

# Statistique Mathématique 2 (MATH-F-309, Chapitre #6)

Thomas Verdebout

Université Libre de Bruxelles

2015/2016

## Plan du cours

1. Vecteurs aléatoires.
2. Loi normale multivariée.
3. Inférence dans les modèles gaussiens.
4. Méthodes classiques de l'analyse multivariée.
5. Données directionnelles.
6. Modèle linéaire

## 6. Modèles linéaires.

### 6.1. Hypothèse de linéarité.

6.2. MLE.

6.3. Une approche par projection.

6.4. Théorie distributionnelle.

6.5. Inférence.

6.6. Analyse des résidus.

## L'hypothèse linéaire

### Définition

Soit  $Y$  un  $n$ -vecteur aléatoire avec  $EY = \mu$ . Un modèle linéaire de dimension  $k$  est une hypothèse pour  $\mu$  de la forme  $H_0 : \mu \in L$ , où  $L$  est un sous-espace linéaire de  $\mathbb{R}^n$  avec  $\dim(L) = k$ .

Pour une base donnée  $X = (x_1, \dots, x_k)$  de  $L$ , ceci veut donc dire que sous  $H_0$  il existe un vecteur de coefficients  $\beta = (\beta_1, \dots, \beta_k)'$  tel que

$$\mu = \sum_{i=1}^k \beta_i x_i = X\beta.$$

Autrement exprimé,

$$Y = X\beta + \varepsilon,$$

où  $E\varepsilon = 0$  (et assez souvent on suppose que  $\text{Var}(\varepsilon) = \sigma^2 I_n$ ).

## L'hypothèse linéaire

Il est à remarquer que d'après la manière dont ce modèle est défini, on ne l'attribue en général pas au domaine de l'analyse multivariée. La raison en est que  $Y = (Y_1, \dots, Y_n)'$  constitue notre échantillon (univarié).

Il existe aussi une version multivariée du modèle linéaire général. Alors les  $Y_i'$  sont des  $p$ -vecteurs aléatoires et nous avons une hypothèse de la forme

$$EY = M = XB,$$

où  $M \in \mathbb{R}^{n \times p}$ ,  $X \in \mathbb{R}^{n \times q}$  et  $B \in \mathbb{R}^{q \times p}$ .

## L'hypothèse linéaire

### Exemples.

- ▶ Les  $Y_i$  sont i.i.d. de moyenne  $\mu$ .

Alors  $X = (1, \dots, 1)'$  et  $\beta = \mu$ . L'estimation et l'inférence se réduisent à des procédures bien connues.

- ▶ La moyenne de  $Y_i$  dépend de plusieurs variables (connues) (*variables indépendantes, régresseurs*)  $x_1, \dots, x_k$  de façon linéaire:

$$Y_i = x_{1i}\beta_1 + x_{2i}\beta_2 + \dots + x_{ki}\beta_k + \varepsilon_i.$$

## L'hypothèse linéaire

*Principaux objectifs:*

- ▶ **Estimer** les paramètres inconnus  $\beta$  (ou  $\mu$  respectivement) et  $\sigma^2$  si  $\text{Var}(\varepsilon) = \sigma^2 I_n$ .
- ▶ Etablir la **distribution des paramètres** quand  $Y$  est un vecteur multivarié normal.
- ▶ **Tester** différentes hypothèses pour  $\beta$  (ou  $\mu$  respectivement). P.ex.  $\beta_\ell = 0$  v.s.  $\beta_\ell \neq 0$  ou  $\beta_1 = \beta_2 = \dots = \beta_k$  v.s. ils ne sont pas tous égaux ou  $\mu \in L_2$  v.s.  $\mu \in L_1 \setminus L_2$  ...
- ▶ **Vérifier** si le modèle est approprié.

