

## 4 Prognose

### 4.1 Die optimale Prognose aus der endlichen Vergangenheit

4.1

#### Die optimale Prognose aus der endlichen Vergangenheit

Sei  $(Y_t)$  ein stochastischer Prozess mit  $\mathbb{E}[Y_t^2] < \infty$  und  $(y_t)_{1 \leq t \leq N}$  die zur Verfügung stehende Zeitreihe.

- Gesucht ist eine Prognose für den Wert  $y_{N+h}$  auf der Grundlage der Zeitreihe  $(y_t)_{1 \leq t \leq N}$ .
- Für einen positiven Prognosehorizont  $h > 0$  liegt  $y_{N+h}$  in der Zukunft, für einen negativen Prognosehorizont  $h < 0$  – in der Vergangenheit.
- Eine Prognose wird mit Hilfe einer Prognosefunktion  $\hat{Y}_{N,h}$  der Zeitreihenvariablen des Prozesses

$$\hat{Y}_{N,h}(Y_1, Y_2, \dots, Y_N)$$

berechnet.

#### Die optimale Prognose aus der endlichen Vergangenheit

4.2

Prognosen sind *Schätzungen*, Prognosefunktionen – *Schätzfunktionen* für eine Realisation  $y_{N+h}$  des Prozesses.

#### Die optimale Prognose aus der endlichen Vergangenheit

4.3

Wir betrachten den Prognosefehler

$$Y_{N+h} - \hat{Y}_{N,h}.$$

Gesucht ist die optimale/beste Prognosefunktion für  $y_{N+h}$ , d.h. die Prognosefunktion, welche den mittleren quadratischen Prognosefehler  $MSE[\hat{Y}_{N,h}]$  minimiert

$$MSE[\hat{Y}_{N,h}] = \mathbb{E}\left[\left(Y_{N+h} - \hat{Y}_{N,h}\right)^2\right].$$

#### Die optimale Prognose aus der endlichen Vergangenheit

4.4

**Theorem 40** (Optimale Prognose). Sei  $(Y_t)$  ein stochastischer Prozess mit  $\mathbb{E}[Y_t^2] < \infty$ . Die optimale Prognose von  $y_{N+h}$  mit Hilfe einer Prognosefunktion der Zeitreihenvariablen  $Y_1, Y_2, \dots, Y_N$  ist der bedingte Erwartungswert

$$\hat{Y}_{N+h}(Y_1, Y_2, \dots, Y_N) = \mathbb{E}[Y_{N+h} | Y_1 = y_1, Y_2 = y_2, \dots, Y_N = y_N].$$

## Die optimale lineare Prognose aus der endlichen Vergangenheit

4.5

**Theorem 41** (Optimale lineare Prognose). Sei  $(Y_t)$  ein stationärer stochastischer Prozess mit Autokorrelationsfunktion  $(\rho_\tau)$ . Die optimale Prognose von  $y_{N+h}$  mit Hilfe einer linearen Prognosefunktion

$$\widehat{Y}_{N,h}(Y_1, Y_2, \dots, Y_N) = \sum_{u=0}^{N-1} a_u Y_{N-u}$$

benutzt die Gewichte  $(a_u)_{0 \leq u \leq N-1}$ , welche das System der Yule-Walker-Gleichungen löst

$$\begin{pmatrix} 1 & \rho_1 & \dots & \rho_{N-1} \\ \rho_1 & 1 & \dots & \rho_{N-2} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{N-1} & \rho_{N-2} & \dots & 1 \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \\ \vdots \\ a_{N-1} \end{pmatrix} = \begin{pmatrix} \rho_h \\ \rho_{h+1} \\ \vdots \\ \rho_{h+N-1} \end{pmatrix}.$$

## Die optimale lineare Prognose aus der endlichen Vergangenheit

4.6

Die optimale lineare Prognose  $\widehat{Y}_{N,h}$  aus der endlichen Vergangenheit  $\{y_1, y_2, \dots, y_N\}$  kann mit Hilfe der R-Funktion `TrenchForecasts` aus dem Paket `Itsa` (Linear Time Series Analysis) implementiert werden.

