

INTRODUCTION à l'INTELLIGENCE ARTIFICIELLE

PASS LYON EST 2025-2026

Pr Pascal Roy MD PhD
31 Octobre 2025



Lyon Recherche Innovation contre le CANcer

Université Claude Bernard Lyon 1



Hospices Civils de Lyon

AURAGEN



1. VARIABILITE

Une Problématique (1)

Un patient n'est jamais identique à un autre !

sa maladie, sa réponse au traitement, son pronostic, tout varie

→ **Comment Analyser, Comprendre, Décider**
dans un monde où la variabilité est la règle ?


Une Problématique (2)

Si les patients étaient identiques entre eux, il n'y aurait pas besoin de biostatistique – mais il n'y aurait pas de médecine non plus : un médecin disposant de la « notice de fonctionnement de l'homme » y suffirait.

Valleron AJ *Préface*. Beuscart R, Benichou J, Roy P, Quantin C. *Biostatistique*, Omniscience[®]


2. ESTIMATION

Modèle Linéaire



Modèle linéaire et Moindres Carrés Ordinaires

Choisir la droite qui minimise la somme des carrés des écarts e_i



Estimation et estimateur des MCO

Choisir les paramètres de sorte que

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \mu_i)^2 = \sum_{i=1}^n [y_i - (\beta_0 + \beta_1 x_i)]^2 \text{ soit le plus petit possible}$$

Les valeurs $\hat{\beta}_0, \hat{\beta}_1$ qui rendent minimale cette somme

des carrés des écarts sont les **estimations des paramètres.**

La fonction qui associe *ces valeurs des paramètres* à un *échantillon* s'appelle un **estimateur.**

C'est donc une fonction qui mesure "l'accord" des données avec la valeur des paramètres.



Méthode des Moindres Carrés Ordinaires

Principe

- Minimiser les écarts e_i
- Eviter que les écarts positifs et négatifs ne se compensent
- $E = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - b_0 - b_1 \cdot x_i)^2$

Résolution


$$\begin{cases} \frac{\partial E}{\partial b_1} = 0 \\ \frac{\partial E}{\partial b_0} = 0 \end{cases}$$

Une solution unique $\begin{cases} b_1 = \frac{s_{XY}}{s_X^2} \\ b_0 = m_Y - b_1 \cdot m_X \end{cases}$

Vraisemblance

- La vraisemblance de **la valeur d'un paramètre** est la probabilité des données si le paramètre a cette valeur
 - C'est donc une quantité qui mesure « l'accord » des données avec la valeur de ce paramètre
- La méthode du **maximum de vraisemblance** consiste à choisir pour estimation du (ou des) paramètre(s) la valeur qui a la vraisemblance maximale
 - C'est donc une méthode générale de construction d'estimateurs
- La **Vraisemblance d'un modèle** est la vraisemblance des estimations du maximum de vraisemblance de ses paramètres

Poids à la naissance / Age gestationnel



Maximum de vraisemblance du modèle linéaire

Pour les modèles linéaires, les estimations du maximum de vraisemblance sont identiques à celles moindres carrés. Il est donc possible d'utiliser l'une ou l'autre des méthodes.

Lorsque le modèle n'est pas linéaire, il n'est plus possible d'utiliser la méthode des moindres carrés. Les valeurs des paramètres du modèle sont estimées en maximisant la vraisemblance.

ESTIMATION DES PARAMETRES (β_j) DES MODELES

Linéaire

$$Y = \beta_0 + \sum \beta_j X_j + \varepsilon$$

Diagnostic (ex logistique)

$$\log\left(\frac{P}{1-P}\right) = \beta_0 + \sum \beta_j X_j + \varepsilon$$

Pronostique (ex modèle de survie de Cox)


$$\log\left(\frac{\lambda(t,X)}{\lambda(t,0)}\right) = \sum \beta_j X_j + \varepsilon$$

Théranostique (avec interaction)

... plus tard dans le cursus ...