## 6. Modèles linéaires.

6.1. Hypothèse de linéarité.

6.2. MLE.

6.3. Une approche par projection.

6.4. Théorie distributionnelle.

6.5. Inférence.

6.6. Analyse des résidus.



## MLE

Supposons que  $Y \sim \mathcal{N}_n(\mu, \sigma^2 I_n)$ . Alors la fonction de vraisemblance est donnée par

$$\begin{aligned}\ell(\mu, \sigma | Y) &= \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left( -\frac{1}{2\sigma^2} (Y - \mu)'(Y - \mu) \right) \\ &= \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left( -\frac{1}{2\sigma^2} \|Y - \mu\|^2 \right).\end{aligned}$$

Si le modèle linéaire tient pour  $Y \sim \mathcal{N}_n(X\beta, \sigma^2 I_n)$  alors le MLE pour  $(\beta, \sigma^2)$  équivaut à

$$(\hat{\beta}, \hat{\sigma}^2) = \operatorname{argmax}_{\beta, \sigma^2} \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left( -\frac{1}{2\sigma^2} \|Y - X\beta\|^2 \right).$$

Notons que

$$\begin{aligned}(\hat{\beta}, \hat{\sigma}^2) &= \operatorname{argmax}_{\beta, \sigma^2} \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left( -\frac{1}{2\sigma^2} \|Y - X\beta\|^2 \right) \\ &= \operatorname{argmin}_{\beta, \sigma^2} \left( \frac{n}{2} \log(\sigma^2) + \frac{1}{2\sigma^2} \|Y - X\beta\|^2 \right).\end{aligned}$$

Si nous fixons  $\sigma^2$  pour le moment, alors nous devons trouver

$$\hat{\beta} = \operatorname{argmin}_{\beta} \|Y - X\beta\|^2.$$

En posant  $\partial\|Y - X\beta\|^2/\partial\beta = 0$ , on obtient facilement (exercice) que

$$\hat{\beta} = (X'X)^{-1}X'Y.$$

## MLE

Afin d'obtenir  $\hat{\sigma}^2$  nous déterminons

$$\operatorname{argmin}_{s>0} \left( \frac{n \log(s)}{2} + \frac{1}{2s} \|Y - X\hat{\beta}\|^2 \right).$$

Des calculs directs (exercice) montrent que

$$\hat{\sigma}^2 = \frac{1}{n} \|Y - X\hat{\beta}\|^2.$$

## MLE

### Théorème

Supposons qu'on a un modèle linéaire de la forme  $Y \sim \mathcal{N}_n(X\beta, \sigma^2 I_n)$ . Alors le MLE est donné par

$$\hat{\beta} = (X'X)^{-1}X'Y \quad \text{et} \quad \hat{\sigma}^2 = \frac{1}{n} \|Y - X\hat{\beta}\|^2.$$

Le maximum de la vraisemblance est donné par

$$\left(\frac{1}{2\pi e}\right)^{n/2} (\hat{\sigma}^2)^{-n/2}.$$



*Remarque.* Les estimateurs

$$\hat{\beta} = (X'X)^{-1}X'Y \quad \text{et} \quad \hat{\sigma}^2 = \frac{1}{n} \|Y - X\hat{\beta}\|^2$$

ne sont pas sans intérêt quand  $Y$  n'est pas normalement distribué. L'estimateur  $\hat{\beta}$  est aussi appelé *estimateur des moindres carrés*.

Le vecteur  $\hat{\varepsilon} := Y - X\hat{\beta}$  est appelé *vecteur des résidus*. Nous notons

$$SSR = \|Y - X\hat{\beta}\|^2$$

la somme des carrés des résidus.

## 6. Modèles linéaires.

6.1. Hypothèse de linéarité.

6.2. MLE.

6.3. Une approche par projection.

6.4. Théorie distributionnelle.

6.5. Inférence.

6.6. Analyse des résidus.

## Une approche par projection

Une autre manière d'obtenir le MLE pour  $\beta$  consiste à écrire

$$\hat{\mu} = X\hat{\beta} = \operatorname{argmin}_{\mu \in L} \|Y - \mu\|,$$

où  $L$  est l'espace linéaire engendré par les vecteurs  $(x_1, \dots, x_k)$ . Par définition  $\hat{\mu} = p_L(Y)$ , la *projection* de  $Y$  sur  $L$ .

