

Lineare Algebra und Numerische Mathematik

Prof. Ralf Hiptmair

Seminar for Applied Mathematics, ETH Zürich

Vorlesung für D-BAUG Herbstsemester 2014

www.math.ethz.ch/education/bachelor/lectures/hs2014/other/linalnum_BAUG

www.sam.math.ethz.ch/~hiptmair/tmp/LANM/

VII. Diagonalisierung

7.1. Lineare Rekursionen

Beispiel VII.1.0.P (Altersstruktur einer Population).

Zustandsraum $\mathcal{V} := \mathbb{R}^n$: $n \in \mathbb{N} \hat{=}$ maximales Alter
 $\mathbf{x} \in \mathcal{V} \triangleright (\mathbf{x})_i \hat{=}$ Anzahl Weibchen im i . Lebensjahr, $i \in \{1, \dots, n\}$

Modellparameter: $f_i \in \mathbb{R}^+$: Durchschnittliche Anzahl von weiblichen Nachkommen eines Weibchens im i . Lebensjahr (fecundicity)
 $m_i \in [0, 1]$: Todeswahrscheinlichkeit für ein Weibchen im i . Lebensjahr (mortality)

Annahme: grosse Population

Modell: Zeitliche Entwicklung: Jahr $k \rightarrow$ Jahr $k+1$

$\underline{x}^{(k)} \hat{=}$ Altersverteilung im Jahr k

$$x_{j+1}^{(k+1)} = (1 - m_j) \cdot x_j^{(k)} \quad [\text{"Überleben"}] \quad j \in \{1, \dots, n-1\}$$

$$x_1^{(k+1)} = \sum_{\ell=1}^n f_{\ell} x_{\ell}^{(k)} \quad [\text{Anz. Kücken}]$$

Regel $\underline{x}^{(k)} \rightarrow \underline{x}^{(k+1)}$: Umschreiben als Matrix \times Vektor

$$\underline{x}^{(k+1)} = \begin{bmatrix} f_1 & f_2 & \dots & f_n \\ 1-m_1 & 0 & & 0 \\ 0 & 1-m_2 & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1-m_{n-1} & 0 \end{bmatrix} \underline{x}^{(k)}$$

$A \in \mathbb{R}^{n,n}$

\Rightarrow

$$\underline{x}^{(k+1)} = A \underline{x}^{(k)}$$

Beispiel VII.1.0.Q ((Vereinfachter) Page-Rank Algorithmus). → [2]

- „Modellinternet“ mit n Seiten, nummeriert $1, \dots, n$.
- $L_\ell \hat{=}$ Anzahl der Links auf Seite ℓ , $\ell \in \{1, \dots, n\}$
- Clickverhalten eines **Zufallssurfers**, der sich aktuell auf Seite ℓ befindet:
- Mit der Wahrscheinlichkeit (d^* gegeben)

$$d_\ell := \begin{cases} 1 & , \text{ wenn } L_\ell = 0, \\ d^* \in]0, 1[& , \text{ wenn } L_\ell > 0, \end{cases}$$

springt der Surfer gleichwahrscheinlich zu einer beliebigen der n Webseiten.

- Mit der Wahrscheinlichkeit $1 - d_\ell$ folgt er gleichwahrscheinlich einem beliebigen der L_ℓ Links auf Seite ℓ .

Sprungwahrscheinlichkeit Seite $\ell \rightarrow$ Seite $j = P_{j\ell}$

- (i) Wenn $L_\ell = 0 \Rightarrow P_{j\ell} = \frac{1}{n}$
- (ii) Wenn $L_\ell > 0 \Rightarrow P_{j\ell} = \begin{cases} d^* \cdot \frac{1}{n} & \text{wenn kein Link auf } j \\ (1-d^*) \frac{1}{L_\ell} + d^* \frac{1}{n} & \text{wenn Link } \ell \rightarrow j \end{cases}$

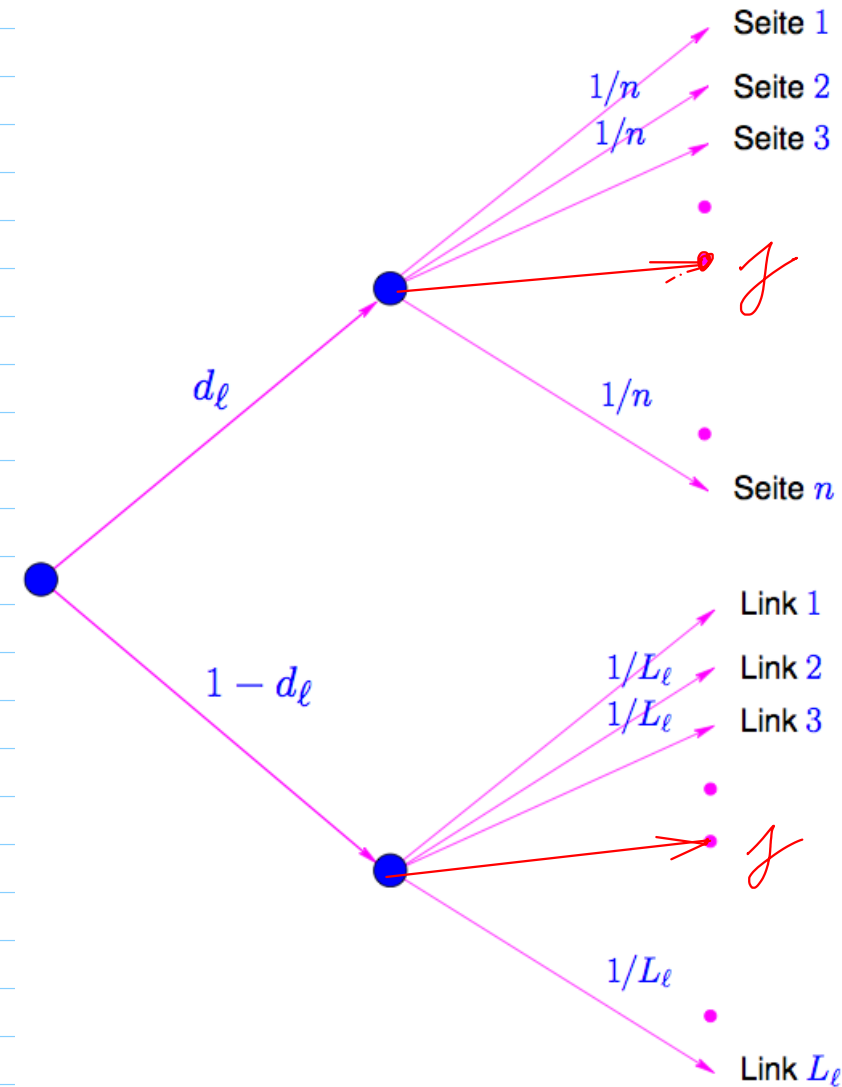
$x_j^{(k)} \hat{=}$ Wahrscheinlichkeit, dass Zufallssurfer nach k . Click auf Seite j

$$x_j^{(k+1)} = \sum_{\ell=1}^n P_{j\ell} x_\ell^{(k)} \quad [\text{Rechenregel für bedingte Wahrscheinlichkeiten}]$$

$P \in \mathbb{R}^{n \times n}$

$$(P)_{j,\ell} := P_{j\ell}$$

$$\Rightarrow \underline{x}^{(k+1)} = P \underline{x}^{(k)} \quad (*)$$



Wahrscheinlichkeitsbaum für Zufallssurfer auf Seite ℓ

Beobachtung: " $\underline{x}^{(k)}$ stabilisiert sich" für grosse k
 $\underline{x}^{(\infty)} := \lim_{k \rightarrow \infty} \underline{x}^{(k)}$ existiert?

\Rightarrow PageRank $\hat{=}$ Sortieren nach Grösse der Einträge in $\underline{x}^{(\infty)}$

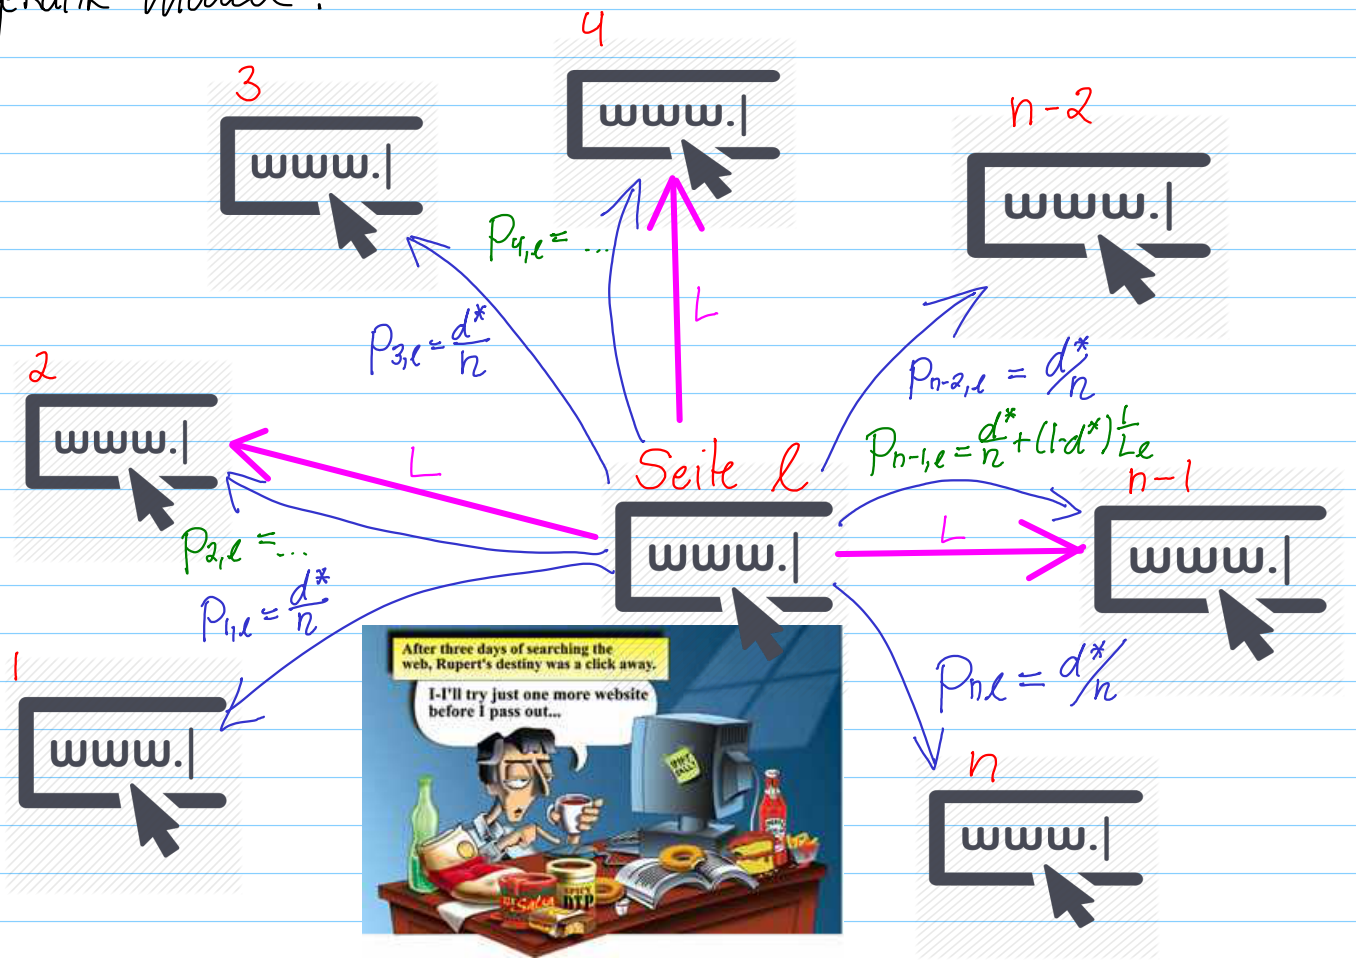
Spezielle Eigenschaft von P : $\sum_{i=1}^n (P)_{i,e} = 1$

$$\sum_{l=1}^n x_l^{(k)} = 1 \Rightarrow \sum_{j=1}^n x_j^{(k+1)} = \sum_{j=1}^n \sum_{l=1}^n (P)_{j,l} x_l^{(k)} = \sum_{l=1}^n \left(\sum_{j=1}^n (P)_{j,l} \right) x_l^{(k)} = 1$$

"Wahrscheinlichkeitsvektor"


$\Rightarrow x^{(k+1)}$ ist auch "Wahrscheinlichkeitsvektor"

PageRank-Modell:



Abstraktion: Stationäre Markov-Kette

System mit n Zuständen: (\Leftrightarrow Surfer auf Seite l $\hat{=}$ Zustand l)



$P \in \mathbb{R}^{n \times n}$
 $(P)_{ij} \hat{=}$ Übergangswahrscheinlichkeit von Zustand j \rightarrow Zustand i
 $(P)_{ij} \in [0,1]$: gegeben.

Nebenbedingung $\sum_{i=1}^n (P)_{ij} = 1$
 $\rightarrow P$ ist stochastische Matrix

$x^{(k)} \in \mathbb{R}^n$: $x_j^{(k)} \hat{=}$ Wahrscheinlichkeit, dass System im k. Schritt im Zustand j

$$x_j^{(k+1)} = \sum_{l=1}^n (P)_{j,l} x_l^{(k)}$$

$$\underline{x}^{(k+1)} = P \underline{x}^{(k)}$$

Definition VII.1.0.A (Lineare Rekursion).

Für eine gegebene quadratische Matrix $\mathbf{A} \in \mathbb{R}^{n,n}$, $n \in \mathbb{N}$, heisst eine der Vorschrift

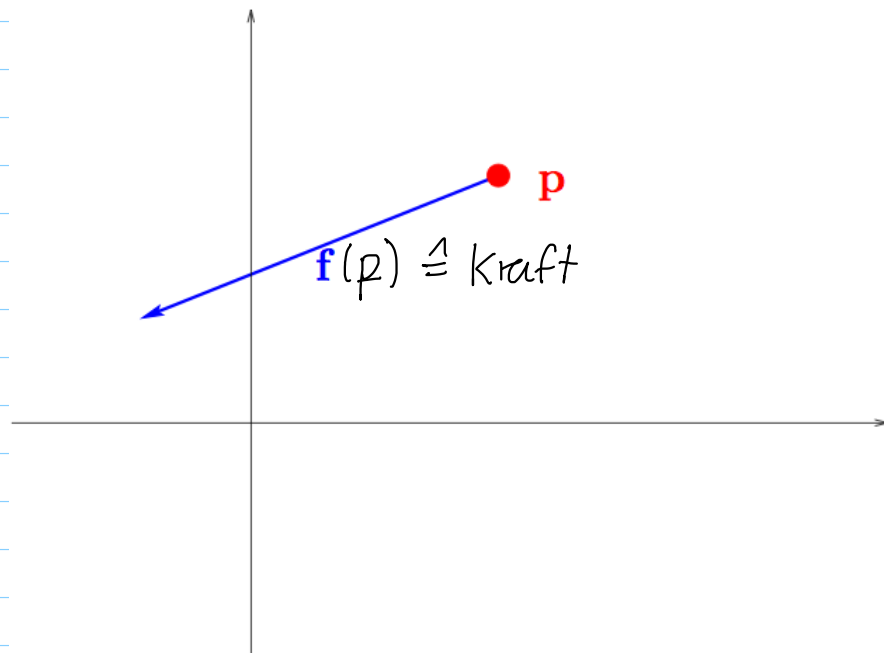
$$\mathbf{x}^{(k+1)} := \mathbf{A}\mathbf{x}^{(k)}, \quad k \in \mathbb{N}_0,$$

genügende Folge $(\mathbf{x}^{(0)}, \mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots) \subset \mathbb{R}^n$ von Spaltenvektoren eine (homogene) lineare Rekursion mit Startvektor $\mathbf{x}^{(0)} \in \mathbb{R}^n$ und Rekursionsmatrix (Propagationsmatrix) \mathbf{A} .

Beispiel VII.1.0.R (Diskretes dynamisches System).

↳ "Shobaskop"

- $\mathbf{f} : \mathbb{R}^2 \rightarrow \mathbb{R}^2 \hat{=} \text{Kraftfeld}$: $\mathbf{f} : \begin{cases} \mathbf{x} \in \mathbb{R}^2 \mapsto \mathbf{f}(\mathbf{x}) \in \mathbb{R}^2 \\ \text{Position} \mapsto \text{wirkende Kraft} \end{cases}$
- $\mathbf{p}^{(k)} \hat{=} \text{Position des Teilchens im } k. \text{ Zeitschritt}$
- $\mathbf{v}^{(k)} \hat{=} \text{Geschwindigkeit des Teilchens im } k. \text{ Zeitschritt}$



Reibungsfrei!

$\tau > 0$: Zeitintervall / Zeitschritt

$k \in \mathbb{N}_0$

$$\begin{aligned} \text{(i)} \quad \mathbf{v}^{(k+1)} - \mathbf{v}^{(k)} &= \tau \cdot \frac{1}{2} (\mathbf{f}(\mathbf{p}^{(k+1)}) + \mathbf{f}(\mathbf{p}^{(k)})), \\ \text{(ii)} \quad \mathbf{p}^{(k+1)} - \mathbf{p}^{(k)} &= \tau \cdot \frac{1}{2} (\mathbf{v}^{(k+1)} + \mathbf{v}^{(k)}). \end{aligned} \quad \text{(VII.1.0.S)}$$

(ii) Änderung (Position) \sim Zeitschritt \cdot Geschwindigkeit

(i) ["Newton"] Änderung (Geschwindigkeit) \sim Zeitschritt \cdot Kraft

Spezialfall: $\mathbf{f}(\underline{x}) = -\mathbf{A}\underline{x}$, $\mathbf{A} \in \mathbb{R}^{2,2}$
(lineares Kraftfeld)

Zustandsvektor: $\underline{x}^{(k)} = \begin{bmatrix} \underline{v}^{(k)} \\ \mathbf{p}^{(k)} \end{bmatrix} \in \mathbb{R}^4$

$$[\text{VII.1.0.S}] \Rightarrow \underline{x}^{(k+1)} - \underline{x}^{(k)} = \frac{1}{2} \tau \underbrace{\begin{bmatrix} \mathbf{0} & -\mathbf{A} \\ \mathbf{I} & \mathbf{0} \end{bmatrix}}_{=: \mathbf{M} \in \mathbb{R}^{4,4}} (\underline{x}^{(k)} + \underline{x}^{(k+1)})$$

$$\Leftrightarrow \underline{x}^{(k+1)} - \underline{x}^{(k)} = \mathbf{M} (\underline{x}^{(k+1)} + \underline{x}^{(k)})$$

$$\cdot (1 - \mathbf{M})^{-1} \quad (1 - \mathbf{M}) \underline{x}^{(k+1)} = (\mathbf{M} + \mathbf{I}) \underline{x}^{(k)}$$

$$\underline{x}^{(k+1)} = \underbrace{(\mathbf{I} - \mathbf{M})^{-1} (\mathbf{I} + \mathbf{M})}_{\mathbf{A}} \underline{x}^{(k)}$$

↓
A
muss invertierbar sein!

Skalare Mehrtermrekursionen:

Fibonacci-Folge: 1 1 2 3 5 8 13 ...
 $\xi^{(k+1)} = \xi^{(k)} + \xi^{(k-1)}, \xi^{(0)} = \xi^{(1)} = 1$

$$\rightarrow m=2, \alpha_1 = \alpha_2 = 1$$

Definition VII.1.0.T (Lineare skalare Mehrtermrekursion).

Für gegebenes $m \in \mathbb{N}$ und $\alpha_1, \dots, \alpha_m \in \mathbb{R}$ heisst eine der Gleichung

$$\xi^{(k+1)} = \sum_{j=1}^m \alpha_j \xi^{(k-j+1)}, \quad k \geq m-1,$$

genügende Zahlenfolge $(\xi^{(0)}, \xi^{(1)}, \xi^{(2)}, \dots)$ eine **m-Term-Rekursion** mit Startwerten $\xi^{(0)}, \dots, \xi^{(m-1)}$.

Trick: Umwandlung in lineare Rekursion

$$\underline{x}^{(k)} = \begin{bmatrix} \xi^{(k)} \\ \xi^{(k-1)} \\ \vdots \\ \xi^{(k-m+1)} \end{bmatrix} \in \mathbb{R}^m \quad \text{Fibonacci} \quad \underline{x}^{(k)} = \begin{bmatrix} \xi^{(k)} \\ \xi^{(k-1)} \end{bmatrix}$$

$$\underline{x}^{(k+1)} = \begin{bmatrix} \alpha_1 & \alpha_2 & \dots & \alpha_m \\ 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & 1 & 0 \end{bmatrix} \underline{x}^{(k)} \in \mathbb{R}^{m,m}$$

Fibonacci:

$$A = \begin{bmatrix} 1 & 1 \\ 1 & 0 \end{bmatrix}$$

Frage: $\lim_{k \rightarrow \infty} \underline{x}^{(k)} = ?$ ("Stationärer Zustand")

7.2. Matrixdiagonalisierung

Definition VII.2.0.A (Diagonalisierbarkeit einer Matrix).

Eine quadratische Matrix $A \in \mathbb{R}^{n,n}$, $n \in \mathbb{N}$, heisst **diagonalisierbar**, wenn es eine invertierbare Matrix $S \in \mathbb{R}^{n,n}$ und Zahlen $\lambda_1, \dots, \lambda_n \in \mathbb{R}$ so gibt, dass

$$S^{-1}AS = D \quad \text{mit} \quad D = \text{diag}(\lambda_1, \dots, \lambda_n) :=$$

$$\begin{bmatrix} \lambda_1 & 0 & \dots & \dots & 0 \\ 0 & \lambda_2 & 0 & \dots & \vdots \\ \vdots & \dots & \dots & \dots & \vdots \\ \vdots & \dots & \dots & \dots & 0 \\ 0 & \dots & \dots & 0 & \lambda_n \end{bmatrix}$$

Diagonalisieren von $A \in \mathbb{R}^{n,n}$ in MATLAB:

- (i) $[S, D] = \text{eig}(A)$: berechnet **S** und **D**,
- (ii) $\text{lambda} = \text{eig}(A)$: berechnet nur die λ_i .

Kubische asymptotische Komplexität: $O(n^3)!$ *

(Billiger für manche dünnbesetzte, symmetrische Matrizen)

* Doppelt so grosse Matrix \Rightarrow 8x Rechenzeit

7.2.1. Geschlossene Darstellung von linearen Rekursionen

$$\underline{x}^{(k+1)} = A \underline{x}^{(k)}, \quad \underline{x}^{(0)} \text{ gegeben}$$

$$\Rightarrow \underline{x}^{(k)} = A^k \underline{x}^{(0)}$$

$$A \text{ diagb. : } A = S \underbrace{\text{diag}(\lambda_1, \dots, \lambda_n)}_{=: D} S^{-1} \in \mathbb{R}^{n \times n}$$

$$A^2 = S D (S^{-1} S) D S^{-1} = S D^2 S^{-1}$$

$$A^3 = S D (S^{-1} S) D (S^{-1} S) D S^{-1} = S D^3 S^{-1}$$

$$\Rightarrow A^k = S D^k S^{-1}$$

$$\underline{x}^{(0)} \in \text{Span} \{ (S)_{:,j}, j \in J^- \} =: \mathcal{E}^-$$

$$\underline{x}^{(0)} = \sum_{j \in J^-} c_j (S)_{:,j}$$

$$S^{-1} \underline{x}^{(0)} = \sum_{j \in J^-} c_j \underline{e}_j \Rightarrow S^{-1} \underline{x}^{(0)} = \begin{bmatrix} 0 \\ c_2 \\ 0 \\ \vdots \\ c_4 \\ \vdots \\ 0 \end{bmatrix}$$

$$\Rightarrow \text{diag}(\lambda_1^k, \dots, \lambda_n^k) \cdot S^{-1} \underline{x}^{(0)} \text{ bleibt beschränkt für } k \rightarrow \infty$$

$$\underline{x}^{(0)} \notin \mathcal{E}^- \Rightarrow (S^{-1} \underline{x}^{(0)})_\ell \neq 0 \text{ für ein } \ell \in \{1, \dots, n\} \text{ für das } |\lambda_\ell| > 1$$

Satz VII.2.1.K (Darstellungsformel für Glieder linearer Rekursionen).

Eine lineare Rekursion $(\mathbf{x}^{(0)}, \mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots)$ im \mathbb{R}^n (\rightarrow **Definition VII.1.0.A**) mit einer diagonalisierbaren Rekursionsmatrix $A \in \mathbb{R}^{n,n}$, $n \in \mathbb{N}$, für die $A = S \text{diag}(\lambda_1, \dots, \lambda_n) S^{-1}$, $\lambda_\ell \in \mathbb{R}$, gemäss **Definition VII.2.0.A**,

$$\mathbf{x}^{(k)} = S \text{diag}(\lambda_1^k, \dots, \lambda_n^k) S^{-1} \mathbf{x}^{(0)}, \quad k \in \mathbb{N}.$$

$$\text{Grenzwert } k \rightarrow \infty : \lim_{k \rightarrow \infty} \lambda^k = \begin{cases} \infty & , \text{ falls } |\lambda| > 1 \\ \text{X} & , \text{ falls } \lambda = -1 \\ 1 & , \text{ falls } \lambda = 1 \\ 0 & , \text{ falls } |\lambda| < 1 \end{cases}$$

Annahme $|\lambda_\ell| > 1$ und $(S^{-1} \underline{x}^{(0)})_\ell \neq 0$

$$\Rightarrow \underbrace{\left(\text{diag}(\lambda_1^k, \dots, \lambda_n^k) S^{-1} \underline{x}^{(0)} \right)_\ell}_{= S^{-1} \underline{x}^{(k)}} \rightarrow \infty \text{ für } k \rightarrow \infty$$

Wenn $|\lambda_\ell| < 1 \quad \forall \ell \Rightarrow \underline{x}^{(k)} \rightarrow 0$ für $k \rightarrow \infty$

Satz VII.2.1.N (Wachstums- und Abklingverhalten linearer Rekursionen).

Sei $A \in \mathbb{R}^{n,n}$ diagonalisierbar gemäss **Definition VII.2.0.A**: $A = S^{-1} \text{diag}(\lambda_1, \dots, \lambda_n) S$, $\lambda_\ell \in \mathbb{R}$. Wir definieren

$$J^- := \{ \ell \in \{1, \dots, n\} : |\lambda_\ell| \leq 1 \}. \quad (7.2.1)$$

und

$$\mathcal{E}^- := \text{Span}\{ (S)_{:, \ell}, \ell \in J^- \} \quad (= \{0\}, \text{ falls } J^- = \emptyset). \quad (7.2.2)$$

Dann gilt für eine lineare Rekursion $(\mathbf{x}^{(k)})_{k \in \mathbb{N}_0}$ mit Rekursionsmatrix A :

$$\mathbf{x}^{(0)} \in \mathcal{E}^- \Leftrightarrow \lim_{k \rightarrow \infty} \|\mathbf{x}^{(k)}\| < \infty.$$

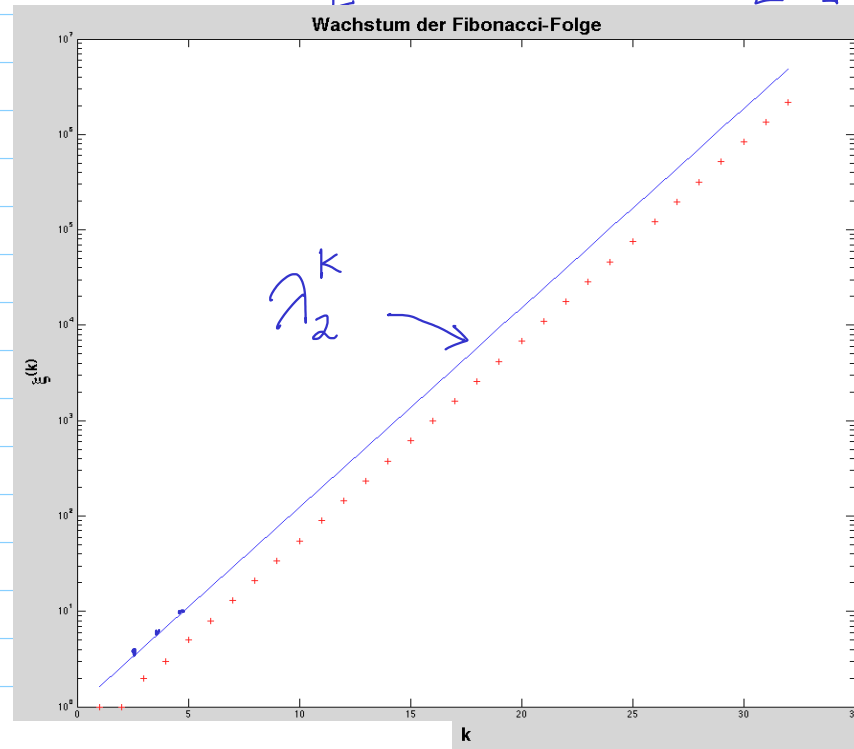
Bsp: Fibonacci-Folge $\bar{z}^{(k+1)} = \bar{z}^{(k)} + \bar{z}^{(k-1)}$, $\bar{z}^{(0)} = \bar{z}^{(1)} = 1$

Mit $\underline{x}^{(k)} = \begin{bmatrix} \bar{z}^{(k)} \\ \bar{z}^{(k-1)} \end{bmatrix}$; $k \in \mathbb{N}$

Lineare Rekursion: $\underline{x}^{(k+1)} = \begin{bmatrix} 1 & 1 \\ 1 & 0 \end{bmatrix} \underline{x}^{(k)}$, $\underline{x}^{(1)} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$

Beobachtung:
(MATLAB-Simulation)

+ $\hat{=}$ $\bar{z}^{(k)}$
/ $\hat{=}$ λ_{\max}^k



Fibonacci-Folge:

1 1 2 3 5 8 13 21 34 55

Rekursionsmatrix fuer Fibonacci-Folge:

$\begin{bmatrix} 1 & 1 \\ 1 & 0 \end{bmatrix}$

Diagonalisierung:

$$[S, D] = \text{eig}(A)$$

S =

$\begin{bmatrix} 0.5257 & -0.8507 \\ -0.8507 & -0.5257 \end{bmatrix}$

D =

$$\begin{bmatrix} -0.6180 & 0 \\ 0 & 1.6180 \end{bmatrix} = \begin{bmatrix} \lambda_1 & \\ & \lambda_2 \end{bmatrix}$$

Lineare Rekursion: $\underline{x}^{(k+1)} = A \underline{x}^{(k)}$

A diagonalisierbar: $A = S \text{diag}(\lambda_1, \dots, \lambda_n) S^{-1}$

$$\underline{x}^{(k)} = A^k \underline{x}^{(0)} = S \text{diag}(\lambda_1^k, \dots, \lambda_n^k) S^{-1} \underline{x}^{(0)}$$

Wenn: $|\lambda_j| > |\lambda_l|$, $l \neq j$ ($|\lambda_j| > 1$)

$\Rightarrow k \gg 1$ gilt $|\lambda_j^k| \gg |\lambda_l^k|$

\hookrightarrow dominiert Wachstum

\Rightarrow i.a. gilt dann $\|\underline{x}^{(k)}\| \sim |\lambda_j|^k$

$$\log \|\underline{x}^{(k)}\| \sim k \log |\lambda_j|$$

7.2.2. Matrix Funktionen

Polynom: $p(x) = \sum_{j=0}^d \alpha_j x^j$, $d \in \mathbb{N}_0 \hat{=} \text{Grad}$

mit Koeffizienten $\alpha_j \in \mathbb{R}$

$$A \in \mathbb{R}^{n,n}: p(A) = \sum_{j=0}^d \alpha_j A^j$$

A diagonal: $A = S D S^{-1}$, $D = \text{diag}(\lambda_1, \dots, \lambda_n)$

$$p(A) = \sum_{j=0}^d \alpha_j (S D S^{-1})^j = \sum_{j=0}^d \alpha_j S D^j S^{-1} = S \left(\sum_{j=0}^d \alpha_j D^j \right) S^{-1}$$

\uparrow Matrixpolynom

Da D diagonal:

$$p(A) = S \begin{bmatrix} p(\lambda_1) & & & \\ & \ddots & & \\ & & \ddots & \\ & & & p(\lambda_n) \end{bmatrix} S^{-1}$$

Zu Bsp.: VII.1.0.R "Diskretes dynamisches System"

$$\underline{x}^{(k+1)} = (I - M)^{-1} (I + M) \underline{x}^{(k)} = f(M) \underline{x}^{(k)}$$

M diagonalisierbar: $M = SDS^{-1}$, D diagonal

$$(I - M)^{-1} (I + M) = (SS^{-1} - SDS^{-1})^{-1} (SS^{-1} + SDS^{-1}) =$$

$$= [S(I - D)S^{-1}]^{-1} S(I + D)S^{-1}$$

$$[(AB)^{-1} = B^{-1}A^{-1}] = S(I - D)^{-1} S^{-1} S(I + D)S^{-1}$$

$$= S[(I - D)^{-1}(I + D)]S^{-1}$$

$$f(x) = \frac{1+x}{1-x} \quad ; \quad = S \left[\text{diag} \left(\frac{1}{1-\lambda_1}, \dots, \frac{1}{1-\lambda_n} \right) \cdot \text{diag} (1+\lambda_1, \dots, 1+\lambda_n) \right] S^{-1}$$

$$x \neq 1 \quad = S \text{diag} \left(\frac{1+\lambda_1}{1-\lambda_1}, \dots, \frac{1+\lambda_n}{1-\lambda_n} \right) S^{-1}$$

$$= S \text{diag} (f(\lambda_1), \dots, f(\lambda_n)) S^{-1}$$

∇ Nur möglich, wenn $\lambda_e \neq 1$

Definition VII.2.2.J (Allgemeine Matrixfunktionen).

Sei $A \in \mathbb{R}^{n,n}$ diagonalisierbar, $A = S \text{diag}(\lambda_1, \dots, \lambda_n) S^{-1}$, $\lambda_\ell \in \mathbb{R}$.

Ist die Funktion $\varphi : D \subset \mathbb{R} \rightarrow \mathbb{R}$ definiert auf einer (offenen) Menge D mit $\lambda_\ell \in D$ für alle $\ell \in \{1, \dots, n\}$, dann definiert

$$\varphi(A) := S \cdot \begin{bmatrix} \varphi(\lambda_1) & 0 & \dots & \dots & 0 \\ 0 & \varphi(\lambda_2) & 0 & \dots & \vdots \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ \vdots & & \ddots & \ddots & 0 \\ 0 & \dots & \dots & 0 & \varphi(\lambda_n) \end{bmatrix} \cdot S^{-1} \quad (\text{VII.2.2.H})$$

die Matrixfunktion $\varphi(A)$.

z.B. $\exp(A)$, $\sin(A)$, $\log(A)$, $A \in \mathbb{R}^{n,n}$

↑
nur definiert, wenn $\lambda_e > 0$

7.4. Eigenwerte und Eigenvektoren

$$A \in \mathbb{R}^{n \times n} \text{ diagbar: } S^{-1}AS = D := \text{diag}(\lambda_1, \dots, \lambda_n)$$

$$\left(S = [\underline{s}^1, \dots, \underline{s}^n] \right)$$

$$\Leftrightarrow \underline{AS} = SD = [\lambda_1 \underline{s}^1, \dots, \lambda_n \underline{s}^n]$$

$$= [A\underline{s}^1, \dots, A\underline{s}^n] \quad \uparrow \text{ Bsp II.3.0.J}$$

$$\Leftrightarrow A\underline{s}^j = \lambda_j \underline{s}^j, \quad j \in \{1, \dots, n\}$$

$$\Leftrightarrow (A - \lambda_j I) \underline{s}^j = \underline{0}$$

$$\Leftrightarrow 0 \neq \underline{s}^j \in \text{Kern}(A - \lambda_j I)$$

\hookrightarrow Eigenvektor zum Eigenwert λ_j

Definition VII.4.0.A (Eigenwerte und Eigenvektoren).

Sei $A \in \mathbb{R}^{n \times n}$, $n \in \mathbb{N}$.

- Eine Zahl $\lambda \in \mathbb{R}$ heisst **Eigenwert (EW)** der Matrix A , wenn $\text{Kern}(A - \lambda I) \neq \{0\}$.
- Ein Spaltenvektor $\underline{v} \in \mathbb{R}^n$, $\underline{v} \neq \underline{0}$, heisst **Eigenvektor (EV)** der Matrix A zum Eigenwert $\lambda \in \mathbb{R}$, wenn

$$A\underline{v} = \lambda \underline{v} \Leftrightarrow \underline{v} \in \text{Kern}(A - \lambda I).$$

- Ist $\lambda \in \mathbb{R}$ Eigenwert von A , so heisst $\text{Kern}(A - \lambda I)$ der **Eigenraum (ER)** zu λ .

Menge der Eigenwerte: **Spektrum** $\sigma(A)$

$$\Rightarrow A = SDS^{-1} \text{ diagbar} \Rightarrow \begin{array}{l} \text{1. Spalte von } S \text{ ist EV} \\ \text{zum EW } \lambda_j \end{array}$$

Bem.: $\downarrow \varphi: D \subset \mathbb{R} \rightarrow \mathbb{R}$

$$\varphi(A) = S \underbrace{\text{diag}(\varphi(\lambda_1), \dots, \varphi(\lambda_n))}_{\text{EW von } \varphi(A)} S^{-1}$$

$$\Rightarrow \sigma(\varphi(A)) = \{ \varphi(\lambda) : \lambda \in \sigma(A) \}$$

Bem.: $0 \notin \sigma(A) \Leftrightarrow \text{Kern}(A) = \{ \underline{0} \}$

$$\Leftrightarrow A \text{ invertierbar}$$

Satz VII.4.0.B (Kriterium für Diagonalisierbarkeit).

Eine Matrix $A \in \mathbb{R}^n$ ist genau dann diagonalisierbar im Sinn von [Definition VII.2.0.A](#), wenn es eine Basis des \mathbb{R}^n aus Eigenvektoren von A gibt.

\hookrightarrow liefert Spalten von S (invertierbar, da Basisvektoren l. u. !)

Nachweis: Orthogonale Projektionsmatrix A erfüllt $A^2 = A$:

$$A = B(B^T B)^{-1} B^T, \quad B \in \mathbb{R}^{n \times k}, \quad \text{Rang}(B) = k \leq n$$

$$A^2 = B \cancel{(B^T B)^{-1}} \cancel{(B^T B)} (B^T B)^{-1} B = A$$

Bsp.: $A = I - \underline{u}\underline{v}^T$, $\underline{u}, \underline{v} \in \mathbb{R}^n \setminus \{0\}$

↳ Tensorprodukt

• $\underline{x} \in \text{Span}\{\underline{v}\}^\perp \Rightarrow \underline{v}^T \underline{x} = \langle \underline{v}, \underline{x} \rangle = 0$

ER zum EW 1 $A\underline{x} = \underline{x} - \underbrace{\underline{u}\underline{v}^T \underline{x}}_{=0} = 1 \cdot \underline{x}$

$\Rightarrow \underline{x}$ EV zum EW 1

• Annahme: $\langle \underline{u}, \underline{v} \rangle \neq 0 \Leftrightarrow \underline{u} \notin \text{Span}\{\underline{v}\}^\perp$, $\underline{u} \neq \underline{v}$

$\Rightarrow A\underline{u} = \underline{u} - \underline{u}(\underline{v}^T \underline{u}) = (1 - \langle \underline{v}, \underline{u} \rangle) \underline{u}$

\underline{u} ist EV von A zum EW $1 - \langle \underline{v}, \underline{u} \rangle$

Diagonalisierbarkeit?

$\{\underline{b}^1, \dots, \underline{b}^{n-1}, \underline{u}\}$ l.M. \rightarrow Basis aus EV

Basis von $\text{Span}\{\underline{v}\}^\perp$

EV zum EW 1

EV zum EW $1 - \langle \underline{v}, \underline{u} \rangle$

$\sigma(A) = \{1, 1 - \langle \underline{v}, \underline{u} \rangle\}$

Bsp.: $A \in \mathbb{R}^{n \times n}$: $A^2 = A$

[z.B.: orthogonale Projektion $B(B^T B)^{-1} B^T$, $B \in \mathbb{R}^{n \times k}$, $\text{Rang}(B) = k$]

• $\underline{x} \in \text{Bild}(A) \setminus \{0\}$, $\exists \underline{w} \in \mathbb{R}^n$: $\underline{x} = A\underline{w}$

$A\underline{x} = A A \underline{w} = A^2 \underline{w} = A \underline{w} = \underline{x}$

$\Rightarrow \underline{x}$ ist EV zum EW 1

• $\underline{x} \in \text{Kern}(A) \setminus \{0\} \Rightarrow \underline{x}$ ist EV zum EW 0

• $\underline{x} \in \text{Kern}(A) \cap \text{Bild}(A)$

\downarrow $A\underline{x} = 0$ \downarrow $\underline{x} = A\underline{w}$ für ein $\underline{w} \in \mathbb{R}^n$

$0 = A\underline{x} = A(A\underline{w}) = A^2 \underline{w} = A\underline{w} = \underline{x}$

$\Rightarrow \text{Kern}(A) \cap \text{Bild}(A) = \{0\}$

$\dim(\underbrace{\text{Kern}(A) + \text{Bild}(A)}_{=\mathbb{R}^n}) = \dim(\text{Kern}(A)) + \dim(\text{Bild}(A)) - \dim(\text{Kern}(A) \cap \text{Bild}(A))$

$= \dim \text{Kern}(A) + \dim \text{Bild}(A) = n$

[nach Dimensionssatz]

$\mathcal{B} := \{\underbrace{\underline{b}^1, \dots, \underline{b}^k}_{\text{Basis von Kern}(A)}, \underbrace{\underline{q}^1, \dots, \underline{q}^{n-k}}_{\text{Basis von Bild}(A)}\} \leftarrow \text{Span} = \mathbb{R}^n$

\mathcal{B} ist Basis aus Eigenvektoren von A :

$$\left. \begin{array}{l} - b^k \text{ EV zum EW } 0 \\ - q^l \text{ EV zum EW } 1 \end{array} \right\} \Rightarrow \sigma(A) = \{0, 1\}$$

Berechnung von EW ("auf Papier")

$$\lambda \text{ EW von } A \in \mathbb{R}^{n \times n} \Leftrightarrow \text{Kern}(A - \lambda I) \neq \{0\}$$

$$[\text{III.3.0.P}] \Leftrightarrow A - \lambda I \text{ nicht invertierbar}$$

$$\Leftrightarrow \underbrace{\det(A - \lambda I)}_{\text{Funktion } \mathbb{R} \rightarrow \mathbb{R}} = 0$$

$$\det(A - \lambda I) = \det$$

↓

Polynom vom Grad $\leq n$

$$\det(M) = \sum_{i_1=1}^n \cdots \sum_{i_n=1}^n \underbrace{m_{i_1,1} \cdots m_{i_n,n}}_{n\text{-faches Produkt}} \underbrace{\sigma(i_1, \dots, i_n)}_{\in \{-1, 0, 1\}}$$

Für $M = A - \lambda I$ ↓ Polynome vom Grad n

$$\begin{bmatrix} a_{1,1} - \lambda & a_{1,2} & a_{1,3} & \cdots & a_{1,n} \\ a_{2,1} & a_{2,2} - \lambda & a_{2,3} & & \vdots \\ \vdots & & \ddots & & \vdots \\ \vdots & & & \ddots & \vdots \\ a_{n,1} & a_{n,2} & \cdots & \cdots & a_{n,n} - \lambda \end{bmatrix}$$

Definition VII.4.0.C (Charakteristisches Polynom).

Die Funktion

$$\chi_A(\lambda) := \det(A - \lambda I) = \det \begin{bmatrix} a_{1,1} - \lambda & a_{1,2} & a_{1,3} & \cdots & a_{1,n} \\ a_{2,1} & a_{2,2} - \lambda & a_{2,3} & & \vdots \\ \vdots & & \ddots & & \vdots \\ \vdots & & & \ddots & \vdots \\ a_{n,1} & a_{n,2} & \cdots & \cdots & a_{n,n} - \lambda \end{bmatrix}, \lambda \in \mathbb{R},$$

heißt das **charakteristische Polynom** der Matrix $A \in \mathbb{R}^{n,n}$, $n \in \mathbb{N}$.

↳ Polynom vom Grad $\leq n$

Beispiel ($n=2$):

$$\chi_A(\lambda) = \det \begin{bmatrix} a_{11} - \lambda & a_{12} \\ a_{21} & a_{22} - \lambda \end{bmatrix} = (a_{11} - \lambda)(a_{22} - \lambda) - a_{21}a_{12}$$

$$= \lambda^2 - (a_{11} + a_{22})\lambda + \det(A) \quad [\text{Grad } 2]$$

$$\text{Nullstellen: } \lambda_{1/2} = \frac{1}{2} \left((a_{11} + a_{22}) \pm \sqrt{D} \right), \quad D = \underbrace{(a_{11} + a_{22})^2 - 4 \det(A)}_{\text{Diskriminante, } \geq 0}$$

Beispiel ($n=3$):

$$\chi_A(\lambda) = \det \begin{bmatrix} a_{11} - \lambda & a_{12} & a_{13} \\ a_{21} & a_{22} - \lambda & a_{23} \\ a_{31} & a_{32} & a_{33} - \lambda \end{bmatrix}$$

$$= (a_{11} - \lambda)(a_{22} - \lambda)(a_{33} - \lambda) + a_{12}a_{23}a_{31} + a_{13}a_{21}a_{32}$$

$$- a_{31}(a_{22} - \lambda)a_{13} - a_{32}a_{23}(a_{11} - \lambda) - (a_{33} - \lambda)a_{21}a_{12}$$

$$= -\lambda^3 + (a_{11} + a_{22} + a_{33})\lambda^2 - (a_{11}a_{22} + a_{11}a_{33} + a_{22}a_{33} + a_{31}a_{13} + a_{32}a_{23} + a_{21}a_{12})\lambda + \det(A) \quad [\text{Grad } 3]$$

Es gilt:

$$\sigma(A) = \{ \lambda : \chi_A(\lambda) = 0 \}$$

↑
Spektrum

▷ $A \in \mathbb{R}^{n,n}$ kann höchstens n verschiedene Eigenwerte haben

(da ein Polynom vom Grad $\leq n$ höchstens n Nullstellen haben kann)

Schritte zur Diagonalisierung "von Hand"

- ① Berechne $\chi_A(\lambda)$
- ② Nullstellen von $\chi_A(\lambda)$ [Tricks for $n \geq 3$]
- ③ Berechne $\ker(A - \lambda I)$, $\sigma \in \sigma(A)$: ZSF

Resultate zu $\sigma(A)$, $\chi_A(\lambda)$:

$$T \in \mathbb{R}^{n,n} \text{ invertierbar} \Rightarrow \chi_{T^{-1}AT}(\lambda) = \chi_A(\lambda)$$

$$\begin{aligned} [\det(T^{-1}AT - \lambda I) &= \det(T^{-1}(A - \lambda I)T) = \\ \text{Determinationsmultiplikations-} &= \det(T^{-1}) \cdot \det(A - \lambda I) \cdot \det(T) \\ \text{satz!} & \end{aligned}$$

Satz VII.4.0.G (Spektrum von Matrix und Transponierter).

Für jede Matrix $A \in \mathbb{R}^{n,n}$ gilt

$$\sigma(A) = \sigma(A^T).$$

da $\det(M) = \det(M^T)$

Anwendung auf stochastische Matrizen:

$$\begin{aligned} \hookrightarrow \sum_{i=1}^n (A)_{ij} &= 1 \quad \forall j \\ \Rightarrow \sum_{j=1}^n (A^T)_{ij} &= 1 \\ \Rightarrow A^T \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} &= \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \Rightarrow 1 \in \sigma(A^T) = \sigma(A) \end{aligned}$$

Für Markov-Ketten:
mit stochastischer Rekursionsmatrix A

$$\underline{x}^{(\infty)} = \lim_{k \rightarrow \infty} \underline{x}^{(k)} \text{ erfüllt}$$

$$A \underline{x}^{(\infty)} = \underline{x}^{(\infty)}$$

↳ EV zum EW 1

Konsequenz aus :

$$\det \left(\begin{array}{c|c} \mathbf{A} & \mathbf{B} \\ \hline \mathbf{O} & \mathbf{C} \end{array} \right) = \det(\mathbf{A}) \cdot \det(\mathbf{C}), \quad \begin{array}{l} \mathbf{A} \in \mathbb{R}^{k,k}, \mathbf{B} \in \mathbb{R}^{k,m}, \\ \mathbf{C} \in \mathbb{R}^{m,m}, \mathbf{O} \hat{=} \text{Nullmatrix.} \end{array} \quad (\text{IV.5.3.L})$$

$$M = \left[\begin{array}{c|c} A & B \\ \hline O & C \end{array} \right]$$

$$\begin{aligned} \chi_M(\lambda) &= \det \left[\begin{array}{c|c} A - \lambda I & B \\ \hline & C - \lambda I \end{array} \right] \\ &= \det(A - \lambda I) \cdot \det(C - \lambda I) \\ &= \underbrace{\chi_A(\lambda) \cdot \chi_C(\lambda)}_{(*)} \end{aligned}$$

Produkt der charakteristischen Polynome

Z.B. : $k = m = 2 \Rightarrow M \in \mathbb{R}^{4,4}$, χ_M hat Grad 4, d.h. die Berechnung der Nullstellen ist i.a. unmöglich.

Aber hier lässt sich χ_M als Produkt von zwei Polynomen vom Grad ≤ 2 schreiben, deren Nullstellen über die Diskriminantenformel berechnet werden können.

Aus $(*)$: $\sigma(M) = \sigma(A) \cup \sigma(C)$

7.5. Diagonalisierbarkeit

VII.4.0.B : $A \in \mathbb{R}^{n \times n}$ diagonalisierbar $\Leftrightarrow \exists$ Basis des \mathbb{R}^n aus EV

Bsp. $A = \begin{bmatrix} 0 & 1 & 1 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix}$ nicht diagonalisierbar

Diagonalisierung auch von reellen Matrizen geht über \mathbb{C}

Rechnen in \mathbb{C} wie in \mathbb{R}

Im \mathbb{C}^n und mit komplexen Matrizen kann man (fast immer) so rechnen wie im \mathbb{R}^n , wenn man nur die Addition und Multiplikation in \mathbb{C} benutzt.

(Fast) alle Konzepte und Resultate über reelle Vektoren/Matrizen übertragen sich auch auf den komplexen Fall.

z.B. Für $A \in \mathbb{C}^{m,n}$: Kern(A), Bild(A), Rang(A).

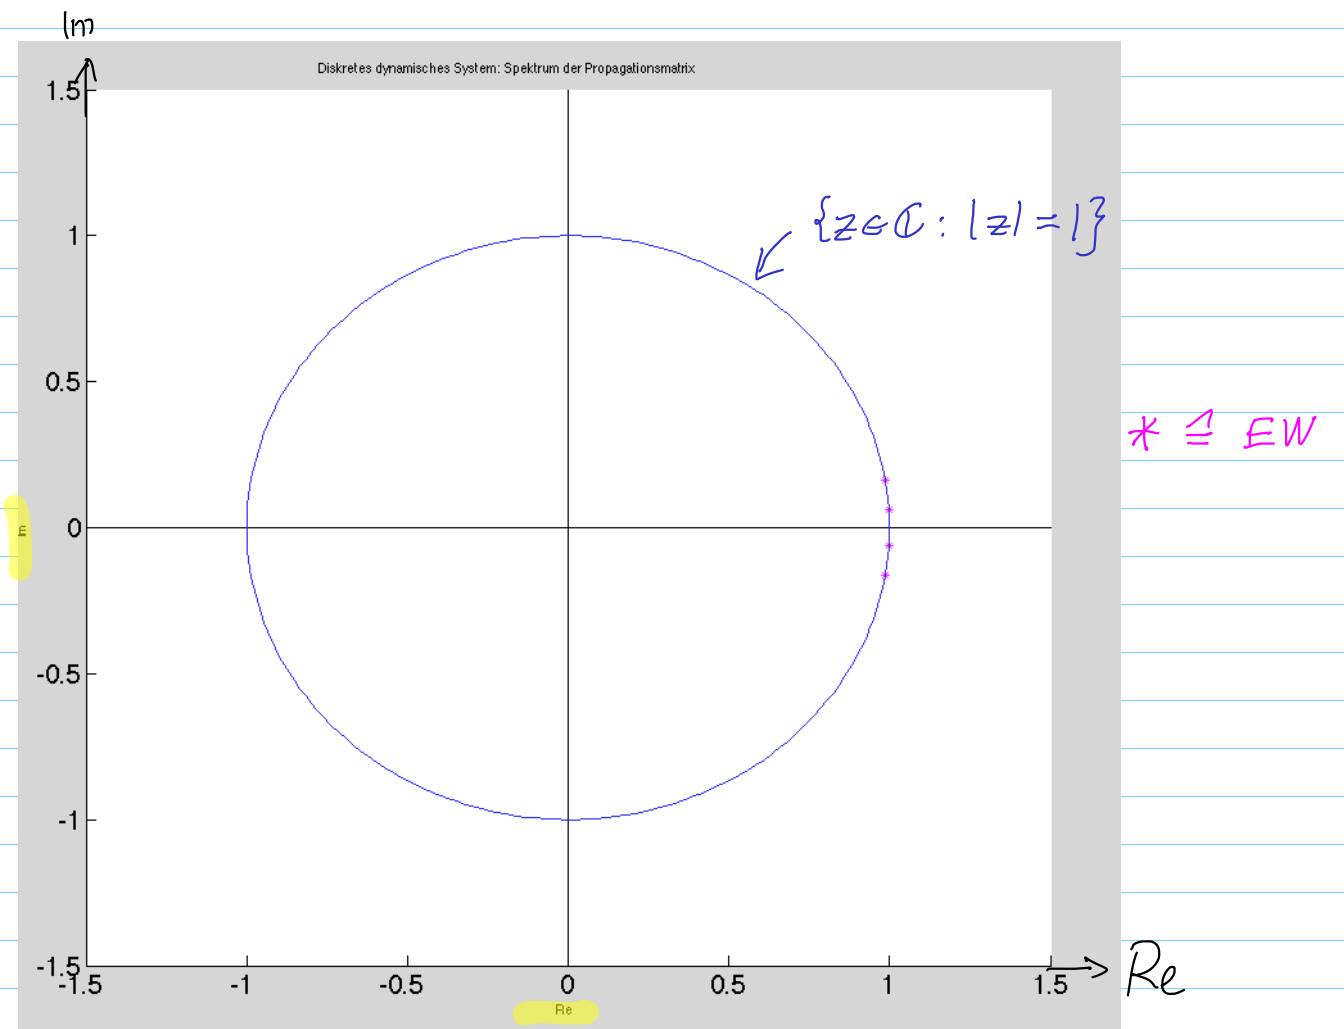
z.B. auch die Konzepte der Invertierbarkeit, Diagonalisierbarkeit, etc.

z.B. Satz über Verhalten linearer Rekursionen gilt auch für EW $\lambda_k \in \mathbb{C}$

$$x^{(k+1)} = A x^{(k)}, \quad \sigma(A) = \{\lambda \in \mathbb{C}, \chi_A(\lambda) = 0\}$$

$$\forall \lambda \in \sigma(A) \subset \mathbb{C} : |\lambda| \leq 1 \Rightarrow x^{(k)} \text{ beschränkt}$$

Anwendung auf Bsp. VII.1.0.R "Partikelbewegung"



Was ist in \mathbb{C} anders:

$$\underline{v}, \underline{w} \in \mathbb{C}^n: \langle \underline{v}, \underline{w} \rangle = \sum_{j=1}^n (v)_j \overline{(w)_j}$$

Komplexe Konjugation
↓

$$\text{Länge: } \|\underline{v}\|^2 = \sum_{j=1}^n (v)_j \overline{(v)_j} = \sum_{j=1}^n |(v)_j|^2 \geq 0$$

$$\text{In } \mathbb{R}: \langle \underline{v}, A\underline{w} \rangle = \langle A^T \underline{v}, \underline{w} \rangle$$

In \mathbb{C} : Modifizierte Transposition (zusätzlich konjugieren)

$$A \in \mathbb{C}^{m,n}: (A^H)_{k,l} = \overline{(A)_{l,k}}$$

$$\Rightarrow \langle \underline{v}, A\underline{w} \rangle = \langle A^H \underline{v}, \underline{w} \rangle \quad \forall \underline{v} \in \mathbb{C}^m, \underline{w} \in \mathbb{C}^n$$

Definition VII.3.0.C (Unitäre Matrix).

Eine Matrix $U \in \mathbb{C}^{n,n}$ heisst **unitär**, wenn $U^{-1} = U^H$.

↳ Verallgemeinerung der orth. Matrizen

Beispiel für konjugieren & transponieren:

$$\begin{bmatrix} i & -i \\ 1 & 1 \end{bmatrix}^H = \begin{bmatrix} -i & 1 \\ i & 1 \end{bmatrix}, \text{ da } \bar{i} = -i!$$

Satz VII.5.1.A (Lineare Unabhängigkeit von Eigenvektoren).

Für eine Matrix $A \in \mathbb{C}^{n,n}$ seien $v^1, \dots, v^k, k \in \{1, \dots, n\}$, Eigenvektoren zu paarweise verschiedenen Eigenwerten. Dann ist $\{v^1, \dots, v^k\}$ linear unabhängig.

$$B (k=2): \begin{aligned} Av^1 &= \lambda_1 v^1 \\ Av^2 &= \lambda_2 v^2 \end{aligned} \quad \lambda_1 \neq \lambda_2, \lambda_1 \neq 0$$

$$c_1 v^1 + c_2 v^2 = \underline{0} \quad (\text{I}), c_1, c_2 \in \mathbb{C}$$

Z.z. $c_1 = c_2 = 0$

$$\rightarrow A \cdot (\text{I}) \Rightarrow c_1 Av^1 + c_2 Av^2 = \underline{0}$$

$$\rightarrow c_1 \lambda_1 v^1 + c_2 \lambda_2 v^2 = \underline{0} \quad (\text{II})$$

$$(\text{II}) - \lambda_1 \cdot (\text{I}) \Rightarrow \underbrace{(\lambda_2 - \lambda_1)}_{\neq 0} c_2 v^2 = \underline{0} \Rightarrow c_2 = 0$$

$$v^1, v^2 \text{ EV} \Rightarrow v^2 \neq 0 \quad \square$$

Satz VII.5.1.B (Kriterien für Diagonalisierbarkeit II).

Eine quadratische Matrix $A \in \mathbb{C}^{n,n}$ mit Eigenwerten $\sigma(A) = \{\lambda_1, \dots, \lambda_k\} \subset \mathbb{C}, 1 \leq k \leq n$ ist diagonalisierbar, wenn

(i) sie n verschiedene Eigenwerte hat, oder

$$(ii) \sum_{l=1}^k \dim \text{Kern}(A - \lambda_l I) = n.$$

Satz VII.5.2.F (Diagonalisierbarkeit von **normalen** Matrizen).

Gilt für $A \in \mathbb{C}^{n,n}$, dass $AA^H = A^H A$, dann gibt es eine unitäre Matrix $U \in \mathbb{C}^{n,n}$ so, dass

$$U^{-1}AU = D := \text{diag}(\lambda_1, \dots, \lambda_n) \in \mathbb{C}^{n,n}.$$

Die $\lambda_k \in \mathbb{C}$ sind die Eigenwerte von A , die Spalten von U die zugehörige orthonormale Menge von Eigenvektoren.

M unitär $\Rightarrow M^{-1} = M^H \Rightarrow M$ spielt nur Rolle von S
 \updownarrow
 \hookrightarrow Spalten sind EV von A

$$M^H M = I$$

$$M = [u^1, \dots, u^n] : \quad \langle u^j, u^k \rangle = \begin{cases} 1, & j=k \\ 0, & \text{sonst} \end{cases}$$

Wichtige Klassen normaler Matrizen (d.h. $A^H A = A A^H$)

• $A = A^H$ ($A \in \mathbb{R}^{n,n} : A = A^T$: symmetrische Matrizen)

$$\text{In } \mathbb{C} : \quad \langle \underline{v}, \underline{w} \rangle = \overline{\langle \underline{w}, \underline{v} \rangle} \quad \forall \underline{v}, \underline{w} \in \mathbb{C}^n$$

$$\underbrace{\langle A\underline{v}, \underline{v} \rangle}_{\in \mathbb{C}} = \langle \underline{v}, A^H \underline{v} \rangle = \langle \underline{v}, A\underline{v} \rangle = \overline{\langle A\underline{v}, \underline{v} \rangle} \Rightarrow \langle A\underline{v}, \underline{v} \rangle \in \mathbb{R}$$

$\lambda \in \sigma(A)$, EV $\underline{v} \neq 0$: $A\underline{v} = \lambda \underline{v}$

$$\underbrace{\langle A\underline{v}, \underline{v} \rangle}_{\in \mathbb{R}} = \langle \lambda \underline{v}, \underline{v} \rangle = \lambda \underbrace{\langle \underline{v}, \underline{v} \rangle}_{\in \mathbb{R}} \Rightarrow \lambda \in \mathbb{R}$$

$$A = A^H \Rightarrow \sigma(A) \subset \mathbb{R}$$

\rightarrow Spezialversion falls $A \in \mathbb{R}^{n,n}$, $A = A^T$
 Dann genügt Rechnen in \mathbb{R} :

Satz VII.5.2.G (Reelle Diagonalisierbarkeit von symmetrischen Matrizen, **Hauptachsentransformation**).

Zu jeder symmetrischen Matrix $A \in \mathbb{R}^{n,n}$ gibt es eine orthogonale Matrix $Q \in \mathbb{R}^{n,n}$ so, dass


$$Q^T A Q = D = \text{diag}(\lambda_1, \dots, \lambda_n) \in \mathbb{R}^{n,n}.$$

Die Spalten von Q bilden eine Orthonormalbasis des \mathbb{R}^n aus Eigenvektoren von A .

• $A^H = -A$ ("schiefsymmetrisch")

$\lambda \in \sigma(A)$, EV $\underline{v} \neq 0$: $A\underline{v} = \lambda \underline{v}$

$$\underbrace{\langle A\underline{v}, \underline{v} \rangle}_{=: z \in \mathbb{C}} = \langle \underline{v}, A^H \underline{v} \rangle = \langle \underline{v}, -A\underline{v} \rangle = \overline{-\langle A\underline{v}, \underline{v} \rangle} = -\overline{z} \Rightarrow z \in i\mathbb{R} \text{ ("rein imaginär")}$$



\rightarrow [gleiches Argument] : $\sigma(A) \subset i\mathbb{R}$

• $A^H = A^{-1}$ (unitäre Matrizen)

$$\|Ax\|^2 = \langle Ax, Ax \rangle = \langle x, \underbrace{A^H A}_{=I} x \rangle = \|x\|^2 \quad (*)$$

$\lambda \in \sigma(A)$, v EV : $Av = \lambda v$, $v \neq 0$

$$(*) \Rightarrow 1 \cdot \cancel{\|v\|} = \|Av\| = \|\lambda v\| = |\lambda| \cancel{\|v\|}$$

$$\Rightarrow |\lambda| = 1$$