

# Sélection-“validation” de modèles

L. Rouvière

[laurent.rouviere@univ-rennes2.fr](mailto:laurent.rouviere@univ-rennes2.fr)

JANVIER 2015

## 1 Quelques jeux de données

## 2 Sélection-choix de modèles

- Critères de choix de modèles
  - Basés sur l'ajustement (AIC-BIC)
  - Basés sur la prévision (probabilité d'erreur-courbe ROC)
- Sélection de variables

## 3 Validation de modèles

- Test d'adéquation de la déviance
- Examen des résidus
- Points leviers et points influents

Bibliographie

## 1 Quelques jeux de données

## 2 Sélection-choix de modèles

- Critères de choix de modèles
  - Basés sur l'ajustement (AIC-BIC)
  - Basés sur la prévision (probabilité d'erreur-courbe ROC)
- Sélection de variables

## 3 Validation de modèles

- Test d'adéquation de la déviance
- Examen des résidus
- Points leviers et points influents

Bibliographie

# Quelques jeux de données

- Un chef d'entreprise souhaite vérifier la qualité d'un type de machines en fonction de l'âge et de la marque des moteurs. Il dispose
  - ❶ d'une variable binaire  $Y$  (1 si le moteur a déjà connu une panne, 0 sinon) ;
  - ❷ d'une variable quantitative `age` représentant l'âge du moteur ;
  - ❸ d'une variable qualitative à 3 modalités `marque` représentant la marque du moteur,
- et de  $n = 33$  observations :

```
> panne
  etat age marque
1     0   4     A
2     0   2     C
3     0   3     C
4     0   9     B
5     0   7     B
```

- Un chef d'entreprise souhaite vérifier la qualité d'un type de machines en fonction de l'âge et de la marque des moteurs. Il dispose
  - ❶ d'une variable binaire  $Y$  (1 si le moteur a déjà connu une panne, 0 sinon) ;
  - ❷ d'une variable quantitative `age` représentant l'âge du moteur ;
  - ❸ d'une variable qualitative à 3 modalités `marque` représentant la marque du moteur,
- et de  $n = 33$  observations :

```
> panne
  etat age marque
1     0   4     A
2     0   2     C
3     0   3     C
4     0   9     B
5     0   7     B
```

# Role des femmes

- Il s'agit d'une étude effectuée en 1975 aux Etats-Unis. Il s'agit d'expliquer l'**accord/désaccord** d'individus avec la phrase

Women should take care of running their homes and leave running the country up to men

par le **sexe** et le **nombre d'années** d'études des répondants.

```
> data("womensrole", package="HSAUR")
> womensrole <- womensrole[-24,]
> womensrole[1:5,]
  education  sex agree disagree
1          0 Male    4         2
2          1 Male    2         0
3          2 Male    4         0
4          3 Male    6         3
5          4 Male    5         5
```

## Remarque

On est en présence de données répétées.

# Role des femmes

- Il s'agit d'une étude effectuée en 1975 aux Etats-Unis. Il s'agit d'expliquer l'**accord/désaccord** d'individus avec la phrase

Women should take care of running their homes and leave running the country up to men

par le **sexe** et le **nombre d'années** d'études des répondants.

```
> data("womensrole", package="HSAUR")
> womensrole <- womensrole[-24,]
> womensrole[1:5,]
  education  sex agree disagree
1          0 Male    4         2
2          1 Male    2         0
3          2 Male    4         0
4          3 Male    6         3
5          4 Male    5         5
```

## Remarque

On est en présence de données répétées.

# Role des femmes

- Il s'agit d'une étude effectuée en 1975 aux Etats-Unis. Il s'agit d'expliquer l'**accord/désaccord** d'individus avec la phrase

Women should take care of running their homes and leave running the country up to men

par le **sexe** et le **nombre d'années** d'études des répondants.

```
> data("womensrole", package="HSAUR")
> womensrole <- womensrole[-24,]
> womensrole[1:5,]
  education  sex agree disagree
1          0 Male    4         2
2          1 Male    2         0
3          2 Male    4         0
4          3 Male    6         3
5          4 Male    5         5
```

## Remarque

On est en présence de données répétées.

- Il s'agit d'expliquer la **présence/absence d'une maladie cardiovasculaire** (chd) par **9 variables**. On dispose de  $n = 462$  individus.

```
> data(SAheart, package="bestglm")
> SAheart[1:5, ]
  sbp tobacco  ldl adiposity famhist typea obesity alcohol age chd
1  160   12.00 5.73   23.11 Present   49   25.30   97.20  52   1
2  144    0.01 4.41   28.61 Absent    55   28.87    2.06  63   1
3  118    0.08 3.48   32.28 Present   52   29.14    3.81  46   0
4  170    7.50 6.41   38.03 Present   51   31.99   24.26  58   1
5  134   13.60 3.50   27.78 Present   60   25.99   57.34  49   1
```

- Il s'agit d'expliquer la **présence/absence d'une maladie cardiovasculaire** (chd) par **9 variables**. On dispose de  $n = 462$  individus.

```
> data(SAheart, package="bestglm")
> SAheart[1:5, ]
  sbp tobacco  ldl adiposity famhist typea obesity alcohol age chd
1  160   12.00 5.73   23.11 Present   49   25.30   97.20  52   1
2  144    0.01 4.41   28.61 Absent   55   28.87    2.06  63   1
3  118    0.08 3.48   32.28 Present  52   29.14    3.81  46   0
4  170    7.50 6.41   38.03 Present  51   31.99   24.26  58   1
5  134   13.60 3.50   27.78 Present  60   25.99   57.34  49   1
```

# Sélection-choix de modèles

Le problème de **sélection/choix de modèles** est ici abordé sous 2 angles (différents mais pas nécessairement indépendants) :

① On est en présence de  $\mathcal{M}_1, \dots, \mathcal{M}_k$  modèles et on se pose le problème d'en choisir un.

- Il n'existe pas de **critère universel** permettant de définir la notion de meilleur modèle.
- On parlera toujours de meilleur modèle **par rapport à un critère donné**.
- On présentera deux types de critère :
  - **ajustement du modèle** (vraisemblances pénalisées)
  - **capacité de prédiction du modèle**

② Etant donné  $Y$  une variable à expliquer et  $X_1, \dots, X_p$   $p$  variables explicatives, comment sélectionner **automatiquement** un modèle logistique ?

Il s'agit de trouver automatiquement un sous-groupe des variables explicatives permettant d'expliquer  $Y$ . On parle de **sélection de variables**.

Le problème de **sélection/choix de modèles** est ici abordé sous 2 angles (différents mais pas nécessairement indépendants) :

① On est en présence de  $\mathcal{M}_1, \dots, \mathcal{M}_k$  modèles et on se pose le problème d'en choisir un.

- Il n'existe pas de **critère universel** permettant de définir la notion de meilleur modèle.
- On parlera toujours de meilleur modèle **par rapport à un critère donné**.
- On présentera deux types de critère :
  - **ajustement du modèle** (vraisemblances pénalisées)
  - **capacité de prédiction du modèle**

② Etant donné  $Y$  une variable à expliquer et  $X_1, \dots, X_p$   $p$  variables explicatives, comment sélectionner **automatiquement** un modèle logistique ?

Il s'agit de trouver automatiquement un sous-groupe des variables explicatives permettant d'expliquer  $Y$ . On parle de **sélection de variables**.

Le problème de **sélection/choix de modèles** est ici abordé sous 2 angles (différents mais pas nécessairement indépendants) :

1 On est en présence de  $\mathcal{M}_1, \dots, \mathcal{M}_k$  modèles et on se pose le problème d'en choisir un.

- Il n'existe pas de **critère universel** permettant de définir la notion de meilleur modèle.
- On parlera toujours de meilleur modèle **par rapport à un critère donné**.
- On présentera deux types de critère :
  - **ajustement du modèle** (vraisemblances pénalisées)
  - **capacité de prédiction du modèle**

2 Etant donnés  $Y$  une variable à expliquer et  $X_1, \dots, X_p$   $p$  variables explicatives, comment sélectionner **automatiquement** un modèle logistique ?

Il s'agit de trouver automatiquement un sous-groupe des variables explicatives permettant d'expliquer  $Y$ . On parle de **sélection de variables**.

Le problème de **sélection/choix de modèles** est ici abordé sous 2 angles (différents mais pas nécessairement indépendants) :

1 On est en présence de  $\mathcal{M}_1, \dots, \mathcal{M}_k$  modèles et on se pose le problème d'en choisir un.

- Il n'existe pas de **critère universel** permettant de définir la notion de meilleur modèle.
- On parlera toujours de meilleur modèle **par rapport à un critère donné**.
- On présentera deux types de critère :
  - **ajustement du modèle** (vraisemblances pénalisées)
  - **capacité de prédiction du modèle**

2 Etant donné  $Y$  une variable à expliquer et  $X_1, \dots, X_p$   $p$  variables explicatives, comment sélectionner **automatiquement** un modèle logistique ?

Il s'agit de trouver automatiquement un sous-groupe des variables explicatives permettant d'expliquer  $Y$ . On parle de **sélection de variables**.

Le problème de **sélection/choix de modèles** est ici abordé sous 2 angles (différents mais pas nécessairement indépendants) :

1 On est en présence de  $\mathcal{M}_1, \dots, \mathcal{M}_k$  modèles et on se pose le problème d'en choisir un.

- Il n'existe pas de **critère universel** permettant de définir la notion de meilleur modèle.
- On parlera toujours de meilleur modèle **par rapport à un critère donné**.
- On présentera deux types de critère :
  - **ajustement du modèle** (vraisemblances pénalisées)
  - **capacité de prédiction du modèle**

2 Etant donné  $Y$  une variable à expliquer et  $X_1, \dots, X_p$   $p$  variables explicatives, comment sélectionner **automatiquement** un modèle logistique ?

Il s'agit de trouver automatiquement un sous-groupe des variables explicatives permettant d'expliquer  $Y$ . On parle de **sélection de variables**.

Le problème de **sélection/choix de modèles** est ici abordé sous 2 angles (différents mais pas nécessairement indépendants) :

- 1 On est en présence de  $\mathcal{M}_1, \dots, \mathcal{M}_k$  modèles et on se pose le problème d'en choisir un.
  - Il n'existe pas de **critère universel** permettant de définir la notion de meilleur modèle.
  - On parlera toujours de meilleur modèle **par rapport à un critère donné**.
  - On présentera deux types de critère :
    - **ajustement du modèle** (vraisemblances pénalisées)
    - **capacité de prédiction du modèle**
- 2 Etant donnés  $Y$  une variable à expliquer et  $X_1, \dots, X_p$   $p$  variables explicatives, comment sélectionner **automatiquement** un modèle logistique ?

Il s'agit de trouver automatiquement un sous-groupe des variables explicatives permettant d'expliquer  $Y$ . On parle de **sélection de variables**.

Le problème de **sélection/choix de modèles** est ici abordé sous 2 angles (différents mais pas nécessairement indépendants) :

- 1 On est en présence de  $\mathcal{M}_1, \dots, \mathcal{M}_k$  modèles et on se pose le problème d'en choisir un.
  - Il n'existe pas de **critère universel** permettant de définir la notion de meilleur modèle.
  - On parlera toujours de meilleur modèle **par rapport à un critère donné**.
  - On présentera deux types de critère :
    - **ajustement du modèle** (vraisemblances pénalisées)
    - **capacité de prédiction du modèle**
- 2 Etant donnés  $Y$  une variable à expliquer et  $X_1, \dots, X_p$   $p$  variables explicatives, comment sélectionner **automatiquement** un modèle logistique ?

Il s'agit de trouver automatiquement un sous-groupe des variables explicatives permettant d'expliquer  $Y$ . On parle de **sélection de variables**.

## Critères de choix de modèles

# Tests entre modèles emboîtés

- Afin de simplifier les notations, on supposera que l'on est en présence de deux modèles candidats  $\mathcal{M}_1$  et  $\mathcal{M}_2$ .
- Nous nous plaçons dans le cas particulier où le modèle  $\mathcal{M}_1$  est emboîté dans  $\mathcal{M}_2$  ( $\mathcal{M}_1$  est un cas particulier de  $\mathcal{M}_2$ ).

## Exemple

$\mathcal{M}_1$  et  $\mathcal{M}_2$  sont respectivement définis par

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4$$

et

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \beta_2 x_2.$$

Un moyen naturel de comparer  $\mathcal{M}_1$  et  $\mathcal{M}_2$  consiste à tester

$$H_0 : \beta_3 = \beta_4 = 0 \quad \text{contre} \quad H_1 : \beta_3 \neq 0 \text{ ou } \beta_4 \neq 0.$$

# Tests entre modèles emboîtés

- Afin de simplifier les notations, on supposera que l'on est en présence de deux modèles candidats  $\mathcal{M}_1$  et  $\mathcal{M}_2$ .
- Nous nous plaçons dans le cas particulier où le modèle  $\mathcal{M}_1$  est **emboité dans**  $\mathcal{M}_2$  ( $\mathcal{M}_1$  est un cas particulier de  $\mathcal{M}_2$ ).

## Exemple

$\mathcal{M}_1$  et  $\mathcal{M}_2$  sont respectivement définis par

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4$$

et

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \beta_2 x_2.$$

Un moyen naturel de comparer  $\mathcal{M}_1$  et  $\mathcal{M}_2$  consiste à tester

$$H_0 : \beta_3 = \beta_4 = 0 \quad \text{contre} \quad H_1 : \beta_3 \neq 0 \text{ ou } \beta_4 \neq 0.$$

# Tests entre modèles emboîtés

- Afin de simplifier les notations, on supposera que l'on est en présence de deux modèles candidats  $\mathcal{M}_1$  et  $\mathcal{M}_2$ .
- Nous nous plaçons dans le cas particulier où le modèle  $\mathcal{M}_1$  est emboîté dans  $\mathcal{M}_2$  ( $\mathcal{M}_1$  est un cas particulier de  $\mathcal{M}_2$ ).

## Exemple

$\mathcal{M}_1$  et  $\mathcal{M}_2$  sont respectivement définis par

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4$$

et

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \beta_2 x_2.$$

Un moyen naturel de comparer  $\mathcal{M}_1$  et  $\mathcal{M}_2$  consiste à tester

$$H_0 : \beta_3 = \beta_4 = 0 \quad \text{contre} \quad H_1 : \beta_3 \neq 0 \text{ ou } \beta_4 \neq 0.$$

# Tests entre modèles emboîtés

- Afin de simplifier les notations, on supposera que l'on est en présence de deux modèles candidats  $\mathcal{M}_1$  et  $\mathcal{M}_2$ .
- Nous nous plaçons dans le cas particulier où le modèle  $\mathcal{M}_1$  est emboîté dans  $\mathcal{M}_2$  ( $\mathcal{M}_1$  est un cas particulier de  $\mathcal{M}_2$ ).

## Exemple

$\mathcal{M}_1$  et  $\mathcal{M}_2$  sont respectivement définis par

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4$$

et

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \beta_2 x_2.$$

Un moyen naturel de comparer  $\mathcal{M}_1$  et  $\mathcal{M}_2$  consiste à tester

$$H_0 : \beta_3 = \beta_4 = 0 \quad \text{contre} \quad H_1 : \beta_3 \neq 0 \text{ ou } \beta_4 \neq 0.$$

- Plus généralement, considérons  $\mathcal{M}_1$  et  $\mathcal{M}_2$  deux modèles logistiques à  $p_1$  et  $p_2$  paramètres tels que  $\mathcal{M}_1$  est emboîté dans  $\mathcal{M}_2$ .
- Tester  $\mathcal{M}_1$  contre  $\mathcal{M}_2$  revient à tester la nullité des coefficients de  $\mathcal{M}_2$  que ne sont pas dans  $\mathcal{M}_1$ .
- On sait faire... On peut mettre en oeuvre un test de Wald, du rapport de vraisemblance ou du score.
- Sous  $H_0$  ces 3 statistiques de test suivent une loi du  $\chi^2_{p_2-p_1}$ .

- Plus généralement, considérons  $\mathcal{M}_1$  et  $\mathcal{M}_2$  deux modèles logistiques à  $p_1$  et  $p_2$  paramètres tels que  $\mathcal{M}_1$  est emboîté dans  $\mathcal{M}_2$ .
- Tester  $\mathcal{M}_1$  contre  $\mathcal{M}_2$  revient à **tester la nullité des coefficients** de  $\mathcal{M}_2$  que ne sont pas dans  $\mathcal{M}_1$ .
- On sait faire... On peut mettre en oeuvre un test de **Wald, du rapport de vraisemblance ou du score**.
- Sous  $H_0$  ces 3 statistiques de test suivent une loi du  $\chi^2_{p_2-p_1}$ .

- Plus généralement, considérons  $\mathcal{M}_1$  et  $\mathcal{M}_2$  deux modèles logistiques à  $p_1$  et  $p_2$  paramètres tels que  $\mathcal{M}_1$  est emboîté dans  $\mathcal{M}_2$ .
- Tester  $\mathcal{M}_1$  contre  $\mathcal{M}_2$  revient à **tester la nullité des coefficients** de  $\mathcal{M}_2$  que ne sont pas dans  $\mathcal{M}_1$ .
- On sait faire... On peut mettre en oeuvre un test de **Wald, du rapport de vraisemblance ou du score**.
- Sous  $H_0$  ces 3 statistiques de test suivent une loi du  $\chi^2_{p_2-p_1}$ .

- Plus généralement, considérons  $\mathcal{M}_1$  et  $\mathcal{M}_2$  deux modèles logistiques à  $p_1$  et  $p_2$  paramètres tels que  $\mathcal{M}_1$  est emboîté dans  $\mathcal{M}_2$ .
- Tester  $\mathcal{M}_1$  contre  $\mathcal{M}_2$  revient à **tester la nullité des coefficients** de  $\mathcal{M}_2$  que ne sont pas dans  $\mathcal{M}_1$ .
- On sait faire... On peut mettre en oeuvre un test de **Wald, du rapport de vraisemblance ou du score**.
- Sous  $H_0$  ces 3 statistiques de test suivent une loi du  $\chi^2_{p_2-p_1}$ .

# Exemple

- Pour le problème sur la maladie cardiovasculaire, on souhaite **comparer les modèles**

```
> model1 <- glm(chd~tobacco+famhist,data=SAheart,family=binomial)
> model2 <- glm(chd~tobacco+famhist+adiposity+alcohol,data=SAheart,
                family=binomial)
```

à l'aide d'un test de rapport de vraisemblance.

