

**Corrigé du partiel du 26 mars 2001**  
**Statistique des processus**  
MST ISASH - Maîtrise MASS

**Exercice 1.** *Exercice bien réussi, noté sur 4 points.*

1) Montrons que  $\phi$  annule les composantes saisonnières.

Méthode 1. On remarque que la transformée en  $z$  de  $\phi$  peut se décomposer en

$$\begin{aligned}\phi(z) &= \frac{1}{3}(2 + z + z^2 - z^3) \\ &= (1 + z + z^2) \times \frac{2 - z}{3}\end{aligned}$$

Autrement dit,  $(1 + z + z^2)$  divise  $\phi(z)$ . Or, si  $(1 + z + \dots + z^{q-1})$  divise la transformée en  $z$  d'une moyenne mobile finie, cette moyenne mobile finie annule les composantes saisonnières de période  $q$ . On en déduit que  $\phi$  annule les saisonnalités de période 3.

Méthode 2. Soit  $x^\sigma$  une composante saisonnière de période 3;  $x^\sigma$  vérifie donc les propriétés suivantes:  $\forall t \in \mathbb{Z}$ ,

$$\begin{aligned}x_t^\sigma + x_{t-1}^\sigma + x_{t-2}^\sigma &= 0 \\ x_t^\sigma &= x_{t-3}^\sigma\end{aligned}$$

On en déduit :

$$\begin{aligned}\phi(x^\sigma)_t &= \frac{1}{3}(2x_t^\sigma + x_{t-1}^\sigma + x_{t-2}^\sigma - x_{t-3}^\sigma) \\ &= \frac{1}{3}((2x_t^\sigma - x_{t-3}^\sigma) + x_{t-1}^\sigma + x_{t-2}^\sigma) \\ &= \frac{1}{3}(x_t^\sigma + x_{t-1}^\sigma + x_{t-2}^\sigma) \\ &= 0\end{aligned}$$

2) Montrons que  $\phi$  conserve les tendances affines.

Méthode 1. Il suffit de vérifier que  $(1-z)^2$  divise  $\phi(z)-1$ , autrement dit que 1 est racine double, ce qui revient à vérifier que  $(\phi(z)-1)|_{z=1} = (\phi(z)-1)'|_{z=1} = 0$ . Or,

$$\begin{aligned}(\phi(z)-1)|_{z=1} &= \left(\frac{1}{3}(2+z+z^2-z^3)-1\right)|_{z=1} \\ &= \frac{1}{3}(2+1+1-1)-1 \\ &= 0\end{aligned}$$

$$\begin{aligned}(\phi(z)-1)'|_{z=1} &= \left(\frac{1}{3}(1+2z-3z^2)\right)|_{z=1} \\ &= \frac{1}{3}(1+2-3) \\ &= 0\end{aligned}$$

Méthode 1 bis. On peut aussi effectuer directement la division, par puissances croissantes ou décroissantes, de  $\phi(z) - 1$  par  $(1 - z)^2$ , et l'on trouve ainsi que

$$\phi(z) - 1 = (1 - z)^2 \frac{z + 1}{3}$$

Méthode 2. Soit  $x_t = \alpha + \beta t$  une tendance polynômiale quelconque de degré inférieur à 2. Montrons que  $\phi(x)_t = x_t$  :

$$\begin{aligned} \phi(x)_t &= \frac{1}{3}(2x_t + x_{t-1} + x_{t-2} - x_{t-3}) \\ &= \frac{1}{3}\left(2(\alpha + \beta t) + (\alpha + \beta(t-1)) + (\alpha + \beta(t-2)) - (\alpha + \beta(t-3))\right) \\ &= \frac{1}{3}(\alpha(2 + 1 + 1 - 1) + \beta(-1 - 2 + 3) + \beta t(2 + 1 + 1 - 1)) \\ &= \frac{1}{3}(3\alpha + 3\beta t) \\ &= x_t \end{aligned}$$

Remarque : la somme des coefficients du filtre  $\sum_{u=0}^4 \phi_u = \frac{1}{3}(2 + 1 + 1 - 1)$  étant égale à 1, on en déduit que le filtre  $\phi$  conserve les constantes (Attention : comme le filtre n'est pas symétrique, cela n'implique pas qu'il conserve les tendances affines). En posant  $y_t = \beta t$ , on peut alors simplifier les calculs précédents en écrivant

$$\phi(x)_t = \phi(\alpha + y)_t = \phi(\alpha)_t + \phi(y)_t = \alpha + \phi(y)_t,$$

et ne reste plus alors à montrer que  $\phi(y)_t = y_t$ .

