

# M2 Statistics & Data Science

## Advanced Statistics & Machine Learning

Faïcel Chamroukhi  
Professeur

<https://chamroukhi.com/>



# Overview

## 1 Rappels

# Rappels

1

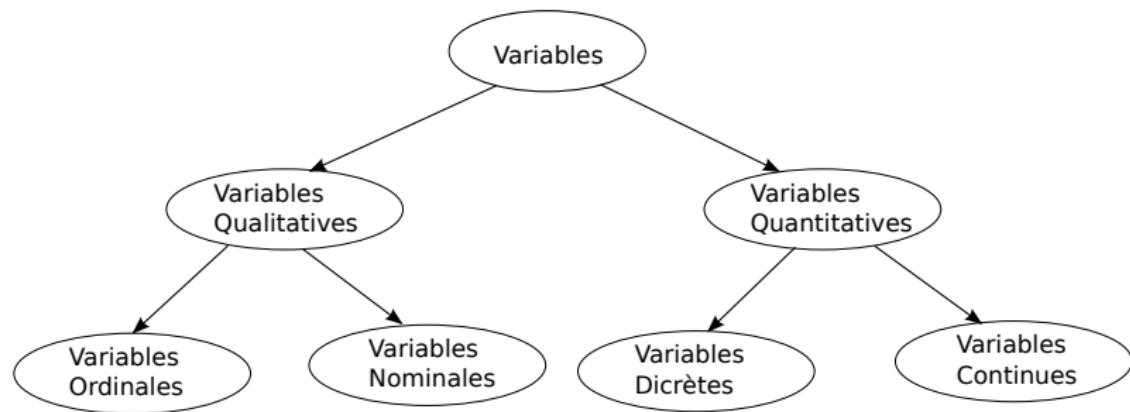
## Rappels

- Variables aléatoires
- Couple de variables aléatoires
- Vecteurs Aléatoires
- Variables et vecteurs aléatoires gaussiens

# Variables aléatoires

- Variables aléatoires

# Variables aléatoires : récapitulatif



# Fonction de densité de probabilité

## Definition

On appelle densité de probabilité toute fonction continue par morceaux (intégrable) :

$$\begin{aligned} f : \mathbb{R} &\rightarrow \mathbb{R}^+ \\ x &\rightarrow f(x) \end{aligned} \tag{1}$$

telle que :

$$(1) \quad \forall x \in \mathbb{R} \quad f(x) \geq 0$$

$$(2) \quad \int_{\mathbb{R}} f(x) dx = 1$$

# Espérance mathématique d'une v.a

L'espérance mathématique d'une variable aléatoire réelle représente la valeur moyenne prise par cette variable aléatoire.

## Espérance mathématique d'une variable aléatoire discrète

Soit  $X$  une variable aléatoire discrète prenant ses valeurs dans l'ensemble  $\{x_1, \dots, x_n\}$  avec des probabilités respectives  $p_1, \dots, p_n$  c.à.d  $P(X = x_k) = p_k$  et  $\sum_{k=1}^n p_k = 1$ . L'espérance de  $X$  est donnée par

$$\mathbb{E}[X] = \sum_k x_k P(X = x_k) = \sum_k x_k p_k \quad (2)$$

⚠ Remarque : On peut remarquer que l'espérance d'une variable aléatoire binaire est égale à sa probabilité de valoir 1, autrement dit si  $X$  est une v.a binaire (prenant ses valeurs dans  $\{0, 1\}$ , on a alors  $\mathbb{E}[X] = P(X = 1)$ ).

