

CONTRAİNTE SUR LES VARIABLES, SUR LES OBSERVATIONS (J)

(04 / 08 / 2020, © Monfort, Dicostat2005, 2005-2020)

Un **modèle statistique** peut comporter des **variables** sujettes à diverses **contraintes** : ces variables ne peuvent parcourir entièrement leur **espace de variables**.

Ceci est eg le cas d'un modèle comportant des **variables endogènes** et des **variables exogènes**.

(i) On considère un **modèle image** $(\mathcal{X}, \mathcal{B}, \mathcal{P}^{\mathcal{X}})$ et un **espace mesurable** auxiliaire $(\mathcal{S}, \mathcal{C})$. La **variable d'intérêt** (ou **statistique** d'intérêt) est ici X . S'il existe une **application mesurable** $\phi : \mathcal{X} \mapsto \mathcal{S}$ et une valeur $s \in \mathcal{S}$ telles que $\phi(X) = s$, on dit que la va X est liée par la **contrainte** ϕ . Souvent, $(\mathcal{S}, \mathcal{C}) = (\mathcal{X}, \mathcal{B})$.

La contrainte ϕ peut notamment être vectorielle si les espaces précédents sont dotés d'une structure d'**espace vectoriel**.

Si X est un N -**échantillon** (X_1, \dots, X_N) , cette contrainte induit une contrainte sur les coordonnées X_n , ie sur les **observations** (cf **contrainte sur les observations**).

(ii) L'approche s'étend directement à un **modèle produit** $(\mathcal{X} \times \mathcal{Y}, \mathcal{B} \otimes \mathcal{C}, \mathcal{P}^{\mathcal{X}} \otimes \mathcal{P}^{\mathcal{Y}})$, la contrainte étant définie par une application $\phi : \mathcal{X} \times \mathcal{Y} \mapsto \mathcal{S}$ et une valeur $s \in \mathcal{S}$ tq $\phi(X, Y) = s$.

(iii) On considère un **modèle de régression multidimensionnel** linéaire exprimé dans l'espace des variables $(\xi_1 \dots \xi_1, \eta_1 \dots \eta_G)$:

$$(1) \quad \begin{aligned} \eta_1 &= \xi_1' b_1 + \varepsilon_1', \\ &\dots \\ \eta_G &= \xi_G' b_G + \varepsilon_G', \end{aligned}$$

écrit sous forme condensée :

$$(1)' \quad \eta' = \xi' B + \varepsilon', \quad \text{avec } B = [b_1, \dots, b_G] \in M_{KG}(\mathbf{R}),$$

et satisfaisant à des hypothèses standards :

$$(2) \quad E \varepsilon = 0, \quad V \varepsilon = \Sigma.$$

On suppose ce modèle « observé » dans l'**espace des observations** (X, Y) selon :

$$(3) \quad Y_n' = X_n' B + U_n', \quad \forall n \in N_N^*,$$

où les variables Y_n' sont sans **corrélacion** entre elles.

On appelle **contrainte** (linéaire) **sur les variables endogènes** η la donnée de **matrices** C_y et C_x tq :

$$(4) \quad \eta' C_y = \xi' C_x .$$

On montre que l'**estimateur des mco** de B et celui de Σ sont identiques à ceux des mco du modèle (1) sans les contraintes (4), ie :

$$(5) \quad B^{\wedge} = (X' X)^{-1} X' Y ,$$

ces matrices étant tq (les X_n et Y_n en étant les vecteurs lignes) :

$$X = [X_1 : X_n : X_N] \in M_{NK}(\mathbf{R}),$$

$$Y = [Y_1 : Y_n : Y_N] \in M_{NG}(\mathbf{R}),$$

et :

$$(6) \quad \Sigma^{\wedge} = N^{-1} \cdot U^{\wedge} ' U^{\wedge}, \quad \text{avec } U^{\wedge} = Y - X B^{\wedge} \text{ et } \text{rg } \Sigma^{\wedge} = G.$$

On en déduit un **estimateur sans biais** $\Sigma^{\sim} = N(N-1)^{-1} \Sigma^{\wedge}$ de Σ .

La **contrainte** (4) porte ici à la fois sur les variables endogènes et sur les variables exogènes.

Il existe des situations dans lesquelles elle ne porte que sur les endogènes : eg **équation de partage**, ou **équation de répartition** (dans laquelle les va endogènes η_g sont contraintes à un total égal à 1) (cf **estimateur par règle de trois**).

(iii) Les contraintes sur les variables engendrent, ipso facto, des **contraintes sur les observations** de ces variables.

(iv) Dans certaines **situations statistiques**, seules certaines observations sont contraintes : eg condition de **signe**, **censure**, existence de **frontières**, etc.

Dans ces cas, une contrainte sur une variable implique une contrainte sur l'une de ses observations, et vice versa (cf **contrainte sur les observations**).