

# Processus stationnaires – modèles ARMA

Angelina Roche

Executive Master Statistique et Big Data

*2018–2019*

## Rappels cours précédent

- ▶ Une série temporelle est l'observation d'une quantité  $X_t$  mesurée à des temps différents  $t_1, \dots, t_n$ .
- ▶ Outils graphiques : chronogramme (`plot.ts()`), diagramme retardé (`lag.plot()`), chronogramme par saison (`monthplot()`).
- ▶ On modélise souvent une série temporelle par un des modèles suivants :
  - ▶ modèle additif  $X_t = m_t + s_t + Z_t$  (`decompose()`, `stl()`, ...),
  - ▶ modèle multiplicatif  $X_t = m_t s_t (1 + Z_t)$  (`decompose()` avec option `type='multiplicative'`, ...).

# Plan du cours d'aujourd'hui

Stationnarité

Modèles ARMA( $p, q$ )

Meilleur prédicteur linéaire et fonction d'autocorrélation partielle

# Plan

Stationnarité

Modèles ARMA( $p, q$ )

Meilleur prédicteur linéaire et fonction d'autocorrélation partielle

## Processus stationnaire



### Définition

Un processus stochastique  $\{X_t, t \in \mathbb{Z}\}$  est dit (faiblement) stationnaire si :



- ▶ sa moyenne  $\mathbb{E}[X_t]$  ne dépend pas de  $t$  (constante),
- ▶ pour tout  $h \in \mathbb{Z}$ ,  $\text{cov}(X_t, X_{t-h})$  ne dépend pas de  $t$  (uniquement de  $h$ ).

## Exemple de processus non stationnaires

Processus à moyenne variable :



Processus à variance variable :



# Bruit blanc


## Définitions

- ▶ Un **bruit blanc**  $\{Z_t, t \in \mathcal{T}\}$  est une suite de variables aléatoires non corrélées, de moyenne nulle et de variance constante.
- ▶ Un **bruit blanc gaussien**  $\{Z_t, t \in \mathcal{T}\}$  est une suite de variables aléatoires i.i.d de loi normale.


Un bruit blanc est un processus stationnaire.

## Bruit blanc

Bruit blanc gaussien :



Bruit blanc non gaussien :



## Fonction d'autocovariance

### Définition

Soit  $X = \{X_t, t \in \mathbb{Z}\}$  un processus stationnaire, on appelle **fonction d'autocovariance** de  $X$  la fonction :

$$h \mapsto \gamma_X(h) := \text{Cov}(X_t, X_{t-h}).$$

### Propriétés

- ▶  $\gamma_X(0) = \text{Var}(X_t) \geq 0$  ;
- ▶  $|\gamma_X(h)| \leq \gamma_X(0)$ , pour tout  $h$  ;
- ▶  $\gamma_X(h) = \gamma_X(-h)$ , pour tout  $h$ .

## Fonction d'autocorrélation

### Définition

Soit  $X = \{X_t, t \in \mathbb{Z}\}$  un processus stationnaire, on appelle **fonction d'autocorrélation** (ou **ACF**) de  $X$  la fonction :

$$h \mapsto \rho_X(h) := \text{Cor}(X_t, X_{t-h}) = \frac{\gamma_X(h)}{\gamma_X(0)}.$$

### Propriétés

- ▶  $\rho_X(0) = 1$  ;
- ▶  $|\rho_X(h)| \leq 1$ , pour tout  $h$  ;
- ▶  $\rho_X(h) = \rho_X(-h)$ , pour tout  $h$ .

## Estimation de la moyenne et des fonctions d'autocovariance et d'autocorrélation

- ▶ Supposons que l'on observe  $X_1, \dots, X_n$ .
- ▶ Estimation de la moyenne  $\mu_X = \mathbb{E}[X_t]$  (`mean()`)

$$\hat{\mu}_X := \frac{1}{n} \sum_{i=1}^n X_i.$$

- ▶ Estimation de la fonction d'autocovariance  $\gamma_X$  (`acf()`) :

$$\hat{\gamma}_X(h) := \frac{1}{n} \sum_{i=h+1}^n (X_i - \hat{\mu}_X)(X_{i-h} - \hat{\mu}_X) \text{ pour } h = 0, \dots, n-1.$$

- ▶ Estimation de la fonction d'autocorrélation  $\rho_X$  (`acf()`) :

$$\hat{\rho}_X(h) := \frac{\hat{\gamma}_X(h)}{\hat{\gamma}_X(0)} \text{ pour } h = 0, \dots, n-1.$$