# Espérance mathématique d'une v.a

## Espérance mathématique d'une variable aléatoire continue

Soit  $X$  une variable aléatoire continue à valeurs réelles ayant comme fonction de densité de probabilité  $f$ . L'espérance de  $X$  est donnée par

$$\mathbb{E}[X] = \int_{\mathbb{R}} xf(x)dx. \quad (3)$$

Plus généralement, soit  $g : \mathbb{R} \rightarrow \mathbb{R}$ , l'espérance de  $g(X)$  est donnée par

$$\mathbb{E}[g(X)] = \int_{\mathbb{R}} g(x)f(x)dx \quad (4)$$

# Variance d'une variable aléatoire

## Definition

On appelle variance d'une variable aléatoire  $X$  la quantité définie par :

$$\text{var}[X] = \mathbb{E}[(X - E[X])^2] = \mathbb{E}[X^2] - (E[X])^2 \quad (5)$$

Ainsi, la variance notée  $\sigma_X^2$  et sa racine carrée l'écart-type (noté  $\sigma_X$ ) mesurent la dispersion de la variable aléatoire  $X$  autour de son espérance  $E[X]$ .

⚠ Remarque : D'après (4) et (5), la variance est donc aussi donnée par

$$\text{var}[X] = \int_{\mathbb{R}} (x - E[X])^2 f(x) dx. \quad (6)$$

## Quelques propriétés de l'espérance et de la variance

Soit  $X$  une v.a réelle, deux fonctions  $g, h : \mathbb{R} \rightarrow \mathbb{R}$  et deux réels  $a$  et  $b$ , alors

$$\mathbb{E}[a.g(X) + b.h(X)] = a.\mathbb{E}[g(X)] + b.\mathbb{E}[h(X)]$$

ainsi le cas particulier affine consiste en la propriété suivante :

$$\mathbb{E}[aX + b] = a\mathbb{E}[X] + b$$

⇒ On dit que l'espérance est **linéaire**

De même, pour la variance, on a la propriété suivante :

$$Var(aX + b) = a^2 Var(X)$$

⇒ On dit que la variance est **quadratique**

# Quelques statistiques sur variables aléatoires

## Definition

Soit  $(X_1, \dots, X_n)$  un échantillon donné d'une population ayant comme fonction de densité de probabilité la fonction  $f$  de paramètre  $\theta$  (une distribution de probabilités  $P(\cdot; \theta)$  pour le cas discret). Une *statistique* est toute fonction de l'échantillon donné  $(X_1, \dots, X_n)$  qui ne dépend pas de  $\theta$ .

## moyenne empirique

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (7)$$

## variance empirique

$$S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2. \quad (8)$$

# Couple de variables aléatoires

- Couple de variables aléatoires

# Couple de variables aléatoires I

Lois jointes, lois conditionnelles et théorème de Bayes

Soient  $X$  et  $Y$  deux variables aléatoires de densités respectives  $f(x)$  et  $f(y)$  (ou de lois respectives  $P(X)$  et  $P(Y)$  pour le cas discret).

Le comportement du couple  $(X, Y)$  est entièrement décrit par leur fonction de **densité de probabilité jointe**  $f_{XY}(x, y)$  (ou **distribution jointe** de probabilité dans le cas discret  $P_{XY}(X = x, Y = y)$ ) .

Il se peut que lors du tirage d'une réalisation de  $(X, Y)$ , que la valeur observée (réalisation)  $x$  de  $X$  fournit une information sur la valeur possible de  $Y$ .

→ Cette information est représentée par la distribution de  $Y$  conditionnellement à  $X = x$  (distribution de  $Y$  étant donné à  $X = x$ ) soit  $f_{Y|X}(y|x)$ .

