


# Prognoserechnungen

## Problemaspekte

Prof. Dr. Stefan Helber



# Gegenstand von Prognosen

## Beispiele von Prognosen im Operations Management


- Bedarfe
- Preise
- Wartezeiten
- Fahrzeiten
- Standzeiten

# Individuelle Zufälligkeit, kollektive Vorhersehbarkeit I

Beispiel: Anrufaufkommen im Call Center

- Mikromodelle und Aggregation?
- Makromodelle unkoordinierten Verhaltens?

# Individuelle Zufälligkeit, kollektive Vorhersehbarkeit II



# Grundidee von Prognoserechnungen: Stabilität datenerzeugender Prozesse I

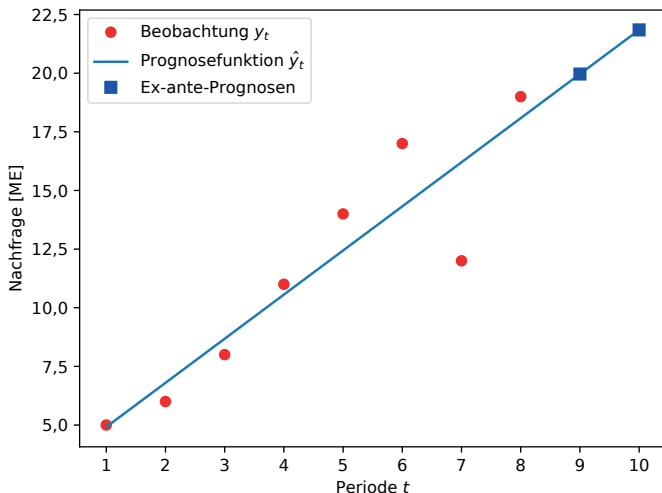
## Annahmen

- 1 Existenz eines **datenerzeugenden Prozesses**
- 2 **Gesetzmäßigkeit** kann **identifiziert** und durch Prognosemodell beschrieben werden
- 3 Prozess ist **stabil**, kein Strukturbruch

## Prognoserechnung

- Ex-post-“Prognose”
- Ex-ante-Prognose


# Grundidee von Prognoserechnungen: Stabilität datenerzeugender Prozesse II



# Prognoserechnungen

## Verwendungszwecke und Voraussetzungen von Prognoserechnungen

Prof. Dr. Stefan Helber



# Verwendungszwecke

## Grundlegende Fragen

- Zweck?
- Genauigkeit?
- Datenbasis?



# Fallkonstellationen

ökonomische  
Bedeutung der  
einzelnen Prognose



Datenbasis



mathematische  
Komplexität der  
Rechnung



Genauigkeit der  
Rechnung



Automatisierungsgrad



Verbreitung in  
der Praxis



einfache  
Prognoserechnung

ausgefeilte  
Prognoserechnung

# Einfache Prognoserechnungen

Lagerhaltung geringwertiger Produkte über

- Bestellmengen und
- Bestellzeitpunkte

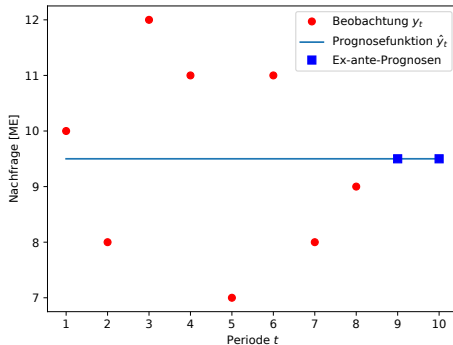
Bedarfsprognose

- computergestützt und automatisiert
- einfache Prognosemethoden
- geringe Anforderungen an die Datenbasis

# Einfache Prognoserechnungen



Beispiel: arithmetische Mittelwerte

$$\hat{y}_{t_a+1} = \hat{y}_{t_a+2} = \dots = \frac{1}{t_a} \sum_{t=1}^{t_a} y_t \quad (1)$$



Vielfach verwendet in der Praxis!

# Ausgefeilte Prognoserechnungen für Energiemärkte



# Ausgefeilte Prognoserechnungen

Datenbasis für das Beispiel der Energiemärkte

- Wetterdaten und -prognosen
- Kalenderdaten
- Verfügbarkeit von Kraftwerken


Instrumente

- Regressionsrechnungen
- Machine-Learning-Methoden
- ...