- Dabei werden die Autokovarianzen mit Lags  $\tau \in \{0, 1, 2, \dots, h + N - 1\}$  benötigt. Werden die  $h + N$  Werte der Autokovarianzfunktion aus der Zeitreihe  $\{y_1, y_2, \dots, y_N\}$  geschätzt, so können lediglich Prognosen mit negativem Prognosehorizont  $h < 0$  erstellt werden. Für Prognosen in die Zukunft muss die Autokovarianzfunktion bekannt sein oder mit einem alternativen Verfahren geschätzt werden.

Für ARIMA-Modelle kann die optimale lineare Prognose  $\widehat{Y}_{N,h}$  aus der endlichen Vergangenheit auch mit Hilfe der Funktion `predict` berechnet werden.

## 4.2 Die optimale lineare Prognose aus der unendlichen Vergangenheit

### Die optimale lineare Prognose aus der unendlichen Vergangenheit ■ Minimierung des mittleren quadratischen Prognosefehlers

4.7

Wir betrachten im Folgenden lineare Prognosen aus der unendlichen Vergangenheit

$$\widehat{Y}_{t,h}(Y_t, Y_{t-1}, \dots) = \sum_{u=0}^{\infty} a_u Y_{t-u}.$$

Der Prognosefehler ist

$$Y_{t+h} - \widehat{Y}_{t,h}.$$

Gesucht ist die optimale/beste Prognosefunktion für  $y_{t+h}$ , d.h. die Prognosefunktion, welche den mittleren quadratischen Prognosefehler  $\text{MSE}[\hat{Y}_{t,h}]$  minimiert

$$\text{MSE}[\hat{Y}_{t,h}] = \mathbb{E}\left[\left(Y_{t+h} - \hat{Y}_{t,h}\right)^2\right].$$

### Die optimale lineare Prognose aus der unendlichen Vergangenheit ■ Minimierung des mittleren quadratischen Prognosefehlers

4.8

Diese Minimierungsaufgabe führt zu einem unendlichen System von Yule-Walker-Gleichungen mit den Unbekannten  $(a_u)$

$$\begin{pmatrix} 1 & \rho_1 & \dots \\ \rho_1 & 1 & \dots \\ \vdots & \vdots & \ddots \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \\ \vdots \end{pmatrix} = \begin{pmatrix} \rho_h \\ \rho_{h+1} \\ \vdots \end{pmatrix}.$$

### Die optimale lineare Prognose aus der unendlichen Vergangenheit ■ Prognose für MA $[\infty]$ -Prozesse

4.9

Sei  $(Y_t)$  ein MA $[\infty]$ -Prozess

$$Y_t = - \sum_{u=0}^{\infty} \beta_u \varepsilon_{t-u},$$

wobei  $\beta_0 = -1$  gesetzt wurde.

Die optimale lineare Prognose für den Wert  $y_{t+h}$  ist

$$\hat{Y}_{t,h} = - \sum_{u=0}^{\infty} \beta_{h+u} \varepsilon_{t-u}.$$

### Die optimale lineare Prognose aus der unendlichen Vergangenheit ■ Unkorreliertheit zwischen dem Prognosefehler und den Zeitreihenvariablen

4.10

Alternativ kann die Folge  $(a_u)$  mit Hilfe des folgenden Satzes bestimmt werden.

**Theorem 42.** Sei  $(Y_t)$  ein rein nicht-deterministischer Prozess. Die lineare Prognose aus der unendlichen Vergangenheit

$$\hat{Y}_{t,h}(Y_t, Y_{t-1}, \dots) = \sum_{u=0}^{\infty} a_u Y_{t-u}$$

ist dann und nur dann optimal, wenn der Prognosefehler  $Y_{t+h} - \hat{Y}_{t,h}$  unkorreliert mit allen Zeitreihenvariablen  $Y_t, Y_{t-1}, \dots$  ist.

