

4 - KNN AND EVALUATION

Aprendizagem 2024/2025

KNN

- Classificar uma nova observação com base nos k vizinhos mais próximos
- Vizinhos podem ser calculados com base em **distâncias** (queremos o mais perto) ou **semelhanças** (queremos o mais semelhante)

DISTÂNCIAS E SEMELHANÇAS

- **Minkowski**: $d(x_a, x_b) = \sqrt[q]{|x_{a1} - x_{b1}|^q + \dots + |x_{am} - x_{bm}|^q}$
- **Manhattan**: Minkowski com $q = 1$
- **Euclidian**: Minkowski com $q = 2$
- **Chebyshev**: $d(x_a, x_b) = \max(|x_{a1} - x_{b1}|, \dots, |x_{am} - x_{bm}|)$
- **Cosine similarity**: $d(x_a, x_b) = \frac{x_a \cdot x_b}{\|x_a\| \|x_b\|}$

MEDIDAS DE AGREGAÇÃO

- Variáveis **categóricas**: moda, moda pesada
- Variáveis **numéricas**: média, média pesada

ERROS

- **Mean absolute error:** $MAE = \frac{1}{n} \sum |y - y'|$
- **Mean squared error:** $MSE = \frac{1}{n} \sum (y - y')^2$
- **Root mean squared error:** $RMSE = \sqrt{MSE}$

ROC E AUC

- **ROC**: representa a performance de um classificador binário para cada valor de threshold (TPR no eixo do y, FPR no eixo do x)

$$TPR = \frac{TP}{P}, \quad FPR = \frac{FP}{N}$$

- **AUC** (area under curve): representa a probabilidade do modelo distinguir entre as duas classes

$$AUC = 1 \text{ (perfeita)}, \quad AUC = 0.5 \text{ (random)}$$

SUMÁRIO

- Ficha 4