- On peut calculer la probabilité critique **à la main**

```
> stat <- 2*(logLik(model2)-logLik(model1))
> stat[1]
[1] 11.11016
> 1-pchisq(stat,df=length(model2$coef)-length(model1$coef))
[1] 0.003867751
```

- Ou directement avec la fonction **anova**

```
> anova(model1,model2,test="LRT")
Analysis of Deviance Table
```

Model 1: chd ~ tobacco + famhist

Model 2: chd ~ tobacco + famhist + adiposity + alcohol

	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	459	524.58			
2	457	513.47	2	11.11	0.003868 **

# Exemple

- Pour le problème sur la maladie cardiovasculaire, on souhaite **comparer les modèles**

```
> model1 <- glm(chd~tobacco+famhist,data=SAheart,family=binomial)
> model2 <- glm(chd~tobacco+famhist+adiposity+alcohol,data=SAheart,
                family=binomial)
```

à l'aide d'un test de rapport de vraisemblance.

- On peut calculer la probabilité critique **à la main**

```
> stat <- 2*(logLik(model2)-logLik(model1))
> stat[1]
[1] 11.11016
> 1-pchisq(stat,df=length(model2$coef)-length(model1$coef))
[1] 0.003867751
```

- Ou directement avec la fonction **anova**

```
> anova(model1,model2,test="LRT")
```

Analysis of Deviance Table

Model 1: chd ~ tobacco + famhist

Model 2: chd ~ tobacco + famhist + adiposity + alcohol

	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	459	524.58			
2	457	513.47	2	11.11	0.003868 **

# Exemple

- Pour le problème sur la maladie cardiovasculaire, on souhaite **comparer les modèles**

```
> model1 <- glm(chd~tobacco+famhist,data=SAheart,family=binomial)
> model2 <- glm(chd~tobacco+famhist+adiposity+alcohol,data=SAheart,
family=binomial)
```

à l'aide d'un test de rapport de vraisemblance.

- On peut calculer la probabilité critique **à la main**

```
> stat <- 2*(logLik(model2)-logLik(model1))
> stat[1]
[1] 11.11016
> 1-pchisq(stat,df=length(model2$coef)-length(model1$coef))
[1] 0.003867751
```

- Ou directement avec la fonction **anova**

```
> anova(model1,model2,test="LRT")
Analysis of Deviance Table
```

Model 1: chd ~ tobacco + famhist

Model 2: chd ~ tobacco + famhist + adiposity + alcohol

	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	459	524.58			
2	457	513.47	2	11.11	0.003868 **

- **Idée** : utiliser la vraisemblance pour comparer  $\mathcal{M}_1$  et  $\mathcal{M}_2$ .

## Problème

Si  $\mathcal{M}_1 \subset \mathcal{M}_2$  alors  $\mathcal{L}_n(\hat{\beta}_1) \leq \mathcal{L}_n(\hat{\beta}_2)$  où  $\hat{\beta}_j$  désigne l'emv du modèle  $\mathcal{M}_j, j = 1, 2$ .

- **Conséquence** : la vraisemblance sélectionnera toujours le modèle le plus complexe.

## Solution

Pénaliser la vraisemblance par la complexité du modèle.

- **Idée** : utiliser la vraisemblance pour comparer  $\mathcal{M}_1$  et  $\mathcal{M}_2$ .

## Problème

Si  $\mathcal{M}_1 \subset \mathcal{M}_2$  alors  $\mathcal{L}_n(\hat{\beta}_1) \leq \mathcal{L}_n(\hat{\beta}_2)$  où  $\hat{\beta}_j$  désigne l'emv du modèle  $\mathcal{M}_j, j = 1, 2$ .

- **Conséquence** : la vraisemblance sélectionnera toujours le modèle le plus complexe.

## Solution

Pénaliser la vraisemblance par la complexité du modèle.

- **Idée** : utiliser la vraisemblance pour comparer  $\mathcal{M}_1$  et  $\mathcal{M}_2$ .

## Problème

Si  $\mathcal{M}_1 \subset \mathcal{M}_2$  alors  $\mathcal{L}_n(\hat{\beta}_1) \leq \mathcal{L}_n(\hat{\beta}_2)$  où  $\hat{\beta}_j$  désigne l'emv du modèle  $\mathcal{M}_j, j = 1, 2$ .

- **Conséquence** : la vraisemblance sélectionnera toujours le modèle le plus complexe.

## Solution

Pénaliser la vraisemblance par la complexité du modèle.

- **Idée** : utiliser la vraisemblance pour comparer  $\mathcal{M}_1$  et  $\mathcal{M}_2$ .

## Problème

Si  $\mathcal{M}_1 \subset \mathcal{M}_2$  alors  $\mathcal{L}_n(\hat{\beta}_1) \leq \mathcal{L}_n(\hat{\beta}_2)$  où  $\hat{\beta}_j$  désigne l'emv du modèle  $\mathcal{M}_j, j = 1, 2$ .

- **Conséquence** : la vraisemblance sélectionnera toujours le modèle le plus complexe.

## Solution

Pénaliser la vraisemblance par la complexité du modèle.

## Définition

Soit  $\mathcal{M}$  un modèle logistique à  $p$  paramètres. On note  $\hat{\beta}_n$  l'emv des paramètres du modèle.

- L'**AIC (Akaike Information Criterion)** du modèle  $\mathcal{M}$  est défini par

$$AIC(\mathcal{M}) = -2\mathcal{L}_n(\hat{\beta}_n) + 2p.$$

- Le **BIC (Bayesian Information Criterion)** du modèle  $\mathcal{M}$  est défini par

$$BIC(\mathcal{M}) = -2\mathcal{L}_n(\hat{\beta}_n) + p \log n.$$

- Le modèle retenu sera celui qui **minimise** l'AIC ou le BIC.
- $\log n > 2$  (pour  $n \geq 8$ ) BIC aura tendance à choisir des modèles plus **parcimonieux** que AIC.

## Définition

Soit  $\mathcal{M}$  un modèle logistique à  $p$  paramètres. On note  $\hat{\beta}_n$  l'emv des paramètres du modèle.

- L'**AIC (Akaike Information Criterion)** du modèle  $\mathcal{M}$  est défini par

$$AIC(\mathcal{M}) = -2\mathcal{L}_n(\hat{\beta}_n) + 2p.$$

- Le **BIC (Bayesian Information Criterion)** du modèle  $\mathcal{M}$  est défini par

$$BIC(\mathcal{M}) = -2\mathcal{L}_n(\hat{\beta}_n) + p \log n.$$

- Le modèle retenu sera celui qui **minimise** l'AIC ou le BIC.
- $\log n > 2$  (pour  $n \geq 8$ ) BIC aura tendance à choisir des modèles plus **parcimonieux** que AIC.

## Définition

Soit  $\mathcal{M}$  un modèle logistique à  $p$  paramètres. On note  $\hat{\beta}_n$  l'emv des paramètres du modèle.

- L'**AIC (Akaike Information Criterion)** du modèle  $\mathcal{M}$  est défini par

$$AIC(\mathcal{M}) = -2\mathcal{L}_n(\hat{\beta}_n) + 2p.$$

- Le **BIC (Bayesian Information Criterion)** du modèle  $\mathcal{M}$  est défini par

$$BIC(\mathcal{M}) = -2\mathcal{L}_n(\hat{\beta}_n) + p \log n.$$

- Le modèle retenu sera celui qui **minimise** l'AIC ou le BIC.
- $\log n > 2$  (pour  $n \geq 8$ ) BIC aura tendance à choisir des modèles plus **parcimonieux** que AIC.

- On considère les mêmes modèles que précédemment :

```
> model1 <- glm(chd~tobacco+famhist,data=SAheart,family=binomial)
> model2 <- glm(chd~tobacco+famhist+adiposity+alcohol,data=SAheart,
                family=binomial)
```

- On les compare en terme d'AIC et de BIC.

```
> c(AIC(model1),AIC(model2))
[1] 530.5759 523.4657
> c(BIC(model1),BIC(model2))
[1] 542.9826 544.1436
```

## Conclusion

AIC sélectionne `model2` tandis que BIC sélectionne `model1`.

- On considère les mêmes modèles que précédemment :

```
> model1 <- glm(chd~tobacco+famhist,data=SAheart,family=binomial)
> model2 <- glm(chd~tobacco+famhist+adiposity+alcohol,data=SAheart,
                family=binomial)
```

- On les compare en terme d'AIC et de BIC.

```
> c(AIC(model1),AIC(model2))
[1] 530.5759 523.4657
> c(BIC(model1),BIC(model2))
[1] 542.9826 544.1436
```

## Conclusion

AIC sélectionne `model2` tandis que BIC sélectionne `model1`.

- On considère les mêmes modèles que précédemment :

```
> model1 <- glm(chd~tobacco+famhist,data=SAheart,family=binomial)
> model2 <- glm(chd~tobacco+famhist+adiposity+alcohol,data=SAheart,
                family=binomial)
```

- On les compare en terme d'AIC et de BIC.

```
> c(AIC(model1),AIC(model2))
[1] 530.5759 523.4657
> c(BIC(model1),BIC(model2))
[1] 542.9826 544.1436
```

## Conclusion

AIC sélectionne `model2` tandis que BIC sélectionne `model1`.

- L'idée est de chercher à comparer les **pouvoirs de prédiction** des modèles concurrents et de choisir celui qui prédit le mieux.
- L'approche consiste à définir une **règle de classification** à partir d'un modèle logistique :

$$\hat{g} : \mathbb{R}^p \rightarrow \{0, 1\}$$

qui à une valeur observée des variables explicatives associe une valeur prédicte pour  $Y$ .

- Il existe plusieurs critères permettant de **mesurer la performance** d'une règle  $\hat{g}$ .
- Un des critère les plus classiques consiste à chercher à estimer la **probabilité d'erreur**

$$P(\hat{g}(X) \neq Y).$$

- L'idée est de chercher à comparer les **pouvoirs de prédiction** des modèles concurrents et de choisir celui qui prédit le mieux.
- L'approche consiste à définir une **règle de classification** à partir d'un modèle logistique :

$$\hat{g} : \mathbb{R}^p \rightarrow \{0, 1\}$$

qui à une valeur observée des variables explicatives associe une valeur prédicte pour  $Y$ .

- Il existe plusieurs critères permettant de **mesurer la performance** d'une règle  $\hat{g}$ .
- Un des critère les plus classiques consiste à chercher à estimer la **probabilité d'erreur**

$$P(\hat{g}(X) \neq Y).$$

- L'idée est de chercher à comparer les **pouvoirs de prédiction** des modèles concurrents et de choisir celui qui prédit le mieux.
- L'approche consiste à définir une **règle de classification** à partir d'un modèle logistique :

$$\hat{g} : \mathbb{R}^p \rightarrow \{0, 1\}$$

qui à une valeur observée des variables explicatives associe une valeur prédicte pour  $Y$ .

- Il existe plusieurs critères permettant de **mesurer la performance** d'une règle  $\hat{g}$ .
- Un des critères les plus classiques consiste à chercher à estimer la **probabilité d'erreur**

$$\mathbf{P}(\hat{g}(X) \neq Y).$$

# Prévision avec un modèle logistique

- Modèle logistique permettant d'expliquer  $Y$  par  $X_1, \dots, X_p$  :

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \dots + \beta_p x_p = x' \beta.$$

- On peut estimer  $p_{\beta}(x)$  par

$$p_{\hat{\beta}_n}(x) = \frac{\exp(x' \hat{\beta}_n)}{1 + \exp(x' \hat{\beta}_n)}.$$

- Un moyen naturel de prédire le label  $y_{n+1}$  d'un nouvel individu  $x_{n+1}$  est de poser

$$\hat{Y}_{n+1} = \begin{cases} 1 & \text{si } p_{\hat{\beta}_n}(x) \geq s \\ 0 & \text{sinon.} \end{cases}$$

## Remarque

Le seuil  $s$  doit être choisi par l'utilisateur. Les logiciels prennent souvent par défaut  $s = 0.5$ .

# Prévision avec un modèle logistique

- Modèle logistique permettant d'expliquer  $Y$  par  $X_1, \dots, X_p$  :

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \dots + \beta_p x_p = x' \beta.$$

- On peut estimer  $p_{\beta}(x)$  par

$$p_{\hat{\beta}_n}(x) = \frac{\exp(x' \hat{\beta}_n)}{1 + \exp(x' \hat{\beta}_n)}.$$

- Un moyen naturel de prédire le label  $y_{n+1}$  d'un nouvel individu  $x_{n+1}$  est de poser

$$\hat{Y}_{n+1} = \begin{cases} 1 & \text{si } p_{\hat{\beta}_n}(x) \geq s \\ 0 & \text{sinon.} \end{cases}$$

## Remarque

Le seuil  $s$  doit être choisi par l'utilisateur. Les logiciels prennent souvent par défaut  $s = 0.5$ .

# Prévision avec un modèle logistique

- Modèle logistique permettant d'expliquer  $Y$  par  $X_1, \dots, X_p$  :

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \dots + \beta_p x_p = x' \beta.$$

- On peut estimer  $p_{\beta}(x)$  par

$$p_{\hat{\beta}_n}(x) = \frac{\exp(x' \hat{\beta}_n)}{1 + \exp(x' \hat{\beta}_n)}.$$

- Un moyen naturel de **prédire le label**  $y_{n+1}$  d'un nouvel individu  $x_{n+1}$  est de poser

$$\hat{Y}_{n+1} = \begin{cases} 1 & \text{si } p_{\hat{\beta}_n}(x) \geq s \\ 0 & \text{sinon.} \end{cases}$$

## Remarque

Le seuil  $s$  doit être **choisi par l'utilisateur**. Les logiciels prennent souvent par défaut  $s = 0.5$ .

# Prévision avec un modèle logistique

- Modèle logistique permettant d'expliquer  $Y$  par  $X_1, \dots, X_p$  :

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \dots + \beta_p x_p = x' \beta.$$

- On peut estimer  $p_{\beta}(x)$  par

$$p_{\hat{\beta}_n}(x) = \frac{\exp(x' \hat{\beta}_n)}{1 + \exp(x' \hat{\beta}_n)}.$$

- Un moyen naturel de **prédire le label**  $y_{n+1}$  d'un nouvel individu  $x_{n+1}$  est de poser

$$\hat{Y}_{n+1} = \begin{cases} 1 & \text{si } p_{\hat{\beta}_n}(x) \geq s \\ 0 & \text{sinon.} \end{cases}$$

## Remarque

Le seuil  $s$  doit être **choisi par l'utilisateur**. Les logiciels prennent souvent par défaut  $s = 0.5$ .

# Intervalles de confiance pour la probabilité estimée

- Etant donnée un nouvel individu  $x_{n+1}$ , il peut être intéressant de construire un **intervalle de confiance** pour la probabilité  $p_\beta(x_{n+1})$ .
- $\hat{\beta}_n$  est (pour  $n$  grand) un **vecteur gaussien** d'espérance  $\beta$  et de matrice de variance-covariance  $\mathcal{I}_n(\beta)^{-1}$ .
- Par conséquent,  $x'_{n+1}\hat{\beta}_n$  est (pour  $n$  grand) une var de loi gaussienne

$$\mathcal{N}(x'_{n+1}\beta, x'_{n+1}\mathcal{I}_n(\beta)^{-1}x_{n+1}).$$

En posant  $\hat{\sigma}^2 = x'_{n+1}(\mathbb{X}'W_{\hat{\beta}}\mathbb{X})^{-1}x_{n+1}$ , on déduit

$$IC_{1-\alpha}(p_\beta(x_{n+1})) = \left[ \frac{\exp(x'_{n+1}\hat{\beta}_n - u_{1-\alpha/2}\hat{\sigma})}{1 + \exp(x'_{n+1}\hat{\beta}_n - u_{1-\alpha/2}\hat{\sigma})}; \frac{\exp(x'_{n+1}\hat{\beta}_n + u_{1-\alpha/2}\hat{\sigma})}{1 + \exp(x'_{n+1}\hat{\beta}_n + u_{1-\alpha/2}\hat{\sigma})} \right]$$

- **Remarque** : il est possible de construire un IC centré en utilisant la delta-méthode.

# Intervalles de confiance pour la probabilité estimée

- Etant donnée un nouvel individu  $x_{n+1}$ , il peut être intéressant de construire un **intervalle de confiance** pour la probabilité  $p_\beta(x_{n+1})$ .
- $\hat{\beta}_n$  est (pour  $n$  grand) un **vecteur gaussien** d'espérance  $\beta$  et de matrice de variance-covariance  $\mathcal{I}_n(\beta)^{-1}$ .
- Par conséquent,  $x'_{n+1}\hat{\beta}_n$  est (pour  $n$  grand) une var de loi gaussienne

$$\mathcal{N}(x'_{n+1}\beta, x'_{n+1}\mathcal{I}_n(\beta)^{-1}x_{n+1}).$$

En posant  $\hat{\sigma}^2 = x'_{n+1}(\mathbb{X}'W_{\hat{\beta}}\mathbb{X})^{-1}x_{n+1}$ , on déduit

$$IC_{1-\alpha}(p_\beta(x_{n+1})) = \left[ \frac{\exp(x'_{n+1}\hat{\beta}_n - u_{1-\alpha/2}\hat{\sigma})}{1 + \exp(x'_{n+1}\hat{\beta}_n - u_{1-\alpha/2}\hat{\sigma})}; \frac{\exp(x'_{n+1}\hat{\beta}_n + u_{1-\alpha/2}\hat{\sigma})}{1 + \exp(x'_{n+1}\hat{\beta}_n + u_{1-\alpha/2}\hat{\sigma})} \right]$$

- **Remarque** : il est possible de construire un IC centré en utilisant la delta-méthode.