Notons que la projection  $p_L(Y)$  est caractérisée comme l'unique élément dans  $L$  tel que

$$\langle Y - p_L(Y), x \rangle = 0 \quad \text{pour tout } x \in L$$

$\Leftrightarrow$

$$\langle Y - p_L(Y), x_j \rangle = 0 \quad \text{pour tout } j \in \{1, \dots, k\}$$

$\Leftrightarrow$

$$X'(Y - p_L(Y)) = 0.$$

## Une approche par projection

Il est limpide que  $X(X'X)^{-1}X'Y \in L$  et on voit facilement que

$$X'(Y - X(X'X)^{-1}X'Y) = 0.$$

D'où nous avons que

$$\hat{\mu} = p_L(Y) = X(X'X)^{-1}X'Y = X\hat{\beta}.$$

La matrice

$$H = X(X'X)^{-1}X'$$

est appelée *matrice de projection* ou *matrice chapeau*. Elle est (exercice)

- ▶ symétrique:  $H = H'$ , et
- ▶ idempotente:  $H^2 = H$ .



## 6. Modèles linéaires.

6.1. Hypothèse de linéarité.

6.2. MLE.

6.3. Une approche par projection.

6.4. Théorie distributionnelle.

6.5. Inférence.

6.6. Analyse des résidus.

## Théorie distributionnelle

La proposition suivante tient sans hypothèse de normalité.

### Proposition

*Supposons que  $Y$  est un modèle linéaire de dimension  $k$  de la forme*

$$Y = \mu + \varepsilon = X\beta + \varepsilon \quad \varepsilon \sim (0, \sigma^2 I_n).$$

*Soient  $\hat{\mu}$ ,  $\hat{\beta}$  et  $\hat{\sigma}^2$  définis comme avant. Alors*

$$E\hat{\beta} = \beta \quad \text{et} \quad E\hat{\mu} = \mu;$$

$$\text{Var}(\hat{\beta}) = \sigma^2(X'X)^{-1} \quad \text{et} \quad \text{Var}(\hat{\mu}) = \sigma^2 H;$$

$$E\hat{\sigma}^2 = \frac{n-k}{n}\sigma^2.$$

## Théorie distributionnelle

*Preuve.* La moyenne et la variance de  $\hat{\beta}$  et  $\hat{\mu}$  sont simples. Nous allons calculer l'espérance de  $\hat{\sigma}^2$ . En ayant recours à  $H' = H$  et  $H^2 = H$ , nous obtenons que la même chose est vraie pour  $I_n - H$ . Notez aussi que  $H\mu = \mu$  et donc  $(I_n - H)\mu = 0$ . Par conséquent

$$\begin{aligned} E\hat{\sigma}^2 &= \frac{1}{n} E\|(I_n - H)Y\|^2 = \frac{1}{n} E\|(I_n - H)\varepsilon\|^2 \\ &= \frac{1}{n} E\text{tr}(\varepsilon'(I_n - H)'(I_n - H)\varepsilon) \\ &= \frac{1}{n} \text{tr}(E\varepsilon\varepsilon'(I_n - H)) = \frac{\sigma^2}{n} \text{tr}(I_n - H). \end{aligned}$$

La preuve suit alors du fait que  $\text{tr}(H) = \text{tr}(X(X'X)^{-1}X') = \text{tr}(X'X(X'X)^{-1}) = k$ .  $\square$

## Théorie distributionnelle

### Proposition

Supposons que  $Y$  est un modèle linéaire de dimension  $k$  de la forme

$$Y = \mu + \varepsilon = X\beta + \varepsilon \quad \varepsilon \sim \mathcal{N}_n(0, \sigma^2 I_n).$$

Soient  $\hat{\mu}$ ,  $\hat{\beta}$  et  $\hat{\sigma}^2$  définis comme avant. Alors

- (i)  $\hat{\beta} \sim \mathcal{N}_p(\beta, \sigma^2(X'X)^{-1})$ ;
- (ii)  $\hat{\mu} \sim \mathcal{N}_n(\mu, \sigma^2 H)$ ;
- (iii)  $\hat{\sigma}^2 \sim \frac{\sigma^2}{n} \chi_{n-k}^2$ ;
- (iv)  $\hat{\sigma}^2$  et  $\hat{\beta}$  (ou  $\hat{\mu}$ , respectivement) sont indépendants.

