

Modélisation

Partie 1 : construction et sélection de modèles

François Husson

Unité pédagogique de mathématiques appliquées
L'Institut Agro

Modéliser c'est comprendre et prévoir

Qui a déjà fait des modélisations complexes ?

Modéliser c'est comprendre et prévoir

Qui a déjà fait des modélisations complexes ? TOUS ... facilement et sans le savoir !

Modéliser c'est comprendre et prévoir

Qui a déjà fait des modélisations complexes? TOUS ... facilement et sans le savoir !

- Prévoir un temps de trajet
- Estimer le temps d'attente à un guichet
- Estimer si le prix de location de l'appartement est juste
- Choisir de prendre un vêtement de pluie pour la journée (prévoir s'il va pleuvoir)

Modéliser c'est comprendre et prévoir

Qui a déjà fait des modélisations complexes? TOUS ... facilement et sans le savoir !

- Prévoir un temps de trajet
- Estimer le temps d'attente à un guichet
- Estimer si le prix de location de l'appartement est juste
- Choisir de prendre un vêtement de pluie pour la journée (prévoir s'il va pleuvoir)

Et comment faites-vous pour prévoir ?

Modéliser c'est comprendre et prévoir

Qui a déjà fait des modélisations complexes ? TOUS ... facilement et sans le savoir !

- Prévoir un temps de trajet
- Estimer le temps d'attente à un guichet
- Estimer si le prix de location de l'appartement est juste
- Choisir de prendre un vêtement de pluie pour la journée (prévoir s'il va pleuvoir)

Et comment faites-vous pour prévoir ?

- ① vous listez toutes les variables (les effets) qui peuvent influencer sur votre réponse
- ② vous éliminez les variables qui sont négligeables
- ③ vous essayez de quantifier l'effet des variables restantes sélectionnées

Modéliser c'est comprendre et prévoir

Qui a déjà fait des modélisations complexes ? TOUS ... facilement et sans le savoir !

- Prévoir un temps de trajet
- Estimer le temps d'attente à un guichet
- Estimer si le prix de location de l'appartement est juste
- Choisir de prendre un vêtement de pluie pour la journée (prévoir s'il va pleuvoir)

Et comment faites-vous pour prévoir ?

- ① vous listez toutes les **variables** (les effets) qui peuvent influencer sur votre **réponse**
- ② vous **éliminez** les variables qui sont **négligeables**
- ③ vous essayez de **quantifier l'effet** des variables restantes **sélectionnées**

Modéliser c'est comprendre et prévoir

Qui a déjà fait des modélisations complexes ? TOUS ... facilement et sans le savoir !

- Prévoir un temps de trajet
- Estimer le temps d'attente à un guichet
- Estimer si le prix de location de l'appartement est juste
- Choisir de prendre un vêtement de pluie pour la journée (prévoir s'il va pleuvoir)

Et comment faites-vous pour prévoir ?

- ① vous listez toutes les **variables** (les effets) qui peuvent influencer sur votre **réponse**
- ② vous **éliminez** les variables qui sont **négligeables**
- ③ vous essayez de **quantifier l'effet** des variables restantes **sélectionnées**

Votre intuition est-elle bien raisonnable ?

Modéliser c'est comprendre et prévoir

Qui a déjà fait des modélisations complexes ? TOUS ... facilement et sans le savoir !

- Prévoir un temps de trajet
- Estimer le temps d'attente à un guichet
- Estimer si le prix de location de l'appartement est juste
- Choisir de prendre un vêtement de pluie pour la journée (prévoir s'il va pleuvoir)

Et comment faites-vous pour prévoir ?

- ① vous listez toutes les **variables** (les effets) qui peuvent influencer sur votre **réponse**
- ② vous **éliminez** les variables qui sont **négligeables**
- ③ vous essayez de **quantifier l'effet** des variables restantes **sélectionnées**

Votre intuition est-elle bien raisonnable ? OUI, C'EST PARFAIT

Modéliser c'est comprendre et prévoir

Qui a déjà fait des modélisations complexes ? TOUS ... facilement et sans le savoir !

- Prévoir un temps de trajet
- Estimer le temps d'attente à un guichet
- Estimer si le prix de location de l'appartement est juste
- Choisir de prendre un vêtement de pluie pour la journée (prévoir s'il va pleuvoir)

Et comment faites-vous pour prévoir ?

- ① vous listez toutes les **variables** (les effets) qui peuvent influencer sur votre **réponse**
- ② vous **éliminez** les variables qui sont **négligeables**
- ③ vous essayez de **quantifier l'effet** des variables restantes **sélectionnées**

Votre intuition est-elle bien raisonnable ? OUI, C'EST PARFAIT

A quoi servent les statistiques alors ?

Modéliser c'est comprendre et prévoir

Qui a déjà fait des modélisations complexes ? TOUS ... facilement et sans le savoir !

- Prévoir un temps de trajet
- Estimer le temps d'attente à un guichet
- Estimer si le prix de location de l'appartement est juste
- Choisir de prendre un vêtement de pluie pour la journée (prévoir s'il va pleuvoir)

Et comment faites-vous pour prévoir ?

- ① vous listez toutes les **variables** (les effets) qui peuvent influencer sur votre **réponse**
- ② vous **éliminez** les variables qui sont **négligeables**
- ③ vous essayez de **quantifier l'effet** des variables restantes **sélectionnées**

Votre intuition est-elle bien raisonnable ? OUI, C'EST PARFAIT

A quoi servent les statistiques alors ? A faire tout cela avec rigueur pour des phénomènes parfois plus complexes

Données, problématique

- Prévoir le temps de cuisson idéal en fonction de la composition et du poids de l'aliment, de la température du four, de l'humidité de l'air, ...
- Prévoir la production de biogaz en fonction de la quantité de déchets agricoles ou alimentaires, des résidus de cultures, d'ordures ménagères ou des restaurants, etc.
- Prévoir la production d'une éolienne en fonction de la vitesse du vent à 10m, à 80m, de la température à 2m, de la pression, de l'humidité relative à 2m, (de la direction du vent)
- Comprendre ce qui influe sur le pourcentage de surface à bas niveau d'intrants d'une zone en fonction du type de culture, de la mise en place ou non d'un programme d'aide, si la zone se situe dans une aire de captage
- Optimiser une réaction chimique en fonction du temps et de la température

Objectifs :

- **Comprendre** quelles variables influent sur une variable **réponse quantitative**
- **Prévoir** les valeurs de la variable réponse pour de nouvelles conditions

Données, problématique

L'association Air Breizh surveille la qualité de l'air et mesure la concentration de polluants comme l'ozone (O_3) ainsi que les conditions météorologiques comme la température, la nébulosité, le vent, etc.

Durant l'été 2001, 112 données ont été relevées à Rennes


```
ozone <- read.table("https://r-stat-sc-donnees.github.io/ozone.txt",
  header=TRUE, stringsAsFactors = TRUE)
```

| | maxO3 | T9 | T12 | T15 | Ne9 | Ne12 | Ne15 | Vx9 | Vx12 | Vx15 | maxO3v | vent | pluie |
|------------|-------|------|------|------|-----|------|------|---------|---------|---------|--------|-------|-------|
| 2001-06-01 | 87 | 15.6 | 18.5 | 18.4 | 4 | 4 | 8 | 0.6946 | -1.7101 | -0.6946 | 84 | Nord | Sec |
| 2001-06-02 | 82 | 17 | 18.4 | 17.7 | 5 | 5 | 7 | -4.3301 | -4 | -3 | 87 | Nord | Sec |
| 2001-06-03 | 92 | 15.3 | 17.6 | 19.5 | 2 | 5 | 4 | 2.9544 | 1.8794 | 0.5209 | 82 | Est | Sec |
| 2001-06-04 | 114 | 16.2 | 19.7 | 22.5 | 1 | 1 | 0 | 0.9848 | 0.3473 | -0.1736 | 92 | Nord | Sec |
| 2001-06-05 | 94 | 17.4 | 20.5 | 20.4 | 8 | 8 | 7 | -0.5 | -2.9544 | -4.3301 | 114 | Ouest | Sec |
| 2001-06-06 | 80 | 17.7 | 19.8 | 18.3 | 6 | 6 | 7 | -5.6382 | -5 | -6 | 94 | Ouest | Pluie |
| 2001-06-07 | 79 | 16.8 | 15.6 | 14.9 | 7 | 8 | 8 | -4.3301 | -1.8794 | -3.7588 | 80 | Ouest | Sec |
| ... | ... | ... | | | | | | | | | | | |

Leur objectif : prévoir la concentration en ozone du lendemain pour avertir la population en cas de pic de pollution

