

## MODÈLE D'INTERDÉPENDANCE LINÉAIRE (J1)

(19 / 12 / 2019, © Monfort, Dicostat2005, 2005-2019))

Le modèle d'interdépendance linéaire est le **modèle d'interdépendance** le plus simple. Dans certains cas, on peut le considérer comme un modèle d'interdépendance « linéarisé », ie comme une **approximation** du modèle d'interdépendance général (ie non linéaire) (cf **modèle linéarisé**). C'est aussi un instrument de base de l'analyse statistique multidimensionnelle (cf **analyse multidimensionnelle**). Il concerne des variables vectorielles, généralement réelles.

(i) Soit  $\xi = (\xi_1, \dots, \xi_K)$  une liste constituée de K **variables exogènes** (scalaires réelles) et  $\eta = (\eta_1, \dots, \eta_G)$  une liste constituée de G **variables endogènes** de même type (ie numériques).

On appelle **modèle d'interdépendance linéaire**, ou **modèle à équations simultanées linéaire**, ou encore **modèle linéaire à équations interdépendantes**, ou **système aléatoire linéaire**, un ensemble de relations linéaires (pr aux paramètres) qui relie  $\eta$  à  $\xi$ .

Ces relations sont souvent données sous la **forme implicite** suivante, dite **forme structurelle** du modèle, exprimée dans  $\mathcal{X}$ ,  $\mathcal{Y} = \mathbf{R}^G \times \mathbf{R}^K$ , ie l'**espace des variables** ( $\eta, \xi$ ) :

$$(1) \quad \begin{aligned} b_{11} \eta_1 + \dots + b_{1G} \eta_G + c_{11} \xi_1 + \dots + c_{1K} \xi_K &= \varepsilon_1, \\ b_{G1} \eta_1 + \dots + b_{GG} \eta_G + c_{G1} \xi_1 + \dots + c_{GK} \xi_K &= \varepsilon_G, \end{aligned}$$

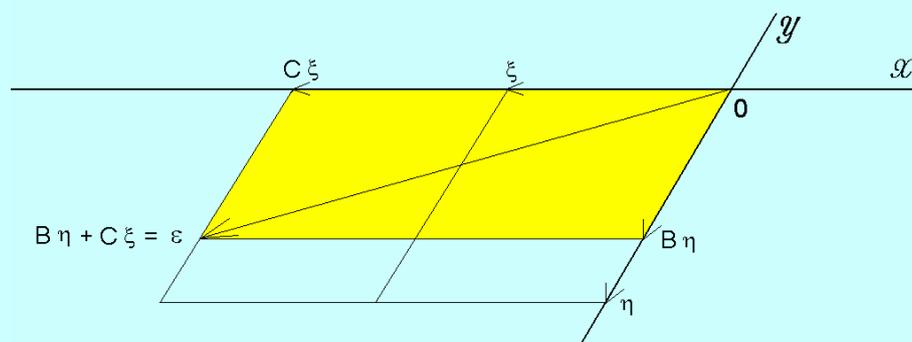
ie, sous forme matricielle (ou sous forme d'opérateurs) :

$$(2) \quad B \eta + C \xi = \varepsilon,$$

dans laquelle  $B \in M_G(\mathbf{R})$ ,  $C \in M_{GK}(\mathbf{R})$  et  $\varepsilon$  est un **vecteur aléatoire** (**perturbation aléatoire** sur l'équation) à valeurs dans  $\mathbf{R}^G$  (cf schéma formel ci-après).

représentation schématique d'un modèle d'interdépendance linéaire

dans l'espace  $\mathcal{X} \times \mathcal{Y}$  des valeurs des variables ( $\xi, \eta$ )



D'autres présentations du même modèle sont les suivantes :

$$(3) \quad B \eta + C \xi + \varepsilon = 0, \quad \text{où } 0 \in \mathbf{R}^G,$$

$$(4) \quad A \zeta = \varepsilon,$$

ou encore :

$$(5) \quad A \zeta + \varepsilon = 0,$$

avec  $A = [B, C]$  (matrice constituée des « **blocs** » B et C) et  $\zeta = (\eta \parallel \xi)$  (vecteur « colonne » constitué des « blocs » ou « listes » des variables).

(ii) L'observation d'un nombre (fini) N de **copies** de  $(\eta, \xi)$ , ie des **va**  $(X_n, Y_n)$ ,  $n = 1, \dots, N$ , définit un couple  $(X, Y)$  constitué des **matrices d'observation**  $X = (x_{nk})_{(n,k)} \in M_{NK}(\mathbf{R})$  et  $Y = (y_{ng})_{(n,g)} \in M_{NG}(\mathbf{R})$  dont les lignes resp sont  $X_n$  et  $Y_n$ .

Pour la n-ième observation  $(X_n, Y_n)$  de  $(\eta, \xi)$  le modèle (1) est alors « observé » selon :

$$(6) \quad B Y_n' + C X_n' = U_n',$$

où,  $\forall n \in N_N^*$ ,  $U_n$  est la n-ième ligne de la  $(N,G)$ -matrice U des perturbations (inobservables) :

$$(7) \quad U_n = (u_{n1}, \dots, u_{nG}), \quad \forall n \in N_N^*.$$

De façon analogue, les représentations (3), (4) et (5) deviennent resp :

$$(8) \quad B Y_n' + C X_n' + U_n' = 0,$$

$$(9) \quad A Z_n' = U_n',$$

et :

$$(10) \quad A Z_n' + U_n' = 0.$$

Une représentation condensée du modèle linéaire peut alors, avec des notations évidentes, prendre l'une des formes suivantes :

$$(11) \quad B Y' + C X' = U', \quad B Y' + C X' + U' = 0,$$

ou l'une des formes suivantes :

$$(12) \quad A Z' = U', \quad A Z' + U' = 0.$$

(iii) On rencontre aussi les formes transposées des précédentes.