**Exercice 2.** *Cet exercice, extrait des fiches de TD, a montré les difficultés très importantes des étudiants à manipuler correctement les indices dans des sommations. Noté sur 5 points.*

1) La démonstration de la formule, vue en cours, consiste simplement en une

suite de calculs :

$$\begin{aligned}
\hat{f}_\varepsilon^{(N)}(0) &= \frac{1}{2\pi} \sum_{|t| \leq N-1} \hat{\gamma}_\varepsilon^{(N)}(t) = \frac{1}{2\pi} \sum_{|t| \leq N-1} \left( \frac{1}{N} \sum_{u=1}^{N-|t|} \varepsilon_u \varepsilon_{u+|t|} \right) \\
&= \frac{1}{2\pi} \left( \frac{1}{N} \sum_{u=1}^N \varepsilon_u^2 \right) + 2 \frac{1}{2\pi} \sum_{t=1}^{N-1} \left( \frac{1}{N} \sum_{u=1}^{N-|t|} \varepsilon_u \varepsilon_{u+t} \right) \\
&= \frac{1}{2\pi N} \left( \sum_{\substack{1 \leq u, v \leq N \\ u=v}} \varepsilon_u \varepsilon_v \right) + \frac{2}{2\pi N} \sum_{t=1}^{N-1} \left( \sum_{\substack{1 \leq u, v \leq N \\ v-u=t}} \varepsilon_u \varepsilon_v \right) \\
&= \frac{1}{2\pi N} \left( \sum_{\substack{1 \leq u, v \leq N \\ u=v}} \varepsilon_u \varepsilon_v \right) + 2 \frac{1}{2\pi N} \left( \sum_{\substack{1 \leq u, v \leq N \\ u < v}} \varepsilon_u \varepsilon_v \right) \\
&= \frac{1}{2\pi N} \left( \sum_{\substack{1 \leq u, v \leq N \\ u=v}} \varepsilon_u \varepsilon_v \right) + \frac{1}{2\pi N} \left( \sum_{\substack{1 \leq u, v \leq N \\ u \neq v}} \varepsilon_u \varepsilon_v \right) \\
&= \frac{1}{2\pi N} \sum_{1 \leq u, v \leq N} \varepsilon_u \varepsilon_v = \frac{1}{2\pi N} \left( \sum_{1 \leq u \leq N} \varepsilon_u \right) \left( \sum_{1 \leq v \leq N} \varepsilon_v \right) \\
&= \frac{1}{2\pi N} \left( \sum_{1 \leq u \leq N} \varepsilon_u \right)^2
\end{aligned}$$

2) La loi de  $\sum_{t=1}^N \varepsilon_t$  est la loi d'une somme de gaussiennes centrées indépendantes ; c'est donc une gaussienne centrée de variance la somme des variances, ici égale à  $N$ . Donc, si l'on note  $U = \frac{1}{\sqrt{2\pi N}} \sum_{t=1}^N \varepsilon_t$ , alors  $U$  est une gaussienne centrée de variance  $\frac{1}{2\pi}$ . Ce dont on déduit que

$$\begin{aligned}
\mathbb{E} \left[ \hat{f}_\varepsilon^{(N)}(0) \right] &= \mathbb{E}[U^2] = \text{var}(U) = \frac{1}{2\pi} \\
\text{var} \left( \hat{f}_\varepsilon^{(N)}(0) \right) &= \mathbb{E}[\hat{f}_\varepsilon^{(N)}(0)^2] - \mathbb{E}[\hat{f}_\varepsilon^{(N)}(0)]^2 \\
&= \mathbb{E}[U^4] - \mathbb{E}[U^2]^2 = 3 \frac{1}{(2\pi)^2} - \left( \frac{1}{2\pi} \right)^2 = \frac{2}{4\pi^2}
\end{aligned}$$

3) La densité spectrale de  $\varepsilon$  vaut  $f_\varepsilon(\lambda) = \frac{\text{var}(\varepsilon_t)}{2\pi} = \frac{1}{2\pi}$ . On voit donc que  $\mathbb{E} \left[ \hat{f}_\varepsilon^{(N)}(0) \right] = f_\varepsilon(0)$ , et que l'estimateur  $\hat{f}_\varepsilon^{(N)}(0)$  est sans biais. On remarque par ailleurs que cet estimateur n'est pas convergent en moyenne quadratique, car sa variance ne tend pas vers 0 quand  $N$  tend vers l'infini. En fait,  $2\pi \hat{f}_\varepsilon^{(N)}(0)$  suit une loi du  $\chi_2$  à un degré de liberté, quel que soit  $N$ .

