

ลิขัณยรรีกรสขััน (Linear Regression)

เขียนโดย ดร.จักรกฤษณ์ แสงแก้ว วันที่ 21 กรกฎาคม 2562

บทนำ

- Linear Regression คือ การนำข้อมูลที่ได้มาคำนวณหาสมการเพื่อแทนลักษณะของข้อมูลนั้น ๆ
- Simple Linear Regression คือ การนำข้อมูล 2 ชุด มาทำการหาสมการเพื่อแทนลักษณะข้อมูลของตัวแปรทั้ง 2
- Multiple Linear Regression คือ การนำข้อมูลมากกว่า 2 ชุด มาทำการหาสมการเพื่อแทนลักษณะข้อมูลของตัวแปรทั้งหมด

ตัวแปรที่เกิดจากรีเกรสชัน

- R-Square หรือ Coefficient of determination มีค่าระหว่าง 0-1 ควรมีค่ามากกว่า 0.6
- Adjusted R-Square คือ การนำข้อมูลออก 1 ตัวแล้วคำนวณ R-Square ใหม่ ถ้าค่า R-Square และ Adjusted R-Square ต่างกันไม่มากถือว่าข้อมูลปกติดี แต่ถ้า Adjust R-Square มีค่าสูงคือข้อมูลที่นำมาวิเคราะห์มีจำนวนน้อยเกินไป
- Coefficients คือ ค่าสัมประสิทธิ์ที่มีผลต่อตัวแปรนั้น ๆ
- P-value คือ ค่าความน่าจะเป็นมีค่าระหว่าง 0-1 ถ้ามีค่ามากกว่า 0.05 หมายถึงตัวแปรนั้นไม่มีความจำเป็นต้องนำมาใช้ในการสร้างสมการรีเกรสชัน

1. Simple Linear Regression

- Simple Linear Regression เป็นการสร้างสมการเส้นตรงจากข้อมูลตัวเลข 2 ชุด คือ 1) ตัวแปรอิสระ x 2) ตัวแปรตาม $\hat{Y}$
- รูปแบบของสมการ Simple Linear Regression เขียนได้ดังนี้

$$\hat{Y} = \alpha + \beta * x$$

$$\beta = \frac{\sum xy - \frac{\sum x \sum y}{n}}{\sum x^2 - n(\bar{x})^2}$$

$$\alpha = \bar{y} - \beta(\bar{x})$$

```


%pylab inline
x = np.array([112,130,148,151,162,189,218,247,315,350])
y = np.array([225,200,459,445,439,577,722,903,1350,1360])
plt.plot(x,y,'bo')
5. plt.grid(True)

n = x.size
xy = x*y
x_square = x**2
10. sp = sum(xy) - ((sum(x)*sum(y))/n)
    ss = sum(x_square) - n * x.mean() **2
    beta = sp/ss
    alpha = y.mean() - beta * (x.mean())

15. print('beta = ',beta)
    print('alpha = ', alpha)
    print('สมการเส้นตรงของข้อมูลชุดนี้คือ : y = alpha + beta * (x)')
    print('สมการเส้นตรงของข้อมูลชุดนี้คือ : y = %f + %f * (x)%(alpha,beta))

```

ผลลัพธ์ :



```

beta = 5.171599134963733
alpha = -377.69734508966667
สมการเส้นตรงของข้อมูลชุดนี้คือ : y = alpha + beta * (x)
สมการเส้นตรงของข้อมูลชุดนี้คือ : y = -377.697345 + 5.171599 * (x)

```

การใช้งาน Simple Linear Regression ด้วย Scikit Learn

ในหัวข้อนี้จะใช้งานไลบรารี Scikit-Learn, Panda และ Seaborn ซึ่งเป็นไลบรารีสำหรับภาษาไพธอน สำหรับงานวิเคราะห์ข้อมูลและการเรียนรู้ของเครื่องจักร โดยสามารถดาวน์โหลดใช้งานได้โดยไม่มีค่าใช้จ่าย

