

# Mathématiques pour l'intelligence artificielle

M2 informatique parcours IAAA, Aix-Marseille Université

Thomas Schatz  
Jeudi 14 septembre 2023

# Moments

“Bilinéarité” de la variance

$$\text{Var} \left[ \sum_{i=1}^n a_i X_i \right] = \sum_{i=1}^n \sum_{j=1}^n a_i a_j \text{Cov}(X_i, X_j)$$

Bilinéarité de la covariance

$$\text{Cov} \left( \sum_{i=1}^n a_i X_i, \sum_{j=1}^m b_j Y_j \right) = \sum_{i=1}^n \sum_{j=1}^m a_i b_j \text{Cov}(X_i, Y_j)$$

# Plan du cours (prévisionnel)

## Introduction

1. Notions de bases sur les preuves

2. Algèbre linéaire

3. Optimisation

4. Probabilités

5. Statistique

## Discussion

# Probabilités

1. Notions de base
2. Calculs d'espérance et de variance
3. Loi gaussienne multivariée et autres distributions

# Example Distributions

Distribution	PDF or PMF	Mean	Variance
$Bernoulli(p)$	$\begin{cases} p, & \text{if } x = 1 \\ 1 - p, & \text{if } x = 0. \end{cases}$	$p$	$p(1 - p)$
$Binomial(n, p)$	$\binom{n}{k} p^k (1 - p)^{n-k}$ for $k = 0, 1, \dots, n$	$np$	$np(1 - p)$
$Geometric(p)$	$p(1 - p)^{k-1}$ for $k = 1, 2, \dots$	$\frac{1}{p}$	$\frac{1-p}{p^2}$
$Poisson(\lambda)$	$\frac{e^{-\lambda} \lambda^k}{k!}$ for $k = 0, 1, \dots$	$\lambda$	$\lambda$
$Uniform(a, b)$	$\frac{1}{b-a}$ for all $x \in (a, b)$	$\frac{a+b}{2}$	$\frac{(b-a)^2}{12}$
$Gaussian(\mu, \sigma^2)$	$\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$ for all $x \in (-\infty, \infty)$	$\mu$	$\sigma^2$
$Exponential(\lambda)$	$\lambda e^{-\lambda x}$ for all $x \geq 0, \lambda \geq 0$	$\frac{1}{\lambda}$	$\frac{1}{\lambda^2}$

---

<sup>2</sup>Table reproduced from Maleki & Do's review handout by Koochak & Irvin

## Random Vectors

Given  $n$  RV's  $X_1, \dots, X_n$ , we can define a random vector  $X$  s.t.

$$X = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix}$$

Note: all the notions of joint PDF/CDF will apply to  $X$ .

Given  $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$ , we have:

$$g(x) = \begin{bmatrix} g_1(x) \\ g_2(x) \\ \vdots \\ g_m(x) \end{bmatrix}, \mathbb{E}[g(X)] = \begin{bmatrix} \mathbb{E}[g_1(X)] \\ \mathbb{E}[g_2(X)] \\ \vdots \\ \mathbb{E}[g_m(X)] \end{bmatrix}.$$

## Covariance Matrices

For a random vector  $X \in \mathbb{R}^n$ , we define its **covariance matrix**  $\Sigma$  as the  $n \times n$  matrix whose  $ij$ -th entry contains the covariance between  $X_i$  and  $X_j$ .

$$\Sigma = \begin{bmatrix} \text{Cov}[X_1, X_1] & \dots & \text{Cov}[X_1, X_n] \\ \vdots & \ddots & \vdots \\ \text{Cov}[X_n, X_1] & \dots & \text{Cov}[X_n, X_n] \end{bmatrix}$$

applying linearity of expectation and the fact that  $\text{Cov}[X_i, X_j] = \mathbb{E}[(X_i - \mathbb{E}[X_i])(X_j - \mathbb{E}[X_j])]$ , we obtain

$$\Sigma = \mathbb{E}[(X - \mathbb{E}[X])(X - \mathbb{E}[X])^T]$$

### Properties:

- ▶  $\Sigma$  is symmetric and PSD
- ▶ If  $X_i \perp X_j$  for all  $i, j$ , then  $\Sigma = \text{diag}(\text{Var}[X_1], \dots, \text{Var}[X_n])$

