

# NUMERISCHE ANALYSIS

VORLESUNG VOM WS 2010/11

MARIO OHLBERGER

Institut für Numerische und Angewandte Mathematik  
Fachbereich Mathematik und Informatik  
Westfälische Wilhelms-Universität Münster

Dieses Skript beruht auf meinen Vorlesungen *Einführung in die Numerische Mathematik* und *Höhere Numerische Mathematik* vom Wintersemester 2007/2008 und Sommersemester 2008 an der Westfälische Wilhelms-Universität Münster.

Gegenüber den vorherigen Vorlesungen hat sich insbesondere die Zusammenstellung der Lehrinhalte geändert. Die Teile zu Interpolation und numerischer Quadratur bauen auf der Vorlesung vom WS 2007/2008 auf, während das Kapitel zur Numerik gewöhnlicher Differentialgleichungen auf der Vorlesung vom SS 2008 basiert.

Es besteht keine Garantie auf Richtigkeit und/oder Vollständigkeit des Manuskripts.

Mario Ohlberger

# Inhaltsverzeichnis

<b>0 Einleitung</b>	<b>1</b>
<b>1 Interpolation</b>	<b>5</b>
1.1 Polynominterpolation . . . . .	7
1.2 Funktionsinterpolation durch Polynome . . . . .	10
1.3 Dividierte Differenzen . . . . .	13
1.4 Hermite Interpolation . . . . .	17
1.5 Richardson Extrapolation . . . . .	19
1.6 Trigonometrische Interpolation . . . . .	23
1.6.1 Schnelle Fourier Transformation (FFT) . . . . .	27
1.7 Spline-Interpolation . . . . .	32
1.7.1 Kubische Spline-Interpolation . . . . .	35
<b>2 Numerische Integration</b>	<b>43</b>
2.1 Newton-Cotes Formeln . . . . .	48
2.2 Gauß-Quadraturen . . . . .	49
2.3 Romberg Verfahren . . . . .	54
<b>3 Numerik Gewöhnlicher Differentialgleichungen</b>	<b>59</b>
3.1 Einleitung . . . . .	59
3.2 Exkurs zur Theorie gewöhnlicher Differentialgleichungen . . . . .	61
3.3 Einschrittverfahren . . . . .	66
3.4 Mehrschrittverfahren . . . . .	82
3.4.1 Theorie der linearen Differenzengleichungen . . . . .	82
3.4.2 Lineare k-Schrittverfahren . . . . .	86
3.4.3 Das Extrapolationsverfahren von Gragg . . . . .	97
3.4.4 Prädiktor-Korrektor-Verfahren . . . . .	100
3.5 Steife Differentialgleichungen und Stabilitätsbegriffe . . . . .	102
3.6 Numerische Lösung von Randwertproblemen . . . . .	106
3.6.1 Sturm-Liouville Probleme . . . . .	108
3.6.2 Das Ritz-Galerkin Verfahren . . . . .	113
3.6.3 Finite Elemente Verfahren . . . . .	116
<b>4 Ausblick: Partielle Differentialgleichungen</b>	<b>121</b>
4.1 Die Wellengleichung . . . . .	122
4.2 Die Poisson Gleichung . . . . .	123
4.3 Die Wärmeleitungsgleichung . . . . .	124



# Abbildungsverzeichnis

1.1	Spline-Interpolation	6
1.2	Polynominterpolation, Beispiel 1	7
1.3	Interpolation von Funktionen, Beispiel 1.6	11
1.4	Beispiel 1.31	27
1.5	Beispiel 1.34: Treppenfunktionen	33
1.6	Beispiel 1.34: Gerade	34
1.7	B-Splines	39
1.8	Unterschiede einiger Interpolationen	41
2.1	Beispiel 2.1	44
2.2	Fehler der Quadraturen	58
3.1	Picard-Lindelöf: Grafische Darstellung von $K_M$ .	63
3.2	Lineare (AWP):Anwendung, Bakterienwachstum.	65
3.3	Runge-Kutta: Eulerverfahren	72
3.4	Runge-Kutta: verbessertes Eulerverfahren	72
3.5	Runge-Kutta: Verfahren von Heun	73
3.6	Runge-Kutta: klassisch	73
3.7	Schätzung mittels Extrapolation	80
3.8	spezielle lineare Mehrschrittverfahren	89
4.1	Erste und zweite Mode einer schwingenden Saite.	123
4.2	Skizze eines Gebietes $\Omega$ mit glattem Rand.	123
4.3	Skizze zu der Verträglichkeitsbedingung (4.9).	124

# Kapitel 0

## Einleitung

Das Ziel dieser Vorlesung ist eine Einführung in die numerische Analysis anhand von Differentialgleichungsproblemen. Zentrale Themen werden sein, die Interpolation von Funktionen, die numerische Integration und die numerische Differentiation im Zusammenhang mit der numerischen Behandlung von Rand- und Anfangswertproblemen.

Um das Zusammenspiel dieser Themen zu veranschaulichen, wollen wir anhand von Variationsproblemen motivieren, wie diese Bereiche der numerischen Mathematik zur Lösung konkreter Fragestellungen ineinander greifen.

### Variationsgleichungen und Galerkinapproximation

In der Physik, aber auch in anderen Anwendungsbereichen, spielt das Prinzip der *Energiemini- mierung* eine wichtige Rolle. Dieses Prinzip ermöglicht uns z.B. die Beschreibung des Verhaltens elastischer Körper. Dazu sei  $u(x, t) \in \mathbb{R}^d$  die Auslenkung/der Verschiebevektor eines elastischen Körpers im Punkt  $x$  zum Zeitpunkt  $t$  und  $\varepsilon(u) := \frac{1}{2}(\nabla u + \nabla u^\top)$  der Verzerrungstensor. Dann ist die potentielle Gesamtenergie eines belasteten, elastischen Körpers gegeben durch

$$E(u) = \frac{1}{2} \int_{\Omega} \sigma : \varepsilon(u) \, dx - \int_{\Omega} f u \, dx.$$

Dabei ist  $\sigma$  der symmetrische Spannungstensor und  $f$  eine äußere Volumenkraft. Für idealisierte Materialien ist der Spannungstensor proportional zum Verzerrungstensor, d.h. es gilt das lineare Materialgesetz

$$\sigma(u) = A \varepsilon(u)$$

mit dem symmetrischen und positiv definiten Elastizitätstensor  $A$ . Zur Modellierung elastischer Körper mit partiellen Differentialgleichungen wenden wir auf die Energie  $E(u)$  das folgende Minimierungsprinzip an.

