

# Sommaire

Introduction .....	1
Principaux modèles multivariés utilisés en épidémiologie .....	2
Définition du modèle logistique.....	3
1. Une seule variable X .....	3
2. Deux variables .....	6
3. Plusieurs variables $X_j$ .....	6
Utilisation du modèle logistique dans les enquêtes cas-témoins .....	7
Estimation des paramètres.....	8
Tests des paramètres.....	17
Exercice 1 .....	25
Interprétation des coefficients et codage des variables.....	26
1. X qualitative à 2 classes (dichotomique) .....	27
2. X qualitative nominale à plus de 2 classes .....	28
3. X qualitative ordinale .....	39
4. X quantitative .....	49
Exercice 2.....	50
Interaction.....	51
Exercice 3.....	61
Choix des variables à inclure dans un modèle logistique.....	62
Principes généraux .....	62
Nombre maximum de variables dans un modèle .....	64
Choix des variables “candidates” .....	65
Sélection des variables à inclure dans le modèle final.....	69
En résumé .....	79
Régression logistique multinomiale .....	83

# Introduction

Un modèle multivarié permet d'exprimer une variable  $Y$  en fonction de plusieurs variables  $X_i$

En épidémiologie,

- $Y$  caractérise la maladie (ou sa distribution dans la population)
- les  $X_i$  caractérisent les facteurs de risque de la maladie ou des variables d'ajustement. Ils peuvent être qualitatifs ou quantitatifs.

- Les méthodes multivariées supposent une certaine **modélisation** de la réalité.

Par exemple, on peut modéliser (représenter) la relation entre  $Y$  et les  $X_i$

- sous forme linéaire
- et/ou en supposant l'absence d'interaction entre les  $X_i$

=> Les conclusions qu'on tire des analyses multivariées sont en partie conditionnées par le bien-fondé des hypothèses faites (par exemple linéarité).

# Principaux modèles multivariés utilisés en épidémiologie

- **Régression linéaire multiple** (Y est quantitative)

$$\bar{Y} = E(Y | X_1, \dots, X_p) = \alpha + \beta_1 X_1 + \dots + \beta_p X_p = \alpha + \sum_{i=1}^p \beta_i X_i$$

$\bar{Y}$  : moyenne de Y connaissant  $X_1, \dots, X_p$

- **Régression logistique** (Y = 0/1)

$$P(M^+ | X_1, \dots, X_p) = \frac{1}{1 + \exp \left\{ - \left( \alpha + \sum_{i=1}^p \beta_i X_i \right) \right\}}$$

$P(M^+ | X_1, \dots, X_p)$  : probabilité de maladie connaissant  $X_1, \dots, X_p$

Y avec plus de 2 classes : régression logistique multinomiale

- **Modèle de Cox** (Y = incidence instantanée  $\lambda$ )

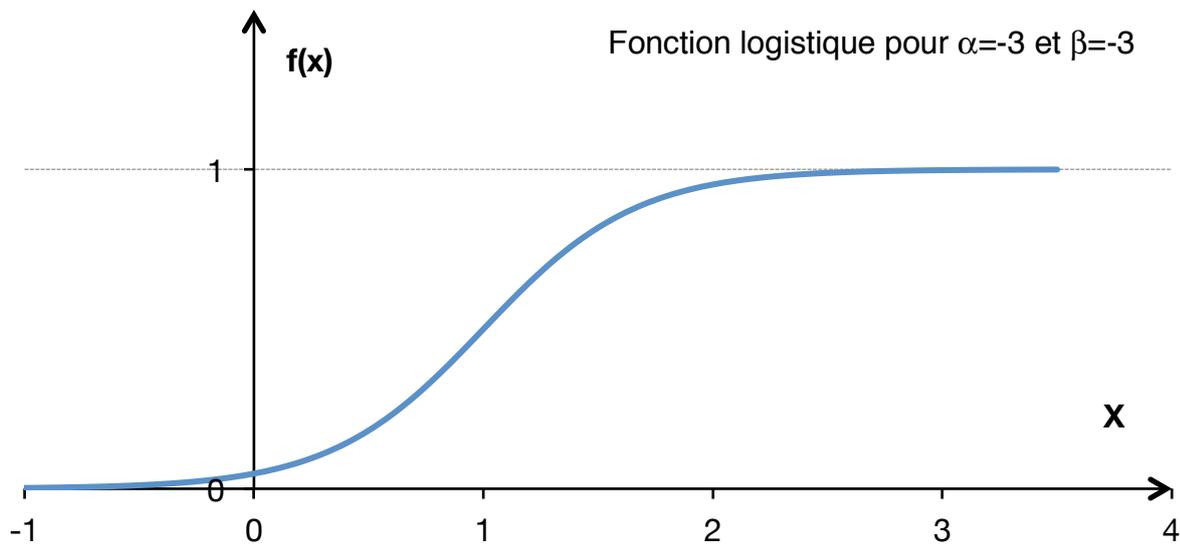
$$\lambda(t, X_1, \dots, X_p) = \lambda_0(t) \exp \left\{ \sum_{i=1}^p \beta_i X_i \right\}$$

# Définition du modèle logistique

## 1. Une seule variable X

$$P(M^+|X) = \frac{1}{1 + e^{-(\alpha + \beta x)}}$$

- Fonction logistique :  $f(x) = \frac{1}{1 + e^{-(\alpha + \beta x)}}$



- L'association entre la maladie M et X est mesurée par  $\beta$ .

Si X est dichotomique (X=1 : exposé et X=0 : non exposé),  $\beta$  permet de retrouver l'odds ratio.

...  $\beta$  permet de retrouver l'odds ratio

$$P(M^+|X) = \frac{1}{1 + e^{-(\alpha + \beta x)}}$$

Par définition :  $OR = \frac{P_1/1 - P_1}{P_0/1 - P_0}$  avec  $P_0 = P(M^+|X=0)$   
 $P_1 = P(M^+|X=1)$

$$\boxed{X=1}$$

$$P(M^+) = P_1 = \frac{1}{1 + e^{-(\alpha + \beta)}} \quad 1 - P_1 = 1 - \frac{1}{1 + e^{-(\alpha + \beta)}} = \frac{e^{-(\alpha + \beta)}}{1 + e^{-(\alpha + \beta)}}$$

$$\boxed{X=0}$$

$$P(M^+) = P_0 = \frac{1}{1 + e^{-\alpha}} \quad 1 - P_0 = \frac{e^{-\alpha}}{1 + e^{-\alpha}}$$

$$\text{d'où : } OR = \frac{P_1/1 - P_1}{P_0/1 - P_0} = \exp(\beta)$$

## Autre écriture du modèle logistique

$$P(M^+|X) = \frac{1}{1 + e^{-(\alpha + \beta X)}}$$

Définition :  $\text{Logit } P = \ln \frac{P}{1-P} = \ln P - \ln(1-P)$

$$P = P(M^+|X) \quad \rightarrow \quad \boxed{\text{Logit } P = \alpha + \beta X}$$

Si X est dichotomique,  $\beta$  permet de retrouver l'odds ratio :

$$\begin{aligned} \ln \text{OR} &= \ln \left( \frac{P_1/1-P_1}{P_0/1-P_0} \right) = \ln(P_1/1-P_1) - \ln(P_0/1-P_0) \\ &= \text{Logit } P_1 - \text{Logit } P_0 \\ &= (\alpha + \beta) - \alpha \\ &= \beta \end{aligned}$$

$$\boxed{\ln \text{OR} = \text{Logit } P_1 - \text{Logit } P_0}$$

# Définition du modèle logistique

## 2. Deux variables

$$\text{Logit } P = \alpha + \beta E + \beta' X$$

$\exp(\beta) = \text{OR}$  lié à l'exposition E **ajusté** sur X

OR ajusté car Logit P varie de  $\beta$  quand E passe de 0 à 1 (non exposé à exposé) à condition que X reste fixe.

Dans la réalité, X peut être différent chez les exposés et les non exposés (et donc ne pas être fixe). L'interprétation de  $\beta$  suppose qu'on "force" (par le calcul) X à être identique chez les exposés et les non exposés. C'est par définition, ce qu'on appelle ajuster sur X.

## 3. Plusieurs variables $X_i$

$$P(M^+ | X_1, \dots, X_k) = \frac{1}{1 + \exp\left(-\left(\alpha + \sum_{i=1}^k \beta_i X_i\right)\right)} \quad \text{ou} \quad \text{Logit } P = \alpha + \sum_{i=1}^k \beta_i X_i$$

Si  $X_i$  prend les valeurs 0 et 1,

$\exp(\beta_i) = \text{OR}$  lié à l'exposition  $X_i$  **ajusté** sur les autres variables

# Utilisation du modèle logistique dans les enquêtes cas-témoins

◇ On peut utiliser le modèle logistique dans les enquêtes cas-témoins.

Cela signifie que les coefficients  $\beta$  obtenus donnent toujours les odds-ratios par la relation  $OR = e^\beta$ .

On peut noter que cela est cohérent avec le fait que OR peut être estimé dans tous les types d'enquête.

◇ Démonstration

Soit  $f_0$  et  $f_1$  les fractions de sondage des témoins ( $Y = 0$ ) et des malades ( $Y = 1$ ).

$$\text{On a : } P(Y=1|X) = f_1 \frac{1}{1 + \exp\left\{-\left(\alpha + \sum \beta_i X_i\right)\right\}}$$

$$P(Y=0|X) = 1 - P(Y=1|X) = f_0 \frac{\exp\left\{-\left(\alpha + \sum \beta_i X_i\right)\right\}}{1 + \exp\left\{-\left(\alpha + \sum \beta_i X_i\right)\right\}}$$

$$\text{D'où : } \frac{P(Y = 1 | X)}{1 - P(Y = 1 | X)} = \frac{f_1}{f_0} \exp\left(\alpha + \sum \beta_i X_i\right)$$

et donc :

$$\text{Logit } P = \text{Ln}\left(\frac{P(Y = 1 | X)}{1 - P(Y = 1 | X)}\right) = \text{Ln}\left(\frac{f_1}{f_0}\right) + \left(\alpha + \sum \beta_i X_i\right) = \alpha' + \sum \beta_i X_i$$

Les coefficients  $\beta_i$  (et donc les  $OR_i$ ) ne changent pas, mais la constante  $\alpha$  n'est pas interprétable.

# Estimation des paramètres

$$\text{Modèle : } P(M^+ | X) = \frac{1}{1 + e^{-(\alpha + \beta x)}}$$

Observations : échantillon de N sujets  $\rightarrow (x_i, y_i) \quad i=1, N$

$\alpha$  et  $\beta$  sont estimés par la méthode du maximum de vraisemblance : les estimations obtenues sont notées  $\hat{\alpha}$  et  $\hat{\beta}$ .

# Vraisemblance d'un échantillon

Définition : la vraisemblance d'un échantillon est la probabilité d'observer l'échantillon. Elle est notée  $V$  (en anglais  $L$  pour likelihood).

Exemple : variable dichotomique ( $M^+ / M^-$ )

$P$  = pourcentage de malades dans la population

- |  |  |  |
|--|--|--|
| <ul style="list-style-type: none"><li>• Echantillon de 1 sujet</li><li>- sujet malade : <math>V = P</math></li><li>- sujet non malade : <math>V = 1-P</math></li></ul> |  | <ul style="list-style-type: none"><li>• Echantillon de 2 sujets</li><li>- <math>M^+M^+</math> : <math>V = P^2</math></li><li>- <math>M^-M^-</math> : <math>V = (1-P)^2</math></li><li>- <math>M^+M^-</math> : <math>V = P(1-P) + (1-P)P = 2P(1-P)</math></li></ul> |
|--|--|--|

• De façon générale, soit un échantillon de  $n$  sujets avec  $k$  malades  
Notons  $p_i$  la probabilité d'observer le sujet  $i$

La vraisemblance de l'échantillon est  $V = c \prod_{i=1}^n p_i$

où  $c$  = nombre d'échantillons possibles avec  $k$  malades

$$c = C_n^k = \frac{n!}{k!(n-k)!} \quad \text{où } n! = n(n-1)\dots 1 \quad 0! = 1$$

Comme on a :

$$p_i = P \quad \text{si le sujet } i \text{ est malade}$$

$$p_i = (1-P) = Q \quad \text{si le sujet } i \text{ est non malade}$$

$$\text{On obtient : } \boxed{V = C_n^k P^k (1-P)^{n-k}}$$

- La valeur de la vraisemblance dépend du nombre de malades dans l'échantillon, mais aussi de P.

Considérons un échantillon de  $n=20$  sujets où on observe  $k=5$  malades

-  $P=10\%$

$$V = C_{20}^5 0,10^5 0,90^{15} = \frac{20!}{5!15!} 0,10^5 0,90^{15} = 0,03$$

-  $P = 25\%$ ,  $V' = C_{20}^5 0,25^5 0,75^{15} = 0,20$

→ *fonction de vraisemblance* :  $V = C_{20}^5 P^5 (1-P)^{15}$

- Lorsqu'on ne connaît pas P, mais qu'on observe n et k sur un échantillon, on se sert de la vraisemblance pour estimer P :

Estimation du maximum de vraisemblance =  
valeur  $p_0$  qui maximise V (connaissant n et k)

Ici, l'estimation du maximum de vraisemblance est  $\frac{k}{n}$ .

• Propriétés :

- Les estimateurs du maximum de vraisemblance ont une distribution asymptotiquement normale
- La méthode du maximum de vraisemblance permet de calculer la variance des paramètres estimés

# Estimation des paramètres du modèle logistique

Dans un échantillon de  $n$  sujet, les observations sont les couples  $(x_i, y_i)$  où  $y_i = 1$  ou  $0$  selon qu'il s'agit d'un malade ou d'un non malade et  $x_i$  est la valeur de  $x$  pour le sujet  $i$ .

La vraisemblance s'écrit toujours :  $V = c \prod_{i=1}^n p_i$

avec  $c = \frac{n!}{k!(n-k)!}$  et  $p_i =$  probabilité d'observer le sujet  $i$

Le modèle logistique permet d'exprimer la probabilité  $P$  d'être malade en fonction de la valeur de  $X$  :  $P = P(M^+|X) = \frac{1}{1 + e^{-(\alpha + \beta x)}}$

Pour le sujet  $i$ , on a donc :

$$p_i = P(M^+|X=x_i) = \frac{1}{1 + e^{-(\alpha + \beta x_i)}} \quad \text{si le sujet est malade}$$

$$p_i = P(M^-|x_i) = 1 - P(M^+|x_i) = \frac{e^{-(\alpha + \beta x_i)}}{1 + e^{-(\alpha + \beta x_i)}} \quad \text{s'il est non malade}$$

On obtient finalement :

$$V = c \frac{\prod_{\text{non malades}} e^{-(\alpha + \beta x_i)}}{\prod_{\text{tous}} (1 + e^{-(\alpha + \beta x_i)})}$$

Vraisemblance de l'échantillon : 
$$V = c \frac{\prod_{\text{non malades}} e^{-(\alpha + \beta x_i)}}{\prod_{\text{tous}} (1 + e^{-(\alpha + \beta x_i)})}$$

Les estimations du maximum de vraisemblance de  $\alpha$  et  $\beta$  sont les valeurs  $\hat{\alpha}$  et  $\hat{\beta}$  qui rendent  $V$  maximum.