3. PART DE VARIANCE EXPLIQUEE

Variance totale et Variance expliquée



4. BIG DATA

Données de Grandes Dimensions

Les données – La data

Grand nombre d'observations (n)

Entrepôts de données

Assurance maladie

Grand nombre de variables (m)

Biologie moléculaire (omics)

Imagerie médicale (radiomique)



Grand nombre d'observations et de variables (n et m)

Omics ($m \gg n$)

3×10^9 bases d'ADN (Génome entier)
GWAS $0.5-2 \times 10^6$ SNP

22 000 gènes (puces à ADN)

Quelques centaines de protéines
Analysées (sur un bien plus grand
nombre)



COMPRENDRE LE BIAIS D'OPTIMISME

		Décision		
		H ₀ non rejetée	H ₀ rejetée	
Réalité	H ₀ vraie	U	V	m₀
	H ₀ fausse	T	<u>S</u>	<u>m₁</u>
		m-R	R	m

Table 1. Répartition des résultats des différents tests effectués

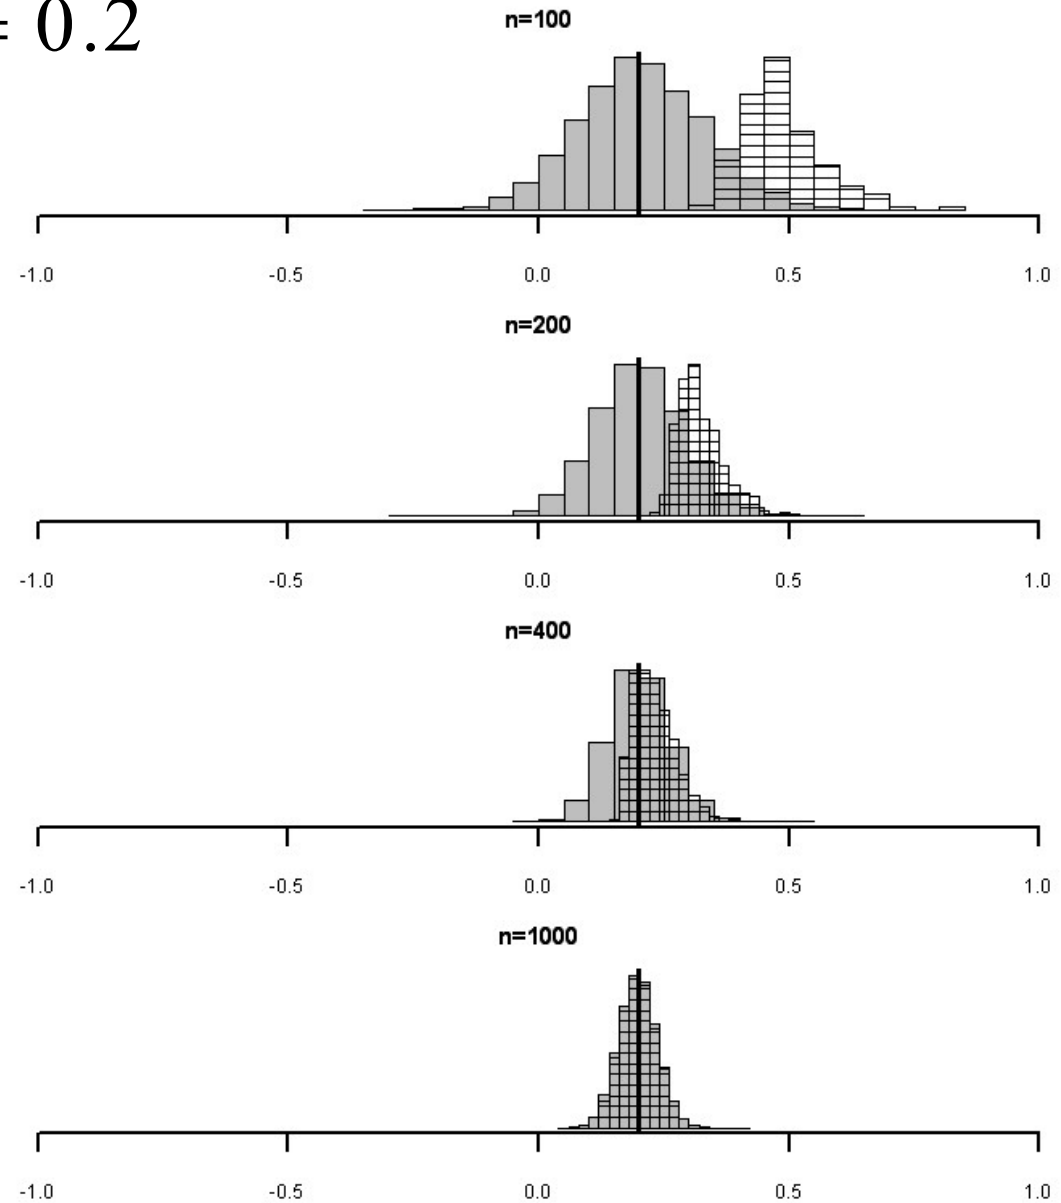
$$\beta = 0.2$$

Biais d'optimisme des Etudes d'identification

Ω_{m1}



Ω_S



Méthodes Pénalisées

Méthodes LASSO, RIDGE, etc ...

LASSO et RIDGE « rétrécissent » les valeurs absolues des paramètres

LASSO sélectionne des variables (certains paramètres sont mis à zéro)

5. INTELLIGENCE ARTIFICIELLE

Intelligence

faculté d'adaptation à l'environnement

→ apprentissage


Intelligence Artificielle

Résoudre des problématiques simples
ou complexes à l'aide de modèles usuels
et de réseaux de neurones

Extraction d'information à partir des données +++

« Central Intelligence Agency » (CIA)
se traduit

« Agence Centrale de Renseignement » !!!



Musée Rodin, Jean de Calan ®


Historique

Travaux de cryptanalyse

→ enigma Jerzy Rozycki
 Marian Rejewski
 Alan Turing



Deep Blue IBM® (IBM.COM)
(Garry Kasparov en 1997)



Bombe Electromécanique de Turing (CNRS)

Test de Turing

