서의 특정 개선은 이전 노드가 최신 버전으로 대체되어야 하며, 이것은 배치 가능하면서 더욱 강력합니다.

또한 특정 언어의 자동 변환을 수행할 수도 있습니다. 이 기능은 사용자가 말하거나 읽을 수 없는 언어로 된 문서를 마이닝할 수 있게 합니다. 변환 기능을 사용하려는 경우, SDL SaaS(Software as a Service)에 대한 액세스 권한이 있어야 합니다. 자세한 정보는 변환 설정 주제를 참조하십시오.

### (4) TLA 결과 캐싱

캐시하는 경우 텍스트 링크 분석 결과는 스트림에 있습니다. 스트림이 실행될 때마다 텍스트 링크 분석 결과의 추출 반복을 피하려면 텍스트 링크 분석 노드를 선택하고 메뉴에서 편집 > 노드 > 캐시 > 사용을 선택하십시오. 다음에 스트림이 실행될 때 출력이 노드에 캐시됩니다. 노드 아이콘은 캐시가 채워질 때 흰색에서 녹색으로 변하는 작은 "문서" 그래픽을 표시합니다. 캐시는

세션의 기간 동안 유지됩니다. 다른 날(스트림이 닫히고 다시 열린 후)을 위해 캐시를 유지하려면 노드를 선택한 후 메뉴에서 편집 > 노드 > 캐시 > 캐시 저장을 선택하십시오. 다음에 스트림을 열 때, 변환을 다시 실행하지 않고 저장된 캐시를 다시 로드할 수 있습니다.

또는 노드를 마우스 오른쪽 단추로 클릭하고 컨텍스트 메뉴에서 캐시를 선택하여 노드 캐시를 저장 또는 사용으로 설정할 수 있습니다.

### (5) 스트림에서 텍스트 링크 분석 노드 사용

텍스트 링크 분석 노드는 데이터에 액세스하고 스트림에서 개념을 추출하는 데 사용됩니다. 임의의 소스 노드를 사용하여 데이터에 액세스할 수 있습니다.

### 예: 텍스트 링크 분석 노드를 갖는 통계량 파일 노드

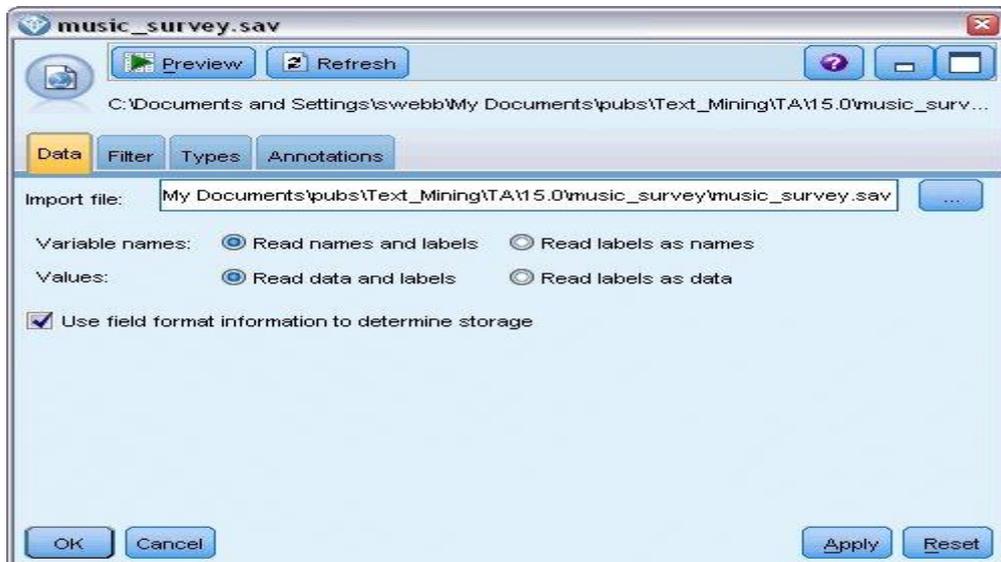
다음 예는 텍스트 링크 분석 노드 사용 방법을 보여줍니다.

그림 1. 예: 텍스트 링크 분석 노드를 갖는 통계량 파일 노드



1. 통계량 파일 노드(데이터 탭). 먼저, 이 노드를 스트림에 추가하여 텍스트가 저장되는 위치를 지정했습니다.

그림 2. 통계량 파일 노드 대화 상자: 데이터 탭



2. **텍스트 링크 분석 노드(필드 탭).** 다음, 다운스트림 모델링 또는 보기를 위한 개념을 추출하기 위해 스트림에 이 노드를 첨부했습니다. ID 필드 및 데이터를 포함하는 텍스트 필드 이름 뿐 아니라 다른 설정도 지정했습니다.

그림 3. 텍스트 링크 분석 노드 대화 상자: 필드 탭



3. **테이블 노드.** 마지막으로, 텍스트 문서에서 추출된 개념을 보기 위해 테이블 노드를 첨부했습니다. 표시된 테이블 출력에서, 이 스트림이 텍스트 링크 분석 노드를 사용하여 실행된 후 데이터에서 발견된 TLA 패턴 결과를 볼 수 있습니다. 일부 결과는 단 하나의 개념/유형이 매치되었음을 표시합니다. 다른 경우에는 결과가 더 복잡하고 여러 가지 유형 및 개념을 포함합니다. 또한, 텍스트 링크 분석 노드를 통해 데이터를 실행하고 개념을 추출한 결과로 데이터의 여러 측면이 변경됩니다. 본 예제의 원 데이터는 8개 필드와 405개의 레코드를 포함했습니다. 텍스트 링크 분석 노드를 실행한 후 이제는 15개 필드와 640개 레코드가 있습니다. 이제 발견된 각 TLA 패턴 결과에 대한 한 행이 있습니다. 예를 들어, 세 개의 TLA 패턴 결과가 추출되었기 때문에 ID 7은 원본에서 세 행이 되었습니다. 이 출력 데이터를 다시 원 데이터에 병합하려는 경우 병합 노드를 사용할 수 있습니다.

그림 4. 테이블 출력 노드

	Concept1	Type1	Concept2	Type2	Conc...	Type3	Con...	Type4	Conc...	Type5	Con...	Type6	Rule Number	ID	Matched Text
1	expensive	NegativeBudget	Null	Null	Null	Null	Null	Null	Null	Null	Null	Null	0.0350_opinion	1	<expensive>
2	screen	Unknown	difficult	Nega...	Null	Null	Null	Null	Null	Null	Null	Null	0.0145_topic + opinion	2	The <screen> is <hard> to see when outside
3	software	Unknown	difficult	Nega...	Null	Null	Null	Null	Null	Null	Null	Null	0.0211_opinion + topic	3	<difficult> <software>
4	nothing	Uncertain	Null	Null	Null	Null	Null	Null	Null	Null	Null	Null	0.0153_topic/opinion	4	<Nothing> <I love it>
5	like	Positive	Null	Null	Null	Null	Null	Null	Null	Null	Null	Null	0.0350_opinion	4	Nothing, <I love it>
6	battery life	Unknown	too long	Nega...	Null	Null	Null	Null	Null	Null	Null	Null	0.0145_topic + opinion	5	<Battery life> seems <shorter> than advertised
7	ubiquitousness	Unknown	Null	Null	Null	Null	Null	Null	Null	Null	Null	Null	0.0500_topic	6	<Ubiquitousness>
8	40gb model	Unknown	available	Positi...	Null	Null	Null	Null	Null	Null	Null	Null	0.0145_topic + opinion	7	I wish the <40GB model> was still <available>
9	20gb model	Unknown	Null	Null	Null	Null	Null	Null	Null	Null	Null	Null	0.0102_topic + Negative + topic	7	I have a <20GB model> and <need more> <memory>
10	memory	Unknown	need more	Nega...	Null	Null	Null	Null	Null	Null	Null	Null	0.0102_topic + Negative + topic	7	I have a <20GB model> and <need more> <memory>

## 5. 외부 소스 텍스트 찾아보기

### 1) 파일 뷰어 노드

문서 컬렉션을 마이닝하고 있을 때, 파일의 전체 경로 이름을 텍스트 마이닝 모델링 노드에 직접 지정할 수 있습니다. 그러나, 테이블 노드로 출력할 때 그 안에 있는 텍스트가 아니라 문서의 전체 경로 이름만 표시됩니다. 파일 뷰어 노드는 테이블 노드와 유사하게 사용될 수 있으며 이 노드를 사용하여 모두를 단일 파일로 병합할 필요 없이 각 문서 내의 실제 텍스트에 액세스할 수 있습니다.

파일 뷰어 노드는 개념이 추출된 소스 또는 변환되지 않은 텍스트에 대한 액세스 권한을 제공함으로써 텍스트 추출의 결과를 더 잘 이해하는 데 도움을 줄 수 있습니다. 그렇지 않으면 스트림에서 액세스할 수 없기 때문입니다. 이 노드는 모든 파일에 대한 링크의 목록을 얻기 위해 파일 목록 노드 뒤에서 스트림에 추가됩니다.

이 노드의 결과는 개념을 추출하기 위해 읽고 사용한 모든 문서 요소를 표시하는 창입니다. 이 창에서 도구 모음 아이콘을 클릭하여 문서 이름을 하이퍼링크로 나열하는 외부 브라우저에서 보고서를 실행할 수 있습니다. 링크를 클릭하여 컬렉션의 대응하는 문서를 열 수 있습니다. 자세한 정보는 파일 뷰어 노드 사용의 내용을 참조하십시오.

IBM® SPSS® Modeler 창의 맨 아래에 있는 노드 팔레트의 IBM SPSS Modeler Text Analytics 탭에서 이 노드를 찾을 수 있습니다. 자세한 정보는 IBM SPSS Modeler Text Analytics 노드의 내용을 참조하십시오.

**참고:** 클라이언트-서버 모드에서 작업 중이고 파일 뷰어 노드가 스트림의 일부일 때, 문서 컬렉션이 서버의 웹 서버 디렉토리에 저장되어야 합니다. 텍스트 마이닝 출력 노드가 웹 서버 디렉토리에 저장되는 문서의 목록을 생성하므로, 웹 서버의 보안 설정이 이들 문서에 대한 권한을 관리합니다.

## (1) 파일 뷰어 노드 설정

파일 뷰어 노드에 대한 다음 설정을 지정할 수 있습니다.

문서 필드, 표시될 문서의 전체 이름 및 경로를 포함하는 데이터에서 필드를 선택하십시오.

생성된 HTML 페이지에 대한 제목, 문서의 목록을 포함하는 페이지의 맨 위에 나타날 제목을 작성하십시오.

## (2) 파일 뷰어 노드 사용

다음 예는 파일 뷰어 노드 사용법을 보여줍니다.

### 예: 파일 목록 노드 및 파일 뷰어 노드

그림 1. 파일 뷰어 노드의 사용을 설명하는 스트림



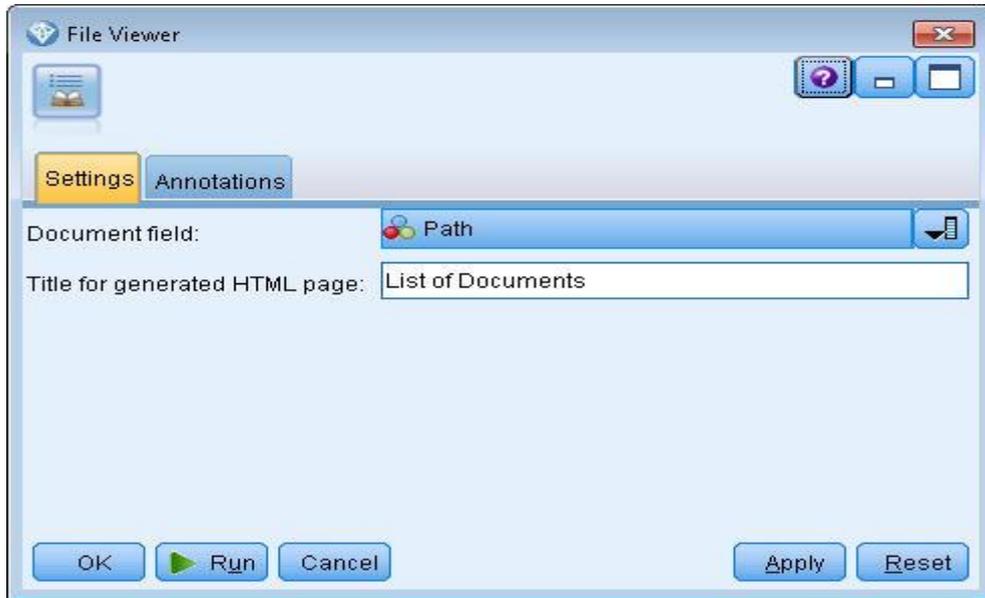
1. 파일 목록 노드(설정 탭). 먼저, 문서가 위치하는 장소를 지정하기 위해 이 노드를 추가했습니다.

그림 2. 파일 목록 노드 대화 상자: 설정 탭



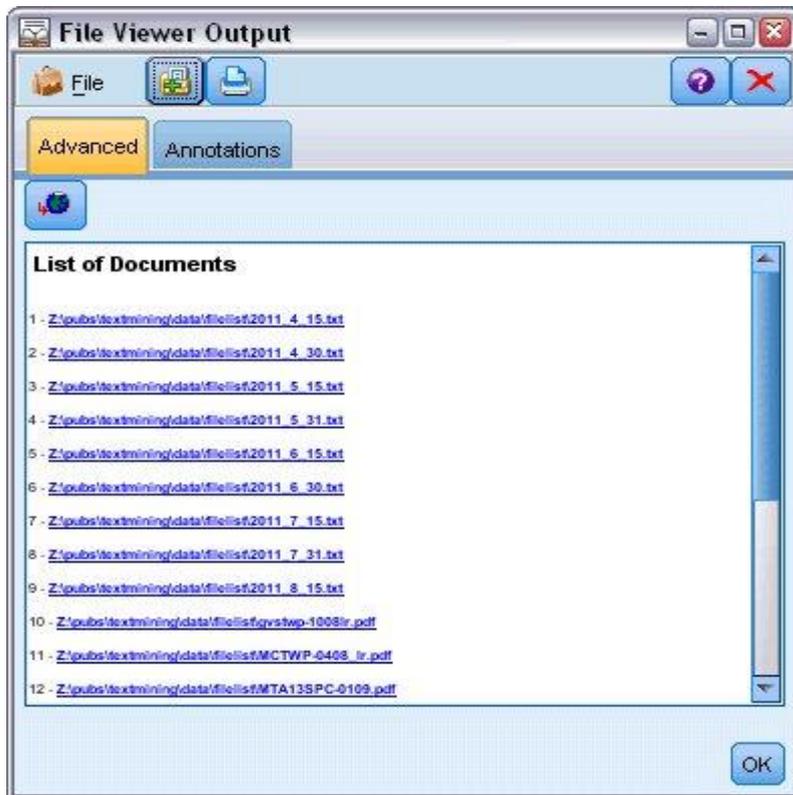
2. 파일 뷰어 노드(설정 탭). 다음, 파일 뷰어 노드를 첨부하여 문서의 HTML 목록을 생성했습니다.

그림 3. 파일 뷰어 노드 대화 상자: 설정 탭



3. 파일 뷰어 출력 대화 상자. 다음, 문서 목록을 새 창에서 출력하는 스트림을 실행했습니다.

그림 4. 파일 뷰어 출력



4. 문서를 보기 위해 빨간색 화살표를 갖는 지구본을 표시하는 도구 모음 단추를 클릭했습니다. 이것은 브라우저에 문서 하이퍼링크의 목록을 열었습니다.

## 6. 스크립팅을 위한 노드 특성

IBM® SPSS® Modeler는 명령행에서 스트림을 실행할 수 있게 하는 스크립팅 언어를 갖고 있습니다. 여기에서 IBM SPSS Modeler Text Analytics와 함께 제공되는 각 노드에 특정한 노드 특성에 대해 배울 수 있습니다. IBM SPSS Modeler와 함께 제공되는 표준 노드 세트에 대한 자세한 정보는 스크립팅 및 자동화 안내서를 참조하십시오.

### 1) 파일 목록 노드: filelistnode

스크립팅에 대해 다음 표의 특성을 사용할 수 있습니다. 노드 자체는 filelistnode라고 부릅니다.

표 1. 파일 목록 노드 스크립팅 특성	
스크립팅 특성	데이터 유형
path	<i>string</i>
recurse	<i>flag</i>
word_processing	<i>flag</i>
excel_file	<i>flag</i>
powerpoint_file	<i>flag</i>
text_file	<i>flag</i>
web_page	<i>flag</i>
xml_file	<i>flag</i>
pdf_file	<i>flag</i>
no_extension	<i>flag</i>

참고: '목록 작성' 매개변수는 더 이상 사용할 수 없으며 해당 옵션을 포함하는 모든 스크립트는 자동으로 '파일' 출력으로 변환됩니다.

### 2) 웹 피드 노드: webfeednode

스크립팅에 대해 다음 표의 특성을 사용할 수 있습니다. 노드 자체를 webfeednode라고 합니다.

표 1. 웹 피드 노드 스크립팅 특성

스크립팅 특성	데이터 유형	특성 설명
urls	<i>string1 string2 ...stringn</i>	각 URL은 목록 구조로 지정됩니다. URL 목록은 “Wn”으로 구분됩니다.
recent_entries	<i>flag</i>	
limit_entries	<i>integer</i>	URL마다 읽을 최근 항목 수.
use_previous	<i>flag</i>	웹 피드 캐시를 저장하고 재사용합니다.
use_previous_label	<i>string</i>	저장된 웹 캐시의 이름.
start_record	<i>string</i>	비RSS 시작 태그.
url <i>n</i> .title	<i>string</i>	목록에서 각 URL에 대해, 여기에서도 정의해야 합니다. 첫 번째는 url1.title입니다. 숫자는 URL 목록에서 해당 위치와 매치됩니다. 이는 내용의 제목을 포함하는 시작 태그입니다.
url <i>n</i> .short_description	<i>string</i>	url <i>n</i> .title의 경우와 같습니다.
url <i>n</i> .description	<i>string</i>	url <i>n</i> .title의 경우와 같습니다.
url <i>n</i> .authors	<i>string</i>	url <i>n</i> .title의 경우와 같습니다.
url <i>n</i> .contributors	<i>string</i>	url <i>n</i> .title의 경우와 같습니다.
url <i>n</i> .published_date	<i>string</i>	url <i>n</i> .title의 경우와 같습니다.
url <i>n</i> .modified_date	<i>string</i>	url <i>n</i> .title의 경우와 같습니다.
html_alg	None HTMLCleaner	내용 필터링 방법.
discard_lines	<i>flag</i>	짧은 행을 삭제합니다. min_words와 함께 사용됩니다.
min_words	<i>integer</i>	최소 단어 수.
discard_words	<i>flag</i>	짧은 행을 삭제합니다. min_avg_len과 함께 사용됩니다.
min_avg_len	<i>integer</i>	
discard_scw	<i>flag</i>	많은 단일 문자 단어가 있는 행을 삭제합니다. max_scw와 함께 사용됩니다.
max_scw	<i>integer</i>	행에서 단일 문자 단어의 최대 비율 0-100 퍼센트
discard_tags	<i>flag</i>	특정 태그를 포함하는 행을 삭제합니다.
tags	<i>string</i>	특수 문자는 백슬래시 문자 w로 이스케이프해야 합니다.
discard_spec_words	<i>flag</i>	특정 문자열을 포함하는 행을 삭제합니다.
words	<i>string</i>	특수 문자는 백슬래시 문자 w로 이스케이프해야 합니다.

### 3) 언어 노드: languageidentifier

스크립팅에 대해 다음 표의 특성을 사용할 수 있습니다. 노드 자체를 languageidentifier라고 합니다.

표 1. 언어 노드 스크립트 특성

스크립팅 특성	데이터 유형	특성 설명
text	<i>field</i>	
language_field_name	<i>string</i>	출력으로 생성되는 필드 이름입니다.
unidentified_language_value	Undefined Supported Custom	언어를 식별할 수 없는 경우에 사용되는 기본값입니다.
unidentified_language_supported	ko de es fr it ja nl pt	Iso 코드. unidentified_language_value가 Supported인 경우에만 사용 가능합니다.
unidentified_language_custom	<i>string</i>	unidentified_language_value가 Custom인 경우에만 사용 가능합니다.

### 4) 텍스트 마이닝 노드: TextMiningWorkbench

다음 매개변수를 사용하여 스크립팅을 통해 노드를 정의하거나 업데이트할 수 있습니다. 노드 자체는 TextMiningWorkbench라고 부릅니다.

❖ **중요사항:** 스크립팅을 통해 다른 자원 템플릿을 지정하는 것은 불가능합니다. 템플릿이 필요하다고 생각하는 경우 노드 대화 상자에서 선택해야 합니다.

표 1. 텍스트 마이닝 모델링 노드 스크립팅 특성

스크립팅 특성	데이터 유형	특성 설명
text	<i>field</i>	
method	ReadText ReadPath	
docType	<i>integer</i>	가능한 값은 (0,1,2)이며, 0 = Full Text, 1 = Structured Text 및 2 = XML
encoding	Automatic "UTF-8" "UTF-16" "ISO-8859-1" "US-ASCII" "CP850" "EUC-JP" "SHIFT-JIS" "ISO2022-JP"	"UTF-8"과 같은 특수 문자가 있는 값은 수학적 연산자와 혼동을 피하기 위해 따옴표로 묶어야 합니다.

스크립팅 특성	데이터 유형	특성 설명
unity	<i>integer</i>	가능한 값은 (0,1)이며, 0 = Paragraph 및 1 = Document
para_min	<i>integer</i>	
para_max	<i>integer</i>	
mtag	<i>string</i>	모든 mtag 설정(XML 파일의 경우 설정 대화 상자의) 포함
mclef	<i>string</i>	모든 mclef 설정(구조화된 텍스트 파일의 경우 설정 대화 상자의) 포함
partition	<i>field</i>	
custom_field	<i>flag</i>	파티션 필드가 지정될지 여부를 표시합니다.
use_model_name	<i>flag</i>	
model_name	<i>string</i>	
use_partitioned_data	<i>flag</i>	파티션 필드가 정의되는 경우, 훈련 데이터만 모델 작성에 사용합니다.
model_output_type	Interactive Model	대화형의 결과는 범주 모델입니다. 모델의 결과는 개념 모델입니다.
use_interactive_info	<i>flag</i>	워크벤치 세션에서만 대화식으로 작성하기 위한 것입니다.
reuse_extraction_results	<i>flag</i>	워크벤치 세션에서만 대화식으로 작성하기 위한 것입니다.
interactive_view	Categories TLA Clusters	워크벤치 세션에서만 대화식으로 작성하기 위한 것입니다.
extract_top	<i>integer</i>	이 매개변수는 model_type = Concept 일 때 사용됩니다.
use_check_top	<i>flag</i>	
check_top	<i>integer</i>	
use_uncheck_top	<i>flag</i>	
uncheck_top	<i>integer</i>	
language	de ko es fr it ja nl pt	
frequency_limit	<i>integer</i>	14.0에서 더 이상 사용되지 않습니다.

스크립팅 특성	데이터 유형	특성 설명
concept_count_limit	<i>integer</i>	최소한 이 값의 글로벌 빈도를 사용하는 개념으로 추출을 제한합니다.
fix_punctuation	<i>flag</i>	
fix_spelling	<i>flag</i>	
spelling_limit	<i>integer</i>	
extract_uniterm	<i>flag</i>	
extract_nonlinguistic	<i>flag</i>	
upper_case	<i>flag</i>	
group_names	<i>flag</i>	
permutation	<i>integer</i>	최대 비기능 단어 순열(기본값: 3).

## 5) 텍스트 마이닝 모델 너깃: TMWBModelApplier

스크립팅에 대해 다음 표의 특성을 사용할 수 있습니다. 너깃 자체는 TMWBModelApplier라고 부릅니다.

표 1. 텍스트 마이닝 모델 너깃 특성

스크립팅 특성	데이터 유형	특성 설명
scoring_mode	Fields Records	
field_values	Flags Counts	이 옵션은 범주 모델 너깃에서 사용할 수 없습니다. Flags의 경우 TRUE 또는 FALSE로 설정하십시오.
true_value	<i>string</i>	Flags를 사용하여, true에 대한 값을 정의하십시오.
false_value	<i>string</i>	Flags를 사용하여, false에 대한 값을 정의하십시오.
extension_concept	<i>string</i>	필드 이름의 확장을 지정하십시오. 필드 이름은 개념 이름에 이 확장을 더해서 사용하여 생성됩니다. add_as 값을 사용하여 이 확장을 넣을 위치를 지정하십시오.

스크립팅 특성	데이터 유형	특성 설명
extension_category	string	필드 이름 확장입니다. 필드 이름에 대해 확장 접두문자/접미문자를 지정하거나 범주 코드를 사용할 것을 선택할 수 있습니다. 필드 이름은 범주 이름에 이 확장을 더해서 사용하여 생성됩니다. add_as 값을 사용하여 이 확장을 넣을 위치를 지정하십시오.
add_as	Suffix Prefix	
fix_punctuation	flag	
excluded_subcategories_descriptors	RollUpToParent Ignore	<p>범주 모델의 경우에만 사용됩니다. 하위 범주가 선택 취소되는 경우 이 옵션으로 스코어링을 위해 선택되지 않은 하위 범주에 속하는 디스크립터가 처리되는 방법을 지정할 수 있습니다. 두 가지 옵션이 있습니다.</p> <ul style="list-style-type: none"> <li>- Ignore. '스코어링에서 디스크립터를 완전히 제외' 옵션은 선택 표시가 없는 (선택 취소된) 하위 범주의 디스크립터가 스코어링 중에 무시되고 사용되지 않게 합니다.</li> <li>- RollUpToParent. '상위 범주에 있는 것과 디스크립터 통합' 옵션은 선택 표시가 없는(선택 취소된) 하위 범주의 디스크립터가 상위 범주(이 하위 범주 위에 있는 범주)에 대한 디스크립터로 사용되도록 합니다. 여러 레벨의 하위 범주가 있고 선택되지 않은 경우, 디스크립터는 첫 번째 사용 가능한 상위 범주 아래에 롤업됩니다.</li> </ul>
check_model	flag	버전 14에서 더 이상 사용되지 않음
text	field	
method	ReadText ReadPath	
docType	integer	가능한 값은 (0,1,2)이며, 0 = Full Text, 1 = Structured Text 및 2 = XML

스크립팅 특성	데이터 유형	특성 설명
encoding	Automatic "UTF-8" "UTF-16" "ISO-8859-1" "US-ASCII" "CP850" "EUC-JP" "SHIFT-JIS" "ISO2022-JP"	"UTF-8"과 같은 특수 문자가 있는 값은 수학적 연산자와 혼동을 피하기 위해 따옴표로 묶어야 합니다.
language	de ko es fr it ja nl pt	

## 6) 텍스트 링크 분석 노드: textlinkanalysis

다음 테이블의 매개변수를 사용하여 스크립팅을 통해 노드를 정의 또는 업데이트할 수 있습니다. 노드 자체는 textlinkanalysis라고 부릅니다.

❖ **중요사항:** 스크립팅을 통해 자원 템플릿을 지정하는 것은 불가능합니다. 템플릿을 선택하려면 노드 대화 상자 안에서 선택해야 합니다.

표 1. 텍스트 링크 분석(TLA) 노드 스크립팅 특성

스크립팅 특성	데이터 유형	특성 설명
id_field	<i>field</i>	
text	<i>field</i>	
method	ReadText ReadPath	
docType	<i>integer</i>	가능한 값은 (0,1,2)이며, 0=Full Text, 1=Structured Text 및 2=XML
encoding	Automatic "UTF-8" "UTF-16" "ISO-8859-1" "US-ASCII" "CP850" "EUC-JP" "SHIFT-JIS" "ISO2022-JP"	"UTF-8"과 같은 특수 문자가 있는 값은 수학적 연산자와 혼동을 피하기 위해 따옴표로 묶어야 합니다.
unity	<i>integer</i>	가능한 값은 (0,1)이며, 0 = Paragraph 및 1 = Document
para_min	<i>integer</i>	
para_max	<i>integer</i>	
mtag	<i>string</i>	모든 mtag 설정(XML 파일의 경우 설정 대화 상자의) 포함

스크립팅 특성	데이터 유형	특성 설명
mclef	<i>string</i>	모든 mclef 설정(구조화된 텍스트 파일의 경우 설정 대화 상자의) 포함
language	de ko es fr it ja nl pt	
concept_count_limit	<i>integer</i>	최소한 이 값의 글로벌 빈도를 사용하는 개념으로 추출을 제한합니다.
fix_punctuation	<i>flag</i>	
fix_spelling	<i>flag</i>	
spelling_limit	<i>integer</i>	
extract_uniterm	<i>flag</i>	
extract_nonlinguistic	<i>flag</i>	
upper_case	<i>flag</i>	
group_names	<i>flag</i>	
permutation	<i>integer</i>	최대 비기능 단어 순열(기본값: 3).

## 7. 대화형 워크벤치 모드

텍스트 마이닝 모델링 노드에서 스트림 실행 중에 대화형 워크벤치 세션을 실행하도록 선택할 수 있습니다. 이 워크벤치에서, 텍스트 데이터에서 주요 개념을 추출하고 범주를 작성하며 텍스트 링크 분석 패턴 및 군집을 탐색하고 범주 모델을 생성할 수 있습니다. 이 섹션에서는 다음을 포함하여 작업할 주요 요소와 함께 상위 레벨 관점에서 워크벤치 인터페이스에 대해 설명합니다.

- **추출 결과.** 추출이 수행된 후 이는 데이터 텍스트에서 식별 및 추출된 주요 단어 및 문구입니다(개념이라고도 함). 이러한 개념은 유형으로 그룹화됩니다. 이러한 개념과 유형을 사용하면 범주를 작성하는 것은 물론 데이터도 탐색할 수 있습니다. **범주 및 개념** 보기에서 관리됩니다.
- **범주.** 디스크립터(예: 추출 결과, 패턴, 규칙)를 정의로 사용하면 범주 정의의 일부가 포함되었는지 여부에 관계없이 문서 및 레코드가 지정되는 범주 세트를 수동으로 또는 자동으로 작성할 수 있습니다. **범주 및 개념** 보기에서 관리됩니다.
- **군집.** 군집은 개념 간의 관계를 표시하는 링크가 발견된 개념 집단입니다. 개념은 다른 요인 중에서 두 개념이 함께 나타나는 빈도를 개별적으로 나타나는 빈도와 비교하는 복합 알고리즘을 사용하여 그룹화됩니다. **군집** 보기에서 관리됩니다. 또한 군집을 구성하는 개념을 범주에 추가할 수 있습니다.
- **텍스트 링크 분석 패턴.** 언어학적 자원에 텍스트 링크 분석(TLA) 패턴 규칙이 있거나 일부

TLA 규칙이 이미 있는 자원 템플릿을 사용 중인 경우, 텍스트 데이터에서 패턴을 추출할 수 있습니다. 이러한 패턴을 사용하여 데이터에 있는 개념 간의 흥미로운 관계를 쉽게 알아낼 수 있습니다. 또한 이러한 패턴을 범주에서 디스크립터로 사용할 수 있습니다. **텍스트 링크 분석** 보기에서 관리됩니다.

- **언어학적 자원.** 추출 프로세스는 매개변수 및 언어 정의 세트에 의존하여 텍스트 추출 및 처리 방법을 제어합니다. **자원 편집기** 보기에서 템플릿 및 라이브러리 양식으로 관리됩니다.

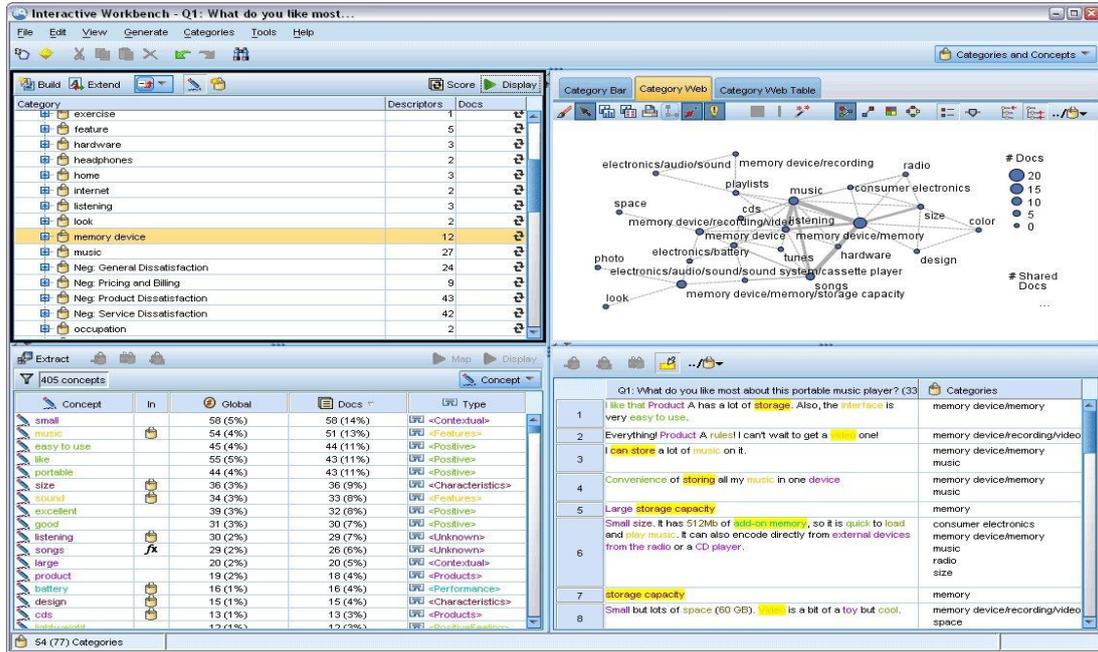
## 잠재적인 대화형 워크벤치 문제

- 다중 대화형 워크벤치 세션으로 인해 작동이 느려질 수 있습니다. SPSS® Modeler Text Analytics 및 SPSS Modeler는 대화형 워크벤치 세션이 시작될 때 공통 Java 런타임 엔진을 공유합니다. SPSS Modeler 세션 동안 호출하는 대화형 워크벤치 세션의 수에 따라 동일한 세션을 열고 닫는 경우에도 시스템 메모리로 인해 애플리케이션이 느려질 수 있습니다. 이 효과는 대형 데이터로 작업하거나 권장되는 RAM 설정(4GB) 이하의 시스템으로 작업하는 경우에 특히 두드러집니다. 시스템 응답이 느려지는 경우, 모든 작업을 저장하고 SPSS Modeler를 종료한 다음 애플리케이션을 다시 시작하도록 권장합니다. 권장 메모리 미만의 시스템에서 SPSS Modeler Text Analytics를 실행하는 경우, 특히 대형 데이터 세트로 작업하거나 장기간 작업하는 경우, Java 메모리가 부족하거나 종료될 수 있습니다. 대형 데이터에 대해 작업하는 경우 권장 메모리 설정 이상으로 업그레이드하거나 SPSS Modeler Text Analytics 서버를 사용하도록 강력히 권장합니다.
- 애플리케이션을 다시 시작하지 않고 다중 SPSS Modeler Text Analytics 대화형 워크벤치 세션이 실행되는 경우, SPSS Modeler 클라이언트의 메모리가 부족할 수 있습니다. 느리게 실행되는 경우, 상태 표시줄에서 메모리 사용량을 확인하고 SPSS Modeler 클라이언트를 닫은 다음 다시 여십시오.

## 1) 범주 및 개념 보기

애플리케이션 인터페이스는 몇 개의 보기로 구성됩니다. 범주 및 개념 보기는 범주를 작성하고 탐색하는 것은 물론 추출 결과를 탐색하고 조정할 수 있는 창입니다. **범주**는 스코어링 프로세스를 통해 문서와 레코드가 지정된 밀접하게 관련된 아이디어 및 패턴 그룹입니다. 반면에 **개념**은 범주에 디스크립터라는 구성 요소로 사용할 사용 가능한 가장 기본적인 수준의 추출 결과를 나타냅니다.

그림 1. 범주 및 개념 보기



범주 및 개념 보기는 네 개의 분할창으로 구성되며, 보기 메뉴에서 해당 이름을 선택하여 각각 숨기거나 표시할 수 있습니다. 자세한 정보는 텍스트 데이터 범주화의 내용을 참조하십시오.

## 범주 분할창

왼쪽 상단 모서리에 위치한 이 영역은 작성하는 범주를 관리할 수 있는 테이블을 제공합니다. 텍스트 데이터에서 개념과 유형을 추출한 후에는 시맨틱 네트워크 및 개념 포함과 같은 기술을 사용하거나 수동으로 작성하여 범주 작성을 시작할 수 있습니다. 범주 이름을 두 번 클릭하면 범주 정의 대화 상자가 열려 정의를 구성하는 모든 디스크립터(예: 개념, 유형, 규칙)를 표시합니다. 자세한 정보는 텍스트 데이터 범주화의 내용을 참조하십시오. 모든 언어에 자동 기술을 모두 사용할 수 있는 것은 아닙니다.

분할창에서 행을 선택하면 데이터 및 시각화 분할창에 해당 문서/레코드 또는 디스크립터에 대한 정보를 표시할 수 있습니다.

## 추출 결과 분할창

왼쪽 상단 모서리에 위치한 이 영역은 추출 결과를 제공합니다. 추출을 실행하면 추출 엔진이 텍스트 데이터를 읽고 관련 개념을 식별하며, 각각에 유형을 지정합니다. 개념은 텍스트 데이터에서 추출된 단어 또는 문구입니다. 유형은 유형 사전 양식으로 저장된 개념에 대한 시맨틱 집합입니다. 추출이 완료되면 개념과 유형이 추출 결과 분할창에 색상 코딩으로 나타납니다. 자세한 정보는 추출 결과: 개념 및 유형의 내용을 참조하십시오.

마우스를 개념 이름 위에 올리면 개념의 기본 용어 세트를 볼 수 있습니다. 그렇게 하면 개념 이름을 표시하는 도구팁과 해당 개념 아래에 그룹화되는 몇몇 용어 라인이 표시됩니다. 이러한 기본 용어에는 언어학적 자원(텍스트에서 발견되는지 여부와 관계없이)에 정의되는 동의어뿐만 아니라 추출된 복수/단수 용어, 순열된 용어, 퍼지 그룹화의 용어 등이 포함됩니다. 이러한 용어를 복사하거나 개념 이름을 마우스 오른쪽 단추로 클릭하고 컨텍스트 메뉴 옵션을 선택하여 전체 기본 용어 세트를 볼 수 있습니다.

텍스트 마이닝은 텍스트 데이터 컨텍스트에 따라 추출 결과를 검토하고 미세 조정하여 새 결과를 생성한 후 재평가하는 대화형 프로세스입니다. 언어학적 자원을 수정하여 추출 결과를 세분화할 수 있습니다. 이 미세 조정을 추출 결과 또는 데이터 분할창에서 직접 부분적으로 수행할 수 있지만 자원 편집기 보기에서도 직접 수행할 수 있습니다. 자세한 정보는 자원 편집기 보기의 내용을 참조하십시오.

**참고:** 분할창에 표시할 수 있는 수보다 결과 수가 많은 경우, 분할창의 맨 아래쪽에 있는 제어를 사용하여 결과 앞 또는 뒤로 이동하거나 이동할 페이지 수를 입력할 수 있습니다.

## 시각화 분할창

오른쪽 상단 모서리에 위치한 이 영역은 문서/레코드 범주화의 공통성에 대한 여러 퍼스펙티브를 제공합니다. 각 그래프 또는 차트는 유사한 정보를 제공하지만 다른 방식으로 또는 다른 세부사항 수준으로 정보를 제공합니다. 이러한 차트와 그래프를 사용하여 범주화 결과를 분석하고 쉽게 범주를 미세 조정하거나 보고서를 작성할 수 있습니다. 예를 들어, 그래프에서 너무 유사하거나(예: 레코드의 75% 이상을 공유) 너무 다른 범주를 발견할 수 있습니다. 그래프 또는 차트의 콘텐츠는 다른 분할창의 선택사항에 해당합니다. 자세한 정보는 범주 그래프 및 도표의 내용을 참조하십시오.

## 데이터 분할창

데이터 분할창은 오른쪽 하단 모서리에 있습니다. 이 분할창은 보기의 다른 영역에서의 선택사항에 해당하는 문서 또는 레코드가 포함된 테이블을 제공합니다. 선택사항에 따라 해당 텍스트만 데이터 분할창에 표시됩니다. 선택했으면 **표시** 단추를 클릭하여 데이터 분할창을 해당 텍스트로 채우십시오.

다른 분할창에 선택사항이 있으면 텍스트에서 쉽게 식별할 수 있도록 해당 문서 또는 레코드가 색상으로 강조표시된 개념을 표시합니다. 색상 코드화된 항목 위에 마우스를 올려 놓아 추출된 개념과 지정된 유형을 표시하는 도구팁도 표시할 수 있습니다. 자세한 정보는 데이터 분할창의 내용을 참조하십시오.

## 범주 및 개념 보기에서 검색 및 찾기

일부 경우 특정 섹션에서 빨리 정보를 찾아야 합니다. 찾기 도구 모음을 사용하면 검색할 문자열을 입력하고 다른 검색 기준(예: 대소문자 구분 또는 검색 방향)을 정의할 수 있습니다. 그리고 나서 검색할 분할창을 선택할 수 있습니다.

### 찾기 기능 사용 방법

1. 범주 및 개념 보기의 메뉴에서 **편집 > 찾기**를 선택하십시오. 찾기 도구 모음이 범주 분할창 및 시각화 분할창 위에 나타납니다.
2. 텍스트 상자에 검색할 단어 문자열을 입력하십시오. 도구 모음 단추를 사용하여 대소문자 구분, 부분 매치 및 검색 방향을 제어할 수 있습니다.
3. 도구 모음에서 검색할 분할창 이름을 클릭하십시오. 매치가 발견되면 창에서 텍스트가 강조 표시됩니다.
4. 다음 매치를 찾으려면 분할창 이름을 다시 클릭하십시오.

## 2) 군집 보기

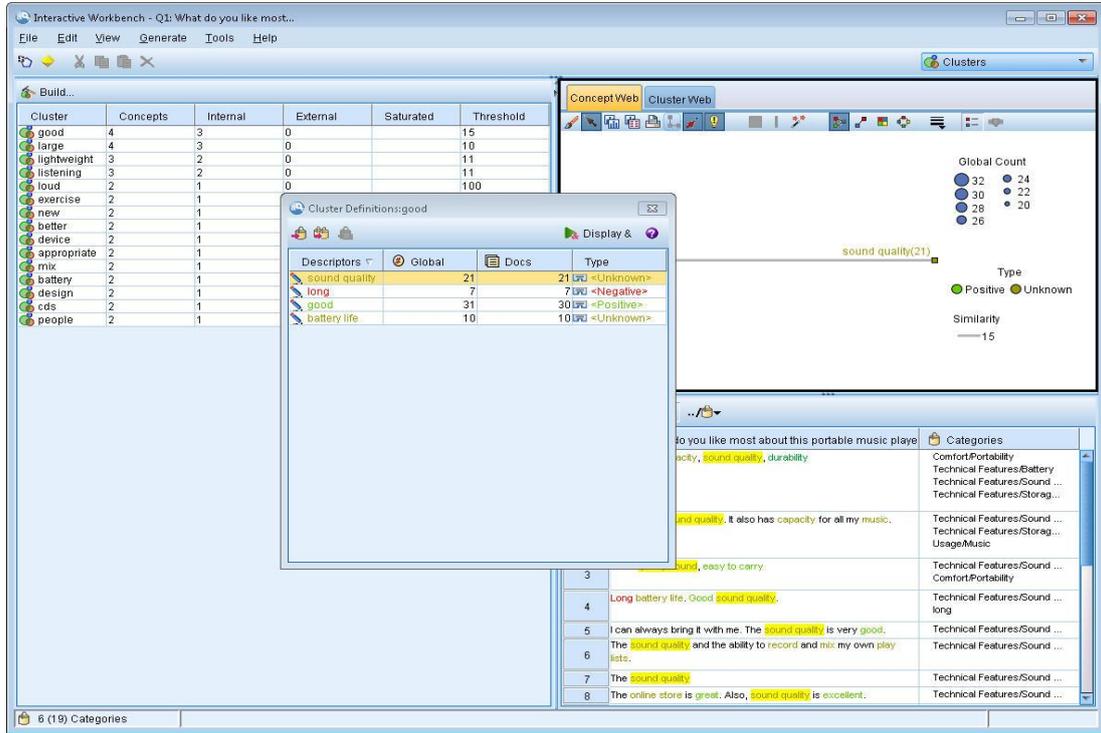
군집 보기에서 텍스트 데이터에서 찾은 군집 결과를 작성하고 탐색할 수 있습니다. 군집은 개념이 발생하는 빈도와 함께 나타나는 빈도를 기반으로 한 군집화 알고리즘을 통해 생성된 개념 집단입니다. 범주의 목적은 범주에 포함된 텍스트가 각 범주에 대해 디스크립터(개념, 규칙, 패턴)를 매치하는 방법을 기반으로 문서 또는 레코드를 그룹화하는 것인 반면 군집의 목적은 함께 동시에 발생하는 개념을 그룹화하는 것입니다.

군집 내에서 개념이 함께 연결되어 발생하는 빈도가 높을수록 다른 개념과 함께 발생하는 빈도가 낮으며, 군집은 흥미로운 개념 관계를 더 잘 식별합니다. 두 개의 개념이 모두 동일한 문서 또는 레코드에 나타나는 경우(또는 동의어나 용어 중 하나가 나타나는 경우) 두 개념은 동시에 발생합니다. 자세한 정보는 군집 분석의 내용을 참조하십시오.

군집을 작성하고, 그렇지 않으면 찾는 데 시간이 너무 많이 걸리는 개념 간의 관계를 파악하는데 도움이 되는 차트 및 그래프 세트에서 탐색할 수 있습니다. 전체 군집을 범주에 추가할 수는 없지만 군집 정의 대화 상자를 통해 군집의 개념을 범주에 추가할 수 있습니다. 자세한 정보는 군집 정의의 내용을 참조하십시오.

군집화 설정을 변경하여 결과에 영향을 줄 수 있습니다. 자세한 정보는 군집 작성의 내용을 참조하십시오.

그림 1. 군집 보기



군집 보기는 세 개의 분할창으로 구성되며, 보기 메뉴에서 해당 이름을 선택하여 각각 숨겨거나 표시할 수 있습니다. 일반적으로 군집 분할창과 시각화 분할창만 표시됩니다.

## 군집 분할창

왼쪽에 위치한 이 분할창은 텍스트 데이터에서 발견된 군집을 제공합니다. 작성 단추를 클릭하여 군집화 결과를 작성할 수 있습니다. 군집은 함께 자주 발생하는 개념을 식별하려고 시도하는 군집화 알고리즘을 통해 형성됩니다.

새 추출이 발생할 때마다 군집 결과가 지워지며, 최신 결과를 얻으려면 군집을 다시 작성해야 합니다. 군집을 작성할 때 일부 설정(예: 작성할 최대 군집 수, 군집에 포함될 수 있는 최대 개념 수 또는 군집이 가질 수 있는 외부 개념과의 최대 링크 수)을 변경할 수 있습니다. 자세한 정보는 군집 탐색의 내용을 참조하십시오.

## 시각화 분할창

오른쪽 상단 모서리에 위치한 이 분할창은 군집화에 대한 두 개의 퍼스펙티브 즉, 개념 웹 그래프와 군집 웹 그래프를 제공합니다. 표시되지 않으면 보기 메뉴에서 이 분할창에 액세스할 수 있습니다(보기 > 시각화). 군집 분할창에서의 선택사항에 따라 군집 간의 또는 군집 내 해당 상호작용을 볼 수 있습니다. 결과는 다음과 같이 다중 형식으로 제공됩니다.

- **개념 웹.** 선택된 군집 내의 모든 개념은 물론 군집 외부의 링크된 개념도 표시하는 웹 그래프입니다.
- **군집 웹.** 선택된 군집에서 다른 군집으로의 링크는 물론 해당 다른 군집 간의 링크도 보여주는 웹 그래프입니다.

**참고:** 군집 웹 그래프를 표시하려면 외부 링크가 있는 군집을 이미 작성했어야 합니다. 외부 링크는 별도 군집의 개념 쌍(한 군집 내 개념과 다른 군집에서 외부의 개념) 간의 링크입니다. 자세한 정보는 군집 그래프의 내용을 참조하십시오.

## 데이터 분할창

데이터 분할창은 오른쪽 하단 모서리에 있으며 기본적으로 숨겨집니다. 이러한 군집은 여러 문서 /레코드에 걸쳐 있기 때문에 군집 분할창에서 데이터 분할창 결과를 표시할 수 없어 데이터 결과가 흥미롭지 못하게 됩니다. 그러나 군집 정의 대화 상자의 선택사항에 해당하는 데이터를 볼 수 있습니다. 해당 대화 상자에서의 선택사항에 따라 해당 텍스트만 데이터 분할창에 표시됩니다. 선택했으면 **표시 &** 단추를 클릭하여 모든 개념을 함께 포함하는 문서 또는 레코드로 데이터 분할창을 채우십시오.

해당 문서 또는 레코드는 텍스트에서 쉽게 식별할 수 있도록 색상으로 강조표시된 개념을 표시합니다. 색상 코드화된 항목 위에 마우스를 올려 놓아 추출된 개념과 지정된 유형도 표시할 수 있습니다. 데이터 분할창에는 여러 개의 열이 포함될 수 있지만 텍스트 필드 열은 항상 표시됩니다. 추출 중에 사용된 텍스트 필드 이름 또는 여러 파일에 텍스트 데이터가 있는 경우에는 문서 이름을 수반합니다. 기타 열은 사용 가능합니다. 자세한 정보는 데이터 분할창의 내용을 참조하십시오.

### 3) 텍스트 링크 분석 보기

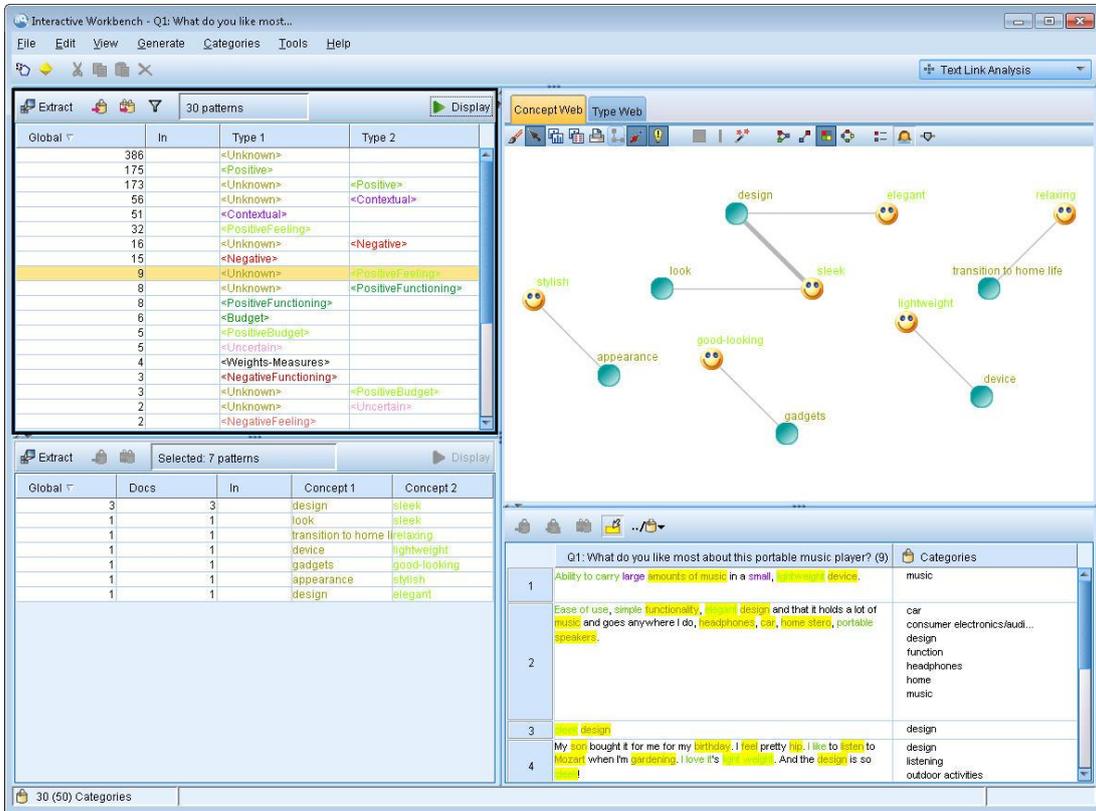
텍스트 링크 분석(TLA) 보기에서 텍스트 데이터에서 찾은 텍스트 링크 분석 패턴을 작성하고 탐색할 수 있습니다. 텍스트 링크 분석(TLA)은 TLA 규칙을 정의하고 이를 텍스트에서 찾은 실제로 추출된 개념 및 관계와 비교할 수 있게 하는 패턴 매치 기술입니다.

패턴은 특정 주제에 대한 의견 또는 개념 간의 관계를 발견하려고 시도할 때 가장 유용합니다. 몇 가지 예로 설문조사 데이터에서 제품에 대한 의견, 의학 연구 논문에서 유전자 관계 또는 지능형 데이터에서 개체 간 또는 위치 간의 관계를 추출하려고 하는 경우를 들 수 있습니다.

일부 TLA 패턴을 추출했으면 데이터 또는 시각화 분할창에서 탐색하고 범주 및 개념 보기에서 범주에 추가할 수 있습니다. TLA 결과를 추출하려면 사용 중인 자원 템플릿 또는 라이브러리에 일부 TLA 규칙이 정의되어 있어야 합니다. 자세한 정보는 텍스트 링크 규칙에 대한 정보의 내용을 참조하십시오.

TLA 패턴 결과를 추출하기로 선택했으면 결과가 이 보기에 제공됩니다. 이렇게 하도록 선택하지 않았으면 추출 단추를 사용하고 패턴 추출 사용 옵션을 선택해야 합니다.

그림 1. 텍스트 링크 분석 보기



텍스트 링크 분석 보기는 네 개의 분할창으로 구성되며, 보기 메뉴에서 해당 이름을 선택하여 각 숨기거나 표시할 수 있습니다. 자세한 정보는 텍스트 링크 분석 탐색의 내용을 참조하십시오.

## 유형 및 개념 패턴 분할창

왼쪽에 위치한 유형 및 개념 패턴 분할창은 TLA 패턴 결과를 탐색하고 선택할 수 있는 두 개의 상호 연결된 분할창입니다. 패턴은 최대 6개의 일련의 유형 또는 6개의 개념으로 구성됩니다. 언어학적 자원에서 정의된 대로 TLA 패턴 규칙은 패턴 결과의 복잡도를 지시합니다. 자세한 정보는 텍스트 링크 규칙에 대한 정보의 내용을 참조하십시오.

패턴 결과는 먼저 유형 수준에서 그룹화된 후 개념 패턴으로 나뉩니다. 이러한 이유로 두 개의 다른 결과 분할창 즉, 유형 패턴(왼쪽 상단)과 개념 패턴(왼쪽 하단)이 있습니다.

- **유형 패턴.** 유형 패턴 분할창은 TLA 패턴 규칙과 매치하는 두 개 이상의 관련 유형으로 구성되는 추출된 패턴을 제공합니다. 유형 패턴은 특정 위치의 조직에 대한 긍정적 피드백을 제공할 수 있는 <Organization> + <Location> + <Positive>로 표시됩니다.

- **개념 패턴.** 개념 패턴 분할창은 그 위의 유형 패턴 분할창에서 현재 선택된 모든 유형 패턴에 대한 추출된 패턴을 개념 수준에서 제공합니다. 개념 패턴은 hotel + paris + wonderful과 같은 구조를 따릅니다.

범주 및 개념 보기에서의 추출 결과의 경우와 마찬가지로 여기서 결과를 검토할 수 있습니다. 이러한 패턴을 구성하는 유형 및 개념에 대해 수행할 세분화가 있으면 범주 및 개념 보기의 추출 결과 분할창에서 또는 자원 편집기에서 직접 세분화를 수행하고 패턴을 재추출하십시오.

## 시각화 분할창

텍스트 링크 분석 보기의 오른쪽 상단 모서리에 위치한 이 분할창은 유형 패턴 또는 개념 패턴으로 선택된 패턴의 웹 그래프를 제공합니다. 표시되지 않으면 보기 메뉴에서 이 분할창에 액세스할 수 있습니다(**보기 > 시각화**). 다른 분할창에서의 선택사항에 따라 문서/레코드 및 패턴 간의 해당 상호작용을 볼 수 있습니다.

결과는 다음과 같이 다중 형식으로 제공됩니다.

- **개념 그래프.** 이 그래프는 선택된 패턴의 모든 개념을 제공합니다. 개념 그래프에서 선 굵기와 노드 크기(유형 아이콘이 표시되지 않은 경우)는 선택된 테이블에서 글로벌 발생 수를 표시합니다.
- **유형 그래프.** 이 그래프는 선택된 패턴의 모든 유형을 제공합니다. 그래프에서 선 굵기와 노드 크기(유형 아이콘이 표시되지 않은 경우)는 선택된 테이블에서 글로벌 발생 수를 표시합니다. 노드는 유형 색상 또는 아이콘으로 표시됩니다.

자세한 정보는 텍스트 링크 분석 그래프의 내용을 참조하십시오.

## 데이터 분할창

데이터 분할창은 오른쪽 하단 모서리에 있습니다. 이 분할창은 보기의 다른 영역에서의 선택사항에 해당하는 문서 또는 레코드가 포함된 테이블을 제공합니다. 선택사항에 따라 해당 텍스트만 데이터 분할창에 표시됩니다. 선택했으면 **표시** 단추를 클릭하여 데이터 분할창을 해당 텍스트로 채우십시오.

다른 분할창에 선택사항이 있으면 텍스트에서 쉽게 식별할 수 있도록 해당 문서 또는 레코드가 색상으로 강조표시된 개념을 표시합니다. 색상 코드화된 항목 위에 마우스를 올려 놓아 추출된 개념과 지정된 유형을 표시하는 도구팁도 표시할 수 있습니다. 자세한 정보는 데이터 분할창의 내용을 참조하십시오.

#### 4) 자원 편집기 보기

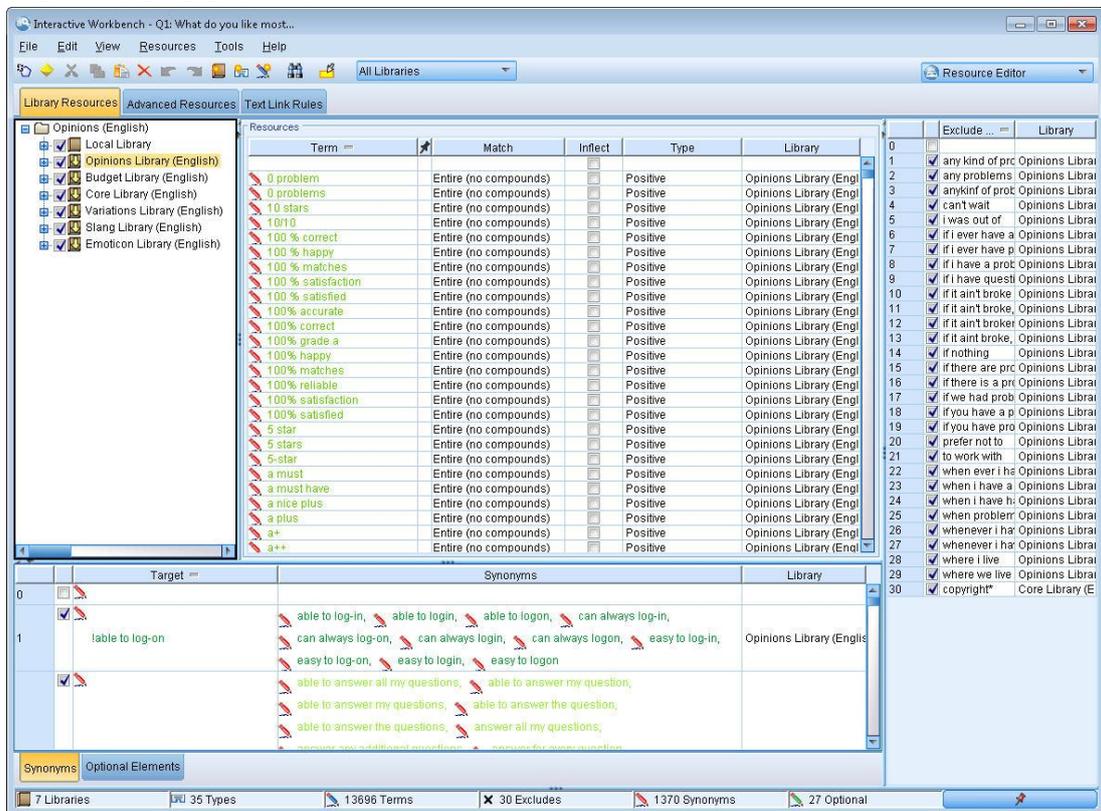
IBM® SPSS® Modeler Text Analytics 는 강력한 추출 엔진을 사용하여 텍스트 데이터로부터 주요 개념을 빠르고 정확하게 캡처합니다. 이 엔진은 얼마나 많은 양의 구조화되지 않은 텍스트 데이터가 분석되고 해석되어야 하는지를 지시하기 위해 언어학적 자원에 크게 의존합니다.

자원 편집기 보기에서는 개념을 추출하는 데 사용된 언어학적 자원을 보고 세부 조정하고, 이들을 유형별로 그룹화하고, 텍스트 데이터에서 패턴을 찾아내는 등의 작업을 할 수 있습니다. IBM SPSS Modeler Text Analytics 에서는 몇몇 사전에 구성된 자원 템플릿을 제공합니다. 또한 몇몇 언어에서는 텍스트 분석 패키지에서 자원을 사용할 수도 있습니다. 자세한 정보는 텍스트 분석 패키지 사용의 내용을 참조하십시오.

이러한 자원이 항상 데이터 컨텍스트에 완벽하게 적합하지는 않을 수 있으므로, 자원 편집기에서 특정 컨텍스트 또는 도메인에서 사용자 고유의 자원을 작성, 편집 및 관리할 수 있습니다. 자세한 정보는 라이브러리에 대한 작업 주제를 참조하십시오.

언어학적 자원을 세부 조정하는 프로세스를 단순화하기 위해 추출 결과 및 데이터 분할창의 컨텍스트 메뉴를 통해 범주 및 개념 보기에서 직접 공통 사전 작업을 수행할 수 있습니다. 자세한 정보는 추출 결과 세분화 주제를 참조하십시오.

그림 1. 자원 편집기 보기



자원 편집기 보기에서 수행하는 작업은 언어학적 자원의 관리 및 세부 조정을 중심으로 합니다. 이러한 자원은 템플릿 및 라이브러리 양식으로 저장됩니다. 자원 편집기 보기는 라이브러리 트리 분할창, 유형 사전 분할창, 대체 사전 분할창, 제외 사전 분할창의 네 개의 파트로 구성됩니다.

 **참고:** 자세한 정보는 편집기 인터페이스의 내용을 참조하십시오.

## 5) 옵션 설정

옵션 대화 상자에서 IBM® SPSS® Modeler Text Analytics의 일반 옵션을 설정할 수 있습니다. 이 대화 상자에는 다음 탭이 있습니다.

- **세션.** 이 탭은 일반 옵션과 구분자를 포함합니다. 자세한 정보는 옵션: 세션 탭 주제를 참조하십시오.
- **표시.** 이 탭은 인터페이스에서 사용되는 색상에 대한 옵션을 포함합니다. 자세한 정보는 옵션: 표시 탭 주제를 참조하십시오.
- **사운드.** 이 탭은 사운드 큐 옵션을 포함합니다. 자세한 정보는 옵션: 사운드 탭 주제를 참조하십시오.

옵션 편집 방법

1. 메뉴에서 **도구 > 옵션**을 선택하십시오. 옵션 대화 상자가 열립니다.
2. 변경할 정보가 포함된 탭을 선택하십시오.
3. 옵션을 변경하십시오.
4. **확인**을 클릭하여 변경사항을 저장하십시오.

### (1) 옵션: 세션 탭

이 탭에서, 일부 기본 설정을 정의할 수 있습니다.

**데이터 분할창 및 범주 그래프 표시.** 이 옵션은 범주 및 개념 보기의 시각화 분할창과 데이터 분할창에서 데이터가 표시되는 방법에 영향을 줍니다.

- **데이터 분할창 및 범주 웹에 대한 표시 한계.** 이 옵션은 범주 및 개념 보기에서 데이터 분할창이나 그래프 및 도표를 채우기 위해 사용하거나 표시할 최대 문서 수를 설정합니다.
- **표시할 때 문서/레코드에 대한 범주 표시.** 선택하면, 문서나 레코드가 속하는 범주가 데이터 분할창의 범주 열과 범주 그래프에 표시될 수 있도록 표시를 클릭할 때마다 문서 또는 레코드가 스코어링됩니다. 일부 경우에는(특히 큰 데이터 세트가 있는 경우) 데이터와 그래프가 더 빨리 표시되도록 이 옵션을 끌 수도 있습니다.

데이터 분할창에서 범주에 추가. 이 옵션은 문서와 레코드가 데이터 분할창에서 추가될 때 범주에 추가될 사항에 영향을 줍니다.

- 범주 및 개념 보기에서, 복사. 이 보기에서 데이터 분할창으로부터 문서 또는 레코드를 추가하면 개념만 또는 개념 및 패턴 둘 다 복사됩니다.
- 텍스트 링크 분석 보기에서, 복사. 이 보기에서 데이터 분할창으로부터 문서 또는 레코드를 추가하면 패턴만 또는 개념 및 패턴 둘 다 복사됩니다.

자원 편집기 구분자. 자원 편집기 보기에서 개념, 동의어 및 선택적 요소와 같은 요소를 입력할 때 구분자로서 사용될 문자를 선택하십시오.

## (2) 옵션: 표시 탭

이 탭에서 애플리케이션의 전반적인 모양과 느낌에 영향을 주는 옵션과 요소를 구별하는 데 사용되는 색상을 편집할 수 있습니다.

참고: 제품의 모양과 느낌을 클래식 모양과 느낌 또는 이전 릴리스의 모양과 느낌으로 전환하려면 기본 IBM® SPSS® Modeler 창의 도구 메뉴에서 사용자 옵션을 여십시오.

사용자 정의 색상. 화면에 나타나는 요소의 색상을 편집하십시오. 테이블의 각 요소에 대해 색상을 변경할 수 있습니다. 사용자 정의 색상을 지정하려면 변경할 요소 오른쪽의 색상 영역을 클릭하고 드롭 다운 목록에서 색상을 선택하십시오.

- **추출되지 않은 텍스트.** 아직 추출되지 않았지만 데이터 분할창에 표시 가능한 텍스트 데이터입니다.
- **강조 배경.** 분할창에서 요소를 선택하거나 데이터 분할창에서 텍스트를 선택할 때 텍스트 선택 배경 색상입니다.
- **추출 필요 배경.** 라이브러리에 변경이 수행되었고 추출이 필요함을 나타내는 추출 결과, 패턴 및 군집 분할창의 배경 색상입니다.
- **범주 피드백 배경.** 작업 후 나타나는 범주 배경 색상입니다.
- **기본 유형.** 데이터 분할창과 추출 결과 분할창에 나타나는 유형 및 개념의 기본 색상입니다. 이 색상은 자원 편집기에서 작성하는 사용자 정의 유형에 적용됩니다. 자원 편집기에서 이러한 유형 사전의 특성을 편집하여 사용자 정의 유형 사전의 이 기본 색상을 대체할 수 있습니다. 자세한 정보는 유형 작성의 내용을 참조하십시오.
- **스트라이프 테이블 1.** 각 선 세트를 구별하기 위해 강제 실행된 개념 편집 대화 상자의 테이블에서 대체 방식으로 사용되는 두 개 색상 중 첫 번째입니다.
- **스트라이프 테이블 2.** 각 선 세트를 구별하기 위해 강제 실행된 개념 편집 대화 상자의 테이블에서 대체 방식으로 사용되는 두 개 색상 중 두 번째입니다.

참고: 기본값으로 재설정 단추를 클릭하면 이 대화 상자의 모든 옵션이 이 제품을 처음 설치했을 때의 값으로 재설정됩니다.

### (3) 옵션: 사운드 탭

이 탭에서 사운드에 영향을 주는 옵션을 편집할 수 있습니다. 사운드 이벤트에서, 이벤트가 발생하면 알리는 데 사용되는 사운드를 지정할 수 있습니다. 다수의 사운드를 사용할 수 있습니다. 사운드를 찾아서 선택하려면 생략 기호 단추(...)를 사용하십시오. IBM® SPSS® Modeler Text Analytics용 사운드를 작성하는 데 사용되는 .wav 파일은 설치 디렉토리의 *media* 서브디렉토리에 저장됩니다. 사운드를 재생하지 않으려면 **모든 사운드 음소거**를 선택하십시오. 사운드는 기본적으로 음소거됩니다.

**참고:** 기본값으로 재설정 단추를 클릭하면 이 대화 상자의 모든 옵션이 이 제품을 처음 설치했을 때의 값으로 재설정됩니다.

## 6) 도움말에 대한 Microsoft Internet Explorer 설정

### Microsoft Internet Explorer 설정

이 애플리케이션에서 대부분의 도움말 기능은 Microsoft Internet Explorer에 기반한 기술을 사용합니다. Internet Explorer 일부 버전(Microsoft Windows XP, 서비스팩 2와 함께 제공되는 버전 포함)은 로컬 컴퓨터의 Internet Explorer 창에서 "액티브 콘텐츠"로 간주하는 내용을 기본적으로 차단합니다. 이 기본 설정으로 인해 도움말 기능에서 일부 콘텐츠가 차단될 수 있습니다. 도움말 콘텐츠를 모두 보려면 Internet Explorer의 기본 작동을 변경할 수 있습니다.

1. Internet Explorer 메뉴에서 다음을 선택하십시오.  
도구 > 인터넷 옵션...
2. 고급 탭을 클릭하십시오.
3. 보안 섹션으로 아래로 스크롤하십시오.
4. 내 컴퓨터에 있는 파일에서 액티브 콘텐츠가 실행되는 것을 허용을 선택하십시오.

## 7) 모델 너깃 및 모델링 노드 생성

대화형 세션에 있을 때 완료한 작업을 사용하여 다음 둘 중 하나를 생성할 수 있습니다.

- **텍스트 마이닝 모델링 노드.** 대화형 워크벤치 세션에서 생성된 모델링 노드는 설정과 옵션이 열린 대화형 세션에 저장된 설정과 옵션을 반영하는 텍스트 마이닝 노드입니다. 이는 원래 텍스트 마이닝 노드가 더 이상 없거나 새 버전을 작성하려고 할 때 유용합니다. 자세한 정보는 개념 및 범주 마이닝의 내용을 참조하십시오.

- **범주 모델 너깃.** 대화형 워크벤치 세션에서 생성된 모델 너깃은 범주 모델 너깃입니다. 범주 모델 너깃을 생성하려면 범주 및 개념 보기에 하나 이상의 범주가 있어야 합니다. 자세한 정보는 텍스트 마이닝 너깃: 범주 모델의 내용을 참조하십시오.

#### 텍스트 마이닝 모델링 노드 생성 방법

1. 메뉴에서 **생성 > 모델링 노드 생성**을 선택하십시오. 텍스트 마이닝 모델링 노드가 현재 워크벤치 세션의 모든 설정을 사용하여 작업 중인 캔버스에 추가됩니다. 노드는 텍스트 필드의 이름을 따서 이름 지정됩니다.

#### 범주 모델 너깃 생성 방법

1. 메뉴에서 **생성 > 모델 생성**을 선택하십시오. 모델 너깃은 기본 이름을 가진 모델 팔레트에 직접 생성됩니다.

## 8) 모델링 노드 업데이트 및 저장

대화형 세션에서 작업하는 동안 이따금씩 모델링 노드를 업데이트하여 변경사항을 저장하는 것이 좋습니다. 또한 대화형 워크벤치 세션에서 작업을 완료하고 작업을 저장하려고 할 때마다 모델링 노드를 업데이트해야 합니다. 모델링 노드를 업데이트할 때 워크벤치 세션 콘텐츠는 대화형 워크벤치 세션을 시작한 텍스트 마이닝 노드에 다시 저장됩니다. 출력 창은 닫히지 않습니다.

**중요!** 이 업데이트는 스트림을 저장하지 않습니다. 스트림을 저장하려면, 모델링 노드를 업데이트한 후 기본 IBM® SPSS® Modeler 창에서 저장을 수행하십시오.

#### 모델링 노드 업데이트 방법

1. 메뉴에서 **파일 > 모델링 노드 업데이트**를 선택하십시오. 보유한 옵션 및 범주와 더불어 작성 및 추출 설정으로 모델링 노드가 업데이트됩니다.

## 9) 세션 닫기 및 종료

세션에서 작업을 완료하면 세 가지의 다른 방법으로 세션에서 나갈 수 있습니다.

- **저장.** 이 옵션을 사용하면 먼저 다른 세션에서 재사용할 수 있도록 라이브러리를 출판할 뿐만 아니라, 나중 세션을 위해 원래의 모델링 노드에 작업을 다시 저장할 수 있습니다. 자세한 정보는 라이브러리 공유의 내용을 참조하십시오. 저장하고 나면, 세션 창이 닫히고 세션은 IBM® SPSS® Modeler 창의 출력 관리자에서 삭제됩니다.

- **종료.** 이 옵션은 저장되지 않은 작업을 삭제하고, 세션 창을 닫은 후, IBM SPSS Modeler 창의 출력 관리자에서 세션을 삭제합니다. 메모리를 사용 가능하도록 하려면, 중요한 작업을 저장하고 세션을 종료하는 것이 좋습니다.
- **닫기.** 이 옵션은 어떤 작업도 저장하거나 삭제하지 않습니다. 이 옵션은 세션 창을 닫지만 세션이 계속 실행됩니다. IBM SPSS Modeler 창의 출력 관리자에서 이 세션을 선택하여 다시 세션 창을 열 수 있습니다.

워크벤치 세션을 닫으려면 다음을 수행하십시오.

1. 메뉴에서 **파일 > 닫기**를 선택하십시오.

## 10) 내게 필요한 옵션의 키보드 기능

대화식 워크벤치 인터페이스는 제품의 기능성을 한층 액세스 가능하도록 만들기 위해 키보드 단축키를 제공합니다. 가장 기본적인 레벨에서 Alt + 해당 키를 눌러 창 메뉴를 활성화(예: Alt+F를 눌러 파일 메뉴에 액세스)하거나 Tab 키를 눌러 대화 상자 제어를 스크롤할 수 있습니다. 이 섹션에서는 대체 탐색에 대한 키보드 단축키에 대해 다룹니다. IBM® SPSS® Modeler 인터페이스의 경우 다른 키보드 단축키가 있습니다.

표 1. 일반 키보드 단축키

단축키	기능
Ctrl+1	탭이 있는 분할창에서 첫 번째 탭을 표시합니다.
Ctrl+2	탭이 있는 분할창에서 두 번째 탭을 표시합니다.
Ctrl+A	초점이 있는 분할창에 대한 모든 요소를 선택합니다.
Ctrl+C	선택한 텍스트를 클립보드로 복사합니다.
Ctrl+E	범주 및 개념 보기와 텍스트 링크 분석 보기에서 추출을 시작합니다.
Ctrl+F	자원 편집기/템플릿 편집기에서 찾기 도구 모음을 표시하고(아직 볼 수 없는 경우) 초점을 그 도구 모음에 둡니다.
Ctrl+I	범주 및 개념 보기에서, 선택된 범주에 대한 범주 정의 대화 상자를 시작합니다. 군집 보기에서, 선택된 군집에 대한 군집 정의 대화 상자를 시작합니다.
Ctrl+R	자원 편집기/템플릿 편집기에서 용어 추가 대화 상자를 엽니다.
Ctrl+T	자원 편집기/템플릿 편집기에서 새 유형을 작성하기 위해 유형 특성 대화 상자를 엽니다.
Ctrl+V	클립보드 내용을 붙여넣습니다.

단축키	기능
Ctrl+X	자원 편집기/템플릿 편집기에서 선택된 항목을 잘라냅니다.
Ctrl+Y	보기에서 마지막 조치를 다시 실행합니다.
Ctrl+Z	보기에서 마지막 조치를 실행 취소합니다.
F1	도움말을 표시하거나, 대화 상자에 있는 경우 항목에 대한 컨텍스트 도움말을 표시합니다.
F2	테이블 셀에서 편집 모드 안팎으로 토글합니다.
F6	활성 보기에서 기본 분할창 사이에 초점을 이동합니다.
F8	크기를 조정하기 위해 분할창 분할기 막대로 초점을 이동합니다.
F10	기본 파일 메뉴를 펼칩니다.
위/아래 화살표	분할기 막대가 선택될 때 수직으로 분할창 크기를 조정합니다.
왼쪽/오른쪽 화살표	분할기 막대가 선택될 때 수평으로 분할창 크기를 조정합니다.
Home, End	분할기 막대가 선택될 때 최소 또는 최대 크기로 분할창 크기를 조정합니다.
Tab	창, 분할창 또는 대화 상자에서 항목 사이에 앞으로 이동합니다.
Shift+F10	항목의 컨텍스트 메뉴를 표시합니다.
Shift+Tab	창 또는 대화 상자에서 항목 사이에 뒤로 이동합니다.
Shift+화살표	편집 모드(F2)에 있을 때 편집 필드에서 문자를 선택합니다.
Ctrl+Tab	창에서 다음 주 영역으로 초점을 앞으로 이동합니다.
Shift+Ctrl+Tab	창에서 이전 주 영역으로 초점을 뒤로 이동합니다.

