orange 활용 데이터 분석 및 머신 러닝

2차시

지도학습 - 회귀1

간단한 정형데이터를 이용하여
선형회귀모델을 만들어봅시다.

데이터의 종류 - ① 정형 데이터(Structured Data)

ID	Name	AGE	SEX
01	KIM	32	M
02	LEE	26	F
03	PARK	72	F
04	CHOI	15	M

	A	B	C	D	E	F
1	번호	이름	국어	수학	사회	과학
2	1	김석진	85	90	95	80
3	2	민윤기	80	95	100	70
4	3	정호석	85	90	85	95
5	4	김남준	100	80	90	90
6	5	박지민	80	95	90	100
7	6	김태형	90	100	80	100
8	7	전정국	85	75	100	85

참고 : TTA정보통신용어사전

데이터의 종류 - ② 비정형 데이터(Unstructured Data)

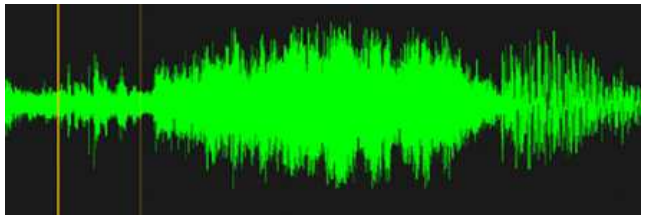

.jpg / .txt /.mp3 / .doc

지도학습, 비지도학습, 강화학습

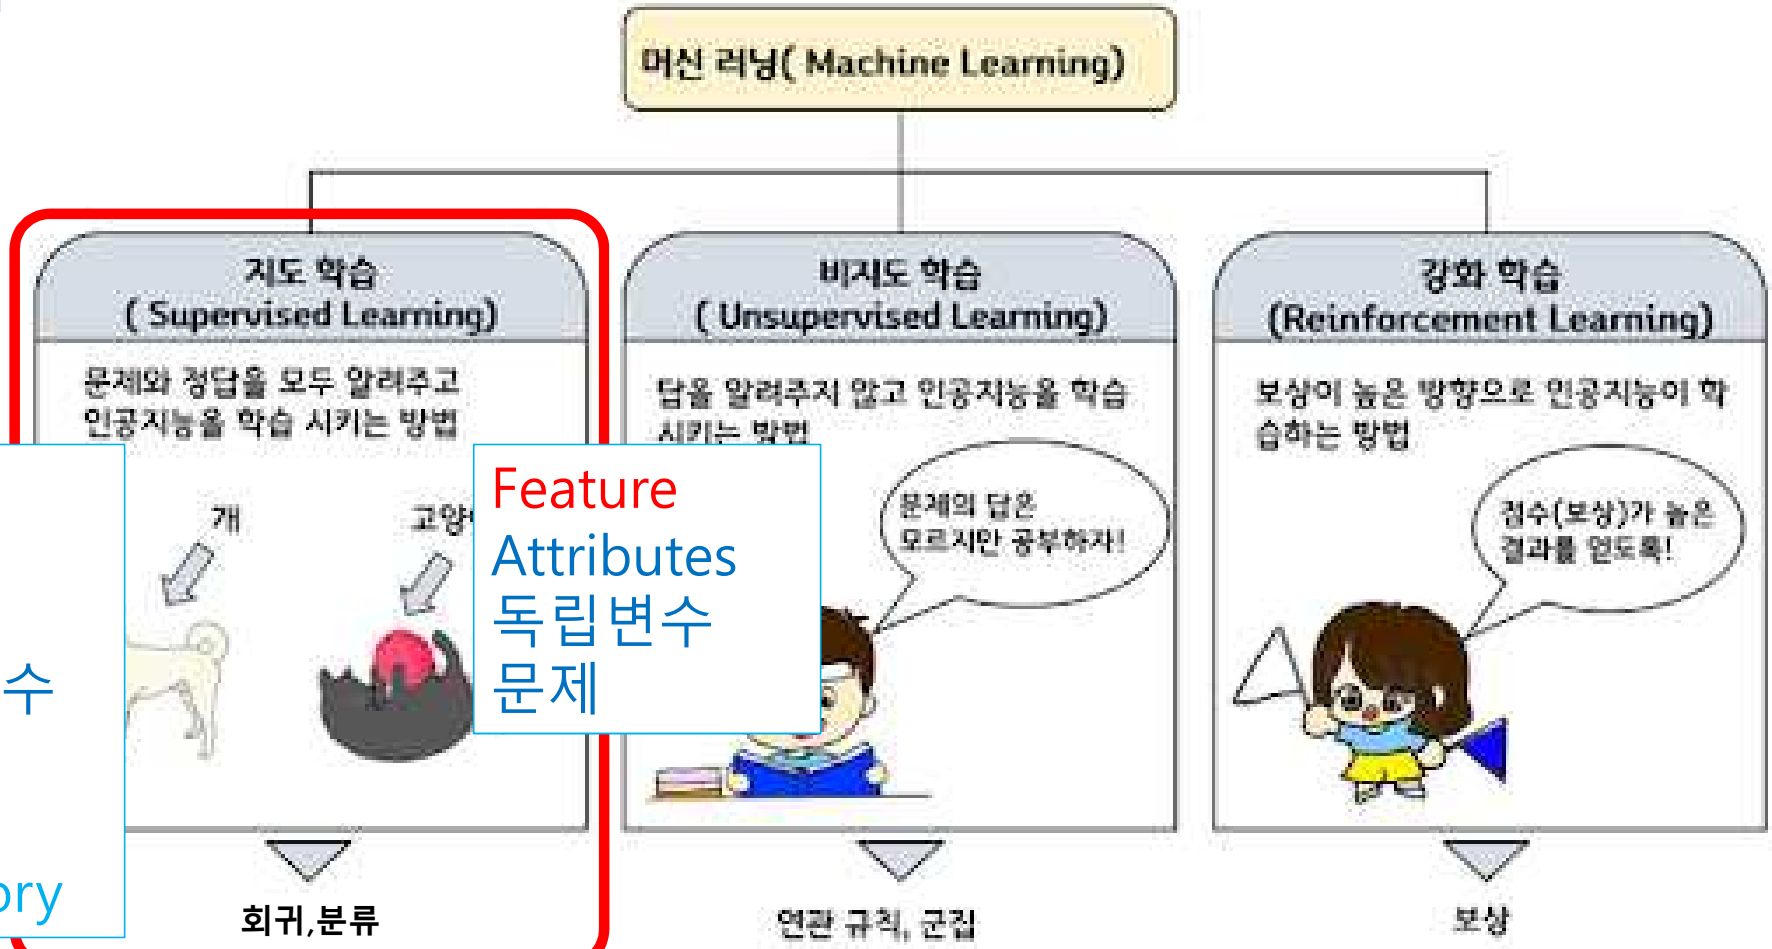

Target
Class
Label
종속변수
목푯값
정답
Category

Feature
Attributes
독립변수
문제

그림 http://ai4school.org

아주 단순한 선형회귀

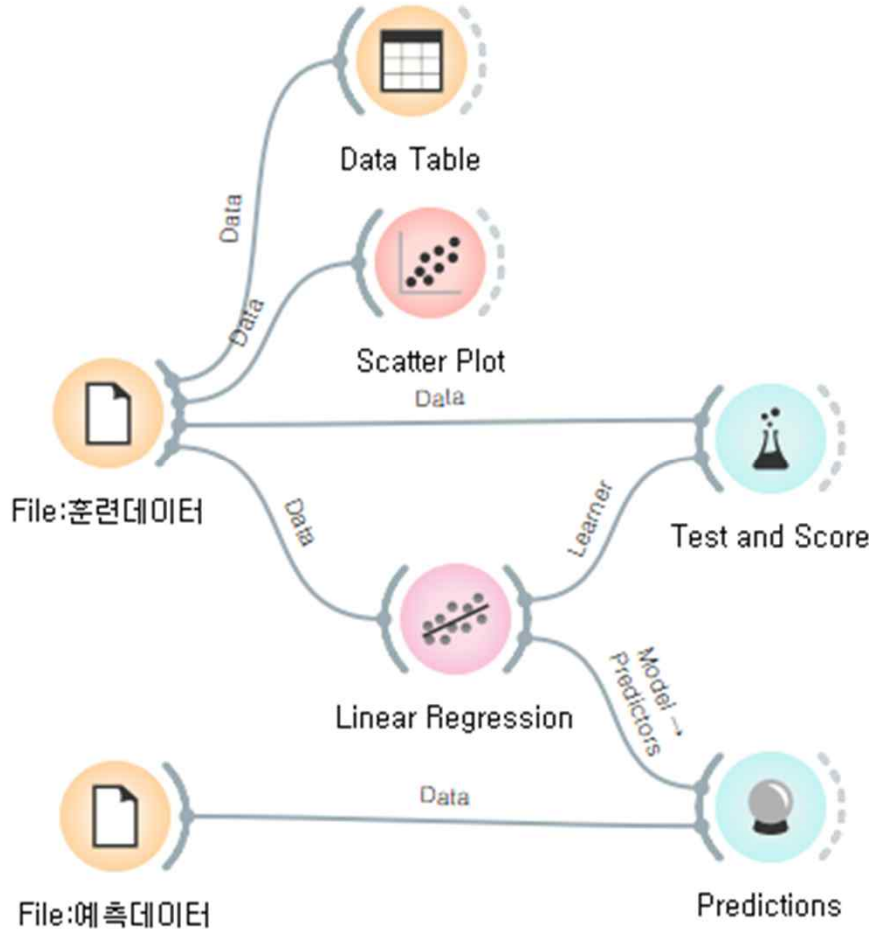
Data Table
Data
Data
Scatter Plot
Data
File:훈련데이터
Data
Learner
Test and Score
Linear Regression
Model → Predictors
Data
File:예측데이터
Predictions

