

# Processos autoregressivos (parte 3)

Prof. Caio Azevedo

# Introdução

- Um processo estocástico  $\{Y_t\}$  é dito ser um processo AR(p) 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 no 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  $\mu$  ( $\mathcal{E}(Y_t) = \mu, \forall t$ ) é dada por:
$$Y_t = \mu + \phi_1(Y_{t-1} - \mu) + \cdots + \phi_p(Y_{t-p} - \mu) + \epsilon_t, \epsilon_t \sim RB(0, \sigma^2).$$
- Considere, inicialmente, o problema de estimar a FAC e FACP de um processo AR(p), com  $\mu = 0$ .

- Note que (multiplicando-se ambos os lados da primeira equação por  $Y_t$ ):

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

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

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

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

- 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 por  $\epsilon_t$ ):

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

- Portanto, aplicando (2) em (4), temos que:

$$\begin{aligned}\gamma(0) &= \phi_1\gamma(1) + \cdots + \phi_p\gamma(p) + \sigma^2 \\ 1 &= \phi_1\rho(1) + \cdots + \phi_p\rho(p) + \frac{\sigma^2}{\gamma(0)} \\ \gamma(0) &= \frac{\sigma^2}{1 - \phi_1\rho(1) - \cdots - \phi_p\rho(p)}.\end{aligned}\tag{3}$$

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

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

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

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

$$\gamma(k) = \phi_1 \gamma(k-1) + \cdots + \phi_p \gamma(k-p)$$

$$\rho(k) = \phi_1 \rho(k-1) + \cdots + \phi_p \rho(k-p)$$

- Lembrando que, em um processo estacionário,  $\rho(h) = \frac{\gamma(h)}{\gamma(0)}$

- Em termos matriciais, para  $k = 1, \dots, p$  temos que:

$$\begin{bmatrix} \rho(0) & \rho(1) & \dots & \rho(p-1) \\ \rho(1) & \rho(0) & \dots & \rho(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ \rho(p-1) & \rho(p-2) & \dots & \rho(0) \end{bmatrix} \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{bmatrix} = \begin{bmatrix} \rho(1) \\ \rho(2) \\ \vdots \\ \rho(p) \end{bmatrix} \quad (4)$$

- Esse sistema 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  $\sigma^2$  através de (3).
- Como estimar  $\rho$  e  $\phi$ ?

# Exemplo

- Considere o processo:

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

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

- 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 causa e, de (4), temos que:

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

# Exemplo

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

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

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

resolvendo o sistema temos que  $\rho(1) = 0,66$  e  $\rho(2) = 0,7178$  e portanto  $\gamma(0) = 2,362391\sigma^2$ .

# 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  $m_2 = 1,12221$ , e 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 calculadas  $\rho(1) = 0,66$  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:

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

# Estimação - Introdução

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

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

- 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](#).  
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  $\mu$ , como este é a média do processo, o estimador pelo métodos dos momentos (EMM) é  $\hat{\mu} = \overline{Y}$ .

# 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:

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

# Estimação - Método dos momentos

- Portanto, temos que o EMM para  $\phi$  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

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

# 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  $\sigma^2$ , uma vez que:

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

então um estimador para  $\sigma^2$  é:

$$\hat{\sigma}^2 = S^2(1 - \hat{\phi}_1\hat{\rho}(1) - \dots - \hat{\phi}_p\hat{\rho}(p)), \quad (5)$$

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 que, 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 ( $\mu$ ) e da função de auto-covariância / 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:

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

- Logo, os estimadores de mínimos quadrados condicionais de  $\theta = (\mu, \phi_1, \dots, \phi_p)' = (\mu, \phi')'$  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  $\mu$  for conhecido, os estimadores de MQC de  $\phi$ , possuem forma fechada.
- 2 Se  $\mu$  for desconhecido, os estimadores de MQC de  $\phi$  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  $\mu$  ( $\hat{\mu} = \bar{Y}$ ), 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:

$$\begin{cases} S(\mu) = \frac{\partial}{\partial \mu} S(\mu, \phi) \big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 2 \sum_{t=p+1}^n \epsilon_t \frac{\partial}{\partial \mu} \epsilon_t \big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 0 \\ S(\phi_1) = \frac{\partial}{\partial \phi_1} S(\mu, \phi) \big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 2 \sum_{t=p+1}^n \epsilon_t \frac{\partial}{\partial \phi_1} \epsilon_t \big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 0 \\ \vdots \\ S(\phi_p) = \frac{\partial}{\partial \phi_p} S(\mu, \phi) \big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 2 \sum_{t=p+1}^n \epsilon_t \frac{\partial}{\partial \phi_p} \epsilon_t \big|_{\mu=\hat{\mu}, \phi=\hat{\phi}} = 0 \end{cases}$$