**Exercice 3.** *Exercice classique, assez correctement réussi et noté sur 7 points. Attention : un ARMA(1,2) n'est ni un AR(1), ni un MA(2), ni les deux à la fois.*

1) Ce processus vérifie le modèle ARMA(1,2) suivant :

$$\phi(B)(X) = \theta(B)(\varepsilon)$$

avec  $\phi(B) = I - 0,8B$  et  $\theta(B) = I + B - 0,75B^2$ . Ce modèle est causal et inversible si les racines des transformées en  $z$  de  $\phi(B)$  et  $\theta(B)$  sont de module strictement supérieur à 1. Or  $\phi(z) = 1 - 0,8z$  a pour racine 1,25 ; le modèle est donc causal. Mais  $\theta(z) = 1 + z - 0,75z^2 = (1 - 0,5z)(1 + 1,5z)$  a pour racines 2 et  $-2/3$  ; le modèle n'est donc pas inversible.

2) On pose  $\varepsilon' = (I + \frac{2}{3}B)^{-1} \circ (I + 1,5B)(\varepsilon)$ . Vérifions que  $\varepsilon'$  est bien un bruit blanc faible. Pour cela, on calcule sa densité spectrale :

$$\begin{aligned} f_{\varepsilon'}(\lambda) &= \left| \frac{1 + 1,5e^{i\lambda}}{1 + \frac{2}{3}e^{i\lambda}} \right|^2 f_{\varepsilon}(\lambda) \\ &= \left| \frac{1}{\frac{2}{3}e^{i\lambda}} \right|^2 \left| \frac{1 + 1,5e^{i\lambda}}{1,5e^{-i\lambda} + 1} \right|^2 \frac{1}{2\pi} \\ &= \frac{9}{4} \times \frac{1}{2\pi} \end{aligned}$$

où l'on a utilisé le fait que  $|e^{i\lambda}| = 1$  et  $|1,5e^{-i\lambda} + 1| = |1 + 1,5e^{i\lambda}|$ . La densité spectrale de  $\varepsilon'$  est donc constante. Ceci implique que  $\varepsilon'$  est un bruit blanc faible. Sa densité spectrale s'écrit alors  $\text{var}(\varepsilon'_t)/2\pi$ , ce dont on déduit que la variance de  $\varepsilon'_t$  vaut 9/4.

Montrons maintenant que  $\varepsilon'$  est le bruit blanc d'innovation associé à  $X : \forall t \in \mathbb{Z}$ ,

$$\begin{aligned} (I - 0,8B)(X)_t &= (I - 0,5B) \circ (I + 1,5B)(\varepsilon)_t \\ &= (I - 0,5B) \circ (I + \frac{2}{3}B) \circ (I + \frac{2}{3}B)^{-1} \circ (I + 1,5B)(\varepsilon)_t \\ &= (I - 0,5B) \circ (I + \frac{2}{3}B)(\varepsilon')_t \\ &= \theta'(B)(\varepsilon')_t \end{aligned}$$

Comme  $\theta'(B)$  est un filtre linéaire dont la transformée en  $z$  s'annule en 2 et en  $-1,5$ , de module plus grand que 1, on conclut que le modèle ARMA(1,2)  $\phi(B)(X) = \theta'(B)(\varepsilon')$  est causal et inversible, et de ce fait que  $\varepsilon'$  est le bruit blanc d'innovation associé à  $X$ .

