

第五次作业

第 7 章 参数估计

1. 若 AR(1) 的模型改为 $Y_t = \phi_0 + \phi_1 Y_{t-1} + e_t$, 其中 $e_t \sim N(0, \sigma_e^2)$, 求 $(\phi_0, \phi_1, \sigma_e^2)$ 的无条件似然函数和极大似然估计需要满足的方程。

解 :

$$\begin{aligned} L(\phi_0, \phi_1, \sigma_e^2) &= f(y_1, y_2, \dots, y_n) \\ &= f(y_1) \prod_{t=2}^n f(y_t | y_{t-1}) \\ &= f(y_1) \prod_{t=2}^n \frac{1}{\sqrt{2\pi\sigma_e^2}} \exp \left[-\frac{(y_t - \phi_0 - \phi_1 y_{t-1})^2}{2\sigma_e^2} \right] \\ &= f(y_1) (2\pi\sigma_e^2)^{-\frac{n-1}{2}} \exp \left[-\frac{1}{2\sigma_e^2} \sum_{t=2}^n (y_t - \phi_0 - \phi_1 y_{t-1})^2 \right] \end{aligned}$$

其中 $f(y_1) = (2\pi\sigma_e^2)^{-\frac{1}{2}} (1 - \phi_1^2)^{\frac{1}{2}} \exp \left[-\frac{1}{2\sigma_e^2} (1 - \phi_1^2)(y_1 - \phi_0)^2 \right]$, 所以 $(\phi_0, \phi_1, \sigma_e^2)$ 的无条件似然函数为

$$f(y_1, y_2, \dots, y_n) = (2\pi\sigma_e^2)^{-\frac{n}{2}} (1 - \phi_1^2)^{\frac{1}{2}} \exp \left\{ -\frac{1}{2\sigma_e^2} \left[\sum_{t=2}^n (y_t - \phi_0 - \phi_1 y_{t-1})^2 + (1 - \phi_1^2)(y_1 - \phi_0)^2 \right] \right\}$$

极大似然估计需要满足的方程为

$$\begin{cases} \partial \log L(\phi_0, \phi_1, \sigma_e^2) / \partial \phi_0 = 0 \\ \partial \log L(\phi_0, \phi_1, \sigma_e^2) / \partial \phi_1 = 0 \\ \partial \log L(\phi_0, \phi_1, \sigma_e^2) / \partial \sigma_e^2 = 0 \end{cases}$$

□

2. 对 AR(2) 模型:

$$Y_t - \mu = \phi_1(Y_{t-1} - \mu) + \phi_2(Y_{t-2} - \mu) + e_t, \quad e_t \sim N(0, \sigma_e^2)$$

- (a) 求给定 (Y_1, Y_2) 时的条件似然函数 $L(\phi_1, \phi_2, \mu, \sigma_e^2 | Y_1, Y_2)$, 并求条件似然估计 $\phi_1, \phi_2, \mu, \sigma_e^2$ 需要满足的方程

解 :

给定 (Y_1, Y_2) 时的条件似然函数 $L(\phi_1, \phi_2, \mu, \sigma_e^2 | Y_1, Y_2)$ 为

$$\begin{aligned} & L(\phi_1, \phi_2, \mu, \sigma_e^2 | Y_1, Y_2) \\ &= f(y_1, y_2, \dots, y_n | Y_1, Y_2) \\ &= 1_{[Y_1=y_1]} 1_{[Y_2=y_2]} \prod_{t=3}^n f(y_t | y_{t-2}, y_{t-1}) \\ &= 1_{[Y_1=y_1]} 1_{[Y_2=y_2]} \prod_{t=3}^n \frac{1}{\sqrt{2\sigma_e^2}} \exp \left\{ \frac{1}{\sigma_e^2} \sum_{t=3}^n [y_t - \mu - \phi_1(y_{t-1} - \mu) - \phi_2(y_{t-2} - \mu)]^2 \right\} \end{aligned}$$

