

Révision: probabilités & ensembles

(CIV8530 - Fiabilité des structures et systèmes)

Enseignant: James-A. Goulet

Département des génies civil, géologique et des mines
Polytechnique Montréal



Chapitre 3 – J.-A. Goulet, (2020), Probabilistic Machine Learning for Civil Engineers, MIT Press

Théorie des probabilités, pourquoi? 🎥

Pour décrire les phénomènes aléatoires? ⚠ non.



Peu de phénomènes sont intrinsèquement aléatoires

On utilise les probabilités pour **représenter notre connaissance (incertitudes épistémiques)**

- ▶ Le module élastique E ne varie pas (localement)
- ▶ On ne connaît pas exactement sa valeur
- ▶ On décrit notre incertitude de E par des probabilités



Le moins on en sait, le plus on devrait utiliser les probabilités



Plan du module #0b

Ensembles

Probabilités

X – V.A.

X – V.A.M.

$E(X)$

$g(X)$

Linéarisation

Organisation de la matière

<i>Théorie probabilité</i>	{	0	Révision algèbre & probabilités	
		1	Lois de probabilités	
		3	PDF multivariés	
<i>Fiabilité des structures & systèmes</i>	{		Introduction	
		2	Formulation fiabilité composantes	$g(X)$
		9	Formulation fiabilité systèmes	
<i>Estimation – p_f échantillonnage</i>	{	4	Monte Carlo	
		12	Échantillonnage par importance	
<i>Estimation – p_f analytique</i>	{	5	FOSM	
		6	FORM	
		8	SORM	
<i>Utilisation des résultats</i>	{	7	Analyse de sensibilité	
		10	Incertitudes aléatoires & épistémiques	
		11	Données empiriques	
		13	Prise de décision	
		14	Métamodèles & modèles empiriques	



Plan de la section

Ensembles

1.1 Définitions

1.2 Exemples

1.3 Règles élémentaires

Définitions

Ensemble: Regroupement d'éléments/événements

Univers/espace d'échantillonnage (\mathcal{S}): Ensemble des résultats possibles (peut être continu/discret & fini/infini)

Évènement élémentaire (x): un seul élément, $x \in \mathcal{S}$

Évènement (E): ensemble d'évènements élémentaires


$E \subseteq \mathcal{S}$: Sous-ensemble de \mathcal{S}

$E = \mathcal{S}$: Évènement certain


$E = \emptyset$: Évènement impossible

\bar{E} : Complément de E

Diagramme de Venn




Exemple #2 – Défaillance d'une composante en traction



$s \in \mathbb{R}^+$: sollicitation

$r \in \mathbb{R}^+$: résistance

$$\mathcal{S} = \mathbb{R}^{2+}$$




$$\text{Défaillance} : \{R \leq S\} \equiv \{R - S \leq 0\}$$


Opérations sur les évènements

Soit des évènements $\{E_1, E_2, \dots, E_n\} \in \mathcal{S}$

Union (i.e. “ou”): $E_1 \cup E_2$



Intersection (i.e. “et”): $E_1 \cap E_2 \equiv E_1 E_2$





Règles

Commutativité: $E_1 \cup E_2 = E_2 \cup E_1$, $E_1 E_2 = E_2 E_1$


Associativité: $(E_1 \cup E_2) \cup E_3 = E_1 \cup (E_2 \cup E_3) = E_1 \cup E_2 \cup E_3$

$$\cup_{i=1}^n E_i = E_1 \cup E_2 \cup \dots \cup E_n$$

$$\cap_{i=1}^n E_i = E_1 \cap E_2 \cap \dots \cap E_n$$



Distributivité: $E_1(E_2 \cup E_3) = (E_1 E_2 \cup E_1 E_3)$




⚠ Convention: l'intersection à priorité sur l'union... sinon ()

Types d'évènements: $\{E_1, E_2, \dots, E_n\} \in \mathcal{S}$

mutuellement exclusifs (ME):

E_1, E_2, \dots, E_n sont ME


si $E_i E_j = \emptyset, \forall i \neq j$





collectivement exhaustifs (CE):

E_1, E_2, \dots, E_n sont CE

si $\cup_{i=1}^n E_i = \mathcal{S}$



mutuellement exclusifs & collectivement exhaustifs (ME & CE) :



Lois de Morgan


$$\overline{\bigcup_i E_i} = \bigcap_i \overline{E_i}$$

Le complément des unions est égal à l'intersection des compléments

$$\overline{\bigcap_i E_i} = \bigcup_i \overline{E_i}$$

Le complément des intersections est égal à l'union des compléments

Exemple – Lois de Morgan



E_i : Le pont n'est pas ouvert à la circulation

Défaillance: $E_1 \cup E_2 \cup \dots \cup E_n = \underbrace{\bigcup_{i=1}^n E_i}_{\text{"ou"}}$

Survie: $\overline{\bigcup_i E_i} = \underbrace{\bigcap_i \overline{E_i}}_{\text{"et"}}$



Plan de la section

Probabilités

2.1 Introduction

2.2 Axiomes et règles élémentaires

2.3 Probabilités conditionnelles & Bayes

Interpretation des probabilités

Probabilité de l'évènement E_i : $\Pr(E_i)$

△ Interpretation Bayésienne:

$\Pr(E_i)$ est une mesure de vraisemblance par rapport aux autres évènements dans \mathcal{S}



- ▶ Dépend de notre connaissance à priori
- ▶ Change lorsque l'on obtient de nouvelles informations

△ Interpretation Fréquentiste:



$$\Pr(E_i) = \lim_{n \rightarrow \infty} \frac{\#x}{n}$$

Axiomes fondamentaux

1. $0 \leq \Pr(E_i) \leq 1$

2. $\Pr(\mathcal{S}) = 1$
 (probabilité d'un évènement certain = 1)


