

# 第七次作业

## 第 10 章 季节模型

**10.7** 假设过程  $\{Y_t\}$  满足  $Y_t = Y_{t-4} + e_t$ , 当  $t = 1, 2, 3, 4$  时,  $Y_t = e_t$ 。

(a) 求  $\{Y_t\}$  的方差函数。

解 :

$Y_t = Y_{t-4} + e_t$ , 则  $EY_t Y_{t-k} = EY_{t-4} Y_{t-k} + Ee_t Y_{t-k}$ , 由于  $e_t$  与  $Y_{t-k}$  独立, 所以  $Ee_t Y_{t-k} = 0$ , 从而  $EY_t Y_{t-k} = EY_{t-4} Y_{t-k}$ , 即  $\gamma_k = \gamma_{k-4}$ 。

同时, 由于  $\gamma_0 = \sigma_e^2$ ,  $\gamma_1 = \gamma_2 = \gamma_3 = 0$ , 所以  $\{Y_t\}$  的方差函数为

$$\gamma_t = \begin{cases} \sigma_e^2, & t = 4k, k \in N \\ 0, & t = 4k + 1, 4k + 2, 4k + 3, k \in N \end{cases}$$

□

(b) 求  $\{Y_t\}$  的自相关函数。

解 :

由于  $\rho_t = \frac{\gamma_t}{\gamma_0}$ , 所以  $\{Y_t\}$  的自相关函数为

$$\rho_t = \begin{cases} 1, & t = 4k, k \in N \\ 0, & t = 4k + 1, 4k + 2, 4k + 3, k \in N \end{cases}$$

□

(c) 证明  $\{Y_t\}$  的模型是季节 ARIMA 模型。


证明 :

注意到  $\{Y_t\}$  为  $AR(1)_4$  的季节 ARIMA 模型。 □

**10.9** 最先由 Box 和 Jenkins(1976) 研究的月航线客运量时间序列被视为典型的时间序列。数据详见文件 airpass。

(a) 画出此序列的原始形式和取对数形式的时间序列图。说明对数变换在这里是恰当的。


```
plot(airpass)
plot(log(airpass))
```



在没对数变换时，每年的变化幅度不同，之前变化幅度少，后来变化幅度大。对数变换后，每年的变化幅度相近了，所以对数变换在这里是恰当的。

(b) 画出并解释取对数后序列的一次差分时间序列图。


```
plot(diff(log(airpass)))
```



一次差分后能看到周期性。

(c) 画出并解释取对数后序列经一次差分和季节差分后的时间序列图。


```
plot(diff(diff(log(airpass)), lag=12))
```



一次差分和季节差分后没有周期性了。

(d) 计算并解释取对数后序列经一次差分和季节差分后的样本 ACF。

```
plot(acf(diff(diff(log(airpass)), lag=12)))
```



一次差分和季节差分后的样本 ACF 在 1 阶和 12 阶（图上显示为 1.0）有明显的自相关性，其他位置没有明显的自相关性，在 3 阶和 9 阶上略微超过临界值可以忽略。

(e) 用“航线模型”( $\text{ARIMA}(0,1,1) \times (0,1,1)_{12}$ )拟合对数化的序列。

```
model.10.9 <- arima(log(airpass), order=c(0, 1, 1), seasonal = list(order = c(0, 1,
                           1), period=12))
print(model.10.9)
```

```
Call:
arima(x = log(airpass), order = c(0, 1, 1), seasonal = list(order = c(0, 1,
                           1), period = 12))
```

```

Coefficients:
      ma1      sma1
     -0.4018   -0.5569
  s.e.   0.0896   0.0731

sigma^2 estimated as 0.001348:  log likelihood = 244.7,  aic = -485.4


```

(f) 对模型及其自相关性和残差的正态性进行诊断。

```

tsdiag(model.10.9, gof.lag = 12)
qqnorm(model.10.9$residuals)
qqline(model.10.9$residuals)
title(expression(Residuals~from~the~ARIMA(list(0,1,1))%*%(list(0,1,1))[12]~Model),line=3)

```



```
shapiro.test(model.10.9$residuals)
```

```

Shapiro-Wilk normality test


data: model.10.9$residuals
W = 0.98637, p-value = 0.1674

```

可以看到，残差没有自相关性，同时 p 值为 0.1674，不能拒绝正态性假设，即接受残差是正态分布的假设。

(g) 假设前置时间为两年，对此序列进行预测，并要求给出预测极限。


```
plot(model.10.9, n1 = c(1970, 1), n.ahead = 24)
```



10.11 美国 Johnson & Johnson 公司于 1960~1980 年间每股收益的季度数据见于文件 JJ 中。

(a) 画出该序列及其取对数后的时间序列图。论证对序列进行对数变换的必要性。


```
plot(JJ)
plot(log(JJ))
```



在没对数变换时，每年的变化幅度不同，之前变化幅度少，后来变化幅度大。对数变换后，每年的变化幅度相近了，所以对数变换在这里是恰当的。

(b) 序列明显是非平稳的。对其进行一次差分变换并画出序列图。现在序列平稳性有无合理性？


```
plot(diff(log(JJ)))
```



现在序列在前期和后期变化幅度大，中期变化幅度小，因此序列平稳性不具有合理性。

(c) 计算并画出经一次差分后序列的样本 ACF，并解释结果。


```
plot(acf(diff(log(JJ))))
```



经一次差分后序列的样本 ACF 仍有较大自相关性，因为季节性未被消除。

(d) 画出并解释经过一次差分和季节差分后的序列图。牢记季度数据一季的长度为 4.


```
plot(diff(diff(log(JJ))), lag=4)
```



可以看到周期性基本消除，并且变化幅度比较接近，所以此时具有平稳性。

(e) 画出并说明经过一次差分和季节差分后的序列的样本 ACF。

```
plot(acf(diff(diff(log(JJ))), lag=4))
```



在 1 阶和 7 阶明显超过临界值。

(f) 拟合 ARIMA(0,1,1) × (0,1,1)<sub>4</sub> 模型，并评估系数估计值的显著性。

```
model.10.11 <- arima(log(JJ), order=c(0, 1, 1), seasonal = list(order = c(0, 1, 1),
                     period=4))
print(model.10.11)
```

```
Call:
arima(x = log(JJ), order = c(0, 1, 1), seasonal = list(order = c(0, 1, 1), period =
        4))

Coefficients:
      ma1      sma1
```

```

-0.6809 -0.3146
s.e. 0.0982 0.1070

sigma^2 estimated as 0.007931: log likelihood = 78.38, aic = -152.75

```


系数估计值较为显著。

(g) 对残差进行所有的诊断性检验。

```

tsdiag(model.10.11, gof.lag = 4)
qqnorm(model.10.11$residuals)
qqline(model.10.11$residuals)
title(expression(Residuals~from~the~ARIMA(list(0,1,1))%*%(list(0,1,1))[4]~Model),line=3)

```



```
shapiro.test(model.10.11$residuals)
```

```

Shapiro-Wilk normality test

data: model.10.11$residuals
W = 0.98583, p-value = 0.489

```

可以看到残差没有自相关性，并且可以接受残差是正态分布的假设。

(h) 计算并画出序列未来两年的预测值，要求给出预测极限。

```
plot(model.10.11, n1 = c(1978, 1), n.ahead = 8)
```