### (1) 대화 상자의 단축키

대화 상자에 대해 작업할 때 몇 개의 단축키 및 스크린 리더 키가 도움이 됩니다. 대화 상자에 입력할 때 첫 번째 제어에 초점을 맞추고 스크린 리더를 초기화하기 위해 Tab 키를 눌러야 할 수도 있습니다. 특수 키보드 및 스크린 리더 단축키의 전체 목록은 다음 테이블에 제공됩니다.

표 1. 대화 상자 단축키

단축키	기능
Tab	창 또는 대화 상자에서 항목 사이에 앞으로 이동합니다.
Ctrl+Tab	텍스트 상자에서 다음 항목으로, 앞으로 이동합니다.
Shift+Tab	창 또는 대화 상자에서 항목 사이에 뒤로 이동합니다.

단축키	기능
Shift+Ctrl+Tab	텍스트 상자에서 이전 항목으로, 뒤로 이동합니다.
스페이스바	초점이 있는 제어 또는 단추를 선택합니다.
Esc	변경사항을 취소시키고 대화 상자를 닫습니다.
Enter	변경사항의 유효성을 검증하고 대화 상자를 닫습니다(확인 단추와 같음). 텍스트 상자에 있는 경우, 먼저 Ctrl+Tab을 눌러서 텍스트 상자에서 나가야 합니다.

## 8. 개념 및 유형 추출

대화형 워크벤치를 실행하는 스트림을 실행할 때마다 스트림의 텍스트 데이터에서 추출이 자동으로 수행됩니다. 이 추출의 결과는 개념, 유형 및 TLA 패턴이 언어학적 자원에 존재하는 경우 패턴 세트입니다. 추출 결과 분할창에서 개념 및 유형을 보고 이에 대한 작업을 할 수 있습니다. 자세한 정보는 추출 작동 방법의 내용을 참조하십시오.

추출 결과를 미세 조정하려는 경우 언어학적 자원을 수정하고 재추출할 수 있습니다. 자세한 정보는 추출 결과 세분화의 내용을 참조하십시오. 추출 프로세스는 자원 및 추출 대화 상자의 매개 변수에 의존하여 결과 추출 및 구성 방법을 지시합니다. 추출 결과를 사용하여 모두는 아니더라도 범주 정의의 더 나은 파트를 정의할 수 있습니다.

**참고:** 버전 18.2부터 추출된 개념 결과가 개선되어 IBM® SPSS® Text Analytics for Surveys에서 추출된 개념 결과와 유사합니다.

### 1) 추출 결과: 개념 및 유형

추출 프로세스 동안에 모든 텍스트 데이터가 스캔되고 관련 개념이 식별되고, 추출되고 유형에 지정됩니다. 추출이 완료되면 결과는 범주와 개념 보기의 왼쪽 하단 구석에 있는 추출 결과 분할창에 나타납니다. 세션을 처음 실행하면 노트에서 선택한 언어학적 자원 템플릿이 이러한 개념과 유형을 추출하고 구성하는 데 사용됩니다.

**참고:** 분할창에 표시할 수 있는 수보다 결과 수가 많은 경우, 분할창의 맨 아래쪽에 있는 제어를 사용하여 결과 앞 또는 뒤로 이동하거나 이동할 페이지 수를 입력할 수 있습니다.

추출되는 개념, 유형 및 TLA 패턴은 집합적으로 **추출 결과**라고 불리고, 이들은 범주의 디스크립터 또는 구성 요소의 역할을 합니다. 범주 규칙에서 개념, 유형 및 패턴을 사용할 수도 있습니다. 또한, 자동 기법은 개념과 유형을 사용하여 범주를 작성합니다.

텍스트 마이닝 은 추출 결과가 텍스트 데이터의 컨텍스트에 따라 검토되고 새로운 결과를 생성하기 위해 세부 조정된 다음 다시 평가되는 반복적인 프로세스입니다. 추출 후에는 결과를 검토하고 언어학적 자원을 수정하여 필요에 따라 변경해야 합니다. 자원을 부분적으로 추출 결과 분할창, 데이터 분할창, 범주 정의 대화 상자 또는 군집 정의 대화 상자에서 직접 세부 조정할 수 있습니다. 자세한 정보는 추출 결과 세분화 주제를 참조하십시오. 자원 편집기 보기에서 직접 수행할 수도 있습니다. 자세한 정보는 자원 편집기 보기 주제를 참조하십시오.

세부 조정 후에는 새로운 결과를 보기 위해서 다시 추출할 수 있습니다. 추출 결과를 처음부터 세부 조정하여 다시 추출할 때마다 데이터의 컨텍스트에 완벽하게 적응된, 범주 정의에서 동일한 결과를 얻도록 할 수 있습니다. 이런 방식으로 문서/레코드는 보다 정확하고 반복 가능한 방식으로 범주 정의에 지정됩니다.

## 개념

추출 프로세스 동안에 텍스트에서 텍스트 데이터가 스캔되고 관심 또는 관련된 단일어(예: election 또는 peace) 및 단어 구(예: presidential election, election of the president 또는 peace treaties)를 식별하기 위해 분석됩니다. 이러한 단어와 구문을 집합적으로 용어라고 부릅니다. 언어학적 자원을 사용하여 관련 용어가 추출된 다음 유사한 용어는 개념이라는 리드 용어 하에 그룹화됩니다.

마우스를 개념 이름 위에 올리면 개념의 기본 용어 세트를 볼 수 있습니다. 그렇게 하면 개념 이름을 표시하는 도구팁과 해당 개념 아래에 그룹화되는 몇몇 용어 라인이 표시됩니다. 이러한 기본 용어에는 언어학적 자원(텍스트에서 발견되는지 여부와 관계없이)에 정의되는 동의어뿐만 아니라 추출된 복수/단수 용어, 순열된 용어, 퍼지 그룹화의 용어 등이 포함됩니다. 이러한 용어를 복사하거나 개념 이름을 마우스 오른쪽 단추로 클릭하고 컨텍스트 메뉴 옵션을 선택하여 전체 기본 용어 세트를 볼 수 있습니다.

기본적으로, 개념은 소문자로 표시되고 문서 개수(문서 열)의 내림차순으로 정렬되어 있습니다. 개념이 추출되면 유사한 개념을 그룹화하기 위해 유형이 지정됩니다. 이들은 이 유형에 따라 색상 코딩됩니다. 색상은 자원 편집기 내에서 유형 특성에 정의됩니다. 자세한 정보는 유형 사전의 내용을 참조하십시오.

개념, 유형 또는 패턴이 범주 정의에 사용될 때마다 아이콘이 정렬 가능한 위치 열에 나타납니다.

## 유형

유형은 개념의 시맨틱 그룹입니다. 개념이 추출되면 유사한 개념을 그룹화하기 위해 유형이 지정됩니다. 몇몇 내장된 유형은 IBM® SPSS® Modeler Text Analytics (예: <Location>, <Organization>, <Person>, <Positive>, <Negative> 등)과 함께 제공됩니다. 예를 들어, <위치> 유형은 지리적 키워드와 장소를 그룹화합니다. 이 유형은 chicago, paris 및 tokyo와 같은 개념에 지정됩니다. 유형 사전에는 없고 텍스트에서는 추출된 대부분의 언어의 경우, 개념은 자동으로 <Unknown>으로 유형이 지정됩니다. 자세한 정보는 내장 유형 주제를 참조하십시오.

유형 보기를 선택할 때 추출된 유형은 기본적으로 글로벌 빈도순으로 내림차순으로 나타납니다. 또한 유형은 식별하기 쉽도록 색상 코딩되어 있음을 볼 수 있습니다. 색상은 유형 특성의 일부입니다. 자세한 정보는 유형 작성의 내용을 참조하십시오. 사용자만의 유형을 작성할 수도 있습니다.

## 패턴

패턴은 또한 텍스트 데이터에서 추출할 수도 있습니다. 그러나 자원 편집기에 일부 텍스트 링크 분석(TLA) 패턴을 포함하는 라이브러리가 있어야 합니다. 또한 IBM SPSS Modeler Text Analytics 노드 설정에서 또는 추출 대화 상자에서 **텍스트 링크 분석 패턴 추출 사용** 옵션을 사용하여 이러한 패턴을 추출하도록 선택해야 합니다. 자세한 정보는 텍스트 링크 분석 탐색의 내용을 참조하십시오.

## 2) 데이터 추출

추출이 필요할 때마다 추출 결과 분할창은 노란색이 되고 **개념을 추출하려면 추출 단추를 누르십시오** 메시지가 이 분할창에서 도구 모음 아래에 나타납니다.

추출 결과가 아직 없거나, 언어학적 자원을 변경했거나, 추출 결과를 업데이트해야 하거나, 추출 결과를 저장하지 않은 세션을 다시 연 경우에(**도구 > 옵션**) 추출해야 할 수도 있습니다.

**참고:** 추출 결과가 **세션 작업 사용...** 옵션을 사용하여 캐싱된 후에 스트림의 소스 노드를 변경한 경우에는 추출 결과를 업데이트하려면 대화식 워크벤치 세션이 실행된 후에 새 추출을 실행해야 합니다.

추출을 실행하면 진행 표시기가 나타나서 추출 상태에 대한 피드백을 제공합니다. 이번에는 추출 엔진은 모든 텍스트 데이터를 읽고 관련 용어와 패턴을 식별하고 이를 추출하고 이를 유형에 지정합니다. 그런 다음 엔진은 동의어를 개념이라고 불리는 하나의 리드 용어 아래에 그룹화하려고 시도합니다. 프로세스가 완료되면 결과로 나오는 개념, 유형 및 패턴이 추출 결과 분할창에 나타납니다.

추출 프로세스는 개념 및 유형 세트뿐만 아니라 텍스트 링크 분석(TLA) 패턴(사용 가능한 경우)을 결과로 생성합니다. 이러한 개념과 유형을 범주 및 개념 보기의 추출 결과 분할창에서 보고 작업할 수 있습니다. TLA 패턴을 추출한 경우에는 이를 텍스트 링크 분석 보기에서 볼 수 있습니다.

**참고:** 데이터 세트의 크기와 추출 프로세스를 완료하는 데 걸리는 시간 간의 관계가 있습니다. 언제든지 표본 노드 업스트림을 삽입하거나 시스템의 구성 최적화를 고려할 수 있습니다.

## 데이터 추출 방법

1. 메뉴에서 **도구 > 추출**을 선택하십시오. 또는 **추출 도구 모음** 단추를 클릭하십시오.
2. 추출 설정 대화 상자를 항상 표시하도록 선택하면 이는 사용자가 변경할 수 있도록 나타납니다. 각 설정의 디스크립터에 대해서는 이 주제를 추가로 참조하십시오.
3. **추출**을 클릭하여 추출 프로세스를 시작하십시오. 추출이 시작되면 진행 대화 상자가 열립니다. 추출 후에는 결과가 추출 결과 분할창에 나타납니다. 기본적으로, 개념은 소문자로 표시되고 문서 개수(문서 열)의 내림차순으로 정렬되어 있습니다.

결과를 다르게 정렬하고, 결과를 필터링하거나 다른 보기(개념 또는 유형)로 전환하려면 도구 모음 옵션을 사용하여 결과를 검토할 수 있습니다. 언어학적 자원에 대해 작업하여 추출 결과를 세분화할 수도 있습니다. 자세한 정보는 추출 결과 세분화 주제를 참조하십시오.

## 잠재적 추출 문제

다중 대화형 워크bench 세션으로 인해 작동이 느려질 수 있습니다. SPSS® Modeler Text Analytics 및 SPSS Modeler는 대화형 워크bench 세션이 시작될 때 공통 Java 런타임 엔진을 공유합니다. SPSS Modeler 세션 동안 호출하는 대화형 워크bench 세션의 수에 따라 동일한 세션을 열고 닫는 경우에도 시스템 메모리로 인해 애플리케이션이 느려질 수 있습니다. 이 효과는 대형 데이터로 작업하거나 권장되는 RAM 설정(4GB) 이하의 시스템으로 작업하는 경우에 특히 두드러집니다. 시스템 응답이 느려지는 경우, 모든 작업을 저장하고 SPSS Modeler를 종료한 다음 애플리케이션을 다시 시작하도록 권장합니다. 권장 메모리 미만의 시스템에서 SPSS Modeler Text Analytics를 실행하는 경우, 특히 대형 데이터 세트로 작업하거나 장기간 작업하는 경우, Java 메모리가 부족하거나 종료될 수 있습니다. 대형 데이터에 대해 작업하는 경우 권장 메모리 설정 이상으로 업그레이드하거나 SPSS Modeler Text Analytics 서버를 사용하도록 강력히 권장합니다.

### 네덜란드어, 영어, 프랑스어, 독일어, 이탈리아어, 포르투갈어 및 스페인어 텍스트의 경우

추출 설정 대화 상자에는 몇몇 기본 추출 옵션이 포함됩니다.

**텍스트 링크 분석 패턴 추출을 사용으로 설정하십시오.** 텍스트 데이터에서 TLA 패턴을 추출하려 함을 지정합니다. 또한 자원 편집기에서 사용자의 라이브러리 중 하나에 TLA 패턴 규칙이 있다고 가정합니다. 이 옵션은 추출 시간을 현저하게 늘릴 수 있습니다. 자세한 정보는 텍스트 링크 분석 탐색의 내용을 참조하십시오.

**구두점 오류를 조정하십시오.** 이 옵션은 추출 중에 구두점 오류가 있는 텍스트(예를 들어, 부적절한 사용법)를 일시적으로 표준화하여 개념의 추출 가능성을 향상시킵니다. 이 옵션은 텍스트가 짧고 품질이 저조한 경우(예를 들어, 개방형 설문조사 반응, 이메일 및 CRM 데이터) 또는 텍스트에 많은 약어가 포함된 경우에 특히 유용합니다.

**최소 단어 문자 길이([n])에 대한 맞춤법 수용** 이 옵션은 맞춤법이 자주 틀리는 단어나 맞춤법이 유사한 단어를 하나의 개념으로 그룹화하는 퍼지 그룹화 기술을 적용합니다. 퍼지 그룹화 알고리즘은 일시적으로 모든 모음(맨 처음 것은 제외)을 지우고 추출된 단어에서 이중/삼중 자음을 지운 다음 modeling과 modelling이 함께 그룹화될 수 있도록 이들이 동일한지 비교합니다. 그러나 각 용어가 <Unknown> 유형을 제외하고 서로 다른 유형에 지정된 경우에는 퍼지 그룹화 기술은 적용되지 않습니다.

퍼지 그룹화를 사용하기 전에 필요한 루트 문자의 최소 수를 정의할 수도 있습니다. 용어에서 루트 문자의 수는 모든 문자를 합한 후 굴절접사를 형성하는 문자와 복합어의 경우에는 한정사 및 전치사를 형성하는 문자를 빼서 계산합니다. 예를 들어, exercises 용어는 "exercise" 양식의 8개 루트 문자가 있는 것으로 간주됩니다. 단어 끝의 s자는 굴절(복수형)이기 때문입니다. 마찬가지로, apple sauce는 10개의 루트 문자로 간주되고("apple sauce") manufacturing of cars는 16개의 루트 문자("manufacturing car")로 간주됩니다. 이 계산 방법은 퍼지 그룹화를 적용해야 하는지 여부를 확인하는 데에만 사용되고 단어가 매치하는 방법에는 영향을 미치지 않습니다.

**참고:** 특정 단어가 나중에 잘못 그룹화되는 경우에는 이를 고급 자원 탭의 **퍼지 그룹화: 예외** 섹션에 명시적으로 선언하여 이 기술에서 단어 쌍을 제외할 수 있습니다. 자세한 정보는 퍼지 그룹화의 내용을 참조하십시오.

**단일어 추출** 이 옵션은 단어가 복합어의 일부가 아니거나 명사이거나 인식되지 않은 품사인 경우에만 단어를 추출합니다.

**비언어 엔티티 추출** 이 옵션은 전화 번호, 주민등록번호, 시간, 날짜, 통화, 숫자, 백분율, 이메일 주소 및 HTTP 주소 등과 같은 비언어 엔티티를 추출합니다. 고급 자원 탭의 **비언어 엔티티: 구성** 섹션에서 비언어 엔티티의 특정 유형을 포함하거나 제외할 수 있습니다. 불필요한 엔티티를 사용 안함으로 설정하면 추출 엔진은 처리 시간을 낭비하지 않습니다. 자세한 정보는 구성의 내용을 참조하십시오.

**대문자 알고리즘** 이 옵션은 용어의 첫 글자가 대문자인 한 내장된 사전에 없는 단순 및 복합어를 추출합니다. 이 옵션은 가장 적합한 명사를 추출하기 위한 좋은 방법을 제공합니다.

**가능한 경우 부분 및 전체 사람 이름을 함께 그룹화** 이 옵션은 텍스트에 다르게 나타나는 이름을 그룹화합니다. 이름은 종종 시작부에는 전체 이름이 언급되고 나중에는 약어로만 표시되기 때문에 이 기능이 유용합니다. 이 옵션은 <Unknown> 유형의 단어를 <Person>으로 입력되는 복합어와 매치시키려고 시도합니다. 예를 들어, doe가 있고 처음에는 <Unknown>으로 입력되는 경우에는, 추출 엔진은 <Person> 유형에 있는 복합어가 doe를 마지막 단어로 포함하는지 여부를 확인합니다(예: john doe). 이 옵션은 이름에는 적용되지 않습니다. 이름의 대부분은 단일어로 추출되지 않기 때문입니다.

**최대 비기능 단어 순열** 이 옵션은 순열 기술을 적용할 때 존재할 수 있는 비기능 단어 최대 수를 지정합니다. 이 순열 기술은 서로 굴절과는 관계없이 포함된 비기능 단어(예: of 및 the)만 다른 유사한 구를 그룹화합니다. 예를 들어, 이 값을 최소 두 개의 단어로 설정하고 company

officials 및 officials of the company 둘 모두가 추출되었다고 해 봅시다. 이 경우, 추출된 두 용어는 모두 마지막 개념 목록에 그룹화됩니다. 두 용어 모두 of the가 무시될 때 동일한 것으로 간주되기 때문입니다.

**다항어를 그룹화할 때 파생 사용** 빅 데이터를 처리할 때 파생 규칙을 사용하여 다항어를 그룹화하려면 이 옵션을 선택하십시오.

**개념 맵의 색인 옵션** 개념 맵을 나중에 빠르게 그릴 수 있도록 추출 시에 맵 색인 작성을 지정합니다. 색인 설정을 편집하려면 **설정**을 클릭하십시오. 자세한 정보는 개념 맵 지수 작성의 내용을 참조하십시오.

**추출을 시작하기 전에 이 대화 상자 항상 표시** 추출할 때마다 추출 설정 대화 상자를 표시하려는지 여부를 지정합니다. 도구 메뉴로 돌아가지 않는 한 이를 표시하지 않거나, 추출할 때마다 추출 설정을 편집하려는지 요청할지 여부를 지정합니다.

### 3) 추출 결과 필터링

매우 큰 데이터 세트에 대한 작업 시 추출 프로세스는 수백만 개의 결과를 생성할 수 있습니다. 많은 사용자가 이 양으로 인해 결과를 효과적으로 검토하기가 더 어렵습니다. 따라서 가장 흥미로운 해당 결과에 주목하려면 추출 결과 분할창에서 사용 가능한 필터 대화 상자를 통해 이러한 결과를 필터링할 수 있습니다.

이 필터 대화 상자의 모든 설정을 함께 사용하여 범주에 사용 가능한 추출 결과를 필터링함을 명심하십시오.

**빈도 기준으로 필터링** 일정 글로벌 또는 문서 빈도 값을 가진 해당 결과만 표시하도록 필터링할 수 있습니다.

- **글로벌 빈도**는 전체 문서 또는 레코드 세트에 개념이 나타나는 총 횟수이며 **글로벌** 열에 표시됩니다.
- **문서 빈도**는 개념이 나타나는 총 문서 또는 레코드 수이며 **문서** 열에 표시됩니다.

예를 들어, 개념 nato가 500개 레코드에 800번 나타났으면 이 개념의 글로벌 빈도는 800이고 문서 빈도는 500입니다.

**유형순** 일정 유형에 속한 해당 결과만 표시하도록 필터링할 수 있습니다. 모든 유형 또는 특정 유형만 선택할 수 있습니다.

**매치 텍스트순** 여기에 정의하는 규칙과 매치하는 해당 결과만 표시하도록 필터링할 수도 있습니다. **매치 텍스트** 필드에 매치될 문자 세트를 입력한 후 매치를 적용할 조건을 선택하십시오.

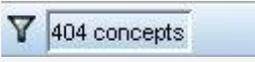
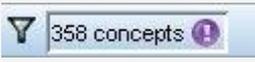
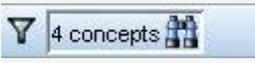
표 1. 매치 텍스트 조건

조건	설명
포함	문자열이 어딘가에 발생하면 텍스트가 매치됩니다(기본 선택사항).
시작 문자	개념 또는 유형이 지정된 텍스트로 시작하는 경우에만 텍스트가 매치됩니다.
끝 문자	개념 또는 유형이 지정된 텍스트로 끝나는 경우에만 텍스트가 매치됩니다.
정확히 일치	전체 문자열이 개념 또는 유형 이름과 매치해야 합니다.

### 추출 결과 분할창에 표시된 결과

필터를 기반으로 추출 결과 분할창 도구 모음에 영어로 결과가 표시되는 방법의 몇 가지 예제는 다음과 같습니다.

표 2. 필터 피드백 예제

필터 피드백	설명
	도구 모음은 결과 수를 표시합니다. 텍스트 매치 필터가 없고 최대 값을 충족하지 않았기 때문에 추가 아이콘이 표시되지 않습니다.
	도구 모음은 필터에 지정된 최대값(이 경우 300)으로 결과가 제한되었음을 표시합니다. 보라색 아이콘이 있는 경우 이는 최대 개념 수가 충족되었음을 의미합니다. 자세한 정보를 보려면 아이콘 위에 마우스를 올려 놓으십시오.
	도구 모음은 매치 텍스트 필터를 사용하여 결과가 제한되었음을 표시합니다. 이는 돋보기 아이콘으로 표시됩니다.

### 결과 필터링 방법

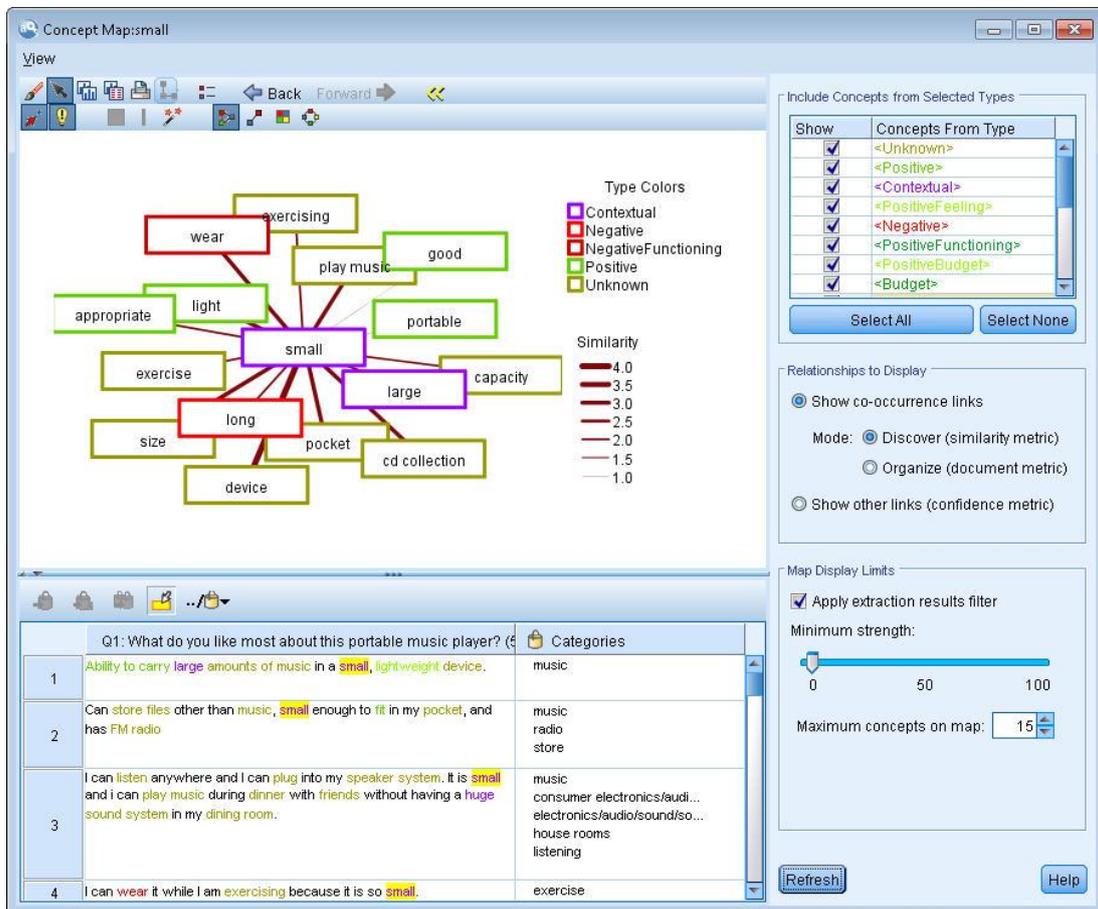
1. 메뉴에서 **도구 > 필터**를 선택하십시오. 필터 대화 상자가 열립니다.
2. 사용할 필터를 선택하고 세분화하십시오.
3. **확인**을 클릭하여 필터를 적용하고 추출 결과 분할창에서 새 결과를 확인하십시오.

#### 4) 개념 맵 탐색

개념 맵을 작성하여 개념이 상호 관련되는 방법을 탐색할 수 있습니다. 단일 개념을 선택하고 맵을 클릭하면 선택된 개념과 관련된 개념 세트를 탐색할 수 있도록 개념 맵 창이 열립니다. 포함시킬 유형, 검색할 관계 종류 등과 같은 설정을 편집하여 표시되는 개념을 필터링할 수 있습니다.

❖ **중요사항:** 맵을 작성하려면 먼저 지수를 생성해야 합니다. 이를 수행하는 데 몇 분이 걸릴 수 있습니다. 그러나 일단 지수를 생성했다면 재추출할 때까지 다시 재생성하지 않아도 됩니다. 추출할 때마다 자동으로 지수를 생성하려면 추출 설정에서 해당 옵션을 선택하십시오. 자세한 정보는 데이터 추출의 내용을 참조하십시오.

그림 1. 선택된 개념에 대한 개념 맵



#### 개념 맵을 보는 방법

1. 추출 결과 분할창에서 단일 개념을 선택하십시오.
2. 이 분할창의 도구 모음에서 맵 단추를 클릭하십시오. 맵 지수가 이미 생성된 경우 개념 맵은 별도의 대화 상자에서 열립니다. 맵 지수가 생성되지 않았거나 오래된 경우에는 지수를 다시 작성해야 합니다. 이 프로세스는 몇 분이 걸릴 수 있습니다.

3. 탐색할 맵을 클릭하십시오. 링크된 개념을 두 번 클릭하면 맵이 저절로 다시 그려져 방금 두 번 클릭한 개념에 대해 링크된 개념을 보여줍니다.
4. 맵 위 도구 모음은 이전 맵으로 다시 이동, 관계 강도에 따라 링크 필터링, 표시할 관계 종류는 물론 나타나는 개념 유형을 제어하기 위한 필터 대화 상자 열기와 같은 몇 가지 기본 맵 도구를 제공합니다. 두 번째 도구 모음 줄은 그래프 편집 도구를 포함합니다. 자세한 정보는 그래프 도구 모음 및 팔레트 사용의 내용을 참조하십시오.
5. 찾고 있는 링크 종류에 만족하지 않으면 맵 오른쪽에 표시된 이 맵 설정을 검토하십시오.

### 맵 설정: 선택된 유형의 개념 포함

테이블에서 선택된 유형에 속한 해당 개념만 맵에 표시됩니다. 일정 유형의 개념을 숨기려면 테이블에서 해당 유형을 선택 취소하십시오.

### 맵 설정: 표시할 관계

**동시 발생 링크 표시** 동시 발생 링크를 표시하려면 모드를 선택하십시오. 모드는 링크 강도 계산 방법에 영향을 줍니다.

- *발견(유사성 매트릭)*. 이 매트릭을 사용하면 두 개념이 함께 나타나는 빈도는 물론 따로 나타나는 빈도도 고려하는 보다 복잡한 계산을 사용하여 링크 강도를 계산합니다. 강도 값이 높으면 개념 쌍이 따로 나타나는 것보다 더 자주 함께 나타나는 경향이 있음을 의미합니다. 다음 수식을 사용하면 부동 소수점 값이 정수로 변환됩니다.

그림 2. 유사성 계수 수식

$$\text{similarity coefficient} = \frac{(C_{IJ})^2}{(C_I \times C_J)}$$

이 수식에서  $C_I$ 는 개념 I가 발생하는 문서 또는 레코드 수입입니다.

$C_J$ 는 개념 J가 발생하는 문서 또는 레코드 수입입니다.

$C_{IJ}$ 는 개념 쌍 I와 J가 문서 세트에서 동시 발생하는 문서 또는 레코드 수입입니다.

- *구성(문서 매트릭)*. 이 매트릭을 사용하면 동시 발생 원래 수를 통해 링크 강도를 판별합니다. 일반적으로 더 빈번한 두 개의 개념이 때때로 함께 발생할 가능성이 높습니다. 강도 값이 높으면 개념 쌍이 자주 함께 나타남을 의미합니다.

**다른 링크 표시(신뢰 매트릭)**. 표시할 다른 링크를 선택할 수 있습니다. 이는 시맨틱, 파생(형태론) 또는 포함(구문)이며 링크된 개념에서 제거된 단계 수와 관련됩니다. 이를 통해 자원 특히, 동의성을 조정하거나 모호성을 해소할 수 있습니다. 이러한 집단 기술 각각에 대한 간단한 설명은 고급 언어학적 설정의 내용을 참조하십시오.

**참고:** 지수가 작성될 때 선택되지 않았거나 관계를 찾을 수 없으면 아무것도 표시되지 않음을 명심하십시오. 자세한 정보는 개념 맵 지수 작성의 내용을 참조하십시오.

## 맵 설정: 맵 표시 한계

**추출 결과 필터 적용.** 모든 개념을 사용하지는 않으려면 추출 결과 분할창에서 필터를 선택하여 표시되는 항목을 제한할 수 있습니다. 그리고 나서 이 옵션을 선택하면 IBM® SPSS® Modeler Text Analytics가 이 필터링된 세트를 사용하여 관련 개념을 찾습니다. 자세한 정보는 추출 결과 필터링의 내용을 참조하십시오.

**최소 강도.** 여기서 최소 링크 강도를 설정하십시오. 이 한계보다 관계 강도가 낮은 관련된 개념은 맵에서 숨겨집니다.

**맵의 최대 개념 수.** 맵에 표시할 최대 관계 수를 지정하십시오.

### (1) 개념 맵 지수 작성

맵을 작성하려면 먼저 개념 관계 지수를 생성해야 합니다. 개념 맵을 작성할 때마다 IBM® SPSS® Modeler Text Analytics는 이 지수를 참조합니다. 이 대화 상자에서 기술을 선택하여 지수화할 관계를 선택할 수 있습니다.

**집단 기술.** 하나 이상의 기술을 선택하십시오. 이러한 기술 각각에 대한 간단한 설명은 언어학적 기술 정보의 내용을 참조하십시오. 모든 텍스트 언어에 모든 기술을 사용할 수 있는 것은 아닙니다.

**특정 개념 쌍 방지.** 프로세스가 출력에 두 개의 개념을 함께 그룹화하거나 쌍으로 만드는 프로세스를 중지하려면 이 선택란을 선택하십시오. 개념 쌍을 작성하거나 관리하려면 쌍 관리를 클릭하십시오. 자세한 정보는 링크 예외 쌍 관리의 내용을 참조하십시오.

지수를 작성하는 데 몇 분이 걸릴 수 있습니다. 그러나 일단 지수를 생성했으면 재추출할 때까지 또는 더 많은 관계를 포함시키도록 설정을 변경하지 않는 한 다시 재생성하지 않아도 됩니다. 추출할 때마다 지수를 생성하려면 추출 설정에서 해당 옵션을 선택할 수 있습니다. 자세한 정보는 데이터 추출의 내용을 참조하십시오.

## 5) 추출 결과 세분화

추출은 결과를 추출 및 검토하고 추출을 변경한 후 다시 추출하여 결과를 업데이트하는 반복적 프로세스입니다. 정확도와 연속성이 성공적인 텍스트 마이닝 및 범주화에 필수적이므로, 시작부터 추출 결과를 미세 조정하는 것이 재추출할 때마다 범주 정의에서 정확하게 동일한 결과를 얻도록 보장합니다. 이 방법으로 레코드 및 문서가 더 정확하고 반복 가능한 방식으로 범주에 지정됩니다.

추출 결과는 범주에 대한 구성 요소의 역할을 합니다. 이들 추출 결과를 사용하여 범주를 작성할 때, 레코드 및 문서가 하나 이상의 범주 디스크립터와 매치하는 텍스트를 포함하는 경우 자동으로 범주에 지정됩니다. 언어학적 자원에 대한 세분화를 수행하기 전에 범주화를 시작할 수 있지만, 시작하기 전에 최소한 한 번은 추출 결과를 검토하는 것이 유용합니다.

결과를 검토할 때 추출 엔진이 상이하게 처리하기 원하는 요소를 발견할 수 있습니다. 다음 예제를 고려하십시오.

- **인식되지 않는 동의어.** smart, intelligent, bright, knowledgeable 같이 동의어인 것으로 간주하는 여러 개의 개념을 발견하고, 이들이 모두 추출 결과에 개별 개념으로 나타난다고 가정하십시오. intelligent, bright, knowledgeable이 대상 개념 smart 아래에 모두 그룹화되는 동의어 정의를 작성할 수 있습니다. 그렇게 하면 이들 모두가 smart와 그룹화되고, 글로벌 빈도 수는 더 높아집니다. 자세한 정보는 동의어 추가의 내용을 참조하십시오.
- **맞춤법이 틀린 개념.** 추출 결과의 개념들이 하나의 유형에 나타나며 이들 개념이 또 다른 유형에 지정되기 원한다고 가정하십시오. 또 다른 예제에서, 추출 결과에서 15개의 채소 개념을 발견하고 이들 모두가 <야채>라는 새 유형에 추가될 원한다고 상상하십시오. 유형 사전에는 없고 텍스트에서는 추출된 대부분의 언어의 경우, 개념은 자동으로 <Unknown>으로 유형이 지정됩니다. 개념을 유형에 추가할 수 있습니다. 자세한 정보는 유형에 개념 추가의 내용을 참조하십시오.
- **무의미한 개념.** 추출되었고 매우 높은 빈도 수를 갖는 개념을 발견한다고 가정하십시오. 즉 많은 레코드 또는 문서에서 발견됩니다. 그러나 이 개념이 사용자 분석에는 중요하지 않다고 간주합니다. 이 개념을 추출에서 제외시킬 수 있습니다. 자세한 정보는 추출에서 개념 제외의 내용을 참조하십시오.
- **올바르지 않은 매치.** 특정 개념을 포함하는 레코드 또는 문서를 검토할 때 faculty와 facility와 같이 두 개의 단어가 올바르게 그룹화되었음을 발견한다고 가정하십시오. 이 매치는 공통된 철자법 오류를 그룹화하기 위해 이중 또는 삼중 자음과 모음을 일시적으로 무시하는 퍼지 그룹화하는 내부 알고리즘이 원인일 수 있습니다. 이들 단어를 그룹화되지 않아야 하는 단어 쌍의 목록에 추가할 수 있습니다. 자세한 정보는 퍼지 그룹화의 내용을 참조하십시오.
- **추출되지 않는 개념.** 추출된 특정 개념을 찾을 것으로 예상하지만 레코드 또는 문서 텍스트를 검토할 때 몇 개의 단어나 구가 추출되지 않았음을 알 것으로 가정하십시오. 종종 이들 단어는 사용자가 관심을 갖지 않는 동사나 형용사입니다. 그러나 가끔은 범주 정의의 일부로서 추출되지 않은 단어나 구를 사용하기 원합니다. 개념을 추출하기 위해 용어를 유형 사전에 강제 실행할 수 있습니다. 자세한 정보는 단어 강제 추출의 내용을 참조하십시오.

이들 변경의 많은 수가 하나 이상의 요소를 선택하고 마우스 오른쪽 단추를 클릭하여 컨텍스트 메뉴에 액세스하여 추출 결과 분할창, 데이터 분할창, 범주 정의 대화 상자 또는 클러스터 정의 대화 상자에서 직접 수행할 수 있습니다.

변경을 수행한 후, 분할창 배경 색상이 변하여 변경사항을 보려면 재추출해야 함을 표시합니다. 자세한 정보는 데이터 추출의 내용을 참조하십시오. 더 큰 데이터 세트에 대해 작업 중인 경우, 각 변경 후가 아니라 여러 개의 변경을 수행한 후 다시 추출하는 것이 더 효율적일 수 있습니다.

**참고:** 자원 편집기 보기(보기 > 자원 편집기)에서 추출 결과를 생성하는 데 사용된 편집 가능한 언어학적 자원의 전체 세트를 볼 수 있습니다. 이들 자원은 이 보기에서 라이브러리 및 사전의 양식으로 나타납니다. 라이브러리 및 사전 안에서 개념과 유형을 직접 사용자 정의할 수 있습니다. 자세한 정보는 라이브러리에 대한 작업의 내용을 참조하십시오.

## (1) 동의어 추가

*동의어*는 동일한 의미를 가지고 있는 두 개 이상의 단어를 연관시킵니다. 동의어는 또한 용어를 약어와 그룹화하거나 공통적으로 맞춤법이 틀린 단어를 올바른 맞춤법과 그룹화하는 데 사용됩니다. 동의어를 사용하면 대상 개념의 빈도가 더 큰데, 이것은 텍스트 데이터에서 여러 가지 방법으로 제시되는 유사한 정보를 발견하기가 훨씬 더 쉽게 만듭니다.

제품과 함께 제공되는 언어학적 자원 템플릿과 라이브러리는 많은 사전 정의된 동의어를 포함하고 있습니다. 그러나 인식되지 않는 동의어를 발견하는 경우, 다음에 추출할 때는 인식되도록 동의어를 정의할 수 있습니다.

첫 번째 단계는 대상 또는 리드, 개념이 무엇인지 결정하는 것입니다. *대상 개념*은 최종 결과에서 모든 동의어 용어를 그룹화하려는 단어나 구입니다. 추출 중에 동의어는 이 대상 개념 아래에 그룹화됩니다. 두 번째 단계는 이 개념에 대한 모든 동의어를 식별하는 것입니다. 대상 개념이 최종 추출에서 모든 동의어에 대해 대체됩니다. 용어가 동의어가 되도록 추출되어야 합니다. 그러나 대체가 발생하기 위해 대상 개념이 추출될 필요는 없습니다. 예를 들어, intelligent가 smart로 대체되기 원하는 경우, intelligent는 동의어이고 smart는 대상 개념입니다.

새 동의어 정의를 작성하는 경우 새 대상 개념이 사전에 추가됩니다. 그런 다음 동의어를 해당 대상 개념에 추가해야 합니다. 동의어를 작성 또는 편집할 때마다, 이들 변경이 자원 편집기의 동의어 사전에 기록됩니다. 이들 동의어 사전의 전체 내용을 보거나 상당한 수의 변경을 작성하려는 경우 자원 편집기에서 직접 작업하는 것이 더 좋을 수 있습니다. 자세한 정보는 대체/동의어 사전의 내용을 참조하십시오.

모든 새 동의어는 자동으로 자원 편집기 보기에 있는 라이브러리 트리에 나열되는 첫 번째 라이브러리에 저장되는데, 기본적으로 이것은 로컬 라이브러리입니다.

**참고:** 동의어 정의를 찾고 컨텍스트 메뉴를 통해서 또는 자원 편집기에서 직접 찾을 수 없는 경우, 내부 퍼지 그룹화 기법으로부터 매치가 발생했을 수 있습니다. 자세한 정보는 퍼지 그룹화의 내용을 참조하십시오.

## 새 동의어 작성 방법

1. 추출 결과 분할창 , 데이터 분할창, 범주 정의 대화 상자 또는 클러스터 정의 대화 상자 중 하나에서, 새 동의어를 작성하려는 개념을 선택하십시오.
2. 메뉴에서 **편집 > 동의어에 추가 > 새로 만들기**를 선택하십시오. 동의어 작성 대화 상자가 열립니다.
3. 대상 텍스트 상자에 대상 개념을 입력하십시오. 이것은 모든 동의어가 그 아래에 그룹화되는 개념입니다.
4. 더 많은 동의어를 추가하려면 동의어 목록 상자에서 입력하십시오. 각 동의어 용어를 구분하려면 글로벌 구분 문자를 사용하십시오. 자세한 정보는 옵션: 세션 탭 주제를 참조하십시오.
5. **확인**을 클릭하여 변경사항을 적용하십시오. 대화 상자가 닫히고 추출 결과 분할창 배경 색상이 변경되어 변경사항을 보려면 다시 추출해야 함을 표시합니다. 변경이 여러 개인 경우 재추출 전에 변경하십시오.

## 동의어 추가 방법

1. 추출 결과 분할창 , 데이터 분할창, 범주 정의 대화 상자 또는 클러스터 정의 대화 상자 중 하나에서, 기존 동의어 정의에 추가하려는 개념을 선택하십시오.
2. 메뉴에서 **편집 > 동의어에 추가**를 선택하십시오. 메뉴는 목록의 맨 위에 가장 최근에 작성된 동의어의 세트를 표시합니다. 선택된 개념을 추가하려는 동의어의 이름을 선택하십시오. 찾고 있는 동의어가 보이면 해당 동의어를 선택하십시오. 개념이 해당 동의어 정의에 추가됩니다. 보이지 않는 경우 **기타**를 선택하여 모든 동의어 대화 상자를 표시하십시오.
3. 모든 동의어 대화 상자에서 목록을 자연적 정렬순(작성 순서)으로 또는 오름차순이나 내림차순으로 정렬할 수 있습니다. 선택된 개념을 추가하려는 동의어의 이름을 선택하고 **확인**을 클릭하십시오. 대화 상자가 닫히고, 개념이 동의어 정의에 추가됩니다.

### (2) 유형에 개념 추가

추출이 실행될 때마다, 추출된 개념이 공통적인 어떤 것을 갖는 용어를 그룹화하기 위해 유형에 지정됩니다. IBM® SPSS® Modeler Text Analytics 는 많은 내장된 유형과 함께 제공됩니다. 자세한 정보는 내장 유형의 내용을 참조하십시오. 유형 사전에는 없고 텍스트에서는 추출된 대부분의 언어의 경우, 개념은 자동으로 <Unknown>으로 유형이 지정됩니다.

결과를 검토할 때 한 유형에 나타나는 일부 개념이 다른 유형에 지정되기 원하거나 단어 그룹이 그 자체가 실제로는 새로운 유형에 속함을 발견할 수 있습니다. 이런 경우, 개념을 다른 유형에 다시 지정하거나 새 유형을 함께 작성하기 원할 것입니다.

예를 들어, 자동차 관련 설문조사 데이터에 대해 작업 중이며 차량의 여러 가지 영역에 집중하

여 범주화하는 데 관심이 있다고 가정하십시오. <대시보드>라는 유형을 작성하여 차량의 대시보드에 있는 계기 및 손잡이와 관련된 모든 개념을 그룹화할 수 있습니다. 그런 다음 해당하는 새 유형에 연료 계기, 히터, 라디오, 주행 기록계 같은 개념을 지정할 수 있습니다.

또 다른 예에서, 대학 및 전문대학과 관련된 설문조사 데이터에서 Johns Hopkins(대학)를 <조직> 유형이 아니라 <사람> 유형으로 갖는 추출에 대해 작업 중이라고 가정하십시오. 이 경우 이 개념을 <조직> 유형에 추가할 수 있습니다.

유형을 작성하거나 유형의 용어 목록에 개념을 추가할 때마다, 이들 변경사항이 자원 편집기에 있는 언어학적 자원 라이브러리의 유형 사전에 기록됩니다. 이들 사전의 내용을 보거나 상당한 수의 변경을 작성하려는 경우 자원 편집기에서 직접 작업하는 것이 더 좋을 수 있습니다. 자세한 정보는 용어 추가의 내용을 참조하십시오.

## 유형에 개념을 추가하는 방법

1. 추출 결과 분할창, 데이터 분할창, 범주 정의 대화 상자 또는 클러스터 정의 대화 상자 중 하나에서, 기존 유형에 추가하려는 개념을 선택하십시오.
2. 마우스 오른쪽 단추를 클릭하여 컨텍스트 메뉴를 여십시오.
3. 메뉴에서 **편집 > 유형에 추가**를 선택하십시오. 메뉴는 목록의 맨 위에 가장 최근에 작성된 유형의 세트를 표시합니다. 선택된 개념을 추가하려는 유형 이름을 선택하십시오. 찾고 있는 유형 이름이 보이면 해당 유형을 선택하십시오. 개념이 해당 유형에 추가됩니다. 보이지 않는 경우 **기타**를 선택하여 모든 유형 대화 상자를 표시하십시오.
4. 모든 유형 대화 상자에서 목록을 자연적 정렬(작성 순서)로 또는 오름차순이나 내림차순으로 정렬할 수 있습니다. 선택된 개념을 추가하려는 유형의 이름을 선택하고 **확인**을 클릭하십시오. 대화 상자가 닫히고, 개념이 유형에 용어로서 추가됩니다.

## 새 유형을 작성하는 방법

1. 추출 결과 분할창, 데이터 분할창, 범주 정의 대화 상자 또는 클러스터 정의 대화 상자 중 하나에서, 새 유형을 작성하려는 개념을 선택하십시오.
2. 메뉴에서 **편집 > 유형에 추가 > 새로 만들기**를 선택하십시오. 유형 특성 대화 상자가 열립니다.
3. 이름 텍스트 상자에 이 유형에 대한 새 이름을 입력하고 기타 필드를 필요에 따라 변경하십시오. 자세한 정보는 유형 작성의 내용을 참조하십시오.
4. **확인**을 클릭하여 변경사항을 적용하십시오. 대화 상자가 닫히고 추출 결과 분할창 배경 색상이 변경되어 변경사항을 보려면 다시 추출해야 함을 표시합니다. 변경이 여러 개인 경우 재추출 전에 변경하십시오.

### (3) 추출에서 개념 제외

결과를 검토할 때 가끔 임의의 자동화된 범주 작성 기법에 의해 추출 또는 사용되길 원하지 않은 개념을 찾을 수 있습니다. 어떤 경우에는 이들 개념이 아주 높은 빈도수를 갖고 있으며 사용자 분석에 전혀 의미가 없습니다. 이 경우에는 최종 추출에서 제외되도록 개념을 표시할 수 있습니다. 일반적으로 이 목록에 추가하는 개념은 연속성을 위해 텍스트에서 사용되지만 어떤 중요한 것을 추가하지 않으며 추출 결과를 어수선하게 만들 수 있는 채우기 단어나 구입니다. 개념을 제외 사전에 추가하면 해당 개념이 추출되지 않도록 보장할 수 있습니다.

개념을 제외시키면 제외된 개념의 모든 변종이 다음에 추출하는 추출 결과에서 사라집니다. 이 개념이 이미 범주에 디스크립터로 나타나는 경우 재추출 후 0의 개수를 갖고 범주에 남아 있습니다.

제외시킬 때 이들 변경은 자원 편집기의 제외 사전에 기록됩니다. 모든 제외 정의를 보고 직접 편집하려는 경우, 자원 편집기에서 직접 작업할 것을 선호할 수 있습니다. 자세한 정보는 제외 사전의 내용을 참조하십시오.

### 개념을 제외하는 방법

1. 추출 결과 분할창, 데이터 분할창, 범주 정의 대화 상자 또는 클러스터 정의 대화 상자 중 하나에서, 추출에서 제외하려는 개념을 선택하십시오.
2. 마우스 오른쪽 단추를 클릭하여 컨텍스트 메뉴를 여십시오.
3. **추출에서 제외**를 선택하십시오. 개념이 자원 편집기의 제외 사전에 추가되며 추출 결과 분할창 배경 색상이 변경되어 변경사항을 보려면 재추출해야 함을 표시합니다. 변경이 여러 개인 경우 재추출 전에 변경하십시오.

 **참고:** 제외하는 모든 단어가 자동으로 자원 편집기의 라이브러리 트리에 나열되는 첫 번째 라이브러리에 저장됩니다. 기본적으로 이것은 로컬 라이브러리입니다.

### (4) 단어 강제 추출

추출 후 데이터 분할창에서 텍스트 데이터를 검토할 때, 일부 단어나 문구가 추출되지 않았음을 발견할 수 있습니다. 보통 이들 단어는 사용자가 관심이 없는 동사나 형용사입니다. 그러나 가끔은 범주 정의의 일부로서 추출되지 않은 단어나 구를 사용하기 원합니다.

이들 단어와 구가 추출되기 원하는 경우 용어를 강제로 유형 라이브러리로 넣을 수 있습니다. 자세한 정보는 용어 강제 실행의 내용을 참조하십시오.

**중요!** 사전에서 용어를 강제 실행으로 표시하는 것은 간단하지 않습니다. 이것은 용어를 사전에

명시적으로 추가했음에도 불구하고 재추출한 후 추출 결과 분할창에 존재하지 않거나 나타나지만 사용자가 선언한 것처럼 정확하게 나타나지 않을 수 있음을 의미합니다. 이런 현상이 드물긴 하지만, 단어나 구가 이미 더 긴 구의 일부로 추출된 경우에 발생할 수 있습니다. 이를 방지하기 위해서 유형 사전에서 이 용어에 **전체(복합 아님)** 매치 옵션을 적용하십시오. 자세한 정보는 용어 추가의 내용을 참조하십시오.

## 9. 텍스트 데이터 범주화

범주 및 개념 보기 에서, 텍스트에서 표현되는 핵심 아이디어, 지식 및 태도를 캡처하는 본질적으로 상위 레벨 개념 또는 주제를 나타내는 범주를 작성할 수 있습니다.

IBM® SPSS® Modeler Text Analytics 14 릴리스 현재, 범주는 계층 구조를 가질 수 있는데, 하위 범주를 포함할 수 있고 하위 범주도 그 자신의 하위 범주를 가질 수 있음을 의미합니다. 이전에는 코드 프레임이라고 불렸고 계층 구조 범주를 갖는 사전 정의된 범주 구조를 가져오고 이들 계층 구조 범주를 제품 안에서 작성할 수 있습니다.

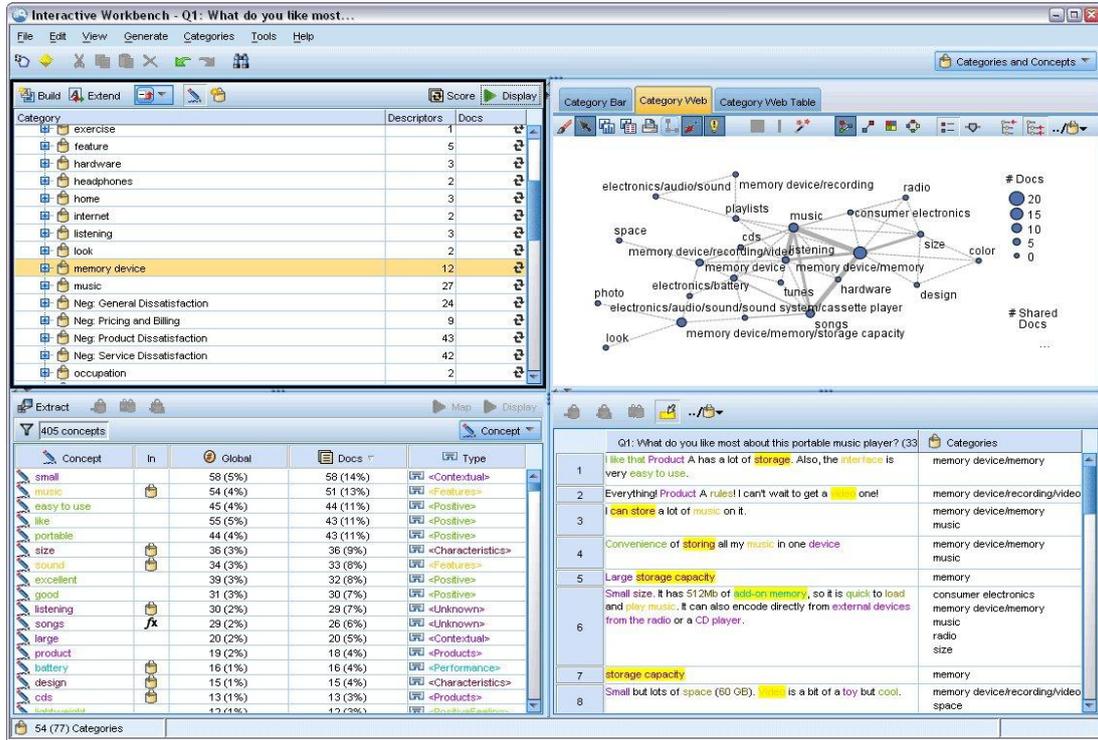
사실상, 계층 구조 범주는 사용자가 하나 이상의 하위 범주를 갖는 트리 구조를 작성하여 여러 가지 개념이나 주제 영역 같은 항목을 더 정확하게 그룹화할 수 있게 합니다. 단순한 예를 레저 활동과 관련시킬 수 있습니다. *시간이 더 있다면 어떤 활동을 하시겠습니까?* 같은 질문에 응답함으로써 *스포츠, 예술 및 공예, 낚시* 등과 같은 최상위 범주를 갖고, *스포츠* 아래에 *구기 종목, 물 관련* 등인지를 보기 위한 하위 범주를 가질 수 있습니다.

범주는 *개념, 유형, 패턴, 범주 규칙* 같은 디스크립터 세트로 구성됩니다. 이들 디스크립터는 함께 사용되어 문서 또는 레코드가 주어진 범주에 속하는지 여부를 식별합니다. 문서 또는 레코드 내의 텍스트를 스캔하여 임의의 텍스트가 디스크립터와 매치하는지 확인할 수 있습니다. 매치가 발견되면 문서/ 레코드가 해당 범주에 지정됩니다. 이 프로세스를 *범주화*라고 부릅니다.

범주 및 개념 보기의 4개의 분할창에 제공되는 데이터를 사용하여 범주를 작업, 작성 및 시각적으로 탐색할 수 있는데, 각 분할창은 보기 메뉴에서 이름을 선택하여 숨기거나 표시할 수 있습니다.

- **범주 분할창.** 이 분할창에서 범주를 작성 및 관리합니다. 자세한 정보는 범주 분할창의 내용을 참조하십시오.
- **추출 결과 분할창.** 이 분할창에서 추출된 개념 및 유형을 탐색하고 그에 대해 작업합니다. 자세한 정보는 추출 결과: 개념 및 유형 주제를 참조하십시오.
- **시각화 분할창.** 이 분할창에서 범주 및 범주가 상호작용하는 방법을 시각적으로 탐색합니다. 자세한 정보는 범주 그래프 및 도표 주제를 참조하십시오.
- **데이터 분할창.** 이 분할창에서 선택에 대응하는 문서 및 레코드 안에 있는 텍스트를 탐색하고 검토합니다. 자세한 정보는 데이터 분할창 주제를 참조하십시오.

그림 1. 범주 및 개념 보기



텍스트 분석 패키지(TAP)의 범주 세트로 시작하거나 사전 정의된 범주 파일을 가져올 수 있지만, 사용자 스스로 범주를 작성해야 할 수도 있습니다. 범주는 제품의 강력한 자동화 기법 세트를 사용하여 자동으로 작성될 수 있는데, 이것은 추출 결과(개념, 유형 및 패턴)를 사용하여 범주 및 해당 디스크립터를 생성합니다. 범주는 또한 사용자가 데이터에 관하여 가질 수 있는 추가 직관을 사용하여 수동으로 작성할 수도 있습니다. 그러나 대화형 워크벤치를 통해서만 범주를 수동으로 작성하거나 세분화할 수 있습니다. 자세한 정보는 텍스트 마이닝 노트: 모델 탭 주제를 참조하십시오. 추출 결과를 범주로 끌어다 놓아서 수동으로 범주 정의를 작성할 수 있습니다. 범주 규칙을 범주에 추가하거나 사용자 자신의 사전 정의된 범주를 사용하거나, 조합하여 이들 범주 또는 빈 범주를 강화할 수 있습니다.

각 기법과 방법은 특정 유형의 데이터 및 상황에 잘 맞지만, 보통 동일한 분석에서 기법을 조합하여 문서 또는 레코드의 전체 범위를 캡처하는 것이 도움이 됩니다. 또한 범주화 과정에서 언어학적 자원에 수행되는 기타 변경을 볼 수 있습니다.

## 1) 범주 분할창

범주 분할창은 범주를 작성하고 관리할 수 있는 영역입니다. 이 분할창은 범주 및 개념 보기의 왼쪽 상단 구석에 위치합니다. 텍스트 데이터에서 개념 및 유형을 추출할 후, 개념 포함, 동시 발생 등과 같은 기법을 사용하여 자동으로 또는 수동으로 범주 작성을 시작할 수 있습니다. 자세한 정보는 범주 작성의 내용을 참조하십시오.

범주가 작성 또는 업데이트될 때마다, 문서 또는 레코드는 **스코어** 단추를 클릭하여 스코어링하여 임의의 텍스트가 주어진 범주의 디스크립터와 매치하는지 여부를 확인할 수 있습니다. 매치가 발견되면 문서 또는 레코드가 해당 범주에 지정됩니다. 최종 결과는 전부는 아니더라도 대부분의 문서 또는 레코드가 범주의 디스크립터를 바탕으로 범주에 지정되는 것입니다.

 **참고:** 분할창에 표시할 수 있는 수보다 범주 수가 많은 경우, 분할창의 맨 아래쪽에 있는 제어를 사용하여 범주 앞 또는 뒤로 이동하거나 이동할 페이지 수를 입력할 수 있습니다.

## 범주 트리 테이블

이 분할창의 트리 테이블은 범주, 하위 범주 및 디스크립터의 세트를 나타냅니다. 트리는 또한 각 트리 항목의 정보를 제공하는 여러 개의 열을 갖고 있습니다. 표시할 수 있는 열은 다음과 같습니다.

- **코드** 각 범주의 코드 값을 나열합니다. 이 열은 기본적으로 숨겨져 있습니다. **보기 > 범주 분할창** 메뉴를 사용하여 이 열을 표시할 수 있습니다.
- **범주.** 범주 및 하위 범주의 이름을 표시하는 포함 트리를 포함합니다. 또한 디스크립터 도구 모음이 클릭되는 경우 디스크립터 세트도 표시됩니다.
- **디스크립터.** 정의를 구성하는 디스크립터의 수를 제공합니다. 이 숫자는 하위 범주에 있는 디스크립터 수는 포함하지 않습니다. 디스크립터 이름이 **범주** 열에 표시되면 개수는 제공되지 않습니다. **보기 > 범주 분할창 > 모든 디스크립터** 메뉴를 통해 트리에서 디스크립터 자체를 표시하거나 숨길 수 있습니다.
- **문서 스코어링 후,** 이 열은 범주 및 해당 범주의 모든 하위 범주로 범주화되는 문서 또는 레코드의 수를 제공합니다. 따라서 5개 레코드가 디스크립터를 바탕으로 최상위 범주와 매치하고 7개의 다른 레코드가 디스크립터를 바탕으로 하위 범주에 매치하는 경우, 최상위 범주에 대한 총 문서 수는 둘의 합이며, 이 경우에는 12입니다. 그러나 동일한 레코드가 최상위 범주 및 그의 하위 범주와 매치한 경우 개수는 11입니다.

범주가 없을 때 테이블은 여전히 두 개의 행을 포함합니다. **모든 문서**라고 부르는 최상위 행은 문서 또는 레코드의 총 수입니다. **범주화 안됨**이라는 두 번째 열은 아직 범주화되지 않은 문서/레코드의 수를 표시합니다.

분할창의 각 범주에 대해 작은 노란색 버킷 아이콘이 범주 이름 앞에 표시됩니다. 범주를 두 번 클릭하거나 선택하거나 메뉴에서 **보기 > 범주 정의를** 클릭하는 경우, 범주 정의 대화 상자가 열리고 개념, 유형, 패턴 및 범주 규칙 같이 정의를 구성하는 *디스크립터*라는 모든 요소를 표시합니다. 자세한 정보는 범주 정보의 내용을 참조하십시오. 기본적으로 범주 트리 테이블은 범주의 디스크립터를 표시하지 않습니다. 범주 정의 대화 상자에서가 아니라 트리에서 직접 디스크립터를 보려는 경우, 도구 모음의 연필 아이콘을 갖는 전환 단추를 클릭하십시오. 이 전환 단추를 선택되면 트리를 펼쳐서 디스크립터도 볼 수 있습니다.

## 범주 스코어링

범주 트리 테이블의 문서 열은 해당 특정 범주로 범주화되는 문서 또는 레코드의 수를 표시합니다. 숫자가 오래 되었거나 계산되지 않은 경우 해당 열에 아이콘이 나타납니다. 분할창 도구 모음의 스코어를 클릭하여 문서 수를 다시 계산할 수 있습니다. 더 큰 데이터 세트에 대해 작업 중일 때는 스코어링 프로세스가 다소 시간이 걸릴 수 있음을 기억하십시오.

## 트리에서 범주 선택

트리에서 선택할 때, 동위 범주만 선택할 수 있습니다. 즉, 최상위 범주를 선택하는 경우 하위 범주도 선택할 수는 없습니다. 또는 주어진 범주의 2 하위 범주를 선택하는 경우, 또 다른 범주의 하위 범주를 동시에 선택할 수 없습니다. 불연속적인 범주를 선택하면 이전 선택이 유실됩니다.

## 데이터 및 시각화 분할창에 표시

테이블에서 행을 선택할 때, 표시 단추를 클릭하여 사용자 선택에 대응하는 정보로 시각화 및 데이터 분할창을 새로 고칠 수 있습니다. 분할창이 표시될 수 없는 경우 표시를 클릭하면 해당 분할창이 나타납니다.

## 범주 세분화

범주화가 첫 번째 시도에서 사용자 데이터에 대한 완벽한 결과를 생성하지 않을 수 있으며, 삭제하거나 다른 범주와 결합하기 원하는 범주도 있을 수 있습니다. 또한 추출 결과의 검토를 통해서 유용하다고 생각하는 몇 가지 범주가 작성되지 않았음을 발견할 수도 있습니다. 그런 경우, 결과를 수동으로 변경하여 특정 컨텍스트에 맞게 세분화할 수 있습니다. 자세한 정보는 범주 편집 및 세분화 주제를 참조하십시오.

## 2) 범주 작성을 위한 방법 및 전략

아직 추출하지 않았거나 추출 결과가 오래된 경우에는 범주 작성 또는 확장 기술 중 하나를 사용하면 추출하라는 메시지가 자동으로 프롬프트됩니다. 기술을 적용한 후에도 범주로 그룹화된 개념과 유형은 여전히 다른 기술로 범주 작성 시 사용할 수 있습니다. 즉, 이를 재사용하지 않도록 선택하지 않는 한 여러 범주에서 개념을 볼 수 있음을 의미합니다.

최상의 범주를 작성하기 위해서는 다음을 검토하십시오.

- **범주 작성 방법.** 자세한 정보는 범주 작성 방법 주제를 참조하십시오.
- **범주 작성 전략.** 자세한 정보는 범주 작성 전략의 내용을 참조하십시오.
- **범주 작성 팁.** 자세한 정보는 범주 작성을 위한 팁 주제를 참조하십시오.

## (1) 범주 작성 방법

모든 데이터 세트가 고유하므로 범주 작성 방법의 수와 이를 적용하는 순서는 시간에 따라 변경될 수 있습니다. 또한 텍스트 마이닝 목적은 한 데이터 세트와 다음 데이터 세트마다 다르므로, 여러 가지 방법을 시도하여 어떤 방법이 지정된 텍스트 데이터별로 최상의 결과를 낼 수 있는지를 살펴볼 필요가 있습니다. 자동 기술은 데이터를 완벽하게 범주화합니다. 그러므로 사용자의 데이터에 가장 적합한 하나 이상의 자동 기술을 찾아서 적용하는 것이 좋습니다.

범주 세트가 미리 작성된 텍스트 분석 패키지(TAP, \*.tap)를 사용하는 것 외에도 다음 방법의 조합을 사용하여 반응을 범주화할 수도 있습니다.

- **자동 작성 기술.** 범주를 자동으로 작성하기 위해 몇몇 언어학적 기반 및 빈도 기반 범주 옵션을 사용할 수 있습니다. 자세한 정보는 범주 작성의 내용을 참조하십시오.
- **자동 확장 기술.** 더 많은 레코드를 캡처할 수 있도록 디스크립터를 추가하거나 개선하여 기존 범주를 확장하는 데 여러 언어학적 기술을 사용할 수 있습니다. 자세한 정보는 범주 확장의 내용을 참조하십시오.
- **수동 기술.** 끌어다 놓기 등과 같은 여러 수동 방법이 있습니다. 자세한 정보는 수동으로 범주 작성의 내용을 참조하십시오.

## (2) 범주 작성 전략

다음 전략 목록은 결코 완전하지는 않지만 범주 작성 방법에 대한 몇 가지 아이디어를 제공할 수 있습니다.

- 텍스트 마이닝 모드를 정의할 때, 몇몇 사전 정의된 범주의 분석을 시작할 수 있도록 텍스트 분석 패키지(TAP)에서 범주 세트를 선택하십시오. 이러한 범주는 텍스트를 처음부터 충분히 범주화할 수 있습니다. 그러나 더 많은 범주를 추가하려는 경우에는 범주 작성 설정(**범주 > 작성 설정**)을 편집할 수 있습니다. **고급 설정: 언어학** 대화 상자를 열고 범주 입력 옵션 **사용되지 않은 추출 결과**를 선택하고 추가 범주를 작성하십시오.
- 노드를 정의할 때, 대화식 워크벤치의 범주 및 개념 보기에 있는 TAP에서 범주 세트를 선택하십시오. 그런 다음 사용되지 않은 개념 또는 패턴을 적합하다고 생각되는 범주에 끌어다 놓으십시오. 그런 다음 방금 편집한 기존 범주(**범주 > 확장된 범주**)를 확장하여 기존 범주 디스크립터와 관련된 더 많은 디스크립터를 획득하십시오.
- 고급 언어학적 설정(**범주 > 범주 작성**)을 사용하여 자동으로 범주를 작성하십시오. 그런 다음 디스크립터를 삭제하고, 범주를 삭제하거나 결과로 나온 범주에 만족할 때까지 유사한 범주를

병합하여 범주를 수동으로 세분화하십시오. 또한 원래 가능한 경우 와일드카드 일반화 옵션을 사용하지 **않고** 범주를 작성한 경우에는 **일반화** 옵션을 사용하여 범주 확장을 사용하여 범주를 자동으로 단순화하려고 시도할 수도 있습니다.

- 설명적인 범주 이름 및/또는 주석(Annotation)을 사용하여 사전에 정의된 범주 파일을 가져오십시오. 또한 원래 가져올 옵션을 선택하거나 범주 이름에서 디스크립터를 생성하지 **않고** 가져온 경우에는 나중에 범주 확장 대화 상자를 사용하고 **범주 이름에서 생성된 디스크립터를 사용하여 빈 범주 확장** 옵션을 선택할 수 있습니다. 그런 다음 이러한 범주를 두 번째로 확장하지만 이번에는 그룹화 기술을 사용하십시오.
- 개념 또는 개념 패턴을 빈도 기준으로 정렬한 다음 가장 흥미로운 범주를 범주 분할창에 끌어다 놓는 방법으로 첫 번째 범주 세트를 수동으로 작성하십시오. 초기 범주 세트가 생긴 후에는 확장 기능(**범주 > 범주 확장**)을 사용하여 다른 관련된 디스크립터를 포함하고 더 많은 레코드와 매치할 수 있도록 선택한 모든 범주를 확장하고 세분화하십시오.

이러한 기술을 적용한 후에는 결과로 나온 범주를 검토하고 수동 기술을 사용하여 약간의 조정을 수행하고, 잘못된 분류를 제거하거나 누락된 레코드나 단어를 추가하는 것이 좋습니다. 또는 서로 다른 기술을 사용하면 중복된 범주가 생길 수 있으므로 필요에 따라 범주를 병합하거나 삭제할 수도 있습니다. 자세한 정보는 범주 편집 및 세분화 주제를 참조하십시오.

### (3) 범주 작성을 위한 팁

더 좋은 범주를 작성하기 위해서 접근 방식에서 결정하도록 도와줄 수 있는 몇 가지 팁을 검토할 수 있습니다.

#### 범주 대 문서 비율에 대한 팁

문서 및 레코드가 지정되는 범주는 보통 다음 두 가지 이상의 이유로 정성적 텍스트 분석에서 상호 배타적이지 않습니다.

- 첫 번째, 일반적인 방법은 텍스트 문서 또는 레코드가 길수록, 표현되는 아이디어와 의견이 더 명확하다는 것입니다. 따라서 문서 또는 레코드가 다중 범주에 지정될 수 있는 기회가 크게 늘어납니다.
- 두 번째, 종종 논리적으로 구별되지 않는 텍스트 문서 또는 레코드를 그룹화하고 해석하는 다양한 방법이 있습니다. 반응자의 정치적 신념에 관한 개방형 질문을 갖는 설문조사의 경우, **진보와 보수** 또는 **공화당원과 민주당원** 같은 범주뿐 아니라 **사회적 진보, 재정적 보수** 등과 같은 보다 특정한 범주를 작성할 수 있습니다. 이들 범주는 상호 배타적이고 철저히 할 필요가 없습니다.

#### 작성할 범주의 수에 대한 팁

범주 작성은 데이터에서 직접 진행되어야 합니다. 데이터에 관해서 관심있는 어떤 것을 볼 때 해당 정보를 나타내기 위한 범주를 작성할 수 있습니다. 일반적으로 작성하는 범주 수에 대한

권장 상한은 없습니다. 그러나 너무 많은 범주를 작성하면 확실히 관리하기가 어려울 수 있습니다. 다음 두 가지 원리가 적용됩니다.

- **범주 빈도.** 범주가 유용하려면 최소 숫자의 문서 또는 레코드를 포함해야 합니다. 한두 개의 문서가 아주 흥미로운 어떤 것을 포함할 수 있지만, 1,000개의 문서 중 한두 개가 있는 경우 거기에 포함된 정보는 실질적으로 유용하기 위해 인구에서 충분히 빈번하지 않을 수 있습니다.
- **복잡도.** 더 많은 범주를 작성할수록 분석을 완료한 후 더 많은 정보를 검토하고 요약해야 합니다. 그러나 너무 많은 범주는 복잡도를 추가하면서도 유용한 세부사항을 추가하지 않을 수 있습니다.

불행하게도, 얼마나 많은 범주가 너무 많은지 판별하거나 범주당 최소 레코드 수를 판별하기 위한 규칙은 없습니다. 사용자의 특정 상황의 수요를 바탕으로 그런 판단을 내려야 합니다.

하지만 시작할 위치에 대해 조언할 수 있습니다. 범주 수가 과도하지 않아야 하지만, 분석의 초기 단계에서는 너무 적은 범주를 갖기 보다는 너무 많은 범주를 갖는 것이 더 좋습니다. 사례를 새로운 범주로 나누기 보다는 상대적으로 비슷한 범주를 그룹화하는 것이 더 쉬우므로, 많은 범주에서 더 적은 범주로 작업하는 전략이 대개 최상의 방법입니다. 텍스트 마이닝의 반복적 본질과 이 소프트웨어 프로그램으로 수행할 수 있는 용이성이 주어지면, 더 많은 범주를 작성하는 것이 시작 시에 유용한 방법입니다.

#### (4) 최상의 디스크립터 선택

다음 정보에는 범주에 대한 최상의 디스크립터(개념, 유형, TLA 패턴, 범주 규칙) 선택 또는 작성을 위한 몇 가지 지침이 들어 있습니다. 디스크립터는 범주의 구성 요소입니다. 문서 또는 레코드에 있는 텍스트의 일부 또는 전부가 디스크립터와 매치할 때, 문서 또는 레코드가 범주와 매치합니다.

디스크립터가 추출된 개념이나 패턴을 포함하거나 대응하지 않는 한, 어떤 문서 또는 레코드에도 매치하지 않습니다. 그러므로 다음 단락에서 설명하는 대로 개념, 유형, 패턴 및 범주 규칙을 사용하십시오.

개념은 그 자체뿐 아니라 복수형/단수형부터 동의어, 철자법 변형까지의 범위를 가질 수 있는 기본 용어 세트를 나타내므로, 개념 자체만 디스크립터 또는 디스크립터의 일부로 사용되어야 합니다. 임의의 주어진 개념에 대한 기본 용어에 대해 자세히 알려면 범주 및 개념 보기의 추출 결과 분할창에서 개념 이름을 클릭하십시오. 개념 이름 위에 마우스를 움직일 때 도구팁이 나타나고 마지막 추출 중에 텍스트에서 발견된 기본 용어 중 하나를 표시합니다. 모든 개념이 기본 용어를 갖지는 않습니다. 예를 들어, 자동차와 차량은 동의어이지만 자동차는 차량을 기본 용어로 갖는 개념으로 추출된 경우, 차량을 갖는 문서 또는 레코드와 자동으로 매치하므로 디스크립터에서 자동차만 사용하기 원합니다.

## 디스크립터로서의 개념 및 유형

해당 개념(또는 그의 기본 용어 중 하나)을 포함하는 모든 문서 또는 레코드를 찾기 원할 때 개념을 디스크립터로 사용하십시오. 이 경우에 정확한 개념 이름이 충분하므로 더 복잡한 범주 규칙은 필요 없습니다. 의견을 추출하는 자원을 사용할 때 가끔 문장의 더 진실한 의미를 캡처하기 위해 TLA 패턴 추출 중에 개념이 변할 수 있음을 기억하십시오(TLA에 대한 다음 절의 예를 참조).

예를 들어, "*사과와 파인애플이 최고*" 같이 각 개인의 좋아하는 과일을 표시하는 설문조사 응답은 사과 및 파인애플의 추출을 가져옵니다. 사과 개념을 디스크립터로서 범주에 추가하여 사과 (또는 그의 모든 기본 용어) 개념을 포함하는 모든 응답이 해당 범주에 매치됩니다.

그러나, 단순히 어떤 방법으로든지 *사과*를 언급하는 응답을 아는 것에 관심을 갖는 경우, \* 사과 \* 같은 범주 규칙을 작성할 수 있으며 사과, 사과 주스 또는 프랑스 사과 타르트 같은 개념을 포함하는 응답을 캡처합니다.

또한 <과일> 같이 유형을 디스크립터로서 직접 사용하여 동일한 방법으로 입력된 개념을 포함하는 모든 문서 또는 레코드를 캡처할 수도 있습니다. 유형에서는 \*를 사용할 수 없음을 주의하십시오.

자세한 정보는 추출 결과: 개념 및 유형 주제를 참조하십시오.

## 디스크립터로서의 텍스트 링크 분석(TLA) 패턴

더 미묘한 뉘앙스의 아이디어를 캡처하기 원할 때는 TLA 패턴 결과를 디스크립터로 사용하십시오. 텍스트가 TLA 추출 중에 분석될 때 텍스트는 전체 텍스트(문서 또는 레코드)를 보기 보다는 한 번에 하나의 문구나 절이 처리됩니다. 단일 문구의 모든 부분을 함께 고려함으로써, TLA는 의견, 두 요소 사이의 관계 또는 반대를 식별하고 예를 들어 더 진실한 의미를 이해할 수 있습니다. 개념 패턴이나 유형 패턴을 디스크립터로 사용할 수 있습니다. 자세한 정보는 유형 및 개념 패턴 주제를 참조하십시오.

예를 들어, "*방이 그렇게 정리되지 않았습니까?*"라는 텍스트가 있는 경우 방 및 정리 개념이 추출될 수 있습니다. 그러나 TLA 추출이 추출 설정에서 사용으로 설정된 경우, TLA는 정리가 부정적인 방식으로 사용되었고 실제로는 더러움의 동의어인 정리되지 않음에 해당함을 발견할 수 있습니다. 여기에서 그 자신에서 정리 개념을 디스크립터로 사용하는 것은 이 텍스트와 매치하지만 청결을 언급하는 다른 문서 또는 레코드도 캡처함을 알 수 있습니다. 그러므로 더러움을 갖는 TLA 개념 패턴을 출력 개념으로 사용하는 것이 더 좋을 수 있습니다. 이 개념은 이 텍스트와 매치하고 더 적합한 디스크립터일 수 있습니다.