3) La représentation de Wold de  $X$  consiste à exprimer  $X_t$  comme somme de la série  $\varepsilon'_t + \sum_{u \geq 1} \psi_u \varepsilon'_{t-u}$ . La variance de  $\varepsilon'$  étant déjà connue, ne reste qu'à préciser la valeur des coefficients ( $\psi_u, u \geq 1$ ). Si l'on note  $\psi(B) = I + \sum_{u \geq 1} \psi_u B^u$ , alors  $\psi(B) = \phi(B)^{-1} \circ \theta'(B)$ . Sa transformée en  $z$  vaut donc :

$$\begin{aligned} \psi(z) &= 1 + \sum_{u \geq 1} \psi_u z^u \\ &= \frac{\theta'(z)}{\phi(z)} \\ &= \frac{(1 - 0,5z)(1 + \frac{2}{3}z)}{1 - 0,8z} \\ &= \frac{13}{48} \frac{1}{1 - 0,8z} + \frac{35}{48} + \frac{5}{12}z \\ &= 1 + \frac{19}{30}z + \sum_{u \geq 2} \frac{13}{48}(0,8)^u z^u \end{aligned}$$

Il appert ainsi que

$$\begin{aligned}
\psi(B) &= I + \frac{19}{30}B + \sum_{u \geq 2} \frac{13}{48}(0,8)^u B^u \\
X_t &= \psi(B)(\varepsilon')_t \\
&= I(\varepsilon')_t + \frac{19}{30}B(\varepsilon')_t + \sum_{u \geq 2} \frac{13}{48}(0,8)^u B^u(\varepsilon')_t \\
&= \varepsilon'_t + \frac{19}{30}\varepsilon'_{t-1} + \sum_{u \geq 2} \frac{13}{48}(0,8)^u \varepsilon'_{t-u}
\end{aligned}$$

4) La densité spectrale de  $X$  vaut

$$\begin{aligned}
f_X(\lambda) &= \left| \frac{\theta'(\lambda)}{\phi(\lambda)} \right|^2 f_{\varepsilon'}(\lambda) \\
&= \left| \frac{(1 - 0,5e^{i\lambda})(1 + \frac{2}{3}e^{i\lambda})}{1 - 0,8e^{i\lambda}} \right|^2 \frac{9}{4} \frac{1}{2\pi} \\
&= \frac{(1 - 0,5e^{i\lambda})(1 - 0,5e^{-i\lambda})(1 + \frac{2}{3}e^{i\lambda})(1 + \frac{2}{3}e^{-i\lambda})}{(1 - 0,8e^{i\lambda})(1 - 0,8e^{-i\lambda})} \frac{9}{4} \frac{1}{2\pi} \\
&= \frac{(1,25 - \cos \lambda)(1 + \frac{4}{9} + \frac{4}{9} \cos \lambda)}{1,64 - 1,6 \cos \lambda} \frac{9}{8\pi} \\
&= \frac{(1,25 - \cos \lambda)(13 + 4 \cos \lambda)}{8\pi(1,64 - 1,6 \cos \lambda)}
\end{aligned}$$

où l'on a noté  $\theta'(\lambda)$  et  $\phi(\lambda)$  les fonctions de transfert associées aux filtres  $\theta'(B)$  et  $\phi(B)$ .

**Exercice 4.** *Exercice le plus difficile de l'épreuve, noté sur 8 points, personne ne l'a traité en totalité. Là encore, des erreurs ont été presque systématiques dans la manipulation des indices de sommation à la question 2).*

1) Le modèle est causal, comme tout modèle  $MA(q)$ , car  $X_t$  s'exprime comme combinaison linéaire des variables  $\varepsilon_s$  d'indice  $s$  inférieur à  $t$ . Il est inversible car  $1 + \theta z$ , la transformée en  $z$  du filtre moyenne mobile  $MA(1)$   $I + \theta B$ , a pour racine  $-1/\theta$  de module plus grand que 1. Le modèle caractérisant  $X$  en fonction de  $\varepsilon$  étant causal et inversible, on en déduit que  $\varepsilon$  est le bruit blanc d'innovation de  $X$ ; autrement dit, que  $\varepsilon_i = X_i - P_{X_{i-1}, X_{i-2}, \dots}^\perp(X_i)$ . En conséquence,  $\varepsilon_i$  est décorrélée avec toute variable  $X_j$  avec  $j < i$ , en particulier avec  $X_1, \dots, X_{i-1}$ . Comme  $\tilde{\varepsilon}_j$  est combinaison affine de  $X_1, \dots, X_j$ , on en déduit que  $\varepsilon_i$  est aussi décorrélé avec  $\tilde{\varepsilon}_j$  dès que  $j$  est strictement inférieur à  $i$ . *Attention: si  $\varepsilon_i$  et  $\tilde{\varepsilon}_i$  sont décorrélées avec  $X_j$  pour  $j < i$ , c'est faux pour  $j \geq i$ . Bien des erreurs, notamment à la question 3) viennent de la confusion.*

