

Processos autoregressivos (parte 3)

Prof. Caio Azevedo

Introdução

- Vimos como estimar, supondo apenas a estacionariedade fraca, de um dado processo, sua média, função de auto-covariância (FACV) e função de auto-correlação (FAC) ([aqui](#)).
- Usualmente, quando outras características desse processo são levadas em consideração, por exemplo, no processo de estimação, podemos obter melhores resultados (menor(es), viés, variância, eqm).
- Vamos considerar, neste momento, processos AR(p).

Introdução

- Um processo estocástico $\{Y_t\}$ é dito ser um processo AR(p) (essencialmente) se:

$$Y_t = \phi_1 Y_{t-1} + \cdots + \phi_p Y_{t-p} + \epsilon_t. \quad (1)$$

- Algumas propriedades foram discutidas (ao menos para casos particulares) [aqui](#), [aqui](#) e [aqui](#).
- Vamos nos focar no caso em que o processo (1) é **estacionário, causal** e que $\epsilon_t \sim RB(0, \sigma^2)$.

Introdução

- Não é difícil verificar que $\mathcal{E}(Y_t) = 0, \forall t$.
- A versão do processo (1) de média μ ($\mathcal{E}(Y_t) = \mu, \forall t$) é dada por:

$$Y_t = \mu + \phi_1 (Y_{t-1} - \mu) + \dots + \phi_p (Y_{t-p} - \mu) + \epsilon_t, \epsilon_t \sim RB(0, \sigma^2).$$

- Considere, inicialmente, o problema de estimar a FACV e FAC de um processo AR(p), com $\mu = 0$.

- Note que (multiplicando-se ambos os lados da primeira Equação (1) por Y_t):

$$Y_t = \phi_1 Y_{t-1} + \cdots + \phi_p Y_{t-p} + \epsilon_t$$

$$Y_t^2 = \phi_1 Y_t Y_{t-1} + \cdots + \phi_p Y_t Y_{t-p} + Y_t \epsilon_t$$

$$E(Y_t^2) = \phi_1 E(Y_t Y_{t-1}) + \cdots + \phi_p E(Y_t Y_{t-p}) + E(Y_t \epsilon_t)$$

$$\gamma(0) = \phi_1 \gamma(1) + \cdots + \phi_p \gamma(p) + E(Y_t \epsilon_t). \quad (2)$$

- Lembrando que $\gamma(h)$ é a função de **auto-covariância** do processo.

- Além disso, como o processo é causal então $E(\epsilon_t Y_{t-k}) = 0$ para $k \geq 1$, logo (multiplicando-se ambos os lados da primeira Equação (1) por ϵ_t):

$$\begin{aligned} Y_t &= \phi_1 Y_{t-1} + \cdots + \phi_p Y_{t-p} + \epsilon_t \\ \epsilon_t Y_t &= \phi_1 \epsilon_t Y_{t-1} + \cdots + \phi_p \epsilon_t Y_{t-p} + \epsilon_t^2 \\ E(\epsilon_t Y_t) &= \phi_1 E(\epsilon_t Y_{t-1}) + \cdots + E(\phi_p \epsilon_t Y_{t-p}) + E(\epsilon_t^2) \\ E(\epsilon_t Y_t) &= E(\epsilon_t^2) = \sigma^2. \end{aligned} \tag{3}$$

- Portanto, aplicando (3) em (2), temos que:

$$\begin{aligned}\gamma(0) &= \phi_1\gamma(1) + \cdots + \phi_p\gamma(p) + \sigma^2 \\ \rightarrow 1 &= \phi_1\rho(1) + \cdots + \phi_p\rho(p) + \frac{\sigma^2}{\gamma(0)} \\ \rightarrow \gamma(0) &= \frac{\sigma^2}{1 - \phi_1\rho(1) - \cdots - \phi_p\rho(p)}.\end{aligned}\tag{4}$$

- Por outro lado, temos que (multiplicando-se ambos os lados da Equação (5) por Y_{t-k} e dividindo-se ambos os lados da Equação (6) por $\gamma(0)$):

