



Modèle de discrimination logistique

David Causeur

Laboratoire de Mathématiques Appliquées

Agrocampus Rennes

IRMAR CNRS UMR 6625

<http://www.agrocampus-rennes.fr/math/causeur/>



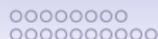
Plan du cours

- 1 Effet de l'environnement sur la coloration du gras d'agneau
- 2 Tests des effets
 - Test global
 - Test d'un modèle contre un sous-modèle
- 3 Sélection d'un sous-modèle
- 4 Discrimination logistique



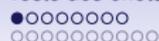
Données « gras coloré »

Alimentation	Logement	Nombre d'agneaux à gras coloré	Effectif total
A_1	L_1 (collectif)	10	$n_{11} = 20$
A_1	L_2	12	$n_{12} = 20$
A_2 (continu)	L_1 (collectif)	15	$n_{21} = 20$
A_2 (continu)	L_2	16	$n_{22} = 20$



Plan du cours

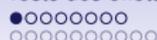
- 1 Effet de l'environnement sur la coloration du gras d'agneau
- 2 Tests des effets
 - Test global
 - Test d'un modèle contre un sous-modèle
- 3 Sélection d'un sous-modèle
- 4 Discrimination logistique



Test global

Modèle complet contre modèle nul

$$\begin{cases} H_0 & : x \text{ n'a pas d'influence sur } Y \\ H_1 & : x \text{ a une influence sur } Y \end{cases}$$



Test global

Modèle complet contre modèle nul

$$\begin{cases} H_0 & : x \text{ n'a pas d'influence sur } Y \\ H_1 & : x \text{ a une influence sur } Y \end{cases}$$

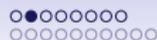
Essai « Gras coloré »

$$\begin{cases} H_0 & : \text{le mode d'alimentation n'a pas} \\ & \text{d'influence sur la coloration du gras} \\ H_1 & : \text{le mode d'alimentation a} \\ & \text{une influence sur la coloration du gras} \end{cases}$$



Modèles de coloration du gras d'agneau

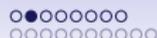
Modèle complet : $\text{logit}(\pi_1) = \mu$, $\text{logit}(\pi_2) = \mu + \alpha_2$



Modèles de coloration du gras d'agneau

Modèle complet : $\text{logit}(\pi_1) = \mu$, $\text{logit}(\pi_2) = \mu + \alpha_2$

Modèle nul : $\text{logit}(\pi_1) = \text{logit}(\pi_2) = \mu$



Modèles de coloration du gras d'agneau

Modèle complet : $\text{logit}(\pi_1) = \mu$, $\text{logit}(\pi_2) = \mu + \alpha_2$

Modèle nul : $\text{logit}(\pi_1) = \text{logit}(\pi_2) = \mu$

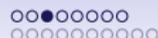
Modèle complet contre modèle nul

$$\begin{cases} H_0 & : \alpha_2 = 0 \\ H_1 & : \alpha_2 \neq 0 \end{cases}$$



Ajustement du modèle nul

$$\hat{\pi}_1 = \hat{\pi}_2 = \frac{Z_1 + Z_2}{80} = 0.66$$



Ajustement du modèle nul

$$\hat{\pi}_1 = \hat{\pi}_2 = \frac{Z_1 + Z_2}{80} = 0.66$$

Qualité de l'ajustement :

$$\begin{aligned}\mathcal{V}_0 &= \hat{\mathbb{P}}(Z_1 = 22)\hat{\mathbb{P}}(Z_2 = 31) \\ &= C_{40}^{22} \hat{\pi}_1^{22} (1 - \hat{\pi}_1)^{40-22} C_{40}^{31} \hat{\pi}_2^{31} (1 - \hat{\pi}_2)^{40-31} \\ &= 0.0019\end{aligned}$$



Ajustement du modèle complet

$$\hat{\pi}_1 = 0.55, \hat{\pi}_2 = 0.775$$



Ajustement du modèle complet

$$\hat{\pi}_1 = 0.55, \hat{\pi}_2 = 0.775$$

Qualité de l'ajustement :

$$\begin{aligned}\mathcal{V} &= \hat{\mathbb{P}}(Z_1 = 22)\hat{\mathbb{P}}(Z_2 = 31) \\ &= C_{40}^{22} \hat{\pi}_1^{22} (1 - \hat{\pi}_1)^{40-22} C_{40}^{31} \hat{\pi}_2^{31} (1 - \hat{\pi}_2)^{40-31} \\ &= 0.019\end{aligned}$$



