

# TIAD - fiche 3

## Exercice 1 (Modèle de régression à variables qualitatives)

Soit  $Y$  une variable observable prenant les valeurs 1, avec probabilité  $p$  et 0, avec probabilité  $1 - p$ . Nous observons un échantillon  $(Y_i)_{i \in \llbracket 1, n \rrbracket}$  de variables aléatoires indépendantes identiquement distribuées de même loi que  $Y$ .

**1.1.** Quelles sont les lois de  $Y$  et  $\sum_{i=1}^n Y_i$  ?

**1.2.** Ecrire la vraisemblance des observations. Calculer et étudier l'estimateur du maximum de vraisemblance  $\hat{p}$  de  $p$ .

Nous considérons maintenant un couple de variables aléatoire  $(Y, X)$  où  $X$  est une variable explicative prenant les valeurs 0 ou 1, et où les  $Y$  est une variable à expliquer, prenant elle aussi les valeurs 0 et 1, et pour laquelle on suppose qu'il existe une variable latente  $Y^*$  telle que

- conditionnellement à  $X$ ,  $Y^*$  suit une loi  $\mathcal{N}(aX + b, 1)$  avec  $a, b \in \mathbb{R}$ ,
- $Y = \mathbf{1}_{Y^* > 0}$ .

**2.1.** Quelles sont les lois de  $Y$  et  $Y^*$  conditionnellement à  $X$  ? Montrer que  $\mathbb{P}(Y = 1 | X = 1) = \Phi(a + b)$  où  $\Phi$ , la fonction de répartition de la loi normale  $\mathcal{N}(0, 1)$ . Calculer les probabilités  $\mathbb{P}(Y = 1 | X = 0)$ ,  $\mathbb{P}(Y = 0 | X = 1)$  et  $\mathbb{P}(Y = 0 | X = 0)$ .

Nous disposons d'un échantillon de 100 observations,  $(y_i, x_i)_{i \in \llbracket 1, 100 \rrbracket}$  réalisations des 100 couples  $(Y_i, X_i)_{i \in \llbracket 1, 100 \rrbracket}$  indépendants deux à deux et de même loi que  $(Y, X)$  étudié à la question 2.1. Ces observations sont résumées dans le Tableau 1.

		Y	
		0	1
X	0	$n_{00} = 26$	$n_{01} = 26$
	1	$n_{10} = 16$	$n_{11} = 32$

TABLE 1 – Tableau de contingence de  $X$  et  $Y$

**2.2.** Ecrire la vraisemblance des observations  $(Y_1, \dots, Y_{100})$  conditionnellement à  $(X_1, \dots, X_{100})$  en utilisant les nouvelles variables  $\alpha = \Phi(a + b)$  et  $\beta = \Phi(b)$  ainsi que les effectifs  $n_{00}$ ,  $n_{01}$ ,  $n_{10}$  et  $n_{11}$  définis dans le Tableau 1.

**2.3.** Donner la log-vraisemblance. Puis, écrire les conditions du premier ordre du programme de maximisation de la log-vraisemblance par rapport à  $\alpha$  et  $\beta$ .

**2.4.** En déduire les estimateurs du maximum de vraisemblance  $\hat{\alpha}$  et  $\hat{\beta}$  pour  $\alpha$  et  $\beta$ . Faire l'application numérique avec les valeurs données dans le Tableau 1.

**2.5.** Donner la valeur de  $\Phi(0)$ . En déduire  $\Phi^{-1}(1/2)$ . Puis, en utilisant que  $\Phi^{-1}(2/3) = 0.43$ , déduire les valeurs numériques des EMV  $\hat{a}$  et  $\hat{b}$  pour les observations décrites au Tableau 1.

**2.6.** Les estimateurs  $\hat{\alpha}$  et  $\hat{\beta}$  sont-ils convergents lorsque  $n_{00} + n_{01} \rightarrow +\infty$  et  $n_{10} + n_{11} \rightarrow +\infty$ ? Qu'en déduire pour  $\hat{a}$  et  $\hat{b}$ ?

**2.7.** Qu'en est-il de la normalité asymptotique?