## 디스크립터로서의 범주 비즈니스 규칙

범주 규칙은 문서 또는 레코드를 추출된 개념, 유형 및 패턴뿐만 아니라 부울 연산자를 사용하여 논리적 표현식을 기반으로 범주에 자동으로 분류하는 명령문입니다. 예를 들어, *추출된 개념*

embassy을 포함하지만 argentina는 포함하지 않는 모든 레코드를 이 범주에 포함을 의미하는 표현식을 작성할 수 있습니다.

범주에서 범주 규칙을 디스크립터로서 작성하고 사용하여 &, |, !() 부울을 사용하여 여러 가지 아이디어를 표현할 수 있습니다. 이들 규칙의 구문 및 규칙을 작성 및 편집하는 방법에 대한 상세한 정보는 범주 규칙 사용을 참조하십시오.

- 2개 이상의 개념이 발생하는 문서 또는 레코드를 찾는 데 도움을 얻으려면 &(AND) 부울 연산자를 갖는 범주 규칙을 사용하십시오. & 연산자에 의해 연결되는 둘 이상의 개념이 동일한 문구나 구에서 발생할 필요는 없으며 범주 매치로 간주될 동일한 문서 또는 레코드의 어디에서나 발생할 수 있습니다. 예를 들어, 범주 규칙 food & cheap를 디스크립터로서 작성하는 경우, "the food was pretty expensive, but the rooms were cheap" 텍스트를 포함하는 레코드와 매치합니다. food가 cheap가 꾸미는 명사가 아님에도 불구하고 텍스트가 food와 cheap를 둘 다 포함하기 때문입니다.
- 일부가 발생하지만 다른 것은 발생하지 않는 문서 또는 레코드를 찾는 데 도움을 받으려면 !()(NOT) 부울 연산자를 갖는 범주 규칙을 디스크립터로 사용하십시오. 이것은 단어를 바탕으로 하면 관련된 것처럼 보이지만 컨텍스트를 바탕으로 하면 관련되지 않을 수 있는 정보 그룹화를 피하는 데 도움이 될 수 있습니다. 예를 들어, 범주 규칙 <Organization> & !(ibm)을 디스크립터로 작성하는 경우 SPSS Inc. was a company founded in 1967 텍스트와 매치하고 the software company was acquired by IBM. 텍스트와는 매치하지 않습니다.
- 여러 가지 개념이나 유형 중 하나를 포함하는 문서 또는 레코드 중 하나를 찾으려면 |(OR) 부울 연산자를 디스크립터로 갖는 범주 규칙을 사용하십시오. 예를 들어 범주 규칙 (personnel | staff | team | coworkers) & bad를 디스크립터로 작성하는 경우, bad 개념을 갖는 명사 중 하나가 발견되는 모든 문서 또는 레코드와 매치합니다.
- 규칙을 더 일반적이고 가능하면 더 배치 가능하게 만들려면 범주 규칙에서 유형을 사용하십시오. 예를 들어, 호텔 데이터에 대해 작업 중인 경우 고객이 호텔 직원에 대해 생각하는 바를 배우는 데 매우 관심이 있을 수 있습니다. 관련 용어는 접수 담당자, 웨이터, 웨이트리스, 접수 데스크, 프런트 데스크 등의 단어를 포함할 수 있습니다. 이 경우에 <HotelStaff>이라는 새 유형을 작성하고 해당 유형에 앞의 모든 용어를 추가할 수 있습니다. [\* waitress \* & nice], [\* desk \* & friendly], [\* receptionist \* & accommodating] 같은 모든 종류의 직원에 대한 하나의 범주 규칙을 작성할 수 있지만, <HotelStaff> 유형을 사용하여 더 일반적인 하나의 범주 규칙을 작성하여 [<HotelStaff> & <Positive>]의 양식으로 호텔 직원의 호의적인 의견을 갖는 모든 응답을 캡처할 수 있습니다.

참고: 규칙에 TLA 패턴을 포함할 때 범주 규칙에서 + 및 &를 둘 다 사용할 수 있습니다. 자세한 정보는 범주 규칙에서 TLA 패턴 사용의 내용을 참조하십시오.

디스크립터로서의 개념, TLA 또는 범주 규칙이 상이하게 매치하는 방법의 예

다음 예는 개념을 디스크립터로서, 범주 규칙을 디스크립터로서 또는 TLA 패턴을 디스크립터로서 사용하는 것이 문서 또는 레코드가 범주화되는 방법에 어떤 영향을 주는지를 보여줍니다. 다음 5개 레코드가 있다고 가정합니다.

- A: "광장한 식당 직원, 탁월한 음식 및 편안하고 깨끗한 객실."
- B: "식당 직원은 꼼직했지만 객실은 깨끗했음."
- C: "안락하고 깨끗한 객실."
- D: "내 방은 그렇게 깨끗하지 않았음."
- E: "깨끗함."

레코드가 깨끗이라는 단어를 포함하고 이 정보를 캡처하기 원하므로, 다음 테이블에 표시된 디스크립터 중 하나를 작성할 수 있습니다. 캡처하려는 본질을 바탕으로, 다른 디스크립터에 비해 한 종류의 디스크립터 사용이 상이한 결과를 생성할 수 있는 방법을 볼 수 있습니다.

표 1. 예제 레코드가 디스크립터와 매치한 방법						
디스크립터	A	B	C	D	E	설명
깨끗	매치	매치	매치	매치	매치	디스크립터가 추출된 개념입니다. 모든 레코드가 깨끗 개념을 포함했으며, TLA가 없으면 자동으로 "깨끗하지 않음"이 TLA 규칙에 의해 더러움을 의미한다고 알려지지 않았으므로 레코드 D도 포함했습니다.
깨끗 + .	-	-	-	-	매치	디스크립터는 그 자체가 깨끗을 나타내는 TLA 패턴입니다. TLA 추출 중에 연관된 개념 없이 깨끗이 추출된 레코드와만 매치합니다.
[깨끗]	매치	매치	매치	-	매치	디스크립터는 그 자체에서 또는 다른 어떤 것에서 깨끗을 포함하는 TLA 규칙을 찾는 범주 규칙입니다. 깨끗이 객실 같은 다른 개념에 링크되고 임의의 슬롯 위치에 있는지 여부와 상관없이 깨끗을 포함하는 TLA 출력이 발견된 모든 레코드와 매치했습니다.

### 3) 범주 정보

범주는 서로 밀접하게 관련된 개념, 의견 또는 속성의 그룹을 가리킵니다. 범주는 중요 의미를 캡처하는 짧은 구문이나 레이블로 쉽게 설명되어야 유용하게 사용할 수 있습니다.

예를 들어, 새 세탁 세제에 대한 고객의 설문 반응을 분석 중이라면 제품의 향을 설명하는 모든 반응을 포함하는 냄새라는 레이블이 있는 범주를 작성할 수 있습니다. 그러나 이러한 범주는 향

을 좋아하는 소비자와 이를 싫어하는 소비자를 분간하지는 못합니다. IBM® SPSS® Modeler Text Analytics 는 적합한 자원을 사용하면 의견을 추출할 수 있으므로 **냄새**를 좋아한 반응자와 **냄새**를 싫어한 반응자를 식별하기 위한 두 개의 다른 범주를 작성할 수 있습니다.

범주 및 개념 보기 창의 왼쪽 상단 분할창에 있는 범주 분할창에서 범주를 작성하고 이에 대해 작업할 수 있습니다. 각 범주는 하나 이상의 디스크립터로 정의됩니다. **디스크립터**는 개념, 유형 및 패턴뿐만 아니라 범주를 정의하는 데 사용된 범주 규칙입니다.

지정된 범주를 구성하는 디스크립터를 보고 싶은 경우에는 범주 분할창 도구 모음에서 연필 아이콘을 클릭한 다음 트리를 확장하여 디스크립터를 볼 수 있습니다. 또는 범주를 선택하고 범주 정의 대화 상자를 여십시오(**보기 > 범주 정의**).

개념 포함 등과 같은 범주 작성 기술을 사용하여 범주를 자동으로 작성하면 기술은 개념 및 유형을 디스크립터로 사용하여 범주를 작성합니다. TLA 패턴을 추출하면 패턴 또는 이러한 패턴의 일부를 범주 디스크립터로 추가할 수 있습니다. 자세한 정보는 텍스트 링크 분석 탐색의 내용을 참조하십시오. 군집을 작성하는 경우에는 군집에서 신규 또는 기존 범주에 개념을 추가할 수 있습니다. 마지막으로 범주에서 디스크립터로 사용하기 위한 범주 규칙을 수동으로 작성할 수 있습니다. 자세한 정보는 범주 규칙 사용의 내용을 참조하십시오.

## (1) 범주 특성

디스크립터에 추가로, 범주에는 또한 범주의 이름을 변경하고, 레이블을 추가하거나 주석(Annotation)을 추가하기 위해 편집할 수 있는 특성이 있습니다.

다음 특성이 있습니다.

- **이름.** 이 이름은 기본적으로 트리에 나타납니다. 자동화된 기술을 사용하여 범주가 작성되면 이는 자동으로 이름이 제공됩니다.
- **레이블.** 레이블 사용은 다른 제품에서나 다른 테이블 또는 그래프에서 사용하기 위해 보다 의미있는 범주 설명을 작성할 때 유용합니다. 레이블을 표시하기 위한 옵션을 선택하는 경우에는 레이블이 범주를 식별하기 위해 인터페이스에 사용됩니다.
- **코드.** 코드 번호는 이 범주의 코드 값에 해당합니다. .
- **주석(Annotation).** 이 필드에서 각 범주의 짧은 설명을 추가할 수 있습니다. 범주가 범주 작성 대화 상자를 사용하여 생성된 경우에는 이 주석(Annotation)에 노트가 자동으로 추가됩니다. 텍스트를 선택하고 메뉴에서 **범주 > 주석(Annotation)에 추가**를 선택하여 데이터 분할창에서 직접 주석(Annotation)에 표본 텍스트를 추가할 수도 있습니다.

## 4) 데이터 분할창

범주를 작성한 후 작업 중인 일부 텍스트 데이터를 검토하려는 경우가 있습니다. 예를 들어, 640 개 문서가 범주화된 범주를 작성하는 경우 해당 문서 중 일부 또는 모두를 살펴 실제로 기록된 텍스트를 확인할 수 있습니다. 오른쪽 하단에 있는 데이터 분할창에서 레코드 또는 문서를 검토할 수 있습니다. 기본적으로 표시되지 않으면 메뉴에서 **보기 > 분할창 > 데이터**를 선택하십시오.

데이터 분할창은 일정 표시 한계까지 범주 분할창, 추출 결과 분할창 또는 범주 정의 대화 상자의 선택사항에 해당하는 문서 또는 레코드당 1행을 제공합니다. 기본적으로 데이터 분할창에 표시된 문서 또는 레코드 수는 데이터를 보다 빨리 볼 수 있도록 제한됩니다. 그러나 옵션 대화 상자에서 이를 조정할 수 있습니다. 매우 큰 데이터 세트를 다루는 경우, 범주를 표시하는 옵션을 해제하여 표시 속도를 개선할 수 있습니다. 자세한 정보는 옵션: 세션 탭의 내용을 참조하십시오.

 **참고:** 분할창에 표시할 수 있는 수보다 레코드 수가 많은 경우, 분할창의 맨 아래쪽에 있는 제어를 사용하여 레코드 앞 또는 뒤로 이동하거나 이동할 페이지 수를 입력할 수 있습니다.

### 데이터 분할창 표시 및 새로 고침

큰 데이터 세트의 경우 자동 데이터 새로 고침을 완료하려면 약간의 시간이 걸리기 때문에 데이터 분할창은 자동으로 표시를 새로 고치지 않습니다. 따라서 이 보기의 다른 분할창 또는 범주 정의 대화 상자에서 선택할 때마다 **표시**를 클릭하여 데이터 분할창의 콘텐츠를 새로 고치십시오.

#### 텍스트 문서 또는 레코드

텍스트 데이터가 레코드 양식으로 되어 있고 텍스트의 길이가 비교적 짧으면, 데이터 분할창의 텍스트 필드는 텍스트 데이터를 전부 표시합니다. 그러나 레코드와 큰 데이터 세트에 대한 작업을 할 때 텍스트 필드 열은 텍스트의 짧은 조각을 표시하고 테이블에서 선택한 레코드의 텍스트를 모두 또는 더 많이 표시할 수 있도록 오른쪽에 텍스트 미리보기 분할창을 엽니다. 텍스트 데이터가 개별 문서 양식으로 되어 있으면 데이터 분할창이 문서의 파일 이름을 표시합니다. 문서를 선택하면 선택된 문서의 텍스트와 함께 텍스트 미리보기 분할창이 열립니다.

#### 색상 및 강조표시

데이터를 표시할 때마다 텍스트에서 쉽게 식별할 수 있도록 해당 문서 또는 레코드에서 찾은 개념 및 디스크립터가 색상으로 강조표시됩니다. 색상 코딩은 개념이 속한 유형에 해당합니다. 색상 코드화된 항목 위에 마우스를 올려 놓아 추출된 개념과 지정된 유형도 표시할 수 있습니다. 추출되지 않은 텍스트는 검은색으로 나타납니다. 일반적으로 추출되지 않은 이러한 단어는 접속사(*and* 또는 *with*), 대명사(*me* 또는 *they*), 동사(*is*, *have* 또는 *take*)인 경우가 많습니다.

## 데이터 분할창 열

텍스트 필드 열이 항상 표시되는 동안에는 다른 열도 표시할 수 있습니다. 다른 열을 표시하려면 메뉴에서 보기 > 데이터 분할창을 선택한 후 데이터 분할창에 표시할 열을 선택하십시오. 표시할 수 있는 열은 다음과 같습니다.

- **"텍스트 필드 이름" (#)/문서.** 개념과 유형이 추출된 텍스트 데이터에 열을 추가합니다. 데이터가 문서에 있는 경우, 열을 문서라고 하며 문서 파일 이름 또는 전체 경로만 표시됩니다. 해당 문서에 대한 텍스트를 보려면 텍스트 미리보기 분할창에서 보아야 합니다. 데이터 분할창의 행 수는 이 열 이름 다음에 괄호로 표시됩니다. 옵션 대화 상자에서 로드 속도를 늘리는 데 사용되는 한계 때문에 모든 문서 또는 레코드가 표시되지는 않는 경우가 있습니다. 최대값에 도달하면 숫자 뒤에 - **Max**가 옵니다. 자세한 정보는 옵션: 세션 탭의 내용을 참조하십시오.
- **범주.** 레코드가 속한 범주를 각각 나열합니다. 이 열이 표시될 때마다 데이터 분할창을 새로 고치면 최신 정보를 표시하기 위해 시간이 약간 오래 걸립니다.
- **자동 설정 시작.** 문서를 강제 적용한 범주를 나열합니다. 편집 > 자동 설정 시작 메뉴를 선택하면 문서가 해당 범주로 강제 적용됩니다. 자세한 정보는 범주에 문서 강제 적용/해제의 내용을 참조하십시오.
- **자동 설정 종료.** 문서를 제거한 범주를 나열합니다. 편집 > 자동 설정 종료 메뉴를 선택하면 문서가 해당 범주에서 강제 해제됩니다. 예를 들어 응답자의 풍자로 응답 범주가 잘못 지정된 경우에 사용할 수 있습니다. 자세한 정보는 범주에 문서 강제 적용/해제의 내용을 참조하십시오.
- **범주 수.** 레코드가 속해 있는 범주 수를 나열합니다.
- **관련성 순위.** 단일 범주에 있는 각 레코드에 대한 순위를 제공합니다. 이 순위는 해당 범주의 다른 레코드와 비교하여 레코드가 범주에 얼마나 잘 맞는지 보여줍니다. 순위를 보려면 범주 분할창(왼쪽 상단 분할창)에서 범주를 선택하십시오. 자세한 정보는 범주 관련성의 내용을 참조하십시오.
- **반응 플래그.** 사용할 수 있는 플래그를 표시하는 열을 추가합니다. 이 열의 내부를 클릭하면 문서에 지정한 플래그의 유형을 변경할 수 있습니다. "완료" 플래그 또는 "중요" 플래그로 문서에 플래그를 지정하거나 플래그를 제거할 수 있습니다. 이는 범주 모델의 완료 여부를 검토하는 데 유용합니다. 자세한 정보는 반응에 플래그 지정의 내용을 참조하십시오.

### (1) 범주 관련성

더 좋은 범주를 작성하기 위해 각 범주에 있는 문서 또는 레코드의 관련성뿐 아니라 문서 또는 레코드가 속하는 모든 범주의 관련성을 검토할 수 있습니다.

#### 레코드에 대한 범주의 관련성

문서 또는 레코드가 데이터 분할창에 나타날 때마다, 그것이 속하는 모든 범주가 범주 열에 나열됩니다. 문서 또는 레코드가 다중 범주에 속하면 이 열의 범주는 관련성이 가장 큰 것부터 가장 작은 것의 순서로 나타납니다. 처음 나열되는 범주는 이 문서 또는 레코드에 최상으로 대응하는 것으로 생각됩니다. 자세한 정보는 데이터 분할창 주제를 참조하십시오.

## 범주에 대한 레코드의 관련성

범주를 선택할 때 데이터 분할창의 관련성 순위 열에서 범주의 각 레코드의 관련성을 검토할 수 있습니다. 이 관련성 순위는 문서 또는 레코드가 해당 범주에 있는 다른 레코드와 비교하여 선택된 범주에 얼마나 잘 맞는지를 표시합니다. 단일 범주에 대한 레코드의 순위를 보려면 범주 분할창(왼쪽 상단 분할창)에서 이 범주를 선택하십시오. 문서 또는 레코드의 순위가 열에 나타납니다. 이 열은 기본적으로 표시되지 않지만 표시할 것을 선택할 수 있습니다. 자세한 정보는 데이터 분할창 주제를 참조하십시오.

레코드 순위에 대한 숫자가 낮을수록, 이 레코드는 선택된 범주에 대해 더 잘 맞거나 더 큰 관련성을 가지며 1이 가장 잘 맞는 것입니다. 둘 이상의 레코드가 동일한 관련성을 갖는 경우, 각각은 동일한 순위를 갖고 나타나며 동일한 관련성을 갖고 있음을 표시하기 위해 등호(=)가 뒤따릅니다. 예를 들어 1=, 1=, 3, 4 등의 순위를 가질 수 있는데, 이것은 이 범주에 대해 최상의 매치로 동일하게 간주될 수 있는 두 개의 레코드가 있음을 의미합니다.

**팁:** 범주 주석(Annotation)에 가장 관련성이 큰 레코드의 텍스트를 추가하여 범주의 더 나은 설명을 제공할 수 있습니다. 텍스트를 선택하고 메뉴에서 **범주 > 주석(Annotation)에 추가**를 선택하여 데이터 분할창에서 직접 텍스트를 추가하십시오.

## (2) 반응에 플래그 지정

진행 상황을 모니터링하는 데 도움이 되도록 데이터 분할창에서 플래그를 사용하여 문서를 표시할 수 있습니다. 이 기능은 소스 문서에 고유 ID가 포함된 경우에만 사용할 수 있습니다. 소스 문서에 고유 ID가 없는 경우 소스 문서와 텍스트 마이닝 노드 간에 파생 노드를 추가할 수 있습니다.

문서를 표시하려는 데는 다음을 포함하여 여러 가지가 이유가 있을 수 있습니다.

- 나중에 시작 위치를 알 수 있도록 수동으로 검토한 문서를 표시하기 위해
- 처리 방법을 알 수 없는 문서를 표시하기 위해

플래그로 문서를 표시한 후에는 계속해서 문서에 대해 작업할 수 있습니다. 이는 순전히 자신의 레코드 보관을 위한 것입니다. 다음 플래그 중에서 선택할 수 있습니다.

표 1. 플래그 설명	
플래그	설명
	완료된 것으로 간주되는 문서를 나타내는 완료 플래그입니다.
	중요한 것으로 간주되는 문서를 나타내는 중요 플래그입니다.

## 플래그로 문서 표시

1. 데이터 분할창에서 표시하려는 문서를 마우스 오른쪽 단추로 클릭하십시오.
2. 컨텍스트 메뉴에서 **보기 > 데이터 분할창 > 반응 플래그**를 선택한 후 사용하려는 플래그의 유형(중요 플래그 또는 완료 플래그)을 선택하십시오. 선택한 플래그가 지정됩니다. 플래그 열이 데이터 분할창에 표시되지 않았다면 표시됩니다.

## 플래그 지우기

1. 데이터 분할창에서 플래그를 제거할 문서를 마우스 오른쪽 단추로 클릭하십시오.
2. 컨텍스트 메뉴에서 **반응 표시 도구 > 플래그 지우기**를 선택하십시오. 선택한 플래그가 제거됩니다.

## 5) 범주 작성

텍스트 분석 패키지에 범주가 있을 수 있지만 언어학적 기술이나 빈도 기술을 사용하여 자동으로 범주를 작성할 수도 있습니다. 범주 작성 설정 대화 상자를 통해 개념 또는 개념 패턴으로부터 범주를 생성하기 위해 자동화된 언어학적 및 빈도 기술을 적용할 수 있습니다.

일반적으로, 범주는 여러 유형의 디스크립터(유형, 개념, TLA 패턴, 범주 규칙)로 구성될 수 있습니다. 자동화된 범주 작성 기술을 사용하여 범주를 작성할 때 결과로 나오는 범주는 개념이나 개념 패턴(선택하는 입력에 따라 다름)을 따라 이름이 지정되고 각각에는 디스크립터 세트가 포함됩니다. 이러한 디스크립터는 범주 규칙이나 개념의 양식일 수 있으며 기술이 발견한 모든 관련 개념이 포함됩니다.

범주를 작성한 후에는 이를 범주 분할창에서 검토하고 그래프와 도표를 통해 탐색하여 범주에 대해 많은 것을 배울 수 있습니다. 그런 다음에는 수동 기술을 사용하여 경미한 조정을 하거나 잘못된 분류를 제거하거나 누락되었을 수 있는 레코드나 단어를 추가할 수 있습니다. 기술을 적용한 후에는 범주로 그룹화된 개념, 유형 및 패턴은 여전히 다른 기술에 사용 가능합니다. 또한, 다른 기술을 사용하면 중복되거나 부적합한 범주를 생성할 수도 있으므로 범주를 병합하거나 삭제할 수도 있습니다. 자세한 정보는 범주 편집 및 세분화 주제를 참조하십시오.

**중요!** 이전 릴리스에서는 동시 발생과 동의어 규칙은 꺾쇠 괄호로 둘러싸였습니다. 이 릴리스에서는 꺾쇠 괄호는 이제는 텍스트 링크 분석 패턴 결과를 나타냅니다. 대신, 동시 발생 및 동의어 규칙은 (speaker systems | speakers)와 같은 소괄호로 캡슐화됩니다.

## 범주 작성 방법

1. 메뉴에서 **범주 > 범주 작성**을 선택하십시오. 프롬프트하지 않기로 선택하지 않은 한 메시지 상자가 표시됩니다.
  2. 지금 작성할지 또는 설정을 먼저 편집할지를 선택하십시오.
- 현재 설정을 사용하여 범주 작성을 시작하려면 **지금 작성**을 클릭하십시오. 기본적으로 선택된 설정은 종종 범주화 프로세스를 시작하기에 충분합니다. 범주 작성 프로세스가 시작되고 진행률 대화 상자가 나타납니다.
  - 작성 설정을 검토하고 수정하려면 **편집**을 클릭하십시오.

 **참고:** 표시할 수 있는 최대 범주 수는 10,000개입니다. 이 숫자에 도달했거나 초과되면 경고가 표시됩니다. 이 경우에는 범주 작성 또는 확장 옵션을 변경하여 작성된 범주 수를 줄여야 합니다.

## 입력

범주는 유형 패턴 또는 유형에서 파생된 디스크립터에서 작성됩니다. 테이블에서 범주 작성 프로세스를 포함하기 위한 개별 유형 또는 패턴을 선택할 수 있습니다.

**유형 패턴.** 유형 패턴을 선택하면 범주는 유형과 개념 대신 패턴으로부터 작성됩니다. 이런 방식으로 선택된 유형 패턴에 속하는 개념 패턴을 포함하는 모든 레코드 또는 문서가 범주화됩니다. 따라서 테이블에서 <Budget> 및 <Positive> 유형 패턴을 선택하면 cost & <Positive> 또는 rates & excellent 등과 같은 범주가 생성될 수 있습니다.

유형 패턴을 자동화된 범주 작성의 입력으로서 사용할 때는 기술이 범주 구조를 형성하기 위한 다양한 방식을 식별하는 때가 있습니다. 기술적으로 범주를 생성하는 한 가지의 옳은 방법이란 없습니다. 그러나 어떤 구조가 다른 구조보다는 사용자의 분석에 더 적합한지를 알아낼 수는 있습니다. 이 경우 출력을 사용자 정의하기 위해서는 유형을 선호 초점으로 지정할 수 있습니다. 생성된 모든 최상위 수준 범주는 다른 유형이 아니라 여기에서 선택한 유형의 개념에서 나옵니다. 모든 하위 범주에는 이 유형의 텍스트 링크 패턴이 포함됩니다. **패턴 유형별 구조 범주:** 필드에서 이 유형을 선택하면 테이블이 선택된 유형을 포함하는 적용 가능한 패턴만을 표시하기 위해 업데이트됩니다. 종종 <Unknown>이 미리 선택되어 있습니다. 그러면 <Unknown> 유형을 포함하는 모든 패턴이 선택됩니다. 테이블은 가장 많은 레코드 또는 문서(문서 개수)부터 시작하여 내림차순으로 유형을 표시합니다.

**유형.** 유형을 선택하면 범주는 선택된 유형에 속하는 개념으로부터 작성됩니다. 따라서 테이블에서 <Budget> 유형을 선택하는 경우 cost 또는 price 등과 같은 범주가 생성됩니다. cost 및 price는 <Budget> 유형에 지정되는 개념이기 때문입니다.

기본적으로 대부분의 레코드 또는 문서를 캡처하는 유형만이 선택됩니다. 이 사전 선택을 통해 가장 관심있는 유형에 빠르게 집중하고 관심없는 범주의 작성을 피할 수 있습니다. 테이블은 가장 많은 레코드 또는 문서(문서 개수)부터 시작하여 내림차순으로 유형을 표시합니다. Opinions 라이브러리의 유형은 기본적으로 유형 테이블에서 선택 취소되어 있습니다.

어떤 입력을 선택하는지가 어떤 범주를 얻게 되는지에 영향을 미칩니다. 유형을 입력으로 선택하면 명확하게 관련된 개념을 보다 쉽게 볼 수 있습니다. 예를 들어, 유형을 입력으로 사용하여 범주를 작성하는 경우에는 apple, pear, citrus fruits, orange 등과 같은 개념이 있는 Fruit 범주를 얻을 수 있습니다. 대신 유형 패턴을 입력으로 선택하고 <Unknown> + <Positive> 패턴을 예를 들어 선택하는 경우에는, fruit + tasty 및 apple + good 등과 같은 하나 또는 두 종류의 과일이 있는 fruit + <Positive> 범주를 얻을 수 있습니다. 이 두 번째 결과는 과일의 다른 발생이 반드시 절대적으로 자격이 있는 것은 아니므로 2개의 개념 패턴만을 보여줍니다. 이는 현재 텍스트 데이터에는 충분하지만 다른 문서 세트를 사용하는 장기적인 조사에서는 citrus fruit + positive 등과 같은 다른 디스크립터에서 수동으로 추가하거나 유형을 사용하려고 할 수도 있습니다. 유형만을 입력으로 단독 사용하면 가능한 모든 과일을 발견하는 데 도움이 됩니다.

## 기술

모든 데이터 세트가 고유하므로 방법의 수와 이를 적용하는 순서는 시간에 따라 변경될 수 있습니다. 텍스트 마이닝 목적은 한 데이터 세트와 다음 데이터 세트마다 다르므로, 여러 가지 방법을 시도하여 어떤 기술이 지정된 텍스트 데이터별로 최상의 결과를 낼 수 있는지를 살펴볼 필요가 있습니다.

이를 사용하기 위해서 이러한 설정의 전문가일 필요는 없습니다. 기본적으로 가장 공통된 평균 설정은 이미 선택되어 있습니다. 그러므로 고급 설정 대화 상자를 무시하고 범주 작성으로 바로 이동할 수 있습니다. 마찬가지로 여기에서 변경하면 마지막 설정은 항상 보존되므로 매번 설정 대화 상자로 돌아갈 필요가 없습니다.

언어학적 또는 빈도 기술을 선택하고 고급 설정 단추를 클릭하여 선택된 기술의 설정을 표시하십시오. 자동 기술은 데이터를 완벽하게 범주화합니다. 그러므로 사용자의 데이터에 가장 적합한 하나 이상의 자동 기술을 찾아서 적용하는 것이 좋습니다. 언어학적 및 빈도 기술을 동시에 사용하여 작성할 수는 없습니다.

- **고급 언어학적 기술.** 자세한 정보는 고급 언어학적 설정 주제를 참조하십시오.
- **고급 빈도 기술.** 자세한 정보는 고급 빈도 설정 주제를 참조하십시오.

## (1) 고급 언어학적 설정

범주를 작성할 때 *개념 포함* 및 *시맨틱 네트워크*(영어 텍스트만 해당) 등의 고급 언어학적 범주 작성 기술 중에서 선택할 수 있습니다. 이러한 기술은 범주를 작성하기 위해 개별적으로 또는 서로 결합하여 사용할 수 있습니다.

모든 데이터 세트가 고유하기 때문에 방법의 수와 이를 적용하는 순서는 시간에 따라 변경될 수 있음을 유의하십시오. 텍스트 마이닝 목적은 한 데이터 세트와 다음 데이터 세트마다 다르므로, 여러 가지 방법을 시도하여 어떤 기술이 지정된 텍스트 데이터별로 최상의 결과를 낼 수 있는지를 살펴볼 필요가 있습니다. 자동 기술은 데이터를 완벽하게 범주화합니다. 그러므로 사용자의 데이터에 가장 적합한 하나 이상의 자동 기술을 찾아서 적용하는 것이 좋습니다.

다음 영역과 필드는 고급 설정: 언어학적 대화 상자에서 사용 가능합니다.

### 입력 및 출력

**범주 입력** 범주가 작성될 시작 위치를 선택하십시오.

- **미사용 추출 결과.** 이 옵션은 기존 범주에 사용되지 않는 추출 결과로부터 범주를 작성할 수 있게 해줍니다. 이는 레코드가 여러 범주에 매치하는 경향을 최소화하고 생성된 범주의 수를 제한합니다.
- **모든 추출 결과.** 이 옵션을 사용하면 추출 결과를 사용하여 범주를 작성할 수 있습니다. 이는 범주가 없거나 몇몇 범주만이 이미 존재하는 경우에 매우 유용합니다.

**범주 출력** 범주가 작성될 일반 구조를 선택하십시오.

- **하위 범주가 있는 계층 구조.** 이 옵션을 사용하면 하위 범주와 하위 하위 범주를 작성할 수 있습니다. 작성할 수 있는 최대 수준 수(작성된 최대 수준 수 필드)를 선택하여 범주의 깊이를 설정할 수 있습니다. 3을 선택하면 범주에는 하위 범주가 포함되고 이러한 하위 범주에는 또 하위 범주가 있을 수 있습니다.
- **평면 범주(단일 수준만).** 이 옵션을 사용하면 한 수준의 범주만이 작성됩니다. 즉 하위 범주가 생성되지 않습니다.

### 그룹화 기술

사용 가능한 각 기술은 특정 데이터 유형과 상황에 잘 맞지만, 종종 문서 또는 레코드의 전체 범위를 캡처하기 위해 동일한 분석으로 기술을 결합하는 것이 유용합니다. 다중 범주에서 개념을 확인하거나 중복 범주를 찾을 수 있습니다.

**개념 포함.** 이 기술은 다른 개념에서 단어의 서브세트 또는 수퍼세트인 단어를 포함하는지 여부를 기초로 다항어 개념(복합어)을 그룹화하여 범주를 작성합니다. 예를 들어, 개념 seat는 safety seat, seat belt 및 seat belt buckle과 함께 그룹화됩니다. 자세한 정보는 개념 포함의 내용을 참조하십시오.

**시맨틱 네트워크.** 이 기술은 광범위한 단어 색인 관계에서 각 개념의 가능한 의미를 식별하여 시작한 다음 관련된 개념을 그룹화하여 범주를 작성합니다. 이 기술은 개념이 시맨틱 네트워크에 알려져 있고 너무 애매하지 않을 경우에 가장 좋습니다. 텍스트에 네트워크에 알려지지 않은 용어나 특수화된 전문용어가 포함된 경우에는 덜 유용합니다. 하나의 예에서, 개념 granny smith apple은 gala apple 및 winesap apple과 그룹화될 수 있습니다. 이들은 granny smith의 형제어이기 때문입니다. 다른 예에서, 개념 animal은 cat 및 kangaroo와 그룹화될 수 있습니다. 이들은 animal의 하위어이기 때문입니다. 이 기술은 이 릴리스에서 영어 텍스트에만 사용할 수 있습니다. 자세한 정보는 시맨틱 네트워크의 내용을 참조하십시오.

 **참고:** 최대 검색 거리 옵션은 사용자가 시맨틱 네트워크를 선택한 경우에만 사용 가능합니다.

**최대 검색 거리** 범주를 생성하기 전에 기술이 검색할 범위를 선택하십시오. 값이 낮을수록 더 적은 수의 결과를 얻게 되지만, 이러한 결과는 잡음이 적고 서로 간에 의미 있게 링크되어 있거나 연관되어 있을 수 있습니다. 값이 높을수록 더 많은 수의 결과를 얻게 되지만 이러한 결과는 믿을 만하지 않거나 적절하지 않을 수 있습니다. 이러한 옵션은 모든 기술에 글로벌하게 적용되지만 동시 발생과 시맨틱 네트워크에 미치는 영향은 상당합니다.

**특정 개념 쌍 방지.** 프로세스가 출력에 두 개의 개념을 함께 그룹화하거나 쌍으로 만드는 프로세스를 중지하려면 이 선택란을 선택하십시오. 개념 쌍을 작성하거나 관리하려면 쌍 관리를 클릭하십시오. 자세한 정보는 링크 예외 쌍 관리 주제를 참조하십시오.

**가능한 경우 와일드카드로 일반화** 별표 와일드카드를 사용하여 제품이 범주에서 일반 규칙을 생성하게 하려면 이 옵션을 선택하십시오. 예를 들어, [apple tart + .] 및 [apple sauce + .] 등과 같은 여러 디스크립터를 생성하는 대신에 와일드카드를 사용하면 [apple \* + .]을 생성할 수 있습니다. 와일드카드를 사용하여 일반화하면 종종 앞서 한 것과 똑같은 수의 레코드 또는 문서 수를 얻게 됩니다. 그러나 이 옵션은 숫자를 줄이고 범주 디스크립터를 단순화하는 장점이 있습니다. 또한 이 옵션은 새 텍스트 데이터(예를 들어, 세로/파동 연구에서)에서 이러한 범주를 사용하여 더 많은 레코드 또는 문서를 범주화하는 기능을 증가시킵니다.

## 범주 작성을 위한 다른 옵션

적용할 그룹 기술을 선택하는 것 외에도 다음과 같은 몇몇 기타 작성 옵션을 편집할 수 있습니다.

**작성된 최상위 수준 범주의 최대 수.** 이 옵션을 사용하여 다음 번에 범주 작성 단추를 클릭할 때 생성할 수 있는 범주 수를 제한할 수 있습니다. 어떤 경우에는 이 값을 높게 설정한 다음에 관심없는 범주의 일부를 삭제하면 더 나은 결과를 얻을 수도 있습니다.

**범주별 최소 디스크립터 및/또는 하위 범주의 수.** 이 옵션을 사용하면 범주를 작성하기 위해 포함해야 하는 최소 디스크립터와 하위 범주 수를 정의할 수 있습니다. 이 옵션은 상당 수의 레코드 또는 문서를 캡처하지 않는 범주 작성을 제한하는 데 도움이 됩니다.

**디스크립터가 둘 이상의 범주에 나타나게 허용** 이 옵션이 선택되면 디스크립터가 다음 번에 작성될 둘 이상의 범주에서 사용할 수 있게 됩니다. 이 옵션은 일반적으로 선택됩니다. 항목은 일반적으로 또는 "자연적으로" 둘 이상의 범주에 해당하고 이를 허용하면 더 높은 품질의 범주로 이어질 수 있기 때문입니다. 이 옵션을 선택하지 않으면 여러 범주에서 레코드의 겹침을 줄이게 되는데, 가지고 있는 데이터의 유형에 따라서 이는 바람직하지 않을 수 있습니다. 그러나 대부분의 데이터 유형에서는 일반적으로 디스크립터를 단일 범주로 제한하면 품질이나 범주 범위가 손실됩니다. 예를 들어, car seat manufacturer 개념이 있다고 해봅시다. 이 옵션을 사용하면 이 개념은 car seat 텍스트를 기반으로 하나의 범주에 나타나거나 manufacturer를 기반으로 또 다른 범주에 나타날 수 있습니다. 그러나 이 옵션이 선택되지 않은 경우에는 두 범주를 모두 얻을 수는 있지만, car seat manufacturer 개념은 car seat 및 manufacturer가 각각 발생하는 레코드 수를 포함하여 여러 요소를 기반으로 가장 매치하는 범주에 디스크립터로만 나타납니다.

**중복된 범주 이름 해결 기준** 이름이 기존 범주와 같은 새 범주 또는 하위 범주를 처리하는 방법을 선택하십시오. 이름이 같은 기존 범주와 새 범주(및 해당 디스크립터)를 병합할 수 있습니다. 또는 기존 범주에서 중복 이름이 발견된 경우 범주의 작성을 건너뛰도록 선택할 수도 있습니다.

### ① 링크 예외 쌍 관리

범주 작성, 군집 및 개념 매핑 동안 내부 알고리즘은 단어를 알려진 연관을 기준으로 그룹화합니다. 두 개의 개념이 쌍을 이루거나 서로 링크되는 것을 막으려면 **범주 작성 고급 설정** 대화 상자, **군집 작성** 대화 상자 및 **개념 맵 색인 설정** 대화 상자에서 이 기능을 켜고 **쌍 관리** 단추를 클릭하십시오.

결과로 나오는 **링크 예외 관리** 대화 상자에서 개념 쌍을 추가, 편집 또는 삭제할 수 있습니다. 해당 한 쌍을 입력하십시오. 여기에 쌍을 입력하면 범주, 군집 및 개념 매핑을 작성하거나 확장할 때 쌍이 발생하는 것을 막습니다. 단어를 원하는 그대로 입력하십시오. 예를 들어, 단어의 액센트 버전은 단어의 액센트가 없는 버전과 같지 않습니다.

예를 들어, hot dog와 dog가 그룹화되지 않도록 하려면 쌍을 테이블에 별도의 행으로서 추가할 수 있습니다.

## (2) 언어학적 기술 정보

범주를 작성하거나 확장할 때 **개념 포함 및 시맨틱 네트워크(영어만)**을 포함하여 여러 고급 언어학적 범주 작성 기술에서 선택할 수 있습니다. 이러한 기술은 범주를 작성하기 위해 개별적으로

또는 서로 결합하여 사용할 수 있습니다.

이를 사용하기 위해서 이러한 설정의 전문가일 필요는 없습니다. 기본적으로 가장 공통된 평균 설정은 이미 선택되어 있습니다. 원하는 경우 이 고급 설정 대화 상자를 무시하고 범주 작성이나 확장으로 바로 이동할 수 있습니다. 마찬가지로 여기에서 변경하는 경우에는 마지막으로 사용된 설정이 기억되므로 매번 설정 대화 상자로 돌아갈 필요가 없습니다.

그러나 모든 데이터 세트가 고유하기 때문에 방법의 수와 이를 적용하는 순서는 시간에 따라 변경될 수 있음을 유의하십시오. 텍스트 마이닝 목적은 한 데이터 세트와 다음 데이터 세트마다 다르므로, 여러 가지 방법을 시도하여 어떤 기술이 지정된 텍스트 데이터별로 최상의 결과를 낼 수 있는지를 살펴볼 필요가 있습니다. 자동 기술은 데이터를 완벽하게 범주화합니다. 그러므로 사용자의 데이터에 가장 적합한 하나 이상의 자동 기술을 찾아서 적용하는 것이 좋습니다.

범주 작성을 위한 기본 자동화된 언어학적 기술은 다음과 같습니다.

- **개념 포함.** 이 기술은 개념을 사용하여 이를 포함하는 다른 개념을 찾는 방법으로 범주를 작성합니다. 자세한 정보는 개념 포함의 내용을 참조하십시오.
- **시맨틱 네트워크.** 이 기술은 광범위한 단어 색인 관계에서 각 개념의 가능한 의미를 식별하여 시작한 다음 관련된 개념을 그룹화하여 범주를 작성합니다. 자세한 정보는 시맨틱 네트워크의 내용을 참조하십시오. 이 옵션은 영어 텍스트에만 사용 가능합니다.

### ① 개념 루트 파생

개념 루트 파생 기술은 개념을 사용하고 개념 구성요소가 형태학상으로 관련되어 있는지 여부를 분석하여 이와 관련된 다른 개념을 찾는 방법으로 범주를 작성합니다. 구성요소는 한 단어입니다. 기술은 개념에서 각 구성요소의 끝부분(접미문자)을 보고 여기에서 파생할 수 있는 다른 개념을 찾아서 개념을 그룹화하려고 시도합니다. 이 아이디어는 단어가 서로 파생되면 의미를 공유하거나 가까울 수 있다는 것입니다. 끝부분을 식별하기 위해 내부 언어 특정 규칙이 사용됩니다. 예를 들어, opportunities to advance 개념은 opportunity for advancement 및 advancement opportunity 개념을 사용하여 그룹화됩니다.

모든 종류의 텍스트에서 개념 루트 파생을 사용할 수 있습니다. 이는 스스로 소수의 범주를 생성하고 각 범주에는 소수의 개념이 포함되는 경향이 있습니다. 각 범주에서의 개념은 동의어이거나 상황적으로 관련이 있을 수 있습니다. 범주를 수동으로 작성하더라도 이 알고리즘을 사용하는 것이 유용할 수 있습니다. 여기에서 발견하는 동의어는 특히 관심이 있는 개념의 동의어일 수 있습니다.

**참고:** 개념을 명시적으로 지정하여 개념이 서로 그룹화되지 않도록 막을 수 있습니다. 자세한 정보는 링크 예외 쌍 관리의 내용을 참조하십시오.

## 용어 컴포넌트화 및 굴절 해제

개념 루트 파생 또는 개념 포함 기술이 적용되면 용어는 먼저 구성요소(단어)로 구분된 다음 구성요소는 굴절이 해제됩니다. 기술이 적용되면 개념 및 해당 연관된 용어가 로드되고 공백, 하이픈 및 어포스트로피 등과 같은 구분 문자를 기반으로 구성요소로 나뉘어집니다. 예를 들어, system administrator 용어는 {administrator, system} 등과 같은 구성요소로 나뉘어집니다.

그러나 원래 용어의 일부분은 사용되지 않거나 검색 엔진에서 제외되는 단어로서 언급될 수도 있습니다. 영어에서는 이러한 무시 가능한 구성요소 중 일부는 a, and, as, by, for, from, in, of, on, or, the, to 및 with가 포함될 수 있습니다.

예를 들어, examination of the data 용어에는 {data, examination} 구성요소 세트가 있고, of 및 the 둘 모두가 무시 가능한 것으로 간주됩니다. 또한 구성요소 순서는 구성요소 세트에 없습니다. 이런 방식으로 cough relief for child, child relief from a cough 및 relief of child cough의 세 개의 용어는 동등할 수 있습니다. 이들 모두는 동일한 구성요소 세트 {child, cough, relief}를 가지고 있기 때문입니다. 용어 쌍이 동등한 것으로 식별될 때마다 해당하는 개념은 모든 용어를 참조하는 새 개념을 형성하기 위해 병합됩니다.

또는 용어의 구성요소가 굴절될 수 있으므로 복수 형태와 같은 굴절 변화와 관계없이 동등한 용어를 식별하기 위해 언어 특정 규칙이 내부적으로 적용됩니다. 이런 방식으로 level of support 및 support levels는 동등한 것으로 식별될 수 있습니다. 굴절이 해제된 단수 양식은 level이기 때문입니다.

## 개념 루트 파생 작업 방법

용어가 컴포넌트화되고 굴절이 해제된 후(이전 섹션 참조) 개념 루트 파생 알고리즘은 구성요소 엔진 또는 접미문자를 분석하여 구성요소 루트를 찾은 다음 개념을 동일하거나 유사한 루트가 있는 다른 개념과 그룹화합니다. 끝부분은 텍스트 언어 특정 언어학적 파생 규칙 세트를 사용하여 식별됩니다. 예를 들어, 접미문자 ical이 있는 동일한 개념 구성요소 끝부분은 동일한 루트 어간과 접미문자 ic가 있는 끝부분에서 파생될 수 있음을 설명하는 영어 언어 텍스트의 파생 규칙이 있습니다. 이 규칙(및 굴절 해제)을 사용하면 알고리즘은 개념 epidemiologic study 및 epidemiological studies를 그룹화할 수 있습니다.

용어가 이미 컴포넌트화되었고 무시 가능한 구성요소(예: in 및 of)가 식별되었으므로, 개념 루트 파생 알고리즘은 개념 studies in epidemiology를 epidemiological studies와 그룹화할 수도 있습니다.

이 알고리즘으로 그룹화된 대부분의 개념이 동의어일 수 있도록 구성요소 파생 규칙 세트가 선택되었습니다. epidemiologic studies, epidemiological studies, studies in epidemiology 개

념은 모두 동등한 용어입니다. 완전성을 늘리기 위해서 알고리즘이 상황적으로 관련된 개념을 그룹화할 수 있도록 해주는 몇몇 파생 규칙이 있습니다. 예를 들어, 알고리즘은 empire builder 및 empire building과 같은 개념을 그룹화할 수 있습니다.

## ② 개념 포함

개념 포함 기술은 개념을 사용하여 범주를 작성하고, 어휘 계열 알고리즘을 사용하여 다른 개념에 포함된 개념을 식별합니다. 이 아이디어는 개념에 있는 단어가 다른 개념의 서브세트이면 기본적인 시맨틱 관계를 반영한다는 것입니다. 포함은 모든 유형의 텍스트와 함께 사용할 수 있는 강력한 기술입니다.

이 기술은 시맨틱 네트워크와 결합하여 잘 작동하지만 별도로 사용될 수 있습니다. 개념 포함은 문서 또는 레코드에 많은 도메인 특정 용어 또는 전문어를 포함한 경우에 더 나은 결과를 제공할 수도 있습니다. 이는 특히 특수 용어가 추출되고 적절하게 그룹화될 수 있도록(동의어와) 사전에 사전을 조정할 경우에 특히 그렇습니다.

### 개념 포함 작동 방법

개념 포함 알고리즘을 적용하기 전에 용어가 컴포넌트화되고 굴절이 해제됩니다. 자세한 정보는 개념 루트 파생의 내용을 참조하십시오. 그런 다음 개념 포함 알고리즘은 구성요소 세트를 분석합니다. 각 구성요소 세트마다 알고리즘은 첫 번째 구성요소 세트의 서브세트인 또 다른 구성요소 세트를 찾습니다.

예를 들어, 구성요소 세트 {breakfast, continental}이 있는 continental breakfast 개념이 있고 {breakfast} 구성요소 세트가 있는 breakfast 개념이 있는 경우에는 알고리즘은 continental breakfast가 breakfast의 종류라고 결론짓고 이들을 그룹화합니다.

더 큰 예에서 추출 결과 분할창에 seat 개념이 있고 이 알고리즘을 적용하는 경우에는 safety seat, leather seat, seat belt, seat belt buckle, infant seat carrier 및 car seat laws 등과 같은 개념 또한 해당 범주에서 그룹화됩니다.

용어가 이미 컴포넌트화되었고 무시 가능한 구성요소(예: in 및 of)가 식별된 경우에는 개념 포함 알고리즘은 advanced spanish course 개념이 course in spanish 개념을 포함한다고 인식합니다.

**참고:** 개념을 명시적으로 지정하여 개념이 서로 그룹화되지 않도록 막을 수 있습니다. 자세한 정보는 링크 예외 쌍 관리의 내용을 참조하십시오.

### ③ 시맨틱 네트워크

이 릴리스에서 시맨틱 네트워크 기술은 영어 텍스트에만 사용할 수 있습니다.

이 기법은 단어 관계의 내장된 네트워크를 사용하여 범주를 작성합니다. 이 때문에 이 기법은 용어가 구체적이고 너무 애매모호하지 않을 때 매우 좋은 결과를 생성할 수 있습니다. 그러나 이 기법이 매우 기술적/전문적 개념 사이의 많은 링크를 찾을 것으로 기대해서는 안 됩니다. 그런 개념을 다룰 때는 개념 포함 및 개념 루트 파생 기법이 더 유용함을 발견할 수 있습니다.

시맨틱 네트워크가 작업하는 방법

시맨틱 네트워크 기술 뒤에 있는 아이디어는 알려진 단어 관계를 활용하여 동의어 또는 **하의어**의 범주를 작성하는 것입니다. 하의어는 하나의 개념이 일종의 두 번째 개념이어서 ISA 관계라고도 알려진 계층 구조 관계가 있을 때입니다. 예를 들어 동물이 하나의 개념일 때 고양이 및 캥거루는 동물의 일종이므로 동물의 하의어입니다.

동의어 및 하의어 관계 외에, 시맨틱 네트워크 기술은 <Location> 유형의 모든 개념 사이의 부분 및 전체 링크를 조사합니다. 예를 들어, 이 기법은 노르망디와 프로방스가 프랑스의 일부이기 때문에 노르망디, 프로방스 및 프랑스를 하나의 범주로 그룹화합니다.

시맨틱 네트워크는 시맨틱 네트워크에 있는 각 개념의 가능한 의미를 식별하여 시작합니다. 개념이 동의어 또는 하의어로서 식별될 때 하나의 범주로 그룹화됩니다. 예를 들어, 기법은 시맨틱 네트워크에 1) dessert apple은 eating apple의 동의어이고, 2) granny smith는 eating apple의 한 종류(eating apple의 하의어임을 의미)라는 정보가 들어 있으므로 eating apple, dessert apple, granny smith를 포함하는 단일 범주를 작성합니다.

개별적으로 취할 때, 많은 개념, 특히 단일어는 애매모호합니다. 예를 들어 뷔페란 개념은 식사의 한 종류 또는 가구의 일부를 나타낼 수 있습니다. 개념 세트가 식사, 가구 및 뷔페를 포함하면, 알고리즘은 뷔페를 식사 또는 가구와 그룹화 사이에서 선택하도록 강제 실행됩니다. 어떤 경우에는 알고리즘에 의해 이루어지는 선택이 레코드 또는 문서의 특정 세트의 컨텍스트에서 적절하지 않을 수 있음을 기억하십시오.

시맨틱 네트워크 기술은 특정 유형의 데이터를 갖는 개념 포함을 능가할 수 있습니다. 시맨틱 네트워크와 개념 포함이 둘 다 애플 파이가 파이의 한 종류임을 인식하지만, 시맨틱 네트워크만 타르트도 파이의 한 종류임을 인식합니다.

시맨틱 네트워크는 다른 기법과 결합하여 작동합니다. 예를 들어, 시맨틱 네트워크와 포함 기법을 둘 다 선택했고 시맨틱 네트워크가 선생님 개념을 튜터 개념과 그룹화(튜터는 선생님의 한 종류이므로)했다고 가정하십시오. 포함 알고리즘은 대졸 튜터를 튜터와 그룹화할 수 있어서 결국 두 알고리즘은 협력하여 튜터, 대졸 튜터, 선생님의 세 개념을 모두 포함하는 출력 범주를 생성합니다.

## 시맨틱 네트워크의 옵션

이 기법에서 관심을 가질 수 있는 많은 추가 설정이 있습니다.

- **최대 검색 거리**를 변경하십시오. 범주를 생성하기 전에 기술이 얼마나 멀리까지 검색하기를 원하는지를 선택하십시오. 값이 낮을수록 더 적은 수의 결과가 생성되지만, 이러한 결과는 잡음이 적고 서로 간에 의미 있게 링크되어 있거나 연관되어 있을 수 있습니다. 값이 높을수록 더 많은 수의 결과를 얻게 되지만 이러한 결과는 믿을 만하지 않거나 적절하지 않을 수 있습니다.

예를 들어, 거리에 따라서 이 알고리즘은 대니시 패스트리부터 커피를(그의 상위)까지를 검색한 후, 번(조부모) 및 빵까지 검색합니다.

검색 거리를 줄임으로써 이 기법은 생성되는 범주가 너무 크거나 너무 많은 것을 그룹화한다고 느끼는 경우 작업하기에 더 쉬울 수 있는 더 작은 범주를 생성합니다.

**중요!** 또한, 일부 잘못된 그룹화가 결과에 부정적 영향을 크게 미칠 수 있으므로 이 기법을 사용할 때 퍼지 그룹화에 대해 **최소 루트 문자 한계에 대해 철자법 오류 수용**(노드의 전문가 탭이나 추출 대화 상자에서 정의됨) 옵션을 적용하지 않을 것을 권장합니다.

### ④ 동시 발생 규칙

동시 발생 규칙을 사용하면 문서 또는 레코드 세트 내에서 강하게 관련되어 있는 개념을 발견하고 그룹화할 수 있습니다. 이 아이디어는 개념이 종종 문서와 레코드에서 발견될 때, 동시 발생은 범주 정의에 있는 값일 가능성이 있는 기본 관계를 반영한다는 것입니다. 이 기술은 새 범주를 작성하고, 범주를 확장하거나 다른 범주 기술에 대한 입력으로 사용될 수 있는 동시 발생 규칙을 작성합니다. 두 개의 개념이 레코드 세트에서 함께 자주 나타나고 다른 레코드에서 드물게 개별적으로 나타나는 경우에는 이들은 강력하게 동시 발생합니다. 이 기술은 최소 수백 개의 문서 또는 레코드가 있는 큰 데이터 세트에서 좋은 결과를 생성할 수 있습니다.

예를 들어, 많은 레코드에 price 및 availability 단어가 포함되는 경우에는 이러한 개념은 동시 발생 규칙, (price & available)로 그룹화될 수 있습니다. 다른 예에서 peanut butter, jelly, sandwich 개념이 따로 떨어지기보다는 자주 함께 나타나는 경우에는 이들은 개념 동시 발생 규칙 (peanut butter & jelly & sandwich)에 그룹화됩니다.

**중요!** 이전 릴리스에서는 동시 발생과 동의어 규칙은 꺾쇠 괄호로 둘러싸였습니다. 이 릴리스에서는 꺾쇠 괄호는 이제는 텍스트 링크 분석 패턴 결과를 나타냅니다. 대신, 동시 발생 및 동의어 규칙은 (speaker systems | speakers)와 같은 소괄호로 캡슐화됩니다.

## 동시 발생 규칙 작동 방법

이 기술은 함께 나타나는 경향이 있는 둘 이상의 개념을 찾기 위해 문서 또는 레코드를 스캔합니다. 둘 이상의 개념은 문서 또는 레코드 세트에 빈번하게 함께 나타나는 경우와 다른 문서 또는 레코드에서는 거의 개별적으로 나타나지 않는 경우에 강력하게 동시 발생합니다.

동시 발생하는 개념이 발견되면 범주 규칙이 형성됩니다. 이러한 규칙은 & 부울 연산자를 사용하여 연결된 둘 이상의 개념으로 구성되어 있습니다. 이러한 규칙은 규칙의 개념 세트가 모두 해당 문서 또는 레코드에서 동시 발생하는 경우 문서 또는 레코드를 범주로 자동으로 분류하는 논리문입니다.

## 동시 발생 규칙의 옵션

동시 발생 규칙 기술을 사용 중인 경우에는 결과로 나오는 규칙에 영향을 미치는 몇몇 설정을 세부 조정할 수 있습니다.

- **최대 검색 거리**를 변경하십시오. 기술이 얼마나 멀리까지 동시 발생을 검색하는지를 선택하십시오. 검색 거리를 늘릴 때 각 동시 발생에 필요한 최소 유사성 값은 낮아집니다. 따라서 많은 동시 발생 규칙이 생성될 수 있지만 유사성 값이 낮으면 중요성 낮습니다. 검색 거리를 줄이면 필요한 최소 유사성 값이 높아집니다. 그 결과로 생성되는 동시 발생 규칙의 수가 줄어들지만 보다 중요해지는(강력해지는) 경향이 있습니다.
- **최소 문서**. 동시 발생으로 간주되기 위해서 지정된 개념 쌍을 포함해야 하는 최소 레코드 또는 문서 수입니다. 이 옵션을 낮게 설정할수록 동시 발생을 쉽게 찾을 수 있습니다. 값을 늘리면 동시 발생의 수는 줄어들지만 중요도는 높아집니다. 예를 들어, "사과"와 "배" 개념이 함께 2개의 레코드에서 발견되었고 두 개의 개념이 다른 레코드에서 발생하지 않는다고 가정합니다. **최소 문서**. 2(기본값)로 설정된 동시 발생 기술은 범주 규칙(사과와 배)을 작성합니다. 값이 3으로 높아지면 규칙은 더 이상 작성되지 않습니다.

**참고:** 작은 데이터 세트(< 1000개 반응)의 경우 기본 설정이 있는 동시 발생을 찾을 수 없을 수도 있습니다. 그런 경우 검색 거리 값을 늘려 보십시오.

**참고:** 개념을 명시적으로 지정하여 개념이 서로 그룹화되지 않도록 막을 수 있습니다. 자세한 정보는 링크 예외 쌍 관리의 내용을 참조하십시오.

## (3) 고급 빈도 설정

간단하고 기계적인 빈도 기술을 기반으로 범주를 작성할 수 있습니다. 이 기술을 사용하면 주어진 레코드 또는 문서 개수를 넘어서 발견된 각 항목(유형, 개념 또는 패턴)마다 하나의 범주를 작성할 수 있습니다. 또한 덜 자주 발생하는 모든 항목에 대해 하나의 범주를 작성할 수 있습니다. 개수는 전체 텍스트에서 총 발생 수와 대조적으로 문제의 추출된 개념(및 해당 모든 동의어), 유형 또는 패턴을 포함하는 레코드 또는 문서 수를 가리킵니다.

자주 발생하는 항목 그룹화는 공통되거나 중요한 반응을 나타낼 수 있으므로 흥미로운 결과를 낼 수 있습니다. 이 기술은 다른 기술이 적용된 후에 사용되지 않은 추출 결과에서 매우 유용합니다. 또 다른 방법은 다른 범주가 하나도 없을 때 추출 직후에 이 기술을 실행하고, 결과를 편집하여 관심 없는 범주를 삭제한 다음 이러한 범주가 더 많은 레코드 또는 문서와 매치할 수 있도록 확장하는 것입니다. 자세한 정보는 범주 확장의 내용을 참조하십시오.

이 기술을 사용하는 대신에 개념 또는 개념 패턴을 추출 결과 분할창에서 레코드 또는 문서 수의 내림차순으로 정렬한 다음 맨 위의 것을 범주 분할창으로 끌어다 놓는 방식으로 해당하는 범주를 작성할 수 있습니다.

다음 필드는 고급 설정: 빈도 대화 상자에서 사용 가능합니다.

**범주 디스크립터 생성 위치.** 디스크립터의 입력 종류를 선택하십시오. 자세한 정보는 범주 작성의 내용을 참조하십시오.

- **개념 수준.** 이 옵션을 선택하면 개념 또는 개념 패턴 빈도가 사용됩니다. 유형이 범주 작성의 입력으로서 선택된 경우에는 개념이 사용되고, 패턴이 선택된 경우에는 개념 패턴이 사용됩니다. 일반적으로 이 기술을 개념 수준에 적용하면 보다 특정적인 결과가 생성됩니다. 개념과 개념 패턴은 더 낮은 측정 수준을 나타내기 때문입니다.
- **유형 수준.** 이 옵션을 선택하면 유형 또는 유형 패턴 빈도가 사용됩니다. 유형이 범주 작성의 입력으로서 선택된 경우에는 유형이 사용되고, 패턴이 선택된 경우에는 유형 패턴이 사용됩니다. 이 기술을 유형 수준에 적용하면 제공된 정보 유형과 관련한 빠른 보기를 볼 수 있습니다.

**자체 범주가 항목의 최소 레코드/문서 수.** 이 옵션을 사용하면 자주 발생하는 항목으로부터 범주를 작성할 수 있습니다. 이 옵션은 출력을 최소 X개의 레코드 또는 문서에서 발생한 디스크립터를 포함하는 범주만으로 제한합니다. 여기서 X는 이 옵션에 입력할 값입니다.

**남은 모든 항목을 호출된 범주로 그룹화.** 이 옵션을 사용하면 덜 빈번하게 발생하는 모든 개념 또는 유형을 원하는 이름으로 된 하나의 '잡동사니' 범주로 그룹화할 수 있습니다. 기본적으로 이 범주의 이름은 *기타*입니다.

**범주 입력.** 기술을 적용할 그룹을 선택하십시오.

- **미사용 추출 결과.** 이 옵션은 기존 범주에 사용되지 않는 추출 결과로부터 범주를 작성할 수 있게 해줍니다. 이는 레코드가 여러 범주에 매치하는 경향을 최소화하고 생성된 범주의 수를 제한합니다.
- **모든 추출 결과.** 이 옵션을 사용하면 추출 결과를 사용하여 범주를 작성할 수 있습니다. 이는 범주가 없거나 몇몇 범주만이 이미 존재하는 경우에 매우 유용합니다.

**중복된 범주 이름 해결 기준** 이름이 기존 범주와 같은 새 범주 또는 하위 범주를 처리하는 방법을 선택하십시오. 이름이 같은 기존 범주와 새 범주(및 해당 디스크립터)를 병합할 수 있습니다. 또는 기존 범주에서 중복 이름이 발견된 경우 범주의 작성을 건너뛰도록 선택할 수도 있습니다.

## 6) 범주 확장

확장은 기존 범주를 '키우기'위해서 디스크립터가 추가되거나 자동으로 개선되는 프로세스입니다. 목적은 해당 범주에 원래 지정되지 않은 관련 레코드 또는 문서를 캡처하는 더 나은 범주를 생성하는 것입니다.

선택하는 자동 그룹화 기술은 기존 범주 디스크립터와 관련된 개념, TLA 패턴 및 범주 규칙을 식별하려고 시도합니다. 이러한 새 개념, 패턴 및 범주 규칙은 그런 다음 새 디스크립터로 추가되거나 기존 디스크립터에 추가됩니다. 확장을 위한 그룹화 기술에는 *개념 루트 파생*, *개념 포함*, *시맨틱 네트워크*(영어만 해당) 및 *동시 발생 규칙*이 포함됩니다. **빈 범주를 범주 이름에서 생성된 디스크립터를 사용하여 확장** 방법은 범주 이름의 단어를 사용하여 디스크립터를 생성합니다. 그러므로 범주 이름이 설명적인 이름일수록 더 좋은 결과가 나옵니다.

 **참고:** 빈도 기술은 범주를 확장할 때에는 사용할 수 없습니다.

확장은 범주를 대화식으로 개선하는 좋은 방법입니다. 다음은 범주를 확장할 수 있는 몇몇 예제입니다.

- 범주 분할창에서 범주를 작성하기 위해 개념 패턴을 끌어서 놓은 후
- 단순 범주 규칙 및 디스크립터를 추가하여 범주를 작성한 후
- 범주에 설명적인 이름이 있는 사전 정의된 범주 파일을 가져온 후
- 선택한 TAP으로부터 나온 범주를 세분화한 후

범주를 여러 번 확장할 수 있습니다. 예를 들어, 매우 설명적인 이름이 있는 사전 정의된 범주 파일을 가져온 경우에는 **범주 이름에서 생성된 디스크립터를 사용하여 빈 범주 확장** 옵션을 사용하여 확장하여 첫 번째 디스크립터 세트를 획득한 다음 이러한 범주를 다시 확장할 수 있습니다. 그러나 다른 경우에는 여러 번 확장하면 디스크립터가 점점 더 넓게 확장되어 너무 일반화된 범주가 생길 수도 있습니다. 그룹 작성 및 확장 기술은 유사한 기반 알고리즘을 사용하므로 범주를 작성한 직후에 확장하면 흥미로운 결과가 나올 가능성이 적습니다.

 **팁:**

- 확장을 시도하지만 결과를 사용하지 않으려는 경우에는 확장한 직후에 작업(**편집 > 실행 취소**)을 언제든지 취소할 수 있습니다.
- 확장하면 범주에 문서 세트가 정확하게 매치하는 둘 이상의 범주 규칙이 생성될 수 있습니다. 규칙은 프로세스와는 별개로 작성되기 때문입니다. 원하는 경우 범주를 검토하고 범주 설명을 수동으로 편집하여 중복을 제거할 수 있습니다. 자세한 정보는 범주 디스크립터 편집의 내용을 참조하십시오.

## 범주 확장 방법

1. 범주 분할창에서 확장하려는 범주를 선택하십시오.
  2. 메뉴에서 범주 > 범주 확장을 선택하십시오. 프롬프트하지 않기로 선택하지 않은 한 메시지 상자가 나타납니다.
  3. 지금 작성할지 또는 설정을 먼저 편집할지를 선택하십시오.
- 현재 설정을 사용하여 범주 확장을 시작하려면 **지금 확장**을 클릭하십시오. 프로세스가 시작되고 진행률 대화 상자가 나타납니다.
  - 설정을 검토하고 수정하려면 **편집**을 클릭하십시오.

확장하려고 시도한 후에 새 디스크립터가 발견된 모든 범주는 범주 분할창에서 빠르게 식별할 수 있도록 **확장됨** 단어가 플래그되어 있습니다. 확장된 텍스트는 다시 확장하거나, 다른 방법으로 범주를 편집하거나 컨텍스트 메뉴를 통해 이를 지울 때까지 그대로 남아 있습니다.

**참고:** 표시할 수 있는 최대 범주 수는 10,000개입니다. 이 숫자에 도달했거나 초과되면 경고가 표시됩니다. 이 경우에는 범주 작성 또는 확장 옵션을 변경하여 작성된 범주 수를 줄여야 합니다.

범주를 작성하거나 확장할 때 사용 가능한 각 기술은 특정 데이터 유형과 상황에 적합하지만 종종 문서 또는 레코드의 전체 범위를 캡처하기 위해 동일한 분석에서 기술을 결합하는 것이 도움이 됩니다. 대화식 워크벤치에서 범주로 그룹화된 개념과 유형은 다음 번에 범주를 작성할 때에도 여전히 사용 가능합니다. 즉 여러 범주에서 개념을 보거나 중복된 범주를 찾을 수도 있습니다.

다음 영역과 필드는 범주 확장: 설정 대화 상자에서 사용 가능합니다.

**확장 방법.** 범주를 확장하는 데 사용될 입력을 선택하십시오.

- **미사용 추출 결과.** 이 옵션은 기존 범주에 사용되지 않는 추출 결과로부터 범주를 작성할 수 있게 해줍니다. 이는 레코드가 여러 범주에 매치하는 경향을 최소화하고 생성된 범주의 수를 제한합니다.
- **모든 추출 결과.** 이 옵션을 사용하면 추출 결과를 사용하여 범주를 작성할 수 있습니다. 이는 범주가 없거나 몇몇 범주만이 이미 존재하는 경우에 매우 유용합니다.

## 그룹화 기술

이러한 각 기술의 간단한 설명은 고급 언어학적 설정의 내용을 참조하십시오. 이러한 기술은 다음을 포함합니다.

- 개념 루트 파생
- 시맨틱 네트워크(영어 텍스트에만 사용 가능하고 일반화 전용 옵션이 선택된 경우에는 사용되지 않습니다.)
- 개념 포함
- 동시 발생 및 최소 문서 수 하위 옵션

많은 유형이 시맨틱 네트워크 기술에서 영구적으로 제외되었습니다. 이러한 유형이 관련 결과를 생성하지 않기 때문입니다. 여기에는 <Positive>, <Negative>, <IP>, 기타 비언어학적 유형 등이 포함됩니다.

**최대 검색 거리** 범주를 생성하기 전에 기술이 검색할 범위를 선택하십시오. 값이 낮을수록 더 적은 수의 결과를 얻게 되지만, 이러한 결과는 잡음이 적고 서로 간에 의미 있게 링크되어 있거나 연관되어 있을 수 있습니다. 값이 높을수록 더 많은 수의 결과를 얻게 되지만 이러한 결과는 믿을 만하지 않거나 적절하지 않을 수 있습니다. 이러한 옵션은 모든 기술에 글로벌하게 적용되지만 동시 발생과 시맨틱 네트워크에 미치는 영향은 상당합니다.

**특정 개념 쌍 방지.** 프로세스가 출력에 두 개의 개념을 함께 그룹화하거나 쌍으로 만드는 프로세스를 중지하려면 이 선택란을 선택하십시오. 개념 쌍을 작성하거나 관리하려면 **쌍 관리**를 클릭하십시오. 자세한 정보는 링크 예외 쌍 관리 주제를 참조하십시오.

**가능한 경우:** 단순히 확장할지, 와일드카드를 사용하여 디스크립터를 일반화할지 또는 둘 모두를 사용할지 선택하십시오.

- **확장 및 일반화.** 이 옵션은 선택된 범주를 확장한 다음 디스크립터를 일반화합니다. 일반화하기로 선택하면 제품은 별표 와일드카드를 사용하여 범주에서 일반 범주 규칙을 작성합니다. 예를 들어, [apple tart + .] 및 [apple sauce + .] 등과 같은 여러 디스크립터를 생성하는 대신에 와일드카드를 사용하면 [apple \* + .]을 생성할 수 있습니다. 와일드카드를 사용하여 일반화하면 종종 앞서 한 것과 똑같은 수의 레코드 또는 문서 수를 얻게 됩니다. 그러나 이 옵션은 숫자를 줄이고 범주 디스크립터를 단순화하는 장점이 있습니다. 또한 이 옵션은 새 텍스트 데이터(예를 들어, 세로/파동 연구에서)에서 이러한 범주를 사용하여 더 많은 레코드 또는 문서를 범주화하는 기능을 증가시킵니다.
- **확장만.** 이 옵션은 일반화없이 범주를 확장합니다. 먼저 수동으로 작성된 범주에 대해 **확장만** 옵션을 선택한 다음 **확장 후 일반화** 옵션을 사용하여 동일한 범주를 다시 확장하는 것이 도움이 됩니다.
- **일반화만.** 이 옵션은 범주를 다른 방법으로 확장하지 않고 디스크립터를 일반화합니다.

 **참고:** 이 옵션을 선택하면 **시맨틱 네트워크** 옵션이 사용 안함으로 설정됩니다. 이는 설명을 확장하려고 할 때 **시맨틱 네트워크** 옵션만이 사용 가능하기 때문입니다.

## 범주 확장을 위한 기타 옵션

적용할 기술을 선택하는 것에 추가로 다음 옵션을 편집할 수 있습니다.

**디스크립터를 확장할 기준이 되는 최대 항목 수.** 항목(개념, 유형 및 기타 표현식)과 함께 디스크립터를 확장할 때 단일 디스크립터에 추가할 수 있는 최대 항목 수를 정의하십시오. 이 한계를 10으로 설정하면 10개가 넘는 추가 항목은 기존 디스크립터에 추가할 수 없습니다. 추가할 항목이 10개가 넘으면 기술은 10번째가 추가된 후에는 새 항목 추가를 중지합니다. 이를 수행하면 디스크립터 목록이 더 짧아지지만 가장 흥미로운 항목이 먼저 사용되게 하지는 못합니다. **가능한 경우 와일드카드로 일반화** 옵션을 사용하여 품질을 저하시키지 않고도 확장의 크기를 줄이는 것을 선호할 수 있습니다. 이 옵션은 부울 &(AND) 또는 !(NOT)을 포함하는 디스크립터에만 적용됩니다.

**하위 범주도 확장.** 이 옵션은 선택한 범주 아래에 있는 모든 하위 범주를 확장합니다.

**범주 이름에서 생성된 디스크립터를 사용하여 빈 범주 확장.** 이 방법은 0개의 디스크립터가 있는 빈 범주에만 적용됩니다. 범주에 이미 디스크립터가 포함된 경우에는 이 방법으로 확장되지 않습니다. 이 옵션은 범주의 이름을 구성하는 단어를 기반으로 각 범주의 디스크립터를 자동으로 작성하려고 시도합니다. 범주 이름은 이름에 있는 단어가 추출된 개념과 매치하는지를 확인하기 위해 스캔됩니다. 개념이 인식된 경우에는 매치하는 개념 패턴을 찾는 데 사용되고 이들 모두는 범주의 디스크립터를 형성하는 데 사용됩니다. 이 옵션은 범주 이름이 둘 모두 길고 설명적인 경우에 최상의 결과를 생성합니다. 이는 범주가 이러한 디스크립터를 포함하는 레코드를 캡처할 수 있도록 범주 디스크립터를 생성하기 위한 빠른 방법입니다. 이 옵션은 다른 곳에서 범주를 가져오거나 긴 설명 이름을 사용하여 수동으로 범주를 작성할 때 가장 유용합니다.

**디스크립터를 다른 이름으로 생성.** 이 옵션은 앞의 옵션이 선택된 경우에만 적용됩니다.

- **개념.** 소스 텍스트에서 추출되었는지 여부와는 관계없이 결과로 나오는 디스크립터를 개념 양식으로 생성하려면 이 옵션을 선택하십시오.
- **패턴.** 결과로 나오는 패턴 또는 임의의 패턴이 추출되었는지 여부와 관계없이 결과로 나오는 디스크립터를 패턴 양식으로 생성하려면 이 옵션을 선택하십시오.

## 7) 수동으로 범주 작성

자동화된 범주 작성 기술, 및 규칙 편집기를 사용하여 범주를 작성하는 데에 추가로 범주를 수동으로 작성할 수도 있습니다. 다음과 같은 수동 방법이 존재합니다.

- 요소를 하나씩 추가할 빈 범주 작성. 자세한 정보는 범주 새로 작성 또는 이름 변경의 내용을 참조하십시오.
- 용어, 유형 및 패턴을 범주 분할창으로 끌기. 자세한 정보는 끌어서 놓기로 범주 작성의 내용을 참조하십시오.

## (1) 범주 새로 작성 또는 이름 변경

개념과 유형을 추가하기 위한 빈 범주를 작성할 수 있습니다. 범주의 이름을 변경할 수도 있습니다.

빈 범주를 새로 작성

1. 범주 분할창으로 이동하십시오.
2. 메뉴에서 **범주 > 빈 범주 작성**을 선택하십시오. 범주 특성 대화 상자가 열립니다.
3. 이름 필드에 이 범주의 이름을 입력하십시오.
4. 이름을 승인하려면 **확인**을 클릭하고 대화 상자를 닫으십시오. 대화 상자가 닫히고 새 범주 이름이 분할창에 나타납니다.

이제 이 범주에 추가를 시작할 수 있습니다. 자세한 정보는 디스크립터를 범주에 추가의 내용을 참조하십시오.

범주 이름 변경

1. 범주를 선택하고 **범주 > 범주 이름 변경**을 선택하십시오. 범주 특성 대화 상자가 열립니다.
2. 이름 필드에 이 범주의 새 이름을 입력하십시오.
3. 이름을 승인하려면 **확인**을 클릭하고 대화 상자를 닫으십시오. 대화 상자가 닫히고 새 범주 이름이 분할창에 나타납니다.

## (2) 끌어서 놓기로 범주 작성

끌어서 놓기 기술은 수동이며 알고리즘을 기반으로 하지 않습니다. 다음을 끌어서 범주 분할창에서 범주를 작성할 수 있습니다.

- 추출된 개념, 유형 또는 패턴을 추출 결과 분할창에서 범주 분할창으로.
- 추출된 개념을 데이터 분할창에서 범주 분할창으로.
- 전체 행을 데이터 분할창에서 범주 분할창으로. 그러면 추출된 모든 개념과 해당 행에 포함된 패턴으로 구성된 범주가 작성됩니다.

**참고:** 추출 결과 분할창은 여러 요소의 끌어서 놓기를 쉽게 할 수 있도록 다중 선택을 지원합니다.

**중요!** 텍스트로부터 추출되지 않았던 데이터 분할창에서는 개념을 끌어서 놓을 수 없습니다. 데이터에서 발견한 개념의 추출을 강제 실행하려면 유형에 이 개념을 추가해야 합니다. 그런 다음 추출을 다시 실행하십시오. 새 추출 결과에는 방금 추가한 개념이 포함됩니다. 그런 다음 이를 범주에 사용할 수 있습니다. 자세한 정보는 유형에 개념 추가의 내용을 참조하십시오.

### 끌어서 놓기를 사용하여 범주 작성:

1. 추출 결과 분할창 또는 데이터 분할창에서 하나 이상의 개념, 패턴, 유형, 레코드 또는 부분 레코드를 선택하십시오.
2. 마우스 단추를 누르고 있는 동안 요소를 기존 범주 또는 분할창 영역으로 끌어서 새 범주를 작성하십시오.
3. 요소를 놓으려는 영역에 도달하면 마우스 단추를 놓으십시오. 요소가 범주 분할창에 추가됩니다. 수정된 범주가 특수 배경 색상과 함께 나타납니다. 이 색상은 **범주 피드백 배경**이라 부릅니다. 자세한 정보는 옵션 설정 주제를 참조하십시오.