Déviante du modèle

Rapport des vraisemblances

\mathcal{V} vraisemblance du modèle complet :

$$RV = \frac{\mathcal{V}_0}{\mathcal{V}}.$$



Déviante du modèle

Rapport des vraisemblances

\mathcal{V} vraisemblance du modèle complet :

$$RV = \frac{\mathcal{V}_0}{\mathcal{V}}.$$

Sous l'hypothèse d'absence d'effet de x

$$\underbrace{-2 \log RV}_{\text{déviante}} \sim \chi_{p-1}^2,$$

où p est le nombre de paramètres du modèle complet.



Analyse de la déviance

$$\nu_0 = \frac{\nu_0}{\nu} \nu,$$



Analyse de la déviance

$$\begin{aligned}\nu_0 &= \frac{\nu_0}{\nu} \nu, \\ \underbrace{-2 \log \nu_0}_{\mathcal{D}_0} &= \underbrace{-2 \log RV}_{\mathcal{D}} \underbrace{-2 \log \nu}_{\mathcal{D}_r},\end{aligned}$$



Analyse de la déviance

$$\begin{aligned}
 \mathcal{V}_0 &= \frac{\mathcal{V}_0}{\mathcal{V}} \mathcal{V}, \\
 \underbrace{-2 \log \mathcal{V}_0}_{\mathcal{D}_0} &= \underbrace{-2 \log RV}_{\mathcal{D}} \underbrace{-2 \log \mathcal{V}}_{\mathcal{D}_r}, \\
 \underbrace{\mathcal{D}_0}_{n-1 \text{ ddl}} &= \underbrace{\mathcal{D}}_{p-1 \text{ ddl}} + \underbrace{\mathcal{D}_r}_{n-p \text{ ddl}},
 \end{aligned}$$



Analyse de la déviance

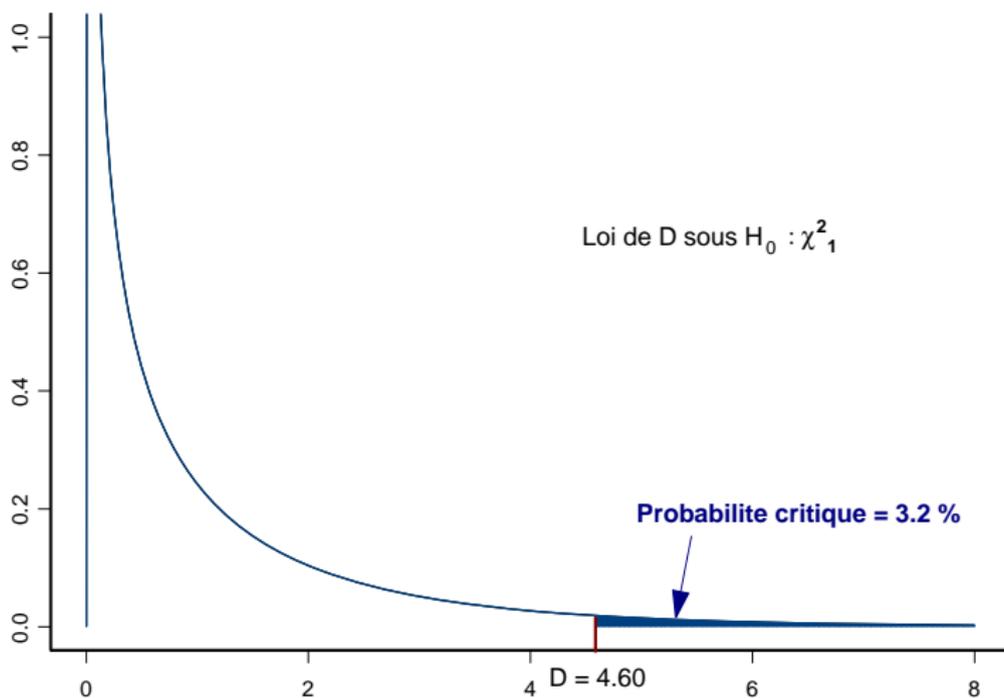
$$\begin{aligned} \mathcal{V}_0 &= \frac{\mathcal{V}_0}{\mathcal{V}} \mathcal{V}, \\ \underbrace{-2 \log \mathcal{V}_0}_{\mathcal{D}_0} &= \underbrace{-2 \log RV}_{\mathcal{D}} \underbrace{-2 \log \mathcal{V}}_{\mathcal{D}_r}, \\ \underbrace{\mathcal{D}_0}_{n-1 \text{ ddl}} &= \underbrace{\mathcal{D}}_{p-1 \text{ ddl}} + \underbrace{\mathcal{D}_r}_{n-p \text{ ddl}}, \end{aligned}$$