**Definition 0.1 (Energieminimierung/Variationsprinzip)**

a) **Physikalisches Prinzip** Ein physikalisches System strebt immer in den Zustand minimaler Energie.

b) **Mathematische Äquivalenz:** Sei  $\bar{u}(x, t)$  eine Zustandsvariable und  $E(\bar{u})$  die Energie eines Systems in Abhängigkeit von  $\bar{u}$ . Dann strebt  $\bar{u}$  gegen einen optimalen Zustand  $u = u(x)$ , der die Energie minimiert, d.h. falls  $E$  genügend glatt ist gilt

$$\frac{d}{d\epsilon} E(u + \epsilon\varphi) \Big|_{\epsilon=0} = 0$$

für beliebige zulässige Variationen  $\varphi$ .

Berechnen wir

$$\frac{d}{d\epsilon} E(u + \epsilon\varphi) \Big|_{\epsilon=0} = 0$$

für die potentielle Energie elastischer Körper, so erhalten wir die Gleichung

$$\int_{\Omega} A\varepsilon(u) : \varepsilon(\varphi) dx = \int_{\Omega} f\varphi dx$$

für alle zulässigen Variationen  $\varphi$ . Nehmen wir an, dass  $u$  genügend oft differenzierbar ist, so folgt mit partieller Integration für Testfunktionen (Variationen)  $\varphi$ , die auf dem Rand von  $\Omega$  verschwinden:

$$\int_{\Omega} \left( -\nabla \cdot (A\varepsilon(u)) - f \right) \varphi dx = 0.$$

Mit dem Hauptsatz der Variationsrechnung folgt somit die Differentialgleichung

$$-\nabla \cdot (A\varepsilon(u)) = f.$$

oder in ausführlicher Notation

$$-\sum_{i=1}^d \sum_{k,l=1}^d \partial_{x_i} A_{ijkl} \varepsilon(u)_{kl} = f_i, \quad \forall j = 1, \dots, d.$$

Im einfachsten eindimensionalen Fall, der Auslenkung eines dünnen Drahtes, reduziert sich diese Differentialgleichung zu

$$-\partial_x (A \partial_x u) = f, \quad \text{b.z.w. } -\partial_x^2 u = f,$$

für  $A = Id$ . Im einfachsten mehrdimensionalen Fall, der Auslenkung einer dünnen Membran, erhalten wir

$$-\nabla \cdot (A \nabla u) = f, \quad \text{b.z.w. } -\Delta u = f,$$

für  $A = Id$ . Wir erhalten also zur Beschreibung der Auslenkung elastischer Körper in Spezialfällen die Poisson-Gleichung.

### Galerkin Verfahren

**Idee:** Energieminimierung in endlich dimensionalen Teilräumen

Die Idee der Galerkin Verfahren beruht auf dem Prinzip der Energieminimierung. Sei also  $V$  ein Funktionenraum und  $E : V \rightarrow \mathbb{R}$  ein Energiefunktional. In Abschnitt 1.1 hatten wir gesehen, dass die Lösung  $u$  vieler physikalischer Fragestellungen formal wie folgt definiert werden können:

$$u = \arg \min_{v \in V} E(v).$$

Aus diesem kontinuierlichen Minimierungsproblem erhält man ein diskretes Minimierungsproblem, wenn man den Funktionenraum  $V$  durch einen endlichdimensionalen Teilraum  $V_h \subset V$  ersetzt. Somit lässt sich die Lösung  $u_h \in V_h$  eines allgemeinen Galerkin Verfahrens wie folgt schreiben

$$u_h = \arg \min_{v_h \in V_h} E(v_h).$$

Analog zum kontinuierlichen Variationsprinzip, ist die diskrete Lösung  $u_h$  dann charakterisiert durch

$$\frac{d}{d\varepsilon} E(u_h + \varepsilon v_h) \Big|_{\varepsilon=0} = 0, \quad \text{für alle } v_h \in V_h,$$

falls  $E$  genügend regulär ist. Da  $V_h$  endlichdimensional ist können wir uns bei dieser Variation auf eine Basis von  $V_h$  einschränken. Sei also  $\Phi := \{\varphi_i | i = 1, \dots, N\}$  eine Basis von  $V_h$ , d.h.  $N = \dim(V_h)$  und  $u_h = \sum_{i=1}^N u_i \varphi_i$  die zugehörige Basisdarstellung von  $u_h$ , so folgt

$$\frac{d}{d\varepsilon} E\left(\sum_{i=1}^N u_i \varphi_i + \varepsilon \varphi_j\right) \Big|_{\varepsilon=0} = 0, \quad \text{für alle } j = 1, \dots, N.$$

Dies ist ein System von  $N$  linearen oder nichtlinearen Gleichungen für die Unbekannten  $u_i, i = 1, \dots, N$ , das mit numerischen Methoden gelöst werden kann.

Galerkinapproximationen erhält man aus diesem allgemeinen Prinzip durch spezielle Wahl des endlichdimensionalen Teilraums  $V_h$  und zugehöriger Basis  $\Phi$  mit der Eigenschaft, dass

$$\frac{d}{d\varepsilon} E(\varphi_i + \varepsilon \varphi_j) \Big|_{\varepsilon=0} \neq 0$$

nur für eine kleine Anzahl von Paaren  $(i, j)$  gilt.

### Beispiel in einer Raumdimension

Wir betrachten das Energiefunktional eines elastischen Drahtes in einer Raumdimension, dass in der einfachsten Form gegeben ist durch:

$$E(u) := \int_0^1 \frac{1}{2} \partial_x u^2 + f u.$$

Ein Minimierer dieses Funktionals erfüllt

$$\frac{d}{d\varepsilon} E(\partial_x u + \varepsilon \partial_x \varphi) \Big|_{\varepsilon=0} = 0.$$

Wir berechnen

$$\begin{aligned} \frac{d}{d\varepsilon} E(\partial_x u + \varepsilon \varphi) &= \frac{d}{d\varepsilon} \int_0^1 \frac{1}{2} (\partial_x u + \varepsilon \partial_x \varphi)^2 + f(u + \varepsilon \varphi) \\ &= \frac{d}{d\varepsilon} \int_0^1 (\partial_x u + \varepsilon \partial_x \varphi) \partial_x \varphi + f \varphi. \end{aligned}$$

Also folgt

$$0 = \frac{d}{d\varepsilon} E(u + \varepsilon \varphi) \Big|_{\varepsilon=0} = \frac{d}{d\varepsilon} \int_0^1 \partial_x u \partial_x \varphi + f \varphi.$$

