

# Rappels Mathématiques et Notations

Machine Learning

Cédric RICHARD

Université Nice Sophia Antipolis

# RECONNAISSANCE DES FORMES

## Objectifs

---

L'objectif de l'analyse de données est de synthétiser, structurer, ..., l'information véhiculée par des données multidimensionnelles :

- ▷  $n$  : nombre d'individus
- ▷  $p$  : nombre de variables

Les méthodes mises en œuvre relèvent essentiellement de l'*algèbre linéaire* et de la *théorie des probabilités*. En effet :

- ▷ les données sont vues comme un nuage de points dans un espace vectoriel
- ▷ La statistique inférentielle permet de fournir des résultats relatifs à une population à partir de mesures statistiques réalisées sur des échantillons.

# VOCABULAIRE

## Individus et variables

---

**Population** : Groupe ou ensemble d'individus que l'on analyse

**Recensement** : Etude de tous les individus d'une population donnée

**Sondage** : Etude d'une partie seulement d'une population appelée échantillon

**Variables** : Ensemble de caractéristiques d'une population

- *quantitatives* : nombres sur lesquels les opérations usuelles ont un sens. Elles peuvent être discrètes ou continues
- *qualitatives* : appartenance à une catégorie donnée. Elles peuvent être nominales, ou ordinales quand les catégories sont ordonnées.

# VOCABULAIRE

## Description de données quantitatives

---

**Variable, individu :** On appelle variable un vecteur  $\boldsymbol{x}$  de taille  $n$ . Chaque coordonnée  $x_i$  correspond à un individu.

**Poids :** Chaque individu a éventuellement un poids  $p_i$ , tel que  $p_1 + \dots + p_n = 1$ . On choisit souvent  $p_i = \frac{1}{n}$ .

**Analyse :** On dispose d'une série d'indicateurs qui ne donne qu'une vue partielle des données : effectif, moyenne, médiane, variance, écart type, minimum, maximum, 1<sup>er</sup> quartile, ...

Ces indicateurs mesurent principalement la tendance centrale et la dispersion. On utilisera surtout la moyenne, la variance et l'écart type.

# GRANDEURS STATISTIQUES DE BASE

## Moyenne arithmétique

---

**Définition 1.** *On appelle moyenne arithmétique, que l'on note  $\bar{x}$ , la quantité suivante*

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

*ou, dans le cas d'une somme pondérée*

$$\bar{x} = \sum_{i=1}^n p_i x_i$$

**Remarque.** La moyenne arithmétique est une mesure de tendance centrale qui dépend de toutes les observations, et est sensible aux valeurs extrêmes.

# GRANDEURS STATISTIQUES DE BASE

## Variance et écart-type

---

**Définition 2.** *La variance de  $x$  est définie par*

$$\sigma_x^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

*ou, dans le cas d'une pondération non-uniforme*

$$\sigma_x^2 = \sum_{i=1}^n p_i (x_i - \bar{x})^2$$

*L'écart type  $\sigma_x$  est la racine-carrée de la variance.*

**Propriété 1.** *La variance satisfait la relation suivante*

$$\sigma_x^2 = \sum_{i=1}^n p_i x_i^2 - \bar{x}^2$$

L'écart-type, qui a la même unité que  $x$ , est une mesure de dispersion.

# GRANDEURS STATISTIQUES DE BASE

Mesure de liaison entre deux variables

---

**Définition 3.** *La covariance observée entre deux variables  $x$  et  $y$  est définie par*

$$\sigma_{xy} = \sum_{i=1}^n p_i (x_i - \bar{x})(y_i - \bar{y})$$

*Le coefficient de corrélation est donné par*

$$r_{xy} = \frac{\sigma_{xy}}{\sigma_x \sigma_y}$$

# GRANDEURS STATISTIQUES DE BASE

## Propriétés du coefficient de corrélation

---

**Propriété 2.** *D'après l'inégalité de Cauchy-Schwartz, on a*

$$-1 \leq r_{xy} \leq 1$$

**Propriété 3.** *Le résultat suivant concerne des variables dites linéairement liées.*

$$|r_{xy}| = 1 \Leftrightarrow ax_i + by_i = c, 1 \leq i \leq n$$

*En particulier, on a  $r_{xx} = 1$ .*

**Remarque.** Si  $r_{xy} = 0$ , les variables sont dites décorrélées. Cela ne signifie pas qu'elles sont indépendantes.

# DESCRIPTION DES DONNÉES

## Notations matricielles

---

**Matrice :** De manière impropre, une matrice à  $p$  lignes et  $n$  colonnes est un tableau rectangulaire de  $mn$  nombres, rangés ligne par ligne.