3. si E_1 et E_2 sont mutuellement exclusifs

$$\Pr(E_1 \cup E_2) = \Pr(E_1) + \Pr(E_2)$$

$\Pr(\emptyset) = 0$



$\Pr(\mathcal{S}) = 1$




Lois dérivées à partir des axiomes fondamentaux

Probabilité du complément: $\Pr(\bar{E}) = 1 - \Pr(E)$

Probabilité de l'ensemble vide: $\Pr(\emptyset) = 1 - 1 = 0$

Loi de l'addition: $\Pr(E_1 \cup E_2) = \Pr(E_1) + \Pr(E_2) - \Pr(E_1 E_2)$





Loi d'inclusion-exclusion:

$$\Pr\left(\bigcup_{i=1}^n E_i\right) = \sum_{i=1}^n \Pr(E_i) - \sum_{i < j} \Pr(E_i E_j) + \sum_{i < j < k} \Pr(E_i E_j E_k) - \dots + (-1)^{n-1} \Pr(E_1 E_2 \dots E_n)$$

$$= 1 - \Pr(\overline{E_1} \overline{E_2} \dots \overline{E_n}) \quad (\text{Loi de Morgan})$$

Pour $n = 3$

$$\Pr(E_1 \cup E_2 \cup E_3) = \Pr(E_1) + \Pr(E_2) + \Pr(E_3) - \Pr(E_1 E_2) - \Pr(E_1 E_3) - \Pr(E_2 E_3) + \Pr(E_1 E_2 E_3)$$




⚠ La difficulté d'évaluer la probabilité conjointe $\Pr(E_1 E_2 \dots E_N)$ augmente avec N (mais sa contribution diminue)

Probabilités conditionnelles

$\Pr(E_1|E_2)$: Probabilité de l'évènement E_1 conditionnelle à la réalisation de l'évènement E_2

$$\Pr(E_1|E_2) = \frac{\Pr(E_1 E_2)}{\Pr(E_2)}, \quad (\Pr(E_2) \neq 0)$$

Probabilité conjointe	=	Probabilité conditionnelle	·	Probabilité marginale
$\Pr(E_1 E_2)$		$\Pr(E_1 E_2)$		$\Pr(E_2)$
		$\Pr(E_2 E_1)$		$\Pr(E_1)$



Si E_1 et E_2 sont **statistiquement indépendants** ($E_1 \perp\!\!\!\perp E_2$)

$$\Pr(E_1|E_2) = \Pr(E_1) \rightarrow \Pr(E_1 E_2) = \Pr(E_1) \cdot \Pr(E_2)$$

Loi de la dérivation en chaîne

$$\begin{aligned}
 \Pr(E_1 E_2 \cdots E_n) &= \Pr(E_1 | E_2 \cdots E_n) \Pr(E_2 \cdots E_n) \\
 &= \Pr(E_1 | E_2 \cdots E_n) \Pr(E_2 | E_3 \cdots E_n) \Pr(E_3 \cdots E_n) \\
 &= \Pr(E_1 | E_2 \cdots E_n) \Pr(E_2 | E_3 \cdots E_n) \cdots \Pr(E_{n-1} | E_n) \Pr(E_n)
 \end{aligned}$$

- ▶ n termes
- ▶ $n - 1$ probabilités conditionnelles
- ▶ 1 probabilité marginale

Exemple:

$$\Pr(E_1 E_2 E_3) = \overbrace{\Pr(E_1 | E_2 E_3)}^{= \Pr(E_1 E_2 E_3)} \underbrace{\Pr(E_2 | E_3) \Pr(E_3)}_{= \Pr(E_2 E_3)}$$


Loi de probabilité totale

Soit un évènement A appartenant à l'espace d'échantillonnage \mathcal{S} (i.e. $A \in \mathcal{S}$)

Soit $\{E_1, E_2, E_3, \dots, E_n\} \in \mathcal{S}$ un ensemble d'éléments mutuellement exclusifs et collectivement exhaustifs (ME&CE) (i.e. $E_i E_j = \emptyset, \forall i \neq j, \cup_{i=1}^n E_i = \mathcal{S}$)

$$\Pr(A) = \sum_{i=1}^n \underbrace{\Pr(A|E_i) \Pr(E_i)}_{=\Pr(AE_i)}$$

(Marginalisation)



Loi de probabilité totale (cont.)

RAPPEL: (ME&CE, $\cup_{i=1}^n E_i = S$, )

Loi de l'addition:

$$\Pr(E_1 \cup E_2 | A) = \Pr(E_1 | A) + \Pr(E_2 | A) - \Pr(E_1 E_2 | A)$$

Loi de la multiplication:

$$\Pr(E_1 E_2 | A) = \Pr(E_1 | E_2 A) \Pr(E_2 | A)$$

$$\Pr(A | B) = \sum_{i=1}^n \underbrace{\Pr(A | E_i B) \Pr(E_i | B)}_{= \Pr(A E_i | B)}$$

Théorème de Bayes


Soit $E_1, E_2, E_3, \dots, E_n$ un ensemble d'éléments mutuellement exclusifs et collectivement exhaustifs (ME&CE)

$$\left. \begin{aligned} \Pr(AE_i) &= \Pr(A|E_i) \Pr(E_i) \\ &= \Pr(E_i|A) \Pr(A) \end{aligned} \right\} \rightarrow \Pr(E_i|A) \Pr(A) = \Pr(A|E_i) \Pr(E_i)$$

$$\underbrace{\Pr(E_i|A)}_{\text{Probabilité à posteriori}} = \frac{\overbrace{\Pr(A|E_i)}^{\text{Fonction de vraisemblance}} \overbrace{\Pr(E_i)}^{\text{Probabilité à priori}}}{\underbrace{\Pr(A)}_{\text{constante de normalisation}}}$$

Théorème de Bayes:

$$\Pr(E_i|A) = \frac{\Pr(A|E_i) \Pr(E_i)}{\Pr(A)} = \frac{\Pr(\text{shaded } E_i)}{\Pr(\text{shaded } A)}$$



Constante de normalisation:

$$\Pr(A) = \sum_{i=1}^n \Pr(A|E_i) \Pr(E_i)$$

⚠ typiquement, $\Pr(A)$ est difficile à évaluer

Exemple – Probabilités conditionnelles & Bayes

Soit un séisme:

$$\mathcal{S}_{\text{intensité}} = \{\text{Léger (L)}, \text{Modéré (M)}, \text{Important (I)}\} \quad \text{🏠}$$

et une structure pouvant être dans l'un des deux états suivants:

$$\mathcal{S}_{\text{état}} = \{\text{endommagé (D)}, \neg \text{endommagé } (\bar{D})\} \quad \text{🏠}$$