Bezeichnen wir mit  $(\cdot, \cdot)$  das  $L^2$ -Skalarprodukt auf dem Intervall  $(0, 1)$ , so lautet unser Problem also: Finde eine Funktion  $u \in V$ , so dass für alle Testfunktionen  $\varphi \in V$  gilt

$$(\partial_x u, \partial_x \varphi) = (f, \varphi). \quad (1)$$

Dabei sei  $V$  ein geeigneter Funktionenraum. Sei nun  $V_h \subset V$  ein endlichdimensionaler Teilraum von  $V$  der Dimension  $\dim(V) = N$ , dann ist eine endlichdimensionale Approximation  $u_h$  von  $u$  gegeben durch :

Finde eine Funktion  $u_h \in V_h$ , so dass für alle Testfunktionen  $\varphi_h \in V_h$  gilt

$$(\partial_x u_h, \partial_x \varphi_h) = (f, \varphi_h). \quad (2)$$

Ist  $(\varphi_1, \dots, \varphi_N)$  eine Basis von  $V_h$ , so können wir die Approximation  $u_h$  in dieser Basis darstellen, d.h.

$$u_h = \sum_{i=1}^N u_i \varphi_i.$$

Dabei sind  $u_i$  die Koeffizienten der Basisdarstellung von  $u_h$ . Da es in der Variationsformulierung (2) ausreicht mit den Basisfunktionen von  $V_h$  zu testen, folgt mit der Basisdarstellung von  $u_h$  für alle  $j = 1, \dots, N$ :

$$\begin{aligned} & (\partial_x u_h, \partial_x \varphi_j) = (f, \varphi_j), \\ \implies & \sum_{i=1}^N u_i (\partial_x \varphi_i, \partial_x \varphi_j) = (f, \varphi_j). \end{aligned}$$

Definieren wir die Matrix  $S$  und Vektoren  $U, F$  durch

$$\begin{aligned} S_{ji} &:= (\partial_x \varphi_i, \partial_x \varphi_j), \\ U_i &:= u_i, \\ F_j &:= (f, \varphi_j), \end{aligned}$$

so ist das discrete Problem (2) also äquivalent zur Lösung des linearen Gleichungssystems

$$SU = F.$$

Wir sehen an diesem Beispiel, dass wir zur numerischen Lösung des Variationsproblems insbesondere numerische Methoden zur Berechnung der Integrale  $(\partial_x u_h, \partial_x \varphi_j)$ , b.z.w.  $(f, \varphi_j)$  benötigen.

Integrale beliebiger Funktionen können in der Regel nicht in geschlossener Form angegeben werden. Andererseits ist es sehr einfach Polynome analytisch zu integrieren. Eine Möglichkeit beliebige Integrale zu approximieren besteht daher darin, diese Funktionen zunächst durch Polynome zu approximieren und diese approximierenden Polynome dann zu integrieren.

Dies motiviert, dass wir uns in Kapitel 1 zunächst mit der Polynominterpolation von Funktionen beschäftigen, um anschließend in Kapitel 2 die darauf aufbauenden Methoden zur numerischen Integration zu studieren. Mit diesen Vorbereitungen werden wir uns dann in Kapitel 3 mit der numerischen Lösung von Anfangswertproblemen und Randwertproblemen beschäftigen. Zur Approximation von Randwertproblemen, werden wir die gerade vorgestellte Methode wieder aufgreifen.

# Kapitel 1

## Interpolation

Sei  $\{\Phi(x, a_0, \dots, a_n) \mid a_0, \dots, a_n \in \mathbb{R}\}$  eine Familie von Funktionen mit  $x \in \mathbb{R}$ , deren Elemente durch  $(n+1)$  Parameter  $a_0, \dots, a_n \in \mathbb{R}$  gegeben sind.

**Aufgabe:** Zu  $(x_k, f_k) \in \mathbb{R}^2$ ,  $k = 0, \dots, n$  mit  $x_i \neq x_k$  für  $i \neq k$ , finde Parameter  $a_0, \dots, a_n$ , so dass

$$\Phi(x_k, a_0, \dots, a_n) = f_k \text{ für } k = 0, \dots, n.$$

Falls  $\Phi$  linear von seinen Parametern abhängt, spricht man von einem **linearen Interpolationsproblem**.  $(x_k, f_k)$  sind zum Beispiel Messdaten oder diskrete Werte aus einem anderen numerischen Verfahren, oder  $f_k = f(x_k)$  für eine Funktion  $f \in C^0$  und  $x_0, \dots, x_n$  sind die **Stützstellen**, an denen  $f$  interpoliert werden soll.

**Beispiel:(Polynominterpolation)**

$V \subset C^0(\mathbb{R})$  Vektorraum und  $\dim(V) = n+1$ ,  $\varphi_0, \dots, \varphi_n$  Basis von  $V$ .

Setze  $\Phi(x, a_0, \dots, a_n) := \sum_{k=0}^n a_k \varphi_k(x)$ .

Sei etwa  $V = \mathbb{P}_n$ ,  $\varphi_n(x) = x^k$ , d.h.  $\Phi(x, a_0, \dots, a_n) = \sum_{k=0}^n a_k x^k$ .

Problem: Finde ein Polynom höchstens  $n$ -ten Grades, so dass  $p(x_k) = f_k$ .

**Weitere wichtige Beispiele:**

Trigonometrische Interpolation

$$\Phi(x, a_0, \dots, a_n) = a_0 + a_1 e^{ix} + a_2 e^{2ix} + \dots + a_n e^{nix} = a_0 + \sum_{k=1}^n a_k (\cos(kx) + i \cdot \sin(kx))$$

Exponentielle Interpolation (nicht linear)

$$\Phi(x, a_0, \dots, a_n, \lambda_0, \dots, \lambda_n) = a_0 e^{\lambda_0 x} + \dots + a_n e^{\lambda_n x}$$

Rationale Interpolation (nicht linear)

$$\Phi(x, a_0, \dots, a_n, b_0, \dots, b_m) = \frac{a_0 + a_1 x + \dots + a_n x^n}{b_0 + b_1 x + \dots + b_m x^m}$$

Erweitertes Problem: Hermite-Interpolation

Es werden nicht nur Funktionswerte  $f_k$  an den Stützstellen  $x_k$  vorgeschrieben, sondern auch Werte für die Ableitung von  $\Phi$ .

Beispiel:  $p(x) = \sum_{k=0}^N a_k x^k$ ,  $N = 2(n+1) - 1$  mit  $p(x_k) = f_k$ ,  $p'(x_k) = d_k$  für gegebene  $(x_k, f_k, d_k) \in \mathbb{R}^3$  ( $k = 0, \dots, n$ ).