## Théorie distributionnelle

*Preuve de (i) et (ii).* Les vecteurs  $\hat{\beta}$  et  $\hat{\mu}$  sont des transformations linéaires du vecteur normal  $Y$ . Donc par les résultats du Chapitre 2,  $\hat{\beta}$  et  $\hat{\mu}$  sont de nouveau normalement distribués. Par la proposition ci-dessus, nous connaissons leur moyenne et variance appropriées. Nous obtenons (i) et (ii). □

Les relations (iii) et (iv) suivront des considérations ci-dessous.

## Théorie distributionnelle

*Sous-espaces orthogonaux.* Deux sous-espaces linéaires  $L_1$  et  $L_2$  de  $\mathbb{R}^n$  sont appelés orthogonaux si  $x \perp y$  pour tout  $x \in L_1$  et  $y \in L_2$ . Alors nous définissons

$$L_1 \oplus L_2 = \{x + y \mid x \in L_1 \text{ et } y \in L_2\}.$$

$$L_1 \ominus L_2 = \{x \in L_1 \mid x \perp L_2\} \quad (\text{en supposant que } L_2 \subset L_1).$$

### Lemme

*Supposons que  $L_2 \subset L_1$  sont des sous-espaces linéaires de  $\mathbb{R}^n$ . Alors*

- (i)  $L_1 \ominus L_2$  est une sous-espace linéaire;
- (ii)  $L_1 \ominus L_2 \perp L_2$ ;
- (iii)  $(L_1 \ominus L_2) \oplus L_2 = L_1$  ( $\implies L^\perp \oplus L = \mathbb{R}^n$ );
- (iv)  $p_{L^\perp}(v) = v - p_L(v)$ .

## Théorie distributionnelle

### Proposition

Soient  $L_1, L_2, \dots, L_r$  des sous-espaces orthogonaux de  $\mathbb{R}^n$  avec  $\dim(L_i) = k_i$  et  $L_1 \oplus L_2 \oplus \dots \oplus L_r = \mathbb{R}^n$  et soit  $\varepsilon \sim \mathcal{N}_n(0, \sigma^2 I_n)$ . Alors

(a)  $p_{L_1}(\varepsilon), \dots, p_{L_r}(\varepsilon)$  sont indépendants.

(b)  $\|p_{L_i}(\varepsilon)\|^2 \sim \sigma^2 \chi_{k_i}^2 \quad 1 \leq i \leq r.$

## Théorie distributionnelle

*Preuve de (a).* Comme  $L_1, L_2, \dots, L_r$  sont des sous-espaces orthogonaux de  $\mathbb{R}^n$  avec  $\dim(L_i) = k_i$  et  $L_1 \oplus L_2 \oplus \dots \oplus L_r = \mathbb{R}^n$ , nous avons une base orthonormale (BON)

$$\{e_{ij}, 1 \leq j \leq k_i, 1 \leq i \leq r\}$$

de  $\mathbb{R}^n$  tel que  $E_i = \{e_{ij}, 1 \leq j \leq k_i\}$  est une BON de  $L_i$ . Il s'ensuit de  $E_i' E_i = I_{k_i}$  que

$$p_{L_i}(\varepsilon) = E_i(E_i' E_i)^{-1} E_i' \varepsilon = E_i E_i' \varepsilon.$$

Donc, comme  $E_i' E_j = 0$  pour  $i \neq j$ , nous obtenons

$$\text{Cov}(p_{L_i}(\varepsilon), p_{L_j}(\varepsilon)) = E_i E_i' \text{Cov}(\varepsilon, \varepsilon) E_j E_j' = 0.$$



