

# La régression multiple

Stéphane Canu  
[stephane.canu@litislab.eu](mailto:stephane.canu@litislab.eu)

M8 - Principes du traitement de l'information

March 28, 2011

# Plan

## 1 Présentation matricielle

- Interprétation matricielle
- Interprétation graphique

## 2 La Régression multiple

- Les données et le modèle
- Mise en œuvre
  - Solution Matlab

## Rappel sur la régression linéaire

$x$  hauteur (en m) des arbres dominants

$y$  logarithme du nombre de nids de processionnaires par arbre

le modèle :

$$y = ax + b + \varepsilon$$

on cherche à expliquer la variable  $y$  par la variable  $x$

on dispose d'un échantillon (d'une ensemble d'observations)

$$(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i), \dots, (x_n, y_n),$$

on cherche à estimer  $a$  et  $b$  à partir de l'échantillon

## Version vectorielle dans $\mathbb{R}^n$

$$\mathbf{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_i \\ \vdots \\ x_n \end{bmatrix} \quad \mathbf{y} = \begin{bmatrix} y_1 \\ \vdots \\ y_i \\ \vdots \\ y_n \end{bmatrix}$$

$$\boldsymbol{\varepsilon} = \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_i \\ \vdots \\ \varepsilon_n \end{bmatrix} \quad \mathbf{e} = \begin{bmatrix} 1 \\ \vdots \\ 1 \\ \vdots \\ 1 \end{bmatrix}$$

- Moyenne :

- ▶  $\mathbf{x}^\top \mathbf{e} = \sum x_i = n \bar{x}$

- ▶  $\mathbf{y}^\top \mathbf{e} = \sum y_i = n \bar{y}$

- Variance – covariance

- ▶  $\|\mathbf{x} - \bar{x} \mathbf{e}\|^2 = n V(\mathbf{x})$


- ▶  $\|\mathbf{y} - \bar{y} \mathbf{e}\|^2 = n V(\mathbf{y})$

- ▶  $(\mathbf{x} - \bar{x} \mathbf{e})^\top (\mathbf{y} - \bar{y} \mathbf{e}) = n \text{cov}(\mathbf{x}, \mathbf{y})$

- Régression : pour tout couple  $(a, b)$

- ▶  $\mathbf{z} = a\mathbf{x} + b\mathbf{e}$

- ▶  $\boldsymbol{\varepsilon} = \mathbf{y} - \underbrace{a\mathbf{x} + b\mathbf{e}}_{\mathbf{z}}$



## l'ensembles des « modèles »

$$\text{un modèle} = \text{un couple } (a, b) \left\{ \begin{array}{l} y_1 = ax_1 + b + \varepsilon_1 \\ \vdots \\ y_i = ax_i + b + \varepsilon_i \\ \vdots \\ y_n = ax_n + b + \varepsilon_n \end{array} \right. \quad a \text{ et } b \text{ scalaires;}$$


$\mathbf{x}, \mathbf{e}, \varepsilon, \mathbf{y}$  et  $\mathbf{z}$  vecteurs de  $\mathbb{R}^n$

$$\mathbf{y} = \underbrace{\mathbf{ax} + \mathbf{be}}_{\mathbf{z}} + \varepsilon$$

le plan engendré par les vecteurs  $\mathbf{x}$  et  $\mathbf{e}$

$$\Omega = \{ \mathbf{z} \in \mathbb{R}^n \mid \exists (a, b) \in \mathbb{R}^2, \mathbf{z} = \mathbf{ax} + \mathbf{be} \}$$

$$\mathbf{x}, \mathbf{e} \text{ et } \mathbf{z} \in \Omega$$



Quel est le meilleur modèle?

# Présentation matricielle

$$X = \begin{bmatrix} x_1 & 1 \\ \vdots & \vdots \\ x_i & 1 \\ \vdots & \vdots \\ x_n & 1 \end{bmatrix} \quad \text{matrice des observations}$$

$$y = \begin{bmatrix} y_1 \\ \vdots \\ y_i \\ \vdots \\ y_n \end{bmatrix} \quad \text{la variable à expliquer et}$$

$$\alpha = \begin{bmatrix} a \\ b \end{bmatrix} \quad \text{le vecteur des inconnues}$$

écriture scalaire

$$\begin{cases} ax_1 + b + \varepsilon_1 = y_1 \\ \vdots \\ ax_i + b + \varepsilon_i = y_i \\ \vdots \\ ax_n + b + \varepsilon_n = y_n \end{cases}$$

