

3 Lineare Ausgleichsrechnung

(3.1) Lemma (Givensrotation)

Zu $x \in \mathbb{R}^N$ mit $x[k]^2 + x[n]^2 > 0$ für $k \neq n, k, n \in \{1, \dots, N\}$, existiert eine Givensrotation

$$Q = c(e_k e_k^T + e_n e_n^T) + s(e_k e_n^T - e_n e_k^T) + \sum_{j \neq k, n} e_j e_j^T$$

mit $c^2 + s^2 = 1$ und $(Qx)[n] = 0$.

Es gilt $QQ^T = I_N$, also ist Q orthogonal.

Beweis. Aus $y = Qx$ folgt

$$y[i] = \begin{cases} x[i] & i \neq m, n \\ cx[m] + sx[n] & i = m \\ -sx[m] + cx[n] & i = n \end{cases}$$

Soll nun $y[n] = -sx[m] + cx[n] = 0$ gelten, dann folgt $sx[m] = cx[n]$. Zur stabilen Berechnung von c, s müssen wir Auslöschung vermeiden, also unterscheiden wir zwei Fälle:

Fall 1: Für $|x[n]| > |x[k]|$ setze $\tau = \frac{x[k]}{x[n]} = \frac{c}{s}$. Dann gilt

$$\tau^2 = \frac{c^2}{s^2} = \frac{c^2 + s^2 - s^2}{s^2} = \frac{1 - s^2}{s^2} = \frac{1}{s^2} - 1 \quad \implies \quad s = \frac{1}{\sqrt{1 + \tau^2}}, \quad c = \tau s.$$

Fall 2: Für $|x[n]| \leq |x[k]|$ setze $\tau = \frac{x[n]}{x[k]} = \frac{s}{c}$. Dann gilt

$$\tau^2 = \frac{s^2}{c^2} = \frac{s^2 + c^2 - c^2}{c^2} = \frac{1 - c^2}{c^2} = \frac{1}{c^2} - 1 \quad \implies \quad c = \frac{1}{\sqrt{1 + \tau^2}}, \quad s = \tau c.$$

□

Eine Givensrotation beschreibt eine Drehung um den Winkel φ mit $(s, c) = (\sin \varphi, \cos \varphi)$ in der Ebene, die von e_m und e_n aufgespannt wird.

(3.2) Lemma (Householdertransformation)

Zu $x \in \mathbb{R}^N, x \neq 0$, existiert eine orthogonale Matrix $Q = I_N - \beta ww^T \in \mathbb{R}^{N \times N}$ mit $\beta = \frac{2}{w^T w}$, $w[1] = 1$ und $Qx = \sigma e_1, |\sigma| = |x|_2$.

Beweis. $Q = I_N - \beta ww^T$ ist orthogonal, es gilt also

$$\begin{aligned} I_N &= Q^T Q = Q^2 = (I_N - \beta ww^T)(I_N - \beta ww^T) \\ &= I_N - 2\beta ww^T + \beta^2 ww^T ww^T \\ &= I_N + \beta(-2 + \beta^2 ww^T)ww^T, \end{aligned}$$

d.h. es ist $\beta = 0$ oder $\beta = \frac{2}{w^T w}$. Es gilt $Qx = x - \beta^2 ww^T x = x - (\beta^2 w^T x)w$ und $|Qx|_2^2 = |x|_2^2$. Aus $Qx = \sigma e_1$ folgt $|\sigma| = |x|_2$. Weiterhin folgt aus $\sigma e_1 = x - (\beta^2 w^T x)w$

$$\sigma = \sigma e_1[1] = x[1] - \beta w^T x,$$

d.h. $\beta w^T x = \sigma - x[1]$ und $w = \frac{1}{x[1] - \sigma}(x - \sigma e_1)$.

Zur Vermeidung von Auslöschung betrachte zwei Fälle:

1. Fall: Für $x[1] > 0$ wähle $\sigma = -|x|_2$, d.h. $w = \frac{1}{x[1] + |x|_2}(x + |x|_2 e_1)$.
2. Fall: Für $x[1] \leq 0$ wähle $\sigma = |x|_2$, d.h. $w = \frac{1}{x[1] - |x|_2}(x - |x|_2 e_1)$.