(iv) En particulier, un modèle linéaire est un **modèle récursif** (H. WOLD) ssi  $B \in T_G^+(\mathbf{R})$  est une **matrice triangulaire** supérieure, ou ssi  $B \in T_G^-(\mathbf{R})$  est une matrice triangulaire inférieure.

Le modèle (1), dans lequel il existe autant de variables endogènes que d'équations est appelé **modèle d'interdépendance complet** (cf **modèle complet**). Si l'on multiplie (2) par une **matrice régulière**  $R$ , on obtient un modèle équivalent au premier. Poser (2) revient implicitement à se placer dans la classe d'équivalence des modèles transformés de (2) par des matrices tq  $R$ .

On appelle **règle de normalisation** la règle (nécessité logique et pratique) qui consiste à poser :

$$(13) \quad b_{gg} = 1, \quad \forall g \in N_G^*.$$

Cette convention de normalisation, généralement implicite, revient (à une permutation près) à prémultiplier (2) par la  $(G,G)$ -**matrice diagonale** :

$$(14) \quad D = (d_{gh})_{(g,h)}, \quad \text{où } d_{gh} = \delta_{gh} / b_{gh} \quad (\text{avec } b_{gh} \neq 0 \text{ si } h = g).$$

Autrement dit, dans chaque équation  $g$ , la variable  $y_g$  se voit affecter un **coefficient**  $b_{gg} = 1$ . En pratique,  $y_g$  est souvent écrite à gauche de l'équation (avec ce coefficient muet), les autres variables (endogènes et exogènes) étant écrites à droite de cette même équation.

(v) La **forme réduite** du modèle d'interdépendance d'explicite selon :

$$(15) \quad \eta = A \xi + \varphi, \quad \text{avec } A = -B^{-1}C \text{ et } \varphi = B^{-1}\varepsilon,$$

ce qui suppose que  $B \in R_G(\mathbf{R})$  (**matrice régulière**). Autrement dit, la forme réduite exprime l'ensemble des variables endogènes en fonction (ici linéaire) de l'ensemble des variables exogènes (cf aussi **régression**).

(vi) Dans l'étude du modèle linéaire précédent (sous forme structurelle ou sous forme réduite), certaines hypothèses sont souvent faites :

(a) le vecteur  $\xi$  des exogènes est observé sans **erreur** ;

(b) le vecteur  $\varepsilon$  des perturbations est en **moyenne** nul ( $E \varepsilon = 0$ ) ;

(c) la **loi de probabilité** de  $U_n'$  ne dépend pas de  $X_n'$ , ni des vecteurs  $X_\alpha'$ ,  $\forall \alpha < n$  ;

(d) les **intercovariances** sont nulles, ie :

$$(16) \quad C(U_\alpha', U_\beta') = E U_\alpha' U_\beta' = 0 \in M_G(\mathbf{R});$$

(e) la matrice des **intracovariances**, ie  $V \varepsilon = E \varepsilon \varepsilon' = \Sigma$ , ne dépend pas des observations  $n \in N_N^*$  ;

(f) les **convergences en probabilité** suivantes sont vérifiées :

$$(17) \quad \bar{X}_N = N^{-1} \sum_{n=1}^N X_n' \rightarrow_{N \rightarrow +\infty} \mu \in \mathbf{R}^K,$$

$$S_N^2 = N^{-1} \sum_{n=1}^N (X_n - \bar{X}_N) (X_n - \bar{X}_N)' \rightarrow_{N \rightarrow +\infty} M_{xx} \in S_K(\mathbf{R});$$

(g) les perturbations sont normales, ie :

$$(18) \quad \varepsilon \sim \mathcal{N}_G(0, \Sigma) \text{ (loi normale multidimensionnelle centrée).}$$

Cette dernière hypothèse est utilisée pour mettre en oeuvre des méthodes d'estimation (eg la **méthode du mv**) ou des **tests d'hypothèses**.

Dans les cas les plus simples, et compte tenu de certaines des hypothèses précédentes, on peut estimer la forme réduite  $Y_n' = A X_n' + U_n'$  à l'aide d'une **méthode de moindres carrés** (cf **méthode des moindres carrés indirects**).

(vii) Le formalisme de type implicite (1) ou (2) est souvent adopté dans des **sciences** (eg sociologie : économie) où l'**homme de l'art** définit les équations « scalaires » une à une : eg équation de comportement d'agents économiques, équations de type « identité », équations de type réglementaire (barèmes), etc.

Dans les formalismes impliquant des notions d'influence ou de **causalité**, le modèle d'interdépendance peut aussi s'écrire sous forme explicite (à perturbation additive) :

$$(19) \quad \eta = D \xi + \varepsilon,$$

dans laquelle on exprime les endogènes  $\eta$  en fonction des exogènes  $\xi$  de façon globale.

Cette équation vectorielle (dans l'espace des variables) s'écrit alors dans l'espace  $\mathbf{R}^N$  des observations (cf **régressions multiples**) :

$$(20) \quad Y_n' = C X_n' + U_n', \quad \forall n \in N_N^*.$$