条件似然估计 $\phi_1, \phi_2, \mu, \sigma_e^2$ 需要满足的方程为

$$\begin{cases} \partial \log L(\phi_1, \phi_2, \mu, \sigma_e^2 | Y_1, Y_2) / \partial \phi_1 = 0 \\ \partial \log L(\phi_1, \phi_2, \mu, \sigma_e^2 | Y_1, Y_2) / \partial \phi_2 = 0 \\ \partial \log L(\phi_1, \phi_2, \mu, \sigma_e^2 | Y_1, Y_2) / \partial \mu = 0 \\ \partial \log L(\phi_1, \phi_2, \mu, \sigma_e^2 | Y_1, Y_2) / \partial \sigma_e^2 = 0 \end{cases}$$

□

- (b) 求无条件似然函数 $L(\phi_1, \phi_2, \mu, \sigma_e^2)$ (提示: $(Y_1, Y_2)^T$ 服从二维正态分布), 并求无条件似然估计 $\phi_1, \phi_2, \mu, \sigma_e^2$ 需要满足的方程

解 :

题目只说 $(Y_1, Y_2)^T$ 服从二维正态分布, 未给定参数, 所以可以设 $(Y_1, Y_2)^T$ 的概率密度函数为 $f(y_1, y_2)$, 因此无条件似然函数为

$$\begin{aligned} & L(\phi_1, \phi_2, \mu, \sigma_e^2) \\ &= f(y_1, y_2) L(\phi_1, \phi_2, \mu, \sigma_e^2 | Y_1, Y_2) \\ &= f(y_1, y_2) 1_{[Y_1=y_1]} 1_{[Y_2=y_2]} \prod_{t=3}^n \frac{1}{\sqrt{2\sigma_e^2}} \exp \left\{ \frac{1}{\sigma_e^2} \sum_{t=3}^n [y_t - \mu - \phi_1(y_{t-1} - \mu) - \phi_2(y_{t-2} - \mu)]^2 \right\} \end{aligned}$$

无条件似然估计 $\phi_1, \phi_2, \mu, \sigma_e^2$ 需要满足的方程为

$$\begin{cases} \partial \log L(\phi_1, \phi_2, \mu, \sigma_e^2) / \partial \phi_1 = 0 \\ \partial \log L(\phi_1, \phi_2, \mu, \sigma_e^2) / \partial \phi_2 = 0 \\ \partial \log L(\phi_1, \phi_2, \mu, \sigma_e^2) / \partial \mu = 0 \\ \partial \log L(\phi_1, \phi_2, \mu, \sigma_e^2) / \partial \sigma_e^2 = 0 \end{cases}$$

□

3. 若 AR(2) 模型改为 $Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + e_t$, 其中 $e_t \sim N(0, \sigma_e^2)$, 求无条件似然函数 $L(\phi_0, \phi_1, \phi_2, \sigma_e^2)$ 以及极大似然估计需要满足的方程。

解：

设 (Y_1, Y_2) 的概率密度函数为 $f(y_1, y_2)$, 则无条件似然函数为

$$\begin{aligned} L(\phi_0, \phi_1, \phi_2, \sigma_e^2) &= f(y_1, y_2, \dots, y_n) \\ &= f(y_1, y_2) \prod_{t=3}^n f(y_t \mid y_{t-2}, y_{t-1}) \\ &= f(y_1, y_2) \prod_{t=3}^n \frac{1}{\sqrt{2\sigma_e^2}} \exp \left\{ \frac{1}{\sigma_e^2} (y_t - \phi_0 - \phi_1 y_{t-1} - \phi_2 y_{t-2})^2 \right\} \\ &= f(y_1, y_2) \frac{1}{\sqrt{2\sigma_e^2}} \exp \left\{ \frac{1}{\sigma_e^2} \sum_{t=3}^n (y_t - \phi_0 - \phi_1 y_{t-1} - \phi_2 y_{t-2})^2 \right\} \end{aligned}$$

极大似然估计需要满足的方程为

$$\begin{cases} \partial \log L(\phi_0, \phi_1, \phi_2, \sigma_e^2) / \partial \phi_0 = 0 \\ \partial \log L(\phi_0, \phi_1, \phi_2, \sigma_e^2) / \partial \phi_1 = 0 \\ \partial \log L(\phi_0, \phi_1, \phi_2, \sigma_e^2) / \partial \phi_2 = 0 \\ \partial \log L(\phi_0, \phi_1, \phi_2, \sigma_e^2) / \partial \sigma_e^2 = 0 \end{cases}$$

