

## DISPERSION (C5, F3)

(30 / 04 / 2020, © Monfort, Dicostat2005, 2005-2020)

La **dispersion** est une propriété selon laquelle les valeurs d'une **variable aléatoire** sont, dans l'ensemble, plus ou moins « proche » d'une valeur donnée, ou encore plus ou moins regroupées, ou concentrées, autour d'une **partie centrale**. On parle aussi de **variabilité** ou d'**éparpillement**. La notion ne se définit pas seulement pour une **variable numérique** ; elle peut s'étendre à une **variable qualitative**.

On peut définir un concept de dispersion dès que l'on peut définir :

(a) une notion d'**écart**, ou de **distance**, entre les valeurs prises par une **variable aléatoire** ;

(b) une notion de **valeur de référence**, ou **valeur centrale**, pour apprécier la **distribution** (ou répartition) des écarts ou distances entre les valeurs.

(i) Un indicateur synthétique, permet souvent de « résumer » cette propriété. Ainsi,  $(\Omega, \mathcal{F}, P)$  étant un **espace probabilisé** et  $\xi : \Omega \mapsto \mathbf{R}^K$  un **vecteur aléatoire** de loi  $P^\xi$  et de carré intégrable, un **indicateur de dispersion** par rapport à un vecteur (certain) donné  $\alpha \in \mathbf{R}^K$ , peut être :

(a) de type scalaire (espérance du carré de la norme, ou moyenne des carrés des écarts) :

$$(1) \quad \sigma^2(\alpha) = E \|\xi - \alpha\|^2 ;$$

(b) de type matriciel (espérance d'un produit matriciel d'écarts vectoriels, ou moyenne des produits des écarts) :

$$(2) \quad \Sigma^2(\alpha) = E (\xi - \alpha)(\xi - \alpha)'$$

Le plus souvent,  $\alpha$  est une **caractéristique** de **centralité** ou un **paramètre de position** de  $P^\xi$  : **espérance mathématique, mode, quantile**.

L'indicateur de dispersion est alors une **caractéristique**, souvent de même nature (centralité ou position), de la loi d'une va  $\eta$  définie à partir de  $\xi$  selon un **changement de variable aléatoire** donné :

$$(3) \quad \eta = \varphi(\xi - \alpha),$$

où  $\varphi : \mathbf{R}^K \mapsto \mathbf{R}^L$  est une fonction donnée.

Dans l'exemple ci-dessus, on considère très souvent le cas où  $\alpha = E \xi$ . D'autre part, dans (1), on a posé  $L = 1$  et  $\varphi(e) = \|e\|^2$  (**norme** euclidienne) avec  $e \in \mathbf{R}^K$  (cf **espace euclidien**) ; dans (2), on a posé  $L = K$  ( $\mathbf{R}^K$  étant identifié à  $M_{K,1}(\mathbf{R})$ ) et  $\varphi(e) = e e'$ , avec  $e \in \mathbf{R}^K$ .

Si  $P^\xi$  est une **loi unimodale**, on peut aussi considérer le cas modal, dans lequel  $\alpha = S \xi$  (**mode** de  $\xi$ ) et définir un indicateur de dispersion analogue à (1) ou (2) selon (mode du carré des écarts pr au mode) :

$$(4) \quad \sigma^2(\alpha) = S \|\xi - \alpha\|^2,$$

ou par (mode d'un produit matriciel d'écarts pr au mode) :

$$(5) \quad \Sigma^2(\alpha) = S \{(\xi - \alpha)(\xi - S \alpha)'\}.$$

La définition d'un indicateur de dispersion n'est pas toujours aisée. Ainsi, on peut mesurer la dispersion du vecteur  $\xi$  à l'aide de :

$$(6) \quad E \|\xi - \alpha\|^2 = E (\xi - \alpha)'(\xi - \alpha) = \text{tr}(V \xi) + \|E \xi - \alpha\|^2,$$