## Multivariate Gaussian

The multivariate Gaussian  $X \sim \mathcal{N}(\mu, \Sigma)$ ,  $X \in \mathbb{R}^n$ :

$$p(x; \mu, \Sigma) = \frac{1}{\det(\Sigma)^{\frac{1}{2}} (2\pi)^{\frac{n}{2}}} \exp\left(-\frac{1}{2}(x - \mu)^T \Sigma^{-1} (x - \mu)\right)$$

The univariate Gaussian  $X \sim \mathcal{N}(\mu, \sigma^2)$ ,  $X \in \mathbb{R}$  is just the special case of the multivariate Gaussian when  $n = 1$ .

$$p(x; \mu, \sigma^2) = \frac{1}{\sigma(2\pi)^{\frac{1}{2}}} \exp\left(-\frac{1}{2\sigma^2}(x - \mu)^2\right)$$

Notice that if  $\Sigma \in \mathbb{R}^{1 \times 1}$ , then  $\Sigma = \text{Var}[X_1] = \sigma^2$ , and so

- ▶  $\Sigma^{-1} = \frac{1}{\sigma^2}$
- ▶  $\det(\Sigma)^{\frac{1}{2}} = \sigma$

## Some Nice Properties of MV Gaussians


- ▶ Marginals and conditionals of a joint Gaussian are Gaussian
- ▶ A  $d$ -dimensional Gaussian  $X \in \mathcal{N}(\mu, \Sigma = \text{diag}(\sigma_1^2, \dots, \sigma_n^2))$  is equivalent to a collection of  $d$  **independent** Gaussians  $X_i \in \mathcal{N}(\mu_i, \sigma_i^2)$ . This results in isocontours aligned with the coordinate axes.
- ▶ In general, the isocontours of a MV Gaussian are  $n$ -dimensional ellipsoids with principal axes in the directions of the eigenvectors of covariance matrix  $\Sigma$  (remember,  $\Sigma$  is PSD, so all  $n$  eigenvectors are non-negative). The axes' relative lengths depend on the eigenvalues of  $\Sigma$ .

# Visualizations of MV Gaussians

Effect of changing variance


$$\Sigma = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

$$\mu = [0 \ 0]^T$$




$$\Sigma = \begin{pmatrix} 0.7 & 0 \\ 0 & 0.7 \end{pmatrix}$$

$$\mu = [0 \ 0]^T$$



$$\Sigma = \begin{pmatrix} 1.5 & 0 \\ 0 & 1.5 \end{pmatrix}$$

$$\mu = [0 \ 0]^T$$




# Visualizations of MV Gaussians

If  $\text{Var}[X_1] \neq \text{Var}[X_2]$ :


$$\Sigma = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

$$\mu = [0 \ 0]^T$$




$$\Sigma = \begin{pmatrix} 0.6 & 0 \\ 0 & 1 \end{pmatrix}$$

$$\mu = [0 \ 0]^T$$



$$\Sigma = \begin{pmatrix} 2 & 0 \\ 0 & 1 \end{pmatrix}$$

$$\mu = [0 \ 0]^T$$



# Visualizations of MV Gaussians

If  $X_1$  and  $X_2$  are positively correlated:

$$\Sigma = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$




$$\mu = [0 \ 0]^T$$

$$\Sigma = \begin{pmatrix} 1 & 0.5 \\ 0.5 & 1 \end{pmatrix}$$

$$\mu = [0 \ 0]^T$$

$$\Sigma = \begin{pmatrix} 1 & 0.8 \\ 0.8 & 1 \end{pmatrix}$$

$$\mu = [0 \ 0]^T$$





# Visualizations of MV Gaussians

If  $X_1$  and  $X_2$  are negatively correlated:



$$\Sigma = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

$$\mu = [0 \ 0]^T$$





$$\Sigma = \begin{pmatrix} 1 & -0.5 \\ -0.5 & 1 \end{pmatrix}$$

$$\mu = [0 \ 0]^T$$



$$\Sigma = \begin{pmatrix} 1 & -0.8 \\ -0.8 & 1 \end{pmatrix}$$

$$\mu = [0 \ 0]^T$$



## Multivariate Gaussian

Définition générale

$$\mathbf{X} \sim \mathcal{N}(\mu, \Sigma) \iff \text{there exist } \mu \in \mathbb{R}^k, \mathbf{A} \in \mathbb{R}^{k \times \ell} \text{ such that } \mathbf{X} = \mathbf{A}\mathbf{Z} + \mu \text{ for } Z_n \sim \mathcal{N}(0, 1), \text{i.i.d.}$$