### Die optimale lineare Prognose aus der unendlichen Vergangenheit ■ Unkorreliertheit zwischen dem Prognosefehler und den Zeitreihenvariablen

4.11

Wir betrachten den Prognosefehler zum Zeitpunkt  $t + h$

$$Y_{t+h} - \widehat{Y}_{t,h}$$

und den mittleren quadratischen Prognosefehler

$$\text{MSE}[\widehat{Y}_{t,h}] = \mathbb{E} \left[ \left( Y_{t+h} - \widehat{Y}_{t,h} \right)^2 \right].$$

Sei  $\Delta(h)$  der mittlere quadratische Prognosefehler für die optimale lineare Prognose

$$\Delta(h) := \min_{(a_u)} \text{MSE}[\widehat{Y}_{t,h}].$$

### Die optimale lineare Prognose aus der unendlichen Vergangenheit ■ Unkorreliertheit zwischen dem Prognosefehler und den Zeitreihenvariablen

4.12

**Definition 43** (deterministischer Prozess). Ein stationärer Prozess  $(Y_t)$  heißt **deterministisch** (singulär, exakt vorhersagbar), wenn gilt

$$\Delta(h) = 0 \quad \forall h > 0.$$

**Definition 44** (rein nicht-deterministischer Prozess). Ein stationärer Prozess  $(Y_t)$  heißt rein nicht-deterministisch, wenn gilt

$$\lim_{h \rightarrow \infty} \Delta(h) = \gamma_0.$$

Ein stationärer Prozess ist dann und nur dann rein nicht-deterministisch, wenn er sich als  $\text{MA}[\infty]$ -Prozess

$$Y_t = \sum_{u=0}^{\infty} \beta_u \varepsilon_{t-u}$$

mit quadratisch summierbaren Gewichten  $\sum_{u=0}^{\infty} \beta_u^2 < \infty$  darstellen lässt.

### Die optimale lineare Prognose aus der unendlichen Vergangenheit ■ Unkorreliertheit zwischen dem Prognosefehler und den Zeitreihenvariablen

4.13

**Theorem 45** (Wold'scher Zerlegungssatz). Jeder stationäre Prozess  $(Y_t)$  kann eindeutig als Summe zweier unkorrelierter stationärer Prozesse, nämlich eines deterministischen und eines rein nicht-deterministischen Prozesses dargestellt werden.

Weiter werden wir uns nur mit der Prognose rein nicht-deterministischer Prozesse beschäftigen.

**Theorem 46.** Sei  $(Y_t)$  ein rein nicht-deterministischer Prozess. Die lineare Prognose aus der unendlichen Vergangenheit

$$\widehat{Y}_{t,h}(Y_t, Y_{t-1}, \dots) = \sum_{u=0}^{\infty} a_u Y_{t-u}$$

ist dann und nur dann optimal, wenn der Prognosefehler  $Y_{t+h} - \widehat{Y}_{t,h}$  unkorreliert mit allen Zeitreihenvariablen  $Y_t, Y_{t-1}, \dots$  ist.

#### 4.2.1 Der Box-Jenkins-Ansatz

##### Der Box-Jenkins-Ansatz

4.14

Der Box-Jenkins-Ansatz ist ein *rekursives* Berechnungsverfahren der optimalen linearen Prognose aus der unendlichen Vergangenheit für allgemeine ARIMA-Prozesse.

##### Der Box-Jenkins-Ansatz ■ Prognose für MA[ $q$ ]-Prozesse

4.15

Sei  $(Y_t)$  ein MA[ $q$ ]-Prozess

$$Y_t = - \sum_{u=0}^q \beta_u \varepsilon_{t-u},$$

wobei  $\beta_0 = -1$  gesetzt wurde. Wir können  $(Y_t)$  als MA[ $\infty$ ]-Prozess mit Parametern  $\beta_u = 0$  für  $u > q$  darstellen.

Dann lautet die optimale lineare Prognose für den Wert  $y_{t+h}$

$$\widehat{Y}_{t,h} = \begin{cases} - \sum_{u=0}^{q-h} \beta_{h+u} \varepsilon_{t-u}, & h \leq q \\ 0, & h > q \end{cases}$$

##### Der Box-Jenkins-Ansatz ■ Prognose für MA[ $q$ ]-Prozesse

4.16

Die Störungen  $(\varepsilon_u)_{t+h-q \leq u \leq t}$  entsprechen den Prognosefehlern der 1-Schritt-Prognosen

$$\begin{aligned} \varepsilon_t &= Y_t - \widehat{Y}_{t-1,1} \\ \varepsilon_{t-1} &= Y_{t-1} - \widehat{Y}_{t-2,1} \\ \varepsilon_{t-2} &= Y_{t-2} - \widehat{Y}_{t-3,1} \\ &\vdots \\ \varepsilon_{t-h-q} &= Y_{t+h-q} - \widehat{Y}_{t+h-q-1,1} \end{aligned}$$

Sie werden *rekursiv* berechnet.

