

Fs 2024

Numerische Methoden

VERSION 2V+1U(+2P) ITET+PHYS

Güte?

Defalgebraische Konvergenz $E(N) = O\left(\frac{1}{N^p}\right)$ mit $p > 0$ $\sim \frac{1}{N^p}$ für N gross§ 1 Quadratur

20.02.2024.

exponentielle Konvergenz

 $E(N) = O(q^N)$ mit $0 < q < 1$ § 1.1. GrundlagenBemRiemann / Darboux Summe numerisch
nicht verwendbar!"gegeben" $f: [a, b] \rightarrow \mathbb{R}/\mathbb{C}$ "glatt"

Ziel

$$\int_a^b f(t) dt \approx \sum_{i=1}^N w_i f(x_i) = Q_N(f, a, b)$$

\downarrow Knoten $x_i \in [a, b]$

Quadraturformel

Gewichte

Idee

kompliziert einfacher

$$f \underset{p}{\approx} f_n$$

$$p \underset{n}{\approx} p_n$$

$$V_n = \text{Span} \{b_1, \dots, b_n\}$$

exakt

(lin. Raum. V
 ∞ -dim.) f "bekannt" nur in x_1, x_2, \dots, x_N Möchte Fehler $E(N) = \left| \int_a^b f(t) dt - Q_N(f, a, b) \right| \rightarrow 0$
"schnell", systematisch $N \rightarrow \infty$

$$\int_a^b f(t) dt \approx \int_a^b f_n(t) dt = \sum_{i=1}^n \alpha_i \int_a^b b_i(t) dt$$

$$\int_a^b f(t) dt = \alpha_1 b_1 + \alpha_2 b_2 + \dots + \alpha_n b_n$$

Bsp $b_k(t) = t^k \Rightarrow$ Approximation mit Polynome.

oder

$$b_k = e^{ikx} = \cos kx + i \sin kx \quad \text{Fourier / Trigonometrische Polynome.}$$

Z.B. Polynomiale Interpolation

Gegebene c_1, \dots, c_n

Suche $p(t) = \alpha_0 + \alpha_1 t + \alpha_2 t^2 + \dots + \alpha_{n-1} t^{n-1}$

so dass $p(c_j) = f(c_j)$ für $j=0, 1, 2, \dots, n-1$

\Rightarrow LGS für $\alpha_0, \alpha_1, \dots, \alpha_{n-1}$ mit $n \times n$

Vandermonde Matrix

schlecht konditioniert

(große Rundungsfehler)

polyfit

Bei es gibt bessere Methoden

(Dokument Kap III, nicht besprochen)

Def Lagrange Polynome zu Knoten c_1, \dots, c_j

$$\left\{ l_j(t) = \prod_{i=1, i \neq j}^n \frac{t - c_i}{c_j - c_i} \right. \quad \text{Polynom Grad } n-1$$

$j = 1, 2, \dots, n$

$$l_j(c_i) = \begin{cases} 0 & , i \neq j \\ 1 & , i = j \end{cases}$$

\Rightarrow Basis in $P_n = \{ p \text{ Polynom von Grad } \leq n-1 \}$

$$f(t) = \sum_{j=1}^n f(c_j) l_j(t)$$

Für Quadratur: $\int_a^b f(t) dt \approx \sum_{j=1}^n f(c_j) \underbrace{\int_a^b l_j(t) dt}_{w_j}$

Bew 1) äquidistante c_1, \dots, c_s und D gross \rightsquigarrow  D.h.

2) es gibt optimale Verteilung von c_1, \dots, c_s
[Kap III nicht besprochen]

3) Feste $c_1, c_2, \dots, c_s \Rightarrow$ nur w_1, w_2, \dots, w_s frei

Dann kann man Polynome vom Grad $\leq D-1$

4) Wären $c_1, \dots, c_s, w_1, \dots, w_s$ frei wählbar

$\Rightarrow P_{2D-1}$ Polygon von Grad $\leq 2D-1$

Ziel: QF soll exakt sein für gewisses P_D

Def Quadraturformel hat Ordnung $n+1$

(Genauigkeitsgrad n)

Wenn sie Polynome von Grad maximal n exakt integriert.

$$\int_a^b p(t) dt = Q(p, a, b)$$

für alle p Polynome Grad max 2.

$1, t, t^2, \dots, t^n$ exakt integriert

$$p \in P_{n+1}$$

Bew Man kann beweisen: ($b-a$'s Grad $n+1$)

Wenn $f \in C^n[a, b]$ und QF exakt für alle in P_n :

$$\left| \int_a^b f(t) dt - Q(f, a, b) \right| \leq \frac{1}{n!} (b-a) \max_{z \in [a, b]} |f^{(n)}(z)|$$

Länge des Intervalls

Glättung

Wichtig:

Idee Zerlege

$$\int_a^b f(t) dt = \sum_{k=0}^{N-1} \int_{x_k}^{x_{k+1}} f(t) dt$$

z.B. mit äquidistanten $x_k = x_0 + kh$, $h = \frac{b-a}{N}$
mit N gross

$$N = \frac{b-a}{h}$$

$$\leq C \cdot \frac{h^{n+1}}{n!} \sum_{k=0}^n 1 = C \cdot \frac{h^{n+1}}{n!} N = C \cdot \frac{h^{n+1}}{n!} \cdot \frac{b-a}{h} = C \cdot (b-a) \frac{h^n}{n!}$$

Idee Wenn f glatt auf jeder $[x_k, x_{k+1}]$ verwendet großes n .

und verwendet die QF auf jedes $[x_k, x_{k+1}]$

\Rightarrow zusammen gesetzte Quadraturformel.

Fehler: $\left| \int_a^b f(t) dt - \sum_{k=0}^{N-1} Q(f, x_k, x_{k+1}) \right| \leq$

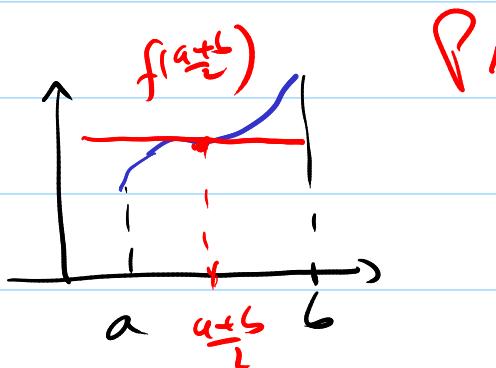
$$\leq \sum_{k=0}^{N-1} \left| \int_{x_k}^{x_{k+1}} f(t) dt - Q(f, x_k, x_{k+1}) \right| \leq$$

$$\leq \sum_{k=0}^{N-1} \frac{1}{n!} h^{n+1} \max_{z \in [x_k, x_{k+1}]} |f^{(n)}(z)|$$

$$\boxed{\max_{z \in [x_k, x_{k+1}]} |f^{(n)}(z)| = C}$$

Bsp/ Mittelpunktsregel.

(MPR) $Q(f, a, b) = (b-a) f\left(\frac{a+b}{2}\right)$



Bew 1) Polynome vom Grad 0 und 1 werden durch (MPR) exakt integriert
(MPR) Q-Ordnung 2

Fehler $\leq \frac{(b-a)^3}{3!} f''(z), z \in [a, b]$

Zusammengefasst: $C \cdot h^2 \max_{x \in [a, b]} |f''(x)|$

$$\int_a^b f(t) dt \approx \sum_{k=0}^{n-1} h f(a + k \frac{h}{n}) = \frac{b-a}{n} \sum_{k=0}^{n-1} f(x_0 + k \frac{h}{n})$$

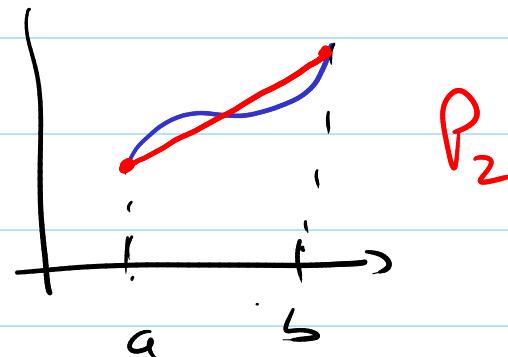
$$h = \frac{b-a}{n}$$

offene QF: Enden des Intervalls sind keine Knoten.

Knoten $c_i = \frac{a+b}{2}$, Gewicht $w_i = (b-a)$.

Bsp 2 Trapezregel

$$(TR) Q(f, a, b) = \frac{b-a}{2} f(a) + \frac{b-a}{2} f(b)$$



$$c_1 = a, c_2 = b, w_1 = \frac{b-a}{2}, w_2 = \frac{b-a}{2}$$

$$Q\text{-Ordnung: } 2; \text{ lokaler Fehler } \frac{1}{2!} \frac{(b-a)^3}{3} f''(z) \quad z \in (a, b)$$

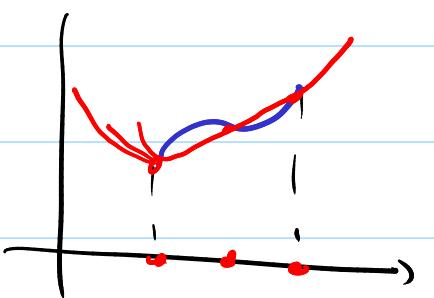
Zusammen gesetzte (TR): Fehler $O(h^2)$

$$\int_a^b f(x) dx \approx \frac{h}{2} f(x_0) + h \sum_{k=1}^{n-1} f(x_k) + \frac{h}{2} f(x_n)$$

geschlossene QF: beide Enden sind Knoten.

Bsp $f = f_n \in P_3$ exakt (Quadratische) Simpson Regel

$$(SR) Q(f, a, b) = \frac{b-a}{6} f(a) + \frac{b-a}{6} f(\frac{a+b}{2}) + \frac{b-a}{6} f(b)$$



$$c_1 = a, c_2 = \frac{a+b}{2}, c_3 = b$$

$$w_1 = \frac{b-a}{6}, w_2 = \frac{b-a}{6}, w_3 = \frac{b-a}{6}$$

Ben Polyno. bis Grad 2 und Grad 3 exakt integriert.

(Q-Ordnung 4) \Rightarrow

$$\text{lokaler Fehler} \cdot c \cdot \left(\frac{b-a}{2}\right)^5 f^{(4)}(z), z \in [a,b]$$

zusammengesetzt: $O(h^4)$.

(TR) auf $[0,1]$: $c_0=0, c_1=1$

$$w_1 = \frac{1}{2}, w_2 = \frac{1}{2}$$

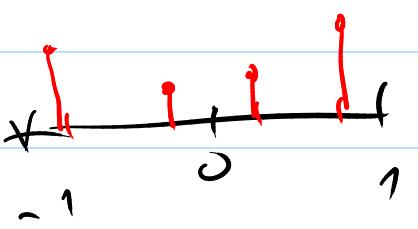
(TR) auf $[-1,1]$: $c_0=-1, c_1=1$

$$w_1 = 1, w_2 = 1$$

Def

QF auf $[-1,1]$ heißt symmetrisch.

falls $c_k = -c_{n+1-k}$



Ben Normalerweise QF auf ein Referenzintervall!

$$\begin{aligned} t &= \frac{1}{2}(1-z)a + \frac{1}{2}(1+z)b \\ dt &= \frac{b-a}{2} dz \\ t &= (1-y)a + yb \\ dt &= (b-a)dy. \end{aligned}$$

$$\int_a^b f(t) dt = \int_{-1}^1 f(z) \frac{b-a}{2} dz = \frac{b-a}{2} \int_{-1}^1 f(z) dz$$

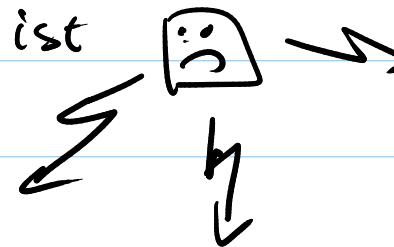
$$\hat{f}(z) = f\left(\frac{1}{2}(1-z)a + \frac{1}{2}(1+z)b\right)$$

T Q-Ordnung einer sym. QF ist gerade

$\begin{pmatrix} \rightarrow (\text{MPR}) \text{ Ordnung } 2 \\ \cdot \quad (\text{SR}) \text{ Ordnung } 4 \end{pmatrix}$

Bem grüsseres D bei äquidistante Knoten.

ist



Loffe nicht!

Tschebyschöff | Chebyshev

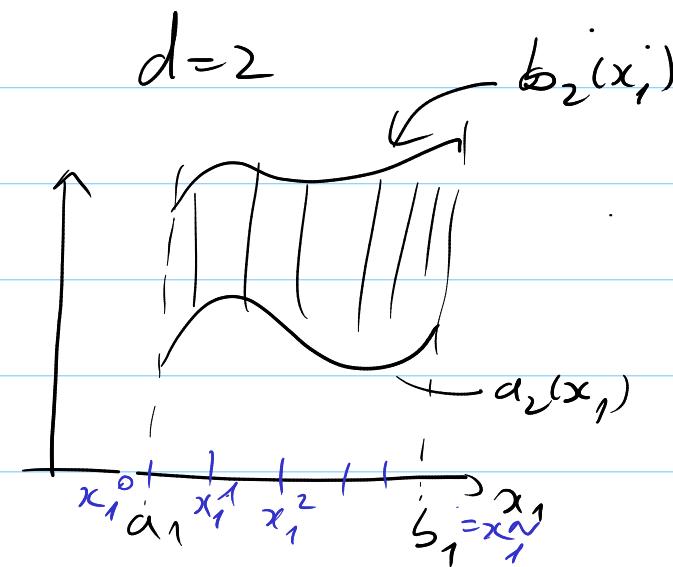
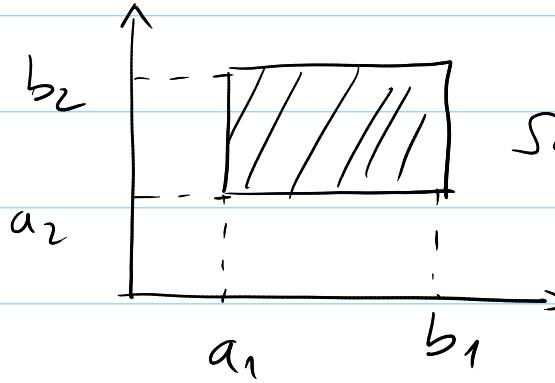
Theorem $f \in C^n([a, b])$, QF mit Q-Urdarz z:

$$1) \left| \int_a^b f(x) dx - Q(f, a, b) \right| \leq c(b-a)^{n+1} \max_{x \in [a, b]} |f^{(n)}(x)|$$

$$2) \left| \int_a^b f(x) dx - \sum_{k=0}^{n-1} h \sum_{j=1}^n b_j f(x_k + c_j h) \right| \leq$$

$$\leq c \cdot (b-a) h \max_{x \in [a, b]} |f^{(n)}(x)|$$

§1.2 Quadratur in \mathbb{R}^d



$$= h_1 \sum_{k_1=1}^{N_1} \sum_{j_1=1}^{P_1} b_{j_1} \int_{x_1^{k_1-1} + h_1 c_{j_1}^1}^{x_1^{k_1} + h_1 c_{j_1}^1} f(x_1^{k_1-1} + h_1 c_{j_1}^1, x_2) dx_1$$

Σ zusammengesetzte QT

$$= h_1 \sum_{k_1=1}^{N_1} \sum_{j_1=1}^{P_1} b_{j_1} h_2 \sum_{k_2=1}^{N_2} \sum_{j_2=1}^{P_2} b_{j_2} f(x_1^{k_1-1} + h_1 c_{j_1}^1, x_2^{k_2-1} + h_2 c_{j_2}^2) =$$

$$I = \int_{\Omega} f(x_1, x_2) dx_1 dx_2 = \int_{a_1}^{b_1} \int_{a_2(x_1)}^{b_2(x_1)} f(x_1, x_2) dx_2 dx_1$$

$$= \int_{a_1}^{b_1} F(x_1) dx_1 \approx \sum_{k_1=1}^{N_1} \int_{x_1^{k_1-1}}^{x_1^{k_1}} F(x_1) dx_1 =$$

N_1, P_1, N_2, P_2 Knoten.

In d-Dimensionen $N_1, P_1, N_2, P_2, \dots, N_d, P_d$

$N_1 = N_2 = \dots = N_d, P_1 = P_2 = \dots = P_d$

$\Rightarrow N^{d,p}$ zu teuer [?]

$$\frac{b_1 - a_1}{N_1} \sum_{k_1=1}^{N_1} \sum_{j_1=1}^{P_1} F(x_1^{k_1-1} + h_1 c_{j_1}^1) b_{j_1} =$$

Knoten Gewichte auf Referenzintervall $(0,1)$

```
In [13]: from scipy import integrate
```

```
from numpy import sqrt
f = lambda x: 1/sqrt(abs(x))
integrate.quad(f, -1, 1)
```

```
<ipython-input-13-61ff175c15de>:2: RuntimeWarning: divide by zero encountered in double_scalar
  f = lambda x: 1/sqrt(abs(x))
<ipython-input-13-61ff175c15de>:3: IntegrationWarning: The maximum number of subdivisions (50)
has been achieved.
  If increasing the limit yields no improvement it is advised to analyze
  the integrand in order to determine the difficulties. If the position of a
  local difficulty can be determined (singularity, discontinuity) one will
  probably gain from splitting up the interval and calling the integrator
  on the subranges. Perhaps a special-purpose integrator should be used.
  integrate.quad(f, -1, 1)
```

```
Out[13]: (nan, nan)
```

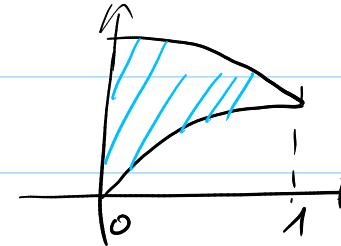
```
In [14]: integrate.quad(f, -1, 1, points=[0]) # can deal with singularity if you tell it
```

```
Out[14]: (3.999999999999813, 5.684341886080802e-14)
```

$$a_1 = 0, \quad b_1 = 1$$

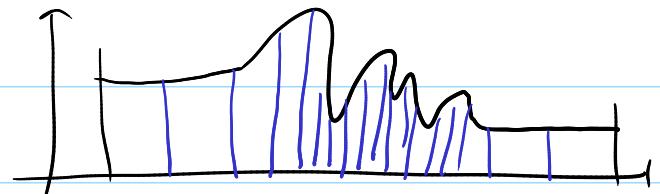
$$ay(x) = \min(1), \quad by(x) = 0.1 + \cos(\frac{x}{2})$$

integrate dblquad(f, 0, 1, ay, by)



§1.3 Adaptive Quadratur

Ziel: Optimierte die Anzahl der Funktionsauswertungen



Wie kann man beim Laufzeit des Algorithms herausfinden
(wo man mehr / weniger Intervalle braucht?)
→ Wie kann man das lokale Fehler beim Rechnen
schätzen?

(lokale Fehler $\varepsilon_k \sim h^{n+1} \max |f^{(n)}(x)|$ für Ordnung n)
 $x \in [x_k, x_{k+1}]$

z.B. (TR):

$$\int_{x_k}^{x_{k+1}} f(x) dx = Q^T(f, x_k, x_{k+1}) + ch^3 \max |f'''(x)|$$

$x \in [x_k, x_{k+1}]$

(SR)

$$\int_{x_k}^{x_{k+1}} f(x) dx = Q^S(f, x_k, x_{k+1}) + c \cdot h^5 \max |f^{(IV)}(x)|$$

$x \in [x_k, x_{k+1}]$

$$\varepsilon_k = \left| \int_{x_k}^{x_{k+1}} f(x) dx - Q^T \right|$$

\hookrightarrow approximiert \int mit einer besserer Form.

\Rightarrow erhalte eine Schätzfunktion $\tilde{\varepsilon}_k \approx \varepsilon_k$

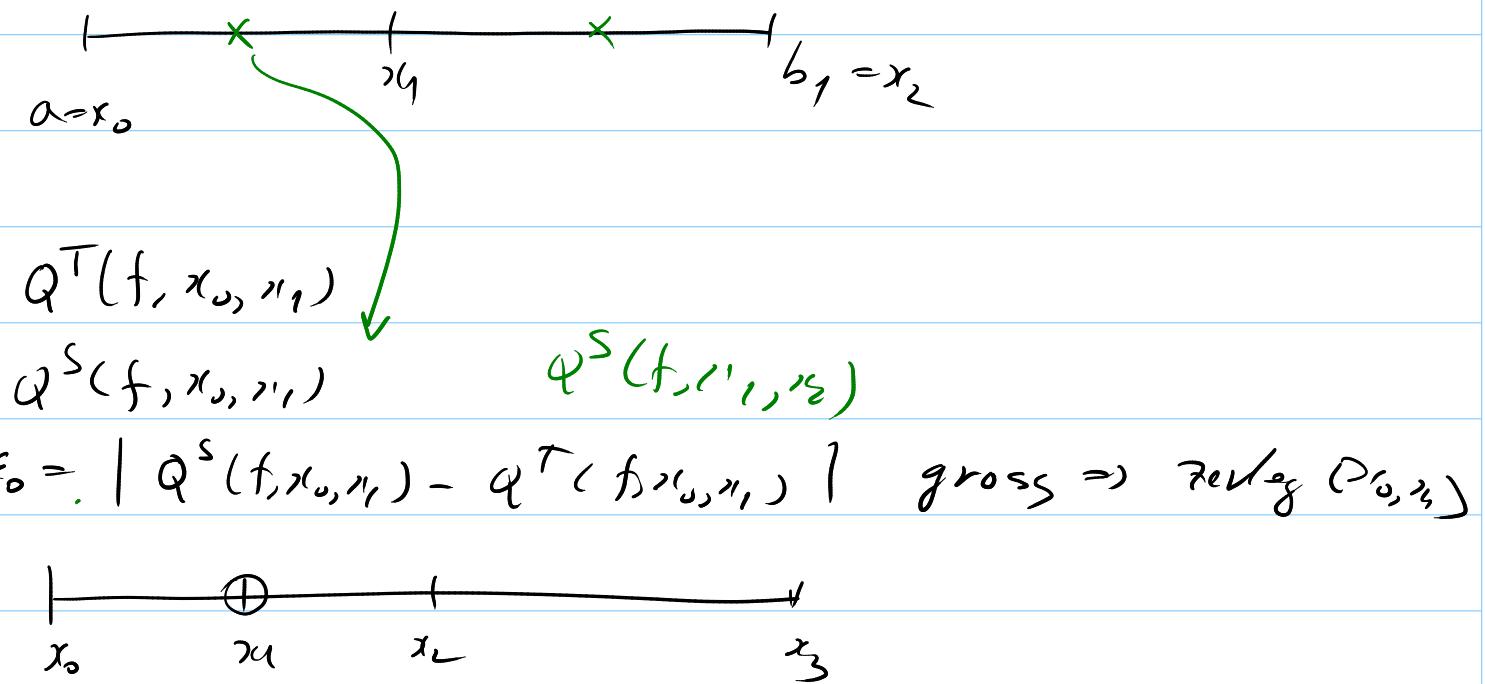
$$\tilde{\varepsilon}_k = |Q^S(f, x_k, x_{k+1}) - Q^T(f, x_k, x_{k+1})|$$

Idee: verfeinere dort wo $\tilde{\varepsilon}_k$ gross ist
(vergrößere dort wo $\tilde{\varepsilon}_k$ sehr klein ist)

Verwende das Ergebnis von Q^S

Q^T wird verwendet nur um die Schätzfunktion vom lokalen Fehler zu berechnen.

Das kann man immer machen, sobald wir 2 Q-Funktionen verschiedener Ordnung.



$$\varepsilon_0 = |Q^S(f, x_0, x_1) - Q^T(f, x_0, x_1)| \text{ gross} \Rightarrow \text{verlängere } (x_0, x_1)$$

```

1 from numpy import *
2 from scipy import integrate
3
4 def adaptquad(f,M,rtol,abstol):
5     """
6         adaptive quadrature using trapezoid and simpson rules
7         Arguments:
8             f      handle to function f
9             M      initial mesh
10            rtol   relative tolerance for termination
11            abstol absolute tolerance for termination, necessary in case the exact
12                integral value = 0, which renders a relative tolerance meaningless.
13
14     h = diff(M)
15     mp = 0.5*(M[:-1]+M[1:])
16     fx = f(M); fm = f(mp)
17     midpoints = mp
18
19     trp_loc = h*(fx[:-1]+2*fm+fx[1:])/4 # local trapezoid rule
20     simp_loc = h*(fx[:-1]+4*fm+fx[1:])/6 # local simpson rule
21     I = sum(simp_loc) # use simpson rule value as
22
23     intermediate approximation for integral value
24     est_loc = abs(simp_loc - trp_loc) # difference of values obtained from
25     local composite trapezoidal rule and local simpson rule is used as an estimate
26     for the local quadrature error.
27     err_tot = sum(est_loc) # estimate for global error (sum
28     moduli of local error contributions)
29     # if estimated total error not below relative or absolute threshold, refine
30     mesh
31     if err_tot > rtol*abs(I) and err_tot > abstol:
32         refcells = nonzero( est_loc > 0.9*sum(est_loc)/size(est_loc) )[0]
33         I = adaptquad(f,sort(append(M,mp[refcells])),rtol,abstol) # add
34
35     midpoints of intervals with large error contributions, recurse.
36
37     return I
38
39 if __name__ == '__main__':
40     M=Das Neue gr. 0 1 1 0
41     f = lambda x: exp(6*sin(2*pi*x))
42     #f = lambda x: 1.0/(1e-4+x*x)
43     M = arange(11.)/10 # 0, 0.1, ... 0.9, 1
44     rtol = 1e-6; abstol = 1e-10
45     I = adaptquad(f,M,rtol,abstol)
46     exact,e = integrate.quad(f,M[0],M[-1])
47     print('adaptquad:',I, '"exact":',exact)
48     print('error:',abs(I-exact))

```

$M = [x_0 \ x_1 \ x_2 \ x_3 \ x_4 \ x_5 \ x_6]$

$h_0 \ h_1 \ h_2 \ h_3 \ h_4$

$m_{p_0} \ m_{p_1} \ m_{p_2} \ m_{p_3}$

$f(x) = e^{6 \sin(2\pi x)}$

$\text{min}(f(x), 100)$

§1.4. Gauss-Quadratur

$$\Rightarrow \int_0^1 n(t) g(t) dt = 0 \Leftrightarrow n \perp g \text{ für alle } g \in P_m$$

$\langle n, g \rangle = \int_0^1 n(t) g(t) dt$ Skalarprodukt

$$\Leftrightarrow n \perp P_m$$

Möchte Knoten c_1, c_2, \dots, c_s und Gewichte b_1, \dots, b_s so dass

Q-Ordnung $p = s+m$, $m \in \mathbb{N}$, $m > 0$ maximal

(d.h. jedes Polynom vom Grad $p \leq s+m-1$ soll exakt integriert werden)

Idee Nehme $M(t) = (t - c_1)(t - c_2) \dots (t - c_s)$
 $\text{Grad } M = s$, $M(c_1) = 0 \dots = M(c_s) = 0$

Sei $f \in P_{s+m}$ ($\text{grad } f \leq s+m-1$)

Polynomdivision.

$$f(t) = M(t)g(t) + r(t) \quad \text{mit}$$

$$\text{Grad } r \leq s-1$$

$$\text{Grad } g \leq m-1$$

Referenzintervall $[0, 1]$, $\int_0^1 dt \Rightarrow$

$$\int_0^1 f(t) dt = \int_0^1 n(t) g(t) dt + \int_0^1 r(t) dt$$

$\Downarrow \leftarrow Q\text{-Fexakt}$

QFexakt

$$\sum_{j=1}^s b_j f(c_j) = \sum_{j=1}^s b_j M(c_j) g(c_j) + \sum_{j=1}^s b_j r(c_j)$$

Theorem Q-Ordnung ist $s+m \Leftrightarrow M \perp P_m$

Theorem Q-Ordnung ist max. 2s (d.h. $m \leq s$)

Beweis R.A. Q-Ordnung ist $\geq s+1$ (d.h. $m = s+1$)

$\langle M, g \rangle = 0$ für alle $g \in P_{s+1}$ (d.h. $\text{Grad } g \leq s$)

nehme $g = M$ $\Rightarrow \langle M, M \rangle = 0 \Rightarrow M = 0$
 $\text{Grad } M = s$

Somit Q-Ordnung $\leq 2s$.

Bem Verallgemeinerung mit Gewichtsfunktionen in Intervall

$$\int_a^b f(t) dt \text{ mit } \int_a^b f(t) w(t) dt$$

w stetig
 $w > 0$, $\int_a^b |x|^k w(x) dx < \infty$

$$\int_0^1 f(t) \cdot g(t) dt \text{ ersetzt durch } \int_a^b f(t) g(t) w(t) dt$$

Bem Gram-Schmidt $\Rightarrow P_0, P_1, P_2, \dots$

$$P_k(t) = t^k + \text{Polynom von Grad } \leq k-1$$

$$P_k \perp \text{span } \{P_0, P_1, \dots, P_{k-1}\}$$

GS \Rightarrow 3-Term-Rekurrenz für die P_k .

Bem $c_1, \dots, c_s = \text{Nullstellen } P_s$

Bem $[0,1], w=1 \Rightarrow \text{Legendre-Polynome} \Rightarrow \text{Gauss-Legendre Quadratur}$

$\mathbb{R}, w(t) = e^{-t^2} \Rightarrow \text{Hermite-Polynome} \Rightarrow \text{Gauss-Hermite Quadratur}$

analog.: Laguerre, Jacobi, Tschebyschoff $\overline{I}, \underline{I}$

\Rightarrow Quadratur

Bsp Gauss-Quadratur

$$1) N=1 \text{ auf } [0,1] \Rightarrow P_1(t) = t - \frac{1}{2} \Rightarrow c_1 = \frac{1}{2}, b_1 = 1 \Rightarrow (\text{MPR})$$

$$2) N=2 \text{ auf } [-1,1] \Rightarrow P_2(t) = t^2 - \frac{1}{3} \Rightarrow c_1 = -\frac{1}{\sqrt{3}}, c_2 = \frac{1}{\sqrt{3}} \\ b_1 = 1, b_2 = 1$$

Für Integrale der Form

$$\int_a^b f(x) \omega(x) dx$$

spielen verschiedene orthogonale Polynome eine wesentliche Rolle:

Quadratur	Intervall	Gewichtsfunktion	Polynom	Not.	scipy.special.
Gauss	$(-1, 1)$	1	Legendre	P_k	roots_legendre
Chebyshev I	$(-1, 1)$	$\frac{1}{\sqrt{1-x^2}}$	Chebyshev I	T_k	roots_chebyt
Chebyshev II	$(-1, 1)$	$\sqrt{1-x^2}$	Chebyshev II	U_k	roots_chebyu
Jacobi $\alpha, \beta > 1$	$(-1, 1)$	$(1-x)^\alpha(1+x)^\beta$	Jacobi	$P_k^{(\alpha, \beta)}$	roots_jacobi
Hermite	\mathbb{R}	e^{-x^2}	Hermite	H_k	roots_hermite
Laguerre	$(0, \infty)$	$x^\alpha e^{-x}$	Laguerre	L_k	roots_genlaguerre

Abb. 1.5.10. Gewichtsfunktionen für Quadraturformeln

auf $[0,1]: c_1 = \frac{1}{2} - \frac{\sqrt{2}}{6}, c_2 = \frac{1}{2} + \frac{\sqrt{2}}{6}$
 $b_1 = \frac{1}{2}, b_2 = \frac{1}{2}$

Ordnung $2s = 2 \cdot 2 = 4 \Rightarrow$ exakt 5. Polynom
Von Grad ≤ 3

3) $N=3$ auf $[-1,1]$

$$P_3(t) = \frac{5}{2}t^3 - \frac{3}{2}t$$

$$c_1 = -\frac{\sqrt{15}}{5}, c_2 = 0, c_3 = \frac{\sqrt{15}}{5}$$

$$b_1 = \frac{5}{9}, b_2 = \frac{8}{9}, b_3 = \frac{5}{9}$$

Ordnung $2s = 2 \cdot 3 = 6$

Bem Gewichte zu c_1, \dots, c_s

Lagrange-Polygone dazu: ℓ_1, \dots, ℓ_s , Grad α_i ,

$$f(t) = \ell_i(t)^2, \text{ Grad } f = 2(\alpha \cdot 1) \leq 2\alpha - 1 \rightarrow \text{QF exakt}$$

$$0 < \int_0^1 \ell_i(t)^2 dt = \sum_{j=1}^s b_j \ell_i(c_j)^2 = b_i$$

$\prod_{j \neq i} c_j = c_i$

$0, s_{0,1}, \dots$

Bem 1) Gauss-Knoten sind nicht verschachtelt ?!

Nachteil bei Adaptivität

2) offene

3) 1 Ende = Knoten ($f(x)$) \Rightarrow nur max Ord $\geq \alpha - 1$ Radom $\ll O(s \log s)$
2 Enden = Knoten ($f(x)$) \Rightarrow nur max Ord $\geq \alpha - 2$ Lohatto

4) Fehler für zusammenge setzt Gauss-QF:

$$\left| \int_a^b f(t) dt - \sum_{s=1}^n G_s(f, x_{k-1}, x_k) \right| \leq C \cdot h \max_{x \in [a, b]} |f^{(2s)}(x)|$$

5) elegante Berechnung der Knoten & Gewichten
der Gauss-Quadratur mit Golub-Welsch Alg
(1969) $\in \mathbb{W}, \in \mathbb{V}$ einer Matrix
aber nicht sehr stabil für grosses s
teuer!

2012-2014 Bogaert-Townsend: bessere
(stabiler & schneller) Alg.

	Arbeit	Gewichtete Knoten	Gewichtete Gewichte
GW	$O(s^3)/O(s^2)$	$O(1)$	$O(s^2)$
BT	$O(1)$	$O(1)$	$O(1)$
		$O(1)$	$O(1)$

05.03.2024

§2 Trigonometrische /Fourier Approximation

§2.1. Grundlagen

Approx: Taylor: $f(t) = f(t_0) + \frac{f'(t_0)}{1!} (t-t_0) + \frac{f''(t_0)}{2!} (t-t_0)^2 + \dots$

Lokal.

↓ ↑
Potenzen $|t-t_0| \leq \text{klein}$. Rest

Fehler

Besser: Interpolation (weder lokal noch global)

$$L^2(0,1) = \left\{ f: (0,1) \rightarrow \mathbb{R}, \|f\|_{L^2(0,1)} < \infty \right\}$$

$$\|f\|_{L^2(0,1)}^2 = \int_0^1 |f(t)|^2 dt$$

$$\|f\|^2 = \langle f, f \rangle, \quad \langle g, f \rangle = \int_0^1 \overline{g(t)} f(t) dt$$

$L^2(0,1)$ lin. Raum mit Norm $\|\cdot\|$
aus dem Skalar product $\langle \cdot, \cdot \rangle$

$$f \in L^2(0,1) \Rightarrow f = \sum_{k=-\infty}^{\infty} \hat{f}(k) e^{2\pi i k t} \quad \text{Fourier Reihe}$$

$$\hat{f}(k) = \int_0^1 f(t) e^{-2\pi i k t} dt \quad \text{Fourier Koeffizient}$$

$$\text{Parseval} \quad \|f\|_{L^2}^2 = \sum_{k=-\infty}^{\infty} |\hat{f}(k)|^2$$

$$L^2(0,1) = \text{span} \left\{ \ell_k ; k \in \mathbb{Z} \right\}$$

$$\ell_k(t) = e^{2\pi i k t}$$

(ℓ_k) vollständige ONB in $L^2(0,1)$

Falls erlaubt:

$$\widehat{f^{(n)}}(k) = (2\pi i k)^n \hat{f}(k)$$

$$\|f^{(n)}\|_2^2 = (2\pi)^{2n} \sum_{k=-\infty}^{\infty} k^{2n} |\hat{f}(k)|^2$$

Glattert von f (\Leftrightarrow $\int_0^1 |f''(t)| dt < \infty$) \Leftrightarrow Abfallverhalten von $\hat{f}(k)$

$$\int_0^1 |f''(t)| dt < \infty \Rightarrow \hat{f}(k) \sim k^{-2}$$

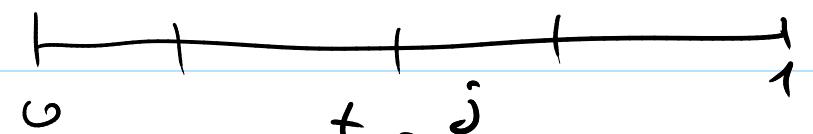
Aliasing für $\frac{N}{2}$ Frequenzen braucht N Punkte / Werte

f periodisch

Wie berechnen wir $\hat{f}(k)$?

Sum. TR:

$$\hat{f}(k) = \int_0^1 f(t) e^{-2\pi i k t} dt$$



$$t_j = \frac{j}{N} \quad j = 0, 1, \dots, N-1 ; \quad f(1) = f(0)$$

(N äquidistante Punkte zw. 0 und 1)

$$J_N = \text{span} \left\{ e^{-\frac{\pi k}{N}}, e^{-\frac{\pi k}{N} + i}, \dots, e^{0}, e^{i}, \dots, e^{\frac{\pi k}{N}} \right\}$$

Raum trigonometrischer Polynome

$\dim J_N = N$, $J_N \subset L^2(0,1)$ Unterraum.

$$f(t) = \sum_{k=-\infty}^{\infty} \hat{f}(k) e^{ikt} \quad \hat{f}_k(t) \approx \sum_{k=-\frac{N}{2}}^{\frac{N}{2}-1} \hat{f}(k) e^{ikt}$$

f glatt \Rightarrow sehr gute (globale) Approximation.
 N gross

Sum. TR:

$$\begin{aligned} \hat{f}(k) &\approx \frac{1}{N} \left[\frac{1}{2} f(0) + \sum_{j=1}^{N-1} f(t_j) e^{-2\pi i k \frac{j}{N}} + \frac{1}{2} f(1) \right] = \\ &= \frac{1}{N} \sum_{j=0}^{N-1} f\left(\frac{j}{N}\right) e^{-2\pi i k \frac{j}{N}} =: \hat{f}_N(k) \end{aligned}$$

$$f(t) \approx P_N(t) = \sum_{k=-\frac{N}{2}}^{\frac{N}{2}-1} \hat{f}_N(k) f_k(t) = \sum_{k=-\frac{N}{2}}^{\frac{N}{2}-1} \hat{f}_N(k) e^{2\pi i k t}$$

$$\hat{f}(k) \approx \hat{f}_N(k) = \frac{1}{N} \sum_{j=0}^{N-1} f\left(\frac{j}{N}\right) w_N^{kj}$$

Fixiere ℓ :

§ 2.2. Diskrete Fourier Transformation

$$N \text{ gerade}, \quad i^2 = -1, \quad \text{Notiere } w_N = e^{-\frac{2\pi i}{N}}, \quad w_N = \bar{w}_N = e^{\frac{2\pi i}{N}}$$

$$\text{Dann: } w_N^{k+N} = w_N^k \quad \text{für alle } k \in \mathbb{Z}$$

$$w_N^{t+kN} = w_N^t \quad \text{für alle } t \in \mathbb{R}, k \in \mathbb{Z}$$

$$w_N^N = 1, \quad w_N^{\frac{N}{2}} = -1$$

$$\sum_{k=0}^{N-1} w_N^{kj} = \begin{cases} N, & j=0 \\ 0, & j \neq 0 \end{cases}$$

$$\begin{aligned} P_N\left(\frac{\ell}{N}\right) &= \sum_{k=-\frac{N}{2}}^{\frac{N}{2}-1} \left(\frac{1}{N} \sum_{j=0}^{N-1} f\left(\frac{j}{N}\right) w_N^{kj} \right) e^{2\pi i k \frac{\ell}{N}} = \\ &= \frac{1}{N} \sum_{j=0}^{N-1} f\left(\frac{j}{N}\right) \sum_{k=-\frac{N}{2}}^{\frac{N}{2}-1} w_N^{k(j-\ell)} \end{aligned}$$

o falls $j-\ell \neq 0$
 ~ falls $j-\ell = 0$

$$\begin{aligned} &= \frac{1}{N} (0 + 0 + \dots + f\left(\frac{\ell}{N}\right) \cdot N + 0 + \dots 0) = \\ &= \frac{1}{N} f\left(\frac{\ell}{N}\right) N = f\left(\frac{\ell}{N}\right) \rightarrow \\ P_N\left(\frac{\ell}{N}\right) &= f\left(\frac{\ell}{N}\right) \end{aligned}$$

$\Rightarrow P_n(t)$ erfüllt die Interpolationsbedingungen:

$$\left\{ \begin{array}{l} P_n(t_j) = f(t_j) \\ j=0, 1, \dots, n-1 \end{array} \right. \quad \left(t_j = \frac{j}{n} \right)$$

Sei nun in \mathbb{C}^n die trigonometrische Basis

$$\{v_0, v_1, \dots, v_{N-1}\} \subset \mathbb{C}^n$$

$$v_k = \begin{bmatrix} w_n^{0 \cdot k} \\ w_n^{1 \cdot k} \\ \vdots \\ w_n^{(N-1)k} \end{bmatrix} \in \mathbb{C}^N \quad \text{für } k=0, 1, \dots, N-1$$

$$\begin{matrix} \text{V} \\ \equiv \end{matrix}^H \begin{matrix} \text{V} \\ \equiv \end{matrix} = \sim \begin{matrix} \text{I} \\ \equiv \text{a} \end{matrix}$$

∇ symmetrisch, nicht Hermite-symmetrisch.

$$\frac{v}{-k} = \frac{V}{-k}$$

$$e_k = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{bmatrix} \leftarrow \text{the Position}$$

e_0, e_1, \dots, e_n , Standard basis

$$\underline{y} = \underline{\underline{V}} \underline{z} \Leftrightarrow \underline{z} = \underline{\underline{V}}^{-1} \underline{y} = \frac{1}{\omega} \underline{\underline{V}}^H \underline{y}$$

$$F_N = \mathbf{V}^H \quad \text{Fourier Matrix}$$

$$F_N = \left(\omega_N^{ij} \right)_{i,j=0,1,\dots,N-1}$$

Def $\mathcal{F}_N: \mathbb{C}^N \rightarrow \mathbb{C}^N, \quad \mathcal{F}_N \underline{y} = \underline{F_N y}$

Diskrete Fourier Transformation.

$\left[\text{fft}(\underline{y}) \right]$

Bew 1) $\frac{1}{\sqrt{N}} \underline{F_N}$ unitär

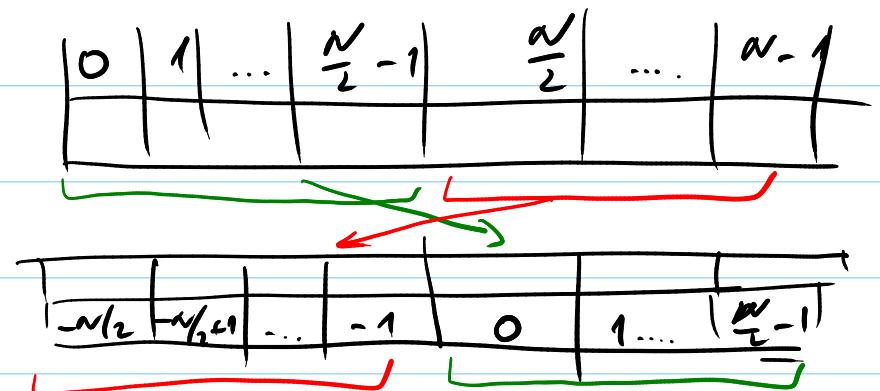
$$2) \frac{1}{\sqrt{N}} \underline{F_N} \underline{F_N}^T = \begin{bmatrix} y_0 \\ y_1 \\ \vdots \\ y_{N-1} \end{bmatrix} = \begin{bmatrix} y_{N-1} \\ y_{N-2} \\ \vdots \\ y_1 \\ y_0 \end{bmatrix}$$

$$3) \frac{1}{N^2} \underline{F_N}^4 = \underline{I} \Rightarrow \text{EV von } \underline{F_N} \text{ sind } \{1, -1, i, -i\}$$

$$\text{Bew 1)} \quad \underline{z} = \frac{1}{\sqrt{N}} \underline{F_N y}, \quad \text{fft}(\underline{y}) = \underline{F_N y} = N \underline{z}$$

$$\text{ifft}(N \underline{z}) = \underline{y}$$

2) fft: die Frequenzen stehen am "falschen" Ort:



fftshift

$$\underline{y} = \sum_{k=0}^{N-1} z_k \underline{v}_k = \sum_{k=0}^{N-1} z_k \begin{bmatrix} w_n^{0k} \\ w_n^{1k} \\ \vdots \\ w_n^{(N-1)k} \end{bmatrix}$$

Daraus schauen wir Komponente l :

$$\underline{y}_l = \sum_{k=0}^{N-1} z_k w_n^{lk} = \sum_{k=0}^{\frac{N}{2}-1} z_k w_n^{lk} + \sum_{k=\frac{N}{2}}^{N-1} z_k w_n^{lk}$$

$$\text{if } k = N+j \Leftrightarrow j = k - N$$

$$\sum_{j=-\frac{N}{2}}^{-1} z_{N+j} w_n^{lj} =$$

$$= \sum_{k=-N}^{N-1} r_k w_N^{-lk}.$$

Theorem

$$\|f - p_N\|_{L^2} \leq \sqrt{1 + c_k \cdot N^{-k}} \|f^{(k)}\|_{L^2}$$

$$\text{mit } c_k = 2 \sum_{l=1}^{\infty} (2l-1)^{-2k}.$$

FFT (fast Fourier Transform)

$$N=2^n$$

$$z_k = \sum_{j=0}^{n-1} y_j e^{-\frac{2\pi i}{n} jk} = \sum_{j=0}^{n-1} y_j e^{-\frac{2\pi i}{2^n} 2jk} +$$

gerade

$$+ \sum_{j=0}^{n-1} y_{2j+1} e^{-\frac{2\pi i}{2^n} (2j+1)k} =$$

ungerade

$$\sum_{j=0}^{n-1} y_{2j+1} e^{-\frac{2\pi i}{2^n} 2jk} + e^{-\frac{2\pi i}{n} k} \sum_{j=0}^{n-1} y_{2j+1} e^{-\frac{2\pi i}{n} jk}$$

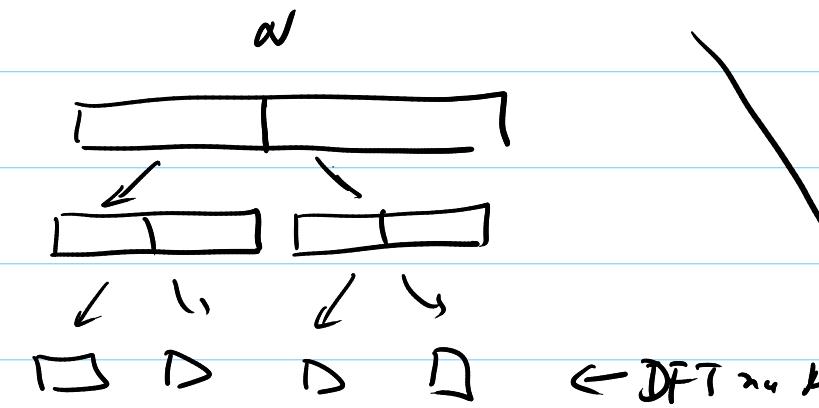
DFT für $n = \frac{N}{2}$ Koeffizienten

$$\sum_{j=0}^{n-1} y_{2j} e^{-\frac{2\pi i}{n} jk}$$

DFT für $n = \frac{N}{2}$ Koeffizienten!

$$+ e^{-\frac{2\pi i}{n} k} \sum_{j=0}^{n-1} y_{2j+1} e^{-\frac{2\pi i}{n} jk}.$$

$$N=2^P$$



$\approx \log(n)$
operations.

$\leftarrow \text{DFT } n \times k$

statt n^2 wie mit

$$\underline{F_N y} = -$$

$n \log n < n^2$ für N gross!

Auswertung in weitere Punkte $\frac{k}{m}$ mit $M > N$

schnell mit FFT und "zero padding"

$$P_N(t) = \sum_{j=-n}^{n-1} z_j e^{2\pi i j t} = \sum_{j=-n}^{j=n-1} \tilde{z}_j e^{2\pi i j t}$$

$$\text{mit } \tilde{z}_j = \begin{cases} z_j & \text{für } -n \leq j \leq n-1 \\ 0 & \text{sonst} \end{cases}$$

Verwende die inverse FFT auf $\tilde{\underline{z}}$

\Rightarrow Werte $P_N(\frac{k}{m})$ in $M \log M$ Operations!

Bem

$$\underline{z} = \frac{1}{\sqrt{N}} \underline{F_N} \underline{y} \Rightarrow \bar{\underline{z}} = \frac{1}{\sqrt{N}} \underline{F_N} \bar{\underline{y}} = \underline{F_N}^{-1} \bar{\underline{y}}$$

$$\Rightarrow \bar{\underline{z}} = \underline{F_N}^{-1} \bar{\underline{y}}$$

Kann manchmal schneller sein
braucht keine Division mit \sqrt{N} mehr!

$$\underline{y} = \underline{F_N} \underline{F_N}^{-1} \bar{\underline{y}} . \text{ Wenn } \underline{y} \in \mathbb{R}^N \Rightarrow \text{brauche kein} -$$

NICE für $\underline{y} \in \mathbb{R}^N$ nur!

Technik f gegebe, Werte $\underline{y} = f(\underline{t})$, $\underline{t} = \left[\begin{array}{c} \frac{0}{N} \\ \frac{1}{N} \\ \vdots \\ \frac{N-1}{N} \end{array} \right]$ Bei Berechnung der Ableitungen.

$$\underline{z} = \frac{1}{N} \underline{F}_N \underline{y} = \frac{1}{N} \text{fft}(\underline{y})$$

erweiteren \underline{z} auf $\underline{\tilde{z}}$



$$\underline{\tilde{z}} = \text{ifft}(\underline{F}_N \underline{y})$$

$O(N \log N) \leq \text{arm direkte Auswertung}$.

Code 2.4.4.

Direkt:

$$f(t) \stackrel{R}{\approx} P_N(t) = \sum_{j=-N}^N z_j e^{2\pi i jt} \Rightarrow$$

$$P_N'(t) = 2\pi i \sum_{j=-N}^N j z_j e^{2\pi i jt}$$

$$\underline{z} = \frac{1}{N} \underline{F}_N \underline{y}$$

$$\underline{z}' = 2\pi i \underbrace{\text{diag}(0, 1, \dots, N-1, -N, -N+1, \dots, -1)}_D \underline{z}$$

$$\underline{y}' = \text{real}(N \underline{F}_N^{-1} \underline{z}') \approx [f'(t_j)]_{j=0, 1, \dots, N-1}$$

Indirekt

$$\underline{c} = \underline{F}_N^{-1}(\underline{y}) \quad (= \underline{\bar{z}})$$

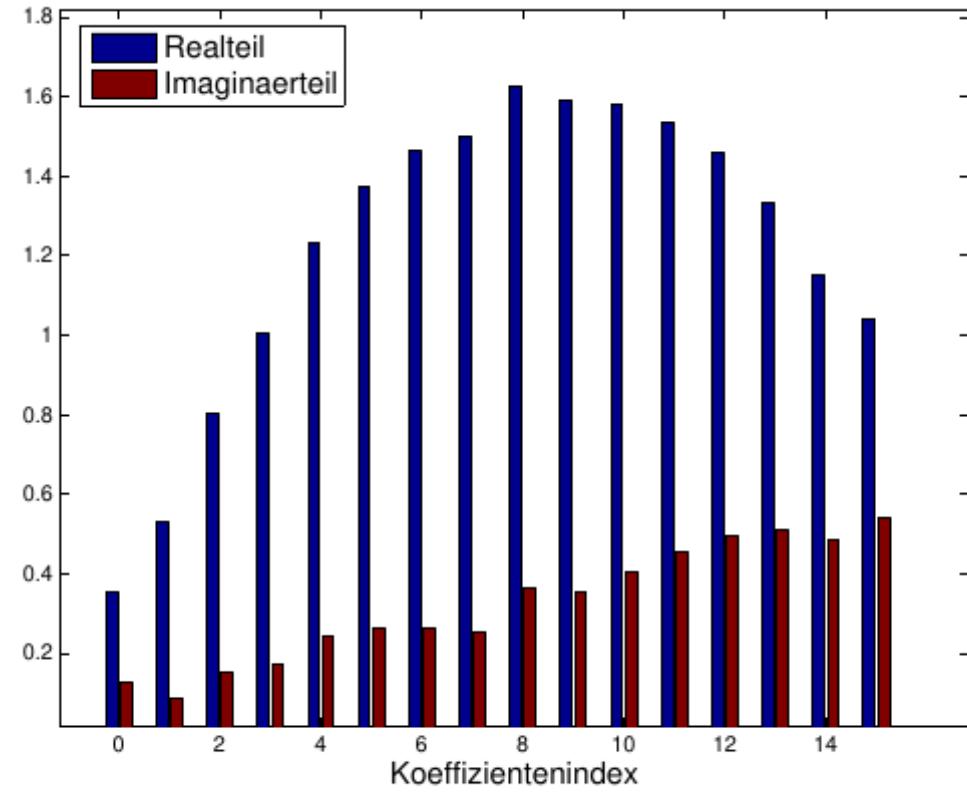
NUR

Für
reelle
Signale \underline{y} !

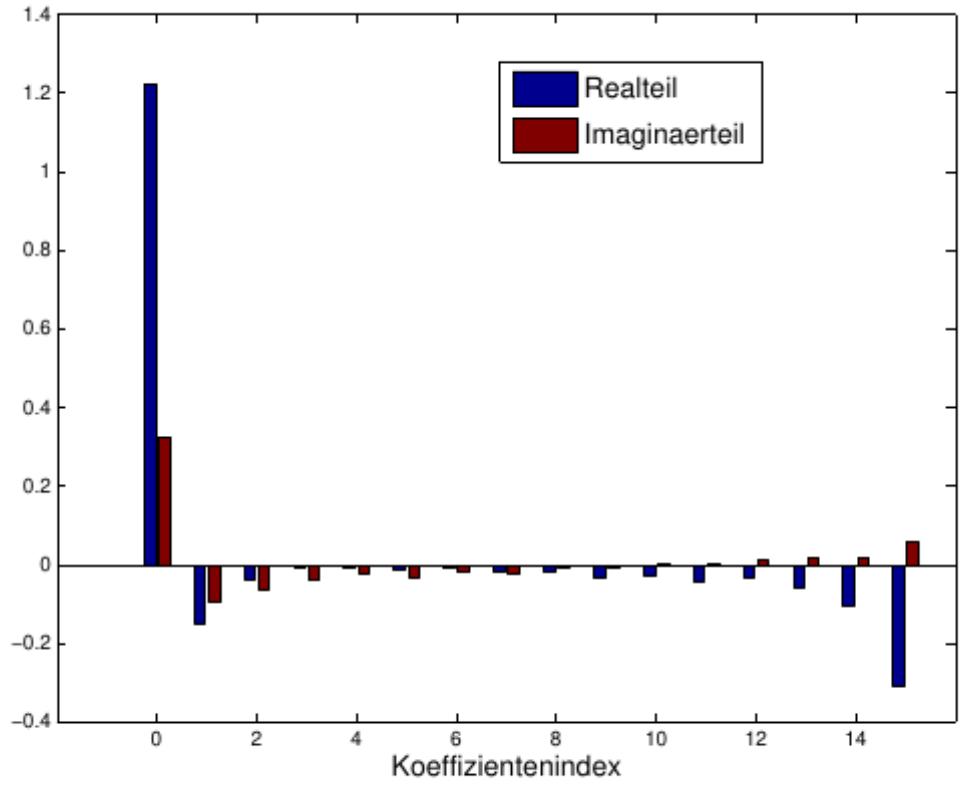
$$\underline{c}' = (-\omega_i) \underline{D} \underline{c} = -\omega_i \underline{D} \underline{\bar{z}}$$

$$\underline{y}' = \text{real}(\underline{F}_N \underline{s}') \quad \text{conj}(\underline{F}_N \underline{s}')$$

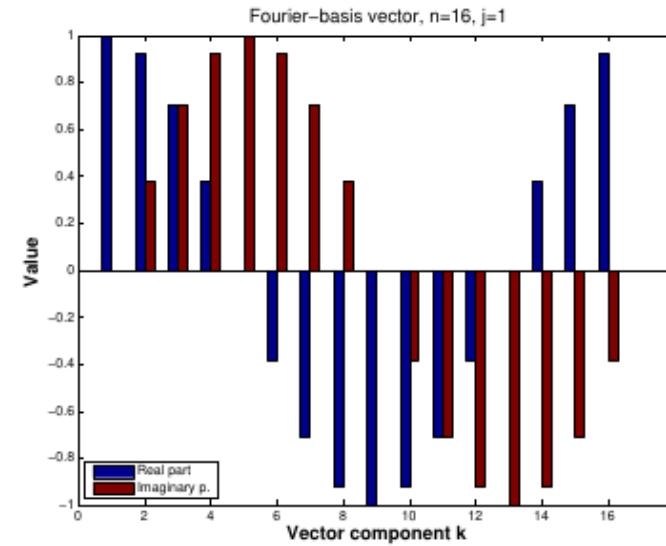
12.03.2024



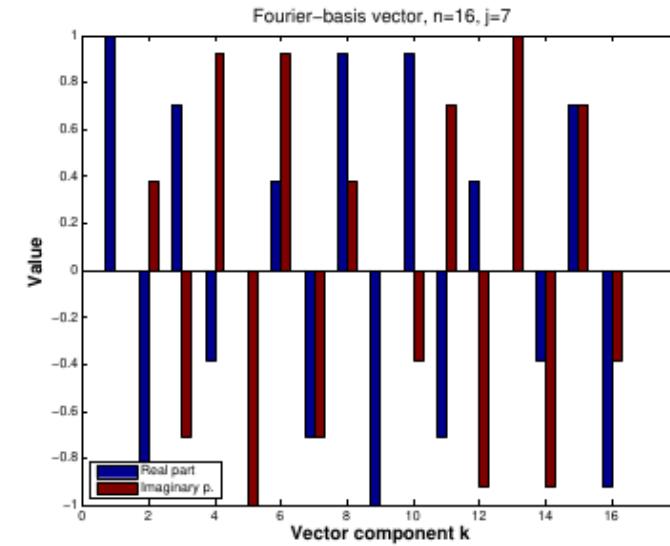
Vektor in Standardbasis



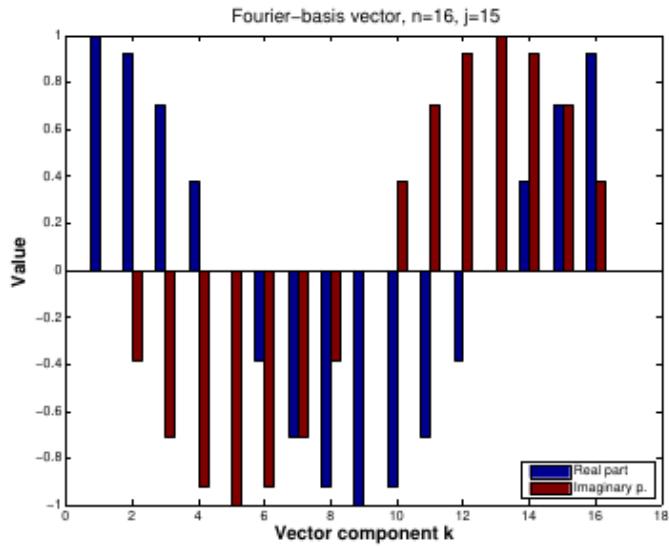
Vektor in der trigonometrische Basis



“niedrige Frequenz”



“hohe Frequenz”



“niedrige Frequenz”

Der ℓ -te Eintrag in \mathbf{y} ist

$$\begin{aligned} y_\ell &= \sum_{k=0}^{N-1} z_k w_N^{\ell k} = \sum_{k=0}^{N/2-1} z_k w_N^{\ell k} + \sum_{k=N/2}^{N-1} z_k w_N^{\ell k} = \sum_{k=0}^{N/2-1} z_k w_N^{\ell k} + \sum_{k=-N/2}^{-1} z_{N+k} w_N^{\ell k} \\ &= \sum_{k=-N/2}^{N/2-1} \gamma_k \exp\left(\frac{2\pi i}{N} \ell k\right), \end{aligned}$$

was einem Teil der Fourier-Reihe ausgewertet im Punkt $\frac{\ell}{N} \in [0, 1[$ entspricht, wobei die (diskreten) Fourier-Koeffizienten durch eine Umsortierung der Koeffizienten in der trigonometrischen Basis gegeben sind:

$$\gamma_k = \begin{cases} z_k, & \text{für } 0 \leq k \leq n-1 = \frac{N}{2}-1 \\ z_{k+N}, & \text{für } -\frac{N}{2} = -n \leq k < 0 \end{cases} \quad (2.2.15)$$

Bemerkung 2.2.8. numpy stellt die Funktionen

$$\mathbf{c} = \text{fft}(\mathbf{y}) \text{ und } \mathbf{y} = \text{ifft}(\mathbf{c})$$

für

$$\mathbf{c} = \mathbf{F}_N \mathbf{y} \text{ und } \mathbf{y} = \frac{1}{N} \mathbf{F}_N^H \mathbf{c}$$

zur Verfügung.

$$f(x) \approx \sum_{j=0}^{\frac{N}{2}-1} z_j e^{2\pi i j x} + \sum_{j=\frac{N}{2}}^{N-1} z_j e^{2\pi i (j-N)x},$$

$$f(x) \approx \sum_{k=0}^{\frac{N}{2}-1} z_k e^{2\pi i k x} + \sum_{k=-\frac{N}{2}}^{-1} z_{k+N} e^{2\pi i k x},$$

$$\zeta = \text{fft}.fftshift(z):$$

$$f(x) \approx \sum_{k=-\frac{N}{2}}^{\frac{N}{2}-1} \zeta_k e^{2\pi i k x}.$$

Beispiel 2.2.11. Wenn wir `fft.fft` auf einen Vektor y der Länge 8 anwenden, erhalten wir den Vektor $c[0], \dots, c[7]$, und `fft.fftshift` stellt diese Einträge in der Reihenfolge $c[4], c[5], c[6], c[7], c[0], c[1], c[2], c[3]$, die der $\gamma_{-4}, \gamma_{-3}, \gamma_2, \gamma_1, \gamma_0, \gamma_1, \gamma_2, \gamma_3$ entsprechen.

