



第六、七、八週

3. 資料探勘與機器學習(9hr)




3.1 相關分析與迴歸


從單變量到多變量




相關分析(續)



- 通常在研究線性關係時，都會先以散佈圖 (scatter plot) 輔助觀察資料走勢。然而散佈圖僅反映兩個變數之間的相互關係，無法明確定義其關係強度




迴歸分析(續)




- 羅吉斯迴歸 (Logistic Regression)
 - 當應變數是分類變數，無法使用前述的線性迴歸模式，可使用羅吉斯迴歸來分析：

$$\log \left(\frac{P(Y_i = 1)}{P(Y_i = 0)} \right) = \log \left(\frac{\pi}{1 - \pi} \right) = \beta_0 + \beta_1 X_{i,1} + \cdots + \beta_1 X_{i,p-1} + \varepsilon_i = X_i^T \beta$$


3.3 機器學習應用



支援向量機的應用




支援向量機分類



- 支援向量機(Support Vector Machines, SVM) 是分類、異常偵測與迴歸的常用工具之一。
- SVM 最早是 Vladimir Vapnik 在 1960 年代中期發展出來的一系列統計模型，其分類模型起源於最大邊界分類器(maximal margin classifiers)，藉由最大化分類超平面與資料之間的邊界幅度，決定出分割不同類樣本的最佳決策邊界。
- 2D空間線性不可分的樣本經過核函數的轉換，在3D空間為線性可區分，即低維度轉換至高維度空間。

參考: <https://youtu.be/OdlNM96sHio>

- 目標變數 letter 的分佈仍然是吾人應該關心的，結果顯示樣本在 26 個英語字母間散佈相當平均。




```
# 各整數值變數介於0 到15 之間(4 bits 像素值)
print(letters.describe(include = 'all'))
```

```
#          letter      xbox     ...      yedge      yedgex
# count    20000  20000.000000  ...  20000.000000  20000.00000
# unique     26          NaN  ...          NaN          NaN
# top        U          NaN  ...          NaN          NaN
# freq      813          NaN  ...          NaN          NaN
# mean        NaN  4.023550  ...  3.691750  7.80120
# std         NaN  1.913212  ...  2.567073  1.61747
# min         NaN  0.000000  ...  0.000000  0.00000
# 25%        NaN  3.000000  ...  2.000000  7.00000
# 50%        NaN  4.000000  ...  3.000000  8.00000
# 75%        NaN  5.000000  ...  5.000000  9.00000
# max        NaN 15.000000  ... 15.000000 15.00000
```


```
# 目標變數各類別分佈平均(預設依各類次數降冪排序)
print(letters['letter'].value_counts())
```

U	813
D	805
P	803
T	796
M	792
A	789
X	787
Y	786
N	783
Q	783
F	775
G	773
E	768
B	766
V	764
L	761
R	758
I	755
O	753
W	752
S	752
J	748
K	747
C	739
H	736
Z	734
Name: letter, dtype: int64	



```
# 真假值矩陣 (類似 R 語言的which函數使用 arr.ind=TRUE)
print(np.argwhere(threTF == True))
# [[0 2]
# [1 3]
# [2 0]
# [3 1]]

# 核對變數名稱，注意相關係數計算時已排除掉第 1 個變數letter
# 預測變數第0~3個為 [xbox,ybox,width,height]，4個變數之間似乎高度相關
(> 0.8)，對於有母數的建模方法可能造成不良後果，但對支援向量機來說卻不是個問題(魯棒性佳)。
print(letters.columns[1:5])
# Index(['xbox', 'ybox', 'width', 'height'], dtype='object')
```



```
# pandas 繪製盒鬚圖 boxplot()，選取 xbox, letter
# 圖形顯示變數 x.box(盒子的水平位置)僅影響字母 A、I、J、L、M 和 W 的辨識
ax1 = letters[['xbox', 'letter']].boxplot(by = 'letter')
fig1 = ax1.get_figure()
# fig1.savefig('img/xbox_boxplot.png')
```

