

# Lineare Algebra

## Themengebiete

- ▶ Vektoren, Matrizen
- ▶ Eigenwerte und Eigenvektoren
- ▶ Invertieren von Matrizen
- ▶ Lösen linearer Gleichungssysteme
  - ▶ Numerisches lösen von DGL

$$\Delta f(x) = g(x) \quad (1)$$

nachdem  $\Delta$  diskretisiert wurde

- ▶ Lösen von Integralgleichungen

$$f(x) = g(x) + \int_0^1 k(x, y)f(y)dy \quad (2)$$

- ▶ Lineare Fits

# Vektornorm

Sei  $X$  ein komplexer bzw. reeller Raum, und  $|\cdot|$  eine lineare Abbildung von

$$|\cdot| : X \rightarrow \mathbb{C}(\mathbb{R})$$

mit

- ▶  $|x| \geq 0$  (Positivität)
- ▶  $|x| = 0 \Leftrightarrow x = 0$  (Definitheit)
- ▶  $|\alpha \cdot x| = |\alpha| \cdot |x| \quad \forall x \in X, \quad \forall \alpha \in \mathbb{C}$  (Homogenität)
- ▶  $|x + y| \leq |x| + |y| \quad \forall x, y \in X$  (Dreiecksungleichung)

so nennt man  $|\cdot|$  eine Norm.

Beispiel:

$$|x|_1 = \sum_{i=1}^n |x_i| \quad (\text{Betragssummennorm}) \quad (3)$$

$$|x|_2 = \sqrt{\sum_{i=1}^n x_i^2} \quad (\text{Euklidische Norm}) \quad (4)$$

# Skalarprodukt

Seien  $\mathbf{x}, \mathbf{y} \in \mathbb{C}^n(\mathbb{R}^n)$  dann ist

$$\mathbf{x} \cdot \mathbf{y} = \sum_{i=1}^n x_i^* y_i \quad \text{im komplexen} \quad (5)$$

$$\mathbf{x} \cdot \mathbf{y} = \sum_{i=1}^n x_i y_i \quad \text{im reellen} \quad (6)$$

das Skalarprodukt der beiden Vektoren.

In  $\mathbb{R}^3$  gilt

$$\mathbf{x} \cdot \mathbf{y} = |\mathbf{x}| |\mathbf{y}| \cos \angle(\mathbf{x}, \mathbf{y}) \quad (7)$$

Oder in Matrixschreibweise

$$\langle \mathbf{x} | \mathbf{y} \rangle = \sum_{i=1}^n x_{1i}^* y_{i1} \quad (8)$$

# Darstellung von Vektoren und Matrizen

Typischerweise werden Vektoren und Matrizen als Listen bzw. verschachtelte Listen dargestellt

- ▶ Python:

```
a=[[1,2],[2,0]]
```

- ▶ C (z.B. GSL):

```
m->data[0*m->tda+0]=1.;  
gsl_matrix_set(m,0,1,2.);  
gsl_matrix_set(m,1,0,2.);  
gsl_matrix_set(m,1,1,0.);
```

- ▶ Mathematica:

```
a={ { 1,2}, {2,0} }
```

# Inversion der Matrix in Python (numpy)/MMA

## Python

```
import numpy as np

a=[[ 1,2],[2,0]]
ainv=np.linalg.inv(a)

print(ainv)
print(np.dot(ainv,a))
```

## Mathematica

```
a={ {1,2}, {2,0} }
ainv=Inverse[a]
ainv.a
```

## Output

```
MathematicaScript -print all -f ./testmath
{{ 1, 2}, {2, 0}}
{{ 0, 1/2}, {1/2, -1/4}}
{{ 1, 0}, {0, 1}}
```

# Inversion der Matrix in gsl

```
#include <stdio.h>
#include ``gsl/gsl_matrix.h``
#include ``gsl/gsl_linalg.h``

int main()
{

gsl_matrix *m;
gsl_matrix *minv;
gsl_permutation *p;
int s;

p=gsl_permutation_calloc(2);
m=gsl_matrix_alloc(2,2);
minv=gsl_matrix_alloc(2,2);

m->data[0*m->tda+0]=1.;
gsl_matrix_set(m,0,1,2.);
gsl_matrix_set(m,1,0,2.);
gsl_matrix_set(m,1,1,0.);

gsl_linalg_LU_decomp (m, p, &s);
gsl_linalg_LU_invert (m,p,minv);

printf(``The inverse is\n``);

printf(``%lf , %lf\n``,gsl_matrix_get(minv,0,0),gsl_matrix_get(minv,0,1));
printf(``%lf , %lf\n``,gsl_matrix_get(minv,1,0),gsl_matrix_get(minv,1,1));

return 0;

}
```

# Vektoren und Matrizen in der Physik

Praktisch werden in der Physik ständig Vektoren und Matrizen gebraucht:

- ▶ Mechanik (Kräftevektoren)
- ▶ Geometrische Optik
- ▶ Quantenmechanik

Einige Definitionen sind hierbei gebräuchlich, insbesondere hinsichtlich Darstellung von Matrizen über ihre Einträge.

# Matrizen

Darstellung einer Matrix über Einträge (*Koordinatenform*)

$$A_{n \times m} = a_{ij} \text{ mit } i \leq n, j \leq m \quad (9)$$

In dieser Schreibweise ist das Produkt zweier Matrizen:

$$A \cdot B = \sum_j a_{ij} b_{jm} = a_{ij} b_{jm} = c_{im} \quad (10)$$

Damit sind auch die beim Skalarprodukt eingeführten *bras* und *kets*

$$\langle x |_i = x_{1i} \quad (\text{Zeilenvektor}) \quad (11)$$

$$|y \rangle_i = y_{i1} \quad (\text{Spaltenvektor}) \quad (12)$$

Man lässt häufig die Summenzeichen weg und meint das über gleiche Indices summiert wird  $\equiv$  Einsteinsche Summenkonvention.



## Einige Operationen mit Matrizen:

- ▶ Transposition

$$\begin{aligned}A^T &= (a_{ij})^T = a_{ji} \\(A \cdot B)^T &= (a_{ij}b_{jm})^T = b_{mj}a_{ji} = B^T \cdot A^T\end{aligned}\quad (13)$$

- ▶ Adjungierte

$$(A^T)^* = A^\dagger = \left( (a_{ij}^T)^* \right) = a_{ji}^* \quad (14)$$

- ▶ Spur

$$\text{Tr}(A) = a_{ii} \quad (15)$$

- ▶ Determinante

$$\det A = \epsilon_{i_1 \dots i_n} a_{1i_1} \dots a_{ni_n} \quad (16)$$

- ▶  $\epsilon$  ist der Levi-Civita-Tensor mit den Eigenschaften

$$\epsilon_{ijk\dots} = \begin{cases} +1 & \text{falls } (i, j, k, \dots) \text{ gerade Permutation} \\ -1 & \text{falls } (i, j, k, \dots) \text{ ungerade Permutation} \\ 0 & \text{wenn mindestens zwei Indices gleich sind} \end{cases} \quad (17)$$

- ▶ Häufig auch Kreuzprodukt zweier Vektoren in Matrixschreibweise

$$(\vec{a} \times \vec{b})_i = \epsilon_{ijk} a_j b_k \quad (18)$$

Hier das Bsp.

$$\vec{a} \cdot (\vec{a} \times \vec{b}) = a_i \epsilon_{ijk} a_j b_k = -\epsilon_{jik} a_i a_j b_k = 0 \quad (19)$$

Besondere Matrizen, z.B.

- ▶ Hermitesch (Symmetrisch)

$$A^\dagger = A \quad (20)$$

$$(a_{ij})^\dagger = a_{ji}^* = a_{ij} \quad (21)$$

- ▶ Unitär (Orthogonal)

$$A^\dagger = A^{-1} \quad (22)$$

Weshalb sind diese beiden Eigenschaften so besonders?

- ▶ Hermitesch  $\Rightarrow$  reelle Eigenwerte (physik. Observable)
- ▶ Unitär  $\Rightarrow$  Normerhaltende Transformationen (Basiswechsel), alle EW liegen auf Einheitskreis

## Zeige beide Eigenschaften in Hilbertraum

Hermiteisch (sei  $A$  Eigenzustand zu  $O$  mit Eigenwert  $a$ ), d.h.

$$O|A\rangle = a|A\rangle$$

Zunächst versteht sich in bra-ket-Schreibweise

$$\begin{aligned} O|A\rangle^\dagger &= \left( O_{ij} A_{j1} \right)^\dagger \\ &= \left( A_{1j}^* O_{ji}^* \right) \\ &= \langle A|O^\dagger \end{aligned} \tag{23}$$

$$\begin{aligned} \langle A|O|A\rangle &= a\langle A|A\rangle \\ \langle A|O|A\rangle &= \langle A|O^\dagger|A\rangle^* = \langle A|O|A\rangle^* \\ &= a^*\langle A|A\rangle \\ \Rightarrow a &= a^* \end{aligned} \tag{24}$$

## Zeige beide Eigenschaften in Hilbertraum

Operator  $U$  ist unitär.

$$\begin{aligned}\langle A|A\rangle &= \langle A|\underbrace{U^\dagger U}_1|A\rangle \\ &= \underbrace{(\langle A|U^\dagger)}_{u^* \langle A|} \underbrace{(U|A\rangle)}_{u|A\rangle} \\ &= u^* u \langle A|A\rangle \\ \Rightarrow u^* u &= 1\end{aligned}\tag{25}$$

Eigenwerte haben Norm 1  $\Rightarrow u = e^{i\phi}$

Häufige Frage: Finde eine unitäre Transformation, sodass eine Matrix Diagonalform annimmt (z.B. Hauptachsentransformation)

# Eigenwerte und Eigenvektoren

- ▶ Eigenwertgleichung für Operator  $O$  mit EV  $A_i$  und EW  $n_i$

$$OA_i = n_i A_i \quad (26)$$

- ▶ Bestimmung über charakteristisches Polynom

$$\det(O - \lambda I) = 0 \quad (27)$$

Nullstellen sind die Eigenwerte.

- ▶ Trafo

$$UOU^\dagger = \tilde{O} \quad (28)$$

wobei  $U$  zeilenweise EV sind

$$U = \begin{pmatrix} A_{1,1} & A_{1,2} & \dots & A_{1,n} \\ \vdots & \vdots & \vdots & \vdots \\ A_{n,1} & A_{n,1} & \dots & A_{n,n} \end{pmatrix} \quad (29)$$

- ▶ Maximaler EW (betragsmässig) wird spektraler Radius genannt

$$\rho(A) = \max\{|\lambda| \mid \lambda \in \sigma(A)\} \quad (30)$$

Beispiel:

$$M = \begin{pmatrix} 2 & 1 \\ 1 & -2 \end{pmatrix}$$

$$\det(M - \lambda I) = \lambda^2 - 5 = 0$$

$$\lambda_{1,2} = \pm\sqrt{5}$$

$$(M - \lambda_{1,2}I)v_{1,2} = 0$$

$$v_1 = (2 - \sqrt{5}, 1)$$

$$v_2 = (2 + \sqrt{5}, 1)$$

$$U = \begin{pmatrix} 2 - \sqrt{5} & 1 \\ 2 + \sqrt{5} & 1 \end{pmatrix}$$

$$UMU^\dagger = \begin{pmatrix} -10(-2 + \sqrt{5}) & 0 \\ 0 & 10(2 + \sqrt{5}) \end{pmatrix} \quad (31)$$

# Matrixzerlegungen

- ▶ Für alle Matrizen  $A \in \mathbb{C}^{n \times n}$  existiert eine unitäre Matrix  $U \in \mathbb{C}^{n \times n}$  derart, dass

$$M = UAU^\dagger \quad (32)$$

eine rechte obere Dreiecksmatrix ist.

- ▶ Sollte  $A$  hermitesch sein ist  $M$  diagonal.
- ▶ Definiere die Konditionszahl einer Matrix  $A$

$$\text{cond}(A) = \|A\|_a \|A^{-1}\|_a \quad (33)$$

mit  $\|A\|_a := \sup_{\|x\|_a=1} \|Ax\|_a$  induzierte Matrixnorm. Je größer

diese Zahl, desto schlechter konvergieren iterative Löser

- ▶ Schreibe Matrix  $A \in \mathbb{R}^{n \times n}$  um

$$UAV^T = \text{diag}\{\sigma_1, \dots, \sigma_n\} \quad (34)$$

mit  $U$  und  $V$  orthogonale Matrizen und

$$0 < \sigma_1 \leq \dots \leq \sigma_n \quad (\text{Singularwerte}) \quad (35)$$



# Singulärwertzerlegung

- ▶ Bestimmungsgleichung der Singulärwerte

$$\det(A^T A - \sigma_i^2 I) = 0 \quad (36)$$

- ▶ SW sind EW von  $A^T A$
- ▶ Damit ist  $V$  unitäre (orthogonale) Trafo

$$VA^T AV^T = \text{diag}\{\sigma_1^2, \dots, \sigma_n^2\} \quad (37)$$

zeilenweise EV von  $A^T A$

- ▶  $U$  lässt sich über das Inverse bestimmen

$$U = \text{diag}\{\sigma_1, \dots, \sigma_n\} (AV^T)^{-1} \quad (38)$$

- ▶ Konditionszahl ist dann

$$\text{cond}(A) = \frac{\sigma_n}{\sigma_1} \quad (39)$$

Singulärwertzerlegung hat viele Anwendungen

- ▶ Einfache Bildung der inversen, da  $U$  und  $V$  unitär (orthogonal sind) braucht nur noch die Kehrwerte der Diagonalmatrix
- ▶ Bestimmung der Pseudoinversen
- ▶ Lösung des LeastSquare-Problems

Es existieren noch weitere Zerlegungen (LR, QR, Cholesky usw.)

# Inversion von Matrizen

Generell gehen wir von quadratischen Matrizen aus.

- ▶ Direkte Verfahren z.B. über Adjunkte, SVD oder andere Zerlegungen
- ▶ Iterative Verfahren (Splitting-Verfahren z.B. Jacobi)

Frage der Eindeutigkeit von Lösungen zu  $Ax = b$

- ▶ Inverse existiert wenn  $\det(A) \neq 0$
- ▶  $\vdots$

$$A^{-1} = \frac{\text{adj}(A)}{\det(A)} \quad (40)$$

# Verfahren über Adjunkte

Die Adjunkte ist definiert

$$\text{adj}(A) = \begin{pmatrix} \tilde{a}_{11} & \tilde{a}_{12} & \cdots & \tilde{a}_{1n} \\ \tilde{a}_{21} & \tilde{a}_{22} & \cdots & \tilde{a}_{2n} \\ \vdots & & \ddots & \\ \tilde{a}_{n1} & \tilde{a}_{n2} & \cdots & \tilde{a}_{nn} \end{pmatrix}^T$$

$$\tilde{a}_{ij} = (-1)^{i+j} \det \begin{pmatrix} a_{11} & \cdots & a_{1j-1} & a_{1j+1} & \cdots & a_{1n} \\ \vdots & \ddots & \vdots & \vdots & \vdots & \\ a_{i-11} & \cdots & a_{i-1j-1} & a_{i-1j+1} & \cdots & a_{i-1n} \\ a_{i+11} & \cdots & a_{i+1j-1} & a_{i+1j+1} & \cdots & a_{i+1n} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \\ a_{n1} & \cdots & a_{nj-1} & a_{nj+1} & \cdots & a_{nn} \end{pmatrix} \quad (41)$$

# Python

```
import numpy as np

def adjunkte(a):
    b=np.zeros( (len(a),len(a)))
    for i in range(len(a)):
        for j in range(len(a)):
            subdet=np.linalg.det(np.delete(np.delete(a,i,0),j,1))
            b[i,j]=(-1)**(i+j)*subdet
    return np.transpose(b)

def inv(a):
    return adjunkte(a)/np.linalg.det(a)
```

# Über SVD

- ▶ Nutze aus, dass in der Zerlegung

$$USV^T = A \quad (42)$$

U und T unitär (orthogonal) sind

$$\begin{aligned} A^{-1} &= (V^T)^{-1} S^{-1} U^{-1} \\ &= VS^{-1}U^T \end{aligned} \quad (43)$$

- ▶ Die inverse der Diagonalmatrix sind einfach die Kehrwerte in der Diagonalen

# Splitting-Verfahren

Ziel ist es eine Fixpunktiteration zu bekommen

$$x_{n+1} = F(x_n) \quad (44)$$

Wir lösen allgemein:

$$A\mathbf{x} = \mathbf{b} \quad (45)$$

- ▶ Iterationsverfahren ist geg. durch Abbildung  $F : \mathbb{C}^n \times \mathbb{C}^n \rightarrow \mathbb{C}^n$  und heißt linear wenn

$$F(\mathbf{x}, \mathbf{b}) = M\mathbf{x} + N\mathbf{b} \quad (46)$$

- ▶  $\mathbf{x} \in \mathbb{C}^n$  bezeichnen wir als Fixpunkt der Abb.  $F : \mathbb{C}^n \times \mathbb{C}^n \rightarrow \mathbb{C}^n$ , wenn

$$\mathbf{x} = F(\mathbf{x}, \mathbf{b}) \quad (47)$$

mit  $\mathbf{b} \in \mathbb{C}^n$ .

- ▶  $F$  heißt konsistent zur Matrix  $A$ , wenn

$$\mathbf{x} = \lim_{n \rightarrow \infty} \mathbf{x}_n = \lim_{n \rightarrow \infty} F(\mathbf{x}_{n-1}, \mathbf{b}) \quad \text{unabh. vom Startwert}$$

- ▶ Iterationsverfahren genau dann konvergent wenn

$$\rho(M) < 1 \quad (48)$$

der Spektralradius der Iterationsmatrix  $< 1$  ist.

- ▶ Splitting-Methode

$$\begin{aligned} A &= B + (A - B) \\ \Rightarrow A\mathbf{x} &= \mathbf{b} \\ B\mathbf{x} &= (B - A)\mathbf{x} + \mathbf{b} \\ \rightarrow \mathbf{x} &= \underbrace{B^{-1}(B - A)}_M \mathbf{x} + \underbrace{B^{-1}}_N \mathbf{b} \end{aligned} \quad (49)$$

- ▶ Lineares Iterationsverfahren

$$x_{n+1} = F(x_n, b) = Mx_n + Nb \quad (50)$$



# Jacobi-Verfahren

- ▶ Wenn  $A$  nichtverschwindende Diagonalelemente aufweist  $a_{ij} \neq 0$  benutze

$$D = \text{diag}\{a_{11}, \dots, a_{nn}\}$$

$$M = D^{-1}(D - A)$$

$$N = D^{-1}$$

Iteration

$$x = D^{-1}(D - A)\mathbf{x} + D^{-1}\mathbf{b} \quad (51)$$

- ▶ Wiederum Inversion der Diagonalmatrix ist sehr einfach.
- ▶ Konvergenz wenn spektraler Radius von  $M < 1$

## Weitere Verfahren

- ▶ Gauß-Seidel  $\equiv$  Splittingverfahren
- ▶ Mehrgitterverfahren
- ▶ Projektive Verfahren (Krylov-Unterraum-Methoden)

# Nichtquadratische Matrizen

Was macht man bei Nichtquadratischen Matrizen  $A \in \mathbb{R}^{m \times n}$ ?

- ▶ Erzeuge quadratische Matrix

$$\begin{aligned} Ax &= b \\ \Rightarrow A^T Ax &= A^T b \\ x &= \underbrace{(A^T A)^{-1}}_P A^T b \end{aligned} \quad (52)$$

P ist pseudoinverse

- ▶ Sollte  $A^T A$  nicht invertierbar sein definiert man die Pseudoinverse über die SVD bei der man die SW  $< \epsilon$  vernachlässigt.

# Least-Squares-Problem

- ▶ Beziehung zum Least-Squares-Problem

$$r = Ax - y \quad (53)$$

definiert das Residuum, dann ist das Abstandsquadrat

$$\begin{aligned} |r|^2 = r^T r &= (x^T A^T - y^T)(Ax - y) \\ &= x^T A^T Ax - x^T A^T y - y^T Ax + y^T y \\ &= x^T A^T Ax - 2y^T Ax + y^T y \end{aligned} \quad (54)$$

- ▶ Finde das Minimum (1. Abl Null setzen)

$$\begin{aligned} \nabla |r|^2 &= 2A^T Ax - 2yA^T = 0 \\ \Rightarrow A^T Ax &= A^T y \end{aligned} \quad (55)$$