

# SÉLECTION DE MODÈLES DE MÉLANGE DE RÉGRESSION MULTIVARIÉE

Abdelaziz Aloui <sup>1</sup>, Abdelaziz El Matouat <sup>2</sup> & Hassania Hamzaoui <sup>3</sup>

<sup>1</sup>*FSDM Université de Fès, Maroc, abdelaziz.aloui@usmba.ac.ma*

<sup>2</sup>*LMAH Université du Havre, France, abdelaziz.el-matouat@univ-lehavre.fr*

<sup>3</sup>*FLSH Université de Fès, Maroc, hassania.hamzaoui@usmba.ac.ma*

**Résumé.** Dans la détermination du nombre de composantes et l'ordre d'un modèle de mélange de régression univarié, Naik et al(2007) ont développé le critère *MRC* (Mixture Regression Criterion). Dans ce travail, nous proposons une généralisation de ce critère au modèle de mélange de régression multivarié et à un modèle de mélange autorégressif vectoriel.

**Mots-clés.** Critères d'information, critère *MRC*, sélection de modèle, régression multivariée, modèle autorégressif vectoriel.

**Abstract.** In determining the number of components and the order of the mixture of univariate regression model, Naik and al(2007) have developed the *MRC* criterion (Mixture Regression Criterion). In this work, we propose a generalisation of this criterion to the mixture multivariate regression model and mixture vector autoregressive model.

**Keywords.** Information criteria, MRC criterion, model selection, multivariate regression, vector autoregressive model.

## 1 Introduction

Un modèle de mélange linéaire multivarié consiste à écrire un vecteur  $y$  en fonction des covariables  $x$  de la façon suivante :

$$y = \begin{cases} \beta'_1 x + \epsilon_1 & \text{avec la probabilité } \alpha_1 \\ \beta'_2 x + \epsilon_2 & \text{avec la probabilité } \alpha_2 \\ \cdot \\ \cdot \\ \beta'_K x + \epsilon_K & \text{avec la probabilité } \alpha_K \end{cases}$$

où  $y = (y_1, \dots, y_m)'$ ,  $x = (x_1, \dots, x_p)'$ ,  $\beta_k$  une matrice d'ordre  $p \times m$ , et  $\epsilon_k$  un vecteur aléatoire représentant les erreurs de spécification du modèle, de dimension  $m$  de loi gaussienne de moyenne 0 et de matrice de variances-covariances  $\Sigma_k$ .

La densité de probabilité relative à la loi de  $y$  conditionnellement à  $x$  est donnée par :

$$f(y, x, \phi) = \sum_{k=1}^K \alpha_k f_k(y, x, \beta_k, \Sigma_k) \quad (1)$$

où  $\phi = \{(\alpha_k, \beta_k, \Sigma_k), k = 1, \dots, K\}$  est l'ensemble des paramètres tel que  $0 < \alpha_k < 1$  et  $\sum_{k=1}^K \alpha_k = 1$ ,  $K$  est le nombre de composantes et  $f_k$  est la fonction densité d'une loi normale  $N(\beta_k'x, \Sigma_k)$ .

Soit  $\{(y_1, x_1), \dots, (y_n, x_n)\}$  un échantillon observé issu du modèle (1), la fonction log-vraisemblance s'écrit :

$$\begin{aligned} L(\phi, Z, Y, X) &= \log \prod_{j=1}^n \prod_{k=1}^K \{\alpha_k f_k(y_j, x_j, \beta_k, \Sigma_k)\}^{z_{jk}} \\ &= \sum_{j=1}^n \sum_{k=1}^K z_{jk} \{\log \alpha_k + \log f_k(y_j, x_j, \beta_k, \Sigma_k)\} \end{aligned} \quad (2)$$

où  $Y = (y_1, \dots, y_n)'$ ,  $Z$  est une variable latente d'ordre  $n \times K$  telle que  $z_{jk}$  vaut 1 lorsque  $y_j$  provient de la  $k^{\text{ième}}$  composante du mélange et à 0 sinon, et  $X = (x_1, \dots, x_n)'$  est la variable explicative.