Beispiel 2.2.13 (Frequenzanalyse mittels DFT). Nun nehmen wir ein periodisches Signal mit zwei Frequenzen (1 und 7); dazu addieren wir eine zufällige Störung. Wir transformieren dann dieses gestörte Signal in die Fourier-Basis und wir schauen uns das sogenannte “power spectrum” (die spektrale Leistungsdichte) an. Die ursprünglichen zwei Frequenzen sind eindeutig sichtbar in der Abbildung 2.2.14. In diesem Beispiel sind die Periodizität und die Abtastpunkte des Signals allerdings wichtig; wir schauen uns auch nur die erste Hälfte der Koeffizienten. Probieren Sie auch `bar(t[:]-64/2,fft.fftshift(p[:]))`!

```

1 from numpy import sin, pi, linspace, random, fft
2 from pylab import plot, bar, show
3 t = linspace(0,63,64)
4 x = sin(2*pi*t/64)+sin(7*2*pi*t/64)
5 y = x + random.randn(len(t)) #distortion
6 c = fft.fft(y)
7 p = abs(c)**2; p /= 64.
8 plot(t,y, '-+'); show()
9 bar(t[:32],p[:32]); show()

```

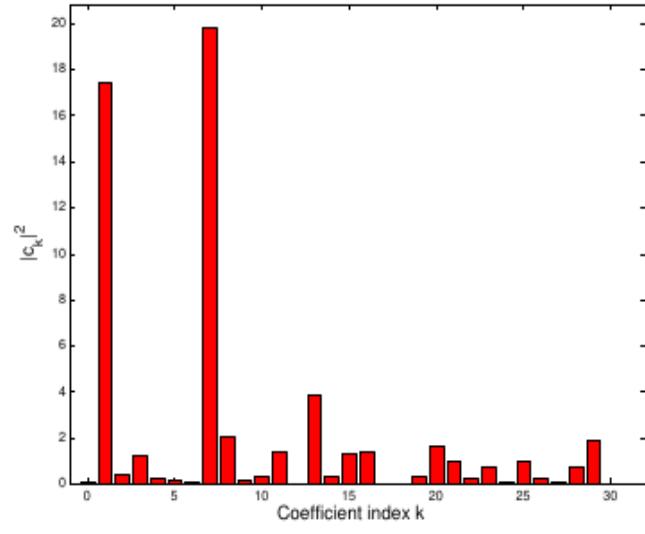
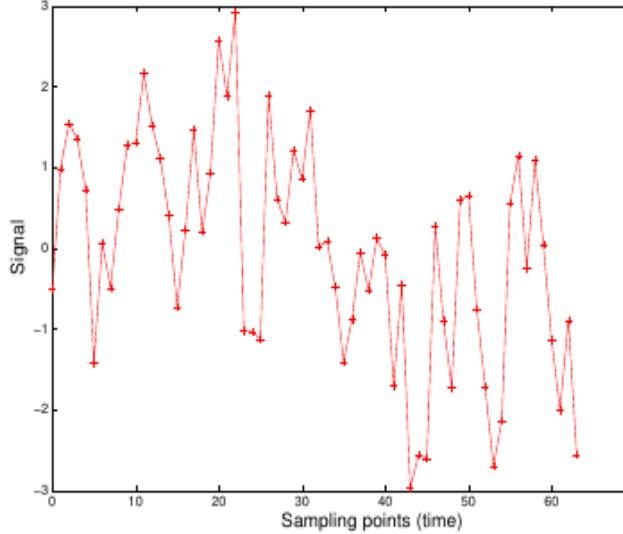
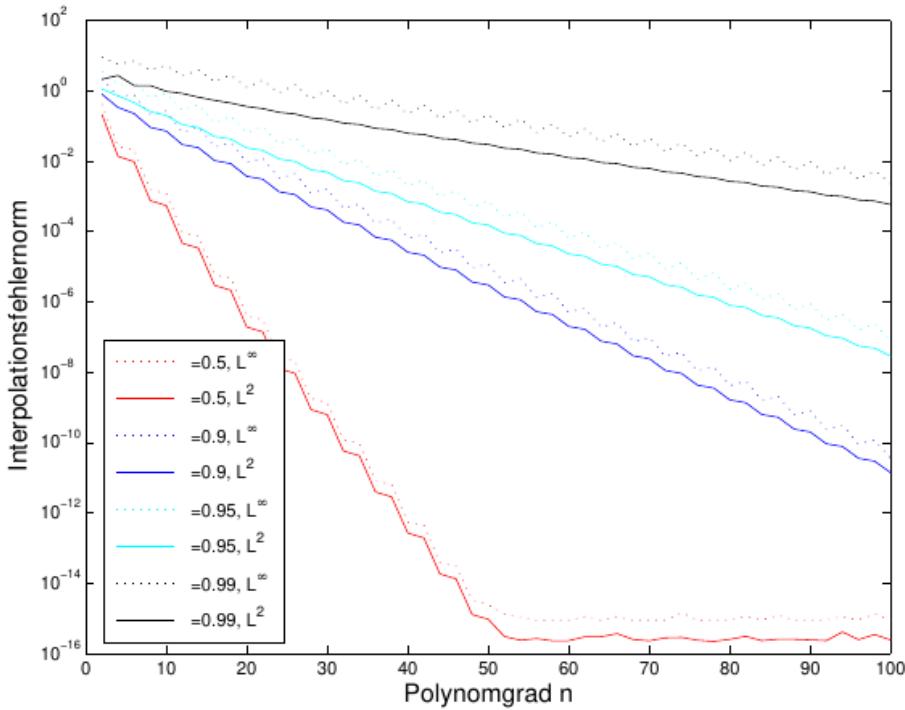


Abb. 2.2.14. Frequenzanalyse mittels DFT

Beispiel 2.5.3. Für $\alpha \in [0, 1]$ definieren wir:

$$f(t) = \frac{1}{\sqrt{1 - \alpha \sin(2\pi t)}} \text{ auf } I = [0, 1] ,$$

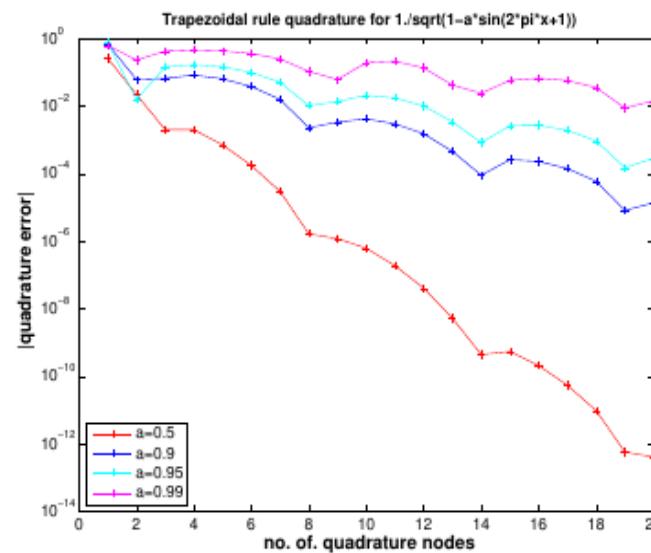
und wir beobachten exponentielle Konvergenz in n , schneller für kleineres α .



Die Trapez-Regel auf äquidistanten Punkten hat Ordnung 2, aber wenn wir sie auf den 1-periodischen glatten (analytischen) Integranden anwenden

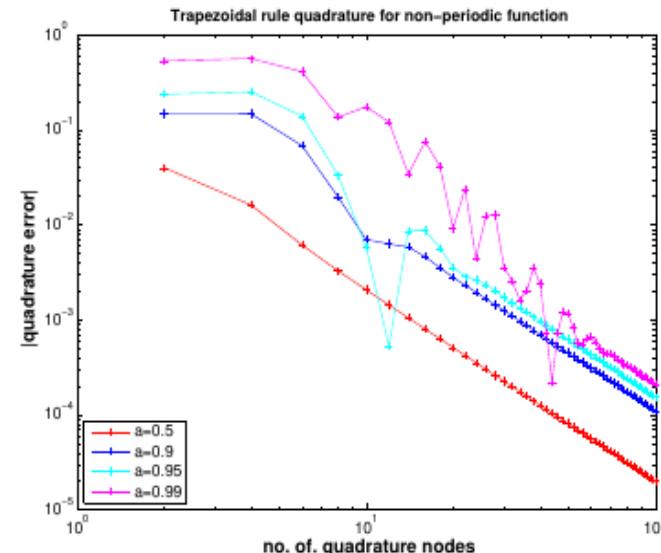
$$f(t) = \frac{1}{\sqrt{1 - a \sin(2\pi t - 1)}} , \quad 0 < a < 1$$

erhalten wir folgende erstaunliche Ergebnisse (als “exakten Wert des Integrals” verwenden wir T_{500}):



Quadratur-Fehler für $T_n(f)$ auf $[0, 1]$

Exponentielle Konvergenz!



Quadratur-Fehler für $T_n(f)$ auf $[0, \frac{1}{2}]$

nur algebraische Konvergenz...

Die Erklärung basiert auf der Tatsache, dass T_m exakt für trigonometrische Polynome vom Grad $< 2m$ sind:

$$f(t) = e^{2\pi i k t} \begin{cases} \int_0^1 f(t) dt = \begin{cases} 0, & \text{wenn } k \neq 0, \\ 1, & \text{wenn } k = 0. \end{cases} \\ T_m(f) = \frac{1}{m} \sum_{l=0}^{m-1} e^{\frac{2\pi i}{m} lk} \stackrel{(2.2.13)}{=} \begin{cases} 0, & \text{wenn } k \notin m\mathbb{Z}, \\ 1, & \text{wenn } k \in m\mathbb{Z}. \end{cases} \end{cases}$$

§2.3

Clenshaw-Curtis Formeln

Die Quadraturformeln von Clenshaw-Curtis, bzw. Fejer, basieren auf der Idee der Approximation des Integranden mittels Chebyschev-Polynomen. Für die Integration beliebiger Funktionen wird die Variablenubstitution $x = \cos(\theta)$ verwendet. Hieraus folgt:

$$\int_{-1}^1 f(x) dx = \int_0^\pi f(\cos(\theta)) \sin(\theta) d\theta.$$

Wir definieren $F(\theta) := f(\cos(\theta))$. Da $F(\theta)$ 2π -periodisch und gerade ist, lässt es sich in eine Kosinus-Reihe entwickeln: $F(\theta) = \sum_{k=0}^{\infty} a_k \cos(k\theta)$, woraus folgt:

$$\int_0^\pi F(\theta) \sin(\theta) d\theta = \int_0^\pi \sum_{k=0}^{\infty} a_k \cos(k\theta) \sin(\theta) d\theta = \sum_{k=0}^{\infty} a_k \int_0^\pi \cos(k\theta) \sin(\theta) d\theta = \sum_{k \text{ gerade}} \frac{2a_k}{1 - k^2}. \quad (1.5.7)$$

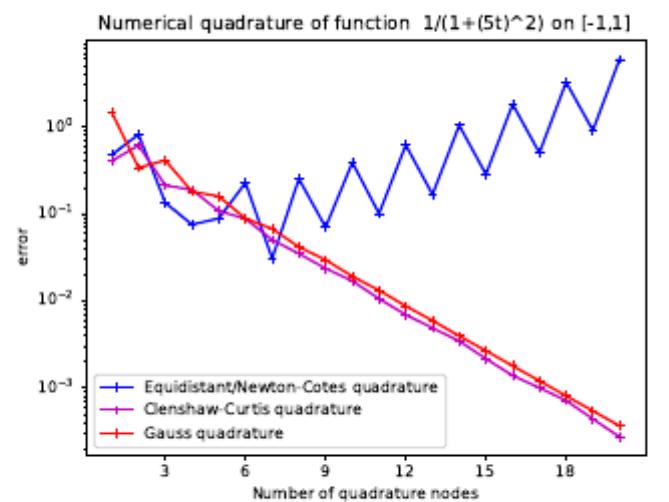
Die Koeffizienten a_k lassen sich mittels FFT³ oder DCT⁴ berechnen.

Für die Stützstellen der Clenshaw-Curtis Quadraturformel gilt der folgende Satz, den wir hier ohne Beweis angeben:

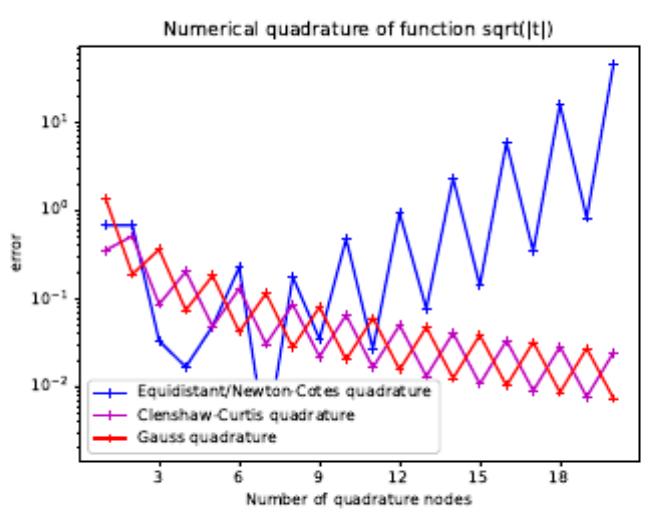
Theorem 1.5.4. Die Stützstellen der Clenshaw-Curtis Quadraturformel sind die Extreme der Chebyschev-Polynome und die Nullstellen der Chebyschev-Polynome 2-ter Art.

Code 1.5.5: Clenshaw-Curtis: direkte Implementierung

Code 1.5.6: Clenshaw-Curtis: Gewichte und Knoten



Fehler für $f_1(t) := \frac{1}{1+(5t)^2}$ auf $[0, 1]$



Fehler für, $f_2(t) := \sqrt{t}$ auf $[0, 1]$

Für Integrale der Form

$$\int_a^b f(x) \omega(x) dx$$

spielen verschiedene orthogonale Polynome eine wesentliche Rolle:

Quadratur	Intervall	Gewichtsfunktion	Polynom	Not.	<code>scipy.special.</code>
Gauss	$(-1, 1)$	1	Legendre	P_k	<code>roots_legendre</code>
Chebyschev I	$(-1, 1)$	$\frac{1}{\sqrt{1-x^2}}$	Chebyschev I	T_k	<code>roots_chebyt</code>
Chebyschev II	$(-1, 1)$	$\sqrt{1-x^2}$	Chebyschev II	U_k	<code>roots_chebyu</code>
Jacobi $\alpha, \beta > 1$	$(-1, 1)$	$(1-x)^\alpha(1+x)^\beta$	Jacobi	$P_k^{(\alpha, \beta)}$	<code>roots_jacobi</code>
Hermite	\mathbb{R}	e^{-x^2}	Hermite	H_k	<code>roots_hermite</code>
Laguerre	$(0, \infty)$	$x^\alpha e^{-x}$	Laguerre	L_k	<code>roots_genlaguerre</code>

Abb. 1.5.10. Gewichtsfunktionen für Quadraturformeln

§3 Einfache Verfahren für ODEs

§3.1 Lokale Linearisierung

ODE = ordinary differential equation

Finde $\underline{y} : [0, T] \rightarrow \mathbb{R}^d$ so dass

$$\begin{cases} \dot{\underline{y}}(t) = f(t, \underline{y}) \\ \underline{y}(0) = \underline{y}_0 \end{cases} \quad f : [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}^d$$

Startwert

Mathematische Pendel



$$m l \ddot{\alpha}(t) = -mg \sin \alpha(t)$$

Physik $\sin \alpha(t) \approx \alpha(t)$

↪ gut nur für $\alpha(t)$ klein

(globale Linearisierung)

$$(0) \begin{cases} \ddot{\alpha}(t) = -\frac{g}{l} \sin \alpha(t) \\ \alpha(0) = \alpha_0 \\ \dot{\alpha}(0) = \dot{\alpha}_0 \end{cases}$$

ODE 2. Ordnung da die 2te Ableitung vorkommt.

$$\dot{\alpha}(t) = \frac{d}{dt} \alpha(t)$$

$$\ddot{\alpha}(t) = \frac{d^2}{dt^2} \alpha(t)$$

$$\sin \alpha = \alpha - \frac{1}{3!} \alpha^3 + \dots = \alpha + O(\alpha^3)$$

↪ klein für α klein

Neues Modell.

$$(1) \begin{cases} \ddot{\beta}(t) = -\frac{g}{l} \beta(t) \\ \beta(0) = \alpha_0 \\ \dot{\beta}(0) = \dot{\alpha}_0 \end{cases} \quad \text{hat exakte Lösung.}$$

$$\omega^2 = \frac{g}{l}$$

$$\beta(t) = \frac{\dot{\alpha}_0}{\omega} \sin(\omega t) + \alpha_0 \cos(\omega t)$$

Trick: Reduziere die Ordnung der ODE:

$$\text{Notieren } p(t) = \dot{\alpha}(t) \Rightarrow$$

$$\dot{p}(t) = \ddot{\alpha}(t) \Rightarrow$$

$$\dot{p}(t) = -\frac{g}{l} \sin \alpha(t)$$

Somit (0) \Leftrightarrow System ODEs 1. Ordnung.

$$\begin{cases} \dot{\alpha} = p \\ \dot{p} = -\frac{g}{l} \sin \alpha \\ \alpha(0) = \alpha_0 \\ p(0) = \dot{\alpha}_0 \end{cases}$$

$$\begin{cases} y_1 = \alpha \\ y_2 = p \end{cases} \quad \begin{cases} \dot{y}_1 = y_2 \\ \dot{y}_2 = -\frac{g}{l} \sin y_1 \end{cases}$$

$$f\left(\begin{bmatrix} y_1 \\ y_2 \end{bmatrix}\right) = \begin{bmatrix} y_2 \\ -\frac{g}{l} \sin y_1 \end{bmatrix}$$

$$\underline{y} = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} \alpha \\ p \end{bmatrix} \quad \underline{y} : [0, T] \rightarrow \mathbb{R}^2 \text{ Unbekannte Funktionen}$$

$$f(\underline{y}) = \begin{bmatrix} y_2 \\ -2y_1 - y_1^2 \end{bmatrix} \quad f: \mathbb{R}^2 \rightarrow \mathbb{R}^2$$

$\underline{y} \mapsto f(\underline{y})$

Bsp Newton Gleichung:

$$m \ddot{u} = F(t, u)$$

$$\text{Notiere } y_1 = u, \quad y_2 = \dot{u} \Rightarrow \dot{\underline{y}} = \begin{bmatrix} \dot{y}_1 \\ \dot{y}_2 \end{bmatrix} = \begin{bmatrix} y_2 \\ \frac{1}{m} F(t, y_1) \end{bmatrix}$$

$$f(t, \underline{y}) = \begin{bmatrix} y_2 \\ \frac{1}{m} F(t, y_1) \end{bmatrix} = \begin{bmatrix} f_1(t, \underline{y}) \\ f_2(t, \underline{y}) \end{bmatrix}$$

$$f_1(t, \underline{y}) = y_2, \quad f_2(t, \underline{y}) = \frac{1}{m} F(t, y_1).$$

Trick: Man kann jede nicht-autonome ODE zu einem System autonomer ODEs

$$\dot{\underline{y}} = f(t, \underline{y}), \quad \text{Notiere } \underline{z} = \begin{bmatrix} \underline{y} \\ t \end{bmatrix} \in \mathbb{R}^{d+1}$$

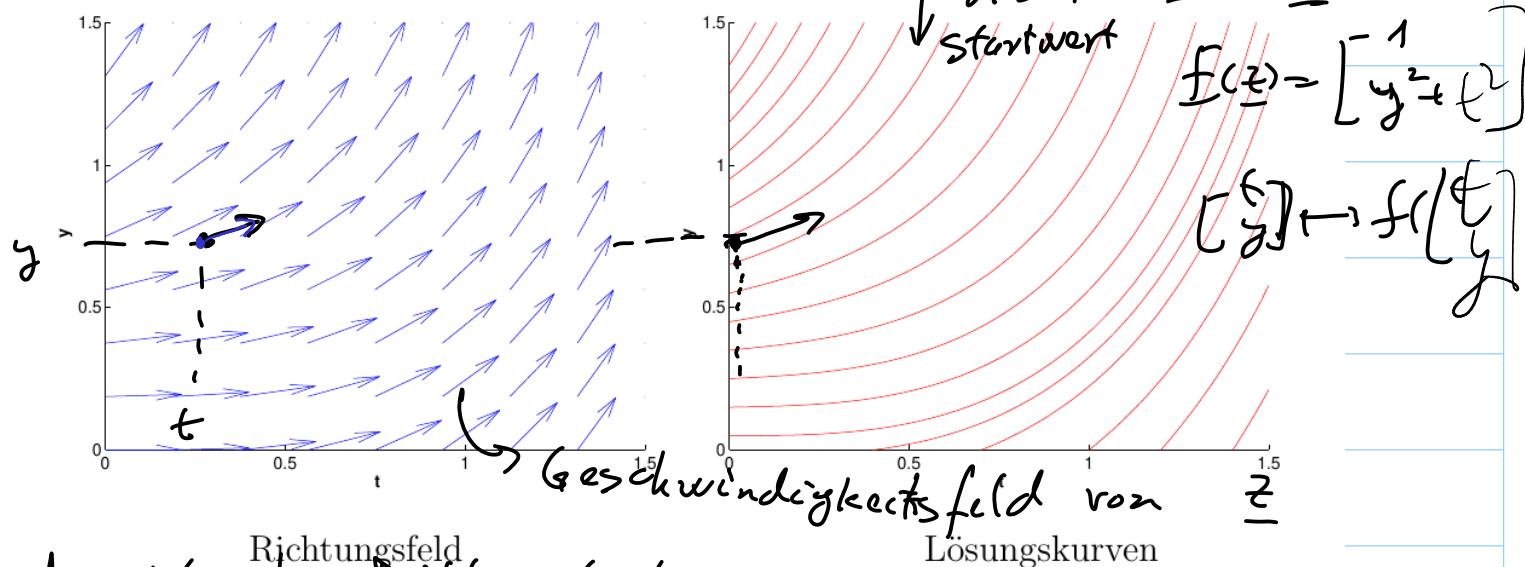
$$\dot{\underline{z}} = g(\underline{z}) \text{ mit } g(z_1) = \begin{bmatrix} f(z_{d+1}) & \begin{bmatrix} z_1 \\ \vdots \\ z_d \end{bmatrix} \\ 1 & \end{bmatrix}$$

Beispiel 2.1.13. (Richtungsfeld und Lösungskurven)

Die Riccati-Differentialgleichung lautet:

$$\dot{y} = y^2 + t^2; \text{ hier: } d = 1, D = \mathbb{R}^+ \text{ und } f \in \mathbb{R}^+$$

Lösungskurve $\underline{z} = \underline{y}$
für diesen $\underline{z} = f(\underline{z})$



$$\dot{y} = (\alpha - \beta y)y$$

$\alpha = \beta = 5$

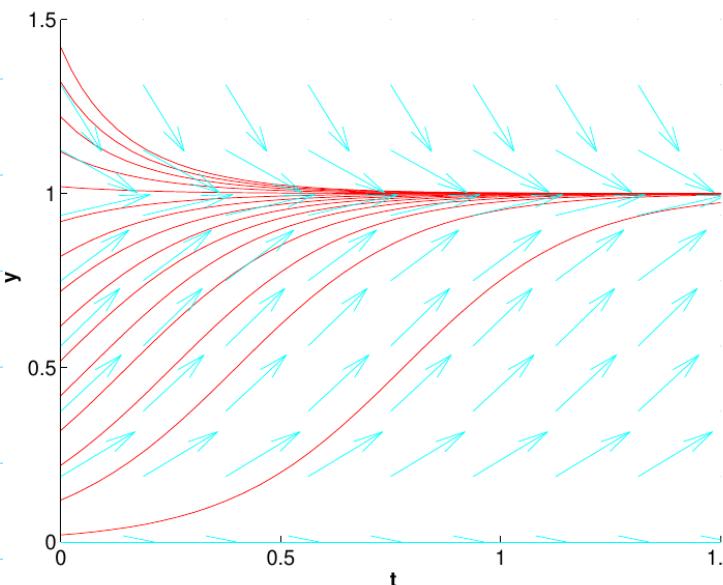
→ attraktiver Fixpunkt

$$f(y) = 5(1-y)y$$

Fixpunkte: $y=1$

$y=0$

repulsiver Fixpunkt



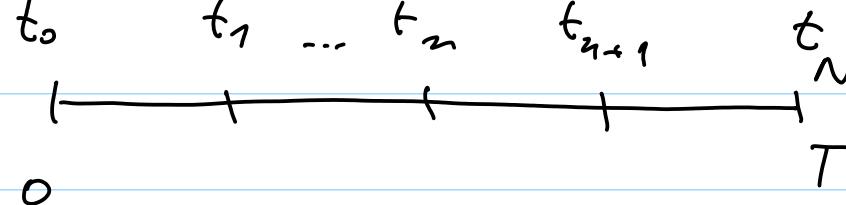
exakte Lösung (2.1.7)

Dem Lineare ODE $\dot{\underline{y}} = A\underline{y} + \underline{b} \rightarrow$ spezielle Techniken. 29

Ziel: Möchte Approximation von

$\underline{y}(T)$ = exakte Lösung zur Endzeit T

Zeitgitter

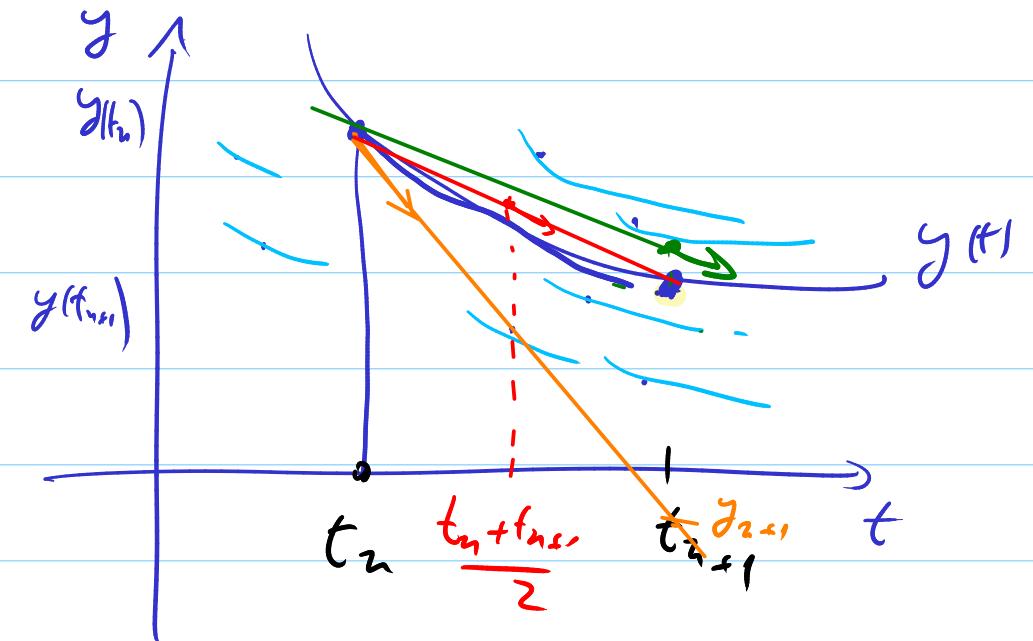
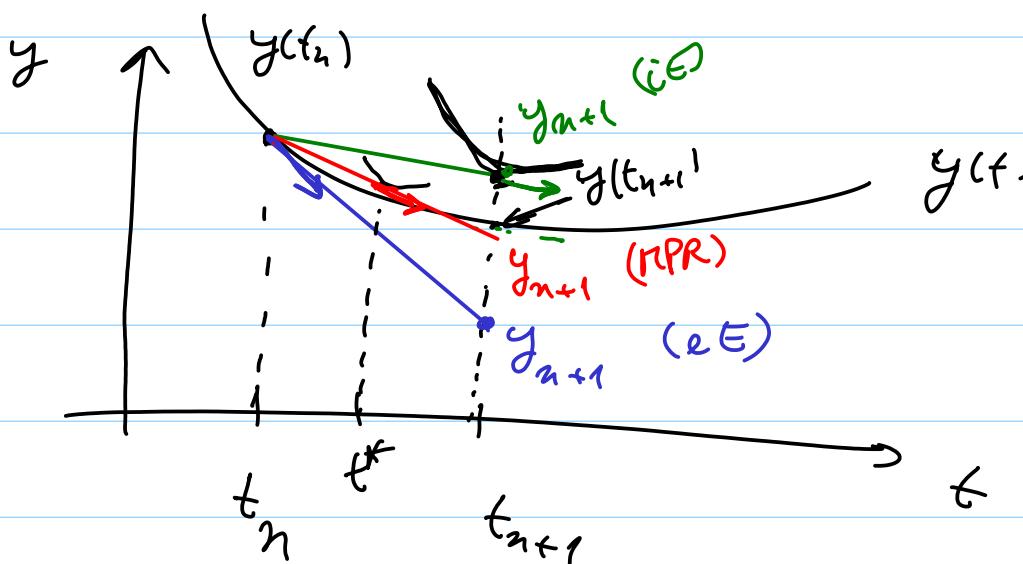


$$0 = t_0 < t_1 < t_2 < \dots < t_n < t_{n+1} < \dots < t_N = T$$

$$\text{Zeitschritt } h_n = t_{n+1} - t_n.$$

Baue Approximationen $\underline{y}_n \approx \underline{y}(t_n)$

Idee local: linearisiere die Lösung local



1) Taylor um t_n für $y(t)$ ausgewertet in $t_{n+1} = t_n + h$

$$\underline{y}(t_n+h) = \underline{y}(t_n) + h \dot{\underline{y}}(t_n) + O(h^2)$$

$\frac{22}{22}$ $\frac{22}{22}$ $\cancel{|| \leftarrow \text{aus der ODE}}$

$$\underline{y}_{n+1} = \underline{y}_n + f(t_n, \underline{y}(t_n)) \approx \underline{y}_n$$

2) Taylor um t_{n+1} für $y(t)$ ausgewertet in $t_n = t_{n+1} - h$

$$\underline{y}(t_{n+1}-h) = \underline{y}(t_{n+1}) - h \dot{\underline{y}}(t_{n+1}) + O(h^2)$$

$\frac{22}{22}$ $\frac{22}{22}$ $\cancel{|| \leftarrow \text{aus der ODE}}$

$$\underline{y}_n = \underline{y}_{n+1} - f(t_{n+1}, \underline{y}(t_{n+1})) \approx \underline{y}_{n+1}$$

(eE) $\begin{cases} \underline{y}_{n+1} = \underline{y}_n + h f(t_n, \underline{y}_n) \\ \underline{y}_0 = \underline{y}(t_0) \end{cases}$ expliziter Euler
 lokaler Fehler $O(h^2)$
 globaler Fehler $O(h)$

(iE) $\begin{cases} \underline{y}_n = \underline{y}_{n+1} - h f(t_{n+1}, \underline{y}_{n+1}) \\ \underline{y}_0 = \underline{y}(t_0) \end{cases}$ impliziter Euler
 lokaler Fehler $O(h^2)$
 globaler Fehler $O(h)$

andere Herleitung

$$f(t_n, \underline{y}(t_n)) = \dot{\underline{y}}(t_n) = \lim_{h \rightarrow 0} \frac{\underline{y}(t_n+h) - \underline{y}(t_n)}{h} \approx \frac{\underline{y}_{n+1} - \underline{y}_n}{h}$$

$$\Rightarrow \underline{y}_{n+1} = \underline{y}_n + h f(t_n, \underline{y}_n)$$

Bsp. $f(t, y) = -\frac{g}{l} \sin y$

(eE) $\underline{y}_{n+1} = \underline{y}_n + h \left(-\frac{g}{l}\right) \sin \underline{y}_n$
 $\underline{y}_0 \rightarrow \underline{y}_1 \rightarrow \underline{y}_2 \rightarrow \dots \rightarrow \underline{y}_N$
 explizit

implizit

(iE) $\underline{y}_n = \underline{y}_{n+1} - h \left(-\frac{g}{l}\right) \sin \underline{y}_{n+1}$
 $\underline{y}_0 \rightarrow \underline{y}_1$ aus einer nicht-linearen Gleichung ausrechnen.
 $\underline{y}_0 = \underline{y}_1 + h \frac{g}{l} \sin \underline{y}_1 \Leftrightarrow$
 $\underline{y}_1 + h \frac{g}{l} \sin \underline{y}_1 - \underline{y}_0 = 0 \Leftrightarrow F(\underline{y}_1) = 0$
 Nullstelle verwenden fsolve 31

3) Taylor um $t^* = \frac{1}{2}(t_n + t_{n+1}) = t_n + \frac{h}{2}$ für $\underline{y}(f)$

ausgewertet in $t_{n+1} = t^* + \frac{h}{2}$:

$$\underline{y}(t_{n+1}) = \underline{y}(t^*) + \frac{h}{2} \dot{\underline{y}}(t^*) + \frac{1}{2} \left(\frac{h}{2}\right)^2 \ddot{\underline{y}}(t^*) + O\left(\left(\frac{h}{2}\right)^3\right)$$

ausgewertet in $t_n = t^* - \frac{h}{2}$:

$$\underline{y}(t_n) = \underline{y}(t^*) - \frac{h}{2} \dot{\underline{y}}(t^*) + \frac{1}{2} \left(-\frac{h}{2}\right)^2 \ddot{\underline{y}}(t^*) + O\left(\left(\frac{h}{2}\right)^3\right)$$

Subtraktion \Rightarrow

$$\underline{y}(t_{n+1}) - \underline{y}(t_n) = h \dot{\underline{y}}(t^*) + O(h^3)$$

$$\begin{array}{c} \cancel{u} \\ \cancel{u} \\ \underline{y}_{n+1} \end{array} \quad \begin{array}{c} \cancel{u} \\ \cancel{u} \\ \underline{y}_n \end{array} \quad \begin{array}{c} \cancel{u} \\ \cancel{u} \\ f(t^*, \underline{y}(t^*)) \end{array}$$

en $\underline{y}(t^*)$ stört noch, brauche noch ein Trick!

3a) Trick: $\underline{y}\left(\frac{1}{2}(t_n + t_{n+1})\right) \approx \frac{1}{2} (\underline{y}(t_n) + \underline{y}(t_{n+1}))$ \Rightarrow

$$\boxed{\underline{y}_{n+1} = \underline{y}_n + h \int [t_n + \frac{h}{2}, \frac{1}{2}(\underline{y}_n + \underline{y}_{n+1})]} \quad (\text{iMP})$$

implizite Mittelpunktsregel.

lokaler Fehler $O(h^3)$

3b) Trick: $f(t^*, \underline{y}(t^*)) \approx \frac{1}{2} (f(t_n, \underline{y}_n) + f(t_{n+1}, \underline{y}_{n+1}))$

$$\Rightarrow \boxed{\underline{y}_{n+1} = \underline{y}_n + \frac{h}{2} (f(t_n, \underline{y}_n) + f(t_{n+1}, \underline{y}_{n+1}))} \quad (\text{iTR})$$

implizite Trapezregel.

lokaler Fehler $O(h^3)$

$$\Rightarrow \text{global } \| \underline{y}(T) - \underline{y}_n \| \leq C \cdot h^2$$

Bei Das geht nur wenn $y(f)$ glatt genug ist.

Bsp Addiere die 2 Taylor-Entwicklungen:

$$\underline{y}(t_{n+1}) + \underline{y}(t_n) = 2\underline{y}(t^*) + \left(\frac{h}{2}\right)^2 \ddot{y}(t^*) + O(h^4)$$

$$\Rightarrow \ddot{y}(t^*) = \frac{\underline{y}(t_{n+1}) - 2\underline{y}(t^*) + \underline{y}(t_n)}{\left(\frac{h}{2}\right)^2} + O(h^2)$$

Daraus:

$$\ddot{y}(t_n + \frac{h}{2}) \approx \frac{\underline{y}_{n+1} - 2\underline{y}_{n+\frac{1}{2}} + \underline{y}_n}{\left(\frac{h}{2}\right)^2}$$

mit lokaler Fehler $O(h^2)$

§3.2. Störmer-Verlet Verfahren

Newton'sche Gleichung = ODE n. 2. Ordnung.

$$\begin{cases} \ddot{y} = f(t, y) \\ y(t_0) = y_0 \\ \dot{y}(t_0) = v_0 \end{cases}$$

$$f(t_n, \underline{y}_n) = \ddot{y}(t_n) \approx \frac{\underline{y}_{n+1} - 2\underline{y}_n + \underline{y}_{n-1}}{h^2} \Rightarrow$$

$$\underline{y}_{n+1} = -\underline{y}_{n-1} + 2\underline{y}_n + h^2 f(t_n, \underline{y}_n)$$

(St=V)

Störmer-Verlet

Bsp Selbe Rechnung um t_n ausgewertet in t_{n+1}, t_{n-1}

gibt

$$\ddot{y}(t_n) \approx \frac{\underline{y}_{n+1} - 2\underline{y}_n + \underline{y}_{n-1}}{h^2}$$

mit lokaler Fehler
 $O(h^2)$

explizit, 2-Schritt-Verfahren

\Rightarrow brauche Startwerte $\underline{y}(t_0) = y_0$

$$\underline{y}_1 \approx \underline{y}(t_1)$$

Startwert: Taylor mit 3 Terzo:

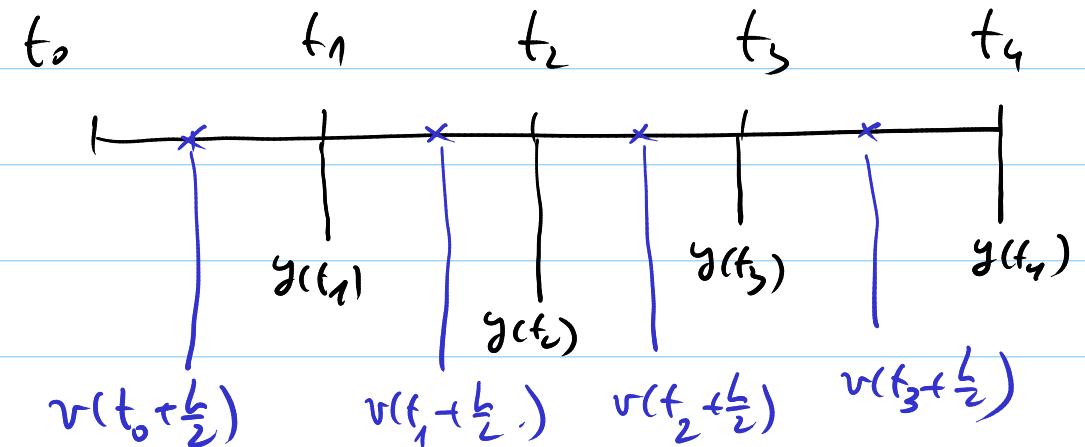
$$\underline{y}(t_1) = \underline{y}(t_0) + h \dot{y}(t_0) + \frac{h^2}{2} \ddot{y}(t_0) + O(h^3) \Rightarrow$$

$$\underline{y}_1 = \underline{y}_0 + h v_0 + \frac{h^2}{2} f(t_0, \underline{y}_0)$$

(St-V) lokal $O(h^3)$ und global $O(h^2)$

$$\|\underline{y}(T) - \underline{y}_n\| \leq c \cdot h^2$$

Vorriere $v_{n+\frac{1}{2}} = \frac{\underline{y}_{n+1} - \underline{y}_n}{h}$ entspricht $\underline{v}(t_n + \frac{1}{2}h) = \underline{v}(t_n + \frac{h}{2})$



$$\text{in (St-V)}: \underline{y}_{n+1} = \underline{y}_n + (\underline{y}_n - \underline{y}_{n-1}) + h^2 f(t_n, \underline{y}_n)$$

$$\underline{y}_{n+1} = \underline{y}_n + h \left(\frac{\underline{y}_n - \underline{y}_{n-1}}{h} + h f(t_n, \underline{y}_n) \right)$$

$$\underline{y}_{n+1} = \underline{y}_n + h \left(\underline{v}_{n-\frac{1}{2}} + h f(t_n, \underline{y}_n) \right)$$

$\underbrace{\hspace{1cm}}$
 $\underline{v}_{n+\frac{1}{2}}$

Leap-Frog:

$$\left\{ \begin{array}{l} \underline{v}_{n+\frac{1}{2}} = \underline{v}_{n-\frac{1}{2}} + h f(t_n, \underline{y}_n) \\ \underline{y}_{n+1} = \underline{y}_n + h \underline{v}_{n+\frac{1}{2}} \end{array} \right.$$

!

= versetzte Gitter für Position \underline{y} und Geschwindigkeit \underline{v}

"staggered grids"

Besser noch "Velocity-Verlet"-Methode:

$$\left\{ \begin{array}{l} \underline{y}_{n+1} = \underline{y}_n + h \underline{v}_n + \frac{h^2}{2} f(t_n, \underline{y}_n) \\ \underline{v}_{n+1} = \underline{v}_n + h \frac{1}{2} \left(f(t_n, \underline{y}_n) + f(t_n, \underline{y}_{n+1}) \right) \end{array} \right.$$

!

Beweise die Herleitung von (VV) aus (StV)

$$\text{(StV)} \quad y_{n+1} = -y_{n-1} + 2y_n + h^2 f(t_n, y_n) \quad \left. \begin{array}{l} \\ \end{array} \right\} \oplus \quad 2y_{n+1} = 2y_n + 2h v_n + h^2 f(t_n, y_n) \Rightarrow y_{n+1} = y_n + h v_n + \frac{h^2}{2} f(t_n, y_n)$$

Notiere $v_n = \frac{y_{n+1} - y_{n-1}}{2h} \Rightarrow y_{n+1} - y_{n-1} = 2h v_n$

Update von v_n ?

$$v_n = \frac{y_{n+1} - y_{n-1}}{2h} = \frac{2y_n - 2y_{n-1} + h^2 f(t_n, y_n)}{2h} = \frac{y_n - y_{n-1}}{h} + \frac{h}{2} f(t_n, y_n) \Rightarrow$$

$$v_n = \frac{y_n - y_{n-1}}{h} + \frac{h}{2} f(t_n, y_n) \quad \left. \begin{array}{l} \\ \end{array} \right\} \oplus$$

$$v_{n+1} = \frac{y_{n+1} - y_n}{h} + \frac{h}{2} f(t_{n+1}, y_{n+1})$$

$$v_n + v_{n+1} = \frac{y_{n+1} - y_{n-1}}{h} + \frac{h}{2} [f(t_n, y_n) + f(t_{n+1}, y_{n+1})] \Rightarrow$$

$\underbrace{\phantom{f(t_n, y_n) + f(t_{n+1}, y_{n+1})}_{2v_n}}$

$$\Rightarrow v = v + \frac{h}{2} [f(t_n, y_n) + f(t_{n+1}, y_{n+1})]$$

Vorteile von VV:

- + stabiler als (StV)
- + $y_n \approx y(t_n)$, $v_n \approx y'(t_n)$ auf demselben Zeitrythm.
- + global $O(h^2)$ also genauer als (EF), (iE)
- + explizit (vergleiche iMP, iTR)
- + erhält die Energie

Beweis für die Konvergenzordnung: FS2019.

$$\dot{u}(t) = f(t, u)$$



$$y_1 = t \Rightarrow \dot{y}_1 = 1$$

$$y_2 = u \Rightarrow \dot{y}_2 = \dot{u} = f(y_1, y_2)$$

$$\underline{\dot{y}} = F(\underline{y}) \text{ mit } F\left(\begin{matrix} y_1 \\ y_2 \end{matrix}\right) = \left[\begin{matrix} 1 \\ f(y_1, y_2) \end{matrix}\right]$$

autonom!

§3.3 Splitting Verfahren

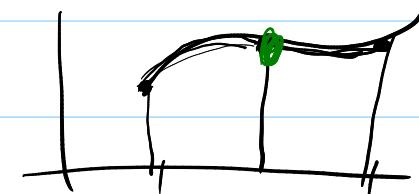
→ Autonome ODEs

Bem $\dot{y} = f(t, y)$

$$y(s) = \underline{x} \in \mathbb{R}^d$$

Notiere $\Phi^{s,t}(\underline{x}) = \underline{y}(t)$ mit $y(s) = \underline{x}$

$\Phi^{s,t}: D \rightarrow D$ zweiparametrische
 $\mathbb{R}^d \mathbb{R}^d$ Familie von
 Fluss der ODE



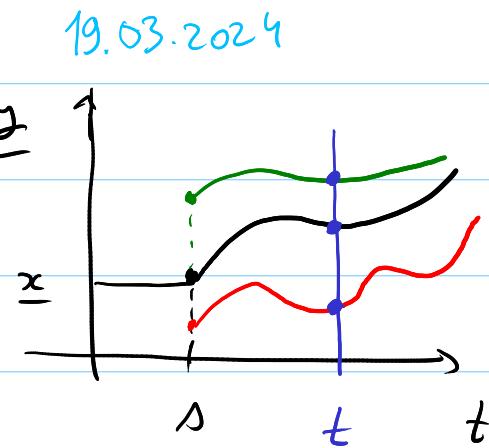
1) $\Phi^{t,t}(\underline{x}) = \underline{x}$ für alle \underline{x}

2) $\Phi^{s,t} = \Phi^{r,s} \circ \Phi^{s,r}$.

3) autonome ODEs sind invariant:

$$\Phi^{s,t} = \Phi^{0,t-s} = \Phi^{t-s}$$

notation



Beweis Sei $t^* \in \mathbb{R}$ fest. Translation in der Zeit:

$$\underline{u}(t) = \underline{y}(t + t^*)$$

Berechne $\frac{d}{dt} \underline{y}(t) = \underline{\dot{y}}(t + t^*) \cdot 1 = f(\underline{y}(t + t^*)) = f(\underline{u}(t))$

$$\Rightarrow \dot{\underline{u}} = f(\underline{u}).$$

Idee vom Splitting: kombiniere Flüsse verschiedener ODEs

Wie? Begründung für lineare ODEs:

Bsp $e^{\lambda h} = \sum_{n=0}^{\infty} \frac{1}{n!} (\lambda h)^n$ Exponentiellefunktion.

auch als die Lösung der ODE:

$$\dot{y}(t) = \lambda y(t) \text{ mit } y(0) = 1$$

Für mehrere lineare entkoppelte ODE:

$$\dot{y}_1(t) = \lambda_1 y_1(t) \Rightarrow y_1(h) = e^{\lambda_1 h} \quad y_1(0) = 1$$

$$\dot{y}_2(t) = \lambda_2 y_2(t) \Rightarrow y_2(h) = e^{\lambda_2 h}$$

$$\dots$$

$$\dot{y}_d(t) = \lambda_d y_d(t) \Rightarrow y_d(h) = e^{\lambda_d h} \quad y_d(0) = 1$$

$$\underline{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_d \end{bmatrix}; \quad \underline{\dot{y}} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_d) \underline{y}$$

mit Lösung.

$$\underline{y}(h) = \text{diag}\left(e^{\lambda_1 h}, e^{\lambda_2 h}, \dots, e^{\lambda_d h}\right) \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix}$$

!! notation!
 $e^{h \text{diag}(\lambda_1, \dots, \lambda_d)}$

$$e^{h \text{diag}(\lambda_1, \dots, \lambda_d)} = \sum_{n=0}^{\infty} \frac{1}{n!} (\text{diag}(\lambda_1, \dots, \lambda_d))^n$$

$$\text{Verallgemeinert: } \underline{\dot{y}} = \underline{\underline{M}} \underline{y} \quad \text{mit} \quad \underline{\underline{M}} \in \mathbb{R}^{d \times d}$$

$$\text{mit Lösung} \quad \underline{y}(t) = e^{\underline{\underline{M}} t} \underline{y}_0$$

alternativ

$$e^{\underline{\underline{M}} t} = \sum_{n=0}^{\infty} \frac{1}{n!} (\underline{\underline{M}} t)^n$$



NICHT für numerische Berechnungen.

Numerisch: "exp3" = Padé-Approximation

$$e^{rh} = \lim_{n \rightarrow \infty} \frac{P_n(rh)}{Q_n(rh)}$$

$O(d^3)$

Oder Krylov-Verfahren.



auch nicht so: $\underline{\underline{E}}\underline{\underline{W}}, \underline{\underline{E}}\underline{\underline{V}}$!!

$\underline{\underline{M}} \approx \underline{\underline{M}}$

$$\underline{\underline{M}} = \underline{\underline{Q}} \underline{\underline{D}} \underline{\underline{Q}}^T \Rightarrow e^{\underline{\underline{M}} h} = \underline{\underline{Q}} e^{\underline{\underline{D}} h} \underline{\underline{Q}}^T$$

$$\text{Bsp} \quad \underline{\underline{M}} = \underline{\underline{A}} + \underline{\underline{B}}$$

$$e^{\underline{\underline{(A+B)}} h} = \underline{\underline{I}} + (\underline{\underline{A}} + \underline{\underline{B}})h + \underbrace{\frac{1}{2} (\underline{\underline{A}}^2 + \underline{\underline{A}}\underline{\underline{B}} + \underline{\underline{B}}\underline{\underline{A}} + \underline{\underline{B}}^2) h^2}_{\text{red wavy line}} + \dots$$

$$e^{\underline{\underline{A}} h} e^{\underline{\underline{B}} h} = (\underline{\underline{I}} + \underline{\underline{A}} h + \frac{1}{2} \underline{\underline{A}}^2 h^2 + \dots)(\underline{\underline{I}} + \underline{\underline{B}} h + \frac{1}{2} \underline{\underline{B}}^2 h^2 + \dots) =$$

$$= \underline{\underline{I}} + \underbrace{(\underline{\underline{A}} + \underline{\underline{B}})h}_{\text{green line}} + \underbrace{(\frac{1}{2} \underline{\underline{A}}^2 + \underline{\underline{A}}\underline{\underline{B}} + \frac{1}{2} \underline{\underline{B}}^2)h^2}_{\text{yellow line}} + \dots$$

$$\underline{\underline{AB}} \neq \underline{\underline{BA}} \Rightarrow e^{\underline{\underline{(A+B)}} h} \neq e^{\underline{\underline{A}} h} e^{\underline{\underline{B}} h}$$

aber man kann erweisen dass

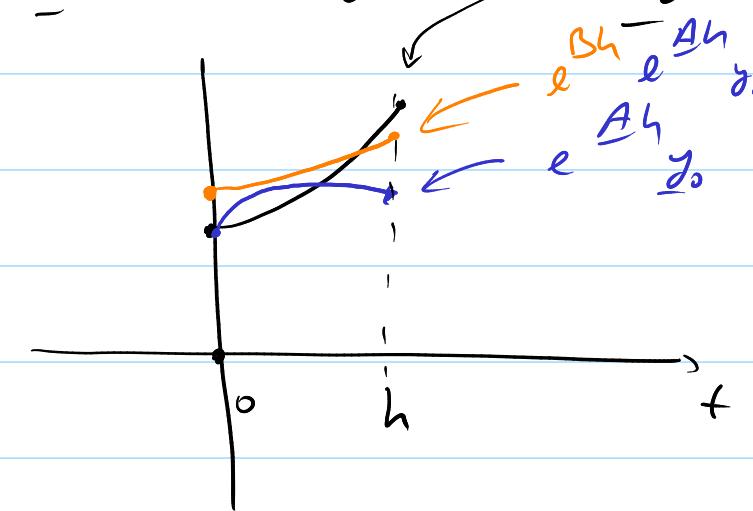
$$\left(e^{(\underline{A} + \underline{B})h} - e^{\underline{A}h} e^{\underline{B}h} \right) \approx O(h^2)$$

↑

$$\left(e^{(\underline{A} + \underline{B})h} - e^{\underline{B}h} e^{\underline{A}h} \right) \approx O(h^2)$$

lokaler Fehler, global zu $T \Rightarrow O(h)$

$$\dot{\underline{y}} = (\underline{A} + \underline{B})\underline{y} \quad \text{mit L\ddot{o}sung } e^{(\underline{A} + \underline{B})h} \underline{y}_0$$



$$\dot{\underline{y}} = \underline{A}\underline{y}$$

$$\dot{\underline{y}} = \underline{B}\underline{y}$$

SPLITTING!

Bew Für autonome ODE

$$(1) \quad \dot{\underline{y}} = \underline{f}(\underline{y}) \quad \text{mit} \quad \underline{f}(\underline{y}) = \underline{f}_a(\underline{y}) + \underline{f}_b(\underline{y})$$

Idee wähle \underline{f}_a und \underline{f}_b so dass

$$(a) \quad \boxed{\dot{\underline{y}} = \underline{f}_{-a}(\underline{y})}$$

und.

$$(b) \quad \boxed{\dot{\underline{y}} = \underline{f}_{-b}(\underline{y})}$$

einfach oder exakt lösbar sind.

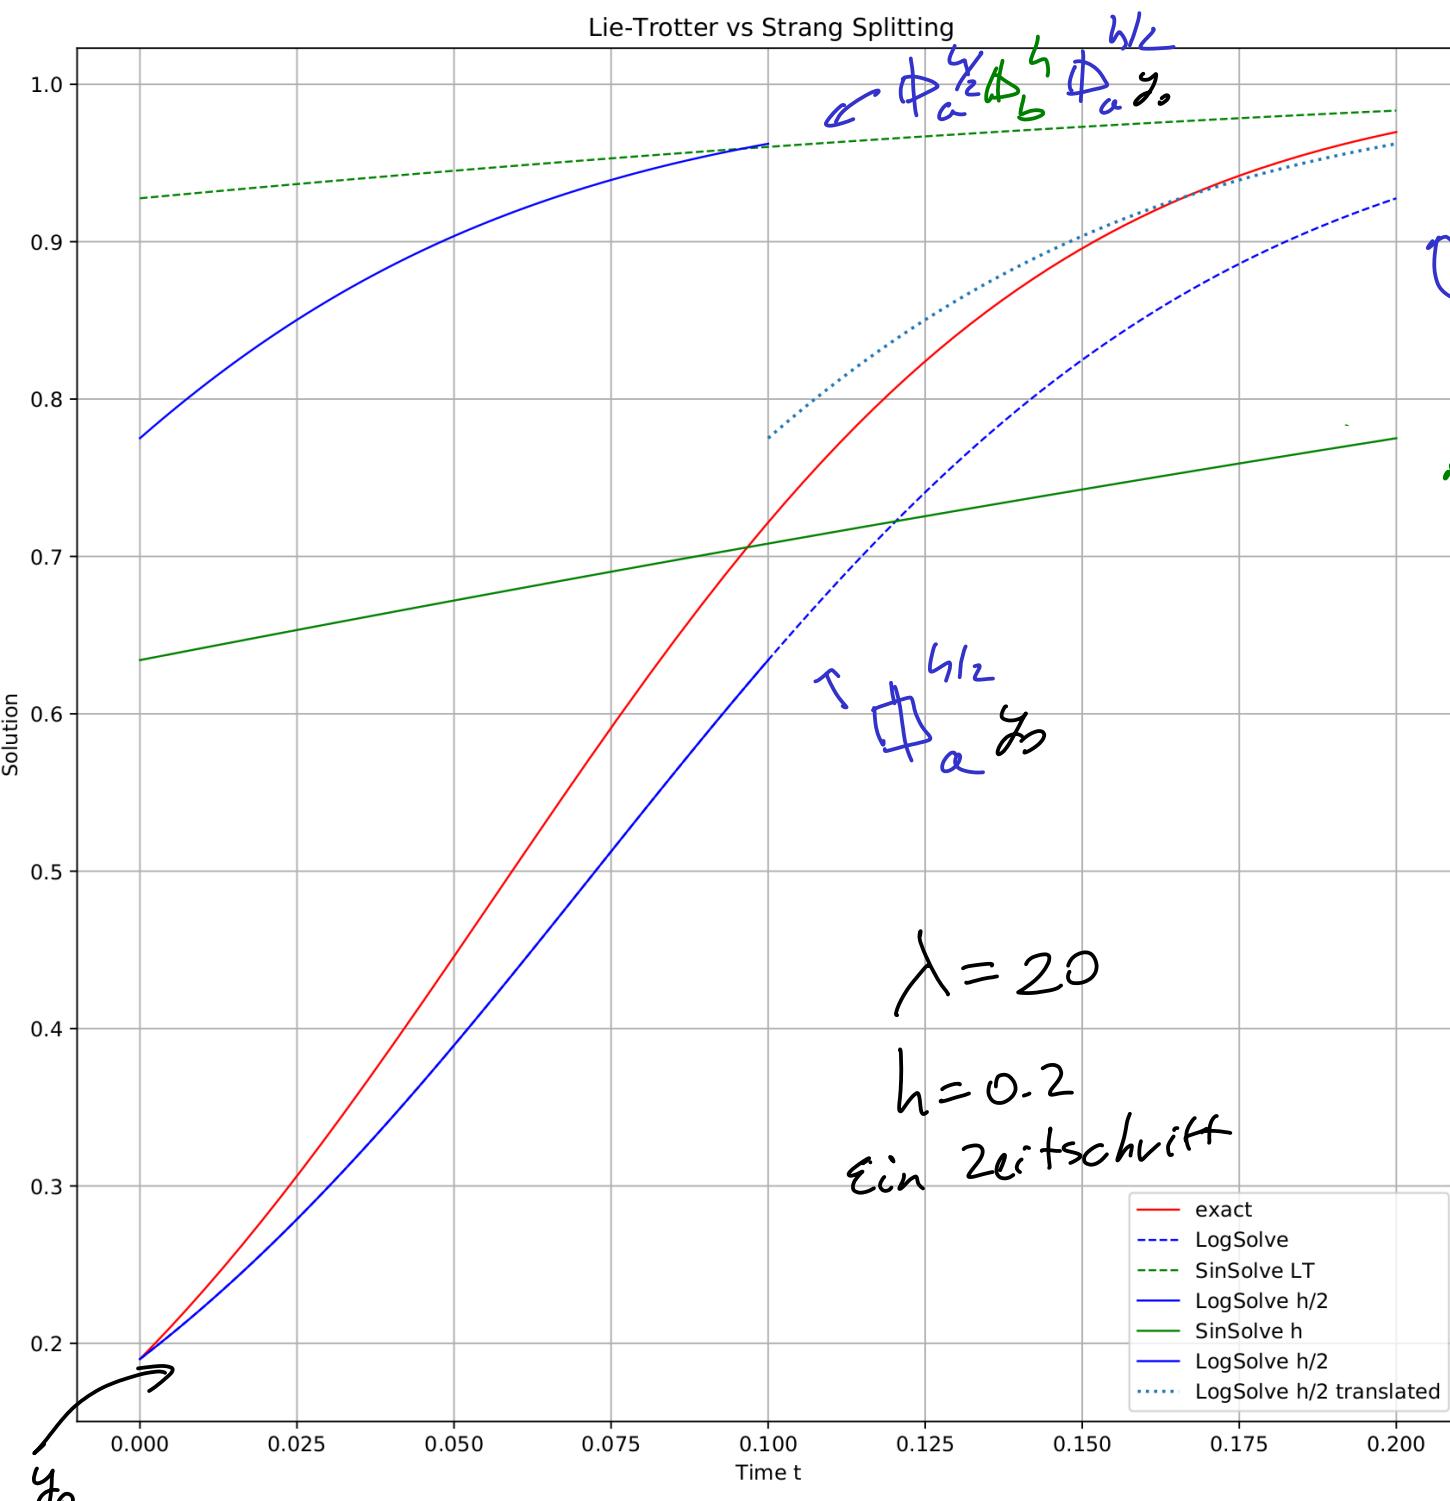
$$\Psi_1^h = \underline{\Phi}_{\underline{y}_0}^h \underline{\Phi}_a^h \approx \underline{\Phi}^h \quad \text{Lie-Trotter Splitting.}$$

non konz beweisen

$$\underbrace{\|\Psi_1^h \dots \Psi_1^h \Psi_1^h \underline{y}_0 - \underline{\Phi}^h \underline{y}_0\|}_{\text{wenn } nh=T} \leq c \cdot h$$

lokal $n h = T$

$$\text{lokal } \|\Psi_1^h \underline{y}_0 - \underline{\Phi}^h \underline{y}_0\| \leq c \cdot h^2$$



$$\text{Lie-Trotter-Lösung} = \Phi_a^h \Phi_b^h g_0$$

$$\text{"exacte Lösung"} = \Phi_{(1)}^{20} g_0$$

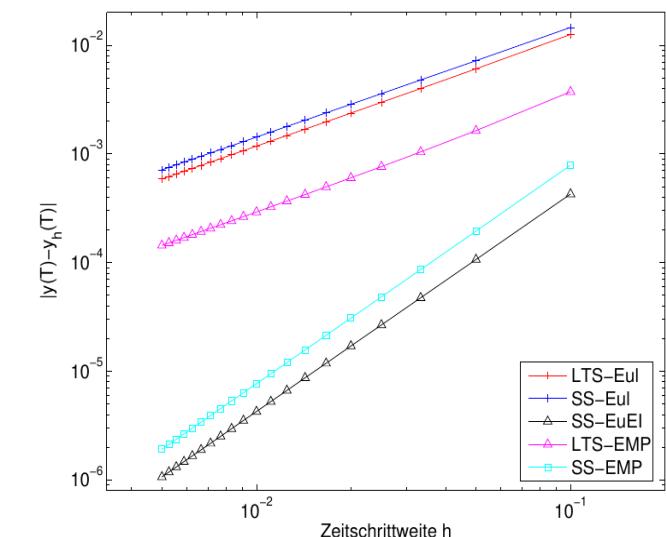
$$\text{Strang-Lösung} = \Phi_a^h \Phi_b^h \Phi_a^{h/2} g_0$$

$$\Phi_a^h g_0$$

$$\Phi_b^h \Phi_a^{h/2} g_0$$

Wenn (a) oder (b) nicht exakt lösbar, dann nimmt man numerische Methoden dafür:

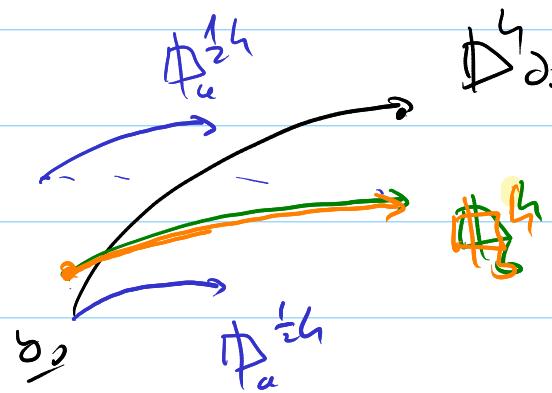
Bsp



LTS-Eul	explizites Euler als $\Psi_{a,b}^h$, $\Psi_{a,b}^h$ und Lie-Trotter-Splitting
SS-Eul	explizites Euler als $\Psi_{a,b}^h$, $\Psi_{a,b}^h$ und Strang-Splitting
SS-EuEI	Strang-Splitting: explizites Euler als $\Phi_a^{h/2}$, exaktes Φ_b^h und implizites Euler als $\Psi_a^{h/2}$
LTS-EMP	explizite Mittelpunkt-Regel als $\Psi_{a,b}^h$, $\Psi_{a,b}^h$ und Lie-Trotter-Splitting
SS-EMP	explizite Mittelpunkt-Regel als $\Psi_{h,g}^h$, $\Psi_{h,f}^h$ und Strang-Splitting

Abb. 2.4.5. Einfache Splitting-Verfahren

Bem Symmetrie schenkt uns eine Oderung mehr:



Strong splitting

$$P^h \approx P_a^{1,h} + P_a^{2,h}$$

$$\begin{array}{ll} \text{lokal} & O(h^3) \\ \text{global} & O(h^2) \end{array}$$

Allgemeines Splittingverfahren.

$$P^h = \frac{\Delta}{T} \sum_{i=1}^n P_a^{b_i h} + P_a^{a_i h}$$

$$\sum_{i=1}^n a_i = 1 = \sum_{i=1}^n b_i$$

$$\Delta = 1 \quad a_1 = b_1 = 1 \quad \text{Lie-Trotter}$$

$$\Delta = 2 \quad a_1 = a_2 = \frac{1}{2}, \quad b_1 = 1, \quad b_2 = 0 \quad \text{Strong}$$

Code 4.4.9: Einige Splitting Routinen
Code 4.4.11: Energieerhaltung beim Splitting Verfahren
Code 4.4.13: Fehler der Splitting Verfahren

Bsp Splitting Verfahren für Newton'sches Gleichung

$$\dot{r} = \underline{a}(r) \Leftrightarrow \dot{\underline{z}} = \begin{bmatrix} \dot{r} \\ \dot{v} \end{bmatrix} = \begin{bmatrix} r \\ v \end{bmatrix} = \underline{F}(\underline{z})$$

$$\underline{F}(\underline{z}) = \underline{F}\left(\begin{bmatrix} r \\ v \end{bmatrix}\right) = \begin{bmatrix} v \\ a(r) \end{bmatrix} = \underbrace{\begin{bmatrix} 0 \\ a(r) \end{bmatrix}}_{\underline{f}} + \underbrace{\begin{bmatrix} v \\ 0 \end{bmatrix}}_{\underline{g}}$$

$$\dot{\underline{z}} = \boxed{\underline{f}(\underline{z})} + \boxed{\underline{g}(\underline{z})}$$

$$\text{Startwert } \underline{z}_0 = \begin{bmatrix} r_0 \\ v_0 \end{bmatrix}$$

$$(a) \quad \dot{\underline{z}} = \underline{f}(\underline{z}) \Leftrightarrow \begin{cases} \dot{r} = 0 \\ \dot{v} = a(r) \end{cases}$$

Löse "exakt"
von r_0, v_0 zu h

$$\dot{r} = 0 \Rightarrow r(t) = \text{konstant} = r_0 \Rightarrow r(h) = r(0) = r_0$$

$$\dot{v} = a(r_0) \Rightarrow v(t) = a(r_0)t + v_0$$

$$\Rightarrow v(h) = a(r_0)h + v_0$$

EXAKT 😊

$$\Phi_f^h \begin{bmatrix} r_0 \\ v_0 \end{bmatrix} = \begin{bmatrix} r_0 \\ a(r_0)h + v_0 \end{bmatrix}$$

$$(b) \quad \dot{y} = g(y) \quad \begin{cases} \dot{r} = v \\ \dot{v} = 0 \Rightarrow v(h) = v(0) = v_0 \end{cases}$$

$$\dot{r} = v_0 \Rightarrow r(h) = v_0 h + r_0 \quad EXAKT \quad \checkmark$$

$$\Phi_g^h \begin{bmatrix} r_0 \\ v_0 \end{bmatrix} = \begin{bmatrix} v_0 h + r_0 \\ v_0 \end{bmatrix}$$

Kombiniere diese 2 exakten Lösungen:

(1) Lie-Trotter

$$\Psi^h \begin{bmatrix} r \\ v \end{bmatrix} = \Phi_g^h \Phi_f^h \begin{bmatrix} r \\ v \end{bmatrix} = \Phi_g^h \begin{bmatrix} r \\ a(r)h + v \end{bmatrix} = \begin{bmatrix} r + (a(r)h + v)h \\ a(r)h + v \end{bmatrix}$$

sympplektisches Euler-Verfahren glösbar

→ diese zerlegung separiert 2 Variablen.

s hängt effektiv nur von r ab $\left\{ \Rightarrow \begin{array}{l} v \\ \text{as} \end{array} \right\}$

2

⇒ EXAKTE LÖSUNGEN!

