

2024 秋季本科时间序列

第 5 次作业答案

11 月 11 日

1. 给定平稳的 AR(2) 过程 $X_t = \mu + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \epsilon_t$, 我们要推导通项表达式 $\hat{X}_{t+s|t}, \forall s \geq 1$, 其中 $Y_t = X_t - \mathbb{E}[X_t]$ 为去均值后的过程。

X_t 是平稳的 AR(2) 过程, 可以表示为:

$$X_t = \mu + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \epsilon_t$$

其中, μ 是常数项, ϵ_t 是白噪声, 方差为 σ_ϵ^2 。定义去均值后的过程 $Y_t = X_t - \mathbb{E}[X_t] = X_t - \frac{\mu}{1-\phi_1-\phi_2}$ 。

给定:

$$\begin{bmatrix} Y_{t+1} \\ Y_t \end{bmatrix} = \begin{bmatrix} \phi_1 & \phi_2 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} Y_t \\ Y_{t-1} \end{bmatrix} + \begin{bmatrix} \epsilon_{t+1} \\ 0 \end{bmatrix}$$

这个表示式表明, Y_t 的演化过程由上一期的 Y_t 和 Y_{t-1} 以及当前的白噪声 ϵ_t 决定。

在给定 t 时, 我们希望推导出 $\hat{X}_{t+s|t}$, 即在时刻 t 时对时刻 $t+s$ 的预测。

由于 $Y_t = X_t - \frac{\mu}{1-\phi_1-\phi_2}$, 我们可以通过对 Y_t 的预测来推导 X_t 的预测。首先, 考虑 $\hat{Y}_{t+s|t}$, 这是对 Y_{t+s} 在时刻 t 的条件预测。

$$\begin{bmatrix} Y_{t+1|t} \\ Y_{t|t} \end{bmatrix} = \begin{bmatrix} \phi_1 & \phi_2 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} Y_{t|t} \\ Y_{t-1|t} \end{bmatrix}$$

对于 $s \geq 1$, 递推可得 $Y_{t+s|t}$ 的表达式:

$$\hat{Y}_{t+s|t} = \phi_1^s Y_t + \sum_{i=0}^{s-1} \phi_1^{s-i-1} \phi_2^i Y_{t-i}$$

由 $X_t = Y_t + \frac{\mu}{1-\phi_1-\phi_2}$, 我们可以通过预测 Y_t 得到:

$$\hat{X}_{t+s|t} = \hat{Y}_{t+s|t} + \frac{\mu}{1-\phi_1-\phi_2}$$

即为,

$$\hat{X}_{t+s|t} = \phi_1^s X_t + \sum_{i=0}^{s-1} \phi_1^{s-i-1} \phi_2^i X_{t-i} + \frac{\mu}{1-\phi_1-\phi_2}$$

得到:

$$\hat{X}_{t+s|t} = \phi_1^s X_t + \sum_{i=0}^{s-1} \phi_1^{s-i-1} \phi_2^i X_{t-i} + \frac{\mu}{1-\phi_1-\phi_2}$$

这个公式表示了从时刻 t 对 $t+s$ 时刻 X_t 的最优预测, 其中 ϕ_1 和 ϕ_2 是 AR(2) 过程的参数, μ 是常数项。

2. 要计算 $L(X_{t+s}|X_t, X_{t-1}) = a_s X_t + b_s X_{t-1}$ 的系数 a_s 和 b_s , 我们需要解决以下最小化问题:

$$\min_{a_s, b_s} E [(X_{t+s} - a_s X_t - b_s X_{t-1})^2]$$

这相当于解以下的正常方程:

$$\begin{cases} E [(X_{t+s} - a_s X_t - b_s X_{t-1})X_t] = 0 \\ E [(X_{t+s} - a_s X_t - b_s X_{t-1})X_{t-1}] = 0 \end{cases}$$

首先, 计算过程 X_t 的自协方差函数 $\gamma_k = \text{Cov}(X_t, X_{t-k})$:

$$\gamma_0 = E[X_t^2] = (1 + \theta^2)\sigma^2, \quad \gamma_1 = E[X_t X_{t-1}] = \theta\sigma^2, \quad \gamma_k = 0 \quad \text{对于 } |k| \geq 2$$

