

Méthodes d'ensemble: Boosting, Bagging, Random Forest

Résumé

Nous explorons dans cette séance les classifieurs construits à partir d'autres classifieurs *plus rudimentaires*.

- La première partie du TP consiste à essayer de mieux cerner le comportement de l'algorithme de boosting grâce à une expérience simulée simple, mais pour laquelle tout est reprogrammé à la main (le code est fourni).
- Ensuite, on expérimente les méthodes vues en cours sur le jeu de données simulées pour lequel on connaît la frontière de Bayes, afin de pouvoir observer leur efficacité visuellement.
- Enfin, on expérimente sur données réelles dans le but de mettre en œuvre les techniques désormais maîtrisées.

1 Comment marche le boosting ?

Récupérer à l'adresse

<https://www.math.univ-toulouse.fr/~agarivie/?q=node/178>

le fichier R intitulé TEST_BOOSTING.R (le lien est appelé "Boosting experiments with R").

Il s'agit de comprendre :

- quel est l'objectif de ce code,
- comment il fonctionne (dans le détail),
- en quoi il permet de visualiser comment le boosting fonctionne,
- comment l'adapter à d'autres classifieurs faibles.

On cherchera en particulier à voir comment l'agrégation permet de s'affranchir des contraintes géométriques des classifieurs faibles, mais aussi comment le sur-apprentissage finit par apparaître.

2 Expérimentation sur données simulées

Sur les mêmes données simulées *matchmaker* que dans les séances précédentes, expérimenter la performance

- du boosting (en boostant les classifieurs de votre choix),
- de Random Forest.

Dans les deux cas, on essayera de visualiser la règle de classification obtenue et de la comparer à la règle de Bayes.

Quels sont les avantages et les inconvénients de ces deux méthodes ?

3 Expérimentations sur données réelles

Comparer l'efficacité de toutes les méthodes de classification supervisée vues jusque là sur le jeu de données *IRIS* présenté précédemment.

Mettre en œuvre une validation croisée 5-fold pour le choix des paramètres.

Donner pour chaque méthode un intervalle de confiance pour la probabilité de mal classifier.

Si le travail est terminé, recommencer avec un jeu de données de votre choix tiré d'UCI, comportant au moins 10000 exemples de chaque classe.