

Managing Massive Multiplayer Online Games  
SS 2016

Übungsblatt 7: Knowledge Discovery and Data Mining II

Besprechung: 16.06.2016

**Aufgabe 7-1**     *Lineare Regression*

Der Mietpreis  $y_i$  einer Wohnung  $i$  hängt stark von der Quadratmeterzahl  $x_i$  ab. Andere Faktoren haben natürlich auch Einfluss, aber vereinfachend kann der Zusammenhang zwischen Mietpreis und Größe über ein lineares Regressionsmodell dargestellt werden, d.h.

$$y_i = w_0 + w_1 x_i$$

Als Trainingsmenge stehen folgende Daten zur Verfügung.

Wohnfläche in m <sup>2</sup>	Kaltmiete in Euro
30	600
60	966
100	1640
55	992
93	1790
195	2925
21	469
61	840
62	1400

- (a) Berechnen Sie die Regressionsgerade, die den mittleren quadratischen Fehler MSE zwischen den Mietpreis-Vorhersagen  $\hat{y}_i$  und den tatsächlichen Preisen  $y_i$  minimiert

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2$$

Wir suchen  $w_0, w_1$ , sodass  $f(w_0, w_1) = \sum_{i=1}^n (\hat{y}_i - (w_0 + w_1 x_i))^2$  minimal wird.

$$\frac{\partial f}{\partial w_0} \sum_{i=1}^n (\hat{y}_i - (w_0 + w_1 x_i))^2 = -2 \sum_{i=1}^n (y_i - (w_0 + w_1 x_i))$$

$$\frac{\partial f}{\partial w_1} \sum_{i=1}^n (\hat{y}_i - (w_0 + w_1 x_i))^2 = -2 \sum_{i=1}^n x_i (y_i - (w_0 + w_1 x_i))$$

Erstere Gleichung lässt sich leicht berechnen:

$$\begin{aligned} \sum_{i=1}^n (y_i - (w_0 + w_1 x_i)) &= 0 \Leftrightarrow -n w_0 + \sum_{i=1}^n y_i - w_1 \sum_{i=1}^n x_i = 0 \\ &\Leftrightarrow w_0 = \bar{y} - w_1 \bar{x} \end{aligned}$$

Zweitere Gleichung lässt sich nur umständlich über ein System von Normalgleichungen unter Verwendung geometrischer Eigenschaften (Hesse-Matrix) berechnen.

Die optimalen Gewichte  $w_0$  und  $w_1$  lassen sich deutlich einfacher über die Matrix-Darstellung berechnen. Dazu sei  $w = (w_0, w_1)^T$ ,  $y$  der Output-Vektor der Trainingsdaten (Mietpreis) und  $x$  der um eine konstante 1-Spalte erweiterte Input-Vektor (Wohnfläche):

$$\begin{pmatrix} 1 & 30 \\ 1 & 60 \\ \vdots & \\ 1 & 62 \end{pmatrix}$$

also eine  $9 \times 2$  Matrix (die Einsen werden für die Multiplikation mit  $w_0$  benötigt:  $y = 1w_0 + xw_1$ ). Dann lässt sich die Fehlerfunktion als Skalarprodukt schreiben:  $f(w) = (y - Xw)^T(y - Xw)$ . Es gilt:

$$\frac{\partial f(w)}{\partial w} = -2X^T(y - Xw)$$

da nach Matrixableitung  $\frac{\partial Ax}{\partial x} = A^T$ .

Aufgelöst nach  $w$ :

$$w = (X^T X)^{-1} X^T y$$

Falls  $X^T X$  nicht invertierbar, addiere  $\varepsilon > 0$  auf  $X$ . Also ergibt sich hier  $w_0 = 213,10$  und  $w_1 = 14,33$ .

- (b) Bestimmen Sie den quadratischen Fehler, um abzuschätzen wie gut das Modell den Zusammenhang beschreibt.

$$\sum (\hat{y}_i - y_i)^2 = 232051$$

MSE: 25783. MAE: 120.

- (c) Berechnen Sie mithilfe der Regressionsgeraden den vorraussichtlichen Preis für eine Wohnung mit 120 Quadratmetern Fläche.

$$\hat{y} = w_0 + w_1 120 = 1932.$$

