

Les modèles d'équations structurelles à variables latentes

Cours de Statistique Multivariée Approfondie

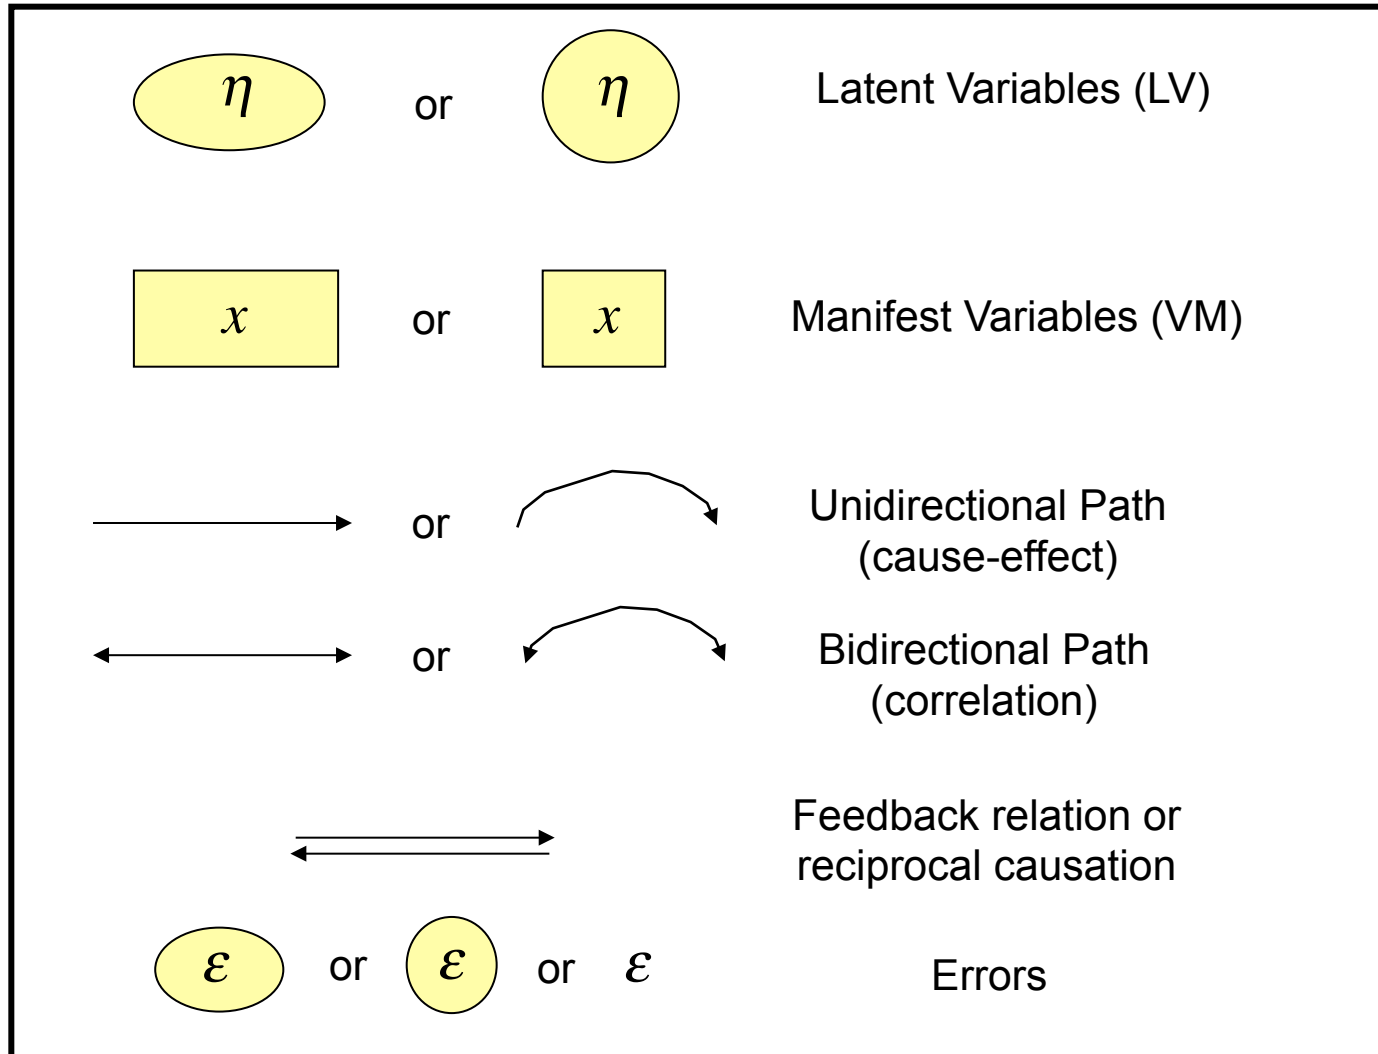
giorgio.russolillo@cnam.fr

le **cnam**

Modèles d'équations structurelles à variables latentes

- Les modèles d'équation structurelles ou SEM permettent de quantifier des **relations de cause à effet** décrites par un modèle théorique
- L'intérêt se concentre sur les **variables latentes** (non observables par une voie directe): les variables psychologiques abstraits comme «intelligence», «satisfaction», «statut social», «capacité», «confiance»
- Les variables latentes sont mesurées par des **indicateurs observables** appelés **variables manifestes**.
- Les modèles d'équations structurelles font le pont entre l'analyse de **régression**, l'analyse utilisant des graphes (**path analysis**) et l'**analyse factorielle**