Visualisation de l'effet linéaire d'une variable quantitative


Effet de T9 sur le maximum d'ozone



```
library(ggplot2)
ggplot(ozone) +
  aes(x=T9, y=maxO3) +
  geom_point() +
  geom_smooth(method="lm", se=FALSE) +
  ggtitle("Effet de T9 sur le maximum d'ozone")
```

Visualisation de l'effet linéaire d'une variable quantitative

Effet de T9 sur le maximum d'ozone




```
library(ggplot2)
ggplot(ozone) +
  aes(x=T9, y=maxO3) +
  geom_point() +
  geom_smooth(method="lm", se=FALSE) +
  ggtitle("Effet de T9 sur le maximum d'ozone")
```

$$\text{MaxO3} \sim T9 \quad \implies \quad \text{MaxO3}_i = \beta_0 + \beta_1 \times T9_i + \text{alea}_i$$

Visualisation de l'effet linéaire d'une variable quantitative

Effet de T9 sur le maximum d'ozone



```
library(ggplot2)
ggplot(ozone) +
  aes(x=T9, y=maxO3) +
  geom_point() +
  geom_smooth(method="lm", se=FALSE) +
  ggtitle("Effet de T9 sur le maximum d'ozone")
```


$$\text{MaxO3} \sim T9 \quad \implies \quad \text{MaxO3}_i = \beta_0 + \beta_1 \times T9_i + \text{alea}_i$$

$$\text{Réponse} \sim \text{var}_1$$

$$\left\{ \begin{array}{l} \forall i = 1, \dots, n \quad Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \\ \forall i = 1, \dots, n \quad \varepsilon_i \text{ i.i.d.}, \quad \mathbb{E}(\varepsilon_i) = 0, \quad \mathbb{V}(\varepsilon_i) = \sigma^2 \\ \forall i \neq k \quad \text{cov}(\varepsilon_i, \varepsilon_k) = 0 \end{array} \right.$$

Visualisation de l'effet linéaire d'une variable quantitative

Effet de T9 sur le maximum d'ozone



```
library(ggplot2)
ggplot(ozone) +
  aes(x=T9, y=maxO3) +
  geom_point() +
  geom_smooth(method="lm", se=FALSE) +
  ggtitle("Effet de T9 sur le maximum d'ozone")
```


$$\text{MaxO3} \sim T9 \quad \implies \quad \text{MaxO3}_i = \beta_0 + \beta_1 \times T9_i + \text{alea}_i$$

$$\text{Réponse} \sim \text{var}_1 + \text{var}_2 + \dots + \text{var}_p$$

$$\left\{ \begin{array}{l} \forall i = 1, \dots, n \quad Y_i = \beta_0 + \beta_1 x_i + \beta_2 v_i + \beta_3 w_i + \dots + \beta_p z_i + \varepsilon_i \\ \forall i = 1, \dots, n \quad \varepsilon_i \text{ i.i.d.}, \quad \mathbb{E}(\varepsilon_i) = 0, \quad \mathbb{V}(\varepsilon_i) = \sigma^2 \\ \forall i \neq k \quad \text{cov}(\varepsilon_i, \varepsilon_k) = 0 \end{array} \right.$$

Visualisation de l'effet linéaire d'une variable quantitative

Effet de T9 sur le maximum d'ozone




```
library(ggplot2)
ggplot(ozone) +
  aes(x=T9, y=maxO3) +
  geom_point() +
  geom_smooth(method="lm", se=FALSE) +
  ggtitle("Effet de T9 sur le maximum d'ozone")
```

$$\text{MaxO3} \sim T9 \quad \implies \quad \text{MaxO3}_i = \beta_0 + \beta_1 \times T9_i + \text{alea}_i$$

$$\text{Réponse} \sim \text{var}_1 + \text{var}_2 + \dots + \text{var}_p$$


$$\left\{ \begin{array}{l} \forall i = 1, \dots, n \quad Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \dots + \beta_p x_{ip} + \varepsilon_i \\ \forall i = 1, \dots, n \quad \varepsilon_i \text{ i.i.d.}, \quad \mathbb{E}(\varepsilon_i) = 0, \quad \mathbb{V}(\varepsilon_i) = \sigma^2 \\ \forall i \neq k \quad \text{cov}(\varepsilon_i, \varepsilon_k) = 0 \end{array} \right.$$

Visualisation de l'effet d'une variable qualitative



```
ggplot(ozone) +  
  aes(x=vent, y=maxO3, fill=vent, col=vent) +  
  geom_boxplot(outlier.shape=NA, alpha=0.4) +  
  geom_jitter()+  
  ggtitle("Effet du vent sur le maximum d'ozone")
```


Visualisation de l'effet d'une variable qualitative



```
ggplot(ozone) +
  aes(x=vent, y=maxO3, fill=vent, col=vent) +
  geom_boxplot(outlier.shape=NA,alpha=0.4) +
  geom_jitter()+
  ggtitle("Effet du vent sur le maximum d'ozone")
```

$$MaxO3 \sim vent \implies MaxO3_{ij} \sim \mu + \left\{ \begin{array}{l} \alpha_1 \text{ si vent d'est} \\ \alpha_2 \text{ si vent du nord} \\ \alpha_3 \text{ si vent d'ouest} \\ \alpha_4 \text{ si vent du sud} \end{array} \right\} + alea_{ij}$$

Visualisation de l'effet d'une variable qualitative




```
ggplot(ozone) +
  aes(x=vent, y=maxO3, fill=vent, col=vent) +
  geom_boxplot(outlier.shape=NA,alpha=0.4) +
  geom_jitter()+
  ggtitle("Effet du vent sur le maximum d'ozone")
```

$$MaxO3 \sim vent \implies MaxO3_{ij} \sim \mu + \begin{cases} \alpha_1 & \text{si vent d'est} \\ \alpha_2 & \text{si vent du nord} \\ \alpha_3 & \text{si vent d'ouest} \\ \alpha_4 & \text{si vent du sud} \end{cases} + alea_{ij}$$

Réponse $\sim var_1$

$$\begin{cases} \forall i,j & Y_{ij} = \mu + \alpha_i + \varepsilon_{ij} \\ \forall i,j & \varepsilon_{ij} \text{ i.i.d.}, \mathbb{E}(\varepsilon_{ij}) = 0, \mathbb{V}(\varepsilon_{ij}) = \sigma^2 \\ \forall i,j & cov(\varepsilon_{ij}, \varepsilon_{i'j'}) = 0 \end{cases}$$

Visualisation de l'effet d'une variable qualitative




```
ggplot(ozone) +
  aes(x=vent, y=maxO3, fill=vent, col=vent) +
  geom_boxplot(outlier.shape=NA,alpha=0.4) +
  geom_jitter()+
  ggtitle("Effet du vent sur le maximum d'ozone")
```

$$MaxO3 \sim vent \implies MaxO3_{ij} \sim \mu + \begin{cases} \alpha_1 & \text{si vent d'est} \\ \alpha_2 & \text{si vent du nord} \\ \alpha_3 & \text{si vent d'ouest} \\ \alpha_4 & \text{si vent du sud} \end{cases} + alea_{ij}$$

Réponse $\sim var_1 + var_2 + \dots$

$$\begin{cases} \forall i, j, k & Y_{ijk} = \mu + \alpha_i + \beta_j + \varepsilon_{ijk} \\ \forall i, j, k & \varepsilon_{ijk} \text{ i.i.d.}, \mathbb{E}(\varepsilon_{ijk}) = 0, \mathbb{V}(\varepsilon_{ijk}) = \sigma^2 \\ \forall i, j, k & cov(\varepsilon_{ijk}, \varepsilon_{i'j'k'}) = 0 \end{cases}$$


Visualisation de l'effet linéaire d'une variable quanti spécifique selon les modalités d'une variables quali



```
ggplot(ozone) +  
  aes(x=T9, y=maxO3, col = vent, group=vent) +  
  geom_smooth(method="lm", se=FALSE) +  
  geom_point()+  
  ggtitle("Effet de T9 sur MaxO3 selon le vent")
```

Visualisation de l'effet linéaire d'une variable quanti spécifique selon les modalités d'une variables quali

Effet de T9 sur le maximum d'ozone selon le vent




```
ggplot(ozone) +
  aes(x=T9, y=maxO3, col = vent, group=vent) +
  geom_smooth(method="lm", se=FALSE) +
  geom_point()+
  ggtitle("Effet de T9 sur MaxO3 selon le vent")
```

$$\text{MaxO3} \sim \text{vent} + T9 + \text{vent} : T9$$

$$\text{MaxO3}_{ij} \sim \mu + \left\{ \begin{array}{l} \alpha_1 \text{ si vent d'est} \\ \alpha_2 \text{ si vent du nord} \\ \alpha_3 \text{ si vent d'ouest} \\ \alpha_4 \text{ si vent du sud} \end{array} \right\} + \left(\beta + \left\{ \begin{array}{l} \gamma_1 \text{ si vent d'est} \\ \gamma_2 \text{ si vent du nord} \\ \gamma_3 \text{ si vent d'ouest} \\ \gamma_4 \text{ si vent du sud} \end{array} \right\} \right) \times T9_{ij} + \text{alea}_{ij}$$

