

# Régression logistique avec plusieurs variables explicative

# Plusieurs variables explicatives



Introduction à la statistique avec R > La régression logistique

$$\text{Log} \left[ \frac{p(\text{h.r. de suicide})}{1 - p(\text{h.r. de suicide})} \right] = a + b \times \text{duree} + c \times \text{discip} + d \times \text{abus}$$



# Plusieurs variables explicatives

Introduction à la statistique avec R > La régression logistique

$$\text{Log} \left[ \frac{p(\text{h.r. de suicide})}{1 - p(\text{h.r. de suicide})} \right] = a + b \times \text{duree} + c \times \text{discip} + d \times \text{abus}$$

```
> mod2 <- glm(suicide.hr~abus+discip+duree, data=smp.1, family="binomial")
```



# Plusieurs variables explicatives

Introduction à la statistique avec R > La régression logistique

$$\text{Log} \left[ \frac{p(\text{h.r. de suicide})}{1 - p(\text{h.r. de suicide})} \right] = a + b \times \text{duree} + c \times \text{discip} + d \times \text{abus}$$

```
> mod2 <- glm(suicide.hr~abus+discip+duree, data=smp.1, family="binomial")
> summary(mod2)
```

Call:

```
glm(formula = suicide.hr ~ abus + discip + duree, family = "binomial",
     data = smp.1)
```

Deviance Residuals:

Min	1Q	Median	3Q	Max
-1.3200	-0.6655	-0.6012	-0.4997	2.0700

Coefficients:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-0.02462	0.49635	-0.050	0.960439
abus	0.62289	0.22764	2.736	0.006213 **
discip	0.52809	0.23767	2.222	0.026287 *
duree	-0.39862	0.11723	-3.400	0.000673 ***

---

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

(Dispersion parameter for binomial family taken to be 1)

```
Null deviance: 555.94 on 549 degrees of freedom
Residual deviance: 533.26 on 546 degrees of freedom
(249 observations deleted due to missingness)
AIC: 541.26
```

Number of Fisher Scoring iterations: 4

# Plusieurs variables explicatives

Introduction à la statistique avec R > La régression logistique

$$\text{Log} \left[ \frac{p(\text{h.r. de suicide})}{1 - p(\text{h.r. de suicide})} \right] = a + b \times \text{duree} + c \times \text{discip} + d \times \text{abus}$$

```
> mod2 <- glm(suicide.hr~abus+discip+duree, data=smp.1, family="binomial")
> summary(mod2)
```

Call:

```
glm(formula = suicide.hr ~ abus + discip + duree, family = "binomial",
     data = smp.1)
```

Deviance Residuals:

Min	1Q	Median	3Q	Max
-1.3200	-0.6655	-0.6012	-0.4997	2.0700

Coefficients:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-0.02462	0.49635	-0.050	0.960439
abus	0.62289	0.22764	2.736	0.006213 **
discip	0.52809	0.23767	2.222	0.026287 *
duree	-0.39862	0.11723	-3.400	0.000673 ***

---

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

(Dispersion parameter for binomial family taken to be 1)

```
Null deviance: 555.94 on 549 degrees of freedom
Residual deviance: 533.26 on 546 degrees of freedom
(249 observations deleted due to missingness)
AIC: 541.26
```

Number of Fisher Scoring iterations: 4

# Plusieurs variables explicatives

Introduction à la statistique avec R > La régression logistique

$$\text{Log} \left[ \frac{p(\text{h.r. de suicide})}{1 - p(\text{h.r. de suicide})} \right] = a + b \times \text{duree} + c \times \text{discip} + d \times \text{abus}$$

```
> mod2 <- glm(suicide.hr~abus+discip+duree, data=smp.1, family="binomial")
> summary(mod2)
```

Call:

```
glm(formula = suicide.hr ~ abus + discip + duree, family = "binomial",
     data = smp.1)
```

Deviance Residuals:

Min	1Q	Median	3Q	Max
-1.3200	-0.6655	-0.6012	-0.4997	2.0700

Coefficients:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-0.02462	0.49635	-0.050	0.960439
abus	<b>0.62289</b>	0.22764	2.736	0.006213 **
discip	<b>0.52809</b>	0.23767	2.222	0.026287 *
duree	<b>-0.39862</b>	0.11723	-3.400	0.000673 ***

---

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

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 555.94 on 549 degrees of freedom  
 Residual deviance: 533.26 on 546 degrees of freedom  
 (249 observations deleted due to missingness)  
 AIC: 541.26