On note  $f^0$  la densité du vrai modèle telle que :

$$f^0(y, x, \phi^0) = \sum_{k=1}^{K^0} \alpha_k^0 f_k^0(y, x, \beta_k^0, \Sigma_k^0)$$

$L^0$  est la log-vraisemblance avec  $1 < K^0 < K$  et  $1 < p^0 < p$ . Sous cette hypothèse, les colonnes de  $X$  peuvent être réorganisées afin que  $X^0 \beta_k^0 = X \beta_k^*$  avec  $\beta_k^* = ((\beta_k^0)', (\beta_k^1)')$  et  $\beta_k^1$  est une matrice nulle d'ordre  $(p - p^0) \times m$  [3].

## 2 Critère MRC pour un modèle de mélange de régression multivarié

### 2.1 Estimation des paramètres

Pour estimer les paramètres d'un modèle de mélange de régression, on applique l'algorithme EM (Expectation-Maximization)[2]. Cet algorithme est une méthode d'estimation itérative composée à l'itération  $q$  de deux étapes :

**Etape E (Expectation) :** on calcule l'espérance  $Q(\phi, \phi^{(q)})$  de la vraisemblance  $L$  conditionnellement aux données observées qui nécessite principalement le calcul des probabilités a posteriori  $\tau_{jk}^{(q)} = E(z_{jk}/y_j) = P(z_{jk} = 1/y_j)$ . Par la formule de Bays on a :

$$\tau_{jk}^{(q)} = \frac{\alpha_k^{(q)} f_k^{(q)}(y_j, x_j, \beta_k^{(q)}, \Sigma_k^{(q)})}{\sum_{k=1}^K \alpha_k^{(q)} f_k^{(q)}(y_j, x_j, \beta_k^{(q)}, \Sigma_k^{(q)})}$$

**Etape M (Maximization) :** on calcule le vecteur paramètre  $\phi^{(q+1)}$  qui maximise, par rapport à  $\phi$ , la fonction  $Q$  qui s'écrit comme suit :

$$Q(\phi, \phi^{(q)}) = \sum_{j=1}^n \sum_{k=1}^K \tau_{jk}^{(q)} \{ \log \alpha_k + \log f_k(y_j, x_j, \beta_k, \Sigma_k) \}$$

Les estimateurs des paramètres sont :

1.  $\alpha_k^{(q+1)} = \sum_{j=1}^n \frac{\tau_{jk}^{(q)}}{n}$
2.  $\beta_k^{(q+1)} = (\tilde{X}_k^{(q)'} \tilde{X}_k^{(q)})^{-1} \tilde{X}_k^{(q)'} \tilde{Y}_k^{(q)}$
3.  $\Sigma_k^{(q+1)} = \tilde{Y}_k^{(q)'} (I - \tilde{H}_k^{(q)}) \tilde{Y}_k^{(q)} / \text{tr}(W_k^{(q)})$

Où  $W_k^{(q)} = \text{diag}(\tau_k^{(q)})$ ,  $\tau_k^{(q)} = (\tau_{1k}^{(q)}, \dots, \tau_{nk}^{(q)})'$   
 $\tilde{Y}_k^{(q)} = (W_k^{(q)})^{1/2} Y$ ,  $\tilde{X}_k^{(q)} = (W_k^{(q)})^{1/2} X$  et  $\tilde{H}_k^{(q)} = \tilde{X}_k^{(q)} (\tilde{X}_k^{(q)'} \tilde{X}_k^{(q)})^{-1} \tilde{X}_k^{(q)'}$ . Les vecteurs paramètres  $\phi^{(q)}$  convergent vers l'estimateur du maximum de vraisemblance  $\hat{\phi}$ .

