Potatura

Problema 1: Come effettuare la potatura ?

Problema 2: Quando fermarsi con la potatura (o alternativamente con l'apprendimento) ?

Quando Fermarsi...

Problema 1: Come effettuare la potatura ?

Problema 2: Quando fermarsi con la potatura (o alternativamente con l'apprendimento) ?

Consideriamo il Problema 2.

Le principali "soluzioni" sono:

1. Valutare le prestazione sull'insieme di apprendimento (usando un test statistico);
2. Valutare le prestazioni su un insieme (separato) di validazione;
3. Usare un principio di minimizzazione della lunghezza di descrizione (MDL)

$$\min_{\text{Tree}} \left[size(\text{Tree}) + size(errori(\text{Tree})) \right]$$

In ogni caso è difficile pervenire ad una soluzione ottima...

Usando l'insieme di validazione

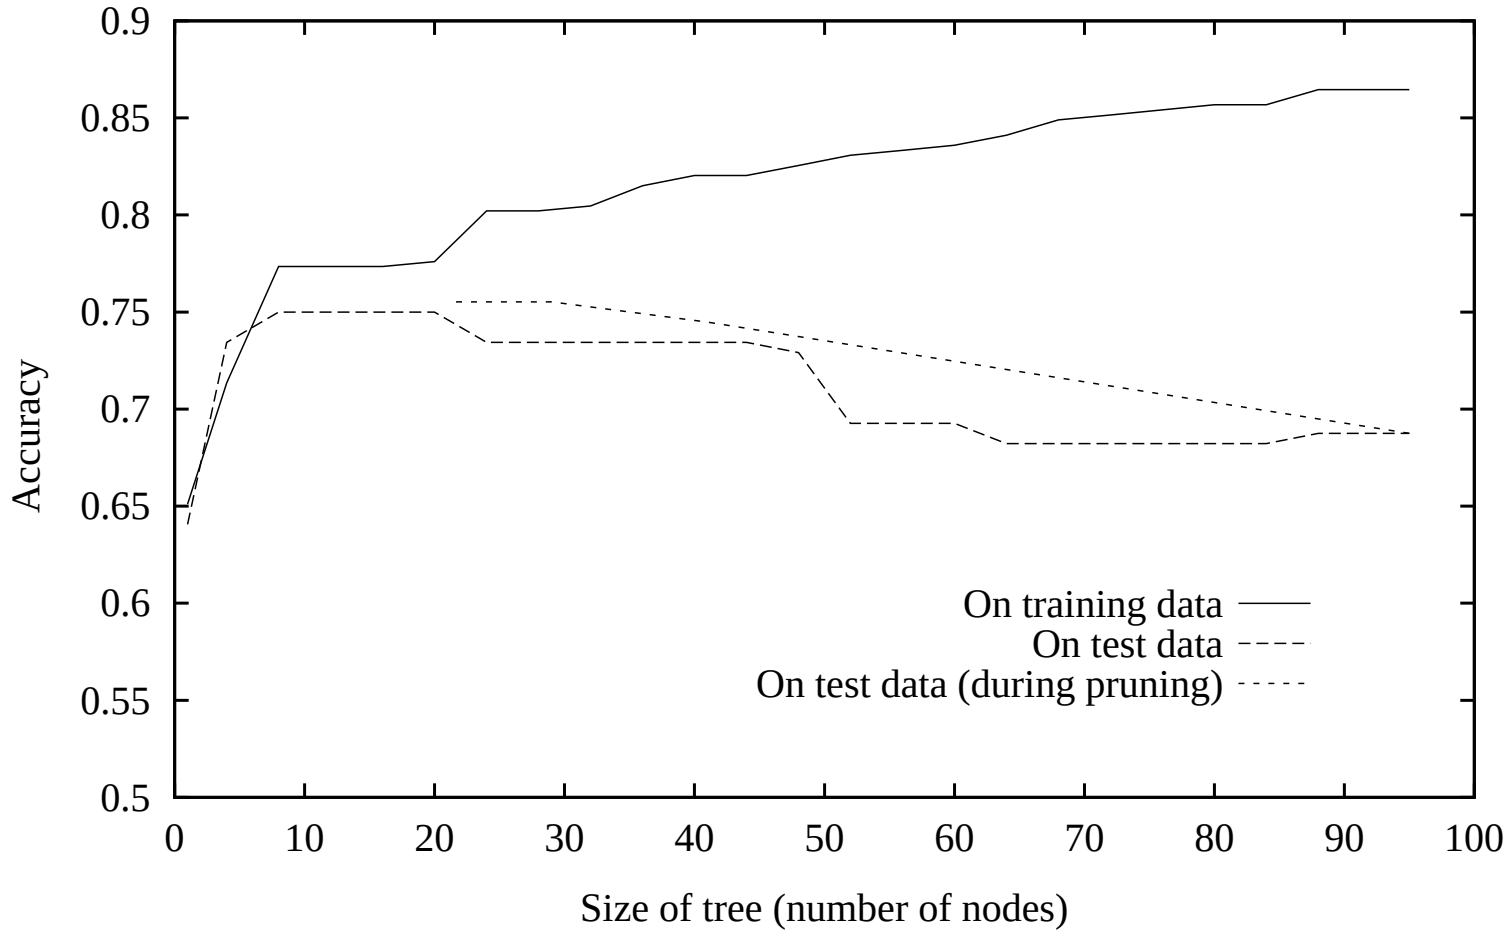

Come Potare...

Problema 1: Come effettuare la potatura ? Le principali "soluzioni" sono:

1. Reduced Error Pruning
   - Dividere Tr in Tr' e Vs (insieme di validazione);
   - Ripetere fino a quando le prestazioni peggiorano
   (a) per ogni nodo (interno) n valutare l'impatto su Vs avendo potato il nodo (e i suoi discendenti);
   (b) effettuare la potatura che porta alle prestazioni migliori su Vs;

   (potatura: al sotto-albero radicato in n si sostituisce una foglia con etichetta uguale alla classe più frequente nell'insieme degli esempi associati al nodo n)
2. Rule-Post Pruning

Rule-Post Pruning

L'idea di base è quella di trasformare un albero di decisione in un insieme di regole, e poi effettuare la potatura delle regole:

1. Si genera una regola R_i per ogni cammino $path(r, f_i)$ dalla radice r alla foglia i-esima f_i; R_i sarà nella forma