□

(3.3) Satz (QR-Zerlegung)

Sei $A \in \mathbb{R}^{K \times N}$. Dann existiert eine orthogonale Matrix $Q \in \mathbb{R}^{K \times K}$ und eine obere Dreiecksmatrix $R \in \mathbb{R}^{K \times N}$ mit $A = QR$.

Beweis. Wir führen eine Induktion über N durch. Für $N = 1$ folgt sofort $Q = 1$, $R = A$.

$N > 1$: Setze $x = A[1 : K, 1] \in \mathbb{R}^K$. Wir unterscheiden zwei Fälle:

1. Fall: $x[2 : K] = 0_{K-1}$

Setze $Q_1 = I_N$ und $\sigma = A[1, 1]$.

2. Fall: $x[2 : K] \neq 0_{K-1}$. Setze

$$\sigma = \begin{cases} -|x|_2 & x[1] > 0, \\ |x|_2 & x[1] \leq 0, \end{cases} \quad w \in \mathbb{R}^N \text{ mit } w[1] = 1, w = \frac{1}{x[1] - \sigma} x[2 : K],$$

$$Q_1 = I_N - \frac{2}{w^T w} w w^T.$$

Damit gilt

$$Q_1 A = \begin{pmatrix} \sigma & R_1[1, 2 : N] \\ 0_{M-1} & A_2 \end{pmatrix},$$

mit

$$R_1[1, 2 : N] = Q_1[1, 1 : K] A[1 : K, 2 : N] \in \mathbb{R}^{1 \times N-1}$$

und

$$A_2 = Q_1[2 : K, 1 : K] A[1 : K, 2 : K] \in \mathbb{R}^{K-1 \times N-1}.$$

Nun sei $A_2 = Q_2 R_2 \in \mathbb{R}^{K-1, N-1}$ eine QR-Zerlegung der Restmatrix. Also

$$\begin{aligned} A &= Q_1 \begin{pmatrix} \sigma & R_1[1, 2 : N] \\ 0_{K-1} & Q_2 R_2 \end{pmatrix} \\ &= \underbrace{Q_1 \begin{pmatrix} 1 & 0_{K-1}^T \\ 0_{K-1} & Q_2 \end{pmatrix}}_{=: Q} \underbrace{\begin{pmatrix} \sigma & R_1[1, 2 : N] \\ 0_{K-1} & R_2 \end{pmatrix}}_{=: R} \end{aligned}$$

□

Bemerkung (Aufwand)

Zählt man alle Operationen zur Lösung des LGS $Ax = b$ zusammen, so erhält man den Aufwand der Verfahren (nur die Terme mit höchstem Exponenten):

$$QR\text{-Zerlegung} : \quad \frac{4}{3} N^3 \text{ Operationen,}$$

$$LR\text{-Zerlegung} : \quad \frac{2}{3} N^3 \text{ Operationen,}$$

$$LL^T\text{-Zerlegung} : \quad \frac{1}{3} N^3 \text{ Operationen.}$$

Wir betrachten die folgenden Spezialfälle:

1. $K = N$, A regulär:

Es gilt $0 \neq \det A = \det Q \det R$, also ist $0 \neq \det R = \prod_{n=1}^N R[n, n]$, woraus $R[n, n] \neq 0$, $n = 1, \dots, N$, folgt.

Eine Lösung von $Ax = b$ berechnet sich wie folgt: Aus $Q^T Ax = Q^T QRx = Q^T b$ folgt $Rx = Q^T b$; $x = R^{-1}(Q^T b)$ ist mit Rückwärtssubstitution in $O(N^2)$ Operationen lösbar.

