

## CARACTÉRISTIQUE, CARACTÉRISTIQUE LÉGALE (C5, F3)

(19 / 10 / 2021, © Monfort, Dicostat2005, 2005-2021)

On emploie parfois le terme de **caractéristique** avec le sens de **caractère** (variable observable sur une **unité statistique**) ou d'**attribut**, ie de **variable qualitative**.

Une autre signification importante se rapporte à la **caractérisation d'une loi de probabilité** à travers des grandeurs (généralement scalaires ou fonctionnelles) qui peuvent s'en déduire (cf aussi **paramètre**): on parle alors de **caractéristique légale**, ou simplement de **caractéristique**.

(i) Soit  $(\Omega, \mathcal{F}, P)$  un **espace probabilisé** et  $(\mathcal{X}, \mathcal{B}, P^\xi)$  un **espace d'observation**, image du premier par une **va**  $\xi : \Omega \mapsto \mathcal{X}$ .

On appelle **caractéristique légale**, ou **caractéristique, (théorique)** de  $P^\xi$  (ou de  $\xi$ ) tout élément  $\gamma$  qui peut être associé à  $P^\xi$  (ou à  $\xi$ ) en vue de la caractériser ou de la décrire (cf aussi **forme, forme légale**):  $\gamma$  peut être un **moment algébrique** d'ordre  $j$  (eg **espérance mathématique, variance**), un **quantile** d'ordre  $p$ , un **mode**, ou encore une **fonction de répartition**, une **densité de probabilité**, une **fonction caractéristique**, etc.

Cet élément est susceptible de parcourir un ensemble  $\Gamma$  de « valeurs », alors appelé **ensemble des caractéristiques**, ou **ensemble caractéristique**, de  $P^\xi$ .

(ii) Plus généralement, si  $(\mathcal{X}, \mathcal{B}, \mathcal{P}^\xi)$  est un **modèle image** d'un **modèle statistique** de base  $(\Omega, \mathcal{F}, \mathcal{P})$  par  $\xi : \Omega \mapsto \mathcal{X}$ , il existe en général une application de  $\mathcal{P}^\xi$  dans  $\Gamma$  définie par :

$$(1) \quad c : \mathcal{P}^\xi \mapsto c(P^\xi) = \gamma,$$

qui associe à toute  $P^\xi$  une **caractéristique**  $\gamma$  : cette application est appelée **application caractéristique**, ou encore **caractérisation**, de  $P^\xi$ .

Cette notion est différente de celle de **fonction caractéristique**, mais une fc peut être considérée comme une caractéristique légale fonctionnelle.

(iii) A titre d'exemples :

(a) lorsque  $\xi \in \mathcal{L}_{\mathbf{R}^K}^1(\Omega, \mathcal{F}, P)$  (où  $\mathbf{R}^K$  désigne  $\mathbf{R}^K$ ),  $\forall P \in \mathcal{P}$ , et que  $\Gamma = \mathbf{R}^K$ , on considère souvent l'**espérance mathématique**  $\gamma = E \xi$ . Si  $K = 1$ , on peut considérer la **médiane**  $\gamma = Q_{1/2} \xi$  (même si l'ensemble médian  $Q_{1/2} \xi$  ne se réduit pas à un seul point), ou encore le **mode**  $\gamma = S \xi$  (même si la zone modale  $S \xi$  n'est pas ponctuelle) (cf **centralité**) ;

(b) lorsque  $P^\xi$  admet une (classe de) **densité(s)**  $f_\xi$  (resp une (classe de) **fr**  $F_\xi$ ) pr à une **mesure positive**  $\mu$  définie sur  $\mathcal{B}$ , on peut considérer pour caractéristique la densité  $\gamma = f_\xi$  (resp la **fonction de répartition**  $\gamma = F_\xi$ ).