**Der Box-Jenkins-Ansatz ■ Prognose für MA[ $q$ ]-Prozesse**

4.17

Wir schreiben die Definitionsgleichung für  $Y_{t+h}$  fort

$$Y_{t+h} = \varepsilon_{t+h} - \beta_1 \varepsilon_{t+h-1} - \dots - \beta_h \varepsilon_t - \beta_{h+1} \varepsilon_{t-1} - \dots - \beta_q \varepsilon_{t+h-q}.$$

Die Prognose  $\hat{Y}_{t,h}$  wird aus  $Y_{t+h}$ , wie folgt, berechnet

$$\hat{Y}_{t,h} = \varepsilon_{t+h} - \beta_1 \varepsilon_{t+h-1} - \dots - \beta_h \varepsilon_t - \beta_{h+1} \varepsilon_{t-1} - \dots - \beta_q \varepsilon_{t+h-q}.$$

- Die Störungen  $\varepsilon_{t+h}, \varepsilon_{t+h-1}, \dots, \varepsilon_{t+1}$  werden mit ihrem Erwartungswert von Null ersetzt.
- Die Störungen  $\varepsilon_t, \varepsilon_{t-1}, \dots$  entsprechen den Prognosefehlern  $Y_t - \hat{Y}_{t-1,1}, Y_{t-1} - \hat{Y}_{t-2,1}, \dots$  der 1-Schritt-Prognosen.

**Der Box-Jenkins-Ansatz ■ Prognose für AR[ $p$ ]-Prozesse**

4.18

Sei  $(Y_t)$  ein AR[ $p$ ]-Prozess

$$Y_t = \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \varepsilon_t.$$

Die optimalen linearen Prognosen sind

$$\begin{aligned} \hat{Y}_{t,1} &= \alpha_1 Y_t + \alpha_2 Y_{t-1} + \dots + \alpha_p Y_{t+1-p} \\ \hat{Y}_{t,2} &= \alpha_1 \hat{Y}_{t,1} + \alpha_2 Y_t + \alpha_3 Y_{t-1} + \dots + \alpha_p Y_{t+2-p} \end{aligned}$$

Für einen beliebigen Prognosehorizont  $h$

$$\begin{aligned} \hat{Y}_{t,h} &= \alpha_1 \hat{Y}_{t,h-1} + \alpha_2 \hat{Y}_{t,h-2} + \dots + \alpha_{h-1} \hat{Y}_{t,1} + \\ &\quad \alpha_h Y_t + \alpha_{h+1} Y_{t-1} + \dots + \alpha_p Y_{t+h-p} \end{aligned}$$

**Der Box-Jenkins-Ansatz ■ Prognose für AR[ $p$ ]-Prozesse**

4.19

Wir schreiben die Definitionsgleichung für  $Y_{t+h}$  fort

$$Y_{t+h} = \alpha_1 Y_{t+h-1} + \alpha_2 Y_{t+h-2} + \dots + \alpha_p Y_{t+h-p} + \varepsilon_{t+h}.$$

Die Prognose  $\hat{Y}_{t,h}$  wird aus  $Y_{t+h}$ , wie folgt, berechnet

$$\hat{Y}_{t,h} = \alpha_1 Y_{t+h-1} + \alpha_2 Y_{t+h-2} + \dots + \alpha_p Y_{t+h-p} + \varepsilon_{t+h}.$$

- Die unbekanntenen Variablen  $Y_{t+h-1}, \dots, Y_{t+1}$  werden mit den optimalen linearen Prognosen  $\hat{Y}_{t,h-1}, \dots, \hat{Y}_{t,1}$  ersetzt.

- Für die Variablen  $Y_t, Y_{t-1}, \dots$  setzen wir ihre Beobachtungen ein.
- Die Störung  $\varepsilon_{t+h}$  wird mit ihrem Erwartungswert von Null ersetzt.