# Intervalles de confiance pour la probabilité estimée

- Etant donnée un nouvel individu  $x_{n+1}$ , il peut être intéressant de construire un **intervalle de confiance** pour la probabilité  $p_\beta(x_{n+1})$ .
- $\hat{\beta}_n$  est (pour  $n$  grand) un **vecteur gaussien** d'espérance  $\beta$  et de matrice de variance-covariance  $\mathcal{I}_n(\beta)^{-1}$ .
- Par conséquent,  $x'_{n+1}\hat{\beta}_n$  est (pour  $n$  grand) une var de loi gaussienne

$$\mathcal{N}(x'_{n+1}\beta, x'_{n+1}\mathcal{I}_n(\beta)^{-1}x_{n+1}).$$

En posant  $\hat{\sigma}^2 = x'_{n+1}(\mathbb{X}'W_{\hat{\beta}}\mathbb{X})^{-1}x_{n+1}$ , on déduit

$$IC_{1-\alpha}(p_\beta(x_{n+1})) = \left[ \frac{\exp(x'_{n+1}\hat{\beta}_n - u_{1-\alpha/2}\hat{\sigma})}{1 + \exp(x'_{n+1}\hat{\beta}_n - u_{1-\alpha/2}\hat{\sigma})}; \frac{\exp(x'_{n+1}\hat{\beta}_n + u_{1-\alpha/2}\hat{\sigma})}{1 + \exp(x'_{n+1}\hat{\beta}_n + u_{1-\alpha/2}\hat{\sigma})} \right]$$

- **Remarque** : il est possible de construire un IC centré en utilisant la delta-méthode.

# Intervalles de confiance pour la probabilité estimée

- Etant donnée un nouvel individu  $x_{n+1}$ , il peut être intéressant de construire un **intervalle de confiance** pour la probabilité  $p_\beta(x_{n+1})$ .
- $\hat{\beta}_n$  est (pour  $n$  grand) un **vecteur gaussien** d'espérance  $\beta$  et de matrice de variance-covariance  $\mathcal{I}_n(\beta)^{-1}$ .
- Par conséquent,  $x'_{n+1}\hat{\beta}_n$  est (pour  $n$  grand) une var de loi gaussienne

$$\mathcal{N}(x'_{n+1}\beta, x'_{n+1}\mathcal{I}_n(\beta)^{-1}x_{n+1}).$$

En posant  $\hat{\sigma}^2 = x'_{n+1}(\mathbb{X}'W_{\hat{\beta}}\mathbb{X})^{-1}x_{n+1}$ , on déduit

$$IC_{1-\alpha}(p_\beta(x_{n+1})) = \left[ \frac{\exp(x'_{n+1}\hat{\beta}_n - u_{1-\alpha/2}\hat{\sigma})}{1 + \exp(x'_{n+1}\hat{\beta}_n - u_{1-\alpha/2}\hat{\sigma})}; \frac{\exp(x'_{n+1}\hat{\beta}_n + u_{1-\alpha/2}\hat{\sigma})}{1 + \exp(x'_{n+1}\hat{\beta}_n + u_{1-\alpha/2}\hat{\sigma})} \right]$$

- **Remarque** : il est possible de construire un IC centré en utilisant la delta-méthode.

# Un critère de prévision : la probabilité d'erreur

- On suppose dans cette section que les **variables explicatives sont aléatoires** et on note  $\mathcal{D}_n = (X_1, Y_1), \dots, (X_n, Y_n)$  un  $n$ -échantillon i.i.d de même loi que  $(X, Y)$ .
- L'approche consiste à comparer deux modèles  $\mathcal{M}_1$  et  $\mathcal{M}_2$  en **comparant les probabilités d'erreur**

$$L(\hat{g}) = \mathbf{P}(\hat{g}(X) \neq Y)$$

des règles de classification issues de ces deux modèles.

La probabilité  $L(\hat{g})$  est **inconnue** et doit être **estimée**.

# Un critère de prévision : la probabilité d'erreur

- On suppose dans cette section que les **variables explicatives sont aléatoires** et on note  $\mathcal{D}_n = (X_1, Y_1), \dots, (X_n, Y_n)$  un  $n$ -échantillon i.i.d de même loi que  $(X, Y)$ .
- L'approche consiste à comparer deux modèles  $\mathcal{M}_1$  et  $\mathcal{M}_2$  en **comparant les probabilités d'erreur**

$$L(\hat{g}) = \mathbf{P}(\hat{g}(X) \neq Y)$$

des règles de classification issues de ces deux modèles.

La probabilité  $L(\hat{g})$  est **inconnue** et doit être **estimée**.

# Un critère de prévision : la probabilité d'erreur

- On suppose dans cette section que les **variables explicatives sont aléatoires** et on note  $\mathcal{D}_n = (X_1, Y_1), \dots, (X_n, Y_n)$  un  $n$ -échantillon i.i.d de même loi que  $(X, Y)$ .
- L'approche consiste à comparer deux modèles  $\mathcal{M}_1$  et  $\mathcal{M}_2$  en **comparant les probabilités d'erreur**

$$L(\hat{g}) = \mathbf{P}(\hat{g}(X) \neq Y)$$

des règles de classification issues de ces deux modèles.

La probabilité  $L(\hat{g})$  est **inconnue** et doit être **estimée**.

- **Première idée** : estimer  $L(\hat{g})$  en
  - 1 appliquant la règle  $\hat{g}$  sur les variables  $X_i$  pour en déduire une **prévision**  $\hat{Y}_i = \hat{g}(X_i)$  de la variable  $Y$  pour chaque individu.
  - 2 comparant la **prévision**  $\hat{Y}_i$  avec la **valeur observée**  $Y_i$

$$L_n(\hat{g}) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\hat{g}(X_i) \neq Y_i}.$$

## Table de confusion

- On dresse généralement la table de confusion

	$\hat{Y} = 0$	$\hat{Y} = 1$
$Y = 0$	OK	$E_1$
$Y = 1$	$E_2$	OK

- La probabilité d'erreur est alors **estimée** par

$$L_n(\hat{g}) = \frac{E_1 + E_2}{n}.$$

- **Première idée** : estimer  $L(\hat{g})$  en
  - 1 appliquant la règle  $\hat{g}$  sur les variables  $X_i$  pour en déduire une **prévision**  $\hat{Y}_i = \hat{g}(X_i)$  de la variable  $Y$  pour chaque individu.
  - 2 comparant la **prévision**  $\hat{Y}_i$  avec la **valeur observée**  $Y_i$

$$L_n(\hat{g}) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\hat{g}(X_i) \neq Y_i}.$$

## Table de confusion

- On dresse généralement la table de confusion

	$\hat{Y} = 0$	$\hat{Y} = 1$
$Y = 0$	OK	$E_1$
$Y = 1$	$E_2$	OK

- La probabilité d'erreur est alors **estimée** par

$$L_n(\hat{g}) = \frac{E_1 + E_2}{n}.$$

- **Première idée** : estimer  $L(\hat{g})$  en
  - 1 appliquant la règle  $\hat{g}$  sur les variables  $X_i$  pour en déduire une **prévision**  $\hat{Y}_i = \hat{g}(X_i)$  de la variable  $Y$  pour chaque individu.
  - 2 comparant la **prévision**  $\hat{Y}_i$  avec la **valeur observée**  $Y_i$

$$L_n(\hat{g}) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\hat{g}(X_i) \neq Y_i}.$$

## Table de confusion

- On dresse généralement la table de confusion

	$\hat{Y} = 0$	$\hat{Y} = 1$
$Y = 0$	OK	$E_1$
$Y = 1$	$E_2$	OK

- La probabilité d'erreur est alors **estimée** par

$$L_n(\hat{g}) = \frac{E_1 + E_2}{n}.$$

- **Première idée** : estimer  $L(\hat{g})$  en
  - 1 appliquant la règle  $\hat{g}$  sur les variables  $X_i$  pour en déduire une **prévision**  $\hat{Y}_i = \hat{g}(X_i)$  de la variable  $Y$  pour chaque individu.
  - 2 comparant la **prévision**  $\hat{Y}_i$  avec la **valeur observée**  $Y_i$

$$L_n(\hat{g}) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\hat{g}(X_i) \neq Y_i}.$$

## Table de confusion

- On dresse généralement la table de confusion

	$\hat{Y} = 0$	$\hat{Y} = 1$
$Y = 0$	OK	$E_1$
$Y = 1$	$E_2$	OK

- La probabilité d'erreur est alors **estimée** par

$$L_n(\hat{g}) = \frac{E_1 + E_2}{n}.$$

## Problème

- $L_n(\hat{g})$  n'est généralement **pas un bon estimateur** de  $L(\hat{g})$  (sous-estimation).
- La loi des grands nombres ne peut s'appliquer car les variables

$$\mathbf{1}_{\hat{g}(X_i) \neq Y_i}$$

ne sont **pas indépendantes**.

- Le problème vient du fait que l'échantillon  $\mathcal{D}_n$  est **utilisé deux fois** (pour calculer  $\hat{g}$  puis pour estimer  $L(\hat{g})$ ).

## Solution

Découper l'échantillon en deux :

- **un échantillon d'apprentissage** utilisé pour calculer la règle  $\hat{g}$  (estimer les paramètres du modèle logistique).
- **un échantillon test ou de validation** utilisé pour estimer la probabilité d'erreur  $L(\hat{g})$ .

## Problème

- $L_n(\hat{g})$  n'est généralement **pas un bon estimateur** de  $L(\hat{g})$  (sous-estimation).
- La loi des grands nombres ne peut s'appliquer car les variables

$$\mathbf{1}_{\hat{g}(X_i) \neq Y_i}$$

ne sont **pas indépendantes**.

- Le problème vient du fait que l'échantillon  $\mathcal{D}_n$  est **utilisé deux fois** (pour calculer  $\hat{g}$  puis pour estimer  $L(\hat{g})$ ).

## Solution

Découper l'échantillon en deux :

- **un échantillon d'apprentissage** utilisé pour calculer la règle  $\hat{g}$  (estimer les paramètres du modèle logistique).
- **un échantillon test ou de validation** utilisé pour estimer la probabilité d'erreur  $L(\hat{g})$ .

## Estimateur de $L(\hat{g})$ par A/V

L'échantillon  $\mathcal{D}_n = (X_1, Y_1), \dots, (X_n, Y_n)$  est séparé aléatoirement en deux sous échantillons :

- 1 **un échantillon d'apprentissage**  $\mathcal{D}_\ell = \{(X_i, Y_i), i \in \mathcal{J}_\ell\}$  de taille  $\ell$  utilisé pour estimer les paramètres du modèle et en déduire la règle  $\hat{g}$ .
- 2 **un échantillon test ou de validation**  $\mathcal{D}_m = \{(X_i, Y_i), i \in \mathcal{J}_m\}$  de taille  $m$  utilisé pour estimer  $L(\hat{g})$  par

$$L_n(\hat{g}) = \frac{1}{m} \sum_{i \in \mathcal{J}_m} \mathbf{1}_{\hat{g}(X_i) \neq Y_i},$$

avec  $\mathcal{J}_\ell \cup \mathcal{J}_m = \{1, \dots, n\}$  et  $\mathcal{J}_\ell \cap \mathcal{J}_m = \emptyset$ .

## Propriété

L'estimateur  $L_n(\hat{g})$  est un estimateur sans biais de  $L(\hat{g})$ .

## Estimateur de $L(\hat{g})$ par A/V

L'échantillon  $\mathcal{D}_n = (X_1, Y_1), \dots, (X_n, Y_n)$  est séparé aléatoirement en deux sous échantillons :

- 1 un échantillon d'apprentissage  $\mathcal{D}_\ell = \{(X_i, Y_i), i \in \mathcal{J}_\ell\}$  de taille  $\ell$  utilisé pour estimer les paramètres du modèle et en déduire la règle  $\hat{g}$ .
- 2 un échantillon test ou de validation  $\mathcal{D}_m = \{(X_i, Y_i), i \in \mathcal{J}_m\}$  de taille  $m$  utilisé pour estimer  $L(\hat{g})$  par

$$L_n(\hat{g}) = \frac{1}{m} \sum_{i \in \mathcal{J}_m} \mathbf{1}_{\hat{g}(X_i) \neq Y_i},$$

avec  $\mathcal{J}_\ell \cup \mathcal{J}_m = \{1, \dots, n\}$  et  $\mathcal{J}_\ell \cap \mathcal{J}_m = \emptyset$ .

## Propriété

L'estimateur  $L_n(\hat{g})$  est un estimateur **sans biais** de  $L(\hat{g})$ .

# Exemple

On estime la probabilité d'erreur pour deux modèles logistiques concurrents sur les données concernant la maladie cardiovasculaire.

- Construction des échantillons d'apprentissage et test

```
n <- nrow(SAheart)
l <- 250 #taille de l'ech d'apprentissage
set.seed(1234)
perm <- sample(n)
dapp <- SAheart[perm[1:l],]
dtest <- SAheart[-perm[1:l],]
```

- Ajustement des modèles sur l'échantillon d'apprentissage.

```
> model1 <- glm(chd~tobacco+famhist,data=dapp,family=binomial)
> model2 <- glm(chd~tobacco+famhist+adiposity+alcohol,data=dapp,family=binomial)
```

- Estimation de la probabilité d'erreur sur l'échantillon test.

```
> prev1 <- round(predict(model1,newdata=dtest,type="response"))
> prev2 <- round(predict(model2,newdata=dtest,type="response"))
>
> mean(prev1!=dtest$chd)
[1] 0.3113208
> mean(prev2!=dtest$chd)
[1] 0.2877358
```

On estime la probabilité d'erreur pour deux modèles logistiques concurrents sur les données concernant la maladie cardiovasculaire.

- **Construction des échantillons** d'apprentissage et test

```
n <- nrow(SAheart)
l <- 250 #taille de l'ech d'apprentissage
set.seed(1234)
perm <- sample(n)
dapp <- SAheart[perm[1:l],]
dtest <- SAheart[-perm[1:l],]
```

- **Ajustement des modèles** sur l'échantillon d'apprentissage.

```
> model1 <- glm(chd~tobacco+famhist,data=dapp,family=binomial)
> model2 <- glm(chd~tobacco+famhist+adiposity+alcohol,data=dapp,family=binomial)
```

- **Estimation de la probabilité d'erreur** sur l'échantillon test.

```
> prev1 <- round(predict(model1,newdata=dtest,type="response"))
> prev2 <- round(predict(model2,newdata=dtest,type="response"))
>
> mean(prev1!=dtest$chd)
[1] 0.3113208
> mean(prev2!=dtest$chd)
[1] 0.2877358
```

# Exemple

On estime la probabilité d'erreur pour deux modèles logistiques concurrents sur les données concernant la maladie cardiovasculaire.

- **Construction des échantillons** d'apprentissage et test

```
n <- nrow(SAheart)
l <- 250 #taille de l'ech d'apprentissage
set.seed(1234)
perm <- sample(n)
dapp <- SAheart[perm[1:l],]
dtest <- SAheart[-perm[1:l],]
```

- **Ajustement des modèles** sur l'échantillon d'apprentissage.

```
> model1 <- glm(chd~tobacco+famhist,data=dapp,family=binomial)
> model2 <- glm(chd~tobacco+famhist+adiposity+alcohol,data=dapp,famil
```

- **Estimation de la probabilité d'erreur** sur l'échantillon test.

```
> prev1 <- round(predict(model1,newdata=dtest,type="response"))
> prev2 <- round(predict(model2,newdata=dtest,type="response"))
>
> mean(prev1!=dtest$chd)
[1] 0.3113208
> mean(prev2!=dtest$chd)
[1] 0.2877358
```

On estime la probabilité d'erreur pour deux modèles logistiques concurrents sur les données concernant la maladie cardiovasculaire.

- **Construction des échantillons** d'apprentissage et test

```
n <- nrow(SAheart)
l <- 250 #taille de l'ech d'apprentissage
set.seed(1234)
perm <- sample(n)
dapp <- SAheart[perm[1:l],]
dtest <- SAheart[-perm[1:l],]
```

- **Ajustement des modèles** sur l'échantillon d'apprentissage.


```
> model1 <- glm(chd~tobacco+famhist,data=dapp,family=binomial)
> model2 <- glm(chd~tobacco+famhist+adiposity+alcohol,data=dapp,famil
```

- **Estimation de la probabilité d'erreur** sur l'échantillon test.

```
> prev1 <- round(predict(model1,newdata=dtest,type="response"))
> prev2 <- round(predict(model2,newdata=dtest,type="response"))
>
> mean(prev1!=dtest$chd)
[1] 0.3113208
> mean(prev2!=dtest$chd)
[1] 0.2877358
```


- Un des avantages de la probabilité d'erreur est qu'elle permet de comparer **différents modèles issus de différentes méthodes**.
- Construisons par exemple un **arbre de classification**.

```
> arbre <- rpart(chd~., data=dapp)
> plot(arbre)
> text(arbre, pretty=0)
```



- Un des avantages de la probabilité d'erreur est qu'elle permet de comparer **différents modèles issus de différentes méthodes**.
- Construisons par exemple un **arbre de classification**.

```
> arbre <- rpart(chd~., data=dapp)
> plot(arbre)
> text(arbre, pretty=0)
```



- Et estimons sa **probabilité d'erreur** sur l'échantillon test

```
> prev3 <- predict(arbre, newdata=dtest, type="class")  
> mean(prev3!=dtest$chd)  
[1] 0.3490566
```

### Probabilités d'erreur estimées

modèle	logit1	logit2	arbre
erreur estimée	0.31	0.29	0.35

- Pour ce critère, on privilégiera le **second modèle logistique**.

- Et estimons sa **probabilité d'erreur** sur l'échantillon test

```
> prev3 <- predict(arbre, newdata=dtest, type="class")  
> mean(prev3!=dtest$chd)  
[1] 0.3490566
```

## Probabilités d'erreur estimées

modèle	logit1	logit2	arbre
erreur estimée	0.31	0.29	0.35

- Pour ce critère, on privilégiera le **second modèle logistique**.

- Et estimons sa **probabilité d'erreur** sur l'échantillon test

```
> prev3 <- predict(arbre, newdata=dtest, type="class")  
> mean(prev3!=dtest$chd)  
[1] 0.3490566
```

## Probabilités d'erreur estimées

modèle	logit1	logit2	arbre
erreur estimée	0.31	0.29	0.35

- Pour ce critère, on privilégiera le **second modèle logistique**.

# Un inconvénient de la probabilité d'erreur

- Le critère de la probabilité d'erreur porte sur une **règle de classification**.
- Il impose donc d'avoir fixé le seuil  $s$  tel que

$$\hat{Y} = \begin{cases} 1 & \text{si } p_{\hat{\beta}_n}(x) \geq s \\ 0 & \text{sinon.} \end{cases}$$

et il dépend du seuil fixé.

- Il existe des **indicateurs plus flexibles** (toujours basés sur la prévision) qui n'imposent pas de fixer le seuil.
- La **courbe ROC** basée sur la notion de **score** fait partie de ces critères.