## Théorie distributionnelle

*Preuve de (b).* Nous déduisons par le théorème de Pythagore que

$$\begin{aligned}\|p_{L_i}(\varepsilon)\|^2 &= \left\| \sum_{j=1}^{k_i} \langle e_{ij}, \varepsilon \rangle e_{ij} \right\|^2 \\ &= \sum_{j=1}^{k_i} \langle e_{ij}, \varepsilon \rangle^2.\end{aligned}$$

Puisque les  $e_{ij}$  sont orthonormaux, il suit que les variables  $\langle e_{ij}, \varepsilon \rangle$  sont des variables aléatoires indépendantes de loi normale. Leur moyenne est 0 et la variance  $\sigma^2$ .  $\square$

## Théorie distributionnelle

*Preuve de (iii) et (iv) de la proposition précédente.* Rappelons que

$$\hat{\sigma}^2 = \frac{1}{n} \|Y - \hat{\mu}\|^2.$$

Nous rappelons que

$$\|Y - \hat{\mu}\|^2 = \|(I_n - H)\varepsilon\|^2.$$

Par le point (iv) du lemme précédent il découle que  $(I_n - H)v = p_{L^\perp}(v)$ , la projection de  $v$  sur l'espace

$$L^\perp = \{x \in \mathbb{R}^n \mid x \perp L = \text{span}(x_1, \dots, x_k)\}.$$

Comme  $\dim(L^\perp) = n - k$ , la preuve de (iii) suit du point (b) de la proposition précédente.

## Théorie distributionnelle

Comme

$$\hat{\mu} = HY = X\beta + H\varepsilon = X\beta + p_L(\varepsilon)$$

et

$$\hat{\sigma}^2 = \frac{1}{n} \|(I_n - H)\varepsilon\|^2 = \frac{1}{n} \|p_{L^\perp}(\varepsilon)\|^2,$$

nous concluons du point (a) de la proposition précédente que  $\hat{\mu}$  et  $\hat{\sigma}^2$  sont indépendants.

L'indépendance de  $\hat{\beta}$  et  $\hat{\sigma}^2$  découle de

$$\hat{\beta} = (X'X)^{-1}X'\hat{\mu}.$$



## 6. Modèles linéaires.

6.1. Hypothèse de linéarité.

6.2. MLE.

6.3. Une approche par projection.

6.4. Théorie distributionnelle.

6.5. Inférence.

6.6. Analyse des résidus.

## Inférence

Pour un modèle linéaire  $Y \sim \mathcal{N}_n(\mu, \sigma^2 I_n)$ , nous allons tester des hypothèses de la forme suivante:

$$H_0 : \mu = \sum_{i=1}^k x_i \beta_i,$$

contre

$$H_1 : \mu = \sum_{i=1}^{\ell} x_i \beta_i, \quad k < \ell \leq n.$$

Ou de manière plus générale

$$H_0 : \mu \in L_2 \quad \text{contre} \quad H_1 : \mu \in L_1 \setminus L_2 \quad (L_2 \subset L_1).$$

Nous supposons dans la suite que  $\dim(L_1) = k_1$  et  $\dim(L_2) = k_2 \leq k_1$ .

## Inférence

Le rapport de vraisemblance est donné par

$$\Lambda(Y) = \frac{\sup_{\mu_2 \in L_2, \sigma_2 > 0} \ell(\mu, \sigma | Y)}{\sup_{\mu_1 \in L_1, \sigma_1 > 0} \ell(\mu, \sigma | Y)}.$$

Rappelons que le maximum de la vraisemblance pour le modèle  $L$  est proportionnel à

$$\|Y - p_L(Y)\|^{-n};$$

la statistique du test de rapport de vraisemblance est donnée par

$$\Lambda(Y) = \left( \frac{\|Y - p_{L_1}(Y)\|^2}{\|Y - p_{L_2}(Y)\|^2} \right)^{n/2},$$

et rejette l'hypothèse nulle si  $\Lambda(Y)$  est trop petit.

