

Examen final

Durée 2h - Sans document

Vendredi 27 octobre 2023

Exercice 1 (4 pts)

Décrire et commenter les résultats obtenus à l'aide du code Python ci-dessous.

Les données considérées sont les résultats d'une analyse chimique de vins cultivés dans la même région d'Italie par trois cultivateurs différents. Treize mesures ont été effectuées pour différents constituants présents dans les trois types de vin.

```
import numpy as np
import sklearn.linear_model as lm
from sklearn import preprocessing
from sklearn import datasets
dataset = datasets.load_wine()
X = dataset.data
X.shape
(178, 13)

y = dataset.target
np.unique(y)
array([0, 1, 2])

X = X[y != 0]
y = y[y != 0]
X.shape
(119, 13)

np.unique(y)
array([1, 2])

scaler = preprocessing.StandardScaler().fit(X)
X = scaler.transform(X)
X.mean(axis=0)
array([ 1.41810000e-15,  4.73943947e-16,  6.67253367e-15,  3.69452368e-16,
        1.20293598e-16, -2.21811365e-16, -4.09569670e-16, -6.69865657e-16,
       -2.00120033e-16, -4.31027763e-16,  7.57563946e-16, -9.19899078e-16,
        2.78721957e-17])

X.var(axis=0)
array([1., 1., 1., 1., 1., 1., 1., 1., 1., 1., 1., 1., 1.])
```

```

model1 = lm.LogisticRegression()
model1.fit(X,y)
model1.penalty
'12'
model1.C
1.0
model1.intercept_
array([-1.93238543])
model1.coef_
array([[ 0.67061806,  0.54717719,  0.63550791,  0.24868629,  0.16614675,
        -0.20010196, -1.34821171, -0.09664867, -0.56443121,  1.26159206,
        -1.16294376, -0.99888229,  0.33789776]])

from sklearn.model_selection import cross_val_score
from sklearn.model_selection import RepeatedKFold
Sel = RepeatedKFold(n_splits=5, n_repeats=100)
scores = cross_val_score(lm.LogisticRegression(), X, y, cv=Sel)
scores.shape
(500,)
scores.mean()
0.9775869565217391

from sklearn.model_selection import GridSearchCV
parameters = {'C':np.logspace(-4, 4, 50),'penalty':['l1','l2']}
model2 = GridSearchCV(lm.LogisticRegression(), parameters,cv=Sel)

model2.fit(X,y)
model2.best_params_
{'C': 0.02811768697974228, 'penalty': 'l2'}

model2.best_score_
0.9889710144927536

```

Exercice 2 (6 pts)

Décrire et commenter les résultats obtenus à l'aide du code Python ci-dessous. Les données considérées sont décrites en annexe.

```

import os
import numpy as np

import pandas as pd
from sklearn.linear_model import LogisticRegression
from sklearn import preprocessing
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestClassifier
from math import sqrt
from sklearn.metrics import classification_report

```

```

path = os.getcwd()
os.chdir('/Users/marin/TEACHING/2324/M2-GLM-HAX912X/EXAMENS')

data = pd.read_csv('Breast-Cancer-Wisconsin.csv')
y = data['diagnosis']
X = data.drop(['id', 'diagnosis', 'Unnamed: 32'], axis = 1)
X.head()

```

	radius_mean	texture_mean	...	symmetry_worst	fractal_dimension_worst
0	17.99	10.38	...	0.4601	0.11890
1	20.57	17.77	...	0.2750	0.08902
2	19.69	21.25	...	0.3613	0.08758
3	11.42	20.38	...	0.6638	0.17300
4	20.29	14.34	...	0.2364	0.07678

```

[5 rows x 30 columns]

pd.value_counts(y, sort = True).sort_index()

B    357
M    212
Name: diagnosis, dtype: int64

scaler = preprocessing.StandardScaler().fit(X)
X = scaler.transform(X)

X_train, X_test, y_train, y_test = train_test_split(X,y,test_size = 0.2,
random_state = 2023)

pd.value_counts(y_train, sort = True).sort_index()
B    286
M    169
Name: diagnosis, dtype: int64

pd.value_counts(y_test, sort = True).sort_index()
B    71
M    43
Name: diagnosis, dtype: int64

forest = RandomForestClassifier(n_estimators=500, max_features=int(sqrt(30)),
oob_score=True,n_jobs=-1)
forest = forest.fit(X_train,y_train)
y_chap = forest.predict(X_test)
print(classification_report(y_test,y_chap))