On cherche $\Pr(D)$ sachant que

$$\left. \begin{array}{l} \Pr(D|L) = 0.01 \\ \Pr(D|M) = 0.10 \\ \Pr(D|I) = 0.60 \end{array} \right\} \text{ \& } \left. \begin{array}{l} \Pr(L) = 0.90 \\ \Pr(M) = 0.08 \\ \Pr(I) = 0.02 \end{array} \right\} \sum = 1$$

$$\begin{aligned} \Pr(D) &= \overbrace{\Pr(D|L) \Pr(L)}^{\Pr(DL)} + \overbrace{\Pr(D|M) \Pr(M)}^{\Pr(DM)} + \overbrace{\Pr(D|I) \Pr(I)}^{\Pr(DI)} \\ &= 0.01 \times 0.90 + 0.10 \times 0.08 + 0.6 \times 0.02 \\ &= 0.029 \end{aligned}$$

À l'inverse: si l'on **observe des dommages** sur une structure (état := D), quelle est la **probabilité de chaque intensité**?

$$\Pr(I|D) = \frac{\Pr(D|I) \Pr(I)}{\Pr(D)} = \frac{0.60 \times 0.02}{0.029} = 0.41$$

$$\Pr(M|D) = \frac{\Pr(D|M) \Pr(M)}{\Pr(D)} = \frac{0.10 \times 0.08}{0.029} = 0.28$$

$$\Pr(L|D) = \frac{\Pr(D|L) \Pr(L)}{\Pr(D)} = \frac{0.01 \times 0.90}{0.029} = 0.31$$



Plan de la section

X – **V.A.**

3.1 Introduction

3.2 Variables discrètes

3.3 Variables continues

3.4 Probabilités conditionnelles


Variables aléatoires (V.A.)

Représentation de l'espace d'échantillonnage \mathcal{S} sur une ligne

Notation:

X : Variable aléatoire

x : Réalisation d'une V.A.



La probabilité que la **variable aléatoire X** prenne une **valeur x** est décrite soit par une **fonction de masse (PMF)** ou une **densité de probabilité (PDF)**

Variables aléatoires discrètes

Fonction de masse (**PMF**): $p_X(x) = \Pr(X = x)$

Propriétés:

$$0 \leq p_X(x) \leq 1$$

$$\sum_x p_X(x) = 1$$


L'ensemble des valeurs possibles de x constitue un ensemble mutuellement exclusif et collectivement exhaustifs (ME&CE)

Variables aléatoires continues

Densité de probabilité (PDF): $f_X(x)$


$$\Pr(x < X \leq x + \Delta x) = f_X(x)\Delta x$$

$$\Pr(X = x) = 0$$



Densité de probabilité cumulative/fonction de répartition (CDF)

$$F_X(x) = \Pr(X \leq x) = \sum_{x' \leq x} p_X(x'), \quad (\text{V.A. discrète})$$



PDF \leftrightarrow CDF

Pour les V.A. continues

$$F_X(x) = \int_{-\infty}^x f_X(x) dx \leftrightarrow f_X(x) = \frac{dF_X(x)}{dx}$$

Pour les V.A. discrètes

$$p_X(x_i) = F_X(x_i) - F_X(x_{i-1})$$

Les **densités de probabilités communes**
seront vues au module #1

Probabilités conditionnelles & V.A. [☰]

Pour un évènement E et une variable aléatoire X ; la probabilité de E conditionnelle à la réalisation de l'évènement $\{X = x\}$ est:

$$\Pr(E|\{X = x\}) = \frac{\Pr(E \cap \{X = x\})}{\Pr(\{X = x\})}$$

Rappel:

$$\Pr(E_1|E_2) = \frac{\Pr(E_1 E_2)}{\Pr(E_2)}$$

$$\begin{aligned} \Pr(E|X = x) &= \frac{\Pr(E \cap X = x)}{\Pr(X = x)} \\ &= \frac{\Pr(X = x|E) \Pr(E)}{\Pr(X = x)} \end{aligned}$$

$$\Pr(E|x) = \frac{\Pr(x|E) \Pr(E)}{\Pr(x)}$$

Probabilités conditionnelles – évènements

Si X est une variable aléatoire **discrète**

$$\boxed{E|x} \rightarrow \Pr(E|x) = \frac{p_{X|E}(x|E) \Pr(E)}{p_X(x)}$$

$$\boxed{X|E} \rightarrow \Pr(X|E) = p_{X|E}(x|E) = \frac{\Pr(E|x)p_X(x)}{\Pr(E)}$$

Si X est une variable aléatoire **continue**

$$\boxed{E|x} \rightarrow \Pr(E|x) = \frac{f_{X|E}(x|E) \Pr(E)}{f_X(x)}$$

$$\boxed{X|E} \rightarrow f_{X|E}(x|E) = \frac{\Pr(E|x)f_X(x)}{\Pr(E)}$$



Plan de la section

X – V.A.M.

4.1 Introduction

4.2 Densités de probabilité

4.3 Probabilités conditionnelles

Variables aléatoires multiples

Soit $\mathbf{X} = [X_1, X_2, \dots, X_n]^T$ $\left\{ \begin{array}{l} \text{vecteur (colonne)} \\ \text{de variable} \\ \text{aléatoires} \end{array} \right.$

Soit $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ $\left\{ \begin{array}{l} \text{vecteur (colonne)} \\ \text{représentant une} \\ \text{réalisation de } \mathbf{X} \end{array} \right.$

X décrit l'occurrence simultanée de plusieurs phénomènes

Densités de probabilité multivariées **discrètes** (PMF)

Définition:

- ▶ $p_{\mathbf{X}}(\mathbf{x}) = \Pr(X_1 = x_1 \cap X_2 = x_2 \cap \cdots \cap X_n = x_n)$
- ▶ $0 \leq p_{\mathbf{X}}(\mathbf{x}) \leq 1$