### Der Box-Jenkins-Ansatz ■ Prognose für ARMA $[p, q]$ -Prozesse

4.20

Sei  $(Y_t)$  ein ARMA $[p, q]$ -Prozess

$$Y_t = \alpha_1 Y_{t-1} + \dots + \alpha_p Y_{t-p} + \varepsilon_t - \beta_1 \varepsilon_{t-1} - \dots - \beta_q \varepsilon_{t-q}.$$

Wir schreiben die Definitionsgleichung für  $Y_{t+h}$  fort

$$Y_{t+h} = \alpha_1 Y_{t+h-1} + \dots + \alpha_p Y_{t+h-p} + \varepsilon_{t+h} - \beta_1 \varepsilon_{t+h-1} - \dots - \beta_q \varepsilon_{t+h-q}.$$

### Der Box-Jenkins-Ansatz ■ Prognose für ARMA $[p, q]$ -Prozesse

4.21

Die Prognose  $\hat{Y}_{t,h}$  wird aus  $Y_{t+h}$ , wie folgt, berechnet

$$\hat{Y}_{t,h} = \alpha_1 Y_{t+h-1} + \dots + \alpha_p Y_{t+h-p} + \varepsilon_{t+h} - \beta_1 \varepsilon_{t+h-1} - \dots - \beta_q \varepsilon_{t+h-q}.$$

- Die unbekanntenen Variablen  $Y_{t+h-1}, \dots, Y_{t+1}$  werden mit den optimalen linearen Prognosen  $\hat{Y}_{t,h-1}, \dots, \hat{Y}_{t,1}$  ersetzt.
- Für die Variablen  $Y_t, Y_{t-1}, \dots$  setzen wir ihre Beobachtungen ein.
- Die Störungen  $\varepsilon_{t+h}, \varepsilon_{t+h-1}, \dots, \varepsilon_{t+1}$  werden mit ihrem Erwartungswert von Null ersetzt.
- Die Störungen  $\varepsilon_t, \varepsilon_{t-1}, \dots$  entsprechen den Prognosefehlern  $Y_t - \hat{Y}_{t-1,1}, Y_{t-1} - \hat{Y}_{t-2,1}, \dots$  der 1-Schritt-Prognosen.

### Der Box-Jenkins-Ansatz ■ Prognose für ARMA $[p, q]$ -Prozesse

4.22

Wir schreiben den ARMA $[p, q]$ -Prozess  $(Y_t)$ , wie folgt, auf:

$$Y_t = c(B) \varepsilon_t$$

mit

$$c(B) = \alpha^{-1}(B) \beta(B).$$

Die Varianz des Prognosefehlers ist

$$\text{Var} \left[ Y_{t+h} - \hat{Y}_{t,h} \right] = \sigma_\varepsilon^2 \sum_{u=0}^{h-1} c_u^2$$

mit  $(c_u)$  die Gewichte des Filters  $c(B)$ .

**Der Box-Jenkins-Ansatz ■ Prognose für ARMA $[p, q]$ -Prozesse**

4.23

Die optimale lineare Prognose eines ARMA $[p, q]$ -Modells hat die folgenden Eigenschaften:

$$\lim_{h \rightarrow \infty} \text{Var} [Y_{t+h} - \hat{Y}_{t,h}] = \text{Var}[Y_t]$$

$$\lim_{h \rightarrow \infty} \hat{Y}_{t,h} = \mathbb{E}[Y_t] = 0$$

Daher ist sie *unbrauchbar für großen Prognosehorizont  $h$* .

**Der Box-Jenkins-Ansatz ■ Prognose für ARMA $[p, q]$ -Prozesse**

4.24

Sei  $(Y_t)$  ein Gaußscher ARMA $[p, q]$ -Prozess. Dann gilt

$$Y_{t+h} - \hat{Y}_{t,h} \sim N \left( 0, \sigma_\varepsilon^2 \sum_{u=0}^{h-1} c_u^2 \right).$$

Prognoseintervall für  $Y_{t+h}$ :

$$\hat{Y}_{t,h} \pm z_{1-\alpha/2} \sigma_\varepsilon \sqrt{\sum_{u=0}^{h-1} c_u^2}$$

mit  $z_{1-\alpha/2}$  das  $1 - \alpha/2$ -Quantil der Standardnormalverteilung.

