

## Estimation des modèles ARMA

# Plan

Introduction

Vraisemblance d'un processus  $AR(1)$  gaussien

Vraisemblance d'un processus  $AR(p)$  gaussien

Estimation par quasi-maximum de vraisemblance

Vraisemblance d'un processus  $MA(1)$  gaussien

Vraisemblance d'un processus  $MA(q)$  gaussien

Vraisemblance d'un processus  $ARMA(p, q)$  gaussien

Optimisation numérique

Distribution asymptotique et tests

Identification et sélection de modèles

# Plan

## Introduction

Vraisemblance d'un processus  $AR(1)$  gaussien

Vraisemblance d'un processus  $AR(p)$  gaussien

Estimation par quasi-maximum de vraisemblance

Vraisemblance d'un processus  $MA(1)$  gaussien

Vraisemblance d'un processus  $MA(q)$  gaussien

Vraisemblance d'un processus  $ARMA(p, q)$  gaussien

Optimisation numérique

Distribution asymptotique et tests

Identification et sélection de modèles

# Le problème de l'estimation

- Soit un modèle ARMA( $p, q$ ) :

$$Y_t = c + \phi_1 Y_{t-1} + \cdots + \phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q}$$

avec  $\varepsilon_t$  un bruit blanc.

- Les chapitres précédents ont montré comment calculer les moments du processus (autocovariances, autocorrélations, prévisions linéaires) en fonction des paramètres.
- **Problème** : Comment estimer les paramètres  $(c, \phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q, \sigma^2)$  à partir d'un échantillon d'observations  $(y_1, y_2, \dots, y_T)$  ?

# Principe du maximum de vraisemblance

- ▶ On note  $\theta = (c, \phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q, \sigma^2)'$  le vecteur des paramètres.
- ▶ On suppose que  $\varepsilon_t \sim \text{i.i.d. } N(0, \sigma^2)$ .
- ▶ On calcule la densité jointe de l'échantillon observé :

$$f_{Y_T, Y_{T-1}, \dots, Y_1}(y_T, y_{T-1}, \dots, y_1; \theta)$$

vue comme une fonction de  $\theta$  pour les données observées.

- ▶ **L'estimateur du maximum de vraisemblance (EMV)** est la valeur  $\hat{\theta}$  qui maximise cette fonction, c'est-à-dire la valeur des paramètres pour laquelle l'échantillon observé est le plus probable.

# Hypothèse de normalité

- ▶ L'hypothèse de normalité sur  $\varepsilon_t$  est forte, mais l'estimation résultante reste pertinente même si elle est violée.
- ▶ Si le vrai processus est non gaussien, les estimateurs obtenus en maximisant la vraisemblance gaussienne restent **convergen**ts. On parle alors d'estimateur de **quasi-maximum de vraisemblance**.
- ▶ En revanche, les erreurs standard calculées sous l'hypothèse de normalité peuvent ne pas être correctes si les données sont non gaussiennes.

## Décomposition en erreurs de prévision

- ▶ La densité jointe peut être factorisée en utilisant la règle de Bayes :

$$f_{Y_T, \dots, Y_1}(y_T, \dots, y_1; \boldsymbol{\theta}) = f_{Y_1}(y_1; \boldsymbol{\theta}) \cdot \prod_{t=2}^T f_{Y_t|Y_{t-1}}(y_t|y_{t-1}; \boldsymbol{\theta})$$

- ▶ La **log-vraisemblance** est donc :

$$\mathcal{L}(\boldsymbol{\theta}) = \log f_{Y_1}(y_1; \boldsymbol{\theta}) + \sum_{t=2}^T \log f_{Y_t|Y_{t-1}}(y_t|y_{t-1}; \boldsymbol{\theta})$$

- ▶ Cette décomposition est connue sous le nom de **décomposition en erreurs de prévision** (*prediction-error decomposition*).

# Plan

Introduction

Vraisemblance d'un processus AR(1) gaussien

Vraisemblance d'un processus AR( $p$ ) gaussien

Estimation par quasi-maximum de vraisemblance

Vraisemblance d'un processus MA(1) gaussien

Vraisemblance d'un processus MA( $q$ ) gaussien

Vraisemblance d'un processus ARMA( $p, q$ ) gaussien

Optimisation numérique

Distribution asymptotique et tests

Identification et sélection de modèles



## Le modèle AR(1) gaussien

- ▶ On considère le processus AR(1) gaussien :

$$Y_t = c + \phi Y_{t-1} + \varepsilon_t$$

avec  $\varepsilon_t \sim \text{i.i.d. } N(0, \sigma^2)$  et  $|\phi| < 1$ .

- ▶ Le vecteur de paramètres est  $\boldsymbol{\theta} = (c, \phi, \sigma^2)'$ .
- ▶ L'espérance du processus stationnaire est  $\mu = c/(1 - \phi)$ .
- ▶ La variance du processus stationnaire est  $\sigma^2/(1 - \phi^2)$ .

## Densité de la première observation

- Puisque  $\varepsilon_t$  est gaussien,  $Y_1$  est également gaussien avec :

$$\mathbb{E}[Y_1] = \mu = \frac{c}{1 - \phi}, \quad \mathbb{V}[Y_1] = \frac{\sigma^2}{1 - \phi^2}$$

- La densité de  $Y_1$  est donc :

$$f_{Y_1}(y_1; \boldsymbol{\theta}) = \frac{1}{\sqrt{2\pi\sigma^2/(1 - \phi^2)}} \exp \left[ \frac{-\{y_1 - c/(1 - \phi)\}^2}{2\sigma^2/(1 - \phi^2)} \right]$$

## Densités conditionnelles

- Conditionnellement à  $Y_{t-1} = y_{t-1}$ , on a :

$$Y_t = c + \phi Y_{t-1} + \varepsilon_t \sim N(c + \phi y_{t-1}, \sigma^2)$$

- La densité conditionnelle est :

$$f_{Y_t|Y_{t-1}}(y_t|y_{t-1}; \boldsymbol{\theta}) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[ \frac{-(y_t - c - \phi y_{t-1})^2}{2\sigma^2} \right]$$

- Cette expression est valable pour  $t = 2, 3, \dots, T$ .

## Log-vraisemblance exacte

- La log-vraisemblance exacte de l'AR(1) gaussien est :

$$\begin{aligned}\mathcal{L}(\boldsymbol{\theta}) = & -\frac{1}{2} \log(2\pi) - \frac{1}{2} \log\left(\frac{\sigma^2}{1-\phi^2}\right) - \frac{\{y_1 - c/(1-\phi)\}^2}{2\sigma^2/(1-\phi^2)} \\ & - \frac{T-1}{2} \log(2\pi) - \frac{T-1}{2} \log(\sigma^2) \\ & - \sum_{t=2}^T \frac{(y_t - c - \phi y_{t-1})^2}{2\sigma^2}\end{aligned}$$

- On regroupe les termes pour obtenir :

$$\begin{aligned}\mathcal{L}(\boldsymbol{\theta}) = & -\frac{T}{2} \log(2\pi) - \frac{T}{2} \log(\sigma^2) + \frac{1}{2} \log(1-\phi^2) \\ & - \frac{(1-\phi^2)}{2\sigma^2} \left(y_1 - \frac{c}{1-\phi}\right)^2 - \sum_{t=2}^T \frac{(y_t - c - \phi y_{t-1})^2}{2\sigma^2}\end{aligned}$$

## Log-vraisemblance conditionnelle

- Une alternative consiste à conditionner sur la première observation  $y_1$  et à maximiser :

$$\mathcal{L}_c(\boldsymbol{\theta}) = -\frac{T-1}{2} \log(2\pi) - \frac{T-1}{2} \log(\sigma^2) - \sum_{t=2}^T \frac{(y_t - c - \phi y_{t-1})^2}{2\sigma^2}$$

- La maximisation par rapport à  $c$  et  $\phi$  revient à minimiser :

$$\sum_{t=2}^T (y_t - c - \phi y_{t-1})^2$$

- C'est un problème de **moindres carrés ordinaires** (MCO) : régression de  $y_t$  sur une constante et  $y_{t-1}$ .

