





PrivateTeacher
Cours Privés de Science

Régression Linéaire

2024.09.08

V 1.5





Introduction

Les droites de régression linéaires sont des modèles dont on se sert pour représenter la réalité.

En tant que modèle, une droite possède plusieurs avantages par rapport aux observations. Une droite en effet, permet de :

- 1) Résumer une série d'observations
- 2) Expliquer les observations.
- 3) Prédire les prochaines observations.

Un modèle cependant n'est pas la réalité mais seulement une approximation de celle-ci. Pour cette raison, une erreur est toujours associée aux droites de régression, comme nous allons le voir dans un instant.





La place du marché

Un marchand de pomme vend le fruit de sa récolte sur la place du marché.



Voici les prix affichés sur son étalage :

0.5 kilo de pomme coûte 1.5 CHF

1 kilo de pomme coûte 3 CHF

10 kilo de pomme coûte 30 CHF

On l'a compris, pour savoir quel est le prix des pommes, il suffit de multiplier le poids des pommes par 3.





Si x représente le poids des pommes,
et y le prix, alors on peut écrire
la relation sous forme d'une équation :

$$y = 3x$$

On dit alors que le prix des pommes
est proportionnel au poids, car le
rapport entre le prix et le poids
est toujours le même quel que soit
le nombre de pomme : $\frac{30}{10} = 3$ $\frac{9}{3} = 3$

On appelle 3 le facteur de proportionnalité

En mathématiques, deux valeurs sont dites
proportionnelles si leur rapport reste
identique, même quand ces valeurs changent.

si	1	kg	coûte	3	CHF
alors	2	kg	coûtent	$3 \cdot 2$	$= 6$
et	4	kg	coûtent	$3 \cdot 4$	$= 12$
et	10	kg	coûtent	$3 \cdot 10$	$= 30$

$$3x = y$$





Cette relation simple permet de résumer toute la liste des prix.

Elle permet également d'expliquer le prix : si je paie cher, c'est par-ce que j'ai mis beaucoup de pommes.

Cette relation enfin permet de prédire un prix qui ne serait pas affiché par le marchand : si je choisis 3.45 kilos de pommes, alors je paie $3.45 \cdot 3 = 10.35$ CHF





Représentation graphique

La droite est une manière visuelle de représenter une relation de proportionnalité.

On la construit à l'aide d'un tableau :


X	Y
2	6
4	12
10	30

Il existe une relation entre la quantité de pommes X et le prix des pommes Y

Mathématiquement elle prend la forme $y = 3x$

Prix (CHF)

Graphiquement on a :






La pente

Si le prix du kilo de pomme avait été plus élevé, le prix des pomme augmenterait plus rapidement et la pente de la droite serait plus élevée

À l'inverse si le prix avait été plus bas, la pente aurait été plus faible






On peut lire la pente directement sur l'équation.

Elle est le facteur qui multiplie "x"

La pente représente le coefficient de proportionnalité entre le prix et la quantité.

À l'inverse, on peut lire la pente directement sur le graphique
voici comment s'y prendre :





Relation de proportionnalité

En mathématiques, deux valeurs sont dites proportionnelles si leur rapport reste identique, même quand ces valeurs changent.

Prenons par exemple le changement de température avec l'altitude.

Il fait toujours plus froid lorsque l'on monte en altitude.

À chaque fois que l'on s'élève de 1 km (dénivellation de 1 km) la température diminue de 6°C en moyenne.

Si l'on monte de 4 km, la température chute de 24°C .

Lorsqu'on écrit le rapport entre la température et la dénivellation, on a :

$$\frac{6}{1} = 6 \quad \frac{24}{4} = 6$$

Le rapport entre la température et la dénivellation est toujours le même

On dit alors que la température est proportionnelle à la dénivellation






Calcul de la pente

La pente indiquée sur ce panneau est de 10 %.

Cela signifie que pour 100 [m] parcouru horizontalement, la voiture sera descendue de 10 [m] verticalement.



Une pente est donc le rapport entre une distance verticale et une distance horizontale.





Ordonnée à l'origine

Imaginons maintenant que l'entrée à la place du marché soit payante.

Avant de pouvoir acheter des pommes au prix indiqué, il faut s'acquitter d'un montant de 8 CHF.