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \epsilon_t$$

$$Y_{t-k} Y_t = \phi_1 Y_{t-k} Y_{t-1} + \dots + \phi_p Y_{t-k} Y_{t-p} + Y_{t-k} \epsilon_t \quad (5)$$

$$E(Y_{t-k} Y_t) = \phi_1 E(Y_{t-k} Y_{t-1}) + \dots + \phi_p E(Y_{t-k} Y_{t-p}) + E(Y_{t-k} \epsilon_t)$$

$$\gamma(k) = \phi_1 \gamma(k-1) + \dots + \phi_p \gamma(k-p) \quad (6)$$

$$\rho(k) = \phi_1 \rho(k-1) + \dots + \phi_p \rho(k-p) \quad (7)$$

- Lembrando que, em um processo estacionário, $\rho(h) = \frac{\gamma(h)}{\gamma(0)}$.
- Em termos matriciais, a Equação (7), para $k = 1, \dots, p$ temos que:

$$\begin{bmatrix} \rho(0) & \rho(1) & \dots & \rho(p-1) \\ \rho(1) & \rho(0) & \dots & \rho(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ \rho(p-1) & \rho(p-2) & \dots & \rho(0) \end{bmatrix} \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{bmatrix} = \begin{bmatrix} \rho(1) \\ \rho(2) \\ \vdots \\ \rho(p) \end{bmatrix} \quad (8)$$

- Esse sistema de equações (Equação (8)) é conhecido na literatura como equações de **Yule-Walker**.
- De posse de $\phi = (\phi_1, \dots, \phi_p)'$ e de $\rho = (\rho(1), \dots, \rho(p))'$ podemos obter σ^2 através de (4), ou seja:

$$\hat{\sigma}^2 = \hat{\phi}(0) \left(1 - \hat{\phi}_1 \hat{\rho}(1) - \dots - \hat{\phi}_p \hat{\rho}(p) \right). \quad (9)$$

- Como estimar ρ e ϕ ?

Exemplo

- Considere o seguinte processo:

$$Y_t = 0,33Y_{t-1} + 0,5Y_{t-2} + \epsilon_t, \quad \epsilon_t \sim RB(0, \sigma^2)$$

$$\rightarrow (1 - 0,33B - 0,5B^2)Y_t = \epsilon_t,$$

- Fazendo $\phi(z) = 1 - 0,33z - 0,5z^2 = 0$ temos que $z = -1,78221$ e $z = 1,12221$.
- Logo o processo é estacionário e causal e, de (8), temos que:

$$\rho(k) = 0,33\rho(k-1) + 0,5\rho(k-2)$$

Exemplo

- Portanto, temos que as equações de Yule-Walker são dadas por:

$$\rho(1) = 0,33 + 0,5\rho(1)$$

$$\rho(2) = 0,33\rho(1) + 0,5.$$

- Resolvendo o sistema de equações acima, temos que $\rho(1) = 0,66$ e $\rho(2) = 0,7178$ e portanto $\gamma(0) = 2,362391\sigma^2$ (da Equação (9)).

Exemplo

- Para resolver as equações em diferença

$$\rho(k) = 0,33\rho(k-1) + 0,5\rho(k-2),$$

precisamos calcular as raízes de $\phi(z) = 1 - 0,33z - 0,5z^2 = 0$, que são $m_1 = -1,78221$ e $m_2 = 1,12221$. Adicionalmente, como elas são reais e diferentes, temos que:

$$\rho(k) = c_1 \left(\frac{1}{m_1} \right)^k + c_2 \left(\frac{1}{m_2} \right)^k.$$

- Para obter c_1 e c_2 utilizamos as primeiras autocorrelações estimadas, ou seja $\rho(1) = 0,66$ e $\rho(2) = 0,7178$.

Exemplo

- Dito isso, temos que:

$$\begin{aligned}0,66 &= c_1 \left(\frac{1}{m_1} \right) + c_2 \left(\frac{1}{m_2} \right) \\0,7178 &= c_1 \left(\frac{1}{m_1} \right)^2 + c_2 \left(\frac{1}{m_2} \right)^2.\end{aligned}$$

- Resolvendo a equação acima temos que $c_1 = 0,159143$ e $c_2 = 0,840867$, portanto:

$$\rho(k) = 0,159143 \left(-\frac{1}{1,78221} \right)^k + 0,840867 \left(\frac{1}{1,12221} \right)^k. \quad (10)$$

- Através a Equação (10) é possível calcular as demais auto-correlações ($k \geq 2$).