## Estimateurs conditionnels du maximum de vraisemblance

- Les estimateurs conditionnels de  $c$  et  $\phi$  sont donnés par la formule des MCO :

$$\begin{bmatrix} \hat{c} \\ \hat{\phi} \end{bmatrix} = \begin{bmatrix} T-1 & \sum y_{t-1} \\ \sum y_{t-1} & \sum y_{t-1}^2 \end{bmatrix}^{-1} \begin{bmatrix} \sum y_t \\ \sum y_{t-1} y_t \end{bmatrix}$$

où les sommes portent sur  $t = 2, 3, \dots, T$ .

- L'estimateur conditionnel de  $\sigma^2$  est la variance résiduelle de la régression :

$$\hat{\sigma}^2 = \frac{1}{T-1} \sum_{t=2}^T (y_t - \hat{c} - \hat{\phi} y_{t-1})^2$$

- Pour  $T$  grand, les estimateurs exact et conditionnel convergent vers la même distribution asymptotique (si  $|\phi| < 1$ ).

## Vraisemblance exacte et conditionnelle : comparaison

- ▶ La vraisemblance exacte nécessite le terme supplémentaire  $\frac{1}{2} \log(1 - \phi^2) - \frac{(1-\phi^2)}{2\sigma^2}(y_1 - \mu)^2$  lié à la première observation.
- ▶ La vraisemblance conditionnelle ignore ce terme et traite  $y_1$  comme déterministe.
- ▶ Si  $T$  est grand, la contribution de la première observation est négligeable.
- ▶ Si  $|\phi| < 1$ , les deux approches donnent des estimateurs **convergents**. Si  $|\phi| > 1$ , la vraisemblance conditionnelle ne fournit pas d'estimateurs convergents car la densité de  $Y_1$  n'est pas correctement spécifiée.

## Expression vectorielle de la vraisemblance (1/6)

- ▶ On peut dériver la vraisemblance d'une manière alternative en considérant le vecteur des  $T$  observations :

$$\mathbf{y} = (y_1, y_2, \dots, y_T)'$$

- ▶ Ce vecteur peut être vu comme une unique réalisation d'un vecteur gaussien de dimension  $T$  :

$$\mathbf{y} \sim N(\boldsymbol{\mu}, \boldsymbol{\Omega})$$

- ▶ Le vecteur d'espérances est  $\boldsymbol{\mu} = (\mu, \mu, \dots, \mu)'$  avec  $\mu = c/(1 - \phi)$ .
- ▶ La matrice de variance-covariance  $\boldsymbol{\Omega}$  est une matrice  $(T \times T)$  dont l'élément  $(i, j)$  est l'autocovariance  $\gamma(|i - j|)$ .



## Expression vectorielle de la vraisemblance (2/6)

- Pour l'AR(1), l'autocovariance est  $\gamma(h) = \sigma^2 \phi^{|h|} / (1 - \phi^2)$ , donc :

$$\Omega = \sigma^2 \mathbf{V}$$

où

$$\mathbf{V} = \frac{1}{1 - \phi^2} \begin{bmatrix} 1 & \phi & \phi^2 & \dots & \phi^{T-1} \\ \phi & 1 & \phi & \dots & \phi^{T-2} \\ \phi^2 & \phi & 1 & \dots & \phi^{T-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \phi^{T-1} & \phi^{T-2} & \phi^{T-3} & \dots & 1 \end{bmatrix}$$

- $\mathbf{V}$  est une matrice de Toeplitz symétrique définie positive.

## Expression vectorielle de la vraisemblance (3/6)

- La densité du vecteur gaussien  $\mathbf{y}$  s'écrit :

$$f_{\mathbf{Y}}(\mathbf{y}; \boldsymbol{\theta}) = (2\pi)^{-T/2} |\boldsymbol{\Omega}|^{-1/2} \exp\left[-\frac{1}{2}(\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Omega}^{-1} (\mathbf{y} - \boldsymbol{\mu})\right]$$

- La log-vraisemblance est donc :

$$\mathcal{L}(\boldsymbol{\theta}) = -\frac{T}{2} \log(2\pi) + \frac{1}{2} \log |\boldsymbol{\Omega}^{-1}| - \frac{1}{2} (\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Omega}^{-1} (\mathbf{y} - \boldsymbol{\mu})$$

- Cette expression fait intervenir l'inverse et le déterminant de la matrice  $\boldsymbol{\Omega}$  de taille  $(T \times T)$ . En apparence, le calcul est coûteux, mais la structure de  $\boldsymbol{\Omega}$  permet de le simplifier.

## Expression vectorielle de la vraisemblance (4/6)

- On introduit la matrice triangulaire inférieure  $\mathbf{L}$  de taille  $(T \times T)$  :

$$\mathbf{L} = \begin{bmatrix} \sqrt{1 - \phi^2} & 0 & 0 & \cdots & 0 & 0 \\ -\phi & 1 & 0 & \cdots & 0 & 0 \\ 0 & -\phi & 1 & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & \cdots & -\phi & 1 \end{bmatrix}$$

- On peut montrer que :

$$\mathbf{L}'\mathbf{L} = \mathbf{V}^{-1}$$

et donc  $\boldsymbol{\Omega}^{-1} = \sigma^{-2}\mathbf{V}^{-1} = \sigma^{-2}\mathbf{L}'\mathbf{L}$ .

## Expression vectorielle de la vraisemblance (5/6)

- Puisque  $\mathbf{L}$  est triangulaire, son déterminant est le produit des éléments diagonaux :

$$|\mathbf{L}| = \sqrt{1 - \phi^2} \cdot \underbrace{1 \cdot 1 \cdots 1}_{T-1} = \sqrt{1 - \phi^2}$$

- Donc  $|\mathbf{L}'\mathbf{L}| = |\mathbf{V}^{-1}| = 1 - \phi^2$ , et :

$$\frac{1}{2} \log |\boldsymbol{\Omega}^{-1}| = \frac{1}{2} \log(\sigma^{-2T} \cdot |\mathbf{V}^{-1}|) = -\frac{T}{2} \log(\sigma^2) + \frac{1}{2} \log(1 - \phi^2)$$

- On définit le vecteur transformé  $\tilde{\mathbf{y}} = \mathbf{L}(\mathbf{y} - \boldsymbol{\mu})$ , de sorte que :

$$(\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Omega}^{-1} (\mathbf{y} - \boldsymbol{\mu}) = \frac{1}{\sigma^2} \tilde{\mathbf{y}}' \tilde{\mathbf{y}}$$

## Expression vectorielle de la vraisemblance (6/6)

- Les composantes de  $\tilde{\mathbf{y}} = \mathbf{L}(\mathbf{y} - \boldsymbol{\mu})$  sont :

$$\tilde{y}_1 = \sqrt{1 - \phi^2} (y_1 - \mu), \quad \tilde{y}_t = (y_t - \mu) - \phi(y_{t-1} - \mu) \quad \text{pour } t \geq 2$$

- En substituant  $\mu = c/(1 - \phi)$  :

$$\tilde{y}_t = y_t - c - \phi y_{t-1} \quad \text{pour } t \geq 2$$

Ce sont les **erreurs de prévision** !