Performances des calculateurs

Nombreux résultats déjà disponibles

- Lecture informatique des électrocardiogrammes (ECG), radiographies, tomodensitométrie (TDM), imagerie par résonance magnétique nucléaire (RMI), photographies rétiniennes, lésions cutanées
- Signatures pronostiques (OMICs)

Dans un futur proche

- Intégration de données cliniques, génomiques, métabolomiques et environnementales pour aider au diagnostic de précision - Synthèse d'entretiens avec les patients (agents conversationnels médicaux « chatbot »)

Beal AL, Drazen JM, Kohane IS, Leong T-Y, Manrai AK, Rubin E. et al. *NEJM* 2023;**388**:1220-1

Haug CJ, Drazen JM. *NEJM* 2023;**388**:1201-8

Blanc C, Bailly A, Francis E et al. *Artificial Intelligence in Medicine*; 2022;**127**:102264

Intelligence Artificielle

L'information vient des données !

Analyse de données de grande dimension (BigData)

Puissance de calcul disponible

Quelle est l'Information réellement contenue dans les données

6. RESEAUX NEURONAUX

6.1. Réseau

Ensemble de neurones et de connexions entre neurones.


Les neurones reçoivent des signaux en entrée, les traitent et fournissent des signaux en sortie.

Les neurones sont des unités de calcul. Les traitements effectués peuvent être simples (e.g. sommation des signaux entrants) ou beaucoup plus complexes.

Les connections caractérisent les flux entre neurones.

6.2. Perceptron monocouche

Schéma d'un ensemble de neurones recueillant I signaux en entrée, directement connectés à 1 ou plusieurs neurone(s) de sortie chacun avec sa fonction d'activation. I est la dimension du problème.




Pas de couche cachée, (I Poids + 1 paramètre de biais + 1 fonction d'activation) par neurone de sortie.