## Inférence

Maintenant comme

$$\|Y - p_{L_2}(Y)\|^2 = \|Y - p_{L_1}(Y) + \underbrace{p_{L_1}(Y) - p_{L_2}(Y)}_{\in L_1}\|^2$$

nous obtenons par le théorème de projection et le théorème de Pythagore que

$$\|Y - p_{L_2}(Y)\|^2 = \|Y - p_{L_1}(Y)\|^2 + \|p_{L_1}(Y) - p_{L_2}(Y)\|^2.$$

Donc le test de rapport de vraisemblance est équivalent au test qui rejette l'hypothèse nulle si

$$F(Y) = \frac{\|p_{L_1}(Y) - p_{L_2}(Y)\|^2 / (k_1 - k_2)}{\|Y - p_{L_1}(Y)\|^2 / (n - k_1)}$$

est trop grand.

## Inférence

Maintenant sous  $H_0 : \mu \in L_2$  nous avons

$$\begin{aligned} F(Y) &= \frac{\|p_{L_1}(Y) - p_{L_2}(Y)\|^2 / (k_1 - k_2)}{\|Y - p_{L_1}(Y)\|^2 / (n - k_1)} \\ &= \frac{\|p_{L_1}(\varepsilon) - p_{L_2}(\varepsilon)\|^2 / (k_1 - k_2)}{\|\varepsilon - p_{L_1}(\varepsilon)\|^2 / (n - k_1)} \\ &= \frac{\|p_{L_1 \ominus L_2}(\varepsilon)\|^2 / (k_1 - k_2)}{\|p_{L_1^\perp}(\varepsilon)\|^2 / (n - k_1)}. \end{aligned}$$

Comme  $\mathbb{R}^n = L_1^\perp \oplus (L_1 \ominus L_2) \oplus L_2$  nous concluons que

$$\|p_{L_1 \ominus L_2}(\varepsilon)\|^2 \sim \chi_{k_1 - k_2}^2 \quad \perp\!\!\!\perp \quad \|p_{L_1^\perp}(\varepsilon)\|^2 \sim \chi_{n - k_1}^2.$$



### Théorème

Supposons qu'on a un modèle linéaire de la forme  $Y \sim \mathcal{N}_n(\mu, \sigma^2 I_n)$ . Le test de rapport de vraisemblance pour  $H_0 : \mu \in L_2$  contre  $H_1 : \mu \in L_1$  est équivalent à un test  $F$ . La statistique de test

$$F(Y) = \frac{\|p_{L_1}(Y) - p_{L_2}(Y)\|^2 / (k_1 - k_2)}{\|Y - p_{L_1}(Y)\|^2 / (n - k_1)}$$

suit une distribution  $F$  de  $k_1 - k_2$  et  $n - k_1$  degrés de liberté. Pour un test de niveau  $\alpha$ , nous rejetons  $H_0$  si

$$F(Y) \geq F_{k_1 - k_2, n - k_1; 1 - \alpha}.$$

## Inférence

*Remarque.* Définissons

$$\tilde{\sigma}_1^2 = \frac{1}{n - k_1} \|Y - p_{L_1}(Y)\|^2.$$

Remarquons que ceci est un estimateur sans biais pour  $\sigma^2$  pour le modèle  $L_1$ , et que sous  $H_0$  aussi bien que sous  $H_1$  il converge vers  $\sigma^2$ .

Alors nous pouvons écrire

$$F(Y) = \frac{1}{k_1 - k_2} \frac{\|\hat{\mu}_1 - \hat{\mu}_2\|^2}{\tilde{\sigma}_1^2},$$

où les  $\hat{\mu}_i$  sont les MLE sous le modèle  $L_i$ .

Asymptotiquement nous voyons que  $\|\hat{\mu}_1 - \hat{\mu}_2\|^2 \sim \sigma^2 \chi_{k_1 - k_2}^2$ .

