

3 Aprendizado de máquina - conceitos básicos

Técnicas de aprendizado de máquina são divididas, de maneira geral, em aprendizado supervisionado e não supervisionado. Se antes do processo de aprendizado o indutor recebe um conjunto de exemplos, cada exemplo sendo formado por um conjunto de atributos de entrada e de saída (rótulos), então esse tipo de aprendizado é classificado como aprendizado supervisionado. Aprendizado não supervisionado é realizado quando, para cada exemplo, apenas os atributos de entrada estão disponíveis.

Essas técnicas de aprendizado são utilizadas quando o objetivo é encontrar padrões, tendências ou aglomerados em um conjunto de dados. Estes padrões, tendências e aglomerados são informações que permitem melhor entendimento destes dados. Neste trabalho apenas algoritmos de aprendizado não supervisionado são apresentados. Com o propósito de facilitar o entendimento dos termos utilizados para aprendizado de máquina, é apresentada a seguir uma lista dos conceitos básicos usados em sua maioria ao longo deste documento [Mitchell, 1997, Monard e Baranauskas, 2003a].

- Exemplo: um objeto único do mundo a partir do qual um modelo será aprendido, ou sobre o qual um modelo será usado. Exemplos costumam ser descritos por vetores de características.
- Característica (atributo, variável): uma quantidade descrevendo um exemplo. Um atributo tem um domínio definido pelo seu tipo, que denota os valores que ele pode assumir.
- Vetor de características: uma lista de características que descreve um exemplo.
- Classe: no aprendizado supervisionado, todo exemplo possui pelo menos um atributo especial denominado rótulo ou classe, que descreve o fenômeno de interesse.
- *Corpus* (conjunto de dados ou exemplos): é composto por um número de exemplos com seus respectivos valores de atributos. No aprendizado supervisionado cada exemplo também é associado a uma classe. Usualmente, o conjunto de exemplos é dividido em dois

subconjuntos disjuntos: o conjunto de treinamento, utilizado para o aprendizado do conceito e o conjunto de teste, utilizado para medir o grau de efetividade do conceito aprendido.

- Acurácia (taxa de erro): a taxa de predições corretas (ou incorretas) realizada pelo modelo para um determinado conjunto de dados.
- Falso positivo: dado um classificador para discriminar classes A e B (supondo que A é a classe mais relevante ou positiva), o número de falsos positivos é a quantidade de exemplos da classe B classificados como da classe A. Do mesmo modo, o número de falsos negativos é a quantidade de exemplos da classe A classificados como da classe B.
- Ruído: é a classificação errada do conjunto de dados de entrada.
- *Overfitting* (super-ajustamento): ocorre quando o modelo se especializa nos dados utilizados no seu treinamento, apresentando uma taxa de acurácia baixa para novos dados.
- Função de confiança: método usado para, na comparação entre dois exemplos, calcular a proximidade entre eles. Ex.: distância Euclidiana e distância de edição.
- Algoritmo guloso: é uma técnica de algoritmos para resolver problemas de otimização, sempre realizando a escolha que parece ser a melhor no momento. Sempre é feita uma escolha ótima local, na esperança de que esta escolha leve até a solução ótima global.
- *Outlier*: Valor discrepante dos outros valores do conjunto. Também podemos chamar um item classificado erroneamente por *outlier* quando o erro for significativo.