# Un inconvénient de la probabilité d'erreur

- Le critère de la probabilité d'erreur porte sur une **règle de classification**.
- Il **impose donc d'avoir fixé le seuil**  $s$  tel que

$$\hat{Y} = \begin{cases} 1 & \text{si } p_{\hat{\beta}_n}(x) \geq s \\ 0 & \text{sinon.} \end{cases}$$

et il dépend du seuil fixé.

- Il existe des **indicateurs plus flexibles** (toujours basés sur la prévision) qui n'imposent pas de fixer le seuil.
- La **courbe ROC** basée sur la notion de **score** fait partie de ces critères.

# Un inconvénient de la probabilité d'erreur

- Le critère de la probabilité d'erreur porte sur une **règle de classification**.
- Il **impose donc d'avoir fixé le seuil**  $s$  tel que

$$\hat{Y} = \begin{cases} 1 & \text{si } p_{\hat{\beta}_n}(x) \geq s \\ 0 & \text{sinon.} \end{cases}$$

et il dépend du seuil fixé.

- Il existe des **indicateurs plus flexibles** (toujours basés sur la prévision) qui n'imposent pas de fixer le seuil.
- La **courbe ROC** basée sur la notion de **score** fait partie de ces critères.

# Un inconvénient de la probabilité d'erreur

- Le critère de la probabilité d'erreur porte sur une **règle de classification**.
- Il **impose donc d'avoir fixé le seuil**  $s$  tel que

$$\hat{Y} = \begin{cases} 1 & \text{si } p_{\hat{\beta}_n}(x) \geq s \\ 0 & \text{sinon.} \end{cases}$$

et il dépend du seuil fixé.

- Il existe des **indicateurs plus flexibles** (toujours basés sur la prévision) qui n'imposent pas de fixer le seuil.
- La **courbe ROC** basée sur la notion de **score** fait partie de ces critères.

# Score : définition

- Un score est une **fonction**  $S : \mathbb{R}^p \rightarrow \mathbb{R}$ .
- Etant données  $n$  un échantillon  $(X_1, Y_1), \dots, (X_n, Y_n)$  le job du statisticien consiste à **construire une fonction**  $S(x)$  qui permettent d'expliquer  $Y$  *au mieux*.



- Une fois le score construit, la **décision** s'effectue selon la procédure

$$\hat{Y} = \begin{cases} 1 & \text{si } \hat{S}(x) \geq s \\ 0 & \text{sinon,} \end{cases}$$

où  $s$  est un **seuil** choisi par l'utilisateur.

- La construction de scores s'effectue généralement avec les **modèles de régression classiques**.

# Score : définition

- Un score est une **fonction**  $S : \mathbb{R}^p \rightarrow \mathbb{R}$ .
- Etant données  $n$  un échantillon  $(X_1, Y_1), \dots, (X_n, Y_n)$  le job du statisticien consiste à **construire une fonction**  $S(x)$  qui permettent d'expliquer  $Y$  *au mieux*.



- Une fois le score construit, la **décision** s'effectue selon la procédure

$$\hat{Y} = \begin{cases} 1 & \text{si } \hat{S}(x) \geq s \\ 0 & \text{sinon,} \end{cases}$$

où  $s$  est un **seuil** choisi par l'utilisateur.

- La construction de scores s'effectue généralement avec les **modèles de régression classiques**.

# Score : définition

- Un score est une **fonction**  $S : \mathbb{R}^p \rightarrow \mathbb{R}$ .
- Etant données  $n$  un échantillon  $(X_1, Y_1), \dots, (X_n, Y_n)$  le job du statisticien consiste à **construire une fonction**  $S(x)$  qui permettent d'expliquer  $Y$  *au mieux*.



- Une fois le score construit, la **décision** s'effectue selon la procédure

$$\hat{Y} = \begin{cases} 1 & \text{si } \hat{S}(x) \geq s \\ 0 & \text{sinon,} \end{cases}$$

où  $s$  est un **seuil** choisi par l'utilisateur.

- La construction de scores s'effectue généralement avec les **modèles de régression classiques**.

# Score : définition

- Un score est une **fonction**  $S : \mathbb{R}^p \rightarrow \mathbb{R}$ .
- Etant données  $n$  un échantillon  $(X_1, Y_1), \dots, (X_n, Y_n)$  le job du statisticien consiste à **construire une fonction**  $S(x)$  qui permettent d'expliquer  $Y$  *au mieux*.



- Une fois le score construit, la **décision** s'effectue selon la procédure

$$\hat{Y} = \begin{cases} 1 & \text{si } \hat{S}(x) \geq s \\ 0 & \text{sinon,} \end{cases}$$

où  $s$  est un **seuil** choisi par l'utilisateur.

- La construction de scores s'effectue généralement avec les **modèles de régression classiques**.

- de loin le plus utilisé...
- On considère le **modèle logistique**

$$\log \frac{p_{\beta}(x)}{1 - p_{\beta}(x)} = \beta_1 x_1 + \dots + \beta_p x_p$$

- Il suffit de poser  $S(x) = p_{\beta}(x)$  ou

$$S(x) = \beta_1 x_1 + \dots + \beta_p x_p.$$

- de loin le plus utilisé...
- On considère le **modèle logistique**

$$\log \frac{p_{\beta}(x)}{1 - p_{\beta}(x)} = \beta_1 x_1 + \dots + \beta_p x_p$$

- Il suffit de poser  $S(x) = p_{\beta}(x)$  ou

$$S(x) = \beta_1 x_1 + \dots + \beta_p x_p.$$

- On calcule un **score logistique** sur l'exemple suivant :
- On dispose d'un **échantillon de taille**  $n = 150$  pour construire les fonctions de score (table `dapp`) :

	X1	X2	Y
1	-1.2070657	0.3158544	1
2	0.2774292	-2.1866448	0
3	1.0844412	-0.3307386	0
4	-2.3456977	-1.9001806	1
5	0.4291247	-0.3691092	0

- On souhaite calculer le score pour 100 **nouveaux individus** (table `dtest`) :

	X1	X2
151	-0.37723765	-0.01545427
152	0.09761946	1.65997581
153	1.63874465	1.24334905
154	-0.87559247	-0.00564424
155	0.12176000	0.44504449

- On calcule un **score logistique** sur l'exemple suivant :
- On dispose d'un **échantillon de taille**  $n = 150$  pour construire les fonctions de score (table `dapp`) :

	X1	X2	Y
1	-1.2070657	0.3158544	1
2	0.2774292	-2.1866448	0
3	1.0844412	-0.3307386	0
4	-2.3456977	-1.9001806	1
5	0.4291247	-0.3691092	0

- On souhaite calculer le score pour 100 **nouveaux individus** (table `dtest`) :

	X1	X2
151	-0.37723765	-0.01545427
152	0.09761946	1.65997581
153	1.63874465	1.24334905
154	-0.87559247	-0.00564424
155	0.12176000	0.44504449

- On ajuste le **modèle logistique** sur l'échantillon d'apprentissage :

```
> model_logit <- glm(Y~.,data=dapp,family=binomial)
```

- On calcule le score des **nouveaux individus** :

```
> S1 <- predict(model_logit,newdata=dtest,type="response")
```

- On peut afficher le score de ces nouveaux individus :

```
> S1[1:5]
      151      152      153      154      155
0.77724343 0.56927363 0.02486394 0.92479413 0.51310825
```

- On ajuste le **modèle logistique** sur l'échantillon d'apprentissage :

```
> model_logit <- glm(Y~.,data=dapp,family=binomial)
```

- On calcule le score des **nouveaux individus** :

```
> S1 <- predict(model_logit,newdata=dtest,type="response")
```

- On peut afficher le score de ces nouveaux individus :

```
> S1[1:5]
      151      152      153      154      155
0.77724343 0.56927363 0.02486394 0.92479413 0.51310825
```

- Etant donné un score et un seuil  $s$ , on peut se donner une règle de décision

$$\hat{Y} = \hat{Y}_s = \begin{cases} 1 & \text{si } S(x) \geq s \\ 0 & \text{sinon.} \end{cases}$$

- Cette règle définit la table de confusion

	$\hat{Y} = 0$	$\hat{Y} = 1$
$Y = 0$	OK	$E_1$
$Y = 1$	$E_2$	OK

- On définit :

- **Spécificité** :  $sp(s) = \mathbf{P}(S(X) < s | Y = 0)$
- **Sensibilité** :  $se(s) = \mathbf{P}(S(X) \geq s | Y = 1)$

- Etant donné un score et un seuil  $s$ , on peut se donner une règle de décision

$$\hat{Y} = \hat{Y}_s = \begin{cases} 1 & \text{si } S(x) \geq s \\ 0 & \text{sinon.} \end{cases}$$

- Cette règle définit la table de confusion

	$\hat{Y} = 0$	$\hat{Y} = 1$
$Y = 0$	OK	$E_1$
$Y = 1$	$E_2$	OK

- On définit :

- **Spécificité** :  $sp(s) = \mathbf{P}(S(X) < s | Y = 0)$
- **Sensibilité** :  $se(s) = \mathbf{P}(S(X) \geq s | Y = 1)$

- Etant donné un score et un seuil  $s$ , on peut se donner une règle de décision

$$\hat{Y} = \hat{Y}_s = \begin{cases} 1 & \text{si } S(x) \geq s \\ 0 & \text{sinon.} \end{cases}$$

- Cette règle définit la table de confusion

	$\hat{Y} = 0$	$\hat{Y} = 1$
$Y = 0$	OK	$E_1$
$Y = 1$	$E_2$	OK

- On définit :
  - **Spécificité** :  $sp(s) = \mathbf{P}(S(X) < s | Y = 0)$
  - **Sensibilité** :  $se(s) = \mathbf{P}(S(X) \geq s | Y = 1)$

## Définition


C'est une courbe paramétrée par le seuil :

$$\begin{cases} x(s) = 1 - sp(s) = \mathbf{P}(S(X) > s | Y = 0) \\ y(s) = se(s) = \mathbf{P}(S(X) \geq s | Y = 1) \end{cases}$$

## Définition

C'est une courbe paramétrée par le seuil :

$$\begin{cases} x(s) = 1 - sp(s) = \mathbf{P}(S(X) > s | Y = 0) \\ y(s) = se(s) = \mathbf{P}(S(X) \geq s | Y = 1) \end{cases}$$



- La courbe ROC associée à une fonction de score  $S$  nécessite le calcul des probabilités  $\mathbf{P}(S(X) > s|Y = 0)$  et  $\mathbf{P}(S(X) \geq s|Y = 1)$ .
- Ces probabilités ne sont pas calculables en pratique et doivent être **estimées**.
- L'estimation s'effectue à l'aide d'un échantillon **indépendant** de celui utilisé pour construire la fonction de score.

- La courbe ROC associée à une fonction de score  $S$  nécessite le calcul des probabilités  $\mathbf{P}(S(X) > s | Y = 0)$  et  $\mathbf{P}(S(X) \geq s | Y = 1)$ .
- Ces probabilités ne sont pas calculables en pratique et doivent être **estimées**.
- L'estimation s'effectue à l'aide d'un échantillon **indépendant** de celui utilisé pour construire la fonction de score.


- La courbe ROC associée à une fonction de score  $S$  nécessite le calcul des probabilités  $\mathbf{P}(S(X) > s | Y = 0)$  et  $\mathbf{P}(S(X) \geq s | Y = 1)$ .
- Ces probabilités ne sont pas calculables en pratique et doivent être **estimées**.
- L'estimation s'effectue à l'aide d'un échantillon **indépendant** de celui utilisé pour construire la fonction de score.

- 2 quantités sont à estimer :
  - 1 La fonction de score  $S(x)$
  - 2 Les paramètres de la courbe ROC :  $\mathbf{P}(S(X) > s | Y = 0)$  et  $\mathbf{P}(S(X) \geq s | Y = 1)$ .
- L'échantillon  $(X_1, Y_1), \dots, (X_n, Y_n)$  est séparé deux :
  - 1 un échantillon d'apprentissage  $(X_1, Y_1), \dots, (X_\ell, Y_\ell)$  utilisé pour estimer la fonction de score (par exemple les paramètres du modèle logistique pour le score logistique).
  - 2 un échantillon test  $(X_{\ell+1}, Y_{\ell+1}), \dots, (X_n, Y_n)$  pour estimer la courbe ROC.

- 2 quantités sont à estimer :
  - 1 La fonction de score  $S(x)$
  - 2 Les paramètres de la courbe ROC :  $\mathbf{P}(S(X) > s | Y = 0)$  et  $\mathbf{P}(S(X) \geq s | Y = 1)$ .
- L'échantillon  $(X_1, Y_1), \dots, (X_n, Y_n)$  est séparé deux :
  - 1 **un échantillon d'apprentissage**  $(X_1, Y_1), \dots, (X_\ell, Y_\ell)$  utilisé pour estimer la fonction de score (par exemple les paramètres du modèle logistique pour le score logistique).
  - 2 **un échantillon test**  $(X_{\ell+1}, Y_{\ell+1}), \dots, (X_n, Y_n)$  pour estimer la courbe ROC.

Une fois le score  $S$  estimé à l'aide de l'échantillon d'apprentissage, les paramètres de la courbe ROC sont estimés comme suit :

- 1 On calcule le score des individus de l'échantillon test.
- 2 On définit un nouvel échantillon  $(S(X_{\ell+1}), Y_1), \dots, (S(X_n), Y_n)$



- 3 Les paramètres de la courbes ROC


$$\begin{cases} x(s) = 1 - sp(s) = \mathbf{P}(S(X) > s | Y = 0) \\ y(s) = se(s) = \mathbf{P}(S(X) \geq s | Y = 1) \end{cases}$$

sont estimés par

$$\begin{cases} \hat{x}(s) = \frac{1}{\text{Card}\{j : Y_j = 0\}} \sum_{i: Y_i=0} \mathbf{1}_{S(X_i) > s} \\ \hat{y}(s) = \frac{1}{\text{Card}\{j : Y_j = 1\}} \sum_{i: Y_i=1} \mathbf{1}_{S(X_i) > s} \end{cases}$$

Une fois le score  $S$  estimé à l'aide de l'échantillon d'apprentissage, les paramètres de la courbe ROC sont estimés comme suit :

- 1 On calcule le score des individus de l'échantillon test.
- 2 On définit un **nouvel échantillon**  $(S(X_{\ell+1}), Y_1), \dots, (S(X_n), Y_n)$



- 3 Les paramètres de la courbes ROC


$$\begin{cases} x(s) = 1 - sp(s) = \mathbf{P}(S(X) > s | Y = 0) \\ y(s) = se(s) = \mathbf{P}(S(X) \geq s | Y = 1) \end{cases}$$

sont **estimés** par

$$\begin{cases} \hat{x}(s) = \frac{1}{\text{Card}\{j : Y_j = 0\}} \sum_{i: Y_i=0} \mathbf{1}_{S(X_i) > s} \\ \hat{y}(s) = \frac{1}{\text{Card}\{j : Y_j = 1\}} \sum_{i: Y_i=1} \mathbf{1}_{S(X_i) > s} \end{cases}$$

Une fois le score  $S$  estimé à l'aide de l'échantillon d'apprentissage, les paramètres de la courbe ROC sont estimés comme suit :

- 1 On calcule le score des individus de l'échantillon test.
- 2 On définit un **nouvel échantillon**  $(S(X_{\ell+1}), Y_1), \dots, (S(X_n), Y_n)$



- 3 Les paramètres de la courbes ROC


$$\begin{cases} x(s) = 1 - sp(s) = \mathbf{P}(S(X) > s | Y = 0) \\ y(s) = se(s) = \mathbf{P}(S(X) \geq s | Y = 1) \end{cases}$$

sont **estimés** par

$$\begin{cases} \hat{x}(s) = \frac{1}{\text{Card}\{j : Y_j = 0\}} \sum_{i: Y_i=0} \mathbf{1}_{S(X_i) > s} \\ \hat{y}(s) = \frac{1}{\text{Card}\{j : Y_j = 1\}} \sum_{i: Y_i=1} \mathbf{1}_{S(X_i) > s} \end{cases}$$

Une fois le score  $S$  estimé à l'aide de l'échantillon d'apprentissage, les paramètres de la courbe ROC sont estimés comme suit :

- 1 On calcule le score des individus de l'échantillon test.
- 2 On définit un **nouvel échantillon**  $(S(X_{\ell+1}), Y_1), \dots, (S(X_n), Y_n)$



- 3 Les paramètres de la courbes ROC

$$\begin{cases} x(s) = 1 - sp(s) = \mathbf{P}(S(X) > s | Y = 0) \\ y(s) = se(s) = \mathbf{P}(S(X) \geq s | Y = 1) \end{cases}$$

sont **estimés** par

$$\begin{cases} \hat{x}(s) = \frac{1}{\text{Card}\{j : Y_j = 0\}} \sum_{i: Y_i=0} \mathbf{1}_{S(X_i) > s} \\ \hat{y}(s) = \frac{1}{\text{Card}\{j : Y_j = 1\}} \sum_{i: Y_i=1} \mathbf{1}_{S(X_i) > s} \end{cases}$$

# Exemple

- On reprend l'exemple sur la maladie cardiovasculaire et on **compare les 3 modèles construits** (2 logistique et un arbre) à l'aide de la **courbe ROC**.
- On calcule d'abord le **score** des individus de **l'échantillon test**.

```
> score1 <- predict(modell1, newdata=dtest, type="response")
> score2 <- predict(modell2, newdata=dtest, type="response")
> score3 <- predict(arbre, newdata=dtest)
```

- On trace ensuite la **courbe roc** à l'aide de la fonction **roc** du package **pROC**.

```
> roc(dtest$chd, score1, plot=TRUE)
> roc(dtest$chd, score2, plot=TRUE, col="red", add=TRUE)
> roc(dtest$chd, score3, plot=TRUE, col="blue", add=TRUE)
> legend("bottomright", legend=c("logit1", "logit2", "arbre"),
        col=c("black", "red", "blue"), lty=1, lwd=2)
```

- On reprend l'exemple sur la maladie cardiovasculaire et on **compare les 3 modèles construits** (2 logistique et un arbre) à l'aide de la **courbe ROC**.
- On calcule d'abord le **score** des individus de **l'échantillon test**.

```
> score1 <- predict(model1, newdata=dtest, type="response")
> score2 <- predict(model2, newdata=dtest, type="response")
> score3 <- predict(arbre, newdata=dtest)
```

- On trace ensuite la **courbe roc** à l'aide de la fonction **roc** du package **pROC**.

```
> roc(dtest$chd, score1, plot=TRUE)
> roc(dtest$chd, score2, plot=TRUE, col="red", add=TRUE)
> roc(dtest$chd, score3, plot=TRUE, col="blue", add=TRUE)
> legend("bottomright", legend=c("logit1", "logit2", "arbre"),
        col=c("black", "red", "blue"), lty=1, lwd=2)
```


- On reprend l'exemple sur la maladie cardiovasculaire et on **compare les 3 modèles construits** (2 logistique et un arbre) à l'aide de la **courbe ROC**.
- On calcule d'abord le **score** des individus de **l'échantillon test**.

```
> score1 <- predict(modell1,newdata=dtest,type="response")
> score2 <- predict(modell2,newdata=dtest,type="response")
> score3 <- predict(arbre,newdata=dtest)
```

- On trace ensuite la **courbe roc** à l'aide de la fonction **roc** du package **pROC**.

```
> roc(dtest$chd,score1,plot=TRUE)
> roc(dtest$chd,score2,plot=TRUE,col="red",add=TRUE)
> roc(dtest$chd,score3,plot=TRUE,col="blue",add=TRUE)
> legend("bottomright",legend=c("logit1","logit2","arbre"),
        col=c("black","red","blue"),lty=1,lwd=2)
```


# Courbes ROC



## Conclusion

Pour le critère ROC, les modèles logistique sont plus performants que l'arbre de classification.