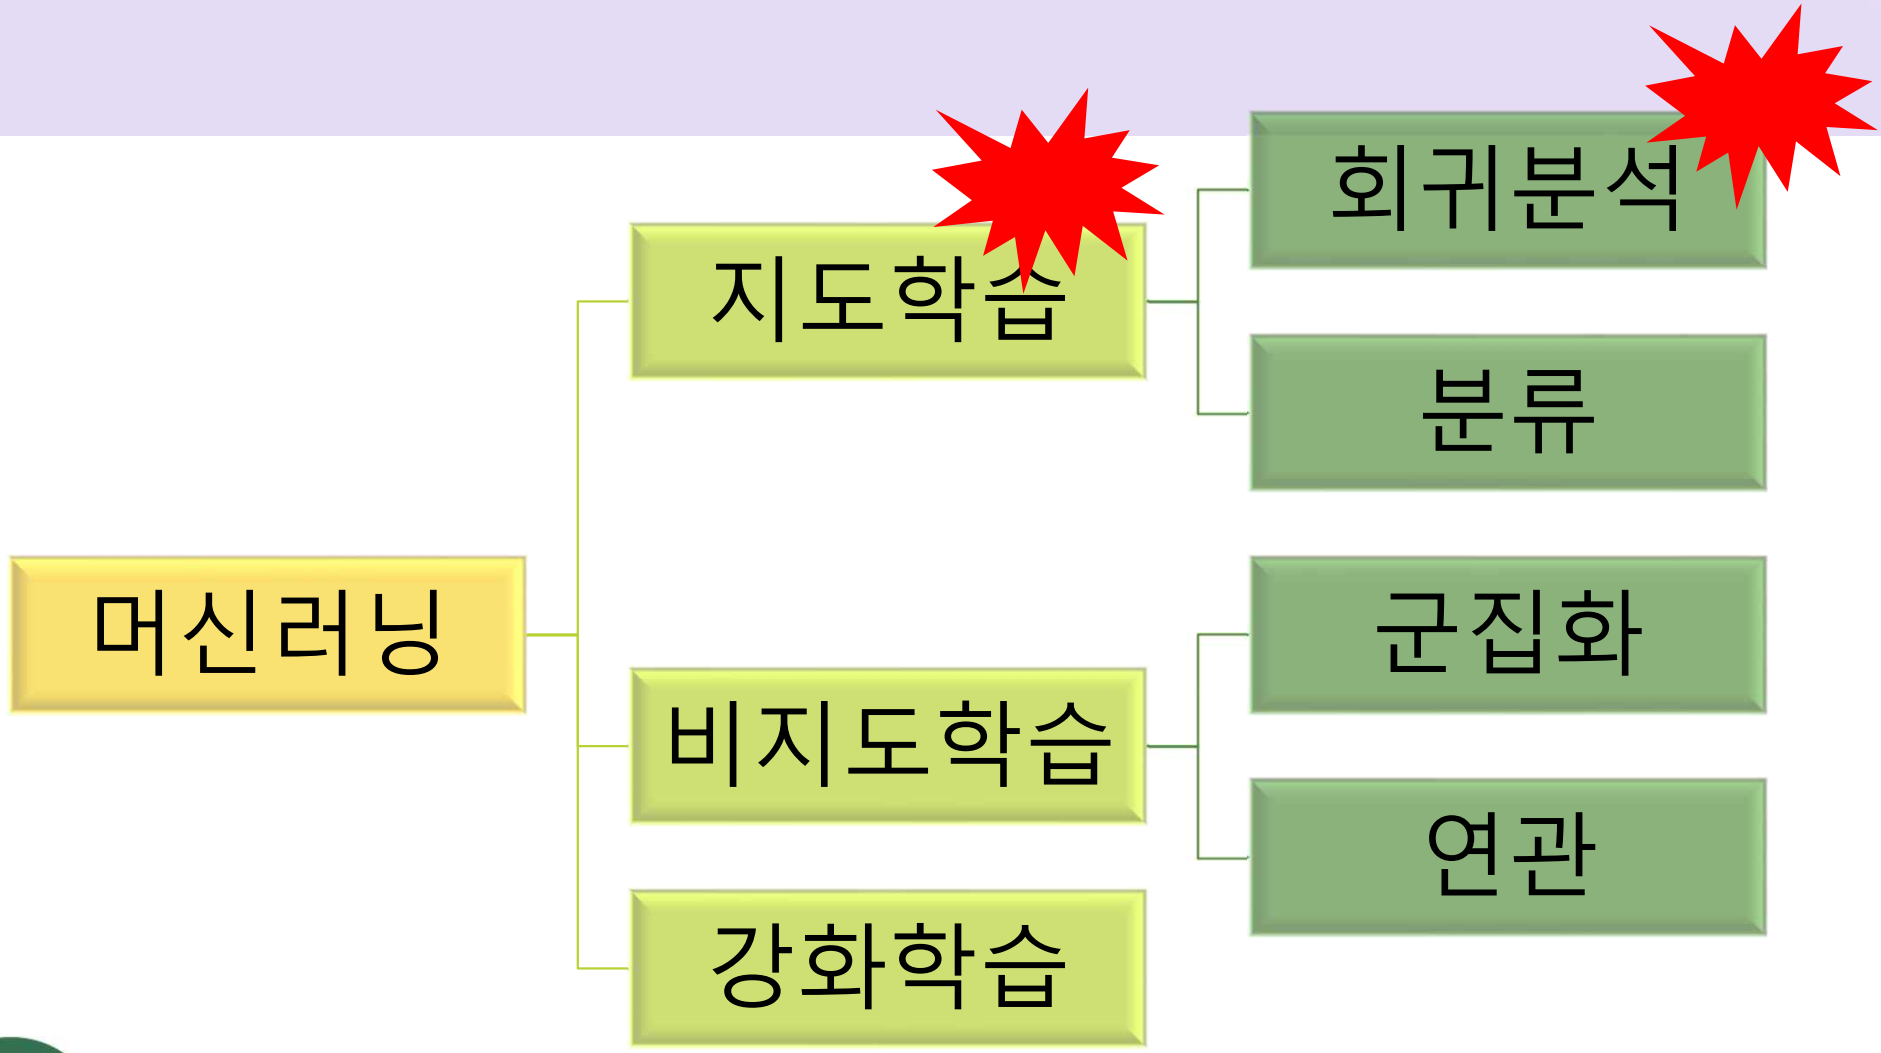
머신러닝
지도학습
회귀분석
분류
비지도학습
군집화
연관
강화학습

데이터 만들기

CSV UTF-8(쉼표로 분리)(*.csv) 선택하여
각각 train.csv와 test.csv 로 저장

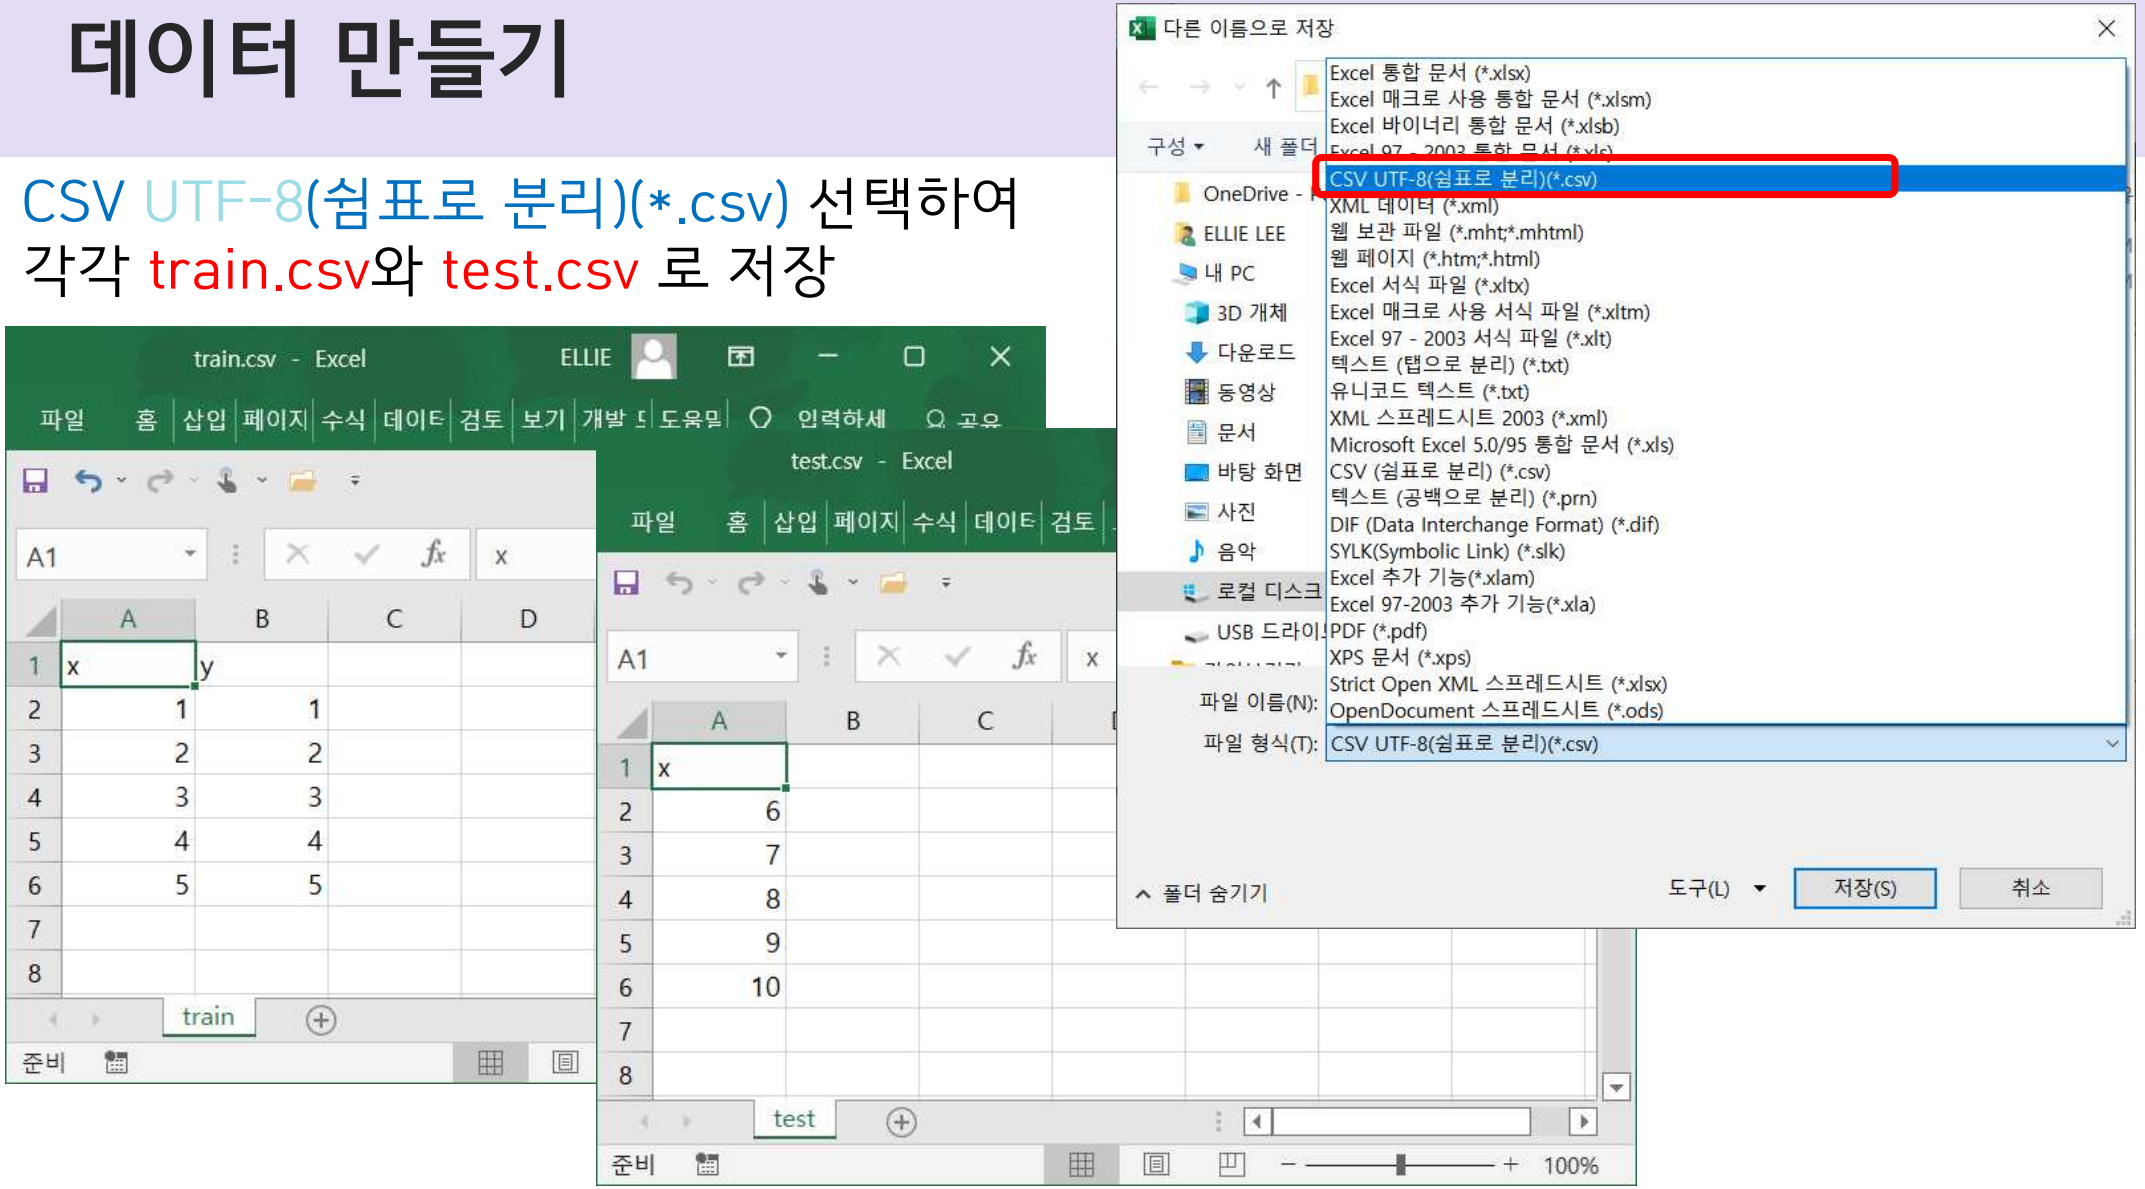

◦ CSV UTF-8(쉼표로 분리)(*.csv) 가 없을 경우 CSV (쉼표로 분리)(*.csv) 선택 -> 도구

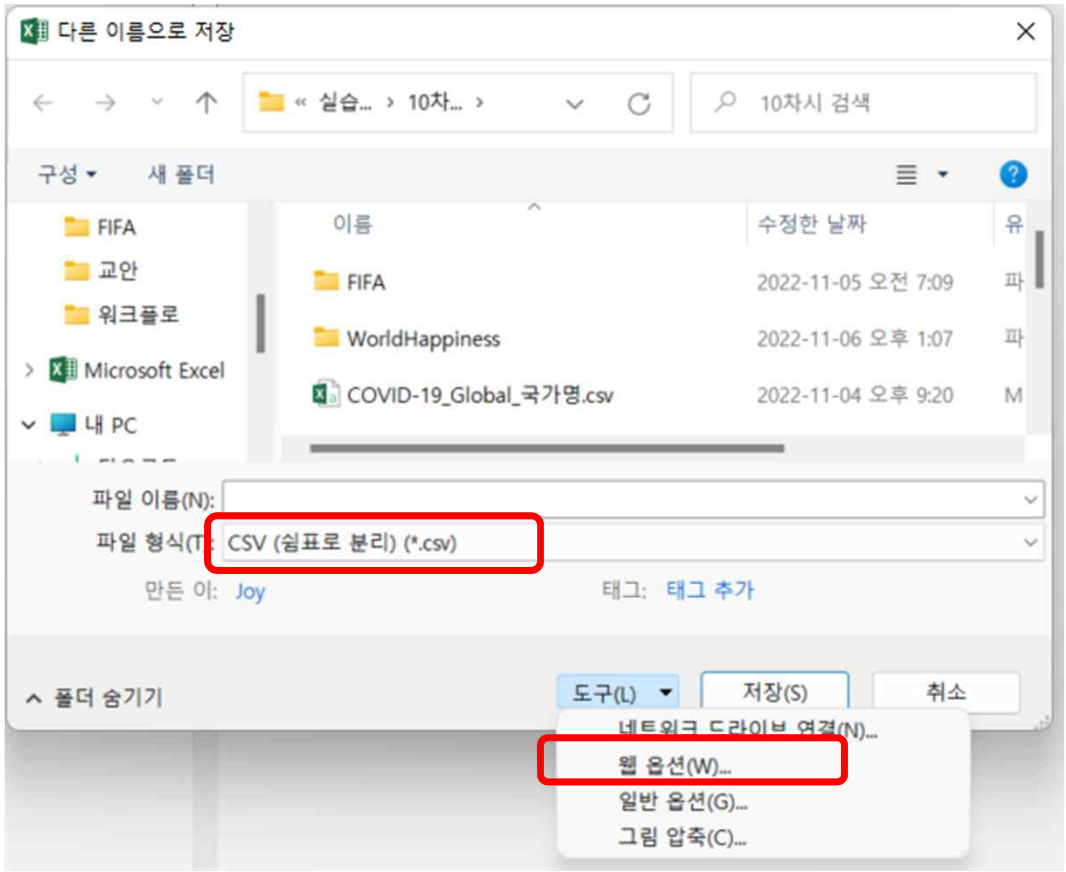

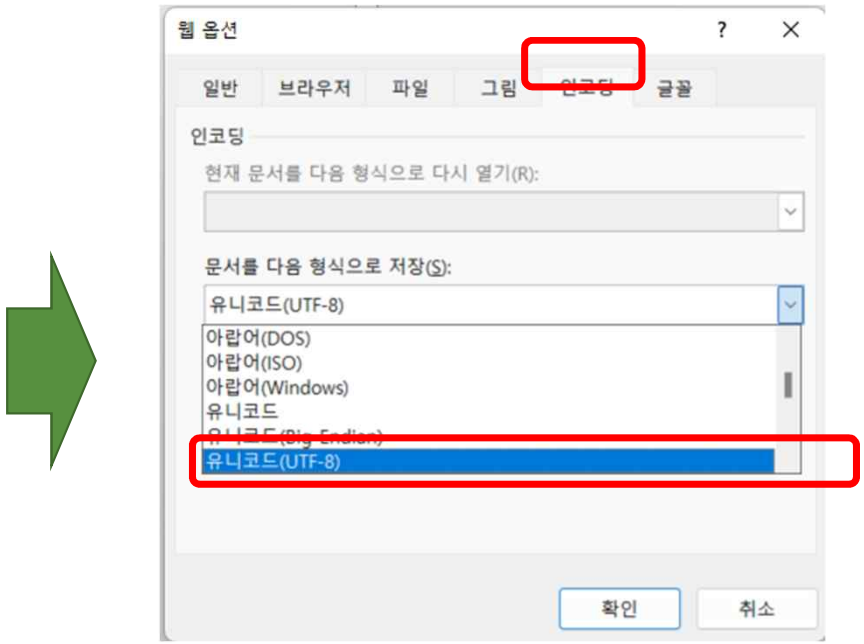

데이터 가져오기

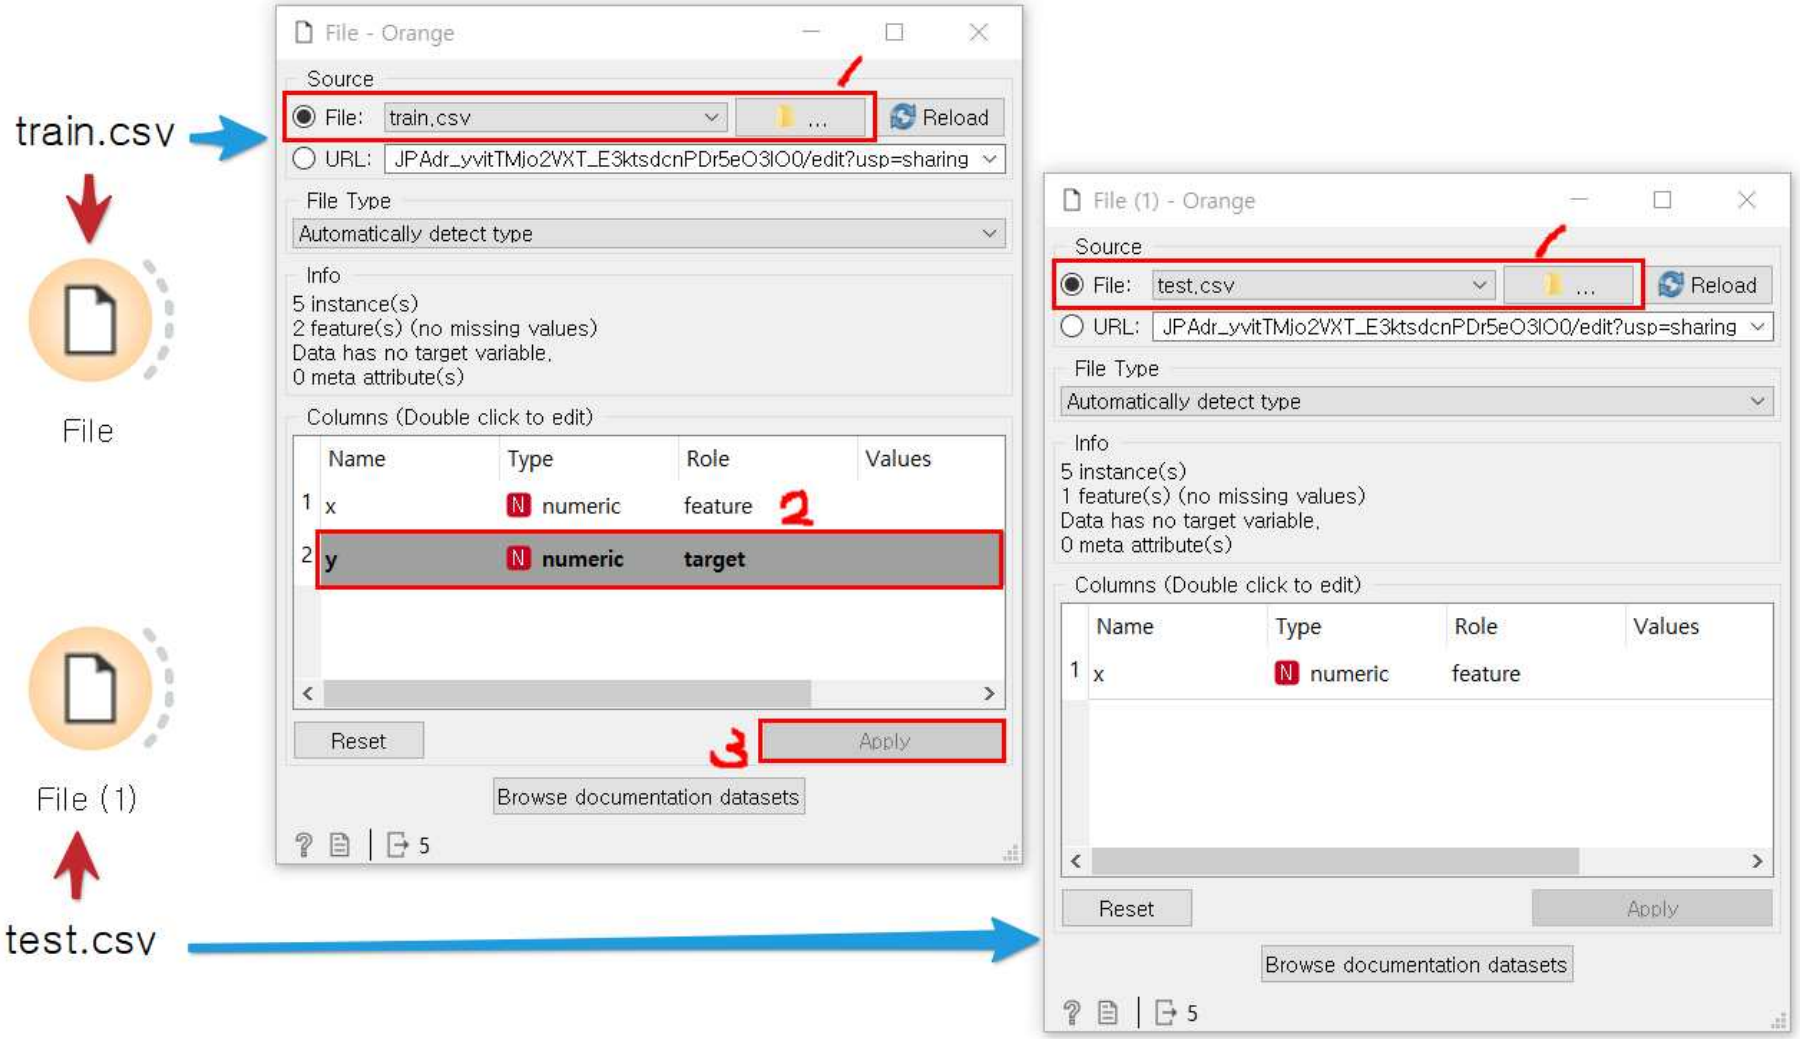
train.csv
File
File (1)
test.csv
File - Orange
Source
File: train.csv
Reload
URL: JPAdr_yvitTMjo2VXT_E3ktsdcnPDr5eO3lO0/edit?usp=sharing
File Type
Automatically detect type
Info
5 instance(s)
2 feature(s) (no missing values)
Data has no target variable.
0 meta attribute(s)
Columns (Double click to edit)
Name Type Role Values
1 x numeric feature
2 y numeric target
Reset
Apply
Browse documentation datasets
File (1) - Orange
Source
File: test.csv
Reload
URL: JPAdr_yvitTMjo2VXT_E3ktsdcnPDr5eO3lO0/edit?usp=sharing
File Type
Automatically detect type
Info
5 instance(s)
1 feature(s) (no missing values)
Data has no target variable.
0 meta attribute(s)
Columns (Double click to edit)
Name Type Role Values
1 x numeric feature
Reset
Apply
Browse documentation datasets