2. $K > N$, $\text{rang}(A) = N$

Es existiert eine QR-Zerlegung $A = QR$ mit

$$R = \begin{pmatrix} R[1 : N, 1 : N] \\ 0 \end{pmatrix}$$

Dann gilt:

$$\begin{aligned} Ax = b \text{ ist lösbar} &\iff Rx = Q^T b = y \text{ ist lösbar} \\ &\iff y[N+1 : K] = 0_{K-N} \end{aligned}$$

3. $K < N$, $\text{rang}(A) = K$:

Es existiert eine Permutationsmatrix P mit $AP = QR$ mit $R = \begin{pmatrix} R[1 : K, 1 : K] & R[1 : K, K+1 : N] \\ R_1 & R_2 \end{pmatrix}$. Dann gilt:

$$Ax = b \iff AP \underbrace{P^T x}_{=:z} = b \iff QRz = b \iff Rz = Q^T b =: y$$

Die spezielle Lösung ist $z[1 : K] = R_1^{-1} y[1 : K]$. Für die allgemeine Lösung wähle $z[K+1 : N] \in \mathbb{R}^{N-K}$, dann folgt $z[1 : K] = R_1^{-1}(b - R_2 z[K+1 : N])$

Im Allgemeinen ist das lineare Gleichungssystem $Ax = b$ für $b \in \mathbb{R}^K$ und $A \in \mathbb{R}^{K \times N}$ nicht oder nicht eindeutig lösbar. Stattdessen untersuchen wir nun das Minimierungsproblem:

$$\text{Bestimme } x \in \mathbb{R}^N \text{ mit } |Ax - b|_2 = \text{Min!}$$

(3.4) Satz

Sei $A \in \mathbb{R}^{K \times N}$, $b \in \mathbb{R}^K$. Dann ist äquivalent:

(a) $|Ax - b|_2 \leq |Ay - b|_2 \quad \forall y \in \mathbb{R}^N$

(b) $x \in \mathbb{R}^N$ löst die Normalengleichung $A^T Ax = A^T b$.

Beweis. Betrachte

$$\begin{aligned} F(x) &= \frac{1}{2} |Ax - b|_2^2 \\ &= \frac{1}{2} (Ax - b)^T (Ax - b) \\ &= \frac{1}{2} x^T A^T Ax - \frac{1}{2} b^T Ax - \frac{1}{2} (Ax)^T b + \frac{1}{2} b^T b \end{aligned}$$

Algorithmus 4 Berechnung einer QR-Zerlegung und Lösung eines Gleichungssystems.

```
function x = qr_solve(A,b)
[M,N] = size(A);
for m = 1:min(N,M-1)
    [v,beta] = householder(A(m:M,m));
    if beta ~= 0
        w = beta * v' * A(m:M,m:N);
        A(m:M,m:N) = A(m:M,m:N) - v * w;
        A(m+1:M,m) = v(2:M-m+1);
    end
end
for m = 1:min(N,M-1)
    v = [1;A(m+1:M,m)];
    beta = 2 / (v' * v);
    if beta ~= 2
        b(m:M) = b(m:M) - beta*(v' * b(m:M)) * v;
    end
end
x = zeros(N,1);
for n=min(N,M):-1:1
    x(n) = (b(n) - A(n,n+1:N) * x(n+1:N)) / A(n,n);
end
return
```

„(a) \implies (b)“

Es gilt $F(x) \leq F(y)$ für alle $y \in \mathbb{R}^N$, d.h. es gilt

$$\begin{aligned}\partial_n F(x) &= \frac{1}{2} e_n^T A^T A x + \frac{1}{2} x^T A^T A e_n - \frac{1}{2} b^T A e_n - \frac{1}{2} (A e_n)^T b \\ &= e_n^T (A^T A x - A^T b) \\ &= 0\end{aligned}$$

Damit folgt $A^T A x = A^T b$.

„(b) \implies (a)“

Mittels Taylorentwicklung folgt

$$\begin{aligned}F(y) &= F(x) + \nabla F(x)(y-x) + \frac{1}{2}(y-x)^T H_k(x)(y-x) \\ &= F(x) + \frac{1}{2}|A(y-x)|_2^2 \\ &\geq F(x)\end{aligned}$$

□

Bemerkung

Die Normalengleichung ist lösbar. Sei dazu $y \in \text{Kern}(A^T A)$. Dann gilt $A^T A y = 0$, also $y^T A^T A y = |A y|_2^2 = 0$. Somit ist $y \in \text{Kern}(A)$, $b^T (A y) = (A^T b)^T y = 0$, also $A^T A x = A^T b$ lösbar.