# Prognoserechnungen

Elementare Prognosemodelle für Zeitreihen mit einem  
näherungsweise konstanten Niveau

Prof. Dr. Stefan Helber



# Zeitreihen mit konstantem Niveau I

## Arithmetischer Mittelwert

$$\hat{y}_{t_a+1} = \frac{1}{t_a} \sum_{t=1}^{t_a} y_t \quad (1)$$

## Gleitender arithmetischer Mittelwert

$$\hat{y}_{t_a+1} = \frac{1}{N} \sum_{t=t_a-N+1}^{t_a} y_t \quad (2)$$

## Exponentielle Glättung 1. Ordnung, Gewichtungsfaktor $\alpha$ mit $0 < \alpha < 1$

$$\hat{y}_{t+1} = \alpha \cdot y_t + (1 - \alpha) \cdot \hat{y}_t \quad (3)$$

# Zeitreihen mit konstantem Niveau II


Exponentielle Glättung 1. Ordnung, Gewichtungsfaktor  $\alpha$  mit  $0 < \alpha < 1$

$$\hat{y}_{t+1} = \alpha \cdot y_t + (1 - \alpha) \cdot \hat{y}_t \quad (4)$$

$$\begin{aligned}\hat{y}_{t+1} &= 0,2 \cdot y_t + 0,8 \cdot \hat{y}_t \\ &= 0,2 \cdot y_t + 0,8 \cdot (0,2 \cdot y_{t-1} + 0,8 \cdot \hat{y}_{t-1}) \\ &= 0,2 \cdot y_t + 0,8 \cdot 0,2 \cdot y_{t-1} + 0,8^2 \cdot \hat{y}_{t-1} \\ &= 0,2 \cdot y_t + 0,8 \cdot 0,2 \cdot y_{t-1} + 0,8^2 \cdot (0,2 \cdot y_{t-2} + 0,8 \cdot \hat{y}_{t-2}) \\ &= 0,2 \cdot y_t + 0,8 \cdot 0,2 \cdot y_{t-1} + 0,8^2 \cdot 0,2 \cdot y_{t-2} + 0,8^3 \cdot \hat{y}_{t-2} \\ &= 0,2 \cdot y_t + 0,8 \cdot 0,2 \cdot y_{t-1} + 0,8^2 \cdot 0,2 \cdot y_{t-2} + 0,8^3 \cdot (0,2 \cdot y_{t-3} + 0,8 \cdot \hat{y}_{t-3}) \\ &= 0,2 \cdot y_t + 0,8 \cdot 0,2 \cdot y_{t-1} + 0,8^2 \cdot 0,2 \cdot y_{t-2} + 0,8^3 \cdot 0,2 \cdot y_{t-3} + 0,8^4 \cdot \hat{y}_{t-3} \\ &= 0,2 \cdot y_t + 0,16 \cdot y_{t-1} + 0,128 \cdot y_{t-2} + 0,1024 \cdot y_{t-3} + 0,4096 \cdot \hat{y}_{t-3} \\ &= \dots\end{aligned}$$