## Théorème de Bayes

Ceci est explicité par le théorème de suivant, appelé **théorème de Bayes** (ou aussi règle de Bayes ou formule de Bayes) comme suit

### Theorem

$$f(x, y) = f(y|x)f(x) \quad (9)$$

et par symétrie on a également

$$f(x, y) = f(x|y)f(y) . \quad (10)$$

Pour les VA discrètes cela revient à

### Theorem

$$P(Y = y, X = x) = P(Y = y|X = x)P(X = x) \quad (11)$$

$$= P(X = x|Y = y)P(Y = y) \quad (12)$$

## Loi marginale de v.a discrètes

La loi de chaque variable est donc donnée par la **loi marginale** comme suit :

$$P(X = x) = \sum_{y \in B} P(X = x, Y = y) \quad (13)$$

et

$$P(Y = y) = \sum_{x \in A} P(X = x, Y = y) \quad (14)$$

⚠ Remarque : On peut remarquer que ces lois correspondent respectivement à la somme des lignes et la somme des colonnes dans le tableau précédent (??).

## Densités marginales

Les variables  $X$  et  $Y$  sont des variables continues de densité respectives

$$f(x) = \int_{\mathbb{R}} f_{X,Y}(x,y) dy \quad (15)$$

et

$$f(y) = \int_{\mathbb{R}} f_{X,Y}(x,y) dx. \quad (16)$$

# Covariance de deux variables aléatoires

Pour une variable aléatoire, on parle de variance  
pour un couple de deux variables aléatoires, on parle de **covariance**  
La covariance mesure la dépendance entre deux v.a. (Si les deux v.a sont indépendantes, leur covariance est donc nulle.)

## Definition

On définit la covariance de deux variables aléatoires  $X$  et  $Y$  comme le terme

$$\text{Cov}(X, Y) = \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])] \quad (17)$$

et on la propriété suivante

## Definition

$$\text{cov}(X, Y) = \sigma_{XY} = \mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y] \quad (18)$$

## Covariance de deux variables aléatoires I

⚠ Remarque : L'espérance du produit  $E(XY)$  se calcule à partir de la loi jointe du couple  $(X, Y)$ .

Ainsi, dans le cas discret, si  $X$  prend ses valeurs dans  $A$  et  $Y$  prend ses valeurs dans  $B$ , on a

$$\mathbb{E}[XY] = \sum_{x \in A} \sum_{y \in B} xyP(X = x, Y = y) \quad (19)$$

Dans le cas de v.a réelles continu, on a

$$\mathbb{E}[XY] = \int_{\mathbb{R}} \int_{\mathbb{R}} xyf_{X,Y}(x, y) dx dy. \quad (20)$$

# Indépendance de deux variables aléatoires

Soient  $X$  et  $Y$  deux variables aléatoires de densités respectives  $f(x)$  et  $f(y)$  (ou de lois respectives  $P(X)$  et  $P(Y)$  pour le cas discret).

## Definition

$X$  et  $Y$  sont dites indépendantes si et seulement si leur densité de probabilité jointe est égale au produit de leurs densités marginales. Plus spécifiquement

$$f_{XY}(x, y) = f(x)f(y) \quad (21)$$

Pour les VA discrètes cela revient à

$$P(Y = y, X = x) = P(X = x)P(Y = y) \quad (22)$$

# Indépendance et espérance

## Theorem

$X$  et  $Y$  sont indépendantes si et seulement si pour toutes fonctions  $f(X)$  et  $g(Y)$

$$\mathbb{E}[f(X)g(Y)] = \mathbb{E}[f(X)]\mathbb{E}[g(Y)]$$

si les espérances existent.

Le théorème direct est facile, la réciproque un peu plus difficile. Un cas particulier est bien celui où Si  $X$  et  $Y$  sont indépendantes, alors

$$\mathbb{E}[XY] = \mathbb{E}[X]\mathbb{E}[Y].$$

# Vecteurs Aléatoires

- Vecteurs Aléatoires

## Definition

Un vecteur aléatoire réel  $\mathbf{X}$  de dimension  $d$  est un vecteur  $\mathbf{X} = (X_1, \dots, X_d)^T$  dont les composantes  $X_j, j = 1, \dots, d$  sont des variables aléatoires réelles.

# Espérance et matrice de covariance d'un vecteur aléatoire

Soit  $\mathbf{X} = (X_1, \dots, X_d)^T$  un vecteur aléatoire réel.