□

7.17 模拟一个 $\phi = 0.7, \theta = 0.4, n = 72$ 的 ARMA(1,1) 序列。

(a) 求 ϕ 和 θ 的矩估计。

TSA 包中的 arima 函数没有矩估计方法, 用大模型实现的矩估计方法一直出错, 自己又不会改, 所以只能放弃了。

(b) 求 ϕ 和 θ 的条件最小二乘估计, 并与 (a) 比较。

```
data_arma_11 = arima.sim(list(ar=0.7, ma=0.4), n=72)
arima(data_arma_11, order=c(1,0,1), method = "CSS")
```

```
Call:
arima(x = data_arma_11, order = c(1, 0, 1), method = "CSS")
```

```
Coefficients:
```

ar1	ma1	intercept
0.7229	0.3242	-0.4065
s.e.	0.0923	0.1234
		0.5606

```
sigma^2 estimated as 0.9802: part log likelihood = -101.44
```

(c) 求 ϕ 和 θ 的极大似然估计，并与 (a) 和 (b) 比较。

```
arima(data_arma_11, order=c(1,0,1),method = "ML")

Call:
arima(x = data_arma_11, order = c(1, 0, 1), method = "ML")

Coefficients:
      ar1     ma1   intercept
      0.7184  0.338    -0.2179
  s.e.  0.0960  0.127     0.5357

sigma^2 estimated as 0.9862:  log likelihood = -102.3,  aic = 210.61
```

(d) 在选取相同参数和样本规模的情况下，使用新的模拟序列重复 (a)、(b) 和 (c)，并将本次与前次的模拟结果进行比较。

```
data_arma_11 = arima.sim(list(ar=0.7, ma=0.4), n=72)
arima(data_arma_11, order=c(1,0,1),method = "CSS")
arima(data_arma_11, order=c(1,0,1),method = "ML")

Call:
arima(x = data_arma_11, order = c(1, 0, 1), method = "CSS")

Coefficients:
      ar1     ma1   intercept
      0.5729  0.1459    -0.1612
  s.e.  0.1359  0.1641     0.2950

sigma^2 estimated as 0.84:  part log likelihood = -95.89

Call:
arima(x = data_arma_11, order = c(1, 0, 1), method = "ML")

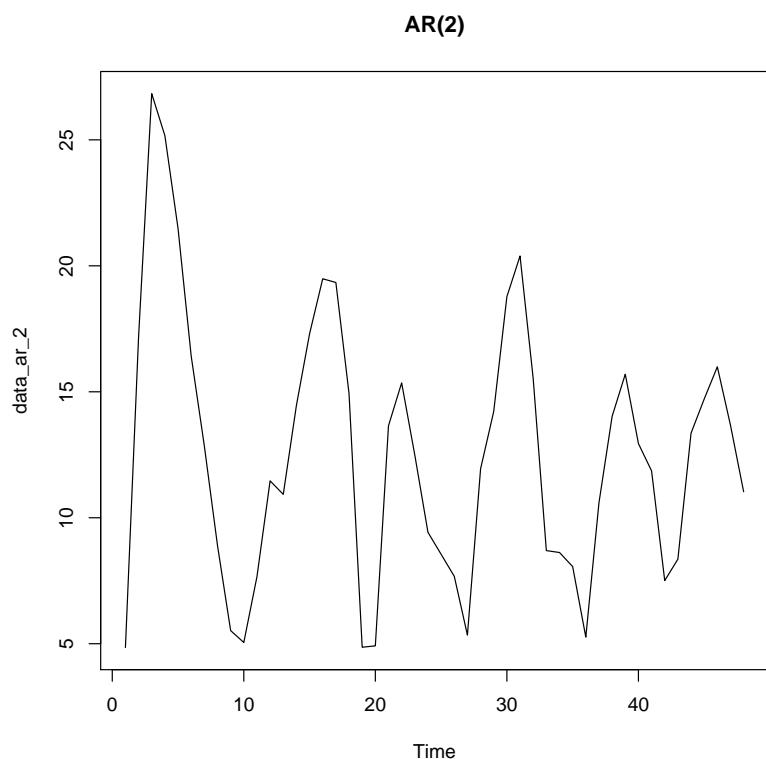
Coefficients:
      ar1     ma1   intercept
      0.600   0.1500    -0.0175
  s.e.  0.152   0.1799     0.3120

sigma^2 estimated as 0.8858:  log likelihood = -98.12,  aic = 202.23
```