## 2.2 Estimation du nombre de composantes et de l'ordre du modèle de mélange de régression multivariée :

L'objectif principal de la sélection du modèle est d'approcher le vrai modèle avec des modèles candidats en faisant varier le couple  $(K, p)$ , cette approche entraîne une conservation du modèle qui entraîne une perte minimale de l'information. Pour cette raison, nous adoptons l'approche prédictive d'Akaike(1985) pour déduire une nouvelle formulation du critère *MRC*. On considère :

$$I(\theta^0, \theta) = E_{Y^*/\theta^0} \{ L^0(\phi^0, Z^*, Y^*, X) - L(\phi, \tau, Y^*, X) \}, \quad \theta = (\phi, \tau) \quad (3)$$

$Y^* = (y_1^*, \dots, y_n^*)'$  est la prédiction,  $Z^*$  est une matrice d'ordre  $n \times K^0$ ,  $\tau$  est une matrice telle que  $\tau_{jk} = E(z_{jk}/y_j)$ , et  $E_{Y^*/\theta^0}$  est l'espérance conditionnelle sachant  $\theta^0 = (\phi^0, \tau^0)$ . En omettant le premier terme de (3) qui ne dépend pas de  $\theta$ , nous avons la proposition suivante :

**Proposition :** Sous des conditions de régularité le critère défini par :

$$MRC = \sum_{k=1}^K \hat{n}_k \log(|\hat{\Sigma}_k|) - 2 \sum_{k=1}^K \hat{n}_k \log(\hat{\alpha}_k) + \sum_{k=1}^K \hat{d}_k m(p_k + \hat{n}_k) \quad (4)$$

est un estimateur de  $\Delta(\hat{\theta}(Y)) = -2E_Y [E_{Y^*} \{ L(\hat{\phi}(Y), \hat{\tau}(Y), Y^*, X) \}]$   
avec  $\hat{\theta} = (\hat{\phi}, \hat{\tau})$ ,  $\hat{n}_k = \text{tr}(\hat{W}_k)$ ,  $\hat{d}_k = \frac{\hat{n}_k}{\hat{n}_k - (m + p_k + 1)}$  et  $p_k = \text{tr}(\hat{H}_k)$

**Preuve : (Idée de la démonstration)**

1. Soit  $\Delta(\hat{\theta}(Y)) = -2E_Y E_{Y^*} [\sum_{k=1}^K \sum_{j=1}^n \hat{\tau}_{jk} \{ \log \hat{\alpha}_k + \log f_k(y_j^*, x_j, \hat{\beta}_k, \hat{\Sigma}_k) \}] \quad (1-1)$

2. Après des simplifications algébriques nous obtenons :

$$\begin{aligned} \Delta(\hat{\theta}(Y)) &= E_Y \left\{ \sum_{k=1}^{K^0} \text{tr}(\hat{W}_k) \log(|\hat{\Sigma}_k|) - 2 \sum_{k=1}^{K^0} \text{tr}(\hat{W}_k)' \log(\hat{\alpha}_k) \right\} \\ &+ E_Y \left\{ \sum_{k=1}^{K^0} \text{tr}[\hat{X}_k(\beta_k^* - \hat{\beta}_k) \hat{\Sigma}_k^{-1} (\beta_k^* - \hat{\beta}_k)' \hat{X}_k'] \right\} + E_Y \left\{ \sum_{k=1}^{K^0} \text{tr}(\hat{W}_k) \text{tr}(\hat{\Sigma}_k^{-1} \Sigma_k^0) \right\} \end{aligned} \quad (1-2)$$