Marginalisation:

- ▶ $\sum_{x_n} p_{X_1, \dots, X_n}(x_1, \dots, x_n) = p_{X_1, \dots, X_{n-1}}(x_1, \dots, x_{n-1})$
- ▶ $\sum_{x_1} \cdots \sum_{x_n} p_{\mathbf{X}}(\mathbf{x}) = 1$


$p_{X_i}(x_i)$: **Fonction de masse marginale**

Exemple – marginalisation

Soit deux V.A. discrètes $X_1 \perp\!\!\!\perp X_2$

$$p_{X_1}(x_1) \begin{cases} p_{X_1}(1) = 0.1 \\ p_{X_1}(2) = 0.5 \\ p_{X_1}(3) = 0.4 \end{cases}$$

$$p_{X_2}(x_2) \begin{cases} p_{X_2}(1) = 0.8 \\ p_{X_2}(2) = 0.15 \\ p_{X_2}(3) = 0.05 \end{cases}$$



$$p_{X_1 X_2}(x_1, x_2) = p_{X_1}(x_1) \cdot p_{X_2}(x_2)$$

$$p_{X_1 X_2}(x_1, x_2) = \begin{cases} \begin{array}{c|ccc} & x_1 = 1 & x_1 = 2 & x_1 = 3 \\ \hline x_2 = 1 & 0.08 & 0.4 & 0.32 \\ x_2 = 2 & 0.015 & 0.075 & 0.06 \\ x_2 = 3 & 0.005 & 0.025 & 0.02 \\ \hline \sum_{i=1}^3 p_{X_1 X_2}(x_1, i) & 0.1 & 0.5 & 0.4 \end{array} \end{cases}$$

Densités de probabilité multivariées continues (PDF)

Définition:

- ▶ $f_{\mathbf{X}}(\mathbf{x})\Delta\mathbf{x} = \Pr(x_1 < X_1 \leq x_1 + \Delta x_1 \cap \dots \cap x_n < X_n \leq x_n + \Delta x_n)$
- ▶ $0 \leq f_{\mathbf{X}}(\mathbf{x})$ Δ peut être > 1

Marginalisation:

- ▶ $\int_{-\infty}^{\infty} f_{X_1, \dots, X_n}(x_1, \dots, x_n) dx_n = f_{X_1, \dots, X_{n-1}}(x_1, \dots, x_{n-1})$
- ▶ $\int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f_{\mathbf{X}}(\mathbf{x}) d\mathbf{x} = 1$

$f_{X_i}(x_i)$: Densité de probabilité marginale

Loi normale bi-variée (PDF) 

Densité de probabilité (PDF) pour 2 variables aléatoires X_1, X_2

$$f_{X_1, X_2}(x_1, x_2) = \frac{1}{2\pi\sigma_{X_1}\sigma_{X_2}\sqrt{1-\rho^2}} \exp \left\{ -\frac{1}{2(1-\rho^2)} \left[\left(\frac{x_1 - \mu_{X_1}}{\sigma_{X_1}} \right)^2 + \left(\frac{x_2 - \mu_{X_2}}{\sigma_{X_2}} \right)^2 - 2\rho \left(\frac{x_1 - \mu_{X_1}}{\sigma_{X_1}} \right) \left(\frac{x_2 - \mu_{X_2}}{\sigma_{X_2}} \right) \right] \right\}$$

5 paramètres: $\mu_{X_1}, \sigma_{X_1}, \mu_{X_2}, \sigma_{X_2}, \rho$

Loi normale bi-variée (PDF)

5 paramètres:

$\mu_{X_1}, \sigma_{X_1}, \mu_{X_2}, \sigma_{X_2}, \rho$

$$\mu = \begin{bmatrix} \mu_{X_1} \\ \mu_{X_2} \end{bmatrix}, \quad \Sigma = \begin{bmatrix} \sigma_{X_1}^2 & \rho\sigma_{X_1}\sigma_{X_2} \\ \rho\sigma_{X_1}\sigma_{X_2} & \sigma_{X_2}^2 \end{bmatrix}$$

$$\mathbf{X} \sim \mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$$



$$\mu_{X_1} = 0$$

$$\sigma_{X_1} = 2$$

$$\mu_{X_2} = 0$$

$$\sigma_{X_2} = 1$$

$$\rho = 0.6$$



Fonctions de répartition multivariées **continues** (CDF)

Définition:

- ▶ $F_{\mathbf{X}}(\mathbf{x}) = \Pr(X_1 \leq x_1 \cap \dots \cap X_n \leq x_n)$
- ▶ $0 \leq F_{\mathbf{X}}(\mathbf{x}) \leq 1$
- ▶ $F_{X_1, \dots, X_{n-1}, X_n}(x_1, \dots, x_{n-1}, -\infty) = 0$
- ▶ $F_{X_1, \dots, X_{n-1}, X_n}(+\infty, \dots, +\infty, +\infty) = 1$

Marginalisation: ($F_{X_1 X_2}(x_1, +\infty) = F_{X_1}(x_1)$)

- ▶ $F_{X_1, \dots, X_{n-1}, X_n}(x_1, \dots, x_{n-1}, +\infty) = F_{X_1, \dots, X_{n-1}}(x_1, \dots, x_{n-1})$



$$F_{\mathbf{X}}(\mathbf{x}) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_n} f_{\mathbf{X}}(\mathbf{x}) d\mathbf{x}, \quad f_{\mathbf{X}}(\mathbf{x}) d\mathbf{x} = \frac{\partial^n F_{\mathbf{X}}(\mathbf{x})}{\partial x_1 \dots \partial x_n}$$

Loi normale bi-variée (CDF)

Densité de probabilité cumulative (CDF) pour 2 variables aléatoires X_1, X_2

$$F_{X_1, X_2}(x_1, x_2) = \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} f_{X_1, X_2}(x_1, x_2) dx dy$$

$$\begin{aligned} \mu_{X_1} &= 0 \\ \sigma_{X_1} &= 2 \\ \mu_{X_2} &= 0 \\ \sigma_{X_2} &= 1 \\ \rho &= 0.6 \end{aligned}$$