SEM: conventions de dessin

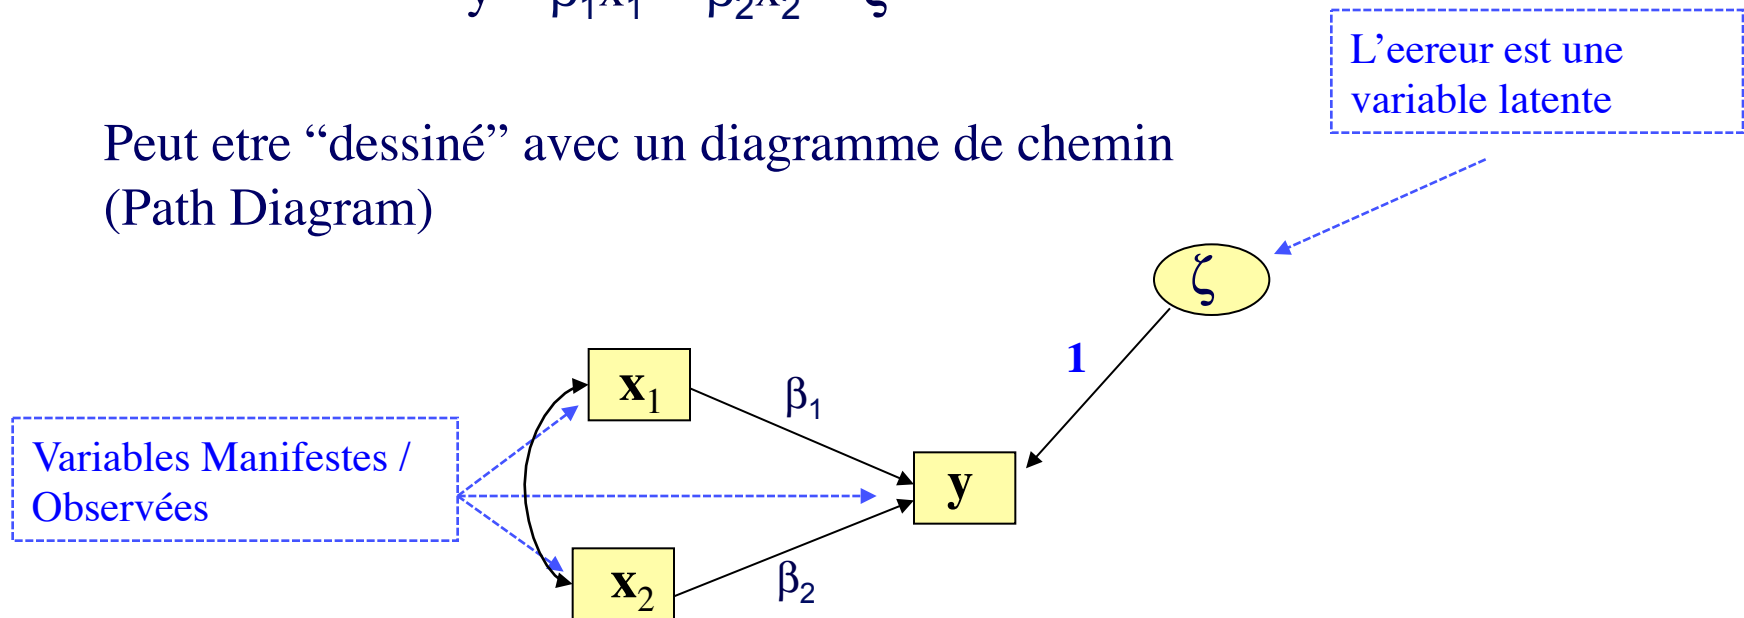


"Dessin" d'un modèle de régression

Ce modèle de régression multiple

$$y = \beta_1 x_1 + \beta_2 x_2 + \zeta$$

Peut être "dessiné" avec un diagramme de chemin
(Path Diagram)




Modèles de chemin avec des variables manifestes

Le modèle de régression multiple peut être généralisée à des chemins où les variables endogènes sont à leur fois causes d'autres variables endogènes.

$$y_1 = \gamma_{11} x_1 + \zeta_1$$

$$y_2 = \beta_{21} y_1 + \zeta_2$$



$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} \quad \Gamma = \begin{bmatrix} \gamma_{11} \\ 0 \end{bmatrix} \quad \mathbf{x} = [x_1] \quad \mathbf{B} = \begin{bmatrix} 0 & 0 \\ \beta_{21} & 0 \end{bmatrix} \quad \boldsymbol{\zeta} = \begin{bmatrix} \zeta_1 \\ \zeta_2 \end{bmatrix}$$


$$\mathbf{y} = \Gamma \mathbf{x} + \mathbf{B} \mathbf{y} + \boldsymbol{\zeta}$$

Modèle factoriel

$$x_1 = \lambda_{11} \xi_1 + \delta_1$$

$$x_2 = \lambda_{21} \xi_1 + \delta_2$$

$$x_3 = \lambda_{31} \xi_1 + \delta_3$$



$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix}$$

$$\Lambda_x = \begin{bmatrix} \lambda_{11} \\ \lambda_{21} \\ \lambda_{31} \end{bmatrix}$$

$$\boldsymbol{\xi} = [\xi_1]$$

$$\boldsymbol{\delta} = \begin{bmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \end{bmatrix}$$

