



Faculté de Technologie

Département d'électronique



Module: Réseaux de neurones artificiels

S2-M1 Automatique et systèmes

Réseaux de neurones artificiels

TP N°1

Régression linéaire simple et multiple

Préparé par:

Nabil Benoudjit, Mohamed Bahaz & Abdelghani Tafsast

But du TP

Construction et évaluation d'un modèle linéaire par le biais de la régression linéaire simple et de la régression linéaire multiple.

I- Partie théorique

1- Régression linéaire simple

La régression s'adresse à un type de problème où les 2 variables quantitatives continues \mathbf{x} et \mathbf{y} ont un rôle asymétrique : la variable \mathbf{y} dépend de la variable \mathbf{x} . La liaison entre la variable \mathbf{y} dépendante (**dite expliquée**) et la variable \mathbf{x} indépendante (**dite explicative**) peut être modélisée par une fonction de type $\mathbf{y} = \mathbf{a} * \mathbf{x} + \mathbf{b}$, représentée graphiquement par une droite. Les coefficients du modèle linéaire sont \mathbf{a} et \mathbf{b} calculés comme suit :

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

$$b = \bar{y} - a * \bar{x} \quad (2)$$

Sous la forme matricielle on a $\mathbf{Y} = \mathbf{X} * \mathbf{A}$, où le vecteur \mathbf{A} contient les coefficients \mathbf{a} et \mathbf{b} du modèle linéaire.

Le vecteur \mathbf{A} est calculé comme suit : $\mathbf{A} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$ (3)

2- Régression linéaire multiple

La régression linéaire multiple est une méthode d'analyse de données quantitatives. Elle a pour but de mettre en évidence la liaison pouvant exister entre une variable dite **expliquée**, que l'on notera \mathbf{Y} et plusieurs autres variables dites **explicatives** que l'on notera X_1, X_2, \dots, X_k .

Les k variables $X_i, i = 1, \dots, k$ sont contrôlées c'est-à-dire qu'elles sont connues **sans erreur**. Nous nous intéressons aux modèles dits **linéaires**, c'est-à-dire aux modèles du type :

$$Y = a_0 + a_1 X_1 + a_2 X_2 + \dots + a_k X_k$$

Où, le vecteur $\mathbf{A} = [\mathbf{b}, \mathbf{a}_1, \dots, \mathbf{a}_k]$ représente les **coefficients du modèle**.

II- Partie simulation

Activité 1:

Nous disposons d'un ensemble de paires de données (voir tableau 1) et nous voulons déterminer la relation entre la variable **expliquée** y et la **variable explicative** x . En d'autres termes trouver la fonction f qui nous permet d'écrire :

$$y = f(x).$$

i	1	2	3	4	5	6
x_i	0	10	20	30	40	50
y_i	4	22	44	60	75	104

Tableau (1)

- 1- Afficher le nuage de points (x_i, y_i) .
- 2- Calculer le centre de gravité du nuage de points \bar{x} et \bar{y} et afficher le sur la même figure.
- 3- Quelle remarque pouvez-vous déduire ?
- 4- Estimer les paramètres a et b du modèle en utilisant les équations (1) et (2).
- 5- Calculer le coefficient de détermination (R^2).
- 6- Calculer l'erreur quadratique moyenne (MSE).
- 7- Estimer les paramètres a et b du modèle, cette fois-ci en utilisant l'équation (3).
- 8- Donner vos conclusions sur cet exemple.

Pour le même exemple, nous avons pour chaque **variable explicative 05 variables expliquées**. Nous proposons de déterminer la relation entre la variable expliquée \bar{y} et la variable explicative x . En d'autre terme trouver la fonction f qui nous permet d'écrire :

$$\bar{y} = f(x).$$

i	1	2	3	4	5	6
x_i	0	10	20	30	40	50
y_{i1}	4	22	44	60	75	104
y_{i2}	3	20	46	63	81	109
y_{i3}	4	21	45	60	79	107
y_{i4}	5	22	44	63	78	101
y_{i5}	4	21	44	63	77	105

Tableau (2)

Refaire la même chose (1 à 8) pour les données du tableau 2.

Activité 2:

Nous cherchons à établir la relation du poids du cerveau (Y) en fonction du poids du corps (X) dans une série d'espèces vivantes (homme + animaux).

