

La régression linéaire

Stéphane Canu
stephane.canu@litislab.eu

M8 - Principes du traitement de l'information

March 26, 2019

Plan

1 Histoire, principe et modèle

- Une régression pour quoi faire ?
- Exemple Simple

2 Les moindres carrés pour la régression simple

- Le cout à minimiser
- innovation ou erreur
- Calcul scalaire des estimateurs
- Le calcul pratique
- Une brève interprétation des coefficients
- Prédiction

Observation d'un couple de variables






Figure 4b: Changes in Property Crime and Abortion Rates, 1985-1997

Figure : Exemples de données qui semblent linéairement liées

(<http://www.math.yorku.ca/SCS/Gallery/>, http://papers.ssrn.com/sol3/papers.cfm?abstract_id=174508)

Le problème de la régression linéaire

- n couples d'observations




- ▶ x : **la variable explicative** :
quantité d'additif, années, température
- ▶ y **la variable à expliquer** :
quantité de produit, nombre de ventes,
concentration en ozone

x	1	2	4	4,5	5,25
y	-1	-2	0,5	1	4

\mathbf{x}	x_1	x_2	x_3	x_4	x_5
\mathbf{y}	y_1	y_2	y_3	y_4	y_5

Le problème de la régression linéaire




- n couples d'observations
 - ▶ x : **la variable explicative** :
quantité d'additif, années, température
 - ▶ y **la variable à expliquer** :
quantité de produit, nombre de ventes,
concentration en ozone
- **Trouver la droite qui représente « au mieux » la relation linéaire**

$$y = ax + b$$

x	1	2	4	4,5	5,25
y	-1	-2	0,5	1	4

\mathbf{x}	x_1	x_2	x_3	x_4	x_5
\mathbf{y}	y_1	y_2	y_3	y_4	y_5

Le problème de la régression linéaire



- n couples d'observations
 - ▶ x : la **variable explicative** :
quantité d'additif, années, température
 - ▶ y la **variable à expliquer** :
quantité de produit, nombre de ventes,
concentration en ozone
- Trouver la droite qui représente « au mieux » la relation linéaire

$$y = ax + b$$


x	1	2	4	4,5	5,25
y	-1	-2	0,5	1	4

\mathbf{x}	x_1	x_2	x_3	x_4	x_5
\mathbf{y}	y_1	y_2	y_3	y_4	y_5

- difficulté : les observations ne sont pas exactement sur la droite : il y a du bruit

$$y_i = ax_i + b + \epsilon_i$$

Le modèle linéaire



Données (x_i, y_i)

inconnues : (a, b, ε_i)

Definition (Le Modèle linéaire)

Le modèle linéaire pose la relation suivante entre la variable explicative x et la variable à expliquer y avec les paramètres inconnus (a, b, ε)

$$y = ax + b + \varepsilon \quad \text{avec} \quad \mathbf{a} = (a, b) \in \mathbb{R}^2$$

Observations = modèle + bruit

$$\mathbb{E}(\varepsilon) = 0 \text{ et } \mathbb{E}(\varepsilon^2) = \sigma^2$$

Vocabulaire

- variables explicatives $\mathbf{x} \in \mathbb{R}^p$
- variable à expliquer $y \in \mathbb{R}$
- erreur ou bruit ε
- paramètres scalaires $a, b \in \mathbb{R}$,
- paramètres vectoriels $\mathbf{a} \in \mathbb{R}^p$
- modèle $y = f(\mathbf{x}, \mathbf{a}) + \varepsilon$
- estimation \hat{a}
- prédiction $\hat{y} = f(\mathbf{x}, \hat{\mathbf{a}})$
- variables aléatoires ε et donc y et donc \hat{a}