比较后发现和前次模拟结果差距还是比较大的，原因应该是样本量不是很大。

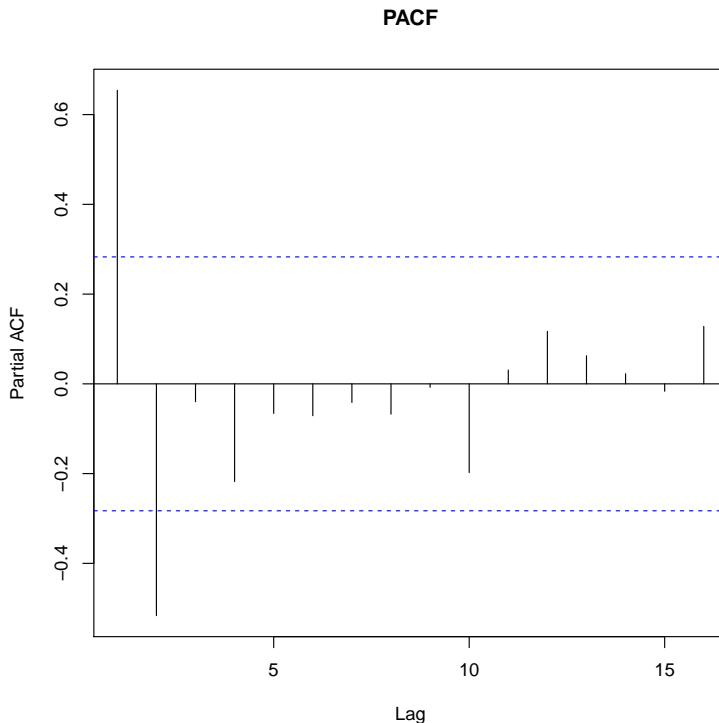
7.24 模拟一个 $\phi_1 = 1.0, \phi_2 = -0.6, n = 48$ 的 AR(2) 序列，但误差项从有 8 个自由度的卡方分布中抽样得到。

```
set.seed(1)
innov <- rchisq(n = 48, df = 8)
data_ar_2 <- arima.sim(list(ar = c(1.0, -0.6)), 48, innov = innov)
plot(data_ar_2)
```



(a) 绘出该序列的样本 PACF，建议建立 AR(2) 模型吗？

```
pacf(data_ar_2, main="PACF")
```



从图中可以看出， $\hat{\Phi}_{11}$ 和 $\hat{\Phi}_{22}$ 都显著超过临界值，其他均未超过临界值，因此建议建立 AR(2) 模型。

(b) 估计 ϕ_1 和 ϕ_2 ，并解释结果。

```
arima(data_ar_2, order = c(2, 0, 0), method = "CSS")
```

```
Call:
arima(x = data_ar_2, order = c(2, 0, 0), method = "CSS")

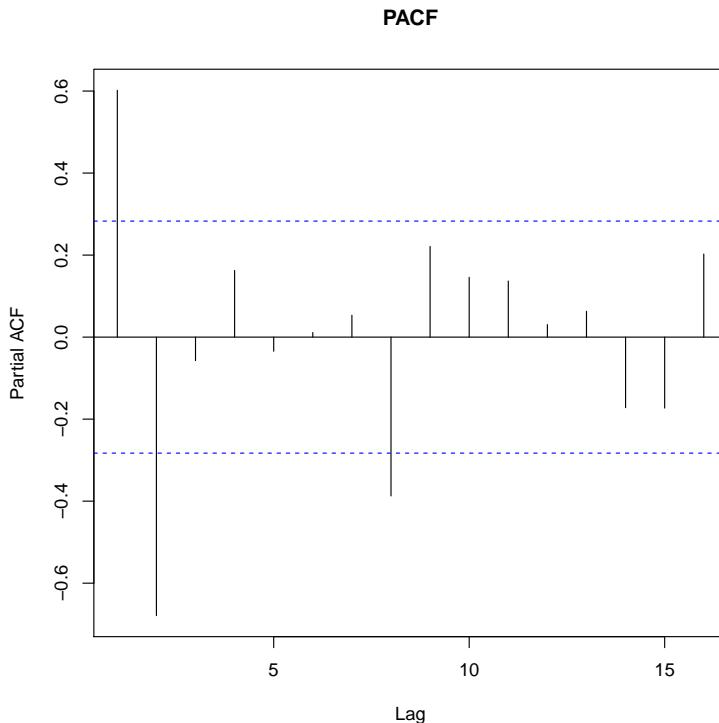
Coefficients:
      ar1     ar2   intercept
    1.1377 -0.6148    12.2435
  s.e.  0.0993  0.0970    0.8140

sigma^2 estimated as 7.165:  part log likelihood = -115.37
```

