

TME 4 - SVM

1 Introduction : Module scikit-learn

Le module scikit-learn (`sklearn` : <http://scikit-learn.org/stable/documentation.html>) est le principal module d'apprentissage statistique de python. Le sous-module `sklearn.linear_model` propose en particulier une implémentation du perceptron, `sklearn.neighbors` une implémentation des k -nn, `sklearn.tree` des arbres de décision. Explorer rapidement ses implémentations, comparer par exemple pour le perceptron les résultats de vos tmes précédents avec les implémentations de `sklearn`. Vérifier bien d'avoir la dernière version installée ! sinon exécuter `pip install -U sklearn -user`

2 Linéaire pénalisé - régularisation de Tikhonov

A faire seulement si vous êtes bien avancé, sinon passer à la section suivante

En reprenant le code du perceptron, changer le coût afin d'intégrer une pénalité sur le vecteur poids :

$$L(\mathbf{w}) = \frac{1}{N} \sum_i \max(0, \alpha - y^i \langle \mathbf{w}, \mathbf{x}^i \rangle) + \lambda \|\mathbf{w}\|^2$$

. Tester sur MNIST et comparer les résultats. Quelle différence avec un modèle SVM linéaire ?

3 SVM et *Grid Search*

Le module `sklearn.svm` propose une implémentation des SVMs. Sur les jeux de données des précédents TMEs (2d artificiels et reconnaissance de chiffres), explorer plusieurs noyaux (linéaire, gaussien, polynomial) et plusieurs paramétrages des noyaux. Vous étudier en particulier les frontières de décisions et les vecteurs supports - les points dont les coefficients sont non nuls. Comment évolue le nombre de ces derniers en fonction du noyau et de son paramétrage ? Est-ce normal ? Que retrouvez vous dans le cas linéaire ?

Afin de trouver les meilleurs paramètres, on opère par validation croisée sur une grille des paramètres (grid search). Pour les différents noyaux et différents nombre d'exemples d'apprentissage, opérer un grid search afin de trouver les paramètres optimaux. Tracer les courbes d'erreurs en apprentissage et en test. Les résultats sont-ils cohérents ?

Afin de visualiser les frontières de décisions en 2D, vous pouvez utiliser ce bout de code :

```
svm = sklearn.svm.SVC(probability = True, ...)
...
def plot_frontiere_proba(data, f, step=20):
    grid, x, y = make_grid(data=data, step=step)
    plt.contourf(x, y, f(grid).reshape(x.shape), 255)

plot_frontiere_proba(data, lambda x: svm.predict_proba(x)[: , 0], step=50)
```

Apprentissage multi-classe

Soit Y un ensemble de k classes y_1, y_2, \dots, y_k . Deux méthodes courantes permettent de traiter des cas multi-classes à partir de classifieurs binaires :

- One-versus-one : on apprend $k(k-1)/2$ classifieurs permettant de départager tout couple de classes y_i, y_j ; la classification se fait en comptant le nombre de vote pour chaque classes.
- One-versus-all : k classifieurs sont appris correspondant à la séparation de chaque classe y_i de l'ensemble des classes $Y/\{y_i\}$. La classification se fait en considérant le classifieur qui obtient le meilleur score.

Tester ses deux méthodes sur la reconnaissance de chiffres.

String Kernel

Le string kernel est un noyau défini sur les mots Σ^* d'un alphabet Σ . Pour un mot s , on dénote $|s|$ la longueur du mot : $s = s_1, s_2, \dots, s_{|s|}$, $s[i : j]$ le sous-mot s_i, \dots, s_j de s . On dit que u est une sous-séquence de s s'il existe une suite d'indices $\mathbf{i} = (i_1, \dots, l_{|u|})$ avec $1 \leq i_1 < i_2 < \dots < i_{|u|} \leq |s|$ tels que $u_j = s_{i_j}$ pour $j = 1, \dots, |u|$, ce que l'on notera $u = s[\mathbf{i}]$. La longueur $l(\mathbf{i})$ de la sous-séquence dans s est $i_{|u|} - i_1 + 1$.

La projection utilisée est l'ensemble des coordonnées $\{\phi_u(s) = \sum_{\mathbf{i}:u=s[\mathbf{i}]} \lambda^{l(\mathbf{i})}\}$ $u \in \Sigma^*$ avec $\lambda \leq 1$.

Ainsi on peut définir le noyau $K_n(s, t) = \sum_{u \in \Sigma^n} \langle \phi_u(s), \phi_u(t) \rangle = \sum_{u \in \Sigma^n} \sum_{\mathbf{i}:u=s[\mathbf{i}]} \sum_{\mathbf{j}:u=t[\mathbf{j}]} \lambda^{l(\mathbf{i})+l(\mathbf{j})}$. Programmer un string kernel, visualiser la matrice de similarité sur des exemples de textes de différents auteurs, puis tester l'apprentissage.