- Scikit-Learn สำหรับงานด้านการเรียนรู้ของเครื่องจักร (Machine Learning) เว็บไซต์ตั้งอยู่ที่ <https://scikit-learn.org>
- Panda สำหรับการเตรียมและจัดการข้อมูลเพื่อการประมวลผล เว็บไซต์ตั้งอยู่ที่ <https://pandas.pydata.org>
- Seaborn สำหรับการแสดงผลข้อมูลในรูปแบบวิซวลทำงานบน matplotlib สามารถแสดงผลข้อมูลเกี่ยวกับสถิติต่าง ๆ ของข้อมูลได้ เว็บไซต์ตั้งอยู่ที่ <https://seaborn.pydata.org/>

```

import pandas as pd
import seaborn as sns
%pylab inline
x = np.array([112,130,148,151,162,189,218,247,315,350])
5. y = np.array([225,200,459,445,439,577,722,903,1350,1360])
data = {'x':x, 'y':y}
df = pd.DataFrame(data)
sns.lmplot(x='x',y='y',data=df,ci=None)
sns.jointplot(x='x',y='y',data=df, kind='reg', ci=None,color='orange')
10.
from sklearn.linear_model import LinearRegression
model = LinearRegression()
print(model)
df.info()
15.
x = df[['x']] # เขียนโดยระบุชื่อคอลัมน์ได้อีกรูปแบบ คือ y = df.x
y = df[['y']] # เขียนโดยระบุชื่อคอลัมน์ได้อีกรูปแบบ คือ y = df.y

model.fit(x,y)
20.
model.score(x,y) # R-squared ของโมเดล
model.intercept_
model.coef_

```

อธิบาย :

บรรทัดที่ 1-2 : ขอใช้ไลบรารี pandas และ seaborn สำหรับจัดการดาต้าเซตและการแสดงกราฟกวีซวลไลซ์

บรรทัดที่ 3 : %pylab inline เป็นการขอใช้ matplotlib และ numpy ฯลฯ เมื่อใช้คำสั่งนี้แล้วไม่ต้อง import numpy และ matplotlib


บรรทัดที่ 4-5 : ประกาศตัวแปร 2 ชุด คือ x และ y

บรรทัดที่ 6 : สร้างตัวแปรดิกชันนารี เพื่อนำไปใช้เป็นอินพุตให้กับดาต้าเฟรมต่อไป

บรรทัดที่ 7 : สร้างตัวแปร df เป็นชนิดดาต้าเฟรมโดยนำข้อมูลมาจากบรรทัดที่ 6 ดังนั้นจะมี 2 คอลัมน์คือ x และ y

บรรทัดที่ 8 : การพล็อตกราฟด้วยฟังก์ชัน lmplot() ซึ่งเป็นลิเนียร์โมเดล ผลลัพธ์จะได้เป็นเส้นตรงแทนข้อมูล x และ y โดยกำหนด ci=None (confidence interval) คือ ไม่ต้องแสดง

บรรทัดที่ 9 : การพล็อตกราฟด้วยฟังก์ชัน jointplot() โดยแสดงค่าความถ้อยออกมาด้วย ในตัวอย่างนี้คือ ความถี่ของของตัวแปร x และ y



บรรทัดที่ 11 : ประกาศการใช้งาน LinearRegression ภายในไลบรารี Scikit-Learn
 บรรทัดที่ 12 : สร้างอ็อบเจกต์ของคลาส LinearRegression เพื่อใช้สำหรับสร้างสมการเส้นตรงต่อไป
 บรรทัดที่ 13 : พิมพ์การตั้งค่าพารามิเตอร์ของโมเดล ผลลัพธ์จะแสดงคำว่า LinearRegression(copy_X=True, fit_intercept=True, n_jobs=None, normalize=False) หมายถึง ทำการคัดลอกค่า X และกำหนดให้ใช้จุดตัดแกน Y และไม่ต้องนอร์มัลไลซ์ข้อมูล
 บรรทัดที่ 14 : แสดงข้อมูลเกี่ยวกับดาต้าเฟรมที่ใช้งาน ในตัวอย่างนี้แสดงผลลัพธ์ เช่น ตัวแปรที่อยู่ภายใน x และ y และจำนวนข้อมูล 10 ตัว มีชนิดข้อมูลเป็นเลขจำนวนเต็ม 32 บิต เป็นต้น แสดงผลลัพธ์ได้ดังนี้

```
RangeIndex: 10 entries, 0 to 9
Data columns (total 2 columns):
x    10 non-null int32
y    10 non-null int32
dtypes: int32(2)
memory usage: 160.0 bytes
```

