

# Modélisation des séries temporelles

## Séance 2

### Les processus ARIMA

Frédéric Sur

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

1/34

## 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  $(\varepsilon_t)$  **bruit blanc gaussien**

2/34

## 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
  - Syntaxe R
- 4 Conclusion

3/34

## 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

### 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 :  $B^k \varepsilon_t = \varepsilon_{t-k}$

4/34

## Stationnarité des processus moyenne-mobile

### Propriété

les processus MA( $q$ ) sont **stationnaires** (à l'ordre 2)

En effet, quelque soit  $t$  :

- $E(X_t) = m$

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

(calcul algébrique simple, cf poly.)

où  $\sigma^2$  est la variance du b.b.g.  $\varepsilon_t$ .

→ les deux premiers moments ne dépendent pas de  $t$ .

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

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

### 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  $q$ .  
(cf séance 1)

5/34

6/34

## 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  $m$ )

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

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), $m = c = 0$

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

Exemple-type, car :  $\Phi(B)X_t = \varepsilon_t \Leftrightarrow \prod (1 - \phi_i B) X_t = \varepsilon_t$

- si  $|\phi| < 1$  (« racine »  $1/\phi$  à l'extérieur du disque unité) alors

$$X_t = (1 + \phi B + \phi^2 B^2 + \dots) \varepsilon_t$$

(car  $(1 - \phi B)^{-1} = 1 + \phi B + \phi^2 B^2 + \dots$ )

→ ( $X_t$ ) **stationnaire**, « équivalent » à MA( $\infty$ ).

- si  $|\phi| > 1$  alors

$$X_t = -(\phi^{-1} B^{-1} + \phi^{-2} B^{-2} + \dots) \varepsilon_t$$

(car  $(1 - \phi B)^{-1} = -(1 - \phi^{-1} B^{-1})^{-1} \phi^{-1} B^{-1} = -\phi^{-1} B^{-1} - \phi^{-2} B^{-2} + \dots$ )

→ ( $X_t$ ) **stationnaire** mais **non causal** sous cette forme.

On démontre qu'il existe un b.b.g.  $\varepsilon'_t$  t.q.  $X_t = \phi^{-1} X_{t-1} + \varepsilon'_t$ .

- 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  $\text{var}(X_t) = \text{var}(X_{t-1}) + \sigma^2$  dépend de  $t$  (non constante).


→ ( $X_t$ ) **non-stationnaire**.

7/34

8/34

## Simulation de processus AR(1)

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



9/34

## Et pour identifier l'ordre d'un processus AR ?

**Exemple** : AR(1) stationnaire,  $|\phi| < 1$

$$X_t = \phi X_{t-1} + \varepsilon_t$$

(quitte à retrancher la moyenne, on suppose  $E(X_t) = 0$ )

**On calcule** :

$$\gamma(1) = \text{Cov}(X_t, X_{t-1}) = \text{Cov}(\phi X_{t-1} + \varepsilon_t, X_{t-1}) = \phi \gamma(0)$$

$$\begin{aligned} \gamma(2) &= \text{Cov}(X_t, X_{t-2}) = \text{Cov}(\phi X_{t-1} + \varepsilon_t, X_{t-2}) \\ &= \text{Cov}(\phi^2 X_{t-2} + \phi \varepsilon_{t-1} + \varepsilon_t, X_{t-2}) = \phi^2 \gamma(0) \end{aligned}$$

...

*Preuve* :  $(\varepsilon_t)$  bruit blanc + causalité

→ l'ACF ne permet pas d'identifier l'ordre  $p$  d'un processus AR aussi simplement que pour un processus MA

→ ici,  $X_t$  est corrélé à  $X_{t-2}$  par l'intermédiaire de  $X_{t-1}$ .