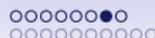
Essai « Gras coloré »

$$\underbrace{\mathcal{D}_0}_{12.54} = \underbrace{\mathcal{D}}_{4.60(1 \text{ ddl})} + \underbrace{\mathcal{D}_r}_{7.94}$$



Analyse de la déviance





Efficacité d'un fongicide

$\pi_i(x)$, probabilité qu'un plant de tournesol exposé au mildiou de race i et traité avec la log-dose x soit contaminé

Modèle complet

$$\text{logit} [\pi_i(x)] = \mu + \alpha_i + [\beta + \delta_i] x$$

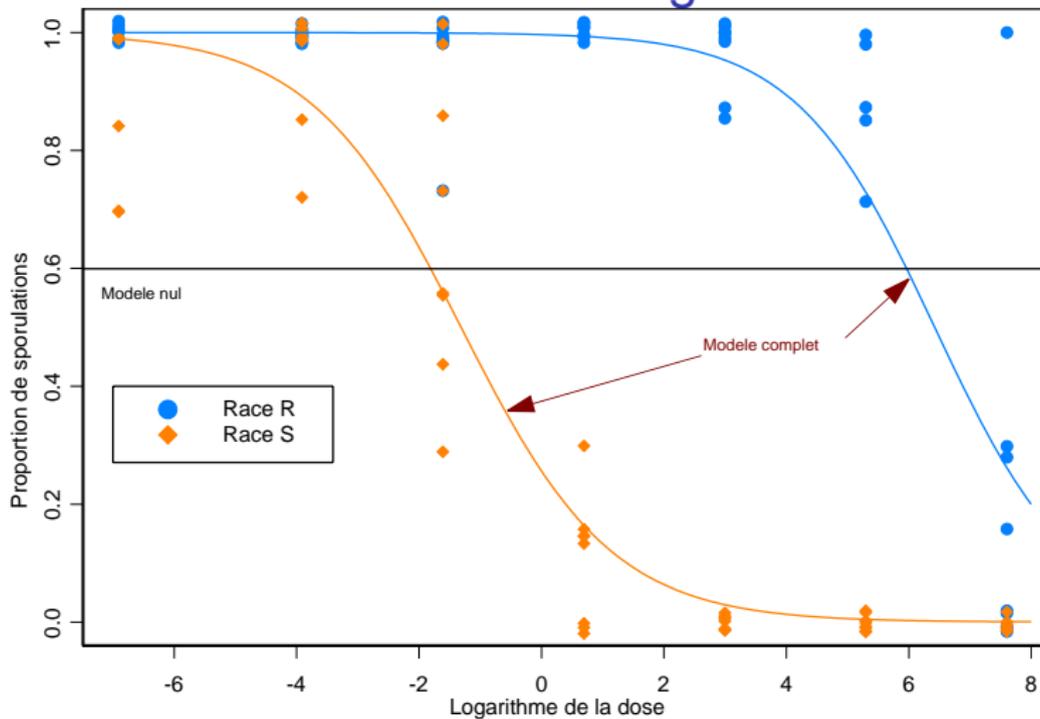
où $\alpha_2 = \delta_2 = 0$.

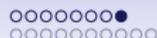
Modèle nul

$$\text{logit} [\pi_i(x)] = \mu.$$



Efficacité d'un fongicide





Test global de l'efficacité d'un fongicide

Analyse de la déviance			
	Déviance	Degré de liberté	Probabilité critique
Modèle nul	836.739	107	
Modèle complet	689.422	3	0
Résiduelle	147.316	104	



Comparaison à un sous-modèle

Modèle complet contre sous modèle

$$\begin{cases} H_0 & : M_p \text{ est aussi intéressant que } M_q \ (q < p) \\ H_1 & : M_p \text{ est plus intéressant que } M_q \end{cases}$$



Test de l'effet d'interaction Race \times Dose

Modèle complet

$$\text{logit} [\pi_i(x)] = \mu + \alpha_i + [\beta + \delta_i] x$$

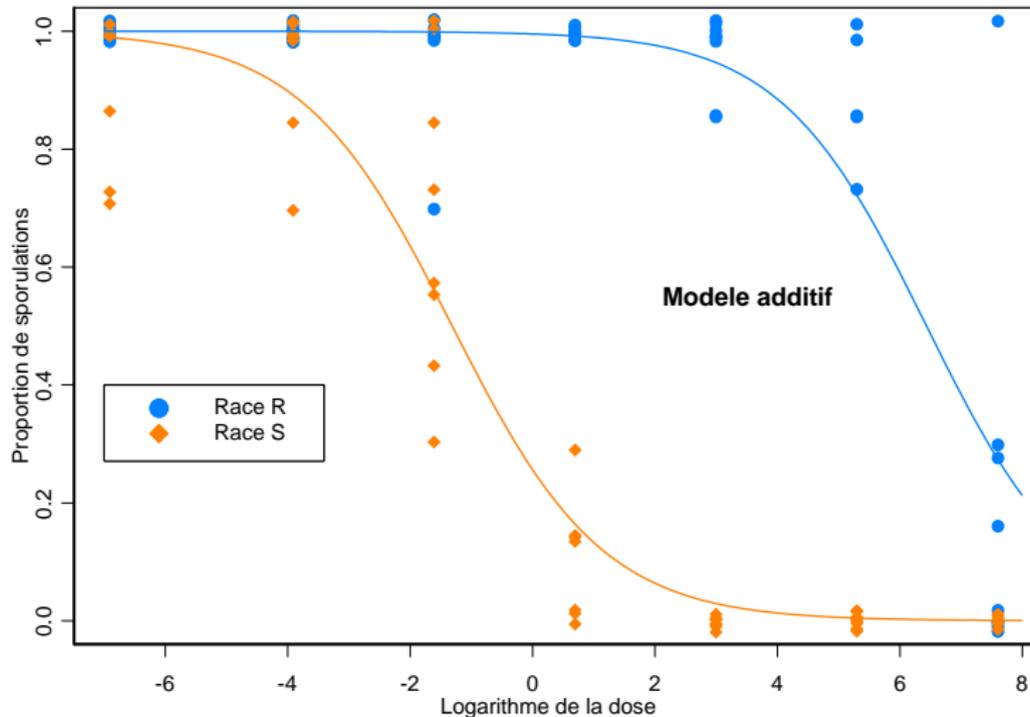
où $\alpha_2 = \delta_2 = 0$.

Modèle sans interaction

$$\text{logit} [\pi_i(x)] = \mu + \alpha_i + \beta x.$$



Test de l'effet d'interaction Race \times Dose





Rapport des vraisemblances

\mathcal{V}_p vraisemblance du modèle complet, \mathcal{V}_q pour le sous-modèle :

$$RV_{p|q} = \frac{\mathcal{V}_q}{\mathcal{V}_p}.$$

Sous l'hypothèse d'absence d'effet de x

$$\underbrace{-2 \log RV_{p|q}}_{\text{déviante}} \sim \chi_{p-q}^2.$$



Analyse de la déviance

$$\chi_0^2 = \frac{\chi_0^2}{\chi_q^2} \frac{\chi_q^2}{\chi_p^2} \chi_p^2,$$



Analyse de la déviance

$$\begin{aligned} \mathcal{V}_0 &= \frac{\mathcal{V}_0}{\mathcal{V}_q} \frac{\mathcal{V}_q}{\mathcal{V}_p} \mathcal{V}_p, \\ \underbrace{-2 \log \mathcal{V}_0}_{\mathcal{D}_0} &= \underbrace{-2 \log RV_q}_{\mathcal{D}_q} \underbrace{-2 \log RV_{p|q}}_{\mathcal{D}_{p|q}} \underbrace{-2 \log \mathcal{V}_p}_{\mathcal{D}_r}, \end{aligned}$$



Analyse de la déviance

$$\begin{aligned}
 \mathcal{V}_0 &= \frac{\mathcal{V}_0}{\mathcal{V}_q} \frac{\mathcal{V}_q}{\mathcal{V}_p} \mathcal{V}_p, \\
 \underbrace{-2 \log \mathcal{V}_0}_{\mathcal{D}_0} &= \underbrace{-2 \log \text{RV}_q}_{\mathcal{D}_q} \underbrace{-2 \log \text{RV}_{p|q}}_{\mathcal{D}_{p|q}} \underbrace{-2 \log \mathcal{V}_p}_{\mathcal{D}_r}, \\
 \underbrace{\mathcal{D}_0}_{n-1 \text{ ddl}} &= \underbrace{\mathcal{D}_q}_{q-1 \text{ ddl}} + \underbrace{\mathcal{D}_{p|q}}_{p-q \text{ ddl}} + \underbrace{\mathcal{D}_r}_{n-p \text{ ddl}}
 \end{aligned}$$



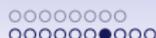
Test de l'efficacité d'un fongicide

Analyse de la déviance			
	Déviance	Degré de liberté	Probabilité critique
Modèle nul	836.739	107	
Modèle sans interaction	689.21	2	0
Modèle avec interaction	0.21	1	0.64
Résiduelle	147.316	104	



Tests des effets «alimentation» et «logement» sur la coloration du gras d'agneau

- H_0 : Seul le mode d'alimentation a une influence sur la coloration du gras
- H_1 : les modes d'alimentation et de logement ont tous deux une influence sur la coloration du gras



Comparaison de modèles

π_{ij} probabilité de coloration du gras avec l'alimentation i et le logement j

Modèle complet : $\text{logit}(\pi_{ij}) = \mu + \alpha_i + \beta_j + \gamma_{ij}$

avec $\alpha_1 = \beta_1 = \gamma_{11} = \gamma_{12} = \gamma_{21} = 0$

Modèle sous H_0 : $\text{logit}(\pi_{ij}) = \mu + \alpha_i$

Modèle complet contre modèle nul

$$\begin{cases} H_0 & : \beta_2 = 0 \\ H_1 & : \beta_2 \neq 0 \end{cases}$$



Ajustement du modèle sous H_0

$$\hat{\pi}_{11} = 0.55, \hat{\pi}_{12} = 0.55, \hat{\pi}_{21} = 0.775, \hat{\pi}_{22} = 0.775$$

Qualité de l'ajustement :

$$\begin{aligned}\mathcal{V} &= \hat{\mathbb{P}}(Z_{11} = 10)\hat{\mathbb{P}}(Z_{12} = 12)\hat{\mathbb{P}}(Z_{21} = 15)\hat{\mathbb{P}}(Z_{22} = 16) \\ &= C_{20}^{10}\hat{\pi}_1^{10}(1 - \hat{\pi}_{11})^{20-10}C_{20}^1\hat{\pi}_{12}^{12}(1 - \hat{\pi}_{12})^{20-12} \dots \\ &= 0.0011\end{aligned}$$



Ajustement du modèle complet

$$\hat{\pi}_{11} = 0.5, \hat{\pi}_{12} = 0.6, \hat{\pi}_{21} = 0.75, \hat{\pi}_{22} = 0.8$$

Qualité de l'ajustement :

$$\begin{aligned}\mathcal{V} &= \hat{\mathbb{P}}(Z_{11} = 10)\hat{\mathbb{P}}(Z_{12} = 12)\hat{\mathbb{P}}(Z_{21} = 15)\hat{\mathbb{P}}(Z_{22} = 16) \\ &= C_{20}^{10}\hat{\pi}_{11}^{10}(1 - \hat{\pi}_{11})^{20-10}C_{20}^{12}\hat{\pi}_{12}^{12}(1 - \hat{\pi}_{12})^{20-12} \dots \\ &= 0.0014\end{aligned}$$



Rapport des vraisemblances

\mathcal{V}_4 vraisemblance du modèle complet, \mathcal{V}_2 pour le sous-modèle :

$$RV_{4|2} = \frac{\mathcal{V}_2}{\mathcal{V}_4}.$$

Sous l'hypothèse d'absence H_0

$$\underbrace{-2 \log RV_{4|2}}_{0.548} \sim \chi_2^2.$$

$$\text{Probabilité critique} = 0.76$$



Plan du cours

- 1 Effet de l'environnement sur la coloration du gras d'agneau
- 2 Tests des effets
 - Test global
 - Test d'un modèle contre un sous-modèle
- 3 Sélection d'un sous-modèle
- 4 Discrimination logistique



Descripteurs les plus impliqués dans l'intention d'achat

Variable	Définition
$x^{(1)}$	Impression visuelle
$x^{(2)}$	Appétance
$x^{(3)}$	Qualité du pain en bouche
$x^{(4)}$	Originalité du pain
$x^{(5)}$	Quantité de garniture
$x^{(6)}$	Qualité de la garniture en bouche
$x^{(7)}$	Originalité de la garniture
$x^{(8)}$	Pertinence de l'association des ingrédients de la garniture



Sélection pas à pas

Variable	1 x	2 x dont $x^{(6)}$	3 x dont $x^{(6)}$ et $x^{(3)}$	4 x dont $x^{(6)}$, $x^{(3)}$ et $x^{(8)}$
$x^{(1)}$	1.7e-2	<u>1.4e-1</u>	<u>4.2e-1</u>	<u>5.6e-1</u>
$x^{(2)}$	1.2e-4	4.0e-2	<u>2.8e-1</u>	<u>3.7e-1</u>
$x^{(3)}$	4.9e-6	1.0e-3		
$x^{(4)}$	<u>7.8e-1</u>	<u>9.6e-1</u>	<u>2.7e-1</u>	<u>2.0e-1</u>
$x^{(5)}$	<u>6.1e-1</u>	<u>8.8e-1</u>	<u>8.6e-1</u>	<u>8.2e-1</u>
$x^{(6)}$	5.4e-10			
$x^{(7)}$	7.7e-3	4.6e-1	<u>3.3e-1</u>	<u>6.9e-1</u>
$x^{(8)}$	1.8e-7	1.1e-2	1.7e-2	



Sélection selon le critère d'Akaike

Start: AIC= 147.76

achat ~ attrait + appetance + painbouche + painorig + quantite + garnbouche +
garnorig + association

	Df	Deviance	AIC
- appetance	1	129.77	145.77
- quantite	1	130.09	146.09
- attrait	1	130.89	146.89
<none>		129.76	147.76
- garnorig	1	132.24	148.24
- association	1	133.38	149.38
- painorig	1	134.40	150.40
- painbouche	1	137.40	153.40
- garnbouche	1	139.74	155.74



Sélection selon le critère d'Akaike

Step: AIC= 145.77

achat ~ attrait + painbouche + painorig + quantite + garnbouche + garnorig +
association

	Df	Deviance	AIC
- quantite	1	130.17	144.17
- attrait	1	131.44	145.44
<none>		129.77	145.77
- garnorig	1	132.37	146.37
- association	1	133.43	147.43
+ appetance	1	129.76	147.76
- painorig	1	134.72	148.72
- painbouche	1	138.00	152.00
- garnbouche	1	140.31	154.31



Sélection selon le critère d'Akaike

Step: AIC= 144.17

achat ~ attrait + painbouche + painorig + garnbouche + garnorig + association

	Df	Deviance	AIC
- attrait	1	131.73	143.73
<none>		130.17	144.17
- garnorig	1	132.44	144.44
- association	1	133.63	145.63
+ quantite	1	129.77	145.77
+ appetance	1	130.09	146.09
- painorig	1	134.78	146.78
- painbouche	1	138.89	150.89
- garnbouche	1	140.51	152.51



Sélection selon le critère d'Akaike

Step: AIC= 143.73

achat ~ painbouche + painorig + garnbouche + garnorig + association

	Df	Deviance	AIC
<none>		131.73	143.73
- garnorig	1	133.78	143.78
+ attrait	1	130.17	144.17
+ appetance	1	131.01	145.01
- painorig	1	135.31	145.31
+ quantite	1	131.44	145.44
- association	1	135.66	145.66
- painbouche	1	141.64	151.64
- garnbouche	1	142.97	152.97

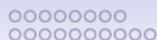


Sélection selon le critère d'Akaike

Anova Table (Type III tests)

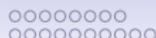
Response: achat

	LR Chisq	Df	Pr(>Chisq)	
painbouche	9.9057	1	0.0016476	**
painorig	3.5794	1	0.0585007	.
garnbouche	11.2399	1	0.0008006	***
garnorig	2.0503	1	0.1521783	
association	3.9306	1	0.0474142	*



Plan du cours

- 1 Effet de l'environnement sur la coloration du gras d'agneau
- 2 Tests des effets
 - Test global
 - Test d'un modèle contre un sous-modèle
- 3 Sélection d'un sous-modèle
- 4 Discrimination logistique



Discrimination

Exemple : mortalité du porcelet

On connaît le **poids de naissance** et le **gain de poids à 24 h** d'un porcelet.

Quel diagnostic ?

Discriminante logistique

- Estimation de la probabilité de survie $\hat{\pi}$ du porcelet
- Si $\hat{\pi}$ dépasse un seuil, on diagnostique la survie

Validation sur la base du

- taux de diagnostics corrects de la survie (spécificité)
- taux de diagnostics corrects de la mort (sensibilité)



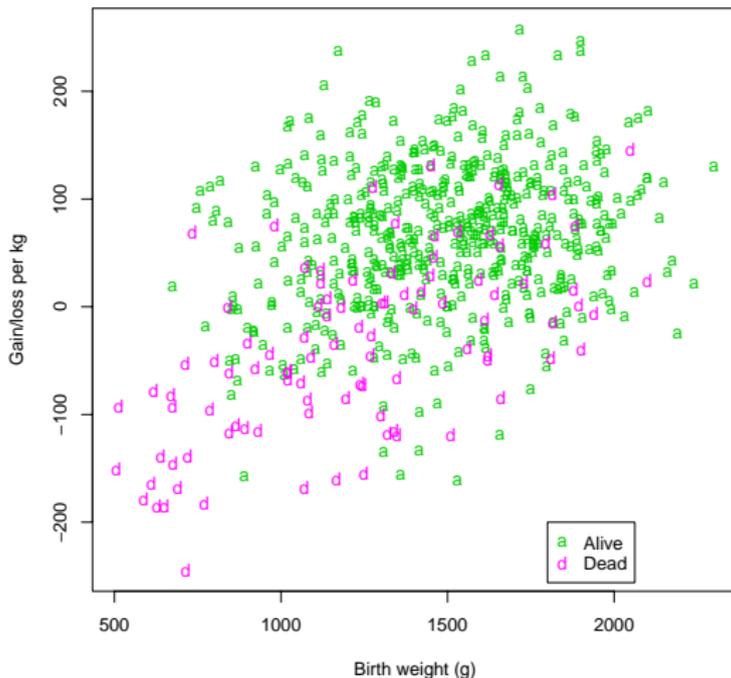
Mortalité du porcelet

Y : état du porcelet au sevrage (1=«Vivant», 0=«Mort»)

$x^{(1)}$: poids à la naissance

$x^{(2)}$: gain de poids (pour 1 kg) à 24h

Mortalité du porcelet





Mortalité du porcelet

Y : état du porcelet au sevrage (1=«Vivant», 0=«Mort»)

$x^{(1)}$: poids à la naissance

$x^{(2)}$: gain de poids (pour 1 kg) à 24h

Ajustement sur 526 porcelets vivants & 97 porcelets morts

Analyse de la déviance			
	Déviance	Degré de liberté	Probabilité critique
Modèle nul	538.85	622	
Poids de naissance	54.16	1	1.85e-13
Gain de poids à 24h	98.08	1	4.03e-23
Résiduelle	386.62	620	



Fonction discriminante logistique

Coefficients:					
	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	1.94e-01	5.69e-01	0.34	0.73	
Poids de naissance	8.55e-04	4.16e-04	2.06	0.04	*
Gain de poids à 24h	17.41	2.07	8.41	< 2e - 16	***

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

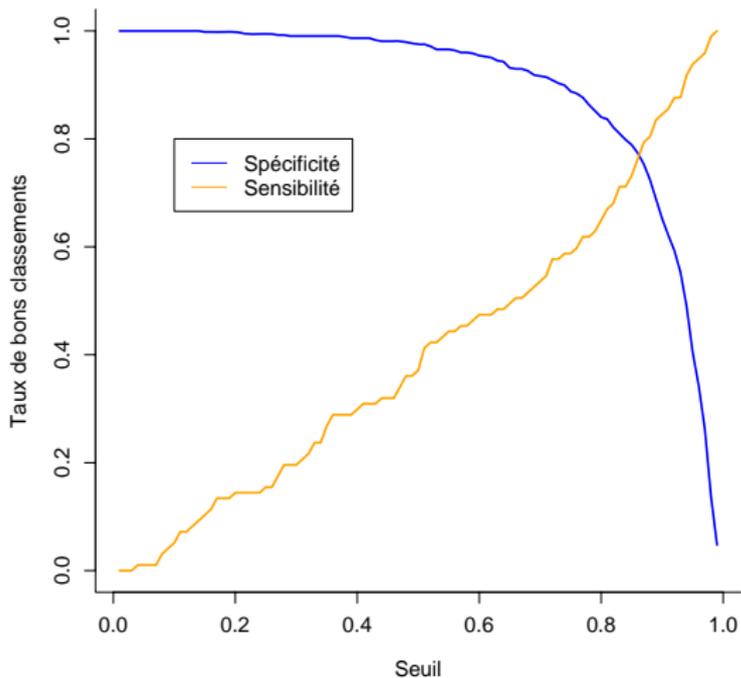
Number of Fisher Scoring Iterations: 6

Règle de discrimination :

Si $\hat{\pi}(x) \geq k$, alors $\hat{Y} = \text{« Vivant »}$

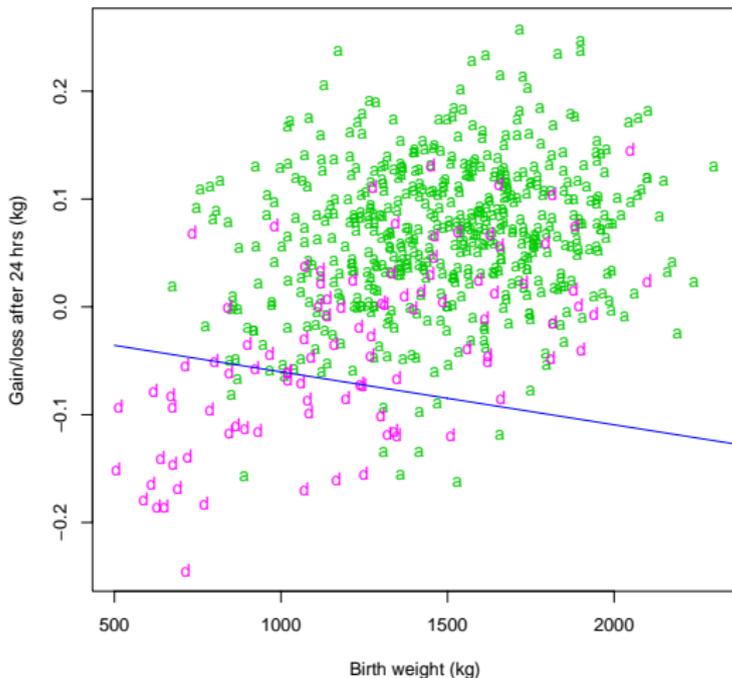


Capabilité de discrimination





Règle de discrimination





Validation d'une règle de discrimination

Validation croisée : confrontation de la règle de décision à des données externes

2 étapes:

- **Échantillon d'apprentissage (de calibration)**
 - Tirage au hasard uniforme dans l'échantillon disponible (2/3)
 - Sert à ajuster la règle de décision
- **Échantillon test**
 - Complémentaire de l'échantillon d'apprentissage
 - Sert à confronter la règle de décision à la réalité (calcul des taux d'erreurs)



Validation croisée robuste

Pour rendre la procédure moins sensible au découpage «apprentissage-test»:

- Répétition de la validation croisée
 - Taux de bons classements : moyennes des taux d'erreurs à chaque validation croisée
- Si échantillon de taille faible, «**leave-one-out**»



Mortalité du porcelet

Matrice de confusion - hors validation croisée:

Affectations	Observations	
	Mort	Vivant
Mort	0.76	0.23
Vivant	0.24	0.77

Matrice de confusion - Validation croisée (10×):

Affectations	Observations	
	Mort	Vivant
Mort	0.75	0.22
Vivant	0.25	0.78



Ouverture

- Lien avec la discriminante linéaire de Fisher



Ouverture

- Lien avec la discriminante linéaire de Fisher
- Extension au cas multi-classes



Ouverture

- Lien avec la discriminante linéaire de Fisher
- Extension au cas multi-classes
- Arbres de décision