# Estimação - Mínimos quadrados condicionais

- Como exemplo, considere um modelo AR(1). Os estimadores de mínimos quadrados condicionais para  $(\mu, \phi)$  são obtidos minimizando:

$$S(\mu, \phi) = \sum_{t=2}^n [y_t - \mu - \phi(y_{t-1} - \mu)]^2 \quad (6)$$

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 (6) com relação a  $\mu$  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 (6) com relação a  $\phi$  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:

$$\begin{aligned}\hat{\mu} &= \frac{\overline{Y_1} - \hat{\phi} \overline{Y_2}}{1 - \hat{\phi}}, \\ \hat{\phi} &= \frac{\sum_{t=2}^n (Y_{t-1} - \hat{\mu})(Y_t - \hat{\mu})}{\sum_{t=2}^n (Y_{t-1} - \hat{\mu})^2}\end{aligned}$$

- Ou seja, não é possível obter uma solução explícita.
- **Proposição:** sob algumas condições, assintoticamente, os estimadores de mínimos quadrados condicionais equivalem aos do MM.

# Estimação - Mínimos quadrados condicionais

- **Prova:** Note que se  $n \rightarrow \infty$  então  $\bar{Y}_1 = \bar{Y}_2 \approx \bar{Y}$  e se  $\hat{\phi} \not\rightarrow 1$ , então:

$$\hat{\mu} \approx \frac{\bar{Y} - \hat{\phi}\bar{Y}}{1 - \hat{\phi}} = \bar{Y}.$$

- E utilizando esse resultado temos que se  $n \rightarrow \infty$ :

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

- Para estimar  $\sigma^2$  podemos utilizar (5), por exemplo.

# Estimação - máxima verossimilhança (MV)

- O método de MV consiste em, essencialmente, maximizar a verossimilhança associado ao modelo estatístico de interesse ([aqui](#))
- Adicionalmente as suposições usuais, assumiremos que  $\epsilon_t \sim NID(0, \sigma^2)$
- Serão apresentados detalhes 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:

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

- Logo, considerando  $y_1, \dots, y_n$  os valores observados do processo, temos que a verossimilhança é dada por:

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

# Estimação - máxima verossimilhança

- Por outro lado, 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

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

- Portanto, temos que os estimador de MV são obtidos maximizando  $L(\mu, \phi, \sigma^2)$  e consequentemente minimizando  $S_1(\mu, \phi)$ .

# Estimação - máxima verossimilhança

- Porém, note que minimizar  $S_1(\mu, \phi)$  é equivalente a minimizar  $S(\mu, \phi)$  (associado ao método dos mínimos quadrados condicional).
- Assim os estimadores de MQC e MV, para  $\mu$  e  $\phi$ , são os mesmos.
- Isso, em geral, não ocorre para  $p \geq 2$ .
- Para  $\sigma^2$  temos que:

$$\begin{aligned} L(\mu, \phi, \sigma^2) &\propto \frac{1}{(\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} S_1(\mu, \phi) \right\} \Rightarrow \\ \ln L = \log \{L(\mu, \phi, \sigma^2)\} &= -\frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} S_1(\mu, \phi) + \text{const.} \end{aligned}$$

# Estimação - máxima verossimilhança

- Cont.:

$$\frac{\partial \ln L}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2(\sigma^2)^2} S_1(\mu, \phi)$$

- Assim, temos que:

$$\hat{\sigma}^2 = \frac{1}{n} S_1(\hat{\mu}, \hat{\phi})$$

em que  $\hat{\mu}$  e  $\hat{\phi}$  são tais que suas estimativas devem ser obtidas numericamente.

# Estimação - máxima verossimilhança

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

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

# 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:

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

em que  $I(\theta)$  é a respectiva informação de Fisher.