### Spline-Interpolation

Sei  $q \in \mathbb{N}$  fest.

**Gesucht:**  $\Phi \in C^q$  mit  $\Phi(x_k) = f_k$  und  $\Phi|_{[x_k, x_{k+1}]} \in \mathbb{P}_r$ , d.h.  $\Phi$  ist stückweise polynomial.

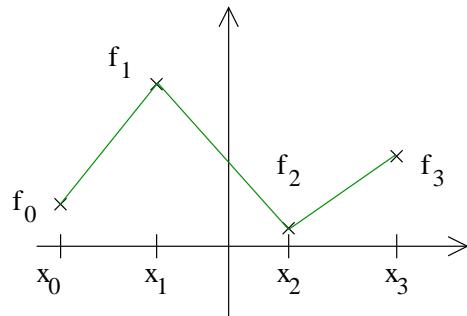


Abbildung 1.1: Spline-Interpolation

Abbildung 1.1 zeigt das Problem für  $q = 0$  und  $r = 1$ , d.h.  $\Phi \notin C^1$ .

## 1.1 Polynominterpolation

**Gegeben:**  $(x_0, f_0), \dots, (x_n, f_n) \in \mathbb{R}^2$  mit  $x_k \neq x_i$  ( $k \neq i$ ).

**Gesucht:**  $p \in \mathbb{P}_N$  mit  $p(x_i) = f_i$  ( $i = 0, \dots, n$ ) mit  $N$  minimal.

**Beispiel:**  $(x_0, f_0) = (0, 0)$ ,  $(x_1, f_1) = (1, 1)$

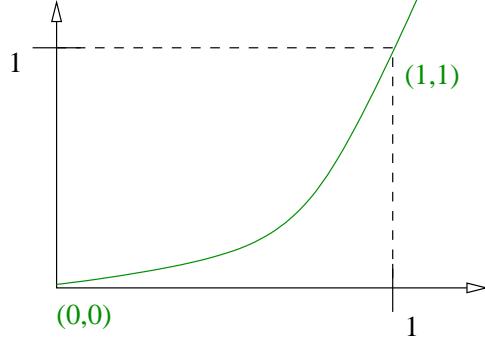


Abbildung 1.2: Polynominterpolation, Beispiel 1

Abbildung 1.2 verdeutlicht das Beispiel, denn  $p(x) = x^N$  erfüllt das Interpolationsproblem für alle  $N \geq 1$ . Gesuchtes Polynom ist dann:  $p(x) = x$ .

### Satz 1.1

Es existiert genau ein  $p \in \mathbb{P}_n$  mit  $p(x_i) = f_i$  ( $i = 0, \dots, n$ ).

*Beweis:* Sei  $\varphi_0, \dots, \varphi_n$  eine Basis von  $\mathbb{P}_n$ . Dann ist das Interpolationsproblem äquivalent dazu, einen Vektor  $a = (a_0, \dots, a_n)^\top$  zu finden, welcher das LGS  $Aa = f$  löst mit  $A = (\alpha_{ik}) \in \mathbb{R}^{(n+1) \times (n+1)}$ ,  $\alpha_{ik} = \varphi_k(x_i)$  und  $f = (f_0, \dots, f_n)^\top \in \mathbb{R}^{n+1}$

$$\begin{aligned} \text{Es gilt: } Aa = f &\iff \sum_{k=0}^n \alpha_{ik} a_k = f \\ &\iff \sum_{k=0}^n a_k \varphi_k(x_i) = f_i \\ &\iff p(x_i) = f_i \text{ mit } p(x) = \sum_{k=0}^n a_k \varphi_k(x) \end{aligned}$$

Existenz und Eindeutigkeit: Es reicht zu zeigen, dass  $A$  regulär ist.

Sei also  $a = (a_0, \dots, a_n)^\top$  Lösung von  $\sum_{k=0}^n a_k \varphi_k(x_i) = 0$  ( $i = 0, \dots, n$ ). Dann hat

$p(x) = \sum_{k=0}^n a_k \varphi_k(x) \in P_n$  die  $(n+1)$ -Nullstellen  $x_0, \dots, x_n$ . Folglich muß  $p \equiv 0$  sein, und somit  $a_0 = \dots = a_n = 0$ .

Also gilt  $Aa = 0 \implies a = 0 \implies A$  injektiv  $\implies A$  regulär.

Also ist das Interpolationsproblem eindeutig lösbar. □

**Bemerkung:** Der Beweis von Satz 1.1 erlaubt es, Verfahren zur Lösung des Interpolationsproblems zu konstruieren. Dazu muss man eine Basis  $\varphi_0, \dots, \varphi_n$  von  $\mathbb{P}_n$  wählen und das  $(n+1) \times (n+1)$  LGS  $Aa = f$  lösen.

Wählt man die Monombasis  $\varphi_0(x) = 1, \varphi_1(x) = x, \varphi_2(x) = x^2, \dots, \varphi_n(x) = x^n$  (also  $\varphi_i(x) = x^i$ ), so gilt  $p(x) = \sum_{i=0}^n \alpha_i \varphi_i(x)$  und es entsteht folgende Matrix:

$$A = \begin{pmatrix} \varphi_0(x_0) & \cdots & \varphi_n(x_0) \\ \vdots & \ddots & \vdots \\ \varphi_0(x_n) & \cdots & \varphi_n(x_n) \end{pmatrix} = \begin{pmatrix} 1 & x_0 & \cdots & x_0^n \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_n & \cdots & x_n^n \end{pmatrix} \in \mathbb{R}^{(n+1) \times (n+1)}$$

$A$  heißt die **Vandermondsche Matrix**; sie ist sehr schlecht konditioniert und voll besetzt. Daher ist das LGS  $Aa = f$  sehr aufwändig zu lösen.

Die Darstellung des Interpolationspolynoms  $\sum_{k=0}^n a_k x^k$  heißt **Normalform**. Diese Darstellung wird in der Praxis nicht verwendet. Andere Darstellungen sind numerisch effizienter, auch wenn dadurch das Interpolationspolynom nicht verändert wird!

