

Insgesamt ergibt dies: $PAQ = \begin{bmatrix} S & 0 \\ 0 & 0 \end{bmatrix}$ mit $S \in \mathbb{R}^{r \times r}$ und $r = \text{Rang } A = \text{Rang } S$, insbesondere $S \in \text{Gl}(r, \mathbb{R})$. Gelingt es, die Existenz einer SVD für S nachzuweisen, so ergibt sich demnach die Existenz einer SVD auch für A .

Sei ab jetzt: $A \in \text{Gl}_n(\mathbb{R})$.

- (b) Da $A \in \text{Gl}_n(\mathbb{R})$, gilt für $x \in \mathbb{R}^{n \times 1} \setminus \{0\}$: ${}^t x {}^t A A x = \|Ax\|^2 > 0$. Damit folgt: $\sigma({}^t A A) \subset \mathbb{R}_+$, denn ist x ein Eigenvektor zum Eigenwert λ von ${}^t A A$, dann gilt:

$$0 < \|Ax\|^2 = {}^t x \underbrace{({}^t A A x)}_{=\lambda x} = \lambda {}^t x x = \lambda \|x\|^2.$$

Es folgt $\lambda > 0$.

Beachte: nicht alle symmetrischen Matrizen haben positive Eigenwerte; z. B. $\begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$.

- (c) Nach Satz 12.22 ist ${}^t A A$ orthogonal ähnlich zu $\text{diag}(\lambda_1, \dots, \lambda_n)$. Zwangsläufig gilt nach (b): $0 < \lambda_i$ für $1 \leq i \leq n$. Mit elementaren Spiegelungen P_1, \dots, P_s erreicht man noch:

$$P_s \cdots P_1 \text{diag}(\lambda_1, \dots, \lambda_n) P_1 \cdots P_s = \text{diag}(\mu_n, \dots, \mu_1) \text{ mit } 0 < \mu_1 \leq \dots \leq \mu_n.$$

Setze $s_i := +\sqrt{\mu_i}$ und $D := \text{diag}(s_n, \dots, s_1)$. Zur Erklärung des Vorstehenden sei daran erinnert, dass $P_i^{-1} = P_i$ und das $S(i, j, 0, 1) = P_j^i$.

- (d) Sei (vgl. Satz 12.22) (v_n, \dots, v_1) eine Orthonormalbasis von Eigenvektoren von ${}^t A A$; Dann ist v_i Eigenvektor zum Eigenwert $s_i^2 = \mu_i$.

Setze $Q := [v_n, \dots, v_1]$ und $P := D^{-1} {}^t Q {}^t A$. Dann gilt $({}^t A \cdot A)Q = QD^2$ **und**

$$PAQ = (D^{-1} {}^t Q {}^t A)AQ = D^{-1} {}^t Q ({}^t A A Q) = D^{-1} {}^t Q Q D^2 = D$$

Die letzte Gleichung ergibt sich, weil nach Konstruktion ${}^t Q Q = E_n$. Dabei ist $Q \in \mathcal{O}(n)$ und, da außerdem

$$P^t P = D^{-1} {}^t Q \underbrace{{}^t A A Q}_{=E_n} D^{-1} = D^{-1} {}^t Q Q D^2 D^{-1} = E_n,$$

also auch $P \in \mathcal{O}(n)$.

Eindeutigkeit: Wenn $PAQ = D$ bzw. $A = {}^t P D {}^t Q$, dann ist ${}^t A A = Q D \underbrace{P^t P}_{E_n} D {}^t Q = Q D^2 {}^t Q$. Es

folgt $\chi_{{}^t A A} = \prod_{i=1}^n (t - \mu_i) = \chi_{D^2}$ □

Ein **völlig** anderer Beweis ergibt sich mit Hilfe des sogenannten Rayleigh-Quotienten (J. W. Rayleigh 1842 - 1919) und Matrix-Normen. Da die Begriffe sowieso wichtig sind, werden Sie jetzt eingeführt und dann Satz 2 nochmal bewiesen.

