

## Modélisation et prévision

### Séries chronologiques - Séance 2 Les processus ARIMA

Frédéric Sur  
École des Mines de Nancy

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

## Motivation / objectif

Box et Jenkins 1970 (à la suite de Yule et Slutsky 1927) :

*de nombreuses phénomènes temporels (ou leur dérivée), dans de nombreux domaines, peuvent être représentés par des processus stationnaires.*

### Rappel :

les processus stationnaires considérés sont de la forme

$$X_t = m + \sum_{j=0}^{+\infty} a_j \varepsilon_{t-j}$$

avec  $\sum_{j=0}^{+\infty} |a_j| < +\infty$  et  $(\varepsilon_t)$  **bruit blanc** (faible)

En fait  $(\varepsilon_t)$  sera même généralement un bruit blanc *gaussien*.

→ on parle de *processus linéaire gaussien*.

## Séance 2

- 1 Processus stationnaires
  - Processus MA
  - Processus AR
  - Processus ARMA
- 2 Processus non stationnaires
  - Processus ARIMA
  - Processus SARIMA
- 3 La méthode de Box-Jenkins
  - Identification
  - Estimation
  - Validation
  - Prévision
- 4 Sous SAS
- 5 Conclusion

## Séance 2

- 1 Processus stationnaires
  - Processus MA
  - Processus AR
  - Processus ARMA
- 2 Processus non stationnaires
  - Processus ARIMA
  - Processus SARIMA
- 3 La méthode de Box-Jenkins
  - Identification
  - Estimation
  - Validation
  - Prévision
- 4 Sous SAS
- 5 Conclusion

## Les processus MA (=moyenne mobile)

**Définition** : processus MA( $q$ ) (Slutsky 1927)

Ce sont les processus ( $X_t$ ) du type :

$$\forall t, X_t = m + \varepsilon_t - \sum_{i=1}^q \theta_i \varepsilon_{t-i}$$

où  $q \geq 1$ ,  $(\theta_i)_{1 \leq i \leq q}$  réels, et  $(\varepsilon_t)$  est un bruit blanc (**gaussien** dans notre cours).

### Convention d'écriture

$$X_t - m = \Theta(B)\varepsilon_t$$

où  $\Theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$   
et  $B$  est l'opérateur retard :  $B^k \varepsilon_t = \varepsilon_{t-k}$ .

**Remarque** : les processus MA( $q$ ) sont **stationnaires**.

## Caractérisation de l'ordre d'un MA( $q$ )

$$\forall h \geq 0, \rho(h) = \frac{\text{Cov}(X_t, X_{t+h})}{\sqrt{\text{Var}(X_t)\text{Var}(X_{t+h})}} = \frac{\gamma(h)}{\gamma(0)}$$

Pour un processus MA( $q$ ) : (calcul algébrique simple)

$$\gamma(h) = \begin{cases} (1 + \theta_1^2 + \dots + \theta_q^2) \sigma^2 & \text{si } h = 0 \\ (\theta_h + \theta_{h+1}\theta_1 + \dots + \theta_q\theta_{q-h}) \sigma^2 & \text{si } 1 \leq h \leq q \\ 0 & \text{si } h > q \end{cases}$$

**Propriété** : fonction d'autocorrélation (ACF) d'un MA( $q$ )

$$\rho(h) = \begin{cases} 1 & \text{si } h = 0 \\ \frac{\theta_h + \theta_{h+1}\theta_1 + \dots + \theta_q\theta_{q-h}}{\theta_1^2 + \dots + \theta_q^2} & \text{si } 1 \leq h \leq q \\ 0 & \text{si } h > q \end{cases}$$


**Intérêt** : détermination de  $q$ .

## Espérance conditionnelle si ( $X_t$ ) gaussien

**Définition** ("rappel") : espérance conditionnelle

$$\mathbb{E}(X_t | X_{t-1}, \dots, X_{t-h}) = a_1(h)X_{t-1} + \dots + a_h(h)X_{t-h}$$

est la « meilleure » approximation de  $X_t$  par une combinaison linéaire de  $(X_{t-1}, \dots, X_{t-h})$  dans  $L^2$  muni du produit scalaire  $\langle X, Y \rangle = \mathbb{E}(XY)$ .  
(cf régression)



## Fonction d'autocorrélation partielle (PACF)

( $X_t$ ) stationnaire donc dans  $(L^2, \mathbb{E}(XY))$ .

$$\mathbb{E}(X_t | X_{t-1}, \dots, X_{t-h}) = a_1(h)X_{t-1} + \dots + a_h(h)X_{t-h}$$

**Définition** : PACF de ( $X_t$ )

Le terme  $r(h) = a_h(h)$  est la *corrélation partielle* d'ordre  $h$ .