Visualisation de l'effet linéaire d'une variable quanti spécifique selon les modalités d'une variables quali

Effet de T9 sur le maximum d'ozone selon le vent



```
ggplot(ozone) +
  aes(x=T9, y=maxO3, col = vent, group=vent) +
  geom_smooth(method="lm", se=FALSE) +
  geom_point()+
  ggtitle("Effet de T9 sur MaxO3 selon le vent")
```

$$\text{MaxO3} \sim \text{vent} + T9 + \text{vent} : T9$$


$$\text{MaxO3}_{ij} \sim \mu + \left\{ \begin{array}{l} \alpha_1 \text{ si vent d'est} \\ \alpha_2 \text{ si vent du nord} \\ \alpha_3 \text{ si vent d'ouest} \\ \alpha_4 \text{ si vent du sud} \end{array} \right\} + \left(\beta + \left\{ \begin{array}{l} \gamma_1 \text{ si vent d'est} \\ \gamma_2 \text{ si vent du nord} \\ \gamma_3 \text{ si vent d'ouest} \\ \gamma_4 \text{ si vent du sud} \end{array} \right\} \right) \times T9_{ij} + \text{alea}_{ij}$$

$$\left\{ \begin{array}{l} \forall i, j \quad Y_{ij} = \mu + \alpha_i + (\beta + \gamma_i) \times x_{ij} + \varepsilon_{ij} \\ \forall i, j \quad \varepsilon_{ij} \text{ i.i.d.}, \quad \mathbb{E}(\varepsilon_{ij}) = 0, \quad \mathbb{V}(\varepsilon_{ij}) = \sigma^2 \\ \forall i, j \quad \text{cov}(\varepsilon_{ij}, \varepsilon_{i'j'}) = 0 \end{array} \right.$$

Visualisation de l'interaction de 2 variables qualitatives

Définition courante : réaction réciproque de deux phénomènes l'un sur l'autre

Définition statistique : l'effet d'un facteur sur Y diffère selon les modalités de l'autre facteur




```
library(dplyr)
ozone %>% group_by(vent, pluie) %>%
  summarize(MOY = mean(maxO3)) %>%
  ggplot() +
  aes(x=vent, y=MOY, col=pluie, group=pluie) +
  geom_line() + geom_point() +
  ggtitle("Interaction pluie:vent sur maxO3")+
  xlab("Direction du vent")+
  ylab("Maximum d'ozone")
```

Visualisation de l'interaction de 2 variables qualitatives

Définition courante : réaction réciproque de deux phénomènes l'un sur l'autre

Définition statistique : l'effet d'un facteur sur Y diffère selon les modalités de l'autre facteur

Interaction pluie:vent sur le maximum d'ozone



```
library(dplyr)
ozone %>% group_by(vent, pluie) %>%
  summarize(MOY = mean(maxO3)) %>%
  ggplot() +
  aes(x=vent, y=MOY, col=pluie, group=pluie) +
  geom_line() + geom_point() +
  ggtitle("Interaction pluie:vent sur maxO3")+
  xlab("Direction du vent")+
  ylab("Maximum d'ozone")
```

$$MaxO3 \sim vent + pluie + vent : pluie$$


$$MaxO3_{ijk} \sim \mu + \left\{ \begin{array}{l} \alpha_1 \text{ si vent d'est} \\ \alpha_2 \text{ si vent du nord} \\ \alpha_3 \text{ si vent d'ouest} \\ \alpha_4 \text{ si vent du sud} \end{array} \right\} + \left\{ \begin{array}{l} \beta_1 \text{ si pluie} \\ \beta_2 \text{ si sec} \end{array} \right\} + \left\{ \begin{array}{l} \alpha\beta_{11} \text{ si vent d'est ET pluie} \\ \alpha\beta_{12} \text{ si vent d'est ET sec} \\ \alpha\beta_{21} \text{ si vent du nord ET pluie} \\ \dots \alpha\beta_{42} \text{ si vent du sud ET sec} \end{array} \right\} + alea_{ijk}$$

Visualisation de l'interaction de 2 variables qualitatives

Définition courante : réaction réciproque de deux phénomènes l'un sur l'autre

Définition statistique : l'effet d'un facteur sur Y diffère selon les modalités de l'autre facteur

Interaction pluie:vent sur le maximum d'ozone



```
library(dplyr)
ozone %>% group_by(vent, pluie) %>%
  summarize(MOY = mean(maxO3)) %>%
  ggplot() +
  aes(x=vent, y=MOY, col=pluie, group=pluie) +
  geom_line() + geom_point() +
  ggtitle("Interaction pluie:vent sur maxO3")+
  xlab("Direction du vent")+
  ylab("Maximum d'ozone")
```

$$MaxO3 \sim vent + pluie + vent : pluie$$


$$MaxO3_{ijk} \sim \mu + \left\{ \begin{array}{l} \alpha_1 \text{ si vent d'est} \\ \alpha_2 \text{ si vent du nord} \\ \alpha_3 \text{ si vent d'ouest} \\ \alpha_4 \text{ si vent du sud} \end{array} \right\} + \left\{ \begin{array}{l} \beta_1 \text{ si pluie} \\ \beta_2 \text{ si sec} \end{array} \right\} + \left\{ \begin{array}{l} \alpha\beta_{11} \text{ si vent d'est ET pluie} \\ \alpha\beta_{12} \text{ si vent d'est ET sec} \\ \alpha\beta_{21} \text{ si vent du nord ET pluie} \\ \dots \alpha\beta_{42} \text{ si vent du sud ET sec} \end{array} \right\} + alea_{ijk}$$

$$\left\{ \begin{array}{l} \forall i, j, k \quad Y_{ijk} = \mu + \alpha_i + \beta_j + \alpha\beta_{ij} + \varepsilon_{ijk} \\ \forall i, j, k \quad \varepsilon_{ijk} \text{ i.i.d.}, \mathbb{E}(\varepsilon_{ijk}) = 0, \mathbb{V}(\varepsilon_{ijk}) = \sigma^2 \\ \forall i, j, k \quad cov(\varepsilon_{ijk}, \varepsilon_{i'j'k'}) = 0 \end{array} \right.$$


Les effets d'un modèle

Quatre types d'effets possibles :


Effet de T9 sur le maximum d'ozone




Effet du vent sur le maximum d'ozone



Effet de T9 sur le maximum d'ozone selon le vent



Interaction pluie:vent sur le maximum d'ozone



Et avec ça on en ajoute autant qu'on veut pour construire ... tous les modèles avec des effets linéaires et des interactions.

Les modèles linéaires

Réponse**Variable(s) explicative(s)****Méthode**

Var. quantitative

1 var. quantitative

régression linéaire simple

Les modèles linéaires

Réponse

Variable(s) explicative(s)

Méthode

Var. quantitative

1 var. quantitative

régression linéaire simple

Var. quantitative

1 var. qualitative à I modalités

analyse de variance à 1 facteur
(rq : si $I = 2$ équivaut à comparaison de 2 moyennes)

Les modèles linéaires

| Réponse | Variable(s) explicative(s) | Méthode |
|-------------------|------------------------------------|---|
| Var. quantitative | 1 var. quantitative | régression linéaire simple |
| Var. quantitative | 1 var. qualitative à I modalités | analyse de variance à 1 facteur (rq : si $I = 2$ équivaut à comparaison de 2 moyennes) |
| Var. quantitative | p var. quantitatives | régression linéaire multiple |

Les modèles linéaires

| Réponse | Variable(s) explicative(s) | Méthode |
|-------------------|------------------------------------|---|
| Var. quantitative | 1 var. quantitative | régression linéaire simple |
| Var. quantitative | 1 var. qualitative à I modalités | analyse de variance à 1 facteur (rq : si $I = 2$ équivaut à comparaison de 2 moyennes) |
| Var. quantitative | p var. quantitatives | régression linéaire multiple |
| Var. quantitative | K var. qualitatives | analyse de variance à K facteurs |

Les modèles linéaires

| Réponse | Variable(s) explicative(s) | Méthode |
|-------------------|------------------------------------|---|
| Var. quantitative | 1 var. quantitative | régression linéaire simple |
| Var. quantitative | 1 var. qualitative à I modalités | analyse de variance à 1 facteur (rq : si $I = 2$ équivaut à comparaison de 2 moyennes) |
| Var. quantitative | p var. quantitatives | régression linéaire multiple |
| Var. quantitative | K var. qualitatives | analyse de variance à K facteurs |
| Var. quantitative | var. quantitatives et qualitatives | analyse de covariance |