Estimação (usando o modelo) - Introdução

- Considere $\{Y_t\}$ um processo AR(p) com média μ , estacionário e causal:

$$Y_t = \mu + \phi_1(Y_{t-1} - \mu) + \dots + \phi_p(Y_{t-p} - \mu) + \epsilon_t, \quad \epsilon_t \sim RB(0, \sigma^2).$$

- Dada uma amostra $(y_1, \dots, y_n)'$ (ST observada), como podemos estimar os parâmetros $\theta = (\mu, \phi_1, \dots, \phi_p, \sigma^2)'$ = $(\mu, \phi', \sigma^2)'$, em que $\phi = (\phi_1, \dots, \phi_p)'$?
- Há algumas opções como : [métodos dos momentos](#), [mínimos quadrados condicionais](#), [máxima verossimilhança](#) e métodos bayesianos [ref1](#), [ref2](#). Discutiremos os três primeiros.

Estimação - Método dos momentos (MM)

- Consiste em igualar os momentos populacionais aos amostrais, resolvendo o respectivo sistema de equações resultante ([aqui](#)).
- Para μ , como este é a média do processo, o estimador pelo métodos dos momentos (EMM) é $\hat{\mu} = \bar{Y}$.

Estimação - Método dos momentos (MM)

- Para $\phi = (\phi_1, \dots, \phi_p)'$ podemos usar o sistema de Yule-Walker, substituindo $\rho(1), \dots, \rho(p)$ pelas **autocorrelações amostrais** $\hat{\rho}(1), \dots, \hat{\rho}(p)$ de sorte que:

$$\begin{bmatrix} \hat{\rho}(0) & \hat{\rho}(1) & \dots & \hat{\rho}(p-1) \\ \hat{\rho}(1) & \hat{\rho}(0) & \dots & \hat{\rho}(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\rho}(p-1) & \hat{\rho}(p-2) & \dots & \hat{\rho}(0) \end{bmatrix} \begin{bmatrix} \hat{\phi}_1 \\ \hat{\phi}_2 \\ \vdots \\ \hat{\phi}_p \end{bmatrix} = \begin{bmatrix} \hat{\rho}(1) \\ \hat{\rho}(2) \\ \vdots \\ \hat{\rho}(p) \end{bmatrix},$$

Estimação - Método dos momentos

- Portanto, temos que o EMM para ϕ é dado por $\hat{\phi} = \mathbf{R}^{-1}\mathbf{r}$, em que $\hat{\phi} = (\hat{\phi}_1, \dots, \hat{\phi}_p)^\top$, $\mathbf{r} = (\hat{\rho}(1), \dots, \hat{\rho}(p))'$ e

$$\mathbf{R} = \begin{bmatrix} 1 & \hat{\rho}(1) & \dots & \hat{\rho}(p-1) \\ \hat{\rho}(1) & 1 & \dots & \hat{\rho}(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\rho}(p-1) & \hat{\rho}(p-2) & \dots & 1 \end{bmatrix}.$$

Estimação - Método dos momentos - Exemplos

- **AR(1):** para o modelo AR(1) temos que $\hat{\phi} = (1)^{-1}\hat{\rho}(1) = \hat{\rho}(1)$.
- **AR(2):** para o modelo AR(2) temos que:

$$\begin{aligned} \begin{bmatrix} \hat{\phi}_1 \\ \hat{\phi}_2 \end{bmatrix} &= \begin{bmatrix} 1 & \hat{\rho}(1) \\ \hat{\rho}(1) & 1 \end{bmatrix}^{-1} \begin{bmatrix} \hat{\rho}(1) \\ \hat{\rho}(2) \end{bmatrix} \\ &= \frac{1}{1 - \hat{\rho}(1)^2} \begin{bmatrix} 1 & -\hat{\rho}(1) \\ -\hat{\rho}(1) & 1 \end{bmatrix} \begin{bmatrix} \hat{\rho}(1) \\ \hat{\rho}(2) \end{bmatrix} \\ &= \frac{1}{1 - \hat{\rho}(1)^2} \begin{bmatrix} \hat{\rho}(1) - \hat{\rho}(1)\hat{\rho}(2) \\ \hat{\rho}(2) - \hat{\rho}(1)^2 \end{bmatrix}. \end{aligned}$$