- La log-vraisemblance s'écrit alors :

$$\mathcal{L}(\boldsymbol{\theta}) = -\frac{T}{2} \log(2\pi) - \frac{T}{2} \log(\sigma^2) + \frac{1}{2} \log(1 - \phi^2) - \frac{1}{2\sigma^2} \sum_{t=1}^T \tilde{y}_t^2$$

- On retrouve exactement l'expression de la log-vraisemblance exacte obtenue par la

# Plan

Introduction

Vraisemblance d'un processus  $AR(1)$  gaussien

Vraisemblance d'un processus  $AR(p)$  gaussien

Estimation par quasi-maximum de vraisemblance

Vraisemblance d'un processus  $MA(1)$  gaussien

Vraisemblance d'un processus  $MA(q)$  gaussien

Vraisemblance d'un processus  $ARMA(p, q)$  gaussien

Optimisation numérique

Distribution asymptotique et tests

Identification et sélection de modèles

## Le modèle AR( $p$ ) gaussien

- ▶ On considère le processus AR( $p$ ) gaussien :

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \cdots + \phi_p Y_{t-p} + \varepsilon_t$$

avec  $\varepsilon_t \sim \text{i.i.d. } N(0, \sigma^2)$ .

- ▶ Le vecteur de paramètres est  $\boldsymbol{\theta} = (c, \phi_1, \phi_2, \dots, \phi_p, \sigma^2)'$ .

- ▶ L'espérance du processus stationnaire est :

$$\mu = \frac{c}{1 - \phi_1 - \phi_2 - \cdots - \phi_p}$$

## Construction de la vraisemblance

- ▶ Les  $p$  premières observations  $(y_1, \dots, y_p)$  suivent une loi gaussienne multivariée  $N(\boldsymbol{\mu}_p, \sigma^2 \mathbf{V}_p)$ .

- ▶ Pour  $t > p$ , conditionnellement aux  $p$  observations précédentes :

$$Y_t | Y_{t-1}, \dots, Y_{t-p} \sim N(c + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p}, \sigma^2)$$

- ▶ La log-vraisemblance exacte est :

$$\begin{aligned} \mathcal{L}(\boldsymbol{\theta}) = & -\frac{T}{2} \log(2\pi) - \frac{T}{2} \log(\sigma^2) + \frac{1}{2} \log |\mathbf{V}_p^{-1}| \\ & - \frac{1}{2\sigma^2} (\mathbf{y}_p - \boldsymbol{\mu}_p)' \mathbf{V}_p^{-1} (\mathbf{y}_p - \boldsymbol{\mu}_p) \\ & - \sum_{t=p+1}^T \frac{(y_t - c - \phi_1 y_{t-1} - \dots - \phi_p y_{t-p})^2}{2\sigma^2} \end{aligned}$$



## Estimateurs conditionnels pour l'AR( $p$ )

- La log-vraisemblance conditionnelle (sur les  $p$  premières observations) est :

$$\begin{aligned}\mathcal{L}_c(\boldsymbol{\theta}) = & -\frac{T-p}{2} \log(2\pi) - \frac{T-p}{2} \log(\sigma^2) \\ & - \sum_{t=p+1}^T \frac{(y_t - c - \phi_1 y_{t-1} - \cdots - \phi_p y_{t-p})^2}{2\sigma^2}\end{aligned}$$

- La maximisation revient à minimiser :

$$\sum_{t=p+1}^T (y_t - c - \phi_1 y_{t-1} - \cdots - \phi_p y_{t-p})^2$$

- C'est la somme des carrés des résidus d'une régression MCO de  $y_t$  sur une constante et ses  $p$  valeurs retardées.

## Estimateur de la variance des innovations

- L'estimateur conditionnel de  $\sigma^2$  est le résidu quadratique moyen :

$$\hat{\sigma}^2 = \frac{1}{T-p} \sum_{t=p+1}^T (y_t - \hat{c} - \hat{\phi}_1 y_{t-1} - \hat{\phi}_2 y_{t-2} - \cdots - \hat{\phi}_p y_{t-p})^2$$

- Les estimateurs exact et conditionnel ont la même distribution asymptotique.
- **Résultat important** : Pour un processus  $AR(p)$ , les estimateurs conditionnels du maximum de vraisemblance sont identiques aux estimateurs des MCO.  
L'estimation d'un  $AR(p)$  est donc particulièrement simple.

# Plan

Introduction

Vraisemblance d'un processus  $AR(1)$  gaussien

Vraisemblance d'un processus  $AR(p)$  gaussien

Estimation par quasi-maximum de vraisemblance

Vraisemblance d'un processus  $MA(1)$  gaussien

Vraisemblance d'un processus  $MA(q)$  gaussien

Vraisemblance d'un processus  $ARMA(p, q)$  gaussien

Optimisation numérique

Distribution asymptotique et tests

Identification et sélection de modèles

## Processus non gaussiens

- ▶ Que se passe-t-il si le processus n'est pas gaussien ?
- ▶ La régression MCO de  $y_t$  sur une constante et ses  $p$  retards fournit une estimation convergente de la **projection linéaire** :

$$\hat{\mathbb{E}}(Y_t | Y_{t-1}, Y_{t-2}, \dots, Y_{t-p})$$

pourvu que le processus soit ergodique pour les moments d'ordre 2.

- ▶ Cette régression MCO maximise aussi la **log-vraisemblance gaussienne conditionnelle**. Même si le processus n'est pas gaussien, maximiser cette fonction fournit des estimateurs convergents.

## Estimateur de quasi-maximum de vraisemblance

- ▶ Un estimateur obtenu en maximisant une vraisemblance mal spécifiée (par exemple, gaussienne alors que les données ne le sont pas) est appelé estimateur de **quasi-maximum de vraisemblance** (QMLE).
- ▶ **Propriété** : Le QMLE fournit des estimateurs **converge**nts des paramètres  $(\phi_1, \dots, \phi_p)$ .
- ▶ Cependant, les erreurs standard calculées sous l'hypothèse gaussienne peuvent ne pas être correctes. Il faut utiliser un estimateur robuste de la matrice de variance-covariance.
- ▶ En pratique, si les données sont non gaussiennes, une transformation préalable (par exemple, le logarithme) peut rapprocher la distribution de la normalité.

# Transformations Box-Cox

- Pour une variable positive  $Y_t$ , Box et Cox (1964) proposent la famille de transformations :

$$Y_t^{(\lambda)} = \begin{cases} \frac{Y_t^\lambda - 1}{\lambda} & \text{si } \lambda \neq 0 \\ \log Y_t & \text{si } \lambda = 0 \end{cases}$$

- On choisit  $\lambda$  de sorte que  $Y_t^{(\lambda)}$  soit bien approximé par un processus ARMA gaussien.
- En pratique, pour les séries économiques qui croissent dans le temps (PIB, prix), on utilise souvent :

$$y_t = \log X_t - \log X_{t-1}$$

c'est-à-dire le taux de croissance en log.

# Plan

Introduction

Vraisemblance d'un processus  $AR(1)$  gaussien

Vraisemblance d'un processus  $AR(p)$  gaussien

Estimation par quasi-maximum de vraisemblance

**Vraisemblance d'un processus  $MA(1)$  gaussien**

Vraisemblance d'un processus  $MA(q)$  gaussien

Vraisemblance d'un processus  $ARMA(p, q)$  gaussien

Optimisation numérique

Distribution asymptotique et tests

Identification et sélection de modèles

## Le modèle MA(1) gaussien

- ▶ On considère le processus MA(1) gaussien :

$$Y_t = \mu + \varepsilon_t + \theta \varepsilon_{t-1}$$

avec  $\varepsilon_t \sim \text{i.i.d. } N(0, \sigma^2)$ .

- ▶ Le vecteur de paramètres est  $\boldsymbol{\theta} = (\mu, \theta, \sigma^2)'$ .
- ▶ Contrairement à l'AR, la vraisemblance du MA ne se réduit **pas** à un problème de moindres carrés.
- ▶ Deux approches : la vraisemblance **conditionnelle** (plus simple) et la vraisemblance **exacte** (plus précise en petit échantillon).