# Beispiel



# Berechnung in Tabellenkalkulation I

|    | A        | B           | C                                | D                         | E                         | F                               | G            | H                           | I                           | J                           |
|----|----------|-------------|----------------------------------|---------------------------|---------------------------|---------------------------------|--------------|-----------------------------|-----------------------------|-----------------------------|
| 1  |          |             | <b>(Gleitende) Durchschnitte</b> |                           |                           | <b>Exp. Glättung 1. Ordnung</b> |              |                             |                             |                             |
| 2  |          |             | <b>Perioden</b>                  | alle                      | 6                         | 3                               | <b>Alpha</b> | 0,1                         | 0,3                         | 0,5                         |
| 3  |          |             |                                  |                           |                           |                                 |              |                             |                             |                             |
| 4  | <i>t</i> | <i>y(t)</i> |                                  | <i>p<sub>gda</sub>(t)</i> | <i>p<sub>gd6</sub>(t)</i> | <i>p<sub>gd3</sub>(t)</i>       |              | <i>p<sub>eg0.1</sub>(t)</i> | <i>p<sub>eg0.3</sub>(t)</i> | <i>p<sub>eg0.5</sub>(t)</i> |
| 5  | 1        | 100         |                                  | NaN                       | NaN                       | NaN                             |              | NaN                         | NaN                         | NaN                         |
| 6  | 2        | 105         |                                  | 100,00                    | NaN                       | NaN                             |              | 100,00                      | 100,00                      | 100,00                      |
| 7  | 3        | 98          |                                  | 102,50                    | NaN                       | NaN                             |              | 100,50                      | 101,50                      | 102,50                      |
| 8  | 4        | 102         |                                  | 101,00                    | NaN                       | 101,00                          |              | 100,25                      | 100,45                      | 100,25                      |
| 9  | 5        | 95          |                                  | 101,25                    | NaN                       | 101,67                          |              | 100,43                      | 100,92                      | 101,13                      |
| 10 | 6        | 130         |                                  | 100,00                    | NaN                       | 98,33                           |              | 99,88                       | 99,14                       | 98,06                       |
| 11 | 7        | 95          |                                  | 105,00                    | 105,00                    | 109,00                          |              | 102,89                      | 108,40                      | 114,03                      |
| 12 | 8        | 103         |                                  | 103,57                    | 104,17                    | 106,67                          |              | 102,10                      | 104,38                      | 104,52                      |
| 13 | 9        | 104         |                                  | 103,50                    | 103,83                    | 109,33                          |              | 102,19                      | 103,97                      | 103,76                      |
| 14 | 10       | 96          |                                  | 103,56                    | 104,83                    | 100,67                          |              | 102,37                      | 103,98                      | 103,88                      |
| 15 | 11       | 99          |                                  | 102,80                    | 103,83                    | 101,00                          |              | 101,74                      | 101,58                      | 99,94                       |
| 16 | 12       | 101         |                                  | 102,45                    | 104,50                    | 99,67                           |              | 101,46                      | 100,81                      | 99,47                       |
| 17 | 13       | 133         |                                  | 102,33                    | 99,67                     | 98,67                           |              | 101,42                      | 100,87                      | 100,23                      |
| 18 | 14       | 125         |                                  | 104,69                    | 106,00                    | 111,00                          |              | 104,58                      | 110,51                      | 116,62                      |
| 19 | 15       | 131         |                                  | 106,14                    | 109,67                    | 119,67                          |              | 106,62                      | 114,85                      | 120,81                      |
| 20 | 16       | 128         |                                  | 107,80                    | 114,17                    | 129,67                          |              | 109,06                      | 119,70                      | 125,90                      |
| 21 | 17       | 124         |                                  | 109,06                    | 119,50                    | 128,00                          |              | 110,95                      | 122,19                      | 126,95                      |
| 22 | 18       | 136         |                                  | 109,94                    | 123,67                    | 127,67                          |              | 112,26                      | 122,73                      | 125,48                      |
| 23 | 19       | 131         |                                  | 111,39                    | 129,50                    | 129,33                          |              | 114,63                      | 126,71                      | 130,74                      |
| 24 | 20       | 129         |                                  | 112,42                    | 129,17                    | 130,33                          |              | 116,27                      | 128,00                      | 130,87                      |

# Berechnung in Tabellenkalkulation II

|    | A        | B           | C               | D                                | E                         | F                         |
|----|----------|-------------|-----------------|----------------------------------|---------------------------|---------------------------|
| 1  |          |             |                 | <b>(Gleitende) Durchschnitte</b> |                           |                           |
| 2  |          |             | <b>Perioden</b> | alle                             | 6                         | 3                         |
| 3  |          |             |                 |                                  |                           |                           |
| 4  | <i>t</i> | <i>y(t)</i> |                 | <i>p<sub>gda</sub>(t)</i>        | <i>p<sub>gd6</sub>(t)</i> | <i>p<sub>gd3</sub>(t)</i> |
| 5  | 1        | 100         |                 | NaN                              | NaN                       | NaN                       |
| 6  | =A5+1    | 105         |                 | =MITTELWERT(\$B\$5:B5)           | NaN                       | NaN                       |
| 7  | =A6+1    | 98          |                 | =MITTELWERT(\$B\$5:B6)           | NaN                       | NaN                       |
| 8  | =A7+1    | 102         |                 | =MITTELWERT(\$B\$5:B7)           | NaN                       | =MITTELWERT(\$B5:\$B7)    |
| 9  | =A8+1    | 95          |                 | =MITTELWERT(\$B\$5:B8)           | NaN                       | =MITTELWERT(\$B6:\$B8)    |
| 10 | =A9+1    | 130         |                 | =MITTELWERT(\$B\$5:B9)           | NaN                       | =MITTELWERT(\$B7:\$B9)    |
| 11 | =A10+1   | 95          |                 | =MITTELWERT(\$B\$5:B10)          | =MITTELWERT(\$B5:\$B10)   | =MITTELWERT(\$B8:\$B10)   |
| 12 | =A11+1   | 103         |                 | =MITTELWERT(\$B\$5:B11)          | =MITTELWERT(\$B6:\$B11)   | =MITTELWERT(\$B9:\$B11)   |
| 13 | =A12+1   | 104         |                 | =MITTELWERT(\$B\$5:B12)          | =MITTELWERT(\$B7:\$B12)   | =MITTELWERT(\$B10:\$B12)  |


