

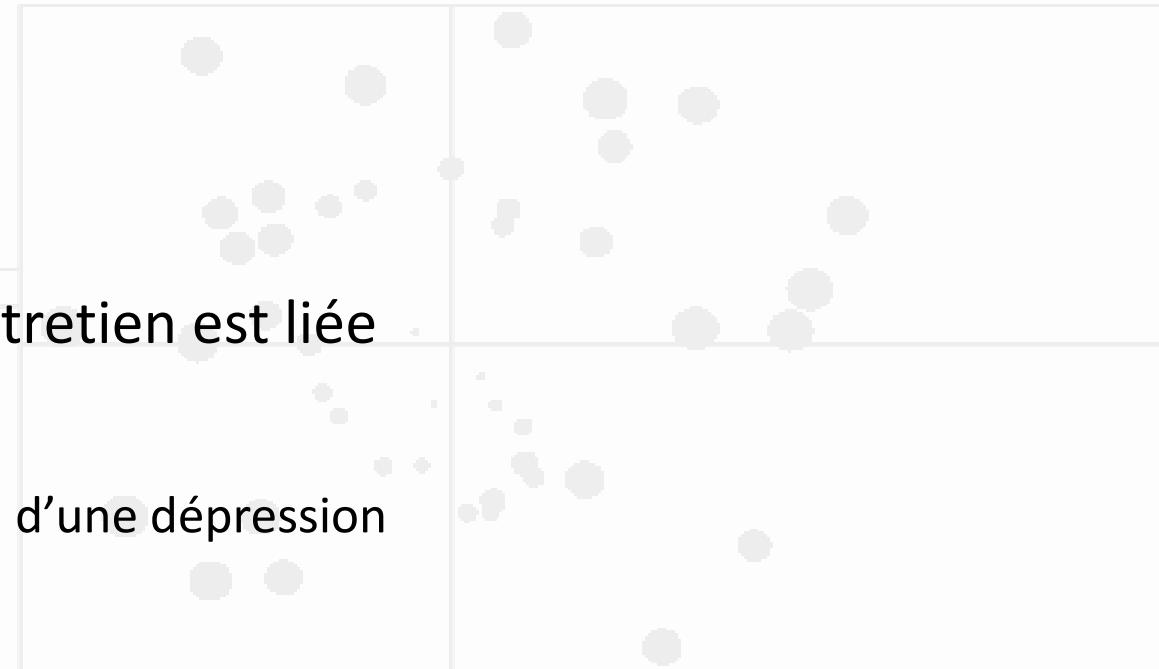
Régression linéaire multiple Analyse de variance

Régression linéaire multiple



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

- La durée d'entretien est liée
 - À l'âge
 - À l'existence d'une dépression



- La durée d'entretien est liée
 - À l'âge
 - À l'existence d'une dépression
 - À l'existence d'un abus de substance
 - À l'existence d'un trouble schizophrénique
- Comment faire la part des choses ?

- La durée d'entretien est liée
 - À l'âge
 - À l'existence d'une dépression
 - À l'existence d'un abus de substance
 - À l'existence d'un trouble schizophrénique
- Comment faire la part des choses ?

$$\text{Durée} = a + b \times \text{age} + c \times \text{dep} + d \times \text{subst} + e \times \text{scz} + \text{bruit}$$

- La durée d'entretien est liée
 - À l'âge
 - À l'existence d'une dépression
 - À l'existence d'un abus de substance
 - À l'existence d'un trouble schizophrénique

- Comment faire la part des choses ?

$$\text{Durée} = a + b \times \text{age} + c \times \text{dep} + d \times \text{subst} + e \times \text{scz} + \text{bruit}$$

$$b \neq 0 ?$$

- La durée d'entretien est liée
 - À l'âge
 - À l'existence d'une dépression
 - À l'existence d'un abus de substance
 - À l'existence d'un trouble schizophrénique

- Comment faire la part des choses ?

$$\text{Durée} = a + b \times \text{age} + c \times \text{dep} + d \times \text{subst} + e \times \text{scz} + \text{bruit}$$

$$b \neq 0 ?$$

Régression linéaire multiple



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons,data=smp.1)
> summary(mod3)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons + subst.cons + scz.cons,
  data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-63.654	-14.522	-1.193	11.482	62.482

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	48.90105	2.62213	18.649	< 2e-16 ***
age	0.22096	0.05708	3.871	0.000118 ***
dep.cons	7.38932	1.44783	5.104	4.24e-07 ***
subst.cons	5.25157	1.74318	3.013	0.002678 **
scz.cons	2.27256	2.52323	0.901	0.368062

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 19.1 on 742 degrees of freedom
(52 observations deleted due to missingness)

Multiple R-squared: 0.05833, Adjusted R-squared: 0.05325
F-statistic: 11.49 on 4 and 742 DF, p-value: 4.692e-09

Régression linéaire multiple

Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons,data=smp.1)
> summary(mod3)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons + subst.cons + scz.cons,
  data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-63.654	-14.522	-1.193	11.482	62.482

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	48.90105	2.62213	18.649	< 2e-16 ***
age	0.22096	0.05708	3.871	0.000118 ***
dep.cons	7.38932	1.44783	5.104	4.24e-07 ***
subst.cons	5.25157	1.74318	3.013	0.002678 **
scz.cons	2.27256	2.52323	0.901	0.368062

Signif. codes:	0 '***'	0.001 '**'	0.01 '*'	0.05 '.'
	0.1 ' '	1		

Residual standard error: 19.1 on 742 degrees of freedom

(52 observations deleted due to missingness)

Multiple R-squared: 0.05833, Adjusted R-squared: 0.05325

F-statistic: 11.49 on 4 and 742 DF, p-value: 4.692e-09

$$\text{Durée} = a + b \times \text{age} + c \times \text{dep} + d \times \text{subst} + e \times \text{scz} + \text{bruit}$$

Régression linéaire multiple

Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons,data=smp.1)
> summary(mod3)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons + subst.cons + scz.cons,
  data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-63.654	-14.522	-1.193	11.482	62.482

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	48.90105	2.62213	18.649	< 2e-16 ***
age	0.22096	0.05708	3.871	0.000118 ***
dep.cons	7.38932	1.44783	5.104	4.24e-07 ***
subst.cons	5.25157	1.74318	3.013	0.002678 **
scz.cons	2.27256	2.52323	0.901	0.368062

Signif. codes:	0 '***'	0.001 '**'	0.01 '*'	0.05 '.'
	0.1 ' '	1		

Residual standard error: 19.1 on 742 degrees of freedom

(52 observations deleted due to missingness)

Multiple R-squared: 0.05833, Adjusted R-squared: 0.05325

F-statistic: 11.49 on 4 and 742 DF, p-value: 4.692e-09

Durée = a + b × age + c × dep + d × subst + e × scz + bruit

Régression linéaire multiple

Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons,data=smp.1)
> summary(mod3)

Call:
lm(formula = dur.interv ~ age + dep.cons + subst.cons + scz.cons,
    data = smp.1)