**Propriété** (cf poly : géométrie dans un espace de Hilbert)

$$\forall h \geq 1, a_h(h) = \text{corr}(\tilde{X}_t, \tilde{X}_{t-h})$$

où :  $\tilde{X}_t = X_t - \mathbb{E}(X_t | X_{t-1}, \dots, X_{t-h+1})$   
et :  $\tilde{X}_{t-h} = X_{t-h} - \mathbb{E}(X_{t-h} | X_{t-1}, \dots, X_{t-h+1})$

**Interprétation** : corrélation entre  $X_t$  et  $X_{t-h}$  lorsque l'influence des variables  $X_{t-1}, \dots, X_{t-h+1}$  a été retirée.

## Retour aux processus MA(q)

L'expression générale du PACF d'un processus MA(q) est compliquée.

**Cas particulier** : MA(1)

$$\forall t, X_t = m + \varepsilon_t + \theta \varepsilon_{t-1}.$$

alors :

$$r(h) = a_h(h) = \frac{\theta^h(\theta^2 - 1)}{1 - \theta^{2h+2}}.$$

→  $(|r(h)|)_{h \geq 1}$  décroît de manière exponentielle (si  $\theta \neq 1$ ).

## Résumé : les processus MA (moyennes mobiles)

### Définition : processus MA(q)

$$X_t = m + \varepsilon_t - \sum_{i=1}^q \theta_i \varepsilon_{t-i}$$

$$X_t - m = \Theta(B)\varepsilon_t$$

avec  $\Theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ .

### Propriété

Un processus MA(q) est stationnaire.

### Corrélogrammes :

- ACF :  $\rho(h) = 0$  si  $h > q$ ,
- PACF :  $r(h)$  tend vers 0. ( $q = 1$  « vitesse exponentielle »)

→ permet l'identification d'un MA(q).

## Les processus AR (=autorégressif)

### Définition : processus AR(p) (Yule 1927)

Ce sont les processus  $(X_t)$  du type :

$$\forall t, X_t = c + \sum_{i=1}^p \phi_i X_{t-i} + \varepsilon_t$$

où  $p \geq 1$ ,  $(\phi_i)_{1 \leq i \leq p}$  réels, et  $(\varepsilon_t)$  est un bruit blanc (gaussien).

**Convention d'écriture** : (constante  $c$  vs. moyenne  $m$ )

$$\Phi(B)X_t = c + \varepsilon_t \quad \text{ou : } \Phi(B)(X_t - m) = \varepsilon_t$$

avec  $\Phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$  ( $B$  : opérateur retard)  
et :  $(1 - \phi_1 - \dots - \phi_p)m = c$

**Question** : un processus AR(p) est-il stationnaire ?

## Exemple : processus AR(1)

$$\forall t, X_t = \phi X_{t-1} + \varepsilon_t \quad (\text{ou } (1 - \phi B)X_t = \varepsilon_t)$$


Exemple-type, car :

$$\Phi(B)X_t = \varepsilon_t \Leftrightarrow \prod_{i=1}^p (1 - \phi_i B) X_t = \varepsilon_t$$

- si  $|\phi| < 1$  alors  
 $X_t = (1 + \phi B + \phi^2 B^2 + \dots) \varepsilon_t$   
→  $(X_t)$  **stationnaire**, « équivalent » à MA( $\infty$ ).
- si  $|\phi| > 1$  alors  
 $X_t = -(\phi^{-1} B^{-1} + \phi^{-2} B^{-2} + \dots) \varepsilon_t$   
→  $(X_t)$  **stationnaire** (mais **non causal** sous cette forme).
- si  $\phi = 1$  (marche aléatoire) :  $X_t = X_{t-1} + \varepsilon_t$ .  
On a bien  $\forall t, \mathbb{E}(X_t) = \mathbb{E}(X_{t-1})$ .  
Mais  $\text{var}(X_t)$  dépend de  $t$  (non constante).  
→  $(X_t)$  **non-stationnaire**.