(2) Strong-Splitting.

$$\begin{aligned} \Psi^h \begin{bmatrix} r \\ v \end{bmatrix} &= \Phi_g^{\frac{h}{2}} \Phi_f^{\frac{h}{2}} \begin{bmatrix} r \\ v \end{bmatrix} = \Phi_g^{\frac{h}{2}} \Phi_f^{\frac{h}{2}} \begin{bmatrix} r + v \frac{h}{2} \\ v \end{bmatrix} = \\ &= \Phi_g^{\frac{h}{2}} \begin{bmatrix} r + v \frac{h}{2} \\ v + h a(r + \underbrace{v \frac{h}{2}}_{\downarrow}) \end{bmatrix} = \\ &= \begin{bmatrix} r + v \frac{h}{2} + h \underbrace{(r + v \frac{h}{2})}_{\text{r}_{k+\frac{1}{2}}} \\ v + h a(r + v \frac{h}{2}) \end{bmatrix} \end{aligned}$$

Notiere

$$\left\{ \begin{array}{l} r_{k+\frac{1}{2}} = r_k + \frac{1}{2} h v_k \\ v_{k+1} = v_k + h a(r_{k+\frac{1}{2}}) \\ r_{k+1} = r_k + \frac{h}{2} v_{k+1} \end{array} \right.$$

ein-Schritt-Formulierung des St-Vorlets Verfahren!

Bem Trick geht genau so für separable Hamilton'system:

$$H(\underline{P}, \underline{q}) = T(\underline{P}) + V(\underline{q})$$

Gesucht $\underline{P}, \underline{q} : [0, T] \rightarrow \mathbb{R}$

$$\begin{cases} \dot{p}_j = -\frac{\partial H}{\partial q_j}(\underline{P}(t), \underline{q}(t)) \\ \dot{q}_j = \frac{\partial H}{\partial p_j}(\underline{P}(t), \underline{q}(t)) \end{cases} \quad \begin{array}{l} \text{autonomes} \\ \text{Ho'-System,} \\ \text{mit Hamiltonfunktion } H \end{array}$$

für $j = 1, 2, \dots, d$

Bem $H(\underline{P}, \underline{q})$ ist Invariante für das Ho'-System!

Bem Leicht gestörte Probleme:

$$\dot{y} = f_a(y) + \underbrace{\varepsilon f_b(y)}_{\substack{\downarrow \\ \text{dominant}}} \quad \text{mit } \varepsilon \text{ klein}$$

Perturbation.

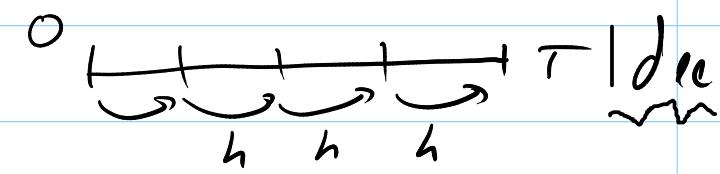
optimierte Splitting-Verfahren
 $O(\varepsilon^{r_1} h^{r_1} + \varepsilon^2 h^{r_2} + \varepsilon^3 h^{r_3} + \dots)$
 mit $r_1 > r_2 > r_3 > \dots$

$$\text{z.B.: } O(\varepsilon^{r_1} h^{r_1} + \varepsilon^2 h^{r_2})$$

Achtung: Perturbationsproblem, nicht-autonom.
 im splitting: t zu f_a

Bem Splitting ist explizit
 Sobald wir Ordnung > 2 haben wollen,
 gibt es negative Parameter a_i, b_i .

Processing Methoden



dec: rechne mit der besseren Methode 4

z-Teilschrift und verwenden $\bar{\alpha}^h$, $(\bar{\pi}^h)^{-1}$ nur
ein Mal (oder bei Ausgäsen)

$$\hat{\psi}^h \text{ def }= \bar{\pi}^h \circ \psi^h \circ (\bar{\pi}^h)^{-1}$$

↳ post-processor ↳ pre-processor

$$(\hat{\psi}^h)^n = \bar{\pi}^h \circ \psi^h \circ (\bar{\pi}^h)^{-1} \circ \bar{\pi}^h \circ \psi^h \circ (\bar{\pi}^h)^{-1} \circ \dots \circ \bar{\pi}^h \circ \psi^h \circ (\bar{\pi}^h)^{-1}$$

$$= \bar{\pi}^h \circ (\hat{\psi}^h)^n \circ (\bar{\pi}^h)^{-1}$$

Bsp Strong-Splitting:

$$\psi_2^h = \Phi_a^{\frac{h}{2}} \Phi_b^h \Phi_a^{\frac{h}{2}} \cdot I = \Phi_a^{\frac{h}{2}} \left(\Phi_b^h \Phi_a^h \right) \left(\Phi_a^{\frac{h}{2}} \right)^{-1}$$

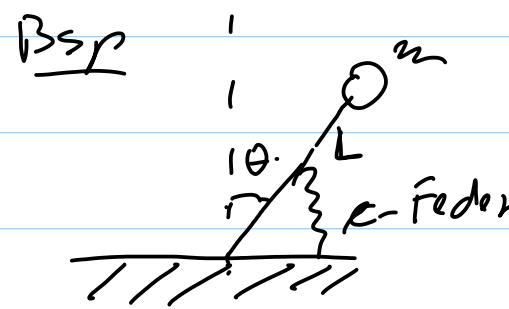
$\Phi_a^{\frac{h}{2}} \left(\Phi_a^{\frac{h}{2}} \right)^{-1}$ Lie-Trotter.

Vorteile falls:

+ $\hat{\psi}^h$ genauer als ψ^h

+ $\bar{\pi}^h$, $(\bar{\pi}^h)^{-1}$ günstig.

+ keine/wenige Ausgaben der Lösung vor Tröpf.



$$\ddot{\theta} = -\frac{c}{mL^2} \theta + \left[\frac{g}{L} \sin \theta \right]$$

A B

$$\ddot{\theta} = A\theta + B \sin \theta$$

⇒ Hamilton's system?

$$q = \theta, \quad p = \dot{\theta}$$

$$\dot{q} = p \quad = \frac{\partial H}{\partial p}$$

$$\dot{p} = Aq + B \sin q \quad = -\frac{\partial H}{\partial q}$$

$$H(q, p) = \frac{1}{2} p^2 - \frac{A}{2} q^2 + B \cos q = \frac{1}{mL^2} E_{\text{tot}}$$

$$E_{\text{tot}} = E_{\text{kin}} + E_{\text{pot}}, \quad E_{\text{kin}} = \frac{1}{2} m L^2 p^2$$

$$V(q) = \frac{1}{2} c q^2 + g m L \cos(q)$$

$$(c) \begin{bmatrix} p \\ Aq + B \sin q \end{bmatrix} = \begin{bmatrix} p \\ 0 \end{bmatrix} + \begin{bmatrix} 0 \\ Aq + B \sin q \end{bmatrix}$$

$$(a) \begin{cases} \dot{q} = p \\ \dot{p} = 0 \end{cases} \Rightarrow p(h) = p_0 \Rightarrow \dot{q} = p_0 \Rightarrow q(h) = q_0 + h p_0$$

$$\oplus_a^h \begin{bmatrix} q_0 \\ p_0 \end{bmatrix} = \begin{bmatrix} q_0 + h p_0 \\ p_0 \end{bmatrix}$$

$$(b) \begin{cases} \dot{q} = 0 \\ \dot{p} = Aq + B \sin q \end{cases} \Rightarrow q(h) = q_0$$

$\downarrow p(h) = p_0 + (Aq_0 + B \sin q_0) h$

$$\oplus_b^h \begin{bmatrix} q_0 \\ p_0 \end{bmatrix} = \begin{bmatrix} q_0 \\ p_0 + (Aq_0 + B \sin q_0) h \end{bmatrix}$$

```

58 def phiA(dt, u):
59     """ Operator A: Phi_A(q,p)
60     INPUT:
61         dt : time step
62         u : solution at the known time level t=t_n, i.e. y_n.
63                         3d array : u[0] = angle, u[1] = angle velocity, u[2]
64     =time
65     OUTPUT:
66         v : solution at time u[2]+dt
67
68     v = np.array([0.,0.,0.])
69     t = 1.*u[2]
70     p = 1.*u[1]
71     q = u[0] + dt*p
72     v = np.array([q,p,t])
73     return v
74
75 def phiB(dt, u):
76     """ Operator B: Phi_B(q,p)
77     INPUT:
78         dt : time step
79         u : solution at the known time level t=t_n, i.e. y_n.
80                         3d array : u[0] = angle, u[1] = angle velocity, u[2]
81     =time
82     OUTPUT:
83         u : solution at time u[2]+dt
84
85     v = np.array([0.,0.,0.])
86     t = u[2] + dt
87     q = 1.*u[0]
88     p = u[1] + dt*(A*q+B*np.sin(q))
89     v = np.array([q,p,t])
90     return v
91
92 def Approximate(T, N, y0, method="LT") :
93
94     tspan = [0., T]
95     ys = np.array([y0[0],y0[1],0.])
96     a,b = S.build(method)
97     t, y = S.intsplit(phiA, phiB,a,b,tspan,N,ys,getall=True)
98     return t, y
99

```

```

.f __name__ == "__main__":
N_SV = 5000
N_6 = 2500

y0 = np.array([theta_0, 0])

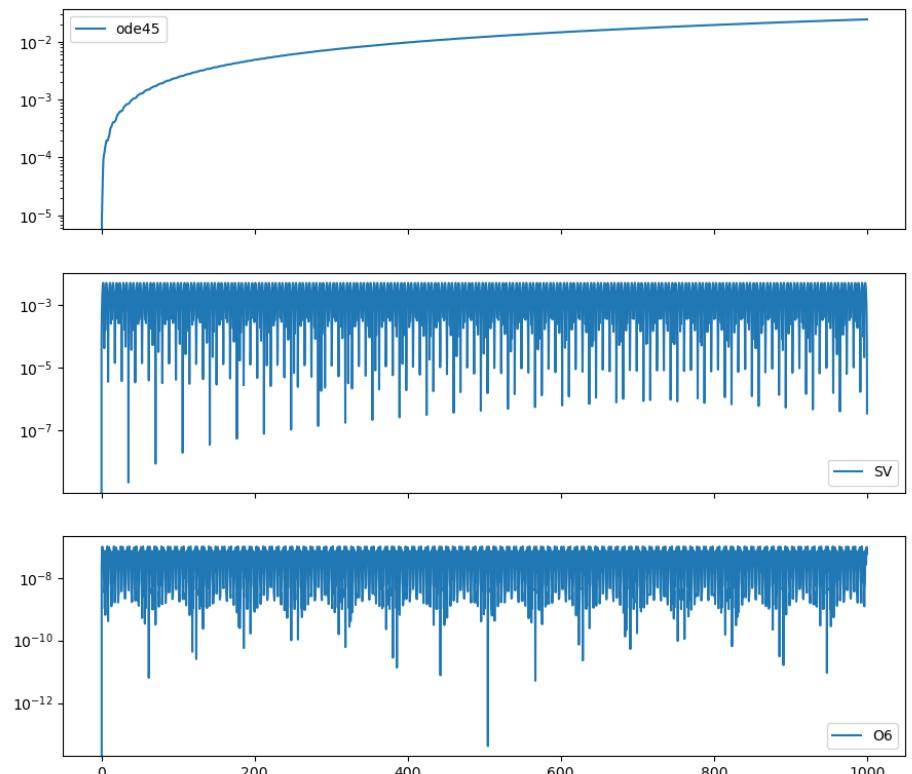
# #For comparison at sub-task d: uncomment once you have implemented odefun!
t_45, y_45 = ode45(odefun,(t0,T), y0)
pE_45, kE_45, tE_45 = Energien(y_45[:,0], y_45[:,1])

# SV
#t_SV, y_SV = np.linspace(t0,T,N_SV), 2*np.ones((N_SV,2))*y0 #TODO: Compute t_SV and y_SV
method_ss = 'SS'
t_SV, y_SV = Approximate(T, N_SV, y0, method=method_ss)
pE_SV, kE_SV, tE_SV = Energien(y_SV[:,0], y_SV[:,1])

# order 6
#t_6, y_6 = np.linspace(t0,T,N_6), 2*np.ones((N_6,2))*y0 #TODO: Compute t_6 and y_6
method_2 = 'BM63'
t_6, y_6 = Approximate(T, N_6, y0, method=method_2)

pE_6, kE_6, tE_6 = Energien(y_6[:,0], y_6[:,1])

```



§3.4. Lineare Transportgleichung (Wellengleichung 1. Ordnung)

($N=2^n$)

Finde $u: [0, T] \times [0, 1] \rightarrow \mathbb{R}$ so dass

$$\left\{ \begin{array}{l} \frac{\partial u}{\partial t}(t, x) + c(x) \frac{\partial u}{\partial x}(t, x) = 0 \\ u(0, x) = \exp(-100(2\pi x - 1)^2) \end{array} \right.$$

Nehme N äquidistante Punkte in $[0, 1]$

$$x_0 = 0, x_1 = \frac{1}{N}, \dots, x_{N-1} = \frac{N-1}{N} \text{ (Ortsgitter)}$$

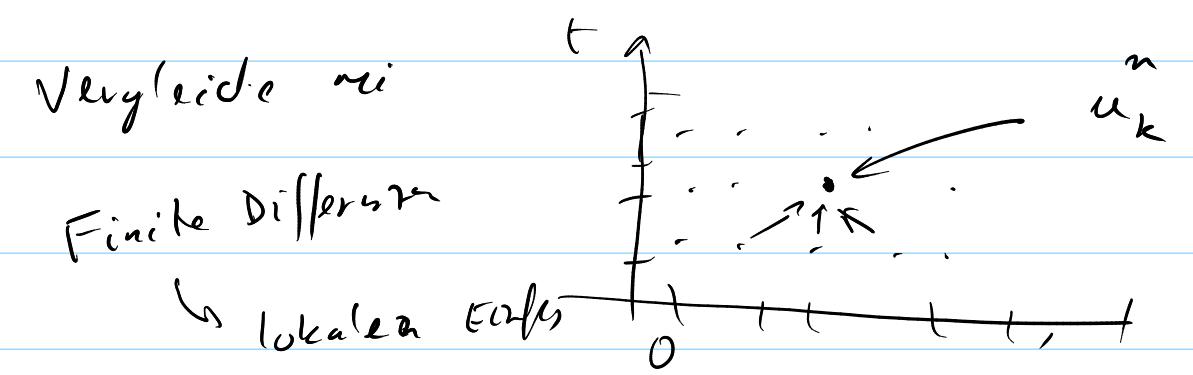
$$\underline{x} = [x_0, x_1, \dots, x_{N-1}]^T \in \mathbb{R}^N$$

$$u(t, \underline{x}) = [u(t, x_0), u(t, x_1), \dots, u(t, x_{N-1})]^T \in \mathbb{R}^N$$

$$c(\underline{x}) = [c(x_0), c(x_1), \dots, c(x_{N-1})]^T \in \mathbb{R}^N$$

$$\frac{\partial}{\partial t} u(t, \underline{x}) + c(\underline{x}) \mathcal{F}_D^{-1} \mathcal{F}_u(t, \underline{x}) = 0$$

$$\mathcal{D} = \text{diag}(-2\pi i k) \quad N \times N$$



$$u(t, x) = \sum_{k=-\infty}^{\infty} z_k(t) e^{-2\pi i k x} \Rightarrow$$

$$\frac{\partial u}{\partial x} u(t, x) = \sum_{k=-\infty}^{\infty} z_k(t) (-2\pi i k) e^{-2\pi i k x} \quad k \in \mathbb{Z} \quad k \in \{-\frac{N}{2}, \dots, -1, 0, 1, \dots, \frac{N}{2}-1\}$$

Collokation: möchte dass die Dgl. in den Punkten

(t_n, x_k) erfüllt ist

1) leap-frog / zentraler Differenz

$$= c(x) \left(c'(x) \frac{\partial u}{\partial x} + c(x) \frac{\partial^2 u}{\partial x^2} \right) \Rightarrow \begin{cases} \text{Num. 1. elliptisch.} \\ \text{hyperbolisch DG.} \end{cases}$$

$$\frac{u(t_{n+1}, x) - u(t_{n-1}, x)}{2h} = -c(x) \mathcal{F}^{-1} \mathcal{D} \mathcal{F} u(t_n, x) \Rightarrow \text{Lax-Wendroff:}$$

$$u(t_{n+1}, x) = u(t_{n-1}, x) - 2h c(x) \mathcal{F}^{-1} \mathcal{D} \mathcal{F} u(t_n, x)$$

Brauche $u(t_0 - h) \approx u(0, x - 0.2h)$

besser: eine Methode $O(h^2)$ für $u(t_1)$ (später)

eTR

2) Lax-Wendroff

technik von Cauchy-Kowalevsky:

$$y(t+h) = y(t) + h \dot{y}(t) + \frac{h^2}{2} \ddot{y}(t) + O(h^3)$$

$$\frac{\partial u}{\partial t} = -c(x) \frac{\partial u}{\partial x}$$

$$\frac{\partial^2 u}{\partial t^2} = \frac{\partial}{\partial t} \left(-c(x) \frac{\partial u}{\partial x} \right) = -c(x) \frac{\partial}{\partial x} \left(\frac{\partial u}{\partial t} \right) = -c(x) \frac{\partial}{\partial x} \left(-c(x) \frac{\partial u}{\partial x} \right) =$$

(DD)

Alternative Finite Differenzen

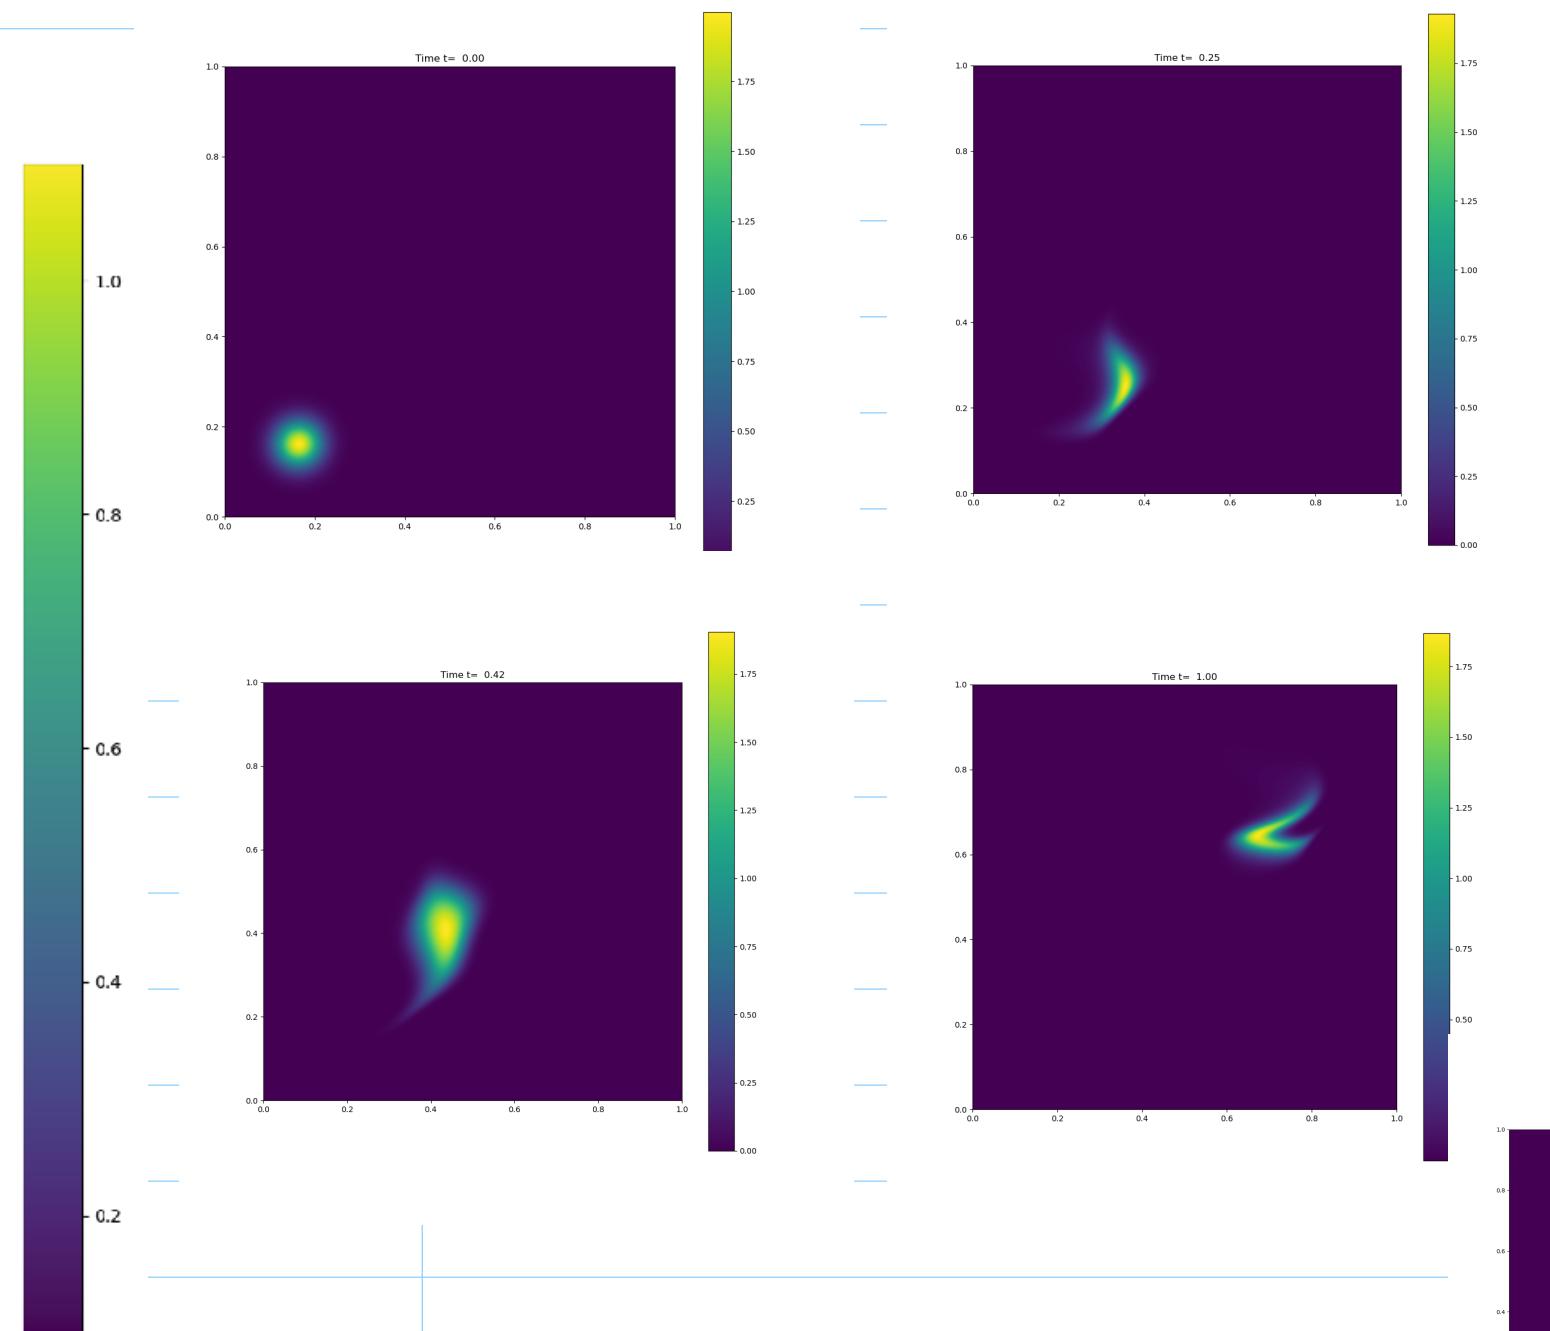
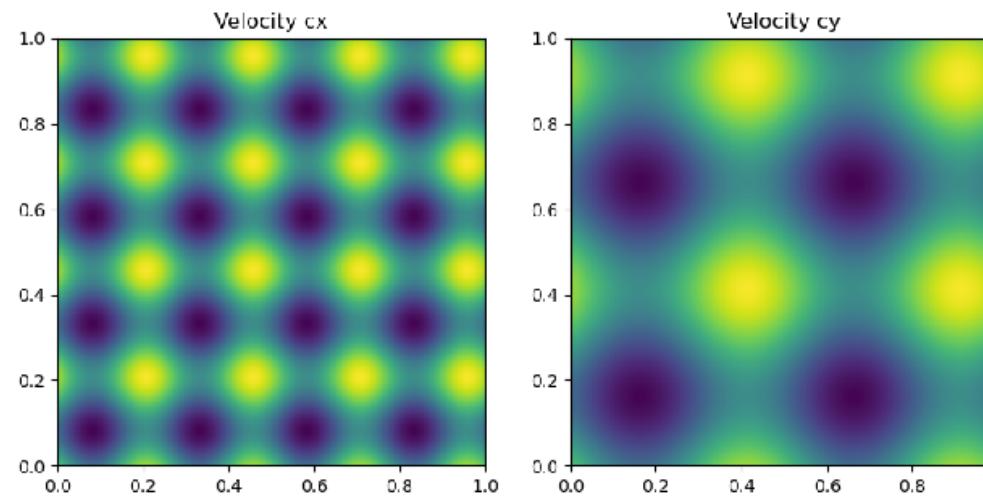
$$u(t_n, x_k) = u_k^n \quad c_k = c(x_k)$$

upwind:

$$\frac{u_k^{n+1} - u_k^n}{h} + \bar{c}_k \frac{u_k^n - u_{k-1}^n}{\Delta x} = 0$$

mit $\bar{c}_k = \frac{1}{2} (c_k - c_{k-1})$ Mittelwert
Finite Elemente!

wave2d02.py
dataEnv16AsymDicht



zu mehrere Dimensionen

Finde:

$$\begin{cases} u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R} \\ u(0, \underline{x}) = u_0(\underline{x}) \end{cases}$$

so dass

$$\underline{c}: \mathbb{R}^d \rightarrow \mathbb{R}^d \quad \underline{c}(\underline{x}) = \begin{bmatrix} c_1(\underline{x}) \\ \vdots \\ c_d(\underline{x}) \end{bmatrix}$$

$$\frac{\partial u}{\partial t} + \sum_{j=1}^d c_j(\underline{x}) \frac{\partial u}{\partial x_j} = 0 \quad (\Rightarrow) \quad \frac{\partial u}{\partial t} + \underline{c}(\underline{x}) \cdot \underline{\text{grad}}_{\underline{x}} u(t, \underline{x}) = 0$$

$$\underline{c}: \mathbb{R}^d \rightarrow \mathbb{R}^d \quad D\underline{c} = \left[\frac{\partial c_{ij}}{\partial x_l} \right]_{i,j,l=1,2,\dots,d} \in \mathbb{R}^{d \times d}$$

$$\begin{aligned} &= + \underline{c}(\underline{x}) \cdot \underline{\text{grad}}_{\underline{x}} (c(\underline{x}) \cdot \underline{\text{grad}}_{\underline{x}} u(t, \underline{x})) = \\ &= \underline{c}(\underline{x}) \cdot \left(\underline{D}\underline{c} \right) \cdot \underline{\text{grad}}_{\underline{x}} u(t, \underline{x}) + \underline{c}(\underline{x}) \underline{\Delta} u(t, \underline{x}) \\ &\text{jede Komp. } \sum_{l=1}^d \left(\sum_{j=1}^d c_j \frac{\partial c_{il}}{\partial x_j} \right) \cdot \frac{\partial u}{\partial x_l} \\ &\underline{\text{grad}} u \cdot (\underline{D}\underline{c} \cdot \underline{c}) \end{aligned}$$

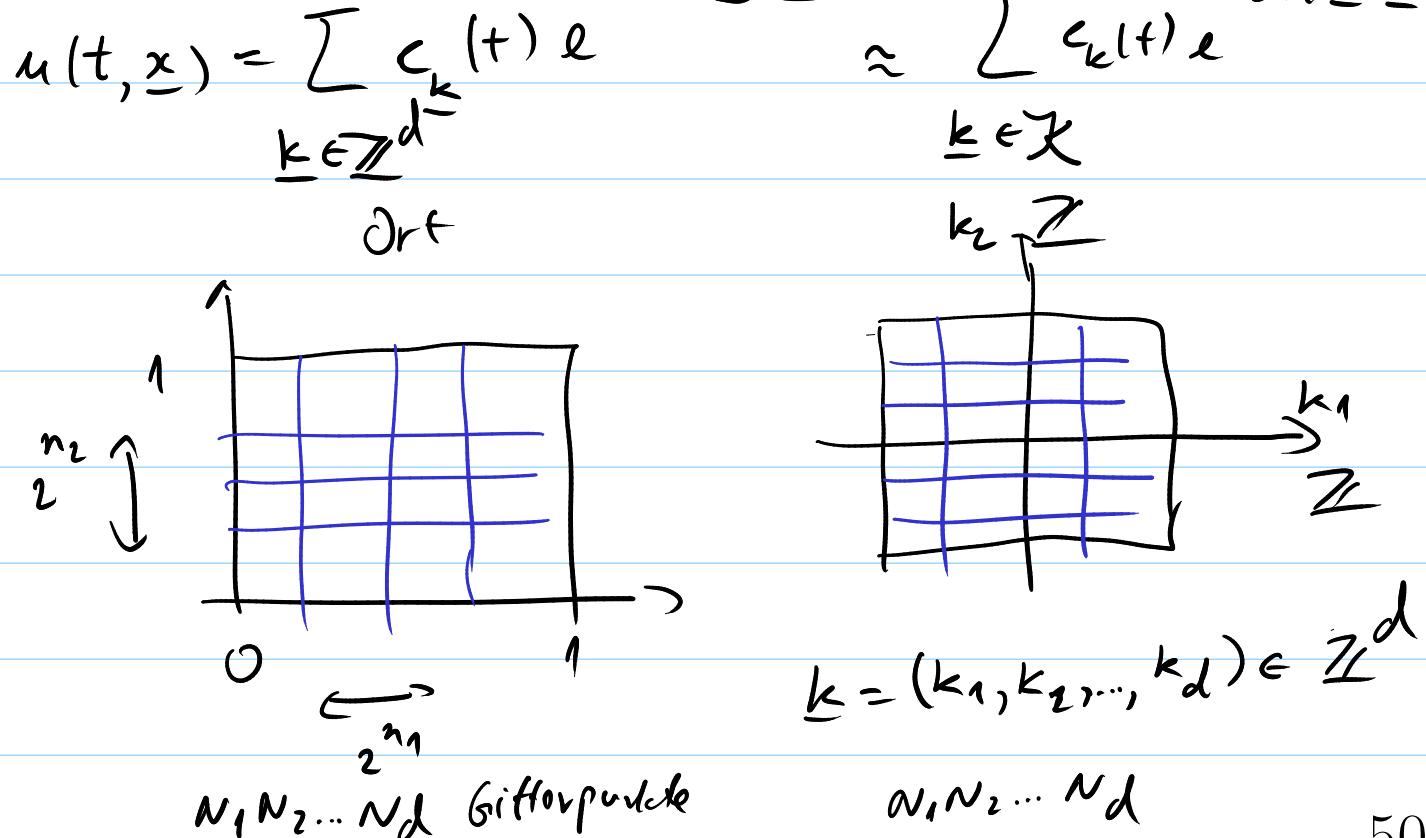
Taylor in t :

$$u(t+h) = u(t) + h \frac{\partial u}{\partial t}(t, \underline{x}) + \frac{h^2}{2} \frac{\partial^2 u}{\partial t^2}(t, \underline{x}) + O(h^3)$$

$$= -\underline{c}(\underline{x}) \cdot \underline{\text{grad}}_{\underline{x}} u(t, \underline{x})$$

$$\frac{\partial^2 u}{\partial t^2} = \frac{\partial}{\partial t} \left(\frac{\partial u}{\partial t} \right) = \frac{\partial}{\partial t} \left(-\underline{c}(\underline{x}) \cdot \underline{\text{grad}}_{\underline{x}} u(t, \underline{x}) \right) =$$

$$= -\underline{c}(\underline{x}) \cdot \frac{\partial}{\partial t} \underline{\text{grad}}_{\underline{x}} u(t, \underline{x}) = -\underline{c}(\underline{x}) \cdot \underline{\text{grad}}_{\underline{x}} \frac{\partial}{\partial t} u(t, \underline{x})$$



$$\frac{\partial u}{\partial x_j} = \sum_{k \in K} c_k(t) (-\pi i k_j) e^{-\pi i k \cdot x}, \quad j=1,2,\dots,d$$

$$\frac{\partial^2 u}{\partial x_j^2} = \sum_{k \in K} c_k(t) (-\pi i k_j)^2 e^{-\pi i k \cdot x}, \quad j=1,2,\dots,d$$

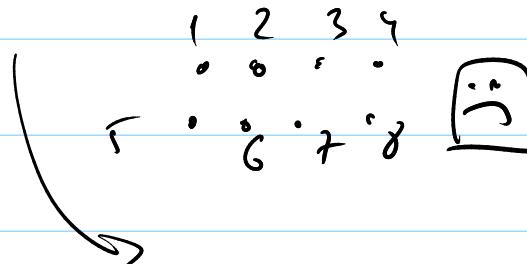
$$\Delta u = \sum_{k \in K} c_k(t) (-\pi i k)^2 \|k\|_2^2 e^{-\pi i k \cdot x} \in \mathbb{R}$$

$$\|k\|_2^2 = k_1^2 + k_2^2 + \dots + k_d^2$$

d=2 Implementierung.

$$x_1 = \left[\frac{0}{n_1}, \frac{1}{n_1}, \dots, \frac{n_1 - 1}{n_1} \right], \quad x_2 = \left[\frac{0}{n_2}, \frac{1}{n_2}, \dots, \frac{n_2 - 1}{n_2} \right]$$

$x, y = \text{meshgrid}(x_1, x_2, \text{indexing}='ij')$



x, y

$f(x, y)$

`imshow(origin='lower')`

$s_1 = f_1 \cdot s \quad s \in \mathbb{R}$
 $s_2 = f_2 \cdot s \quad s \in \mathbb{R}$
 $f X, f Y = \text{meshgrid}(f_1, f_2, \text{indexing}='ij')$

$$\frac{\partial \hat{u}}{\partial x} \text{ braucht } f X$$

$$\frac{\partial \hat{u}}{\partial y} \text{ f } Y$$

$$f_1 \Delta = \|f_1\|^2 \cdot \text{reshape}(N_1, 1)$$

$$f_2 \Delta = \|f_2\|^2 \cdot \text{reshape}(1, N_2)$$

broadcast \rightarrow
 $f_1 \Delta + f_2 \Delta$

$$m \begin{bmatrix} & \\ & \ddots \\ & & k_1^2 + k_2^2 \end{bmatrix} \Delta(\hat{u})$$

§ 4 Runge-Kutta-Verfahren

§ 4.1 Grundidee

$$\begin{cases} \dot{y} = f(t, y) \\ y(t_0) = y_0 \end{cases} \Rightarrow \underline{y}(t_1) = \underline{y}(t_0) + \int_{t_0}^{t_1} f(t, \underline{y}(t)) dt$$

$h = t_1 - t_0$, Referenzintervall $[t_0, 1]$

(QF mit Knoten $c_i \in [0, 1]$ und Gewichte b_i)

$$\underline{y}(t_1) \approx \underline{y}(t_0) + h \sum_{i=1}^n b_i f(t_0 + h c_i, \underline{y}(t_0 + h c_i))$$

\hookrightarrow Inkremente

noch unbekannt

$$\underline{y}(t_1) \approx \underline{y}(t_0) + h \sum_{i=1}^n b_i k_i$$

Herlaubt uns ein lokalen Fehler $O(h^{p+1})$ für $\underline{y}(t_1)$ zu bekommen, auch wenn wir für $\underline{y}(t_0 + h c_i)$ nur eine Approx. der Ordnung $O(h^p)$ verwenden.

Bsp 1) QF = Trapezregel. $c_1 = 0, c_2 = 1$

$$b_1 = \frac{1}{2}, b_2 = \frac{1}{2}$$

$$\underline{y}(t_1) \approx \underline{y}_0 + h \left(\frac{1}{2} \underbrace{f(t_0 + h \cdot 0, \underline{y}(t_0 + h \cdot 0))}_{\underline{y}(t_0)} + \frac{1}{2} \underbrace{f(t_0 + h \cdot 1, \underline{y}(t_0 + h \cdot 1))}_{\underline{y}(t_1)} \right)$$

(TR)

Idee: verwendet etwas Bildiges für

$$\underline{y}_0(t_0 + h) \approx \underline{y}_1 + h \underline{f}(t_0, \underline{y}_0) \quad (\epsilon \in)$$

$$\begin{cases} k_1 = f(t_0, \underline{y}_0) \\ k_2 = f(t_0 + h, \underline{y}_0 + h \underline{k}_1) \\ \underline{y}_1 = \underline{y}_0 + h \left(\frac{1}{2} \underline{k}_1 + \frac{1}{2} \underline{k}_2 \right) \end{cases}$$

explizite Trapezregel

$$\text{Bsp 2)} \quad QF = MPR \quad c_1 = \frac{1}{2}, \quad b_1 = 1$$

$$\underline{y}(t_1) \approx \underline{y}_0 + h f(t_0 + h \frac{1}{2}, \underline{y}(t_0 + h \frac{1}{2}))$$

$$\underline{y}(t_0 + h \frac{1}{2}) \approx \underline{y}_0 + h \frac{1}{2} \underline{f}(t_0, \underline{y}_0) \quad (\text{es})$$

$\underbrace{\underline{k}_1}_{\underline{k}_1}$

$$\begin{cases} \underline{k}_1 = \underline{f}(t_0, \underline{y}_0) \\ \underline{k}_2 = \underline{f}(t_0 + h \frac{1}{2}, \underline{y}_0 + \frac{h}{2} \underline{k}_1) \\ \underline{y}_1 = \underline{y}_0 + h \underline{k}_2 \end{cases}$$

explizite MPR.

hätten hier (ϵ) statt (es) \rightarrow implizite MPR.

Def Runge-Kutta-Verfahren mit s Stufen
Gegeben Butcher-Tableau (Schema)

$$\begin{array}{c|ccccc} c_1 & & & & & \\ c_2 & & & & & \\ \vdots & & & & & \\ c_s & & & & & \\ \hline 1 & b_1 & b_2 & \dots & b_s \end{array} \quad A \in \mathbb{R}^{s \times s}$$

notwendig für die Konvergenzordn.

so dass $b_1 + b_2 + \dots + b_s = 1$

$\sum_{j=1}^s a_{ij} = c_i$ für $i = 1, 2, \dots, s$

nicht notwendig aber meistens erfüllt (z.B. Kollation) und wurde von Butcher in der Konstruktion verwendet

$$\begin{cases} \underline{r}_i = \underline{f}(t_0 + h c_i, \underline{y}_0 + h \sum_{j=1}^s a_{ij} \underline{k}_j) \\ \text{für } i = 1, 2, \dots, s \end{cases} \quad \text{Stufen}$$

$$\underline{y}_1 = \underline{y}_0 + h \sum_{i=1}^s b_i \underline{k}_i$$

$\underline{k}_i = \text{Inkrement}$

nicht-linearen algebraischen Gleichungssystem

$$\underline{A} = \begin{bmatrix} 0 & & & \\ & 0 & & 0 \\ & & 0 & \ddots \\ * & & & 0 \end{bmatrix} \quad a_{ij} = 0 \text{ für } i \leq j \\ \Rightarrow \text{RK explizit}$$

$$k_i = f(t_0 + h c_i, y_0 + h \sum_{j=1}^{i-1} a_{ij} k_j)$$

$$\underline{A} = \begin{bmatrix} 0 & & & \\ & * & & \\ & & \ddots & \\ & & & 0 \end{bmatrix} \Rightarrow \text{diagonal impliziter RK} \\ (\text{DIRK})$$

$$\left\{ \begin{array}{l} k_i = f(t_0 + h c_i, y_0 + h \sum_{j=1}^{i-1} a_{ij} k_j + h a_{ii} k_i) \\ \text{dxd nicht-linearen algebraischen Gleichungssystem.} \end{array} \right.$$

Def Konsistenzordnung q wenn $\|y_0(t_0+h) - \underline{y}_1\| \leq c \cdot h^{q+1}$

Theorem RK hat Konsistenzordnung $q \Rightarrow$
 \Rightarrow QF hat Ordnung q
 (ist exakt für Polynome vom Grad max $q-1$)

Beweis

$$\text{Nehme } \begin{cases} y = t^n \\ y(0) = 0 \end{cases} \Rightarrow \underline{y}(t) = \frac{1}{n+1} t^{n+1}$$

Fehler:

$$|y(h) - \underline{y}_1| = \left| \frac{1}{n+1} h^{n+1} - h \sum_{j=1}^n b_j (h c_j)^n \right| \leq c \cdot h^{q+1} \quad |: h^{n+1}|$$

$$\Rightarrow 0 \leq \left| \frac{1}{n+1} - \sum_{j=1}^n b_j c_j^n \right| \leq c \cdot h^{q-n} \quad \Rightarrow$$

$$\text{Für } n=0, 1, 2, \dots, q-1 \Rightarrow q-n > 0 \quad \xrightarrow[0]{(h \rightarrow 0)}$$

\Rightarrow QF ist exakt genau für $n=0, 1, \dots, q-1$
 \Rightarrow QF hat Ordnung q .

Konsequenz RK mit s Stufen hat
maximale Konsistenzordnung $2s$

$$1) \sum_{j=1}^s b_j = 1 \Leftarrow \text{mindestens Konsistenzordn. } q=1$$

$$2) \text{ Konsistenzordn. } 2 \Rightarrow \sum_{j=1}^s b_j c_j = \frac{1}{2}$$

$$3) q=3 \Rightarrow \sum_{j=1}^s b_j c_j^2 = \frac{1}{3}$$

$$\oplus \quad \sum_{j=1}^s b_j \sum_{n=1}^s a_{jn} c_n = \frac{1}{6}$$

usw es wird sehr kompliziert

Theorem RK explizit $\Rightarrow q \leq s$

Gauss-Quadratur $\Rightarrow q=2s$ 

Radau-Quadratur \Rightarrow Radau-Verfahren  für ODE $q=2s-1$

Lobatto-Quadratur =

Lobatto-Verfahren für ODE $q=2s-2$ 

Theorem RK hat Konsistenzordnung $q \Rightarrow$

RK hat globale Konvergenzordnung q

$$\| \underline{y}(t_i) - \underline{y}_i \| \leq c \cdot h^q \text{ für alle } i=1, 2, \dots, n, T=Nh$$



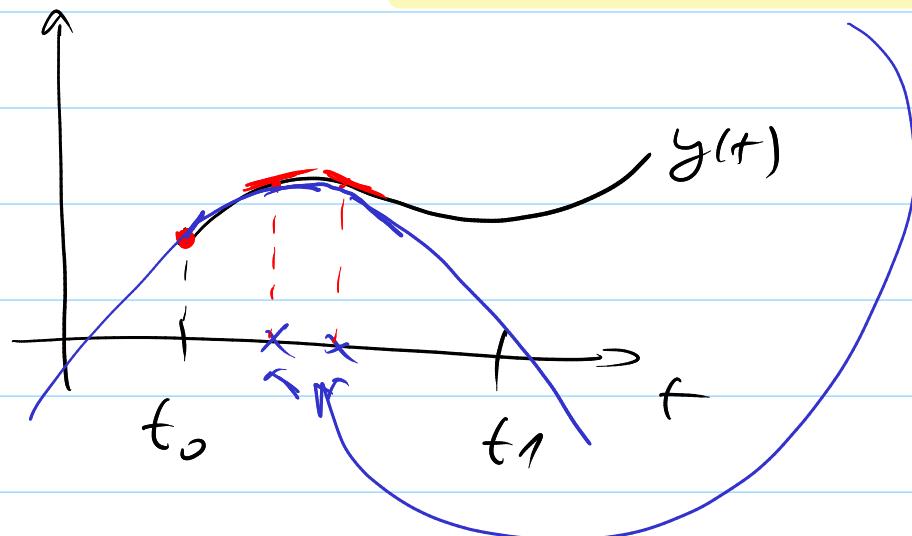
§4.2. Kollokation

Def $c_1, c_2, \dots, c_s \in [t_0, t_1]$ verschieden

Kollokationspolygon $\underline{u}(t)$ vom Grad D :

$$\begin{cases} \underline{u}(t_0) = y_0 \\ \underline{u}(t_0 + hc_i) = f(t_0 + hc_i, \underline{u}(t_0 + hc_i)) \end{cases} \quad \text{für } i=1, 2, \dots, D$$

Kollokationspunkte



Bsp 1) $D=1$ Polygon vom Grad 1

$$\underline{u}(t) = y_0 + (t - t_0) k$$

mit $k \neq 0$ bestimmt, dass

$$\underline{u}(t_0 + hc_1) = f(t_0 + hc_1, \underline{u}(t_0 + hc_1))$$

Kollokationspunkt $t_0 + hc_1$

$$c_1 = 0 \Rightarrow (e^t)$$

$$c_1 = 1 \Rightarrow (i \in)$$

$$c_1 = \frac{1}{2} \Rightarrow (i \text{ NP})$$

2) $D=2$; $c_1=0, c_2=1 \Rightarrow$ implizite Trapezregel

$$c_{1,2} = \frac{1}{2} \pm \frac{\sqrt{3}}{6} \Rightarrow \text{Gauss-Verfahren. } O(h^4)$$

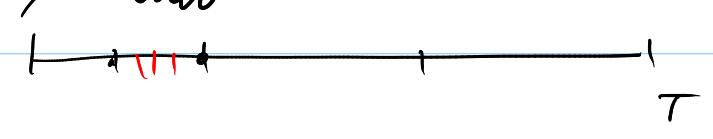
Theorie Die Kollokation mit Knoten c_1, \dots, c_s

$$\begin{aligned} & \uparrow \\ & s\text{-Stufiges RK-Verfahren mit } a_{ij} = \int_0^{c_i} l_j(z) dz \\ & b_i = \int_0^1 l_i(z) dz \end{aligned}$$

Wobei $l_i(z) = \text{Lagrange Polynome zu } c_1, \dots, c_s$

$$l_i(z) = \prod_{\substack{j=1 \\ j \neq i}}^{s-1} \frac{z - c_j}{c_i - c_j}; \quad l_i(c_j) = \begin{cases} 1, & i=j \\ 0, & i \neq j \end{cases}$$

§ 6.3. Adaptivität



Wunsch: Vergrößere h , wenn die Lösung gut genug ist
verkleinere h , wenn die Lösung nicht gut genug ist.

Beweis Notiere $u_i(t_0 + c_i h)$

$$u_i(t_0 + h z) = \sum_{j=1}^s k_j l_j(z) \quad \xrightarrow{\text{Satz } \text{6.1}}$$

hat Grad $s-1$

$$\Rightarrow u(t_0 + h c_i) = y_0 + h \sum_{j=1}^s k_j \int_0^{c_i} l_j(z) dz$$

$$\int_0^1 \Rightarrow u(t_0 + h) = y_0 + h \sum_{j=1}^s k_j \int_0^1 l_j(z) dz$$

Konservative Kollokationsmethode hat dieselbe
ordnung wie die entsprechende QF.

$$\text{Ordnung } p: \text{lokaler Fehler } ||\hat{\psi}_{t_0}^{t_0+h} y_0 - \psi_{t_0}^{t_0+h} y_0|| \leq c \cdot h^{p+1}$$

verwende

$$\text{EST}_k = \left| \hat{\psi}_{t_k}^{t_k+h} y(t_k) - \psi_{t_k}^{t_k+h} y(t_k) \right| \approx ch^{\frac{p+1}{2}}$$

berechne $h \Rightarrow$ Skript.

bessere Approximation,

Professional: 2 Rk. explizite $O(h^4)$ & $O(h^5)$
 "ode45"; Dormand-Prince 5(4)

§ 4. Partitionierte Rk-Verfahren

System ODE partitioniert:

$$\begin{cases} \dot{\underline{y}} = \underline{f}(\underline{y}, \underline{z}) \\ \dot{\underline{z}} = \underline{g}(\underline{y}, \underline{z}) \end{cases}$$

Idee: Verwende 2 verschiedene Rk-Verfahren für $\underline{y}, \underline{z}$:

für \underline{y} : für \underline{z} :

$$\begin{cases} \underline{k}_i = \underline{f}(\underline{y}_0 + h \sum_{j=1}^i a_{ij} \underline{k}_j, \underline{z}_0 + h \sum_{j=1}^{i-1} \hat{a}_{ij} \underline{l}_j) \\ \underline{l}_j = \underline{g}(\underline{y}_0 + h \sum_{i=1}^j a_{ij} \underline{k}_i, \underline{z}_0 + h \sum_{i=1}^{j-1} \hat{a}_{ij} \underline{l}_i) \end{cases}$$

$$\underline{y}_1 = \underline{y}_0 + h \sum_{j=1}^1 b_j \underline{k}_j$$

$$\underline{z}_1 = \underline{z}_0 + h \sum_{j=1}^1 \hat{b}_j \underline{l}_j.$$

Bsp 1) (E) $b_1 = 1, a_{11} = 1$ } \Rightarrow Newton-Gleichg.
 anwenden an die
 Position
 (iE) $\hat{b}_1 = 1, \hat{a}_{11} = 0$
 z = Geschwindigkeit

\Rightarrow symplektische Euler-Verfahren.

Bsp 2)
 für Newton-Gleichg.

\Rightarrow Störmer-Verlet Verfahren.

Bsp 3) 3-stufige Lobatto-Paar:

$$\begin{array}{c|ccc} 0 & 0 & 0 & 0 \\ \frac{1}{2} & \frac{5}{24} & \frac{1}{3} & -\frac{1}{24} \\ 1 & \frac{1}{6} & \frac{2}{3} & \frac{1}{6} \\ \hline 1 & \frac{1}{6} & \frac{2}{3} & \frac{1}{6} \end{array}$$

$$\begin{array}{c|ccc} 0 & \frac{1}{6} & -\frac{1}{6} & 0 \\ \frac{1}{2} & \frac{1}{6} & \frac{1}{3} & 0 \\ 1 & \frac{1}{6} & \frac{5}{6} & 0 \\ \hline 1 & \frac{1}{6} & \frac{2}{3} & \frac{1}{6} \end{array}$$

$\Rightarrow O(h^4)$ Verallgemeinerung von Störmer-Verfahren.

Bem Newton'sche Gleichung:

$$\begin{cases} \dot{y} = z \\ \dot{z} = g(t, y, z) \end{cases} \xrightarrow{\text{RK}} \text{RK-Nyström-Verfahren}$$

(RKV)

$$\left\{ \begin{array}{l} \underline{l}_i = g(t_0 + c_i h, \underline{y}_0 + c_i h \underline{z}_0 + h^2 \sum_{j=1}^3 \bar{a}_{ij} \underline{l}_j, \underline{z}_0 + h \sum_{j=1}^3 \hat{a}_{ij} \underline{l}_j) \\ \underline{y}_1 = \underline{y}_0 + h \left(\underline{z}_0 + h \sum_{i=1}^3 \underline{b}_i \underline{l}_i \right) \\ \underline{z}_1 = \underline{z}_0 + h \sum_{i=1}^3 \underline{b}_i \underline{l}_i \end{array} \right.$$

$$\text{mit } \underline{b}_i = \sum_{k=1}^3 b_k \hat{a}_{ki}$$

$$\bar{a}_{ij} = \sum_{k=1}^3 a_{ik} \hat{a}_{kj}$$

Wenn g nicht explizit \dot{y} abhängig ist
 \Rightarrow braucht man \hat{a}_{kj} nicht.

Bem PRK = Splitting mit

$$\underline{u} = \begin{bmatrix} \underline{y} \\ \underline{z} \end{bmatrix}, \quad \underline{f}_a = \begin{bmatrix} \underline{f}(\underline{u}) \\ 0 \end{bmatrix}, \quad \underline{f}_L = \begin{bmatrix} 0 \\ \underline{g}(\underline{u}) \end{bmatrix}$$

Splitting: $\dot{\underline{u}} = \underline{f}_a(\underline{u})$

mit d.

RK-Verfahren

mit
RK-Verfahren

$$\dot{\underline{u}} = \underline{f}_L(\underline{u})$$

\Rightarrow PRK

BS_R BM 42 mit $O(h^4)$] symplektische
BS 63 mit $O(h^6)$] Verfahren.

§5 Nichtlineare Algebraische Gleichungen

§5.1. Konvergenz, Fixpunktiterationen

Gegeben: $F: \mathbb{R}^d \rightarrow \mathbb{R}^d$

Gesucht: $\underline{x}^* \in \mathbb{R}^d$ so dass $F(\underline{x}^*) = \underline{0}$

Wie: Iteration $\underline{x}^{(k+1)} = \Phi(\underline{x}^{(k)})$ so dass $\underline{x}^{(k)} \rightarrow \underline{x}^*$

Konvergenzbegriff: die Iteration $\underline{x}^{(k+1)} = \Phi(\underline{x}^{(k)})$ heißt

+ linear konvergent nach \underline{x}^* , falls es gibt $L < 1$ so dass

$$\|\underline{x}^{(k+1)} - \underline{x}^*\| \leq L \|\underline{x}^{(k)} - \underline{x}^*\| \text{ für alle } k \in \mathbb{N}$$

+ konvergent mit Ordnung $p > 1$, falls es gibt C so dass

$$\|\underline{x}^{(k+1)} - \underline{x}^*\| \leq C \|\underline{x}^{(k)} - \underline{x}^*\|^p \text{ für alle } k \in \mathbb{N}$$

[für $p=1$ muss $C < 1$ damit lineare Konvergenz]

Bem lin. konvergente It (\Rightarrow Graph von $\log \|\underline{x}^k - \underline{x}^*\|$ = Gerade mit Steigung $\log L$)

Bsp Bisektionsverfahren - nur für $d=1$; lineare Konvergenz

F stetig; $F(a)F(b) < 0$

$c = \frac{a+b}{2}$ und Rekursion auf $[a, c]$ falls $F(a)F(c) < 0$
 $[c, b]$ falls $F(c)F(b) < 0$

Analysis: Banach'scher Fixpunktsatz \Rightarrow wichtiges Tool: Fixpunktiteration

Idee: Schreibe Nullstellenproblem $F(\underline{x}) = \underline{0}$ in

Fixpunktiteration $\Phi(\underline{x}^*) = \underline{x}^*$ um.

Verwende dann Φ als Iterationsvorschrift.

viele Möglichkeiten: wähle die Φ , die (schnelle) Konvergenz ergibt!

Bsp $F: \mathbb{R} \rightarrow \mathbb{R}$, $F(x) = xe^x - 1$

$$1) xe^x - 1 = 0 \Leftrightarrow xe^x = 1 \Leftrightarrow x = e^{-x}, \text{ nehme } \Phi_1(x) = e^{-x}$$

$$2) xe^x - 1 = 0 \Leftrightarrow xe^x - 1 + x = x \Leftrightarrow x(e^x + 1) = x + 1 \Leftrightarrow x = \frac{x+1}{e^x + 1}, \Phi_2(x) = \frac{x+1}{e^x + 1}$$

$$3) xe^x - 1 = 0 \Leftrightarrow xe^x - 1 - x = -x \Leftrightarrow x = x + 1 - xe^{-x}, \Phi_3(x) = x + 1 - xe^{-x}$$

Beobachte:

k	$x^{(k+1)} := \phi_1(x^{(k)})$	$x^{(k+1)} := \phi_2(x^{(k)})$	$x^{(k+1)} := \phi_3(x^{(k)})$	k	$ x_1^{(k+1)} - x^* $	$ x_2^{(k+1)} - x^* $	$ x_3^{(k+1)} - x^* $
0	0.5000000000000000	0.5000000000000000	0.5000000000000000	0	0.067143290409784	0.067143290409784	0.067143290409784
1	0.606530659712633	0.566311003197218	0.675639364649936	1	0.39387369302849	0.000832287212566	0.108496074240152
2	0.545239211892605	0.567143165034862	0.347812678511202	2	0.021904078517179	0.000000125374922	0.219330611898582
3	0.579703094878068	0.567143290409781	0.855321409174107	3	0.012559804468284	0.000000000000003	0.288178118764323
4	0.560064627938902	0.567143290409784	-0.156505955383169	4	0.007078662470882	0.000000000000000	0.723649245792953
5	0.571172148977215	0.567143290409784	0.977326422747719	5	0.004028858567431	0.000000000000000	0.410183132337935
6	0.564862946980323	0.567143290409784	-0.619764251895580	6	0.002280343429460	0.000000000000000	1.186907542305364
7	0.568438047570066	0.567143290409784	0.713713087416146	7	0.001294757160282	0.000000000000000	0.146569797006362
8	0.566409452746921	0.567143290409784	0.256626649129847	8	0.000733837662863	0.000000000000000	0.310516641279937
9	0.567559634262242	0.567143290409784	0.924920676910549	9	0.000416343852458	0.000000000000000	0.35777386500765
10	0.566907212935471	0.567143290409784	-0.407422405542253	10	0.000236077474313	0.000000000000000	0.974565695952037

lineare quadratische keine lineare quadratische keine Konvergenz

↳ Anzahl exakter Stellen nach der Komma

verdoppelt sich in jeder Iteration.

Worum ist es so?

Banach'scher Fixpunktsatz: Φ Kontraktion \Rightarrow konvergente Iteration.

$\Phi: \mathbb{B} \rightarrow \mathbb{B}$, \mathbb{B} kompakt im normierten Raum

Φ -Kontraktion: $\|\Phi(x) - \Phi(y)\| \leq L \|x - y\|$ für alle $x, y \in \mathbb{B}$ mit $L < 1$

Bei Falls Φ stetig diffbar im konvexen $U \subset \mathbb{R}^d$,

reicht $L = \sup_{\underline{x} \in U} \|D\Phi(\underline{x})\| < 1$ für lokale lin. Konvergenz

Theorem Sei $\Phi(\underline{x}^*) = \underline{x}^*$ mit Φ $(m+1)$ -mal stetig differenzierbar.

Falls $\Phi^{(l)}(\underline{x}^*) = 0$ für $l=1, 2, \dots, m \geq 1$,

dann konvergiert $\underline{x}^{k+1} = (\Phi^{(k)})^{-1}$ gegen \underline{x}^* lokal mit Ordnung $p \geq m+1$

Beweis

$$\text{Taylor um } x: \Phi(y) = \Phi(x) + \sum_{k=1}^m \frac{1}{k!} \Phi^{(k)}(x) (y-x)^k + O(|y-x|^{m+1})$$

Nehme $x = \underline{x}^*$, $y = \underline{x}^{(k)}$:

$$\underline{x}^{(k+1)} - \underline{x}^* = \Phi(\underline{x}^{(k)}) - \Phi(\underline{x}^*) = \sum_{k=1}^m \frac{1}{k!} \underbrace{\Phi^{(k)}(\underline{x}^*)}_{0} (\underline{x}^{(k)} - \underline{x}^*)^k + O(\|\underline{x}^{(k)} - \underline{x}^*\|^{m+1})$$

$$\Rightarrow \|\underline{x}^{(k+1)} - \underline{x}^*\| \leq C \cdot \|\underline{x}^{(k)} - \underline{x}^*\|^{m+1}$$

$$\text{Bsp } \Phi_2(x) = \frac{x+1}{e^x + 1} \rightarrow \Phi'_2(x) = \frac{1 - xe^x}{(e^x + 1)^2} = \frac{F(x)}{(e^x + 1)^2} \rightarrow \Phi'_2(\underline{x}^*) = 0 \text{ da } F(\underline{x}^*) = 0$$

$\Rightarrow \Phi_2$ mindestens Ordnung 2.

Wann sollen wir eine Iteration abbrechen?

1) nach k Schritte \square (endet sicher)

2) falls $\|\underline{x}^{(k)} - \underline{x}^*\| \leq \text{TOL}$ \square

$$\text{Ersatz: } \|\underline{x}^{(k)} - \underline{x}^{(k+1)}\| \leq \text{TOL}$$

Alternative: falls kleines Residuum: $\|F(\underline{x}^k)\|_2 < \text{TOL}$

$\rightarrow \infty$ Iteration möglich \rightarrow verwende 1) + 2)
zu früh stoppen möglich!