Probabilités conditionnelles – discrètes

Si X_i est une variable aléatoire **discrète**

$$p_{X_1 X_2}(x_1, x_2) = p_{X_1|X_2}(x_1|x_2)p_{X_2}(x_2) = p_{X_2|X_1}(x_2|x_1)p_{X_1}(x_1)$$

$$\boxed{X_1|x_2} \rightarrow p_{X_1|X_2}(x_1|x_2) = \frac{p_{X_2|X_1}(x_2|x_1)p_{X_1}(x_1)}{p_{X_2}(x_2)}$$

$$\boxed{X_2|x_1} \rightarrow p_{X_2|X_1}(x_2|x_1) = \frac{p_{X_1|X_2}(x_1|x_2)p_{X_2}(x_2)}{p_{X_1}(x_1)}$$

Probabilités conditionnelles – discrètes

X_1 et X_2 sont statistiquement indépendantes (\perp) si

$$p_{X_1|X_2}(x_1|x_2) = p_{X_1}(x_1)$$

si $X_1 \perp X_2 \perp \dots \perp X_n$

$$p_{X_1 \dots X_n}(x_1, \dots, x_n) = p_{X_1}(x_1) p_{X_2}(x_2) \dots p_{X_n}(x_n)$$

Cas général: X_1 et X_2 **pas** statistiquement indépendantes

→ **dérivation en chaîne**

$$p_{X_1 \dots X_n}(x_1, \dots, x_n) = p_{X_1|X_2 \dots X_n}(x_1|x_2, \dots, x_n) \dots p_{X_{n-1}|X_n}(x_{n-1}|x_n) p_{X_n}(x_n)$$

$$\text{e.g. } p_{X_1 X_2 X_3}(x_1, x_2, x_3) = p_{X_1|X_2 X_3}(x_1|x_2, x_3) \cdot p_{X_2|X_3}(x_2|x_3) \cdot p_{X_3}(x_3)$$

Probabilités conditionnelles – continues

Exactement la même chose que pour les V.A. discrètes

$$p_X(x) \rightarrow f_X(x)$$



Plan de la section

$\mathbb{E}(X)$

5.1 Définition

5.2 Moments d'ordre m

5.3 Variance

5.4 Covariance

5.5 Notation matricielle

Espérance mathématique (expected value)

Espérance mathématique: Somme pondérée de toutes les valeurs possibles d'une variable aléatoire

$$\mathbb{E}[X] = \int_{-\infty}^{\infty} x \cdot f_X(x) dx \quad (\text{V.A. continue})$$

$$\mathbb{E}[X] = \sum x \cdot p_X(x) dx \quad (\text{V.A. discrète})$$

L'espérance est une **opération linéaire**

$$\mathbb{E}[g(\mathbf{X})] = \int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} g(\mathbf{x}) \cdot f_{\mathbf{X}}(\mathbf{x}) d\mathbf{x}$$

Moments

Moment d'ordre m : $\mathbb{E}[X^m]$

$$\mathbb{E}[X^m] = \int_{-\infty}^{\infty} x^m f_X(x) dx$$

Pour $m = 1$: $\mathbb{E}[X] = \mu_X$ (**espérance / centre de gravité**)

Pour $m = 2$: $\mathbb{E}[X^2]$ (espérance des carrés)

Moments centrés d'ordre m : $\mathbb{E}[(X - \mu_X)^m]$

$$\mathbb{E}[(X - \mu_X)^m] = \int_{-\infty}^{\infty} (x - \mu_X)^m f_X(x) dx$$

Pour $m = 1$: $\mathbb{E}[(X - \mu_X)^1] = 0$

Pour $m = 2$: $\mathbb{E}[(X - \mu_X)^2] = \sigma_X^2 = \text{var}[X]$ (**variance / inertie**)

Variance – $\mathbb{E}[(X - \mu_X)^2]$

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

$\text{var}[X]$: La variance mesure la dispersion de la densité de probabilité. Concept analogue à l'inertie d'une poutre.

σ_X : Écart-type

$\delta_X = \frac{\sigma_X}{\mu_X}$: coefficient de variation (C.O.V.).

Mesure adimensionnelle de la dispersion ($\Delta \mu_X \neq 0$)

Covariance – $\mathbb{E}[(X_i - \mu_i)(X_j - \mu_j)]$


Soit deux variables aléatoires X_i, X_j

$$\text{cov}[X_i X_j] = \mathbb{E}[(X_i - \mu_i)(X_j - \mu_j)] = \mathbb{E}[X_i X_j] - \mathbb{E}[X_i]\mathbb{E}[X_j]$$

ρ_{ij} : coefficient de corrélation.

(Quantifie la **dépendance linéaire** entre X_i et X_j)

$$\rho_{ij} = \frac{\text{cov}[X_i X_j]}{\sigma_i \sigma_j}, \quad -1 \leq \rho_{ij} \leq +1$$



▶ $X_i \perp X_j \implies \rho_{ij} = 0$

▶ $\rho_{ij} = 0 \not\Rightarrow X_i \perp X_j \triangle$

▶ correlation $\not\Rightarrow$ causalité \triangle

[onlinestatbook.com, Wikipedia]

Covariance – $\mathbb{E}[(X_i - \mu_i)(X_j - \mu_j)]$


Soit deux variables aléatoires X_i, X_j

$$\text{cov}[X_i X_j] = \mathbb{E}[(X_i - \mu_i)(X_j - \mu_j)] = \mathbb{E}[X_i X_j] - \mathbb{E}[X_i]\mathbb{E}[X_j]$$

ρ_{ij} : coefficient de corrélation.