## Normalité asymptotique

Normalité asymptotique de l'autocorrélation empirique

Sous certaines hypothèses assez génériques,


$$\sqrt{n} \left( \begin{pmatrix} \hat{\rho}_X(1) \\ \vdots \\ \hat{\rho}_X(h) \end{pmatrix} - \begin{pmatrix} \rho_X(1) \\ \vdots \\ \rho_X(h) \end{pmatrix} \right) \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, T),$$

où  $T = (T_{j,k})_{1 \leq j, k \leq h}$  est donnée par la formule de Bartlett,


$$T_{j,k} = \sum_{r=1}^{+\infty} (\rho_X(r+j) + \rho_X(r-j) - 2\rho_X(j)\rho_X(r)) (\rho_X(r+k) + \rho_X(r-k) - 2\rho_X(k)\rho_X(r)).$$

## Exemple du bruit blanc


autocovariance théorique




autocovariance empirique



autocorrélation théorique




autocorrélation empirique



## Comment se ramener à une série stationnaire ?


- ▶ Opérateur retard :  $BX_t = X_{t-1}$ ,  $B^2X_t = BBX_t = X_{t-2}, \dots$ ,  
 $B^kX_t = X_{t-k}$ .
- ▶ Opérateur différence (**diff()**) :  $\Delta = (I - B)$ .  
 $\Delta X_t = X_t - X_{t-1} \leftrightarrow$  élimine une tendance linéaire. Plus généralement  $\Delta^k$  élimine une tendance polynomiale d'ordre  $k$ .
- ▶ Opérateur différence saisonnière :  $\Delta_k = (1 - B^k) \leftrightarrow$  élimine une saisonnalité de période  $k$ .
- ▶ En présence d'hétéroscedasticité (variance non constante) on transforme généralement les données (transformation **log**,  $\sqrt{\cdot}, \dots$ ).

## Exemple : évolution du nombre de passagers aériens




## Méthode 1 :


1. Transformation log pour stabiliser la variance ( $\log(\text{AirPassengers})$ ) :



2. Différentiation saisonnière ( $\text{diff}(\log(\text{AirPassengers}), \text{lag}=12)$ ) :




## Exemple : évolution du nombre de passagers aériens




## Méthode 2 :

1. Différentiation saisonnière ( $\text{diff}(\text{AirPassengers}, \text{lag}=12)$ ) :



2. Différentiation pour éliminer la tendance ( $\text{diff}(\text{diff}(\text{AirPassengers}, \text{lag}=12))$ ) :



# Plan

Stationnarité

Modèles ARMA( $p, q$ )

Meilleur prédicteur linéaire et fonction d'autocorrélation partielle

## Processus AR( $p$ )



### Définition

Un processus stationnaire  $\{X_t, t \in \mathbb{Z}\}$  est dit **autorégressif d'ordre  $p$**  (ou **AR( $p$ )**) s'il obéit à une équation du type

$$X_t = c + \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + Z_t, \forall t \in \mathbb{Z},$$

avec :

- ▶  $c \in \mathbb{R}$ ,  $\varphi = (\varphi_1, \dots, \varphi_p) \in \mathbb{R}^p$ ,
- ▶  $\{Z_t, t \in \mathbb{Z}\}$  un bruit blanc.

Exemples processus AR(1) :  $X_t = \varphi X_{t-1} + Z_t$ 

## Processus MA( $q$ )

### Définition



Un processus  $\{X_t, t \in \mathbb{Z}\}$  est un processus moyenne mobile d'ordre  $q$  (ou MA( $q$ )) si

$$X_t = \mu + Z_t + \theta_1 Z_{t-1} + \theta_2 Z_{t-2} + \dots + \theta_q Z_{t-q}, \forall t \in \mathbb{Z},$$

avec :

- ▶  $\mu \in \mathbb{R}$ ,  $\theta = (\theta_1, \dots, \theta_q) \in \mathbb{R}^q$ ,
- ▶  $\{Z_t, t \in \mathbb{Z}\}$  un bruit blanc.

Un processus MA( $q$ ) est toujours stationnaire.

Exemples processus MA(1) :  $X_t = \theta Z_{t-1} + Z_t$ 







Fonction d'autocorrélation d'un MA( $q$ )

Si  $X = \{X_t, t \in \mathbb{Z}\}$  est un processus MA( $q$ ) de paramètres  $\theta = (\theta_1, \dots, \theta_q)$ , alors :

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

avec  $\sigma_Z^2 = \text{Var}(Z_t)$ .

## Exemples



## Processus ARMA( $p, q$ )

### Définition

Un processus stationnaire  $\{X_t, t \in \mathbb{Z}\}$  obéit à un modèle ARMA( $p, q$ ) s'il vérifie une équation du type


$$X_t = c + \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + Z_t + \theta_1 Z_{t-1} + \theta_2 Z_{t-2} + \dots + \theta_q Z_{t-q}, \forall t \in \mathbb{Z},$$

avec :


- ▶  $c \in \mathbb{R}$ ,  $(\varphi_1, \dots, \varphi_p) \in \mathbb{R}^p$ ,  $(\theta_1, \dots, \theta_q) \in \mathbb{R}^q$ ,
- ▶  $\{Z_t, t \in \mathbb{Z}\}$  un bruit blanc.

