

Zerlegungen

1) LU

Sei $A \in GL_n(\mathbb{R})$. Dann existieren

$$\left. \begin{array}{l} P: \text{Permutationsmatrix} \\ L: \text{untere } \Delta\text{-Matrix} \\ U: \text{obere } \Delta\text{-Matrix} \end{array} \right\} n \times n\text{-Matrizen}$$

s.d. $A = PLU$

Sinnvoll, da dann schnelles Lösen von LGS mittels Substitution

$$Ax = b \Leftrightarrow L \underbrace{Ux}_z = \underbrace{P^T b}_{\tilde{b}}$$

a) löse zuerst $Lz = \tilde{b}$ (Vorwärtssub.)

b) löse dann $Ux = z$ (Rückwärtssub.)

Super, da $\left(\begin{array}{c|c} \Delta & 0 \\ \hline 0 & \end{array} \right) z = \tilde{b} \Leftrightarrow$

$$\begin{aligned} z_1 &= \frac{\tilde{b}_1}{L_{11}} \\ z_2 &= \frac{\tilde{b}_2 - L_{21}z_1}{L_{22}} \end{aligned} \quad \left(\begin{array}{l} \text{Lösung direkt} \\ \text{ausrechnen} \end{array} \right)$$

+ existieren sehr stabile Algorithmen für die LU-Zerlegung

2) Cholesky

Falls $A \in GL_n(\mathbb{R})$ symmetrisch + pos. definit, dann existieren

L (untere Δ -Mat.), U (obere Δ -Mat.) s.d. $A = LL^T = UU^T$

3) QR-Zerlegung (orthogonal $\equiv$ bzgl. euklid. Skalarprod.)

Sei $A \in \text{Mat}_{m \times n}(\mathbb{R})$ mit vollem Rang. Dann kann man folgende Zerlegungen machen:

1) $m = n \Rightarrow A \in GL_n(\mathbb{R})$

$$Q \in O(n) \quad (Q^T Q = 1), \quad R \in GL_n(\mathbb{R}) \quad (\text{obere } \Delta\text{-Mat.})$$

$$A = QR$$

2) $m > n$:

reduziert: $\tilde{Q} \in \text{Mat}_{m \times n}(\mathbb{R})$ mit orth. Spalten

$\tilde{R} \in GL_n(\mathbb{R})$ obere Δ -Mat. s.d.

$$A = \tilde{Q} \tilde{R}$$

vollständig: $Q \in O(n)$ mit $Q = (\hat{Q} | q_{n+1} | \dots | q_m)$
 $R \in \text{Mat}_{m \times n}(\mathbb{R})$ mit $R = \begin{pmatrix} \hat{R} \\ 0 \end{pmatrix}_{\substack{3n \\ 3m-n}}$

$$A = Q \cdot R$$

$$\begin{pmatrix} \\ \\ \end{pmatrix} = \begin{pmatrix} \hat{Q} \\ \vdots \end{pmatrix}_{\substack{n \\ }} \begin{pmatrix} \hat{R} \\ 0 \end{pmatrix}_{\substack{3n \\ }}$$

3) $m < n$: $Q \in O(n)$, $R \in \text{Mat}_{m \times n}(\mathbb{R})$ mit vollem Rang s.d. $A = QR$

$$A = Q \cdot R$$

$$\begin{matrix} m \\ \end{matrix} \begin{pmatrix} \\ \\ \end{pmatrix} = \begin{matrix} \\ m \end{matrix} \begin{pmatrix} \\ \\ \end{pmatrix} \begin{pmatrix} \diagup & \\ 0 & \end{pmatrix}_{\substack{m \\ }}$$

Wieso QR-Zerlegung?

Die orthogonalen Matrizen Q sind gut konditioniert, da sie die 2-Norm erhalten: $\|Qx\|_2 = \|x\| \quad \forall Q \in O(n)$

+ orthogonale Koordinaten vereinfachen viele Rechnungen (z.B. Symmetrien in Physik)

Lösen von LGS:

$$Ax = b \Leftrightarrow QRx = b$$

$$\Leftrightarrow Rx = Q^T b$$

Verfahren für QR-Zerlegung:

- a) Gram-Schmit (GS)
- b) Givens-Rot
- c) Householder-Spiegelungen

a) GS

Nehme Spalten von $A = (a_1 | \dots | a_n)$ als Startvektoren für GS-Verfahren

(+) analytisch gut verständlich

Wenn Verfahren in der Mitte abgebrochen wird, dann haben wir trotzdem schon die orth. Vektoren q_i bis dahin

(-) numerisch instabil

Verbesserung: modifiziertes GS-Verfahren

(berücksichtigt Rundungsfehler in jedem Schritt)

Bemerkung: QR-Zerlegung durch Multiplikation mit oberen Δ -Mat erzeugt

$\Rightarrow \Delta$ -Mat. nicht gut konditioniert $\Rightarrow$ Stabilität leidet

Besser: Erstelle Q , indem nur orthogonale Transformationen angewendet werden müssen

$\hookrightarrow$ Householder / Givens

Idee Householder: Spiegele eine Spalte von A direkt so, dass die gewünschte Spalte von R entsteht

SVD

Hilfreich für Datenkompression, Datenanalyse, Ausgleichsrechnung

Sei $A \in \mathbb{C}^{m \times n}$, dann $\exists U \in U(m) \exists V \in U(n)$, $\Sigma := \text{diag}(\sigma_1, \dots, \sigma_p)$ mit $p = \min\{n, m\}$

$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_p \geq 0$ s.d. $A = U \Sigma V^*$

Numerisch: Unterscheidung von numerischem und theoretischem Rang

Durch Rundungsfehler: $\underbrace{\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r}_{\text{numerischer Rang}} \gg \underbrace{\sigma_{r+1} \approx \dots \approx \sigma_p \approx 0}_{\text{Zählt nicht zum Rang}}$

SVD und Kondition:

Satz: Sei $A \in \mathbb{C}^{n \times n}$, dann $\text{cond}_2(A) = \frac{\sigma_1}{\sigma_m}$ (Kondition mit Singulärwerten verbinden)

Anwendungen SVD:

1) Datenkompression: $A \in \mathbb{C}^{m \times n}$

A normal speichern: $m \cdot n$ Werte

$A = \sum_{k=1}^p \sigma_k U_k V_k^*$ speichern: $p(1+n+m)$ Werte

$\Rightarrow$ für p klein weniger Speicherplatz (z.B. in Bildkompression)

2) Datenanalyse:

Mit Principal Component Analysis kann man Datensets auf die grössten Singulärwerte reduzieren