(iv) Le plus souvent, plusieurs caractéristiques  $\gamma_1, \dots, \gamma_Q$  de  $P^\xi$  (ou de  $\xi$ ) sont considérées simultanément, resp à valeurs dans des ensembles  $\Gamma_1, \dots, \Gamma_Q$ . On pose alors :

$$(2) \quad \Gamma = \prod_{q=1}^Q \Gamma_q \text{ et } \quad c = (c_1, \dots, c_Q) : \mathcal{P}^\xi \mapsto \Gamma.$$

Ainsi :

(a) lorsque  $\xi \in \mathcal{L}_{\mathbb{R}^k}^2(\Omega, \mathcal{F}, P)$ ,  $\forall P \in \mathcal{P}$ , on considère souvent (eg **modèle de régression**) le couple  $\gamma_1 = c_1(P^\xi) = E \xi$  et  $\gamma_2 = c_2(P^\xi) = V \xi$ . Ici,  $\Gamma_1 = \mathbb{R}^k$  et  $\Gamma_2 = M_k^+(\mathbb{R}) \cap S_k(\mathbb{R})$  (ensemble des matrices symétriques réelles semi-définies positives) (cf **matrice symétrique, matrice définie positive**) ;

(b) lorsque  $dP^\xi / d\mu = f_\xi$ , et que  $f_\xi$  est de classe  $C^1$  (ce qui suppose que  $\Omega$  est un **espace normé**), on considère parfois (eg en **statistique non paramétrique**)  $\gamma_1 = c_1(P^\xi) = f_\xi$  et  $\gamma_2 = c_2(P^\xi) = f_\xi'$ . Ici, on a  $\Gamma_1 = \mathcal{D}$  (ensemble des (classes de) densité(s))  $f_\xi = dP^\xi / d\mu$ , où  $P^\xi \in \mathcal{P}^\xi$  et  $\Gamma_2 = \mathcal{L}$  (ensemble des dérivées  $f_\xi'$  considérées comme **applications linéaires**) (en identifiant les classes de densités  $\mu$ -équivalentes avec leurs représentants).

Dans le cas paramétrique fréquent, où  $\mathcal{P}^\xi = (P_\theta^\xi)_{\theta \in \Theta}$  est une **famille** de **lp** indexée par un **espace vectoriel**  $\Theta$  de dimension finie (ensemble des valeurs du **paramètre** vectoriel  $\theta$ ), certaines caractéristiques peuvent aussi être des paramètres, ou inversement, ie :

$$(3) \quad \Gamma \cap \Theta \neq \emptyset.$$

(v) Une caractéristique  $\gamma$  peut ainsi être un **paramètre d'intérêt**  $\theta$ , et inversement. A titre d'exemple, lorsque  $P_\theta^\xi = \mathcal{N}_k(\mu, \Sigma)$  (**loi normale multidimensionnelle**), avec  $\theta = (\mu, \Sigma)$  et  $\Theta = \mathbb{R}^k \times (M_k^+(\mathbb{R}) \cap S_k(\mathbb{R}))$ , alors  $\mu = E \xi$  et  $\Sigma = V \xi$  (**espérance, dispersion**).

(vi) Dans certaines situations (eg en **théorie bayésienne**), il est possible de munir l'ensemble  $\Gamma$  d'une structure d'**espace mesurable** (resp d'**espace mesuré**), noté  $(\Gamma, \mathcal{B}_\Gamma)$  (resp  $(\Gamma, \mathcal{B}_\Gamma, \nu)$ ), où  $\nu$  est une **mesure positive** définie sur  $\mathcal{B}_\Gamma$ . On appelle alors (**mesure de**) **probabilité a priori** sur  $\Gamma$  une **mesure de probabilité**  $\Pi$  définie sur  $\mathcal{B}_\Gamma$  et, en général, supposée absolument continue pr à  $\nu$ , la **dérivée de NIKODYM-RADON**  $d\Pi / d\nu$  étant appelée **densité a priori**. Si l'on pose  $\Gamma = \mathcal{P}^\xi$  et  $c = \text{id}(\mathcal{P}^\xi)$

(**identité** de  $\mathcal{P}^\zeta$ ), on admet aussi, par extension, que  $P^\zeta$  est une caractéristique d'elle-même (avec  $\Gamma = \mathcal{P}^\zeta$  et  $c : \mathcal{P}^\zeta \mapsto \Gamma$ ).