Le prix des pommes "y" est toujours proportionnel au nombre de pommes ($y = 3x$) mais cette fois, le montant de l'entrée s'y ajoute systématiquement si bien que le prix final devient :

$$y = 3x + 8$$

2 kg coûtent	$3 \cdot 2 + 8$	$= 14$
4 kg coûtent	$3 \cdot 4 + 8$	$= 20$
10 kg coûtent	$3 \cdot 10 + 8$	$= 38$

$$3x + 8 = y$$


Pour dessiner la relation entre le prix des pommes et le nombre de pommes, on refait notre tableau

x	y
2	14
4	20
10	38





Graphiquement, cela se traduit par une droite parallèle au dessus de la précédente :



On le voit, quelque soit le nombre de pommes, le prix final est toujours supérieur de 8 CHF.

Sur le graphique en $X = 0$ (0 pomme) on lit que le prix est de 8 CHF.

Cette valeur de y en $X = 0$ se nomme l'ordonnée à l'origine.





Equation de la droite

Les droites nous l'avons vu, sont déterminées par deux valeurs :
sa pente et son ordonnée à l'origine.

Les droites en générale possède toutes
une pente que l'on note "a" et une
ordonnée à l'origine que l'on note "b"

$$y = ax + b$$

Il s'agit là de la forme générale de
l'équation de la droite.

Cette forme désigne la famille de toutes
les droites. d'équation :

$$y = 4x + 2$$

désigne une droite en particulier.


On peut choisir "a" et "b" librement
et obtenir n'importe quelle droite
en particulier.

Pour cette raison, "a" et "b" se nomment
les paramètres de la droite.





La droite en bref



On peut dessiner
le graphique
à partir de
l'équation.

On peut lire
l'équation
sur le
graphique

$$y = \frac{1}{2}x + 3$$





Régression linéaire

Lorsque l'on passe de l'équation générale de la droite $y = ax + b$ à une équation particulière p. exple $y = 4x + 7$, dans le but d'ajuster la droite à des observations on effectue ce qu'on appelle une régression linéaire.

La régression linéaire est un processus qui permet de trouver l'équation d'une droite particulière : la droite qui se superpose à nos observations.

De telles équations représentent donc un modèle de la réalité dont on peut dès lors se servir pour faire des prédictions.

Dans une certaine mesure on peut substituer le modèle à la réalité mais il ne faut jamais oublier que ceux-ci ne sont que des approximations.





Nous avons vu quels étaient les avantages d'utiliser une droite pour représenter une relation de proportionnalité.

Voyons à présent comment trouver une telle relation au sein de nos données.

Nos observations sont réunies dans le tableau ci-contre.

Voici comment réaliser une régression linéaire à la main.


X	Y
1	12.45
2	9.14
3	15.80
4	20.96
5	24.57
6	18.95
7	24.07
8	23.28
9	30.31
10	26.92
11	35.34
12	34.86
13	35.89
14	42.34
15	35.95
16	39.10
17	41.97
18	40.26
19	42.26
20	50.09





1) la première étape consiste à représenter graphiquement une caractéristique X en fonction d'une caractéristique Y


On réalise cela à l'aide d'un scatterplot





2) On ajuste ensuite une droite à la main.
Le but du jeu est de trouver la
droite qui passe au plus près
de tous les points.


Par exemple celle-ci :





3) On utilise ensuite les outils vu auparavant pour déterminer l'équation de la droite :

$$y = ax + b$$



$$y = 2x + 10$$

Il s'agit là de notre modèle :
l'équation de la droite de régression
obtenue par régression linéaire sur
nos observations.





Ce modèle $y = 2X + 10$ permet de :

Résumer l'information

À lui tout seul, ce modèle permet de résumer toutes les données. Plus besoin de 20 paires de points en effet, on sait qu'elles sont toutes situées autour de cette droite.

Prédire les valeurs

Grâce à ce modèle, on peut également prédire la valeur de y pour des x que l'on a pas du tout mesuré. $x = 40$ par exemple, n'apparaît même pas sur le graphique. À l'aide de ce modèle pourtant on peut calculer que la valeur y correspondante vaut $y = 2 \cdot 40 + 10 = 90$

Expliquer les variations de y

Ce modèle nous permet également d'expliquer les valeurs de y . Si y augmente par exple c'est par ce que x augmente. On peut même dire que y augmente deux fois plus que x car leur coefficient de proportionnalité vaut 2.





Voici à présent comment s'y prendrait une machine (un ordinateur) pour ajuster une droite sur cette même série de point .

Dans la pratique , un ordinateur utilise une méthode qui consiste à réduire au maximum la différence entre la droite et les points .

Voici comment cela fonctionne :

Une première droite est tracée approximativement .

Pour chaque point , un logiciel calcul à quelle distance il se trouve de la droite

Afin d'éviter que les distances positives ne compensent les distances négative , on les élève au carré

On fait ensuite la somme de chacune de ces distance au carré pour obtenir un score .