$a$  et  $b$  sont des scalaires;  $\mathbf{x}$ ,  $\mathbf{e}$ ,  $\varepsilon$  et  $\mathbf{y}$  sont des vecteurs de  $\mathbb{R}^n$

$$a \mathbf{x} + b \mathbf{e} + \varepsilon = \mathbf{y}$$

écriture matricielle

$$X\alpha + \varepsilon = \mathbf{y}$$

## Version matricielle du cout

Le problème de moindres carré se réécrit de la manière suivante :

$$\min_{\alpha} J(\alpha) \quad \text{avec} \quad J(\alpha) = \frac{1}{2} \|\mathbf{y} - X\alpha\|^2$$

soit en développant :

$$\begin{aligned} \min_{\alpha} J(\alpha) &= \frac{1}{2} \|\mathbf{y} - X\alpha\|^2 \\ &= \frac{1}{2} (\mathbf{y} - X\alpha)^{\top} (\mathbf{y} - X\alpha) \\ &= \frac{1}{2} \mathbf{y}^{\top} \mathbf{y} - \frac{1}{2} \alpha^{\top} X^{\top} \mathbf{y} - \frac{1}{2} \mathbf{y}^{\top} X\alpha + \frac{1}{2} \alpha^{\top} X^{\top} X\alpha \\ &= \frac{1}{2} \mathbf{y}^{\top} \mathbf{y} - \alpha^{\top} X^{\top} \mathbf{y} + \frac{1}{2} \alpha^{\top} X^{\top} X\alpha \end{aligned}$$

Calcul matriciel :  $\mathbf{y}^{\top} \mathbf{y}$  est un scalaire,  $X^{\top} \mathbf{y}$  est un vecteur de  $\mathbb{R}^2$  et  $X^{\top} X$  est une matrice  $2 \times 2$ .

## Dérivées partielles du coût

$$\begin{aligned} J(\alpha) &= \frac{1}{2} \mathbf{y}^\top \mathbf{y} - \alpha^\top \mathbf{X}^\top \mathbf{y} + \frac{1}{2} \alpha^\top \mathbf{X}^\top \mathbf{X} \alpha \\ \frac{\partial J(\alpha)}{\partial \alpha_i} &= 0 - w_i + \frac{1}{2} \sum_{j=1}^{p+1} (M_{ij} + M_{ji}) \alpha_j \end{aligned}$$

avec  $\mathbf{w} = \mathbf{X}^\top \mathbf{y}$  et  $M = \mathbf{X}^\top \mathbf{X}$

- $\frac{\partial \alpha^\top \mathbf{w}}{\partial \alpha_i} = \frac{\partial \sum_{j=1}^{p+1} w_j \alpha_j}{\partial \alpha_i} = w_i$
- $\frac{\partial \alpha^\top M \alpha}{\partial \alpha_i} = \frac{\partial \sum_{j=1}^{p+1} \sum_{k=1}^{p+1} \alpha_j \alpha_k M_{jk}}{\partial \alpha_i} = \sum_{j=1}^{p+1} \alpha_j M_{ji} + \sum_{k=1}^{p+1} \alpha_k M_{ik}$

car  $(uv)' = uv' + u'v$  avec  $u = \alpha_j$  et  $v = \sum_{k=1}^{p+1} \alpha_k M_{jk}$

$$\nabla J(\hat{\alpha}) = -\mathbf{w} + M\hat{\alpha} = -\mathbf{X}^\top \mathbf{y} + \mathbf{X}^\top \mathbf{X} \hat{\alpha}$$



## La minimisation du cout

La minimisation du cout  $J(\alpha)$  est réalisée lorsque le gradient du cout s'annule, soit lorsque :

$$\nabla J(\hat{\alpha}) = 0 \Leftrightarrow -X^T \mathbf{y} + X^T X \hat{\alpha} = 0$$

C'est-à-dire dans le cas de la régression simple :

$$-\begin{pmatrix} xy_1 \\ xy_2 \end{pmatrix} + \begin{pmatrix} xx_{11} & xx_{12} \\ xx_{21} & xx_{22} \end{pmatrix} \begin{pmatrix} \hat{a} \\ \hat{b} \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

La solution du problème de minimisation des moindres carrés est le vecteur  $\hat{\alpha}$  défini par :

$$\hat{\alpha} = (X^T X)^{-1} X^T \mathbf{y}$$

## Prévision

$$\begin{aligned}z &= X \hat{a} \\ &= X (X^T X)^{-1} X^T y \\ &= H y\end{aligned}$$

avec  $H = X (X^T X)^{-1} X^T$

Theorem (les moindres carrés comme une projection)