```

	precision	recall	f1-score	support
B	0.95	0.99	0.97	71
M	0.97	0.91	0.94	43
accuracy			0.96	114
macro avg	0.96	0.95	0.95	114

weighted avg 0.96 0.96 0.96 114

```
forest.oob_score_  
0.9604395604395605
```

```
forest.oob_decision_function_  
array([[0.           , 1.           ],  
       [1.           , 0.           ],  
       [0.05747126, 0.94252874],  
       [0.           , 1.           ],  
       [1.           , 0.           ],  
       [0.99456522, 0.00543478],  
       ...  
       [1.           , 0.           ],  
       [0.00534759, 0.99465241],  
       [0.96907216, 0.03092784],  
       ...  
       [1.           , 0.           ],  
       [1.           , 0.           ],  
       [0.98809524, 0.01190476],  
       [0.99450549, 0.00549451],  
       [0.9893617 , 0.0106383 ],  
       [0.12429379, 0.87570621],  
       [0.56666667, 0.43333333],  
       [0.           , 1.           ],  
       [1.           , 0.           ],  
       [0.87434555, 0.12565445],  
       [1.           , 0.           ],  
       [0.34104046, 0.65895954],  
       [1.           , 0.           ],  
       [1.           , 0.           ],  
       [0.           , 1.           ],  
       [0.9902439 , 0.0097561 ],  
       [1.           , 0.           ],  
       [1.           , 0.           ],  
       [0.98969072, 0.01030928],  
       [0.97354497, 0.02645503],  
       [0.95854922, 0.04145078]])
```

Exercice 3 (8 pts)

On considère un n -échantillons $(y_1, x_1), \dots, (y_n, x_n)$ du couple (y, x) où y est une variable aléatoire à valeurs dans $\{0, 1\}$ et x est une variable fixée prenant également les valeurs $\{0, 1\}$. On suppose qu'il existe une variable latente y^* telle que

$$f(y^*|x) = \frac{\exp(-(y^* - \beta_0 - \beta_1 x))}{(1 + \exp(-(y^* - \beta_0 - \beta_1 x)))^2}$$

et

$$y = \begin{cases} 1 & \text{si } y^* \leq 0 \\ 0 & \text{si } y^* > 0 \end{cases} .$$

1 (3 pts) Montrer qu'il s'agit d'un modèle linéaire généralisée et l'expliciter.

Indication : la primitive de $\frac{\exp(-(y - \mu))}{(1 + \exp(-(y - \mu)))^2}$ est $\frac{1}{1 + \exp(-(y - \mu))}$.

2 (2 pts) Est-ce le lien canonique qui a été choisi ?

3 (3 pts) Nous disposons de 100 observations (y_i, x_i) décrites dans la table de contingence suivante

	$y = 0$	$y = 1$
$x = 0$	30	20
$x = 1$	20	30

Donner la log-vraisemblance en fonction de β_0 et β_1 .

Exercice 4 (2 pts)

Décrire la méthode de construction d'arbre de régression.

Annexe

Breast cancer data (Données sur le cancer du sein)

About Dataset

Features are computed from a digitized image of a fine needle aspirate (FNA) of a breast mass. They describe characteristics of the cell nuclei present in the image. In the 3-dimensional space is that described in:

[K. P. Bennett and O. L. Mangasarian: "Robust Linear Programming Discrimination of Two Linearly Inseparable Sets", Optimization Methods and Software 1, 1992, 23-34].