# Courbes ROC



## Conclusion

Pour le critère ROC, les modèles logistique sont plus performants que l'arbre de classification.

## Sélection de variables

- Dans la partie précédente, on a présenté des outils permettant de comparer des modèles **construits**.
- On se place dans un cadre différent : étant donné  $p$  variables explicatives  $X_1, \dots, X_p$ , on cherche une procédure automatique permettant de trouver le "meilleur" **sous-groupe de variables** à mettre dans le modèle logistique.

## Pourquoi ?

(Au moins) 2 raisons peuvent motiver cette démarche :

- 1 **Descriptif** : identifier les variables qui permettent d'**expliquer la cible**.
- 2 **Statistique** : la variance des estimateurs augmente avec le nombre de paramètres du modèle. Diminuer le nombre de variables permettra d'avoir des **estimateurs plus précis**.

- Dans la partie précédente, on a présenté des outils permettant de comparer des modèles **construits**.
- On se place dans un cadre différent : étant donné  $p$  variables explicatives  $X_1, \dots, X_p$ , on cherche une procédure automatique permettant de trouver le **"meilleur" sous-groupe de variables** à mettre dans le modèle logistique.

## Pourquoi ?

(Au moins) 2 raisons peuvent motiver cette démarche :

- 1 **Descriptif** : identifier les variables qui permettent d'**expliquer la cible**.
- 2 **Statistique** : la variance des estimateurs augmente avec le nombre de paramètres du modèle. Diminuer le nombre de variables permettra d'avoir des **estimateurs plus précis**.

- Dans la partie précédente, on a présenté des outils permettant de comparer des modèles **construits**.
- On se place dans un cadre différent : étant donné  $p$  variables explicatives  $X_1, \dots, X_p$ , on cherche une procédure automatique permettant de trouver le **"meilleur" sous-groupe de variables** à mettre dans le modèle logistique.

## Pourquoi ?

(Au moins) 2 raisons peuvent motiver cette démarche :

- 1 **Descriptif** : identifier les variables qui permettent d'**expliquer la cible**.
- 2 **Statistique** : la variance des estimateurs augmente avec le nombre de paramètres du modèle. Diminuer le nombre de variables permettra d'avoir des **estimateurs plus précis**.

- Dans la partie précédente, on a présenté des outils permettant de comparer des modèles **construits**.
- On se place dans un cadre différent : étant donné  $p$  variables explicatives  $X_1, \dots, X_p$ , on cherche une procédure automatique permettant de trouver le "**meilleur**" **sous-groupe de variables** à mettre dans le modèle logistique.

## Pourquoi ?

(Au moins) 2 raisons peuvent motiver cette démarche :

- ➊ **Descriptif** : identifier les variables qui permettent d'**expliquer la cible**.
- ➋ **Statistique** : la variance des estimateurs augmente avec le nombre de paramètres du modèle. Diminuer le nombre de variables permettra d'avoir des **estimateurs plus précis**.

# Recherche exhaustive

- Une approche naturelle est de construire **tous** les modèles logistiques ( $2^p$ ) et de retenir celui qui **optimise un critère donné** (AIC-BIC...).
- Les package leaps permet de faire cela pour la **régression linéaire**.
- Pour le **modèle logistique**, on peut utiliser le package bestglm.

```
> library(bestglm)
> model4 <- bestglm(dapp,family=binomial,IC="BIC")
Morgan-Tatar search since family is non-gaussian.
> model4$BestModel
```

```
Call: glm(formula = y ~ ., family = family, data = Xi, weights = weights)
```

```
Coefficients:
```

(Intercept)	ldl	famhistPresent	age
-4.29645	0.18650	0.82172	0.05088

```
Degrees of Freedom: 249 Total (i.e. Null); 246 Residual
```

```
Null Deviance: 319.2
```

```
Residual Deviance: 267.5 AIC: 275.5
```

# Recherche exhaustive

- Une approche naturelle est de construire **tous** les modèles logistiques ( $2^p$ ) et de retenir celui qui **optimise un critère donné** (AIC-BIC...).
- Les package leaps permet de faire cela pour la **régression linéaire**.
- Pour le **modèle logistique**, on peut utiliser le package bestglm.

```
> library(bestglm)
> model4 <- bestglm(dapp,family=binomial,IC="BIC")
Morgan-Tatar search since family is non-gaussian.
> model4$BestModel
```

```
Call: glm(formula = y ~ ., family = family, data = Xi, weights = weights)
```

```
Coefficients:
```

(Intercept)	ldl	famhistPresent	age
-4.29645	0.18650	0.82172	0.05088

```
Degrees of Freedom: 249 Total (i.e. Null); 246 Residual
```

```
Null Deviance: 319.2
```

```
Residual Deviance: 267.5 AIC: 275.5
```

# Recherche exhaustive

- Une approche naturelle est de construire **tous** les modèles logistiques ( $2^p$ ) et de retenir celui qui **optimise un critère donné** (AIC-BIC...).
- Les package leaps permet de faire cela pour la **régression linéaire**.
- Pour le **modèle logistique**, on peut utiliser le package bestglm.

```
> library(bestglm)
> model4 <- bestglm(dapp,family=binomial,IC="BIC")
Morgan-Tatar search since family is non-gaussian.
> model4$BestModel
```

```
Call: glm(formula = y ~ ., family = family, data = Xi, weights = weights)
```

```
Coefficients:
```

(Intercept)	ldl	famhistPresent	age
-4.29645	0.18650	0.82172	0.05088

```
Degrees of Freedom: 249 Total (i.e. Null); 246 Residual
```

```
Null Deviance: 319.2
```

```
Residual Deviance: 267.5 AIC: 275.5
```

# Recherche exhaustive

- Une approche naturelle est de construire **tous** les modèles logistiques ( $2^p$ ) et de retenir celui qui **optimise un critère donné** (AIC-BIC...).
- Les package leaps permet de faire cela pour la **régression linéaire**.
- Pour le **modèle logistique**, on peut utiliser le package bestglm.

```
> library(bestglm)
> model4 <- bestglm(dapp,family=binomial,IC="BIC")
Morgan-Tatar search since family is non-gaussian.
> model4$BestModel
```

```
Call: glm(formula = y ~ ., family = family, data = Xi, weights = weights)
```

```
Coefficients:
```

(Intercept)	ldl	famhistPresent	age
-4.29645	0.18650	0.82172	0.05088

```
Degrees of Freedom: 249 Total (i.e. Null); 246 Residual
```

```
Null Deviance: 319.2
```

```
Residual Deviance: 267.5 AIC: 275.5
```

- On peut également visualiser les **variables retenues dans les meilleurs modèles** pour le critère donné

```
> model4$BestModels
      sbp tobacco   ldl adiposity famhist typea obesity alcohol  age Criteri
1 FALSE  FALSE  TRUE   FALSE     TRUE FALSE  FALSE  FALSE TRUE  284.04
2 FALSE  FALSE  TRUE   FALSE     FALSE FALSE  FALSE  FALSE TRUE  286.05
3 FALSE   TRUE  TRUE   FALSE     TRUE FALSE  FALSE  FALSE TRUE  286.78
4 FALSE  FALSE FALSE   FALSE     TRUE FALSE  FALSE  FALSE TRUE  287.32
5 FALSE  FALSE  TRUE   FALSE     TRUE  TRUE  FALSE  FALSE TRUE  287.93
```

Lorsque le nombre de variables  $p$  est trop grand, balayer tous les modèles peut se révéler **très couteux en tant de calcul**. On a alors recours à des méthodes **pas à pas**.

L'approche consiste à :

- construire un **modèle initial**
- Ajouter (**forward**) ou supprimer (**backward**) la variable qui optimise un critère donné (**BIC** ou **AIC**) par exemple.
- Répéter le processus jusqu'à un **critère d'arrêt**.


L'approche consiste à :

- construire un **modèle initial**
- Ajouter (**forward**) ou supprimer (**backward**) la variable qui optimise un critère donné (**BIC** ou **AIC**) par exemple.
- Répéter le processus jusqu'à un **critère d'arrêt**.

L'approche consiste à :

- construire un **modèle initial**
- Ajouter (**forward**) ou supprimer (**backward**) la variable qui optimise un critère donné (**BIC** ou **AIC**) par exemple.
- Répéter le processus jusqu'à un **critère d'arrêt**.

# Technique ascendante utilisant l'AIC



- La fonction **step** permet de sélectionner des variables à l'aide de méthodes **pas à pas**.

```
> model_complet <- glm(chd~.,data=dapp,family=binomial)
> model_step <- step(model_complet,direction="backward",k=log(nrow(dapp)))
> model_step
```

```
Call:  glm(formula = chd ~ ldl + famhist + age, family = binomial,
           data = dapp)
```

Coefficients:

(Intercept)	ldl	famhistPresent	age
-4.29645	0.18650	0.82172	0.05088

# Validation de modèles

- Poser un modèle revient à faire une **hypothèse** : la loi de la variable d'intérêt appartient à une **famille de loi donnée**.
- Pour le **modèle logistique** cette hypothèse est que la loi des  $Y_i$  est une Bernoulli de paramètre  $p_\beta(x_i)$  tel que

$$\text{logit } p_\beta(x_i) = \beta_1 x_{i1} + \dots + \beta_p x_{ip}.$$

- Les résultats présentés précédemment sont **vrais uniquement sous cette hypothèse**. Il faut par conséquent la vérifier.

Les techniques permettant (**dans une certaine mesure**) de vérifier cette hypothèse sont **similaires à celles du modèle de régression linéaire** (tests d'adéquation, étude des résidus...).

- Poser un modèle revient à faire une **hypothèse** : la loi de la variable d'intérêt appartient à une **famille de loi donnée**.
- Pour le **modèle logistique** cette hypothèse est que la loi des  $Y_i$  est une Bernoulli de paramètre  $p_\beta(x_i)$  tel que

$$\text{logit } p_\beta(x_i) = \beta_1 x_{i1} + \dots + \beta_p x_{ip}.$$

- Les résultats présentés précédemment sont **vrais uniquement sous cette hypothèse**. Il faut par conséquent la vérifier.

Les techniques permettant (dans une certaine mesure) de vérifier cette hypothèse sont **similaires à celles du modèle de régression linéaire** (tests d'adéquation, étude des résidus...).

- Poser un modèle revient à faire une **hypothèse** : la loi de la variable d'intérêt appartient à une **famille de loi donnée**.
- Pour le **modèle logistique** cette hypothèse est que la loi des  $Y_i$  est une Bernoulli de paramètre  $p_\beta(x_i)$  tel que

$$\text{logit } p_\beta(x_i) = \beta_1 x_{i1} + \dots + \beta_p x_{ip}.$$

- Les résultats présentés précédemment sont **vrais uniquement sous cette hypothèse**. Il faut par conséquent la vérifier.

Les techniques permettant (**dans une certaine mesure**) de vérifier cette hypothèse sont **similaires à celles du modèle de régression linéaire** (tests d'adéquation, étude des résidus...).

## Test d'adéquation de la déviance

- **Idée** : se baser sur la **vraisemblance**. En effet, plus la vraisemblance est proche de 1, plus le modèle est "proche" des données.
- La valeur d'une vraisemblance est difficile à interpréter (elle dépend notamment du nombre de données).
- La **déviance** permet de comparer la vraisemblance du modèle à celle d'un modèle parfait en terme d'adequation aux données : **le modèle saturé**.

- **Idée** : se baser sur la **vraisemblance**. En effet, plus la vraisemblance est proche de 1, plus le modèle est "proche" des données.
- La valeur d'une vraisemblance est difficile à interpréter (elle dépend notamment du nombre de données).
- La **déviance** permet de comparer la vraisemblance du modèle à celle d'un modèle parfait en terme d'adequation aux données : **le modèle saturé**.

- **Idée** : se baser sur la **vraisemblance**. En effet, plus la vraisemblance est proche de 1, plus le modèle est "proche" des données.
- La valeur d'une vraisemblance est difficile à interpréter (elle dépend notamment du nombre de données).
- La **déviance** permet de comparer la vraisemblance du modèle à celle d'un modèle parfait en terme d'adequation aux données : **le modèle saturé**.

# Le modèle saturé

- C'est le modèle qui ajuste **"parfaitement"** les observations. Il faut dissocier les types de données pour le définir.

## Données individuelles

On note  $(x_1, Y_1), \dots, (x_n, Y_n)$  l'échantillon (tous les  $x_i$  sont différents). Le modèle saturé modélise la loi des  $Y_i$  par des Bernoulli de paramètre  $p_{sat}(x_i)$  estimés selon  $\hat{p}_{sat}(x_i) = Y_i$ .

## Données répétées

On note  $(x_1, n_1, Y_1), \dots, (x_T, n_T, Y_T)$  l'échantillon. Le modèle saturé modélise la loi des  $Y_t$  par des Binomiale de paramètres  $(n_t, p_{sat}(x_t))$  avec  $\hat{p}_{sat}(x_t) = Y_t/n_t$ .

# Le modèle saturé

- C'est le modèle qui ajuste "parfaitement" les observations. Il faut dissocier les types de données pour le définir.

## Données individuelles

On note  $(x_1, Y_1), \dots, (x_n, Y_n)$  l'échantillon (tous les  $x_i$  sont différents). Le modèle saturé modélise la loi des  $Y_i$  par des Bernoulli de paramètre  $p_{sat}(x_i)$  estimés selon  $\hat{p}_{sat}(x_i) = Y_i$ .

## Données répétées

On note  $(x_1, n_1, Y_1), \dots, (x_T, n_T, Y_T)$  l'échantillon. Le modèle saturé modélise la loi des  $Y_t$  par des Binomiale de paramètres  $(n_t, p_{sat}(x_t))$  avec  $\hat{p}_{sat}(x_t) = Y_t/n_t$ .

- On désigne par  $\mathcal{L}_{sat}$  la log-vraisemblance du modèle saturé calculé au point défini par les  $\hat{p}_{sat}(x_i)$ .

## Propriété

- Dans le cas de **données individuelles**,  $\mathcal{L}_{sat} = 0$ .
- Pour des **données répétées**, on a

$$\mathcal{L}_{sat} = \sum_{t=1}^T \log \binom{n_t}{y_t} + \sum_{t=1}^T y_t \log \hat{p}_{sat}(x_t) + (n_t - y_t) \log(1 - \hat{p}_{sat}(x_t)).$$

## Remarque

- En terme d'**ajustement**, on ne peut pas faire mieux que le modèle saturé.
- Néanmoins, ce modèle n'est généralement pas bon : il est **sur-paramétré** (il contient autant de paramètres que de points d'observations), d'où son nom.

- On désigne par  $\mathcal{L}_{sat}$  la log-vraisemblance du modèle saturé calculé au point défini par les  $\hat{p}_{sat}(x_i)$ .

## Propriété

- Dans le cas de **données individuelles**,  $\mathcal{L}_{sat} = 0$ .
- Pour des **données répétées**, on a

$$\mathcal{L}_{sat} = \sum_{t=1}^T \log \binom{n_t}{y_t} + \sum_{t=1}^T y_t \log \hat{p}_{sat}(x_t) + (n_t - y_t) \log(1 - \hat{p}_{sat}(x_t)).$$

## Remarque

- En terme d'**ajustement**, on ne peut pas faire mieux que le modèle saturé.
- Néanmoins, ce modèle n'est généralement pas bon : il est **sur-paramétré** (il contient autant de paramètres que de points d'observations), d'où son nom.

- On désigne par  $\mathcal{L}_{sat}$  la log-vraisemblance du modèle saturé calculé au point défini par les  $\hat{p}_{sat}(x_i)$ .

## Propriété

- Dans le cas de **données individuelles**,  $\mathcal{L}_{sat} = 0$ .
- Pour des **données répétées**, on a

$$\mathcal{L}_{sat} = \sum_{t=1}^T \log \binom{n_t}{y_t} + \sum_{t=1}^T y_t \log \hat{p}_{sat}(x_t) + (n_t - y_t) \log(1 - \hat{p}_{sat}(x_t)).$$

## Remarque

- En terme d'**ajustement**, on ne peut pas faire mieux que le modèle saturé.
- Néanmoins, ce modèle n'est généralement pas bon : il est **sur-paramétré** (il contient autant de paramètres que de points d'observations), d'où son nom.

- On désigne par  $\mathcal{L}_{sat}$  la log-vraisemblance du modèle saturé calculé au point défini par les  $\hat{p}_{sat}(x_i)$ .

## Propriété

- Dans le cas de **données individuelles**,  $\mathcal{L}_{sat} = 0$ .
- Pour des **données répétées**, on a

$$\mathcal{L}_{sat} = \sum_{t=1}^T \log \binom{n_t}{y_t} + \sum_{t=1}^T y_t \log \hat{p}_{sat}(x_t) + (n_t - y_t) \log(1 - \hat{p}_{sat}(x_t)).$$

## Remarque

- En terme d'**ajustement**, on ne peut pas faire mieux que le modèle saturé.
- Néanmoins, ce modèle n'est généralement pas bon : il est **sur-paramétré** (il contient autant de paramètres que de points d'observations), d'où son nom.