Il n'y a de solutions explicites pour  $\hat{\alpha}$  et  $\hat{\beta}$  que dans le cas d'un seul coefficient  $\beta$  et d'une variable  $X$  dichotomique. Sinon (quand il y a plusieurs variables  $X$ ), il faut procéder par itérations, et les valeurs obtenues sont des approximations numériques

NB : en fait les logiciels donnent  $\ln V$  et non  $V$ , et ne font pas figurer "c" (ce qui ne change rien pour la recherche du maximum)

# Exemple<sup>1</sup>

## Grossesse extra-utérine et antécédent de salpingite

- La variable maladie est notée "ct" (0 = accouchement; 1= GEU)
- La variable "exposition" est notée "salp" (salpingite clinique prouvée ou suspectée : 0 = non ; 1 = oui)

Le modèle est donc :  $\text{Logit}P = \alpha + \beta \text{salp}$

$$\text{ou : } P(M^+ | \text{salp}) = \frac{1}{1 + e^{-(\alpha + \beta \text{salp})}}$$

```
. tab ct salp
```

0:acc 1:GEU	salp clinique prouv ou susp		Total
	0	1	
0	1,122	26	1,148
1	466	91	557
Total	1,588	117	1,705

<sup>1</sup> Sauf mention contraire, les exemples s'appuient sur une enquête cas-témoins sur les facteurs de risque de la grossesse extra-utérine (GEU). Les données sont disponibles à l'adresse <https://sites.google.com/site/master2eq/> sous les formats Stata et Excel (fichier geu)

$$\text{Logit}P = \alpha + \beta \text{salp}$$

. tab ct salp

0:acc 1:GEU	salp clinique prouv ou susp		Total
	0	1	
0	1,122	26	1,148
1	466	91	557
Total	1,588	117	1,705

Contribution à la vraisemblance :

$$91 \text{ sujets } E^+ M^+ : p_1 = \frac{1}{1 + e^{-(\alpha+\beta)}}$$

$$466 \text{ sujets } E^- M^+ : p_2 = \frac{1}{1 + e^{-\alpha}}$$

$$26 \text{ sujets } E^+ M^- : p_3 = \frac{e^{-(\alpha+\beta)}}{1 + e^{-(\alpha+\beta)}}$$

$$1122 \text{ sujets } E^- M^- : p_4 = \frac{e^{-\alpha}}{1 + e^{-\alpha}}$$

$$V = C p_1^{91} p_2^{466} p_3^{26} p_4^{1122} = \frac{[e^{-(\alpha+\beta)}]^{26} [e^{-\alpha}]^{1122}}{[1 + e^{-(\alpha+\beta)}]^{117} [1 + e^{-\alpha}]^{1588}}$$

# Exemple (suite)

Grossesse extra-utérine et antécédent de salpingite

$$\text{Logit } P = \alpha + \beta \text{salp}$$

```
. logit ct salp

Iteration 0:  log likelihood = -1077.2309
Iteration 1:  log likelihood = -1023.1123
Iteration 2:  log likelihood = -1023.0534
Iteration 3:  log likelihood = -1023.0534

Logistic regression               Number of obs   =       1705
                                IR chi2(1)       =       108.36
                                Prob > chi2      =       0.0000
                                Pseudo R2         =       0.0503

Log likelihood = -1023.0534
```

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
salp	2.131445	.229102	9.30	0.000	1.682413	2.580476
_cons	-.8786825	.0551107	-15.94	0.000	-.9866974	-.7706675

$$\hat{\alpha} = -0,879$$

$$s_{\hat{\alpha}} = 0,0551$$

$$\hat{\beta} = 2,131$$

$$s_{\hat{\beta}} = 0,229$$

$$\text{OR} = e^{\hat{\beta}} = 8,42$$

Intervalle de confiance

$$\text{I.C. de } \beta : \hat{\beta} \pm z_{\alpha/2} s_{\hat{\beta}} = 2,131 \pm 1,96 \times 0,229 = [1,682 ; 2,580]$$

$$\text{D'où : I.C. de OR : } [e^{1,682} ; e^{2,580}] = [5,38 ; 13,20]$$

- On peut obtenir directement l'odds ratio et son intervalle de confiance avec la commande "logistic" :

```
. logistic ct salp
```

<b>Logistic regression</b>		Number of obs	=	1705
Log likelihood = -1023.0534		LR chi2(1)	=	108.36
		Prob > chi2	=	0.0000
		Pseudo R2	=	0.0503

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
salp	8.427032	1.93065	9.30	0.000	5.378519 13.20343
_cons	.4153298	.0228891	-15.94	0.000	.3728059 .4627041

- On retrouve les mêmes résultats avec le tableau initial :

$$OR = \frac{ad}{bc} = \frac{91 \times 1122}{26 \times 466} = 8,43$$

```
. cc ct salp,w
```

	salp clinique prouv ou susp		Total	Proportion Exposed
	Exposed	Unexposed		
Cases	91	466	557	0.1634
Controls	26	1122	1148	0.0226
Total	117	1588	1705	0.0686
	Point estimate		[95% Conf. Interval]	
Odds ratio	8.427039		5.378522	13.20344 (Woolf)
Attr. frac. ex.	.8813344		.8140753	.9242621 (Woolf)
Attr. frac. pop	.1439882			

chi2(1) = 116.21 Pr>chi2 = 0.0000

# Tests des paramètres

Hypothèse testée :  $H_0 : OR = 1 \Leftrightarrow \beta=0 \Leftrightarrow P_0=P_1$   
 $H_1 : OR \neq 1$

- Test de  $\chi^2$  “habituel”

	E <sup>+</sup>	E <sup>-</sup>	
M+	a	b	m <sub>1</sub>
M-	c	d	m <sub>0</sub>
	n <sub>1</sub>	n <sub>0</sub>	n

$$\chi_c^2 = \frac{\left( |ad - bc| - \frac{n}{2} \right)^2 n}{n_1 n_2 m_1 m_2}$$

- Test de Wald

si  $H_0$  est vraie,  $z = \frac{\hat{\beta} - 0}{s_{\hat{\beta}}}$

=> on calcule  $z_0 = \frac{\hat{\beta}}{s_{\hat{\beta}}}$  et on compare au seuil de la loi normale

centrée réduite  $N(0,1)$

Souvent exprimé sous forme de  $\chi^2$  :

si  $H_0$  est vrai,  $\chi_0^2 = \frac{\hat{\beta}^2}{s_{\hat{\beta}}^2} = \frac{\hat{\beta}^2}{\text{var}(\hat{\beta})}$  suit une loi de  $\chi^2$  à 1 ddl

## • Test du rapport des vraisemblances

modèle 1 :  $\text{Logit } P = \alpha$       X n'est pas associé à P  
vraisemblance :  $V_1$

modèle 2 :  $\text{Logit } P = \alpha' + \beta X$       vraisemblance :  $V_2$

$V_1 \leq V_2$  car le modèle 2 est plus complet

$\beta$  est différent de 0 si  $V_1$  est inférieure à  $V_2$

Test :  $2 \ln \frac{V_2}{V_1} = 2 \ln(V_2) - 2 \ln(V_1)$  suit une loi de  $\chi^2$  à 1ddl

# Exemple

## Association GEU - Antécédent de salpingite

- Test du  $\chi^2$  "habituel"

```
. tab ct salp,chi
```

0:acc 1:GEU	salp clinique prouv ou susp		Total
	0	1	
0	1,122	26	1,148
1	466	91	557
Total	1,588	117	1,705

Pearson chi2(1) = 116.2093 Pr = 0.000

- Test de Wald

```
. logistic ct salp
```

Logistic regression

Log likelihood = -1023.0534

Number of obs	=	1705
LR chi2(1)	=	108.36
Prob > chi2	=	0.0000
Pseudo R2	=	0.0503

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
salp	8.427032	1.93065	9.30	0.000	5.378519	13.20343
_cons	.4153298	.0228891	-15.94	0.000	.3728059	.4627041

- Test du rapport des vraisemblances

```

. logistic ct salp

Logistic regression               Number of obs   =      1705
                                LR chi2(1)       =      108.36
                                Prob > chi2        =      0.0000
Log likelihood = -1023.0534      Pseudo R2      =      0.0503

-----+-----
      ct | Odds Ratio   Std. Err.      z    P>|z|     [95% Conf. Interval]
-----+-----
      salp |   8.427032   1.93065     9.30  0.000    5.378519   13.20343
      _cons |   .4153298   .0228891   -15.94  0.000    .3728059   .4627041

. est store a

. logistic ct if salp!=.

Logistic regression               Number of obs   =      1705
                                LR chi2(0)       =      -0.00
                                Prob > chi2        =      .
Log likelihood = -1077.2309      Pseudo R2      =      -0.0000

-----+-----
      ct | Odds Ratio   Std. Err.      z    P>|z|     [95% Conf. Interval]
-----+-----
      _cons |   .4851916   .025054   -14.01  0.000    .4384899   .5368674

. est store b

. lrtest a b

Likelihood-ratio test
(Assumption: b nested in a)      LR chi2(1)    =      108.36
                                Prob > chi2    =      0.0000

```

$\chi^2$ "habituel"	Wald	Rapport des vraisemblances
116,2	86,49 (9,30 <sup>2</sup> )	108,36

- Le test du rapport de vraisemblance ne s'applique qu'à 2 modèles emboîtés

$M_2$  est emboîté dans  $M_1$  (ou est un sous-modèle de  $M_1$ ) si, en partant de  $M_1$  et en imposant certaines relations entre ses coefficients, on retrouve le modèle  $M_2$ . C'est le cas, en particulier, quand on passe de  $M_1$  à  $M_2$  en enlevant une variable.

exemple : les 2 modèles suivants ne sont pas comparables (pas emboîtés)

modèle 1 :  $\text{Logit } P = \alpha + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3$

modèle 2 :  $\text{Logit } P = \alpha' + \beta'_1 X_1 + \beta'_2 X_2 + \beta'_4 X_4$

- De plus, les deux vraisemblances doivent être calculées sur les mêmes sujets

```
. logistic ct salp
Logistic regression               Number of obs =      1705
                                LR chi2(1)         =      108.36
                                Prob > chi2        =       0.0000
Log likelihood = -1023.0534       Pseudo R2         =       0.0503

-----+-----
      ct | Odds Ratio   Std. Err.      z    P>|z|   [95% Conf. Interval]
-----+-----
      salp |   8.427032   1.93065   9.30  0.000   5.378519   13.20343
      _cons |   .4153298   .0228891  -15.94 0.000   .3728059   .4627041

. est store a

. logistic ct
Logistic regression               Number of obs =      1725
                                LR chi2(0)         =       0.00
                                Prob > chi2        =       .
Log likelihood = -1097.2925       Pseudo R2         =       0.0000

-----+-----
      ct | Odds Ratio   Std. Err.      z    P>|z|   [95% Conf. Interval]
-----+-----
      _cons |   .4986968   .0254822  -13.62 0.000   .451172   .5512276

. est store b
.
. lrtest a b
observations differ: 1705 vs. 1725
```

- Les tests de Wald et du rapport de vraisemblance s'étendent au test de plusieurs coefficients à la fois

Exemple avec 2 paramètres

modèle 1 :  $\text{Logit } P = \alpha + \beta_1 X_1$

modèle 2 :  $\text{Logit } P = \alpha' + \beta_1' X_1 + \beta_2' X_2 + \beta_3' X_3$

$H_0 : \beta_2 = 0 \text{ et } \beta_3 = 0$

$H_1 : \beta_2 \neq 0 \text{ ou } \beta_3 \neq 0$

### • Test du rapport des vraisemblances

Test :  $2 \text{ Ln} \frac{V_2}{V_1} = 2 \text{ Ln} (V_2) - 2 \text{ Ln} (V_1)$  suit une loi de  $\chi^2$  à 2 ddl

### • Test de Wald

$\chi_0^2 = \frac{\hat{\beta}^2}{\text{var}(\hat{\beta})}$  à 1 ddl pour un paramètre s'étend en un  $\chi^2$  à 2 ddl

En effet :  $z_0 = \frac{\hat{\beta}}{s_{\hat{\beta}}} \Leftrightarrow \chi_0^2 = \frac{\hat{\beta}^2}{\text{var}(\hat{\beta})} = (\hat{\beta})' [\text{var}(\hat{\beta})]^{-1} (\hat{\beta})$

extension :  $\theta = \begin{pmatrix} \beta_1 \\ \beta_2 \end{pmatrix} \quad \text{var}(\theta) = \begin{pmatrix} \text{var}(\beta_1) & \text{cov}(\beta_1, \beta_2) \\ \text{cov}(\beta_1, \beta_2) & \text{var}(\beta_2) \end{pmatrix}$

Test :  $\chi_0^2 = (\hat{\theta})' [\text{var}(\hat{\theta})]^{-1} (\hat{\theta})$  à 2 ddl

# Exemple

univf : niveau d'études universitaires; fprof : activité prof. femme

```
. logistic ct salp univf fprof
```

Logistic regression	Number of obs	=	1230
	LR chi2(3)	=	71.66
	Prob > chi2	=	0.0000
Log likelihood = -730.93713	Pseudo R2	=	0.0467

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
salp	7.392144	1.944662	7.60	0.000	4.414114 12.37933
univf	.8476072	.1323978	-1.06	0.290	.624073 1.151208
fprof	1.369012	.198271	2.17	0.030	1.030694 1.818381
_cons	.3314003	.0405161	-9.03	0.000	.2607878 .4211322

Le modèle logistique s'écrit :  $\text{Logit } P = \alpha + \beta_1 \text{salp} + \beta_2 \text{univf} + \beta_3 \text{fprof}$

L'hypothèse testée est :

$$H_0 : \beta_2 = 0 \text{ et } \beta_3 = 0$$

$H_1 : \beta_2 \neq 0 \text{ ou } \beta_3 \neq 0$  nb : dans le cas présent, le test simultané de  $\beta_2$  et  $\beta_3$  a un intérêt limité. Il n'est donné qu'à titre d'exemple. Voir plus loin des situations où c'est plus utile (variables indicatrices)

```

. logistic ct salp univf fprof

Logistic regression               Number of obs =      1230
                                LR chi2(3)         =      71.66
                                Prob > chi2        =      0.0000
Log likelihood = -730.93713      Pseudo R2         =      0.0467

```

---

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
salp	7.392144	1.944662	7.60	0.000	4.414114 12.37933
univf	.8476072	.1323978	-1.06	0.290	.624073 1.151208
fprof	1.369012	.198271	2.17	0.030	1.030694 1.818381
_cons	.3314003	.0405161	-9.03	0.000	.2607878 .4211322

$H_0 : \beta_2 = 0 \text{ et } \beta_3 = 0$   
 $H_1 : \beta_2 \neq 0 \text{ ou } \beta_3 \neq 0$

• Test de Wald

```

. testparm univf fprof

( 1) [ct]univf = 0
( 2) [ct]fprof = 0

      chi2( 2) =      5.06
      Prob > chi2 =      0.0797

```

• Test du rapport des vraisemblances

```

. est store a

. logistic ct salp if univf!=. & fprof!=.

Logistic regression               Number of obs =      1230
                                LR chi2(1)         =      66.53
                                Prob > chi2        =      0.0000
Log likelihood = -733.50452      Pseudo R2         =      0.0434

```

---

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
salp	7.151568	1.872462	7.51	0.000	4.2809 11.94724
_cons	.3995128	.0260965	-14.05	0.000	.3515034 .4540795

```

. est store b
.
. lrtest a b

Likelihood-ratio test           LR chi2(2) =      5.13
(Assumption: b nested in a)    Prob > chi2 =      0.0767

```

# Exercice 1

Cet exercice, ainsi que les suivants (exercice 2 et 3), font l'objet de la 1<sup>ère</sup> séance de TP. Ils reposent sur le fichier de données `geu.dta` (format Stata) ou `geu.xls` (format Excel) disponible sur le site web. Ils seront réalisés et corrigés en TP avec le logiciel Stata. Le format Excel vous permet cependant d'avoir accès aux données sans le logiciel Stata.

1. Calculez l'odds ratio de GEU associé à un antécédent d'accouchement (variable `aacc`) et son intervalle de confiance.

Est-il significativement différent de 1 ?