**참고:** 결과로 나오는 범주가 자동으로 이름이 지정되었습니다. 이름을 변경하려면 변경할 수 있습니다. 자세한 정보는 범주 새로 작성 또는 이름 변경의 내용을 참조하십시오.

범주에 어떤 레코드가 지정되는지 보려면 범주 분할창에서 해당 범주를 선택하십시오. 데이터 분할창이 자동으로 새로 고쳐지고 해당 범주의 모든 레코드를 표시합니다.

## 8) 범주 규칙 사용

여러 가지 방법으로 범주를 작성할 수 있습니다. 이러한 방법 중 하나는 아이디어를 표현하기 위해 범주 규칙을 정의하는 것입니다. 범주 규칙은 문서 또는 레코드를 추출된 개념, 유형 및 패턴뿐만 아니라 부울 연산자를 사용하여 논리적 표현식을 기반으로 범주에 자동으로 분류하는 명령문입니다. 예를 들어, *추출된 개념 embassy을 포함하지만 argentina는 포함하지 않는 모든 레코드를 이 범주에 포함*을 의미하는 표현식을 작성할 수 있습니다.

**동시 발생 및 개념 루트 파생(범주 > 작성 설정 > 고급 설정: 언어학적)** 등과 같은 그룹화 기술을 사용하여 범주를 작성할 때 몇몇 범주 규칙은 자동으로 생성되지만 규칙 편집기에서 데이터와 컨텍스트의 범주 이해를 사용하여 범주 규칙을 수동으로 작성할 수도 있습니다. 각 규칙은 규칙과 매치하는 각 문서 또는 레코드가 해당 범주에 기록될 수 있도록 단일 범주에 첨부됩니다.

범주 규칙은 반응을 특이도를 사용하여 범주화할 수 있게 하여 텍스트 마이닝 결과의 품질과 생산성 및 보다 양적인 분석을 개선하는 데 도움을 줍니다. 사용자의 경험과 비즈니스 지식은 데이터와 컨텍스트의 특정 이해를 제공할 수 있습니다. 추출된 요소를 부울 논리와 결합하여 문서 또는 레코드를 보다 효율적이고 정확하게 범주화하기 위해 이 이해를 활용하여 해당 지식을 범주 규칙으로 변환할 수 있습니다.

이러한 규칙을 작성하는 기능은 비즈니스 지식을 제품의 추출 기술로 계층화할 수 있도록 허용하여 코드 정확도, 효율성 및 생산성을 개선합니다.

규칙으로 다음을 수행할 수 있습니다.

- 규칙을 작성하고 테스트합니다. 자세한 정보는 범주 규칙 작성의 내용을 참조하십시오.
- 규칙을 편집하거나 삭제합니다. 자세한 정보는 규칙 편집 및 삭제의 내용을 참조하십시오.

**참고:** 규칙이 텍스트와 매치하는 방법에 대한 예제는 범주 규칙 예제의 내용을 참조하십시오.

## (1) 범주 규칙 구문

동시 발생 및 개념 루트 파생(범주 > 작성 설정 > 고급 설정: 언어학적) 등과 같은 그룹화 기술을 사용하여 범주를 작성할 때 몇몇 범주 규칙은 자동으로 생성되지만 규칙 편집기에서 범주 규칙을 수동으로 작성할 수도 있습니다. 각 규칙은 단일 범주의 디스크립터입니다. 그러므로 규칙과 매치하는 각 문서 또는 레코드가 해당 범주에 자동으로 기록됩니다.

**참고:** 규칙이 텍스트와 매치하는 방법에 대한 예제는 범주 규칙 예제의 내용을 참조하십시오.

규칙을 작성하거나 편집할 때 규칙이 규칙 편집기에서 열려 있어야 합니다. 개념, 유형 또는 패턴을 추가하거나 와일드카드를 사용하여 매치를 확장할 수 있습니다. 추출된 개념, 유형 및 패턴을 사용하면 이는 관련된 모든 개념을 찾으므로 장점이 있습니다.

**중요!** 일반적인 오류를 피하려면 개념을 추출 결과 분할창, 텍스트 링크 분석 분할창 또는 데이터 분할창에서 직접 규칙 편집기로 끌어다 놓거나 가능한 경우 컨텍스트 메뉴를 통해 이를 추가하는 것이 좋습니다.

개념, 유형 및 패턴이 인식되면 아이콘이 텍스트 옆에 나타납니다.

표 1. 추출 아이콘	
아이콘	설명
	추출된 개념
	추출된 유형
	추출된 패턴

## 규칙 구문 및 연산자

다음 표는 규칙 구문을 정의할 때 사용할 문자를 포함합니다. 이러한 문자를 개념, 유형 및 패턴과 함께 사용하여 사용자만의 규칙을 작성하십시오.

표 2. 지원되는 구문

문자	설명
&	"and" 부울. 예를 들어, a & b에는 다음과 같은 a 및 b 둘 모두가 포함됩니다. - invasion & united states - 2016 & olympics - good & apple
	"or" 부울은 포함이며 이는 요소의 일부 또는 모두가 발견되면 매치가 이뤄짐을 의미합니다. 예를 들어, a   b에는 다음과 같은 a 또는 b가 포함됩니다. - attack   france - condominium   apartment
!()	"not" 부울. 예를 들어, !(a)에는 a를 포함하지 않습니다. 예: !(good & hotel) , assassination & !(austria) 또는 !(gold) & !(copper)
*	사용 방법에 따라 단일 문자부터 전체 단어까지 모든 것을 표현하는 와일드카드. 자세한 정보는 범주 규칙에서 와일드카드 사용의 내용을 참조하십시오.
()	표현식 구분자. 괄호 안에 있는 표현식이 먼저 평가됩니다.
+	순서 특정 패턴을 형성하는 데 사용된 패턴 연결자. 이 패턴 연결자가 있으면 꺾쇠 대괄호가 사용되어야 합니다. 자세한 정보는 범주 규칙에서 TLA 패턴 사용의 내용을 참조하십시오.
[]	범주 규칙 내에서 추출된 TLA 패턴을 기반으로 매치를 찾고 있는 경우에는 패턴 구분자는 필수입니다. 대괄호 내의 콘텐츠는 TLA 패턴을 가리키고 단순 동시 발생을 기반으로 하는 개념이나 유형과는 매치하지 않습니다. 이 TLA 패턴을 추출하지 않은 경우에는 매치가 가능하지 않습니다. 자세한 정보는 범주 규칙에서 TLA 패턴 사용의 내용을 참조하십시오. 패턴 대신에 개념과 유형 매치를 찾고 있다면 꺾쇠 대괄호를 사용하지 마십시오. 참고: 이전 버전에서는 범주 작성 기술을 사용하여 생성된 동시 발생 및 동의어 규칙은 꺾쇠 대괄호로 둘러싸여 있었습니다. 모든 신규 버전에서는 꺾쇠 대괄호는 TLA 패턴의 존재를 나타냅니다. 대신, 동시 발생 기술과 동의어를 사용하여 생성된 규칙은 괄호로 캡슐화되어 있습니다(예: (speaker systems   speakers)).

& 및 | 연산자는 가환적입니다(예: a & b = b & a 및 a | b = b | a).

#### 문자를 백슬래시로 이스케이프

마찬가지로 구문 문자인 모든 문자를 포함하는 개념이 있는 경우에는 규칙이 제대로 해석되게 하려면 해당 문자 앞에 백슬래시를 놓아야 합니다. 백슬래시(\) 문자는 백슬래시를 사용하지 않을 경우에는 특별한 의미를 가지고 있는 문자를 이스케이프 처리하는 데 사용됩니다. 편집기에 끌어서 놓으면 백슬래시가 자동으로 추가됩니다.

규칙 구문 문자를 규칙 구문이 아닌 것처럼 처리하려면 규칙 구문 문자 앞에 백슬래시가 와야 합니다.

& ! | + < > ( ) [ ] \*

예를 들어, 개념 r&d에 "and" 연산자(&)가 포함되므로 이를 규칙 편집기에 입력할 때 백슬래시가 필요합니다(예: r\&d).

## (2) 범주 규칙에서 TLA 패턴 사용

텍스트 링크 분석 패턴은 보다 특정적이고 컨텍스트상 결과를 얻을 수 있도록 범주 규칙에 명시적으로 정의될 수 있습니다. 범주 규칙에서 패턴을 정의할 때 더 많은 단순 개념 추출 결과와 추출된 텍스트 링크 분석 패턴 결과를 기반으로 매치하는 문서와 레코드만을 무시하고 있습니다.

**중요!** 범주 규칙에서 TLA 패턴을 사용하여 문서를 매치시키려면 텍스트 링크 분석이 사용 가능한 상태에서 추출을 실행해야 합니다. 범주 규칙은 해당 프로세스 동안에 발견된 매치를 찾습니다. 텍스트 마이닝 노드의 모델 탭에서 TLA 결과를 탐색하려고 선택하지 않은 경우에는 대화식 세션 내에서 추출 설정에서 TLA 추출을 사용 가능으로 선택한 다음에 다시 추출할 수 있습니다. 자세한 정보는 데이터 추출의 내용을 참조하십시오.

**꺾쇠 대괄호로 구분.** 범주 규칙 내에서 TLA 패턴을 사용 중이라면 이를 꺾쇠 대괄호 [ ]로 둘러싸야 합니다. 추출된 TLA 패턴을 기반으로 매치를 찾고 있는 경우에는 패턴 구분자는 필수입니다. 범주 규칙은 유형, 개념 또는 패턴을 포함할 수 있으므로, 대괄호는 대괄호 내의 콘텐츠가 추출된 TLA 패턴을 가리킨다는 점을 규칙에 분명히 합니다. 이 TLA 패턴을 추출하지 않은 경우에는 매치가 가능하지 않습니다. 범주 분할창에서 apple + good 등과 같이 대괄호가 없는 패턴을 보는 경우에는 패턴이 범주 규칙 편집기 외부의 범주에 직접 추가되었음을 의미합니다. 예를 들어, 개념 패턴을 텍스트 링크 분석 보기 에서 범주에 직접 추가하는 경우에는 이는 꺾쇠 대괄호와 함께 나타나지 않습니다. 그러나 범주 규칙 내의 패턴을 사용할 때는 범주 규칙 내에서 패턴을 꺾쇠 대괄호 내에 캡슐화해야 합니다(예: [banana + !(good)]).

**패턴에서 + 부호 사용.** IBM® SPSS® Modeler Text Analytics에서 최대 6개의 파트 또는 -슬롯, 패턴이 있을 수 있습니다. 순서가 중요함을 나타내려면 + 부호를 사용하여 각 요소를 연결하십시오(예: [company1 + acquired + company2]). 회사가 획득하고 있는 의미를 변경할 수 있으므로 여기에서는 순서가 중요합니다. 순서는 문장 구조로 결정되지 않지만 TLA 패턴 출력이 구조화되는 방법으로 결정됩니다. 예를 들어, "I love Paris" 텍스트가 있고 이 아이디어를 추출하려면, TLA 패턴은 [<Positive> + <Location>]가 아니라 [paris + like] 또는 [<Location> + <Positive>]일 수 있습니다. 기본 의견 자원은 일반적으로 의견을 2개의 파트로 된 패턴에서 두 번째 위치에 놓기 때문입니다. 따라서 문제를 피하기 위해서는 범주에서 패턴을 디스크립터로 직접 사용하는 것이 도움이 될 수 있습니다. 그러나 패턴을 보다 복잡한 명령문의 일부로 사용해야 하는 경우에는 텍스트 링크 분석 보기에 있는 패턴 내의 요소의 순서에 특히 주의를 기울이십시오. 순서는 매치를 발견할 수 있는지 여부에 커다란 역할을 하기 때문입니다.

예를 들어, 다음과 같이 두 개의 샘플 텍스트 표현식이 있다고 가정해 봅시다: "I like pineapple" and "I hate pineapple. However, I like strawberries". like & pineapple 표현식은 개념 표현식이고 텍스트 링크 규칙이 아니므로(대괄호로 둘러싸이지 않음) 두 텍스트 모두와 매치합니다. 표현식 pineapple + like는 "I like pineapple"와만 매치합니다. 두 번째 텍스트에서 단어 like는 대신 strawberries와 연관되기 때문입니다.

**패턴으로 그룹화.** 사용자만의 패턴을 사용하여 규칙을 단순화할 수 있습니다. 다음과 같이 cayenne peppers + like, chili peppers + like 및 peppers + like의 세 개의 표현식을 캡처한다고 가정합니다. 이를 단일 범주 그룹으로 그룹화할 수 있습니다(예: [\* peppers & like]). 또 다른 표현식 hot peppers + good이 있는 경우에는 이들 네 개를 규칙으로 그룹화할 수 있습니다(예: [\* peppers + <Positive>]).

**패턴에서의 순서.** 출력을 보다 잘 구성하기 위해서 제품과 함께 설치한 템플릿에 제공된 텍스트 링크 분석 규칙은 문장에서의 단어 순서와는 관계없이 동일한 순서로 기본 패턴을 출력하려고 시도합니다. 예를 들어, "Good presentations." 텍스트를 포함하는 레코드와 "the presentations were good"을 포함하는 또 다른 레코드가 있는 경우에는 두 텍스트 모두 동일한 규칙으로 매치하고 개념 패턴 결과에서 presentation + good 및 good + presentation이 아닌 presentation + good과 동일한 순서로 출력됩니다. 예제에서처럼 두 개의 슬롯 패턴에서는 Opinions 라이브러리에서 유형에 지정된 개념은 기본적으로 apple + bad에서와 같이 출력에서 마지막에 제공됩니다.

표 1. 패턴 구문 및 부호 사용법	
표현식	문서 또는 레코드와 매치합니다.
[ ]	모든 TLA 패턴을 포함합니다. 추출된 TLA 패턴을 기반으로 매치를 찾고 있는 경우에는 패턴 구분자는 범주 규칙에서 필수입니다. 대괄호 내의 콘텐츠는 단순 개념과 유형이 아니라 TLA 패턴을 가리킵니다. 이 TLA 패턴을 추출하지 않은 경우에는 매치가 가능하지 않습니다. 패턴을 포함하지 않는 규칙을 작성하려는 경우에는 !( [ ])를 사용할 수 있습니다.
[a]	패턴에서의 위치와 관계없이 하나 이상의 요소가 a인 패턴을 포함합니다. 예를 들어, [deal]은 [deal + good] 또는 단지 [deal + .]와 매치할 수 있습니다.
[a + b]	개념 패턴을 포함합니다. 예를 들어, [deal + good]입니다. 참고: 다른 요소를 추가하지 않고 이 패턴을 캡처만 하려는 경우에는 패턴을 사용하여 규칙을 작성하는 대신 범주에 직접 추가하는 것이 좋습니다.
[a + b + c]	개념 패턴을 포함합니다. + 부호는 매치하는 요소의 순서가 중요함을 나타냅니다. 예를 들어, [company1 + acquired + company2]입니다.

표현식	문서 또는 레코드와 매치합니다.
[<A> + <B>]	첫 번째 슬롯에 <A> 유형이 있는 패턴과 두 번째 슬롯에 <B> 유형이 있는 패턴을 포함하고 정확히 두 개의 슬롯이 있습니다. + 부호는 매치하는 요소의 순서가 중요함을 나타냅니다. 예를 들어, [<Budget> + <Negative>]입니다. 참고: 다른 요소를 추가하지 않고 이 패턴을 캡처만 하려는 경우에는 패턴을 사용하여 규칙을 작성하는 대신 범주에 직접 추가하는 것이 좋습니다.
[<A> & <B>]	<A> 유형 및 <B> 유형이 있는 모든 유형 패턴을 포함합니다. 예를 들어, [<Budget> & <Negative>]입니다. 이 TLA 패턴은 결코 추출되지 않습니다. 그러나 이렇게 작성되면 정말로 [<Budget> + <Negative>][<Negative> + <Budget>]과 동등합니다. 매치 요소의 순서는 중요하지 않습니다. 또한 다른 요소는 패턴에 있을 수 있지만 하나 이상의 <Budget> 및 <Negative>가 있어야 합니다.
[a + .]	a가 유일한 개념이고 해당 패턴의 다른 슬롯에 아무것도 없는 패턴을 포함합니다. 예를 들어, [deal + .]는 유일한 출력이 deal인 개념 패턴과 매치합니다. 개념 deal을 범주 디스크립터로서 추가한 경우에는 deal에 대한 긍정적인 명령문을 포함하여 deal이 있는 모든 레코드를 개념으로서 얻을 수 있습니다. 그러나 [deal + .]을 사용하면 deal을 표현하는 레코드 패턴 결과와만 매치하고 다른 관계나 의견과는 매치하지 않고 deal + fantastic과도 매치하지 않습니다. 참고: 다른 요소를 추가하지 않고 이 패턴을 캡처만 하려는 경우에는 패턴을 사용하여 규칙을 작성하는 대신 범주에 직접 추가하는 것이 좋습니다.
[<A> + <>]	<A>가 유일한 유형인 패턴을 포함합니다. 예를 들어, [<Budget> + <>]는 유일한 출력이 <Budget> 유형의 개념인 패턴과 매치합니다. 참고: <> 를 사용하여 유형 패턴에서 패턴 + 기호 뒤에 이를 배치할 때만 빈 유형을 나타낼 수 있습니다(예: [<Budget> + <>], [price + <>]는 아님). 참고: 다른 요소를 추가하지 않고 이 패턴을 캡처만 하려는 경우에는 패턴을 사용하여 규칙을 작성하는 대신 범주에 직접 추가하는 것이 좋습니다.
[a + !(b)]	개념 a를 포함하지만 개념 b를 포함하지 않는 하나 이상의 패턴을 포함합니다. 하나 이상의 패턴을 포함해야 합니다. 예를 들어, [price + !(high)] 또는 유형의 경우 [!(<Fruit> <Vegetable>) + <Positive>]
!([<A> & <B>])	특정 패턴을 포함하지 않습니다. 예를 들어, ![(<Budget> & <Negative>)]입니다.

참고: 규칙이 텍스트와 매치하는 방법에 대한 예제는 범주 규칙 예제의 내용을 참조하십시오.

### (3) 범주 규칙에서 와일드카드 사용

와일드카드는 매치하는 기능을 확장하기 위해 규칙에서 개념에 추가할 수 있습니다. 별표 \* 와일드카드는 개념이 어떻게 매치하는지를 표시하기 위해 단어 앞이나 뒤에 놓을 수 있습니다. 와일드카드 사용에는 두 개의 유형이 있습니다.

- **첨부 와일드카드.** 이러한 와일드카드는 문자열과 별표를 구분하는 공백 없이 접두문자나 접미문자를 바로 붙입니다. 예를 들어, *operat\**는 *operat, operate, operates, operations, operational* 등과 매치할 수 있습니다.
- **단어 와일드카드.** 이러한 와일드카드는 개념과 별표 사이의 공백을 사용하여 개념에 접두문자나 접미문자를 추가합니다. 예를 들어, *\* operation*은 *operation, surgical operation, post operation* 등과 매치할 수 있습니다. 또한 단어 와일드카드는 첨부 와일드카드와 나란히 사용할 수 있습니다. 예를 들어, *\* operat\* \**는 *operation, surgical operation, telephone operator, operatic aria* 등과 매치할 수 있습니다. 이 마지막 예에서 볼 수 있듯이 그물을 너무 넓게 던져서 원하지 않는 매치를 캡처하지 않도록 와일드카드를 주의깊게 사용하는 것이 좋습니다.

#### 예외!

- 와일드카드는 단독으로 사용될 수 없습니다. 예를 들어, *(apple | \* )*는 허용되지 않습니다.
- 와일드카드는 유형 이름과 매치시키는 데 사용할 수 없습니다. *<Negative\*>*는 어떤 유형 이름과도 매치하지 않습니다.
- 특정 유형을 와일드카드를 통해 발견된 개념과 매치하지 않도록 필터링할 수 없습니다. 개념이 지정된 유형이 자동으로 사용됩니다.
- 와일드카드는 단어의 끝이나 시작이거나 관계없이 단어 순서의 중간에 오거나(*open\* account*) 독립된 구성요소(*open \* account*)일 수 없습니다. 와일드카드는 유형 이름에도 사용할 수 없습니다. 예를 들어, *word\* word*(예: *apple\* recipe*)는 *applesauce recipe* 또는 다른 어떤 것과도 매치하지 않습니다. 그러나 *apple\* \**는 *applesauce recipe, apple pie, apple* 등과 매치합니다. 다른 예제에서 *word \* word*(예: *apple \* toast*)는 *apple cinnamon toast* 또는 다른 어떤 것과도 매치하지 않습니다. 별표가 두 개의 다른 단어 사이에 나타나기 때문입니다. 그러나 *apple \**는 *apple cinnamon toast, apple, apple pie* 등과 매치합니다.

표 1. 와일드카드 사용법

표현식	문서 또는 레코드와 매치합니다.
*apple	작성된 글자로 끝나지만 다른 여러 글자가 접두문자로 있을 수 있는 개념을 포함합니다. 예를 들어, *apple은 <i>apple</i> 글자로 끝나지만 다음과 같은 접두문자를 사용할 수 있습니다. - <i>apple - pineapple - crabapple</i>

표현식	문서 또는 레코드와 매치합니다.
apple*	작성된 글자로 시작하지만 다른 여러 글자가 접미문자로 있을 수 있는 개념을 포함합니다. 예를 들어, apple*는 글자 <i>apple</i> 로 시작하지만 접미문자를 사용하거나 사용하지 않을 수 있습니다. 예: - apple - applesauce - applejack 예를 들어, apple* & !(pear*   quince)은 글자 apple로 시작하는 개념을 포함하지만 글자 <i>pear</i> 로 시작하는 개념이나 quince 개념을 포함하지 않고 apple & quince와 매치하지 않습니다. 그러나 다음과 같은 매치할 수 있습니다. - applesauce - apple & orange
*product*	작성된 글자 product를 포함하지만 접두문자나 접미문자 또는 둘 모두로 여러 글자가 사용되고 있을 수 있는 개념을 포함합니다. 예를 들어, *product*는 다음과 매치할 수 있습니다. - product - byproduct - unproductive
* loan	단어 loan을 포함하지만 앞에 다른 단어가 있는 복합어일 수 있는 개념을 포함합니다. 예를 들어, * loan은 다음과 매치할 수 있습니다. - loan - car loan - home equity loan 예를 들어, [* delivery + <Negative>]는 첫 번째 위치에서 단어 delivery로 끝나는 개념을 포함하고 두 번째 위치에서 <Negative> 유형을 포함하고 다음 개념 패턴과 매치할 수 있습니다. - package delivery + slow - overnight delivery + late
event *	단어 event를 포함하지만 다른 단어가 따라오는 복합어일 수 있는 개념을 포함합니다. 예를 들어, event *는 다음과 매치할 수 있습니다. - event - event location - event planning committee
* apple *	또 다른 단어가 따라올 가능성이 있고 단어 apple이 따라오는 단어로 시작할 수 있는 개념을 포함합니다. *는 0 또는 n을 의미하므로 이는 또한 apple과 매치합니다. 예를 들어, * apple *는 다음과 매치할 수 있습니다. - gala applesauce - granny smith apple crumble - famous apple pie - apple 예를 들어, [* reservation* * + <Positive>]는 단어 reservation(개념에 있는지 여부와 관계없이)이 첫 번째 위치에 있는 개념을 포함하고 두 번째 위치에 유형 <Positive>를 포함하고 개념 패턴과 매치할 수 있습니다. - reservation system + good - online reservation + good

참고: 규칙이 텍스트와 매치하는 방법에 대한 예제는 범주 규칙 예제의 내용을 참조하십시오.

#### (4) 범주 규칙 예제

규칙이 이를 표현하는 데 사용된 구문에 따라 다르게 레코드에 어떻게 매치하는지를 시연하려면 다음 예제를 고려하십시오.

예제 레코드

두 개의 레코드가 있다고 상상해 보십시오.

- 레코드 A: *“when I checked my wallet, I saw I was missing 5 dollars.”*
- 레코드 B: *“\$5 was found at the picnic area, but the blanket was missing.”*

다음 두 개의 테이블은 개념과 유형뿐만 아니라 개념 패턴과 유형 패턴에서 무엇이 추출될 수 있는지를 보여줍니다.

예제에서 추출된 개념 및 유형

표 1. 추출된 개념 및 유형 예제	
추출된 개념	개념 유형
wallet	<Unknown >
missing	<Negative>
USD5	<Currency>
blanket	<Unknown >
picnic area	<Unknown >

예제에서 추출된 TLA 패턴

표 2. 예제 추출된 TLA 패턴 출력		
추출된 개념 패턴	추출된 유형 패턴	시작 레코드
picnic area + .	<Unknown> + <>	레코드 B
wallet + .	<Unknown> + <>	레코드 A
blanket + missing	<Unknown> + <Negative>	레코드 B
USD5 + .	<Currency> + <>	레코드 B
USD5 + missing	<Currency> + <Negative>	레코드 A

### 범주 규칙이 매치하는 방법

다음 표에는 범주 규칙 편집기에 입력할 수 있는 몇몇 구문이 포함됩니다. 여기에 있는 모든 규칙이 작동하는 것은 아니며 모두 동일 레코드와 매치하는 것은 아닙니다. 서로 다른 구문이 매치된 레코드에 어떤 영향을 미치는지를 확인하십시오.

표 3. 표본 규칙	
규칙 구문	결과
USD5 & missing	레코드 A와 B 둘 모두 추출된 개념 missing과 추출된 개념 USD5를 포함하므로 둘 모두 매치합니다. 이는 다음과 동등합니다. (USD5 & missing)
missing & USD5	레코드 A와 B 둘 모두 추출된 개념 missing과 추출된 개념 USD5를 포함하므로 둘 모두 매치합니다. 이는 다음과 동등합니다. (missing & USD5)
missing & <Currency>	레코드 A와 B 둘 모두 추출된 개념 missing과 <Currency> 유형과 매치하는 개념을 포함하므로 둘 모두 매치합니다. 이는 다음과 동등합니다. (missing & <Currency>)
<Currency> & missing	레코드 A와 B 둘 모두 추출된 개념 missing과 <Currency> 유형과 매치하는 개념을 포함하므로 둘 모두 매치합니다. 이는 다음과 동등합니다. (<Currency> & missing)
[USD5 + missing]	레코드 B는 USD5 + missing을 포함하는 TLA 패턴 출력을 생성하지 않으므로 A와는 매치하지만 B와는 매치하지 <b>않습니다</b> (이전 테이블 참조). 이는 TLA 패턴 출력과 동등합니다. USD5 + missing
[missing + USD5]	추출된 TLA 패턴이 여기에 첫 번째 위치에 missing으로 표현된 순서와 매치하지 않으므로(이전 테이블 참조) 레코드 A나 B와 매치하지 않습니다. 이는 TLA 패턴 출력과 동등합니다. USD5 + missing
[missing & USD5]	이러한 TLA 패턴이 레코드 B로부터 추출되지 않았으므로 A와는 매치하지만 B와는 매치하지 <b>않습니다</b> . & 문자를 사용하면 매치할 때 순서가 중요하지 않음을 나타냅니다. 그러므로 이 규칙은 [missing + USD5] 또는 [USD5 + missing]에 대한 패턴 매치를 찾습니다. 레코드 A의 [USD5 + missing]만이 매치합니다.
[missing + <Currency>]	추출된 TLA 패턴이 이 순서와 매치하지 않았으므로 레코드 A나 B와 매치하지 않습니다. TLA 출력은 용어 (USD5 + missing) 또는 유형 (<Currency> + <Negative>)만을 기반으로 하지만 개념과 유형을 혼합하지 않으므로 동등한 것이 없습니다.

규칙 구문	결과
[<Currency> + <Negative>]	TLA 패턴이 레코드 B에서 추출되지 않았으므로 레코드 A와는 매치하지만 B와는 매치하지 않습니다. 이는 TLA 출력과 동등합니다. <Currency> + <Negative>
[<Negative> + <Currency>]	추출된 TLA 패턴이 이 순서와 매치하지 않았으므로 레코드 A나 B와 매치하지 않습니다. Opinions 템플릿에서 기본적으로 주제가 의견을 사용하여 발견되면 주제(<Currency>)는 첫 번째 슬롯 위치를 차지하고 의견(<Negative>)은 두 번째 슬롯 위치를 차지합니다.

### (5) 범주 규칙 작성

규칙을 작성하거나 편집할 때 규칙이 규칙 편집기에서 열려 있어야 합니다. 개념, 유형 또는 패턴을 추가하거나 와일드카드를 사용하여 매치를 확장할 수 있습니다. 인식된 개념, 유형 및 패턴을 사용하면 이는 관련된 모든 개념을 찾으므로 장점이 있습니다. 예를 들어, 개념을 사용하면 연관된 모든 용어, 복수 형식 및 동의어는 또한 규칙과 매치합니다. 마찬가지로, 유형을 사용하면 모든 해당 개념 또한 규칙에 의해 캡처됩니다.

기존 규칙을 편집하거나 범주 이름을 마우스 오른쪽 단추로 클릭하고 **규칙 작성**을 선택하여 규칙 편집기를 열 수 있습니다.

컨텍스트 메뉴, 끌어다 놓기를 사용하거나 개념, 유형 및 패턴을 편집기에 수동으로 입력할 수 있습니다. 그런 다음 이들을 부울 연산자(&, !(), |) 및 대괄호와 결합하여 규칙 표현식을 작성하십시오. 일반적인 오류를 피하려면 개념을 추출 결과 분할창 또는 데이터 분할창에서 직접 규칙 편집기로 끌어다 놓는 것이 좋습니다. 오류를 피하려면 규칙의 구문에 세심한 주의를 기울이십시오. 자세한 정보는 범주 규칙 구문의 내용을 참조하십시오.

**참고:** 규칙이 텍스트와 매치하는 방법에 대한 예제는 범주 규칙 예제의 내용을 참조하십시오.

#### 규칙 작성

1. 아직 데이터를 추출하지 않았거나 추출이 오래된 경우에는 지금 수행하십시오. 자세한 정보는 데이터 추출의 내용을 참조하십시오.  
**참고:** 더 이상 표시되는 개념이 없는 방식으로 추출을 필터링하는 경우에는 범주 규칙을 작성하거나 편집하려고 시도할 때 오류 메시지가 표시됩니다. 이를 방지하려면 개념을 사용 가능하도록 추출 필터를 수정하십시오.
2. 범주 분할창에서 규칙을 추가하려는 범주를 선택하십시오.
3. 메뉴에서 **범주 > 규칙 작성**을 선택하십시오. 범주 규칙 편집기 분할창이 창에서 열립니다.
4. 규칙 이름 필드에 규칙의 이름을 입력하십시오. 이름을 제공하지 않으면 표현식이 자동으로 이름으로 사용됩니다. 나중에 이 규칙의 이름을 변경할 수 있습니다.

5. 더 큰 표현식 텍스트 필드에서 다음을 수행할 수 있습니다.
  - 필드에 텍스트를 직접 입력하거나 다른 분할창에서 끌어다 놓으십시오. 추출된 개념, 유형 및 패턴만을 사용하십시오. 예를 들어, 단어 cats를 입력했는데 단수형 cat만이 추출 결과 분할창에 나타나는 경우에는 편집기는 cats를 인식할 수 없습니다. 이 마지막 케이스에서 단수형은 자동으로 복수형을 포함할 수도 있지만 그렇지 않은 경우에는 와일드카드를 사용할 수 있습니다. 자세한 정보는 범주 규칙 구문의 내용을 참조하십시오.
  - 규칙에 추가하려는 개념, 유형 또는 패턴을 선택하고 메뉴를 사용하십시오.
  - 규칙의 요소를 서로 링크하려면 부울 연산자를 추가하십시오. 도구 모음 단추를 사용하여 "and" 부울 &, "or" 부울 |, "not" 부울 !(), 괄호 () 및 패턴의 대괄호 [ ]를 규칙에 추가하십시오.
6. **규칙 테스트** 단추를 클릭하여 규칙이 잘 형성되었는지 확인하십시오. 자세한 정보는 범주 규칙 구문의 내용을 참조하십시오. 발견된 문서 또는 레코드 수가 텍스트 **테스트 결과** 옆의 괄호에 나타납니다. 이 텍스트 오른쪽에는 규칙에서 인식되었던 요소 또는 오류 메시지를 볼 수 있습니다. 유형, 패턴 또는 개념 옆의 그래픽이 빨간색 물음표와 함께 나타나는 경우에는 이는 요소가 알려진 추출과 매치하지 않음을 나타냅니다. 매치하지 않으면 규칙은 레코드를 발견하지 않습니다.
7. 규칙의 일부를 테스트하려면 해당 파트를 선택하고 **테스트 선택**을 클릭하십시오.
8. 문제점을 발견한 경우 필요한 변경사항을 수행하고 규칙을 다시 테스트하십시오.
9. 완료되면 **저장 & 닫기**를 클릭하여 규칙을 다시 저장하고 편집기를 닫으십시오. 새 규칙 이름이 범주에 나타납니다.

## (6) 규칙 편집 및 삭제

규칙을 작성하고 저장한 후에는 언제든지 그 규칙을 편집할 수 있습니다. 자세한 정보는 범주 규칙 구문의 내용을 참조하십시오.

규칙을 더 이상 원하지 않으면 이를 삭제할 수 있습니다.

### 규칙 편집하기

1. 범주 정의 대화 상자의 디스크립터 테이블에서 규칙을 선택하십시오.
2. 메뉴에서 **범주 > 규칙 편집**을 선택하거나 규칙 이름을 두 번 클릭하십시오. 편집기가 선택된 규칙이 열린 상태로 열립니다.
3. 추출 결과와 도구 모음 단추를 사용하여 규칙을 변경하십시오.
4. 예측한 결과를 리턴하게 하려면 규칙을 다시 테스트하십시오.
5. **저장 & 닫기**를 클릭하여 규칙을 다시 저장하고 편집기를 닫으십시오.

### 규칙 삭제하기

1. 범주 정의 대화 상자의 디스크립터 테이블에서 규칙을 선택하십시오.
2. 메뉴에서 **편집 > 삭제**를 선택하십시오. 규칙이 범주에서 삭제됩니다.

## 9) 사전 정의된 범주 가져오기 및 내보내기

Microsoft Excel(\*.xls, \*.xlsx) 파일에 사용자 고유의 범주가 저장된 경우에는 이를 IBM® SPSS® Modeler Text Analytics 로 가져올 수 있습니다. 자세한 정보는 사전 정의된 범주 가져오기 주제를 참조하십시오.

열려 있는 대화식 워크벤치 세션 에 있는 범주를 Microsoft Excel(\*.xls, \*.xlsx) 파일로 내보낼 수도 있습니다. 범주를 내보낼 때 디스크립터 및 스코어 등과 같은 몇몇 추가 정보를 포함하거나 제외할지를 선택할 수 있습니다. 자세한 정보는 범주 내보내기의 내용을 참조하십시오.

사전 정의된 범주에 코드가 없거나 새 코드를 원하는 경우에는 메뉴에서 **범주 > 범주 관리 > 코드 자동 생성**을 선택하여 범주 분할창에서 범주 세트에 대한 새 코드 세트를 자동으로 생성할 수 있습니다. 그러면 기존 코드가 제거되고 모두 자동으로 다시 번호가 지정됩니다.

### (1) 사전 정의된 범주 가져오기

사전 정의된 범주를 IBM® SPSS® Modeler Text Analytics 로 가져올 수 있습니다. 가져오기 전에 사전 정의된 범주 파일이 Microsoft Excel(\*.xls, \*.xlsx) 파일에 있고 지원 형식 중 하나로 구조화되었는지를 확인하십시오. 제품이 자동으로 형식을 발견하도록 선택할 수도 있습니다. 다음 형식이 지원됩니다.

- **평면 목록 형식:** 자세한 정보는 평면 목록 형식 주제를 참조하십시오.
- **최소 형식:** 자세한 정보는 최소 형식 주제를 참조하십시오.
- **들여쓰기 형식:** 자세한 정보는 들여쓰기 형식 주제를 참조하십시오.

사전에 정의된 범주 가져오기

1. 대화식 워크벤치 메뉴에서 **범주 > 범주 관리 > 사전 정의된 범주 가져오기**를 선택하십시오. 사전 정의된 범주 가져오기 마법사가 표시됩니다.
2. 찾아보기 드롭 다운 목록에서 파일이 있는 드라이브와 폴더를 선택하십시오.
3. 목록에서 파일을 선택하십시오. 파일 이름이 파일 이름 텍스트 상자에 나타납니다.
4. 목록에서 사전 정의된 범주를 포함하는 워크시트를 선택하십시오. 워크시트 이름이 워크시트 필드에 나타납니다.
5. 데이터 형식 선택을 시작하려면 **다음**을 클릭하십시오.
6. 파일의 형식을 선택하거나 제품이 자동으로 형식을 발견하게 하는 옵션을 선택하십시오. 자동 발견은 대부분의 공통 형식에서 잘 작동합니다.
  - **평면 목록 형식:** 자세한 정보는 평면 목록 형식 주제를 참조하십시오.
  - **최소 형식:** 자세한 정보는 최소 형식 주제를 참조하십시오.
  - **들여쓰기 형식:** 자세한 정보는 들여쓰기 형식 주제를 참조하십시오.

7. 추가로 가져오기 옵션을 정의하려면 다음을 클릭하십시오. 형식을 자동으로 발견하도록 선택하면 최종 단계로 이동됩니다.
8. 하나 이상의 행에 열 헤더 또는 다른 관련 없는 정보가 포함된 경우에는 **행에서 가져오기 시작** 옵션에서 가져오기를 시작할 행 번호를 선택하십시오. 예를 들어, 범주 이름이 7행에서 시작하는 경우에는 파일을 올바르게 가져오려면 이 옵션에 숫자 7을 입력해야 합니다.
9. 파일에 범주 코드가 포함된 경우에는 **범주 코드 포함** 옵션을 선택하십시오. 이를 수행하면 마법사가 데이터를 제대로 인식하는 데 도움이 됩니다.
10. 색상 코딩된 셀과 범례를 검토하여 데이터가 올바르게 식별되었는지 확인하십시오. 파일에서 발견된 오류는 빨간색으로 표시되고 형식 미리보기 테이블 아래에 표시됩니다. 잘못된 형식이 선택된 경우에는 뒤로 돌아가서 또 다른 형식을 선택하십시오. 파일을 수정해야 하는 경우에는 변경을 수행하고 파일을 다시 선택하여 마법사를 다시 시작하십시오. 마법사를 마치기 전에 모든 오류를 수정해야 합니다.
11. 가져올 범주 및 하위 범주 세트를 검토하고 이러한 범주에 대한 디스크립터를 작성하는 방법을 정의하려면 다음을 클릭하십시오.
12. 테이블에서 가져올 범주 세트를 검토하십시오. 디스크립터로 표시될 것으로 예상한 키워드가 보이지 않으면 가져오기 중에 인식되지 않은 것일 수도 있습니다. 이러한 키워드에 접두 문자가 제대로 추가되었는지와 올바른 셀에 나타나는지를 확인하십시오.
13. 세션에서 사전에 존재하는 범주를 처리하는 방법을 선택하십시오.
  - **기존 범주를 모두 대체.** 이 옵션은 기존 범주를 모두 제거한 다음 그 자리에 새로 가져온 범주가 단독으로 사용됩니다.
  - **기존 범주에 추가.** 이 옵션은 범주를 가져오고 공통된 범주를 기존 범주와 병합합니다. 기존 범주에 추가할 때에는 중복이 처리되는 방법을 결정해야 합니다. 한 가지 선택사항(옵션: **병합**)은 가져오는 범주를 기존 범주와 병합하는 것입니다(범주 이름을 공유하는 경우). 또 다른 선택사항(옵션: **가져오기에서 제외**)은 같은 이름의 범주가 존재하는 경우 범주 가져오기를 금지하는 것입니다.
14. **키워드를 디스크립터로서 가져오기**는 데이터에서 식별된 키워드를 연관된 범주의 디스크립터로서 가져오는 것입니다.
15. **디스크립터를 파생하여 범주 확장**은 범주 이름 또는 하위 범주를 나타내는 단어 및/또는 주석(Annotation)을 구성하는 단어에서 디스크립터를 생성하는 옵션입니다. 단어가 추출된 결과와 매치하면 이들은 디스크립터로서 범주에 추가됩니다. 이 옵션은 범주 이름 또는 주석(Annotation)이 둘 모두 길고 설명적인 경우에 최상의 결과를 생성합니다. 이는 범주가 이러한 디스크립터를 포함하는 레코드를 캡처할 수 있도록 범주 디스크립터를 생성하기 위한 빠른 방법입니다.
  - **시작 필드**를 사용하면 디스크립터가 어떤 텍스트에서 파생될지, 이름 또는 범주 및 하위 범주인지 주석(Annotation)에 있는 단어인지 또는 둘 모두인지를 선택할 수 있습니다.
  - **양식 필드**를 사용하면 이러한 디스크립터를 개념 또는 TLA 패턴의 양식으로 작성할지를 선택할 수 있습니다. TLA 추출이 발생하지 않으면 이 마법사에서 **패턴** 옵션은 사용 안 함으로 설정됩니다.
16. 사전 정의된 범주를 범주 분할창으로 가져오려면 **마침**을 클릭하십시오.

### ① 평면 목록 형식

평면 목록 형식에는 계층 구조가 없는 단 하나의 최상의 수준 범주만이 있습니다. 즉 하위 범주나 서브넷이 없습니다. 범주 이름은 단일 열에 있습니다.

다음 정보가 이 형식의 파일에 포함될 수 있습니다.

- 선택적 코드 열에는 각 범주를 고유하게 식별하는 숫자 값이 포함됩니다. 데이터 파일에 코드가 포함되는 경우에는(컨텐츠 설정 단계에서 범주 코드 포함 옵션), 각 범주의 고유한 코드가 범주 이름의 바로 왼쪽에 있는 셀에 존재해야 합니다. 데이터에 코드가 포함되지 않지만 나중에 몇몇 코드를 작성하려는 경우에는 나중에 언제든지 코드를 생성할 수 있습니다(범주 > 범주 관리 > 코드 자동 생성).
- 필수 범주 이름 열에는 범주의 모든 이름이 포함됩니다. 이 열은 이 형식을 사용하여 가져오는 데 필요합니다.
- 범주 이름의 바로 오른쪽에 있는 셀에 있는 선택적 주석(Annotation). 이 주석(Annotation)은 범주/하위 범주를 설명하는 텍스트로 구성됩니다.
- 선택적 키워드는 범주의 디스크립터로서 가져올 수 있습니다. 이러한 키워드가 인식되기 위해서는 연관된 범주/하위 범주의 바로 아래에 있는 셀에 있어야 하며 키워드 목록에는 밑줄(\_) 문자가 접두문자로 추가되어야 합니다(예: \_firearms, weapons / guns). 키워드 셀에는 각 범주를 설명하는 데 사용되는 하나 이상의 단어가 포함될 수 있습니다. 이러한 단어는 디스크립터로서 가져오거나 마법사의 마지막 단계에 지정하는 내용에 따라 무시됩니다. 나중에, 디스크립터는 텍스트에서 추출된 결과와 비교됩니다. 매치가 발견되면 해당 레코드나 문서는 이 디스크립터를 포함하는 범주에 기록됩니다.

표 1. 코드, 키워드 및 주석(Annotation)이 있는 평면 목록 형식

열 A	열 B	열 C
범주 코드(선택적)	범주 이름	주석(Annotation)
	_Descriptor/keyword 목록(선택적)	

### ② 최소 형식

최소 형식은 계층적인 범주와 함께 사용된다는 점을 제외하고는 평면 목록 형식과 유사하게 구조화되어 있습니다. 그러므로 각 범주와 하위 범주의 계층적 수준을 정의하려면 코드 수준 열이 필요합니다.

다음 정보가 이 형식의 파일에 포함될 수 있습니다.

- 필수 코드 수준 열에는 해당 행에서 후속 정보의 계층적 위치를 나타내는 번호가 포함됩니다. 예를 들어, 값 1, 2 또는 3이 지정되고 범주와 하위 범주 둘 모두가 있는 경우에는, 1은 범주

용이고, 2는 하위 범주용이고, 3은 하위 하위 범주용입니다. 범주와 하위 범주만이 있는 경우에는 1은 범주용이고, 2는 하위 범주용입니다. 원하는 범주 깊이까지 이런 방식입니다.

- 선택적 코드 열에는 각 범주를 고유하게 식별하는 값을 포함합니다. 데이터 파일에 코드가 포함되는 경우에는(컨텐츠 설정 단계에서 범주 코드 포함 옵션), 각 범주의 고유한 코드가 범주 이름의 바로 왼쪽에 있는 셀에 존재해야 합니다. 데이터에 코드가 포함되지 않지만 나중에 몇몇 코드를 작성하려는 경우에는 나중에 언제든지 코드를 생성할 수 있습니다(범주 > 범주 관리 > 코드 자동 생성).
- 필수 범주 이름 열에는 범주와 하위 범주의 모든 이름이 포함됩니다. 이 열은 이 형식을 사용하여 가져오는 데 필요합니다.
- 범주 이름의 바로 오른쪽에 있는 셀에 있는 선택적 주석(Annotation). 이 주석(Annotation)은 범주/하위 범주를 설명하는 텍스트로 구성됩니다.
- 선택적 키워드는 범주의 디스크립터로서 가져올 수 있습니다. 이러한 키워드가 인식되기 위해서는 연관된 범주/하위 범주의 바로 아래에 있는 셀에 있어야 하며 키워드 목록에는 밑줄(\_) 문자가 접두문자로 추가되어야 합니다(예: \_firearms, weapons / guns). 키워드 셀에는 각 범주를 설명하는 데 사용되는 하나 이상의 단어가 포함될 수 있습니다. 이러한 단어는 디스크립터로서 가져오거나 마법사의 마지막 단계에 지정하는 내용에 따라 무시됩니다. 나중에, 디스크립터는 텍스트에서 추출된 결과와 비교됩니다. 매치가 발견되면 해당 레코드나 문서는 이 디스크립터를 포함하는 범주에 기록됩니다.

표 1. 코드를 포함하는 소형 형식 예제

열 A	열 B	열 C
계층적 코드 수준	범주 코드(선택적)	범주 이름
계층적 코드 수준	하위 범주 코드(선택적)	하위 범주 이름

표 2. 코드가 없는 소형 형식 예제

열 A	열 B
계층적 코드 수준	범주 이름
계층적 코드 수준	하위 범주 이름

### ③ 들여쓰기 형식

들여쓰기 파일 형식에서는 컨텐츠는 계층적이며 이는 범주와 하나 이상의 하위 범주 수준이 포함됨을 의미합니다. 또한 구조는 이 계층 구조를 표시하기 위해 들여쓰기되어 있습니다. 파일의 각 행에는 범주 또는 하위 범주가 포함되어 있지만 하위 범주는 범주로부터 들여쓰기되어 있고 모든 하위 하위 범주는 하위 범주로부터 들여쓰기되어 있습니다. 이 구조를 Microsoft Excel에서 수동으로 작성하거나 또 다른 제품에서 내보내었고 Microsoft Excel 형식으로 저장된 구조를 사용할 수 있습니다.

- 상위 수준 범주 코드 및 범주 이름은 각각 열 A와 B를 차지합니다. 또는 코드가 없는 경우에는 범주 이름은 열 A에 있습니다.
- 하위 범주 코드 및 하위 범주 이름은 각각 열 B와 C를 차지합니다. 또는 코드가 없는 경우에는 하위 범주 이름이 열 B에 있습니다. 하위 범주는 범주의 일부입니다. 최상위 수준 범주가 없는 경우에는 하위 범주를 가질 수 없습니다.

표 1. 코드를 포함하는 들여쓰기 구조

열 A	열 B	열 C	열 D
범주 코드(선택적)	범주 이름		
	하위 범주 코드(선택적)	하위 범주 이름	
		하위 하위 범주 코드(선택적)	하위 하위 범주 이름

표 2. 코드를 포함하지 않는 들여쓰기 구조

열 A	열 B	열 C
범주 이름		
	하위 범주 이름	
		하위 하위 범주 이름

다음 정보가 이 형식의 파일에 포함될 수 있습니다.

- 선택적 코드는 각 범주 또는 하위 범주를 고유하게 식별하는 값이어야 합니다. 데이터 파일에 코드가 포함됨을 지정한 경우에는(컨텐츠 설정 단계에서 범주 코드 포함 옵션), 각 범주 또는 하위 범주의 고유한 코드가 범주/하위 범주 이름의 바로 왼쪽에 있는 셀에 존재해야 합니다. 데이터에 코드가 포함되지 않지만 나중에 몇몇 코드를 작성하려는 경우에는 나중에 언제든지 코드를 생성할 수 있습니다(범주 > 범주 관리 > 코드 자동 생성).
- 각 범주 및 하위 범주의 필수 이름입니다. 하위 범주는 개별 행에서 범주로부터 오른쪽으로 한 셀씩 들여써야 합니다.
- 범주 이름의 바로 오른쪽에 있는 셀에 있는 선택적 주석(Annotation). 이 주석(Annotation)은 범주/하위 범주를 설명하는 텍스트로 구성됩니다.
- 선택적 키워드는 범주의 디스크립터로서 가져올 수 있습니다. 이러한 키워드가 인식되기 위해서는 연관된 범주/하위 범주의 바로 아래에 있는 셀에 있어야 하며 키워드 목록에는 밑줄(\_) 문자가 접두문자로 추가되어야 합니다(예: \_firearms, weapons / guns). 키워드 셀에는 각 범주를 설명하는 데 사용되는 하나 이상의 단어가 포함될 수 있습니다. 이러한 단어는 디스크립터로서 가져오거나 마법사의 마지막 단계에 지정하는 내용에 따라 무시됩니다. 나중에, 디스크립터는 텍스트에서 추출된 결과와 비교됩니다. 매치가 발견되면 해당 레코드나 문서는 이 디스크립터를 포함하는 범주에 기록됩니다.

**중요!** 코드를 한 수준에서 사용하는 경우에는 각 범주와 하위 범주의 코드를 포함해야 합니다. 그렇지 않으면 가져오기 프로세스가 실패합니다.

## (2) 범주 내보내기

열려 있는 대화식 워크벤치 세션 에 있는 범주를 Microsoft Excel(\*.xls, \*.xlsx) 파일 형식으로 내보낼 수도 있습니다. 내보낼 데이터는 대부분 범주 분할창의 현재 내용 또는 범주 특성에서 나옵니다. 그러므로 Docs. 스코어 값 또한 내보낼 계획이면 다시 스코어링하는 것이 좋습니다.

표 1. 범주 내보내기 옵션

항상 내보냄...	선택적으로 내보냄...
- 범주 코드(있는 경우)	- Docs. 스코어
- 범주(및 하위 범주) 이름	- 범주 주석(Annotation)
- 코드 수준(있는 경우)( <i>평균/최소</i> 형식)	- 디스크립터 이름
- 열 머리말( <i>평균/최소</i> 형식)	- 디스크립터 수

**중요!** 디스크립터를 내보낼 때 이들은 텍스트 문자열로 변환되고 밑줄이 접두문자로 추가됩니다. 이 제품으로 다시 가져오면 패턴인 디스크립터와 범주 규칙인 디스크립터 및 일반 개념인 디스크립터를 구분하는 기능이 유실됩니다. 이러한 범주를 이 제품에서 다시 사용하려면, 대신 텍스트 분석 패키지(TAP) 파일을 작성할 것을 권장합니다. TAP 형식은 모든 디스크립터뿐만 아니라 모든 범주, 코드 및 사용된 언어학적 자원까지 모두 현재 정의된 대로 보존하기 때문입니다. TAP 파일은 IBM® SPSS® Modeler Text Analytics 및 IBM SPSS Text Analytics for Surveys 둘 모두에서 사용할 수 있습니다. 자세한 정보는 텍스트 분석 패키지 사용의 내용을 참조하십시오.

사전에 정의된 범주 내보내기

1. 대화식 워크벤치 메뉴에서 **범주 > 범주 관리 > 범주 내보내기**를 선택하십시오. 범주 내보내기 마법사가 표시됩니다.
2. 위치를 선택하고 내보낼 파일의 이름을 입력하십시오.
3. 파일 이름 텍스트 상자에 출력 파일의 이름을 입력하십시오.
4. 범주 데이터를 내보낼 형식을 선택하려면 **다음**을 클릭하십시오.
5. 다음에서 형식을 선택하십시오.
  - **평균 또는 최소 목록 형식:** 자세한 정보는 평균 목록 형식 주제를 참조하십시오. 평균 목록에는 하위 범주가 없습니다. 자세한 정보는 최소 형식의 내용을 참조하십시오. 최소 목록 형식에는 계층적 범주가 포함됩니다.
  - **들여쓰기 형식:** 자세한 정보는 들여쓰기 형식 주제를 참조하십시오.

6. 내보낼 내용을 선택하기 시작하고 제안된 데이터를 검토하려면 다음을 클릭하십시오.
7. 내보낸 파일의 내용을 검토하십시오.
8. 주석(Annotation) 또는 디스크립터 이름 등과 같이 내보낼 추가적인 내용 설정을 선택하거나 선택 취소하십시오.
9. 범주를 내보내려면 마침을 클릭하십시오.

## 10) 텍스트 분석 패키지 사용

TAP라고도 불리는 텍스트 분석 패키지는 텍스트 반응 범주화를 위한 템플릿의 역할을 합니다. TAP를 사용하는 것은 최소한의 개입만으로 텍스트 데이터를 범주화하는 쉬운 방법입니다. 여기에는 방대한 수의 레코드를 빠르게 자동으로 코딩하는 데 필요한 사전에 작성된 범주 세트 및 언어학적 자원이 포함되어 있기 때문입니다. 언어학적 자원을 사용하여 텍스트 데이터는 주요 개념을 추출하기 위해 분석되고 마이닝됩니다. 텍스트에서 발견된 주요 개념과 패턴을 기반으로 레코드는 사용자가 TAP에서 선택한 범주 세트로 범주화될 수 있습니다. 사용자만의 TAP를 작성하거나 이를 업데이트할 수 있습니다.

TAP는 다음 요소로 구성됩니다.

- **범주 세트.** 범주 세트는 본질적으로 사전 정의된 범주, 범주 코드, 각 범주의 디스크립터, 마지막으로 전체 범주 세트의 이름으로 구성됩니다. 디스크립터는 용어 *저렴한* 또는 패턴 *좋은 가격* 등과 같은 언어학적 요소(개념, 유형, 패턴 및 규칙)입니다. 디스크립터는 텍스트가 범주 디스크립터와 매치하고, 문서 또는 레코드가 범주에 들어갈 수 있도록 범주를 정의하는 데 사용됩니다.
- **언어학적 자원.** 언어학적 자원은 주요 개념과 패턴을 추출하기 위해 조정된 라이브러리와 고급 자원의 세트입니다. 이러한 추출 개념 및 패턴은 그런 다음 레코드를 범주 세트의 범주에 배치할 수 있게 해주는 디스크립터로서 사용됩니다.

다음 태스크는 텍스트 분석 패키지에서만 가능합니다.

- 텍스트 분석 패키지를 작성하십시오. 자세한 정보는 텍스트 분석 패키지 작성의 내용을 참조하십시오.
- 텍스트 분석 패키지를 로드하십시오. 또는 텍스트 분석 패키지로 변환될 SPSS® Text Analytics for Surveys 프로젝트(.tas)를 로드할 수 있습니다. 자세한 정보는 텍스트 분석 패키지 로드의 내용을 참조하십시오.
- 텍스트 분석 패키지를 업데이트하십시오. 자세한 정보는 텍스트 분석 패키지 업데이트의 내용을 참조하십시오.

TAP를 선택하고 범주 세트를 선택한 후에는 SPSS Modeler Text Analytics 는 사용자의 레코드를 추출하고 범주화할 수 있습니다.

**참고:** TAP는 SPSS Text Analytics for Surveys 및 SPSS Modeler Text Analytics 사이에 상호 교환적으로 작성 및 사용될 수 있습니다. 단, 텍스트 분석 패키지(TAP)를 SPSS Modeler Text Analytics에서 직접 로드했는지 또는 TAP를 IBM® SPSS Text Analytics for Surveys에서 로드했는지에 따라 SPSS Modeler Text Analytics에서 스코어링 규칙이 다를 수 있습니다. SPSS Modeler Text Analytics에서 작성된 TAP를 사용하도록 권장합니다. IBM SPSS Text Analytics for Surveys에서 작성된 TAP가 다른 버전의 언어 자원을 사용하여 작성되었을 수 있기 때문입니다.

## (1) 텍스트 분석 패키지 작성

하나 이상의 범주와 몇몇 자원이 있는 세션이 있을 때마다 열려 있는 대화식 워크벤치 세션의 콘텐츠에서 텍스트 분석 패키지(TAP)를 작성할 수 있습니다. 범주 및 디스크립터(개념, 유형, 규칙 또는 TLA 패턴 출력) 세트는 자원 편집기에 열려 있는 모든 언어학적 자원과 함께 TAP에 작성할 수 있습니다.

자원 작성 시 사용된 언어를 볼 수 있습니다. 언어는 템플릿 편집기 또는 자원 편집기의 고급 자원 탭에 설정됩니다.

텍스트 분석 패키지 작성

1. 메뉴에서 **파일 > 텍스트 분석 패키지 > 패키지 작성**을 선택하십시오. 패키지 작성 대화 상자가 나타납니다.
2. TAP을 저장할 디렉토리로 이동하십시오. 기본적으로 TAP은 제품 설치 디렉토리의 WTAP 하위 디렉토리에 저장됩니다.
3. **파일 이름** 필드에 TAP의 이름을 입력하십시오.
4. **패키지 레이블** 필드에 레이블을 입력하십시오. 파일 이름을 입력하면 이 이름은 레이블로 자동으로 나타나지만 이 레이블은 변경할 수 있습니다.
5. TAP에서 범주 세트를 제외하려면 **포함** 선택란을 선택 취소하십시오. 그러면 이는 패키지에 추가되지 않게 됩니다. 기본적으로 질문당 하나의 범주 세트가 TAP에 포함됩니다. TAP에는 항상 하나 이상의 범주 세트가 있어야 합니다.
6. 범주 세트의 이름을 변경하십시오. **새 범주 세트** 열에는 기본적으로 일반 이름이 포함됩니다. 이는 텍스트 변수 이름에 Cat\_ 접두문자를 추가하여 생성됩니다. 셀을 한 번 클릭하면 이름이 편집 가능하게 됩니다. Enter를 누르거나 다른 곳을 클릭하면 이름 변경이 적용됩니다. 범주 세트의 이름을 변경하는 경우에는 이름은 TAP에서만 변경되고 열려 있는 세션에서 변수 이름을 변경하지 않습니다.
7. 원하는 경우 범주 세트 테이블 오른쪽의 화살표 키를 사용하여 범주 세트를 다시 정렬하십시오.
8. 텍스트 분석 패키지를 작성하려면 **저장**을 클릭하십시오. 대화 상자가 닫힙니다.

## (2) 텍스트 분석 패키지 로드

텍스트 마이닝 모델링 노드를 구성할 때 추출 중에 사용될 자원을 지정해야 합니다. 자원뿐만 아니라 범주 세트를 노드로 복사하기 위해 자원 템플릿을 선택하는 대신 텍스트 분석 패키지 (TAP) 또는 SPSS® Text Analytics for Surveys 프로젝트(.tas)를 선택할 수 있습니다. .tas 파일을 선택할 경우 이 파일은 TAP로 변환됩니다.

TAP는 범주 모델을 대화식으로 작성할 때 가장 적절합니다. 범주 세트를 범주화의 시작점으로 사용할 수 있기 때문입니다. 스트림을 실행하면 대화식 워크벤치 세션이 실행되고 이 범주 세트가 범주 분할창에 나타납니다. 이 방법으로 즉시 이러한 범주를 사용하여 문서와 레코드를 기록한 다음 사용자의 요구를 충족시킬 때까지 이러한 범주를 계속해서 세분화, 작성 및 확장하십시오. 자세한 정보는 범주 작성을 위한 방법 및 전략의 내용을 참조하십시오.

버전 14부터 **로드**를 클릭하고 TAP를 선택하면 TAP의 자원이 정의된 언어를 볼 수도 있습니다.

## TAP 또는 TAS 로드

1. 텍스트 마이닝 모델링 노드를 편집하십시오.
2. 모델 탭의 **자원 복사 시작** 섹션에서 텍스트 분석 패키지를 선택하십시오.
3. **로드**를 클릭하십시오. 텍스트 분석 패키지 로드 대화 상자가 열립니다.
4. 노드로 복사하려는 자원과 범주 세트가 포함되어 있는 TAP 또는 SPSS Text Analytics for Surveys 프로젝트(.tas)의 위치로 이동하십시오. 기본적으로 제품 설치 디렉토리의 \WTAP 서브디렉토리에 저장됩니다.
5. **파일 이름** 필드에 TAP의 이름을 입력하십시오. 레이블이 자동으로 표시됩니다.
6. 사용하려는 범주 세트를 선택하십시오. 이는 대화식 워크벤치 세션에 나타나는 범주 세트입니다. 그런 다음 이러한 범주를 수동으로나 범주 작성 또는 확장 옵션을 사용하여 수정하고 향상시킬 수 있습니다.
7. **로드**를 클릭하여 텍스트 분석 패키지 또는 SPSS Text Analytics for Surveys 프로젝트의 콘텐츠를 노드로 복사하십시오. 대화 상자가 닫힙니다. 콘텐츠를 로드하면 해당 콘텐츠가 노드로 복사되므로, 외부 자원과 범주가 변경된 경우 변경사항을 명시적으로 업데이트하고 다시 로드하기 전까지는 적용되지 않습니다.

## (3) 텍스트 분석 패키지 업데이트

범주 세트, 언어학적 자원을 개선하거나 전체 새 범주 세트를 작성하는 경우에는 텍스트 분석 패키지(TAP)를 업데이트하여 이러한 개선사항을 나중에 쉽게 다시 사용할 수 있습니다. 이를 수행하려면 TAP에 넣으려는 정보를 포함하는 열려 있는 세션에 있어야 합니다. 업데이트할 때 범주 세트를 추가하고, 자원을 재배치하고, 패키지 레이블을 변경하거나 범주 세트의 이름을 변경하거나 순서를 다시 정렬하기를 선택할 수 있습니다.

## 텍스트 분석 패키지 업데이트

1. 메뉴에서 **파일 > 텍스트 분석 패키지 > 패키지 업데이트**를 선택하십시오. 패키지 업데이트 대화 상자가 나타납니다.
2. 업데이트하려는 텍스트 분석 패키지를 포함하는 디렉토리로 이동하십시오.
3. **파일 이름** 필드에 TAP의 이름을 입력하십시오.
4. TAP 내부에 있는 언어학적 자원을 현재 세션에 있는 자원으로 대체하려면 **이 패키지의 자원을 열어 있는 세션의 자원으로 대체** 옵션을 선택하십시오. 이는 범주 정의를 작성하는 데 사용된 주요 개념과 패턴을 추출하는 데 사용되었으므로 일반적으로 언어학적 자원을 업데이트하는 것이 맞습니다. 가장 최신 언어학적 자원을 가지고 있으면 레코드를 범주화할 때 최상의 결과를 얻을 수 있습니다. 이 옵션을 선택하지 않으면 패키지에 이미 있는 언어학적 자원은 변경되지 않은 상태로 있습니다.
5. 언어학적 자원만을 업데이트하려면 **이 패키지의 자원을 열어 있는 세션의 자원으로 대체** 옵션을 선택하고 TAP에 이미 있는 현재 범주 세트만을 선택했는지 확인하십시오.
6. 열어 있는 세션에서 새 범주 세트를 TAP에 포함시키려면 추가할 각 범주 세트의 선택란을 선택하십시오. 범주 세트를 하나, 여러 개 추가하거나 하나도 추가하지 않을 수 있습니다.
7. TAP에서 범주 세트를 제거하려면 해당하는 **포함** 선택란을 선택 취소하십시오. 개선된 범주 세트를 추가 중이므로 TAP에 이미 있는 범주 세트를 제거하기로 선택할 수도 있습니다. 이를 수행하려면 현재 범주 세트 열에서 해당하는 범주 세트의 **포함** 선택란을 선택 취소하십시오. TAP에는 항상 하나 이상의 범주 세트가 있어야 합니다.
8. 필요한 경우 범주 세트의 이름을 변경하십시오. 셀을 한 번 클릭하면 이름이 편집 가능하게 됩니다. Enter를 누르거나 다른 곳을 클릭하면 이름 변경이 적용됩니다. 범주 세트의 이름을 변경하는 경우에는 이름은 TAP에서만 변경되고 열어 있는 세션에서 변수 이름을 변경하지 않습니다. 두 개의 범주 세트가 같은 이름을 가지고 있으면 이름은 중복을 수정할 때까지 빨간색으로 나타납니다.
9. 세션 콘텐츠가 선택된 TAP의 콘텐츠와 병합된 상태로 새 패키지를 작성하려면 **다른 이름으로 새로 저장**을 클릭하십시오. 텍스트 분석 패키지를 다른 이름으로 저장 대화 상자가 나타납니다. 다음 지시사항을 참조하십시오.
10. TAP에 선택한 변경사항을 저장하려면 **업데이트**를 클릭하십시오.

## 텍스트 분석 패키지 저장

1. TAP 파일을 저장할 디렉토리로 이동하십시오. 기본적으로 TAP은 설치 디렉토리의 WTAP 하위 디렉토리에 저장됩니다.
2. **파일 이름** 필드에 TAP 파일의 이름을 입력하십시오.
3. **패키지 레이블** 필드에 레이블을 입력하십시오. 파일 이름을 입력하면 이 이름은 자동으로 레이블로 사용됩니다. 그러나 이 레이블의 이름을 변경할 수 있습니다. 레이블이 있어야 합니다.
4. 새 패키지를 작성하려면 **저장**을 클릭하십시오.

## 11) 범주 편집 및 세분화

일부 범주를 작성한 후에는 이를 예외없이 검사한 다음에 조정하려고 할 수 있습니다. 언어학적 자원을 세분화하는 데 추가로 정의를 결합하거나 정리하는 방법을 찾고 일부 범주화된 문서 또는 레코드를 확인하여 범주를 검토해야 합니다. 범주에서 문서 또는 레코드를 검토하고 범주가 뉘앙스와 차이가 캡처되는 방식으로 정의될 수 있도록 조정할 수도 있습니다.

내장된 자동화된 범주 작성 기술을 사용하여 범주를 작성할 수 있습니다. 그러나 이러한 범주에 몇몇 조정 작업을 수행하려고 할 수도 있습니다. 하나 이상의 기술을 사용한 후에는 많은 새 범주가 창에 나타납니다. 그런 다음 범주에서 데이터를 검토하고 범주 정의에 만족할 때까지 조정할 수 있습니다. 자세한 정보는 범주 정보의 내용을 참조하십시오.

다음은 범주를 세분화하기 위한 몇몇 옵션입니다.

### (1) 디스크립터를 범주에 추가

자동화된 기술을 사용한 후에 범주 정의에 사용되지 않은 추출 결과가 여전히 남아 있을 수 있습니다. 확장 결과 분할창에서 이 목록을 검토해야 합니다. 범주로 이동하려는 요소를 찾으려면 이를 기존 범주 또는 신규 범주에 추가할 수 있습니다.

개념이나 유형을 범주에 추가

1. 추출 결과 및 데이터 분할창 내에서 신규 또는 기존 범주에 추가하려는 요소를 선택하십시오.
2. 메뉴에서 **범주 > 범주에 추가**를 선택하십시오. 모든 범주 대화 상자가 범주 세트를 표시합니다. 선택한 요소를 추가하려는 범주를 선택하십시오. 요소를 새 범주에 추가하려면 **새 범주**를 선택하십시오. 새 범주가 첫 번째 선택된 요소의 이름을 사용하여 범주 분할창에 나타납니다.

### (2) 범주 디스크립터 편집

몇몇 범주를 작성한 후에는 각 범주를 열어서 해당 정의를 구성하는 모든 디스크립터를 볼 수 있습니다. 범주 정의 대화 상자 내에서 범주 디스크립터를 여러 번 편집할 수 있습니다. 또한 범주가 범주 트리에 표시되면 여기에서 이에 대해 작업할 수도 있습니다.

범주 편집

1. 범주 분할창에서 편집할 범주를 선택하십시오.
2. 메뉴에서 **보기 > 범주 정의를** 선택하십시오. 범주 정의 대화 상자가 열립니다.
3. 편집하려는 디스크립터를 선택하고 해당하는 도구 모음 단추를 클릭하십시오.

다음 테이블은 범주 정의를 편집하기 위해 사용할 수 있는 각 도구 모음 단추를 설명합니다.

표 1. 도구 모음 단추 및 설명	
아이콘	설명
	범주에서 선택한 디스크립터를 삭제합니다.
	선택한 디스크립터를 신규 또는 기존 범주로 이동합니다.
	선택한 디스크립터를 & 범주 규칙의 양식으로 범주로 이동합니다. 자세한 정보는 범주 규칙 사용의 내용을 참조하십시오.
	선택한 각 디스크립터를 자체 신규 범주로 이동합니다.
 표시	데이터 분할창과 시각화 분할창에 표시된 내용을 선택한 디스크립터에 따라 업데이트합니다.

### (3) 범주 이동

범주를 또 다른 기존 범주에 놓거나 디스크립터를 또 다른 범주로 이동하려는 경우에는 이를 이동할 수 있습니다.

범주 이동

1. 범주 분할창에서 또 다른 범주로 이동하려는 범주 를 선택하십시오.
2. 메뉴에서 **범주 > 범주로 이동**을 선택하십시오. 메뉴는 범주 세트에 목록의 맨 위에 있는 가장 최근에 작성된 범주를 제공합니다. 선택한 개념을 이동하려는 범주 이름을 선택하십시오.
  - 찾고 있는 이름이 보이면, 이를 선택하면 선택된 요소가 해당 범주에 추가됩니다.
  - 보이지 않으면 기타를 선택하여 모든 범주 대화 상자를 표시하고 목록에서 범주를 선택하십시오.

### (4) 범주 평면화

범주와 하위 범주가 있는 계층적 범주 구조가 있는 경우 구조를 평면화할 수 있습니다. 범주를 평면화할 때 해당 범주의 하위 범주에 있는 모든 디스크립터가 선택한 범주로 이동되고 현재 비어 있는 하위 범주는 삭제됩니다. 이런 방식으로 하위 범주와 매치시키는 데 사용된 모든 문서는 이제 선택된 범주로 범주화됩니다.

범주 평면화

1. 범주 분할창에서 평면화하려는 범주(최상위 수준 또는 하위 범주)를 선택하십시오.
2. 메뉴에서 **범주 > 범주 평면화**를 선택하십시오. 하위 범주는 제거되고 디스크립터가 선택된 범주로 병합됩니다.

## (5) 범주 병합 또는 결합

둘 이상의 기존 범주를 새 범주로 결합하려는 경우에는 이를 병합하면 됩니다. 범주를 병합할 때에는 새 범주가 일반 이름으로 작성됩니다. 범주 디스크립터에 사용된 모든 개념, 유형 및 패턴은 이 새 범주로 이동됩니다. 나중에 범주 특성을 편집하여 이 범주의 이름을 변경할 수 있습니다.

범주 또는 범주의 일부 병합

1. 범주 분할창에서 병합하려는 요소를 선택하십시오.
2. 메뉴에서 **범주 > 범주 병합**을 선택하십시오. 새로 작성된 범주의 이름을 입력하는 범주 특성 대화 상자가 표시됩니다. 선택된 범주가 새 범주에 하위 범주로서 병합됩니다.

## (6) 범주에 문서 강제 적용/해제

문서를 범주에 강제 적용/해제하면 실제 범주 정의를 변경하지 않고도 자동 범주 작성 기술을 통해 작성된 범주 정의를 대체할 수 있습니다. 문서에 특정 범주를 정의하는 데 사용되는 용어가 포함되어 있지만 문서 자체는 해당 범주에 있지 않을 수 있습니다. 이 경우 범주 정의에서 해당 용어를 제거할 필요 없이 해당 범주에서 문서를 강제 해제할 수 있습니다.

강제 적용/해제는 문서가 한 범주에 속하지만(속하지 않지만), 하나 또는 다른 이유(예: 특정 용어가 포함되어 있음)가 해당 범주에 지정된(지정되지 않은) 특수한 경우에 사용됩니다. 예를 들어 이 상황은 응답자가 *피자가 아주 맛있었습니다. 타고 식은 피자를 누구나 좋아할 것입니다.*와 같은 풍자를 자신의 응답에 사용할 경우에 발생합니다. 레스토랑에서 제공하는 음식과 관련하여 긍정적인 의견을 캡처하는 Pos: [〈Food〉 + 〈Positive〉]라는 범주가 있고 이 반응은 해당 범주에 지정되었다고 가정합니다. 이 경우 이 반응을 해당 범주에서 강제 해제할 수 있습니다.

## 범주에 강제 적용/해제

1. 데이터 분할창에서 특정 범주에 강제 적용/해제할 문서를 선택하십시오.
2. 메뉴에서 **범주 > 자동 설정 시작** 또는 **범주 > 자동 설정 종료**를 선택하십시오. 하위 메뉴에 선택 가능한 범주 목록이 표시됩니다.
3. 이 문서를 강제 적용/해제할 범주를 선택하십시오. 범주를 많이 작성한 경우 일부가 하위 메뉴에 표시되지 않을 수 있습니다.

- 이 경우 하위 메뉴의 맨 아래에 있는 **더 보기**를 선택하십시오. 범주를 선택할 수 있는 모든 범주 대화 상자가 열립니다. **확인**을 클릭하여 변경사항을 적용하십시오.
- 새 범주에 문서를 강제 적용하려면 **빈 범주 작성**을 선택하십시오. 새 범주가 일반 이름을 사용하여 범주 트리에 표시됩니다.

범주에 강제 적용된 문서가 하나 이상 포함된 경우 **자동 설정 시작** 또는 **자동 설정 종료**라는 유사 범주가 트리의 범주 이름 아래에 표시됩니다.

## 강제 적용/해제 상태 지우기

1. 데이터 분할창에서 범주에 강제 적용/해제할 문서를 선택하십시오.
2. 강제 적용하려면 메뉴에서 **범주 > 자동 설정 시작**을 선택하고, 강제 해제하려면 **범주 > 자동 설정 종료**를 선택하십시오. 문서가 강제 적용/해제된 범주 앞에는 선택 표시가 있습니다.
3. 하위 메뉴에서 강제 적용을 제거할 선택 표시가 있는 문서를 선택하십시오. 선택 표시가 제거되고 문서가 더 이상 강제 적용되지 않습니다.

## 강제 적용/해제 상태 모두 지우기

1. 데이터 분할창에서 **자동 설정 시작** 또는 **자동 설정 종료**가 포함된 레코드를 선택하십시오.
2. 메뉴에서 **범주 > 모두 지우기 > 자동 설정 시작** 또는 **범주 > 모두 지우기 > 자동 설정 종료**를 시작하십시오. 문서의 강제 적용 상태가 지워지고 더 이상 범주에 강제 적용/해제되지 않습니다.

**참고:** 이 기능은 소스 텍스트에 고유 ID가 포함된 경우에만 사용할 수 있습니다. 소스 텍스트에 고유 ID가 없는 경우 소스 문서와 텍스트 마이닝 노드 간에 파생 노드를 추가할 수 있습니다. 이 기능은 대화식 세션을 세션을 실행할 경우에만 영향을 미칩니다. 비대화식 스코어링을 위해 범주 모델을 배포하는 경우 이 정보는 문서 ID를 기반으로 하기 때문에 보존되거나 사용되지 않습니다.

## (7) 범주 삭제

범주를 유지하지 않으려면 이를 삭제하면 됩니다.

범주 삭제

1. 범주 분할창에서 삭제하려는 범주를 선택하십시오.
2. 메뉴에서 **편집 > 삭제**를 선택하십시오.

## 10. 군집 분석

군집 보기(보기 > 군집)에서 개념 군집을 작성하고 탐색할 수 있습니다. *군집*은 이러한 개념이 문서/레코드 세트에서 발생하는 빈도와 동일한 문서에서 함께 나타나는 빈도(*동시 발생*이라고도 함)를 기반으로 군집화 알고리즘에 의해 생성된 관련 개념 그룹화입니다. 군집의 각 개념은 군집에서 하나 이상의 다른 개념과 동시 발생합니다. 범주의 목적은 범주에 포함된 텍스트가 각 범주에 대해 디스크립터(개념, 규칙, 패턴)를 매치하는 방법을 기반으로 문서 또는 레코드를 그룹화하는 것인 반면 군집의 목적은 함께 동시 발생하는 개념을 그룹화하는 것입니다.

좋은 군집은 강하게 링크되고 자주 동시 발생하는 개념이 있으며 다른 군집의 개념에 대한 링크가 거의 없는 군집입니다. 큰 데이터 세트에 대한 작업 시 이 기술로 인해 처리 시간이 상당히 길어질 수 있습니다.

