

Fundamentos de Árvores de Decisão

Parte I

1. Árvores de Decisão

- De um ponto de vista formal, uma **árvore** é um grafo não-direcionado no qual dois vértices quaisquer se conectam por um único caminho (um grafo acíclico não-direcionado) [Wikipedia, 2019]. Trata-se de uma estrutura de dados de grande importância para a computação em geral e para as áreas de aprendizado de máquina, tomada de decisão e teoria de jogos em particular.
- A árvore possui um nó raiz, do qual parte o processo de decisão. Nesse processo, valores distintos de atributos geram arestas (ramificação) e, quando se chega a um nó folha, ocorre uma atribuição de classe.

- Na Fig. 1, temos um exemplo baseado no conjunto de dados *Titanic*. Nesse conjunto, analisam-se atributos diversos para estimar se uma pessoa sobreviveu ou não.

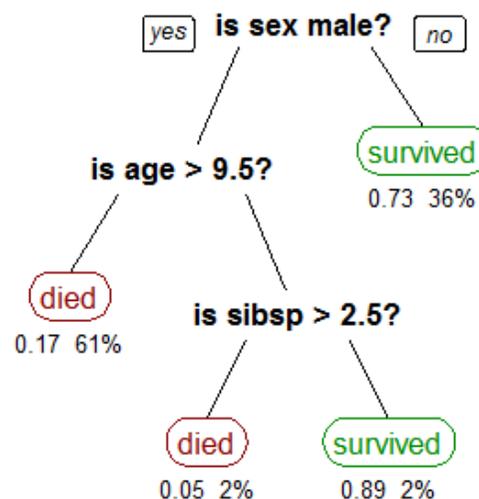


Figura 1. Exemplo de Árvore de Decisão (de [Wikipedia, 2019]).

- Cada atributo, no caso, leva a uma resposta binária (sim / não), e, para cada nó folha, atinge-se uma decisão sobre morte e sobrevivência.

- O uso da árvore para classificar padrões é relativamente direto, mas é preciso dar uma resposta a uma questão crucial: como induzir uma árvore de decisão a partir de dados? Para que possamos dar uma resposta válida a essa questão, seguiremos aproximadamente o curso do artigo seminal de J. R. Quinlan [Quinlan, 1986]. Partiremos, desse modo, de um exemplo dado por ele.

1.1. Exemplo de Árvore de Decisão

- Consideremos um conjunto de dados da forma (\mathbf{x}_i, d_i) , onde \mathbf{x}_i é um vetor de atributos e d_i é um rótulo. Nesse conjunto, cada entrada diz respeito à condição meteorológica de um dia. Os atributos são:
 - **Tempo:** {ensolarado, nublado, chuvoso}
 - **Temperatura:** {dia frio, dia agradável, dia quente}
 - **Umidade:** {alta, normal}
 - **Vento:** {presente, ausente}
- Os rótulos, por sua vez, são apenas “positivo” (P) e “negativo” (N), denotando um problema genérico com duas classes. Um exemplo de manhã poderia ser descrito da seguinte forma: {nublado, dia frio, normal, ausente}.
- O conjunto de treinamento é a base para definir a árvore. Um conjunto que contenha inconsistências, como dois padrões com os mesmos atributos e classes

diferentes, precisará ser reconsiderado (os atributos podem não ser suficientes, por exemplo).

- Um conjunto de treinamento possível é dado na Fig. 2.

| No. | Attributes | | | | Class |
|-----|------------|-------------|----------|-------|-------|
| | Outlook | Temperature | Humidity | Windy | |
| 1 | sunny | hot | high | false | N |
| 2 | sunny | hot | high | true | N |
| 3 | overcast | hot | high | false | P |
| 4 | rain | mild | high | false | P |
| 5 | rain | cool | normal | false | P |
| 6 | rain | cool | normal | true | N |
| 7 | overcast | cool | normal | true | P |
| 8 | sunny | mild | high | false | N |
| 9 | sunny | cool | normal | false | P |
| 10 | rain | mild | normal | false | P |
| 11 | sunny | mild | normal | true | P |
| 12 | overcast | mild | high | true | P |
| 13 | overcast | hot | normal | false | P |
| 14 | rain | mild | high | true | N |

Figura 2. Possível Conjunto de Treinamento (de [Quinlan, 1986]).

- Apenas para mostrar o objetivo de projeto, apresentamos, na Fig. 3, uma árvore que classifica corretamente os exemplos do conjunto de dados.

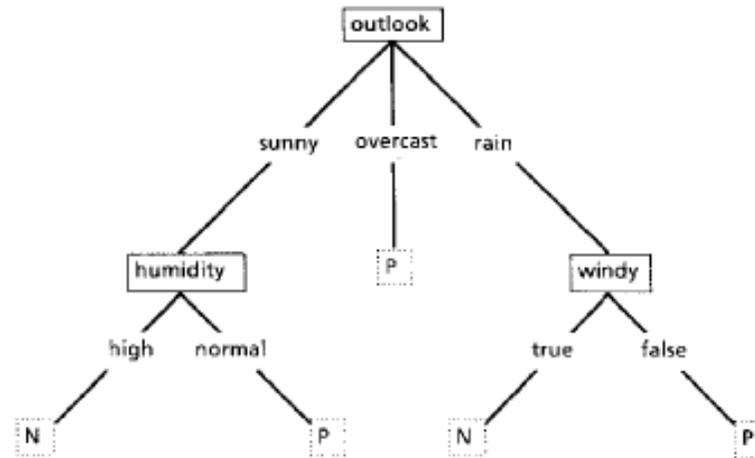


Figura 3. Exemplo de Árvore de Decisão.

