

## TD3 : Régression linéaire, $\chi^2$ et corrélations des rangs

### Exercice 1

Nous souhaitons établir une relation entre l'âge  $a$  d'un individu et sa taille  $t$ . Pour cela, nous avons mesuré les membres d'une population et nous avons regroupé les résultats par tranches d'âge identifiées par leurs moyennes. Cela donne les observations uniformément pondérées suivantes :

|       |       |       |       |       |       |
|-------|-------|-------|-------|-------|-------|
| $k$   | 1     | 2     | 3     | 4     | 5     |
| $a_k$ | 18    | 20    | 22    | 24    | 26    |
| $t_k$ | 176.1 | 178.1 | 178.8 | 179.9 | 181.2 |

1. Calculer  $\text{Var}(a)$ ,  $\text{Var}(t)$  et  $\text{Cov}(a, t)$ .
2. Comment s'interprète le signe de  $\text{Cov}(a, t)$  ?
3. Donner l'équation de la droite de régression de  $t$  en fonction de  $a$ .
4. Prédire la taille d'un individu de 30 ans et celle d'un individu de 75 ans. Commenter.

### Exercice 2

Le responsable d'une chaîne de magasins de bricolage pense qu'il y a une relation entre le nombre de personnes qui s'installent dans la région et le chiffre d'affaire des magasins. Il a noté, pour chacune des 10 dernières années, la valeur  $n_k$  du nombre de personnes ayant déménagé pour s'installer dans la région pendant l'année et  $c_k$  le chiffre d'affaire cumulé de l'ensemble des magasins de la chaîne lors de l'année. Le tableau suivant reproduit ces valeurs :

|       |       |       |       |       |       |       |       |       |       |       |
|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
|       | 2001  | 2002  | 2003  | 2004  | 2005  | 2006  | 2007  | 2008  | 2009  | 2010  |
| $n_k$ | 5.2   | 4.6   | 7.3   | 8.2   | 6.4   | 7.8   | 3.6   | 4.9   | 2.6   | 3.7   |
| $c_k$ | 25.85 | 28.30 | 31.68 | 36.98 | 31.89 | 34.59 | 24.14 | 23.11 | 18.60 | 24.72 |

1. Représenter le nuage de points associé à ces observations.
2. Vu le graphique, vous semble-t-il y avoir une relation entre les deux variables ? De quelle nature ? Justifier votre réponse en calculant une certaine quantité et en la commentant.
3. Déterminer la droite de régression linéaire et tracer la sur le graphique. Est-ce que le modèle linéaire vous semble correct ?
4. En 2011, la région prévoit une valeur de  $n$  égale à 4.9. A quelle valeur de  $c$  le responsable peut-il s'attendre. Comparer votre réponse avec le chiffre d'affaire obtenu en 2008 et commenter la différence.

### Exercice 3

Les observations de deux variables qualitatives sur une population de 12 individus ont donné les résultats suivants :

|   |   |   |   |   |   |   |   |   |   |   |   |
|---|---|---|---|---|---|---|---|---|---|---|---|
| B | A | C | C | C | A | A | C | B | C | B | C |
| X | X | Y | X | X | Y | X | Y | X | Y | X | X |

1. Représenter ces données par un tableau d'effectifs  $n_{ij}$ .

- Déterminer le tableau théorique  $n_{ij}^*$  de données indépendantes donnant les mêmes effectifs en lignes et colonnes.
- Calculer le  $\chi^2$  d'écart à l'indépendance. Commenter.

#### Exercice 4

Nous nous intéressons à l'existence d'une relation entre le sexe d'une personne ( $\sigma$  pour un homme et  $\varphi$  pour une femme) et la couleur de ses cheveux (Br pour brun, Bl pour blond et R pour roux). Pour réaliser cette étude, nous demandons à 19 individus uniformément pondérés ces deux informations et nous obtenons les résultats suivants :

|           |           |          |          |          |          |          |           |           |           |          |           |           |           |          |           |           |          |           |
|-----------|-----------|----------|----------|----------|----------|----------|-----------|-----------|-----------|----------|-----------|-----------|-----------|----------|-----------|-----------|----------|-----------|
| 1         | 2         | 3        | 4        | 5        | 6        | 7        | 8         | 9         | 10        | 11       | 12        | 13        | 14        | 15       | 16        | 17        | 18       | 19        |
| $\varphi$ | $\varphi$ | $\sigma$ | $\sigma$ | $\sigma$ | $\sigma$ | $\sigma$ | $\varphi$ | $\varphi$ | $\varphi$ | $\sigma$ | $\varphi$ | $\varphi$ | $\varphi$ | $\sigma$ | $\varphi$ | $\varphi$ | $\sigma$ | $\varphi$ |
| Br        | R         | Bl       | R        | Br       | Bl       | Bl       | Bl        | Br        | Br        | Bl       | R         | Bl        | R         | Bl       | Br        | Bl        | Br       | Bl        |