### a) Lagrange-Form des Interpolationsproblems

Am einfachsten ist  $Aa = f$  zu lösen, falls  $A = \mathbb{I}$ , d.h.  $\varphi_k(x_i) = \delta_{ki}$  ( $0 \leq k, i \leq n$ ). Wir erhalten mit  $\varphi_k(x_i) = 0$  für  $k \neq i$  den Ansatz

$$\varphi_k(x) = c \prod_{\substack{i=0 \\ i \neq k}}^n (x - x_i).$$

Aus  $\varphi_k(x_k) = 1$  folgt dann

$$c = \left( \prod_{\substack{i=0 \\ i \neq k}}^n (x_k - x_i) \right)^{-1}$$

und somit erhalten wir

$$\varphi_k(x) = \prod_{\substack{i=0 \\ i \neq k}}^n \frac{(x - x_i)}{x_k - x_i}, \quad (k = 0, \dots, n).$$

#### Definition 1.2 (Lagrange-Polynome)

Die Polynome

$$l_k^n(x) := \prod_{\substack{i=0 \\ i \neq k}}^n \frac{(x - x_i)}{x_k - x_i}$$

heißen **Lagrange-Polynome**.  $(l_0^n, \dots, l_n^n)$  bilden eine Basis von  $\mathbb{P}_n$  und  $p(x) = \sum_{k=0}^n f_k l_k^n(x)$  ist das Interpolationspolynom zu  $(x_0, f_0), \dots, (x_n, f_n)$ .

Für die Lagrange-Polynome gilt  $l_i^n(x_j) = \delta_{ij}$ .

**Bemerkung:** Diese Darstellung ist für die Theorie sehr brauchbar. Mit dieser Konstruktion zu arbeiten ist angenehm, weil für  $p(x) = \sum_{i=1}^n f_i l_i^n(x)$  gilt

$$p(x_j) = \sum_{i=1}^n f_i l_i^n(x_j) = f_j.$$

**Nachteil:** Die Basispolynome ändern sich bei Hinzunahme von weiteren Stützstellen.

### b) Newton-Form des Interpolationsproblems

Wähle eine Basis von  $\mathbb{P}_n$ , so dass  $A$  eine untere  $\Delta$ -Matrix wird

$$\varphi_k(x) := \prod_{j=0}^{k-1} (x - x_j), \quad (k = 0, \dots, n) \implies \varphi_k \in \mathbb{P}_k.$$

$$\begin{aligned} \text{etwa: } \varphi_0(x) &= 1 \left( \text{verwende Konvention } \prod_{j=j_0}^{j_n} a_j = 1 \text{ falls } j_n < j_0 \right) \\ \varphi_1(x) &= (x - x_0) \\ \varphi_2(x) &= (x - x_0)(x - x_1) \\ &\vdots \end{aligned}$$

Damit ist  $A$  untere  $\Delta$ -Matrix, da

$$\varphi_k(x_i) = 0 \text{ für } i < k.$$

#### Definition 1.3 (Newton-Polynome)

Die Polynome

$$N_k^n := \prod_{j=0}^{k-1} (x - x_j)$$

heißen **Newton-Polynome** und das Interpolationspolynom  $p(x) = \sum_{k=0}^n a_k N_k^n(x)$  heißt in **Newton-Form**.

$$\begin{aligned} \text{Es gilt: } a_0 &= \frac{f_0}{\varphi_0(x_0)} = f_0, \\ a_1 &= \frac{(f_1 - \varphi_0(x_1)a_0)}{\varphi_1(x_1)} = \frac{f_1 - f_0}{x_1 - x_0} =: f[x_0, x_1], \\ a_2 &= \frac{(f_2 - \varphi_0(x_2)a_0 - \varphi_1(x_2)a_1)}{\varphi_2(x_2)} \\ &= \frac{f_2 - f_1 - \frac{f_1 - f_0}{x_1 - x_0}}{x_2 - x_0} = \frac{f[x_1, x_2] - f[x_0, x_1]}{x_2 - x_0} =: f[x_0, x_1, x_2] \end{aligned}$$

Diese Koeffizienten werden berechnet über die **dividierten Differenzen**  $f[x_0, \dots, x_n]$  (siehe Abschnitt 1.3).

## 1.2 Funktionsinterpolation durch Polynome

**Gegeben:** Stützstellen  $x_0, \dots, x_n$  und  $f$  stetig.

**Gesucht:** Interpolationspolynom zu  $(x_0, f(x_0)), \dots, (x_n, f(x_n))$ .

### Satz 1.4 (Fehlerdarstellung)

Sei  $f \in C^{n+1}(a, b)$  und  $p \in \mathbb{P}_n$  das Interpolationspolynom zu den Stützstellen  $x_0, \dots, x_n$  paarweise verschieden. Dann existiert zu jedem  $x \in (a, b)$  ein  $\xi_x \in (a, b)$  mit

$$(*) \quad f(x) - p(x) = \frac{1}{(n+1)!} f^{(n+1)}(\xi_x) \cdot \prod_{k=0}^n (x - x_k)$$

*Beweis:* Für  $x = x_i$  ( $i = 0, \dots, n$ ) ist nichts zu zeigen, da  $f(x_i) = p(x_i)$  und  $\prod_{k=0}^n (x - x_k) = 0$ . Sei also  $x \neq x_i$ : Setze

$$\omega(t) := \prod_{i=0}^n (t - x_i)$$

und betrachte

$$\Phi(t) := f(t) - p(t) - \lambda \omega(t)$$

mit  $\lambda = \frac{f(x) - p(x)}{\omega(x)} \in \mathbb{R}$  (beachte  $x$  fest). Es folgt  $\Phi(x) = 0$  und  $\Phi(x_i) = 0$  ( $i = 0, \dots, n$ ) und somit hat  $\Phi$   $n+2$  Nullstellen. Nach dem Satz von Rolle folgt weiter:  $\Phi'$  hat  $n+1$  Nullstellen und folglich  $\Phi^{(n+1)}$  eine Nullstelle  $\xi_x \in (a, b)$  mit

$$0 = \Phi^{(n+1)}(\xi_x) = f^{(n+1)}(\xi_x) - (n+1)! \frac{f(x) - p(x)}{\omega(x)}$$

Also haben wir  $(*)$  bewiesen. □

### Folgerung 1.5

Seien die Voraussetzungen von Satz 1.4 erfüllt.

Dann gilt  $\|f - p\|_\infty \leq \frac{1}{(n+1)!} \|f^{(n+1)}\|_\infty \|\omega\|_\infty$  mit dem **Knotenpolynom**  $\omega(x) = \prod_{j=0}^n (x - x_j)$ .

*Beweis:* Folgt direkt aus Satz 1.4.