Anwendungen

1. $N \ll K$, $\text{rang} A = N$

$A^T A \in \mathbb{R}^{N \times N}$ ist symmetrisch und positiv definit. Berechne eine Cholesky-Zerlegung $LL^T = A^T A$ und löse $LL^T x = A^T b$.

2. $K < N$, $\text{rang} A = K$

$A^T A \in \mathbb{R}^{N \times N}$ ist singulär. Berechne eine QR-Zerlegung $A = QR$. Damit gilt $A^T A x = R^T Q^T Q R x = R^T R x = R^T Q b$.

Ist $R[1 : K, 1 : K] = R_1$ regulär, so löst $x[1 : K] = R_1^{-1} Q^T b$, $x[K+1 : N] = 0_{N-K}$ die Normalengleichung.

3. A hat nicht vollen Rang

Das Ausgleichsproblem ist nicht sachgemäß gestellt; es muss regularisiert werden.

Die Singulärwertzerlegung

(3.5) Satz

Sei $A \in \mathbb{R}^{K \times N}$ mit $R = \text{rang } A$. Dann existieren Singulärwerte $\sigma_1, \dots, \sigma_R > 0$ und orthogonale Matrizen $V \in \mathbb{R}^{K \times R}$, $U \in \mathbb{R}^{N \times R}$ und eine Zerlegung

$$A = V\Sigma U^T$$

mit $\Sigma \in \mathbb{R}^{R \times R}$, $\Sigma = \text{diag}(\sigma_1, \dots, \sigma_R)$.

Beweis. Die Matrix $A^T A \in \mathbb{R}^{N \times N}$ ist symmetrisch und positiv semidefinit mit $\text{rang } A = R$. Also existieren eine Orthonormalbasis $u_1, \dots, u_n \in \mathbb{R}^N$ und Eigenwerte

$$\lambda_1 \geq \dots \geq \lambda_R > \lambda_{R+1} = \dots = \lambda_N = 0$$

mit $A^T A u_k = \lambda_k u_k$.

Dann gilt $A^T A U = U \Sigma^2$, mit $U[1 : N, k] = u_k$, $\Sigma = \text{diag}(\sqrt{\lambda_1}, \dots, \sqrt{\lambda_R})$. Weiter gilt $U^T U = I_R$, also $U^T A^T A U = \Sigma^2$.

Definiere $V = A U \Sigma^{-1} \in \mathbb{R}^{K \times N}$, d.h. es ist $A = V \Sigma U^T$.

V ist orthogonal: $V^T V = \Sigma^{-1} U^T A^T A U \Sigma^{-1} = \Sigma^{-1} \Sigma^2 \Sigma^{-1} = I_R$.

□

Bemerkung

Es gilt

$$\begin{aligned} \text{kern } A &= \text{span}\{u_k \mid k = R + 1, \dots, N\}, \\ \text{bild } A &= \text{span}\{v_k \mid k = 1, \dots, R\}, \quad v_k = V[1 : K, k]. \end{aligned}$$

Damit ergibt sich die Darstellung

$$A = V \Sigma U^T = \sum_{k=1}^R \sigma_k v_k u_k^T, \quad Ax = \sum_{r=1}^R \sigma_r (u_r^T x) v_r$$

(3.6) Definition

Wir definieren die Pseudo-Inverse durch $A^+ = U \Sigma^{-1} V^T$. Es gilt $A^+ = \sum_{r=1}^R \frac{1}{\sigma_r} u_r v_r^T$ und $A^+ y = \sum_{r=1}^R \frac{1}{\sigma_r} (v_r^T y) u_r$.

(3.7) Lemma

Die Normalengleichung $A^T A x = A^T b$ wird durch $x = A^+ b$ gelöst.