# Berechnung in Tabellenkalkulation III

|    | A        | B           | G                               | H                           | I                           | J                           |
|----|----------|-------------|---------------------------------|-----------------------------|-----------------------------|-----------------------------|
| 1  |          |             | <b>Exp. Glättung 1. Ordnung</b> |                             |                             |                             |
| 2  |          |             | <b>Alpha</b> 0,1                |                             | 0,3                         | 0,5                         |
| 3  |          |             |                                 |                             |                             |                             |
| 4  | <i>t</i> | <i>y(t)</i> |                                 | <i>p<sub>eg0.1</sub>(t)</i> | <i>p<sub>eg0.3</sub>(t)</i> | <i>p<sub>eg0.5</sub>(t)</i> |
| 5  | 1        | 100         |                                 | NaN                         | NaN                         | NaN                         |
| 6  | =A5+1    | 105         | =B5                             | =B5                         | =B5                         | =B5                         |
| 7  | =A6+1    | 98          | =H\$2*\$B6+(1-H\$2)*H6          | =I\$2*\$B6+(1-I\$2)*I6      | =J\$2*\$B6+(1-J\$2)*J6      | =J\$2*\$B6+(1-J\$2)*J6      |
| 8  | =A7+1    | 102         | =H\$2*\$B7+(1-H\$2)*H7          | =I\$2*\$B7+(1-I\$2)*I7      | =J\$2*\$B7+(1-J\$2)*J7      | =J\$2*\$B7+(1-J\$2)*J7      |
| 9  | =A8+1    | 95          | =H\$2*\$B8+(1-H\$2)*H8          | =I\$2*\$B8+(1-I\$2)*I8      | =J\$2*\$B8+(1-J\$2)*J8      | =J\$2*\$B8+(1-J\$2)*J8      |
| 10 | =A9+1    | 130         | =H\$2*\$B9+(1-H\$2)*H9          | =I\$2*\$B9+(1-I\$2)*I9      | =J\$2*\$B9+(1-J\$2)*J9      | =J\$2*\$B9+(1-J\$2)*J9      |
| 11 | =A10+1   | 95          | =H\$2*\$B10+(1-H\$2)*H10        | =I\$2*\$B10+(1-I\$2)*I10    | =J\$2*\$B10+(1-J\$2)*J10    | =J\$2*\$B10+(1-J\$2)*J10    |


# Berechnung in Tabellenkalkulation IV

|    | A        | B           | C                                | D                         | E                         | F                               | G            | H                           | I                           | J                           |
|----|----------|-------------|----------------------------------|---------------------------|---------------------------|---------------------------------|--------------|-----------------------------|-----------------------------|-----------------------------|
| 1  |          |             | <b>(Gleitende) Durchschnitte</b> |                           |                           | <b>Exp. Glättung 1. Ordnung</b> |              |                             |                             |                             |
| 2  |          |             | <b>Perioden</b>                  | alle                      | 6                         | 3                               | <b>Alpha</b> | 0,1                         | 0,3                         | 0,5                         |
| 3  |          |             |                                  |                           |                           |                                 |              |                             |                             |                             |
| 4  | <i>t</i> | <i>y(t)</i> |                                  | <i>p<sub>gda</sub>(t)</i> | <i>p<sub>gd6</sub>(t)</i> | <i>p<sub>gd3</sub>(t)</i>       |              | <i>p<sub>eg0.1</sub>(t)</i> | <i>p<sub>eg0.3</sub>(t)</i> | <i>p<sub>eg0.5</sub>(t)</i> |
| 5  | 1        | 100         |                                  | NaN                       | NaN                       | NaN                             |              | NaN                         | NaN                         | NaN                         |
| 6  | 2        | 105         |                                  | 100,00                    | NaN                       | NaN                             |              | 100,00                      | 100,00                      | 100,00                      |
| 7  | 3        | 98          |                                  | 102,50                    | NaN                       | NaN                             |              | 100,50                      | 101,50                      | 102,50                      |
| 8  | 4        | 102         |                                  | 101,00                    | NaN                       | 101,00                          |              | 100,25                      | 100,45                      | 100,25                      |
| 9  | 5        | 95          |                                  | 101,25                    | NaN                       | 101,67                          |              | 100,43                      | 100,92                      | 101,13                      |
| 10 | 6        | 130         |                                  | 100,00                    | NaN                       | 98,33                           |              | 99,88                       | 99,14                       | 98,06                       |
| 11 | 7        | 95          |                                  | 105,00                    | 105,00                    | 109,00                          |              | 102,89                      | 108,40                      | 114,03                      |
| 12 | 8        | 103         |                                  | 103,57                    | 104,17                    | 106,67                          |              | 102,10                      | 104,38                      | 104,52                      |
| 13 | 9        | 104         |                                  | 103,50                    | 103,83                    | 109,33                          |              | 102,19                      | 103,97                      | 103,76                      |
| 14 | 10       | 96          |                                  | 103,56                    | 104,83                    | 100,67                          |              | 102,37                      | 103,98                      | 103,88                      |
| 15 | 11       | 99          |                                  | 102,80                    | 103,83                    | 101,00                          |              | 101,74                      | 101,58                      | 99,94                       |
| 16 | 12       | 101         |                                  | 102,45                    | 104,50                    | 99,67                           |              | 101,46                      | 100,81                      | 99,47                       |
| 17 | 13       | 133         |                                  | 102,33                    | 99,67                     | 98,67                           |              | 101,42                      | 100,87                      | 100,23                      |
| 18 | 14       | 125         |                                  | 104,69                    | 106,00                    | 111,00                          |              | 104,58                      | 110,51                      | 116,62                      |
| 19 | 15       | 131         |                                  | 106,14                    | 109,67                    | 119,67                          |              | 106,62                      | 114,85                      | 120,81                      |
| 20 | 16       | 128         |                                  | 107,80                    | 114,17                    | 129,67                          |              | 109,06                      | 119,70                      | 125,90                      |
| 21 | 17       | 124         |                                  | 109,06                    | 119,50                    | 128,00                          |              | 110,95                      | 122,19                      | 126,95                      |
| 22 | 18       | 136         |                                  | 109,94                    | 123,67                    | 127,67                          |              | 112,26                      | 122,73                      | 125,48                      |
| 23 | 19       | 131         |                                  | 111,39                    | 129,50                    | 129,33                          |              | 114,63                      | 126,71                      | 130,74                      |
| 24 | 20       | 129         |                                  | 112,42                    | 129,17                    | 130,33                          |              | 116,27                      | 128,00                      | 130,87                      |

