

# Multiple lineare Regression

## Beispiel 1

In einer Umfrage wurden Körpergrösse, Gewicht und Schuhgrösse von erwachsenen Männern ermittelt:

Grösse (cm)	Gewicht (kg)	Schuhgrösse (EU)
183	68	45
171	76	42
196	93	45
175	58	38

*Ziel:* Ein Modell, das es erlaubt, bei erwachsenen Männern die Schuhgrösse aus ihrer Grösse und ihrem Gewicht zu schätzen.

## Begriffe


Jede Tabellenzeile stellt ein *Trainingsbeispiel* dar.

Ein Trainingsbeispiel besteht aus den *Inputvariablen Körpergrösse* und *Gewicht* sowie der *Output- oder Zielvariable Schuhgrösse*.

Das  $i$ -te Trainingsbeispiel wird durch das Paar  $(\mathbf{x}^{(i)}, y^{(i)})$  dargestellt, wobei  $\mathbf{x}^{(i)} = (x_1^{(i)}, x_2^{(i)})$  der Zeilenvektor mit der Körpergrösse  $x_1^{(i)}$ , und dem Gewicht  $x_2^{(i)}$  des  $i$ -ten Mannes ist.

Beachte:

- Variablen in fetter Schrift bezeichnen Vektoren.
- Der Index  $^{(i)}$  ist kein Exponent sondern eine Variable, mit der man die Trainingsbeispiele durchnummeriert.
- $(x^{(2)}, y^{(2)}) =$
- $y^{(4)} =$
- $x_1^{(1)} =$
- $x_2^{(3)} =$



Ein Dach über einer Variable bedeutet, dass der jeweilige Wert eine *Schätzung* des „wahren“ Werts darstellt.

Der Input  $\mathbf{x}$  erhält hier keinen Index, da es sich in der Regel um neue Inputdaten handelt, für die man den jeweiligen Outputwert  $\hat{y}$  schätzen möchte.

Bei der multiplen linearen Regression besteht das Modell aus einer Linearkombination der Inputvariablen. Wenn eine Problemstellung  $d$  Inputvariablen hat, so gilt


$$\hat{y} = h(\mathbf{x}) = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_d x_d = \boldsymbol{\beta}^T \mathbf{x} \quad \text{mit} \quad \boldsymbol{\beta} = \begin{pmatrix} \beta_1 \\ \beta_2 \\ \dots \\ \beta_d \end{pmatrix}$$

Die Zahlen  $\beta_1, \beta_2, \dots, \beta_d$  sind die gesuchten *Modellparameter*.

Um anschaulich zeigen zu können, wie der Vektor  $\boldsymbol{\beta}$  bestimmt wird, verwenden wir ein sehr einfaches Beispiel und kehren danach wieder zum Beispiel 1 zurück.

## Beispiel 2

Welche Ursprungsgerade  $y = \beta x$  passt am besten durch die Punkte  $(8, 7)$  und  $(4, 1)$ ?




Gesucht wird eine Zahl  $\beta$  mit der Eigenschaft

$$\begin{aligned} \beta \cdot 8 &= 7 \\ \beta \cdot 4 &= 1 \end{aligned} \quad \Leftrightarrow \quad \beta \cdot \underbrace{\begin{pmatrix} 8 \\ 4 \end{pmatrix}}_{\mathbf{x}} = \underbrace{\begin{pmatrix} 7 \\ 1 \end{pmatrix}}_{\mathbf{y}}$$

Dieses „Gleichungssystem“ ist nicht erfüllbar. Wir können aber eine Zahl  $\hat{\beta}$  suchen, die eine möglichst gute Näherung für die Lösung darstellt; d. h. für die  $\hat{\beta} \cdot \mathbf{x}$  möglichst nahe bei  $\mathbf{y}$  liegt.

Zur Veranschaulichung stellen wir den Vektor  $\mathbf{x} = (8 \ 4)^T$  mit den  $x$ -Koordinaten und den Vektor  $\mathbf{y} = (7 \ 1)^T$  mit den  $y$ -Koordinaten in einem gemeinsamen Koordinatensystem dar.



Wir suchen jetzt ein  $\hat{\beta}$ , für das  $\hat{\beta}\mathbf{x}$  möglichst nahe bei  $\mathbf{y}$  liegt.


$\hat{\beta}\mathbf{x}$  ist die orthogonale Projektion von  $\mathbf{y}$  auf  $\mathbf{x}$ .