บรรทัดที่ 16-17 : กำหนดตัวแปร x และ y โดยจะทับข้อมูลเดิมที่ประกาศในบรรทัดที่ 4-5 เพื่อจะนำไปใช้ในการสร้างลิเนียร์เรกรेशनโมเดลต่อไป บรรทัดนี้ผู้อ่านสามารถกำหนดเป็นตัวแปรอื่นได้เพื่อป้องกันการสับสน
 บรรทัดที่ 19 : สร้างโมเดลลิเนียร์เรกรेशनด้วยฟังก์ชัน fit() โดยป้อนข้อมูลตัวแปรอิสระและตัวแปรตาม ตามลำดับ
 บรรทัดที่ 21 : เป็นการพิมพ์ค่า R-square ของโมเดล ซึ่งในตัวอย่างนี้มีค่า 0.98
 บรรทัดที่ 22 : แสดงค่าจุดตัดแกน y หรือค่า α ของสมการลิเนียร์เรกรेशन ซึ่งมีค่า -377.69
 บรรทัดที่ 23 : แสดงค่าสัมประสิทธิ์ Coefficient หรือค่า β ของสมการลิเนียร์เรกรेशन มีค่า 5.17

2. Multiple Linear Regression

- Multiple Linear Regression คือ การสร้างสมการเส้นตรงเพื่อแทนลักษณะข้อมูลของกลุ่มตัวแปร มากกว่า 2 ตัวขึ้นไป
- สมการของ Multiple Linear Regression คือ $Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$
- สำหรับการคำนวณหาค่า $\beta_1, \beta_2, \dots, \beta_n$ ดำเนินการในลักษณะเดียวกับ Simple Linear Regression

การใช้งาน Multiple Linear Regression ด้วย Python และ Scikit Learn

ในหัวข้อนี้เป็นการใช้งานลิเนียร์เรกรेशनหลายตัวแปร (Multiple Linear Regression) โดยใช้ดาต้าเซตการโฆษณาและยอดขาย ประกอบด้วยการโฆษณา จาก 3 แหล่ง ได้แก่ โทรทัศน์ วิทยุ หนังสือพิมพ์

1. ตัวแปรตาม (dependent variable) คือ ยอดขาย
2. ตัวแปรอิสระหรือตัวแปรต้น (independent variable) คือ ก) โฆษณากับโทรทัศน์ ข) โฆษณากับวิทยุ ค) โฆษณากับหนังสือพิมพ์

วัตถุประสงค์ของการทำ Multiple Linear Regression คือ การสร้างสมการเส้นตรงจากข้อมูลที่เก็บรวบรวมมา โดยมีตัวแปรอิสระมากกว่า 1 ตัวขึ้นไป

