

LA MODÉLISATION DES DONNÉES PAR LA RÉGRESSION FREINE

RÉSUMÉ DE LA THÉORIE ET DES APPLICATIONS

Régression linéaire

Un ensemble donné de paires de valeurs est considéré $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$, L'exemple le plus simple d'une fonction continue qui se rapproche de la dépendance $y(x)$, basée sur des paires discrètes connues, est une ligne droite $f(x) = a_0 + a_1x$. Méthode d'approximation dans le sens des plus petits carrés, le droit de régression est uniquement déterminé par la condition de minimiser la somme des erreurs soulevées à la deuxième puissance.

$$S_r = \sum_{i=1}^n (y_i - a_0 - a_1x_i)^2.$$

L'annulation des dérivés partiels de la Sum S aux coefficients et conduit à un système d'équations avec la solution: a_0, a_1

$$\begin{cases} a_1 = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2} \\ a_0 = \bar{y} - a_1 \bar{x} \end{cases}$$

où sont les moyennes arithmétiques des valeurs y et \bar{y} si \bar{x}_i respectivement, x_i .

L'écart standard entre les valeurs connues et les bonnes valeurs est

$$\sigma_y = \sqrt{\frac{S_r}{n-2}}.$$

Régression linéaire multiple

Dans le cas de la dépendance à une taille y de deux paramètres x_1 et x_2 , la fonction d'approximation la plus simple est l'expression linéaire $f(x_1, x_2) = a_0 + a_1x_1 + a_2x_2$.

L'optimisation de la somme des carrés d'erreur permet la détermination sans ambiguïté des coefficients a_0, a_1 si a_2 :

$$\begin{cases} na_0 + a_1 \sum_{i=1}^n x_{1,i} + a_2 \sum_{i=1}^n x_{2,i} = \sum_{i=1}^n y_i \\ a_0 \sum_{i=1}^n x_{1,i} + a_1 \sum_{i=1}^n x_{1,i}^2 + a_2 \sum_{i=1}^n x_{1,i} x_{2,i} = \sum_{i=1}^n x_{1,i} y_i \\ a_0 \sum_{i=1}^n x_{2,i} + a_1 \sum_{i=1}^n x_{1,i} x_{2,i} + a_2 \sum_{i=1}^n x_{2,i}^2 = \sum_{i=1}^n x_{2,i} y_i \end{cases}$$

Régressions liniarizatã

Si le modèle mathématique de la foule point est une fonction non linéaire, parfois il peut se transformer en l'équation d'une droite à travers les opérations mathématiques.

Par exemple, une dépendance exponentielle du type $y = a_1 e^{b_1 x}$, où a_1 et b_1 sont constants, sont transformés par logarithme $\ln y = \ln a_1 + b_1 x$. Si noté $y^* = \ln y$, $a_0^* = \ln a_1$ și $a_1^* = b_1$, ensemble de données approximatives avec (x^*, y^*) $f(x^*) = a_0^* + a_1^* \cdot x^*$. Une fois que vous apprenez ces coefficients à partir de l'application de l'algorithme de régression linéaire, les coefficients initiaux:

$$a_1 = e^{a_0^*} \text{ și } b_1 = a_1^*.$$

Aplicația 1.

Trouver l'équation d'une ligne droite qui se rapproche, dans le sens des plus petits carrés, l'ensemble de données indiqué dans le tableau suivant et calculer l'écart standard (déviation) de l'approximation:

i	1	2	3	4	5	6	7
x_i	1	2	3	4	5	6	7
y_i	0.5	2.5	2	4	3.5	6	5.5

Aplicația 2.

Utiliser une régression linéaire multiple pour approximer les données dans le tableau suivant:

x_1	0	2	2,5	1	4	7
x_2	0	1	2	3	6	2
y	5,1	10,2	8,9	0	2,8	27,2

Indicație:

Résoudre le système, les coefficients sont obtenus a_0 , a_1 și a_2 .

$$\begin{bmatrix} n & \sum_{i=1}^n x_{1,i} & \sum_{i=1}^n x_{2,i} \\ \sum_{i=1}^n x_{1,i} & \sum_{i=1}^n x_{1,i}^2 & \sum_{i=1}^n x_{1,i} x_{2,i} \\ \sum_{i=1}^n x_{2,i} & \sum_{i=1}^n x_{1,i} x_{2,i} & \sum_{i=1}^n x_{2,i}^2 \end{bmatrix} \begin{Bmatrix} a_0 \\ a_1 \\ a_2 \end{Bmatrix} = \begin{Bmatrix} \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_{1,i} y_i \\ \sum_{i=1}^n x_{2,i} y_i \end{Bmatrix}$$

Aplicația 3.

Le flux volumétrique à travers un tuyau dépend de son diamètre et de sa pente selon une loi du type:.

$V = a_0 \cdot D^{a_1} \cdot P^{a_2}$ Trouvez le débit correspondant à un tuyau avec D-25 cm et P-0.025 si les données expérimentales suivantes sont connues:

$$D = [10 \ 20 \ 30 \ 10 \ 20 \ 30 \ 10 \ 20 \ 30]; \text{ [cm]}$$

$$P = [0.001 \ 0.001 \ 0.001 \ 0.01 \ 0.01 \ 0.01 \ 0.05 \ 0.05 \ 0.05]; \text{ [-]}$$

$$V = [140 \ 830 \ 2420 \ 470 \ 2890 \ 8400 \ 1110 \ 6900 \ 20000]; \text{ [cm}^3\text{/sec]}$$

Indicație:

It is liniarizeaz-rela-aia de depends:

$$\log(V) = \log(a_0) + a_1 \cdot \log(D) + a_2 \cdot \log(P)$$

$$x_1 = \log(D);$$

$$x_2 = \log(P);$$

$$y = \log(V);$$

De minimiser la somme des carrés d'erreur, trois équations linéaires dans les inconnus $b_0 = \log(a_0)$, a_1 and a_2 .

Probleme propose

1. En utilisant la méthode des plus petits carrés, approximatif le droit (fonction degré 1) qui se rapproche des données expérimentales suivantes:

$$X = [1 \ 2 \ 3 \ 4 \ 5]; \ Y = [0 \ 4 \ 3 \ 6 \ 8].$$

2. Utilisez la méthode des plus petits carrés pour approximer à travers une parabole $f(x) = a_0 + a_1x_i + a_2x_i^2$ les données expérimentales suivantes :

x_i	1	3	8	5
y_i	9	6	9	3

3. Déterminer la fonction $f(x) = a \cdot e^{b/x}$ qui se rapproche dans le sens des plus petits carrés, les valeurs dans le tableau suivant. Spécifier l'écart maximal absolu et relatif. Représenter graphiquement les points donnés et la fonction déterminée.

i	x_i	y_i
0	2	20
1	6	38
2	12	49
3	15	51
4	30	61
5	46	70

4. Utiliser une régression linéaire multiple $f(x_1, x_2)$ pour approximer les données suivantes:

x_1	0	1	2	0	1	2
x_2	2	2	4	4	6	6
y	19	12	11	24	22	15