

Statistique

L. Rouvière

laurent.rouviere@univ-rennes2.fr

AVRIL 2017

Première partie I

Présentation de l'enseignement

- 1 Modèle de densité
- 2 Modèle de régression
- 3 Objectifs et plan du cours

Qu'est-ce qu'un modèle ?

Mathématiquement, un **modèle** est un triplet $(\mathcal{H}, \mathcal{A}, \{P, P \in \mathcal{P}\})$ avec

- \mathcal{H} est l'espace des observations (l'ensemble de tous les résultats possibles de l'expérience) ;
- \mathcal{A} est une tribu sur \mathcal{H} ;
- \mathcal{P} est une **famille de probabilités** définie sur $(\mathcal{H}, \mathcal{A})$.

A quoi sert un modèle ?

Expliquer, décrire les mécanismes du phénomène considéré.

- **Question** : quel est le lien entre la définition mathématique et l'utilité du phénomène ?

Qu'est-ce qu'un modèle ?

Mathématiquement, un **modèle** est un triplet $(\mathcal{H}, \mathcal{A}, \{P, P \in \mathcal{P}\})$ avec

- \mathcal{H} est l'espace des observations (l'ensemble de tous les résultats possibles de l'expérience) ;
- \mathcal{A} est une tribu sur \mathcal{H} ;
- \mathcal{P} est une **famille de probabilités** définie sur $(\mathcal{H}, \mathcal{A})$.

A quoi sert un modèle ?

Expliquer, **décrire** les mécanismes du phénomène considéré.

- **Question** : quel est le lien entre la définition mathématique et l'utilité du phénomène ?

Qu'est-ce qu'un modèle ?

Mathématiquement, un **modèle** est un triplet $(\mathcal{H}, \mathcal{A}, \{P, P \in \mathcal{P}\})$ avec

- \mathcal{H} est l'espace des observations (l'ensemble de tous les résultats possibles de l'expérience) ;
- \mathcal{A} est une tribu sur \mathcal{H} ;
- \mathcal{P} est une **famille de probabilités** définie sur $(\mathcal{H}, \mathcal{A})$.

A quoi sert un modèle ?

Expliquer, décrire les mécanismes du phénomène considéré.

- **Question** : quel est le lien entre la définition mathématique et l'utilité du phénomène ?

Qu'est-ce qu'un modèle ?

Mathématiquement, un **modèle** est un triplet $(\mathcal{H}, \mathcal{A}, \{P, P \in \mathcal{P}\})$ avec

- \mathcal{H} est l'espace des observations (l'ensemble de tous les résultats possibles de l'expérience) ;
- \mathcal{A} est une tribu sur \mathcal{H} ;
- \mathcal{P} est une **famille de probabilités** définie sur $(\mathcal{H}, \mathcal{A})$.

A quoi sert un modèle ?

Expliquer, **décrire** les mécanismes du phénomène considéré.

- **Question** : quel est le lien entre la définition mathématique et l'utilité du phénomène ?

Qu'est-ce qu'un modèle ?

Mathématiquement, un **modèle** est un triplet $(\mathcal{H}, \mathcal{A}, \{P, P \in \mathcal{P}\})$ avec

- \mathcal{H} est l'espace des observations (l'ensemble de tous les résultats possibles de l'expérience) ;
- \mathcal{A} est une tribu sur \mathcal{H} ;
- \mathcal{P} est une **famille de probabilités** définie sur $(\mathcal{H}, \mathcal{A})$.

A quoi sert un modèle ?

Expliquer, **décrire** les mécanismes du phénomène considéré.

- **Question** : quel est le lien entre la définition mathématique et l'utilité du phénomène ?

- 1 **Modèle de densité**
- 2 **Modèle de régression**
- 3 **Objectifs et plan du cours**

Exemple 1

- On souhaite **tester l'efficacité d'un nouveau traitement** à l'aide d'un essai clinique.
- On traite $n = 100$ patients atteints de la pathologie.
- A l'issue de l'étude, 72 patients sont guéris.

- Soit p_0 la probabilité de guérison suite au traitement en question.
- On est tentés de conclure $p_0 \approx 0.72$.

Un tel résultat n'a cependant guère d'intérêt si on n'est pas capable de **préciser l'erreur** susceptible d'être commise par cette estimation.

Exemple 1



- On souhaite **tester l'efficacité d'un nouveau traitement** à l'aide d'un essai clinique.
- On traite $n = 100$ patients atteints de la pathologie.
- A l'issue de l'étude, 72 patients sont guéris.

- Soit p_0 la probabilité de guérison suite au traitement en question.
- On est tentés de conclure $p_0 \approx 0.72$.

Un tel résultat n'a cependant guère d'intérêt si on n'est pas capable de **préciser l'erreur** susceptible d'être commise par cette estimation.

Exemple 2



- On s'intéresse au nombre de **mails reçus par jour** par un utilisateur pendant 36 journées.
- $\bar{x} = 5.22$, $S_n^2 = 5.72$.



Quelle est la **probabilité** de recevoir plus de 5 mails dans une journée ?

Exemple 2


- On s'intéresse au nombre de **mails reçus par jour** par un utilisateur pendant 36 journées.
- $\bar{x} = 5.22$, $S_n^2 = 5.72$.



Quelle est la **probabilité** de recevoir plus de 5 mails dans une journée ?

Exemple 3

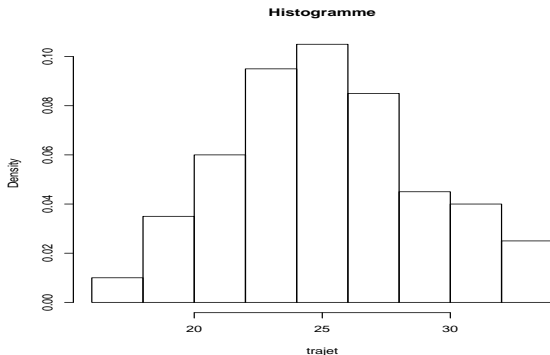
- Durée de trajet domicile-travail.
- On dispose de $n = 100$ mesures : $\bar{x} = 25.1$, $S_n^2 = 14.46$.



J'ai une réunion à 8h30, quelle est la probabilité que j'arrive en retard si je pars de chez moi à 7h55 ?

Exemple 3

- Durée de trajet domicile-travail.
- On dispose de $n = 100$ mesures : $\bar{x} = 25.1$, $S_n^2 = 14.46$.



J'ai une réunion à 8h30, quelle est la **probabilité** que j'arrive en retard si je pars de chez moi à 7h55 ?

Problème

- Nécessité de se **dégager des observations** x_1, \dots, x_n pour répondre à de telles questions.
- Si on mesure la durée du trajet pendant 100 nouveaux jours, on peut en effet penser que les nouvelles observations ne seront **pas** exactement les mêmes que les anciennes.

Idée

Considérer que les n valeurs observées x_1, \dots, x_n sont des **réalisations de variables aléatoires** X_1, \dots, X_n .

Attention

X_i est une **variable aléatoire** et x_i est une **réalisation** de cette variable, c'est-à-dire un nombre !

Problème

- Nécessité de se **dégager des observations** x_1, \dots, x_n pour répondre à de telles questions.
- Si on mesure la durée du trajet pendant 100 nouveaux jours, on peut en effet penser que les nouvelles observations ne seront **pas** exactement les mêmes que les anciennes.

Idée

Considérer que les n valeurs observées x_1, \dots, x_n sont des **réalisations de variables aléatoires** X_1, \dots, X_n .

Attention

X_i est une **variable aléatoire** et x_i est une **réalisation** de cette variable, c'est-à-dire un nombre !

Problème

- Nécessité de se **dégager des observations** x_1, \dots, x_n pour répondre à de telles questions.
- Si on mesure la durée du trajet pendant 100 nouveaux jours, on peut en effet penser que les nouvelles observations ne seront **pas** exactement les mêmes que les anciennes.

Idée

Considérer que les n valeurs observées x_1, \dots, x_n sont des **réalisations de variables aléatoires** X_1, \dots, X_n .

Attention

X_i est une **variable aléatoire** et x_i est une **réalisation** de cette variable, c'est-à-dire un nombre !

Définition

Une **variable aléatoire réelle** est une application

$$X : (\Omega, \mathcal{A}) \rightarrow (\mathbb{R}, \mathcal{B}(\mathbb{R}))$$

telle que

$$\forall B \in \mathcal{B}(\mathbb{R}), X^{-1}(B) \in \mathcal{A}.$$

- Lors de la modélisation statistique, l'espace Ω n'est généralement **jamais caractérisé**.
- Il contient tous les "phénomènes" pouvant expliquer les **sources d'aléa** (qui ne sont pas explicables...).
- En pratique, l'espace d'arrivée est généralement suffisant.

Définition

Une **variable aléatoire réelle** est une application

$$X : (\Omega, \mathcal{A}) \rightarrow (\mathbb{R}, \mathcal{B}(\mathbb{R}))$$

telle que

$$\forall B \in \mathcal{B}(\mathbb{R}), X^{-1}(B) \in \mathcal{A}.$$

- Lors de la modélisation statistique, l'espace Ω n'est généralement **jamais caractérisé**.
- Il contient tous les "phénomènes" pouvant expliquer les **sources d'aléa** (qui ne sont pas explicables...).
- En pratique, l'espace d'arrivée est généralement suffisant.

Définition

Une **variable aléatoire réelle** est une application

$$X : (\Omega, \mathcal{A}) \rightarrow (\mathbb{R}, \mathcal{B}(\mathbb{R}))$$

telle que

$$\forall B \in \mathcal{B}(\mathbb{R}), X^{-1}(B) \in \mathcal{A}.$$

- Lors de la modélisation statistique, l'espace Ω n'est généralement **jamais caractérisé**.
- Il contient tous les "phénomènes" pouvant expliquer les **sources d'aléa** (qui ne sont pas explicables...).
- En pratique, l'espace d'arrivée est généralement suffisant.

Loi de probabilité

Etant donnée \mathbf{P} une probabilité sur (Ω, \mathcal{A}) et X une variable aléatoire réelle définie sur Ω , on appelle **loi de probabilité** de X la mesure \mathbf{P}_X définie par

$$\mathbf{P}_X(B) = \mathbf{P}(X^{-1}(B)) = \mathbf{P}(X \in B) = \mathbf{P}(\{\omega \in \Omega : X(\omega) \in B\}) \quad \forall B \in \mathcal{B}(\mathbb{R}).$$

Une loi de probabilité est caractérisée par

- sa **fonction de répartition** : $F_X(x) = \mathbf{P}(X \leq x)$.
- sa **densité** : $f_X : \mathbb{R} \rightarrow \mathbb{R}^+$ telle que $\forall B \in \mathcal{B}(\mathbb{R})$

$$\mathbf{P}_X(B) = \int_B f_X(x) d\mu(x).$$

Loi de probabilité

Etant donnée \mathbf{P} une probabilité sur (Ω, \mathcal{A}) et X une variable aléatoire réelle définie sur Ω , on appelle **loi de probabilité** de X la mesure \mathbf{P}_X définie par

$$\mathbf{P}_X(B) = \mathbf{P}(X^{-1}(B)) = \mathbf{P}(X \in B) = \mathbf{P}(\{\omega \in \Omega : X(\omega) \in B\}) \quad \forall B \in \mathcal{B}(\mathbb{R}).$$

Une loi de probabilité est caractérisée par

- sa **fonction de répartition** : $F_X(x) = \mathbf{P}(X \leq x)$.
- sa **densité** : $f_X : \mathbb{R} \rightarrow \mathbb{R}^+$ telle que $\forall B \in \mathcal{B}(\mathbb{R})$

$$\mathbf{P}_X(B) = \int_B f_X(x) d\mu(x).$$

Un modèle pour l'exemple 1

- On note $x_i = 1$ si le $i^{\text{ème}}$ patient a guéri, 0 sinon.
- On peut supposer que x_i est la **réalisation** d'une variable aléatoire X_i de loi de **Bernoulli** de paramètre p_0 .
- Si les individus sont choisis de manière **indépendante** et ont tous la **même probabilité de guérir** (ce qui peut revenir à dire qu'ils en sont au même stade de la pathologie), il est alors raisonnable de supposer que les variables aléatoires X_1, \dots, X_n sont indépendantes et de même loi (i.i.d.).

On dit que X_1, \dots, X_n est un **n -échantillon** de variables aléatoires indépendantes de même loi $B(p_0)$.

Un modèle pour l'exemple 1

- On note $x_i = 1$ si le $i^{\text{ème}}$ patient a guéri, 0 sinon.
- On peut supposer que x_i est la **réalisation** d'une variable aléatoire X_i de loi de **Bernoulli** de paramètre p_0 .
- Si les individus sont choisis de manière **indépendante** et ont tous la **même probabilité de guérir** (ce qui peut revenir à dire qu'ils en sont au même stade de la pathologie), il est alors raisonnable de supposer que les variables aléatoires X_1, \dots, X_n sont indépendantes et de même loi (i.i.d.).

On dit que X_1, \dots, X_n est un **n -échantillon** de variables aléatoires indépendantes de même loi $B(p_0)$.

Un modèle pour l'exemple 1

- On note $x_i = 1$ si le $i^{\text{ème}}$ patient a guéri, 0 sinon.
- On peut supposer que x_i est la **réalisation** d'une variable aléatoire X_i de loi de **Bernoulli** de paramètre p_0 .
- Si les individus sont choisis de manière **indépendante** et ont tous la **même probabilité de guérir** (ce qui peut revenir à dire qu'ils en sont au même stade de la pathologie), il est alors raisonnable de supposer que les variables aléatoires X_1, \dots, X_n sont indépendantes et de même loi (i.i.d.).

On dit que X_1, \dots, X_n est un **n -échantillon** de variables aléatoires indépendantes de même loi $B(p_0)$.

- 1 Modèle de densité
- 2 Modèle de régression
- 3 Objectifs et plan du cours

Modèle de régression

- On cherche à **expliquer** une variable Y par p variables explicatives $\mathbf{X}_1, \dots, \mathbf{X}_p$. On dispose d'un n échantillon i.i.d. $(X_i, Y_i), i = 1, \dots, n$.

Modèle linéaire (paramétrique)

- On pose

$$Y = \beta_0 + \beta_1 \mathbf{X}_1 + \dots + \beta_p \mathbf{X}_p + \varepsilon \quad \text{où} \quad \varepsilon \sim \mathcal{N}(0, \sigma^2).$$

- Le problème est d'**estimer** $\beta = (\beta_0, \dots, \beta_p) \in \mathbb{R}^{p+1}$ à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

Un modèle non paramétrique

- On pose

$$Y = m(\mathbf{X}_1, \dots, \mathbf{X}_p) + \varepsilon$$

où $m : \mathbb{R}^p \rightarrow \mathbb{R}$ est une **fonction continue**.

- Le problème est d'**estimer** m à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

Modèle de régression

- On cherche à **expliquer** une variable Y par p variables explicatives $\mathbf{X}_1, \dots, \mathbf{X}_p$. On dispose d'un n échantillon i.i.d. $(X_i, Y_i), i = 1, \dots, n$.

Modèle linéaire (paramétrique)

- On pose

$$Y = \beta_0 + \beta_1 \mathbf{X}_1 + \dots + \beta_p \mathbf{X}_p + \varepsilon \quad \text{où} \quad \varepsilon \sim \mathcal{N}(0, \sigma^2).$$

- Le problème est d'**estimer** $\beta = (\beta_0, \dots, \beta_p) \in \mathbb{R}^{p+1}$ à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

Un modèle non paramétrique

- On pose

$$Y = m(\mathbf{X}_1, \dots, \mathbf{X}_p) + \varepsilon$$

où $m : \mathbb{R}^p \rightarrow \mathbb{R}$ est une **fonction continue**.

- Le problème est d'**estimer** m à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

Modèle de régression

- On cherche à **expliquer** une variable Y par p variables explicatives $\mathbf{X}_1, \dots, \mathbf{X}_p$. On dispose d'un n échantillon i.i.d. $(X_i, Y_i), i = 1, \dots, n$.

Modèle linéaire (paramétrique)

- On pose

$$Y = \beta_0 + \beta_1 \mathbf{X}_1 + \dots + \beta_p \mathbf{X}_p + \varepsilon \quad \text{où} \quad \varepsilon \sim \mathcal{N}(0, \sigma^2).$$

- Le problème est d'**estimer** $\beta = (\beta_0, \dots, \beta_p) \in \mathbb{R}^{p+1}$ à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

Un modèle non paramétrique

- On pose


$$Y = m(\mathbf{X}_1, \dots, \mathbf{X}_p) + \varepsilon$$

où $m : \mathbb{R}^p \rightarrow \mathbb{R}$ est une **fonction continue**.

- Le problème est d'**estimer** m à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

2 types d'erreur

- Poser un modèle revient à **choisir une famille de loi candidates** pour reconstruire la loi des données **P**.




On distingue deux types d'erreurs :

- **Erreur d'estimation** : erreur commise par le choix d'une loi dans \mathcal{P} par rapport au meilleur choix.
- **Erreur d'approximation** : erreur commise par le choix de \mathcal{P} .

2 types d'erreur

- Poser un modèle revient à **choisir une famille de loi candidates** pour reconstruire la loi des données **P**.



On distingue deux types d'erreurs :

- **Erreur d'estimation** : erreur commise par le choix d'une loi dans \mathcal{P} par rapport au meilleur choix.
- **Erreur d'approximation** : erreur commise par le choix de \mathcal{P} .

- 1 On récolte n observations (n valeurs) x_1, \dots, x_n qui sont le résultats de n expériences aléatoires indépendantes.
- 2 **Modélisation** : on suppose que les n valeurs sont des réalisations de n variables aléatoires indépendantes X_1, \dots, X_n et de même loi \mathbf{P}_{θ_0} .
- 3 **Estimation** : chercher dans le modèle une loi $\mathbf{P}_{\hat{\theta}}$ qui soit le plus proche possible de $\mathbf{P}_{\theta_0} \implies$ chercher un **estimateur** $\hat{\theta}$ de θ_0 .
- 4 **"Validation" de modèle** : on revient en arrière et on tente de vérifier si l'hypothèse de l'étape 2 est raisonnable (test d'adéquation, etc...)

- 1 On récolte n observations (n valeurs) x_1, \dots, x_n qui sont le résultats de n expériences aléatoires indépendantes.
- 2 **Modélisation** : on **suppose** que les n valeurs sont des réalisations de n variables aléatoires indépendantes X_1, \dots, X_n et de même loi \mathbf{P}_{θ_0} .
- 3 **Estimation** : chercher dans le modèle une loi $\mathbf{P}_{\hat{\theta}}$ qui soit le plus proche possible de $\mathbf{P}_{\theta_0} \implies$ chercher un **estimateur** $\hat{\theta}$ de θ_0 .
- 4 **"Validation" de modèle** : on revient en arrière et on tente de vérifier si l'hypothèse de l'étape 2 est raisonnable (test d'adéquation, etc...)

- 1 On récolte n observations (n valeurs) x_1, \dots, x_n qui sont le résultats de n expériences aléatoires indépendantes.
- 2 **Modélisation** : on **suppose** que les n valeurs sont des réalisations de n variables aléatoires indépendantes X_1, \dots, X_n et de même loi \mathbf{P}_{θ_0} .
- 3 **Estimation** : chercher dans le modèle une loi $\mathbf{P}_{\hat{\theta}}$ qui soit le plus proche possible de $\mathbf{P}_{\theta_0} \implies$ chercher un **estimateur** $\hat{\theta}$ de θ_0 .
- 4 "Validation" de modèle : on revient en arrière et on tente de vérifier si l'hypothèse de l'étape 2 est raisonnable (test d'adéquation, etc...)

- 1 On récolte n observations (n valeurs) x_1, \dots, x_n qui sont le résultats de n expériences aléatoires indépendantes.
- 2 **Modélisation** : on **suppose** que les n valeurs sont des réalisations de n variables aléatoires indépendantes X_1, \dots, X_n et de même loi \mathbf{P}_{θ_0} .
- 3 **Estimation** : chercher dans le modèle une loi $\mathbf{P}_{\hat{\theta}}$ qui soit le plus proche possible de $\mathbf{P}_{\theta_0} \implies$ chercher un **estimateur** $\hat{\theta}$ de θ_0 .
- 4 **"Validation" de modèle** : on revient en arrière et on tente de vérifier si l'hypothèse de l'étape 2 est raisonnable (test d'adéquation, etc...)

- 1 Modèle de densité
- 2 Modèle de régression
- 3 Objectifs et plan du cours

- 1 Formaliser mathématiquement les étapes de **modélisation et d'estimation**.
- 2 Proposer des **procédures automatiques** permettant construire des "bons estimateurs".
- 3 Mesurer la **performance des estimateurs**.

Outils

Les techniques permettant de répondre à ces 3 objectifs font appel à la **théorie des probabilités**.

- 1 Formaliser mathématiquement les étapes de **modélisation et d'estimation**.
- 2 Proposer des **procédures automatiques** permettant construire des "bons estimateurs".
- 3 Mesurer la **performance des estimateurs**.

Outils

Les techniques permettant de répondre à ces 3 objectifs font appel à la **théorie des probabilités**.

- 1 **Notions de statistiques descriptives** : indicateurs permettant de synthétiser l'information contenue dans un tableau de données : cas univariés (moyenne, médiane, variance...), bivariés (corrélation), multivariés (analyse en composante principale).
- 2 **Modèle statistique et estimation** : formulation mathématique du problème de modélisation, construction et mesure de performance (à distance finie et asymptotique) d'estimateurs.
- 3 **Tests d'hypothèses** : théorie de la décision, notions de risque, construction de tests (principe de Neyman-Pearson).
- 4 **Le modèle de régression linéaire** : adaptation des outils développés dans les chapitres précédents pour répondre à un problème de régression.

- 1 **Notions de statistiques descriptives** : indicateurs permettant de synthétiser l'information contenue dans un tableau de données : cas univariés (moyenne, médiane, variance...), bivariés (corrélation), multivariés (analyse en composante principale).
- 2 **Modèle statistique et estimation** : formulation mathématique du problème de modélisation, construction et mesure de performance (à distance finie et asymptotique) d'estimateurs.
- 3 **Tests d'hypothèses** : théorie de la décision, notions de risque, construction de tests (principe de Neyman-Pearson).
- 4 **Le modèle de régression linéaire** : adaptation des outils développés dans les chapitres précédents pour répondre à un problème de régression.

- 1 **Notions de statistiques descriptives** : indicateurs permettant de synthétiser l'information contenue dans un tableau de données : cas univariés (moyenne, médiane, variance...), bivariés (corrélation), multivariés (analyse en composante principale).
- 2 **Modèle statistique et estimation** : formulation mathématique du problème de modélisation, construction et mesure de performance (à distance finie et asymptotique) d'estimateurs.
- 3 **Tests d'hypothèses** : théorie de la décision, notions de risque, construction de tests (principe de Neyman-Pearson).
- 4 **Le modèle de régression linéaire** : adaptation des outils développés dans les chapitres précédents pour répondre à un problème de régression.

- 1 **Notions de statistiques descriptives** : indicateurs permettant de synthétiser l'information contenue dans un tableau de données : cas univariés (moyenne, médiane, variance...), bivariés (corrélation), multivariés (analyse en composante principale).
- 2 **Modèle statistique et estimation** : formulation mathématique du problème de modélisation, construction et mesure de performance (à distance finie et asymptotique) d'estimateurs.
- 3 **Tests d'hypothèses** : théorie de la décision, notions de risque, construction de tests (principe de Neyman-Pearson).
- 4 **Le modèle de régression linéaire** : adaptation des outils développés dans les chapitres précédents pour répondre à un problème de régression.

Deuxième partie II

Statistiques descriptives

1 Introduction

2 La statistique exploratoire

- Etude d'une variable
- Etude de deux variables
- Etude de plus de deux variables

3 L'analyse en composantes principales

- Quelques rappels d'algèbre linéaire
- Introduction à l'ACP - Réduction de la dimension
- Analyse du nuage des individus
 - Recherche des axes factoriels
 - Contributions et qualités de représentation
- Analyse du nuage des variables

1 Introduction

2 La statistique exploratoire

- Etude d'une variable
- Etude de deux variables
- Etude de plus de deux variables

3 L'analyse en composantes principales

- Quelques rappels d'algèbre linéaire
- Introduction à l'ACP - Réduction de la dimension
- Analyse du nuage des individus
 - Recherche des axes factoriels
 - Contributions et qualités de représentation
- Analyse du nuage des variables

Vocabulaire (voir Saporta : Probabilités, analyse des données et statistique)

- **Population** : ensemble d'objets de même nature.
- **Individu** : élément de cette population.
- **Variable** : caractéristique étudiée sur la population.
- **Echantillon** : sous ensemble de la population dont les individus feront l'objet de l'étude

Un exemple

- On s'intéresse aux **performances de décathloniens** de haut niveau dans les **10 disciplines** qui composent ce sport.
- On dispose des performances de $n = 41$ athlètes réalisées au cours des JO et au décastar :

	X100m	Longueur	Poids	Hauteur	X400m	X110mH	Disque	Perche
Sebrle	10.85	7.84	16.36	2.12	48.36	14.05	48.72	5.0
Clay	10.44	7.96	15.23	2.06	49.19	14.13	50.11	4.9
Karpov	10.50	7.81	15.93	2.09	46.81	13.97	51.65	4.6
Macey	10.89	7.47	15.73	2.15	48.97	14.56	48.34	4.4
Warners	10.62	7.74	14.48	1.97	47.97	14.01	43.73	4.9

	Javelot	X1500m	Classement	Points	Competition
Sebrle	70.52	280.01	1	8893	OlympicG
Clay	69.71	282.00	2	8820	OlympicG
Karpov	55.54	278.11	3	8725	OlympicG
Macey	58.46	265.42	4	8414	OlympicG
Warners	55.39	278.05	5	8343	OlympicG

- **Population** : ensemble des décathlons de haut niveau.
- **Individu** : un décathlonien de haut niveau.
- **Variables** : performances dans chacune des 10 disciplines.
- **Echantillon** : les décathloniens ayant participé au JO ou au décastar.

- **But** : synthétiser, résumer, structurer l'information contenue dans un tableau de données.
- **Comment ?** : représentations sous forme de tableaux, de graphiques, d'indicateurs numériques.
- **Exemple** : calcul de la longueur moyenne sautée dans l'épreuve de saut en longueur...

- **But** : étendre les propriétés constatées sur l'échantillon à la population toute entière.
- **Comment ?** : les méthodes font généralement appel à la théorie des probabilités (construction d'intervalles de confiance, de tests d'hypothèses).
- **Exemple** : peut-on dire que les performances des athlètes sont meilleurs aux JO qu'au décastar ?

1 Introduction

2 La statistique exploratoire

- Etude d'une variable
- Etude de deux variables
- Etude de plus de deux variables

3 L'analyse en composantes principales

- Quelques rappels d'algèbre linéaire
- Introduction à l'ACP - Réduction de la dimension
- Analyse du nuage des individus
 - Recherche des axes factoriels
 - Contributions et qualités de représentation
- Analyse du nuage des variables

Les méthodes diffèrent selon le type de variables :

- **quantitative** : additionner les modalités à un sens.
 - **continue** : la variable prend ses valeurs dans un intervalle de \mathbb{R} (taille, poids, saut en longueur...);
 - **discrète** : nombre fini ou dénombrable de valeurs (nombre de personnes dans une file d'attente à un moment donnée, classement du décathlon...).
- **qualitative** : additionner les modalités n'a pas de sens.
 - **ordinaire** : relation d'ordre entre les modalités (type de mention à un examen);
 - **nominale** : sinon (type de traitement subi, CSP).

1 Introduction

2 La statistique exploratoire

- Etude d'une variable
- Etude de deux variables
- Etude de plus de deux variables

3 L'analyse en composantes principales

- Quelques rappels d'algèbre linéaire
- Introduction à l'ACP - Réduction de la dimension
- Analyse du nuage des individus
 - Recherche des axes factoriels
 - Contributions et qualités de représentation
- Analyse du nuage des variables

On note x_1, \dots, x_n n observations d'une variable quantitative X .

- **moyenne** : $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$.
- **médiane** : "valeur qui coupe l'échantillon en 2". On la définit à partir de la fonction de répartition empirique

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\{x_i \leq x\}}.$$

- **médiane** : plus petite valeur M telle que $F_n(x) \geq 0.5$:

$$M = \inf\{x : F_n(x) \geq 0.5\}.$$

- **quantile d'ordre α** : plus petite valeur q_α telle que $F_n(x) \geq \alpha$:

$$q_\alpha = \inf\{x : F_n(x) \geq \alpha\}.$$

Mesures de tendance centrale

On note x_1, \dots, x_n n observations d'une variable quantitative X .

- **moyenne** : $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$.
- **médiane** : "valeur qui coupe l'échantillon en 2". On la définit à partir de la fonction de répartition empirique

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\{x_i \leq x\}}.$$

- **médiane** : plus petite valeur M telle que $F_n(x) \geq 0.5$:

$$M = \inf\{x : F_n(x) \geq 0.5\}.$$

- **quantile d'ordre α** : plus petite valeur q_α telle que $F_n(x) \geq \alpha$:

$$q_\alpha = \inf\{x : F_n(x) \geq \alpha\}.$$

On note x_1, \dots, x_n n observations d'une variable quantitative X .

- **moyenne** : $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$.
- **médiane** : "valeur qui coupe l'échantillon en 2". On la définit à partir de la fonction de répartition empirique

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\{x_i \leq x\}}.$$

- **médiane** : plus petite valeur M telle que $F_n(x) \geq 0.5$:

$$M = \inf\{x : F_n(x) \geq 0.5\}.$$

- **quantile d'ordre α** : plus petite valeur q_α telle que $F_n(x) \geq \alpha$:

$$q_\alpha = \inf\{x : F_n(x) \geq \alpha\}.$$

On note x_1, \dots, x_n n observations d'une variable quantitative X .

- **moyenne** : $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$.
- **médiane** : "valeur qui coupe l'échantillon en 2". On la définit à partir de la fonction de répartition empirique

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\{x_i \leq x\}}.$$

- **médiane** : plus petite valeur M telle que $F_n(x) \geq 0.5$:


$$M = \inf\{x : F_n(x) \geq 0.5\}.$$

- **quantile d'ordre α** : plus petite valeur q_α telle que $F_n(x) \geq \alpha$:

$$q_\alpha = \inf\{x : F_n(x) \geq \alpha\}.$$

Exemple


X_1	X_2	X_3	X_4	X_5	X_6
4	2	2	8	7	9



$$M = 4, \quad q_{0.25} = 2, \quad q_{5/6} = 8.$$

Exemple


x_1	x_2	x_3	x_4	x_5	x_6
4	2	2	8	7	9



$$M = 4, \quad q_{0.25} = 2, \quad q_{5/6} = 8.$$

- Mesurer la tendance centrale n'est pas suffisant :

x_1	x_2	x_3	x_4	x_5	\bar{x}	M
10	10	10	10	10	10	10
15	10	5	12	8	10	10




- Variance :

$$S_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2.$$

- série 1 : $S_n^2 = 0$, série 2
 $S_n^2 = \frac{1}{5}(5^2 + 0^2 + \dots) = 11.6$.
- Conclusion** : les observations de la série 2 sont plus dispersées autour de leur moyenne.

- Mesurer la tendance centrale n'est pas suffisant :

x_1	x_2	x_3	x_4	x_5	\bar{x}	M
10	10	10	10	10	10	10
15	10	5	12	8	10	10




- Variance :

$$S_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2.$$

- série 1 : $S_n^2 = 0$, série 2
 $S_n^2 = \frac{1}{5}(5^2 + 0^2 + \dots) = 11.6$.
- Conclusion : les observations de la série 2 sont plus dispersées autour de leur moyenne.

- Mesurer la tendance centrale n'est pas suffisant :

x_1	x_2	x_3	x_4	x_5	\bar{x}	M
10	10	10	10	10	10	10
15	10	5	12	8	10	10




- Variance :

$$S_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2.$$

- série 1 : $S_n^2 = 0$, série 2
 $S_n^2 = \frac{1}{5}(5^2 + 0^2 + \dots) = 11.6$.
- Conclusion** : les observations de la série 2 sont plus dispersées autour de leur moyenne.

Boxplot

x_1	x_2	x_3	x_4	x_5	\bar{x}	M
10	10	10	10	10	10	10
15	10	5	12	8	10	10



1 Introduction



2 La statistique exploratoire

- Etude d'une variable
- **Etude de deux variables**
- Etude de plus de deux variables

3 L'analyse en composantes principales

- Quelques rappels d'algèbre linéaire
- Introduction à l'ACP - Réduction de la dimension
- Analyse du nuage des individus
 - Recherche des axes factoriels
 - Contributions et qualités de représentation
- Analyse du nuage des variables

- On observe 2 variables quantitatives X et Y sur un échantillon de n individus. Les observations sont notées $(x_i, y_i), i = 1, \dots, n$.
- **Problème** : mesurer la relation entre X et Y .
- **Exemple** :



- **Définition**

- **covariance** entre X et Y :

$$\mathbf{cov}(X, Y) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x}\bar{y}.$$

- **corrélation** entre X et Y :

$$\rho(X, Y) = \frac{\mathbf{cov}(X, Y)}{\sigma(X)\sigma(Y)}.$$

- **Propriété**

- $-1 \leq \rho(X, Y) \leq 1$ et $|\rho(X, Y)| = 1$ si et seulement si il existe a et b tels que $y_i = ax_i + b$.
- Si $|\rho(X, Y)| \approx 1$ on dit que X et Y sont corrélées et si $|\rho(X, Y)| \approx 0$ on dit qu'elles sont non corrélées.

- **Exemple** : $\rho(\text{Poids, Disque}) = 0.62$ et $\rho(400m, perche) = -0.08$.

- **Définition**

- **covariance** entre X et Y :

$$\mathbf{cov}(X, Y) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \bar{y}.$$

- **corrélation** entre X et Y :

$$\rho(X, Y) = \frac{\mathbf{cov}(X, Y)}{\sigma(X)\sigma(Y)}.$$

- **Propriété**

- $-1 \leq \rho(X, Y) \leq 1$ et $|\rho(X, Y)| = 1$ si et seulement si il existe a et b tels que $y_i = ax_i + b$.
- Si $|\rho(X, Y)| \approx 1$ on dit que X et Y sont corrélées et si $|\rho(X, Y)| \approx 0$ on dit qu'elles sont non corrélées.

- **Exemple** : $\rho(\text{Poids, Disque}) = 0.62$ et $\rho(400m, perche) = -0.08$.

1 Introduction

2 La statistique exploratoire

- Etude d'une variable
- Etude de deux variables
- Etude de plus de deux variables

3 L'analyse en composantes principales

- Quelques rappels d'algèbre linéaire
- Introduction à l'ACP - Réduction de la dimension
- Analyse du nuage des individus
 - Recherche des axes factoriels
 - Contributions et qualités de représentation
- Analyse du nuage des variables

- Lorsque l'on cherche à étudier **plus de deux variables** simultanément, les choses se compliquent...
- Sur l'exemple du décathlon, on a $n = 41$ individus et $p = 10$ variables.
- **Questions :**
 - peut-on **regrouper certains individus** selon leur performance ? On pourrait calculer les $n(n - 1)/2 = 820$ distances entre individus... difficile à analyser.
 - peut-on identifier des **groupes de variables** (des disciplines pour lesquelles certains individus pourraient être très performants ou non) ? Une idée : utiliser la **matrice des corrélations**.

- Lorsque l'on cherche à étudier **plus de deux variables** simultanément, les choses se compliquent...
- Sur l'exemple du décathlon, on a $n = 41$ individus et $p = 10$ variables.
- **Questions :**
 - peut-on **regrouper certains individus** selon leur performance ? On pourrait calculer les $n(n - 1)/2 = 820$ distances entre individus... difficile à analyser.
 - peut-on identifier des **groupes de variables** (des disciplines pour lesquelles certains individus pourraient être très performants ou non) ? Une idée : utiliser la **matrice des corrélations**.

- Lorsque l'on cherche à étudier **plus de deux variables** simultanément, les choses se compliquent...
- Sur l'exemple du décathlon, on a $n = 41$ individus et $p = 10$ variables.
- **Questions :**
 - peut-on **regrouper certains individus** selon leur performance ? On pourrait calculer les $n(n - 1)/2 = 820$ distances entre individus... difficile à analyser.
 - peut-on identifier des **groupes de variables** (des disciplines pour lesquelles certains individus pourraient être très performants ou non) ? Une idée : utiliser la **matrice des corrélations**.

Un exemple

	X100m	Longueur	Poids	Hauteur	X400m	X110mH	Disque	Perche	Javelot	X1500m
X100m	1.00	-0.60	-0.36	-0.25	0.52	0.58	-0.22	-0.08	-0.16	-0.06
Longueur	-0.60	1.00	0.18	0.29	-0.60	-0.51	0.19	0.20	0.12	-0.03
Poids	-0.36	0.18	1.00	0.49	-0.14	-0.25	0.62	0.06	0.37	0.12
Hauteur	-0.25	0.29	0.49	1.00	-0.19	-0.28	0.37	-0.16	0.17	-0.04
X400m	0.52	-0.60	-0.14	-0.19	1.00	0.55	-0.12	-0.08	0.00	0.41
X110mH	0.58	-0.51	-0.25	-0.28	0.55	1.00	-0.33	0.00	0.01	0.04
Disque	-0.22	0.19	0.62	0.37	-0.12	-0.33	1.00	-0.15	0.16	0.26
Perche	-0.08	0.20	0.06	-0.16	-0.08	0.00	-0.15	1.00	-0.03	0.25
Javelot	-0.16	0.12	0.37	0.17	0.00	0.01	0.16	-0.03	1.00	-0.18
X1500m	-0.06	-0.03	0.12	-0.04	0.41	0.04	0.26	0.25	-0.18	1.00

On mesure les corrélations deux à deux mais difficile d'obtenir une information plus globale...

Un exemple

	X100m	Longueur	Poids	Hauteur	X400m	X110mH	Disque	Perche	Javelot	X1500m
X100m	1.00	-0.60	-0.36	-0.25	0.52	0.58	-0.22	-0.08	-0.16	-0.06
Longueur	-0.60	1.00	0.18	0.29	-0.60	-0.51	0.19	0.20	0.12	-0.03
Poids	-0.36	0.18	1.00	0.49	-0.14	-0.25	0.62	0.06	0.37	0.12
Hauteur	-0.25	0.29	0.49	1.00	-0.19	-0.28	0.37	-0.16	0.17	-0.04
X400m	0.52	-0.60	-0.14	-0.19	1.00	0.55	-0.12	-0.08	0.00	0.41
X110mH	0.58	-0.51	-0.25	-0.28	0.55	1.00	-0.33	0.00	0.01	0.04
Disque	-0.22	0.19	0.62	0.37	-0.12	-0.33	1.00	-0.15	0.16	0.26
Perche	-0.08	0.20	0.06	-0.16	-0.08	0.00	-0.15	1.00	-0.03	0.25
Javelot	-0.16	0.12	0.37	0.17	0.00	0.01	0.16	-0.03	1.00	-0.18
X1500m	-0.06	-0.03	0.12	-0.04	0.41	0.04	0.26	0.25	-0.18	1.00

On mesure les corrélations deux à deux mais **difficile d'obtenir une information plus globale...**

1 Introduction

2 La statistique exploratoire

- Etude d'une variable
- Etude de deux variables
- Etude de plus de deux variables

3 L'analyse en composantes principales

- Quelques rappels d'algèbre linéaire
- Introduction à l'ACP - Réduction de la dimension
- Analyse du nuage des individus
 - Recherche des axes factoriels
 - Contributions et qualités de représentation
- Analyse du nuage des variables

1 Introduction

2 La statistique exploratoire

- Etude d'une variable
- Etude de deux variables
- Etude de plus de deux variables

3 L'analyse en composantes principales

- Quelques rappels d'algèbre linéaire
- Introduction à l'ACP - Réduction de la dimension
- Analyse du nuage des individus
 - Recherche des axes factoriels
 - Contributions et qualités de représentation
- Analyse du nuage des variables

- Soit E un espace vectoriel de dimension finie n muni d'un produit scalaire $\langle \cdot, \cdot \rangle$ et F un sous-espace vectoriel de E de dimension p .


Définition

Un **projecteur** $p : E \rightarrow E$ est une application linéaire qui vérifie $p \circ p = p$.

Projection orthogonale

P_F est la **projection orthogonale** sur F si

- $\forall u \in E, P_F(u) \in F$;
- $\forall u \in E, u - P_F(u) \in F^\perp$.



Propriétés

- 1 Soient $(u, v) \in E^2$. Le **projeté orthogonal** de u sur $F = \text{vect}(v)$ est donné par

$$P_F(u) = \frac{\langle u, v \rangle}{\|v\|^2} v.$$

- 2 Soit F un sev de E de dimension p et $\mathcal{B} = (v_1, \dots, v_p)$ une **base orthogonale** de F , alors

$$P_F(u) = \frac{\langle u, v_1 \rangle}{\|v_1\|^2} v_1 + \dots + \frac{\langle u, v_p \rangle}{\|v_p\|^2} v_p.$$

Soient F et G 2 sev **orthogonaux** de E . Alors

$$P_{F \oplus G} = P_F + P_G.$$

Propriétés

- 1 Soient $(u, v) \in E^2$. Le **projeté orthogonal** de u sur $F = \text{vect}(v)$ est donné par

$$P_F(u) = \frac{\langle u, v \rangle}{\|v\|^2} v.$$

- 2 Soit F un sev de E de dimension p et $\mathcal{B} = (v_1, \dots, v_p)$ une **base orthogonale** de F , alors

$$P_F(u) = \frac{\langle u, v_1 \rangle}{\|v_1\|^2} v_1 + \dots + \frac{\langle u, v_p \rangle}{\|v_p\|^2} v_p.$$

Soient F et G 2 sev **orthogonaux** de E . Alors

$$P_{F \oplus G} = P_F + P_G.$$

Propriétés

- ① Soient $(u, v) \in E^2$. Le **projeté orthogonal** de u sur $F = \text{vect}(v)$ est donné par

$$P_F(u) = \frac{\langle u, v \rangle}{\|v\|^2} v.$$

- ② Soit F un sev de E de dimension p et $\mathcal{B} = (v_1, \dots, v_p)$ une **base orthogonale** de F , alors

$$P_F(u) = \frac{\langle u, v_1 \rangle}{\|v_1\|^2} v_1 + \dots + \frac{\langle u, v_p \rangle}{\|v_p\|^2} v_p.$$

Soient F et G 2 sev **orthogonaux** de E . Alors

$$P_{F \oplus G} = P_F + P_G.$$

Définition

Soit A une matrice $n \times n$.

- $v \in E$ est un **vecteur propre** de A si et seulement si il existe $\lambda \in \mathbb{R}$ tel que $Av = \lambda v$ (λ est appelé valeur propre de A).
- L'ensemble des vecteurs propres de A associé à la valeur propre λ est appelé **espace propre** E_λ :

$$E_\lambda = \ker(A - \lambda I).$$

Propriété

λ est **valeur propre** de A si et seulement si $\det(A - \lambda I) = 0$.

Définition

Soit A une matrice $n \times n$.

- $v \in E$ est un **vecteur propre** de A si et seulement si il existe $\lambda \in \mathbb{R}$ tel que $Av = \lambda v$ (λ est appelé valeur propre de A).
- L'ensemble des vecteurs propres de A associé à la valeur propre λ est appelé **espace propre** E_λ :

$$E_\lambda = \ker(A - \lambda I).$$

Propriété

λ est **valeur propre** de A si et seulement si $\det(A - \lambda I) = 0$.

Définition

A est diagonalisable si il existe une matrice P **inversible** et une matrice D **diagonale** telles que $A = P^{-1}DP$.

Propriété

Soit A une matrice admettant pour valeurs propres $\lambda_1, \dots, \lambda_k$. La matrice A est **diagonalisable** si et seulement si la **somme des dimensions des sous-espaces propres** est égale à n , c'est-à-dire

$$\sum_{j=1}^k \dim(E_{\lambda_j}) = n.$$

Définition

A est diagonalisable si il existe une matrice P inversible et une matrice D diagonale telles que $A = P^{-1}DP$.

Propriété

Soit A une matrice admettant pour valeurs propres $\lambda_1, \dots, \lambda_k$. La matrice A est diagonalisable si et seulement si la somme des dimensions des sous-espaces propres est égale à n , c'est-à-dire

$$\sum_{j=1}^k \dim(E_{\lambda_j}) = n.$$

Propriété

Soit A une matrice symétrique **semi-définie positive**. Alors

- 1 A est diagonalisable ;
- 2 Les valeurs propres de A sont ≥ 0 ;
- 3 Les espaces propres de A sont deux à deux orthogonaux.

Propriété

Soit X une matrice $n \times p$. Alors

- 1 la matrice $X'X = \Sigma$ de dimension $p \times p$ est semi-définie positive.
- 2 la matrice $XX' = A$ de dimension $n \times n$ est semi-définie positive.
- 3 Σ et A ont les **mêmes valeurs propres non nulles**.

Propriété

Soit A une matrice symétrique **semi-définie positive**. Alors

- 1 A est diagonalisable ;
- 2 Les valeurs propres de A sont ≥ 0 ;
- 3 Les espaces propres de A sont deux à deux orthogonaux.

Propriété

Soit X une matrice $n \times p$. Alors

- 1 la matrice $X'X = \Sigma$ de dimension $p \times p$ est semi-définie positive.
- 2 la matrice $XX' = A$ de dimension $n \times n$ est semi-définie positive.
- 3 Σ et A ont les **mêmes valeurs propres non nulles**.