## Espérance

L'espérance du vecteur aléatoire  $\mathbf{X}$  est donnée par le vecteur déterministe

$$\mathbb{E}[\mathbf{X}] = (\mathbb{E}[X_1], \dots, \mathbb{E}[X_d])^T = (\mu_1, \dots, \mu_d)^T \text{ avec } \mu_j = \mathbb{E}[X_j], j = 1, \dots, d$$

## Matrice de covariance

La matrice de variance-covariance (appelée aussi matrice de covariance) d'un vecteur aléatoire  $\mathbf{X}$  est la matrice carrée parfois notée  $\boldsymbol{\Sigma}$  dont le terme générique est donné par :  $\boldsymbol{\Sigma}_{i,j} = \text{cov}(X_i, X_j)$ . Elle est définie comme :

$$\boldsymbol{\Sigma}_{\mathbf{X}} = \text{cov}(\mathbf{X}) = \mathbb{E} \left[ (\mathbf{X} - \mathbb{E}[\mathbf{X}])(\mathbf{X} - \mathbb{E}[\mathbf{X}])^T \right] = \mathbb{E}[\mathbf{X}\mathbf{X}^T] - \mathbb{E}[\mathbf{X}](\mathbb{E}[\mathbf{X}])^T, \quad (23)$$

$\mathbb{E}[\mathbf{X}]$  étant l'espérance mathématique de  $\mathbf{X}$ .

# Espérance et matrice de covariance d'un vecteur aléatoire

En développant les termes on obtient la forme suivante :

$$\Sigma = \begin{bmatrix} E[(X_1 - \mu_1)(X_1 - \mu_1)] & E[(X_1 - \mu_1)(X_2 - \mu_2)] & \cdots & E[(X_1 - \mu_1)(X_n - \mu_n)] \\ E[(X_2 - \mu_2)(X_1 - \mu_1)] & E[(X_2 - \mu_2)(X_2 - \mu_2)] & \cdots & E[(X_2 - \mu_2)(X_n - \mu_n)] \\ \vdots & \vdots & \ddots & \vdots \\ E[(X_n - \mu_n)(X_1 - \mu_1)] & E[(X_n - \mu_n)(X_2 - \mu_2)] & \cdots & E[(X_n - \mu_n)(X_n - \mu_n)] \end{bmatrix}$$
$$= \begin{pmatrix} \text{var}(X_1) & \text{cov}(X_1 X_2) & \cdots & \text{cov}(X_1 X_p) \\ \text{cov}(X_2 X_1) & \ddots & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \text{cov}(X_p X_1) & \cdots & \cdots & \text{var}(X_p) \end{pmatrix} = \begin{pmatrix} \sigma_{X_1}^2 & \sigma_{X_1 X_2} & \cdots & \sigma_{X_1 X_p} \\ \sigma_{X_2 X_1} & \ddots & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{X_p X_1} & \cdots & \cdots & \sigma_{X_p}^2 \end{pmatrix}$$

où les  $\sigma_{X_j}^2, j = 1, \dots, p$  sont les variances respectives des v.a  $X_j$  et les  $\sigma_{X_i, X_j}^2, i \neq j$  sont les covariances respectives des couples de v.a  $(X_i, X_j)$  :  
 $\sigma_{X_i, X_j}^2 = \text{cov}(X_i, X_j)$ .