## Vraisemblance conditionnelle du MA(1) (1/2)

- ▶ On conditionne sur la valeur initiale  $\varepsilon_0 = 0$ . Sachant  $\varepsilon_{t-1}$ , la densité de  $Y_t$  est :

$$f_{Y_t|\varepsilon_{t-1}}(y_t|\varepsilon_{t-1}; \boldsymbol{\theta}) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[ \frac{-(y_t - \mu - \theta\varepsilon_{t-1})^2}{2\sigma^2} \right]$$

- ▶ Sachant  $\varepsilon_0 = 0$ , on déduit  $\varepsilon_1$  de l'observation  $y_1$  :

$$\varepsilon_1 = y_1 - \mu$$

- ▶ Plus généralement, les innovations sont calculées récursivement :

$$\varepsilon_t = y_t - \mu - \theta\varepsilon_{t-1}$$

pour  $t = 1, 2, \dots, T$ , en partant de  $\varepsilon_0 = 0$ .

## Vraisemblance conditionnelle du MA(1) (2/2)

- La log-vraisemblance conditionnelle est :

$$\mathcal{L}_c(\boldsymbol{\theta}) = -\frac{T}{2} \log(2\pi) - \frac{T}{2} \log(\sigma^2) - \sum_{t=1}^T \frac{\varepsilon_t^2}{2\sigma^2}$$

où  $\varepsilon_t = y_t - \mu - \theta\varepsilon_{t-1}$  avec  $\varepsilon_0 = 0$ .

- La log-vraisemblance est une fonction **non linéaire** de  $\mu$  et  $\theta$  : pas de solution analytique explicite.
- La maximisation requiert une **optimisation numérique**.
- **Condition d'inversibilité** : L'approximation conditionnelle est valide si  $|\theta| < 1$ . Si l'optimisation conduit à  $|\hat{\theta}| > 1$ , il faut recommencer avec  $\hat{\theta}^{-1}$ .

## Effet de la condition initiale

- ▶ En développant la récurrence  $\varepsilon_t = y_t - \mu - \theta\varepsilon_{t-1}$  :

$$\begin{aligned}\varepsilon_t &= (y_t - \mu) - \theta(y_{t-1} - \mu) + \theta^2(y_{t-2} - \mu) - \cdots \\ &\quad + (-1)^{t-1}\theta^{t-1}(y_1 - \mu) + (-1)^t\theta^t\varepsilon_0\end{aligned}$$

- ▶ Si  $|\theta| < 1$ , l'effet de  $\varepsilon_0 = 0$  décroît géométriquement :  $(-1)^t\theta^t\varepsilon_0 \rightarrow 0$ .
- ▶ Pour  $T$  suffisamment grand, l'approximation  $\varepsilon_0 = 0$  est inoffensive.
- ▶ Si  $|\theta|$  est proche de 1, les premières innovations  $\varepsilon_t$  sont mal estimées, ce qui peut affecter l'estimation en petit échantillon.

## Vraisemblance exacte du MA(1) (1/6)

- ▶ La vraisemblance exacte traite les  $T$  observations comme un vecteur gaussien  $\mathbf{y} = (y_1, \dots, y_T)'$  de loi  $N(\boldsymbol{\mu}, \boldsymbol{\Omega})$ .
- ▶ La matrice de variance-covariance  $\boldsymbol{\Omega}$  a une structure **tridiagonale** :

$$\boldsymbol{\Omega} = \sigma^2 \begin{bmatrix} 1 + \theta^2 & \theta & 0 & \dots & 0 \\ \theta & 1 + \theta^2 & \theta & \dots & 0 \\ 0 & \theta & 1 + \theta^2 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 + \theta^2 \end{bmatrix}$$

- ▶ La log-vraisemblance exacte est :

$$\mathcal{L}(\boldsymbol{\theta}) = -\frac{T}{2} \log(2\pi) - \frac{1}{2} \log |\boldsymbol{\Omega}| - \frac{1}{2} (\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Omega}^{-1} (\mathbf{y} - \boldsymbol{\mu})$$

## Vraisemblance exacte du MA(1) (2/6)

- ▶ On cherche la **factorisation triangulaire**  $\Omega = \mathbf{A}\mathbf{D}\mathbf{A}'$  où :
  - ▶  $\mathbf{A}$  est triangulaire inférieure avec des 1 sur la diagonale,
  - ▶  $\mathbf{D}$  est diagonale avec des éléments strictement positifs.
- ▶ Puisque  $\Omega$  est tridiagonale,  $\mathbf{A}$  est **bidiagonale** : seuls les éléments diagonaux et sous-diagonaux sont non nuls.
- ▶ On note  $S_t = 1 + \theta^2 + \theta^4 + \dots + \theta^{2(t-1)}$  la somme géométrique. On a  $S_1 = 1$  et :

$$S_t = \frac{1 - \theta^{2t}}{1 - \theta^2} \quad \text{si } \theta^2 \neq 1$$

## Vraisemblance exacte du MA(1) (3/6)

- ▶ On obtient **A** et **D** par **élimination de Gauss** sur  $\Omega/\sigma^2$ .
- ▶ **Étape 1** : Le pivot est  $d_1 = (1 + \theta^2) = S_2/S_1$ . On élimine le terme sous-diagonal  $\theta$  en soustrayant  $\frac{\theta}{1+\theta^2}$  fois la première ligne. Cela donne  $a_{21} = \frac{\theta}{1+\theta^2} = \frac{\theta S_1}{S_2}$ .
- ▶ **Étape 2** : Le nouveau pivot est :

$$d_2 = (1 + \theta^2) - \frac{\theta^2}{1 + \theta^2} = \frac{(1 + \theta^2)^2 - \theta^2}{1 + \theta^2} = \frac{1 + \theta^2 + \theta^4}{1 + \theta^2} = \frac{S_3}{S_2}$$

Le multiplicateur est  $a_{32} = \frac{\theta}{d_2} = \frac{\theta S_2}{S_3}$ .

## Vraisemblance exacte du MA(1) (4/6)

- En poursuivant, on montre par récurrence que pour  $t = 1, \dots, T$  :

$$\boxed{d_t = \frac{S_{t+1}}{S_t}} \quad \text{et} \quad \boxed{a_{t+1,t} = \frac{\theta S_t}{S_{t+1}}}$$

- Explicitement, les matrices sont (en factorisant  $\sigma^2$  dans  $\mathbf{D}$ ) :

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & 0 & \cdots & 0 \\ \frac{\theta S_1}{S_2} & 1 & 0 & \cdots & 0 \\ 0 & \frac{\theta S_2}{S_3} & 1 & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & 1 \end{bmatrix}, \quad \mathbf{D} = \sigma^2 \begin{bmatrix} \frac{S_2}{S_1} & & & & \\ & \frac{S_3}{S_2} & & & \\ & & \ddots & & \\ & & & \ddots & \\ & & & & \frac{S_{T+1}}{S_T} \end{bmatrix}$$

## Vraisemblance exacte du MA(1) (5/6)

- Le vecteur transformé  $\tilde{\mathbf{y}} = \mathbf{A}^{-1}(\mathbf{y} - \boldsymbol{\mu})$  a pour composantes :

$$\tilde{y}_1 = y_1 - \mu, \quad \tilde{y}_t = (y_t - \mu) - \frac{\theta S_{t-1}}{S_t} \tilde{y}_{t-1} \quad \text{pour } t \geq 2$$

- Puisque  $|\mathbf{A}| = 1$  (triangulaire avec des 1 sur la diagonale) et  $\boldsymbol{\Omega} = \mathbf{A}\mathbf{D}\mathbf{A}'$  :

$$|\boldsymbol{\Omega}| = |\mathbf{D}| = \sigma^{2T} \prod_{t=1}^T \frac{S_{t+1}}{S_t} = \sigma^{2T} \frac{S_{T+1}}{S_1} = \sigma^{2T} S_{T+1}$$

car le produit est télescopique.

