

Processos de média móveis: parte 2

Prof. Caio Azevedo

Estimação - método dos momentos

- Considere $\{Y_t\}$ um processo $MA(q)$ de média μ ([link](#)).
- Uma vez que a média do processo é μ , então o EMM (estimador pelo método dos momentos) para μ é dado por $\hat{\mu} = \bar{Y}$ (semelhante ao processo $AR(p)$, [link](#)).
- Por outro lado, para $\theta_1, \dots, \theta_q$ os respectivos EMM's são obtidos resolvendo-se as equações definidas pelas [auto-correlações amostrais](#).
- Por exemplo, considere o modelo $MA(1)$ de média μ : $Y_t = \mu + \theta\epsilon_{t-1} + \epsilon_t$, em que $\epsilon_t \sim RB(0, \sigma^2)$. Para este processo temos que $\gamma(0) = \sigma^2(1 + \theta^2)$, $\gamma(1) = \sigma^2\theta$ e portanto $\rho(1) = \theta/(1 + \theta^2)$.

Estimação - método dos momentos

- Então um estimador para θ é encontrado resolvendo-se:

$$\widehat{\rho}(1) = \frac{\widehat{\theta}}{1 + \widehat{\theta}^2}, \quad (1)$$

a qual é uma equação do 2º grau.

- Nesse caso, devemos escolher a solução cujo valor de $\widehat{\theta}$ torne o processo invertível (ser possível escrever $\epsilon_t = \sum_{j=0}^{\infty} (-\theta)^j Y_{t-j}$).

Estimação - método dos momentos

- Além disso, as soluções serão números reais se e somente se $|\hat{\rho}(1)| < 1/2$ (para esse caso).
- Se $|\hat{\rho}(1)| < 1/2$, resolvendo a equação (1) temos que a solução invertível é dada por:

$$\hat{\theta} = \frac{1 - \sqrt{1 - 4\hat{\rho}(1)^2}}{2\hat{\rho}(1)}.$$

Estimação - máxima verossimilhança

- Diferentemente do modelo $AR(p)$, para um modelo $MA(q)$ é útil escrevermos a verossimilhança associada em termos dos erros de previsão a um passo a frente $Y_t - Y_t(1)$ (veremos adiante que pode ser calculada tanto por (3) no slide 14 quanto por (4) no slide 17) uma vez que temos uma verossimilhança mais tratável neste caso.
- Para um modelo $MA(q)$, seja $\beta = (\mu, \theta_1, \dots, \theta_q)'$ o vetor de dimensão $q + 1$ de parâmetros. Temos que a respectiva verossimilhança é dada por:

$$L(\beta, \sigma^2) = \prod_{t=1}^n f(y_t | y_{t-1}, \dots, y_1).$$

Estimação - máxima verossimilhança

- Com efeito, temos que a distribuição de $Y_t | Y_{t-1} = y_{t-1}, \dots, Y_1 = y_1$ é normal com média y_{t+1}^t e variância $\text{Var}(P_{t+1}^t) = \sigma^2$. Portanto a verossimilhança pode ser escrita como:

$$L(\beta, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{t=1}^n (y_t - y_{t+1}^t)^2 \right\}, \quad (2)$$

em que y_{t+1}^t é função somente de β (como veremos adiante).

- Por fim os estimadores são obtidos maximizando-se a equação (2) com respeito a β e σ^2 .

Estimação - mínimos quadrados condicionais

- Podemos escrever um modelo MA(q) de média μ em termos de seus erros:

$$\epsilon_t = Y_t - \mu - \sum_{k=1}^q \theta_k \epsilon_{t-k}.$$

- Neste método de estimação aproximamos a soma dos quadrados dos erros pelo condicionamento em $\epsilon_0 = \epsilon_1 = \dots = \epsilon_{1-q} = 0$. Portanto, os estimadores de $\beta = (\theta_1, \dots, \theta_q)'$ são dados minimizando-se:

$$S_c(\beta) = \sum_{t=1}^n \epsilon_t^2.$$

- Exercício (expanda o somatório acima).

Comentários

- Essencialmente, os comentários feitos [aqui](#), slides 21, 24 e 41.
- São necessários métodos numéricos para obter as estimativas (MQC e MV).
- Erros-padrão, intervalos de confiança e testes de hipótese podem ser obtidos/construídos através de teoria assintótica ou métodos numéricos.

Previsão - Método 1

- Considere $\{Y_t\}$ um processo $MA(q)$ invertível. Sem perda de generalidade assuma que média zero. Caso não o tenha, basta centrá-lo em sua média $Y_t = X_t - \mu$. Logo temos que $Y_t = \theta(B)\epsilon_t$, em que $\epsilon_t \sim RB(0, \sigma^2)$.
- Desejamos obter previsões m passos a frente para esse processo (semelhante ao que fora feito [para o processo \$AR\(p\)\$](#)).