Hinweise zu Anwendungen der SVD sind u. a. zu finden in:

H. Möller: algorithmische Mathematik, Vieweg, 1997.

W. Mackens und H. Voß: Mathematik 1 für Studierende der Ingenieurwissenschaften, Heco-Verlag, 1993

G. Stewart: Early history of SVD, Universität Maryland, Report.

V. Mehrmann: Numerik, Vorlesungskript, TH Berlin.

Definition 3: (a) $A \in \mathbb{R}^{m \times n}$

$\|A\|_2 := \max_{x \neq 0} \frac{\|Ax\|}{\|x\|}$ heißt (2-)Norm von A . Dies ist die Standard-Matrixnorm zum Standardskalarprodukt.

Vorsicht! Dass das Maximum angenommen wird, wird unten erst gezeigt, kann aber auch direkt mit analytischen Überlegungen erkannt werden.

- (b) Sei $A \in \mathbb{R}^{n \times n}$ **symmetrisch**. Die Abbildung $R_A : \mathbb{R}^{n \times 1} \setminus \{0\} \rightarrow \mathbb{R}$ mit $R_A(x) = \frac{tAx}{tAx}$ heißt **Rayleighquotient** zur Matrix A .
- (c) Die **Frobenius-Norm** einer Matrix $A \in \mathbb{R}^{m \times n}$ ist die Länge des 'Vektors' $A \in \mathbb{R}^{m \times n}$ bzgl. dem Standardskalarprodukt:

$$\|A\|_F = \sqrt{\sum_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}} a_{ij}^2}.$$

Beispiel 4: (a) $\|E_n\|_2 = 1, \|E_n\|_F = \sqrt{n}, R_{E_n}(x) = 1$.

- (b) Sei $A = \begin{bmatrix} 1 & s \\ 0 & 1 \end{bmatrix} \in \mathbb{R}^{2 \times 2}$. dann ist $\|A\|_F = \sqrt{2 + s^2}$. Was ist $\|A\|_2$? Behauptung: $\|A\|_2 = 1 + \frac{s^2}{2} + \frac{1}{2}\sqrt{4s^2 + s^4}$. Dies ergibt sich mit dem folgenden Satz 6.

- (c) Normberechnung in Maple: z. B.: so:

with(linalg): A:=matrix(.....);norm(A,2);

- (d) Sei A symmetrisch und $Ax = \lambda x$ für ein $x \neq 0$, dann ist $R_A(x) = \lambda$.

Beobachtung 5: $\|A\|_F$ und $\|A\|_2$ sind sogenannte Matrixnormen, d.h. es gilt (mit $\|\cdot\|$ statt $\|\cdot\|_F$ oder $\|\cdot\|_2$):

- (i) $\forall A \in \mathbb{R}^{m \times n} : \|A\| = 0 \Leftrightarrow A = 0$.
(ii) $\forall \lambda \in \mathbb{R}, A, B \in \mathbb{R}^{m \times n} : \|\lambda A\| = |\lambda| \|A\|$ und $\|A + B\| \leq \|A\| + \|B\|$.
(iii) $\forall A \in \mathbb{R}^{m \times n}, B \in \mathbb{R}^{n \times p}, \lambda \in \mathbb{R} :$

$$\|Ax\| \leq \|A\| \|x\| \text{ und } \|AB\| \leq \|A\| \cdot \|B\|$$

Bei (iii) wird angenommen, dass "gleichartige" Normen in $\mathbb{R}^{m \times n}$ und \mathbb{R}^n vorliegen. Bezüglich (i) und (ii) sei auch auf [F], Seite 275 verwiesen.

Beweis: Übungsaufgabe. ((iii) für $\|\cdot\|_2$ trivial; für $\|\cdot\|_F$ in Beweis von Satz 6 (b) enthalten.)