**Bemerkung** Folgerung 1.5 zeigt, dass die Approximation durch Polynominterpolation durch eine geeignete Wahl der Stützstellen optimiert werden kann. **Frage:** Wird der Interpolationsfehler bei wachsender Stützstellenanzahl immer kleiner? Das folgende Beispiel zeigt, dass dies i.A. nicht der Fall ist.

### Beispiel 1.6 (Runge)

Betrachten wir  $f(x) = \frac{1}{1+x^2}$ ,  $-5 \leq x \leq 5$  und  $x_n^{(n)} := -5 + kh_n$ ,  $0 \leq k \leq n$  mit  $h_n := \frac{10}{n}$  (gleichmäßige Stützstellenverteilung). Sei  $p_n(x_k^{(n)}) = f(x_k^{(n)})$ .

Man kann zeigen (siehe Abb. 1.3), dass es ein  $\tilde{x} \approx 3,6$  gibt, so dass für  $|x| < \tilde{x}$  Konvergenz vorliegt, während der Interpolationsfehler für  $|x| > \tilde{x}$  gegen unendlich geht.

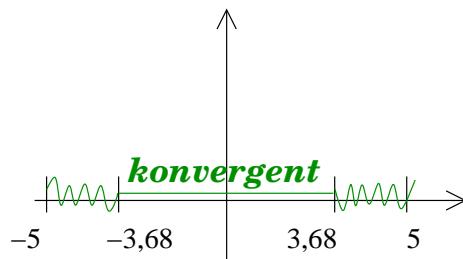


Abbildung 1.3: Interpolation von Funktionen, Beispiel 1.6

**Allgemein gilt:**

1. Für jede stetige Funktion  $f$  existiert eine Folge von Stützstellen mit  $p_n \rightarrow f$  gleichmäßig.
2. Zu jeder Folge von Stützstellen gibt es eine stetige Funktion  $f$ , so dass  $p_n \not\rightarrow f$  gleichmäßig.

**Optimale Wahl von Stützstellen für das Referenzintervall  $[-1, 1]$**

**Idee:** Wähle Stützstellen  $x_0, \dots, x_n \in [-1, 1]$ , so dass  $\|w\|_{L^\infty([-1,1])}$  minimiert wird.

**Bemerkung:** Das Knotenpolynom  $\omega(t) = \prod_{k=0}^n (t - x_k)$  ist ein normiertes Polynom  $(n+1)$ -tes Grades (d.h. Koeffizient 1 vor  $x^{n+1}$ ) und die Stützstellen  $x_0, \dots, x_n$  sind die Nullstellen von  $\omega$ . Wir erreichen also dann eine optimale Wahl der Stützstellen, wenn wir ein normiertes Polynom  $(n+1)$ -tes Grades finden, dass unter allen normierten Polynomen die  $\infty$ -Norm minimiert.

**Definition 1.7 (Tschebyschev-Polynome)**

Wir definieren die Tschebyschev-Polynome auf  $[-1, 1]$  durch

$$T_0(x) = 1, \quad T_1(x) = x, \quad T_{n+1}(x) = 2xT_n(x) - T_{n-1}(x), \quad \hat{T}_n(x) = 2^{1-n}T_n(x).$$

$$D.h. \quad T_2(x) = 2x^2 - 1, \quad T_3(x) = 4x^3 - 3x, \quad \hat{T}_2(x) = x^2 - \frac{1}{2}, \quad \hat{T}_3(x) = x^3 - \frac{3}{4}x.$$

**Satz 1.8**

Für  $x \in [-1, 1]$  gilt:

$$T_n(x) = \cos(n \cos^{-1}(x)). \quad (*)$$

Weiterhin gilt:

$$(i) \quad |T_n(x)| \leq 1,$$

$$(ii) \quad T_n \left( \cos \left( \frac{j\pi}{n} \right) \right) = (-1)^j \quad (0 \leq j \leq n),$$

$$(iii) \quad T_n \left( \cos \left( \pi \frac{2j-1}{2n} \right) \right) = 0 \quad (1 \leq j \leq n),$$

$$(iv) \quad T_n \in P_n(-1, 1),$$

$$(v) \quad \hat{T}_n \in P_n(-1, 1) \text{ mit Koeffizient 1 vor } x^n \text{ (normiertes Polynom).}$$

*Beweis:* Nach Additionstheorem gilt

$$\cos(A + B) = \cos(A) \cos(B) - \sin(A) \sin(B).$$

Also folgt

$$\cos((n+1)\Theta) = \cos(n\Theta) \cos(\Theta) - \sin(n\Theta) \sin(\Theta)$$

und

$$\cos((n-1)\Theta) = \cos(n\Theta) \cos(\Theta) + \sin(n\Theta) \sin(\Theta).$$

Zusammen erhalten wir

$$\cos((n+1)\Theta) + \cos((n-1)\Theta) = 2 \cos(n\Theta) \cos(\Theta).$$

Setze  $\Theta := \cos^{-1}(x)$ , bzw.  $x := \cos(\Theta)$ , so folgt weiter

$$\cos((n+1)\cos^{-1}(x)) = 2 \cos(n\cos^{-1}(x))x - \cos((n-1)\cos^{-1}(x))$$

d.h.  $F_n := \cos(n\cos^{-1}(x))$  genügt der Rekursionsformel von Definition 1.7. Weiter ist  $F_0(x) = 1$ ,  $F_1(x) = \cos(\cos^{-1}(x)) = x$  und somit  $F_n = T_n$ , was (\*) beweist.

Die Eigenschaften (i), (ii), (iii) folgen direkt aus (\*); (iv) und (v) folgen aus der Rekursionsformel für  $T_n$  in Definition 1.7.  $\square$

### Lemma 1.9

Sei  $p \in \mathbb{P}_n$  ein normiertes Polynom auf  $[-1, 1]$ . Dann gilt:

$$\|p\|_\infty = \max_{-1 \leq x \leq 1} |p(x)| \geq 2^{1-n} \quad \text{und} \quad \|\hat{T}_n\|_\infty = 2^{1-n}.$$

*Beweis:* Annahme: Es gibt ein normiertes Polynom  $p$  mit  $|p(x)| < 2^{1-n} \quad \forall x \in [-1, 1]$ .

Sei  $x_i = \cos\left(\frac{i\pi}{n}\right)$ . Nach Satz 1.8 (ii) folgt dann

$$(-1)^i p(x_i) \leq |p(x_i)| < 2^{1-n} = (-1)^i \hat{T}_n(x_i)$$

und hieraus

$$(-1)^i \left( \hat{T}_n(x_i) - p(x_i) \right) > 0 \quad \text{für } 0 \leq i \leq n.$$

D.h. das Polynom  $\hat{T}_n - p$  wechselt  $(n+1)$ -Mal das Vorzeichen im Intervall  $[-1, 1]$ . Da  $\hat{T}_n$  und  $p$  normierte Polynome sind, ist dies ein Widerspruch dazu, dass  $\hat{T}_n - p$  vom Grad  $n-1$  ist.

