

**MODELISATION DE DONNÉES  
QUALITATIVES**

***REGRESSION LOGISTIQUE  
SIMPLE***

*Pierre-Louis Gonzalez*

# MODELES A REPONSE DICHOTOMIQUE

**Quelques applications:  
Y est dichotomique: succès ou échec, présence  
ou absence.**

- **Un organisme de crédit doit-il accorder un prêt à l'un de ses clients ?**
- **Une entreprise présente t-elle des risques de faillite à moyen terme ( 2ans) ?**
- **Un patient est-il atteint d'une certaine maladie ?**
- **Doit-on déclencher une alerte à la pollution atmosphérique ?**

# LA RÉGRESSION LOGISTIQUE SIMPLE

## (cas $Y$ binaire)

### I LE MODÈLE LOGISTIQUE

#### 1 - Les données

$Y$  = variable à expliquer binaire

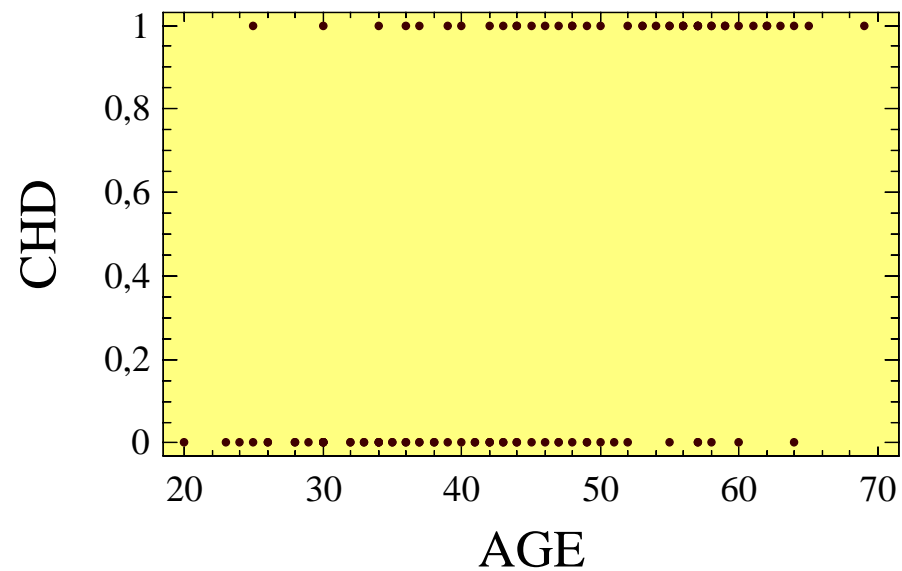
(Ex : présence/absence d'une maladie cardiaque)

$X$  = variable explicative quantitative

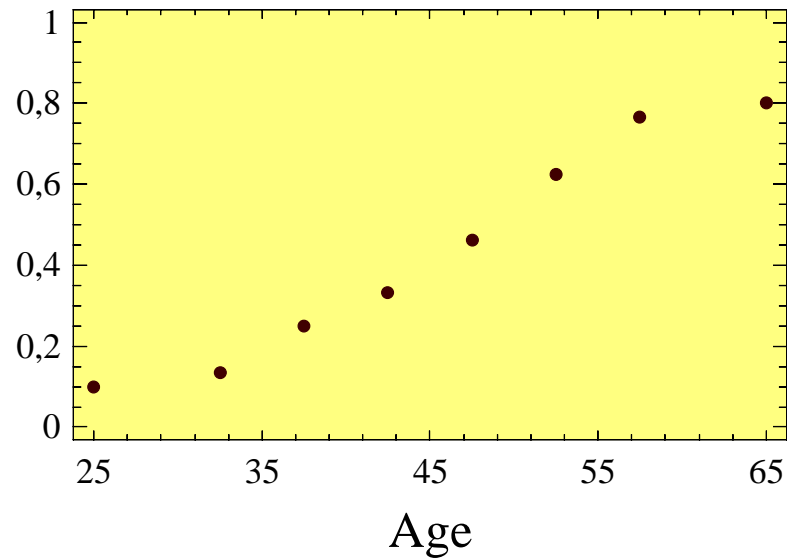
(Ex : âge)

## II.1 Etude des données

- Le graphique 4 ne montre pas clairement l'existence d'une liaison entre Y et X.



- Par contre si l'on utilise la variable âge découpée en classes et la proportion de malades par classe, la liaison entre Y et X apparaît plus clairement sous la forme d'une courbe en S.