$$\mathbf{x} = \Lambda_x \boldsymbol{\xi} + \boldsymbol{\delta}$$

Modèle factoriel multiple

$$x_1 = \lambda_{11} \xi_1 + \delta_1 ,$$


$$x_2 = \lambda_{21} \xi_1 + \lambda_{22} \xi_2 + \delta_2$$

$$x_3 = \lambda_{31} \xi_1 + \delta_3$$

$$x_4 = \lambda_{42} \xi_2 + \delta_4$$

$$x_5 = \lambda_{52} \xi_2 + \delta_5$$

$$x_6 = \lambda_{62} \xi_2 + \delta_6$$



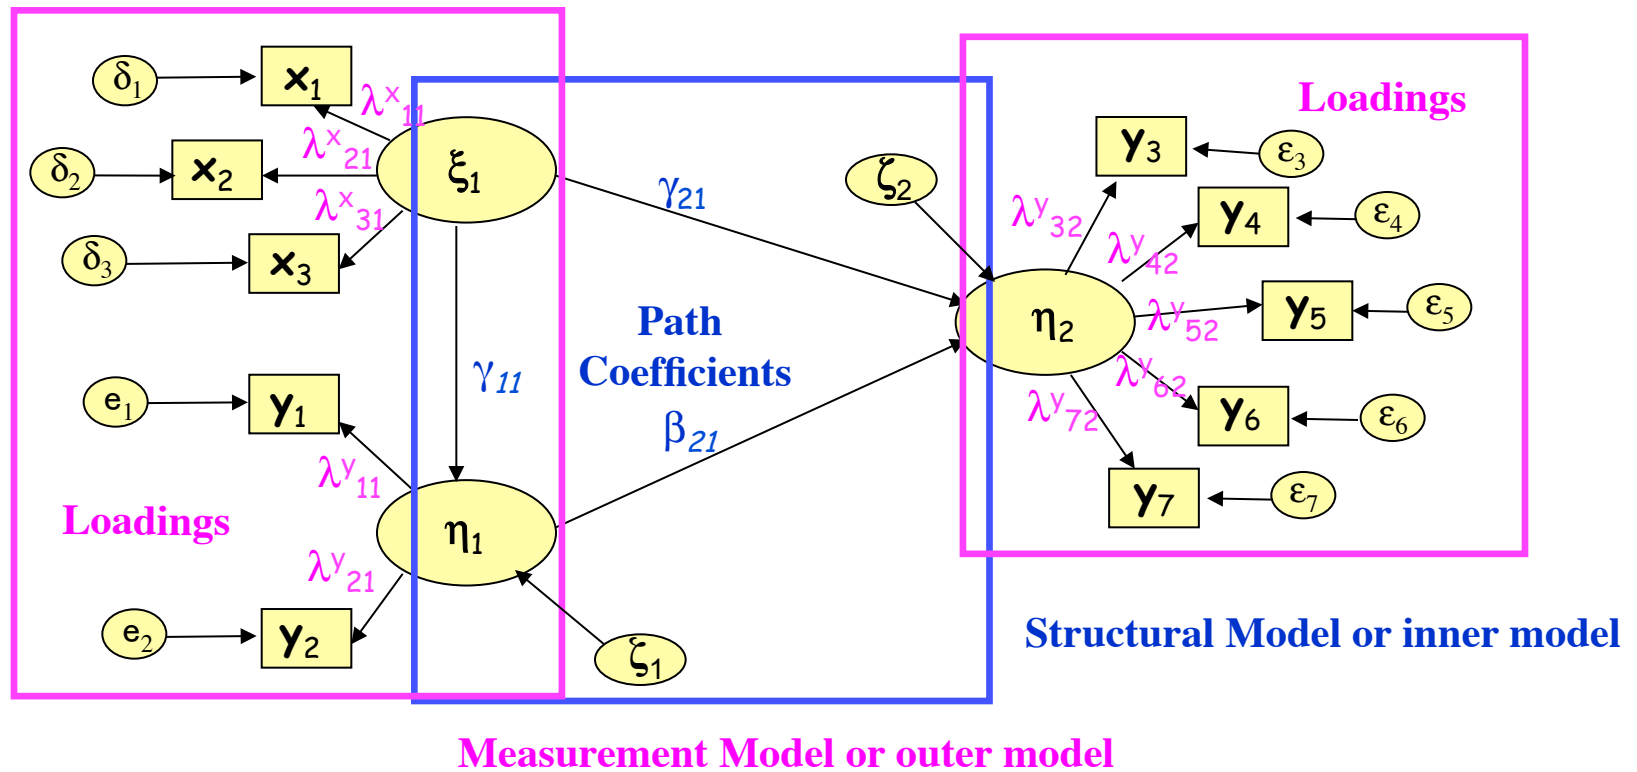
$$\mathbf{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_6 \end{bmatrix} \quad \Lambda_x = \begin{bmatrix} \lambda_{11} & 0 \\ \lambda_{21} & \lambda_{22} \\ \lambda_{31} & 0 \\ 0 & \lambda_{42} \\ 0 & \lambda_{52} \\ 0 & \lambda_{62} \end{bmatrix}$$

$$\boldsymbol{\xi} = \begin{bmatrix} \xi_1 \\ \xi_2 \end{bmatrix}$$

$$\boldsymbol{\delta} = \begin{bmatrix} \delta_1 \\ \vdots \\ \delta_6 \end{bmatrix}$$


$$\mathbf{X} = \Lambda_x \boldsymbol{\xi} + \boldsymbol{\delta}$$

Modèle de chemin avec des variables latentes



Le modèle de mesure (externe) pour les VM exogènes

$$\begin{aligned}x_1 &= \lambda_{11}^x \xi_1 + \delta_1 \\x_2 &= \lambda_{21}^x \xi_1 + \delta_2 \\x_3 &= \lambda_{31}^x \xi_1 + \delta_3\end{aligned}$$



$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} \Lambda_x = \begin{bmatrix} \lambda_{11}^x \\ \lambda_{21}^x \\ \lambda_{31}^x \end{bmatrix}$$

$(P \times 1)$ $(P \times M)$

$$\xi = [\xi_1] \quad \delta = \begin{bmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \end{bmatrix}$$

$(M \times 1)$ $(P \times 1)$

$$\mathbf{x} = \Lambda_x \xi + \delta$$

Le modèle de mesure (externe) pour les VM endogènes

$$y_1 = \lambda^{y_{11}} \eta_1 + \varepsilon_1$$

$$y_2 = \lambda^{y_{21}} \eta_1 + \varepsilon_2$$


$$y_3 = \lambda^{y_{32}} \eta_2 + \varepsilon_3$$

$$y_4 = \lambda^{y_{42}} \eta_2 + \varepsilon_4$$

$$y_5 = \lambda^{y_{52}} \eta_2 + \varepsilon_5$$

$$y_6 = \lambda^{y_{62}} \eta_2 + \varepsilon_6$$

$$y_7 = \lambda^{y_{72}} \eta_2 + \varepsilon_7$$




$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \\ y_5 \\ y_6 \\ y_7 \end{bmatrix} \quad \Lambda_y = \begin{pmatrix} \lambda_{11} & 0 \\ \lambda_{21} & 0 \\ 0 & \lambda_{42} \\ 0 & \lambda_{52} \\ 0 & \lambda_{62} \\ 0 & \lambda_{72} \end{pmatrix} \quad \eta = \begin{bmatrix} \eta_1 \\ \eta_2 \end{bmatrix} \quad \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \\ \varepsilon_6 \\ \varepsilon_7 \end{bmatrix}$$

$$\mathbf{y} = \Lambda_y \boldsymbol{\eta} + \boldsymbol{\varepsilon}$$

Le modèle structurel (interne)

$$\eta_1 = \gamma_{11} \xi_1 + \zeta_1$$

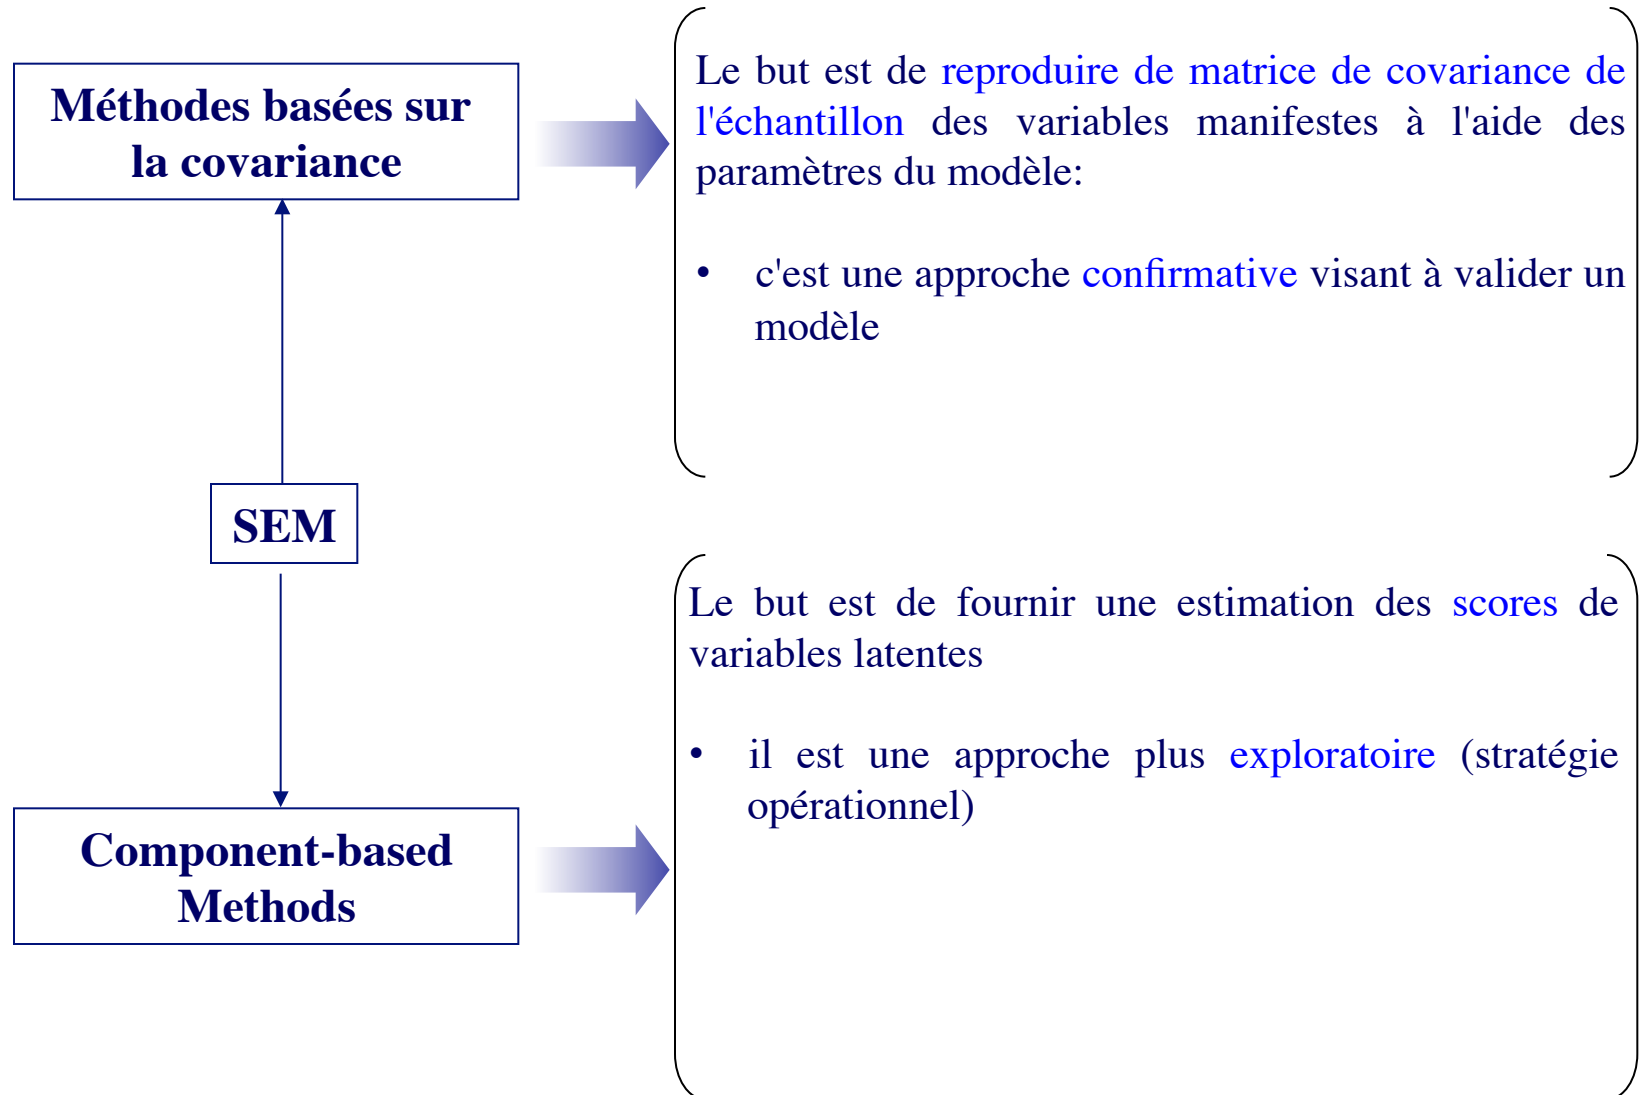
$$\eta_2 = \gamma_{21} \xi_1 + \beta_{21} \eta_1 + \zeta_2$$




$$\eta = \begin{bmatrix} \eta_1 \\ \eta_2 \end{bmatrix} \quad \xi = [\xi_1] \quad \Gamma = \begin{bmatrix} \gamma_{11} \\ \gamma_{21} \end{bmatrix} \quad \mathbf{B} = \begin{bmatrix} 0 & 0 \\ \beta_{21} & 0 \end{bmatrix} \quad \zeta = \begin{bmatrix} \zeta_1 \\ \zeta_2 \end{bmatrix}$$

$$\eta = \Gamma \xi + \mathbf{B} \eta + \zeta$$

Two families of methods for estimating paths models with latent variables



Les hypothèses du modèle



$$\mathbf{x} = \Lambda_x \boldsymbol{\xi} + \boldsymbol{\delta}$$

$$\mathbf{y} = \Lambda_y \boldsymbol{\eta} + \boldsymbol{\varepsilon}$$

$$\boldsymbol{\eta} = (\mathbf{I} - \mathbf{B})^{-1} (\boldsymbol{\Gamma} \boldsymbol{\xi} + \boldsymbol{\zeta})$$