Weiter folgt aus  $|T_n(x)| \leq 1$ , dass  $|\tilde{T}_n(x)| \leq 2^{1-n}$  und mit  $\tilde{T}_n(x_i) = 2^{1-n}(-1)^i$  folgt die Behauptung.  $\square$

### Folgerung 1.10 (Optimale Wahl der Stützstellen)

Mit den Stützstellen  $x_k = \cos\left(\pi \frac{2k-1}{2(n+1)}\right)$ ,  $k = 1, \dots, n+1$  als die Nullstellen von  $T_{n+1}$  gilt, dass das Knotenpolynom gerade  $\hat{T}_{n+1}$  ist, d.h. die Maximumsnorm des Knotenpolynoms ist  $2^{1-(n+1)}$ .

## 1.3 Dividierte Differenzen

**Wiederholung:** Die Newton-Form des Interpolationspolynom ist gegeben durch  $p(x) = \sum_{k=0}^n a_k N_k(x)$  mit

$$N_k(x) = \begin{cases} 1 & : k = 0 \\ \prod_{j=0}^{k-1} (x - x_j) & : k \geq 1 \end{cases}.$$

**Gesucht:** Algorithmus zur effizienten Berechnung von  $a_0, \dots, a_n$ .

**Bemerkung:** Setze  $p_m(x) = \sum_{k=0}^m a_k N_k(x)$  für  $m \leq n$ , dann gilt  $p_m(x_j) = f_j$  ( $0 \leq j \leq m$ ) und  $p_m \in \mathbb{P}_m$ , da  $N_k \in \mathbb{P}_m$  für  $0 \leq k \leq m$ . D.h.  $p_m$  ist **das** Interpolationspolynom in  $\mathbb{P}_m$  zu den Daten  $(x_0, f_0), \dots, (x_m, f_m)$ . Insbesondere hängt  $a_k$  nur ab von  $(x_0, f_0), \dots, (x_k, f_k)$  für  $0 \leq k \leq m$ . Es wird daher die Schreibweise  $f[x_0, \dots, x_k]$  für  $a_k$  benutzt.

Beachte:  $a_m$  ist der Koeffizient vor dem  $x^m$  im Polynom  $p_m$ .

### Definition 1.11 (Dividierte Differenzen)

Seien  $i_0, \dots, i_k \in \{0, \dots, n\}$  paarweise verschieden und sei  $p_{i_0, \dots, i_k}$  das Interpolationspolynom zu den Daten  $(x_{i_0}, f_{i_0}), \dots, (x_{i_k}, f_{i_k})$ . Mit  $f[x_{i_0}, \dots, x_{i_k}]$  bezeichnen wir den Koeffizienten vor  $x^k$  im Polynom  $p_{i_0, \dots, i_k}$ .

$f[i_0, \dots, i_k]$  wird als **dividierte Differenz** der Ordnung  $k$  bezeichnet.

### Satz 1.12

- (i) Die Polynome  $p_{i_0, \dots, i_k}$  genügen der Rekursionsformel
 
$$(1) \quad p_{i_0, \dots, i_k}(x) = \frac{(x - x_{i_0})p_{i_1, \dots, i_k}(x) - (x - x_{i_k})p_{i_0, \dots, i_{k-1}}}{x_{i_k} - x_{i_0}}.$$
- (ii) Die dividierten Differenzen genügen der Rekursionsformel
 
$$(2) \quad f[x_{i_0}, \dots, x_{i_k}] = \frac{f[x_{i_1}, \dots, x_{i_k}] - f[x_{i_0}, \dots, x_{i_{k-1}}]}{x_{i_k} - x_{i_0}}, \quad f[x_{i_l}] = f_{i_l}.$$
- (iii) Die dividierten Differenzen sind unabhängig von der Reihenfolge ihrer Koeffizienten, d.h. ist  $x_{j_0}, \dots, x_{j_n}$  eine Permutation von  $x_{i_0}, \dots, x_{i_n}$ , so gilt  $f[x_{j_0}, \dots, x_{j_n}] = f[x_{i_0}, \dots, x_{i_n}]$ .

**Bemerkung:** Die dividierten Differenzen können in der Form eines Tableaus geschrieben werden.

$$\begin{array}{ll} x_0 & a_0 = f_0 \\ x_1 & f_1 \\ x_2 & f_2 \\ x_3 & f_3 \end{array} \left| \begin{array}{lll} a_1 = f[x_0, x_1] & a_2 = f[x_0, x_1, x_2] & a_3 = f[x_0, x_1, x_2, x_3] \\ f[x_1, x_2] & f[x_1, x_2, x_3] \\ f[x_2, x_3] \end{array} \right.$$

Dabei ist z.B.  $f[x_1, x_2, x_3] = \frac{f[x_2, x_3] - f[x_1, x_2]}{x_3 - x_1}$ . Beachte,  $f_k = f[x_k]$  und  $p(x) = \sum_{k=0}^n f[x_0, \dots, x_k]N_k(x)$  ist das gesuchte Interpolationspolynom.

### Beispiel 1.13

Wir betrachten die Daten

$x$	3	1	5	
$f$	1	-3	2	

Die dividierten Differenzen liefern:

3	1	$2 = \frac{-3-1}{1-3} = -\frac{3}{2}$	$-\frac{3}{8} = \frac{5/4-2}{5-3}$	
1	-3	$\frac{5}{4} = \frac{2-(-3)}{5-1}$		
5	2			

Das Interpolationspolynom ist also  $p(x) = 1 + 2(x-3) - \frac{3}{8}(x-3)(x-1)$ .

Fügen wir eine Stützstelle hinzu, so betrachten wir die Daten:

$x$	3	1	5	6	
$f$	1	-3	2	4	

Die dividierten Differenzen liefern durch hinzufügen einer “Diagonalen”:

3	1	$2$	$-\frac{3}{8}$	$\frac{7}{40}$	
1	-3	$\frac{5}{4}$	$\frac{3}{20}$		
5	2	2			
6	4				

Das Interpolationspolynom lautet:

$$p(x) = 1 + 2(x-3) - \frac{3}{8}(x-3)(x-1) + \frac{7}{40}(x-3)(x-1)(x-5)$$

*Beweis:* (von Satz 1.12)

(i) Setze  $R(x)$  als rechte Seite von (1). Zu zeigen:  $p_{i_0, \dots, i_n} = R(x)$ .

