

## VL6: Die Methode der kleinsten Quadrate bei $p$ Regressoren, Teil2 und Anwendungsbeispiel: Fourierreihenentwicklung

Letztes Mal hatten wir das folgende Theorem bewiesen:

**Theorem 5.2:** Gegeben seien die Datenvektoren  $\vec{y} \in \mathbb{R}^n$  und  $\vec{x}_0, \vec{x}_1, \dots, \vec{x}_p \in \mathbb{R}^n$  mit  $n \geq p + 1$  wobei die  $p + 1$  Regressoren  $\vec{x}_0, \vec{x}_1, \dots, \vec{x}_p$  linear unabhängig seien, die Matrix der Regressoren

$$X := \begin{pmatrix} | & | & \cdots & | \\ \vec{x}_0 & \vec{x}_1 & & \vec{x}_p \\ | & | & & | \end{pmatrix} \in \mathbb{R}^{n \times (p+1)} \quad (1)$$

habe also maximalen Rang. Wir betrachten das Minimierungsproblem

$$\begin{aligned} F(\vec{\beta}) &= F(\beta_0, \beta_1, \dots, \beta_p) = \|\vec{y} - (\beta_0 \vec{x}_0 + \beta_1 \vec{x}_1 + \dots + \beta_p \vec{x}_p)\|^2 \\ &= \|\vec{y} - X\vec{\beta}\|^2 \stackrel{!}{\rightarrow} \min \end{aligned}$$

Dann gilt: Das  $F$  wird durch die folgende Wahl der beta's minimiert,

$$\vec{\beta}_{\min} = (X^T X)^{-1} X^T \vec{y}$$

und die beste Approximation an das  $\vec{y}$ , der Regression-Fit  $\vec{y}_{\min} := X\vec{\beta}_{\min}$ , ist gegeben durch

$$\vec{y}_{\min} = P_X \vec{y}$$

mit der linearen Abbildung

$$\begin{aligned} P_X &: \mathbb{R}^n \rightarrow \mathbb{R}^n, \\ P_X &= X(X^T X)^{-1} X^T. \end{aligned}$$

Betrachten wir den  $p + 1$  dimensionalen linearen Unterraum im  $\mathbb{R}^n$ , der durch die  $p + 1$  Regressoren  $\vec{x}_0, \vec{x}_1, \dots, \vec{x}_p$  aufgespannt wird,

$$L_X := \left\{ \sum_{j=0}^p \lambda_j \vec{x}_j \mid \lambda_0, \lambda_1, \dots, \lambda_p \in \mathbb{R} \right\} \subset \mathbb{R}^n \quad (2)$$

Dann gilt das folgende

**Theorem 6.1 (Geometrische Interpretation):** Es sei  $X$  die Matrix der Regressoren gegeben durch (1) und  $L_X$  der von den Regressoren aufgespannte lineare Unterraum im  $\mathbb{R}^n$ . Weiter sei

$$\begin{aligned} P_X &: \mathbb{R}^n \rightarrow \mathbb{R}^n, \\ P_X &= X(X^T X)^{-1} X^T. \end{aligned} \quad (3)$$

Dann gilt: Das  $P_X$  ist die orthogonale Projektion auf  $L_X$  und

$$P_{X^\perp} := Id - P_X \quad (4)$$

ist die orthogonale Projektion auf das orthogonale Komplement von  $L_X$ . Genauer gelten die folgenden Eigenschaften:

- a)  $P_X \vec{x}_j = \vec{x}_j \quad \forall j = 0, \dots, p$
- b)  $P_X^2 = P_X$
- c)  $P_X^T = P_X$
- d)  $P_X P_{X^\perp} = P_{X^\perp} P_X = 0$

**Beweis:** a) Wir haben

$$X^T \vec{x}_j = \begin{pmatrix} - & \vec{x}_0 & - \\ - & \vec{x}_1 & - \\ & \vdots & \\ - & \vec{x}_p & - \end{pmatrix} \begin{pmatrix} | \\ \vec{x}_j \\ | \end{pmatrix} = \begin{pmatrix} \vec{x}_0 \vec{x}_j \\ \vec{x}_1 \vec{x}_j \\ \vdots \\ \vec{x}_p \vec{x}_j \end{pmatrix} = (X^T X)_{j\text{-te Spalte}}$$