Estimação - Método dos momentos

- Para σ^2 , uma vez que:

$$\gamma(0) = \frac{\sigma^2}{1 - \phi_1\rho(1) - \dots - \phi_p\rho(p)},$$

então um estimador para σ^2 é:

$$\hat{\sigma}^2 = S^2(1 - \hat{\phi}_1\hat{\rho}(1) - \dots - \hat{\phi}_p\hat{\rho}(p)), \quad (11)$$

em que $S^2 = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \hat{\mu})^2$ é a variância amostral dos valores observados do processo.

Estimação - Método dos momentos

- Para obter outros resultados inferenciais (EP, IC, TH), o seguinte resultado assintótico é útil: sob certas condições de regularidade ([aqui](#)):

$$\sqrt{n}(\hat{\phi} - \phi) \xrightarrow[n \rightarrow \infty]{D} N(\mathbf{0}, \sigma^2 \mathbf{R}^{-1}).$$

- Note que, uma vez que estamos estimando parâmetros associados à um modelo de regressão, utilizando determinados métodos de estimação, os estimadores da média (μ) e da função de auto-covariância/auto-correlação ($\gamma(h), \phi(h)$), podem ser diferentes daqueles propostos [aqui](#).

Estimação - Mínimos quadrados condicionais (MQC)

- Assemelha-se ao método de mínimos quadrados ([aqui](#)), no sentido de minimizar uma soma de quadrados.
- Para um modelo AR(p) podemos escrever os erros como:

$$\epsilon_t = Y_t - \mu - \phi_1(Y_{t-1} - \mu) - \dots - \phi_p(Y_{t-p} - \mu).$$

- Contudo, no método de MQC, considera-se apenas os erros cujas esperanças condicionais de $Y_t | (Y_1, \dots, Y_p)$ são observáveis ($t \geq p$).
- Por exemplo, se $p = 1$ (AR(1)), não se observa (Y_0). Logo, $Y_1 = \mu + \phi Y_0 + \epsilon_1$ e, assim $\mathcal{E}(Y_1 | y_0) = \mu + \phi y_0$ não é observável.

Estimação - Mínimos quadrados condicionais (MQC)

- Logo, os estimadores de mínimos quadrados condicionais de $\theta = (\mu, \phi_1, \dots, \phi_p)'$ são obtidos minimizando:

$$S(\mu, \phi) = \sum_{t=p+1}^n \epsilon_t^2,$$

em relação à $(\mu, \phi)'$.

- Note que se utiliza $n - p$ observações no processo de estimação.

Estimação - Mínimos quadrados condicionais (MQC)

- 1 Se μ for conhecido, os estimadores de MQC de ϕ , possuem forma fechada.
- 2 Se μ for desconhecido, os estimadores de MQC de ϕ não possuem forma explícita. Assim, ou **métodos numéricos** (**resolução de sistemas de equações não lineares**, como Newton-Raphson, Escore de Fisher, BFGS etc), ou **aproximações analíticas/assintóticas** como expansão em série de Taylor, convergência estocástica, devem ser utilizados.
- 3 Uma alternativa é utilizar o EMM de μ ($\hat{\mu} = \bar{Y}$), na expressão de $\hat{\phi}$, mencionada no item 1).
- 4 Para mais detalhes veja [aqui](#) e [aqui](#).