## Simulation de processus AR(1)

$(\varepsilon_t)$  i.i.d.  $\sim \mathcal{N}(0, 1)$



## Caractérisation de l'ordre d'un AR(p) stationnaire

**Propriété : PACF d'un processus AR(p)**

Si  $r(h)$  est la fonction d'autocorrélation partielle :

$$\forall h > p, r(h) = 0$$

*Preuve :*  $X_t = \sum_{i=1}^p \phi_i X_{t-i} + \sum_{i=p+1}^h 0 \cdot X_{t-i} + \varepsilon_t$ , puis projection sur  $(X_{t-1}, \dots, X_{t-h})$  sachant  $\varepsilon_t$  décorrélé de  $X_{t-1}, \dots, X_{t-h}$ .

**Intérêt :** détermination de  $p$ .

**Propriété : ACF d'un processus AR(p)**

$(|\rho(h)|)_{h \geq 1}$  décroît vers 0 de manière exponentielle.

*Preuve :* cf équations de Yule-Walker, qui permettent de retrouver les  $\phi_i$  à partir des  $\rho(h)$  (poly).

## Résumé : les processus AR (autorégressifs)

**Définition : processus AR(p)**

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

$$\Phi(B)(X_t - m) = \varepsilon_t \quad \Phi(B)(X_t) = c + \varepsilon_t$$

avec  $\Phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ .

**Propriété**

Un processus AR(p) est stationnaire si  $\Phi$  n'a pas de racine unité.

**Corrélogrammes :**

- ACF :  $\rho(h)$  décroît de « manière exponentielle » vers 0
- PACF :  $\forall h > p, r(h) = 0$

→ permet l'identification d'un AR(p).

## Les processus ARMA (=autorégressif moyenne mobile)

**Définition : processus ARMA(p,q)**

Ce sont les processus  $(X_t)$  du type :

$$\forall t, X_t = \theta_0 + \sum_{i=1}^p \phi_i X_{t-i} - \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t$$

où  $p \geq 1$ ,  $(\phi_i)_{1 \leq i \leq p}$  et  $(\theta_j)_{0 \leq j \leq q}$  réels, et  $(\varepsilon_t)$  b.b. gaussien.

**Notation symbolique :**  $\Phi(B)X_t = \theta_0 + \Theta(B)\varepsilon_t$ .

ou :  $\Phi(B)(X_t - \mu) = \Theta(B)\varepsilon_t$

avec :  $\theta_0 = \Phi(B)\mu$  ( $\theta_0$  joue le rôle de  $c$  dans proc. AR)

**Remarque :** si  $\Phi$  a ses racines à l'extérieur du cercle unité, alors on peut écrire :

$$X_t = \sum_{j=0}^{+\infty} a_j \varepsilon_{t-j} \quad (\text{sous forme MA}(+\infty) + \text{relations entre } a_j)$$

→ cf. principe de parcimonie.

## Séance 2

- 1 Processus stationnaires
  - Processus MA
  - Processus AR
  - Processus ARMA
- 2 Processus non stationnaires
  - Processus ARIMA
  - Processus SARIMA
- 3 La méthode de Box-Jenkins
  - Identification
  - Estimation
  - Validation
  - Préviation
- 4 Sous SAS
- 5 Conclusion

## Les processus non stationnaires

Forme générale d'une chronique (modèle linéaire) :

$$X_t = T_t + S_t + u_t.$$

avec  $T_t$  tendance,  $S_t$  saisonnalité,  $u_t$  perturbation aléatoire.

→  $(X_t)$  n'est pas stationnaire.

## Les processus ARIMA (=ARMA intégré)

Opérateur de différentiation :

$$\nabla X_t = X_t - X_{t-1} = (1 - B)X_t.$$

**Définition :** processus ARIMA( $p, d, q$ )

Ce sont les processus  $(X_t)$  du type :

$$\Phi(B)(1 - B)^d X_t = \theta_0 + \Theta(B)\varepsilon_t$$

où  $\Phi$  sans racine unitaire,  $p, d, q \geq 0$ ,  
et  $(\varepsilon_t)$  est un bruit blanc gaussien (écart-type  $\sigma$ ).

