

Corrigé

Examen ING2 EILCO - Ingénierie Mathématique

Rattrapage

Janvier 2025

Nom :

Prénom :

Total: 31 points

Durée: 2h

Instructions générales: Aucun matériel autorisé, pas de calculatrice autorisée

L'examen comprend 2 parties (Chacune de ces parties reprenant différentes sous-questions). Vous êtes libres de rédiger vos réponses sur des pages supplémentaires en veillant toutefois à bien indiquer le numéro de chaque question. Une fois l'examen terminé, Assurez vous de bien écrire votre nom (de façon lisible) sur chacune des pages. Répondez à un maximum de questions, en commençant par les questions qui vous semblent les plus abordables.

Question 1 (18pts)

1. [5pts] Indiquer si les affirmations suivantes sont vraies ou fausses

Vrai / Faux En régression linéaire, pour un taux d'apprentissage suffisamment petit et un nombre suffisamment élevé d'itérations, la descente de gradient donnera toujours une solution qui annule la fonction coût

Vrai / Faux Dans la décomposition biais variance, l'erreur quadratique moyenne diminue lorsque le biais diminue

Vrai / Faux La dérivée de la fonction sigmoïde satisfait $\sigma' = \sigma(\sigma - 1)$

Vrai / Faux Dans la décomposition biais variance, l'erreur quadratique moyenne diminue lorsque la complexité du modèle augmente

Vrai / Faux La régression Ridge correspond à supposer une distribution Gaussienne pour les résidus

Vrai / Faux Dans le cadre de l'astuce du noyau, la mise à jour est donnée par

$$\lambda_j \leftarrow \lambda_j + \frac{2\eta}{N} \left(t^{(j)} - \sum_{i=1}^N \lambda_i (\varphi^{(i)})^\top \varphi^{(j)} \right)$$

Vrai / Faux L'a priori de type Laplace utilisé dans le modèle LASSO est donné par $\frac{1}{2\lambda} \exp\left(-\frac{|x|}{\lambda}\right)$

Vrai / Faux La régularisation ne peut être utilisée qu'en régression, pas en classification

2. [4pts] Déterminer quelles sont, parmi les affirmations suivantes, celles qui sont correctes:

1) En scikit-learn, quel est le rôle du paramètre α du modèle Ridge?

A. Il détermine le poids de la norme ℓ_1 .

B. Il contrôle l'équilibre entre la fidélité aux données et l'amplitude des coefficients de régression.

C. Il conduit certains des coefficients à s'annuler exactement.

D. Il permet de contrôler le taux d'apprentissage

2) Que se passe-t-il si le paramètre α du modèle Lasso est fixé à zéro?

- A. Le modèle se réduit à un modèle de régression linéaire simple
 B. Le modèle se réduit à un modèle de type Ridge
 C. Tous les coefficients du modèle s'annulent
 D. Tous les coefficients du modèle s'annulent sauf le biais.
- 3) En scikit-learn, quelle fonction est utilisée pour diviser les données en un ensemble de test et un ensemble d'entraînement?
 A. data_split()
 B. fit_transform()
 C. split_data()
 D. train_test_split()
 E. cross_val_score()
- 4) Quel type de frontière de décision le modèle LogisticRegression de scikit-learn produit-il?
 A. Quadratique
 B. Linéaire
 C. Non Linéaire
 D. Polynomiale
 E. Circulaire
- 5) Que fait la fonction np.random.normal de numpy?
 A. Elle génère des entiers aléatoirement dans un intervalle donné
 B. Elle génère des échantillons issus d'une distribution uniforme
 C. Elle génère des échantillons Gaussiens
 D. Elle génère un tableau de valeurs équidistantes
- 6) Parmi les solveurs suivants, lesquels ne sont pas implémentés par le modèle MLPClassifier de Scikit-learn?
 A. lbfgs
 B. sgd
 C. adam
 D. gradient_descent
 E. newton
3. [4pts] On considère le modèle de régression linéaire suivant

$$\hat{t} = \beta_0 + \beta_1 x \quad (1)$$

- (a) Soit les données $\{x^{(i)}, t^{(i)}\}_{i=1}^N$ et soit $SXX = \sum_{i=1}^N (x^{(i)} - \bar{x})^2$ où \bar{x} est la moyenne empirique, $\bar{x} = \frac{1}{N} \sum_{i=1}^N x^{(i)}$. Montrer que

$$SXX = \sum_{i=1}^N (x^{(i)} - \bar{x}) x^{(i)} \quad (2)$$

- (b) Soit la quantité SXY définie par $SXY = \sum_{i=1}^N (x^{(i)} - \bar{x})(t^{(i)} - \bar{t})$. Montrer que

$$SXY = \sum_{i=1}^n (x^{(i)} - \bar{x}) t^{(i)} \quad (3)$$

- (c) En se basant sur les résultats (2) et (3), si $\hat{\beta}_1$ et $\hat{\beta}_0$ sont les solutions du problème de minimisation par moindres carrés

$$\hat{\beta}_1, \hat{\beta}_0 = \underset{\beta}{\operatorname{argmin}} \sum_{i=1}^n (t^{(i)} - (\beta_0 + \beta_1 x^{(i)}))^2 \quad (4)$$

montrer que

$$\hat{\beta}_1 = \frac{SXY}{SXX} \quad (5)$$

Question 2 (13pts)

