

Modélisation des séries temporelles

Séance 3

Compléments sur ARIMA, processus SARIMA

Frédéric Sur

<https://members.loria.fr/FSur/enseignement/modseries/>

1/31

Séance 3

- 1 Méthode de Box-Jenkins
 - Rappels
 - Prévission
- 2 Processus SARIMA
- 3 Quelques « règles » et compléments
 - Retour sur la significativité des paramètres
 - Retour sur la transformation par passage au log
 - Tests de Dickey-Fuller
 - Astuces et critères pour l'identification des modèles
- 4 Conclusion

2/31

Modélisation des chroniques par (S)ARIMA

- soit la chronique est stationnaire
(*propriétés statistiques invariantes au cours du temps*)
→ modélisation AR / MA / ARMA.
- soit elle ne l'est pas
(*tendance stochastique / marche aléatoire, ou tendance déterministe*)
→ on commence par dériver pour stationnariser.

3/31

Méthode de Box-Jenkins : rappel

- 1 **Transformation** (éventuelle) de la chronique
(généralement log) pour « se ramener » au modèle additif.
- 2 **Identification** des paramètres p, d, q .
→ identification des ordres p et q avec fonctions Acf et Pacf (fonction `tsdisplay`), éventuellement différenciée à l'ordre d au préalable.
- 3 **Estimation** des θ_j, ϕ_i, μ (ou constant) et σ .
(fonction `Arima`)
- 4 **Validation** du modèle.
→ gaussianité des résidus (ACF, Portmanteau, graphe des résidus), significativité des coefficients, σ .
(fonctions `tsdiag, coeftest...`)
- 5 **Prévission** du futur.
(fonction `forecast`, aujourd'hui)

4/31

Prévision avec modèle ARIMA(p,d,q) (1)

Rappel : processus ARIMA

$$\Phi(B) \left((1-B)^d X_t - \mu \right) = \Theta(B) \varepsilon_t$$

ou :

$$\Psi(B) X_t = \theta_0 + \Theta(B) \varepsilon_t$$

c'est-à-dire (pour simplifier, on suppose $\theta_0 = 0$) :

$$X_t = \psi_1 X_{t-1} + \dots + \psi_{p+d} X_{t-p-d} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

Prévision : on connaît (X_t) jusque la date $t = T$, on cherche une prévision $\hat{X}_T(h)$ de X à un horizon de h après la date T .

Prévision avec modèle ARIMA(p,d,q) (2)

Pour tout t' , on définit $\hat{X}_{t'}(h) = \mathbb{E}(X_{t'+h} | (X_t)_{t \leq t'})$.

→ projection : « meilleure » approximation de $X_{t'+h}$ par combinaison linéaire des $(X_t)_{t \leq t'}$ (cf. séance 2)

Remarques : pour tout $t' \leq T$

- $\hat{X}_{t'}(h) = X_{t'+h}$ si $h \leq 0$.
- $\hat{\varepsilon}_{t'}(h) = \mathbb{E}(\varepsilon_{t'+h} | (X_t)_{t \leq t'}) = \varepsilon_{t'+h}$ si $h \leq 0$
et $\hat{\varepsilon}_{t'}(1) = 0$ car ε b.b.g.

De plus :
$$X_{t'+1} = \sum_{i=1}^{p+d} \psi_i X_{t'+1-i} + \varepsilon_{t'+1} - \sum_{j=1}^q \theta_j \varepsilon_{t'+1-j}$$

Donc : $\hat{X}_{t'}(1) = X_{t'+1} - \varepsilon_{t'+1}$ (par projection)

soit : pour tout t , $\varepsilon_t = X_t - \hat{X}_{t-1}(1)$

→ cela va permettre l'estimation des ε_t pour $t \leq T$

Mais comment calcule-t-on les prévisions $\hat{X}_t(1)$, $\hat{X}_t(2)$, etc ?

5/31

6/31

Prévision avec modèle ARIMA(p,d,q) (3)

$$X_{T+h} = \sum_{i=1}^{p+d} \psi_i X_{T+h-i} + \varepsilon_{T+h} - \sum_{j=1}^q \theta_j \varepsilon_{T+h-j}$$

Donc, avec $h \geq 0$:

$$\hat{X}_T(h) = \sum_{i=1}^{p+d} \psi_i \hat{X}_T(h-i) - \sum_{j=h}^q \theta_j \varepsilon_{T+h-j}$$

car $\mathbb{E}(\varepsilon_{T+h-j} | (X_t)_{t \leq T}) = \varepsilon_{T+h-j}$ si $j \geq h$ et = 0 sinon.
($\varepsilon_{T+h-j} \in \text{Vect}(X_t)_{t \leq T}$ si $j \geq h$ et (ε_t) non corrélés).