2) La formule demandée a été vue en cours, mais non démontrée. Pour le faire, calculons  $\text{cov}(X_i, \tilde{\varepsilon}_{i-j})$ :

$$\begin{aligned}
\text{cov}(X_i, \tilde{\varepsilon}_{i-j}) &= \text{cov}\left(\tilde{\varepsilon}_i + \sum_{k=1}^{i-1} \psi_{i,k} \tilde{\varepsilon}_{i-k}, \tilde{\varepsilon}_{i-j}\right) \\
&= \text{cov}(\tilde{\varepsilon}_i, \tilde{\varepsilon}_{i-j}) + \sum_{k=1}^{i-1} \psi_{i,k} \text{cov}(\tilde{\varepsilon}_{i-k}, \tilde{\varepsilon}_{i-j})
\end{aligned}$$

Or il a été établi en cours que les variables  $(\tilde{\varepsilon}_l, l \geq 1)$  sont décorrélées. On en déduit que dans la somme précédente tous les termes sont nuls sauf celui pour lequel  $k = j$ . D'où

$$\text{cov}(X_i, \tilde{\varepsilon}_{i-j}) = \psi_{i,j} \quad \text{cov}(\tilde{\varepsilon}_{i-j}, \tilde{\varepsilon}_{i-j}) = \psi_{i,j} \tilde{\sigma}_{i-j}^2$$

Il en résulte la formule attendue. Si, de plus,  $j$  est supérieur ou égal à 2, alors

$$\begin{aligned} \text{cov}(X_i, \tilde{\varepsilon}_{i-j}) &= \text{cov}(\varepsilon_i + \theta \varepsilon_{i-1}, \tilde{\varepsilon}_{i-j}) \\ &= \text{cov}(\varepsilon_i, \tilde{\varepsilon}_{i-j}) + \theta \text{cov}(\varepsilon_{i-1}, \tilde{\varepsilon}_{i-j}) \\ &= 0 + 0, \end{aligned}$$

car d'après le 1),  $\varepsilon_i$  et  $\varepsilon_{i-1}$  sont décorrélés avec  $\tilde{\varepsilon}_{i-j}$ . Il s'ensuit que  $\psi_{i,j} = 0$  si  $j \geq 2$ .

3) Les formules de récurrence sont celles qui apparaissent dans l'algorithme des innovations. Pour obtenir la première, on calcule  $\text{cov}(X_{i+1}, X_i)$ :

$$\begin{aligned} \gamma_X(1) &= \text{cov}(X_{i+1}, X_i) \\ &= \text{cov}(\tilde{\varepsilon}_{i+1} + \psi_{i+1} \tilde{\varepsilon}_i, \tilde{\varepsilon}_i + \psi_i \tilde{\varepsilon}_{i-1}) \\ &= \text{cov}(\tilde{\varepsilon}_{i+1}, \tilde{\varepsilon}_i) + \psi_i \text{cov}(\tilde{\varepsilon}_{i+1}, \tilde{\varepsilon}_{i-1}) + \psi_{i+1} \text{cov}(\tilde{\varepsilon}_i, \tilde{\varepsilon}_i) + \psi_{i+1} \psi_i \text{cov}(\varepsilon_i, \tilde{\varepsilon}_{i-1}) \\ &= \psi_{i+1} \text{cov}(\tilde{\varepsilon}_i, \tilde{\varepsilon}_i) = \psi_{i+1} \tilde{\sigma}_i^2 \end{aligned}$$

où l'on s'est encore servi du fait que les  $(\tilde{\varepsilon}_k, k \geq 1)$  sont décorrélés. La deuxième formule s'obtient en calculant la variance de  $X_{i+1}$ :

$$\gamma_X(0) = \text{var}(X_{i+1}) = \text{var}(\tilde{\varepsilon}_{i+1} + \psi_{i+1,1} \tilde{\varepsilon}_i) = \text{var}(\tilde{\varepsilon}_{i+1}) + \psi_{i+1,1}^2 \text{var}(\tilde{\varepsilon}_i) = \tilde{\sigma}_{i+1}^2 + \psi_{i+1,1}^2 \tilde{\sigma}_i^2$$

D'où le résultat.