Attribute Information:

- 1) ID number
- 2) Diagnosis (M = malignant, B = benign)

3-32)

Ten real-valued features are computed for each cell nucleus:

- a) radius (mean of distances from center to points on the perimeter)
- b) texture (standard deviation of gray-scale values)
- c) perimeter
- d) area
- e) smoothness (local variation in radius lengths)
- f) compactness (perimeter² / area - 1.0)

- g) concavity (severity of concave portions of the contour)
- h) concave points (number of concave portions of the contour)
- i) symmetry
- j) fractal dimension ("coastline approximation" - 1)

The mean, standard error and "worst" or largest (mean of the three largest values) of these features were computed for each image, resulting in 30 features. For instance, field 3 is Mean Radius, field 13 is Radius SE, field 23 is Worst Radius.

All feature values are recoded with four significant digits.

Missing attribute values: none

Class distribution: 357 benign, 212 malignant

Correction Examen Final

27 octobre 2023

H4X912X

(1)

Exercice 1

4 points doivent être mentionnés

↳ Importation des données
avec au final (après suppression
de certains individus)

119 individus

13 variables dont une
variable à expliquer y
variable binaire

Les 12 variables explicatives
sont centrées réduites

(1pt)

2] Théorie de régression logistique (2)
avec paramètres par défaut et
mis en œuvre simultanément et
contraints à la parallélisation $C=1$
dans les coefficients estimés sont
non nuls - (1 pt)

3] Estimation de la zone de
bonne classification par
validation croisée à 5
ensembles répétés 100 fois
résultat $\approx 0,98\%$ (moyenne
des 500 estimations) (1 pt)

4] Choisir la meilleure méthode de
régularisation entre Lasso (L1)
et ridge (L2) pour 50 valeurs
de C entre e^{-4} et e^4 uniformément
réparties en échelle log -

Peilleux merliu

(3)

Midye avec $\alpha \neq 0,03$

Tous les bien classé avec 0,99%

Pour un échantillon fini /

mon encre utilisé pour grimer
ce tout correctement -

EXERCICE 2

3 points doivent être mentionnés

1) Les données - les cellules d'une
image d'un tissu issu d'un
sein canceré sont analysées -

L'analyse statistique de la
cellule, il y a 519 dont

212 cancéreuses - Objectif : construire

une fonction capable de prédire

si une cellule est cancéreuse ou non

à partir de 30 variables descriptives

Les 30 variables explicatives
sont centrées réduites. Les

(4)

classes sont séparées en deux
échantillons : un échantillon

(2 pts)

d'apprentissage contenant 455

individus et un échantillon de test
contenant 114 individus.

2] Un classement par forêt aléatoire
est entraîné sur l'échantillon
d'apprentissage. Il contient
500 arbres et à chaque nœud

le meilleur variable est choisie. (2 pts)

Sur un nouveau échantillon tiré

aléatoirement de 30 variables -
Tous les bons classements sur l'échantillon
de test 96% -

3] Avec les foies électrons, (5)
on peut déterminer un échantillon
de test en validation croisée la
qualité d'un classifieur. Pour ce
faire, il suffit d'utiliser
l'estimateur out-of-box sur

l'échantillon d'apprentissage -
Dans ce cas, le taux de bonnes
classifications est estimé à (2pts)
96% - Talem est l'estimation
obtenue sur l'échantillon de test.

