

## TRANSFORMATION DE BOX - COX (C2, K2)

(21 / 09 / 2020, © Monfort, Dicostat2005, 2005-2020)

La **transformation de BOX - COX** est, en réalité, une **famille** de transformations à un « **paramètre** », souvent utilisée pour la **transformation des données**.

(i) Cette **famille**, indexée par un paramètre  $\lambda \in \mathbf{R}$ , est définie selon :

$$(1) \quad \beta_\lambda : u \mapsto u_\lambda = \lambda^{-1} (u^\lambda - 1), \quad \forall u \in \mathbf{R}_+^*.$$

Par continuité, on a :

$$(2) \quad \beta_0 : u \mapsto u_0 = \text{Log } u, \quad \forall u \in \mathbf{R}_+^*.$$

(ii) Cette **transformation de G.E.P. BOX - D.R. COX** permet eg :

(a) d'obtenir un **modèle de régression** dont les **perturbations** sont indépendantes et gaussiennes. Ainsi, si  $\eta = \xi' b + \varepsilon$  est un **modèle de régression linéaire** multiple défini dans un **espace de variables**  $(\xi, \eta)$  et observé dans un **espace d'observation**  $(X, y)$  selon  $y = X b + u$ , avec  $u = (u_1, \dots, u_N)$ , on peut rechercher le paramètre de la transformation pour lequel les perturbations  $u$  sont des **copies** indépendantes d'une **variable parente** dont la **loi** est  $\mathcal{N}(0, 1)$  (**loi normale réduite**) ;

(b) de simplifier un modèle de **régression non linéaire**. Ainsi, le modèle  $\eta = f(\xi, b) + \varepsilon$  peut être transformé selon :

$$(3) \quad \lambda^{-1} (\eta^\lambda - 1) = f \{ \mu_1^{-1} (\xi^{\mu(1)} - 1), \dots, \mu_K^{-1} (\xi^{\mu(K)} - 1), b \} + \varepsilon.$$

Par suite, un choix approprié des paramètres  $\lambda, \mu_1, \dots, \mu_K$  peut conduire à une **forme** plus simple, eg :

$$(4) \quad \eta_\lambda = \varphi (\xi_{1,\mu(1)}, \dots, \xi_{K,\mu(K)})' \psi (b) + \varepsilon \quad (\text{modèle à « forme séparée »),$$

dans laquelle, par commodité,  $\mu(K)$  désigne  $\mu_K$ . Ceci peut conduire à des fonctions  $\varphi$  ou  $\psi$  plus simples : eg lorsque  $\psi$  est quasiment linéaire au voisinage de la **vraie valeur**  $b^*$  de  $b$ .

(iii) Une version plus générale de la transformation (1) contient deux paramètres :

$$(1) \quad \beta_{\alpha\lambda} : u \mapsto u_{\alpha\lambda} = \lambda^{-1} \{(u - \alpha)^\lambda - 1\}, \quad \forall u > \alpha.$$

Lorsque  $\lambda \rightarrow 0+$ , on obtient, par continuité :

$$(2)' \quad \beta_{\alpha 0} : u \mapsto u_{\alpha 0} = \text{Log } (u - \alpha), \quad \forall u > \alpha.$$

(iv) Les transformations de BOX - COX peuvent remplacer un **modèle statistique** dans un **contexte** « standard ». Ainsi, lorsque le **modèle de régression multiple** linéaire  $y = X b + u$  ne vérifie pas les hypothèses usuelles :

$$(3) \quad E u = 0, \quad V u = \sigma_u^2 \cdot I_N,$$

des transformations analogues à celles de l'exemple (ii)<sub>(b)</sub> ci-dessus peuvent conduire à un modèle transformé tq :

$$(4) \quad \eta(\lambda) = \sum_{k=1}^K b_k \cdot x_k(\mu_k) + v,$$

en sorte que (hypothèses à tester) (cf **test préliminaire**) :

$$(3)' \quad E v = 0, \quad V v = \sigma_v^2 \cdot I_N.$$

Par suite, le modèle (4) nécessite l'estimation des  $3 + K$  paramètres ( $b, \sigma_v^2, \lambda, \mu_1, \dots, \mu_K$ ) : la **méthode du maximum de vraisemblance** peut alors permettre de résoudre le problème initial.

Il en va de même, dans certains cas, lorsque le vecteur  $u$  des perturbations n'est pas gaussien, ie  $P^u \neq \mathcal{N}_N(0, \sigma_u^2 \cdot I_N)$ . Une transformation tq l'une des précédentes peut permettre d'obtenir  $P^v = \mathcal{N}_N(0, \sigma_v^2 \cdot I_N)$ . On l'appelle parfois **transformation « normalisante »**.