1 Introduction

2 La statistique exploratoire

- Etude d'une variable
- Etude de deux variables
- Etude de plus de deux variables

3 L'analyse en composantes principales

- Quelques rappels d'algèbre linéaire
- **Introduction à l'ACP - Réduction de la dimension**
- Analyse du nuage des individus
 - Recherche des axes factoriels
 - Contributions et qualités de représentation
- Analyse du nuage des variables

- Tableau des données

$$X = \begin{matrix} & X_1 & \dots & X_p \\ e_1 & (x_{1,1} & \dots & x_{1,p}) \\ \vdots & \vdots & & \vdots \\ e_n & (x_{n,1} & \dots & x_{n,p}) \end{matrix}$$

- $e_i = (x_{i,1}, \dots, x_{i,p})'$ l'individu i et $X_j = (x_{1,j}, \dots, x_{n,j})'$ la variable j .
- $e_i \in \mathbb{R}^p$, la représentation de l'ensemble des individus est un nuage de points dans \mathbb{R}^p , appelé **nuage des individus**, \mathcal{N} .
- $X_j \in \mathbb{R}^n$, la représentation de l'ensemble des variables est un nuage de points dans \mathbb{R}^n , appelé **nuage des variables**, \mathcal{M} .

Si l'œil était capable de **visualiser dans \mathbb{R}^n et \mathbb{R}^p** , il n'y aurait pas de problème...

- Tableau des données

$$X = \begin{matrix} & X_1 & \dots & X_p \\ e_1 & (x_{1,1} & \dots & x_{1,p}) \\ \vdots & \vdots & & \vdots \\ e_n & (x_{n,1} & \dots & x_{n,p}) \end{matrix}$$

- $e_i = (x_{i,1}, \dots, x_{i,p})'$ l'individu i et $X_j = (x_{1,j}, \dots, x_{n,j})'$ la variable j .
- $e_i \in \mathbb{R}^p$, la représentation de l'ensemble des individus est un nuage de points dans \mathbb{R}^p , appelé **nuage des individus**, \mathcal{N} .
- $X_j \in \mathbb{R}^n$, la représentation de l'ensemble des variables est un nuage de points dans \mathbb{R}^n , appelé **nuage des variables**, \mathcal{M} .

Si l'œil était capable de **visualiser dans \mathbb{R}^n et \mathbb{R}^p** , il n'y aurait pas de problème...

- Tableau des données

$$X = \begin{matrix} & X_1 & \dots & X_p \\ e_1 & (x_{1,1} & \dots & x_{1,p}) \\ \vdots & \vdots & & \vdots \\ e_n & (x_{n,1} & \dots & x_{n,p}) \end{matrix}$$

- $e_i = (x_{i,1}, \dots, x_{i,p})'$ l'individu i et $X_j = (x_{1,j}, \dots, x_{n,j})'$ la variable j .
- $e_i \in \mathbb{R}^p$, la représentation de l'ensemble des individus est un nuage de points dans \mathbb{R}^p , appelé **nuage des individus**, \mathcal{N} .
- $X_j \in \mathbb{R}^n$, la représentation de l'ensemble des variables est un nuage de points dans \mathbb{R}^n , appelé **nuage des variables**, \mathcal{M} .

Si l'œil était capable de visualiser dans \mathbb{R}^n et \mathbb{R}^p , il n'y aurait pas de problème...

- Tableau des données

$$X = \begin{matrix} & X_1 & \dots & X_p \\ e_1 & (x_{1,1} & \dots & x_{1,p}) \\ \vdots & \vdots & & \vdots \\ e_n & (x_{n,1} & \dots & x_{n,p}) \end{matrix}$$

- $e_i = (x_{i,1}, \dots, x_{i,p})'$ l'individu i et $X_j = (x_{1,j}, \dots, x_{n,j})'$ la variable j .
- $e_i \in \mathbb{R}^p$, la représentation de l'ensemble des individus est un nuage de points dans \mathbb{R}^p , appelé **nuage des individus**, \mathcal{N} .
- $X_j \in \mathbb{R}^n$, la représentation de l'ensemble des variables est un nuage de points dans \mathbb{R}^n , appelé **nuage des variables**, \mathcal{M} .

Si l'œil était capable de visualiser dans \mathbb{R}^n et \mathbb{R}^p , il n'y aurait pas de problème...

Objectifs

Déterminer un **sous-espace de dimension réduite** qui soit "compréhensible" par l'œil sur lequel projeter le nuage.

Un exemple "jouet"

Ménage	Revenu	nb pièces	nb enfants
A	10 000	1	1
B	10 000	2	1
C	10 000	2	3
D	10 000	1	3
E	70 000	2	2




Objectifs

Déterminer un **sous-espace de dimension réduite** qui soit "compréhensible" par l'œil sur lequel projeter le nuage.

Un exemple "jouet"



Ménage	Revenu	nb pièces	nb enfants
A	10 000	1	1
B	10 000	2	1
C	10 000	2	3
D	10 000	1	3
E	70 000	2	2

Diverses représentations



Fonction PCA

On obtient sur R avec la fonction **PCA** : `res <- PCA(D)`



Le **plan de projection** est ici défini par $\mathcal{P} = \text{vect}(u_1, u_2)$ avec $u_1 = X_1 + X_2$ et $u_2 = X_3$.

1 Introduction

2 La statistique exploratoire

- Etude d'une variable
- Etude de deux variables
- Etude de plus de deux variables

3 L'analyse en composantes principales

- Quelques rappels d'algèbre linéaire
- Introduction à l'ACP - Réduction de la dimension
- **Analyse du nuage des individus**
 - Recherche des axes factoriels
 - Contributions et qualités de représentation
- Analyse du nuage des variables

On se place dans l'espace \mathbb{R}^p muni de la distance euclidienne :

- $\langle e_i, e_j \rangle = \sum_{k=1}^p x_{i,k} x_{j,k}$
- $\|e_i\|^2 = \sum_{k=1}^p e_{i,k}^2$
- $d(e_i, e_j)^2 = \sum_{k=1}^p (x_{i,k} - x_{j,k})^2 = \|e_i - e_j\|^2$

Centrage des données :

- Soit $G = \frac{1}{n} \sum_{i=1}^n e_i = (\bar{X}_1, \dots, \bar{X}_p)'$ le centre de gravité du nuage des individus.
- Pour simplifier l'écriture de la méthode, on centre le nuage :

$$e_j^c = \begin{pmatrix} x_{j,1} - \bar{X}_1 \\ \vdots \\ x_{j,p} - \bar{X}_p \end{pmatrix} \quad \text{et} \quad \mathcal{N}^c = \{e_1^c, \dots, e_n^c\}.$$

On se place dans l'espace \mathbb{R}^p muni de la distance euclidienne :

- $\langle e_i, e_j \rangle = \sum_{k=1}^p x_{i,k} x_{j,k}$
- $\|e_i\|^2 = \sum_{k=1}^p e_{i,k}^2$
- $d(e_i, e_j)^2 = \sum_{k=1}^p (x_{i,k} - x_{j,k})^2 = \|e_i - e_j\|^2$

Centrage des données :

- Soit $G = \frac{1}{n} \sum_{i=1}^n e_i = (\bar{X}_1, \dots, \bar{X}_p)'$ le centre de gravité du nuage des individus.
- Pour simplifier l'écriture de la méthode, on centre le nuage :

$$e_i^c = \begin{pmatrix} x_{i,1} - \bar{X}_1 \\ \vdots \\ x_{i,p} - \bar{X}_p \end{pmatrix} \quad \text{et} \quad \mathcal{N}^c = \{e_1^c, \dots, e_n^c\}.$$

Idée

Chercher à projeter les observations dans un sous-espace \mathcal{F} visible à l'œil qui "restitue au mieux" l'information contenue dans le tableau.

L'inertie

- On appelle **inertie totale** du nuage de points \mathcal{N}

$$I(\mathcal{N}) = \frac{1}{n} \sum_{i=1}^n d(e_i, G)^2 = \frac{1}{n} \sum_{i=1}^n \|e_i - G\|^2 = \frac{1}{n} \sum_{i=1}^n \|e_i^c\|^2 = I(\mathcal{N}^c).$$

- On appelle **inertie portée par un sous espace \mathcal{F}** du nuage de points \mathcal{N}

$$I_{\mathcal{F}}(\mathcal{N}) = \frac{1}{n} \sum_{i=1}^n \|P_{\mathcal{F}}(e_i^c)\|^2,$$

où $P_{\mathcal{F}}(\cdot)$ est la projection orthogonale sur \mathcal{F} .

Idée

Chercher à projeter les observations dans un sous-espace \mathcal{F} visible à l'œil qui "restitue au mieux" l'information contenue dans le tableau.

L'inertie

- On appelle **inertie totale** du nuage de points \mathcal{N}

$$I(\mathcal{N}) = \frac{1}{n} \sum_{i=1}^n d(e_i, G)^2 = \frac{1}{n} \sum_{i=1}^n \|e_i - G\|^2 = \frac{1}{n} \sum_{i=1}^n \|e_i^c\|^2 = I(\mathcal{N}^c).$$

- On appelle **inertie portée par un sous espace \mathcal{F}** du nuage de points \mathcal{N}

$$I_{\mathcal{F}}(\mathcal{N}) = \frac{1}{n} \sum_{i=1}^n \|P_{\mathcal{F}}(e_i^c)\|^2,$$

où $P_{\mathcal{F}}(\cdot)$ est la projection orthogonale sur \mathcal{F} .

Idée

Chercher à projeter les observations dans un sous-espace \mathcal{F} visible à l'œil qui "restitue au mieux" l'information contenue dans le tableau.

L'inertie

- On appelle **inertie totale** du nuage de points \mathcal{N}

$$I(\mathcal{N}) = \frac{1}{n} \sum_{i=1}^n d(e_i, G)^2 = \frac{1}{n} \sum_{i=1}^n \|e_i - G\|^2 = \frac{1}{n} \sum_{i=1}^n \|e_i^c\|^2 = I(\mathcal{N}^c).$$

- On appelle **inertie portée par un sous espace \mathcal{F}** du nuage de points \mathcal{N}

$$I_{\mathcal{F}}(\mathcal{N}) = \frac{1}{n} \sum_{i=1}^n \|P_{\mathcal{F}}(e_i^c)\|^2,$$

où $P_{\mathcal{F}}(\cdot)$ est la projection orthogonale sur \mathcal{F} .

- L'ACP permet de prendre en compte une pondération différente des individus : p_i poids de l'individu i tel que $\sum_{i=1}^n p_i = 1$.
- L'inertie est alors définie par $I(\mathcal{N}) = \sum_{i=1}^n p_i d(e_i, G)^2$.
- Dans ce cours, on supposera que tous les individus ont le même poids : $p_i = 1/n, i = 1, \dots, n$.

Il est facile de voir que $I_{\mathcal{F}}(\mathcal{N}) \leq I(\mathcal{N})$: projeter fait perdre de l'inertie.

Objectif

Trouver le sous espace \mathcal{F} qui minimise cette perte d'inertie, ou encore trouver le sous espace \mathcal{F} tel que

$$I_{\mathcal{F}}(\mathcal{N}) \text{ soit maximale.}$$

Un "léger" problème

- 1 Les variables ne sont généralement pas à la même échelle.
- 2 L'inertie est donc généralement "portée" par un sous groupe de variables.
- 3 Sur l'exemple, la variable revenu porte à elle seule la quasi totalité de l'inertie...

Il est facile de voir que $l_{\mathcal{F}}(\mathcal{N}) \leq l(\mathcal{N})$: projeter fait perdre de l'inertie.

Objectif

Trouver le sous espace \mathcal{F} qui minimise cette perte d'inertie, ou encore trouver le sous espace \mathcal{F} tel que

$$l_{\mathcal{F}}(\mathcal{N}) \text{ soit maximale.}$$

Un "léger" problème

- 1 Les variables ne sont généralement pas à la même échelle.
- 2 L'inertie est donc généralement "portée" par un sous groupe de variables.
- 3 Sur l'exemple, la variable revenu porte à elle seule la quasi totalité de l'inertie...

Il est facile de voir que $l_{\mathcal{F}}(\mathcal{N}) \leq l(\mathcal{N})$: projeter fait perdre de l'inertie.

Objectif


Trouver le sous espace \mathcal{F} qui minimise cette perte d'inertie, ou encore trouver le sous espace \mathcal{F} tel que

$$l_{\mathcal{F}}(\mathcal{N}) \text{ soit maximale.}$$


Un "léger" problème

- 1 Les variables ne sont généralement pas à la même échelle.
- 2 L'inertie est donc généralement "portée" par un sous groupe de variables.
- 3 Sur l'exemple, la variable revenu porte à elle seule la quasi totalité de l'inertie...

Individuals factor map (PCA)



Variables factor map (PCA)




Pour pallier à cette difficulté, on **réduit** les données initiales :


$$X = \begin{matrix} & X_1 & \dots & X_p \\ e_1 & \left(\begin{array}{ccc} \tilde{x}_{11} & \dots & \tilde{x}_{1p} \\ \vdots & & \vdots \\ \tilde{x}_{n1} & \dots & \tilde{x}_{np} \end{array} \right) \\ \vdots & & & \\ e_n & & & \end{matrix} \quad \text{avec} \quad \tilde{x}_{ij} = \frac{x_{ij} - \bar{x}_j}{\sigma_j} \quad \text{et} \quad \sigma_j = \sigma(X_j).$$

Avec un léger abus, on note $x_{ij} = \tilde{x}_{ij}$.

Individuals factor map (PCA)



Variables factor map (PCA)



Pour pallier à cette difficulté, on **réduit** les données initiales :

$$X = \begin{matrix} & X_1 & \dots & X_p \\ e_1 & \left(\begin{array}{ccc} \tilde{x}_{11} & \dots & \tilde{x}_{1p} \\ \vdots & & \vdots \\ \tilde{x}_{n1} & \dots & \tilde{x}_{np} \end{array} \right) \\ \vdots & & & \\ e_n & & & \end{matrix} \quad \text{avec} \quad \tilde{x}_{ij} = \frac{x_{ij} - \bar{x}_j}{\sigma_j} \quad \text{et} \quad \sigma_j = \sigma(X_j).$$

Avec un léger abus, on note $x_{ij} = \tilde{x}_{ij}$.

Centrage et réduction

- On rappelle que

	revenu	pieces	enfants
A	10000	1	1
B	10000	2	1
C	10000	2	3
D	10000	1	3
E	70000	2	2
μ	22000.0	1.6	2.0
σ	24 000	0.4898979	0.8944272

- On obtient après **centrage et réduction**

	revenu	pieces	enfants
A	-0.5	-1.2247449	-1.118034
B	-0.5	0.8164966	-1.118034
C	-0.5	0.8164966	1.118034
D	-0.5	-1.2247449	1.118034
E	2.0	0.8164966	0.000000
μ	0	0	0
σ	1	1	1

- On rappelle que

	revenu	pieces	enfants
A	10000	1	1
B	10000	2	1
C	10000	2	3
D	10000	1	3
E	70000	2	2
μ	22000.0	1.6	2.0
σ	24 000	0.4898979	0.8944272

- On obtient après **centrage et réduction**

	revenu	pieces	enfants
A	-0.5	-1.2247449	-1.118034
B	-0.5	0.8164966	-1.118034
C	-0.5	0.8164966	1.118034
D	-0.5	-1.2247449	1.118034
E	2.0	0.8164966	0.000000
μ	0	0	0
σ	1	1	1

"Meilleur" sous-espace de dimension 1

Il s'agit de chercher une droite vectorielle Δ_1 dirigée par un **vecteur unitaire** $u_1 \in \mathbb{R}^p$ telle que $I_{\Delta_1}(\mathcal{N})$ soit **maximale**.

Propriété

- $I_{\Delta_1}(\mathcal{N}) = \frac{1}{n} \sum_{i=1}^n \langle e_i, u_1 \rangle^2 = \frac{1}{n} C_1' C_1$ où

$$C_1 = (\langle e_1, u_1 \rangle, \dots, \langle e_n, u_1 \rangle)' = Xu_1.$$

Le problème mathématique

Chercher u_1 unitaire qui maximise $I_{\Delta_1}(\mathcal{N})$ revient à résoudre le **problème d'optimisation** suivant :

$$\text{maximiser } \frac{1}{n} u_1' X' X u_1 \text{ sous la contrainte } \|u_1\| = 1.$$

"Meilleur" sous-espace de dimension 1

Il s'agit de chercher une droite vectorielle Δ_1 dirigée par un **vecteur unitaire** $u_1 \in \mathbb{R}^p$ telle que $I_{\Delta_1}(\mathcal{N})$ soit **maximale**.

Propriété

- $I_{\Delta_1}(\mathcal{N}) = \frac{1}{n} \sum_{i=1}^n \langle e_i, u_1 \rangle^2 = \frac{1}{n} C_1' C_1$ où

$$C_1 = (\langle e_1, u_1 \rangle, \dots, \langle e_n, u_1 \rangle)' = Xu_1.$$

Le problème mathématique

Chercher u_1 unitaire qui maximise $I_{\Delta_1}(\mathcal{N})$ revient à résoudre le **problème d'optimisation** suivant :

$$\text{maximiser } \frac{1}{n} u_1' X' X u_1 \text{ sous la contrainte } \|u_1\| = 1.$$

"Meilleur" sous-espace de dimension 1

Il s'agit de chercher une droite vectorielle Δ_1 dirigée par un **vecteur unitaire** $u_1 \in \mathbb{R}^p$ telle que $I_{\Delta_1}(\mathcal{N})$ soit **maximale**.

Propriété

- $I_{\Delta_1}(\mathcal{N}) = \frac{1}{n} \sum_{i=1}^n \langle e_i, u_1 \rangle^2 = \frac{1}{n} C_1' C_1$ où

$$C_1 = (\langle e_1, u_1 \rangle, \dots, \langle e_n, u_1 \rangle)' = Xu_1.$$

Le problème mathématique

Chercher u_1 unitaire qui maximise $I_{\Delta_1}(\mathcal{N})$ revient à résoudre le **problème d'optimisation** suivant :

$$\text{maximiser } \frac{1}{n} u_1' X' X u_1 \text{ sous la contrainte } \|u_1\| = 1.$$

Propriété

Un vecteur propre unitaire u_1 rendant l'inertie $I_{\Delta_1}(\mathcal{N})$ maximale est un vecteur propre normé associé à la **plus grande valeur propre** λ_1 de la matrice $\Sigma = \frac{1}{n}X'X$.

Remarques

- La matrice d'inertie $\Sigma = \frac{1}{n}X'X$ étant symétrique et définie positive, elle est diagonalisable et **toutes ses valeurs propres sont positives ou nulles**.
- u_1 est appelé **premier axe factoriel**.

Propriété

Un vecteur propre unitaire u_1 rendant l'inertie $I_{\Delta_1}(\mathcal{N})$ maximale est un vecteur propre normé associé à la **plus grande valeur propre** λ_1 de la matrice $\Sigma = \frac{1}{n}X'X$.

Remarques

- La matrice d'inertie $\Sigma = \frac{1}{n}X'X$ étant symétrique et définie positive, elle est diagonalisable et **toutes ses valeurs propres sont positives ou nulles**.
- u_1 est appelé **premier axe factoriel**.

Exemple

Sur l'exemple "jouet", on a

$$\frac{1}{n}X'X = \begin{pmatrix} 1.0000000 & 0.4082483 & 0.000000e + 00 \\ 0.4082483 & 1.0000000 & 3.144186e - 18 \\ 0.0000000 & 0.0000000 & 1.000000e + 00 \end{pmatrix}$$

D'où

```
$values  
[1] 1.4082483 1.0000000 0.5917517
```

```
$vectors  
      [,1] [,2] [,3]  
[1,] 0.7071068  0  0.7071068  
[2,] 0.7071068  0 -0.7071068  
[3,] 0.0000000  1  0.0000000
```

On obtient les coordonnées des individus sur le premier axe

```
> X%*%u1 #coordonnées des individus sur les axes  
      [,1]  
A -1.2195788  
B  0.2237969  
C  0.2237969  
D -1.2195788  
E  1.9915638
```

Sur l'exemple "jouet", on a

$$\frac{1}{n}X'X = \begin{pmatrix} 1.0000000 & 0.4082483 & 0.000000e + 00 \\ 0.4082483 & 1.0000000 & 3.144186e - 18 \\ 0.0000000 & 0.0000000 & 1.000000e + 00 \end{pmatrix}$$

D'où

```
$values  
[1] 1.4082483 1.0000000 0.5917517
```

```
$vectors  
      [,1] [,2] [,3]  
[1,] 0.7071068  0  0.7071068  
[2,] 0.7071068  0 -0.7071068  
[3,] 0.0000000  1  0.0000000
```

On obtient les coordonnées des individus sur le premier axe

```
> X%*%u1 #coordonnées des individus sur les axes  
      [,1]  
A -1.2195788  
B  0.2237969  
C  0.2237969  
D -1.2195788  
E  1.9915638
```

Problème

Trouver une droite vectorielle Δ_2 dirigée par un **vecteur normé** u_2 telle que

$$\begin{cases} I_{\Delta_2}(\mathcal{N}) = u_2' \Sigma u_2 \text{ maximale} \\ \|u_2\|^2 = u_2' u_2 = 1 \\ \langle u_2, u_1 \rangle = u_2' u_1 = 0 \end{cases}$$

Solution

Un vecteur unitaire u_2 solution du problème précédent est un vecteur propre normé associé à la **deuxième plus grande valeur propre** λ_2 de la matrice $\Sigma = \frac{1}{n} X' X$.

Question

Le plan $\text{vect}(u_1, u_2)$ est-il le meilleur sous-espace de dimension 2 en terme de maximisation d'inertie projetée ?

Réponse

La réponse est oui ! On déduit ainsi qu'un sous-espace de dimension $q < p$ qui maximise l'inertie projetée est donné par $\text{vect}(u_1, \dots, u_q)$ où u_j est un vecteur normé associé à la $j^{\text{ème}}$ plus grande valeur propre λ_j de $\Sigma = \frac{1}{n}X'X$.

Conclusion : chercher les axes factoriels revient à diagonaliser $\Sigma = \frac{1}{n}X'X$.

Question

Le plan $\text{vect}(u_1, u_2)$ est-il le meilleur sous-espace de dimension 2 en terme de maximisation d'inertie projetée ?

Réponse

La réponse est oui ! On déduit ainsi qu'un sous-espace de dimension $q < p$ qui maximise l'inertie projetée est donné par $\text{vect}(u_1, \dots, u_q)$ où u_j est un vecteur normé associé à la $j^{\text{ème}}$ plus grande valeur propre λ_j de $\Sigma = \frac{1}{n}X'X$.

Conclusion : chercher les axes factoriels revient à diagonaliser $\Sigma = \frac{1}{n}X'X$.

Question

Le plan $\text{vect}(u_1, u_2)$ est-il le meilleur sous-espace de dimension 2 en terme de maximisation d'inertie projetée ?

Réponse

La réponse est oui ! On déduit ainsi qu'un sous-espace de dimension $q < p$ qui maximise l'inertie projetée est donné par $\text{vect}(u_1, \dots, u_q)$ où u_j est un vecteur normé associé à la $j^{\text{ème}}$ plus grande valeur propre λ_j de $\Sigma = \frac{1}{n}X'X$.

Conclusion : chercher les axes factoriels revient à diagonaliser $\Sigma = \frac{1}{n}X'X$.

ACP \approx changement de base

Base canonique

$$X = \begin{pmatrix} X_1 & \dots & X_p \\ X_{11} & \dots & X_{1p} \\ \vdots & \vdots & \vdots \\ X_{n1} & \dots & X_{np} \end{pmatrix}$$

Base $\{u_1, \dots, u_p\}$

$$X = \begin{pmatrix} C_1 & \dots & C_p \\ C_{11} & \dots & C_{1p} \\ \vdots & \vdots & \vdots \\ C_{n1} & \dots & C_{np} \end{pmatrix}$$

Propriété

- 1 $C_j = Xu_j = \sum_{k=1}^p u_{kj}X_k$
- 2 C_j centrée et $\mathbf{V}(C_j) = \frac{1}{n}\|C_j\|^2 = \lambda_j = l_{\Delta_j}(\mathcal{N})$.
- 3 $\rho(C_j, C_k) = 0$ pour $k \neq j$.

Conclusion

L'ACP normée remplace les variables d'origines X_j par de nouvelles variables C_j appelées **composantes principales**, de variance maximale, non corrélées deux à deux et qui s'expriment comme combinaison linéaire des variables d'origine.

ACP \approx changement de base

Base canonique

$$X = \begin{pmatrix} X_1 & \dots & X_p \\ X_{11} & \dots & X_{1p} \\ \vdots & \vdots & \vdots \\ X_{n1} & \dots & X_{np} \end{pmatrix}$$

Base $\{u_1, \dots, u_p\}$

$$X = \begin{pmatrix} C_1 & \dots & C_p \\ C_{11} & \dots & C_{1p} \\ \vdots & \vdots & \vdots \\ C_{n1} & \dots & C_{np} \end{pmatrix}$$

Propriété

- 1 $C_j = Xu_j = \sum_{k=1}^p u_{kj} X_k$
- 2 C_j centrée et $V(C_j) = \frac{1}{n} \|C_j\|^2 = \lambda_j = l_{\Delta_j}(\mathcal{N})$.
- 3 $\rho(C_j, C_k) = 0$ pour $k \neq j$.

Conclusion

L'ACP normée remplace les variables d'origines X_j par de nouvelles variables C_j appelées **composantes principales**, de variance maximale, non corrélées deux à deux et qui s'expriment comme combinaison linéaire des variables d'origine.

ACP \approx changement de base

Base canonique

$$X = \begin{pmatrix} X_1 & \dots & X_p \\ X_{11} & \dots & X_{1p} \\ \vdots & \vdots & \vdots \\ X_{n1} & \dots & X_{np} \end{pmatrix}$$

Base $\{u_1, \dots, u_p\}$

$$X = \begin{pmatrix} C_1 & \dots & C_p \\ C_{11} & \dots & C_{1p} \\ \vdots & \vdots & \vdots \\ C_{n1} & \dots & C_{np} \end{pmatrix}$$

Propriété

- 1 $C_j = Xu_j = \sum_{k=1}^p u_{kj} X_k$
- 2 C_j centrée et $\mathbf{V}(C_j) = \frac{1}{n} \|C_j\|^2 = \lambda_j = I_{\Delta_j}(\mathcal{N})$.
- 3 $\rho(C_j, C_k) = 0$ pour $k \neq j$.

Conclusion

L'ACP normée remplace les variables d'origines X_j par de nouvelles variables C_j appelées **composantes principales**, de variance maximale, non corrélées deux à deux et qui s'expriment comme combinaison linéaire des variables d'origine.

ACP \approx changement de base

Base canonique

$$X = \begin{pmatrix} X_1 & \dots & X_p \\ X_{11} & \dots & X_{1p} \\ \vdots & \vdots & \vdots \\ X_{n1} & \dots & X_{np} \end{pmatrix}$$

Base $\{u_1, \dots, u_p\}$

$$X = \begin{pmatrix} C_1 & \dots & C_p \\ C_{11} & \dots & C_{1p} \\ \vdots & \vdots & \vdots \\ C_{n1} & \dots & C_{np} \end{pmatrix}$$

Propriété

- 1 $C_j = Xu_j = \sum_{k=1}^p u_{kj} X_k$
- 2 C_j centrée et $\mathbf{V}(C_j) = \frac{1}{n} \|C_j\|^2 = \lambda_j = I_{\Delta_j}(\mathcal{N})$.
- 3 $\rho(C_j, C_k) = 0$ pour $k \neq j$.

Conclusion

L'ACP normée remplace les variables d'origines X_j par de nouvelles variables C_j appelées **composantes principales**, de variance maximale, non corrélées deux à deux et qui s'expriment comme combinaison linéaire des variables d'origine.

ACP \approx changement de base

Base canonique

$$X = \begin{pmatrix} X_1 & \dots & X_p \\ X_{11} & \dots & X_{1p} \\ \vdots & \vdots & \vdots \\ X_{n1} & \dots & X_{np} \end{pmatrix}$$

Base $\{u_1, \dots, u_p\}$

$$X = \begin{pmatrix} C_1 & \dots & C_p \\ C_{11} & \dots & C_{1p} \\ \vdots & \vdots & \vdots \\ C_{n1} & \dots & C_{np} \end{pmatrix}$$

Propriété

- 1 $C_j = Xu_j = \sum_{k=1}^p u_{kj}X_k$
- 2 C_j centrée et $\mathbf{V}(C_j) = \frac{1}{n}\|C_j\|^2 = \lambda_j = I_{\Delta_j}(\mathcal{N})$.
- 3 $\rho(C_j, C_k) = 0$ pour $k \neq j$.

Conclusion

L'ACP normée remplace les variables d'origines X_j par de nouvelles variables C_j appelées **composantes principales**, de variance maximale, non corrélées deux à deux et qui s'expriment comme combinaison linéaire des variables d'origine.

Calculer les axes factoriels n'est pas difficile. Il reste néanmoins plusieurs problèmes à régler pour mener l'analyse :

- 1 Comment **choisir le sous-espace** ? (Ou encore, combien d'axes factoriels doit-on retenir ?)
- 2 Comment mesurer la **qualité de représentation** d'un individu sur le sous-espace choisi ?
- 3 Comment **interpréter** les axes ?

Calculer les axes factoriels n'est pas difficile. Il reste néanmoins plusieurs problèmes à régler pour mener l'analyse :

- 1 Comment **choisir le sous-espace** ? (Ou encore, combien d'axes factoriels doit-on retenir ?)
- 2 Comment mesurer la **qualité de représentation** d'un individu sur le sous-espace choisi ?
- 3 Comment **interpréter** les axes ?

Calculer les axes factoriels n'est pas difficile. Il reste néanmoins plusieurs problèmes à régler pour mener l'analyse :

- 1 Comment **choisir le sous-espace** ? (Ou encore, combien d'axes factoriels doit-on retenir ?)
- 2 Comment mesurer la **qualité de représentation** d'un individu sur le sous-espace choisi ?
- 3 Comment **interpréter** les axes ?

Propriétés

- 1 $I(\mathcal{N}) = \text{tr}(\Sigma) = \sum_{j=1}^p \lambda_j.$
- 2 $I_{\Delta_j}(\mathcal{N}) = \lambda_j.$
- 3 L'inertie est **additive** : si on note \mathcal{F}_k le sous espace de \mathbb{R}^p engendré par les k premiers vecteurs propres associés aux k plus grandes valeurs propres de Σ , alors

$$I_{\mathcal{F}_k}(\mathcal{N}) = \sum_{j=1}^k \lambda_j.$$

Définitions

- La **contribution à l'inertie** de l'axe Δ_k est $\lambda_k.$
- La **contribution relative à l'inertie** de l'axe Δ_k est $\lambda_k / \sum_{j=1}^p \lambda_j.$
- La **contribution relative à l'inertie** du plan (Δ_j, Δ_k) est $(\lambda_j + \lambda_k) / \sum_{j=1}^p \lambda_j.$

Propriétés

- 1 $I(\mathcal{N}) = \text{tr}(\Sigma) = \sum_{j=1}^p \lambda_j.$
- 2 $I_{\Delta_j}(\mathcal{N}) = \lambda_j.$
- 3 L'inertie est **additive** : si on note \mathcal{F}_k le sous espace de \mathbb{R}^p engendré par les k premiers vecteurs propres associés aux k plus grandes valeurs propres de Σ , alors

$$I_{\mathcal{F}_k}(\mathcal{N}) = \sum_{j=1}^k \lambda_j.$$

Définitions

- La **contribution à l'inertie** de l'axe Δ_k est $\lambda_k.$
- La **contribution relative à l'inertie** de l'axe Δ_k est $\lambda_k / \sum_{j=1}^p \lambda_j.$
- La **contribution relative à l'inertie** du plan (Δ_j, Δ_k) est $(\lambda_j + \lambda_k) / \sum_{j=1}^p \lambda_j.$

Propriétés

- 1 $I(\mathcal{N}) = \text{tr}(\Sigma) = \sum_{j=1}^p \lambda_j.$
- 2 $I_{\Delta_j}(\mathcal{N}) = \lambda_j.$
- 3 L'inertie est **additive** : si on note \mathcal{F}_k le sous espace de \mathbb{R}^p engendré par les k premiers vecteurs propres associés aux k plus grandes valeurs propres de Σ , alors

$$I_{\mathcal{F}_k}(\mathcal{N}) = \sum_{j=1}^k \lambda_j.$$

Définitions

- La **contribution** à l'inertie de l'axe Δ_k est $\lambda_k.$
- La **contribution relative** à l'inertie de l'axe Δ_k est $\lambda_k / \sum_{j=1}^p \lambda_j.$
- La **contribution relative** à l'inertie du plan (Δ_j, Δ_k) est $(\lambda_j + \lambda_k) / \sum_{j=1}^p \lambda_j.$

Propriétés

- 1 $I(\mathcal{N}) = \text{tr}(\Sigma) = \sum_{j=1}^p \lambda_j.$
- 2 $I_{\Delta_j}(\mathcal{N}) = \lambda_j.$
- 3 L'inertie est **additive** : si on note \mathcal{F}_k le sous espace de \mathbb{R}^p engendré par les k premiers vecteurs propres associés aux k plus grandes valeurs propres de Σ , alors

$$I_{\mathcal{F}_k}(\mathcal{N}) = \sum_{j=1}^k \lambda_j.$$

Définitions

- La **contribution à l'inertie** de l'axe Δ_k est $\lambda_k.$
- La **contribution relative à l'inertie** de l'axe Δ_k est $\lambda_k / \sum_{j=1}^p \lambda_j.$
- La **contribution relative à l'inertie** du plan (Δ_j, Δ_k) est $(\lambda_j + \lambda_k) / \sum_{j=1}^p \lambda_j.$

Hélas

Il n'existe **pas de méthodes "universelles"** permettant de choisir le nombre d'axes.

Les critères sont le plus souvent empiriques :

- Pourcentage d'inertie **reconstitué par le sous-espace sélectionné.**
- Etudier la **décroissance des valeurs propres** (critère dit "du coude").


Hélas

Il n'existe **pas de méthodes "universelles"** permettant de choisir le nombre d'axes.

Les critères sont le plus souvent empiriques :

- Pourcentage d'inertie **reconstitué par le sous-espace sélectionné.**
- Etudier la **décroissance des valeurs propres** (critère dit "du coude").


Exemple du décathlon



	eigenvalue	percentage of variance	cumulative percentage of variance
comp 1	3.27	32.72	32.72
comp 2	1.74	17.37	50.09
comp 3	1.40	14.05	64.14
comp 4	1.06	10.57	74.71
comp 5	0.68	6.85	81.56
comp 6	0.60	5.99	87.55
comp 7	0.45	4.51	92.06
comp 8	0.40	3.97	96.03
comp 9	0.21	2.15	98.18
comp 10	0.18	1.82	100.00

Il semble que retenir 4 axes puisse être un choix intéressant.

Exemple du décathlon



	eigenvalue	percentage of variance	cumulative percentage of variance
comp 1	3.27	32.72	32.72
comp 2	1.74	17.37	50.09
comp 3	1.40	14.05	64.14
comp 4	1.06	10.57	74.71
comp 5	0.68	6.85	81.56
comp 6	0.60	5.99	87.55
comp 7	0.45	4.51	92.06
comp 8	0.40	3.97	96.03
comp 9	0.21	2.15	98.18
comp 10	0.18	1.82	100.00

Il semble que retenir **4 axes** puisse être un choix intéressant.

Questions

- 1 Quels individus ont le plus **contribué** à la formation des axes factoriels ?
- 2 Quels individus sont bien **représentés** par les axes factoriels ?

Solutions

- 1 Comme $I_{\Delta_j}(\mathcal{N}) = \frac{1}{n} C_j' C_j = \frac{1}{n} \sum_{i=1}^n c_{ij}^2 = \lambda_j$, on mesure la contribution de l'individu i à l'axe j par

$$CR_j(i) = \frac{c_{ij}^2}{n\lambda_j}.$$

- 2 Un individu e_i sera bien représenté par un axe Δ_j si il est "**proche**" de son **projeté** sur Δ_j , ou encore si le cosinus de l'angle $\theta_{ij} = (\widehat{e_i, u_j})$ est proche de 1 ou -1 .

Questions

- 1 Quels individus ont le plus **contribué** à la formation des axes factoriels ?
- 2 Quels individus sont bien **représentés** par les axes factoriels ?

Solutions

- 1 Comme $I_{\Delta_j}(\mathcal{N}) = \frac{1}{n} C_j' C_j = \frac{1}{n} \sum_{i=1}^n c_{ij}^2 = \lambda_j$, on mesure la contribution de l'individu i à l'axe j par

$$CR_j(i) = \frac{c_{ij}^2}{n\lambda_j}.$$

- 2 Un individu e_i sera bien représenté par un axe Δ_j si il est "**proche**" de son **projeté** sur Δ_j , ou encore si le cosinus de l'angle $\theta_{ij} = \widehat{(e_i, u_j)}$ est proche de 1 ou -1 .

Questions

- 1 Quels individus ont le plus **contribué** à la formation des axes factoriels ?
- 2 Quels individus sont bien **représentés** par les axes factoriels ?

Solutions

- 1 Comme $I_{\Delta_j}(\mathcal{N}) = \frac{1}{n} C_j' C_j = \frac{1}{n} \sum_{i=1}^n c_{ij}^2 = \lambda_j$, on mesure la contribution de l'individu i à l'axe j par

$$CR_j(i) = \frac{c_{ij}^2}{n\lambda_j}.$$

- 2 Un individu e_i sera bien représenté par un axe Δ_j si il est **"proche"** de **son projeté** sur Δ_j , ou encore si le cosinus de l'angle $\theta_{ij} = (\widehat{e_i, u_j})$ est proche de 1 ou -1 .

Solutions (suite)

La **qualité de représentation** de l'individu e_i sur l'**axe** u_j est ainsi mesurée par

$$\text{qlt}_j(i) = \cos^2 \theta_{ij} = \frac{\|P_{\Delta_j}(e_i)\|^2}{\|e_i\|^2}.$$

De même la qualité de représentation de e_i sur le **plan** $\mathcal{F} = (\Delta_j, \Delta_k)$ est mesurée par

$$\text{qlt}_{\mathcal{F}}(i) = \frac{\|P_{\mathcal{F}}(e_i)\|^2}{\|e_i\|^2}.$$

Propriétés

Le cosinus carré étant additif sur des sous-espaces orthogonaux, on déduit

$$\text{qlt}_{\mathcal{F}}(i) = \frac{\|P_{\Delta_j}(e_i)\|^2 + \|P_{\Delta_k}(e_i)\|^2}{\|e_i\|^2}.$$

Solutions (suite)

La **qualité de représentation** de l'individu e_i sur l'**axe** u_j est ainsi mesurée par

$$\text{qlt}_j(i) = \cos^2 \theta_{ij} = \frac{\|P_{\Delta_j}(e_i)\|^2}{\|e_i\|^2}.$$

De même la qualité de représentation de e_i sur le **plan** $\mathcal{F} = (\Delta_j, \Delta_k)$ est mesurée par

$$\text{qlt}_{\mathcal{F}}(i) = \frac{\|P_{\mathcal{F}}(e_i)\|^2}{\|e_i\|^2}.$$

Propriétés

Le cosinus carré étant additif sur des sous-espaces orthogonaux, on déduit

$$\text{qlt}_{\mathcal{F}}(i) = \frac{\|P_{\Delta_j}(e_i)\|^2 + \|P_{\Delta_k}(e_i)\|^2}{\|e_i\|^2}.$$

Solutions (suite)

La **qualité de représentation** de l'individu e_i sur l'**axe** u_j est ainsi mesurée par

$$\text{qlt}_j(i) = \cos^2 \theta_{ij} = \frac{\|P_{\Delta_j}(e_i)\|^2}{\|e_i\|^2}.$$

De même la qualité de représentation de e_i sur le **plan** $\mathcal{F} = (\Delta_j, \Delta_k)$ est mesurée par


$$\text{qlt}_{\mathcal{F}}(i) = \frac{\|P_{\mathcal{F}}(e_i)\|^2}{\|e_i\|^2}.$$

Propriétés

Le cosinus carré étant additif sur des sous-espaces orthogonaux, on déduit

$$\text{qlt}_{\mathcal{F}}(i) = \frac{\|P_{\Delta_j}(e_i)\|^2 + \|P_{\Delta_k}(e_i)\|^2}{\|e_i\|^2}.$$


Exemple



```
> res$ind$contrib
      Dim.1      Dim.2      Dim.3
A 21.1237244 2.500000e+01 8.876276
B  0.7113098 2.500000e+01 29.288690
C  0.7113098 2.500000e+01 29.288690
D 21.1237244 2.500000e+01 8.876276
E 56.3299316 3.081488e-31 23.670068
```

```
> res$ind$cos2
      Dim.1      Dim.2      Dim.3
A 0.49579081 4.166667e-01 0.08754252
B 0.02311617 5.769231e-01 0.39996075
C 0.02311617 5.769231e-01 0.39996075
D 0.49579081 4.166667e-01 0.08754252
E 0.84992711 3.301594e-33 0.15007289
```


Exemple




```
> res.pca$ind$contrib[1:5,1:2]
          Dim.1    Dim.2
Sebrle  12.157506  2.619234357
Clay    11.451090  0.983545343
Karpov  15.910981  0.002245949
Macey   3.718536  1.523786399
Warners 3.505038  4.565322740
```

```
> res.pca$ind$cos2[1:5,1:2]
          Dim.1    Dim.2
Sebrle  0.6954102  7.954314e-02
Clay    0.7112052  3.243204e-02
Karpov  0.8517553  6.383365e-05
Macey   0.4230486  9.203950e-02
Warners 0.5299437  3.664716e-01
```

Comment interpréter les positions des individus ?

Exemple



```
> res.pca$ind$contrib[1:5,1:2]
          Dim.1  Dim.2
Sebrle 12.157506 2.619234357
Clay   11.451090 0.983545343
Karpov 15.910981 0.002245949
Macey  3.718536 1.523786399
Warners 3.505038 4.565322740
```

```
> res.pca$ind$cos2[1:5,1:2]
          Dim.1  Dim.2
Sebrle 0.6954102 7.954314e-02
Clay   0.7112052 3.243204e-02
Karpov 0.8517553 6.383365e-05
Macey  0.4230486 9.203950e-02
Warners 0.5299437 3.664716e-01
```

Comment **interpréter** les positions des individus ?

1 Introduction

2 La statistique exploratoire

- Etude d'une variable
- Etude de deux variables
- Etude de plus de deux variables

3 L'analyse en composantes principales

- Quelques rappels d'algèbre linéaire
- Introduction à l'ACP - Réduction de la dimension
- Analyse du nuage des individus
 - Recherche des axes factoriels
 - Contributions et qualités de représentation
- **Analyse du nuage des variables**

- On s'intéresse maintenant au **nuage des variables** $\{X_1, \dots, X_p\}$, $X_j \in \mathbb{R}^n$.
- Pour prendre en compte les **poids des individus**, on munit \mathbb{R}^n de la métrique $P = \text{diag}(p_1, \dots, p_n)$ (on mène l'analyse avec $p_i = 1/n$)

Conséquence

- 1 $\|X_j\|_P = 1$ et $\cos(X_j, X_k) = \rho(X_j, X_k)$.
- 2 Les variables X_j se trouvent sur la **sphère unité** de \mathbb{R}^n .
- 3 La projection des X_j sur des plans passant par l'origine se trouveront à l'**intérieur du cercle** unité de \mathbb{R}^2 (que nous appellerons cercle des corrélations).

On souhaite transposer l'analyse du nuage des individus à celui des variables (on parle **d'analyse duale**).

- On s'intéresse maintenant au **nuage des variables** $\{X_1, \dots, X_p\}$, $X_j \in \mathbb{R}^n$.
- Pour prendre en compte les **poids des individus**, on munit \mathbb{R}^n de la métrique $P = \text{diag}(p_1, \dots, p_n)$ (on mène l'analyse avec $p_i = 1/n$)

Conséquence

- 1 $\|X_j\|_P = 1$ et $\cos(X_j, X_k) = \rho(X_j, X_k)$.
- 2 Les variables X_j se trouvent sur la **sphère unité** de \mathbb{R}^n .
- 3 La projection des X_j sur des plans passant par l'origine se trouveront à l'**intérieur du cercle** unité de \mathbb{R}^2 (que nous appellerons cercle des corrélations).

On souhaite transposer l'analyse du nuage des individus à celui des variables (on parle **d'analyse duale**).

- On s'intéresse maintenant au **nuage des variables** $\{X_1, \dots, X_p\}$, $X_j \in \mathbb{R}^n$.
- Pour prendre en compte les **poids des individus**, on munit \mathbb{R}^n de la métrique $P = \text{diag}(p_1, \dots, p_n)$ (on mène l'analyse avec $p_i = 1/n$)

Conséquence

- 1 $\|X_j\|_P = 1$ et $\cos(X_j, X_k) = \rho(X_j, X_k)$.
- 2 Les variables X_j se trouvent sur la **sphère unité** de \mathbb{R}^n .
- 3 La projection des X_j sur des plans passant par l'origine se trouveront à l'**intérieur du cercle** unité de \mathbb{R}^2 (que nous appellerons cercle des corrélations).

On souhaite transposer l'analyse du nuage des individus à celui des variables (on parle **d'analyse duale**).

- On s'intéresse maintenant au **nuage des variables** $\{X_1, \dots, X_p\}$, $X_j \in \mathbb{R}^n$.
- Pour prendre en compte les **poids des individus**, on munit \mathbb{R}^n de la métrique $P = \text{diag}(p_1, \dots, p_n)$ (on mène l'analyse avec $p_i = 1/n$)

Conséquence

- 1 $\|X_j\|_P = 1$ et $\cos(X_j, X_k) = \rho(X_j, X_k)$.
- 2 Les variables X_j se trouvent sur la **sphère unité** de \mathbb{R}^n .
- 3 La projection des X_j sur des plans passant par l'origine se trouveront à l'**intérieur du cercle** unité de \mathbb{R}^2 (que nous appellerons cercle des corrélations).

On souhaite transposer l'analyse du nuage des individus à celui des variables (on parle **d'analyse duale**).

Bonheur...

- Les axes factoriels de \mathbb{R}^n (ceux du nuage des variables) se **déduisent** de ceux de \mathbb{R}^p (ceux du nuage des individus).
- Les taux d'inerties sont **identiques** pour des axes du même rang dans les deux analyses.

