

# 1 Formules mathématiques de la droite de régression linéaire

## Définitions.

Soit  $X$  et  $Y$  deux séries statistiques (numériques) ayant même effectif  $n$  :

$$X = (x_1, x_2, x_3, \dots, x_n) \quad ; \quad Y = (y_1, y_2, y_3, \dots, y_n)$$

Le **nuage de points** d'abscisses dans  $X$  et d'ordonnées dans  $Y$  est l'ensemble des points  $M(x_i, y_i)$  du plan rapporté à un repère orthonormé,  $i \in [[1, n]]$ . C'est un ensemble de  $n$  points du plan.

La droite approchant le mieux le nuage de points, au sens des moindres carrés, est la **droite de régression linéaire**. C'est la droite d'équation

$$Y = a.X + b$$

avec  $a = \frac{\sum_{i=1}^n (x_i - \bar{X})(y_i - \bar{Y})}{\sum_{i=1}^n (x_i - \bar{X})^2}$  et  $b = \bar{Y} - a.\bar{X}$

où  $\bar{X}$  et  $\bar{Y}$  désignent les moyennes des séries  $X$  et  $Y$ .

Le **coefficient de corrélation** est défini comme :

$$r = -\frac{\sum_{i=1}^n (x_i - \bar{X})(y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{X})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{Y})^2}}$$

Alors  $r \in [-1, 1]$  et la droite de régression linéaire approche d'autant mieux le nuage de point que  $|r|$  est proche de 1.

- En notant pour deux séries statistiques  $X = (x_1, x_2, x_3, \dots, x_n)$  et  $Y = (y_1, y_2, y_3, \dots, y_n)$ , de même effectif  $n$  :

- La **variance** de  $X$ ,  $V(X) = \overline{(X - \bar{X})^2}$ , soit :

$$V(X) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^2$$

- L'**écart-type** de  $X$ ,  $\sigma_X = \sqrt{V(X)}$ , soit :

$$\sigma_X = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^2}$$

- La **covariance** de  $X$  et  $Y$ ,  $cov(X, Y) = \overline{(X - \bar{X})(Y - \bar{Y})}$ , soit :

$$cov(X, Y) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})(y_i - \bar{Y})$$

la **droite de régression linéaire**  $Y = a.X + b$ , et son **coefficient de corrélation** sont alors obtenus par les formules :

$$a = \frac{cov(X, Y)}{V(X)} \quad ; \quad b = \bar{Y} - a.\bar{X}$$

$$r = \frac{cov(X, Y)}{\sigma_X \cdot \sigma_Y}$$

## 2 Exemple pratique

En laboratoire on a mesuré l'évolution de la concentration d'un réactif lors d'une réaction chimique. Les différents temps de mesure et concentrations mesurées figurent dans le tableau ci-contre.

On souhaite modéliser l'évolution de la concentration de ce réactif, et pour cela nous allons confronter deux modèles cinétiques, celui d'une réaction chimique d'ordre 1 avec celui d'une réaction chimique d'ordre 2.

Dans ces modèles la vitesse d'accroissement  $C'(t)$  au temps  $t$  de la concentration d'un produit est proportionnelle respectivement à la concentration  $C(t)$  au temps  $t$  ou à son carré  $C(t)^2$ , c'est à dire :

| Temps (s) | Concentration (mol/l) |
|-----------|-----------------------|
| 0         | 34,97                 |
| 3         | 17,52                 |
| 5         | 13,23                 |
| 7         | 10,13                 |
| 10        | 8,16                  |
| 12        | 6,55                  |
| 15        | 5,78                  |
| 18        | 5,22                  |
| 20        | 4,66                  |
| 23        | 4,15                  |
| 25        | 3,86                  |

$$\text{Ordre 1 : } \frac{d}{dt}C(t) = -\lambda C(t)$$

$$\text{Ordre 2 : } \frac{d}{dt}C(t) = -\lambda C(t)^2$$

On admettra ici (et l'on montrera en cours de Mathématiques) que les solutions à ces équations différentielles sont de la forme (respectivement à l'ordre 1 et à l'ordre 2) :

$$C(t) = C_0 \exp(-\lambda t) \quad ; \quad C(t) = \frac{C_0}{1 - \lambda C_0 t}$$

pour  $C_0$  une constante réelle.

À l'aide d'une régression linéaire, nous allons déterminer quel modèle, réaction chimique d'ordre 1 ou d'ordre 2, décrit le mieux l'évolution de la concentration mesurée.