- On note  $\mathcal{M}$  un modèle logistique,  $\hat{\beta}_n$  l'emv des paramètres et  $\mathcal{L}_n$  la log-vraisemblance de ce modèle.

## Définition

La déviance de  $\mathcal{M}$  est définie par

$$D_{\mathcal{M}} = 2(\mathcal{L}_{sat} - \mathcal{L}_n(\hat{\beta}_n)).$$

- La déviance est positive  $D_{\mathcal{M}} \geq 0$ .
- Plus la déviance est faible, meilleur est le modèle en terme d'ajustement.

- On note  $\mathcal{M}$  un modèle logistique,  $\hat{\beta}_n$  l'emv des paramètres et  $\mathcal{L}_n$  la log-vraisemblance de ce modèle.

## Définition

La déviance de  $\mathcal{M}$  est définie par

$$D_{\mathcal{M}} = 2(\mathcal{L}_{sat} - \mathcal{L}_n(\hat{\beta}_n)).$$

- La déviance est positive  $D_{\mathcal{M}} \geq 0$ .
- Plus la déviance est faible, meilleur est le modèle en terme d'ajustement.

# Illustration

- On reprend le jeu de données sur le "role des femmes" dans la société (données répétées).
- La déviance est présente dans les sorties de la fonction **glm** :

```
> modell <- glm(cbind(agree, disagree) ~ sex + education, data=womensrole, family=binomial)
> modell
```

```
Call:  glm(formula = cbind(agree, disagree) ~ sex + education,
          family = binomial, data = womensrole)
```

Coefficients:

(Intercept)	sexFemale	education
2.74796	-0.04349	-0.28970

Degrees of Freedom: 29 Total (i.e. Null); 27 Residual

Null Deviance: 398.9

**Residual Deviance: 36.89** AIC: 165.4

- On peut également la récupérer avec la fonction **deviance**

```
> deviance(modell)
[1] 36.89419
```

# Illustration

- On reprend le jeu de données sur le "role des femmes" dans la société (données répétées).
- La déviance est présente dans les sorties de la fonction **glm** :

```
> modell <- glm(cbind(agree, disagree) ~ sex + education, data=womensrole, family=binomial)
> modell
```

```
Call:  glm(formula = cbind(agree, disagree) ~ sex + education,
          family = binomial, data = womensrole)
```

Coefficients:

(Intercept)	sexFemale	education
2.74796	-0.04349	-0.28970

Degrees of Freedom: 29 Total (i.e. Null); 27 Residual

Null Deviance: 398.9

**Residual Deviance: 36.89** AIC: 165.4

- On peut également la récupérer avec la fonction **deviance**

```
> deviance(modell)
[1] 36.89419
```

# Le test d'adéquation de la déviance

- **Idée** : déviance faible  $\implies$  bonne adéquation.
- On pose  $H_0$  : "le modèle est adéquat" (les données sont bien générées selon le modèle logistique en question) contre  $H_1$  : "il ne l'est pas".

## Propriété

En présence de **données répétées**, la déviance suit une loi du  $\chi^2_{T-p}$  sous  $H_0$  lorsque  $n_t \rightarrow \infty, t = 1, \dots, T$ .

- **Conclusion** : on rejette  $H_0$  si  $D_{M,obs}$  est plus grande que le quantile d'ordre  $1 - \alpha$  de la loi  $\chi^2_{T-p}$ .
- Sur R, on calcule la **probabilité critique** avec

```
> 1-pchisq(modell$deviance,modell$df.resid)
[1] 0.09705949
```

# Le test d'adéquation de la déviance

- **Idée** : déviance faible  $\implies$  bonne adéquation.
- On pose  $H_0$  : "le modèle est adéquat" (les données sont bien générées selon le modèle logistique en question) contre  $H_1$  : "il ne l'est pas".

## Propriété

En présence de **données répétées**, la déviance suit une loi du  $\chi^2_{T-p}$  sous  $H_0$  lorsque  $n_t \rightarrow \infty, t = 1, \dots, T$ .

- **Conclusion** : on rejette  $H_0$  si  $D_{M,obs}$  est plus grande que le quantile d'ordre  $1 - \alpha$  de la loi  $\chi^2_{T-p}$ .
- Sur R, on calcule la **probabilité critique** avec

```
> 1-pchisq(modell$deviance,modell$df.resid)
[1] 0.09705949
```

# Le test d'adéquation de la déviance

- **Idée** : déviance faible  $\implies$  bonne adéquation.
- On pose  $H_0$  : "le modèle est adéquat" (les données sont bien générées selon le modèle logistique en question) contre  $H_1$  : "il ne l'est pas".

## Propriété

En présence de **données répétées**, la déviance suit une loi du  $\chi^2_{T-p}$  sous  $H_0$  lorsque  $n_t \rightarrow \infty, t = 1, \dots, T$ .

- **Conclusion** : on rejette  $H_0$  si  $D_{M,obs}$  est plus grande que le quantile d'ordre  $1 - \alpha$  de la loi  $\chi^2_{T-p}$ .
- Sur R, on calcule la **probabilité critique** avec

```
> 1-pchisq(modell$deviance,modell$df.resid)
[1] 0.09705949
```

# Le test d'adéquation de la déviance

- **Idée** : déviance faible  $\implies$  bonne adéquation.
- On pose  $H_0$  : "le modèle est adéquat" (les données sont bien générées selon le modèle logistique en question) contre  $H_1$  : "il ne l'est pas".

## Propriété

En présence de **données répétées**, la déviance suit une loi du  $\chi^2_{T-p}$  sous  $H_0$  lorsque  $n_t \rightarrow \infty, t = 1, \dots, T$ .

- **Conclusion** : on rejette  $H_0$  si  $D_{M,obs}$  est plus grande que le quantile d'ordre  $1 - \alpha$  de la loi  $\chi^2_{T-p}$ .
- Sur R, on calcule la **probabilité critique** avec

```
> 1-pchisq(modell$deviance,modell$df.resid)
[1] 0.09705949
```

# Le test d'adéquation de la déviance

- **Idée** : déviance faible  $\implies$  bonne adéquation.
- On pose  $H_0$  : "le modèle est adéquat" (les données sont bien générées selon le modèle logistique en question) contre  $H_1$  : "il ne l'est pas".

## Propriété

En présence de **données répétées**, la déviance suit une loi du  $\chi^2_{T-p}$  sous  $H_0$  lorsque  $n_t \rightarrow \infty, t = 1, \dots, T$ .

- **Conclusion** : on rejette  $H_0$  si  $D_{M,obs}$  est plus grande que le quantile d'ordre  $1 - \alpha$  de la loi  $\chi^2_{T-p}$ .
- Sur R, on calcule la **probabilité critique** avec

```
> 1-pchisq(modell$deviance,modell$df.resid)
[1] 0.09705949
```

# Le test d'adéquation de Pearson

- Permet de tester les mêmes hypothèses que précédemment et toujours pour des **données répétées**.
- La **statistique de test** est la suivante :

$$P = \sum_{t=1}^T \frac{(y_t - n_t p_{\hat{\beta}_n}(x_t))^2}{n_t p_{\hat{\beta}_n}(x_t) (1 - p_{\hat{\beta}_n}(x_t))}$$

## Propriété

En présence de **données répétées**,  $P$  suit une loi du  $\chi^2_{T-p}$  sous  $H_0$  en présence de données répétées lorsque  $n_t \rightarrow \infty, t = 1, \dots, T$ .

- **Conclusion** : on rejette  $H_0$  si  $P_{obs}$  est plus grande que le quantile d'ordre  $1 - \alpha$  de la loi  $\chi^2_{T-p}$ .
- Sur R, on calcule la **probabilité critique** avec

```
> P <- sum(residuals(modell, type="pearson")^2)
> 1-pchisq(P, nrow(womensrole) - length(modell$coef))
```

# Le test d'adéquation de Pearson

- Permet de tester les mêmes hypothèses que précédemment et toujours pour des **données répétées**.
- La **statistique de test** est la suivante :

$$P = \sum_{t=1}^T \frac{(y_t - n_t p_{\hat{\beta}_n}(x_t))^2}{n_t p_{\hat{\beta}_n}(x_t) (1 - p_{\hat{\beta}_n}(x_t))}$$

## Propriété

En présence de **données répétées**,  $P$  suit une loi du  $\chi^2_{T-p}$  sous  $H_0$  en présence de données répétées lorsque  $n_t \rightarrow \infty, t = 1, \dots, T$ .

- **Conclusion** : on rejette  $H_0$  si  $P_{obs}$  est plus grande que le quantile d'ordre  $1 - \alpha$  de la loi  $\chi^2_{T-p}$ .
- Sur R, on calcule la **probabilité critique** avec

```
> P <- sum(residuals(modell, type="pearson")^2)
> 1-pchisq(P, nrow(womensrole) - length(modell$coef))
```

# Le test d'adéquation de Pearson

- Permet de tester les mêmes hypothèses que précédemment et toujours pour des **données répétées**.
- La **statistique de test** est la suivante :

$$P = \sum_{t=1}^T \frac{(y_t - n_t p_{\hat{\beta}_n}(x_t))^2}{n_t p_{\hat{\beta}_n}(x_t) (1 - p_{\hat{\beta}_n}(x_t))}$$

## Propriété

En présence de **données répétées**,  $P$  suit une loi du  $\chi^2_{T-p}$  sous  $H_0$  en présence de données répétées lorsque  $n_t \rightarrow \infty, t = 1, \dots, T$ .

- **Conclusion** : on rejette  $H_0$  si  $P_{obs}$  est plus grande que le quantile d'ordre  $1 - \alpha$  de la loi  $\chi^2_{T-p}$ .
- Sur R, on calcule la **probabilité critique** avec

```
> P <- sum(residuals(modell, type="pearson")^2)
> 1-pchisq(P, nrow(womensrole) - length(modell$coef))
```

# Le test d'adéquation de Pearson

- Permet de tester les mêmes hypothèses que précédemment et toujours pour des **données répétées**.
- La **statistique de test** est la suivante :

$$P = \sum_{t=1}^T \frac{(y_t - n_t p_{\hat{\beta}_n}(x_t))^2}{n_t p_{\hat{\beta}_n}(x_t) (1 - p_{\hat{\beta}_n}(x_t))}$$

## Propriété

En présence de **données répétées**,  $P$  suit une loi du  $\chi^2_{T-p}$  sous  $H_0$  en présence de données répétées lorsque  $n_t \rightarrow \infty, t = 1, \dots, T$ .

- **Conclusion** : on rejette  $H_0$  si  $P_{obs}$  est plus grande que le quantile d'ordre  $1 - \alpha$  de la loi  $\chi^2_{T-p}$ .
- Sur R, on calcule la **probabilité critique** avec

```
> P <- sum(residuals(modell, type="pearson")^2)
> 1-pchisq(P, nrow(womensrole) - length(modell$coef))
```

# Le test d'adéquation de Pearson

- Permet de tester les mêmes hypothèses que précédemment et toujours pour des **données répétées**.
- La **statistique de test** est la suivante :

$$P = \sum_{t=1}^T \frac{(y_t - n_t p_{\hat{\beta}_n}(x_t))^2}{n_t p_{\hat{\beta}_n}(x_t) (1 - p_{\hat{\beta}_n}(x_t))}$$

## Propriété

En présence de **données répétées**,  $P$  suit une loi du  $\chi^2_{T-p}$  sous  $H_0$  en présence de données répétées lorsque  $n_t \rightarrow \infty, t = 1, \dots, T$ .

- **Conclusion** : on rejette  $H_0$  si  $P_{obs}$  est plus grande que le quantile d'ordre  $1 - \alpha$  de la loi  $\chi^2_{T-p}$ .
- Sur R, on calcule la **probabilité critique** avec

```
> P <- sum(residuals(modell, type="pearson")^2)
> 1-pchisq(P, nrow(womensrole) - length(modell$coef))
```

- Les deux tests d'adéquation sont **asymptotiques** et utilisables **uniquement dans le cas de données répétées**.
- Il faut par conséquent avoir **suffisamment d'observations en chaque points du design** pour pouvoir les appliquer.
- Le test de déviance est généralement privilégié.
- En présence de données individuelles, on utilise souvent le **test de Hosmer et Lemeshow** : l'approche consiste à **regrouper les données** et à définir une statistique de test de type Pearson.

- Les deux tests d'adéquation sont **asymptotiques** et utilisables **uniquement dans le cas de données répétées**.
- Il faut par conséquent avoir **suffisamment d'observations en chaque points du design** pour pouvoir les appliquer.
- Le test de déviance est généralement privilégié.
- En présence de données individuelles, on utilise souvent le **test de Hosmer et Lemeshow** : l'approche consiste à **regrouper les données** et à définir une statistique de test de type Pearson.

- Les deux tests d'adéquation sont **asymptotiques** et utilisables **uniquement dans le cas de données répétées**.
- Il faut par conséquent avoir **suffisamment d'observations en chaque points du design** pour pouvoir les appliquer.
- Le test de déviance est généralement privilégié.
- En présence de données individuelles, on utilise souvent le **test de Hosmer et Lemeshow** : l'approche consiste à **regrouper les données** et à définir une statistique de test de type Pearson.

- Les deux tests d'adéquation sont **asymptotiques** et utilisables **uniquement dans le cas de données répétées**.
- Il faut par conséquent avoir **suffisamment d'observations en chaque points du design** pour pouvoir les appliquer.
- Le test de déviance est généralement privilégié.
- En présence de données individuelles, on utilise souvent le **test de Hosmer et Lemeshow** : l'approche consiste à **regrouper les données** et à définir une statistique de test de type Pearson.

# Test d'Hosmer Lemeshow

On est en présence de données individuelles  $(x_1, Y_1), \dots, (x_n, Y_n)$ . La statistique de test se construit comme suit.

- 1 Les probabilités estimées  $p_{\hat{\beta}_n}(x_i)$  sont **ordonnées par ordre croissant**.
- 2 Ces probabilités ordonnées sont ensuite **séparées en  $K$  groupes** de taille égale (on prend souvent  $K = 10$  si  $n$  est suffisamment grand). On note
  - $m_k$  les effectifs du groupe  $k$  ;
  - $o_k$  le nombre de succès ( $Y = 1$ ) observé dans le groupe  $k$  ;
  - $\mu_k$  la moyenne des  $\hat{p}_{\beta}(x_i)$  dans le groupe  $k$ .

- La statistique de test est alors

$$C^2 = \sum_{k=1}^K \frac{(o_k - m_k \mu_k)^2}{m_k \mu_k (1 - \mu_k)}.$$

- Le test se conduit de manière identique au test de déviance, la statistique  $C^2$  suivant approximativement sous  $H_0$  un  $\chi_{K-2}^2$ .

# Test d'Hosmer Lemeshow

On est en présence de données individuelles  $(x_1, Y_1), \dots, (x_n, Y_n)$ . La statistique de test se construit comme suit.

- 1 Les probabilités estimées  $p_{\hat{\beta}_n}(x_i)$  sont **ordonnées par ordre croissant**.
- 2 Ces probabilités ordonnées sont ensuite **séparées en  $K$  groupes** de taille égale (on prend souvent  $K = 10$  si  $n$  est suffisamment grand). On note
  - $m_k$  les effectifs du groupe  $k$  ;
  - $o_k$  le nombre de succès ( $Y = 1$ ) observé dans le groupe  $k$  ;
  - $\mu_k$  la moyenne des  $\hat{p}_{\beta}(x_i)$  dans le groupe  $k$ .

- La statistique de test est alors

$$C^2 = \sum_{k=1}^K \frac{(o_k - m_k \mu_k)^2}{m_k \mu_k (1 - \mu_k)}.$$

- Le test se conduit de manière identique au test de déviance, la statistique  $C^2$  suivant approximativement sous  $H_0$  un  $\chi_{K-2}^2$ .

# Test d'Hosmer Lemeshow

On est en présence de données individuelles  $(x_1, Y_1), \dots, (x_n, Y_n)$ . La statistique de test se construit comme suit.

- 1 Les probabilités estimées  $p_{\hat{\beta}_n}(x_i)$  sont **ordonnées par ordre croissant**.
- 2 Ces probabilités ordonnées sont ensuite **séparées en  $K$  groupes** de taille égale (on prend souvent  $K = 10$  si  $n$  est suffisamment grand). On note
  - $m_k$  les effectifs du groupe  $k$  ;
  - $o_k$  le nombre de succès ( $Y = 1$ ) observé dans le groupe  $k$  ;
  - $\mu_k$  la moyenne des  $\hat{p}_{\beta}(x_i)$  dans le groupe  $k$ .

- La statistique de test est alors

$$C^2 = \sum_{k=1}^K \frac{(o_k - m_k \mu_k)^2}{m_k \mu_k (1 - \mu_k)}.$$

- Le test se conduit de manière identique au test de déviance, la statistique  $C^2$  suivant approximativement sous  $H_0$  un  $\chi_{K-2}^2$ .

# Test d'Hosmer Lemeshow

On est en présence de données individuelles  $(x_1, Y_1), \dots, (x_n, Y_n)$ . La statistique de test se construit comme suit.

- 1 Les probabilités estimées  $p_{\hat{\beta}_n}(x_i)$  sont **ordonnées par ordre croissant**.
- 2 Ces probabilités ordonnées sont ensuite **séparées en  $K$  groupes** de taille égale (on prend souvent  $K = 10$  si  $n$  est suffisamment grand). On note
  - $m_k$  les effectifs du groupe  $k$  ;
  - $o_k$  le nombre de succès ( $Y = 1$ ) observé dans le groupe  $k$  ;
  - $\mu_k$  la moyenne des  $\hat{p}_{\beta}(x_i)$  dans le groupe  $k$ .

- La statistique de test est alors

$$C^2 = \sum_{k=1}^K \frac{(o_k - m_k \mu_k)^2}{m_k \mu_k (1 - \mu_k)}.$$

- Le test se conduit de manière identique au test de déviance, la statistique  $C^2$  suivant approximativement sous  $H_0$  un  $\chi^2_{K-2}$ .

