


8-5-2025

Regression Trees


Decision Tree



Linear Regression

$$f(x) = b_0 + b_1 x_1 + \dots + b_p x_p$$

1)
$$f(x) = \sum_{i=1}^n c_i \cdot 1(x \in R_i)$$



$$y \approx b_0 + b_1 x$$

$$RSS \ll$$

2) Τα δέντρα έχουν πιο εύκολη ερμηνεία των προβλεπτικών αναρίων

3) Αν υπάρχουν πολλοί μεταβλητές $x_1, \dots, x_p$

με regression: $y = b_0 + b_1 x_1 + \dots + b_k x_k \quad (k \leq p)$


$\exists$ τρόποι να αξιοποιηθεί η
σημαντικότητα μιας μεταβλητής

Αυτό είναι όμοιο στο decision tree

4) Γενικά ένα "μεγάλο" decision tree έχει μεγάλο
variance.

ENERGIES


Terminologia: model ensemble.



Η εφαρμογή εδώ

- 1) Bagging
- 2) Random Forests
- 3) Boosting

1) Bagging



Es sei $V(\hat{x}_n) = \text{Var} \hat{f}(x_n)$

$$\text{An } \bar{f}_N(x_0) = \frac{1}{N} \sum_{i=1}^N \hat{f}_i(x_0) \Rightarrow E[\bar{f}_N(x_0)] = E[f(x_0)]$$

$$\text{Var}\left[\bar{f}_N(x_0)\right] = \frac{1}{N} V(x_0)$$

An έχουμε μόνο ένα training set
μεγεθους n ("training n ")

κ' πάρουμε N bootstrap δείγματα
από αυτό

1) κάθε bootstrap set iid ανι εμπειρική
κατανομή των δειγμάτων

2) Η εμπειρική κατανομή των δειγμάτων $\approx$
πραγματική κατανομή των (X, Y)
όταν n μεγάλο

Bagging Algorithm

1) Bootstrap samples $b = 1, \dots, B$
από training set


2) Dec. tree $\in$ κάθε $b \rightarrow \hat{f}_b(x)$

3) $\hat{f}(x) = \frac{1}{B} \sum_{b=1}^B \hat{f}_b(x)$

Variance importance factors (VIF) Σ μεταβλητή X_1

Σε κάθε δείγμα $b = 1, \dots, B$

υπολογίζουμε τη συνολική πίεση του RSS
που προκύπτει από αυτή τη μεταβλητή X_1 .



$(VIF)_{X_1}$ = συνολική πίεση $\Delta(RSS)$ εφ' όλης της X_1
(μέσος όρος σε $b = 1, \dots, B$)

2) Τυχαία Δείγμα

Εάν οι n X_i είναι από ομογενή
Τότε θα υπάρξει μια πληθώρα bootstrap samples
και τα $\hat{f}_1, \dots, \hat{f}_b$ θα έχουν
δυνατά μικρότερο

Εάν X_1, X_2 i.i.d. offa $\text{Cov}(X_1, X_2) \neq 0$

$$\text{Var}\left(\frac{X_1 + X_2}{2}\right) \neq \frac{1}{2} \text{Var}(X_1)$$

$$\text{Var}(X_1 + X_2) = 2 \text{Var}(X_1) + 2 \text{Cov}(X_1, X_2)$$

$$\text{Var}\left(\frac{X_1 + X_2}{2}\right) = \frac{1}{2} \text{Var}(X_1) + \frac{1}{2} \text{Cov}(X_1, X_2)$$