


Une application de Gram-Schmidt à la régression linéaire



$$\sum_{i=1}^n (ax_i + b - y_i)^2 = \|\vec{u} - \vec{v}\|^2$$

Il suffit de prendre


le produit scalaire usuel sur \mathbb{R}^n ($n =$ nombre de points)

$$\vec{v} \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} = \vec{Y}$$

$$\vec{u} \begin{pmatrix} ax_1 + b \\ \vdots \\ ax_n + b \end{pmatrix} = a\vec{X} + b\vec{1}$$

$$\vec{X} \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \quad \vec{1} \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}$$

on cherche a et b qui minimisent $\|a\vec{X} + b\vec{1} - \vec{Y}\|^2$
 $a\vec{X} + b\vec{1}$ parcourt un plan vectoriel de \mathbb{R}^n



La solution est obtenue en calculant le projeté orthogonal du vecteur \vec{Y} sur le plan vectoriel $P = \text{Vect}(\vec{1}, \vec{X})$

Gram-Schmidt sur P
 $\vec{e}_1 = \vec{1}$ $\vec{e}_2 = \vec{X}$
 Normalisation \vec{e}_1

$$\|\vec{1}\|^2 = \underbrace{1^2 + \dots + 1^2}_n = n$$

$$\vec{u}_1 = \frac{\vec{1}}{\sqrt{n}}$$

$$\text{pr}_{\vec{u}_1}(\vec{e}_2) = \langle \vec{u}_1 | \vec{e}_2 \rangle \vec{u}_1$$

$$= \frac{1}{n} \langle \vec{1} | \vec{X} \rangle \vec{1}$$

$$\langle \vec{1} | \vec{X} \rangle = \left\langle \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} \middle| \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \right\rangle$$

$$= x_1 + \dots + x_n$$

$$\frac{1}{n} \langle \vec{1} | \vec{X} \rangle = \frac{x_1 + \dots + x_n}{n} = \bar{x} \quad \text{moyenne des } x_i$$

$$pr_{\vec{u}_1}(\vec{e}_2) = \bar{x} \vec{1}$$

$$\vec{p}_2 = \vec{e}_2 - pr_{\vec{u}_1}(\vec{e}_2)$$

$$= \vec{X} - \bar{x} \vec{1} = \begin{pmatrix} x_1 - \bar{x} \\ \vdots \\ x_n - \bar{x} \end{pmatrix}$$

$$\|\vec{p}_2\|^2 = \sum_{i=1}^n (x_i - \bar{x})^2$$

$$\vec{u}_2 = \frac{\vec{X} - \bar{x} \vec{1}}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}}$$

Projection de \vec{Y} sur (\vec{u}_1, \vec{u}_2)

$$\langle \vec{u}_1 | \vec{Y} \rangle \vec{u}_1 + \langle \vec{u}_2 | \vec{Y} \rangle \vec{u}_2$$

$$= \frac{1}{n} \langle \vec{1} | \vec{Y} \rangle \vec{1} +$$

$$\frac{1}{\sum_{i=1}^n (x_i - \bar{x})^2} \langle \vec{X} - \bar{x} \vec{1} | \vec{Y} \rangle$$

$$(\vec{X} - \bar{x} \vec{1})$$

$$\langle \vec{1} | \vec{Y} \rangle = \sum_{i=1}^n y_i$$

$$\langle \vec{X} - \bar{x} \vec{1} | \vec{Y} \rangle$$

$$= \sum_{i=1}^n (x_i - \bar{x}) y_i$$

$$= \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

$$\text{car } \sum_{i=1}^n (x_i - \bar{x}) = 0$$

$$\text{avec } \bar{y} = \frac{\sum y_i}{n}$$

$$= \bar{y} \vec{1} + \frac{\sigma_{xy}}{\sigma_{xx}} (\vec{X} - \bar{x} \vec{1})$$

avec

$$\sigma_{xy} = \frac{1}{n} \sum (x_i - \bar{x})(y_i - \bar{y})$$

$$\sigma_{xx} = \frac{1}{n} \sum (x_i - \bar{x})^2$$

$$= \underbrace{\frac{\sigma_{xy}}{\sigma_{xx}}}_{a} \vec{X} + \underbrace{(\bar{y} - a\bar{x})}_{b} \vec{1}$$

La droite de régression
a pour pente $a = \frac{\sigma_{xy}}{\sigma_{xx}}$

et elle passe par \bar{x} et \bar{y} (\bar{x}, \bar{y})

$$a\bar{x} + b$$

$$= a\bar{x} + (\bar{y} - a\bar{x})$$

$$= \bar{y}$$