- Donner la table de contingence des effectifs associés à ces observations.
- En vous basant sur les marges observées, déterminer la table de contingence des effectifs théoriques en cas d'indépendance entre les variables.
- Calculer la distance du  $\chi^2$  à l'indépendance et commenter le résultat.

#### Exercice 5

Nous nous intéressons à l'existence d'une relation entre le QI d'une personne et la taille de sa tête. Pour cela, nous avons calculé le QI de 5 individus et nous avons mesuré leurs crânes. Voici les rangs associés à ces mesures :

|                                |   |   |   |   |   |
|--------------------------------|---|---|---|---|---|
| Personne                       | A | B | C | D | E |
| Rang pour le QI                | 1 | 2 | 3 | 4 | 5 |
| Rang pour la taille de la tête | 3 | 5 | 2 | 1 | 4 |

- Calculer le coefficient de corrélation  $\rho_S$  de Spearman.
- Calculer le coefficient de corrélation  $\rho_K$  de Kendall.

#### Exercice 6

Cinq produits sont soumis à une batterie de dix tests. Dans le tableau ci-dessous, on retrouve leurs prix et le nombre de tests auxquels ils ont résisté.

|       |     |    |     |      |    |
|-------|-----|----|-----|------|----|
| Prix  | 100 | 80 | 500 | 2000 | 50 |
| Tests | 6   | 2  | 10  | 9    | 4  |

- Calculer le coefficient  $\rho_S$  de corrélation de Spearman en représentant le tableau des rangs centrés et en calculant la variance et la covariance des rangs.
- Calculer  $\rho_S$  par la formule

$$\rho_S = 1 - \frac{6}{n(n^2 - 1)} \sum_{k=1}^n (r_k - s_k)^2$$

- Calculer le coefficient  $\rho_K$  de corrélation des rangs de Kendall.

### Exercice 7

En classant les valeurs de deux variables observées sur  $n$  individus, on obtient des rangs :

$$r_1 = 1, r_2 = 2, \dots, r_n = n$$

et

$$s_1 = n, s_2 = 1, s_3 = 2, \dots, s_n = n - 1 .$$

1. Calculer  $\rho_S$ . Vérifier le cas  $n = 5$  en calculant directement la covariance avec les rangs centrés.
2. Calculer  $\rho_K$ .

### Exercice 8

En introduisant deux ex-aequo, on obtient des rangs

$$r_1 = 1, r_2 = 2.5, r_3 = 2.5, r_4 = 4, r_5 = 5, \dots, r_n = n .$$

Pour calculer  $\text{Var}(r)$  avec des poids uniformes normalisés  $p_k = 1/n$ , on s'aide du calcul de  $\text{Var}(s) = (n^2 - 1)/12$  où  $s_k = k$ . On considère un premier groupe avec les deux ex-aequo  $\{2, 3\}$  et un second groupe avec tous les autres indices.

1. Donner les poids  $q_1$  et  $q_2$  des deux groupes.
2. Comparer les moyennes dans le premier groupe  $\bar{r}_1$  et  $\bar{s}_1$ . Qu'en est-il pour les moyennes  $\bar{r}_2$  et  $\bar{s}_2$  dans le second groupe ? En déduire que les variances inter-groupes de  $r$  et  $s$  sont égales.
3. Calculer les variances dans le premier groupe  $\sigma_1^2(r)$  et  $\sigma_1^2(s)$ . Expliquer pourquoi les variances  $\sigma_2^2(r)$  et  $\sigma_2^2(s)$  dans le second groupe sont égales. Que pouvez-vous déduire sur les variances intra-groupes de  $r$  et  $s$ .
4. Calculer  $\text{Var}(r)$ .

**Attention :** les seuls calculs de cet exercice sont ceux de  $\sigma_1^2(r)$  et  $\sigma_1^2(s)$ . Ne vous lancez pas dans des calculs fastidieux et inutiles...