**Vecteur :** Un vecteur, ligne ou colonne, est une matrice ne comportant qu'une seule ligne ou qu'une seule colonne.

**Transposition :** Echange des lignes et des colonnes d'une matrice. On note  $M^T$  la transposée de  $M$ .

**Exemples :**

$$I = \begin{pmatrix} 1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & 1 \end{pmatrix} \quad \mathbf{1} = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}$$

# DESCRIPTION DES DONNÉES

## Tableau de données

---

Dans toute la suite, pour  $n$  individus et  $p$  variables, on s'intéresse aux tableaux de données définis comme suit

$$\mathbf{X} = (\mathbf{x}^1 \quad \dots \quad \mathbf{x}^p) = \begin{pmatrix} x_1^1 & x_1^2 & \dots & x_1^p \\ x_2^1 & x_2^2 & & \\ & & \ddots & \\ \vdots & & & x_i^j & \vdots \\ & & & & \ddots \\ x_n^1 & & \dots & & x_n^p \end{pmatrix} \quad \mathbf{1} = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}$$

# DESCRIPTION DES DONNÉES

Vecteurs variable et individu

---

**Variable :** Une colonne du tableau de données

$$\mathbf{x}^j = \begin{pmatrix} x_1^j \\ x_2^j \\ \dots \\ x_n^j \end{pmatrix}$$

**Individu :** Une ligne du tableau de données, transposées

$$\mathbf{x}_i = \left( x_i^1 \quad x_i^2 \quad \dots \quad x_i^p \right)^\top$$

# DESCRIPTION DES DONNÉES

## Matrice de poids

---

**Pourquoi :** Elle est nécessaire quand les individus n'ont pas la même importance.

**Comment :** On associe un poids  $p_i$  à chaque individu tel que :

$$p_1 + p_2 + \dots + p_n = 1$$

On regroupe ces poids dans une matrice diagonale de taille  $n$  :

$$D = \begin{pmatrix} p_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & p_n \end{pmatrix}$$

**Cas uniforme :** Tous les individus ont le même poids  $p_i = 1/n$

# PRÉ-TRAITEMENTS

## Individu moyen et tableau centré

---

**Individu moyen :** L'individu moyen est obtenu à partir de la moyenne arithmétique de chaque variable

$$\mathbf{m} = \left( \bar{x}^1 \quad \bar{x}^2 \quad \dots \quad \bar{x}^p \right)^\top$$

avec  $\bar{x}^j = \sum_{i=1}^n p_i x_i^j$ . On peut aussi écrire

$$\mathbf{m} = \mathbf{X}^\top \mathbf{D} \mathbf{1}$$

**Tableau centré :** Il est obtenu en centrant l'ensemble des variables du tableau de données :  $y_i^j = x_i^j - \bar{x}^j$ . Sous forme matricielle, on écrit

$$\mathbf{Y} = \mathbf{X} - \mathbf{1} \mathbf{m}^\top = (\mathbf{I} - \mathbf{1} \mathbf{1}^\top \mathbf{D}) \mathbf{X}$$

# PRÉ-TRAITEMENTS

## Matrice de variance-covariance

---

**Définition :** Il s'agit d'une matrice de dimension  $p$  définie par

$$\Sigma = \begin{pmatrix} \sigma_1^2 & \sigma_{12} & \cdots & \sigma_{1p} \\ \sigma_{21} & \sigma_2^2 & & \\ & & \ddots & \\ \vdots & & & \sigma_i^2 & \vdots \\ & & & & \ddots \\ \sigma_{p1} & \cdots & & & \sigma_p^2 \end{pmatrix}$$

où  $\sigma_{ij}$  est la covariance des variables  $x^i$  et  $x^j$ , et  $\sigma_j^2$  est la variance de  $x^j$ .

**Formulation matricielle :**

$$\Sigma = X^\top DX - mm^\top = Y^\top DY$$

# PRÉ-TRAITEMENTS

## Matrice de corrélation

---

**Définition :** Il s'agit d'une matrice de dimension  $p$  définie par

$$R = \begin{pmatrix} 1 & r_{12} & \cdots & r_{1p} \\ r_{21} & 1 & & \\ & & \ddots & \\ \vdots & & & r_{ij} & \vdots \\ & & & & \ddots \\ r_{p1} & & \cdots & & 1 \end{pmatrix}$$

où  $r_{ij} = \frac{\sigma_{ij}}{\sigma_i \sigma_j}$  est le coefficient de corrélation des variables  $x^i$  et  $x^j$ .