## 2 - Le modèle logistique

**Objectif** Modéliser  $\Pi(\mathbf{x}) = \text{Prob}(Y = 1 / X = \mathbf{x})$

### 2.1 Modèle linéaire

$$\Pi(\mathbf{x}) = \beta_0 + \beta_1 \mathbf{x}$$

Ce modèle convient mal pour deux raisons :

- $\Pi(\mathbf{x})$  sort de  $[0,1]$
- $\Pi'(\mathbf{x})$  doit tendre vers  $0$  lorsque  $\Pi(\mathbf{x})$  tend vers  $0$  ou  $1$

$\Pi(\mathbf{x})$  est une courbe en S

## 2.2 Modèle logistique

$$\Pi(\mathbf{x}) = \frac{e^{\beta_0 + \beta_1 \mathbf{x}}}{1 + e^{\beta_0 + \beta_1 \mathbf{x}}}$$


$$\Pi'(\mathbf{x}) = \beta_1 \Pi(\mathbf{x}) (1 - \Pi(\mathbf{x}))$$

Donc  $\Pi'(\mathbf{x}) \rightarrow \mathbf{0}$  lorsque  $\Pi(\mathbf{x}) \rightarrow \mathbf{0}$  ou  $\mathbf{1}$

## Justifications concernant le choix de la fonction logistique

La fonction logistique est définie par :

$$F(x) = 1 / (1 + e^{-x})$$





- Cette fonction est bien adaptée à la modélisation de probabilités car elle prend ses valeurs entre 0 et 1 **selon une courbe en S**.

Son utilisation est par exemple indiquée lors de la modélisation du risque individuel de développer une maladie dans les études épidémiologiques.

- En effet, en considérant que la variable  $x$  représente un indice résultant de la combinaison de plusieurs facteurs de risque, on peut interpréter  $F(x)$  comme le risque d'être atteint de cette maladie.

Dans ce contexte le risque est minimal pour de faibles valeurs de  $x$ .

Il augmente pour les valeurs intermédiaires de  $x$ .

Il apparaît proche de 1 pour des valeurs plus élevées de  $x$ .

### 3 - Estimation des paramètres du modèle logistique

#### Données

<b>X</b>	<b>Y</b>
$\mathbf{x}_1$	$\mathbf{y}_1$
$\mathbf{x}_2$	$\mathbf{y}_2$
$\vdots$	$\vdots$
$\mathbf{x}_i$	$\mathbf{y}_i$
$\vdots$	$\vdots$
$\mathbf{x}_n$	$\mathbf{y}_n$

$$\begin{aligned}\Pi(\mathbf{x}_i) &= \Pi_i = \mathbf{P}(\mathbf{Y} = 1 | \mathbf{X} = \mathbf{x}_i) \\ &= \frac{e^{\beta_0 + \beta_1 \mathbf{x}_i}}{1 + e^{\beta_0 + \beta_1 \mathbf{x}_i}}\end{aligned}$$

## Vraisemblance

$$\mathbf{L}(\mathbf{B}) = \prod_{i=1}^n \Pi(\mathbf{x}_i)^{y_i} \left(1 - \Pi(\mathbf{x}_i)\right)^{1-y_i}$$

(Ceci résulte du fait que :

$$\begin{aligned} \mathbf{f}(\mathbf{y}_i, \boldsymbol{\beta}) &= \text{Prob} \left[ \mathbf{Y} = \mathbf{y}_i \mid \mathbf{X} = \mathbf{x}_i, \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix} \right] \\ &= \begin{cases} \Pi(\mathbf{x}_i) & \text{pour } \mathbf{y}_i = \mathbf{1} \\ 1 - \Pi(\mathbf{x}_i) & \text{pour } \mathbf{y}_i = \mathbf{0} \end{cases} \end{aligned}$$

## Log de la vraisemblance

$$\text{Log } \mathbf{L}(\boldsymbol{\beta}) = \sum_{i=1}^n y_i \text{Log } \Pi_i(\mathbf{x}) + (1 - y_i) \text{Log}(1 - \Pi_i(\mathbf{x}))$$

## Maximum de vraisemblance

On obtient  $\hat{\boldsymbol{\beta}}$  en annulant  $\frac{\partial \text{Log } \mathbf{L}(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}}$

$$\left\{ \begin{array}{l} \frac{\partial \text{Log } \mathbf{L}(\boldsymbol{\beta})}{\partial \beta_0} = \sum_{i=1}^n (y_i - \Pi(\mathbf{x}_i)) \\ \quad = \sum_{i=1}^n \left( y_i - \frac{e^{\beta_0 + \beta_1 \mathbf{x}_i}}{1 + e^{\beta_0 + \beta_1 \mathbf{x}_i}} \right) = \mathbf{0} \\ \\ \frac{\partial \text{Log } \mathbf{L}(\boldsymbol{\beta})}{\partial \beta_1} = \sum_{i=1}^n \mathbf{x}_i (y_i - \Pi(\mathbf{x}_i)) \\ \quad = \sum_{i=1}^n \mathbf{x}_i \left( y_i - \frac{e^{\beta_0 + \beta_1 \mathbf{x}_i}}{1 + e^{\beta_0 + \beta_1 \mathbf{x}_i}} \right) = \mathbf{0} \end{array} \right.$$