## 6. Modèles linéaires.

6.1. Hypothèse de linéarité.

6.2. MLE.

6.3. Une approche par projection.

6.4. Théorie distributionnelle.

6.5. Inférence.

6.6. Analyse des résidus.

## Analyse des résidus

L'idée générale de l'analyse des résidus réside dans l'étude de divers plots de résidus afin d'évaluer à quel point un modèle donné est proche des/fitte les données. Nous sommes donc amenés à d'abord étudier la distribution des résidus afin de savoir comment ils sont censés se comporter.

Supposons avoir un modèle linéaire  $Y \sim \mathcal{N}_n(\mu, \sigma^2 I_n)$ , avec  $\mu \in L$  sous  $H_0$ . Le vecteur de résidus est

$$R = Y - \hat{\mu} = Y - HY = (I_n - H)Y = (I_n - H)(\mu + \varepsilon) \stackrel{H_0}{=} (I_n - H)\varepsilon.$$

Donc

$$ER = 0 \quad \text{et} \quad \text{Var}(R) = \sigma^2(I_n - H),$$

montrant que

$$R \sim \mathcal{N}_n(0, \sigma^2(I_n - H)).$$

Remarquons que  $\hat{\mu}$  et  $R$  sont indépendants.

## Analyse des résidus

Remarquons que  $R$  est dans un certain sens un estimateur pour l'erreur statistique non-observée  $\varepsilon$ . Comme

$$\varepsilon - R = H\varepsilon,$$

nous avons (nous utilisons encore une fois le fait que  $H$  est idempotent) que

$$\text{Var}(\varepsilon - R) = \sigma^2 H.$$

## Analyse des résidus

*Exemple.* Considérons le modèle de régression linéaire simple

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad \varepsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2),$$

où  $1 \leq i \leq n$ . Nous pouvons réécrire ceci comme

$$Y_i = \alpha_0 + \beta_1 t_i + \varepsilon_i,$$

où  $\alpha_0 = \beta_0 + \beta_1 \bar{x}$  et  $t_i = x_i - \bar{x}$ . Alors  $\bar{t} = 0$ . Notons  $t_+ = \sum t_i^2$ .

En forme vectorielle notre modèle correspond à

$$Y = X\beta + \varepsilon, \quad \text{avec } X = (1_n, t) \quad \text{et } \beta = (\alpha_0, \beta_1),$$

où  $1_n = (1, \dots, 1)' \in \mathbb{R}^n$ . Notons que  $1_n' t = n\bar{t} = 0$ .

## Analyse des résidus

*Exemple, suite.*

Dans cet exemple  $X'X = \begin{pmatrix} n & 0 \\ 0 & t_+ \end{pmatrix}$ . Ceci montre (pourquoi?) que  $\hat{\alpha}_0$  et  $\hat{\beta}_1$  sont indépendants. De plus nous avons

$$H = X(X'X)^{-1}X' = \left( \left( \frac{1}{n} + \frac{t_i t_j}{t_+} \right) \right)_{i,j=1}^n.$$

Si nous supposons que les  $x_i$  sont des nombres aléatoires iid, de moyenne  $m_x$  et de variance  $\sigma_x^2$ , alors par la loi des grands nombres  $H_{ij} = O_P(n^{-1})$  pour tout  $1 \leq i \leq j \leq n$ .

En particulier les éléments diagonaux de  $H$ ,  $\varepsilon_i - R_i$ , seront très proches de zéro si  $n$  est grand, montrant que les résidus devraient se comporter similairement que  $\varepsilon$ .

## Analyse des résidus

*Exemple, suite.*

De plus, comme

$$\text{Var}(R) = \sigma^2(I_n - H),$$

nous voyons que

$$\text{cov}(R_i, R_j) \approx \begin{cases} \sigma^2 & \text{si } i = j \\ 0 & \text{autrement} \end{cases}$$

quand  $n$  est grand. Ceci est en accord avec  $\text{Var}(\varepsilon) = \sigma^2 I_n$ .