Conséquence : formules d'actualisation avec les ψ_i , θ_j , ε_t :

$$\hat{X}_T(1) = \sum_{i=1}^{p+d} \psi_i X_{T+1-i} - \sum_{j=1}^q \theta_j \varepsilon_{T+1-j}$$

$$\hat{X}_T(2) = \psi_1 \hat{X}_T(1) + \sum_{i=2}^{p+d} \psi_i X_{T+2-i} - \sum_{j=2}^q \theta_j \varepsilon_{T+2-j}$$

etc.

forecast R : I.C. pour $\hat{X}_T(h)$ sous hypothèse de normalité des ε_t

7/31

Séance 3

1 Méthode de Box-Jenkins

- Rappels
- Prévision

2 Processus SARIMA

3 Quelques « règles » et compléments

- Retour sur la significativité des paramètres
- Retour sur la transformation par passage au log
- Tests de Dickey-Fuller
- Astuces et critères pour l'identification des modèles

4 Conclusion

8/31

Cas des chroniques périodiques, période π

Remarque 1 : X_t peut ne pas être stationnaire à cause d'un comportement du type :

$$X_t = S_t + u_t \quad (S_t \text{ déterministe } \pi\text{-périodique})$$

ou

$$X_t = \mu + X_{t-\pi} + u_t \quad (\text{cf marche aléatoire})$$

→ on peut stationnariser en étudiant $(1 - B^\pi)X_t$.

Remarque 2 : des corrélations saisonnières (période π) peuvent être présentes dans la chronique X_t

(corrélations / corrélations partielles aux décalages de $\pi, 2\pi, 3\pi \dots$)

→ ARMA *saisonnier* :

$$\phi(B^\pi)X_t = \theta(B^\pi)\varepsilon_t$$

Les processus SARIMA

Définition : processus SARIMA(p, d, q)(P, D, Q) $_\pi$

Ce sont les processus (X_t) :

$$\Phi_p(B)\Phi_P(B^\pi) \left((1 - B)^d(1 - B^\pi)^D X_t - \mu \right) = \Theta_q(B)\Theta_Q(B^\pi)\varepsilon_t$$

où $p, d, q, P, D, Q \geq 0$, π est la période de la saisonnalité et (ε_t) est un bruit blanc gaussien.

Autre notation : $(1 - B)^d(1 - B^\pi)^D X_t = \mu + \frac{\Theta_q(B)\Theta_Q(B^\pi)}{\Phi_p(B)\Phi_P(B^\pi)}\varepsilon_t$

Intérêt : traiter les chroniques non-stationnaires, avec tendance et saisonnalité ou comportement style « marche aléatoire ».

Remarque : SARIMA = ARIMA particulier, mais la factorisation limite le nombre de coefficients à estimer.
(cf *parcimonie, rasoir d'Ockham*)

9/31

10/31

Exemples

- ① processus SARIMA(1, 0, 2)(1, 1, 0) $_4$:
(chronique trimestrielle, période annuelle)

$$(1 - \phi_1 B)(1 - \phi_1' B^4)(1 - B^4)X_t = \theta_0 + (1 - \theta_1 B - \theta_2 B^2)\varepsilon_t$$

ou

$$(1 - \phi_1 B)(1 - \phi_1' B^4) \left((1 - B^4)X_t - \mu \right) = (1 - \theta_1 B - \theta_2 B^2)\varepsilon_t$$

- ② processus SARIMA(0, 1, 1)(1, 0, 0) $_{12}$:
(chronique mensuelle, période annuelle)

$$(1 - \phi_1' B^{12})(1 - B)X_t = \theta_0 + (1 - \theta_1 B)\varepsilon_t$$

ou

$$(1 - \phi_1' B^{12}) \left((1 - B)X_t - \mu \right) = (1 - \theta_1 B)\varepsilon_t$$

Identification des modèles

TP précédent : identification des ordres des processus ARIMA selon ACF et PACF.

TP aujourd'hui : identification des ordres des processus SARIMA : on **regarde ACF et PACF aux décalages** $\pi, 2\pi, 3\pi \dots$
(en pratique, pour saisonnalité annuelle : décalages 12 et 24)

Important : on cherche des modèles *simples*...