où  $V \xi$  est la **matrice des covariances** de  $\xi$ , du fait de l'**équation triviale**  $\xi - \alpha = (\xi - E \xi) + (E \xi - \alpha)$ . Mais cette représentation scalaire possède l'inconvénient de ne pas permettre une comparaison toujours efficace de la dispersion entre deux va. En effet, si  $\eta : \Omega \mapsto \mathbf{R}^K$  est une autre va, on peut avoir :

$$(7) \quad E \|\xi - \alpha\|^2 < E \|\eta - \alpha\|^2,$$

avec, néanmoins,  $E(\xi_{k_0} - \alpha_{k_0})^2 > E(\eta_{k_0} - \alpha_{k_0})^2$  pour un indice  $k_0 \in N_K^*$  (une coordonnée de  $\xi$  est, en moyenne, plus dispersée que la coordonnée de même indice de  $\eta$ ).

C'est pourquoi l'on préfère plutôt utiliser des définitions tq :

$$(8) \quad E (h' \xi - h' \alpha)^2 = q(h),$$

**forme quadratique** en  $h \in \mathbf{R}^K$  qui s'écrit :

$$(9) \quad q(h) = h' E (\xi - \alpha)(\xi - \alpha)' h = h' (D_\alpha \xi) h,$$

où  $D_\alpha \xi$ , aussi notée  $D(\xi, \alpha)$ , désigne la **matrice de dispersion** de  $\xi$  autour de  $\alpha$ . La **matrice des covariances** de  $\xi$  est alors définie comme  $V \xi = D(\xi, E \xi)$ , aussi notée  $D \xi$ , ce qui n'est autre que  $\Sigma^2(\alpha)$  définie en (2) avec  $\alpha = E \xi$ . Dans ce cas :

$$(9) \quad q(h) = V(h' \xi).$$

(ii) Par ailleurs, on peut considérer la **dispersion entre lois** elles-mêmes, au lieu de leurs seules caractéristiques de dispersion. Si  $\alpha$  est considéré comme une **variable dégénérée**, de loi  $\delta_\alpha$  (**loi de DIRAC** au point  $\alpha \in \mathbf{R}^K$ ), on dit que  $\xi$  est une **variable aléatoire dispersée** pr à  $\alpha$  dès que  $P^\xi \neq \delta_\alpha$ . Soit  $\mathcal{P}$  l'ensemble des **mesures de probabilité** sur  $\mathcal{T}$  et  $\mathcal{P}^\xi$  l'image de  $\mathcal{P}$  par  $\xi$ . Si l'on munit  $\mathcal{P}^\xi$  d'une distance  $\delta$ , un **indicateur de dispersion** (scalaire) de  $\xi$  pr à  $\alpha$  sera donc naturellement défini par la distance (cf **distance entre probabilités**) :

$$(10) \quad \delta^2(\alpha) = d^2(P^\xi, \delta_\alpha), \quad \forall P^\xi \in \mathcal{P}^\xi.$$

Par suite, la **dispersion relative entre lois**, eg  $P_1^\xi$  et  $P_2^\xi$ , ayant même paramètre de centralité  $\alpha$ , sera définie par :

$$(11) \quad \Delta^2(P_1, P_2) = d^2(P_1^\xi, P_2^\xi).$$

(iii) On peut relier la notion de dispersion à celle de **centralité**. En effet, soit  $(\mathcal{X}, \mathcal{B})$  un **espace probabilisable** dans lequel  $\mathcal{X}$  est un **espace topologique** et  $\xi : \Omega \mapsto \mathcal{X}$  une v.a donnée, dont la **lp**  $P^\xi$  est supposée absolument continue pr à une **mesure positive**  $\sigma$ -finie  $\mu$  définie sur  $\mathcal{B}$ . Si  $C \in \mathcal{B}$  est une **partie centrale** pour  $\xi$  (ou pour sa loi), alors la dispersion (scalaire) de  $\xi$  dans  $C$  peut être définie à l'aide du « **volume** » de  $C$ , mesuré par  $\mu(C)$ . La notion de dispersion est aussi à rapprocher de celles d'**aplatissement** (cf **coefficient d'aplatissement**) ou de **queue d'une loi**.