Den Faktor  $\hat{\beta}$  berechnet man bekanntlich mit folgender Formel:

$$\hat{\beta} = \frac{\mathbf{x}^T \mathbf{y}}{\mathbf{x}^T \mathbf{x}} = (\mathbf{x}^T \mathbf{x})^{-1} \mathbf{x}^T \mathbf{y}$$

$$\text{Konkret: } \beta = \left[ (8 \ 4) \begin{pmatrix} 8 \\ 4 \end{pmatrix} \right]^{-1} (8 \ 4) \begin{pmatrix} 7 \\ 1 \end{pmatrix} = \frac{1}{80} \cdot 60 = \frac{3}{4}$$

Im Streudiagramm erhält man folgendes Bild:



### Beispiel 1 (Fortsetzung)

Modell:  $\hat{y} = \beta_1 x_1 + \beta_2 x_2$

Die Werte der Inputvariablen  $x_1$  und  $x_2$  werden in einer Matrix zusammengefasst:

$$\mathbf{X} = \begin{pmatrix} 183 & 68 \\ 171 & 76 \\ 196 & 93 \\ 175 & 58 \end{pmatrix}$$

Ebenso die Werte der Outputvariablen:

$$\mathbf{y} = \begin{pmatrix} 45 \\ 42 \\ 45 \\ 38 \end{pmatrix}$$

## Die Matrixform der Projektionsformel

Um die folgende Formel herleiten zu können, müssten weitere mathematische Voraussetzungen erarbeitet werden, für die uns im Rahmen dieses Kapitels jedoch die Zeit fehlt.

$$\boldsymbol{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

Wie man aber sehen kann, handelt es sich um eine Verallgemeinerung der Formel, die wir zur Lösung von Beispiel 2 verwendet haben.

Damit erhält man für die Daten von Beispiel 1:

$$\boldsymbol{\beta} = \begin{pmatrix} 0.2097 \\ 0.06036 \end{pmatrix} \Rightarrow \hat{y} = 0.2097x_1 + 0.06036x_2$$

## Prognosen

### Das Bestimmtheitsmass

Ohne Herleitung:

$$R^2 = \frac{\boldsymbol{\beta}^T \mathbf{X}^T \mathbf{G} \mathbf{X} \boldsymbol{\beta}}{\mathbf{y}^T \mathbf{G} \mathbf{y}}$$

mit  $G = I_n - \frac{1}{n}(J_n J_n^T)$

$$\text{wobei } I_n = \begin{pmatrix} 1 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & 1 \end{pmatrix} \text{ und } J = \begin{pmatrix} 1 \\ 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix}$$

Die Grösse  $R^2$  drückt aus, wie gut Daten und Modell übereinstimmen.

Für  $R^2$  gilt:  $0 \leq R^2 \leq 1$

Im Gegensatz zur einfachen linearen Regression gibt es bei der multiplen linearen Regression kein Vorzeichen, das angibt, ob der lineare Zusammenhang fallender oder wachsender Natur ist.

Werte von  $R^2$ , die nahe bei 1 liegen, bedeuten einen guten Zusammenhang; Werte, die Nahe bei 0 liegen, bedeuten einen schlechten Zusammenhang.

Im Beispiel 1:  $R^2 = 0.8267$

Das folgende Programm nimmt uns die mühsame Eingabe der obigen Formeln ab.

Da uns der TI-84+ für Matrizen nur die Variablen [A]–[J] zur Verfügung stellt, können wir nicht die in der Literatur üblichen Bezeichnungen gebrauchen und verwenden statt dessen:

$$\mathbf{X} \rightarrow [\mathbf{A}], \mathbf{y} \rightarrow [\mathbf{B}], \boldsymbol{\beta} \rightarrow [\mathbf{C}]$$

Das Programm setzt also voraus, dass die Werte der Inputvariablen in der Matrix [A] und die Werte der Outputvariablen in der Matrix [B] gespeichert sind. Der Vektor  $\boldsymbol{\beta}$  mit den berechnete Modellparametern heisst dann [C].