Plus le score est petit plus la droite est proche des points .

Le logiciel utilise ce score pour ajuster la droite .

La droite définitive est trouvée quand le score est minimum .

On appelle cette méthode la méthode des moindres carré .





Voici comment se présente les résultats d'une régression linéaire faite à l'aide d'un logiciel de statistique.

Il s'agit d'une sortie logicielle (un output) du programme R. Il existe bien d'autres programmes capables de faire la même chose mais dont les sorties logicielles sont différentes.

Tous cependant ont en commun un certain nombre de points essentiels, et ce sont ceux là que nous allons voir à présent.

Call:

`lm(formula = y ~ x, data = df)`

Residuals:

Min	1Q	Median	3Q	Max
-5.4641	-2.4263	-0.2633	2.4766	5.6858

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	10.934	1.474	7.419	7.05e-07 ***
x	1.838	0.123	14.938	1.38e-11 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 3.173 on 18 degrees of freedom

Multiple R-squared: 0.9254, Adjusted R-squared: 0.9212

F-statistic: 223.1 on 1 and 18 DF, p-value: 1.382e-11





Reprenons cette sortie logicielle dans les détails
Elle se compose de 4 parties importante

Call:
lm(formula = y ~ x, data = df)

1

Residuals:

2

Min	1Q	Median	3Q	Max
-5.4641	-2.4263	-0.2633	2.4766	5.6858

Coefficients:

3

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	10.934	1.474	7.419	7.05e-07 ***
x	1.838	0.123	14.938	1.38e-11 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 3.173 on 18 degrees of freedom
Multiple R-squared: 0.9254, Adjusted R-squared: 0.9212
F-statistic: 223.1 on 1 and 18 DF, p-value: 1.382e-11

4





L'appel (call) de la fonction

Call:

`lm(formula = y ~ x, data = df)`



Cette partie est spécifique au logiciel R et n'a donc pas d'intérêt si on utilise un autre logiciel.

Dans cette partie, le logiciel (R) nous dit simplement la commande qui lui a été donnée par l'utilisateur-trice.

On s'en sert pour vérifier que le logiciel est bien en train de faire ce qu'on pense qu'il fait ^^

Dans le cas présent, on a demandé à R de lire les données (data) dans une variable qui s'appelle "df" pour en tirer un modèle linéaire (linear model, lm)

On lui précise ensuite que la variable dépendante (y) doit être expliquée à l'aide de la variable explicative X. $y \sim x$





Le résidu du modèle


Residuals:

Min	1Q	Median	3Q	Max
-5.4641	-2.4263	-0.2633	2.4766	5.6858

2

Une fois le processus de régression terminé et que la droite passant au plus près de tous les points à été trouvée on peut s'intéresser à la précision du modèle (par "modèle" on entend la droite de régression)

On dit que la droite a été ajustée au points. Or, quelque soit la qualité de cet ajustement, il demeure toujours une différence entre la droite et les points






Si le rôle de la droite de régression est d'expliquer les variations de "y" à l'aide de "x", alors chacune des différences entre la droite et les points est une variation qui reste à expliquer

Pour cette raison on appelle ces différences les résidus de la régression.

Il y a autant de résidus que de valeurs expérimentales. Tout comme ces valeurs, les résidus suivent une certaine distribution de probabilité.






Lorsque le modèle est bon l'essentiel des variations sur "y" ont été expliquées. Tout ce qui reste n'est que du bruit sans aucune valeur explicative.

Or, une caractéristique de ce "bruit" est qu'il se distribue normalement autour de zéro.

Un résidu normalement (symétriquement) distribué autour de zéro est donc une indication que le modèle explique les données correctement.

C'est la toute l'utilité d'afficher les différents quartiles de la distribution des résidus.





Residuals:

Min	1Q	Median	3Q	Max
-5.4641	-2.4263	-0.2633	2.4766	5.6858

2

On le voit, la distribution des résidus est centrée en 0 (Median = -0.2633)

On peut lire également que la distribution est symétrique autour de 0
(Min = -Max et $Q_1 = -Q_3$)

Ce sont donc là des indications que notre modèle est capable d'expliquer correctement les variations de "y" en terme de "x"





les paramètres à proprement parler

Une fois que la droite qui passe au plus près de tous les points a été trouvée, le logiciel affiche leur valeur. Ce sont ces valeurs que l'on trouve ici dans la colonne "estimate"



Coefficients:

	Estimate	Std. Error.	t	value Pr(> t)
(Intercept)	10.934	1.474	7.419	7.05e-07 ***
x	1.838	0.123	14.938	1.38e-11 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

3

On trouve ici deux paramètres. Le premier est l'ordonnée à l'origine (intercept) c'est le "b" du $ax + b$. Le deuxième est le coefficient qui se trouve devant la variable "x" c'est la pente de la droite, le "a" du $ax + b$!