Number of Fisher Scoring iterations: 4

# Plusieurs variables explicatives

Introduction à la statistique avec R > La régression logistique

$$\text{Log} \left[ \frac{p(\text{h.r. de suicide})}{1 - p(\text{h.r. de suicide})} \right] = a + b \times \text{duree} + c \times \text{discip} + d \times \text{abus}$$

```
> mod2 <- glm(suicide.hr~abus+discip+duree, data=smp.1, family="binomial")
> summary(mod2)
```

Call:

```
glm(formula = suicide.hr ~ abus + discip + duree, family = "binomial",
     data = smp.1)
```

Deviance Residuals:

Min	1Q	Median	3Q	Max
-1.3200	-0.6655	-0.6012	-0.4997	2.0700

Coefficients:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-0.02462	0.49635	-0.050	0.960439
abus	<b>0.62289</b>	0.22764	2.736	0.006213 **
discip	<b>0.52809</b>	0.23767	2.222	0.026287 *
duree	<b>-0.39862</b>	0.11723	-3.400	0.000673 ***

---

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

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 555.94 on 549 degrees of freedom  
 Residual deviance: 533.26 on 546 degrees of freedom  
 (249 observations deleted due to missingness)  
 AIC: 541.26

Number of Fisher Scoring iterations: 4

# Plusieurs variables explicatives

Introduction à la statistique avec R > La régression logistique

## Codage

abus : « 1 » oui, « 0 » non  
 discip : « 1 » oui, « 0 » non  
 duree : 1 à 5 (gradation)

```
> mod2 <- glm(suicide.hr~abus+discip+duree, data=smp.1, family="binomial")
> summary(mod2)

Call:
glm(formula = suicide.hr ~ abus + discip + duree, family = "binomial",
     data = smp.1)

Deviance Residuals:
    Min      1Q   Median      3Q      Max 
-1.3200 -0.6655 -0.6012 -0.4997  2.0700 

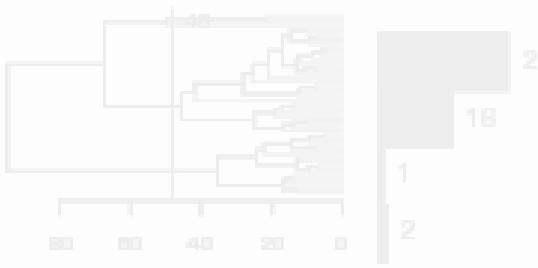
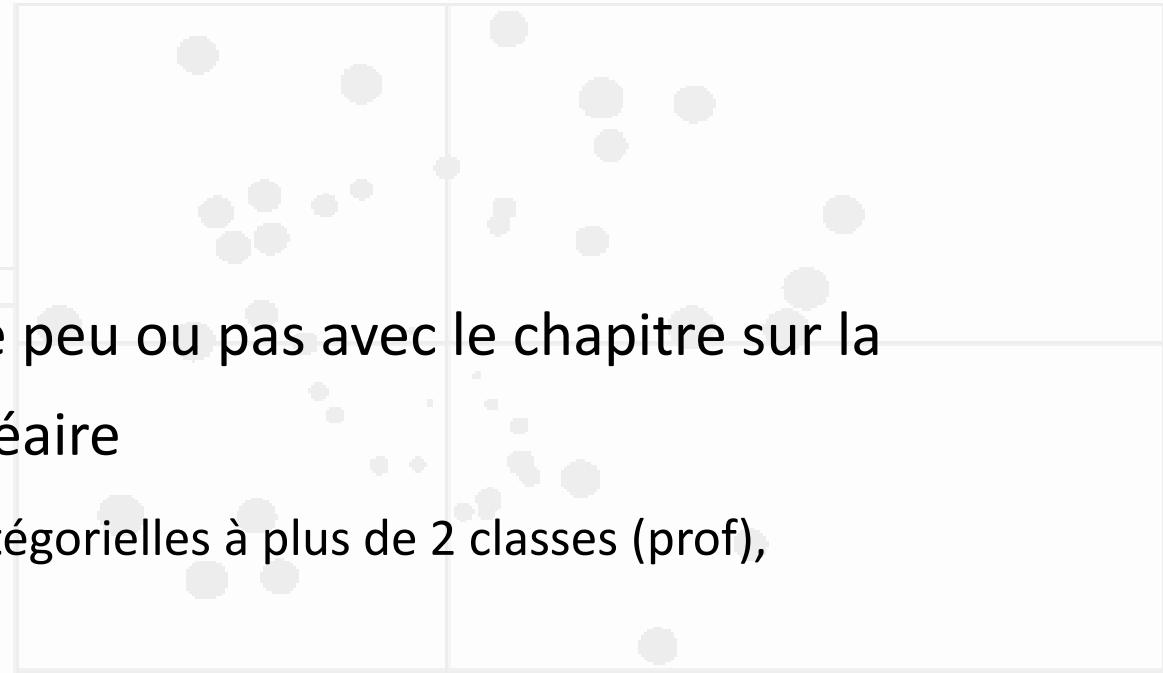
Coefficients:
            Estimate Std. Error z value Pr(>|z|)    
(Intercept) -0.02462    0.49635 -0.050  0.960439    
abus          0.62289    0.22764  2.736  0.006213 **  
discip        0.52809    0.23767  2.222  0.026287 *   
duree        -0.39862    0.11723 -3.400  0.000673 *** 
---
Signif. codes:  0 '****' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 555.94 on 549 degrees of freedom
Residual deviance: 533.26 on 546 degrees of freedom
(249 observations deleted due to missingness)
AIC: 541.26

Number of Fisher Scoring iterations: 4
> exp(coefficients(mod2))
(Intercept)      abus       discip      duree      
  0.9756803    1.8643147    1.6956873    0.6712485
```