Satz 6: (a) sei $A \in \mathbb{R}^{m \times n}$ **symmetrisch**. Sei $\lambda_1 = \min \sigma(A)$ und $\lambda_n = \max \sigma(A)$.

- (i) $\lambda_1 = \min_{x \neq 0} R_A(x)$ und $\lambda_n = \max_{x \neq 0} R_A(x)$.

- (ii) Für alle $x \in \mathbb{R}^{n \times 1} \setminus \{0\} :$ $R_A(x) = \lambda_1 \Leftrightarrow x \in \text{Eig}(A, \lambda_1)$ beachte: λ_1, λ_n speziell!
 $R_A(x) = \lambda_n \Leftrightarrow x \in \text{Eig}(A, \lambda_n)$

- (b) Sei $A \in \mathbb{R}^{m \times n}$, dann ist

$$\|A\|_2 = \max \{ \sqrt{\lambda} : \lambda \in \sigma(tAA) \} = \sqrt{\max \{ R_{tAA}(x) : x \in \mathbb{R}^{n \times 1} \setminus \{0\} \}} \leq \|A\|_F$$

Man beachte den Zusammenhang mit den Singulärwerten: $\|A\|_2 =$ größter Singulärwert.

Beweis:

- (a) Da A symmetrisch ist, gibt es eine Orthonormalbasis (w_1, \dots, w_n) von Eigenvektoren (Satz 12.22), die wir so so ordnen, dass w_1 zum kleinsten Eigenwert λ_1 und w_n zum größten Eigenwert λ_n gehört: $\lambda_1 \leq \dots \leq \lambda_n$, u. U. $\lambda_1 = \lambda_n$!

Mit $x = \sum_{i=1}^n x_i w_i$ gilt:

$$\begin{aligned} tAx &= t \left(\sum_{i=1}^n x_i w_i \right) A \left(\sum_{j=1}^n x_j w_j \right) = t \left(\sum_{i=1}^n x_i w_i \right) \left(\sum_{j=1}^n x_j A w_j \right) \\ &= t \left(\sum_{i=1}^n x_i w_i \right) \left(\sum_{j=1}^n \lambda_j x_j w_j \right) = \sum_{i=1}^n \lambda_i x_i^2 \end{aligned}$$

und ${}^t x x = \|x\|^2$. Daher ist

$$R_A(x) = \sum_{i=1}^n \lambda_i \underbrace{\frac{x_i^2}{\|x\|^2}}_{\geq 0} \quad (1)$$

$$\text{Es folgt } \lambda_1 \leq \lambda_1 \frac{\|x\|^2}{\|x\|^2} = \sum_{i=1}^n \lambda_i \frac{x_i^2}{\|x\|^2} \leq \sum_{i=1}^n \lambda_i \frac{x_i^2}{\|x\|^2} \stackrel{\lambda_1 \leq \lambda_i}{=} \underbrace{\sum_{i=1}^n \lambda_i \frac{x_i^2}{\|x\|^2}}_{=R_A(x)} \leq \sum_{i=1}^n \lambda_n \frac{x_i^2}{\|x\|^2} \stackrel{\lambda_i \leq \lambda_n}{=} \lambda_n \cdot$$

Außerdem ergibt (1) für $x = w_1$: $R_A(w_1) = \lambda_1$ und für $x = w_n$: $R_A(w_n) = \lambda_n$. Insgesamt ergibt sich (i).

zu (ii): Wenn $R_A(x) = \lambda_1$, dann muss in (1) gelten:

$$x_k = 0 \text{ falls } \lambda_k \neq \lambda_1,$$

denn dann ist $\lambda_1 < \lambda_k$. Es folgt $x = \sum_{\substack{w_i \text{ Eigenvektor} \\ \text{zum Eigenwert } \lambda_1}} x_i w_i$ und $Ax = \lambda_1 x$, analog, wenn

$R_A(x) = \lambda_n$. Die Umkehrung ist jeweils trivial (vgl. Beispiel 4(d)).