11/31

12/31

Cas AR/MA + SAR/SMA

Remarque : on commence par regarder ACF/PACF pour « petits décalages » ($h \leq 6$), on identifie AR/MA, puis ACF/PACF pour $h = 12, 24, 36$ et identification SAR/SMA.

(pour se débarrasser de l'influence des corrélations « court termes » sur la composante saisonnière)

Exemple : $X_t = (1 - \theta_1 B)(1 - \theta_1' B^{12})\varepsilon_t$

alors : $X_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_1' \varepsilon_{t-12} + \theta_1 \theta_1' \varepsilon_{t-13}$

$$\text{donc : } \begin{cases} \gamma(11) = \text{Cov}(X_t, X_{t-11}) = \theta_1 \theta_1' \\ \gamma(12) = \text{Cov}(X_t, X_{t-12}) = -\theta_1' - \theta_1^2 \theta_1' \\ \gamma(13) = \text{Cov}(X_t, X_{t-13}) = \theta_1 \theta_1' \end{cases}$$


Mais si on identifie un premier modèle AR de résidus Y :

$X_t = (1 - \theta_1 B)Y_t$, donc $Y_t = (1 - \theta_1' B^{12})\varepsilon_t$

$$\text{et : } \begin{cases} \gamma(11) = \text{Cov}(Y_t, Y_{t-11}) = 0 \\ \gamma(12) = \text{Cov}(Y_t, Y_{t-12}) = -\theta_1' \\ \gamma(13) = \text{Cov}(Y_t, Y_{t-13}) = 0 \end{cases}$$

→ ACF plus lisible pour identifier SMA

ACF et PACF pour (S)AR(1) et (S)MA(1)



14/31

13/31

Séance 3

1 Méthode de Box-Jenkins

- Rappels
- Prédiction

2 Processus SARIMA

3 Quelques « règles » et compléments

- Retour sur la significativité des paramètres
- Retour sur la transformation par passage au log
- Tests de Dickey-Fuller
- Astuces et critères pour l'identification des modèles

4 Conclusion

15/31

Retour sur la significativité des paramètres du modèle

On estime un paramètre du modèle à partir de la chronique, réalisation d'un processus aléatoire :

→ variable aléatoire \bar{X} d'espérance μ

($\mu =$ « vraie » valeur si estimateur non biaisé)

→ l'estimation par Arima donne **une** valeur x (une réalisation)

L'erreur-type (*standard error se*) est l'estimation de l'écart-type de l'estimateur (calculé par Arima)

Exemple : estimation de la moyenne μ d'un échantillon i.i.d.

$$\bar{X} = \frac{1}{N} \sum_{k=1}^N X_k$$

si σ écart-type des X_k alors $\text{std}(\bar{X}) = \sigma / \sqrt{N}$

on calcule x et se empiriques (estimations de μ et $\text{std}(\bar{X})$)

16/31

z-test

Si ε_t est un b.b.g., et \bar{X} est l'estimateur d'un paramètre du modèle (par exemple selon maximum de vraisemblance), la statistique de test

$$Z = (\bar{X} - \mu) / \text{std}(\bar{X})$$

est distribuée selon une loi normale centrée réduite.

Test d'hypothèse (z-test) : $\mathcal{H}_0 : \mu = 0$

on calcule la p -valeur : $\Pr_{\mathcal{H}_0}(|Z| > |x|/se)$

Z distribuée selon une loi de Student (ou normale, cf. help coefstest)

Si p -valeur $< 5\%$, alors on rejette \mathcal{H}_0

→ il est peu probable que les fluctuations d'échantillonnage seules puissent expliquer une valeur aussi grande de $|x|/se$,

$\mu \neq 0$ est sans doute une meilleure explication

→ le paramètre est dit *significatif*

(c'est-à-dire significativement non nul)

17/31

Intervalle de confiance

Risque α (= 5%)

$Z = (\bar{X} - \mu) / \text{std}(\bar{X})$ suit une loi normale

Soit $z_\alpha > 0$ t.q. $\Pr(|Z| < z_\alpha) = 1 - \alpha$

(exemple : si $\alpha = 5\%$, alors $z_\alpha \simeq 2$)

alors : $\Pr(-z_\alpha \leq (\bar{X} - \mu) / \text{std}(\bar{X}) \leq z_\alpha) = 1 - \alpha$

d'où : $\Pr(\bar{X} - z_\alpha \text{std}(\bar{X}) \leq \mu \leq \bar{X} + z_\alpha \text{std}(\bar{X})) = 1 - \alpha$