Propriétés

- 1 $I(\mathcal{N}) = I(\mathcal{M}) = \text{trace}\left(\frac{1}{n}X'X\right) = p$, les deux dernières égalités viennent du fait que la matrice des données est **centrée-réduite**.
- 2 Chercher un vecteur v_1 de \mathbb{R}^n unitaire qui maximise $I_{\text{vect } v_1}(\mathcal{M})$ revient à **résoudre le problème**

$$\text{maximiser } \frac{1}{n} v_1' X X' v_1 \text{ sous la contrainte } \|v_1\|_P = 1$$

- 3 La solution est donnée par un vecteur propre normé de $\frac{1}{n}XX'$ associé à la **plus grande valeur propre** de $\frac{1}{n}XX'$.

Bonheur...

- Les axes factoriels de \mathbb{R}^n (ceux du nuage des variables) se **déduisent** de ceux de \mathbb{R}^p (ceux du nuage des individus).
- Les taux d'inerties sont **identiques** pour des axes du même rang dans les deux analyses.

Propriétés

- 1 $I(\mathcal{N}) = I(\mathcal{M}) = \text{trace}\left(\frac{1}{n}X'X\right) = p$, les deux dernières égalités viennent du fait que la matrice des données est **centrée-réduite**.
- 2 Chercher un vecteur v_1 de \mathbb{R}^n unitaire qui maximise $I_{\text{vect } v_1}(\mathcal{M})$ revient à **résoudre le problème**

$$\text{maximiser } \frac{1}{n}v_1'XX'v_1 \text{ sous la contrainte } \|v_1\|_P = 1$$

- 3 La solution est donnée par un vecteur propre normé de $\frac{1}{n}XX'$ associé à la **plus grande valeur propre** de $\frac{1}{n}XX'$.

Propriétés

- $v_j = \frac{1}{\sqrt{\lambda_j}} X u_j$ et $u_j = \frac{1}{\sqrt{\lambda_j}} X' P v_j$;
- Coordonnées du projeté de X_j projeté $i^{\text{ème}}$ axe :
 - 1 $d_{ij} = \langle X_j, v_i \rangle_P \implies D_j = X' P v_j$
 - 2 $D_j = \frac{1}{\sqrt{\lambda_j}} X' P C_j$ et $C_j = \frac{1}{\sqrt{\lambda_j}} X D_j$.

Propriétés

- $v_j = \frac{1}{\sqrt{\lambda_j}} X u_j$ et $u_j = \frac{1}{\sqrt{\lambda_j}} X' P v_j$;
- Coordonnées du projeté de X_j projeté $i^{\text{ème}}$ axe :
 - 1 $d_{ij} = \langle X_j, v_i \rangle_P \implies D_j = X' P v_j$
 - 2 $D_j = \frac{1}{\sqrt{\lambda_j}} X' P C_j$ et $C_j = \frac{1}{\sqrt{\lambda_j}} X D_j$.

PROPRIETE

$$d_{ij} = \rho(X_j, C_i)$$

Conséquence

- Si d_{ij} est **grand** (proche de 1 ce qui signifie que la projection de la variable est proche du cercle des corrélations), cela signifie que :
 - la $j^{\text{ème}}$ variable est **fortement corrélée** à la $i^{\text{ème}}$ composante principale.
 - les individus qui possèdent une coordonnée élevée sur l'axe i seront parmi ceux possédant une forte valeur de la variable j .
- Cette propriété permet de faire le **lien** entre la représentation du **nuage des variables** et celle du **nuage des individus** sur un plan factoriel.


PROPRIETE

$$d_{ij} = \rho(X_j, C_i)$$


Conséquence

- Si d_{ij} est **grand** (proche de 1 ce qui signifie que la projection de la variable est proche du cercle des corrélations), cela signifie que :
 - la $j^{\text{ème}}$ variable est **fortement corrélée** à la $i^{\text{ème}}$ composante principale.
 - les individus qui possèdent une coordonnée élevée sur l'axe i seront parmi ceux possédant une forte valeur de la variable j .
- Cette propriété permet de faire le **lien** entre la représentation du **nuage des variables** et celle du **nuage des individus** sur un plan factoriel.

Individuals factor map (PCA)




Variables factor map (PCA)




Interprétations

- L'axe 1 oppose les individus possédant des **revenus élevés** et vivant dans de **grands appartements** à des individus plus **pauvres** et vivant dans des appartements **plus petits**.
- L'axe 2 les **grandes familles** aux **petites**.

Individuals factor map (PCA)



Variables factor map (PCA)



Interprétations

- L'axe 1 oppose les individus possédant des **revenus élevés** et vivant dans de **grands appartements** à des individus plus **pauvres** et vivant dans des appartements **plus petits**.
- L'axe 2 les **grandes familles** aux **petites**.

- **Contribution** de la variable j à l'axe i : d_{ij}^2/λ_i car

$$I_{v_i}(\mathcal{M}) = \sum_{j=1}^p (\langle X_j, v_i \rangle_P)^2 = \sum_{j=1}^p d_{ij}^2 = \lambda_i.$$

- **Qualité de représentation** de la variable X_j sur l'axe i :

$$\cos^2(X_j, v_i) = \langle X_j, v_i \rangle_P^2 = d_{ij}^2.$$

- **Corrélations entre variables** : $\rho(X_j, X_k) = \cos(X_j, X_k)$. Donc, sur le cercle des corrélations, deux variable **bien représentées**
 - proches sont fortement corrélées ;
 - qui s'opposent sont négativement corrélées ;
 - orthogonales sont non corrélées.

- **Contribution** de la variable j à l'axe i : d_{ij}^2/λ_i car

$$I_{v_i}(\mathcal{M}) = \sum_{j=1}^p (\langle X_j, v_i \rangle_P)^2 = \sum_{j=1}^p d_{ij}^2 = \lambda_i.$$

- **Qualité de représentation** de la variable X_j sur l'axe i :

$$\cos^2(X_j, v_i) = \langle X_j, v_i \rangle_P^2 = d_{ij}^2.$$

- **Corrélations entre variables** : $\rho(X_j, X_k) = \cos(X_j, X_k)$. Donc, sur le cercle des corrélations, deux variable **bien représentées**
 - proches sont fortement corrélées ;
 - qui s'opposent sont négativement corrélées ;
 - orthogonales sont non corrélées.

- **Contribution** de la variable j à l'axe i : d_{ij}^2/λ_i car

$$I_{v_i}(\mathcal{M}) = \sum_{j=1}^p (\langle X_j, v_i \rangle_P)^2 = \sum_{j=1}^p d_{ij}^2 = \lambda_i.$$

- **Qualité de représentation** de la variable X_j sur l'axe i :

$$\cos^2(X_j, v_i) = \langle X_j, v_i \rangle_P^2 = d_{ij}^2.$$

- **Corrélations entre variables** : $\rho(X_j, X_k) = \cos(X_j, X_k)$. Donc, sur le cercle des corrélations, deux variable **bien représentées**
 - proches sont fortement corrélées ;
 - qui s'opposent sont négativement corrélées ;
 - orthogonales sont non corrélées.

Certaines analyses peuvent être menées en **retirant des variables ou des individus** pour construire les axes de l'ACP :

- individus **aberrants** pouvant "trop" contribuer à l'inertie ;
- variables ayant été **construites à partir d'autres variables** déjà utilisées dans l'analyse. Les variables classement et points sur l'exemple du décathlon.

Une fois l'ACP réalisée, il peut néanmoins être intéressant de visualiser comment ces individus ou variables se situent par rapport aux autres.


La méthode est simple. Il suffit de

- 1 faire subir à ces nouveaux éléments les **mêmes transformations** qu'aux autres (centrage et réduction) ;
- 2 **projeter** ces nouveaux éléments sur les axes factoriels du nuage des individus ou des variables.


- On fait l'ACP du jeu de données en utilisant les 41 individus et les 10 variables correspondant aux disciplines du decathlon. les variables classement, points et competition sont mises en supplémentaire.
- On fait l'analyse des 4 premiers axes.

Premier plan factoriel

Individuals factor map (PCA)




Variables factor map (PCA)

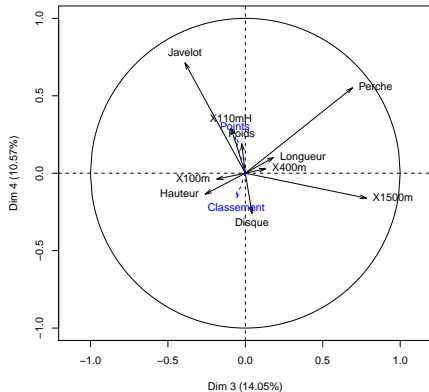


Second plan factoriel

Individuals factor map (PCA)



Variables factor map (PCA)



Troisième partie III

Théorie de l'estimation

1 Introduction

- Quelques exemples
- Rappels sur les variables aléatoires
- Modèle statistique

2 Qualités d'un estimateur

- Biais, variance et risque quadratique
- Critère de performance asymptotique
- 2 méthodes d'estimation
 - La méthode des moments
 - La méthode du maximum de vraisemblance

3 Information de Fisher et Borne de Cramer Rao

- Dimension 1
- Dimension p

4 Estimation par intervalle de confiance

1

Introduction

- Quelques exemples
- Rappels sur les variables aléatoires
- Modèle statistique

2

Qualités d'un estimateur

- Biais, variance et risque quadratique
- Critère de performance asymptotique
- 2 méthodes d'estimation
 - La méthode des moments
 - La méthode du maximum de vraisemblance

3

Information de Fisher et Borne de Cramer Rao

- Dimension 1
- Dimension p

4

Estimation par intervalle de confiance

1

Introduction

- Quelques exemples
- Rappels sur les variables aléatoires
- Modèle statistique

2

Qualités d'un estimateur

- Biais, variance et risque quadratique
- Critère de performance asymptotique
- 2 méthodes d'estimation
 - La méthode des moments
 - La méthode du maximum de vraisemblance

3

Information de Fisher et Borne de Cramer Rao

- Dimension 1
- Dimension p

4

Estimation par intervalle de confiance

Exemple 1

- On souhaite tester l'efficacité d'un nouveau traitement à l'aide d'un essai clinique.
- On traite $n = 100$ patients atteints de la pathologie.
- A l'issue de l'étude, 72 patients sont guéris.

- Soit p_0 la probabilité de guérison suite au traitement en question.
- On est tentés de conclure $p_0 \approx 72$.

Un tel résultat n'a cependant guère d'intérêt si on n'est pas capable de préciser l'erreur susceptible d'être commise par cette estimation.

Exemple 1



- On souhaite tester l'efficacité d'un nouveau traitement à l'aide d'un essai clinique.
- On traite $n = 100$ patients atteints de la pathologie.
- A l'issue de l'étude, 72 patients sont guéris.

- Soit p_0 la probabilité de guérison suite au traitement en question.
- On est tentés de conclure $p_0 \approx 72$.

Un tel résultat n'a cependant guère d'intérêt si on n'est pas capable de préciser l'erreur susceptible d'être commise par cette estimation.

Exemple 2



- On s'intéresse au nombre de mails reçus par jour par un utilisateur pendant 36 journées.
- $\bar{x} = 5.22$, $S_n^2 = 5.72$.



Quelle est la probabilité de recevoir plus de 5 mails dans une journée ?

Exemple 2


- On s'intéresse au nombre de mails reçus par jour par un utilisateur pendant 36 journées.
- $\bar{x} = 5.22$, $S_n^2 = 5.72$.



Quelle est la probabilité de recevoir plus de 5 mails dans une journée ?

Exemple 3


- Temps mis pour venir de son domicile à Supelec.
- On dispose de $n = 100$ mesures : $\bar{x} = 25.1$, $S_n^2 = 14.46$.



J'ai un devoir à 8h30, quelle est la probabilité que j'arrive en retard si je pars de chez moi à 7h55 ?

Exemple 3

- Temps mis pour venir de son domicile à Supelec.
- On dispose de $n = 100$ mesures : $\bar{x} = 25.1$, $S_n^2 = 14.46$.



J'ai un devoir à 8h30, quelle est la probabilité que j'arrive en retard si je pars de chez moi à 7h55 ?

Problème

- Nécessité de se dégager des observations x_1, \dots, x_n pour répondre à de telles questions.
- Si on mesure la durée du trajet pendant 100 nouveaux jours, on peut en effet penser que les nouvelles observations ne seront pas exactement les mêmes que les anciennes.

Idée

Considérer que les n valeurs observées x_1, \dots, x_n sont des réalisations de variables aléatoires X_1, \dots, X_n .

Attention

X_i est une variable aléatoire et x_i est une réalisation de cette variable, c'est-à-dire un nombre !

Problème

- Nécessité de se dégager des observations x_1, \dots, x_n pour répondre à de telles questions.
- Si on mesure la durée du trajet pendant 100 nouveaux jours, on peut en effet penser que les nouvelles observations ne seront pas exactement les mêmes que les anciennes.

Idée

Considérer que les n valeurs observées x_1, \dots, x_n sont des réalisations de variables aléatoires X_1, \dots, X_n .

Attention

X_i est une variable aléatoire et x_i est une réalisation de cette variable, c'est-à-dire un nombre !

Problème

- Nécessité de se dégager des observations x_1, \dots, x_n pour répondre à de telles questions.
- Si on mesure la durée du trajet pendant 100 nouveaux jours, on peut en effet penser que les nouvelles observations ne seront pas exactement les mêmes que les anciennes.

Idée

Considérer que les n valeurs observées x_1, \dots, x_n sont des réalisations de variables aléatoires X_1, \dots, X_n .

Attention

X_i est une variable aléatoire et x_i est une réalisation de cette variable, c'est-à-dire un nombre !

Un modèle pour l'exemple 1

- On note $x_i = 1$ si le $i^{\text{ème}}$ patient a guéri, 0 sinon.
- On peut supposer que x_i est la réalisation d'une variable aléatoire X_i de loi de bernoulli de paramètre p_0 .
- Si les individus sont choisis de manière indépendante et ont tous la même probabilité de guérir (ce qui peut revenir à dire qu'ils en sont au même stade de la pathologie), il est alors raisonnable de supposer que les variables aléatoires X_1, \dots, X_n sont indépendantes.

On dit que X_1, \dots, X_n est un n -échantillon de variables aléatoires indépendantes de même loi $B(p_0)$.

Un modèle pour l'exemple 1

- On note $x_i = 1$ si le $i^{\text{ème}}$ patient a guéri, 0 sinon.
- On peut supposer que x_i est la réalisation d'une variable aléatoire X_i de loi de bernoulli de paramètre p_0 .
- Si les individus sont choisis de manière indépendante et ont tous la même probabilité de guérir (ce qui peut revenir à dire qu'ils en sont au même stade de la pathologie), il est alors raisonnable de supposer que les variables aléatoires X_1, \dots, X_n sont indépendantes.

On dit que X_1, \dots, X_n est un n -échantillon de variables aléatoires indépendantes de même loi $B(p_0)$.

Un modèle pour l'exemple 1

- On note $x_i = 1$ si le $i^{\text{ème}}$ patient a guéri, 0 sinon.
- On peut supposer que x_i est la réalisation d'une variable aléatoire X_i de loi de bernoulli de paramètre p_0 .
- Si les individus sont choisis de manière indépendante et ont tous la même probabilité de guérir (ce qui peut revenir à dire qu'ils en sont au même stade de la pathologie), il est alors raisonnable de supposer que les variables aléatoires X_1, \dots, X_n sont indépendantes.

On dit que X_1, \dots, X_n est un n -échantillon de variables aléatoires indépendantes de même loi $B(p_0)$.

1

Introduction

- Quelques exemples
- **Rappels sur les variables aléatoires**
- Modèle statistique

2

Qualités d'un estimateur

- Biais, variance et risque quadratique
- Critère de performance asymptotique
- 2 méthodes d'estimation
 - La méthode des moments
 - La méthode du maximum de vraisemblance

3

Information de Fisher et Borne de Cramer Rao

- Dimension 1
- Dimension p

4

Estimation par intervalle de confiance

Définition

Une **variable aléatoire réelle** est une application

$$X : (\Omega, \mathcal{A}) \rightarrow (\mathbb{R}, \mathcal{B}(\mathbb{R}))$$

telle que

$$\forall B \in \mathcal{B}(\mathbb{R}), X^{-1}(B) \in \mathcal{A}.$$

- Lors de la modélisation statistique, l'espace Ω n'est généralement jamais caractérisé.
- Il contient tous les "phénomènes" pouvant expliquer les sources d'aléa (qui ne sont pas explicables...).
- En pratique, l'espace d'arrivée est généralement suffisant.

Définition

Une **variable aléatoire réelle** est une application

$$X : (\Omega, \mathcal{A}) \rightarrow (\mathbb{R}, \mathcal{B}(\mathbb{R}))$$

telle que

$$\forall B \in \mathcal{B}(\mathbb{R}), X^{-1}(B) \in \mathcal{A}.$$

- Lors de la modélisation statistique, l'espace Ω n'est généralement jamais caractérisé.
- Il contient tous les "phénomènes" pouvant expliquer les sources d'aléa (qui ne sont pas explicables...).
- En pratique, l'espace d'arrivée est généralement suffisant.

Définition

Une **variable aléatoire réelle** est une application

$$X : (\Omega, \mathcal{A}) \rightarrow (\mathbb{R}, \mathcal{B}(\mathbb{R}))$$

telle que

$$\forall B \in \mathcal{B}(\mathbb{R}), X^{-1}(B) \in \mathcal{A}.$$

- Lors de la modélisation statistique, l'espace Ω n'est généralement jamais caractérisé.
- Il contient tous les "phénomènes" pouvant expliquer les sources d'aléa (qui ne sont pas explicables...).
- En pratique, l'espace d'arrivée est généralement suffisant.

Loi de probabilité

Etant donnée \mathbf{P} une probabilité sur (Ω, \mathcal{A}) et X une variable aléatoire réelle définie sur Ω , on appelle loi de probabilité de X la mesure \mathbf{P}_X définie par

$$\mathbf{P}_X(B) = \mathbf{P}(X^{-1}(B)) = \mathbf{P}(X \in B) = \mathbf{P}(\{\omega \in \Omega : X(\omega) \in B\}) \quad \forall B \in \mathcal{B}(\mathbb{R}).$$

Une loi de probabilité est caractérisée par

- sa fonction de répartition : $F_X(x) = \mathbf{P}(X \leq x)$.
- sa densité : $f_X : \mathbb{R} \rightarrow \mathbb{R}^+$ telle que $\forall B \in \mathcal{B}(\mathbb{R})$

$$\mathbf{P}_X(B) = \int_B f_X(x) dx.$$

Loi de probabilité

Etant donnée \mathbf{P} une probabilité sur (Ω, \mathcal{A}) et X une variable aléatoire réelle définie sur Ω , on appelle loi de probabilité de X la mesure \mathbf{P}_X définie par

$$\mathbf{P}_X(B) = \mathbf{P}(X^{-1}(B)) = \mathbf{P}(X \in B) = \mathbf{P}(\{\omega \in \Omega : X(\omega) \in B\}) \quad \forall B \in \mathcal{B}(\mathbb{R}).$$

Une loi de probabilité est caractérisée par

- sa fonction de répartition : $F_X(x) = \mathbf{P}(X \leq x)$.
- sa densité : $f_X : \mathbb{R} \rightarrow \mathbb{R}^+$ telle que $\forall B \in \mathcal{B}(\mathbb{R})$

$$\mathbf{P}_X(B) = \int_B f_X(x) dx.$$

1

Introduction

- Quelques exemples
- Rappels sur les variables aléatoires
- **Modèle statistique**

2

Qualités d'un estimateur

- Biais, variance et risque quadratique
- Critère de performance asymptotique
- 2 méthodes d'estimation
 - La méthode des moments
 - La méthode du maximum de vraisemblance

3

Information de Fisher et Borne de Cramer Rao

- Dimension 1
- Dimension p

4

Estimation par intervalle de confiance

Modèle

On appelle **modèle statistique** tout triplet $(\mathcal{H}, \mathcal{A}, \mathcal{P})$ où

- \mathcal{H} est l'espace des observations (l'ensemble de tous les résultats possibles de l'expérience) ;
- \mathcal{A} est une tribu sur \mathcal{H} ;
- \mathcal{P} est une famille de probabilités définie sur $(\mathcal{H}, \mathcal{A})$.

Le problème du statisticien

- n variables aléatoires i.i.d. X_1, \dots, X_n de loi \mathbf{P} .
- Trouver une famille de lois \mathcal{P} susceptible de contenir \mathbf{P} .
- Trouver dans \mathcal{P} une loi qui soit **la plus proche** de \mathbf{P}

Modèle

On appelle **modèle statistique** tout triplet $(\mathcal{H}, \mathcal{A}, \mathcal{P})$ où

- \mathcal{H} est l'espace des observations (l'ensemble de tous les résultats possibles de l'expérience) ;
- \mathcal{A} est une tribu sur \mathcal{H} ;
- \mathcal{P} est une famille de probabilités définie sur $(\mathcal{H}, \mathcal{A})$.

Le problème du statisticien

- n variables aléatoires i.i.d. X_1, \dots, X_n de loi \mathbf{P} .
- Trouver une famille de lois \mathcal{P} susceptible de contenir \mathbf{P} .
- Trouver dans \mathcal{P} une loi qui soit **la plus proche** de \mathbf{P}

Exemples

	\mathcal{H}	\mathcal{A}	\mathcal{P}
Exemple 1	$\{0, 1\}$	$\mathcal{P}(\{0, 1\})$	$\{B(p), p \in \{0, 1\}\}$
Exemple 2	\mathbb{N}	$\mathcal{P}(\mathbb{N})$	$\{\mathcal{P}(\lambda), \lambda > 0\}$
Exemple 3	\mathbb{R}	$\mathcal{B}(\mathbb{R})$	$\{\mathcal{N}(\mu, \sigma^2), \mu \in \mathbb{R}, \sigma \in \mathbb{R}^+\}$

Définition

- Si $\mathcal{P} = \{\mathbf{P}_\theta, \theta \in \Theta\}$ où $\Theta \in \mathbb{R}^d$ alors on parle de **modèle paramétrique** et Θ est l'espace des paramètres. Si $\theta \mapsto \mathbf{P}_\theta$ est injective, le modèle est dit **identifiable**.
- Si $\mathcal{P} = \{\mathbf{P}, \mathbf{P} \in \mathcal{F}\}$ où \mathcal{F} est de dimension infinie, on parle de **modèle non paramétrique**.

Exemple : modèle de densité

- $\mathcal{P} = \{\mathcal{N}(\mu, \sigma^2), (\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}^+\}$ est un modèle paramétrique.
- $\mathcal{P} = \{\text{densités } f \text{ 2 fois dérivables}\}$ est un modèle non paramétrique.

Le problème sera d'estimer (μ, σ^2) ou f à partir de l'échantillon X_1, \dots, X_n .

Définition

- Si $\mathcal{P} = \{\mathbf{P}_\theta, \theta \in \Theta\}$ où $\Theta \in \mathbb{R}^d$ alors on parle de **modèle paramétrique** et Θ est l'espace des paramètres. Si $\theta \mapsto \mathbf{P}_\theta$ est injective, le modèle est dit **identifiable**.
- Si $\mathcal{P} = \{\mathbf{P}, \mathbf{P} \in \mathcal{F}\}$ où \mathcal{F} est de dimension infinie, on parle de **modèle non paramétrique**.

Exemple : modèle de densité

- $\mathcal{P} = \{\mathcal{N}(\mu, \sigma^2), (\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}^+\}$ est un modèle paramétrique.
- $\mathcal{P} = \{\text{densités } f \text{ 2 fois dérivables}\}$ est un modèle non paramétrique.

Le problème sera d'estimer (μ, σ^2) ou f à partir de l'échantillon X_1, \dots, X_n .

Définition

- Si $\mathcal{P} = \{\mathbf{P}_\theta, \theta \in \Theta\}$ où $\Theta \in \mathbb{R}^d$ alors on parle de **modèle paramétrique** et Θ est l'espace des paramètres. Si $\theta \mapsto \mathbf{P}_\theta$ est injective, le modèle est dit **identifiable**.
- Si $\mathcal{P} = \{\mathbf{P}, \mathbf{P} \in \mathcal{F}\}$ où \mathcal{F} est de dimension infinie, on parle de **modèle non paramétrique**.

Exemple : modèle de densité

- $\mathcal{P} = \{\mathcal{N}(\mu, \sigma^2), (\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}^+\}$ est un modèle paramétrique.
- $\mathcal{P} = \{\text{densités } f \text{ 2 fois dérivables}\}$ est un modèle non paramétrique.

Le problème sera d'estimer (μ, σ^2) ou f à partir de l'échantillon X_1, \dots, X_n .

Définition

- Si $\mathcal{P} = \{\mathbf{P}_\theta, \theta \in \Theta\}$ où $\Theta \in \mathbb{R}^d$ alors on parle de **modèle paramétrique** et Θ est l'espace des paramètres. Si $\theta \mapsto \mathbf{P}_\theta$ est injective, le modèle est dit **identifiable**.
- Si $\mathcal{P} = \{\mathbf{P}, \mathbf{P} \in \mathcal{F}\}$ où \mathcal{F} est de dimension infinie, on parle de **modèle non paramétrique**.

Exemple : modèle de densité

- $\mathcal{P} = \{\mathcal{N}(\mu, \sigma^2), (\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}^+\}$ est un modèle paramétrique.
- $\mathcal{P} = \{\text{densités } f \text{ 2 fois dérivables}\}$ est un modèle non paramétrique.

Le problème sera d'estimer (μ, σ^2) ou f à partir de l'échantillon X_1, \dots, X_n .

Modèle de régression

- On cherche à expliquer une variable Y par p variables explicatives $\mathbf{X}_1, \dots, \mathbf{X}_p$. On dispose d'un n échantillon i.i.d. $(X_1, Y_1), \dots, (X_n, Y_n)$.

Modèle linéaire (paramétrique)

- On pose

$$Y = \beta_0 + \beta_1 \mathbf{X}_1 + \dots + \beta_p \mathbf{X}_p + \varepsilon \quad \text{où} \quad \varepsilon \sim \mathcal{N}(0, \sigma^2).$$

- Le problème est d'estimer $\beta = (\beta_0, \dots, \beta_p) \in \mathbb{R}^{p+1}$ à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

Un modèle non paramétrique

- On pose

$$Y = m(\mathbf{X}_1, \dots, \mathbf{X}_p) + \varepsilon$$

où $m : \mathbb{R}^p \rightarrow \mathbb{R}$ est une fonction continue.

- Le problème est d'estimer m à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

Modèle de régression

- On cherche à expliquer une variable Y par p variables explicatives $\mathbf{X}_1, \dots, \mathbf{X}_p$. On dispose d'un n échantillon i.i.d. $(X_1, Y_1), \dots, (X_n, Y_n)$.

Modèle linéaire (paramétrique)

- On pose

$$Y = \beta_0 + \beta_1 \mathbf{X}_1 + \dots + \beta_p \mathbf{X}_p + \varepsilon \quad \text{où} \quad \varepsilon \sim \mathcal{N}(0, \sigma^2).$$

- Le problème est d'estimer $\beta = (\beta_0, \dots, \beta_p) \in \mathbb{R}^{p+1}$ à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

Un modèle non paramétrique

- On pose

$$Y = m(\mathbf{X}_1, \dots, \mathbf{X}_p) + \varepsilon$$

où $m : \mathbb{R}^p \rightarrow \mathbb{R}$ est une fonction continue.

- Le problème est d'estimer m à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

Modèle de régression

- On cherche à expliquer une variable Y par p variables explicatives $\mathbf{X}_1, \dots, \mathbf{X}_p$. On dispose d'un n échantillon i.i.d. $(X_1, Y_1), \dots, (X_n, Y_n)$.

Modèle linéaire (paramétrique)

- On pose

$$Y = \beta_0 + \beta_1 \mathbf{X}_1 + \dots + \beta_p \mathbf{X}_p + \varepsilon \quad \text{où} \quad \varepsilon \sim \mathcal{N}(0, \sigma^2).$$

- Le problème est d'estimer $\beta = (\beta_0, \dots, \beta_p) \in \mathbb{R}^{p+1}$ à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

Un modèle non paramétrique

- On pose


$$Y = m(\mathbf{X}_1, \dots, \mathbf{X}_p) + \varepsilon$$

où $m : \mathbb{R}^p \rightarrow \mathbb{R}$ est une fonction continue.

- Le problème est d'estimer m à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

2 types d'erreur

- Poser un modèle revient à choisir une famille de loi candidates pour reconstruire la loi des données \mathbf{P} .




On distingue deux types d'erreurs :

- **Erreur d'estimation** : erreur commise par le choix d'une loi dans \mathcal{P} par rapport au meilleur choix.
- **Erreur d'approximation** : erreur commise par le choix de \mathcal{P} .

2 types d'erreur

- Poser un modèle revient à choisir une famille de loi candidates pour reconstruire la loi des données \mathbf{P} .



On distingue deux types d'erreurs :

- **Erreur d'estimation** : erreur commise par le choix d'une loi dans \mathcal{P} par rapport au meilleur choix.
- **Erreur d'approximation** : erreur commise par le choix de \mathcal{P} .

Etant donné un modèle $(\mathcal{H}, \mathcal{A}, \mathcal{P})$:

- trouver des procédures (automatiques) permettant de sélectionner une loi $\hat{\mathbf{P}}$ dans \mathcal{P} à partir d'un n -échantillon X_1, \dots, X_n .
- Etudier les performances des lois choisies.

- Dans la suite, on va considérer uniquement des modèles paramétriques $\mathcal{P} = \{\mathbf{P}_\theta, \theta \in \Theta\}$ avec Θ de dimension finie (typiquement \mathbb{R}^p).
- Choisir une loi reviendra donc à choisir un paramètre $\hat{\theta}$ à partir de l'échantillon X_1, \dots, X_n .

Etant donné un **modèle** $(\mathcal{H}, \mathcal{A}, \mathcal{P})$:

- trouver des **procédures (automatiques)** permettant de sélectionner une loi $\hat{\mathbf{P}}$ dans \mathcal{P} à partir d'un n -échantillon X_1, \dots, X_n .
 - Etudier les **performances** des lois choisies.
-
- Dans la suite, on va considérer uniquement des **modèles paramétriques** $\mathcal{P} = \{\mathbf{P}_\theta, \theta \in \Theta\}$ avec Θ de dimension finie (typiquement \mathbb{R}^p).
 - Choisir une loi reviendra donc à **choisir un paramètre** $\hat{\theta}$ à partir de l'échantillon X_1, \dots, X_n .

- Les modèles que nous allons considérer auront pour espace d'observations un ensemble dénombrable Ω ou \mathbb{R}^d et seront munis des tribus $\mathcal{P}(\Omega)$ ou $\mathcal{B}(\mathbb{R}^d)$.
- Dans la suite, on se donne un modèle $\mathcal{M} = (\mathcal{H}, \mathcal{P} = \{\mathbf{P}_\theta, \theta \in \Theta\})$.

Echantillon

Un **échantillon** de taille n est une suite X_1, \dots, X_n de n **variables aléatoires indépendantes et de même loi** \mathbf{P}_{θ_0} , pour $\theta_0 \in \Theta$.

Notations

- L'échantillon définit un **vecteur aléatoire** (X_1, \dots, X_n) ayant comme loi $\mathbf{P}_{\theta_0}^{\otimes n}$.
- On note $\mathcal{M}_n = (\mathcal{H}^n, \{\mathbf{P}^{\otimes n}, \theta \in \Theta\})$ le modèle produit.
- Le modèle \mathcal{M}_n correspond à un ensemble de lois sur \mathcal{H}^n contenant $\mathbf{P}_{\theta_0}^{\otimes n}$.

- Les modèles que nous allons considérer auront pour espace d'observations un ensemble dénombrable Ω ou \mathbb{R}^d et seront munis des tribus $\mathcal{P}(\Omega)$ ou $\mathcal{B}(\mathbb{R}^d)$.
- Dans la suite, on se donne un modèle $\mathcal{M} = (\mathcal{H}, \mathcal{P} = \{\mathbf{P}_\theta, \theta \in \Theta\})$.

Echantillon

Un **échantillon** de taille n est une suite X_1, \dots, X_n de n **variables aléatoires indépendantes et de même loi \mathbf{P}_{θ_0}** , pour $\theta_0 \in \Theta$.

Notations

- L'échantillon définit un **vecteur aléatoire** (X_1, \dots, X_n) ayant comme loi $\mathbf{P}_{\theta_0}^{\otimes n}$.
- On note $\mathcal{M}_n = (\mathcal{H}^n, \{\mathbf{P}^{\otimes n}, \theta \in \Theta\})$ le modèle produit.
- Le modèle \mathcal{M}_n correspond à un ensemble de lois sur \mathcal{H}^n contenant $\mathbf{P}_{\theta_0}^{\otimes n}$.

- Les modèles que nous allons considérer auront pour espace d'observations un ensemble dénombrable Ω ou \mathbb{R}^d et seront munis des tribus $\mathcal{P}(\Omega)$ ou $\mathcal{B}(\mathbb{R}^d)$.
- Dans la suite, on se donne un modèle $\mathcal{M} = (\mathcal{H}, \mathcal{P} = \{\mathbf{P}_\theta, \theta \in \Theta\})$.

Echantillon

Un **échantillon** de taille n est une suite X_1, \dots, X_n de n **variables aléatoires indépendantes et de même loi** \mathbf{P}_{θ_0} , pour $\theta_0 \in \Theta$.

Notations

- L'échantillon définit un **vecteur aléatoire** (X_1, \dots, X_n) ayant comme loi $\mathbf{P}_{\theta_0}^{\otimes n}$.
- On note $\mathcal{M}_n = (\mathcal{H}^n, \{\mathbf{P}^{\otimes n}, \theta \in \Theta\})$ le modèle produit.
- Le modèle \mathcal{M}_n correspond à un ensemble de lois sur \mathcal{H}^n contenant $\mathbf{P}_{\theta_0}^{\otimes n}$.

- 1 On récolte **n observations** (n valeurs) x_1, \dots, x_n qui sont le résultats de n expériences aléatoires indépendantes.
- 2 **Modélisation** : on suppose que les n valeurs sont des **réalisations de n variables aléatoires indépendantes** X_1, \dots, X_n et de même loi \mathbf{P}_{θ_0} .
Ce qui nous amène à définir le modèle $\mathcal{M}_n = (\mathcal{H}^n, \{\mathbf{P}_{\theta}^{\otimes n}, \theta \in \Theta\})$.
- 3 **Estimation** : chercher dans le modèle une loi $\mathbf{P}_{\hat{\theta}}$ qui soit **la plus proche possible** de $\mathbf{P}_{\theta_0} \implies$ chercher un **estimateur** $\hat{\theta}$ de θ_0 .

- 1 On récolte n observations (n valeurs) x_1, \dots, x_n qui sont le résultats de n expériences aléatoires indépendantes.
- 2 **Modélisation** : on suppose que les n valeurs sont des réalisations de n variables aléatoires indépendantes X_1, \dots, X_n et de même loi \mathbf{P}_{θ_0} .
Ce qui nous amène à définir le modèle $\mathcal{M}_n = (\mathcal{H}^n, \{\mathbf{P}_{\theta}^{\otimes n}, \theta \in \Theta\})$.
- 3 **Estimation** : chercher dans le modèle une loi $\mathbf{P}_{\hat{\theta}}$ qui soit la plus proche possible de $\mathbf{P}_{\theta_0} \implies$ chercher un estimateur $\hat{\theta}$ de θ_0 .

- 1 On récolte n observations (n valeurs) x_1, \dots, x_n qui sont le résultats de n expériences aléatoires indépendantes.
- 2 **Modélisation** : on suppose que les n valeurs sont des réalisations de n variables aléatoires indépendantes X_1, \dots, X_n et de même loi \mathbf{P}_{θ_0} .
Ce qui nous amène à définir le modèle $\mathcal{M}_n = (\mathcal{H}^n, \{\mathbf{P}_{\theta}^{\otimes n}, \theta \in \Theta\})$.
- 3 **Estimation** : chercher dans le modèle une loi $\mathbf{P}_{\hat{\theta}}$ qui soit la plus proche possible de $\mathbf{P}_{\theta_0} \implies$ chercher un estimateur $\hat{\theta}$ de θ_0 .

Définitions

- Une **statistique** est une application mesurable définie sur \mathcal{H}^n .
- Un **estimateur** (de θ_0) est une fonction mesurable de (X_1, \dots, X_n) indépendante de θ à valeurs dans un sur-ensemble de Θ .

Exemple 1

Les variables aléatoires $\hat{\theta}_1 = X_1$ et $\hat{\theta}_2 = \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ sont des estimateurs de ρ_0 .

Remarque

- Un estimateur $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$: c'est une **variable aléatoire**.
- **Démarche** :
 - 1 Chercher le "meilleur" **estimateur** $\hat{\theta}(X_1, \dots, X_n)$.
 - 2 A la fin, calculer l'**estimation** $\hat{\theta}(x_1, \dots, x_n)$ (fait par le logiciel).

Définitions

- Une **statistique** est une application mesurable définie sur \mathcal{H}^n .
- Un **estimateur** (de θ_0) est une fonction mesurable de (X_1, \dots, X_n) indépendante de θ à valeurs dans un sur-ensemble de Θ .

Exemple 1

Les variables aléatoires $\hat{\theta}_1 = X_1$ et $\hat{\theta}_2 = \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ sont des estimateurs de ρ_0 .

Remarque

- Un estimateur $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$: c'est une **variable aléatoire**.
- **Démarche** :
 - 1 Chercher le "meilleur" **estimateur** $\hat{\theta}(X_1, \dots, X_n)$.
 - 2 A la fin, calculer l'**estimation** $\hat{\theta}(x_1, \dots, x_n)$ (fait par le logiciel).

Définitions

- Une **statistique** est une application mesurable définie sur \mathcal{H}^n .
- Un **estimateur** (de θ_0) est une fonction mesurable de (X_1, \dots, X_n) indépendante de θ à valeurs dans un sur-ensemble de Θ .

Exemple 1

Les variables aléatoires $\hat{\theta}_1 = X_1$ et $\hat{\theta}_2 = \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ sont des estimateurs de ρ_0 .

Remarque

- Un estimateur $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$: c'est une **variable aléatoire**.
- **Démarche** :
 - 1 Chercher le "meilleur" **estimateur** $\hat{\theta}(X_1, \dots, X_n)$.
 - 2 A la fin, calculer l'**estimation** $\hat{\theta}(x_1, \dots, x_n)$ (fait par le logiciel).

1

Introduction

- Quelques exemples
- Rappels sur les variables aléatoires
- Modèle statistique

2

Qualités d'un estimateur

- Biais, variance et risque quadratique
- Critère de performance asymptotique
- 2 méthodes d'estimation
 - La méthode des moments
 - La méthode du maximum de vraisemblance

3

Information de Fisher et Borne de Cramer Rao

- Dimension 1
- Dimension p

4

Estimation par intervalle de confiance



- 1 Introduction
 - Quelques exemples
 - Rappels sur les variables aléatoires
 - Modèle statistique

- 2 **Qualités d'un estimateur**
 - **Biais, variance et risque quadratique**
 - Critère de performance asymptotique
 - 2 méthodes d'estimation
 - La méthode des moments
 - La méthode du maximum de vraisemblance

- 3 **Information de Fisher et Borne de Cramer Rao**
 - Dimension 1
 - Dimension p

- 4 **Estimation par intervalle de confiance**

- Un estimateur $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ est une variable aléatoire. Il va donc posséder une loi.



- Un moyen de mesurer la qualité de $\hat{\theta}$ est de regarder sa "valeur moyenne" et de la comparer à θ .

Biais d'un estimateur

- On désigne par \mathbf{E}_θ l'espérance sous la loi \mathbf{P}_θ :

$$\mathbf{E}_\theta(\hat{\theta}) = \mathbf{E}_\theta(\hat{\theta}(X_1, \dots, X_n)) = \int_{\mathcal{H}_n} \hat{\theta}(x) \mathbf{P}_\theta dx$$

où $x = (x_1, \dots, x_n)$.

Soit $\hat{\theta}$ un estimateur d'ordre 1.

- Le **biais** de $\hat{\theta}$ en θ est $\mathbf{E}_\theta(\hat{\theta}) - \theta$.
- $\hat{\theta}$ est **sans biais** lorsque son biais est nul en chaque $\theta \in \Theta$.
- $\hat{\theta}$ est **asymptotiquement sans biais** si pour chaque $\theta \in \Theta$,
 $\lim_{n \rightarrow \infty} \mathbf{E}_\theta(\hat{\theta}) = \theta$.

Exemple 1

Les estimateurs $\hat{\theta}_1$ et $\hat{\theta}_2$ sont **sans biais**.

Biais d'un estimateur

- On désigne par \mathbf{E}_θ l'espérance sous la loi \mathbf{P}_θ :

$$\mathbf{E}_\theta(\hat{\theta}) = \mathbf{E}_\theta(\hat{\theta}(X_1, \dots, X_n)) = \int_{\mathcal{H}_n} \hat{\theta}(x) \mathbf{P}_\theta dx$$

où $x = (x_1, \dots, x_n)$.

Soit $\hat{\theta}$ un estimateur d'ordre 1.

- 1 Le **biais** de $\hat{\theta}$ en θ est $\mathbf{E}_\theta(\hat{\theta}) - \theta$.
- 2 $\hat{\theta}$ est **sans biais** lorsque son biais est nul en chaque $\theta \in \Theta$.
- 3 $\hat{\theta}$ est **asymptotiquement sans biais** si pour chaque $\theta \in \Theta$,
 $\lim_{n \rightarrow \infty} \mathbf{E}_\theta(\hat{\theta}) = \theta$.

Exemple 1

Les estimateurs $\hat{\theta}_1$ et $\hat{\theta}_2$ sont **sans biais**.

Biais d'un estimateur

- On désigne par \mathbf{E}_θ l'espérance sous la loi \mathbf{P}_θ :

$$\mathbf{E}_\theta(\hat{\theta}) = \mathbf{E}_\theta(\hat{\theta}(X_1, \dots, X_n)) = \int_{\mathcal{H}_n} \hat{\theta}(x) \mathbf{P}_\theta dx$$

où $x = (x_1, \dots, x_n)$.



Soit $\hat{\theta}$ un estimateur d'ordre 1.

- Le **biais** de $\hat{\theta}$ en θ est $\mathbf{E}_\theta(\hat{\theta}) - \theta$.
- $\hat{\theta}$ est **sans biais** lorsque son biais est nul en chaque $\theta \in \Theta$.
- $\hat{\theta}$ est **asymptotiquement sans biais** si pour chaque $\theta \in \Theta$,
 $\lim_{n \rightarrow \infty} \mathbf{E}_\theta(\hat{\theta}) = \theta$.

Exemple 1

Les estimateurs $\hat{\theta}_1$ et $\hat{\theta}_2$ sont **sans biais**.

- Mesurer le biais n'est **pas suffisant**.
- Il faut également mesurer la **dispersion** des estimateurs.



Définitions

Soit $\hat{\theta}$ un estimateur d'ordre 2.

- 1 Le **risque quadratique** de $\hat{\theta}$ sous \mathbf{P}_θ est

$$\mathcal{R}(\theta, \hat{\theta}) = \mathbf{E}_\theta \|\hat{\theta} - \theta\|^2$$

- 2 Soit $\hat{\theta}'$ un autre estimateur d'ordre 2. On dit que $\hat{\theta}$ est **préférable** à $\hat{\theta}'$ si

$$\mathcal{R}(\theta, \hat{\theta}) \leq \mathcal{R}(\theta, \hat{\theta}') \quad \forall \theta \in \Theta.$$

Exemple 1

$\hat{\theta}_2$ est préférable à $\hat{\theta}_1$.

Définitions

Soit $\hat{\theta}$ un estimateur d'ordre 2.

- 1 Le **risque quadratique** de $\hat{\theta}$ sous \mathbf{P}_θ est

$$\mathcal{R}(\theta, \hat{\theta}) = \mathbf{E}_\theta \|\hat{\theta} - \theta\|^2$$

- 2 Soit $\hat{\theta}'$ un autre estimateur d'ordre 2. On dit que $\hat{\theta}$ est **préférable** à $\hat{\theta}'$ si

$$\mathcal{R}(\theta, \hat{\theta}) \leq \mathcal{R}(\theta, \hat{\theta}') \quad \forall \theta \in \Theta.$$

Exemple 1

$\hat{\theta}_2$ est préférable à $\hat{\theta}_1$.

Propriété décomposition biais variance

- 1 Si $\hat{\theta}$ est d'ordre 2, on a la décomposition

$$\mathcal{R}(\theta, \hat{\theta}) = \|\mathbf{E}_\theta(\hat{\theta}) - \theta\|^2 + \mathbf{E}_\theta \|\hat{\theta} - \mathbf{E}_\theta \hat{\theta}\|^2.$$

- 2 Si $\theta \in \mathbb{R}$, on obtient

$$\mathcal{R}(\theta, \hat{\theta}) = b(\hat{\theta})^2 + \mathbf{V}(\hat{\theta}).$$

Définition

Si $\hat{\theta}$ est sans biais, on dit qu'il est de **variance uniformément minimum parmi les estimateurs sans biais (VUMSB)** si il est préférable à tout autre estimateur sans biais d'ordre 2.

Exemple

$\hat{\theta}_2$ est VUMSB.

Propriété décomposition biais variance

- 1 Si $\hat{\theta}$ est d'ordre 2, on a la décomposition

$$\mathcal{R}(\theta, \hat{\theta}) = \|\mathbf{E}_\theta(\hat{\theta}) - \theta\|^2 + \mathbf{E}_\theta \|\hat{\theta} - \mathbf{E}_\theta \hat{\theta}\|^2.$$

- 2 Si $\theta \in \mathbb{R}$, on obtient

$$\mathcal{R}(\theta, \hat{\theta}) = b(\hat{\theta})^2 + \mathbf{V}(\hat{\theta}).$$

Définition

Si $\hat{\theta}$ est sans biais, on dit qu'il est de **variance uniformément minimum parmi les estimateurs sans biais (VUMSB)** si il est préférable à tout autre estimateur sans biais d'ordre 2.

Exemple

$\hat{\theta}_2$ est VUMSB.