Les modèles linéaires

| Réponse | Variable(s) explicative(s) | Méthode |
|-------------------|------------------------------------|---|
| Var. quantitative | 1 var. quantitative | régression linéaire simple |
| Var. quantitative | 1 var. qualitative à I modalités | analyse de variance à 1 facteur (rq : si $I = 2$ équivaut à comparaison de 2 moyennes) |
| Var. quantitative | p var. quantitatives | régression linéaire multiple |
| Var. quantitative | K var. qualitatives | analyse de variance à K facteurs |
| Var. quantitative | var. quantitatives et qualitatives | analyse de covariance |
| Var. qualitative | var. quantitatives et qualitatives | régression logistique |

Écriture du modèle

Modèle de régression multiple (toutes les variables explicatives sont quantitatives) :

$$\left\{ \begin{array}{l} \forall i = 1, \dots, n \quad Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \dots + \beta_p x_{ip} + \varepsilon_i \\ \forall i = 1, \dots, n \quad \varepsilon_i \text{ i.i.d.}, \quad \mathbb{E}(\varepsilon_i) = 0, \quad \mathbb{V}(\varepsilon_i) = \sigma^2 \\ \forall i \neq k \quad \text{cov}(\varepsilon_i, \varepsilon_k) = 0 \end{array} \right.$$

(p+1) paramètres à estimer + 1 paramètre de variance σ^2

Ecriture du modèle

Modèle de régression multiple (toutes les variables explicatives sont quantitatives) :

$$\begin{cases} \forall i = 1, \dots, n & Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \dots + \beta_p x_{ip} + \varepsilon_i \\ \forall i = 1, \dots, n & \varepsilon_i \text{ i.i.d.}, \mathbb{E}(\varepsilon_i) = 0, \mathbb{V}(\varepsilon_i) = \sigma^2 \\ \forall i \neq k & \text{cov}(\varepsilon_i, \varepsilon_k) = 0 \end{cases}$$

(p+1) paramètres à estimer + 1 paramètre de variance σ^2

Matriciellement : $Y = X\beta + E$ avec $\mathbb{E}(E) = 0$, $\mathbb{V}(E) = \sigma^2 Id$

$$\begin{pmatrix} Y_1 \\ \vdots \\ Y_i \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} \beta_0 & \beta_1 & \beta_2 & \dots & \beta_p \\ 1 & x_{11} & x_{12} & \dots & x_{1p} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & x_{i1} & x_{i2} & & x_{ip} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{np} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_i \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

Ecriture du modèle

Modèle de régression multiple (toutes les variables explicatives sont quantitatives) :

$$\begin{cases} \forall i = 1, \dots, n & Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \dots + \beta_p x_{ip} + \varepsilon_i \\ \forall i = 1, \dots, n & \varepsilon_i \text{ i.i.d.}, \mathbb{E}(\varepsilon_i) = 0, \mathbb{V}(\varepsilon_i) = \sigma^2 \\ \forall i \neq k & \text{cov}(\varepsilon_i, \varepsilon_k) = 0 \end{cases}$$

(p+1) paramètres à estimer + 1 paramètre de variance σ^2

Matriciellement : $Y = X\beta + E$ avec $\mathbb{E}(E) = 0$, $\mathbb{V}(E) = \sigma^2 Id$

$$\begin{pmatrix} Y_1 \\ \vdots \\ Y_i \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1p} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & x_{i1} & x_{i2} & & x_{ip} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{np} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_i \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

Remarque : Les modèles d'analyse de variance et d'analyse de covariance peuvent aussi s'écrire sous cette forme !!

$$\begin{cases} \forall i, j, k & Y_{ijk} = \mu + \alpha_i + \beta_j + \alpha\beta_{ij} + \varepsilon_{ijk} \\ \forall i, j, k & \varepsilon_{ijk} \text{ i.i.d.}, \mathbb{E}(\varepsilon_{ijk}) = 0, \mathbb{V}(\varepsilon_{ijk}) = \sigma^2 \\ \forall i, j, k & \text{cov}(\varepsilon_{ijk}, \varepsilon_{i'j'k'}) = 0 \end{cases} \quad \begin{cases} \forall i, j & Y_{ij} = \mu + \alpha_i + (\beta + \gamma_i) \times x_{ij} + \varepsilon_{ij} \\ \forall i, j & \varepsilon_{ij} \text{ i.i.d.}, \mathbb{E}(\varepsilon_{ij}) = 0, \mathbb{V}(\varepsilon_{ij}) = \sigma^2 \\ \forall i, j & \text{cov}(\varepsilon_{ij}, \varepsilon_{i'j'}) = 0 \end{cases}$$

Estimation des paramètres du modèle

Critère des moindres carrés : estimer les paramètres en minimisant la somme des carrés des écarts entre observations et prévisions par le modèle

Estimation des paramètres du modèle

Critère des moindres carrés : estimer les paramètres en minimisant la somme des carrés des écarts entre observations et prévisions par le modèle

$$Y \approx X\beta$$

$$X'Y \approx X'X\beta$$

$$\hat{\beta} = (X'X)^{-1}X'Y \quad \text{si } X'X \text{ est inversible}$$

Estimation des paramètres du modèle

Critère des moindres carrés : estimer les paramètres en minimisant la somme des carrés des écarts entre observations et prévisions par le modèle

$$Y \approx X\beta$$

$$X'Y \approx X'X\beta$$

$$\hat{\beta} = (X'X)^{-1}X'Y \quad \text{si } X'X \text{ est inversible}$$

Propriétés : $\mathbb{E}(\hat{\beta}) = \beta$; $\mathbb{V}(\hat{\beta}) = (X'X)^{-1}\sigma^2$

Estimation des paramètres du modèle

Critère des moindres carrés : estimer les paramètres en minimisant la somme des carrés des écarts entre observations et prévisions par le modèle

$$Y \approx X\beta$$

$$X'Y \approx X'X\beta$$

$$\hat{\beta} = (X'X)^{-1}X'Y \quad \text{si } X'X \text{ est inversible}$$

Propriétés : $\mathbb{E}(\hat{\beta}) = \beta$; $\mathbb{V}(\hat{\beta}) = (X'X)^{-1}\sigma^2$

La variance des résidus σ^2 est estimée par :

$$\hat{\sigma}^2 = \frac{\sum_i (Y_i - \hat{Y}_i)^2}{\text{nb données} - \text{nb paramètres estimés à partir des données}}$$

$$\mathbb{E}(\hat{\sigma}^2) = \sigma^2$$

Décomposition de la variabilité

$$\begin{array}{rcc} \text{Variabilité} & & \\ \text{totale} & = & \text{modèle} & + & \text{résiduelle} \\ \sum_{i=1}^n (y_i - \bar{y})^2 & = & \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 & + & \sum_{i=1}^n (y_i - \hat{y}_i)^2 \end{array}$$

Pourcentage de variabilité de Y expliquée par le modèle : $R^2 = \frac{SC_{modele}}{SC_{total}}$

Propriétés : $0 \leq R^2 \leq 1$

Décomposition de la variabilité

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Variabilité totale = Variabilité modèle + Variabilité résiduelle

Pourcentage de variabilité de Y expliquée par le modèle : $R^2 = \frac{SC_{modele}}{SC_{total}}$

Propriétés : $0 \leq R^2 \leq 1$

La variabilité du modèle peut être décomposée par variable de 2 façons :

- en calculant la variabilité expliquée par chaque variable les unes après les autres (pb : la variabilité d'une variable dépend de l'ordre d'introduction des variables)
- en calculant la variabilité expliquée exclusivement par une variable (pb : la somme des variabilités de toutes les variables n'est pas égale à la variabilité du modèle)

Dans certains cas (données équilibrées), la variabilité du modèle se décompose parfaitement et ces 2 calculs donnent les mêmes résultats

Exemple sur l'ozone

```
library(FactoMineR)
```

```
LinearModel(maxO3 ~ T0+T12+T15+Ne9+Ne12+Ne15+Vx9+Vx12+Vx15+maxO3v+pluie+vent, data=ozone)
```

Exemple sur l'ozone

```
library(FactoMineR)
LinearModel(maxO3 ~ ., data = ozone)    ## écriture simplifiée
```

Residual standard error: 14.51 on 97 degrees of freedom

Multiple R-squared: 0.7686

F-statistic: 23.01 on 14 and 97 DF, p-value: 8.744e-25

AIC = 613 BIC = 653.8

Ftest

| | SS | df | MS | F value | Pr(>F) |
|-----------|---------|----|--------|---------|-----------|
| T9 | 0.2 | 1 | 0.2 | 0.0011 | 0.97325 |
| T12 | 376.0 | 1 | 376.0 | 1.7868 | 0.18445 |
| T15 | 30.3 | 1 | 30.3 | 0.1439 | 0.70526 |
| Ne9 | 1016.5 | 1 | 1016.5 | 4.8312 | 0.03033 |
| Ne12 | 37.9 | 1 | 37.9 | 0.1803 | 0.67208 |
| Ne15 | 0.1 | 1 | 0.1 | 0.0003 | 0.98680 |
| Vx9 | 50.2 | 1 | 50.2 | 0.2388 | 0.62619 |
| Vx12 | 35.7 | 1 | 35.7 | 0.1697 | 0.68127 |
| Vx15 | 122.6 | 1 | 122.6 | 0.5826 | 0.44715 |
| maxO3v | 5560.4 | 1 | 5560.4 | 26.4261 | 1.421e-06 |
| vent | 297.8 | 3 | 99.3 | 0.4718 | 0.70267 |
| pluie | 182.9 | 1 | 182.9 | 0.8694 | 0.35344 |
| Residuals | 20410.2 | 97 | 210.4 | | |

Test de l'effet d'une ou plusieurs variables

Question : l'ensemble de variables \mathcal{V} apporte-t-il des informations complémentaires intéressantes sachant que les autres variables sont déjà dans le modèle ?