$$y = \underbrace{ax + b}_{f(x, \mathbf{a})} + \varepsilon$$

Un exemple : l'étalonnage d'un capteur

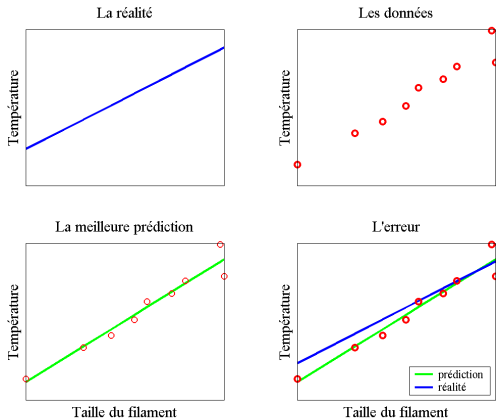


Figure : Les différentes phases de la régression

Plan

1 Histoire, principe et modèle

- Une régression pour quoi faire ?
- Exemple Simple

2 Les moindres carrés pour la régression simple

- **Le cout à minimiser**
- innovation ou erreur
- Calcul scalaire des estimateurs
- Le calcul pratique
- Une brève interprétation des coefficients
- Prédiction

Le critère des moindres carrés

$$\min_{a,b} J(a, b)$$
$$J(a, b) = \sum_{i=1}^n \underbrace{(y_i - ax_i - b)}_{\varepsilon_i}^2$$

Ce problème peut s'interpréter comme la recherche de la droite d'équation $ax + b$ passant « au mieux » (au sens des moindres carrés) parmi le nuage des observations (x_i, y_i) $i = 1, n$.




Figure : Les résidus de la régression

Le critère des moindres carrés

$$\min_{a,b} J(a, b)$$
$$J(a, b) = \sum_{i=1}^n \underbrace{(y_i - ax_i - b)}_{\varepsilon_i}^2$$

Ce problème peut s'interpréter comme la recherche de la droite d'équation $ax + b$ passant « au mieux » (au sens des moindres carrés) parmi le nuage des observations (x_i, y_i) $i = 1, n$.




Figure : Les résidus de la régression

Le critère des moindres carrés

$$\min_{a,b} J(a, b)$$

$$J(a, b) = \sum_{i=1}^n \underbrace{(y_i - ax_i - b)}_{\varepsilon_i}^2$$

Ce problème peut s'interpréter comme la recherche de la droite d'équation $ax + b$ passant « au mieux » (au sens des moindres carrés) parmi le nuage des observations (x_i, y_i) $i = 1, n$.




Figure : Les résidus de la régression

Le critère des moindres carrés

$$\min_{a,b} J(a, b)$$
$$J(a, b) = \sum_{i=1}^n \underbrace{(y_i - ax_i - b)^2}_{\varepsilon_i}$$

Ce problème peut s'interpréter comme la recherche de la droite d'équation $ax + b$ passant « au mieux » (au sens des moindres carrés) parmi le nuage des observations (x_i, y_i) $i = 1, n$.




Figure : Les résidus de la régression

Le problème des moindres carrés

Les données dont nous disposons peuvent aussi être vue comme un système de n équations à $2 + n$ inconnues (a , b et ε). Ce système s'écrit de la manière suivante :

$$\left\{ \begin{array}{l} ax_1 + b + \varepsilon_1 = y_1 \\ \dots \quad \dots \\ ax_i + b + \varepsilon_i = y_i \\ \dots \quad \dots \\ ax_n + b + \varepsilon_n = y_n \end{array} \right.$$

on recherche a et b qui minimisent simultanément tous les $\varepsilon_i, i = 1, n$

$$J(a, b) = \sum_{i=1}^n \underbrace{(y_i - ax_i - b)}_{\varepsilon_i}^2$$

Calcul du gradient

$$\min_{a,b} J(a,b) \quad \text{avec} \quad J(a,b) = \frac{1}{2} \sum_{i=1}^n (ax_i + b - y_i)^2$$

$$\left\{ \begin{array}{l} \frac{\partial J(a,b)}{\partial a} = \sum_{i=1}^n (ax_i + b - y_i) x_i = \sum_{i=1}^n (ax_i^2 + bx_i - y_i x_i) \\ \qquad \qquad \qquad = \sum_{i=1}^n ax_i^2 + \sum_{i=1}^n bx_i - \sum_{i=1}^n y_i x_i \\ \qquad \qquad \qquad = a \sum_{i=1}^n x_i^2 + b \sum_{i=1}^n x_i - \sum_{i=1}^n y_i x_i \\ \frac{\partial J(a,b)}{\partial b} = \sum_{i=1}^n (ax_i + b - y_i) = \sum_{i=1}^n ax_i + \sum_{i=1}^n b - \sum_{i=1}^n y_i \\ \qquad \qquad \qquad = a \sum_{i=1}^n x_i + bn - \sum_{i=1}^n y_i \end{array} \right.$$