(Quantifie la **dépendance linéaire** entre X_i et X_j)

$$\rho_{ij} = \frac{\text{cov}[X_i X_j]}{\sigma_i \sigma_j}, \quad -1 \leq \rho_{ij} \leq +1$$



▶ $X_i \perp\!\!\!\perp X_j \implies \rho_{ij} = 0$

▶ $\rho_{ij} = 0 \not\implies X_i \perp\!\!\!\perp X_j \triangle$

▶ correlation $\not\iff$ causalité \triangle

[onlinestatbook.com, Wikipedia]

Notation matricielle

Soit n variables aléatoires $\mathbf{X} = [X_1, X_2, \dots, X_n]^T$ où,

$\mathbf{M}_X = [\mu_1, \mu_2, \dots, \mu_n]^T$ est un vecteur contenant les moyennes,

\mathbf{D}_{XX} est la matrice contenant les écarts-types, \mathbf{R}_{XX} est la matrice de corrélation, et $\mathbf{\Sigma}_{XX}$ est la matrice de covariance.

$$\mathbf{D}_{XX} = \begin{bmatrix} \sigma_{X_1} & 0 & 0 & 0 \\ & \sigma_{X_2} & 0 & 0 \\ & & \ddots & 0 \\ \text{sym.} & & & \sigma_{X_n} \end{bmatrix}, \quad \mathbf{R}_{XX} = \begin{bmatrix} 1 & \rho_{12} & \cdots & \rho_{1n} \\ & 1 & \cdots & \rho_{2n} \\ & & \ddots & \rho_{n-1n} \\ \text{sym.} & & & 1 \end{bmatrix}$$

$$\mathbf{\Sigma}_{XX} = \mathbf{D}_{XX} \mathbf{R}_{XX} \mathbf{D}_{XX} = \begin{bmatrix} \sigma_{X_1}^2 & \rho_{12} \sigma_{X_1} \sigma_{X_2} & \cdots & \rho_{1n} \sigma_{X_1} \sigma_{X_n} \\ & \sigma_{X_2}^2 & \cdots & \rho_{2n} \sigma_{X_2} \sigma_{X_n} \\ & & \ddots & \vdots \\ \text{sym.} & & & \sigma_{X_n}^2 \end{bmatrix}$$



Plan de la section

$g(\mathbf{X})$

6.1 Définition

6.2 Règle de transformation

Fonctions de variables aléatoires – $g(\mathbf{X})$

Soit $\mathbf{X} = [X_1, X_2, \dots, X_n]^T$ défini par le PDF $f_{\mathbf{X}}(\mathbf{x})$, et soit $\mathbf{Y} = [Y_1, Y_2, \dots, Y_m]^T$ obtenu à partir d'une fonction

$$\mathbf{Y} = \mathbf{g}(\mathbf{X}) = \begin{bmatrix} g_1(\mathbf{X}) \\ g_2(\mathbf{X}) \\ \vdots \\ g_m(\mathbf{X}) \end{bmatrix}$$

Question: déterminer la densité de probabilité $f_{\mathbf{Y}}(\mathbf{y})$,

3 cas:

1. $m = n = 1$
2. $m = n > 1$
3. $m = 1, n > 1$

On s'intéresse aux
fonctions linéaires
 i.e. $Y_k = g_k(X) = aX_k + b$


$Y = g(X)$: Cas 1, $m = n = 1$

$$f_Y(y)dy = f_X(x)dx$$

$$f_Y(y) = \underbrace{f_X(x)}_{f_X(x) \geq 0} \left| \frac{dx}{dy} \right|$$

Pour $Y = aX + b$

$$\left| \frac{dy}{dx} \right| = |a|$$



$$\{X : \mu_X, \sigma_X\} \rightarrow \{Y : a\mu_X + b, |a|\sigma_X\}$$


Exemple: Cas 1, $Y = 2X$

Variable aléatoire:

$$X \sim \mathcal{N}(\underbrace{10}_{\mu_X}, \underbrace{5^2}_{\sigma_X^2})$$

$$f_X(x) = \frac{1}{\sqrt{2\pi}\sigma_X} \exp\left[-\frac{1}{2}\left(\frac{x-\mu_X}{\sigma_X}\right)^2\right]$$

$$\frac{dy}{dx} = 2$$



Transformation $X \rightarrow Y$:

$$f_Y(y) = f_X(x) \left| \frac{dx}{dy} \right| = f_X(x) \left| \frac{dy}{dx} \right|^{-1} = f_X\left(\underbrace{\frac{y}{2}}_{x=y/2}\right) \cdot \frac{1}{2}$$


$$f_Y(y) = \frac{1}{2\sqrt{2\pi}\sigma_X} \exp\left[-\frac{1}{2}\left(\frac{\frac{y}{2} - \mu_X}{\sigma_X}\right)^2\right], \quad Y \sim \mathcal{N}(\underbrace{2\mu_X}_{\mu_Y}, \underbrace{(2\sigma_X)^2}_{\sigma_Y^2})$$

Exemple: Cas 1, $Y = 2X$ **Variable aléatoire:**

$$X \sim \mathcal{N}(\underbrace{10}_{\mu_X}, \underbrace{5^2}_{\sigma_X^2})$$

$$f_X(x) = \frac{1}{\sqrt{2\pi}\sigma_X} \exp\left[-\frac{1}{2}\left(\frac{x-\mu_X}{\sigma_X}\right)^2\right]$$

$$\frac{dy}{dx} = 2$$

**Transformation $X \rightarrow Y$:**


$$f_Y(y) = f_X(x) \left| \frac{dx}{dy} \right| = f_X(x) \left| \frac{dy}{dx} \right|^{-1} = f_X\left(\underbrace{\frac{y}{2}}_{x=y/2}\right) \cdot \frac{1}{2}$$

$$f_Y(y) = \frac{1}{\sqrt{2\pi}2\sigma_X} \exp\left[-\frac{1}{2}\left(\frac{y-2\mu_X}{2\sigma_X}\right)^2\right], \quad Y \sim \mathcal{N}(\underbrace{2\mu_X}_{\mu_Y}, \underbrace{(2\sigma_X)^2}_{\sigma_Y^2})$$


Exemple: $Y = 2X$ (cont.)

$$X \sim \mathcal{N}(\underbrace{10}_{\mu_X}, \underbrace{5^2}_{\sigma_X^2})$$

$$Y \sim \mathcal{N}(\underbrace{2\mu_X}_{\mu_Y}, \underbrace{(2\sigma_X)^2}_{\sigma_Y^2})$$



