

Interrogation 2022-2023

Exercice 1 : QCM (5 points)

Cocher la (les) bonne (s) réponse (s) :

1) Quelle est la fonction d'erreur la plus couramment utilisée en régression linéaire?

- a) La fonction de perte de Hinge
- b) La fonction de perte logistique
- c) La fonction d'erreur quadratique moyenne
- d) La fonction de perte de Perceptron

2) Qu'est-ce qu'un arbre de décision?

- a) Un algorithme de classification linéaire
- b) Un algorithme de régression linéaire
- c) Un algorithme de classification non linéaire
- d) Un algorithme de clustering

3) Comment est déterminée la meilleure variable de division dans un arbre de décision?

- a) En maximisant l'information gain
- b) En minimisant l'information gain
- c) En maximisant le sur-apprentissage de l'arbre
- d) En minimisant sur-apprentissage de l'arbre

4) Comment est déterminée la profondeur optimale d'un arbre de décision?

- a) En maximisant l'information gain
- b) En minimisant l'information gain
- c) En maximisant sur-apprentissage de l'arbre
- d) En minimisant sur-apprentissage de l'arbre

5) Qu'est-ce que la règle de Bayes?

- a) Un théorème mathématique qui permet de calculer la probabilité conditionnelle
- b) Une heuristique utilisée pour choisir la meilleure variable de division dans un arbre de décision
- c) Une méthode d'optimisation utilisée pour minimiser la fonction de coût dans la régression linéaire
- d) Une méthode d'optimisation utilisée pour minimiser l'impureté de Gini dans un arbre de décision

6) Quel est l'avantage de la régression linéaire par rapport à d'autres algorithmes de régression?

- a) Elle est plus rapide à entraîner
- b) Elle peut modéliser des relations non linéaires
- c) Elle est plus précise que les autres algorithmes
- d) Elle est plus facile à comprendre et à interpréter

7) Qu'est-ce que la descente de gradient?

- a) Une méthode pour minimiser la fonction de coût dans la régression linéaire
- b) Une méthode pour maximiser l'information gain dans les arbres de décision
- c) Une méthode pour calculer la probabilité conditionnelle dans le classificateur de Bayes
- d) Une méthode pour maximiser la précision de la classification linéaire

8) Qu'est-ce que l'entropie?

- a) Une mesure de la pureté d'un nœud dans un arbre de décision
- b) Une mesure de la distance entre les données dans l'espace des caractéristiques
- c) Une mesure de l'erreur de prédiction pour un modèle de classification
- d) Une mesure de la qualité d'un modèle de régression linéaire

9) Qu'est-ce que le classificateur de Bayes naïf?

- a) Un algorithme de classification linéaire qui utilise une approche probabiliste
- b) Un algorithme d'apprentissage non supervisé qui recherche des motifs dans les données
- c) Un algorithme de classification qui utilise des règles conditionnelles simples et indépendantes
- d) Un algorithme de régression linéaire qui utilise une approche bayésienne

10) Quelle est la différence entre l'overfitting et l'underfitting?

- a) L'overfitting se produit lorsque le modèle est trop simple pour les données, tandis que l'underfitting se produit lorsque le modèle est trop complexe pour les données.
- b) L'overfitting se produit lorsque le modèle s'adapte trop bien aux données d'entraînement, tandis que l'underfitting se produit lorsque le modèle ne s'adapte pas suffisamment bien aux données d'entraînement.
- c) L'overfitting se produit lorsque le modèle a une variance élevée, tandis que l'underfitting se produit lorsque le modèle a une erreur de biais élevée.
- d) L'overfitting et l'underfitting sont des termes interchangeables qui décrivent tous deux une mauvaise adaptation du modèle aux données.

Exercice 2 : Classificateur de Bayes (5 points)

Nous souhaitons réaliser un classifieur bayésien permettant de classifier les emails en « Spam » ou « Ham (not spam) ». Pour ce faire, chaque mot w_i d'un e-mail, quel que soit l'endroit où il se trouve dans l'e-mail, est supposé avoir une probabilité $P(W = w_i | Y)$, où W prend des mots dans un dictionnaire prédéterminé (la ponctuation est ignorée). Y prend une valeur binaire (Spam ou ham).

I. Supposons que nous avons trois emails comme ensemble d'apprentissage.

(Spam) dear sir, if you could answer my questions I would be most grateful.

(Ham) see you at 12

(Ham) well, prepare it for tomorrow.

A partir de cet ensemble d'entraînement, calculer les probabilités bayésiennes suivantes.

- $P(W = \text{sir} | Y = \text{spam})$
- $P(W = \text{see} | Y = \text{ham})$
- $P(W = \text{today} | Y = \text{ham})$
- $P(Y = \text{ham})$

II. Le tableau suivant montre les probabilités estimées d'un ensemble de mots spams entraînés sur un large corpus d'emails.

W	$good$	to	$fine$	$luck$	pay
$P(W/Y=spam)$	$1/6$	$1/8$	$1/4$	$1/8$	$1/4$
$P(W/Y=ham)$	$1/8$	$1/3$	$1/4$	$1/12$	$1/12$

On vous donne un nouvel email à classer, avec seulement deux mots :

Good luck

1. Calculer la décision estimée pour cet email, sachant que :
 $P(Y = spam) = 1/5$.
2. Quelle est l'intervalle de probabilités de $P(Y = spam)$ pour lequel le classifieur bayésien classe ce nouvel email comme spam ?

Exercice 3 Régression linéaire avec la bibliothèque Scikit-learn/Python (10 points)

Nous avons un ensemble de données comprenant deux variables, X et Y. Nous souhaitons créer un modèle de régression linéaire pour prédire la variable Y en fonction de la variable X.

Les données sont les suivantes :

X = [23, 45, 12, 67, 87, 43, 65, 34, 56, 78]

Y = [450, 678, 340, 980, 1200, 600, 900, 520, 800, 1100]

1. Tracer un graphique représentant les données.
2. Diviser les données en ensembles d'entraînement (80%) et de test (20%).
3. Créer un modèle de régression linéaire à l'aide de l'ensemble d'entraînement.
4. Prédire les valeurs de Y pour l'ensemble de test en utilisant le modèle de régression linéaire.
5. Évaluer les performances du modèle en utilisant la métrique de l'erreur quadratique moyenne (Mean Squared Error - MSE).
6. Tracer un graphique représentant les prédictions du modèle par rapport aux vraies valeurs pour l'ensemble de test.

Bon courage