# Berechnung in Tabellenkalkulation V




# Berechnung in Tabellenkalkulation VI



# Prognoserechnungen

## Konstruktion komplexerer Prognosemodelle mittels Regressionsrechnung

Prof. Dr. Stefan Helber





# Prognosefunktion, Prognosefehler, Verlustfunktion

Datenpunkte  $i = 1, \dots, I$

$$Y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_i \\ \vdots \\ y_I \end{pmatrix} \quad \text{und} \quad X = \begin{pmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \\ \vdots \\ \mathbf{x}_i \\ \vdots \\ \mathbf{x}_I \end{pmatrix} = \begin{pmatrix} x_{1,1} & x_{1,2} & \dots & x_{1,j} & \dots & x_{1,J} \\ x_{2,1} & x_{2,2} & \dots & x_{2,j} & \dots & x_{2,J} \\ \vdots & & \ddots & & & \vdots \\ x_{i,1} & x_{i,2} & \dots & x_{i,j} & \dots & x_{i,J} \\ \vdots & & \ddots & & & \vdots \\ x_{I,1} & x_{I,2} & \dots & x_{I,j} & \dots & x_{I,J} \end{pmatrix} \quad (1)$$

Prognosemodell

$$\hat{y}_i = f(\mathbf{x}_i) = f(x_{i,1}, x_{i,2}, \dots, x_{i,j}, \dots, x_{i,J}) \quad (2)$$

liefert Schätzwert  $\hat{y}_i$

# Beispiel

| Person | Gewicht [kg] | Alter [Jahre] | Größe [cm] | Geschlecht |
|--------|--------------|---------------|------------|------------|
| 1      | 80           | 45            | 185        | m          |
| 2      | 55           | 42            | 170        | w          |
| 3      | 50           | 17            | 172        | w          |
| 4      | 65           | 16            | 180        | m          |

Dummy-Variable für Geschlecht

$$Y = \begin{pmatrix} 80 \\ 55 \\ 50 \\ 65 \end{pmatrix} \quad \text{und} \quad X = \begin{pmatrix} 45 & 185 & 1 & 0 \\ 42 & 170 & 0 & 1 \\ 17 & 172 & 0 & 1 \\ 16 & 180 & 1 & 0 \end{pmatrix} \quad (3)$$

## Beispiel: Zwei Prognosemodelle

$$Y = \begin{pmatrix} 80 \\ 55 \\ 50 \\ 65 \end{pmatrix} \quad \text{und} \quad X = \begin{pmatrix} 45 & 185 & 1 & 0 \\ 42 & 170 & 0 & 1 \\ 17 & 172 & 0 & 1 \\ 16 & 180 & 1 & 0 \end{pmatrix} \quad (4)$$

$$f_A(\mathbf{x}_i) = \hat{y}_i^A = c_1 \cdot x_{i,1} + c_2 \cdot x_{i,2} + c_3 \cdot x_{i,3} + c_4 \cdot x_{i,4} \quad (5)$$

$$f_B(\mathbf{x}_i) = \hat{y}_i^B = c_0 + c_1 \cdot x_{i,1} + c_2 \cdot x_{i,2} + c_3 \cdot x_{i,3} \quad (6)$$