- De plus :

$$(\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Omega}^{-1} (\mathbf{y} - \boldsymbol{\mu}) = \tilde{\mathbf{y}}' \mathbf{D}^{-1} \tilde{\mathbf{y}} = \sum_{t=1}^T \frac{\tilde{y}_t^2}{d_t}$$



## Vraisemblance exacte du MA(1) (6/6)

- La log-vraisemblance exacte s'écrit alors :

$$\mathcal{L}(\boldsymbol{\theta}) = -\frac{T}{2} \log(2\pi) - \frac{1}{2} \sum_{t=1}^T \log(d_t) - \frac{1}{2} \sum_{t=1}^T \frac{\tilde{y}_t^2}{d_t}$$

avec  $d_t = \sigma^2 S_{t+1}/S_t$  et  $S_t = 1 + \theta^2 + \dots + \theta^{2(t-1)}$ .

- Cette expression est valide pour **toute** valeur de  $\theta$  (pas seulement  $|\theta| < 1$ ).
- On montre que si  $\theta = \hat{\theta}$  maximise cette expression, alors  $\hat{\theta}^{-1}$  donne la même valeur. On retient la solution inversible :  $|\hat{\theta}| < 1$ .
- Pour la vraisemblance conditionnelle, cette propriété n'est pas garantie.

# Plan

Introduction

Vraisemblance d'un processus  $AR(1)$  gaussien

Vraisemblance d'un processus  $AR(p)$  gaussien

Estimation par quasi-maximum de vraisemblance

Vraisemblance d'un processus  $MA(1)$  gaussien

**Vraisemblance d'un processus  $MA(q)$  gaussien**

Vraisemblance d'un processus  $ARMA(p, q)$  gaussien

Optimisation numérique

Distribution asymptotique et tests

Identification et sélection de modèles

## Le modèle MA( $q$ ) gaussien

- ▶ On considère le processus MA( $q$ ) gaussien :

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q}$$

avec  $\varepsilon_t \sim \text{i.i.d. } N(0, \sigma^2)$ .

- ▶ Le vecteur de paramètres est  $\boldsymbol{\theta} = (\mu, \theta_1, \dots, \theta_q, \sigma^2)'$ .
- ▶ La matrice de variance-covariance  $\boldsymbol{\Omega}$  est une matrice bande de largeur  $q$  : les autocovariances  $\gamma_k$  sont nulles pour  $k > q$ .

## Vraisemblance conditionnelle du MA( $q$ )

- ▶ On pose  $\varepsilon_0 = \varepsilon_{-1} = \dots = \varepsilon_{-q+1} = 0$ .
- ▶ Les innovations sont calculées par récurrence :

$$\varepsilon_t = y_t - \mu - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

pour  $t = 1, 2, \dots, T$ .

- ▶ La log-vraisemblance conditionnelle est :

$$\mathcal{L}_c(\boldsymbol{\theta}) = -\frac{T}{2} \log(2\pi) - \frac{T}{2} \log(\sigma^2) - \sum_{t=1}^T \frac{\varepsilon_t^2}{2\sigma^2}$$

- ▶ Cette approximation est valide si toutes les racines de  $1 + \theta_1 z + \dots + \theta_q z^q = 0$  sont de module  $> 1$  (inversibilité).

## Vraisemblance exacte du $\text{MA}(q)$

- ▶ La structure bande de  $\boldsymbol{\Omega}$  permet d'utiliser la factorisation triangulaire  $\boldsymbol{\Omega} = \mathbf{A}\mathbf{D}\mathbf{A}'$ .
- ▶  $\mathbf{A}$  est une matrice triangulaire inférieure bande :  $a_{ij} = 0$  pour  $i > q + j$ .
- ▶ Les éléments de  $\tilde{\mathbf{y}} = \mathbf{A}^{-1}(\mathbf{y} - \boldsymbol{\mu})$  se calculent récursivement par résolution d'un système triangulaire.
- ▶ La log-vraisemblance exacte est :

$$\mathcal{L}(\boldsymbol{\theta}) = -\frac{T}{2} \log(2\pi) - \frac{1}{2} \sum_{t=1}^T \log(d_{tt}) - \frac{1}{2} \sum_{t=1}^T \frac{\tilde{y}_t^2}{d_{tt}}$$

- ▶ Contrairement à la vraisemblance conditionnelle, l'expression exacte est valide pour toute valeur de  $(\theta_1, \dots, \theta_q)$ .

# Plan

Introduction

Vraisemblance d'un processus  $AR(1)$  gaussien

Vraisemblance d'un processus  $AR(p)$  gaussien

Estimation par quasi-maximum de vraisemblance

Vraisemblance d'un processus  $MA(1)$  gaussien

Vraisemblance d'un processus  $MA(q)$  gaussien

Vraisemblance d'un processus  $ARMA(p, q)$  gaussien

Optimisation numérique

Distribution asymptotique et tests

Identification et sélection de modèles

## Le modèle ARMA( $p, q$ ) gaussien

- Le modèle ARMA( $p, q$ ) gaussien s'écrit :

$$Y_t = c + \phi_1 Y_{t-1} + \cdots + \phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q}$$

avec  $\varepsilon_t \sim \text{i.i.d. } N(0, \sigma^2)$ .

- Le vecteur de paramètres est  $\boldsymbol{\theta} = (c, \phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q, \sigma^2)'$ .
- Le nombre de paramètres est  $p + q + 2$ .

## Vraisemblance conditionnelle du ARMA( $p, q$ )

- ▶ On fixe les conditions initiales :
  - ▶  $\mathbf{y}_0 = (y_0, y_{-1}, \dots, y_{-p+1})'$  aux valeurs observées ou à l'espérance,
  - ▶  $\boldsymbol{\varepsilon}_0 = (\varepsilon_0, \varepsilon_{-1}, \dots, \varepsilon_{-q+1})' = \mathbf{0}$ .
- ▶ Les innovations sont calculées récursivement :

$$\varepsilon_t = y_t - c - \phi_1 y_{t-1} - \dots - \phi_p y_{t-p} - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

pour  $t = 1, 2, \dots, T$ .

- ▶ La log-vraisemblance conditionnelle est :

$$\mathcal{L}_c(\boldsymbol{\theta}) = -\frac{T}{2} \log(2\pi) - \frac{T}{2} \log(\sigma^2) - \sum_{t=1}^T \frac{\varepsilon_t^2}{2\sigma^2}$$



## Conditions initiales alternatives

- ▶ **Approche Box-Jenkins** : On fixe  $y_s = c/(1 - \phi_1 - \dots - \phi_p)$  pour  $s \leq 0$  et  $\varepsilon_s = 0$  pour  $s \leq 0$ .
- ▶ **Approche alternative** : On fixe les  $\varepsilon$  à zéro et les  $y$  à leurs valeurs observées. On commence l'itération à  $t = p + 1$  :

$$\varepsilon_p = \varepsilon_{p-1} = \dots = \varepsilon_{p-q+1} = 0$$

La log-vraisemblance conditionnelle est alors :

$$\mathcal{L}_c(\boldsymbol{\theta}) = -\frac{T-p}{2} \log(2\pi) - \frac{T-p}{2} \log(\sigma^2) - \sum_{t=p+1}^T \frac{\varepsilon_t^2}{2\sigma^2}$$

- ▶ Ces approximations sont valides si toutes les racines de  $\phi(z) = 0$  et  $\theta(z) = 0$  sont de module  $> 1$ .

## Vraisemblance exacte

- ▶ L'approche la plus rigoureuse utilise le **filtre de Kalman** pour calculer la vraisemblance exacte.
- ▶ Le filtre de Kalman fournit, de manière récursive, les prévisions optimales et les erreurs de prévision, ce qui permet de construire la vraisemblance par décomposition en erreurs de prévision.
- ▶ Alternativement, on peut utiliser la **factorisation triangulaire** de la matrice de variance-covariance  $\Omega$ , comme dans le cas MA.
- ▶ Les deux approches donnent le même résultat mais différent en termes d'implémentation informatique.