Damit bekommen wir, wenn  $Id_{p+1}$  die  $p+1$  dimensionale Einheitsmatrix bezeichnet,

$$\begin{aligned} (X^T X)^{-1} X^T \vec{x}_j &= (X^T X)^{-1} (X^T X)_{j\text{-te Spalte}} \\ &= (Id_{p+1})_{j\text{-te Spalte}} \\ &= (\delta_{i,j})_{i=0}^p \end{aligned}$$

und damit

$$\begin{aligned} P_X \vec{x}_j &= X(X^T X)^{-1} X^T \vec{x}_j \\ &= X(\delta_{i,j})_{i=0}^p \\ &= \begin{pmatrix} | & | & \cdots & | \\ \vec{x}_0 & \vec{x}_1 & & \vec{x}_p \\ | & | & & | \end{pmatrix} (\delta_{i,j})_{i=0}^p = \begin{pmatrix} | \\ \vec{x}_j \\ | \end{pmatrix} = \vec{x}_j \end{aligned}$$

b) Wir haben

$$\begin{aligned} P_X^2 &= X(X^T X)^{-1} X^T X(X^T X)^{-1} X^T \\ &= X(X^T X)^{-1} \underbrace{X^T X(X^T X)^{-1}}_{=Id} X^T \\ &= X(X^T X)^{-1} X^T = P_X \end{aligned}$$

c) Es gilt

$$\begin{aligned} P_X^T &= [X(X^T X)^{-1} X^T]^T \\ &= (X^T)^T [(X^T X)^{-1}]^T X^T \\ &= X [(X^T X)^T]^{-1} X^T \\ &= X [X^T X]^{-1} X^T = P_X \end{aligned}$$

d) Schliesslich, mit  $P_X^2 = P_X$ ,

$$P_{X^\perp} P_X = (Id - P_X) P_X = P_X - P_X^2 = P_X - P_X = 0$$

und  $P_X P_{X^\perp} = 0$  mit einer analogen Rechnung. Damit können wir für jedes  $\vec{y} \in \mathbb{R}^n$  schreiben

$$\begin{aligned} \vec{y} &= Id \vec{y} \\ &= P_X \vec{y} + (Id - P_X) \vec{y} \\ &=: \vec{y}_1 + \vec{y}_2 \end{aligned}$$

mit  $\vec{y}_1 \cdot \vec{y}_2 = 0$  und  $\vec{y}_1 \in L_X$ ,  $\vec{y}_2 \in L_{X^\perp}$ . Damit ist das Theorem bewiesen. ■

## Anwendungsbeispiel: Fourierreihenentwicklung

Erinnerung Fourierreihen: Jede integrierbare Funktion<sup>1</sup>

$$f : [-\pi, +\pi] \rightarrow \mathbb{R}$$

kann man in eine Fourierreihe entwickeln:

$$f(x) = \frac{a_0}{2} + \sum_{k=1}^{\infty} \{ a_k \cos kx + b_k \sin kx \} \quad (5)$$

mit den Entwicklungskoeffizienten

$$a_k = \frac{1}{\pi} \int_{-\pi}^{\pi} f(x) \cos kx \, dx, \quad k = 0, 1, 2, \dots \quad (6)$$

$$b_k = \frac{1}{\pi} \int_{-\pi}^{\pi} f(x) \sin kx \, dx, \quad k = 1, 2, \dots \quad (7)$$

---

<sup>1</sup>das kann auch ein anderes Intervall sein, wir nehmen der Einfachheit halber  $[-\pi, \pi]$

Dabei bilden die Funktionen

$$1, \cos x, \cos 2x, \cos 3x, \dots \\ \sin x, \sin 2x, \sin 3x, \dots$$

eine Orthogonalbasis von  $L^2([- \pi, \pi])$ , das ist die Menge der quadrat-integrablen Funktionen auf dem Intervall  $[- \pi, \pi]$ . Genauer gelten die folgenden Orthogonalitätsrelationen, die folgenden Integrale:

$$\int_{-\pi}^{\pi} \cos \ell x \cos m x \, dx = \pi \delta_{\ell, m} \\ \int_{-\pi}^{\pi} \sin \ell x \sin m x \, dx = \pi \delta_{\ell, m}$$

und

$$\int_{-\pi}^{\pi} \cos \ell x \sin m x \, dx = 0$$

mit natürlichen Zahlen  $\ell$  und  $m$ .

Formulierung als Regressionsproblem: Es sei jetzt

$$f : [-\pi, +\pi] \rightarrow \mathbb{R}$$

eine gegebene Funktion. Wir diskretisieren das Intervall  $[-\pi, \pi]$  mit Schrittweite  $\Delta x$ :

$$-\pi =: x_0, x_1 = x_0 + \Delta x, x_2 = x_0 + 2\Delta x, \dots, x_n = x_0 + n\Delta x = +\pi$$

mit

$$\Delta x = \frac{+\pi - (-\pi)}{n} = \frac{2\pi}{n}$$

Unser Datenvektor  $\vec{y}$  ist dann

$$\vec{y} = \begin{pmatrix} f(x_0) \\ \vdots \\ f(x_n) \end{pmatrix} \in \mathbb{R}^{n+1}$$

und die Regressoren sind gegeben durch

$$\begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}, \begin{pmatrix} \cos x_0 \\ \vdots \\ \cos x_n \end{pmatrix}, \begin{pmatrix} \cos 2x_0 \\ \vdots \\ \cos 2x_n \end{pmatrix}, \dots, \begin{pmatrix} \cos px_0 \\ \vdots \\ \cos px_n \end{pmatrix}$$

und

$$\begin{pmatrix} \sin x_0 \\ \vdots \\ \sin x_n \end{pmatrix}, \begin{pmatrix} \sin 2x_0 \\ \vdots \\ \sin 2x_n \end{pmatrix}, \dots, \begin{pmatrix} \sin px_0 \\ \vdots \\ \sin px_n \end{pmatrix}$$

