

# MoDoBio Modélisation des Données en Biologie

## L3 Sciences de la Vie, parcours Biologie-Ecologie

Elodie Brunel MA et Céline Devaux BE

Université de Montpellier – Faculté des Sciences

2024-2025



# **Modèle Linéaire Multiple**

(Extension au cas de plusieurs variables explicatives)

## Retour en vallée d'Aure ...

Nous avons mis en évidence avec la modélisation linéaire simple que :

- ▶ il existe un lien significatif entre la biomasse et la variable explicative % surface d'abris
- ▶ le % surface d'abris explique 30% de la variabilité de la biomasse. Elle ne suffit pas à elle seule à expliquer toute la variabilité de la biomasse.

Nous voulons enrichir le modèle linéaire en introduisant d'autres variables explicatives disponibles :

Altitude, Température, Conductivité électrique, Pente, Largeur, Profondeur, Vitesse de Fond, Vitesse de Surface, Abris, Densité d'Invertébrés, Module, DebitE

## Description des $p = 12$ variables explicatives disponibles

- ▶ **Altitude** (en  $m$ )
- ▶ **Température** moyenne du mois le plus chaud (en  $^{\circ}C$ ).
- ▶ **Conductivité** électrique (en  $\mu S/cm$ )
- ▶ **Pente** (en %) de la ligne d'eau,
- ▶ **Largeur moyenne** (en  $m$ ) mesurée à partir de transects positionnés tous les 6  $m$ ,
- ▶ **Profondeur moyenne** (en  $m$ ),
- ▶ **Vitesse de Fond** (en  $m/s$ ) mesurée à l'aide d'un courantomètre,
- ▶ **Vitesse de Surface** (en  $m/s$ ) calculée en chronométrant le temps d'écoulement d'un colorant,
- ▶ **Abris** % de surface d'abris en effectuant le rapport de la surface occupée par les abris sur la surface totale de la station.
- ▶ **Densité d'Invertébrés** (individus / $0,1 m^2$ ),
- ▶ **Module** (en  $m^3/s$ ) représente la quantité totale d'eau circulant pendant une année moyenne sur un tronçon de rivière.
- ▶ **DebitE** (en % du Module) est le débit du cours d'eau à l'étiage (période où le débit est le plus faible)

## Modèle Linéaire Multiple (ou Multivarié)

Soit  $Y$  une variable aléatoire qui dépend de  $p$  variables explicatives  $x_1, \dots, x_p$  par :

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \epsilon_i, i = 1, \dots, n.$$

où

- $Y_i$  est la variable réponse de l'individu  $i$
- $x_{ij}$  est la valeur observée de la variable  $x_j$  pour l'individu  $i$
- les erreurs  $\epsilon_i$  sont **inobservées**, mais supposées **indépendantes** et de loi  $\mathcal{N}(0, \sigma_\epsilon^2)$ .

$\beta_0, \beta_1, \dots, \beta_p$  sont les coefficients inconnus du modèle.

Le modèle linéaire s'écrit de façon matricielle :

$$\underbrace{\begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix}}_{\mathbf{Y}:n \times 1} = \underbrace{\begin{pmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1p} \\ 1 & x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & & \vdots & \\ 1 & x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix}}_{\mathbf{X}:n \times p} \underbrace{\begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{pmatrix}}_{\beta:p \times 1} + \underbrace{\begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{pmatrix}}_{\epsilon:n \times 1}$$

Les estimateurs des moindres carrés minimisent la somme des carrés :

$$\sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_{i1} - \dots - \beta_p x_{ip})^2$$

et ils s'obtiennent *via* des calculs matriciels (omis ici ...). Les logiciels de statistique fournissent les valeurs numériques des estimateurs :

$$\hat{\beta} = \begin{pmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \vdots \\ \hat{\beta}_p \end{pmatrix} = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{Y}$$

On retrouve (comme dans le modèle linéaire simple), la formule de décomposition de la variabilité de la réponse :

$$SST = SSM + SSR$$

avec :

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2; \quad SSM = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2; \quad SSR = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \text{ et } \hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_p x_{ip}$$

## Test de Fisher "global"

Une régression multiple s'accompagne toujours d'une analyse de variance (ANalyse Of VAriance = ANOVA). On cherche si l'ensemble des variables explicatives influent de façon significative sur la variable réponse.