估计出的值为： $\hat{\phi}_1 = 1.1377, \hat{\phi}_2 = -0.6148$ ，和理论值 $\phi_1 = 1.0, \phi_2 = -0.6$ 比较接近。

(c) 在相同条件下，使用新的模拟序列重复 (a) 和 (b)。

```
set.seed(2)
innov <- rchisq(n = 48, df = 8)
data_ar_2 <- arima.sim(list(ar = c(1.0, -0.6)), 48, innov = innov)
pacf(data_ar_2, main="PACF")
arima(data_ar_2, order = c(2, 0, 0), method = "CSS")
```



从图中可以看出， $\hat{\Phi}_{11}$ 和 $\hat{\Phi}_{22}$ 都显著超过临界值，而 $\hat{\Phi}_{66}$ 略微超过临界值，但 6 距离 2 较远，其他均未超过临界值，因此建议建立 AR(2) 模型。

```

Call:
arima(x = data_ar_2, order = c(2, 0, 0), method = "CSS")

Coefficients:
      ar1     ar2   intercept
    1.0322 -0.6947    13.4058
  s.e.  0.1031   0.1018    0.9448

sigma^2 estimated as 18.79:  part log likelihood = -138.5

```

估计出的值为： $\hat{\phi}_1 = 1.0322, \hat{\phi}_2 = -0.6947$ ，和理论值 $\phi_1 = 1.0, \phi_2 = -0.6$ 比较接近。