**Remarque :** processus ARIMA non stationnaires,  
mais  $d$  fixé tel que  $(1 - B)^d X_t$  stationnaire.

## Dérivation des processus

$$\text{ARIMA : } \Phi(B)(1 - B)^d X_t = \theta_0 + \Theta(B)\varepsilon_t$$

**Intérêt 1 :** permet de traiter les chroniques avec tendance.

- $X_t = at + b + u_t$  :  
alors  $(1 - B)X_t = a + (1 - B)u_t$  est stationnaire.
- $X_t = at^2 + bt + c + u_t$  :  
 $(1 - B)^2 X_t$  est stationnaire.
- etc.

**Intérêt 2 :** permet de stabiliser la variance.

- $X_t = X_{t-1} + u_t$  (marche aléatoire),  
alors  $(1 - B)X_t = u_t$  est stationnaire.

**Remarque :** dans les deux cas, *racine unité* dans la  
partie AR.

# Les processus SARIMA

Permettent de traiter le cas de la saisonnalité.

→ cf prochaine séance.

Modélisation et  
prévision

F. Sur - ENSMN

Processus  
stationnaires  
Processus MA  
Processus AR  
Processus ARMA

Processus non  
stationnaires  
Processus ARIMA  
Processus SARIMA

La méthode de  
Box-Jenkins

Identification  
Estimation  
Validation  
Prévision

Sous SAS

Conclusion

# Séance 2

- 1 Processus stationnaires
  - Processus MA
  - Processus AR
  - Processus ARMA
- 2 Processus non stationnaires
  - Processus ARIMA
  - Processus SARIMA
- 3 La méthode de Box-Jenkins
  - Identification
  - Estimation
  - Validation
  - Prévision
- 4 Sous SAS
- 5 Conclusion

Modélisation et  
prévision

F. Sur - ENSMN

Processus  
stationnaires  
Processus MA  
Processus AR  
Processus ARMA

Processus non  
stationnaires  
Processus ARIMA  
Processus SARIMA

La méthode de  
Box-Jenkins

Identification  
Estimation  
Validation  
Prévision

Sous SAS

Conclusion

21/35

22/35

# Modélisation des chroniques par (S)ARIMA

Comment modéliser une chronique  $X_t$  par un  $ARIMA(p,d,q)$  ?

→ méthode de Box et Jenkins (1970)

- 1 **Identification** des paramètres  $p, d, q$ .
- 2 **Estimation** des  $\theta_j, \phi_i$ , et  $\sigma$
- 3 **Validation** du modèle.
- 4 **Prévision** du futur.

Modélisation et  
prévision

F. Sur - ENSMN

Processus  
stationnaires  
Processus MA  
Processus AR  
Processus ARMA

Processus non  
stationnaires  
Processus ARIMA  
Processus SARIMA

La méthode de  
Box-Jenkins

Identification  
Estimation  
Validation  
Prévision

Sous SAS

Conclusion

# Identification du modèle $ARIMA(p,d,q)$

0. **Transformation** de la chronique (log, exp,  $\sqrt{\cdot}$ , Box-Cox) pour stabiliser la variance, passage au « modèle additif ».

1. **Identification** de  $d$ .

Indices de non-stationnarité :

- « ça se voit » sur le graphique (tendance),
- l'ACF ne décroît pas assez vite.

→ dériver.

Attention à ne pas *trop* dériver...

Si  $X_t$  déjà stationnaire, alors  $Y_t = X_t - X_{t-1}$  a tendance à présenter un  $\rho(1)$  (ACF) « proche » de  $-1$ .

(introduction d'autocorrélations négatives)

→ indication de  $d$  trop grand...

Modélisation et  
prévision

F. Sur - ENSMN

Processus  
stationnaires  
Processus MA  
Processus AR  
Processus ARMA

Processus non  
stationnaires  
Processus ARIMA  
Processus SARIMA

La méthode de  
Box-Jenkins

Identification  
Estimation  
Validation  
Prévision

Sous SAS

Conclusion

23/35

24/35

## Identification du modèle ARIMA(p,d,q)

### 2. Identification de p et q.

Utilisation des corrélogrammes.

Rappel :

	ACF	PACF
AR(p)	$\rho(h)$ : décroissance exponentielle vers 0	$r(h) = 0$ si $h > p$
MA(q)	$\rho(h) = 0$ si $h > q$	$r(h)$ décroissance ~ exponentielle vers 0

**Remarque 1** : on dispose des ACF et PACF empiriques. SAS donne des intervalles de confiance pour les  $\hat{\rho}(h)$  et  $\hat{r}(h)$ , on vérifie que « les pics ne sont pas significatifs ».

**Remarque 2** : si « vrai » ARMA(p,q), comme on se limitera à  $p, q \leq 2$ , on teste les différents modèles... (sinon méthodes plus sophistiquées, cf *méthode du coin*.)

## Estimation des paramètres $\theta_j, \phi_i, \sigma$ (1)

**Définition** : vraisemblance de la réalisation d'un v.a. X

Soit  $f_\theta$  la densité de X, et x une réalisation de X :

$$\mathcal{L}(x; \theta) = f_\theta(x)$$

( $\theta$  : paramètres de la densité d'un vecteur aléatoire)

Méthode du **maximum de vraisemblance** :


estimer  $\theta$  qui maximise  $\mathcal{L}(x; \theta)$ , connaissant x.

(idée : plus la vraisemblance est grande, plus il est probable que le modèle pour les  $(X_t)$  soit bon)

**Exemple** :  $x_1, x_2, \dots, x_n$

réalisations i.i.d. gaussiennes :

$$\mathcal{L}(x_1, x_2, \dots, x_n; \mu, \sigma) = \frac{1}{\sigma^n (2\pi)^{n/2}} \exp\left(-\frac{1}{2} \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma}\right)^2\right)$$



## Estimation des paramètres $\theta_j, \phi_i, \sigma$ (2)

$$\forall t, X_t = \theta_0 + \sum_{i=1}^p \phi_i X_{t-i} + \varepsilon_t - \sum_{j=1}^q \theta_j \varepsilon_{t-j}$$

**Hypothèse** :  $(\varepsilon_t)$  i.i.d.  $\sim \mathcal{N}(0, \sigma^2)$ .

Donc  $(X_t)_{0 \leq t \leq T}$  est un vecteur gaussien.

(car combinaison linéaire des  $(\varepsilon_t)$ )

**Vraisemblance** des T observations  $X_t$  :

$$\mathcal{L}((X_t) | (\phi_i), (\theta_j), \sigma) = \frac{1}{(2\pi)^{T/2} \sqrt{\det \Omega}} \exp\left(-\frac{1}{2} X' \Omega^{-1} X\right)$$

où  $\Omega$  dépend des  $\phi_i, \theta_j, \sigma$ ;  $X = (X_t)_{1 \leq t \leq T}$

→ Estimation des paramètres  $(\phi_i), (\theta_j), \sigma$  par la méthode (numérique) du **maximum de vraisemblance**.

**Remarque** : il existe d'autres méthodes d'estimation.

→ à utiliser lorsque SAS avertit d'un problème d'optimisation numérique.

## Examen de la validité du modèle

### 1. Significativité des paramètres estimés (Student)

### 2. Résidus = bruit blanc gaussien ?

Estimation  $e_t$  des résidus : écart entre observation  $X_t$  et prévision  $\hat{X}_{t-1}(1)$  (cf *prévision*)

→ Vérifier que les résidus  $(e_t)$  sont bien des « réalisations » d'un bruit blanc gaussien  $(\varepsilon_t)$  :

- vérification graphique : moyenne nulle, variance constante, pas de « structure ».
- ACF et PACF **des résidus** ne doivent pas avoir de pics significatifs.
- **Portmanteau Test** (Box-Pierce) **sur les résidus** : soit  $\rho(h)$  l'ACF des résidus. Alors :  $(T - K) \sum_{h=1}^K \rho(h)^2$  suit un  $\chi^2$  à  $K - p - q$  d.d.l., sous hypothèse  $(\varepsilon_t)$  bruit blanc gaussien. Mieux : Ljung-Box. (sous SAS, généralement  $K = 6, K = 12 \dots$ )

## Sélection de modèle

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

Plusieurs possibilités :

- Minimisation de la variance des résidus  $\sigma^2$ .
- Minimisation de *critères d'information* :  
 $AIC = -2 \log(\mathcal{L}) + 2(p + q)$   
ou  $BIC = SBC = -2 \log(\mathcal{L}) + (p + q) \log(T)$ .  
(compromis entre vraisemblance et nombre de paramètres)

**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*).

Modélisation et  
prévision

F. Sur - ENSMN

Processus  
stationnaires  
Processus MA  
Processus AR  
Processus ARMA

Processus non  
stationnaires  
Processus ARIMA  
Processus SARIMA

La méthode de  
Box-Jenkins

Identification  
Estimation  
Validation  
Prévision

Sous SAS

Conclusion

## Prévision avec modèle ARIMA( $p,d,q$ )

→ la semaine prochaine.

Modélisation et  
prévision

F. Sur - ENSMN

Processus  
stationnaires  
Processus MA  
Processus AR  
Processus ARMA

Processus non  
stationnaires  
Processus ARIMA  
Processus SARIMA

La méthode de  
Box-Jenkins

Identification  
Estimation  
Validation  
Prévision

Sous SAS

Conclusion

29/35

30/35

## Séance 2

- 1 Processus stationnaires
  - Processus MA
  - Processus AR
  - Processus ARMA
- 2 Processus non stationnaires
  - Processus ARIMA
  - Processus SARIMA
- 3 La méthode de Box-Jenkins
  - Identification
  - Estimation
  - Validation
  - Prévision
- 4 Sous SAS
- 5 Conclusion

Modélisation et  
prévision

F. Sur - ENSMN

Processus  
stationnaires  
Processus MA  
Processus AR  
Processus ARMA

Processus non  
stationnaires  
Processus ARIMA  
Processus SARIMA

La méthode de  
Box-Jenkins

Identification  
Estimation  
Validation  
Prévision

Sous SAS

Conclusion

## La procédure ARIMA

Identification d'un modèle ARIMA( $p,d,q$ ) :

```
proc arima data=serie;  
  identify var=variable;  
run;  
  identify var=variable(1);  
run;  
  estimate p=1 plot;  
run;  
  estimate p=1 q=1 plot;  
run;  
  forecast out=sortie back=10 lead=10;  
run;
```

→ **identify** : identification des ordres  $p$  et  $q$  avec ACF et PACF de la chronique, éventuellement différenciée (ordre  $d$ ).

→ **estimate** : estimation des paramètres et significativité, ACF et PACF des résidus, portmanteau.

→ **forecast** : prévisions.

Modélisation et  
prévision

F. Sur - ENSMN

Processus  
stationnaires  
Processus MA  
Processus AR  
Processus ARMA

Processus non  
stationnaires  
Processus ARIMA  
Processus SARIMA

La méthode de  
Box-Jenkins

Identification  
Estimation  
Validation  
Prévision

Sous SAS

Conclusion

31/35

32/35



## Écriture des différents modèles : estimate

estimate p=3;

$$Y_t = \theta_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \varepsilon_t$$

ARIMA(3, d, 0)

estimate p=3 noconstant;

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \varepsilon_t$$

sous-modèle de ARIMA(3, d, 0)

estimate p=1 q=2;

$$Y_t = \theta_0 + \phi_1 Y_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2}$$

ARIMA(1, d, 2)

estimate p=2 q=(2);

$$Y_t = \theta_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \varepsilon_t - \theta_2 \varepsilon_{t-2}$$

sous-modèle de ARIMA(2, d, 2)

estimate q=(1 3);

$$Y_t = \theta_0 - \theta_1 \varepsilon_{t-1} - \theta_3 \varepsilon_{t-3}$$

sous-modèle de ARIMA(0, d, 3)

estimate p=(12) q=2;

$$Y_t = \theta_0 + \phi_{12} Y_{t-12} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2}$$

SARIMA(0, d, 2)(1, d', 0)<sub>12</sub>

## Séance 2

- 1 Processus stationnaires
  - Processus MA
  - Processus AR
  - Processus ARMA
- 2 Processus non stationnaires
  - Processus ARIMA
  - Processus SARIMA
- 3 La méthode de Box-Jenkins
  - Identification
  - Estimation
  - Validation
  - Prévision
- 4 Sous SAS
- 5 Conclusion

## Conclusion

- Processus stationnaire ?
  - AR « pur » (sans racine unité),
  - MA « pur »,
  - ARMA.

→ identifications des ordres  $p$  /  $q$  : ACF et PACF.
- Processus non-stationnaire ?

→ on stationnarise d'abord en transformant la variable et / ou dérivant (ARIMA / SARIMA)
- Il faut aussi valider le modèle identifié (significativité des coefficients, résidus b.b.g., etc).

→ à pratiquer en TD !