Propriété décomposition biais variance

- 1 Si $\hat{\theta}$ est d'ordre 2, on a la décomposition

$$\mathcal{R}(\theta, \hat{\theta}) = \|\mathbf{E}_\theta(\hat{\theta}) - \theta\|^2 + \mathbf{E}_\theta \|\hat{\theta} - \mathbf{E}_\theta \hat{\theta}\|^2.$$

- 2 Si $\theta \in \mathbb{R}$, on obtient

$$\mathcal{R}(\theta, \hat{\theta}) = b(\hat{\theta})^2 + \mathbf{V}(\hat{\theta}).$$

Définition

Si $\hat{\theta}$ est sans biais, on dit qu'il est de **variance uniformément minimum parmi les estimateurs sans biais (VUMSB)** si il est préférable à tout autre estimateur sans biais d'ordre 2.

Exemple

$\hat{\theta}_2$ est VUMSB.

- 1 Introduction
 - Quelques exemples
 - Rappels sur les variables aléatoires
 - Modèle statistique

- 2 **Qualités d'un estimateur**
 - Biais, variance et risque quadratique
 - **Critère de performance asymptotique**
 - 2 méthodes d'estimation
 - La méthode des moments
 - La méthode du maximum de vraisemblance

- 3 Information de Fisher et Borne de Cramer Rao
 - Dimension 1
 - Dimension p

- 4 Estimation par intervalle de confiance

On dit que l'estimateur $\hat{\theta}$ est **consistant** (ou **convergent**) si $\hat{\theta} \xrightarrow{\mathbf{P}_\theta} \theta \forall \theta \in \Theta$, c'est-à-dire

$$\forall \theta \in \Theta, \forall \varepsilon > 0 \lim_{n \rightarrow \infty} \mathbf{P}_\theta(\|\hat{\theta} - \theta\| > \varepsilon) = 0.$$

Soit $(v_n)_n$ une suite de réels positifs telle que $v_n \rightarrow \infty$. On dit que $\hat{\theta}$ est **asymptotiquement normal**, de vitesse v_n si $\forall \theta \in \Theta$

$$v_n(\hat{\theta} - \theta) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma_\theta)$$

où Σ_θ est une matrice symétrique définie positive.

On dit que l'estimateur $\hat{\theta}$ est **consistant** (ou **convergent**) si $\hat{\theta} \xrightarrow{\mathbf{P}_\theta} \theta \forall \theta \in \Theta$, c'est-à-dire

$$\forall \theta \in \Theta, \forall \varepsilon > 0 \lim_{n \rightarrow \infty} \mathbf{P}_\theta(\|\hat{\theta} - \theta\| > \varepsilon) = 0.$$

Soit $(v_n)_n$ une suite de réels positifs telle que $v_n \rightarrow \infty$. On dit que $\hat{\theta}$ est **asymptotiquement normal**, de vitesse v_n si $\forall \theta \in \Theta$

$$v_n(\hat{\theta} - \theta) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma_\theta)$$

où Σ_θ est une matrice symétrique définie positive.

La **loi des grands nombres** et le **théorème central limite** sont souvent utilisés pour montrer la consistance et la normalité asymptotique.

Loi des grands nombres

Soit $(X_n)_n$ une suite de vecteurs aléatoires i.i.d. d'espérance $\mu \in \mathbb{R}^d$. Alors $\bar{X}_n \xrightarrow{p.s.} \mu$. Si de plus X_i est d'ordre 2, on a $\bar{X}_n \xrightarrow{L_2} \mu$.

TCL

Soit $(X_n)_n$ une suite de vecteurs aléatoires i.i.d. d'espérance $\mu \in \mathbb{R}^d$ et de matrice de variance covariance Σ , alors

$$\sqrt{n}(\bar{X}_n - \mu) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma).$$

Exemple 1

$\hat{\theta}_2$ est **consistant** et **asymptotiquement normal** (avec la vitesse \sqrt{n}).

La **loi des grands nombres** et le **théorème central limite** sont souvent utilisés pour montrer la consistance et la normalité asymptotique.

Loi des grands nombres

Soit $(X_n)_n$ une suite de vecteurs aléatoires i.i.d. d'espérance $\mu \in \mathbb{R}^d$. Alors $\bar{X}_n \xrightarrow{p.s.} \mu$. Si de plus X_i est d'ordre 2, on a $\bar{X}_n \xrightarrow{L_2} \mu$.

TCL

Soit $(X_n)_n$ une suite de vecteurs aléatoires i.i.d. d'espérance $\mu \in \mathbb{R}^d$ et de matrice de variance covariance Σ , alors

$$\sqrt{n}(\bar{X}_n - \mu) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma).$$

Exemple 1

$\hat{\theta}_2$ est **consistant** et **asymptotiquement normal** (avec la vitesse \sqrt{n}).

La **loi des grands nombres** et le **théorème central limite** sont souvent utilisés pour montrer la consistance et la normalité asymptotique.

Loi des grands nombres

Soit $(X_n)_n$ une suite de vecteurs aléatoires i.i.d. d'espérance $\mu \in \mathbb{R}^d$. Alors $\bar{X}_n \xrightarrow{p.s.} \mu$. Si de plus X_i est d'ordre 2, on a $\bar{X}_n \xrightarrow{L_2} \mu$.

TCL

Soit $(X_n)_n$ une suite de vecteurs aléatoires i.i.d. d'espérance $\mu \in \mathbb{R}^d$ et de matrice de variance covariance Σ , alors

$$\sqrt{n}(\bar{X}_n - \mu) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma).$$

Exemple 1

$\hat{\theta}_2$ est **consistant** et **asymptotiquement normal** (avec la vitesse \sqrt{n}).

Delta méthode

- X_1, \dots, X_n n échantillon i.i.d. de loi exponentielle de paramètre $\lambda > 0$.
 $\hat{\lambda} = 1/\bar{X}_n$ estimateur de λ asymptotiquement normal ?

Delta méthode

Si $v_n(\hat{\theta} - \theta) \xrightarrow{\mathcal{L}} X \sim \mathcal{N}(0, \Sigma)$ et si $h : \mathbb{R}^d \rightarrow \mathbb{R}^m$ admet des dérivées partielles au point θ , alors

$$v_n(h(\hat{\theta}) - h(\theta)) \xrightarrow{\mathcal{L}} Dh_{\theta}X$$

où Dh_{θ} est la matrice $m \times d$ de terme $(Dh_{\theta})_{ij} = \frac{\partial h_i}{\partial \theta_j}(\theta)$.

- On obtient grâce à la delta-méthode :

$$\frac{\sqrt{n}}{\lambda} \left[\frac{1}{\bar{X}_n} - \lambda \right] \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1).$$

Delta méthode

- X_1, \dots, X_n n échantillon i.i.d. de loi exponentielle de paramètre $\lambda > 0$.
 $\hat{\lambda} = 1/\bar{X}_n$ estimateur de λ asymptotiquement normal ?

Delta méthode

Si $v_n(\hat{\theta} - \theta) \xrightarrow{\mathcal{L}} X \sim \mathcal{N}(0, \Sigma)$ et si $h : \mathbb{R}^d \rightarrow \mathbb{R}^m$ admet des dérivées partielles au point θ , alors

$$v_n(h(\hat{\theta}) - h(\theta)) \xrightarrow{\mathcal{L}} Dh_{\theta}X$$

où Dh_{θ} est la matrice $m \times d$ de terme $(Dh_{\theta})_{ij} = \frac{\partial h_i}{\partial \theta_j}(\theta)$.

- On obtient grâce à la delta-méthode :

$$\frac{\sqrt{n}}{\lambda} \left[\frac{1}{\bar{X}_n} - \lambda \right] \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1).$$

Delta méthode

- X_1, \dots, X_n n échantillon i.i.d. de loi exponentielle de paramètre $\lambda > 0$.
 $\hat{\lambda} = 1/\bar{X}_n$ estimateur de λ asymptotiquement normal ?

Delta méthode

Si $v_n(\hat{\theta} - \theta) \xrightarrow{\mathcal{L}} X \sim \mathcal{N}(0, \Sigma)$ et si $h : \mathbb{R}^d \rightarrow \mathbb{R}^m$ admet des dérivées partielles au point θ , alors

$$v_n(h(\hat{\theta}) - h(\theta)) \xrightarrow{\mathcal{L}} Dh_{\theta}X$$

où Dh_{θ} est la matrice $m \times d$ de terme $(Dh_{\theta})_{ij} = \frac{\partial h_i}{\partial \theta_j}(\theta)$.

- On obtient grâce à la delta-méthode :

$$\frac{\sqrt{n}}{\lambda} \left[\frac{1}{\bar{X}_n} - \lambda \right] \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1).$$

1

Introduction

- Quelques exemples
- Rappels sur les variables aléatoires
- Modèle statistique

2

Qualités d'un estimateur

- Biais, variance et risque quadratique
- Critère de performance asymptotique
- **2 méthodes d'estimation**
 - La méthode des moments
 - La méthode du maximum de vraisemblance

3

Information de Fisher et Borne de Cramer Rao

- Dimension 1
- Dimension p

4

Estimation par intervalle de confiance

- modèle $(\mathcal{H}, \{\mathbf{P}_\theta, \theta \in \Theta\})$.
- n échantillon X_1, \dots, X_n i.i.d. de loi \mathbf{P}_θ .

Idée

Trouver le paramètre $\theta \in \Theta$ tel que les moments empiriques coïncident avec les moments théoriques :

$$\hat{m}_j = \frac{1}{n} \sum_{i=1}^n X_i^j \approx m_j(\theta_0) = \mathbf{E}_{\theta_0}(X_i^j), \quad j = 1, \dots, p.$$

Si $p = 1$ la méthode revient à résoudre l'équation en θ :

$$\frac{1}{n} \sum_{i=1}^n X_i = \mathbf{E}_\theta(X_1).$$

- modèle $(\mathcal{H}, \{\mathbf{P}_\theta, \theta \in \Theta\})$.
- n échantillon X_1, \dots, X_n i.i.d. de loi \mathbf{P}_θ .

Idée

Trouver le paramètre $\theta \in \Theta$ tel que les moments empiriques coïncident avec les moments théoriques :

$$\hat{m}_j = \frac{1}{n} \sum_{i=1}^n X_i^j \approx m_j(\theta_0) = \mathbf{E}_{\theta_0}(X_i^j), \quad j = 1, \dots, p.$$

Si $p = 1$ la méthode revient à résoudre l'équation en θ :

$$\frac{1}{n} \sum_{i=1}^n X_i = \mathbf{E}_\theta(X_1).$$

- modèle $(\mathcal{H}, \{\mathbf{P}_\theta, \theta \in \Theta\})$.
- n échantillon X_1, \dots, X_n i.i.d. de loi \mathbf{P}_θ .

Idée

Trouver le paramètre $\theta \in \Theta$ tel que les moments empiriques coïncident avec les moments théoriques :

$$\hat{m}_j = \frac{1}{n} \sum_{i=1}^n X_i^j \approx m_j(\theta_0) = \mathbf{E}_{\theta_0}(X_i^j), \quad j = 1, \dots, p.$$

Si $p = 1$ la méthode revient à résoudre l'équation en θ :

$$\frac{1}{n} \sum_{i=1}^n X_i = \mathbf{E}_\theta(X_1).$$

L'estimateur des moments est défini comme la solution du système à p équations :

$$\begin{cases} m_1(\theta) = \hat{m}_1 \\ \vdots \\ m_p(\theta) = \hat{m}_p \end{cases}$$

Si

$$M : \Theta \rightarrow \mathcal{L}$$

$$\theta \mapsto (m_1(\theta), \dots, m_p(\theta))$$

est une bijection. Alors l'estimateur des moments existe et est unique.

L'estimateur des moments est défini comme la solution du système à p équations :

$$\begin{cases} m_1(\theta) = \hat{m}_1 \\ \vdots \\ m_p(\theta) = \hat{m}_p \end{cases}$$

Si

$$\begin{aligned} M : \Theta &\rightarrow \mathcal{L} \\ \theta &\mapsto (m_1(\theta), \dots, m_p(\theta)) \end{aligned}$$

est une bijection. Alors l'estimateur des moments existe et est unique.

Pour le modèle gaussien $\mathbf{P}_\theta = \mathcal{N}(\mu, \sigma^2)$, il est facile de voir que l'estimateur des moments $\hat{\theta} = (\hat{\mu}, \hat{\sigma}^2)$ est

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i \quad \text{et} \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \hat{\mu}^2.$$

Rappel

Si \mathbf{P}_θ est d'ordre p , la LFGN et le TCL assure la consistance et la normalité asymptotique des moments empiriques.

Théorème

Soit $\hat{\theta}$ l'estimateur des moments.

- 1 Si \mathbf{P}_θ admet un moment d'ordre p fini et si M est un homéomorphisme alors $\hat{\theta}$ est consistant.
- 2 Si \mathbf{P}_θ admet un moment d'ordre $2p$ fini et si M est un difféomorphisme alors

$$\sqrt{n}(\hat{\theta} - \theta) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \mathbb{V}_\theta)$$

où $\mathbb{V}_\theta = DM_\theta^{-1} \Sigma_\theta (DM_\theta^{-1})'$ et $\Sigma_\theta = \mathbf{V}(X_1, X_1^2, \dots, X_1^p)$.

Rappel

Si \mathbf{P}_θ est d'ordre p , la LFGN et le TCL assure la consistance et la normalité asymptotique des moments empiriques.

Théorème

Soit $\hat{\theta}$ l'estimateur des moments.

- 1 Si \mathbf{P}_θ admet un moment d'ordre p fini et si M est un homéomorphisme alors $\hat{\theta}$ est consistant.
- 2 Si \mathbf{P}_θ admet un moment d'ordre $2p$ fini et si M est un difféoéomorphisme alors

$$\sqrt{n}(\hat{\theta} - \theta) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \mathbb{V}_\theta)$$

où $\mathbb{V}_\theta = DM_\theta^{-1} \Sigma_\theta (DM_\theta^{-1})'$ et $\Sigma_\theta = \mathbf{V}(X_1, X_1^2, \dots, X_1^p)$.

Rappel

Si \mathbf{P}_θ est d'ordre p , la LFGN et le TCL assure la consistance et la normalité asymptotique des moments empiriques.

Théorème

Soit $\hat{\theta}$ l'estimateur des moments.

- 1 Si \mathbf{P}_θ admet un moment d'ordre p fini et si M est un homéomorphisme alors $\hat{\theta}$ est consistant.
- 2 Si \mathbf{P}_θ admet un moment d'ordre $2p$ fini et si M est un difféoéomorphisme alors

$$\sqrt{n}(\hat{\theta} - \theta) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \mathbb{V}_\theta)$$

où $\mathbb{V}_\theta = DM_\theta^{-1} \Sigma_\theta (DM_\theta^{-1})'$ et $\Sigma_\theta = \mathbf{V}(X_1, X_1^2, \dots, X_1^p)$.

Retour à l'exemple 1

- X_1, \dots, X_n i.i.d. $X_1 \sim B(p)$.
- x_1, \dots, x_n réalisations de X_1, \dots, X_n .

Idée

- 1 La quantité $L(x_1, \dots, x_n; p) = \mathbf{P}_p(X_1 = x_1, \dots, X_n = x_n)$ peut être vue comme une mesure de la probabilité d'observer les données dont on dispose.
 - 2 Choisir le paramètre p qui maximise cette probabilité.
-
- $L(x_1, \dots, x_n; p)$ est appelée **vraisemblance** (elle mesure la vraisemblance des réalisations x_1, \dots, x_n sous la loi \mathbf{P}_p).
 - L'approche consiste à choisir p qui "rend ces réalisations les plus vraisemblables possible".

Retour à l'exemple 1

- X_1, \dots, X_n i.i.d. $X_1 \sim B(p)$.
- x_1, \dots, x_n réalisations de X_1, \dots, X_n .

Idée

- 1 La quantité $L(x_1, \dots, x_n; p) = \mathbf{P}_p(X_1 = x_1, \dots, X_n = x_n)$ peut être vue comme une mesure de la probabilité d'observer les données dont on dispose.
 - 2 Choisir le paramètre p qui maximise cette probabilité.
- $L(x_1, \dots, x_n; p)$ est appelée **vraisemblance** (elle mesure la vraisemblance des réalisations x_1, \dots, x_n sous la loi \mathbf{P}_p).
 - L'approche consiste à choisir p qui "rend ces réalisations les plus vraisemblables possible".

Retour à l'exemple 1

- X_1, \dots, X_n i.i.d. $X_1 \sim B(p)$.
- x_1, \dots, x_n réalisations de X_1, \dots, X_n .

Idée

- 1 La quantité $L(x_1, \dots, x_n; p) = \mathbf{P}_p(X_1 = x_1, \dots, X_n = x_n)$ peut être vue comme une mesure de la probabilité d'observer les données dont on dispose.
 - 2 Choisir le paramètre p qui maximise cette probabilité.
-
- $L(x_1, \dots, x_n; p)$ est appelée **vraisemblance** (elle mesure la vraisemblance des réalisations x_1, \dots, x_n sous la loi \mathbf{P}_p).
 - L'approche consiste à choisir p qui "rend ces réalisations les plus vraisemblables possible".

Cas discret

La **vraisemblance** du paramètre θ pour la réalisation (x_1, \dots, x_n) est l'application $L : \mathcal{H}^n \times \Theta$ définie par

$$L(x_1, \dots, x_n; \theta) = \mathbf{P}_\theta^{\otimes n}(\{x_1, \dots, x_n\}) = \prod_{i=1}^n \mathbf{P}_\theta(\{x_i\}).$$

Cas absolument continu

Soit $f(\cdot, \theta)$ la densité associée à \mathbf{P}_θ . La **vraisemblance** du paramètre θ pour la réalisation (x_1, \dots, x_n) est l'application $L : \mathcal{H}^n \times \Theta$ définie par

$$L(x_1, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i, \theta).$$

Cas discret

La **vraisemblance** du paramètre θ pour la réalisation (x_1, \dots, x_n) est l'application $L : \mathcal{H}^n \times \Theta$ définie par

$$L(x_1, \dots, x_n; \theta) = \mathbf{P}_\theta^{\otimes n}(\{x_1, \dots, x_n\}) = \prod_{i=1}^n \mathbf{P}_\theta(\{x_i\}).$$

Cas absolument continu

Soit $f(\cdot, \theta)$ la densité associée à \mathbf{P}_θ . La **vraisemblance** du paramètre θ pour la réalisation (x_1, \dots, x_n) est l'application $L : \mathcal{H}^n \times \Theta$ définie par

$$L(x_1, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i, \theta).$$

Définition

Un **estimateur du maximum de vraisemblance (EMV)** est une statistique g qui maximise la vraisemblance, c'est-à-dire

$$\forall (x_1, \dots, x_n) \in \mathcal{H}^n$$

$$L(x_1, \dots, x_n; g(x_1, \dots, x_n)) = \sup_{\theta \in \Theta} L(x_1, \dots, x_n; \theta).$$

L'EMV s'écrit donc $\hat{\theta} = g(X_1, \dots, X_n)$.

- Pour le modèle gaussien $\mathbf{P}_\theta = \mathcal{N}(\mu, \sigma^2)$, L'EMV est

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i \text{ et } \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \hat{\mu}^2.$$

- Il coïncide avec l'estimateur des moments.

Définition

Un **estimateur du maximum de vraisemblance (EMV)** est une statistique g qui maximise la vraisemblance, c'est-à-dire

$$\forall (x_1, \dots, x_n) \in \mathcal{H}^n$$

$$L(x_1, \dots, x_n; g(x_1, \dots, x_n)) = \sup_{\theta \in \Theta} L(x_1, \dots, x_n; \theta).$$

L'EMV s'écrit donc $\hat{\theta} = g(X_1, \dots, X_n)$.

- Pour le modèle gaussien $\mathbf{P}_\theta = \mathcal{N}(\mu, \sigma^2)$, L'EMV est

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i \text{ et } \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \hat{\mu}^2.$$

- Il coïncide avec l'estimateur des moments.

Invariance

Soit $\psi : \Theta \rightarrow \mathbb{R}^k$ et $\hat{\theta}$ l'EMV de θ . Alors l'emv de $\psi(\theta)$ est $\psi(\hat{\theta})$.

Consistance

On suppose que \mathbf{P}_θ admet une densité $f(x, \theta)$, que Θ est un ouvert et que $\theta \mapsto f(x, \theta)$ est différentiable. Alors l'EMV $\hat{\theta}$ est consistant.

Invariance

Soit $\psi : \Theta \rightarrow \mathbb{R}^k$ et $\hat{\theta}$ l'EMV de θ . Alors l'emv de $\psi(\theta)$ est $\psi(\hat{\theta})$.

Consistance

On suppose que \mathbf{P}_θ admet une densité $f(x, \theta)$, que Θ est un ouvert et que $\theta \mapsto f(x, \theta)$ est différentiable. Alors l'EMV $\hat{\theta}$ est consistant.

1

Introduction

- Quelques exemples
- Rappels sur les variables aléatoires
- Modèle statistique

2

Qualités d'un estimateur

- Biais, variance et risque quadratique
- Critère de performance asymptotique
- 2 méthodes d'estimation
 - La méthode des moments
 - La méthode du maximum de vraisemblance

3

Information de Fisher et Borne de Cramer Rao

- Dimension 1
- Dimension p

4

Estimation par intervalle de confiance

1

Introduction

- Quelques exemples
- Rappels sur les variables aléatoires
- Modèle statistique

2

Qualités d'un estimateur

- Biais, variance et risque quadratique
- Critère de performance asymptotique
- 2 méthodes d'estimation
 - La méthode des moments
 - La méthode du maximum de vraisemblance

3

Information de Fisher et Borne de Cramer Rao

- Dimension 1
- Dimension p

4

Estimation par intervalle de confiance

- On se place dans le cas où θ est réel.

Objectif : montrer que sous certaines hypothèses de régularité l'EMV est asymptotiquement VUMSB :

- 1 $\hat{\theta}$ est asymptotiquement sans biais.
- 2 il existe une fonction $r(n, \theta)$ telle que pour tout estimateur T sans biais de θ , on a $\mathbf{V}(T) \geq r(n, \theta)$.
- 3 la variance asymptotique de l'EMV vaut $r(n, \theta)$.

L'information de Fisher

Soit $\mathcal{M} = (\mathcal{H}, \{\mathbf{P}_\theta, \theta \in \Theta\})$ un modèle. On suppose dans cette partie que :

- Θ est un ouvert.
- \mathbf{P}_θ admet une densité $f(x, \theta)$ (par rapport à la mesure de Lebesgue ou à la mesure de comptage) et que f est deux fois dérivable par rapport à θ .
- $\forall h \in L^1(\mathbf{P}_\theta)$ on a

$$\frac{\partial}{\partial \theta} \int h(x) f(x, \theta) dx = \int h(x) \frac{\partial}{\partial \theta} f(x, \theta) dx.$$

On appelle **information de Fisher** du modèle \mathcal{M} au point θ :

$$I(\theta) = \mathbf{E}_\theta \left[\left(\frac{\partial}{\partial \theta} \log(f(X, \theta)) \right)^2 \right].$$

- **Fonction de score :**

$$S(x, \theta) = \frac{\partial}{\partial \theta} \log(f(x, \theta)).$$

Propriété

$$I(\theta) = -\mathbf{E}_{\theta} \left[\frac{\partial^2}{\partial \theta^2} \log(f(X, \theta)) \right].$$

$$I(\theta) \geq 0 \text{ et } I(\theta) = 0 \Leftrightarrow f(x, \theta) = f(\theta).$$

$I(\theta)$ mesure en quelque sorte le pouvoir de discrimination du modèle entre deux valeurs proches du paramètre θ :

- $I(\theta)$ grand : il sera "facile" d'identifier quel modèle est le meilleur.
- $I(\theta)$ petit : l'identification sera plus difficile.

- **Fonction de score :**

$$S(x, \theta) = \frac{\partial}{\partial \theta} \log(f(x, \theta)).$$

Propriété

$$I(\theta) = -\mathbf{E}_{\theta} \left[\frac{\partial^2}{\partial \theta^2} \log(f(X, \theta)) \right].$$

$$I(\theta) \geq 0 \text{ et } I(\theta) = 0 \Leftrightarrow f(x, \theta) = f(\theta).$$

$I(\theta)$ mesure en quelque sorte le pouvoir de discrimination du modèle entre deux valeurs proches du paramètre θ :

- $I(\theta)$ grand : il sera "facile" d'identifier quel modèle est le meilleur.
- $I(\theta)$ petit : l'identification sera plus difficile.

Propriété d'additivité

Si X_1 et X_2 sont deux variables i.i.d. de loi \mathbf{P}_θ , alors

$$I_{(X_1, X_2)}(\theta) = I_{X_1}(\theta) + I_{X_2}(\theta) = 2I_{X_1}(\theta).$$

Corollaire

L'information de Fisher du modèle produit \mathcal{M}_n au point θ vaut

$$I_n(\theta) = nI(\theta).$$

Sur l'exemple 1, on a $I_n(p) = \frac{n}{p(1-p)}$.

Propriété d'additivité

Si X_1 et X_2 sont deux variables i.i.d. de loi \mathbf{P}_θ , alors

$$I_{(X_1, X_2)}(\theta) = I_{X_1}(\theta) + I_{X_2}(\theta) = 2I_{X_1}(\theta).$$

Corollaire

L'**information de Fisher** du modèle produit \mathcal{M}_n au point θ vaut

$$I_n(\theta) = nI(\theta).$$

Sur l'exemple 1, on a $I_n(p) = \frac{n}{p(1-p)}$.

Propriété d'additivité

Si X_1 et X_2 sont deux variables i.i.d. de loi \mathbf{P}_θ , alors

$$I_{(X_1, X_2)}(\theta) = I_{X_1}(\theta) + I_{X_2}(\theta) = 2I_{X_1}(\theta).$$

Corollaire

L'**information de Fisher** du modèle produit \mathcal{M}_n au point θ vaut

$$I_n(\theta) = nI(\theta).$$

Sur l'exemple 1, on a $I_n(p) = \frac{n}{p(1-p)}$.

Théorème

Soit $T = T(X_1, \dots, X_n)$ un estimateur sans biais de θ . Alors

$$\mathbf{V}(T) \geq \frac{1}{I_n(\theta)}.$$

- 1 La quantité $\frac{1}{I_n(\theta)}$ est appelée borne de Cramer-Rao.
- 2 Si un estimateur sans biais $\hat{\theta}$ atteint la borne de Cramer-Rao, il est VUMSB.
- 3 Si T est un estimateur sans biais de $g(\theta)$ avec g dérivable, alors
$$\mathbf{V}(T) \geq \frac{(g'(\theta))^2}{I_n(\theta)}.$$

Exemple 1

$\hat{\rho} = \bar{X}$ est VUMSB.

Théorème

Soit $T = T(X_1, \dots, X_n)$ un estimateur sans biais de θ . Alors

$$\mathbf{V}(T) \geq \frac{1}{I_n(\theta)}.$$

- 1 La quantité $\frac{1}{I_n(\theta)}$ est appelée borne de Cramer-Rao.
- 2 Si un estimateur sans biais $\hat{\theta}$ atteint la borne de Cramer-Rao, il est VUMSB.
- 3 Si T est un estimateur sans biais de $g(\theta)$ avec g dérivable, alors
$$\mathbf{V}(T) \geq \frac{(g'(\theta))^2}{I_n(\theta)}.$$

Exemple 1

$\hat{\rho} = \bar{X}$ est VUMSB.

Théorème

Soit $T = T(X_1, \dots, X_n)$ un estimateur sans biais de θ . Alors

$$\mathbf{V}(T) \geq \frac{1}{I_n(\theta)}.$$

- 1 La quantité $\frac{1}{I_n(\theta)}$ est appelée borne de Cramer-Rao.
- 2 Si un estimateur sans biais $\hat{\theta}$ atteint la borne de Cramer-Rao, il est VUMSB.
- 3 Si T est un estimateur sans biais de $g(\theta)$ avec g dérivable, alors
$$\mathbf{V}(T) \geq \frac{(g'(\theta))^2}{I_n(\theta)}.$$

Exemple 1

$\hat{\rho} = \bar{X}$ est VUMSB.

Théorème

Sous certaines conditions de régularité sur la densité $f(x, \theta)$, l'EMV $\hat{\theta}_n$ est asymptotiquement gaussien et

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{\mathcal{L}} N\left(0, \frac{1}{I(\theta)}\right).$$

- $\hat{\theta}_n$ est asymptotiquement sans biais.
- $\hat{\theta}_n$ est asymptotiquement efficace.
- $\hat{\theta}_n$ converge vers θ en moyenne quadratique.

Théorème

Sous certaines conditions de régularité sur la densité $f(x, \theta)$, l'EMV $\hat{\theta}_n$ est asymptotiquement gaussien et

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{\mathcal{L}} N\left(0, \frac{1}{I(\theta)}\right).$$

- $\hat{\theta}_n$ est asymptotiquement sans biais.
- $\hat{\theta}_n$ est asymptotiquement efficace.
- $\hat{\theta}_n$ converge vers θ en moyenne quadratique.

1

Introduction

- Quelques exemples
- Rappels sur les variables aléatoires
- Modèle statistique

2

Qualités d'un estimateur

- Biais, variance et risque quadratique
- Critère de performance asymptotique
- 2 méthodes d'estimation
 - La méthode des moments
 - La méthode du maximum de vraisemblance

3

Information de Fisher et Borne de Cramer Rao

- Dimension 1
- Dimension p

4

Estimation par intervalle de confiance

- On se place dans un modèle de densités $\mathcal{M} = (\mathcal{H}, \{\mathbf{P}_\theta, \theta \in \mathbb{R}^p\})$, où $\mathbf{P}_\theta \sim f(\cdot, \theta)$;
- On note $\hat{\theta} = (\hat{\theta}_1, \dots, \hat{\theta}_p)'$ un estimateur du paramètre $\theta = (\theta_1, \dots, \theta_p)'$ de matrice de variance covariance $\Sigma_{\hat{\theta}}$.

Définition

La matrice d'information de Fisher au point θ du modèle ci-dessus est la matrice de dimension $p \times p$ définie par

$$\begin{aligned} I(\theta)_{i,j} &= \mathbf{E}_\theta \left[\frac{\partial}{\partial \theta_i} \log(f(X, \theta)) \frac{\partial}{\partial \theta_j} \log(f(X, \theta)) \right] \\ &= - \mathbf{E}_\theta \left[\frac{\partial^2}{\partial \theta_i \partial \theta_j} \log(f(X, \theta)) \right]. \end{aligned}$$

Théorème

La borne de Cramer-Rao du modèle précédent est $\frac{1}{n}I(\theta)^{-1}$. C'est-à-dire que pour tout estimateur sans biais $\hat{\theta}$ de θ , on a

$$\Sigma_{\hat{\theta}} \geq \frac{1}{n}I(\theta)^{-1}$$

(l'inégalité est à prendre au sens des matrices sdv).

Un exemple : le modèle gaussien

Pour le modèle gaussien $\mathbf{P}_\theta = \mathcal{N}(\mu, \sigma^2)$, la matrice d'information de Fisher est donnée par :

$$I(\theta) = \begin{pmatrix} \frac{1}{\sigma^2} & 0 \\ 0 & \frac{1}{2\sigma^4} \end{pmatrix}.$$

La borne de Cramer-Rao vaut

$$BCR = \begin{pmatrix} \frac{\sigma^2}{n} & 0 \\ 0 & \frac{2\sigma^4}{n} \end{pmatrix}.$$

Un exemple : le modèle gaussien

Pour le modèle gaussien $\mathbf{P}_\theta = \mathcal{N}(\mu, \sigma^2)$, la matrice d'information de Fisher est donnée par :

$$I(\theta) = \begin{pmatrix} \frac{1}{\sigma^2} & 0 \\ 0 & \frac{1}{2\sigma^4} \end{pmatrix}.$$

La borne de Cramer-Rao vaut

$$BCR = \begin{pmatrix} \frac{\sigma^2}{n} & 0 \\ 0 & \frac{2\sigma^4}{n} \end{pmatrix}.$$

- **Question** : l'estimateur $\tilde{\theta} = (\bar{X}, S^2)$ est-il efficace ?

Rappel : Corollaire de Cochran

Soit X_1, \dots, X_n un échantillon i.i.d. de loi $\mathcal{N}(\mu, \sigma^2)$. Alors :

- 1 $\bar{X} \sim \mathcal{N}(\mu, \sigma^2/n)$;
- 2 \bar{X} et $\hat{\sigma}^2$ sont indépendantes ;
- 3 $(n\hat{\sigma}^2)/\sigma^2 \sim \chi^2_{(n-1)}$.

- On déduit

$$\Sigma_{\tilde{\theta}} = \begin{pmatrix} \frac{\sigma^2}{n} & 0 \\ 0 & \frac{2\sigma^4}{n-1} \end{pmatrix}$$

$\tilde{\theta}$ est (presque) efficace.

- **Question** : l'estimateur $\tilde{\theta} = (\bar{X}, S^2)$ est-il efficace ?

Rappel : Corollaire de Cochran

Soit X_1, \dots, X_n un échantillon i.i.d. de loi $\mathcal{N}(\mu, \sigma^2)$. Alors :

- 1 $\bar{X} \sim \mathcal{N}(\mu, \sigma^2/n)$;
- 2 \bar{X} et $\hat{\sigma}^2$ sont indépendantes ;
- 3 $(n\hat{\sigma}^2)/\sigma^2 \sim \chi^2_{(n-1)}$.

- On déduit

$$\Sigma_{\tilde{\theta}} = \begin{pmatrix} \frac{\sigma^2}{n} & 0 \\ 0 & \frac{2\sigma^4}{n-1} \end{pmatrix}$$

$\tilde{\theta}$ est (presque) efficace.

Théorème

On se place dans un modèle de densité $(\mathcal{H}, \{f(\cdot, \theta), \theta \in \Theta\})$. Sous certaines hypothèses de régularité sur la densité f , l'emv $\hat{\theta}$ de θ est

- consistant ;
- asymptotiquement normal :

$$\sqrt{n}(\hat{\theta} - \theta) \xrightarrow{\mathcal{L}} \mathcal{N}(0, I(\theta)^{-1}).$$

Retour au modèle gaussien

L'emv est donné par $\hat{\theta} = (\bar{X}, \hat{\sigma}^2)$. On obtient par Cochran

$$\begin{aligned} \sqrt{n}(\hat{\theta} - \theta) &\sim \mathcal{N}\left(0, \begin{pmatrix} \sigma^2 & 0 \\ 0 & 2\sigma^4 \frac{n-1}{n} \end{pmatrix}\right) \\ &\xrightarrow{\mathcal{L}} \mathcal{N}(0, I(\theta)^{-1}). \end{aligned}$$

Théorème

On se place dans un modèle de densité $(\mathcal{H}, \{f(\cdot, \theta), \theta \in \Theta\})$. Sous certaines hypothèses de régularité sur la densité f , l'emv $\hat{\theta}$ de θ est

- consistant ;
- asymptotiquement normal :

$$\sqrt{n}(\hat{\theta} - \theta) \xrightarrow{\mathcal{L}} \mathcal{N}(0, I(\theta)^{-1}).$$

Retour au modèle gaussien

L'emv est donné par $\hat{\theta} = (\bar{X}, \hat{\sigma}^2)$. On obtient par Cochran

$$\begin{aligned} \sqrt{n}(\hat{\theta} - \theta) &\sim \mathcal{N}\left(0, \begin{pmatrix} \sigma^2 & 0 \\ 0 & 2\sigma^4 \frac{n-1}{n} \end{pmatrix}\right) \\ &\xrightarrow{\mathcal{L}} \mathcal{N}(0, I(\theta)^{-1}). \end{aligned}$$

1 Introduction

- Quelques exemples
- Rappels sur les variables aléatoires
- Modèle statistique

2 Qualités d'un estimateur

- Biais, variance et risque quadratique
- Critère de performance asymptotique
- 2 méthodes d'estimation
 - La méthode des moments
 - La méthode du maximum de vraisemblance

3 Information de Fisher et Borne de Cramer Rao

- Dimension 1
- Dimension p

4 Estimation par intervalle de confiance

- Donner une seule valeur pour estimer un paramètre peut se révéler trop ambitieux.
- **Exemple 1** : le taux de guérison du traitement est de 72% (alors qu'on ne l'a testé que sur 100 patients).
- Il peut parfois être plus raisonnable de donner une réponse dans le genre, le taux de guérison se trouve dans l'intervalle $[70\%, 74\%]$ avec une confiance de 90%.

- Donner une seule valeur pour estimer un paramètre peut se révéler trop ambitieux.
- **Exemple 1** : le taux de guérison du traitement est de 72% (alors qu'on ne l'a testé que sur 100 patients).
- Il peut parfois être plus raisonnable de donner une réponse dans le genre, le taux de guérison se trouve dans l'intervalle [70%, 74%] avec une confiance de 90%.

Intervalle de confiance

- X_1, \dots, X_n n échantillon i.i.d. de loi \mathbf{P}_{θ_0} .

Définition

Soit $\alpha \in]0, 1[$. On appelle intervalle de confiance pour θ_0 tout intervalle de la forme $[A_n, B_n]$, où A_n et B_n sont des fonctions mesurables telles que $\forall \theta \in \Theta$:

$$\mathbf{P}_{\theta}(\theta \in [A_n, B_n]) = 1 - \alpha.$$

Si $\lim_{n \rightarrow \infty} \mathbf{P}_{\theta}(\theta \in [A_n, B_n]) = 1 - \alpha$, on dit que $[A_n, B_n]$ est un intervalle de confiance asymptotique pour θ_0 au niveau $1 - \alpha$.

Remarque importante

- Les quantités $A_n = A_n(X_1, \dots, X_n)$ et $B_n = B_n(X_1, \dots, X_n)$ sont **aléatoires** !
- Les logiciels renverront les réels $a_n = A_n(x_1, \dots, x_n)$ et $b_n = B_n(x_1, \dots, x_n)$.

Intervalle de confiance

- X_1, \dots, X_n n échantillon i.i.d. de loi \mathbf{P}_{θ_0} .

Définition

Soit $\alpha \in]0, 1[$. On appelle intervalle de confiance pour θ_0 tout intervalle de la forme $[A_n, B_n]$, où A_n et B_n sont des fonctions mesurables telles que $\forall \theta \in \Theta$:

$$\mathbf{P}_{\theta}(\theta \in [A_n, B_n]) = 1 - \alpha.$$

Si $\lim_{n \rightarrow \infty} \mathbf{P}_{\theta}(\theta \in [A_n, B_n]) = 1 - \alpha$, on dit que $[A_n, B_n]$ est un intervalle de confiance asymptotique pour θ_0 au niveau $1 - \alpha$.

Remarque importante

- Les quantités $A_n = A_n(X_1, \dots, X_n)$ et $B_n = B_n(X_1, \dots, X_n)$ sont **aléatoires** !
- Les logiciels renverront les réels $a_n = A_n(x_1, \dots, x_n)$ et $b_n = B_n(x_1, \dots, x_n)$.

Intervalle de confiance

- X_1, \dots, X_n n échantillon i.i.d. de loi \mathbf{P}_{θ_0} .

Définition

Soit $\alpha \in]0, 1[$. On appelle intervalle de confiance pour θ_0 tout intervalle de la forme $[A_n, B_n]$, où A_n et B_n sont des fonctions mesurables telles que $\forall \theta \in \Theta$:

$$\mathbf{P}_{\theta}(\theta \in [A_n, B_n]) = 1 - \alpha.$$

Si $\lim_{n \rightarrow \infty} \mathbf{P}_{\theta}(\theta \in [A_n, B_n]) = 1 - \alpha$, on dit que $[A_n, B_n]$ est un intervalle de confiance asymptotique pour θ_0 au niveau $1 - \alpha$.

Remarque importante

- Les quantités $A_n = A_n(X_1, \dots, X_n)$ et $B_n = B_n(X_1, \dots, X_n)$ sont **aléatoires** !
- Les logiciels renverront les réels $a_n = A_n(x_1, \dots, x_n)$ et $b_n = B_n(x_1, \dots, x_n)$.

Intervalle de confiance

- X_1, \dots, X_n n échantillon i.i.d. de loi \mathbf{P}_{θ_0} .

Définition

Soit $\alpha \in]0, 1[$. On appelle intervalle de confiance pour θ_0 tout intervalle de la forme $[A_n, B_n]$, où A_n et B_n sont des fonctions mesurables telles que $\forall \theta \in \Theta$:

$$\mathbf{P}_{\theta}(\theta \in [A_n, B_n]) = 1 - \alpha.$$

Si $\lim_{n \rightarrow \infty} \mathbf{P}_{\theta}(\theta \in [A_n, B_n]) = 1 - \alpha$, on dit que $[A_n, B_n]$ est un intervalle de confiance asymptotique pour θ_0 au niveau $1 - \alpha$.

Remarque importante

- Les quantités $A_n = A_n(X_1, \dots, X_n)$ et $B_n = B_n(X_1, \dots, X_n)$ sont **aléatoires** !
- Les logiciels renverront les réels $a_n = A_n(x_1, \dots, x_n)$ et $b_n = B_n(x_1, \dots, x_n)$.

- Inégalité de Bienaymé Tchebychev.
- Utilisation d'une **fonction pivotable pour le paramètre θ** : fonction mesurable des observations et du paramètre inconnu mais dont la loi ne dépend pas de θ .

Méthode

- 1 se donner un niveau $1 - \alpha$.
- 2 trouver un estimateur $\hat{\theta}_n$ de θ dont on connaît la loi afin de construire une fonction pivotable.

- Inégalité de Bienaymé Tchebychev.
- Utilisation d'une **fonction pivotable pour le paramètre θ** : fonction mesurable des observations et du paramètre inconnu mais dont la loi ne dépend pas de θ .

Méthode

- 1 se donner un niveau $1 - \alpha$.
- 2 trouver un estimateur $\hat{\theta}_n$ de θ dont on connaît la loi afin de construire une fonction pivotable.

- Inégalité de Bienaymé Tchebychev.
- Utilisation d'une **fonction pivotable pour le paramètre θ** : fonction mesurable des observations et du paramètre inconnu mais dont la loi ne dépend pas de θ .

Méthode

- 1 se donner un niveau $1 - \alpha$.
- 2 trouver un estimateur $\hat{\theta}_n$ de θ dont on connaît la loi afin de construire une fonction pivotable.

Exemple

- 1 On considère le modèle gaussien $\mathcal{P} = \{\mathcal{N}(\mu, 4), \mu \in \mathbb{R}\}$ et on cherche un intervalle de confiance de niveau 95% pour μ .
- 2 On pose $\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i$. On a

$$\frac{\sqrt{n}}{2}(\hat{\mu} - \mu) \sim \mathcal{N}(0, 1).$$

- 3 On déduit

$$IC_{95\%}(\mu) = \left[\hat{\mu} - q_{0.975} \frac{2}{\sqrt{n}}; \hat{\mu} + q_{0.975} \frac{2}{\sqrt{n}} \right].$$

Exemple

- 1 On considère le modèle gaussien $\mathcal{P} = \{\mathcal{N}(\mu, 4), \mu \in \mathbb{R}\}$ et on cherche un intervalle de confiance de niveau 95% pour μ .
- 2 On pose $\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i$. On a

$$\frac{\sqrt{n}}{2}(\hat{\mu} - \mu) \sim \mathcal{N}(0, 1).$$

- 3 On déduit

$$IC_{95\%}(\mu) = \left[\hat{\mu} - q_{0.975} \frac{2}{\sqrt{n}}; \hat{\mu} + q_{0.975} \frac{2}{\sqrt{n}} \right].$$

Exemple

- 1 On considère le modèle gaussien $\mathcal{P} = \{\mathcal{N}(\mu, 4), \mu \in \mathbb{R}\}$ et on cherche un intervalle de confiance de niveau 95% pour μ .
- 2 On pose $\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i$. On a

$$\frac{\sqrt{n}}{2}(\hat{\mu} - \mu) \sim \mathcal{N}(0, 1).$$

- 3 On déduit

$$IC_{95\%}(\mu) = \left[\hat{\mu} - q_{0.975} \frac{2}{\sqrt{n}}; \hat{\mu} + q_{0.975} \frac{2}{\sqrt{n}} \right].$$

- ① $P_\theta = \mathcal{N}(\mu_0, \sigma^2)$ avec σ^2 connu :

$$IC_{1-\alpha}(\mu_0) = \left[\bar{X} - q_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + q_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} \right].$$

- ② $P_\theta = \mathcal{N}(\mu_0, \sigma^2)$ avec σ^2 inconnu :

$$IC_{1-\alpha}(\mu_0) = \left[\bar{X} - t_{1-\alpha/2} \frac{S_n}{\sqrt{n}}, \bar{X} + t_{1-\alpha/2} \frac{S_n}{\sqrt{n}} \right].$$

- ③ P_θ d'espérance μ_0 et de variance σ^2 inconnue :

$$IC_{1-\alpha}^{asympt}(\mu_0) = \left[\bar{X} - t_{1-\alpha/2} \frac{S_n}{\sqrt{n}}, \bar{X} + t_{1-\alpha/2} \frac{S_n}{\sqrt{n}} \right].$$

- Soit X_1, \dots, X_n i.i.d. de loi $\mathcal{B}(p_0)$.
- On pose $\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i$. On a d'après le **TCL**

$$\frac{\sqrt{n}}{\sqrt{p_0(1-p_0)}}(\hat{p} - p_0) \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1).$$

- On pose

$$IC_{1-\alpha}(p_0) = \left[\hat{p} - q_{1-\alpha/2} \sqrt{\frac{p_0(1-p_0)}{n}}; \hat{p} + q_{1-\alpha/2} \sqrt{\frac{p_0(1-p_0)}{n}} \right].$$

- **Prolème** : l'IC dépend de p_0 et n'est donc **pas calculable**.

- Soit X_1, \dots, X_n i.i.d. de loi $\mathcal{B}(p_0)$.
- On pose $\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i$. On a d'après le **TCL**

$$\frac{\sqrt{n}}{\sqrt{p_0(1-p_0)}}(\hat{p} - p_0) \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1).$$

- On pose

$$IC_{1-\alpha}(p_0) = \left[\hat{p} - q_{1-\alpha/2} \sqrt{\frac{p_0(1-p_0)}{n}}; \hat{p} + q_{1-\alpha/2} \sqrt{\frac{p_0(1-p_0)}{n}} \right].$$

- **Prolème** : l'IC dépend de p_0 et n'est donc **pas calculable**.