Y = g(X) : Cas 2, m = n > 1



Jacobien (J_{y,x}): taille du “voisinage” de dy par rapport à dx

$$\mathbf{J}_{y,x} = \begin{bmatrix} J_{y_1,x_1} & \cdots & J_{y_1,x_n} \\ \vdots & \ddots & \vdots \\ J_{y_m,x_1} & \cdots & J_{y_m,x_n} \end{bmatrix} = \begin{bmatrix} \nabla g_1(\mathbf{x}) \\ \vdots \\ \nabla g_n(\mathbf{x}) \end{bmatrix}$$

$$\frac{dx}{dy} = |\det \mathbf{J}_{y,x}|^{-1}$$

$$\frac{dy}{dx} = |\det \mathbf{J}_{y,x}|$$

$$f_X(\mathbf{x}) dx = f_Y(\mathbf{y}) dy$$

$$f_X(\mathbf{x}) \frac{dx}{dy} = f_Y(\mathbf{y})$$

$$J_{k,i} = J_{y_k,x_i} = \frac{\partial y_k}{\partial x_i}$$

$$f_Y(\mathbf{y}) = f_X(\mathbf{x}) |\det \mathbf{J}_{y,x}|^{-1}$$

$\mathbf{Y} = \mathbf{g}(\mathbf{X})$: Cas 2, $m = n > 1$ (cont.)

Soit une fonction linéaire $\mathbf{Y} = \mathbf{g}(\mathbf{X}) = \mathbf{A}\mathbf{X} + \mathbf{b}$ où

$$\mathbf{X} = \begin{bmatrix} X_1 \\ \vdots \\ X_n \end{bmatrix}, \quad \mathbf{M}_X = \begin{bmatrix} \mu_{X_1} \\ \vdots \\ \mu_{X_n} \end{bmatrix}, \quad \boldsymbol{\Sigma}_{XX} = \begin{bmatrix} \sigma_{X_1}^2 & \cdots & \rho_{1n}\sigma_{X_1}\sigma_{X_n} \\ \vdots & \ddots & \vdots \\ \text{sym.} & & \sigma_{X_n}^2 \end{bmatrix}$$

$$\underbrace{\begin{bmatrix} \\ \\ \end{bmatrix}}_{\mathbf{Y}}^{n \times 1} = \underbrace{\begin{bmatrix} \\ \\ \end{bmatrix}}_{\mathbf{A} = \mathbf{J}_{y,x}}^{n \times n} \times \underbrace{\begin{bmatrix} \\ \\ \end{bmatrix}}_{\mathbf{X}}^{n \times 1} + \underbrace{\begin{bmatrix} \\ \\ \end{bmatrix}}_{\mathbf{b}}^{n \times 1}$$

$$\mathbf{M}_Y = \mathbf{g}(\mathbf{M}_X) = \mathbf{A}\mathbf{M}_X + \mathbf{b}$$

$$\boldsymbol{\Sigma}_{YY} = \mathbf{A}\boldsymbol{\Sigma}_{XX}\mathbf{A}^T = \mathbf{J}_{y,x}\boldsymbol{\Sigma}_{XX}\mathbf{J}_{y,x}^T$$

$Y = g(\mathbf{X})$: Cas 3, $m = 1, n > 1$

Soit une fonction linéaire $Y = g(\mathbf{X}) = \mathbf{A}\mathbf{X} + b$ où

$$\mathbf{x} = \begin{bmatrix} X_1 \\ \vdots \\ X_n \end{bmatrix}, \quad \mathbf{M}_x = \begin{bmatrix} \mu_{X_1} \\ \vdots \\ \mu_{X_n} \end{bmatrix}, \quad \Sigma_{xx} = \begin{bmatrix} \sigma_{X_1}^2 & \cdots & \rho_{1n}\sigma_{X_1}\sigma_{X_n} \\ \vdots & \ddots & \vdots \\ \text{sym.} & & \sigma_{X_n}^2 \end{bmatrix}$$

$$\underbrace{\begin{bmatrix} \end{bmatrix}}_{\mathbf{Y}}_{1 \times 1} = \underbrace{\begin{bmatrix} \end{bmatrix}}_{\mathbf{A} = \nabla g(\mathbf{x})}_{1 \times N} \times \underbrace{\begin{bmatrix} \end{bmatrix}}_{\mathbf{x}}_{N \times 1} + \underbrace{\begin{bmatrix} \end{bmatrix}}_{b}_{1 \times 1}$$

$$\begin{aligned} \mu_Y &= g(\mathbf{M}_x) = \mathbf{A}\mathbf{M}_x + b \\ \sigma_Y^2 &= \nabla g(\mathbf{X})\Sigma_{xx}\nabla g(\mathbf{X})^T \\ &= \mathbf{A}\Sigma_{xx}\mathbf{A}^T \end{aligned}$$

où $\nabla g(\mathbf{x}) = \underbrace{\left[\frac{\partial g(\mathbf{x})}{\partial x_1}, \dots, \frac{\partial g(\mathbf{x})}{\partial x_n} \right]}_{\text{Gradient}}_{\mathbf{x}}$

Fonctions non-linéaires: $Y = g(\mathbf{X})$

Que fait-on si $g(\mathbf{X})$ est non-linéaire? On linéarise.

$$Y = g(\mathbf{X}) \approx \mathbf{AX} + \mathbf{b}$$



Plan de la section

Linéarisation

7.1 Définition


7.2 Série de Taylor

7.3 Approximation du premier ordre

7.4 Importance des variables

Linéarisation

On remplace $g(X)$ par une fonction linéaire (e.g. une droite)




Linéarisation autour
de la moyenne μ_x
**⚠ contenu de
probabilité élevé**

$$\underbrace{\nabla g(\mu_x) = \left[\frac{dg(x)}{dx} \right]_{x=\mu_x}}_{\text{Gradient}}$$

Linéarisation

On remplace $g(X)$ par une fonction linéaire (e.g. une droite)




Linéarisation autour
de la moyenne μ_x
**⚠ contenu de
probabilité élevé**

$$\underbrace{\nabla g(\mu_x) = \left[\frac{dg(x)}{dx} \right]_{x=\mu_x}}_{\text{Gradient}}$$

Linéarisation

On remplace $g(X)$ par une fonction linéaire (e.g. une droite)



