



2

Normalisation



2. Normalisation : pourquoi ?



Mettre sur une même échelle toutes les données quantitatives

Rendre les plages cohérentes entre les variables

Avoir une influence similaire des variables sur les modèles

Conserver les rapports de distance

Améliorer les performances et stabiliser le modèle

2. Normalisation : comment ?



Scaler	Caractéristiques
Min Max Scaler sklearn.preprocessing.MinMaxScaler	Std faible, distrib. non normale, [0,1] Sensible outliers
Standard Scaler sklearn.preprocessing.StandardScaler	Std 1, distrib. Normale centrée en 0 Sensible outliers (Z-Score)
Robust Scaler sklearn.preprocessing.RobustScaler	Std faible, distrib. non gaussienne Insensible outliers
Max Abs Scaler sklearn.preprocessing.MaxAbsScaler	Distrib. Éparse, centrée en 0, [-1,1] Insensible outliers
Power Transformer Scaler sklearn.preprocessing.PowerTransformer	trouve le facteur d'échelle optimal pour stabiliser la variance et minimiser l'asymétrie grâce à l'estimation du maximum de vraisemblance. rendre les données plus gaussiennes.
Quantile Transformer Scaler sklearn.preprocessing.QuantileTransformer	1. Calcule la fonction de distribution cumulative de la variable 2. Il utilise ce cdf pour faire correspondre les valeurs à une distribution normale 3. Établit une correspondance entre les valeurs obtenues et la distribution de sortie souhaitée à l'aide de la fonction quantile associée Distrib. Normale, large dataset Insensible outliers
Unit Vector Scaler sklearn.preprocessing.normalize	Mise à l'échelle se fait en considérant que le vecteur d'élément entier est de longueur unitaire. [0, 1]
Normalizer Scaler sklearn.preprocessing.Normalizer	Normalise selon la norme L1 (manhatan) ou L2 (euclidienne)

$$x_{new} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

$$x_{new} = \frac{x - \mu}{\sigma}$$

$$\frac{x_i - Q_1(x)}{Q_3(x) - Q_1(x)}$$

$$x' = \frac{x}{||x||}$$

$$\sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad \sum_{i=1}^n |x_i - y_i|$$

2. Normalisation : algorithmes ?



Calculer un vecteur de poids

Scoring

Descente de gradient

Logistic Regression

Linear Regression

Réseaux de neurones

Calculer des distances pour déduire le degré de similarité de deux items

Support Vector Machines (SVM)

K-Nearest Neighbors (KNN)

K-Means (clustering...)

Principal Component Analysis (PCA)

INUTILE

Tree-base algorithm :

Gradient Boosted Decision Trees

Regression Tree

Classification Trees

Random Forests

Linear Discriminant Analysis(LDA)

Naive Bayes