- Soit X_1, \dots, X_n i.i.d. de loi $\mathcal{B}(p_0)$.
- On pose $\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i$. On a d'après le **TCL**

$$\frac{\sqrt{n}}{\sqrt{p_0(1-p_0)}}(\hat{p} - p_0) \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1).$$

- On pose

$$IC_{1-\alpha}(p_0) = \left[\hat{p} - q_{1-\alpha/2} \sqrt{\frac{p_0(1-p_0)}{n}}; \hat{p} + q_{1-\alpha/2} \sqrt{\frac{p_0(1-p_0)}{n}} \right].$$

- **Prolème** : l'IC dépend de p_0 et n'est donc **pas calculable**.

- On peut montrer que

$$\frac{\sqrt{n}}{\sqrt{\hat{p}(1-\hat{p})}}(\hat{p} - p_0) \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1),$$

- et en déduire l'intervalle de confiance asymptotique

$$IC_{1-\alpha}(p_0) = \left[\hat{p} - q_{1-\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}; \hat{p} + q_{1-\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \right].$$

Exemple sur R : IC pour une moyenne

- On s'intéresse au **poids moyen** d'adultes atteint d'une pathologie. On dispose de $n = 50$ observations.

```
> poids[1:5]
[1] 85 80 80 60 83
> t.test(poids,conf.level=0.95)
```

One Sample t-test

```
data: poids
t = 60.6608, df = 49, p-value < 2.2e-16
alternative hypothesis: true mean is not equal to 0
95 percent confidence interval:
 70.00451 74.80165
sample estimates:
mean of x
 72.40308
```

Exemple sur R : IC pour une proportion

- On effectue un sondage électoral sur $n = 500$ personnes concernant le second tour d'une élection

```
> sondage[1:5]
[1] B A A B A
Levels: A B
> binom.test(sum(sondage=="A"),500,conf.level=0.90)
```

Exact binomial test

```
data: sum(sondage == "A") and 500
number of successes = 218, number of trials = 500, p-value = 0.004792
alternative hypothesis: true probability of success is not equal to 0.5
90 percent confidence interval:
 0.3988760 0.4736887
sample estimates:
probability of success
      0.436
```


Quatrième partie IV

Tests d'hypothèses

1 Introduction

2 Tests paramétriques

- Vocabulaire
- Le principe de Neyman-Pearson
- Puissance de test - Test UPP
- Exemples
- Comparaison de deux échantillons gaussiens
- Cas non gaussien

3 Une introduction aux tests non paramétriques

- Le test du χ^2 d'adéquation
- Le test du χ^2 d'indépendance

1 Introduction

2 Tests paramétriques

- Vocabulaire
- Le principe de Neyman-Pearson
- Puissance de test - Test UPP
- Exemples
- Comparaison de deux échantillons gaussiens
- Cas non gaussien

3 Une introduction aux tests non paramétriques

- Le test du χ^2 d'adéquation
- Le test du χ^2 d'indépendance

Exemple 1 : test de conformité

- On s'intéresse à la longueur de pièces fabriquées par une machine.
- "En théorie" la longueur moyenne de ces pièces doit être de 150cm.
- On décide de mesurer 49 pièces choisies au hasard. La valeur moyenne des mesures est de 149.9.

Peut-on dire que la machine est toujours bien réglée ?

Exemple 1 : test de conformité

- On s'intéresse à la longueur de pièces fabriquées par une machine.
- "En théorie" la longueur moyenne de ces pièces doit être de 150cm.
- On décide de mesurer 49 pièces choisies au hasard. La valeur moyenne des mesures est de 149.9.

Peut-on dire que la machine est toujours bien réglée ?

- Un médicament couramment utilisé est connu pour guérir 60% des patients.
- Un nouveau traitement est expérimenté sur 80 patients.
- On observe 60 guérisons.

Doit-on remplacer l'ancien traitement par le nouveau ?

- Une entreprise emploie 40 hommes et 60 femmes.

Peut-on affirmer que les recruteurs sont sexistes ?

- Un médicament couramment utilisé est connu pour guérir 60% des patients.
- Un nouveau traitement est expérimenté sur 80 patients.
- On observe 60 guérisons.

Doit-on remplacer l'ancien traitement par le nouveau ?

- Une entreprise emploie 40 hommes et 60 femmes.

Peut-on affirmer que les recruteurs sont sexistes ?

Exemples 2-3

- Un médicament couramment utilisé est connu pour guérir 60% des patients.
- Un nouveau traitement est expérimenté sur 80 patients.
- On observe 60 guérisons.

Doit-on remplacer l'ancien traitement par le nouveau ?

- Une entreprise emploie 40 hommes et 60 femmes.

Peut-on affirmer que les recruteurs sont sexistes ?

Exemple 4

- On s'intéresse au nombre de garçons dans des familles de 4 enfants :

Nb de garçons	0	1	2	3	4	Total
Effectifs	3	30	39	23	5	100

Est-ce que la variable aléatoire nombre de garçons suit une loi Binomiale $\mathcal{B}(4, p)$?

Exemple 4

- On s'intéresse au nombre de garçons dans des familles de 4 enfants :

Nb de garçons	0	1	2	3	4	Total
Effectifs	3	30	39	23	5	100

Est-ce que la variable aléatoire nombre de garçons suit une loi Binomiale $\mathcal{B}(4, p)$?

Exemple 5

Le titanic a emporté à son bord :

- 325 passagers en première classe
- 285 passagers en deuxième classe
- 706 passagers en troisième classe
- 885 membres d'équipage.

Parmi les survivants on compte :

- 203 passagers en première classe
- 118 passagers en deuxième classe
- 178 passagers en troisième classe
- 212 membres d'équipage.

Existe-t-il un lien entre le fait d'avoir survécu et la classe d'appartenance ?

Exemple 5

Le titanic a emporté à son bord :

- 325 passagers en première classe
- 285 passagers en deuxième classe
- 706 passagers en troisième classe
- 885 membres d'équipage.

Parmi les survivants on compte :

- 203 passagers en première classe
- 118 passagers en deuxième classe
- 178 passagers en troisième classe
- 212 membres d'équipage.

Existe-t-il un lien entre le fait d'avoir survécu et la classe d'appartenance ?

Exemple 5

Le titanic a emporté à son bord :

- 325 passagers en première classe
- 285 passagers en deuxième classe
- 706 passagers en troisième classe
- 885 membres d'équipage.

Parmi les survivants on compte :

- 203 passagers en première classe
- 118 passagers en deuxième classe
- 178 passagers en troisième classe
- 212 membres d'équipage.

Existe-t-il un lien entre le fait d'avoir survécu et la classe d'appartenance ?

- Ici, il ne s'agit plus d'estimer un paramètre à partir d'un échantillon mais de prendre une décision à l'aide de cet échantillon.
- Répondre aux questions posées revient à choisir une hypothèse parmi deux (on les notera H_0 et H_1).
- Un **test statistique** permet de réaliser un tel choix.

	H_0	H_1
Exemple 1	$\mu = 150$	$\mu \neq 150$
Exemple 2	$p = 0.6$	$p \geq 0.6$
Exemple 3	$p_F = p_H$	$p_F \neq p_H$
Exemple 4	$X \sim \mathcal{B}(4, p)$	$X \not\sim \mathcal{B}(4, p)$
Exemple 5	$S \perp\!\!\!\perp C$	$S \not\perp\!\!\!\perp C$

1 Introduction

2 Tests paramétriques

- Vocabulaire
- Le principe de Neyman-Pearson
- Puissance de test - Test UPP
- Exemples
- Comparaison de deux échantillons gaussiens
- Cas non gaussien

3 Une introduction aux tests non paramétriques

- Le test du χ^2 d'adéquation
- Le test du χ^2 d'indépendance

1 Introduction

2 Tests paramétriques

- Vocabulaire
- Le principe de Neyman-Pearson
- Puissance de test - Test UPP
- Exemples
- Comparaison de deux échantillons gaussiens
- Cas non gaussien

3 Une introduction aux tests non paramétriques

- Le test du χ^2 d'adéquation
- Le test du χ^2 d'indépendance

Hypothèse nulle et hypothèse alternative

- **Modèle statistique** $(\mathcal{H}, \{\mathbf{P}_\theta, \theta \in \Theta\})$.
- **Hypothèse nulle** $\Rightarrow H_0 : \theta \in \Theta_0$.
- **Hypothèse alternative** $\Rightarrow H_1 : \theta \in \Theta_1$.

Si $\Theta = \{\theta\}$ l'hypothèse est dite **simple**, sinon elle est dite **multiple**.

A partir de n observations $x = (x_1, \dots, x_n)$, prendre une décision :

- accepter H_0 .
- rejeter H_0 au profit de H_1 .

Hypothèse nulle et hypothèse alternative

- **Modèle statistique** $(\mathcal{H}, \{\mathbf{P}_\theta, \theta \in \Theta\})$.
- **Hypothèse nulle** $\Rightarrow H_0 : \theta \in \Theta_0$.
- **Hypothèse alternative** $\Rightarrow H_1 : \theta \in \Theta_1$.

Si $\Theta = \{\theta\}$ l'hypothèse est dite **simple**, sinon elle est dite **multiple**.

A partir de n observations $x = (x_1, \dots, x_n)$, prendre une décision :

- accepter H_0 .
- rejeter H_0 au profit de H_1 .

Définition

- On appelle **fonction de test** toute statistique $\varphi : \mathcal{H}^n \rightarrow \{0, 1\}$
- L'ensemble $\varphi^{-1}(\{1\})$ noté \mathcal{R}_{H_0} est **la région de rejet ou région critique** du test.
- L'ensemble $\varphi^{-1}(\{0\})$ noté \mathcal{A}_{H_0} est **la région d'acceptation** du test.

Exemple

- $\mathbf{P}_\theta = \mathcal{N}(\mu, 1)$, $n = 10$.
- $H_0 : \mu = 3$ contre $H_1 : \mu = 3.5$.
- $\mathcal{R}_{H_0} = \{x \in \mathbb{R}^n : \bar{x} > s_0\}$.
- $\mathcal{A}_{H_0} = \{x \in \mathbb{R}^n : \bar{x} \leq s_0\}$.

Définition

- On appelle **fonction de test** toute statistique $\varphi : \mathcal{H}^n \rightarrow \{0, 1\}$
- L'ensemble $\varphi^{-1}(\{1\})$ noté \mathcal{R}_{H_0} est **la région de rejet ou région critique** du test.
- L'ensemble $\varphi^{-1}(\{0\})$ noté \mathcal{A}_{H_0} est **la région d'acceptation** du test.

Exemple

- $\mathbf{P}_\theta = \mathcal{N}(\mu, 1)$, $n = 10$.
- $H_0 : \mu = 3$ contre $H_1 : \mu = 3.5$.
- $\mathcal{R}_{H_0} = \{x \in \mathbb{R}^n : \bar{x} > s_0\}$.
- $\mathcal{A}_{H_0} = \{x \in \mathbb{R}^n : \bar{x} \leq s_0\}$.

Définition

- On appelle **fonction de test** toute statistique $\varphi : \mathcal{H}^n \rightarrow \{0, 1\}$
- L'ensemble $\varphi^{-1}(\{1\})$ noté \mathcal{R}_{H_0} est **la région de rejet ou région critique** du test.
- L'ensemble $\varphi^{-1}(\{0\})$ noté \mathcal{A}_{H_0} est **la région d'acceptation** du test.

Exemple

- $\mathbf{P}_\theta = \mathcal{N}(\mu, 1)$, $n = 10$.
- $H_0 : \mu = 3$ contre $H_1 : \mu = 3.5$.
- $\mathcal{R}_{H_0} = \{x \in \mathbb{R}^n : \bar{x} > s_0\}$.
- $\mathcal{A}_{H_0} = \{x \in \mathbb{R}^n : \bar{x} \leq s_0\}$.

		Réalité	
		H_0	H_1
Décision	H_0	OK	erreur de deuxième espèce
	H_1	erreur de première espèce	OK

- Le risque de première espèce d'un test φ est la fonction

$$\begin{aligned}\alpha &: \Theta_0 \rightarrow [0, 1] \\ \theta_0 &\mapsto \mathbf{P}_{\theta_0}(\mathcal{R}_{H_0})\end{aligned}$$

- Le risque de deuxième espèce d'un test φ est la fonction

$$\begin{aligned}\beta &: \Theta_1 \rightarrow [0, 1] \\ \theta_1 &\mapsto \mathbf{P}_{\theta_1}(\mathcal{A}_{H_0})\end{aligned}$$

		Réalité	
		H_0	H_1
Décision	H_0	OK	erreur de deuxième espèce
	H_1	erreur de première espèce	OK

- Le risque de première espèce d'un test φ est la fonction

$$\begin{aligned}\alpha &: \Theta_0 \rightarrow [0, 1] \\ \theta_0 &\mapsto \mathbf{P}_{\theta_0}(\mathcal{R}_{H_0})\end{aligned}$$

- Le risque de deuxième espèce d'un test φ est la fonction

$$\begin{aligned}\beta &: \Theta_1 \rightarrow [0, 1] \\ \theta_1 &\mapsto \mathbf{P}_{\theta_1}(\mathcal{A}_{H_0})\end{aligned}$$

		Réalité	
		H_0	H_1
Décision	H_0	OK	erreur de deuxième espèce
	H_1	erreur de première espèce	OK

- Le **risque de première espèce d'un test** φ est la fonction

$$\begin{aligned}\alpha &: \Theta_0 \rightarrow [0, 1] \\ \theta_0 &\mapsto \mathbf{P}_{\theta_0}(\mathcal{R}_{H_0})\end{aligned}$$

- Le **risque de deuxième espèce d'un test** φ est la fonction

$$\begin{aligned}\beta &: \Theta_1 \rightarrow [0, 1] \\ \theta_1 &\mapsto \mathbf{P}_{\theta_1}(\mathcal{A}_{H_0})\end{aligned}$$

Exemple

- $\mathbf{P}_\theta = \mathcal{N}(\mu, 1)$, $n = 10$.
- $H_0 : \mu = 3$ contre $H_1 : \mu = 3.5$.
- $\mathcal{R}_{H_0} = \{x \in \mathbb{R}^n : \bar{x} > s_0\}$.
- $\mathcal{A}_{H_0} = \{x \in \mathbb{R}^n : \bar{x} \leq s_0\}$.

- Risque de première espèce :

$$\alpha = \mathbf{P}_{H_0}(\{x \in \mathbb{R}^n : \bar{x} > s_0\}) = \mathbf{P}_{H_0}(\bar{X}_n > s_0) = 1 - F_{3,0.1}(s_0)$$

- Risque de deuxième espèce :

$$\beta = \mathbf{P}_{H_1}(\{x \in \mathbb{R}^n : \bar{x} \leq s_0\}) = F_{3.5,0.1}(s_0).$$

Exemple

- $\mathbf{P}_\theta = \mathcal{N}(\mu, 1)$, $n = 10$.
- $H_0 : \mu = 3$ contre $H_1 : \mu = 3.5$.
- $\mathcal{R}_{H_0} = \{x \in \mathbb{R}^n : \bar{x} > s_0\}$.
- $\mathcal{A}_{H_0} = \{x \in \mathbb{R}^n : \bar{x} \leq s_0\}$.

- **Risque de première espèce :**

$$\alpha = \mathbf{P}_{H_0}(\{x \in \mathbb{R}^n : \bar{x} > s_0\}) = \mathbf{P}_{H_0}(\bar{X}_n > s_0) = 1 - F_{3,0.1}(s_0)$$

- **Risque de deuxième espèce :**

$$\beta = \mathbf{P}_{H_1}(\{x \in \mathbb{R}^n : \bar{x} \leq s_0\}) = F_{3.5,0.1}(s_0).$$

- $\mathbf{P}_\theta = \mathcal{N}(\mu, 1)$, $n = 10$.
- $H_0 : \mu = 3$ contre $H_1 : \mu = 3.5$.
- $\mathcal{R}_{H_0} = \{x \in \mathbb{R}^n : \bar{x} > s_0\}$.
- $\mathcal{A}_{H_0} = \{x \in \mathbb{R}^n : \bar{x} \leq s_0\}$.

- **Risque de première espèce :**

$$\alpha = \mathbf{P}_{H_0}(\{x \in \mathbb{R}^n : \bar{x} > s_0\}) = \mathbf{P}_{H_0}(\bar{X}_n > s_0) = 1 - F_{3,0.1}(s_0)$$

- **Risque de deuxième espèce :**

$$\beta = \mathbf{P}_{H_1}(\{x \in \mathbb{R}^n : \bar{x} \leq s_0\}) = F_{3.5,0.1}(s_0).$$

1 Introduction

2 Tests paramétriques


- Vocabulaire
- Le principe de Neyman-Pearson
- Puissance de test - Test UPP
- Exemples
- Comparaison de deux échantillons gaussiens
- Cas non gaussien

3 Une introduction aux tests non paramétriques

- Le test du χ^2 d'adéquation
- Le test du χ^2 d'indépendance


Une idée

- Choisir les ensembles \mathcal{R}_{H_0} et \mathcal{A}_{H_0} qui minimisent les risques α et β .
- Si $\mathcal{A}_{H_0} = \mathcal{H}^n$ alors $\mathcal{R}_{H_0} = \emptyset$, $\alpha = 0$ et $\beta = 1$.
- Si $\mathcal{A}_{H_0} = \emptyset$ alors $\mathcal{R}_{H_0} = \mathcal{H}^n$, $\alpha = 1$ et $\beta = 0$.
- Les risques α et β varient généralement en sens inverse.



Une idée

- Choisir les ensembles \mathcal{R}_{H_0} et \mathcal{A}_{H_0} qui minimisent les risques α et β .
- Si $\mathcal{A}_{H_0} = \mathcal{H}^n$ alors $\mathcal{R}_{H_0} = \emptyset$, $\alpha = 0$ et $\beta = 1$.
- Si $\mathcal{A}_{H_0} = \emptyset$ alors $\mathcal{R}_{H_0} = \mathcal{H}^n$, $\alpha = 1$ et $\beta = 0$.
- Les risques α et β varient généralement en sens inverse.



Le principe de Neyman et Pearson

- Neyman et Pearson (1933) proposent de traiter les risques de façon non symétrique.
- On fixe tout d'abord le risque maximal de première espèce $\alpha = \sup_{\theta_0 \in \Theta_0} \alpha(\theta_0)$. Ce risque maximal est appelé **niveau du test**.

La procédure de Neyman et Pearson consiste à chercher dans l'ensemble des tests de niveau α un test optimal (dans le sens où son risque de deuxième espèce sera minimum).

Le principe de Neyman et Pearson


- Neyman et Pearson (1933) proposent de traiter les risques de façon non symétrique.
- On fixe tout d'abord le risque maximal de première espèce $\alpha = \sup_{\theta_0 \in \Theta_0} \alpha(\theta_0)$. Ce risque maximal est appelé **niveau du test**.

La procédure de Neyman et Pearson consiste à chercher dans l'ensemble des tests de niveau α un test optimal (dans le sens où son risque de deuxième espèce sera minimum).


- $\mathbf{P}_\theta = N(\mu, 1)$, $n = 10$, $H_0 = 3$ contre $H_1 = 3.5$
- Sous H_0 : $\bar{X}_n \sim \mathcal{N}(3, \frac{1}{n})$.

$$\varphi(x_1, \dots, x_n) = \mathbf{1}_{\bar{x}_n > s}$$

$$\varphi(x_1, \dots, x_n) = \mathbf{1}_{s_0 \leq \bar{x}_n \leq s_1}$$



$$\beta = \mathbf{P}_{H_1}(\bar{X}_n \leq 3.52) \approx 0.525.$$



$$\beta = \mathbf{P}_{H_1}(2.38 \leq \bar{X}_n \leq 3.62) \approx 0.648.$$

La construction d'un test de niveau α se compose des étapes suivantes :

- 1 Détermination des **hypothèses** H_0 et H_1 à partir du problème posé.
- 2 Détermination d'une **statistique de test** et de la **forme de la fonction de test**.
- 3 Détermination précise des **constantes** intervenant dans la fonction de test de sorte que le niveau du test soit α .
- 4 **Conclusion** au vu de l'observation.

- H_0 et H_1 ne jouent pas des rôles symétriques.
- En pratique le seul risque contrôlé est le risque de première espèce (fixé à α), H_0 est ainsi l'hypothèse à privilégier, il faut en tenir compte dans le choix des hypothèses.

Exemple

- 1 Mise en circulation d'un nouveau médicament :

$$H_0 : p_N = p_A \quad \text{contre} \quad H_1 : p_N > p_A.$$

- 2 Procès d'assise $\Rightarrow H_0$: "innocent" contre H_1 : "coupable".

- H_0 et H_1 ne jouent pas des rôles symétriques.
- En pratique le seul risque contrôlé est le risque de première espèce (fixé à α), H_0 est ainsi l'hypothèse à privilégier, il faut en tenir compte dans le choix des hypothèses.

Exemple

- 1 Mise en circulation d'un nouveau médicament :

$$H_0 : p_N = p_A \quad \text{contre} \quad H_1 : p_N > p_A.$$

- 2 Procès d'assise $\Rightarrow H_0$: "innocent" contre H_1 : "coupable".

- H_0 et H_1 ne jouent pas des rôles symétriques.
- En pratique le seul risque contrôlé est le risque de première espèce (fixé à α), H_0 est ainsi l'hypothèse à privilégier, il faut en tenir compte dans le choix des hypothèses.

Exemple

- 1 Mise en circulation d'un nouveau médicament :

$$H_0 : p_N = p_A \quad \text{contre} \quad H_1 : p_N > p_A.$$

- 2 Procès d'assise $\Rightarrow H_0$: "innocent" contre H_1 : "coupable".

- H_0 et H_1 ne jouent pas des rôles symétriques.
- En pratique le seul risque contrôlé est le risque de première espèce (fixé à α), H_0 est ainsi l'hypothèse à privilégier, il faut en tenir compte dans le choix des hypothèses.

Exemple

- 1 Mise en circulation d'un nouveau médicament :

$$H_0 : p_N = p_A \quad \text{contre} \quad H_1 : p_N > p_A.$$

- 2 Procès d'assise $\Rightarrow H_0$: "innocent" contre H_1 : "coupable".

- H_0 et H_1 ne jouent pas des rôles symétriques.
- En pratique le seul risque contrôlé est le risque de première espèce (fixé à α), H_0 est ainsi l'hypothèse à privilégier, il faut en tenir compte dans le choix des hypothèses.

Exemple

- 1 Mise en circulation d'un nouveau médicament :



$$H_0 : p_N = p_A \quad \text{contre} \quad H_1 : p_N > p_A.$$

- 2 Procès d'assise $\Rightarrow H_0$: "innocent" contre H_1 : "coupable".

- H_0 doit être l'hypothèse à privilégier.
- Le choix de H_1 intervient dans le choix de la fonction de test (ou encore sur la forme de la zone de rejet du test)

$$H_0 : \mu = \mu_0 \text{ vs } H_1 : \mu \neq \mu_0$$

$$H_0 : \mu = \mu_0 \text{ vs } H_1 : \mu > \mu_0$$



$$\mathcal{R}_{H_0} = \{] - \infty, x_1 [\cup] x_2, \infty [\}$$

$$\mathcal{R}_{H_0} = \{] x, \infty [\}$$

Accepter-rejeter les hypothèses ?

- Sur l'exemple précédent, on voit que la décision est prise en étudiant la loi d'une **statistique de test sous H_0** .
- Pour décider, on regarde si la valeur observée t_{obs} de la statistique de test T tombe dans une zone "raisonnable" sous l'hypothèse nulle H_0 .

Conclusion

- Si $t_{obs} \in \mathcal{A}_{H_0}$, on dit qu'on accepte l'hypothèse H_0 au niveau α .
- Si $t_{obs} \in \mathcal{R}_{H_0}$, on dit qu'on rejette l'hypothèse H_0 au profit de H_1 au niveau α .

Accepter-rejeter les hypothèses ?

- Sur l'exemple précédent, on voit que la décision est prise en étudiant la loi d'une **statistique de test sous H_0** .
- Pour décider, on regarde si la valeur observée t_{obs} de la statistique de test T tombe dans une zone "raisonnable" sous l'hypothèse nulle H_0 .

Conclusion

- Si $t_{obs} \in \mathcal{A}_{H_0}$, on dit qu'on accepte l'hypothèse H_0 au niveau α .
- Si $t_{obs} \in \mathcal{R}_{H_0}$, on dit qu'on rejette l'hypothèse H_0 au profit de H_1 au niveau α .

Accepter-rejeter les hypothèses ?

- Sur l'exemple précédent, on voit que la décision est prise en étudiant la loi d'une **statistique de test sous H_0** .
- Pour décider, on regarde si la valeur observée t_{obs} de la statistique de test T tombe dans une zone "raisonnable" sous l'hypothèse nulle H_0 .

Conclusion

- Si $t_{obs} \in \mathcal{A}_{H_0}$, on dit qu'on accepte l'hypothèse H_0 au niveau α .
- Si $t_{obs} \in \mathcal{R}_{H_0}$, on dit qu'on rejette l'hypothèse H_0 au profit de H_1 au niveau α .

1 Introduction

2 Tests paramétriques

- Vocabulaire
- Le principe de Neyman-Pearson
- **Puissance de test - Test UPP**
- Exemples
- Comparaison de deux échantillons gaussiens
- Cas non gaussien

3 Une introduction aux tests non paramétriques

- Le test du χ^2 d'adéquation
- Le test du χ^2 d'indépendance

- On appelle **puissance d'un test** la probabilité de rejeter H_0 alors qu'elle est effectivement fautive, c'est-à-dire

$$\eta : \Theta_1 \rightarrow [0, 1]$$

$$\theta_1 \mapsto \mathbf{P}_{\theta_1}(\mathcal{R}_{H_0}) = 1 - \beta(\theta_1).$$

- Soit φ_1 et φ_2 deux tests de niveau α . φ_1 est dit **uniformément plus puissant (UPP)** que φ_2 si

$$\forall \theta_1 \in \Theta_1 \quad \eta_{\varphi_1}(\theta_1) \geq \eta_{\varphi_2}(\theta_1).$$

- Un test φ est dit **UPP** parmi les tests de niveau α si il est de niveau α et si il est UPP que tout test de niveau α .

- On appelle **puissance d'un test** la probabilité de rejeter H_0 alors qu'elle est effectivement fautive, c'est-à-dire

$$\eta : \Theta_1 \rightarrow [0, 1]$$
$$\theta_1 \mapsto \mathbf{P}_{\theta_1}(\mathcal{R}_{H_0}) = 1 - \beta(\theta_1).$$

- Soit φ_1 et φ_2 deux tests de niveau α . φ_1 est dit **uniformément plus puissant (UPP)** que φ_2 si

$$\forall \theta_1 \in \Theta_1 \quad \eta_{\varphi_1}(\theta_1) \geq \eta_{\varphi_2}(\theta_1).$$

- Un test φ est dit **UPP** parmi les tests de niveau α si il est de niveau α et si il est UPP que tout test de niveau α .

- On appelle **puissance d'un test** la probabilité de rejeter H_0 alors qu'elle est effectivement fautive, c'est-à-dire

$$\eta : \Theta_1 \rightarrow [0, 1]$$
$$\theta_1 \mapsto \mathbf{P}_{\theta_1}(\mathcal{R}_{H_0}) = 1 - \beta(\theta_1).$$

- Soit φ_1 et φ_2 deux tests de niveau α . φ_1 est dit **uniformément plus puissant (UPP)** que φ_2 si


$$\forall \theta_1 \in \Theta_1 \quad \eta_{\varphi_1}(\theta_1) \geq \eta_{\varphi_2}(\theta_1).$$

- Un test φ est dit **UPP** parmi les tests de niveau α si il est de niveau α et si il est UPP que tout test de niveau α .

Un test φ de niveau α est dit **sans biais** si pour tout $\theta_1 \in \Theta_1$ on a $\eta_\varphi(\theta_1) \geq \alpha$.

Exemple

- $X \sim \mathcal{N}(\mu, 1)$, $H_0 : \mu = 3$,
 $H_1 : \mu > 3$, $\alpha = 0.05$.
- $\mathcal{R}_{H_0} = \{x : x > q_{0.95,3,1}\}$.
- $\eta(\mu) = 1 - F_{\mu,1}(q_{0.95,3,1})$
pour $\mu > 3$.




Le test est sans biais.

Un test φ de niveau α est dit **sans biais** si pour tout $\theta_1 \in \Theta_1$ on a $\eta_\varphi(\theta_1) \geq \alpha$.

Exemple

- $X \sim \mathcal{N}(\mu, 1)$, $H_0 : \mu = 3$,
 $H_1 : \mu > 3$, $\alpha = 0.05$.
- $\mathcal{R}_{H_0} = \{x : x > q_{0.95,3,1}\}$.
- $\eta(\mu) = 1 - F_{\mu,1}(q_{0.95,3,1})$
pour $\mu > 3$.



Le test est sans biais.

1 Introduction

2 Tests paramétriques

- Vocabulaire
- Le principe de Neyman-Pearson
- Puissance de test - Test UPP
- **Exemples**
- Comparaison de deux échantillons gaussiens
- Cas non gaussien

3 Une introduction aux tests non paramétriques

- Le test du χ^2 d'adéquation
- Le test du χ^2 d'indépendance

Test sur la moyenne d'une loi gaussienne

- X_1, \dots, X_n i.i.d. de loi $\mathcal{N}(\mu, 1)$ avec $n = 10$. On souhaite tester $H_0 : \mu = 3$ contre $H_1 : \mu \neq 3$ au niveau $\alpha = 5\%$.
- Statistique de test :

$$T = \sqrt{n}(\bar{X}_n - \mu) \sim \mathcal{N}(0, 1).$$

- Sous H_0 :

$$T = \sqrt{n}(\bar{X}_n - 3) \sim \mathcal{N}(0, 1).$$

- On déduit

$$\mathcal{R}_{H_0} =] - \infty, q_{0.025}[\cup] q_{0.975}, +\infty[=] - \infty, -1.96[\cup] 1.96, +\infty[.$$

- On rejette H_0 au niveau 5% si $T_{obs} \in \mathcal{R}_{H_0}$.

Test sur la moyenne d'une loi gaussienne

- X_1, \dots, X_n i.i.d. de loi $\mathcal{N}(\mu, 1)$ avec $n = 10$. On souhaite tester $H_0 : \mu = 3$ contre $H_1 : \mu \neq 3$ au niveau $\alpha = 5\%$.
- Statistique de test :

$$T = \sqrt{n}(\bar{X}_n - \mu) \sim \mathcal{N}(0, 1).$$

- Sous H_0 :

$$T = \sqrt{n}(\bar{X}_n - 3) \sim \mathcal{N}(0, 1).$$

- On déduit

$$\mathcal{R}_{H_0} =] - \infty, q_{0.025}[\cup] q_{0.975}, +\infty[=] - \infty, -1.96[\cup] 1.96, +\infty[.$$

- On rejette H_0 au niveau 5% si $T_{obs} \in \mathcal{R}_{H_0}$.

Test sur la moyenne d'une loi gaussienne

- X_1, \dots, X_n i.i.d. de loi $\mathcal{N}(\mu, 1)$ avec $n = 10$. On souhaite tester $H_0 : \mu = 3$ contre $H_1 : \mu \neq 3$ au niveau $\alpha = 5\%$.
- Statistique de test :

$$T = \sqrt{n}(\bar{X}_n - \mu) \sim \mathcal{N}(0, 1).$$

- Sous H_0 :

$$T = \sqrt{n}(\bar{X}_n - 3) \sim \mathcal{N}(0, 1).$$

- On déduit

$$\mathcal{R}_{H_0} =] - \infty, q_{0.025}[\cup] q_{0.975}, +\infty[=] - \infty, -1.96[\cup] 1.96, +\infty[.$$

- On rejette H_0 au niveau 5% si $T_{obs} \in \mathcal{R}_{H_0}$.

Test sur la moyenne d'une loi gaussienne

- X_1, \dots, X_n i.i.d. de loi $\mathcal{N}(\mu, 1)$ avec $n = 10$. On souhaite tester $H_0 : \mu = 3$ contre $H_1 : \mu \neq 3$ au niveau $\alpha = 5\%$.
- Statistique de test :

$$T = \sqrt{n}(\bar{X}_n - \mu) \sim \mathcal{N}(0, 1).$$

- Sous H_0 :

$$T = \sqrt{n}(\bar{X}_n - 3) \sim \mathcal{N}(0, 1).$$

- On déduit

$$\mathcal{R}_{H_0} =] - \infty, q_{0.025}[\cup] q_{0.975}, +\infty[=] - \infty, -1.96[\cup] 1.96, +\infty[.$$

- On rejette H_0 au niveau 5% si $T_{obs} \in \mathcal{R}_{H_0}$.

- X_1, \dots, X_n i.i.d de loi $\mathcal{N}(\mu, \sigma^2)$ avec σ^2 connu.

H_0	H_1	Stat de test	\mathcal{R}_{H_0}	Propriétés
$\mu = \mu_0$	$\mu > \mu_0$	$\sqrt{n} \frac{\bar{X}_n - \mu_0}{\sigma}$	$\{x : x > q_{1-\alpha}\}$	UPP
$\mu = \mu_0$	$\mu \neq \mu_0$	$\sqrt{n} \frac{\bar{X}_n - \mu_0}{\sigma}$	$\{x : x < q_{\alpha/2} \text{ ou } x > q_{1-\alpha/2}\}$	UPPSB

- X_1, \dots, X_n i.i.d de loi $\mathcal{N}(\mu, \sigma^2)$ avec σ^2 inconnu.

H_0	H_1	Stat de test	\mathcal{R}_{H_0}	Propriétés
$\mu = \mu_0$	$\mu > \mu_0$	$\sqrt{n} \frac{\bar{X}_n - \mu_0}{S_n}$	$\{x : x > t_{1-\alpha}\}$	UPP
$\mu = \mu_0$	$\mu \neq \mu_0$	$\sqrt{n} \frac{\bar{X}_n - \mu_0}{S_n}$	$\{x : x < t_{\alpha/2} \text{ ou } x > t_{1-\alpha/2}\}$	UPPSB

- X_1, \dots, X_n i.i.d de loi $\mathcal{N}(\mu, \sigma^2)$ avec σ^2 connu.

H_0	H_1	Stat de test	\mathcal{R}_{H_0}	Propriétés
$\mu = \mu_0$	$\mu > \mu_0$	$\sqrt{n} \frac{\bar{X}_n - \mu_0}{\sigma}$	$\{x : x > q_{1-\alpha}\}$	UPP
$\mu = \mu_0$	$\mu \neq \mu_0$	$\sqrt{n} \frac{\bar{X}_n - \mu_0}{\sigma}$	$\{x : x < q_{\alpha/2} \text{ ou } x > q_{1-\alpha/2}\}$	UPPSB

- X_1, \dots, X_n i.i.d de loi $\mathcal{N}(\mu, \sigma^2)$ avec σ^2 inconnu.

H_0	H_1	Stat de test	\mathcal{R}_{H_0}	Propriétés
$\mu = \mu_0$	$\mu > \mu_0$	$\sqrt{n} \frac{\bar{X}_n - \mu_0}{S_n}$	$\{x : x > t_{1-\alpha}\}$	UPP
$\mu = \mu_0$	$\mu \neq \mu_0$	$\sqrt{n} \frac{\bar{X}_n - \mu_0}{S_n}$	$\{x : x < t_{\alpha/2} \text{ ou } x > t_{1-\alpha/2}\}$	UPPSB

Tests sur une variance - échantillons gaussiens

- X_1, \dots, X_n i.i.d de loi $\mathcal{N}(\mu, \sigma^2)$ avec μ connu.

H_0	H_1	Stat de test	\mathcal{R}_{H_0}	Propriétés
$\sigma^2 = \sigma_0^2$	$\sigma^2 > \sigma_0^2$	$\sum_{i=1}^n \frac{(X_i - \mu)^2}{\sigma_0^2}$	$\{x : x > \chi_{1-\alpha}^2(n)\}$	"UPP"
$\sigma^2 = \sigma_0^2$	$\sigma^2 \neq \sigma_0^2$	$\sum_{i=1}^n \frac{(X_i - \mu)^2}{\sigma_0^2}$	$\{x : x < \chi_{\alpha/2}^2(n) \text{ ou } x > \chi_{1-\alpha/2}^2(n)\}$	"UPPSB"

- X_1, \dots, X_n i.i.d de loi $\mathcal{N}(\mu, \sigma^2)$ avec μ inconnu.

H_0	H_1	Stat de test	\mathcal{R}_{H_0}	Propriétés
$\sigma^2 = \sigma_0^2$	$\sigma^2 > \sigma_0^2$	$\sum_{i=1}^n \frac{(X_i - \bar{X})^2}{\sigma_0^2}$	$\{x : x > \chi_{1-\alpha}^2(n-1)\}$	"UPP"
$\sigma^2 = \sigma_0^2$	$\sigma^2 \neq \sigma_0^2$	$\sum_{i=1}^n \frac{(X_i - \bar{X})^2}{\sigma_0^2}$	$\{x : x < \chi_{\alpha/2}^2(n-1) \text{ ou } x > \chi_{1-\alpha/2}^2(n-1)\}$	"UPPSB"

Tests sur une variance - échantillons gaussiens

- X_1, \dots, X_n i.i.d de loi $\mathcal{N}(\mu, \sigma^2)$ avec μ connu.

H_0	H_1	Stat de test	\mathcal{R}_{H_0}	Propriétés
$\sigma^2 = \sigma_0^2$	$\sigma^2 > \sigma_0^2$	$\sum_{i=1}^n \frac{(X_i - \mu)^2}{\sigma_0^2}$	$\{x : x > \chi_{1-\alpha}^2(n)\}$	"UPP"
$\sigma^2 = \sigma_0^2$	$\sigma^2 \neq \sigma_0^2$	$\sum_{i=1}^n \frac{(X_i - \mu)^2}{\sigma_0^2}$	$\{x : x < \chi_{\alpha/2}^2(n) \text{ ou } x > \chi_{1-\alpha/2}^2(n)\}$	"UPPSB"

- X_1, \dots, X_n i.i.d de loi $\mathcal{N}(\mu, \sigma^2)$ avec μ inconnu.

H_0	H_1	Stat de test	\mathcal{R}_{H_0}	Propriétés
$\sigma^2 = \sigma_0^2$	$\sigma^2 > \sigma_0^2$	$\sum_{i=1}^n \frac{(X_i - \bar{X})^2}{\sigma_0^2}$	$\{x : x > \chi_{1-\alpha}^2(n-1)\}$	"UPP"
$\sigma^2 = \sigma_0^2$	$\sigma^2 \neq \sigma_0^2$	$\sum_{i=1}^n \frac{(X_i - \bar{X})^2}{\sigma_0^2}$	$\{x : x < \chi_{\alpha/2}^2(n-1) \text{ ou } x > \chi_{1-\alpha/2}^2(n-1)\}$	"UPPSB"

1 Introduction

2 Tests paramétriques

- Vocabulaire
- Le principe de Neyman-Pearson
- Puissance de test - Test UPP
- Exemples
- **Comparaison de deux échantillons gaussiens**
- Cas non gaussien

3 Une introduction aux tests non paramétriques

- Le test du χ^2 d'adéquation
- Le test du χ^2 d'indépendance

- On dispose de $n_1 = 13$ observations du poids de poulpes femelles et $n_2 = 15$ observations du poids de poulpes males.
- On souhaite vérifier si le sexe a une influence sur le poids.

Modélisation

- X_i v.a. correspondant au poids du $i^{\text{ème}}$ poulpe femelle, $X_i \sim \mathcal{N}(\mu_1, \sigma_1^2)$.
- Y_i v.a. correspondant au poids du $i^{\text{ème}}$ poulpe male, $Y_i \sim \mathcal{N}(\mu_2, \sigma_2^2)$.
- On souhaite tester les hypothèses $H_0 : \mu_1 = \mu_2$ contre $H_1 : \mu_1 \neq \mu_2$.

- On dispose de $n_1 = 13$ observations du poids de poulpes femelles et $n_2 = 15$ observations du poids de poulpes males.
- On souhaite vérifier si le sexe a une influence sur le poids.

Modélisation

- X_i v.a. correspondant au poids du $i^{\text{ème}}$ poulpe femelle, $X_i \sim \mathcal{N}(\mu_1, \sigma_1^2)$.
- Y_i v.a. correspondant au poids du $i^{\text{ème}}$ poulpe male, $Y_i \sim \mathcal{N}(\mu_2, \sigma_2^2)$.
- On souhaite tester les hypothèses $H_0 : \mu_1 = \mu_2$ contre $H_1 : \mu_1 \neq \mu_2$.

- On dispose de $n_1 = 13$ observations du poids de poulpes femelles et $n_2 = 15$ observations du poids de poulpes males.
- On souhaite vérifier si le sexe a une influence sur le poids.

Modélisation

- X_i v.a. correspondant au poids du $i^{\text{ème}}$ poulpe femelle, $X_i \sim \mathcal{N}(\mu_1, \sigma_1^2)$.
- Y_i v.a. correspondant au poids du $i^{\text{ème}}$ poulpe male, $Y_i \sim \mathcal{N}(\mu_2, \sigma_2^2)$.
- On souhaite tester les hypothèses $H_0 : \mu_1 = \mu_2$ contre $H_1 : \mu_1 \neq \mu_2$.

	σ_i connus		σ_i inconnus	
	$\sigma_1 = \sigma_2$	$\sigma_1 \neq \sigma_2$	$\sigma_1 = \sigma_2$	$\sigma_1 \neq \sigma_2$
Stat de test	$\frac{\bar{X} - \bar{Y}}{\sigma \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$	$\frac{\bar{X} - \bar{Y}}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$	$\frac{\bar{X} - \bar{Y}}{S \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$	$\frac{\bar{X} - \bar{Y}}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}}$
Lois sous H_0	$\mathcal{N}(0, 1)$	$\mathcal{N}(0, 1)$	$\mathcal{T}(n_1 + n_2 - 2)$	$\approx \mathcal{N}(0, 1)$

Test de comparaison de variances

- $H_0 : \sigma_1 = \sigma_2$ contre $H_1 : \sigma_1 \neq \sigma_2$. On note
 - $\widehat{\sigma}_1^2 = \frac{1}{n_1} \sum_{i=1}^{n_1} (X_i - \mu_1)^2$ et $\widehat{\sigma}_2^2 = \frac{1}{n_2} \sum_{i=1}^{n_2} (Y_i - \mu_2)^2$
 - $S_1^2 = \frac{1}{n_1 - 1} \sum_{i=1}^{n_1} (X_i - \bar{X})^2$ et $S_2^2 = \frac{1}{n_2} \sum_{i=1}^{n_2} (Y_i - \bar{Y})^2$

μ_1 et μ_2 connus

Sous H_0 la statistique $\frac{\widehat{\sigma}_1^2}{\widehat{\sigma}_2^2}$ suit une loi de Fisher $\mathcal{F}(n_1, n_2)$.

μ_1 et μ_2 inconnus

Sous H_0 la statistique $\frac{S_1^2}{S_2^2}$ suit une loi de Fisher $\mathcal{F}(n_1 - 1, n_2 - 1)$.

Test de comparaison de variances

- $H_0 : \sigma_1 = \sigma_2$ contre $H_1 : \sigma_1 \neq \sigma_2$. On note
 - $\widehat{\sigma}_1^2 = \frac{1}{n_1} \sum_{i=1}^{n_1} (X_i - \mu_1)^2$ et $\widehat{\sigma}_2^2 = \frac{1}{n_2} \sum_{i=1}^{n_2} (Y_i - \mu_2)^2$
 - $S_1^2 = \frac{1}{n_1 - 1} \sum_{i=1}^{n_1} (X_i - \bar{X})^2$ et $S_2^2 = \frac{1}{n_2} \sum_{i=1}^{n_2} (Y_i - \bar{Y})^2$

μ_1 et μ_2 connus

Sous H_0 la statistique $\frac{\widehat{\sigma}_1^2}{\widehat{\sigma}_2^2}$ suit une loi de Fisher $\mathcal{F}(n_1, n_2)$.

μ_1 et μ_2 inconnus

Sous H_0 la statistique $\frac{S_1^2}{S_2^2}$ suit une loi de Fisher $\mathcal{F}(n_1 - 1, n_2 - 1)$.

Test de comparaison de variances

- $H_0 : \sigma_1 = \sigma_2$ contre $H_1 : \sigma_1 \neq \sigma_2$. On note
 - $\widehat{\sigma}_1^2 = \frac{1}{n_1} \sum_{i=1}^{n_1} (X_i - \mu_1)^2$ et $\widehat{\sigma}_2^2 = \frac{1}{n_2} \sum_{i=1}^{n_2} (Y_i - \mu_2)^2$
 - $S_1^2 = \frac{1}{n_1 - 1} \sum_{i=1}^{n_1} (X_i - \bar{X})^2$ et $S_2^2 = \frac{1}{n_2} \sum_{i=1}^{n_2} (Y_i - \bar{Y})^2$

μ_1 et μ_2 connus

Sous H_0 la statistique $\frac{\widehat{\sigma}_1^2}{\widehat{\sigma}_2^2}$ suit une loi de Fisher $\mathcal{F}(n_1, n_2)$.

μ_1 et μ_2 inconnus

Sous H_0 la statistique $\frac{S_1^2}{S_2^2}$ suit une loi de Fisher $\mathcal{F}(n_1 - 1, n_2 - 1)$.

Exemple des poulpes avec R

- Test d'égalité des variances.

```
> var.test(Poids~Sexe, conf.level=0.95, data=poulpes)
```

F test to compare two variances

data: Poids by Sexe

F = 0.2883, num df = 12, denom df = 14, **p-value = 0.03713**

alternative hypothesis: true ratio of variances is not equal to 1

95 percent confidence interval:

0.0945296 0.9244467

sample estimates:

ratio of variances

0.2883299

La fonction ne renvoie pas la décision mais une **p-value** (valeur-p en français) également appelée **probabilité critique**.