$\mathcal{H}_0$  : "Aucune des variables n'influe significativement sur la réponse"  
contre  $\mathcal{H}_1$  : "Au moins une variable a un lien significatif"

ce qui se traduit par :

$\mathcal{H}_0 : \beta_1 = \dots = \beta_p = 0$  contre  $\mathcal{H}_1 : \text{au moins un } \beta_j \neq 0$

Sous  $\mathcal{H}_0$ , on a :

$$F = \frac{SSM/p}{SSR/(n-p-1)} \sim F_{p, n-p-1}$$

Loi de Fisher à  $p$  et  $n - p - 1$  degrés de liberté (d.d.l) où  $p$  nombre de variables explicatives

**Remarque : Ce test ne permet pas de décider quels sont les coefficients dans le modèle de régression qui contribuent de façon significative à la réponse : test "global".**

# Test de Fisher "global"

**Règle de décision** : On rejette  $\mathcal{H}_0$  pour un risque de première espèce  $\alpha$  si la valeur observée  $F_{obs}$  de la  $F$ -statistique sur les données est telle que :

$$F_{obs} > \text{quantile d'ordre } \alpha \text{ d'une loi } F_{p,n-p-1}$$

ou de façon équivalente si la probabilité critique ou la  $p$ -value associée à  $F_{obs}$  est inférieure à  $\alpha$ .



## Exemple : Test de Fisher pour le modèle de la biomasse avec 12 coefficients de l'habitat

$$Y = \beta_0 + \beta_1 \text{Altitude} + \beta_2 \text{Temp} + \beta_3 \text{Cond} + \beta_4 \text{Pente} + \beta_5 \text{Larg} + \beta_6 \text{Prof} + \beta_7 \text{V.Fond} + \beta_8 \text{V.Surf} + \beta_9 \text{Abris} + \beta_{10} \text{DensInv} + \beta_{11} \text{Module} + \beta_{12} \text{DebitE} + \epsilon$$

Residual standard error: 0.4193 on 20 degrees of freedom

Multiple R-squared: 0.7884, Adjusted R-squared: 0.6614

F-statistic: 6.209 on 12 and 20 DF, p-value: 0.0001867

**Table ANOVA avec  $p = 12$  nombre de variables explicatives**

Source	Degrés de liberté	Somme des Carrés	Carrés Moyens	F - statistique de test	p-value
Modèle	12	SSM = 13,103	$\frac{SSM}{12}$	$F_{obs} = \frac{13,103/12}{3,517/20}$ = 6,209	0,00019
Résidus	20	SSR = 3,517	$\frac{SSR}{20}$		

On rejette l'hypothèse  $\mathcal{H}_0$  : "Aucune des variables n'influe sur la réponse" .

**Remarque :**

$$r^2 = 0,7884 \quad \text{et} \quad r_{ajusté}^2 = 0,6614 \text{ "corrigé" lorsque } p > 1.$$

## Exemple : Estimation et test de Student des 12 coefficients de l'habitat

$$Y = \beta_0 + \beta_1 \text{Altitude} + \beta_2 \text{Temp} + \beta_3 \text{Cond} + \beta_4 \text{Pente} + \beta_5 \text{Larg} + \beta_6 \text{Prof} + \beta_7 \text{V.Fond} + \beta_8 \text{V.Surf} + \beta_9 \text{Abris} + \beta_{10} \text{DensInv} + \beta_{11} \text{Module} + \beta_{12} \text{DebitE} + \epsilon$$

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	13.3635609	4.0054570	3.336	0.00329	**
Altitude	-0.0031159	0.0013832	-2.253	0.03567	*
Temp	-0.2495276	0.2148390	-1.161	0.25913	
Cond	0.0014675	0.0034465	0.426	0.67480	
Pente	-0.0563558	0.0567191	-0.994	0.33229	
Larg	-0.0890235	0.0527550	-1.687	0.10704	
Prof	-1.7418561	1.9553569	-0.891	0.38362	
V.Fond	-0.4704475	1.5234659	-0.309	0.76067	
V.Surf	-1.1883832	0.5512356	-2.156	0.04345	*
Abris	0.0306894	0.0110323	2.782	0.01151	*
DensInv	0.0003378	0.0004689	0.721	0.47955	
Module	0.0002368	0.0001217	1.946	0.06587	.
DebitE	0.0073534	0.0064769	1.135	0.26966	

---

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



Residual standard error: 0.4193 on 20 degrees of freedom

**Conclure (grâce au test de Fisher) que la régression est, dans son ensemble, significative n'implique pas nécessairement que toutes les variables explicatives ont une contribution significative.**

- ▶ Comment choisir les variables explicatives les plus pertinentes ?