Hypothèses : H_0 : "tous les coefficients associés aux variables de \mathcal{V} sont égaux à 0" contre H_1 : "au moins un coefficient des variables \mathcal{V} est différent de 0"

Statistique de test : $F_{obs} = \frac{SC_{\mathcal{V}}/ddl_{\mathcal{V}}}{SC_R/ddl_R} = \frac{CM_{\mathcal{V}}}{CM_R}$

Loi de la statistique de test : Sous H_0 , $\mathcal{L}(F_{obs}) = \mathcal{F}_{ddl_{\mathcal{V}}}^{ddl_R}$

Décision : $\mathbb{P}(\mathcal{F}_{ddl_{\mathcal{V}}}^{ddl_R} > F_{obs}) < 0.05 \implies$ Rejet de H_0

Test de l'effet d'une ou plusieurs variables

Question : l'ensemble de variables \mathcal{V} apporte-t-il des informations complémentaires intéressantes sachant que les autres variables sont déjà dans le modèle ?

Hypothèses : H_0 : "tous les coefficients associés aux variables de \mathcal{V} sont égaux à 0" contre H_1 : "au moins un coefficient des variables \mathcal{V} est différent de 0"

Statistique de test : $F_{obs} = \frac{SC_{\mathcal{V}}/ddl_{\mathcal{V}}}{SC_R/ddl_R} = \frac{CM_{\mathcal{V}}}{CM_R}$

Loi de la statistique de test : Sous H_0 , $\mathcal{L}(F_{obs}) = \mathcal{F}_{ddl_{\mathcal{V}}}^{ddl_R}$

Décision : $\mathbb{P}(\mathcal{F}_{ddl_{\mathcal{V}}}^{ddl_R} > F_{obs}) < 0.05 \implies \text{Rejet de } H_0$

- Revient à choisir entre le sous-modèle sans les variables \mathcal{V} ou le modèle complet
- On teste le plus souvent \mathcal{V} avec 1 variable ou avec toutes les variables
- Si \mathcal{V} contient tous les effets : revient à tester si R^2 est significativement différent de 0, i.e. si toutes les variables sont inutiles (versus au moins une utile)
- On somme les degrés de liberté associés à l'ensemble \mathcal{V} sachant qu'1 variable quanti à 1 ddl, 1 variable quali à $I - 1$ ddl et une interaction a comme ddl le produit des ddl de chaque facteur

\implies Pour la séance de TD écrire le test pour 1 variable quali, celui pour 1 interaction, celui pour le test de toutes les variables

Sélection de variables

Comment sélectionner un « bon » sous-modèle ?

- sélectionner le modèle pour lequel la probabilité critique du test du R^2 est la plus petite (rejet de l'hypothèse : le modèle n'est pas intéressant)
- sélectionner le modèle qui minimise le critère AIC pour mieux prédire (ou BIC pour mieux sélectionner les variables) : ces critères sont un compromis entre un modèle qui maximise la vraisemblance (i.e. qui s'ajuste bien aux données), et qui n'a pas trop de paramètres (pénalité augmente avec le nombre de variables retenues)

Plusieurs stratégies :

- Construction exhaustive de tous les sous-modèles (long et même impossible si trop de variables)
- Méthode descendante (backward) : construire le modèle complet ; supprimer la variable explicative la moins intéressante et reconstruire le modèle sans cette variable ; itérer jusqu'à ce que toutes les variables explicatives soient intéressantes
- Méthode ascendante (forward) : partir du modèle avec la variable la plus intéressante ; ajouter la variable qui, connaissant les autres variables du modèle, apporte le plus d'information complémentaire ; itérer jusqu'à ce qu'aucune variable n'apporte d'information intéressante
- Méthode stepwise : compromis entre les 2 méthodes ci-dessus

Exemple sur l'ozone : sélection de variables

```
library(FactoMineR)
```

```
LinearModel(maxO3~., data=ozone, selection="bic")
```

```
Results for the complete model:
```

```
=====
```

```
Call:
```

```
LinearModel(formula = maxO3 ~ ., data = ozone, selection = "bic")
```

```
Residual standard error: 14.51 on 97 degrees of freedom
```

```
Multiple R-squared: 0.7686
```

```
F-statistic: 23.01 on 14 and 97 DF, p-value: 8.744e-25
```

```
AIC = 613 BIC = 653.8
```

```
Results for the model selected by BIC criterion:
```

```
=====
```

```
Call:
```

```
LinearModel(formula = maxO3 ~ T12 + Ne9 + Vx9 + maxO3v, data = ozone,  
            selection = "BIC")
```

```
Residual standard error: 14 on 107 degrees of freedom
```

```
Multiple R-squared: 0.7622
```

```
F-statistic: 85.75 on 4 and 107 DF, p-value: 1.763e-32
```

```
AIC = 596 BIC = 609.6
```

Exemple sur l'ozone : sélection de variables (suite)

Ftest

| | SS | df | MS | F value | Pr(>F) |
|-----------|----------|-----|---------|---------|-----------|
| T12 | 6650.39 | 1 | 6650.39 | 33.9334 | 6.073e-08 |
| Ne9 | 2714.81 | 1 | 2714.81 | 13.8522 | 0.0003172 |
| Vx9 | 903.37 | 1 | 903.37 | 4.6094 | 0.0340547 |
| maxO3v | 7363.50 | 1 | 7363.50 | 37.5721 | 1.499e-08 |
| Residuals | 20970.24 | 107 | 195.98 | NA | NA |

Ttest

| | Estimate | Std. Error | t value | Pr(> t) |
|-------------|-----------|------------|---------|----------|
| (Intercept) | 12.631310 | 11.000877 | 1.1482 | 0.25344 |
| T12 | 2.764090 | 0.474502 | 5.8252 | < 2e-16 |
| Ne9 | -2.515402 | 0.675845 | -3.7219 | 0.00032 |
| Vx9 | 1.292857 | 0.602180 | 2.1470 | 0.03405 |
| maxO3v | 0.354832 | 0.057888 | 6.1296 | < 2e-16 |

Démarche en modélisation

- 1 Lister les variables qui entrent en jeu pour expliquer ou prédire la variable réponse
- 2 Visualiser les données et notamment les liaisons avec la variable réponse
- 3 Ecrire puis construire le modèle en choisissant effets et interactions qui expliquent potentiellement la réponse (ne pas nécessairement tout mettre dans le modèle)
- 4 Sélectionner le sous-modèle qui minimise l'AIC (ou le BIC ou à la main) en supprimant les interactions et effets non utiles
- 5 Construire ce sous-modèle
- 6 Interpréter les résultats (les effets significatifs comme ceux non significatifs)
- 7 Interpréter les coefficients du modèle (attention aux confusions possibles notamment pour les variables quantitatives)
- 8 Prédire pour de nouvelles valeurs si vous avez un objectif de prédiction

Modélisation

Partie 2 : interprétation et prédiction

François Husson

Unité pédagogique de mathématiques appliquées
L'Institut Agro

Retour sur le codage et les contraintes pour variables qualitatives

La matrice X (dans $Y = X\beta + E$) a autant de lignes que d'individus et pour colonnes :

- une colonne de 1 est utilisée pour les constantes comme μ ou $\beta_0 \implies 1$ ddl
- chaque variable quantitative correspond à une colonne $\implies 1$ ddl
- chaque variable qualitative est transformée en autant d'indicateurs qu'elle a de modalités
Il suffit d'avoir $I - 1$ indicateurs pour estimer tous les paramètres \implies on pose une contrainte, le mieux est de prendre $\sum_{i=1}^I \alpha_i = 0 \implies (I - 1)$ ddl
- chaque interaction est codée par autant d'indicateurs qu'il y a de paires de modalités
On a alors besoin de seulement $(I - 1)(J - 1)$ indicateurs, d'où des contraintes $\forall i, \sum_j \alpha\beta_{ij} = 0$ et $\forall j, \sum_i \alpha\beta_{ij} = 0 \implies (I - 1)(J - 1)$ ddl