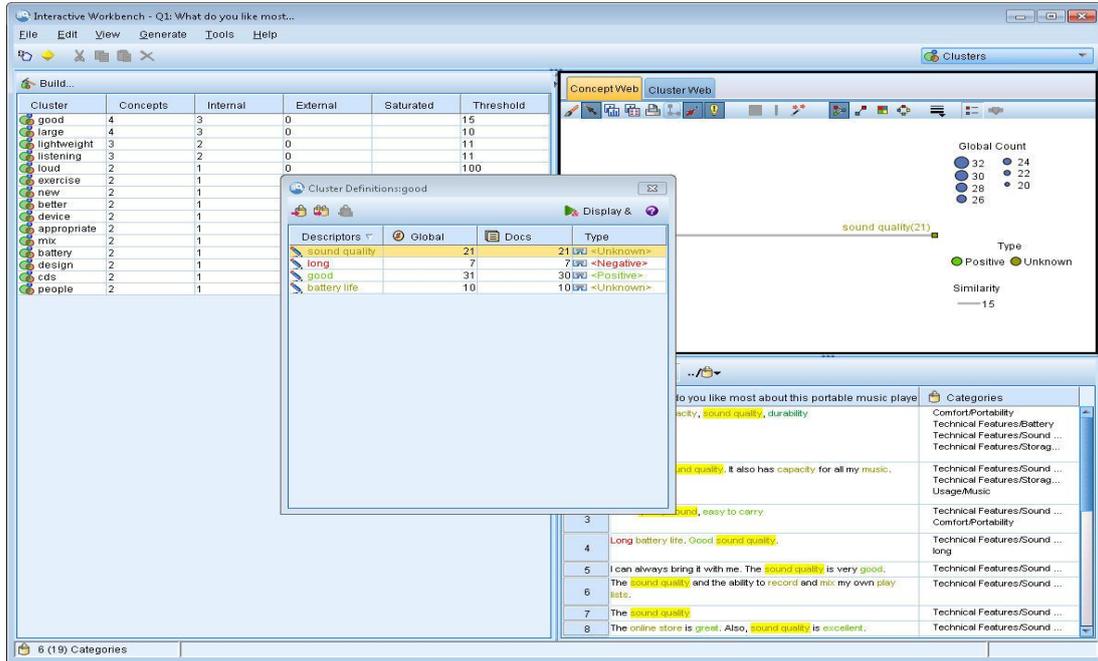
군집화는 개념 세트를 분석하고 문서에서 자주 발생하는 개념을 검색함으로써 시작되는 프로세스입니다. 한 문서에서 동시 발생하는 두 개의 개념을 개념 쌍으로 간주합니다. 그 다음에 군집화 프로세스는 쌍이 함께 발생하는 문서 수를 각 개념이 발생하는 문서 수와 비교하여 각 개념 쌍의 *유사성* 값을 평가합니다. 자세한 정보는 유사성 링크 값 계산의 내용을 참조하십시오.

마지막으로 군집화 프로세스는 통합을 통해 유사한 개념을 군집으로 그룹화하고 해당 링크 값과 군집 작성 대화 상자에 정의된 설정을 고려합니다. 통합을 통해 군집이 포화 상태가 될 때까지 개념이 추가되거나 작은 군집이 더 큰 군집으로 병합됩니다. 개념 또는 작은 군집을 추가로 합쳐 군집 작성 대화 상자에 정의된 설정(개념, 내부 링크 또는 외부 링크 수)을 초과하게 되면 군집이 *포화 상태*가 됩니다. 군집은 군집 내에서 군집 내 다른 개념에 대한 전체 링크 수가 가장 많은 개념의 이름을 사용합니다.

다른 군집에 더 강한 링크가 있거나 포화로 인해 개념 쌍이 발생하는 군집을 병합할 수 없기 때문에 결국 모든 개념 쌍이 동일한 군집에 함께 있게 되는 것은 아닙니다. 이러한 이유로 내부 및 외부 링크가 모두 있습니다.

- *내부 링크*는 군집 내 개념 쌍 간의 링크입니다. 모든 개념이 군집에서 서로 링크되는 것은 아닙니다. 그러나 각 개념은 군집 내에서 하나 이상의 다른 개념에 링크됩니다.
- *외부 링크*는 별도 군집의 개념 쌍(한 군집 내 개념과 다른 군집에서 외부의 개념) 간의 링크입니다.

그림 1. 군집 보기



군집 보기는 세 개의 분할창으로 구성되며, 보기 메뉴에서 해당 이름을 선택하여 각각 숨기거나 표시할 수 있습니다.

- **군집 분할창** 이 분할창에서 군집을 작성하고 관리할 수 있습니다. 자세한 정보는 군집 탐색의 내용을 참조하십시오.
- **시각화 분할창** 이 분할창에서 군집 및 군집 상호작용 방법을 시각적으로 탐색할 수 있습니다. 자세한 정보는 군집 그래프의 내용을 참조하십시오.
- **데이터 분할창** 군집 정의 대화 상자의 선택사항에 해당하는 문서 및 레코드 내에 포함된 텍스트를 탐색하고 검토할 수 있습니다. 자세한 정보는 군집 정의의 내용을 참조하십시오.

## 1) 군집 작성

처음 군집 보기에 액세스할 때, 어떤 군집도 볼 수 없습니다. 메뉴를 통하거나(도구 >군집 작성) 도구 모음에서 **작성...** 단추를 클릭하여 군집을 작성할 수 있습니다. 이 조치는 군집 작성을 위한 설정 및 한계를 정의할 수 있는 군집 작성 대화 상자를 엽니다.

**참고:** 추출 결과가 더 이상 자원과 매치하지 않는 경우, 이 분할창은 추출 결과 분할창에서와 같이 노란색이 됩니다. 최근 추출 결과를 확보하기 위해 다시 추출할 수 있으며, 노란색이 사라집니다. 그러나 추출이 수행될 때마다 군집 분할창이 지워지므로 군집을 다시 작성해야 합니다. 마찬가지로 군집은 한 세션에서 다른 세션으로 저장되지 않습니다.

군집 작성 대화 상자에서 다음 영역 및 필드를 사용할 수 있습니다.

## 입력

**입력 테이블** 군집은 특정 유형에서 파생된 디스크립터에서 작성됩니다. 테이블에서, 작성 프로세스에 포함할 유형을 선택할 수 있습니다. 대부분의 레코드 또는 문서를 캡처하는 유형은 기본적으로 미리 선택됩니다.

**군집에 대한 개념:** 군집에 사용할 개념을 선택하는 방법을 선택하십시오. 개념 수를 줄여서, 군집 프로세스를 가속화할 수 있습니다. 상위 개념 수, 상위 개념 퍼센트 또는 모든 개념 사용을 통해 군집할 수 있습니다.

- **문서 개수를 기준으로 한 수 상위 개념 수**를 선택하는 경우, 군집에 고려될 개념 수를 입력하십시오. 개념은 최상위 문서 수 값을 가지고 있는 개념을 기준으로 선택됩니다. 문서 개수는 개념이 나타나는 문서 또는 레코드의 수입니다. 최대값은 150,000입니다.
- **문서 개수를 기준으로 한 퍼센트 개념의 상위 퍼센트**를 선택하는 경우, 군집에 고려될 개념의 퍼센트를 입력하십시오. 개념은 최상위 문서 개수 값을 가지고 있는 개념의 퍼센트를 기준으로 선택됩니다.

## 출력 한계

**작성할 최대 군집 수** 이 값은 군집 분할창에서 생성하고 표시할 최대 군집 수입니다. 군집 프로세스 동안, 포화모형 군집은 불포화모형 군집 이전에 제시되므로, 결과로 생성되는 많은 군집이 포화모형이 됩니다. 불포화모형 군집을 더 보려면, 이 설정을 포화모형 군집 수보다 큰 값으로 변경하면 됩니다.

**군집 내의 최대 개념** 이 값은 군집이 포함할 수 있는 최대 개념 수입니다.

**군집 내의 최소 개념** 이 값은 군집을 작성하기 위해 링크해야 하는 최소 개념 수입니다.

**최대 내부 링크 수** 이 값은 군집이 포함할 수 있는 최대 내부 링크 수입니다. 내부 링크는 군집 내의 개념 쌍 사이에 있는 링크입니다.

**최대 외부 링크 수** 이 값은 군집 외부에서 개념에 대한 최대 링크 수입니다. 외부 링크는 별도의 군집에서 개념 쌍 사이에 있는 링크입니다.

**최소 링크 값** 이 값은 군집에 고려할 개념 쌍에 대해 승인된 가장 작은 링크 값입니다. 링크 값은 유사성 수식을 사용하여 계산됩니다. 자세한 정보는 유사성 링크 값 계산의 내용을 참조하십시오.

**특정 개념 쌍 방지.** 프로세스가 출력에 두 개의 개념을 함께 그룹화하거나 쌍으로 만드는 프로세스를 중지하려면 이 선택란을 선택하십시오. 개념 쌍을 작성하거나 관리하려면 **쌍 관리**를 클릭하십시오. 자세한 정보는 링크 예외 쌍 관리의 내용을 참조하십시오.

### (1) 유사성 링크 값 계산

개념 쌍이 동시 발생하는 문서 수만 알면 본질적으로 두 개념이 어느 정도 유사한지 알 수 없습니다. 이러한 경우 유사성 값이 유용합니다. 유사성 링크 값은 동시 발생 문서 개수를 관계의 각 개념에 대한 개별 문서 수와 비교하여 측정됩니다. 유사성을 계산할 때 측정 단위는 개념 또는 개념 쌍을 찾은 문서 수(문서 개수)입니다. 문서에서 최소 한 번 발생하면 문서에서 개념 또는 개념 쌍을 "찾을 수 있습니다". 개념 그래프에서 선 굵기로 그래프에 유사성 링크 값을 표시하도록 선택할 수 있습니다.

알고리즘은 가장 강력한 해당 관계를 표시하는데, 텍스트 데이터에 함께 나타날 개념에 대한 경향이 독립적으로 발생할 경향보다 훨씬 높음을 의미합니다. 내부적으로 알고리즘은 0 - 1 범위의 유사성 계수를 산출합니다. 여기서 1 값은 두 개념이 항상 동시에 나타나며 별도로 나타나지 않음을 의미합니다. 유사성 계수 결과는 100을 곱하여 가장 가까운 정수로 반올림됩니다. 유사성 계수는 다음 그림에 표시된 수식을 사용하여 계산됩니다.

그림 1. 유사성 계수 수식

$$\text{similarity coefficient} = \frac{(C_{IJ})^2}{(C_I \times C_J)}$$

여기서,

- $C_I$ 는 개념 I가 발생하는 문서 또는 레코드 수입니다.
- $C_J$ 는 개념 J가 발생하는 문서 또는 레코드 수입니다.
- $C_{IJ}$ 는 개념 쌍 I와 J가 문서 세트에서 동시 발생하는 문서 또는 레코드 수입니다.

예를 들어, 5,000개의 문서가 있다고 가정하십시오. I와 J는 추출된 개념이고 IJ는 I와 J의 개념 쌍 동시 발생입니다. 다음 테이블에서는 계수 및 링크 값 계산 방법을 보여주는 두 개의 시나리오를 제안합니다.

표 1. 개념 빈도 예제		
개념/쌍	시나리오 A	시나리오 B
개념: I	20개 문서에 발생	30개 문서에 발생
개념: J	20개 문서에 발생	60개 문서에 발생
개념 쌍: IJ	20개 문서에 동시 발생	20개 문서에 동시 발생
유사성 계수	1	0.22222
유사성 링크 값	100	22

시나리오 A에서 개념 I와 J는 물론 쌍 II는 20개 문서에서 발생하며 유사성 계수 1을 산출합니다(개념이 항상 함께 발생함을 의미). 이 쌍의 유사성 링크 값은 100입니다.

시나리오 B에서 개념 I는 30개 문서에서 발생하고 개념 J는 60개 문서에서 발생하지만 쌍 II는 20개 문서에서만 발생합니다. 따라서 유사성 계수는 0.22222입니다. 이 쌍의 유사성 링크 값은 22로 반내림됩니다.

## 2) 군집 탐색

군집을 작성하면, 군집 분할창에서 결과 세트를 볼 수 있습니다. 군집마다, 테이블에서 다음 정보를 사용할 수 있습니다.

- **군집.** 군집의 이름입니다. 군집 이름은 내부 링크 수가 가장 많은 개념 뒤에 지정됩니다.
- **개념.** 군집의 개념 수입니다. 자세한 정보는 군집 정의의 내용을 참조하십시오.
- **내부.** 군집의 내부 링크 수입니다. 내부 링크는 군집 내의 개념 쌍 사이에 있는 링크입니다.
- **외부.** 군집에 있는 외부 링크 수입니다. 외부 링크는 하나의 개념이 하나의 군집에 있고 다른 개념이 다른 군집에 있는 경우 개념 쌍 사이에 있는 링크입니다.
- **포화.** 기호가 존재하면, 이 군집이 더 커질 수 있지만, 하나 이상의 한계가 초과될 수 있어서, 군집 프로세스가 해당 군집에 대해 종료되고 포화모형인 것으로 간주됩니다. 군집 프로세스 끝에서, 포화모형 군집은 불포화모형 군집 이전에 제시되므로, 결과로 생성되는 많은 군집이 포화모형이 됩니다. 불포화모형 군집을 보려면, **작성할 최대 군집 수** 설정을 포화모형 군집 수보다 더 큰 값으로 변경하거나 **최소 링크 값**을 감소시킬 수 있습니다. 자세한 정보는 군집 작성의 내용을 참조하십시오.
- **임계값.** 군집에서 발생하는 모든 개념 쌍에 대해, 군집에서 유사성이 가장 낮은 링크 값입니다. 자세한 정보는 유사성 링크 값 계산의 내용을 참조하십시오. 임계값이 높은 군집은 군집의 개념이 전반적으로 높은 유사성을 가지고 있고 임계값이 낮은 군집의 개념보다 훨씬 근접하게 관련됨을 나타냅니다.

지정된 군집에 대해 더 자세히 알아보기 위해 군집을 선택할 수 있으며, 오른쪽의 시각화 분할창이 군집을 탐색할 수 있도록 두 개의 그래프를 표시합니다. 자세한 정보는 군집 그래프의 내용을 참조하십시오. 또한 테이블의 내용을 다른 애플리케이션으로 잘라내어 붙여넣을 수도 있습니다.

추출 결과가 더 이상 자원과 매치하지 않는 경우, 이 분할창은 추출 결과 분할창에서와 같이 노란색이 됩니다. 최근 추출 결과를 확보하기 위해 다시 추출할 수 있으며, 노란색이 사라집니다. 그러나 추출이 수행될 때마다 군집 분할창이 지워지므로 군집을 다시 작성해야 합니다. 마찬가지로 군집은 한 세션에서 다른 세션으로 저장되지 않습니다.

## (1) 군집 정의

군집 분할창에서 선택하고 군집 정의 대화 상자를 열어서(보기 > 군집 정의) 군집 내에서 모든 개념을 볼 수 있습니다.

선택된 군집의 모든 개념은 군집 정의 대화 상자에 나타납니다. 군집 정의 대화 상자에서 하나 이상의 개념을 선택하고 표시 &를 클릭하면, 데이터 분할창에 선택된 모든 개념이 함께 표시되는 모든 문서 또는 레코드가 표시됩니다. 그러나 군집 분할창에서 군집을 선택할 때 데이터 분할창에 텍스트 레코드 또는 문서가 표시되지 않습니다. 데이터 분할창에 관한 일반 정보는 in의 내용을 참조하십시오.

이 대화 상자에서 개념을 선택하면 개념 웹 그래프도 변경됩니다. 자세한 정보는 군집 그래프의 내용을 참조하십시오. 마찬가지로, 군집 정의 대화 상자에서 하나 이상의 개념을 선택할 때 해당 개념의 모든 외부 및 내부 링크가 시각화 분할창에 표시됩니다.

### 열 설명

각 디스크립터를 쉽게 식별할 수 있도록 아이콘이 표시됩니다.

표 1. 열 및 디스크립터 아이콘	
열	설명
디스크립터	개념의 이름.
 글로벌	해당 디스크립터가 전체 데이터 세트에 나타나는 횟수를 표시하며, 전역 빈도라고도 합니다.
 문서	이 디스크립터가 나타나는 문서 또는 레코드 수로, 문서 빈도라고도 합니다.
Type	디스크립터가 속하는 유형을 표시합니다. 디스크립터가 범주 규칙인 경우, 어떤 유형 이름도 이 열에 표시되지 않습니다.

### 도구 모음 조치

이 대화 상자에서, 범주에 사용할 하나 이상의 개념을 선택할 수도 있습니다. 이를 수행하기 위한 몇 가지 방법이 있지만, 군집에 발생하는 개념을 선택하고 범주 규칙으로 추가하는 것이 가장 좋습니다. 자세한 정보는 동시 발생 규칙의 내용을 참조하십시오. 도구 모음 단추를 사용하여 범주에 개념을 추가할 수 있습니다.

표 2. 범주에 개념을 추가할 도구 모음 단추

아이콘	설명
	선택된 개념을 기존 또는 새 범주에 추가합니다.
	& 범주 규칙 양식으로 선택된 개념을 기존 또는 새 범주에 추가합니다. 자세한 정보는 범주 규칙 사용의 내용을 참조하십시오.
	선택된 각 개념을 자체의 고유한 새 범주로 추가합니다.
	데이터 분할창과 시각화 분할창에 표시된 내용을 선택한 디스크립터에 따라 업데이트합니다.

참고: 컨텍스트 메뉴를 사용하여 동의어나 제외 항목으로 유형에 개념을 추가할 수도 있습니다.

## 11. 텍스트 링크 분석 탐색

텍스트 링크 분석(TLA) 보기에서 텍스트 링크 분석 패턴 결과를 탐색할 수 있습니다. 텍스트 링크 분석은 패턴 규칙을 정의하고 이를 텍스트에서 찾은 실제로 추출된 개념 및 관계와 비교할 수 있게 하는 패턴 매치 기술입니다.

예를 들어, 조직에 대한 아이디어 추출이 충분히 흥미롭지 않을 수 있습니다. TLA를 사용하면 이 조직과 다른 조직 또는 조직 내 사용자 간의 링크에 대해서도 알 수 있습니다. TLA를 사용하여 제품에 대한 의견 또는 일부 언어의 경우 유전자 간의 관계도 추출할 수 있습니다.

일부 TLA 패턴 결과를 추출했으면 텍스트 링크 분석 보기의 유형 및 개념 패턴 분할창에서 검토할 수 있습니다. 자세한 정보는 유형 및 개념 패턴의 내용을 참조하십시오. 이 보기의 데이터 또는 시각화 분할창에서 추가로 탐색할 수 있습니다. 아마 가장 중요하게는 범주에 추가할 수 있습니다.

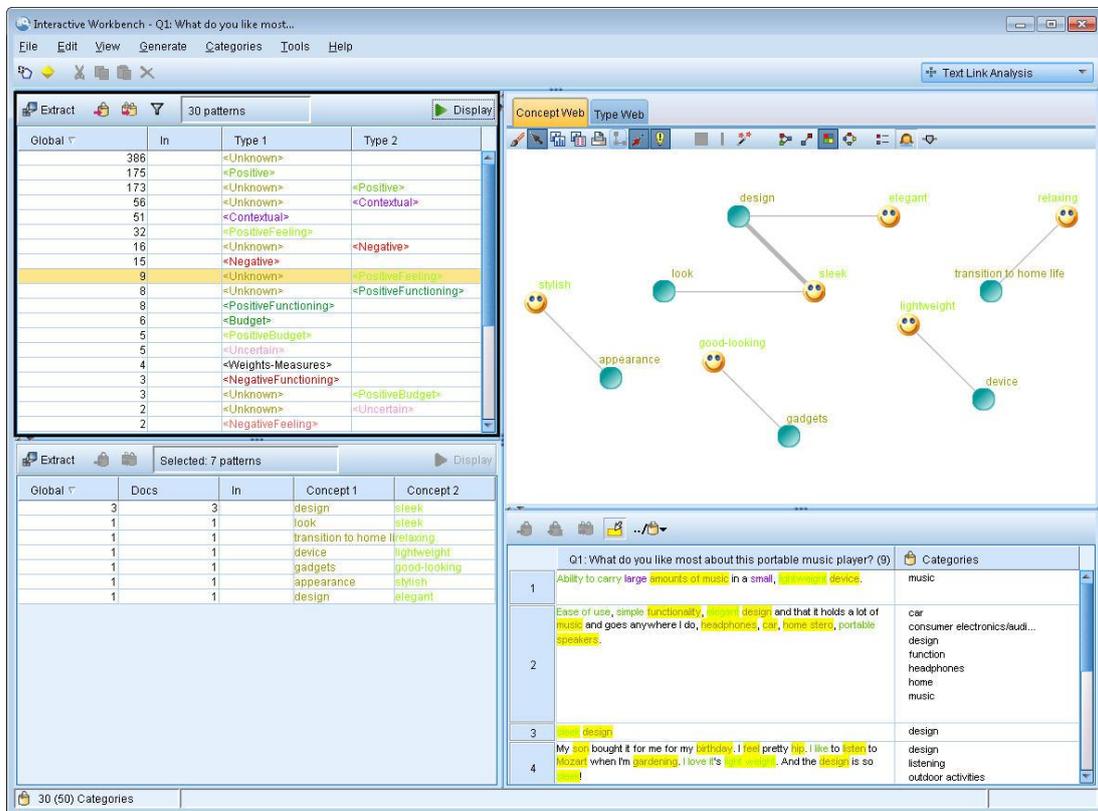
아직 그렇게 하도록 선택하지 않았으면 **추출**을 클릭하고 추출 설정 대화 상자에서 **텍스트 링크 분석 패턴 추출 사용**을 선택할 수 있습니다. 자세한 정보는 TLA 패턴 결과 추출의 내용을 참조하십시오.

TLA 패턴 결과를 추출하려면 사용 중인 자원 템플릿 또는 라이브러리에 일부 TLA 패턴 규칙이 정의되어 있어야 합니다. IBM® SPSS® Modeler Text Analytics와 함께 제공되는 일정 자원 템플릿에서 TLA 패턴을 사용할 수 있습니다. 추출할 수 있는 관계 및 패턴 종류는 자원에 정의된 TLA 규칙에 전적으로 좌우됩니다. 직접 TLA 규칙을 정의할 수 있습니다. 패턴은 입력 텍스트와 비교되는 부울 쿼리 또는 규칙을 형성하기 위한 매크로, 단어 목록 또는 단어 간격으로 구성됩니다. 자세한 정보는 텍스트 링크 규칙에 대한 정보의 내용을 참조하십시오.

TLA 패턴 규칙이 텍스트와 매치할 때마다 이 텍스트를 패턴으로 추출하고 출력 데이터로 재구성할 수 있습니다. 그러면 텍스트 링크 분석 보기 분할창에 결과가 표시됩니다. 보기 메뉴에서 해당 이름을 선택하여 각 분할창을 숨기거나 표시할 수 있습니다.

- **유형 및 개념 패턴 분할창.** 이 두 개의 분할창에서 패턴을 작성하고 탐색할 수 있습니다. 자세한 정보는 유형 및 개념 패턴의 내용을 참조하십시오.
- **시각화 분할창.** 이 분할창에서 패턴의 개념 및 유형이 상호작용하는 방법을 시각적으로 탐색할 수 있습니다. 자세한 정보는 텍스트 링크 분석 그래프의 내용을 참조하십시오.
- **데이터 분할창.** 다른 분할창의 선택사항에 해당하는 문서 및 레코드 내에 포함된 텍스트를 탐색하고 검토할 수 있습니다. 자세한 정보는 데이터 분할창의 내용을 참조하십시오.

그림 1. 텍스트 링크 분석 보기



## 1) TLA 패턴 결과 추출

추출 프로세스는 개념 및 유형 세트뿐만 아니라 텍스트 링크 분석(TLA) 패턴(사용 가능한 경우)을 결과로 생성합니다. TLA 패턴을 추출한 경우 텍스트 링크 분석 보기에서 이를 볼 수 있습니다. 추출 결과가 자원과 동기화되지 않을 때마다 패턴 분할창은 재추출이 다른 결과를 생성함을 나타내는 노랑 색상이 됩니다.

노드 설정 또는 추출 대화 상자에서 **텍스트 링크 분석 패턴 추출 사용** 옵션을 사용하여 이러한 패턴을 추출하도록 선택해야 합니다. 자세한 정보는 데이터 추출의 내용을 참조하십시오.

**참고:** 데이터 세트의 크기와 추출 프로세스를 완료하는 데 걸리는 시간 간의 관계가 있습니다. 성능 통계 및 권장사항은 설치 지시사항을 참조하십시오. 표본 노드 업스트림 삽입 또는 시스템 구성 최적화를 항상 고려할 수 있습니다.

#### 데이터 추출 방법

1. 메뉴에서 **도구 > 추출**을 선택하십시오. 또는 **추출 도구 모음** 단추를 클릭하십시오.
2. 사용할 옵션을 변경하십시오. TLA 패턴 결과를 추출하려면 이 탭에서 **텍스트 링크 분석 패턴 추출 사용** 옵션을 선택해야 하는 것은 물론 템플릿에 TLA 규칙이 있어야 함을 명심하십시오. 자세한 정보는 데이터 추출의 내용을 참조하십시오.
3. **추출**을 클릭하여 추출 프로세스를 시작하십시오.

추출이 시작되면 진행 대화 상자가 열립니다. 추출을 중단하려면 **취소**를 클릭하십시오. 추출이 완료되면 대화 상자가 닫히고 분할창에 결과가 나타납니다. 자세한 정보는 유형 및 개념 패턴의 내용을 참조하십시오.

## 2) 유형 및 개념 패턴

패턴은 두 개의 파트 즉, 개념과 유형을 조합하여 구성됩니다. 패턴은 특정 주제에 대한 의견 또는 개념 간의 관계를 발견하려고 시도할 때 가장 유용합니다. 예를 들어, 경쟁자의 제품 이름을 추출하는 것이 충분히 흥미롭지 않을 수 있습니다. 이 경우, 추출된 패턴을 살펴 문서 또는 레코드에 제품이 좋음, 나쁨 또는 비쌌을 표현하는 텍스트가 포함된 예제를 찾을 수 있는지 여부를 확인할 수 있습니다.

패턴은 최대 6개의 유형 또는 6개의 개념으로 구성될 수 있습니다. 이러한 이유로 두 패턴 분할창 모두의 행은 최대 6개의 슬롯 또는 위치를 포함합니다. 언어학적 자원에서 정의된 대로 각 슬롯은 TLA 패턴 규칙에서 요소의 특정 위치에 해당합니다. 대화형 워크벤치에서는 슬롯에 값이 포함되지 않은 경우 테이블에 슬롯이 표시되지 않습니다. 예를 들어, 가장 긴 패턴 결과에 단지 4개의 슬롯이 포함된 경우 마지막 2개는 표시되지 않습니다. 자세한 정보는 텍스트 링크 규칙에 대한 정보의 내용을 참조하십시오.

패턴 결과를 추출할 때 패턴 결과는 먼저 유형 수준에서 그룹화된 후 개념 패턴으로 나뉩니다. 이러한 이유로 두 개의 다른 결과 분할창 즉, **유형 패턴**(왼쪽 상단)과 **개념 패턴**(왼쪽 하단)이 있습니다. 리턴된 개념 패턴을 모두 보려면 모든 유형 패턴을 선택하십시오. 그러면 맨 아래 개념 패턴 분할창이 필터 대화 상자에 정의된 대로 순위 최대값까지 개념 패턴을 모두 표시합니다.

**유형 패턴** 이 분할창은 TLA 패턴 규칙과 매치하는 하나 이상의 관련 유형으로 구성되는 패턴 결과를 제공합니다. 유형 패턴은 특정 위치의 조직에 대한 긍정적 피드백을 제공할 수 있는 <Organization> + <Location> + <Positive>로 표시됩니다. 구문은 다음과 같습니다.

```
<Type1> + <Type2> + <Type3> + <Type4> + <Type5> + <Type6>
```

**개념 패턴** 이 분할창은 그 위의 유형 패턴 분할창에서 현재 선택된 모든 유형 패턴에 대한 패턴 결과를 개념 수준에서 제공합니다. 개념 패턴은 hotel + paris + wonderful과 같은 구조를 따릅니다. 구문은 다음과 같습니다.

```
concept1 + concept2 + concept3 + concept4 + concept5 + concept6
```

패턴 결과가 최대 6개 미만의 슬롯을 사용하는 경우 필요한 수의 슬롯(또는 열)만 표시됩니다. 채워진 두 개의 슬롯 사이에 발견된 빈 슬롯은 버리므로 <Type1>+<>+<Type2>+<>+<>+<> 패턴을 <Type1>+<Type3>으로 나타낼 수 있습니다. 개념 패턴의 경우, 이는 concept1+concept2입니다(여기서 .는 널값을 나타냄).

범주 및 개념 보기에서의 추출 결과의 경우와 마찬가지로 여기서 결과를 검토할 수 있습니다. 이러한 패턴을 구성하는 유형 및 개념에 대해 수행할 세분화가 있으면 범주 및 개념 보기의 추출 결과 분할창에서 또는 자원 편집기에서 직접 세분화를 수행하고 패턴을 재추출할 수 있습니다. 개념, 유형 또는 패턴이 범주 정의에서 있는 그대로 또는 규칙의 일부로 사용될 때마다 범주 또는 규칙 아이콘이 패턴 또는 추출 결과 테이블의 위치 열에 나타납니다.

**참고:** 분할창에 표시할 수 있는 수보다 결과 수가 많은 경우, 분할창의 맨 아래쪽에 있는 제어를 사용하여 결과 앞 또는 뒤로 이동하거나 이동할 페이지 수를 입력할 수 있습니다.

### 3) TLA 결과 필터링

매우 큰 데이터 세트에 대한 작업 시 추출 프로세스는 수백만 개의 결과를 생성할 수 있습니다. 많은 사용자가 이 양으로 인해 결과를 효과적으로 검토하기가 더 어렵습니다. 그러나 가장 흥미로운 해당 결과에 주목하려면 이러한 결과를 필터링할 수 있습니다. 필터 대화 상자의 설정을 변경하여 표시되는 패턴을 제한할 수 있습니다. 이러한 설정은 모두 함께 사용됩니다.

TLA 보기에서 필터 대화 상자는 다음 영역과 필드를 포함합니다.

**빈도 기준으로 필터링** 일정 글로벌 또는 문서 빈도 값을 가진 해당 결과만 표시하도록 필터링할 수 있습니다.

- **글로벌 빈도**는 전체 문서 또는 레코드 세트에 패턴이 나타나는 총 횟수이며 **글로벌** 열에 표시됩니다.
- **문서 빈도**는 패턴이 나타나는 총 문서 또는 레코드 수이며 **문서** 열에 표시됩니다.

예를 들어, 패턴이 500개 레코드에 300번 나타났으면 이 패턴의 글로벌 빈도는 300이고 문서 빈도는 500입니다.

**매치 텍스트** 순 여기에 정의하는 규칙과 매치하는 해당 결과만 표시하도록 필터링할 수도 있습니다. **매치 텍스트** 필드에 매치될 문자 세트를 입력한 후 슬롯 번호 또는 모두를 식별하여 개념 또는 유형 이름 내에서 이 텍스트를 검색할 것인지 여부를 선택하십시오. 그리고 나서 매치를 적용할 조건을 선택하십시오(꺾쇠괄호를 사용하여 유형 이름의 시작 또는 끝을 표시하지 않아도 됨). 규칙이 두 명령문 모두 또는 이 중 하나와만 매치하도록 **And** 또는 **Or**을 선택하고 첫 번째와 동일한 방식으로 두 번째 텍스트 매치 명령문을 정의하십시오.

표 1. 매치 텍스트 조건

조건	설명
포함	문자열이 어딘가에 발생하면 텍스트가 매치됩니다(기본 선택사항).
시작 문자	개념 또는 유형이 지정된 텍스트로 시작하는 경우에만 텍스트가 매치됩니다.
끝 문자	개념 또는 유형이 지정된 텍스트로 끝나는 경우에만 텍스트가 매치됩니다.
정확히 일치	전체 문자열이 개념 또는 유형 이름과 매치해야 합니다.

## 패턴 분할창에 표시된 결과

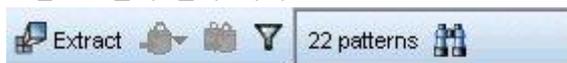
영어 버전의 소프트웨어를 사용 중이라고 가정하십시오. 필터를 기반으로 패턴 분할창 도구 모음에 결과가 표시되는 방법의 몇 가지 예제는 다음과 같습니다.

그림 1. 필터 결과 예제 1



이 예제에서 도구 모음은 순위 최대값이 필터에 지정되기 때문에 리턴된 패턴 수가 제한되었음을 보여줍니다. 보라색 아이콘이 있는 경우 이는 최대 패턴 수가 충족되었음을 의미합니다. 자세한 정보를 보려면 아이콘 위에 마우스를 올려 놓으십시오. **순위별** 필터에 대한 이전 설명을 참조하십시오.

그림 2. 필터 결과 예제 2



이 예제에서 도구 모음은 매치 텍스트 필터를 사용하여 결과가 제한되었음을 표시합니다(돋보기 아이콘 참조). 아이콘 위에 마우스를 올려 놓아 매치 텍스트 내용을 볼 수 있습니다.

## 결과 필터링 방법

1. 메뉴에서 **도구 > 필터**를 선택하십시오. 필터 대화 상자가 열립니다.
2. 사용할 필터를 선택하고 세분화하십시오.
3. **확인**을 클릭하여 필터를 적용하고 새 결과를 확인하십시오.

## 4) 데이터 분할창

텍스트 링크 분석 패턴을 추출하고 탐색할 때 작업 중인 일부 데이터를 검토할 수 있습니다. 예를 들어, 패턴 그룹이 발견된 실제 레코드를 볼 수 있습니다. 오른쪽 하단에 있는 데이터 분할창에서 레코드 또는 문서를 검토할 수 있습니다. 기본적으로 표시되지 않으면 메뉴에서 **보기 > 분할창 > 데이터**를 선택하십시오.

데이터 분할창은 일정 표시 한계까지 보기의 선택사항에 해당하는 문서 또는 레코드당 1행을 제공합니다. 기본적으로 데이터 분할창에 표시된 문서 또는 레코드 수는 데이터를 보다 빨리 볼 수 있도록 제한됩니다. 그러나 옵션 대화 상자에서 이를 조정할 수 있습니다. 자세한 정보는 옵션: 세션 탭의 내용을 참조하십시오.

 **참고:** 분할창에 표시할 수 있는 수보다 결과 수가 많은 경우, 분할창의 맨 아래쪽에 있는 제어를 사용하여 결과 앞 또는 뒤로 이동하거나 이동할 페이지 수를 입력할 수 있습니다.

## 데이터 분할창 표시 및 새로 고침

큰 데이터 세트의 경우 자동 데이터 새로 고침을 완료하려면 약간의 시간이 걸리기 때문에 데이터 분할창은 자동으로 표시를 새로 고치지 않습니다. 따라서 이 보기에서 유형 또는 개념을 선택할 때마다 **표시**를 클릭하여 데이터 분할창의 콘텐츠를 새로 고칠 수 있습니다.

### 텍스트 문서 또는 레코드

텍스트 데이터가 레코드 양식으로 되어 있고 텍스트의 길이가 비교적 짧으면, 데이터 분할창의 텍스트 필드는 텍스트 데이터를 전부 표시합니다. 그러나 레코드와 큰 데이터 세트에 대한 작업을 할 때 텍스트 필드 열은 텍스트의 짧은 조각을 표시하고 테이블에서 선택한 레코드의 텍스트를 모두 또는 더 많이 표시할 수 있도록 오른쪽에 텍스트 미리보기 분할창을 엽니다. 텍스트 데이터가 개별 문서 양식으로 되어 있으면 데이터 분할창이 문서의 파일 이름을 표시합니다. 문서를 선택하면 선택된 문서의 텍스트와 함께 텍스트 미리보기 분할창이 열립니다.

## 색상 및 강조표시

데이터를 표시할 때마다 텍스트에서 쉽게 식별할 수 있도록 해당 문서 또는 레코드에서 찾은 개념 및 디스크립터가 색상으로 강조표시됩니다. 색상 코딩은 개념이 속한 유형에 해당합니다. 색상 코드화된 항목 위에 마우스를 올려 놓아 추출된 개념과 지정된 유형도 표시할 수 있습니다. 추출되지 않은 텍스트는 검은색으로 나타납니다. 일반적으로 추출되지 않은 이러한 단어는 접속사(*and* 또는 *with*), 대명사(*me* 또는 *they*), 동사(*is*, *have* 또는 *take*)인 경우가 많습니다.

## 데이터 분할창 열

텍스트 필드 열이 항상 표시되는 동안에는 다른 열도 표시할 수 있습니다. 다른 열을 표시하려면 메뉴에서 **보기 > 데이터 분할창**을 선택한 후 데이터 분할창에 표시할 열을 선택하십시오. 표시할 수 있는 열은 다음과 같습니다.

- **"텍스트 필드 이름" (#)/문서.** 개념과 유형이 추출된 텍스트 데이터에 열을 추가합니다. 데이터가 문서에 있는 경우, 열을 문서라고 하며 문서 파일 이름 또는 전체 경로만 표시됩니다. 해당 문서에 대한 텍스트를 보려면 텍스트 미리보기 분할창에서 보아야 합니다. 데이터 분할창의 행 수는 이 열 이름 다음에 괄호로 표시됩니다. 옵션 대화 상자에서 로드 속도를 늘리는데 사용되는 한계 때문에 모든 문서 또는 레코드가 표시되지는 않는 경우가 있습니다. 최대값에 도달하면 숫자 뒤에 - **Max**가 옵니다. 자세한 정보는 옵션: 세션 탭의 내용을 참조하십시오.
- **범주.** 레코드가 속한 범주를 각각 나열합니다. 이 열이 표시될 때마다 데이터 분할창을 새로 고치면 최신 정보를 표시하기 위해 시간이 약간 오래 걸립니다.
- **자동 설정 시작.** 문서를 강제 적용한 범주를 나열합니다. **편집 > 자동 설정 시작** 메뉴를 선택하면 문서가 해당 범주로 강제 적용됩니다. 자세한 정보는 범주에 문서 강제 적용/해제의 내용을 참조하십시오.
- **자동 설정 종료.** 문서를 제거한 범주를 나열합니다. **편집 > 자동 설정 종료** 메뉴를 선택하면 문서가 해당 범주에서 강제 해제됩니다. 예를 들어 응답자의 풍자로 응답 범주가 잘못 지정된 경우에 사용할 수 있습니다. 자세한 정보는 범주에 문서 강제 적용/해제의 내용을 참조하십시오.
- **범주 수.** 레코드가 속해 있는 범주 수를 나열합니다.
- **관련성 순위.** 단일 범주에 있는 각 레코드에 대한 순위를 제공합니다. 이 순위는 해당 범주의 다른 레코드와 비교하여 레코드가 범주에 얼마나 잘 맞는지를 보여줍니다. 순위를 보려면 범주 분할창(왼쪽 상단 분할창)에서 범주를 선택하십시오. 자세한 정보는 범주 관련성의 내용을 참조하십시오.
- **반응 플래그.** 사용할 수 있는 플래그를 표시하는 열을 추가합니다. 이 열의 내부를 클릭하면 문서에 지정한 플래그의 유형을 변경할 수 있습니다. "완료" 플래그 또는 "중요" 플래그로 문서에 플래그를 지정하거나 플래그를 제거할 수 있습니다. 이는 범주 모델의 완료 여부를 검토하는 데 유용합니다. 자세한 정보는 반응에 플래그 지정의 내용을 참조하십시오.

## (1) 반응에 플래그 지정

진행 상황을 모니터링하는 데 도움이 되도록 데이터 분할창에서 플래그를 사용하여 문서를 표시할 수 있습니다. 이 기능은 소스 문서에 고유 ID가 포함된 경우에만 사용할 수 있습니다. 소스 문서에 고유 ID가 없는 경우 소스 문서와 텍스트 마이닝 노드 간에 파생 노드를 추가할 수 있습니다.

문서를 표시하려는 데는 다음을 포함하여 여러 가지가 이유가 있을 수 있습니다.

- 나중에 시작 위치를 알 수 있도록 수동으로 검토한 문서를 표시하기 위해
- 처리 방법을 알 수 없는 문서를 표시하기 위해

플래그로 문서를 표시한 후에는 계속해서 문서에 대해 작업할 수 있습니다. 이는 순전히 자신의 레코드 보관을 위한 것입니다. 다음 플래그 중에서 선택할 수 있습니다.

플래그	설명
	완료된 것으로 간주되는 문서를 나타내는 완료 플래그입니다.
	중요한 것으로 간주되는 문서를 나타내는 중요 플래그입니다.

## 플래그로 문서 표시

1. 데이터 분할창에서 표시하려는 문서를 마우스 오른쪽 단추로 클릭하십시오.
2. 컨텍스트 메뉴에서 보기 > 데이터 분할창 > 반응 플래그를 선택한 후 사용하려는 플래그의 유형(중요 플래그 또는 완료 플래그)을 선택하십시오. 선택한 플래그가 지정됩니다. 플래그 열이 데이터 분할창에 표시되지 않았다면 표시됩니다.

## 플래그 지우기

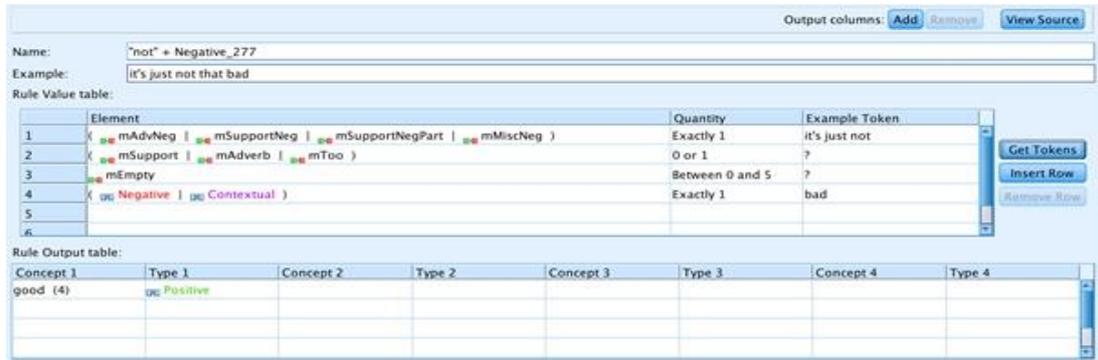
1. 데이터 분할창에서 플래그를 제거할 문서를 마우스 오른쪽 단추로 클릭하십시오.
2. 컨텍스트 메뉴에서 반응 표시 도구 > 플래그 지우기를 선택하십시오. 선택한 플래그가 제거됩니다.

## 5) 유형 재할당 규칙

유형 재할당 규칙(TRR)은 유형, 매크로 및/또는 토큰으로 구성된 시퀀스를 특정 유형의 새 개념으로 변환합니다. 또한 의견 템플릿에서 극성이 변경된 의견을 포착하는 데 사용할 수 있습니다. 예를 들어 "not that bad" 문구, "bad" 단어는 부정적인 의견입니다. 이 컨텍스트에서 실제 의미는 "not bad"이며 긍정적인 의미입니다.

버전 18.2까지는 이 극성 변경을 특정 텍스트 링크 분석(TLA) 규칙으로 관리했습니다.

그림 1. TLA 규칙



여러 의견 유형(Positive, PositiveAttitude, PositiveBudget, PositiveCompetence, PositiveFeeling, PositiveFunctioning, PositiveRecommendation, Negative, NegativeAttitude, NegativeBudget, NegativeCompetence, NegativeFeeling, NegativeFunctioning, NegativeRecommendation, Contextual) 때문에 이 규칙은 다음에 대한 특정 TLA 규칙을 작성하는 것과 관련됩니다.

- 각 유형. 예를 들어,

```
"not + xxx + <NegativeBudget>" => "<PositiveBudget>"
```

또는

```
"not + xxx + <PositiveAttitude>" => "<NegativeAttitude>"
```

- 여러 구문 컨텍스트. 예를 들어,

```
* topic + negation + opinion ("hotel wasn't good")
* negation + opinion + topic ("it was not a good hotel")
* negation + opinion ("not very good")
* topic + opinion + negation + opinion ("hotel was well-located but not that good")
* 2 topics + negation + opinion ("room and swimming pool weren't always clean")
* ...
```

버전 18.2부터 제공되는 새로운 접근법은 이러한 시퀀스(부정어 + 빈 단어 + 특정 의견)를 "포착"하고, 새 개념에 표시할 단어(표준화된 부정 - "not" - 의견)를 선택한 후 이 새 개념에 대한 유형("유사 용어")을 정의하는 것입니다. 이 새 개념은 TLA 규칙에서 사용할 수 있습니다.

따라서 다음 규칙은 특정 의견 하위 유형(속성, 예상 등)에 관계없이, 의견이 술어(comfortable) 또는 유사 술어(not economical)이든지 간에 주제 뒤에 의견이 오는 시퀀스와 매치됩니다.

```
## Bed was extremely comfortable
[pattern(190)]
name=topic + opinion_190
value=$mTopic ($mEmpty|mToo){0,3} ($mOpinionPos|mOpinionNeg|Contextual)
output(1)=$1wt#1wt$3wt#3
```

TRR을 사용하면 의견의 극성을 변경하는 것 이외에도 사전을 미세 조정하는 데도 도움이 됩니다. 예를 들어 본문 부분이 heart, chest, breast, adrenal gland인 Anatomy이라는 유형이 있고, 절차가 biopsy, needle biopsy, MRI, CT scan인 MedicalProcedures라는 다른 유형이 있다고 가정합니다. 장기와 연관된 모든 의료 절차를 올바르게 나열한다는 것은 불가능합니다. 따라서 다음 그림에 표시된 것과 같이 가능한 의료 절차를 식별하는 두 개의 TRR을 작성할 수 있습니다. 그런 다음 추출이 수행되면 PotentialMedicalProcedures 유형에 대한 필터를 추가하고, 후보 용어를 검토한 후 MedicalProcedures 유형에 이를 추가할 수 있습니다.

그림 2. anatomy + medical procedures에 대한 TRR

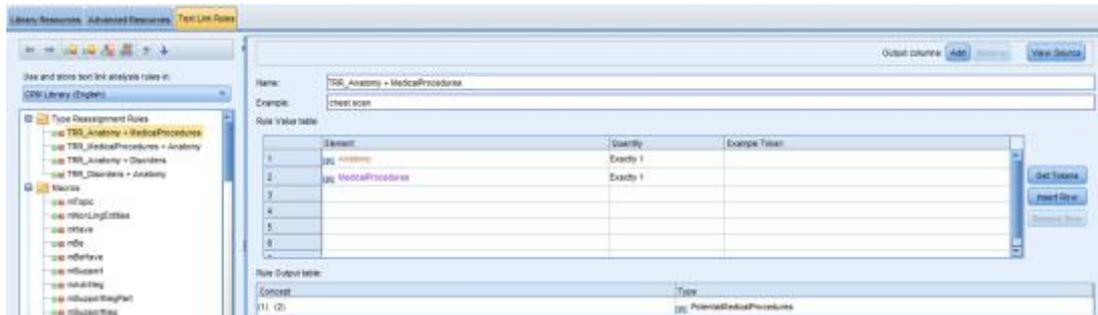
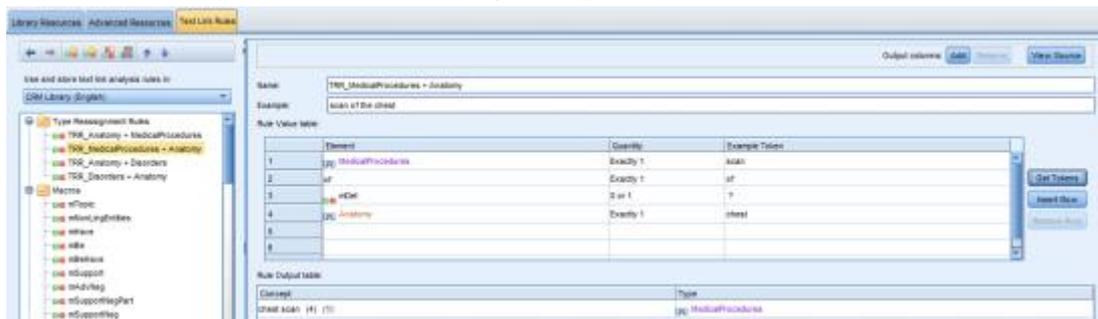


그림 3. medical procedures + anatomy에 대한 TRR



## 구문

```
#@# not that expensive
[typeReassignmentRule]
name=TRR_"not" NegativeBudget
value=$mAllNeg ($mAdverb|$mBel|$mHave|$mSupport|$mDet|that|more|$mQuant){0,3}
$NegativeBudget
output=not $3w#tPositiveBudget
```

- "name"은 고유해야 하며(TRR\_"not" NegativeBudget), 매크로 또는 TLA 규칙에서 사용할 수 없습니다. 출력에 정의된 유형만 사용할 수 있습니다.
- "value"은 매치될 요소의 시퀀스입니다. 요소는 유형(\$NegativeBudget), 매크로(\$mAllNeg) 또는 토큰(more)입니다. 일부 요소는 필수 또는 선택적이거나 특정 수량을 지정할 수 있습니다.

- "output"은 개념+유형(not \$3\wtPositiveBudget)의 단일 쌍입니다. 출력에서 사용 가능한 유형(템플릿에 정의된 유형)을 사용하거나 새 유형을 작성할 수 있습니다.

출력 유형은 매치된 요소(예: #2)를 참조할 수도 있습니다. 이 기능은 값과 출력 간에 유형 변경이 있는 경우에 특히 유용합니다. 예를 들어,

```
#@# could not have been any more pleased
[typeReassignmentRule]
name=TRR_"couldn't be more" opinion
value=$mNotNeg ($mOpinionPos|mOpinionNeg|$Contextual)
output=$2\wt#2
```

TLA 규칙과 마찬가지로, 일반적인 TRR을 정의하기 전에 구체적인 TRR을 정의해야 합니다. 모든 TRR이 올바른 순서로 정의되도록 하기 위해 토큰 가져오기 기능을 사용하여 TRR을 각각 순서대로 테스트할 수 있습니다. TRR이 매치되지 않지만 다른 정의와 매치되는 경우 위 또는 아래로 이동할 수 있습니다.

## 특수 사례

일부 경우 TRR이 아닌 시퀀스의 개별 요소에도 액세스해야 합니다. 이는 일반적으로 부정보다 *등위 접속사*와 관련됩니다. "not that fashionable or eyecatching" 문구에서 등위 접속사 "or"는 검색을 허용하지 않습니다. 따라서 이 컨텍스트에서 "eyecatching"은 실제로 "not eyecatching"을 의미합니다.

이 경우 다음과 같은 특정 규칙을 사용하는 것이 좋습니다.

```
#@# not that fashionable or eyecatching
[pattern(263)]
name="not" + 2 Positive_263
value=($mAdvNeg|mSupportNeg|mMiscNeg) @0,1} $PositiveFeeling or $PositiveFeeling
output(1)=not $3\wtNegativeFeeling
output(2)=not $5\wtNegativeFeeling
```

규칙의 첫 번째 파트((\$mAdvNeg|mSupportNeg|mMiscNeg) @0,1} \$PositiveFeeling)는 TRR과 일치할 수 있지만, TLA 규칙이 우선적으로 적용됩니다.

다음 예와 같은 일반적인 규칙을 작성할 경우 버전 18.1.1 및 이전 버전에서와 동일한 제한사항이 적용됩니다. 작성된 새 개념(유사 개념)에 잘못된 유형(<NegativeFeeling> 대신 <Negative>)이 있으므로, TLA 개념이 서로 다른 두 개의 유형을 사용할 수 있습니다. 임시 해결책은 올바른 유형을 사용하여 해당 용어(xxx 아님)를 작성하는 것입니다.

```
#@# not that fashionable or eyecatching
[pattern(263)]
name="not" + 2 Positive_263
value=($mAdvNeg|mSupportNeg|mMiscNeg) @0,1} $mPos or $mPos
output(1)=not $3\wtNegative
output(2)=not $5\wtNegative
```

## 이점

- TRR 사용의 주요 이점은 TLA 규칙을 덜 사용한다는 것입니다.
- 덜 명확한 이점은 TRR을 사용하면 유사 용어를 통해 대부분 올바른 유형이 지정될 수 있다는 점입니다. 단 앞에서 언급한 바와 같이 제한사항은 있습니다. 과거에는 일부 특정 TLA 규칙이 누락되어 일부 “not + positiveXXX”의 유형이 NegativeXXX 대신 Negative로 지정되었습니다.
- 사용자가 특정 의견 유형(예: NegativeNoise)을 추가할 경우 특정 극성을 되돌리기 위해 TLA 규칙을 복제할 필요가 없습니다. 사용자가 관련 TRR을 작성하기만 하면 됩니다.

## 12. 그래프 시각화

범주 및 개념 보기, 군집 보기, 텍스트 링크 분석 보기에는 모두 창의 오른쪽 상단 모서리에 시각화 분할창이 있습니다. 이 분할창을 사용하여 데이터를 시각적으로 탐색할 수 있습니다. 사용 가능한 그래프 및 차트는 다음과 같습니다.

- **범주 및 개념 보기.** 이 보기에는 세 개의 그래프 및 차트(**범주 막대**, **범주 웹**, **범주 웹 테이블**)가 있습니다. 이 보기에서는 **표시**를 클릭하는 경우에만 그래프가 업데이트됩니다. 자세한 정보는 범주 그래프 및 도표의 내용을 참조하십시오.
- **군집 보기.** 이 보기에는 두 개의 웹 그래프(**개념 웹 그래프**와 **군집 웹 그래프**)가 있습니다. 자세한 정보는 군집 그래프의 내용을 참조하십시오.
- **텍스트 링크 분석 보기.** 이 보기에는 두 개의 그래프(**개념 웹 그래프**와 **유형 웹 그래프**)가 있습니다. 자세한 정보는 텍스트 링크 분석 그래프의 내용을 참조하십시오.

### 1) 범주 그래프 및 도표

범주를 작성할 때 범주 정의, 포함하는 문서 또는 레코드, 범주가 겹치는 방법을 검토하는 것이 중요합니다. 시각화 분할창은 사용자의 범주에 대한 몇몇 퍼스펙티브를 제공합니다. 시각화 분할창은 범주 및 개념 보기 의 오른쪽 상단 구석에 있습니다. 아직 표시되지 않은 경우에는 보기 메뉴(**보기 > 분할창 > 시각화**)에서 이 분할창에 액세스할 수 있습니다.

이 보기에서는 시각화 분할창은 문서 또는 레코드 범주화에서 일반성에 대한 세 개의 퍼스펙티브를 제공합니다. 이 분할창의 차트와 그래프는 범주화 결과를 분석하는 데 사용하고 범주 또는 보고를 세부 조정하는 데 도움을 줄 수 있습니다. 범주를 세분화할 때 이 분할창을 사용하여 범주 정의를 검토하여 너무 유사하거나(예를 들어, 문서 또는 레코드의 75% 이상을 공유함) 너무 다른 범주를 찾아낼 수 있습니다. 두 개의 범주가 너무 유사한 경우에는 두 개의 범주를 결합하기로 결정하는 것이 도움이 될 수 있습니다. 또는 특정 디스크립터를 한 범주 또는 다른 범주에서 제거하여 범주 정의를 세분화하기로 결정할 수도 있습니다.

추출 결과 분할창, 범주 분할창 또는 범주 정의 대화 상자에서 선택된 내용에 따라서 이 분할창의 각 탭에서 문서/레코드 및 범주 간의 해당하는 상호작용을 볼 수 있습니다. 각각은 유사한 정보를 제공하지만 서로 다른 방식으로 보여주거나 세부사항의 수준이 다릅니다. 그러나 현재 선택의 그래프를 새로 고치기 위해서는 선택한 분할창 또는 대화 상자의 도구 모음에서 표시를 클릭하십시오.

범주 및 개념 보기에서 시각화 분할창은 다음 그래프와 도표를 제공합니다.

- **범주 막대형 차트.** 테이블과 막대형 차트는 사용자의 선택 및 연관된 범주에 해당하는 문서/레코드 간의 겹침을 제공합니다. 막대형 차트는 또한 범주에서 문서/레코드 과 문서/레코드 자세한 정보는 범주 막대형 차트의 내용을 참조하십시오.
- **범주 웹 그래프.** 이 그래프는 다른 분할창에서 선택사항에 따라 which the 문서/레코드 이 속하는 범주의 문서/레코드 겹침을 제공합니다. 자세한 정보는 범주 웹 그래프의 내용을 참조하십시오.
- **범주 웹 테이블.** 이 테이블은 범주 웹과 동일한 정보를 테이블 형식으로 제공합니다. 테이블에는 열 헤더를 클릭하면 정렬할 수 있는 세 개의 열을 포함합니다. 자세한 정보는 범주 웹 테이블의 내용을 참조하십시오.

자세한 정보는 텍스트 데이터 범주화의 내용을 참조하십시오.

### (1) 범주 막대형 차트

이 탭은 사용자 선택에 대응하는 문서/레코드와 연관된 범주 사이의 겹침을 표시하는 테이블과 막대형 차트를 표시합니다. 막대형 차트는 또한 문서 또는 레코드 의 총 수에 대한 범주에 있는 문서/레코드 의 비율을 표시합니다. 이 차트의 레이아웃은 편집할 수 없습니다. 그러나 열 헤더를 클릭하여 열을 정렬할 수 있습니다.

차트에는 다음 열이 들어 있습니다.

- **범주.** 이 열은 사용자 선택의 범주 이름을 표시합니다. 기본적으로, 선택에서 가장 일반적인 범주가 처음 나열됩니다.
- **막대.** 이 열은 문서 또는 레코드의 총 수에 대한 주어진 범주에 있는 문서 또는 레코드의 비율을 시각적인 방식으로 표시합니다.
- **선택 %.** 이 열은 선택에서 나타나는 문서 또는 레코드의 총 수에 대한 범주에 대한 문서 또는 레코드의 총 수의 비율을 기반으로 백분율을 표시합니다.
- **문서.** 이 열은 주어진 범주에 대한 선택에서 문서 또는 레코드의 수를 나타냅니다.

## (2) 범주 웹 그래프

이 탭은 범주 웹 그래프를 표시합니다. 웹은 다른 분할창에서의 선택에 따라서 문서 또는 레코드 이 속하는 범주에 대한 문서 또는 레코드 겹침을 표시합니다. 범주 레이블이 있으면 이들 레이블이 그래프에 나타납니다. 이 분할창의 도구 모음 단추를 사용하여 그래프 레이아웃(네트워크, 원형, 지시 또는 눈금)을 선택할 수 있습니다.

웹에서 각 노드는 범주를 나타냅니다. 마우스를 사용하여 분할창 안에서 노드를 선택하고 이동할 수 있습니다. 노드의 크기는 사용자가 선택한 범주에 대한 문서 또는 레코드 수를 바탕으로 하는 상대 크기를 나타냅니다. 두 범주 사이의 선의 두께와 색상이 범주가 갖는 공통 문서 또는 레코드의 수를 나타냅니다. 탐색 모드에서 마우스를 노드 위에서 움직이면 도구팁이 범주의 이름(또는 레이블) 및 범주에 있는 문서 또는 레코드의 전체 수를 표시합니다.

**참고:** 기본적으로 탐색 모드는 노드를 이동할 수 있는 그래프에서 사용 가능합니다. 그러나 편집 모드로 전환하여 색상, 글꼴, 범례 등을 포함한 그래프 레이아웃을 편집할 수 있습니다. 추가 정보는 그래프 도구 모음 및 팔레트 사용의 내용을 참조하십시오.

시각화 데이터 복사 단추를 사용하여 스프레드시트 또는 텍스트 편집기에 붙여넣는 방법으로 그래프 데이터를 복사하는 경우, 데이터에 V1, V2에서 V7까지 열 헤더가 있는 것을 볼 수 있습니다. 이러한 열은 다음 정보를 포함합니다.

- V1, V2 이러한 값은 화면 좌표(각각 X 및 Y)에 해당됩니다.
- V3, V5 범주 개념을 나열합니다.
- 크기, V6 개념이 발견된 문서의 수를 표시합니다.
- V7 현재 사용되지 않습니다.

## (3) 범주 웹 테이블

이 탭은 범주 웹 탭과 동일한 정보를 테이블 형식으로 표시합니다. 테이블에는 열 헤더를 클릭하여 정렬할 수 있는 세 개의 열이 들어 있습니다.

- 개수. 이 열은 두 범주 사이의 공유 또는 공통 문서 또는 레코드의 수를 표시합니다.
- 범주 1. 이 열은 첫 번째 범주의 이름과 소괄호 안에 표시된 범주의 문서 또는 레코드의 총 수를 표시합니다.
- 범주 2. 이 열은 두 번째 범주의 이름과 소괄호 안에 표시된 범주의 문서 또는 레코드의 총 수를 표시합니다.

## (4) 오류 수정

가끔 시각화를 렌더링할 수 없는 경우가 있습니다. 이 경우에는 시각화를 렌더링할 수 없음 대화 상자가 표시됩니다.

오류가 발생하기 전의 시각화 상태로 되돌아가려면 **실행 취소**를 클릭하십시오. 또는 오류에도 불구하고 계속 진행하려면 **계속**을 클릭할 수도 있습니다. 계속을 클릭하면 문제점이 수정될 때까지 시각화가 표시되지 않습니다.

## 2) 군집 그래프

군집을 작성한 후에는 시각화 분할창의 웹 그래프에서 시각적으로 탐색할 수 있습니다. 시각화 분할창은 군집화에 대한 두 개의 퍼스펙티브 즉, 개념 웹 그래프와 군집 웹 그래프를 제공합니다. 이 분할창의 웹 그래프를 사용하여 군집 결과를 분석하고 범주에 추가할 일부 개념과 규칙 발견 시 도움을 받을 수 있습니다. 시각화 분할창은 군집 보기의 오른쪽 상단 모서리에 있습니다. 아직 표시되지 않으면 보기 메뉴에서 이 분할창에 액세스할 수 있습니다(**보기 > 분할창 > 시각화**). 군집 분할창에서 군집을 선택하여 시각화 분할창에 해당 그래프를 자동으로 표시할 수 있습니다.

**참고:** 기본적으로 그래프는 노드를 이동할 수 있는 대화형/선택 모드에 있습니다. 그러나 편집 모드에서 색상과 글꼴, 범례 등을 포함하여 그래프 레이아웃을 편집할 수 있습니다. 자세한 정보는 그래프 도구 모음 및 팔레트 사용의 내용을 참조하십시오.

군집 보기에는 두 개의 웹 그래프가 있습니다.

- **개념 웹 그래프.** 이 그래프는 선택된 군집 내의 모든 개념은 물론 군집 외부의 링크된 개념도 제공합니다. 이 그래프를 통해 군집 내의 개념이 링크되는 방법과 외부 링크를 볼 수 있습니다. 자세한 정보는 개념 웹 그래프의 내용을 참조하십시오.
- **군집 웹 그래프.** 이 그래프는 점선으로 표시된 선택된 군집 간의 모든 외부 링크가 있는 선택된 군집을 제공합니다. 자세한 정보는 군집 웹 그래프의 내용을 참조하십시오.

자세한 정보는 군집 분석의 내용을 참조하십시오.

### (1) 개념 웹 그래프

이 탭은 선택된 군집 내의 개념은 물론 군집 외부의 링크된 개념도 모두 표시합니다. 이 그래프를 통해 군집 내의 개념이 링크되는 방법과 외부 링크를 볼 수 있습니다. 군집의 각 개념은 노드로 표시되며 유형 색상에 따라 색상 코드화됩니다. 자세한 정보는 유형 작성의 내용을 참조하십시오.

군집 내 개념 간의 내부 링크가 그려지며 각 링크의 선 굵기는 그래프 도구 모음에서의 선택사항에 따라 각 개념 쌍의 동시 발생에 대한 문서 개수 또는 유사성 링크 값과 직접 관련됩니다. 군집의 개념과 군집 외부의 해당 개념 간의 외부 링크도 표시됩니다.

군집 정의 대화 상자에서 개념을 선택하면 개념 웹 그래프가 해당 개념 및 해당 개념과 연관된 내부 및 외부 링크를 표시합니다. 선택된 개념 중 하나를 포함하지 않는 다른 개념 간의 링크는 그래프에 나타나지 않습니다.

**참고:** 기본적으로 그래프는 노드를 이동할 수 있는 대화형/선택 모드에 있습니다. 그러나 편집 모드에서 색상과 글꼴, 범례 등을 포함하여 그래프 레이아웃을 편집할 수 있습니다. 추가 정보는 그래프 도구 모음 및 팔레트 사용의 내용을 참조하십시오.

**시각화 데이터 복사** 단추를 사용하여 스프레드시트 또는 텍스트 편집기에 붙여넣는 방법으로 그래프 데이터를 복사하는 경우, 데이터에 V1, V2에서 V7까지 열 헤더가 있는 것을 볼 수 있습니다. 이러한 열은 다음 정보를 포함합니다.

- V1, V2 이러한 값은 화면 좌표(각각 X 및 Y)에 해당됩니다.
- V3, V6 개념 유형을 나열합니다.
- V4, V5 개념 레이블을 표시합니다.
- V7 현재 사용되지 않습니다.

## (2) 군집 웹 그래프

이 탭은 선택된 군집을 보여주는 웹 그래프를 표시합니다. 선택된 군집 간의 외부 링크는 물론 다른 군집 간의 링크도 모두 점선으로 표시됩니다. 군집 웹 그래프에서 각 노드는 전체 군집을 나타내며 이들 사이에 그려진 선 굵기는 두 군집 간의 외부 링크 수를 나타냅니다.

**중요!** 군집 웹 그래프를 표시하려면 외부 링크가 있는 군집을 이미 작성했어야 합니다. 외부 링크는 별도 군집의 개념 쌍(한 군집 내 개념과 다른 군집에서 외부의 개념) 간의 링크입니다.

예를 들어, 두 개의 군집이 있습니다. Cluster A에는 세 개의 개념(A1, A2, A3)이 있습니다. Cluster B에는 두 개의 개념(B1, B2)이 있습니다. 다음 개념이 링크됩니다. A1-A2, A1-A3, A2-B1(외부), A2-B2(외부), A1-B2(외부), B1-B2. 이는 군집 웹 그래프에서 선 굵기가 세 개의 외부 링크를 나타냄을 의미합니다.

**참고:** 기본적으로 그래프는 노드를 이동할 수 있는 대화형/선택 모드에 있습니다. 그러나 편집 모드에서 색상과 글꼴, 범례 등을 포함하여 그래프 레이아웃을 편집할 수 있습니다. 자세한 정보는 그래프 도구 모음 및 팔레트 사용의 내용을 참조하십시오.

## 3) 텍스트 링크 분석 그래프

텍스트 링크 분석(TLA) 패턴을 추출한 후에는 시각화 분할창의 웹 그래프에서 시각적으로 탐색할 수 있습니다. 시각화 분할창은 TLA에 대한 두 개의 퍼스펙티브 즉, 개념 (패턴) 웹 그래프와

유형 (패턴) 웹 그래프를 제공합니다. 이 분할창의 웹 그래프를 사용하여 패턴을 시각적으로 표시할 수 있습니다. 시각화 분할창은 텍스트 링크 분석의 오른쪽 상단 모서리에 있습니다. 아직 표시되지 않으면 보기 메뉴에서 이 분할창에 액세스할 수 있습니다([보기 > 분할창 > 시각화](#)). 선택사항이 없으면 그래프 영역이 비어 있습니다.

참고: 기본적으로 그래프는 노드를 이동할 수 있는 대화형/선택 모드에 있습니다. 그러나 편집 모드에서 색상과 글꼴, 범례 등을 포함하여 그래프 레이아웃을 편집할 수 있습니다. 자세한 정보는 그래프 도구 모음 및 팔레트 사용의 내용을 참조하십시오.

텍스트 링크 분석 보기에는 두 개의 웹 그래프가 있습니다.

- **개념 웹 그래프.** 이 그래프는 선택된 패턴의 모든 개념을 제공합니다. 개념 그래프에서 선 굵기와 노드 크기(유형 아이콘이 표시되지 않은 경우)는 선택된 테이블에서 글로벌 발생 수를 표시합니다. 자세한 정보는 개념 웹 그래프의 내용을 참조하십시오.
- **유형 웹 그래프.** 이 그래프는 선택된 패턴의 모든 유형을 제공합니다. 그래프에서 선 굵기와 노드 크기(유형 아이콘이 표시되지 않은 경우)는 선택된 테이블에서 글로벌 발생 수를 표시합니다. 노드는 유형 색상 또는 아이콘으로 표시됩니다. 자세한 정보는 유형 웹 그래프의 내용을 참조하십시오.

자세한 정보는 텍스트 링크 분석 탐색의 내용을 참조하십시오.

### (1) 개념 웹 그래프

이 웹 그래프는 현재 선택에 표시된 모든 개념을 제공합니다. 예를 들어, 세 개의 매치하는 개념 패턴이 있는 유형 패턴을 선택한 경우 이 그래프는 세 세트의 링크된 개념을 표시합니다. 개념 그래프에서 선 굵기와 노드 크기는 글로벌 빈도 수를 표시합니다. 그래프는 패턴 분할창에서 선택된 것과 동일한 정보를 시각적으로 표시합니다. 각 개념의 유형은 그래프 도구 모음에서의 선택사항에 따라 색상 또는 아이콘으로 제공됩니다. 자세한 정보는 그래프 도구 모음 및 팔레트 사용의 내용을 참조하십시오.

### (2) 유형 웹 그래프

이 웹 그래프는 현재 선택에 대한 각 유형 패턴을 제공합니다. 예를 들어, 두 개의 개념 패턴을 선택한 경우 이 그래프는 선택된 패턴의 유형별 하나의 노드와 동일한 패턴에서 찾은 개념 간의 링크를 표시합니다. 선 굵기와 노드 크기는 세트의 글로벌 빈도 수를 표시합니다. 그래프는 패턴 분할창에서 선택된 것과 동일한 정보를 시각적으로 표시합니다. 그래프에 나타나는 유형 이름 이외에 유형은 그래프 도구 모음에서의 선택사항에 따라 해당 색상 또는 유형 아이콘으로도 식별됩니다. 자세한 정보는 그래프 도구 모음 및 팔레트 사용의 내용을 참조하십시오.

#### 4) 그래프 도구 모음 및 팔레트 사용

각 그래프에 대해, 그래프를 사용하여 많은 조치를 수행할 수 있는 몇 가지 공통 팔레트에 대한 빠른 액세스를 제공하는 도구 모음이 있습니다. 각 보기(범주 및 개념, 군집, 텍스트 링크 분석)는 약간 다른 도구 모음을 갖고 있습니다. *탐색* 보기 모드와 *편집* 보기 모드 사이에서 선택할 수 있습니다.

탐색 모드에서는 시각화로 표시되는 데이터 및 값을 분석적으로 탐색할 수 있는 반면, 편집 모드에서는 시각화의 레이아웃 및 모양을 변경할 수 있습니다. 예를 들어, 조직의 스타일 가이드에 맞게 글꼴 및 색상을 변경할 수 있습니다. 이 모드를 선택하려면 메뉴에서 **보기 > 시각화 분할창 > 편집 모드**를 선택하십시오(또는 도구 모음 아이콘을 클릭).

편집 모드에서는 시각화 레이아웃의 다양한 측면에 영향을 주는 여러 도구 모음이 제공됩니다. 사용하지 않는 도구 모음이 있는 경우 이러한 도구 모음을 숨겨 대화 상자에서 그래프가 표시되는 공간을 늘릴 수 있습니다. 도구 모음을 선택 또는 선택 취소하려면 보기 메뉴에서 관련 도구 모음이나 팔레트 이름을 클릭하십시오.

표 1. 텍스트 분석 도구 모음 단추

단추/목록	설명
	편집 모드를 활성화합니다. 글꼴을 확대하거나 기업 스타일 가이드와 매치하도록 색상을 변경하거나 레이블 및 범례를 제거하는 등 그래프의 모양을 변경하려면 편집 모드로 전환하십시오.
	탐색 모드를 활성화합니다. 기본적으로 탐색 모드가 켜지는데, 이것은 노드를 그래프 주위로 이동하고 끌고갈 수 있으며 그래프 오브젝트 위에서 움직여서 추가 도구 팁 정보를 볼 수 있음을 의미합니다.
	범주 및 개념 보기뿐 아니라 텍스트 링크 분석 보기에서 그래프에 대한 웹 표시의 유형을 선택하십시오. <ul style="list-style-type: none"> <li>- <b>원 레이아웃</b> 임의의 그래프에 적용할 수 있는 일반 레이아웃입니다. 링크가 방향이 지정되지 않고 모든 노드를 동일하게 취급한다고 가정하고 그래프를 배치합니다. 노드는 원의 주변에만 배치됩니다.</li> <li>- <b>네트워크 레이아웃</b> 임의의 그래프에 적용할 수 있는 일반 레이아웃입니다. 링크가 방향이 지정되지 않고 모든 노드를 동일하게 취급한다고 가정하고 그래프를 배치합니다. 노드는 레이아웃 안에서 자유롭게 배치됩니다.</li> <li>- <b>방향이 있는 레이아웃</b> 방향이 있는 그래프에만 사용해야 하는 레이아웃입니다. 이 레이아웃은 루트 노드에서 리프 노드를 향하는 트리형 구조를 생성하며 색상으로 구성됩니다. 계층 구조 데이터는 이 레이아웃으로 잘 표시되는 경향이 있습니다.</li> <li>- <b>눈금 레이아웃</b> 임의의 그래프에 적용할 수 있는 일반 레이아웃입니다. 링크가 방향이 지정되지 않고 모든 노드를 동일하게 취급한다고 가정하고 그래프를 배치합니다. 노드는 공간 내의 격자점에만 배치됩니다.</li> </ul>

단추/목록	설명
	<p>링크 크기 표시입니다. 그래프에서 선의 두께가 표시하는 것을 선택하십시오. 이것은 군집 보기에만 적용됩니다. 군집 웹 그래프는 군집 사이의 외부 링크 수만 표시합니다. 다음 중에서 선택할 수 있습니다.</p> <ul style="list-style-type: none"> <li>- 유사성 두께는 두 군집 사이의 외부 링크 수를 표시합니다.</li> <li>- 동시 발생 두께가 디스크립터의 동시 발생이 발생하는 문서 수를 표시합니다.</li> </ul>
	<p>누르면 범례를 표시하는 전환 단추입니다. 이 단추를 누르지 않으면 범례가 표시되지 않습니다.</p>
	<p>누르면 그래프에 유형 색상이 아니라 유형 아이콘을 표시하는 전환 단추입니다. 이것은 텍스트 링크 분석 보기에만 적용됩니다.</p>
	<p>누르면 그래프 아래에 링크 슬라이더를 표시하는 전환 단추입니다. 화살표를 밀어서 결과를 필터링할 수 있습니다.</p>
	<p>하위 범주가 아니라 선택된 범주의 최상위 레벨에 대한 그래프를 표시합니다.</p>
	<p>선택된 범주의 최하위 레벨에 대한 그래프를 표시합니다.</p>
	<p>이 옵션은 하위 범주의 이름이 출력에 표시되는 방법을 제어합니다.</p> <ul style="list-style-type: none"> <li>- 전체 범주 경로 이 옵션은 적용 가능한 경우 슬래시를 사용하여 범주 이름을 하위 범주 이름과 구분하여 범주의 이름 및 상위 범주의 전체 경로를 출력합니다.</li> <li>- 짧은 범주 경로 이 옵션은 범주의 이름만 출력하지만 생략 기호를 사용하여 문제가 되는 범주에 대한 상위 범주의 수를 표시합니다.</li> <li>- 최하위 레벨 범주 이 옵션은 전체 경로 또는 상위 범주가 표시되지 않으면서 범주의 이름만 출력합니다.</li> </ul>

### 13. 세션 자원 편집기

IBM® SPSS® Modeler Text Analytics는 텍스트 데이터에서 주요 개념을 신속하고 정확하게 캡처하고 추출합니다. 이 추출 프로세스는 주로 언어학적 자원에 의존하여 텍스트 데이터에서 정보를 추출하는 방법을 지시합니다. 기본적으로 이러한 자원은 자원 템플릿에서 비롯됩니다.

IBM SPSS Modeler Text Analytics는 데이터 처리 및 추출 방법을 쉽게 정의할 수 있도록 라이브러리 및 고급 자원 양식으로 언어 및 비언어학적 자원 세트를 포함하는 **자원 템플릿 세트**와 함께 제공됩니다. 자세한 정보는 템플릿 및 자원의 내용을 참조하십시오.

노드 대화 상자에서 템플리트의 자원 사본을 노드에 로드할 수 있습니다. 대화형 워크벤치 세션 안에 있으면 원할 경우 이 노드의 데이터에 대해 특별히 이러한 자원을 사용자 정의할 수 있습니다. 대화형 워크벤치 세션 동안 자원 편집기 보기에서 자원에 대한 작업을 할 수 있습니다. 대화형 세션이 실행될 때마다, 노드에 데이터 및 추출 결과를 캐시하지 않았으면 노드 대화 상자에 로드된 자원을 사용하여 추출이 수행됩니다.

