

## STATISTIQUE DE ANDERSON (I7, K7, K9)

(12 / 11 / 2019, © Monfort, Dicostat2005, 2005-2019)

La **statistique de ANDERSON** permet de classer une **observation** supplémentaire dans l'une parmi deux **populations**. Ces populations sont supposées gaussiennes et homogènes (même dispersion) (cf **problème à plusieurs échantillons, homogénéité**).

(i) Soit  $X^i = (X_{i1}, \dots, X_{iN(i)})$  ( $i = 1, 2$ ) deux **échantillons aléatoires** (on note de façon équivalente  $N(i)$  et  $N_i$ ). On suppose que  $\xi_1$  et  $\xi_2$  sont des va indépendantes, chacune distribuée selon la **loi normale**  $\mathcal{L}(\xi_i) = \mathcal{N}_K(\mu_i, \Sigma)$  ( $i = 1, 2$ ), et que la **matrice de dispersion**  $\Sigma$  leur est commune (ie ne dépend pas de  $i$ ). On note  $X^i$  un **échantillon iid** issu de  $\xi_i$  ( $i = 1, 2$ ) (donc  $X^1$  et  $X^2$  sont indépendants entre eux). On pose ( $i = 1, 2$ ) :

$$(1) \quad \begin{aligned} \bar{X}_i &= (N_i)^{-1} \sum_{n(i)=1}^{N(i)} X_{in(i)}, \\ S_i^2 &= (N_i - 1)^{-1} \cdot \sum_{n(i)=1}^{N(i)} (X_{in(i)} - \bar{X}_i) (X_{in(i)} - \bar{X}_i)', \end{aligned}$$

la **moyenne empirique** vectorielle et la **matrice de dispersion** empirique (corrigée) de l'échantillon n°  $i$ , considérés comme estimateurs resp de  $\mu_i$  et de  $\Sigma$ .

La **variance empirique** d'ensemble « corrigée » est définie comme moyenne (arithmétique) pondérée :

$$(2) \quad S^2 = (N_1 + N_2 - 2)^{-1} \cdot \{(N_1 - 1) S_1^2 + (N_2 - 1) S_2^2\}.$$

$S^2$  est alors un **estimateur sans biais** de la dispersion commune  $\Sigma$ .

(ii) Si  $X^*$  représente une observation supplémentaire, on appelle **statistique de T.W. ANDERSON** la **statistique** suivante :

$$(3) \quad W_{N(1)N(2)} = X^{*'} S^{-2} (\bar{X}_1 - \bar{X}_2) - (1/2) (\bar{X}_1 + \bar{X}_2)' S^{-2} (\bar{X}_1 - \bar{X}_2),$$

qui s'écrit aussi :

$$(4) \quad W_{N(1)N(2)} = \{X^* - (1/2) (\bar{X}_1 + \bar{X}_2)\}' S^{-2} (\bar{X}_1 - \bar{X}_2).$$

La **règle de décision**, appelée **règle d'affectation** ou **règle de classement** (ou parfois **règle de classification** ou **règle de discrimination**), de  $X^*$  est alors la suivante :

$$(5) \quad \begin{aligned} W_{N(1)N(2)} > q_{1-\alpha} &\Rightarrow X^* \sim P^{\xi(1)}, \\ W_{N(1)N(2)} < q_{1-\alpha} &\Rightarrow X^* \sim P^{\xi(2)}, \end{aligned}$$

où  $q_{1-\alpha}$  est le **quantile** d'ordre  $\alpha \in ]0, 1[$  de la **loi**  $\mathcal{L}(W_{N(1)N(2)})$  de  $W_{N(1)N(2)}$ .

Cette loi est tabulée et possède des **approximations** asymptotiques (cf **loi asymptotique**).