(b) Aufgrund von (a) ergibt sich: $\|A\|_2^2 = \max_{x \neq 0} \frac{{}^t x A A x}{{}^t x x} = \max_{x \neq 0} R_{{}^t A A}(x) = \max \sigma({}^t A A)$. Zu zeigen

ist nun noch $\|A\|_2 \leq \|A\|_F$.

Für $x \in \mathbb{R}^{n \times 1}$ gilt, wenn etwa $A = (a_{ij})$:

$$\|Ax\|^2 = \sum_{i=1}^n \left(\sum_{j=1}^n a_{ij} x_j \right)^2 \leq \sum_{i=1}^n \left(\sum_{j=1}^n a_{ij}^2 \right) \left(\sum_{j=1}^n x_j^2 \right) = \|A\|_F^2 \|x\|^2$$

Dabei ergibt sich die Ungleichung aufgrund der Cauchy-Schwarz-schen Ungleichung für das Standardskalarprodukt der Vektoren ${}^t A_{i\bullet}$ und x . Es folgt für alle $x \neq 0$;

$$\frac{\|Ax\|}{\|x\|} \leq \|A\|_F \quad \text{bzw.} \quad \|A\|_2 \leq \|A\|_F \quad \square$$

Zurück zu Beispiel 4(b):

Dort ist ${}^t A A = \begin{bmatrix} 1 & 0 \\ s & 1 \end{bmatrix} \begin{bmatrix} 1 & s \\ 0 & 1 \end{bmatrix} = \begin{bmatrix} 1 & s \\ s & s^2 + 1 \end{bmatrix}$, $\chi_{{}^t A A} = (1+t)((s^2+1)-t) - s^2 = t^2 - (2+s^2)t + 1$

und

$$\sigma({}^t A A) = \left\{ \underbrace{1 + \frac{s^2}{2} - \frac{1}{2} \sqrt{4s^2 + s^4}}_{=: \lambda_1}, \underbrace{1 + \frac{s^2}{2} + \frac{1}{2} \sqrt{4s^2 + s^4}}_{\lambda_2} \right\}.$$

Bemerkung: Der Rayleigh-Quotient und die Matrizennormen spielen eine wichtige Rolle bei der sogenannten **”Lokalisierung von Eigenwerten”**. Es gilt nämlich (erste grobe Info)

Satz 7: Sei $A \in \mathbb{R}^{n \times n}$ und $\lambda \in \sigma_{\mathbb{C}}(A)$. Dann gilt

$$\left(\sqrt{\lambda \bar{\lambda}} \right) = |\lambda| \leq \|A\|_2$$

Der kurze Beweis erfordert die Ausweitung der Theorie ins Komplexe und dann gilt der Satz auch für $A \in \mathbb{C}^{n \times n}$.

Mehr Info dazu (z. B. Min Max-Prinzip für Eigenwerte) meist in Büchern über allgemeine lineare Algebra und Matrizenrechnung, Volesungen zur Ingenieurmathematik und der Numerik.

Um die Methoden zu erproben, folgt ein völlig andersartiger Beweis von Satz 2 mit Hilfe der Sätze 5 und 6:

Sei $0 \neq A \in \mathbb{R}^{m \times n}$ und sei v ein Vektor derart, dass $s := \|A\|_2 = \frac{\|Av\|}{\|v\|} = \max_{x \neq 0} \frac{\|Ax\|}{\|x\|} > 0$.