## 1) 자원 편집기에서 자원 편집

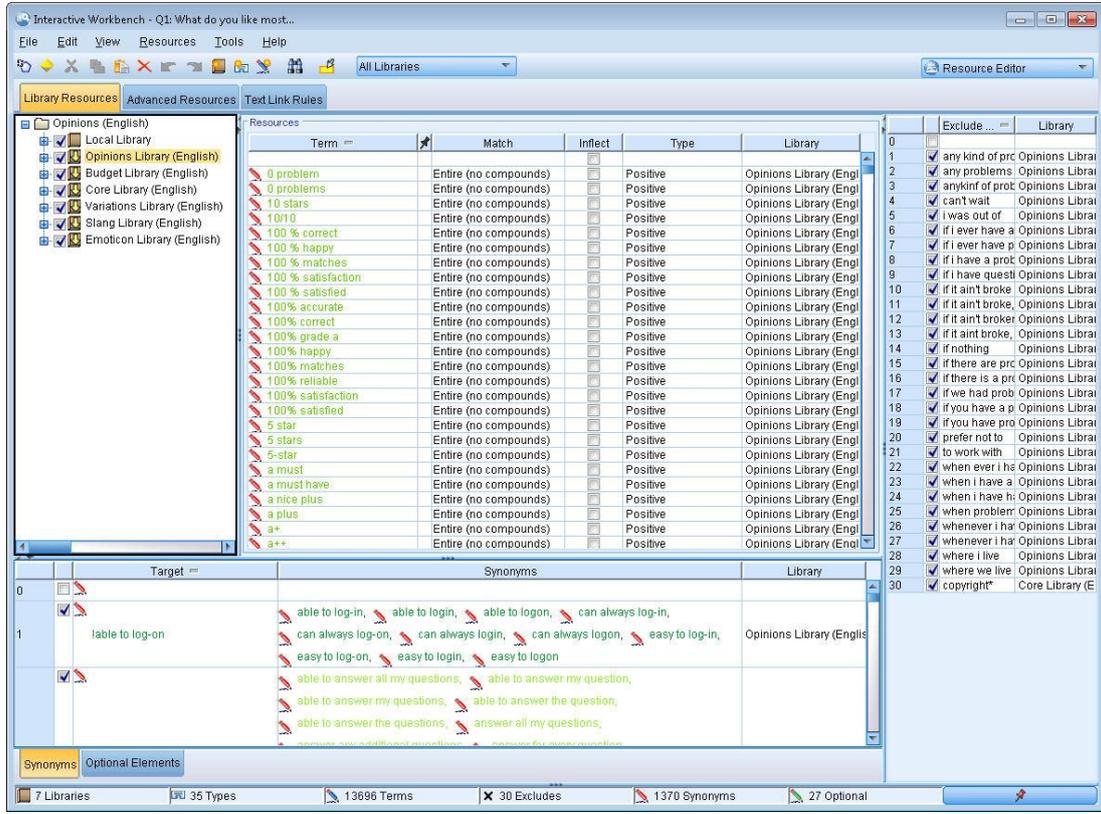
자원 편집기는 대화형 워크벤치 세션에 대한 추출 결과(개념, 유형, 패턴)를 생성하는 데 사용되는 자원 세트에 대한 액세스를 제공합니다. 자원 편집기에서는 이 세션에 대한 자원을 편집한다는 점을 제외하고 이 편집기는 템플리트 편집기와 매우 유사합니다. 자원 및 완료한 다른 작업에 대한 작업을 완료했으면 모델링 노드를 업데이트하여 후속 대화형 워크벤치 세션에서 복원할 수 있도록 이 작업을 저장할 수 있습니다. 자세한 정보는 모델링 노드 업데이트 및 저장의 내용을 참조하십시오.

노드에 자원을 로드하는 데 사용되는 템플리트에 대해 직접 작업하려면 템플리트 편집기를 사용하는 것이 좋습니다. 자원 편집기에서 수행할 수 있는 많은 태스크가 템플리트 편집기에서와 마찬가지로 수행되는데, 다음과 같습니다.

- 라이브러리에 대한 작업. 자세한 정보는 라이브러리에 대한 작업의 내용을 참조하십시오.
- 유형 사전 작성. 자세한 정보는 유형 작성의 내용을 참조하십시오.
- 사전에 용어 추가. 자세한 정보는 용어 추가의 내용을 참조하십시오.
- 동의어 작성. 자세한 정보는 동의어 정의의 내용을 참조하십시오.
- 템플리트 가져오기 및 내보내기. 자세한 정보는 템플리트 가져오기 및 내보내기의 내용을 참조하십시오.
- 라이브러리 출판. 자세한 정보는 라이브러리 출판의 내용을 참조하십시오.

네덜란드어, 영어, 프랑스어, 독일어, 이탈리아어, 포르투갈어 및 스페인어 텍스트의 경우

그림 1. 자원 편집기 보기



## 2) 템플릿 작성 및 업데이트

자원을 변경하고 나중에 재사용하기 원할 때마다 자원을 템플릿으로 저장할 수 있습니다. 그렇게 할 때 기존 템플릿 이름을 사용하거나 새 이름을 제공하여 저장할 것을 선택할 수 있습니다. 그러면, 나중에 이 템플릿을 로드할 때마다 동일한 자원을 얻을 수 있습니다. 자세한 정보는 템플릿 및 TAP에서 자원 복사 주제를 참조하십시오.

**참고:** 라이브러리를 출판하고 공유할 수도 있습니다. 자세한 정보는 라이브러리 공유의 내용을 참조하십시오.

템플릿을 작성(또는 업데이트)하려면 다음을 수행하십시오.

1. 자원 편집기 보기의 메뉴에서 **자원 > 자원 템플릿 작성**을 선택하십시오. 자원 템플릿 작성 대화 상자가 열립니다.
2. 새 템플릿을 작성하려는 경우 템플릿 이름 필드에 새 이름을 입력하십시오. 기존 템플릿을 현재 로드된 자원으로 덮어쓰려면 테이블에서 템플릿을 선택하십시오.
3. 템플릿을 작성하려면 **저장**을 클릭하십시오.

**중요!** 템플리트는 노드에서 선택할 때 로드되고 스트림이 실행될 때는 로드되지 않으므로, 최신 변경사항을 얻으려는 경우 템플리트가 사용되는 다른 모든 노드에서 자원 템플리트를 다시 로드하십시오. 자세한 정보는 로드 후 노드 자원 업데이트의 내용을 참조하십시오.

### 3) 자원 템플리트 전환

세션에 있는 현재 로드된 자원을 다른 템플리트의 자원 사본으로 바꾸려는 경우 해당 자원으로 전환할 수 있습니다. 그렇게 하면 세션에서 현재 로드된 모든 자원을 덮어씁니다. 몇 가지 사전 정의된 텍스트 링크 분석(TLA) 패턴 규칙을 갖기 위해 자원을 전환하려는 경우, 반드시 TLA 열에서 표시된 템플리트를 선택하십시오.

자원 전환은 특히 세션 작업(범주, 패턴, 자원)을 복원하지만 다른 세션 작업을 잃지 않고 템플리트로부터 자원의 업데이트된 사본을 로드하려는 경우에 유용합니다. 내용을 자원 편집기에 복사하려는 템플리트를 선택하고 **확인**을 클릭할 수 있습니다. 그러면 이 세션에서 갖고 있는 자원이 대체됩니다. 다음에 대화형 워크bench 세션을 시작할 때 이들 변경을 보존하려는 경우 세션 종료 시에 모델링 노드를 업데이트하십시오.

 **참고:** 대화형 세션 동안 다른 템플리트의 콘텐츠로 전환하면 노드에 나열된 템플리트의 이름이 여전히 로드 및 복사된 마지막 템플리트의 이름이 됩니다. 이들 자원이나 다른 세션 작업을 활용하기 위해서, 세션을 종료하기 전에 모델링 노드를 업데이트하고 노드에서 **세션 작업 사용** 옵션을 선택하십시오. 자세한 정보는 모델링 노드 업데이트 및 저장의 내용을 참조하십시오.

### 자원 전환 방법

1. 자원 편집기 보기의 메뉴에서 **자원 > 자원 템플리트 전환**을 선택하십시오. 자원 전환 대화 상자가 열립니다.
2. 테이블에 표시된 템플리트에서 사용할 템플리트를 선택하십시오.
3. **확인**을 클릭하여 현재 로드된 자원을 중단하고 그 자리에 선택된 템플리트에 있는 자원의 사본을 로드하십시오. 자원을 변경했고 나중에 사용하기 위해 라이브러리를 저장하려는 경우, 전환하기 전에 자원을 출판, 업데이트 및 공유할 수 있습니다. 자세한 정보는 라이브러리 공유의 내용을 참조하십시오.

## 14. 템플릿 및 자원

IBM® SPSS® Modeler Text Analytics 는 텍스트 데이터에서 주요 개념을 신속하고 정확하게 캡처하고 추출합니다. 이 추출 프로세스는 주로 언어학적 자원에 의존하여 텍스트 데이터에서 정보를 추출하는 방법을 지시합니다. 자세한 정보는 추출 작동 방법의 내용을 참조하십시오. 자원 편집기 보기에서 이러한 자원을 미세 조정할 수 있습니다.

소프트웨어를 설치하면 특수 자원 세트도 얻게 됩니다. 이렇게 제공된 자원을 사용하여 특정 언어 및 특정 애플리케이션에 대한 수년 간의 연구 및 미세 조정을 통해 도움을 받을 수 있습니다. 제공된 자원이 항상 데이터 컨텍스트에 맞게 완벽하게 조정된 것은 아니므로 이러한 자원 템플릿을 편집하거나 조직의 데이터에 맞게 고유하게 미세 조정된 사용자 정의 라이브러리를 작성하여 사용할 수 있습니다. 이러한 자원은 다양한 양식으로 제공되며 각각 세션에서 사용할 수 있습니다. 다음 위치에서 자원을 찾을 수 있습니다.

- **자원 템플릿.** 템플릿은 특정 도메인이나 컨텍스트(예: 제품 의견)에 맞게 조정된 특수 자원 세트를 함께 형성하는 일부 고급 자원, 라이브러리, 유형 세트로 구성됩니다.
- **텍스트 분석 패키지(TAP).** 템플릿에 저장된 자원 이외에 TAP도 해당 자원을 사용하여 생성된 하나 이상의 특수 범주 세트를 함께 번들화하므로 범주와 자원 모두 함께 저장되고 재사용 가능합니다. 자세한 정보는 텍스트 분석 패키지 사용의 내용을 참조하십시오.
- **라이브러리.** 라이브러리는 TAP과 템플릿 모두에 구성 요소로 사용됩니다. 세션 에서 사용할 수 있습니다. 각 라이브러리는 유형, 동의어, 제외 목록을 정의하고 관리하는 데 사용되는 몇 개의 사전으로 구성됩니다. 라이브러리는 개별적으로도 제공되지만 템플릿과 TAP에서는 함께 패키징됩니다. 자세한 정보는 라이브러리에 대한 작업의 내용을 참조하십시오.

**참고:** 추출 중에는 컴파일된 일부 내부 자원도 사용됩니다. 컴파일된 이러한 자원은 코어 라이브러리의 유형을 보완하는 상당수의 정의를 포함합니다. 컴파일된 이러한 자원은 편집할 수 없습니다.

자원 편집기는 추출 결과(개념, 유형, 패턴)를 생성하는 데 사용되는 자원 세트에 대한 액세스를 제공합니다. 자원 편집기에서 수행할 수 있는 다수의 태스크가 있으며 다음과 같습니다.

- **라이브러리에 대한 작업.** 자세한 정보는 라이브러리에 대한 작업의 내용을 참조하십시오.
- **유형 사전 작성.** 자세한 정보는 유형 작성의 내용을 참조하십시오.
- **사전에 용어 추가.** 자세한 정보는 용어 추가의 내용을 참조하십시오.
- **동의어 작성.** 자세한 정보는 동의어 정의의 내용을 참조하십시오.
- **TAP의 자원 업데이트.** 자세한 정보는 텍스트 분석 패키지 업데이트의 내용을 참조하십시오.
- **템플릿 작성.** 자세한 정보는 템플릿 작성 및 업데이트의 내용을 참조하십시오.
- **템플릿 가져오기 및 내보내기.** 자세한 정보는 템플릿 가져오기 및 내보내기의 내용을 참조하십시오.
- **라이브러리 출판.** 자세한 정보는 라이브러리 출판의 내용을 참조하십시오.

## 1) 템플리트 편집기 vs. 자원 편집기

템플리트, 라이브러리 및 해당 자원에 대한 작업과 편집을 위한 두 가지 주요 방법이 있습니다. 템플리트 편집기 또는 자원 편집기에서 언어학적 자원에 대해 작업할 수 있습니다.

### 템플리트 편집기

템플리트 편집기를 사용하면 대화형 워크벤치 세션 없이 특정 노드 또는 스트림과 관계없이 자원 템플리트를 작성하고 편집할 수 있습니다. 이 편집기를 사용하여 텍스트 링크 분석 노드 및 텍스트 마이닝 모델링 노드에 로드하기 전에 자원 템플리트를 작성하거나 편집할 수 있습니다.

도구 > 텍스트 분석 템플리트 편집기 메뉴에서 기본 IBM® SPSS® Modeler 도구 모음을 통해 템플리트 편집기에 액세스할 수 있습니다.

### 자원 편집기

대화형 워크벤치 세션에서 액세스 가능한 자원 편집기를 사용하면 특정 노드 및 데이터 세트의 컨텍스트에서 자원에 대한 작업을 할 수 있습니다. 스트림에 텍스트 마이닝 모델링 노드를 추가할 때 자원 템플리트의 콘텐츠 사본 또는 텍스트 분석 패키지 사본(범주 세트 및 자원)을 로드하여 텍스트 마이닝을 위한 텍스트 추출 방법을 제어할 수 있습니다. 대화형 워크벤치 세션을 실행할 때 범주 작성, 텍스트 링크 분석 패턴 추출, 범주 모델 작성 이외에 통합된 자원 편집기 보기에서 해당 세션의 데이터에 대한 자원을 미세 조정할 수도 있습니다. 자세한 정보는 자원 편집기에서 자원 편집의 내용을 참조하십시오.

대화형 워크벤치 세션에서 자원에 대한 작업을 할 때마다 해당 변경사항은 해당 세션에만 적용됩니다. 후속 세션에서 계속할 수 있도록 작업(자원, 범주, 패턴 등)을 저장하려면 모델링 노드를 업데이트해야 합니다. 자세한 정보는 모델링 노드 업데이트 및 저장의 내용을 참조하십시오.

업데이트된 이 템플리트를 다른 노드에 로드할 수 있도록 변경사항을 콘텐츠가 모델링 노드에 복사된 원래 템플리트에 다시 저장하려면 자원으로부터 템플리트를 작성할 수 있습니다. 자세한 정보는 템플리트 작성 및 업데이트의 내용을 참조하십시오.

**참고:** 템플리트 또는 라이브러리를 변경하고 백업 디렉토리에 저장한 후 IBM SPSS Modeler Text Analytics의 버전을 업그레이드하면 사용자 정의 템플리트와 라이브러리를 가져올 수 있는 옵션이 제공됩니다. 업그레이드 후 SPSS Modeler Text Analytics 스트림을 처음으로 실행하거나 자원 편집기를 열면 기본 템플리트와 라이브러리가 시스템으로 복사됩니다. 제품 업그레이드의 일부로 업데이트된 템플리트 및/또는 라이브러리 목록과 함께 저장된 템플리트 경고 또는 저장된 라이브러리 경고(또는 두 경고 모두)가 표시되며,

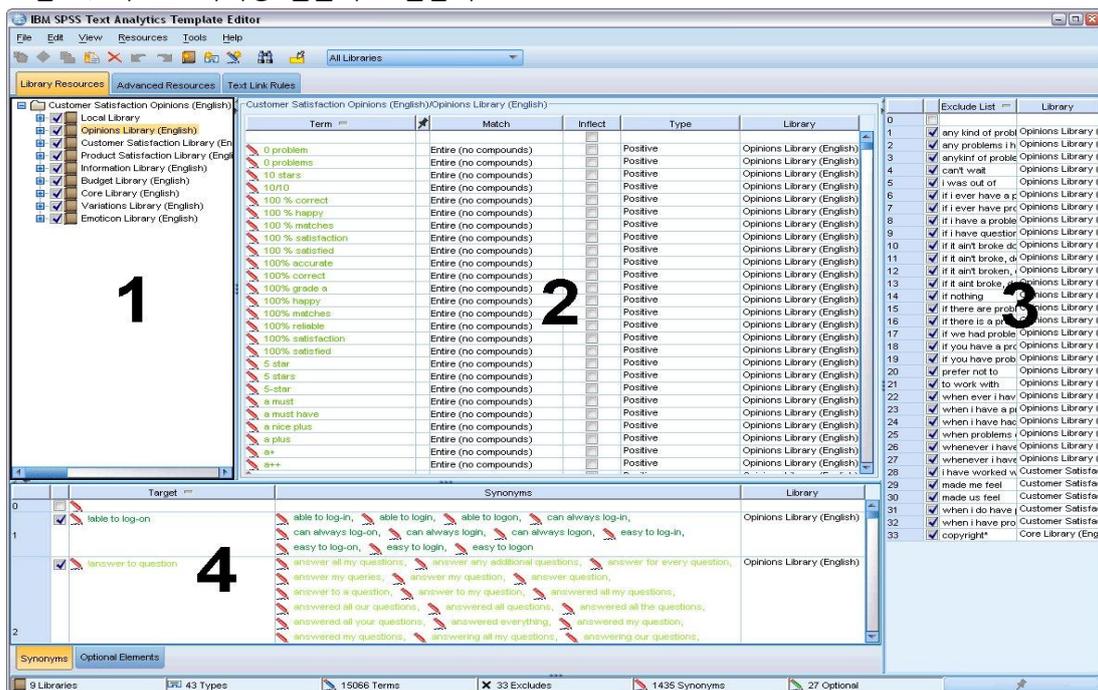
이들을 저장한 디렉토리에서 사용자 정의 템플릿과 라이브러리를 가져올 수 있는 옵션이 제공됩니다. 경고 메시지에서 확인을 클릭하면 언제든지 **자원 템플릿 관리** 대화 상자 또는 **라이브러리 관리** 대화 상자를 열어 가져올 사용자 정의 템플릿과 라이브러리를 선택할 수 있습니다.

## 2) 편집기 인터페이스

템플릿 편집기 또는 자원 편집기에서 수행하는 작업은 언어학적 자원 관리 및 미세 조정을 중심으로 돌아갑니다. 이러한 자원은 템플릿 및 라이브러리 양식으로 저장됩니다. 자세한 정보는 유형 사전의 내용을 참조하십시오.

라이브러리 자원 탭

그림 1. 텍스트 마이닝 템플릿 편집기



인터페이스는 다음과 같이 네 개의 파트로 구성됩니다.

**1. 라이브러리 트리 분할창.** 왼쪽 상단 구석에 있는 이 계획은 라이브러리의 트리를 표시합니다. 이 트리에서 라이브러리를 사용 및 사용 안함으로 설정하고 트리에서 라이브러리를 선택하여 다른 분할창에서 보기를 필터링할 수 있습니다. 컨텍스트 메뉴를 사용하여 이 트리에서 여러 작업을 수행할 수 있습니다. 트리에서 라이브러리를 펼치면 포함된 유형 세트를 볼 수 있습니다. 특정 라이브러리에만 초점을 맞추고 싶으면 **보기** 메뉴를 통해 이 목록을 필터링할 수도 있습니다.

2. **유형 사전 분할창의 용어 목록.** 라이브러리 트리의 오른쪽에 있는 이 분할창은 트리에서 선택된 라이브러리의 유형 사건의 용어 목록을 표시합니다. **유형 사전**은 하나의 레이블 또는 유형, 이름 아래에 그룹화될 유형 컬렉션입니다. 추출 엔진은 텍스트 데이터를 읽고 텍스트에서 찾은 단어를 유형 사건의 용어와 비교합니다. 추출된 개념이 유형 사전에 용어로 나타나 있는 경우에는 해당 유형 이름이 지정됩니다. 유형 사전을 공통점이 있는 개별 용어 사전으로 간주할 수 있습니다. 예를 들어, 코어 라이브러리의 <Location> 유형에는 new orleans, great britain 및 new york 등과 같은 개념이 포함됩니다. 이러한 용어는 모두 지리적 위치를 나타냅니다. 라이브러리에는 하나 이상의 유형 사전을 포함할 수 있습니다. 자세한 정보는 유형 사건의 내용을 참조하십시오.

3. **제외 사전 분할창.** 오른쪽에 있는 이 분할창은 최종 추출 결과에서 제외될 용어 컬렉션을 표시합니다. 이 제외 사전에 나타나는 용어는 추출 결과 분할창에 나타나지 않습니다. 제외된 용어는 선택하는 라이브러리에 저장될 수 있습니다. 그러나, 제외 사전 분할창은 라이브러리 트리에 표시 가능한 모든 라이브러리의 제외된 용어를 모두 표시합니다. 자세한 정보는 제외 사전 주제를 참조하십시오.

4. **대체 사전 분할창.** 왼쪽 하단에 위치한 이 분할창에는 동의어 및 선택적 요소가 각자의 탭에 표시됩니다. 동의어 및 선택적 요소는 유사한 용어를 하나의 리드 또는 대상, 최종 추출 결과의 개념 아래에 그룹화합니다. 이 사전에는 알려진 동의어 및 사용자 정의 동의어 및 요소뿐만 아니라 올바른 맞춤법과 쌍을 이룬 자주 틀리는 맞춤법을 포함할 수 있습니다. 동의어 정의 및 선택적 요소는 사용자가 선택하는 라이브러리에 저장될 수 있습니다. 그러나 대체 사전 분할창은 라이브러리 트리에 표시 가능한 모든 라이브러리의 모든 콘텐츠를 표시합니다. 이 분할창은 모든 라이브러리의 모든 동의어 또는 선택적 요소를 표시하지만 트리에 있는 모든 라이브러리의 대체가 이 분할창에 함께 표시됩니다. 라이브러리는 단 하나의 대체 사전만을 포함할 수 있습니다. 자세한 정보는 대체/동의어 사건의 내용을 참조하십시오.

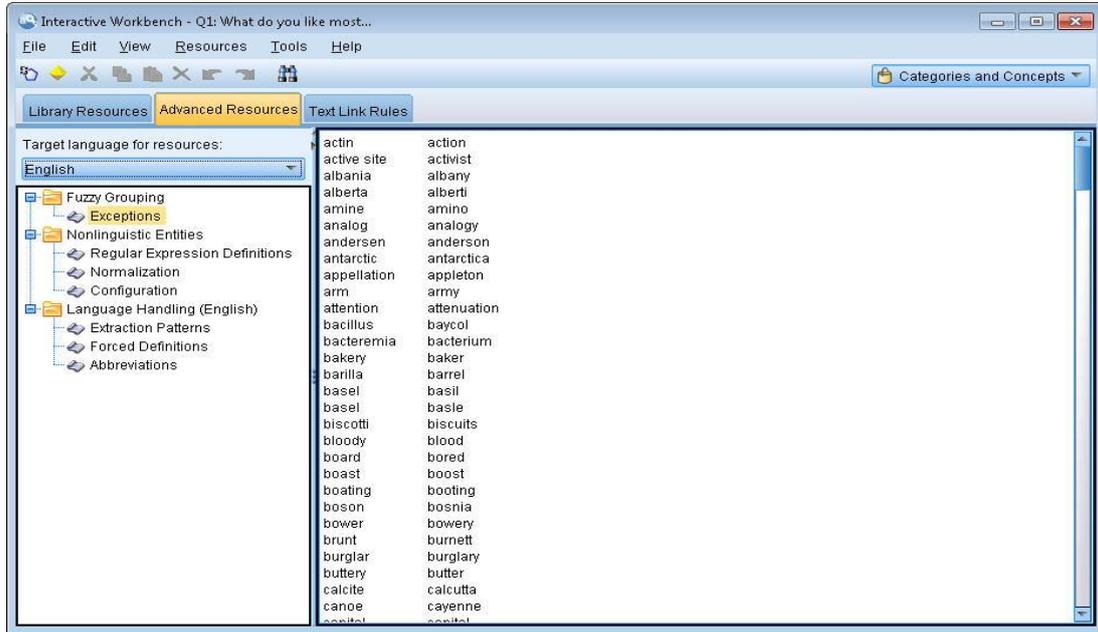
#### 참고:

- 단일 라이브러리와 관련된 정보만을 볼 수 있도록 필터링하려는 경우에는 도구 모음의 드롭 다운 목록을 사용하여 라이브러리 보기를 변경할 수 있습니다. 여기에는 **모든 라이브러리**라고 불리는 최상위 수준 항목뿐만 아니라 각 개별 라이브러리의 추가 항목이 포함됩니다. 자세한 정보는 라이브러리 보기의 내용을 참조하십시오.

## 고급 자원 탭

편집기 보기의 두 번째 탭에서 고급 자원 탭을 사용할 수 있습니다. 이 탭에서 고급 자원을 검토하고 편집할 수 있습니다. 자세한 정보는 고급 자원에 대한 정보의 내용을 참조하십시오.

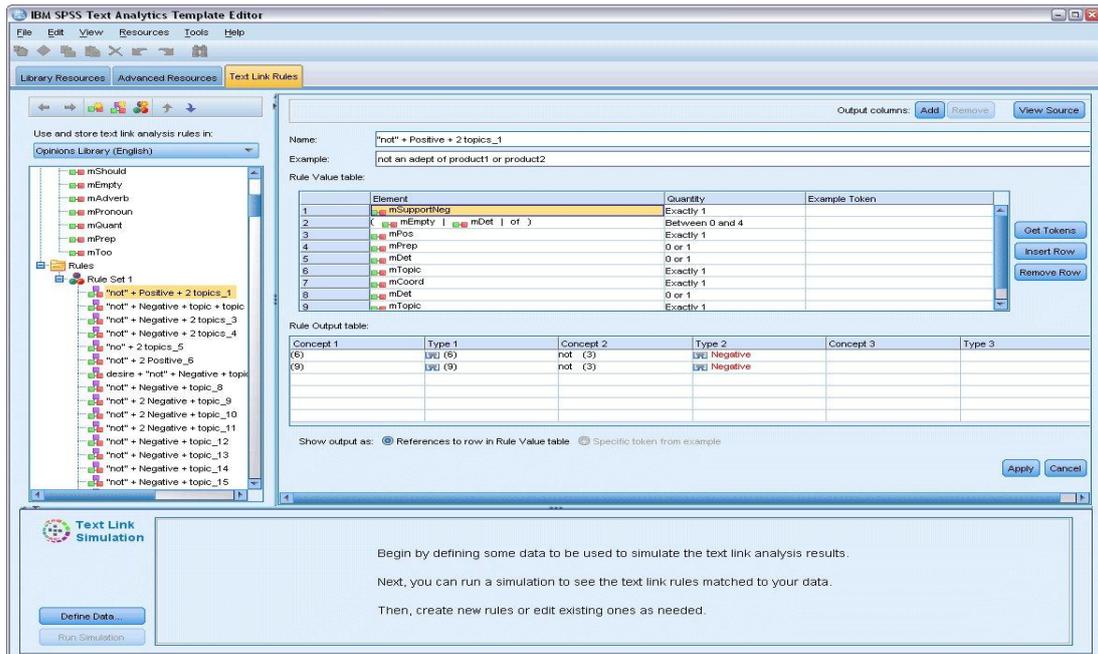
그림 2. 텍스트 마이닝 템플릿 편집기 - 고급 자원 탭



### 텍스트 링크 규칙 탭

버전 14부터 텍스트 링크 분석 규칙을 편집기 보기의 자체 탭에서 편집할 수 있습니다. 규칙 편집기에서 작업하고 자체 규칙을 작성하며, 시뮬레이션을 실행하여 규칙이 TLA 결과에 어떻게 영향을 주는지도 확인할 수 있습니다. 자세한 정보는 텍스트 링크 규칙에 대한 정보의 내용을 참조하십시오.

그림 3. 텍스트 마이닝 템플릿 편집기 - 텍스트 링크 규칙 탭



### 3) 템플리트 열기

템플리트 편집기를 실행하면 템플리트를 열도록 프롬프트가 표시됩니다. 마찬가지로 파일 메뉴에서 템플리트를 열 수 있습니다. 일부 텍스트 링크 분석(TLA) 규칙을 포함하는 템플리트를 원할 경우 TLA 열에 아이콘이 있는 템플리트를 선택하십시오. 템플리트가 작성된 언어가 언어 열에 표시됩니다.

테이블에 표시되지 않은 템플리트를 가져오거나 템플리트를 내보내려면 템플리트 열기 대화 상자의 단추를 사용할 수 있습니다. 자세한 정보는 템플리트 가져오기 및 내보내기의 내용을 참조하십시오.

템플리트를 여는 방법

1. 템플리트 편집기의 메뉴에서 **파일 > 자원 템플리트 열기**를 선택하십시오. 템플리트 열기 대화 상자가 열립니다.
2. 테이블에 표시된 템플리트에서 사용할 템플리트를 선택하십시오.
3. **확인**을 클릭하여 이 템플리트를 여십시오. 편집기에서 다른 템플리트가 현재 열려 있는 경우, 확인을 클릭하면 해당 템플리트를 포기하고 여기서 선택한 템플리트를 표시합니다. 자원을 변경했고 향후 사용을 위해 라이브러리를 저장하려면 다른 템플리트를 열기 전에 라이브러리를 출판, 업데이트, 공유할 수 있습니다. 자세한 정보는 라이브러리 공유의 내용을 참조하십시오.

### 4) 템플리트 저장

템플리트 편집기에서는 템플리트 변경사항을 저장할 수 있습니다. 기존 템플리트 이름을 사용하거나 새 이름을 제공하여 저장하도록 선택할 수 있습니다.

이전 시간에 노드에 이미 로드한 템플리트를 변경하는 경우, 최신 변경사항을 가져오려면 노드에 템플리트 콘텐츠를 재로드해야 합니다. 자세한 정보는 템플리트 및 TAP에서 자원 복사의 내용을 참조하십시오.

또는 텍스트 마이닝 노드의 모델 탭에서 **저장된 대화형 작업 사용** 옵션을 사용하는 경우(이전 대화형 워크벤치 세션의 자원을 사용함을 의미) 대화형 워크벤치 세션에서 이 템플리트의 자원으로 전환해야 합니다. 자세한 정보는 자원 템플리트 전환의 내용을 참조하십시오.

**참고:** 라이브러리를 출판하고 공유할 수도 있습니다. 자세한 정보는 라이브러리 공유의 내용을 참조하십시오.

## 템플리트 저장 방법

1. 템플리트 편집기의 메뉴에서 **파일 > 자원 템플리트 저장**을 선택하십시오. 자원 템플리트 저장 대화 상자가 열립니다.
2. 이 템플리트를 새 템플리트로 저장하려면 템플리트 이름 필드에 새 이름을 입력하십시오. 기존 템플리트를 현재 로드된 자원으로 덮어쓰려면 테이블에서 템플리트를 선택하십시오.
3. 원하면 테이블에 주석 또는 주석(Annotation)을 표시할 설명을 입력하십시오.
4. **저장**을 클릭하여 템플리트를 저장하십시오.

**중요!** 템플리트 또는 TAP의 자원이 노드에 로드/복사되기 때문에 템플리트를 변경하고 기존 스트림에서 이러한 변경의 도움을 받으려면 재로드하여 자원을 업데이트해야 합니다. 자세한 정보는 로드 후 노드 자원 업데이트의 내용을 참조하십시오.

## 5) 로드 후 노드 자원 업데이트

기본적으로 스트림에 노드를 추가하면 기본 템플리트의 자원 세트가 노드에 로드되어 임베드됩니다. 템플리트를 변경하거나 TAP을 사용하는 경우 로드하면 해당 자원 사본이 자원을 덮어씁니다. 템플리트와 TAP은 노드에 직접적으로 링크되지 않기 때문에 템플리트 또는 TAP 변경사항을 기존 노드에서 자동으로 사용할 수 없습니다. 해당 변경의 도움을 받으려면 해당 노드에서 자원을 업데이트해야 합니다. 두 가지 방법 중 하나로 자원을 업데이트할 수 있습니다.

### 방법 1: 모델 탭에서 자원 재로드

새 또는 업데이트된 템플리트나 TAP을 사용하여 노드의 자원을 업데이트하려면 노드의 모델 탭에서 재로드할 수 있습니다. 재로드하면 노드의 자원 사본이 최신 사본으로 대체됩니다. 편의를 위해 업데이트된 시간 및 날짜가 원래 템플리트의 이름과 함께 모델 탭에 나타납니다. 자세한 정보는 템플리트 및 TAP에서 자원 복사의 내용을 참조하십시오.

그러나 텍스트 마이닝 모델링 노드에서 대화형 세션 데이터에 대해 작업 중이고 모델 탭에서 **세션 작업 사용** 옵션을 선택한 경우에는 저장된 세션 작업과 자원이 사용되고 **로드** 단추를 사용할 수 없습니다. 대화형 워크벤치 세션 동안 일찍이 **모델링 노드 업데이트** 옵션을 선택하고 범주, 자원, 다른 세션 작업을 유지했기 때문에 사용할 수 없습니다. 그런 경우, 해당 자원을 변경하거나 업데이트하려면 자원 편집기에서 자원을 전환하는 다음 방법을 시도할 수 있습니다.

### 방법 2: 자원 편집기에서 자원 전환

대화형 세션 동안 다른 자원을 사용하려면 언제든지 자원 전환 대화 상자를 사용하여 해당 자원을 교환할 수 있습니다. 이는 기존 범주 작업을 재사용하지만 자원을 대체할 경우 특히 유용합니다. 이 경우, 텍스트 마이닝 모델링 노드의 모델 탭에서 **세션 작업 사용** 옵션을 선택할 수 있습니다.

이렇게 하면 노드 대화 상자를 통한 템플리트 재로드 기능을 사용할 수 없으며 대신에 세션 동안 수행된 변경사항과 설정을 유지합니다. 그러면 스트림을 실행하여 대화형 워크벤치 세션을 실행하고 자원 편집기에서 자원을 전환할 수 있습니다. 자세한 정보는 자원 템플리트 전환의 내용을 참조하십시오.

자원을 포함하여 후속 세션에 대해 세션 작업을 유지하려면 자원(및 다른 데이터)이 노드에 다시 저장되도록 대화형 워크벤치 세션 내에서 모델링 노드를 업데이트해야 합니다. 자세한 정보는 모델링 노드 업데이트 및 저장의 내용을 참조하십시오.

**참고:** 대화형 세션 동안 다른 템플리트의 콘텐츠로 전환하면 노드에 나열된 템플리트의 이름이 여전히 로드 및 복사된 마지막 템플리트의 이름이 됩니다. 이러한 자원 또는 다른 세션 작업의 도움을 받으려면 세션을 종료하기 전에 모델링 노드를 업데이트하십시오.

## 6) 템플리트 관리

템플리트에 대해 이따금씩 수행할 몇 가지 기본 관리 태스크(예: 템플리트 이름 변경, 템플리트 가져오기 및 내보내기 또는 사용하지 않는 템플리트 삭제)도 있습니다. 이러한 태스크는 템플리트 관리 대화 상자에서 수행됩니다. 템플리트 가져오기 및 내보내기를 사용하여 다른 사용자와 템플리트를 공유할 수 있습니다. 자세한 정보는 템플리트 가져오기 및 내보내기의 내용을 참조하십시오.

**참고:** 이 제품과 함께 설치된(또는 제공된) 템플리트를 이름 변경하거나 삭제할 수 없습니다. 대신에, 이름을 변경하려면 설치된 템플리트를 열고 선택한 이름을 가진 새 템플리트를 작성할 수 있습니다. 사용자 정의 템플리트를 삭제할 수 있습니다. 그러나 제공된 템플리트를 삭제하려고 하면 원래 설치된 버전으로 재설정됩니다.

### 템플리트 이름 변경 방법

1. 메뉴에서 **자원 > 자원 템플리트 관리**를 선택하십시오. 템플리트 관리 대화 상자가 열립니다.
2. 이름을 변경할 템플리트를 선택하고 **이름 변경**을 클릭하십시오. 이름 상자가 테이블에서 편집 가능한 필드가 됩니다.
3. 새 이름을 입력하고 Enter 키를 누르십시오. 확인 대화 상자가 열립니다.
4. 이름 변경에 만족하면 **예**를 클릭하십시오. 그렇지 않으면 **아니오**를 클릭하십시오.

### 템플리트 삭제 방법

1. 메뉴에서 **자원 > 자원 템플리트 관리**를 선택하십시오. 템플리트 관리 대화 상자가 열립니다.
2. 템플리트 관리 대화 상자에서 삭제할 템플리트를 선택하십시오.
3. **삭제**를 클릭하십시오. 확인 대화 상자가 열립니다.

4. **예**를 클릭하여 삭제하거나 **아니오**를 클릭하여 요청을 취소하십시오. **예**를 클릭하면 템플리트가 삭제됩니다.

## 7) 템플리트 가져오기 및 내보내기

템플리트를 가져오고 내보내 다른 사용자 또는 시스템과 공유할 수 있습니다. 템플리트는 내부 데이터베이스에 저장되지만 하드 드라이브에 \*.lrt 파일로 내보낼 수 있습니다.

템플리트를 가져오거나 내보낼 상황이 있기 때문에 해당 기능을 제공하는 몇 개의 대화 상자가 있습니다.

- 템플리트 편집기의 템플리트 열기 대화 상자
- 텍스트 마이닝 모델링 노드 및 텍스트 링크 분석 노드의 자원 로드 대화 상자
- 템플리트 편집기 및 자원 편집기의 템플리트 관리 대화 상자

템플리트를 가져오는 방법

1. 대화 상자에서 **가져오기**를 클릭하십시오. 템플리트 가져오기 대화 상자가 열립니다.
2. 가져올 자원 템플리트 파일(\*.lrt)을 선택하고 **가져오기**를 클릭하십시오. 가져올 템플리트를 다른 이름으로 저장하거나 기존 템플리트를 덮어쓸 수 있습니다. 대화 상자가 닫히고 이제 템플리트가 테이블에 나타납니다.

템플리트를 내보내는 방법

1. 대화 상자에서 내보낼 템플리트를 선택하고 **확인**을 클릭하십시오. 디렉토리 선택 대화 상자가 열립니다.
2. 내보낼 디렉토리를 선택하고 **내보내기**를 클릭하십시오. 이 대화 상자가 닫히며, 템플리트를 내보내고 파일 확장자(\*.lrt)를 수반합니다.

## 8) 템플리트 편집기 종료

템플리트 편집기에서 작업을 완료했으면 작업을 저장하고 편집기를 종료할 수 있습니다.

템플리트 편집기 종료 방법

1. 메뉴에서 **파일 > 닫기**를 선택하십시오. 저장 및 닫기 대화 상자가 열립니다.
2. 편집기를 닫기 전에 열린 템플리트를 저장하려면 **템플리트 변경사항 저장**을 선택하십시오.

3. 편집기를 닫기 전에 열린 템플릿의 라이브러리를 출판하려면 **라이브러리 출판**을 선택하십시오. 이 옵션을 선택하면 출판할 라이브러리를 선택하도록 프롬프트가 표시됩니다. 자세한 정보는 라이브러리 출판의 내용을 참조하십시오.

## 9) 자원 백업

보안 조치로 이따금씩 자원을 백업할 수 있습니다.

**중요!** 복원할 때는 자원의 전체 콘텐츠를 깨끗하게 지우고 제품에서 백업 파일의 콘텐츠에만 액세스할 수 있습니다. 여기에는 열린 작업이 포함됩니다.

**참고:** 동일한 주 버전의 소프트웨어만 백업하고 복원할 수 있습니다. 예를 들어, 버전 15에서 백업하는 경우에는 해당 백업을 버전 16으로 복원할 수 없습니다.

자원 백업 방법

1. 메뉴에서 **자원 > 백업 도구 > 자원 백업**을 선택하십시오. 백업 대화 상자가 열립니다.
2. 백업 파일의 이름을 입력하고 **저장**을 클릭하십시오. 대화 상자가 닫히고 백업 파일이 작성됩니다.

자원 복원 방법

1. 메뉴에서 **자원 > 백업 도구 > 자원 복원**을 선택하십시오. 경고가 표시되어 복원하면 데이터 베이스의 현재 콘텐츠를 덮어쓰게 됨을 경고합니다.
2. **예**를 클릭하여 진행하십시오. 대화 상자가 열립니다.
3. 복원할 백업 파일을 선택하고 **열기**를 클릭하십시오. 대화 상자가 닫히고 애플리케이션에서 자원이 복원됩니다.

## 10) 자원 파일 가져오기

이 제품 외부에서 자원 파일에 직접 변경사항을 작성한 경우, 해당 라이브러리를 선택하고 가져오기로 진행하여 선택된 라이브러리로 파일을 가져올 수 있습니다. 디렉토리를 가져올 때, 모든 지원 파일을 특정의 열린 라이브러리로 가져올 수 있습니다. \*.txt 파일만 가져올 수 있습니다.

가져온 각 파일에는 해당 하나의 항목만 포함하며, 내용이 다음과 같이 구조화되는 경우

- 목록 단어 또는 구문(행마다 하나). 파일은 유형 사전의 용어 목록으로 가져옵니다. 유형 사전은 파일 이름에서 확장자를 제외하고 사용합니다.
- term1 <TAB> term2와 같은 항목 목록은 동의어 목록으로 가져옵니다. 여기서 term1은 기본적인 용어 세트이며 term2는 대상 용어입니다.

## 단일 자원 파일을 가져오는 방법

1. 메뉴에서, **자원 > 파일 가져오기 > 단일 파일 가져오기**를 선택하십시오. 파일 가져오기 대화 상자가 열립니다.
2. 가져오려는 파일을 선택하고 **가져오기**를 클릭하십시오. 파일 내용은 내부 형식으로 변환되고 라이브러리에 추가됩니다.

## 디렉토리에서 모든 파일을 가져오는 방법

1. 메뉴에서 **자원 > 파일 가져오기 > 전체 디렉토리 가져오기**를 선택하십시오. 디렉토리 가져오기 대화 상자가 열립니다.
2. 모든 자원 파일을 **가져오기** 목록에서 가져오려고 하는 라이브러리를 선택하십시오. **기본값** 옵션을 선택하면, 새 라이브러리는 해당 이름으로 디렉토리의 이름을 사용하여 작성됩니다.
3. 파일을 가져올 디렉토리를 선택하십시오. 서브디렉토리는 읽지 않습니다.
4. **가져오기**를 클릭하십시오. 대화 상자가 닫히고 가져온 자원 파일의 내용이 사전 및 고급 자원 파일 양식으로 편집기에 나타납니다.

## 15. 라이브러리에 대한 작업

텍스트 데이터에서 용어를 추출하고 그룹화하기 위해 추출 엔진에서 사용되는 자원에는 항상 하나 이상의 라이브러리가 포함됩니다. 템플릿 편집기 및 자원 편집기의 상단 왼쪽 부분에 있는 라이브러리 트리에 라이브러리 세트가 표시될 수 있습니다. 라이브러리는 세 가지 종류의 사전인

- 유형 사전
- 대체 사전
- 제외 사전

자세한 정보는 라이브러리 사전 정보의 내용을 참조하십시오.

선택한 TAP의 자원 또는 자원 템플릿에는 텍스트 데이터에서 개념 추출을 즉시 시작할 수 있도록 하는 몇 개의 라이브러리가 포함되어 있습니다. 그러나, 자신의 고유 라이브러리를 작성하고 재사용할 수 있도록 이 라이브러리를 출판할 수도 있습니다. 자세한 정보는 라이브러리 출판의 내용을 참조하십시오.

예를 들어, 자동차 산업에 관련된 텍스트 데이터에 대해 자주 작업한다고 가정해 보십시오. 데이터를 분석한 후, 산업 특성의 어휘 또는 전문어를 처리하기 위해 일부 사용자 정의 자원을 작성할 것을 결정합니다. 템플릿 편집기를 사용하여, 새 템플릿을 작성하고, 이 템플릿에서 자

동차 용어를 추출하고 그룹화하기 위해 라이브러리를 작성할 수 있습니다. 이 라이브러리의 정보를 다시 필요하게 되므로, **라이브러리 관리** 대화 상자에서 액세스 가능한 중앙 저장소에 라이브러리를 출판하여, 다른 스트림 세션 에서 독립적으로 재사용할 수 있도록 합니다.

또한 전자 장치, 엔진, 냉각 시스템 또는 특정 제조업체나 시장과 같은 다양한 하위 산업에 특정한 용어를 그룹화하는 데 관심이 있다고 가정해 보십시오. 그룹마다 라이브러리를 작성한 후 여러 텍스트 데이터 세트에 사용할 수 있도록 라이브러리를 출판할 수 있습니다. 이 방식에서, 텍스트 데이터에 가장 잘 맞는 라이브러리를 추가할 수 있습니다.

**참고:** 고급 자원 탭에서 추가 자원을 구성하고 관리할 수 있습니다. 일부는 모든 라이브러리에 적용되고, 비언어 엔티티, 퍼지 그룹화 예외 등을 관리합니다. 또한, 텍스트 링크 분석 패턴 규칙을 편집할 수 있습니다. 이 규칙은 텍스트 링크 규칙 탭에서 라이브러리에 특정한 규칙입니다. 자세한 정보는 고급 자원에 대한 정보의 내용을 참조하십시오.

## 1) 제공된 라이브러리

기본적으로 여러 라이브러리가 IBM® SPSS® Modeler Text Analytics와 함께 설치됩니다. 사전 형식화된 이러한 라이브러리를 사용하여 사전 정의된 수천 개의 용어와 동의어는 물론 다수의 많은 유형에 액세스할 수 있습니다. 제공된 이러한 라이브러리는 여러 도메인에 맞게 미세 조정되며 여러 언어로 사용 가능합니다.

라이브러리는 많지만 가장 일반적으로 사용되는 라이브러리는 다음과 같습니다.

- **로컬 라이브러리.** 사용자 정의 사전을 저장하는 데 사용됩니다. 기본적으로 모든 자원에 추가된 빈 라이브러리입니다. 빈 유형 사전도 포함합니다. 범주 및 개념 보기, 군집 보기, 텍스트 링크 분석 보기 에서 자원을 직접 변경하거나 세분화할 경우(예: 유형에 단어 추가) 가장 유용합니다. 이 경우, 변경사항 및 세분화 사항은 자원 편집기의 라이브러리 트리에 나열된 첫 번째 라이브러리(기본적으로 이는 *로컬 라이브러리*)에 자동으로 저장됩니다. 세션 데이터에 특정하기 때문에 이 라이브러리를 출판할 수는 없습니다. 콘텐츠를 출판하려면 먼저 라이브러리 이름을 변경해야 합니다.
- **코어 라이브러리.** 사용자, 위치, 조직, 제품, 알 수 없음을 나타내는 기본적인 5개의 내장 유형으로 구성되기 때문에 대부분의 경우에 사용됩니다. 유형 사전 중 하나에 나열된 몇 개의 용어만 볼 수 있긴 하지만 코어 라이브러리에 표시된 유형은 텍스트 마이닝 제품과 함께 제공되는 컴파일된 내부 자원에서 찾은 로버스트 유형을 실제로 보완합니다. 이러한 컴파일된 내부 자원은 각 유형에 대해 수천 개의 용어를 포함합니다. 이러한 이유로 유형 사전 용어 목록에 용어가 표시되지 않더라도 여전히 추출하여 코어 유형으로 유형을 지정할 수 있습니다. 이는 코어 라이브러리의 <Person> 유형 사전에 *John*이 나타나는 경우에만 *George*와 같은 이름을 추출하고 <Person>으로 유형을 지정할 수 있는 방법을 설명합니다. 마찬가지로 코어 라이브러리를 포함시키지 않으면 이러한 유형이 포함된 컴파일된 자원을 추출 엔진이 여전히 사용하기 때문에 추출 결과에서 이러한 유형을 여전히 볼 수 있습니다.

- **Opinions 라이브러리.** 텍스트 데이터에서 의견과 정서를 추출하는 데 가장 일반적으로 사용됩니다. 이 라이브러리는 주제에 대한 의견을 표시하는 태도, 규정자, 기본 설정(다른 용어와 함께 사용되는 경우)을 나타내는 수천 개의 단어를 포함합니다. 이 라이브러리는 다수의 내장 유형, 동의어, 제외를 포함합니다. 텍스트 링크 분석에 사용되는 큰 패턴 규칙 세트도 포함합니다. 이 라이브러리의 텍스트 링크 분석 규칙과 이 규칙이 생성하는 패턴 결과가 도움이 되려면 이 라이브러리를 텍스트 링크 규칙 탭에 지정해야 합니다. 자세한 정보는 텍스트 링크 규칙에 대한 정보 주제를 참조하십시오.
- **예산 라이브러리.** 어떤 것의 비용을 참조하는 용어를 추출하는 데 사용됩니다. 이 라이브러리는 어떤 것의 가격이나 품질에 관한 형용사, 규정자, 판단을 나타내는 많은 단어와 문구를 포함합니다.
- **변형 라이브러리.** 일정 언어 변형을 적절히 그룹화하려면 동의어 정의가 필요한 경우를 포함시키는 데 사용됩니다. 이 라이브러리는 동의어 정의만 포함합니다.

템플릿 외부에 제공된 일부 라이브러리가 일부 템플릿의 콘텐츠와 유사하긴 하지만 템플릿은 특정 애플리케이션에 맞게 특별히 조정되었으며 추가 고급 자원을 포함합니다. 작업할 텍스트 데이터 종류에 맞게 설계된 템플릿을 사용하고 보다 일반적인 템플릿에 단순히 개별 라이브러리를 추가하기 보다는 해당 자원을 변경하는 것이 좋습니다.

컴파일된 자원은 또한 IBM SPSS Modeler Text Analytics와 함께 제공됩니다. 항상 추출 프로세스 중에 사용되며 기본 라이브러리에 내장 유형 사전에 대한 상당수의 보완 정의를 포함합니다. 이러한 자원은 컴파일되기 때문에 보거나 편집할 수 없습니다. 그러나 이러한 컴파일된 자원이 유형 지정한 용어를 다른 사전에 강제 실행할 수 있습니다. 자세한 정보는 용어 강제 실행의 내용을 참조하십시오.

## 2) 라이브러리 작성

라이브러리를 얼마든지 작성할 수 있습니다. 새 라이브러리를 작성한 후 이 라이브러리에서 유형 사전 작성을 시작하고 용어, 동의어, 제외를 입력할 수 있습니다.

라이브러리 작성 방법

1. 메뉴에서 **자원 > 새 라이브러리**를 선택하십시오. 라이브러리 특성 대화 상자가 열립니다.
2. 이름 텍스트 상자에 라이브러리 이름을 입력하십시오.
3. 원하면 주석(Annotation) 텍스트 상자에 주석을 입력하십시오.
4. 라이브러리에 무언가를 입력하기 전에 지금 이 라이브러리를 출판하려면 **출판**을 클릭하십시오. 자세한 정보는 라이브러리 공유의 내용을 참조하십시오. 나중에 언제든지 출판할 수도 있습니다.
5. **확인**을 클릭하여 라이브러리를 작성하십시오. 대화 상자가 닫히고 라이브러리가 트리 보기에 나타납니다. 트리에서 라이브러리를 펼치면 빈 유형 사전이 라이브러리에 자동으로 추가되었음을 알 수 있습니다. 여기에서 용어 추가를 즉시 시작할 수 있습니다. 자세한 정보는 용어 추가의 내용을 참조하십시오.

### 3) 공용 라이브러리 추가

다른 세션 데이터의 라이브러리를 재사용하는 경우, 공용 라이브러리면 현재 자원에 추가할 수 있습니다. 공용 라이브러리는 출판된 라이브러리입니다. 자세한 정보는 라이브러리 출판의 내용을 참조하십시오.

공용 라이브러리를 추가할 때 로컬 사본이 세션 데이터에 임베드됩니다. 이 라이브러리를 변경할 수 있습니다. 그러나 변경사항을 공유하려면 공용 버전의 라이브러리를 재출판해야 합니다.

공용 라이브러리를 추가할 때 한 라이브러리의 용어 및 유형과 다른 로컬 라이브러리의 용어 및 유형 간에 충돌이 발견되면 충돌 해결 대화 상자가 나타날 수 있습니다. 이 작업을 완료하려면 이러한 충돌을 해결하거나 제안된 해결책을 승인해야 합니다. 자세한 정보는 충돌 해결의 내용을 참조하십시오.

 **참고:** 대화형 워크벤치 세션을 실행하거나 세션을 닫을 때 출판 하는 경우 라이브러리를 항상 업데이트하면 라이브러리가 동기화되지 않을 가능성이 낮습니다. 자세한 정보는 라이브러리 공유의 내용을 참조하십시오.

### 라이브러리 추가 방법

1. 메뉴에서 **자원 > 라이브러리 추가**를 선택하십시오. 라이브러리 추가 대화 상자가 열립니다.
2. 목록에서 라이브러리를 선택하십시오.
3. **추가**를 클릭하십시오. 새로 추가된 라이브러리와 이미 거기에 있던 라이브러리 간에 충돌이 발생하는 경우, 작업을 완료하기 전에 충돌 해결책을 확인하거나 라이브러리를 변경하라는 요청을 받습니다. 자세한 정보는 충돌 해결의 내용을 참조하십시오.

### 4) 용어 및 유형 찾기

찾기 기능을 사용하여 편집기의 여러 분할창에서 검색할 수 있습니다. 편집기의 메뉴에서 **편집 > 찾기**를 선택할 수 있으며 찾기 도구 모음이 나타납니다. 이 도구 모음을 사용하여 한 번에 하나의 발생을 찾을 수 있습니다. 찾기를 다시 클릭하여 검색어의 후속 발생을 찾을 수 있습니다.

검색 시 편집기는 찾기 도구 모음의 드롭 다운 목록에 나열된 라이브러리만 검색합니다. **모든 라이브러리**가 선택된 경우 프로그램은 편집기에서 모든 것을 검색합니다.

검색을 시작할 때 검색은 초점이 있는 영역에서 시작됩니다. 검색은 각 섹션을 통해 계속되며 활성 셀로 돌아갈 때까지 루프백됩니다. 방향 화살표를 사용하여 검색 순서를 반대로 할 수 있습니다. 검색이 대소문자를 구분하는지 여부도 선택할 수 있습니다.

## 보기에서 문자열을 찾는 방법

1. 메뉴에서 편집 > 찾기를 선택하십시오. 찾기 도구 모음이 표시됩니다.
2. 검색할 문자열을 입력하십시오.
3. 찾기 단추를 클릭하여 검색을 시작하십시오. 용어 또는 유형의 다음 발생이 강조표시됩니다.
4. 단추를 다시 클릭하여 발생 간에 이동하십시오.

## 용어에 별표 사용

사이에 공백 없이 다른 단어를 함께 결합하여 새 단어를 작성하는 교착어를 다루는 경우에 용어에 별표(\*)를 사용하는 방법이 특히 유용합니다. 예를 들어, 독일어 *Übernachtungspreis*는 *Übernachtung* + *s* + *Preis*로 구성됩니다.

예를 들어, Budget 유형에서 *preis\**를 검색하는 경우, *preiserhöhung* 등의 추출된 개념과 매치됩니다. 동일한 방법으로 *\*preis*가 *Übernachtung*과 매치되며 *\*preis\**가 *Übernachtungspreiserhöhung*과 매치됩니다.

## 5) 라이브러리 보기

하나의 특정 라이브러리 또는 모든 라이브러리의 콘텐츠를 표시할 수 있습니다. 이는 많은 라이브러리를 처리하거나 출판하기 전에 특정 라이브러리의 콘텐츠를 검토하려는 경우 유용합니다. 보기 변경은 이 라이브러리 자원 탭에 표시되는 내용에만 영향을 주지만 추출 중에 라이브러리를 사용할 수 없게 하지는 않습니다. 자세한 정보는 로컬 라이브러리 사용 안함의 내용을 참조하십시오.

기본 보기는 트리에 모든 라이브러리를 표시하고 다른 분할창에 해당 콘텐츠를 표시하는 **모든 라이브러리**입니다. 도구 모음의 드롭 다운 목록을 사용하여 또는 메뉴 선택(**보기 > 라이브러리**)을 통해 이 선택을 변경할 수 있습니다. 단일 라이브러리를 보는 경우에는 다른 라이브러리의 모든 항목이 보기에서 사라지지만 추출 중에 여전히 읽을 수 있습니다.

라이브러리 보기 변경 방법

1. 라이브러리 자원 탭의 메뉴에서 **보기 > 라이브러리**를 선택하십시오. 모든 로컬 라이브러리가 있는 메뉴가 열립니다.
2. 볼 라이브러리를 선택하거나, 모든 라이브러리의 콘텐츠를 보려면 **모든 라이브러리** 옵션을 선택하십시오. 보기 콘텐츠는 선택사항에 따라 필터링됩니다.

## 6) 로컬 라이브러리 관리

로컬 라이브러리는 공용 라이브러리와 대조적으로 대화형 워크벤치 세션 안에 있거나 템플릿 안에 있는 라이브러리입니다. 자세한 정보는 공용 라이브러리 관리의 내용을 참조하십시오. 다음을 포함하여 수행할 몇 가지 기본 로컬 라이브러리 관리 태스크도 있습니다.

- 로컬 라이브러리 이름 변경. 자세한 정보는 로컬 라이브러리 이름 변경의 내용을 참조하십시오.
- 로컬 라이브러리 사용 또는 사용 안함. 자세한 정보는 로컬 라이브러리 사용 안함의 내용을 참조하십시오.
- 로컬 라이브러리 삭제. 자세한 정보는 로컬 라이브러리 삭제의 내용을 참조하십시오.

### (1) 로컬 라이브러리 이름 변경

로컬 라이브러리의 이름을 변경할 수 있습니다. 로컬 라이브러리의 이름을 변경하는 경우 공용 버전이 존재하면 공용 버전과 분리됩니다. 이는 후속 변경사항을 공용 버전과 더 이상 공유할 수 없음을 의미합니다. 이 로컬 라이브러리를 새 이름으로 재출판할 수 있습니다. 이는 원래 공용 버전을 이 로컬 버전에 수행하는 변경사항으로 업데이트할 수 없음도 의미합니다.

*참고:* 공용 라이브러리의 이름을 변경할 수 없습니다.

1. 메뉴에서 **편집 > 라이브러리 특성**을 선택하십시오. 라이브러리 특성 대화 상자가 열립니다.

로컬 라이브러리 이름 변경 방법

1. 트리 보기에서 이름을 변경할 라이브러리를 선택하십시오.
2. 이름 텍스트 상자에 라이브러리의 새 이름을 입력하십시오.
3. **확인**을 클릭하여 라이브러리의 새 이름을 승인하십시오. 대화 상자가 닫히고 라이브러리 이름이 트리 보기에서 업데이트됩니다.

### (2) 로컬 라이브러리 사용 안함

추출 프로세스에서 일시적으로 라이브러리를 제외하려면 트리 보기에서 라이브러리 이름 왼쪽의 확인 상자를 선택 취소할 수 있습니다. 이는 라이브러리를 유지하지만 충돌 검사 시와 추출 중에는 콘텐츠를 무시함을 나타냅니다.

라이브러리를 사용 안함으로 설정하는 방법

1. 라이브러리 트리 분할창에서 사용 안함으로 설정할 라이브러리를 선택하십시오.
2. 스페이스바를 클릭하십시오. 이름 왼쪽에 있는 확인 상자가 지워집니다.

### (3) 로컬 라이브러리 삭제

공용 버전의 라이브러리를 삭제하지 않고 라이브러리를 제거할 수 있으며 그 반대도 가능합니다. 로컬 라이브러리를 삭제하면 세션 에서만 라이브러리와 모든 콘텐츠가 삭제됩니다. 로컬 버전의 라이브러리를 삭제하면 다른 세션 또는 공용 버전에서 해당 라이브러리가 제거되지 않습니다. 자세한 정보는 공용 라이브러리 관리의 내용을 참조하십시오.

로컬 라이브러리 제거 방법

1. 트리 보기에서 삭제할 라이브러리를 선택하십시오.
2. 메뉴에서 **편집 > 삭제**를 선택하여 라이브러리를 삭제하십시오. 라이브러리가 제거됩니다.
3. 전에 이 라이브러리를 출판한 적이 없으면 이 라이브러리를 삭제할 것인지 유지할 것인지 여부를 묻는 메시지가 열립니다. **삭제**를 클릭하여 계속하거나 이 라이브러리를 유지하려면 **유지**를 클릭하십시오.

**참고:** 항상 한 개의 라이브러리가 남아 있어야 합니다.

## 7) 공용 라이브러리 관리

로컬 라이브러리를 재사용하려면 로컬 라이브러리를 출판한 후 이에 대한 작업을 수행하고 라이브러리 관리 대화 상자(**자원 > 라이브러리 관리**)를 통해 볼 수 있습니다. 자세한 정보는 라이브러리 공유의 내용을 참조하십시오. 수행할 몇 가지 기본 공용 라이브러리 관리 태스크로는 공용 라이브러리 가져오기, 내보내기 또는 삭제가 있습니다. 공용 라이브러리의 이름을 변경할 수 없습니다.

공용 라이브러리 가져오기

1. 라이브러리 관리 대화 상자에서 **가져오기...**를 클릭하십시오. 라이브러리 가져오기 대화 상자가 열립니다.
2. 가져올 라이브러리 파일(\*.lib)을 선택하고 이 라이브러리를 로컬로 추가하려면 **현재 프로젝트에 라이브러리 추가**를 선택하십시오.
3. **가져오기**를 클릭하십시오. 대화 상자가 닫힙니다. 동일한 이름을 가진 공용 라이브러리가 이미 존재하는 경우, 가져올 라이브러리의 이름을 변경하거나 현재 공용 라이브러리를 덮어쓰라는 요청을 받습니다.

공용 라이브러리 내보내기

공유할 수 있도록 공용 라이브러리를 .lib 형식으로 내보낼 수 있습니다.

1. 라이브러리 관리 대화 상자의 목록에서 내보낼 라이브러리를 선택하십시오.
2. **내보내기**를 클릭하십시오. 디렉토리 선택 대화 상자가 열립니다.
3. 내보낼 디렉토리를 선택하고 **내보내기**를 클릭하십시오. 대화 상자가 닫히고 라이브러리 파일 (\*.lib)을 내보냅니다.

#### 공용 라이브러리 삭제

공용 버전의 라이브러리를 삭제하지 않고 로컬 라이브러리를 제거할 수 있으며 그 반대도 가능합니다. 그러나 라이브러리가 이 대화 상자에서 삭제되면 로컬 버전이 다시 출판될 때까지 세션 자원에 더 이상 추가할 수 없습니다.

제품과 함께 설치된 라이브러리를 삭제하면 원래 설치된 버전이 복원됩니다.

1. 라이브러리 관리 대화 상자에서 삭제할 라이브러리를 선택하십시오. 해당 헤더를 클릭하여 목록을 정렬할 수 있습니다.
2. **삭제**를 클릭하여 라이브러리를 삭제하십시오. IBM® SPSS® Modeler Text Analytics 는 로컬 버전의 라이브러리가 공용 라이브러리와 동일한지 여부를 확인합니다. 동일하면 경고 없이 라이브러리가 제거됩니다. 라이브러리 버전이 다르면 공용 버전을 유지할 것인지 제거할 것인지 여부를 묻는 경고가 열려 발행됩니다.

## 8) 라이브러리 공유

라이브러리를 사용하여 다중 대화형 워크bench 세션 간에 공유하기 쉬운 방법으로 자원에 대한 작업을 할 수 있습니다. 라이브러리가 두 개의 상태 또는 버전으로 존재할 수 있습니다. 편집기에서 편집 가능하고 대화형 워크bench 세션의 일부인 라이브러리를 **로컬 라이브러리**라고 합니다. 대화형 워크bench 세션에서 작업하는 동안 예를 들어 **채소류** 라이브러리에서 많은 변경을 수행할 수 있습니다. 변경사항이 다른 데이터에 유용한 경우 **채소류** 라이브러리의 **공용 라이브러리** 버전을 작성하여 이러한 자원을 사용 가능하게 할 수 있습니다. 이름이 나타내듯 공용 라이브러리는 다른 대화형 워크bench 세션의 자원에 사용 가능합니다.

라이브러리 관리 대화 상자에서 공용 라이브러리를 볼 수 있습니다. 일단 이 공용 라이브러리 버전이 존재하면 이러한 사용자 정의 언어학적 자원을 공유할 수 있도록 다른 컨텍스트에서 자원에 추가할 수 있습니다.

제공된 라이브러리는 처음에 공용 라이브러리입니다. 이러한 라이브러리의 자원을 편집한 후 새 공용 버전을 작성할 수 있습니다. 그런 다음 다른 대화형 워크bench 세션에서 해당 새 버전에 액세스할 수 있습니다.

라이브러리에 대한 작업을 계속하고 변경을 수행하면 라이브러리 버전이 비동기화됩니다. 로컬 버전이 공용 버전보다 최신인 경우가 있고 공용 버전이 로컬 버전보다 최신인 경우도 있습니다. 다른 대화형 워크벤치 세션 내에서 공용 버전이 업데이트된 경우 공용 및 로컬 버전 모두 다른 하나가 포함하지 않는 변경사항을 포함하는 것도 가능합니다. 라이브러리 버전이 비동기화되게 되면 다시 동기화할 수 있습니다. 라이브러리 버전 동기화는 로컬 라이브러리 재출판 및/또는 업데이트로 구성됩니다.

대화형 워크벤치 세션을 실행하거나 세션을 닫을 때마다 업데이트 또는 재출판이 필요한 라이브러리를 동기화하도록 프롬프트가 표시됩니다. 또한 트리 보기에서 라이브러리 이름 옆에 나타나는 아이콘을 통해 또는 라이브러리 특성 대화 상자를 보고 로컬 라이브러리의 동기화 상태를 쉽게 식별할 수 있습니다. 또한 메뉴 선택을 통해 언제든지 동기화를 수행하도록 선택할 수 있습니다. 다음 테이블에서는 5개의 가능한 상태 및 연관된 아이콘을 설명합니다.

표 1. 로컬 라이브러리 동기화 상태	
아이콘	로컬 라이브러리 상태 설명
	출판되지 않음 - 로컬 라이브러리가 출판되지 않았습니다.
	동기화됨 - 로컬 및 공용 라이브러리 버전이 동일합니다. 세션 특정 자원만 포함하기 때문에 출판할 수 없는 로컬 라이브러리에도 적용됩니다.
	오래됨 - 공용 라이브러리 버전이 로컬 버전보다 최신입니다. 변경사항으로 로컬 버전을 업데이트할 수 있습니다.
	더 최신임 - 로컬 라이브러리 버전이 공용 버전보다 최신입니다. 공용 버전에 로컬 버전을 재출판할 수 있습니다.
	동기화되지 않음 - 로컬 및 공용 라이브러리 모두 다른 하나가 포함하지 않는 변경사항을 포함합니다. 로컬 라이브러리를 업데이트할 것인지 출판할 것인지 여부를 결정해야 합니다. 업데이트하는 경우 지난 번 업데이트하거나 출판한 이후로 수행된 변경사항이 유실됩니다. 공개하기로 선택하면 공용 버전의 변경사항을 덮어씁니다.

**참고:** 대화형 워크벤치 세션을 실행하거나 세션을 닫을 때 출판하는 경우 라이브러리를 항상 업데이트하면 라이브러리가 동기화되지 않을 가능성이 낮습니다.

라이브러리의 변경사항이 이 라이브러리도 포함할 수 있는 다른 스트림에 도움이 된다고 생각하면 언제든지 라이브러리를 재출판할 수 있습니다. 그런 다음 변경사항이 다른 스트림에 도움이 되면 해당 스트림에서 로컬 버전을 업데이트할 수 있습니다. 이런 방법으로 새 라이브러리 작성 및/또는 자원에 임의의 수의 공용 라이브러리 추가를 통해 데이터에 적용되는 각 컨텍스트 또는 도메인에 대해 스트림을 작성할 수 있습니다.

공용 버전의 라이브러리가 공유되면 로컬 버전과 공용 버전 간에 차이가 발생할 가능성이 커집니다. 대화형 워크벤치 세션에서 실행하거나 닫고 출판하거나 템플릿 편집기에서 템플릿을 열거나 닫을 때마다 버전이 라이브러리 관리 대화 상자의 해당 버전과 동기화되지 않은 라이브러리를 출판 및/또는 업데이트할 수 있도록 메시지가 표시됩니다. 공용 라이브러리 버전이 로컬 버전보다 최신이면 업데이트할 것인지 여부를 묻는 대화 상자가 열립니다. 공용 버전으로 업데이트하는 대신 로컬 버전을 있는 그대로 유지할 것인지 업데이트를 로컬 라이브러리에 병합할 것인지 여부를 선택할 수 있습니다.

### (1) 라이브러리 출판

특정 라이브러리를 출판한 적이 없는 경우 출판하면 데이터베이스에 로컬 라이브러리 공용 사본이 작성됩니다. 라이브러리를 재출판하는 경우, 로컬 라이브러리의 콘텐츠가 기존 공용 버전의 콘텐츠를 대체합니다. 재출판한 후에는 로컬 버전이 공용 버전과 동기화되도록 다른 스트림 세션에서 이 라이브러리를 업데이트할 수 있습니다. 라이브러리를 출판할 수 있긴 하지만 로컬 버전은 항상 세션에 저장됩니다.

**중요!** 로컬 라이브러리를 변경하고 도중에 공용 버전의 라이브러리도 변경된 경우 라이브러리는 동기화되지 않은 것으로 간주됩니다. 로컬 버전을 공용 변경사항으로 업데이트하는 것으로 시작하고 원하는 변경을 수행한 후 두 버전이 모두 동일하도록 로컬 버전을 다시 출판하는 것이 좋습니다. 먼저 변경을 수행하고 출판하는 경우 공용 버전의 변경사항을 덮어씁니다.

데이터베이스에 로컬 라이브러리를 출판하는 방법

1. 메뉴에서 **자원 > 라이브러리 출판**을 선택하십시오. 출판이 필요한 모든 라이브러리가 기본적으로 선택된 상태에서 라이브러리 출판 대화 상자가 열립니다.
2. 출판하거나 재출판할 각 라이브러리의 왼쪽에 있는 선택란을 선택하십시오.
3. **출판**을 클릭하여 라이브러리 관리 데이터베이스에 라이브러리를 출판하십시오.

### (2) 라이브러리 업데이트

대화형 워크벤치 세션을 실행하거나 닫을 때마다 공용 버전과 더 이상 동기화되지 않은 라이브러리를 업데이트하거나 출판할 수 있습니다. 공용 라이브러리 버전이 로컬 버전보다 최신이면 라이브러리를 업데이트할 것인지 여부를 묻는 대화 상자가 열립니다. 공용 버전으로 업데이트하거나 로컬 버전을 공용 버전으로 대체하는 대신 로컬 버전을 유지할 것인지 여부를 선택할 수 있습니다. 공용 버전의 라이브러리가 로컬 버전보다 최신이면 로컬 버전을 업데이트하여 콘텐츠를 공용 버전의 콘텐츠와 동기화할 수 있습니다. 업데이트는 공용 버전에서 찾은 변경사항을 로컬 버전에 통합함을 의미합니다.

**참고:** 대화형 워크벤치 세션을 실행하거나 세션을 닫을 때 출판 하는 경우 라이브러리가 동기화되지 않을 가능성이 낮습니다. 자세한 정보는 라이브러리 공유의 내용을 참조하십시오.

## 로컬 라이브러리 업데이트 방법

1. 메뉴에서 **자원 > 라이브러리 업데이트**를 선택하십시오. 업데이트가 필요한 모든 라이브러리가 기본적으로 선택된 상태에서 라이브러리 업데이트 대화 상자가 열립니다.
2. 출판하거나 재출판할 각 라이브러리의 왼쪽에 있는 선택란을 선택하십시오.
3. **업데이트**를 클릭하여 로컬 라이브러리를 업데이트하십시오.

## 9) 충돌 해결

### 로컬 대 공용 라이브러리 충돌

스트림 세션을 시작할 때마다 IBM® SPSS® Modeler Text Analytics 는 로컬 라이브러리를 라이브러리 관리 대화 상자에 나열된 라이브러리와 비교합니다. 세션 의 로컬 라이브러리가 출판된 버전과 동기화되지 않은 경우에는 라이브러리 동기화 경고 대화 상자가 열립니다. 다음 옵션 중에서 선택하여 여기서 사용할 라이브러리 버전을 선택할 수 있습니다.

- **파일에 로컬인 모든 라이브러리.** 이 옵션은 모든 로컬 라이브러리를 있는 그대로 유지합니다. 나중에 재출판하거나 업데이트할 수 있습니다.
- **이 시스템에 출판된 모든 라이브러리.** 이 옵션은 표시된 로컬 라이브러리를 데이터베이스에서 발견된 버전으로 대체합니다.
- **모든 최신 라이브러리.** 이 옵션은 오래된 로컬 라이브러리를 데이터베이스의 최신 공용 버전으로 대체합니다.
- **기타.** 이 옵션을 사용하여 테이블에서 버전을 선택하여 원하는 버전을 수동으로 선택할 수 있습니다.

### 강제 실행된 용어 충돌

공용 라이브러리를 추가하거나 로컬 라이브러리를 업데이트할 때마다 이 라이브러리의 용어 및 유형과 자원에 있는 다른 라이브러리의 용어 및 유형 간에 충돌과 중복 항목이 발견될 수 있습니다. 이런 상황이 발생하면 강제 실행된 용어 편집 대화 상자에서 작업을 완료하기 전에 제안된 충돌 해결책을 확인하거나 용어를 변경하라는 요청을 받습니다. 자세한 정보는 용어 강제 실행의 내용을 참조하십시오.

강제 실행된 용어 편집 대화 상자는 충돌하는 각 용어 또는 유형 쌍을 포함합니다. 대체 배경색상은 각 충돌 쌍을 시각적으로 구별하는 데 사용됩니다. 이러한 색상을 옵션 대화 상자에서 변경할 수 있습니다. 자세한 정보는 옵션: 표시 탭 주제를 참조하십시오. 강제 실행된 용어 편집 대화 상자에는 다음 두 개의 탭이 있습니다.

- **중복.** 이 탭은 라이브러리에서 발견된 중복 용어를 포함합니다. 용어 뒤에 푸시핀 아이콘이 나

타나는 경우 이는 이 용어 발생이 강제 실행되었음을 의미합니다. 검은색 X 아이콘이 나타나는 경우 이는 다른 곳에 강제 실행되었기 때문에 추출 중에 이 용어 발생이 무시됨을 의미합니다.

- **사용자 정의.** 이 탭은 충돌을 통해서가 아니라 유형 사전 용어 분할창에서 수동으로 강제 실행된 용어 목록을 포함합니다.

**참고:** 라이브러리를 추가하거나 업데이트한 후에는 강제 실행된 용어 편집 대화 상자가 열립니다. 이 대화 상자에서 취소하는 경우 라이브러리 업데이트 또는 추가를 취소하지 않습니다.

#### 충돌 해결 방법

1. 강제 실행된 용어 편집 대화 상자에서 강제 실행할 용어에 대한 사용 열에서 단일 선택 단추를 선택하십시오.
2. 완료했으면 **확인**을 클릭하여 강제 실행된 용어를 적용하고 대화 상자를 닫으십시오. **취소**를 클릭하면 이 대화 상자에서 수행한 변경사항을 취소합니다.

## 16. 라이브러리 사전 정보

텍스트 데이터를 추출하는 데 사용되는 자원은 템플릿 및 라이브러리 양식으로 저장됩니다. 라이브러리는 세 개의 사전으로 구성될 수 있습니다.

- **유형 사전**은 하나의 레이블 또는 유형 이름 아래에 그룹화된 용어 컬렉션을 포함합니다. 추출 엔진은 텍스트 데이터를 읽을 때 텍스트에서 찾은 단어를 유형 사전에서 정의된 용어와 비교합니다. 추출 중에 굴절된 양식의 유형의 용어와 동의어는 개념이라는 대상 용어 아래에 그룹화됩니다. 추출된 개념은 용어로 나타나는 유형 사전에 지정됩니다. 편집기의 왼쪽 상단 및 가운데 분할창(라이브러리 트리 및 용어 분할창)에서 유형 사전을 관리할 수 있습니다. 자세한 정보는 유형 사전의 내용을 참조하십시오.
- **대체 사전**은 하나의 대상 용어(최종 추출 결과에서는 개념이라고 함) 아래에 유사한 용어를 그룹화하는 데 사용되는 동의어로 또는 선택적 요소로 정의된 단어 컬렉션을 포함합니다. 동의어 탭 및 선택사항 탭을 사용하여 편집기의 왼쪽 하단 분할창에서 대체 사전을 관리할 수 있습니다. 자세한 정보는 대체/동의어 사전의 내용을 참조하십시오.
- **제외 사전**은 최종 추출 결과에서 제거될 용어 및 유형 컬렉션을 포함합니다. 편집기의 맨 오른쪽 분할창에서 제외 사전을 관리할 수 있습니다. 자세한 정보는 제외 사전의 내용을 참조하십시오.

자세한 정보는 라이브러리에 대한 작업의 내용을 참조하십시오.