3) Falls lin. Konvergenz mit bekannter $L \Rightarrow$ nutze

$$\|\underline{x}^{(k)} - \underline{x}^{(k+1)}\| \leq \frac{1-L}{L} \text{TOL}$$

$$L \text{ unbekannt} \Rightarrow \text{schätze } L \approx \frac{\|\underline{x}^{(k+1)} - \underline{x}^{(N)}\|}{\|\underline{x}^{(k)} - \underline{x}^{(N)}\|} =: \frac{\varepsilon_{k+1}}{\varepsilon_k}$$

$$x^{(k+1)} = x^{(k)} + \frac{\cos x^{(k)} + 1}{\sin x^{(k)}}.$$

k	$x^{(0)} = 0.4$		$x^{(0)} = 0.6$		$x^{(0)} = 1$	
	$x^{(k)}$	$\frac{ x^{(k)} - x^{(15)} }{ x^{(k-1)} - x^{(15)} }$	$x^{(k)}$	$\frac{ x^{(k)} - x^{(15)} }{ x^{(k-1)} - x^{(15)} }$	$x^{(k)}$	$\frac{ x^{(k)} - x^{(15)} }{ x^{(k-1)} - x^{(15)} }$
2	3.3887	0.1128	3.4727	0.4791	2.9873	0.4959
3	3.2645	0.4974	3.3056	0.4953	3.0646	0.4989
4	3.2030	0.4992	3.2234	0.4988	3.1031	0.4996
5	3.1723	0.4996	3.1825	0.4995	3.1224	0.4997
6	3.1569	0.4995	3.1620	0.4994	3.1320	0.4995
7	3.1493	0.4990	3.1518	0.4990	3.1368	0.4990
8	3.1454	0.4980	3.1467	0.4980	3.1392	0.4980

$x^0 = 0.4:$

k	$ x^{(k)} - \pi $	$\frac{L}{1-L} x^{(k)} - x^{(k-1)} $	Fehler in der Abschätzung
1	2.191562221997101	4.933154875586894	2.741592653589793
2	0.247139097781070	1.944423124216031	1.697284026434961
3	0.122936737876834	0.124202359904236	0.001265622027401
4	0.061390835206217	0.061545902670618	0.000155067464401
5	0.030685773472263	0.030705061733954	0.000019288261691
6	0.015341682696235	0.015344090776028	0.000002408079792
7	0.007670690889185	0.007670991807050	0.000000300917864
8	0.003835326638666	0.003835364250520	0.000000037611854
9	0.001917660968637	0.001917665670029	0.000000004701392
10	0.000958830190489	0.000958830778147	0.000000000587658
11	0.000479415058549	0.000479415131941	0.000000000073392
12	0.000239707524646	0.000239707533903	0.00000000009257
13	0.000119853761949	0.000119853762696	0.000000000000747
14	0.000059926881308	0.000059926880641	0.000000000000667
15	0.000029963440745	0.000029963440563	0.000000000000181

§5.2 Newton-Verfahren

Suche $\underline{x}^* \in \mathbb{R}^d$ so dass $\underline{F}(\underline{x}^*) = \underline{0} \in \mathbb{R}^d$

Idee: linearisiere \underline{F} und löse das lineare Problem \Rightarrow Iteration

$$\underline{x}^{(0)} \text{ gegeben} \Rightarrow \underline{F}(\underline{x}) = \underline{F}(\underline{x}^0) + \underline{\underline{DF}}(\underline{x}^0)(\underline{x} - \underline{x}^0) + O(\|\underline{x} - \underline{x}^0\|^2)$$

$\underline{\underline{F}}(\underline{x})$ linear

statt $\underline{F}(\underline{x}) = \underline{0}$ löse $\underline{\tilde{F}}(\underline{x}) = \underline{0} \Leftrightarrow$

$$\underline{\underline{DF}}(\underline{x}^0)(\underline{x}^0 - \underline{x}) = \underline{\tilde{F}}(\underline{x}^0) \Leftrightarrow \text{löse } \underline{\underline{DF}}(\underline{x}^0) \underline{\Delta} = \underline{\tilde{F}}(\underline{x}^0)$$

dann $\underline{x}^{(1)} = \underline{x}^{(0)} - \underline{\Delta}$

$\underline{\Delta}$ = Newton Korrektur

Methode: $\underline{x}^{(k+1)} = \underline{x}^{(k)} - \underline{\underline{DF}}(\underline{x}^k)^{-1} \underline{F}(\underline{x}^k)$ niemals so implementiert

Sondern immer:

löse $\underline{\underline{DF}}(\underline{x}^k) \underline{\Delta} = \underline{\tilde{F}}(\underline{x}^k)$	update $\underline{x}^{(k+1)} = \underline{x}^{(k)} - \underline{\Delta}$
--	---

numerische Lineare Algebra

Newton-Verfahren

Theorem Newton-Verfahren konvergiert lokal mit Ordnung $p=2$

$\underline{\Phi}(\underline{x}) = \underline{x} - \underline{\underline{DF}}(\underline{x})^{-1} \underline{F}(\underline{x})$ ist Fixpunktiteration

$$\text{Rechnen: } \underline{\underline{D}}\underline{\Phi}(\underline{x}) = \underline{\underline{I}} - \underline{\underline{D}} \left[\underline{\underline{DF}}(\underline{x})^{-1} \right] \underline{F}(\underline{x}) - \underbrace{\underline{\underline{DF}}(\underline{x})^{-1} \cdot \underline{\underline{DF}}(\underline{x})}_{''\underline{\underline{I}}''} \Rightarrow$$

$$\underline{\underline{D}}\underline{\Phi}(\underline{x}^*) = -\underline{\underline{D}} \left[\underline{\underline{DF}}(\underline{x}^*)^{-1} \right] \underline{F}(\underline{x}^*) = \underline{0} \Rightarrow \text{Ordnung } p=2.$$

Bedingung: $\underline{\underline{DF}}(\underline{x}^*)$ ist invertierbar!
(für $d=1$: $F'(x^*) \neq 0$!)

→ Bsp S.7.3. Seite 238

Achtung: $\underline{\underline{DF}}$ am besten analytisch berechnen!
z.B. sympy + lambdify.

ML: nur einfache Funktionen \Rightarrow automatische Differentiation
(backpropagation)

Vermiede Finite Differenzen um $\underline{\underline{DF}}$ zu approximieren
(möglichliche Rundungsfehler)

optimize.fsolve, optimize.root

1D-viele Methoden

d>1: broyden / Lm / hybr

d gross $\Rightarrow \underline{\underline{DF}}(\underline{x})$ kann sehr teuer sein

Idee: verwende dieselbe Matrix $\underline{\underline{\mathcal{D}}} = \underline{\underline{DF}}(\underline{x})$ in mehrere Iterationen
 \Rightarrow vereinfachtes Newton:

$$\underline{\underline{\mathcal{D}}} = \underline{\underline{DF}}(\underline{x}^{(0)})$$

Auswertung.

$$\underline{\underline{\mathcal{D}}} = \underline{\underline{L}} \ \underline{\underline{U}}$$

$O(d^3)$

für $k=1, 2, \dots$:

$$\text{löse } \underline{\underline{L}} \ \underline{\underline{U}} \ \underline{s} = \underline{\underline{F}}(\underline{x}^{(k)}) \quad O(d^2)$$

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

Nachteil: nur lineare Konvergenz!

Quasi-Newton und Broyden

$\underline{\underline{DF}}(\underline{x})$ steht nicht zur Verfügung!

Idee $d=1$: statt Tangente, verwende eine Sekante

\Rightarrow brauche 2 Startwerte: $\underline{x}^{(0)}, \underline{x}^{(1)}$ gegeben

$$\underline{F}'(\underline{x}^{(k)}) \approx \frac{\underline{F}(\underline{x}^{(k)}) - \underline{F}(\underline{x}^{(k-1)})}{\underline{x}^{(k)} - \underline{x}^{(k-1)}}$$

Sekantenverfahren

$$\text{Update } \underline{s}^{(k)} = \frac{\underline{x}^{(k)} - \underline{x}^{(k-1)}}{\underline{F}(\underline{x}^{(k)}) - \underline{F}(\underline{x}^{(k-1)})} \underline{F}(\underline{x}^{(k)})$$

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

Ordnung < 2

$d > 1$: statt $\underline{\underline{DF}}(\underline{x}^{(k)})$ verwende eine Matrix $\underline{\underline{\mathcal{D}}}_k$ so dass

$$\underline{\underline{\mathcal{D}}}_k (\underline{x}^{(k)} - \underline{x}^{(k-1)}) = \underline{\underline{F}}(\underline{x}^{(k)}) - \underline{\underline{F}}(\underline{x}^{(k-1)})$$

Bem Viele $\underline{\underline{\mathcal{D}}}_k$ sind möglich!

Idee von Broyden: Baue $\underline{\underline{\mathcal{D}}}_k$ als Rang-1-Änderung von $\underline{\underline{\mathcal{D}}}_{k-1}$:

$$\underline{\underline{\mathcal{D}}}_k = \underline{\underline{\mathcal{D}}}_{k-1} + \frac{1}{\|\underline{x}^{(k)} - \underline{x}^{(k-1)}\|_2^2} \underline{\underline{F}}(\underline{x}^{(k)}) (\underline{x}^{(k)} - \underline{x}^{(k-1)})^T$$

□ □ □

Vorteil #1: Für nur ein einziges Mal auswerten!

Broyden-Verfahren: naive Implementierung:

$$\underline{x}^{(0)} \text{ gegeben}, \underline{\underline{\mathcal{D}}}_0 = \underline{\underline{DF}}(\underline{x}^{(0)})$$

für $k=0, 1, 2, \dots$

$$\text{löse } \underline{\underline{\mathcal{D}}}_k \ \underline{s} = \underline{\underline{F}}(\underline{x}^{(k)})$$

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

$$\underline{\underline{\mathcal{D}}}_{k+1} = \underline{\underline{\mathcal{D}}}_k + \frac{1}{\|\underline{s}\|_2^2} \underline{\underline{F}}(\underline{x}^{(k+1)}) (-\underline{s})^T$$

Man kann beweisen: $\lim_{k \rightarrow \infty} \frac{\|\underline{x}^{(k+1)} - \underline{x}^{(k)}\|}{\|\underline{x}^{(k)} - \underline{x}^{(k-1)}\|} = 2$ Superlineare Konvergenz

Bessere Implementierung via Sherman-Morrison-Formel.

$$\underline{\underline{\Delta}}_{k+1} = \underline{\underline{\Delta}}_k + \text{Rang-1-Matrix.}$$

$$(\underline{\underline{A}} + \underline{\underline{u}}\underline{\underline{v}}^T)^{-1} = \underline{\underline{A}}^{-1} - \frac{1}{1 + \underline{\underline{v}}^T \underline{\underline{A}}^{-1} \underline{\underline{u}}} \underline{\underline{A}}^{-1} \underline{\underline{u}} \underline{\underline{v}}^T \underline{\underline{A}}^{-1}$$

$$\underline{\underline{\Delta}}_{k+1}^{-1} = \underline{\underline{\Delta}}_k^{-1} + \frac{\underline{\underline{\Delta}}_k^{-1} F(x^{k+1}) \underline{\underline{\Delta}}^T \underline{\underline{\Delta}}_k^{-1}}{\|\underline{\underline{\Delta}}_k\|^2 - \underline{\underline{\Delta}}^T \underline{\underline{\Delta}}_k^{-1} F(x^{k+1})}$$

Schreibe die Iteration von

$$\text{gegeben: } \underline{\underline{x}}^0, \underline{\underline{\Delta}}_0 = \underline{\underline{D}} F(\underline{\underline{x}}^0)$$

$$\text{zerlege } \underline{\underline{\Delta}}_0 = \underline{\underline{L}} \underline{\underline{U}}$$

$$\text{löse } \underline{\underline{L}} \underline{\underline{U}} \underline{\underline{\Delta}}^0 = F(\underline{\underline{x}}^0)$$

$$\underline{\underline{x}}^1 = \underline{\underline{x}}^0 - \underline{\underline{\Delta}}^0$$

$$\underline{\underline{\Delta}}_1^{-1} = \underline{\underline{\Delta}}_0^{-1} + \frac{\underline{\underline{\Delta}}_0^{-1} F(\underline{\underline{x}}^1) \underline{\underline{\Delta}}^0 \underline{\underline{\Delta}}_0^{-1}}{\|\underline{\underline{\Delta}}_0\|^2 - \underline{\underline{\Delta}}^0 \underline{\underline{\Delta}}_0^{-1} F(\underline{\underline{x}}^1)}$$

$$\underline{\underline{x}}^2 = \underline{\underline{x}}^1 - \underline{\underline{\Delta}}_1^{-1} F(\underline{\underline{x}}^1)$$

$$\begin{aligned} \underline{\underline{\Delta}}^1 &= \underline{\underline{\Delta}}_1^{-1} F(\underline{\underline{x}}^1) = \underline{\underline{\Delta}}_0^{-1} F(\underline{\underline{x}}^1) + \frac{\underline{\underline{\Delta}}_0^{-1} \underline{\underline{\Delta}}^0 \underline{\underline{\Delta}}_0^{-1} F(\underline{\underline{x}}^1)}{\|\underline{\underline{\Delta}}_0\|^2 - \underline{\underline{\Delta}}^0 \underline{\underline{\Delta}}_0^{-1} \underline{\underline{\Delta}}^0} \\ &= \underline{\underline{\Delta}}_0^{-1} F(\underline{\underline{x}}^1) + \frac{\underline{\underline{\Delta}}_0^{-1} \underline{\underline{\Delta}}^0 \underline{\underline{\Delta}}_0^{-1} F(\underline{\underline{x}}^1)}{\|\underline{\underline{\Delta}}_0\|^2 - \underline{\underline{\Delta}}^0 \underline{\underline{\Delta}}_0^{-1} \underline{\underline{\Delta}}^0} \end{aligned}$$

$$\underline{\underline{w}} = \underline{\underline{\Delta}}_0^{-1} F(\underline{\underline{x}}^1) \Rightarrow \underline{\underline{w}} \text{ aus Löse } z \in \mathbb{R}$$

$$\underline{\underline{\Delta}}_0 \underline{\underline{w}} = F(\underline{\underline{x}}^0)$$

mit $\underline{\underline{L}}, \underline{\underline{U}}$)

$$\underline{\underline{\Delta}}^1 = \underline{\underline{w}} + \frac{\underline{\underline{w}} z}{\|\underline{\underline{w}}\|^2 - z} = \left(1 + \frac{z}{\|\underline{\underline{w}}\|^2 - z} \right) \underline{\underline{w}}$$

$$\Rightarrow \underline{\underline{x}}^2 = \underline{\underline{x}}^1 - \underline{\underline{\Delta}}^1$$

"BFGS"

→ Code S9.4. Bsp. S.9.5, S.9.2.

Bem Konvergenz ist immer von einem guten Startwert abhängig.

Wie? Bild / Intuition / Randomization / Dämpfung der Schritte.

$$\text{ML: least squares: } \min_{\theta} \frac{1}{N} \sum_{i=1}^N \|f(x_i, \theta) - y_i\|^2 = \min_{\theta} h(\theta)$$

↳ messungen
Funktionswerte zu x_i y parameter
(to learn)

N sehr gross

$\theta \in \mathbb{R}^d$, d sehr gross

⇒ auch BFGS kann zu langsam sei.

Gradienten-Verfahren: Iterationen in Richtung steilsten Abstieg.

↳ zu langsam für {
 } Toller conjugate gradient
 grosses d
 grosses N

$$f: \mathbb{D} \subset \mathbb{R}^d \rightarrow \mathbb{R}, f(\underline{x}^*) = \min_{\underline{x} \in \mathbb{D}} f(\underline{x}), f \text{ diff } \stackrel{\text{bor}}{=}$$

$$\text{kritische Stelle: } Df(\underline{x}) = 0 \quad F(\underline{x}) := \underline{Df}(\underline{x}) = \underline{\text{grad}} f(\underline{x})$$

$$\underline{x}^* \text{ lok. Min.: } F(\underline{x}^*) = \underline{\text{grad}}(\underline{x}^*) = 0 \quad \& \quad \underline{D}F(\underline{x}^*) > 0 \text{ positiv def.}$$

↓
Nullstellenproblem; Newton braucht $\underline{D}F = \underline{D}^2 f$ Hesse Matrix
↓ teuer!

Verwende Broyden-Variation: BFGS

→ C-BFGS-G

constraint (Nebenbedingungen)

optimize minimize ⇒ viele Möglichkeiten: BFGS, CG, ..

⇒ Wähle zufällig Richtungen und führe Schritte des Gradienten-Verfahrens nur dort,
d.h. ersetze den Schritt $\underline{\theta}^{k+1} = \underline{\theta}^k + r \underline{\text{grad}} h(\underline{\theta}^k)$

learning rate =
Schritt Länge in Abstieg.

mit: Wähle zufällig "batch" und verwenden nur:

$$\underline{\theta}^{k+1} = \underline{\theta}^k - \frac{1}{2|batch|} \sum_{i \in batch} |f(x_i, \underline{\theta}^k) - \underline{y}_i| \frac{\partial}{\partial \theta} f(x_i, \underline{\theta}^k)$$

⇒ stochastic gradient pytorch
adam, etc

§6 Steife Differentialgleichungen

§6.1. Einführung

Modellproblem

$$\dot{y} = \lambda y \text{ mit } \lambda < 0$$

$$y(t) = e^{\lambda t} y(0) \rightarrow 0 \text{ für } t \rightarrow \infty$$

Interesse:

asymptotisches Verhalten der numerischen Lösung **sollte** qualitativ (zumindest) ähnlich der exakten Lösung sein.

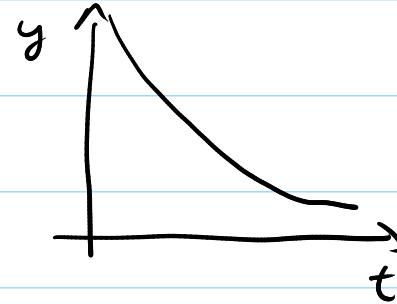
$$(E) \quad y_1 = y_0 + h f(y_0) = y_0 + h \lambda y_0 = (1+h\lambda) y_0$$

$$y_2 = y_1 + h f(y_1) = (1+h\lambda) y_0 + h \lambda (1+h\lambda) y_0 = (1+h\lambda)^2 y_0$$

$$\dots$$

$$y_N = (1+h\lambda)^N y_0 \rightarrow 0 \text{ für } N \rightarrow \infty$$

nur wenn $|1+h\lambda| < 1$



Somit: $y_N \rightarrow 0$ für $N \rightarrow \infty$ nur wenn $0 < h < \frac{1}{|\lambda|}$
klein genug!

Def ODE heißt **steif**, falls explizite Verfahren einen Zeitschritt h sehr klein brauchen, kleiner als die Genaugkeit verlangt!

Bsp

$$\frac{d}{dt} \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \underbrace{\begin{bmatrix} -50 & 49 \\ 49 & -50 \end{bmatrix}}_{B} \begin{bmatrix} y_1 \\ y_2 \end{bmatrix}$$

$$\dot{y} = B y \quad B$$

B symmetrisch \Rightarrow B diagonalisierbar, d.h.

es gibt S (mit SS^T = I) so dass

$$B = S D S^T \text{ mit } D = \text{Diagonalmatrix}$$

$$\dot{\underline{y}} = \underline{S} \underline{D} \underline{S}^T \underline{y} \Rightarrow \underline{S}^T \dot{\underline{y}} = \underline{D} \underline{S}^T \underline{y} \Rightarrow$$

\underline{z}

aber der Zeitschrift h wird durch e^{-5g} lost!

$$h < \frac{2}{9g}$$

$$\dot{\underline{z}} = \underline{D} \underline{z} \Rightarrow \begin{cases} \dot{z}_1 = \lambda_1 z_1 \\ \dot{z}_2 = \lambda_2 z_2 \end{cases}$$

$$\underline{y} = \underline{S} \underline{z}$$

$$\underline{D} = \begin{bmatrix} -1 & 0 \\ 0 & -9g \end{bmatrix} \Rightarrow \begin{cases} \dot{z}_1 = -z_1 \Rightarrow h < 2 \\ \dot{z}_2 = -9g z_2 \Rightarrow h < \frac{2}{9g} \end{cases}$$

\Rightarrow (e.E) verlangt eine Zeitschrift

$$h < \frac{2}{9g}$$

(i.E) für das Modellproblem $y = \lambda y$ mit $\lambda < 0$

$$y(t) = e^{\lambda t} y_0$$

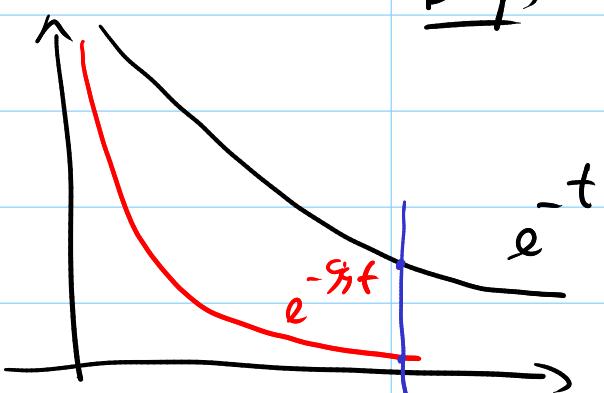
$$y_1 = y_0 + h f(y_1) = y_0 + h \lambda y_1 \Rightarrow y_1 = \frac{1}{1-\lambda h} y_0$$

$$y_N = \frac{1}{(1-\lambda h)^N} y_0 \rightarrow 0 \text{ für } N \rightarrow \infty \text{ für jedo, och.}$$

Beim implizite Verfahren stellen keine Bedingung an h .

Bsp explizite Trapezregel.

$$\begin{cases} k_1 = \lambda y_0 \\ k_2 = \lambda(y_0 + h k_1) = \lambda(y_0 + h \lambda y_0) = \\ = \lambda y_0 + h \lambda^2 y_0 \end{cases}$$



Die exakte Lösung:

$$\begin{cases} y_1(t) = e^{-t} - e^{-9gt} \\ y_2(t) = e^{-t} - e^{-5gt} \end{cases}$$

$$y_1(1) = e^{-1} + \boxed{e^{-5g}}$$

sehr klein, irrelevant!

$$y_1 = y_0 + \frac{1}{2} h k_1 + \frac{1}{2} h k_2 = y_0 + \frac{1}{2} h \lambda y_0 + \frac{1}{2} h \lambda^2 y_0$$

$$\Rightarrow y_1 = \underbrace{\left(1 + h\lambda + \frac{1}{2}(h\lambda)^2\right)}_{S(h\lambda)} y_0 = S(h\lambda) y_0$$

$$y_N = (S(h\lambda))^N y_0 \rightarrow 0 \text{ nur wenn } |S(h\lambda)| < 1$$

§6.2. Stabilität der RK-Verfahren

$$\begin{cases} \dot{y} = \lambda y \text{ mit } \lambda \in \mathbb{C}, \operatorname{Re} \lambda < 0 \\ y(t) = e^{\lambda t} y_0 \end{cases}$$

Numerisches Verfahren. $y_N = [S(h\lambda)]^N y_0$

Frage: Wann $|y_N| \rightarrow 0$ für $N \rightarrow \infty$.

$S(z)$ = Stabilitätsfunktion.

Dsp

$$(EE) \quad S(z) = 1+z$$

$$(CE) \quad S(z) = \frac{1}{1-z}$$

$$(CTR) \quad S(z) = 1+z + \frac{1}{2}z^2$$

RK-Verfahren mit Δ Stufen:

$$y_1 = y_0 + h \sum_{j=1}^{\Delta} b_i k_i$$

$$\left\{ \begin{array}{l} k_i = f(t_0 + h c_i, y_0 + h \sum_{j=1}^{i-1} a_{ij} k_j) \\ i = 1, 2, \dots, \Delta \end{array} \right.$$

für $i = \lambda_j$ d.h. $f(t, y) = \lambda_j y \Rightarrow$

$$\left\{ \begin{array}{l} k_i = \lambda y_0 + h \lambda \sum_{j=1}^{i-1} a_{ij} k_j \\ i = 1, 2, \dots, \Delta \end{array} \right.$$

$$\underline{k} = \begin{bmatrix} k_1 \\ \vdots \\ k_\Delta \end{bmatrix}$$

($z = h\lambda$)

$$\Rightarrow \underline{k} = \lambda y_0 \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} + z \underline{A} \underline{k} \Leftrightarrow$$

$$\left(\underline{I} - z \underline{A} \right) \underline{k} = \lambda y_0 \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}$$

Falls $\underline{I} - z \underline{A}$ singulär \rightsquigarrow

$$\text{Falls } \underline{I} - z \underline{A} \text{ regulär } \Rightarrow \underline{k} = \lambda y_0 \left(\underline{I} - z \underline{A} \right)^{-1} \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}$$

$$y_1 = y_0 + \underbrace{\lambda}_{\frac{1}{2}} \sum_{i=1}^D b_i \left((\underline{I} - z \underline{A})^{-1} \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \right)_i$$

$$y_1 = y_0 \left(1 + z \underline{B}^T (\underline{I} - z \underline{A})^{-1} \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \right)$$

$$S(z) = 1 + z \underline{B}^T (\underline{I} - z \underline{A})^{-1} \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix}$$

↓ Stabilitätsfunktion des n -stufigen RKV.

$$|y_n| \rightarrow 0 \text{ für } N \rightarrow \infty \text{ nur wenn } |S(z)| < 1$$

Theorem

Die Stabilitätsfunktion eines n -stufigen RKV ist eine (komplexwertige) rationale Funktion.

$$S(z) = \frac{P(z)}{Q(z)} \text{ mit } P, Q \text{ Polynome von Grad } \leq n$$

und $Q(z) = 0$ für $z = \frac{1}{\mu}$ mit $\mu \in \mathbb{K}$ von \underline{A}

Falls RKV explizit ist, dann $Q(z) \equiv 1$.

Beweis explizites RKV $\underline{A} = \begin{bmatrix} 0 & 0 & 0 \\ * & 0 & 0 \\ * & * & 0 \end{bmatrix} \Rightarrow$

$$\underline{A}^n = \underline{A} \cdot \underline{A} \cdots \underline{A} = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$

$$\begin{aligned} (\underline{I} - z \underline{A})^{-1} &= \underline{I} + z \underline{A} + (z \underline{A})^2 + \dots + (z \underline{A})^{n-1} + \dots \\ &= \underline{I} + z \underline{A} + z^2 \underline{A} + \dots + z^{n-1} \underline{A} + 0 \end{aligned}$$

= Polygon von Grad $n-1$ in \mathbb{Z} .

$$\underline{v} = (\underline{I} - z \underline{A})^{-1} \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \Rightarrow v_i(z) = \frac{P(z)}{\det(\underline{I} - z \underline{A})} = \frac{P(z)}{Q(z)}$$

Cramer's Regel

$$Q(z) = 0 \Leftrightarrow \det(\underline{I} - z \underline{A}) = 0 \Leftrightarrow z = \frac{1}{\mu} \text{ mit } \mu \in \mathbb{K} \text{ von } \underline{A}.$$

Konsequenz

1) Falls $\frac{1}{h\lambda}$ nicht $\in \mathbb{K}$ vor ≤ 1 ist, dann

$$y_n = S(h\lambda)^n y_0 \text{ mit } n=0, 1, 2, \dots$$

mit wohldefinierter Stabilitätsfunktion $S(z)$.

2) $y_0 = 1 \Rightarrow$ exakte Lösung $y(t) = e^{\lambda t}$

num. Lösung $y_n = S(h\lambda)^n$

RK hat Konsistenzordn. q :

$$\text{Fehler } |e^{nh\lambda} - S(h\lambda)^n| \leq ch^{q+1}$$

$\Rightarrow S(z)$ ist eine Approximation an e^z

$$|e^z - S(z)| \leq c \cdot |z|^{q+1}$$

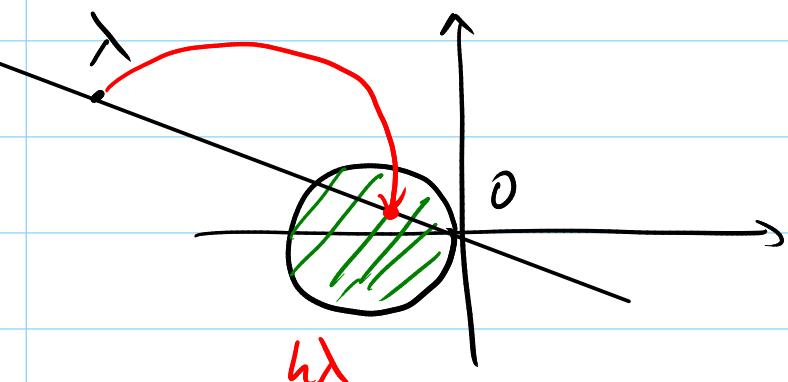
\Rightarrow Taylorpolygone von e^z , $S(z)$ um $z=0$ sind identisch bis zum Grad q .

Def Stabilitätsgebiet des num. Verfahrens 4

$$S_4 = \{ z \in \mathbb{C} \text{ sodass } |S(z)| < 1 \}$$

$$y_n = S(z)^n y_0 \rightarrow 0 \text{ nur wenn } z \in S_4$$

für gegebenes λ ,
wie klein muß h gewählt werden?



$$h\lambda \in S_4$$

Bem RK explizit $\Rightarrow S(z) = \text{Polynom von Grad } q-1$

\Rightarrow Stabilitätsbereich ist beschränkt!

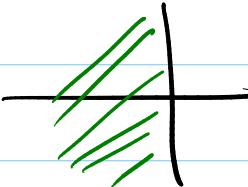
\Rightarrow immer eine Schranke nach oben!

Dazu ODE 45 / dopri54 verwenden explizite RK

$\Rightarrow S_4$ beschränkt \Rightarrow eventuell kleineres h .

Def Ein Verfahren heißt A-stabil, falls

$$\{z \in \mathbb{C} ; \operatorname{Re} z < 0\} \subset S_A$$



Radau -Verfahren von Ordnung 3,5 → Skript.

Bsp ($i \in$) ist A-stabil

RK-Gauss Verfahren sind A-stabil.

z.B. (iMP) ist A-stabil.

Bew $S(z) = e^z$, $z \rightarrow -\infty : e^z \rightarrow 0$
 $S(-\infty) = \emptyset$?

Def N.u.z. Verfahren heißt L-stabil falls

$$\lim_{z \rightarrow -\infty} S(z) = 0$$

Bew L-stabil falls $b^T = a_D = \text{letzte Zeile in } A$

$$\begin{array}{c|cc} \hline & A \\ \hline 1 & b^T \\ \hline \end{array} \Rightarrow c_1 = 1$$

letzte Koeffizienten in QF

⇒ Radau-Verfahren (basiert auf Radau-QF)
L-stabil und hat höchst mögliche Ordnung (2n-1)

§ 6.3. Linear-implizite Einschrittverfahren

autonome ODE $\dot{y} = f(y)$ mit impl. RK:

$$\left\{ \begin{array}{l} k_i = f(y_0 + h \sum_{j=1}^{i-1} a_{ij} k_j) \\ i = 1, 2, \dots, d \end{array} \right.$$

$$y_1 = y_0 + h \sum_{i=1}^d b_i k_i$$

$$\begin{array}{l} f: \mathbb{R}^d \rightarrow \mathbb{R}^d \\ A \in \mathbb{R}^{d \times d} \end{array}$$

NL GS mit ds Gleichungen.

einfache Idee 😐 linearisiere

$$\left\{ \begin{array}{l} k_i = f(y_0) + h \sum_{j=1}^{i-1} a_{ij} k_j \\ i = 1, 2, \dots, d \end{array} \right.$$

ein LGS mit ds Gleichungen.

Bsp } $\dot{y} = \lambda y(1-y)$, $\lambda=5$
 $y(0)=0.1$

$$\begin{array}{c|cc} 1 & \frac{5}{12} & -\frac{1}{12} \\ \frac{1}{3} & \frac{3}{4} & \frac{1}{4} \\ \hline & \frac{3}{4} & \frac{1}{4} \end{array}$$

Radau mit $n=2$ Stufen.

$$\Rightarrow O(h^3)$$

mit Linearisierung $\Rightarrow O(h^2)$



Idee verwenden DIRK (diagonal implizite RK)

$$A = \begin{bmatrix} \gamma & & & \\ & \ddots & & \\ & & \ddots & \\ & & & \gamma \end{bmatrix} \Rightarrow \text{gestaffelter System (NLGS)}$$

$$\left\{ k_i = f(y_0 + h \sum_{j=1}^{i-1} a_{ij} k_j + h a_{ii} \underline{k}_i) \right. \\ i=1, 2, \dots, n$$

\Rightarrow löse n NLGS der Dimension d.

Idee: verwendet vereinfachtes Newton Verfahren
mit Df und $a_{ii}=\gamma \Rightarrow$ nur eine LU-Zerlegg.

\Rightarrow einfache-diagonale-implizite RK

SDIRK-Verfahren.

$$\begin{array}{c|ccc} \gamma & \gamma & & \\ c_1 & a_{11} & \gamma & 0 \\ \vdots & \vdots & \ddots & \gamma \\ c_n & \vdots & \cdots & a_{nn} \gamma \\ \hline b_1 & b_2 & \dots & b_n \end{array}$$

$$n=2 \Rightarrow O(h^3)$$

$$\gamma = \frac{1}{2} \pm \frac{1}{6}\sqrt{3}$$

$$c_1 = 1 - \gamma, \quad c_2 = \frac{1-\gamma}{2} \\ b_1 = \frac{c_1 - \frac{1}{2}}{c_2 - \gamma}, \quad b_2 = \frac{\frac{1}{2} - \gamma}{c_2 - \gamma}$$

3-stufige SDIRK mit $O(h^4)$

$$\begin{array}{c|cccc} \gamma & \gamma & & & \\ \frac{1}{2} & -\frac{\alpha}{2} & \gamma & & \\ \hline \frac{1-\alpha}{2} & 1+\alpha & -1-2\alpha & \gamma & \\ & \hline & \frac{1}{6}\alpha^2 & 1-\frac{1}{3}\alpha^2 & \frac{1}{6}\alpha^2 \end{array}$$

$$\text{mit } \alpha^3 - \alpha = \frac{1}{3}$$

$$\alpha_1 = \frac{2}{3}\sqrt{3} \cos 10^\circ$$

$$-\frac{2}{3}\sqrt{3} \cos 70^\circ$$

$$-\frac{2}{3}\sqrt{3} \cos 50^\circ$$

Idee: nur ein Schrift von Newton
mit besonderes gut gewähltes Startwort.

→ siehe Skript! [Row]

(praktische Aspekte)

$$\underline{\underline{P}} \underline{\underline{A}} = \underline{\underline{L}} \underline{\underline{U}}$$

Gauss-Elimination

Reduktion zur oberen Zeilen-Stufenform

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

$$(\underline{\underline{Q}}^T \underline{\underline{Q}} = \underline{\underline{I}})$$

Gram-Schmidt / Rotationen / Spiegelungen

$$\underline{\underline{A}} = \underline{\underline{U}} \underline{\underline{\Sigma}} \underline{\underline{V}}^T$$

Singularwertzerlegung (SVD)

$$\underline{\underline{A}} = \underline{\underline{Q}} \underline{\underline{T}} \underline{\underline{Q}}^H$$

Schur-Zerlegung

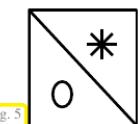
$$\mathbf{A} \mathbf{x} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} a_{11}x_1 + a_{12}x_2 + a_{13}x_3 \\ a_{21}x_1 + a_{22}x_2 + a_{23}x_3 \\ a_{31}x_1 + a_{32}x_2 + a_{33}x_3 \end{bmatrix}. \quad \mathbf{A}\mathbf{x} = x_1\mathbf{a}_1 + x_2\mathbf{a}_2 + x_3\mathbf{a}_3.$$

Definition 1.1.0.6. Matrix mal Vektor Multiplikation

Das Ergebnis \mathbf{b} der Multiplikation einer Matrix \mathbf{A} mit einem Vektor \mathbf{x} (in dieser Reihenfolge) ist die **lineare Kombination von den Spalten der Matrix \mathbf{A} mit den Koeffizienten aus dem Vektor \mathbf{x}** .

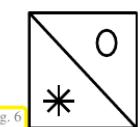
Diese Operation ist nur dann möglich, wenn die Matrix \mathbf{A} genau so viele Spalten wie der Vektor \mathbf{x} Einträge hat.

Definition 1.2.0.1. Obere Dreiecksmatrix



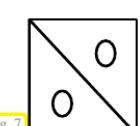
Die obere Dreiecksmatrix hat unterhalb der Hauptdiagonale nur Nullen und beliebige Zahlen oberhalb. Sie wird oft mit \mathbf{U} für das Englische "upper" oder \mathbf{R} für das Deutsche "rechts" notiert.

Definition 1.2.0.2. Untere Dreiecksmatrix



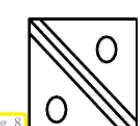
Die untere Dreiecksmatrix hat oberhalb der Hauptdiagonale nur Nullen und beliebige Zahlen unterhalb. Sie wird oft mit \mathbf{L} für das Englische "lower", oder das Deutsche "links" notiert.

Definition 1.2.0.3. Diagonalmatrix



Die Diagonalmatrix hat nur auf der Hauptdiagonale Zahlen und sonst überall Nullen. Sie wird oft mit \mathbf{D} notiert. Eine wichtige Diagonalmatrix ist die Identitätsmatrix $\mathbf{I} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$, bei welcher alle Diagonaleinträge Eins sind.

Definition 1.2.0.4. Tridiagonalmatrix



Die Tridiagonalmatrix hat eine Hauptdiagonale und zwei direkt anliegende Nebendiagonalen mit Zahlen und sonst überall Nullen.

Bemerkung 1.6.0.1 (Die Gauss-Elimination liefert die LU-Zerlegung)

Die Gauss-Elimination einer Matrix \mathbf{A} , bei welcher keine Zeilen vertauscht werden, die liefert zwei Matrizen \mathbf{L}, \mathbf{U} mit der Eigenschaft, dass

$$\mathbf{A} = \mathbf{LU}.$$

Falls bei der Gauss-Elimination auch Zeilen vertauscht werden, so bekommt man noch eine dritte Matrix \mathbf{P} , die Permutationsmatrix, und es gilt

$$\mathbf{PA} = \mathbf{LU}.$$

Die Matrix \mathbf{A} wurde also in eine untere Dreiecksmatrix \mathbf{L} und eine Matrix mit oberer Zeilenstufenform \mathbf{U} zerlegt; dies wird *LU-Zerlegung* oder auch *LR-Zerlegung* einer Matrix genannt.

Bemerkung 1.6.0.2 (LGS löst man mit der LU-Zerlegung, nicht mit der Inversen)

Wo müssen wir bei der Gauss-Elimination am meisten Rechenarbeit leisten?

Wenn ein LGS $\mathbf{Ax} = \mathbf{b}$ gelöst werden muss, werden die folgenden Schritte gemacht:

$$\mathbf{Ax} = \mathbf{b} \xrightarrow{\mathbf{P}} \mathbf{PAx} = \mathbf{Pb} \xrightarrow{\mathbf{L} \underbrace{\mathbf{Ux}}_{\mathbf{y}} = \mathbf{Pb}} \mathbf{A} = \mathbf{LU} = \mathbf{LD}\tilde{\mathbf{U}}.$$

Die Einträge von \mathbf{D} sind die Diagonaleinträge d_1, d_2, \dots, d_n von \mathbf{U} . Die Einträge von $\tilde{\mathbf{U}}$ entsprechen denen von \mathbf{U} , wobei die i -te Zeile aber durch das dazugehörige d_i geteilt wurde:

$$\mathbf{D} = \begin{bmatrix} d_1 & 0 & \cdots & 0 \\ 0 & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & \cdots & d_n \end{bmatrix} \quad \tilde{\mathbf{U}} = \begin{bmatrix} 1 & \frac{u_{12}}{d_1} & \cdots & \frac{u_{1n}}{d_1} \\ 0 & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & \frac{u_{n-1,n}}{d_{n-1}} \\ 0 & \cdots & 0 & 1 \end{bmatrix}.$$

LDU-Zerlegung symmetrischer Matrizen

Die transponierte Matrix \mathbf{A}^T von \mathbf{A} lässt sich also schreiben als:

$$\mathbf{A}^T = \tilde{\mathbf{U}}^T \mathbf{D} \mathbf{L}^T.$$

Wenn wir auch noch die Annahme treffen, dass die Matrix \mathbf{A} symmetrisch ist, dann also gilt $\mathbf{A} = \mathbf{A}^T$ so haben wir $\mathbf{L}^T = \tilde{\mathbf{U}}$ und $\tilde{\mathbf{U}}^T = \mathbf{L}$, denn wir haben gesehen, dass die LU-Zerlegung einer regulären Matrix eindeutig ist.

In diesem Fall liefert die Gauss-Elimination die folgende Zerlegung einer symmetrischen regulären Matrix:

$$\mathbf{A} = \mathbf{L} \mathbf{D} \mathbf{L}^T.$$

Cholesky-Zerlegung

Wenn nun auch noch gilt, dass alle (Pivote in der Gauss-Elimination) $d_1, \dots, d_n > 0$, so kann für die symmetrische Matrix \mathbf{A} die sogenannte Cholesky-Zerlegung definiert werden.

Für diese Zerlegung wird \mathbf{D} in zwei identische Matrizen zerteilt $\mathbf{D} = \sqrt{\mathbf{D}} \sqrt{\mathbf{D}}$ mit

$$\sqrt{\mathbf{D}} = \begin{bmatrix} \sqrt{d_1} & 0 \\ 0 & \sqrt{d_n} \end{bmatrix}.$$

Dies wird nun mit der LDU-Zerlegung von symmetrischen Matrix kombiniert um eine weitere Zerlegung zu erhalten:

$$\begin{aligned} \mathbf{A} &= \mathbf{L} \mathbf{D} \mathbf{L}^T = \underbrace{\mathbf{L} \sqrt{\mathbf{D}}}_{\mathbf{R}^T} \underbrace{\sqrt{\mathbf{D}} \mathbf{L}^T}_{\mathbf{R}} = \mathbf{R}^T \mathbf{R} \\ \mathbf{A} &= \mathbf{R}^T \mathbf{R}. \end{aligned}$$

Das \mathbf{R} ist eine obere Dreiecksmatrix. Diese Zerlegung von \mathbf{A} in $\mathbf{R}^T \mathbf{R}$ ist die Cholesky-Zerlegung. Die Cholesky-Zerlegung hat wichtige Anwendungen in der Statistik, in der Physik und in der Numerik. Man kann die Symmetrie der Matrix \mathbf{A} ausnutzen, um die Cholesky-Zerlegung mit nur einem Drittel der Operationen, die man für die standardmäßige Gauss-Elimination braucht, zu realisieren.

Definition 1.7.0.1. Orthogonale Vektoren

Zwei Vektoren $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$ (keiner davon darf Null sein), heißen orthogonal, notiert als $\mathbf{x} \perp \mathbf{y}$, falls

$$\langle \mathbf{x}, \mathbf{y} \rangle = 0.$$

Definition 1.7.0.2. Orthogonale Matrix

Eine reelle $n \times n$ Matrix \mathbf{A} heißt orthogonal, wenn

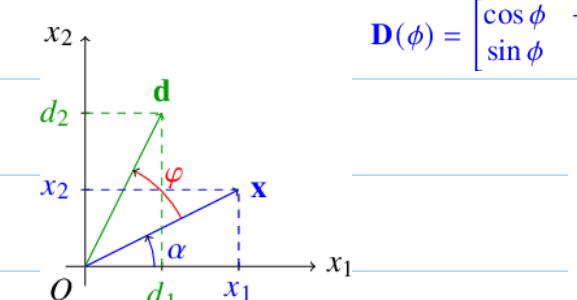
$$\mathbf{A}^T \mathbf{A} = \mathbf{I}.$$

Eine komplexe $n \times n$ Matrix \mathbf{A} heißt unitär, wenn

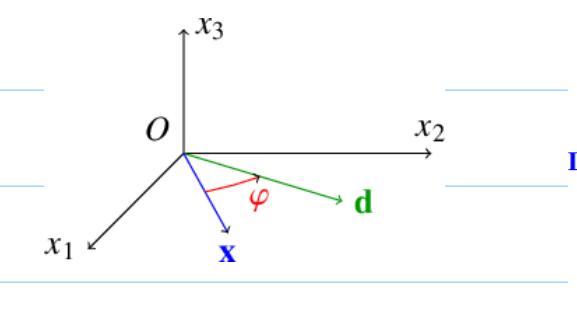
$$\mathbf{A}^H \mathbf{A} = \mathbf{I}.$$

Satz 1.7.0.6. Erhaltungssatz

Orthogonale Matrizen verändern Längen und Winkel nicht.

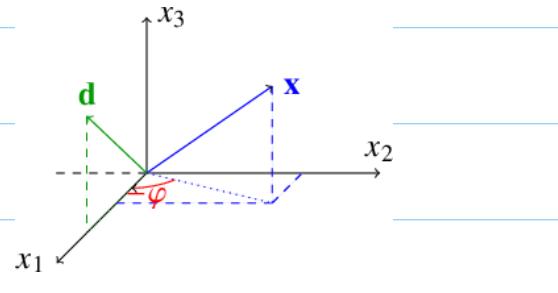


$$\mathbf{D}(\phi) = \begin{bmatrix} \cos \phi & -\sin \phi \\ \sin \phi & \cos \phi \end{bmatrix}.$$

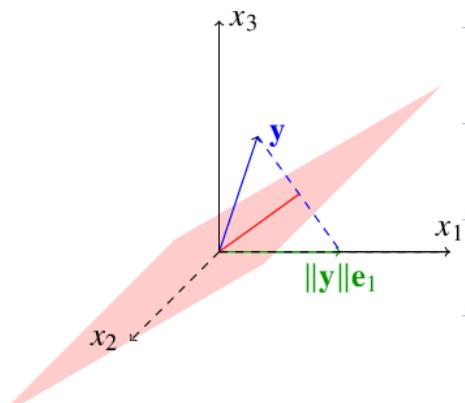
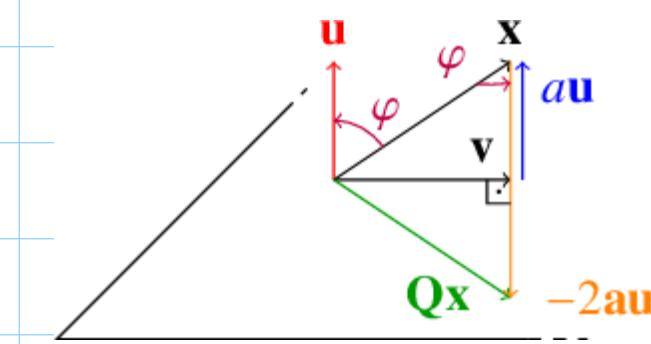


$$\mathbf{D}_{ij}(\phi) = \begin{bmatrix} 1 & 0 & \dots & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \ddots & \ddots & \vdots \\ 0 & 0 & \dots & \cos \phi & \dots & -\sin \phi \\ 0 & 0 & \dots & \sin \phi & \dots & \cos \phi \\ \vdots & \vdots & \ddots & \ddots & \ddots & \vdots \\ 0 & 0 & \dots & 0 & \dots & 1 \end{bmatrix}$$

← i-te Spalte ← j-te Zeile



$$D_{ij}(-\phi) \begin{bmatrix} x_1 \\ \vdots \\ x_i \\ \vdots \\ x_j \\ \vdots \\ x_n \end{bmatrix} = \begin{bmatrix} x_1 \\ \vdots \\ r \\ \vdots \\ 0 \\ \vdots \\ x_n \end{bmatrix}.$$



$$G_{1k}(a_1 a_k) \begin{bmatrix} a_1 \\ \vdots \\ a_k \\ \vdots \\ a_n \end{bmatrix} := \begin{bmatrix} \bar{\gamma} & \cdots & \bar{\sigma} & \cdots & 0 \\ \vdots & \ddots & \vdots & \cdots & \vdots \\ -\sigma & \cdots & \gamma & \cdots & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ 0 & \cdots & 0 & \cdots & 1 \end{bmatrix} \begin{bmatrix} a_1 \\ \vdots \\ a_k \\ \vdots \\ a_n \end{bmatrix} = \begin{bmatrix} a_1^{(1)} \\ \vdots \\ \mathbf{0} \\ \vdots \\ a_n \end{bmatrix}, \quad \gamma = \frac{a_1}{\sqrt{|a_1|^2 + |a_k|^2}}, \quad \sigma = \frac{a_k}{\sqrt{|a_1|^2 + |a_k|^2}}.$$

Definition 1.7.0.13. Householder Matrix

$\mathbf{Q} = \mathbf{I} - 2\mathbf{u}\mathbf{u}^T$ ist die Householder Matrix, welche einen Vektor an einer Ebene mit normalen Vektor \mathbf{u} spiegelt. Der normalen Vektor \mathbf{u} muss Norm 1 haben, falls dies nicht der Fall ist, muss anstelle von \mathbf{u} mit $\frac{\mathbf{u}}{\|\mathbf{u}\|}$ gerechnet werden.

Definition 1.8.0.1. QR-Zerlegung

Die QR-Zerlegung ist die Zerlegung einer Matrix \mathbf{A} in eine orthogonale Matrix \mathbf{Q} und eine obere Dreiecksmatrix \mathbf{R} , so dass $\mathbf{A} = \mathbf{Q}\mathbf{R}$.

Man verwendet die folgende Konvention für die Givens-Drehungen ($\mathbb{K} = \mathbb{R}$):

$$\mathbf{G} = \begin{bmatrix} \bar{\gamma} & \bar{\sigma} \\ -\sigma & \gamma \end{bmatrix} \implies \text{speichere } \rho := \begin{cases} 1, & \text{if } \gamma = 0, \\ \frac{1}{2} \text{sign}(\gamma)\sigma, & \text{if } |\sigma| < |\gamma|, \\ 2 \text{sign}(\sigma)/\gamma, & \text{if } |\sigma| \geq |\gamma|. \end{cases}$$

$$\begin{cases} \rho = 1 \implies \gamma = 0, \sigma = 1 \\ |\rho| < 1 \implies \sigma = 2\rho, \gamma = \sqrt{1 - \sigma^2} \\ |\rho| > 1 \implies \gamma = 2/\rho, \sigma = \sqrt{1 - \gamma^2}. \end{cases}$$

Man speichert die Rotationsmatrix $\mathbf{G}_{ij}(ab)$ als (i, j, ρ) , was effizient ist, falls die Matrix \mathbf{A} dünnbestimmt ist.

$$\begin{array}{ccc} n & m & n \\ \mathbf{A} & = & \mathbf{Q} & \mathbf{R} \\ m & & m & m \\ & & 0 & * \end{array}$$

$$\begin{array}{ccc} n & m & n \\ \mathbf{A} & = & \mathbf{Q} & \mathbf{R} \\ m & & m & m \\ & & 0 & * \end{array}$$

$$\mathbf{Q}_2 \mathbf{Q}_1 \mathbf{A} = \begin{bmatrix} * & * & * & * \\ 0 & * & * & * \\ 0 & 0 & * & * \\ 0 & 0 & * & * \end{bmatrix}.$$

$$\mathbf{Q}_{n-1} \dots \mathbf{Q}_2 \mathbf{Q}_1 \mathbf{A} = \mathbf{R} \implies \mathbf{A} = \mathbf{QR}.$$

Satz 1.8.0.6. QR-Zerlegung einer allgemeinen Matrix

Für jedes $\mathbf{A} \in \mathbb{R}^{m \times n}$ mit $m \geq n$ und $\text{Rang}(\mathbf{A}) = n$ gibt es eine eindeutige orthogonale Matrix $\mathbf{Q} \in \mathbb{R}^{m \times m}$ so dass

$$\mathbf{A} = \mathbf{Q} \begin{bmatrix} \mathbf{R} \\ \mathbf{0} \end{bmatrix}$$

mit \mathbf{R} obere Dreiecksmatrix mit allen Diagonalelementen ≥ 0 .

Falls alle Diagonalelemente > 0 dann ist \mathbf{R} die Cholesky-Zerlegung von $\mathbf{A}^\top \mathbf{A}$.

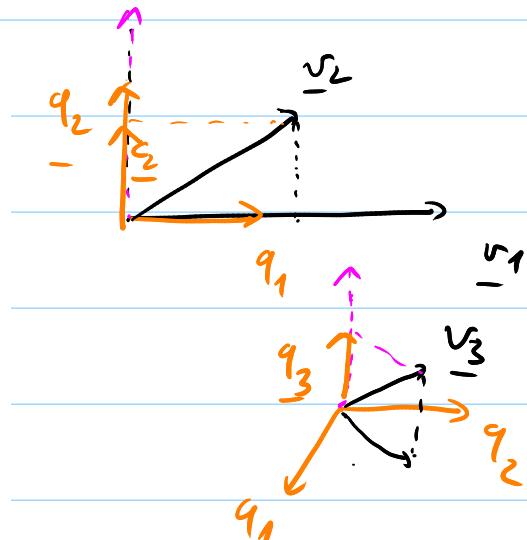
$$\mathbf{A}^\top \mathbf{A} = [\mathbf{R}^\top \quad \mathbf{0}] \underbrace{\mathbf{Q}^\top \mathbf{Q}}_{\mathbf{I}} \begin{bmatrix} \mathbf{R} \\ \mathbf{0} \end{bmatrix} = \mathbf{R}^\top \mathbf{R} + \mathbf{0} \mathbf{0} = \mathbf{R}^\top \mathbf{R}.$$

Gram-Schmidt:

$$q_1 : \quad q_1 = \frac{1}{\|v_1\|} v_1 \\ \implies v_1 = \|v_1\| q_1 = \langle q_1, v_1 \rangle q_1.$$

$$q_2 : \quad c_2 = v_2 - P_{q_1}^\perp v_2 = v_2 - \langle q_1, v_2 \rangle q_1 \\ q_2 = \frac{c_2}{\|c_2\|} \\ \implies c_2 = \|c_2\| q_2 = \langle q_2, v_2 \rangle q_2 \\ \implies v_2 = \langle q_1, v_2 \rangle q_1 + \langle q_2, v_2 \rangle q_2.$$

$$q_3 : \quad c_3 = v_3 - P_{\text{Span}\{q_1, q_2\}}^\perp v_3 = v_3 - \langle q_1, v_3 \rangle q_1 - \langle q_2, v_3 \rangle q_2 \\ q_3 = \frac{c_3}{\|c_3\|} \\ \implies c_3 = \|c_3\| q_3 = \langle q_3, v_3 \rangle q_3 \\ \implies v_3 = \langle q_1, v_3 \rangle q_1 + \langle q_2, v_3 \rangle q_2 + \langle q_3, v_3 \rangle q_3.$$

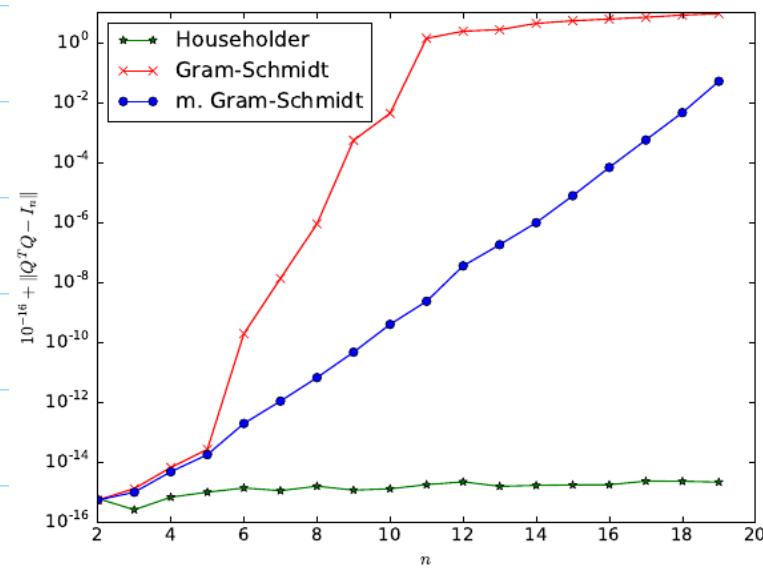


$$c_k = v_k - P_{\text{Span}\{q_1, \dots, q_{k-1}\}}^\perp v_k = v_k - \langle q_1, v_k \rangle q_1 - \langle q_2, v_k \rangle q_2 - \dots - \langle q_{k-1}, v_k \rangle q_{k-1} \\ q_k = \frac{c_k}{\|c_k\|} \\ \implies c_k = \|c_k\| q_k = \langle q_k, v_k \rangle q_k \\ \implies v_k = \langle q_1, v_k \rangle q_1 + \langle q_2, v_k \rangle q_2 + \dots + \langle q_k, v_k \rangle q_k.$$

$$v_k = [q_1 \quad q_2 \quad \dots \quad q_k]$$

$$\underbrace{\begin{bmatrix} \mathbf{v}_1 & \mathbf{v}_2 & \dots & \mathbf{v}_k \end{bmatrix}}_{\mathbf{A}_k} = \underbrace{\begin{bmatrix} \mathbf{q}_1 & \mathbf{q}_2 & \dots & \mathbf{q}_k \end{bmatrix}}_{\mathbf{Q}_k} \underbrace{\begin{bmatrix} \mathbf{q}_1^\top \mathbf{v}_1 & \mathbf{q}_1^\top \mathbf{v}_2 & \dots & \mathbf{q}_1^\top \mathbf{v}_k \\ 0 & \mathbf{q}_2^\top \mathbf{v}_2 & \dots & \mathbf{q}_2^\top \mathbf{v}_k \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 0 \end{bmatrix}}_{\mathbf{R}_k}$$

$$\underbrace{\begin{bmatrix} \mathbf{v}_1 & \dots & \mathbf{v}_n \end{bmatrix}}_{\mathbf{A}_n} = \underbrace{\begin{bmatrix} \mathbf{q}_1 & \dots & \mathbf{q}_n \end{bmatrix}}_{\mathbf{Q}_n} \underbrace{\begin{bmatrix} * & \dots & * \\ \vdots & \ddots & \vdots \\ 0 & \dots & * \end{bmatrix}}_{\mathbf{R}_n}.$$



Bemerkung 7.1.31. Es gibt mehrere Möglichkeiten, die QR-Zerlegung einer Matrix A zu berechnen:

- 1) Der modifizierte Gram-Schmidt Algorithmus orthogonalisiert A via trianguläre Operationen (obere Dreiecksmatrizen); Vorteil: wir können früher aufhören und haben schon die ersten orthogonalen Spalten. Nachteil: die Stabilität ist nicht garantiert.
- 2) Orthogonale Transformationen (Householder-Spiegelungen für eine vollbesetzte Matrix oder Givens-Rotationen für eine dünnbestetzte Matrix) triangulieren A ; Vorteil: \mathbf{Q} ist orthogonal trotz Rundungsfehler.

Gegeben a_1, a_2, \dots, a_n GS

für $j = 1, 2, \dots, n$

$$v = a_j$$

für $i = 1, 2, \dots, j-1$

$$r_{ij} = q_i^T a_j$$

$$v = v - r_{ij} q_i$$

$$r_{jj} = \|v\|$$

$$q_j = v / r_{jj}$$

modifizierte GS

$$r_{ij} = q_i^T v$$

d.h. Projektion auf die gefundene q_i wird.

$$P_{q_{j-1}} \cdots P_{q_2} P_{q_1} v$$

$i=j$

bilig, Rundungsfehler sind tödlich

→ teuer, Q immer orthogonal!

Satz 8.1.0.1. Singulärwertzerlegung (Singular Value Decomposition/SVD)

Sei eine Matrix $\mathbf{A} \in \mathbb{R}^{m \times n}$ beliebig. Es gibt zwei orthogonale Matrizen $\mathbf{U} \in \mathbb{R}^{m \times m}$ und $\mathbf{V} \in \mathbb{R}^{n \times n}$ sodass:

$$\mathbf{A} = \mathbf{U}\Sigma\mathbf{V}^T, \quad (8.1.0.2)$$

wobei die Matrix $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_p) \in \mathbb{R}^{m \times n}$ ($p = \min(m, n)$) die Singulärwerte der Matrix \mathbf{A} auffasst. Die Singulärwerte stehen auf der Hauptdiagonale von Σ und sind der Grösse nach absteigend geordnet: σ_1 ist der grösste und σ_p ist der kleinste Singulärwert:

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_p \geq 0. \quad (8.1.0.3)$$

$$m \begin{bmatrix} n \\ \mathbf{A} \end{bmatrix} = \begin{bmatrix} m \\ \mathbf{U} \end{bmatrix} \begin{bmatrix} n \\ \mathbf{m} \end{bmatrix} \begin{bmatrix} n \\ 0 \\ 0 \\ \Sigma \end{bmatrix} \begin{bmatrix} n \\ \mathbf{m} \\ \mathbf{V}^T \\ n \end{bmatrix}$$

$$m \begin{bmatrix} n \\ \mathbf{A} \end{bmatrix} = \begin{bmatrix} m \\ \mathbf{U} \end{bmatrix} \begin{bmatrix} m \\ \mathbf{m} \end{bmatrix} \begin{bmatrix} n \\ \Sigma \end{bmatrix} \begin{bmatrix} n \\ \mathbf{m} \\ \mathbf{V}^T \\ n \end{bmatrix}$$

$$n \begin{bmatrix} n \\ \mathbf{A} \end{bmatrix} = \begin{bmatrix} n \\ \mathbf{U} \end{bmatrix} \begin{bmatrix} n \\ \mathbf{n} \end{bmatrix} \begin{bmatrix} n \\ \Sigma \end{bmatrix} \begin{bmatrix} n \\ \mathbf{n} \\ \mathbf{V}^T \\ n \end{bmatrix}$$

Die entsprechende Python-Funktion ist: `scipy.linalg.svd`.

`full_matrices=False`: sparsame SVD:

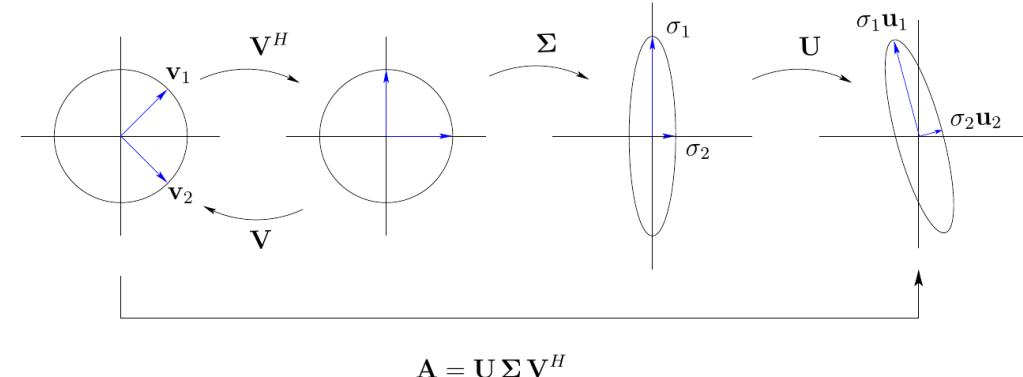
$$\begin{bmatrix} \mathbf{A} \end{bmatrix} = \begin{bmatrix} \mathbf{U} \end{bmatrix} \begin{bmatrix} \Sigma \end{bmatrix} \begin{bmatrix} \mathbf{V}^H \end{bmatrix}$$

Komplexität:

$$\begin{aligned} 2mn^2 + 2n^3 + O(n^2) + O(mn) & \text{ für } \mathbf{s} = \text{svdvals}(\mathbf{A}), \\ 4m^2n + 22n^3 + O(mn) + O(n^2) & \text{ für } \mathbf{U}, \mathbf{S}, \mathbf{V} = \text{svd}(\mathbf{A}), \\ O(mn^2) + O(n^3) & \text{ für } \mathbf{U}, \mathbf{S}, \mathbf{V} = \text{svd}(\mathbf{A}, \text{full_matrices=False}), m \gg n. \end{aligned}$$

$$\begin{bmatrix} \mathbf{A} \end{bmatrix} = \begin{bmatrix} \mathbf{U} \end{bmatrix} \begin{bmatrix} \Sigma \end{bmatrix} \begin{bmatrix} \mathbf{V}^H \end{bmatrix} \quad (7.1.4)$$

columns = ONB of $\text{Im } \mathbf{A}$ rows = ONB of $\text{ker } \mathbf{A}$



Satz 8.1.0.4. Fundamentalsatz der linearen Algebra - Teil II.

Mit den Notationen aus der Singulärwertzerlegung gilt:

1. $\mathbf{v}_{r+1}, \dots, \mathbf{v}_n$ ist eine Orthonormalbasis vom Kern von \mathbf{A} ;
2. $\mathbf{v}_1, \dots, \mathbf{v}_r$ spannen das Bild von \mathbf{A}^\top und heißen rechte Singulärvektoren von \mathbf{A} ;
3. $\mathbf{u}_1, \dots, \mathbf{u}_r$ spannen das Bild von \mathbf{A} und heißen linke Singulärvektoren von \mathbf{A} ;
- 4.

$$\mathbf{u}_1^\top \mathbf{A} \mathbf{v}_1 = \sigma_1, \quad \mathbf{u}_2^\top \mathbf{A} \mathbf{v}_2 = \sigma_2, \dots, \mathbf{u}_r^\top \mathbf{A} \mathbf{v}_r = \sigma_r;$$

5.

$$\mathbf{u}_1 = \frac{1}{\sigma_1} \mathbf{A} \mathbf{v}_1 \Rightarrow \mathbf{A} \mathbf{v}_1 = \sigma_1 \mathbf{u}_1$$

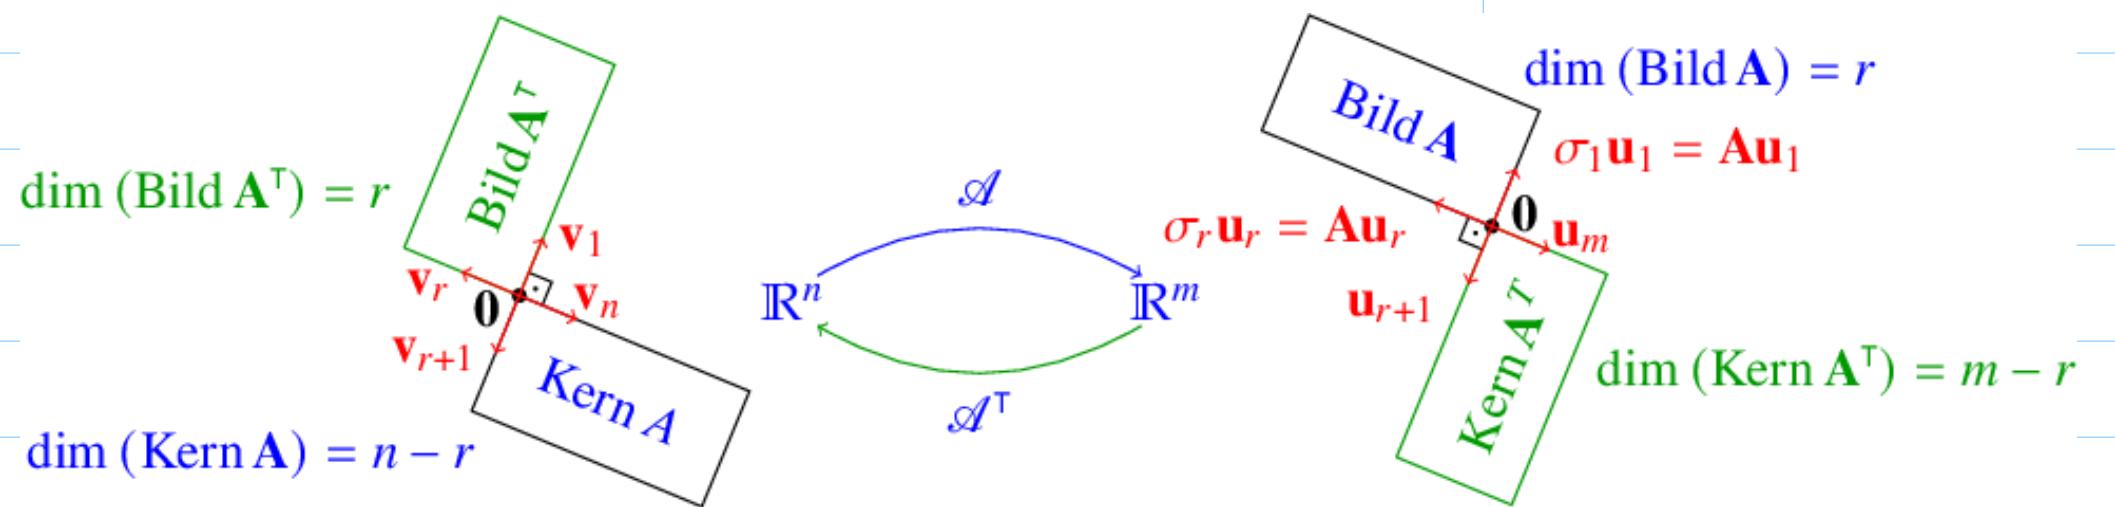
$$\vdots \qquad \vdots$$

$$\mathbf{u}_r = \frac{1}{\sigma_r} \mathbf{A} \mathbf{v}_r \Rightarrow \mathbf{A} \mathbf{v}_r = \sigma_r \mathbf{u}_r$$

$$\mathbf{A} \mathbf{v}_{r+1} = 0$$

$$\vdots$$

$$\mathbf{A} \mathbf{v}_n = 0.$$



8. Ausgleichsrechnung

8.1 Lineare Ausgleichsrechnung

Modell: $\mathbb{R} \ni b = d^T t + c$ $d \in \mathbb{R}^s, c \in \mathbb{R}$ $t \in \mathbb{R}^s$

Messpunkte: t_1, t_2, \dots, t_m

Gemessen: b_1, b_2, \dots, b_m

$$\Rightarrow \begin{cases} d^T t_1 + c - b_1 = r_1 \\ \dots \\ d^T t_m + c - b_m = r_m \end{cases} \Rightarrow \Gamma = \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_m \end{bmatrix} \quad \text{Residuum}$$

$$\min_{\mathbf{p} \in \mathbb{R}^n, q \in \mathbb{R}} \{ |r_1|^2 + \dots + |r_m|^2 \} = \min_{\mathbf{p} \in \mathbb{R}^n, q \in \mathbb{R}} \sum_{i=1}^s |\mathbf{p}^T t_i + q - b_i|^2. = \min_{q \in \mathbb{R}, \mathbf{p} \in \mathbb{R}^n} \sum_{i=1}^s |1 \cdot q + t_i^T \mathbf{p} + q - b_i|^2.$$

$$\mathbf{x} = \begin{bmatrix} q \\ \mathbf{p} \end{bmatrix} \in \mathbb{R}^{n+1}, \quad n = s+1$$

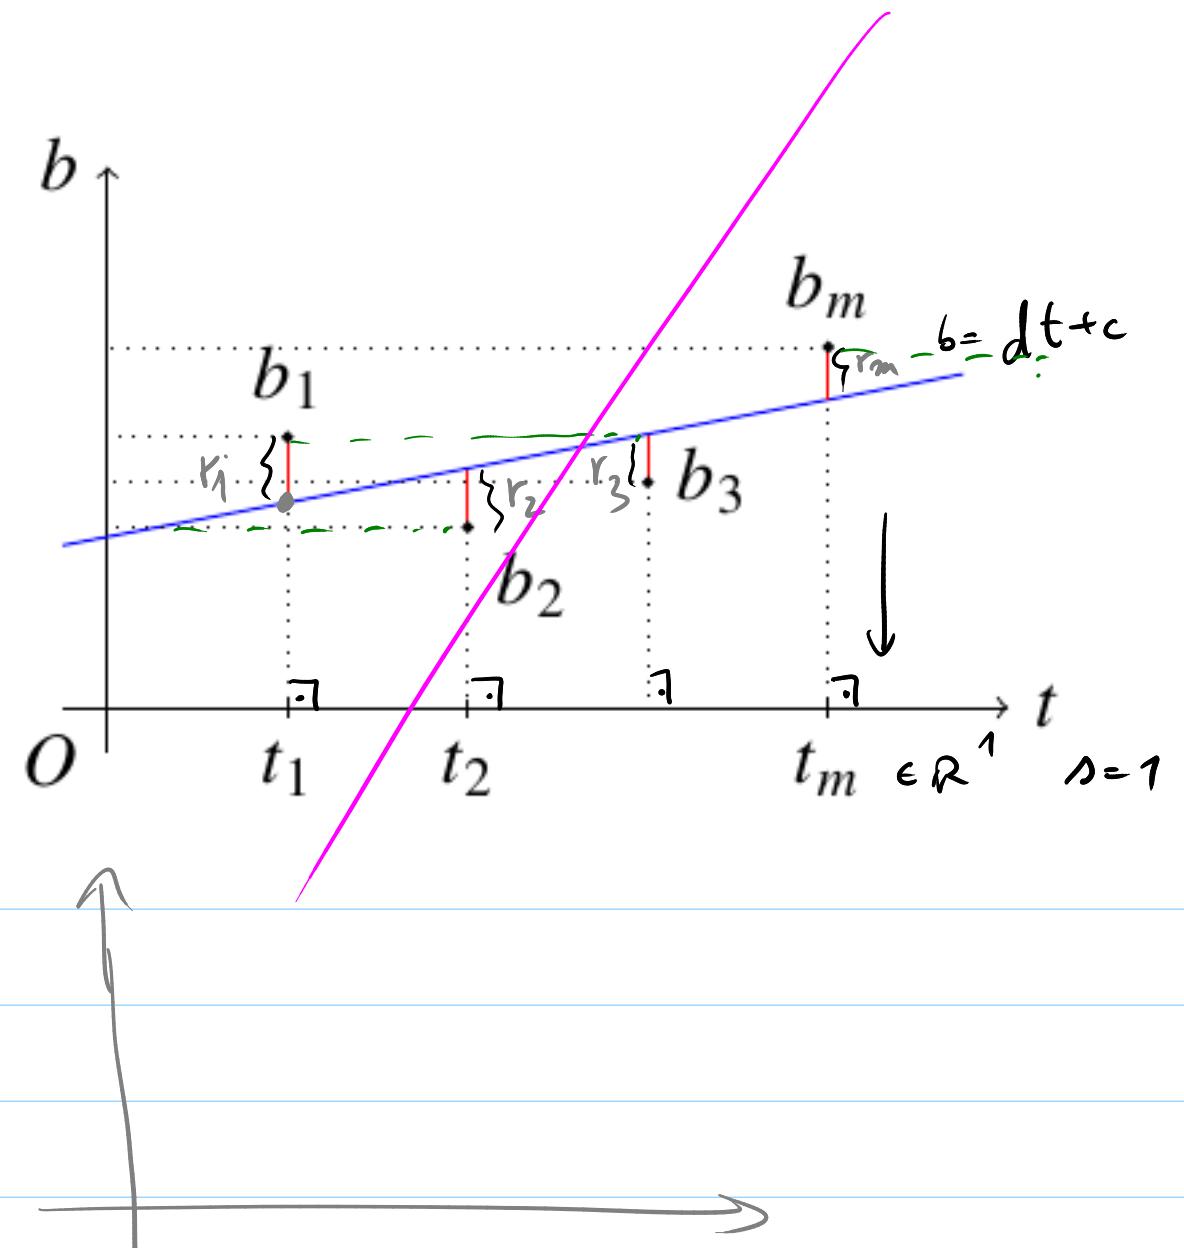
$$\mathbf{A} = \begin{bmatrix} 1 & t_1^T \\ 1 & t_2^T \\ \vdots & \vdots \\ 1 & t_m^T \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_m \end{bmatrix}.$$

$$\min_{x \in \mathbb{R}^n} \|\mathbf{Ax} - \mathbf{b}\|_2^2.$$

Definition 5.1.0.2. Lineare Ausgleichsrechnung als lineares Gleichungssystem

Sei eine $m \times n$ Matrix \mathbf{A} und der Vektor \mathbf{b} mit m Einträgen. Gesucht ist ein $\hat{\mathbf{x}}$, so dass

$$\|\mathbf{A}\hat{\mathbf{x}} - \mathbf{b}\|_2 = \min_{x \in \mathbb{R}^n} \|\mathbf{Ax} - \mathbf{b}\|_2.$$



Beispiel 5.1.0.4 (Modell im Unterraum)

Sei $f \in V$, wobei V ein ∞ -dimensionaler linearer Raum (z.B. L^2) ist. Sei nun $V_n \subset V$ ein endlich-dimensional Unterraum. Wir wollen eine Funktion $f_n \in V_n$ finden, die $f \in V$ im gewissen Sinne approximiert.

Sei b_1, \dots, b_n eine Basis in V_n . Das Ziel ist also:

$$f \approx f_n = \sum_{j=1}^n x_j b_j.$$

Ist das System z.B. zeitabhängig, so wählen wir eine zeitabhängige Basis:

$$f(t) \approx f_n(t) = \sum_{j=1}^n x_j b_j(t).$$

Verwenden wir nur die Werte/Messungen $y_i = f(t_i)$, so bekommen wir sehr einfach eine Approximation: Für die gegebenen $t_i, y_i, i = 1, 2, \dots, m$, finden wir die Koeffizienten x_1, \dots, x_n , sodass die Summe der Quadrate der punktweisen Approximationsfehler

$$\sum_{i=1}^m |f_n(t_i) - y_i|^2,$$

Nehmen wir beispielsweise an, dass $V = L^2(0, 1) = \{f : [0, 1] \rightarrow \mathbb{R}, \int_0^1 |f(t)|^2 dt < \infty\}$ und wählen die Basis der Monome $b_i(t) = t^{i-1}$, so dass wir V durch eine Polynommenge \mathcal{P} beschreiben können ($V_n = \mathcal{P}_n$). Dieser Ansatz produziert dann das »beste« Polynom p_n vom Grad maximal $n-1$, so dass die euklidische Norm des Residuumsvektors

$$\sum_{i=1}^m |p_n(t_i) - y_i|^2$$

minimal ist.

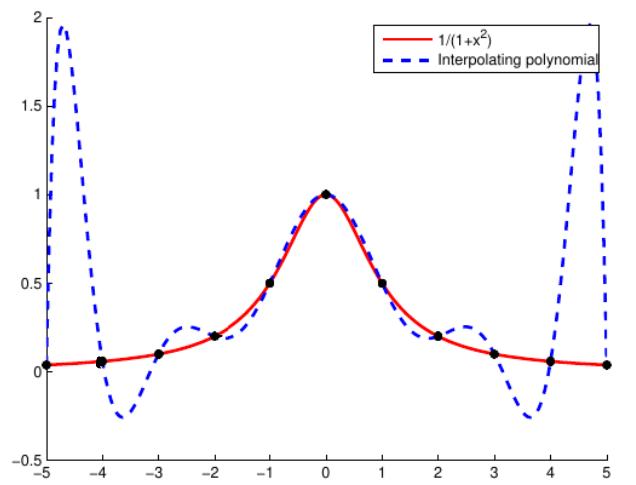
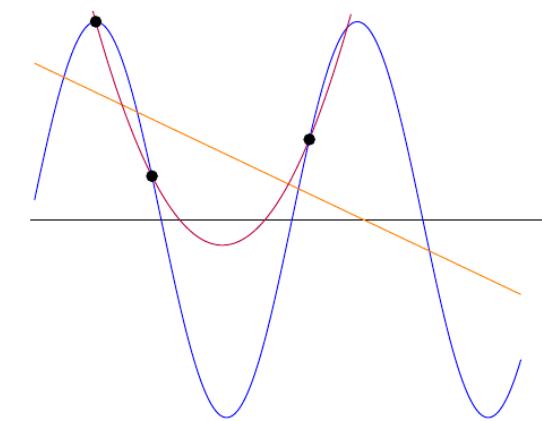


Abb. 3.4.18. Äquidistante Stützstellen

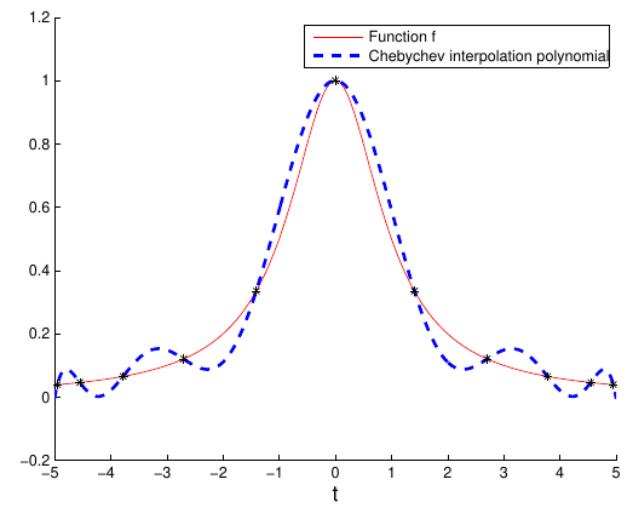


Abb. 3.4.19. Chebyshev-Knoten

Definition 5.2.0.1. Normalengleichung

Die Gleichung

$$\mathbf{A}^T \mathbf{A} \mathbf{x} = \mathbf{A}^T \mathbf{b}$$

heisst *Normalengleichung*.

Satz 5.2.0.2. Lösung der Ausgleichsrechnung mit der Normalengleichung

Sei eine Matrix $\mathbf{A} \in \mathbb{R}^{mxn}$ gegeben. Falls der Rang dieser Matrix gleich n ist, so ist $\mathbf{A}^T \mathbf{A}$ invertierbar. In diesem Fall hat die Normalengleichung also genau eine Lösung, die die Lösung des linearen Ausgleichsproblems ist.

8.2 Lineare Ausgleichsrechnung: via orthogonaler Transformationen

Wir schauen uns eine Alternativberechnung an, um numerische Fehler für grosse Matrizen zu vermeiden. Dazu bedienen wir uns wieder bei der QR-Zerlegung:

$$\mathbf{A} = \mathbf{Q} \mathbf{R} = \mathbf{Q} \begin{bmatrix} \widehat{\mathbf{R}} \\ 0 \end{bmatrix}.$$

Wenn die $m \times n$ Matrix \mathbf{A} Rang n hat, dann hat die $m \times n$ Matrix \mathbf{R} auch Rang n , so dass die ersten n Zeilen eine $n \times n$ invertierbare obere Dreiecksmatrix $\widehat{\mathbf{R}}$ sind. \mathbf{Q} ist eine $m \times m$ orthogonale (bzw. unitäre) Matrix: $\mathbf{Q}^T \mathbf{Q} = \mathbf{I}$, bzw. $\mathbf{Q}^H \mathbf{Q} = \mathbf{I}$. Da orthogonale/unitäre Matrizen die Längen nicht verändern, haben wir:

$$\begin{aligned} \min_{\mathbf{x} \in \mathbb{R}^n} \|\mathbf{Ax} - \mathbf{b}\|_2^2 &= \min_{\mathbf{x} \in \mathbb{R}^n} \|\mathbf{QRx} - \mathbf{QQ}^H \mathbf{b}\|_2^2 = \min_{\mathbf{x} \in \mathbb{R}^n} \|\mathbf{Q}(\mathbf{Rx} - \mathbf{Q}^H \mathbf{b})\|_2^2 \\ &= \min_{\mathbf{x} \in \mathbb{R}^n} \|\mathbf{Rx} - \mathbf{Q}^H \mathbf{b}\|_2^2. \end{aligned}$$

Definieren wir nun einen neuen Vektor $\widehat{\mathbf{b}} = \mathbf{Q}^H \mathbf{b}$. Wir fassen die ersten n Komponenten von $\widehat{\mathbf{b}}$ im Vektor \mathbf{c} zusammen und können dann die Block-Matrix-Schreibweise verwenden:

$$\begin{aligned} \min_{\mathbf{x} \in \mathbb{R}^n} \left\| \begin{bmatrix} \widehat{\mathbf{R}} \\ 0 \end{bmatrix} \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} - \begin{bmatrix} \widehat{\mathbf{b}}_1 \\ \vdots \\ \widehat{\mathbf{b}}_n \\ \widehat{\mathbf{b}}_{n+1} \\ \vdots \\ \widehat{\mathbf{b}}_m \end{bmatrix} \right\|_2^2 &= \min_{\mathbf{x} \in \mathbb{R}^n} \left\| \begin{bmatrix} \widehat{\mathbf{R}} \mathbf{x} \\ 0 \end{bmatrix} - \begin{bmatrix} \mathbf{c} \\ \widehat{\mathbf{b}}_{n+1} \\ \vdots \\ \widehat{\mathbf{b}}_m \end{bmatrix} \right\|_2^2 \\ &= \min_{\mathbf{x} \in \mathbb{R}^n} \left\| \begin{bmatrix} \widehat{\mathbf{R}} \mathbf{x} - \mathbf{c} \\ \widehat{\mathbf{b}}_{n+1} \\ \vdots \\ \widehat{\mathbf{b}}_m \end{bmatrix} \right\|_2^2 = \min_{\mathbf{x} \in \mathbb{R}^n} (\|\widehat{\mathbf{R}} \mathbf{x} - \mathbf{c}\|_2^2 + |\widehat{b}_{n+1}|^2 + \dots + |\widehat{b}_m|^2) \\ &= 0 + |\widehat{b}_{n+1}|^2 + \dots + |\widehat{b}_m|^2 \end{aligned}$$

falls $\widehat{\mathbf{R}} \mathbf{x} = \mathbf{c}$ st. Wir sehen, dass in der letzten Gleichung die Terme ab \widehat{b}_{n+1} unabhängig von \mathbf{x} sind. Dieses \mathbf{x} ist somit die Lösung im Sinne der kleinsten Quadrate, wobei der Fehler gleich der Norm des Residuums ist.

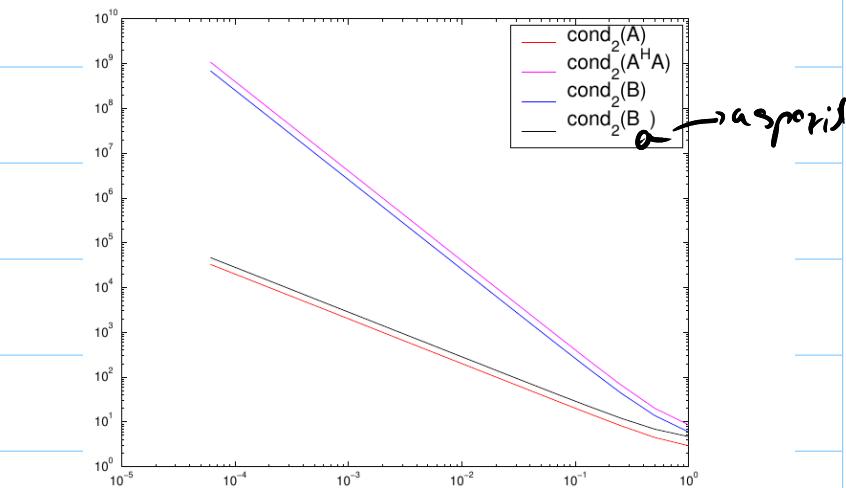
Das Residuum $\mathbf{r} = \mathbf{Ax} - \mathbf{b}$ wird als eine weitere Unbekannte behandelt. Man kann die Gleichung (8.1.4) folgendermassen umschreiben:

$$\mathbf{A}^H \mathbf{Ax} = \mathbf{A}^H \mathbf{b} \Leftrightarrow \mathbf{B} \begin{bmatrix} \mathbf{r} \\ \mathbf{x} \end{bmatrix} := \begin{bmatrix} -\mathbf{I} & \mathbf{A} \\ \mathbf{A}^H & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{r} \\ \mathbf{x} \end{bmatrix} = \begin{bmatrix} \mathbf{b} \\ 0 \end{bmatrix}. \quad (8.1.5)$$

Allgemeiner definiert man $\mathbf{r} := \frac{1}{a}(\mathbf{Ax} - \mathbf{b})$, wobei $a > 0$ gilt; dann kann man in Gleichung (8.1.5) die Matrix \mathbf{B} durch

$$\mathbf{B}_a := \begin{bmatrix} -a\mathbf{I} & \mathbf{A} \\ \mathbf{A}^H & \mathbf{0} \end{bmatrix}$$

ersetzen. Dabei wählt man a so, dass $\kappa(\mathbf{B}_a)$ minimal wird. Die Umformung (8.1.5) von Gleichung (8.1.4) sowie ihre Variante führen bei dünn besetztem \mathbf{A} wieder zu einer dünn besetzten Matrix \mathbf{B}_a und sind somit mit Hilfe von effizienten Verfahren für dünn besetzte Matrizen lösbar.



$$\mathbf{A} = \begin{bmatrix} 1 + \epsilon & 1 \\ 1 - \epsilon & 1 \\ \epsilon & \epsilon \end{bmatrix}.$$

$$\|\mathbf{Ax} - \mathbf{b}\|_2 = \|\mathbf{U}\Sigma\mathbf{V}^H\mathbf{x} - \mathbf{b}\|_2 = \|\Sigma\mathbf{V}^H\mathbf{x} - \mathbf{U}^H\mathbf{b}\|_2.$$

Wenn $\text{rank}(A) = r < \min(m, n)$, dann

$$\Sigma = \begin{bmatrix} \Sigma_r & 0 \\ 0 & 0 \end{bmatrix},$$

und alle Zeilenvektoren \mathbf{v}_j der Matrix \mathbf{V} , für die gilt: $j > r$, liegen im Kern von \mathbf{A} . Ähnliches gilt auch für die Matrix \mathbf{U} . Beide werden folgendermassen unterteilt:

$$\mathbf{A} = [\mathbf{U}_1 \quad \mathbf{U}_2] \begin{bmatrix} \Sigma_r & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \mathbf{V}_1^H \\ \mathbf{V}_2^H \end{bmatrix}$$

$$\left[\begin{array}{c} \mathbf{A} \\ \mathbf{U}_1 \quad \mathbf{U}_2 \\ \Sigma_r & 0 \\ 0 & 0 \\ \mathbf{V}_1^H \\ \mathbf{V}_2^H \end{array} \right] = \left[\begin{array}{c} \mathbf{U}_1 \quad \mathbf{U}_2 \\ \Sigma_r & 0 \\ 0 & 0 \\ \mathbf{V}_1^H \\ \mathbf{V}_2^H \end{array} \right],$$

mit je orthonormalen Spalten in den Matrizen U_1, U_2, V_1 und V_2 :

$$\mathbf{U}_1 \in \mathbb{K}^{m \times r}, \mathbf{U}_2 \in \mathbb{K}^{m \times n-r}, \mathbf{V}_1 \in \mathbb{K}^{n \times r}, \mathbf{V}_2 \in \mathbb{K}^{n \times n-r}.$$

Damit gilt für das Residuum:

$$\|\mathbf{Ax} - \mathbf{b}\|_2 = \|[\mathbf{U}_1 \quad \mathbf{U}_2] \begin{bmatrix} \Sigma_r & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \mathbf{V}_1^H \\ \mathbf{V}_2^H \end{bmatrix} \mathbf{x} - \mathbf{b}\|_2 = \left\| \begin{bmatrix} \Sigma_r \mathbf{V}_1^H \mathbf{x} \\ 0 \end{bmatrix} - \begin{bmatrix} \mathbf{U}_1^H \mathbf{b} \\ \mathbf{U}_2^H \mathbf{b} \end{bmatrix} \right\|_2.$$

Somit wird das Residuum genau dann minimal, wenn

$$\Sigma_r \mathbf{V}_1^H \mathbf{x} = \mathbf{U}_1^H \mathbf{b} \Leftrightarrow \mathbf{V}_1^H \mathbf{x} = \Sigma_r^+ \mathbf{U}_1^H \mathbf{b}, \quad (8.1.8)$$

wobei $\Sigma_r^+ = \text{diag}(\frac{1}{\sigma_1}, \dots, \frac{1}{\sigma_r})$ die "Inverse" von Σ_r ist. Das Residuum dazu ist $\|\mathbf{U}_2^H \mathbf{b}\|_2$. Wir definieren nun

$$\mathbf{x} = \mathbf{V}_1 \Sigma_r^+ \mathbf{U}_1^H \mathbf{b}, \quad (8.1.9)$$

Definition 8.2.2.1. Pseudoinverse nach Moore (1920) und Penrose (1955)

Sei $\mathbf{A} \in \mathbb{R}^{m \times n}$ gegeben und sei $\mathbf{U}\Sigma\mathbf{V}^T$ ihre Singulärwertzerlegung. Die Pseudoinverse (Moore-Penrose) ist dann definiert als:

$$\mathbf{A}^\dagger = \mathbf{V}\Sigma^\dagger\mathbf{U}^H,$$

mit der $n \times m$ Diagonalmatrix:

$$\Sigma^\dagger = \begin{bmatrix} \sigma_1^{-1} & 0 & \cdots & 0 \\ 0 & \sigma_2^{-1} & \cdots & 0 \\ \vdots & \ddots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{bmatrix}.$$

$$\begin{aligned} \|\mathbf{Ax}\|_2^2 &= \|\mathbf{U}\Sigma\mathbf{V}^T\mathbf{x}\|_2^2 = \|\Sigma\mathbf{V}^T\mathbf{x}\|_2^2 \\ &= \sigma_1^2 |\mathbf{v}_1^T \mathbf{x}|^2 + \sigma_2^2 |\mathbf{v}_2^T \mathbf{x}|^2 + \dots + \sigma_r^2 |\mathbf{v}_r^T \mathbf{x}|^2. \end{aligned}$$

$$\|\mathbf{A}\|_2 = \max_{\|\mathbf{x}\|_2=1} \|\mathbf{Ax}\|_2 = \max_{\|\mathbf{x}\|_2=1} \|\Sigma\mathbf{V}^T\mathbf{x}\|_2 = \max_{\|\mathbf{x}\|_2=1} \|\Sigma\mathbf{y}\|_2.$$

$$\begin{aligned} \|\Sigma\mathbf{y}\|_2^2 &= \sigma_1^2 |y_1|^2 + \dots + \sigma_r^2 |y_r|^2 \\ &= \sigma_1^2 [|y_1|^2 + \frac{\sigma_2^2}{\sigma_1^2} |y_2|^2 + \dots + \frac{\sigma_r^2}{\sigma_1^2} |y_r|^2] \\ &\leq \sigma_1^2 \|\mathbf{y}\|_2^2. \end{aligned}$$

numerischer Rang der Matrix



$$\sigma_1 \geq \sigma_2 \dots \geq \sigma_k \gg \sigma_{k+1} \geq \dots \geq \sigma_r > 0.$$

Satz 8.2.6.2. Beste Approximation an einer Matrix: Schmidt 1907 wiederentdeckt von Eckart 1933 und Young 1936

Sei $\mathbf{A} \in \mathbb{R}^{m \times n}$ beliebig. Für jedes $k \leq \text{Rang } \mathbf{A}$ gibt die abgebrochene Singulärwertzerlegung

$$\mathbf{A}_k = \sum_{j=1}^k \sigma_j \mathbf{u}_j \mathbf{v}_j^T$$

die beste Approximation von Rang k an \mathbf{A} im Sinne von:

$$\|\mathbf{A} - \mathbf{A}_k\| = \min_{\substack{\mathbf{B} \in \mathbb{R}^{m \times n} \\ \text{Rang } \mathbf{B} \leq k}} \|\mathbf{A} - \mathbf{B}\| = \sigma_{k+1}.$$

Dabei kann $\|\cdot\|$ die euklidische, die Frobenius oder Nuklearnorm der Matrix sein.

Definition 7.3.0.11. Konditionszahl

Die Konditionszahl einer invertierbaren Matrix \mathbf{A} ist

$$k(\mathbf{A}) = \frac{\|\mathbf{A}\|_2}{\|\mathbf{A}^{-1}\|_2} = \sqrt{\frac{d_{\max}}{d_{\min}}}, = \frac{\sigma_1}{\sigma_r} \quad !!$$

wobei d_{\max} das grösste und d_{\min} das kleinste Eigenwert von $\mathbf{A}^H \mathbf{A}$ sind.

$$\max_{\substack{\mathbf{x} \in \mathbb{R}^n \\ \mathbf{x} \notin \text{span}\{\mathbf{v}_1\}}} \frac{\|\mathbf{Ax}\|_2}{\|\mathbf{x}\|_2} = \sigma_2 \text{ erreicht für } \mathbf{x} = \mathbf{V} \begin{bmatrix} 0 \\ 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix} = \mathbf{v}_2.$$

$$\max_{\substack{\mathbf{x} \in \mathbb{R}^n \\ \mathbf{x} \notin \text{span}\{\mathbf{v}_1, \mathbf{v}_2\}}} \frac{\|\mathbf{Ax}\|_2}{\|\mathbf{x}\|_2} = \sigma_3 \text{ erreicht für } \mathbf{x} = \mathbf{V} \begin{bmatrix} 0 \\ 0 \\ 1 \\ \vdots \\ 0 \end{bmatrix} = \mathbf{v}_3,$$

Definition 8.2.3.2. Wichtige Matrizennormen

Sei \mathbf{A} eine $m \times n$ Matrix.

Die euklidische Norm oder (wie gerade bewiesen) auch Spektralnorm ist

$$\|\mathbf{A}\|_2 = \max_{\mathbf{x} \neq \mathbf{0}} \frac{\|\mathbf{Ax}\|_2}{\|\mathbf{x}\|_2} = \sigma_1.$$

Die Frobenius Norm ist

$$\|\mathbf{A}\|_F = \sqrt{\sum_{i,j} |A_{i,j}|^2} = \text{Spur}(\mathbf{A}^T \mathbf{A}) = \sqrt{\sigma_1^2 + \sigma_2^2 + \dots + \sigma_r^2}.$$

Die Nuklearnorm ist

$$\|\mathbf{A}\|_N = \sigma_1 + \sigma_2 + \dots + \sigma_r.$$

Satz 8.2.3.3. Nützliche Ungleichungen zwischen Matrixnormen

Für $\mathbf{A} \in \mathbb{R}^{m \times n}$ von Rang r gelten die Ungleichungen:

$$\|\mathbf{A}\|_2 \leq \|\mathbf{A}\|_F \leq \sqrt{r}\|\mathbf{A}\|_2$$

$$\|\mathbf{A}\|_F \leq \|\mathbf{A}\|_N \leq \sqrt{r}\|\mathbf{A}\|_F$$

$$\|\mathbf{A}\|_{max} \leq \|\mathbf{A}\|_2 \leq \sqrt{mn}\|\mathbf{A}\|_{max}$$

$$\frac{1}{\sqrt{n}}\|\mathbf{A}\|_\infty \leq \|\mathbf{A}\|_2 \leq \sqrt{m}\|\mathbf{A}\|_\infty$$

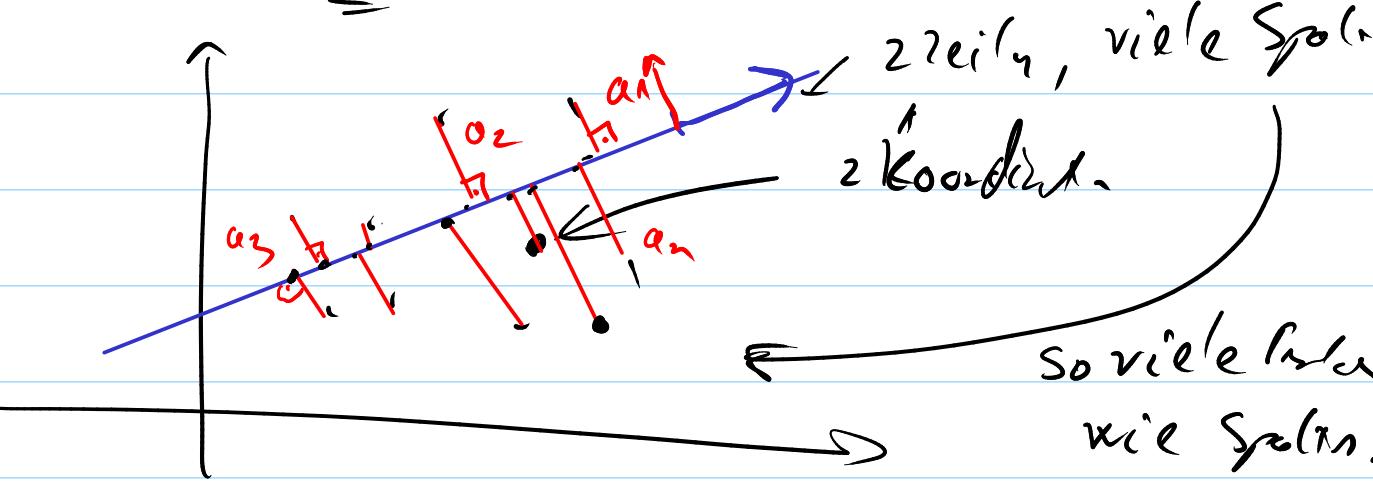
$$\frac{1}{\sqrt{m}}\|\mathbf{A}\|_1 \leq \|\mathbf{A}\|_2 \leq \sqrt{n}\|\mathbf{A}\|_1,$$

und außerdem:

$$\|\mathbf{A}\|_2 \leq \sqrt{\|\mathbf{A}\|_1\|\mathbf{A}\|_\infty}.$$

8.3 Hauptkomponentenanalyse PCA = principal component analysis

Data \underline{A} Matrix



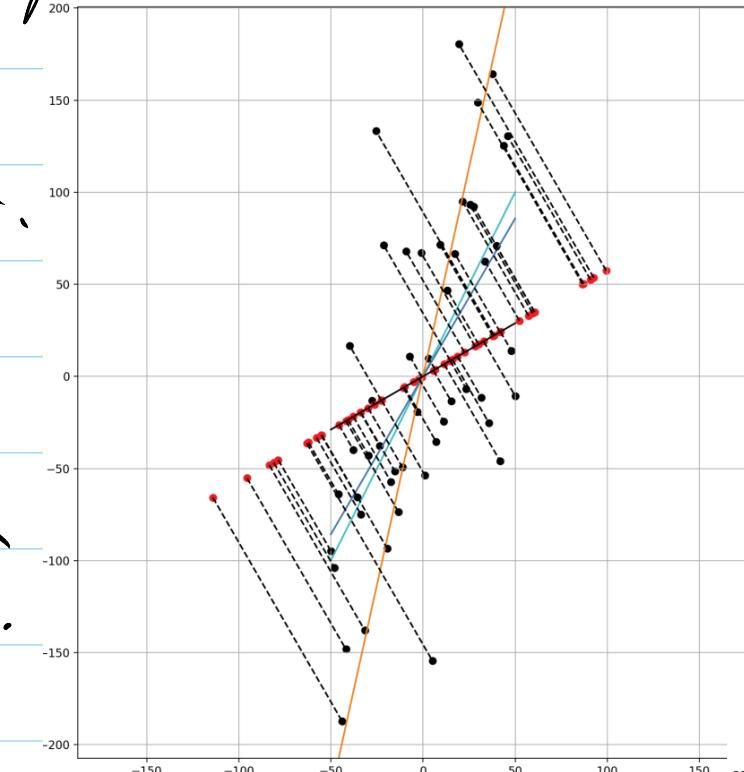
$$\min \{ a_1^2 + a_2^2 + \dots + a_n^2 \}$$

LA: Welche Spalten sind linear abhängig.

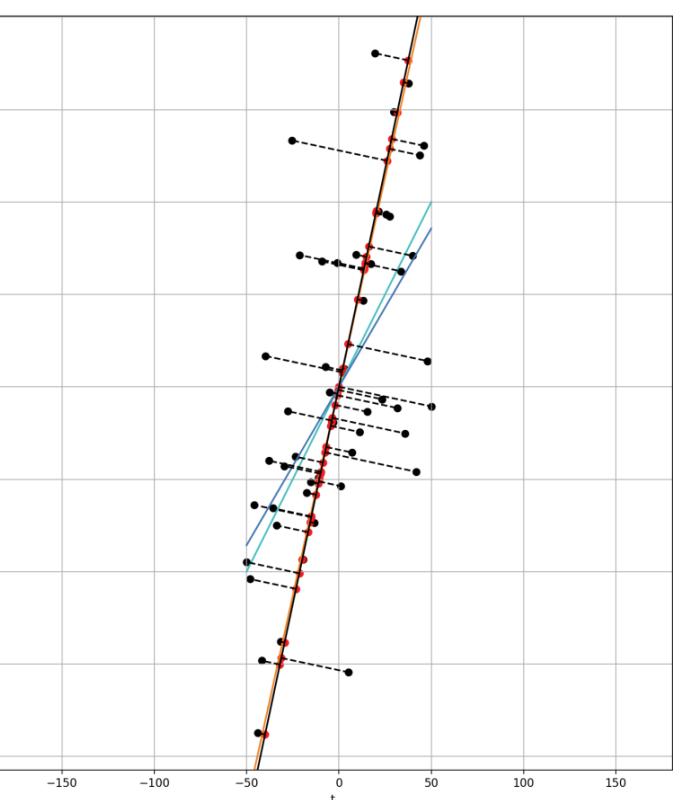
=> Hauptkomponentenanalyse

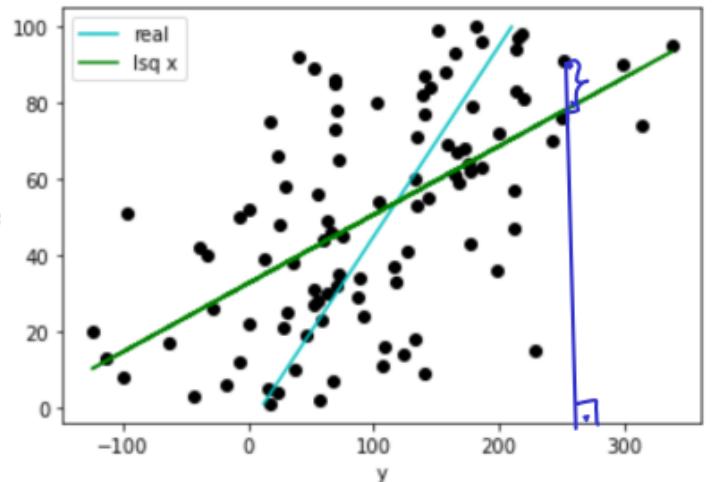
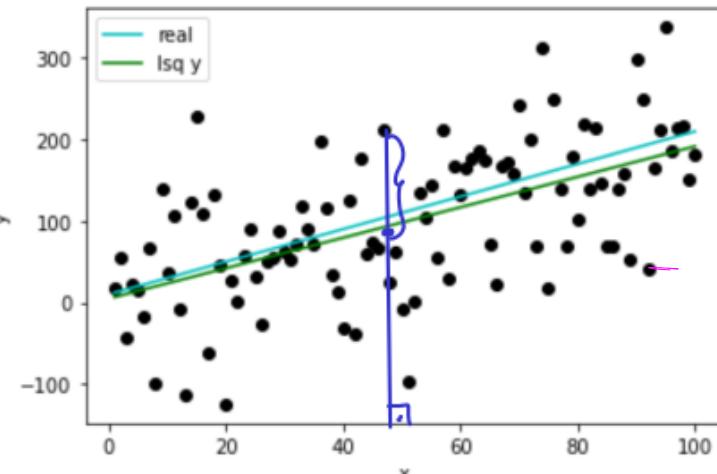
$$\underline{A} = \underline{U} \Sigma \underline{V}^T \approx \sum_{k=1}^r \underbrace{\begin{bmatrix} u_k \\ \sigma_k \\ v_k^T \end{bmatrix}}_{\text{Gewichte}}$$

Hauptkomponenten



OLS = LSQ

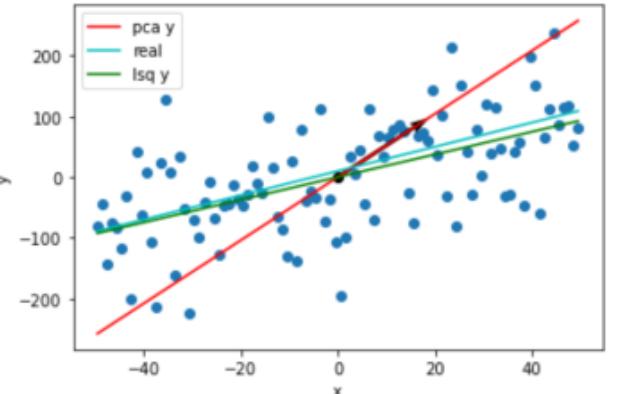
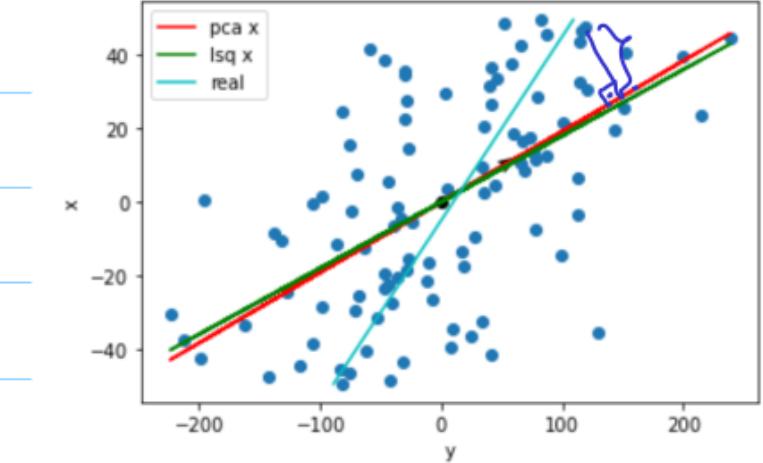
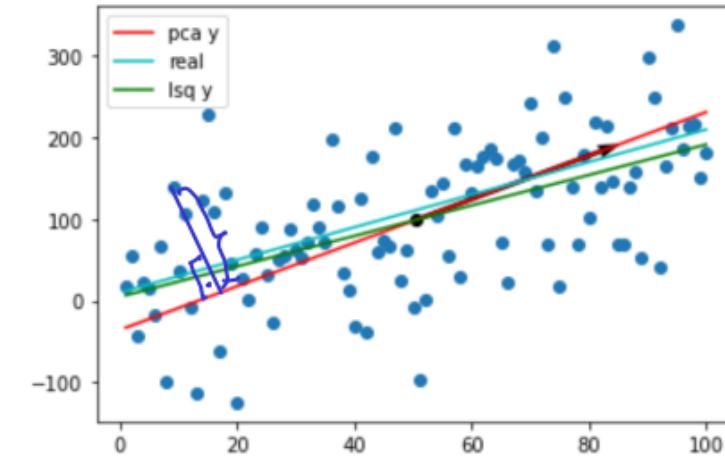
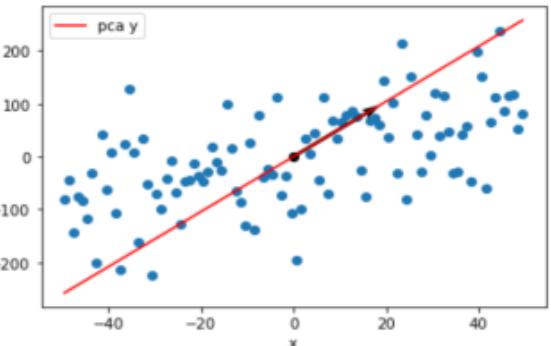
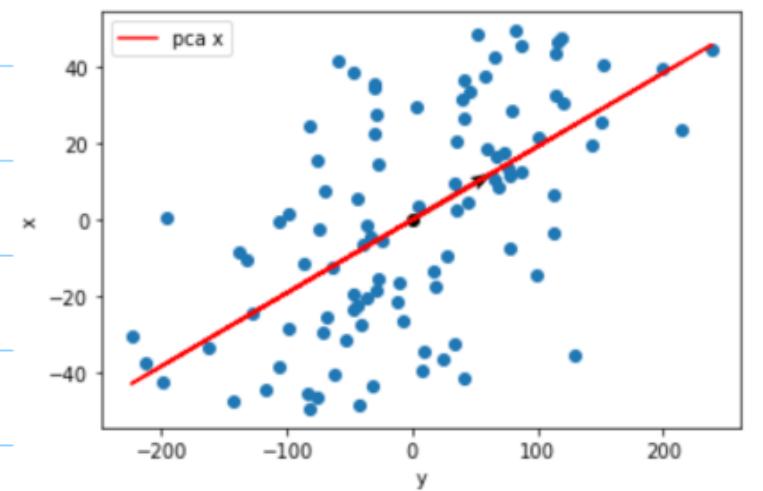
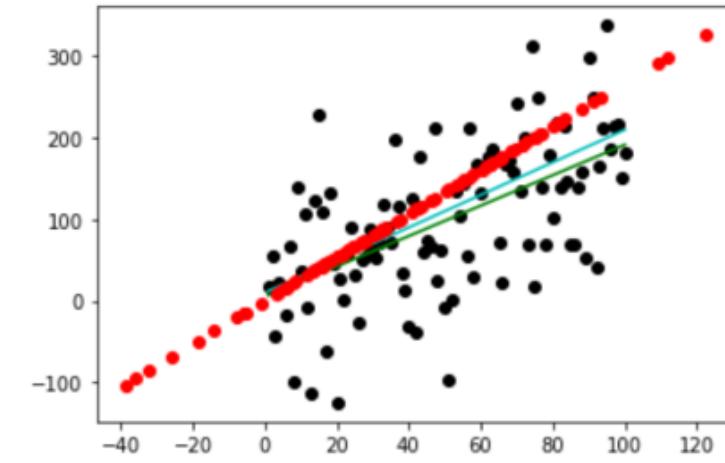
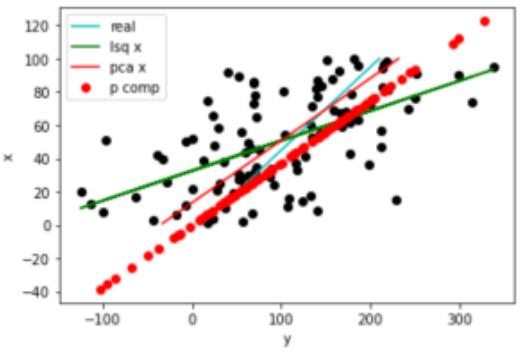




Für ein lineares Modell:

$$y = ax + c; \quad c=10, a=2 \\ x \in [0, 100]$$

$y_b = y + \text{random} \dots$



SLR Lineare Ausgleichsrechnung mit linearen Nebenbedingungen

$$\underline{A} \in \mathbb{R}^{m \times n}, m \geq n = \text{Rang } \underline{A}$$

m

$$\underline{b} \in \mathbb{R}^m$$

$$\underline{C} \in \mathbb{R}^{p \times n}, n > p = \text{Rang } \underline{C}$$

n

$$\underline{d} \in \text{Bild } \underline{C} \subset \mathbb{R}^p$$

p

$$\min_{\underline{x} \in \mathbb{R}^n} \|\underline{A}\underline{x} - \underline{b}\|^2$$

$$\boxed{\underline{C}\underline{x} = \underline{d}}$$

Nebenbedingung

Methode 1: Lagrange Multiplikatoren $\underline{m} \in \mathbb{R}^p$

$$L(\underline{x}, \underline{m}) = \frac{1}{2} \|\underline{A}\underline{x} - \underline{b}\|_2^2 + \underline{m}^\top (\underline{C}\underline{x} - \underline{d})$$

Löse

$$\begin{aligned} \min_{\underline{x} \in \mathbb{R}^n} \\ \max_{\underline{m} \in \mathbb{R}^p} \end{aligned}$$

$$L(\underline{x}, \underline{m})$$

In Sattelpunkt:

$$\left. \begin{aligned} \frac{\partial L}{\partial \underline{x}}(\underline{x}, \underline{m}) &= \mathbf{0} \\ \frac{\partial L}{\partial \underline{m}}(\underline{x}, \underline{m}) &= \mathbf{0} \end{aligned} \right\}$$

$$\left. \begin{aligned} \underline{A}^\top(\underline{A}\underline{x} - \underline{b}) + \underline{C}^\top \underline{m} &= \mathbf{0} \\ \underline{C}\underline{x} - \underline{d} &= \mathbf{0} \end{aligned} \right\}$$

$$\begin{bmatrix} \underline{A}^\top \underline{A} & \underline{C}^\top \\ \underline{C} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \underline{x} \\ \underline{m} \end{bmatrix} = \begin{bmatrix} \underline{A}^\top \underline{b} \\ \underline{d} \end{bmatrix}$$

Wie lösen? Block-LR-Zerlegung.

$$1) \text{ Cholesky-Zerlegung: } \underline{\underline{A}}^T \underline{\underline{A}} = \underline{\underline{R}}^T \underline{\underline{R}}$$

$$2) \text{ berechne } \underline{\underline{G}} \text{ aus } \underline{\underline{R}}^T \underline{\underline{G}}^T = \underline{\underline{S}}^T$$

$$3) \text{ berechne } \underline{\underline{S}} \text{ aus Cholesky-Zerlegung.}$$

$$\underline{\underline{S}}^T \underline{\underline{S}} = -\underline{\underline{G}} \underline{\underline{G}}^T$$

$$\begin{bmatrix} \underline{\underline{A}}^T & \underline{\underline{A}} \\ \underline{\underline{C}} & \underline{\underline{C}} \end{bmatrix} = \begin{bmatrix} \underline{\underline{R}}^T & 0 \\ \underline{\underline{G}} & \underline{\underline{S}} \end{bmatrix} \begin{bmatrix} \underline{\underline{R}} & \underline{\underline{G}}^T \\ 0 & \underline{\underline{S}}^T \end{bmatrix}$$

$$\begin{bmatrix} \underline{\underline{y}}_1 \\ \underline{\underline{y}}_2 \end{bmatrix}^{\text{Not.}} = \begin{bmatrix} \underline{\underline{R}} & \underline{\underline{G}}^T \\ 0 & \underline{\underline{S}}^T \end{bmatrix} \begin{bmatrix} \underline{\underline{x}}_1 \\ \underline{\underline{x}}_2 \end{bmatrix}$$

$$\begin{bmatrix} \underline{\underline{R}}^T & 0 \\ \underline{\underline{G}} & \underline{\underline{S}} \end{bmatrix} \begin{bmatrix} \underline{\underline{y}}_1 \\ \underline{\underline{y}}_2 \end{bmatrix} = \begin{bmatrix} \underline{\underline{A}}^T \underline{\underline{b}} \\ \underline{\underline{d}} \end{bmatrix}$$

$$\Rightarrow \underline{\underline{R}}^T \underline{\underline{y}}_1 = \underline{\underline{A}}^T \underline{\underline{b}} \Rightarrow \underline{\underline{y}}_1 = (\underline{\underline{R}}^T)^{-1} \underline{\underline{A}}^T \underline{\underline{b}}$$

$\underline{\underline{y}}_1 = \text{solve}(\underline{\underline{R}}^T, \underline{\underline{A}}^T \underline{\underline{b}})$

$$\underline{\underline{G}} \underline{\underline{y}}_1 + \underline{\underline{S}} \underline{\underline{y}}_2 = \underline{\underline{d}} \Rightarrow \underline{\underline{S}} \underline{\underline{y}}_2 = \underline{\underline{d}} - \underline{\underline{G}} \underline{\underline{y}}_1$$

obere Dreiecksstruktur.

$$\underline{\underline{y}}_2 = \text{solve}(\underline{\underline{S}}, \underline{\underline{d}} - \underline{\underline{G}} \underline{\underline{y}}_1)$$

$$\begin{bmatrix} \underline{\underline{R}} & \underline{\underline{G}}^T \\ 0 & \underline{\underline{S}}^T \end{bmatrix} \begin{bmatrix} \underline{\underline{x}} \\ \underline{\underline{z}} \end{bmatrix} = \begin{bmatrix} \underline{\underline{y}}_1 \\ \underline{\underline{y}}_2 \end{bmatrix}$$

$$\underline{\underline{S}}^T \underline{\underline{z}} = \underline{\underline{y}}_2 \Rightarrow \underline{\underline{z}} = \text{solve}(\underline{\underline{S}}^T, \underline{\underline{y}}_2)$$

$$\underline{\underline{R}} \underline{\underline{x}} = \underline{\underline{y}}_1 - \underline{\underline{G}}^T \underline{\underline{z}} \Rightarrow \underline{\underline{x}} = \text{solve}(\underline{\underline{R}}, \underline{\underline{y}}_1 - \underline{\underline{G}}^T \underline{\underline{z}})$$

Methode 2:

Singularwertzerlegung von \underline{C} :

$$\underline{P} \quad \underline{\underline{C}} = \underline{U} \begin{bmatrix} \Sigma & 0 \end{bmatrix} \begin{bmatrix} \underline{V}_1^\top \\ \underline{V}_2^\top \end{bmatrix}$$

$\text{Rang } \underline{C} = p \quad \begin{bmatrix} & & & \\ & & & \\ \underline{v}_1, \underline{v}_2, \dots, \underline{v}_p & \underline{0} \end{bmatrix}$

$$\underline{x}_0 = \underline{V}_1 \Sigma^{-1} \underline{U}^\top \underline{d}$$

$\xrightarrow{\text{suche } \underline{x} \in \text{Ker } \underline{C}}$

$$\underline{x} = \underline{x}_0 + \underline{V}_2 \underline{y}$$

$\xrightarrow{\text{free}}$

Vorteil: stabiler

Nachteil: Struktur von \underline{A} kann nicht verwendet werden!

Suche :

$$\begin{aligned} \underline{C} \underline{x} &= \underline{C} \underline{x}_0 + \underline{C} (\underline{V}_2 \underline{y}) \\ &= \underline{\Sigma} \underline{\Sigma} \underbrace{\underline{V}_1^\top \underline{V}_1}_{\text{fest}} \underline{\Sigma}^{-1} \underline{U}^\top \underline{d} = \underline{\Sigma}^\top \underline{\Sigma} \underline{d} = \underline{d} \Rightarrow \text{Nebenbedingung ist vor diesen } \underline{x} \text{ erzielt erfüllt.} \end{aligned}$$

$$\|\mathbf{Ax} - \mathbf{b}\|_2^2 = \|\mathbf{Ax}_0 + \mathbf{AV}_2 \mathbf{y} - \mathbf{b}\|_2^2 = \|\mathbf{AV}_2 \mathbf{y} - (\mathbf{b} - \mathbf{Ax}_0)\|_2^2$$

free

fest

Das ist ein standard Ausgleichsproblem

mit Matrix $\underline{A} \underline{V}_2$ und rechte Seite $\underline{b} - \underline{A} \underline{x}_0$

8.5 Nichtlineare Ausgleichsrechnung

Modell:

$$f(t, \underline{x}) = y$$

$\underline{x} \in \mathbb{R}^n$ Parameter, aus Messungen zu bestimmen

Messungen:

$$f(t_i, \underline{x}) = y_i \quad \text{für } i=1, 2, \dots, m$$

Residuum:

$$F(\underline{x}) = \begin{bmatrix} f(t_1, \underline{x}) - y_1 \\ \vdots \\ f(t_m, \underline{x}) - y_m \end{bmatrix} \quad F: \mathbb{R}^n \rightarrow \mathbb{R}^m$$

Aufgabe (nichtlineare Ausgleichsrechnung): Finde $\underline{x} \in \mathbb{R}^n$, so dass

$$\underline{x} = \underset{\underline{u} \in \mathbb{R}^n}{\operatorname{argmin}} \left(\sum_{i=1}^m |f(t_i, \underline{u}) - y_i|^2 \right) = \underset{\underline{u} \in \mathbb{R}^n}{\operatorname{argmin}} \underbrace{\frac{1}{2} \|F(\underline{u})\|_2^2}_{\Phi(\underline{u})}$$

Für $\underline{x}^* = \text{Lösung von } \operatorname{argmin} :$

$$\operatorname{grad} \Phi(\underline{x}^*) = 0$$

$$\Phi(\underline{x}) = \frac{1}{2} \|F(\underline{x})\|_2^2$$

$$\operatorname{grad} \Phi(\underline{x}) = (\underline{D}F(\underline{x}))^T \underline{F}(\underline{x})$$

$$D(\operatorname{grad} \Phi)(\underline{x}) = (\underline{D}F(\underline{x}))^T \underline{D}F(\underline{x}) + \sum_{j=1}^m F_j(\underline{x}) D^2 F_j(\underline{x})$$

$$\underline{H}_{\Phi}(\underline{x})$$

Hesse-Matrix

Newton:

$$\underline{x}^{(k+1)} = \underline{x}^{(k)} - (\underline{D} \operatorname{grad} \Phi(\underline{x}))^{-1} \operatorname{grad} \Phi(\underline{x})$$

Oder:

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

mit Newton-Korrektur aus den LGS

$$\underline{H}_{\Phi}(\underline{x}^{(k)}) \underline{\Delta} = \underline{D}F(\underline{x}^{(k)})^T \underline{F}(\underline{x}^{(k)})$$

$$=$$

Hesse Matrix.

Alternative: Gauss-Newton - Verfahren

Idee: linearisiere F um \mathbf{y} .

$$\begin{aligned} F(\mathbf{x}) &\approx F(\mathbf{y}) + DF(\mathbf{y})(\mathbf{x} - \mathbf{y}) = F(\mathbf{y}) + \mathbf{J}_F(\mathbf{y})(\mathbf{x} - \mathbf{y}) \\ &= F(\mathbf{y}) + \mathbf{J}_F(\mathbf{y})\mathbf{x} - \mathbf{J}_F(\mathbf{y})\mathbf{y} \end{aligned}$$

lineare Version von F

$$\operatorname{argmin}_{\mathbf{x} \in \mathbb{R}^n} \frac{1}{2} \|F(\mathbf{x})\|_2^2 \approx \operatorname{argmin}_{\mathbf{x} \in \mathbb{R}^n} \frac{1}{2} \|F(\mathbf{y}) + \mathbf{J}_F(\mathbf{y})\mathbf{x} - \mathbf{J}_F(\mathbf{y})\mathbf{y}\|_2^2 = \operatorname{argmin}_{\mathbf{x} \in \mathbb{R}^n} \frac{1}{2} \|\mathbf{Ax} - \mathbf{b}\|_2^2$$

Standard LSQ !

Setzt man $\mathbf{x} = \mathbf{x}^{k+1} = \mathbf{x}^k - \mathbf{s}$ und $\mathbf{y} = \mathbf{x}^k$, dann erhält man

$$\begin{aligned} \operatorname{argmin}_{\mathbf{z} \in \mathbb{R}^n} \frac{1}{2} \|F(\mathbf{x}^k - \mathbf{z})\| &\approx \operatorname{argmin}_{\mathbf{z} \in \mathbb{R}^n} \frac{1}{2} \|F(\mathbf{x}^k) + \mathbf{J}_F(\mathbf{x}^k)(\mathbf{x}^k - \mathbf{z} - \mathbf{x}^k)\| \\ &= \operatorname{argmin}_{\mathbf{z} \in \mathbb{R}^n} \frac{1}{2} \|F(\mathbf{x}^k) - \mathbf{J}_F(\mathbf{x}^k)\mathbf{z}\| \end{aligned}$$

erste Ableitung von F

+ code

+ Bilder zu Skript

↪ $\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - \mathbf{s}$ mit $\mathbf{s} := \operatorname{argmin}_{\mathbf{z} \in \mathbb{R}^n} \|F(\mathbf{x}^{(k)}) - \mathbf{J}_F(\mathbf{x}^{(k)})\mathbf{z}\|_2^2$.

Bsp Modell $f(t, \underline{x}) = x_1 + x_2 e^{-x_3 t}$

$$\underline{x} = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} \in \mathbb{R}^3$$

$$\underline{t} = \begin{bmatrix} t_1 \\ \vdots \\ t_m \end{bmatrix} \in \mathbb{R}^m$$

Messungen $t_1, \dots, t_m \in \mathbb{R}$

$$\underline{y} = \begin{bmatrix} y_1 \\ \vdots \\ y_m \end{bmatrix} \in \mathbb{R}^m$$

$$y_1, \dots, y_m \in \mathbb{R}$$

Residuum:

$$\underline{F}(t, \underline{x}) = f(\underline{t}, \underline{x}) - \underline{y} \in \mathbb{R}^m$$

$$f(t_j, \underline{x}) - y_j \quad j=1, 2, \dots, m$$

$$\underline{\underline{D}}F(\underline{x}) = \begin{bmatrix} \frac{\partial}{\partial x_i} f(t_j, \underline{x}) \dots \\ \vdots \\ \frac{\partial}{\partial x_i} f(t_j, \underline{x}) \dots \\ \vdots \\ \frac{\partial}{\partial x_i} f(t_j, \underline{x}) \dots \end{bmatrix}_{j=1, 2, \dots, m} \quad i=1, 2, 3 \quad (\text{Index der Parameter})$$

$$i=1, 2, 3 \quad (\text{Index der Parameter})$$

$$j=1, 2, \dots, m \quad (\text{Index der Messungen})$$

$$\frac{\partial f}{\partial x_1} = 1$$

$$\frac{\partial f}{\partial x_2} = e^{-x_3 t}$$

$$\frac{\partial f}{\partial x_3} = -t x_2 e^{-x_3 t}$$

$$\underline{\underline{D}}\underline{F}(\underline{x}) = \begin{bmatrix} 1 & \dots & \dots \\ \vdots & \ddots & \vdots \\ 1 & \dots & \dots \end{bmatrix} \in \mathbb{R}^{m \times 3}$$

$$\underline{f} \in \mathbb{R}^m$$

$$\underline{f} = F(\underline{t}, \underline{x})$$

$$\underline{df} = \underline{\underline{D}}F(\underline{x}) \in \mathbb{R}^{m \times 3}$$

2. Ableitung:

$$\left[\begin{array}{ccc} \frac{\partial^2 f}{\partial t^2} = 0 & \frac{\partial^2 f}{\partial x_1 \partial t} = 0 & \frac{\partial^2 f}{\partial x_3 \partial t} = 0 \\ 0 & \frac{\partial^2 f}{\partial x_1^2} = 0 & \frac{\partial^2 f}{\partial x_3 \partial x_2} = -t e^{-x_3 t} \\ 0 & -t e^{-x_3 t} & \frac{\partial^2 f}{\partial x_2^2} = t^2 x_2 e^{-x_3 t} \end{array} \right]$$

Punktwise in \underline{t} auswerten!

$$\underline{t}_{\text{exp}} = \underline{t} e^{-x_3 \underline{t}} \quad \text{Punktwise Auswertung}$$

$$\in \mathbb{R}^m$$

$$\sum_{j=1}^m F_j(\underline{x}) \underline{\underline{D}} F_j(\underline{x})$$

Damit: Newton, Gauss-Newton, ...

GPS: N Sattellitten: für $i=1, \dots, N$ bekannt $[t_{s,i}, x_{s,i}, y_{s,i}, z_{s,i}]$

Gesucht: $\underline{x} = [t_r, x_r, y_r, z_r]$ Zeit + Position Receiver
 ↗ ungenau im Receiver, darum mit zu bestimmen

Laufzeit messung \Rightarrow

Residuum: $F: \mathbb{R}^4 \rightarrow \mathbb{R}^N$

$$F(x) = \left[-c^2(t_r - t_{s,i})^2 + (x_r - x_{s,i})^2 + (y_r - y_{s,i})^2 + (z_r - z_{s,i})^2 \right] \quad i=1, 2, \dots, N$$

$$\Rightarrow \min_{x \in \mathbb{R}^4} \|F(x)\|_2^2$$

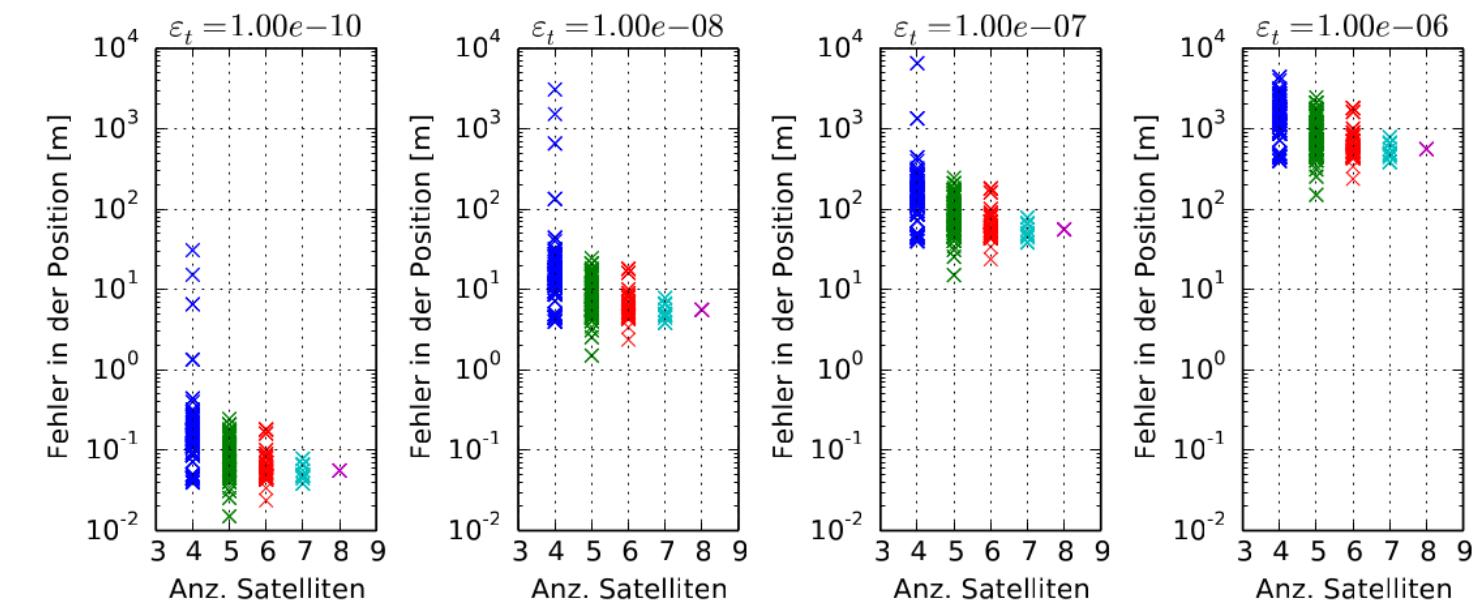
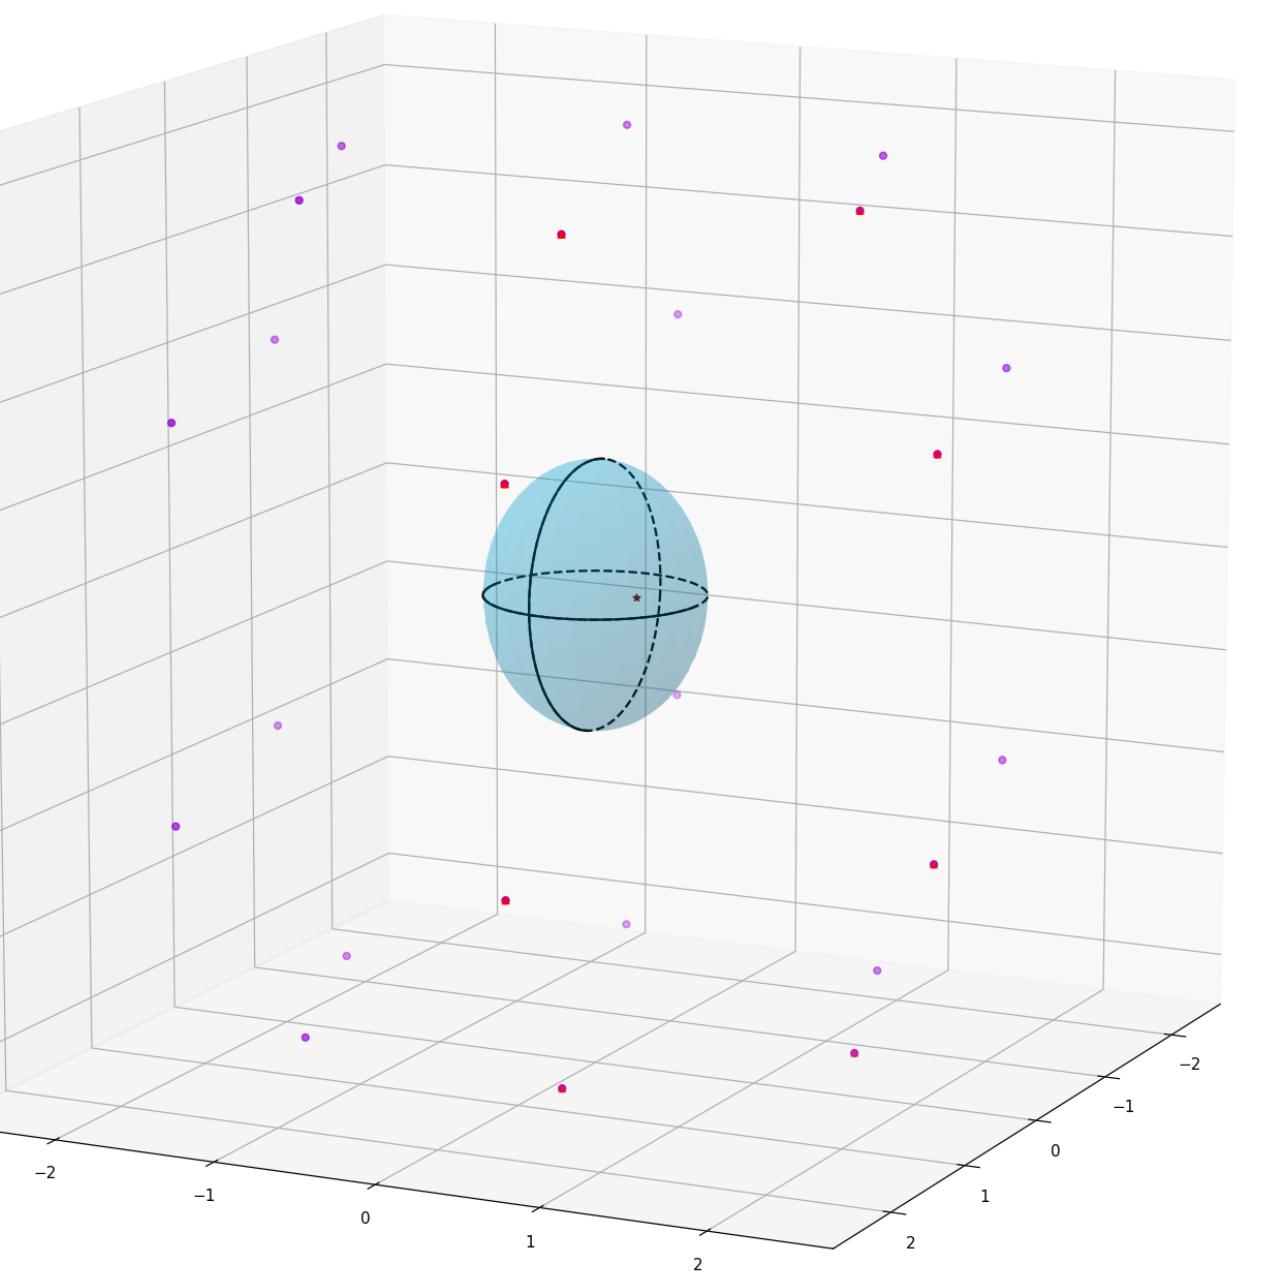


Abbildung 4: Fehler in der Positionsbestimmung in Abhängigkeit der Anz. Satelliten und dem Messfehler in der Signallaufzeit für 1000 Versuche in dem jeder Satellit mit Wahrscheinlichkeit 0.5 ausgewählt wurde. ε_t : Standardabweichung im Messfehler der Signallaufzeit.



Bei Viele Methoden zur Minimierung.
Welche ist billig



Gradientenverfahren : laufe in
der Richtung des steilsten
Abstiegs.

Hier : $\underset{\underline{x} \in \mathbb{R}^n}{\operatorname{argmin}} \underline{\Phi}(\underline{x})$ mit

$$\underline{\Phi}(\underline{x}) = \frac{1}{2} \|\underline{F}(\underline{x})\|_2^2 \quad \text{mit } \underline{F}: \mathbb{R}^n \rightarrow \mathbb{R}^m$$

steilster Abstieg: Richtung des $\operatorname{grad} \underline{\Phi}(\underline{x}) = \underline{\underline{D}\underline{F}(\underline{x})}^T \underline{F}(\underline{x})$

$$\underline{x}_{k+1} = \underline{x}_k - \lambda_k \underline{\underline{D}\underline{F}(\underline{x}^k)^T F(\underline{x}^k)}$$

grad $\underline{\Phi}(x^*)$

Schriftweite / Learning rate.

Mit S-Notation :

GD=gradient descent

(GD)

$$\left[\begin{array}{l} \underline{x}_{k+1} = \underline{x}_k - \rho \\ \text{mit } \underline{\rho} = \lambda_k \underline{\underline{D}\underline{F}(\underline{x}^k)^T F(\underline{x}^k)} \end{array} \right]$$

(a) ^{update}

$$\begin{bmatrix} \underline{x}^{k+1} = \underline{x}^k - \underline{\Delta} & \text{mit Newton-Korrektur} \\ \underline{\Delta}^T \underline{\nabla} \underline{\Phi}(\underline{x}^k) \underline{\Delta} = \underline{\nabla} \underline{F}(\underline{x}^k)^T \underline{\nabla} \underline{F}(\underline{x}^k) \end{bmatrix}$$

\hookrightarrow zu teuer für n, m Gess!

(GN) ^{update}

$$\underline{x}^{k+1} = \underline{x}^k - \underline{\Delta} \quad \text{mit GN-update:}$$

$$(\arg\min \frac{1}{2} \|\underline{F}(\underline{x}^k) - \underline{\nabla} \underline{F}(\underline{x}^k) \underline{\Delta}\|^2)$$

z.B. mit Normalengleich \underline{b}

$$\underline{\nabla} \underline{F}(\underline{x}^k)^T \underline{\nabla} \underline{F}(\underline{x}^k) \underline{\Delta} = \underline{\nabla} \underline{F}(\underline{x}^k)^T \underline{F}(\underline{x}^k)$$

minim.: BFGS: Broyden mit spezielle/schnelle Ausworb.

in J.

→ code + Bilder GD, CG

/scratch/users/gvasile/LaTeX_doc/Numcourses/NumPhys/Slides/p1_SystemsOfEquations/ch4_IterativeMethodsLSE/PYTHON

/scratch/users/gvasile/LaTeX_doc/Numcourses/NumPhys/Vorlesungen/Prepare
vizGD03.py vizGD02.py

Ben

$$\begin{aligned} \underline{\Phi}(\underline{x}) &= \frac{1}{2} (\underline{x}_1^2 + b \underline{x}_2^2) \\ \text{grad } \underline{\Phi}(\underline{x}) &= \begin{bmatrix} \underline{x}_1 \\ b \underline{x}_2 \end{bmatrix}; \quad \underline{x}^{k+1} = \underline{x}^k - \lambda \begin{bmatrix} \underline{x}_1^{(k)} \\ b \underline{x}_2^{(k)} \end{bmatrix} = \begin{bmatrix} (1-\lambda) \underline{x}_1^{(k)} \\ (1-\lambda b) \underline{x}_2^{(k)} \end{bmatrix} \end{aligned}$$

$$\Rightarrow \underline{\Phi}(\underline{x}^{(k)}) = \frac{1}{2} (\underline{x}_1^{(k)} + b(1-\lambda)^{k-1} \underline{x}_2^{(0)})$$

mit optimal gewählt λ , λ in jedem Schritt

$$\underline{x}^{(k)} = \underline{r}^k \begin{bmatrix} (-1)^k b \\ 1 \end{bmatrix} \Rightarrow \text{zick-zack!}$$

→ min. nie erreicht

$0 < b \ll 1$.

(daraus besser CG)

In Praxis beobachtet man:

GD bewegt sich am Anfang schnell gegen das Min. dann zick-zack!

GN braucht einen guten Startpunkt!

⇒ Idee: kombiniere die beiden!

$$\Rightarrow \text{LM} : \left[\underline{\nabla} \underline{F}(\underline{x}^k)^T \underline{\nabla} \underline{F}(\underline{x}^k) + \lambda \underline{I} \right] \underline{\Delta} = \underline{\nabla} \underline{F}(\underline{x}^k)^T \underline{F}(\underline{x}^k)$$

Wie beschleunigt man GD?
"CG"

Momentum-Methoden ADAM

Idee: kein Zick-Zack für schweres Ball im engen Tal!

⇒ füge Trägkeit hinzu:

$$\underline{x}^{k+1} = \underline{x}^k - \lambda \underline{z}^k \quad \text{mit } \underline{z}^k = \text{grad } \Phi(\underline{x}^k) + \beta \underline{z}^{k-1}$$

λ, β zu wählen., 2-Schritt-Methode

Umschreibe in.

$$\begin{cases} \underline{x}^{k+1} = \underline{x}^k - \lambda \underline{z}^k \\ \underline{z}^{k+1} - \text{grad } \Phi(\underline{x}^{k+1}) = \beta \underline{z}^k \end{cases}$$

(ähnlich wie bei Velocity-Verlet!)

Kunst: λ, β zu wählen (ADAM, ...)

Bsp für $\Phi(\underline{x}) = \frac{1}{2} \underline{x}^T \underline{\Sigma} \underline{x}$ mit $\underline{\Sigma}$ spd.
⇒ optimale λ, β finden.
⇒ viel schnellere Konvergenz!

Bsp Es gibt auch andere Arten GD zu beschleun.
z.B. Numerov-Verfahren.

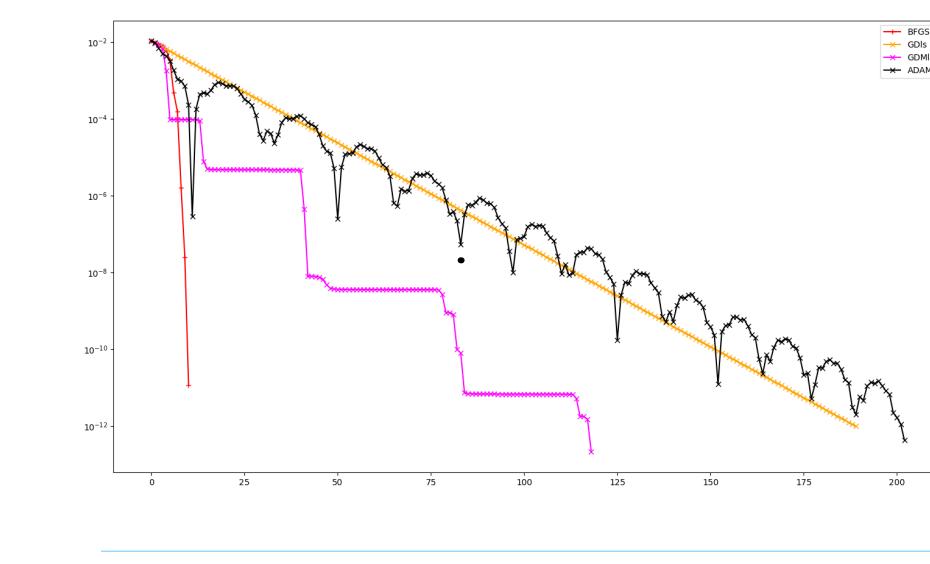
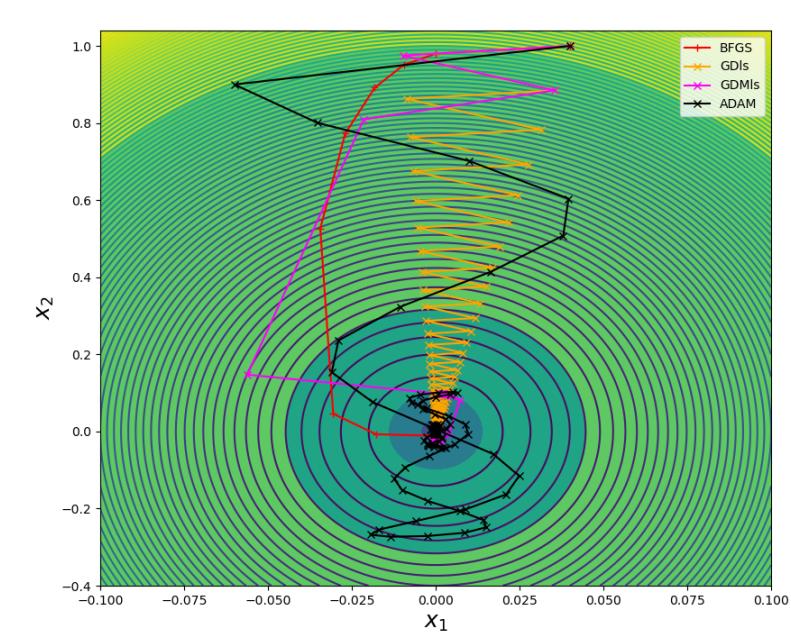
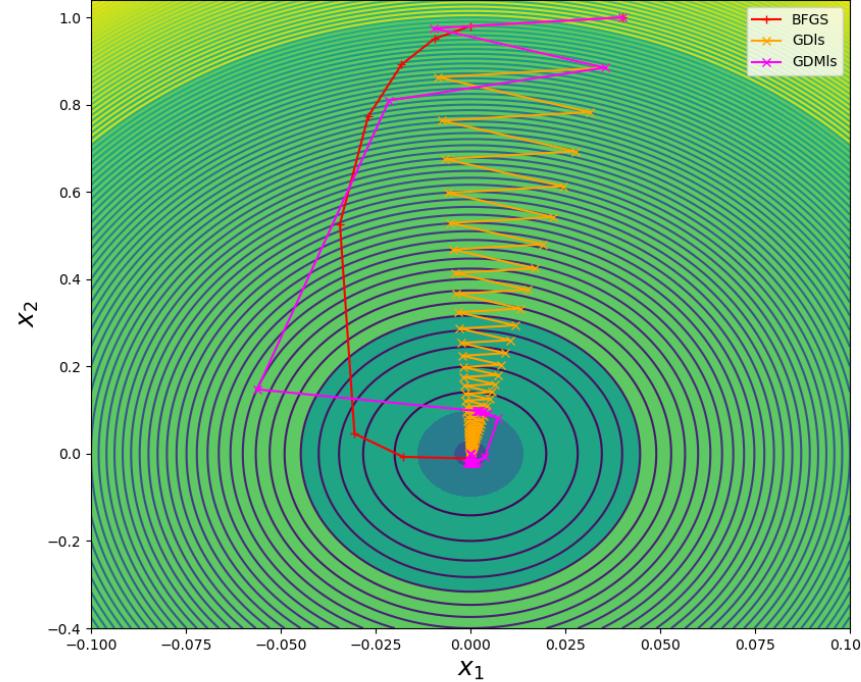
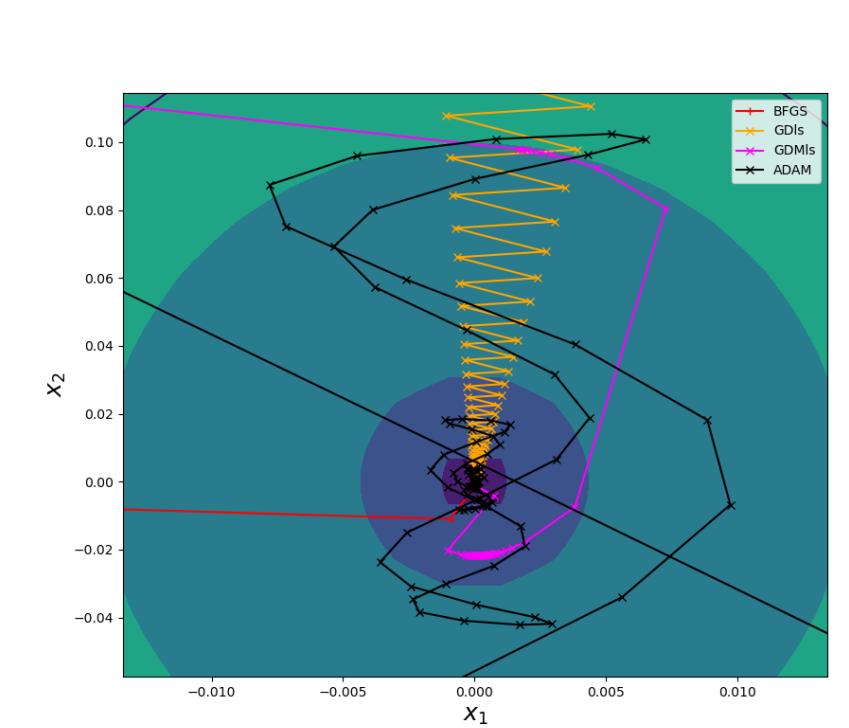
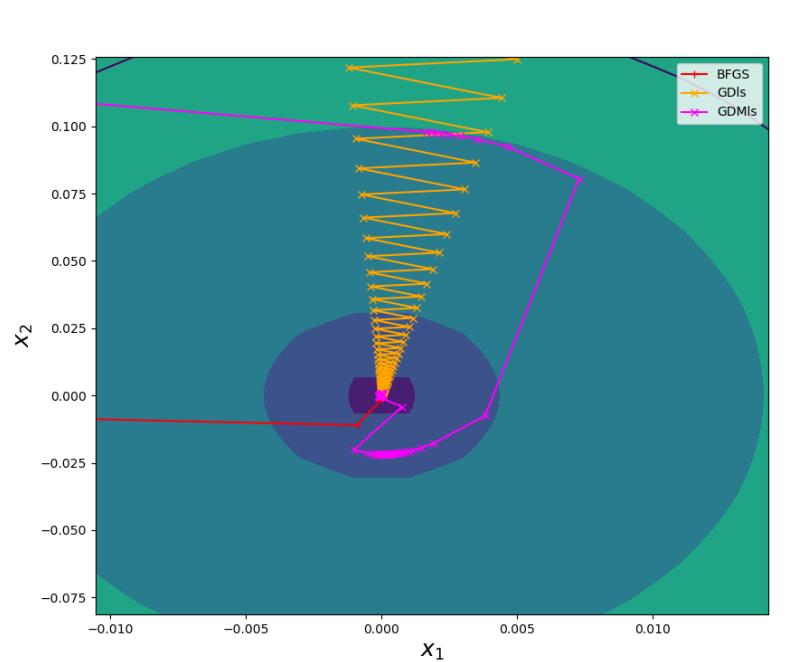
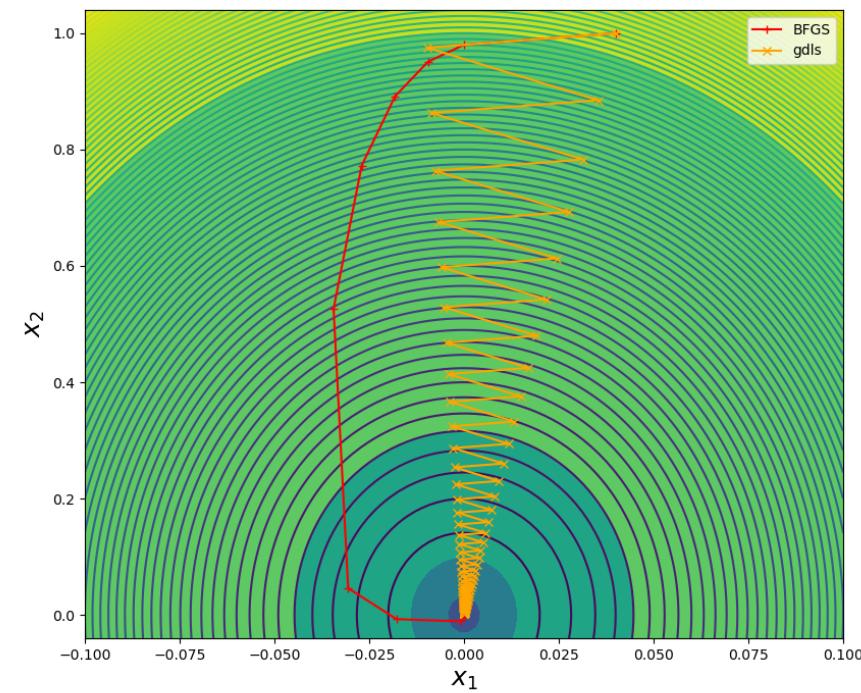
Bsp

$$1) \Phi(\underline{x}) = \frac{1}{2} (\underline{x}_1^2 + b \underline{x}_2^2), \quad b = 0.02$$

$D\Phi, D^2\Phi$ exakt, $\underline{x}_0 = \begin{bmatrix} 2 \\ b \end{bmatrix}, \underline{x}_1 = \begin{bmatrix} 0.09 \\ 1 \end{bmatrix}$

Φ billig ⇒ statt festes Schritte in 1D
nutze minimiziere für 1D
(nicht praktikabel für Φ feuer,
z.B. in ML ist Φ zufällig)

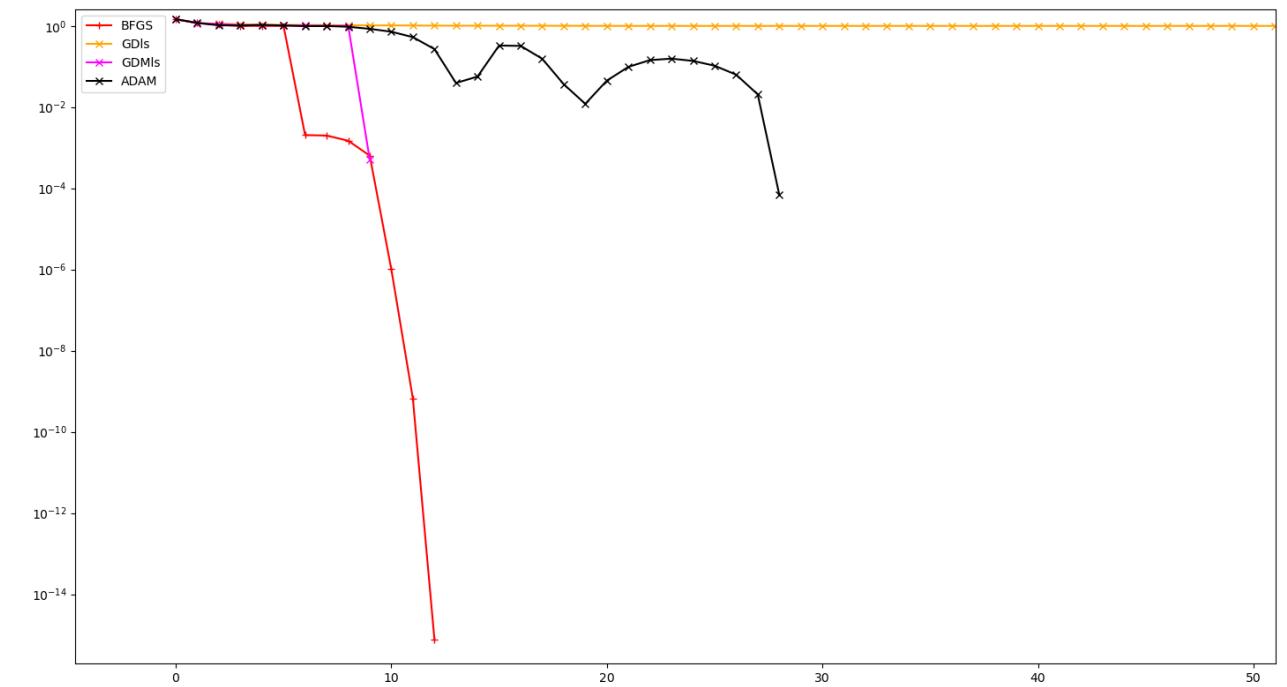
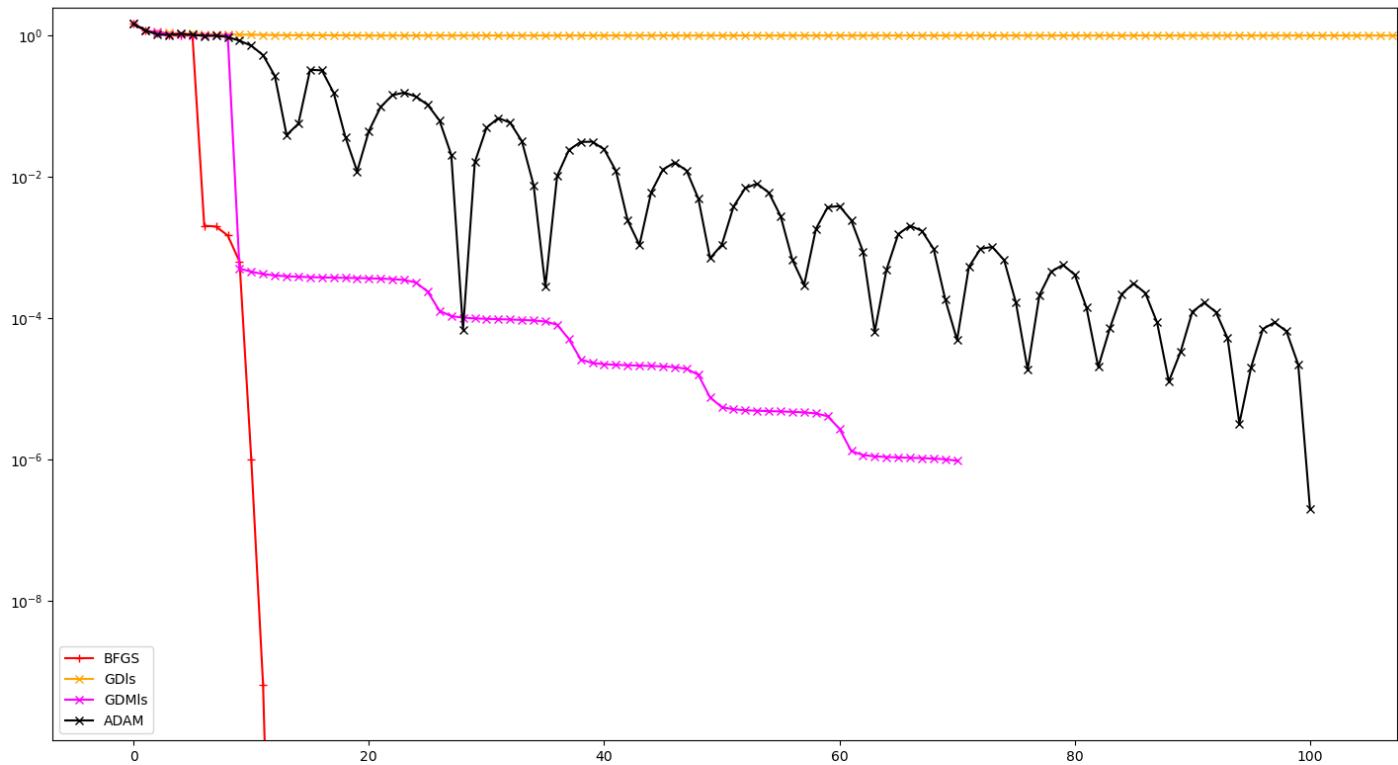
↪ feste Schritte in 1D
(learning rate)

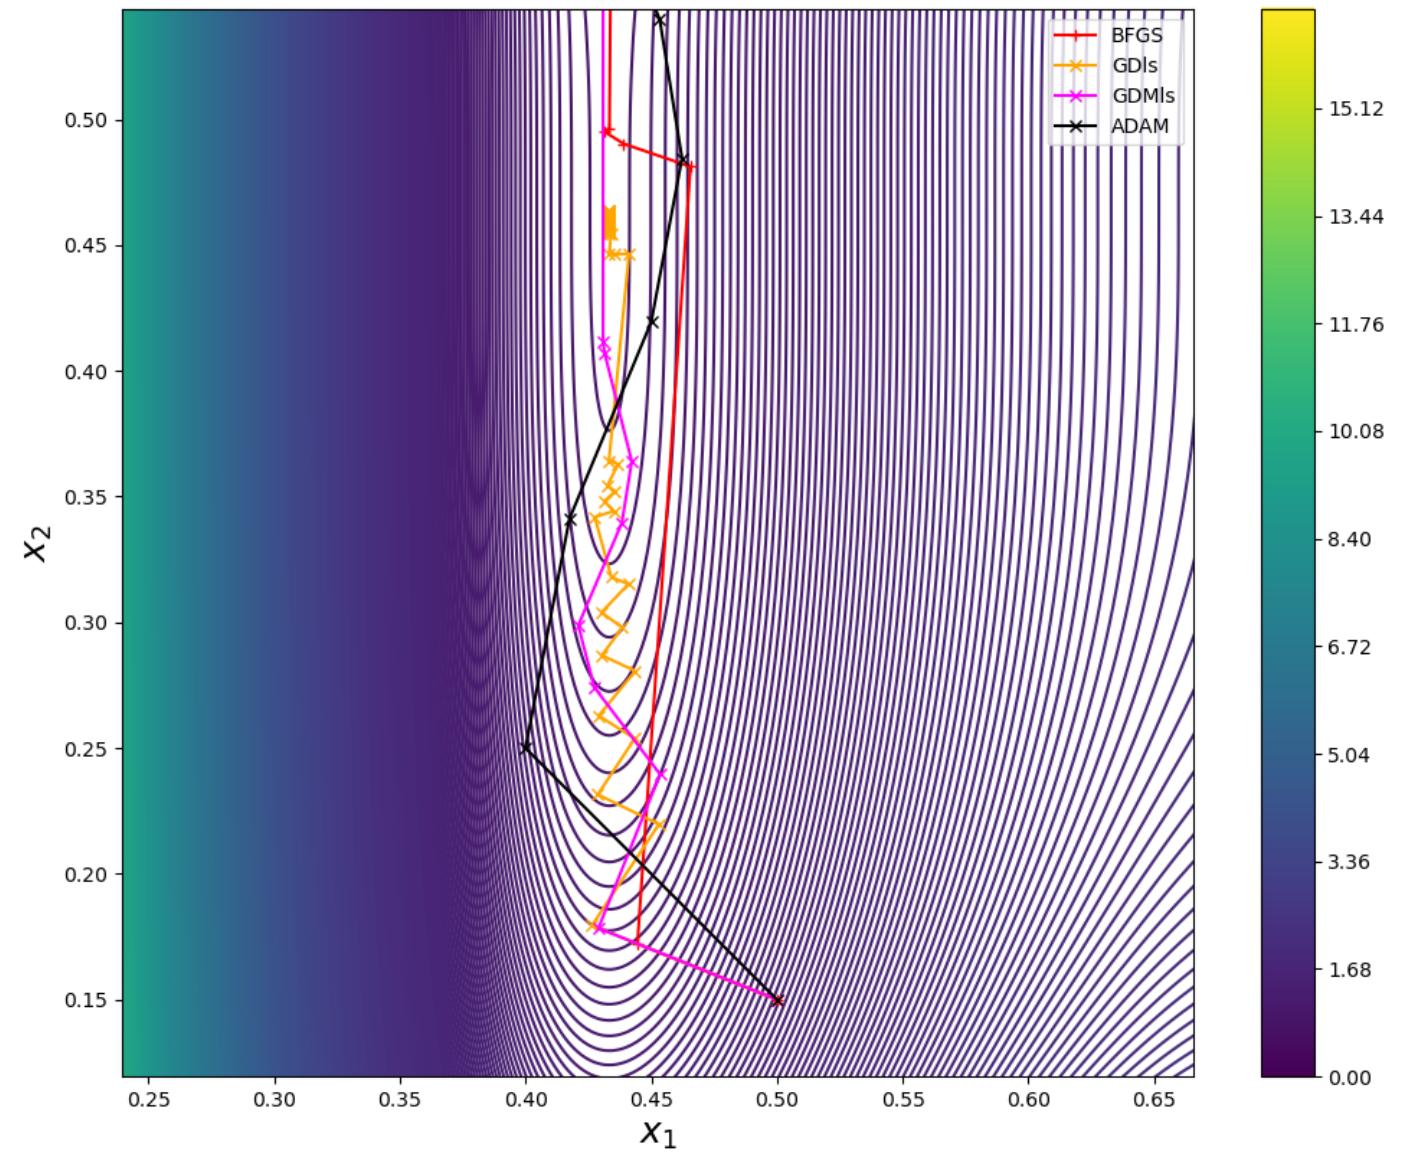
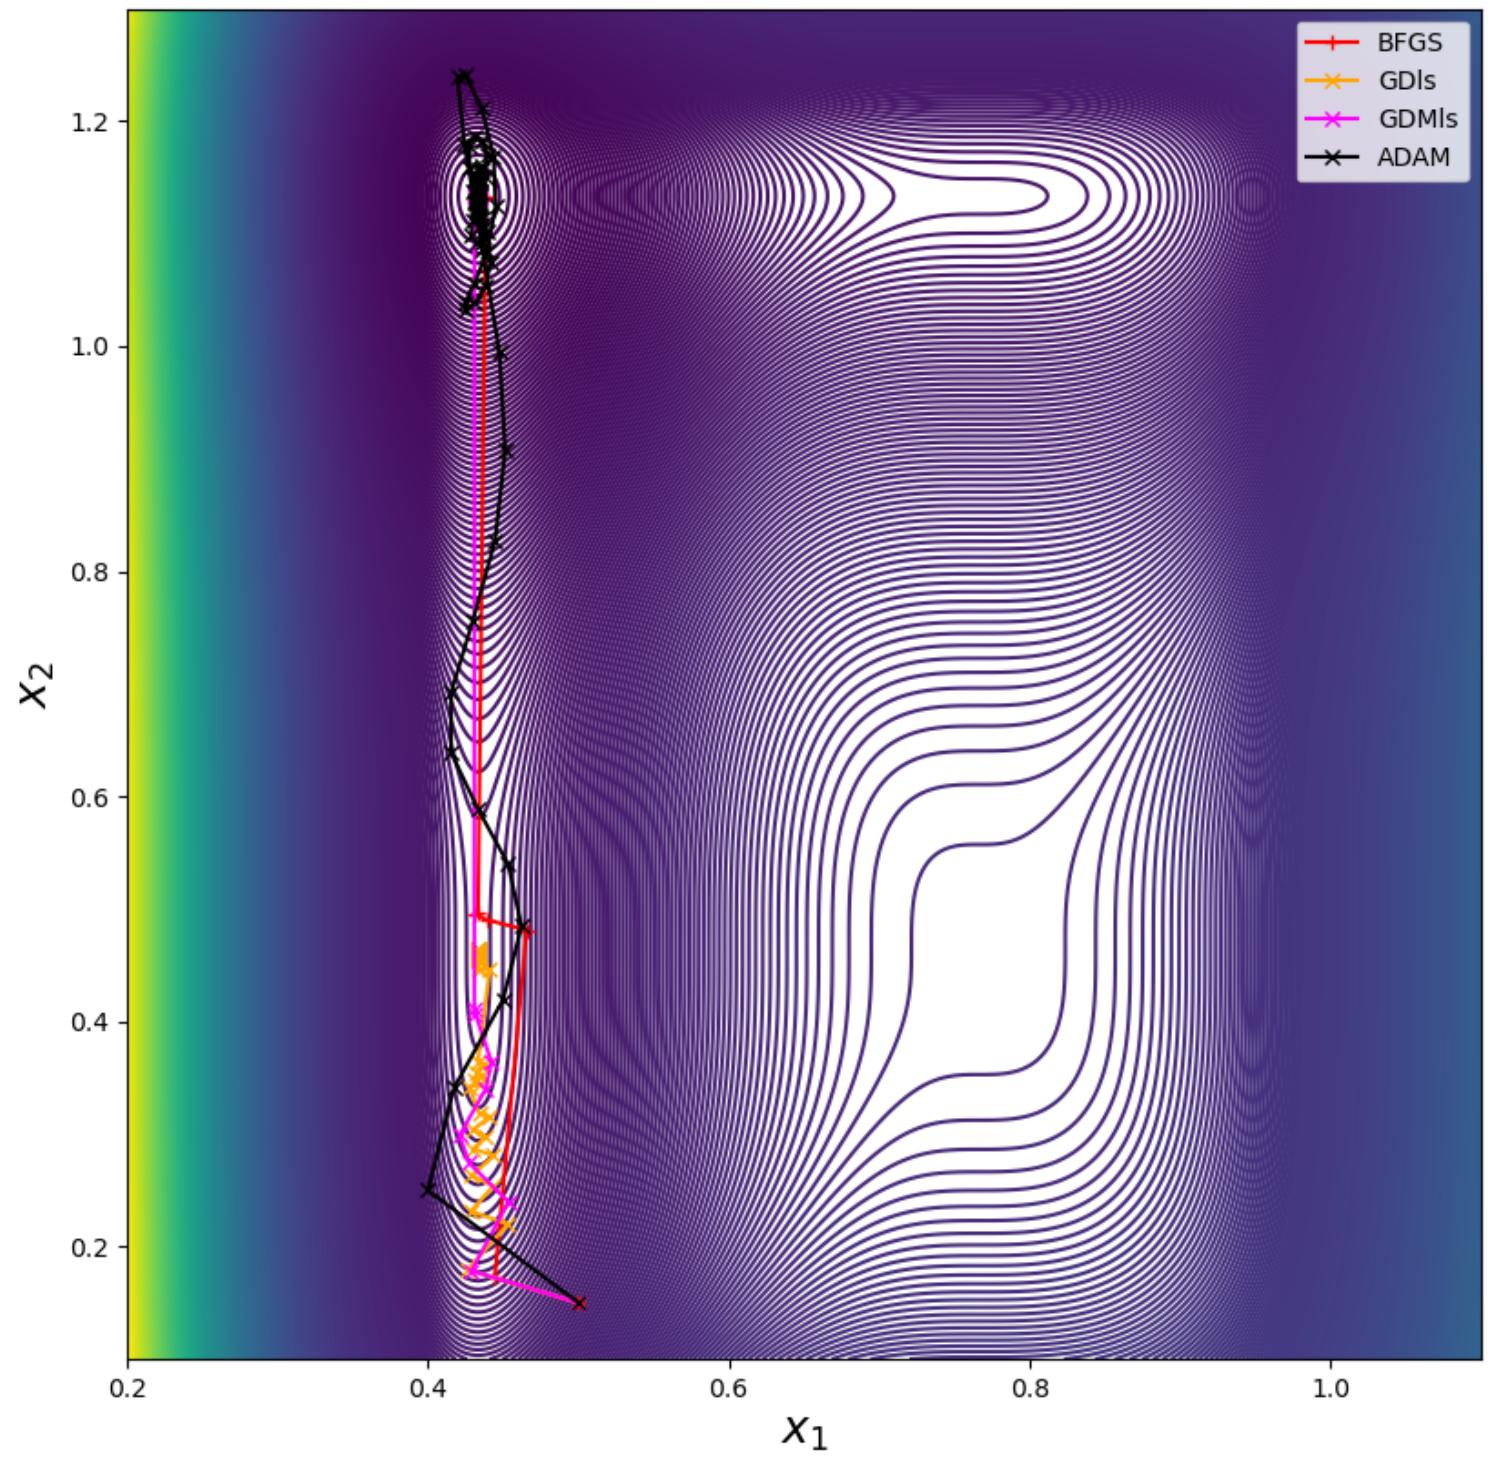


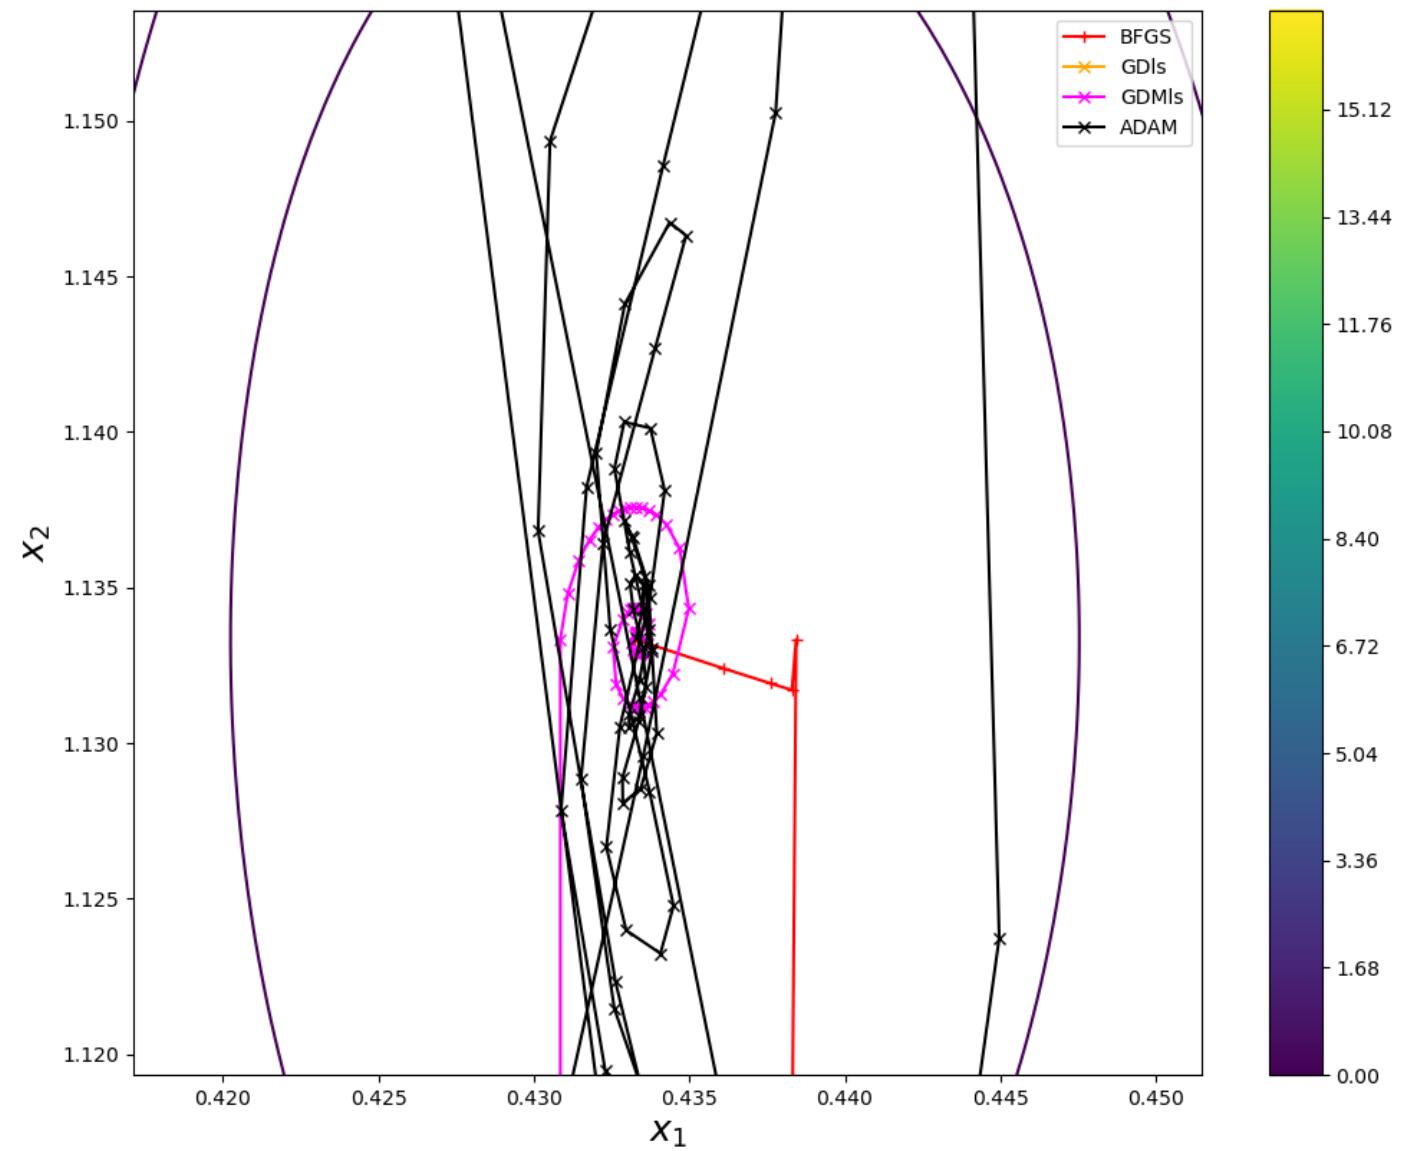
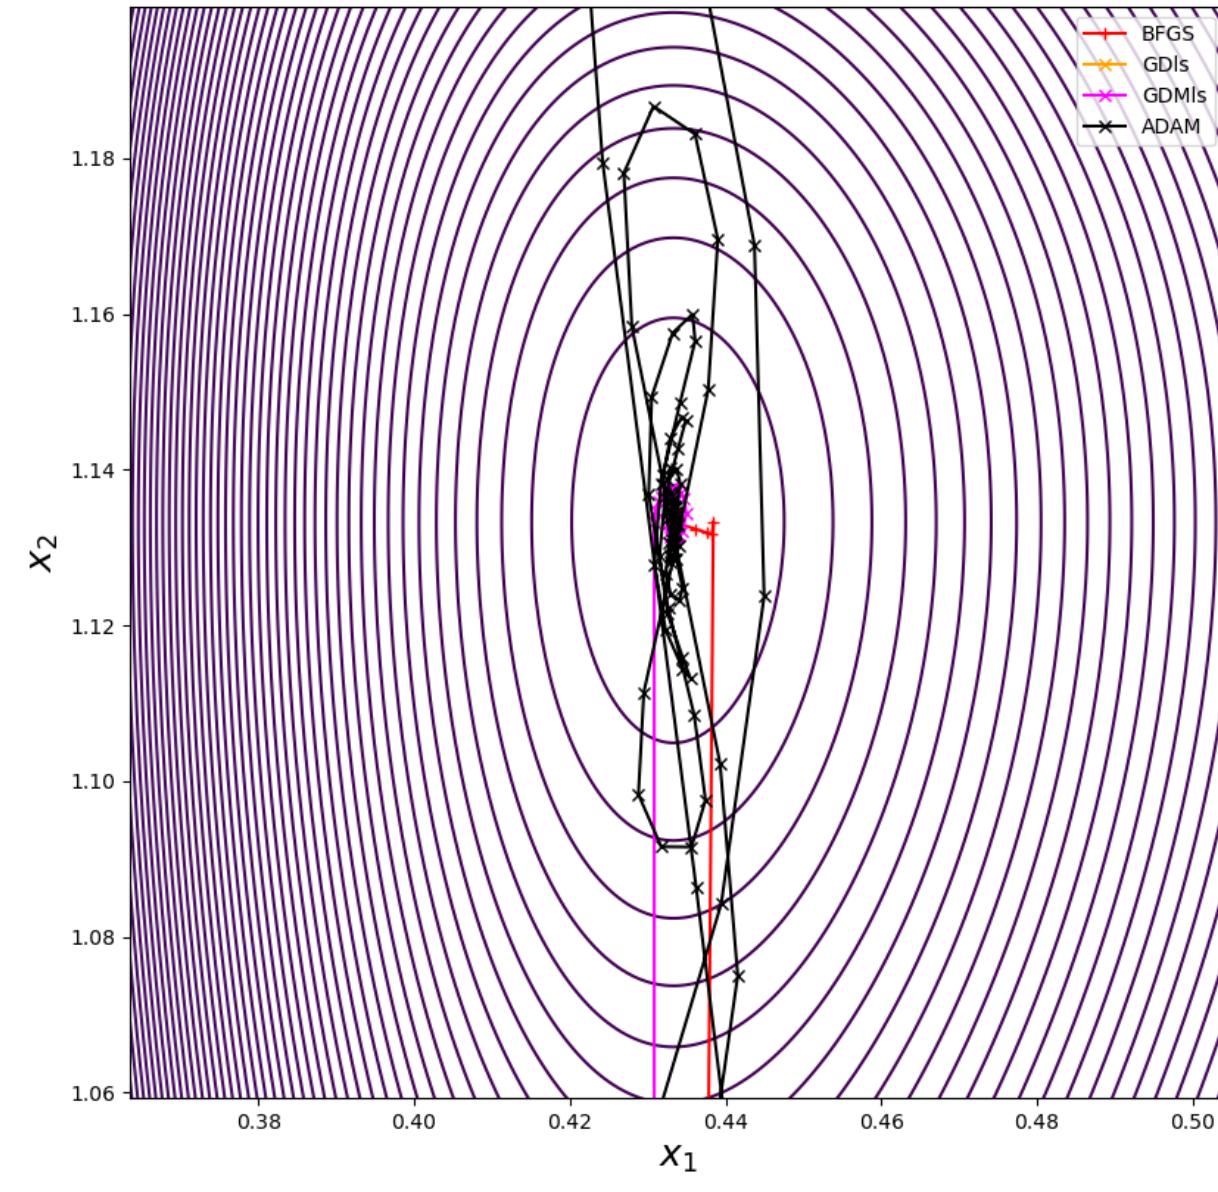
$$\text{Bsp: } \Phi(x) = (1 + (3x_1 - 2.3)^3)^2 + (1 + (0.7 - \frac{3}{2}x_2)^3)^2$$

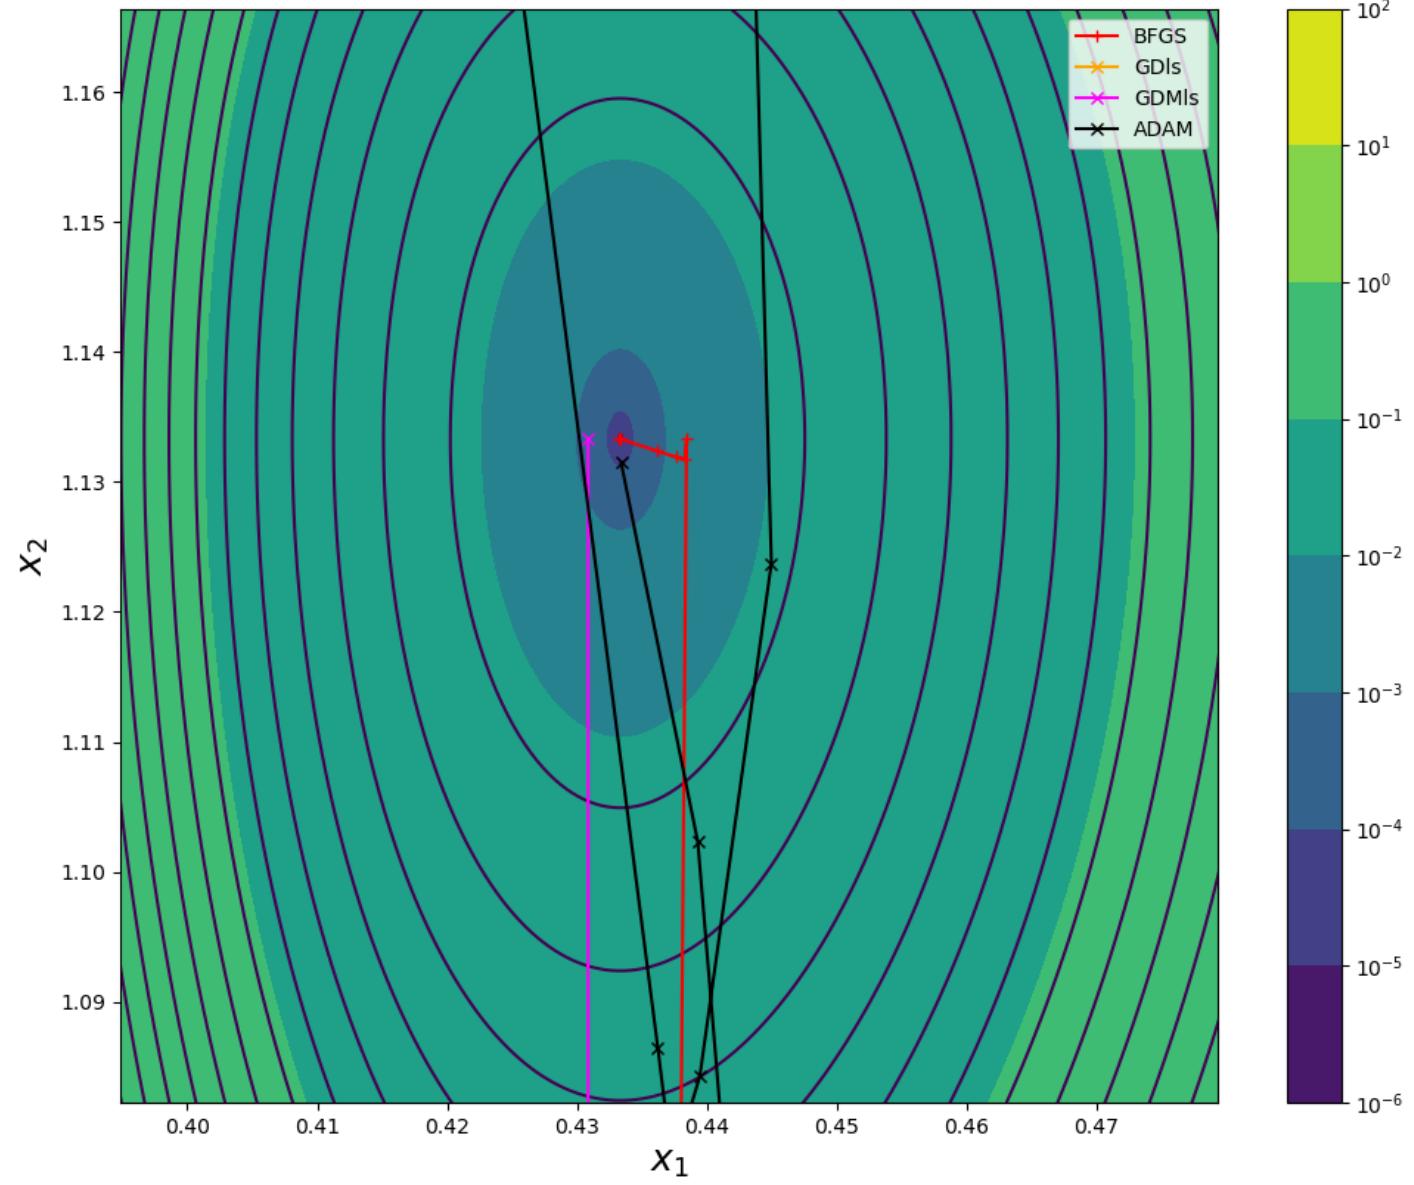
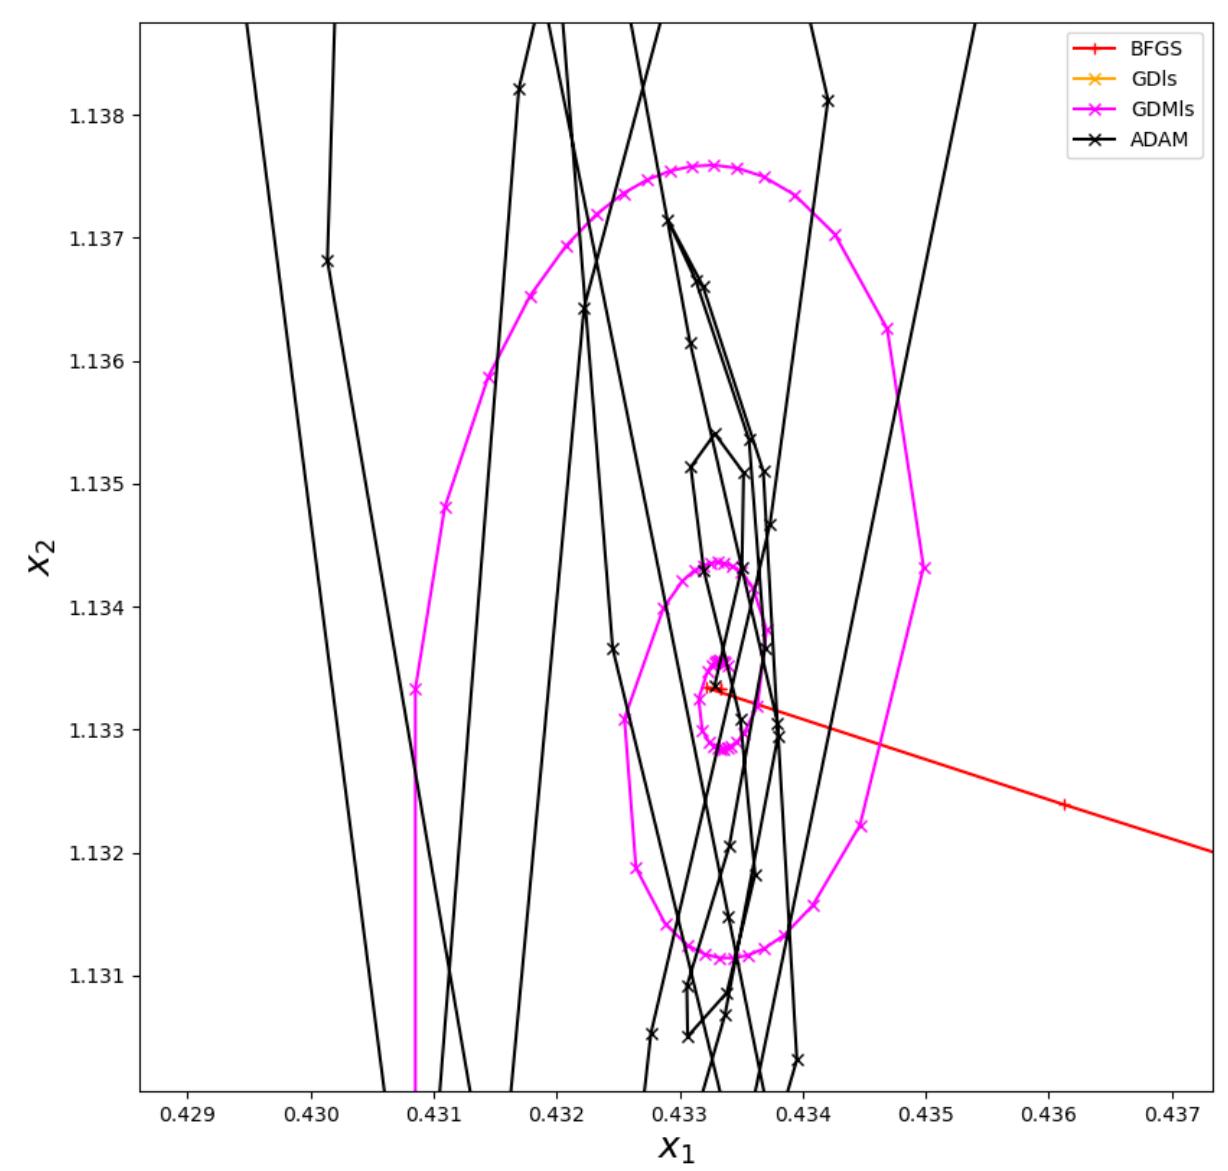
$\nabla\Phi, \nabla^2\Phi$ exakt + 1D minimizere

$$\text{TOL} = 10^{-6} \text{ oder } \text{TOL} = 10^{-2}$$









Parameter estimation aus ODE

$$(1) \quad \begin{cases} \dot{\underline{x}} = g(t, \underline{x}, \underline{u}) \in \mathbb{R}^d \\ \underline{u}(0) = \underline{u}_0 \in \mathbb{R}^d \\ \underline{x} \in \mathbb{R}^n \text{ Parameter} \end{cases} \quad \begin{array}{l} t \in \mathbb{R} \text{ Zeit} \\ \underline{x}(t, \underline{x}) \in \mathbb{R}^d \text{ Zustand} \end{array}$$

Messungen $\underline{y}_j \approx \underline{x}(t_j, \underline{x}^*)$, ..., $\underline{y}_n \approx \underline{x}(t_n, \underline{x}^*)$

Residuen $\underline{F}: \mathbb{R} \rightarrow \mathbb{R}^n$

$$\underline{F}_{(m,j)}(\underline{x}) = u_j(t_m, \underline{x}) - y_{mj}$$

$$\text{Zielfunktion: } \Phi(\underline{x}) = \frac{1}{2} \left\| \underline{F}(\underline{x}) \right\|_2^2$$

$$\Phi(\underline{x}) = \frac{1}{2} \sum_{m=1}^n \sum_{j=1}^d (u_j(t_m, \underline{x}) - y_{mj})^2$$

$$= \frac{1}{2} \sum_{m,j} F_{(m,j)}(\underline{x})^2$$

$$\text{Ziel: } \underline{x}^* = \underset{\underline{x} \in \bar{\mathcal{B}} \subseteq \mathbb{R}^n}{\arg \min} \Phi(\underline{x})$$

$$\underline{x} \in \bar{\mathcal{B}} \subseteq \mathbb{R}^n$$

↪ Bereich admissibel Parameter.

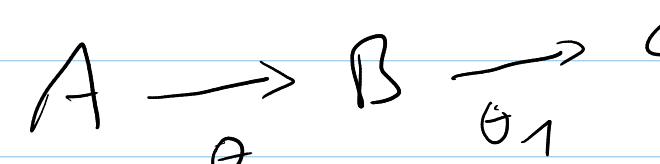
Im Prinzip: $\underline{F}(\underline{x}^*)^T \underline{F}(\underline{x}^*) \rightarrow$ ist möglich, brauche zusätzliche ODE, ist zu kompliziert
aber in Praxis funktioniert selten

Einfacher: kombiniere die starken Optimierungstools aus scipy mit ivpsolve

Achtung: für gewisse Parameter kann die ODE sehr steif sein \Rightarrow implizite Solver

$t \nearrow$
teuer!

Bsp Reaktion:



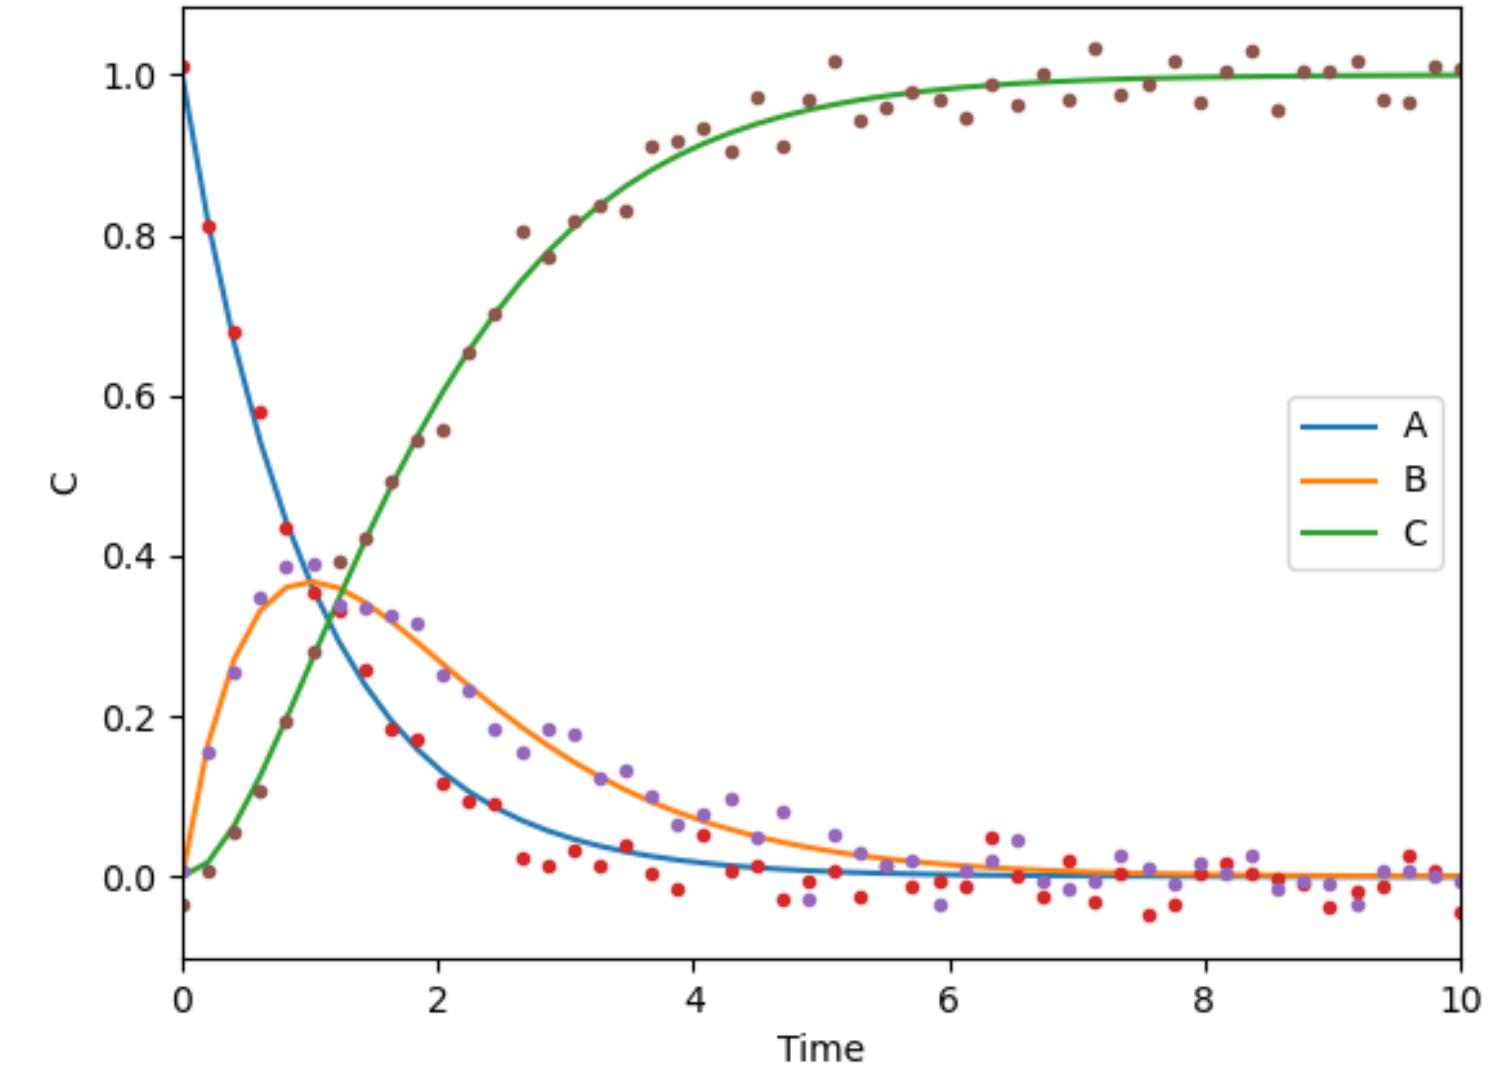
$$\underline{u} = \begin{bmatrix} c_A \\ c_B \\ c_C \end{bmatrix} \quad \dot{\underline{u}} = \begin{bmatrix} -\theta_0 & 0 & 0 \\ 0 & -\theta_1 & 0 \\ 0 & 0 & \theta_1 \end{bmatrix} \underline{u}$$

$$\underline{u}(0) = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} \quad u: [0, 10] \rightarrow \mathbb{R}_+$$

$$f(\underline{\theta}) = \underline{u}(t=10)$$

$$\underline{\theta} \approx [1, 1]; \text{ Messungen}$$

Errechnet $\underline{\theta}$ daraus



```
start optimisation
```

```
standard: BFGS
```

```
    message: Optimization terminated successfully.
```

```
success: True
```

```
status: 0
```

```
    fun: 0.08322427869240534
```

```
    x: [ 1.007e+00 1.000e+00]
```

```
    nit: 8
```

```
    jac: [ 2.557e-06 -1.062e-07]
```

```
    hess_inv: [[ 2.463e-01 -1.206e-01]
```

```
                  [-1.206e-01 3.300e-01]]
```

```
    nfev: 36
```

```
    njev: 12
```

```
-----
```

```
standard BFGS, jac = 3-point
```

```
    message: Optimization terminated successfully.
```

```
success: True
```

```
status: 0
```

```
    fun: 0.08322427869242109
```

```
    x: [ 1.007e+00 1.000e+00]
```

```
    nit: 8
```

```
    jac: [ 2.562e-06 -9.856e-08]
```

```
    hess_inv: [[ 2.463e-01 -1.206e-01]
```

```
                  [-1.206e-01 3.300e-01]]
```

```
    nfev: 60
```

```
    njev: 12
```

```
-----
```

```
tnc
```

```
    message: Converged ( $|f_n-f_{(n-1)}| \sim= 0$ )
```

```
success: True
```

```
status: 1
```

```
    fun: 0.08322427883444601
```

```
    x: [ 1.007e+00 1.000e+00]
```

```
    nit: 6
```

```
    jac: [ 1.973e-05 -1.765e-05]
```

```
    nfev: 105
```

```
-----
```

```
least_squares: standard, i.e. trf
```

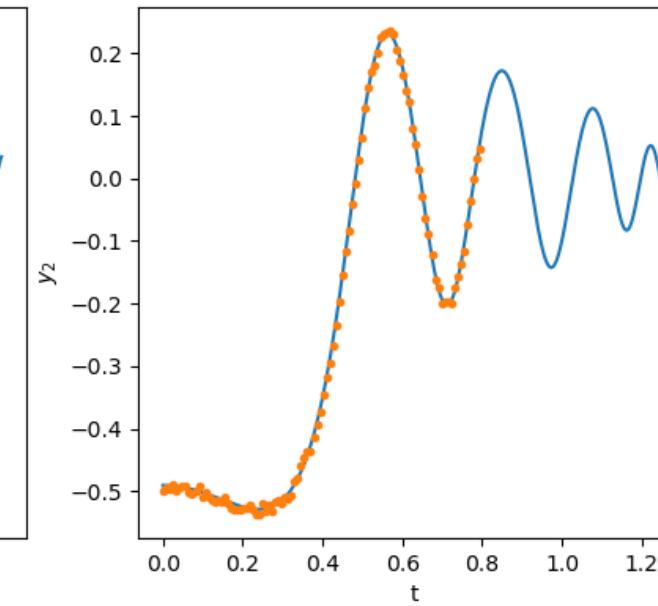
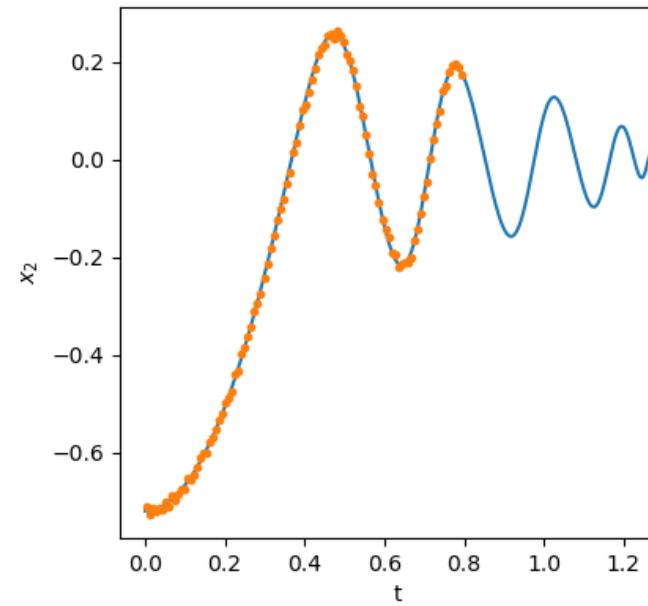
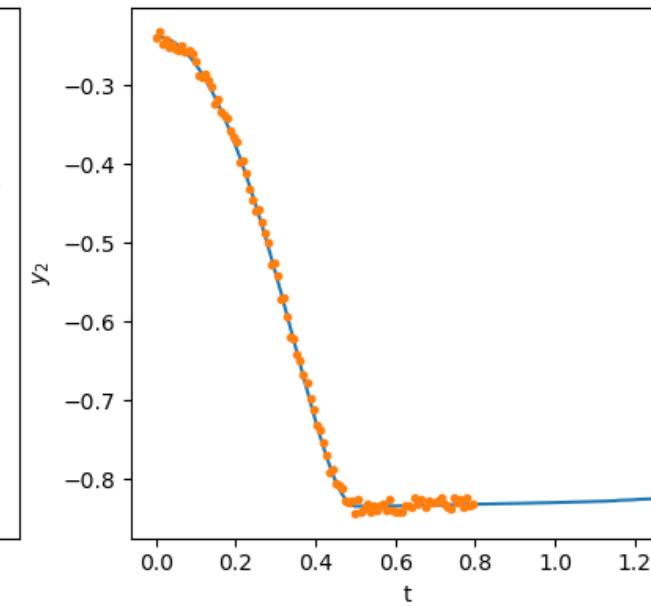
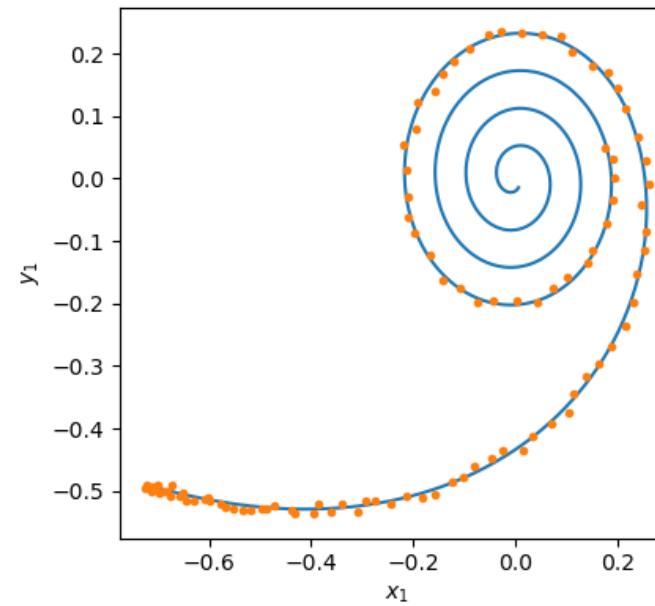
```
[1.00900421 1.02286028] `ftol` termination condition is satisfied. 24 15
```

```
-----
```

```
least_squares: lm
```

```
[1.00900588 1.02285591] `ftol` termination condition is satisfied. 60 None
```

$$\mu = 0.34, \gamma_1 = 0.001, \gamma_2 = 0.001, \alpha = 0.001$$

Trajectory of M_1 

computed till time: 1.264252850570114

start optimisation

----- brute random search with 1000 samples... -----

RuntimeWarning: invalid value encountered in scalar divide

dudt[3] = (fric*(u[1]*u[2]**2 - R*dudt[2] - g*np.cos(u[0]) - igam1/m*A*B) - R*dudt[2] - g - igam1/m*B*B)

===== brute random search gives staring point: =====

[0.33720436 0.00101525 0.00463321 0.00400535] 0.007009948080765383

run L-BFGS-B...

/usr/lib64/python3.11/site-packages/scipy/optimize/_numdiff.py:576: RuntimeWarning: invalid value

df = fun(x) - f0

standard: L-BFGS-B

message: CONVERGENCE: REL_REDUCTION_OF_F_<=_FACTR*EPSMCH

success: True

status: 0

fun: 0.007009948080765383

x: [3.372e-01 1.015e-03 4.633e-03 4.005e-03]

nit: 1

jac: [1.295e+03 -1.309e+02 1.446e+00 -5.657e-02]

nfev: 15

njev: 3

hess_inv: <4x4 LbfgsInvHessProduct with dtype=float64>

error = 0.005481623309378464

run TNC...

/scratch/users/gvasile/LaTeX_doc/Numcourses/NumPhys/Vorlesungen/Prepare/paramode04.py:46

dudt[3] = (fric*(u[1]*u[2]**2 - R*dudt[2] - g*np.cos(u[0]) - igam1/m*A*B) - R*dudt[2] - g - igam1/m*B*B)

TNC

message: Max. number of function evaluations reached

success: False

status: 3

fun: 0.006952453003604948

x: [3.372e-01 1.017e-03 4.634e-03 4.005e-03]

nit: 5

jac: [5.774e+03 2.250e+03 5.773e+03 1.276e+02]

nfev: 505

error = 0.005484330850227615

run Least Squares TRF....

least_squares: standard, i.e. trf

[0.33701153 0.00101449 0.00482116 0.00707985] `xtol` termination condition is satisfied. 16

error = 0.00777984926671802

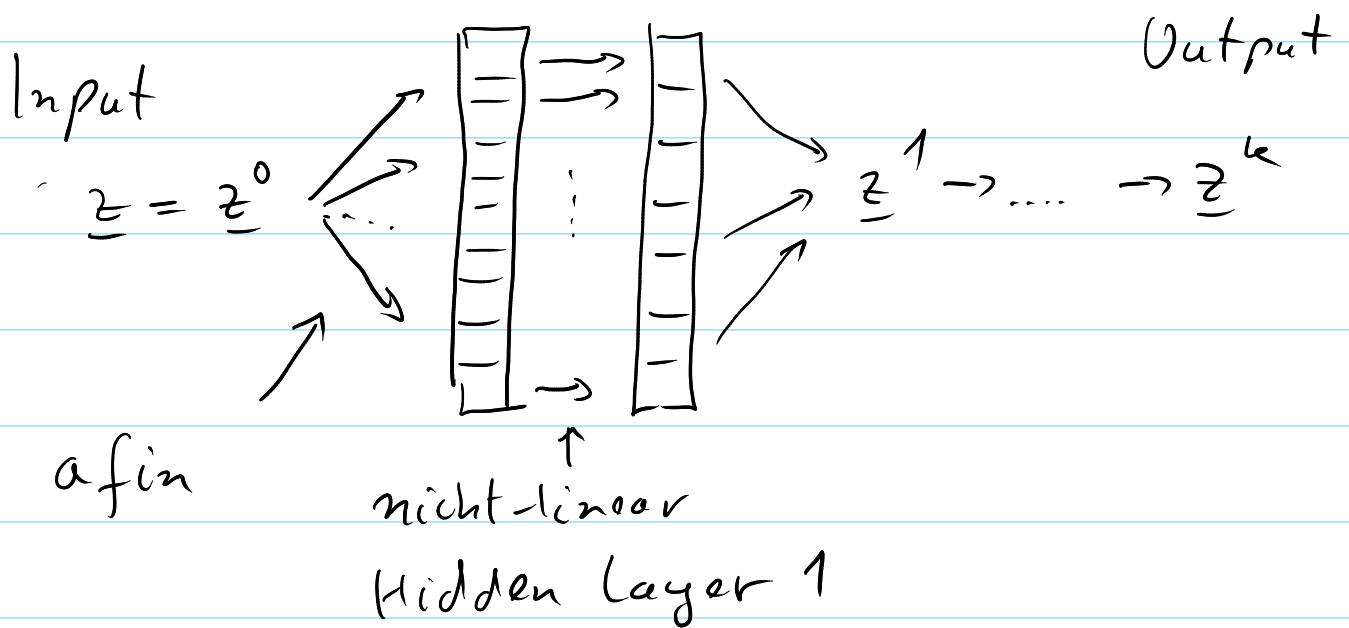
Recap:
message: CONVERGENCE: REL_REDUCTION_OF_F_<=_FACTR*EPSMCH
success: True
status: 0
fun: 0.007009948080765383
x: [3.372e-01 1.015e-03 4.633e-03 4.005e-03]
nit: 1
jac: [1.295e+03 -1.309e+02 1.446e+00 -5.657e-02]
nfev: 15
njev: 3
hess_inv: <4x4 LbfgsInvHessProduct with dtype=float64>
error = 0.005481623309378464

message: Max. number of function evaluations reached
success: False
status: 3
fun: 0.006952453003604948
x: [3.372e-01 1.017e-03 4.634e-03 4.005e-03]
nit: 5
jac: [5.774e+03 2.250e+03 5.773e+03 1.276e+02]
nfev: 505
error = 0.005484330850227615

[0.33701153 0.00101449 0.00482116 0.00707985] `xtol` termination condition is satisfied. 16 9
error = 0.007777984926671802

§ 8.7. DNNs + PINNs

DNN = Deep Neuronal Network



$$\begin{aligned} \underline{z} &\in \mathbb{R}^d && \text{Gewichte} \\ \underline{z}_1 &= \underline{z} && \swarrow \text{Bias} \\ \underline{z}_1 &= \underline{w}^1 \underline{z}_1 + \underline{b}^1 && \text{activation function} \\ \underline{z}_2 &= \sigma(\underline{w}^1 \underline{z}_1 + \underline{b}^1) \end{aligned}$$

k = Tiefe des DNNs.

$$f(\underline{z}) = c_0 c_k \sigma c_{k-1} \dots c_2 \sigma c_1(\underline{z})$$

$$W = \{\underline{w}^j, j=1, \dots, k\} \quad B = \{\underline{b}^j, j=1, \dots, k\}$$

$$\Theta = (W, B) \subset \mathbb{R}^{\sum_{j=1}^k (d_j+1) d_j} \approx 10^{11}, 10^{12}$$

Wahl der "activation function"

Wikipedia:

Name	Plot	Function, $g(x)$	Derivative of g , $g'(x)$	Range	Order of continuity
Identity		x	1	$(-\infty, \infty)$	C^∞
Binary step		$\begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x \geq 0 \end{cases}$	0	{0, 1}	C^{-1}
Logistic, sigmoid, or soft step		$\sigma(x) \doteq \frac{1}{1 + e^{-x}}$	$g(x)(1 - g(x))$	$(0, 1)$	C^∞
Hyperbolic tangent (tanh)		$\tanh(x) \doteq \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$1 - g(x)^2$	$(-1, 1)$	C^∞
Soboleva modified hyperbolic tangent (smht)		$\text{smht}(x) \doteq \frac{e^{ax} - e^{-bx}}{e^{cx} + e^{-dx}}$		$(-1, 1)$	C^∞
Rectified linear unit (ReLU) ^[10]		$(x)^+ \doteq \begin{cases} 0 & \text{if } x \leq 0 \\ x & \text{if } x > 0 \end{cases} = \max(0, x) = x \mathbf{1}_{x>0}$	$\begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x > 0 \end{cases}$	$[0, \infty)$	C^0
Gaussian Error Linear Unit (GELU) ^[2]		$\frac{1}{2}x \left(1 + \text{erf}\left(\frac{x}{\sqrt{2}}\right)\right) = x\Phi(x)$	$\Phi(x) + x\phi(x)$	$(-0.17\dots, \infty)$	C^∞
Softplus ^[11]		$\ln(1 + e^x)$	$\frac{1}{1 + e^{-x}}$	$(0, \infty)$	C^∞
Exponential linear unit (ELU) ^[12]		$\begin{cases} \alpha(e^x - 1) & \text{if } x \leq 0 \\ x & \text{if } x > 0 \end{cases}$ with parameter α	$\begin{cases} \alpha e^x & \text{if } x < 0 \\ 1 & \text{if } x > 0 \end{cases}$	$(-\alpha, \infty)$	$\begin{cases} C^1 & \text{if } \alpha = 1 \\ C^0 & \text{otherwise} \end{cases}$
Scaled exponential linear unit (SELU) ^[13]		$\lambda \begin{cases} \alpha(e^x - 1) & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases}$ with parameters $\lambda = 1.0507$ and $\alpha = 1.67326$	$\lambda \begin{cases} \alpha e^x & \text{if } x < 0 \\ 1 & \text{if } x \geq 0 \end{cases}$	$(-\lambda\alpha, \infty)$	C^0
Leaky rectified linear unit (Leaky ReLU) ^[14]		$\begin{cases} 0.01x & \text{if } x \leq 0 \\ x & \text{if } x > 0 \end{cases}$	$\begin{cases} 0.01 & \text{if } x < 0 \\ 1 & \text{if } x > 0 \end{cases}$	$(-\infty, \infty)$	C^0
Parametric rectified linear unit (PReLU) ^[15]		$\begin{cases} \alpha x & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases}$ with parameter α	$\begin{cases} \alpha & \text{if } x < 0 \\ 1 & \text{if } x \geq 0 \end{cases}$	$(-\infty, \infty)$	C^0
Sigmoid linear unit (SiLU) ^[2] Sigmoid shrinkage, ^[16] SiL ^[17] or Swish-1 ^[18]		$\frac{x}{1 + e^{-x}}$	$\frac{1 + e^{-x} + xe^{-x}}{(1 + e^{-x})^2}$	$[-0.278\dots, \infty)$	C^∞
Gaussian		e^{-x^2}	$-2xe^{-x^2}$	$(0, 1]$	C^∞

Supervised Learning

Zielfunktion

$$f: \mathbb{R}^d \rightarrow \mathbb{R}$$

$$\underline{y}_i \Rightarrow f(\underline{y}_i) + \text{Rausch} = \underline{f}_i$$

Trainingsmengen

$$\mathcal{T} = \{ \underline{y}_n \in \mathbb{R}^d, n=1, \dots, M \}$$

Finde $\theta \in \Theta \subset \mathbb{R}^{\sum_{j=1}^k (d_j + 1) d_j}$ so dass $f^*(\theta) \approx f$

$$\Theta = \{ \underline{w}_1, b_1, \underline{w}_2, b_2, \dots, \underline{w}_k, b_k \}$$

+ stetige aber stückweise lineare Funktionen
 \Rightarrow viele Parameter möglich, leicht zu berechnen

+ Nacheinanderausführung \Rightarrow deep network

Loss: $\mathcal{J}(\theta) = \frac{1}{N} \sum_{m=1}^M \| f_{\theta}(y_m) - f_{\theta}^*(x_m) \|_p^p$
 $1 \leq p < \infty$

$p=2 \Rightarrow$ Methode der kleinsten Quadrate

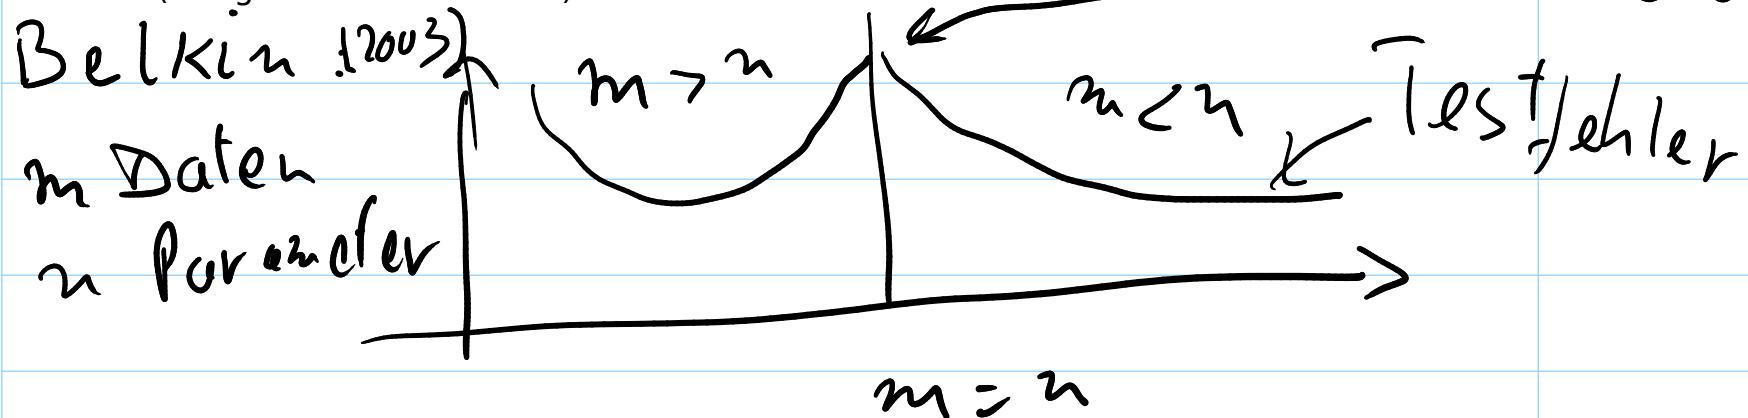
$p=1 \Rightarrow$ "sparse" / dann losetze Dantzig.

Solve minimize \Rightarrow "trained NN": θ
 verwende $f_{\theta}^*(y)$ für neue y .
 \Rightarrow neue Werte.

Bem.:
 ML funktioniert am besten, wenn das Problem **unterdeterminiert** ist
 ML funktioniert gar nicht, wenn das Problem überdeterminiert ist: overfitting!

Kunst von K.I.= aus der grossen Menge möglicher Lösungen finde eine,
 die sich auf neue Daten/messungen sich verallgemeinern lässt

2012: ImageNet: 1.2 Millionen Bilder; AlexNet verwendete 60 Millionen Gewichte!
 (5 Tage GradientDescend)



Schlüsselideen für DNNs:

- + Nacheinanderausführung (go deep)
- + Kettenregel (Ableitungen nach Parameter sind möglich)
- + Stochastik Gradient Descend
- + Backpropagation (schnelle Kettenregel)
- + Nichtlinearität der Aktivierungsfunktion

$$F_k(z) = \sigma(w^k z + b^k) = \sigma(c_k)$$

$$f(z) = \sigma c_k \circ c_{k-1} \circ \dots \circ c_1 = F_k(F_{k-1} \circ \dots \circ F_1(z))$$

$$\text{Parameter: } w^1, b^1, \dots, w^k, b^k$$

$$\sigma(z) = \text{ReLU}(z)$$

Ziel: Klassifizierung:

Hund \rightarrow Kaffe
 anfahrendes Auto/Zug
 weg fahrendes Auto/Zug

Backpropagation:

Kettenregel: $\frac{\partial F}{\partial \theta} = \frac{\partial F_k}{\partial F_{k-1}} \frac{\partial F_{k-1}}{\partial F_{k-2}} \dots \frac{\partial F_1}{\partial \theta}$

\Rightarrow Schelle n^2 -Operationen
 (von rechts nach links
 wie n^3 Operationen!
 da Matrix \times Matrix!)

Bei $\frac{\partial F}{\partial \theta_j}$ verwendet nur $\theta_j, \theta_{j+1}, \dots, \theta_k$

Notiere $\ell = (f - F(\theta, y))^\top (f - F(\theta, y))$

1. Idee:

$$\frac{\partial \ell}{\partial F} = 2(f - F(\theta, y)) \text{ vector}$$

$$\underline{M}_k = \frac{\partial F_k}{\partial F_{k-1}} \text{ Matrix}$$

$$\frac{\partial \ell}{\partial \theta_j} = \left(\left(\frac{\partial \ell}{\partial F} \underline{M}_k \right) \underline{M}_{k-1} \dots \underline{M}_{j+1} \right)$$

$\square = n^2$ Operationen

2. Idee: verwendet die Vorarbeit

$$\frac{\partial \ell}{\partial F_k} \text{ für alle } j \leq k$$

Aly:

Forward (Initialisierung)

 $\underline{y} \mapsto \text{speichere } \bar{F}_j := \sigma g_j$ für $j = k, k-1, \dots, 1$:

$$\frac{\partial \ell}{\partial b_j} = \frac{\partial \ell}{\partial \bar{F}_j} \frac{\partial \bar{F}_j}{\partial b_j}$$

$$\frac{\partial \ell}{\partial w_j} = \frac{\partial \ell}{\partial \bar{F}_j} \frac{\partial \bar{F}_j}{\partial w_j}$$

↑ Speicher

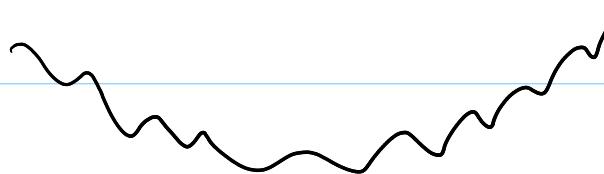
falls $j \neq 1$:

$$\frac{\partial \ell}{\partial \bar{F}_{j-1}} = \frac{\partial \ell}{\partial F_j} \frac{\partial F_j}{\partial \bar{F}_{j-1}}$$

Keras; Tensorflow; Pytorch

Optimierung

\mathcal{J} nicht konvex aber diff_{bar} (leicht zu berechnen)



↑
automatisch.

Gradientenverfahren

Für $l=0, 1, 2, \dots$:

$$\theta_{l+1} = \theta_l - \eta_l \text{grad}_{\theta} \mathcal{J}(\theta_l)$$

$\eta_l \ll 1$

↳(adaptiv) learning rate

konvergiert zu einer lokalen Minima.

$$\text{grad}_{\theta} \mathcal{J}(\theta_l) = \frac{1}{n} \sum_{m=1}^n \text{grad}_{\theta} \mathcal{J}_m(\theta_l)$$

$$\mathcal{J}_m(\theta_l) = (f(y_m) - f_{\theta_l}(y_m))^2$$

$n =$ sehr gross \neq Speicher
 \neq Zeit

↑
steepest descent

Stochastic Gradient



1-SG

Im l -ten Schritt θ_l gesetzt.

wähle $m_l \in \{1, \dots, n\}$ zufällig.

$$\theta_{l+1} = \theta_l - \eta_l \text{grad}_{\theta} \mathcal{J}_{m_l}(\theta_l)$$

n-SG

$\mathcal{I} = \cup \mathcal{I}_j$, $\#\mathcal{I}_j = n$ und $\frac{1}{n}$ Untergruppen.
↳ Batches der Länge n

Im l -ten Schritt:

$$\theta_{l+1} = \theta_l - \eta_l \sum_{m \in \mathcal{I}_j} \text{grad}_{\theta} \mathcal{J}_m(\theta_l)$$

$\mathcal{I}_1, \mathcal{I}_2, \dots, \mathcal{I}_{\frac{n}{M}}$ Batches

Ein durchlauf allen Batches = 1 Epoch
Dann Batches umordn. (zufällig)

Methoden: GD, ADAM, SGD, AdaGrad, GDM, RMSProp, etc.

L-BFGS-R 2. Ordnung, kann mit Batches arbeiten aber meistens zu teuer

PLAN = Physical instructed Neural Network.

Theorem Gegeben $\varepsilon > 0$ gibt es ein NN $f^* = f_{\theta^*}$
mit $\theta^* \in \Theta \subseteq \mathbb{R}^d$ so dass,

$$\|f - f^*\|_X < \varepsilon$$

"Approximationseigenschaft der NN"
F = stetig. kein Polygon!

→ kein Hinweis auf Konstruktion. 

$$\dot{u} = g(t, u)$$

$$u \approx u_\theta$$

Trainingszyklus

$$\mathcal{T} = \{t_1, t_2, \dots, t_M\}$$

Testzyklus

$$\tilde{\mathcal{T}} = \{\tilde{t}_1, \tilde{t}_2, \dots, \tilde{t}_N\}$$

$$R_T(t_i) = u_\theta(t_i) - u_i \quad \text{Knotenpunkte}$$

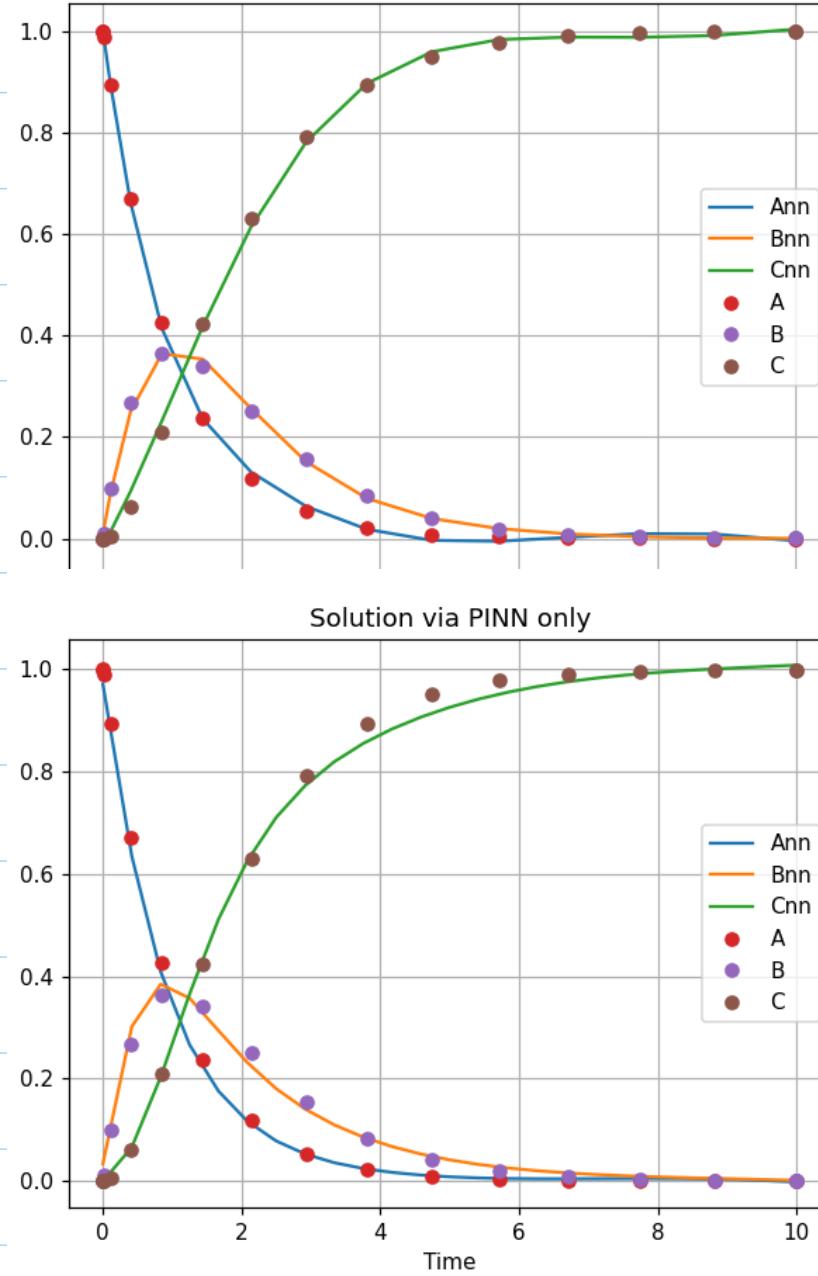
$$R_D(\tilde{t}_i) = \underbrace{u_\theta(\tilde{t}_i)}_{\text{auch automatisch berechn.}} - g(\tilde{t}_i, u_\theta(\tilde{t}_i))$$

$$\mathcal{J}(\theta) = \frac{1}{M} \sum_{m=1}^M R_T(t_m)^2 w_m + \frac{1}{N} \sum_{j=1}^N R_D(\tilde{t}_j) \tilde{w}_j$$

$$\Theta \vdash \min \mathcal{J}(\theta) \Rightarrow u_{\theta^*}(t)$$

$i = g(t, u, \mu)$ noch μ auch optimieren!

NN learned the solution given by solve_ivp



A NN can learn the solution...
 Solve the ODE with a PINN using adam
 Iteration 0 objective 4.901094881441509
 Iteration 100 objective 0.6899595433185512
 Iteration 200 objective 0.5256140910911087
 Iteration 300 objective 0.30172420828432256
 Iteration 400 objective 0.06713165176847836
 Iteration 500 objective 0.020769341937793753
 0.2 minutes elapsed this time. Total time = 0.19 min. Total epochs = 501.

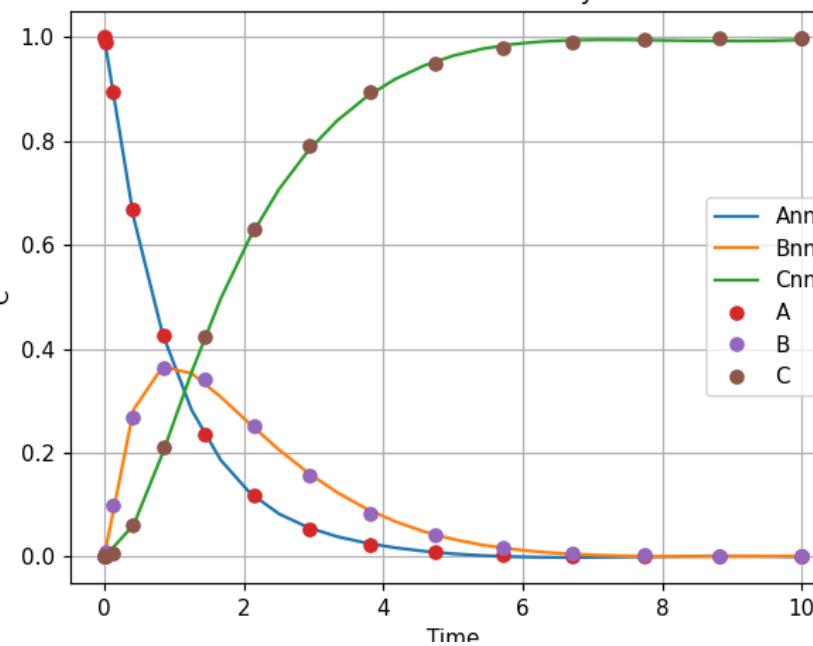
Layer: [1, 8, 3], lr = 10^{-2}

[1, 8, 3], lr = 10^{-3}

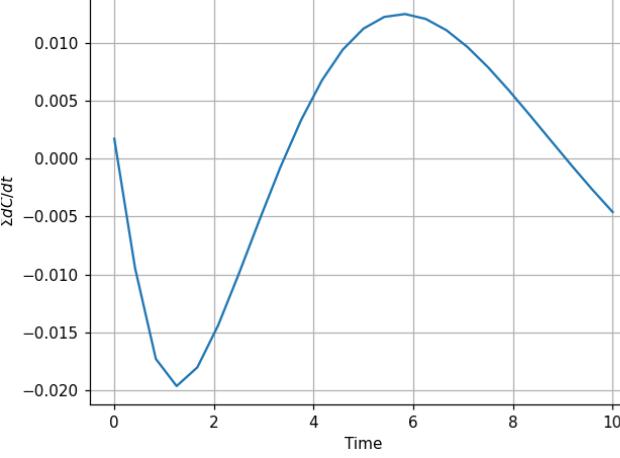
5000 steps

500 steps

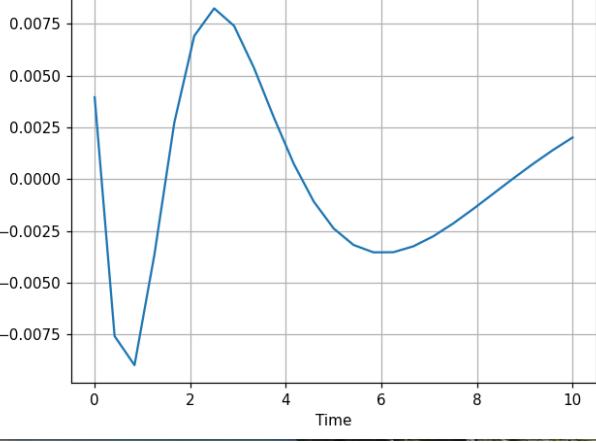
Solution via PINN only



Sum of the derivatives should be 0



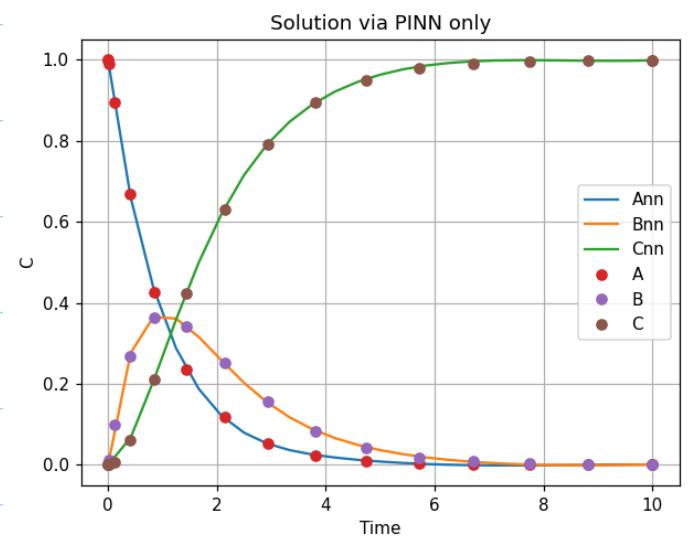
Sum of the derivatives should be 0



python onlyautograd02.py

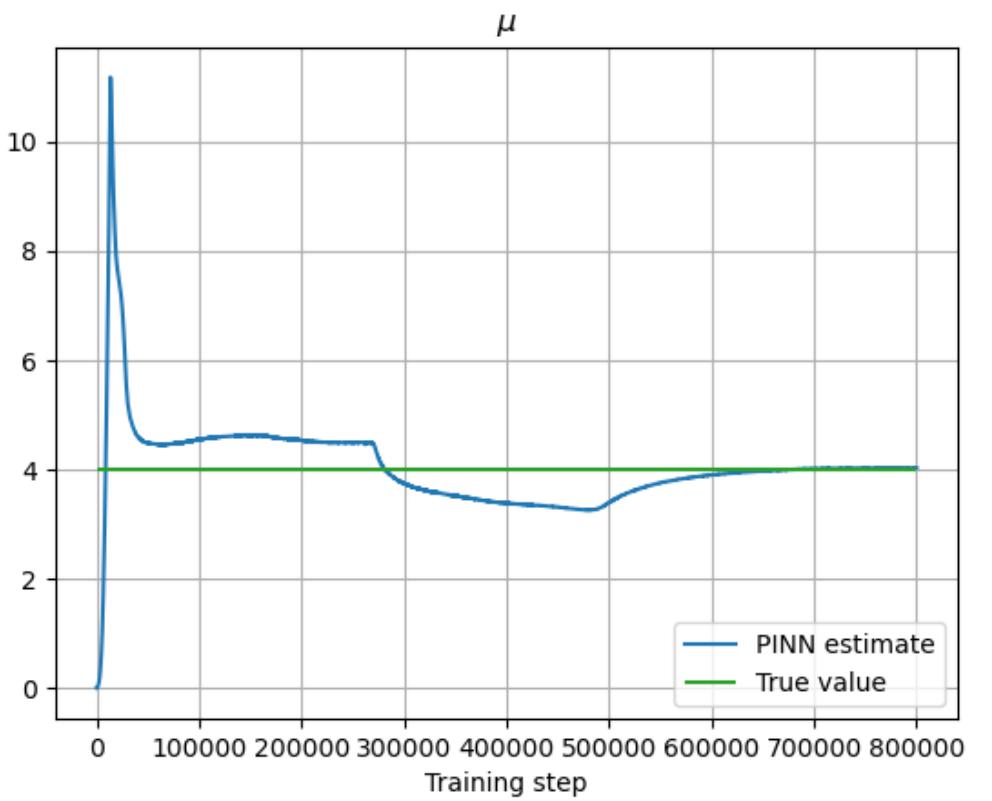
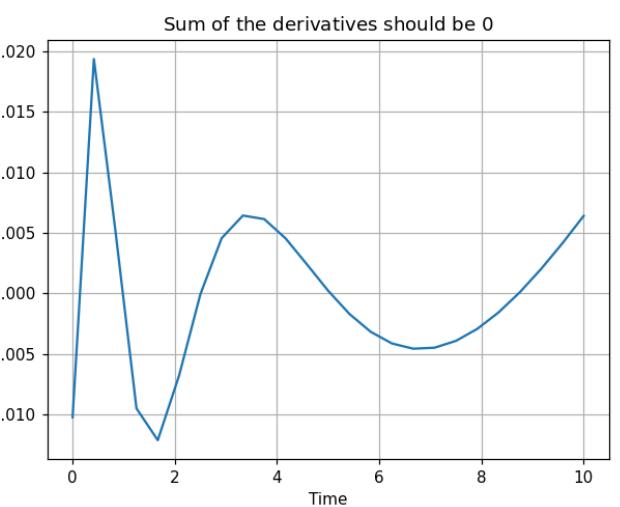
```

Iteration 2300 objective 0.21837992273256943
Iteration 2400 objective 0.15067501923377044
Iteration 2500 objective 0.10750242875475156
Iteration 2600 objective 0.08290887034465583
Iteration 2700 objective 0.06843241704758321
Iteration 2800 objective 0.05949095869641032
Iteration 2900 objective 0.053362240536638864
Iteration 3000 objective 0.048461984808600256
Iteration 3100 objective 0.044106230164504705
Iteration 3200 objective 0.040059307858911604
Iteration 3300 objective 0.03624299672367966
Iteration 3400 objective 0.03262181017619072
Iteration 3500 objective 0.029170944087145
Iteration 3600 objective 0.025872821077357253
Iteration 3700 objective 0.022721699315778818
Iteration 3800 objective 0.01972928511329969
Iteration 3900 objective 0.016927537127111775
Iteration 4000 objective 0.014364117294925314
Iteration 4100 objective 0.012086484009305466
Iteration 4200 objective 0.010119205240268183
Iteration 4300 objective 0.008452583236811351
Iteration 4400 objective 0.007054863163250895
Iteration 4500 objective 0.005891236235982176
Iteration 4600 objective 0.004930063096682349
Iteration 4700 objective 0.00414238843457355
Iteration 4800 objective 0.0035023909476854915
Iteration 4900 objective 0.0029875362493808344
Iteration 5000 objective 0.0025780349882505854
2.0 minutes elapsed this time. Total time = 2.02 min.
  
```



A NN can learn the solution...
 Solve the ODE with a PINN using adam
 Iteration 0 objective 1.2060713847102091
 Iteration 100 objective 0.06426963241254897
 Iteration 200 objective 0.0037654361568503357
 Iteration 300 objective 0.0013668805784190507
 Iteration 400 objective 0.0007517324457044832
 Iteration 500 objective 0.0004981669314175369
 0.3 minutes elapsed this time. Total time = 0.32 min.

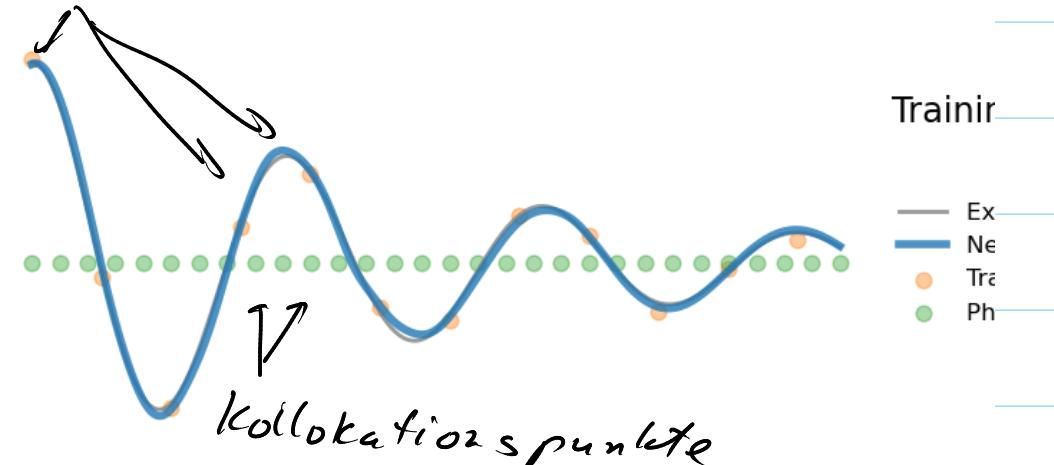
$E(1,8,8,3)$, $\tau r = 10^5$



$$\begin{aligned} w^2 \\ \dots \\ \mu + \mu \mu + \mu = 0 \\ \text{noise} = 0.05 * \text{uniform } (-1,1) \end{aligned}$$

3 layers 32 neurons

Validierungspunkte \neq Trainingspunkte



Ein stochastischer Algorithm für Lineare Ausgleichsrechnung

$$\|\underline{A}\underline{x} - \underline{b}\|_2^2$$

$\underline{A} \in \mathbb{R}^{m \times n}$
 m, n sehr sehr gross

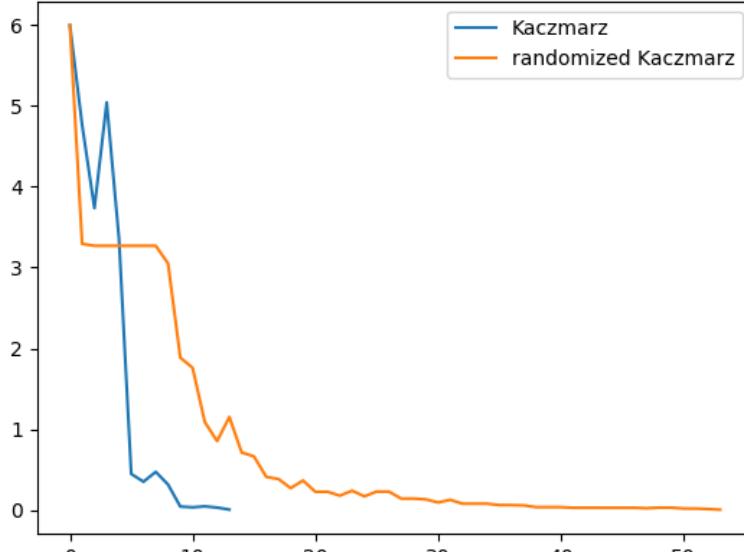
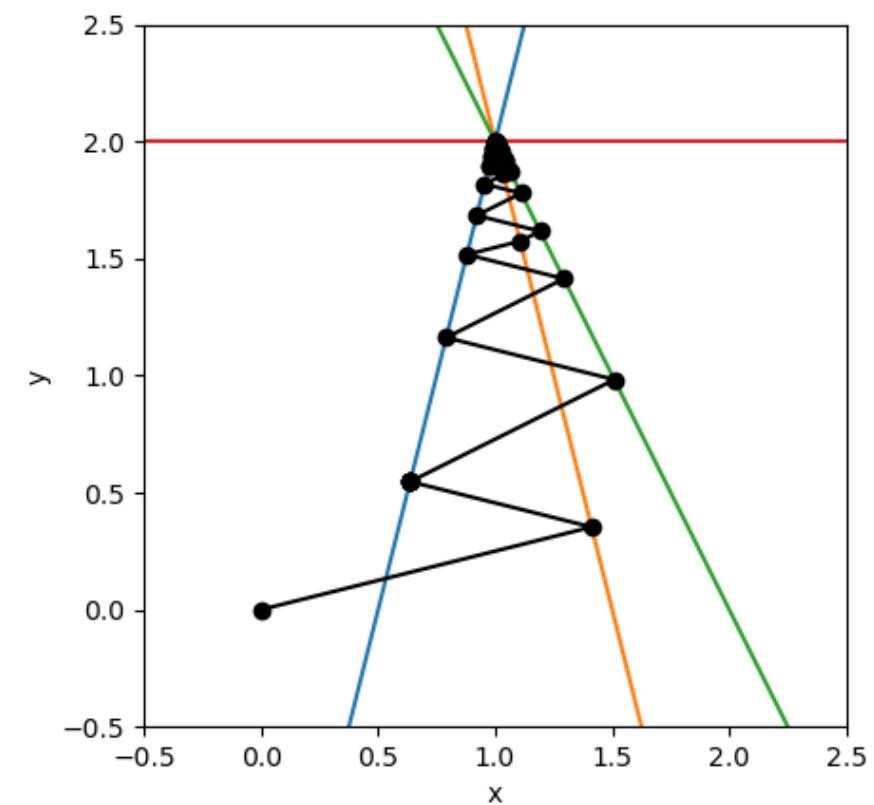
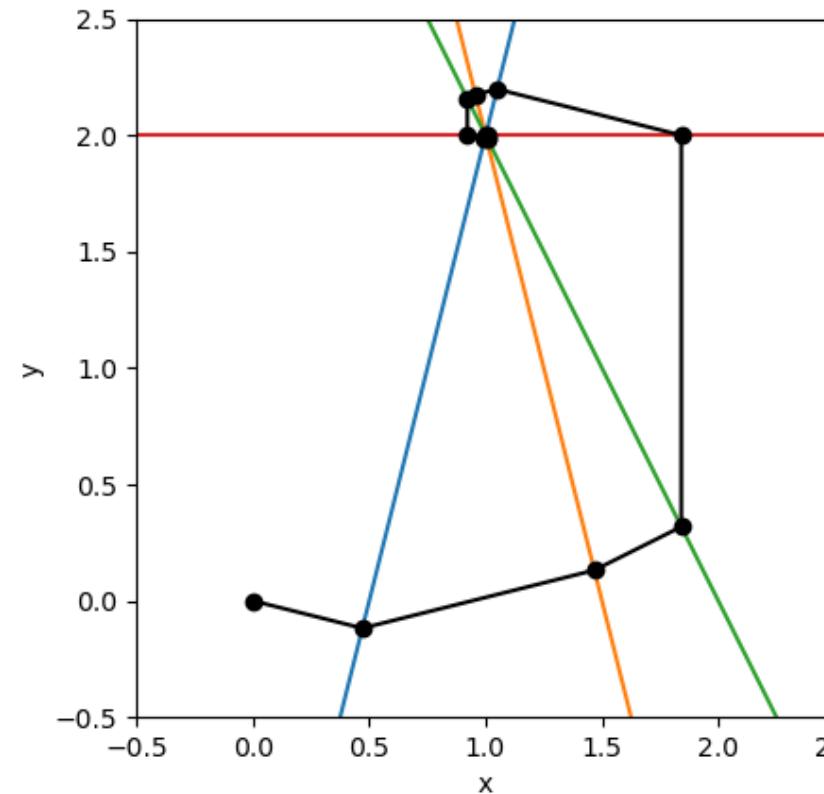
$$\underline{A}\underline{x} = \underline{b}$$

Hyperebene: $\underline{A}_{i,:} \cdot \underline{x} = b_i$

Diagramm einer Hyperebene in 2D:

$$A = \begin{bmatrix} -1 & 1 \\ 2 & 1/2 \\ 3 & 3/2 \\ 0 & 1 \end{bmatrix}; b = \begin{bmatrix} -2 \\ 3 \\ 6 \\ 1 \end{bmatrix}; x = \begin{bmatrix} 1 \\ 2 \end{bmatrix}$$

randKacz.py



Abhaengig von der density kann sparse besser als voll sein.

Etwa gleich schnell sind sie bei density = 0.1 (d.h 10% der Eintraege sind nicht Null).

density < 0.1 => sparse gewinnt.

bei density=0.05 hatte ich:

```
In [149]: %%timeit None
...:     ind_s, ind_e = A.indptr[i:i+2]
...:     vs = A.data[ind_s:ind_e]
...:     ind = A.indices[ind_s:ind_e]
...:     aiX = (vs*X[ind]).sum()
...:     nai = (vs**2).sum()
...:     X[ind] += ((b[i] - aiX)/nai) * vs
...:
29.4 µs ± 207 ns per loop (mean ± std. dev. of 7 runs, 10,000 loops each)
```

In [150]: ai = MA[i]

```
In [151]: %%timeit None
...:     (b[i] - ai @ X) / np.linalg.norm(ai)**2 * ai
...:
50.8 µs ± 654 ns per loop (mean ± std. dev. of 7 runs, 10,000 loops each)
```

In [141]: timeit spsolve_kaczmarz(A, b, 1.e-2, randomize=True)

687 ms ± 81.4 ms per loop (mean ± std. dev. of 7 runs, 1 loop each)

In [142]: timeit spsla.lsqr(A,b)

14.2 ms ± 5.07 ms per loop (mean ± std. dev. of 7 runs, 100 loops each)

In [143]: timeit spsla.lsqr(A,b)

The slowest run took 10.40 times longer than the fastest. This could mean that an intermediate
47.3 ms ± 49.9 ms per loop (mean ± std. dev. of 7 runs, 100 loops each)

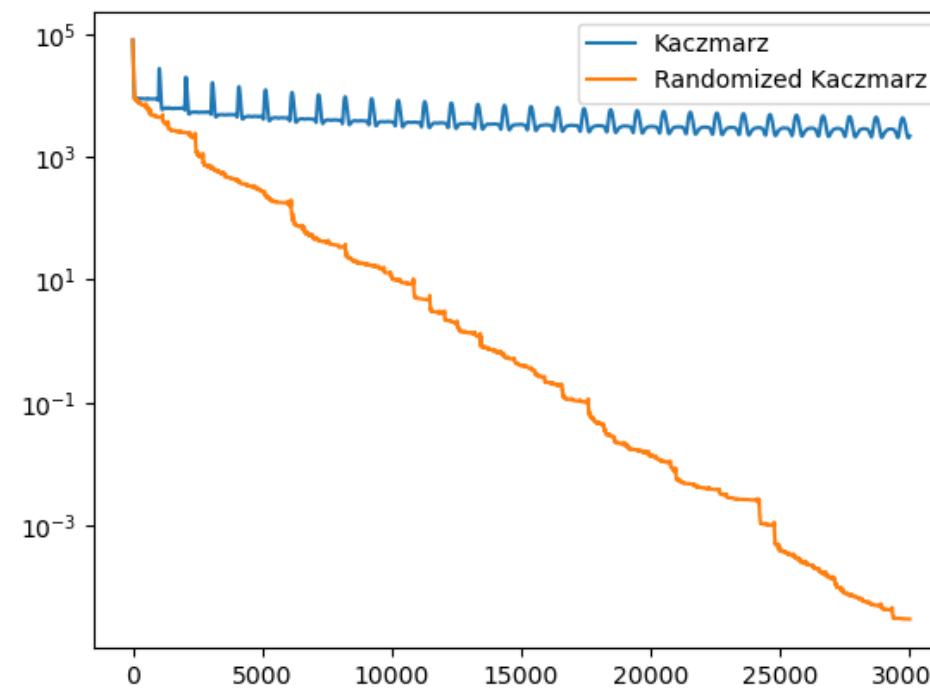
In [144]: timeit spsla.lsqr(A,b)

16.4 ms ± 7.64 ms per loop (mean ± std. dev. of 7 runs, 100 loops each)

In [145]: timeit np.linalg.lstsq(MA,b, rcond=-1)

The slowest run took 5.07 times longer than the fastest. This could mean that an intermediate
1.39 s ± 896 ms per loop (mean ± std. dev. of 7 runs, 1 loop each)

sparse lsqr gewinnt immer locker, auch bei density 0.25! Arpack ist schwer zu schlagen!



