

ML 01 Méthode des moindres carrés

1 Espace de fonctions

Soit un espace vectoriel composé de fonctions. Une base de cet espace est un ensemble de fonctions (f_1, f_2, \dots, f_N) tel que toute fonction de l'espace s'exprime comme combinaison linéaire des fonctions de base.

$$f(\mathbf{x}) = a_1 f_1(\mathbf{x}) + a_2 f_2(\mathbf{x}) + \dots + a_N f_N(\mathbf{x})$$

Pour un jeu de données $\{\mathbf{x}^{(k)}, y^{(k)}\}_{k=1}^N$ de taille N , les coefficients a_i sont solution d'un système linéaire.

$$\begin{pmatrix} f_1(\mathbf{x}^{(1)}) & f_2(\mathbf{x}^{(1)}) & \dots & f_N(\mathbf{x}^{(1)}) \\ f_1(\mathbf{x}^{(2)}) & f_2(\mathbf{x}^{(2)}) & \dots & f_N(\mathbf{x}^{(2)}) \\ \dots & \dots & \dots & \dots \\ f_1(\mathbf{x}^{(N)}) & f_2(\mathbf{x}^{(N)}) & \dots & f_N(\mathbf{x}^{(N)}) \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \\ \dots \\ a_N \end{pmatrix} = \begin{pmatrix} y^{(1)} \\ y^{(2)} \\ \dots \\ y^{(N)} \end{pmatrix}$$

Nous notons ce système linéaire $\mathbf{Ax} = \mathbf{b}$.

2 Expression matricielle

Le système linéaire $\mathbf{Ax} = \mathbf{b}$ avec $\mathbf{A} \in \mathbb{R}^{M \times N}$ n'a pas de solution quand le nombre d'observations dépasse le nombre de fonctions de base (c'est-à-dire, $M > N$). Une approche possible est alors de chercher une approximation $\mathbf{Ax} \approx \mathbf{b}$ qui minimise la somme des carrés des erreurs : $\|\mathbf{Ax} - \mathbf{b}\|_2^2$.

$$\begin{aligned} & \|\mathbf{Ax} - \mathbf{b}\|_2^2 \\ &= \{\|\mathbf{x}\|_2 = \sqrt{\mathbf{x} \cdot \mathbf{x}}\} \\ & \quad (\mathbf{Ax} - \mathbf{b}) \cdot (\mathbf{Ax} - \mathbf{b}) \\ &= \{\text{Par définition du produit scalaire euclidien}\} \\ & \quad (\mathbf{Ax} - \mathbf{b})^T (\mathbf{Ax} - \mathbf{b}) \\ &= \{\text{propriété de la transposition}\} \\ & \quad (\mathbf{x}^T \mathbf{A}^T - \mathbf{b}^T) (\mathbf{Ax} - \mathbf{b}) \\ &= \{\text{multiplication}\} \\ & \quad \mathbf{x}^T \mathbf{A}^T \mathbf{Ax} - \mathbf{x}^T \mathbf{A}^T \mathbf{b} - \mathbf{b}^T \mathbf{Ax} + \mathbf{b}^T \mathbf{b} \\ &= \{\mathbf{b}^T \mathbf{Ax} \text{ étant une valeur scalaire, } \mathbf{b}^T \mathbf{Ax} = (\mathbf{b}^T \mathbf{Ax})^T = \mathbf{x}^T \mathbf{A}^T \mathbf{b}\} \\ & \quad \mathbf{x}^T \mathbf{A}^T \mathbf{Ax} - 2\mathbf{x}^T \mathbf{A}^T \mathbf{b} + \mathbf{b}^T \mathbf{b} \end{aligned}$$

Cette dernière expression quadratique en \mathbf{x} correspond à une surface convexe. Donc son minimum peut être calculé en annulant sa dérivée (penser à une courbe $y = a + bx + cx^2$ dont l'unique extremum est atteint lorsque la pente est nulle).

$$\begin{aligned} \mathbf{0} &= 2\mathbf{A}^T \mathbf{Ax} - 2\mathbf{A}^T \mathbf{b} \\ &= \\ \mathbf{A}^T \mathbf{Ax} &= \mathbf{A}^T \mathbf{b} \end{aligned}$$

Ainsi, quand $M > N$, la solution approximée \mathbf{x} , telle que $\mathbf{Ax} \approx \mathbf{b}$ par minimisation de la somme des carrés des erreurs, est la solution du système linéaire suivant où $\mathbf{A}^T \mathbf{A}$ est appelée la matrice de Gram.


$$\mathbf{A}^T \mathbf{Ax} = \mathbf{A}^T \mathbf{b}$$

3 Méthode des moindres carrés appliquée à la régression polynomiale

Pour un polynôme de degré $N - 1$, les fonctions de bases mentionnées ci-dessus sont : $f_1(x) = 1$, $f_2(x) = x$, $f_3(x) = x^2, \dots, f_N(x) = x^{N-1}$. Elles permettent de définir la matrice des données \mathbf{A} et la matrice de Gram $\mathbf{A}^T \mathbf{A}$.

Nous reprenons l'exemple synthétique du précédent chapitre et nous résolvons le système linéaire correspondant à la matrice de Gram pour un polynôme de degré fixé.

```
set.seed(1123)
# Image par f d'un échantillon uniforme sur l'intervalle [0,1], avec ajout d'un
# bruit gaussien de moyenne nulle et d'écart type 0.2
data = gendat(10,0.2)
coef = polyreg2(data,3)
plt(data,f)
pltpoly(coef)
```



Ce polynôme de degré trois modélise mieux la fonction génératrice inconnue que celui de degré quatre qui ne commettait aucune erreur sur les données observées.