

ENTROPIE (C5, F3, G6)

(21 / 04 / 2020, © Monfort, Dicostat2005, 2005-2020)

Le concept d'**entropie** (R.E. CLAUSIUS, L.E. BOLTZMANN) caractérise l'**hétérogénéité** d'une **population statistique** ou la **dispersion** d'une **loi de probabilité**. On le présente dans des situations usuelles.

(i) Cas scalaire discret

Soit (Ω, \mathcal{F}, P) un **espace probabilisé**, $(\mathcal{X}, \mathcal{B})$ un **espace mesurable** (au plus) dénombrable (avec $\mathcal{B} = \mathcal{P}(\mathcal{X})$) et $\xi : \Omega \mapsto \mathcal{X}$ une **variable discrète** de **loi** P^ξ . On pose $f(x) = P^\xi(\{x\})$, $\forall x \in \mathcal{X}$ (**distribution des « masses »**).

On appelle **entropie**, ou **incertitude**, ou **degré d'indétermination**, de ξ (ou de P^ξ) la valeur de la série (si elle converge) :

$$(1) \quad H(P^\xi) = \sum_{x \in \mathcal{X}} f(x) \cdot \text{Log}(1/f(x)),$$

avec la convention de continuité $u(0) = 0$ pour la fonction $u : t \mapsto u(t) = t \cdot \text{Log}(1/t)$, définie sur $]0, 1]$.

En particulier, si \mathcal{X} est **fini** ($\text{Card } \mathcal{X} = I$) et si $P^\xi = \mathcal{U}(\mathcal{X})$ (**loi uniforme discrète** sur \mathcal{X}), on définit la notion d'entropie la plus simple, l'**entropie de R.V. HARTLEY** :

$$(2) \quad H(\mathcal{U}(\mathcal{X})) = \text{Log}(\text{Card } \mathcal{X}) = \text{Log } I.$$

On note l'entropie $H(\xi)$ (entropie de la va ξ), ou $H(P^\xi)$ (entropie de la loi P^ξ), ou $H(f)$ (entropie de la **densité** f de P^ξ), ou encore $H(F)$ (entropie de la **fr** F associée à P^ξ).

(ii) Si \mathcal{Y} est un autre ensemble tq $f : \mathcal{X} \mapsto \mathcal{Y}$ soit bijective (donc $f(\mathcal{X}) \subset \mathcal{Y}$ au plus dénombrable), on établit la **propriété d'invariance de l'entropie** (dans le cas discret) :

$$(3) \quad H(f(\xi)) = H(\xi), \text{ P-p.s..}$$

Cette propriété est parfois utilisée dans l'étude des variables qualitatives : f est alors un **codage**.

Dans le cas d'une **variable qualitative**, l'**entropie** se définit selon :

$$(4) \quad H(p) = \sum_{i \in I} p_i \text{Log}(1/p_i) = - \sum_{i \in I} p_i \text{Log } p_i,$$

où les p_i ($i \in I$) sont des **proportions** ou des **fréquences empiriques** (eg les **proportions empiriques** attachées à un **tableau de contingence** (multidimensionnel), i désignant alors le multi-**indice** associé aux **critères** définissant ce tableau (cf **loi qualitative**).

(iii) On montre que :

(a) $H(\xi) = 0 \Rightarrow \xi = c$ (P-p.s.), ie $P^\xi = \delta_c$ (**loi de DIRAC** chargeant le point c), où c est une **constante** ;

(b) si $\text{Card } \mathcal{X} = I < +\infty$, alors $H(\xi) \leq \text{Log } I$;

(c) si \mathcal{Y} est dénombrable et $\varphi : \mathcal{X} \mapsto \mathcal{Y}$ mesurable, alors : $H(\varphi(\xi)) \leq H(\xi)$;

(d) si \mathcal{Y} est dénombrable, si $\xi : \Omega \mapsto \mathcal{X}$, $\eta : \Omega \mapsto \mathcal{Y}$, et si $H(\xi) < +\infty$ et $H(\eta) < +\infty$, alors : $H((\xi, \eta)) \leq H(\xi) + H(\eta)$. De plus, la saturation à égalité équivaut à l'**indépendance** de ξ et de η .

(iv) **Cas vectoriel « continu »**

Soit (Ω, \mathcal{F}, P) un **espace probabilisé** et $\xi : \Omega \mapsto \mathbf{R}^K$ un **vecteur aléatoire** réel de loi $P^\xi = \xi(P)$. On suppose que P^ξ admet une **densité** f pr à la **mesure de LEBESGUE** λ_K définie sur $\mathcal{B}(\mathbf{R}^K)$ et l'on note F sa **fr**.