Exemple des poulpes avec R

- Test d'égalité des variances.

```
> var.test(Poids~Sexe, conf.level=0.95, data=poulpes)
```

F test to compare two variances

data: Poids by Sexe

F = 0.2883, num df = 12, denom df = 14, **p-value = 0.03713**

alternative hypothesis: true ratio of variances is not equal to 1

95 percent confidence interval:

0.0945296 0.9244467

sample estimates:

ratio of variances

0.2883299

La fonction ne renvoie pas la décision mais une **p-value** (valeur-p en français) également appelée **probabilité critique**.

Définition

La **probabilité critique** est la probabilité que sous H_0 la statistique de test prenne une valeur au moins aussi extrême que celle observée.

Calcul de la p_c

On note T la statistique de test et t_{obs} la valeur observée.

- Si la région de rejet est unilatérale, par exemple $\{x : x > c\}$ alors $p_c = \mathbf{P}_{H_0}(T > t_{obs})$.
- Si la région de rejet est bilatérale, par exemple $\{x : x > c_1 \text{ ou } x < c_2\}$ alors

$$p_c = \begin{cases} 2\mathbf{P}_{H_0}(T > t_{obs}) & \text{si } t_{obs} > M \\ 2\mathbf{P}_{H_0}(T < t_{obs}) & \text{si } t_{obs} < M \end{cases}$$

Définition

La **probabilité critique** est la probabilité que sous H_0 la statistique de test prenne une valeur au moins aussi extrême que celle observée.

Calcul de la p_c

On note T la statistique de test et t_{obs} la valeur observée.

- Si la région de rejet est unilatérale, par exemple $\{x : x > c\}$ alors $p_c = \mathbf{P}_{H_0}(T > t_{obs})$.
- Si la région de rejet est bilatérale, par exemple $\{x : x > c_1 \text{ ou } x < c_2\}$ alors

$$p_c = \begin{cases} 2\mathbf{P}_{H_0}(T > t_{obs}) & \text{si } t_{obs} > M \\ 2\mathbf{P}_{H_0}(T < t_{obs}) & \text{si } t_{obs} < M \end{cases}$$

Définition

La **probabilité critique** est la probabilité que sous H_0 la statistique de test prenne une valeur au moins aussi extrême que celle observée.

Calcul de la p_c

On note T la statistique de test et t_{obs} la valeur observée.

- Si la région de rejet est unilatérale, par exemple $\{x : x > c\}$ alors $p_c = \mathbf{P}_{H_0}(T > t_{obs})$.
- Si la région de rejet est bilatérale, par exemple $\{x : x > c_1 \text{ ou } x < c_2\}$ alors

$$p_c = \begin{cases} 2\mathbf{P}_{H_0}(T > t_{obs}) & \text{si } t_{obs} > M \\ 2\mathbf{P}_{H_0}(T < t_{obs}) & \text{si } t_{obs} < M \end{cases}$$

- La probabilité critique correspond au niveau de test minimum pour lequel on rejette H_0 . Ainsi,
 - si $pc \geq \alpha$ l'hypothèse nulle est acceptée au niveau α .
 - si $pc < \alpha$ l'hypothèse nulle est rejetée au niveau α .

En pratique...

- Les logiciels ne renvoient généralement pas la conclusion du test mais la valeur de la probabilité critique.
- La décision est prise en comparant cette valeur au niveau fixé par l'utilisateur.

- La probabilité critique correspond au niveau de test minimum pour lequel on rejette H_0 . Ainsi,
 - si $pc \geq \alpha$ l'hypothèse nulle est acceptée au niveau α .
 - si $pc < \alpha$ l'hypothèse nulle est rejetée au niveau α .

En pratique...

- Les logiciels ne renvoient généralement pas la conclusion du test mais la valeur de la probabilité critique.
- La décision est prise en comparant cette valeur au niveau fixé par l'utilisateur.



- La probabilité critique correspond au niveau de test minimum pour lequel on rejette H_0 . Ainsi,
 - si $pc \geq \alpha$ l'hypothèse nulle est acceptée au niveau α .
 - si $pc < \alpha$ l'hypothèse nulle est rejetée au niveau α .

En pratique...

- Les logiciels ne renvoient généralement pas la conclusion du test mais la valeur de la probabilité critique.
- La décision est prise en comparant cette valeur au niveau fixé par l'utilisateur.

Exemple pour un test unilatéral



- $H_0 : \mu = \mu_0$ vs $H_1 : \mu > \mu_0$.
- $\alpha = 0.05$.
- $T \sim \mathcal{N}(0, 1)$ sous H_0 .



Conclusion : $pc > \alpha$ donc H_0 est acceptée au niveau 5%.

Exemple pour un test unilatéral

- $H_0 : \mu = \mu_0$ vs $H_1 : \mu > \mu_0$.
- $\alpha = 0.05$.
- $T \sim \mathcal{N}(0, 1)$ sous H_0 .




Conclusion : $pc > \alpha$ donc H_0 est acceptée au niveau 5%.


Exemple pour un test bilatéral

- Test d'égalité des variances pour les poulpes.
- $H_0 : \sigma_1 = \sigma_2$ vs $H_1 : \sigma_1 \neq \sigma_2$.
- $\alpha = 0.05$.
- $T \sim \mathcal{F}(12, 14)$ sous H_0 .

Zone de rejet



Probabilité critique




$pc \leq \alpha$ donc H_0 est rejetée au profit de H_1 . On conclut que la variance de la variable poids diffère selon le sexe.


Exemple pour un test bilatéral

- Test d'égalité des variances pour les poulpes.
- $H_0 : \sigma_1 = \sigma_2$ vs $H_1 : \sigma_1 \neq \sigma_2$.
- $\alpha = 0.05$.
- $T \sim \mathcal{F}(12, 14)$ sous H_0 .

Zone de rejet



Probabilité critique



$pc \leq \alpha$ donc H_0 est rejetée au profit de H_1 . On conclut que la variance de la variable poids diffère selon le sexe.

Comparaison du poids moyen des poulpes

- Pour comparer la poids moyen des poulpes, on fait ainsi un test d'égalité de moyenne avec variances inégales.
- Sur R, on obtient

```
> t.test(Poids~Sexe,alternative="two.sided",conf.level=0.95,  
         var.equal=FALSE,data=poulpes)
```

Welch Two Sample t-test

```
data: Poids by Sexe  
t = -3.7496, df = 22.021, p-value = 0.001107  
alternative hypothesis: true difference in means is not equal to 0  
95 percent confidence interval:  
 -2010.624 -578.607  
sample estimates:  
mean in group Femelle      mean in group Male  
      1405.385              2700.000
```

Au seuil $\alpha = 5\%$, on conclut que le poids des poulpes est différent selon le sexe.

1 Introduction

2 Tests paramétriques

- Vocabulaire
- Le principe de Neyman-Pearson
- Puissance de test - Test UPP
- Exemples
- Comparaison de deux échantillons gaussiens
- **Cas non gaussien**

3 Une introduction aux tests non paramétriques

- Le test du χ^2 d'adéquation
- Le test du χ^2 d'indépendance

Question

Que se passe-t-il si les paramètres que l'on souhaite tester ne sont pas gaussiens ?

Une réponse

Dans le cas où la paramètre à tester correspond à l'espérance d'une variable aléatoire, on utilise souvent l'approximation gaussienne via le TCL.

Nous illustrons cette approche à travers des exemples de tests de proportions.

Question

Que se passe-t-il si les paramètres que l'on souhaite tester ne sont pas gaussiens ?

Une réponse

Dans le cas où la paramètre à tester correspond à l'espérance d'une variable aléatoire, on utilise souvent l'approximation gaussienne via le TCL.

Nous illustrons cette approche à travers des exemples de tests de proportions.

Test sur le paramètre d'une loi de Bernoulli

- X_1, \dots, X_n i.i.d de loi de Bernoulli p_0 .
- $H_0 : p = p_0$ contre $H_1 : p \neq p_0$.
- TCL :

$$\sqrt{n} \frac{\hat{p} - p}{\sqrt{p(1-p)}} \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1).$$

- Sous H_0 , on fait l'approximation :

$$T_n = \sqrt{n} \frac{\hat{p} - p_0}{\sqrt{p_0(1-p_0)}} \sim \mathcal{N}(0, 1).$$

- On déduit $\mathcal{R}_{H_0} =] -\infty, -q_{1-\alpha/2}[\cup] q_{1-\alpha/2}, +\infty[.$

Test sur le paramètre d'une loi de Bernoulli

- X_1, \dots, X_n i.i.d de loi de Bernoulli p_0 .
- $H_0 : p = p_0$ contre $H_1 : p \neq p_0$.
- TCL :

$$\sqrt{n} \frac{\hat{p} - p}{\sqrt{p(1-p)}} \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1).$$

- Sous H_0 , on fait l'approximation :

$$T_n = \sqrt{n} \frac{\hat{p} - p_0}{\sqrt{p_0(1-p_0)}} \sim \mathcal{N}(0, 1).$$

- On déduit $\mathcal{R}_{H_0} =] -\infty, -q_{1-\alpha/2}[\cup] q_{1-\alpha/2}, +\infty[.$

- X_1, \dots, X_n i.i.d de loi de Bernoulli p_0 .
- $H_0 : p = p_0$ contre $H_1 : p \neq p_0$.
- TCL :

$$\sqrt{n} \frac{\hat{p} - p}{\sqrt{p(1-p)}} \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1).$$

- Sous H_0 , on fait l'approximation :

$$T_n = \sqrt{n} \frac{\hat{p} - p_0}{\sqrt{p_0(1-p_0)}} \sim \mathcal{N}(0, 1).$$

- On déduit $\mathcal{R}_{H_0} =] -\infty, -q_{1-\alpha/2}[\cup] q_{1-\alpha/2}, +\infty[.$

Exemple

- Une entreprise emploie 40 hommes et 60 femmes.

Peut-on affirmer que les recruteurs sont sexistes ?

- **Modélisation** : on note p la probabilité de recruter une femme et X_i la va qui prend pour valeur 1 si la $i^{\text{ème}}$ personne recrutée est une femme, 0 sinon.
- $H_0 : p = 0.5$ contre $H_1 : p \neq 0.5$ au niveau $\alpha = 0.05$.
- Sous H_0 , la statistique

$$T = \sqrt{100} \frac{\hat{p} - 0.5}{\sqrt{0.5(1 - 0.5)}}$$

suit (approximativement) une loi $\mathcal{N}(0, 1)$.

- $\mathcal{R}_{H_0} =] - \infty, -1.96[\cup] 1.96, +\infty[$.
- $T_{obs} = 2 \in \mathcal{R}_{H_0}$, on rejette H_0 au niveau 0.05 ($pc = 0.0455$).

Exemple

- Une entreprise emploie 40 hommes et 60 femmes.

Peut-on affirmer que les recruteurs sont sexistes ?

- **Modélisation** : on note p la probabilité de recruter une femme et X_i la va qui prend pour valeur 1 si la $i^{\text{ème}}$ personne recrutée est une femme, 0 sinon.
- $H_0 : p = 0.5$ contre $H_1 : p \neq 0.5$ au niveau $\alpha = 0.05$.
- Sous H_0 , la statistique

$$T = \sqrt{100} \frac{\hat{p} - 0.5}{\sqrt{0.5(1 - 0.5)}}$$

suit (approximativement) une loi $\mathcal{N}(0, 1)$.

- $\mathcal{R}_{H_0} =] - \infty, -1.96[\cup] 1.96, +\infty[$.
- $T_{obs} = 2 \in \mathcal{R}_{H_0}$, on rejette H_0 au niveau 0.05 ($pc = 0.0455$).

Exemple

- Une entreprise emploie 40 hommes et 60 femmes.

Peut-on affirmer que les recruteurs sont sexistes ?

- **Modélisation** : on note p la probabilité de recruter une femme et X_i la va qui prend pour valeur 1 si la $i^{\text{ème}}$ personne recrutée est une femme, 0 sinon.
- $H_0 : p = 0.5$ contre $H_1 : p \neq 0.5$ au niveau $\alpha = 0.05$.
- Sous H_0 , la statistique

$$T = \sqrt{100} \frac{\hat{p} - 0.5}{\sqrt{0.5(1 - 0.5)}}$$

suit (approximativement) une loi $\mathcal{N}(0, 1)$.

- $\mathcal{R}_{H_0} =] - \infty, -1.96[\cup] 1.96, +\infty[$.
- $T_{obs} = 2 \in \mathcal{R}_{H_0}$, on rejette H_0 au niveau 0.05 ($pc = 0.0455$).

Exemple

- Une entreprise emploie 40 hommes et 60 femmes.

Peut-on affirmer que les recruteurs sont sexistes ?

- **Modélisation** : on note p la probabilité de recruter une femme et X_i la va qui prend pour valeur 1 si la $i^{\text{ème}}$ personne recrutée est une femme, 0 sinon.
- $H_0 : p = 0.5$ contre $H_1 : p \neq 0.5$ au niveau $\alpha = 0.05$.
- Sous H_0 , la statistique

$$T = \sqrt{100} \frac{\hat{p} - 0.5}{\sqrt{0.5(1 - 0.5)}}$$

suit (approximativement) une loi $\mathcal{N}(0, 1)$.

- $\mathcal{R}_{H_0} =] - \infty, -1.96[\cup] 1.96, +\infty[$.
- $T_{obs} = 2 \in \mathcal{R}_{H_0}$, on rejette H_0 au niveau 0.05 ($pc = 0.0455$).

Test de comparaison de deux proportions

- X_1, \dots, X_{n_1} i.i.d de loi $B(p_1)$.
- Y_1, \dots, Y_{n_2} i.i.d de loi $B(p_2)$.
- $H_0 : p_1 = p_2$ contre $H_1 : p_1 \neq p_2$.
- On note $\hat{p} = \frac{n_1 \hat{p}_1 + n_2 \hat{p}_2}{n_1 + n_2}$ et sous H_0 on approche la loi de

$$T = \frac{\hat{p}_1 - \hat{p}_2}{\sqrt{\hat{p}(1 - \hat{p})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}}$$

par la loi $\mathcal{N}(0, 1)$.

- On rejettera donc H_0 si

$$t_{obs} \in \mathcal{R}_{H_0} =] - \infty, -q_{1-\alpha/2}[\cup] q_{1-\alpha/2}, +\infty[.$$

Test de comparaison de deux proportions

- X_1, \dots, X_{n_1} i.i.d de loi $B(p_1)$.
- Y_1, \dots, Y_{n_2} i.i.d de loi $B(p_2)$.
- $H_0 : p_1 = p_2$ contre $H_1 : p_1 \neq p_2$.
- On note $\hat{p} = \frac{n_1 \hat{p}_1 + n_2 \hat{p}_2}{n_1 + n_2}$ et sous H_0 on approche la loi de

$$T = \frac{\hat{p}_1 - \hat{p}_2}{\sqrt{\hat{p}(1 - \hat{p})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}}$$

par la loi $\mathcal{N}(0, 1)$.

- On rejettera donc H_0 si

$$t_{obs} \in \mathcal{R}_{H_0} =] - \infty, -q_{1-\alpha/2}[\cup] q_{1-\alpha/2}, +\infty[.$$

1 Introduction

2 Tests paramétriques

- Vocabulaire
- Le principe de Neyman-Pearson
- Puissance de test - Test UPP
- Exemples
- Comparaison de deux échantillons gaussiens
- Cas non gaussien

3 Une introduction aux tests non paramétriques

- Le test du χ^2 d'adéquation
- Le test du χ^2 d'indépendance

- A un âge donné, on a pu observer que parmi les bébés non prématurés : 50% marchent, 12% ont une ébauche de marche et 38% ne marchent pas.
- Pour le même âge, sur 80 prématurés, on a observé que 35 marchent, 4 ont une ébauche de marche et 41 ne marchent pas.

Les bébés prématurés développent-ils la marche de la même manière que les bébés non-prématurés ?

- Exemple du nombre de garçons qui suit une loi Binomiale ?
- Dépendance entre le fait d'avoir survécu et la classe d'appartenance pour les passagers du Titanic.

- A un âge donné, on a pu observer que parmi les bébés non prématurés : 50% marchent, 12% ont une ébauche de marche et 38% ne marchent pas.
- Pour le même âge, sur 80 prématurés, on a observé que 35 marchent, 4 ont une ébauche de marche et 41 ne marchent pas.

Les bébés prématurés développent-ils la marche de la même manière que les bébés non-prématurés ?

- Exemple du nombre de garçons qui suit une loi Binomiale ?
- Dépendance entre le fait d'avoir survécu et la classe d'appartenance pour les passagers du Titanic.

- On peut répondre à ces questions à l'aide de tests statistiques.
- Ici, le problème est de confronter la loi d'une variable à une autre loi, ou encore de tester l'indépendance entre deux variables.
- Les hypothèses ne vont plus porter sur les paramètres de lois de probabilités, c'est pourquoi on parle de **tests non paramétriques**.

- On peut répondre à ces questions à l'aide de tests statistiques.
- Ici, le problème est de confronter la loi d'une variable à une autre loi, ou encore de tester l'indépendance entre deux variables.
- Les hypothèses ne vont plus porter sur les paramètres de lois de probabilités, c'est pourquoi on parle de **tests non paramétriques**.

- On peut répondre à ces questions à l'aide de tests statistiques.
- Ici, le problème est de confronter la loi d'une variable à une autre loi, ou encore de tester l'indépendance entre deux variables.
- Les hypothèses ne vont plus porter sur les paramètres de lois de probabilités, c'est pourquoi on parle de **tests non paramétriques**.

La distance du χ^2

- Soit X_1, \dots, X_n n va réelles de loi P . On note $P_n = \frac{1}{n} \sum_{i=1}^n \delta_{X_i}$.
- Soit (O_1, \dots, O_m) une partition de \mathbb{R} , on note $p_k = \mathbf{P}(X_1 \in O_k)$.
- Soit $N_k = \sum_{i=1}^n \mathbf{1}_{X_i \in O_k}$.

Définition

La distance du χ^2 entre P et P_n est définie par

$$D(P_n, P) = \sum_{k=1}^m \frac{(N_k - np_k)^2}{np_k}.$$

Théorème

Lorsque $n \rightarrow \infty$, on a

$$D(P_n, P) \xrightarrow{\mathcal{L}} \chi^2(m-1).$$

La distance du χ^2

- Soit X_1, \dots, X_n n va réelles de loi P . On note $P_n = \frac{1}{n} \sum_{i=1}^n \delta_{X_i}$.
- Soit (O_1, \dots, O_m) une partition de \mathbb{R} , on note $p_k = \mathbf{P}(X_1 \in O_k)$.
- Soit $N_k = \sum_{i=1}^n \mathbf{1}_{X_i \in O_k}$.

Définition

La distance du χ^2 entre P et P_n est définie par

$$D(P_n, P) = \sum_{k=1}^m \frac{(N_k - np_k)^2}{np_k}.$$

Théorème

Lorsque $n \rightarrow \infty$, on a

$$D(P_n, P) \xrightarrow{\mathcal{L}} \chi^2(m-1).$$

La distance du χ^2

- Soit X_1, \dots, X_n n va réelles de loi P . On note $P_n = \frac{1}{n} \sum_{i=1}^n \delta_{X_i}$.
- Soit (O_1, \dots, O_m) une partition de \mathbb{R} , on note $p_k = \mathbf{P}(X_1 \in O_k)$.
- Soit $N_k = \sum_{i=1}^n \mathbf{1}_{X_i \in O_k}$.

Définition

La distance du χ^2 entre P et P_n est définie par

$$D(P_n, P) = \sum_{k=1}^m \frac{(N_k - np_k)^2}{np_k}.$$

Théorème

Lorsque $n \rightarrow \infty$, on a

$$D(P_n, P) \xrightarrow{\mathcal{L}} \chi^2(m-1).$$

- $D(P_n, P)$ est une sorte de distance entre la loi empirique P_n et la loi théorique P .
- Elle est construite en comparant les effectifs observés N_k aux effectifs théoriques np_k .

Utile pour tester des hypothèses du genre $H_0 : P = P_0$ contre $H_1 : P \neq P_0$.
En effet,

- Sous H_0 , D_n aura tendance à ne pas prendre de trop grande valeurs puisque $N_k/n \xrightarrow{p.s.} p_k$ (LFGN).
- Sous H_1 , D_n prendra de fortes valeurs puisque $D_n \xrightarrow{p.s.} \infty$.

- $D(P_n, P)$ est une sorte de distance entre la loi empirique P_n et la loi théorique P .
- Elle est construite en comparant les effectifs observés N_k aux effectifs théoriques np_k .

Utile pour tester des hypothèses du genre $H_0 : P = P_0$ contre $H_1 : P \neq P_0$.
En effet,

- Sous H_0 , D_n aura tendance à ne pas prendre de trop grande valeurs puisque $N_k/n \xrightarrow{p.s.} p_k$ (LFGN).
- Sous H_1 , D_n prendra de fortes valeurs puisque $D_n \xrightarrow{p.s.} \infty$.

- $D(P_n, P)$ est une sorte de distance entre la loi empirique P_n et la loi théorique P .
- Elle est construite en comparant les effectifs observés N_k aux effectifs théoriques np_k .

Utile pour tester des hypothèses du genre $H_0 : P = P_0$ contre $H_1 : P \neq P_0$.
En effet,

- Sous H_0 , D_n aura tendance à ne pas prendre de trop grande valeurs puisque $N_k/n \xrightarrow{p.s.} p_k$ (LFGN).
- Sous H_1 , D_n prendra de fortes valeurs puisque $D_n \xrightarrow{p.s.} \infty$.

1 Introduction

2 Tests paramétriques


- Vocabulaire
- Le principe de Neyman-Pearson
- Puissance de test - Test UPP
- Exemples
- Comparaison de deux échantillons gaussiens
- Cas non gaussien

3 Une introduction aux tests non paramétriques

- Le test du χ^2 d'adéquation
- Le test du χ^2 d'indépendance

Le test d'adéquation du χ^2

- $H_0 : P = P_0$ contre $H_1 : P \neq P_0$.
- Sous H_0 la statistique $D(P_n, P_0) \stackrel{\text{approx}}{\sim} \chi^2(m-1)$.
- $\mathcal{R}_{H_0} =]\chi_{1-\alpha}^2(m-1), +\infty[$.




Remarque

Le test étant asymptotique, il est recommandé de l'appliquer pour $n > 30$ et $np_k^0 > 5$.

Le test d'adéquation du χ^2

- $H_0 : P = P_0$ contre $H_1 : P \neq P_0$.
- Sous H_0 la statistique $D(P_n, P_0) \stackrel{\text{approx}}{\sim} \chi^2(m-1)$.
- $\mathcal{R}_{H_0} =]\chi_{1-\alpha}^2(m-1), +\infty[$.



Remarque

Le test étant asymptotique, il est recommandé de l'appliquer pour $n > 30$ et $np_k^0 > 5$.

Exemple

- X : "Marche à l'âge donné" pour les prématurés. 3 modalités (oui, ébauche, non).
- $H_0 : X \sim P_0$ contre $H_1 : X \not\sim P_0$ avec $P_0(\text{oui}) = 0.5$, $P_0(\text{ébauche}) = 0.12$, $P_0(\text{non}) = 0.38$. Risque $\alpha = 0.05$.
- Sous H_0 la statistique

$$D_n = \sum_{k=1}^3 \frac{(N_k - np_k)^2}{np_k} \underset{\text{approx}}{\sim} \chi^2(2).$$

- $\mathcal{R}_{H_0} =]5.991, +\infty[.$

Exemple

- X : "Marche à l'âge donné" pour les prématurés. 3 modalités (oui, ébauche, non).
- $H_0 : X \sim P_0$ contre $H_1 : X \not\sim P_0$ avec $P_0(\text{oui}) = 0.5$, $P_0(\text{ébauche}) = 0.12$, $P_0(\text{non}) = 0.38$. Risque $\alpha = 0.05$.
- Sous H_0 la statistique

$$D_n = \sum_{k=1}^3 \frac{(N_k - np_k)^2}{np_k} \underset{\text{approx}}{\sim} \chi^2(2).$$

- $\mathcal{R}_{H_0} =]5.991, +\infty[.$

Exemple

- X : "Marche à l'âge donné" pour les prématurés. 3 modalités (oui, ébauche, non).
- $H_0 : X \sim P_0$ contre $H_1 : X \not\sim P_0$ avec $P_0(\text{oui}) = 0.5$, $P_0(\text{ébauche}) = 0.12$, $P_0(\text{non}) = 0.38$. Risque $\alpha = 0.05$.
- Sous H_0 la statistique

$$D_n = \sum_{k=1}^3 \frac{(N_k - np_k)^2}{np_k} \stackrel{\text{approx}}{\sim} \chi^2(2).$$

- $\mathcal{R}_{H_0} =]5.991, +\infty[.$

	oui	ébauche	non	Total
obs	35	4	41	80
théo	40	9.6	30.4	80
écart	0.625	3.267	3.696	7.588

- $D_{obs} \in \mathcal{R}_{H_0}$, on rejette H_0 au risque 5%
($pc = 1 - F_{\chi_2^2}(7.588) = 0.0225$).
- Sur R, on peut réaliser le test avec les commandes

```
> x <- c(35,4,41)
> p0 <- c(0.5,0.12,0.38)
> chisq.test(x, p=p0)
```

Chi-squared test for given probabilities

```
data: x
X-squared = 7.5877, df = 2, p-value = 0.02251
```

	oui	ébauche	non	Total
obs	35	4	41	80
théo	40	9.6	30.4	80
écart	0.625	3.267	3.696	7.588

- $D_{obs} \in \mathcal{R}_{H_0}$, on rejette H_0 au risque 5%
($pc = 1 - F_{\chi^2_2}(7.588) = 0.0225$).
- Sur R, on peut réaliser le test avec les commandes

```
> x <- c(35,4,41)
> p0 <- c(0.5,0.12,0.38)
> chisq.test(x, p=p0)
```

Chi-squared test for given probabilities

```
data: x
X-squared = 7.5877, df = 2, p-value = 0.02251
```


	oui	ébauche	non	Total
obs	35	4	41	80
théo	40	9.6	30.4	80
écart	0.625	3.267	3.696	7.588

- $D_{obs} \in \mathcal{R}_{H_0}$, on rejette H_0 au risque 5%
($pc = 1 - F_{\chi_2^2}(7.588) = 0.0225$).
- Sur R, on peut réaliser le test avec les commandes

```
> x <- c(35,4,41)
> p0 <- c(0.5,0.12,0.38)
> chisq.test(x,p=p0)
```

Chi-squared test for given probabilities

```
data: x
X-squared = 7.5877, df = 2, p-value = 0.02251
```

Propriété

Si la loi P_0 dépend de r paramètres, alors ces paramètres sont estimés (MV par exemple) et dans ce cas, sous H_0 $D(P_n, P_0) \xrightarrow{\mathcal{L}} \chi_{m-r-1}^2$.

Exemple du nombre de garçons

- $H_0 : X \sim B(4, p)$ contre $H_1 : X \neq B(4, p)$.
- Estimateur de p : $\hat{p} = 0.4925$.

	0	1	2	3	4	Total
obs	3	30	39	23	5	100
théo	6.63	25.7	37.48	24.2	5.8	100

$D_{obs} = 2.95 \notin]7.81, +\infty[$. On accepte H_0 au risque 5%.

Propriété

Si la loi P_0 dépend de r paramètres, alors ces paramètres sont estimés (MV par exemple) et dans ce cas, sous H_0 $D(P_n, P_0) \xrightarrow{\mathcal{L}} \chi_{m-r-1}^2$.

Exemple du nombre de garçons

- $H_0 : X \sim B(4, p)$ contre $H_1 : X \not\sim B(4, p)$.
- Estimateur de p : $\hat{p} = 0.4925$.

	0	1	2	3	4	Total
obs	3	30	39	23	5	100
théo	6.63	25.7	37.48	24.2	5.8	100

$D_{obs} = 2.95 \notin]7.81, +\infty[$. On accepte H_0 au risque 5%.

Propriété

Si la loi P_0 dépend de r paramètres, alors ces paramètres sont estimés (MV par exemple) et dans ce cas, sous H_0 $D(P_n, P_0) \xrightarrow{\mathcal{L}} \chi_{m-r-1}^2$.

Exemple du nombre de garçons

- $H_0 : X \sim B(4, p)$ contre $H_1 : X \neq B(4, p)$.
- Estimateur de p : $\hat{p} = 0.4925$.

	0	1	2	3	4	Total
obs	3	30	39	23	5	100
théo	6.63	25.7	37.48	24.2	5.8	100

$D_{obs} = 2.95 \notin]7.81, +\infty[$. On accepte H_0 au risque 5%.

Propriété

Si la loi P_0 dépend de r paramètres, alors ces paramètres sont estimés (MV par exemple) et dans ce cas, sous H_0 $D(P_n, P_0) \xrightarrow{\mathcal{L}} \chi_{m-r-1}^2$.

Exemple du nombre de garçons

- $H_0 : X \sim B(4, p)$ contre $H_1 : X \not\sim B(4, p)$.
- Estimateur de p : $\hat{p} = 0.4925$.

	0	1	2	3	4	Total
obs	3	30	39	23	5	100
théo	6.63	25.7	37.48	24.2	5.8	100

$D_{obs} = 2.95 \notin]7.81, +\infty[$. On accepte H_0 au risque 5%.

1 Introduction

2 Tests paramétriques

- Vocabulaire
- Le principe de Neyman-Pearson
- Puissance de test - Test UPP
- Exemples
- Comparaison de deux échantillons gaussiens
- Cas non gaussien

3 Une introduction aux tests non paramétriques

- Le test du χ^2 d'adéquation
- Le test du χ^2 d'indépendance

Notations

- Soient X et Y deux variables aléatoires à valeurs dans E et F . On souhaite tester au niveau α les hypothèses H_0 : "X et Y sont indépendantes" contre H_1 : "X et Y ne sont pas indépendantes".
- On se donne (E_1, \dots, E_I) et (F_1, \dots, F_J) deux partitions de E et F .
- On dispose de n mesures du couple (X, Y) et on désigne par N_{ij} l'effectif observé dans la classe $E_i \times F_j$.

	F_1	...	F_j	...	F_J	Total
E_1	N_{11}	...	N_{1j}	...	N_{1J}	$N_{1\bullet}$
\vdots						\vdots
E_i	N_{i1}	...	N_{ij}	...	N_{iJ}	$N_{i\bullet}$
\vdots						\vdots
E_I	N_{I1}	...	N_{Ij}	...	N_{IJ}	$N_{I\bullet}$
Total	$N_{\bullet 1}$...	$N_{\bullet j}$...	$N_{\bullet J}$	n

Notations

- Soient X et Y deux variables aléatoires à valeurs dans E et F . On souhaite tester au niveau α les hypothèses H_0 : "X et Y sont indépendantes" contre H_1 : "X et Y ne sont pas indépendantes".
- On se donne (E_1, \dots, E_I) et (F_1, \dots, F_J) deux partitions de E et F .
- On dispose de n mesures du couple (X, Y) et on désigne par N_{ij} l'effectif observé dans la classe $E_i \times F_j$.

	F_1	...	F_j	...	F_J	Total
E_1	N_{11}	...	N_{1j}	...	N_{1J}	$N_{1\bullet}$
\vdots						\vdots
E_i	N_{i1}	...	N_{ij}	...	N_{iJ}	$N_{i\bullet}$
\vdots						\vdots
E_I	N_{I1}	...	N_{Ij}	...	N_{IJ}	$N_{I\bullet}$
Total	$N_{\bullet 1}$...	$N_{\bullet j}$...	$N_{\bullet J}$	n

Notations

- Soient X et Y deux variables aléatoires à valeurs dans E et F . On souhaite tester au niveau α les hypothèses H_0 : "X et Y sont indépendantes" contre H_1 : "X et Y ne sont pas indépendantes".
- On se donne (E_1, \dots, E_I) et (F_1, \dots, F_J) deux partitions de E et F .
- On dispose de n mesures du couple (X, Y) et on désigne par N_{ij} l'effectif observé dans la classe $E_i \times F_j$.

	F_1	...	F_j	...	F_J	Total
E_1	N_{11}	...	N_{1j}	...	N_{1J}	$N_{1\bullet}$
\vdots						\vdots
E_i	N_{i1}	...	N_{ij}	...	N_{iJ}	$N_{i\bullet}$
\vdots						\vdots
E_I	N_{I1}	...	N_{Ij}	...	N_{IJ}	$N_{I\bullet}$
Total	$N_{\bullet 1}$...	$N_{\bullet j}$...	$N_{\bullet J}$	n

Notations

- Soient X et Y deux variables aléatoires à valeurs dans E et F . On souhaite tester au niveau α les hypothèses H_0 : "X et Y sont indépendantes" contre H_1 : "X et Y ne sont pas indépendantes".
- On se donne (E_1, \dots, E_I) et (F_1, \dots, F_J) deux partitions de E et F .
- On dispose de n mesures du couple (X, Y) et on désigne par N_{ij} l'effectif observé dans la classe $E_i \times F_j$.

	F_1	...	F_j	...	F_J	Total
E_1	N_{11}	...	N_{1j}	...	N_{1J}	$N_{1\bullet}$
\vdots						\vdots
E_i	N_{i1}	...	N_{ij}	...	N_{iJ}	$N_{i\bullet}$
\vdots						\vdots
E_I	N_{I1}	...	N_{Ij}	...	N_{IJ}	$N_{I\bullet}$
Total	$N_{\bullet 1}$...	$N_{\bullet j}$...	$N_{\bullet J}$	n

Propriété

Sous H_0 la statistique

$$X_n = \sum_{i=1}^I \sum_{j=1}^J \frac{\left(\frac{N_{i\bullet} N_{\bullet j}}{n} - N_{ij} \right)^2}{\frac{N_{i\bullet} N_{\bullet j}}{n}}$$

converge en loi vers la loi $\chi^2_{(I-1)(J-1)}$.

- Au niveau α , on rejettera l'hypothèse H_0 si X_{obs} est supérieure au quantile d'ordre $1 - \alpha$ de la loi du $\chi^2_{(I-1)(J-1)}$.
- Le test étant asymptotique, il faudra s'assurer en pratique que $n > 30$ et $\frac{N_{i\bullet} N_{\bullet j}}{n} > 5$.

Propriété

Sous H_0 la statistique

$$X_n = \sum_{i=1}^I \sum_{j=1}^J \frac{\left(\frac{N_{i\bullet} N_{\bullet j}}{n} - N_{ij} \right)^2}{\frac{N_{i\bullet} N_{\bullet j}}{n}}$$

converge en loi vers la loi $\chi^2_{(I-1)(J-1)}$.

- Au niveau α , on rejettera l'hypothèse H_0 si X_{obs} est supérieure au quantile d'ordre $1 - \alpha$ de la loi du $\chi^2_{(I-1)(J-1)}$.
- Le test étant asymptotique, il faudra s'assurer en pratique que $n > 30$ et $\frac{N_{i\bullet} N_{\bullet j}}{n} > 5$.

Propriété

Sous H_0 la statistique

$$X_n = \sum_{i=1}^I \sum_{j=1}^J \frac{\left(\frac{N_{i\bullet} N_{\bullet j}}{n} - N_{ij}\right)^2}{\frac{N_{i\bullet} N_{\bullet j}}{n}}$$

converge en loi vers la loi $\chi^2_{(I-1)(J-1)}$.

- Au niveau α , on rejettera l'hypothèse H_0 si X_{obs} est supérieure au quantile d'ordre $1 - \alpha$ de la loi du $\chi^2_{(I-1)(J-1)}$.
- Le test étant asymptotique, il faudra s'assurer en pratique que $n > 30$ et $\frac{N_{i\bullet} N_{\bullet j}}{n} > 5$.

L'exemple du Titanic

- X : survécu ou pas, Y : classe.
- H_0 : "X et Y sont indépendantes" contre H_1 : "X et Y ne sont pas indépendantes".

	Effectifs observés				Total
	1	2	3	E	Total
oui	203	118	178	212	711
non	122	167	528	673	1490
Total	325	285	706	885	2201

	Effectifs Théoriques				Total
	1	2	3	E	Total
oui	105	92	228	286	711
non	220	192	478	599	1490
Total	325	285	706	885	2201

$X_{obs} = 190.4011 > 0.352 = \chi_{0.95}^2(3)$, l'hypothèse nulle est donc (clairement !) rejetée au niveau α .

L'exemple du Titanic

- X : survécu ou pas, Y : classe.
- H_0 : "X et Y sont indépendantes" contre H_1 : "X et Y ne sont pas indépendantes".

		Effectifs observés				
		1	2	3	E	Total
oui	203	118	178	212	711	
non	122	167	528	673	1490	
Total	325	285	706	885	2201	

		Effectifs Théoriques				
		1	2	3	E	Total
oui	105	92	228	286	711	
non	220	192	478	599	1490	
Total	325	285	706	885	2201	

$X_{obs} = 190.4011 > 0.352 = \chi_{0.95}^2(3)$, l'hypothèse nulle est donc (clairement !) rejetée au niveau α .

L'exemple du Titanic

- X : survécu ou pas, Y : classe.
- H_0 : "X et Y sont indépendantes" contre H_1 : "X et Y ne sont pas indépendantes".

	Effectifs observés				Total
	1	2	3	E	
oui	203	118	178	212	711
non	122	167	528	673	1490
Total	325	285	706	885	2201

	Effectifs Théoriques				Total
	1	2	3	E	
oui	105	92	228	286	711
non	220	192	478	599	1490
Total	325	285	706	885	2201

$\chi_{obs}^2 = 190.4011 > 0.352 = \chi_{0.95}^2(3)$, l'hypothèse nulle est donc (clairement !) rejetée au niveau α .

L'exemple du Titanic

- X : survécu ou pas, Y : classe.
- H_0 : "X et Y sont indépendantes" contre H_1 : "X et Y ne sont pas indépendantes".

	Effectifs observés				Total
	1	2	3	E	
oui	203	118	178	212	711
non	122	167	528	673	1490
Total	325	285	706	885	2201

	Effectifs Théoriques				Total
	1	2	3	E	
oui	105	92	228	286	711
non	220	192	478	599	1490
Total	325	285	706	885	2201

$X_{obs} = 190.4011 > 0.352 = \chi_{0.95}^2(3)$, l'hypothèse nulle est donc (clairement !) rejetée au niveau α .

Cinquième partie V

Le modèle de régression linéaire

1 Introduction

2 La régression linéaire simple

- Ajustement par moindres carrés
- Propriétés des estimateurs
- Quelques lois de probabilités
- Inférence statistique

3 La régression multiple

- Notations et modélisation
- Estimateur des moindres carrés
- Propriétés statistiques

4 Validation et choix de modèles

- Résidus et coefficient de détermination
- Tests entre modèles emboîtés

5 Analyse de la variance

- Modèle à un facteur
- ANOVA à deux facteurs
- Sélection de modèles

6 Bibliographie

1 Introduction

2 La régression linéaire simple

- Ajustement par moindres carrés
- Propriétés des estimateurs
- Quelques lois de probabilités
- Inférence statistique

3 La régression multiple

- Notations et modélisation
- Estimateur des moindres carrés
- Propriétés statistiques

4 Validation et choix de modèles

- Résidus et coefficient de détermination
- Tests entre modèles emboîtés

5 Analyse de la variance

- Modèle à un facteur
- ANOVA à deux facteurs
- Sélection de modèles

6 Bibliographie

Le problème de régression

- On cherche à expliquer une variable Y par p variables $\mathbf{X}_1, \dots, \mathbf{X}_p$.
- Il s'agit de trouver une fonction $m : \mathbb{R}^p \rightarrow \mathbb{R}$ telle que $Y \approx m(\mathbf{X}_1, \dots, \mathbf{X}_p)$.
- Sauf cas (très) particulier, le lien n'est jamais "parfait"

$$Y = m(\mathbf{X}_1, \dots, \mathbf{X}_p) + \varepsilon.$$

Modèle de régression

- Poser un modèle de régression revient à supposer que la fonction m appartient à un certain espace \mathcal{M} .
- Le problème du statisticien sera alors de trouver la "meilleure" fonction dans \mathcal{M} à l'aide d'un n -échantillon i.i.d. $(X_1, Y_1), \dots, (X_n, Y_n)$.

Le problème de régression

- On cherche à expliquer une variable Y par p variables $\mathbf{X}_1, \dots, \mathbf{X}_p$.
- Il s'agit de trouver une fonction $m : \mathbb{R}^p \rightarrow \mathbb{R}$ telle que $Y \approx m(\mathbf{X}_1, \dots, \mathbf{X}_p)$.
- Sauf cas (très) particulier, le lien n'est jamais "parfait"

$$Y = m(\mathbf{X}_1, \dots, \mathbf{X}_p) + \varepsilon.$$

Modèle de régression

- Poser un modèle de régression revient à supposer que la fonction m appartient à un certain espace \mathcal{M} .
- Le problème du statisticien sera alors de trouver la "meilleure" fonction dans \mathcal{M} à l'aide d'un n -échantillon i.i.d. $(X_1, Y_1), \dots, (X_n, Y_n)$.

Le problème de régression

- On cherche à expliquer une variable Y par p variables $\mathbf{X}_1, \dots, \mathbf{X}_p$.
- Il s'agit de trouver une fonction $m : \mathbb{R}^p \rightarrow \mathbb{R}$ telle que $Y \approx m(\mathbf{X}_1, \dots, \mathbf{X}_p)$.
- Sauf cas (très) particulier, le lien n'est jamais "parfait"

$$Y = m(\mathbf{X}_1, \dots, \mathbf{X}_p) + \varepsilon.$$

Modèle de régression

- Poser un modèle de régression revient à supposer que la fonction m appartient à un certain espace \mathcal{M} .
- Le problème du statisticien sera alors de trouver la "meilleure" fonction dans \mathcal{M} à l'aide d'un n -échantillon i.i.d. $(X_1, Y_1), \dots, (X_n, Y_n)$.

Le problème de régression

- On cherche à expliquer une variable Y par p variables $\mathbf{X}_1, \dots, \mathbf{X}_p$.
- Il s'agit de trouver une fonction $m : \mathbb{R}^p \rightarrow \mathbb{R}$ telle que $Y \approx m(\mathbf{X}_1, \dots, \mathbf{X}_p)$.
- Sauf cas (très) particulier, le lien n'est jamais "parfait"

$$Y = m(\mathbf{X}_1, \dots, \mathbf{X}_p) + \varepsilon.$$

Modèle de régression

- Poser un modèle de régression revient à supposer que la fonction m appartient à un certain espace \mathcal{M} .
- Le problème du statisticien sera alors de trouver la "meilleure" fonction dans \mathcal{M} à l'aide d'un n -échantillon i.i.d. $(X_1, Y_1), \dots, (X_n, Y_n)$.

Modèle non paramétrique

- L'espace \mathcal{M} est de dimension infinie.
- **Exemple** : On pose $Y = m(\mathbf{X}_1, \dots, \mathbf{X}_p) + \varepsilon$ où m appartient à l'espace des fonctions continues.

Modèle paramétrique

- L'espace \mathcal{M} est de dimension finie.
- **Exemple** : on suppose que la fonction m est linéaire

$$Y = \beta_0 + \beta_1 \mathbf{X}_1 + \dots + \beta_p \mathbf{X}_p + \varepsilon.$$

Le problème est alors d'estimer $\beta = (\beta_0, \beta_1, \dots, \beta_p)$ à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

- C'est le modèle de **régression linéaire**.

Modèle non paramétrique

- L'espace \mathcal{M} est de dimension infinie.
- **Exemple** : On pose $Y = m(\mathbf{X}_1, \dots, \mathbf{X}_p) + \varepsilon$ où m appartient à l'espace des fonctions continues.

Modèle paramétrique

- L'espace \mathcal{M} est de dimension finie.
- **Exemple** : on suppose que la fonction m est linéaire

$$Y = \beta_0 + \beta_1 \mathbf{X}_1 + \dots + \beta_p \mathbf{X}_p + \varepsilon.$$

Le problème est alors d'estimer $\beta = (\beta_0, \beta_1, \dots, \beta_p)$ à l'aide de $(X_1, Y_1), \dots, (X_n, Y_n)$.

- C'est le modèle de **régression linéaire**.

- On cherche à **expliquer** ou à **prédire** la concentration en ozone.
- On dispose de $n = 112$ observations de la concentration en ozone ainsi que de 12 autres variables susceptibles d'expliquer cette concentration :
 - Température relevée à différents moments de la journée.
 - Indice de nébulosité relevé à différents moments de la journée.
 - Direction du vent.
 - Pluie.

Question

Comment expliquer (modéliser) la concentration en ozone à l'aide de toutes ces variables ?

- On cherche à **expliquer** ou à **prédire** la concentration en ozone.
- On dispose de $n = 112$ observations de la concentration en ozone ainsi que de 12 autres variables susceptibles d'expliquer cette concentration :
 - Température relevée à différents moments de la journée.
 - Indice de nébulosité relevé à différents moments de la journée.
 - Direction du vent.
 - Pluie.

Question


Comment expliquer (modéliser) la concentration en ozone à l'aide de toutes ces variables ?

Ozone en fonction de la température à 12h ?

MaxO3	87	82	92	114	94	80	...
T12	18.5	18.4	17.6	19.7	20.5	19.8	...


Ozone en fonction de la température à 12h ?

MaxO3	87	82	92	114	94	80	...
T12	18.5	18.4	17.6	19.7	20.5	19.8	...




Ozone en fonction de la température à 12h ?

MaxO3	87	82	92	114	94	80	...
T12	18.5	18.4	17.6	19.7	20.5	19.8	...



Ozone en fonction de la température à 12h ?

MaxO3	87	82	92	114	94	80	...
T12	18.5	18.4	17.6	19.7	20.5	19.8	...




Comment ajuster le nuage de points ?

Ozone en fonction du vent ?

MaxO3	87	82	92	114	94	80	...
Vent	Nord	Nord	Est	Nord	Ouest	Ouest	...


Ozone en fonction du vent ?

MaxO3	87	82	92	114	94	80	...
Vent	Nord	Nord	Est	Nord	Ouest	Ouest	...