计算 $E[X_{t+s} X_t]$ 和 $E[X_{t+s} X_{t-1}]$:

- 对于 $s = 1$:

$$E[X_{t+1} X_t] = \theta\sigma^2, \quad E[X_{t+1} X_{t-1}] = 0$$

- 对于 $s \geq 2$:

$$E[X_{t+s}X_t] = 0, \quad E[X_{t+s}X_{t-1}] = 0$$

对于 $s = 1$, 正常方程为:

$$\begin{cases} E[X_{t+1}X_t] = a_1E[X_t^2] + b_1E[X_{t-1}X_t] \\ E[X_{t+1}X_{t-1}] = a_1E[X_tX_{t-1}] + b_1E[X_{t-1}^2] \end{cases}$$

将已知值代入:

$$\begin{cases} \theta\sigma^2 = a_1(1 + \theta^2)\sigma^2 + b_1\theta\sigma^2 \\ 0 = a_1\theta\sigma^2 + b_1(1 + \theta^2)\sigma^2 \end{cases}$$

消去 σ^2 , 得到:

$$\begin{cases} \theta = a_1(1 + \theta^2) + b_1\theta \\ 0 = a_1\theta + b_1(1 + \theta^2) \end{cases}$$

解第二个方程, 得到 $b_1 = -\frac{a_1\theta}{1+\theta^2}$ 。将其代入第一个方程, 求解 a_1 :

$$\theta = a_1(1 + \theta^2) - \frac{a_1\theta^2}{1 + \theta^2}$$

化简得到:

$$a_1 = \frac{\theta(1 + \theta^2)}{1 + \theta^2 + \theta^4}$$

然后计算 b_1 :

$$b_1 = -\frac{a_1\theta}{1 + \theta^2} = -\frac{\theta^2}{1 + \theta^2 + \theta^4}$$

对于 $s \geq 2$, 由于相关系数为零, 因此 $a_s = 0$, $b_s = 0$ 。

课件中给出的最优预测器为：

$$\hat{X}_{t+1|t} = \theta \sum_{j=0}^{\infty} (-\theta)^j X_{t-j}$$

展开前两项：

$$\hat{X}_{t+1|t} = \theta X_t - \theta^2 X_{t-1} + \theta^3 X_{t-2} - \dots$$

使用所有过去数据时，系数为：

- X_t 的系数： θ
- X_{t-1} 的系数： $-\theta^2$
- X_{t-2} 的系数： θ^3
- ...

而使用仅 X_t 和 X_{t-1} 时，系数为：

- X_t 的系数： $a_1 = \frac{\theta(1+\theta^2)}{1+\theta^2+\theta^4}$
- X_{t-1} 的系数： $b_1 = -\frac{\theta^2}{1+\theta^2+\theta^4}$

对于任意 $s \geq 1$ ：

- 当 $s = 1$ 时，线性预测系数为：

$$a_1 = \frac{\theta(1+\theta^2)}{1+\theta^2+\theta^4}, \quad b_1 = -\frac{\theta^2}{1+\theta^2+\theta^4}$$

- 当 $s \geq 2$ 时，系数均为零：

$$a_s = 0, \quad b_s = 0$$

与课件中使用全部过去数据的最优预测相比，只有当 $s = 1$ 时，系数 a_1 和 b_1 与对应项有所不同。使用全部过去数据时，预测器的系数为 $\theta, -\theta^2, \theta^3$ 等，包含更多的滞后项，因此预测效果更好。

3. 均值向量 $\boldsymbol{\mu} = (\mu_X, \mu_Y)^\top$, 协方差矩阵 $\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_X^2 & \sigma_{XY} \\ \sigma_{XY} & \sigma_Y^2 \end{bmatrix}$, 设 ρ 为相关系数, 定义为: $\rho = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$

由多元正态分布定义有

$$f(x, y) = \frac{1}{2\pi|\boldsymbol{\Sigma}|^{1/2}} \exp\left\{-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu})\right\}$$