Ces valeurs sont données,

mais ATTENTION on ne commence pas la lecture de cette partie de la sortie logicielle par la colonne "estimate" !





Coefficients:

	Estimate	Std. Error.	t	value Pr(> t)
(Intercept)	10.934	1.474	7.419	7.05e-07 ***
x	1.838	0.123	14.938	1.38e-11 ***

3

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Pour interpréter correctement la valeur de ces coefficient en effet, il faut commencer par évaluer leur significativité statistique.

Dans le cadre d'un modèle mathématique issu d'une régression (qu'elle soit linéaire ou pas) la significativité statistique d'un paramètre mesure la probabilité, sous l'hypothèse selon laquelle sa valeur serait nulle, que la valeur soit au moins aussi grande que la valeur calculée.

Autrement dit, il s'agit d'une mesure qui nous dit si la valeur calculée est significativement différente de zéro.

Si tel est le cas, le paramètre en question est utile pour expliquer le y. sa p-valeur sera donc inférieure au seuil critique α . Sinon, le paramètre n'est pas utile pour expliquer les données et on ne regarde alors même pas sa valeur.





Coefficients:

	Estimate	Std. Error.	t	value Pr(> t)
(Intercept)	10.934	1.474	7.419	7.05e-07 ***
x	1.838	0.123	14.938	1.38e-11 ***

3

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Dans notre exemple les deux paramètres sont statistiquement significatifs, on peut donc s'intéresser à leur valeur à proprement parler.

Il s'agit des valeurs suivantes :

$$\text{Intercept} = 10.934$$

$$\text{slope}(x) = 1.838$$

Notre modèle mathématique s'écrit donc :

$$y = 1.838x + 10.934$$

Le modèle on le voit est très proche des valeurs que nous avons trouvé à la main.

$$y = 2x + 10$$

La différence provient du manque de précision dont nous avons fait preuve en posant la droite à la main.






Residual standard error: 3.173 on 18 degrees of freedom
Multiple R-squared: 0.9254, Adjusted R-squared: 0.9212
F-statistic: 223.1 on 1 and 18 DF, p-value: 1.382e-11

4

Residual Standard Error nous donne une mesure de la dispersion des valeurs des résidus autour de la moyenne



Les degrés de liberté (degree of freedom) correspondent au nombre N_T d'observation dont on a soustrait le nombre de paramètres N_{prm} du modèle

$$N_T = 20$$
$$N_{\text{prm}} = 2$$

$$20 - 2 = 18 \text{ dof}$$





Le R -carré (R -squared R^2) quant à lui est une mesure de la qualité du modèle. Il s'agit d'une valeur qui varie entre 0 et 1 :

$$0 < R^2 < 1$$

Lorsque R^2 est proche de 0, il est difficile de faire des prédictions en utilisant ce modèle. On dit alors que le pouvoir prédictif du modèle est faible.

Au contraire, lorsque R^2 est proche de 1, la qualité du modèle est bonne. Cela signifie que l'on peut s'en servir pour faire des prédictions. Autrement dit lorsque R^2 est proche de 1, le pouvoir prédictif du modèle est important.

Dans le cas des régression linéaires univariée (une seule variable prédictive) telle que celle que nous avons pris comme exemple jusqu'ici, R^2 représente également le rapport entre la variance expliquée par la régression et la variance totale.





la statistique F enfin (F -statistique)
est elle aussi une valeur qui permet
d'évaluer la qualité globale du modèle.

On ne l'utilise pas directement cependant
comme on peut le faire avec R^2

la statistique F sert à tester l'hypothèse
selon laquelle le coefficient " b " de la
régression est significativement différent
de 0.

$$H_0 : b = 0$$

$$H_1 : b \neq 0$$

Autrement dit on cherche à savoir si la
variable X est utile pour expliquer y .

Dans notre exemple, la p -valeur associée
à la statistique de test F est plus petite
que le seuil alpha ($1.382 \cdot 10^{-11} < 0.05$)
on rejette donc H_0 ce qui signifie qu'il
est raisonnable de considérer le coefficient
" b " comme étant différent de 0.

Autrement dit, la variable X est probablement
utile pour expliquer la variable y .





Régression linéaire multiple

Maintenant que l'on sait comment sont construits les modèles linéaires simples il devient possible de se représenter les régressions linéaires multiples.