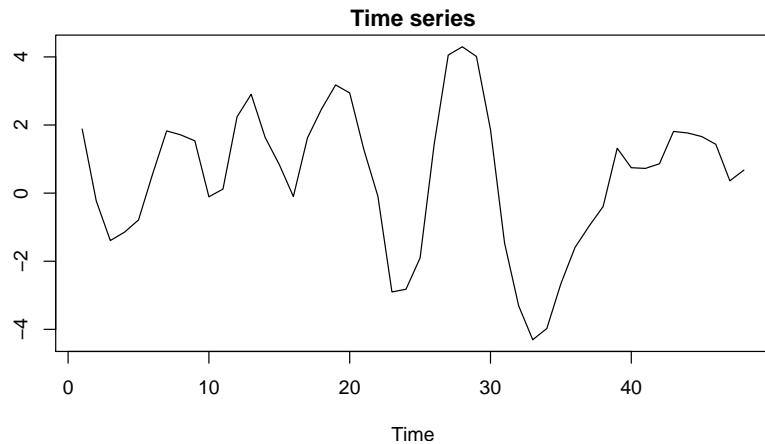
第 8 章 模型诊断

8.6 模拟 $n = 48, \phi_1 = 1.5, \phi_2 = -0.75$ 的 AR(2) 模型。

```

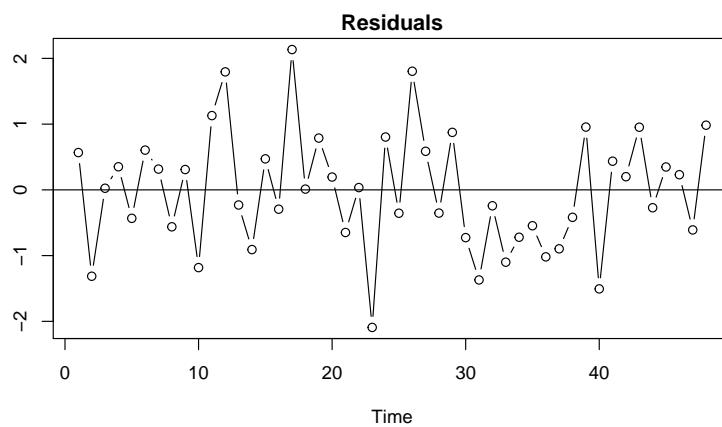
set.seed(1)
data_ar_2 = arima.sim(list(ar=c(1.5, -0.75)), n = 48)
par(mar=c(20,3,1.5,1.5))
plot(data_ar_2, main = "Time series")

```



(a) 拟合正确识别的 AR(2) 模型，观察残差的时间序列图，该图支持 AR(2) 的识别吗？

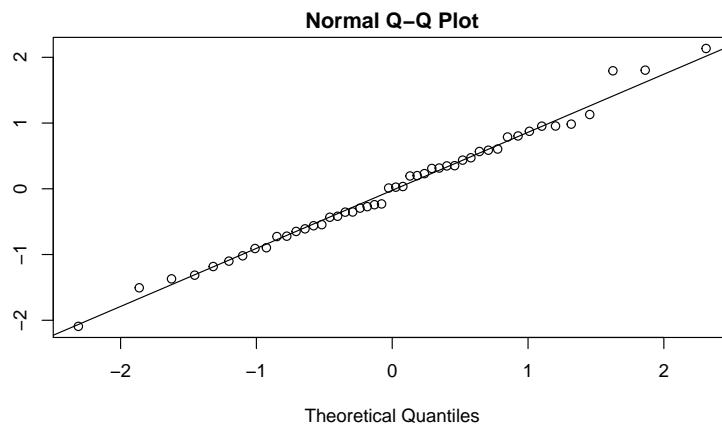
```
model_ar_2 = arima(data_ar_2, order = c(2, 0, 0))
model_ar_2
plot(residuals(model_ar_2), main = "Residuals")
abline(h=0)
```



残差图围绕零水平线，无明显趋势，所以该图支持 AR(2) 的识别。

(b) 展示标准残差的正态分位数-分位数图，该图支持 AR(2) 的识别吗？

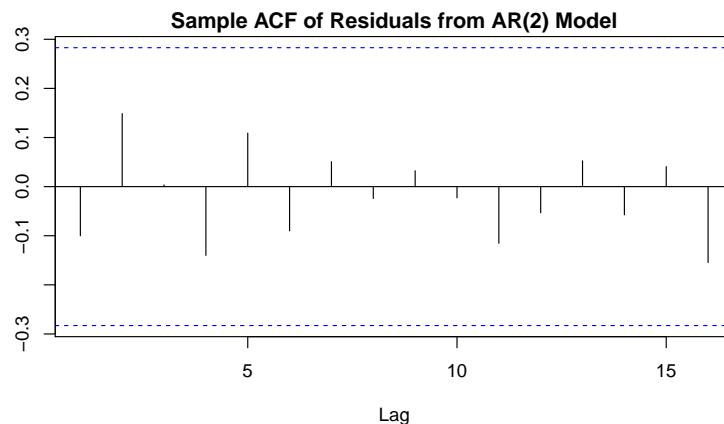
```
qqnorm(residuals(model_ar_2))
qqline(residuals(model_ar_2))
```



图中的点接近一条直线，在极值处也是如此，所以该图支持 AR(2) 的识别。

(c) 展示残差的样本 ACF，该图支持 AR(2) 的识别吗？

```
acf(residuals(model_ar_2), main = "Sample ACF of Residuals from AR(2) Model")
```