Remarque : le choix de la contrainte impacte FORTEMENT l'interprétation

- avec $\sum_i \alpha_i = 0$, la comparaison se fait par rapport à la moyenne des moyennes par modalité (un coefficient égal à 0 signifie que les résultats de la modalité ne sont pas différents de l'effet moyen)
- avec $\alpha_1 = 0$ (par défaut pour certaines fonctions de R, par ex. `lm`), la comparaison se fait par rapport au niveau 1 qui sert de référence \implies contrainte à proscrire quand il y a des interactions car l'interprétation devient très compliquée

Interprétation des résultats

Une fois le modèle sélectionné, on interprète l'absence ou la présence des différents effets (variable quantitative, variable qualitative, interactions)

Deux situations bien distinctes :

- Le cas d'interprétation idéal quand les données sont équilibrées
- La difficile interprétation des résultats pour des données déséquilibrées

Remarques :

- Le choix des données avec des plans d'expériences permet d'avoir des données équilibrées, et donc des résultats facilement interprétables
- Souvent en analyse de variance les données sont équilibrées (ou peu déséquilibrées)
- En régression ou analyse de covariance les données sont déséquilibrées dès qu'il y a une corrélation non nulle entre les variables explicatives (ce qui est quasi systématique sans plan d'expériences)

Décomposition de la variabilité : variables qualitatives, données équilibrées

Quand les données sont équilibrées, la décomposition de la variabilité est parfaite :

$$\begin{aligned} \sum_{i,j,k} (y_{ijk} - y_{\bullet\bullet\bullet})^2 &= \sum_{i,j,k} (y_{i\bullet\bullet} - y_{\bullet\bullet\bullet})^2 + \sum_{i,j,k} (y_{\bullet j\bullet} - y_{\bullet\bullet\bullet})^2 \\ &\quad + \sum_{i,j,k} (y_{ij\bullet} - y_{i\bullet\bullet} - y_{\bullet j\bullet} + y_{\bullet\bullet\bullet})^2 + \sum_{i,j,k} (y_{ijk} - y_{ij\bullet})^2 \end{aligned}$$

Décomposition de la variabilité : variables qualitatives, données équilibrées

Quand les données sont équilibrées, la décomposition de la variabilité est parfaite :

$$\begin{aligned} \sum_{i,j,k} (y_{ijk} - y_{\bullet\bullet\bullet})^2 &= \sum_{i,j,k} (y_{i\bullet\bullet} - y_{\bullet\bullet\bullet})^2 + \sum_{i,j,k} (y_{\bullet j\bullet} - y_{\bullet\bullet\bullet})^2 \\ &\quad + \sum_{i,j,k} (y_{ij\bullet} - y_{i\bullet\bullet} - y_{\bullet j\bullet} + y_{\bullet\bullet\bullet})^2 + \sum_{i,j,k} (y_{ijk} - y_{ij\bullet})^2 \end{aligned}$$

Quand les données sont équilibrées, les coefficients s'estiment simplement :

$$\begin{aligned} \hat{\mu} &= y_{\bullet\bullet\bullet} & \forall i, \hat{\alpha}_i &= y_{i\bullet\bullet} - y_{\bullet\bullet\bullet} \\ \forall j, \hat{\beta}_j &= y_{\bullet j\bullet} - y_{\bullet\bullet\bullet} & \forall i, j, \hat{\alpha}\hat{\beta}_{ij} &= y_{ij\bullet} - y_{i\bullet\bullet} - y_{\bullet j\bullet} + y_{\bullet\bullet\bullet} \end{aligned}$$

Décomposition de la variabilité : variables qualitatives, données équilibrées

Quand les données sont équilibrées, la décomposition de la variabilité est parfaite :

$$\begin{aligned} \sum_{i,j,k} (y_{ijk} - y_{\bullet\bullet\bullet})^2 &= \sum_{i,j,k} \underbrace{(y_{i\bullet\bullet} - y_{\bullet\bullet\bullet})^2}_{\hat{\alpha}_i^2} + \sum_{i,j,k} \underbrace{(y_{\bullet j\bullet} - y_{\bullet\bullet\bullet})^2}_{\hat{\beta}_j^2} \\ &+ \sum_{i,j,k} \underbrace{(y_{ij\bullet} - y_{i\bullet\bullet} - y_{\bullet j\bullet} + y_{\bullet\bullet\bullet})^2}_{\widehat{\alpha\beta}_{ij}^2} + \sum_{i,j,k} \underbrace{(y_{ijk} - y_{ij\bullet})^2}_{\epsilon_{ijk}^2} \end{aligned}$$

Quand les données sont équilibrées, les coefficients s'estiment simplement :

$$\begin{aligned} \hat{\mu} &= y_{\bullet\bullet\bullet} & \forall i, \hat{\alpha}_i &= y_{i\bullet\bullet} - y_{\bullet\bullet\bullet} \\ \forall j, \hat{\beta}_j &= y_{\bullet j\bullet} - y_{\bullet\bullet\bullet} & \forall i, j \hat{\alpha\beta}_{ij} &= y_{ij\bullet} - y_{i\bullet\bullet} - y_{\bullet j\bullet} + y_{\bullet\bullet\bullet} \end{aligned}$$

Décomposition de la variabilité : variables qualitatives, données équilibrées

Quand les données sont équilibrées, la décomposition de la variabilité est parfaite :

$$\begin{aligned} \sum_{i,j,k} (y_{ijk} - y_{\bullet\bullet\bullet})^2 &= \sum_{i,j,k} \underbrace{(y_{i\bullet\bullet} - y_{\bullet\bullet\bullet})^2}_{\hat{\alpha}_i^2} + \sum_{i,j,k} \underbrace{(y_{\bullet j\bullet} - y_{\bullet\bullet\bullet})^2}_{\hat{\beta}_j^2} \\ &+ \sum_{i,j,k} \underbrace{(y_{ij\bullet} - y_{i\bullet\bullet} - y_{\bullet j\bullet} + y_{\bullet\bullet\bullet})^2}_{\widehat{\alpha\beta}_{ij}^2} + \sum_{i,j,k} \underbrace{(y_{ijk} - y_{ij\bullet})^2}_{\varepsilon_{ijk}^2} \end{aligned}$$

Quand les données sont équilibrées, les coefficients s'estiment simplement :

$$\begin{aligned} \hat{\mu} &= y_{\bullet\bullet\bullet} & \forall i, \hat{\alpha}_i &= y_{i\bullet\bullet} - y_{\bullet\bullet\bullet} \\ \forall j, \hat{\beta}_j &= y_{\bullet j\bullet} - y_{\bullet\bullet\bullet} & \forall i, j, \widehat{\alpha\beta}_{ij} &= y_{ij\bullet} - y_{i\bullet\bullet} - y_{\bullet j\bullet} + y_{\bullet\bullet\bullet} \end{aligned}$$

⇒ On quantifie parfaitement ce qui est expliqué par chaque variable ou interaction

Décomposition de la variabilité : données déséquilibrées

Quand les données sont déséquilibrées, impossible de distinguer quel effet ou variable explique la variabilité. On parle de confusion (alias en anglais)

En sommant les variabilités de toutes les variables et de la résiduelle, on ne retrouve pas la variabilité totale (la somme est plus petite que la variabilité totale)

Quand les variables explicatives sont très corrélées, l'interprétation est très difficile
⇒ la sélection de variables évite les mauvaises interprétations (signe du coefficient de régression différent de celui de la corrélation), mais derrière l'effet d'une variable explicative, il peut y avoir celui d'autres variables non sélectionnées dans le modèle (non sélectionnée car elle n'apporte pas d'information supplémentaire significative par rapport aux autres variables ... même si elle influe sur la variable réponse)

Test de l'effet d'une variable qualitative – d'une interaction

Test de l'effet d'une variable qualitative (on l'a déjà vu!!) :

Question : Y a-t'il un effet du facteur A ? Est-ce que pour au moins une modalité les individus prennent des valeurs significativement différentes ?

Hypothèses : $H_0 : \forall i \alpha_i = 0$ contre $H_1 : \exists i / \alpha_i \neq 0$

Statistique de test : $F_{obs} = \frac{SC_A/ddl_A}{SC_R/ddl_R} = \frac{CM_A}{CM_R}$

Loi de la statistique de test : Sous H_0 , $\mathcal{L}(F_{obs}) = \mathcal{F}_{ddl_R}^{ddl_A}$

Décision : $\mathbb{P}(\mathcal{F}_{ddl_R}^{ddl_A} > F_{obs}) < 0.05 \implies \text{Rejet de } H_0$

Test de l'effet d'une variable qualitative – d'une interaction

Test de l'effet d'une variable qualitative (on l'a déjà vu!!) :

Question : Y a-t-il un effet du facteur A ? Est-ce que pour au moins une modalité les individus prennent des valeurs significativement différentes ?

