

数値計算用ライブラリ

```
import numpy as np          機械学習用ライブラリScikit-learn
from sklearn.linear_model import LinearRegression
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error
import matplotlib.pyplot as plt  グラフ作成用ライブラリ
```

```
%matplotlib inline
```

```
np.random.seed(100)  いつも同じ乱数に固定
```

```
data_size = 100
```

```
X = np.random.randn(data_size)  標準正規分布の乱数
```

```
y = 5 * X + 10 + np.random.randn(data_size)  誤差
```

```
fig = plt.figure()
```

```
ax = fig.add_subplot(1,1,1)
```


```
ax.scatter(X, y)  散布図
```

```
ax.set_title(u"x and y scatter plot")
```

```
ax.set_xlabel("X")
```

```
ax.set_ylabel("y")
```

```
plt.show()
```



X_train,X_test,y_train,y_test=¥

train_test_split(X,y,test_size=0.3,random_state=0)

print("X_train :", X_train.shape)

print("X_test :", X_test.shape)

print("y_train :", y_train.shape)

print("y_test :", y_test.shape)

lr = LinearRegression() ←線形回帰

lr.fit(X_train.reshape(-1, 1), y_train)

print("傾き:",lr.coef_)

print("切片:",lr.intercept_)

y_pred = lr.predict(X_test.reshape(-1, 1))

print('予測結果¥n', y_test[:5]) 予測結果 [14.6040065 9.83994175 12.79186354 11.39130635 9.23670159]

print('答え¥n', y_pred[:5]) 答え [13.44602999 10.41128697 15.50471957 12.35730517 7.19382354]

print('トレーニングデータの平均乗誤差:',¥

mean_squared_error(y_train,
lr.predict(X_train.reshape(-1, 1))))

print('テストデータの平均2乗誤差:',

mean_squared_error(y_test, y_pred))

＼もしくは¥は、改行無視

Xとyのデータを指定した割合で分割
学習用データ:テストデータ=7:3

残差の2乗の合計が最小となる勾配と切片を算出
lr.fit(データ)

傾き: [4.87800146]


切片: 9.880209243463511

トレーニングデータの平均乗誤差: 1.050530750671141


テストデータの平均2乗誤差: 1.2382110791683136

[[1.028]
 [1.911]
 [3.002]
 [3.985]
 [4.977]
 [5.936]
 [6.957]
 [7.917]
 [9.002]
 [10.018]]
 [[136.7467638]
 [179.3086724]
 [124.7939742]
 [91.608693]
 [99.06056946]
 [211.3147593]
 [331.87715]
 [407.3815]
 [425.1095402]
 [449.1164546]]


rmse : 67.44116527130275
 R2 : 0.7534254734665234



rmse : 37.231982479228975
 R2 : 0.9248497551567119



rmse : 50.06437014920699
 R2 : 0.8641199837148785




degree を少しずつ増やし、R2などの評価を確認
 R2 > 0.9 となる degree (多項式) を採用

決定係数

degree	R2
1	0.753
2	0.864
3	0.925
10	1.000

rmse : 3.635961863135608e-06
 R2 : 0.9999999999999993



どちらが良さそう？

$$\text{損失関数} = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

←予測したい曲線

○ ←予測したいy

残差
 $(y_i - \hat{y}_i)^2$

機械学習では「過学習」と呼びます

←損失関数を最小にするとこのような曲線
にフィットさせる可能性があります

y

x

x_e

y_i

$\hat{y}_i$

$$\text{損失関数} = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

過学習を防ぐためこの項を加える

リッジ回帰: 重みの二乗の合計を足したもの

$$\sum_{i=1}^n (y_i - \hat{y}_i)^2 + \lambda \sum_{l=1}^k \omega_l^2$$

LASSO回帰: 重みの合計を足したもの

$$\sum_{i=1}^n (y_i - \hat{y}_i)^2 + \lambda \sum_{l=1}^k |\omega_l|$$

リッジ回帰

Alphaは罰則の重み

```
from sklearn.linear_model import Ridge  
rg = Ridge(alpha=0.3, random_state=1234)
```

```
rg.fit(X_train.reshape(-1, 1), y_train)
```

Ridge(alpha=0.3, copy_X=True, fit_intercept=True, max_iter=None, normalize=False, random_state=1234, solver='auto', tol=0.001)

```
print("傾き:", rg.coef_)
```

傾き: [4.85673346]

```
print("切片:", rg.intercept_)
```

切片: 9.878280306770973

```
y_pred = rg.predict(X_test.reshape(-1, 1))
```

```
print('予測結果¥n', y_test[:5])
```

```
print('答え¥n', y_pred[:5])
```

予測結果 [14.6040065 9.83994175 12.79186354 11.39130635 9.23670159]
答え [13.42855414 10.40704254 15.47826787 12.34457614 7.20360719]

```
print('トレーニングデータの平均乗誤差:', ¥
```

```
mean_squared_error(y_train,  
rg.predict(X_train.reshape(-1, 1))))
```

```
print('テストデータの平均2乗誤差:',
```

トレーニングデータの平均乗誤差: 1.050973435013048

```
mean_squared_error(y_test, y_pred)
```

テストデータの平均2乗誤差: 1.2311162936334716

LASSO回帰

```
from sklearn.linear_model import Lasso
la = Lasso(alpha=0.3, random_state=1234)
la.fit(X_train.reshape(-1, 1), y_train)    Ridge(alpha=0.3, copy_X=True, fit_intercept=True, max_iter=None,
                                             normalize=False, random_state=1234, solver='auto', tol=0.001)

print("傾き:", la.coef_)    傾き: [4.85673346]
print("切片:", la.intercept_)    切片: 9.878280306770973

y_pred = la.predict(X_test.reshape(-1, 1))
print('予測結果¥n', y_test[:5])    予測結果 [14.6040065  9.83994175 12.79186354 11.39130635  9.23670159]
print('答え¥n', y_pred[:5])    答え [13.42855414 10.40704254 15.47826787 12.34457614  7.20360719]

print('トレーニングデータの平均2乗誤差:', ¥
      mean_squared_error(y_train,
la.predict(X_train.reshape(-1, 1))))
print('テストデータの平均2乗誤差:',    トレーニングデータの平均乗誤差: 1.050973435013048
      mean_squared_error(y_test, y_pred))    テストデータの平均2乗誤差: 1.2311162936334716
```

	傾き	切片	平均2乗誤差	
			トレーニングデータ	テストデータ
線形回帰	4.878	9.880	1.0505	1.2382
リッジ回帰	4.857	9.878	1.0510	1.2311
LASSO回帰	4.857	9.878	1.0510	1.2311

```

fig = plt.figure()
ax = fig.add_subplot(1,1,1)
ax.scatter(X_test, y_test)
ax.set_title(u"x and y scatter plot")
ax.plot(X_test, lr.predict(X_test.reshape(-1, 1)), color = 'r',
        linestyle="--", label="LinearRegression")
ax.plot(X_test, rg.predict(X_test.reshape(-1, 1)), color = 'b',
        linestyle="--", label="Ridge")
ax.plot(X_test, la.predict(X_test.reshape(-1, 1)), color = 'g',
        linestyle=":", label="Lasso")
ax.set_xlabel("x")
ax.set_ylabel("y")
ax.legend(loc="best")
plt.show()

```