## Sélection des variables

(Quelques algorithmes "automatiques" d'aide à la décision)

On souhaite sélectionner parmi les  $p$  variables explicatives, celles qui donnent le "meilleur" modèle pour prédire la réponse  $Y$ .

On cherche donc :

- ▶ un critère de qualité d'un modèle afin de comparer deux modèles n'ayant pas nécessairement le même nombre de variables explicatives.
- ▶ une procédure qui permet de choisir parmi tous les modèles : On parle de procédure de choix de modèle.
- ▶ Comme la complexité augmente avec le nombre de variables : il y a  $2^p - 1$  modèles possibles (avec  $p = 12$  : 4095 modèles possibles ...) En pratique, on utilise donc des heuristiques dont les plus simples sont les procédures pas à pas ascendante ou descendante.

## Méthode 1 : élimination pas à pas à l'aide du test de Student

- ▶ **méthode "descendante"** : on estime le modèle complet avec les  $p$  variables disponibles. On retire du modèle la variable dont la  $p$ -value du test de Student est la moins significative (la plus grande). Et ainsi de suite ...jusqu'à ce que toutes les variables restantes soient "significatives" pour un seuil  $\alpha$  donné.

Variables éliminées : V.Fond, Cond, DensInv, Prof, Pente, Temp, DebitE

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	9.278e+00	5.792e-01	16.017	2.6e-15	***
Altitude	-1.918e-03	5.005e-04	-3.832	0.00069	***
Larg	-1.150e-01	3.750e-02	-3.065	0.00489	**
V.Surf	-7.806e-01	3.507e-01	-2.226	0.03458	*
Abris	1.934e-02	5.829e-03	3.318	0.00260	**
Module	1.891e-04	8.445e-05	2.239	0.03356	*

---  
Multiple R-squared: 0.7104, Adjusted R-squared: 0.6568  
F-statistic: 13.25 on 5 and 27 DF, p-value: 1.441e-06

## Méthode 2 : élimination pas à pas à l'aide de critères : le

$r^2_{ajusté}$

Les coefficients  $r^2$  et  $r^2_{ajusté}$  :

- ▶ Le coefficient  $r^2 = \frac{SSM}{SST} = 1 - \frac{SSR}{SST}$  :
  - mesure l'"ajustement" du modèle aux données,
  - augmente lorsque le nombre de variables incluses dans le modèle augmente,
  - permet de comparer des modèles ayant le même nombre de variables.
- ▶ Le coefficient  $r^2_{ajusté} = 1 - \frac{SSR/(n-p-1)}{SST/(n-1)}$  :
  - n'augmente pas forcément lorsque le nombre de variables introduites dans le modèle augmente,
  - permet de comparer des modèles ayant un nombre de variables différent.

## Méthode 3 : élimination pas à pas à l'aide de critères pénalisés AIC ou BIC

On minimise ces critères dans une procédure de sélection de variables :

$$AIC = n \log(SSR) + 2 \times k \quad (\text{Akaike Information Criterion})$$

et

$$BIC = n \log(SSR) + k \log(n) \quad (\text{Bayesian Information Criterion})$$

Le critère *BIC* aura tendance à pénaliser davantage les modèles avec un grand nombre de variables.



## Méthode 3 : élimination pas à pas "descendante" AIC :

- ▶ on estime le modèle complet avec les  $p$  variables disponibles. A chaque étape on calcule l'AIC en retirant du modèle une des variables, et on garde le modèle qui donne le critère AIC le plus petit. On arrête lorsque le critère AIC ne diminue plus lorsqu'on retire une variable de plus.