残差的自相关系数均未超过临界值，所以可以认为残差没有自相关的迹象，所以该图支持 AR(2) 的识别。

(d) 计算 Ljung-Box 统计量，求和至 $K = 12$ ，该统计量支持 AR(2) 的识别吗？

```
LB.test(model_ar_2, lag = 12)
```

```
Call:
arima(x = data_ar_2, order = c(2, 0, 0))

Coefficients:
      ar1     ar2   intercept
    1.3426  -0.7001    0.5863
  s.e.  0.1007   0.0988    0.3612

sigma^2 estimated as 0.792:  log likelihood = -63.67,  aic = 133.35

^Box-Ljung test

data:  residuals from model_ar_2
X-squared = 5.2, df = 10, p-value = 0.8774

TheRPlugin_ProxyDevice
2
```

p 值大于 0.05，所以该统计量支持 AR(2) 的识别。

8.11 图表 6-31 建议对石油价格的对数差分序列识别 AR(1) 模型或 AR(4) 模型(文件名为 oil.price)。

(a) 用极大似然估计法估计两个模型，用本章讨论的诊断检验对结果进行比较。

```
data(oil.price)
model_ar_1 = arima(log(oil.price), order = c(1,1,0), method = "ML")
model_ar_2 = arima(log(oil.price), order = c(4,1,0), method = "ML")
model_ar_1
model_ar_2
tsdiag(model_ar_1)
tsdiag(model_ar_2)
```

估计的结果为：

```
Call:
arima(x = log(oil.price), order = c(1, 1, 0), method = "ML")

Coefficients:
      ar1
      0.2364
  s.e.  0.0660

sigma^2 estimated as 0.006787:  log likelihood = 258.55,  aic = -515.11

Call:
arima(x = log(oil.price), order = c(4, 1, 0), method = "ML")

Coefficients:
      ar1      ar2      ar3      ar4
      0.2673  -0.1550  0.0238 -0.0970
  s.e.  0.0669  0.0691  0.0691  0.0681

sigma^2 estimated as 0.006603:  log likelihood = 261.82,  aic = -515.64
```

诊断的结果如图 5.1 和 5.2 所示。

(b) 图表 6-32 建议为对数差分序列设定 MA(1) 模型，用极大似然法估计该模型并用本章讨论的检验进行诊断。

```
model_ma_1 = arima(log(oil.price), order = c(0,1,1), method = "ML")
model_ma_1
tsdiag(model_ma_1)
```

```
Call:
arima(x = log(oil.price), order = c(0, 1, 1), method = "ML")

Coefficients:
      ma1
      0.2956
  s.e.  0.0693
```

