

## MODÈLE DE COX (F8, J8, N)

(08 / 06 / 2020, © Monfort, Dicostat2005, 2005-2020)

Le **modèle de COX** se relie à l'étude des **durées de vie** (ou de survie) d'**unités statistiques** sujettes à une **fin de vie** ou à une **disparition** eg : par désagrégation ou fin de fonctionnement (pannes ou « défaillances » d'unités physiques, décès d'unités biologiques), par transformation (d'unités sociologiques), etc.

(i) Soit  $(\Omega, \mathcal{F}, \mathcal{P})$  un **modèle statistique** de base,  $(\mathcal{Z}, \mathcal{G})$  un **espace mesurable** auxiliaire et  $(\tau, \zeta) : \Omega \mapsto \mathbf{R}_+ \times \mathcal{Z}$  un **couple aléatoire** dans lequel  $\tau$  représente le « **temps** » (cf **durée de vie**) et  $\zeta$  une **variable exogène** appelée **variable concomitante** ».

On suppose que la **loi conditionnelle** de  $\tau$  pr à  $\zeta$  possède une fonction de **taux d'échec**  $r : \mathbf{R}_+ \mapsto \mathbf{R}_+$  de la forme :

$$(1) \quad r(t/z) = r_0(t) \cdot w(z, b), \quad \forall b \in \mathbf{R}^Q,$$

dans laquelle  $r_0(t)$  est un **hasard de référence** (calculé lorsque  $t = 0$ ) et  $w(z, b)$  un **facteur de risque** relatif tq  $w(t, 0) = 1$ . Le **paramètre d'intérêt** est alors  $b$ .

On appelle alors **modèle à hasard proportionnel de D.R. COX**, ou **modèle à taux d'échec proportionnel de D.R. COX**, le modèle défini par l'équation (1).

Lorsque  $b = 0$ ,  $z$  n'exerce aucun effet sur le hasard  $r$  (cf aussi **hasard, fonction de hasard**).

Lorsque  $\zeta$  est un vecteur de **vars** exogènes  $\zeta_1, \dots, \zeta_L$  et que  $Q = L$ , alors :

(a) si  $w(z, b) = v(z' b)$  (ie ne dépend que du **produit scalaire**), on définit le **modèle de D.R. COX linéaire** ;

(b) si, de plus,  $\text{Log } v(z' b) = z' b$ , on obtient le modèle de COX original.

(ii) Etant donné un **ensemble** (eg **échantillon**)  $A$  ( $\text{Card } A = N > L$ ) d'unités statistiques  $a_n$  (où  $n \in N_N^*$ ), on observe les instants (aléatoires) de disparition  $t_n$  de ces unités, ainsi que les valeurs  $z_n$  correspondantes de  $\zeta$ . On suppose que ces instants sont ordonnés selon  $t_1 < \dots < t_N$  et l'on note  $Z_n$  la  $n$ -ième **observation** de  $\zeta$  (ie celle effectuée sur  $a_n$ ).

On appelle **ensemble à risque** à l'instant  $t_n$  l'ensemble  $R_n$  des unités  $a_n$  qui survivent jusqu'en  $t_n$ . Le couple  $(t_n, Z_n)$  est donc l'observation de  $(\tau, \zeta)$  associée à l'unité  $a_n$  qui risque de disparaître à l'instant  $t_n$ . La variable  $\tau$  « censure » ainsi la variable  $\zeta$ , laquelle est observée selon  $Z_n$  tant que  $t < t_n$  (cf **censure**). On note enfin  $p_n(z)$  la **proportion** des unités  $a_n \in R_n$  pour lesquelles on observe  $\zeta$  et  $Z(n)$  l'ensemble des valeurs  $Z_n$  des unités  $a_n \in R_n$ .

Pour estimer  $b$ , la **méthode du maximum de vraisemblance**, adaptée au cadre précédent, conduit à définir la **vraisemblance** conditionnelle de  $b$  (pr aux instants de disparition antérieurs) selon (contribution de  $R_n$ ) :

$$(2) \quad L_n(Z_n, b) = p_n(Z_n) \cdot w(Z_n, b) / \prod_{z \in Z(n)} p_n(z) w(z, b), \quad \forall n \in \mathbb{N}^*.$$

On appelle (**fonction de**) **vraisemblance « partielle »** (ie pr à  $b$ ) du modèle le produit des vraisemblances précédentes, ie :

$$(3) \quad L(Z, b) = \prod_{n=1}^N L_n(Z_n, b).$$

L'estimateur  $b^\#$  recherché est alors solution du problème de **programmation mathématique** :

$$(4) \quad \max_{b \in \mathbb{R}^Q} L(Z, b) \quad (\text{où } \mathbb{R}^Q \text{ désigne } \mathbf{R}^Q).$$

Ainsi, dans le cas eg du modèle original, on peut écrire :

$$(5) \quad L_n(Z_n, b) = r(t, Z_n) / \prod_{\{n: a(n) \in R_n\}} r(t, Z_n) = Z_n' b / \prod_{\{n: a(n) \in R_n\}} Z_n' b.$$

et :

$$(6) \quad L(Z, b) = \prod_{\{n: n \in D_n\}} L_n(Z_n, b),$$

où  $D_n$  (aussi noté  $D_n$ ) désigne l'ensemble des unités décédées à l'instant  $t_n$  et  $R_n$  désigne  $R_n$ .