## Résultats

$$\hat{\beta}_0 = -5,3095$$

$$\hat{\beta}_1 = 0,1109$$

$$- 2 \text{ Log } \mathbf{L} = 107,35 \quad \text{est minimum}$$

**Modèle estimé :** 
$$\hat{\Pi}(\mathbf{x}) = \frac{e^{-5,3095+0,1109\mathbf{x}}}{1 + e^{-5,3095+0,1109\mathbf{x}}}$$

La probabilité d'être atteint de la maladie augmente avec l'âge.

## 4 - Calcul des écarts-types des estimateurs des paramètres

En notant  $\hat{\Pi}_i = \hat{\Pi}(\mathbf{x}_i)$ , on a :

$$\hat{\mathbf{V}}(\hat{\boldsymbol{\beta}}) = \left[ \frac{-\partial^2 \text{Log } \mathbf{L}(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}^2} \right]_{\boldsymbol{\beta}=\hat{\boldsymbol{\beta}}}^{-1} = \left[ \begin{array}{cc} \sum_{i=1}^n \hat{\Pi}_i(1-\hat{\Pi}_i) & \sum_{i=1}^n \mathbf{x}_i \hat{\Pi}_i(1-\hat{\Pi}_i) \\ \sum_{i=1}^n \mathbf{x}_i \hat{\Pi}_i(1-\hat{\Pi}_i) & \sum_{i=1}^n \mathbf{x}_i^2 \hat{\Pi}_i(1-\hat{\Pi}_i) \end{array} \right]^{-1}$$

$$= \left( \left[ \begin{array}{c} \left[ \mathbf{1} \quad \mathbf{x}_1 \right] \\ \vdots \\ \left[ \mathbf{1} \quad \mathbf{x}_n \right] \end{array} \right]' \left[ \begin{array}{ccc} \hat{\Pi}_1(1-\hat{\Pi}_1) & & \\ & \ddots & \\ & & \mathbf{0} \\ & & & \ddots & \\ & & & & \hat{\Pi}_n(1-\hat{\Pi}_n) \end{array} \right] \left[ \begin{array}{c} \left[ \mathbf{1} \quad \mathbf{x}_1 \right] \\ \vdots \\ \left[ \mathbf{1} \quad \mathbf{x}_n \right] \end{array} \right] \right)^{-1}$$

$$= (\mathbf{X}' \mathbf{V} \mathbf{X})^{-1}$$

## Résultats

### •Analysis of Maximum Likelihood Estimates

•Variable	DF	Parameter Estimate	Standard Error	Wald Chi-Square	Pr > Chi-Square	Standardized Estimate	Odds Ratio
•INTERCPT	1	-5.3095	1.1337	21.9350	0.0001	.	.
•AGE	1	0.1109	0.0241	21.2541	0.0001	0.716806	1.117

$$\hat{V}(\hat{\beta}) = \begin{bmatrix} 1,285 & -0,0266 \\ -0,0266 & 0,0005388 \end{bmatrix}$$

D'où

$$s(\hat{\beta}_0) = \sqrt{1,285} = 1,1337$$

$$s(\hat{\beta}_1) = \sqrt{0,0005388} = 0,0241$$

## 5 - Utilisations des écarts-types

### 5.1 Test de nullité (ou de signification) d'un coefficient $\beta_j$ au niveau $\alpha$

$$\begin{cases} H_0 & : \beta_j = 0 \\ H_1 & : \beta_j \neq 0 \end{cases}$$



## Test de Wald :



$$\frac{\hat{\beta}_j^2}{s^2(\hat{\beta}_j)} \rightarrow \chi^2(1) \quad \text{sous } \mathbf{H}_0$$

On rejette  $\mathbf{H}_0$  si :

$$W_j = \frac{\hat{\beta}_j^2}{s^2(\hat{\beta}_j)} > \chi_{\alpha}^2(1)$$

$$\Leftrightarrow \underbrace{\Pr[\chi_{(1)}^2 > w_j]}_{\text{P-value}} < \alpha$$

$$\Leftrightarrow \frac{|\hat{\beta}_j|}{s(\hat{\beta}_j)} > u_{\frac{\alpha}{2}}$$



## 5.2 Intervalle de confiance de $\Pi(\mathbf{x})$

$$\Pi(\mathbf{x}) = \frac{e^{\beta_0 + \beta_1 \mathbf{x}}}{1 + e^{\beta_0 + \beta_1 \mathbf{x}}}$$

On déduit un intervalle de confiance de  $\Pi(\mathbf{x})$  de l'intervalle de confiance de  $\mathbf{g}(\mathbf{x}) = \beta_0 + \beta_1 \mathbf{x}$ .

