

CHAPITRE VIII

Prédiction et prévision avec la régression linéaire

Des $(x_i, y_i)_i$ observés, on a tiré une estimation $\hat{Y} = \hat{a}_0 + \hat{a}_1 X$
de la relation théorique $Y = a_0 + a_1 X + \mathbf{e}$

Pour une nouvelle observation x_h
Comment *prévoir*¹ y_h ?

Il est clair que la vraie valeur devrait être :

$$y_h = a_0 + a_1 x_h + \mathbf{e}_h$$

Mais cela suppose la parfaite connaissance de:

- a_0
- a_1
- et même \mathbf{e}_h la valeur de l'erreur théorique !!!

Ne connaissant que \hat{a}_0, \hat{a}_1 , 3 possibilités s'offrent donc à nous :

1. Utiliser $\hat{a}_0 + \hat{a}_1 X$... comme **prédiction**
2. Utiliser $a_0 + a_1 X$ et rappeler que si $\hat{a}_0 + \hat{a}_1 X$ en est un estimateur, il faut lui associer un intervalle de confiance.
3. Utiliser $a_0 + a_1 X + \mathbf{e}$ et se rappeler que l'on dispose d'un estimateur de l'erreur théorique.

Revenons sur chacune de ces stratégies.

¹ Prédiction : affirmer ce qui sera Prévoir : : déterminer ce qui pourrait être.

STRATEGIE 1 : Prédiction ou estimation ponctuelle :

On assimile y_h à \hat{y}_h
la valeur donnée par la droite de régression linéaire.

Exemple :

- Hier, on a estimé la relation linéaire $\hat{Y} = \hat{a}_0 + \hat{a}_1 X$
- On observe ce matin $x_h = 0,3$.
- Le niveau prévu par la droite de régression est :
$$\hat{y}_h = \hat{a}_0 + \hat{a}_1 x_h = \hat{a}_0 + 0,3 \cdot \hat{a}_1$$

Pb : Cette valeur n'est en fait qu'une **prédiction** possible parmi d'autres² puisque l'on sait qu'à chaque estimateur \hat{a}_i correspond un intervalle de confiance ...

STRATEGIE 2 : Moyenne des prévisions, intervalle de confiance

On cherche à fixer y_h à la valeur moyenne que l'on doit théoriquement obtenir :

$$a_0 + a_1 x_h = E[y_h]$$

qui est estimé par $\hat{a}_0 + \hat{a}_1 x_h$.

La prise en compte des erreurs d'estimation des coefficients est aisée puisqu'on a les variances estimées et donc $\hat{S}_{\hat{a}_0}$ et $\hat{S}_{\hat{a}_1}$.

En fait, les statistiques nous disent que : $E[y_h] \sim N(\hat{y}_h, \mathbf{S}_{E[y_h]}^2)$

Autrement dit :

$$\frac{E[y_h] - \hat{y}_h}{\mathbf{S}_{E[y_h]}} \sim N(0,1)$$

et qu'un estimateur de la variance est donnée par :

² En fait c'est la prédiction moyenne

$$\mathbf{s}_{E[y_h]}^2 = \mathbf{s}_e^2 \left(\frac{1}{n} + \frac{(x_h - \bar{x})^2}{\sum (x_i - \bar{x})^2} \right)$$

On a donc :

$$\frac{E[y_h] - \hat{y}_h}{\hat{\mathbf{s}}_{E[y_h]}} \sim t_{n-2}$$

D'où :

$$\hat{y}_h - \hat{\mathbf{s}}_{E[y_h]} t_{n-2}^{1-\alpha/2} \leq E[y_h] \leq \hat{y}_h + \hat{\mathbf{s}}_{E[y_h]} t_{n-2}^{1-\alpha/2}$$

avec $t_{n-2}^{1-\alpha/2}$ le seuil de confiance.

L'intervalle est d'autant plus grand que :

- la variance estimée augmente ...
- $(x_h - \bar{x})^2$ augmente ...
- que $x_h \ll \bar{x}$ ou $x_h \gg \bar{x}$.

STRATEGIE 3 : Intervalle de prévision

On cherche à déterminer l'ensemble des prévisions "admissibles" en tenant compte de l'erreur théorique de modélisation.

On a théoriquement :

$$y_h = a_0 + a_1 x_h + \mathbf{e}_h$$

Qui peut aussi s'écrire :

$$y_h = E[y_h] + \mathbf{e}_h$$

Or, on sait que :

$$E[y_h] \sim N(\hat{y}_h, \mathbf{s}_{E[y_h]}^2)$$

$$\mathbf{e} \sim N(0, \mathbf{s}_e^2)$$

Somme de 2 variables normales et indépendantes, on a :

- y_h est une loi normale
- de moyenne la somme des moyennes
- de variance la somme des variances (l'erreur est non corrélée avec la variable exogène)

Conclusion :

$$y_h = E[y_h] + \mathbf{e}_h \sim N(\hat{y}_h, \mathbf{s}_{E[y_h]}^2 + \mathbf{s}_e^2)$$

et donc

$$\frac{y_h - \hat{y}_h}{\sqrt{\mathbf{s}_{E[y_h]}^2 + \mathbf{s}_e^2}} \sim N(0,1)$$

En remplaçant les variances par leurs estimateurs :

$$\frac{y_h - \hat{y}_h}{\sqrt{\hat{\mathbf{s}}_{E[y_h]}^2 + \hat{\mathbf{s}}_e^2}} \sim t_{n-2}$$

On obtient donc l'intervalle :

$$\boxed{\hat{y}_h - \sqrt{\hat{\mathbf{s}}_{E[y_h]}^2 + \hat{\mathbf{s}}_e^2} t_{n-2}^{1-\alpha/2} \leq y_h \leq \hat{y}_h + \sqrt{\hat{\mathbf{s}}_{E[y_h]}^2 + \hat{\mathbf{s}}_e^2} t_{n-2}^{1-\alpha/2}}$$

D'un point de vue théorique :

- la stratégie 1 : non satisfaisante,
- la stratégie 2 : si on assume l'erreur théorique,
- la stratégie 3 : l'idéal.