1. [5pts] Indiquer si les affirmations suivantes sont vraies ou fausses

Vrai / Faux La limite quand p tend vers l'infini des normes ℓ_p correspond à l'hypercube $\max_i |x_i| \leq 1$

Vrai / Faux L'estimateur de Maximum de Vraisemblance produit un modèle qui maximise la probabilité d'observer les données

Vrai / Faux La fonction d'entropie binaire croisée est équivalente à une fonction de log-vraisemblance dont les probabilités de classe sont définies par la sortie du modèle

Vrai / Faux Dans le cadre de la régression linéaire, ajouter une pénalité de type Ridge, de coefficient associé $\lambda > 0$, correspond à translater les valeurs propres de la matrice $\mathbf{X}^T \mathbf{X}$ de λ .

Vrai / Faux Dans l'algorithme de backpropagation, dans l'expression des $\frac{\partial L}{\partial a_i}$ de la couche ℓ en fonction des $\frac{\partial L}{\partial a_i}$ de la couche $\ell + 1$, le nombre de termes dans l'expression dépend du nombre de neurones de la couche $\ell + 1$

Vrai / Faux Lorsque l'a priori est uniforme, l'estimateur de maximum a posteriori se réduit à un estimateur de maximum de vraisemblance

Vrai / Faux Dans l'algorithme du perceptron, la fonction de coût à minimiser est donnée par

$$\ell(\beta) = \sum_{i=1}^N t^{(i)} (\beta_0 + \beta_1 x_1^{(i)} + \dots + \beta_D x_D^{(i)})$$

Vrai / Faux Si un jeu de données est linéairement séparable par un modèle de régression logistique de la forme $\sigma(\mathbf{w}^T \mathbf{x} + b)$ où $\sigma(a) = 1/(1 + e^{-a})$, alors il reste linéairement séparable par tout modèle de la forme $\sigma(\mathbf{w}_c^T \mathbf{x} + b_c)$ où $\mathbf{w}_c = c\mathbf{w}$ et $b_c = cb$.

2. [4pts] On considère les extraits de code donnés en page 5. Pour chaque extrait, donner le résultat de la dernière (ou des deux dernières) commandes `print`

3. [4pts] On considère un réseau de neurones à 2 couches prenant en entrée un vecteur caractéristique de taille 3 et dont les deux couches contiennent respectivement 3 neurones (pour la première couche) et 1 neurone (pour la couche de sortie). La sortie du réseau est donnée par le scalaire $y(\mathbf{x}) \in \mathbb{R}$. Les matrices de poids et biais pour chacune des couches sont données par

$$\mathbf{W}_1 = \begin{bmatrix} 1 & -1 & 0 \\ 0.5 & 2 & -1 \\ -1 & 1 & 1 \end{bmatrix}, \quad \mathbf{b}_1 = \begin{bmatrix} 0.5 \\ -1 \\ 1 \end{bmatrix} \quad (6)$$

$$\mathbf{W}_2 = [1 \quad -1 \quad 0], \quad \mathbf{b}_2 = -0.5 \quad (7)$$

La $i^{\text{ème}}$ ligne de la matrice \mathbf{W}_ℓ correspond donc aux poids $\mathbf{w}_i^{(\ell)} = [w_{i1}^{(\ell)}, w_{i2}^{(\ell)}, w_{i3}^{(\ell)}]$ du $i^{\text{ème}}$ neurone de la couche ℓ . On suppose que tous les neurones sont munis d'une fonction d'activation de type ReLU (Unité Linéaire Rectifiée), $\sigma(\mathbf{x}) = \text{ReLU}(x)$ définie par

$$\text{ReLU}(x) = \begin{cases} x & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases} \quad (8)$$