เขียนโปรแกรมด้วยภาษาไพธอนและ Scikit-Learn ได้ดังนี้

```

import pandas as pd
import seaborn as sns
%pylab inline

5. df = pd.read_csv("https://raw.githubusercontent.com/dsdi/dataset/master/th-advertising.csv", usecols=[1,2,
3,4])
sns.set(font="Kanit-Light",font_scale=2)
sns.set_context("paper", font_scale=1.5)
sns.lmplot(x='โทรทัศน์',y='ยอดขาย', data=df, ci=None, scatter_kws={'alpha':0.4}, line_kws={'color':'orange'})
sns.jointplot(x='โทรทัศน์',y='ยอดขาย', data=df, kind='reg', ci=None,color='orange')

10.
from sklearn.linear_model import LinearRegression
x = df.drop(columns=['ยอดขาย'][:160])
y = df['ยอดขาย'][:160]
x.head()

15. model = LinearRegression()
model.fit(x,y)
model.score(x,y) #R-Squared
model.intercept_
model.coef_ #สัมประสิทธิ์ ของ โทร วิทยุ หนังสือพิมพ์

20. model.predict([[250,40,70]]) #โฆษณาด้วย โทร 250, วิทยุ 40 และหนังสือพิมพ์ 70 จะมียอดขาย 22
model.predict([[250,40,70],
[50,40,45],
[20,50,70]])

x_test = df.drop(columns=['ยอดขาย'])[160:]
25. x_test.head()
y_predict = model.predict(x_test)
print(y_predict)

dc = pd.concat([df[160:].reset_index(), pd.Series(y_predict,name='พยากรณ์')],axis='columns')
30. dc

```

คำอธิบาย :

บรรทัดที่ 1-2 : ขอใช้ไลบรารี pandas และ seaborn

บรรทัดที่ 3 : ขอใช้งาน matplotlib และ numpy ผ่านคำสั่ง %pylab inline


บรรทัดที่ 5 : อ่านดาต้าเซตเข้ามาซึ่งเก็บไว้ใน github ในขั้นตอนนี้อาจต้องเชื่อมต่ออินเทอร์เน็ตเพื่อโหลดข้อมูล

บรรทัดที่ 6 : กำหนดฟอนต์ kanit-light เพื่อแสดงผลภาษาไทยบนกราฟซึ่งต้องติดตั้งในคอมพิวเตอร์ก่อนการใช้งาน หากสามารถ
ใช้ฟอนต์ Tahoma แทนได้

บรรทัดที่ 7 : กำหนดขนาดฟอนต์ใหญ่ขึ้น 1.5 เท่า

บรรทัดที่ 8 : พล็อตเส้นตรงด้วยฟังก์ชัน lmplot() ซึ่งเป็น linear model โดยกำหนดค่า "โทรทัศน์" เป็นตัวแปรต้น และ "ยอดขาย" เป็นตัวแปรตาม ใช้ข้อมูลจากตัวแปร df และไม่ต้องแสดง ci (confidence interval) กำหนดให้พล็อตแบบ scatter มีค่าโปร่งแสง 40 เปอร์เซนต์ และระบายสีเส้นด้วยสีส้ม

บรรทัดที่ 9 : พล็อตข้อมูลโดยแสดงความถี่ของข้อมูลด้านบนและด้านข้างของกราฟเพื่อแสดงความหนาแน่นของข้อมูล โดยใช้ฟังก์ชัน jointplot() และใช้ตัวแปรต้น คือ โทรทัศน์ ส่วนตัวแปรตาม คือ ยอดขาย กำหนดพารามิเตอร์ kind เป็นชนิด "reg" (regression) ไม่ต้องแสดง confidence interval และระบายสีเส้นลงบนเส้นถ้อยรีเกรสชัน



บรรทัดที่ 11 : ขอใช้งานคลาส LinearRegression จากไลบรารี Scikit-Learn

บรรทัดที่ 12 : สร้างตัวแปรต้นเก็บไว้ใน x ให้มีข้อมูลเพียง 3 คอลัมน์ โดยลบคอลัมน์ "ยอดขาย" ออกไป และดึงข้อมูลมาเพียง 160 เรคคอร์ด

บรรทัดที่ 13 : สร้างตัวแปรตามเก็บไว้ใน y ให้มีข้อมูลเพียง 1 คอลัมน์ คือ "ยอดขาย" และดึงข้อมูลมา 160 เรคคอร์ด

บรรทัดที่ 14 : แสดงข้อมูล header ของตัวแปรต้น ออกมา ซึ่งจะประกอบด้วย โทรทัศน์ วิทยุ หนังสือพิมพ์ ดังนี้