On appelle **entropie de (la loi de) ξ** le nombre réel (s'il existe) :

$$(5) \quad H(\xi) = E \text{Log}(1/f(\xi)) = \int f(x) \text{Log}(1/f(x)) d\lambda_K(x),$$

qui est l'**espérance** de la va $\eta : \Omega \mapsto \mathbf{R}$ définie par $\eta = \text{Log}(1/f(\xi))$. On a donc $H(\xi) = -E \text{Log } f(\xi)$.

On peut aussi écrire :

$$(6) \quad H(\xi) = \int \text{Log}(1/f(x)) dF(x) = \int (1/f(x))^{-1} \text{Log}(1/f(x)) d\lambda_K(x)$$

(entropie de la fr ou de la densité).

Comme précédemment, on note aussi, selon le cas, $H(P^\xi)$, ou $H(f)$ ou encore $H(F)$.

(v) Soit $\varphi : \mathbf{R} \mapsto \mathbf{R}$ une fonction définissant un **changement de variable aléatoire** $\xi^* = \varphi(\xi)$ et f^* la densité de la **lp** de ξ^* pr à λ_1 . Alors, en notant $H(f) = -E \text{Log } f(\xi)$ l'entropie de ξ , celle de ξ^* s'écrit (par définition) :

$$(7) \quad H(f^*) = -E \text{Log } f^*(\xi^*) = -\int f^*(x^*) \text{Log } f^*(x^*) dx^*,$$

soit explicitement :

$$(8) \quad H(f^*) = -\int f^*(\varphi(x)) \text{Log } f^*(\varphi(x)) \varphi'(x) dx.$$

(vi) Si $\xi \in L_{\mathbf{R}^K}^2(\Omega, \mathcal{F}, P)$, si la densité f de la loi P^ξ de ξ par à λ_K est continue, et si $\mu \in \mathbf{R}^K$ est un vecteur donné et $\Sigma \in M_K(\mathbf{R})$ une **matrice** donnée, alors le **problème d'optimisation** suivant :

$$(9) \quad \begin{aligned} & \max H(P^\xi) \\ & \text{sous } E \xi = \mu \text{ et } V \theta = \Sigma \end{aligned}$$

admet pour solution la **loi normale multidimensionnelle** $P^\xi = \mathcal{N}_K(\mu, \Sigma)$. Par suite :

$$(10) \quad H^*(\mathcal{N}_K(\mu, \Sigma)) = (1/2) \cdot \{K \text{Log}(2\pi) + K + \text{Log}|\Sigma|\}.$$

En particulier, si $K = 1$, $E \xi = 0$ et $V \xi = 1$, on obtient la solution $\mathcal{N}(0, 1)$ (**loi normale réduite**) dont l'entropie vaut $H(\mathcal{N}(0,1)) = \text{Log}(2\pi e)$.

(vii) On appelle **neg-entropie**, ou **information de S. KULLBACK - R.A. LEIBLER**, de ξ , ou de sa loi, la quantité, si elle existe :

$$(11) \quad K(\xi) = -H(\xi).$$

(viii) Si $K = 1$ et si $p \mapsto F^{-1}(p) = \inf \{x \in \mathbf{R} : F(x) \geq p\}$ désigne la **fonction quantile**, on montre que :

$$(12) \quad H(\xi) = \int \text{Log}\{\Psi(p)\} dp, \quad \text{avec } \Psi(p) = dF^{-1}(p) / dp.$$

D'autre part, un changement affine de va $\xi = \mu + \sigma \varepsilon$ (avec $\sigma > 0$) entraîne : $H(\xi) = H(\varepsilon) + \text{Log} \sigma$, ie $H(F) = H(G) + \text{Log} \sigma$, où F est la fr de ξ et G celle de ε .

La relation (12) permet de définir un **estimateur de l'entropie** ainsi qu'un **test de normalité** basé sur l'entropie (cf **test de VASICKEK**).

(ix) Soit f la densité associée à la loi $\mathcal{L}(\xi)$ de la **vars** ξ par à la **mesure de LEBESGUE** dx , et dont le **support** est le segment $[a, b] \subset \mathbf{R}$. Soit $(\mu, \nu) \in \mathbf{R} \times \mathbf{R}$ un paramètre donné et $h : [a, b] \mapsto \mathbf{R}$ une **fonction numérique** donnée. Alors, la maximisation de l'entropie :

$$(13) \quad H(f) = - \int \mathbf{1}_{([a, b])} x \cdot f(x) \cdot \text{Log}(x \cdot f(x)) dx$$

sous les contraintes :

$$(14) \quad \begin{aligned} & \int \mathbf{1}_{([a, b])} x \cdot f(x) dx = \alpha && \text{(espérance de } \xi), \\ & \int \mathbf{1}_{([a, b])} h(x) \cdot f(x) dx = \beta && \text{(espérance de } h(\xi)), \end{aligned}$$

conduit à une solution de la forme :

$$(15) \quad f^*(x) = \{c(\alpha, \beta) / x\} \cdot \exp \{-(\beta / x)(h(x) - \alpha)\}, \quad \forall x \in \mathbf{R},$$

où $c(\alpha, \beta) > 0$ est une **constante** de **normalisation** qui dépend de (α, β) .