I.C. à 95 % de  $\mathbf{g}(\mathbf{x}) = \beta_0 + \beta_1 \mathbf{x}$ .

$$\hat{\beta}_0 + \hat{\beta}_1(\mathbf{x}) \pm 1,96 \hat{\sigma} \left( \hat{\beta}_0 + \hat{\beta}_1 \mathbf{x} \right)$$

$$\text{avec } \hat{\sigma} \left( \hat{\beta}_0 + \hat{\beta}_1 \mathbf{x} \right) = (\mathbf{1}, \mathbf{x}) \hat{\mathbf{V}} \left( \hat{\beta} \right) \begin{pmatrix} 1 \\ \mathbf{x} \end{pmatrix}$$

## Exemple

$x = 20$  ans

$$\begin{aligned}\hat{g}(20) &= \hat{\beta}_0 + \hat{\beta}_1 20 = -5,3095 + 0,1109 * 20 \\ &= \underline{-3,0915}\end{aligned}$$

$$\hat{\Pi}(20) = \frac{e^{-3,0915}}{1 + e^{-3,0915}} = \frac{0,0454338}{1,0454338} = \underline{0,0434592}$$

$$\begin{aligned}\hat{\sigma}^2(\hat{\beta}_0 + \hat{\beta}_1 20) &= (1, 20) \begin{bmatrix} 1,2852 & - 0,0267 \\ - 0,0267 & 0,0005788 \end{bmatrix} \begin{pmatrix} 1 \\ 20 \end{pmatrix} \\ &= \underline{0,448}\end{aligned}$$

Intervalle de confiance à 95 % de  $g(20) = \beta_0 + \beta_1 20$

$$- 3,0915 \pm 1,96 \sqrt{0,448} = [- 4,4034 ; - 1,7796]$$

Intervalle de confiance à 95 % de  $\Pi(20) = \text{Prob}(Y = 1|X = 1)$

$$\text{Inf (95 \%)} = \frac{e^{-4,4034}}{1 + e^{-4,4034}} = 0,012$$

$$\text{Sup (95 \%)} = \frac{e^{-1,7796}}{1 + e^{-1,7796}} = 0,144$$

## 6 - Autres tests

### 6.1 Test du rapport de vraisemblance

$$\text{Modèle} \quad \Pi(\mathbf{x}_i) = \frac{e^{\beta_0 + \beta_1 x_i}}{1 + e^{\beta_0 + \beta_1 x_i}}$$

Test de l'influence de X sur Y

$$\begin{cases} \mathbf{H}_0 : \beta_1 = 0 \\ \mathbf{H}_1 : \beta_1 \neq 0 \end{cases}$$

**Statistique utilisée**

$$\Lambda = -2 \text{Log} \left[ \frac{\mathbf{L}(\tilde{\beta}, \beta_1 = 0)}{\mathbf{L}(\hat{\beta}_0, \hat{\beta}_1)} \right]$$

## Calcul du Log (vraisemblance) sous $H_0$

$$\text{Sous } H_0 : \Pi(\mathbf{x}_i) = \frac{e^{\beta_0 + \beta_1 x_i}}{1 + e^{\beta_0 + \beta_1 x_i}} = \frac{e^{\beta_0}}{1 + e^{\beta_0}}$$

$$\hat{\Pi}(\mathbf{x}_i) = \frac{e^{\tilde{\beta}_0}}{1 + e^{\tilde{\beta}_0}} = \frac{\mathbf{n}_1}{\mathbf{n}}$$

où  $\mathbf{n}_1$  = nombre de  $(y_i = 1)$

$$\text{Log} \left( L(\tilde{\beta}_0, \beta_1 = 0) \right) = \sum_{i=1}^n \left[ y_i \text{Log} \hat{\Pi}_i + (1 - y_i) \text{Log} (1 - \hat{\Pi}_i) \right]$$

$$= \mathbf{n}_1 \text{Log} \frac{\mathbf{n}_1}{\mathbf{n}} + \mathbf{n}_0 \text{Log} \frac{\mathbf{n}_0}{\mathbf{n}}$$

où  $\mathbf{n}_0$  = nombre de  $(y_i = 0)$

## Résultat

$$\Lambda = -2 \text{ Log} \left[ \frac{\text{L} (\tilde{\beta}_0, \beta_1 = 0)}{\text{L} (\hat{\beta}_0, \hat{\beta}_1)} \right]$$

$$= -2 \text{ Log} (\text{vraisemblance sans la variable}) \\ - (-2 \text{ Log} (\text{vraisemblance avec la variable}))$$