2. a) Calculez l'odds ratio de GEU associé à un antécédent d'accouchement et son intervalle de confiance après ajustement sur l'âge (prendre la variable `age30` (0 : < 30 ans 1 : ≥ 30 ans)).

b) Testez si cet odds ratio est différent de 1 par les différentes méthodes que vous connaissez.

c) L'âge est-il facteur de confusion pour la relation entre le risque de GEU et l'antécédent d'accouchement ?

3. Les antécédents obstétricaux (accouchement, `fcs`, `ivg` et `geu`) sont-ils globalement liés au risque de GEU ?

(les variables correspondantes dans le fichier de données sont `aacc`, `afcs`, `aivg`, et `ageu`)

# Interprétation des coefficients et codage des variables

De façon générale, si  $\text{Logit } P = \alpha + \beta X$ , l'odds ratio entre les catégories  $X = x_1$  et  $X = x_0$  est donné par :

$$\text{Ln OR} = \text{Logit } P_1 - \text{Logit } P_0 = (\alpha + \beta x_1) - (\alpha + \beta x_0) = \beta(x_1 - x_0)$$

d'où :  $\text{OR} = e^{\beta(x_1 - x_0)}$

Exemple :  $X = \text{age}$

```
. logit ct agea
Iteration 0:  log likelihood = -1095.6718
Iteration 1:  log likelihood = -1068.2162
Iteration 2:  log likelihood = -1068.1198
Iteration 3:  log likelihood = -1068.1198

Logistic regression               Number of obs   =       1721
                                LR chi2(1)       =        55.10
                                Prob > chi2      =       0.0000
Log likelihood = -1068.1198      Pseudo R2      =       0.0251
```

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
agea	.0772543	.0105806	7.30	0.000	.0565166	.0979919
_cons	-2.965807	.3185008	-9.31	0.000	-3.590057	-2.341556

$$\text{Logit } P = -3,00 + 0,0772 \text{ age}$$

$$\text{OR entre } X_0 = 29 \text{ et } X_1 = 30 : \text{OR} = \exp(0,0772) = 1,08$$

$$\begin{aligned} \text{OR entre } X_0 = 25 \text{ et } X_1 = 40 : \text{OR} &= \exp(15 \times 0,0772) = 1,08^{15} \\ &= 3,18 \end{aligned}$$

# 1. X qualitative à 2 classes (dichotomique)

X=1 : exposé

X=0 : non exposé

$$e^{\beta} = \text{OR}$$

Autre codage de X

X= +1 : exposé ( $x_1$ )

X= -1 : non exposé ( $x_0$ )

$$\text{OR} = e^{\beta(x_1 - x_0)} = e^{2\beta}$$

Coefficient  $\beta \leftrightarrow \text{oddsratio}$

```

.gen z=2*salp-1
(20 missing values generated)

.tab salp z,miss
  salp |
clinique |
prouv ou |
 susp |      -1      1      . | Total
-----+-----+-----+-----
      0 |     1,588      0      0 |   1,588
      1 |          0     117      0 |    117
      . |          0      0     20 |    20
-----+-----+-----+-----
 Total |     1,588     117     20 |   1,725

.logistic ct salp

Logistic regression               Number of obs =      1705
LR chi2(1)                        =     108.36
Prob > chi2                        =     0.0000
Pseudo R2                          =     0.0503

Log likelihood = -1023.0534

-----+-----+-----+-----+-----+-----+-----+
      ct | Odds Ratio  Std. Err.      z    P>|z|    [95% Conf. Interval]
-----+-----+-----+-----+-----+-----+-----+
      salp |  8.427032   1.93065   9.30  0.000   5.378519   13.20343
      _cons |  .4153298   .0228891  -15.94  0.000   .3728059   .4627041

.logistic ct z

Logistic regression               Number of obs =      1705
LR chi2(1)                        =     108.36
Prob > chi2                        =     0.0000
Pseudo R2                          =     0.0503

Log likelihood = -1023.0534

-----+-----+-----+-----+-----+-----+-----+
      ct | Odds Ratio  Std. Err.      z    P>|z|    [95% Conf. Interval]
-----+-----+-----+-----+-----+-----+-----+
      z |  2.902935   .3325341   9.30  0.000   2.319163   3.633652
      _cons |  1.205675   .1381113   1.63  0.103   .9632176   1.509164
  
```

8,427 = 2,903<sup>2</sup>

# Interprétation des coefficients et codage des variables

## 2. X qualitative nominale à plus de 2 classes

$Y = \text{GEU}$	$X =$	$X=0 \rightarrow \text{Non induite}$
	induction de	$X=1 \rightarrow \text{Hcg}$
	la grossesse	$X=2 \rightarrow \text{Clomid}$
		$X=3 \rightarrow \text{Autre}$

Logit P =  $\alpha + \beta X$

Entre les catégories  $X=0$  et  $X=1$  :  $\text{OR}_{0,1} = e^{\beta}$

$$\text{Ln}(\text{OR}_{0,1}) = \text{Logit } P_1 - \text{Logit } P_0 = (\alpha + \beta) - \alpha = \beta$$

Entre les catégories  $X=0$  et  $X=2$  :  $\text{OR}_{0,2} = e^{2\beta} = (\text{OR}_{0,1})^2$

$X=2 \rightarrow E^+$ ,  $X=0 \rightarrow E^-$

$$\text{D'où : } \text{Ln}(\text{OR}_{0,2}) = \text{Logit } P_1 - \text{Logit } P_0 = (\alpha + 2\beta) - \alpha = 2\beta$$

On obtient donc : OR associé à Clomid est le carré de celui associé à Hcg

$$Y = \text{GEU}$$

$$X = \begin{array}{|l} X=0 \rightarrow \text{Non induite} \\ X=1 \rightarrow \text{Hcg} \\ X=2 \rightarrow \text{Clomid} \\ X=3 \rightarrow \text{Autre} \end{array}$$

$$\text{Logit } P = \alpha + \beta X$$

En prenant la catégorie "Non induite" comme référence :

- $\text{OR}^{\text{"Hcg"}} = e^{\beta}$
- $\text{OR}^{\text{"Autre"}} = e^{3\beta} = (\text{OR}^{\text{"Hcg"}})^3$
- $\text{OR}^{\text{"Clomid"}} = e^{2\beta} = (\text{OR}^{\text{"Hcg"}})^2$

Le modèle contient ces relations entre les odds-ratios dans son écriture (c'est-à-dire indépendamment des données observées).

Si le codage avait été :

$X'=0 \rightarrow \text{Non induite}$

$X'=1 \rightarrow \text{Clomid}$

$X'=2 \rightarrow \text{Hcg}$

$X'=3 \rightarrow \text{Autre}$

$$\text{Logit } P = \alpha' + \beta' X'$$

On aurait obtenu (toujours avec la catégorie "Non induite" comme référence) :

- $\text{OR}^{\text{"Clomid"}} = e^{\beta'}$
- $\text{OR}^{\text{"Autre"}} = e^{3\beta'} = (\text{OR}^{\text{"Clomid"}})^3$
- $\text{OR}^{\text{"Hcg"}} = e^{2\beta'} = (\text{OR}^{\text{"Clomid"}})^2$

**Une variable X qualitative nominale à plus de 2 classes ne doit jamais être incluse dans un modèle logistique sous sa forme initiale.**





	$X_1$	$X_2$	$X_3$	
0	0	0	0	$\text{Logit } P = \alpha + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3$
1	1	0	0	
$X = 2$	0	1	0	
3	0	0	1	

$X_1$ ,  $X_2$  et  $X_3$  sont appelées des variables indicatrices.

- $\beta_1 = \text{Ln}(\text{OR}_{0,1})$

$\text{Ln}(\text{OR}_{0,1}) = \text{Logit } P_1 - \text{Logit } P_0$

$P_1$  correspond à  $X_1 = 1, X_2 = 0, X_3 = 0$

$P_0$  correspond à  $X_1 = 0, X_2 = 0, X_3 = 0$

D'où :  $\text{Ln}(\text{OR}_{0,1}) = (\alpha + \beta_1) - \alpha = \beta_1$

De même :

- $\beta_2 = \text{Ln}(\text{OR}_{0,2})$

- $\beta_3 = \text{Ln}(\text{OR}_{0,3})$

- $\text{Ln}(\text{OR})$  entre les catégories 1 et 2 =  $\beta_2 - \beta_1$

Dans Stata, des variables indicatrices sont construites en ajoutant i. devant le nom de la variable.

- voir "factor variables" dans la documentation ou le help de Stata

- l'ancienne méthode nécessitait d'ajouter "xi" devant la commande (voir la syntaxe dans le help). Elle est toujours utile pour les commandes non compatibles avec "factor variables".

# Exemple

(suite)

```
. logit ct i.gind
```

Logistic regression

Log likelihood = -1088.8724

Number of obs = 1719  
LR chi2(3) = 9.20  
Prob > chi2 = 0.0267  
Pseudo R2 = 0.0042

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
gind						
1	.4706954	.4239421	1.11	0.267	-.3602159	1.301607
2	.6663683	.2637133	2.53	0.012	.1494998	1.183237
3	.9562032	.672907	1.42	0.155	-.3626703	2.275077
_cons	-.7330597	.0529515	-13.84	0.000	-.8368426	-.6292767

4 variables indicatrices sont créées correspondant aux 4 classes 0, 1, 2 et 3 de gind. Elles n'apparaissent pas dans la liste des variables, mais sont accessibles avec les noms 0.gind, 1.gind, 2.gind et 3.gind.

Par défaut, la catégorie gind = 0 (valeur la plus petite de gind) est prise comme référence. Cela se traduit par l'omission de la variable 0.gind dans le modèle logistique.

On peut imposer une autre catégorie de référence (ou de base) en remplaçant `i.` par `ib(#)` où `#` est la valeur de la catégorie de référence voulue ou par `ib(##)` où `#` est le numéro d'ordre de la catégorie de référence voulue.

Par exemple, pour prendre comme référence la catégorie codée 2, il faut écrire `ib(2).gind` ou `ib(#3).gind`.

```
. logit ct ib(2).gind
```

```
Logistic regression           Number of obs =      1719
                              LR chi2(3)           =         9.20
                              Prob > chi2          =         0.0267
Log likelihood = -1088.8724    Pseudo R2          =         0.0042
```

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
gind						
0	-.6663683	.2637133	-2.53	0.012	-1.183237	-.1494998
1	-.1956729	.4936232	-0.40	0.692	-1.163157	.7718109
3	.2898349	.7188469	0.40	0.687	-1.119079	1.698749
_cons	-.0666914	.2583425	-0.26	0.796	-.5730333	.4396505

```
. logit ct ib(#3).gind
```

```
Logistic regression           Number of obs =      1719
                              LR chi2(3)           =         9.20
                              Prob > chi2          =         0.0267
Log likelihood = -1088.8724    Pseudo R2          =         0.0042
```

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
gind						
0	-.6663683	.2637133	-2.53	0.012	-1.183237	-.1494998
1	-.1956729	.4936232	-0.40	0.692	-1.163157	.7718109
3	.2898349	.7188469	0.40	0.687	-1.119079	1.698749
_cons	-.0666914	.2583425	-0.26	0.796	-.5730333	.4396505

# Exemple

## (suite)

```
. tab ct gind
```

0:acc 1:GEU	0:non ind 0	1:hcg 1	2:clomid 2	3:autr 3	Total
0	1,099	13	31	4	1,147
1	528	10	29	5	572
Total	1,627	23	60	9	1,719

$$OR_{Hcg} = \frac{10 \times 1099}{13 \times 528} = 1,60$$

```
. logit ct i.gind
```

Logistic regression

Number of obs = 1719

LR chi2(3) = 9.20

Prob > chi2 = 0.0267

Pseudo R2 = 0.0042

Log likelihood = -1088.8724

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
gind						
1	.4706954	.4239421	1.11	0.267	-.3602159	1.301607
2	.6663683	.2637133	2.53	0.012	.1494998	1.183237
3	.9562032	.672907	1.42	0.155	-.3626703	2.275077
_cons	-.7330597	.0529515	-13.84	0.000	-.8368426	-.6292767

$$\text{Logit } P = -0,73 + 0,47 X_1 + 0,67 X_2 + 0,96 X_3$$

$$OR_{Hcg} = e^{0,47} = 1,60 \quad OR_{Clomid} = e^{0,67} = 1,95$$

$$OR_{Autre} = e^{0,96} = 2,61$$

Lorsqu'on décompose  $X$  en variables indicatrices, celles-ci doivent être toutes présentes (ou absentes) du modèle *en même temps*.

Supposons qu'on enlève  $X_3$

	$X_1$	$X_2$	$X_3$
0	0	0	0
1	1	0	0
2	0	1	0
3	0	0	1

$$\text{Logit } P = \alpha' + \beta'_1 X_1 + \beta'_2 X_2$$

Les catégories 0 et 3 de  $X$  ne sont plus distinguables avec les variables restantes  $X_1$  et  $X_2$ .

Le coefficient  $\beta'_1$  de la variable  $X_1$  n'a plus le sens précédent.

Il devient le logarithme de l'odds ratio entre la catégorie  $X=1$  et les catégories  $X = 0$  et  $X = 3$  réunies.

=> retirer  $X_3$  revient à regrouper les catégories  $X = 0$  et  $X = 3$ .

$$\text{Logit } P = \alpha + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3$$

Le test de l'association entre X et la maladie doit être un test global

$$H_0 : \beta_1 = \beta_2 = \beta_3 = 0 \quad H_1 : \beta_1 \neq 0 \text{ ou } \beta_2 \neq 0 \text{ ou } \beta_3 \neq 0$$

```
. logistic ct i.gind
```

```
Logistic regression           Number of obs =      1719
                              LR chi2(3)           =       9.20
                              Prob > chi2          =      0.0267
Log likelihood = -1088.8724    Pseudo R2          =      0.0042
```

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
<b>gind</b>					
1	1.601107	.6787768	1.11	0.267	.6975257 3.675197
2	1.947153	.51349	2.53	0.012	1.161253 3.264925
3	2.601799	1.750769	1.42	0.155	.6958158 9.728665
<b>_cons</b>	<b>.4804368</b>	<b>.0254398</b>	<b>-13.84</b>	<b>0.000</b>	<b>.4330757 .5329772</b>

## Test de Wald

```
. testparm i.gind // équivale à testparm 1.gind 2.gind 3.gind
```

- ( 1) [ct]1.gind = 0
- ( 2) [ct]2.gind = 0
- ( 3) [ct]3.gind = 0

```
chi2( 3) = 9.36
Prob > chi2 = 0.0248
```

## Test du rapport de vraisemblance

```
. est store a
```

```
. logistic ct if gin!=.
```

```
Logistic regression           Number of obs =      1719
                              LR chi2(0)          =       0.00
                              Prob > chi2          =       .
Log likelihood = -1093.4734    Pseudo R2          =      0.0000
```

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
<b>_cons</b>	<b>.4986922</b>	<b>.0255265</b>	<b>-13.59</b>	<b>0.000</b>	<b>.4510891 .5513189</b>

```
. est store b
```

```
. lrtest a b
```

```
Likelihood-ratio test           LR chi2(3) = 9.20
(Assumption: b nested in a)     Prob > chi2 = 0.0267
```

On présente les résultats de la façon suivante :