(ix) Diverses extensions de l'entropie ont été définies, eg :

(a) on peut remplacer, dans les définitions, la mesure de LEBESGUE par une **mesure positive** σ -finie (cf **mesure σ -finie**) ;

(b) l'**entropie de A. RÉNYI**. Si X est une **variable discrète** et si $\text{Card } \mathcal{X} = I$ est fini, on appelle **entropie (au sens de RÉNYI) d'ordre α** (avec $\alpha \geq 0$) le nombre réel, $H_\alpha(\xi)$ défini, s'il existe, par (cf **information de C.E. SHANNON**) :

$$(16) \quad H_\alpha(\xi) = \begin{cases} (1 - \alpha)^{-1} \{\text{Log } \sum_{i=1}^I (f(x_i))^\alpha\} & \text{si } \alpha \neq 0, \\ H(\xi) & \text{si } \alpha = 0, \end{cases}$$

où l'on note $dP^\xi = \prod_{i=1}^I f(x_i) dx_i$.

(x) L'entropie sert parfois de **fonction de perte** ou de pseudo « **distance** ». Ainsi, une (fonction de) **perte entropique** peut s'écrire (eg dans le cas gaussien) :

$$(17) \quad L(\Sigma, \Sigma_0) = \text{tr}(\Sigma_0 \Sigma^{-1}) - \text{Log} |\Sigma_0 \Sigma^{-1}| - p,$$

où $\xi \sim \mathcal{N}_p(\mu, \Sigma)$ (**loi normale multidimensionnelle**) et où Σ est une **matrice définie positive**.

(xi) Enfin, on rencontre souvent, au lieu des **logarithmes népériens** utilisés dans les questions théoriques, des logarithmes exprimés dans une **base** différente de e (eg logarithmes de base 2, ou **logarithmes décimaux**, ie de base 10).

La relation circulaire classique $\log_a c = (\log_a b)(\log_b c)$ permet de passer d'une définition à une autre.

(xii) En **Statistique**, soit $(\Omega, \mathcal{F}, (P_\theta)_{\theta \in \Theta})$ un **modèle paramétrique** et $\xi : \Omega \mapsto \mathbf{R}^K$ un **vecteur aléatoire** réel de loi $P_\theta^\xi = \xi(P_\theta)$. On suppose que P_θ^ξ admet une **densité** f_θ ou $f(\cdot, \theta)$ pr à la **mesure de LEBESGUE** λ_K définie sur $\mathcal{B}(\mathbf{R}^K)$ et l'on note F_θ sa **fr**.

On appelle **entropie de (la loi de) ξ** le nombre réel (s'il existe) :

$$(5) \quad H_\theta(\xi) = E \text{Log} (1 / f(\xi, \theta)) = \int f(x, \theta) \text{Log} (1 / f(x, \theta)) d\lambda_K(x),$$

qui est l'**espérance** de la va $\eta : \Omega \mapsto \mathbf{R}$ définie par $\eta = \text{Log} (1 / f(\xi, \theta))$. On a donc $H_\theta(\xi) = - E_\theta \text{Log} f(\xi, \theta)$.

On peut aussi écrire :

$$(6) \quad H_{\theta}(\xi) = \int \text{Log}(1/f(x, \theta)) dF(x) = \int (1/f(x, \theta))^{-1} \text{Log}(1/f(x, \theta)) d\lambda_{\kappa}(x)$$

(entropie de la fr ou de la densité).

Comme précédemment, on note aussi, selon le cas, $H(P_{\theta}^{\xi})$, ou $H(f_{\theta})$ ou encore $H(F_{\theta})$.

(xiii) De nombreuses **procédures statistiques** (construction de **modèles**, **sélection de modèles**) font usage d'un **principe d'entropie maximum**, en particulier en **théorie bayésienne**.

Le concept d'entropie se retrouve aussi dans celles d'**entropie d'une partition**, d'**entropie d'un recouvrement**, d'**entropie relative** ou d'**information**.