$$\rightarrow \chi^2(1) \text{ sous } \mathbf{H}_0$$

## Exemple

$$\Lambda = 136,663 - 107,353 = 29,30$$

$\Rightarrow$  âge très significatif

## 6.2 Test du score

**Vecteur score :**

$$\mathbf{u}(\boldsymbol{\beta}) = \begin{bmatrix} \frac{\partial \text{Log } \mathbf{L}(\boldsymbol{\beta})}{\partial \beta_0} \\ \frac{\partial \text{Log } \mathbf{L}(\boldsymbol{\beta})}{\partial \beta_1} \end{bmatrix}$$

$$\mathbf{u}(\boldsymbol{\beta}) \rightarrow \mathbf{N}(\mathbf{0}, \mathbf{I}(\boldsymbol{\beta}))$$

$$\text{où } \mathbf{I}(\boldsymbol{\beta}) = \mathbf{E} \left[ \frac{-\partial^2 \text{Log } \mathbf{L}(\boldsymbol{\beta})}{\partial \beta^2} \right]$$



**Test** 
$$\begin{cases} \mathbf{H}_0 : \beta_1 = 0 \\ \mathbf{H}_1 : \beta_1 \neq 0 \end{cases}$$

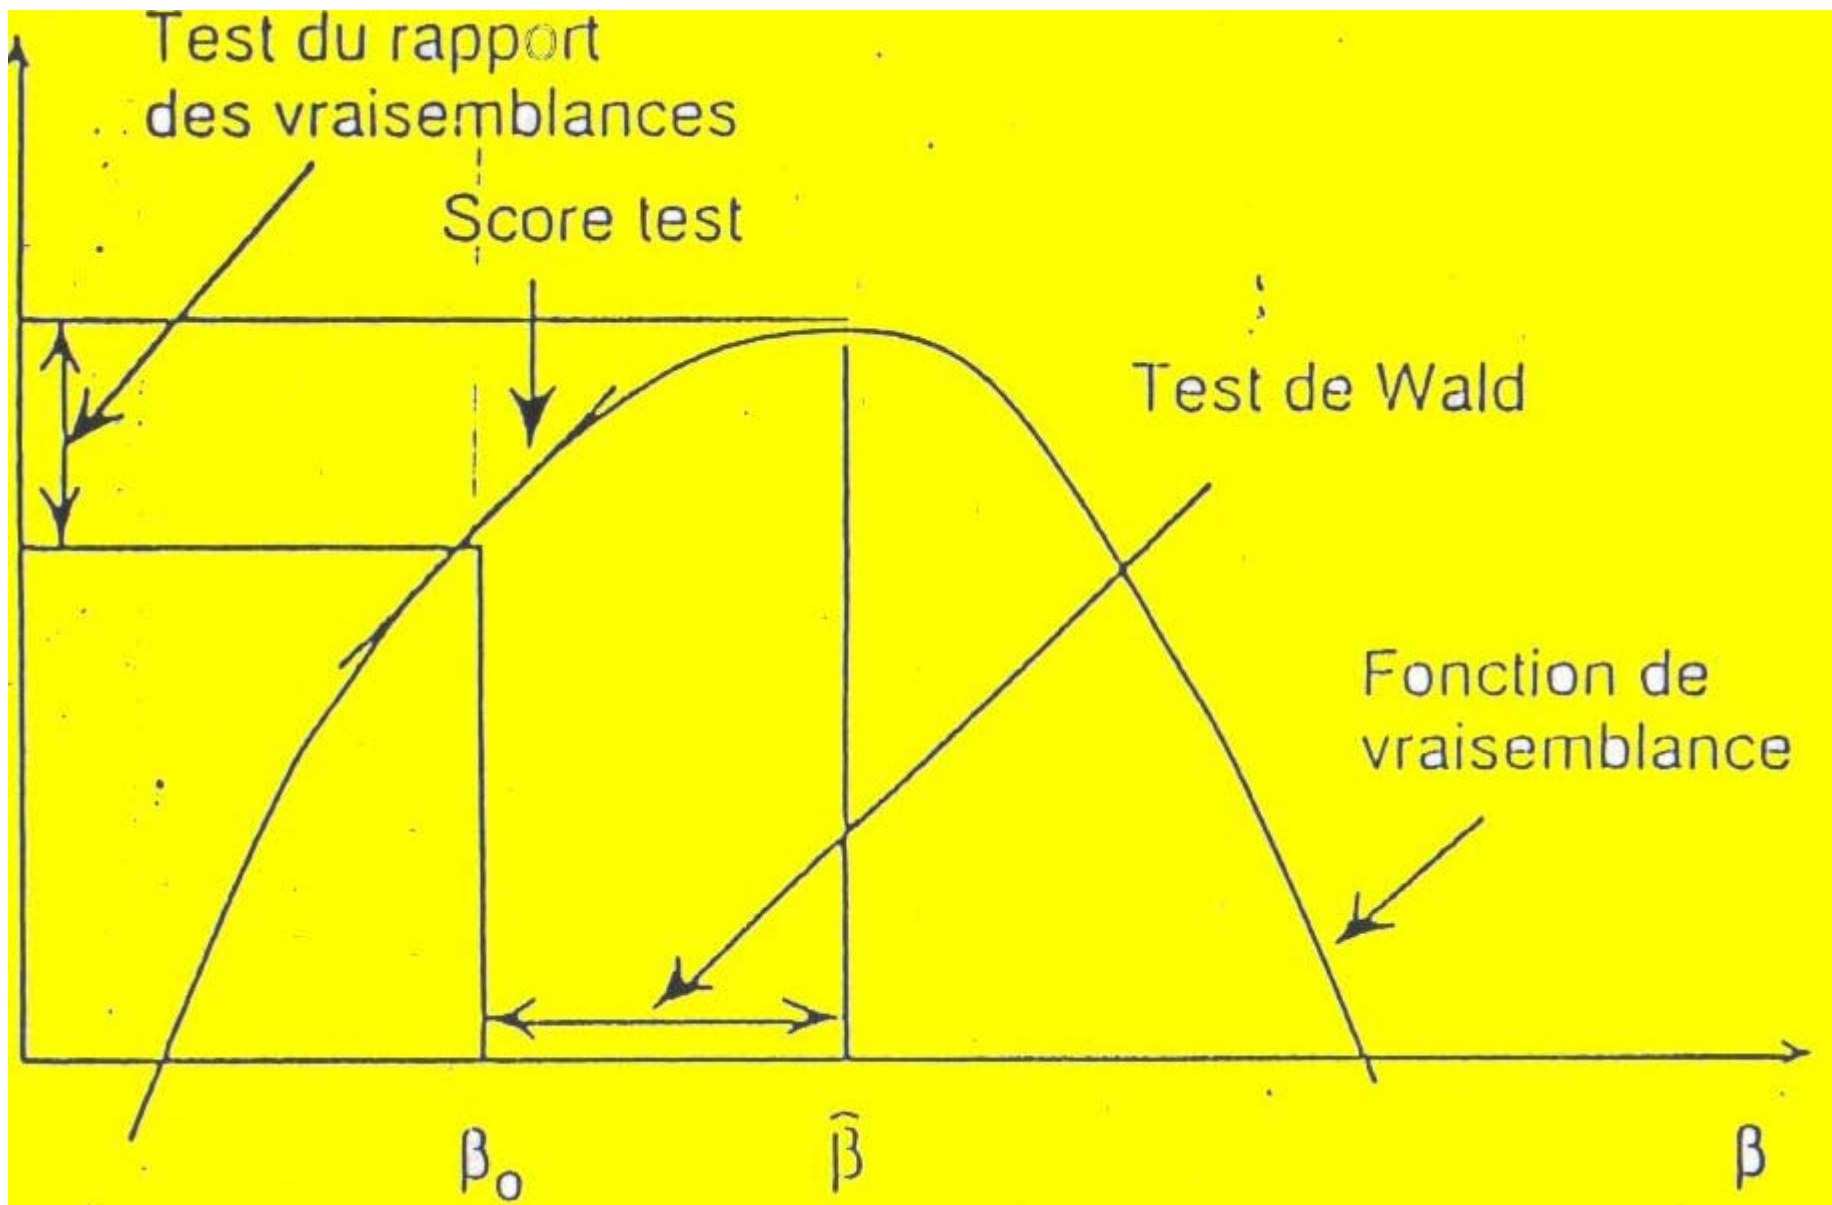
On estime  $\beta$  sous  $\mathbf{H}_0$

$$\Rightarrow \hat{\beta}_{\mathbf{H}_0} = (\hat{\beta}_0, \mathbf{0}) = \left( \mathbf{Log} \frac{\mathbf{n}_1}{\mathbf{n}}, \mathbf{0} \right)$$

**Statistique utilisée**

$$\begin{aligned} \text{Score} &= \mathbf{U} \left( \hat{\beta}_{\mathbf{H}_0} \right)' \hat{\mathbf{I}} \left( \hat{\beta}_{\mathbf{H}_0} \right)^{-1} \mathbf{U} \left( \hat{\beta}_{\mathbf{H}_0} \right) \\ &= \frac{(\sum \mathbf{x}_i (y_i - \bar{y}))^2}{\bar{y}(1 - \bar{y}) \sum (\mathbf{x}_i - \bar{\mathbf{x}})^2} \rightarrow \chi^2(1) \text{ sous } \mathbf{H}_0 \end{aligned}$$