Induction de la grossesse	Total	Témoins %	Cas %	OR et IC	p
non	1627	96	92	1	< 0,03
Hcg	23	1,1	1,8	1,6 [0,7 ; 3,7]	
Clomid	60	2,7	5,1	1,9 [1,2 ; 3,3]	
Autre	9	0,35	0,87	2,6 [0,7 ; 9,7]	

```

. logistic ct i.gind

Logistic regression               Number of obs   =       1719
                                LR chi2(3)       =        9.20
                                Prob > chi2         =       0.0267
Log likelihood = -1088.8724      Pseudo R2       =       0.0042

-----+-----
      ct | Odds Ratio   Std. Err.      z    P>|z|    [95% Conf. Interval]
-----+-----
      gind
      1 |   1.601107   .6787768    1.11  0.267   .6975257   3.675197
      2 |   1.947153   .51349      2.53  0.012   1.161253   3.264925
      3 |   2.601799   1.750769    1.42  0.155   .6958158   9.728665
      _cons | .4804368   .0254398  -13.84  0.000   .4330757   .5329772
-----+-----

. testparm i.gind // équivalent à testparm 1.gind 2.gind 3.gind

( 1) [ct]1.gind = 0
( 2) [ct]2.gind = 0
( 3) [ct]3.gind = 0

      chi2( 3) =    9.36
      Prob > chi2 =   0.0248

```

# Interprétation des coefficients et codage des variables

## 3. X qualitative ordinale

### Exemple

Consommation de tabac comptée en cigarettes par jour

```
. tab ct tabfc
```

0:acc 1:GEU	0:nf;1:1-9;2:10-19;3:≥20				Total
	0	1	2	3	
0	809	158	106	71	1,144
1	264	78	113	94	549
Total	1,073	236	219	165	1,693

En prenant les non fumeuses comme référence, il faut 3 odds ratios pour décrire l'ensemble de l'association GEU - tabac :

Nombre de cigarettes par jour	0	1-9	10-19	≥ 20
OR	1	1,51	3,27	4,06

Pour inclure la variable tabac dans un modèle logistique, il y a deux possibilités :

- "conserver" les 3 odds ratios en décomposant la variable tabac en variables indicatrices (comme précédemment).
- "modéliser" l'association GEU - tabac pour représenter la relation dose-effet (de façon similaire à une régression linéaire)

## A. Décomposition en variables indicatrices

Le modèle correspondant est :  $\text{Logit } P = \alpha + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3$

```
logistic ct i.tabfc
```

Logistic regression

Number of obs = 1693  
 LR chi2(3) = 107.61  
 Prob > chi2 = 0.0000  
 Pseudo R2 = 0.0504

Log likelihood = -1012.8708

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
tabfc					
1	1.512802	.2352084	2.66	0.008	1.11542 2.051756
2	3.26676	.4987294	7.75	0.000	2.421955 4.406242
3	4.057085	.6997357	8.12	0.000	2.893378 5.68883
_cons	.3263288	.0231302	-15.80	0.000	.2840026 .3749631

On retrouve effectivement les 3 odds ratios précédents.

Choix de la catégorie de référence pour la décomposition :

- Il s'impose en pratique quand il y a une catégorie "non exposé".
- Sinon, plusieurs choix sont possibles

Exemple : niveau d'études

```
. tab ct et4
```

0:acc 1:GEU	0:aucune;1:prim;2:sec,tech;3:univ				Total
	0	1	2	3	
0	4	93	781	258	1,136
1	6	36	377	127	546
Total	10	129	1,158	385	1,682

## Référence : X=0 (pas d'études)

. logistic ct i.et4						
Logistic regression			Number of obs	=	1,682	
Log likelihood = -1057.9179			LR chi2(3)	=	4.49	
			Prob > chi2	=	0.2134	
			Pseudo R2	=	0.0021	
ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
+-----						
et4						
1	.2580646	.1741118	-2.01	0.045	.068776	.9683216
2	.3218097	.2087054	-1.75	0.080	.0902743	1.147188
3	.3281655	.2147959	-1.70	0.089	.0909811	1.18368
_cons	1.5	.9682455	0.63	0.530	.4232948	5.315442
-----						
. testparm i.et4						
( 1) [ct]1.et4 = 0						
( 2) [ct]2.et4 = 0						
( 3) [ct]3.et4 = 0						
chi2( 3) = 4.38						
Prob > chi2 = 0.2235						

## Référence : X=1 (niveau d'études primaire)

. logistic ct ibl.et4						
Logistic regression			Number of obs	=	1,682	
Log likelihood = -1057.9179			LR chi2(3)	=	4.49	
			Prob > chi2	=	0.2134	
			Pseudo R2	=	0.0021	
ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
+-----						
et4						
0	3.874999	2.614396	2.01	0.045	1.032715	14.53995
2	1.247012	.2569675	1.07	0.284	.832658	1.867561
3	1.271641	.2851439	1.07	0.284	.8194019	1.973477
_cons	.3870968	.0759839	-4.84	0.000	.2634727	.5687264
-----						
. testparm i.et4						
( 1) [ct]0.et4 = 0						
( 2) [ct]2.et4 = 0						
( 3) [ct]3.et4 = 0						
chi2( 3) = 4.38						
Prob > chi2 = 0.2235						

Finalement, le choix de la catégorie de référence :

- n'a pas de conséquence pour retrouver les différents odds

$$\text{ratios : } 1,247 = \frac{0,322}{0,258}$$

- peut changer "l'impression" donnée par les odds ratios présentés ou leur précision si une catégorie a un effectif petit

## B. Modélisation de l'association GEU - tabac

La décomposition en variables indicatrices ne tient pas compte de l'ordre des catégories de la variable tabac.

=> perte d'information et perte de puissance possible s'il y a une relation dose-effet.

0:acc 1:GEU	0:nf;1:1-9;2:10-19;3:>=20				Total
	0	1	2	3	
0	809	158	106	71	1,144
1	264	78	113	94	549
Total	1,073	236	219	165	1,693

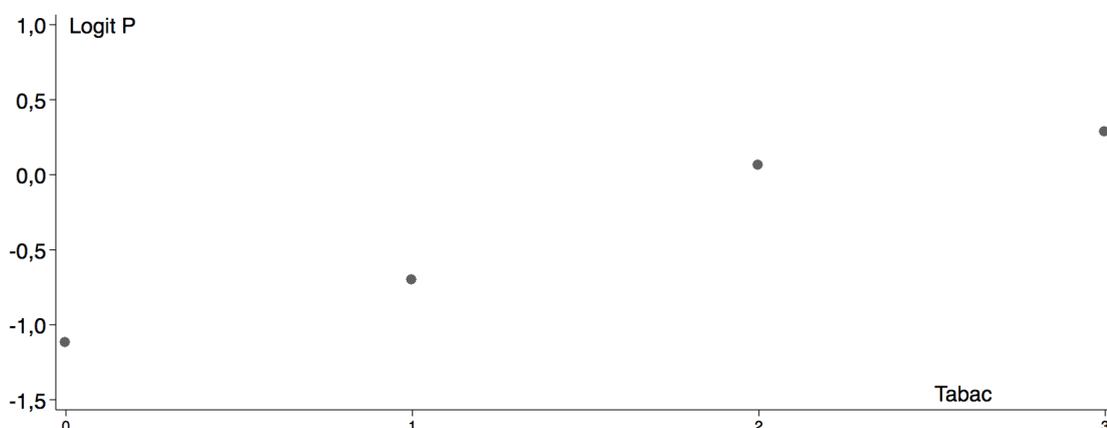
**OR(observé)**      **1**      **1,51**      **3,27**      **4,06**

Le calcul des Logit P pour les 4 catégories de tabac donne :

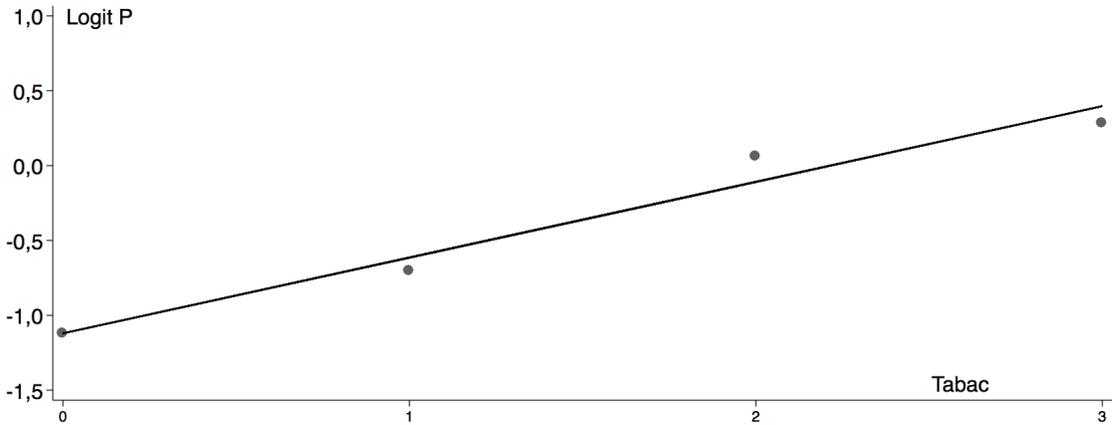
$$\text{Logit } P_0 = \text{Ln}\left(\frac{P_0}{1-P_0}\right) = \text{Ln}\left(\frac{264 / 1073}{809 / 1073}\right) = \text{Ln}\left(\frac{264}{809}\right) = -1,12$$

de même :  $\text{Logit } P_1 = -0,71$      $\text{Logit } P_2 = 0,064$      $\text{Logit } P_3 = 0,28$

D'où la représentation graphique :



=> on peut raisonnablement représenter la variation des logits en fonction de la quantité de cigarettes par une droite.



Le modèle correspondant est :  $\text{Logit } P = \alpha + \beta X$

```
. logit ct tabfc

Logistic regression              Number of obs   =       1693
                                LR chi2(1)      =       104.99
                                Prob > chi2     =       0.0000
                                Pseudo R2       =       0.0492

Log likelihood = -1014.1795

-----+-----
      ct |      Coef.  Std. Err.      z    P>|z|    [95% Conf. Interval]
-----+-----
  tabfc |   .505858   .0499975    10.12  0.000   .4078648   .6038512
   _cons |  -1.120282  .0673178   -16.64  0.000  -1.252222  -.9883411
-----+-----
```

$\exp(\beta) = \exp(0,506) = 1,66$

Nombre de cigarettes par jour	0	1-9	10-19	≥ 20
X	0	1	2	3
OR observé	1	1,51	3,27	4,07
OR donné par le modèle Logit $P = \alpha + \beta X$	1	1,66	2,75	4,56

Les odds ratios donnés par le modèle sont différents des odds ratios observés, mais on a résumé l'association GEU - tabac par un seul paramètre :  $\beta = 0,506$  (ou OR = 1,66).

```

. logit ct tabfc

Logistic regression              Number of obs   =    1693
                                LR chi2(1)       =    104.99
                                Prob > chi2          =    0.0000
Log likelihood = -1014.1795      Pseudo R2       =    0.0492

```

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
tabfc	.505858	.0499975	10.12	0.000	.4078648	.6038512
_cons	-1.120282	.0673178	-16.64	0.000	-1.252222	-.9883411

Nombre de cigarettes par jour	0	1-9	10-19	≥ 20
X	0	1	2	3
OR observé	1	1,51	3,27	4,07
OR donné par le modèle Logit $P = \alpha + \beta X$	1	1,66	2,75	4,56

Pour trouver avec Stata l'odds ratio correspondant à X=2 et son intervalle de confiance, la commande est lincom (linear combination).

```

. lincom 2*tabfc,or

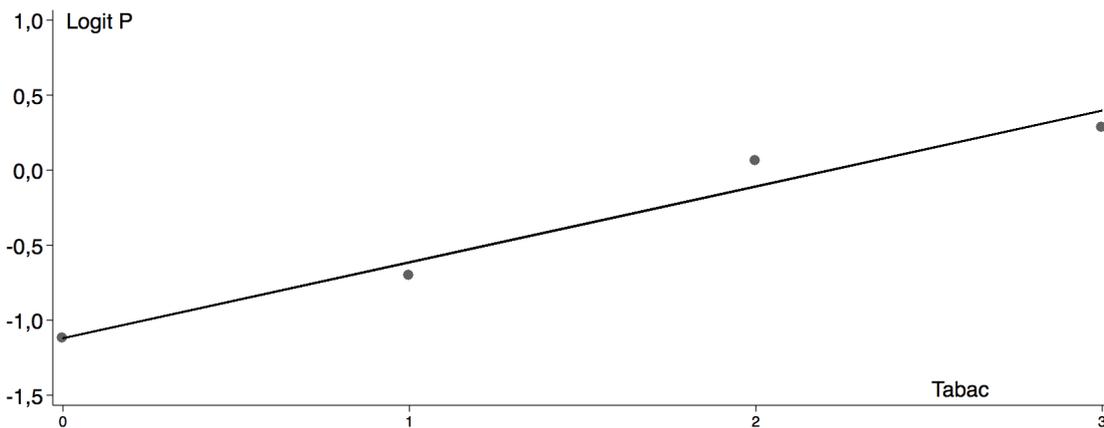
( 1) 2*[ct]tabfc = 0

```

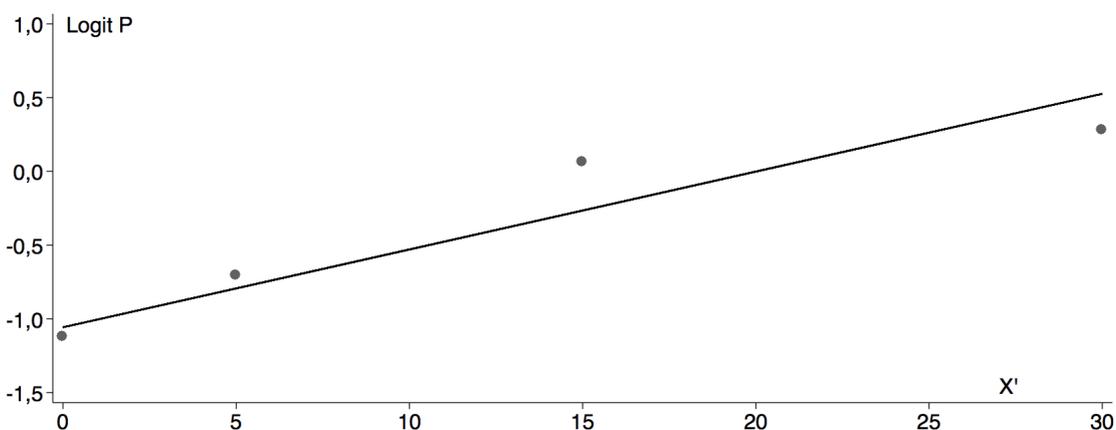
ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
(1)	2.750316	.2750177	10.12	0.000	2.260824	3.345789

## Choix des valeurs de X

Nombre de cigarettes par jour	0	1-9	10-19	≥ 20
X	0	1	2	3
OR observé	1	1,51	3,27	4,07
OR donné par le modèle Logit P = $\alpha + \beta X$	1	1,66	2,75	4,56



Nombre de cigarettes par jour	0	1-9	10-19	≥ 20
X' (centre de la classe)	0	5	15	30
OR observé	1	1,51	3,27	4,07
OR donné par le modèle Logit P = $\alpha + \beta X'$	1	1,30	2,21	4,87

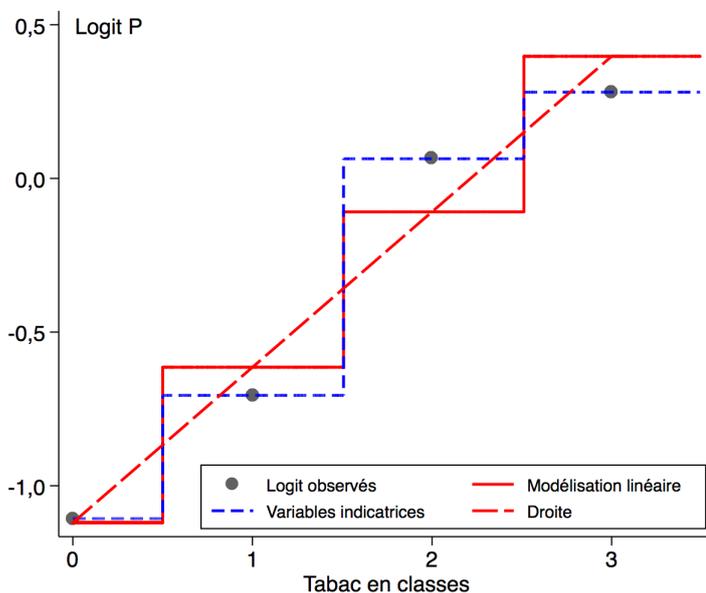


NB : il n'y a pas de test pour comparer les deux codages, mais on peut, pour chacun d'eux, tester s'il s'écarte de la linéarité.