โทรทัศน์ วิทยุ หนังสือพิมพ์

0	230.1	37.8	69.2
1	44.5	39.3	45.1
2	17.2	45.9	69.3
3	151.5	41.3	58.5
4	180.8	10.8	58.4

บรรทัดที่ 15 : สร้างอินสแตนซ์ของคลาส LinearRegression() ชื่อ model เพื่อใช้สำหรับการสร้างโมเดลโดยสามารถตั้งชื่ออื่นตามที่ต้องการ ได้ เช่น my_linear_regression_model เป็นต้น

บรรทัดที่ 16 : คำสั่ง fit() เป็นการสร้างรีเกรสชันโมเดลโดยระบุตัวแปรต้นและตัวแปรอิสระลงไป ในตัวอย่างนี้ x เป็นตัวแปรต้น ส่วน y เป็นตัวแปรอิสระ

บรรทัดที่ 17-19 : แสดงค่า R-Square ด้วยคำสั่ง score(x,y) ตามด้วยแสดงค่า β_0 หรือค่าจุดตัดแกน y (intercept_) และสุดท้ายแสดงค่าสัมประสิทธิ์ของตัวแปรซึ่งเก็บไว้ใน model.coef_ มีจำนวนเท่ากับตัวแปรอิสระ ได้แก่ สัมประสิทธิ์การโฆษณาด้วยโทรทัศน์ วิทย์ และหนังสือพิมพ์ตามลำดับ

บรรทัดที่ 20 : คำนวณค่า ยอดขาย จากโมเดลที่สร้างขึ้นด้วยการป้อนข้อมูลใหม่เข้าไปเพื่อพยากรณ์ว่ายอดขายจะเท่ากับเท่าไร โดยระบุโทรทัศน์ (250), วิทย์ (40) และหนังสือพิมพ์ (70) พบว่าโมเดลที่ได้ทำนายผลลัพธ์ยอดขายมีค่า 21.89

บรรทัดที่ 21-23 : เป็นการคำนวณ ยอดขาย เหมือนบรรทัด 20 แต่ส่งข้อมูลไปพร้อมกัน 3 แถว ผลลัพธ์ แสดงดังนี้ array([21.89282947, 12.46601233, 12.82406754])

บรรทัดที่ 24 : สร้างตัวแปร x_test สำหรับนำส่วนที่เหลือจากแถวที่ 161 - 200 มาคำนวณ ยอดขาย โดยส่งเข้าไปให้ฟังก์ชัน predict()

บรรทัดที่ 25 : แสดงข้อมูลของตัวแปร x_test ออกมาด้วยคำสั่ง x_test.head(8) เมื่อเลข 8 คือจำนวนเรคคอร์ดที่ต้องการแสดงผลลัพธ์ออกมาเพียงบางส่วน ดังนี้

	โทรทัศน์	วิทย์	หนังสือพิมพ์
160	172.5	18.1	30.7
161	85.7	35.8	49.3
162	188.4	18.1	25.6
163	163.5	36.8	7.4
164	117.2	14.7	5.4
165	234.5	3.4	84.8
166	17.9	37.6	21.6
167	206.8	5.2	19.4

บรรทัดที่ 27 : แสดงผลลัพธ์การคำนวณ ยอดขาย จากแถวที่ 161 ถึง 200 ออกมา

บรรทัดที่ 29 : สร้างตัวแปรใหม่ ชื่อ dc โดยเพิ่มผลลัพธ์ที่คำนวณได้ในบรรทัดที่ 27 ขึ้นมาเป็นอีก 1 คอลัมน์ ชื่อ "พยากรณ์"