# Illustration sous R

- Sous R, on peut effectuer le test avec la fonction **HLgof.test** du package MKmisc.
- On teste le modèle sélectionné par la fonction **bestglm** sur l'exemple de la maladie cardiovasculaire :

```
> library(MKmisc)
> HLgof.test(fit=fitted(model4), obs=dapp$chd)
$C
```

Hosmer-Lemeshow C statistic

```
data: fitted(model4) and dapp$chd
X-squared = 3.9695, df = 8, p-value = 0.8599
```

```
$H
```

Hosmer-Lemeshow H statistic

```
data: fitted(model4) and dapp$chd
X-squared = 4.5285, df = 8, p-value = 0.8066
```

# Illustration sous R

- Sous R, on peut effectuer le test avec la fonction **HLgof.test** du package MKmisc.
- On **teste le modèle sélectionné** par la fonction **bestglm** sur l'exemple de la maladie cardiovasculaire :

```
> library(MKmisc)
> HLgof.test(fit=fitted(model4), obs=dapp$chd)
$C
```

Hosmer-Lemeshow C statistic

```
data: fitted(model4) and dapp$chd
X-squared = 3.9695, df = 8, p-value = 0.8599
```

```
$H
```

Hosmer-Lemeshow H statistic

```
data: fitted(model4) and dapp$chd
X-squared = 4.5285, df = 8, p-value = 0.8066
```

# Illustration sous R

- Sous R, on peut effectuer le test avec la fonction **HLgof.test** du package MKmisc.
- On teste le modèle sélectionné par la fonction **bestglm** sur l'exemple de la maladie cardiovasculaire :

```
> library(MKmisc)
> HLgof.test(fit=fitted(model4), obs=dapp$chd)
$C
```

Hosmer-Lemeshow C statistic

```
data: fitted(model4) and dapp$chd
X-squared = 3.9695, df = 8, p-value = 0.8599
```

```
$H
```

Hosmer-Lemeshow H statistic

```
data: fitted(model4) and dapp$chd
X-squared = 4.5285, df = 8, p-value = 0.8066
```

# Examen des résidus

- L'analyse des résidus permet, dans une certaine mesure, d'affiner un modèle.
- Elle permet de détecter des individus atypiques ou aberrants ou encore de détecter des effets non linéaires.
- On distingue plusieurs types de résidus que nous présentons dans le cas de données répétées.

- L'analyse des résidus permet, dans une certaine mesure, d'affiner un modèle.
- Elle permet de détecter des individus atypiques ou aberrants ou encore de détecter des effets non linéaires.
- On distingue plusieurs types de résidus que nous présentons dans le cas de données répétées.

- L'analyse des résidus permet, dans une certaine mesure, d'affiner un modèle.
- Elle permet de détecter des individus atypiques ou aberrants ou encore de détecter des effets non linéaires.
- On distingue plusieurs types de résidus que nous présentons dans le cas de données répétées.

# Les résidus de Pearson

On désigne par  $(x_t, n_t, Y_t)$ ,  $t = 1, \dots, T$  les données.

- Les résidus de Pearson sont définis par :

$$Rp_t = \frac{Y_t - n_t p_{\hat{\beta}_n}(x_t)}{\sqrt{n_t p_{\hat{\beta}_n}(x_t)(1 - p_{\hat{\beta}_n}(x_t))}}.$$

- Lorsque  $n_t$  est grand, la loi de  $Rp_t$  est proche d'une  $\mathcal{N}(0, 1)$ . On peut ainsi analyser les résidus de Pearson de la même manière que les résidus du modèle linéaire Gaussien.
- La statistique de Pearson s'exprime en fonction des résidus de Pearson  $P = \sum_{t=1}^T Rp_t^2$ .

# Les résidus de Pearson

On désigne par  $(x_t, n_t, Y_t)$ ,  $t = 1, \dots, T$  les données.

- Les résidus de Pearson sont définis par :

$$Rp_t = \frac{Y_t - n_t p_{\hat{\beta}_n}(x_t)}{\sqrt{n_t p_{\hat{\beta}_n}(x_t) (1 - p_{\hat{\beta}_n}(x_t))}}.$$

- Lorsque  $n_t$  est grand, la loi de  $Rp_t$  est proche d'une  $\mathcal{N}(0, 1)$ . On peut ainsi analyser les résidus de Pearson de la même manière que les résidus du modèle linéaire Gaussien.
- La statistique de Pearson s'exprime en fonction des résidus de Pearson  $P = \sum_{t=1}^T Rp_t^2$ .

# Les résidus de Pearson

On désigne par  $(x_t, n_t, Y_t)$ ,  $t = 1, \dots, T$  les données.

- Les résidus de Pearson sont définis par :

$$Rp_t = \frac{Y_t - n_t p_{\hat{\beta}_n}(x_t)}{\sqrt{n_t p_{\hat{\beta}_n}(x_t) (1 - p_{\hat{\beta}_n}(x_t))}}.$$

- Lorsque  $n_t$  est grand, la loi de  $Rp_t$  est proche d'une  $\mathcal{N}(0, 1)$ . On peut ainsi analyser les résidus de Pearson de la même manière que les résidus du modèle linéaire Gaussien.
- La statistique de Pearson s'exprime en fonction des résidus de Pearson  $P = \sum_{t=1}^T Rp_t^2$ .

# Version standardisée

- Les résidus de Pearson définis précédemment ne sont **pas de variance 1**.
- Il est souvent préférable d'utiliser une **version standardisée** de ces résidus. Pour ce faire, on remarque que

$$\mathbf{V}[Y_t - n p_{\hat{\beta}_n}(x_t)] \approx n_t p_{\beta}(x_t)(1 - p_{\beta}(x_t))(1 - h_t),$$

où  $h_t$  est le terme élément de la diagonale de

$$\mathbf{H} = \mathbf{X}(\mathbf{X}' \mathbf{W}_{\hat{\beta}_n} \mathbf{X})^{-1} \mathbf{X}' \mathbf{W}_{\hat{\beta}_n}.$$

## Définition

Les **résidus de Pearson standardisés** sont définis par

$$R_{ps_t} = \frac{Y_t - n_t p_{\hat{\beta}_n}(x_t)}{\sqrt{n_t p_{\hat{\beta}_n}(x_t)(1 - p_{\hat{\beta}_n}(x_t))(1 - h_t)}}, t = 1, \dots, T.$$

# Version standardisée

- Les résidus de Pearson définis précédemment ne sont **pas de variance 1**.
- Il est souvent préférable d'utiliser une **version standardisée** de ces résidus. Pour ce faire, on remarque que

$$\mathbf{V}[Y_t - n p_{\hat{\beta}_n}(x_t)] \approx n_t p_{\beta}(x_t)(1 - p_{\beta}(x_t))(1 - h_t),$$

où  $h_t$  est le terme élément de la diagonale de

$$\mathbf{H} = \mathbf{X}(\mathbf{X}' \mathbf{W}_{\hat{\beta}_n} \mathbf{X})^{-1} \mathbf{X}' \mathbf{W}_{\hat{\beta}_n}.$$

## Définition

Les **résidus de Pearson standardisés** sont définis par

$$R_{ps_t} = \frac{Y_t - n_t p_{\hat{\beta}_n}(x_t)}{\sqrt{n_t p_{\hat{\beta}_n}(x_t)(1 - p_{\hat{\beta}_n}(x_t))(1 - h_t)}}, t = 1, \dots, T.$$

# Version standardisée

- Les résidus de Pearson définis précédemment ne sont **pas de variance 1**.
- Il est souvent préférable d'utiliser une **version standardisée** de ces résidus. Pour ce faire, on remarque que

$$\mathbf{V}[Y_t - np_{\hat{\beta}_n}(x_t)] \approx n_t p_{\beta}(x_t)(1 - p_{\beta}(x_t))(1 - h_t),$$

où  $h_t$  est le terme élément de la diagonale de

$$\mathbf{H} = \mathbf{X}(\mathbf{X}' \mathbf{W}_{\hat{\beta}_n} \mathbf{X})^{-1} \mathbf{X}' \mathbf{W}_{\hat{\beta}_n}.$$

## Définition

Les **résidus de Pearson standardisés** sont définis par

$$Rps_t = \frac{Y_t - n_t p_{\hat{\beta}_n}(x_t)}{\sqrt{n_t p_{\hat{\beta}_n}(x_t)(1 - p_{\hat{\beta}_n}(x_t))(1 - h_t)}}, t = 1, \dots, T.$$

# Résidus de déviance

- Les **résidus de déviance** sont définis par

$$Rd_t = \sqrt{2 \left[ y_t \log \frac{\bar{Y}_t}{p_{\hat{\beta}_n}(x_t)} + (n_t - Y_t) \log \frac{n_t - Y_t}{n_t - n_t p_{\hat{\beta}_n}(x_t)} \right]}.$$

- Lorsque  $n_t$  est grand, la loi de  $Rd_t$  est proche d'une  $\mathcal{N}(0, 1)$ . On peut ainsi analyser les résidus de déviance de la même manière que les résidus du modèle linéaire Gaussien.
- La **déviance** s'exprime en fonction des résidus de déviance  $D = \sum_{t=1}^T Rd_t^2$ .

- Là encore, il existe une version standardisée :

$$Rds_t = \frac{Rd_t}{\sqrt{1 - h_t}}, \quad t = 1, \dots, T.$$

# Résidus de déviance

- Les **résidus de déviance** sont définis par

$$Rd_t = \sqrt{2 \left[ y_t \log \frac{\bar{Y}_t}{p_{\hat{\beta}_n}(x_t)} + (n_t - Y_t) \log \frac{n_t - Y_t}{n_t - n_t p_{\hat{\beta}_n}(x_t)} \right]}.$$

- Lorsque  $n_t$  est grand, la loi de  $Rd_t$  est proche d'une  $\mathcal{N}(0, 1)$ . On peut ainsi analyser les résidus de déviance de la même manière que les résidus du modèle linéaire Gaussien.
- La **déviance** s'exprime en fonction des résidus de déviance  
 $D = \sum_{t=1}^T Rd_t^2$ .

- Là encore, il existe une version standardisée :

$$Rds_t = \frac{Rd_t}{\sqrt{1 - h_t}}, \quad t = 1, \dots, T.$$

# Résidus de déviance

- Les **résidus de déviance** sont définis par

$$Rd_t = \sqrt{2 \left[ y_t \log \frac{\bar{Y}_t}{p_{\hat{\beta}_n}(x_t)} + (n_t - Y_t) \log \frac{n_t - Y_t}{n_t - n_t p_{\hat{\beta}_n}(x_t)} \right]}.$$

- Lorsque  $n_t$  est grand, la loi de  $Rd_t$  est proche d'une  $\mathcal{N}(0, 1)$ . On peut ainsi analyser les résidus de déviance de la même manière que les résidus du modèle linéaire Gaussien.
- La **déviance** s'exprime en fonction des résidus de déviance  $D = \sum_{t=1}^T Rd_t^2$ .

- Là encore, il existe une version standardisée :

$$Rds_t = \frac{Rd_t}{\sqrt{1 - h_t}}, \quad t = 1, \dots, T.$$

# Résidus de déviance

- Les **résidus de déviance** sont définis par

$$Rd_t = \sqrt{2 \left[ y_t \log \frac{\bar{Y}_t}{p_{\hat{\beta}_n}(x_t)} + (n_t - Y_t) \log \frac{n_t - Y_t}{n_t - n_t p_{\hat{\beta}_n}(x_t)} \right]}.$$

- Lorsque  $n_t$  est grand, la loi de  $Rd_t$  est proche d'une  $\mathcal{N}(0, 1)$ . On peut ainsi analyser les résidus de déviance de la même manière que les résidus du modèle linéaire Gaussien.
- La **déviance** s'exprime en fonction des résidus de déviance  $D = \sum_{t=1}^T Rd_t^2$ .

- Là encore, il existe une version standardisée :

$$Rds_t = \frac{Rd_t}{\sqrt{1 - h_t}}, \quad t = 1, \dots, T.$$

# Examen des résidus

- Les diagnostics sont essentiellement **graphiques** :
  - ① **Index plot** : numéro de l'observation en abscisse, valeur du résidu en ordonnée.
  - ② **Prédiction/résidus** : probabilité prédite au point  $x_t$  en abscisse et résidu en ordonnée.
- On pourra identifier :
  - ① Les valeurs **élevées de résidus** (individus atypiques...)
  - ② **Structures sur le nuage des résidus** (si c'est le cas il faudra envisager de modifier la combinaison linéaire des variables explicatives)

## Remarque importante

- Les résultats énoncés sur les résidus (Pearson ou déviance) sont vraies lorsque  $n_t$  est grand...
- Dans le cas de données individuelles, on observera (quasi)-systématiquement des structurations sur les nuages de résidus.

# Examen des résidus

- Les diagnostics sont essentiellement **graphiques** :
  - 1 **Index plot** : numéro de l'observation en abscisse, valeur du résidu en ordonnée.
  - 2 **Prédiction/résidus** : probabilité prédite au point  $x_t$  en abscisse et résidu en ordonnée.
- On pourra identifier :
  - 1 Les valeurs **élevées de résidus** (individus atypiques...)
  - 2 **Structures sur le nuage des résidus** (si c'est le cas il faudra envisager de modifier la combinaison linéaire des variables explicatives)

## Remarque importante

- Les résultats énoncés sur les résidus (Pearson ou déviance) sont vraies lorsque  $n_t$  est grand...
- Dans le cas de données individuelles, on observera (quasi)-systématiquement des structurations sur les nuages de résidus.

# Examen des résidus

- Les diagnostics sont essentiellement **graphiques** :
  - 1 **Index plot** : numéro de l'observation en abscisse, valeur du résidu en ordonnée.
  - 2 **Prédiction/résidus** : probabilité prédite au point  $x_t$  en abscisse et résidu en ordonnée.
- On pourra identifier :
  - 1 Les valeurs **élevées de résidus** (individus atypiques...)
  - 2 **Structures sur le nuage des résidus** (si c'est le cas il faudra envisager de modifier la combinaison linéaire des variables explicatives)

## Remarque importante

- Les résultats énoncés sur les résidus (Pearson ou déviance) sont vraies lorsque  $n_t$  est grand...
- Dans le cas de données individuelles, on observera (quasi)-systématiquement des structurations sur les nuages de résidus.

# Examen des résidus

- Les diagnostics sont essentiellement **graphiques** :
  - 1 **Index plot** : numéro de l'observation en abscisse, valeur du résidu en ordonnée.
  - 2 **Prédiction/résidus** : probabilité prédite au point  $x_t$  en abscisse et résidu en ordonnée.
- On pourra identifier :
  - 1 Les valeurs **élevées de résidus** (individus atypiques...)
  - 2 **Structures sur le nuage des résidus** (si c'est le cas il faudra envisager de modifier la combinaison linéaire des variables explicatives)

## Remarque importante

- Les résultats énoncés sur les résidus (Pearson ou déviance) sont vraies lorsque  $n_t$  est grand...
- Dans le cas de données individuelles, on observera (quasi)-systématiquement des structurations sur les nuages de résidus.

# Examen des résidus

- Les diagnostics sont essentiellement **graphiques** :
  - ① **Index plot** : numéro de l'observation en abscisse, valeur du résidu en ordonnée.
  - ② **Prédiction/résidus** : probabilité prédite au point  $x_t$  en abscisse et résidu en ordonnée.
- On pourra identifier :
  - ① Les valeurs **élevées de résidus** (individus atypiques...)
  - ② **Structures sur le nuage des résidus** (si c'est le cas il faudra envisager de modifier la combinaison linéaire des variables explicatives)

## Remarque importante

- Les résultats énoncés sur les résidus (Pearson ou déviance) sont vraies lorsque  $n_t$  est grand...
- Dans le cas de données individuelles, on observera **(quasi)-systématiquement des structurations sur les nuages de résidus.**

- On reprend les données **womensrole** et on considère le modèle logistique

```
> modell <- glm(cbind(agree, disagree) ~ sex + education, data=womensrole,
                family=binomi
```

- Les fonctions **residuals** et **rstandard** permettent de calculer les différents type des résidus ainsi que leur version standardisée.

```
> res1 <- residuals(modell, type="deviance") #résidus de déviance
> res2 <- rstandard(modell, type="deviance") #résidus de déviance stan
```

- On trace les graphes avec

```
> par(mfrow=c(1, 2))
> plot(res2, ylab="Residuals")
> abline(h=c(-2, 2))
> plot(predict(modell, type="r"), res2, xlab="Fitted values", ylab="Resid
> abline(h=c(-2, 2))
```

- On reprend les données **womensrole** et on considère le modèle logistique

```
> modell <- glm(cbind(agree, disagree) ~ sex + education, data=womensrole,
                family=binomi
```

- Les fonctions **residuals** et **rstandard** permettent de calculer les différents type des résidus ainsi que leur version standardisée.

```
> res1 <- residuals(modell, type="deviance") #résidus de déviance
> res2 <- rstandard(modell, type="deviance") #résidus de déviance stan
```

- On trace les graphes avec

```
> par(mfrow=c(1,2))
> plot(res2, ylab="Residuals")
> abline(h=c(-2,2))
> plot(predict(modell, type="r"), res2, xlab="Fitted values", ylab="Resid
> abline(h=c(-2,2))
```

- On reprend les données **womensrole** et on considère le modèle logistique

```
> modell <- glm(cbind(agree, disagree) ~ sex + education, data=womensrole,
                family=binomi
```



- Les fonctions **residuals** et **rstandard** permettent de calculer les différents type des résidus ainsi que leur version standardisée.

```
> res1 <- residuals(modell, type="deviance") #résidus de déviance
> res2 <- rstandard(modell, type="deviance") #résidus de déviance stan
```

- On trace les graphes avec

```
> par(mfrow=c(1,2))
> plot(res2, ylab="Residuals")
> abline(h=c(-2,2))
> plot(predict(modell, type="r"), res2, xlab="Fitted values", ylab="Resid
> abline(h=c(-2,2))
```

# Tracé des résidus



# Résidus Partiels

- On considère le modèle logistique

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \dots, \beta_p x_p.$$

- Les résidus partiels sont définis par :

$$r_{tj} = \frac{Y_t - n_t p_{\hat{\beta}_n}(x_t)}{n_t p_{\hat{\beta}_n}(x_t)(1 - p_{\hat{\beta}_n}(x_t))} + \hat{\beta}_j x_{tj}, \quad t = 1, \dots, T, j = 1 \dots p.$$

## Diagnostic

- L'analyse consiste à tracer pour **toutes les variables  $j$**  les  $T$  résidus  $r_{tj}, t = 1, \dots, T$ .
- Si le tracé est linéaire alors tout est "normal". Si par contre une **tendance non linéaire se dégage**, il faut remplacer la variable  $j$  par une fonction de celle ci donnant la même tendance que celle observée.