구글 스프레드시트에서 데이터 읽어오기

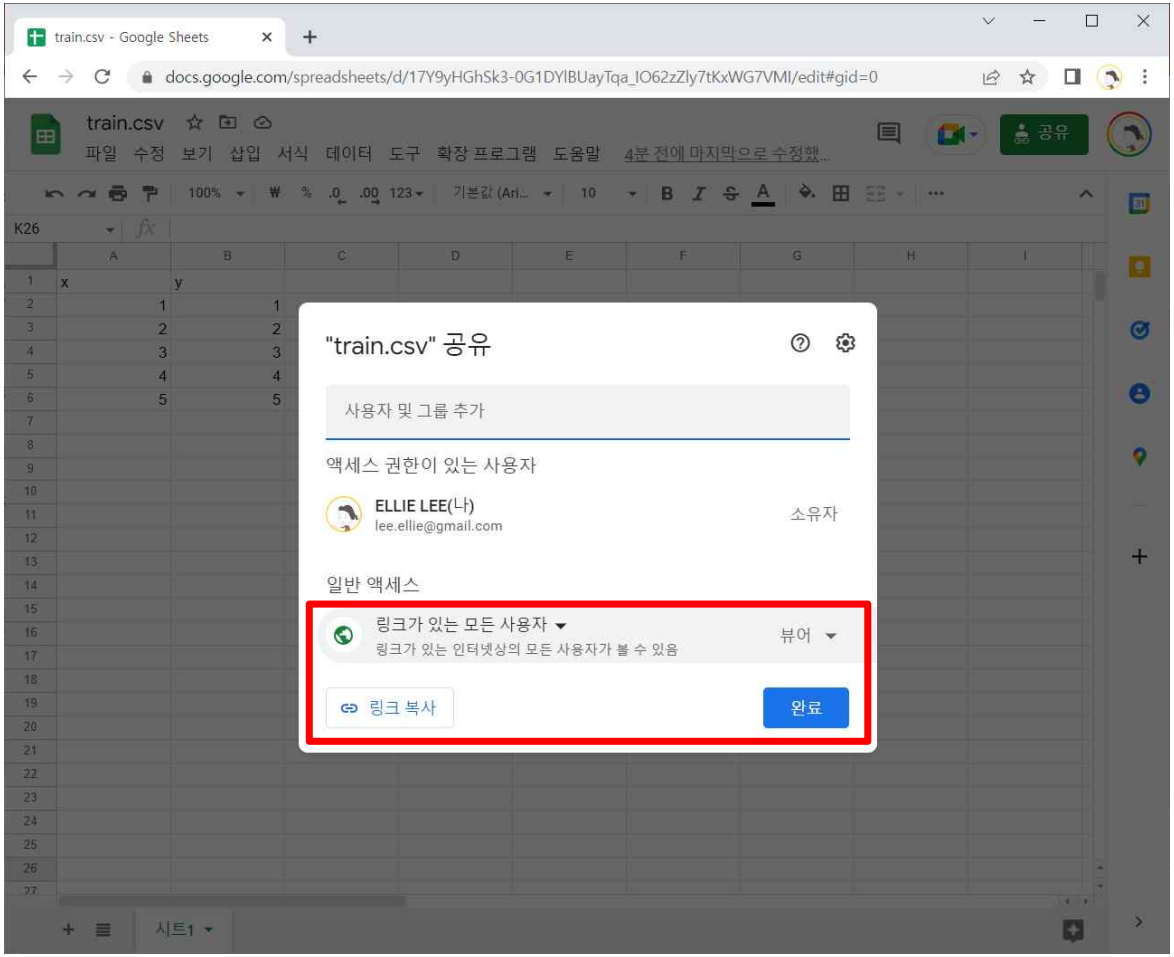

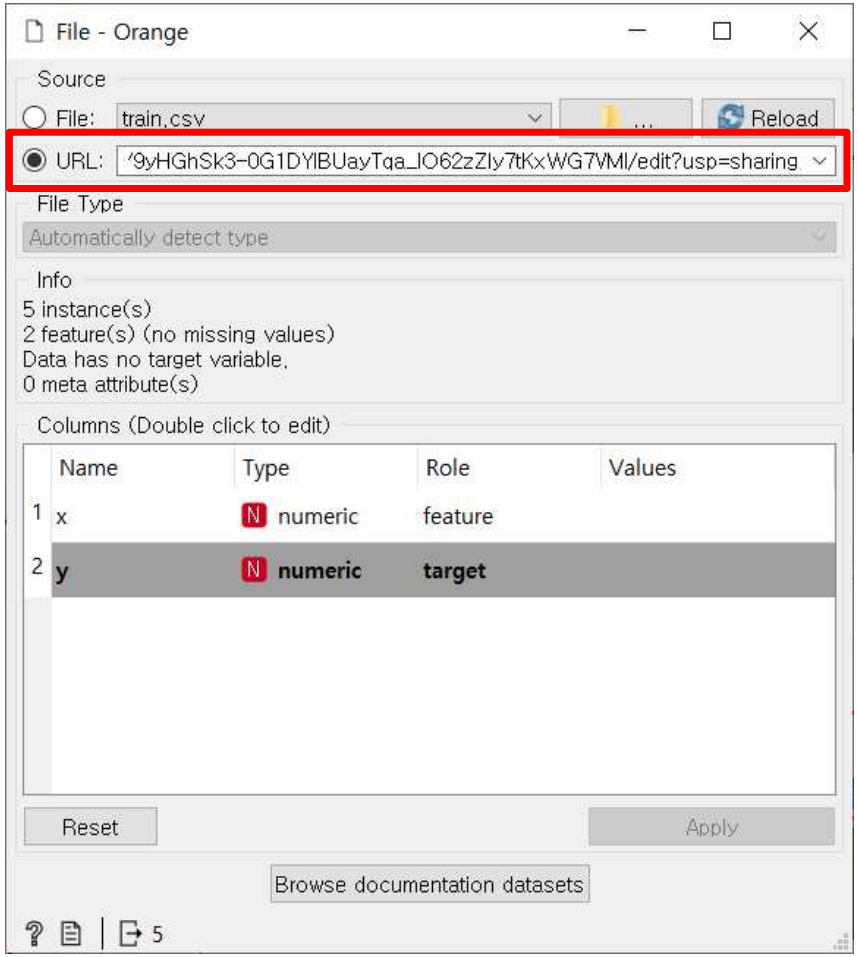

데이터분석 과정 알아보기

- 훈련 데이터(train.csv) :학습용
- 테스트 데이터(test.csv) : 모델 학습 결과 평가용

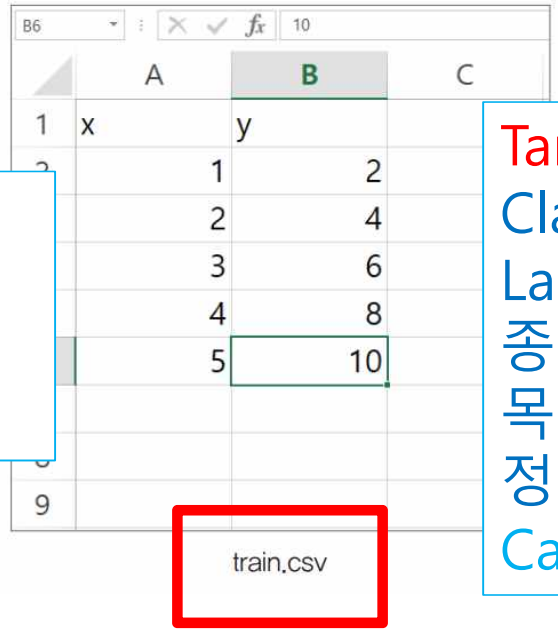

Feature
Attributes
독립변수
문제

Target
Class
Label
종속변수
목푯값
정답
Category

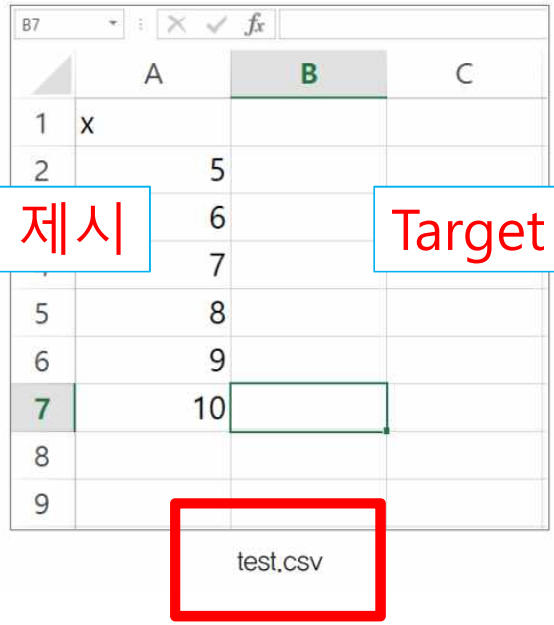

Feature 제시

Target 예측

- feature(특성): 기계학습에 영향을 미치는 원인이 되는 속성, 독립변수
- target(목표값): 예측하고자 하는 결과가 되는 속성, 종속변수

학습알고리즘 적용

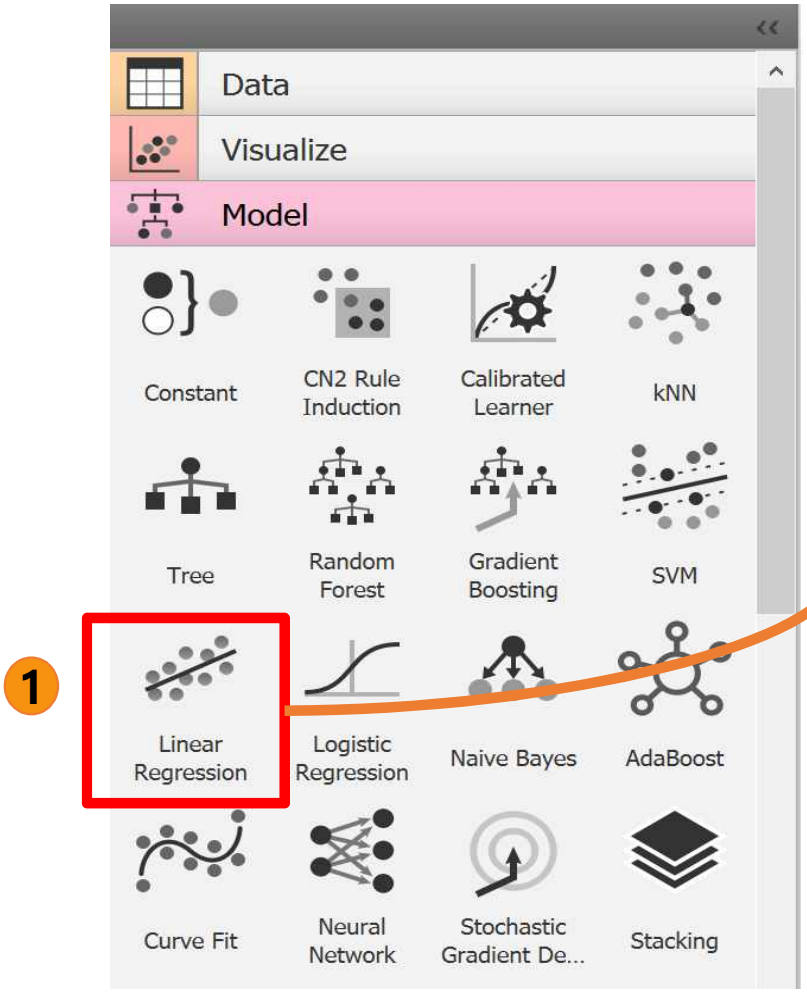

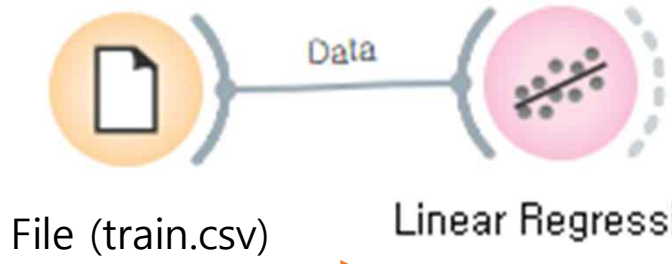

연결선을 연결하면 자동으로 위젯이 실행되어 모델이 훈련 데이터를 학습

출처> AI교육용도구활용부

예측하기

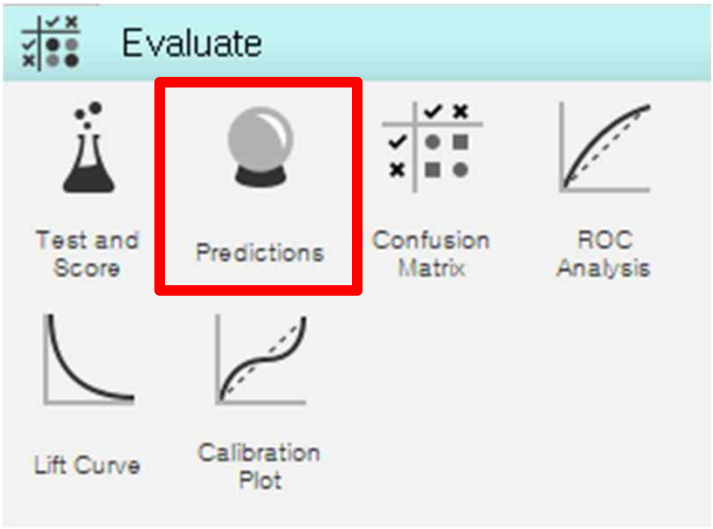

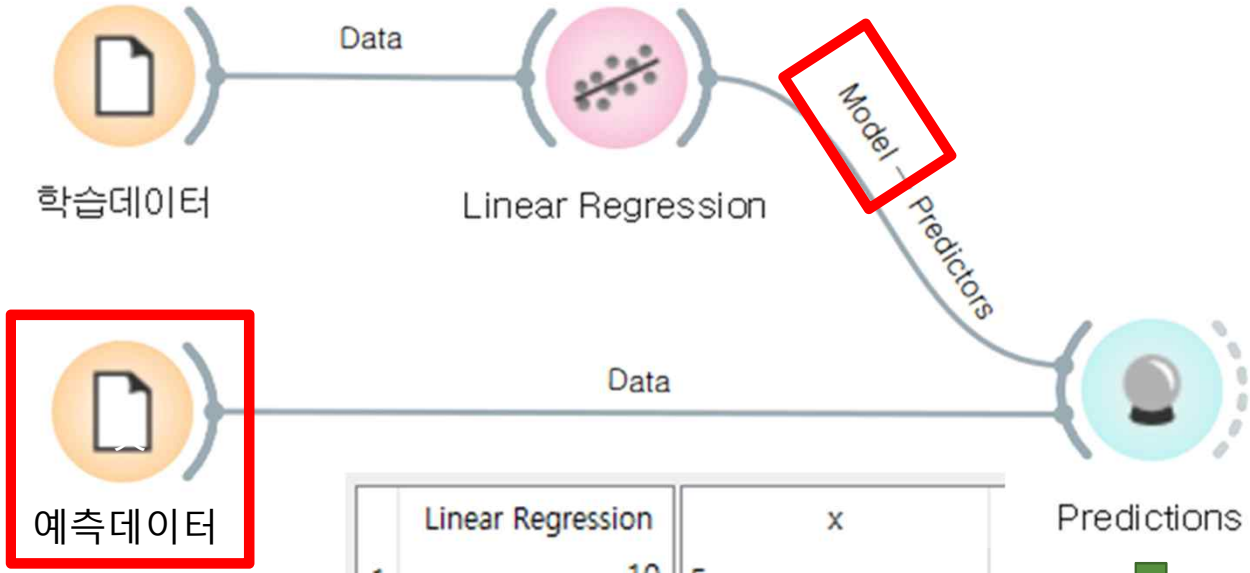

	Linear Regression	x
1	10	5
2	12	6
3	14	7
4	16	8
5	18	9
6	20	10

성능평가하기

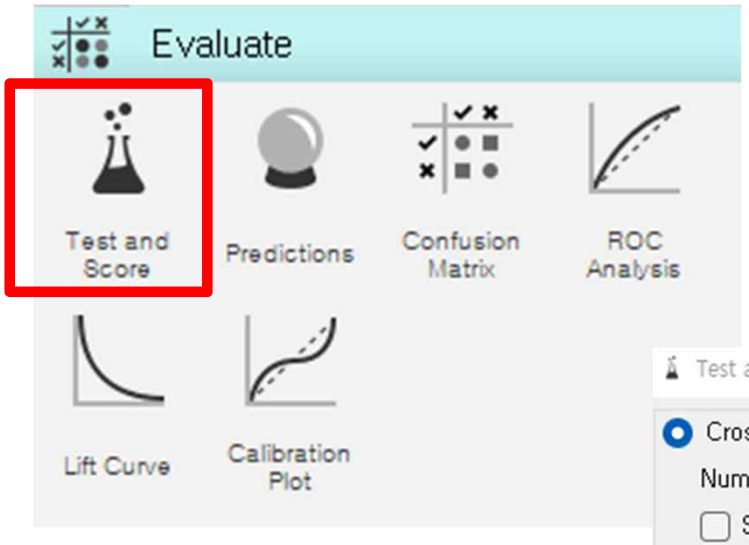

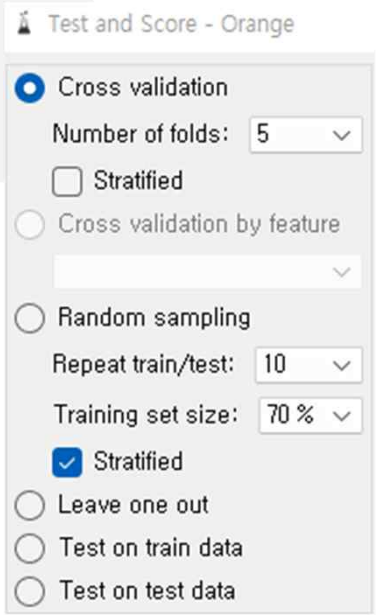

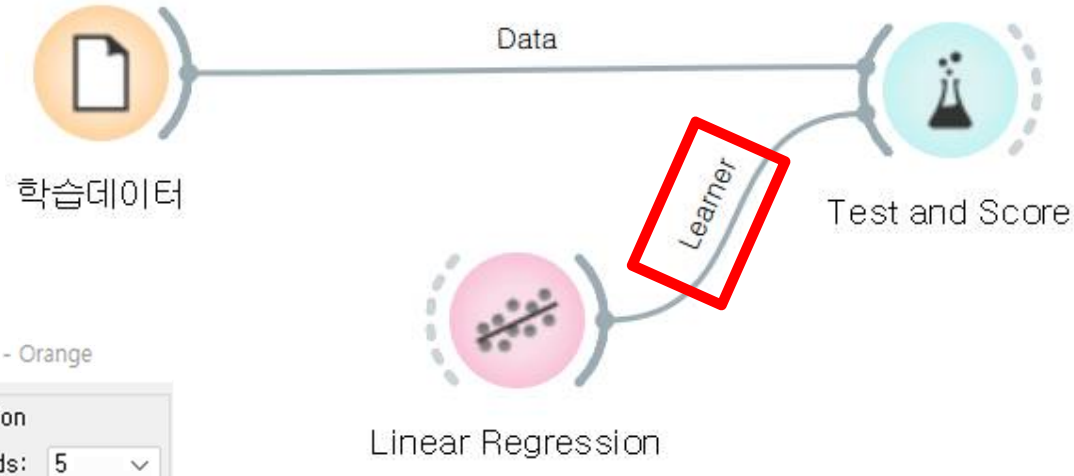

Model	MSE	RMSE	MAE	R2
Linear Regression	0.000	0.000	0.000	1.000

전체 워크플로

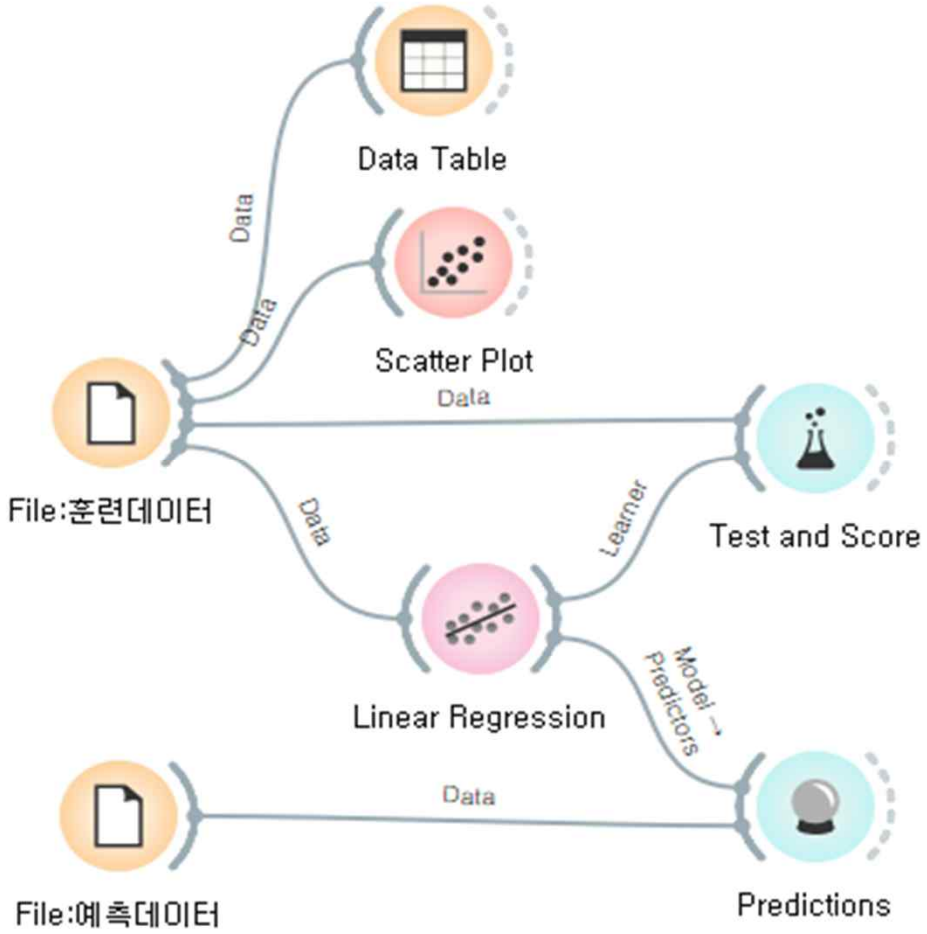
Data Table
Data
Data
Scatter Plot
Data
File:훈련데이터
Data
Learner
Test and Score
Linear Regression
Model
Predictors
Data
File:예측데이터
Predictions

