

TD 3

Exercice 1 – Régression linéaire

Soit un ensemble de données d'apprentissage $\mathcal{D} = \{\mathbf{x}^i, y^i\}_{i=1, \dots, N}$, $\mathbf{x}^i \in \mathbb{R}$, $y^i \in \mathbb{R}$.

Q 1.1 Rappeler le principe de la régression linéaire. Quelle fonction d'erreur est utilisée ?

Q 1.2 Par convention que l'on suivra dans toute la suite du cours, la matrice de données sera notée X , où chaque ligne correspond à un exemple. La matrice Y des réponses est donc une matrice colonne ; la matrice W des poids également. L'erreur sur \mathcal{D} sera notée $C(W)$. Quelles sont les dimensions des matrices ? Rappeler la formulation matricielle de l'erreur.

Q 1.3 Trouver analytiquement la matrice W solution de la régression linéaire, qui minimise $C(W)$.

Exercice 2 – Descente de gradient

Q 2.1 Apéro

Q 2.1.1 Parmi les fonctions suivantes, lesquelles sont convexes :

$f(x) = x \cos(x)$, $g(x) = -\log(x) + x^2$, $h(x) = x\sqrt{x}$, $t(x) = -\log(x) - \log(10 - x)$?

Q 2.1.2 Soit une application linéaire $f \in \mathbb{R}^{n \times d} \rightarrow \mathbb{R}$; rappeler ce qu'est le gradient de f par rapport à $A : \nabla_A f(A)$, avec $f(x) = (f_1(x), f_2(x), \dots, f_n(x))$

Q 2.1.3 Exprimer $\nabla_x(f(x) + g(x))$, $\nabla_x t f(x)$; Donner l'expression de $\nabla_x b'x$ avec $b \in \mathbb{R}^d$, $\nabla_x x'Ax$ pour A symétrique.

Q 2.2 Rappeler le principe de l'algorithme de descente du gradient. L'appliquer dans le cas de la régression linéaire.

Q 2.3 Dans le cas d'un problème 2D

Q 2.3.1 Tracer un espace des paramètres en 2D sur votre feuille. Positionner arbitrairement les points W_0 , point initial, et W^* , solution analytique du problème.

Q 2.3.2 Etant donnée la nature quadratique du coût, tracer les iso-contours de la fonction de coût dans l'espace des paramètres. Quelle est la forme de la fonction de coût $C(W)$ dans l'espace des paramètres ?

Q 2.3.3 Dessiner le vecteur $\nabla_w C(w_0)$. A quoi correspond ce vecteur géométriquement ?

Exercice 3 – Régression logistique

Q 3.1 Rappeler le principe de la régression logistique : quelle est son but ? Par quoi est-elle paramétrée ? Quelle est l'expression de $p(y|x)$? Quelles valeurs sont choisies généralement pour \mathcal{Y} ? (rappel : fonction logistique : $f(x) = \frac{1}{1+e^{-x}}$). Que vaut $\log\left(\frac{p(y|x)}{(1-p(y|x))}\right)$?

Q 3.2 Pour une dimension x_i , quelle est l'influence de sa valeur pour $p(y|x)$ dans le cas binaire ? Dans

le cas réel? Quelle est la limite de la régression logistique?

Q 3.3 Soit W les paramètres recherchés. Quelle est l'expression de la vraisemblance conditionnelle de W par rapport à un exemple (x, y) ? La log-vraisemblance? Et dans le cas d'un ensemble d'exemple \mathcal{D} ?

Q 3.4 Proposer un algorithme pour résoudre le problème de la régression logistique.

Exercice 4 – Optimisation d'un modèle gaussien par descente de gradient

Nous disposons ici d'un jeu de données non-étiquetées : $\mathcal{D} = \{\mathbf{x}_i\}_{i=1,\dots,N}$, $\mathbf{x}_i \in \mathbb{R}^d$.

Nous souhaitons apprendre en mode non supervisé un modèle gaussien correspondant aux données de \mathcal{D} . Le modèle gaussien est défini par un ensemble de paramètres $\{\mu, \Sigma\}$

Q 4.1 Exprimez la log-vraisemblance en supposant les exemples de \mathcal{D} statistiquement indépendants.

Q 4.2 Solution analytique

Q 4.2.1 Que vérifie la solution W^* du maximum de vraisemblance?

Q 4.2.2 Montrez que la solution W^* du maximum de vraisemblance correspond à la moyenne et la covariance empirique des données \mathcal{D} dans le cas où Σ est une matrice diagonale.

Q 4.3 Méthode de gradient

Q 4.3.1 Déterminez le gradient de la vraisemblance en un point W_0 .

Q 4.3.2 Ecrire deux algorithmes de gradient batch et stochastique permettant d'apprendre une loi gaussienne à partir de \mathcal{D} .