Residuals:
    Min      1Q  Median      3Q     Max 
-63.654 -14.522 -1.193  11.482  62.482 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 48.90105   2.62213 18.649 < 2e-16 ***
age          0.22096   0.05708  3.871 0.000118 ***
dep.cons     7.38932   1.44783  5.104 4.24e-07 ***
subst.cons   5.25157   1.74318  3.013 0.002678 **  
scz.cons     2.27256   2.52323  0.901 0.368062  
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 19.1 on 742 degrees of freedom
(52 observations deleted due to missingness)
Multiple R-squared:  0.05833,  Adjusted R-squared:  0.05325 
F-statistic: 11.49 on 4 and 742 DF,  p-value: 4.692e-09
```

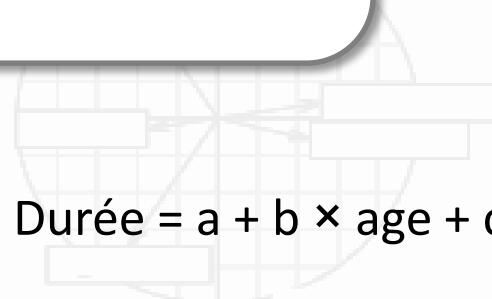
Durée = a + b × age + c × dep + d × subst + e × scz + bruit

Variable à expliquer = a + b × variable explicative 1 + ... + bruit

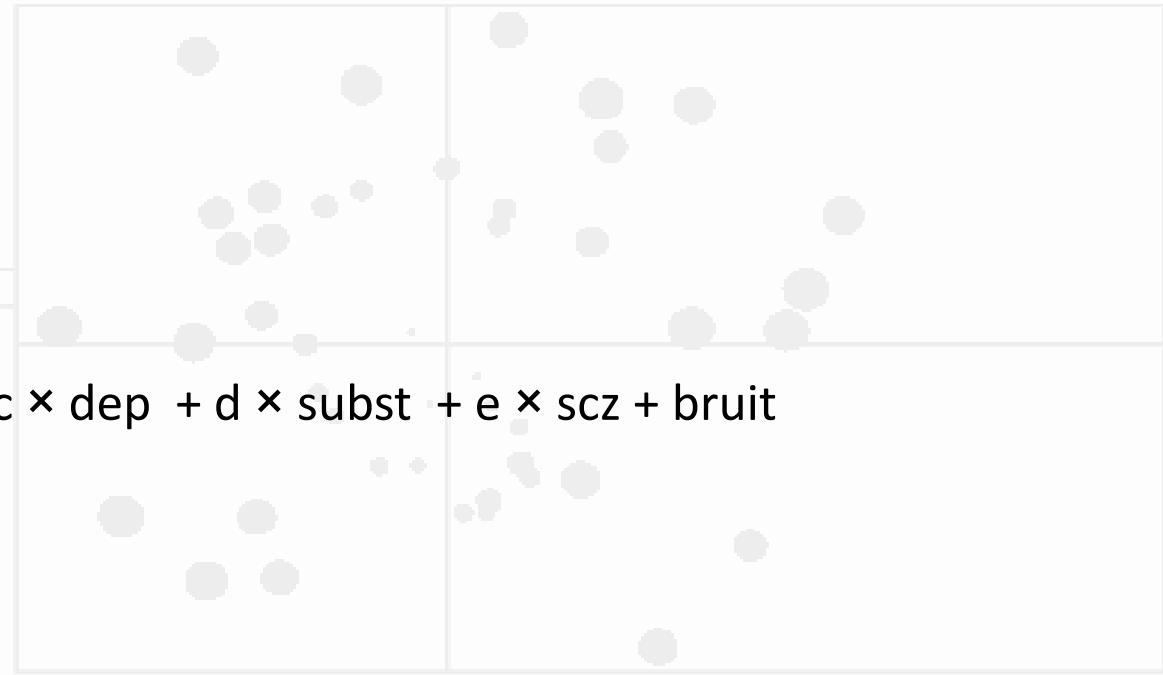
Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA



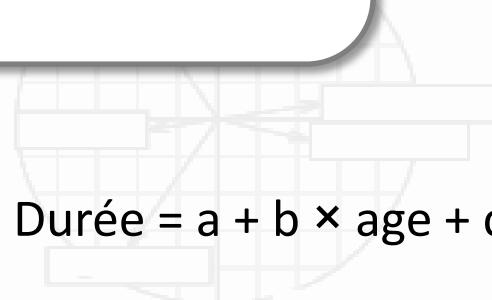
$$\text{Durée} = a + b \times \text{age} + c \times \text{dep} + d \times \text{subst} + e \times \text{scz} + \text{bruit}$$



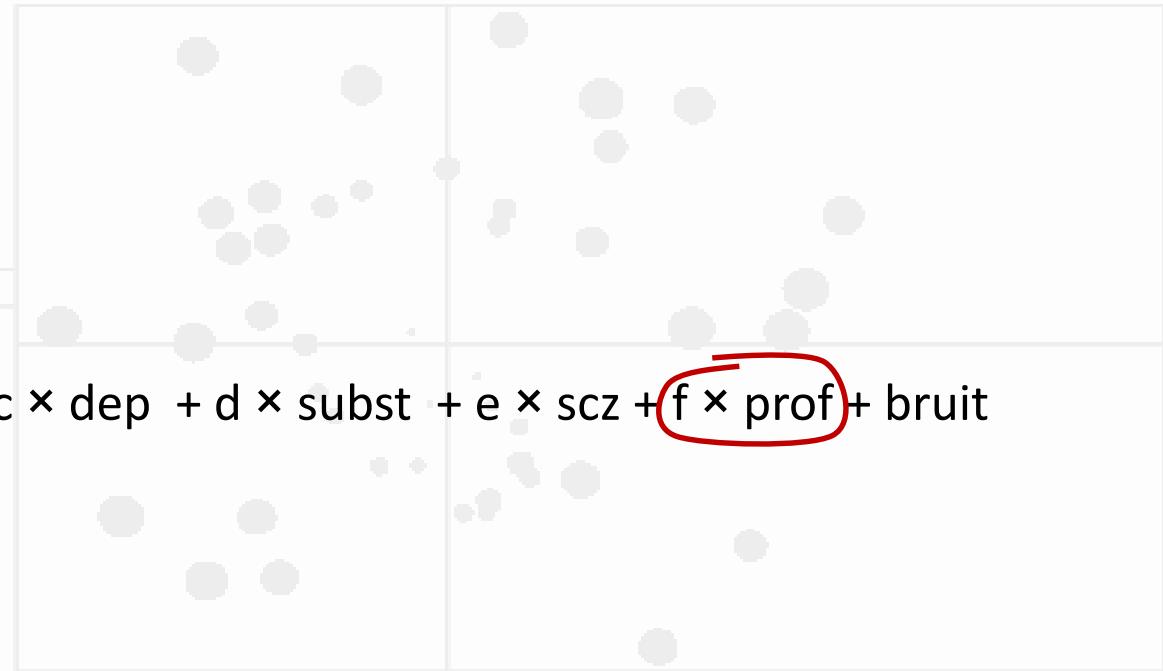
Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA



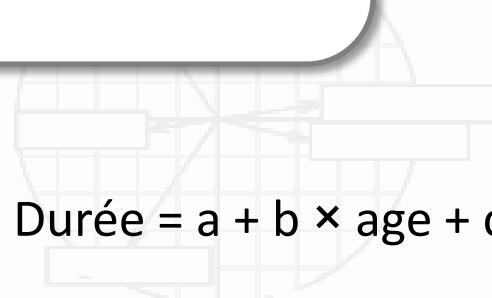
$$\text{Durée} = a + b \times \text{age} + c \times \text{dep} + d \times \text{subst} + e \times \text{scz} + f \times \text{prof} + \text{bruit}$$



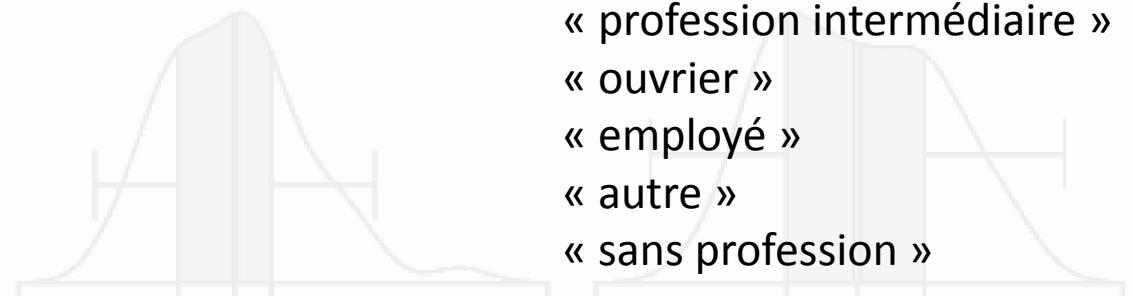
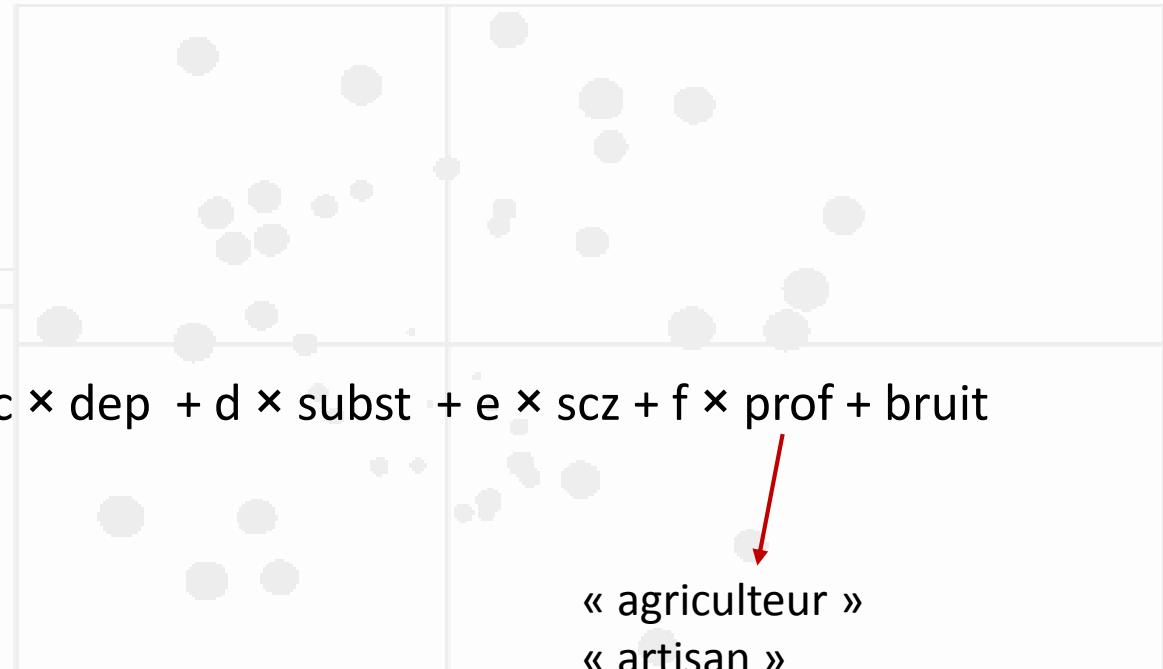
Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA



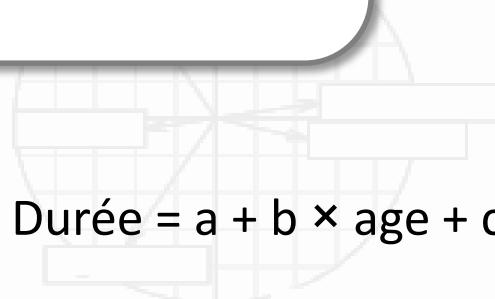
$$\text{Durée} = a + b \times \text{age} + c \times \text{dep} + d \times \text{subst} + e \times \text{scz} + f \times \text{prof} + \text{bruit}$$



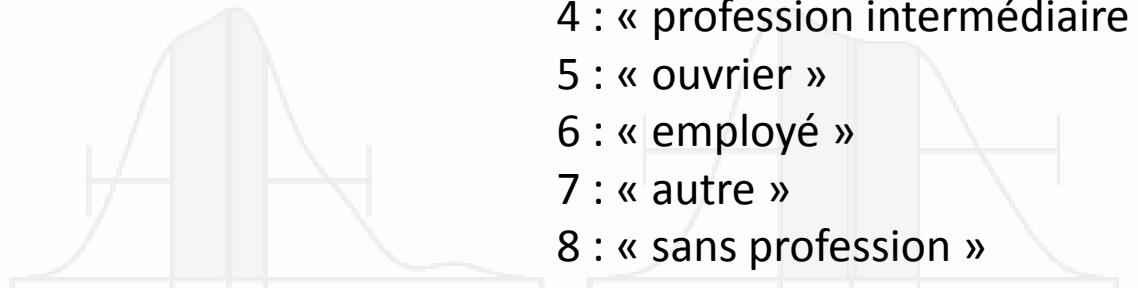
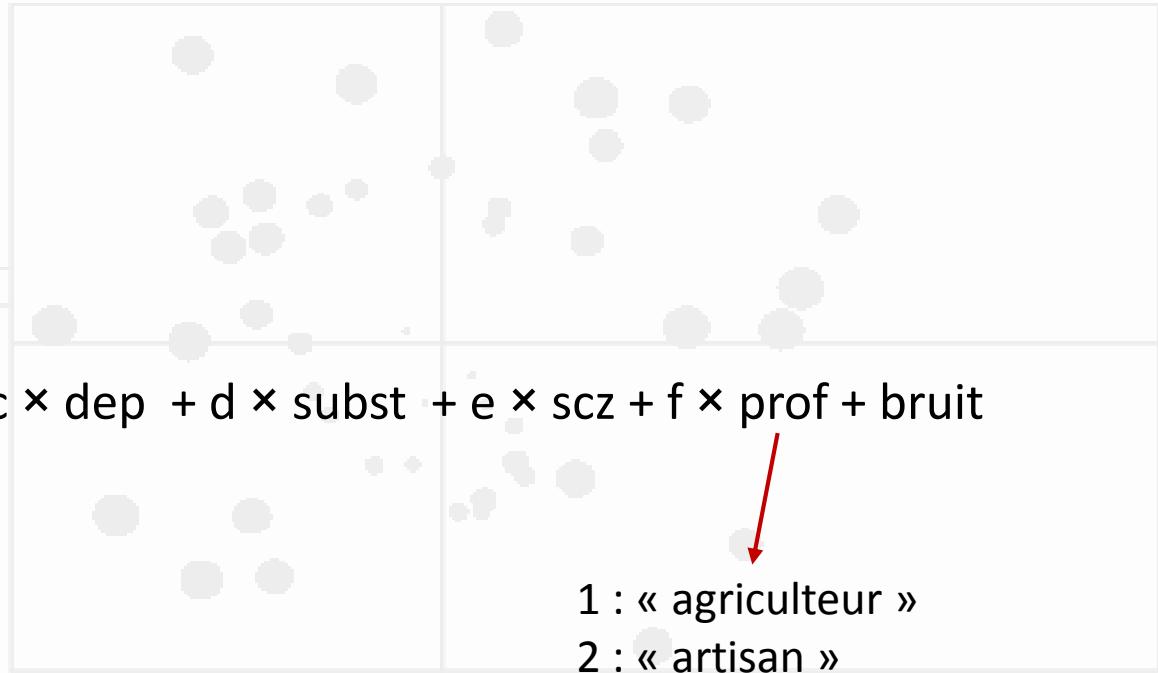
Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA



$$\text{Durée} = a + b \times \text{age} + c \times \text{dep} + d \times \text{subst} + e \times \text{scz} + f \times \text{prof} + \text{bruit}$$



Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

$$\text{Durée} = a + b \times \text{age} + c \times \text{dep} + d \times \text{subst} + e \times \text{scz} + f \times \text{prof} + \text{bruit}$$

- f1 : artisan=1 vs 0
- f2 : cadre=1 vs 0
- f3 : prof inter=1 vs 0
- f4 : ouvrier=1 vs 0
- f5 : employé=1 vs 0
- f6 : autre=1 vs 0
- f7 : sans prof=1 vs 0

- « agriculteur »
- « artisan »
- « cadre »
- « profession intermédiaire »
- « ouvrier »
- « employé »
- « autre »
- « sans profession »

Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> mod4 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
> summary(mod4)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons + subst.cons + scz.cons +
    prof, data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-63.280	-14.164	-1.337	10.959	63.184

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	62.79202	10.20779	6.151	1.26e-09 ***
age	0.21289	0.05884	3.618	0.000317 ***
dep.cons	7.36792	1.45840	5.052	5.53e-07 ***
subst.cons	5.34589	1.76902	3.022	0.002599 **
scz.cons	2.50439	2.54734	0.983	0.325863
profartisan	-11.48515	9.82936	-1.168	0.243005
profautre	-10.28748	10.33482	-0.995	0.319862
profcadre	-19.29636	10.38568	-1.858	0.063574 .
profemployé	-13.55809	9.76340	-1.389	0.165358
profouvrier	-14.01270	9.72111	-1.441	0.149880
profprof.intermédiaire	-13.01926	9.96911	-1.306	0.191977
profsans emploi	-14.27866	9.71782	-1.469	0.142174

Signif. codes: 0 '****' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 19.11 on 731 degrees of freedom

(56 observations deleted due to missingness)

Multiple R-squared: 0.06595, Adjusted R-squared: 0.05189

F-statistic: 4.692 on 11 and 731 DF, p-value: 5.825e-07

Durée = a + b × age + c × dep + d × subst + e × scz + f × prof + bruit



Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> mod4 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof,data=smp.1)