- No projeto de uma árvore, é necessário ter em conta o princípio que norteia o aprendizado de máquina em geral: uma estrutura demasiadamente complexa pode significar que o conjunto de treinamento foi “aprendido” de maneira

artificial, ou seja, que houve sobreajuste. Portanto, o princípio da *navalha de Ockham* permeia o projeto de árvores de decisão.

- Para ilustrar esse ponto, apresentamos, na Fig. 4, uma árvore que também explica os dados, mas que é significativamente mais rebuscada. Essa árvore não seria desejável.

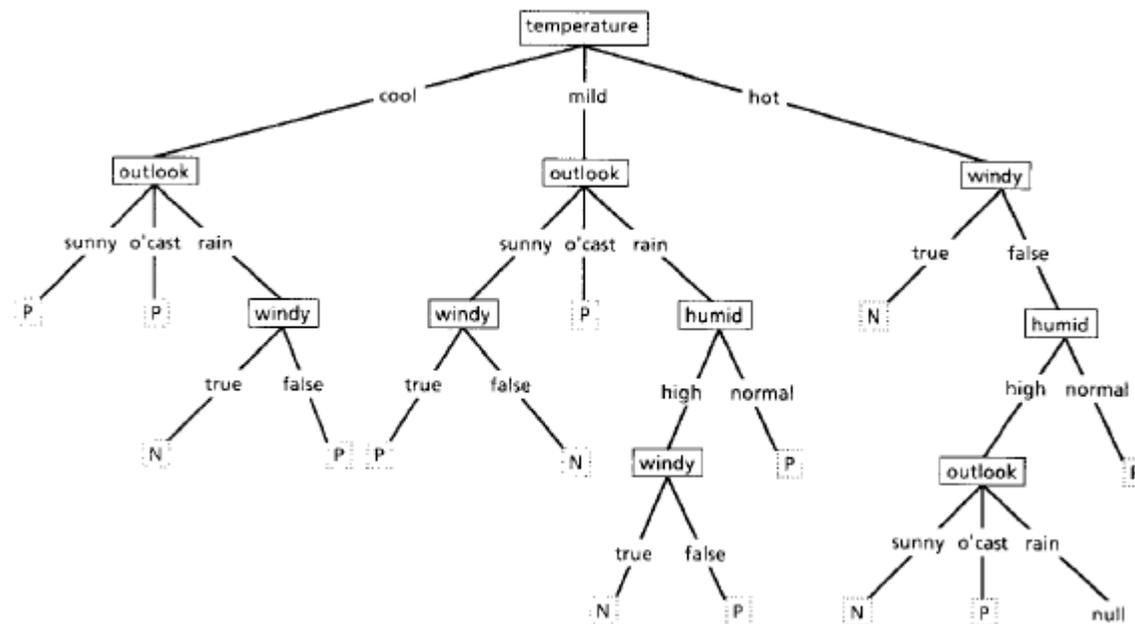


Figura 4. Árvore Complexa (de [Quinlan, 1986]).

1.2. O Processo de Indução (Exemplo do Método ID3)

- Uma primeira abordagem poderia ser construir, de maneira exaustiva, todas as árvores capazes de resolver determinado problema e selecionar a mais simples. Essa abordagem, no entanto, pode ser demasiadamente custosa. O método ID3 (*Iterative Dichotomiser 3*), que discutiremos a seguir, é uma abordagem que não garante a obtenção da menor árvore, mas busca obter árvores apropriadas num período de tempo relativamente curto.
- No método, escolhe-se aleatoriamente um subconjunto dos dados de treinamento (janela) e se constrói uma árvore que o representa. São, então, apresentados os demais padrões do conjunto de treinamento: caso eles também sejam adequadamente classificados, a árvore estará pronta; caso contrário, uma seleção dos dados classificados incorretamente é adicionada à janela e se repete o processo de construção da árvore.

- Vejamos como a árvore é construída a partir de uma coleção de exemplos. Consideremos um teste T que seja feito sobre determinado atributo, com possíveis resultados O_1, O_2, \dots, O_w . Cada padrão no conjunto C terá esses resultados para o teste T , de modo que surge uma partição $\{C_1, \dots, C_w\}$, como mostra a Fig. 5.