**Formulation matricielle :**

$$R = D_{1/\sigma} \Sigma D_{1/\sigma}$$

où  $D_{1/\sigma}$  est la matrice diagonale de termes diagonaux  $\frac{1}{\sigma_i}$ .

# ANALYSE DES DONNÉES

## Métrie

---

**Motivation :** Il est nécessaire d'introduire une métrie afin de caractériser la topologie du nuage de points.

**Définition :** On appelle distance sur  $E$  une application  $d : E \times E \rightarrow \mathbb{R}^+$  vérifiant les propriétés suivantes

- symétrie :  $\forall x, y \in E, \quad d(x, y) = d(y, x)$
- séparation :  $\forall x, y \in E, \quad d(x, y) = 0 \Leftrightarrow x = y$
- inégalité triangulaire :  $\forall x, y, z \in E, \quad d(x, z) \leq d(x, y) + d(y, z)$

**Exemple :** La distance euclidienne entre 2 points  $\mathbf{u}$  et  $\mathbf{v}$  de  $\mathbb{R}^p$  est définie par

$$d^2(\mathbf{u}, \mathbf{v}) = \sum_{j=1}^p (u_j - v_j)^2 = \|\mathbf{u} - \mathbf{v}\|^2$$

# ANALYSE DES DONNÉES

## Métrie

---

**Matrice définie positive :** Il s'agit d'une matrice symétrique  $\mathbf{M}$  telle que, pour tout  $\mathbf{u}$  non nul, on a  $\mathbf{u}^\top \mathbf{M} \mathbf{u} > 0$ .

**Définition :** Soit  $\mathbf{M}$  une matrice définie positive de dimension  $p$ . La fonction suivante  $d_M : \mathbb{R}^p \times \mathbb{R}^p \rightarrow \mathbb{R}^+$  définit une métrie

$$d_M^2(\mathbf{u}, \mathbf{v}) = \|\mathbf{u} - \mathbf{v}\|_M^2 \quad \text{avec} \quad \|\mathbf{u}\|_M^2 = \sum_{i,j=1}^p m_{ij} u_i u_j$$

Cette distance est appelée distance de Mahalanobis lorsque  $\mathbf{M} = \mathbf{\Sigma}^{-1}$ , où  $\mathbf{\Sigma}$  est la matrice de variance-covariance des données.

**Produit scalaire :** La métrie définie ci-dessus dérive du produit scalaire

$$\langle \mathbf{u}, \mathbf{v} \rangle_M = \sum_{i,j=1}^p m_{ij} u_i v_j$$

On dit que  $\mathbf{u}$  et  $\mathbf{v}$  sont orthogonaux si  $\langle \mathbf{u}, \mathbf{v} \rangle_M = 0$ .

# ANALYSE DES DONNÉES

## Métriques particulières

---

**Métrique euclidienne :** Elle est obtenue pour  $M = I$ .

L'une des difficultés rencontrées avec la métrique euclidienne est qu'elle privilégie les variables les plus dispersées et dépend donc de leur unité de mesure.

**Métrique réduite :** Elle consiste à prendre  $M = D_{1/\sigma^2}$ , où  $D_{1/\sigma^2}$  est la matrice diagonale de termes diagonaux les inverses  $\frac{1}{\sigma_i}$  des variances des variables.

$$D_{1/\sigma^2} = \begin{pmatrix} \frac{1}{\sigma_1^2} & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \frac{1}{\sigma_p^2} \end{pmatrix}$$

# ANALYSE DES DONNÉES

## Inertie

---

**Définition :** L'inertie du nuage de points  $\{\mathbf{x}_1, \dots, \mathbf{x}_n\}$  en un point quelconque  $\mathbf{a}$  est donnée par

$$I_a = \sum_{i=1}^n p_i \|\mathbf{x}_i - \mathbf{a}\|_M^2$$

**Définition :** L'inertie totale du nuage de points  $\{\mathbf{x}_1, \dots, \mathbf{x}_n\}$  est donnée par

$$I_m = \frac{1}{2} \sum_{i,j=1}^n p_i p_j \|\mathbf{x}_i - \mathbf{x}_j\|_M^2$$

# ANALYSE DES DONNÉES

## Inertie

---

Propriété :

$$I_m = \text{Trace}(\Sigma M)$$

Démonstration : On introduit le vecteur moyen  $\mathbf{m}$ , et on déroule le calcul

$$\begin{aligned} I_m &= \frac{1}{2} \sum_{i,j=1}^n p_i p_j \|\mathbf{x}_i - \mathbf{x}_j\|_M^2 \\ &= \frac{1}{2} \sum_{i,j=1}^n p_i p_j \|(\mathbf{x}_i - \mathbf{m}) - (\mathbf{x}_j - \mathbf{m})\|_M^2 \\ &= \underbrace{\sum_{i=1}^n p_i \|\mathbf{x}_i - \mathbf{m}\|_M^2}_{\text{Trace}(\Sigma M)} - \underbrace{\sum_{i,j=1}^n p_i p_j \langle \mathbf{x}_i - \mathbf{m}, \mathbf{x}_j - \mathbf{m} \rangle_M}_0 \\ &= \text{Trace}(\Sigma M) \end{aligned}$$