3. D'après les conditions de régularité,  $\hat{\tau}_k$  est un estimateur consistant de  $\tau_k^0 = (\tau_{1k}^0, \dots, \tau_{nk}^0)$  [4] où  $\tau_{jk}^0 = E(z_{jk}^0/Y)$ . Par conséquent, nous pouvons remplacer  $\hat{W}_k$  et  $\hat{H}_k$  dans les troisième et quatrième termes de droite de (1-2) par  $W_k^0 = \text{diag}(\tau_k^0)$  et  $H_k^0$ , respectivement, où  $H_k^0 = X_k^0 (X_k^{0'} X_k^0)^{-1} X_k^{0'}$  et  $X_k^0 = (W_k^0)^{1/2} X$ , et pour simplifier encore nous supposons que dans le vrai modèle les classes sont disjointes telles que les éléments diagonaux de  $W_k^0$  sont égaux à 0 ou 1. On a :  $n_k^0 \hat{\Sigma}_k \sim W_k(\Sigma_k, n_k^0 - m)$  et  $E_Y(\hat{\Sigma}_k^{-1}) = d_k^0 (\Sigma_k^0)^{-1}$  avec :  $d_k^0 = \frac{n_k^0}{n_k^0 - (m + p_k^0 + 1)}$  [3]

$$\text{On a : } \text{tr}[E_Y(\hat{\Sigma}_k^{-1}) E_Y\{(\beta_k^* - \hat{\beta}_k)' (X_k^0)' X_k^0 (\beta_k^* - \hat{\beta}_k)\}] = d_k^0 p_k^0 m \quad (1-3)$$

$$\text{et } E_Y \sum_{k=1}^{K^0} \text{tr}(W_k^0) \text{tr}(\hat{\Sigma}_k^{-1} \Sigma_k^0) = \sum_{k=1}^{K^0} \text{tr}(W_k^0) d_k^0 m \quad (1-4)$$

4. En remplaçant (1-3) et (1-4) dans le deuxième et le troisième terme de (1-2) respectivement, et  $K^0$  et  $W_k^0$  par  $K$  et  $\hat{W}_k$  respectivement, on obtient un estimateur de  $\Delta(\hat{\theta}(Y))$  définie par :

$$MRC = \sum_{k=1}^K \hat{n}_k \log(|\hat{\Sigma}_k|) - 2 \sum_{k=1}^K \hat{n}_k \log(\hat{\alpha}_k) + \sum_{k=1}^K \hat{d}_k m (p_k + \hat{n}_k)$$

$$\text{où } \hat{d}_k = \frac{\hat{n}_k}{\hat{n}_k - (m + p_k + 1)} \text{ et } \hat{n}_k = \text{tr}(\hat{W}_k)$$

**Remarque :**

– si  $m = 1$  (cas univarié), on a :

$$MRC = \sum_{k=1}^K \hat{n}_k \log(\hat{\sigma}_k^2) + \sum_{k=1}^K \hat{n}_k (\hat{n}_k + p_k) (\hat{n}_k - p_k - 2) - 2 \sum_{k=1}^K \hat{n}_k \log(\hat{\alpha}_k)$$

qui est le critère défini par Naik et al.(2007)

– Si  $K = 1$  et  $m = 1$  (cas seule composante et univarié) on a :

$$MRC = n \log(\hat{\sigma}^2) + \frac{n(n+p)}{n-p-2} = AIC_c$$

on retrouve le critère d'Akaike corrigé.

### 3 Dérivation du critère MRC pour un modèle de mélange autorégressif vectoriel

Soit  $MVAR(m, K, p_1, p_2, \dots, p_k)$  un modèle de mélange autorégressif vectoriel relatif à un vecteur  $y_t$  de dimension  $m$  avec  $K$  composantes dont l'expression est :

$$F(y_t / \mathfrak{F}_{t-1}) = \sum_{k=1}^K \alpha_k \Phi[\Sigma_k^{-\frac{1}{2}} (y_t - \Theta_{k1} y_{t-1} - \Theta_{k2} y_{t-2} - \dots - \Theta_{kp_k} y_{t-p_k})], t = p+1, \dots, n \quad (5)$$