Hypothèses : $H_0 : \forall i \alpha_i = 0$ contre $H_1 : \exists i / \alpha_i \neq 0$

Statistique de test : $F_{obs} = \frac{SC_A/ddl_A}{SC_R/ddl_R} = \frac{CM_A}{CM_R}$

Loi de la statistique de test : Sous H_0 , $\mathcal{L}(F_{obs}) = \mathcal{F}_{ddl_R}^{ddl_A}$

Décision : $\mathbb{P}(\mathcal{F}_{ddl_R}^{ddl_A} > F_{obs}) < 0.05 \implies$ Rejet de H_0

Test de l'effet d'une interaction : (c'est exactement pareil!!)

Question : Y a-t-il un effet de l'interaction ? Y a-t-il un effet conjoint (une interaction) des facteurs A et B sur Y ? Est-ce que pour une combinaison d'une modalité de A avec une modalité de B on a des valeurs de Y significativement plus élevées ou plus faibles qu'attendu avec un modèle additif ?

Hypothèses : $H_0 : \forall i, j \alpha_{\beta ij} = 0$ contre $H_1 : \exists(i, j) / \alpha_{\beta ij} \neq 0$

Statistique de test : $F_{obs} = \frac{SC_{interaction}/ddl_{interaction}}{SC_R/ddl_R} = \frac{CM_{interaction}}{CM_R}$

Loi de la statistique de test : Sous H_0 , $\mathcal{L}(F_{obs}) = \mathcal{F}_{ddl_R}^{ddl_{interaction}}$

Décision : $\mathbb{P}(\mathcal{F}_{ddl_R}^{ddl_{interaction}} > F_{obs}) < 0.05 \implies$ Rejet de H_0

Inférence : test d'un coefficient

Question : ce coefficient α_1 (par exemple) est-il différent de 0 ? La modalité 1 donne-t-elle des résultats significativement différents de la moyenne ?

Hypothèses : $H_0 : \alpha_1 = 0$ contre $H_1 : \alpha_1 \neq 0$

Statistique de test : $T_{obs} = \frac{\hat{\alpha}_1}{\hat{\sigma}_{\hat{\alpha}_1}}$

Loi de la statistique de test sous H_0 : $\mathcal{L}(T_{obs}) = \mathcal{T}_{ddl_R}$ (loi de Student)

Décision : $\mathbb{P}(\mathcal{T}_{ddl_R} > |T_{obs}|) < 0.05 \implies \text{Rejet de } H_0$

Inférence : test d'un coefficient

Question : ce coefficient α_1 (par exemple) est-il différent de 0 ? La modalité 1 donne-t-elle des résultats significativement différents de la moyenne ?

Hypothèses : $H_0 : \alpha_1 = 0$ contre $H_1 : \alpha_1 \neq 0$

Statistique de test : $T_{obs} = \frac{\hat{\alpha}_1}{\hat{\sigma}_{\hat{\alpha}_1}}$

Loi de la statistique de test sous H_0 : $\mathcal{L}(T_{obs}) = \mathcal{T}_{ddl_R}$ (loi de Student)

Décision : $\mathbb{P}(\mathcal{T}_{ddl_R} > |T_{obs}|) < 0.05 \implies \text{Rejet de } H_0$

Remarque : ce test en régression revient à tester si 1 variable quantitative a un effet significatif

Comparaison des moyennes ajustées

Travailler sur les moyennes ajustées ($\hat{\mu} + \hat{\alpha}_i$) permet de s'affranchir de l'effet des autres variables, i.e. de neutraliser l'effet des autres variables

On peut comparer les modalités 2 à 2 grâce à un test de comparaison par paire, avec une correction de Bonferroni par exemple

```
mod <- LinearModel(sucre~choc+juge+choc:juge, data=chocolats)
meansComp(mod,~choc, adjust="bonferonni")
```


```
$adjMean
```

| choc | emmean | SE | df | lower.CL | upper.CL |
|-------|--------|-------|-----|----------|----------|
| choc1 | 3.14 | 0.243 | 174 | 2.66 | 3.62 |
| choc2 | 4.62 | 0.243 | 174 | 4.14 | 5.10 |
| choc3 | 7.60 | 0.243 | 174 | 7.12 | 8.08 |
| choc4 | 4.29 | 0.243 | 174 | 3.81 | 4.77 |
| choc5 | 5.22 | 0.243 | 174 | 4.74 | 5.70 |
| choc6 | 5.62 | 0.243 | 174 | 5.14 | 6.10 |

Results are averaged over the levels of: juge
Confidence level used: 0.95

```
$groupComp
```

| choc1 | choc4 | choc2 | choc5 | choc6 | choc3 |
|-------|-------|-------|-------|-------|-------|
| "a" | "b" | "b" | "bc" | "c" | "d" |



Prévisions

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_p x_{ip}$$

Prédire Y pour : (T12=19, Ne9=8, Vx9=1.2, maxO3v=70) et (T12=23, Ne9=10, Vx9=0.9, maxO3v=95)

| | Estimate | Std. Error | t value | Pr(> t) |
|-------------|-----------|------------|---------|----------|
| (Intercept) | 12.631310 | 11.000877 | 1.1482 | 0.25344 |
| T12 | 2.764090 | 0.474502 | 5.8252 | < 2e-16 |
| Ne9 | -2.515402 | 0.675845 | -3.7219 | 0.00032 |
| Vx9 | 1.292857 | 0.602180 | 2.1470 | 0.03405 |
| maxO3v | 0.354832 | 0.057888 | 6.1296 | < 2e-16 |

Calcul à la main de la prédiction 1 = 12.63 + 2.764*19 - 2.515*8 + 1.292*1.2 + 0.354*70 = 71.41544

Sur ordinateur :

```
xnew <- data.frame(T12=c(19,23), Ne9=c(8,10), Vx9=c(1.2,0.9), maxO3v=c(70,95))
predict(model,xnew,interval="pred")
```

```
      fit      lwr      upr
1 71.41544 42.90026 99.93063
2 85.92393 56.76803 115.07983
```


```
predict(model,xnew,interval="confidence")
```

```
      fit      lwr      upr
1 71.41544 64.86327 77.96761
2 85.92393 76.98627 94.86159
```

Analyse des résidus du modèle

Test de Bartlett de l'homoscédasticité
des **Résidus**


```
model <- lm(maxO3~T12+...,data=ozone)
res <- residuals(model)
boxplot(res~vent,data=ozone)
bartlett.test(res~vent,data=ozone)
```



Analyse des résidus du modèle


Test de Bartlett de l'homoscédasticité des **Résidus**

```
model <- lm(maxO3~T12+...,data=ozone)
res <- residuals(model)
boxplot(res~vent,data=ozone)
bartlett.test(res~vent,data=ozone)
```



Test de Shapiro-Wilk de normalité des **Résidus**
(Rq : la non-normalité n'est pas un pb tant que la distribution est symétrique)

```
model <- lm(maxO3~T12+...,data=ozone)
res <- residuals(model)
hist(res,main="Histogramme résidus",xlab="Résidus")
shapiro.test(res)
```



Retour sur l'exemple ozone

- On s'intéresse au maximum d'ozone : variable réponse
- Les variables de températures, nébulosité, vitesse de vent (quanti), et la direction et la pluie (quali) sont prises en compte
- On ne sait pas si les interactions entre variables quali et entre les variables quanti et quali sont négligeables \implies on les met dans le modèle
- On écrit le modèle :

```
LinearModel(maxO3 ~ (T9 + T12 + T15 + Ne9 + Ne12 + Ne15 + Vx9 + Vx12 + Vx15 +  
maxO3v + pluie + vent) * (pluie + vent), data=ozone, selection="bic")
```

Retour sur l'exemple ozone

- On s'intéresse au maximum d'ozone : variable réponse
- Les variables de températures, nébulosité, vitesse de vent (quanti), et la direction et la pluie (quali) sont prises en compte
- On ne sait pas si les interactions entre variables quali et entre les variables quanti et quanti sont négligeables \implies on les met dans le modèle
- On écrit le modèle :

```
LinearModel(maxO3 ~ (T9 + T12 + T15 + Ne9 + Ne12 + Ne15 + Vx9 + Vx12 + Vx15 +  
maxO3v + pluie + vent) * (pluie + vent), data=ozone, selection="bic")
```