Linéarisation autour
de la moyenne μ_x
**⚠ contenu de
probabilité élevé**

$$\underbrace{\nabla g(\mu_x) = \left[\frac{dg(x)}{dx} \right]_{x=\mu_x}}_{\text{Gradient}}$$

Linéarisation – Série de Taylor développée autour de \mathbf{M}_X

Soit une fonction **non-linéaire** $Y = g(\mathbf{X}) \approx \mathbf{A}\mathbf{X} + \mathbf{b}$

$$\begin{array}{c}
 \text{approximation du } 2^{\text{eme}} \text{ ordre} \\
 \underbrace{\hspace{15em}} \\
 Y \approx \underbrace{g(\mathbf{M}_X) + \overbrace{\nabla g(\mathbf{M}_X)}^{\text{Gradient}} (\mathbf{X} - \mathbf{M}_X)}_{\text{approximation du } 1^{\text{er}} \text{ ordre}} + \frac{1}{2} (\mathbf{X} - \mathbf{M}_X)^T \overbrace{\mathbf{H}(\mathbf{M}_X)}^{\text{Hessien}} (\mathbf{X} - \mathbf{M}_X) + \dots \\
 \underbrace{\hspace{15em}} \\
 \text{approximation du } N^{\text{eme}} \text{ ordre}
 \end{array}$$

Note: Pour une fonction non-linéaire, le gradient/Jacobien varie en fonction du point où il est évalué $\rightarrow \nabla \mathbf{G}(\mathbf{M}_X) / \mathbf{J}_{Y,X}(\mathbf{M}_X)$

Linéarisation – Approximation du premier ordre

Approximation du premier ordre centré sur la moyenne \equiv
linéarisation de $g(\mathbf{X})$ à \mathbf{M}_X

$$Y = g(\mathbf{X}) \cong g(\mathbf{M}_X) + \nabla g(\mathbf{M}_X)(\mathbf{X} - \mathbf{M}_X)$$

$$\mu_Y \cong g(\mathbf{M}_X)$$

$$\sigma_Y^2 \cong \nabla g(\mathbf{M}_X) \boldsymbol{\Sigma}_{XX} \nabla g(\mathbf{M}_X)^\top$$

où

$$\underbrace{\nabla g(\mathbf{M}_X) = \left[\frac{\partial g(\mathbf{x})}{\partial x_1}, \dots, \frac{\partial g(\mathbf{x})}{\partial x_n} \right]_{\mathbf{x}=\mathbf{M}_X}}_{\text{Gradient}}$$

Importance des variables, $\text{Imp}(X_i \rightarrow Y)$

$$\text{Imp}(X_i \rightarrow Y) \propto |a_i| \sigma_{X_i}$$

$$\underbrace{\begin{bmatrix} a_1 & \cdots & a_n \end{bmatrix}}_{\mathbf{A} = \left[\frac{\partial y}{\partial x_i} \right] = \nabla g(\mathbf{x})}_{1 \times n} \quad \Sigma_{\mathbf{X}\mathbf{X}} = \begin{bmatrix} \sigma_{X_1}^2 & \cdots & \rho_{1n} \sigma_{X_1} \sigma_{X_n} \\ & \ddots & \vdots \\ \text{sym.} & & \sigma_{X_n}^2 \end{bmatrix}$$

Résumé

Probabilités:

- ▶ Les probabilités **représentent notre connaissance**
- ▶ Le moins on en sait, le plus on devrait utiliser les probabilités

Interpretation Bayésienne: $\Pr(E_i)$ est une mesure de vraisemblance par rapport aux autres événements dans \mathcal{S}

Lois/opération événements: $\cap, \cup, \subset, \subseteq, \in$

Axiomes fondamentaux:

- $0 \leq \Pr(E_i) \leq 1$
- $\Pr(\mathcal{S}) = 1$
- Si E_1 et E_2 sont mutuellement exclusifs
 $\Pr(E_1 \cup E_2) = \Pr(E_1) + \Pr(E_2)$

Loi d'inclusion-exclusion: $\Pr(\bigcup_{i=1}^n E_i) = \dots$

Théorème de Bayes: $\Pr(E_j|A) = \frac{\Pr(A|E_j)\Pr(E_j)}{\Pr(A)}$

Densités de probabilités: PDF, CDF, PMF, CMF

Normale multivariée: $\mu_1, \sigma_1, \mu_2, \sigma_2, \rho_{12}$

Densités de probabilité multivariées:

- ▶ $0 \leq f_X(x)$
- ▶ $\int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f_X(x) dx = 1$

Probabilités conditionnelles:

- ▶ si $p_{X_1|X_2}(x_1|x_2) = p_{X_1}(x_1)$, $X_1 \perp\!\!\!\perp X_2$
- ▶ si $X_1 \perp\!\!\!\perp X_2$ $p_{X_1 X_2}(x_1, x_2) = p_{X_1}(x_1)p_{X_2}(x_2)$

Cas général: $X_1 \not\perp\!\!\!\perp X_2 \rightarrow$ **dérivation en chaîne**

Espérance & Variance:

$$\mathbb{E}[X] = \int_{-\infty}^{\infty} x \cdot f_X(x) dx \quad (\text{V.A. continue})$$

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

Notation matricielle: $\Sigma_{XX} = D_{XX} R_{XX} D_{XX}$

Fonctions de variables aléatoires: $Y = g(X)$

$$f_Y(y) dy = f_X(x) dx$$

$$M_Y = g(M_X) = AM_X + b$$

$$\Sigma_{YY} = A \Sigma_{XX} A^T = J_{y,x} \Sigma_{XX} J_{y,x}^T$$

Linéarisation – Approximation du premier ordre

$$\begin{aligned} Y = g(X) &\cong g(M_X) + \nabla g(M_X)(X - M_X) \\ \mu_Y &\cong g(M_X) \\ \sigma_Y^2 &\cong \nabla g(M_X) \Sigma_{XX} \nabla g(M_X)^T \end{aligned}$$

Importance des variables

$$\text{Imp}(X_i \rightarrow Y) \propto |a_i| \sigma_{X_i}$$