Calculer la valeur de la sortie du réseau, $y(\mathbf{x})$, pour un vecteur caractéristique d'entrée donné par $\mathbf{x} = [2, -1, 0]$.

```

1 import numpy as np
2 import matplotlib.pyplot as plt
3 from sklearn.preprocessing import PolynomialFeatures
4
5 x_class1 = np.asarray([-1,-1,-1])
6 y_class1 = np.asarray([1,2,3])
7
8 x_class2 = np.asarray([1,1,1])
9 y_class2 = np.asarray([1,2,3])
10
11
12
13 X1 = np.vstack((x_class1.flatten(), y_class1.flatten())).T
14 X2 = np.vstack((x_class2.flatten(), y_class2.flatten())).T
15
16 X = np.vstack((X1, X2))
17
18 print(X)
19

```

Résultat Extrait 1:

$$X = \begin{bmatrix} -1 & 1 \\ -1 & 2 \\ -1 & 3 \\ 1 & 1 \\ 1 & 2 \\ 1 & 3 \end{bmatrix}$$

```

1 my_poly = PolynomialFeatures(2)
2
3 Xpoly = my_poly.fit_transform(X)
4
5 print(Xpoly)

```

Résultat Extrait 2:

$$X_{poly} = \begin{bmatrix} 1 & -1 & 1 & -1 & 1 & 1 \\ 1 & -1 & 2 & -2 & 1 & 4 \\ 1 & -1 & 3 & -3 & 1 & 9 \\ 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 2 & 2 & 1 & 4 \\ 1 & 1 & 3 & 3 & 1 & 9 \end{bmatrix}$$

```

1 x = np.linspace(1,10,10)
2 t = np.linspace(1,10,10)
3
4 print(x)
5 print(t)

```

```

[ 1.  2.  3.  4.  5.  6.  7.  8.  9. 10.]
[ 1.  2.  3.  4.  5.  6.  7.  8.  9. 10.]

```

```

1 from sklearn.linear_model import LinearRegression
2
3 my_model = LinearRegression().fit(x.reshape(-1,1), t)
4
5 xpred = np.linspace(0,5,5)
6 print(xpred)
7

```

```
[0.  1.25 2.5 3.75 5. ]
```

```

1 model_prediction = my_model.predict(xpred.reshape(-1,1))
2
3 print(model_prediction)
4

```

Résultat Extrait 3:

$$\text{model_prediction} = [0 \quad 1.25 \quad 2.5 \quad 3.75 \quad 5]$$

Examen INK2 - EILCO - INGÉNIÉRIE MATHÉMATIQUE (Rattrapage)

Correction

Question 1.3 (a)

$$\begin{aligned}
 \text{On a } S_{XX} &= \sum_{i=1}^N (x^{(i)} - \bar{x})^2 \\
 &= \sum_{i=1}^N \left(x^{(i)} - \frac{1}{N} \sum_{j=1}^N x^{(j)} \right)^2 = \\
 &= \sum_{i=1}^N (x^{(i)})^2 + \frac{1}{N^2} \sum_{i=1}^N \left(\sum_{j=1}^N x^{(j)} \right)^2 - \frac{2}{N} \sum_{i=1}^N \sum_{j=1}^N x^{(i)} x^{(j)} \\
 &= \sum_{i=1}^N (x^{(i)})^2 + \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^N x^{(i)} x^{(j)} - \frac{2}{N} \sum_{i=1}^N \sum_{j=1}^N x^{(i)} x^{(j)} \\
 &= \sum_{i=1}^N x^{(i)} \left(x^{(i)} - \sum_{j=1}^N \frac{x^{(j)}}{N} \right) \\
 &= \sum_{i=1}^N x^{(i)} (x^{(i)} - \bar{x})
 \end{aligned}$$

Question 1.3. (b)

$$\begin{aligned}
 \text{On a } S_{XY} &= \sum_{i=1}^N (x^{(i)} - \bar{x})(t^{(i)} - \bar{t}) \\
 &= \sum_{i=1}^N x^{(i)} t^{(i)} - \frac{1}{N} \sum_{j=1}^N x^{(j)} \sum_{i=1}^N t^{(i)} \\
 &\quad + \sum_{i=1}^N x^{(i)} \frac{1}{N} \sum_{j=1}^N t^{(j)} - \sum_{i=1}^N \frac{1}{N^2} \sum_{j=1}^N \sum_{k=1}^N x^{(i)} t^{(k)} \\
 &= \sum_{i=1}^N x^{(i)} t^{(i)} - \sum_{i=1}^N \frac{1}{N^2} \sum_{j=1}^N \sum_{k=1}^N x^{(i)} t^{(k)} \\
 &= \sum_{i=1}^N x^{(i)} t^{(i)} - \sum_{i=1}^N t^{(i)} \frac{1}{N} \sum_{j=1}^N x^{(j)} = \sum_{i=1}^N (x^{(i)} - \bar{x}) t^{(i)}
 \end{aligned}$$

la dernière ligne provient du

fait que
$$\sum_{i=1}^N \frac{1}{N^2} \sum_{j=1}^N \sum_{k=1}^N x^{(i)} t^{(k)} = \sum_{i=1}^N t^{(i)} \frac{1}{N} \sum_{j=1}^N x^{(j)}$$

