

Arbres de classification / régression + Boosting.

I. Décisions par arbres (Et régression)

Contexte: Trouver \hat{f} tel que \hat{f} rend petite l'erreur empirique

$$\hat{M}(\hat{f}) = \frac{1}{n} \sum_{i=1}^n P(y_i, \hat{f}(x_i))$$



- Classification: $P(y, \hat{f}) = \frac{1}{\mathbb{R}_-} \mathbb{1}_{(y \neq \hat{f})}$ $y \in \{-1, 1\}$

- Régression: $P(y, \hat{f}) = (y - \hat{f})^2$

💡 Chercher \hat{f} sous la forme d'un "algorithme" se représentant

sur un arbre.

Exemple $x = (x^{(1)}, x^{(2)}) \in [0, 1]^2$, $y \in \{-1, 1\}$



Cet arbre est-il unique?

(2)

Avantage principal: Interprétabilité!

Formalisation du problème:

• $x = (x^{(1)}, \dots, x^{(d)})$ où $x^{(1)}, \dots, x^{(d)}$ sont des variables

• $y \in \{1, \dots, k\}$ pour un problème de ~~régression~~ ^{classification} à k classes explicatives.
• $y \in \mathbb{R}^d$ pour un problème de régression.

définition: Une fonction f se représente sous la forme d'un arbre si $f(x)$ peut être calculé avec un graphe de calcul représentable sous un arbre binaire.

- Chaque nœud interne a exactement deux fils.
- Le critère qui détermine si on doit partir des fils droit ou gauche porte sur une ~~de~~ variable explicative unique.
- Chaque feuille encode une valeur de y .

Remarque: Le premier nœud est appelé la racine.

(3)

Définition: Une division pour un nœud est dite admissible si aucun des fils qu'elle engendre n'est \emptyset .

↳ On élimine les divisions triviales.

II. Entraînement : Chaîne des divisions

Il reste à expliquer :

- Comment ~~on choisit~~ choisir de bonnes divisions
- Qui fait dans le cas d'une feuille.
- Expliquer quand on doit s'arrêter ou créer une feuille.

Quand s'arrêter :

Un nœud devient une feuille si :

- Il est homogène (tous les y s des x s concernés par le nœud sont les mêmes)
- (ou) Si le nombre de (x, y) s concernés par ce nœud est trop faible (hyperparamètre)
- (ou) Si le nœud est trop profond (hyperparamètre).

Qui faire en cas de feuille

(9)

• En régression: Prédire la moyenne empirique des y s concernés par la feuille

• En classification: Prédire la classe majoritaire par mis les y s concernés par la feuille.

Comment séparer un nœud en deux fils:

Soit D (par "discrepancy") une ρ mesure de non-uniformité.

Pour une variable explicative J ,

$D(\{g_1, \dots, g_n\})$ mesure à quel point les points sont différents.

Alors, pour un nœud N , l'algorithme cherche à ~~se~~ décomposer N sous forme de deux fils L et R .

$(F_{\text{gauche}}, F_{\text{droit}})$ e argmin
 (F'_y, F'_d)
 $\neq \emptyset \neq \emptyset$

$$D(F'_y) + D(F'_d)$$

Essayer de maximiser la cohésion au sein de chaque fils.

III. Mesures de ~~tests~~ non-uniformité

(5)

1) Pour la ~~classification~~ régression

Pour la ~~classification~~ régression, on utilise la variance empirique

$$D(y_1, \dots, y_n) = \sum_{i=1}^n (y_i - \bar{y})^2$$

$$\text{ou } \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

2) Pour la classification

Pour la classification, on construit (p_1, \dots, p_b) le vecteur des probabilités empiriques des classes au nœud x

Il existe alors deux mesures de non-uniformité (au choix)

Entropie $D = -\ln \sum_i p_i \log(p_i)$ conv: $0 \times \log(0) = 0$

\Rightarrow maximale pour $(p_1, \dots, p_b) = (\frac{1}{b}, \dots, \frac{1}{b})$

\Rightarrow minimale si $\exists i$ t.q. $p_i = 1$.

Mesure la quantité d'information.

Coefficient de Gini:

(6)

$$D = |X| \sum_{i=1}^p p_i (1-p_i)$$

IV Boosting - Random Forests

💡 L'idée générale du boosting est qu'il peut être plus intéressant de combiner des estimateurs aux performances modestes plutôt que d'essayer d'en construire un unique.

1) Bagging

L'idée générale du bagging est de

1) Pour b allant de 1 à B

- Sampler avec remplacement un sous-jeu de données.
- Entraîner \hat{f}_b sur ce sous-jeu de données.

2) Combier $\{\hat{f}_1, \dots, \hat{f}_b\}$ en un estimateur \hat{f}^n

- En faisant la moyenne empirique pour de la régression.
- En ~~pas~~ retournant la classe majoritaire pour de la classification.

2) Random Forests

L'algorithme de Random Forest est le résultat de la méthode de bagging appliquée aux arbres de classification et de régression.

Exercice Quel est la prédiction aux points $(x^{(1)}, x^{(2)}) = (0,2; 0,4)$

pour de la classification si les arbres de la

$(0,8; 0,3)$

$(0,5; 0,5)$

Forêt est