> summary(mod4)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons + subst.cons + scz.cons +
    prof, data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-63.280	-14.164	-1.337	10.959	63.184

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	62.79202	10.20779	6.151	1.26e-09 ***
age	0.21289	0.05884	3.618	0.000317 ***
dep.cons	7.36792	1.45840	5.052	5.53e-07 ***
subst.cons	5.34589	1.76902	3.022	0.002599 **
scz.cons	2.50439	2.54734	0.983	0.325863
profartisan	-11.48515	9.82936	-1.168	0.243005
profautre	-10.28748	10.33482	-0.995	0.319862
profcadre	-19.29636	10.38568	-1.858	0.063574 .
profemployé	-13.55809	9.76340	-1.389	0.165358
profouvrier	-14.01270	9.72111	-1.441	0.149880
profprof.intermédiaire	-13.01926	9.96911	-1.306	0.191977
profsans emploi	-14.27866	9.71782	-1.469	0.142174

Signif. codes: 0 '****' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 19.11 on 731 degrees of freedom

(56 observations deleted due to missingness)

Multiple R-squared: 0.06595, Adjusted R-squared: 0.05189

F-statistic: 4.692 on 11 and 731 DF, p-value: 5.825e-07

Durée = a + b × age + c × dep + d × subst + e × scz + f × prof + bruit



Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> mod4 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof,data=smp.1)
> summary(mod4)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons + subst.cons + scz.cons +
    prof, data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-63.280	-14.164	-1.337	10.959	63.184

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	62.79202	10.20779	6.151	1.26e-09 ***
age	0.21289	0.05884	3.618	0.000317 ***
dep.cons	7.36792	1.45840	5.052	5.53e-07 ***
subst.cons	5.34589	1.76902	3.022	0.002599 **
scz.cons	2.50439	2.54734	0.983	0.325863
profartisan	-11.48515	9.82936	-1.168	0.243005
profautre	-10.28748	10.33482	-0.995	0.319862
profcadre	-19.29636	10.38568	-1.858	0.063574 .
profemployé	-13.55809	9.76340	-1.389	0.165358
profouvrier	-14.01270	9.72111	-1.441	0.149880
profprof.intermédiaire	-13.01926	9.96911	-1.306	0.191977
profsans emploi	-14.27866	9.71782	-1.469	0.142174

Signif. codes: 0 '****' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 19.11 on 731 degrees of freedom

(56 observations deleted due to missingness)

Multiple R-squared: 0.06595, Adjusted R-squared: 0.05189

F-statistic: 4.692 on 11 and 731 DF, p-value: 5.825e-07

$$\text{Durée} = a + b \times \text{age} + c \times \text{dep} + d \times \text{subst} + e \times \text{scz} + f \times \text{prof} + \text{bruit}$$

Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> smp.1$prof <- relevel(smp.1$prof, ref="ouvrier")
> mod5 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
> summary(mod5)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons + subst.cons + scz.cons +
    prof, data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-63.280	-14.164	-1.337	10.959	63.184

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)		
(Intercept)	48.77932	2.83938	17.180	< 2e-16 ***		
age	0.21289	0.05884	3.618	0.000317 ***		
dep.cons	7.36792	1.45840	5.052	5.53e-07 ***		
subst.cons	5.34589	1.76902	3.022	0.002599 **		
scz.cons	2.50439	2.54734	0.983	0.325863		
profagriculteur	14.01270	9.72111	1.441	0.149880		
profartisan	2.52755	2.48989	1.015	0.310381		
profautre	3.72522	3.99637	0.932	0.351567		
profcadre	-5.28366	4.25567	-1.242	0.214798		
profemployé	0.45460	2.12659	0.214	0.830785		
profprof.intermédiaire	0.99344	2.95809	0.336	0.737089		
profsans emploi	-0.26596	1.87727	-0.142	0.887375		

Signif. codes:	0 '***'	0.001 '**'	0.01 '*'	0.05 '.'	0.1 ' '	1

Residual standard error: 19.11 on 731 degrees of freedom
(56 observations deleted due to missingness)

Multiple R-squared: 0.06595, Adjusted R-squared: 0.05189
F-statistic: 4.692 on 11 and 731 DF, p-value: 5.825e-07

Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> smp.1$prof <- relevel(smp.1$prof, ref="ouvrier")
> mod5 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
> summary(mod5)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons + subst.cons + scz.cons +
    prof, data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-63.280	-14.164	-1.337	10.959	63.184

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)		
(Intercept)	48.77932	2.83938	17.180	< 2e-16 ***		
age	0.21289	0.05884	3.618	0.000317 ***		
dep.cons	7.36792	1.45840	5.052	5.53e-07 ***		
subst.cons	5.34589	1.76902	3.022	0.002599 **		
scz.cons	2.50439	2.54734	0.983	0.325863		
profagriculteur	14.01270	9.72111	1.441	0.149880		
profartisan	2.52755	2.48989	1.015	0.310381		
profautre	3.72522	3.99637	0.932	0.351567		
profcadre	-5.28366	4.25567	-1.242	0.214798		
profemployé	0.45460	2.12659	0.214	0.830785		
profprof.intermédiaire	0.99344	2.95809	0.336	0.737089		
profsans emploi	-0.26596	1.87727	-0.142	0.887375		

Signif. codes:	0 '***'	0.001 '**'	0.01 '*'	0.05 '.'	0.1 ' '	1

Residual standard error: 19.11 on 731 degrees of freedom
(56 observations deleted due to missingness)

Multiple R-squared: 0.06595, Adjusted R-squared: 0.05189
F-statistic: 4.692 on 11 and 731 DF, p-value: 5.825e-07

Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> smp.1$prof <- relevel(smp.1$prof, ref="ouvrier")
> mod5 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
> summary(mod5)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons + subst.cons + scz.cons +
    prof, data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-63.280	-14.164	-1.337	10.959	63.184

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)		
(Intercept)	48.77932	2.83938	17.180	< 2e-16 ***		
age	0.21289	0.05884	3.618	0.000317 ***		
dep.cons	7.36792	1.45840	5.052	5.53e-07 ***		
subst.cons	5.34589	1.76902	3.022	0.002599 **		
scz.cons	2.50439	2.54734	0.983	0.325863		
profagriculteur	14.01270	9.72111	1.441	0.149880		
profartisan	2.52755	2.48989	1.015	0.310381		
profautre	3.72522	3.99637	0.932	0.351567		
profcadre	-5.28366	4.25567	-1.242	0.214798		
profemployé	0.45460	2.12659	0.214	0.830785		
profprofessionnel	0.99344	2.95809	0.336	0.737089		
profsans emploi	-0.26596	1.87727	-0.142	0.887375		

Signif. codes:	0 '***'	0.001 '**'	0.01 '*'	0.05 '.'	0.1 ' '	1

Residual standard error: 19.11 on 731 degrees of freedom
(56 observations deleted due to missingness)

Multiple R-squared: 0.06595, Adjusted R-squared: 0.05189
F-statistic: 4.692 on 11 and 731 DF, p-value: 5.825e-07

Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> smp.1$prof <- relevel(smp.1$prof, ref="ouvrier")
> mod5 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
> summary(mod5)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons + subst.cons + scz.cons +
    prof, data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-63.280	-14.164	-1.337	10.959	63.184

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)		
(Intercept)	48.77932	2.83938	17.180	< 2e-16 ***		
age	0.21289	0.05884	3.618	0.000317 ***		
dep.cons	7.36792	1.45840	5.052	5.53e-07 ***		
subst.cons	5.34589	1.76902	3.022	0.002599 **		
scz.cons	2.50439	2.54734	0.983	0.325863		
profagriculteur	14.01270	9.72111	1.441	0.149880		
profartisan	2.52755	2.48989	1.015	0.310381		
profautre	3.72522	3.99637	0.932	0.351567		
profcadre	-5.28366	4.25567	-1.242	0.214798		
profemployé	0.45460	2.12659	0.214	0.830785		
profprof.intermédiaire	0.99344	2.95809	0.336	0.737089		
profsans emploi	-0.26596	1.87727	-0.142	0.887375		

Signif. codes:	0 '***'	0.001 '**'	0.01 '*'	0.05 '.'	0.1 ' '	1

Residual standard error: 19.11 on 731 degrees of freedom
(56 observations deleted due to missingness)

Multiple R-squared: 0.06595, Adjusted R-squared: 0.05189
F-statistic: 4.692 on 11 and 731 DF, p-value: 5.825e-07

Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> drop1(mod5,.~.,test="F")
```