**Exemple** Score = **26,4**  $\Rightarrow$  âge très significatif



## II - ANALYSE DES RÉSIDUS, DES OBSERVATIONS

### 1 - Analyse des résidus

#### Résidu de Pearson

Modèle :  $Y_i = \Pi_i + \varepsilon_i$

$$\Rightarrow \varepsilon_i = 1 - \Pi_i \text{ avec une proba } \Pi_i$$

$$\text{et } \varepsilon_i = -\Pi_i \text{ avec une proba } 1 - \Pi_i$$

$$E(\varepsilon_i) = (1 - \Pi_i)\Pi_i - \Pi_i(1 - \Pi_i) = 0$$

$$V(\varepsilon_i) = (1 - \Pi_i)^2 \Pi_i + \Pi_i^2 (1 - \Pi_i) = \Pi_i (1 - \Pi_i)$$

On définit le **résidu de Pearson** par :

$$\mathbf{r}_i = \frac{y_i - \hat{\Pi}_i}{\sqrt{\hat{\Pi}_i(1 - \hat{\Pi}_i)}} \quad \text{à comparer à } Z$$

**Résultat :**

$$\chi^2 = \sum_{i=1}^n \mathbf{r}_i^2 \longrightarrow \chi_{n-2}^2 \quad \text{si le modèle étudié est exact.}$$

## Déviante

$$\begin{aligned}\text{Déviante} &= -2 \mathbf{Log} (\text{vraisemblance modèle étudié}) \\ &= -2 \sum_{i=1}^n \left( y_i \mathbf{Log} \hat{\Pi}_i + (1 - y_i) \mathbf{Log} (1 - \hat{\Pi}_i) \right)\end{aligned}$$

$\mathbf{D} = -2 \mathbf{Log} \mathbf{L} \approx$  somme des carrés résiduelle

### Résidu-déviante :

$$d_i = \begin{cases} \sqrt{2y_i |\mathbf{Log} \hat{\Pi}_i|} = \sqrt{2 |\mathbf{Log} \Pi_i|} & \text{pour } y_i = 1 \\ -\sqrt{2(1-y_i) |\mathbf{Log} (1 - \hat{\Pi}_i)|} = -\sqrt{2 |\mathbf{Log} (1 - \hat{\Pi}_i)|} & \text{pour } y_i = 0 \end{cases}$$

### Résultat :

$$\mathbf{D} = \sum_{i=1}^n d_i^2 = -2 \mathbf{Log} \mathbf{L} \longrightarrow \chi_{(n-2)}^2 \quad \text{si le modèle étudié est exact.}$$

## 2 - Analyse des observations

### ► Levier

$$\mathbf{H} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \quad \text{en régression multiple}$$

$$\mathbf{H} = \mathbf{V}^{1/2} \mathbf{X}(\mathbf{X}'\mathbf{V}\mathbf{X})^{-1} \mathbf{X}'\mathbf{V}^{1/2} \quad \text{en régression logistique}$$

$$\text{où } \mathbf{X} = \begin{pmatrix} \mathbf{1} & \mathbf{x}_1 \\ \vdots & \vdots \\ \mathbf{1} & \mathbf{x}_n \end{pmatrix} \text{ et } \mathbf{V} = \begin{pmatrix} \hat{\Pi}_1(1 - \hat{\Pi}_1) & & & \\ & \ddots & & \\ & & \mathbf{0} & \\ & & & \ddots \\ & & & & \hat{\Pi}_n(1 - \hat{\Pi}_n) \end{pmatrix}$$

On définit le **levier** par :

$$\mathbf{h}_i = \hat{\Pi}_i(1 - \hat{\Pi}_i) (\mathbf{1}, \mathbf{x}_i) (\mathbf{X}'\mathbf{V}\mathbf{X})^{-1} \begin{pmatrix} \mathbf{1} \\ \mathbf{x}_i \end{pmatrix}$$

**Résultats** :  $\frac{1}{n} \leq h_i \leq 1$        $\bar{h} = \frac{2}{n}$

Mesure l'éloignement d'une observation par rapport aux autres dans l'espace des variables explicatives lorsque  $0,1 \leq \hat{\Pi}_i \leq 0,9$ .

On compare  $h_i$  à  $2\bar{h} = \frac{4}{n}$ .