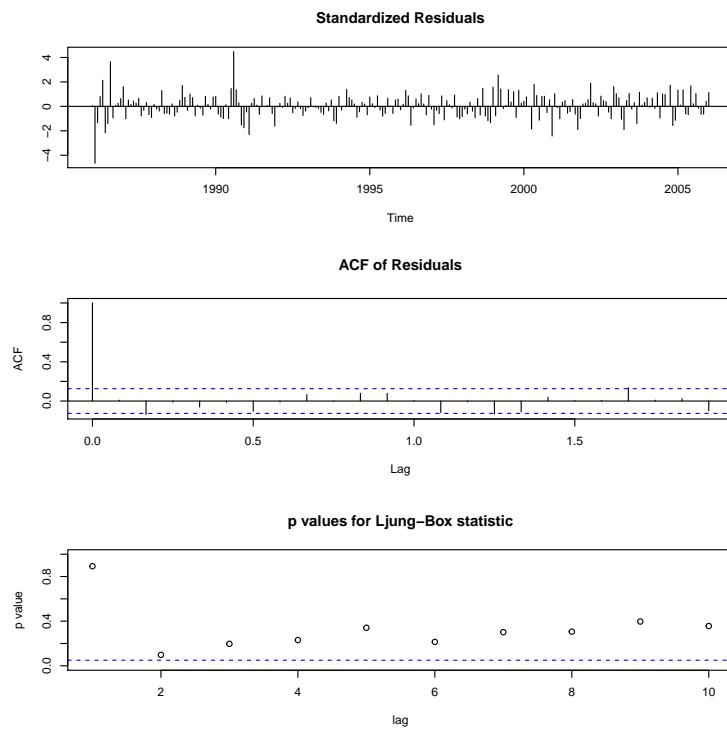


图 5.1: AR(1) 的诊断结果

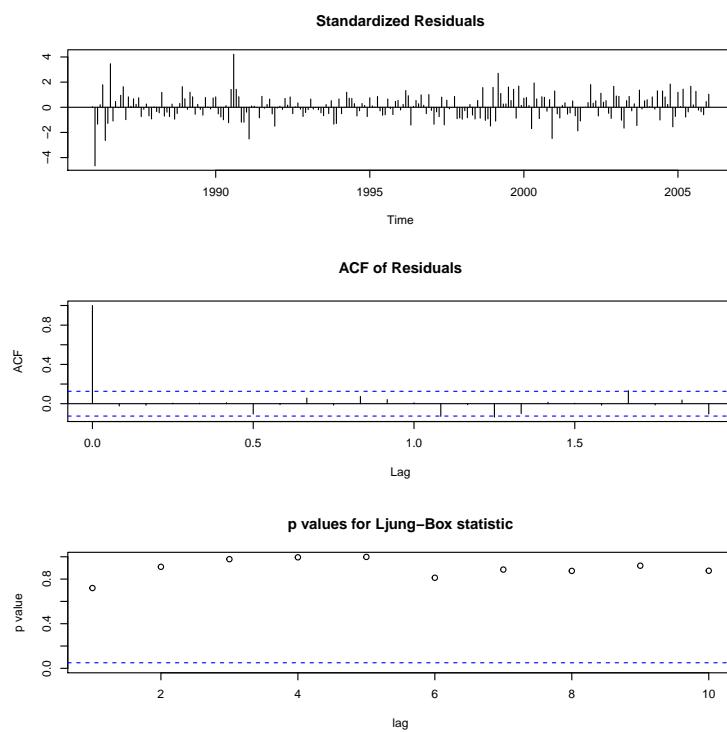


图 5.2: AR(4) 的诊断结果

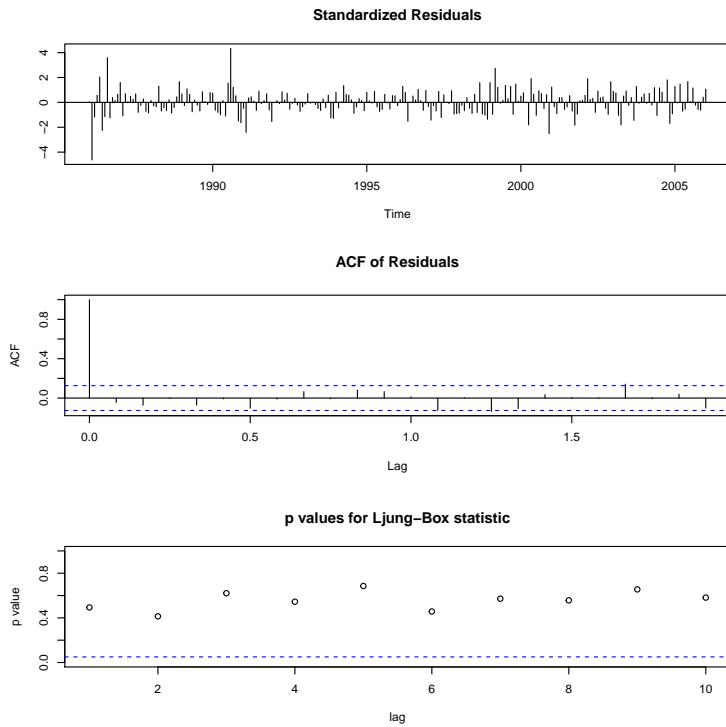


图 5.3: MA(1) 的诊断结果

```
sigma^2 estimated as 0.006689: log likelihood = 260.29, aic = -518.58
```

诊断的结果如图 5.3 所示。

- (c) 基于 (a)、(b) 部分给出的结果，你更偏好 AR(1)、AR(4) 和 MA(1) 三个模型中的哪一个？

由于残差图、残差 ACF 图均无明显区别，而 Ljung-Box 统计量的 p 值均大于 0.05，所以也无法区分。因此根据 AIC 来判断，MA(1) 的 AIC 最小，所以更偏好 MA(1) 模型。