Single term deletions

Model:

```
dur.interv ~ age + dep.cons + subst.cons + scz.cons + prof
```

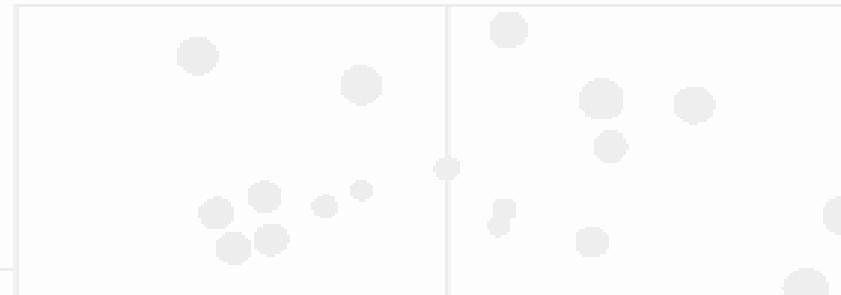
	Df	Sum of Sq	RSS	AIC	F value	Pr(>F)	
<none>		266846	4395.6				
age	1	4778.4	271624	4406.8	13.0899	0.0003173	***
dep.cons	1	9317.1	276163	4419.1	25.5233	5.527e-07	***
subst.cons	1	3333.6	270180	4402.8	9.1322	0.0025992	**
scz.cons	1	352.8	267199	4394.6	0.9666	0.3258633	
prof	7	2295.5	269142	4388.0	0.8983	0.5071556	

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA



```
> drop1(mod5,.~.,test="F")
```

Single term deletions

Model:

```
dur.interv ~ age + dep.cons + subst.cons + scz.cons + prof
```

	Df	Sum of Sq	RSS	AIC	F value	Pr(>F)
<none>		266846	4395.6			
age	1	4778.4	271624	4406.8	13.0899	0.0003173 ***
dep.cons	1	9317.1	276163	4419.1	25.5233	5.527e-07 ***
subst.cons	1	3333.6	270180	4402.8	9.1322	0.0025992 **
scz.cons	1	352.8	267199	4394.6	0.9666	0.3258633
prof	7	2295.5	269142	4388.0	0.8983	0.5071556

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Variables catégorielles à plus de deux classes



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> drop1(mod5,.~.,test="F")
```

Single term deletions

Model:

```
dur.interv ~ age + dep.cons + subst.cons + scz.cons + prof
```

	Df	Sum of Sq	RSS	AIC	F value	Pr(>F)	
<none>		266846	4395.6				
age	1	4778.4	271624	4406.8	13.0899	0.0003173	***
dep.cons	1	9317.1	276163	4419.1	25.5233	5.527e-07	***
subst.cons	1	3333.6	270180	4402.8	9.1322	0.0025992	**
scz.cons	1	352.8	267199	4394.6	0.9666	0.3258633	
prof	7	2295.5	269142	4388.0	0.8983	0.5071556	

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Interaction entre deux variables explicatives



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons,data=smp.1)
> summary(mod3)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons + subst.cons + scz.cons,
  data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-63.654	-14.522	-1.193	11.482	62.482

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)		
(Intercept)	48.90105	2.62213	18.649	< 2e-16 ***		
age	0.22096	0.05708	3.871	0.000118 ***		
dep.cons	7.38932	1.44783	5.104	4.24e-07 ***		
subst.cons	5.25157	1.74318	3.013	0.002678 **		
scz.cons	2.27256	2.52323	0.901	0.368062		

Signif. codes:	0 ****	0.001 ***	0.01 **	0.05 *	0.1 .	1

Residual standard error: 19.1 on 742 degrees of freedom

(52 observations deleted due to missingness)

Multiple R-squared: 0.05833, Adjusted R-squared: 0.05325

F-statistic: 11.49 on 4 and 742 DF, p-value: 4.692e-09

Interaction entre deux variables explicatives



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons,data=smp.1)
> summary(mod3)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons + subst.cons + scz.cons,
  data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-63.654	-14.522	-1.193	11.482	62.482

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	48.90105	2.62213	18.649	< 2e-16 ***
age	0.22096	0.05708	3.871	0.000118 ***
dep.cons	7.38932	1.44783	5.104	4.24e-07 ***
subst.cons	5.25157	1.74318	3.013	0.002678 **
scz.cons	2.27256	2.52323	0.901	0.368062

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 19.1 on 742 degrees of freedom

(52 observations deleted due to missingness)

Multiple R-squared: 0.05833, Adjusted R-squared: 0.05325

F-statistic: 11.49 on 4 and 742 DF, p-value: 4.692e-09

Interaction entre deux variables explicatives



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> mod6 <- lm(dur.interv~age+dep.cons*subst.cons+scz.cons, data=smp.1)
> summary(mod6)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons * subst.cons + scz.cons,
  data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-62.032	-14.251	-1.163	11.472	62.313

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	49.51693	2.65788	18.630	< 2e-16 ***
age	0.21728	0.05711	3.805	0.000154 ***
dep.cons	6.15780	1.69775	3.627	0.000306 ***
subst.cons	3.17244	2.29849	1.380	0.167931
scz.cons	1.97233	2.53094	0.779	0.436059
dep.cons:subst.cons	4.49688	3.24296	1.387	0.165963

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 19.08 on 741 degrees of freedom
(52 observations deleted due to missingness)

Multiple R-squared: 0.06077, Adjusted R-squared: 0.05443
F-statistic: 9.588 on 5 and 741 DF, p-value: 7.024e-09

Durée = a + b × age + c × dep + d × subst + e × scz + f × (dep × subst) + bruit

Interaction ⇔ synergie



Pr. Bruno Falissard

UNIVERSITÉ
PARIS
SUD

Interaction entre deux variables explicatives



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> mod6 <- lm(dur.interv~age+dep.cons*subst.cons+scz.cons, data=smp.1)
> summary(mod6)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons * subst.cons + scz.cons,
  data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-62.032	-14.251	-1.163	11.472	62.313

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	49.51693	2.65788	18.630	< 2e-16 ***
age	0.21728	0.05711	3.805	0.000154 ***
dep.cons	6.15780	1.69775	3.627	0.000306 ***
subst.cons	3.17244	2.29849	1.380	0.167931
scz.cons	1.97233	2.53094	0.779	0.436059
dep.cons:subst.cons	4.49688	3.24296	1.387	0.165963

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 19.08 on 741 degrees of freedom
(52 observations deleted due to missingness)

Multiple R-squared: 0.06077, Adjusted R-squared: 0.05443
F-statistic: 9.588 on 5 and 741 DF, p-value: 7.024e-09

Durée = a + b × age + c × dep + d × subst + e × scz + f × (dep × subst) + bruit

Interaction ⇔ synergie



Pr. Bruno Falissard

UNIVERSITÉ
PARIS
SUD

Interaction entre deux variables explicatives



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> mod6 <- lm(dur.interv~age+dep.cons*subst.cons+scz.cons, data=smp.1)
> summary(mod6)
```

Call:

```
lm(formula = dur.interv ~ age + dep.cons * subst.cons + scz.cons,
  data = smp.1)
```

Residuals:

Min	1Q	Median	3Q	Max
-62.032	-14.251	-1.163	11.472	62.313

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	49.51693	2.65788	18.630	< 2e-16 ***
age	0.21728	0.05711	3.805	0.000154 ***
dep.cons	6.15780	1.69775	3.627	0.000306 ***
subst.cons	3.17244	2.29849	1.380	0.167931
scz.cons	1.97233	2.53094	0.779	0.436059
dep.cons:subst.cons	4.49688	3.24296	1.387	0.165963

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 19.08 on 741 degrees of freedom
(52 observations deleted due to missingness)

Multiple R-squared: 0.06077, Adjusted R-squared: 0.05443
F-statistic: 9.588 on 5 and 741 DF, p-value: 7.024e-09

Durée = a + b × age + c × dep + d × subst + e × scz + f × (dep × subst) + bruit

Interaction ⇔ synergie



Pr. Bruno Falissard

UNIVERSITÉ
PARIS
SUD

Analyse de variance



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

ANalysis Of VAriance

=
ANOVA
=

régression linéaire
où les variables explicatives
sont toutes catégorielles !



```
> mod7 <- lm(dur.interv~prof,data=smp.1)
```

ANalysis Of VAriance

=

ANOVA

=

régression linéaire

où les variables explicatives
sont toutes catégorielles !

Analyse de variance

Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

ANalysis Of VAriance

=

ANOVA

=

régression linéaire
où les variables explicatives
sont toutes catégorielles !

```
> mod7 <- lm(dur.interv~prof,data=smp.1)
> summary(mod7)

Call:
lm(formula = dur.interv ~ prof, data = smp.1)

Residuals:
    Min      1Q  Median      3Q     Max 
-61.731 -13.826 -1.731  12.947  58.912 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 61.7315   1.3359  46.211 <2e-16 ***
profagriculteur 17.0185   9.9071   1.718   0.0863 .  
profartisan    2.0941   2.5033   0.837   0.4031    
profautre      2.4993   4.0755   0.613   0.5399    
profcadre      -4.7750   4.3063  -1.109   0.2679    
profemployé    0.3220   2.1742   0.148   0.8823    
profprof.intermédiaire 1.3440   3.0096   0.447   0.6553    
profsans emploi -0.6432   1.9168  -0.336   0.7373    
---
Signif. codes:  0 '****' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 19.63 on 735 degrees of freedom
(56 observations deleted due to missingness)
Multiple R-squared:  0.008295, Adjusted R-squared:  -0.001149 
F-statistic: 0.8783 on 7 and 735 DF,  p-value: 0.5231
```

Analyse de variance



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

ANalysis Of VAriance

=

ANOVA

=

régression linéaire
où les variables explicatives
sont toutes catégorielles !

```
> mod7 <- lm(dur.interv~prof,data=smp.1)
> summary(mod7)

Call:
lm(formula = dur.interv ~ prof, data = smp.1)

Residuals:
    Min      1Q  Median      3Q     Max 
-61.731 -13.826 -1.731  12.947  58.912 

Coefficients:
              Estimate Std. Error t value Pr(>|t|)    
(Intercept)  61.7315   1.3359  46.211 <2e-16 ***
profagriculteur 17.0185   9.9071   1.718  0.0863 .  
profartisan    2.0941   2.5033   0.837  0.4031    
profautre      2.4993   4.0755   0.613  0.5399    
profcadre      -4.7750   4.3063  -1.109  0.2679    
profemployé    0.3220   2.1742   0.148  0.8823    
profprof.intermédiaire 1.3440   3.0096   0.447  0.6553    
profsans emploi -0.6432   1.9168  -0.336  0.7373    
---
Signif. codes:  0 '****' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 19.63 on 735 degrees of freedom
(56 observations deleted due to missingness)
Multiple R-squared:  0.008295, Adjusted R-squared:  -0.001149 
F-statistic: 0.8783 on 7 and 735 DF,  p-value: 0.5231

> drop1(mod7,.~.,test="F")
Single term deletions

Model:
dur.interv ~ prof

          Df Sum of Sq    RSS      AIC F value Pr(>F)    
<none>            283316 4432.1                
prof      7     2369.9 285686 4424.3  0.8783 0.5231
```

Conditions de validité



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

- Normalité du « bruit »



- Normalité du « bruit »
- La variance du bruit ne doit dépendre ni des valeurs de la variable à expliquer, ni des valeurs des variables explicatives