Distributions conditionnelles

$$\mathbf{x} = \begin{bmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \end{bmatrix} \text{ with sizes } \begin{bmatrix} q \times 1 \\ (N-q) \times 1 \end{bmatrix} \quad \boldsymbol{\mu} = \begin{bmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_2 \end{bmatrix} \text{ with sizes } \begin{bmatrix} q \times 1 \\ (N-q) \times 1 \end{bmatrix}$$

$$\boldsymbol{\Sigma} = \begin{bmatrix} \boldsymbol{\Sigma}_{11} & \boldsymbol{\Sigma}_{12} \\ \boldsymbol{\Sigma}_{21} & \boldsymbol{\Sigma}_{22} \end{bmatrix} \text{ with sizes } \begin{bmatrix} q \times q & q \times (N-q) \\ (N-q) \times q & (N-q) \times (N-q) \end{bmatrix}$$

$$p(\mathbf{x}_1 \mid \mathbf{x}_2 = \mathbf{a}) = \mathcal{N}(\bar{\boldsymbol{\mu}}, \bar{\boldsymbol{\Sigma}}), \text{ with}$$

$$\bar{\boldsymbol{\mu}} = \boldsymbol{\mu}_1 + \boldsymbol{\Sigma}_{12} \boldsymbol{\Sigma}_{22}^+ (\mathbf{a} - \boldsymbol{\mu}_2)$$

$$\bar{\boldsymbol{\Sigma}} = \boldsymbol{\Sigma}_{11} - \boldsymbol{\Sigma}_{12} \boldsymbol{\Sigma}_{22}^+ \boldsymbol{\Sigma}_{21}$$

Distributions marginales ?

# Probabilités

1. Notions de base
2. Calculs d'espérance et de variance
3. Loi gaussienne multivariée et autres distributions

# Plan du cours (prévisionnel)

Introduction

1. Notions de bases sur les preuves

2. Algèbre linéaire

3. Optimisation

4. Probabilités

5. Statistique

Discussion

# Statistique

1. Cadre général
2. Statistique non-asymptotique: biais, variance, risque et concentration
3. Statistique asymptotique

# Cadre général

Cadre général

Modèle statistique  $\mathcal{P}$   
Distribution  $P \in \mathcal{P}$   
Observations  $O \sim P$

- Estimation ponctuelle

Fonctionnelle  $f : \mathcal{P} \rightarrow E$

Estimateur  $\hat{f} : \mathcal{O} \rightarrow E$

But  $\hat{f}(O) \approx f(P)$

- Estimation par intervalle, tests d'hypothèses

# Cadre général

- Problème de l’induction, inséparable de la démarche scientifique dans son ensemble
- Bayésien vs fréquentiste et autres (“best systems” etc.)
  - Question d'**interprétation** de la modélisation probabiliste dans un cadre applicatif donné (que représentent les probabilités considérées ?)
    - Une méthode formelle n’est donc pas intrinsèquement “Bayésienne” ou “fréquentiste”, tout dépend de son utilisation
    - Référence sur le sujet : <https://plato.stanford.edu/entries/probability-interpret/>

# Statistique

1. Cadre général
2. Statistique non-asymptotique: biais, variance, risque et concentration
3. Statistique asymptotique

# Qualité statistique d'un estimateur ponctuel

- biais  $b_P(\hat{f}) = E_{O \sim P}[\hat{f}(O)] - f(P)$   $\|b_P(\hat{f})\|_2$
- variance  $\text{Var}_P(\hat{f}) = \text{Var}_{O \sim P}[\hat{f}(O)]$
- risque  $R_P(\hat{f}) = E_{O \sim P}[\ell(f(P), \hat{f}(O))]$   
 $\ell$  Fonction de coût

Décomposition biais-variance du risque dans le cas  $\ell : x, y \mapsto \|x - y\|_2^2$

$$R_P(\hat{f}) = \text{Var}_P(\hat{f}) + \|b_P(\hat{f})\|_2^2$$

# Comment obtenir un estimateur ?

## Cas paramétrique: estimateur du maximum de vraisemblance

Modèle statistique  $\mathcal{P}$

Distribution  $P \in \mathcal{P}$

Observations  $O \sim P$

Fonctionnelle  $f : \mathcal{P} \rightarrow E$

Estimateur  $\hat{f} : \mathcal{O} \rightarrow E$

Cas paramétrique :

$$\mathcal{P} = \{P_\theta \mid \theta \in \Theta\}$$

$$f(P_\theta) = \theta$$

$$\hat{f} : O \mapsto \arg \max_{\theta \in \Theta} (p_\theta(O))$$

# Statistique

1. Cadre général
2. Statistique non-asymptotique: biais, variance, risque et concentration
3. Statistique asymptotique

# Modes de convergence

- Convergence en loi  $X_n \rightarrow_d X$  si et seulement si
$$\lim_{n \rightarrow +\infty} E[f(X_n)] = E[f(X)]$$
pour toute fonction  $f$  à valeurs réelles, continue et bornée