# ANALYSE DES DONNÉES

## Inertie

---

Métrie euclidienne :

$$I_m = \text{Trace}(\boldsymbol{\Sigma}) = \sum_{i=1}^p \sigma_i^2$$

Métrie réduite :

$$\begin{aligned} I_m &= \text{Trace}(\boldsymbol{\Sigma} \mathbf{D}_{1/\sigma^2}) \\ &= \text{Trace}(\mathbf{D}_{1/\sigma} \boldsymbol{\Sigma} \mathbf{D}_{1/\sigma}) \\ &= \text{Trace}(\mathbf{R}) = p \end{aligned}$$

# ANALYSE DES DONNÉES

## Métrie et tableau de données

---

Utiliser la métrie  $\mathbf{M} = \mathbf{T}^\top \mathbf{T}$  sur le tableau de données  $\mathbf{X}$  est équivalent à travailler avec la métrie euclidienne sur le tableau transformé  $\mathbf{X}\mathbf{T}^\top$ .

**Tableau transformé :** Lorsqu'on travaille sur le tableau transformé comme ci-dessus, il convient d'utiliser la norme euclidienne. En effet,

$$\langle \mathbf{T}\mathbf{x}_i, \mathbf{T}\mathbf{x}_j \rangle = (\mathbf{T}\mathbf{x}_i)^\top (\mathbf{T}\mathbf{x}_j) = \mathbf{x}_i^\top (\mathbf{T}^\top \mathbf{T}) \mathbf{x}_j = \langle \mathbf{x}_i, \mathbf{x}_j \rangle_{\mathbf{M}}$$

**Réciproque :** Pour toute matrice définie positive  $\mathbf{M}$ , il existe une matrice définie positive  $\mathbf{T}$  telle que  $\mathbf{M} = \mathbf{T}^\top \mathbf{T}$ . On notera improprement  $\mathbf{T} = \mathbf{M}^{\frac{1}{2}}$ .

# RAPPELS ÉLÉMENTAIRES D'ALGÈBRE LINÉAIRE

## Valeurs et vecteurs propres

---

**Définition :** Une matrice  $A$  à coefficients dans un corps  $\mathbb{K}$  est diagonalisable sur ce corps  $\mathbb{K}$  s'il existe une matrice inversible  $P$  et une matrice diagonale  $D$  à coefficients dans  $\mathbb{K}$  telles que

$$A = P D P^{-1}$$

Chaque colonne  $p$  de  $P$  est un vecteur propre de  $M$ , c'est à dire qu'il existe  $\lambda$  sur la diagonale de  $D$  tel que

$$A p = \lambda p$$

# RAPPELS ÉLÉMENTAIRES D'ALGÈBRE LINÉAIRE

## Valeurs et vecteurs propres

---

**Propriété :** Toute matrice symétrique réelle est diagonalisable sur  $\mathbb{R}$  par une matrice orthogonale  $P$ , c'est à dire telle que

$$P^{\top} P = I$$

**Propriété :** Toute matrice  $M$ -symétrique réelle ( $A^{\top} M = M A$ ) est diagonalisable sur  $\mathbb{R}$  par une matrice  $M$ -orthogonale  $P$ , c'est à dire telle que

$$P^{\top} M P = I$$

# RAPPELS ÉLÉMENTAIRES D'ALGÈBRE LINÉAIRE

Valeurs et vecteurs propres : cas de la matrice  $\Sigma M$

---

**Valeurs propres :** La matrice  $\Sigma M$  est  $M$ -symétrique. Elle est donc diagonalisable sur  $\mathbb{R}$ . Ses valeurs propres sont positives, et l'on note

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$$

**Vecteurs propres :** Les vecteurs propres de  $\Sigma M$  sont  $M$ -orthogonaux.

**Lien avec l'inertie :** On sait que

$$\text{Trace}(\Sigma M) = \lambda_1 + \lambda_2 + \dots + \lambda_k + \dots + \lambda_p$$

En conservant l'information relative au sous-espace propre  $\{\lambda_1, \dots, \lambda_k\}$ , on conserve l'inertie  $\lambda_1 + \lambda_2 + \dots + \lambda_k$ .