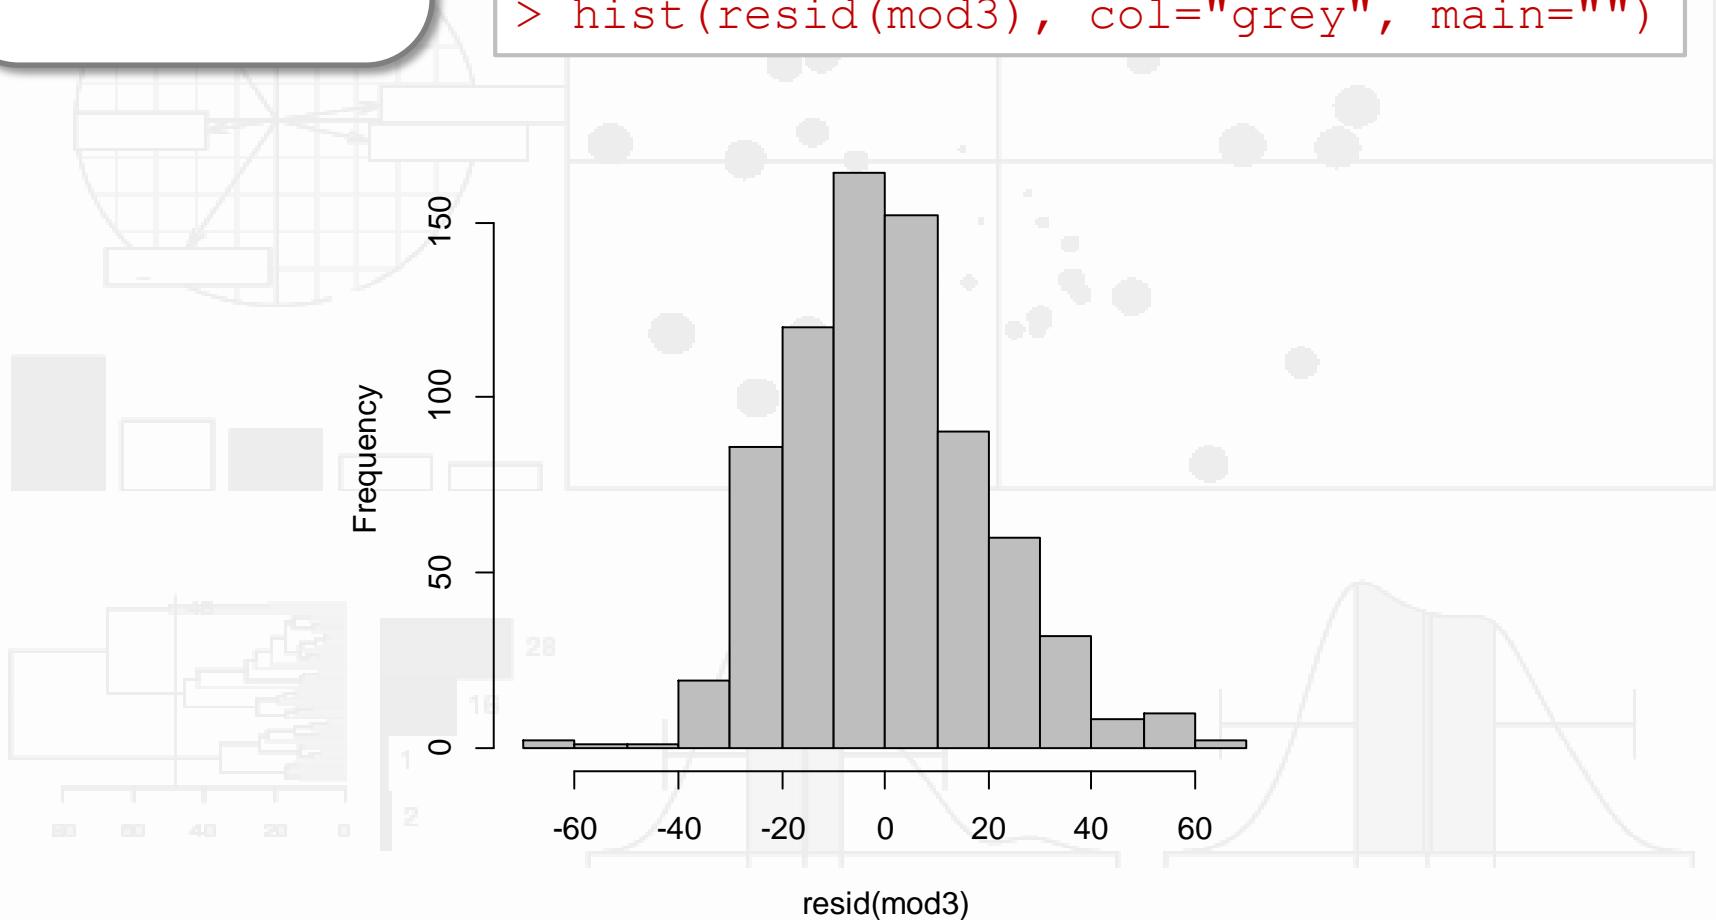
- Normalité du « bruit »
- La variance du bruit ne doit dépendre ni des valeurs de la variable à expliquer, ni des valeurs des variables explicatives
- Le bruit doit être un « vrai » bruit (pas de structure de corrélation évidente)

Conditions de validité



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA

```
> mod3 <- lm(dur.interv~age+dep.cons+
  subst.cons+scz.cons, data=smp.1)
> hist(resid(mod3), col="grey", main="")
```



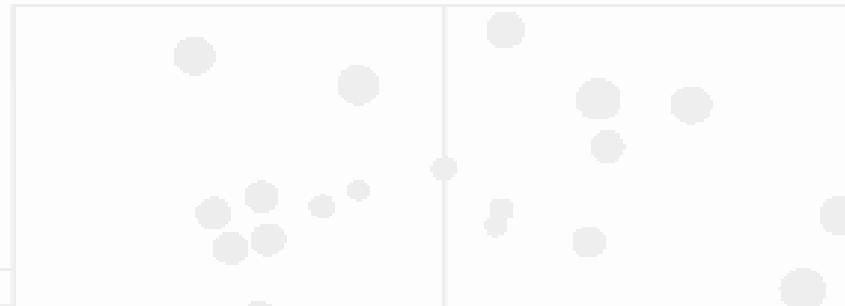
Pr. Bruno Falissard

UNIVERSITÉ
PARIS
SUD

Conditions de validité



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA



```
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
summary(mod3)
mod4 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod4)
smp.1$prof <- relevel(smp.1$prof, ref="ouvrier")
mod5 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod5)
drop1(mod5, .~., test="F")

mod6 <- lm(dur.interv~age+dep.cons*subst.cons+scz.cons, data=smp.1)
summary(mod6)

mod7 <- lm(dur.interv~prof, data=smp.1)
summary(mod7)
drop1(mod7, .~., test="F")

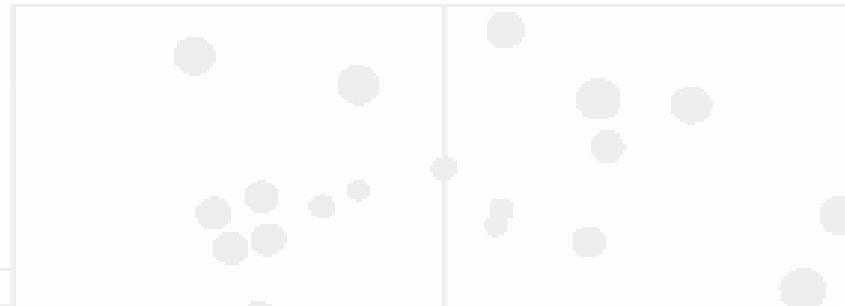
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
hist(resid(mod3), col="grey", main="")
```