## C. Choix entre variables indicatrices et modélisation linéaire

En fait, il est abusif de représenter la relation tabac/GEU avec la modélisation linéaire par une droite car la variable tabac est en classes avec 4 valeurs.

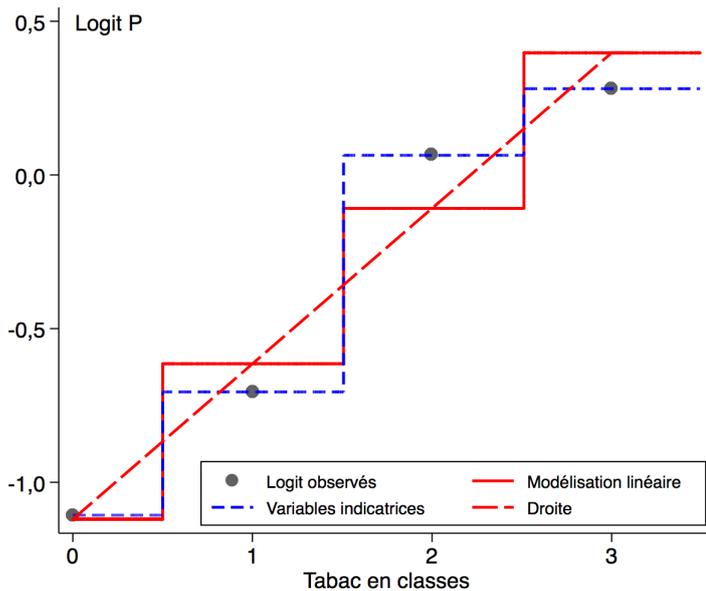
Il vaut mieux la représenter par un escalier (qui a des "marches régulières")



Modèle avec variables indicatrices :  
 $\text{Logit } P = \alpha + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3$

Modèle "linéaire" :  $\text{Logit } P = \alpha + \beta X$   
(avec  $X = 0, 1, 2$  ou  $3$ )

Droite : pas de modèle correspondant



Modèle avec variables indicatrices :

$$\text{Logit } P = \alpha + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3$$

Modèle "linéaire" :  $\text{Logit } P = \alpha + \beta X$   
(avec  $X = 0, 1, 2$  ou  $3$ )

Droite : pas de modèle correspondant

### Modèle avec variables indicatrices :

- représente la relation par un escalier (ce qui a peu de chances d'être la réalité, mais le fait de mettre la variable tabac en classes n'est pas non plus très réaliste ...)
- est le plus proche possible des observations puisqu'il passe par tous les points observés
- est sensible aux fluctuations d'échantillonnage (les hauteurs des "marches" peuvent être très variables selon l'échantillon, surtout si une classe a un effectif petit)

### Modélisation linéaire :

- utilise l'information concernant l'ordre des catégories de  $X$
- représente la relation par une droite (ou du moins par un escalier régulier) (ce qui ne peut être qu'une approximation de la réalité)
- résume et synthétise la relation par un coefficient (la pente de la droite), ce qui donne un test de tendance

On peut comparer les 2 modèles car ils sont emboîtés (voir poly spécifique). Le test est un test de linéarité

Comparaison entre :

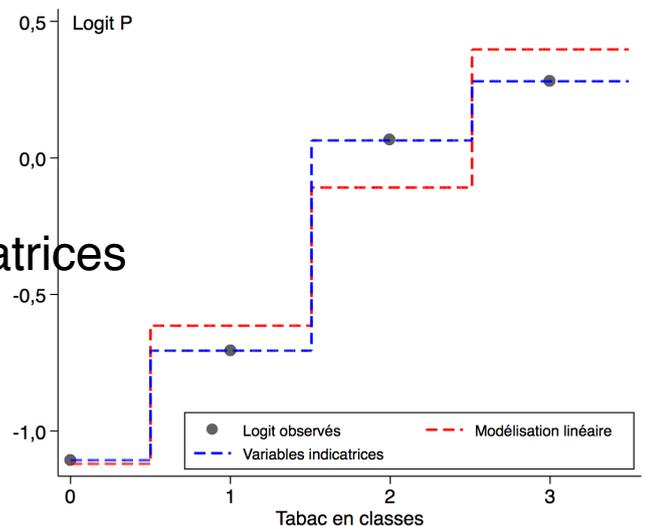
- la modélisation linéaire

$$\text{Logit } P = \alpha + \beta X$$

- la décomposition en variables indicatrices

$$\text{Logit } P = \alpha + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3$$

Test du rapport de vraisemblance  
(test de linéarité)



```
. logit ct tabfc
```

```
Logistic regression              Number of obs =      1693
                                LR chi2(1)         =      104.99
                                Prob > chi2          =      0.0000
Log likelihood = -1014.1795      Pseudo R2         =      0.0492
```

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
tabfc	.505858	.0499975	10.12	0.000	.4078648 .6038512
_cons	-1.120282	.0673178	-16.64	0.000	-1.252222 -.9883411

```
. est store lin
```

```
. logit ct i.tabfc
```

```
Logistic regression              Number of obs =      1693
                                LR chi2(3)         =      107.61
                                Prob > chi2          =      0.0000
Log likelihood = -1012.8708      Pseudo R2         =      0.0504
```

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
tabfc					
1	.4139636	.1554786	2.66	0.008	.1092311 .7186961
2	1.183799	.1526679	7.75	0.000	.8845749 1.483022
3	1.400465	.1724725	8.12	0.000	1.062425 1.738505
_cons	-1.11985	.07088	-15.80	0.000	-1.258772 -.9809276

```
. est store indic
```

```
. lrtest indic lin
```

```
Likelihood-ratio test          LR chi2(2) =      2.62
(Assumption: lin nested in indic) Prob > chi2 =      0.2702
```

Différence non significative :

- linéarité non rejetée
- on retient la modélisation linéaire

# Interprétation des coefficients et codage des variables

## 4. X quantitative

- On peut inclure X dans le modèle avec son codage initial sous la forme :  $\text{Logit } P = \alpha + \beta X$

=> la liaison entre Logit P et X est alors supposée linéaire

D'autres modélisations sont possibles (voir le chapitre consacré aux variables quantitatives).

## Exercice 2

1. Pour tester si la liaison entre la consommation de tabac et Logit P est linéaire, on procède comme cela vient d'être indiqué en prenant la variable tabfc des pages précédentes.

On considère donc les deux modèles logistiques :

$M_1$  :  $\text{Logit } P = \alpha_0 + \beta_1 \text{tabfc}_1 + \beta_2 \text{tabfc}_2 + \beta_3 \text{tabfc}_3$  où  $\text{tabfc}_1$ ,  $\text{tabfc}_2$  et  $\text{tabfc}_3$  sont les variables indicatrices des catégories de tabfc.

$M_2$  :  $\text{Logit } P = \alpha + \beta \text{tabfc}$

Ecrivez les hypothèses testées lorsqu'on compare ces deux modèles. Faites le test et donnez votre conclusion.

2. Etudiez le lien entre le nombre de fausses couches spontanées antérieures (variable nafcs) et le risque de GEU.

# Interaction

E : exposition (en 0/1)

X : variable en 0/1

Il y a interaction entre E et X si l'odds ratio associé à E est différent pour X=0 et X=1.

Le modèle Logit  $P = \alpha + \beta E + \gamma X$  "tient compte" des deux variables E et X, mais suppose l'absence d'interaction :

$$X = 0 \rightarrow \text{Ln OR}_0 = \text{Logit } P_1 - \text{Logit } P_0 = \alpha + \beta - \alpha = \beta$$

$$X = 1 \rightarrow \text{Ln OR}_1 = \text{Logit } P_1 - \text{Logit } P_0 = \alpha + \beta + \gamma - (\alpha + \gamma) = \beta$$

En présence d'une interaction, on a  $\text{OR}_1 \neq \text{OR}_0$

C'est-à-dire :

$$X = 0 \rightarrow \text{Ln OR}_0 = \beta$$

$$X = 1 \rightarrow \text{Ln OR}_1 = \beta + \delta$$

d'où le modèle :  $\text{Logit } P = \alpha + \beta E + \gamma X + \delta EX$

avec  $EX = 0$  si  $E = 0$  ou  $X = 0$

$EX = 1$  si  $E = X = 1$

Les variables d'interaction sont construites par Stata avec le système de "factor variables".  
 La syntaxe est `i.var1##i.var2`

## Exemple

Induction de la grossesse : 0 = non induite  
 1 = induction par Clomid

Age30 : 0 = âge < 30 ans  
 1 = âge ≥ 30 ans

```
. logit ct i.clomid##i.age30
```

Logistic regression

Log likelihood = -1046.124

Number of obs = 1683  
 LR chi2(3) = 44.67  
 Prob > chi2 = 0.0000  
 Pseudo R2 = 0.0209

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
1.clomid	1.234339	.3807449	3.24	0.001	.4880927	1.980585
1.age30	.6511233	.1072584	6.07	0.000	.4409006	.8613459
clomid#age30						
1 1	-1.127027	.5354195	-2.10	0.035	-2.17643	-.0776236
_cons	-1.0267	.0744555	-13.79	0.000	-1.17263	-.8807696

La commande `i.clomid##i.age30` crée :

- des variables indicatrices pour clomid et age30 et exclut du calcul celles correspondant aux catégories de référence.

- des termes d'interaction combinant les variables indicatrices : `0.clomid#0.age30`, `0.clomid#1.age30`, `1.clomid#0.age30` et `1.clomid#1.age30`. Ceux correspondant aux catégories de référence sont exclus, il ne reste donc ici que le dernier.

## Exemple (suite)

Induction de la grossesse : 0 = non induite  
 1 = induction par Clomid

Age30 : 0 = âge < 30 ans  
 1 = âge ≥ 30 ans

```
. logit ct i.clomid##i.age30
```

Logistic regression		Number of obs = 1683			
Log likelihood = -1046.124		LR chi2(3) = 44.67			
		Prob > chi2 = 0.0000			
		Pseudo R2 = 0.0209			
ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
1.clomid	1.234339	.3807449	3.24	0.001	.4880927 1.980585
1.age30	.6511233	.1072584	6.07	0.000	.4409006 .8613459
clomid#age30					
1 1	-1.127027	.5354195	-2.10	0.035	-2.17643 -.0776236
_cons	-1.0267	.0744555	-13.79	0.000	-1.17263 -.8807696

Logit P = -1,027 + 1,234 CLOMID+ 0,651 AGE30  
 - 1,127 CLOMID×AGE30

Il y a **deux** odds-ratios associés au Clomid :

- chez les femmes de moins de 30 ans :  $OR = e^{1,234} = 3,43$
- chez les femmes de plus de 30 ans:  $OR = e^{1,234-1,127} = 1,11$

Le test du coefficient de la variable d'interaction est un test de comparaison de ces deux odds-ratios. Il est ici à la limite de la signification (p=0,035).

On peut le reproduire avec la commande testparm :

```
. testparm 1.clomid#1.age30
( 1) [ct]1.clomid#1.age30 = 0
chi2( 1) = 4.43
Prob > chi2 = 0.0353
```

# Exemple (suite)

Attention à bien mettre ## et pas #.

```
. logit ct i.clamid##i.age30
```

Logistic regression

Number of obs = 1683  
LR chi2(3) = 44.67  
Prob > chi2 = 0.0000  
Pseudo R2 = 0.0209

Log likelihood = -1046.124

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
1.clamid	1.234339	.3807449	3.24	0.001	.4880927	1.980585
1.age30	.6511233	.1072584	6.07	0.000	.4409006	.8613459
clamid#age30						
1 1	-1.127027	.5354195	-2.10	0.035	-2.17643	-.0776236
_cons	-1.0267	.0744555	-13.79	0.000	-1.17263	-.8807696

```
. logit ct i.clamid#i.age30
```

Logistic regression

Number of obs = 1683  
LR chi2(3) = 44.67  
Prob > chi2 = 0.0000  
Pseudo R2 = 0.0209

Log likelihood = -1046.124

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
clamid#age30						
0 1	.6511233	.1072584	6.07	0.000	.4409006	.8613459
1 0	1.234339	.3807449	3.24	0.001	.4880927	1.980585
1 1	.7584357	.3758859	2.02	0.044	.0217128	1.495159
_cons	-1.0267	.0744555	-13.79	0.000	-1.17263	-.8807696

Les résultats sont équivalents, mais ne s'interprètent pas de la même façon ...

## Intervalle de confiance des odds ratios en présence d'interaction

$$\text{Logit } P = \alpha + \beta E + \gamma X + \delta EX$$

$$\text{Ln } OR_0 = \beta \quad \text{Ln } OR_1 = \beta + \delta$$

$$\text{IC de } \beta : \hat{\beta} \pm 1,96\sqrt{\text{var}(\hat{\beta})}$$

$$\begin{aligned} \text{IC de } \beta + \delta : \hat{\beta} + \hat{\delta} \pm 1,96\sqrt{\text{var}(\hat{\beta} + \hat{\delta})} \\ = \hat{\beta} + \hat{\delta} \pm 1,96\sqrt{\text{var}(\hat{\beta}) + \text{var}(\hat{\delta}) + 2\text{cov}(\hat{\beta}, \hat{\delta})} \end{aligned}$$

L'IC de  $\beta$  (et donc de  $OR_0$ ) se lit directement dans les résultats de la commande logit (ou logistic).

Ce n'est pas le cas de l'IC de  $\beta + \delta$  qui fait intervenir la covariance entre  $\beta$  et  $\delta$ . Il faut utiliser la commande lincom qui permet de calculer l'IC d'une combinaison linéaire des coefficients (et donc de l'OR correspondant).