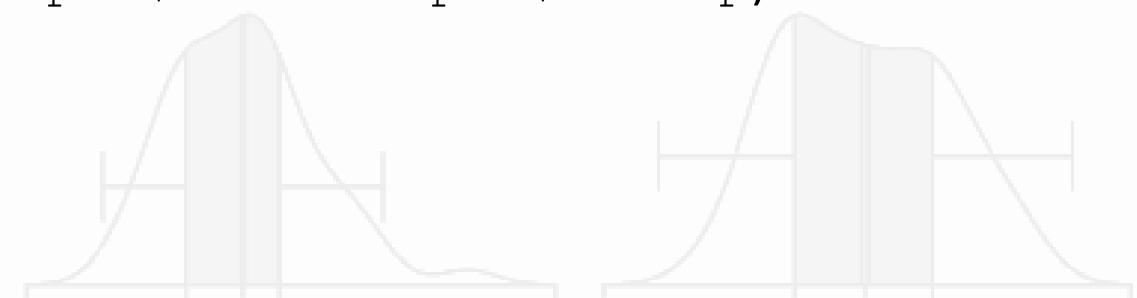
- Ce qui change peu ou pas avec le chapitre sur la régression linéaire
  - Variables catégorielles à plus de 2 classes (prof),



- Ce qui change peu ou pas avec le chapitre sur la régression linéaire
  - Variables catégorielles à plus de 2 classes (prof),
  - `drop1(mod1, .~., test="Chisq")`,



- Ce qui change peu ou pas avec le chapitre sur la régression linéaire
  - Variables catégorielles à plus de 2 classes (prof),
  - `drop1(mod1, .~., test="Chisq")`,
  - Interaction (`smp.l$duree*smp.l$discip`)



# Conditions de validité

Introduction à la statistique avec R > La régression logistique

- Conditions de validité de la régression logistique

- Conditions de validité de la régression logistique

« Au moins 5-10 événements par variable explicative »

- Conditions de validité de la régression logistique

« Au moins 5-10 événements par variable explicative »

- Fichier « smp.l » : 799 détenus
- Variable à expliquer : « forme sévère de schizophrénie » : 54 détenus

- Conditions de validité de la régression logistique

« Au moins 5-10 événements par variable explicative »

- Fichier « smp.l » : 799 détenus
- Variable à expliquer : « forme sévère de schizophrénie » : 54 détenus
- Variables explicatives : age, trauma, prof

- Conditions de validité de la régression logistique

« Au moins 5-10 événements par variable explicative »

- Fichier « smp.l » : 799 détenus
- Variable à expliquer : « forme sévère de schizophrénie » : 54 détenus
- Variables explicatives : age (1), trauma (1), prof (7)

- Conditions de validité de la régression logistique

« Au moins 5-10 événements par variable explicative »

- Fichier « smp.l » : 799 détenus
- Variable à expliquer : « forme sévère de schizophrénie » : 54 détenus
- Variables explicatives : age, trauma, prof
- $(1+1+7) \times 10 = 90 > 54 \rightarrow \text{pas bon}$

- Conditions de validité de la régression logistique

« Au moins 5-10 événements par variable explicative »

- Fichier « smp.l » : 799 détenus
- Variable à expliquer : « forme sévère de schizophrénie » : 54 détenus
- Variables explicatives : age, trauma, prof
- $(1+1+7) \times 10 = 90 > 54 \rightarrow$  pas bon
- $(1+1+7) \times 5 = 45 < 54 \rightarrow$  OK mais franchement limite

# Conclusion

Introduction à la statistique avec R > La régression logistique

```
mod2 <- glm(suicide.hr~abus+discip+duree, data=smp.1,  
            family="binomial")  
summary(mod2)  
exp(coefficients(mod2))
```