Conditions de validité



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA



```
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
summary(mod3)
mod4 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod4)
smp.1$prof <- relevel(smp.1$prof, ref="ouvrier")
mod5 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod5)
drop1(mod5, .~., test="F")

mod6 <- lm(dur.interv~age+dep.cons*subst.cons+scz.cons, data=smp.1)
summary(mod6)

mod7 <- lm(dur.interv~prof, data=smp.1)
summary(mod7)
drop1(mod7, .~., test="F")

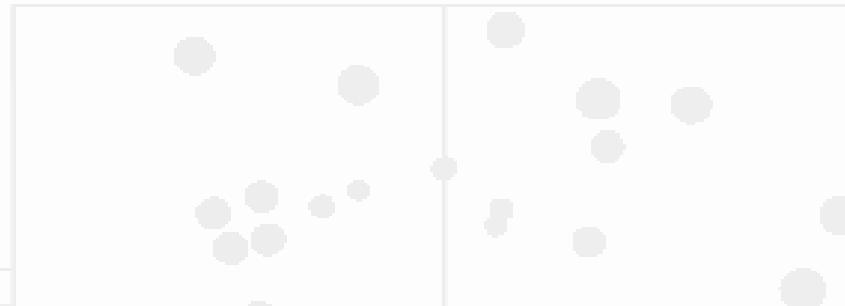
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
hist(resid(mod3), col="grey", main="")
```



Conditions de validité



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA



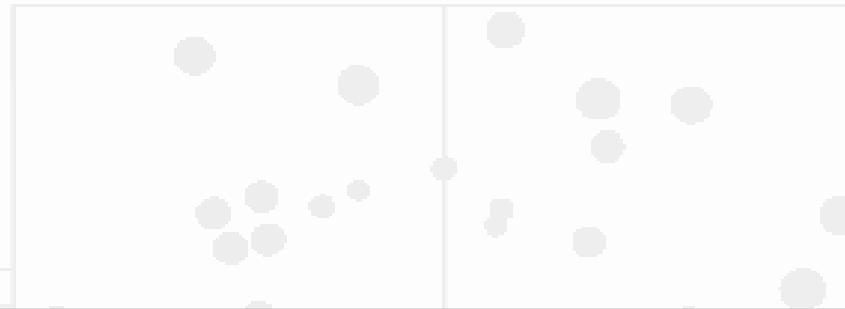
```
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
summary(mod3)
mod4 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod4)
smp.1$prof <- relevel(smp.1$prof, ref="ouvrier")
mod5 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod5)
drop1(mod5, .~., test="F")
mod6 <- lm(dur.interv~age+dep.cons*subst.cons+scz.cons, data=smp.1)
summary(mod6)
mod7 <- lm(dur.interv~prof, data=smp.1)
summary(mod7)
drop1(mod7, .~., test="F")
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
hist(resid(mod3), col="grey", main="")
```



Conditions de validité



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA



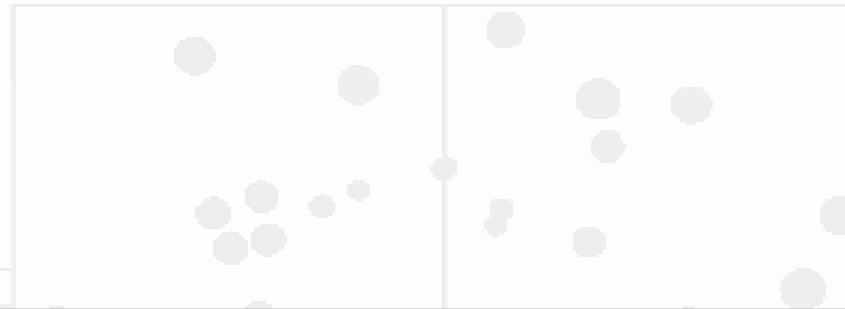
```
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
summary(mod3)
mod4 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod4)
smp.1$prof <- relevel(smp.1$prof, ref="ouvrier")
mod5 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod5)
drop1(mod5, .~., test="F")
mod6 <- lm(dur.interv~age+dep.cons*subst.cons+scz.cons, data=smp.1)
summary(mod6)
mod7 <- lm(dur.interv~prof, data=smp.1)
summary(mod7)
drop1(mod7, .~., test="F")
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
hist(resid(mod3), col="grey", main="")
```



Conditions de validité



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA



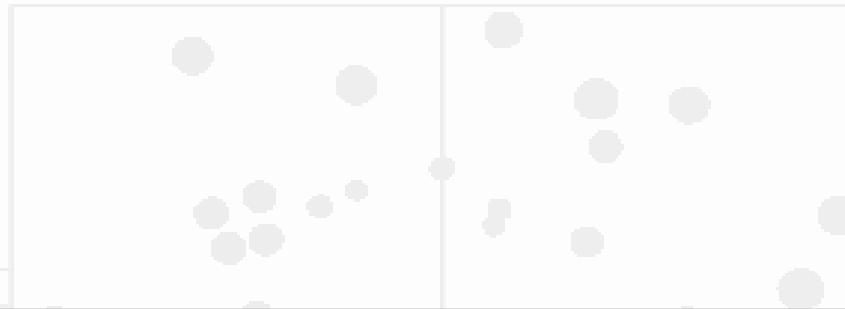
```
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
summary(mod3)
mod4 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod4)
smp.1$prof <- relevel(smp.1$prof, ref="ouvrier")
mod5 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod5)
drop1(mod5, .~., test="F")
mod6 <- lm(dur.interv~age+dep.cons*subst.cons+scz.cons, data=smp.1)
summary(mod6)
mod7 <- lm(dur.interv~prof, data=smp.1)
summary(mod7)
drop1(mod7, .~., test="F")
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
hist(resid(mod3), col="grey", main="")
```



Conditions de validité



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA



```
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
summary(mod3)
mod4 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod4)
smp.1$prof <- relevel(smp.1$prof, ref="ouvrier")
mod5 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod5)
drop1(mod5, .~., test="F")

mod6 <- lm(dur.interv~age+dep.cons*subst.cons+scz.cons, data=smp.1)
summary(mod6)

mod7 <- lm(dur.interv~prof, data=smp.1)
summary(mod7)
drop1(mod7, .~., test="F")

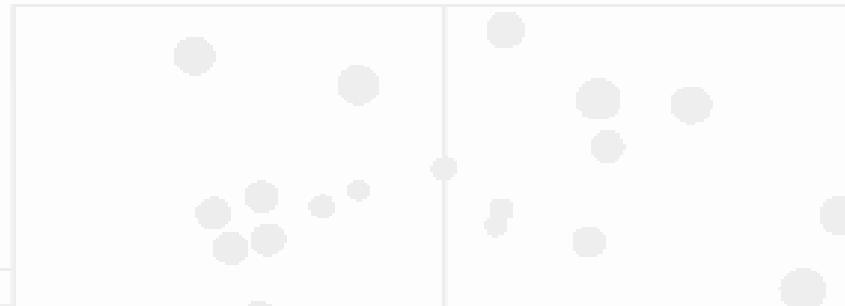
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
hist(resid(mod3), col="grey", main="")
```



Conditions de validité



Introduction à la statistique avec R > Rég. linéaire multiple, ANOVA



```
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
summary(mod3)
mod4 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod4)
smp.1$prof <- relevel(smp.1$prof, ref="ouvrier")
mod5 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons+prof, data=smp.1)
summary(mod5)
drop1(mod5, .~., test="F")
mod6 <- lm(dur.interv~age+dep.cons*subst.cons+scz.cons, data=smp.1)
summary(mod6)
mod7 <- lm(dur.interv~prof, data=smp.1)
summary(mod7)
drop1(mod7, .~., test="F")
mod3 <- lm(dur.interv~age+dep.cons+subst.cons+scz.cons, data=smp.1)
hist(resid(mod3), col="grey", main="")
```