Conditions d'optimalité

$$(\hat{a}, \hat{b}) \text{ est solution du problème } \min_{a,b} J(a,b) \Leftrightarrow \begin{cases} \frac{\partial J(\hat{a}, \hat{b})}{\partial a} = 0 \\ \frac{\partial J(\hat{a}, \hat{b})}{\partial b} = 0 \end{cases}$$

$$\begin{cases} \frac{\partial J(\hat{a}, \hat{b})}{\partial a} = 0 \\ \frac{\partial J(\hat{a}, \hat{b})}{\partial b} = 0 \end{cases} \Leftrightarrow \begin{cases} \hat{a} \sum_{i=1}^n x_i^2 + \hat{b} \sum_{i=1}^n x_i = \sum_{i=1}^n y_i x_i & \times n \quad (1) \\ \hat{a} \sum_{i=1}^n x_i + \hat{b} n = \sum_{i=1}^n y_i & \times \sum_{i=1}^n x_i \quad (2) \end{cases}$$

$$\hat{a} \left(n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2 \right) = n \sum_{i=1}^n y_i x_i - \sum_{i=1}^n y_i \sum_{i=1}^n x_i$$

Deux équations linéaires à deux inconnues

$$\hat{a} = \frac{n \sum_{i=1}^n y_i x_i - \sum_{i=1}^n y_i \sum_{i=1}^n x_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2} \qquad \hat{b} = \frac{\sum_{i=1}^n y_i - \hat{a} \sum_{i=1}^n x_i}{n}$$

Réécriture de la solution

si l'on note $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$, $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$ et $V_x = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ la variance des x_i

$$\begin{aligned}\hat{a} &= \frac{n \sum_{i=1}^n y_i x_i - \sum_{i=1}^n y_i \sum_{i=1}^n x_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i\right)^2} \\ &= \frac{\frac{1}{n} \sum_{i=1}^n y_i x_i - \frac{1}{n} \sum_{i=1}^n y_i \frac{1}{n} \sum_{i=1}^n x_i}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2} \\ &= \frac{\frac{1}{n} \sum_{i=1}^n y_i x_i - \bar{y} \bar{x}}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2} \\ &= \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}\end{aligned}$$

$$\begin{aligned}\hat{b} &= \frac{\sum_{i=1}^n y_i - \hat{a} \sum_{i=1}^n x_i}{n} \\ &= \frac{1}{n} \sum_{i=1}^n y_i - \hat{a} \frac{1}{n} \sum_{i=1}^n x_i \\ &= \bar{y} - \hat{a} \bar{x}\end{aligned}$$

$$= \frac{\text{cov}(\mathbf{x}, \mathbf{y})}{V_x}$$

Le théorème des moindres carrés

Théorème des moindres carrés

Soient $(x_i, y_i), i = 1, n$ un ensemble de couples d'observations.

La solution du problème de minimisation de la somme des carrés des erreurs

$$\min_{a,b} \sum_{i=1}^n (ax_i + b - y_i)^2$$

est donnée par \hat{a} et \hat{b} définis par :

$$\hat{a} = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\text{cov}(x, y)}{V_x} \quad \text{et} \quad \hat{b} = \bar{y} - \hat{a} \bar{x}$$

\hat{a} et \hat{b} que l'on appelle aussi les estimateurs au sens des moindres carrés.