Question 1.3 (Corrigé) suite

(c) En prenant les dérivées partielles par rapport à β_0, β_1 , on trouve les équations normales

$$\frac{\partial}{\partial \beta_1} \sum_{i=1}^N (t^{(i)} - (\beta_0 + \beta_1 x^{(i)}))^2 = -2 \sum_{i=1}^N (t^{(i)} - (\beta_0 + \beta_1 x^{(i)})) x^{(i)}$$

$$\frac{\partial}{\partial \beta_0} \sum_{i=1}^N (t^{(i)} - (\beta_0 + \beta_1 x^{(i)}))^2 = -2 \sum_{i=1}^N (t^{(i)} - (\beta_0 + \beta_1 x^{(i)}))$$

On a donc
$$\beta_0 = \frac{1}{N} \sum_{i=1}^N t^{(i)} - \frac{1}{N} \sum_{i=1}^N x^{(i)} \beta_1$$

$$\beta_1 \left(\sum_{i=1}^N (x^{(i)})^2 \right) = \sum_{i=1}^N x^{(i)} t^{(i)} - \sum_{i=1}^N \beta_0 x^{(i)}$$

En substituant l'expression de β_0 dans celle de β_1 , on trouve

$$\beta_1 \left(\sum_{i=1}^N (x^{(i)})^2 \right) = \sum_{i=1}^N x^{(i)} t^{(i)} - \sum_{i=1}^N x^{(i)} \frac{1}{N} \sum_{j=1}^N t^{(j)} + \sum_{i=1}^N x^{(i)} \frac{1}{N} \sum_{j=1}^N x^{(j)} \beta_1$$

$$\Rightarrow \beta_1 \left[\sum_{i=1}^N (x^{(i)})^2 - \sum_{i=1}^N x^{(i)} \bar{x} \right] = \sum_{i=1}^N x^{(i)} t^{(i)} - \sum_{j=1}^N t^{(j)} \bar{x}$$

$$\Rightarrow \beta_1 = \frac{\sum_{i=1}^N x^{(i)} t^{(i)} - \sum_{i=1}^N t^{(i)} \bar{x}}{\sum_{i=1}^N (x^{(i)})^2 - \sum_{i=1}^N x^{(i)} \bar{x}}$$

Question 2.3 (Corrigé)

En utilisant les matrices de poids et de biais, la sortie de la 1^{ère} couche est donnée par

$$\begin{bmatrix} z_1 \\ z_2 \\ z_3 \end{bmatrix} = \sigma \left(\begin{bmatrix} 1 & -2 & 0 \\ 0.5 & 2 & -1 \\ -1 & 1 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} + \begin{bmatrix} 0.5 \\ -1 \\ 1 \end{bmatrix} \right)$$

Question 2.3 (Corrigé) suite

$$\text{où } \sigma(x) = \begin{cases} x & x \geq 0 \\ 0 & \text{sinon} \end{cases}$$

pour la couche de sortie, on trouve

$$y(x) = \sigma \left([1, -1, 0] \begin{bmatrix} z_1 \\ z_2 \\ z_3 \end{bmatrix} - 0.5 \right)$$

En choisissant $x = [2, -1, 0]$ on retrouve

$$\begin{bmatrix} z_1 \\ z_2 \\ z_3 \end{bmatrix} = \sigma \left(\begin{bmatrix} 1 & -2 & 0 \\ 0.5 & 2 & -1 \\ -1 & 1 & 1 \end{bmatrix} \begin{bmatrix} 2 \\ -1 \\ 0 \end{bmatrix} + \begin{bmatrix} 0.5 \\ -1 \\ 1 \end{bmatrix} \right)$$

$$= \sigma \left(\begin{bmatrix} 3 \\ -1 \\ -3 \end{bmatrix} + \begin{bmatrix} 0.5 \\ -1 \\ 1 \end{bmatrix} \right) = \sigma \left(\begin{bmatrix} 3.5 \\ -2 \\ -2 \end{bmatrix} \right) = \begin{bmatrix} 3.5 \\ 0 \\ 0 \end{bmatrix}$$

En propageant ces données à travers la couche de sortie, on trouve

$$y(x) = \sigma \left([1, -1, 0] \begin{bmatrix} 3.5 \\ 0 \\ 0 \end{bmatrix} - 0.5 \right) = \sigma(3.5 - 0.5) = 3$$