Montrons maintenant les formules explicites données pour  $\psi_{i,1}$  et  $\tilde{\sigma}_i^2$  par induction. Posons comme hypothèse de récurrence:

H(i):

$$\begin{aligned} \psi_{j,1} &= \theta \frac{1 - \theta^{2(j-1)}}{1 - \theta^{2j}} \quad \forall j = 2, \dots, i \\ \tilde{\sigma}_j^2 &= \sigma_\varepsilon^2 \frac{1 - \theta^{2(j+1)}}{1 - \theta^{2j}} \quad \forall j = 1, \dots, i \end{aligned}$$

Montrons que H(1) est vraie: il suffit pour cela de vérifier que

$$\tilde{\sigma}_1^2 = \sigma_\varepsilon^2 \frac{1 - \theta^4}{1 - \theta^2}$$

Or, en effet:

$$\tilde{\sigma}_1^2 = \text{var}(\tilde{\varepsilon}_1) = \text{var}(X_1) = \text{var}(\varepsilon_1 + \theta \varepsilon_0) = \sigma_\varepsilon^2 (1 + \theta^2)$$

$$\sigma_\varepsilon^2 \frac{1 - \theta^{2(i+1)}}{1 - \theta^{2i}} \Big|_{i=1} = \sigma_\varepsilon^2 \frac{1 - \theta^4}{1 - \theta^2} = \sigma_\varepsilon^2 \frac{(1 - \theta^2)(1 + \theta^2)}{1 - \theta^2} = \sigma_\varepsilon^2 (1 + \theta^2)$$

Montrons ensuite que  $H(i) \implies H(i+1)$  pour tout  $i \geq 1$ . Supposons H(i) vraie. Alors, d'après les formules de récurrence établies précédemment, et sachant que

$$\gamma_X(1) = \text{cov}(X_1, X_0) = \text{cov}(\varepsilon_1 + \theta \varepsilon_0, \varepsilon_0 + \theta \varepsilon_{-1}) = \theta \text{cov}(\varepsilon_0, \varepsilon_0) = \theta \sigma_\varepsilon^2,$$

on a

$$\begin{aligned}
\psi_{i+1,1} &= \frac{\gamma_X(1)}{\tilde{\sigma}_i^2} \\
&= \frac{\theta \sigma_\varepsilon^2}{\sigma_\varepsilon^2 \frac{1-\theta^{2(i+1)}}{1-\theta^{2i}}} \\
&= \theta \frac{1-\theta^{2i}}{1-\theta^{2(i+1)}} \\
\tilde{\sigma}_{i+1}^2 &= \gamma_X(0) - \psi_{i+1,1}^2 \tilde{\sigma}_i^2 \\
&= \sigma_\varepsilon^2(1+\theta^2) - \left( \theta \frac{1-\theta^{2i}}{1-\theta^{2(i+1)}} \right)^2 \sigma_\varepsilon^2 \frac{1-\theta^{2(i+1)}}{1-\theta^{2i}} \\
&= \sigma_\varepsilon^2(1+\theta^2) - \sigma_\varepsilon^2 \theta^2 \frac{1-\theta^{2i}}{1-\theta^{2(i+1)}} \\
&= \sigma_\varepsilon^2 \frac{(1+\theta^2)(1-\theta^{2(i+1)}) - \theta^2(1-\theta^{2i})}{1-\theta^{2(i+1)}} \\
&= \sigma_\varepsilon^2 \frac{1-\theta^{2(i+2)}}{1-\theta^{2(i+1)}}
\end{aligned}$$

Ceci montre que  $H(i+1)$  est vraie. On en déduit que  $H(n)$  est vraie quel que soit  $n \geq 1$ . Ce qui démontre les formules demandées.

4) Comme  $\theta$  est de module strictement plus petit que 1, la limite de  $\theta^i$  vaut 0 quand  $i$  tend vers l'infini. D'où

$$\begin{aligned}
\lim_{i \rightarrow +\infty} \tilde{\sigma}_i^2 &= \sigma_\varepsilon^2 \\
\lim_{i \rightarrow +\infty} \psi_{i,1} &= \theta \\
\lim_{i \rightarrow +\infty} \psi_{i,k} &= \lim_{i \rightarrow +\infty} 0 = 0 \quad \forall k \geq 2
\end{aligned}$$

On en conclut que l'algorithme des innovations permet bien de retrouver les coefficients de la décomposition de Wold de  $X$ .