→ il y a donc une probabilité $1 - \alpha$ que μ soit dans l'intervalle (aléatoire...) $\bar{X} \pm z_\alpha \text{std}(\bar{X})$

Conclusion : l'intervalle de confiance du paramètre estimé au risque α est : $x \pm z_\alpha se$

→ fonction coefci

Remarque : 0 est dans l'I.C. \Leftrightarrow le paramètre est non-significatif

Preuve : 0 dans I.C. $\Leftrightarrow x - z_\alpha se < 0$ et $x + z_\alpha se > 0$

$\Leftrightarrow |x|/se < z_\alpha$


$\Leftrightarrow \Pr_{\mathcal{H}_0}(Z < |x|/se) < 1 - \alpha$

$\Leftrightarrow \Pr_{\mathcal{H}_0}(Z > |x|/se) > \alpha$

18/31

Remarque : transformation de (X_t) ...

Exemple : chronique airline




→ passage au log...

19/31

Passage au log

Exemple : logarithme de la chronique airline



→ modèle additif avec tendance.

Question : *quid* de la prévision sur airline ?

20/31

Étude de $Y_t = \log(X_t)$

Hypothèse : $Y_\tau \sim \mathcal{N}(\hat{Y}_\tau, \hat{\sigma}_\tau^2)$ ($\tau > T$)


forecast : fournit la prévision \hat{Y}_τ
+ intervalle de confiance $[L_\tau, U_\tau]$ (centré sur \hat{Y}_τ).

Question : intervalle et prévision pour $X_\tau = \exp(Y_\tau)$?


- Comme exp est croissante :
 $\Pr(\exp(Y_\tau) \in [\exp(L_\tau), \exp(U_\tau)]) \leq 95\%$.
Donc « intervalle de confiance » au risque 5% :
 $[\exp(L_\tau), \exp(U_\tau)]$.
- Prévision ?
Naïf : $\hat{X}_\tau = \exp(\hat{Y}_\tau)$
Mieux : $\hat{X}_\tau = \mathbb{E}(X_\tau) = \exp(\hat{Y}_\tau + \hat{\sigma}_\tau^2/2)$
car X_τ suit une loi log-normale.

Illustration : $Y_t = \log(X_t)$

$$\hat{Y}_\tau = 0, \quad \hat{\sigma}_\tau = 1.$$



loi de Y_τ (normale)



loi de X_τ (log-normale)

Ici : $\hat{Y}_\tau = 0$, I.C. risque 5% : $[-1.96, 1.96]$.

Prévision sur X_τ : I.C. risque 5% : $[0.14, 7.1]$

$$\exp(\hat{Y}_\tau) = 1$$

$$\hat{X}_\tau = \exp(\hat{Y}_\tau + \hat{\sigma}_\tau^2/2) = 1.6$$

Remarque : bien sûr, correction négligeable si $\hat{\sigma}_\tau^2/2 \ll \hat{Y}_\tau$

21/31

22/31

Tests de Dickey-Fuller

Objectif : test de stationnarité

On réécrit les processus AR + tendance :

$$X_t = \alpha + \beta t + \sum_{i=1}^p \phi_i X_{t-i} + \varepsilon_t$$

sous la forme :

$$\Delta X_t = \alpha + \beta t + (\rho_1 - 1)X_{t-1} + \rho_2 \Delta X_{t-1} + \dots + \rho_p \Delta X_{t-p+1} + \varepsilon_t$$

Propriété : $(X_t - \alpha - \beta t)$ non stationnaire $\Leftrightarrow \rho_1 = 1$.

Les tests augmentés de Dickey-Fuller fournissent la p-valeur de $\hat{\rho}_1/se$ ($\mathcal{H}_0 : \rho_1 = 1$) pour différentes valeurs de p dans les cas suivants :

- type 1 : $\alpha = \beta = 0$
- type 2 : $\alpha \neq 0, \beta = 0$
- type 3 : $\alpha \neq 0, \beta \neq 0$

En pratique : a priori on ne connaît ni le type, ni p ...