Estimação - Mínimos quadrados condicionais

- Essencialmente, temos que resolver o seguinte sistema de equações não-lineares:

$$\left\{ \begin{array}{l} S(\mu) = \frac{\partial}{\partial \mu} S(\mu, \phi) \Big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 2 \sum_{t=p+1}^n \epsilon_t \frac{\partial}{\partial \mu} \epsilon_t \Big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 0 \\ S(\phi_1) = \frac{\partial}{\partial \phi_1} S(\mu, \phi) \Big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 2 \sum_{t=p+1}^n \epsilon_t \frac{\partial}{\partial \phi_1} \epsilon_t \Big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 0 \\ \vdots \\ S(\phi_p) = \frac{\partial}{\partial \phi_p} S(\mu, \phi) \Big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 2 \sum_{t=p+1}^n \epsilon_t \frac{\partial}{\partial \phi_p} \epsilon_t \Big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 0 \end{array} \right.$$

Estimação - Mínimos quadrados condicionais

- Como exemplo, considere um modelo AR(1). Os estimadores de mínimos quadrados condicionais para (μ, ϕ) são obtidos minimizando:

$$S(\mu, \phi) = \sum_{t=2}^n [y_t - \mu - \phi(y_{t-1} - \mu)]^2, \quad (12)$$

ou seja, resolvendo o seguinte sistema de equações:

$$\begin{cases} S(\mu) = \frac{\partial}{\partial \mu} S(\mu, \phi) \Big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 0 \\ S(\phi) = \frac{\partial}{\partial \phi} S(\mu, \phi) \Big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 0 \end{cases}$$

Estimação - Mínimos quadrados condicionais

- Derivando a Equação em (12) com relação a μ temos que:

$$\begin{aligned}\frac{\partial}{\partial \mu} S(\mu, \phi) &= 2 \sum_{t=2}^n (\phi - 1) [y_t - \mu - \phi(y_{t-1} - \mu)] \\ &= 2(\phi - 1) \sum_{t=2}^n y_t - 2\mu(\phi - 1)(n - 1) \\ &\quad - 2\phi(\phi - 1) \sum_{t=2}^n (y_{t-1} - \mu) \\ &= 2(\phi - 1)(n - 1) [\bar{y}_1 - \mu - \phi\bar{y}_2 + 2\phi\mu],\end{aligned}$$

em que $\bar{y}_1 = \sum_{t=2}^n y_t / (n - 1)$ e $\bar{y}_2 = \sum_{t=2}^n y_{t-1} / (n - 1)$.

Estimação - Mínimos quadrados condicionais

- Agora, derivando a Equação em (12) com relação a ϕ temos que:

$$\begin{aligned}\frac{\partial}{\partial \phi} S(\mu, \phi) &= -2 \sum_{t=2}^n (y_{t-1} - \mu) [y_t - \mu - \phi(y_{t-1} - \mu)] \\ &= -2 \left[\sum_{t=2}^n (y_{t-1} - \mu)(y_t - \mu) - \phi \sum_{t=2}^n (y_{t-1} - \mu)^2 \right].\end{aligned}$$

Estimação - Mínimos quadrados condicionais

- Por fim fazendo $\frac{\partial}{\partial \mu} S(\mu, \phi) = 0$ e $\frac{\partial}{\partial \phi} S(\mu, \phi) = 0$, temos que:

$$\begin{aligned}\hat{\mu} &= \frac{\bar{Y}_1 - \hat{\phi}\bar{Y}_2}{1 - \hat{\phi}}, \\ \hat{\phi} &= \frac{\sum_{t=2}^n (Y_{t-1} - \hat{\mu})(Y_t - \hat{\mu})}{\sum_{t=2}^n (Y_{t-1} - \hat{\mu})^2}.\end{aligned}\tag{13}$$

- Ou seja, não é possível obter uma solução explícita.
- Para estimar σ^2 podemos utilizar (11), por exemplo.
- **Proposição:** sob algumas condições, assintoticamente, os estimadores de mínimos quadrados condicionais equivalem aos estimadores pelo MM.