Variables éliminées (dans l'ordre) : V.Fond, Cond, DensInv, Prof

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	1.438e+01	3.412e+00	4.215	0.000306	***
Altitude	-3.599e-03	1.125e-03	-3.200	0.003844	**
Temp	-2.858e-01	1.828e-01	-1.563	0.131076	
Pente	-6.537e-02	4.976e-02	-1.314	0.201392	
Larg	-1.032e-01	4.170e-02	-2.474	0.020831	*
Abris	2.329e-02	6.427e-03	3.624	0.001354	**
V.Surf	-1.306e+00	4.886e-01	-2.673	0.013319	*
Module	1.885e-04	8.188e-05	2.303	0.030284	*
DebitE	7.976e-03	5.014e-03	1.591	0.124770	

---

AIC = -53.683

Multiple R-squared: 0.7738, Adjusted R-squared: 0.6984

F-statistic: 10.26 on 8 and 24 DF, p-value: 4.049e-06

## Méthode 3 : élimination pas à pas "descendante" BIC :

- ▶ on part du modèle complet avec les  $p$  variables disponibles. A chaque étape on calcule le BIC en retirant du modèle une des variables, et on garde le modèle qui donne le critère *BIC* le plus petit. On arrête lorsque le critère *BIC* ne diminue plus lorsqu'on retire une variable de plus.

Variables éliminées (dans l'ordre) : V.Fond, Cond, DensInv, Prof, Pente, Temp

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	9.226e+00	5.489e-01	16.808	1.75e-15	***
Altitude	-2.205e-03	4.944e-04	-4.460	0.00014	***
Larg	-1.343e-01	3.675e-02	-3.654	0.00115	**
Abris	2.009e-02	5.530e-03	3.632	0.00121	**
V.Surf	-7.366e-01	3.327e-01	-2.214	0.03580	*
Module	2.149e-04	8.094e-05	2.655	0.01335	*
DebitE	9.956e-03	4.898e-03	2.033	0.05240	.

---

BIC=-43,925

Multiple R-squared: 0.7501, Adjusted R-squared: 0.6925

F-statistic: 13.01 on 6 and 26 DF, p-value: 9.168e-07

# Comparaison de modèles "emboîtés"

Les 3 méthodes ne sélectionnent pas les mêmes variables.

– **Model 0** : sélection par test de Student :

5 Variables sélectionnées : Altitude, Larg, V.Surf, Abris, Module

– **Model 1** : sélection par BIC :

6 Variables sélectionnées : Altitude, Larg, V.Surf, Abris, Module, DebitE

– **Model 2** : sélection par AIC : 8 Variables sélectionnées : Altitude, Temp, Pente, Larg, V.Surf, Abris, Module, DebitE

Les modèles sont "emboîtés" (les variables du "plus petit" modèle sont toutes présentes dans le modèle "plus grand") :

**Model 0** ("student") est emboîté dans **Model 1** (BIC) et dans **Model 2** (AIC).

**Model 1** (BIC) est emboîté dans **Model 2** (AIC).

**Comment les comparer ? avec des modèles emboîtés, on peut réaliser un test de Fisher (encore lui !)**

# Comparaison de modèles "emboîtés" : test de Fisher

On teste  $\mathcal{H}_0$  : Model 0 ("student") contre  $\mathcal{H}_0$  : Model 1 (BIC) :  
Si on rejette  $\mathcal{H}_0$  alors on garde les variables du Model 1.

Exemple : (sortie R)

```
Model 0: logBiomTot ~ Altitude + Larg + Abris + V.Surf + Module
```

```
Model 1: logBiomTot ~ Altitude + Larg + Abris + V.Surf + Module  
+ DebitE
```

	Res.Df	RSS	Df	Sum of Sq	F	Pr(>F)
1	27	4.8128				
2	26	4.1528	1	0.66003	4.1324	0.0524

Conclusion : au risque de 5%, on garde le Model 0 plutôt que le Model 1 (de justesse mais on ne rejette pas  $\mathcal{H}_0$  !).

## Comparaison de modèles "emboîtés" : test de Fisher

On teste  $\mathcal{H}_0$  : Model 1 ("BIC") contre  $\mathcal{H}_0$  : Model 2 (AIC) :

Si on rejette  $\mathcal{H}_0$  alors on garde les variables du Model 2, sinon il n'y a pas d'intérêt à ajouter les variables du Model 2 et donc on garde le Model 1.

Exemple : (sortie R)

```
Model 1:logBiomTot ~Altitude + Larg + Abris + V.Surf + Module + DebitE
```

```
Model 2:logBiomTot ~Altitude + Temp + Pente + Larg + Abris + V.Surf  
+ Module + DebitE
```

	Res.Df	RSS	Df	Sum of Sq	F	Pr(>F)
1	26	4.1528				
2	24	3.7595	2	0.3933	1.2554	0.303

Conclusion : au risque de 5%, on garde le Model 1 plutôt que le Model 2 (on ne rejette pas  $\mathcal{H}_0$ ).