Autres fonctions d'activation (→ ensemble image)


fonction ReLU (Rectifier Linear Unit) $\mathbb{R} \rightarrow [0 ; +\infty[$

$$z = \sum w_i X_i - \theta$$
$$H(z) = \max(0, z)$$




Fonction Tangente hyperbolique $\mathbb{R} \rightarrow [-1 ; 1]$

$$H(z) = \tanh(z)$$



Fonction sigmoïde (logistique) $\mathbb{R} \rightarrow [0 ; 1]$

$$H(z) = \frac{1}{1 + \exp(-z)}$$



Fonction softmax (extension de logistique)

Intérêt : fonction continuellement

dérivable → entraînement des réseaux

Perceptron monocouche (exemple illustratif)

cas simple : 2 neurones en entrée

Fonction d'activation = fonction marche (Heaviside)

→ le modèle de classification conduit à séparer le plan d'axes X_1 et X_2 en 2 demi-plans séparés par une droite dont l'équation découle de l'annulation de z

$$z = 0$$


$$w_0 + w_1 X_1 + w_2 X_2 - \theta = 0$$

$$X_2 = \frac{1}{w_2} (\theta - w_0 - w_1 X_1)$$

Fonction marche :

3 neurones en entrée

>3 neurones en entrée



→ séparateur plan

→ séparateur hyperplan

Exemple illustratif d'un perceptron monocouche particulièrement simple (interprétable)

$$X_2 = \beta_0 + \beta_1 X_1$$

$$\beta_0 = \frac{-w_0}{w_2}$$


$$\beta_1 = \frac{-w_1}{w_2}$$

$$X_2 = .25 + 0.5 X_1$$

$$\beta_0 = \frac{-w_0}{w_2} = \frac{-(-0.5)}{(2)}$$

$$\beta_1 = \frac{-w_1}{w_2} = \frac{-(-1)}{(2)}$$

→ <https://lucleray.github.io/perceptron/>



Perceptron monocouche (exemple illustratif)

$$X_2 = \beta_0 + \beta_1 X_1$$

$$\beta_0 = \frac{-w_0}{w_2}$$

$$\beta_1 = \frac{-w_1}{w_2}$$

$$X_2 = .25 + 0.5 X_1$$

$$\beta_0 = \frac{-w_0}{w_2} = \frac{-(-0.5)}{(2)}$$

$$\beta_1 = \frac{-w_1}{w_2} = \frac{-(-1)}{(2)}$$



→ <https://lucleray.github.io/perceptron/>

Fonction d'activation sigmoïde – Algorithme de descente du gradient
(α : Coefficient d'apprentissage = learning rate / epoch : nombre de cycle)

Perceptron

RAZ

? Aide : survolez pour avoir plus d'informations



$\alpha =$ 1

apprentissage : simple / total



id	x	y
----	---	---

<https://lucleray.github.io/perceptron/>

Perceptron

RAZ

? Effectuez l'apprentissage jusqu'à ce que tout les points soient correctement classés



id	x	y
0	0.2125	0.9
1	0.0825	0.66
2	0.0975	0.8475
3	0.485	0.9425
4	0.3825	0.91
5	0.0925	0.3475
6	0.6075	0.6025
7	0.285	0.7175
8	0.825	0.895
9	0.76	0.715
10	0.6275	0.8275
11	0.465	0.925
12	0.5275	0.9275
13	0.9725	0.76
14	0.345	0.75
15	0.0575	0.4

<https://lucleray.github.io/perceptron/>

$$X_2 = \frac{-(-28)}{94.6} + \frac{-(-44)}{94.6} X_1 \approx 0.30 + 0.47 X_1$$


6.3. Réseau neuronal multicouche

Une couche d'entrée comprenant autant de neurones que de signaux à capter

Une ou plusieurs couches cachées

Une couche de sortie comprenant autant de neurones que de modalités d'intérêt

Réseau neuronal multicouche



Couche
d'entrée

Couches
cachées

Couche
de Sortie

6.4. Architectures des réseaux multicouches

Réseau neuronal à propagation avant (feed-forward networks)
(vus précédemment)

Réseaux récurrents (boucles d'activation)

6.5. Apprentissage supervisé (estimation des paramètres)

L'ajustement des poids se fait par apprentissage.

(= estimation des paramètres du modèle)

Valeurs initiales aléatoires, mise à jour en continue.