*H est un projecteur de  $\mathbb{R}^n$*

démonstration :  $HH = H$  puisque

$$\begin{aligned}HH &= X (X^T X)^{-1} X^T X (X^T X)^{-1} X^T \\ &= X (X^T X)^{-1} (X^T X (X^T X)^{-1}) X^T \\ &= X (X^T X)^{-1} X^T = H\end{aligned}$$

# Plan

## 1 Présentation matricielle

- Interprétation matricielle
- Interprétation graphique

## 2 La Régression multiple


- Les données et le modèle
- Mise en œuvre
  - Solution Matlab

# La régression du point de vue géométrique

- $\Omega = \text{span}\{\mathbf{x}, \mathbf{e}\}$

le sous espace vectoriel de  $\mathbb{R}^n$   
engendré par les vecteurs  $\mathbf{x}$  et  $\mathbf{e}$   
(c'est-à-dire les colonnes de la  
matrice  $X$ )

$$\mathbf{z} \in \Omega \Leftrightarrow \exists a, b \in \mathbb{R} \quad \mathbf{z} = a\mathbf{x} + b\mathbf{e}$$



La régression est la projection du vecteur  $\mathbf{y}$  sur le sous espace vectoriel engendré par les observations  $X$ . En effet, on a :

$$X\hat{\alpha} = H\mathbf{y} \quad \text{avec} \quad H = X(X^T X)^{-1} X^T \quad (1)$$


## Estimation et orthogonalité

$$J(\alpha) = \frac{1}{2} \|\varepsilon\|^2$$

$\|\varepsilon\|^2$  est minimal quand on choisit  $\alpha$  tel que  $\mathbf{z} = X\alpha$  est la projection orthogonale de  $\mathbf{y}$  sur  $\Omega$

$$\forall \mathbf{v} \in \Omega \quad \mathbf{v}^\top \varepsilon = 0$$

$$X^\top (\mathbf{y} - X\hat{\alpha}) = 0$$



$$\begin{aligned} X^\top (\mathbf{y} - X\hat{\alpha}) = 0 &\Leftrightarrow X^\top \mathbf{y} - X^\top X\hat{\alpha} = 0 \\ &\Leftrightarrow X^\top X\hat{\alpha} = X^\top \mathbf{y} \\ &\Leftrightarrow \hat{\alpha} = (X^\top X)^{-1} X^\top \mathbf{y} \end{aligned}$$

# Plan

## 1 Présentation matricielle

- Interprétation matricielle
- Interprétation graphique

## 2 La Régression multiple

- Les données et le modèle
- Mise en œuvre
  - Solution Matlab

# La Régression multiple

- Variables explicatives :
  - 1 altitude (en m)
  - 2 pente (en degré)
  - 3 nombre de pins moyens dans une placette de 5 ares
  - 4 hauteur de l'arbre échantillonné au centre de la placette
  - 5 diamètre de cet arbre
  - 6 note de densité du peuplement
  - 7 orientation de la placette (1 : sud, 2 : autres)
  - 8 hauteur (en m) des arbres dominants
  - 9 nombre de strates de végétation
  - 10 mélange du peuplement (1 : pas mélangé, 2 : mélangé)
- Variable à expliquer ( $y$ ) :
  - ▶ logarithme du nombre de nids de processionnaires par arbre d'une placette

source : Tomassone et al. [1992]

$$y = a_0 + a_1x_1 + a_2x_2 + \dots + a_jx_j + \dots + a_px_p + \varepsilon$$

$p = 1$  c'est la régression linéaire simple

# Les objectifs de la régression multiple

$$y = a_0 + a_1x_1 + a_2x_2 + \dots + a_jx_j + \dots + a_px_p + \varepsilon$$

- identifier le modèle :
  - ▶ estimer les coefficients  $a_j$ ,  $j = 0, p$  à partir des observations disponibles
  - ▶ estimer la précision de cette estimation
  - ▶ décider de la nature de l'influence de chaque variable explicative  $x_j$  sur la variable à expliquer  $y$  (si en fait  $a_j = 0$ )
- valider le modèle :
  - ▶ donner une mesure de la qualité globale de la régression
- détecter les points aberrants où hors épure
- prévoir pour une nouvelle observation  $\mathbf{x}$  la valeur de  $y$



# Les données

X_1	X_2	X_3	...	X_10	Y
-0.6416	-0.3934	-0.7313	...	0.9820	0.5524
0.8415	2.1730	0.3442	...	1.6411	0.7336
0.6521	0.5006	3.4307	...	-0.5842	-1.6001
0.1848	-0.2535	0.3812	...	-0.8544	-0.3328
0.3635	0.5542	1.9298	...	0.6564	0.6291
0.5890	-0.2903	1.5685	...	-1.6603	-0.5648
0.5153	-0.4606	0.2263	...	1.6934	-1.0449
0.9598	1.2378	-2.0753	...	0.5395	-0.4543
1.9332	2.2013	-0.2789	...	0.2030	-1.4092
-0.0956	-2.0578	-0.9055	...	-2.3387	1.0096
0.5377	2.7694	1.4090	...	-0.3034	0.3252
1.8339	-1.3499	1.4172	...	0.2939	-0.7549
-2.2588	3.0349	0.6715	...	-0.7873	1.3703
0.8622	0.7254	-1.2075	...	0.8884	-1.7115
0.3188	-0.0631	0.7172	...	-1.1471	-0.1022
-1.3077	0.7147	1.6302	...	-1.0689	-0.2414
-0.4336	-0.2050	0.4889	...	-0.8095	0.3192
0.3426	-0.1241	1.0347	...	-2.9443	0.3129
3.5784	1.4897	0.7269	...	1.4384	-0.8649

$$\begin{pmatrix} X_{11} & X_{12} & \dots & X_{1j} & \dots & X_{1p} \\ X_{21} & X_{22} & \dots & X_{2j} & \dots & X_{2p} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ X_{i1} & X_{i2} & \dots & X_{ij} & \dots & X_{ip} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ X_{n1} & X_{n2} & \dots & X_{nj} & \dots & X_{np} \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_i \\ \vdots \\ y_n \end{pmatrix}$$

$$p = 10, \quad n = 19$$

attention

$$X = \begin{pmatrix} 1 & X_{11} & X_{12} & \dots & X_{1j} & \dots & X_{1p} \\ 1 & X_{21} & X_{22} & \dots & X_{2j} & \dots & X_{2p} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & X_{i1} & X_{i2} & \dots & X_{ij} & \dots & X_{ip} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & X_{n1} & X_{n2} & \dots & X_{nj} & \dots & X_{np} \end{pmatrix}$$

$n$  lignes et  $p + 1$  colonnes

# La Régression multiple : le modèle matriciel

$$y = a_0 + a_1x_1 + a_2x_2 + \dots + a_jx_j + \dots + a_px_p + \varepsilon$$

$$\mathbf{y} = X\alpha + \varepsilon$$

## Hypothèse


$X$  est une matrice de rang  $p + 1$  et donc la matrice  $X^T X$  est inversible

$\|\varepsilon\|^2$  est minimal quand on choisit  $\alpha$   
tel que  $\mathbf{z} = X\alpha$  est la projection  
orthogonale de  $\mathbf{y}$  sur  $\Omega$

$$\forall \mathbf{v} \in \Omega \quad \mathbf{v}^T \varepsilon = 0 \quad X^T (\mathbf{y} - X\hat{\alpha}) = 0$$

$$\hat{\alpha} = (X^T X)^{-1} X^T \mathbf{y}$$

on doit résoudre un système linéaire  
de  $p + 1$  inconnues et  $p + 1$  équations



## Mise en œuvre

$$\hat{\alpha} = (X^T X)^{-1} X^T \mathbf{y}$$

Résoudre un système de  $p + 1$  équations linéaires à  $p + 1$  inconnues.

- méthode directe
  - ▶ calcul de l'inverse :  $M = \text{inv}(X^T X)$
  - ▶ calcul des alpha :  $\hat{\alpha} = M(X^T \mathbf{y})$
- factorisation de Cholesky
  - ▶  $\hat{\alpha} = (X^T X) \setminus (X^T \mathbf{y})$
- factorisation QR
  - ▶  $X = QR$ ,  $Q$  matrice orthogonale, et  $R$ , une matrice triangulaire supérieure
  - ▶  $(R^T Q^T QR) \hat{A} = R^T Q^T \mathbf{y}$  soit
  - ▶  $R \hat{\alpha} = Q^T \mathbf{y}$

# Solution Matlab

```
function ahat = regression(x,y)

n = length(y);           % nombre d'observations
X = [ones(n,1) x];      % construction du regresseur
% ahat = inv(X'*X)*(X'*yi); % calcul direct de l'inverse de la matrice
ahat = (X'*X)\(X'*yi);  % résolution du système linéaire par cholesky

% [Q R] = qr(X);
% ahat = R\(Q'*yi);      % résolution par la méthode de Householder
% ahat = X\yi;          % idem mais directement
%-----
function TestRegression

n = 10; d = 5;
xi = rand(n,d); X = [ones(n,1) xi];
a = randn(d+1,1);
sig = 0.1;
yi = X*a + sig*randn(n,1);

ahat = regression(xi,yi);

erreur = norm(a-ahat);
```


## Qualité du modèle : Décomposition de la variance

$$\begin{aligned}\sum_{i=1}^n (y_i - \bar{y})^2 &= \sum_{i=1}^n (y_i - z_i + z_i - \bar{y})^2 \\ &= \sum_{i=1}^n (y_i - z_i)^2 + \sum_{i=1}^n (z_i - \bar{y})^2 + 2 \sum_{i=1}^n (y_i - z_i)(z_i - \bar{y}) \\ &= \sum_{i=1}^n \varepsilon_i^2 + \sum_{i=1}^n (z_i - \bar{y})^2 + 2 \sum_{i=1}^n \varepsilon_i \left( \sum_{j=1}^{p+1} x_{ij} a_j - \bar{y} \right)\end{aligned}$$

$\underbrace{\sum_{i=1}^n (y_i - \bar{y})^2}_{\text{SC Total}} = \underbrace{\sum_{i=1}^n (y_i - z_i)^2}_{\text{SC Résiduels}} + \underbrace{\sum_{i=1}^n (z_i - \bar{y})^2}_{\text{SC Expliqué}}$
--

Interprétation graphique :

$$\begin{aligned}\|y\|^2 &= \|\varepsilon\|^2 + \|z\|^2 \\ \|y - \bar{y}\|^2 &= \|\varepsilon\|^2 + \|z - \bar{y}\|^2\end{aligned}$$



## Qualité du modèle : mesurée par le $R^2$

$$\underbrace{\sum_{i=1}^n (y_i - \bar{y})^2}_{\text{SC Total}} = \underbrace{\sum_{i=1}^n (y_i - z_i)^2}_{\text{SC Résiduels}} + \underbrace{\sum_{i=1}^n (z_i - \bar{y})^2}_{\text{SC Expliqué}}$$

le coefficient de détermination  $R^2$

$$0 \leq R^2 \leq 1$$

$$R^2 = \frac{\text{SC Expliqué}}{\text{SC Total}} = \frac{\sum_{i=1}^n (z_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

$$= \cos^2(\mathbf{y} - \bar{y}\mathbf{e}, \mathbf{z} - \bar{y}\mathbf{e})$$

$$= 1 - \frac{\text{SC Résiduels}}{\text{SC Total}}$$

$R^2$  proche de 1 :  
le modèle est bon

$R^2$  proche de 0 :  
le modèle est mauvais

le coefficient de corrélation multiple :  $R = \sqrt{R^2} = |\text{cor}(\mathbf{y}, \mathbf{z})|$  ;  $\mathbf{z} = X\hat{\alpha}$

## Régression sur variables qualitatives

$y$  : le rendement (quintaux/ha) = rendement moyen + effet variété

$$\begin{aligned}y &= a_0 + a_1x_1 + a_2x_2 + \cdots + a_jx_j + \cdots + a_px_p \\ &= a_0 + a_10 + a_20 + \cdots + a_j1 + \cdots + a_p0 = a_0 + a_j\end{aligned}$$

$$X = \begin{pmatrix} 1 & 1 & \cdots & 0 & \cdots & 0 \\ 1 & 1 & \cdots & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & \cdots & 1 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & \cdots & 0 & \cdots & 1 \end{pmatrix}$$

$X$  n'est pas de rang  $p + 1$  et donc  $X^T X$  est singulière. On impose en plus une contrainte d'équilibrage.

$$a_1 + a_2 + \cdots + a_j + \cdots + a_p = 0$$

## Différents type de modèles linéaires (simples)

$$\mathbf{y} = X\mathbf{a} + \varepsilon$$

	variable à expliquer $\mathbf{y}$	variable explicative $X$	nom de la méthode
exemple :	quantitative position	quantitative temps	régression
exemple :	quantitative rendement	qualitative variété	analyse de la variance
exemple :	qualitative variété	quantitative taille	analyse discriminante
exemple :	qualitative spam/nospam	qualitative présence de mots	analyse discriminante



# Conclusion

- le modèle linéaire

- ▶  $\mathbf{y} = X\hat{\alpha} + \varepsilon$

- Moindres carré

- ▶ le cout est minimal quand  $X^T(\mathbf{y} - X\hat{\alpha}) = 0$

- ▶ calcul de  $\hat{\alpha}$  au prix de la résolution d'un système linéaire

- reste à faire

- ▶ diagnostic du modèle
  - ▶ diagnostic des variables
  - ▶ diagnostic des individus
  - ▶ transformation des variables

## Repères bibliographiques