Previsão Método 1

- Para isso consideraremos $Y_n(m) = \mathcal{E}(Y_{n+m}|Y_n, \dots, Y_1)$ o preditor ótimo sob o erro quadrático médio, baseado na amostra finita (Y_1, \dots, Y_n) , e $\tilde{Y}_n(m) = \mathcal{E}(Y_{n+m}|Y_n, \dots, Y_1, Y_0, Y_{-1}, \dots)$ o preditor correspondente, baseado na amostra infinita $(\dots, Y_{-1}, Y_0, Y_1, \dots, Y_n)$ ou simplesmente (Y_n, \dots) .
- Utilizaremos $\tilde{Y}_n(m)$ pois as respectivas contas são mais simples se comparadas àquelas relativas à $Y_n(m)$ (para os processos MA(q) e também para os processos ARMA(p,q), que veremos adiante).
- Uma vez encontrado $\tilde{Y}_n(m)$ ele é truncado para o caso finito (amostra de tamanho n).

Previsão - Método 1

- Primeiramente, temos que como $\{Y_t\}$ é invertível, logo

$$Y_{n+m} = \theta(B)\epsilon_{n+m}$$

$$\epsilon_{n+m} = \sum_{j=0}^{\infty} \pi_j Y_{n+m-j}, \quad \pi_0 = 1,$$

$$\mathcal{E}(\epsilon_{n+m} | Y_n, \dots, Y_{-1}, \dots) = \sum_{j=0}^{\infty} \pi_j \mathcal{E}(Y_{n+m-j} | Y_n, \dots, Y_{-1}, \dots)$$

$$0 = \sum_{j=0}^{\infty} \pi_j \tilde{Y}_n(m-j)$$

Previsão - Método 1

- Continuando:

$$0 = \tilde{Y}_n(m) + \sum_{j=1}^{\infty} \pi_j \tilde{Y}_n(m-j)$$

$$\tilde{Y}_n(m) = - \sum_{j=1}^{\infty} \pi_j \tilde{Y}_n(m-j) = - \sum_{j=1}^{m-1} \pi_j \tilde{Y}_n(m-j) - \sum_{j=m}^{\infty} \pi_j \tilde{Y}_n(m-j).$$

Porém note que $\tilde{Y}_t(0) = \mathcal{E}(Y_t | Y_n, \dots, Y_{-1}, \dots) = Y_t$, para $t \leq n$, devido a forma do processo MA (exercício). Logo ($\tilde{Y}_n(m-j) = Y_{n+m-j}$) e

$$\tilde{Y}_n(m) = - \sum_{j=1}^{m-1} \pi_j \tilde{Y}_n(m-j) - \sum_{j=m}^{\infty} \pi_j Y_{n+m-j},$$

Previsão - Método 1

- Dessa forma, começando com $m = 1$, temos um procedimento recursivo para obtermos previsões para um modelo $MA(q)$.
- Por definição, esse procedimento também pode ser utilizado para acharmos previsões para um processo $ARMA(p, q)$, o qual estudaremos adiante.
- Note que esse método necessita que o modelo seja invertível e que seja fácil a obtenção de π_j .
- Na prática fazemos:

$$\tilde{Y}_n(m) = - \sum_{j=1}^{m-1} \pi_j \tilde{Y}_n(m-j) - \sum_{j=m}^n \pi_j Y_{n+m-j}$$

Estrutura - Previsão - Método 1

$$\tilde{Y}_n(1) = - \sum_{j=1}^n \pi_j Y_{n+1-j} \quad (3)$$

$$\tilde{Y}_n(2) = -\pi_1 \tilde{Y}_n(1) - \sum_{j=2}^n \pi_j Y_{n+2-j}$$

$$\tilde{Y}_n(3) = -\pi_1 \tilde{Y}_n(2) - \pi_2 \tilde{Y}_n(1) - \sum_{j=3}^n \pi_j Y_{n+3-j}$$

\vdots

Exemplo - Previsão - Método 1

- Considere o modelo MA(1) em que $Y_t = -0,3\epsilon_{t-1} + \epsilon_t$, $\epsilon_t \sim RB(0, \sigma^2)$.
- Sabemos que $Y_t = (1 - 0,3B)\epsilon_t$ e que $\theta(z) = 1 - 0,3z = 0 \iff z \approx 3,33 > 1$, logo $\{Y_t\}$ é invertível e portanto:

$$\epsilon_t = \frac{1}{1 - 0,3B} Y_t = \sum_{j=0}^{\infty} 0,3^j Y_{t-j} = \sum_{j=0}^{\infty} \pi_j Y_{t-j},$$

em que $\pi_j = 0,3^j$.