N°	Espèce	Corps (Kg)	Cerveau (g)	N°	Espèce	Corps (Kg)	Cerveau (g)
1	Castor	1,35	8,1	15	Eléphant Afrique	6654	5712
2	Vache	465	423	16	Triceratops	9400	70
3	Loup gris	36,3	119,5	17	Singe Rhésus	6,8	179
4	Chèvre	27,66	115	18	Kangourou	35	56
5	Cochon d'inde	1,04	5,5	19	Hamster	0,12	1
6	Diplodocus	11700	50	20	Souris	0,023	0,4
7	Eléphant d'Asie	2547	4603	21	Lapin	2,5	12,1
8	Ane	187,1	419	22	Mouton	55,5	175
9	Cheval	521	655	23	Jaguar	100	157
10	Macaque	10	115	24	Chimpanzé	52,16	440
11	Chat	3,3	25,6	25	Brachiosaure	87000	154,5
12	Girafe	529	680	26	Rat	0,28	1,9
13	Gorille	207	406	27	Taupe	0,122	3
14	Homme	62	1320	28	Cochon	192	180

Tableau (3)

- 1- Afficher le nuage de points (x_i, y_i) . Quelle remarque pouvez-vous déduire ?
- 2- Utiliser le logarithme sur les x_i et y_i . Afficher le nouveau nuage de points $(\log(x_i), \log(y_i))$.
- 3- Quelle remarque pouvez-vous déduire après cette transformation ?
- 4- Calculer le centre de gravité du nouveau nuage de points \bar{x} et \bar{y} et afficher le sur la même figure.
- 5- Estimer les paramètres **a** et **b** du modèle en utilisant l'équation (3).
- 6- Calculer le coefficient de détermination (R^2).
- 7- Calculer l'erreur quadratique moyenne (MSE).
- 8- Enlever les échantillons (mesures) **aberrants 6, 16 et 25** de la base de données et afficher le nouveau nuage.
- 9- Calculer le centre de gravité du nouveau nuage de points \bar{x} et \bar{y} et afficher le sur la même figure.
- 10- Estimer les nouveaux paramètres **a** et **b** du modèle en utilisant l'équation (3).
- 11- Calculer le nouveau coefficient de détermination (R^2).
- 12- Calculer la nouvelle erreur quadratique moyenne (MSE).
- 13- Donner vos conclusions sur cet exemple.

Activité 3:

Nous voulons réaliser une régression linéaire multiple pour expliquer la hauteur de neige (y_i) en fonction de l'altitude (x_{i1}), de la rugosité (x_{i2}), de la pente (x_{i3}), de l'orientation (x_{i4}), de la latitude (x_{i5}) et de la longitude (x_{i6}).

N°	Hauteur neige	Altitude	Rugosité	Pente	Orientation	Latitude	Longitude
1	95	2768	252	22	324	8760219	438465.0625
2	150	4108	333	29	308	8760195	438474.0625
3	4	4045	62	5	249	8760168	438480.0625
4	0	4572	85	8	14	8760135	438489.0625
5	0	4614	115	10	63	8760105	438495.0625
6	80	4321	176	16	130	8760072	438498.0625
7	95	3886	72	6	199	8760039	438504.0625
8	20	4206	57	5	32	8760012	438507.0625

9	90	4192	266	23	197	8759985	438513.0625
10	10	4051	69	6	113	8759955	438519.0625
11	10	3746	62	5	149	8759922	438519.0625
12	50	3789	42	3	218	8759895	438525.0625
13	45	3771	44	4	53	8759865	438531.0625
14	60	3796	48	4	101	8759838	438534.0625
15	55	3885	77	7	332	8759811	438537.0625
16	3	4295	113	10	18	8759787	438540.0625
17	33	4467	147	13	50	8759760	438546.0625
18	0	4764	12	1	276	8759730	438552.0625
19	35	4313	38	3	350	8759703	438552.0625
20	45	4387	40	3	46	8759673	438558.0625

Tableau (4)

- 1- Estimer les paramètres du modèle (le vecteur A) en utilisant l'équation (3).
- 2- Calculer le coefficient de détermination (R^2).
- 3- Calculer l'erreur quadratique moyenne (MSE).
- 4- Donner vos conclusions sur cet exemple.

Bon courage