Exemples processus ARMA( $p,q$ )







ARMA(1,1)



ARMA(2,1)



## ACF



# Plan

Stationnarité

Modèles ARMA( $p, q$ )

Meilleur prédicteur linéaire et fonction d'autocorrélation partielle

## Meilleur prédicteur linéaire d'un processus stationnaire

- ▶ On observe  $X_1, \dots, X_n$  et l'on veut prédire au mieux  $X_t$  pour  $t > n$ .
- ▶ Le meilleur prédicteur linéaire de  $X_t$ , sachant les observations  $X_1, \dots, X_n$ , est la quantité

$$X_{t|n} = a_0 + \sum_{j=1}^n a_j X_{n+1-j}$$

où  $a_0, a_1, \dots, a_n$  définis de façon à minimiser l'erreur quadratique moyenne

$$EQM = \mathbb{E} \left[ (X_t - X_{t|n})^2 \right].$$

- ▶ La résolution du problème de minimisation nous donne :

$$a_0 = \mu_X \left( 1 - \sum_{i=1}^n a_i \right) \text{ et } \Gamma_n \mathbf{a}_n = \boldsymbol{\gamma}_n(h),$$

où  $\mathbf{a}_n = (a_1, \dots, a_n)^t$ ,  $\Gamma_n = (\gamma_X(i-j))_{1 \leq i, j \leq n}$  et  $\boldsymbol{\gamma}_n(h) = (\gamma_X(h), \dots, \gamma_X(h+n-1))^t$ .

## Fonction d'autocorrélation partielle

### Définition

Soit  $\{X_t, t \in \mathbb{Z}\}$  un processus stationnaire centré ( $\mu_X = 0$ ). La fonction d'autocorrélation partielle (ou PACF) est la fonction

$$\rho_X(h) = a_h^{(h)},$$

où  $a_h^{(h)}$  tel que

$$X_{h|h-1} = \sum_{j=1}^h a_j^{(h)} X_{h+1-j}.$$

### PACF théorique

La PACF d'un  $AR(p)$  est nulle à partir de l'ordre  $p + 1$ .


## Estimation de la PACF

On peut estimer la PACF d'un processus stationnaire à partir d'une estimation de son ACF par l'algorithme de Durbin-Levinson.


### Propriétés de $\hat{p}_X$

Si  $X = \{X_t, t \in \mathbb{Z}\}$  est un  $AR(p)$  alors :



- ▶  $\hat{p}_X(p)$  converge vers  $p_X(p)$  quand  $n \rightarrow +\infty$ ,
- ▶  $\hat{p}_X(h)$  converge vers 0 quand  $n \rightarrow +\infty$  pour tout  $h > p$ ,
- ▶  $\text{Var}(\hat{p}_X(h))$  de l'ordre de  $1/n$  pour tout  $h > p$ .

Exemples : processus  $AR(p)$  ou  $MA(q)$ processus  $AR(1)$ 


PACF théorique




PACF empirique

processus  $MA(1)$ 







PACF théorique



PACF empirique



# Processus ARMA( $p, q$ )



## Identification d'un $ARMA(p,q)$ : méthode de Box et Jenkins

1. Se ramener à un processus stationnaire : transformer éventuellement les données, éliminer la tendance et la saisonnalité,...
2. Identifier  $p$  et  $q$  :

- ▶ À l'aide des tracés de l'ACF et de la PACF empirique :

Fonction	MA( $q$ )	AR( $p$ )	ARMA( $p,q$ )	BB
ACF	0 à p. rg( $q$ )	déc. exp.	déc. exp.	0
PACF	déc. exp.	0 à p. rg( $p$ )	déc. exp.	0

- ▶ Critère  $AIC = n \log(\hat{\sigma}_Z^2) + 2(p + q)$ ,  
 $AICc = AIC + 2(p + q)(p + q + 1)/(n - p - q - 1)$  (petits échantillons), BIC,...
- ▶ Modélisation automatique : fonctions `auto.arima()` de `forecast`, `armasubsets()` de `TSA`, `armaselect()` de `caschro`,...

## Estimation des paramètres $\varphi$ et $\theta$

- ▶ Lorsque  $p$  et  $q$  sont fixés, nous pouvons estimer les paramètres  $\varphi$  et  $\theta$  du modèle choisi.
- ▶ Méthode classique : maximum de vraisemblance dont il existe différentes variantes (`arima()` ou `ar()`, `Arima()` de `forecast`, `arimax()` de `TSA`,.... ).