학습알고리즘과 데이터 모델링

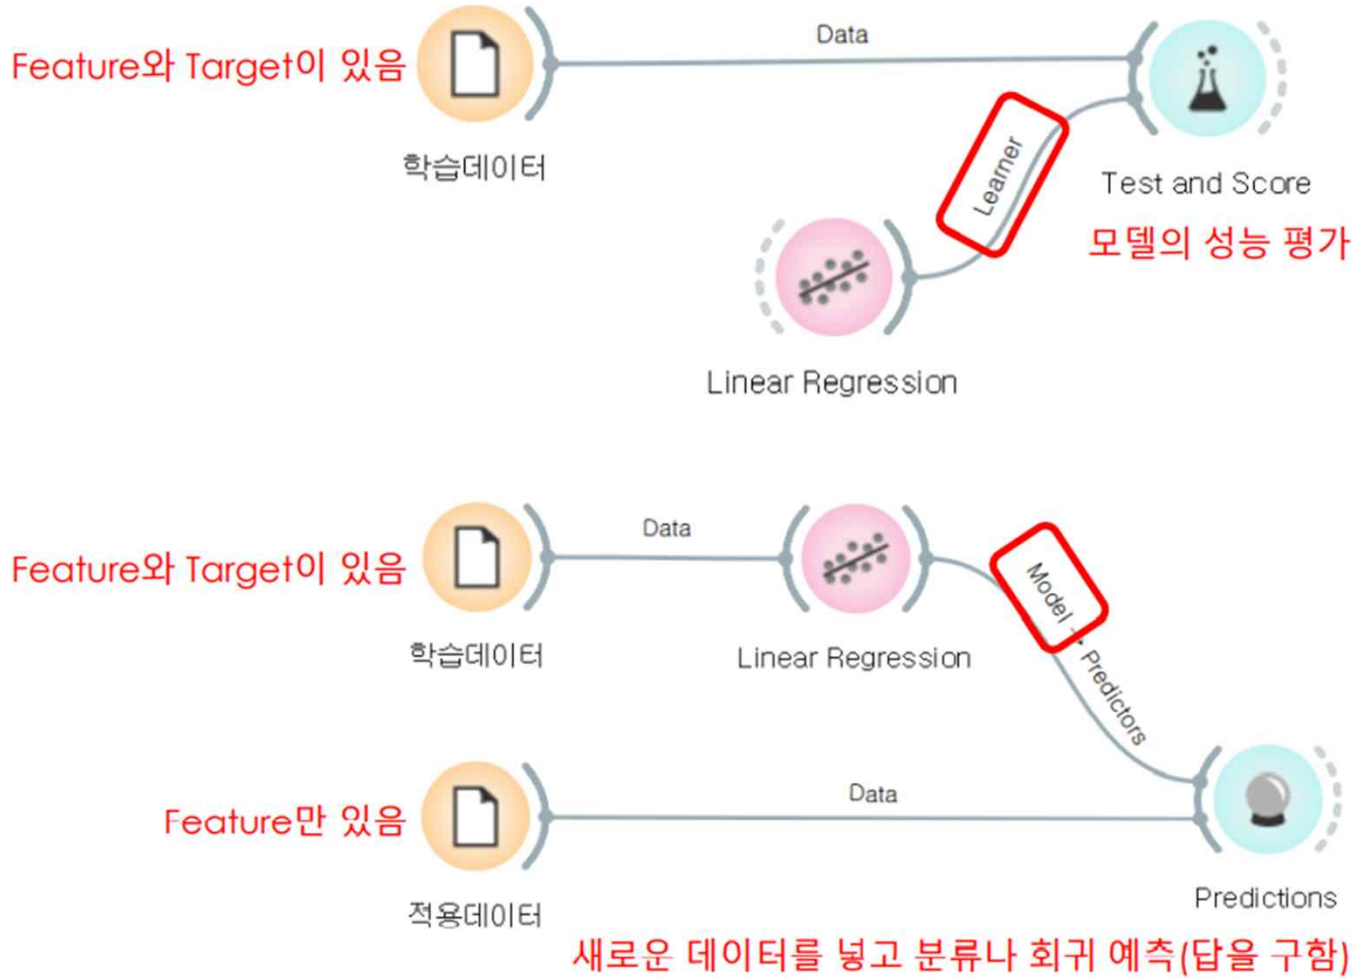

평가(Test and Score)와 예측(Predictions)

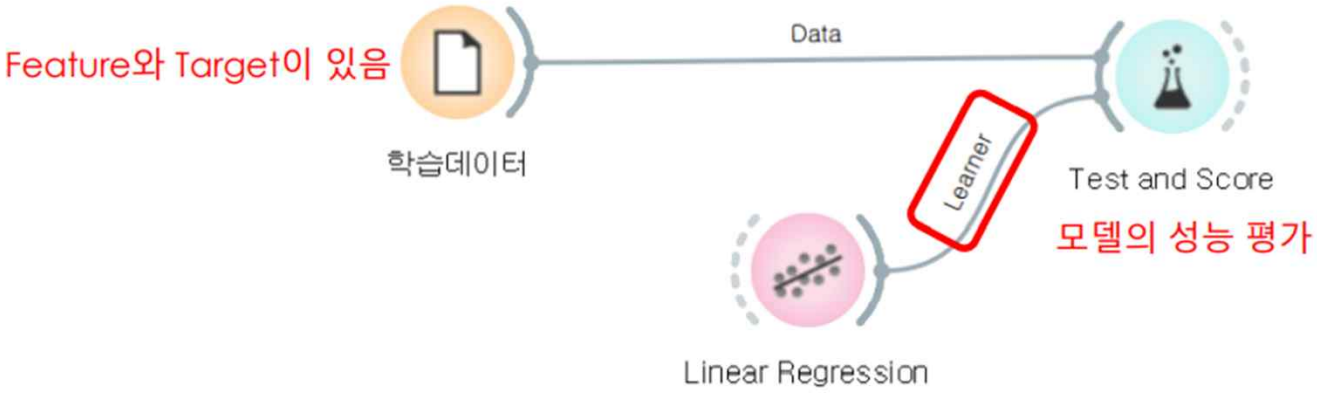

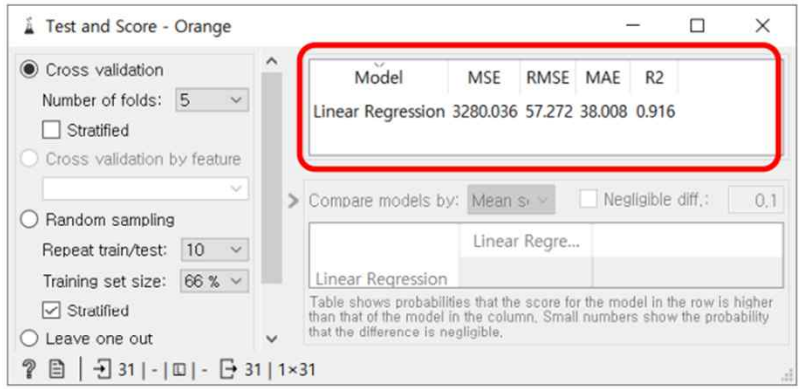

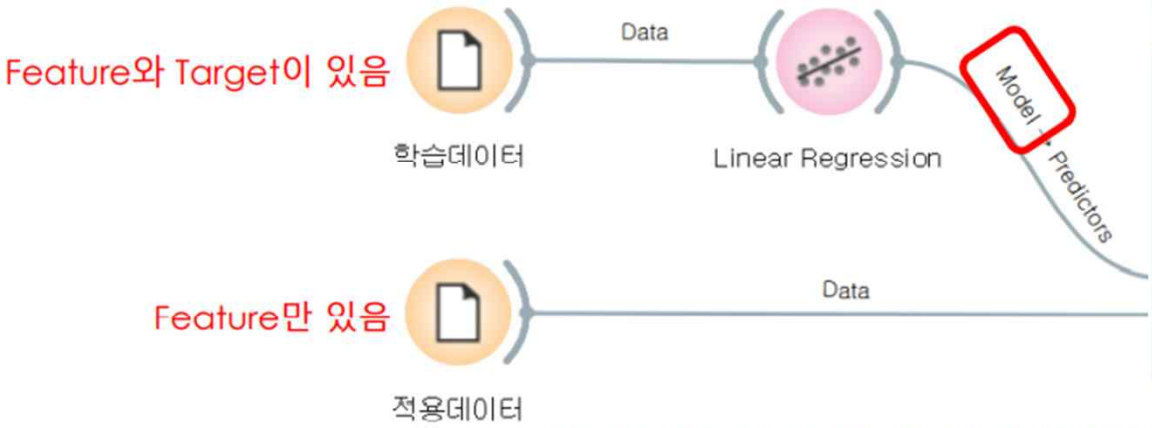

새로운 데이터를 넣고 분류나 회귀 예측(답을 구함)

선형회귀 (Linear Regression)의 원리

반복하며 w와 b 값을 찾아 나간다

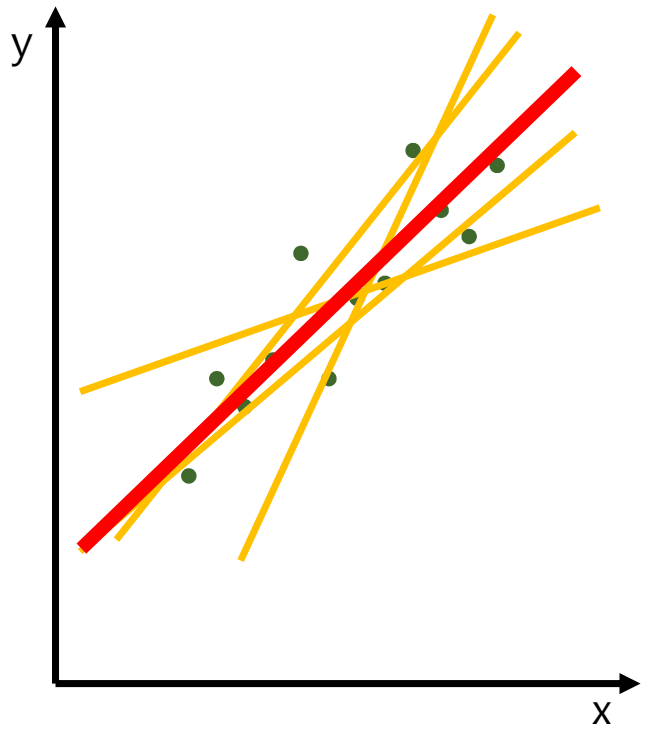

$$y = wx + b$$

$$y = w_1x_1 + w_2x_2 + \ldots + w_nx_n + b$$

예) 선형 회귀를 활용한 와인 품질 감별

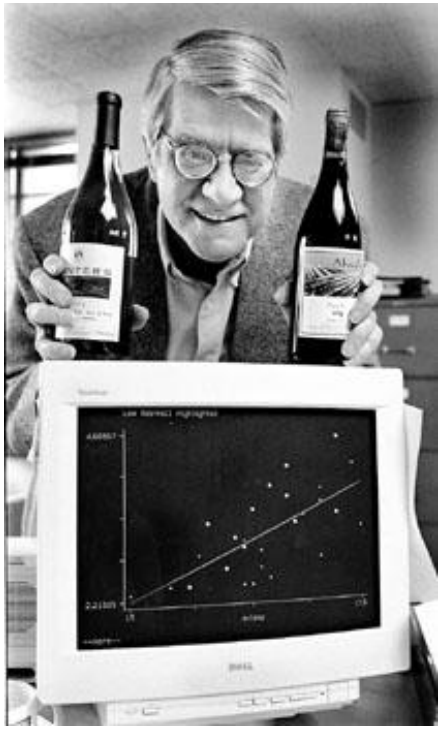

1.고정 산도
2.휘발성 산도
3.구연산
4.잔류 설탕
5.염화물
6.유리 이산화황
7.총 이산화황
8.밀도
9.pH
10.황산염
11.알코올

Quality = 4.4300987+(-1.0127527)× (휘발산)+(-2.0178138) ×(염화물) + (0.0050774) ×(free.무수아황산)+(-0.0034822) ×(total.무수아황산)+(-0.4826614) ×(pH)+(0.8826651) ×(황산염)+(0.2893028) ×(알코올)

"좋은 품질"(7 점 이상) 또는 아닙니다 (7 점 미만)

www.kaggle.com/uciml/red-wine-quality-cortez-et-al-2009

다른 회귀알고리즘과의 성능비교

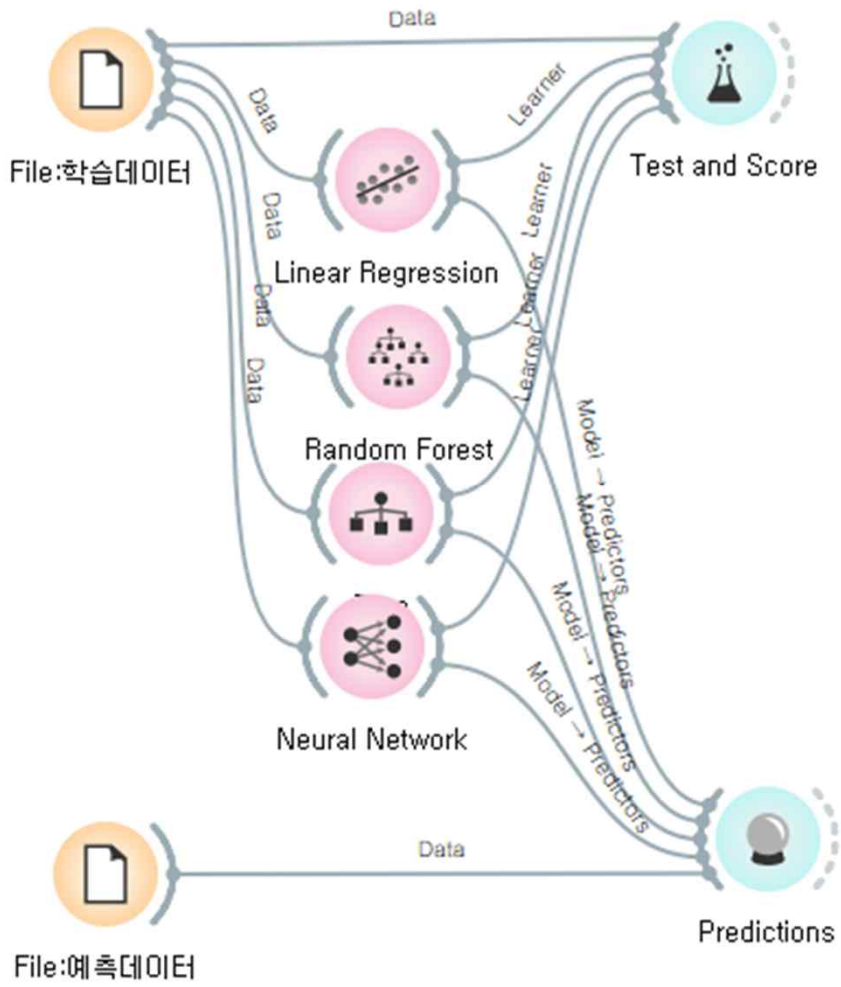

Model	MSE	RMSE	MAE	R2
Linear Regression	0.000	0.000	0.000	1.000
Neural Network	4.820	2.195	1.870	0.397
Tree	12.500	3.536	3.000	-0.562
Random Forest	13.359	3.655	3.080	-0.670

평가 결과값을 확인하면 Linear Regression 모델의 성능이 가장 우수함을 알 수 있다.