# Plan

Introduction

Vraisemblance d'un processus  $AR(1)$  gaussien

Vraisemblance d'un processus  $AR(p)$  gaussien

Estimation par quasi-maximum de vraisemblance

Vraisemblance d'un processus  $MA(1)$  gaussien

Vraisemblance d'un processus  $MA(q)$  gaussien

Vraisemblance d'un processus  $ARMA(p, q)$  gaussien

**Optimisation numérique**

Distribution asymptotique et tests

Identification et sélection de modèles

## Le problème d'optimisation

- ▶ La log-vraisemblance est une fonction non linéaire de  $\theta$ . Il faut trouver :

$$\hat{\theta} = \arg \max_{\theta} \mathcal{L}(\theta)$$

- ▶ **Exception** : pour un processus AR pur, les estimateurs ont une solution analytique (MCO).
- ▶ Dans le cas général (MA ou ARMA), il faut recourir à des méthodes d'**optimisation numérique**.
- ▶ Idée : calculer numériquement  $\mathcal{L}(\theta)$  pour différentes valeurs de  $\theta$  et chercher la valeur qui maximise cette fonction.

## Recherche sur grille (*grid search*)

- ▶ La méthode la plus simple : évaluer  $\mathcal{L}(\theta)$  sur une grille de valeurs de  $\theta$ .
- ▶ **Exemple** : Pour un AR(1) avec  $c = 0$  et  $\sigma^2 = 1$ , on évalue  $\mathcal{L}(\phi)$  pour  $\phi \in \{-0.9, -0.8, \dots, 0.8, 0.9\}$ .
- ▶ On raffine la grille autour du maximum.
- ▶ **Avantage** : Simple et permet de visualiser la surface de vraisemblance.
- ▶ **Inconvénient** : Devient impraticable quand le nombre de paramètres augmente (malédiction de la dimension).

# Gradient et méthode de plus forte pente

- ▶ On définit le **gradient** de la log-vraisemblance :

$$\mathbf{g}(\boldsymbol{\theta}) = \frac{\partial \mathcal{L}(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}}$$

C'est un vecteur qui pointe dans la direction d'augmentation la plus rapide de  $\mathcal{L}$ .

- ▶ Méthode de plus forte pente (*steepest ascent*) :

$$\boldsymbol{\theta}^{(n+1)} = \boldsymbol{\theta}^{(n)} + \alpha_n \mathbf{g}(\boldsymbol{\theta}^{(n)})$$

où  $\alpha_n > 0$  est le **pas** de l'algorithme.

- ▶ On itère jusqu'à convergence :  $\|\boldsymbol{\theta}^{(n+1)} - \boldsymbol{\theta}^{(n)}\| < \epsilon$  ou  $\|\mathbf{g}(\boldsymbol{\theta}^{(n)})\| < \epsilon$ .

## Calcul du gradient

- ▶ Le gradient peut être calculé de deux manières.
- ▶ **Analytiquement** : On différencie  $\mathcal{L}(\boldsymbol{\theta})$  par rapport à chaque élément de  $\boldsymbol{\theta}$ . C'est possible pour les modèles AR et MA, mais les expressions deviennent complexes pour les modèles ARMA.
- ▶ **Numériquement** : On approxime les dérivées partielles par différences finies :

$$\frac{\partial \mathcal{L}}{\partial \theta_i} \approx \frac{\mathcal{L}(\boldsymbol{\theta} + h\mathbf{e}_i) - \mathcal{L}(\boldsymbol{\theta} - h\mathbf{e}_i)}{2h}$$

où  $\mathbf{e}_i$  est le  $i$ -ème vecteur de la base canonique et  $h$  est un petit incrément.

- ▶ Le gradient numérique est facile à programmer mais introduit une erreur d'approximation.

# Maxima locaux et globaux

- ▶ Si la log-vraisemblance est **unimodale**, les méthodes itératives convergent vers le maximum global, quel que soit le point de départ.
- ▶ En général,  $\mathcal{L}(\boldsymbol{\theta})$  peut avoir plusieurs **maxima locaux**. L'algorithme converge alors vers le maximum local le plus proche du point de départ.
- ▶ **Stratégies pratiques :**
  - ▶ Essayer plusieurs points de départ différents
  - ▶ Utiliser d'abord une recherche sur grille grossière, puis affiner avec une méthode de gradient
  - ▶ Comparer les valeurs de  $\mathcal{L}(\hat{\boldsymbol{\theta}})$  obtenues à partir de différents points de départ



# Plan

Introduction

Vraisemblance d'un processus  $AR(1)$  gaussien

Vraisemblance d'un processus  $AR(p)$  gaussien

Estimation par quasi-maximum de vraisemblance

Vraisemblance d'un processus  $MA(1)$  gaussien

Vraisemblance d'un processus  $MA(q)$  gaussien

Vraisemblance d'un processus  $ARMA(p, q)$  gaussien

Optimisation numérique

**Distribution asymptotique et tests**

Identification et sélection de modèles

## La fonction de score

- ▶ On appelle **fonction de score** le gradient de la log-vraisemblance :

$$\mathbf{s}(\boldsymbol{\theta}) = \frac{\partial \mathcal{L}(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}}$$

C'est un vecteur de dimension  $(p + q + 2) \times 1$ .

- ▶ Sous des conditions de régularité (échange dérivée/intégrale), le score a une espérance nulle évaluée en la vraie valeur :

$$\mathbb{E}_{\boldsymbol{\theta}_0}[\mathbf{s}(\boldsymbol{\theta}_0)] = \mathbf{0}$$

- ▶ Intuition : à la vraie valeur des paramètres, la log-vraisemblance est en moyenne à son maximum.

## Matrice d'information de Fisher

- La **matrice d'information de Fisher** est définie par :

$$\mathcal{I}(\boldsymbol{\theta}) = \mathbb{V}_{\boldsymbol{\theta}}[\mathbf{s}(\boldsymbol{\theta})] = \mathbb{E}_{\boldsymbol{\theta}}[\mathbf{s}(\boldsymbol{\theta})\mathbf{s}(\boldsymbol{\theta})']$$

- Sous les conditions de régularité, on a l'**égalité de l'information** :

$$\mathcal{I}(\boldsymbol{\theta}) = -\mathbb{E}_{\boldsymbol{\theta}}\left[\frac{\partial^2 \mathcal{L}(\boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}'}\right] = -\mathbb{E}_{\boldsymbol{\theta}}[\mathbf{H}(\boldsymbol{\theta})]$$

où  $\mathbf{H}(\boldsymbol{\theta})$  est la matrice **hessienne** de la log-vraisemblance.

- La matrice d'information mesure la quantité d'information que l'échantillon contient sur les paramètres.

# Borne de Cramér-Rao

- **Borne de Cramér-Rao** : Pour tout estimateur sans biais  $\hat{\theta}$  de  $\theta$  :

$$\mathbb{V}(\hat{\theta}) \geq \mathcal{I}(\theta)^{-1}$$

au sens des matrices (la différence est semi-définie positive).

- L'estimateur du maximum de vraisemblance **atteint** cette borne asymptotiquement : c'est l'estimateur le plus précis (asymptotiquement) parmi les estimateurs réguliers.
- Plus la courbure de la log-vraisemblance est forte autour de  $\theta_0$  (information de Fisher élevée), plus l'estimation est précise.

