

Coding e Big Data

2024-2025

Vincenzo Nardelli



vincenzo.nardelli@unicatt.it

Cos'è un Albero di Classificazione

- ▶ Un albero di classificazione è un modello di apprendimento automatico usato per classificare osservazioni in categorie (classi).
- ▶ Costruisce una serie di domande (split) su variabili indipendenti per predire una variabile target.
- ▶ Ogni nodo rappresenta una domanda, ogni ramo una risposta, e ogni foglia (nodo terminale) una previsione di classe.

Differenza con Algoritmo Deterministico

- ▶ Un algoritmo deterministico produce sempre lo stesso output per un dato input (es. una funzione matematica).
- ▶ Gli alberi di classificazione non sono deterministici: le divisioni (split) possono cambiare a seconda del dataset, del campionamento e di altri fattori.
- ▶ Gli alberi di classificazione si basano su criteri probabilistici e la loro struttura può cambiare con un nuovo campione di dati.

Deviance: Definizione e Formula

- ▶ La deviance misura l'eterogeneità dei dati in un nodo dell'albero di classificazione. Una deviance più bassa indica un nodo più omogeneo rispetto alla variabile target.
- ▶ Formula della deviance (classificazione binaria):

$$\text{Deviance} = -2 \sum_{i=1}^n (y_i \log(p) + (1 - y_i) \log(1 - p))$$

Dove:

- ▶ y_i è la classe dell'osservazione (1 per la classe positiva, 0 per la negativa),
- ▶ p è la probabilità stimata di appartenere alla classe positiva,
- ▶ n è il numero di osservazioni.

Gradi di Libertà

- ▶ I gradi di libertà rappresentano il numero di valori indipendenti che possono variare in un'analisi statistica, dato un certo numero di vincoli.
- ▶ Nel contesto della deviance residua di un modello, i gradi di libertà si calcolano come:

$$\text{Gradi di libertà} = n - p$$

dove:

- ▶ n è il numero totale di osservazioni,
 - ▶ p è il numero di parametri stimati (o nodi terminali nell'albero di classificazione).
- ▶ Un numero maggiore di gradi di libertà indica più libertà nell'adattamento del modello ai dati.

Esempio di Riduzione della Deviance con uno Split

- ▶ Consideriamo un nodo con 100 osservazioni, di cui 40 appartengono alla classe "Yes" e 60 alla classe "No".
- ▶ Deviance iniziale del nodo:

$$\text{Deviance} = -2 (40 \cdot \log(0.4) + 60 \cdot \log(0.6)) \approx 91.61$$

Esempio di Riduzione della Deviance con uno Split

- ▶ Consideriamo un nodo con 100 osservazioni, di cui 40 appartengono alla classe "Yes" e 60 alla classe "No".
- ▶ Deviance iniziale del nodo:

$$\text{Deviance} = -2 (40 \cdot \log(0.4) + 60 \cdot \log(0.6)) \approx 91.61$$

- ▶ Effettuiamo uno split in base a una variabile, creando due nuovi nodi:
 - ▶ Nodo 1: 30 osservazioni (10 Yes, 20 No)
Deviance = $-2(10 \cdot \log(0.33) + 20 \cdot \log(0.67)) \approx 31.62$
 - ▶ Nodo 2: 70 osservazioni (30 Yes, 40 No)
Deviance = $-2(30 \cdot \log(0.43) + 40 \cdot \log(0.57)) \approx 51.35$
- ▶ Deviance totale dopo lo split: $31.62 + 51.35 = 82.97$
- ▶ La deviance si è ridotta da 91.61 a 82.97, segnalando un miglioramento nell'omogeneità dei nodi.

Esempio di Output di un Albero di Classificazione

- ▶ Nodo radice: Rappresenta l'intero dataset, con la probabilità per ciascuna classe.
- ▶ Split: Condizione che divide il dataset in due sottoinsiemi.
- ▶ Nodo terminale: Nodo senza ulteriori divisioni, dove si assegna una classe.

Interpretazione Output

1) root 400 541.50 No (0.5900 0.4100)

- Nodo radice con 400 osservazioni, deviance = 541.5. Classe predetta: No (59% No, 41% Yes).

Interpretazione della Deviance

- ▶ La deviance misura l'eterogeneità dei dati nel nodo.
- ▶ La deviance del nodo radice è alta poiché contiene l'intero dataset.
- ▶ La deviance si riduce con ogni split, creando nodi più omogenei.
- ▶ Deviance residua media (1.102) = deviance totale (435.2) / gradi di libertà (395).

Misclassification Error Rate

- ▶ Indica la percentuale di osservazioni classificate in modo errato dal modello.
- ▶ Nell'esempio:
Misclassification error rate = $\frac{105}{400} = 0.2625$ (26.25%).
- ▶ Precisione del modello: 73.75%, con 295 osservazioni classificate correttamente.

Confusion Matrix

- ▶ La matrice di confusione aiuta a valutare le prestazioni del modello:

	No	Yes
No	170	39
Yes	66	125

- ▶ True Positives (Yes predetto correttamente): 125
- ▶ True Negatives (No predetto correttamente): 170
- ▶ False Positives: 66, False Negatives: 39

Conclusioni

- ▶ Gli alberi di classificazione sono modelli interpretabili, che permettono di prevedere la classe di un'osservazione basandosi su variabili esplicative.
- ▶ Il tasso di errore e la deviance sono metriche chiave per valutare l'efficacia del modello.
- ▶ Il modello ha un'accuratezza del 73.75%, con un buon equilibrio tra le classi predette.