où  $p = \max(p_1, p_2, \dots, p_K)$  avec  $p_k$  l'ordre du  $k^{\text{ième}}$  autorégressif,  $\mathfrak{F}_{t-1}$  est la tribu engendrée par  $\{y_{t-1}, y_{t-2}, y_{t-3}, \dots\}$ ,  $\Phi(\cdot)$  est la distribution normale multivariée de moyenne nulle et de matrice de variances-covariances  $I$ ,  $\alpha_k$  est la probabilité de la  $k^{\text{ième}}$  composante telle que  $\alpha_1 \geq \alpha_2 \geq \dots \geq \alpha_K \geq 0$  et  $\sum \alpha_i = 1$ ,  $\Theta_{k1}, \dots, \Theta_{kp_k}$  sont des matrices d'ordre  $m \times m$ , et  $\Sigma_k$  est la matrice variance-covariance d'ordre  $m \times m$ .

### 3.1 Estimation des paramètres

Soit  $y_1, \dots, y_n$  des observations du modèle  $MVAR(m, K, p_1, \dots, p_K)$ . Pour  $t = 1, \dots, n$  soit  $z_t = (z_{t,1}, \dots, z_{t,K})'$  où  $z_{t,k} = 1$  si  $y_t$  provient de la  $k^{\text{ième}}$  composante pour  $k = 1, \dots, K$  et  $z_{t,k} = 0$  sinon, les vecteurs  $z_1, \dots, z_n$  sont généralement non observés, la densité des données complètes  $(y_t, z_t)$  est :  $\prod_{k=1}^K [\alpha_k f_k(\mathbf{e}_{kt}, \Sigma_k)]^{z_{t,k}}$  où  $f_k(\mathbf{e}_{kt}, \Sigma_k) = (2\Pi)^{-\frac{m}{2}} |\Sigma_k|^{-\frac{1}{2}} \exp(-\frac{1}{2} \mathbf{e}'_{kt} \Sigma_k^{-1} \mathbf{e}_{kt})$ ,  $\mathbf{e}_{kt} = y_t - \Theta_{k1}y_{t-1} - \Theta_{k2}y_{t-2} - \dots - \Theta_{kp_k}y_{t-p_k} = y_t - \beta_k x_{kt}$  avec  $\beta_k = [\Theta_{k1}, \dots, \Theta_{kp_k}]$  et  $x_{kt} = (y'_{t-1}, y'_{t-2}, \dots, y'_{t-p_k})'$ , pour  $k = 1, \dots, K$ . La log-vraisemblance est donnée par :

$$L(\phi, Y, Z) = \sum_{t=p+1}^n \left\{ \sum_{k=1}^K z_{t,k} \log(\alpha_k) - \frac{1}{2} \sum_{k=1}^K z_{t,k} \log |\Sigma_k| - \frac{1}{2} \sum_{k=1}^K z_{t,k} (\mathbf{e}'_{kt} \Sigma_k^{-1} \mathbf{e}_{kt}) \right\}$$

avec :  $\alpha = (\alpha_1, \dots, \alpha_{K-1})'$  et  $\phi = (\alpha', \text{vec}(\beta_1)', \text{vec}(\Sigma_1)', \dots, \text{vec}(\beta_K)', \text{vec}(\Sigma_K)')'$   
 Pour estimer les paramètres on utilise l'algorithme EM, nous avons :

$$\begin{aligned} - \hat{\alpha}_k &= \frac{1}{T-p} \sum_{t=p+1}^T \hat{\tau}_{t,k} \\ - \hat{\beta}'_k &= (\sum_{t=p+1}^T \hat{\tau}_{t,k} x_{kt} x'_{kt})^{-1} (\sum_{t=p+1}^T \hat{\tau}_{t,k} x_{kt} y'_{kt}) \\ - \hat{\Sigma}_k &= \frac{\sum_{t=p+1}^T \hat{\tau}_{t,k} \hat{\mathbf{e}}_{kt} \hat{\mathbf{e}}'_{kt}}{\sum_{t=p+1}^T \hat{\tau}_{t,k}} \end{aligned}$$