Avec E=clomid et X=age30, on obtient les résultats suivants :

$$OR_0 = 3,44 [1,63 ; 7,25]$$

$$OR_1 = 1,11 [0,53 ; 2,33]$$

```
. logistic ct i.clomid##i.age30
```

Logistic regression

Number of obs = 1,683  
 LR chi2(3) = 44.67  
 Prob > chi2 = 0.0000  
 Pseudo R2 = 0.0209

Log likelihood = -1046.124

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
1.clomid	3.436107	1.30828	3.24	0.001	1.629206	7.246984
1.age30	1.917694	.2856888	6.07	0.000	1.554188	2.366344
clomid#age30						
1 1	.3239952	.1734734	-2.10	0.035	.1134459	.9253126
_cons	.3581871	.026669	-13.79	0.000	.3095518	.4144638

```
. lincom 1.clomid + 1.age30#1.clomid
```

( 1) [ct]1.clomid + [ct]1.age30#1.clomid = 0

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
(1)	1.113282	.4190843	0.29	0.776	.5323271	2.328262

# Interaction et analyses séparées pour X=0 et X=1

## 1. Avec terme d'interaction

```
. logit ct i.clamid##i.age30
```

Logistic regression

Number of obs = 1683  
 LR chi2(3) = 44.67  
 Prob > chi2 = 0.0000  
 Pseudo R2 = 0.0209

Log likelihood = -1046.124

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
1.clamid	1.234339	.3807449	3.24	0.001	.4880927 1.980585
1.age30	.6511233	.1072584	6.07	0.000	.4409006 .8613459
clamid#age30					
1 1	-1.127027	.5354195	-2.10	0.035	-2.17643 -.0776236
_cons	-1.0267	.0744555	-13.79	0.000	-1.17263 -.8807696

## 2. Analyses séparées

X=0 (moins de 30 ans)

```
. logit ct clamid if age30==0
```

Logistic regression

Number of obs = 958  
 LR chi2(1) = 10.35  
 Prob > chi2 = 0.0013  
 Pseudo R2 = 0.0092

Log likelihood = -555.90136

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
clamid	1.234339	.3807449	3.24	0.001	.4880928 1.980585
_cons	-1.0267	.0744555	-13.79	0.000	-1.17263 -.8807696

X=1 (plus de 30 ans)

```
. logit ct clamid if age30==1
```

Logistic regression

Number of obs = 725  
 LR chi2(1) = 0.08  
 Prob > chi2 = 0.7761  
 Pseudo R2 = 0.0001

Log likelihood = -490.22259

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
clamid	.1073125	.3764404	0.29	0.776	-.6304971 .845122
_cons	-.3755765	.0772059	-4.86	0.000	-.5268973 -.2242556

On peut remarquer que :

- $n = 1683 = n_0 + n_1 = 958 + 725$      $\text{Ln}V = -1046,1 = -555,9 - 490,2$
- les coefficients de clomid sont les mêmes ( $0,107 = 1,234 - 1,127$ ) ainsi que les intervalles de confiance

Donc : résultats identiques sans modification de puissance.

L'interaction est une notion symétrique entre les deux variables E et X.

```
. logit ct i.clomid##i.age30
```

Logistic regression		Number of obs	=	1683
Log likelihood = -1046.124		LR chi2(3)	=	44.67
		Prob > chi2	=	0.0000
		Pseudo R2	=	0.0209

ct	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
1.clomid	1.234339	.3807449	3.24	0.001	.4880927 1.980585
1.age30	.6511233	.1072584	6.07	0.000	.4409006 .8613459
clomid#age30					
1 1	-1.127027	.5354195	-2.10	0.035	-2.17643 -.0776236
_cons	-1.0267	.0744555	-13.79	0.000	-1.17263 -.8807696

$$\text{Logit } P = -1,027 + 0,651 \text{ AGE30} + 1,234 \text{ CLOMID} - 1,127 \text{ AGE30} \times \text{CLOMID}$$

Il y a **deux** odds-ratios associés au Clomid :

- chez les femmes de moins de 30 ans :  $OR = e^{1,234} = 3,43$
- chez les femmes de plus de 30 ans:  $OR = e^{1,234-1,127} = 1,11$

Il y a aussi **deux** odds-ratios associés à l'âge supérieur à 30 ans :

- chez les femmes sans clomid :  $OR = e^{0,651} = 1,92$
- chez les femmes avec clomid :  $OR = e^{0,651-1,127} = 0,62$

# Interaction et facteur à plus de 2 classes

X en 3 classes -> décomposition en  $X_1$  et  $X_2$

$$\text{Logit } P = \alpha + \beta E + \beta_1 X_1 + \beta_2 X_2 + \delta_1 E X_1 + \delta_2 E X_2$$

Test de l'interaction :  $H_0 : \delta_1 = 0$  et  $\delta_2 = 0$

Exemple : agec3 = 0 : < 30 ; 1 : 30-34 ; 2 : ≥ 35

```
. logistic ct i.clomid##i.agec3
```

Logistic regression		Number of obs	=	1683
Log likelihood = -1041.5811		LR chi2(5)	=	53.76
		Prob > chi2	=	0.0000
		Pseudo R2	=	0.0252

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
1.clomid	3.436107	1.30828	3.24	0.001	1.629206 7.246984
agec3					
1	1.690709	.1984507	4.47	0.000	1.343251 2.128043
2	2.729796	.456932	6.00	0.000	1.966302 3.789746
clomid#agec3					
1 1	.2746101	.1623754	-2.19	0.029	.0861799 .8750387
1 2	.4960686	.4152704	-0.84	0.402	.0961571 2.559187
_cons	.3581871	.026669	-13.79	0.000	.3095518 .4144638

## Test de l'interaction

```
. testparm 1.clomid#1.agec3 1.clomid#2.agec3 // ou testparm 1.c*#1.a* 1.c*#2.a*
( 1) [ct]1.clomid#1.agec3 = 0
( 2) [ct]1.clomid#2.agec3 = 0
      chi2( 2) = 4.82
      Prob > chi2 = 0.0898
```

Attention : 3,44 =  $OR_{Clomid}$  chez les femmes < 30 ans

Il y a 3 odds-ratios associés au Clomid :

Chez les femmes < 30 ans :  $OR_1 = e^\beta = 3,44$

Chez les femmes 30-34 ans :  $OR_2 = e^{\beta+\delta_1} = 3,44 \times 0,27 = 0,93$

Chez les femmes ≥ 35 ans :  $OR_3 = e^{\beta+\delta_2} = 3,44 \times 0,50 = 1,72$

# Interaction et variable continue

$$\text{Logit } P = \alpha + \beta E + \gamma X + \delta EX$$

Exemple

agea = âge en années

```
. logistic ct i.cloimid##c.agea
```

Logistic regression		Number of obs	=	1683
Log likelihood = -1036.5066		LR chi2(3)	=	63.91
		Prob > chi2	=	0.0000
		Pseudo R2	=	0.0299

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
1.cloimid	112.8515	213.0682	2.50	0.012	2.788711 4566.787
agea	1.084319	.0119044	7.37	0.000	1.061237 1.107904
cloimid#c.agea					
1	.8735553	.0537033	-2.20	0.028	.7743929 .9854156
_cons	.0447012	.0147564	-9.41	0.000	.023406 .085371

Attention : 112,9 =  $OR_{Cloimid}$  chez les femmes de 0 ans !

Si on remplace agea par ageabis=agea-25, les résultats deviennent plus facilement interprétables :

3,84 =  $OR_{Cloimid}$  chez les femmes de 25 ans

```
. logistic ct i.cloimid##c.ageabis
```

Logistic regression		Number of obs	=	1,683
Log likelihood = -1036.5066		LR chi2(3)	=	63.91
		Prob > chi2	=	0.0000
		Pseudo R2	=	0.0299

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
1.cloimid	3.843857	1.639776	3.16	0.002	1.665895 8.869248
ageabis	1.084319	.0119044	7.37	0.000	1.061237 1.107904
cloimid#c.ageabis					
1	.8735553	.0537033	-2.20	0.028	.7743929 .9854156
_cons	.3382596	.025155	-14.58	0.000	.2923814 .3913367

## Exercice 3

1. Y a-t-il un lien entre d'une part le risque de GEU et d'autre part le nombre de partenaires sexuels (variable npart) et l'âge au premier rapport sexuel (variable aprs) ?
2. Y a-t-il une interaction entre ces deux variables (npart et aprs) ?
3. Quel est l'odds ratio (et son intervalle de confiance) associé à une "exposition" conjointe à plus de 5 partenaires sexuels et un âge au premier rapport sexuel inférieur à 14 ans ?

Note : Le nombre de partenaires sexuel est une variable en 3 classes codées 1 à 3 (1, 2-5, >5). L'âge au premier rapport sexuel est une variable en 4 classes codées 1 à 4 ( $\leq 14$ , 15-17, 18-20, >20)

# Choix des variables à inclure dans un modèle logistique

## Principes généraux

- C'est le cœur de l'analyse des enquêtes épidémiologiques
  - Question difficile, toujours discutée aujourd'hui et sans solution uniformément meilleure que les autres
  - Importance d'explicitier ce qu'on fait
- ◇ Le choix des variables suppose la définition de critères précisant ce qu'est le “meilleur” modèle, ce qui peut dépendre des objectifs de l'étude :
- prédire un événement d'intérêt (maladie, guérison, grossesse, ...)
    - on privilégie les qualités prédictives du modèle ( $\approx$  adéquation du modèle)
    - la limitation du nombre de variables n'est pas toujours un objectif prioritaire
  - identifier les facteurs de risque importants de la maladie, comprendre et quantifier leur effet (plus fréquent en épidémiologie)
    - variables scientifiquement importantes prises en compte
    - phénomènes de confusion contrôlés
    - résultats suffisamment stables pour être extrapolables

- ◇ Le choix des variables repose sur un “mélange” :
  - de connaissances scientifiques indépendamment des données ("subject-matter knowledge") (souvent limitées)
  - d'utilisation de méthodes statistiques appliquées aux données ("data driven procedures")
  - d'expérience et de bon sens

◇ Il faut trouver un équilibre entre :

- Trop de facteurs pris en compte
  - perte de puissance
  - sur-ajustement ou même "création" de biais de confusion
  - résultats instables, et moins interprétables
- Pas assez de facteurs pris en compte
  - possibilité de confusion résiduelle
  - moins bonne adéquation du modèle
  - interprétation plus facile

◇ On procède en général en deux étapes

### 1 . Choix des variables “candidates”

L'objectif est de faire un premier tri parmi l'ensemble des variables disponibles dans un fichier de données ou une enquête

### 2 . Sélection des variables à inclure dans le modèle final

A l'aide de méthodes statistiques lorsqu'il reste encore trop de variables à l'étape précédente.

# Nombre maximum de variables dans un modèle

Le nombre de sujets doit être assez grand pour que :

- la méthode du maximum de vraisemblance donne des résultats (estimations, intervalles de confiance et tests) non biaisés
- le processus de sélection des variables soit “stable”

La limite habituellement retenue porte sur le nombre d’ “événements par variable” (EPV).

Le nombre d’événements est le nombre de malades (ou de non malades s’il est plus petit).

Règle générale pour modèle logistique :  $EPV \geq 10$

(pour modèle de Cox :  $EPV \geq 10$ , pour modèle linéaire :  $EPV \geq 2$ )

Cette règle est discutée :

- pour certains auteurs  $EPV \geq 5$  suffit dans la plupart des cas
- pour d'autres, EPV ne résume pas tout. La corrélation entre les variables, des coefficients élevés demandent que EPV augmente

Dans le cas de la GEU, il y a 574 cas. Il ne faut donc pas dépasser 57 variables dans le modèle (ce qui laisse de la marge ...).

NB : il existe des méthodes “exactes” d’estimation adaptées aux petits échantillons.

- elles résolvent (en partie au moins) les problèmes statistiques d’estimation
- elles ne résolvent pas l’instabilité des modèles et de la sélection des variables

# Choix des variables “candidates”

## **Au moment du protocole**

Le choix est en partie fait à ce moment (les variables doivent figurer dans le questionnaire ...)

- connaissance scientifique de la question
- hypothèses nouvelles à tester ou résultats anciens à confirmer
- revue bibliographique
- facteurs de risque reconnus de la maladie (souvent inclus de façon systématique dans les analyses ultérieures)

## Au moment de l'analyse

◇ Commencer par une analyse univariée détaillée et complète pour :

- examiner les liens entre les facteurs de risque reconnus et la maladie

ces facteurs seront de toute façon retenus dans les variables candidates, mais il est utile de vérifier si on retrouve les associations connues

- identifier les autres facteurs de risque

=> étudier de façon systématique les liens entre les différentes variables de l'enquête et la maladie

retenir celles dont le degré de signification est  $\leq 20$  ou 25% (5% ne suffit pas)

- choisir le codage des variables

regroupement de catégories des variables qualitatives nominales

représentation des variables qualitatives ordinales et quantitatives

(ces choix pourront être rediscutés dans la suite de l'analyse)

- nb :

• la pertinence de cette étape est discutée en raison de la multiplication des tests et de l'imprécision générée sur le modèle final

• elle doit être guidée par les connaissances biblio sur la question étudiée

◇ Si besoin, générer des variables synthétiques pour limiter les phénomènes de colinéarité

◇ Eliminer les variables qui ont trop de données manquantes ou d'erreurs de mesure, ou qui ont trop peu de variabilité

◇ Rechercher les interactions à prendre en compte

Ce choix pourra aussi être revu dans la suite de l'analyse après ajustement sur les autres variables

- rechercher les interactions au cas par cas (et quand il y a "une certaine logique") par analyse "bivariée"
- en pratique, on ne prend en compte que rarement les interactions d'ordre supérieur à 2
- ne retenir que le minimum de termes d'interaction car ils rendent l'interprétation du modèle difficile voire impossible

◇ Dans les étapes précédentes :

- ne pas conserver deux variables qui représentent à peu près la même chose (colinéarité)
- porter une attention particulière aux variables dont la variabilité est faible ou dont la répartition est déséquilibrée, notamment les variables pour lesquelles les tableaux croisés avec la maladie comportent des 0.

Elles sont généralement à l'origine de problèmes numériques et d'instabilité dans les analyses ultérieures.

Ces problèmes sont d'autant plus fréquents que la taille de l'échantillon est petite

Exemple : intervention chirurgicale sur les trompes (ctub:chirurgie tubaire) et antécédent de GEU (ageu).

Les GEU étaient presque toutes traitées chirurgicalement

```
. tab ctub ageu
```

chir tubaire	atcd geu		Total
	0	1	
0	1,540	1	1,541
1	70	114	184
Total	1,610	115	1,725

```
. logistic ct ctub
Logistic regression
Number of obs = 1725
LR chi2(1) = 177.23
Prob > chi2 = 0.0000
Pseudo R2 = 0.0808
Log likelihood = -1008.6796
```

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
ctub	9.301394	1.744355	11.89	0.000	6.440451	13.43321
_cons	.3870387	.0219819	-16.71	0.000	.3462664	.4326118

```
. logistic ct ageu
Logistic regression
Number of obs = 1725
LR chi2(1) = 148.57
Prob > chi2 = 0.0000
Pseudo R2 = 0.0677
Log likelihood = -1023.0071
```

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
ageu	14.78487	4.064826	9.80	0.000	8.62572	25.34192
_cons	.4185022	.02287	-15.94	0.000	.3759949	.4658151

```
. logistic ct ctub ageu
Logistic regression
Number of obs = 1725
LR chi2(2) = 188.82
Prob > chi2 = 0.0000
Pseudo R2 = 0.0860
Log likelihood = -1002.8848
```

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
ctub	4.823154	1.230297	6.17	0.000	2.925536	7.951641
ageu	3.390356	1.235502	3.35	0.001	1.65979	6.92528
_cons	.3866787	.0219646	-16.73	0.000	.3459387	.4322165

La forte variation des OR lorsque les deux variables sont incluses ensembles doit alerter sur l'existence possible d'un problème (ici le fort lien entre ctub et ageu).

En pratique :

impossible de séparer les rôles de ctub et ageu

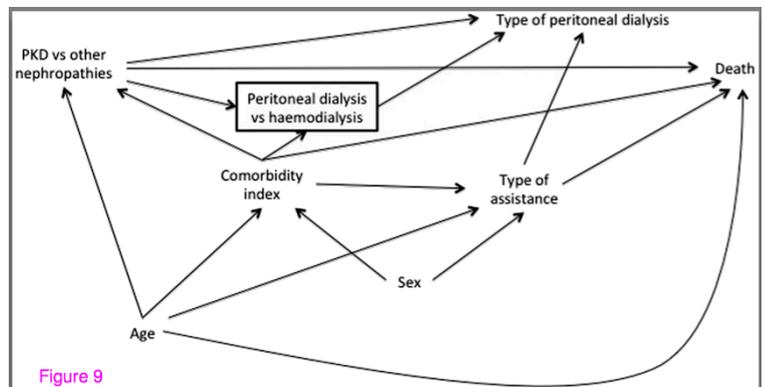
il faut - en choisir une

ou - faire une variable combinée "ctub ou ageu" (qui est ici presque identique à ctub).