# Résidus Partiels

- On considère le modèle logistique

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \dots, \beta_p x_p.$$

- Les résidus partiels sont définis par :

$$r_{tj} = \frac{Y_t - n_t p_{\hat{\beta}_n}(x_t)}{n_t p_{\hat{\beta}_n}(x_t)(1 - p_{\hat{\beta}_n}(x_t))} + \hat{\beta}_j x_{tj}, \quad t = 1, \dots, T, j = 1 \dots p.$$

## Diagnostic

- L'analyse consiste à tracer pour toutes les variables  $j$  les  $T$  résidus  $r_{tj}, t = 1, \dots, T$ .
- Si le tracé est linéaire alors tout est "normal". Si par contre une tendance non linéaire se dégage, il faut remplacer la variable  $j$  par une fonction de celle ci donnant la même tendance que celle observée.

# Résidus Partiels

- On considère le modèle logistique

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \dots, \beta_p x_p.$$

- Les résidus partiels sont définis par :

$$r_{tj} = \frac{Y_t - n_t p_{\hat{\beta}_n}(x_t)}{n_t p_{\hat{\beta}_n}(x_t)(1 - p_{\hat{\beta}_n}(x_t))} + \hat{\beta}_j x_{tj}, \quad t = 1, \dots, T, j = 1 \dots p.$$

## Diagnostic

- L'analyse consiste à tracer pour **toutes les variables  $j$**  les  $T$  résidus  $r_{tj}, t = 1, \dots, T$ .
- Si le tracé est linéaire alors tout est "normal". Si par contre une **tendance non linéaire se dégage**, il faut remplacer la variable  $j$  par une fonction de celle ci donnant la même tendance que celle observée.

# Résidus Partiels

- On considère le modèle logistique

$$\text{logit } p_{\beta}(x) = \beta_1 x_1 + \dots, \beta_p x_p.$$

- Les résidus partiels sont définis par :

$$r_{tj} = \frac{Y_t - n_t p_{\hat{\beta}_n}(x_t)}{n_t p_{\hat{\beta}_n}(x_t) (1 - p_{\hat{\beta}_n}(x_t))} + \hat{\beta}_j x_{tj}, \quad t = 1, \dots, T, j = 1 \dots p.$$

## Diagnostic

- L'analyse consiste à tracer pour **toutes les variables  $j$**  les  $T$  résidus  $r_{tj}, t = 1, \dots, T$ .
- Si le tracé est linéaire alors tout est "normal". Si par contre une **tendance non linéaire se dégage**, il faut remplacer la variable  $j$  par une fonction de celle ci donnant la même tendance que celle observée.

- On considère le modèle logistique permettant d'expliquer `etat` par `marque` et `age` pour les données `panne`.

- La fonction `residuals` permet de calculer les **résidus partiels**

```
> model <- glm(etat~.,data=panne,family=binomial)
> residpartiel <- residuals(model,type="partial")
```

- On trace les résidus partiels pour la variable `age` avec :

```
> plot(panne$age, residpartiel[, "age"], cex=0.5)
> est <- loess(residpartiel[, "age"]~panne$age)
> ordre <- order(panne$age)
> matlines(panne$age[ordre], predict(est)[ordre])
> abline(lsfite(panne$age, residpartiel[, "age"]), lty=2)
```

- On considère le modèle logistique permettant d'expliquer `etat` par `marque` et `age` pour les données `panne`.
- La fonction **residuals** permet de calculer les **résidus partiels**

```
> model <- glm(etat~.,data=panne,family=binomial)
> residpartiel <- residuals(model,type="partial")
```

- On trace les résidus partiels pour la variable `age` avec :

```
> plot(panne$age, residpartiel[, "age"], cex=0.5)
> est <- loess(residpartiel[, "age"]~panne$age)
> ordre <- order(panne$age)
> matlines(panne$age[ordre], predict(est)[ordre])
> abline(lsfite(panne$age, residpartiel[, "age"]), lty=2)
```


- On considère le modèle logistique permettant d'expliquer `etat` par `marque` et `age` pour les données `panne`.
- La fonction **residuals** permet de calculer les **résidus partiels**

```
> model <- glm(etat~.,data=panne,family=binomial)
> residpartiel <- residuals(model,type="partial")
```

- On trace les résidus partiels pour la variable `age` avec :

```
> plot (panne$age, residpartiel[, "age"], cex=0.5)
> est <- loess (residpartiel[, "age"]~panne$age)
> ordre <- order (panne$age)
> matlines (panne$age[ordre], predict (est) [ordre])
> abline (lsfit (panne$age, residpartiel[, "age"]), lty=2)
```


# Tracé des résidus partiels



## Conclusion

Le graphe suggère d'ajouter la variable  $age^2$  dans le modèle.

# Tracé des résidus partiels



## Conclusion

Le graphe suggère d'ajouter la variable  $age^2$  dans le modèle.

## Points leviers et points influents

- Ce sont les points du design qui déterminent **fortement leur propre estimation**.
- L'analyse est **similaire à celle du modèle de régression linéaire**.

- On rappelle que l'emv  $\hat{\beta}_n$  s'écrit

$$\hat{\beta}_n = (\mathbb{X}' W_{\hat{\beta}} \mathbb{X})^{-1} \mathbb{X} W_{\hat{\beta}} Z.$$

- La prédiction linéaire des individus est donc donnée par

$$\mathbb{X} \hat{\beta}_n = \mathbb{X} (\mathbb{X}' W_{\hat{\beta}} \mathbb{X})^{-1} \mathbb{X} W_{\hat{\beta}} Z = HZ,$$

- Et celle de l'individu  $i$  par

$$[\mathbb{X} \hat{\beta}_n]_i = H_{ij} Z_i + \sum_{j \neq i} H_{ij} Z_j.$$

- Ce sont les points du design qui déterminent **fortement leur propre estimation**.
- L'analyse est **similaire à celle du modèle de régression linéaire**.

- On rappelle que l'emv  $\hat{\beta}_n$  s'écrit

$$\hat{\beta}_n = (\mathbb{X}' \mathbb{W}_{\hat{\beta}} \mathbb{X})^{-1} \mathbb{X} \mathbb{W}_{\hat{\beta}} \mathbb{Z}.$$

- La prédiction linéaire des individus est donc donnée par

$$\mathbb{X} \hat{\beta}_n = \mathbb{X} (\mathbb{X}' \mathbb{W}_{\hat{\beta}} \mathbb{X})^{-1} \mathbb{X} \mathbb{W}_{\hat{\beta}} \mathbb{Z} = \mathbb{H} \mathbb{Z},$$

- Et celle de l'individu  $i$  par

$$[\mathbb{X} \hat{\beta}_n]_i = H_{ii} Z_i + \sum_{j \neq i} H_{ij} Z_j.$$

- Ce sont les points du design qui déterminent **fortement leur propre estimation**.
- L'analyse est **similaire à celle du modèle de régression linéaire**.

- On rappelle que l'emv  $\hat{\beta}_n$  s'écrit

$$\hat{\beta}_n = (\mathbb{X}' \mathbb{W}_{\hat{\beta}} \mathbb{X})^{-1} \mathbb{X} \mathbb{W}_{\hat{\beta}} \mathbb{Z}.$$

- La prédiction linéaire des individus est donc donnée par

$$\mathbb{X} \hat{\beta}_n = \mathbb{X} (\mathbb{X}' \mathbb{W}_{\hat{\beta}} \mathbb{X})^{-1} \mathbb{X} \mathbb{W}_{\hat{\beta}} \mathbb{Z} = \mathbb{H} \mathbb{Z},$$

- Et celle de l'individu  $i$  par

$$[\mathbb{X} \hat{\beta}_n]_i = H_{ii} Z_i + \sum_{j \neq i} H_{ij} Z_j.$$

- Ce sont les points du design qui déterminent **fortement leur propre estimation**.
- L'analyse est **similaire à celle du modèle de régression linéaire**.

- On rappelle que l'emv  $\hat{\beta}_n$  s'écrit

$$\hat{\beta}_n = (\mathbb{X}' \mathbb{W}_{\hat{\beta}} \mathbb{X})^{-1} \mathbb{X} \mathbb{W}_{\hat{\beta}} \mathbb{Z}.$$

- La prédiction linéaire des individus est donc donnée par

$$\mathbb{X} \hat{\beta}_n = \mathbb{X} (\mathbb{X}' \mathbb{W}_{\hat{\beta}} \mathbb{X})^{-1} \mathbb{X} \mathbb{W}_{\hat{\beta}} \mathbb{Z} = \mathbb{H} \mathbb{Z},$$

- Et celle de l'individu  $i$  par

$$[\mathbb{X} \hat{\beta}_n]_i = H_{ii} Z_i + \sum_{j \neq i} H_{ij} Z_j.$$

- $H$  étant un projecteur, on a  $0 \leq H_{ij} \leq 1$ . Par conséquent
  - Si  $H_{ij} = 1$ , alors  $p_{\hat{\beta}_n}(x_i)$  est entièrement déterminé par la  $i$ ème observation.
  - Si  $H_{ij} = 0$ , la  $i$ ème observation n'influence pas  $p_{\hat{\beta}_n}(x_i)$ .

## Conclusion

- Pour mesurer l'influence d'une observation sur sa propre estimation, on représente le diagramme en batons des  $H_{ij}$ .
- On compare généralement la valeur des  $H_{ij}$  à  $2p/n$  ou  $3p/n$  pour déclarer les points comme **leviers**.

- $H$  étant un projecteur, on a  $0 \leq H_{ij} \leq 1$ . Par conséquent
  - Si  $H_{ij} = 1$ , alors  $p_{\hat{\beta}_n}(x_i)$  est entièrement déterminé par la  $i$ ème observation.
  - Si  $H_{ij} = 0$ , la  $i$ ème observation n'influence pas  $p_{\hat{\beta}_n}(x_i)$ .

## Conclusion

- Pour mesurer l'influence d'une observation sur sa propre estimation, on représente le diagramme en batons des  $H_{ij}$ .
- On compare généralement la valeur des  $H_{ij}$  à  $2p/n$  ou  $3p/n$  pour déclarer les points comme **leviers**.

- $H$  étant un projecteur, on a  $0 \leq H_{ij} \leq 1$ . Par conséquent
  - Si  $H_{ij} = 1$ , alors  $p_{\hat{\beta}_n}(x_i)$  est entièrement déterminé par la  $i$ ème observation.
  - Si  $H_{ij} = 0$ , la  $i$ ème observation n'influence pas  $p_{\hat{\beta}_n}(x_i)$ .

## Conclusion

- Pour mesurer l'influence d'une observation sur sa propre estimation, on représente le diagramme en batons des  $H_{ij}$ .
- On compare généralement la valeur des  $H_{ij}$  à  $2p/n$  ou  $3p/n$  pour déclarer les points comme leviers.

- $H$  étant un projecteur, on a  $0 \leq H_{ij} \leq 1$ . Par conséquent
  - Si  $H_{ij} = 1$ , alors  $p_{\hat{\beta}_n}(x_i)$  est entièrement déterminé par la  $i$ ème observation.
  - Si  $H_{ij} = 0$ , la  $i$ ème observation n'influence pas  $p_{\hat{\beta}_n}(x_i)$ .

## Conclusion

- Pour mesurer l'influence d'une observation sur sa propre estimation, on représente le diagramme en batons des  $H_{ij}$ .
- On compare généralement la valeur des  $H_{ij}$  à  $2p/n$  ou  $3p/n$  pour déclarer les points comme leviers.

- $H$  étant un projecteur, on a  $0 \leq H_{ij} \leq 1$ . Par conséquent
  - Si  $H_{ij} = 1$ , alors  $p_{\hat{\beta}_n}(x_i)$  est entièrement déterminé par la  $i$ ème observation.
  - Si  $H_{ij} = 0$ , la  $i$ ème observation n'influence pas  $p_{\hat{\beta}_n}(x_i)$ .


## Conclusion

- Pour mesurer l'influence d'une observation sur sa propre estimation, on représente le diagramme en batons des  $H_{ij}$ .
- On compare généralement la valeur des  $H_{ij}$  à  $2p/n$  ou  $3p/n$  pour déclarer les points comme **leviers**.

# Exemple

- On trace le diagramme en baton des  $H_{ij}$  pour le modèle construit sur les données **womensrole**.


```
> model <- glm(cbind(agree, disagree) ~ sex + education, data=womensrole,
               family=binomial)
> p <- length(model$coef)
> n <- nrow(panne)
> plot(influence(model)$hat, type="h", ylab="hii")
> abline(h=c(2*p/n, 3*p/n))
```



# Exemple

- On trace le diagramme en baton des  $H_{ij}$  pour le modèle construit sur les données **womensrole**.

```
> model <- glm(cbind(agree, disagree) ~ sex + education, data=womensrole,
               family=binomial)
> p <- length(model$coef)
> n <- nrow(panne)
> plot(influence(model)$hat, type="h", ylab="hii")
> abline(h=c(2*p/n, 3*p/n))
```



# Points influents

- Les **points influents** sont des points qui influent sur le modèle de telle sorte que si on les enlève, alors l'**estimation des coefficients sera fortement changée**.
- La mesure la plus classique d'influence est la **distance de Cook**. Il s'agit d'une distance entre le coefficient estimé avec **toutes les observations** et celui estimé avec toutes les observations sauf une.

## Définition

La distance de Cook pour l'individu  $i$  est définie par

$$DC_i = \frac{1}{p} (\hat{\beta}_{(i)} - \hat{\beta}_n)' \mathbf{X}' W_{\hat{\beta}} \mathbf{X} (\hat{\beta}_{(i)} - \hat{\beta}_n) \approx \frac{r_{Pi}^2 H_{ij}}{p(1 - H_{ij})^2},$$

où  $r_{Pi}$  est le résidu de Pearson pour le  $i$ ème individu et  $\hat{\beta}_{(i)}$  est l'emv calculé sans la  $i$ ème observation.

# Points influents

- Les **points influents** sont des points qui influent sur le modèle de telle sorte que si on les enlève, alors l'**estimation des coefficients sera fortement changée**.
- La mesure la plus classique d'influence est la **distance de Cook**. Il s'agit d'une distance entre le coefficient estimé avec **toutes les observations** et celui estimé avec toutes les observations sauf une.

## Définition

La distance de Cook pour l'individu  $i$  est définie par

$$DC_i = \frac{1}{p} (\hat{\beta}_{(i)} - \hat{\beta}_n)' \mathbf{X}' W_{\hat{\beta}} \mathbf{X} (\hat{\beta}_{(i)} - \hat{\beta}_n) \approx \frac{r_{Pi}^2 H_{ij}}{p(1 - H_{ij})^2},$$

où  $r_{Pi}$  est le résidu de Pearson pour le  $i$ ème individu et  $\hat{\beta}_{(i)}$  est l'emv calculé sans la  $i$ ème observation.

- Les **points influents** sont des points qui influent sur le modèle de telle sorte que si on les enlève, alors l'**estimation des coefficients sera fortement changée**.
- La mesure la plus classique d'influence est la **distance de Cook**. Il s'agit d'une distance entre le coefficient estimé avec **toutes les observations** et celui estimé avec toutes les observations sauf une.

## Définition

La distance de Cook pour l'individu  $i$  est définie par

$$DC_i = \frac{1}{p} (\hat{\beta}_{(i)} - \hat{\beta}_n)' \mathbb{X}' W_{\hat{\beta}} \mathbb{X} (\hat{\beta}_{(i)} - \hat{\beta}_n) \approx \frac{r_{Pi}^2 H_{ii}}{p(1 - H_{ii})^2},$$

où  $r_{Pi}$  est le résidu de Pearson pour le  $i$ ème individu et  $\hat{\beta}_{(i)}$  est l'emv calculé sans la  $i$ ème observation.

- Là encore, on représente la distance de Cook de chaque point du design à l'aide d'un **diagramme en batons**.
- Si une distance se révèle **grande par rapport aux autres**, alors ce point sera considéré comme **influent**. Il convient alors de comprendre pourquoi il est influent :
  - il est levier ;
  - il est aberrant ;
  - (les deux !)

Dans tous les cas il convient de **comprendre si une erreur de mesure, une différence dans la population des individus est à l'origine de ce phénomène**. Eventuellement pour obtenir des conclusions robustes il sera bon de **refaire l'analyse sans ce(s) point(s)**.

- Là encore, on représente la distance de Cook de chaque point du design à l'aide d'un **diagramme en batons**.
- Si une distance se révèle **grande par rapport aux autres**, alors ce point sera considéré comme **influent**. Il convient alors de comprendre pourquoi il est influent :
  - il est levier ;
  - il est aberrant ;
  - (les deux !)

Dans tous les cas il convient de **comprendre si une erreur de mesure, une différence dans la population des individus est à l'origine de ce phénomène**. Eventuellement pour obtenir des conclusions robustes il sera bon de **refaire l'analyse sans ce(s) point(s)**.

- Là encore, on représente la distance de Cook de chaque point du design à l'aide d'un **diagramme en batons**.
- Si une distance se révèle **grande par rapport aux autres**, alors ce point sera considéré comme **influent**. Il convient alors de comprendre pourquoi il est influent :
  - il est levier ;
  - il est aberrant ;
  - (les deux !)

Dans tous les cas il convient de **comprendre si une erreur de mesure, une différence dans la population des individus est à l'origine de ce phénomène**. Eventuellement pour obtenir des conclusions robustes il sera bon de **refaire l'analyse sans ce(s) point(s)**.


- Là encore, on représente la distance de Cook de chaque point du design à l'aide d'un **diagramme en batons**.
- Si une distance se révèle **grande par rapport aux autres**, alors ce point sera considéré comme **influent**. Il convient alors de comprendre pourquoi il est influent :
  - il est levier ;
  - il est aberrant ;
  - (les deux !)

Dans tous les cas il convient de **comprendre si une erreur de mesure, une différence dans la population des individus est à l'origine de ce phénomène**. Eventuellement pour obtenir des conclusions robustes il sera bon de **refaire l'analyse sans ce(s) point(s)**.

# Exemple

- La fonction **cooks.distance** permet de calculer les distances de Cook sur R :

```
> plot(cooks.distance(model), type="h", ylab="Distance de Cook")
```



# Exemple

- La fonction **cooks.distance** permet de calculer les distances de Cook sur R :

```
> plot(cooks.distance(model), type="h", ylab="Distance de Cook")
```