**Der Box-Jenkins-Ansatz ■ Prognose für angepasste ARMA $[p, q]$ -Prozesse**

4.25

Der Box-Jenkins-Ansatz ist ein rekursives Berechnungsverfahren für die optimale lineare Prognose  $\hat{Y}_{t,h}$ , wenn

- die Parameter  $\alpha = (\alpha_1 \ \alpha_2 \ \dots \ \alpha_p)$  und  $\beta = (\beta_1 \ \beta_2 \ \dots \ \beta_q)$  bekannt sind,
- eine unendliche Zeitreihe  $y_{-\infty}, \dots, y_t$  zur Verfügung steht (unendliche Vergangenheit).

**Der Box-Jenkins-Ansatz ■ Prognose für angepasste ARMA $[p, q]$ -Prozesse**

4.26

In praktischen Anwendungen verwenden wir eine angepasste Prognosefunktion auf der Grundlage von  $\hat{Y}_{t,h}$ . Dabei setzen wir die folgenden Werte ein:

- die Parameterschätzungen  $\hat{\alpha} = (\hat{\alpha}_1 \ \hat{\alpha}_2 \ \dots \ \hat{\alpha}_p)$  und  $\hat{\beta} = (\hat{\beta}_1 \ \hat{\beta}_2 \ \dots \ \hat{\beta}_q)$  nach einer der Methoden CLS, ULS oder ML,
- geeignete Startwerte  $\tilde{\varepsilon}_0, \tilde{\varepsilon}_{-1}, \dots, \tilde{Y}_0, \tilde{Y}_{-1}, \dots$



- Schätzungen (Approximationen)  $\tilde{\varepsilon}_t, \dots, \tilde{\varepsilon}_1$  für die Störungen  $\varepsilon_t, \dots, \varepsilon_1$ .

Diese Prognosefunktion bezeichnen wir im Folgenden mit  $\tilde{Y}_{t,h}$ .

### Der Box-Jenkins-Ansatz ■ Prognose für angepasste ARMA $[p, q]$ -Prozesse

4.27

**Theorem 47.** Sei  $(Y_t)$  ein stationärer und invertierbarer ARMA $[p, q]$ -Prozess,  $\alpha(B)Y_t = \beta(B)\varepsilon_t$ , mit White-Noise-Prozess  $(\varepsilon_t)$ . Sei  $\tilde{Y}_{t,h}$  die entsprechend angepasste Prognosefunktion auf der Grundlage der optimalen linearen Prognose aus der unendlichen Vergangenheit  $\hat{Y}_{t,h}$ . Dann gilt für  $\varepsilon > 0$  beliebig

$$\lim_{N \rightarrow \infty} \mathbb{P} \left[ \sqrt{N} \left| \tilde{Y}_{t,h} - \hat{Y}_{t,h} \right| > \varepsilon \right] = 0.$$

- Die Anwendung der Prognosefunktion  $\tilde{Y}_{t,h}$  anstatt von  $\hat{Y}_{t,h}$  hat einen vernachlässigbaren Effekt auf die Prognosegüte.

### Literaturhinweise

4.28

Schlittgen und Streitberg (1999), Zeitreihenanalyse: Kapitel 4.1.1, 4.2.1, 4.3.1

Schlittgen (2015), Angewandte Zeitreihenanalyse mit R: Kapitel 5.2

## 4.3 Die exponentielle Glättung

### Die exponentielle Glättung

4.29

Die exponentielle Glättung ist ein Extrapolationsverfahren für die Berechnung von Prognosen. Es basiert auf das Bilden rekursiver Fortschreibungen der Form

$$\hat{y}_{N,1} = (1 - \alpha)\hat{y}_{N-1,1} + \alpha y_N.$$

Durch rekursives Einsetzen der Prognosen erhalten wir die Darstellung als exponentiell gewichtete Summe von Zeitreihenwerten

$$\hat{y}_{N,1} = (1 - \alpha)^{N-1} y_1 + \alpha \sum_{u=0}^{N-2} (1 - \alpha)^u y_{N-u}.$$

Dabei wurde das Verfahren mit  $\hat{y}_{1,1} = y_1$  initialisiert.

### Die exponentielle Glättung

4.30

Alternative Darstellung:

$$\hat{y}_{N,1} = \hat{y}_{N-1,1} + \alpha(y_N - \hat{y}_{N-1,1})$$

Eine neue Prognose wird durch Aufdatierung der letzten Prognose erstellt. Dabei erfolgt eine Korrektur um den letzten Prognosefehler.

#### Literaturhinweise

4.31

Schlittgen (2015), Angewandte Zeitreihenanalyse mit R: Kapitel 5.1

## 4.4 Auswertung von Prognoseergebnissen

### Auswertung von Prognoseergebnissen

4.32

Prognoseverfahren:

- optimale lineare Prognose  $\hat{Y}_{N,h}$  aus der endlichen Vergangenheit  $\{y_1, y_2, \dots, y_N\}$ . Berechnung durch Lösen der Yule-Walker-Gleichungen mit Hilfe des Levinson-Durbin-Algorithmus.
- optimale lineare Prognose  $\hat{Y}_{t,h}$  aus der unendlichen Vergangenheit  $\{y_t, y_{t-1}, y_{t-2} \dots\}$ . Speziell für ARIMA-Modelle kann  $\hat{Y}_{t,h}$  mit Hilfe des Box-Jenkins-Ansatzes berechnet werden.

### Auswertung von Prognoseergebnissen

4.33

Gegeben sei eine Zeitreihe  $(y_t)$  der Länge  $N$ ,  $t \in \{1, 2, \dots, N\}$ . Wir unterscheiden zwischen

- **in-sample Prognose (innerhalb der Stichprobe):** wir schätzen das Zeitreihenmodell (ZR-Modell) aus der Zeitreihe  $(y_t)$  und erstellen Prognosen ebenfalls für  $(y_t)$ .
- **out-of-sample Prognose (außerhalb der Stichprobe):** wir schätzen das ZR-Modell aus der Zeitreihe  $(y_t)$ . Die Prognosen werden für einen unterschiedlichen, zukünftigen Zeitraum  $s \in \{N + 1, N + 2, \dots, N + H\}$  erstellt.

### Auswertung von Prognoseergebnissen

4.34

Gegeben sei eine Zeitreihe  $(y_t)$  der Länge  $N$ . Wir erstellen Prognosen  $(\hat{y}_s)$  für den Prognosezeitraum  $s \in \{N + 1, N + 2, \dots, N + H\}$ . Wir untersuchen die Prognosegüte von  $(\hat{y}_s)$  ex-post, d.h. durch Vergleiche zwischen den Prognosen  $(\hat{y}_s)$  und den tatsächlichen Realisationen  $(y_s)$ .

**Fragestellung 1:** Wir berechnen  $(\hat{y}_s)$ . Wir möchten die Prognosegüte von  $(\hat{y}_s)$  beurteilen.

**Fragestellung 2:** Wir erstellen Prognosen  $(\hat{y}_s^A)$  und  $(\hat{y}_s^B)$  mit zwei unterschiedlichen ZR-Modellen oder zwei unterschiedlichen Prognoseverfahren  $A$  und  $B$ . Wir möchten bestimmen, welches Modell/Verfahren die beste Prognose geliefert hat.

### Auswertung von Prognoseergebnissen ■ Empirische Maßzahlen

4.35

Wir berechnen

- den empirischen mittleren absoluten Prognosefehler

$$\widehat{MAE}(\hat{y}_s) = \frac{1}{H} \sum_{s=N+1}^{N+H} |y_s - \hat{y}_s|$$

- den empirischen mittleren quadratischen Prognosefehler

$$\widehat{MSE}(\hat{y}_s) = \frac{1}{H} \sum_{s=N+1}^{N+H} (y_s - \hat{y}_s)^2.$$

Niedrige Werte dieser empirischen Maßzahlen sprechen für eine gute Prognose  $(\hat{y}_s)$ .

### Auswertung von Prognoseergebnissen ■ Mincer-Zarnowitz-Regression

4.36

Wir führen eine einfache lineare Regression der Realisationen  $(y_s)$  auf die Prognosen  $(\hat{y}_s)$

$$y_s = \beta_0 + \beta_1 \hat{y}_s + u_s, \quad s = N + 1, N + 2, \dots, N + H$$

durch.

