


TP : Discrimination linéaire

1 Chargement des données et pré-traitement

- Télécharger le fichier “digits.mat”.
- Charger ce fichier sous matlab en utilisant la fonction `load`. Le fichier contient les matrices suivantes :
 - \mathbf{x} et \mathbf{xt} : matrices de données contenant respectivement $n = 3000$ et $nt = 1500$ exemples d’images manuscrites. Chaque ligne de ces matrices correspond à une image stockée sous la forme d’un vecteur transposé.
 - \mathbf{y} et \mathbf{yt} : étiquettes des images décrites dans les matrices précédentes. Ce sont des vecteurs qui contiennent la classe (1, 7, 8) de chaque image de \mathbf{x} et \mathbf{xt} .
- Utiliser la fonction `reshape` pour extraire quelques images de taille 28×28 pour chaque classe. Les visualiser avec la fonction `imagesc`.
- Centrer et normaliser les données d’apprentissage \mathbf{x} et de test \mathbf{xt} . Faire attention aux variables ayant un écart type nul.

2 Présentation de la LDA avec deux classes



L’Analyse Linéaire Discriminante (ou Linear Discriminant Analysis en anglais) est une méthode simple de discrimination basée sur une modélisation probabiliste des données. On veut classifier des exemples (vecteurs) $\mathbf{x} \in \mathbb{R}^d$ qui peuvent appartenir à la classe positive $+$ ou à la classe négative $-$ (discrimination binaire). On suppose pour cela que les exemples sont des réalisations de lois normales multidimensionnelles $\mathcal{N}(\mu_+, \Sigma)$ pour la classe positive de probabilité p_+ et $\mathcal{N}(\mu_-, \Sigma)$ pour la classe négative de probabilité p_- telle que $p_+ + p_- = 1$.

En calculant la vraisemblance pour un exemple \mathbf{x} pour chaque classe $\{-1, 1\}$ on se rend compte que la prédiction de la classe peut être faite en prenant le signe d’une fonction linéaire de la forme

$$f(\mathbf{x}) = \mathbf{x}^T \mathbf{w} + b \quad (1)$$

avec $\mathbf{w} \in \mathbb{R}^d$ et b les coefficients du classifieur de valeur

$$\mathbf{w} = \Sigma^{-1}(\mu_+ - \mu_-) \quad (2)$$

$$b = -\mathbf{w}^t(\mu_+ + \mu_-)/2 + \log(p_+) - \log(p_-) \quad (3)$$

Une variante de la LDA visant à promouvoir une meilleure robustesse consiste à remplacer l'inverse de la matrice de covariance Σ^{-1} par l'inverse $(\Sigma + \lambda \mathbf{I})^{-1}$ où λ est un paramètre de régularisation qui assure que la matrice est inversible et \mathbf{I} est la matrice identité. Cette méthode appelée LDA régularisée est préférée lorsque le nombre d'exemples d'apprentissage est limité ou lorsque le nombre de variables est important ($d > n$).

3 Discrimination binaire

- Créer un problème de classification binaire à partir des trois classes. Vous pourrez par exemple choisir de classer la classe 8 contre 1 et 7. Stocker les étiquettes binaires $(-1, 1)$ dans les vecteurs \mathbf{y}_b et \mathbf{y}_{tb} .
- Estimer les probabilités p_+ et p_- à partir des données d'apprentissage.
- Estimer les moyennes μ_- et μ_+ à partir des données d'apprentissage.
- Centrer les exemples de chaque classe et estimer la matrice de covariance Σ (fonction `cov`).
- En déduire les paramètres du classifieur \mathbf{w} et b . Que se passe-t-il si on ne régularise pas ($\lambda = 0$) ?
- Prédire la classe sur les données d'apprentissage et de test. Calculer le taux de bonne reconnaissance, c'est-à-dire la proportion d'exemples bien classés pour chaque jeu de données.
- Interpréter les résultats.
- Quel effet a la régularisation sur les performances sur les données d'apprentissage et de test ?
- Visualiser quelques exemples mal classés sous la forme d'image, conclusions.
- Visualiser le classifieur \mathbf{w} sous la forme d'une image, interpréter.

- Refaire les étapes précédentes pour la détection de 1 contre 7 et 8 et 7 contre 1 et 8. Quelles sont les différences de performance ? À quoi sont-elles dues ?

4 Régression logistique

- Coder l'algorithme de descente de gradient pour la régression logistique régularisée.
- Faire varier les paramètre de l'algorithme d'optimisation pour en voir l'impact sur l'évolution du coût.
- Comparer les performances de classification (taux de bonne classification) entre les 3 méthodes de classification (Bayésienne gaussienne, moindre carrés et régression logistique).
- Calculer le nombre de paramètres nécessaire à estimer pour chaque méthode. En déduire quelles sont les méthodes les moins sensibles au sur-apprentissage.

5 Discrimination multiclasse

- Pour effectuer une discrimination multiclasse, une approche commune est de faire ce qui s'appelle du « un contre tous ».
- Pour cela on estime 1 classifieur binaire par classe en prenant tous les exemples des autres classes comme étant négatifs (voir section précédente).

-
- Les scores de prédiction pour chaque classe sont calculés pour chaque exemple.
 - La prédiction finale consiste à choisir la classe qui a le score le plus important.
 - Utiliser la méthode « un contre tous » sur les données d'apprentissage et de test.
 - Calculer les performances et discuter les résultats.