L'échantillon d'apprentissage intègre évidemment la variable réponse.

Méthodes de rétropropagation du gradient ou assimilées (de la dernière couche → la première) pour les réseaux à propagation avant

Méthodes de rétropropagation à travers le temps pour les réseaux récurrents

→ maximiser la vraisemblance

6.6. Performances des modèles de classification (sur échantillons tests indépendants)

Accuracy $(VP + VN) / (VP + VN + FP + FN) = (exactitude)$

Caractéristiques intrinsèques

Recall (*rappel*) $VP / (VP + FN) = \text{sensibilité} = Se$

Specificity $VN / (VN + FP) = \text{spécificité} = Sp$

AUROC Aire sous la courbe ROC

		REALITE	
		+	-
TEST	+	VP	FP
	-	FN	VN

Caractéristiques extrinsèques

Precision $VP / (VP + FP) = \text{Valeur prédictive Positive (VPP)}$

VPN $VN / (VN + FN) = \text{Valeur prédictive négative (VPN)}$

score F1
$$F1\text{-score} = \frac{2 VP}{2 VP + FP + FN} = \frac{2}{\frac{1}{precision} + \frac{1}{recall}}$$

CONCLUSION

**Une question médicale → un type d'étude →
Un modèle statistique**

**Les réseaux de neurones sont des modèles
statistiques !**

**Diapos 43 à 45 : Comprendre l'évolution des
modèles (sans connaître les formules !!!)**

MODELES

GLM

Linéaire

$$Y = \beta_0 + \sum \beta_j X_j + \varepsilon$$

Diagnostic

$$\log\left(\frac{P}{1-P}\right) = \beta_0 + \sum \beta_j X_j + \varepsilon$$

Pronostique

$$\log\left(\frac{\lambda(t,X)}{\lambda(t,0)}\right) = \sum \beta_j X_j + \varepsilon$$

Theranostique

$$\log\left(\frac{P}{1-P}\right) = \beta_0 + \sum \beta_j X_j + \sum \gamma_j T X_j + \varepsilon$$

$$\log\left(\frac{\lambda(t,X)}{\lambda(t,0)}\right) = \sum \beta_j X_j + \sum \gamma_j T X_j + \varepsilon$$

Estimation des paramètres → maximum de vraisemblance ou approche similaire

MODELES

GAM

Linéaire

$$Y = f(X_1, X_2, \dots, X_J) + \varepsilon$$

Diagnostique

$$\log\left(\frac{P}{1-P}\right) = f(X_1, X_2, \dots, X_J) + \varepsilon$$

Pronostique

$$\log\left(\frac{\lambda(t, X)}{\lambda(t, 0)}\right) = f(X_1, X_2, \dots, X_J) + \varepsilon$$

Theranostique

$$\log\left(\frac{P}{1-P}\right) = f(T, X_1, X_2, \dots, X_J) + \varepsilon$$

$$\log\left(\frac{\lambda(t, X)}{\lambda(t, 0)}\right) = f(T, X_1, X_2, \dots, X_J) + \varepsilon$$

Estimation des paramètres → maximum de vraisemblance ou approche similaire

MODELES

Réseaux de neurones

Linéaire

$$Y = \sum_{i=0}^I w_i Z_i^{K-1} + \varepsilon$$

Diagnostic

$$\log\left(\frac{P}{1-P}\right) = \sum_{i=0}^I w_i Z_i^{K-1} + \varepsilon$$

Pronostique

$$\log\left(\frac{\lambda(t,X)}{\lambda(t,0)}\right) = \sum_{i=0}^I w_i Z_i^{K-1} + \varepsilon$$

Theranostique

$$\log\left(\frac{P}{1-P}\right) = \sum_{i=0}^I w_i Z_i^{K-1} + \varepsilon$$

$$\log\left(\frac{\lambda(t,X)}{\lambda(t,0)}\right) = \sum_{i=0}^I w_i Z_i^{K-1} + \varepsilon$$

Estimation des paramètres → maximum de vraisemblance ou approche similaire

Merci pour votre attention !