10/34

## Autocorrélation partielle

Retirons la *dépendance linéaire* de  $X_{t-1}$  sur  $X_t$  et  $X_{t-2}$  :

→ régression de  $X_t$  sur  $X_{t-1}$  : on cherche  $\alpha$  minimisant

$$E(X_t - \alpha X_{t-1})^2 = \gamma(0) - 2\alpha\gamma(1) + \alpha^2\gamma(0)$$

d'où :  $\alpha = \gamma(1)/\gamma(0) = \phi$

notation :  $\tilde{X}_t = \phi X_{t-1}$  (« influence » de  $X_{t-1}$  sur  $X_t$ )

→ régression de  $X_{t-2}$  sur  $X_{t-1}$  : on cherche  $\beta$  minimisant

$$E(X_{t-2} - \beta X_{t-1})^2 = \gamma(0) - 2\beta\gamma(1) + \beta^2\gamma(0)$$

d'où :  $\beta = \phi$

notation :  $\tilde{X}_{t-2} = \phi X_{t-1}$  (« influence » de  $X_{t-1}$  sur  $X_{t-2}$ )

**Conséquence** :

$$\text{Cov}(X_t - \tilde{X}_t, X_{t-2} - \tilde{X}_{t-2}) = \text{Cov}(\varepsilon_t, X_{t-2} - \phi X_{t-1}) = 0$$

**Conclusion** : la notion utile pour identifier l'ordre d'un processus AR est l'*autocorrélation partielle* plutôt que l'autocorrélation.

11/34


## Espérance conditionnelle si $(X_t)$ gaussien

**Définition** (« rappel ») : espérance conditionnelle, cas gaussien

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

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 & cours « apprentissage automatique »)



12/34

## 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 *corrélacion partielle* d'ordre  $h$ .

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

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

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

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

**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.

→ on vient de voir  $a_1(1) = \gamma(1)/\gamma(0) = \text{corr}(X_t, X_{t-1})$ .

13/34

## 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 :

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

→  $(|r(h)|)_{h \geq 1}$  décroît « exponentiellement vite » (si  $\theta \neq 1$ )

14/34

## 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** d'un MA(q) :

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

→ permet l'identification d'un MA(q).

15/34

## 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 « exponentiellement vite ».

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

→ cf calcul précédent pour AR(1) :  $\rho(h) = \phi^h$

16/34

## 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** d'un AR( $p$ ) stationnaire :

- 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 :

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

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 un 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 : MA(+ $\infty$ ) représenté avec  $p+q+1$  param.

17/34

18/34

## 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
  - Syntaxe R
- 4 Conclusion

19/34

## Les processus non stationnaires

**Rappel** : 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

→ dans la suite du cours, les chroniques non stationnaires seront modélisés comme des processus ARIMA ou SARIMA

20/34

## Les processus ARIMA (=ARMA intégré)

Opérateur de différenciation :  $\nabla X_t = X_t - X_{t-1} = (1 - B)X_t$ .

### 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,  $p, d, q \geq 0$ ,  
 $\deg(\Phi) = p$ ,  $\deg(\Theta) = q$ ,  
et ( $\varepsilon_t$ ) est un bruit blanc gaussien (écart-type  $\sigma$ ).

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

## Cas de non stationarité

**Hypothèse** : ( $U_t$ ) stationnaire d'espérance nulle

**Tendance déterministe** : (espérance non constante)

$$X_t = f(t) + U_t \quad (\text{par ex. } f(t) = at + b)$$

alors on estime les paramètres de  $f$  par minimisation des moindres carrés et on cherche un modèle ARMA sur les résidus  $U_t$ .

**Tendance stochastique** :

$$X_t = X_{t-1} + U_t \quad (\text{marche aléatoire})$$

→ variance non constante

$$X_t = \mu + X_{t-1} + U_t \quad (\text{marche aléatoire avec drift - dérive})$$

→ tendance + variance non constantes

alors  $(1 - B)X_t = (\mu+) U_t$  est stationnaire

(on dit : la chronique  $X_t$  est intégrée d'ordre 1)

21/34

22/34

## Les processus SARIMA

Permettent de traiter le cas de la saisonnalité.

→ séance 3.

## 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
  - Syntaxe R
- 4 Conclusion

23/34

24/34

## 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.

25/34

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

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

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

Indices de non-stationnarité :

- « ça se voit » sur le graphique (tendance, variance pas constante)
- l'ACF ne décroît pas assez vite
- tests de Dickey-Fuller augmenté (séance 3)

→ il faut dériver.

26/34

## 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**.

R donne des intervalles de confiance pour les  $\hat{\rho}(h)$  et  $\hat{r}(h)$  sous hypothèse  $\rho(h) = 0$  et  $r(h) = 0$

**Remarque 2 :** si « vrai » ARMA( $p, q$ ), comme on se limitera à  $p, q \leq 2$ , on teste les différents modèles...

27/34

## Estimation des paramètres $\theta_j, \phi_i, \sigma$ (à grands traits... - 1)

**Définition :** vraisemblance de la réalisation d'un vecteur aléatoire  $X$

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  $\mathcal{L}_x(\theta)$


*Idee :* plus  $\mathcal{L}_x(\theta)$  est grand, plus il est plausible que  $f_\theta$  est la bon modèle

**Exemple :**  $x = (x_1, x_2, \dots, x_n)$

échantillon i.i.d. gaussien :

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

*Maximum of likelihood estimation (MLE)*



28/34

## Estimation des paramètres $\theta_j, \phi_i, \sigma$ (à grands traits... - 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  $X_t$  :

$$\mathcal{L}_X((\phi_i), (\theta_j), \sigma) = \frac{1}{(2\pi)^{T/2} \sqrt{\det \Omega}} \exp\left(-\frac{1}{2}(X - \mu)^T \Omega^{-1}(X - \mu)\right)$$

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

→ 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  $R$  avertit d'un problème d'optimisation numérique.

29/34

## Examen de la validité du modèle

### 1. Résidus = **bruit blanc gaussien** ?

Estimation  $e_t$  des résidus :  $X_t - \hat{X}_{t-1}(1)$  (cf *prévision*, séance 3)

→ on vérifie 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 », QQ-plot (« droite de Henry »).
- ACF **des résidus** ne doit pas présenter de  $\rho(h)$  significatif.
- **Portmanteau Test** (Box-Pierce) **sur les résidus** :  
soit  $\rho(h)$  l'ACF des résidus (théoriquement,  $\rho(h) = 0$  si  $h > 0$ )  
→  $(T - K) \sum_{h=1}^K \hat{\rho}(h)^2$  suit un  $\chi^2$  à  $K - p - q$  d.d.l.,  
sous hypothèse  $(\varepsilon_t)$  bruit blanc gaussien.  
(généralement on fait le test pour plusieurs valeurs de  $K$ )

### 2. **Significativité** des estimations des paramètres (Z-tests, Student, cf séance 3)

→ si un paramètre n'est pas significatif, on relance la modélisation en imposant sa valeur à 0.

30/34

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

→ la semaine prochaine.

31/34

## Syntaxe R

`help(arima)` (on utilisera en fait `Arima` du package `forecast`)

Details

Different definitions of ARMA models have different signs for the AR and/or MA coefficients. The definition used here has

$$X[t] = a[1]X[t-1] + \dots + a[p]X[t-p] + e[t] + b[1]e[t-1] + \dots + b[q]e[t-q]$$

and so the MA coefficients differ in sign from those of S-PLUS. Further, if `include.mean` is true (the default for an ARMA model), this formula applies to  $X - m$  rather than  $X$ . For ARIMA models with differencing, the differenced series follows a zero-mean ARMA model. If `am.xreg` term

Avec les notations du cours :

$$\begin{aligned} & (1 - B)^d X_t - m \\ &= \text{ar}[1] ((1 - B)^d X_{t-1} - m) + \dots + \text{ar}[p] ((1 - B)^d X_{t-p} - m) \\ & \quad + \varepsilon_t + \text{ma}[1] \varepsilon_{t-1} + \dots + \text{ma}[q] \varepsilon_{t-q} \end{aligned}$$

D'où :

$$\begin{aligned} & (1 - \text{ar}[1]B - \dots - \text{ar}[p]B^p) \left( (1 - B)^d X_t - m \right) \\ &= (1 + \text{ma}[1]B + \dots + \text{ma}[q]B^q) \varepsilon_t \end{aligned}$$

32/34



## 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
  - Syntaxe R
- 4 Conclusion

## Conclusion

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

→ identification des ordres  $p / q$  : ACF et PACF.
  - Processus non-stationnaire ?
    - ARIMA (si tendance)
    - SARIMA (si saisonnalité)

→ on « stationnarise » en dérivant
  - Il faut aussi valider le modèle identifié (résidus b.b.g., significativité des coefficients, etc).
- à pratiquer en TD !