

## DISCRÉTISATION (C2, C5, C10)

(29 / 04 / 2020, © Monfort, Dicostat2005, 2005-2020)

La **discrétisation** d'une **loi de probabilité** (resp de sa **densité**) consiste à la transformer en une **loi discrète** (resp en une densité discrète). La loi initiale est souvent de type « continu » (cf **loi absolument continue**, **variable continue**). Il existe deux définitions usuelles.

(i) **Première définition.** Soit  $(\Omega, \mathcal{F}, P)$  un **espace probabilisé** et  $\xi : \Omega \mapsto \mathbf{R}$  une **vars** dont la loi  $P^\xi$  est supposée absolument continue pr à la **mesure de LEBESGUE**  $\lambda$  et dont la densité (**dérivée de NIKODYM-RADON**) est  $f$  :

$$(1) \quad f = d P^\xi / d\lambda.$$

Soit  $D \subset \mathbf{R}$  une **partie discrète** (ie au plus dénombrable) de  $\mathbf{R}$  (en général,  $D \subseteq \mathbf{N}$  ou  $D \subseteq \mathbf{Z}$ , inclusions au sens large). On pose (**restriction** de  $f$  à  $D$ ) :

$$(2) \quad f^* = f|_D.$$

On appelle alors :

(a) **(densité) discrétisée** de  $f$  la fonction  $f_d : D \mapsto \mathbf{R}_+$  définie par :

$$(3) \quad f_d = f^* / \sum_{x \in D} f^*(x).$$

L'application  $f \mapsto f_d$  est appelée **discrétisation** de  $f$ . On dit aussi que  $f^*$  est la **discrétisée** de  $f$  et  $f_d$  la **discrétisée « normée »** de  $f$ .

La discrétisée  $f_d$  de  $f$  est donc une répartition de masses probabiliste qui vérifie les propriétés usuelles :

$$(4) \quad \begin{aligned} f_d &\geq 0 \text{ (positivité),} \\ \sum_{x \in D} f_d(x) &= 1 \text{ (normalisation).} \end{aligned}$$

C'est donc une densité pr à la **mesure de comptage**  $\nu : \mathcal{P}(D) \mapsto \mathbf{N}$  définie par :

$$(5) \quad \nu(B) = \sum_{x \in D} \delta_x(B), \quad \forall B \in \mathcal{P}(D).$$

où  $\delta_x$  désigne la **loi de DIRAC** placée au point  $x$ .

(b) **(loi de probabilité) discrétisée** de  $P^\xi$  la loi  $P_d^\xi$  définie par :

$$(6) \quad P_d^\xi = \sum_{x \in D} f_d(x) \delta_x.$$

L'application  $P^\xi \mapsto P_d^\xi$  est appelée **discrétisation** de  $P^\xi$ , ou encore discrétisation sur  $\mathcal{D}^\xi$  si l'on considère une famille  $\mathcal{D}^\xi$  de lois tq  $P^\xi$ . La va  $\xi_d : \Omega \mapsto D$ , dont la loi est  $P_d^\xi$ , est dite **(variable) discrétisée** de  $\xi$ .

On peut écrire :

$$(7) \quad \xi_d = \mathbf{1}_A \cdot \xi, \quad \text{où } A = \xi^{-1}(D) \in \mathcal{F}.$$

(ii) La définition précédente s'étend directement à un **vecteur aléatoire** (ie à une va multidimensionnelle) réelle  $\xi : \Omega \mapsto \mathbf{R}^K$ .

Dans le cas général, si  $(E, \mathcal{A})$  et  $(F, \mathcal{B})$  sont des **espaces mesurables**,  $\mu$  une **mesure abstraite** positive finie sur  $\mathcal{A}$ ,  $\xi : E \mapsto F$  une application  $(\mathcal{A}, \mathcal{B})$ -mesurable,  $\mu^\xi$  l'image de  $\mu$  par  $\xi$ , supposée absolument continue pr à une **mesure positive**  $\nu$  définie sur  $\mathcal{B}$ , et  $D$  une partie (au plus) dénombrable de  $F$ , la discrétisation de  $f = d\mu^\xi / d\nu$ ,  $\xi$  et  $\mu^\xi$  peut s'effectuer en quatre étapes selon le même procédé :

$$(8) \quad \begin{aligned} f^* &= f|_D, \\ f_d &= f^* / \sum_{x \in D} f^*(x) && \text{(discrétisée normée de } f), \\ \mu_d^\xi &= \sum_{x \in D} f_d(x) \delta_x && \text{(discrétisée de } \mu^\xi), \\ \xi_d &= \mathbf{1}_A \xi : \Omega \mapsto D && \text{(discrétisée de } \xi, \text{ avec } A = \xi^{-1}(D) \in \mathcal{A}). \end{aligned}$$

(iii) **Seconde définition.** On appelle ici **discrétisation** une transformation définie comme suit. Soit  $(\Omega, \mathcal{F}, P)$  un **espace probabilisé**,  $\xi : \Omega \mapsto \mathbf{R}$  une **vars** (eg discrète ou continue) de loi  $P^\xi$  et  $\Pi_{\mathbf{R}} = (I_k)_{k=1, \dots, K}$  une **partition** finie de  $\mathbf{R}$ , avec (cf aussi **histogramme**) :

$$(12) \quad \begin{aligned} I_1 &= ]-\infty, a_1[, \\ I_k &= [a_{k-1}, a_k[, \quad \forall k = 2, \dots, K-1, \\ I_K &= [a_K, +\infty[. \end{aligned}$$

On appelle alors **discrétisée** de  $\xi$  la **variable qualitative**  $\eta : \Omega \mapsto \Pi_{\mathbf{R}}$  associée à  $\xi$  selon :

$$(13) \quad \eta(\omega) = I_k, \quad \forall \omega \in \Omega \text{ tq } \xi(\omega) \in I_k, \quad \forall k \in N_K^*.$$

Autrement dit,  $\eta$  prend la « valeur » (ie la **modalité**)  $I_k$  lorsque  $\xi$  prend l'une des valeurs  $x_k \in I_k$ .

On écrit encore :

$$(14) \quad [\eta = I_k] \Rightarrow [\xi \in I_k], \quad \forall k \in \mathbf{N}_K^*.$$

La loi  $P^\eta$  de  $\eta$ , définie selon :

$$(15) \quad P^\eta(I_k) = P([\xi \in I_k]) = \int \mathbf{1}(I_k) dP, \quad \forall k \in \mathbf{N}_K^*,$$

est aussi dite **(loi) discrétisée** de  $P^\xi$ . C'est donc une **loi qualitative**.

(iv) La définition précédente s'étend :

(a) à des partitions dénombrables de  $\mathbf{R}$  ;

(b) à des partitions de  $\mathbf{R}^K$  (avec  $K > 1$ ).

Un tel procédé permet de définir une **variable qualitative** à partir d'une **variable quantitative** (cf aussi **classification**).