Exemplo - Previsão - Método 1

- Logo, a previsão a m passos é dada recursivamente por:

$$\tilde{Y}_n(m) = - \sum_{j=1}^{m-1} 0,3^j \tilde{Y}_n(m-j) - \sum_{j=m}^n 0,3^j Y_{n+m-j}.$$

Previsão - Método 2

- Do processo $MA(q)$ temos que:

$$\begin{aligned}Y_{n+m} &= \theta_1 \epsilon_{n+m-1} + \cdots + \theta_q \epsilon_{n+m-q} + \epsilon_{n+m} \\ \mathcal{E}(Y_{n+m} | Y_n, \dots) &= \theta_1 \mathcal{E}(\epsilon_{n+m-1} | Y_n, \dots) + \cdots + \theta_q \mathcal{E}(\epsilon_{n+m-q} | Y_n, \dots) \\ &\quad + \mathcal{E}(\epsilon_{n+m} | Y_n, \dots) \\ \tilde{Y}_n(m) &= \theta_1 \tilde{\epsilon}_n(m-1) + \cdots + \theta_q \tilde{\epsilon}_n(m-q) + \tilde{\epsilon}_n(m), \quad (4)\end{aligned}$$

notando (devido a causalidade e a invertibilidade) que $\tilde{\epsilon}_n(t) = \mathcal{E}(\epsilon_t | Y_n, \dots) = \mathcal{E}(\epsilon_t | \epsilon_n, \dots) = \epsilon_t$ para $t \leq n$ (exercício).

- Mas como imputar ϵ_t na prática dado que ele é estocástico?

Previsão - Método 2

- Note que do processo $MA(q)$: $\epsilon_t = Y_t - \theta_1\epsilon_{t-1} - \dots - \theta_q\epsilon_{t-q}$, portanto assumindo que $y_i = 0$ e $\epsilon_i = 0$ para $i \leq 0$, podemos proceder recursivamente, ou seja:

$$\epsilon_1 = y_1$$

$$\epsilon_2 = y_2 - \theta_1\epsilon_1$$

$$\epsilon_3 = y_3 - \theta_1\epsilon_2 - \theta_2\epsilon_1$$

$$\epsilon_4 = y_4 - \theta_1\epsilon_3 - \theta_2\epsilon_2 - \theta_3\epsilon_1$$

$$\vdots$$

$$\epsilon_n = y_n - \theta_1\epsilon_{n-1} - \dots - \theta_q\epsilon_{n-q}.$$

Exemplo - Previsão - Método 2

- Considere novamente o modelo MA(1) em que $Y_t = -0,3\epsilon_{t-1} + \epsilon_t$, $\epsilon_t \sim RB(0, \sigma^2)$.
- Dito isso, temos que $\tilde{Y}_n(m) = -0,3\tilde{\epsilon}_n(m-1) + \tilde{\epsilon}_n(m)$, e portanto:

$$\tilde{Y}_n(1) = -0,3\tilde{\epsilon}_n(0) = -0,3\epsilon_n$$

$$\tilde{Y}_n(k) = 0, k \geq 2,$$

em que (próximo slide)

Exemplo - Previsão - Método 2

$$\epsilon_1 = y_1$$

$$\epsilon_2 = y_2 + 0,3\epsilon_1 = y_2 + 0,3y_1$$

$$\epsilon_3 = y_3 + 0,3\epsilon_2 = y_3 + 0,3(y_2 + 0,3y_1)$$

$$= y_3 + 0,3y_2 + 0,3^2y_1$$

\vdots

$$\epsilon_n = \sum_{j=1}^n 0,3^{n-j}y_j.$$

Erro de previsão

- O erro de previsão para m passos a frente de $1 \leq m \leq q$ é dado por (veja slides anteriores):

$$\begin{aligned} P_n(m) = Y_{n+m} - \tilde{Y}_n(m) &= (\theta_1 \epsilon_{n+m-1} + \cdots + \theta_q \epsilon_{n+m-q} + \epsilon_{n+m}) \\ &- (\theta_1 \tilde{\epsilon}_n(m-1) + \cdots + \theta_q \tilde{\epsilon}_n(m-q) + \tilde{\epsilon}_n(m)) \\ &= \sum_{j=0}^{m-1} \theta_j \epsilon_{n+m-j}, \quad \theta_0 = 1. \end{aligned}$$

- A respectiva variância então é dada por:

$$\sigma_n^2(m) = \text{Var}(P_n(m)) = \sigma^2 \sum_{j=0}^{m-1} \theta_j^2,$$

Erro de previsão

- E a covariância é dada por:

$$\text{Cov}(P_n(m), P_n(m+k)) = \sigma^2 \sum_{j=0}^{m-1} \theta_j \theta_{j+k},$$

logo, temos que os erros de previsão são correlacionados.

Propriedades

- Considere $\{X_t\}$ um processo $MA(q)$ de média μ e que desejamos fazer previsões para X_{n+m} . Dessa forma podemos trabalhar com $Y_t = X_t - \mu$, realizar previsões para Y_{n+m} de interesse e recuperar as previsões para X_{n+m} tal que $\tilde{X}_n(m) = \tilde{Y}_n(m) + \mu$.
- Além disso, sabemos que $\tilde{X}_n(m) = \mu + \theta_1 \tilde{\epsilon}_n(m-1) + \dots + \theta_q \tilde{\epsilon}_n(m-q) + \tilde{\epsilon}_n(m)$. Logo quando $m \rightarrow \infty$, $\tilde{X}_n(m) \rightarrow \mu$ e conseqüentemente $Var(P_n(m)) \rightarrow \gamma_X(0)$.
- Portanto, temos que a previsão para um processo $MA(q)$ a longo prazo torna-se a própria média do processo.