Predictions - Orange

Restore Original O

	Linear Regression	Random Forest	Tree	Neural Network	x
1	10	6	8	8	5
2	12	6	8	10	6
3	14	6	8	12	7
4	16	6	8	14	8
5	18	6	8	16	9
6	20	6	8	18	10

보스톤지역의 주택가격예측

feature	description
crim	자치시(town)별 1인당 범죄율
zn	25,000 평방 피트를 초과하는 거주지역의 비율
indus	비소매상업지역이 차지하고 있는 토지의 비율
chas	찰스강의 경계에 위치한 경우는 1, 아니면 0
nox	10ppm 당 농축 일산화질소
rm	주택 1가구당 평균 방의 수
age	1940년 이전에 건축한 소유주택 비율
dis	보스톤 직업센터까지의 접근성 지수
rad	방사형 도로까지의 접근성 지수
tax	10,000 달러당 재산세율
ptratio	자치시(town)별 학생/교사 비율
b	자치시(town)별 흑인의 비율
lstat	모집단의 하위 계층의 비율
medv	본인 소유의 주택가격 중앙값(단위 $1000)

데이터의 입출력

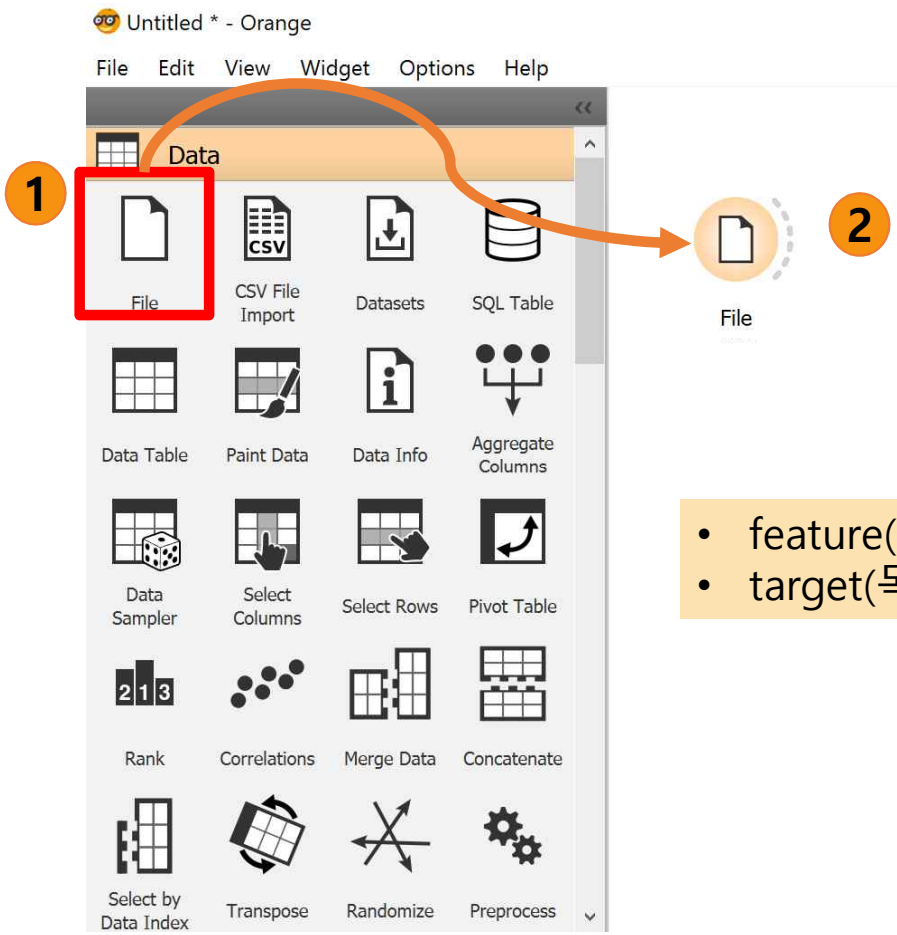

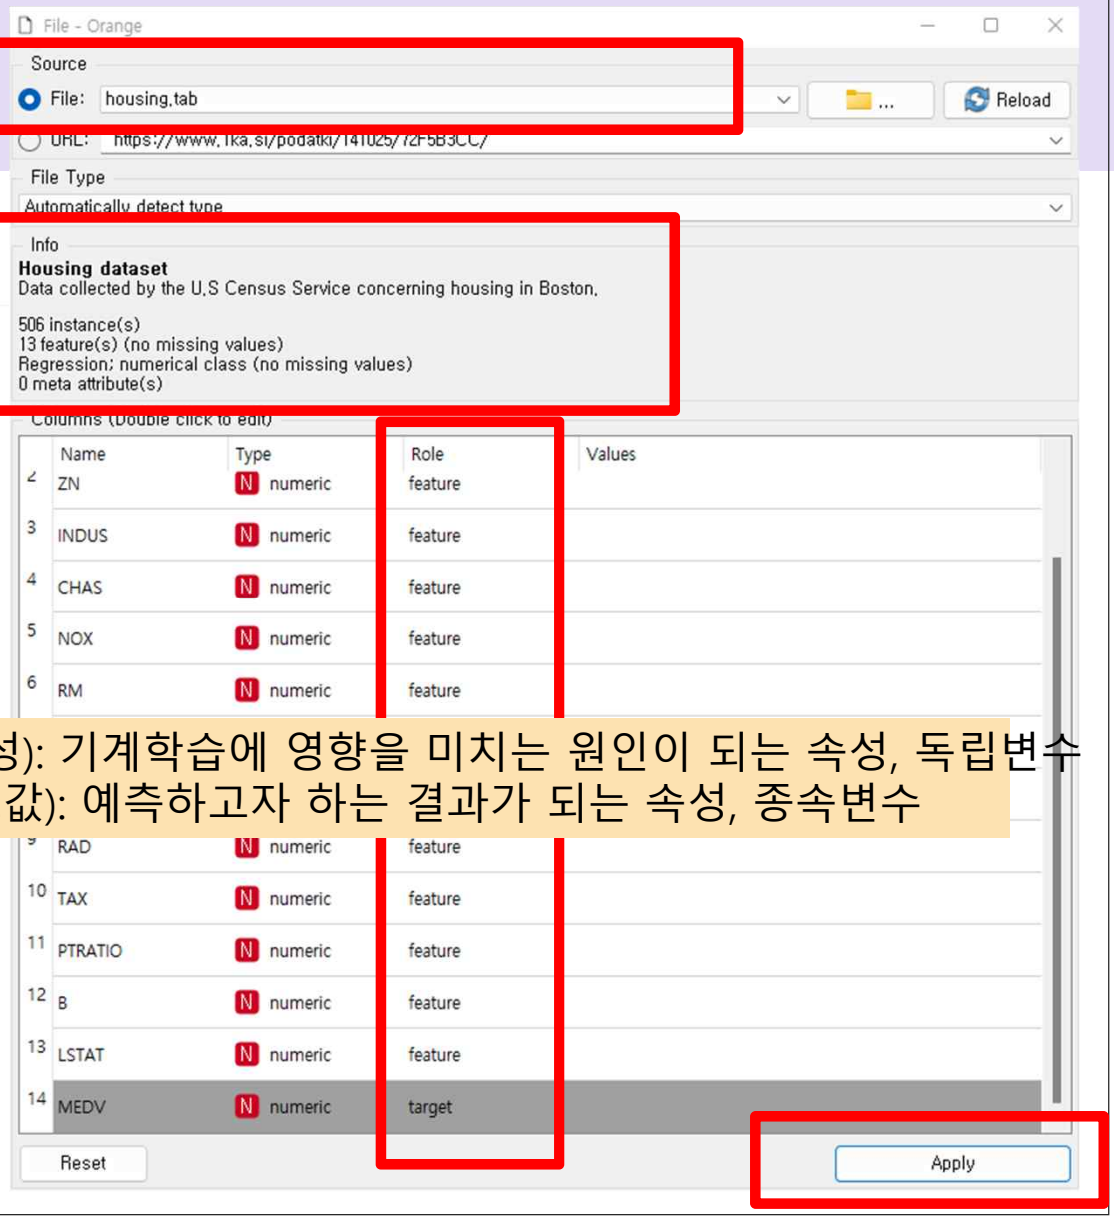

- feature(특성): 기계학습에 영향을 미치는 원인이 되는 속성, 독립변수
- target(목표값): 예측하고자 하는 결과가 되는 속성, 종속변수