## Quelques propriétés de la matrice de covariance

La matrice de covariance possède les propriétés suivantes :

- ① La matrice est **symétrique** car on a  $\text{cov}(X, Y) = \text{cov}(Y, X)$
- ② Elle est **semi-définie positive** (ses valeurs propres sont positives ou nulles).
- ③ Les éléments de sa diagonale ( $\Sigma_{i,i}$ ) représentent la variance de chaque variable, étant donné la propriété  $\text{cov}(X, X) = \text{var}(X)$
- ④ Les éléments en dehors de la diagonale ( $\Sigma_{i,j}, i \neq j$ ) représentent la covariance entre les variables  $i$  et  $j$ .
- ⑤ la matrice de covariance d'un vecteur décorrélé ou indépendant est diagonale ( $\Sigma_{i,j} = 0 \forall i \neq j$ )

# Indépendance de vecteurs aléatoires

notion de VA i.i.d

## Cas des variables discrètes

Soit  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  une suite de variables aléatoires discrètes, et soit  $(S_1, S_2, \dots, S_n)$  une suite d'ensembles finis ou dénombrables tels que, pour tout  $i \leq n$ ,  $\mathbb{P}(X_i \in S_i) = 1$ .

## Definition

$(X_1, X_2, \dots, X_n)$  est une suite de variables aléatoires indépendantes si et seulement si, pour tout  $\mathbf{x} = (x_1, x_2, \dots, x_n) \in \prod_{i=1}^n S_i$ ,

$$\mathbb{P}(\mathbf{X} = \mathbf{x}) = \prod_{i=1}^n \mathbb{P}(X_i = x_i).$$

# Indépendance de vecteurs aléatoires

## Cas des variables aléatoires à densité

Soit une suite  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  de variables aléatoires réelles définies sur le même espace de probabilité  $(\Omega, \mathcal{A}, \mathbb{P})$  et de densités de probabilité respectives  $f_i$ .

## Definition

Les variables aléatoires réelles  $(X_1, X_2, \dots, X_n)$  sont dites indépendantes si et seulement si le vecteur  $\mathbf{X}$  a une densité de probabilité  $f$  qui se définit par

$$\forall \mathbf{x} = (x_1, \dots, x_n)^T \in \mathbb{R}^n, \quad f(x_1, \dots, x_n) = \prod_{i=1}^n f_i(x_i).$$

# Quelques statistique sur vecteurs aléatoires I

Soit un échantillon de valeurs de vecteurs aléatoires continues  $(\mathbf{x}_1, \dots, \mathbf{x}_n)$ ,  $\mathbf{x}_i \in \mathbb{R}^d$ , on a le vecteur moyen empirique et la matrice de covariance empirique sont respectivement données par

## Vecteur moyen empirique

$$\bar{\mathbf{x}} = \frac{1}{n} \sum_i \mathbf{x}_i \quad (24)$$

## Matrice de covariance empirique

$$\mathbf{S} = \frac{1}{n} \sum_i (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T \quad (25)$$

# Variables et vecteurs aléatoires gaussiens

- Variables et vecteurs aléatoires gaussiens

# Variables et vecteurs aléatoires gaussiens

## Definition

On appelle loi ou densité normale (ou gaussienne) univariée de paramètres  $(\mu, \sigma^2)$  (où  $\sigma \geq 0$ ) la loi de probabilité définie par la densité  $f : \mathbb{R} \rightarrow \mathbb{R}^+$ , telle que pour tout  $x \in \mathbb{R}$  :

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}. \quad (26)$$

Soit  $X$  une variable aléatoire réelle admettant pour densité de probabilité la loi normale (26), appelée variable aléatoire gaussienne, son espérance est  $\mu$  et son écart type est  $\sigma$  (sa variance est  $\sigma^2$ ).

On note

$$X \sim \mathcal{N}(\mu, \sigma^2)$$

et on lit "X suit la loi normale d'espérance  $\mu$  et de variance  $\sigma^2$ ". Sa densité de probabilité dessine une courbe dite courbe en cloche

## Loi normale centrée réduite

La loi normale centrée réduite correspond à un cas particulier de la loi normale générale (26).