Beweis. Sei dazu $x = A^+ b = U \Sigma^{-1} V^T b$. Dann gilt $\Sigma U^T x = V^T b$; durch Erweitern erhalten wir $U \Sigma V^T V \Sigma U^T x = U \Sigma V^T b$, also $A^T A x = A^T b$.

□

Die Tikhonov-Regularisierung

Zwei Probleme bleiben bei den bisherigen Verfahren bestehen:

Problem 1: Wenn eine Aufgabe schlecht konditioniert ist dann werden Datenfehler extrem verstärkt. Dies ist zum Beispiel der Fall bei $Ax = b$ mit $\kappa(A) \gg 1$.

Problem 2: Wenn eine Aufgabe nicht sachgemäß gestellt ist, ist sie entweder nicht eindeutig lösbar oder die Lösung ist nicht stetig von den Daten abhängig. Eine solche Situation tritt beispielsweise bei $|Ax - b|_2 = \min!$ für Kern $A \neq \{0\}$ auf.

Zu $F(x) = \min!$ betrachte $F_\alpha(x) = F(x) + \frac{\alpha}{2}|x|_2^2$, $\alpha > 0$, die Regularisierung von F . $F_\alpha(x) = \min!$ ist für $\alpha > 0$ sachgemäß gestellt. Die Aufgabe ist, einen Kompromiss zwischen großem Regularisierungsfehler bei großem α und schlechter Kondition bei kleinem α zu finden.

(3.8) Satz

Zu $A \in \mathbb{R}^{K \times N}$, $b \in \mathbb{R}^K$, $\alpha > 0$ existiert genau ein $x^\alpha \in \mathbb{R}^N$, welches die Tikhonov-Regularisierung

$$F_\alpha(x) := \frac{1}{2}|Ax - b|_2^2 + \frac{\alpha}{2}|x|_2^2$$

minimiert. Es gilt

$$x^\alpha = (A^T A + \alpha I_N)^{-1} A^T b.$$

Beweis. Es gilt

$$F_\alpha(x) = \frac{1}{2}|Ax - b|_2^2 + \frac{\alpha}{2}|x|_2^2 = \frac{1}{2}(x^T A^T A x - 2x^T A b + b^T b + \alpha x^T x),$$

sodass

$$\begin{aligned} \nabla F_\alpha(x) &= A^T A x - A^T b + \alpha x, \\ \nabla^2 F_\alpha(x) &= A^T A + \alpha I_N. \end{aligned}$$

Damit ist x^α Extremwert von $F_\alpha(x)$, wenn $\nabla F_\alpha(x) = 0_N$, also $A^T A x + \alpha x = A^T b$. Folglich ist x^α einziger kritischer Punkt und da $\nabla^2 F_\alpha(x^\alpha)$ positiv definit ist, ist x^α ein lokales Minimum. Weiterhin gilt $F_\alpha(x) \rightarrow \infty$ für $|x|_2 \rightarrow \infty$, also ist x^α globales Minimum. \square

(3.9) Satz

Es gilt:

$$\lim_{\alpha \rightarrow 0} x^\alpha = \lim_{\alpha \rightarrow 0} (A^T A + \alpha I_N)^{-1} A^T b = A^+ b.$$

Beweis. Sei $A = V \Sigma U^T$ Singulärwertzerlegung mit $U = (u_1 | \dots | u_R)$, $V = (v_1 | \dots | v_R)$, $\Sigma = \text{diag}(\sigma_1, \dots, \sigma_R)$, σ_r^2 positive Eigenwerte von $A^T A$, $U^T U = V^T V = I_R$ und $R = \text{rang } A$. Dann gilt

$$\begin{aligned} A^T A &= U \Sigma V^T V \Sigma U^T = U \Sigma^2 U^T \\ A^T b &= U \Sigma V^T b = \sum_{r=1}^R u_r \sigma_r (v_r^T b) \end{aligned}$$

Somit folgt

$$(A^T A + \alpha I_N) u_k = \sum_{r=1}^R u_r \sigma_r^2 (u_r^T u_k + \alpha u_k) = (\sigma_k^2 + \alpha) u_k$$

also

$$\begin{aligned} x^\alpha &= (A^T A + \alpha I_N)^{-1} \sum_{r=1}^R u_r \sigma_r (v_r^T b) \\ &= \sum_{r=1}^R \frac{\sigma_r}{\sigma_r^2 + \alpha} (v_r^T b) u_r, \end{aligned}$$

und damit

$$\lim_{\alpha \rightarrow 0} x^\alpha = \sum_{r=1}^R \frac{1}{\sigma_r} (v_r^T b) u_r = U \Sigma^{-1} V^T b = A^+ b.$$

□

(3.10) Folgerung

1. $A^+ = \lim_{\alpha \rightarrow 0} (A^T A + \alpha I_N)^{-1} A^T$ ist eindeutig bestimmt.
2. Für $\text{rang} A = N$ gilt $A^+ = (A^T A)^{-1} A^T$.

Bemerkung

A^+ ist eindeutig durch die Penrose-Axiome

$$(A^+ A)^T = A^+ A, \quad (A A^+)^T = A A^+, \quad A^+ A A^+ = A^+, \quad A A^+ A = A$$

bestimmt. Allgemein ist $(AB)^+ \neq B^+ A^+$.

Bemerkung

Für die Kondition der Tikhonov-Regularisierung gilt

$$\begin{aligned} \kappa_2(A^T A + \alpha I_N) &= \|A^T A + \alpha I_N\|_2 \| (A^T A + \alpha I_N)^{-1} \|_2 \\ &= \frac{\max \sigma_n^2 + \alpha}{\min \sigma_n^2 + \alpha} \leq \frac{\rho^2(A) + \alpha}{\alpha}. \end{aligned}$$

Das Diskrepanz-Prinzip

Wir betrachten nun den Fall, dass die rechte Seite b nur ungefähr gegeben ist (z.B. wegen Messungenauigkeiten). Dazu definieren wir einen sogenannten *Noiselevel* $\delta > 0$ und zeigen: wenn δ kleiner wird, dann wird das optimale α kleiner. Genauer:

Sei $x = A^+ b \in \text{Bild}(A)$, also $Ax = b$, und es gelte $|b^\delta - b|_2 < \delta < |b|_2$.

Dann existiert zu δ ein $\alpha = \alpha(\delta)$ mit $x^\alpha = (A^T A + \alpha I_N)^{-1} A^T b^\delta$ und $|Ax^\alpha - b^\delta|_2 = \delta$, und für $\delta \rightarrow 0$ gilt $x^\alpha \rightarrow x$.

Beweis. Es gilt für

$$F^\delta(\alpha) = |Ax^\alpha - b^\delta|_2^2 - \delta^2 = \sum_{k=1}^K \frac{\alpha^2}{(\alpha + \sigma_k^2)^2} v_k^T b^\delta - \delta^2$$

$F^\delta(0) = -\delta^2 < 0$, und $F^\delta(\alpha)$ ist für wachsendes α streng monoton wachsend.
 Also existiert $\alpha = \alpha(\delta)$ mit $F^\delta(\alpha) = 0$ und $|b^\delta|_2 - \delta = |b^\delta|_2 - |Ax^\alpha - b^\delta|_2 \leq |Ax^\alpha|_2$.
 Aus $(A^T A + \alpha I_N)x^\alpha = A^T b^\delta$ folgt $\alpha x^\alpha = A^T b^\delta - A^T Ax^\alpha$ und

$$\alpha |Ax^\alpha|_2 = |A(A^T b^\delta - A^T Ax^\alpha)|_2 \leq \|AA^T\|_2 (|b^\delta|_2 - \delta) \leq \|AA^T\|_2 \delta.$$

Also gilt

$$\alpha \leq \delta \frac{\|AA^T\|_2}{|Ax^\alpha|_2} \leq \delta \frac{\|AA^T\|_2}{|b^\delta|_2 - \delta} \leq \|AA^T\|_2 \delta \rightarrow 0 \text{ für } \delta \rightarrow 0$$

□