บรรทัดที่ 30 : แสดงผลตัวแปร dc หลังจากเพิ่มคอลัมน์ "พยากรณ์" เข้าไป แสดงผลลัพธ์ได้ ดังนี้

	index	โทรทัศน์	วิทยุ	หนังสือพิมพ์	ยอดขาย	พยากรณ์
0	160	172.5	18.1	30.7	14.4	14.327603
1	161	85.7	35.8	49.3	13.3	13.393180
2	162	188.4	18.1	25.6	14.9	15.083726
3	163	163.5	36.8	7.4	18.0	17.288872
4	164	117.2	14.7	5.4	11.9	11.126712
5	165	234.5	3.4	84.8	11.9	14.561304
6	166	17.9	37.6	21.6	8.0	10.539499
7	167	206.8	5.2	19.4	12.2	13.638024
8	168	215.4	23.6	57.6	17.1	17.318893
9	169	284.3	10.6	6.4	15.0	18.283913
10	170	50.0	11.6	18.4	8.4	7.381340

การใช้งาน Multiple Linear Regression ด้วย Python และ Statsmodels

ในหัวข้อนี้เป็นการใช้งาน Multi Linear Regression ด้วยภาษาไพธอนและใช้ไลบรารีอีกตัวหนึ่งที่ชื่อว่า statsmodel ให้ผลการวิเคราะห์ข้อมูลทางสถิติละเอียดกว่า scikit-learn พิจารณาตัวอย่างต่อไปนี้

```
import statsmodels.api as sm
import statsmodels.formula.api as smf
df = pd.read_csv("https://raw.githubusercontent.com/dsdi/dataset/master/en-advertising.csv", usecols=[1,2,3,4])
model = smf.ols(formula="Sales ~ TV + Radio + Newspaper", data=df[:160]).fit()
5. print(model.summary())
```

ผลลัพธ์ :

OLS Regression Results

```
=====
Dep. Variable:          Sales  R-squared:          0.896
Model:                  OLS   Adj. R-squared:         0.894
Method:                 Least Squares  F-statistic:         448.7
Date:                   Mon, 22 Jul 2019  Prob (F-statistic):    1.80e-76
Time:                   12:47:30  Log-Likelihood:        -310.02
No. Observations:       160      AIC:                  628.0
Df Residuals:           156      BIC:                  640.3
Df Model:                3
Covariance Type:        nonrobust
=====
```

	coef	std err	t	P> t	[0.025	0.975]
Intercept	2.9490	0.358	8.236	0.000	2.242	3.656
TV	0.0473	0.002	29.965	0.000	0.044	0.050
Radio	0.1799	0.010	18.149	0.000	0.160	0.200
Newspaper	-0.0009	0.007	-0.143	0.886	-0.014	0.012

```
=====
```

```
Omnibus:                52.610  Durbin-Watson:          2.120
Prob(Omnibus):           0.000  Jarque-Bera (JB):        128.997
Skew:                    -1.388  Prob(JB):                 9.74e-29
Kurtosis:                 6.412  Cond. No.                 453.
=====
```

Warnings:

[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.

อธิบาย :

บรรทัดที่ 1-2 : ขอใช้ไลบรารี statsmodels

บรรทัดที่ 3 : สร้างตัวแปรตามแฟรมตั้งชื่อ df โดยโหลดข้อมูลจากไฟล์ en-advertising.csv ใช้คอลัมน์ 1,2,3 และ 4 ตามลำดับ

บรรทัดที่ 4 : สร้างโมเดลจากสูตร "Sales ~ TV + Radio + Newspaper" โดยใช้ข้อมูล 160 เรคอร์ดด้านบนจากทั้งหมด 200 เรคอร์ด

บรรทัดที่ 5 : แสดงรายละเอียดข้อมูลชุดนี้ ประกอบด้วยค่าสถิติหลายตัว ได้แก่ R-Squared และ Adjusted R-Squared ฯลฯ

- ค่า p-value ช่วยให้เห็นว่า ตัวแปร newspaper มีค่า 0.886 ซึ่งไม่น่ามีนัยสำคัญทางสถิติ หมายถึงตัวแปรดังกล่าวไม่จำเป็นต้องนำมาใช้ในการสร้างสมการจะยังคงให้ความถูกต้องไม่แตกต่างกัน

ศึกษาเพิ่มเติม

- <https://sites.google.com/site/mystatistics01/home>

- <https://www.youtube.com/user/RStatsInstitute/videos>