### Definition

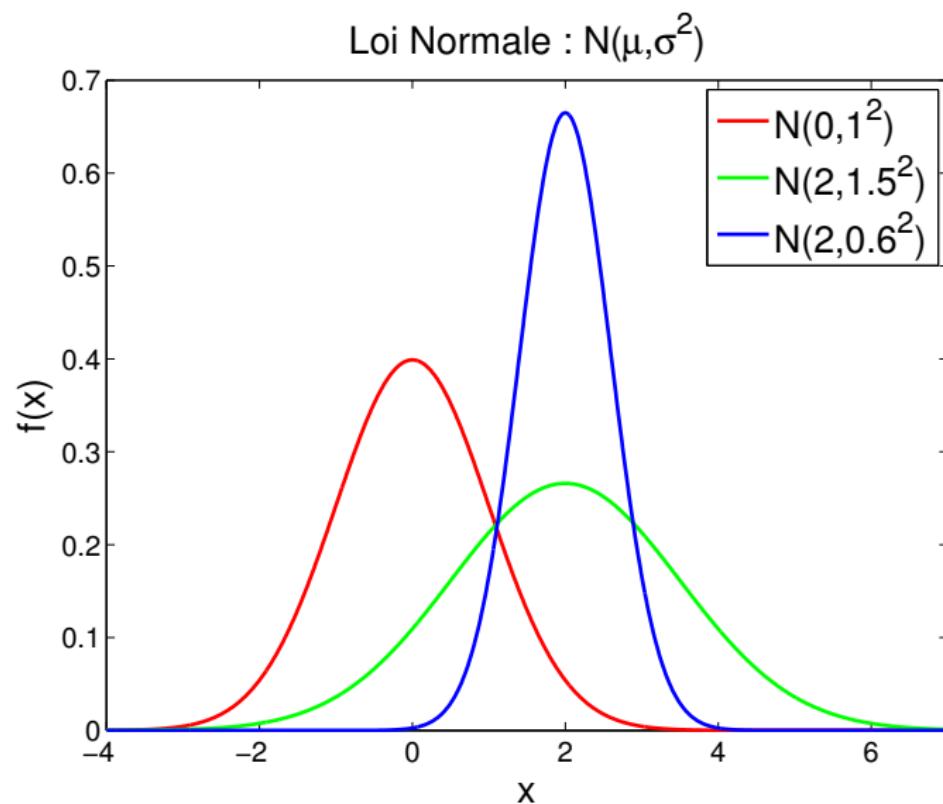
On appelle loi normale (ou gaussienne) centrée réduite la loi définie par la densité de probabilité  $\varphi : \mathbb{R} \rightarrow \mathbb{R}^+$  définie par :

$$\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} \quad (27)$$

qui se note  $\mathcal{N}(0, 1)$ . Elle est dite centrée de part son espérance nulle et réduite de part sa variance unité.

# Représentations graphiques

## Loi normale monodimensionnelle



## Quelques propriétés I

Soit une variable aléatoire  $X$  qui suit la loi normale  $\mathcal{N}(\mu, \sigma^2)$ . Alors :

- son espérance et sa variance existent et  $\mathbb{E}(X) = \mu$ ,  $\text{Var}(X) = \sigma^2 \geq 0$ ,
- la variable aléatoire  $X^* = \frac{X - \mathbb{E}(X)}{\sqrt{\text{var}(X)}}$ , c'est-à-dire  $X^* = \frac{X - \mu}{\sigma}$ , suit la loi normale centrée réduite  $\mathcal{N}(0, 1)$ ,
- si  $a, b$  sont deux réels ( $a \neq 0$ ), alors la variable aléatoire  $aX + b$  suit la loi normale  $\mathcal{N}(a\mu + b, a^2\sigma^2)$

# Vecteurs aléatoires gaussiens

## Definition

Un vecteur aléatoire  $\mathbf{X} = (X_1, \dots, X_d)^T$  est dit gaussien si, pour tout  $\mathbf{u} \in \mathbb{R}^d$ , la variable aléatoire réelle  $\mathbf{u}^T \mathbf{X}$  est une variable aléatoire gaussienne. C'est à dire si toute combinaison linéaire de ses composantes est une variable gaussienne.