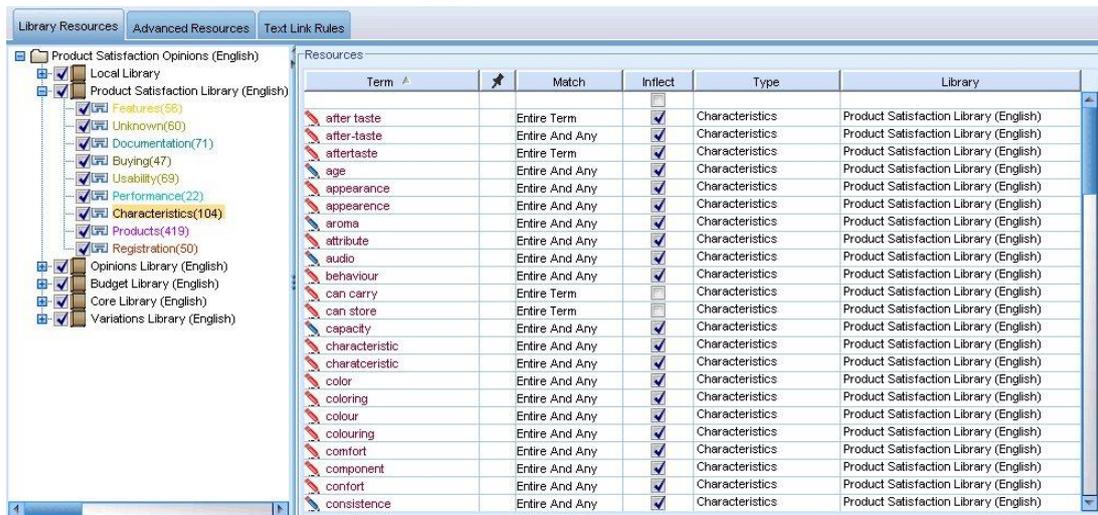
## 1) 유형 사전

유형 사전은 유형 이름 또는 레이블과 용어 목록으로 구성됩니다. 유형 사전은 편집기에 있는 라이브러리 자원 탭의 상단 왼쪽 및 중앙 분할창에서 관리됩니다. 메뉴에서 보기 > 자원 편집기를 사용하여 이 보기에 액세스할 수 있습니다(대화형 워크벤치 세션에 있는 경우). 그렇지 않으면, 템플릿 편집기에서 특정 템플릿에 대한 사전을 편집할 수 있습니다.

추출 엔진이 텍스트 데이터를 읽을 때, 유형 사전에 정의된 용어와 텍스트에서 발견된 단어를 비교합니다. 용어는 언어학적 자원의 유형 사전에 있는 단어 또는 문구입니다.

단어가 용어와 매치될 때, 이 단어는 해당 용어에 대한 유형 이름에 지정됩니다. 자원이 추출 동안 읽혀지면, 텍스트에서 발견된 용어는 추출 결과 분할창에서 개념이 되기 전에 몇 개의 처리 단계를 거칩니다. 동일한 유형 사전에 속하는 여러 용어가 추출 엔진에 의해 동의어인 것으로 판별되면, 가장 자주 발생하는 용어 아래에서 그룹화되고 추출 결과 분할창에서 개념이라고 합니다. 예를 들어, 용어 question과 query가 끝에서 개념 이름 question 아래에 나타날 수 있습니다.

그림 1. 라이브러리 트리 및 용어 분할창



유형 사전 목록은 왼쪽에 있는 라이브러리 트리 분할창에 표시됩니다. 각 유형 사전의 내용은 중앙 분할창에 나타납니다. 유형 사전은 용어 목록보다 많은 용어로 구성됩니다. 텍스트 데이터의 단어 및 단어 문구가 유형 사전에 정의된 용어에 매치되는 방식은 정의된 매치 옵션으로 판별됩니다. **매치 옵션**은 텍스트 데이터의 후보 단어 또는 문구에 대해 용어가 고정(anchor)되는 방법을 지정합니다. 자세한 정보는 용어 추가 주제를 참조하십시오.

또한, 자동으로 용어의 굴절된 양식을 생성하고 사전에 추가할 것인지 여부를 지정하여 유형 사전에서 용어를 확장할 수 있습니다. 굴절된 양식을 생성하여, 자동으로 단수 용어의 복수 양식, 복수 용어의 단수 양식, 형용사를 유형 사전에 추가합니다. 자세한 정보는 용어 추가의 내용을 참조하십시오.

**참고:** 유형 사전에는 없고 텍스트에서는 추출된 대부분의 언어의 경우, 개념은 자동으로 <Unknown>으로 유형이 지정됩니다.

## 용어에 별표 사용

사이에 공백 없이 다른 단어를 함께 결합하여 새 단어를 작성하는 교착어를 다루는 경우에 용어에 별표(\*)를 사용하는 방법이 특히 유용합니다. 예를 들어, 독일어 *Übernachtungspreis*는 *Übernachtung* + *s* + *Preis*로 구성됩니다.

예를 들어, Budget 유형에서 *preis\**를 검색하는 경우, *preiserhöhung* 등의 추출된 개념과 매치됩니다. 동일한 방법으로 *\*preis*가 *Übernachtung*과 매치되며 *\*preis\**가 *Übernachtungspreiserhöhung*과 매치됩니다.

### (1) 내장 유형

IBM® SPSS® Modeler Text Analytics 는 제공된 라이브러리와 컴파일된 자원 양식의 형태인 언어학적 자원 세트와 함께 제공됩니다. 제공된 라이브러리는 <Location>, <Organization>, <Person>, <Product>와 같은 내장 유형 사전 세트를 포함합니다.

추출 엔진은 이러한 유형 사전을 사용하여 추출하는 개념에 유형을 지정합니다(예: *paris* 개념에 <Location> 유형 지정). 내장 유형 사전에 상당수의 용어가 정의되어 있긴 하지만 모든 가능성을 다루지는 않습니다. 따라서 직접 추가하거나 작성할 수 있습니다. 제공된 특정 유형 사전의 콘텐츠에 대한 설명은 유형 특성 대화 상자의 주석(Annotation)을 읽으십시오. 트리에서 유형을 선택하고 컨텍스트 메뉴에서 **편집 > 특성**을 선택하십시오.

**참고:**

제공된 라이브러리 이외에 컴파일된 자원(역시 추출 엔진이 사용함)은 내장 유형 사전을 보완하는 상당수의 정의를 포함하지만 해당 콘텐츠는 제품에 표시되지 않습니다. 그러나 컴파일된 사전이 유형 지정한 용어를 다른 사전에 강제 실행할 수 있습니다. 자세한 정보는 용어 강제 실행의 내용을 참조하십시오.

### (2) 유형 작성

유사한 용어를 쉽게 그룹화할 수 있도록 유형 사전을 작성할 수 있습니다. 이 사전에 나타나는 용어가 추출 프로세스 중에 발견되면 이 유형 이름에 지정되고 개념 이름으로 추출됩니다. 라이브러리를 작성할 때마다 용어 입력을 즉시 시작할 수 있도록 빈 유형 라이브러리가 항상 포함됩니다.

식품에 대한 텍스트를 분석하고 채소류에 관한 용어를 그룹화하려면 직접 <Vegetables> 유형 사전을 작성할 수 있습니다. 그리고 나서 텍스트에 나타날 중요한 용어라고 생각되면 carrot, broccoli, spinach와 같은 용어를 추가할 수 있습니다. 그런 다음 추출 동안 이러한 용어가 발견되면 개념으로 추출되어 <Vegetables> 유형에 지정됩니다.

용어의 굴절된 양식을 생성하도록 선택할 수 있기 때문에 단어 또는 표현식의 모든 양식을 정의하지 않아도 됩니다. 이 옵션을 선택하면 추출 엔진이 이 유형에 속한 다른 양식 중에서 용어의 단수 또는 복수 양식을 자동으로 인식합니다. 동사나 형용사의 굴절된 양식을 원할 가능성이 없기 때문에 이 옵션은 유형에 주로 명사가 포함된 경우 특히 유용합니다.

유형 특성 대화 상자는 다음 필드를 포함합니다.

**이름.** 작성할 유형 사전에 제공하는 이름입니다. 유형 이름에(특히, 두 개 이상의 유형 이름이 같은 단어로 시작하는 경우) 공백을 사용하지 말 것을 권장합니다.

 **참고:** 유형 이름과 기호 사용에 대한 몇 가지 제약조건이 있습니다. 예를 들어, "@" 또는 "!"와 같은 기호를 이름에서 사용하지 마십시오.

**기본 매치.** 기본 매치 속성은 이 용어를 텍스트 데이터와 매치시킬 방법을 추출 엔진에 알려 줍니다. 이 유형 사전에 용어를 추가할 때마다 이는 자동으로 지정되는 매치 속성입니다. 용어 목록에서 수동으로 항상 매치 선택을 변경할 수 있습니다. 옵션은 **전체 용어, 시작, 끝, 모두, 시작 또는 끝, 전체 및 시작, 전체 및 끝, 전체 및 (시작 또는 끝), 전체(복합어 없음)**입니다. 자세한 정보는 용어 추가의 내용을 참조하십시오.

**추가 대상.** 이 필드는 새 유형 사전을 작성할 라이브러리를 표시합니다.

**기본적으로 굴절된 양식 생성.** 이 옵션은 문법적 형태론을 사용하여 이 사전에 추가하는 용어의 유사 양식(예: 용어의 단수 또는 복수 양식)을 캡처하고 그룹화하도록 추출 엔진에 알립니다. 이 옵션은 유형에 주로 명사가 포함된 경우 특히 유용합니다. 이 옵션을 선택하면, 목록에서 수동으로 변경할 수 있긴 하지만 이 유형에 추가된 모든 새 용어가 자동으로 이 옵션을 갖게 됩니다.

**글꼴 색상.** 이 필드를 사용하여 이 유형의 결과를 인터페이스의 다른 유형의 결과와 구별할 수 있습니다. **상위 색상 사용**을 선택하는 경우, 이 유형 사전에도 기본 유형 색상이 사용됩니다. 이 기본 색상은 옵션 대화 상자에서 설정됩니다. 자세한 정보는 옵션: 표시 탭 주제를 참조하십시오. **사용자 정의를** 선택하는 경우, 드롭 다운 목록에서 색상을 선택하십시오.

**주석(Annotation).** 이 필드는 선택사항이며 임의의 주석이나 설명에 사용할 수 있습니다.

## 유형 사전 작성 방법

1. 새 유형 사전을 작성할 라이브러리를 선택하십시오.

2. 메뉴에서 **편집 > 새 유형**을 선택하십시오. 유형 특성 대화 상자가 열립니다.
3. **이름** 텍스트 상자에 유형 사전의 이름을 입력하고 원하는 옵션을 선택하십시오.
4. **확인**을 클릭하여 유형 사전을 작성하십시오. 새 유형이 라이브러리 트리 분할창에 표시되며 가운데 분할창에 나타납니다. 용어 추가를 즉시 시작할 수 있습니다. 추가 정보는 용어 추가의 내용을 참조하십시오.

**참고:** 이러한 지시사항은 자원 편집기 보기 또는 템플릿 편집기에서 변경하는 방법을 보여줍니다. 추출 결과 분할창, 데이터 분할창, 범주 분할창 또는 다른 보기의 군집 정의 대화 상자에서도 직접 이런 종류의 미세 조정을 수행할 수 있음을 명심하십시오. 자세한 정보는 추출 결과 세분화의 내용을 참조하십시오.

### (3) 용어 추가

라이브러리 트리 분할창은 라이브러리를 표시하며 펼쳐서 포함된 유형 사전을 표시할 수 있습니다. 가운데 분할창에서 용어 목록은 트리에서의 선택사항에 따라 선택된 라이브러리 또는 유형 사전의 용어를 표시합니다.

자원 편집기에서, 용어 분할창에서 또는 새 용어 추가 대화 상자를 통해 유형 사전에 용어를 직접 추가할 수 있습니다. 추가하는 용어는 단일 단어 또는 복합 단어입니다. 새 용어를 추가할 수 있도록 항상 목록 맨 위에서 공백 행을 찾습니다.

**참고:** 이러한 지시사항은 자원 편집기 보기 또는 템플릿 편집기에서 변경하는 방법을 보여줍니다. 추출 결과 분할창, 데이터 분할창, 범주 분할창 또는 다른 보기의 군집 정의 대화 상자에서도 직접 이런 종류의 미세 조정을 수행할 수 있음을 명심하십시오. 자세한 정보는 추출 결과 세분화의 내용을 참조하십시오.

### 용어 열

이 열에서 단일 또는 복합 단어를 셀에 입력하십시오. 용어가 나타나는 색상은 용어가 저장되거나 강제 실행되는 유형의 색상에 따라 다릅니다. 유형 특성 대화 상자에서 유형 색상을 변경할 수 있습니다. 자세한 정보는 유형 작성의 내용을 참조하십시오.

### 강제 실행 열

이 열에서 이 셀에 푸시핀 아이콘을 두면 추출 엔진이 다른 라이브러리에서 이 동일 용어의 다른 발생을 무시함을 알게 됩니다. 자세한 정보는 용어 강제 실행의 내용을 참조하십시오.

## 매치 열

이 열에서 이 용어를 텍스트 데이터와 매치시킬 방법을 추출 엔진에 알려 줄 매치 옵션을 선택 하십시오. 예제는 테이블을 참조하십시오. 유형 특성을 편집하여 기본값을 변경할 수 있습니다. 자세한 정보는 유형 작성의 내용을 참조하십시오. 메뉴에서 **편집 > 매치 변경**을 선택하십시오. 이러한 조합도 가능하기 때문에 기본 매치 옵션은 다음과 같습니다.

- **시작.** 사전의 용어가 텍스트에서 추출된 개념의 첫 번째 단어와 매치하면 이 유형이 지정됩니다. 예를 들어, apple을 입력하면 apple tart가 매치됩니다.
- **끝.** 사전의 용어가 텍스트에서 추출된 개념의 마지막 단어와 매치하면 이 유형이 지정됩니다. 예를 들어, apple을 입력하면 cider apple이 매치됩니다.
- **모두.** 사전의 용어가 텍스트에서 추출된 개념의 임의 단어와 매치하면 이 유형이 지정됩니다. 예를 들어, apple을 입력하면 모두 옵션은 apple tart, cider apple, cider apple tart를 동일한 방법으로 유형 지정합니다.
- **전체 용어.** 텍스트에서 추출된 전체 개념이 사전의 정확한 용어와 매치하면 이 유형이 지정됩니다. 용어를 **전체 용어**로 추가하면 **전체 및 시작**, **전체 및 끝**, **전체 및 모두** 또는 **전체(복합어 없음)**가 용어 추출을 강제 실행합니다.  
뿐만 아니라 <Person> 유형은 두 개의 파트 이름(예: *edith piaf* 또는 *mohandas gandhi*)만 추출하기 때문에 성이 언급되지 않을 때 이름을 추출하려는 경우 이 유형 사전에 명시적으로 이름을 추가할 수 있습니다. 예를 들어, *edith*의 인스턴스를 이름으로 모두 포착하려면 **전체 용어** 또는 **전체 및 시작**을 사용하여 <Person> 유형에 edith를 추가해야 합니다.
- **전체(복합어 없음).** 텍스트에서 추출된 전체 개념이 사전의 정확한 용어와 매치하면 이 유형이 지정되며, 추출이 중지되어 추출이 용어를 더 이상 복합어와 매치하지 못합니다. 예를 들어, apple을 입력하면 **전체(복합어 없음)** 옵션이 apple을 유형 지정하고 어딘가 다른 곳에서 강제 실행되지 않는 한 복합어 apple sauce를 추출하지 않습니다.

다음 표에서는 apple 용어가 유형 사전에 있다고 가정하십시오. 매치 옵션에 따라 이 테이블은 텍스트에서 발견되면 추출되고 유형 지정되는 개념을 보여줍니다.

표 1. 매치 예제

용어에 대한 매 치 옵션	추출된 개념			
 apple	apple	apple tart	ripe apple	homemade apple tart
전체 용어	<input checked="" type="checkbox"/>			
시작(Start)		<input checked="" type="checkbox"/>		
끝			<input checked="" type="checkbox"/>	
시작 또는 끝		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	
전체 및 시작	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		
전체 및 끝	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	
전체 및 (시작 또는 끝)	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	
모두		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
전체 및 모두	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
전체(복합어 없음)	<input checked="" type="checkbox"/>	추출되지 않음	추출되지 않음	추출되지 않음

## 굴절 열

이 열에서 모두 함께 그룹화되도록 추출 엔진이 추출 중에 이 용어의 굴절된 양식을 생성해야 하는지 여부를 선택하십시오. 이 열의 기본값은 유형 특성에 정의되어 있지만 이 열에서 직접 케이스별로 이 옵션을 변경할 수 있습니다. 메뉴에서 **편집 > 굴절 변경**을 선택하십시오.

## 유형 열

이 열의 드롭 다운 목록에서 유형 사전을 선택하십시오. 유형 목록은 라이브러리 트리 분할창에서 사용자의 선택에 따라 필터링됩니다. 목록의 첫 번째 유형은 항상 라이브러리 트리 분할창에서 선택된 기본 유형입니다. 메뉴에서 **편집 > 유형 변경**을 선택하십시오.

## 라이브러리 열

이 열에 용어가 저장된 라이브러리가 나타납니다. 용어를 라이브러리 트리 분할창의 다른 유형으로 끌어서 놓아 라이브러리를 변경할 수 있습니다.

### 유형 사전에 단일 용어를 추가하는 방법

1. 라이브러리 트리 분할창에서 용어를 추가할 유형 사전을 선택하십시오.
2. 가운데 분할창의 용어 목록에서 사용 가능한 첫 번째 빈 셀에 용어를 입력하고 이 용어에 원하는 옵션을 설정하십시오.

### 유형 사전에 여러 용어를 추가하는 방법

1. 라이브러리 트리 분할창에서 용어를 추가할 유형 사전을 선택하십시오.
2. 메뉴에서 **도구 > 새 용어**를 선택하십시오. 새 용어 추가 대화 상자가 열립니다.
3. 용어를 입력하거나 용어 세트를 복사해서 붙여넣어 선택된 유형 사전에 추가할 용어를 입력하십시오. 여러 용어를 입력하는 경우, 옵션 대화 상자에 정의된 구분자를 사용하여 구분하고 새 행에서 각 용어를 추가해야 합니다. 자세한 정보는 옵션 설정 주제를 참조하십시오.
4. **확인**을 클릭하여 용어를 사전에 추가하십시오. 매치 옵션은 이 유형 라이브러리의 기본 옵션으로 자동으로 설정됩니다. 대화 상자가 닫히고 새 용어가 사전에 나타납니다.

#### (4) 용어 강제 실행

용어를 특정 유형에 지정하려면 해당 유형 사전에 추가할 수 있습니다. 그러나 이름이 동일한 용어가 여러 개 있으면 추출 엔진이 사용해야 하는 유형을 알아야 합니다. 따라서 사용해야 하는 유형을 선택하도록 프롬프트가 표시됩니다. 이를 유형에 용어를 **강제 실행**한다고 합니다. 이 옵션은 컴파일된 (내부, 편집 불가능) 사전의 유형 할당을 대체하는 경우 가장 유용합니다. 일반적으로 중복 용어를 전적으로 피하는 것이 좋습니다.

강제 실행은 이 용어의 다른 발생을 **제거**하지 않습니다. 오히려 추출 엔진이 이를 무시합니다. 용어를 강제 실행하거나 강제 실행을 해제하여 사용해야 하는 발생을 나중에 변경할 수 있습니다. 공용 라이브러리를 추가하거나 공용 라이브러리를 업데이트하는 경우에도 유형 사전에 용어를 강제 실행해야 합니다.

용어 분할창의 두 번째 열인 강제 실행 열에서 강제 실행되거나 무시된 용어를 볼 수 있습니다. 푸시핀 아이콘이 나타나는 경우 이는 이 용어 발생이 강제 실행되었음을 의미합니다. 검은색 X 아이콘이 나타나는 경우 이는 다른 곳에 강제 실행되었기 때문에 추출 중에 이 용어 발생이 무

시뮬을 의미합니다. 또한 용어를 강제 실행하면 강제 실행된 유형에 대한 색상으로 용어가 나타납니다. 이는 Type 1과 Type 2 모두에 있는 용어를 Type 1에 강제 실행한 경우 창에 이 용어가 표시될 때는 언제든지 Type 1에 대해 정의된 글꼴 색상으로 나타남을 의미합니다.

아이콘을 두 번 클릭하여 상태를 변경할 수 있습니다. 용어가 다른 곳에 나타나는 경우, 사용하여 하는 발생을 선택할 수 있도록 충돌 해결 대화 상자가 열립니다.

## (5) 유형 이름 변경

유형 사전의 이름을 변경하거나 유형 특성을 편집하여 다른 사전 설정을 변경할 수 있습니다.

❖ **중요사항:** 유형 이름에(특히, 두 개 이상의 유형 이름이 같은 단어로 시작하는 경우) 공백을 사용하지 말 것을 권장합니다. 코어 또는 Opinions 라이브러리의 유형 이름을 변경하거나 기본 매치 속성을 변경하지 말 것을 권장합니다.

### 유형 이름 변경 방법

1. 라이브러리 트리 분할창에서 이름을 변경할 유형 사전을 선택하십시오.
2. 마우스 오른쪽 단추를 클릭하고 컨텍스트 메뉴에서 **유형 특성**을 선택하십시오. 유형 특성 대화 상자가 열립니다.
3. 이름 텍스트 상자에 유형 사전의 새 이름을 입력하십시오.
4. **확인**을 클릭하여 새 이름을 승인하십시오. 새 유형 이름이 라이브러리 트리 분할창에 표시됩니다.

## (6) 유형 이동

라이브러리 내 다른 위치 또는 트리의 다른 라이브러리로 유형 사전을 끌 수 있습니다.

### 라이브러리에서 유형을 다시 정렬하는 방법

1. 라이브러리 트리 분할창에서 이동할 유형 사전을 선택하십시오.
2. 메뉴에서 **편집 > 위로 이동**을 선택하여 유형 사전을 라이브러리 트리 분할창에서 한 위치 위로 이동하거나 **편집 > 아래로 이동**을 선택하여 한 위치 아래로 이동하십시오.

### 다른 라이브러리로 유형을 이동하는 방법

1. 라이브러리 트리 분할창에서 이동할 유형 사전을 선택하십시오.

2. 마우스 오른쪽 단추를 클릭하고 컨텍스트 메뉴에서 **유형 특성**을 선택하십시오. 유형 특성 대화 상자가 열립니다. (다른 라이브러리로 유형을 끌어서 놓을 수도 있습니다.)
3. 추가 대상 목록 상자에서 유형 사전을 이동할 라이브러리를 선택하십시오.
4. **확인**을 클릭하십시오. 대화 상자가 닫히며, 유형은 이제 사용자가 선택한 라이브러리에 있습니다.

## (7) 유형 사용 안함 및 삭제

일시적으로 유형 사전을 제거하려면 라이브러리 트리 보기에서 사전 이름 왼쪽의 확인 상자를 선택 취소하여 사용 안함으로 설정할 수 있습니다. 이는 라이브러리에 사전을 유지하지만 충돌 검사 중 및 추출 프로세스 중에는 콘텐츠를 무시함을 나타냅니다.

라이브러리에서 유형 사전을 영구적으로 삭제할 수도 있습니다.

### 유형 사전을 사용 안함으로 설정하는 방법

1. 라이브러리 트리 분할창에서 사용 안함으로 설정할 유형 사전을 선택하십시오.
2. 스페이스바를 클릭하십시오. 유형 이름 왼쪽에 있는 선택란이 지워집니다.

### 유형 사전 삭제 방법

1. 라이브러리 트리 분할창에서 삭제할 유형 사전을 선택하십시오.
2. 메뉴에서 **편집 > 삭제**를 선택하여 유형 사전을 삭제하십시오.

## 2) 대체/동의어 사전

*대체 사전*은 하나의 대상 용어에서 유사한 용어를 그룹화하는 데 도움이 되는 용어 컬렉션입니다. 대체 사전은 라이브러리 자원 탭의 맨 아래 분할창에서 관리됩니다. 메뉴에서 **보기 > 자원 편집기**를 사용하여 이 보기에 액세스할 수 있습니다(대화형 워크벤치 세션에 있는 경우). 그렇지 않으면, 템플릿 편집기 에서 특정 템플릿에 대한 사전을 편집할 수 있습니다.

이 사전에서 두 가지 대체 양식인 *동의어* 및 *선택적 요소*를 정의합니다. 이 분할창에서 탭을 클릭하여 두 양식 사이에 전환할 수 있습니다.

텍스트 데이터에서 추출을 실행한 후, 동의어나 다른 개념의 굴절된 양식인 몇 개의 개념을 찾을 수 있습니다. 선택적 요소 및 동의어를 식별하여, 추출 엔진이 이를 단일 대상 용어에 매핑하도록 할 수 있습니다.

동의어 및 선택적 요소를 사용하여 대체하면 빈도 문서 개수가 높은 더 유의하고 대표적인 개념으로 개념이 결합되어 추출 결과 분할창에서 개념 수가 감소됩니다.

## 동의어

동의어는 동일한 의미를 가지고 있는 두 개 이상의 단어를 연관시킵니다. 동의어를 사용하여 해당 약어가 있는 용어를 그룹화하거나 일반적으로 맞춤법이 틀린 용어를 올바른 맞춤법으로 그룹화할 수도 있습니다. 동의어 탭에서 이러한 동의어를 정의할 수 있습니다.

동의어 정의는 두 부분으로 구성됩니다. 첫 번째는 **대상 용어**로, 추출 엔진이 그 아래에서 모든 동의어 용어를 그룹화하도록 할 용어입니다. 이 대상 용어가 다른 대상 용어의 동의어로 사용되거나 제외되지 않으면, 추출 결과 분할창에 나타내는 개념이 됩니다. 두 번째는 대상 용어 아래에서 그룹화될 동의어 목록입니다.

예를 들어, automobile을 vehicle로 바꾸려는 경우, automobile은 동의어이고 vehicle은 대상 용어입니다.

**동의어** 열에 단어를 입력할 수 있지만, 추출 동안 단어가 발견되지 않고 용어의 매치 옵션이 Entire인 경우 대체는 발생할 수 없습니다. 그러나 대상 용어는 이 용어 아래에서 그룹화될 동의어에 대해 추출되지 않아도 됩니다.

## 선택적 요소

선택적 요소는 텍스트에서 약간 다르게 나타나더라도 유사한 용어를 함께 유지하기 위해 추출 동안 무시될 수 있는 선택적 단어를 복합 용어에서 식별합니다. 선택적 요소는 복합 용어에서 제거된 경우 다른 용어와의 매치를 작성할 수 있는 단일 단어입니다. 이 단일 단어는 복합 용어 어디에서나(시작, 중간 또는 끝에) 나타날 수 있습니다. 선택사항 탭에서 선택적 요소를 정의할 수 있습니다.

예를 들어, 용어 ibm 및 ibm corp를 함께 그룹화하려면, corp가 이 경우에 선택적 요소로 처리되도록 선언해야 합니다. 다른 예에서, 용어 access를 선택적 요소가 되도록 지정하고 추출 동안 internet access speed 및 internet speed 둘 다가 발견되는 경우, 가장 자주 발생하는 용어 아래에서 함께 그룹화됩니다.

### (1) 동의어 정의

동의어 탭에서 테이블의 맨 위에 있는 빈 행에 동의어 정의를 입력할 수 있습니다. 대상 용어

및 동의어를 정의하여 시작하십시오. 또한 이 정의를 저장하려는 라이브러리를 선택할 수도 있습니다. 추출 중에 모든 동의어 발생은 최종 추출에서 대상 용어 아래에 그룹화됩니다. 자세한 정보는 용어 추가의 내용을 참조하십시오.

예를 들어, 텍스트 데이터에 많은 원격 통신 정보가 포함된 경우에는 cellular phone, wireless phone, mobile phone 용어가 있습니다. 이 예제에서는 cellular와 mobile을 wireless의 동의어로 정의하려고 합니다. 이러한 동의어를 정의하는 경우, 추출된 모든 cellular phone 및 mobile phone 발생은 wireless phone과 동일한 용어로 간주되며 용어 목록에 함께 나타납니다.

유형 사전을 작성할 때 용어를 입력한 후 해당 용어에 대해 3개 또는 4개의 동의어를 생각할 수 있습니다. 이러한 경우, 모든 용어를 입력한 후 대상 용어를 대체 사전에 입력한 후 동의어를 끌어갈 수 있습니다.

동의어 대체는 동의어의 굴절된 양식(예: 복수 양식)에도 적용됩니다. 컨텍스트에 따라 용어 대체 방법에 대한 제약조건을 둘 수 있습니다. 일정 문자를 사용하여 동의어 처리가 진행되어야 하는 정도에 대한 제한을 둘 수 있습니다.

- **느낌표(!)**. 느낌표가 동의어 바로 앞에 오는 경우(!synonym) 이는 동의어의 굴절된 양식이 대상 용어로 대체되지 않음을 표시합니다. 그러나 대상 용어 바로 앞에 오는 느낌표(!target-term)는 복합 대상 용어 또는 변량의 일부가 추가 대체를 수신하지 않음을 의미합니다.
- **별표(\*)**. 동의어 바로 뒤에 위치한 별표(예: synonym\*)는 이 단어가 대상 용어로 대체됨을 의미합니다. 예를 들어, manage\*를 동의어로, management를 대상으로 정의한 경우 associate managers는 대상 용어 associate management로 대체됩니다. 또한 단어 뒤에 공백과 별표를 추가(synonym \*)할 수 있습니다(예: internet \*). 대상을 internet으로, 동의어를 internet \* 및 web \*로 정의한 경우 internet access card 및 web portal은 internet으로 대체됩니다. 이 사전에서는 별표 와일드카드를 단어나 문자열을 시작할 수 없습니다.
- **캐럿(^)**. 동의어 앞에 오는 캐럿과 공백(예: ^ synonym)은 용어가 동의어로 시작하는 경우에만 동의어 그룹화가 적용됨을 의미합니다. 예를 들어, ^ wage를 동의어로, income을 대상으로 정의하고 두 용어 모두 추출된 경우에는 income 용어 아래에 함께 그룹화됩니다. 그러나 minimum wage 및 income이 추출된 경우에는 minimum wage가 wage로 시작하지 않기 때문에 함께 그룹화되지 않습니다. 공백은 이 기호와 동의어 사이에 위치해야 합니다.
- **달러 부호(\$)**. 동의어 다음에 오는 공백과 달러 부호(예: synonym \$)는 용어가 동의어로 끝나는 경우에만 동의어 그룹화가 적용됨을 의미합니다. 예를 들어, cash \$를 동의어로, money를 대상으로 정의하고 두 용어 모두 추출된 경우에는 money 용어 아래에 함께 그룹화됩니다. 그러나 cash cow 및 money가 추출된 경우에는 cash cow가 cash로 끝나지 않기 때문에 함께 그룹화되지 않습니다. 공백은 이 기호와 동의어 사이에 위치해야 합니다.
- **캐럿(^) 및 달러 부호(\$)**. 캐럿 및 달러 부호가 함께 사용되는 경우(예: ^ synonym \$) 정확히 일치하는 경우에만 용어가 동의어와 매치됩니다. 이는 동의어 그룹화가 발생하려면 추출된 용어에서 동의어 앞이나 뒤에 단어가 나타날 수 없음을 의미합니다. 예를 들어, van만 truck과 함께 그룹화되는 반면 marie van guerin은 변경되지 않은 채로 남도록 ^ van \$를 동의어로, truck을 대상으로 정의하려고 합니다. 또한 캐럿 및 달러 부호를 사용하여 동의어를 정의하고 이 단어가 소스 텍스트 어딘가에 나타날 때마다 동의어가 자동으로 추출됩니다.

## 동의어 항목 추가 방법

1. 대체 분할창이 표시된 상태에서 왼쪽 하단 모서리에 있는 **동의어** 탭을 클릭하십시오.
2. 테이블의 맨 위의 빈 줄에서 대상 열에 대상 용어를 입력하십시오. 입력한 대상 용어는 색상으로 나타납니다. 이 색상은 용어가 나타나거나 강제 실행되는(해당 경우) 유형을 나타냅니다. 용어가 검은색으로 나타나는 경우, 어떤 유형 사전에도 나타나지 않음을 의미합니다.
3. 대상의 오른쪽에 있는 두 번째 셀에서 클릭하고 동의어 세트를 입력하십시오. 옵션 대화 상자에 정의된 대로 글로벌 구분자를 사용하여 각 항목을 분리하십시오. 자세한 정보는 옵션 설정 주제를 참조하십시오. 입력하는 용어는 색상으로 나타납니다. 이 색상은 용어가 나타나는 유형을 나타냅니다. 용어가 검은색으로 나타나는 경우, 어떤 유형 사전에도 나타나지 않음을 의미합니다.
4. 마지막 셀에서 클릭하여 이 동의어 정의를 저장하려는 라이브러리를 선택하십시오.

 **참고:** 이러한 지시사항은 자원 편집기 보기 또는 템플릿 편집기 에서 변경하는 방법을 보여줍니다. 추출 결과 분할창 , 데이터 분할창 , 범주 분할창 또는 다른 보기의 군집 정의 대화 상자에서도 직접 이런 종류의 미세 조정을 수행할 수 있음을 명심하십시오. 자세한 정보는 추출 결과 세분화의 내용을 참조하십시오.

### (2) 선택적 요소 정의

선택사항 탭에서 원하는 라이브러리에 대해 선택적 요소를 정의할 수 있습니다. 이러한 항목은 각 라이브러리에 대해 함께 그룹화됩니다. 라이브러리가 라이브러리 트리 창에 추가되는 즉시 비어 있는 선택적 요소 행이 선택사항 탭에 추가됩니다.

모든 항목은 자동으로 소문자 단어로 변환됩니다. 추출 엔진은 항목을 텍스트에서 소문자와 대문자 단어 모두와 매치시킵니다.

 **참고:** 용어는 옵션 대화 상자에 정의된 구분자를 사용하여 구분됩니다. 자세한 정보는 옵션 설정 주제를 참조하십시오. 입력하는 선택적 요소에 용어의 일부와 동일한 구분자가 포함된 경우 앞에 백슬래시가 와야 합니다.

## 항목 추가 방법

1. 대체 분할창이 표시된 상태에서 편집기 왼쪽 하단 모서리에 있는 선택사항 탭을 클릭하십시오.
2. 이 항목을 추가할 라이브러리에 대해 선택적 요소 열에서 셀을 클릭하십시오.
3. 선택적 요소를 입력하십시오. 옵션 대화 상자에 정의된 대로 글로벌 구분자를 사용하여 각 항목을 분리하십시오. 자세한 정보는 옵션 설정 주제를 참조하십시오.

### (3) 대체 사용 안함 및 삭제

사전에서 사용 안함으로 설정하여 일시적인 방법으로 항목을 제거할 수 있습니다. 항목을 사용 안함으로 설정하면 추출 중에 항목을 무시합니다.

대체 사전에서 더 이상 사용하지 않는 항목도 삭제할 수 있습니다.

항목을 사용 안함으로 설정하는 방법

1. 사전에서 사용 안함으로 설정할 항목을 선택하십시오.
2. 스페이스바를 클릭하십시오. 항목 왼쪽에 있는 확인 상자가 지워집니다.

참고: 항목 왼쪽에 있는 확인 상자를 선택 취소하여 사용 안함으로 설정할 수도 있습니다.

동의어 항목 삭제 방법

1. 사전에서 삭제할 항목을 선택하십시오.
2. 메뉴에서 **편집 > 삭제**를 선택하거나 키보드의 **Delete** 키를 누르십시오. 항목이 더 이상 사전에 없습니다.

선택적 요소 항목 삭제 방법

1. 사전에서 삭제할 항목을 두 번 클릭하십시오.
2. 용어를 수동으로 삭제하십시오.
3. Enter를 눌러 변경사항을 적용하십시오.

### 3) 제외 사전

*제외 사전*은 단어, 문구 또는 부분 문자열 목록입니다. 제외 사전의 항목과 매치하거나 이를 포함하는 용어는 추출에서 무시되거나 제외됩니다. 제외 사전은 편집기의 오른쪽 분할창에서 관리됩니다. 일반적으로 이 목록에 추가하는 용어는 연속성을 위해 텍스트에서 사용되지만 텍스트에 중요한 것을 실제로 추가하지 않으며 추출 결과를 혼란스럽게 할 수 있는 기입 단어 또는 문구입니다. 이러한 용어를 제외 사전에 추가하여 추출되지 않게 할 수 있습니다.

제외 사전은 편집기에서 라이브러리 자원 탭의 오른쪽 상단 분할창에서 관리됩니다. 메뉴에서 **보기 > 자원 편집기**를 사용하여 이 보기에 액세스할 수 있습니다(대화형 워크벤치 세션에 있는 경우). 그렇지 않으면, 템플릿 편집기에서 특정 템플릿에 대한 사전을 편집할 수 있습니다.

제외 사전에서 테이블 맨 위의 빈 줄에 단어, 문구 또는 부분 문자열을 입력할 수 있습니다. 하나 이상의 단어 또는 별표를 와일드카드로 사용하는 부분 단어로 제외 사전에 문자열을 추가할 수 있습니다. 제외 사전에 선언된 항목은 개념이 추출되지 않도록 하는 데 사용됩니다. 인터페이스의 어딘가 다른 곳(예: 유형 사전)에도 항목이 선언된 경우, 취소선으로 표시되어 현재 제외됨을 나타냅니다. 이 문자열은 텍스트 데이터에 나타나거나 적용될 유형 사전의 일부로 선언되지 않아도 됩니다.

**참고:** 동의어 항목에서 대상의 역할도 하는 개념을 제외 사전에 추가하면 대상과 모든 동의어도 제외됩니다. 자세한 정보는 동의어 정의의 내용을 참조하십시오.

## 와일드카드 사용(\*)

별표 와일드카드를 사용하여 제외 항목을 부분 문자열로 간주하도록 표시할 수 있습니다. 추출 엔진이 찾은 제외 사전에 입력된 문자열로 시작하거나 끝나는 단어가 포함된 용어가 최종 추출에서 제외됩니다. 그러나 와일드카드 사용이 허용되지 않는 두 가지 경우가 있습니다.

- 별표 와일드카드가 앞에 오는 대시 문자(-)(예: \*-)
- 별표 와일드카드가 앞에 오는 어포스트로피(')(예: \*'s)

표 1. 제외 항목 예제

항목	예제	결과
단어	<i>next</i>	<i>next</i> 단어가 포함된 경우 개념(또는 용어)이 추출되지 않습니다.
문구	<i>for example</i>	<i>for example</i> 문구가 포함된 경우 개념(또는 용어)이 추출되지 않습니다.
부분	<i>copyright*</i>	<i>copyright</i> 단어의 변형과 매치하거나 이를 포함하는 개념(또는 용어)(예: <i>copyrighted</i> , <i>copyrighting</i> , <i>copyrights</i> 또는 <i>copyright 2010</i> )을 제외합니다.
부분	<i>*ware</i>	<i>ware</i> 단어의 변형과 매치하거나 이를 포함하는 개념(또는 용어)(예: <i>freeware</i> , <i>shareware</i> , <i>software</i> , <i>hardware</i> , <i>beware</i> 또는 <i>silverware</i> )을 제외합니다.

## 항목 추가 방법

- 테이블의 맨 위의 빈 줄에 용어를 입력하십시오. 입력하는 용어는 색상으로 나타납니다. 이 색상은 용어가 나타나는 유형을 나타냅니다. 용어가 검은색으로 나타나는 경우, 어떤 유형 사전에도 나타나지 않음을 의미합니다.

## 항목을 사용 안함으로 설정하는 방법

제외 사전에서 사용 안함으로 설정하여 일시적으로 항목을 제거할 수 있습니다. 항목을 사용 안함으로 설정하면 추출 중에 항목을 무시합니다.

1. 제외 사전에서 사용 안함으로 설정할 항목을 선택하십시오.
2. 스페이스바를 클릭하십시오. 항목 왼쪽에 있는 확인 상자가 지워집니다.

 **참고:** 항목 왼쪽에 있는 선택란을 선택 취소하여 사용 안함으로 설정할 수도 있습니다.

## 항목 삭제 방법

제외 사전에서 필요하지 않은 항목을 삭제할 수 있습니다.

1. 제외 사전에서 삭제할 항목을 선택하십시오.
2. 메뉴에서 **편집 > 삭제**를 선택하십시오. 항목이 더 이상 사전에 없습니다.

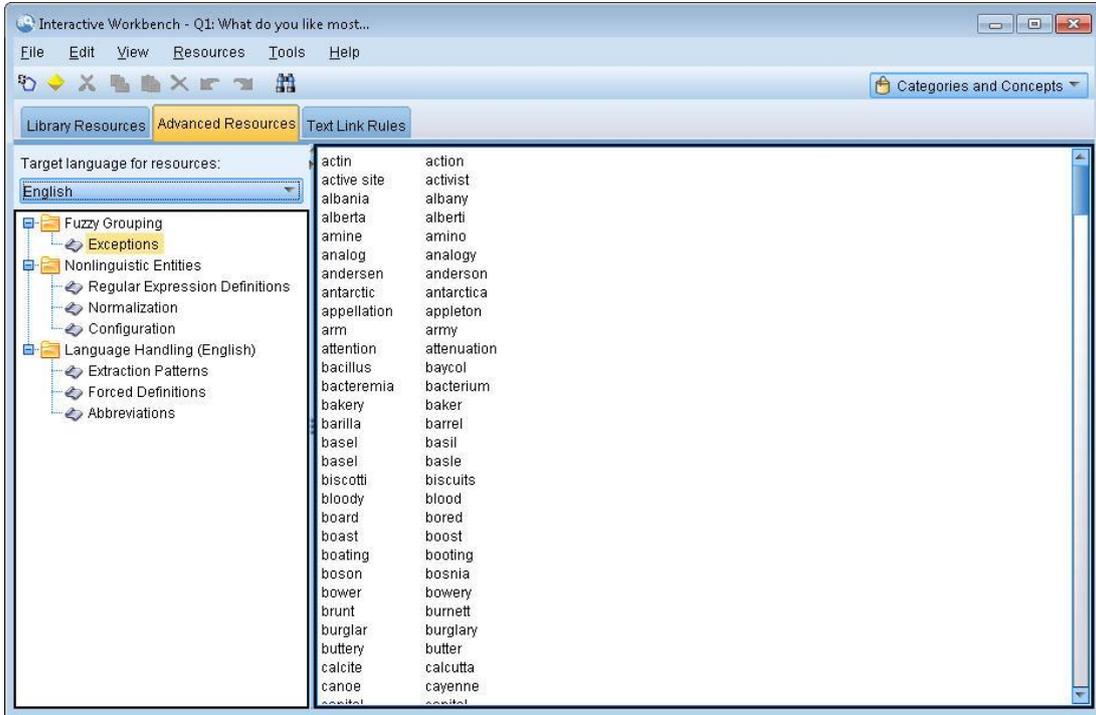
## 17. 고급 자원에 대한 정보

또한 유형, 제외 및 대체 사전 외에도, 퍼지 그룹화 설정 또는 비언어 유형 정의와 같은 다양한 고급 자원 설정에 대해 작업할 수 있습니다. 템플릿 편집기 또는 자원 편집기 보기에서 고급 자원 탭에서 이 자원에 대해 작업할 수 있습니다.

고급 자원 탭으로 이동할 때, 다음 정보를 편집할 수 있습니다.

- **자원에 대한 대상 언어.** 자원이 작성되고 조정될 언어를 선택하기 위해 사용됩니다. 자세한 정보는 자원의 대상 언어의 내용을 참조하십시오.
- **퍼지 그룹화(예외).** 퍼지 그룹화(맞춤법 오류 정정) 알고리즘에서 단어 쌍을 제외하기 위해 사용됩니다. 자세한 정보는 퍼지 그룹화의 내용을 참조하십시오.
- **비언어 엔티티.** 추출될 수 있는 비언어 항목과, 추출 동안 적용되는 정규식 및 정규화 규칙을 사용하거나 사용하지 않도록 설정하기 위해 사용됩니다. 자세한 정보는 비언어 엔티티의 내용을 참조하십시오.
- **언어 처리** 선택된 언어에 대해 문장을 구조화하고(추출 패턴 및 강제실행된 정의) 약어를 사용하는 특수 방식을 선언하기 위해 사용됩니다. 자세한 정보는 언어 처리의 내용을 참조하십시오.

그림 1. 텍스트 마이닝 템플릿 편집기 - 고급 자원 탭



**참고:** 정보를 빠르게 찾거나 섹션에 대해 일정한 변경사항을 작성하기 위해 찾기/바꾸기 도구 모음을 사용할 수 있습니다. 자세한 정보는 바꾸기의 내용을 참조하십시오.

## 고급 자원 편집

1. 편집할 자원 섹션을 찾고 선택하십시오. 내용은 오른쪽 분할창에 표시됩니다.
2. 필요한 경우, 내용을 자르거나, 복사하거나, 붙여넣기 위해 메뉴 또는 도구 모음을 사용하십시오.
3. 이 섹션에서 형식화 규칙을 사용하여 변경하려는 파일을 편집하십시오. 변경사항은 작성하는 즉시 저장됩니다. 이전 변경사항으로 되돌리려면 도구 모음에서 실행 취소 또는 다시 실행 화살표를 사용하십시오.

### 1) 찾기

일부 경우 특정 섹션에서 빨리 정보를 찾아야 합니다. 예를 들어, 텍스트 링크 분석을 수행하는 경우 수백 개의 매크로 및 패턴 정의를 가지고 있을 수 있습니다. 찾기 기능을 사용하여, 특정 규칙을 신속하게 찾을 수 있습니다. 섹션에서 정보를 검색하기 위해 찾기 도구 모음을 사용할 수 있습니다.

## 찾기 기능을 사용하려면 다음을 수행하십시오.

1. 검색하려고 하는 자원 섹션을 찾아서 선택하십시오. 편집기의 오른쪽 분할창에 내용이 표시됩니다.
2. 메뉴에서 **편집 > 찾기**를 선택하십시오. 편집 고급 자원 대화 상자의 상단 오른쪽에 찾기 도구 모음이 나타납니다.
3. 텍스트 상자에 검색할 단어 문자열을 입력하십시오. 도구 모음 단추를 사용하여 대소문자 구분, 부분 매치 및 검색 방향을 제어할 수 있습니다.
4. **찾기**를 클릭하여 검색을 시작하십시오. 매치가 발견되면 창에서 텍스트가 강조표시됩니다.
5. 다음 매치를 찾으려면 다시 **찾기**를 클릭하십시오.

 **참고:** 텍스트 링크 규칙 탭에서 작업할 때, 찾기 옵션은 소스 코드를 보고 있을 때만 사용할 수 있습니다.

## 2) 바꾸기

일부 경우에, 고급 자원에 대해 광범위하게 업데이트를 작성해야 할 수 있습니다. 바꾸기 기능은 내용에 대해 일정한 업데이트를 작성하는 데 도움이 될 수 있습니다.

## 바꾸기 기능을 사용하려면 다음을 수행하십시오.

1. 검색하고 바꿀 자원 섹션을 찾아서 선택하십시오. 편집기의 오른쪽 분할창에 내용이 표시됩니다.
2. 메뉴에서, **편집 > 바꾸기**를 선택하십시오. 바꾸기 대화 상자가 열립니다.
3. **찾을 문자열** 텍스트 상자에서 검색할 단어 문자열을 입력하십시오.
4. **바꿀 문자열** 텍스트 상자에서 발견된 텍스트 대신에 사용하려는 문자열을 입력하십시오.
5. 완전한 단어만 찾거나 바꾸려면 **전체 단어 매치만**을 선택하십시오.
6. 대소문자가 완전하게 매치하는 단어만 찾거나 바꾸려면 **대소문자 구분**을 선택하십시오.
7. 매치를 찾으려면 **다음 찾기**를 클릭하십시오. 매치가 발견되면 창에서 텍스트가 강조표시됩니다. 이 매치를 바꾸지 않으려면, 바꿀 매치를 찾을 때까지 다시 **다음 찾기**를 클릭하십시오.
8. 선택된 매치를 바꾸려면 **바꾸기**를 클릭하십시오.
9. 섹션에서 모든 매치를 바꾸려면 바꾸기를 클릭하십시오. 작성된 바꾸기 수와 함께 메시지가 열립니다.
10. 바꾸기 작성이 완료되면 **닫기**를 클릭하십시오. 대화 상자가 닫힙니다.

 **참고:** 바꾸기 오류를 작성한 경우, 대화 상자를 닫고 메뉴에서 **편집 > 실행 취소**를 선택하여 바꾸기를 실행 취소할 수 있습니다. 실행 취소할 변경사항마다 한 번씩 이를 수행해야 합니다.

### 3) 자원의 대상 언어

자원은 특정 텍스트 언어에 대해 작성됩니다. 이 자원이 조정되는 언어는 고급 자원 탭에서 정의됩니다. 필요한 경우 **자원에 대한 대상 언어** 콤보 상자에서 해당 언어를 선택하여 다른 언어로 전환할 수 있습니다. 또한 여기에 나열되는 언어는 자원으로 작성하는 텍스트 분석 패키지의 언어로 표시됩니다.

❖ **중요사항:** 드물게는 자원에서 언어를 변경해야 합니다. 그렇게 하면 자원이 더 이상 추출 언어와 매치하지 않은 때 문제가 발생할 수 있습니다. 드물게 사용되지만, 두 개 이상의 언어로 된 텍스트가 있을 것으로 예상하여 추출 동안 ALL 언어 옵션을 사용하려고 한 경우, 언어를 변경할 수 있습니다. 예를 들어 언어를 변경하여, 관심이 있는 2차 언어에 대한 추출 패턴, 약어 및 강제 실행 정의에 대한 자원을 처리하는 언어에 액세스할 수 있습니다. 그러나 작성한 자원 변경사항을 저장하거나 출판하기 전에 추출 시 관심이 있는 1차 언어로 다시 언어를 설정해야 합니다.

### 4) 퍼지 그룹화

텍스트 마이닝 노드 및 추출 설정에서 **최소 루트 문자 한계에 대한 맞춤법 수용**을 선택하면, 퍼지 그룹화 알고리즘을 사용할 수 있습니다.

퍼지 그룹화는 추출된 단어에서 모든 모음(첫 번째 모음 제외)과 이중 또는 삼중 자음을 임시로 스트리핑한 후 동일한지 보기 위해 비교하여 일반적으로 맞춤법이 틀린 단어나 거의 형성된 단어를 그룹화하는 데 도움이 됩니다. 추출 프로세스 동안, 퍼지 그룹화 기능은 추출된 용어에 적용되고 결과는 매치 발견 여부를 판별하기 위해 비교됩니다. 그러한 경우, 원래 용어는 최종 추출 목록에서 함께 그룹화됩니다. 데이터에서 가장 자주 발생하는 용어 아래에서 그룹화됩니다.

❗ **참고:** 비교되는 두 개의 용어가 여러 유형에 지정되면(〈Unknown〉 유형 제외), 퍼지 그룹화 기술이 이 쌍에 적용되지 않습니다. 다시 말하면, 기술을 적용하기 위해 용어가 동일한 유형이나 〈Unknown〉 유형에 속해야 합니다.

이 기능을 사용 가능하게 하고, 유사한 맞춤법의 두 단어가 올바르게 않게 함께 그룹화된 경우 퍼지 그룹화에서 제외할 수 있습니다. 고급 자원 탭의 예외 섹션에 매치된 쌍을 올바르게 않게 입력하여 이를 수행할 수 있습니다. 자세한 정보는 고급 자원에 대한 정보의 내용을 참조하십시오.

다음 예는 퍼지 그룹화 수행 방법을 보여줍니다. 퍼지 그룹화가 사용되면, 다음 단어는 동일하게 나타나고 다음 방식으로 매치됩니다.

```
color -> colr          mountain -> montn
colour -> colr         montana -> montn

modeling -> modlng     furniture -> furntr
modelling -> modlng    furnature -> furntr
```

이전 예에서, mountain과 montana를 함께 그룹화하는 작업에서 가장 제외하려고 합니다. 따라서, 다음 방식으로 예외 섹션에서 이 단어를 입력할 수 있습니다.

mountain      montana

❖ **중요사항:** 일부 경우에, 퍼지 그룹화 예외는 특정 동의어 규칙이 적용되기 때문에 2 단어가 쌍을 이루는 것을 중지하지 않습니다. 그러한 경우, 느낌표 와일드카드(!)와 함께 동의어를 입력하여 단어가 출력에서 동의어가 되는 것을 금지할 수 있습니다. 자세한 정보는 동의어 정의의 내용을 참조하십시오.

### 퍼지 그룹화 예외에 대한 형식화 규칙

- 해당 단 하나의 예외 쌍만 정의합니다.
- 단순어 또는 복합어를 사용합니다.
- 단어의 소문자만 사용합니다. 대문자 단어는 무시됩니다.
- 쌍에서 각 단어를 구분하려면 TAB 문자를 사용하십시오.

## 5) 비언어 엔티티

특정 종류의 데이터에 대해 작업할 때, 날짜, 주민등록번호, 퍼센트 또는 다른 비언어 엔티티 추출에 많은 흥미가 있을 수 있습니다. 이 엔티티는 엔티티를 사용하거나 사용하지 않도록 설정할 수 있는 구성 파일에서 명시적으로 선언됩니다. 자세한 정보는 구성의 내용을 참조하십시오. 추출 엔진에서 출력을 최적화하려면, 비언어 처리의 입력이 사전정의된 형식에 따라 유사한 엔티티를 그룹화하도록 정규화됩니다. 자세한 정보는 정규화의 내용을 참조하십시오.

**참고:** 추출 설정에서 비언어 엔티티 추출을 켜고 끌 수 있습니다.

### 사용 가능한 비언어 엔티티

다음 테이블의 비언어 엔티티를 추출할 수 있습니다. 유형 이름은 소괄호로 묶습니다.

표 1. 추출될 수 있는 비언어 엔티티

주소	<<Address>>
아미노산	<<Aminoacid>>

통화	(<Currency>)
날짜	(<Date>)
보류	(<Delay>)
숫자	(<Digit>)
이메일 주소	(<email>)
HTTP/URL 주소	(<url>)
IP 주소	(<IP>)
조직	(<Organization>)
퍼센트	(<Percent>)
제품	(<Product>)
단백질	(<Gene>)
전화번호	(<PhoneNumber>)
시간	(<Time>)
주민등록번호	(<SocialSecurityNumber>)
가중값 및 측도	(<Weights-Measures>)

## 처리를 위해 텍스트 정리

비언어 엔티티 추출이 발생하기 전에, 입력 텍스트가 정리됩니다. 이 단계 동안, 다음 용어 변경 사항이 작성되어, 비언어 엔티티가 식별되고 추출될 수 있습니다.

- 두 개 이상의 공백 시퀀스는 단일 공백으로 바뀝니다.
- 도표 작성은 공백으로 바뀝니다.
- 하나의 행 끝 문자 또는 시퀀스 문자는 공백으로 바뀌며, 여러 행 끝 시퀀스는 단락 끝으로 표시됩니다. 행 끝은 캐리지 리턴(CR) 및 줄 바꾸기(LF) 또는 둘 다로 표시될 수 있습니다.
- HTML 및 XML 태그는 임시로 스트립되고 무시됩니다.

### (1) 정규식 정의

비언어 엔티티를 추출할 때, 정규식을 식별하는 데 사용되는 정규식 정의에 추가하거나 편집할 수 있습니다. 이는 고급 자원 탭의 **정규식 정의** 섹션에서 수행됩니다. 자세한 정보는 고급 자원에 대한 정보의 내용을 참조하십시오.

파일은 고유 섹션으로 분리됩니다. 첫 번째 섹션을 [macros]라고 합니다. 해당 섹션 외에, 추가 섹션이 각 비언어 엔티티에 존재할 수 있습니다. 이 파일에 섹션을 추가할 수 있습니다. 각 섹션 내에서, 규칙에 번호가 매겨집니다(*regexp1*, *regexp2* 등). 이 규칙에는 1 - *n*으로 연속으로 번호를 매겨야 합니다. 번호 매김이 중단되면 이 파일의 처리도 함께 일시중단됩니다.

특정 경우에서 엔티티는 언어의 영향을 받습니다. 엔티티는 구성 파일에서 언어 매개변수에 대해 0 이외의 값을 사용하면 언어의 영향을 받는다고 간주됩니다. 자세한 정보는 구성의 내용을 참조하십시오. 엔티티가 언어 종속 상태이면, 언어를 사용하여 섹션 이름에 접두문자를 붙여야 합니다(예: [english/PhoneNumber]). 해당 섹션에는 PhoneNumber 엔티티에 언어에 대해 2 값이 제공되는 경우 영어 전화 번호에만 적용되는 규칙이 포함됩니다.

**중요!** 편집기에서 이 파일 또는 다른 파일을 변경하고 추출 엔진이 더 이상 원하는 대로 작동하지 않는 경우, 파일을 원래 제공된 내용으로 재설정하기 위해 도구 모음에서 **원래값으로 재설정** 옵션을 사용하십시오. 이 파일에는 정규식과의 특정 수준의 친숙도가 필요합니다. 이 영역에서 추가 지원이 필요한 경우 IBM® Corp.에 도움을 요청하십시오.

특수 문자. [] {} () \w \* + ? | ^ \$

모든 문자는 다음 특수 문자를 제외하고 자신과 매치됩니다. 다음 특수 문자는 표현식에서 특정 목적으로 사용됩니다. `[() \w*+?|^$` 특수 문자를 이와 같이 사용하려면, 정의에서 앞에 백슬래시(`\`)를 붙여야 합니다.

예를 들어, 웹 주소를 추출하기 위해 시도한 경우, 전체 중지 문자는 엔티티에 매우 중요하므로, 다음과 같이 백슬래시를 사용해야 합니다.

```
www\w.[a-z]+\w.[a-z]+
```

반복 연산자 및 수량사 ? + \* {}

정의를 한층 융통성 있게 하려면, 정규식에 표준인 몇 개의 와일드카드를 사용할 수 있습니다. 와일드카드는 \* ? +입니다.

- 별표 \*는 0개 이상의 이전 문자열이 있음을 표시합니다. 예: `ab*c`는 "ac", "abc", "abbbc" 등과 매치됩니다.
- 더하기 부호 +는 하나 이상의 이전 문자열이 있음을 표시합니다. 예: `ab+c`는 "abc", "abbc", "abbbc"와 매치되지만 "ac"에는 매치되지 않습니다.
- 물음표 ?는 0개 또는 하나의 이전 문자열이 있음을 표시합니다. 예: `modell?ing`은 "modeling" 및 "modeling" 둘 다와 매치됩니다.
- 대괄호 {}로 반복 제한은 반복의 경계를 표시합니다. 예를 들어, `[0-9]{n}`은 정확히 *n*번 반복되는 숫자를 매치합니다. 예를 들어, `[0-9]{4}`는 "1998"을 매치하지만 "33" 또는 "19983"은 매치하지 않습니다.

[0-9]{n,}은 *n*번 이상 반복되는 숫자를 매치합니다. 예를 들어, [0-9]{3,}은 “199” 또는 “1998”은 매치하지만, “19”는 매치하지 않습니다.

[0-9]{n,m}은 *n* 및 *m*번(*n* 및 *m* 포함) 사이에 반복되는 숫자를 매치합니다. 예를 들어, [0-9]{3,5}는 “199”, “1998” 또는 “19983”은 매치하지만 “19” 또는 “199835”는 매치하지 않습니다.

### 선택적 공백 및 하이픈

어떤 경우에는 정의에 선택적 공백을 포함해야 합니다. 예를 들어, “*uruguayan pesos*”, “*uruguayan peso*”, “*uruguay pesos*”, “*uruguay peso*”, “*pesos*” 또는 “*peso*”와 같은 통화를 추출하려는 경우, 공백으로 구분되는 두 단어가 있다는 사실을 처리해야 합니다. 이러한 경우, 이 정의는 (uruguayan | uruguay )?pesos?와 같이 작성해야 합니다. *uruguayan* 또는 *uruguay*는 *pesos* / *peso*와 함께 사용될 때 공백이 뒤에 오므로, 선택적 공백을 선택적 시퀀스 (uruguayan | uruguay ) 내에서 정의해야 합니다. 공백이 선택적 시퀀스에 없는 경우(예: (uruguayan | uruguay)? pesos?), 공백이 필요하므로 “*pesos*” 또는 “*peso*”에 대해 매치되지 않습니다.

목록에서 하이픈 문자(-)를 포함하여 어떤 것의 시리즈를 찾고 있는 경우, 하이픈을 마지막으로 정의해야 합니다. 예를 들어, 콤마(,) 또는 하이픈(-)을 찾는 경우, [-,]를 사용하고 [-,]는 사용하지 마십시오.

### 목록 및 매크로에서 문자열 순서

짧은 시퀀스 이전에 가장 긴 시퀀스를 정의해야 합니다. 그렇지 않으면 매치가 짧은 시퀀스에 대해 발생하므로 가장 긴 시퀀스는 읽혀지지 않습니다. 예를 들어, 문자열 “*billion*” 또는 “*bill*”을 찾는 경우, “*billion*”이 “*bill*” 전에 정의되어야 합니다. 따라서, 예를 들어 (billion | bill)은 가능하지만 (bill | billion)은 안 됩니다. 이는 매크로에도 적용됩니다. 매크로는 문자열 목록이기 때문입니다.

### 정의 섹션에서 규칙의 순서

행마다 하나의 규칙을 정의합니다. 각 섹션 내에서, 규칙에 번호가 매겨집니다(*regex1*, *regex2* 등). 이 규칙에는 1 - *n*으로 연속으로 번호를 매겨야 합니다. 번호 매김이 중단되면 이 파일의 처리도 함께 일시중단됩니다. 항목을 사용하지 않으려면 정규식을 정의하기 위해 사용되는 각 행의 맨 앞에 # 기호를 놓으십시오. 항목을 사용하려면 해당 행 앞의 # 문자를 제거하십시오.

각 섹션에서, 가장 특징적인 규칙은 적절한 처리를 위해 가장 일반적인 규칙 이전에 정의해야 합니다. 예를 들어, “*month year*” 및 “*month*” 양식의 날짜를 찾는 경우 “*month year*” 규칙이 “*month*” 규칙 이전에 정의되어야 합니다. 다음은 정의하는 방법입니다.

```
#@# January 1932
regexp1=$(MONTH),? [0-9]{4}
```

```
#@# January
regexp2=$(MONTH)
```

다음은 아닙니다.

```
#@# January
regexp1=$(MONTH)
```

```
#@# January 1932
regexp2=$(MONTH),? [0-9]{4}
```

규칙에서 매크로 사용

특정 시퀀스가 여러 규칙에서 사용될 때마다, 매크로를 사용할 수 있습니다. 그러면, 이 시퀀스의 정의를 변경해야 하는 경우에 한 번만 변경해야 하고, 이를 참조하는 모든 규칙에서 변경하지는 않습니다. 예를 들어 다음 스크립트가 있다고 가정합니다.

```
MONTH=((january|february|march|april|june|july|august|september|october|
november|december)|(jan|feb|mar|apr|may|jun|jul|aug|sep|oct|nov|dec)(w.?)?)
```

매크로의 이름을 참조할 때마다 \$( )로 묶어야 합니다(예: regexp1=\$(MONTH)).

모든 매크로는 [macros] 섹션에서 정의해야 합니다.

## (2) 정규화

비언어 엔티티를 추출할 때, 발견되는 엔티티는 사전정의된 형식에 따라 유사한 엔티티를 그룹화하도록 정규화됩니다. 예를 들어, 통화 기호와 해당되는 단어는 동일하게 처리됩니다. 정규화 항목은 고급 자원 탭의 **정규화** 섹션에서 저장됩니다. 자세한 정보는 고급 자원에 대한 정보의 내용을 참조하십시오. 파일은 고유 섹션으로 분리됩니다.

**중요!** 이 파일은 고급 사용자를 위한 파일입니다. 이 파일을 변경해야 할 경우는 거의 없습니다. 이 영역에서 추가 지원이 필요한 경우 IBM® Corp.에 도움을 요청하십시오.

정규화에 대한 형식화 규칙

- 행마다 하나의 정규화 항목만 추가하십시오.
- 반드시 이 파일에 있는 섹션에 따르십시오. 새 섹션을 추가할 수 없습니다.
- 항목을 사용하지 않으려면 해당 행의 맨 앞에 # 기호를 놓으십시오. 항목을 사용하려면 해당 행 앞의 # 문자를 제거하십시오.

## 정규화에서 영역 날짜

기본적으로 영어 템플릿의 날짜는 미국 스타일 날짜 형식(즉, 월, 일, 년)으로 인식됩니다. 이를 일, 월, 년 형식으로 변경해야 하는 경우, "format:US"행을 사용하지 않도록 설정하고(행 앞에 # 추가) "format:UK"를 사용하도록 설정하십시오(해당 행에서 # 제거).

### (3) 구성

비언어 엔티티 구성 파일에서 추출하려는 비언어 엔티티 유형을 사용하거나 사용하지 않도록 설정할 수 있습니다. 필요하지 않은 엔티티를 사용하지 않도록 설정하여, 필요한 처리 시간을 줄일 수 있습니다. 이는 고급 자원 탭의 구성 섹션에서 수행됩니다. 자세한 정보는 고급 자원에 대한 정보의 내용을 참조하십시오. 비언어학적 추출이 사용되는 경우, 추출 엔진은 추출해야 하는 비언어 엔티티 유형을 판별하기 위해 추출 프로세스 동안 구성 파일을 읽습니다.

이 파일의 명령문은 다음과 같습니다.

```
#name<TAB>Language<TAB>Code
```

표 1. 구성 파일의 명령문

열 레이블	설명
#name	비언어 엔티티가 비언어 엔티티 추출을 위한 다른 두 개의 필수 파일에서 참조될 어귀. 여기에서 사용되는 이름에서는 대소문자가 구분됩니다.
Language	문서의 언어. 특정 언어를 선택하는 것이 최상이지만 <b>모두</b> 옵션이 있습니다. 가능한 옵션은 0 = 모두(regex가 언어에 특정하지 않고 IP/URL/이메일 주소와 같이 언어가 다른 여러 템플릿에서 사용될 수 있을 때마다 사용됨), 1 = 프랑스어, 2 = 영어, 4 = 독일어, 5 = 스페인어, 6 = 네덜란드어, 8 = 포르투갈어, 10 = 이탈리아어입니다.
Code	품사 코드. 대부분의 엔티티는 약간의 경우를 제외하고 "s" 값을 사용합니다. 가능한 값은 s(검색 엔진에서 제외되는 단어), a(형용사), n(명사)입니다. 사용되는 경우, 비언어 엔티티가 첫 번째로 추출되며 추출 패턴은 대형 컨텍스트에서 해당 역할을 식별하기 위해 적용됩니다. 예를 들어, 백분율에는 "a" 값이 제공됩니다. 30%가 비언어 엔티티로 추출되었다고 가정해 보십시오. 형용사로 식별됩니다. 그리고 나서 텍스트에 "30% salary increase"가 포함된 경우 "30%" 비언어 엔티티는 품사 패턴 "ann"(형용사 명사 명사)에 맞춰집니다.

## 정의 엔티티에서 순서

파일에서 엔티티가 선언되는 순서는 중요하며 추출 방식에 영향을 줍니다. 나열되는 순서에 적용됩니다. 순서를 변경하면 결과가 변경됩니다. 가장 특정한 비언어 엔티티는 더 일반적인 엔티티 이전에 정의해야 합니다.

예를 들어, 비언어 엔티티 "Aminoacid"는 다음과 같이 정의됩니다.

```
regex1=$(AA)-?(NUM)
```

여기서 \$(AA)는 특정 아미노산에 해당되는 특정의 3자 시퀀스인 "(ala | arg | asn | asp | cys | gln | glu | gly | his | ile | leu | lys | met | phe | pro | ser)"에 해당됩니다.

다른 한편으로, 비언어 엔티티 "Gene"는 한층 일반적이며 다음과 같이 정의됩니다.

```
regex1=p[0-9]{2,3}
regex2=[a-z]{2,4}-?[0-9]{1,3}-?[r]
regex3=[a-z]{2,4}-?[0-9]{1,3}-p?
```

"Gene"가 구성 섹션에서 "Aminoacid" 이전에 정의되는 경우, "Aminoacid"는 결코 매치되지 않습니다. "Gene"의 regex3가 항상 먼저 매치됩니다.

## 구성에 대한 형식화 규칙

- 열의 각 항목을 구분하기 위해 TAB 문자를 사용하십시오.
- 행을 삭제하지 마십시오.
- 이전 테이블에 표시된 구문을 준수하십시오.
- 항목을 사용하지 않으려면 해당 행의 맨 앞에 # 기호를 놓으십시오. 엔티티를 사용하려면, 해당 행 앞에서 # 문자를 제거하십시오.

## 6) 언어 처리

오늘날 사용되는 모든 언어에는 아이디어 표현, 문장 구조화 및 약어 사용에 대한 특수한 방식이 있습니다. 언어 처리 섹션에서, 추출 패턴을 편집하고, 해당 패턴에 대한 정의를 강제 실행하며, 언어 드롭 다운 목록에서 선택한 언어에 대한 약어를 선언할 수 있습니다.

- 추출 패턴. 자세한 정보는 추출 패턴 주제를 참조하십시오.
- 강제 실행된 정의. 자세한 정보는 강제 실행된 정의 주제를 참조하십시오.
- 약어. 자세한 정보는 약어 주제를 참조하십시오.

## (1) 추출 패턴

문서에서 정보를 추출할 때 추출 엔진은 추출을 위한 후보 용어(단어 및 문구)를 식별하기 위해 텍스트의 단어 "스택"에 품사 추출 패턴 세트를 적용합니다. 추출 패턴을 추가하거나 수정할 수 있습니다.

품사에는 명사, 형용사, 과거 분사, 한정사, 전치사, 등위 접속사, 이름, 이니셜, 불변화사와 같은 문법적 요소가 포함됩니다. 이러한 일련의 요소가 품사 추출 패턴을 구성합니다. IBM® Corp. 텍스트 마이닝 제품에서 각 품사는 패턴을 쉽게 정의할 수 있도록 1자로 표시됩니다. 예를 들어, 형용사는 소문자 a로 표시됩니다. 지원 코드 세트는 사용되는 각 코드를 쉽게 이해할 수 있도록 패턴 세트 및 각 패턴 예제와 함께 각각의 기본 추출 패턴 섹션 맨 위에 기본적으로 나타냅니다.

### 추출 패턴 형식화 규칙

- 행당 하나의 패턴.
- 패턴을 사용하지 않으려면 행 처음에 #을 사용하십시오.

주어진 단어 시퀀스는 추출 엔진이 한 번만 읽고 엔진이 매치를 찾는 첫 번째 추출 패턴에 지정되기 때문에 추출 패턴을 나열하는 순서는 매우 중요합니다.

### 지원되는 품사 코드

다음은 영어 컴파일 사전에서 정의되는 모든 지원되는 품사 코드 표입니다.

특정 템플릿에서 사용되는 모든 품사는 **고급 자원 > 추출 패턴**의 맨 위쪽에 나열됩니다.

기본 자원 템플릿 및 의견 템플릿의 주요한 차이는 기본에서 최소 관사("d") 및 전치사("c")가 사용될 때 의견에서는 확장된 등위("e" 및 "r")가 사용되는 점입니다. "0"과 "1"은 모든 의견 템플릿에서 사용이 제한됩니다. **고급 자원 > 언어 처리(영어) > 강제 실행된 정의 및 추출 패턴**을 참조하십시오.

기타 영어 템플릿은 사전에 나열되지 않은 일부 품사를 사용할 수 있습니다. 예를 들어, Market Intelligence 템플릿의 "w" 및 "W"가 있습니다. 그러나 이런 경우, 해당 품사가 **고급 자원 > 강제 실행된 정의** 아래의 특정 단어에 지정됩니다.

표 1. 지원되는 품사 코드

코드	의미	예제
a	형용사	abdominal, blue...
A	사용되지 않음	사용되지 않음
b	부사	frequently, often, very, ...
B	사용되지 않음	사용되지 않음
c	전치사	"of"
C	철자가 잘못된 단어에 대한 내부 코드	
d	관사	"the"
D	사용되지 않음	사용되지 않음
e	확장된 관사	the, an, my, your...
E	사용되지 않음	사용되지 않음
f	이름	John, Mary...
F	사용되지 않음	사용되지 않음
g	사용되지 않음	사용되지 않음
G	국적 형용사	french, american...
h	사용되지 않음	사용되지 않음
H	사용되지 않음	사용되지 않음
i	이니셜(뒤에 "."이 붙는 모든 단일 문자)	"a.", "w." 및 "w"와 같은 일부 단일 문자 (John W. Doe와 같은 사람 이름을 추출하는데 사용됨)
I	사용되지 않음	사용되지 않음
j	사용되지 않음	사용되지 않음
J	사용되지 않음	사용되지 않음
k	사용되지 않음	사용되지 않음
K	사용되지 않음	사용되지 않음
l	사용되지 않음	사용되지 않음
L	사용되지 않음	사용되지 않음
m	명사 또는 알 수 없음	dog, ibm
M	사용되지 않음	사용되지 않음

코드	의미	예제
n	명사	dog
N	소수의 고유 명사	ibm
o	등위 접속사	"and", "&"
O	사용되지 않음	사용되지 않음
p	과거 분사	abandoned, accessorized...
P	사용되지 않음	사용되지 않음
q	사용되지 않음	사용되지 않음
Q	규정자	expensive, small, good, ...
r	확장된 전치사	of, among, against, from...
R	사용되지 않음	사용되지 않음
s	제외어	추출하지 않는 모든 단어
S	사용되지 않음	사용되지 않음
t	직위	mrs., mrs, captain, brig., ...
T	사용되지 않음	사용되지 않음
u	정의를 알 수 없음, 사전에 없음	
U	사용되지 않음	사용되지 않음
v	동사	eat, eats, ate, eating, ...
V	동사 원형	eat, ...
w	사용되지 않음	사용되지 않음
W	사용되지 않음	사용되지 않음
x	조동사	be
X	사용되지 않음	사용되지 않음
y	전치사	von, di, de, ... (사람 이름 추출에 사용됨: John von Doe)
Y	사용되지 않음	사용되지 않음
z	사용되지 않음	사용되지 않음
Z	사용되지 않음	사용되지 않음
0	의견 부사	의견에서만 사용됨. 고급 자원 > 언어 처리(영어) > 강제 실행된 정의를 참조하십시오.

코드	의미	예제
1	의견의 "to"	고급 자원 > 언어 처리(영어) > 강제 실행된 정의를 참조하십시오.
2	사용되지 않음	사용되지 않음
3	사용되지 않음	사용되지 않음
4	사용되지 않음	사용되지 않음
5	사용되지 않음	사용되지 않음
6	사용되지 않음	사용되지 않음
7	사용되지 않음	사용되지 않음
8	사용되지 않음	사용되지 않음
9	사용되지 않음	사용되지 않음

## (2) 강제 실행된 정의

문서에서 정보를 추출할 때 추출 엔진은 텍스트를 스캔하고 발생하는 모든 단어의 품사를 식별합니다. 일부 경우에는 컨텍스트에 따라 한 단어가 여러 개의 역할에 맞습니다. 강제로 단어가 특정 품사 역할을 갖게 하거나 단어를 처리에서 완전히 제외하려면 고급 자원 탭의 **강제 실행된 정의** 섹션에서 이렇게 할 수 있습니다. 자세한 정보는 고급 자원에 대한 정보의 내용을 참조하십시오.

주어진 단어에 품사 역할을 강제 실행하려면 다음 구문을 사용하여 이 섹션에 행을 추가해야 합니다.

```
term:code
```

표 1. 구문 설명

항목	설명
term	용어 이름입니다.
code	품사 역할을 나타내는 1자 코드입니다. 단일어당 최대 6개의 다른 품사 코드를 나열할 수 있습니다. 또한 소문자 코드 s를 사용하여(예: additional:s) 단어가 복합 단어/문구로 추출되지 않게 할 수 있습니다.

## 강제 실행된 정의 형식화 규칙

- 단어당 한 행.
- 용어는 콜론을 포함할 수 없습니다.
- 단어가 함께 추출되지 않게 하려면 `s`를 품사 코드로 사용하십시오.
- 행당 최대 6개의 품사 코드를 사용하십시오. 지원되는 품사 코드는 추출 패턴 섹션에 표시됩니다. 자세한 정보는 추출 패턴의 내용을 참조하십시오.
- 부분 매치의 경우 문자열 끝에 별표(\*)를 와일드카드로 사용하십시오. 예를 들어, `add*s`를 입력하면 `add`, `additional`, `additionally`, `addendum`, `additive`와 같은 단어가 용어 또는 복합 단어 용어의 일부로 추출되지 않습니다. 그러나 컴파일된 사전 또는 강제 실행된 정의에 단어 매치가 용어로 명시적으로 선언된 경우에는 여전히 추출됩니다. 예를 들어, `add*s`와 `addendum:n`을 모두 입력하는 경우 텍스트에서 찾으면 `addendum`이 여전히 추출됩니다.

### (3) 약어

추출 엔진은 텍스트를 처리할 때 일반적으로 찾은 마침표를 문장이 끝났다는 표시로 간주합니다. 이는 일반적으로 맞습니다. 그러나 텍스트에 약어가 포함된 경우에는 이 마침표 문자 처리가 적용되지 않습니다.