Ozone en fonction du vent ?


MaxO3	87	82	92	114	94	80	...
Vent	Nord	Nord	Est	Nord	Ouest	Ouest	...



$$\text{MaxO3} \approx \alpha_1 \mathbf{1}_{\text{Vent=est}} + \dots + \alpha_4 \mathbf{1}_{\text{Vent=sud}}.$$


$$\alpha_j = ???$$

Ozone en fonction de la température à 12h et du vent ?



$$\max O_3 \approx \begin{cases} \beta_{01} + \beta_{11} T_{12} & \text{si vent=est} \\ \vdots & \vdots \\ \beta_{04} + \beta_{14} T_{12} & \text{si vent=ouest} \end{cases}$$

Ozone en fonction de la température à 12h et du vent ?



$$\max O_3 \approx \begin{cases} \beta_{01} + \beta_{11} T_{12} & \text{si vent=est} \\ \vdots & \vdots \\ \beta_{04} + \beta_{14} T_{12} & \text{si vent=ouest} \end{cases}$$

- Généralisation

$$\max O3 \approx \beta_0 + \beta_1 V_1 + \dots + \beta_{12} V_{12}$$

Questions

- Comment calculer (ou plutôt **estimer**) les paramètres β_j ?
- Le modèle avec les 12 variables est-il "meilleur" que des modèles avec moins de variables ?
- Comment trouver le "meilleur" sous-groupe de variables ?

- Généralisation

$$\max O3 \approx \beta_0 + \beta_1 V_1 + \dots + \beta_{12} V_{12}$$

Questions

- Comment calculer (ou plutôt **estimer**) les paramètres β_j ?
- Le modèle avec les 12 variables est-il "meilleur" que des modèles avec moins de variables ?
- Comment trouver le "meilleur" sous-groupe de variables ?

1 Introduction

2 La régression linéaire simple

- Ajustement par moindres carrés
- Propriétés des estimateurs
- Quelques lois de probabilités
- Inférence statistique

3 La régression multiple

- Notations et modélisation
- Estimateur des moindres carrés
- Propriétés statistiques

4 Validation et choix de modèles

- Résidus et coefficient de détermination
- Tests entre modèles emboîtés

5 Analyse de la variance

- Modèle à un facteur
- ANOVA à deux facteurs
- Sélection de modèles

6 Bibliographie

1 Introduction

2 La régression linéaire simple

- Ajustement par moindres carrés
- Propriétés des estimateurs
- Quelques lois de probabilités
- Inférence statistique

3 La régression multiple

- Notations et modélisation
- Estimateur des moindres carrés
- Propriétés statistiques

4 Validation et choix de modèles

- Résidus et coefficient de détermination
- Tests entre modèles emboîtés

5 Analyse de la variance

- Modèle à un facteur
- ANOVA à deux facteurs
- Sélection de modèles


6 Bibliographie

Notations

- n observations y_1, \dots, y_n de la **variable à expliquer** (maxO3).
- n observations x_1, \dots, x_n de la **variable explicative** (T12).


Notations

- n observations y_1, \dots, y_n de la **variable à expliquer** (maxO3).
- n observations x_1, \dots, x_n de la **variable explicative** (T12).



Notations


- n observations y_1, \dots, y_n de la **variable à expliquer** (maxO3).
- n observations x_1, \dots, x_n de la **variable explicative** (T12).



Ajustement linéaire d'un nuage de points

Notations

- n observations y_1, \dots, y_n de la **variable à expliquer** (maxO3).
- n observations x_1, \dots, x_n de la **variable explicative** (T12).



Problème


Trouver la droite qui ajuste "au mieux" le nuage de points $(x_i, y_i)_{i=1, \dots, n}$.

- On cherche $y = \beta_0 + \beta_1 x$ qui ajuste au mieux le nuage des points.
- Toutes les observations mesurées ne se trouvent pas sur une droite :

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i.$$


- On cherche $y = \beta_0 + \beta_1 x$ qui ajuste au mieux le nuage des points.
- Toutes les observations mesurées ne se trouvent pas sur une droite :

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i.$$



- On cherche $y = \beta_0 + \beta_1 x$ qui ajuste au mieux le nuage des points.
- Toutes les observations mesurées ne se trouvent pas sur une droite :

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i.$$



Idée

Chercher à minimiser les **erreurs** ou les **bruits** ε_i .

Critère des MC

On cherche (β_0, β_1) qui minimisent

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2.$$

Solution

La solution est donnée par :

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \quad \text{et} \quad \hat{\beta}_1 = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

à condition que tous les x_i ne soient pas égaux.

Critère des MC

On cherche (β_0, β_1) qui minimisent

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2.$$

Solution

La solution est donnée par :

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \quad \text{et} \quad \hat{\beta}_1 = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

à condition que tous les x_i ne soient pas égaux.

1 Introduction

2 La régression linéaire simple

- Ajustement par moindres carrés
- **Propriétés des estimateurs**
- Quelques lois de probabilités
- Inférence statistique

3 La régression multiple

- Notations et modélisation
- Estimateur des moindres carrés
- Propriétés statistiques

4 Validation et choix de modèles

- Résidus et coefficient de détermination
- Tests entre modèles emboîtés

5 Analyse de la variance

- Modèle à un facteur
- ANOVA à deux facteurs
- Sélection de modèles

6 Bibliographie

- L'idée sous-jacente est que la variable Y est liée à X par une relation linéaire ou quasi-linéaire.
- Sur les observations, la linéarité n'est généralement pas "parfaite".
- **Hypothèse** : cet "écart" à la linéarité est la conséquence de phénomène que l'on ne peut contrôler de manière déterministe (**phénomènes aléatoires**).

Les erreurs $\varepsilon_i, i = 1, \dots, n$ sont des variables aléatoires.

- L'idée sous-jacente est que la variable Y est liée à X par une relation linéaire ou quasi-linéaire.
- Sur les observations, la linéarité n'est généralement pas "parfaite".
- **Hypothèse** : cet "écart" à la linéarité est la conséquence de phénomène que l'on ne peut contrôler de manière déterministe (**phénomènes aléatoires**).

Les erreurs $\varepsilon_i, i = 1, \dots, n$ sont des variables aléatoires.

- L'idée sous-jacente est que la variable Y est liée à X par une relation linéaire ou quasi-linéaire.
- Sur les observations, la linéarité n'est généralement pas "parfaite".
- **Hypothèse** : cet "écart" à la linéarité est la conséquence de phénomène que l'on ne peut contrôler de manière déterministe (**phénomènes aléatoires**).

Les erreurs $\varepsilon_i, i = 1, \dots, n$ sont des variables aléatoires.

Le modèle de régression linéaire (V1)

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, \dots, n$$

avec

- $\varepsilon_1, \dots, \varepsilon_n$ n variables aléatoires indépendantes.

Conséquence

- Y_1, \dots, Y_n sont n variables aléatoires indépendantes.
- Qu'en est-il pour les x_i ?
 - quantités déterministes ?
 - quantités aléatoires ?
- L'étude des propriétés statistiques du modèle linéaire est quasiment identique selon la nature des x_i , nous les supposons déterministes dans la suite.

Le modèle de régression linéaire (V1)

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, \dots, n$$

avec

- $\varepsilon_1, \dots, \varepsilon_n$ n variables aléatoires indépendantes.

Conséquence

- Y_1, \dots, Y_n sont n variables aléatoires indépendantes.
- Qu'en est-il pour les x_i ?
 - quantités déterministes ?
 - quantités aléatoires ?
- L'étude des propriétés statistiques du modèle linéaire est quasiment identique selon la nature des x_i , nous les supposons déterministes dans la suite.

Le modèle de régression linéaire (V1)

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, \dots, n$$

avec

- $\varepsilon_1, \dots, \varepsilon_n$ n variables aléatoires indépendantes.

Conséquence

- Y_1, \dots, Y_n sont n variables aléatoires indépendantes.
- Qu'en est-il pour les x_i ?
 - quantités déterministes ?
 - quantités aléatoires ?
- L'étude des propriétés statistiques du modèle linéaire est quasiment identique selon la nature des x_i , nous les supposons déterministes dans la suite.

Le modèle de régression linéaire (V1)

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, \dots, n$$

avec

- $\varepsilon_1, \dots, \varepsilon_n$ n variables aléatoires indépendantes.

Conséquence

- Y_1, \dots, Y_n sont n variables aléatoires indépendantes.
- Qu'en est-il pour les x_i ?
 - quantités déterministes ?
 - quantités aléatoires ?
- L'étude des propriétés statistiques du modèle linéaire est quasiment identique selon la nature des x_i , nous les supposons déterministes dans la suite.

Rappels

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x} \quad \text{et} \quad \hat{\beta}_1 = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

Propriétés

Sous les hypothèses :

- 1 $\mathcal{H}_1 : \mathbf{E}(\varepsilon_i) = 0$ pour $i = 1, \dots, n$.
- 2 $\mathcal{H}_2 : \mathbf{V}(\varepsilon_i) = \sigma^2$ pour $i = 1, \dots, n$.

on a

- 1 $\hat{\beta}_0$ et $\hat{\beta}_1$ sont des estimateurs sans biais.
- 2 Les variances sont données par

$$\mathbf{V}(\hat{\beta}_0) = \sigma^2 \frac{\sum_{i=1}^n x_i^2}{n \sum_{i=1}^n (x_i - \bar{x})^2} \quad \text{et} \quad \mathbf{V}(\hat{\beta}_1) = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}.$$

Rappels

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x} \quad \text{et} \quad \hat{\beta}_1 = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

Propriétés

Sous les hypothèses :

- 1 $\mathcal{H}_1 : \mathbf{E}(\varepsilon_i) = 0$ pour $i = 1, \dots, n$.
- 2 $\mathcal{H}_2 : \mathbf{V}(\varepsilon_i) = \sigma^2$ pour $i = 1, \dots, n$.

on a

- 1 $\hat{\beta}_0$ et $\hat{\beta}_1$ sont des estimateurs sans biais.
- 2 Les variances sont données par

$$\mathbf{V}(\hat{\beta}_0) = \sigma^2 \frac{\sum_{i=1}^n x_i^2}{n \sum_{i=1}^n (x_i - \bar{x})^2} \quad \text{et} \quad \mathbf{V}(\hat{\beta}_1) = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}.$$

Rappels

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x} \quad \text{et} \quad \hat{\beta}_1 = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

Propriétés

Sous les hypothèses :

- 1 $\mathcal{H}_1 : \mathbf{E}(\varepsilon_i) = 0$ pour $i = 1, \dots, n$.
- 2 $\mathcal{H}_2 : \mathbf{V}(\varepsilon_i) = \sigma^2$ pour $i = 1, \dots, n$.

on a

- 1 $\hat{\beta}_0$ et $\hat{\beta}_1$ sont des estimateurs sans biais.
- 2 Les variances sont données par

$$\mathbf{V}(\hat{\beta}_0) = \sigma^2 \frac{\sum_{i=1}^n x_i^2}{n \sum_{i=1}^n (x_i - \bar{x})^2} \quad \text{et} \quad \mathbf{V}(\hat{\beta}_1) = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}.$$

Vocabulaire

- $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$: valeur ajustée de Y_i par le modèle.
- $\hat{\varepsilon}_i = Y_i - \hat{Y}_i$ résidu.
- Etant donné x_{n+1} une nouvelle valeur de la variable X , cherche à estimer $y_{n+1} = \beta_0 + \beta_1 x_{n+1}$.
- Un estimateur naturel est la prévision associée à cette nouvelle observation \hat{Y}_{n+1} :

$$\hat{Y}_{n+1} = \hat{\beta}_0 + \hat{\beta}_1 x_{n+1}.$$

Vocabulaire


- $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$: valeur ajustée de Y_i par le modèle.
- $\hat{\varepsilon}_i = Y_i - \hat{Y}_i$ résidu.
- Etant donné x_{n+1} une nouvelle valeur de la variable X , cherche à estimer $y_{n+1} = \beta_0 + \beta_1 x_{n+1}$.
- Un estimateur naturel est la prévision associée à cette nouvelle observation \hat{Y}_{n+1} :

$$\hat{Y}_{n+1} = \hat{\beta}_0 + \hat{\beta}_1 x_{n+1}.$$

Vocabulaire

- $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$: valeur ajustée de Y_i par le modèle.
- $\hat{\varepsilon}_i = Y_i - \hat{Y}_i$ résidu.
- Etant donné x_{n+1} une nouvelle valeur de la variable X , cherche à estimer $y_{n+1} = \beta_0 + \beta_1 x_{n+1}$.
- Un estimateur naturel est la prévision associée à cette nouvelle observation \hat{Y}_{n+1} :

$$\hat{Y}_{n+1} = \hat{\beta}_0 + \hat{\beta}_1 x_{n+1}.$$



Propriété

On a

$$\mathbf{V}(\hat{Y}_{n+1}) = \sigma^2 \left(\frac{1}{n} + \frac{(x_{n+1} - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right).$$

La variance de la prévision est d'autant plus faible que :

- σ^2 est petit (on pouvait s'y attendre...).
- x_{n+1} est proche du centre de gravité des x_i (plus difficile de bien prédire vers les extrêmes).

Questions

- 1 Comment mesurer la qualité du modèle ?
- 2 Comment tester la valeur des coefficients du modèle ?
- 3 Peut-on obtenir des intervalles de confiance pour les paramètres β_j ou pour la prévision \hat{Y}_{n+1} ?

Propriété

On a

$$\mathbf{V}(\hat{Y}_{n+1}) = \sigma^2 \left(\frac{1}{n} + \frac{(x_{n+1} - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right).$$

La variance de la prévision est d'autant plus faible que :

- σ^2 est petit (on pouvait s'y attendre...).
- x_{n+1} est proche du centre de gravité des x_i (plus difficile de bien prédire vers les extrêmes).

Questions

- 1 Comment mesurer la qualité du modèle ?
- 2 Comment tester la valeur des coefficients du modèle ?
- 3 Peut-on obtenir des intervalles de confiance pour les paramètres β_j ou pour la prévision \hat{Y}_{n+1} ?

Propriété

On a

$$\mathbf{V}(\hat{Y}_{n+1}) = \sigma^2 \left(\frac{1}{n} + \frac{(x_{n+1} - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right).$$

La variance de la prévision est d'autant plus faible que :

- σ^2 est petit (on pouvait s'y attendre...).
- x_{n+1} est proche du centre de gravité des x_i (plus difficile de bien prédire vers les extrêmes).

Questions

- 1 Comment mesurer la qualité du modèle ?
- 2 Comment tester la valeur des coefficients du modèle ?
- 3 Peut-on obtenir des intervalles de confiance pour les paramètres β_j ou pour la prévision \hat{Y}_{n+1} ?

1 Introduction

2 La régression linéaire simple

- Ajustement par moindres carrés
- Propriétés des estimateurs
- **Quelques lois de probabilités**
- Inférence statistique

3 La régression multiple

- Notations et modélisation
- Estimateur des moindres carrés
- Propriétés statistiques

4 Validation et choix de modèles

- Résidus et coefficient de détermination
- Tests entre modèles emboîtés

5 Analyse de la variance

- Modèle à un facteur
- ANOVA à deux facteurs
- Sélection de modèles

6 Bibliographie

Définition

- Une v.a.r X suit une loi normale de paramètres $\mu \in \mathbb{R}$ et $\sigma^2 > 0$ admet pour densité

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right).$$

Propriétés

- $\mathbf{E}[X] = \mu$ et $\mathbf{V}[X] = \sigma^2$.
- Si $X \sim N(\mu, \sigma^2)$ alors

$$\frac{X - \mu}{\sigma} \sim \mathcal{N}(0, 1).$$

Définition

- Une v.a.r X suit une loi normale de paramètres $\mu \in \mathbb{R}$ et $\sigma^2 > 0$ admet pour densité

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right).$$



Propriétés

- $\mathbf{E}[X] = \mu$ et $\mathbf{V}[X] = \sigma^2$.
- Si $X \sim N(\mu, \sigma^2)$ alors

$$\frac{X - \mu}{\sigma} \sim \mathcal{N}(0, 1).$$

Définition

- Soit X_1, \dots, X_n n variables aléatoires réelles indépendantes de loi $\mathcal{N}(0, 1)$. La variable $Y = X_1^2 + \dots + X_n^2$ suit une loi du Chi-Deux à n degrés de liberté. Elle est notée $\chi^2(n)$.
- $\mathbf{E}[Y] = n$ et $\mathbf{V}[Y] = 2n$.







Définition

- Soient X et Y deux v.a.r. indépendantes de loi $\mathcal{N}(0, 1)$ et $\chi^2(n)$. Alors la v.a.r.

$$T = \frac{X}{\sqrt{Y/n}}$$

suit une loi de student à n degrés de liberté. On note $\mathcal{T}(x)$.

- $\mathbf{E}[T] = 0$ et $\mathbf{V}[T] = n/(n - 2)$.
- Lorsque n est grand la loi de student à n degrés de liberté peut être approchée par la loi $\mathcal{N}(0, 1)$.



Densités des lois de student à 2, 5, 10 et 100 degrés de liberté (bleu) et densité de la loi $\mathcal{N}(0, 1)$ (rouge).

Définition

- Soient X et Y deux v.a.r indépendantes de lois $\chi^2(m)$ et $\chi^2(n)$. Alors la v.a.r

$$F = \frac{X/m}{Y/m}$$

suit une loi de Fisher à m et n degrés de liberté. On note $\mathcal{F}(m, n)$.

- Si $F \sim \mathcal{F}(m, n)$ alors $1/F \sim \mathcal{F}(n, m)$.




FIGURE – Densités $\mathcal{F}(5, 2)$ et $\mathcal{F}(10, 4)$

1 Introduction

2 La régression linéaire simple

- Ajustement par moindres carrés
- Propriétés des estimateurs
- Quelques lois de probabilités
- **Inférence statistique**

3 La régression multiple

- Notations et modélisation
- Estimateur des moindres carrés
- Propriétés statistiques

4 Validation et choix de modèles

- Résidus et coefficient de détermination
- Tests entre modèles emboîtés

5 Analyse de la variance

- Modèle à un facteur
- ANOVA à deux facteurs
- Sélection de modèles

6 Bibliographie

- Pour pouvoir faire de l'inférence, il nous faut mettre une loi sur la variable à expliquer.

\mathcal{H}_2 : les variables aléatoires ε_j suivent une loi $\mathcal{N}(0, \sigma^2)$.

Remarque

Cette hypothèse revient à supposer que $Y_i \sim \mathcal{N}(\beta_0 + \beta_1 x_i, \sigma^2)$. Elle nous amène donc à considérer le modèle paramétrique $(\mathbb{R}, \{\mathcal{N}(\beta_0 + \beta_1 x_i, \sigma^2), (\beta_0, \beta_1) \in \mathbb{R}^2\})$.

- Pour pouvoir faire de l'inférence, il nous faut mettre une loi sur la variable à expliquer.

\mathcal{H}_2 : les variables aléatoires ε_i suivent une loi $\mathcal{N}(0, \sigma^2)$.

Remarque

Cette hypothèse revient à supposer que $Y_i \sim \mathcal{N}(\beta_0 + \beta_1 x_i, \sigma^2)$. Elle nous amène donc à considérer le modèle paramétrique $(\mathbb{R}, \{\mathcal{N}(\beta_0 + \beta_1 x_i, \sigma^2), (\beta_0, \beta_1) \in \mathbb{R}^2\})$.

- Pour pouvoir faire de l'inférence, il nous faut mettre une loi sur la variable à expliquer.

\mathcal{H}_2 : les variables aléatoires ε_i suivent une loi $\mathcal{N}(0, \sigma^2)$.

Remarque

Cette hypothèse revient à supposer que $Y_i \sim \mathcal{N}(\beta_0 + \beta_1 x_i, \sigma^2)$. Elle nous amène donc à considérer le modèle paramétrique $(\mathbb{R}, \{\mathcal{N}(\beta_0 + \beta_1 x_i, \sigma^2), (\beta_0, \beta_1) \in \mathbb{R}^2\})$.

σ^2 connu

$$\textcircled{1} \hat{\beta}_0 \sim \mathcal{N}(\beta_0, \sigma_{\hat{\beta}_0}^2) \text{ et } \hat{\beta}_1 \sim \mathcal{N}(\beta_1, \sigma_{\hat{\beta}_1}^2)$$

σ^2 inconnu

On pose $\widehat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n \widehat{\varepsilon}_i^2 = \frac{\|\widehat{\varepsilon}\|^2}{n-2}$. On a

$$\textcircled{1} (n-2) \frac{\widehat{\sigma}^2}{\sigma^2} \sim \chi_{(n-2)}^2.$$

$\textcircled{2}$ $(\hat{\beta}_0, \hat{\beta}_1)$ et $\widehat{\sigma}^2$ sont indépendants.

$$\textcircled{3} \frac{\hat{\beta}_0 - \beta_0}{\widehat{\sigma}_{\hat{\beta}_0}} \sim \mathcal{T}_{n-2}.$$

$$\textcircled{4} \frac{\hat{\beta}_1 - \beta_1}{\widehat{\sigma}_{\hat{\beta}_1}} \sim \mathcal{T}_{n-2}.$$

Il est alors "facile" de construire des intervalles de confiance sur les paramètres ainsi que des tests d'hypothèses du genre $H_0 : \beta_j = 0$ contre $H_1 : \beta_j \neq 0$.

σ^2 connu

1 $\hat{\beta}_0 \sim \mathcal{N}(\beta_0, \sigma_{\hat{\beta}_0}^2)$ et $\hat{\beta}_1 \sim \mathcal{N}(\beta_1, \sigma_{\hat{\beta}_1}^2)$

σ^2 inconnu

On pose $\widehat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n \hat{\varepsilon}_i^2 = \frac{\|\hat{\varepsilon}\|^2}{n-2}$. On a

1 $(n-2) \frac{\widehat{\sigma}^2}{\sigma^2} \sim \chi_{(n-2)}^2$.

2 $(\hat{\beta}_0, \hat{\beta}_1)$ et $\widehat{\sigma}^2$ sont indépendants.

3 $\frac{\hat{\beta}_0 - \beta_0}{\widehat{\sigma}_{\hat{\beta}_0}} \sim \mathcal{T}_{n-2}$.

4 $\frac{\hat{\beta}_1 - \beta_1}{\widehat{\sigma}_{\hat{\beta}_1}} \sim \mathcal{T}_{n-2}$.

Il est alors "facile" de construire des intervalles de confiance sur les paramètres ainsi que des tests d'hypothèses du genre $H_0 : \beta_j = 0$ contre $H_1 : \beta_j \neq 0$.

σ^2 connu

1 $\hat{\beta}_0 \sim \mathcal{N}(\beta_0, \sigma_{\hat{\beta}_0}^2)$ et $\hat{\beta}_1 \sim \mathcal{N}(\beta_1, \sigma_{\hat{\beta}_1}^2)$

σ^2 inconnu

On pose $\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n \hat{\varepsilon}_i^2 = \frac{\|\hat{\varepsilon}\|^2}{n-2}$. On a

1 $(n-2) \frac{\hat{\sigma}^2}{\sigma^2} \sim \chi_{(n-2)}^2$.

2 $(\hat{\beta}_0, \hat{\beta}_1)$ et $\hat{\sigma}^2$ sont indépendants.

3 $\frac{\hat{\beta}_0 - \beta_0}{\hat{\sigma}_{\hat{\beta}_0}} \sim \mathcal{T}_{n-2}$.

4 $\frac{\hat{\beta}_1 - \beta_1}{\hat{\sigma}_{\hat{\beta}_1}} \sim \mathcal{T}_{n-2}$.

Il est alors "facile" de construire des intervalles de confiance sur les paramètres ainsi que des tests d'hypothèses du genre $H_0 : \beta_j = 0$ contre $H_1 : \beta_j \neq 0$.

σ^2 connu

$$\textcircled{1} \hat{\beta}_0 \sim \mathcal{N}(\beta_0, \sigma_{\hat{\beta}_0}^2) \text{ et } \hat{\beta}_1 \sim \mathcal{N}(\beta_1, \sigma_{\hat{\beta}_1}^2)$$

σ^2 inconnu

On pose $\widehat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n \hat{\varepsilon}_i^2 = \frac{\|\hat{\varepsilon}\|^2}{n-2}$. On a

$$\textcircled{1} (n-2) \frac{\widehat{\sigma}^2}{\sigma^2} \sim \chi_{(n-2)}^2.$$

$\textcircled{2}$ $(\hat{\beta}_0, \hat{\beta}_1)$ et $\widehat{\sigma}^2$ sont indépendants.

$$\textcircled{3} \frac{\hat{\beta}_0 - \beta_0}{\widehat{\sigma}_{\hat{\beta}_0}} \sim \mathcal{T}_{n-2}.$$

$$\textcircled{4} \frac{\hat{\beta}_1 - \beta_1}{\widehat{\sigma}_{\hat{\beta}_1}} \sim \mathcal{T}_{n-2}.$$

Il est alors "facile" de construire des intervalles de confiance sur les paramètres ainsi que des tests d'hypothèses du genre $H_0 : \beta_j = 0$ contre $H_1 : \beta_j \neq 0$.

σ^2 connu

$$\textcircled{1} \hat{\beta}_0 \sim \mathcal{N}(\beta_0, \sigma_{\hat{\beta}_0}^2) \text{ et } \hat{\beta}_1 \sim \mathcal{N}(\beta_1, \sigma_{\hat{\beta}_1}^2)$$

σ^2 inconnu

On pose $\widehat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n \hat{\varepsilon}_i^2 = \frac{\|\hat{\varepsilon}\|^2}{n-2}$. On a

$$\textcircled{1} (n-2) \frac{\widehat{\sigma}^2}{\sigma^2} \sim \chi_{(n-2)}^2.$$

$\textcircled{2}$ $(\hat{\beta}_0, \hat{\beta}_1)$ et $\widehat{\sigma}^2$ sont indépendants.

$$\textcircled{3} \frac{\hat{\beta}_0 - \beta_0}{\widehat{\sigma}_{\hat{\beta}_0}} \sim \mathcal{T}_{n-2}.$$

$$\textcircled{4} \frac{\hat{\beta}_1 - \beta_1}{\widehat{\sigma}_{\hat{\beta}_1}} \sim \mathcal{T}_{n-2}.$$

Il est alors "facile" de construire des intervalles de confiance sur les paramètres ainsi que des tests d'hypothèses du genre $H_0 : \beta_j = 0$ contre $H_1 : \beta_j \neq 0$.

Exemple de l'ozone

```
> reg.simple <- lm(maxO3~T12,data=donnees)
> summary(reg.simple)
```

```
Call:
lm(formula = maxO3 ~ T12, data = donnees)
```

Residuals:

	Min	1Q	Median	3Q	Max
	-38.0789	-12.7352	0.2567	11.0029	44.6714

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-27.4196	9.0335	-3.035	0.003 **
T12	5.4687	0.4125	13.258	<2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 17.57 on 110 degrees of freedom

Multiple R-squared: 0.6151, Adjusted R-squared: 0.6116

F-statistic: 175.8 on 1 and 110 DF, p-value: < 2.2e-16


IC pour Y_{n+1}

$$\left[\hat{Y}_{n+1} + t_{n-2}(1 - \alpha/2)\hat{\sigma} \sqrt{1 + \frac{1}{n} + \frac{(x_{n+1} - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} \right]$$

Intervalle de confiance de prévision

IC pour Y_{n+1}


$$\left[\hat{Y}_{n+1} \pm t_{n-2}(1 - \alpha/2)\hat{\sigma} \sqrt{1 + \frac{1}{n} + \frac{(x_{n+1} - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} \right]$$



Intervalle de confiance de prévision

IC pour Y_{n+1}

$$\left[\hat{Y}_{n+1} \pm t_{n-2}(1 - \alpha/2)\hat{\sigma} \sqrt{1 + \frac{1}{n} + \frac{(x_{n+1} - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} \right]$$



- 1 Introduction
- 2 La régression linéaire simple
 - Ajustement par moindres carrés
 - Propriétés des estimateurs
 - Quelques lois de probabilités
 - Inférence statistique
- 3 La régression multiple
 - Notations et modélisation
 - Estimateur des moindres carrés
 - Propriétés statistiques
- 4 Validation et choix de modèles
 - Résidus et coefficient de détermination
 - Tests entre modèles emboîtés
- 5 Analyse de la variance
 - Modèle à un facteur
 - ANOVA à deux facteurs
 - Sélection de modèles
- 6 Bibliographie

- 1 Introduction
- 2 La régression linéaire simple
 - Ajustement par moindres carrés
 - Propriétés des estimateurs
 - Quelques lois de probabilités
 - Inférence statistique
- 3 La régression multiple
 - **Notations et modélisation**
 - Estimateur des moindres carrés
 - Propriétés statistiques
- 4 Validation et choix de modèles
 - Résidus et coefficient de détermination
 - Tests entre modèles emboîtés
- 5 Analyse de la variance
 - Modèle à un facteur
 - ANOVA à deux facteurs
 - Sélection de modèles
- 6 Bibliographie

- La température à 12h n'est pas la seule variable permettant d'**expliquer** ou de **prédire** la concentration en ozone.
- D'autres variables doivent être prise en compte (nébulosité, force et direction du vent...).
- Nécessité d'étendre le modèle linéaire à plus d'une variable explicative.

- Y : variable (aléatoire) à expliquer à valeurs dans \mathbb{R} .
- X_1, \dots, X_p : p variables explicatives à valeurs dans \mathbb{R} .
- n observations $(x_1, Y_1), \dots, (x_n, Y_n)$ avec $x_i = (x_{i1}, \dots, x_{ip})$.

Le modèle de régression linéaire multiple

Le modèle s'écrit :

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i$$

où les erreurs aléatoires ε_i sont i.i.d. de loi $\mathcal{N}(0, \sigma^2)$.

- Y : variable (aléatoire) à expliquer à valeurs dans \mathbb{R} .
- X_1, \dots, X_p : p variables explicatives à valeurs dans \mathbb{R} .
- n observations $(x_1, Y_1), \dots, (x_n, Y_n)$ avec $x_i = (x_{i1}, \dots, x_{ip})$.

Le modèle de régression linéaire multiple

Le modèle s'écrit :

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i$$

où les erreurs aléatoires ε_i sont i.i.d. de loi $\mathcal{N}(0, \sigma^2)$.

- On note

$$\mathbf{Y} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}, \quad \mathbf{X} = \begin{pmatrix} 1 & x_{11} & \dots & x_{1p} \\ \vdots & \vdots & & \vdots \\ 1 & x_{n1} & \dots & x_{np} \end{pmatrix}, \quad \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \vdots \\ \beta_p \end{pmatrix}, \quad \boldsymbol{\varepsilon} = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

Ecriture matricielle

Le modèle se réécrit

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

où $\boldsymbol{\varepsilon} \sim \mathcal{N}(0, \sigma^2 \mathbf{I}_n)$.

- On note

$$\mathbf{Y} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}, \quad \mathbf{X} = \begin{pmatrix} 1 & x_{11} & \dots & x_{1p} \\ \vdots & \vdots & & \vdots \\ 1 & x_{n1} & \dots & x_{np} \end{pmatrix}, \quad \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \vdots \\ \beta_p \end{pmatrix}, \quad \boldsymbol{\varepsilon} = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

Ecriture matricielle

Le modèle se réécrit

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

où $\boldsymbol{\varepsilon} \sim \mathcal{N}(0, \sigma^2 \mathbf{I}_n)$.

- 1 Introduction
- 2 La régression linéaire simple
 - Ajustement par moindres carrés
 - Propriétés des estimateurs
 - Quelques lois de probabilités
 - Inférence statistique

- 3 La régression multiple
 - Notations et modélisation
 - **Estimateur des moindres carrés**
 - Propriétés statistiques

- 4 Validation et choix de modèles
 - Résidus et coefficient de détermination
 - Tests entre modèles emboîtés

- 5 Analyse de la variance
 - Modèle à un facteur
 - ANOVA à deux facteurs
 - Sélection de modèles

- 6 Bibliographie


Définition

On appelle **estimateur des moindres carrés** $\hat{\beta}$ de β la statistique suivante :

$$\hat{\beta} = \operatorname{argmin}_{\beta_0, \dots, \beta_p} \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_{i1} - \dots - \beta_p x_{ip})^2 = \operatorname{argmin}_{\beta \in \mathbb{R}^{p+1}} \|\mathbf{Y} - \mathbf{X}\beta\|^2.$$

- On note $\mathcal{F}(\mathbf{X})$ le s.e.v. de \mathbb{R}^n de dimension $p + 1$ engendré par les $p + 1$ colonnes de \mathbf{X} .
- Chercher l'estimateur des moindres carrés revient à minimiser la distance entre $\mathbf{Y} \in \mathbb{R}^n$ et $\mathcal{F}(\mathbf{X})$.

Représentation géométrique



- On déduit que $\mathbb{X}\hat{\beta}$ est le projeté orthogonal de \mathbb{Y} sur $\mathcal{F}(\mathbb{X})$:

$$\mathbb{X}\hat{\beta} = \mathbf{P}_{\mathcal{F}(\mathbb{X})}(\mathbb{Y}) = \mathbb{X}(\mathbb{X}'\mathbb{X})^{-1}\mathbb{X}'\mathbb{Y}.$$

Théorème

Si la matrice \mathbb{X} est de plein rang, l'estimateur des MC est donné par :

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

- On déduit que $\mathbb{X}\hat{\beta}$ est le projeté orthogonal de \mathbb{Y} sur $\mathcal{F}(\mathbb{X})$:

$$\mathbb{X}\hat{\beta} = \mathbf{P}_{\mathcal{F}(\mathbb{X})}(\mathbb{Y}) = \mathbb{X}(\mathbb{X}'\mathbb{X})^{-1}\mathbb{X}'\mathbb{Y}.$$

Théorème

Si la matrice \mathbb{X} est de plein rang, l'estimateur des MC est donné par :

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

- On déduit que $\mathbb{X}\hat{\beta}$ est le projeté orthogonal de \mathbb{Y} sur $\mathcal{F}(\mathbb{X})$:

$$\mathbb{X}\hat{\beta} = \mathbf{P}_{\mathcal{F}(\mathbb{X})}(\mathbb{Y}) = \mathbb{X}(\mathbb{X}'\mathbb{X})^{-1}\mathbb{X}'\mathbb{Y}.$$

Théorème

Si la matrice \mathbb{X} est de plein rang, l'estimateur des MC est donné par :

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

- 1 Introduction
- 2 La régression linéaire simple
 - Ajustement par moindres carrés
 - Propriétés des estimateurs
 - Quelques lois de probabilités
 - Inférence statistique
- 3 **La régression multiple**
 - Notations et modélisation
 - Estimateur des moindres carrés
 - **Propriétés statistiques**
- 4 Validation et choix de modèles
 - Résidus et coefficient de détermination
 - Tests entre modèles emboîtés
- 5 Analyse de la variance
 - Modèle à un facteur
 - ANOVA à deux facteurs
 - Sélection de modèles
- 6 Bibliographie

Propriété

- 1 $\hat{\beta}$ est un estimateur sans biais de β .
- 2 La matrice de variance-covariance de $\hat{\beta}$ est donnée par

$$\mathbf{V}(\hat{\beta}) = \sigma^2(\mathbf{X}'\mathbf{X})^{-1}.$$

- 3 $\hat{\beta}$ est VUMSB.

Remarque

La log-vraisemblance du modèle $(\mathbb{R}^n, \{\mathcal{N}(x_i'\beta, \sigma^2)\}^{\otimes n}, \beta \in \mathbb{R}^{p+1})$ est donnée par

$$\mathcal{L}(y_1, \dots, y_n; \beta) = \frac{n}{2} \log(\sigma^2) - \frac{n}{2} \log(2\pi) - \frac{1}{2\sigma^2} \|\mathbf{Y} - \mathbf{X}\beta\|^2.$$

Conclusion : l'estimateur du maximum de vraisemblance $\hat{\beta}_{MV}$ coïncide avec l'estimateur des moindres carrés $\hat{\beta}$.

Propriété

- 1 $\hat{\beta}$ est un estimateur sans biais de β .
- 2 La matrice de variance-covariance de $\hat{\beta}$ est donnée par

$$\mathbf{V}(\hat{\beta}) = \sigma^2(\mathbf{X}'\mathbf{X})^{-1}.$$

- 3 $\hat{\beta}$ est VUMSB.

Remarque

La log-vraisemblance du modèle $(\mathbb{R}^n, \{\mathcal{N}(x_i'\beta, \sigma^2)\}^{\otimes n}, \beta \in \mathbb{R}^{p+1})$ est donnée par

$$\mathcal{L}(y_1, \dots, y_n; \beta) = \frac{n}{2} \log(\sigma^2) - \frac{n}{2} \log(2\pi) - \frac{1}{2\sigma^2} \|\mathbf{Y} - \mathbf{X}\beta\|^2.$$

Conclusion : l'estimateur du maximum de vraisemblance $\hat{\beta}_{MV}$ coïncide avec l'estimateur des moindres carrés $\hat{\beta}$.

Propriété

- 1 $\hat{\beta}$ est un estimateur sans biais de β .
- 2 La matrice de variance-covariance de $\hat{\beta}$ est donnée par

$$\mathbf{V}(\hat{\beta}) = \sigma^2(\mathbf{X}'\mathbf{X})^{-1}.$$

- 3 $\hat{\beta}$ est VUMSB.

Remarque

La log-vraisemblance du modèle $(\mathbb{R}^n, \{\mathcal{N}(x_i'\beta, \sigma^2)\}^{\otimes n}, \beta \in \mathbb{R}^{p+1})$ est donnée par

$$\mathcal{L}(y_1, \dots, y_n; \beta) = \frac{n}{2} \log(\sigma^2) - \frac{n}{2} \log(2\pi) - \frac{1}{2\sigma^2} \|\mathbf{Y} - \mathbf{X}\beta\|^2.$$

Conclusion : l'estimateur du maximum de vraisemblance $\hat{\beta}_{MV}$ coïncide avec l'estimateur des moindres carrés $\hat{\beta}$.

- Soit $\hat{\varepsilon} = \mathbf{Y} - \hat{\mathbf{Y}}$ le vecteur des résidus et $\widehat{\sigma^2}$ l'estimateur de σ^2 défini par

$$\widehat{\sigma^2} = \frac{\|\hat{\varepsilon}\|^2}{n - (p + 1)}.$$

Proposition

- 1 $\hat{\beta}$ est un vecteur gaussien d'espérance β et de matrice de variance-covariance $\sigma^2(\mathbf{X}'\mathbf{X})^{-1}$.
- 2 $(n - (p + 1))\frac{\widehat{\sigma^2}}{\sigma^2} \sim \chi^2_{n-(p+1)}$.
- 3 $\hat{\beta}$ et $\widehat{\sigma^2}$ sont indépendantes.

- Soit $\hat{\varepsilon} = \mathbf{Y} - \hat{\mathbf{Y}}$ le vecteur des résidus et $\widehat{\sigma}^2$ l'estimateur de σ^2 défini par

$$\widehat{\sigma}^2 = \frac{\|\hat{\varepsilon}\|^2}{n - (p + 1)}.$$

Proposition

- 1 $\hat{\beta}$ est un vecteur gaussien d'espérance β et de matrice de variance-covariance $\sigma^2(\mathbf{X}'\mathbf{X})^{-1}$.
- 2 $(n - (p + 1))\frac{\widehat{\sigma}^2}{\sigma^2} \sim \chi^2_{n-(p+1)}$.
- 3 $\hat{\beta}$ et $\widehat{\sigma}^2$ sont indépendantes.

- Soit $\hat{\varepsilon} = \mathbf{Y} - \hat{\mathbf{Y}}$ le vecteur des résidus et $\widehat{\sigma^2}$ l'estimateur de σ^2 défini par

$$\widehat{\sigma^2} = \frac{\|\hat{\varepsilon}\|^2}{n - (p + 1)}.$$

Proposition

- 1 $\hat{\beta}$ est un vecteur gaussien d'espérance β et de matrice de variance-covariance $\sigma^2(\mathbf{X}'\mathbf{X})^{-1}$.
- 2 $(n - (p + 1))\frac{\widehat{\sigma^2}}{\sigma^2} \sim \chi^2_{n-(p+1)}$.
- 3 $\hat{\beta}$ et $\widehat{\sigma^2}$ sont indépendantes.

Corollaire

On note $\widehat{\sigma}_j^2 = \widehat{\sigma}^2 [\mathbb{X}'\mathbb{X}]_{jj}^{-1}$ pour $j = 0, \dots, p$. On a

$$\forall j = 0, \dots, p, \quad \frac{\hat{\beta}_j - \beta_j}{\widehat{\sigma}_j} \sim \mathcal{T}(n - (p + 1)).$$

On déduit de ce corollaire :

- des intervalles de confiance de niveau $1 - \alpha$ pour β_j .
- des procédures de test pour des hypothèses du genre $H_0 : \beta_j = 0$ contre $H_1 : \beta_j \neq 0$.

Corollaire

On note $\widehat{\sigma}_j^2 = \widehat{\sigma}^2 [\mathbb{X}'\mathbb{X}]_{jj}^{-1}$ pour $j = 0, \dots, p$. On a

$$\forall j = 0, \dots, p, \quad \frac{\hat{\beta}_j - \beta_j}{\widehat{\sigma}_j} \sim \mathcal{T}(n - (p + 1)).$$

On déduit de ce corollaire :

- des intervalles de confiance de niveau $1 - \alpha$ pour β_j .
- des procédures de test pour des hypothèses du genre $H_0 : \beta_j = 0$ contre $H_1 : \beta_j \neq 0$.

- On dispose d'une nouvelle observation $x_{n+1} = (x_{n+1,1}, \dots, x_{n+1,p})$ et on souhaite prédire la valeur $y_{n+1} = x'_{n+1}\beta$ associée à cette nouvelle observation.

- Un estimateur (naturel) de y_{n+1} est $\hat{y}_{n+1} = x'_{n+1}\hat{\beta}$.
- Un intervalle de confiance de niveau $1 - \alpha$ pour y_{n+1} est donné par

$$\left[\hat{y}_{n+1} \pm t_{n-(p+1)}(\alpha/2)\hat{\sigma} \sqrt{x'_{n+1}(\mathbb{X}'\mathbb{X})^{-1}x_{n+1} + 1} \right].$$

- On dispose d'une nouvelle observation $x_{n+1} = (x_{n+1,1}, \dots, x_{n+1,p})$ et on souhaite prédire la valeur $y_{n+1} = x'_{n+1}\beta$ associée à cette nouvelle observation.

- Un estimateur (naturel) de y_{n+1} est $\hat{y}_{n+1} = x'_{n+1}\hat{\beta}$.
- Un intervalle de confiance de niveau $1 - \alpha$ pour y_{n+1} est donné par

$$\left[\hat{y}_{n+1} \pm t_{n-(p+1)}(\alpha/2)\hat{\sigma} \sqrt{x'_{n+1}(\mathbb{X}'\mathbb{X})^{-1}x_{n+1} + 1} \right].$$

- On dispose d'une nouvelle observation $x_{n+1} = (x_{n+1,1}, \dots, x_{n+1,p})$ et on souhaite prédire la valeur $y_{n+1} = x'_{n+1}\beta$ associée à cette nouvelle observation.

- Un estimateur (naturel) de y_{n+1} est $\hat{y}_{n+1} = x'_{n+1}\hat{\beta}$.
- Un intervalle de confiance de niveau $1 - \alpha$ pour y_{n+1} est donné par

$$\left[\hat{y}_{n+1} \pm t_{n-(p+1)}(\alpha/2)\hat{\sigma} \sqrt{x'_{n+1}(\mathbb{X}'\mathbb{X})^{-1}x_{n+1} + 1} \right].$$

Exemple de l'ozone

- On considère le modèle de régression multiple :

$$\text{MaxO3} = \beta_0 + \beta_1 T_{12} + \beta_2 T_{15} + \beta_3 N_{12} + \beta_4 V_{12} + \beta_5 \text{MaxO3v} + \varepsilon.$$

```
> reg.multi <- lm(maxO3~T12+T15+Ne12+Vx12+maxO3v,data=donnees)
> summary(reg.multi)
```

Call:

```
lm(formula = maxO3 ~ T12 + T15 + Ne12 + Vx12 + maxO3v, data = donnees)
```

Residuals:

Min	1Q	Median	3Q	Max
-54.216	-9.446	-0.896	8.007	41.186

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	3.04498	13.01591	0.234	0.8155
T12	2.47747	1.09257	2.268	0.0254 *
T15	0.63177	0.96382	0.655	0.5136
Ne12	-1.83560	0.89439	-2.052	0.0426 *
Vx12	1.33295	0.58168	2.292	0.0239 *
maxO3v	0.34215	0.05989	5.713	1.03e-07 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 14.58 on 106 degrees of freedom

Multiple R-squared: 0.7444, Adjusted R-squared: 0.7324

F-statistic: 61.75 on 5 and 106 DF, p-value: < 2.2e-16

- 1 Introduction
- 2 La régression linéaire simple
 - Ajustement par moindres carrés
 - Propriétés des estimateurs
 - Quelques lois de probabilités
 - Inférence statistique
- 3 La régression multiple
 - Notations et modélisation
 - Estimateur des moindres carrés
 - Propriétés statistiques
- 4 Validation et choix de modèles
 - Résidus et coefficient de détermination
 - Tests entre modèles emboîtés
- 5 Analyse de la variance
 - Modèle à un facteur
 - ANOVA à deux facteurs
 - Sélection de modèles
- 6 Bibliographie

- Le modèle linéaire repose sur certaines hypothèses (normalité des erreurs par exemple), comment les vérifier ?
- A partir de p variables explicatives, il est possible de construire (au moins) 2^p modèles linéaires, comment choisir le "meilleur" sous-ensemble de variables à inclure dans le modèle ?

- Le modèle linéaire repose sur certaines hypothèses (normalité des erreurs par exemple), comment les vérifier ?
- A partir de p variables explicatives, il est possible de construire (au moins) 2^p modèles linéaires, comment choisir le "meilleur" sous-ensemble de variables à inclure dans le modèle ?