Pour cela, on remarque d'abord que :

- Si la réaction chimique est d'ordre 1 :

$$C(t) = C_0 \exp(-\lambda t)$$

alors en posant  $Y(t) = \ln(C(t))$ , la fonction  $Y(t)$  est affine :

$$Y(t) = -\lambda \cdot t + \ln(C_0).$$

- Si la réaction chimique est d'ordre 2, alors en posant  $Z(t) = 1/C(t)$ , la fonction  $Z(t)$  est affine :

$$Z(t) = -\lambda \cdot t + \frac{1}{C_0}.$$

1. Dans un tableur (calc, open office), saisir sur deux lignes les séries statistiques des temps de mesure, et des concentrations mesurées :

|   | A | B     | C     | D     | E     | F    | G    | H    | I    | J    | K    | L    |
|---|---|-------|-------|-------|-------|------|------|------|------|------|------|------|
| 1 | T | 0     | 3     | 5     | 7     | 10   | 12   | 15   | 18   | 20   | 23   | 25   |
| 2 | C | 34,97 | 17,52 | 13,23 | 10,13 | 8,16 | 6,55 | 5,78 | 5,22 | 4,66 | 4,15 | 3,86 |

2. Ajouter deux nouvelles lignes avec les valeurs de  $Y = \ln(C)$  et  $Z = 1/C$ .

Pour cela taper dans la cellule B3 la commande = LN(B2), valider, puis copier la cellule B3 dans les cellules C3 à L3. Faire de même ligne 4, en tapant dans B4 la commande = 1/B2, etc.


|   | A       | B      | C     | D     | E     | F     | G     | H      | I     | J      | K      | L      |
|---|---------|--------|-------|-------|-------|-------|-------|--------|-------|--------|--------|--------|
| 1 | T       | 0      | 3     | 5     | 7     | 10    | 12    | 15     | 18    | 20     | 23     | 25     |
| 2 | C       | 34,97  | 17,52 | 13,23 | 10,13 | 8,16  | 6,55  | 5,78   | 5,22  | 4,66   | 4,15   | 3,86   |
| 3 | Y=LN(C) | 3,5545 | 2,863 | 2,582 | 2,316 | 2,099 | 1,879 | 1,7544 | 1,652 | 1,539  | 1,4231 | 1,3507 |
| 4 | Z=1/C   | 0,0286 | 0,057 | 0,076 | 0,099 | 0,123 | 0,153 | 0,173  | 0,192 | 0,2146 | 0,241  | 0,2591 |

3. À l'aide de l'outil graphique, insérer un graphique contenant le nuage de point des séries  $(T, Y)$ . Pour cela :


– Barre de menu **Insertion >> Diagramme**

Une nouvelle fenêtre s'ouvre pour sélectionner le type de diagramme.

– Sélectionner **XY (dispersion)** >> **Points seuls** >> **Suivant**



– Sélectionner **Séries de données** et **ajouter** puis définir les plages de données  $X$  ( $=T$ ) et  $Y$  ( $=Y$ ). Puis cliquer sur **Terminer**. On obtient le graphique :



4. Insérer la droite de régression linéaire sur le graphique ; pour cela, le graphique étant toujours sélectionné :

– Menu **Insertion** >> **Courbe de tendance** >> **Type de régression** : cocher "régression linéaire". Cliquer sur OK.


Remarque : deux boutons en bas de fenêtre peuvent être cochés pour afficher sur le graphe  $R^2$  ou l'équation de la droite.

Le **coefficient de détermination  $R^2$**  est le rapport entre la somme des carrés des écarts à la moyenne des valeurs prédictes ( $\hat{y}_i$ ) $_{1 \leq i \leq n}$ ) et des valeurs mesurées ( $y_i$ ) $_{1 \leq i \leq n}$  :

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{Y})^2}{\sum_{i=1}^n (y_i - \bar{Y})^2}$$

C'est un nombre entre 0 et 1 : la corrélation est d'autant meilleure que  $R^2$  est proche de 1.


Tout comme le coefficient de corrélation linéaire, c'est un estimateur de la qualité de la régression.



5. Obtenir le coefficient de corrélation (Insertion >> fonction >> Statistiques >> Coefficient de corrélation), la pente  $a$  de la droite de régression linéaire (Insertion >> fonction >> Statistiques >> pente) ainsi que son ordonnée à l'origine  $b = \bar{Y} - a\bar{T}$  :

|        |          |
|--------|----------|
| R:     | -0,94659 |
| pente  | -0,07747 |
| MOY(T) | 12,5455  |
| MOY(Y) | 2,0922   |
| b      | 3,06404  |

6. Effectuer les mêmes action avec le nuage de points  $(T, Z)$  :




|        |             |
|--------|-------------|
| R:     | 0,99835098  |
| pente  | 0,0091573   |
| MOY(T) | 12,5454545  |
| MOY(Y) | 0,14676378  |
| b      | 0,031881236 |

7. En déduire que le modèle à retenir est celui d'une réaction chimique d'ordre 2. L'évolution de la concentration est alors

donnée dans ce modèle par :

$$\frac{1}{C(t)} = 0,0091573 \cdot t + 0,031881236 \implies C(t) = \frac{1}{0,0091573 \cdot t + 0,031881236}$$

8. En déduire les concentrations prédites par ce modèle :



et le tracé de l'évolution des concentrations aux temps mesurés :

**Insertion >> Diagramme**

– Sélectionner XY (dispersion) >> Points et lignes >> Suivant

– Sélectionner Séries de données et ajouter puis définir les plages de données X (=T) et Y (Prévisions).

Cliquer sur Terminer.