입력된 데이터의 탐색

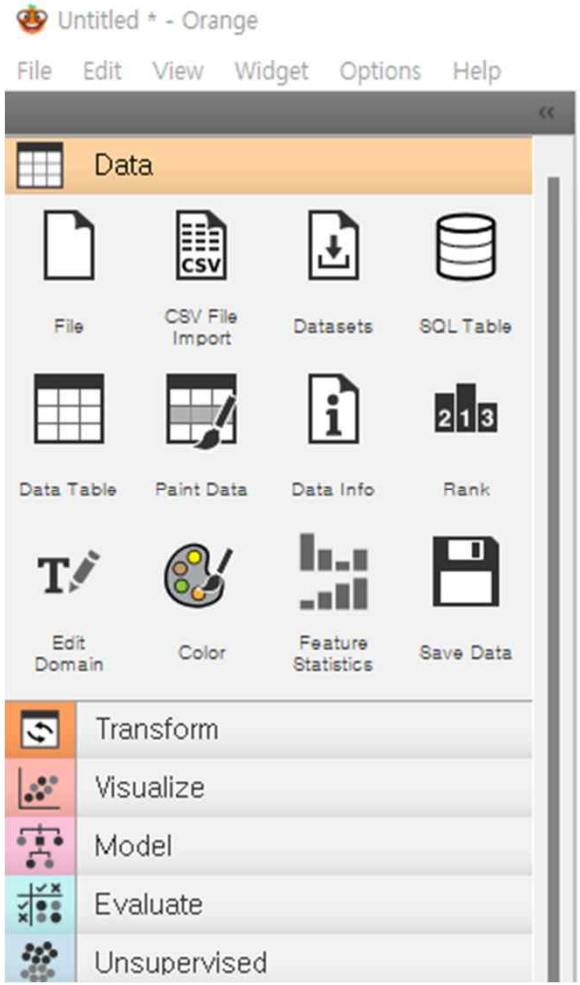

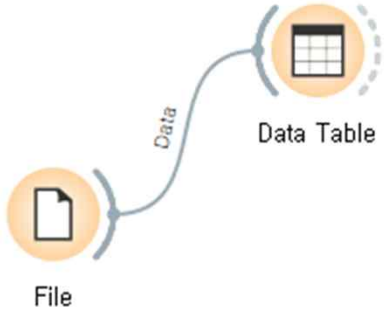

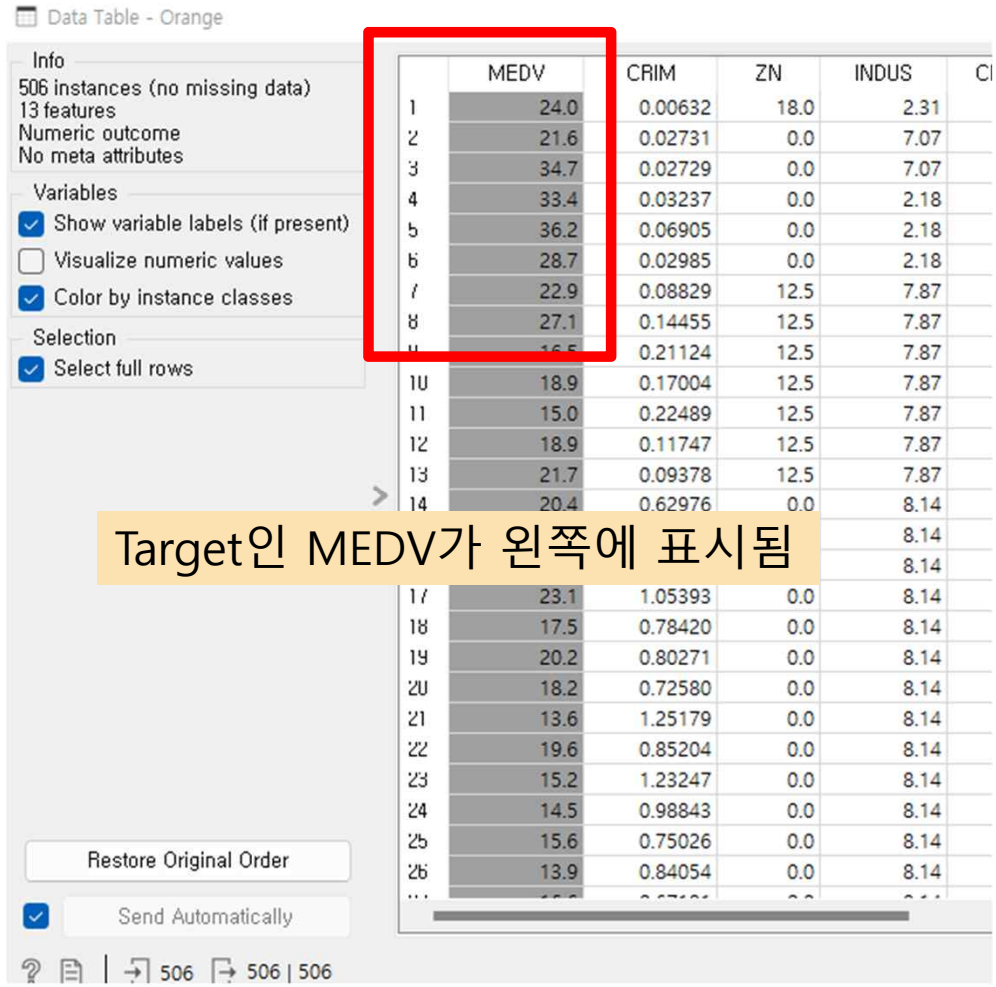

Target인 MEDV가 왼쪽에 표시됨

속성들 간의 상관관계 분석

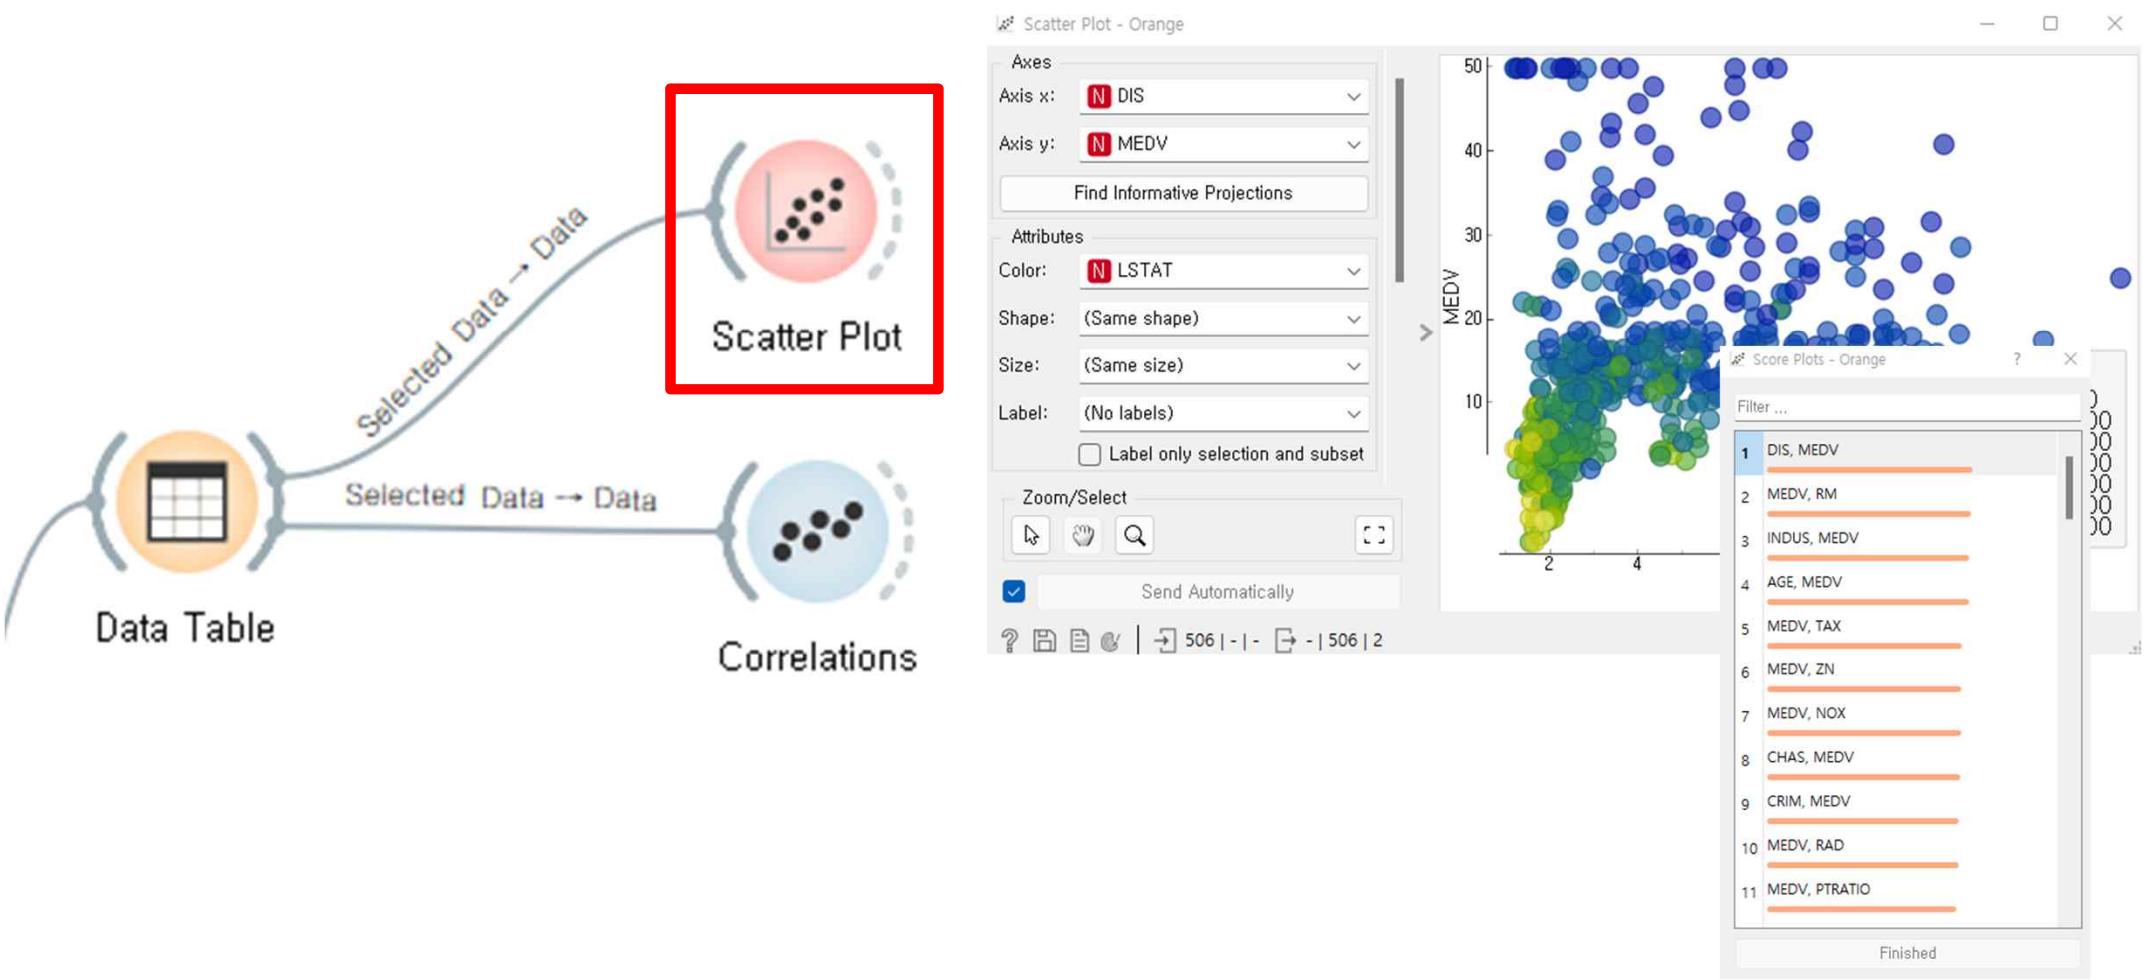

속성들 간의 상관관계 분석

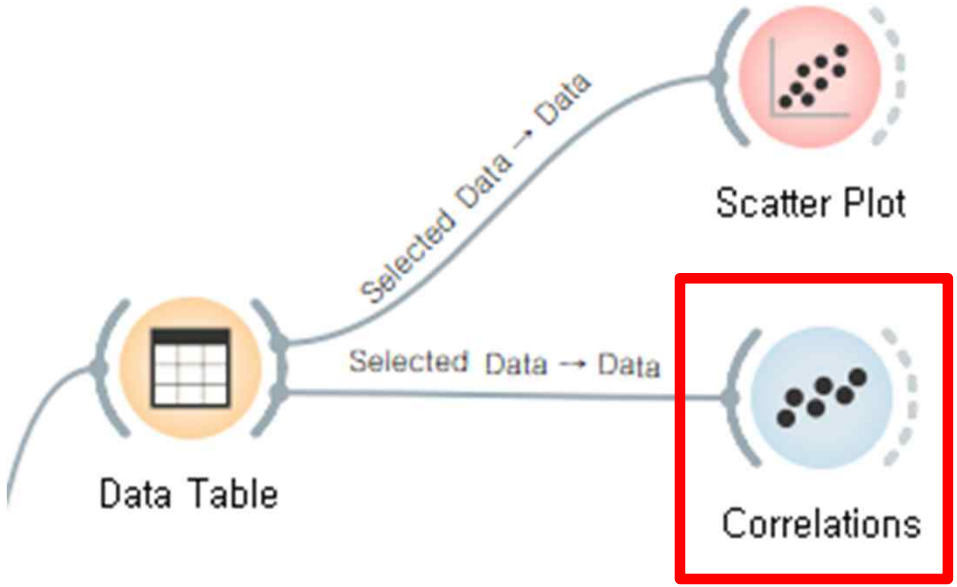

Correlations - Orange

Pearson correlation

N MEDV

Filter ...

1	-0.738	LSTAT	MEDV
2	+0.695	MEDV	RM
3	-0.508	MEDV	PTRATIO
4	-0.484	INDUS	MEDV
5	-0.469	MEDV	TAX
6	-0.427	MEDV	NOX
7	-0.388	CRIM	MEDV
8	-0.382	MEDV	RAD
9	-0.377	AGE	MEDV
10	+0.360	MEDV	ZN
11	+0.333	B	MEDV
12	+0.250	DIS	MEDV
13	+0.175	CHAS	MEDV

Finished

506 506 | 2 | 13

학습 알고리즘을 적용하여 모델을 생성해보자

$y = wx + b$

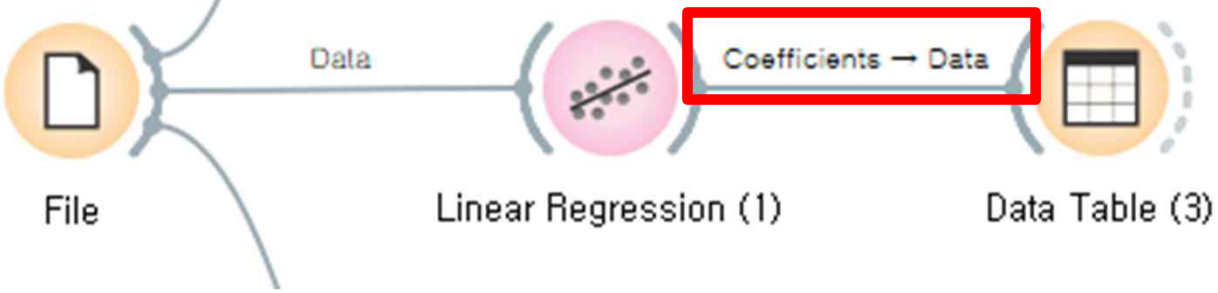

회귀계수

	name	coef
1	intercept	36.4371
2	CRIM	-0.107994
3	ZN	0.0464248
4	INDUS	0.0204177
5	CHAS	2.68491
6	NOX	-17.7328
7	RM	3.80991
8	AGE	0.000666336
9	DIS	-1.47504
10	RAD	0.305974
11	TAX	-0.0123375
12	PTRATIO	-0.952383
13	B	0.00931343
14	LSTAT	-0.524815

주택가격 = -0.107994 X CRIM + 0.0464248 X ZN + 0.0204177 X INDUS + 2.68491 X CHAS + ….. + 36.4371

예측하기 - 예측 데이터 준비

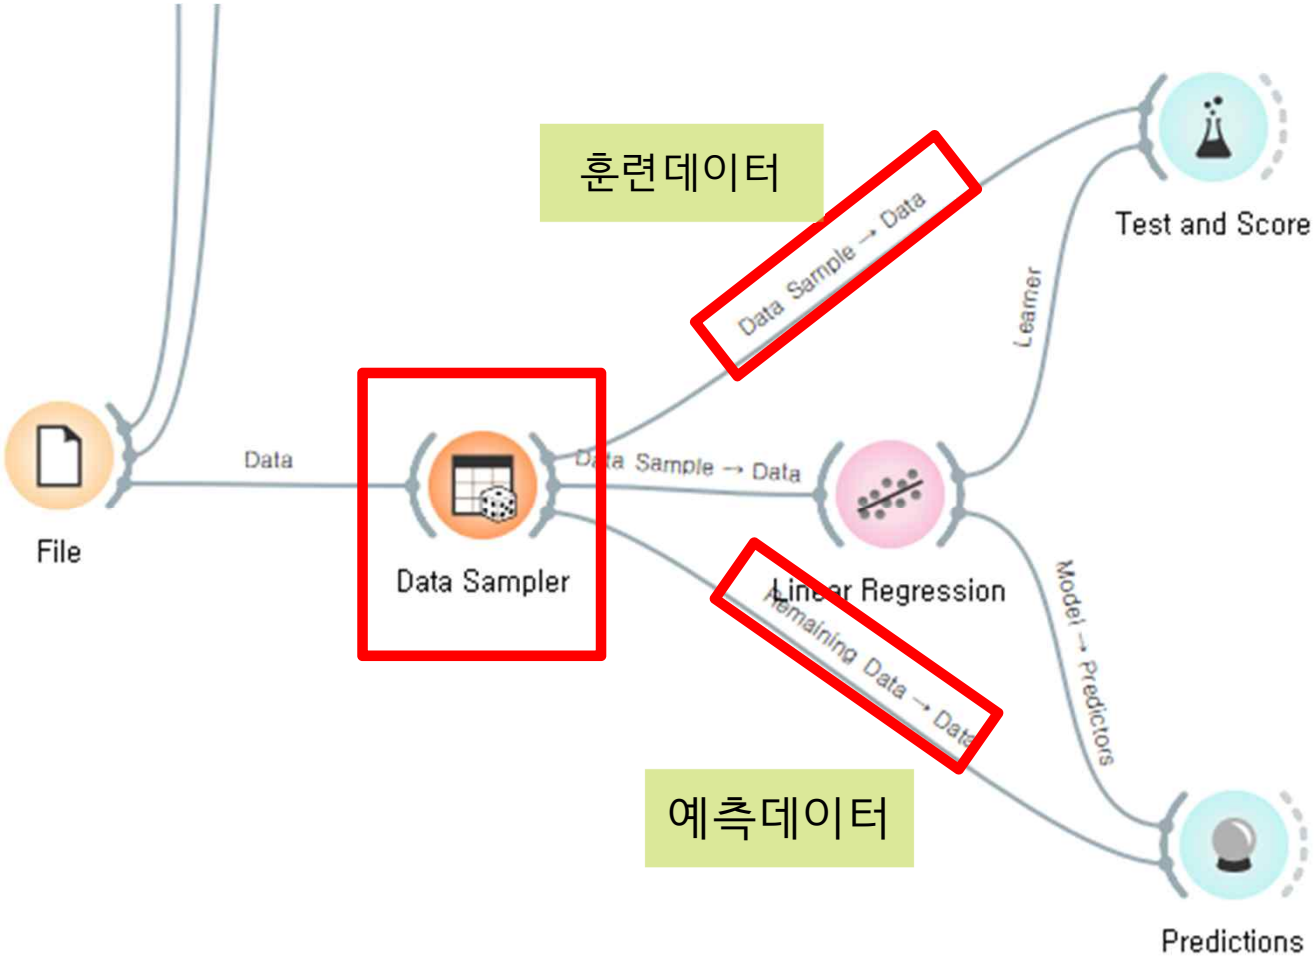

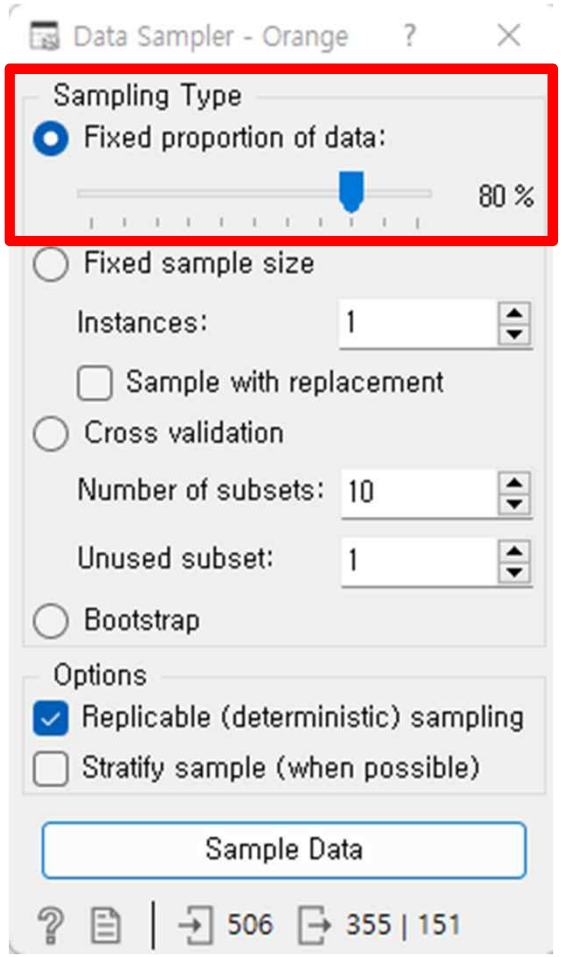

집값예측

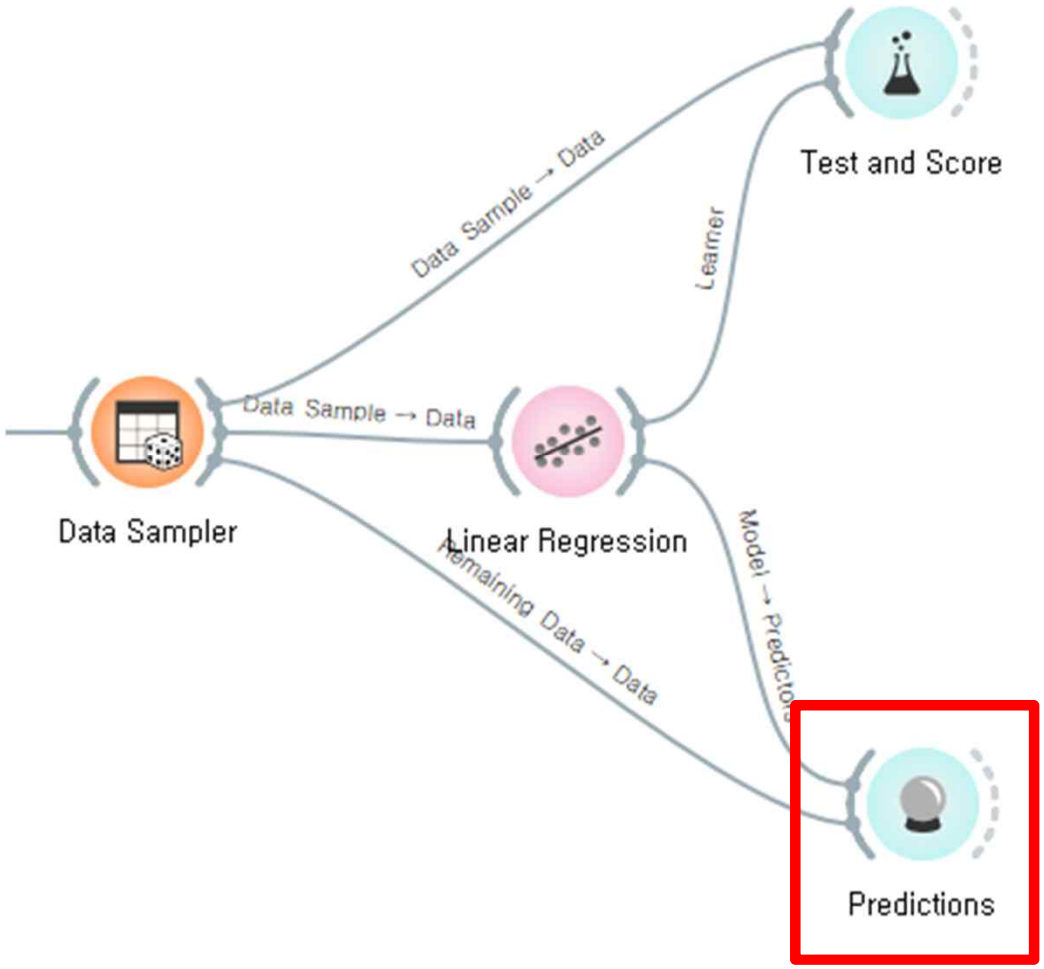

Predictions - Orange

Restore Original

	Linear Regression	MEDV	CRIM	ZN	INDUS
1	27.7	36.2	0.06905	0.0	2.18
2	38.0	44.0	0.01538	90.0	3.75
3	22.1	17.8	8.24809	0.0	18.10
4	24.7	27.5	0.14866	0.0	8.56
5	37.6	37.6	0.38214	0.0	6.20
6	18.9	14.1	10.06230	0.0	18.10
7	24.8	28.1	0.14052	0.0	10.59
8	16.8	10.2	12.24720	0.0	18.10
9	24.3	19.1	2.31390	0.0	19.58
10	34.3	43.8	0.08187	0.0	2.89
11	32.7	27.9	0.03615	80.0	4.95
12	24.3	25.0	0.19802	0.0	10.59
13	19.5	16.0	0.17171	25.0	5.13
14	18.1	16.6	0.22927	0.0	6.91
15	8.8	13.2	1.38799	0.0	8.14
16	40.3	50.0	0.57834	20.0	3.97
17	19.1	22.2	0.24103	0.0	7.38
18	30.5	32.9	0.01778	95.0	1.47
19	19.4	15.2	5.44114	0.0	18.10
20	15.1	14.8	0.95577	0.0	8.14

Show perfomance scores

Model	MSE	RMSE	MAE	R2
Linear Regression	22.226	4.714	3.359	0.725

151 | 151 | 1×151

평가하기

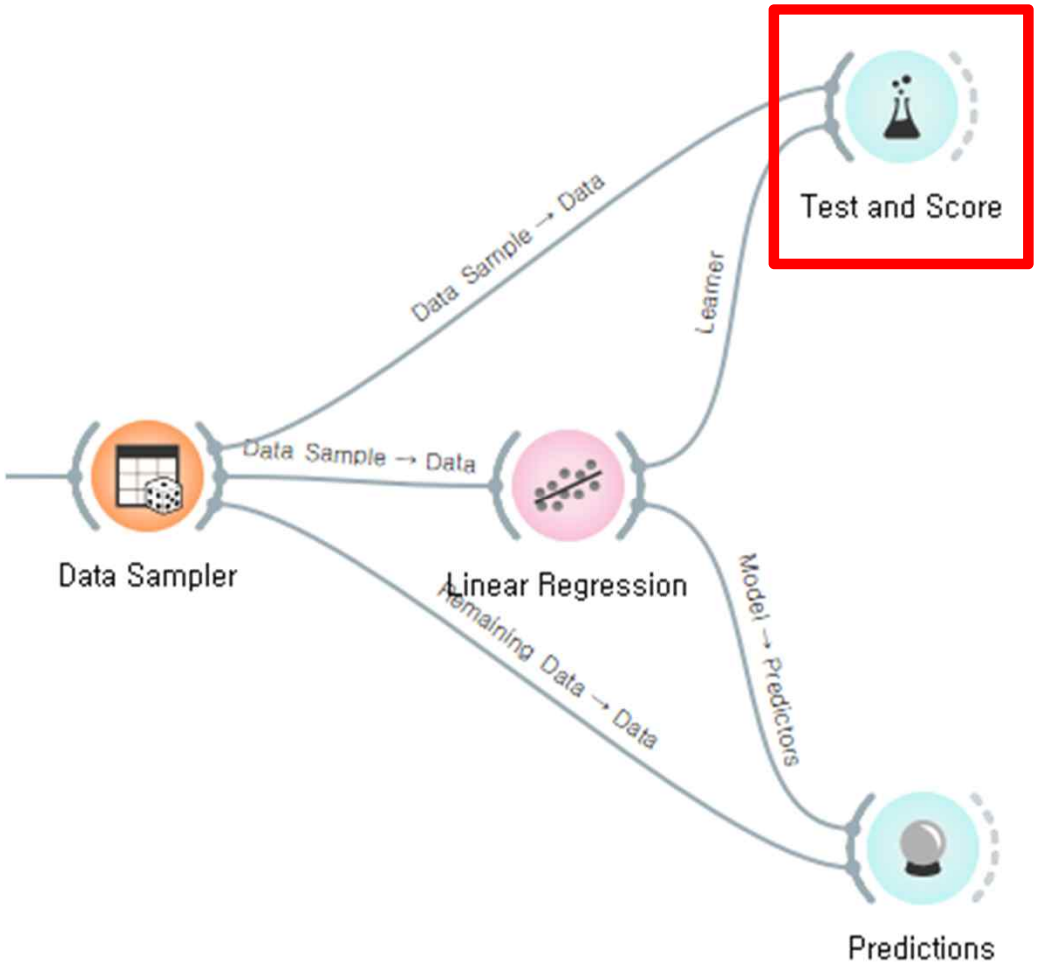
Test and Score
Data Sample → Data
Learner
Data Sample → Data
Data Sampler
Linear Regression
Model → Predictors
Remaining Data → Data
Predictions