# Sélection des variables à inclure dans le modèle final

## Les différentes méthodes de sélection

- Utilisation des connaissances scientifiques existantes sur la question
- Examen de la variation de OR entre  $OR_{brut}$  et  $OR_a$
- Méthodes de sélection pas à pas (stepwise)
- Autres méthodes
  - Examen de tous les modèles possibles
  - MFP (multivariable fractional polynomial, voir plus loin, variables quantitatives)
  - Approche bayésienne : prise en compte de la probabilité a priori que chaque modèle soit possible
  - DAG (Directed acyclic graphs) : moyen pratique et utile de présenter les connaissances scientifiques sur une question



- random forest : méthode utilisée pour repérer les variables influentes
- shrinkage (contraction): méthode visant à ramener les coefficients vers 0 pour éviter une surestimation liée au processus de choix du modèle

## Fréquence d'utilisation des différentes méthodes

Analyse de 4 revues majeures d'épidémiologie en 2008 (300 articles)<sup>2</sup> (American Journal of Epidemiology, Epidemiology, European Journal of Epidemiology and the International Journal of Epidemiology)

- Utilisation des connaissances a priori : 28%  
(mais la moitié sans donner de références pour justifier les choix)
- Changement de l'estimation de OR : 15%
- Méthodes de sélection pas à pas (stepwise) : 20%
- Autres méthodes : 3%
- méthode non précisée : 35%  
(souvent parce que la partie matériel et méthodes est trop imprécise)

## Comparaison entre les méthodes

Pas de comparaison possible avec l'utilisation des connaissances a priori

pourtant c'est la méthode recommandée par la majorité des ouvrages de référence

Dans l'ensemble stepwise fait moins bien que des méthodes plus "modernes", mais l'écart est faible

Le pourcentage de variables incluses à tort ou non incluses à tort est de l'ordre de 10 à 15% avec stepwise et 5% avec des méthodes plus sophistiquées.

---

<sup>2</sup> Walter S, Tiemeier H. Variable selection: current practice in epidemiological studies. Eur J Epidemiol. 2009;24(12):733-6  
Régression logistique

## Sélection selon la modification du coefficient de la variable d'intérêt

Particulièrement utile s'il y a une exposition d'intérêt E, les autres variables  $X_i$  étant des facteurs de confusion potentiels (ce n'est pas la situation la plus fréquente)

Le modèle complet s'écrit :  $\text{Logit } P = \alpha + \beta E + \sum \beta_i X_i$

Principe général : on retire une (ou des) variables  $X_i$  du modèle à condition que les effets de confusion soient correctement pris en compte c'est-à-dire que le retrait des variables ne modifie pas (trop) la valeur du coefficient  $\beta$  de l'exposition d'intérêt principal.

Critère de décision :

- variation de  $\beta$  inférieure à une valeur seuil (par exemple moins de 10%), parce qu'alors le phénomène de confusion dû à  $X_i$  est négligeable et  $X_i$  peut être retirée.
- test de la variation de  $\beta$  qui présente plusieurs problèmes
  - peu présent dans les logiciels
  - discutable dans son principe car l'hypothèse que  $X_i$  est facteur de confusion est peu intéressante (voire non pertinente) à tester. Ce qui compte c'est l'ampleur du phénomène de confusion.
    - Il faudrait aussi s'intéresser à la modification de l' IC

Avec Stata, la variation de  $\beta$  peut être étudiée avec le module chest.

Exemple : association entre GEU et age>30ans ajustée sur les facteurs de confusion potentiels

```
. logistic ct age30 tabf univf fprof afcs aivg ainf clomid ptub
```

```
Logistic regression                Number of obs   =    1,187
                                IR chi2(9)         =    212.42
                                Prob > chi2        =    0.0000
Log likelihood = -631.06752        Pseudo R2       =    0.1441
```

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
age30	1.399087	.2048355	2.29	0.022	1.050082 1.864087
tabf	2.059245	.2983083	4.99	0.000	1.550245 2.735367
univf	.9197903	.158741	-0.48	0.628	.6558207 1.290008
fprof	1.392854	.2212318	2.09	0.037	1.02025 1.901538
afcs	1.538804	.2524503	2.63	0.009	1.115677 2.122405
aivg	1.096733	.2121842	0.48	0.633	.7506189 1.602442
ainf	2.473358	.4513877	4.96	0.000	1.729588 3.536968
clomid	1.39017	.4958898	0.92	0.356	.6909304 2.797057
ptub	4.074246	.643337	8.90	0.000	2.989783 5.552068
_cons	.1193269	.0212106	-11.96	0.000	.0842239 .16906

```
. chest age30,eform format(%5.3g)
```

Change-in-estimate

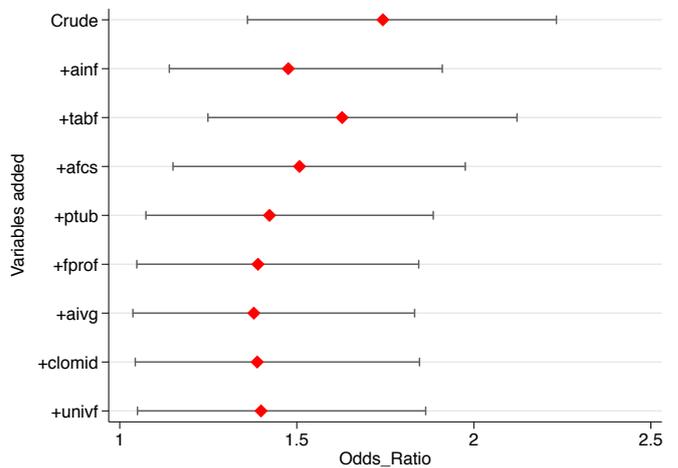
logistic regression.

number of obs = 1187

Outcome: ct

Exposure: age30

Variables added	exp(Coef.)	[95% Conf. Interval]	Change, %
Crude	1.74	1.36 2.23	
+ainf	1.48	1.14 1.91	-15.3
+tabf	1.63	1.25 2.12	10.3
+afcs	1.51	1.15 1.98	-7.39
+ptub	1.42	1.07 1.89	-5.62
+fprof	1.39	1.05 1.84	-2.28
+aivg	1.38	1.04 1.83	-.843
+clomid	1.39	1.04 1.85	.699
+univf	1.4	1.05 1.86	.771



```
graph export chest.png
```

# Examen de tous les modèles possibles

- peu fréquemment programmé dans les logiciels classiques

p variables =>  $2^p$  modèles (p=20 donne 1 048 576 modèles ...)

## Stata : module confall

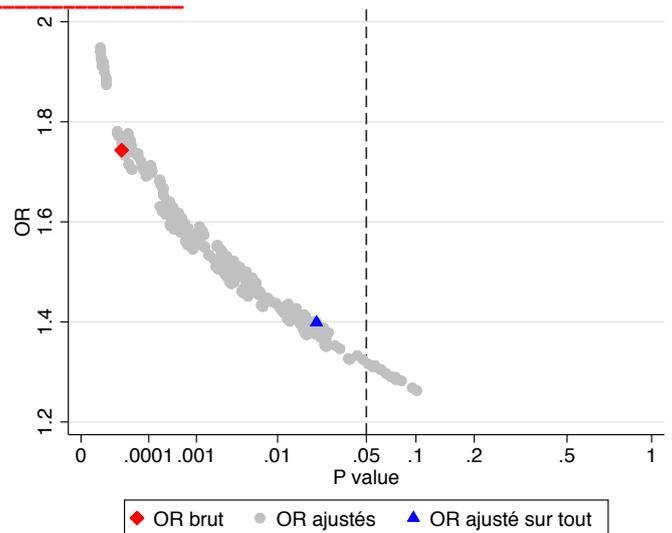
`confall age30, eform table`

Var.adj.	Exp(Coef.)	[95% Conf.	Interval]
Null	1.743234	1.360727	2.233264
tabf	1.911759	1.482228	2.465761
univf	1.777161	1.383996	2.282015
.....			
tabf fprof afcs aivg ainf clomid ptub	1.388378	1.043871	1.846581
univf fprof afcs aivg ainf clomid ptub	1.289524	.9733552	1.708393
tabf univf fprof afcs aivg ainf clomid p	1.399087	1.050083	1.864085

256 sets of confounders

Outcome variable: ct Exposure: age30

`graph export confall.png,replace`



- sélection des modèles basée sur la minimisation d'un critère d'information de la forme  $IC = -2 \ln(V) + a \dim(M)$

$\dim(M)$  = nombre de paramètres ; a = constante de "pénalité"

critère d'Aikaïke (AIC) : a = 2

critère de Bayes (BIC) : a =  $\ln(n)$

## Procédures pas à pas

Particulièrement utile lorsqu'on s'intéresse à l'ensemble des facteurs de risque de la maladie (c'est la situation la plus fréquente, mais il ne s'agit pas alors seulement de s'occuper d'une question de confusion).

Le modèle complet s'écrit :  $\text{Logit } P = \alpha + \sum \beta_i X_i$

Principe général : on retire une variable  $X_i$  si son coefficient est non significativement différent de 0 (ou avec un degré de signification supérieur à une limite fixée, par exemple 0,10).

On retire donc successivement les variables qui ne sont pas facteur de risque de la maladie.

C'est ce que proposent les procédures pas à pas ("stepwise") de la plupart des logiciels.

### • Procédure descendante

1. On part du modèle "complet" contenant toutes les variables  $X_i$  retenues.
2. On retire successivement la variable  $X_k$  dont le degré de signification  $p$  du lien avec la maladie (ajusté sur les autres variables) est le plus grand, tant que  $p \geq \alpha$  (constante fixée).

procédure descendante "mixte"

2bis. A partir du moment où 2 variables ont été retirées :

- si la variable exclue la plus significative vérifie  $p < \alpha'$ , on la réintègre
- si la variable incluse la moins significative vérifie  $p \geq \alpha$ , on la retire

### • Procédure ascendante

Même principe ("à l'envers") en partant du modèle vide

- Possibilité de “forcer des variables”
- Le choix des constantes  $\alpha$  et  $\alpha'$  est important. Plus elles sont grandes, plus le modèle final comprendra de variables. On prend souvent  $\alpha$  et  $\alpha'$  de l'ordre de 0,10 à 0,15.
- Les modèles obtenus ne sont pas toujours les mêmes avec les procédures descendantes et ascendantes. En général, moins de variables sélectionnées avec procédure ascendante.
- Procédure descendante a l'avantage de partir du modèle complet qui est une meilleure référence que le modèle vide.

# Avantages et inconvénients des procédures pas à pas

## Avantages

- utilisation facile
- examen systématique et standardisé de l'ensemble des variables
- pas de réelle alternative en l'absence de connaissances scientifiques fortes des mécanismes gouvernant la question étudiée (ce qui est fréquent)
- résultats obtenus sont satisfaisants

## Inconvénients

- fondées sur des critères uniquement statistiques
- absence de considérations épidémiologiques (méthodes "pas politiquement correctes")
- violation de conditions statistiques (risque d'erreur, distribution)
- sous estimation des IC des coefficients qui ne tient pas compte de l'incertitude ajoutée par le choix du modèle
- biais possibles dans la sélection des variables
  - la sélection est basée sur les coefficients estimés des variables (pas sur leur vraie valeur)
  - une variable est plus vraisemblablement incluse si son coefficient est surestimé
    - les "prédicteurs forts" (facteurs fortement liés à la maladie) sont presque toujours inclus que leur coefficient soit sous-estimé ou pas
    - les "prédicteurs faibles" ne sont inclus que si leur coefficient est sur-estimé

# Exemples de procédure pas à pas

## Modèle complet

```
. logistic ct ctub i.agec tabf univf aacc afcs aivg ainf clamid
```

```
Logistic regression              Number of obs   =      1,620  
                                LR chi2(11)     =      302.66  
                                Prob > chi2      =      0.0000  
Log likelihood = -863.89877      Pseudo R2     =      0.1491
```

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
ctub	7.013603	1.494838	9.14	0.000	4.618715 10.65029
agec					
1	.9546271	.1684659	-0.26	0.792	.6754911 1.349112
2	1.129204	.2221671	0.62	0.537	.7678939 1.660517
3	1.511209	.3402527	1.83	0.067	.972018 2.349497
tabf	2.870179	.3520093	8.60	0.000	2.256912 3.650089
univf	1.119296	.1614581	0.78	0.435	.8436442 1.485014
aacc	1.164726	.1544326	1.15	0.250	.8981763 1.510378
afcs	1.422089	.2010925	2.49	0.013	1.077857 1.876256
aivg	1.153113	.1871852	0.88	0.380	.8388724 1.585067
ainf	2.322488	.3787415	5.17	0.000	1.687109 3.197156
clamid	1.372395	.4458498	0.97	0.330	.7260211 2.594232
_cons	.1534527	.0252264	-11.40	0.000	.1111844 .21179

## • Procédure descendante

(dans Stata, on ne peut pas utiliser "factor variable", il faut utiliser "l'ancienne" commande xi)

```
. xi : stepwise,pr(.15) pe(.1) : logistic ct ctub (i.agec) tabf univf aacc afcs aivg ainf clomid
i.agec      _Iagec_0-3      (naturally coded; _Iagec_0 omitted)
              begin with full model
p = 0.4346 >= 0.1500  removing univf
p = 0.3838 >= 0.1500  removing aivg
p = 0.3023 >= 0.1500  removing clomid
p = 0.3393 >= 0.1500  removing aacc
```

```
Logistic regression              Number of obs   =      1,620
                                LR chi2(7)        =      299.33
                                Prob > chi2         =      0.0000
Log likelihood = -865.56246      Pseudo R2      =      0.1474
```

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
ctub	6.869142	1.459751	9.07	0.000	4.529132 10.41814
_Iagec_1	1.017915	.1745255	0.10	0.918	.727394 1.42447
_Iagec_2	1.259479	.2299469	1.26	0.206	.8806118 1.801347
_Iagec_3	1.721392	.3596479	2.60	0.009	1.142983 2.592508
tabf	2.870837	.3463653	8.74	0.000	2.266269 3.636685
ainf	2.35047	.3631412	5.53	0.000	1.736386 3.181728
afcs	1.437321	.2023726	2.58	0.010	1.090702 1.894095
_cons	.1643953	.0258905	-11.46	0.000	.1207353 .2238436

## • Procédure ascendante

```
. xi : stepwise,pr(.15) pe(.1) forw : logistic ct ctub (i.agec) tabf univf aacc afcs aivg ainf clomid
i.agec      _Iagec_0-3      (naturally coded; _Iagec_0 omitted)
              begin with empty model
p = 0.0000 < 0.1000  adding  ctub
p = 0.0000 < 0.1000  adding  tabf
p = 0.0000 < 0.1000  adding  ainf
p = 0.0012 < 0.1000  adding  afcs
p = 0.0180 < 0.1000  adding  _Iagec_1 _Iagec_2 _Iagec_3
```

```
Logistic regression              Number of obs   =      1,620
                                LR chi2(7)        =      299.33
                                Prob > chi2         =      0.0000
Log likelihood = -865.56246      Pseudo R2      =      0.1474
```

ct	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
ctub	6.869142	1.459751	9.07	0.000	4.529132 10.41814
tabf	2.870837	.3463653	8.74	0.000	2.266269 3.636685
ainf	2.35047	.3631412	5.53	0.000	1.736386 3.181728
afcs	1.437321	.2023726	2.58	0.010	1.090702 1.894095
_Iagec_1	1.017915	.1745255	0.10	0.918	.727394 1.42447
_Iagec_2	1.259479	.2299469	1.26	0.206	.8806118 1.801347
_Iagec_3	1.721392	.3596479	2.60	0.009	1.142983 2.592508
_cons	.1643953	.0258905	-11.46	0.000	.1207353 .2238436

## En résumé

- Si

- l'étape l'étape du choix des variables candidates a été faite soigneusement (et cela peut prendre du temps ...)
- on a une bonne connaissance du problème et/ou une expérience suffisante
- les données s'y prêtent ....,

alors, le nombre de variables retenues est limité, elles sont toutes pertinentes et on les inclut donc toutes dans le modèle final.