텍스트에서 용어를 추출하고 일정 약어가 잘못 처리되었음을 발견하면 이 섹션에서 해당 약어를 명시적으로 선언해야 합니다.

**참고:** 약어가 동의어 정의에 이미 나타나거나 유형 사전에 용어로 정의된 경우에는 여기서 약어 항목을 추가하지 않아도 됩니다.

### 약어 형식화 규칙

- 행당 하나의 약어를 정의하십시오.

## 18. 텍스트 링크 규칙에 대한 정보

텍스트 링크 분석(TLA)은 규칙 세트를 사용하여 텍스트에서 발견된 관계를 추출하기 위해 사용되는 패턴 매치 기법입니다. 추출에 대해 텍스트 링크 분석이 사용되는 경우, 텍스트 데이터는 이 규칙에 대해 비교됩니다. 매치가 발견되면, 텍스트 링크 분석 패턴이 추출되어 제시됩니다. 이 규칙은 텍스트 링크 규칙 탭에서 정의됩니다.

예를 들어, 조직에 대한 단순한 아이디어를 나타내는 개념을 추출하는 것은 사용자에게 충분히 흥미롭지 않을 수도 있지만, TLA를 사용하여 다양한 조직 또는 조직과 연관된 사람들 사이의 링크에 대해 배울 수도 있습니다. TLA는 또한 제공된 제품이나 경험에 대해 사람들이 어떻게 느끼는지와 같은 주제에 대한 의견을 추출하기 위해 사용할 수도 있습니다.

TLA의 이득을 얻기 위해서는 텍스트 링크(TLA) 규칙을 포함하는 자원을 가지고 있어야 합니다. 템플릿을 선택할 때, TLA 옆에 아이콘을 가지고 있는지 여부에 의해 TLA 규칙이 있는 템플릿을 알 수 있습니다.

텍스트 링크 분석 패턴은 추출 프로세스의 패턴 매치 단계 동안 텍스트 데이터에서 발견됩니다. 이 단계 동안, 규칙은 텍스트 데이터와 비교되고 매치가 발견되면 해당 정보가 패턴으로 추출됩니다. 텍스트 링크 분석에서 더 많은 것을 가져오거나 매치 방법을 변경하고자 할 경우가 있습니다. 이러한 경우, 규칙을 세분화하여 특정 필요성에 적용하십시오. 이는 텍스트 링크 규칙 탭에서 수행됩니다.

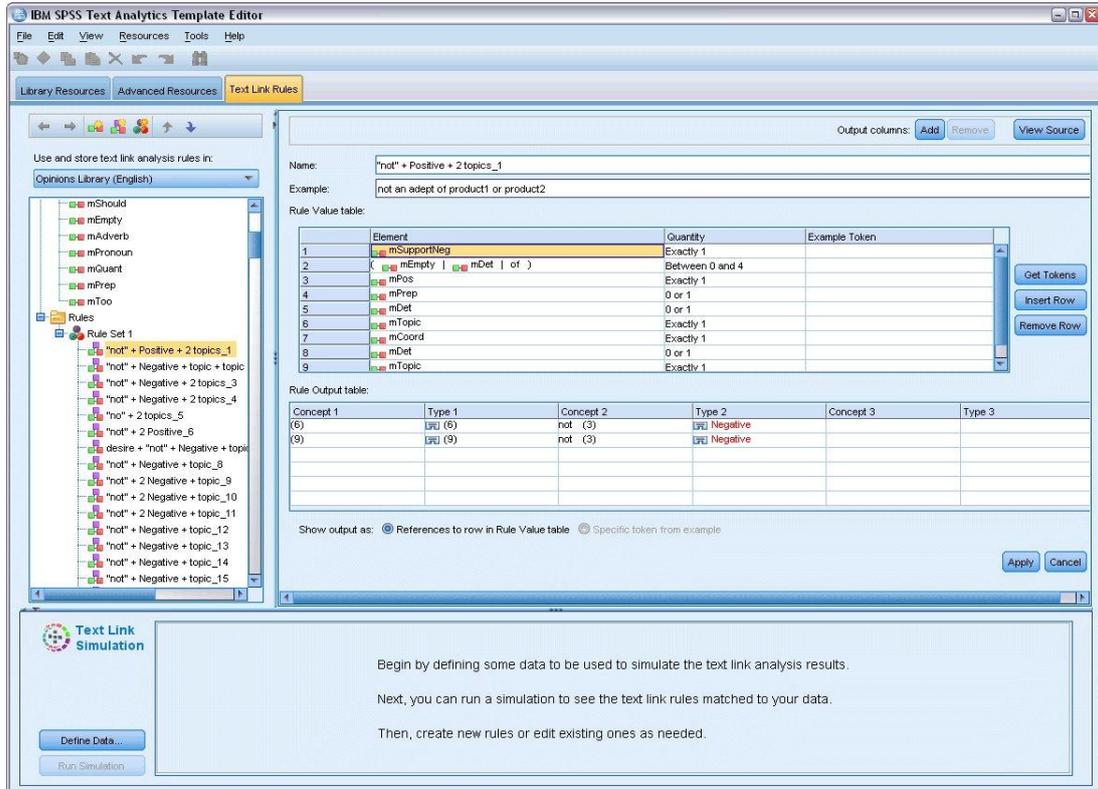
 **참고:** 버전 18.2부터 유형 재할당 규칙(TRR)이 사용 가능합니다. TRR은 유형, 매크로 및 /또는 토큰으로 구성된 시퀀스를 특정 유형의 새 개념으로 변환합니다. 또한 의견 템플릿에서 극성이 변경된 의견을 포착하는 데 사용할 수 있습니다. 자세한 정보는 유형 재할당 규칙의 내용을 참조하십시오.

## 1) 텍스트 링크 규칙에 대해 작업할 위치

템플릿 편집기 또는 자원 편집기 보기의 텍스트 링크 탭에서 직접 규칙을 편집하고 작성할 수 있습니다. 규칙이 텍스트와 매치될 수 있는 방법을 알기 위해 이 탭에서 시뮬레이션을 실행할 수 있습니다. 시뮬레이션 동안, 추출은 샘플 시뮬레이션 데이터에 대해서만 실행되고 텍스트 링크 규칙은 패턴이 매치되는지 보기 위해 적용됩니다. 텍스트와 매치되는 규칙이 시뮬레이션 분할 창에 표시됩니다. 매치를 기반으로, 텍스트가 매치되는 방법을 변경할 규칙 및 매크로를 편집할 것을 선택할 수 있습니다.

다른 고급 자원과 달리, TLA 규칙은 라이브러리에 고유하므로, 한 번에 하나의 라이브러리에서만 TLA 규칙을 사용할 수 있습니다. 템플릿 편집기 또는 자원 편집기에서, **텍스트 링크 규칙** 탭으로 이동하십시오. 이 탭에서, 사용하거나 편집하려는 TLA 규칙을 포함하는 라이브러리를 템플릿에서 지정할 수 있습니다. 이러한 이유로, 특정한 이유가 없으면 모든 규칙을 하나의 라이브러리에 저장할 것을 권장합니다.

그림 1. 텍스트 링크 규칙 탭



## 2) 시작 위치

텍스트 링크 규칙 탭 편집기에서 작업을 시작하기 위한 많은 방법이 있습니다.

- 일부 샘플 텍스트로 결과를 시뮬레이션하는 것으로 시작하여 시뮬레이션 데이터에서 현재 규칙 세트가 패턴을 추출하는 방법을 기반으로 매치 규칙을 편집하거나 작성합니다. 자세한 정보는 텍스트 링크 분석 결과 시뮬레이션 주제를 참조하십시오.
- 스크래치에서 새 규칙을 작성하거나 기존 규칙을 편집합니다. 자세한 정보는 텍스트 링크 규칙에 대한 작업 주제를 참조하십시오.
- 소스 보기에서 직접 작업합니다. 자세한 정보는 소스 모드에서 보기 및 작업 주제를 참조하십시오.

## 3) 규칙 편집 또는 작성 시기

각 템플릿과 함께 전달된 텍스트 링크 분석 규칙이 종종 많은 단순하거나 복잡한 관계를 텍스트에서 추출하는 데 적합한 반면, 이 규칙을 수정하거나 사용자 자신의 규칙을 작성하고자 하는 경우가 있습니다. 예를 들어,

- 새 규칙 또는 매크로를 작성하여 기존 규칙에서 추출되지 않는 아이디어 또는 관계를 캡처하려는 경우.
- 자원에 추가한 유형의 기본 작동을 변경하려는 경우. 이때 보통 mTopic 또는 mNonLingEntities와 같은 매크로를 편집해야 합니다. 자세한 정보는 특수 매크로: mTopic, mNonLingEntities, SEP의 내용을 참조하십시오.
- 기존 텍스트 링크 분석 규칙 및 매크로에 새 유형을 추가하는 경우. 예를 들어, 유형 <Organization>이 너무 광범위하다고 생각하면, <Pharmaceuticals>, <Car Manufacturing>, <Finance> 등과 같은 여러 다른 업무 부문에 조직을 위한 새 유형을 작성할 수 있습니다. 이러한 경우, 텍스트 링크 분석 규칙을 편집하고(하거나) 이 새 유형을 이용하고 각각의 경우에 이를 처리하기 위해 매크로를 작성해야 합니다.
- 유형을 기존 텍스트 링크 분석 규칙에 추가하는 경우. 예를 들어, 다음 텍스트 john doe called jane doe를 캡처하는 규칙을 가지고 있지만 이 규칙이 이메일 교환을 캡처하기 위해 전화 통신을 캡처하는 것도 원할 수 있습니다. 규칙에 이메일에 대한 비언어 엔티티 유형을 추가할 수 있으므로, johndoe@ibm.com emailed janedoe@ibm.com과 같은 텍스트도 캡처합니다.
- 새 규칙을 작성하는 대신 기존 규칙을 약간 수정하는 경우. 예를 들어, 다음 텍스트 xyz is very good doe와 매치되는 규칙을 가지고 있지만 이 규칙이 xyz is very, very good도 캡처하기를 원할 수 있습니다.

#### 4) 텍스트 링크 분석 결과 시뮬레이션

새 텍스트 링크 규칙을 쉽게 정의하거나 특정 문장이 텍스트 링크 분석 동안 매치되는 방법을 쉽게 이해하기 위해, 샘플 텍스트 조각을 사용하여 시뮬레이션을 실행하는 것이 종종 유용합니다. 시뮬레이션 동안, 추출은 현재 언어학적 자원 세트 및 현재 추출 설정을 사용하여 샘플 시뮬레이션 데이터에 대해서만 실행됩니다. 목적은 시뮬레이트된 결과를 확보하고 이 결과를 사용하여 규칙을 개선하거나, 새 규칙을 작성하거나, 매치 발생 방법을 더 잘 이해하기 위한 것입니다. 텍스트 조각(컨텍스트에 따라 문장, 단어 또는 절) 각각에 대해, 시뮬레이션 출력은 해당 텍스트에서 패턴을 포함하지 않은 TLA 규칙과 토큰 콜렉션을 표시합니다. 토큰은 추출 프로세스 동안 식별되는 단어 또는 단어 구문으로 정의됩니다.

다른 고급 자원과 달리, TLA 규칙은 라이브러리에 고유하므로, 한 번에 하나의 라이브러리에서만 TLA 규칙을 사용할 수 있습니다. 템플릿 편집기 또는 자원 편집기에서, **텍스트 링크 규칙** 탭으로 이동하십시오. 이 탭에서, 사용하거나 편집하려는 TLA 규칙을 포함하는 라이브러리를 템플릿에서 지정할 수 있습니다. 이러한 이유로, 특정한 이유가 없으면 모든 규칙을 하나의 라이브러리에 저장할 것을 권장합니다.

**중요!** 데이터 파일을 사용하는 경우, 처리 시간을 최소화하기 위해 이 파일에 포함되는 텍스트가 간단하지 확인하십시오. 시뮬레이션의 목적은 텍스트 조각이 해석되는 방법을 보고 규칙이 이 텍스트와 매치되는 방법을 이해하는 것입니다. 이 정보는 규칙을 작성하고 편집하는 데 도움이 됩니다.

니다. 한층 완전한 데이터 세트에 대한 결과를 확보하려면 TLA 추출이 사용되는 대화형 세션으로 스트림을 실행하거나 텍스트 링크 분석 노드를 사용하십시오. 이 시뮬레이션은 단지 테스트 및 규칙 작성 목적을 위한 것입니다.

## (1) 시뮬레이션에 대한 데이터 정의

규칙이 텍스트와 매치될 수 있는 방법을 쉽게 알려면, 표본 데이터를 사용하여 시뮬레이션을 실행할 수 있습니다. 첫 번째 단계는 데이터를 정의하는 것입니다.

### 데이터 정의

1. **텍스트 링크 규칙** 탭의 맨 아래에 있는 시뮬레이션 분할창에서 **데이터 정의**를 클릭하십시오. 또는 이전에 데이터를 정의하지 않은 경우, 메뉴에서 **도구 > 시뮬레이션 실행**을 선택하십시오. 시뮬레이션 데이터 마법사가 열립니다.
2. 다음 중 하나를 선택하여 데이터 유형을 지정하십시오.
  - **직접 텍스트 붙여넣기 또는 입력:** 텍스트를 클립보드에서 붙여넣거나 처리할 텍스트를 수동으로 입력할 수 있는 텍스트 상자가 제공됩니다. 행마다 하나의 문장을 입력하거나 구두점(예: 마침표 또는 콤마)을 사용하여 문장을 분리할 수 있습니다. 텍스트를 입력한 경우, **시뮬레이션 실행**을 클릭하여 시뮬레이션을 시작할 수 있습니다.
  - **파일 데이터 소스 지정:** 이 옵션은 텍스트를 포함하는 파일을 처리할 것을 표시합니다. 처리될 파일을 정의할 수 있는 마법사 단계로 진행하려면 **다음**을 클릭하십시오. 파일이 선택되면, **시뮬레이션 실행**을 클릭하여 시뮬레이션을 시작할 수 있습니다. .txt 및 .text 파일 유형이 지원됩니다. 선택하는 데이터 파일은 시뮬레이션 동안 "있는 그대로" 읽혀집니다. 전체 파일은 사용자가 텍스트 마이닝 노드에 파일 목록 노드를 연결한 것과 동일한 방식으로 처리됩니다.

❖ **중요사항:** 데이터 파일을 사용하는 경우, 처리 시간을 최소화하기 위해 이 파일에 포함되는 텍스트가 간단하지 확인하십시오. 시뮬레이션의 목적은 텍스트 조각이 해석되는 방법을 보고 규칙이 이 텍스트와 매치되는 방법을 이해하는 것입니다. 이 정보는 규칙을 작성하고 편집하는 데 도움이 됩니다. 한층 완전한 데이터 세트에 대한 결과를 확보하려면 TLA 추출이 사용되는 대화형 세션으로 스트림을 실행하거나 텍스트 링크 분석 노드를 사용하십시오. 이 시뮬레이션은 단지 테스트 및 규칙 작성 목적을 위한 것입니다.

3. 시뮬레이션 프로세스를 시작하려면 **시뮬레이션 실행**을 클릭하십시오. 진행률 대화 상자가 나타납니다. 대화형 세션에 있으면, 시뮬레이션 동안 사용한 추출 설정은 이 대화형 세션에서 현재 선택되어 있는 설정입니다(개념 및 범주 보기의 **도구 > 추출 설정** 참조). 템플릿 편집기에 있는 경우에는, 시뮬레이션 동안 사용한 추출 설정이 기본 추출 설정이며, 이 설정은 텍스트 링크 분석 노드의 전문가 탭에 표시되는 것과 같습니다. 추가 정보는 시뮬레이션 결과 이해의 내용을 참조하십시오.

## (2) 시뮬레이션 결과 이해

규칙이 텍스트와 매치될 수 있는 방법을 쉽게 알려면, 표본 데이터 사용을 사용하여 시뮬레이션을 실행하고 결과를 검토할 수 있습니다. 여기에서 규칙 세트를 사용자 데이터에 잘 맞도록 변경할 수 있습니다. 추출 및 시뮬레이션 프로세스가 완료되면, 시뮬레이션 결과와 함께 표시됩니다.

추출 동안 식별된 "문장"마다, 정확한 "문장", 입력 텍스트 문장에서 발견된 토큰의 명세, 마지막으로 해당 문장에서 텍스트와 매치된 규칙을 포함하여 몇몇 정보 조각이 함께 표시됩니다. "문장"에 의해, 추출기가 텍스트를 읽을 수 있는 청크로 분리하는 방법에 따라 단어, 문장 또는 절을 의미합니다.

토큰은 추출 프로세스 중에 식별된 단어 또는 단어 문구로 정의됩니다. 예를 들어, *My uncle lives in New York* 문장에서는 추출 중에 *my*, *uncle*, *lives*, *in* 및 *new york* 토큰을 발견할 수 있습니다. 또한 *uncle*을 개념으로 추출하고 <Unknown>으로 유형 지정하며, *new york*을 개념으로 추출하고 <Location>으로 유형 지정할 수 있습니다. 모든 개념은 토큰이지만 모든 토큰이 개념인 것은 아닙니다. 토큰은 다른 매크로, 리터럴 문자열, 단어 간격일 수도 있습니다. 유형이 지정된 해당 단어 또는 단어 문구만 개념이 될 수 있습니다.

대화형 세션 또는 자원 편집기에서 작업할 때, 개념 수준에서 작업하는 것입니다. TLA 규칙은 한층 세부 단위여서, 추출되고 유형이 지정되지 않아도 문장의 개별 토큰이 규칙 정의에서 사용될 수 있습니다. 개념이 아닌 토큰을 사용할 수 있으면 텍스트에서 복잡한 관계 캡처 시 추가 융통성이 규칙에 제공됩니다.

시뮬레이션 데이터에 두 개 이상 문장이 있으면, **다음** 및 **이전**을 클릭하여 결과에서 앞뒤로 이동할 수 있습니다.

문장이 선택된 라이브러리(이 탭에서 트리 위체 있는 라이브러리 이름 참조)의 어떤 TLA 규칙과도 매치되지 않는 경우, 결과는 매치되지 않는 것으로 간주되고 어떤 규칙도 매치를 발견하지 못한 텍스트가 있음을 알 수 있도록 하고 해당 인스턴스를 신속하게 탐색할 수 있도록 하기 위해 **다음 매치되지 않음** 및 **이전 매치되지 않음** 단추가 사용됩니다.

새 규칙을 작성한 후, 규칙을 편집하거나 자원 또는 추출 설정을 변경하거나, 시뮬레이션을 다시 실행할 수 있습니다. 시뮬레이션을 다시 실행하려면 시뮬레이션 분할창에서 **시뮬레이션 실행**을 클릭하십시오. 동일한 입력 데이터가 다시 사용됩니다.

다음 필드 및 테이블이 시뮬레이션 결과에 표시됩니다.

**입력 텍스트.** 마법사에서 정의한 시뮬레이션 데이터로부터 추출 프로세스에 의해 식별된 실제 '문장'. 문장 기준으로, 추출기가 텍스트를 읽을 수 있는 청크로 분리하는 방법에 따라 단어, 문장 또는 절을 의미합니다.

시스템 보기. 추출 프로세스가 식별한 토큰의 컬렉션.

- **입력 텍스트 토큰.** 각 토큰은 입력 텍스트에서 발견되었습니다. 토큰은 이 주제의 앞에서 정의했습니다.
- **다음과 같이 유형 지정.** 토큰이 개념으로 식별되고 유형이 지정된 경우, 연관된 유형 이름(예: <Unknown>, <Person>, <Location>)이 이 열에 표시됩니다.
- **매치 매크로.** 토큰이 기존 매크로와 매치된 경우, 연관된 매크로 이름이 이 열에 표시됩니다.

**입력 텍스트에 매치된 규칙.** 이 테이블은 입력 텍스트에 대해 매치된 TLA 규칙을 보여줍니다. 매치된 규칙마다, **규칙 출력** 열에서 규칙의 이름이 표시되고 해당 규칙에 대해 연관된 출력 값 (개념 + 유형 쌍)이 표시됩니다. 매치된 규칙 이름을 두 번 클릭하여 시뮬레이션 분할창 위의 편집기 분할창에서 규칙을 열 수 있습니다.

**규칙 생성 단추.** 시뮬레이션 분할창에서 이 단추를 클릭하면, 새 규칙이 시뮬레이션 분할창 위의 규칙 편집기 분할창에서 열립니다. 이 규칙은 입력 텍스트를 해당되는 예로 사용합니다. 마찬가지로, 시뮬레이션 동안 매크로에 대해 매치되거나 유형이 지정된 토큰은 **규칙 값 테이블**에서 요소 열에 자동으로 삽입됩니다. 토큰에 유형이 지정되고 토큰이 매크로에 매치된 경우, 매크로 값은 규칙을 단순화하기 위해 규칙에서 사용될 값입니다. 예를 들어, 문장 *"I like pizza"*는 추출 동안 <Unknown>으로 유형이 지정되고 매크로 mTopic에 매치될 수 있습니다(기본 영어 자원을 사용하는 경우). 이러한 경우 mTopic은 생성된 규칙에서 요소로 사용됩니다. 자세한 정보는 텍스트 링크 규칙에 대한 작업의 내용을 참조하십시오.

## 5) 트리에서 규칙 및 매크로 탐색

추출 동안 텍스트 링크분석이 수행될 때, **텍스트 링크 규칙** 탭에서 선택된 라이브러리에 저장된 텍스트 링크 규칙이 사용됩니다.

다른 고급 자원과 달리, TLA 규칙은 라이브러리에 고유하므로, 한 번에 하나의 라이브러리에서만 TLA 규칙을 사용할 수 있습니다. 템플릿 편집기 또는 자원 편집기에서, **텍스트 링크 규칙** 탭으로 이동하십시오. 이 탭에서, 사용하거나 편집하려는 TLA 규칙을 포함하는 라이브러리를 템플릿에서 지정할 수 있습니다. 이러한 이유로, 특정한 이유가 없으면 모든 규칙을 하나의 라이브러리에 저장할 것을 강력하게 권장합니다.

이 탭의 **텍스트 링크 분석 규칙 사용 및 저장 위치:** 드롭다운 목록에서 해당 라이브러리를 선택하여 텍스트 링크 규칙 탭에서 작업하려고 하는 라이브러리를 지정할 수 있습니다. 추출 동안 텍스트 링크분석이 수행될 때, **텍스트 링크 규칙** 탭에서 선택된 라이브러리에 저장된 텍스트 링크 규칙이 사용됩니다. 따라서, 두 개 이상의 라이브러리에서 텍스트 링크 규칙(TLA 규칙)을 정의한 경우, TLA 규칙이 발견된 첫 번째 라이브러리만 텍스트 링크 분석에 사용됩니다. 이러한 이유로, 특정한 이유가 없으면 모든 규칙을 하나의 라이브러리에 저장할 것을 적극 권장합니다.

트리에서 매크로 또는 규칙을 선택할 때, 해당 내용은 오른쪽에 있는 편집기 창에 표시됩니다. 트리에서 항목을 마우스 오른쪽 단추로 클릭하면, 다음과 같이 가능한 다른 태스크를 표시하기 위해 컨텍스트 메뉴가 열립니다.

- 트리에서 새 매크로를 작성하고 오른쪽에 있는 편집기에서 엽니다.
- 트리에서 새 규칙을 작성하고 오른쪽에 있는 편집기에서 엽니다.
- 트리에서 새 규칙을 작성합니다.
- 편집을 단순화하기 위해 항목을 잘라내고, 복사하며, 붙여넣습니다.
- 자원에서 제거하기 위해 매크로, 규칙 및 규칙 세트를 삭제합니다.
- 처리 동안 무시되어야 함을 표시하기 위해 매크로, 규칙 및 규칙 세트를 사용하지 않도록 설정합니다.
- 처리 순서에 영향이 미치도록 위 또는 아래로 규칙을 이동합니다.

## 트리의 경고

경고는 트리에서 노란색 삼각형으로 표시되고, 문제점이 있을 수 있음을 알립니다. 팝업 설명을 표시하려면 결합 매크로 또는 규칙 위로 마우스 포인터를 움직이십시오. 대부분의 경우, **경고: 제공된 예가 없습니다. 예를 입력하십시오**가 표시되므로 예를 입력해야 합니다.

예가 없거나 예가 규칙과 매치되지 않는 경우, 토큰 가져오기 기능을 사용할 수 없으므로 규칙마다 하나의 예만 입력하도록 합니다.

규칙이 노랑색에서 강조표시될 때 유형 또는 매크로가 TLA 편집기에 알려지지 않음을 의미합니다. 메시지는 **경고: 알 수 없는 유형 또는 매크로**와 유사합니다. 소스 보기에서 \$something에 의해 정의되는 항목(예: \$myType)은 라이브러리에서 레거시 유형이 아니며 매크로도 아닙니다.

명령문 검사 프로그램을 업데이트하려면 다른 규칙 또는 매크로로 전환해야 합니다. 어떤 것도 다시 컴파일하지 않아도 됩니다. 따라서, 예를 들어 예가 없어서 규칙 A가 경고를 표시하는 경우, 예를 추가하고 상단 또는 하단 규칙을 클릭한 후 규칙 A로 다시 이동하여 현재 올바른지 확인해야 합니다.

## 6) 매크로에 대한 작업

매크로는 유형, 다른 매크로 및 리터럴(단어) 문자열을 OR 연산자(|)로 함께 그룹화할 수 있도록 하여 텍스트 링크 분석 규칙의 형태를 단순화할 수 있습니다. 매크로 사용의 장점은 여러 텍스트 링크 분석 규칙에서 매크로를 재사용하여 단순화시키는 것 외에도, 모든 텍스트 링크 분석 규칙에서 업데이트를 수행하기 보다는 하나의 매크로에서 업데이트를 수행할 수 있도록 하는 것입니다. 제공되는 대부분의 TLA 규칙에는 사전 정의된 매크로가 포함됩니다. 매크로는 텍스트 링크 규칙 탭의 가장 왼쪽 분할창에서 트리 맨 위에 나타납니다.

다음 필드 및 테이블이 시뮬레이션 결과에 표시됩니다.

**이름.** 이 매크로를 식별하는 고유 이름. 규칙에서 신속하게 매크로를 식별할 수 있도록 소문자 m을 매크로 이름 앞에 붙일 것을 권장합니다. 수동으로 규칙에서 매크로를 참조할 때(인라인 편집 시 또는 소스 보기에서) 추출 프로세스에서 이 특수 이름을 찾을 수 있도록 \$ 접두문자를 사용해야 합니다. 그러나 매크로 이름을 끌어서 놓거나 컨텍스트 메뉴를 통해 이 이름을 추가하는 경우, 제품은 자동으로 이를 매크로로 인식하고 \$가 추가되지 않습니다.

#### 매크로 값 테이블.

- 이 매크로가 표시할 수 있는 가능한 모든 값을 표시하는 여러 행. 이 값에서는 대소문자가 구분됩니다.
- 이 값에는 유형, 리터럴 문자열, 단어 간격 또는 매크로 중 하나이거나 이 유형의 조합이 포함될 수 있습니다. 자세한 정보는 규칙 및 매크로에 대해 지원되는 요소의 내용을 참조하십시오.
- 매크로에서 요소의 값을 입력하려면 작업할 행을 두 번 클릭하십시오. 유형 참조, 매크로 참조, 리터럴 문자열 또는 단어 간격을 입력할 수 있는 편집 가능한 텍스트 상자가 나타납니다. 또는 공통 매크로, 유형 이름 및 비언어 유형 이름의 목록을 제공하는 컨텍스트 메뉴를 표시하기 위해 셀에서 마우스 오른쪽 단추를 클릭하십시오. 유형 또는 매크로를 참조하려면 '\$' 문자를 매크로 또는 유형 이름 앞에 붙여야 합니다(예: 매크로 mTopic의 경우 \$mTopic). 인수를 조합할 때, 괄호 ( )를 사용하여 인수를 그룹화하고 문자 |를 사용하여 부울 OR을 표시해야 합니다.
- 오른쪽에 있는 단추를 사용하여 매크로 값 테이블에서 행을 추가하거나 제거할 수 있습니다.
- 해당되는 행에서 각 요소를 입력하십시오. 예를 들어, am OR was OR is와 같은 3 리터럴 문자열 중 하나를 나타내는 매크로를 작성하려는 경우, 보기에서 별도의 행에 각 리터럴 문자열을 입력하고 매크로 테이블에 세 행을 포함합니다.

### (1) 매크로 작성 및 편집

새 매크로를 작성하거나 기존 매크로를 편집할 수 있습니다. 매크로 편집기에 대한 지침과 설명을 따르십시오. 자세한 정보는 매크로에 대한 작업의 내용을 참조하십시오.

#### 새 매크로 작성

1. 메뉴에서 **도구 > 새 매크로**를 선택하십시오. 또는 트리 도구 모음에서 새 매크로 아이콘을 클릭하여 편집기에서 새 매크로를 여십시오.
2. 고유한 이름을 입력하고 매크로 값 요소를 정의하십시오.
3. 오류 확인을 완료하면 **적용**을 클릭하십시오.

## 매크로 편집

1. 트리에서 매크로 이름을 클릭하십시오. 매크로는 오른쪽에 있는 편집기 분할창에서 열립니다.
2. 변경사항을 작성하십시오.
3. 오류 확인을 완료하면 **적용**을 클릭하십시오.

## (2) 매크로 사용 안함 및 삭제

### 매크로 사용 안함

처리 동안 매크로가 무시되도록 하려면, 매크로를 사용하지 않도록 설정할 수 있습니다. 이렇게 하면 사용하지 않도록 설정한 매크로를 계속 참조하는 규칙에서 경고나 오류가 발생할 수 있습니다. 매크로를 삭제하고 사용하지 않도록 설정할 때 주의하십시오.

1. 트리에서 매크로 이름을 클릭하십시오. 매크로는 오른쪽에 있는 편집기 분할창에서 열립니다.
2. 이름을 마우스 오른쪽 단추로 클릭하십시오.
3. 컨텍스트 메뉴에서 **사용할 수 없음**을 선택하십시오. 매크로 아이콘은 회색이 되고 매크로 자체는 편집할 수 없게 됩니다.

### 매크로 삭제

매크로를 제거하려면, 해당 매크로를 삭제할 수 있습니다. 이렇게 하면 해당 매크로를 계속 참조하는 규칙에서 오류가 발생할 수 있습니다. 매크로를 삭제하고 사용하지 않도록 설정할 때 주의하십시오.

1. 트리에서 매크로 이름을 클릭하십시오. 매크로는 오른쪽에 있는 편집기 분할창에서 열립니다.
2. 이름을 마우스 오른쪽 단추로 클릭하십시오.
3. 컨텍스트 메뉴로부터 **삭제**를 선택하십시오. 매크로가 목록에서 사라집니다.

## (3) 오류 확인, 저장 및 취소

### 매크로 변경사항 적용

매크로 편집기 외부로 클릭하거나 **적용**을 클릭하는 경우, 매크로는 오류를 찾기 위해 자동으로 스캔됩니다. 오류가 발견되면, 애플리케이션의 다른 부분으로 이동하기 전에 수정해야 합니다.

그러나 덜 심각한 오류가 발견되면, 경고만 제공됩니다. 예를 들어, 매크로에 유형 또는 다른 매크로에 대한 완료되지 않거나 참조되지 않는 정의가 있는 경우, 경고 메시지가 표시됩니다. **적용**을 클릭하는 경우, 정정되지 않은 경고는 왼쪽 분할창에 있는 규칙 및 매크로 트리에서 매크로 이름의 왼쪽에 경고 아이콘이 나타나도록 합니다.

매크로를 적용해도 매크로가 영구적으로 저장됨을 의미하지는 않습니다. 적용하면 오류 및 경고에 대해 확인하기 위해 검증 프로세스가 발생합니다.

대화형 워크벤치 세션 내에서 자원 저장

1. 대화식 워크벤치 세션 동안 자원에 대해 작성한 변경사항을 저장하기 위해, 다음에 스트림을 실행할 때 변경사항을 가져올 수 있습니다.
  - 다음에 스트림을 실행할 때 동일한 자원을 가져올 수 있도록 모델링 노드를 업데이트하십시오. 자세한 정보는 모델링 노드 업데이트 및 저장의 내용을 참조하십시오. 그런 다음 스트림을 저장하십시오. 스트림을 저장하려면, 모델링 노드를 업데이트한 후 기본 IBM® SPSS® Modeler 창에서 저장을 수행하십시오.
2. 다른 스트림에서 사용할 수 있도록 대화식 워크벤치 세션 동안 자원에 대해 작성한 변경사항을 저장하기 위해, 다음을 수행할 수 있습니다.
  - 사용한 템플릿을 업데이트하거나 새 템플릿을 작성하십시오. 자세한 정보는 템플릿 작성 및 업데이트의 내용을 참조하십시오. 현재 노드에 대한 변경사항은 저장되지 않습니다(이전 단계 참조).
  - 또는 사용한 TAP를 업데이트하십시오. 자세한 정보는 텍스트 분석 패키지 업데이트의 내용을 참조하십시오.

템플릿 편집기 내에서 자원 저장

1. 먼저 라이브러리를 출판하십시오. 자세한 정보는 라이브러리 출판의 내용을 참조하십시오.
2. 그런 다음, 메뉴에서 **파일 > 자원 템플릿 저장**을 통해 템플릿을 저장하십시오.

매크로 변경사항 취소

1. 변경사항을 삭제하려면 **취소**를 클릭하십시오.

#### (4) 특수 매크로: mTopic, mNonLingEntities, SEP

Opinions 템플릿(및 유사한 템플릿)와 기본 자원 템플릿은 mTopic 및 mNonLingEntities와 같은 두 개의 특수 매크로와 함께 제공됩니다.

mTopic

기본적으로, 매크로 mTopic은 유형이 의견(opinion) 유형(예: <Negative> 또는 <Positive>)이나 고급 자원에서 비언어 엔티티로 정의된 유형이 아닌 한, 코어 라이브러리 유형 <Person>, <Organization>, <Location> 등과 같이 의견과 연결될 템플릿에서 제공되는 모든 유형을 그룹화합니다.

Opinions(또는 유사한) 템플릿에서 새 유형을 작성할 때마다, 제품은 이 유형이 고급 자원 탭의 비언어 엔티티 섹션이나 다른 매크로에서 지정되지 않는 한 매크로 mTopic에서 정의된 다른 유형과 동일한 방식으로 처리된다고 가정합니다.

Opinions 템플릿으로부터 자원에서 새 유형 <Vegetables> 및 <Fruit>를 작성한다고 가정해 보십시오. 변경하지 않아도, 새 유형은 mTopic 유형으로 처리되므로, 새 유형에 대하여 긍정, 부정, 중립 및 컨텍스트 의견을 자동으로 노출할 수 있습니다. 추출 동안, 예를 들어 문장 *"I enjoy broccoli, but I hate grapefruit"*는 다음 두 가지의 출력 패턴을 생성합니다.

broccoli <Vegetables> + like <Positive>

grapefruit <Fruit> + dislike <Negative>

그러나 mTopic에서 다른 유형과 다르게 해당 유형을 처리하려면, mPos와 같은 유형 이름을 기존 매크로에 추가하거나(모든 긍정 의견 유형이 그룹화 됨) 나중에 하나 이상의 규칙에서 참조할 수 있는 새 매크로를 작성할 수 있습니다.

**중요!** <Vegetables>와 같은 새 유형을 작성하는 경우, 이 새 유형은 mTopic에서 유형으로 포함되지만, 이 유형 이름이 명시적으로 매크로 정의에 표시되지는 않습니다.

mNonLingEntities

마찬가지로, 새 비언어 엔티티를 고급 자원 탭의 **비언어 엔티티** 섹션에서 추가하면, 달리 지정하지 않는 한 자동으로 mNonLingEntities로 처리됩니다. 자세한 정보는 비언어 엔티티의 내용을 참조하십시오.

SEP

또한 사전정의된 매크로 SEP를 사용할 수 있습니다. 이 매크로는 로컬 머신에서 정의된 전역 구분 문자(일반적으로 콤마(,))에 해당됩니다.

## 7) 텍스트 링크 규칙에 대한 작업

텍스트 링크 분석 규칙은 문장에 매치를 수행하기 위해 사용되는 부울 쿼리입니다. 텍스트 링크 분석 규칙에는 유형, 매크로, 리터럴 문자열 또는 단어 간격 인수 중 하나 이상이 포함됩니다. TLA 결과를 추출하기 위해 하나 이상의 텍스트 링크 분석 규칙을 가지고 있어야 합니다.

다음 영역 및 필드가 텍스트 링크 규칙 탭, 규칙 편집기에 표시됩니다.

**이름 필드.** 텍스트 링크 규칙의 고유 이름.

**예 필드.** 선택적으로, 이 규칙에 의해 캡처되는 예 문장 또는 단어 시퀀스를 포함할 수 있습니다. 예를 사용하도록 하십시오. 이 편집기에서, 이 예 텍스트에서 토큰을 생성하여 텍스트가 규칙에 매치되는 방법과 출력될 방법을 볼 수 있습니다. **토큰**은 추출 프로세스 중에 식별된 단어 또는 단어 문구로 정의됩니다. 예를 들어, *My uncle lives in New York* 문장에서는 추출 중에 *my, uncle, lives, in* 및 *new york* 토큰을 발견할 수 있습니다. 또한 *uncle*을 개념으로 추출하고 <Unknown>으로 유형 지정하며, *new york*을 개념으로 추출하고 <Location>으로 유형 지정할 수 있습니다. 모든 개념은 토큰이지만 모든 토큰이 개념인 것은 아닙니다. 토큰은 다른 매크로, 리터럴 문자열, 단어 간격일 수도 있습니다. 유형이 지정된 해당 단어 또는 단어 문구만 개념이 될 수 있습니다.

**규칙 값 테이블.** 이 테이블에는 규칙을 문장에 매치하기 위해 사용되는 규칙 요소가 포함되어 있습니다. 오른쪽에 있는 단추를 사용하여 테이블에서 행을 추가하거나 제거할 수 있습니다. 테이블은 세 개의 열로 구성됩니다.

- **요소 열.** 유형, 리터럴 문자열, 단어 간격(<Any Token>) 또는 매크로 중 하나 또는 이들의 조합으로 값을 입력하십시오. 자세한 정보는 규칙 및 매크로에 대해 지원되는 요소의 내용을 참조하십시오. 요소 셀을 두 번 클릭하여 정보를 직접 입력하십시오. 또는 공통 매크로, 유형 이름 및 비언어 유형 이름의 목록을 제공하는 컨텍스트 메뉴를 표시하기 위해 셀에서 마우스 오른쪽 단추를 클릭하십시오. 정보를 입력하여 셀에 입력하는 경우, '\$' 문자를 매크로 또는 유형 이름 앞에 붙이십시오(예: 매크로 mTopic의 경우 \$mTopic). 요소 행을 작성하는 순서는 규칙이 텍스트에 매치되는 방법에 중요합니다. 인수를 조합할 때, 괄호 ( )를 사용하여 인수를 그룹화하고 문자 |를 사용하여 부울 OR을 표시해야 합니다. 값에서 대소문자가 구분됩니다.
- **양 열.** 이는 매치 발생을 위해 요소가 발견되어야 하는 최소 및 최대 횟수를 표시합니다. 예를 들어, 0 - 3개 단어의 다른 두 요소 사이에 간격 또는 단어 시리즈를 정의하려는 경우, 목록에서 **0 및 3 사이**를 선택하거나 직접 대화 상자에 숫자를 입력할 수 있습니다. 기본값은 '**정확히 1**'입니다. 일부 경우에는, 요소를 선택사항으로 만들려고 합니다. 이러한 경우, 최소 양이 0이고 최대 양이 0 보다 큼(즉, 0 또는 1, 0 및 2 사이). 규칙의 첫 번째 요소는 선택사항일 수 없으며, 이는 양이 0이 될 수 없음을 의미합니다.
- **예 토큰 열.** **토큰 가져오기**를 클릭하면, 프로그램은 예 텍스트를 토큰으로 분리하고 이 토큰들을 사용하여 이 열을 사용자가 정의한 요소와 매치되는 토큰으로 채웁니다. 출력 테이블에서 이 토큰을 볼 수도 있습니다(이와 같이 표시되도록 선택하는 경우).

**규칙 출력 테이블** 이 테이블의 각 행은 TLA 패턴 출력이 결과에 나타나는 방식을 정의합니다. 규칙 출력은 최대 6개 개념/유형 열 쌍의 패턴을 생성할 수 있습니다. 각각은 슬롯을 나타냅니다. 예를 들어, 유형 패턴 <Location> + <Positive>은 두 개의 슬롯 패턴으로, 두 개의 개념/유형 열 쌍으로 구성됨을 의미합니다.

 **참고:** 규칙 값 테이블의 요소 열의 용어 또는 규칙 출력 테이블의 개념 열의 용어는 다음 문자로 시작할 수 없음: ` , # , % , ^ , \* , \_ , - , : , < , > , / , ₩ 또는 "

언어는 다양한 방식으로 동일한 기본 아이디어를 표현하기 위한 자유를 제공하므로, 동일한 기본 아이디어를 캡처하도록 정의된 여러 규칙이 있을 수 있습니다. 예를 들어, 텍스트 *"Paris is a place I love"* 및 텍스트 *"I really, really like Paris and Florence"*는 동일한 기본 아이디어 (Paris is liked)를 나타내지만 다르게 표현되어 두 개의 다른 규칙 둘 다가 캡처되어야 합니다. 그러나, 유사한 아이디어가 함께 그룹화된 경우 패턴 결과에 대해 더 쉽게 작업할 수 있습니다. 이러한 이유로, 이 두 개의 구문을 캡처하기 위한 두 가지의 다른 규칙을 가지고 있어도, 두 규칙 모두에 대해 동일한 출력을 정의할 수 있습니다(예: 둘 다 텍스트를 나타내도록 유형 패턴 <Location> + <Positive>). 그리고 이 방식에서, 출력이 항상 원래 텍스트에서 발견된 단어 순서 또는 구조를 모방하지 않음을 볼 수 있습니다. 게다가, 이러한 유형 패턴은 다른 구문과 매치될 수 있고, paris + like 및 tokyo + like와 같은 개념 패턴을 생성할 수 있습니다.

오류를 적게 하면서 신속하게 출력을 정의하려면, 컨텍스트 메뉴를 사용하여 출력에서 보려고 하는 요소를 선택할 수 있습니다. 또는 규칙 값 테이블에서 출력으로 요소를 끌어다 놓을 수 있습니다. 예를 들어, 규칙 값 테이블의 행 2에서 mTopic 매크로에 대한 참조를 포함하는 규칙을 가지고 있고 해당 값이 출력되도록 하려면, 단지 mTopic에 대한 요소를 규칙 출력 테이블의 첫 번째 열 쌍으로 끌어다 놓으면 됩니다. 이와 같이 하면 선택한 쌍에 대한 개념 및 유형 둘 다 자동으로 채워집니다. 또는 규칙 값 테이블의 세 번째 요소(행 3)에 의해 정의된 유형으로 출력이 시작되도록 하려면, 해당 유형을 규칙 값 테이블에서 출력 테이블의 **유형 1** 셀로 끄십시오. 테이블은 괄호로 행 참조를 표시하도록 업데이트됩니다(3).

또는 출력할 각 **개념** 열에서 셀을 두 번 클릭하고 \$와 행 번호를 차례로 입력하여(예: 규칙 값 테이블의 행 2에 정의된 용어를 참조할 경우 \$2) 참조를 수동으로 테이블에 입력할 수도 있습니다. 수동으로 정보를 입력할 때, **유형** 열도 정의해야 하고, #와 행 번호를 차례로 입력해야 합니다(예: 규칙 값 테이블의 2 행에 정의된 요소를 참조하는 경우 #2).

게다가, 방법을 조합할 수도 있습니다. 규칙 값 테이블의 행 4에 유형 <Positive>가 있다고 가정해 보십시오. Type 2 열로 끌어온 후 Concept 2 열에서 셀을 두 번 클릭하여 수동으로 앞에 단어 'not'을 입력할 수 있습니다. 그러면 출력 열은 테이블에서 not (4)를 읽거나, 편집 모드 또는 소스 모드에서 not \$4를 읽게 됩니다. 그러면 Type 1 열에서 마우스 오른쪽 단추를 클릭하고 예를 들어 mTopic이라고 하는 매크로를 선택할 수 있습니다. 그러면, 이 출력은 car + bad와 같은 개념 패턴이 될 수 있습니다.

대부분의 규칙에는 단 하나의 행이 있지만 두 개 이상의 출력이 가능하고 바람직한 경우가 있습니다. 이러한 경우, 규칙 출력 테이블에서 행마다 하나의 출력을 정의하십시오.

❖ **중요사항:** 다른 언어적 처리 조작은 TLA 패턴의 추출 동안 수행됩니다. 따라서 출력이 t\$3wt#3을 읽을 때, 이는 패턴이 궁극적으로 세 번째 요소에 대한 최종 개념을 표시할 것이고 모든 언어적 처리 후 세 번째 요소의 최종 유형이 적용됨을 의미합니다(동의를 및 기타 그룹).

- 지정된 대로 출력 표시. 기본적으로 규칙 값 테이블의 행에 대한 참조 옵션이 선택되고 출력은 규칙 값 탭에 정의된 대로 행에 대한 숫자 참조를 사용하여 표시됩니다. 이전에 토큰 가져오기를 클릭하고 규칙 값 테이블의 예 토큰 열에 토큰이 있는 경우, 옵션을 선택하여 이러한 특정 토큰에 대한 출력을 볼 것을 선택할 수 있습니다.

**참고:** 출력 테이블에 충분한 개념/유형 출력 쌍이 표시되지 않은 경우, 편집기 도구 모음에서 추가 단추를 클릭하여 다른 쌍을 추가할 수 있습니다. 세 개의 쌍이 현재 표시되고 추가를 클릭하는 경우, 두 개 이상의 열(개념 4 및 유형 4)이 테이블에 추가됩니다. 이는 이제 모든 규칙에 대한 출력 테이블에서 네 개의 쌍이 표시됨을 의미합니다. 또한 이 라이브러리의 규칙 세트에 있는 다른 규칙이 해당 쌍을 사용하지 않는 한 사용되지 않는 쌍을 제거할 수도 있습니다.

## 예 규칙

자원에 다음 텍스트 링크 분석 규칙이 포함되고 TLA 결과 추출을 사용하도록 설정하였다고 가정해 보십시오.

그림 1. 텍스트 링크 규칙 탭: 규칙 편집기

Output columns: [Add](#) [Remove](#) [View Source](#)

Name:

Example:

Rule Value table:

	Element	Quantity	Example Token
1	mSupportNeg	Exactly 1	isn't
2		0 or 1	
3	( anything  (( any   a   one ) thing ?))	Exactly 1	anything
4		Between 0 and 2	that i
5	mNeg	Exactly 1	disliked
6	( about   with   in )	Exactly 1	about
7		0 or 1	
8	mDet	0 or 1	the

Buttons: [Get Tokens](#), [Insert Row](#), [Remove Row](#)

Rule Output table:

Concept 1	Type 1	Concept 2	Type 2	Concept 3	Type 3
product (9)	<a href="#">Products</a> (9)	no dislike (5)	<a href="#">Positive</a>		

Show output as:  References to row in Rule Value table  Specific token from example

[Apply](#) [Cancel](#)

추출할 때마다, 추출 엔진은 각 문장을 읽고 다음 시퀀스와 매치하려고 합니다.

표 1. 추출 시퀀스 예

요소(행)	인수 설명
1	매크로 mPos 또는 mNeg에 의해 표시되는 유형 중 하나, 또는 유형 <Uncertain>의 개념.
2	매크로 mTopic에 의해 표시되는 유형 중 하나로 입력된 개념.
3	매크로 mBe에 의해 표시되는 단어 중 하나.
4	단어 간격 또는 <Any Token>으로도 언급되는 선택적 요소(0 또는 1개 단어)
5	매크로 mTopic에 의해 표시되는 유형 중 하나로 입력된 개념.

출력 테이블은 이 규칙에서 원하는 모든 것이 **규칙 값 테이블**의 행 5에 정의된 mTopic 매크로 + **규칙 값 테이블**의 행 1에 정의된 대로 mPos, mNeg 또는 <Uncertain>에 해당하는 개념 또는 유형인 패턴임을 보여줍니다. 이는 sausage + like 또는 <Unknown> + <Positive>가 될 수 있습니다.

### (1) 규칙 작성 및 편집

새 규칙을 작성하거나 기존 규칙을 편집할 수 있습니다. 규칙 편집기에 대한 지침과 설명을 따르십시오. 자세한 정보는 텍스트 링크 규칙에 대한 작업의 내용을 참조하십시오.

#### 새 규칙 작성

1. 메뉴에서 **도구 > 새 규칙**을 선택하십시오. 또는 트리 도구 모음에서 새 규칙 아이콘을 클릭하여 편집기에서 새 규칙을 여십시오.
2. 고유한 이름을 입력하고 규칙 값 요소를 정의하십시오.
3. 오류 확인을 완료하면 **적용**을 클릭하십시오.

#### 규칙 편집

1. 트리에서 규칙 이름을 클릭하십시오. 규칙은 오른쪽에 있는 편집기 분할창에서 열립니다.
2. 변경사항을 작성하십시오.
3. 오류 확인을 완료하면 **적용**을 클릭하십시오.

## (2) 규칙 사용 안함 및 삭제

### 규칙 사용 안함

처리 중에 규칙이 무시되도록 하려면 이 규칙을 사용하지 않도록 설정할 수 있습니다. 규칙을 삭제하거나 사용하지 않도록 설정할 때 주의하십시오.

1. 트리에서 규칙 이름을 클릭하십시오. 규칙은 오른쪽에 있는 편집기 분할창에서 열립니다.
2. 이름을 마우스 오른쪽 단추로 클릭하십시오.
3. 컨텍스트 메뉴에서 **사용할 수 없음**을 선택하십시오. 규칙 아이콘은 회색이 되고 규칙 자체는 편집할 수 없게 됩니다.

### 규칙 삭제

규칙을 제거하기 위해 규칙을 삭제할 수 있습니다. 규칙을 삭제하거나 사용하지 않도록 설정할 때 주의하십시오.

1. 트리에서 규칙 이름을 클릭하십시오. 규칙은 오른쪽에 있는 편집기 분할창에서 열립니다.
2. 이름을 마우스 오른쪽 단추로 클릭하십시오.
3. 컨텍스트 메뉴로부터 **삭제**를 선택하십시오. 규칙이 목록에서 사라집니다.

## (3) 오류 확인, 저장 및 취소

### 규칙 변경사항 적용

규칙 편집기 외부로 클릭하거나 **적용**을 클릭하는 경우, 규칙은 오류를 찾기 위해 자동으로 스캔됩니다. 오류가 발견되면, 애플리케이션의 다른 부분으로 이동하기 전에 수정해야 합니다.

그러나 덜 심각한 오류가 발견되면, 경고만 제공됩니다. 예를 들어, 규칙에 유형 또는 매크로에 대한 완료되지 않거나 참조되지 않는 정의가 있는 경우, 경고 메시지가 표시됩니다. **적용**을 클릭하는 경우, 정정되지 않은 경고는 왼쪽 분할창에 있는 트리에서 규칙 이름의 왼쪽에 경고 아이콘이 나타나도록 합니다.

규칙을 적용해도 규칙이 영구적으로 저장됨을 의미하지는 않습니다. 적용하면 오류 및 경고에 대해 확인하기 위해 검증 프로세스가 발생합니다.

### 대화형 워크벤치 세션 내에서 자원 저장

1. 대화식 워크벤치 세션 동안 자원에 대해 작성한 변경사항을 저장하기 위해, 다음에 스트림을 실행할 때 변경사항을 가져올 수 있습니다.

- 다음에 스트림을 실행할 때 동일한 자원을 가져올 수 있도록 모델링 노드를 업데이트하십시오. 자세한 정보는 모델링 노드 업데이트 및 저장의 내용을 참조하십시오. 그런 다음 스트림을 저장하십시오. 스트림을 저장하려면, 모델링 노드를 업데이트한 후 기본 IBM® SPSS® Modeler 창에서 저장을 수행하십시오.
2. 다른 스트림에서 사용할 수 있도록 대화식 워크벤치 세션 동안 자원에 대해 작성한 변경사항을 저장하기 위해, 다음을 수행할 수 있습니다.
- 사용한 템플릿을 업데이트하거나 새 템플릿을 작성하십시오. 자세한 정보는 템플릿 작성 및 업데이트의 내용을 참조하십시오. 현재 노드에 대한 변경사항은 저장되지 않습니다(이전 단계 참조).
  - 또는 사용한 TAP를 업데이트하십시오. 자세한 정보는 텍스트 분석 패키지 업데이트의 내용을 참조하십시오.

#### 템플릿 편집기 내에서 자원 저장

1. 먼저 라이브러리를 출판하십시오. 자세한 정보는 라이브러리 출판의 내용을 참조하십시오.
2. 그런 다음, 메뉴에서 **파일 > 자원 템플릿 저장**을 통해 템플릿을 저장하십시오.

#### 규칙 변경사항 취소

1. 변경사항을 삭제하려면, 편집기 창에서 **취소**를 클릭하십시오.

## 8) 규칙 순서 처리

텍스트 링크 분석이 추출 동안 수행될 때, 매치가 발견되거나 모든 규칙이 소모될 때까지 각 규칙에 대해 차례로 "문장"(절, 단어, 구문)이 매치됩니다. 트리에서 위치는 규칙이 시도되는 순서를 알려줍니다. 우수 사례는 가장 특정한 규칙에서 가장 일반적인 규칙으로 순서를 지정하는 것입니다. 가장 특정한 규칙은 트리의 맨 위에 있어야 합니다. 특정 규칙 또는 규칙 세트의 순서를 변경하려면, 도구 모음의 위 및 아래 화살표나 규칙 및 매크로 트리 컨텍스트 메뉴를 통해 **위로 이동** 또는 **아래로 이동**을 선택하십시오.

소스 보기에 있는 경우, 편집기에서 이동하여 규칙의 순서를 변경할 수 없습니다. 소스 보기에서 규칙이 더 위에 표시될수록 더 빨리 처리됩니다. 복사/붙여넣기 문제를 방지하려면 트리에서만 규칙을 다시 정렬하도록 하십시오.

**중요!** IBM® SPSS® Modeler Text Analytics의 이전 버전에서는, 고유한 숫자 규칙 ID를 가지고 있어야 했습니다. 18.3.0 버전부터는 트리에서 규칙을 위 또는 아래로 이동하거나 소스 보기에서 해당 위치에 의해서만 처리 순서를 표시할 수 있습니다.

예를 들어, 텍스트에 다음 두 개의 문장이 포함되어 있다고 가정하십시오.

*I love anchovies*

*I love anchovies and green peppers*

또한 다음 값을 가지고 있는 두 개의 텍스트 링크 분석 규칙이 존재한다고 가정해 보십시오.

그림 1. 두 가지의 예 규칙

<b>A</b>			
	Element	Quantity	Example Token
1	Positive	Exactly 1	
2	mDet	0 or 1	
3	mTopic	Exactly 1	
4			
5			
6			
7			

<b>B</b>			
	Element	Quantity	Example Token
1	Positive	Exactly 1	
2	mDet	0 or 1	
3	mTopic	Exactly 1	
4	( SEP   and   or )	1 or 2	
5	mDet	0 or 1	
6	mTopic	Exactly 1	
7			

소스 보기에서, 규칙 값은 다음과 유사할 수 있습니다.

A: value = \$Positive \$mDet? \$mTopic

B: value = \$Positive \$mDet? \$mTopic (\$SEPlandlor){1,2} \$mDet? \$mTopic

규칙 **A**가 규칙 **B**보다 트리에서 위(맨 위 가까이)에 있으면, 규칙 **A**가 먼저 처리되고 문장 *I love anchovies and green peppers*는 \$Positive \$mDet? \$mTopic에 의해 먼저 매치되어, 불완전한 패턴 출력(anchovies + like)을 생성합니다. 두 개의 \$mTopic 매치에 대해 찾지 못한 규칙에 의해 매치되었기 때문입니다.

따라서, 텍스트의 본질을 캡처하려면 가장 특정한 규칙(이 경우 **B**)이 더 일반적인 규칙(이 경우 **A**)보다 트리에서 위에 위치되어야 합니다.

## 9) 규칙 세트에 대한 작업(다중 전달)

규칙 세트는 여러 전달 프로세스를 수행하도록 규칙 및 매크로 트리에서 함께 관련 규칙 세트를 그룹화하는 유용한 방법입니다. 규칙 세트에는 이름 이외의 어떤 정의 자체도 없으며 규칙을 의미있는 그룹으로 구성하기 위해 사용됩니다. 일부 컨텍스트에서, 텍스트는 너무 서식이 많고 단일 전달로 처리되기에는 다양합니다. 예를 들어, 보안 정보 데이터에 대해 작업할 때, 텍스트는 접속 방법(*x called y*), 가족 관계(*y's brother-in-law x*), 화폐 교환(*x wired \$100 to y*) 등을 통해 노출되는 개별값 사이의 링크를 포함할 수 있습니다. 이러한 경우, 특수화된 텍스트 링크 분석 규칙 세트를 작성하는 것이 유용합니다. 이 세트는 노출되는 접속에 대한 하나의 관계, 노출되는 가족 구성원에 대한 다른 관계 등 특정 종류의 관계에 초점을 맞춥니다.

규칙 세트를 작성하려면, 규칙 및 매크로 트리 컨텍스트 메뉴나 도구 모음에서 “규칙 세트 작성”을 선택하십시오. 그러면 트리의 규칙 세트 노드 아래에서 직접 새 규칙을 작성하거나 규칙 세트에 기존 규칙을 이동할 수 있습니다.

규칙이 규칙 세트로 그룹화되는 자원을 사용하여 추출을 실행할 때, 추출 엔진은 각각의 전달에서 서로 다른 종류의 패턴과 매치하기 위해 텍스트를 통하여 여러 전달을 작성하도록 강요할 수 있습니다. 이러한 경우, "문장"은 각 규칙 세트에서 규칙에 매치될 수 있는 반면, 규칙 세트 없이는 단일 규칙에만 매치될 수 있습니다.

참고: 규칙 세트마다 최대 512개의 규칙을 추가할 수 있습니다.

### 새 규칙 세트 작성

1. 메뉴에서 **도구 > 새 규칙 세트**를 선택하십시오. 또는 트리 도구 모음에서 새 규칙 세트 아이콘을 클릭하십시오. 규칙 세트는 규칙 트리에 나타납니다.
2. 이 규칙 세트에 새 규칙을 추가하거나 기존 규칙을 세트로 이동하십시오.

### 규칙 세트 사용 안함

1. 트리에서 규칙 세트 이름을 마우스 오른쪽 단추로 클릭하십시오.
2. 컨텍스트 메뉴에서 **사용할 수 없음**을 선택하십시오. 규칙 세트 아이콘은 회색이 되고 해당 규칙 세트 내에 포함된 모든 규칙 역시 처리 동안 사용할 수 없도록 되어 무시됩니다.

### 규칙 세트 삭제

1. 트리에서 규칙 세트 이름을 마우스 오른쪽 단추로 클릭하십시오.
2. 컨텍스트 메뉴로부터 **삭제**를 선택하십시오. 포함하는 규칙 세트와 모든 규칙이 자원에서 삭제됩니다.

## 10) 규칙 및 매크로에 대해 지원되는 요소

다음 인수는 텍스트 링크 분석 규칙 및 매크로의 값 매개변수에 대해 승인됩니다.

### 매크로

텍스트 링크 분석 규칙이나 다른 매크로에서 직접 매크로를 사용할 수 있습니다. 직접 매크로 이름을 입력하거나 소스 보기에서 입력하는 경우(컨텍스트 메뉴에서 매크로 이름을 선택하는 것과 반대로), 달러 부호 문자(\$)가 이름 앞에 붙여 있는지 확인하십시오(예: \$mTopic). 매크로 이름에서는 대소문자가 구분됩니다. 컨텍스트 메뉴를 통해 매크로를 선택할 때 현재 텍스트 링크 규칙 탭에서 정의된 매크로에서 선택할 수 있습니다.

### 유형

텍스트 링크 분석 규칙이나 매크로에서 직접 유형을 사용할 수 있습니다. 직접 유형 이름을 입력하거나 소스 보기에서 입력하는 경우(컨텍스트 메뉴에서 유형을 선택하는 것과 반대로), 달러 부호 문자(\$)가 유형 이름 앞에 붙여 있는지 확인하십시오(예: \$Person). 유형 이름에서는 대소문자가 구분됩니다. 컨텍스트 메뉴를 사용하는 경우, 사용되는 현재 자원 세트의 유형에서 선택할 수 있습니다.

인식되지 않은 유형을 참조하는 경우, 경고 메시지를 수신하고 규칙에는 사용자가 작성할 때까지 규칙 및 매크로 트리에 경로 아이콘이 있습니다.

### 리터럴 문자열

추출되지 않은 정보를 포함하기 위해, 추출 엔진이 검색할 리터럴 문자열을 정의할 수 있습니다. 추출된 모든 단어 또는 구문이 유형에 지정되었고 이러한 이유로 리터럴 문자열에서 사용할 수 없습니다. 추출된 단어를 사용하는 경우, 해당 유형이 <Unknown>인 경우에도 무시됩니다.

리터럴 문자열은 하나 이상의 단어가 될 수 있습니다. 다음 규칙은 리터럴 문자열을 정의할 때 적용됩니다.

- 문자열 목록을 (his)와 같이 괄호로 묶으십시오. 리터럴 문자열 선택사항이 있는 경우 각 문자열은 OR 연산자에 의해 구분됩니다(예: (alan|the) 또는 (his|hers|lits)).
- 단일 또는 복합 단어를 사용하십시오.
- 목록의 각 단어를 | 문자(부울 OR)로 구분하십시오.
- 단수 및 복수 양식 모두를 매치하려면 두 양식을 입력하십시오. 굴절은 자동으로 생성되지 않습니다.
- 소문자만 사용하십시오.
- 리터럴 문자열을 재사용하려면, 이 리터럴 문자열을 매크로로 정의한 후 다른 매크로 및 텍스트 링크 분석 규칙에서 해당 매크로를 사용하십시오.

- 문자열에 마침표(전체 중지)이나 하이픈이 있는 경우, 이들도 포함해야 합니다. 예를 들어, 텍스트에서 a.k.a를 매치하려면 리터럴 문자열로 문자 a.k.a와 함께 마침표를 입력하십시오.

### 제외 연산자

특정 슬롯 차지에서 부정 표현식을 중지하려면 제외 연산자로 !를 사용하십시오. 인라인 셀 편집을 통해 직접(규칙 값 테이블 또는 매크로 값 테이블에서 셀을 두 번 클릭) 추가하거나 소스 보기에서 추가할 수 있습니다. 예를 들어, \$mTopic @{0,2} !(\$Positive) \$Budget을 텍스트 링크 분석 규칙에 추가하는 경우, (1) mTopic 매크로에서 유형에 지정된 용어를 포함하고, (2) 0 - 2 개 단어 길이의 단어 간격을 포함하며, (3) <Positive> 유형에 지정된 용어의 인스턴스는 전혀 없고, (4) <Budget> 유형에 지정된 용어를 포함하는 텍스트를 찾습니다. 이는 "cars have an inflated price tag"를 캡처할 수 있지만 "store offers amazing discounts"는 무시됩니다.

이 연산자를 사용하려면, 셀을 두 번 클릭하여 요소 셀에 수동으로 느낌표와 괄호를 입력해야 합니다.

### 단어 간격(<Any Token>)

<Any Token>이라고도 하는 단어 간격은 두 요소 사이에 있을 수 있는 토큰의 숫자 범위를 정의합니다. 단어 간격은 추가 한정사, 위치 문구, 형용사 또는 다른 이와 같은 단어의 존재로, 약간만 다를 수 있는 매우 유사한 구문과 매치할 때 아주 유용합니다.

표 1. 단어 간격 없이 규칙 값 테이블에서 요소의 예

#	요소
1	 Unknown
2	 mBeHave
3	 Positive

참고: 소스 보기에서 이 값은 \$Unknown \$mBeHave \$Positive로 정의됩니다.

이 값은 "the hotel staff was nice"와 같은 문장을 매치합니다. 여기서 hotel staff는 유형 <Unknown>에 속하며, was는 매크로 mBeHave 아래에 있고 nice는 <Positive> 아래에 있습니다. 그러나 "the hotel staff was very nice"는 매치하지 않습니다.

표 2. <Any Token> 단어 간격의 규칙 값 테이블의 요소 예

#	요소
1	 Unknown
2	 mBeHave
3	
4	 Positive

참고: 소스 보기에서 이 값은 \$Unknown \$mBeHave @{0,1} \$Positive로 정의됩니다.

단어 간격을 규칙 값에 추가하면, “the hotel staff was nice” 및 “the hotel staff was very nice” 둘 다에 매치됩니다.

소스 보기에서, 또는 인라인 편집 사용 시 단어 간격의 명령문은 @{#,#}입니다. 여기서 @은 단어 간격을 나타내고 {#,#}은 이전 요소와 다음 요소 사이에 승인된 최소 및 최대 단어 수를 정의합니다. 예를 들어, @{1,3}은 최소 하나의 단어가 존재하지만 세 개 이하의 단어가 두 요소 사이에 나타나는 경우 정의된 두 요소 사이에 매치가 작성될 수 있음을 의미합니다. @{0,3}은 0, 1, 2 또는 3개 단어가 존재하지만 세 개 이하의 단어가 두 요소 사이에 나타나는 경우 정의된 두 요소 사이에 매치가 작성될 수 있음을 의미합니다.

## 11) 소스 모드에서 보기 및 작업

각 규칙 및 매크로에 대해, TLA 편집기는 TLA 출력 매치 및 생성을 위해 추출기에서 사용되는 기본적인 소스 코드를 생성합니다. 코드 자체에 대해 작업하려는 경우, 이 소스 코드를 보고 편집기의 맨 위에 있는 “소스 보기” 단추를 클릭하여 직접 편집할 수 있습니다. 소스 보기는 현재 선택된 규칙 또는 매크로로 점프하여 강조표시합니다. 그러나 오류 가능성을 줄이기 위해 편집기 분할창을 사용할 것을 권장합니다.

소스 보기 및 편집을 완료하면 소스 종료를 클릭하십시오. 규칙에 대한 유효하지 구문이 생성되면, 먼저 이 구문을 수정하고 소스 코드를 종료해야 합니다.

❖ **중요사항:** 소스 보기에서 편집하는 경우, 규칙과 매크로를 한 번에 하나씩 편집하도록 합니다. 매크로를 편집한 후, 추출한 결과의 유효성을 검증하십시오. 결과에 만족하면, 다른 변경을 작성하기 전에 템플릿을 저장하도록 하십시오. 결과에 만족하지 않거나 오류가 발생하면 저장된 자원으로 되돌리십시오.

## 소스 보기의 매크로

```
[macro]
name = macro_name
value = ([type_name|macro_name|literal_string|word_gap])
```

표 1. 매크로 항목

[macro]	각 매크로는 매크로의 시작을 표시하기 위해 [macro] 표시가 있는 행으로 시작해야 합니다.
name	매크로 정의의 이름. 각 이름은 고유해야 합니다.
value	하나 이상의 유형, 리터럴 문자열, 단어 간격 또는 매크로의 조합. 자세한 정보는 규칙 및 매크로에 대해 지원되는 요소 주제를 참조하십시오. 인수를 조합할 때, 소괄호 ( )를 사용하여 인수를 그룹화하고 문자  를 사용하여 부울 OR을 표시해야 합니다.

매크로의 섹션에 수록된 지침 및 구문 외에, 편집기 보기에서 작업할 때 필요하지 않은 몇 가지의 추가 지침이 소스 보기에 있습니다. 매크로는 또한 소스 모드에서 작업할 때 다음 사항을 준수해야 합니다.

- 각 매크로는 매크로 시작을 표시하기 위해 [macro] 표시가 있는 행으로 시작해야 합니다.
- 요소를 사용하지 않도록 설정하려면 각 행 앞에 주석 표시기(#)를 입력하십시오.

예. 다음 예는 mTopic이라고 하는 매크로를 정의합니다. mTopic의 값은 <Product>, <Person>, <Location>, <Organization>, <Budget> 또는 <Unknown> 유형 중 *하나*와 매치되는 항의 존재입니다.

```
[macro]
name=mTopic
value=($Unknown|$Product|$Person|$Location|$Organization|$Budget|$Currency)
```

## 소스 보기의 규칙

```
[pattern(ID)]
name = pattern_name
value = [$type_name|macro_name|word_gaps|literal_strings]
output = $digit[wt]#digit[wt]$digit[wt]#digit[wt]$digit[wt]#digit[wt]
```

표 2. 규칙 항목

[pattern (<ID>)]	해당 텍스트 링크 분석의 시작을 표시하고 처리 순서를 판별하기 위해 고유한 숫자 ID 사용을 제공합니다.
name	이 텍스트 링크 분석 규칙에 대한 고유 이름을 제공합니다.
value	텍스트에 매치될 인수 및 구문을 제공합니다. 자세한 정보는 규칙 및 매크로에 대해 지원되는 요소의 내용을 참조하십시오.
output	<p>텍스트에서 발견되는, 매치 패턴 결과에 대한 출력 형식. 출력은 소스 텍스트에서 요소의 정확한 원래 위치와 항상 유사하지는 않습니다. 또한 각각의 출력을 별도의 행에 놓아서 제공된 텍스트 링크 분석 규칙에 대해 여러 출력을 수반할 수 있습니다.</p> <p>출력 구문:</p> <ul style="list-style-type: none"> <li>- 출력을 탭 코드 wt로 구분하십시오(예: \$1wt#1wt\$3wt#3).</li> <li>- \$ 및 숫자는 해당 위치에서 값 매개변수에 정의된 인수와 매치되는 발견된 항목을 요청합니다. 따라서 \$1은 값에 대해 정의된 첫 번째 인수와 매치되는 항목을 의미합니다.</li> <li>- # 및 숫자는 해당 위치에서 요소의 유형 이름을 요청합니다. 항목이 리터럴 문자열 목록인 경우, 유형 &lt;Unknown&gt;이 지정됩니다.</li> <li>- NullwtNull 값은 어떤 출력도 작성하지 않습니다.</li> </ul>

규칙의 섹션에 수록된 지침 및 구문 외에, 편집기 보기에서 작업할 때 필요하지 않은 몇 가지의 추가 지침이 소스 보기에 있습니다. 규칙은 또한 소스 모드에서 작업할 때 다음 사항을 준수해야 합니다.

- 두 개 이상의 요소가 정의될 때마다, 선택사항 여부에 관계없이 괄호로 묶어야 합니다(예: (\$Negative)\$Positive) 또는 (\$mCoord|\$SEP?). \$SEP는 콤마를 나타냅니다.
- 텍스트 링크 분석 규칙에서 첫 번째 요소는 선택적 요소가 될 수 없습니다. 예를 들어, value = \$mTopic? 또는 value = @{0,1}로 시작할 수 없습니다.
- 양(또는 인스턴스 개수)을 토큰과 연관시킬 수 있습니다. 이는 각 케이스에 대해 별도의 규칙을 작성하는 대신 모든 케이스를 포함하는 단 하나의 규칙을 작성할 때 유용합니다. 예를 들어, ,(콤마) 또는 and와 매치하는 경우 리터럴 문자열 (\$SEP|and)를 사용할 수 있습니다. 리터럴 문자열이 (\$SEP|and){1,2}가 되도록 양을 추가하여 이를 확장하는 경우, 이제는 ", " "and" ", and" 인스턴스와 매치됩니다.
- 공백은 텍스트 링크 분석 규칙 value의 \$ 및 ? 문자와 매크로 이름 사이에서 지원되지 않습니다.
- 공백은 텍스트 링크 분석 규칙 output에서 지원되지 않습니다.
- 요소를 사용하지 않도록 설정하려면 각 행 앞에 주석 표시기(#)를 입력하십시오.

예. 자원에 다음 TLA 텍스트 링크 분석 규칙이 포함되고 TLA 결과 추출을 사용하도록 설정하였다고 가정해 보십시오.

```
## Jean Doe was the former HR director of IBM in France
[pattern(201)]
name= 1_201
value = $Person ($SEP|$mDet|$mSupport|as|then){1,2} @{0,1} $Function
(of|with|for|in|to|at) @{0,1} $Organization @{0,2} $Location
output = $1\wt#1\wt$4\wt#4\wt$7\wt#7\wt$9\wt#9
```

추출할 때마다, 추출 엔진은 각 문장을 읽고 다음 시퀀스와 매치하려고 합니다.

표 3. 추출 시퀀스 예	
위치	인수 설명
1	사람의 이름(\$Person),
2	콤마(\$SEP), 한정사(\$mDet), 보조 동사(\$mSupport), 문자열 “then” 또는 “as” 중 하나 또는 둘.
3	0 또는 1개 단어(@{0,1})
4	함수(\$Function)
5	“of”, “with”, “for”, “in”, “to” 또는 “at” 문자열 중 하나.
6	0 또는 1개 단어(@{0,1})
7	조직의 이름(\$Organization)
8	0, 1 또는 2개 단어(@{0,2})
9	위치의 이름(\$Location)

이 샘플 텍스트 링크 분석 규칙은 다음과 같이 문장 또는 구문과 매치합니다.

*Jean Doe, the HR director of IBM in France*

*Jean Doe was the former HR director of IBM in France*

*IBM appointed Jean Doe as the HR director of IBM in France*

이 샘플 텍스트 링크 분석 규칙은 다음 출력을 생성합니다.

```
jean doe <Person> hr director <Function> ibm <Organization> france <Location>
```

여기서,

- jean doe는 \$1(텍스트 링크 분석 규칙에서 첫 번째 요소)에 대응하는 항이고 <Person>은 jean doe(#1)의 유형입니다.
- hr director는 \$4(텍스트 링크 분석 규칙에서 네 번째 요소)에 해당되는 항이고 <Function>은 hr director(#4)의 유형입니다.
- ibm은 \$7(텍스트 링크 분석 규칙에서 7번째 요소)에 해당하는 항이고 <Organization>은 ibm(#7)의 유형입니다.
- france는 '\$9(텍스트 링크 분석 규칙에서 9번째 요소)에 해당하는 항이고 <Location>이 france(#9)의 유형입니다.

## 소스 보기의 규칙 세트

```
[set(<ID>)]
```

여기서 [set (<ID>)]는 규칙 세트의 시작을 표시하고 세트의 처리 순서를 판별하기 위해 사용하는 고유 숫자 ID를 제공합니다.

예. 다음 문장에는 개인, 회사 내에서 개인의 기능, 해당 회사의 합병/인수 활동에 대한 정보가 포함됩니다.

Org1 Inc has entered into a definitive merger agreement with Org2 Ltd, said John Doe, CEO of Org2 Ltd.

가능한 모든 출력을 처리하도록 몇 가지의 출력이 있는 하나의 규칙을 작성할 수 있습니다.

```
## Org1 Inc entered into a definitive merger agreement with Org2 Ltd, said  
John Doe, CEO of Org2 Ltd.
```

```
[pattern(020)]  
name=020  
value = $Organization @{0,4} $ActionNouns @{0,6} $mOrg @{1,2}  
$Person @{0,2} $Function @{0,1} $Organization  
output = $1\wt#1\wt$3\wt#3\wt$5\wt#5  
output = $7\wt#7\wt$9\wt#9\wt$11\wt#11
```

이는 다음의 두 가지 출력 패턴을 생성합니다.

- org1 inc<Organization> + merges with <ActiveVerb> + org2 ltd<Organization>
- john doe <Person> + ceo <Function> + org2 ltd<Organization>

**중요!** 다른 언어적 처리 조작은 TLA 패턴의 추출 동안 수행됩니다. 이러한 경우, merger은 추출 프로세스의 동의어 그룹화 단계 동안 merges with 아래에서 그룹화됩니다. 그리고 merges with는 <ActiveVerb> 유형에 속하므로, 이 유형 이름은 마지막 TLA 패턴 출력에 나타납니다. 따라서 출력이 t\$3wt#3을 읽을 때, 이는 패턴이 궁극적으로 세 번째 요소에 대한 최종 개념을 표시할 것이고 모든 언어적 처리 후 세 번째 요소의 최종 유형이 적용됨을 의미합니다(동의어 및 기타 그룹).

이전과 같이 복합 규칙을 작성하는 대신, 두 개의 규칙에 대해 관리하고 작업하는 것이 더 쉬울 수 있습니다. 첫 번째는 회사 사이의 합병/인수를 찾을 때 특수화됩니다.

```
[set(1)
## Org1 Inc has entered into a definitive merger agreement with Org2 Ltd
[pattern(44)]
name=firm + action + firm_0044
value=$mOrg @0,20} $ActionNouns @0,6} $mOrg
output(1)=$1wt#1wt$3wt#3wt$5wt#5
```

이는 다음을 생성합니다. org1 inc<Organization> + merges with <ActiveVerb> + org2 ltd <Organization>

두 번째는 다음과 같이 개인/기능/회사에서 특수화됩니다.

```
[set(2)
## said John Doe, CEO of Org2 Ltd
[pattern(52)]
name=individual + role + firm_0007
value=$Person @0,3} $mFunction (at|of)? ($mOrg|$Media|$Unknown)
output(1)=$1wt#1wt$3wtFunctionwt$5wt#5
```

이는 다음을 생성합니다. john doe <Person> + ceo <Function> + org2 ltd <Organization>