## Distribution asymptotique de l'EMV

- Sous des conditions de régularité (stationnarité, ergodicité, identifiabilité,  $\theta_0$  intérieur à l'espace des paramètres), l'EMV vérifie :

- Convergence :

$$\hat{\theta} \xrightarrow{p} \theta_0 \quad \text{quand } T \rightarrow \infty$$

- Normalité asymptotique :

$$\sqrt{T} \left( \hat{\theta} - \theta_0 \right) \xrightarrow{d} N(\mathbf{0}, \mathcal{I}(\theta_0)^{-1})$$

- En d'autres termes, pour  $T$  grand :

$$\hat{\theta} \overset{a}{\sim} N\left(\theta_0, \frac{1}{T} \mathcal{I}(\theta_0)^{-1}\right)$$

## Erreurs standard et intervalles de confiance

- ▶ En pratique, on estime la matrice de variance-covariance en remplaçant la matrice d'information par la **hessienne observée** :

$$\widehat{\mathbf{V}}(\hat{\boldsymbol{\theta}}) = \left[ -\mathbf{H}(\hat{\boldsymbol{\theta}}) \right]^{-1} = \left[ -\frac{\partial^2 \mathcal{L}}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}'} \Big|_{\boldsymbol{\theta}=\hat{\boldsymbol{\theta}}} \right]^{-1}$$

- ▶ L'**erreur standard** du  $i$ -ème paramètre est :

$$\text{se}(\hat{\theta}_i) = \sqrt{\left[ \widehat{\mathbf{V}}(\hat{\boldsymbol{\theta}}) \right]_{ii}}$$

- ▶ Un **intervalle de confiance** à 95% pour  $\theta_i$  est :

$$\hat{\theta}_i \pm 1,96 \times \text{se}(\hat{\theta}_i)$$

## Estimateur OPG

- ▶ Une alternative à la hessienne est l'estimateur **OPG** (*outer product of gradients*). On décompose la log-vraisemblance en contributions individuelles :

$$\mathcal{L}(\boldsymbol{\theta}) = \sum_{t=1}^T \ell_t(\boldsymbol{\theta})$$

- ▶ La matrice d'information est estimée par :

$$\hat{\mathcal{I}}_{\text{OPG}} = \sum_{t=1}^T \frac{\partial \ell_t(\hat{\boldsymbol{\theta}})}{\partial \boldsymbol{\theta}} \frac{\partial \ell_t(\hat{\boldsymbol{\theta}})}{\partial \boldsymbol{\theta}'}$$

- ▶ Cet estimateur est facile à calculer (pas besoin de dérivées secondes), mais peut être moins précis en petit échantillon.

## Cas du quasi-maximum de vraisemblance

- ▶ Si le modèle est mal spécifié (par exemple, on maximise une vraisemblance gaussienne alors que les erreurs ne sont pas gaussiennes), l'égalité de l'information **ne tient plus** :

$$\mathbf{A} = -\mathbb{E}[\mathbf{H}(\boldsymbol{\theta}_0)] \neq \mathbf{B} = \mathbb{E}[\mathbf{s}(\boldsymbol{\theta}_0)\mathbf{s}(\boldsymbol{\theta}_0)']$$

- ▶ La distribution asymptotique du QMLE est alors :

$$\sqrt{T} \left( \hat{\boldsymbol{\theta}} - \boldsymbol{\theta}_0 \right) \xrightarrow{d} N(\mathbf{0}, \mathbf{A}^{-1} \mathbf{B} \mathbf{A}^{-1})$$

- ▶ La matrice  $\mathbf{A}^{-1} \mathbf{B} \mathbf{A}^{-1}$  est appelée **matrice sandwich** (ou estimateur de White/Huber). Il faut l'utiliser pour obtenir des erreurs standard robustes.



## Estimation de la matrice sandwich

- En pratique, on estime :

$$\hat{\mathbf{A}} = -\frac{1}{T} \mathbf{H}(\hat{\boldsymbol{\theta}}) = -\frac{1}{T} \frac{\partial^2 \mathcal{L}}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}'} \bigg|_{\hat{\boldsymbol{\theta}}}$$

- Et :

$$\hat{\mathbf{B}} = \frac{1}{T} \sum_{t=1}^T \frac{\partial \ell_t(\hat{\boldsymbol{\theta}})}{\partial \boldsymbol{\theta}} \frac{\partial \ell_t(\hat{\boldsymbol{\theta}})}{\partial \boldsymbol{\theta}'}$$

- L'estimateur robuste de la variance est alors :

$$\hat{\mathbf{V}}_{\text{rob}}(\hat{\boldsymbol{\theta}}) = \frac{1}{T} \hat{\mathbf{A}}^{-1} \hat{\mathbf{B}} \hat{\mathbf{A}}^{-1}$$

- Si le modèle est correctement spécifié,  $\hat{\mathbf{A}} \approx \hat{\mathbf{B}}$  et on retrouve l'estimateur classique.

## Test de Wald

- ▶ On souhaite tester l'hypothèse linéaire  $H_0 : \mathbf{R}\boldsymbol{\theta} = \mathbf{r}$  où  $\mathbf{R}$  est une matrice  $(r \times k)$  de rang  $r$  et  $k = p + q + 2$ .
- ▶ La statistique de Wald est :

$$W = (\mathbf{R}\hat{\boldsymbol{\theta}} - \mathbf{r})' \left[ \mathbf{R} \hat{\mathbb{V}}(\hat{\boldsymbol{\theta}}) \mathbf{R}' \right]^{-1} (\mathbf{R}\hat{\boldsymbol{\theta}} - \mathbf{r})$$

- ▶ Sous  $H_0$  et asymptotiquement :

$$W \xrightarrow{d} \chi^2(r)$$

- ▶ **Avantage** : Ne nécessite que l'estimation du modèle **non contraint**.

## Test de Wald : cas scalaire

- Pour tester  $H_0 : \theta_i = \theta_i^0$  (un seul paramètre), la statistique de Wald se simplifie en la ***t*-statistique** au carré :

$$W = \left( \frac{\hat{\theta}_i - \theta_i^0}{\text{se}(\hat{\theta}_i)} \right)^2 \xrightarrow{d} \chi^2(1)$$

- De manière équivalente, la *t*-statistique :

$$t = \frac{\hat{\theta}_i - \theta_i^0}{\text{se}(\hat{\theta}_i)} \xrightarrow{d} N(0, 1)$$

- **Exemple** : Pour tester si un coefficient AR ou MA est significativement différent de zéro, on calcule  $t = \hat{\theta}_i / \text{se}(\hat{\theta}_i)$  et on rejette  $H_0$  si  $|t| > 1,96$  au seuil de 5%.

## Test du rapport de vraisemblance

- ▶ On estime le modèle sous  $H_0$  (contraint,  $\tilde{\theta}$ ) et sous  $H_1$  (non contraint,  $\hat{\theta}$ ).
- ▶ La **statistique du rapport de vraisemblance** (*likelihood ratio*) est :

$$LR = 2 \left[ \mathcal{L}(\hat{\theta}) - \mathcal{L}(\tilde{\theta}) \right]$$

- ▶ Sous  $H_0$  et asymptotiquement :

$$LR \xrightarrow{d} \chi^2(r)$$

- ▶ **Avantage** : Ne nécessite pas le calcul de la matrice de variance-covariance.
- ▶ **Inconvénient** : Requiert l'estimation des deux modèles (contraint et non contraint).

## Test du rapport de vraisemblance : exemple

- ▶ **Test d'un AR(1) contre un AR(2) :**

- ▶ Modèle non contraint :  $Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \varepsilon_t$
- ▶ Modèle contraint ( $H_0 : \phi_2 = 0$ ) :  $Y_t = c + \phi_1 Y_{t-1} + \varepsilon_t$

- ▶ On calcule :

$$LR = 2 \left[ \mathcal{L}_{\text{AR}(2)}(\hat{\boldsymbol{\theta}}) - \mathcal{L}_{\text{AR}(1)}(\tilde{\boldsymbol{\theta}}) \right]$$

- ▶ On rejette  $H_0$  si  $LR > \chi_{1,0,95}^2 = 3,84$  (seuil à 5%, 1 degré de liberté).
- ▶ Ce test est directement applicable à la sélection de l'ordre d'un modèle ARMA.

## Test du multiplicateur de Lagrange

- ▶ Le test du **multiplicateur de Lagrange** (ou **test du score**) utilise uniquement l'estimation sous  $H_0$  :

$$LM = s(\tilde{\theta})' \mathcal{I}(\tilde{\theta})^{-1} s(\tilde{\theta})$$

où  $s(\tilde{\theta})$  est le score évalué à l'estimateur contraint.