## Loi normale multidimensionnelle

La loi normale multidimensionnelle représente la distribution d'un vect. a. gaussien. Soit  $\mathbf{X}$  un vect. a. gaussien de dimension  $d$ . On appelle loi normale multidimensionnelle d'espérance  $\boldsymbol{\mu}$  et de matrice de covariance  $\boldsymbol{\Sigma}$  la densité de probabilité  $f : \mathbb{R}^d \rightarrow \mathbb{R}^+$  définie par :

$$f(\mathbf{x}) = \frac{1}{(2\pi)^{d/2} |\boldsymbol{\Sigma}|^{1/2}} \exp\left(-\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})\right), \quad (28)$$

$|\boldsymbol{\Sigma}|$  étant le déterminant de  $\boldsymbol{\Sigma}$ .

# Vecteurs aléatoires gaussiens

La loi normale multidimensionnelle se note habituellement  $\mathcal{N}(\mu, \Sigma)$ .

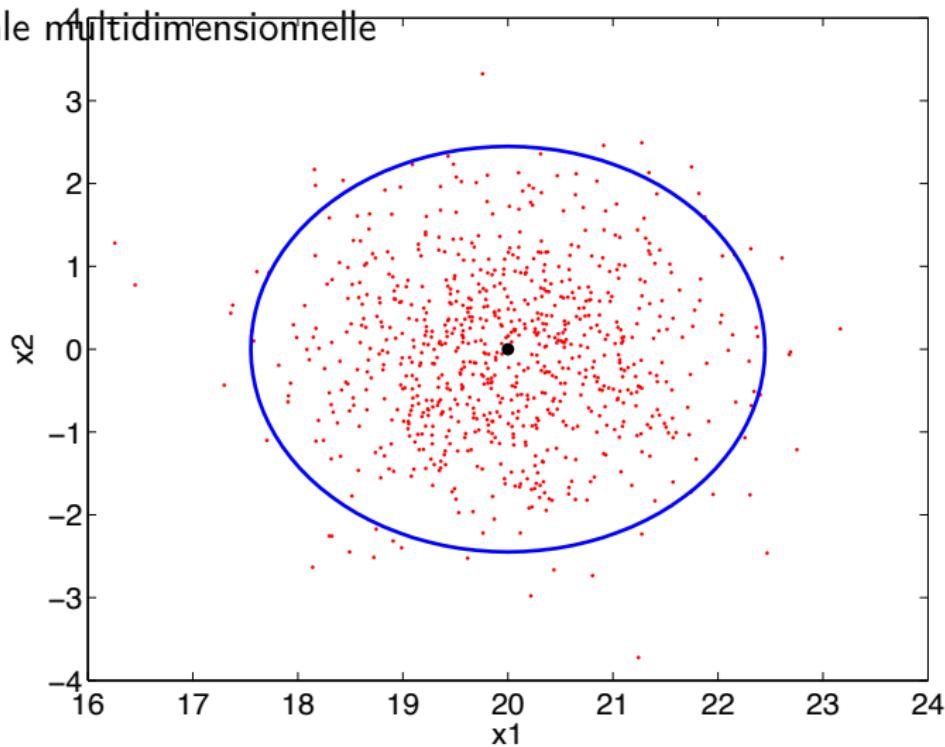
## Distance de Mahalanobis

Le terme présent dans l'exponentielle dans (28)  $(x - \mu)^T \Sigma^{-1} (x - \mu)$  est le carré de la **distance de Mahalanobis**. Cette dernière est en effet donnée par