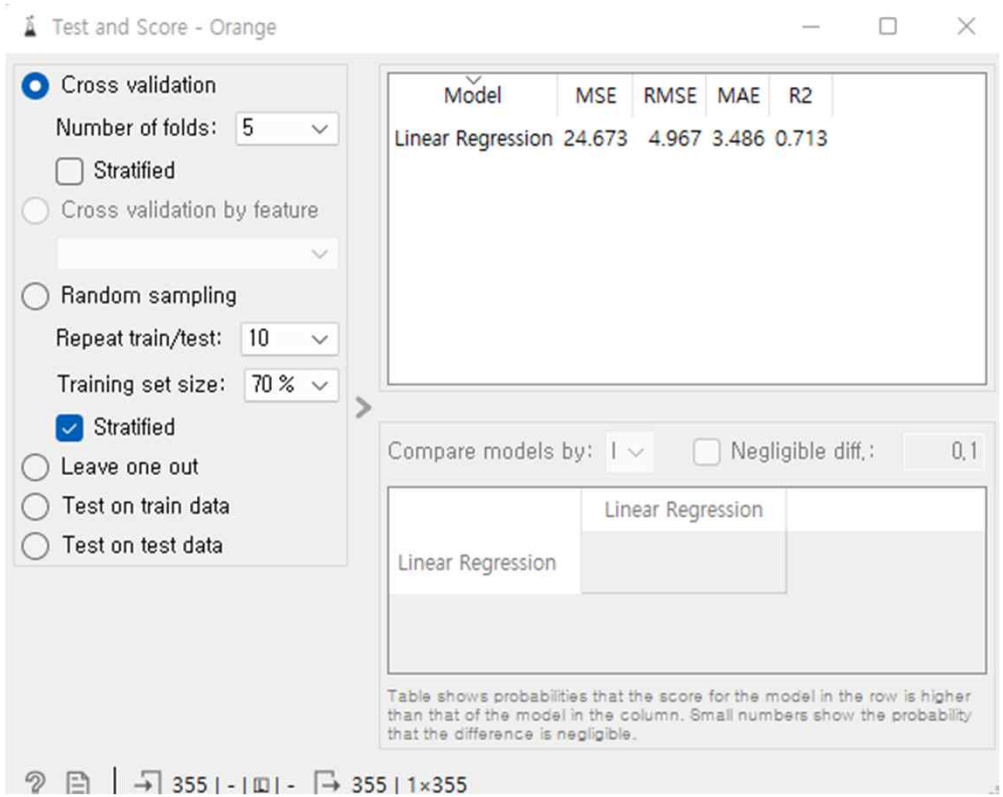
Test and Score - Orange
Cross validation
Number of folds: 5
Stratified
Cross validation by feature
Random sampling
Repeat train/test: 10
Training set size: 70 %
Stratified
Leave one out
Test on train data
Test on test data
Model MSE RMSE MAE R2
Linear Regression 24.673 4.967 3.486 0.713
Compare models by:
Negligible diff.: 0.1
Linear Regression
Linear Regression
Table shows probabilities that the score for the model in the row is higher than that of the model in the column. Small numbers show the probability that the difference is negligible.
355 | - | - 355 | 1×355

지금까지 간단한 선형모델을 활용하여 선형회귀 모델의 개념에 대해 알아보았고, 보스턴 집값을 예측하는 모델을 생성해보았습니다. 다음시간에는 회귀모델의 성능평가지표를 활용하여 선형회귀모델 이외의 다양한 회귀모델을 생성 비교 해보고 실생활에서 적용할 수 있는 회귀분석을 실습해보도록 하겠습니다. 감사합니다.

orange 활용 데이터 분석 및 머신 러닝

3차시

지도학습 - 회귀2

orange

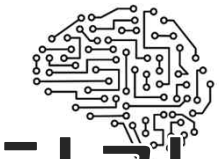

1. 다양한 회귀모델 활용하기
2. 회귀의 성능평가지표
3. 실생활에서 회귀분석 활용

보스턴 집값데이터셋을 활용한 회귀 워크플로

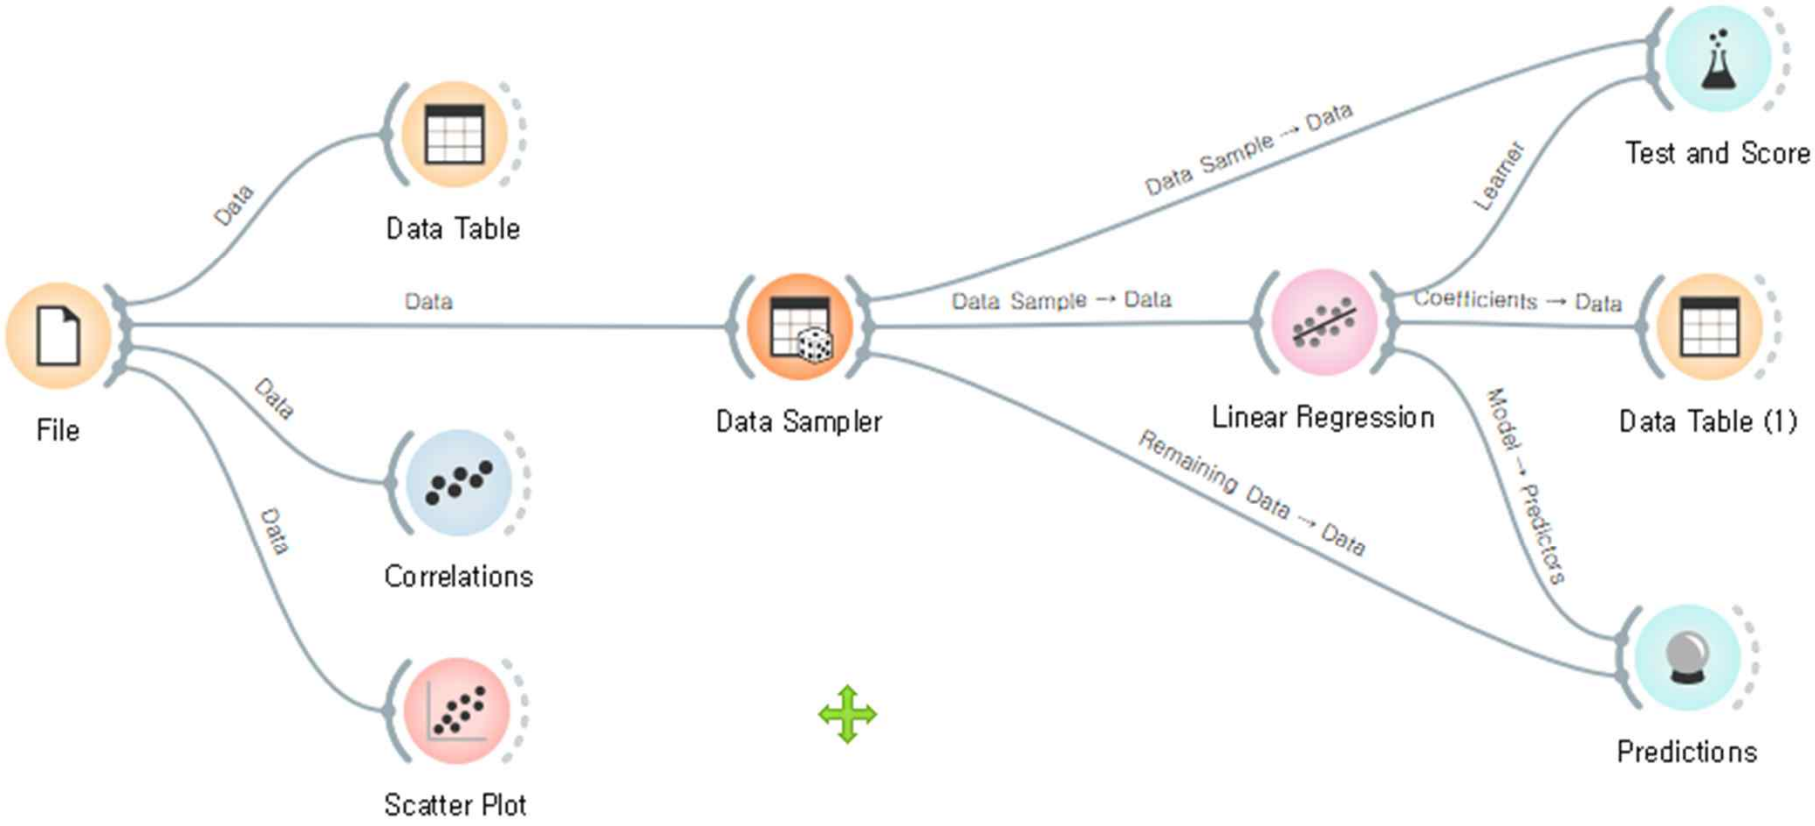

여러 모델을 평가하고 비교하기

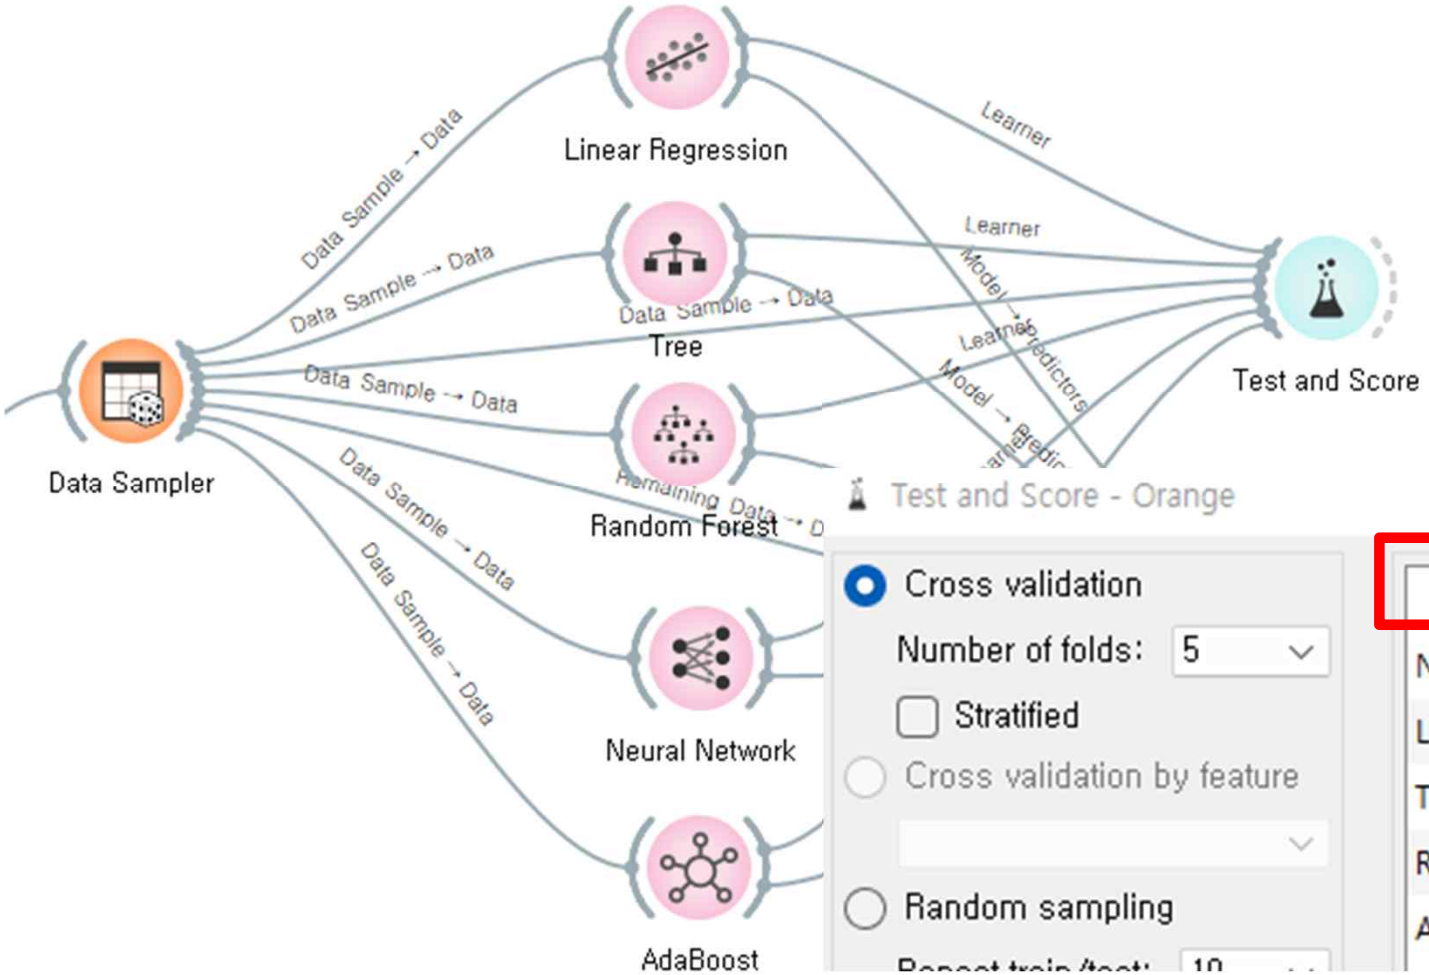

Model	MSE	RMSE	MAE	R2
Neural Network	31.485	5.611	4.058	0.633
Linear Regression	24.673	4.967	3.486	0.713
Tree	24.212	4.921	3.297	0.718
Random Forest	14.300	3.782	2.531	0.833
AdaBoost	14.174	3.765	2.407	0.835

평가지표 (회귀)

Predictions - Orange

Restore Original Order

	Linear Regression	Tree	Random Forest	Neural Network	AdaBoost	MEDV	CR
1	27.7	36.7	34.5	35.6	36.1	36.2	0.06905
2	38.0	42.9	45.1	37.1	43.5	44.0	0.01538
3	22.1	13.0	17.1	16.6	16.1	17.8	8.24809
4	24.7	25.1	24.3	22.0	24.1	27.5	0.14866
5	37.6	46.2	47.4	37.3	48.3	37.6	0.38214
6	18.9	19.5	20.5	11.3	19.1	14.1	10.06230
7	24.8	25.6	23.7	22.6	23.7	28.1	0.14052

Show perfomance scores

Model	MSE	RMSE	MAE	R2
AdaBoost				
Random Forest	9.325	3.054	2.232	0.885
Tree	15.430	3.928	2.995	0.809
Linear Regression	22.226	4.714	3.359	0.725
Neural Network	30.965	5.565	4.066	0.616

151 | 151 | 5×151

$$H(x) = Wx + b$$

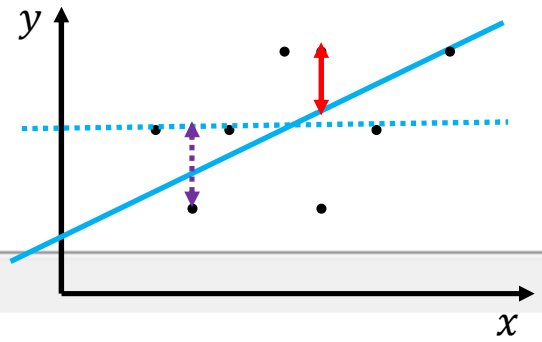

MSE(Mean Squared Error)

$$\frac{1}{n}\sum_{i=1}^{n}(H(x_i)-y_i)^2$$

RMSE(Root Mean Squared Error)

$$\sqrt{\frac{1}{n}\sum_{i=1}^{n}(H(x_i)-y_i)^2}$$

MAE(Mean Absolute Error)

$$\frac{1}{n}\sum_{i=1}^{n}|H(x_i)-y_i|$$

R2(R Squared, R^2, 결정계수)