- Eine gute Prognose  $(\hat{y}_s)$  ist durch ein hohes Bestimmtheitsmaß  $R^2$  gekennzeichnet.
- Auch können wir einen  $F$ -Test mit den Testhypothesen:

$$H_0 : \beta_0 = 0 \wedge \beta_1 = 1 \quad \text{gegen} \quad H_1 : \beta_0 \neq 0 \vee \beta_1 \neq 1$$

durchführen. Die Beibehaltung der  $H_0$ -Hypothese weist auf eine gute Prognose  $(\hat{y}_s)$  hin.

**Achtung!** Der Störterm  $(u_s)$  ist nicht White-Noise. Dazu noch mehr in Kapitel „Regressionsmodelle für Zeitreihen“.

### Auswertung von Prognoseergebnissen

4.37

Wir betrachten die Prognosen  $(\hat{y}_s^A)$  und  $(\hat{y}_s^B)$  mit zwei unterschiedlichen ZR-Modellen/Prognoseverfahren  $A$  und  $B$ . Wir können die beiden Prognosen bzgl.

- der empirischen Maßzahlen

- der Güte der jeweiligen Mincer-Zarnowitz-Regressionen

miteinander vergleichen.

Diese Resultate werden auf der Grundlage einer Realisation  $(y_s)$  ermittelt und sind dem Zufall überlassen. Neue Realisationen  $(y_s)$  führen möglicherweise zu unterschiedlichen Resultaten. Wir brauchen Methoden, womit wir einen statistisch signifikanten Unterschied zwischen  $(\hat{y}_s^A)$  und  $(\hat{y}_s^B)$  belegen können.

### Auswertung von Prognoseergebnissen ■ Diebold-Mariano-Test

4.38

Wir möchten die Prognosen  $(\hat{y}_s^A)$  und  $(\hat{y}_s^B)$  mit zwei ZR-Modellen/Prognoseverfahren  $A$  und  $B$  bzgl. ihrer Genauigkeit vergleichen. Wir betrachten

- den Abstand zwischen ihren quadrierten Prognosefehlern zum Zeitpunkt  $s$

$$d_s = (y_s - \hat{y}_s^A)^2 - (y_s - \hat{y}_s^B)^2$$

- den Abstand zwischen ihren empirischen  $MSE$ -Werten

$$\begin{aligned} \bar{d} &= \widehat{MSE}(\hat{y}_s^A) - \widehat{MSE}(\hat{y}_s^B) \\ &= \frac{1}{H} \sum_{s=N+1}^{N+H} (y_s - \hat{y}_s^A)^2 - \frac{1}{H} \sum_{s=N+1}^{N+H} (y_s - \hat{y}_s^B)^2. \end{aligned}$$

### Auswertung von Prognoseergebnissen ■ Diebold-Mariano-Test

4.39

**Theorem 48** (Prognosen mit gleicher Prognosegenauigkeit). *Zwei Prognosen  $(\hat{y}_s^A)$  und  $(\hat{y}_s^B)$  haben die gleiche Genauigkeit dann und nur dann wenn*

$$E[d_s] = 0$$

für alle Prognosezeitpunkte  $s$  gilt.

### Auswertung von Prognoseergebnissen ■ Diebold-Mariano-Test

4.40

Testhypothesen:

$$H_0 : E[d_s] = 0 \quad \forall s \quad \text{gegen} \quad H_1 : \exists s \quad E[d_s] \neq 0$$

Teststatistik:

$$\frac{\sqrt{H} \bar{d}}{\sqrt{\hat{\omega}}} \xrightarrow{d} N(0, 1) | H_0$$

mit  $\hat{\omega}$  einem asymptotischen konsistenten Schätzer der Größe  $Var \left[ \sqrt{H} \bar{d} \right]$ .

Testentscheidung:

- Bestimme den kritischen Wert  $\kappa_\alpha$  zu gegebenem  $\alpha \in (0, 1)$ :

$$\kappa_\alpha = z_{1-\frac{\alpha}{2}}.$$

- Lehne  $H_0$  mit Irrtumswahrscheinlichkeit  $\alpha$  ab, falls

$$|z| > \kappa_\alpha.$$

Dann haben die Prognosen  $(\hat{y}_s^A)$  und  $(\hat{y}_s^B)$  unterschiedliche Prognosegenauigkeit (Irrtumswahrscheinlichkeit  $\alpha$ ).