

# Examen ING2 EILCO - Ingénierie Mathématique

Décembre 2022

Nom :

Prénom :

**Total:** 27 points

**Durée:** 2h

**Instructions générales:** 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 (14pts)

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

- Vrai / Faux     Minimiser la fonction d'entropie binaire croisée correspond à rechercher un estimateur de maximum de vraisemblance
- Vrai / Faux     Le modèle de régression logistique est un exemple de modèle de classification de type génératif
- Vrai / Faux     Dans le cadre de la régularisation de type Ridge et pour un coefficient de régularisation  $\lambda > 0$ , augmenter la valeur de  $\lambda$  résulte en une augmentation de la variance de la famille de modèles correspondants
- Vrai / Faux     Dans le cadre de la régression linéaire, ajouter une pénalité de type Ridge, de coefficient associé  $\lambda > 0$ , correspond à traduire les valeurs propres de la matrice  $\mathbf{X}^T \mathbf{X}$  de  $\lambda$
- Vrai / Faux     Les équations normales admettent toujours au moins une solution
- Vrai / Faux     Dans le cas d'un modèle de classification linéaire, initialiser l'ensemble des poids et des biais à zéro aura pour conséquence de n'entraîner aucune mise à jour de ces paramètres dans le cadre d'une descente de gradient
- Vrai / Faux     Une descente de gradient appliquée à un modèle linéaire et à une fonction de coût donnée par la somme des carrés des erreurs, retourne toujours le minimum global.

2. [3pts] Donner le pseudo-code pour le modèle de classification "un contre tous"

3. [6pts] On considère le modèle de régression suivant, connu sous le nom de "réseau élastique",

$$L\left(\beta, \left\{x^{(i)}, t^{(i)}\right\}_{i=1}^N\right) = \frac{1}{N} \sum_{i=1}^N \left(t^{(i)} - \beta_0 - \sum_{j=1}^D \beta_j x_j^{(i)}\right)^2 + \lambda_2 \left(\sum_{j=1}^D |\beta_j|^2\right) + \lambda_1 \left(\sum_{j=1}^D |\beta_j|\right) \quad (1)$$

(a) [1pt] Indiquer la partie dérivable et la partie non dérivable de la fonction coût.

(b) [2pts] On a représenté, à la Figure 2, l'évolution des coefficients de régression (chacun des  $\beta_j$  est représenté par une courbe) obtenus en minimisant la fonction de coût (1) pour différents choix de  $(\lambda_1, \lambda_2)$ . En particulier, chacun des différents cas suivants est représenté par l'une des 3 figures:

- Le modèle Ridge ( $\lambda_1 = 0, \lambda_2 > 0$ )
- Le modèle LASSO ( $\lambda_2 = 0, \lambda_1 > 0$ )
- Un modèle intermédiaire, donné par des coefficients  $\lambda_1, \lambda_2 > 0$  avec  $\lambda_1 = 9\lambda_2$

Indiquer, sur chacune des figures, le modèle correspondant.

(c) [3pts] On considère le projecteur suivant dont la  $i^{\text{ème}}$  composante est définie par

$$[\mathcal{T}_{\lambda t}(\boldsymbol{\beta})]_i = \max(0, |\beta_i| - \lambda t) \text{sign}(\beta_i) \quad (2)$$

Le projecteur remplace donc par zéro les coefficients  $\beta_i$  dont l'amplitude est inférieure à  $\lambda t$ . À l'aide de ce projecteur, donner un algorithme de minimisation de la fonction de coût (1).

## Question 2 (13pts)

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

Vrai / Faux Augmenter le nombre de neurones dans la couche cachée d'un réseau à une couche augmente la variance de la famille de modèles correspondants

Vrai / Faux Un réseau de neurones profond dont toutes les fonctions d'activation sont données par l'identité est équivalent à un modèle linéaire

Vrai / Faux L'algorithme de descente de gradient appliqué à un réseau de neurones avec un taux d'apprentissage suffisamment faible et un nombre suffisamment grand d'itérations converge nécessairement vers le minimum global de la fonction coût

Vrai / Faux Le nombre minimum de neurones nécessaires à l'apprentissage d'un modèle de type 'OU Exclusif' (XOR) est égal à 4

Vrai / Faux En terme d'expressivité (i.e. capacité à capturer une distribution de données), un réseau de neurones est plus puissant qu'un modèle linéaire basé sur des caractéristiques polynomiales

2. [3pts] On considère le réseau de neurones représenté à la Figure 1, reprenant 3 couches cachées. Les poids associés à l'unité  $i$  de la couche  $\ell$  sont représentés par la variable  $w_{ij}^{(\ell)}$ . Chaque neurone est représenté par une fonction d'activation sigmoïdale  $\sigma$ , et muni d'un biais  $w_{i0}^{(\ell)}$  (non représenté sur la figure)

(a) [1pts] Esquisser la fonction sigmoïde

(b) [2pts] Donner l'expression détaillée de  $y(\mathbf{x})$  en fonction de  $\mathbf{x} = (x_1, x_2, x_3)$  et des paramètres  $w_{ij}^{(\ell)}$ .

3. [5pts] On souhaite utiliser l'algorithme de Backpropagation, afin de calculer le gradient de l'entropie binaire croisée (pour une paire  $(\mathbf{x}^{(i)}, t^{(i)})$ ) par rapport au poids  $w_{11}^{(0)}$  du réseau de neurones représenté à la Figure 1. Pour ce faire on procédera comme suit:

(a) [1pts] Donner l'expression de la fonction d'entropie binaire croisée pour la paire  $\{\mathbf{x}^{(i)}, t^{(i)}\}$

(b) [1pts] Donner l'expression du  $\delta^{(2)} = \delta_{out} = \frac{\partial L}{\partial a_{out}}$  (dérivée de la fonction d'entropie par rapport à la valeur de préactivation en sortie du réseau)

(c) [2pts] Donner l'équation de backpropagation et utiliser cette équation pour déduire, à partir de  $\delta_{out}$ , la valeurs des  $\delta_i^1$  pour  $i = 1, 2$ . Ensuite déduire, à partir des  $\delta_i^1$ , la valeur de  $\delta_1^0$ .

(d) [1pts] Finalement, donner l'expression de la dérivée  $\frac{\partial L}{\partial w_{11}^0}$  de la fonction de coût par rapport au poids  $w_{11}^0$  en fonction de  $\delta_1^0$  et de  $z_1^{(0)} = x_1$ . En déduire, à partir de votre expression de  $\delta_1^0$  la réponse à la question.




Figure 1: Réseau de neurones utilisé pour les questions 2.2 et 2.3




Figure 2: Évolution des coefficients de régression pour une valeur croissante des coefficients de régularisation  $\lambda_1, \lambda_2$  dans le modèle de type “réseau élastique”. Les différentes courbes correspondent aux différents coefficients.