Exercice 3

1] $y \sim \mathcal{B}(p, K)$

La loi de Bernoulli appartient à la
famille exponentielle scalaire.

$$f(y|p) = p^y (1-p)^{1-y} \prod_{y \in \{0,1\}} S(dy) \quad (6)$$

$$f(y|p) = \exp\left(y \log\left(\frac{p}{1-p}\right) + \log(1-p)\right) \mathbb{1}_{\{0,1\}}(y)$$

$$\theta = \log\left(\frac{p}{1-p}\right) \Rightarrow p = \frac{e^\theta}{1+e^\theta}$$

$$h(\theta) = -\log\left(\frac{1}{1+e^\theta}\right) = \log(1+e^\theta)$$

For all κ , $p(\kappa) = \mathbb{P}(y=1)$

$$p(\kappa) = \mathbb{P}(y^* \leq 0)$$

$$p(\kappa) = \int_{-\infty}^0 \frac{\exp(-|y^* - \beta_0 - \beta_1 \kappa|)}{(1 + \exp(-|y^* - \beta_0 - \beta_1 \kappa|))^2} \mathbb{1}_{y^*}(dy^*)$$

$$\Leftrightarrow p(\kappa) = \left[\frac{1}{1 + \exp(-|y^* - \beta_0 - \beta_1 \kappa|)} \right]_{-\infty}^0$$

$$\Leftrightarrow p(\kappa) = \frac{1}{1 + e^{\beta_0 + \beta_1 \kappa}} = \left[\frac{e^{-\beta_0 - \beta_1 \kappa}}{1 + e^{-\beta_0 - \beta_1 \kappa}} \right]$$

$$E(y) = f'(0) = \frac{e^0}{1+e^0} = \rho$$

$$E(y) = \frac{1}{1+e^{\beta_0+\beta_1 K}} = f^{-1}(\beta_0+\beta_1 K)$$

Il s'agit bien d'un modèle linéaire généralisé -

2] Nouveaux paramètres

$$0 = \log\left(\frac{1}{1+e^{\beta_0+\beta_1 K}} \times \frac{1+e^{\beta_0+\beta_1 K}}{e^{\beta_0+\beta_1 K}}\right)$$

$$0 = -\beta_0 - \beta_1 K + \beta_0 + \beta_1 K$$

cependant si l'on considère les paramètres $\tilde{\beta}_0 = -\beta_0$ et $\tilde{\beta}_1 = -\beta_1$

alors $0 = \tilde{\beta}_0 + \tilde{\beta}_1 K$

Donc formellement, ce n'est pas le même modèle que qui a été utilisé mais pour $(\tilde{\beta}_0, \tilde{\beta}_1)$ c'est bien lui -

En termes mathématiques, c'est un. (8)
 En termes de manipulation, c'est simple.

$$3) \mathcal{L}(\beta_0, \beta_1) = - \sum_{i=1}^{100} y_i \log(1 + e^{\beta_0 + \beta_1 x_i})$$

$$+ \sum_{i=1}^{100} (1 - y_i) \log\left(\frac{e^{\beta_0 + \beta_1 x_i}}{1 + e^{\beta_0 + \beta_1 x_i}}\right)$$

$$\Leftrightarrow \mathcal{L}(\beta_0, \beta_1) = - \sum_{i=1}^{100} y_i (\beta_0 + \beta_1 x_i)$$

$$+ \sum_{i=1}^{100} \log\left(\frac{e^{\beta_0 + \beta_1 x_i}}{1 + e^{\beta_0 + \beta_1 x_i}}\right)$$

$$\Leftrightarrow \mathcal{L}(\beta_0, \beta_1) = - 50 \beta_0 - 30 \beta_1$$

$$+ 100 \beta_0 + 50 \beta_1 - \sum_{i=1}^{100} \log(1 + e^{\beta_0 + \beta_1 x_i})$$

$$\Leftrightarrow \mathcal{L}(\beta_0, \beta_1) = 50 \beta_0 + 20 \beta_1 - 50 \log(1 + e^{\beta_0})$$

$$- 50 \log(1 + e^{\beta_0 + \beta_1})$$

Exercice 4

(9)

Soit un arbre en ordre de classification
avec étiquettes à chaque nœud
l'arbre le meilleur avec le
(variable, seul) en utilisant le critère
des membres - corrigé - le critère
est pondéré par les membres
et individuellement dans les familles
absente et familles à gauche
un point à la fin -