其中 $\mathbf{x} = (x, y)^\top$, $|\boldsymbol{\Sigma}|$ 表示协方差矩阵的行列式, 有 $|\boldsymbol{\Sigma}| = \sigma_X^2 \sigma_Y^2 - (\sigma_{XY})^2 = \sigma_X^2 \sigma_Y^2 (1 - \rho^2)$,

$$\boldsymbol{\Sigma}^{-1} = \frac{1}{|\boldsymbol{\Sigma}|} \begin{bmatrix} \sigma_Y^2 & -\sigma_{XY} \\ -\sigma_{XY} & \sigma_X^2 \end{bmatrix}, \text{ 代入 } f(x, y) \text{ 得到:}$$

$$f(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho^2}} \exp\left\{-\frac{1}{2(1-\rho^2)} \left[\frac{(x-\mu_X)^2}{\sigma_X^2} - \frac{2\rho(x-\mu_X)(y-\mu_Y)}{\sigma_X\sigma_Y} + \frac{(y-\mu_Y)^2}{\sigma_Y^2} \right]\right\}$$

接下来计算 X 的边缘密度函数 $f_X(x) = \int_{-\infty}^{\infty} f(x, y)dy$, 令 $A = \frac{x-\mu_X}{\sigma_X}$, $B = \frac{y-\mu_Y}{\sigma_Y}$, 则指数部分变为:

$$\begin{aligned} & -\frac{1}{2(1-\rho^2)} [A^2 - 2\rho AB + B^2] \\ & = -\frac{1}{2(1-\rho^2)} [(B - \rho A)^2 + (1-\rho^2)A^2] \end{aligned}$$

所以

$$f(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho^2}} \exp\left(-\frac{A^2}{2}\right) \exp\left(-\frac{(B - \rho A)^2}{2(1-\rho^2)}\right)$$

对 y 积分, 即对 B 积分, 令 $C = \frac{B - \rho A}{\sqrt{1-\rho^2}}$

$$\begin{aligned} f_X(x) &= \exp\left(-\frac{A^2}{2}\right) \cdot \frac{1}{\sqrt{2\pi}\sigma_X} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}\sigma_Y\sqrt{1-\rho^2}} \exp\left(-\frac{(B - \rho A)^2}{2(1-\rho^2)}\right) \sigma_Y dB \\ &= \exp\left(-\frac{A^2}{2}\right) \cdot \frac{1}{\sqrt{2\pi}\sigma_X} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}\sigma_Y\sqrt{1-\rho^2}} \exp\left(-\frac{(B - \rho A)^2}{2(1-\rho^2)}\right) \sigma_Y \sqrt{1-\rho^2} dC \end{aligned}$$

注意到积分为标准正态分布的积分, 结果为 1, 故

$$\begin{aligned} f_X(x) &= \frac{1}{\sqrt{2\pi}\sigma_X} \exp\left(-\frac{A^2}{2}\right) \\ &= \frac{1}{\sqrt{2\pi}\sigma_X} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu_X}{\sigma_X}\right)^2\right\} \end{aligned}$$

再计算 Y 的条件密度函数 $f(y|x) = \frac{f(x, y)}{f_X(x)}$, 代入已知的 $f(x, y)$ 和 $f_X(x)$, 化简可得 (注

意其仍然是正态分布)

$$\begin{aligned}
 f(y|x) &= \frac{1}{\sqrt{2\pi}\sigma_Y\sqrt{1-\rho^2}} \exp\left(-\frac{(B-\rho A)^2}{2(1-\rho^2)}\right) \\
 &= \frac{1}{\sqrt{2\pi}\sigma_Y\sqrt{1-\rho^2}} \exp\left\{-\frac{\left[y - \left(\mu_Y - \rho\frac{\sigma_Y}{\sigma_X}(x - \mu_X)\right)\right]^2}{2\sigma_Y^2(1-\rho^2)}\right\} \\
 &= \frac{1}{\sqrt{2\pi}\sigma_{Y|X}} \exp\left\{-\frac{1}{2}\left(\frac{y - \mathbb{E}(Y|X=x)}{\sigma_{Y|X}}\right)^2\right\}
 \end{aligned}$$