Imaginons par exemple une régression linéaire à deux variables. On note :

$$y = a_1 X_1 + a_2 X_2 + b$$


Chacune des deux variables X_1 et X_2 est ici associé à un paramètre a_1 et a_2 respectivement. Cela signifie que la variable y est proportionnelle aussi bien à X_1 que à X_2

Comme nous avons affaire ici à 2 variables X plus 1 variable y , il est possible de se représenter la situation en 3 dimensions







Représentation graphique d'un modèle
linéaire à deux variables :



Projections de la droite le long des
deux axes x_1 et x_2





Du modèle à la réalité

Il existe entre le modèle et la réalité une différence importante qui ne se résume pas à une différence de valeur.

La différence fondamentale entre un modèle et la réalité réside dans la difficulté de réaliser des mesures susceptibles de caractériser notre sujet d'étude.

On pense mesurer la taille des gens alors que ce que l'on mesure en réalité, c'est leur âge par exemple, leur pays d'origine, leur genre ou peut-être tout cela en même temps.

La réalité est infiniment complexe et variée et aucun modèle mathématique, aussi sophistiqué soit-il, ne pourra jamais expliquer la réalité dans toute sa diversité.

L'exemple qui va suivre va nous permettre d'illustrer ce point important.





Dans ce document, nous nous sommes servi d'une série de points pour calculer une droite de régression.

Nous avons d'abord réalisé une régression à la main, pour illustrer la démarche, puis nous avons utilisé un logiciel pour exécuter cette même démarche exactement.

Le résultat des calculs exacts réalisé par le logiciel, nous l'avons vu est la droite d'équation :

$$y = 1.238 X + 10.934$$

Or, la droite qui a servi à modéliser ces points est la droite d'équation :


$$y = 2X + 10$$

Voici les instructions qui ont servi à générer la série de points dont nous nous sommes servis dans ce cours :





```
# On crée pour commencer  
# une série de points (axe x) entre 1 et 20  
x = 1:20  
  
# Que l'on met en relation avec y  
# selon une équation linéaire  
# (La vraie relation entre x et y)  
y = 2*x + 10  
  
# On génère ensuite du bruit aléatoire  
rnd = rnorm(20, mean=0, sd=3)  
  
# Que l'on ajoute à y  
y_rnd = y + rnd  
  
# On affiche le résultat sur un scatterplot  
plot(x, y_rnd, pch=19, col='black')
```





Les points que nous avons utilisés ont été générés à l'aide d'une droite. Une certaine quantité de désordre a été ajoutée ensuite.


Or, le processus de régression n'a pas été capable de retrouver ces paramètres initiaux. Ils étaient comme masqués par le désordre bruit que nous avons ajouté.

Si ce bruit avait été plus intense encore, la droite initiale aurait totalement disparu. Elle aurait été complètement couverte par le bruit ambiant. Si tel avait été le cas, l'ordinateur n'aurait pas trouvé de droite et le processus de régression aurait échoué.

Or c'est précisément ce qui se passe dans la réalité : Dans la réalité, la vraie relation entre x et y est inconnue. On essaie de la retrouver à l'aide de la méthode décrite dans ce document.

Les modèles, aussi bons soient-ils, ne sont que des représentations de la réalité. Garde bien cela présent à l'esprit à chaque fois que tu te serviras d'un modèle !








Les Statistiques

Expliquées Simplement


Cours Privés Individuels



- Progrès rapide
- Réponses précises
- Cours sur mesure

60 CHF / heure


Cours Privés Collectifs



- Travail d'équipe
- Réponse aux questions
- Cours préparé d'avance
- Dès deux personnes

40 CHF / h / Pers.


Modules à Choix



- Maîtriser 1 sujet précis
- Formation intensive
- Exercices pratiques
- Groupe de 5 pers. max
- Durée: 2 heures

40 CHF / heure

Pack 12 Heures



- Se mettre à jour
- Suivi personnalisé
- Méthode de travail
- Exces de renforcement
- **10h + 2h Offertes**

50 CHF / heure





Voici mes disponibilités

Genève UNIMAIL :

Lundi et Vendredi
14h00 - 18h00

Bern ANTHROPOLE :

Mardi, Mercredi et Jeudi
14h00 - 18h00

Visio TELEGRAM :

Lundi - Vendredi
9h00 - 11h00
18h00 - 20h00

Réservation Calendrier
(Min 2 jours à l'avance)



Horaires WEEKEND

J'ai la possibilité de mettre à disposition
des périodes durant le weekend si la
situation le demande.

Mes tarifs sont alors majoré de 50%