Cette procédure est généralement considérée comme la méthode de référence (la "meilleure").

- Sinon (et c'est la situation la plus fréquente en raison du manque de connaissances solides a priori)

on peut utiliser des procédures statistiques s'appuyant sur les données observées et des règles "automatiques" de sélection des variables.

- modification du coefficient de la variable d'intérêt (ne pas oublier de s'intéresser aussi à l'IC du coefficient)
- procédures pas à pas (les plus courantes)

Les procédures pas à pas peuvent être associées à d'autres méthodes :

◇ "Garde-fous" statistiques

- faire un test global préalable avec l'ensemble des variables candidates (si NS, on s'arrête)
- recourir à des méthodes de shrinkage pour limiter la surestimation des coefficients
- vérifier la stabilité des résultats (sur une autre partie de l'échantillon ou par bootstrap)

◇ Introduction des connaissances a priori

- forcer certaines variables
- regrouper les variables en groupes homogènes
- examiner soigneusement chaque étape de la sélection

◇ Groupes homogènes de variables

Si les variables sont nombreuses, on peut les réunir en groupes homogènes qu'on commence par analyser séparément

- cela revient à introduire de la connaissance du problème (matter-knowledge) dans les procédures automatiques
- cela permet aussi d'ordonner sa réflexion et la présentation des résultats
- les procédures précédentes sont appliquées à chaque groupe

- certaines variables peuvent intervenir dans plusieurs sous-analyses : par exemple, on peut ajuster systématiquement l'analyse des antécédents sur l'âge
- les variables retenues dans chaque groupe sont ensuite incluses dans le modèle final

Exemple : Y = Grossesse extra-utérine  
Variables  $X_i$

<b>Carac. socio-prof.</b>	<b>Exposition potentielle aux MST</b>
Age	Infection gynécologique
Tabac	Sérologie positive pour C. Trachomatis
Niveau d'études	Age aux premiers rapports sexuels
	Nombre de partenaires
<b>Antécédents chir. et obstét.</b>	<b>Fertilité</b>
Appendicectomie	Antécédent de contraception
Chirurgie tubaire	Dernier mode de contraception
Antécédent de GEU	Antécédent d'infécondité
Antécédent de FCS	Grossesse induite
Antécédent d'accouchement	Délai depuis la dernière grossesse
Antécédent d'IVG	

◇ Examiner soigneusement chaque étape de la sélection

- Pour s'assurer qu'on est capable d'interpréter les opérations réalisées (codage des variables, termes d'interaction, retrait ou ajout de variable ...)
- Chaque fois que c'est nécessaire, il ne faut pas hésiter à revenir à l'analyse univariée pour bien comprendre les résultats des analyses multivariées
- Sur le modèle "final", il est possible de revoir (remettre en cause ?) le codage des variables et/ou la présence d'interactions

◇ Ne pas oublier que

- Le choix des variables ne se pose vraiment que pour celles qui ont un lien faible avec la maladie
- Quand l'échantillon est petit, les procédures de sélection sont toutes instables

# Régression logistique multinomiale

$Y = 0, 1, \dots, k-1$  (variable nominale à  $k$  classes)

Le modèle logistique multinomial s'écrit :

$$\text{Ln}\left(\frac{P(Y = j | X)}{P(Y = 0 | X)}\right) = \alpha_j + g_j(x) = \alpha_j + \sum \beta_{ji} x_i$$

Cela revient en fait à prendre la catégorie  $Y = 0$  comme référence et à faire  $k-1$  régressions logistiques dichotomiques.

Comme  $\sum P(Y=j) = 1$ , le modèle peut s'écrire :

$$P(Y = 0 | X) = \frac{1}{1 + \exp\{\alpha_1 + g_1(x)\} + \dots + \exp\{\alpha_{k-1} + g_{k-1}(x)\}}$$
$$= \frac{1}{1 + \sum_{l=1}^{k-1} \exp\{\alpha_l + g_l(x)\}}$$

$$P(Y = j | X) = \frac{\exp\{\alpha_j + g_j(x)\}}{1 + \sum_{l=1}^{k-1} \exp\{\alpha_l + g_l(x)\}} \quad \text{pour } j = 1, \dots, k-1$$

L'écriture peut se synthétiser en :

$P(Y = j   X) = \frac{\exp\{\alpha_j + g_j(x)\}}{\sum_{l=0}^{k-1} \exp\{\alpha_l + g_l(x)\}}$	avec $\alpha_0 = \beta_{0i} = 0$ et $j = 0, \dots, k-1$
---	--

Le modèle logistique multinomial est utilisable dans des enquêtes de type cas-témoins.

Soit  $f_j$  la fraction de sondage de la catégorie  $Y = j$ .

$$\text{On a : } P(Y = j | X) = f_j \frac{\exp(\alpha_j + g_j(x))}{\sum_{l=0}^{k-1} \exp\{\alpha_l + g_l(x)\}} \quad \text{avec } \alpha_0 = \beta_{0i} = 0$$

D'où :

$$\frac{P(Y = j | X)}{P(Y = 0 | X)} = \frac{f_j \exp\{\alpha_j + g_j(x)\}}{f_0 \exp\{\alpha_0 + g_0(x)\}} = \frac{f_j}{f_0} \exp\{\alpha_j + g_j(x)\}$$

et donc :

$$\text{Ln} \left( \frac{P(Y = j | X)}{P(Y = 0 | X)} \right) = \text{Ln} \left( \frac{f_j}{f_0} \right) + \{\alpha_j + g_j(x)\} = \alpha'_j + \sum \beta_{ji} x_i$$

# Exemple

Y = issue de grossesse (après FIV)

0 : à terme (référence)

1 : prématurée (rupture des membranes)

2 : prématurée (spontanée)

3 : prématurée (provoquée)

## 1. Coefficients

```
. mlogit cprema age35
```

```
Multinomial logistic regression      Number of obs =      7601
LR chi2(3) =      8.70
Prob > chi2 =      0.0336
Pseudo R2 =      0.0014

Log likelihood = -3025.1826
```

cprema		Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
0		(base outcome)					
1	age35	.1761545	.1993624	0.88	0.377	-.2145885	.5668976
	_cons	-4.211474	.1221634	-34.47	0.000	-4.45091	-3.972038
2	age35	.084688	.1188679	0.71	0.476	-.1482887	.3176648
	_cons	-3.088647	.0707297	-43.67	0.000	-3.227275	-2.950019
3	age35	.35869	.1277462	2.81	0.005	.1083121	.6090679
	_cons	-3.407101	.0824436	-41.33	0.000	-3.568688	-3.245514

## 2. Odds ratios

```
. mlogit cprema age35,rrr
```

```
Multinomial logistic regression      Number of obs =      7601
LR chi2(3) =      8.70
Prob > chi2 =      0.0336
Pseudo R2 =      0.0014

Log likelihood = -3025.1826
```

cprema		RRR	Std. Err.	z	P> z	[95% Conf. Interval]	
0		(base outcome)					
1	age35	1.192622	.237764	0.88	0.377	.8068734	1.76279
	_cons	.0148245	.001811	-34.47	0.000	.0116679	.018835
2	age35	1.088377	.1293731	0.71	0.476	.8621822	1.373916
	_cons	.0455635	.0032227	-43.67	0.000	.0396654	.0523387
3	age35	1.431453	.1828626	2.81	0.005	1.114396	1.838717
	_cons	.0331371	.0027319	-41.33	0.000	.0281928	.0389485

On retrouve les mêmes résultats avec des régressions logistiques “simples”

- A terme / rupture prématurée des membranes

```
. logistic rupmemb age35
Logistic regression                Number of obs   =    7015
                                   LR chi2(1)         =     0.77
                                   Prob > chi2         =    0.3805
                                   Pseudo R2          =    0.0007

Log likelihood = -561.69019
```

	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
age35	1.192622	.237764	0.88	0.377	.8068734	1.76279
_cons	.0148245	.001811	-34.47	0.000	.0116679	.018835

- A terme / prématurité spontanée

```
. logistic spont age35
Logistic regression                Number of obs   =    7230
                                   LR chi2(1)         =     0.50
                                   Prob > chi2         =    0.4779
                                   Pseudo R2          =    0.0002

Log likelihood = -1322.4787
```

	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
age35	1.088378	.1293732	0.71	0.476	.862183	1.373917
_cons	.0455636	.0032227	-43.67	0.000	.0396654	.0523387

- A terme / prématurité provoquée

```
. logistic prov age35
Logistic regression                Number of obs   =    7168
                                   LR chi2(1)         =     7.71
                                   Prob > chi2         =    0.0055
                                   Pseudo R2          =    0.0034

Log likelihood = -1120.2642
```

	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
age35	1.431453	.1828626	2.81	0.005	1.114396	1.838717
_cons	.0331371	.0027319	-41.33	0.000	.0281928	.0389485

- Régression multinomiale

```
. mlogit cprema age35,rrr
Multinomial logistic regression    Number of obs   =    7601
                                   LR chi2(3)         =     8.70
                                   Prob > chi2         =    0.0336
                                   Pseudo R2          =    0.0014

Log likelihood = -3025.1826
```

cprema	RRR	Std. Err.	z	P> z	[95% Conf. Interval]	
0	(base outcome)					
1						
age35	1.192622	.237764	0.88	0.377	.8068734	1.76279
_cons	.0148245	.001811	-34.47	0.000	.0116679	.018835
2						
age35	1.088377	.1293731	0.71	0.476	.8621822	1.373916
_cons	.0455635	.0032227	-43.67	0.000	.0396654	.0523387
3						
age35	1.431453	.1828626	2.81	0.005	1.114396	1.838717
_cons	.0331371	.0027319	-41.33	0.000	.0281928	.0389485

## Dans le cas de plusieurs variables X, les résultats sont différents, mais légèrement seulement

(voir Begg CB, Gray R : Calculation of polychotomous logistic regression parameters using individualized regressions. Biometrika 1984; 71 : 11-18)

### • Régression multinomiale

```
. mlogit cprena age35 hta, rrr
```

```
Multinomial logistic regression      Number of obs =      7601
LR chi2(6) =      71.91
Prob > chi2 =      0.0000
Pseudo R2 =      0.0119
Log likelihood = -2993.5779
```

	cprena	RRR	Std. Err.	z	P> z	[95% Conf. Interval]
0		(base outcome)				
1	age35	1.193357	.2379296	0.89	0.375	.8073451 1.763931
	hta	.8710343	.5135622	-0.23	0.815	.2742625 2.76633
	_cons	.0148815	.0018322	-34.17	0.000	.0116908 .0189429
2	age35	1.085837	.1291046	0.69	0.489	.8601182 1.370792
	hta	1.499127	.409747	1.48	0.139	.8773738 2.561486
	_cons	.0448984	.0032195	-43.28	0.000	.0390116 .0516735
3	age35	1.404867	.1808795	2.64	0.008	1.091544 1.808128
	hta	5.511777	1.022349	9.20	0.000	3.831836 7.928232
	_cons	.0292238	.0025245	-40.90	0.000	.0246721 .0346152

### • A terme / rupture prématurée des membranes

```
. logistic rupmemb age35 hta
```

```
Logistic regression      Number of obs =      7015
LR chi2(2) =      0.83
Prob > chi2 =      0.6614
Pseudo R2 =      0.0007
Log likelihood = -561.66125
```

	rupmemb	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
	age35	1.193451	.2379533	0.89	0.375	.8074022 1.764084
	hta	.87036	.51318	-0.24	0.814	.2740407 2.764285
	_cons	.0148814	.001832	-34.18	0.000	.0116911 .0189423

## • A terme / prématurité spontanée

. logistic spont age35 hta

```

Logistic regression              Number of obs   =       7230
                                LR chi2(2)       =         2.47
                                Prob > chi2          =       0.2909
Log likelihood = -1321.4958      Pseudo R2      =       0.0009
  
```

spont	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
age35	1.085099	.1290305	0.69	0.492	.8595124	1.369894
hta	1.497894	.4094452	1.48	0.139	.8766122	2.559497
_cons	.0449104	.003219	-43.29	0.000	.0390243	.0516842

## • A terme / prématurité provoquée

. logistic prov age35 hta

```

Logistic regression              Number of obs   =       7168
                                LR chi2(2)       =       69.83
                                Prob > chi2          =       0.0000
Log likelihood = -1089.2052      Pseudo R2      =       0.0311
  
```

prov	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
age35	1.407678	.1813277	2.65	0.008	1.093596	1.811963
hta	5.518765	1.023717	9.21	0.000	3.836596	7.938486
_cons	.0291983	.0025242	-40.88	0.000	.0246474	.0345895

# Intérêt de la régression logistique multinomiale : comparaison des OR selon les valeurs de Y

```
. mlogit cprema age35 hta,rrr
```

```
Multinomial logistic regression      Number of obs =      7601
                                      IR chi2(6)      =      71.91
                                      Prob > chi2     =      0.0000
Log likelihood = -2993.5779          Pseudo R2      =      0.0119
```

cprema		RRR	Std. Err.	z	P> z	[95% Conf. Interval]	
0		(base outcome)					
1	age35	1.193357	.2379296	0.89	0.375	.8073451	1.763931
	hta	.8710343	.5135622	-0.23	0.815	.2742625	2.76633
	_cons	.0148815	.0018322	-34.17	0.000	.0116908	.0189429
2	age35	1.085837	.1291046	0.69	0.489	.8601182	1.370792
	hta	1.499127	.409747	1.48	0.139	.8773738	2.561486
	_cons	.0448984	.0032195	-43.28	0.000	.0390116	.0516735
3	age35	1.404867	.1808795	2.64	0.008	1.091544	1.808128
	hta	5.511777	1.022349	9.20	0.000	3.831836	7.928232
	_cons	.0292238	.0025245	-40.90	0.000	.0246721	.0346152

	Rupt préma	Préma spont.	Préma prov.
Age ≥ 35	1,2 [0,81 ; 1,8]	1,1 [0,86 ; 1,4]	1,4 [1,1 ; 1,8]
HTA	0,87 [0,27 ; 2,8]	1,5 [0,88 ; 2,6]	5,5 [3,8 ; 7,9]

<pre>. test [1=2] : age35 ( 1) [1]age35 - [2]age35 = 0.0       chi2( 1) =    0.17       Prob &gt; chi2 =  0.6805</pre>	<pre>. test [1=3] : age35 ( 1) [1]age35 - [3]age35 = 0.0       chi2( 1) =    0.48       Prob &gt; chi2 =  0.4868</pre>
<pre>. test ([1=2] : age35) ([1=3] : age35) ( 1) [1]age35 - [2]age35 = 0 ( 2) [1]age35 - [3]age35 = 0       chi2( 2) =    2.27       Prob &gt; chi2 =  0.3210</pre>	
<pre>. test [1=2] : hta ( 1) [1]hta - [2]hta = 0.0       chi2( 1) =    0.71       Prob &gt; chi2 =  0.3980</pre>	<pre>. test [1=3] : hta ( 1) [1]hta - [3]hta = 0.0       chi2( 1) =    9.14       Prob &gt; chi2 =  0.0025</pre>
<pre>. test ([1=2] : hta) ([1=3] : hta) ( 1) [1]hta - [2]hta = 0 ( 2) [1]hta - [3]hta = 0       chi2( 2) =   22.88       Prob &gt; chi2 =  0.0000</pre>	