### **Influence de chaque observation sur le calcul de $\hat{\beta}$**

On note  $\hat{\beta}_{(-i)}$  = estimation de  $\beta$  sans utiliser l'observation  $\mathbf{i}$

$$\begin{aligned} C_i &= \left( \hat{\beta} - \hat{\beta}_{(-i)} \right)' \mathbf{X}' \mathbf{V} \mathbf{X} \left( \hat{\beta} - \hat{\beta}_{(-i)} \right) \\ &= \frac{\mathbf{r}_i^2 \mathbf{h}_i}{(1 - \mathbf{h}_i)^2} \end{aligned}$$

### **Influence de chaque observation sur le $\chi^2$ de Pearson**

$$\Delta_i \chi^2 = \frac{\mathbf{r}_i^2}{1 - \mathbf{h}_i}$$



► Influence de chaque observation sur la déviance

$$\Delta_i \mathbf{D} = \mathbf{d}_i^2 + \frac{\mathbf{r}_i^2 \mathbf{h}_i}{\mathbf{1} - \mathbf{h}_i}$$

► Influence de chaque observation sur le calcul de  $\hat{\beta}_j$

$$\text{DFBETA}_j(-i) = \frac{\hat{\beta}_j - \hat{\beta}_j(-i)}{\hat{\sigma}(\hat{\beta}_j)}$$

### III - REMARQUES

1

Le cas où la variable indépendante est à plusieurs modalités est traité dans le cadre de la **régression logistique multiple**.

**En effet, on remplace la colonne de la variable qualitative codée par le tableau des indicatrices de ses modalités.**

Pour éviter les **problèmes d'indétermination**, on supprime une des indicatrices des calculs (souvent on supprime celle qui correspond à la situation la plus courante : situation de référence). Les résultats sont indépendants du choix effectué.

2

**Les aspects généraux concernant la qualité d'un modèle, l'interprétation des coefficients ... seront traités après la présentation de la régression logistique multiple**

### 3. Comparaison des modèles utilisant les fonctions de lien logit et probit.

- L'estimation du paramètre  $\beta_1$  obtenue avec la fonction de lien logit est environ  $\pi/\sqrt{3}$  fois plus grande que celle obtenue avec la fonction de lien probit. **Les estimations standardisées sont donc assez proches l'une de l'autre.**
- **Les résultats des tests de validité des modèles sont équivalents.**
- Enfin la comparaison des probabilités estimées montre que **les prévisions sont relativement similaires.**

- **PROBIT**

- Model Fitting Information and Testing Global Null Hypothesis BETA=0

- 

- 

- 

- 

- 

- 

- 

- 

- 

Criterion	Intercept Only	Intercept and Covariates	Chi-Square for Covariates
AIC	138.663	111.499	.
SC	141.268	116.709	.
-2 LOG L	136.663	107.499	29.164 with 1 DF (p=0.0001)
Score	.	.	26.399 with 1 DF (p=0.0001)

- **LOGIT**

- 

- 

- 

- 

- 

- 

- 

- 

Criterion	Intercept Only	Intercept and Covariates	Chi-Square for Covariates
AIC	138.663	111.353	.
SC	141.268	116.563	.
-2 LOG L	136.663	107.353	29.310 with 1 DF (p=0.0001)
Score	.	.	26.399 with 1 DF (p=0.0001)

- **PROBIT**

- Analysis of Maximum Likelihood Estimates

- 
- 
- 
- 
- 
- 
- 
- 
- 
- 
- 

Variable	DF	Parameter Estimate	Standard Error	Wald Chi-Square	Pr > Chi-Square	Standardized Estimate
INTERCPT	1	-3.1457	0.6246	25.3657	0.0001	.
AGE	1	0.0658	0.0133	24.3095	0.0001	0.771313

- **LOGIT**

- 
- 
- 
- 
- 
- 
- 
- 
- 
- 
- 

Variable	DF	Parameter Estimate	Standard Error	Wald Chi-Square	Pr > Chi-Square	Standardized Estimate	Odds Ratio
INTERCPT	1	-5.3095	1.1337	21.9350	0.0001	.	.
AGE	1	0.1109	0.0241	21.2541	0.0001	0.716806	1.117

## EXEMPLES DE PREVISIONS

- **PROBIT**

•	OBS	ID	AGRP	AGE	CHD	_LEVEL_	PCALCULE	INF95	SUP95
•	1	1	1	20	0	1	0.03365	0.00534	0.13436
•	39	39	4	40	1	1	0.30378	0.20511	0.41932
•	91	91	8	60	0	1	0.78888	0.63227	0.89745
•	100	100	8	69	1	1	0.91846	0.76581	0.98051

- **LOGIT**

•	OBS	ID	AGRP	AGE	CHD	_LEVEL_	PCALCULE	INF95	SUP95
•	1	1	1	20	0	1	0.04348	0.01207	0.14470
•	39	39	4	40	1	1	0.29471	0.19510	0.41873
•	91	91	8	60	0	1	0.79344	0.63245	0.89556
•	100	100	8	69	1	1	0.91246	0.76287	0.97124