   IF $\underbrace{(Attr_{i_1} = v_{i_1}) \wedge (Attr_{i_2} = v_{i_2}) \wedge \cdots \wedge (Attr_{i_k} = v_{i_k})}_{precondizioni}$ THEN $label_{f_i}$

2. Si effettua la potatura indipendentemente su ogni regola R_i:
   - si stimano le prestazioni ottenute utilizzando SOLO R_i come classifi catore;
   - si rimuovono le precondizioni (una o più) che conducono ad un aumento della stima delle prestazioni usando un approccio greedy;
3. Si ordinano le R_i potate per ordine decrescente di prestazione (evita conflitti); eventualmente, aggiunge come classifi cazione di default la classe più frequente;

Classifi care una nuova istanza

La classificazione di una nuova istanza da parte delle regole ordinate avviene seguendo l’ordine stabilito per le regole:

- la prima regola la cui precondizione è soddisfatta dalla istanza è usata per generare la classificazione
- se nessuna regola ha le condizioni soddisfatte, si utilizza la regola di default per classificare l’istanza (cioè si ritorna la classe più frequente nell‘insieme di apprendimento);

Considerazioni

Alcune considerazioni sul Rule-Post Pruning:

- la stima delle prestazioni necessaria per effettuare la potatura può essere fatta sia usando un insieme di validazione che utilizzando un test statistico sui dati di apprendimento;
- la trasformazione Albero $\rightarrow$ Regole permette di generare regole dove si possono considerare contesti per un nodo che non necessariamente contengono i suoi nodi avi (e in particolare la radice);
- di solito le regole sono più semplici da comprendere per un umano;

In genere il Rule-Post Pruning riesce a migliorare le prestazioni dell'albero di decisione di partenza e si comporta meglio del Reduced-Error Pruning