Ce qui revient à écrire :

```
maxO3 ~ T9 + T12 + T15 + Ne9 + Ne12 + Ne15 + Vx9 + Vx12 + Vx15 + maxO3v + pluie + vent +  
T9:pluie + T12:pluie + T15:pluie + Ne9:pluie + Ne12:pluie + Ne15:pluie +  
Vx9:pluie + Vx12:pluie + Vx15:pluie + maxO3v:pluie + vent:pluie +  
T9:vent + T12:vent + T15:vent + Ne9:vent + Ne12:vent + Ne15:vent +  
Vx9:vent + Vx12:vent + Vx15:vent + maxO3v:vent
```

On sélectionne le sous-modèle

Results for the complete model:

=====

Call:

```
LinearModel(formula = maxO3 ~ (T9 + T12 + T15 + Ne9 + Ne12 + Ne15 +  
  Vx9 + Vx12 + Vx15 + maxO3v + pluie + vent) * (pluie + vent),  
  data = ozone, selection = "bic")
```

Residual standard error: 14.54 on 56 degrees of freedom

Multiple R-squared: 0.8658

F-statistic: 6.569 on 55 and 56 DF, p-value: 2.585e-11

AIC = 634 BIC = 786.2

Results for the model selected by BIC criterion:

=====

Call:

```
LinearModel(formula = maxO3 ~ T9 + T15 + Ne12 + Vx9 + maxO3v + vent +  
  T9:vent + T15:vent, data = ozone, selection = "bic")
```

Residual standard error: 13.8 on 97 degrees of freedom

Multiple R-squared: 0.7906

F-statistic: 26.16 on 14 and 97 DF, p-value: 8.082e-27

AIC = 601.8 BIC = 642.6

Et maintenant le plus intéressant : l'interprétation des résultats

On donne quelques extraits d'interprétation !

Ftest

| | SS | df | MS | F value | Pr(>F) |
|-----------|---------|----|--------|---------|-----------|
| T9 | 698.9 | 1 | 698.9 | 3.6710 | 0.0583123 |
| T15 | 557.5 | 1 | 557.5 | 2.9279 | 0.0902552 |
| Ne12 | 2107.0 | 1 | 2107.0 | 11.0664 | 0.0012425 |
| Vx9 | 1657.3 | 1 | 1657.3 | 8.7046 | 0.0039790 |
| maxO3v | 5160.8 | 1 | 5160.8 | 27.1060 | 1.078e-06 |
| vent | 182.9 | 3 | 61.0 | 0.3202 | 0.8107707 |
| T9:vent | 2587.1 | 3 | 862.4 | 4.5294 | 0.0051335 |
| T15:vent | 3722.1 | 3 | 1240.7 | 6.5165 | 0.0004613 |
| Residuals | 18468.3 | 97 | 190.4 | | |

On peut dire (à partir des effets significatifs) qu'il y a, sur le max d'O3 :

- des effets de nébulosité, de vitesse de vent, du maximum d'O3 de la veille
- des effets de la direction du vent et des températures mais à travers les interactions : la direction du vent modifie l'effet de la T° (i.e. amplifie l'effet de la T° ou la diminue selon la direction du vent) sur max O3

Et maintenant le plus intéressant : l'interprétation des résultats

On donne quelques extraits d'interprétation !

Ftest

| | SS | df | MS | F value | Pr(>F) |
|-----------|---------|----|--------|---------|-----------|
| T9 | 698.9 | 1 | 698.9 | 3.6710 | 0.0583123 |
| T15 | 557.5 | 1 | 557.5 | 2.9279 | 0.0902552 |
| Ne12 | 2107.0 | 1 | 2107.0 | 11.0664 | 0.0012425 |
| Vx9 | 1657.3 | 1 | 1657.3 | 8.7046 | 0.0039790 |
| maxO3v | 5160.8 | 1 | 5160.8 | 27.1060 | 1.078e-06 |
| vent | 182.9 | 3 | 61.0 | 0.3202 | 0.8107707 |
| T9:vent | 2587.1 | 3 | 862.4 | 4.5294 | 0.0051335 |
| T15:vent | 3722.1 | 3 | 1240.7 | 6.5165 | 0.0004613 |
| Residuals | 18468.3 | 97 | 190.4 | | |

On peut dire (à partir des effets significatifs) qu'il y a, sur le max d'O3 :

- des effets de nébulosité, de vitesse de vent, du maximum d'O3 de la veille
- des effets de la direction du vent et des températures mais à travers les interactions : la direction du vent modifie l'effet de la T° (i.e. amplifie l'effet de la T° ou la diminue selon la direction du vent) sur max O3

On peut aussi dire (à partir des absences d'effets significatifs) :

- la pluviométrie n'est pas un facteur déterminant qui influe sur le max d'O3
- une seule nébulosité (Ne12) est conservée dans le modèle : cela ne veut pas dire que les autres nébulosités n'ont pas d'effet (elles peuvent avoir un effet similaire). Idem pour la vitesse de vent.
- pour la T°, on a besoin des T° à 9h et à 15h pour mieux prévoir le maximum d'ozone. L'effet de la T° n'est pas exactement le même entre 9h et 15h (mais 12h n'est pas utile comme info)
- l'effet de la nébulosité est le même quelle que soit la direction du vent. Idem pour la vitesse du vent.
- etc.

Et maintenant le plus intéressant : l'interprétation des résultats

Et on affine les interprétations

Ttest

| | Estimate | Std. Error | t value | Pr(> t) |
|--------------------|-----------|------------|---------|-----------|
| (Intercept) | 18.206308 | 13.705946 | 1.3284 | 0.187179 |
| T9 | 1.826916 | 1.023832 | 1.7844 | 0.077487 |
| T15 | 1.020017 | 0.885187 | 1.1523 | 0.252022 |
| Ne12 | -3.013169 | 0.905775 | -3.3266 | 0.001243 |
| Vx9 | 2.221261 | 0.752878 | 2.9504 | 0.003979 |
| maxO3v | 0.346696 | 0.066591 | 5.2063 | 1.078e-06 |
| vent - Est | 0.473424 | 17.010219 | 0.0278 | 0.977854 |
| vent - Nord | 3.297358 | 15.035620 | 0.2193 | 0.826875 |
| vent - Ouest | -1.125022 | 14.006616 | -0.0803 | 0.936148 |
| vent - Sud | -2.645761 | 15.148862 | -0.1747 | 0.861718 |
| vent - Est : T9 | -4.744227 | 2.141774 | -2.2151 | 0.029094 |
| vent - Nord : T9 | 6.140768 | 1.701384 | 3.6093 | 0.000488 |
| vent - Ouest : T9 | -0.950539 | 1.345534 | -0.7064 | 0.481608 |
| vent - Sud : T9 | -0.446002 | 1.522150 | -0.2930 | 0.770142 |
| vent - Est : T15 | 3.680964 | 1.796744 | 2.0487 | 0.043194 |
| vent - Nord : T15 | -5.227943 | 1.215336 | -4.3016 | 4.045e-05 |
| vent - Ouest : T15 | 0.979689 | 0.930826 | 1.0525 | 0.295188 |
| vent - Sud : T15 | 0.567290 | 1.111141 | 0.5105 | 0.610828 |

- pour T9 et T15, coefficients non significativement différents de 0
- plus il y a de nébulosité, moins le max d'O3 est grand (**on vérifie que le signe est le même que celui de la corrélation**)
- plus le maximum d'O3 de la veille est grand, plus le maximum d'O3 est grand
- les jours de vents d'est et surtout du nord ont des max d'O3 supérieur aux jours de vents d'ouest et du sud
- les jours de vent du nord, l'effet de la T° à 9h est plus important (coef = 6.14); au contraire quand le vent vient de l'est. C'est l'inverse pour la T° à 15h
- Ainsi, quand le vent vient du nord, l'effet de la T° à 9h est particulièrement fort (donc s'il fait chaud à 9h quand le vent vient du nord, le max d'O3 risque d'être important)
- etc.

Pour conclure : démarche en modélisation

- 1 Lister les variables qui entrent en jeu pour expliquer ou prédire la variable réponse
- 2 Visualiser les données et notamment les liaisons avec la variable réponse
- 3 Ecrire puis construire le modèle en choisissant effets et interactions qui expliquent potentiellement la réponse (ne pas nécessairement tout mettre dans le modèle)
- 4 Sélectionner le sous-modèle qui minimise le BIC en supprimant les interactions et effets non utiles
- 5 Construire ce sous-modèle
- 6 Interpréter les résultats (les effets significatifs comme ceux non significatifs)
- 7 Interpréter les coefficients du modèle (attention aux confusions possibles notamment pour les variables quantitatives)
- 8 Prédire pour de nouvelles valeurs si vous avez un objectif de prédiction

Et évidemment, cela peut suggérer de nouvelles analyses !! (synthétiser des variables, rendre qualitatives certaines variables, ajouter d'autres variables, etc.)