

Überbestimmte lineare Gleichungssysteme und lineare Regression

Steffen Solyga*

15. - 19. Juni 2006

Vorgelegt seien m reelle Zahlen y_i und mn reelle Zahlen a_{ij} , $i = 1, 2, \dots, m$, $j = 1, 2, \dots, n$. Gesucht sind n reelle Zahlen x_j , so daß gilt

$$\begin{pmatrix} a_{11} & \dots & a_{1n} \\ \vdots & & \vdots \\ a_{m1} & \dots & a_{mn} \end{pmatrix} \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} y_1 \\ \vdots \\ y_m \end{pmatrix} \quad (1)$$

oder kurz

$$\mathbf{Ax} = \mathbf{y}. \quad (2)$$

Die lineare Algebra lehrt, daß (2) genau dann lösbar ist, wenn der Rang der Matrix \mathbf{A} kleiner oder gleich n ist. Im ersten Falle, $r(\mathbf{A}) < n$, existieren unendlich viele Lösungen \mathbf{x} , und im zweiten Falle, $r(\mathbf{A}) = n$, ist die Lösung \mathbf{x} eindeutig bestimmt. Ist jedoch $r(\mathbf{A}) > n$, was $m > n$ impliziert, ist das System nicht lösbar; man nennt das Gleichungssystem oder \mathbf{x} dann auch überbestimmt.

In diesem Falle kann man aber vielleicht ein \mathbf{x} finden, das (2) wenigstens näherungsweise löst, d.h. den Vektor $\mathbf{y} - \mathbf{Ax}$ möglichst „klein“ macht. Als Maß für die „Größe“ eines m -zeiligen Vektors \mathbf{v} bietet sich das Produkt mit sichselbst an:

$$\mathbf{v}^T \mathbf{v} = v_1^2 + v_2^2 + \dots + v_m^2. \quad (3)$$

Dies ist offenbar ein quadratisches Maß, weshalb man von einer Näherung nach der *Methode der kleinsten Quadrate* spricht. Wir verlangen also, daß

$$f(\mathbf{x}) = (\mathbf{y} - \mathbf{Ax})^T (\mathbf{y} - \mathbf{Ax}) = \mathbf{y}^T \mathbf{y} - 2\mathbf{y}^T \mathbf{Ax} + \mathbf{x}^T \mathbf{A}^T \mathbf{Ax} \quad (4)$$

– eine reellwertige Funktion des variablen Vektors \mathbf{x} – minimal wird. Dann müssen notwendigerweise alle partiellen Ableitungen von f verschwinden

$$\mathbf{grad} f(\mathbf{x}) = -2\mathbf{y}^T \mathbf{A} + 2\mathbf{x}^T \mathbf{A}^T \mathbf{A} = \mathbf{0}^T, \quad (5)$$

und durch Transponieren erhält man daraus das quadratische System

$$\mathbf{A}^T \mathbf{Ax} = \mathbf{A}^T \mathbf{y}. \quad (6)$$

*solyga@gmx.de

Jede geeignete Näherungslösung \mathbf{x} von (2) muß also der Gleichung (6) genügen. Hinreichend für ein Minimum von f ist, daß außerdem die Matrix der zweiten Ableitungen

$$\begin{pmatrix} f_{x_1 x_1} & \cdots & f_{x_1 x_n} \\ \vdots & \ddots & \vdots \\ f_{x_n x_1} & \cdots & f_{x_n x_n} \end{pmatrix} = \mathbf{A}^T \mathbf{A} \quad (7)$$

positiv definit ist. Nun ist $\mathbf{A}^T \mathbf{A}$ sicherlich positiv semidefinit, denn $Q(\mathbf{x}) = \mathbf{x}^T \mathbf{A}^T \mathbf{A} \mathbf{x} = (\mathbf{A} \mathbf{x})^T (\mathbf{A} \mathbf{x})$ kann als Summe von Quadraten für kein \mathbf{x} negativ werden. Eine positiv semidefinite Matrix ist aber genau dann positiv definit, wenn sie regulär ist.¹ D.h. $\mathbf{A}^T \mathbf{A}$ ist genau dann positiv definit, wenn (6) eindeutig lösbar ist, weshalb gilt:

Satz 1 *Besitzt (6) eine eindeutig bestimmte Lösung \mathbf{x} , so handelt es sich dabei gerade um die Näherungslösung von (2) im Sinne der Methode der kleinsten Quadrate.*