Definieren wir etwa die Matrizen

$$X_{\cos} := \begin{pmatrix} | & | & \cdots & | \\ \cos x_i & \cos 2x_i & \cdots & \cos px_i \\ | & | & & | \end{pmatrix} \in \mathbb{R}^{(n+1) \times p}$$

$$X_{\sin} := \begin{pmatrix} | & | & \cdots & | \\ \sin x_i & \sin 2x_i & \cdots & \sin px_i \\ | & | & & | \end{pmatrix} \in \mathbb{R}^{(n+1) \times p}$$

dann ist die Fourierreihenentwicklung (5), wenn wir sie nach  $p$  Termen abbrechen,

$$f(x) = \frac{a_0}{2} + \sum_{k=1}^p \{ a_k \cos kx + b_k \sin kx \} + \text{error} \quad (8)$$

äquivalent zu

$$\begin{pmatrix} | \\ f(x_i) \\ | \end{pmatrix} = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} \frac{a_0}{2} + X_{\cos} \begin{pmatrix} a_1 \\ \vdots \\ a_p \end{pmatrix} + X_{\sin} \begin{pmatrix} b_1 \\ \vdots \\ b_p \end{pmatrix} + \text{error} \quad (9)$$

$$\Leftrightarrow \vec{y} = X\vec{\beta} + \text{error}$$

mit der Matrix  $X$  der Regressoren gegeben durch, mit  $\vec{x}_0 = (1, 1, \dots, 1) \in \mathbb{R}^{n+1}$ ,

$$X := \begin{pmatrix} \vec{x}_0 & X_{\cos} & X_{\sin} \end{pmatrix} \in \mathbb{R}^{(n+1) \times (2p+1)}$$

und den Regressionskoeffizienten

$$\vec{\beta} := (a_0/2, a_1, a_2, \dots, a_p, b_1, b_2, \dots, b_p) \in \mathbb{R}^{2p+1}$$

Mit Hilfe des `lm()`-Befehls aus der R-Software lassen sich die Regressionskoeffizienten dann sehr einfach bestimmen.

→ Start R-Session.

Schauen wir uns noch an, wie die allgemeine Formel für die beta's in diesem Fall konkret aussieht: Wir hatten

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

mit

$$X^T X = (\vec{x}_\ell \cdot \vec{x}_m)$$

gegeben durch die Skalarprodukte der Regressoren. Betrachten wir der Einfachheit halber etwa eine reine Sinus-Entwicklung so dass  $X = X_{\sin}$ . Dann haben wir etwa, wenn  $X_{\sin,\ell}$  die  $\ell$ 'te Spalte der Regressionsmatrix bezeichnet,

$$\begin{aligned} X_{\sin,\ell} \cdot X_{\sin,m} &= \sum_{i=0}^n \sin \ell x_i \sin m x_i \\ &= \frac{1}{\Delta x} \Delta x \sum_{i=0}^n \sin \ell x_i \sin m x_i \\ &\approx \frac{1}{\Delta x} \int_{-\pi}^{\pi} \sin \ell x \sin m x dx \\ &= \frac{\pi}{\Delta x} \delta_{\ell,m} \end{aligned}$$

Also haben wir, bei einer reinen Sinus-Entwicklung,

$$X^T X \approx \frac{\pi}{\Delta x} Id$$

und damit

$$(X^T X)^{-1} \approx \frac{\Delta x}{\pi} Id$$

Weiterhin ist

$$X^T \vec{y} = \begin{pmatrix} | \\ \vec{x}_\ell \cdot \vec{y} \\ | \end{pmatrix}$$

mit

$$\begin{aligned} \vec{x}_\ell \cdot \vec{y} &= X_{\sin,\ell} \cdot \begin{pmatrix} | \\ f(x_i) \\ | \end{pmatrix} = \sum_{i=0}^n \sin(\ell x_i) f(x_i) \\ &\approx \frac{1}{\Delta x} \int_{-\pi}^{\pi} \sin(\ell x) f(x) dx \\ &\stackrel{(\tau)}{=} \frac{\pi}{\Delta x} b_\ell \end{aligned}$$

Also liefert die allgemeine Formel für die Regressionskoeffizienten in diesem konkreten Fall

$$\begin{aligned} \vec{\beta} &= (X^T X)^{-1} X^T \vec{y} \\ &\approx \frac{\Delta x}{\pi} Id \frac{\pi}{\Delta x} \begin{pmatrix} | \\ b_\ell \\ | \end{pmatrix} \\ &= \begin{pmatrix} b_1 \\ \vdots \\ b_p \end{pmatrix} \end{aligned}$$

und wir erhalten genau die Entwicklungskoeffizienten der Fourierreihenentwicklung.