Le calcul pratique

Pratiquement, il est pratique de calculer les quantités suivante :

$$\begin{aligned} SX &= \sum_{i=1}^n x_i & \bar{x} &= \frac{SX}{n} & SXX &= \sum_{i=1}^n (x_i - \bar{x})^2 \\ SY &= \sum_{i=1}^n y_i & \bar{y} &= \frac{SY}{n} & SY Y &= \sum_{i=1}^n (y_i - \bar{y})^2 \\ & & & & SXY &= \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} \end{aligned}$$

et en déduire :

$$\hat{a} = \frac{SXY}{SXX} \quad \text{et} \quad \hat{b} = \bar{y} - \hat{a}\bar{x}$$

Le tableau des moindres carrés

variables explicatives x	variables à expliquer y	prédiction $y_p = \hat{a}x_i + \hat{b}$	résidus $\varepsilon_i = y - y_p$
0.1000	2.3196	2.0681	0.2514
0.3000	2.1000	2.3061	-0.2061
0.7000	2.5836	2.7820	-0.1984
0.8000	2.7000	2.9010	-0.2010
0.9500	3.4335	3.0795	0.3540

$sx2 = \text{sum}((x - \text{mean}(x)).^2)$, $sy2 = \text{sum}((y - \text{mean}(y)).^2)$, $sxy = ((x - \text{mean}(x)))' * (y - \text{mean}(y))$
 $sx2 = 0.5080$ $sy2 = 1.0299$ $sxy = 0.6044$

$a = sxy/sx2 = 1.1898$

$b = \text{mean}(y) - a * \text{mean}(x) = 1.9492$

$y_p = a * x + b$

$e = y - y_p$

Le poids des individus et le choc des variables

Une première remarque permet d'évaluer l'influence de chacune des observation dans le calcul de coefficient directeur \hat{a} . En effet on a :

$$\hat{a} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\sum_{i=1}^n (x_i - \bar{x}) y_i}{\sum_{i=1}^n (x_i - \bar{x})^2} = \sum_{i=1}^n \frac{x_i - \bar{x}}{\sum_{i=1}^n (x_i - \bar{x})^2} y_i = \sum_{i=1}^n w_i y_i$$

$$w_i = \frac{x_i - \bar{x}}{\sum_{i=1}^n (x_i - \bar{x})^2} \text{ mesure le poids de l'observation } x_i \text{ dans le calcul de } \hat{a}.$$

Le lien de \hat{a} avec la corrélation est évident puisque l'on a :

$$\hat{a} = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\text{cov}(\mathbf{x}, \mathbf{y})}{s_x^2}$$

Il peut aussi s'écrire en fonction de la corrélation :

$$\hat{a} = \frac{\text{cov}(\mathbf{x}, \mathbf{y})}{s_x s_x} \frac{s_y}{s_y} = \frac{\text{cov}(\mathbf{x}, \mathbf{y})}{s_x s_y} \frac{s_y}{s_x} = \text{cor}(\mathbf{x}, \mathbf{y}) \frac{s_y}{s_x}$$

L'équation de la droite de régression s'écrit aussi :

$$y = \frac{\text{cov}(\mathbf{x}, \mathbf{y})}{s_x^2} (x - \bar{x}) + \bar{y}$$

car

$$\begin{aligned} y &= \hat{a}x + \hat{b} \\ &= \hat{a}x + \bar{y} - \hat{a}\bar{x} \\ &= \hat{a}(x - \bar{x}) + \bar{y} = \frac{\text{cov}(\mathbf{x}, \mathbf{y})}{s_x^2} (x - \bar{x}) + \bar{y} \end{aligned}$$

La droite de régression passe par le point (\bar{x}, \bar{y}) , le centre de gravité du nuage de points car $\hat{a}\bar{x} + \hat{b} = \bar{y}$.

Prédiction et erreur de prédiction

Pour un x donné, $y_x = f(x)$ est une v.a.

$$y_x = \hat{a}x + \hat{b} + \varepsilon = \bar{y} + \hat{a}(x - \bar{x}) + \varepsilon$$

on calcule son espérance : $\mathbb{E}(y_x) = ax + b$
que l'on estime par :

$$\widehat{\mathbb{E}(y_x)} = \hat{a}x + \hat{b} = \bar{y} + \hat{a}(x - \bar{x})$$

Il est aussi possible d'associer à cette prévision une mesure d'incertitude :

$$V(y_x) = V(\bar{y}) + V(\hat{a})(x - \bar{x})^2 + \sigma^2$$




Figure : prédiction avec la régression

Théorème : pour un x donné il est très probable que (avec une probabilité α)

$$y_x \in \left\{ \bar{y} + \hat{a}(x - \bar{x}) \pm t_{\frac{\alpha}{2}} \hat{\sigma} \sqrt{1 + \frac{1}{n} + \frac{(x - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} \right\}$$

Plus on s'éloigne de la moyenne des x , plus l'incertitude grandit

Démonstration

$$\begin{aligned}V(\hat{a}) &= V\left(\frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (\mathbf{x}_i - \bar{x})^2}\right) \\&= \left(\frac{1}{\sum_{i=1}^n (\mathbf{x}_i - \bar{x})^2}\right)^2 V\left(\sum_{i=1}^n (a(x_i - \bar{x}) + \varepsilon)(x_i - \bar{x})\right) \\&= \left(\frac{1}{\sum_{i=1}^n (\mathbf{x}_i - \bar{x})^2}\right)^2 V\left(\sum_{i=1}^n \varepsilon(x_i - \bar{x})\right) \\&= \frac{\sigma^2}{\sum_{i=1}^n (\mathbf{x}_i - \bar{x})^2}\end{aligned}$$

D'où

$$\begin{aligned}V(y_x) &= V(\bar{y}) + V(\hat{a})(\mathbf{x} - \bar{x})^2 + \sigma^2 \\&= \frac{\sigma^2}{n} + \frac{\sigma^2}{\sum_{i=1}^n (\mathbf{x}_i - \bar{x})^2} (\mathbf{x} - \bar{x})^2 + \sigma^2 \\&= \sigma^2 \left(1 + \frac{1}{n} + \frac{(\mathbf{x} - \bar{x})^2}{\sum_{i=1}^n (\mathbf{x}_i - \bar{x})^2}\right)\end{aligned}$$

Puis on estime σ^2 par la moyenne pondérée des carrés des résidus

$$\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n (y_i - (\hat{a}x_i + \hat{b}))^2$$

Codage de la régression en matlab et en python

```

sx2 = sum((x-mean(x)).^2),
sy2 = sum((y-mean(y)).^2),
sxy=(x-mean(x))*(y-mean(y))

a = sxy/sx2
b = mean(y) - a*mean(x)

yp = a*x+b
e = y - yp

n = length(e);
sigma2_hat = 1/(n-2)* e'*e;

xt = 0:0.01:1;
yt = a*xt+b;
t = icdf('t',0.025,n-2);
interval = t*sqrt(sigma2_hat*
    (1+1/n+(xt-mean(x)).^2/sx2));

plot(xt,yt);
hold on
plot(xt,yt+interval,'--')
plot(xt,yt-interval,'--')
```

```

sx2 = np.sum((x-np.mean(x))**2)
sy2 = np.sum((y-np.mean(y))**2)
sxy=((x-np.mean(x)).T @ (y-np.mean(y)))

a = sxy/sx2
b = np.mean(y) - a*np.mean(x)

yp = a*x+b;
e = y - yp

n = len(e);
sigma2_hat = 1/(n-2)* e.T@e

xp = np.arange(0,1,.01)
yp = a*xp+b
tv = t.ppf(0.025,n-2)
interval = tv*np.sqrt(sigma2_hat*
    (1+1/n+(xp-np.mean(x))**2/sx2));

plt.plot([xp, xp],[yp-interval, yp+interval])
plt.plot([xm,xM],[ym,yM], 'gv-', linewidth=2)
plt.plot(x,y,'b+')
plt.show()
```

ACP pour $p = 2$ et régression linéaire

Régression linéaire :

$$\min_{a,b} \sum_{i=1}^n (ax_i + b - y_i)^2$$

ACP :

$$\min_{a,b} \sum_{i=1}^n \|(x_i, y_i) - \text{proj sur } \Delta_{(a,b)}\|^2$$

où $\Delta_{(a,b)}$ est la droite d'équation $y = ax + b$.





Figure : Régression linéaire et ACP (régression orthogonale)

Conclusion



- observation = modèle + bruit
 - ▶ modèle linéaire
 - ▶ certains modèles non linéaires peuvent être linéarisés
- Moindres carré
 - ▶ facile à calculer
- reste à faire
 - ▶ passer au multi dimensionnel (plusieurs variables explicatives)
 - ▶ valider le modèle : diagnostique de la régression

Repères bibliographiques

- `http://papers.ssrn.com/sol3/papers.cfm?abstract_id=174508`