所以 $\mathbb{E}(Y|X=x) = \mu_Y + \rho\frac{\sigma_Y}{\sigma_X}(x - \mu_X)$

4. (a) i.

$$\begin{aligned}
 P_X \xi &= X(X^T X)^{-1} X^T X a \\
 &= X I a \\
 &= X a \\
 &= \xi
 \end{aligned}$$

ii.

$$\begin{aligned}
 (X a)^T (I - P_X) \zeta &= a^T X^T (\zeta - X(X^T X)^{-1} X^T \zeta) \\
 &= a^T X^T \zeta - a^T I X^T \zeta \\
 &= 0
 \end{aligned}$$

(b) i. 由 OLS 估计系数表达式可知, Y 对 W 回归的系数为 $(W^T W)^{-1} W^T Y$, 而 Z 对 W 回归的系数为 $(W^T W)^{-1} W^T Z$, 故两组回归对应的残差向量分别为

$$(I - W(W^T W)^{-1} W^T) Y = (I - P_W) Y = \tilde{Y}$$

$$(I - W(W^T W)^{-1} W^T) Z = (I - P_W) Z = \tilde{Z}$$

ii. $\hat{e} = Y - X\hat{\beta} = Y - X(X^T X)^{-1} X^T Y = (I - P_X) Y$, 由 (a) 的结论可得 \hat{e} 与 X 的每个列向量互相垂直, 故垂直于 Z 与 W (i.e. $Z^T \hat{e} = W^T \hat{e} = 0$)

iii. $P_W \hat{e} = W(W^T W)^{-1} W^T \hat{e} = 0$ (由 ii. 可知 $W^T \hat{e} = 0$)

iv. 只需要说明 $\hat{\delta}$ 正好满足回归 $\tilde{Y} = \tilde{Z}\delta + u$ 的 OLS 系数估计所满足的一阶条件

$$\tilde{Z}^T \tilde{Y} - \tilde{Z}^T \tilde{Z} \delta = 0.$$

首先注意到 $\hat{e} = Y - X\hat{\beta} = Y - Z\hat{\delta} - W\hat{\theta}$, 两端同时乘以 $I - P_W$ 有

$$(I - P_W)\hat{e} = (I - P_W)Y - (I - P_W)Z\hat{\delta} - (I - P_W)W\hat{\theta}$$

$$\hat{e} = \tilde{Y} - \tilde{Z}\hat{\delta} \quad (\text{由 i.-iii. 可知})$$

再在两端同乘 \tilde{Z}^T 可得

$$\tilde{Z}^T \tilde{Y} - \tilde{Z}^T \tilde{Z} \hat{\delta} = \tilde{Z}^T (\tilde{Y} - \tilde{Z} \hat{\delta})$$

$$= \tilde{Z}^T \hat{e}$$

$$= 0$$

所以 (1) 中 OLS 估计的结果 $\hat{\delta}$ 同样满足回归 $\tilde{Y} = \tilde{Z}\delta + u$ 的一阶条件, 得证

(c) 题干中回归可改写为该矩阵形式 $Y = \mathbf{1}\alpha + X\beta + e$, 其中 $\mathbf{1}$ 为每个元素均为 1 的

$T \times 1$ 列向量, 同上定义回归残差 \tilde{Y} 和 \tilde{X} , 可推得

$$\tilde{Y} = (\mathbf{1} - P_1)Y$$

$$= Y - \mathbf{1}(\mathbf{1}^T \mathbf{1})^{-1} \mathbf{1}^T Y$$

$$= Y - \mathbf{1}T^{-1}(Y_1 + \cdots + Y_T)$$

$$= Y - \mathbf{1}\bar{Y}$$

$$= Y - \bar{Y}$$

$$\tilde{X} = X - \bar{X}$$

因此由 FWL 定理可知, 去均值后的回归 $\tilde{Y} = \tilde{X}\beta + u$ 得到的 OLS 估计系数 $\hat{\beta}$ 与原回归得到的估计值等价