Estimação - Mínimos quadrados condicionais

- **Prova:** Note que se $n \rightarrow \infty$ então $\bar{Y}_1 = \bar{Y}_2 \approx \bar{Y}$ e se $\hat{\phi} \neq 1$, então:

$$\hat{\mu} \approx \frac{\bar{Y} - \hat{\phi}\bar{Y}}{1 - \hat{\phi}} = \bar{Y}. \quad (14)$$

- Assim, utilizando a Equação (14) na Equação (13), temos (se $n \rightarrow \infty$), que:

$$\hat{\phi} \approx \frac{\sum_{t=2}^n (Y_{t-1} - \bar{Y})(Y_t - \bar{Y})}{\sum_{t=2}^n (Y_{t-1} - \bar{Y})^2} = \hat{\rho}(1).$$

Estimação - máxima verossimilhança (MV)

- O método de MV consiste em, essencialmente, maximizar a verossimilhança associado ao modelo estatístico de interesse ([aqui](#)).
- Adicionalmente às suposições usuais, assumiremos que $\epsilon_t \sim NID(0, \sigma^2)$.
- Serão apresentados detalhes apenas para o modelo AR(1).
- Para o modelo geral AR(p) o raciocínio é análogo (veja [aqui](#)).

Estimação - máxima verossimilhança (MV)

- Seja, assim, o modelo AR(1) gaussiano:

$$Y_t = \mu + \phi(Y_{t-1} - \mu) + \epsilon_t, \quad \epsilon_t \sim N(0, \sigma^2), \quad |\phi| < 1. \quad (15)$$

- Da Equação (15), temos que $Y_t|y_{t-1} \sim N(\mu + \phi(Y_{t-1} - \mu), \sigma^2)$.
- Logo, considerando y_1, \dots, y_n os valores observados do processo, temos que a verossimilhança (condicional) é dada por:

$$L(\mu, \phi, \sigma^2) = f(y_1, \dots, y_n; \mu, \phi, \sigma^2) = f(y_1|y_0)f(y_2|y_1) \dots f(y_n|y_{n-1}).$$

Estimação - máxima verossimilhança (MV)

- Note que, para o modelo $AR(1)$, teremos e lidar com a “ausência” de Y_0 , pois $Y_1 = \mu + \phi(Y_0 - \mu) + \epsilon_1$.
- Logo, em $f(y_1|y_0)$, y_0 não é observável.
- Analogamente, no modelo $AR(p)$, teremos que lidar com a ausência de $(Y_0, Y_{-1}, \dots, Y_{p-1})'$.

Estimação - máxima verossimilhança (MV)

- Algumas soluções possíveis (veja [aqui](#)):
 - Usar a verossimilhança exata ou não condicional (sempre que possível, utilizaremos este método), que leva à não dependência de tais valores (podemos ter verossimilhanças exata e não condicional, diferentes entre si).
 - Usar a verossimilhança condicional e
 - Substituir os valores “ausentes” por valores considerados razoáveis (por especialista(s) na área em questão) ou por estimativas obtidas por outro método.
 - Usar métodos de “previsão para o passado” (“backforecasting”).

Estimação - máxima verossimilhança

- Voltando, temos que $Y_t|y_{t-1} \sim N(\mu + \phi(y_{t-1} - \mu), \sigma^2)$ com densidade:

$$f(y_t|y_{t-1}) = f_Z((y_t - \mu) - \phi(y_{t-1} - \mu)),$$

em que $f_Z(\cdot)$ é a densidade de $Z \sim N(0, \sigma^2)$.

- Logo, temos que:

$$L(\mu, \phi, \sigma^2) = f(y_1) \prod_{t=2}^n f_Z((y_t - \mu) - \phi(y_{t-1} - \mu)).$$

- Sabendo que $\{y_t\}$ é causal, então $y_1 = \mu + \sum_{j=0}^{\infty} \phi^j \epsilon_{1-j}$ e portanto $Y_1 \sim N(\mu, \sigma^2/(1 - \phi^2))$.

Estimação - máxima verossimilhança

- Finalmente, temos que:

$$L(\mu, \phi, \sigma^2) = \frac{\sqrt{1 - \phi^2}}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} S_1(\mu, \phi) \right\},$$

em que

$$S_1(\mu, \phi) = (1 - \phi^2)(y_1 - \mu)^2 + \sum_{t=2}^n [(y_t - \mu) - \phi(y_{t-1} - \mu)]^2,$$

é a soma de quadrados não condicional.