Modelle äquivalent

# Prognosefehler $e_i = y_i - \hat{y}_i$ und Verlustfunktion

- mittlerer quadratischer Fehler, (*Mean Squared Error, MSE*)

$$L^{\text{MSE}} = \frac{1}{I} \sum_{i=1}^I (y_i - \hat{y}_i)^2 \quad (7)$$

Quadratwurzel daraus, (*Root Mean Squared Error, RMSE*)

$$L^{\text{RMSE}} = \sqrt{L^{\text{MSE}}} = \sqrt{\frac{1}{I} \sum_{i=1}^I (y_i - \hat{y}_i)^2}. \quad (8)$$

- mittlerer absolute Fehler, (*Mean Absolute Error, MAE*)

$$L^{\text{MAE}} = \frac{1}{I} \sum_{i=1}^I |y_i - \hat{y}_i|. \quad (9)$$

- mittlerer absoluter prozentuale Fehler, (*Mean Absolute Percentage Error, MAPE*)

$$L^{\text{MAPE}} = \frac{1}{I} \sum_{i=1}^I \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (10)$$

# Konstruktion eines elementaren Prognosemodells I

Schätzfunktion

$$\hat{y}_i = f(\mathbf{x}_i) = f(x_{i,1}, x_{i,2}, \dots, x_{i,j}, \dots, x_{i,J}) = c, \quad (11)$$

Verlustfunktion

$$L^{\text{MSE}} = \frac{1}{I} \sum_{i=1}^I (y_i - \hat{y}_i)^2 = \frac{1}{I} \sum_{i=1}^I (y_i - c)^2 \quad (12)$$

Ableitung der Verlustfunktion  $L^{\text{MSE}}$  nach  $c$

$$\frac{dL^{\text{MSE}}}{dc} = (-2) \frac{1}{I} \sum_{i=1}^I (y_i - c) \stackrel{!}{=} 0 \quad (13)$$

# Konstruktion eines elementaren Prognosemodells II

Nullsetzen und Auflösen


$$c = \frac{1}{I} \sum_{i=1}^I y_i \quad (14)$$

Prognosefunktion jetzt explizit

$$f(\mathbf{x}_i) = c = \frac{1}{I} \sum_{i=1}^I y_i \quad (15)$$

Ermittlung der Koeffizienten mit Software wie `R` oder `Python`

# Trainings- vs. Validierungsdaten, Overfitting I



# Trainings- vs. Validierungsdaten, Overfitting II

Zeit bzw. Polynome der Zeit als erklärende Variable

$$Y = \begin{pmatrix} 7,5 \\ 10,2 \\ 11,3 \\ 11,2 \\ 6,2 \\ 10,8 \\ 8,1 \\ 11,7 \\ 7,2 \\ 9,0 \end{pmatrix} \quad \text{und} \quad X = \begin{pmatrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \\ 7 \\ 8 \\ 9 \\ 10 \end{pmatrix} \quad (16)$$



# Trainings- vs. Validierungsdaten, Overfitting III

lineare Regressionsrechnung für lineares Modell

$$\hat{y}_i^{(1)} = f_1(\mathbf{x}_i) = c_0 + c_1 \cdot x_i \quad (17)$$

mit Trainingsdatensatz

$$\mathbf{y}^{\text{train}} = \begin{pmatrix} 7,5 \\ 10,2 \\ 11,3 \\ 11,2 \\ 6,2 \\ 10,8 \end{pmatrix} \quad \text{und} \quad \mathbf{X}^{\text{train}} = \begin{pmatrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \end{pmatrix}. \quad (18)$$

# Trainings- vs. Validierungsdaten, Overfitting IV

lineare Regression für quadratisches Modell

$$\hat{y}_i^{(2)} = f_2(\mathbf{x}_i) = c_0 + c_1 \cdot x_i + c_2 \cdot x_i^2 \quad (19)$$

mit Trainingsdaten

$$y^{\text{train}} = \begin{pmatrix} 7,5 \\ 10,2 \\ 11,3 \\ 11,2 \\ 6,2 \\ 10,8 \end{pmatrix} \quad \text{und} \quad X^{\text{train}} = \begin{pmatrix} 1 & 1 \\ 2 & 4 \\ 3 & 9 \\ 4 & 16 \\ 5 & 25 \\ 6 & 36 \end{pmatrix} \quad (20)$$

# Trainings- vs. Validierungsdaten, Overfitting V


lineare Regression für kubisches Modell

$$\hat{y}_i^{(3)} = f_3(\mathbf{x}_i) = c_0 + c_1 \cdot x_i + c_2 \cdot x_i^2 + c_3 \cdot x_i^3 \quad (21)$$

mit Trainingsdaten

$$\mathbf{y}^{\text{train}} = \begin{pmatrix} 7,5 \\ 10,2 \\ 11,3 \\ 11,2 \\ 6,2 \\ 10,8 \end{pmatrix} \quad \text{und} \quad \mathbf{X}^{\text{train}} = \begin{pmatrix} 1 & 1 & 1 \\ 2 & 4 & 8 \\ 3 & 9 & 27 \\ 4 & 16 & 64 \\ 5 & 25 & 125 \\ 6 & 36 & 216 \end{pmatrix} \quad (22)$$

# Trainings- vs. Validierungsdaten. Overfitting VI



# Trainings- vs. Validierungsdaten, Overfitting VII

## Ergebnisse der drei Regressionsrechnungen

| Nr. | Schätzfunktion  | Koeffizienten   | RMSE-Train | RMSE-Test |
|-----|---|---|------------|-----------|
| 1   | $\hat{y}_i^{(1)} = c_0 + c_1 \cdot x_i$                                     | $c_0 = 9,09333333$<br>$c_1 = 0,12571429$                            | 1,954      | 2,064     |
| 2   | $\hat{y}_i^{(2)} = c_0 + c_1 \cdot x_i + c_2 \cdot x_i^2$                   | $c_0 = 6,61$<br>$c_1 = 1,98821429$<br>$c_2 = -0,26607143$           | 1,838      | 5,918     |
| 3   | $\hat{y}_i^{(3)} = c_0 + c_1 \cdot x_i + c_2 \cdot x_i^2 + c_3 \cdot x_i^3$ | $c_0 = -3,866$<br>$c_1 = 15,167$<br>$c_2 = -4,631$<br>$c_3 = 0,416$ | 1,230      | 54,305    |


# Beispiel: Besucherprognose im Fitnessstudio

Einflussgrößen der Besucherzahl je Stunde („Kundenstunden“)


- Wochentag
- Stunde des Tages
- Monat
- Feiertag
- Schulferien
- Wetter

Prognose Basis für Personaleinsatzplan, Datenerfassung über Armbänder

# Kundenstunden und Mitgliederbestand




(a) Monatliche Kundenstunden




(b) Mitgliederbestand

# Kundenstunden auf Tages- und Stundenbasis



(a) Kundenstunden auf Tagesbasis



(b) Kundenstunden auf Stundenbasis



# Naives Modell

Regression auf Kundenanzahl und Uhrzeit

$$\hat{y}_i = c_{\text{Anz}} \cdot x_{i,\text{Anz}} + c_{8\text{h}} \cdot x_{i,8\text{h}} + c_{9\text{h}} \cdot x_{i,9\text{h}} + \dots + c_{21\text{h}} \cdot x_{i,21\text{h}} \quad (23)$$

Problem: Schwankungsbreite hängt dann nicht von der Kundenanzahl ab

Alternativer Ansatz: Multiplikative Modelle

# Multiplikatives Modell A I

$$\hat{y}_i^A = x_{i,\text{Anz}}^{c_{\text{Anz}}} \cdot c_{8h}^{x_{i,8h}} \cdot c_{9h}^{x_{i,9h}} \cdot \dots \cdot c_{21h}^{x_{i,21h}} \quad (24)$$

Logarithmieren zur Linearisierung

$$\begin{aligned} \ln(\hat{y}_i^A) &= \ln\left(x_{i,\text{Anz}}^{c_{\text{Anz}}} \cdot c_{8h}^{x_{i,8h}} \cdot c_{9h}^{x_{i,9h}} \cdot \dots \cdot c_{21h}^{x_{i,21h}}\right) \\ &= \ln\left(x_{i,\text{Anz}}^{c_{\text{Anz}}}\right) + \ln\left(c_{8h}^{x_{i,8h}}\right) + \ln\left(c_{9h}^{x_{i,9h}}\right) + \dots + \ln\left(c_{21h}^{x_{i,21h}}\right) \\ &= c_{\text{Anz}} \cdot \ln(x_{i,\text{Anz}}) + \ln(c_{8h}) \cdot x_{i,8h} + \ln(c_{9h}) \cdot x_{i,9h} + \dots + \ln(c_{21h}) \cdot x_{i,21h} \end{aligned} \quad (25)$$


Kurzschreibweise

$$\begin{aligned} \tilde{c}_{8h} &= \ln(c_{8h}) \\ \tilde{c}_{9h} &= \ln(c_{9h}) \\ &\vdots \\ \tilde{c}_{21h} &= \ln(c_{21h}) \end{aligned}$$


lineare Schätzfunktion

$$\ln(\hat{y}_i^A) = c_{\text{Anz}} \cdot \ln(x_{i,\text{Anz}}) + \tilde{c}_{8h} \cdot x_{i,8h} + \tilde{c}_{9h} \cdot x_{i,9h} + \dots + \tilde{c}_{21h} \cdot x_{i,21h} \quad (26)$$

# Multiplikatives Modell A II



(a) Kundenstunden auf Tagesbasis




(b) Kundenstunden auf Stundenbasis


Problem: Alle Wochentage werden gleich behandelt

# Multiplikatives Modell B

$$\ln(\hat{y}_i^B) = c_{\text{Anz}} \cdot \ln(x_{i,\text{Anz}}) + \tilde{C}_{8h} \cdot x_{i,8h} + \tilde{C}_{9h} \cdot x_{i,9h} + \dots + \tilde{C}_{21h} \cdot x_{i,21h} + \tilde{C}_{\text{Mo}} \cdot x_{i,\text{Mo}} + \tilde{C}_{\text{Di}} \cdot x_{i,\text{Di}} + \dots + \tilde{C}_{\text{Sa}} \cdot x_{i,\text{Sa}} + \tilde{C}_{\text{So}} \cdot x_{i,\text{So}} \quad (27)$$



(a) Kundenstunden auf Tagesbasis




(b) Kundenstunden auf Stundenbasis


Problem: Unterschiedliche Muster innerhalb der Wochentage nicht erfasst

# Multiplikatives Modell C

$$\ln(\hat{y}_i^C) = c_{\text{Anz}} \cdot \ln(x_{i,\text{Anz}}) + \tilde{c}_{\text{Mo8h}} \cdot x_{i,\text{Mo8h}} + \tilde{c}_{\text{Mo9h}} \cdot x_{i,\text{Mo9h}} + \dots + \tilde{c}_{\text{So21h}} \cdot x_{i,\text{So21h}} \quad (28)$$



(a) Kundenstunden auf Tagesbasis




(b) Kundenstunden auf Stundenbasis


Problem: Unterschiede der Monate nicht erfasst

# Multiplikatives Modell D

$$\ln(\hat{y}_i^D) = c_{\text{Anz}} \cdot \ln(X_{i,\text{Anz}}) + \tilde{c}_{\text{Mo8h}} \cdot X_{i,\text{Mo8h}} + \tilde{c}_{\text{Mo9h}} \cdot X_{i,\text{Mo9h}} + \dots + \tilde{c}_{\text{So21h}} \cdot X_{i,\text{So21h}} + \tilde{c}_{\text{Jan}} \cdot X_{i,\text{Jan}} + \tilde{c}_{\text{Feb}} \cdot X_{i,\text{Feb}} + \dots + \tilde{c}_{\text{Dez}} \cdot X_{i,\text{Dez}} \quad (29)$$



(a) Kundenstunden auf Tagesbasis




(b) Kundenstunden auf Stundenbasis


Problem: Schulferien und Feiertage nicht erfasst

# Multiplikatives Modell E

$$\ln(\hat{y}_i^E) = c_{\text{Anz}} \cdot \ln(x_{i,\text{Anz}}) + \tilde{c}_{\text{Mo8h}} \cdot x_{i,\text{Mo8h}} + \tilde{c}_{\text{Mo9h}} \cdot x_{i,\text{Mo9h}} + \dots + \tilde{c}_{\text{So21h}} \cdot x_{i,\text{So21h}} + \tilde{c}_{\text{Jan}} \cdot x_{i,\text{Jan}} + \tilde{c}_{\text{Feb}} \cdot x_{i,\text{Feb}} + \dots + \tilde{c}_{\text{Dez}} \cdot x_{i,\text{Dez}} + \tilde{c}_{\text{SFFT}} \cdot x_{i,\text{SFFT}} \quad (30)$$



(a) Kundenstunden auf Tagesbasis



(b) Kundenstunden auf Stundenbasis

# Vergleich der Modelle

| Modell | erklärende Variablen   | RMSE-Train | RMSE-Test |
|--------|--|------------|-----------|
| A      | $X_{i,Anz}, X_{i,8h}, \dots, X_{i,21h}$  | 118,96     | 181,56    |
| B      | $X_{i,Anz}, X_{i,8h}, \dots, X_{i,21h}, X_{i,Mo}, \dots, X_{i,So}$                   | 110,55     | 168,06    |
| C      | $X_{i,Anz}, X_{i,Mo8h}, \dots, X_{i,So21h}$  | 73,14      | 124,98    |
| D      | $X_{i,Anz}, X_{i,Mo8h}, \dots, X_{i,So21h}, X_{i,Jan}, \dots, X_{i,Dez}$             | 55,45      | 65,57     |
| E      | $X_{i,Anz}, X_{i,Mo8h}, \dots, X_{i,So21h}, X_{i,Jan}, \dots, X_{i,Dez}, X_{i,SFFT}$ | 41,80      | 47,77     |

## Erkenntnisse

- Modellbildung sukzessiver Prozess
- Test- oder Validierungsdaten wichtig
- Software wie R oder Python erforderlich
- Statistik-Kenntnisse und Programmierkenntnisse erforderlich