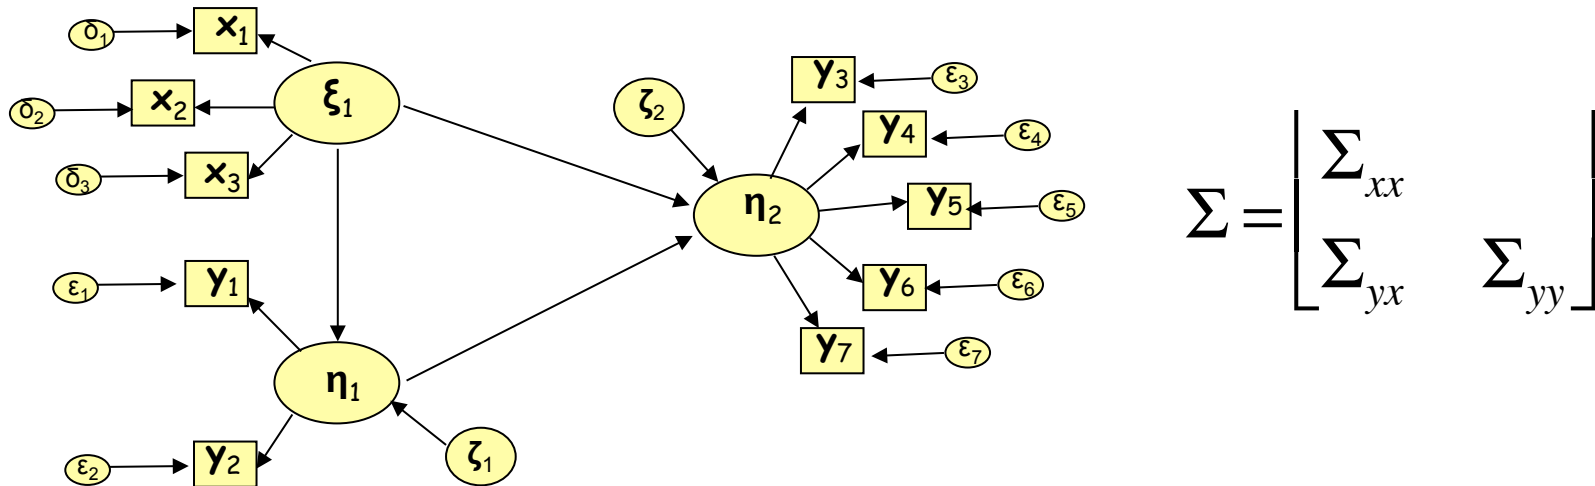
$$E(\mathbf{x}) = 0, E(\mathbf{y}) = 0, E(\boldsymbol{\xi}) = 0, E(\boldsymbol{\eta}) = 0, E(\boldsymbol{\delta}) = 0, E(\boldsymbol{\varepsilon}) = 0, E(\boldsymbol{\zeta}) = 0$$

$$E(\boldsymbol{\delta} \boldsymbol{\varepsilon}') = 0, E((\boldsymbol{\zeta} \boldsymbol{\delta}')) = 0, E(\boldsymbol{\zeta} \boldsymbol{\varepsilon}') = 0$$

$$E(\boldsymbol{\delta} \boldsymbol{\xi}') = 0, E(\boldsymbol{\delta} \boldsymbol{\eta}') = 0, E(\boldsymbol{\varepsilon} \boldsymbol{\xi}') = 0, E(\boldsymbol{\varepsilon} \boldsymbol{\eta}') = 0$$

$$E(\boldsymbol{\zeta} \boldsymbol{\xi}') = 0$$

Covariance Structure Analysis (CSA, aka LISREL)



Une fois que le modèle est spécifié, la matrice de covariance des MV est exprimée en termes de paramètres du modèle

$$\Sigma(\Omega) = \Sigma(\Gamma, \mathbf{B}, \Lambda_x, \Lambda_y, \Phi, \Psi, \Theta_\delta, \Theta_\epsilon)$$

Diagram illustrating the components of the covariance matrix $\Sigma(\Omega)$ in terms of model parameters:

- Path Coefficients (Γ)
- Loadings (Λ_x, Λ_y)
- Exog. LV Covariance (Φ)
- Structural Error Covariance (Ψ)
- Measurement Error Covariance ($\Theta_\delta, \Theta_\epsilon$)

Analysing the covariance

Estimation minimise une certaine **fonction de la divergence** entre la matrice de covariance (C) impliquée par le modèle et la matrice de covariance (S).

$$\Sigma = \begin{bmatrix} \Sigma_{xx} & \\ \Sigma_{yx} & \Sigma_{yy} \end{bmatrix}$$

Population Covariance matrix

$$S = \begin{bmatrix} S_{xx} & \\ S_{yx} & S_{yy} \end{bmatrix}$$

Empirical covariance matrix

$$\Sigma(\Omega) = \begin{bmatrix} \Lambda_x \Phi \Lambda_x' + \Theta_\delta & \\ \Lambda_y (\mathbf{I} - \mathbf{B})^{-1} \Gamma \Phi' \Lambda_x' & \Lambda_y \left[(\mathbf{I} - \mathbf{B})^{-1} (\Gamma \Phi \Gamma' + \Psi) (\mathbf{I} - \mathbf{B})^{-1} \right] \Lambda_y' + \Theta_\varepsilon \end{bmatrix}$$

“Implied” covariance matrix

$$\Sigma(\hat{\Omega}) = \mathbf{C} = \begin{bmatrix} \hat{\Lambda}_x \hat{\Phi} \hat{\Lambda}_x' + \hat{\Theta}_\delta & \\ \hat{\Lambda}_y (\mathbf{I} - \hat{\mathbf{B}})^{-1} \hat{\Gamma} \hat{\Phi}' \hat{\Lambda}_x' & \hat{\Lambda}_y \left[(\mathbf{I} - \hat{\mathbf{B}})^{-1} (\hat{\Gamma} \hat{\Phi} \hat{\Gamma}' + \hat{\Psi}) (\mathbf{I} - \hat{\mathbf{B}})^{-1} \right] \hat{\Lambda}_y' + \hat{\Theta}_\varepsilon \end{bmatrix}$$

Estimated covariance matrix

$$S \approx C$$

Fonctions de divergence

Maximum Likelihood

$$F_{ML} = \log|\mathbf{C}| + tr(\mathbf{S}\mathbf{C}^{-1}) - \log|\mathbf{S}| - (p + q)$$

Unweighted Least Squares

$$F_{ULS} = \frac{1}{2} tr \left[(\mathbf{S} - \mathbf{C})^2 \right]$$

Generalised Least Squares

$$F_{GLS} = \frac{1}{2} tr \left[\mathbf{W}^{-1} (\mathbf{S} - \mathbf{C})^2 \right]$$

Considerations sur l'approche CSA

- Estimateurs avec de **bonnes propriétés statistiques**
- Les estimations sont obtenues au moyen de **ML, ULS, WLS, GLS**;
- **Taille de l'échantillon**: 200-400 cas pour 10-15 variables observées;
- **L'identification du modèle** (estimation unique des paramètres) peut être un problème (qui peut être résolu en imposant un ensemble de contraintes sur les paramètres)
- **Aucune estimation directe de variables latentes** -> ce n'est pas son objectif!!

Références

- K.A. Bollen : Structural Equations with Latent Variables, John Wiley & Sons., 1989
- R. Cudeck, S. Du Toit, D. Sörbom (Editors) : Structural Equation Modeling: Present and Future - A Festschrift in honor of Karl G. Jöreskog, Scientific Software International Chicago, 2001
- R. Hoyle : Structural equation modeling: concepts, issues and applications, SAGE Publications, 1995
- K.G. Jöreskog & D. Sörbom : Advances in Factor Analysis and Structural Equation Models, Abt Books, 1979
- K.G. Jöreskog, D. Sörbom, S. Du Toit, M. Du Toit : LISREL8: New Statistical Features, Second Printing with Revisions, Scientific Software International Chicago, 2000
- D. Kaplan : Structural Equation Modeling: Foundations and Extensions, SAGE Publications, 2000
- Rex B. Kline : Principles and Practice of Structural Equation Modeling, The Guilford Press, New York, 2005
- D. Kaplan : Structural Equation Modeling: Foundations and Extensions, SAGE Publications, 2000