(vii) La notion de caractéristique est donc très générale. On peut établir la classification simplifiée de la notion de caractéristique comme suit :

(a) **caractéristique de position**, ou **caractéristique de localisation**, ou **caractéristique de centralité** (cf aussi **paramètre de position**) ;

(b) **caractéristique d'échelle**, ou **caractéristique de dispersion** (cf aussi **paramètre d'échelle**) ;

(c) **caractéristique de concentration** ou **caractéristique de densification**, ou, à l'inverse, **caractéristique d'éparpillement** ou **caractéristique de raréfaction** ;

(d) **caractéristique de forme** : **asymétrie**, **aplatissement**, **concentration** (cf précédente), etc ;

(e) **caractéristique fonctionnelle** : **densité de probabilité**, **fonction de répartition**, **fonction génératrice**, **fonction caractéristique** (cf **transformée de FOURIER**), **régression**, etc (cf aussi **fonctionnelle**).

(viii) Les **caractéristiques théoriques** précédentes se distinguent des **caractéristiques empiriques** en raison de leur mode de calcul :

(a) soit à partir de la **loi de probabilité** (théorique)  $P^\zeta$  d'une **variable aléatoire**  $\zeta$  (a priori) **observable** qui se relie à (ie décrit) un **phénomène** donné : cette loi permet de définir la notion de **caractéristique théorique** ;

(b) soit à partir d'un ensemble de  $N$  valeurs prises par un **échantillon aléatoire**  $Z = (Z_1, \dots, Z_N)$  dont la loi est  $P^Z = Z(P)$  : la **loi empirique**  $P_N$  de  $Z$  permet alors de définir la notion de **caractéristique empirique**. Autrement dit,  $\zeta$  est observée sur  $N$  **unités statistiques**  $a_n$  ( $n = 1, \dots, N$ ) « participant » au phénomène considéré, avec  $Z_n = \zeta(a_n)$ ,  $\forall n \in N_N^*$ . En particulier, lorsque  $Z$  est un **échantillon iid** issu de  $P^\zeta$ , les  $Z_n$  sont des **copies** de  $\zeta$ , ie  $P^Z = (P^\zeta)^{\otimes N}$ .

Cette loi empirique permet aussi le calcul de diverses **statistiques** (cf aussi **fonction des moments empiriques**). En effet, une caractéristique théorique admet généralement pour estimateur naturel la **caractéristique empirique** analogue, ie celle calculée à l'aide de  $P_N$  (cf **statistique naturelle**). Si l'opération  $c$  a un sens, une caractéristique  $\gamma = c(P^\zeta)$  peut ainsi être (a priori) estimée par son analogue empirique  $g_N = c(P_N)$ .

Cet **estimateur** n'est pas nécessairement le meilleur et doit parfois être corrigé (cf **correction**, **modification**, **moment corrigé**).

(ix) Selon la nature de la **variable aléatoire** considérée ou de sa **loi de probabilité**, la définition d'une caractéristique peut posséder un sens ou non. Ainsi :

(a) le **mode** peut (généralement) être défini aussi bien pour une **variable qualitative**  $\kappa$  que pour une **variable numérique**  $\xi$ . Il en va de même pour la notion de « **densité** » (cf **densité de probabilité**), à condition d'étendre sa définition en la **suite**  $((k_1, p_1) \dots, (k_M, p_M))$ , dans laquelle  $(k_1 \dots, k_M)$  est la suite des modalités de  $\kappa$  et  $(p_1 \dots, p_M)$  celle de ses fréquences (théoriques), ou probabilités, associées ;

(b) de même, on peut associer la notion de **quantile** à une **variable ordinale** (si le nombre  $M$  de ses modalités est suffisant).

A l'inverse, ces propriétés ne sont pas vérifiées pour une **dispersion** (eg **variance**).