Ferner verschwindet $Q(\mathbf{x})$ dann und nur dann, wenn $\mathbf{A} \mathbf{x} = \mathbf{0}$ ist. Folglich ist $\mathbf{A}^T \mathbf{A}$ genau dann regulär, wenn $r(\mathbf{A}) \geq n$ gilt. Damit ergibt sich für die ggf. näherungsweise Lösung von (2) folgendes Bild:

1. Ist $r(\mathbf{A}) < n$, so besitzt (2) beliebig viele (exakte) Lösungen \mathbf{x} . Diese lösen dann natürlich auch (6), was man durch Vormultiplikation von (2) mit \mathbf{A}^T sofort einsieht. Die Lösungsmengen müssen aber nicht identisch sein.
2. Ist $r(\mathbf{A}) = n$, so besitzen (2) und (6) dieselbe (exakte) Lösung \mathbf{x} .
3. Ist $r(\mathbf{A}) > n$, so ist (2) zwar nicht exakt, aber im Sinne der Methode der kleinsten Quadrate näherungsweise lösbar. Die Näherungslösung \mathbf{x} ist als Lösung von (6) eindeutig bestimmt.

Ein Spezialfall der eben besprochenen Ausgleichsrechnung ist die lineare Regression: Gegeben seien zwei n -zeilige Vektoren \mathbf{x} und \mathbf{y} . Gesucht sind reelle Zahlen p und q , so daß

$$f(p, q) = \sum_{i=1}^n [y_i - (px_i + q)]^2 \quad (8)$$

minimal wird. Dazu betrachten wir das aus n Gleichungen bestehende System

$$\begin{pmatrix} x_1 & 1 \\ \vdots & \vdots \\ x_n & 1 \end{pmatrix} \begin{pmatrix} p \\ q \end{pmatrix} = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} \quad (9)$$

oder kurz

$$\mathbf{A} \mathbf{p} = \mathbf{y}. \quad (10)$$

Im Falle $n = 1$ existieren unendlich viele (exakte) Lösungen, und im Falle $n = 2$ existiert eine eindeutig bestimmte Lösung, sofern $x_1 \neq x_2$. Die Ausgleichsrechnung greift im Falle $r(\mathbf{A}) \geq 2$, und zwar erhalten wir die beste Näherungslösung von (10) als Lösung von

$$\mathbf{A}^T \mathbf{A} \mathbf{p} = \mathbf{A}^T \mathbf{y}. \quad (11)$$

¹Beweis: Eine Matrix ist genau dann positiv definit (semidefinit), wenn sie nur positive (nichtnegative) Eigenwerte besitzt (Satz). Andererseits ist eine Matrix genau dann regulär, wenn keiner ihrer Eigenwerte verschwindet (Satz).

Wegen

$$\mathbf{A}^T \mathbf{A} = \begin{pmatrix} x_1 & \dots & x_n \\ 1 & \dots & 1 \end{pmatrix} \begin{pmatrix} x_1 & 1 \\ \vdots & \vdots \\ x_n & 1 \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^n x_i^2 & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & n \end{pmatrix} \quad (12)$$

und

$$\mathbf{A}^T \mathbf{y} = \begin{pmatrix} x_1 & \dots & x_n \\ 1 & \dots & 1 \end{pmatrix} \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^n x_i y_i \\ \sum_{i=1}^n y_i \end{pmatrix} \quad (13)$$

folgt nach der CRAMERSchen Regel

$$\mathbf{p} = \begin{pmatrix} p \\ q \end{pmatrix} = \frac{1}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2} \begin{pmatrix} n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_i^2 \sum_{i=1}^n y_i - \sum_{i=1}^n x_i \sum_{i=1}^n x_i y_i \end{pmatrix}. \quad (14)$$

Mit $n\bar{x} := \sum_{i=1}^n x_i$ und $n\bar{y} := \sum_{i=1}^n y_i$ erhält man daraus die bekannten Formeln

$$p = \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}, \quad (15)$$

$$q = \frac{\bar{y} \sum_{i=1}^n x_i^2 - \bar{x} \sum_{i=1}^n x_i y_i}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}. \quad (16)$$

Literatur

- [1] Karl Brammer; Gerhard Siffing:
Kalman-Bucy-Filter, Deterministische Beobachtung und stochastische Filterung.
R. Oldenbourg Verlag München/Wien 1975
ISBN 3-486-34661-X