### Ein Programm für den TI-84+

```
PROGRAM:LSQM
:([A]^T*[A])^-1*[A]^T*[B]→[C]
:dim([A])→L3
:L3(1)→N
:{N,1}→dim([J])
:Fill(1,[J])
:identity(N)-1/N*[J]*[J]^T→[G]
:[C]^T*[A]^T*[G]*[A]*[C]→[D]
:[B]^T*[G]*[B]→[E]
:[D](1,1)/[E](1,1)→R
:Disp [C]
:Disp "R²:",R
```

### Beispiel 1 (Revisited)

Das Modell  $\hat{y} = \beta_1 x_1 + \beta_2 x_2$  kann mit einer Konstanten  $\beta_0$  zu

$$\hat{y} = \beta_0 \cdot 1 + \beta_1 x_1 + \beta_2 x_2$$

erweitert werden. In diesem Fall ist

$$\mathbf{X} = \begin{pmatrix} 1 & 183 & 68 \\ 1 & 171 & 76 \\ 1 & 196 & 93 \\ 1 & 175 & 58 \end{pmatrix}$$

und damit:  $\hat{y} = 15.44x_0 + 0.1087x_1 + 0.09979x_2$

Wegen  $R^2 = 0.5583$  bringt die Aufnahme eines zusätzlichen Parameters keine Verbesserung.

### Beispiel 3

Sophie möchte untersuchen, ob und wie einige ihrer Lebensgewohnheiten ihren Notenerfolg beeinflussen. Deshalb sammelt sie Daten über sich.

Kaffee (#)	Frühstück (0/1)	Lernzeit (h)	Note
2	0	1	4.5
1	1	2	5
0	1	3	5
1	0	2	5.5
2	0	0	3

Lineares Modell:  $\hat{y} = \beta_0 \cdot 1 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \beta_3 \cdot x_3$

$$\mathbf{X} = \begin{pmatrix} 1 & 2 & 0 & 1 \\ 1 & 1 & 1 & 2 \\ 1 & 0 & 1 & 3 \\ 1 & 1 & 0 & 2 \\ 1 & 2 & 0 & 0 \end{pmatrix} \rightarrow [\mathbf{A}]; \mathbf{y} = \begin{pmatrix} 4.5 \\ 5 \\ 5 \\ 5.5 \\ 3 \end{pmatrix} \rightarrow [\mathbf{B}]$$

Welche Modellparameter erhalten wir jetzt mit der Methode der kleinsten Quadrate?

### Prognosen erstellen

Welche Note  $y$  könnte man bei  $x = (2, 0, 2)$  erwarten?

Welche Note  $y$  könnte man bei  $x = (4, 0, 0)$  erwarten?

## Polynomielle Regression

Das oben beschriebene lineare Modell kann zusätzlich um Potenzen der unabhängigen Variablen erweitert werden. Die Gleichung


$$\hat{y} = \beta_0 \cdot 1 + \beta_1 \cdot x_1 + \beta_2 \cdot x_1^2$$

versucht, im Sinne der Methode der kleinsten Quadrate, eine Parabel durch die gegebenen Punkte  $(x^{(i)}, y^{(i)})$  zu legen.

*Achtung:* Auch wenn jetzt Quadrate in der Gleichung auftreten, ist das Modell immer noch *linear*, da es sich um eine *Linearkombination* der unabhängigen Variablen (und allfälliger Potenzen davon) handelt.

### Beispiel 4

Stelle die Punkte  $(2, 2)$ ,  $(4, 5)$ ,  $(7, 6)$ ,  $(10, 4)$  in einem Streudiagramm dar:



$$\text{Modell: } y = \beta_0 \cdot 1 + \beta_1 \cdot x + \beta_2 \cdot x^2$$

$$\begin{pmatrix} \phantom{0} \\ \phantom{0} \\ \phantom{0} \end{pmatrix} \rightarrow [A] \quad \text{und} \quad \begin{pmatrix} \phantom{0} \\ \phantom{0} \\ \phantom{0} \end{pmatrix} \rightarrow [B]$$

LSQM:

### Bemerkung

Je mehr Terme man in das Modell aufnimmt, desto besser kann sich die Kurve den gegebenen Werten anpassen.

$$\text{Modell: } y = \beta_0 \cdot 1 + \beta_1 \cdot x + \beta_2 \cdot x^2 + \beta_3 \cdot x^3$$

$$\begin{pmatrix} \phantom{0} \\ \phantom{0} \\ \phantom{0} \\ \phantom{0} \end{pmatrix} \rightarrow [A] \quad \text{und} \quad \begin{pmatrix} \phantom{0} \\ \phantom{0} \\ \phantom{0} \\ \phantom{0} \end{pmatrix} \rightarrow [B]$$

LSQM:

;

### Was schief gehen kann (Teil 1)

$x_0$	$x_1$	$x_2$	$y$
1	2	4	1
1	3	6	3
1	4	8	4
1	5	10	6

LSQM:

### Was schief gehen kann (Teil 2)

$x_0$	$x_1$	$x_2$	$y$
1	2	4	1
1	3	7	3

LSQM: