

**Data Science****Régression****Exercice I**

On dispose des mesures suivantes du temps d'exécution d'un algorithme en secondes (y) en fonction de la taille d'un tableau de données (x).

x	110	125	152	172	190	208	220	242	253	270	290
y	187	225	305	318	367	365	400	435	450	506	558

On donne les résultats suivants :

$$\sum x_i = 2232, \sum y_i = 4116, \sum x_i^2 = 487750, \sum x_i y_i = 900961, \sum y_i^2 = 1666782.$$

1. Représentez sur un graphique ces données par un nuage de points.
2. Trouvez la fonction de régression  $y = \alpha x + \beta$  obtenue par la méthode des moindres carrés sur ce jeu de données. Tracez la droite de régression sur le graphique.
3. Utilisez la fonction de régression obtenue pour prédire le temps d'exécution de l'algorithme pour un tableau de taille 500. Interprétez le résultat obtenu à partir du graphique que vous avez tracé.
4. Supposons qu'on dispose du temps d'exécution de l'algorithme pour chacune des  $n = 20$  valeurs suivantes  $x_1 = 110, x_2 = 115, \dots, x_{20} = 205$ . Si l'objectif principal est d'estimer  $\alpha$  le plus précisément possible, serait-il préférable d'utiliser le jeu de données avec  $n=20$  ou celui avec  $n=11$  décrit par le tableau ci-dessus ?

**Exercice II**

On considère le problème d'apprentissage d'une fonction à valeur réelle  $h : \mathbb{R}^d \rightarrow \mathbb{R}$  à partir d'un ensemble de données d'apprentissage  $S = \{(x_i, y_i), 1 \leq i \leq n\}$ ,  $x_i \in \mathbb{R}^d$  et  $y_i \in \mathbb{R}$ . On considère uniquement le cas où la fonction  $h$  est linéaire et qui s'écrit sous la forme  $h(x) = \langle w, x \rangle$ , avec  $w \in \mathbb{R}^n$  le vecteur de pondération solution du problème d'optimisation suivant :

$$\min_{w \in \mathbb{R}^d} \sum_{i=1}^n (\langle w, x_i \rangle - y_i)^2 + \lambda \|w\|_2^2,$$

où  $\lambda \in \mathbb{R}_+$  est le paramètre de régularisation.

Soit  $X$  la matrice de taille  $n \times d$  telle que  $X_{i,j} = (x_i)_j$  et  $Y$  le vecteur colonne de taille  $n$  tel que sa  $i$  ème composante est  $y_i$ . Finalement, soit  $W$  le vecteur de dimension  $d$  correspondant au vecteur de pondération  $w$ .

1. Exprimer la fonction objective du problème d'optimisation ci-dessus en fonction des matrices  $X, Y, W$  et le paramètre de régularisation  $\lambda$ .
2. Déterminer une forme analytique de la solution optimal  $W^*$  du problème d'optimisation en fonction de  $X, Y$  et  $\lambda$ . [Vous pourriez avoir besoin d'utiliser  $\frac{\partial \|A\|^2}{\partial A} = 2A$ , pour une matrice  $A$ .]
3. Quelle est la complexité en temps pour calculer le vecteur de pondération optimal  $W^*$  comme une fonction du nombre d'attributs  $d$  et du nombre d'exemples  $n$ ? Quelle est la complexité de calculer  $h(x)$  pour une nouvelle donnée  $x \in \mathbb{R}^n$ ?
4. La matrice  $XX^\top$  est appelé la matrice de Gram. Utilisant le fait que :

$$X^\top (XX^\top + \lambda I)^{-1} = (X^\top X + \lambda I)^{-1} X^\top,^1$$

déterminer une nouvelle expression de la solution optimale  $W^*$ ? Quelle est la complexité en temps de calcul de  $W^*$  utilisant cette forme analytique de la solution?

## Exercice III

On utilise les mêmes notations que l'exercice précédent.

Montrer que l'estimateur de la régression Ridge peut être obtenu à partir de l'estiméur des moindres carrés sur un jeu de donnée augmenté. Pour cela, augmenter la matrice des variables explicatives (données d'entrée)  $X \in \mathbb{R}^{n \times d}$  par  $p$  lignes en ajoutant la matrice  $\sqrt{\lambda}I$  et le vecteur de réponses (sorties)  $Y$  par  $p$  valeurs nulles.

## Exercice IV

Considérons le problème d'optimisation « elastic-net » :

$$\min_{w \in \mathbb{R}^d} \sum_{i=1}^n (\langle w, x_i \rangle - y_i)^2 + \lambda [\alpha \|w\|_2^2 + (1 - \alpha) \|w\|_1].$$

Montrer que résoudre ce problème revient à résoudre le problème lasso sur un jeu de données augmenté.

---

1. Voir The Matrix Cookbook, Eq. 167.