Wir setzen $v_1 = \frac{1}{\|v\|}v$, dann ist $\|Av_1\| = \|A\|_2 = s$. Sei weiter $u_1 = s^{-1}Av_1$. Dann gilt:

$$Av_1 = s \cdot u_1 \quad \text{und} \quad \|v_1\| = 1, \|u_1\| = 1$$

Seien (v_1, \dots, v_n) eine Orthonormalbasis von $\mathbb{R}^{n \times 1}$, (u_1, \dots, u_m) eine Orthonormalbasis von $\mathbb{R}^{m \times 1}$, und seien $Q = [v_1, \dots, v_n]$, $P = [u_1, \dots, u_m]$. Dann ist

$$B := {}^tPAQ = \begin{bmatrix} {}^tu_1 \\ \vdots \\ {}^tu_n \end{bmatrix} [Av_1, \dots, Av_n] = \begin{bmatrix} {}^tu_1 \\ \vdots \\ {}^tu_n \end{bmatrix} [su_1, Av_2, \dots, Av_n] = \begin{bmatrix} s & {}^tw \\ 0 & A_1 \\ \vdots & \\ 0 & \end{bmatrix} = B.$$

Dabei ist ${}^tw = [{}^tu_1Av_2, \dots, {}^tu_1Av_n]$.

Automatisch ist $w = 0$, denn einerseits ist $B \cdot \begin{bmatrix} s \\ w \end{bmatrix} = \begin{bmatrix} s^2 + {}^tw w \\ A_1 w \end{bmatrix}$ und somit

$$\|B \begin{bmatrix} s \\ w \end{bmatrix}\|^2 = (s^2 + {}^tw w)^2 + \|A_1 w\|^2 \geq (s^2 + {}^tw w)^2 = \left\| \begin{bmatrix} s \\ w \end{bmatrix} \right\|^4$$

und daher

$$\|B\|_2 \geq s^2 + {}^tw w.$$

Es ist auch :

$$\begin{aligned} s^2 = \|A\|_2^2 &= \max \sigma({}^tAA) = \max \sigma({}^t(PB{}^tQ)(PB{}^tQ)) \\ &= \max \sigma(Q{}^tBB{}^tQ) = \max \sigma({}^tBB) = \|B\|_2 \end{aligned}$$

Es folgt: $w = 0!$

Nun kann mit vollständiger Induktion der Beweis abgeschlossen werden. □

Folgender Zusammenhang besteht zwischen der Singulärwertzerlegung und den Moore-Penrose-Inversen:

Satz 8: Sei $A \in \mathbb{R}^{m \times n}$ und

$$PAQ = \begin{bmatrix} s_r & & & 0 \\ & \ddots & & \\ & & s_1 & \\ 0 & & & 0 \end{bmatrix} \quad \text{mit } P \in O(m), Q \in O(n)$$

die Singulärwertzerlegung von A .

$$\text{Dann gilt: } A^\# = QD^\#P \quad \text{mit } D^\# = \begin{bmatrix} s_r^{-1} & & & 0 \\ & \ddots & & \\ \vdots & & s_1^{-1} & \\ 0 & & & \ddots & \\ & & & & 0 \end{bmatrix} \quad (\in \mathbb{R}^{n \times m}).$$

Dabei ist $A^\#$ wie in Aufgabe (7)(8) erklärt.

Folgerung 9:

$$A^\# = A \quad \text{und} \quad {}^t(A^\#) = ({}^tA)^\#$$

□

Für den Beweis von Satz 8 sei auf die bereits oben erwähnten Büchern von Mackens / Voß und von Serre verwiesen.

Bemerkungen

- (a) Der Stoff ab Satz 7 wurde in der Vorlesung nicht behandelt und nur teilweise als Info erwähnt.
- (b) In dem Buch von Max Köcher: Lineare Algebra und analytische Geometrie, Springer, 1983, S. 199/200; findet man eine Version von Satz 2, die dort für invertierbare A dem französischen Mathematiker E. Cartan (1859 - 1951) zugeschrieben wird. Demnach wäre es wohl angebrachter, von der **Cartan-Normalform** zu sprechen statt den schwer motivierbaren Namen "Singulärwertzerlegung" zu benutzen.