- ▶ Sous  $H_0$  et asymptotiquement :

$$LM \xrightarrow{d} \chi^2(r)$$

- ▶ **Intuition** : Si  $H_0$  est vraie, le score  $s(\tilde{\theta})$  doit être proche de zéro. Un score élevé (en norme) fournit une preuve contre  $H_0$ .
- ▶ **Avantage** : Ne nécessite que l'estimation du modèle **contraint** (le plus simple).

## Comparaison des trois tests

- ▶ Les trois tests (Wald, LR, LM) sont **asymptotiquement équivalents** sous  $H_0$  : ils ont la même distribution limite  $\chi^2(r)$ .
- ▶ En échantillon fini, ils peuvent donner des résultats différents. On montre que :

$$W \geq LR \geq LM$$

Le test de Wald rejette le plus souvent, le test LM le moins.

- ▶ **Choix pratique :**
  - ▶ Test de Wald : facile si le modèle non contraint est déjà estimé,
  - ▶ Test LR : le plus couramment utilisé pour comparer des modèles emboîtés,
  - ▶ Test LM : utile quand le modèle contraint est beaucoup plus simple.

## Critères d'information

- Pour comparer des modèles **non emboîtés**, on utilise des critères d'information qui pénalisent la complexité.

- **Critère d'Akaike (AIC, 1973) :**

$$\text{AIC} = -2\mathcal{L}(\hat{\theta}) + 2k$$

où  $k$  est le nombre de paramètres estimés.

- **Critère bayésien de Schwarz (BIC, 1978) :**

$$\text{BIC} = -2\mathcal{L}(\hat{\theta}) + k \log T$$

- On sélectionne le modèle qui **minimise** le critère. Le BIC pénalise davantage la complexité ( $\log T > 2$  dès que  $T \geq 8$ ) et sélectionne des modèles plus parcimonieux.



## Critères d'information : propriétés

- ▶ **AIC** : Minimise asymptotiquement l'erreur quadratique moyenne de prévision. Tend à sélectionner des modèles légèrement sur-paramétrés.
- ▶ **BIC** : Sélectionne le vrai modèle avec probabilité tendant vers 1 quand  $T \rightarrow \infty$  (**consistant**). Tend à sélectionner des modèles sous-paramétrés en petit échantillon.
- ▶ **En pratique** :
  - ▶ Si l'objectif est la **prévision**, l'AIC est souvent préféré.
  - ▶ Si l'objectif est l'**identification** du vrai modèle, le BIC est plus adapté.
  - ▶ On estime plusieurs modèles ARMA( $p, q$ ) pour  $p, q \in \{0, 1, \dots, p_{\max}\}$  et on retient celui qui minimise le critère choisi.

# Plan

Introduction

Vraisemblance d'un processus  $AR(1)$  gaussien

Vraisemblance d'un processus  $AR(p)$  gaussien

Estimation par quasi-maximum de vraisemblance

Vraisemblance d'un processus  $MA(1)$  gaussien

Vraisemblance d'un processus  $MA(q)$  gaussien

Vraisemblance d'un processus  $ARMA(p, q)$  gaussien

Optimisation numérique

Distribution asymptotique et tests

Identification et sélection de modèles

# Approche de Box-Jenkins

- ▶ Box et Jenkins (1976) proposent une procédure en quatre étapes :
- ▶ **(1) Transformation** : Transformer les données pour obtenir une série approximativement stationnaire (différenciation, logarithme).
- ▶ **(2) Identification** : Choisir les ordres  $p$  et  $q$  à l'aide des autocorrélations et autocorrélations partielles empiriques.
- ▶ **(3) Estimation** : Estimer les paramètres  $\phi(L)$  et  $\theta(L)$  par maximum de vraisemblance.
- ▶ **(4) Diagnostic** : Vérifier que le modèle estimé est compatible avec les données observées.

## Autocorrélations empiriques

- L'autocorrélation empirique d'ordre  $j$  est :

$$\hat{\rho}_j = \frac{\hat{\gamma}_j}{\hat{\gamma}_0}$$

où

$$\hat{\gamma}_j = \frac{1}{T} \sum_{t=j+1}^T (y_t - \bar{y})(y_{t-j} - \bar{y}), \quad \bar{y} = \frac{1}{T} \sum_{t=1}^T y_t$$

- Si les données proviennent d'un processus  $MA(q)$ , alors  $\rho_j = 0$  pour  $j > q$ . On s'attend donc à ce que  $\hat{\rho}_j \approx 0$  pour  $j > q$ .
- Sous l'hypothèse de bruit blanc,  $\hat{\rho}_j$  est approximativement distribué selon  $N(0, 1/T)$ . L'intervalle de confiance à 95% est  $\pm 2/\sqrt{T}$ .

## Autocorrélations partielles empiriques

- L'**autocorrélation partielle** empirique d'ordre  $m$  est le dernier coefficient  $\hat{\alpha}_m^{(m)}$  dans la régression :

$$y_{t+1} = \hat{c} + \hat{\alpha}_1^{(m)} y_t + \hat{\alpha}_2^{(m)} y_{t-1} + \cdots + \hat{\alpha}_m^{(m)} y_{t-m+1} + \hat{e}_t$$

- Si les données proviennent d'un processus  $AR(p)$ , alors l'autocorrélation partielle est nulle pour  $m > p$  :

$$\alpha_m^{(m)} = 0 \quad \text{pour } m > p$$

- Sous cette hypothèse,  $\mathbb{V}(\hat{\alpha}_m^{(m)}) \approx 1/T$  et l'intervalle de confiance à 95% est  $\pm 2/\sqrt{T}$ .

## Règles d'identification

- ▶ **Processus MA( $q$ )** : Les autocorrélations  $\hat{\rho}_j$  sont significativement non nulles pour  $j \leq q$ , puis deviennent nulles au-delà. Les autocorrélations partielles décroissent progressivement.
- ▶ **Processus AR( $p$ )** : Les autocorrélations partielles  $\hat{\alpha}_m^{(m)}$  sont significativement non nulles pour  $m \leq p$ , puis deviennent nulles au-delà. Les autocorrélations décroissent progressivement (mélange d'exponentielles ou de sinusoides amorties).
- ▶ **Processus ARMA( $p, q$ )** : Les deux fonctions décroissent progressivement. L'identification est plus difficile et demande souvent d'essayer plusieurs spécifications.

# Philosophie de la parcimonie

- ▶ Box et Jenkins insistent sur le principe de **parcimonie** : utiliser le moins de paramètres possible.
- ▶ Un modèle avec trop de paramètres :
  - ▶ s'ajuste bien aux données historiques (sur-ajustement),
  - ▶ mais prévoit mal hors échantillon.
- ▶ La découverte que des modèles ARMA avec de petites valeurs de  $p$  et  $q$  produisent souvent de meilleures prévisions que les grands modèles macroéconométriques a été un résultat marquant.
- ▶ En pratique, des valeurs de  $p$  et  $q$  inférieures ou égales à 2 ou 3 suffisent pour la plupart des applications.

# Résumé

- ▶ Le **maximum de vraisemblance** est le principe d'estimation dominant.
- ▶ Pour les processus **AR purs**, l'estimation se réduit aux MCO.
- ▶ Pour les processus **MA** et **ARMA**, la vraisemblance est non linéaire et nécessite une optimisation numérique.
- ▶ La vraisemblance **conditionnelle** simplifie les calculs mais nécessite l'inversibilité. La vraisemblance **exacte** est plus robuste.
- ▶ L'EMV est **asymptotiquement normal** avec une variance atteignant la borne de Cramér-Rao.
- ▶ Les tests de **Wald**, du **rapport de vraisemblance** et du **multiplicateur de Lagrange** permettent de tester des hypothèses sur les paramètres.
- ▶ Les critères **AIC** et **BIC** complètent l'identification par les autocorrélations pour la sélection de modèles.