Estimação - máxima verossimilhança

- Logo, temos que maximizar

$$l \equiv l(\mu, \phi, \sigma^2) = \frac{1}{2} \ln(1 - \phi^2) - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} S_1(\mu, \phi) + \text{const.}$$

- Além disso:

$$\begin{aligned} S_1(\mu, \phi, \sigma^2) &= \frac{\partial l}{\partial \mu} = -\frac{1}{\sigma^2} (1 - \phi^2) (y_1 - \mu) \\ &+ \frac{1}{\sigma^2} \sum_{t=2}^n [(y_t - \mu) - \phi(y_{t-1} - \mu)] (1 - \phi) \quad (16) \end{aligned}$$

Estimação - máxima verossimilhança

- Adicionalmente:

$$\begin{aligned} S_2(\mu, \phi, \sigma^2) &= \frac{\partial l}{\partial \phi} = -\frac{\phi}{(1-\phi^2)} \\ &+ \frac{\phi(y_1 - \mu)^2}{\sigma^2} + \frac{1}{\sigma^2} \sum_{t=2}^n [(y_t - \mu) - \phi(y_{t-1} - \mu)](y_t - \mu) \end{aligned}$$

- Finalmente:

$$S_3(\mu, \phi, \sigma^2) = -\frac{n}{2\sigma^2} + \frac{1}{2(\sigma^2)^2} S_1(\mu, \phi).$$

Estimação - máxima verossimilhança

- Note que $S_1(\hat{\mu}, \hat{\phi}, \hat{\sigma}^2) = 0$ e $S_2(\hat{\mu}, \hat{\phi}, \hat{\sigma}^2) = 0$ não tem solução analítica.
- Contudo,

$$S_3(\hat{\mu}, \hat{\phi}, \hat{\sigma}^2) = 0 \rightarrow \hat{\sigma}^2 = \frac{1}{n-1} S_1(\hat{\mu}, \hat{\phi}). \quad (18)$$

- Logo, utilizamos (18) em (16) e (17) e resolvemos, numericamente (Newton-Raphson, Escore de Fisher, L-BFGS-B), o seguinte sistema de equações:

$$\begin{cases} S_1(\hat{\mu}, \hat{\phi}, \hat{\sigma}^2) = 0 \\ S_2(\hat{\mu}, \hat{\phi}, \hat{\sigma}^2) = 0 \end{cases}$$

Estimação - máxima verossimilhança

- Para o modelo AR(p), dada uma amostra de tamanho n , a ideia é decompor a verossimilhança como:

$$\begin{aligned}L(\boldsymbol{\theta}) &= f_{Y_1, Y_2, \dots, Y_{t-1}, Y_t}(y_1, y_2, \dots, y_{t-1}, y_t; \boldsymbol{\theta}) \\ &= f_{Y_{p+1}, \dots, Y_t | Y_1, \dots, Y_p}(y_{p+1}, \dots, y_t | y_1, \dots, y_p; \boldsymbol{\theta}) \\ &\times f_{Y_1, Y_2, \dots, Y_p}(y_1, y_2, \dots, y_p; \boldsymbol{\theta}) \\ &= \left\{ \prod_{t=p+1}^T f_{Y_t | Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}}(y_t | y_{t-1}, y_{t-2}, \dots, y_{t-p}; \boldsymbol{\theta}) \right\} \\ &\times f_{Y_1, Y_2, \dots, Y_p}(y_1, y_2, \dots, y_p; \boldsymbol{\theta}).\end{aligned}$$

Comentários

- Assintoticamente, os EMM e os EMQC são assintoticamente equivalentes ($n \rightarrow \infty$).
- Um procedimento usual que tende a levar aos melhores resultados (entre os que foram apresentados) consiste em:
 - Obter as estimativas de MQC (de modo iterativo) a partir de estimativas iniciais pelo MM ou pelo MQC (de forma não iterativa).
 - Usar as estimativas obtidas anteriormente como valores iniciais no processo iterativo para a obtenção das estimativas de MV.

Comentários

- Sob certas condições de regularidade ([aqui](#) e [aqui](#)), temos, para n suficientemente grande, que:

$$\hat{\boldsymbol{\theta}}_{MV} \approx N_{p+2} \left(\boldsymbol{\theta}, \mathbf{I}(\boldsymbol{\theta})^{-1} \right),$$

em que $\mathbf{I}(\boldsymbol{\theta})$ é a respectiva informação de Fisher.