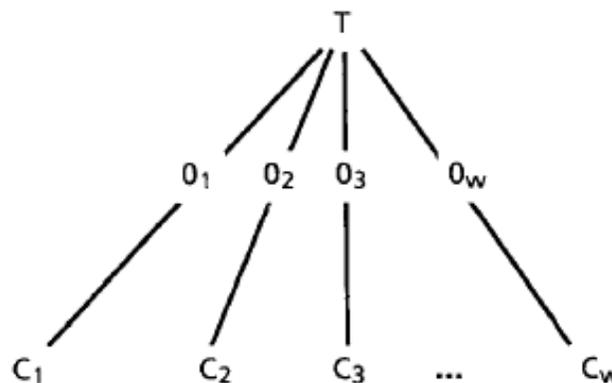


Figura 5. Partição (de [Quinlan, 1986]).

Dois pontos devem ser ressaltados:

- Se cada subconjunto C_i for associado a uma árvore de decisão, ter-se-á uma árvore mais ampla para todos os padrões.
- Se dois ou mais C_i 's são não-vazios, cada C_i será menor que C .

- Como se seleciona o atributo a gerar a partição? A metodologia do ID3 é baseada na teoria da informação. Duas hipóteses são fundamentais (o valor p é o número de amostras da classe P e o valor n é o número de amostras da classe negativa):
 - Qualquer árvore de decisão correta para C classificará objetos na mesma proporção de ocorrência das classes no conjunto de dados. Assim, a probabilidade de um dado ser da classe P é $p/(p + n)$ e a de um dado ser da classe N é $n/(p + n)$.
 - Assim, a árvore de decisão pode ser vista como uma fonte binária de informação com entropia igual a:

$$I(p, n) = -\frac{p}{p + n} \log_2 \left(\frac{p}{p + n} \right) - \frac{n}{p + n} \log_2 \left(\frac{n}{p + n} \right)$$

- Consideremos um atributo A com valores $\{A_1, \dots, A_v\}$ a ser usado junto ao nó raiz. Esse atributo particionará os dados em conjuntos $\{C_1, \dots, C_v\}$. Consideremos que C_i contenha p_i objetos da classe P e n_i objetos da classe N. A informação média $E(A)$ associada ao atributo A como raiz é:

$$E(A) = \sum_{i=1}^v \frac{p_i + n_i}{p + n} I(p_i, n_i)$$

- O ganho de informação obtido pela partição segundo o atributo A é:

$$\text{Ganho}(A) = I(p, n) - E(A)$$

- A ideia seria então maximizar esse ganho de informação e então usar o procedimento recursivamente para os subconjuntos C_1, \dots, C_v . Ou seja, escolhe-se o atributo que gera a primeira ramificação e, então, se repete o processo para construir as subárvores.
- Como exemplo, podemos avaliar os dados da Fig. 2. Há 14 padrões, 9 da classe P e 5 da classe N. A informação (entropia) é:

$$I(p, n) = -\frac{9}{14} \log_2 \left(\frac{9}{14} \right) - \frac{5}{14} \log_2 \left(\frac{5}{14} \right) = 0,940 \text{ bits}$$

- Consideremos agora o atributo “tempo” (“*outlook*”). Cinco padrões tem o valor “ensolarado”, e, destes, dois são classe P e três da N. Assim, $p_1 = 2$, $n_1 = 3$ e $I(p_1, n_1) = 0,971$ bits. Analogamente, $p_2 = 4$, $n_2 = 0$ e $I(p_2, n_2) = 0$. Por fim, $p_3 = 3$, $n_3 = 2$ e $I(p_3, n_3) = 0,971$. Portanto,

$$E(\text{'tempo'}) = \frac{5}{14} I(p_1, n_1) + \frac{4}{14} I(p_2, n_2) + \frac{5}{14} I(p_3, n_3) = 0,694 \text{ bits}$$

- O ganho do atributo é $\text{ganho}(\text{'tempo'}) = 0,940 - E(\text{'tempo'}) = 0,246$ bits. A análise dos atributos ‘temperatura’, ‘umidade’ e ‘vento’ leva a ganhos de, respectivamente, 0,029, 0,151 e 0,048 bits. Dessa forma, escolhe-se o atributo “tempo”. Em seguida, dividem-se os padrões em subconjuntos de acordo com os valores do atributo escolhido e uma árvore de decisão é induzida para cada subconjunto de maneira idêntica. Isso leva exatamente à árvore da Fig. 3.

1.3. Alguns Aspectos

- Há outras métricas que podem ser usadas para definir as partições (além do ganho de informação). Uma possibilidade é usar métricas de distância / divergência, como o índice de Gini [Murthy, 1998].
- Caso haja dados ruidosos, ou seja, dados que não plenamente “consistentes”, passa a ser necessária uma análise estatística mais ampla, incluindo, por exemplo, testes de hipóteses.
- Outro ponto importante é, se for o caso, buscar metodologias para lidar com atributos faltantes.

2. Referências bibliográficas

MURTHY, S. K., “Automatic Construction of Decision Trees from Data: a Multi-Disciplinary Survey”, *Data Mining and Knowledge Discovery*, Vol. 2, No. 4, pp. 345 – 389, 1998.

QUINLAN, J. R., “Induction of Decision Trees”, *Machine Learning*, Vol. 1, pp. 81 – 106, 1986.

WIKIPEDIA, *Artigos Diversos*, 2019.