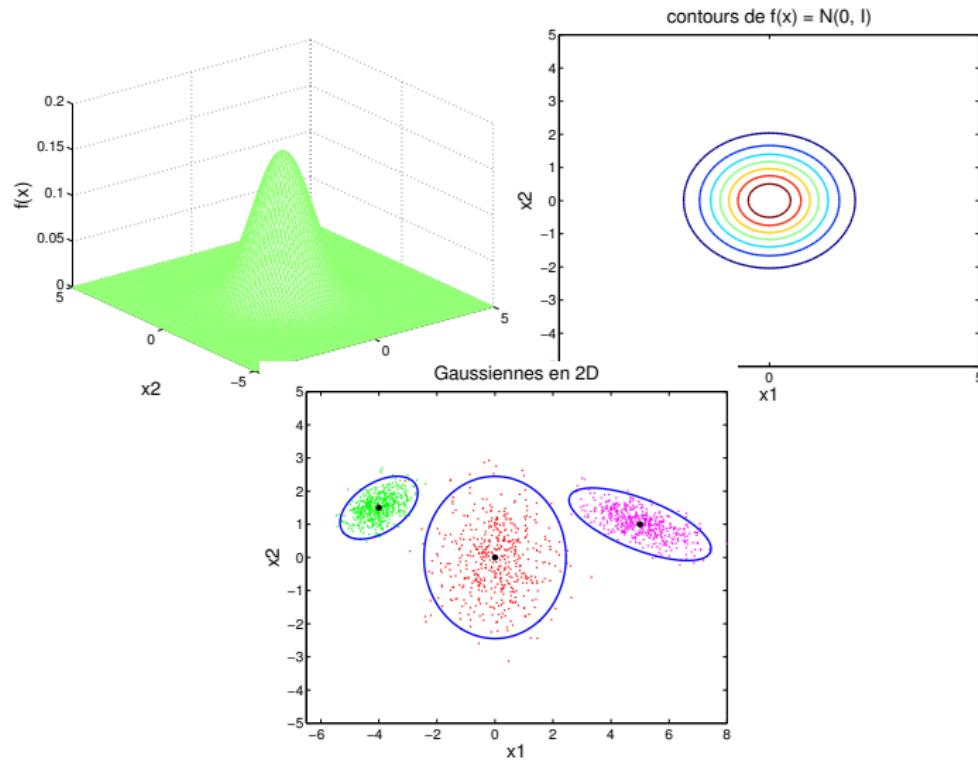
$$\sqrt{(x - \mu)^T \Sigma^{-1} (x - \mu)}$$

# Vecteurs aléatoires gaussiens

Loi normale multidimensionnelle



# Repr. graphiques : Loi normale multidimensionnelle



# Vecteurs aléatoires gaussiens

Soit  $\mathbf{X} = (X_1, \dots, X_d)^T$  un vecteur aléatoire gaussien de dimension  $d$  suivant la loi  $\mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , on a :

## Quelques Propriétés

- l'espérance et la matrice de covariance de  $\mathbf{X}$  sont respectivement  $\mathbb{E}[\mathbf{X}] = \boldsymbol{\mu}$  et  $\text{Cov}(\mathbf{X}) = \boldsymbol{\Sigma}$ ,
- les variables aléatoires  $X_1, \dots, X_d$  sont indépendantes si et seulement si la matrice de covariance est diagonale,
- Tout sous-vecteur d'un vecteur aléatoire gaussien suit une loi normale. En particulier, ses composantes sont toutes gaussiennes,
- Si  $\mathbf{A}$  est une matrice constante de dimensions  $[n \times d]$  et  $\mathbf{b}$  un vecteur constant dans  $\mathbb{R}^d$ , alors la densité du vecteur aléatoire  $\mathbf{Y} = \mathbf{A}\mathbf{X} + \mathbf{b}$  (de dimension  $[n \times d]$ ) est la loi normale de  $n$  dimensions suivante  $\mathcal{N}(\mathbf{A}\boldsymbol{\mu} + \mathbf{b}, \mathbf{A}\boldsymbol{\Sigma}\mathbf{A}^T)$ .