§9 Eigenwerte

§9.1 Einführung

- * Kein Alg. um exakt die $\in \mathbb{W}, \in \mathbb{V}$ für eine allgemeine Matrix zu berechnen!
 \Rightarrow Approximation von $\in \mathbb{W}, \in \mathbb{V}$ braucht iterativen Verfahren!

- * Software:
 - eig($\underline{\underline{A}}$) kostet (KN^3) für $N \times N$
 - eigh($\underline{\underline{A}}$) kostet (KN^2) für $\underline{\underline{A}}^H = \underline{\underline{A}}$

↳ QR-Algorithmus mit Shift

- * EV werden typischerweise nicht so gut approximiert.

$$\underline{\underline{A}}^H = (\underline{\underline{A}})^T$$

$$\underline{\underline{A}} \in \mathbb{C}^{n \times n}$$

§9.2 Potenzmethoden

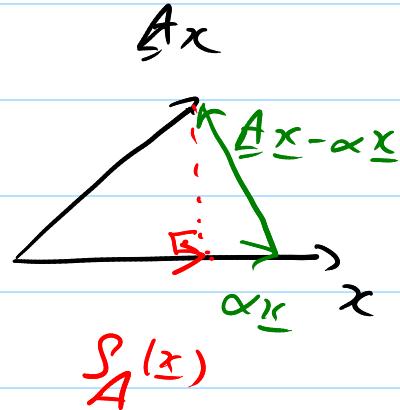
$\underline{\underline{A}}$ $n \times n$ Matrix

Def Rayleigh-Quotienten

$$s_{\underline{\underline{A}}}(\underline{x}) = \frac{\underline{x}^H \underline{\underline{A}} \underline{x}}{\underline{x}^H \underline{x}} \quad \text{für } \underline{x} \neq \underline{0}$$

Bei Falls $\underline{x} \in \mathbb{V}$ von $\underline{\underline{A}}$ dann $\underline{\underline{A}} \underline{x} = \lambda \underline{x} \Rightarrow$

$$s_{\underline{\underline{A}}}(\underline{x}) = \frac{\underline{x}^H \underline{\underline{A}} \underline{x}}{\underline{x}^H \underline{x}} = \frac{\underline{x}^H \lambda \underline{x}}{\underline{x}^H \underline{x}} = \lambda$$



$$\text{Bei } p(x) = \underset{\underline{A}}{\text{argmin}} \|\underline{\underline{A}} \underline{x} - \alpha \underline{x}\|$$

$$\frac{d}{d\alpha} \|\underline{\underline{A}} \underline{x} - \alpha \underline{x}\|^2 = 2 \sum_{j=1}^n ((\underline{\underline{A}} \underline{x})_j - \alpha x_j) x_j = 0$$

$\Rightarrow (\underline{\underline{A}} \underline{x} - \alpha \underline{x}) \perp \underline{x} \Leftrightarrow \text{ nach. ist erreicht}$

Wen. $\underline{\underline{A}} \underline{x} - \alpha \underline{x} \perp \underline{x} \Leftrightarrow \alpha \underline{x} = P_{\underline{x}}(\underline{\underline{A}} \underline{x}) \Rightarrow$

$$\alpha \underline{x} = \frac{1}{\underline{x}^H \underline{x}} \underline{x} \underline{x}^H (\underline{A} \underline{x})$$

$\Leftrightarrow \alpha \underline{x} = \left[\frac{\underline{x}^H \underline{A} \underline{x}}{\underline{x}^H \underline{x}} \right] \underline{x}$

$\Leftrightarrow \alpha = f_{\underline{A}}(\underline{x})$

$$f_{\underline{A}}(\underline{x}) - f_{\underline{A}}(\underline{x}^*) = 0 + O\left(\|\underline{x} - \underline{x}^*\|_2^2\right)$$

für \underline{x} nah an $\text{EV } \underline{x}^*$.

Ben $\underline{A} \in \mathbb{R}^{n \times n}$, $\underline{x} \in \mathbb{R}^n$

$$D f_{\underline{A}}(\underline{x}) = \frac{(\underline{x}^T \underline{x})(\underline{A}^T + \underline{A})\underline{x} - 2(\underline{x}^T \underline{A}\underline{x})\underline{x}}{(\underline{x}^T \underline{x})^2} =$$

$$= \frac{1}{\underline{x}^T \underline{x}} \left[(\underline{A}^T + \underline{A}) - 2 f_{\underline{A}}(\underline{x}) \underline{x} \underline{x}^T \right] \underline{x}$$

Falls $\underline{x}^* \in \text{EV}$ von $\underline{A} = \underline{A}^T$ ist:

$$D f_{\underline{A}}(\underline{x}^*) = \frac{1}{\underline{x}^T \underline{x}^*} \left(\lambda_{\underline{x}^*} + \lambda_{\underline{x}^*} - 2 \lambda_{\underline{x}^*} \right) = 0$$

$\underline{x}^* \in \text{EV}$ von $\underline{A} \Rightarrow \underline{x}^*$ Stationärpunkt von $f_{\underline{A}}(\cdot)$

\Rightarrow Taylor für $f_{\underline{A}}(\cdot)$ um $\underline{x}^* \in \text{EV}$ von $\underline{A} \Rightarrow$

$\Rightarrow f_{\underline{A}}(\underline{x})$ kann als gute Approximation an $f_{\underline{A}}(\underline{x}^*) = \lambda$ funktionieren.

Direkte Potenzmethode

Ziel: finde das betragsgrößte EV von \underline{A} !
und ein $\underline{v} \in \text{EV}$ dazu.

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

$$|\lambda_1| > |\lambda_2| \geq |\lambda_3| \geq \dots \geq |\lambda_n| \geq 0$$

$$\lambda_1, \dots, \lambda_n \in \mathbb{K}$$

$$\underline{\Delta}_1, \dots, \underline{\Delta}_n \in \mathbb{K}$$

\hookrightarrow Spalten von \underline{S} $\|\underline{\Delta}_j\|_2 = 1$

$\mathbb{R}^n \ni x = \sum_{j=1}^n c_j \underline{\Delta}_j$ mit $c_1 \neq 0$, sonst beliebig.

$$\Rightarrow \frac{\underline{\Delta}^k x}{\|\underline{\Delta}^k x\|} \rightarrow \pm \underline{\Delta}_1$$

$$\underline{\Delta}^k x = \sum_{j=1}^n c_j \underline{\Delta}_j = \sum_{j=1}^n c_j \lambda_j^k \underline{\Delta}_j$$

$$\underline{\Delta}^2 x = \sum_{j=1}^n c_j \lambda_j^2 \underline{\Delta}_j$$

$$\dots$$

$$\underline{\Delta}^k x = \sum_{j=1}^n c_j \lambda_j^k \underline{\Delta}_j = \lambda_1^k \left(c_1 \underline{\Delta}_1 + \sum_{j=2}^n \left(\frac{\lambda_j}{\lambda_1} \right)^k c_j \underline{\Delta}_j \right)$$

$$\left| \frac{\lambda_j}{\lambda_1} \right| < 1$$

\downarrow
für $k \rightarrow \infty$

0

=> für grosses k zeigt $\underline{\Delta}^k x$ in der "Richtung" von $\underline{\Delta}_1$

da alle $\underline{\Delta}_2, \dots, \underline{\Delta}_n$ den Verfaktor

$\left(\frac{\lambda_2}{\lambda_1} \right)^k, \dots, \left(\frac{\lambda_n}{\lambda_1} \right)^k$ haben.
 $\ll 1$

Idee: notiere $x_k = \underline{\Delta}^k x$ und berechne

$$S_{\underline{\Delta}}(x_k) = \frac{x_k^H \underline{\Delta} x_k}{x_k^H x_k} = \frac{1}{x_k^H x_k} \left(x_k^H \sum_{j=1}^n c_j \lambda_j^k \underline{\Delta}_j \right)$$

$$= \lambda_1 + O\left(\left| \frac{\lambda_2}{\lambda_1} \right|^k\right)$$

Potenzmethode:

wähle x_0 zufällig, $\|x_0\|=1$

für $k=1, 2, \dots$

$$w = \underline{\Delta} x_{k-1}$$

$$x_k = \frac{w}{\|w\|}$$

$$\lambda_k = x_k^H \underline{\Delta} x_k$$

Theorem Die Potenzmethode liefert eine Iteration, die linear gegen λ_1 konvergiert mit der Konvergenzrate $|\frac{x_2}{x_1}|$

Bew. Falls \underline{A} normal ($\Rightarrow \underline{E}V$ orthogonal)

\Rightarrow Fehler

$$O\left(\left|\frac{\lambda_2}{\lambda_1}\right|^{2k}\right) \Rightarrow \text{quadratische Konvergenz!}$$

Grundlage PageRank-Algorithmus von Google!

Beweis $\underline{A} = \underline{A}^H \Rightarrow$ DB von $\underline{E}V$ u_1, \dots, u_n

$$\sum_{j=1}^n c_j u_j = \underline{U} \in \text{diag}(\lambda_1, \dots, \lambda_n) = \underline{\Lambda}$$

$$x = \sum_{j=1}^n c_j u_j = \underline{U} \in \text{mit } \underline{U} \text{ unitär.}$$

$$\frac{x^H \underline{A} x}{x^H x} = \frac{c^H \underline{U}^H \underline{A} \underline{U} c}{c^H c} = \frac{c^H \underline{\Lambda} c}{c^H c} = \frac{\lambda_1 |c_1|^2 + \lambda_2 |c_2|^2 + \dots + \lambda_n |c_n|^2}{|c_1|^2 + \dots + |c_n|^2}$$

$$= \lambda_1 + \beta \left| \frac{\lambda_2}{\lambda_1} \right|^{2k} + \dots$$

Ziel: Finde das kleinste ϵ_V
Annahme: \underline{A} invertierbar

$$\underline{A}^{-1} \mid \underline{A}x = \lambda x \Leftrightarrow x = \lambda \underline{A}^{-1} x \Leftrightarrow \frac{1}{\lambda} x = \underline{A}^{-1} x$$

$\lambda_n = \text{betrag kleinste } \epsilon_V \text{ von } \underline{A} \Leftrightarrow$

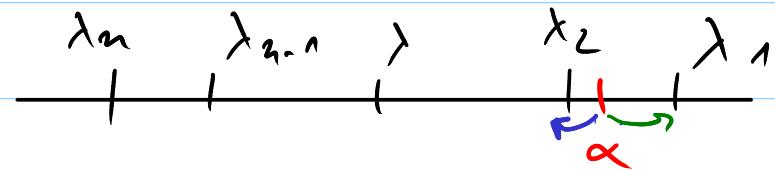
$\frac{1}{\lambda_n} = \text{betrag grösste } \epsilon_V \text{ von } \underline{A}^{-1}$

inverse Potenzmethode = Potenzmethode für \underline{A}^{-1}

Bew. Wir berechnen nicht \underline{A}^{-1} sondern nur eine LU-Zerlegung von \underline{A} am besten mit einem Alg., der die Struktur der Matrix \underline{A} bei behält, falls möglich.

Dann löse LGS mit Matrizen $\underline{L}, \underline{U}$ um $\underline{A}^{-1}x$ zu implementieren.

Ziel: Gegeben $\alpha \in \mathbb{C}$, finde ∞ nah an α



$$|\alpha - \lambda| = \min \{ |\alpha - \mu| \text{ mit } \mu \in \mathbb{C} \text{ von } A \}$$

$$\underline{A}\underline{x} = \lambda \underline{x} \Leftrightarrow \underline{A}\underline{x} - \alpha \underline{I}\underline{x} = \lambda \underline{x} - \alpha \underline{x}$$

Shift

$$\hookrightarrow (\underline{A} - \alpha \underline{I})\underline{x} = (\lambda - \alpha)\underline{x}$$

$$\hookrightarrow \frac{1}{\lambda - \alpha} \underline{x} = (\underline{A} - \alpha \underline{I})^{-1} \underline{x}$$

Potenzmethode für $(\underline{A} - \alpha \underline{I})^{-1} \Rightarrow \frac{1}{|\lambda - \alpha|} \max$

$= |\lambda - \alpha| \min.$

↳ "shifted inverse iteration"

$\frac{1}{|\lambda_2 - \alpha|}$ gross, $\frac{1}{|\lambda_1 - \alpha|}, \frac{1}{|\lambda_3 - \alpha|}$ klein

Bem: shifted inverse iteration

ist schneller wenn α nah an einem Eigenwert ist.



Idee wähle Shift α adaptiv
(in jedem Iterationschritt)

z.B. $\alpha = S_{\underline{A}}(\underline{x}^{k-1})$ im k -ten Schritt.

⇒ beschleunigte Konvergenz

Rayleigh-Quotienten-Iteration (RQI)

Bem: Wir brauchen einen guten Startwert

z.B. für RQI einige Schritte von LT.

⇒ Konvergenzordnung 3

Preis: für jedes neue α brauchen wir
eine neue LU-Zerlegung: $\underline{A} - \alpha \underline{I}$.

Bew $\underline{x} \in \text{span}\{\underline{u}_1\}^\perp \Rightarrow c_1 = 0$

$$\underline{x} = c_2 \underline{u}_2 + \dots + c_m \underline{u}_m$$

Bew $\underline{A} = \underline{A}^H$, $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$; \underline{x} beliebig
 $\underline{x} = \underline{U} \underline{c}$

$$= \underline{s}_{\underline{A}}(\underline{x}) = \frac{\lambda_1|c_1|^2 + \dots + \lambda_n|c_n|^2}{|c_1|^2 + \dots + |c_n|^2} \Rightarrow \lambda_2 \leq \underline{s}_{\underline{A}}(\underline{x})$$

$$\Rightarrow \underline{s}_{\underline{A}}(\underline{x}) = \frac{\lambda_1|c_1|^2 + \dots + \lambda_n|c_n|^2}{|c_1|^2 + \dots + |c_n|^2}$$

$$\lambda_2 = \min \underline{s}_{\underline{A}}(\underline{x}) \quad \text{erreicht f\"ur } \underline{c} = \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$\Rightarrow \lambda_1 \leq \underline{s}_{\underline{A}}(\underline{x}) \leq \lambda_n$$

$$\lambda_1 = \min \underline{s}_{\underline{A}}(\underline{x}) \quad \text{erreicht f\"ur } \underline{c} = \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$\lambda_n = \max \underline{s}_{\underline{A}}(\underline{x}) \quad \text{erreicht f\"ur } \underline{c} = \begin{bmatrix} 0 \\ \vdots \\ 0 \\ 1 \end{bmatrix}$$

$$\lambda_{n-1} = \max \underline{s}_{\underline{A}}(\underline{x})$$

$$\underline{x} \in \text{span}\{\underline{u}_n\}^\perp$$

und so weiter.

$$\lambda_k = \min \underline{s}_{\underline{A}}(\underline{x})$$

$$\underline{x} \in \text{span}\{\underline{u}_1, \dots, \underline{u}_{k-1}\}^\perp \quad \underline{x} \in \text{span}\{\underline{u}_1, \dots, \underline{u}_k\}$$

$$= \max \underline{s}_{\underline{A}}(\underline{x})$$

Theorem (Courant-Fisher)

$$\lambda_k = \min_{\mathcal{U}} \max_{x \in \mathcal{U}} S_A(x) =$$

$\dim \mathcal{U} = k$

$$= \max_{\mathcal{U}} \min_{x \in \mathcal{U}} S_A(x).$$

$\dim \mathcal{U} = n-k+1$

Bem $x_k^H A^k x_k, x_k^H A^k y_k + \dots$ mit Orthogonalisierung liefert

$$x_k \rightarrow \underline{\theta}_1, x_k \rightarrow \underline{\theta}_2$$

2. Möglichkeiten das zu verallgemeinern.

→ mit Orthogonalen Transformationen

(H-Spliterung) \Rightarrow "QR"-Algorithmus

→ Gram-Schmidt Orthogonalisierung.

Theorem (Cauchy)

$$A = \begin{bmatrix} H & B^H \\ B & R \end{bmatrix} \quad \text{mit } H \in \mathbb{C}^{m \times m} \quad \text{mit } \in \mathbb{W} \quad \theta_1 \leq \dots \leq \theta_m$$

$$\lambda_1 < \dots < \lambda_n \in \text{EW von } A$$

$$(m < n) \quad \text{mit } \in \mathbb{W} \quad \theta_1 \leq \dots \leq \theta_m$$

$$\text{Dann } \lambda_k \leq \underline{\theta}_k \leq \lambda_{k+n-m}$$

Idee $\underline{Q}_m \in \mathbb{C}^{n \times m}$

$$= \underline{Q} \in \mathbb{C}^{n \times n}$$

= unitäre Matrix.

$$\text{mit } \underline{Q}_m^H \underline{Q}_m = \underline{I}_m$$

erweitere \underline{Q}_m auf ONB in \mathbb{C}^n

$$\underline{Q}^H \underline{A} \underline{Q} = \begin{bmatrix} \underline{Q}_m^H A \underline{Q}_m & \underline{Q}_m^H A \underline{Q}_m^T \\ \underline{Q}_m^T A \underline{Q}_m & \underline{Q}_m^T A \underline{Q}_m^T \end{bmatrix}$$

hat diese LInen $\in \mathbb{W}$ wie A

$$\theta_1 < \theta_2 < \dots < \theta_m \in \text{EW von } \underline{Q}_m^H A \underline{Q}_m$$

$$\lambda_1 < \theta_1 < \lambda_2 < \theta_2 < \dots < \lambda_k < \theta_k < \lambda_{k+n-m} < \dots$$

$$\lambda_m < \theta_m < \lambda_n$$

Idee: Für $m \ll n$, wähle \underline{Q}_m so dass

$$\text{Bild } \underline{Q}_m \approx \text{span} \{ \underline{u}_1, \dots, \underline{u}_m \}$$

\hookrightarrow EV von \underline{A} zu $\lambda_1, \dots, \lambda_m$

\Rightarrow gute Approximation $\underline{v}_k \approx \underline{\lambda}_k$ für $k=1, \dots, m$

Wie? modifiziertes Gram-Schmidt für

$$\{ \underline{v}, \underline{A}\underline{v}, \underline{A}^2\underline{v}, \dots, \underline{A}^{m-1}\underline{v} \}$$

= Krylov-Verfahren

Arnoldi/Lanczos

§ 9.3 Krylov-Verfahren

Def Sei $\underline{0} \neq \underline{z} \in \mathbb{C}^n$, $\underline{A} \in \mathbb{C}^{n \times n}$

$$K_l(\underline{A}, \underline{z}) = \text{span} \{ \underline{z}, \underline{A}\underline{z}, \underline{A}^2\underline{z}, \dots, \underline{A}^{l-1}\underline{z} \}$$

$$= \{ p(\underline{A})\underline{z} ; p = \text{Polynom von Grad } \leq l-1 \}$$

Krylov-Raum.

Suche eine ONB in $K_l(\underline{A}, \underline{z}) \subseteq \mathbb{C}^n$

Bsp für "kleinere" Matrizen: eig (QR-Alg) gut

$$K_1 = \text{span} \{ \underline{z} \} \subset \text{span} \{ \underline{z}, \underline{A}\underline{z} \} = K_2 \subset K_3 \subset \dots \subset K_l$$

"grossere": eig zu langsam
nutzt Struktur von \underline{A} nicht!

Iterativ: gegeben $\underline{v}_1, \underline{v}_2, \dots, \underline{v}_l$ ONB in $K_l(\underline{A}, \underline{z})$

$$\text{mit } \text{span} \{ \underline{v}_1, \dots, \underline{v}_j \} = K_j(\underline{A}, \underline{z}) \text{ für } j=1, 2, \dots, l$$

Krylov: geeignet für grosse, dünnbesetzte Matrizen.

" \underline{A} mal \underline{x} "

Seien $\underline{v}_1, \underline{v}_2, \dots, \underline{v}_l, \underline{v}_{l+1}$ ONB in $K_{l+1}(\underline{A}, \underline{z})$

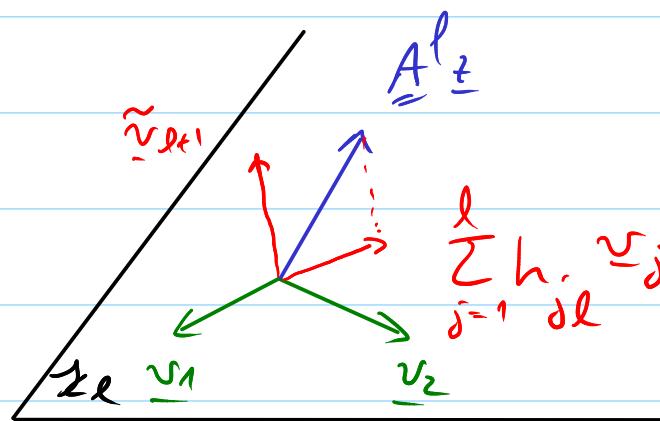
$$\text{span} \{ \underline{z}, \underline{A}\underline{z}, \dots, \underline{A}^{l-1}\underline{z}, \underline{A}^l\underline{z} \}$$

Entweder $\underline{A}^l \underline{z} \in \mathcal{K}_l(\underline{A}, \underline{z})$ d.h. $\underline{A}^l \underline{z}$ linear abhängig von $\underline{z}, \underline{A}\underline{z}, \dots, \underline{A}^{l-1}\underline{z}$

oder

$$\underline{A}^l \underline{z} \notin \mathcal{K}_l(\underline{A}, \underline{z}) \Rightarrow \underline{A}^l \underline{z} \in \mathcal{X}_{l+1} \setminus \mathcal{K}_l$$

dann \underline{v}_{l+1} aus (modifiziertem) Gram-Schmidt.



Dabei sind $h_{j,l} = \underline{v}_j^H \underline{A} \underline{v}_l$ da $\underline{v}_1, \dots, \underline{v}_l$ orthonormiert.

$$\underline{\tilde{v}}_{l+1} = \underline{A}^l \underline{z} - \sum_{j=1}^l h_{j,l} \underline{v}_j$$

$$\underline{v}_{l+1} = \frac{1}{\|\underline{\tilde{v}}_{l+1}\|} \underline{\tilde{v}}_{l+1}$$

Algorithmus (Arnoldi Prozess)

$\underline{z} = \text{beliebig } \neq 0$

$$\underline{v}_1 = \frac{1}{\|\underline{z}\|} \underline{z}$$

für $l=1, 2, \dots, k-1$

$l=1 \quad l=2 \quad l=3$

$$\underline{z} = \underline{A} \underline{v}_l$$

für $j=1, 2, \dots, l$

$$h_{j,l} = \underline{v}_j^H \underline{z}$$

$$h_{11}$$

$$h_{22}$$

$$h_{33}$$

$$\underline{z} = \underline{z} - h_{j,l} \underline{v}_j$$

$$h_{l+1,l} = \|\underline{z}\|$$

$$h_{21}$$

$$h_{23}$$

$$h_{34}$$

$$v_{l+1} = \underline{z} / h_{l+1,l}$$

es entsteht
eine "Hessenberg"
Matrix

$$\begin{bmatrix} x & x & x & \cdots \\ x & x & x & \cdots \\ 0 & x & x & \cdots \\ 0 & 0 & x & \cdots \\ \vdots & \vdots & 0 & \ddots \\ 0 & 0 & 0 & \ddots \end{bmatrix}$$

Bem Falls $b_{l+1, \ell} = 0 \Rightarrow$ Abbruch der Iteration.

Fall $\underline{A} \vee_{\ell} \in \Sigma_{\ell}(A, \underline{z})$

$$\underline{V}_l = \begin{bmatrix} \underline{v}_1 & \underline{v}_2 & \dots & \underline{v}_l \end{bmatrix} \in \mathbb{C}^{n \times l}$$

$$\tilde{H}_\ell = \begin{bmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ 0 & h_{32} & h_{33} \\ 0 & 0 & h_{43} \end{bmatrix} \in \mathbb{C}^{l+1, l}$$

$$H_2 = \begin{bmatrix} & & & \\ & & & \\ & & & \\ 0 & & & \end{bmatrix} \quad \text{obere Hessenberg matrix}$$

Aus Konstruktion

$$\text{Konstruktion.}$$

$$\hat{A} \underline{v}_k = h_{k+1,k} \underline{v}_{k+1} + \sum_{j=1}^k h_{jk} \underline{v}_j \quad \text{für } k=1, 2, \dots, l$$

$$\underline{A} \underline{\underline{V}}_l = \underline{\underline{V}}_{l+1} \underline{H}_l = \boxed{\begin{array}{|c|c|c|c|c|} \hline 0 & 0 & 1 & 0 & x \\ \hline \end{array}} + \underline{\underline{V}}_l \underline{H}_l$$

$$l < n$$

The diagram shows four stages of set construction:

- Stage 1:** A large rectangle labeled n at the top and bottom. Inside, the letter $\underline{\underline{A}}$ is written.
- Stage 2:** The rectangle is divided into l vertical strips. A yellow dot is located at the bottom of the second strip from the left. An equals sign ($=$) is placed between the first two stages.
- Stage 3:** The rectangle is divided into $l+1$ vertical strips. A yellow dot is located at the bottom of the third strip from the left.
- Stage 4:** The rectangle is divided into $l+1$ vertical strips. A small square contains a graph with a curve labeled x , a point O , and axes labeled x and y . Below the graph, the text $0 \dots x$ is written.

$$\underline{\text{Bew}} \quad \text{D) } \underline{\underline{V_e}}^H \underline{\underline{V_e}} = \underline{\underline{I_e}}$$

$$V_e^u = V_e \quad \left[\begin{array}{l} \\ \end{array} \right] = \left[\begin{array}{c} 0\% \\ I_e \end{array} \right]$$

$$2) \quad \underline{\underline{V}}_e^H \underline{\underline{A}} \underline{\underline{V}}_e = \underline{\underline{V}}_e^H \begin{array}{c} \text{[0]} \\ \boxed{x} \end{array} + \underline{\underline{V}}_Q^H \underline{\underline{V}}_e \underline{\underline{H}}_Q = \underline{\underline{H}}_e$$

A diagram of a piecewise constant function f_l . The function is zero on the interval $[0, x_{l+1}]$ and increases linearly to a value I_l on the interval $[x_{l+1}, \infty)$. A green brace above the function indicates the jump at x_{l+1} , and the label v_{l+1} is written above the brace.

$$\underline{V}_e^H \underline{A} \underline{V}_e = \underline{H}_e$$

$$\boxed{\underline{V}_e^H} \quad \underline{A} \quad \boxed{\underline{V}_e} = \boxed{\underline{0}} \quad \underline{H}_e$$

(statt variable Länge ℓ)

$$\begin{aligned}\underline{V}_{\ell+1} &= \underline{A} \underline{V}_\ell - h_{\ell,\ell} \underline{V}_\ell - h_{\ell-1,\ell} \underline{V}_{\ell-1} \\ &\Rightarrow \text{Longos-Verfahren. } O(nk)\end{aligned}$$

3) falls $h_{\ell+1,\ell} = 0 \Rightarrow \mathcal{K}_{\ell+1} = \mathcal{K}_\ell$ und

$$\underline{A} \underline{V}_\ell = \underline{V}_\ell \underline{H}_\ell \Rightarrow \underline{V}_\ell^H \underline{A} \underline{V}_\ell = \underline{H}_\ell.$$

Für allgemeine Matrizen: Arnoldi $O(nk^2)$

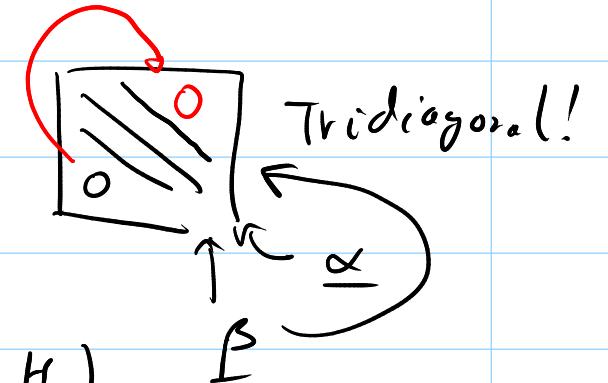
k = Anzahl Krylov-Schritte

4) falls $\underline{A}^H = \underline{A}$ (\underline{A} Hermit-symmetrische)

$$\underline{H}_\ell = \underline{V}_\ell^H \underline{A} \underline{V}_\ell \stackrel{(\cdot)^H}{=} \underline{H}_\ell^H = \underline{V}_\ell^H \underline{A}^H \underline{V}_\ell = \underline{V}_\ell^H \underline{A} \underline{V}_\ell = \underline{H}_\ell$$

$\Rightarrow \underline{H}_\ell$ auch Hermit-symmetrisch

$$\Rightarrow \underline{H}_\ell =$$



\Rightarrow es reicht α, β (=Diagonalen in \underline{H}_ℓ)

zu speichern / berechnen

\Rightarrow innere Schleife in Arnoldi hat konstante (2) Länge.

Theoreme

Falls $h_{\ell+1,\ell} = 0$ und $h_{j+1,j} \neq 0$ für $j=1, \dots, \ell-1$, dann

(1) jeder EV von \underline{H}_ℓ ist auch EV von \underline{A}

(2) falls \underline{A} regulär, dann gibt es $\underline{y} \in \mathbb{C}^\ell$ so dass

$$\underline{A} \underline{x} = \underline{b} \text{ mit } \underline{x} = \underline{V}_\ell \underline{y}.$$

Beweis (1) Sei $\lambda \in \mathbb{W}$ von \underline{H}_ℓ zu $\underline{v} \in \mathbb{V}$ $\underline{y} \neq \underline{0}$

$$\underline{H}_\ell \underline{y} = \lambda \underline{y} \Rightarrow \underline{V}_\ell \underline{H}_\ell \underline{y} = \lambda \underline{V}_\ell \underline{y}$$

$\underline{V}_\ell |$

Iteration bricht ab $\underline{A} \underline{V}_0 = \underline{V}_\ell \underline{H}_0 \Rightarrow$

$$\Rightarrow \underline{A} \underline{V}_\ell \underline{y} = \underline{V}_\ell \underline{H}_\ell \underline{y} = \lambda \underline{V}_\ell \underline{y} \Rightarrow$$

$\lambda \in \mathbb{W}$ von \underline{A} zu $\underline{v} \in \mathbb{V}$ $\underline{V}_\ell \underline{y}$

(2) Gegeben: \underline{b} , \underline{A} regulär

\underline{v} ist kein EW von \underline{A}

\underline{v} ist kein EW von \underline{H}_ℓ

Sei \underline{V}_ℓ gebaut für $\mathcal{L}_\ell(\underline{A}, \underline{b})$

$$\underline{b} = \beta \underline{v}_1 = \underline{V}_\ell \beta \underline{e}_1, \text{ mit } \underline{e}_1 = \begin{bmatrix} 1 \\ \vdots \\ 0 \end{bmatrix}^\top$$

$$\underline{b} = \beta \underline{V}_\ell \underline{e}_1 = \underline{V}_\ell \underline{\beta} \underline{e}_1$$

Betrachte LGS $\underline{A}\underline{x} = \underline{b}$

$$\underline{H}_\ell \underline{y} = \beta \underline{e}_1 \text{ hat Lösung } \underline{y} \in \mathbb{C}^\ell$$

$$\text{Somit } \underline{A} \underline{V}_\ell \underline{y} = \underline{V}_\ell \underline{H}_\ell \underline{y} = \underline{V}_\ell \beta \underline{e}_1 = \underline{b}$$

$\Rightarrow \underline{x} = \underline{V}_\ell \underline{y}$ ist die Lösung von $\underline{A}\underline{x} = \underline{b}$.

Bew

$$\underline{H}_\ell \in \mathbb{C}^{l \times l}, l \ll n$$

obere Hessenberg / falls $\underline{A}'' = \underline{A} \Rightarrow$ tridiagon.

eig(\underline{H}_ℓ) ist sehr schnell ($l \ll n$) \Rightarrow anwendbar.

Theorie \rightarrow Erweitere $\{\underline{v}_1, \dots, \underline{v}_\ell\}$ zu \mathbb{B} und in \mathbb{C}^n

$$\underline{Q} = \begin{bmatrix} \underline{V}_\ell & \underline{V}_{\ell+1} & \cdots & \underline{V}_n \end{bmatrix}$$

$$\underline{Q}^\top \underline{A} \underline{Q} = \begin{bmatrix} \underline{V}_\ell^\top \underline{A} \underline{V}_\ell & & & \\ \hline & \ddots & & \\ & & \ddots & \\ & & & \underline{X} \end{bmatrix}$$

Cauchy.

$$\lambda_k < \theta_k < \lambda_{k+n-l}$$

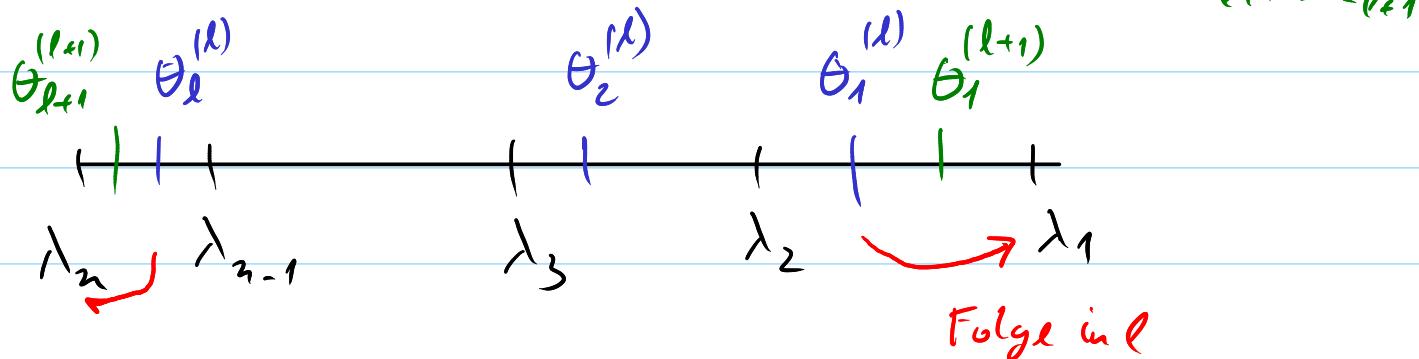
EW von \underline{H}_ℓ

Theorem Sei $\underline{A} \in \mathbb{C}^{n \times n}$ Hermite symmetrisch.

und $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \in \mathbb{K}$ von \underline{A}

$$\Theta_1^{(l)} \geq \Theta_2^{(l)} \geq \dots \geq \Theta_l^{(l)} \in \mathbb{K} \text{ von } \underline{H}_l = \underline{V}_l^H \underline{A} \underline{V}_l$$

für $l=1, 2, 3, \dots$



Dazu gelten für $1 \leq j \leq l$ die Ungleichungsketten:

$$\Theta_j^{(l)} \leq \Theta_j^{(l+1)} \leq \lambda_j$$

$$\lambda_{n-j+1} \leq \Theta_{l+1-j+1}^{(l+1)} \leq \Theta_{l-j+1}^{(l)}$$

Bem $l=n \Rightarrow$ Iteration bricht automatisch ab

$$\Rightarrow \mathbb{K} \lambda_1, \lambda_2, \dots, \lambda_n$$

Skript → einfache Implementierungen. Arnoldi Longos

ARPACK → eigs [eigs]

Tricks anwendbar mit krylov - Verfahren

$$\rightarrow \text{shift} = \mathbb{K} \quad \underline{A} + \sigma \underline{I}$$

$$\rightarrow \text{shift \& inverso: } (\underline{A} - \sigma \underline{I})^{-1}$$

$$\rightarrow \text{Cayley Transformation: } (\underline{A} - \sigma \underline{I})^{-1}(\underline{A} + \tau \underline{I})$$

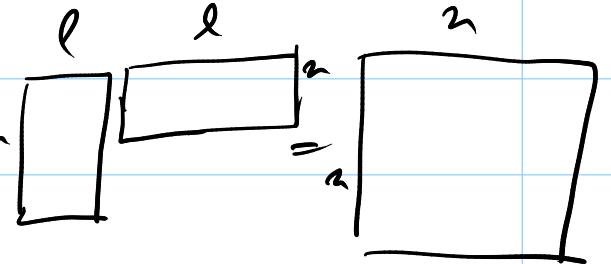
$$\rightarrow \text{Folding} \quad (\underline{A} + \sigma \underline{I})^2$$

"LGS Lösen"

ONB
 $\mathcal{K}_\ell = \text{Bild } \{\underline{v}_1, \dots, \underline{v}_\ell\} \subset \mathbb{C}^n$

Projektor (orthogonaler Projektor)

$$\begin{matrix} P_{\mathcal{K}_\ell} & : \mathbb{C}^n \rightarrow \mathcal{K}_\ell \\ \downarrow & \\ \text{als Matrix} & P_{\mathcal{K}_\ell} = \underline{V}_\ell \underline{V}_\ell^H \end{matrix}$$



$$P_{\mathcal{K}_\ell} A = \underline{V}_\ell \underline{V}_\ell^H A$$

$$\underline{u} \in \mathcal{K}_\ell \Rightarrow \underline{u} = c_1 \underline{v}_1 + c_2 \underline{v}_2 + \dots + c_\ell \underline{v}_\ell \in \mathcal{K}_\ell \subseteq \mathbb{C}^n \quad \underline{c} = \begin{bmatrix} c_1 \\ \vdots \\ c_\ell \end{bmatrix}$$

\downarrow "Basiswechsel"

$$P_{\mathcal{K}_\ell} A \underline{u} = \underline{V}_\ell \underline{V}_\ell^H A \underline{u} = \underline{V}_\ell \underline{V}_\ell^H \underline{c} =$$

$= \underline{V}_\ell (\underline{H} \underline{c}) \Rightarrow \underline{H} \underline{c}$ gibt die Koeffizienten
 in der Basis $\{\underline{v}_1, \dots, \underline{v}_\ell\}$

\cap
 \mathcal{K}_ℓ von $P_{\mathcal{K}_\ell} A \underline{u}$

$\Rightarrow P_{\mathcal{K}_\ell} A \stackrel{\cong}{=} \text{ wird auf } \mathcal{K}_\ell \text{ durch } \underline{H}_\ell \text{ dargestellt}$

$$\begin{matrix} A & : \mathbb{C}^n \rightarrow \mathbb{C}^n \\ \cong & \cup \quad \cup \end{matrix}$$

$$P_{\mathcal{K}_\ell} A : \mathcal{K}_\ell \rightarrow \mathcal{K}_\ell$$

„Raum kleiner Dimension.“

Standard Idee aus der Approximation:

ersetze der unbequeme Raum grosser/unendlicher Dimension durch bequemen Raum kleiner Dimension

$$\begin{matrix} A & \text{durch} & P_{\mathcal{K}_\ell} A \\ \cong & & \end{matrix}$$

und nun schreibe es in der ONB von \mathcal{K}_ℓ

$\begin{matrix} \cong & \underline{H}_\ell \\ \underline{H}_\ell & \in \mathbb{C}^{\ell \times \ell} \end{matrix}$
 mit $\ell < n$ und berechne die EV von \underline{H}_ℓ mit eig. (QR-Iteration)

Arnoldi-Verfahren sind gut zu setzen wenn
 $A^H = A$ und A dünn besetzt.

Bem

Numerik →

Schur-Zerlegung $A = U T U'$

für

großere Dreiecksch.

Für nicht-symmetrische Matrizen ist es deutlich problematischer

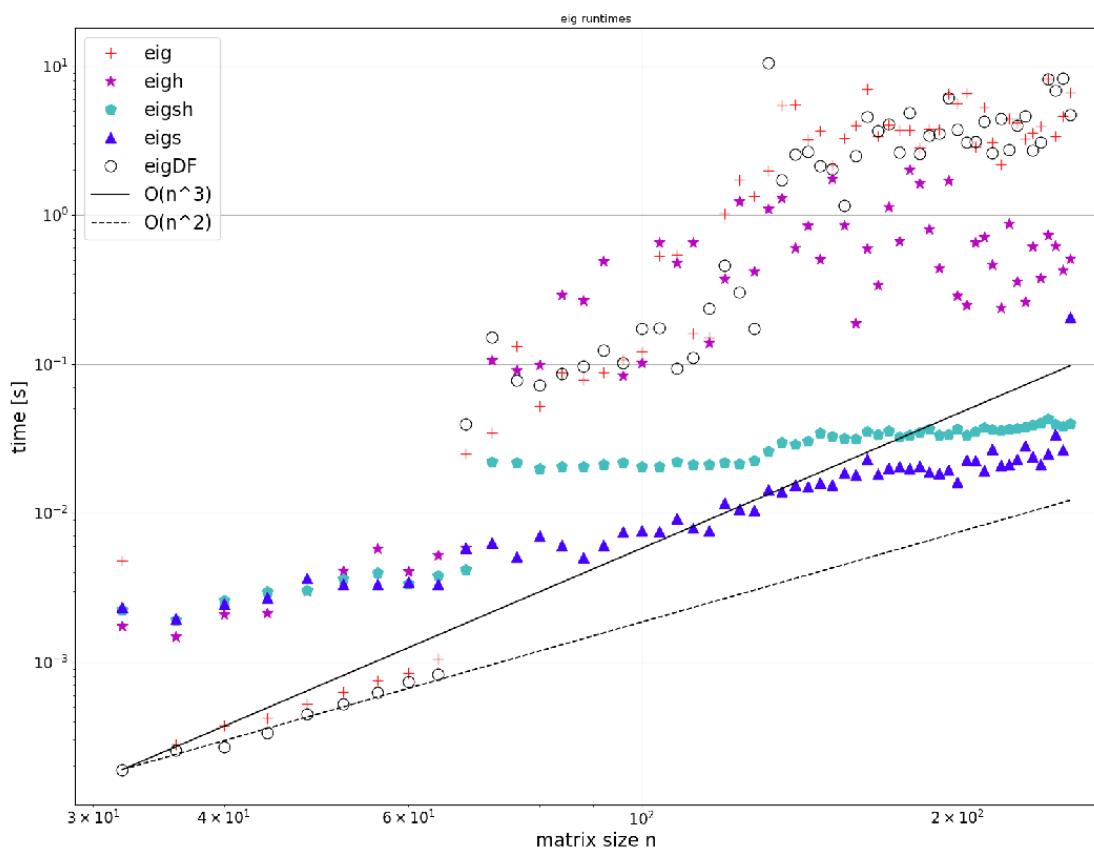
Theorie →

Jordan-Zerlegung.

↳ numerisch sehr schlecht konditioniert

Wenn A voll besetzt ist kann das zu teuer werden.

Darum ist eig immer noch nutzlich!



§ 10 Lineare Anfangswertprobleme

1. Fall

$$\begin{cases} \dot{\underline{y}} = \underline{A} \underline{y} & \text{Falls } \underline{A} \text{ diagonalisierbar} \\ \underline{y}(0) = \underline{y}_0 & \underline{A} = \underline{S}^{-1} \underline{D} \underline{S} \end{cases}$$

Für $d=5, \dots, 50, 100$

$$\underline{y}(t) = e^{\underline{A}t} \underline{y}_0 \quad \text{Padé-Approximation}$$

$\hookrightarrow \exp_m(\underline{A}t) \underline{y}_0$

Variablenwechsel $\hat{\underline{y}} = \underline{S}^{-1} \underline{y} \Rightarrow$ entkoppeln

$$\begin{cases} \dot{\hat{\underline{y}}}_1 = \lambda_1 \hat{\underline{y}}_1 \\ \vdots \\ \dot{\hat{\underline{y}}}_d = \lambda_d \hat{\underline{y}}_d \end{cases} \Rightarrow \hat{\underline{y}}_i(t) = (\underline{S}^{-1} \underline{y}_0)_i e^{\lambda_i t} \quad \text{für } i \in \mathbb{R}$$

$$\underline{y}(t) = \underline{S} \begin{bmatrix} e^{\lambda_1 t} & & \\ & \ddots & \\ & & e^{\lambda_d t} \end{bmatrix} \underline{S}^{-1} \underline{y}_0$$

ok für kleines d oder exakt/analytisch.
sonst instabil \rightsquigarrow d gross, \underline{A} dünnbesetzt: Krylov-Verfahren.Krylov: für \underline{A} gilt es $\underline{V} \in \mathbb{C}^{d \times m}$
mit orthonormalen Spalten.

$$\underline{V}_m^H \underline{A} \underline{V}_m = \underline{H}_m \quad m \times m \quad \text{mit } m \ll d$$

Lobare Hessenberg Matrix.

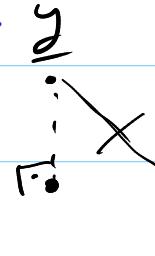
$$\underline{y}(t) \in \mathbb{R}^d$$

\mathcal{Z}

$$\begin{aligned} \underline{u}_m(t) \in \mathcal{K}_m(\underline{A}, \underline{y}_0) &= \text{span}\{\underline{y}_0, \underline{A}\underline{y}_0, \dots, \underline{A}^{m-1}\underline{y}_0\} \\ &= \text{span}\{\underline{v}_1, \dots, \underline{v}_m\} \quad \text{Spalten von } \underline{V} \text{ unB.} \end{aligned}$$

$$\dot{\underline{y}}(t) - \underline{A} \underline{y}(t) = 0$$

$\underline{u}_m(t)$ so dass $(\dot{\underline{u}}_m(t) - \underline{A} \underline{u}_m(t)) \perp \underline{x}_m$



$$\langle \underline{w}, \dot{\underline{u}}_m(t) - \underline{A} \underline{u}_m(t) \rangle = 0 \text{ für alle } \underline{w} \in \mathcal{K}_m$$

Ersetze $\begin{cases} \dot{\underline{y}}(t) = \underline{A} \underline{y}(t) \\ \underline{y}(0) = \underline{y}_0 \end{cases}$ durch

finde $\underline{u}_m(t) \in \mathcal{K}_m$ so dass

$$\langle \underline{w}, \dot{\underline{u}}_m(t) - \underline{A} \underline{u}_m(t) \rangle = 0 \text{ für alle } \underline{w} \in \mathcal{K}_m$$

$$\underline{u}_m(t) \in \mathcal{K}_m = \text{span} \{ \underline{v}_1, \dots, \underline{v}_m \}$$

$$\underline{u}_m(t) = \sum_{k=1}^m c_k(t) \underline{v}_k \quad \underline{c}(t) = \begin{bmatrix} c_1(t) \\ \vdots \\ c_m(t) \end{bmatrix}$$

$$\underline{u}_m(0) = \underline{v}_1 = \frac{1}{\| \underline{v}_1 \|} \underline{y}_0 \quad (\text{der erste in krylov/Arnoldi})$$

Einsetzen:

$$\left\langle \underline{w}, \sum_{k=1}^m c_k(t) \underline{v}_k - \sum_{k=1}^m c_k(t) \underline{A} \underline{v}_k \right\rangle = 0$$

für alle $\underline{w} \in \mathcal{K}_m$ ($\underline{A}, \underline{z}_0$)

Wähl' $\underline{w} = \underline{v}_1$

$$\langle \underline{v}_1, \sum_{k=1}^m c_k(t) \underline{v}_k \rangle = \langle \underline{w}, \sum_{k=1}^m c_k(t) \underline{A} \underline{v}_k \rangle$$

$$\Leftrightarrow \sum_{k=1}^m c_k(t) \langle \underline{v}_1, \underline{v}_k \rangle = \sum_{k=1}^m c_k(t) \langle \underline{v}_1, \underline{A} \underline{v}_k \rangle$$

II
0 für $k \neq 1$
1 für $k = 1$

$$\underline{v}_1^\top \underline{A} \underline{v}_k = (H_m)_{1k}$$

$$\Rightarrow c_1(t) = \sum_{k=1}^m (H_m)_{1k} c_k(t)$$

Für $\underline{w} = \underline{w}_2, \dots, \underline{w}_m \Rightarrow$

$$\Rightarrow \dot{\underline{c}}(t) = \underline{H}_m \underline{c}(t)$$

$$\underline{y}(0) = \underline{y}_0 \Rightarrow \underline{c}(0) = \|\underline{y}_0\| \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \in \mathbb{R}^m$$

mit $m < d \Rightarrow \exp^m(\underline{H}_m)$ Pode' ist
stetig!

$$\Rightarrow \underline{c}(t) = \exp^m(\underline{H}_m t) \underline{c}(0)$$

$$\Rightarrow \underline{u}_m(t) = \sum_{k=1}^m \underline{c}_k(t) \underline{v}_k = \|\underline{y}_0\| \underline{v}_m e^{\underline{H}_m t} \begin{bmatrix} 0 \\ \vdots \\ 0 \end{bmatrix}$$

2. Fall $\dot{\underline{y}}(t) = \underline{A} \underline{y}(t) + \underline{g}(t)$ inhomogener Fall

$$\underline{y}(t) = e^{\underline{A}(t-t_0)} \underline{y}_0 + \int_{t_0}^t e^{\underline{A}(t-s)} \underline{g}(s) ds$$

Formel der Variation der Konstanten

3. Fall

$$\sim \begin{cases} \dot{\underline{y}}(t) = \underline{A}(t) \underline{y}(t) \\ \underline{y}(t_0) = \underline{y}_0 \end{cases}$$

Unter bestimmten Voraussetzungen

$$\underline{y}(t) = e^{\underline{\Sigma}(t, t_0)} \underline{y}_0$$

$$\underline{\Sigma} = \sum_{k=1}^{\infty} \underline{\Sigma}_k$$

$$\underline{\Sigma}_1 = \int_{t_0}^t \underline{A}(z_1) dz_1$$

$$\underline{\Sigma}_2 = \frac{1}{2} \int_{t_0}^t \int_{t_0}^{z_1} [\underline{A}(z_1), \underline{A}(z_2)] dz_2 dz_1$$

$$\underline{\Sigma}_3 = \frac{1}{12} \int_{t_0}^t \int_{t_0}^{z_1} \int_{t_0}^{z_2} \left(\begin{aligned} & [[\underline{A}(z_1), \underline{A}(z_2)], \underline{A}(z_3)] + \\ & [\underline{A}(z_1), [\underline{A}(z_2), \underline{A}(z_3)]] \end{aligned} \right) dz_3 dz_2 dz_1$$

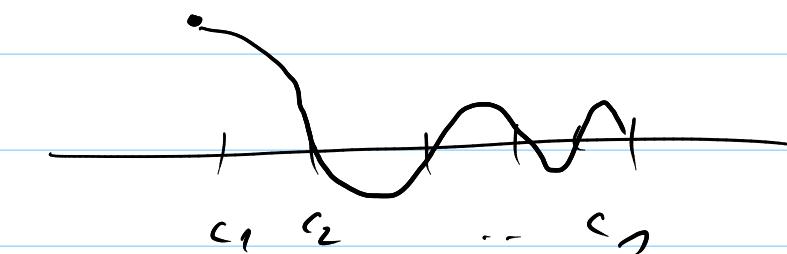
Magnus Entwicklung.

$$[[\underline{A}, \underline{B}] = \underline{A}\underline{B} - \underline{B}\underline{A} \text{ Kommutator}]$$

IdeeStatt $\underline{\dot{y}} = \underline{\underline{A}}(t) \underline{y}$ löse $\underline{\dot{\hat{y}}} = \underline{\hat{\underline{A}}}(t) \underline{\hat{y}}$ Vorteil: Integration nur für Polynome ist \Rightarrow
einfach exakt berechnen.

wobei

$$\underline{\hat{\underline{A}}}(t) = \sum_{i=1}^s l_i(t) \underline{\underline{A}}(t_n + c_i h)$$

 $l_i(t) = \text{Lagrange-Polynom in } t_n + c_i h$ $c_i = \text{Quadraturknoten in } [t_0, t_1]$ $\underline{\hat{\underline{A}}}(t) = \text{Polynom vom Grad } (s-1) \text{ in } t \text{ auf } [t_n, t_n + h]$ $\underline{\hat{\underline{A}}}(t_n + c_i h) = \underline{\underline{A}}(t_n + c_i h) \quad \text{für } i = 1, 2, \dots, s$ 

Dann

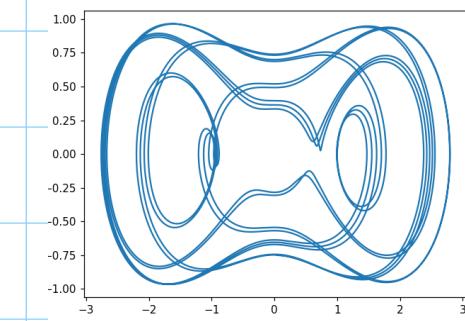
Magnus Entwicklung für $\underline{\dot{\hat{y}}} = \underline{\hat{\underline{A}}}(t) \underline{\hat{y}}$ $\underline{\hat{\underline{A}}}(t)$ glatt

Man kann zeigen:

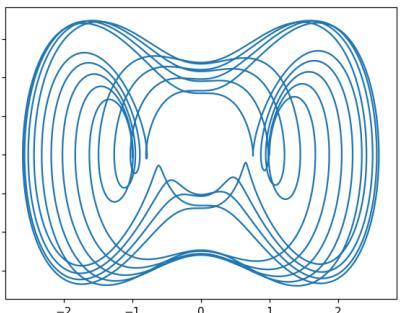
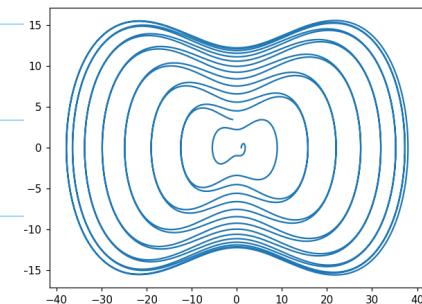
Rest in der Magnusentwicklung. $\underline{\underline{\Sigma}}$ ist $O(t^5)$
noch 4 Terme.

Theorem $(b_i, c_i)_{i=1, \dots, s}$ Quadraturformel
der Ordnung $p=1$

$$y(t_n + h) - \underline{\hat{y}}(t_n + h) = O(h^{p+1})$$



Bsp Mathieu-Gleichung.



§ 11 Exponentielle Integratoren

$$\begin{cases} \dot{\underline{y}} = \underline{f}(\underline{y}) \\ \underline{y}(0) = \underline{y}_0 \end{cases} \quad \text{autonom mit } f \text{ stetig differenzierbar}$$

Idee der Linearisierung $\underline{\dot{y}} = D\underline{f}(\underline{y})$

$$\dot{\underline{y}} = \boxed{\underline{\dot{y}}} + \underbrace{\underline{f}(\underline{y}) - \underline{\dot{y}}}_{\text{linsar } g(\underline{y})}$$

Variation der Konstanten:

$$\underline{y}(h) = e^{\underline{\dot{y}} h} \underline{y}_0 + \int_0^h e^{\underline{\dot{y}}(h-s)} g(\underline{y}(s)) ds$$

Ersetze $\underline{y}(s)$ durch $\underline{y}_0 \Rightarrow$ "Quadratur"/Approximation.

$$\int_0^h e^{\underline{\dot{y}}(h-s)} g(\underline{y}(s)) ds \approx \int_0^h e^{\underline{\dot{y}}(h-s)} g(\underline{y}_0) ds = h \ell(h \underline{\dot{y}}) g(\underline{y}_0)$$

Notiere / Definiere:

$$\ell(z) = \frac{e^z - 1}{z} = \sum_{n=1}^{\infty} \frac{1}{n!} z^{n-1} = \sum_{n=0}^{\infty} \frac{z^n}{(n+1)!}$$

$$\text{Für Matrizen: } \ell(A) = \sum_{n=0}^{\infty} \frac{1}{(n+1)!} A^n = (e^A - I) A^{-1}$$

Beweis

$$\int_0^h e^{\underline{\dot{y}}(h-s)} g(\underline{y}_0) ds = \int_0^h \sum_{n=0}^{\infty} \frac{1}{n!} (\underline{\dot{y}}(h-s))^n g(\underline{y}_0) ds =$$

\uparrow Unterschon

$$= \int_0^h (h-s)^n ds$$

$$= \sum_{n=0}^{\infty} \frac{1}{n!} \underline{\dot{y}}^{(n)} (-1)^n \frac{(h-s)^{n+1}}{n+1} \Big|_{s=0}^{s=h} g(\underline{y}_0) =$$

$$= \sum_{n=0}^{\infty} \frac{1}{n!} \frac{\partial^n}{\partial h^n} g(\underline{y}_0) = h \sum_{n=0}^{\infty} \frac{1}{(n+1)!} \frac{\partial^n h^n}{\partial h^n} g(\underline{y}_0) = h f(\underline{\partial} h) g(\underline{y}_0)$$

$f(\underline{\partial} h)$

$$\Rightarrow \underline{y}(h) \approx \underline{y}_0 + h f(\underline{\partial} h) \underline{f}_{\underline{y}_0}$$

exponentielles Eulerverfahren.

$$\underline{\partial} = \underline{\partial} f(\underline{y}_0)$$

$$f(h\underline{\partial}) = \left(e^{h\underline{\partial}} - I \right) (h\underline{\partial})^{-1}$$

teuer für grosses d .

Bem Definition von $\underline{g}(\underline{y}_0) = \underline{f}(\underline{y}_0) - \underline{\partial} \underline{y}_0$

$$h f(\underline{\partial} h) \underline{g}(\underline{y}_0) = h f(\underline{\partial} h) \underline{f}(\underline{y}_0) - h f(\underline{\partial} h) \underline{\partial} \underline{y}_0$$

Nehme

$$h f(\underline{\partial} h) \underline{\partial} \underline{y}_0 = h \sum_{n=0}^{\infty} \frac{1}{(n+1)!} \underline{\partial}^n h^n \underline{\partial} \underline{y}_0 = e^{\underline{\partial} h} \underline{y}_0 - \underline{y}_0$$

$$\Rightarrow h f(\underline{\partial} h) \underline{g}(\underline{y}_0) = h f(\underline{\partial} h) \underline{f}(\underline{y}_0) - e^{\underline{\partial} h} \underline{y}_0 + \underline{y}_0$$

Bem Für grosses d kann man das Krylov-Verfahren für $e^{\underline{\partial} h}$ verwenden!

$$f(A) b = \bigvee_{n=1}^m f(H_n) \begin{bmatrix} 1 \\ \vdots \\ 0 \end{bmatrix}$$

aus Krylov-Verfahren mit $\mathcal{F}_m(A, b)$

Somit erhalten wir zusammen:

$$\underline{y}(h) \approx e^{\underline{\partial} h} \underline{y}_0 + h f(\underline{\partial} h) \underline{f}(\underline{y}_0) - e^{\underline{\partial} h} \underline{y}_0 + \underline{y}_0$$

Bem Stabilitätsfunktion. $S(z) = e^z$

\Rightarrow das ideale Stabilitätsgetriebe!

da exakt für $\underline{\dot{y}} = A \underline{y} + g$ konstant

Verallgemeinertes: exponentielle RK-Verfahren.

$$\underline{\vartheta} = \underline{D}\underline{f}(\underline{x})$$

semi-implizite Euler: $\underline{\vartheta}_1 = \underline{\vartheta}_0 + \boxed{(\underline{\underline{I}} - h\underline{\underline{\vartheta}})^{-1} h \underline{f}(\underline{x}_0)}$

exponentielle Euler: $\underline{\vartheta}_1 = \underline{\vartheta}_0 + \boxed{\ell(h\underline{\underline{\vartheta}})} h \underline{f}(\underline{x}_0)$

Idee: ersetze $\frac{1}{1-z}$ durch $\ell(z) = \frac{e^z - 1}{z}$ in RöW

$$R_i = \ell(h\underline{\underline{\vartheta}}) \left(f(\underline{x}_i) + h\underline{\underline{\vartheta}} \sum_{j=1}^{i-1} \underline{\vartheta}_{ij} \underline{k_j} \right)$$

$$\underline{x}_i = \underline{\vartheta}_0 + h \sum_{j=1}^{i-1} \underline{\alpha}_{ij} \underline{k_j}$$

$$\underline{\vartheta}_1 = \underline{\vartheta}_0 + h \sum_{i=1}^n b_i \underline{x}_i$$

explizite RK: $\ell(z) = 1$ und $\underline{\underline{\vartheta}} = \underline{\underline{0}}$

RöW

$$\ell(z) = \frac{1}{1-z}$$

$$\ell(z) = \frac{e^z - 1}{z}$$

ODE	nicht-steife	ster-f.	oscillat. sit.
method	IVP-Solve	IVP-Solve (method=)	exp
	explizit	implicit	
	RK 4,5, adaptiv		

stabilität? $h < \frac{1}{\lambda}$
unterstnden h muss klein sein.
splitting
Erhaltung. wichtig.

- Quadratur FFT { Quadratur
- Fourier mit Anwendung an Differentialgleichg. ..
- Numerische LA: QR, s.v.d. → PCA.

EV, EV

↓ Arnoldi

exp.

→ Ausgleichsproblem

↓

M.L. (A.I.) $\boxed{\ddot{o}}$

c10 Lineare ODEs (Seite 139)

c11 Exponentielle Integratoren (Seite 143)

c1. Quadratur
1.1 Grundlagen (Seite 1):
QFormel, Knoten, gewichte, alg. & exp. Konvergenz,
Polynomiale Interpolation, Lagrange Polynome,
Ordnung einer QFormel, Fehler, zusammen gesetzte QFormel,
MPR, TR, SR, Referenzintervalle, Fehler

1.2 Quadratur in \mathbb{R}^d (Seite 8)
1.3 Adaptive Quadratur (Seite 9)
1.4 Gauss-Quadratur (Seite 12)

c2 Trigonometrische (Fourier) Approximation
2.1 Grundlagen (Seite 15)
2.2 Diskrete Fourier Transformation (Seite 17)
2.3 Clenshaw-Curtis-Quadratur (Seite 26)

c3 Einfache Verfahren fuer ODEs
3.1 Lokale Linearisierung (Seite 28)
3.2 Stoermer-Verlet (Seite 33)
3.3 Splitting Verfahren (Seite 37)
3.4 Lineare Transportgleichung (Seite 47)

c4 Runge-Kutta Verfahren
4.1 Grundidee (Seite 52)
4.2 Kollokation (Seite 56)
4.3 Adaptivitaet (Seite 57)
4.4 Partitionierte Runge-Kutta Verfahren (Seite 58)

c5 Nichtlineare algebraische Gleichungen

5.1 Konvergenz, Fixpunktiteration (Seite 61)
5.2 Newton-Verfahren (Seite 64)
5.3 Anwendungen zur Optimierung:
BFGS, Gradienten-Verfahren (sehr kurz, Details bei DNNs) (Seite 67)

c6 Steife Differentialgleichungen

6.1 Einfuehrung (Seite 68)
6.2 Stabilitaet der Runge-Kutta Verfahren (Seite 70)
6.3 Linear-Implizite Einschrittverfahren, Rosenbock-Manner Methoden (Skript) (Seite 73)
naechstes Mal ein bisschen mehr ueber ROW schreiben

c7 Intermezzo ueber Numerische Lineare Algebra (Seite 76)

c8 Ausgleichsrechnung
8.1 Lineare Ausgleichsrechnung: via Normalgleichung (Seite 84)
8.2 Lineare Ausgleichsrechnung: via orthogonaler Transformationen (Seite 86)
8.3 PCA und LSQ (Seite 90)
8.4 Lineare Ausgleichsrechnung mit linearen Nebenbedingungen (Seite 108)
8.5 Nichtlineare Ausgleichsrechnung (Seite 95):
Newton, Gauss-Newton, Gradienten-Verfahren, GDM, ADAM
8.6 Schaezung der Parameter aus ODEs (Seite 108)
8.7 DNNs und PNNs (Seite 113):
Backpropagation, stochastic Gradient

c9 Eigenwerte
9.1 Einfuehrung (Seite 124)
9.2 Potenzmethoden (Seite 124)
9.3 Krylov-Verfahren (Seite 131)