- 1 Introduction
- 2 La régression linéaire simple
 - Ajustement par moindres carrés
 - Propriétés des estimateurs
 - Quelques lois de probabilités
 - Inférence statistique
- 3 La régression multiple
 - Notations et modélisation
 - Estimateur des moindres carrés
 - Propriétés statistiques
- 4 **Validation et choix de modèles**
 - **Résidus et coefficient de détermination**
 - Tests entre modèles emboîtés
- 5 Analyse de la variance
 - Modèle à un facteur
 - ANOVA à deux facteurs
 - Sélection de modèles
- 6 Bibliographie

Analyse des résidus

- Le modèle linéaire

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

- Les erreurs ε sont inconnues. On les estime par $\hat{\varepsilon}_i = Y_i - \hat{Y}_i$.

Propriété

$$\mathbf{E}(\hat{\varepsilon}_i) = 0 \quad \text{et} \quad \mathbf{V}(\hat{\varepsilon}_i) = \sigma^2(1 - \mathbf{P}_{\mathcal{F}(\mathbb{X})}).$$

Conséquence

Un moyen de vérifier l'hypothèse de normalité des erreurs est de comparer la distribution des **résidus studentisés**

$$\frac{\hat{\varepsilon}_i}{\hat{\sigma} \sqrt{1 - h_{ii}}}$$

à la distribution gaussienne centrée réduite.

- Le modèle linéaire

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

- Les erreurs ε sont inconnues. On les estime par $\hat{\varepsilon}_i = Y_i - \hat{Y}_i$.

Propriété

$$\mathbf{E}(\hat{\varepsilon}_i) = 0 \quad \text{et} \quad \mathbf{V}(\hat{\varepsilon}_i) = \sigma^2(1 - \mathbf{P}_{\mathcal{F}(\mathbb{X})}).$$

Conséquence

Un moyen de vérifier l'hypothèse de normalité des erreurs est de comparer la distribution des **résidus studentisés**

$$\frac{\hat{\varepsilon}_i}{\hat{\sigma} \sqrt{1 - h_{ii}}}$$

à la distribution gaussienne centrée réduite.

- Le modèle linéaire

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

- Les erreurs ε sont inconnues. On les estime par $\hat{\varepsilon}_i = Y_i - \hat{Y}_i$.

Propriété

$$\mathbf{E}(\hat{\varepsilon}_i) = 0 \quad \text{et} \quad \mathbf{V}(\hat{\varepsilon}_i) = \sigma^2(1 - \mathbf{P}_{\mathcal{F}(\mathbb{X})}).$$


Conséquence

Un moyen de vérifier l'hypothèse de normalité des erreurs est de comparer la distribution des **résidus studentisés**

$$\frac{\hat{\varepsilon}_i}{\hat{\sigma} \sqrt{1 - h_{ii}}}$$


à la distribution gaussienne centrée réduite.

Tracé d'un index plot



L'analyse de ce type de graphique est généralement accompagné d'un test d'adéquation des résidus à la loi normale (test de Shapiro-Wilks par exemple).

Tracé d'un index plot



L'analyse de ce type de graphique est généralement accompagné d'un test d'adéquation des résidus à la loi normale (test de Shapiro-Wilks par exemple).

Le coefficient de détermination R^2

Equation d'analyse de la variance

On a d'après Pythagore :

$$\begin{aligned}\|Y - \bar{y}\mathbf{1}\|^2 &= \|\hat{Y} - \bar{y}\mathbf{1}\|^2 + \|\hat{\varepsilon}\|^2 \\ SCT &= SCE + SCR\end{aligned}$$

Coefficient de détermination R^2

$$R^2 = \frac{\text{V. expliquée par le modèle}}{\text{V. totale}} = \frac{\|\hat{Y} - \bar{y}\mathbf{1}\|^2}{\|Y - \bar{y}\mathbf{1}\|^2} = \frac{SCE}{SCT}.$$

- $0 \leq R^2 \leq 1$.
- Si $R^2 = 1$, la variabilité est entièrement expliquée par le modèle.
- Si $R^2 = 0$, la variabilité se trouve dans la résiduelle (ce qui n'est pas très bon...).

Le coefficient de détermination R^2

Equation d'analyse de la variance

On a d'après Pythagore :

$$\begin{aligned}\|Y - \bar{y}\mathbf{1}\|^2 &= \|\hat{Y} - \bar{y}\mathbf{1}\|^2 + \|\hat{\varepsilon}\|^2 \\ SCT &= SCE + SCR\end{aligned}$$

Coefficient de détermination R^2

$$R^2 = \frac{\text{V. expliquée par le modèle}}{\text{V. totale}} = \frac{\|\hat{Y} - \bar{y}\mathbf{1}\|^2}{\|Y - \bar{y}\mathbf{1}\|^2} = \frac{SCE}{SCT}.$$

- $0 \leq R^2 \leq 1$.
- Si $R^2 = 1$, la variabilité est entièrement expliquée par le modèle.
- Si $R^2 = 0$, la variabilité se trouve dans la résiduelle (ce qui n'est pas très bon...).

Le coefficient de détermination R^2

Equation d'analyse de la variance

On a d'après Pythagore :

$$\begin{aligned}\|Y - \bar{y}\mathbf{1}\|^2 &= \|\hat{Y} - \bar{y}\mathbf{1}\|^2 + \|\hat{\varepsilon}\|^2 \\ SCT &= SCE + SCR\end{aligned}$$

Coefficient de détermination R^2

$$R^2 = \frac{\text{V. expliquée par le modèle}}{\text{V. totale}} = \frac{\|\hat{Y} - \bar{y}\mathbf{1}\|^2}{\|Y - \bar{y}\mathbf{1}\|^2} = \frac{SCE}{SCT}.$$

- $0 \leq R^2 \leq 1$.
- Si $R^2 = 1$, la variabilité est entièrement expliquée par le modèle.
- Si $R^2 = 0$, la variabilité se trouve dans la résiduelle (ce qui n'est pas très bon...).

- 1 Introduction
- 2 La régression linéaire simple
 - Ajustement par moindres carrés
 - Propriétés des estimateurs
 - Quelques lois de probabilités
 - Inférence statistique
- 3 La régression multiple
 - Notations et modélisation
 - Estimateur des moindres carrés
 - Propriétés statistiques
- 4 **Validation et choix de modèles**
 - Résidus et coefficient de détermination
 - **Tests entre modèles emboîtés**
- 5 Analyse de la variance
 - Modèle à un facteur
 - ANOVA à deux facteurs
 - Sélection de modèles
- 6 Bibliographie

Le test de Fisher global

- Modèle

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2).$$

- Hypothèses

$$H_0 : \beta_1 = \dots = \beta_p = 0 \quad \text{contre} \quad H_1 : \exists j \in \{1, \dots, p\} \beta_j \neq 0.$$

- Sous H_0 ,

$$F = \frac{R^2}{1 - R^2} \frac{n - (p + 1)}{p} \sim \mathcal{F}_{p, n - (p + 1)}.$$

- On rejette H_0 si $F_{obs} > F_{p, n - (p + 1)}(1 - \alpha)$.

Le test de Fisher global

- Modèle

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2).$$

- Hypothèses

$$H_0 : \beta_1 = \dots = \beta_p = 0 \quad \text{contre} \quad H_1 : \exists j \in \{1, \dots, p\} \beta_j \neq 0.$$

- Sous H_0 ,

$$F = \frac{R^2}{1 - R^2} \frac{n - (p + 1)}{p} \sim \mathcal{F}_{p, n - (p + 1)}.$$

- On rejette H_0 si $F_{obs} > F_{p, n - (p + 1)}(1 - \alpha)$.

Le test de Fisher global

- Modèle

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2).$$

- Hypothèses

$$H_0 : \beta_1 = \dots = \beta_p = 0 \quad \text{contre} \quad H_1 : \exists j \in \{1, \dots, p\} \beta_j \neq 0.$$

- Sous H_0 ,

$$F = \frac{R^2}{1 - R^2} \frac{n - (p + 1)}{p} \sim \mathcal{F}_{p, n - (p + 1)}.$$

- On rejette H_0 si $F_{obs} > F_{p, n - (p + 1)}(1 - \alpha)$.

- On souhaite tester le modèle \mathcal{M}_1

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2)$$

contre le modèle \mathcal{M}_0

$$Y_i = \beta_q x_{iq} + \dots + \beta_p x_{ip} + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2).$$

- Cela revient à tester si les q premiers coefficients de \mathcal{M}_1 sont nuls

$$H_0 : \beta_0 = \dots = \beta_{q-1} = 0 \quad \text{contre} \quad H_1 : \exists j \in \{0, \dots, q-1\} \beta_j \neq 0.$$

On parle de test entre modèles emboîtés car \mathcal{M}_0 est un cas particulier de \mathcal{M}_1 .

- On souhaite tester le modèle \mathcal{M}_1

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2)$$

contre le modèle \mathcal{M}_0

$$Y_i = \beta_q x_{iq} + \dots + \beta_p x_{ip} + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2).$$

- Cela revient à tester si les q premiers coefficients de \mathcal{M}_1 sont nuls

$$H_0 : \beta_0 = \dots = \beta_{q-1} = 0 \quad \text{contre} \quad H_1 : \exists j \in \{0, \dots, q-1\} \beta_j \neq 0.$$

On parle de test entre modèles emboîtés car \mathcal{M}_0 est un cas particulier de \mathcal{M}_1 .

- On souhaite tester le modèle \mathcal{M}_1

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2)$$

contre le modèle \mathcal{M}_0

$$Y_i = \beta_q x_{iq} + \dots + \beta_p x_{ip} + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2).$$

- Cela revient à tester si les q premiers coefficients de \mathcal{M}_1 sont nuls

$$H_0 : \beta_0 = \dots = \beta_{q-1} = 0 \quad \text{contre} \quad H_1 : \exists j \in \{0, \dots, q-1\} \beta_j \neq 0.$$

On parle de test entre modèles emboîtés car \mathcal{M}_0 est un cas particulier de \mathcal{M}_1 .

Idée

On note :

- $\mathcal{F}(\mathbb{X})$ le s.e.v de dimension $p + 1$ engendré par les colonnes de \mathbb{X} et $\hat{\mathbb{Y}}$ la projection de \mathbb{Y} sur \mathcal{F} .
- $\mathcal{F}_0(\mathbb{X})$ le s.e.v de dimension $p - q + 1$ engendré par les $p - q + 1$ colonnes de \mathbb{X} et $\hat{\mathbb{Y}}_0$ la projection de \mathbb{Y} sur \mathcal{F}_0 .
- $\mathcal{F}_0(\mathbb{X}) \subset \mathcal{F}(\mathbb{X})$, l'idée consiste à regarder si $\hat{\mathbb{Y}}_0$ est "proche" de $\hat{\mathbb{Y}}$:
 - si $\hat{\mathbb{Y}}_0 \approx \hat{\mathbb{Y}}$, on choisira le modèle \mathcal{M}_0 (on acceptera H_0).
 - Sinon, on choisira le modèle \mathcal{M}_1 (on rejettera H_0).

Idée

On note :

- $\mathcal{F}(\mathbb{X})$ le s.e.v de dimension $p + 1$ engendré par les colonnes de \mathbb{X} et $\hat{\mathbb{Y}}$ la projection de \mathbb{Y} sur \mathcal{F} .
- $\mathcal{F}_0(\mathbb{X})$ le s.e.v de dimension $p - q + 1$ engendré par les $p - q + 1$ colonnes de \mathbb{X} et $\hat{\mathbb{Y}}_0$ la projection de \mathbb{Y} sur \mathcal{F}_0 .
- $\mathcal{F}_0(\mathbb{X}) \subset \mathcal{F}(\mathbb{X})$, l'idée consiste à regarder si $\hat{\mathbb{Y}}_0$ est "proche" de $\hat{\mathbb{Y}}$:
 - si $\hat{\mathbb{Y}}_0 \approx \hat{\mathbb{Y}}$, on choisira le modèle \mathcal{M}_0 (on acceptera H_0).
 - Sinon, on choisira le modèle \mathcal{M}_1 (on rejettera H_0).

Idée


On note :

- $\mathcal{F}(\mathbb{X})$ le s.e.v de dimension $p + 1$ engendré par les colonnes de \mathbb{X} et $\hat{\mathbb{Y}}$ la projection de \mathbb{Y} sur \mathcal{F} .
- $\mathcal{F}_0(\mathbb{X})$ le s.e.v de dimension $p - q + 1$ engendré par les $p - q + 1$ colonnes de \mathbb{X} et $\hat{\mathbb{Y}}_0$ la projection de \mathbb{Y} sur \mathcal{F}_0 .
- $\mathcal{F}_0(\mathbb{X}) \subset \mathcal{F}(\mathbb{X})$, l'idée consiste à regarder si $\hat{\mathbb{Y}}_0$ est "proche" de $\hat{\mathbb{Y}}$:
 - si $\hat{\mathbb{Y}}_0 \approx \hat{\mathbb{Y}}$, on choisira le modèle \mathcal{M}_0 (on acceptera H_0).
 - Sinon, on choisira le modèle \mathcal{M}_1 (on rejettera H_0).

Idée

On note :

- $\mathcal{F}(\mathbb{X})$ le s.e.v de dimension $p + 1$ engendré par les colonnes de \mathbb{X} et $\hat{\mathbb{Y}}$ la projection de \mathbb{Y} sur \mathcal{F} .
- $\mathcal{F}_0(\mathbb{X})$ le s.e.v de dimension $p - q + 1$ engendré par les $p - q + 1$ colonnes de \mathbb{X} et $\hat{\mathbb{Y}}_0$ la projection de \mathbb{Y} sur \mathcal{F}_0 .
- $\mathcal{F}_0(\mathbb{X}) \subset \mathcal{F}(\mathbb{X})$, l'idée consiste à regarder si $\hat{\mathbb{Y}}_0$ est "proche" de $\hat{\mathbb{Y}}$:
 - si $\hat{\mathbb{Y}}_0 \approx \hat{\mathbb{Y}}$, on choisira le modèle \mathcal{M}_0 (on acceptera H_0).
 - Sinon, on choisira le modèle \mathcal{M}_1 (on rejettera H_0).



Cochran...

Sous H_0 ,

$$F = \frac{\|\hat{Y}_0 - \hat{Y}\|^2/q}{\|Y - \hat{Y}\|^2/(n - (p + 1))} \sim \mathcal{F}_{q, n - (p + 1)}.$$

- On rejette H_0 si $F_{obs} > F_{q, n - (p + 1)}(1 - \alpha)$.

Cochran...

Sous H_0 ,

$$F = \frac{\|\hat{Y}_0 - \hat{Y}\|^2/q}{\|Y - \hat{Y}\|^2/(n - (p + 1))} \sim \mathcal{F}_{q, n - (p + 1)}.$$

- On rejette H_0 si $F_{obs} > F_{q, n - (p + 1)}(1 - \alpha)$.

Exemple

- On considère le modèle

$$\text{MaxO3} = \beta_0 + \beta_1 T_{12} + \beta_2 T_{15} + \beta_3 N_{12} + \beta_4 V_{12} + \beta_5 \text{MaxO3v} + \varepsilon$$

et on teste $H_0 : \beta_2 = \beta_3 = \beta_4 = 0$ contre $H_1 : \exists j \in \{2, 3, 4\} : \beta_j \neq 0$.

```
> reg0 <- lm(maxO3~T12+maxO3v,data=donnees)
> reg1 <- lm(maxO3~T12+T15+Ne12+Vx12+maxO3v,data=donnees)
> anova(reg0,reg1)
```

Analysis of Variance Table

Model 1: maxO3 ~ T12 + maxO3v

Model 2: maxO3 ~ T12 + T15 + Ne12 + Vx12 + maxO3v

	Res.Df	RSS	Df	Sum of Sq	F	Pr(>F)
1	109	26348				
2	106	22540	3	3808.4	5.97	0.000844 ***

$pc = 0.000844 > 0.05$, on rejette H_0 et on conserve le modèle à 5 variables par rapport au modèle à 2 variables.

Exemple

- On considère le modèle

$$\text{MaxO3} = \beta_0 + \beta_1 T_{12} + \beta_2 T_{15} + \beta_3 N_{12} + \beta_4 V_{12} + \beta_5 \text{MaxO3v} + \varepsilon$$

et on teste $H_0 : \beta_2 = \beta_3 = \beta_4 = 0$ contre $H_1 : \exists j \in \{2, 3, 4\} : \beta_j \neq 0$.

```
> reg0 <- lm(max03~T12+max03v,data=donnees)
> reg1 <- lm(max03~T12+T15+Ne12+Vx12+max03v,data=donnees)
> anova(reg0,reg1)
```

Analysis of Variance Table

Model 1: max03 ~ T12 + max03v

Model 2: max03 ~ T12 + T15 + Ne12 + Vx12 + max03v

	Res.Df	RSS	Df	Sum of Sq	F	Pr(>F)
1	109	26348				
2	106	22540	3	3808.4	5.97	0.000844 ***

$pc = 0.000844 > 0.05$, on rejette H_0 et on conserve le modèle à 5 variables par rapport au modèle à 2 variables.

Exemple

- On considère le modèle

$$\text{MaxO3} = \beta_0 + \beta_1 T_{12} + \beta_2 T_{15} + \beta_3 N_{12} + \beta_4 V_{12} + \beta_5 \text{MaxO3v} + \varepsilon$$

et on teste $H_0 : \beta_2 = \beta_3 = \beta_4 = 0$ contre $H_1 : \exists j \in \{2, 3, 4\} : \beta_j \neq 0$.

```
> reg0 <- lm(max03~T12+max03v,data=donnees)
> reg1 <- lm(max03~T12+T15+Ne12+Vx12+max03v,data=donnees)
> anova(reg0,reg1)
```

Analysis of Variance Table

Model 1: max03 ~ T12 + max03v

Model 2: max03 ~ T12 + T15 + Ne12 + Vx12 + max03v

	Res.Df	RSS	Df	Sum of Sq	F	Pr(>F)
1	109	26348				
2	106	22540	3	3808.4	5.97	0.000844 ***

$pc = 0.000844 > 0.05$, on rejette H_0 et on conserve le modèle à 5 variables par rapport au modèle à 2 variables.

- 1 Introduction
- 2 La régression linéaire simple
 - Ajustement par moindres carrés
 - Propriétés des estimateurs
 - Quelques lois de probabilités
 - Inférence statistique
- 3 La régression multiple
 - Notations et modélisation
 - Estimateur des moindres carrés
 - Propriétés statistiques
- 4 Validation et choix de modèles
 - Résidus et coefficient de détermination
 - Tests entre modèles emboîtés
- 5 Analyse de la variance
 - Modèle à un facteur
 - ANOVA à deux facteurs
 - Sélection de modèles

- 6 Bibliographie

- 1 Introduction
- 2 La régression linéaire simple
 - Ajustement par moindres carrés
 - Propriétés des estimateurs
 - Quelques lois de probabilités
 - Inférence statistique
- 3 La régression multiple
 - Notations et modélisation
 - Estimateur des moindres carrés
 - Propriétés statistiques
- 4 Validation et choix de modèles
 - Résidus et coefficient de détermination
 - Tests entre modèles emboîtés
- 5 Analyse de la variance
 - **Modèle à un facteur**
 - ANOVA à deux facteurs
 - Sélection de modèles
- 6 Bibliographie

- Jusqu'à présent, les variables explicatives étaient quantitatives.
- Comment généraliser le modèle linéaire à des variables explicatives qualitatives.

Exemple

Comment expliquer la variable `max03` par la variable `vent` (ou `pluie`) ?

- Jusqu'à présent, les variables explicatives étaient quantitatives.
- Comment généraliser le modèle linéaire à des variables explicatives qualitatives.

Exemple

Comment expliquer la variable `max03` par la variable `vent` (ou `pluie`) ?

Le modèle

- Y variable à expliquer (quantitative) et X variable explicative (qualitative) à J modalités, niveaux ou facteurs.
- On dispose de n observations. Soit n_j le nombre d'individus pour lesquels on a observé la $j^{\text{ème}}$ modalité de X .
- On ordonne les individus selon les modalités de X :

Y	Y_{11}	...	Y_{1n_1}	Y_{21}	Y_{J,n_J}
X	M_1	...	M_1	M_2	M_J

Ecriture 1

Le modèle d'ANOVA à un facteur s'écrit

$$Y_{ij} = \alpha_j + \varepsilon_{ij}, \quad i = 1, \dots, n_j, \quad j = 1, \dots, J,$$

avec ε_{ij} i.i.d. et de loi $\mathcal{N}(0, \sigma^2)$.

- Y variable à expliquer (quantitative) et X variable explicative (qualitative) à J modalités, niveaux ou facteurs.
- On dispose de n observations. Soit n_j le nombre d'individus pour lesquels on a observé la $j^{\text{ème}}$ modalité de X .
- On ordonne les individus selon les modalités de X :

Y	Y_{11}	...	Y_{1n_1}	Y_{21}	Y_{J,n_J}
X	M_1	...	M_1	M_2	M_J

Ecriture 1

Le modèle d'ANOVA à un facteur s'écrit

$$Y_{ij} = \alpha_j + \varepsilon_{ij}, \quad i = 1, \dots, n_j, \quad j = 1, \dots, J,$$

avec ε_{ij} i.i.d. et de loi $\mathcal{N}(0, \sigma^2)$.

Écriture matricielle

- n observations $(x_1, Y_1), \dots, (x_n, Y_n)$ et on écrit le modèle

$$Y_i = \beta_1 \mathbf{1}_{x_i=M_1} + \beta_2 \mathbf{1}_{x_i=M_2} + \dots + \beta_J \mathbf{1}_{x_i=M_J} + \varepsilon_i$$

où ε_i i.i.d. de loi $\mathcal{N}(0, \sigma^2)$.

- Si on note

$$\mathbb{Y} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}, \mathbb{X} = \begin{pmatrix} \mathbf{1}_{x_1=M_1} & \dots & \mathbf{1}_{x_1=M_J} \\ \vdots & & \vdots \\ \mathbf{1}_{x_n=M_1} & \dots & \mathbf{1}_{x_n=M_J} \end{pmatrix}, \beta = \begin{pmatrix} \beta_1 \\ \vdots \\ \beta_J \end{pmatrix}, \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}.$$

On a alors l'écriture matricielle

$$\mathbb{Y} = \mathbb{X}\beta + \varepsilon.$$

- Il s'agit d'un modèle de régression multiple pour une matrice \mathbb{X} particulière.
- Tout ce qui a été vu dans les sections précédentes (estimation, tests, résidus...) peut s'appliquer à ce nouveau modèle.

Écriture matricielle

- n observations $(x_1, Y_1), \dots, (x_n, Y_n)$ et on écrit le modèle

$$Y_i = \beta_1 \mathbf{1}_{x_i=M_1} + \beta_2 \mathbf{1}_{x_i=M_2} + \dots + \beta_J \mathbf{1}_{x_i=M_J} + \varepsilon_i$$

où ε_i i.i.d. de loi $\mathcal{N}(0, \sigma^2)$.

- Si on note

$$\mathbb{Y} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}, \mathbb{X} = \begin{pmatrix} \mathbf{1}_{x_1=M_1} & \dots & \mathbf{1}_{x_1=M_J} \\ \vdots & & \vdots \\ \mathbf{1}_{x_n=M_1} & \dots & \mathbf{1}_{x_n=M_J} \end{pmatrix}, \beta = \begin{pmatrix} \beta_1 \\ \vdots \\ \beta_J \end{pmatrix}, \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}.$$

On a alors l'écriture matricielle

$$\mathbb{Y} = \mathbb{X}\beta + \varepsilon.$$

- Il s'agit d'un modèle de régression multiple pour une matrice \mathbb{X} particulière.
- Tout ce qui a été vu dans les sections précédentes (estimation, tests, résidus...) peut s'appliquer à ce nouveau modèle.

Écriture matricielle

- n observations $(x_1, Y_1), \dots, (x_n, Y_n)$ et on écrit le modèle

$$Y_i = \beta_1 \mathbf{1}_{x_i=M_1} + \beta_2 \mathbf{1}_{x_i=M_2} + \dots + \beta_J \mathbf{1}_{x_i=M_J} + \varepsilon_i$$

où ε_i i.i.d. de loi $\mathcal{N}(0, \sigma^2)$.

- Si on note

$$\mathbb{Y} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}, \mathbb{X} = \begin{pmatrix} \mathbf{1}_{x_1=M_1} & \dots & \mathbf{1}_{x_1=M_J} \\ \vdots & & \vdots \\ \mathbf{1}_{x_n=M_1} & \dots & \mathbf{1}_{x_n=M_J} \end{pmatrix}, \beta = \begin{pmatrix} \beta_1 \\ \vdots \\ \beta_J \end{pmatrix}, \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}.$$

On a alors l'écriture matricielle

$$\mathbb{Y} = \mathbb{X}\beta + \varepsilon.$$

- Il s'agit d'un modèle de régression multiple pour une matrice \mathbb{X} particulière.
- Tout ce qui a été vu dans les sections précédentes (estimation, tests, résidus...) peut s'appliquer à ce nouveau modèle.

Écriture matricielle

- n observations $(x_1, Y_1), \dots, (x_n, Y_n)$ et on écrit le modèle

$$Y_i = \beta_1 \mathbf{1}_{x_i=M_1} + \beta_2 \mathbf{1}_{x_i=M_2} + \dots + \beta_J \mathbf{1}_{x_i=M_J} + \varepsilon_i$$

où ε_i i.i.d. de loi $\mathcal{N}(0, \sigma^2)$.

- Si on note

$$\mathbb{Y} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}, \mathbb{X} = \begin{pmatrix} \mathbf{1}_{x_1=M_1} & \dots & \mathbf{1}_{x_1=M_J} \\ \vdots & & \vdots \\ \mathbf{1}_{x_n=M_1} & \dots & \mathbf{1}_{x_n=M_J} \end{pmatrix}, \beta = \begin{pmatrix} \beta_1 \\ \vdots \\ \beta_J \end{pmatrix}, \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}.$$

On a alors l'écriture matricielle

$$\mathbb{Y} = \mathbb{X}\beta + \varepsilon.$$

- Il s'agit d'un modèle de régression multiple pour une matrice \mathbb{X} particulière.
- Tout ce qui a été vu dans les sections précédentes (estimation, tests, résidus...) peut s'appliquer à ce nouveau modèle.

Un exemple

```
> reg <- lm(max03~vent,data=donnees)
> reg
Call:
lm(formula = max03 ~ vent, data = donnees)
Coefficients:
(Intercept)      ventNord      ventOuest      ventSud
    105.600         -19.471         -20.900         -3.076
```

Remarque importante

- La fonction renvoie une estimation pour une constante et pas d'estimation pour la modalité Est.
- Le modèle ajusté est le suivant :

$$Y_i = \beta_0 + \beta_1 \mathbf{1}_{x_i=Est} + \beta_2 \mathbf{1}_{x_i=Nord} + \beta_3 \mathbf{1}_{x_i=Ouest} + \beta_4 \mathbf{1}_{x_i=Sud} + \varepsilon_i$$

muni de la contrainte $\beta_1 = 0$.

- Une telle écriture est moins intuitive mais donne lieu à d'importantes généralisations.

Un exemple

```
> reg <- lm(max03~vent,data=donnees)
> reg
Call:
lm(formula = max03 ~ vent, data = donnees)
Coefficients:
(Intercept)      ventNord      ventOuest      ventSud
    105.600         -19.471         -20.900          -3.076
```

Remarque importante

- La fonction renvoie une estimation pour une constante et pas d'estimation pour la modalité Est.
- Le modèle ajusté est le suivant :

$$Y_i = \beta_0 + \beta_1 \mathbf{1}_{x_i=Est} + \beta_2 \mathbf{1}_{x_i=Nord} + \beta_3 \mathbf{1}_{x_i=Ouest} + \beta_4 \mathbf{1}_{x_i=Sud} + \varepsilon_i$$

muni de la contrainte $\beta_1 = 0$.

- Une telle écriture est moins intuitive mais donne lieu à d'importantes généralisations.

Un exemple

```
> reg <- lm(max03~vent,data=donnees)
> reg
Call:
lm(formula = max03 ~ vent, data = donnees)
Coefficients:
(Intercept)      ventNord      ventOuest      ventSud
  105.600        -19.471        -20.900         -3.076
```

Remarque importante

- La fonction renvoie une estimation pour une constante et pas d'estimation pour la modalité Est.
- Le modèle ajusté est le suivant :

$$Y_i = \beta_0 + \beta_1 \mathbf{1}_{x_i=Est} + \beta_2 \mathbf{1}_{x_i=Nord} + \beta_3 \mathbf{1}_{x_i=Ouest} + \beta_4 \mathbf{1}_{x_i=Sud} + \varepsilon_i$$

muni de la contrainte $\beta_1 = 0$.

- Une telle écriture est moins intuitive mais donne lieu à d'importantes généralisations.

Un exemple

```
> reg <- lm(max03~vent,data=donnees)
> reg
Call:
lm(formula = max03 ~ vent, data = donnees)
Coefficients:
(Intercept)      ventNord      ventOuest      ventSud
  105.600        -19.471        -20.900         -3.076
```

Remarque importante

- La fonction renvoie une estimation pour une constante et pas d'estimation pour la modalité Est.
- Le modèle ajusté est le suivant :

$$Y_i = \beta_0 + \beta_1 \mathbf{1}_{x_i=Est} + \beta_2 \mathbf{1}_{x_i=Nord} + \beta_3 \mathbf{1}_{x_i=Ouest} + \beta_4 \mathbf{1}_{x_i=Sud} + \varepsilon_i$$

muni de la contrainte $\beta_1 = 0$.

- Une telle écriture est moins intuitive mais donne lieu à d'importantes généralisations.

Test de "significativité" du facteur

- On souhaite savoir si la variable X a une influence sur Y : la direction du vent a-t-elle une influence sur la concentration en ozone ?
- On teste donc $H_0 : \beta_1 = \dots = \beta_4 = 0$ contre $H_1 : \exists j \in \{1, \dots, 4\} : \beta_j \neq 0$ pour le modèle

$$Y_i = \beta_0 + \beta_1 \mathbf{1}_{x_i=Est} + \beta_2 \mathbf{1}_{x_i=Nord} + \beta_3 \mathbf{1}_{x_i=Ouest} + \beta_4 \mathbf{1}_{x_i=Sud} + \varepsilon_i.$$

- Il suffit de reprendre le test de Fisher vu dans la partie précédente.

```
> anova(reg)
Analysis of Variance Table

Response: maxO3
          Df Sum Sq Mean Sq F value Pr(>F)
vent       3   7586  2528.69   3.3881 0.02074 *
Residuals 108  80606   746.35
```

$pc = 0.02074 < 0.05$, on rejette H_0 . On peut conclure au risque $\alpha = 5\%$ que la direction du vent a une influence sur la concentration en ozone.

Test de "significativité" du facteur

- On souhaite savoir si la variable X a une influence sur Y : la direction du vent a-t-elle un influence sur la concentration en ozone ?
- On teste donc $H_0 : \beta_1 = \dots = \beta_4 = 0$ contre $H_1 : \exists j \in \{1, \dots, 4\} : \beta_j \neq 0$ pour le modèle

$$Y_i = \beta_0 + \beta_1 \mathbf{1}_{x_i=Est} + \beta_2 \mathbf{1}_{x_i=Nord} + \beta_3 \mathbf{1}_{x_i=Ouest} + \beta_4 \mathbf{1}_{x_i=Sud} + \varepsilon_i.$$

- Il suffit de reprendre le test de Fisher vu dans la partie précédente.

```
> anova(reg)
Analysis of Variance Table

Response: maxO3
          Df Sum Sq Mean Sq F value Pr(>F)
vent       3   7586  2528.69   3.3881 0.02074 *
Residuals 108  80606   746.35
```

$pc = 0.02074 < 0.05$, on rejette H_0 . On peut conclure au risque $\alpha = 5\%$ que la direction du vent à une influence sur la concentration en ozone.

Test de "significativité" du facteur

- On souhaite savoir si la variable X a une influence sur Y : la direction du vent a-t-elle un influence sur la concentration en ozone ?
- On teste donc $H_0 : \beta_1 = \dots = \beta_4 = 0$ contre $H_1 : \exists j \in \{1, \dots, 4\} : \beta_j \neq 0$ pour le modèle

$$Y_i = \beta_0 + \beta_1 \mathbf{1}_{x_i=Est} + \beta_2 \mathbf{1}_{x_i=Nord} + \beta_3 \mathbf{1}_{x_i=Ouest} + \beta_4 \mathbf{1}_{x_i=Sud} + \varepsilon_i.$$

- Il suffit de reprendre le test de Fisher vu dans la partie précédente.

```
> anova(reg)
Analysis of Variance Table

Response: maxO3
          Df Sum Sq Mean Sq F value Pr(>F)
vent       3   7586  2528.69   3.3881 0.02074 *
Residuals 108  80606   746.35
```

$pc = 0.02074 < 0.05$, on rejette H_0 . On peut conclure au risque $\alpha = 5\%$ que la direction du vent à une influence sur la concentration en ozone.

Test de "significativité" du facteur

- On souhaite savoir si la variable X a une influence sur Y : la direction du vent a-t-elle un influence sur la concentration en ozone ?
- On teste donc $H_0 : \beta_1 = \dots = \beta_4 = 0$ contre $H_1 : \exists j \in \{1, \dots, 4\} : \beta_j \neq 0$ pour le modèle

$$Y_i = \beta_0 + \beta_1 \mathbf{1}_{x_i=Est} + \beta_2 \mathbf{1}_{x_i=Nord} + \beta_3 \mathbf{1}_{x_i=Ouest} + \beta_4 \mathbf{1}_{x_i=Sud} + \varepsilon_i.$$

- Il suffit de reprendre le test de Fisher vu dans la partie précédente.

```
> anova(reg)
Analysis of Variance Table

Response: maxO3
          Df Sum Sq Mean Sq F value Pr(>F)
vent       3   7586  2528.69   3.3881 0.02074 *
Residuals 108  80606   746.35
```

$pc = 0.02074 < 0.05$, on rejette H_0 . On peut conclure au risque $\alpha = 5\%$ que la direction du vent à une influence sur la concentration en ozone.

Test de "significativité" du facteur

- On souhaite savoir si la variable X a une influence sur Y : la direction du vent a-t-elle un influence sur la concentration en ozone ?
- On teste donc $H_0 : \beta_1 = \dots = \beta_4 = 0$ contre $H_1 : \exists j \in \{1, \dots, 4\} : \beta_j \neq 0$ pour le modèle

$$Y_i = \beta_0 + \beta_1 \mathbf{1}_{x_i=Est} + \beta_2 \mathbf{1}_{x_i=Nord} + \beta_3 \mathbf{1}_{x_i=Ouest} + \beta_4 \mathbf{1}_{x_i=Sud} + \varepsilon_i.$$

- Il suffit de reprendre le test de Fisher vu dans la partie précédente.

```
> anova(reg)
Analysis of Variance Table

Response: maxO3
          Df Sum Sq Mean Sq F value Pr(>F)
vent       3   7586  2528.69   3.3881 0.02074 *
Residuals 108  80606   746.35
```

$pc = 0.02074 < 0.05$, on rejette H_0 . On peut conclure au risque $\alpha = 5\%$ que la direction du vent à une influence sur la concentration en ozone.

- 1 Introduction
- 2 La régression linéaire simple
 - Ajustement par moindres carrés
 - Propriétés des estimateurs
 - Quelques lois de probabilités
 - Inférence statistique
- 3 La régression multiple
 - Notations et modélisation
 - Estimateur des moindres carrés
 - Propriétés statistiques
- 4 Validation et choix de modèles
 - Résidus et coefficient de détermination
 - Tests entre modèles emboîtés
- 5 Analyse de la variance
 - Modèle à un facteur
 - ANOVA à deux facteurs
 - Sélection de modèles
- 6 Bibliographie

Un exemple

- On souhaite expliquer max03 par la direction du vent et la pluie.
- On dispose de n observations (x_i, Y_i) et on écrit le modèle

$$Y_i = \beta_0 + \beta_1 \mathbf{1}_{x_{i1}=\text{Est}} + \beta_2 \mathbf{1}_{x_{i1}=\text{Nord}} + \beta_3 \mathbf{1}_{x_{i1}=\text{Ouest}} + \beta_4 \mathbf{1}_{x_{i1}=\text{Sud}} \\ + \beta_5 \mathbf{1}_{x_{i2}=\text{pluie}} + \beta_6 \mathbf{1}_{x_{i2}=\text{Sec}} + \varepsilon$$

muni des contraintes $\beta_1 = 0$ et $\beta_5 = 0$.

```
> reg <- lm(max03~vent+pluie,data=donnees)
> reg
```

Call:

```
lm(formula = max03 ~ vent + pluie, data = donnees)
```

Coefficients:

(Intercept)	ventNord	ventOuest	ventSud	pluieSec
85.123	-16.333	-12.709	-2.101	25.597

Un exemple

- On souhaite expliquer max03 par la direction du vent et la pluie.
- On dispose de n observations (x_i, Y_i) et on écrit le modèle

$$Y_i = \beta_0 + \beta_1 \mathbf{1}_{x_{i1}=\text{Est}} + \beta_2 \mathbf{1}_{x_{i1}=\text{Nord}} + \beta_3 \mathbf{1}_{x_{i1}=\text{Ouest}} + \beta_4 \mathbf{1}_{x_{i1}=\text{Sud}} \\ + \beta_5 \mathbf{1}_{x_{i2}=\text{pluie}} + \beta_6 \mathbf{1}_{x_{i2}=\text{Sec}} + \varepsilon$$

muni des contraintes $\beta_1 = 0$ et $\beta_5 = 0$.

```
> reg <- lm(max03~vent+pluie,data=donnees)
> reg
```

Call:

```
lm(formula = max03 ~ vent + pluie, data = donnees)
```

Coefficients:

(Intercept)	ventNord	ventOuest	ventSud	pluieSec
85.123	-16.333	-12.709	-2.101	25.597

Test de signicativité des facteurs

- Une fois de plus, c'est le test de Fisher qui nous permet de tester la signicativité des variables explicatives dans le modèle.
- On réalise les deux tests de Fisher pour les hypothèses :

$$H_0 : \beta_1 = \dots = \beta_4 = 0 \quad \text{contre} \quad H_1 : \exists j \in \{1, \dots, 4\} : \beta_j \neq 0.$$

$$H_0 : \beta_5 = \beta_6 = 0 \quad \text{contre} \quad H_1 : \exists j \in \{5, 6\} : \beta_j \neq 0.$$

```
> anova(reg)
```

```
Analysis of Variance Table
```

```
Response: maxO3
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
vent	3	7586	2528.7	4.1984	0.007514	**
pluie	1	16159	16159.4	26.8295	1.052e-06	***
Residuals	107	64446	602.3			

Test de signicativité des facteurs

- Une fois de plus, c'est le test de Fisher qui nous permet de tester la signicativité des variables explicatives dans le modèle.
- On réalise les deux tests de Fisher pour les hypothèses :

$$H_0 : \beta_1 = \dots = \beta_4 = 0 \quad \text{contre} \quad H_1 : \exists j \in \{1, \dots, 4\} : \beta_j \neq 0.$$

$$H_0 : \beta_5 = \beta_6 = 0 \quad \text{contre} \quad H_1 : \exists j \in \{5, 6\} : \beta_j \neq 0.$$

```
> anova(reg)
```

```
Analysis of Variance Table
```

```
Response: maxO3
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
vent	3	7586	2528.7	4.1984	0.007514	**
pluie	1	16159	16159.4	26.8295	1.052e-06	***
Residuals	107	64446	602.3			

- Une fois de plus, c'est le test de Fisher qui nous permet de tester la signficativité des variables explicatives dans le modèle.
- On réalise les deux tests de Fisher pour les hypothèses :

$$H_0 : \beta_1 = \dots = \beta_4 = 0 \quad \text{contre} \quad H_1 : \exists j \in \{1, \dots, 4\} : \beta_j \neq 0.$$

$$H_0 : \beta_5 = \beta_6 = 0 \quad \text{contre} \quad H_1 : \exists j \in \{5, 6\} : \beta_j \neq 0.$$

```
> anova(reg)
```

```
Analysis of Variance Table
```

```
Response: maxO3
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
vent	3	7586	2528.7	4.1984	0.007514	**
pluie	1	16159	16159.4	26.8295	1.052e-06	***
Residuals	107	64446	602.3			

Conclusion

- Les variables explicatives quantitatives et qualitatives ont été traitées séparément dans ce chapitre.
- Bien évidemment, en pratique il convient de les traiter ensemble (il suffit d'écrire correctement la partie quantitative et la partie qualitative du modèle).

Exemple

$$\text{maxO3} = \beta_0 + \beta_1 T_{12} + \beta_2 \text{Ne}_{15} + \beta_3 \mathbf{1}_{\text{pluie}} + \beta_4 \mathbf{1}_{\text{sec}} + \varepsilon$$

muni de la contrainte $\beta_3 = 0$.

```
> reg <- lm(maxO3~T12+Ne15+pluie,data=donnees)
> reg
```

```
Call:
lm(formula = maxO3 ~ T12 + Ne15 + pluie, data = donnees)
```

Coefficients:

(Intercept)	T12	Ne15	pluieSec
-5.978	4.594	-1.613	8.413

Conclusion

- Les variables explicatives quantitatives et qualitatives ont été traitées séparément dans ce chapitre.
- Bien évidemment, en pratique il convient de les traiter ensemble (il suffit d'écrire correctement la partie quantitative et la partie qualitative du modèle).

Exemple

$$\text{maxO3} = \beta_0 + \beta_1 T_{12} + \beta_2 \text{Ne}_{15} + \beta_3 \mathbf{1}_{\text{pluie}} + \beta_4 \mathbf{1}_{\text{sec}} + \varepsilon$$

muni de la contrainte $\beta_3 = 0$.

```
> reg <- lm(maxO3~T12+Ne15+pluie,data=donnees)
> reg
```

```
Call:
lm(formula = maxO3 ~ T12 + Ne15 + pluie, data = donnees)
```

Coefficients:

(Intercept)	T12	Ne15	pluieSec
-5.978	4.594	-1.613	8.413

Conclusion

- Les variables explicatives quantitatives et qualitatives ont été traitées séparément dans ce chapitre.
- Bien évidemment, en pratique il convient de les traiter ensemble (il suffit d'écrire correctement la partie quantitative et la partie qualitative du modèle).

Exemple

$$\text{maxO3} = \beta_0 + \beta_1 T_{12} + \beta_2 \text{Ne}_{15} + \beta_3 \mathbf{1}_{\text{pluie}} + \beta_4 \mathbf{1}_{\text{sec}} + \varepsilon$$

muni de la contrainte $\beta_3 = 0$.

```
> reg <- lm(maxO3~T12+Ne15+pluie,data=donnees)
> reg
```

```
Call:
lm(formula = maxO3 ~ T12 + Ne15 + pluie, data = donnees)
```

Coefficients:

(Intercept)	T12	Ne15	pluieSec
-5.978	4.594	-1.613	8.413

Conclusion

- Les variables explicatives quantitatives et qualitatives ont été traitées séparément dans ce chapitre.
- Bien évidemment, en pratique il convient de les traiter ensemble (il suffit d'écrire correctement la partie quantitative et la partie qualitative du modèle).

Exemple

$$\text{maxO3} = \beta_0 + \beta_1 T_{12} + \beta_2 \text{Ne}_{15} + \beta_3 \mathbf{1}_{\text{pluie}} + \beta_4 \mathbf{1}_{\text{sec}} + \varepsilon$$

muni de la contrainte $\beta_3 = 0$.

```
> reg <- lm(maxO3~T12+Ne15+pluie,data=donnees)
> reg
```

```
Call:
lm(formula = maxO3 ~ T12 + Ne15 + pluie, data = donnees)
```

Coefficients:

(Intercept)	T12	Ne15	pluieSec
-5.978	4.594	-1.613	8.413

- 1 Introduction
- 2 La régression linéaire simple
 - Ajustement par moindres carrés
 - Propriétés des estimateurs
 - Quelques lois de probabilités
 - Inférence statistique
- 3 La régression multiple
 - Notations et modélisation
 - Estimateur des moindres carrés
 - Propriétés statistiques
- 4 Validation et choix de modèles
 - Résidus et coefficient de détermination
 - Tests entre modèles emboîtés
- 5 Analyse de la variance
 - Modèle à un facteur
 - ANOVA à deux facteurs
 - Sélection de modèles
- 6 Bibliographie

Un exemple de sélection de variables

```
> reg <- lm(max03~.,data=donnees)
> anova(reg)
Analysis of Variance Table
```

Response: max03

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
T9	1	43138	43138	205.0160	< 2.2e-16	***
T12	1	11125	11125	52.8706	9.165e-11	***
T15	1	876	876	4.1619	0.0440614	*
Ne9	1	3244	3244	15.4170	0.0001613	***
Ne12	1	232	232	1.1035	0.2961089	
Ne15	1	5	5	0.0248	0.8752847	
Vx9	1	2217	2217	10.5355	0.0016079	**
Vx12	1	1	1	0.0049	0.9443039	
Vx15	1	67	67	0.3186	0.5737491	
max03v	1	6460	6460	30.6993	2.584e-07	***
vent	3	234	78	0.3709	0.7741473	
pluie	1	183	183	0.8694	0.3534399	
Residuals	97	20410	210			

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Méthode pas à pas

```
> reg1 <- step(reg,direction="backward")
> anova(reg1)
Analysis of Variance Table
```

Response: max03

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
T12	1	54244	54244	276.777	< 2.2e-16	***
Ne9	1	3579	3579	18.260	4.193e-05	***
Vx9	1	2035	2035	10.385	0.001684	**
max03v	1	7364	7364	37.572	1.499e-08	***
Residuals	107	20970	196			

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

1 Introduction

2 La régression linéaire simple

- Ajustement par moindres carrés
- Propriétés des estimateurs
- Quelques lois de probabilités
- Inférence statistique

3 La régression multiple

- Notations et modélisation
- Estimateur des moindres carrés
- Propriétés statistiques

4 Validation et choix de modèles

- Résidus et coefficient de détermination
- Tests entre modèles emboîtés

5 Analyse de la variance

- Modèle à un facteur
- ANOVA à deux facteurs
- Sélection de modèles

6 Bibliographie

