

Fiche P3.1 : Séries statistiques à deux variables

1 – Série statistique double

- On étudie simultanément deux **caractères** au sein d'une même **population**.
- Une **série statistique à deux variables** est constituée de deux listes de n **valeurs** x_1, \dots, x_n et y_1, \dots, y_n :

Valeurs de x_i	x_1	x_2	x_3	...	x_n
Valeurs de y_i	y_1	y_2	y_3	...	y_n

- Dans certaines situations, il semble exister un lien entre les deux caractères : On parle alors de **corrélacion**. On ne peut cependant pas affirmer que ce lien est lien de cause à effet (**causalité**).

Exemple 1 : Une étude statistique française donne une correspondance entre le prix moyen x_i d'un paquet de 20 cigarettes (en €) et le nombre y_i de cigarettes vendues chaque année (en dizaines de milliards). Les données sont regroupées dans le tableau ci-dessous :

Années	2001	2002	2003	2006	2012	2013	2016	2018
Prix : (x_i)	3.4	3.6	4	5	6.3	6.7	7	8
Nombre total : (y_i)	8.3	8.1	7	5.5	5.2	4.8	4.5	4


2 – Nuage de points, Point moyen

Définition 1 : On se place dans un repère du plan

- Une série statistique à deux variables se représente par un **nuage de points** de coordonnées $M_i(x_i; y_i)$
- On appelle **point moyen** du nuage le point $G(\bar{x}; \bar{y})$ où :

. \bar{x} est la moyenne de la 1^e variable : $\bar{x} = \frac{x_1 + \dots + x_n}{n}$

. \bar{y} est la moyenne de la 2^e variable : $\bar{y} = \frac{y_1 + \dots + y_n}{n}$




Exemple 1 (Suite) :

- 1) Représenter dans le repère ci-dessous, le nuage de points $M_i(x_i; y_i)$ associé à la série ci-dessus.
- 2) Calculer les coordonnées du point moyen G du nuage, puis placer le dans le repère.

$$\bar{x} = \frac{3.4 + 3.6 + \dots + 8}{8} = 5.5$$

$$\bar{y} = \frac{8.3 + 8.1 + \dots + 4}{8} = 5.93$$

Le point moyen est donc $G(5.5; 5.93)$.



3 – Covariance

Commençons par rappeler la définition de la variance (et de l'écart type) pour une série simple :

Définition 1 : On considère une série statistique $x = (x_1; \dots; x_n)$ de moyenne \bar{x} .

- La **variance** est la moyenne des écarts au carré entre chaque valeur de la série et sa moyenne \bar{x} :

$$V(x) = \frac{(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n}$$

- L'**écart-type** est alors le nombre $\sigma(x) = \sqrt{V(x)}$

Remarque :

- Dans la formule de la variance, le carré sert à obtenir un nombre positif qui mesure la distance entre chaque valeur et la moyenne. La racine carrée dans la formule de l'écart-type permet alors de revenir dans la même unité que les valeurs de la série. En pratique, on utilise donc plutôt l'écart-type que la variance.
- Ces deux paramètres mesurent la **dispersion** des valeurs de la série autour de leur moyenne : Plus l'écart-type est grand, plus les écarts avec la moyenne sont importants et plus les valeurs seront éloignées les unes des autres.

Définition 2 : On considère une série statistique à deux variables $x = (x_1; \dots; x_n)$ et $y = (y_1; \dots; y_n)$ de moyenne respective \bar{x} et \bar{y} . La **covariance** de x et y notée $cov(x; y)$ est le nombre défini par :

$$cov(x; y) = \frac{(x_1 - \bar{x})(y_1 - \bar{y}) + (x_2 - \bar{x})(y_2 - \bar{y}) + \dots + (x_n - \bar{x})(y_n - \bar{y})}{n} = \frac{x_1 y_1 + x_2 y_2 + \dots + x_n y_n}{n} - \bar{x} \bar{y}$$

Remarque : La covariance mesure si ces 2 variables « covarient » ensemble par rapport à leurs moyennes : Si les écarts à la moyenne ont tendance à être dans le même sens pour les deux variables alors la covariance sera positive ; s'ils ont tendance à être dans le sens opposé alors la covariance sera négative. Plus la valeur absolue de la covariance est importante, plus il y a une **corrélation** entre ses deux variables.

Calculatrice : En pratique on utilise la calculatrice pour déterminer la variance, l'écart-type et la covariance.

Casio : Touche **MENU** puis menu **STAT**

- Entrer la série statistique (**EXE** pour valider) :
 - . **List 1** : Valeurs de la 1^e variable.
 - . **List 2** : Valeurs de la 2^e variable.
- Configuration : **F2** (**CALC**) puis **F5** (**SET**) :
 - . **2Var XList : List1** **F2** (**LIST**) / **1**
 - . **2Var YList : List2** **F2** (**LIST**) / **2**
 - . Appuyer sur **EXIT** puis **F2** (**EQW**)
- Affichage :
 - . \bar{x} et \bar{y} : Moyenne de x et de y .
 - . σx et σy : Ecart-type de x et de y .
 - . Σxy : Sommes des produits $x_i y_i$

TI : Touche **STAT** puis touche **1** : **1: Editer**.

- Entrer la série statistique (**ENTER** pour valider) :
 - . **List 1** : Valeurs de la 1^e variable.
 - . **List 2** : Valeurs de la 2^e variable.
- Configuration : Touche **STAT**, puis touche **▸** (**CALC**)
 - . Dans l'onglet **CALC** sélectionner **2: Stats 2 Var**.
 - . **XListe** : L_1 et **YListe** : L_2 puis **Calculer**
- Affichage :
 - . \bar{x} et \bar{y} : Moyenne de x et de y .
 - . σx et σy : Ecart-type de x et de y .
 - . Σxy : **Sommes des produits $x_i y_i$**

Exemple 1 (Suite) : Déterminer les écarts-types de x et y ainsi que la covariance de la série.

$$\sigma(x) \approx 1.62 \text{ et } \sigma(y) \approx 1.55. \quad cov(x; y) = \frac{\Sigma xy}{n} - \bar{x} \bar{y} = \frac{241,3}{8} - 5.5 \times 5.93 = -2.425$$