$$\frac{\sum_{i=1}^{n}(H(x_i)-\bar{y})^2}{\sum_{i=1}^{n}(y_i-\bar{y})^2}$$

회귀에서 성능평가

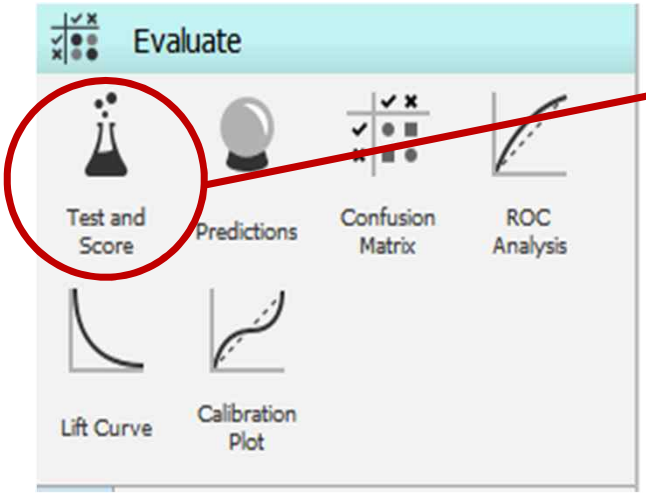

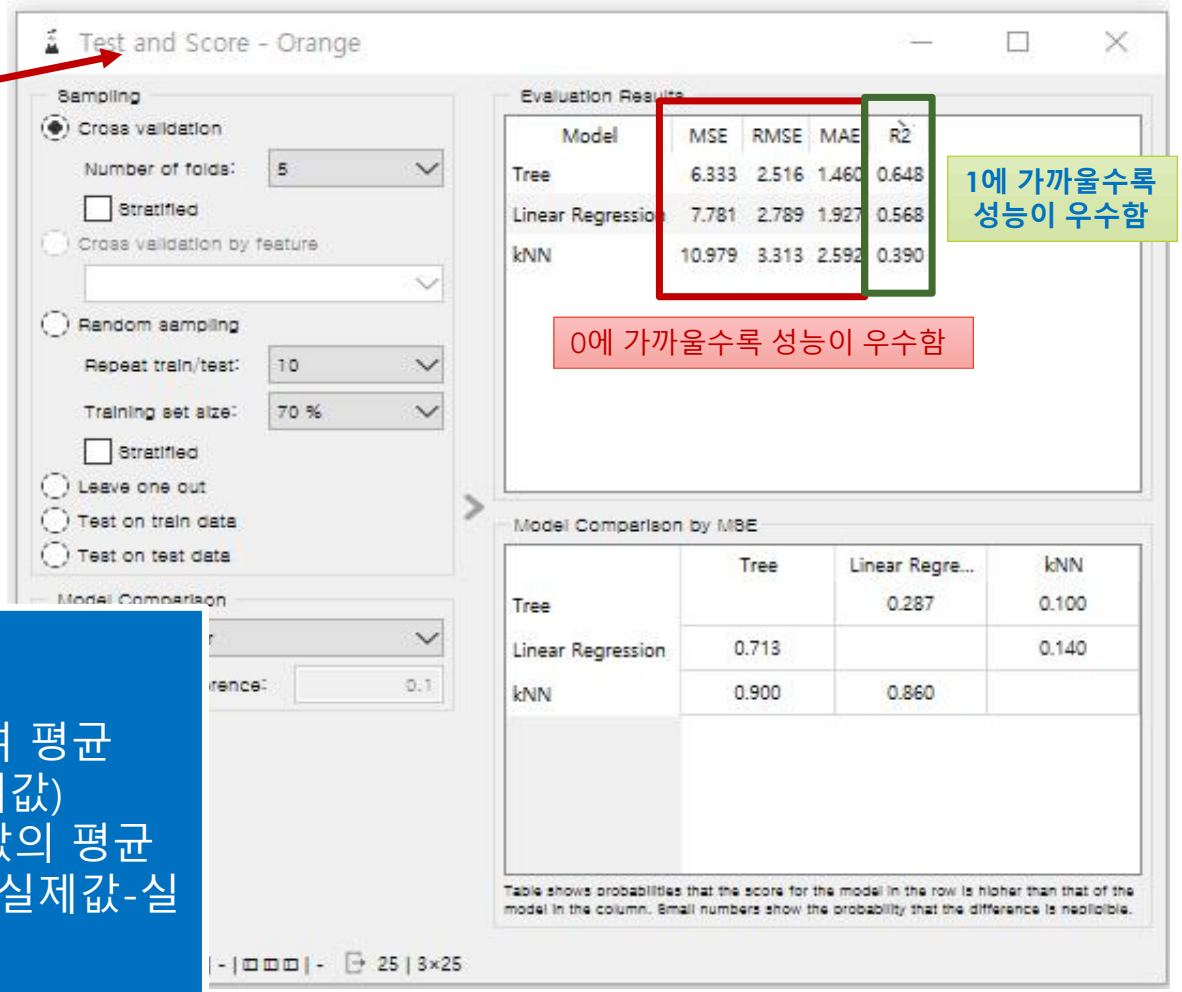

* 성능 평가
  - MSE : 예측값과 실젯값 차이 제곱하여 평균
  - RMSE : MSE 를 ROOT 처리한 값(실제값)
  - MAE : 예측값 – 실제값 차이의 절대값의 평균
  - R2 : (예측값-실제값평균)의 제곱합/ (실제값-실제값평균)의 제곱합

[활용] 우리동네 미세먼지 농도 예측하기

다른 동네 미세먼지 농도 데이터를 보고 우리동네의 농도를 추정해보자.

➔ 구월동을 target으로 해서 결측치를 예측하자.

	A	B	C	D	E	F	G	H	I	J
1	날짜	송림	연희	원당	숭의	부평	구월	신흥	고잔	석남
2	2022-07-01	17	18	24	14	17	12	16	17	14
3	2022-07-02	31	28	36	29	29	26	28	31	23
4	2022-07-03	36	30	39	38	31		37	36	25
5	2022-07-04	32	35	42	31	33	28	34	32	26
6	2022-07-05	47	45	63	42	49		50	47	42
7	2022-07-06	41	39	47	35	39			42	33
8	2022-07-07	25	24	41	20	24			28	18
9	2022-07-08	27	27	48	24	30	19		24	21
10	2022-07-09	27	24	41	25	26	23	27	23	19
11	2022-07-10	39	43	70	36	46	34	36	37	39
12	2022-07-11	25	24	27	23	25	23	24	29	22
13	2022-07-12	22	19	19	17	19	16	22	25	15
14	2022-07-13	24	22			20	15	22		17

[활용] 우리동네 미세먼지 농도 예측하기

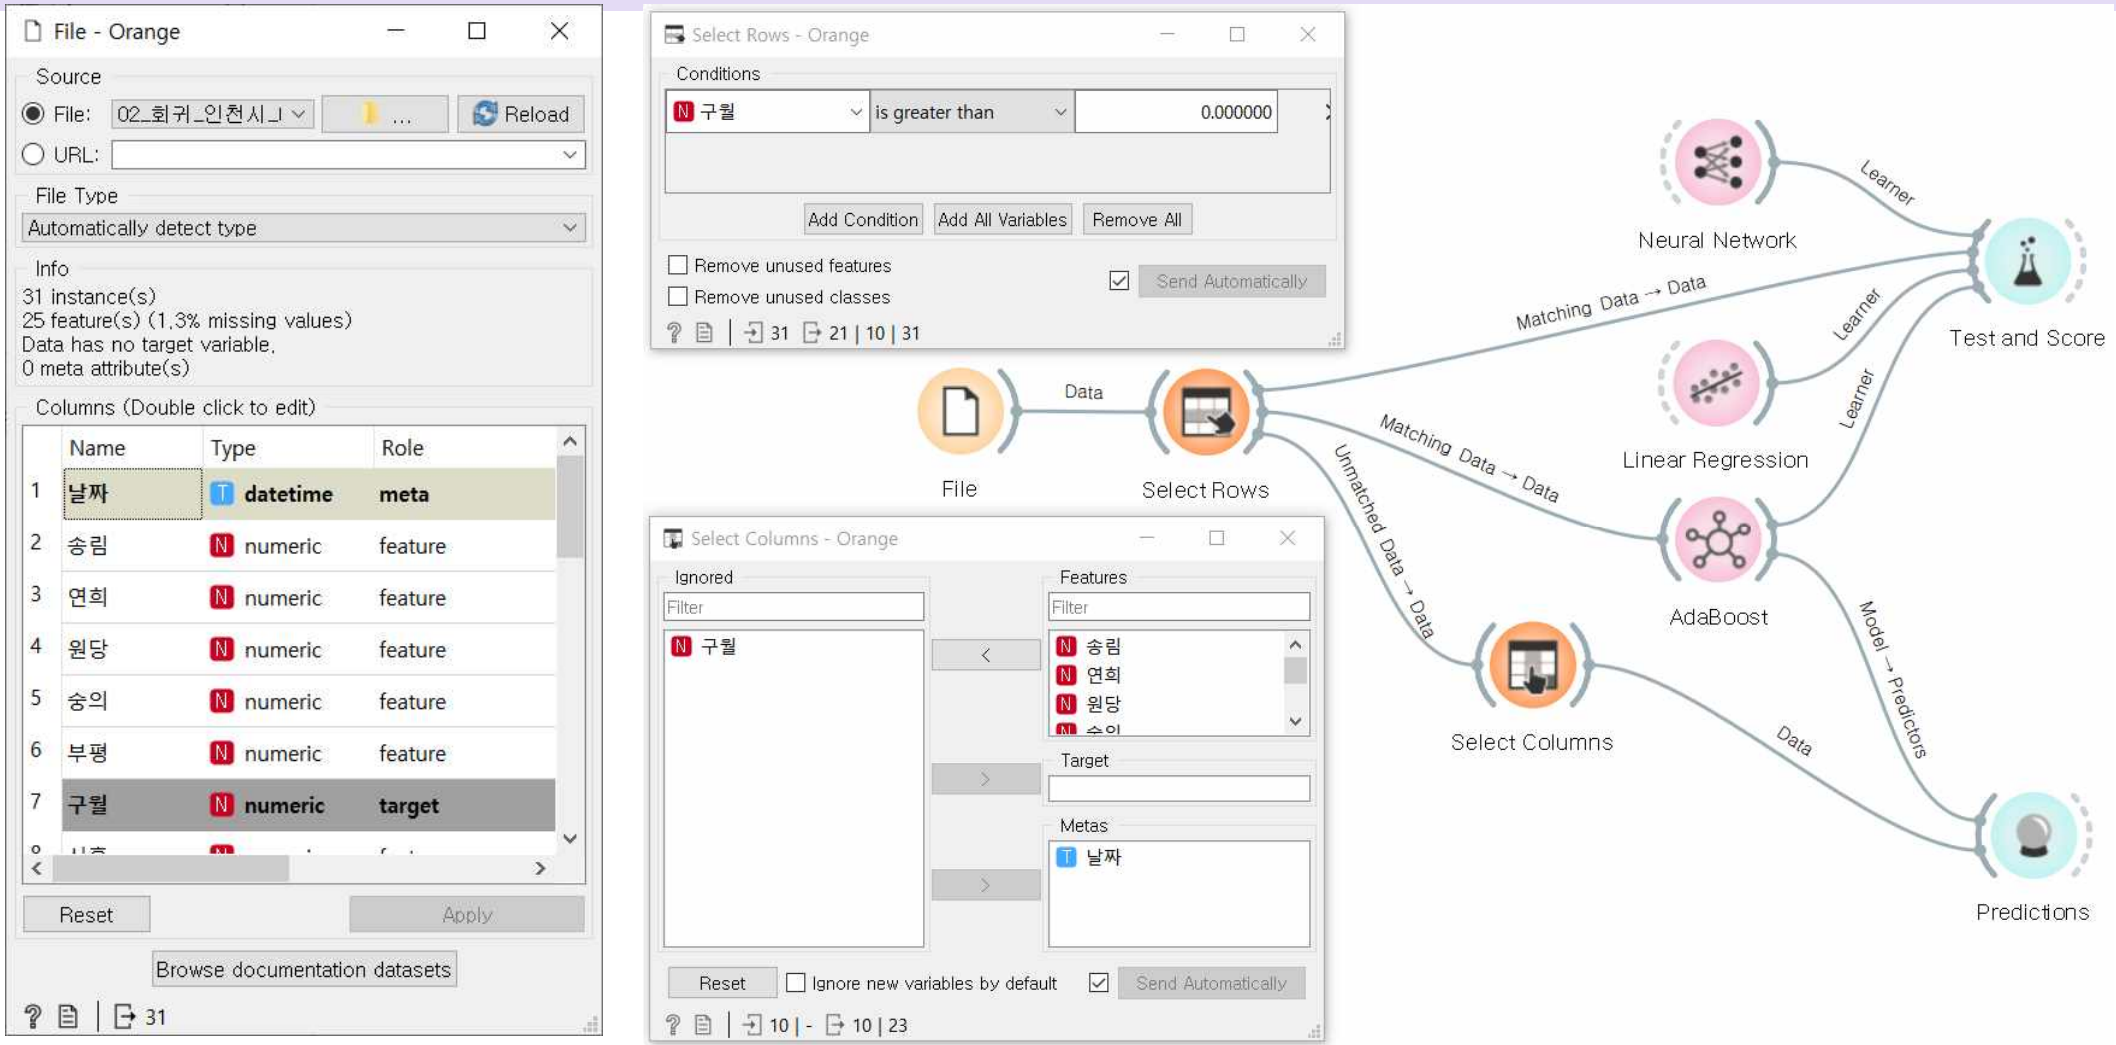

[활용] 국가별 기대수명 예측

	A	B	C	D	E	F	G	H	I	J	K
1	Country	Year	Status	Life expec	Adult Mor	infant deat	Alc				
2	Afghanista	2015	Developin	65	263	62					
3	Afghanista	2014	Developin	59.9	271	64					
4	Afghanista	2013	Developin	59.9	268	66					
5	Afghanista	2012	Developin	59.5	272	69					
6	Afghanista	2011	Developin	59.2	275	71					
7	Afghanista	2010	Developin	58.8	279	74					
8	Afghanista	2009	Developin	58.6	281	77					
9	Afghanista	2008	Developin	58.1	287	80					
10	Afghanista	2007	Developin	57.5	295	82					
11	Afghanista	2006	Developin	57.3	295	84					

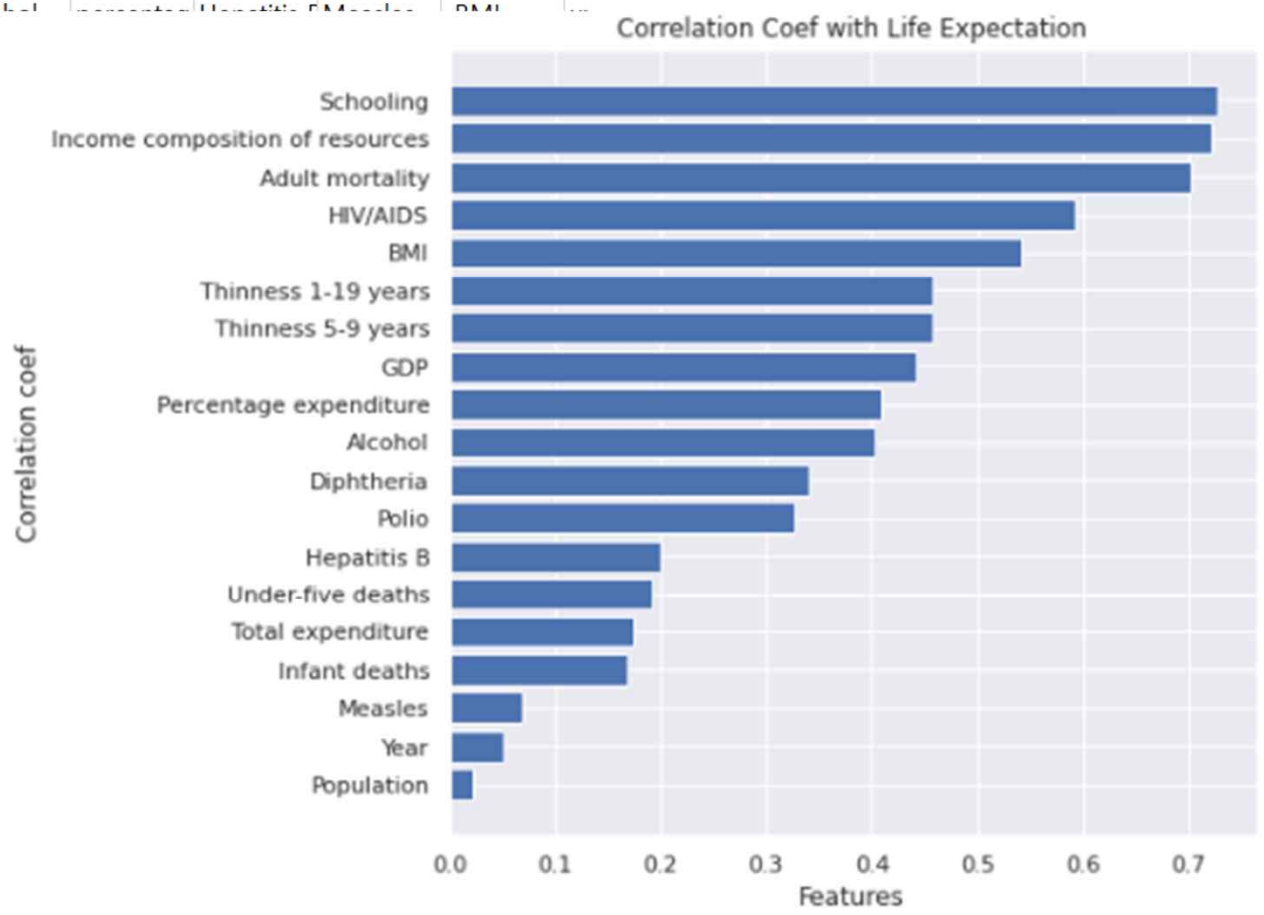

기대수명 데이터셋의 속성들

- Country: 국가명
- Year: 2000년부터 2015년까지의 연도
- Status: Developed(선진국) or Developing(개발도상국) status
- Life expectancy: 기대수명(나이)
- Adult Mortality: 15세~60세사이의 성인 1000명당 사망자수
- infant deaths: 유아 1000명당 사망자수
- Alcohol: 1인당 알콜 소비량
- percentage expenditure: GDP 대비 보건 예산 지출비율(%)
- Hepatitis B: 1세 아동의 B형 간염 예방 접종률(%)
- Measles: 인구 1000명당 홍역 예방 접종률(%)
- BMI: 전인구 평균 체질량 지수
- Under-five deaths: 5세이하 아동 1000명당 사망자수
- Polio: 1세 아동의 소아마비 면역률(%)
- Total expenditure: 정부 총예산 대비 보건 분야 예산(%)
- Diphtheria: 1세 아동의 디프테리아 예방 접종률(%) HIV/AIDS: HIV/AIDS 감염상태로 태어남 0-4세 인구 1000명당 사망자수
- GDP: 1인당 GDP
- Population: 국가 총인구
- thinness 1-19 years: 1-19 세 청소년 중 저체중 비율
- thinness 5-9 years:5-9세 사이의 아동의 저체중 비율
- Income composition of resources: 소득 구성에 따른 인간개발지수
- Schooling: 학교 재학 연수

Feature의 개수와 성능과의 관계?

- 상관도가 낮은 속성을 제거 한 후 예측했을 경우 평가지표는 어떻게 변할까?
- 특정한 두가지 속성이 연관관계가 있거나 상관도가 매우 높은 경우 둘 중 하나의 속성을 제거하는 것이 모델의 복잡도를 줄이고 성능을 높이는 데에 더 도움이 되지 않을까?

공공 데이터 제공 사이트

공공 데이터 : 나라에서 만들거나 취득하여 관리하는 데이터 (중앙정부, 지방자치단체, 공기업, 공공기관)

사이트명	URL
공공데이터 포털(행정안전부)	http://www.data.go.kr/
국가통계포털(통계청)	http://cosis.kr
고속도로 데이터포털(한국도로공사)	http://data.ex.co.kr
서울 열린 데이터 광장(서울시)	http://data.seoul.go.kr
경기데이터드림(경기도)	http://data.gg.go.kr
부동산 실거래가(국토교통부)	http://rt.molit.go.kr/
마이크로데이터 통합 서비스	https://mdis.kostat.go.kr/index.do
보건복지 데이터포털	https://kdx.kr/main
국민건강보험(NHISS)	https://nhiss.nhis.or.kr/bd/ay/bdaya001iv.do
구글 트랜드	https://trends.google.co.kr/trends/?geo=KR
네이버 데이터랩	https://datalab.naver.com/
한국데이터거래소(민간)	https://data.kihasa.re.kr/
캐글(해외)	https://www.kaggle.com/
Out World in Data(해외)	https://ourworldindata.org

다음 시간에는
지도학습 - ‘정형데이터를 활용한 분류1’ 를 알아봅시다.