### 3.2 Dérivation de MRC

Soit  $Y = (y_{p+1}, \dots, y_n)'$ ,  $X = (x_{p+1}, \dots, x_n)'$ ,  $x_j = (y'_{j-1}, \dots, y'_{j-p_k})'$  et  $\beta'_k = [\Theta_{k1}, \dots, \Theta_{kp_k}]'$  où  $j = p+1, \dots, n$  et  $k = 1, \dots, K$ . Alors l'écart des log-vraisemblances du modèle candidat de mélange autogéressif vectoriel et le vrai modèle est :

$$\Delta(\hat{\theta}(Y)) = -2E_Y E_{Y^*} L(\hat{\phi}, \hat{\tau}, Y^*, X)$$

$\Delta(\hat{\theta}(Y)) = -2E_Y E_{Y^*} [\sum_{k=1}^K \sum_{j=p+1}^n \hat{\tau}_{j,k} \{\log \hat{\alpha}_k + \log f_k(y_j^*, x_j, \hat{\beta}_k, \hat{\Sigma}_k)\}]$   $\hat{\phi}$ ,  $\hat{\tau}$  et  $Y^*$  sont définis dans le paragraphe (1). La dernière expression de  $\Delta(\hat{\theta}(Y))$  est la même que celle de (1-1), et par conséquent  $\Delta(\hat{\theta}(Y))$  peut être approché par le dernier terme de (1-2). Une application des techniques utilisées dans la démonstration de la proposition de la partie 2.2 entraîne finalement l'expression du MRC pour un modèle de mélange multivarié :

$$MRC = \sum_{k=1}^K \hat{n}_k \log(|\hat{\Sigma}_k|) - 2 \sum_{k=1}^K \hat{n}_k \log(\hat{\alpha}_k) + \sum_{k=1}^K \hat{d}_k m (p_k + \hat{n}_k)$$

où  $\hat{d}_k = \frac{\hat{n}_k}{\hat{n}_k - (m + p_k + 1)}$  et  $\hat{n}_k = \text{tr}(\hat{W}_k)$ .

## Conclusion

Le critère  $MRC$  est une extension du critère  $AIC_c$  dans le cas des modèles de mélange de régression. Nous avons proposé une démonstration du critère  $MRC$  dans le cas des modèles de mélange de régression multivariée. Nous avons aussi donnée une formulation du critère  $MRC$  pour sélectionner les modèles de mélange autorégressifs vectoriels.

## Bibliographie

- [1] Akaike, H.(1985), Prediction and entropy, *In A Celebration of Statistics*, Ed. A.C. Atkinson and S.E. Fienberg, pp.1–24, New York :Springer
- [2] Dempster, A.P, Laird, N.M and Rubin, D.P. (1977) Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society Series B*, 39, 1–38.
- [3] Edward J. Bedrick and Chih-Ling Tsai. (1994) Model Selection for Multivariate Regression in small Samples, *Biometrics*, 50, 226–231.
- [4] Leroux, B.(1992), Consistent estimation of a mixing distribution, *The Annals of Statistics*, 20, 1350–1360
- [5] Naik PA, Shi P, Tsai CL. (2007) Extending the Akaike information criterion to mixture regression models. *J Am Stat Assoc*, 102(477) :244–254.
- [6] P.W.Fong, W.K.Li, C.W.Yau and C.S.Wong (2007) On a Mixture Vector Autoregressive Model. *The Canadian Journal of Statistics / la Revue canadienne de Statistique*, 14 1080–10100
- [7] Schwarz G.(1978) Srivastava, M.S., and Khatri, C.G.(1979) An Introduction to Multivariate Statistics. North-Holland, New York.