Définition équivalente pour des variables aléatoires réelles:

$$\lim_{n \rightarrow +\infty} F_{X_n}(x) = F_X(x) \text{ en tout point } X \text{ où } F_X \text{ est continue}$$

# Modes de convergence

- Convergence presque sûre ou presque partout  $X_n \rightarrow_{a.s.} X$   
$$P\left(\lim_{n \rightarrow +\infty} X_n = X\right) = 1$$
- Convergence en probabilité  $X_n \rightarrow_p X$   
$$\forall \epsilon > 0, \lim_{n \rightarrow +\infty} P(|X_n - X| > \epsilon) = 0$$
- Convergence en moyenne quadratique  $X_n \rightarrow_{\mathcal{L}_2} X$   
$$\lim_{n \rightarrow +\infty} E[|X_n - X|^2] = 0$$

# Loi forte des grands nombres

$X_1, X_2, \dots$  variables aléatoires i.i.d.

(ii) (The SLLN). A necessary and sufficient condition for the existence of a constant  $c$  for which

$$\frac{1}{n} \sum_{i=1}^n X_i \rightarrow_{a.s.} c \quad (1.81)$$

is that  $E|X_1| < \infty$ , in which case  $c = EX_1$

# Théorème de la limite centrale

(Multivariate CLT). Let  $X_1, \dots, X_n$  be i.i.d. random  $k$ -vectors with a finite  $\Sigma = \text{Var}(X_1)$ . Then

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n (X_i - EX_1) \rightarrow_d N_k(0, \Sigma). \blacksquare$$

# Transformations continues et théorème de Slutsky

**Theorem 1.10.** Let  $X, X_1, X_2, \dots$  be random  $k$ -vectors defined on a probability space and  $g$  be a measurable function from  $(\mathcal{R}^k, \mathcal{B}^k)$  to  $(\mathcal{R}^l, \mathcal{B}^l)$ . Suppose that  $g$  is continuous a.s.  $P_X$ . Then

- (i)  $X_n \rightarrow_{a.s.} X$  implies  $g(X_n) \rightarrow_{a.s.} g(X)$ ;
- (ii)  $X_n \rightarrow_p X$  implies  $g(X_n) \rightarrow_p g(X)$ ;
- (iii)  $X_n \rightarrow_d X$  implies  $g(X_n) \rightarrow_d g(X)$ . ■

**Theorem 1.11** (Slutsky's theorem). Let  $X, X_1, X_2, \dots, Y_1, Y_2, \dots$  be random variables on a probability space. Suppose that  $X_n \rightarrow_d X$  and  $Y_n \rightarrow_p c$ , where  $c$  is a fixed real number. Then

- (i)  $X_n + Y_n \rightarrow_d X + c$ ;
- (ii)  $Y_n X_n \rightarrow_d cX$ ;
- (iii)  $X_n / Y_n \rightarrow_d X/c$  if  $c \neq 0$ .

# Delta method

Soit  $X_1, X_2, \dots$  and  $Y$  des vecteurs aléatoires de dimension  $k$ , tels que :

$$a_n(X_n - c) \rightarrow_d Y,$$

pour  $c \in \mathbf{R}^k$  et  $(a_n)$  une suite de nombres positifs tendant vers  $+\infty$ . Alors pour toute fonction  $g : \mathbf{R}^k \rightarrow \mathbf{R}$  différentiable en  $c$ , on a:

$$a_n[g(X_n) - g(c)] \rightarrow_d [\nabla g(c)]^T Y.$$

# Statistique

1. Cadre général
2. Statistique non-asymptotique: biais, variance, risque et concentration
3. Statistique asymptotique

# Plan du cours (prévisionnel)

## Introduction

1. Notions de bases sur les preuves

2. Algèbre linéaire

3. Optimisation

4. Probabilités

5. Statistique

## Discussion