→ cf poly p. 58 (attention coquille $\Delta X_t = \dots$ dans types 1,2,3)

Quelques « règles » complémentaires : différentiation (1)

- ordre de différentiation saisonnière : $D = 0$ ou $D = 1$.
- ordre de différentiation totale (saisonnière D & non-saisonnière d) : $d + D \leq 2$.
- si la décroissance de l'ACF est lente, penser à différencier plutôt qu'introduire un AR.
- si l'ACF est périodique (effet « pont suspendu »), alors différentiation saisonnière.
→ si X_t π -périodique, alors $\hat{\rho}(h)$ aussi.

23/31

24/31

Quelques « règles » complémentaires : différentiation (2)

- si ACF pour décalage 1 est « franchement » négatif, la chronique est sans doute trop différenciée.
→ enlever un ordre de dérivation plutôt qu'introduire un MA.

« Justification » :

si X_t déjà stationnaire et $Y_t = (1 - B)X_t$, alors :

$$\gamma_Y(1) = 2\gamma_X(1) - \gamma_X(0) - \gamma_X(2)$$

$$\gamma_Y(0) = 2\gamma_X(0) - 2\gamma_X(1)$$


$$\text{donc } \rho_Y(1) = -\frac{1}{2} \left(\frac{1 - 2\rho_X(1) + \rho_X(2)}{1 - \rho_X(1)} \right)$$

et on est conduit à introduire un MA(1)...

Pourquoi éviter de trop différencier ?

Cf intervalles de confiance de la prévision...


Exemple :



$$(1 - 0.805B)Y_t = 0.3939 + \varepsilon_t$$

($\sigma = 1.002$)

ou $(1 - 0.805B)(Y_t - 2.02) = \varepsilon_t$



$$(1 - B)Y_t = -0.011 + \varepsilon_t$$

($\sigma = 1.052$)

Quelques « règles » complémentaires : la constante / moyenne

$$\Phi_p(B)\Phi_p(B^\pi) \left((1 - B)^d(1 - B^\pi)^D X_t - \underline{m} \right) = \Theta_q(B)\Theta_q(B^\pi)\varepsilon_t$$

- chronique différenciée à l'ordre 1 :
constante = pente de la tendance.
On peut avoir une constante nulle
(ex : marche aléatoire)
ou pas
(ex : marche aléatoire avec dérive, tendance « $at + b$ »)
(pas très fréquent : ...constante nulle par défaut dans Arima)
- chronique différenciée à l'ordre 2 (la pente « varie ») :
constante = coef du terme quadratique.
(tendance quadratique rare, donc *constante nulle* dans ce cas)

Quelques « règles » complémentaires : divers

- éviter de mélanger SAR et SMA.
- les termes en AR et MA peuvent se compenser.
Ex : si ARIMA(2, d, 1) identifié,
on peut essayer ARIMA(1, d, 0)
(cas où les racines de AR et MA se « compensent »).

Sélection de modèle

Question : comment choisir entre différents modèles
ARIMA(p,d,q) valides?

Plusieurs possibilités :

- Minimisation de la variance des résidus σ^2
→ mais plus le modèle est « compliqué » (p,d,q grands), plus σ est faible. . .

- Minimisation de *critères d'information* :

$$\text{AIC} = -2 \log(\mathcal{L}) + 2k \quad (\text{Akaïke})$$

$$\text{ou AICc} = \text{AIC} + \frac{2k(k+1)}{T-k-1} \quad (\text{correction selon } T)$$

$$\text{ou BIC} = \text{SBC} = -2 \log(\mathcal{L}) + k \log(T) \quad (\text{Schwarz Bayes})$$

→ compromis entre vraisemblance \mathcal{L} et nombre de paramètres estimés
($k = p + q + 1 + 0/1$ si ARIMA(p,d,q) complet)

Remarque 1 : « le » choix entre différents modèles se fait selon **un** critère.

Remarque 2 : on préfère les modèles simples (principe du *rasoir d'Ockham* ou de *parcimonie*).

29/31

Séance 3

- 1 Méthode de Box-Jenkins
 - Rappels
 - Prévision
- 2 Processus SARIMA
- 3 Quelques « règles » et compléments
 - Retour sur la significativité des paramètres
 - Retour sur la transformation par passage au log
 - Tests de Dickey-Fuller
 - Astuces et critères pour l'identification des modèles
- 4 Conclusion

30/31

Tous les modèles sont faux . . .
mais certains sont utiles !

“Remember that all models are wrong; the practical question is how wrong do they have to be to not be useful.”

George E. P. Box, Norman R. Draper
Empirical Model-Building and Response Surface,
Wiley, 1987.

Pour la prochaine séance : début de l'étude de la chonique ozone.

31/31