**Notation:**

$$p_k = p_{i_0, \dots, i_k}, \quad p_{k-1} = p_{i_0, \dots, i_{k-1}}, \quad q_k = p_{i_1, \dots, i_k}$$

Dann ist

$$\begin{aligned} R(x) &= \frac{(x - x_{i_0})q_k(x) - (x - x_{i_k})p_{k-1}(x)}{x_{i_k} - x_{i_0}} \\ \implies R(x_{i_0}) &= \frac{0 - (x_{i_0} - x_{i_k})f_{i_0}}{x_{i_k} - x_{i_0}} = f_{i_0}, \\ R(x_{i_k}) &= \frac{(x_{i_k} - x_{i_0})f_{i_k} - 0}{x_{i_k} - x_{i_0}} = f_{i_k}, \\ R(x_{i_l}) &= \frac{(x_{i_l} - x_{i_k})f_{i_l} - (x_{i_l} - x_{i_k})f_{i_l}}{x_{i_k} - x_{i_0}} = f_{i_l} \quad \forall 0 < l < k. \end{aligned}$$

Also ist  $R$  ist das Interpolationspolynom zu  $(x_{i_0}, f_{i_0}), \dots, (x_{i_n}, f_{i_n})$ . Aufgrund der Eindeutigkeit folgt dann  $p_{i_0, \dots, i_k} = R$ .

(ii) Aus (i) folgt, dass der Koeffizient vor  $x^k$  in  $R(x)$  durch  $\frac{f[x_{i_1}, \dots, x_{i_k}] - f[x_{i_0}, \dots, x_{i_{k-1}}]}{x_{i_k} - x_{i_0}}$  gegeben ist. Nach Definition ist dieser Koeffizient gleich  $f[x_{i_0}, \dots, x_{i_k}]$ , also folgt (ii).  $\square$

**Satz 1.14 (Weitere Eigenschaften der dividierten Differenz)**

Sei  $f \in C^0(a, b)$ ,  $x_0, \dots, x_n \in (a, b)$  paarweise verschieden und  $t$  fest gewählt mit  $t \neq x_k \forall k = 0, \dots, n$ .

(i) Wenn  $p$  das Interpolationspolynom von  $f$  an den Stützstellen  $x_0, \dots, x_n$  ist, so gilt:

$$f(t) - p(t) = f[x_0, \dots, x_n, t] \prod_{j=0}^n (t - x_j)$$

(ii) Ist  $f \in C^n(a, b)$ , so existiert ein  $\xi \in (a, b)$  mit  $f[x_0, \dots, x_n] = \frac{1}{n!} f^{(n)}(\xi)$ .

*Beweis:* (Siehe Übungsaufgaben) □

**Algorithmus 1.15 (Dividierte Differenzen)**

**Ziel:** Das ganze Tableau soll berechnet und in eine Matrix gespeichert werden. Wenn eine weitere Stützstelle hinzugefügt wird, dann reicht es die Diagonale der dividierten Differenzen auszurechnen.

$$c_{i0} := f_i$$

Für  $j = 1, \dots, n$

$$\text{Für } i = 0, n-j \\ c_{ij} := \frac{c_{i+1,j-1} - c_{i,j-1}}{x_{i+j} - x_i}$$

$$\implies c_{ij} = f[x_i, \dots, x_{i+j}] .$$

Nach Hinzunahme einer weiteren Stützstelle  $(x_{n+1}, f_{n+1})$ :

$$c_{n+1,0} := f_{n+1}$$

Für  $j = 1, \dots, n+1$

$$c_{n+1-j,j} := \frac{c_{n+1-j+1,j-1} - c_{n+1-j,j-1}}{x_{n+1} - x_{n+1-j}}$$

**Satz 1.16 (Auswertung des Interpolationspolynoms)**

**1. Fall:** Die Koeffizienten  $a_0, \dots, a_n$  seien bekannt. Dann kann folgendes Schema zur Auswertung benutzt werden (**Horner-Schema**):

$$\begin{aligned} p(x) &= \sum_{k=0}^n a_k \underbrace{\prod_{j=0}^{k-1} (x - x_j)}_{:= \chi_j} \\ &= (((\dots ((a_n \chi_{n-1} + a_{n-1}) \chi_{n-2} + a_{n-2}) \chi_{n-3} \dots) \chi_1 + a_1) \chi_0 + a_0) \end{aligned}$$

**Algorithmus:**

$$p := a_n$$

Für  $k = n-1, \dots, 0$

$$p := p(x - x_k) + a_k$$

**2. Fall:** Das Interpolationspolynom  $p$  soll nur an einer Stelle ausgerechnet werden ohne vorher die Koeffizienten zu berechnen (**Neville-Schema**):

Sei  $p_{i_0, \dots, i_k} \in P_n$  das Interpolationspolynom zu  $(x_{i_0}, f_{i_0}), \dots, (x_{i_k}, f_{i_k})$ . Das Neville-Schema verwendet die Rekursion aus 1.12 (i):

$x_0$	$f_0 = p_0(x)$	$p_{0,1}(x)$	$\cdots$	$p_{0,1,\dots,n}(x)$
$x_1$	$f_1 = p_1(x)$	$p_{1,2}(x)$	$\cdots$	
$\vdots$	$\vdots$	$\vdots$		
$x_n$	$f_n = p_n(x)$	$p_{n,n+1}(x)$		

$p_{0,1,\dots,n}(x)$  ist gesucht, also der letzte Eintrag in der Tabelle.

### Beispiel 1.17

Gegeben:

$x_i$	3	1	5	6
$f_i$	1	-3	2	4

Gesucht:  $p(0)$

(i) Mit **dividierten Differenzen** erhält man

$$p(x) = 1 + 2(x-3) - \frac{3}{8}(x-3)(x-1) + \frac{7}{40}(x-3)(x-1)(x-5)$$

Mit dem **Horner-Schema** folgt anschließend:

$$\begin{aligned} p(0) &= \left( \left( \left( \frac{7}{40}(0-5) - \frac{3}{8} \right) (-1) + 2 \right) (-3) + 1 \right) \\ &= \left( \left( \frac{5}{4} + 2 \right) (-3) + 1 \right) \\ &= \left( -\frac{39}{4} + 1 \right) = -\frac{35}{4} \end{aligned}$$

(ii) Mit dem **Neville-Schema** erhält man

$x_0$	$f_0$			
3	1	$\frac{(0-3)(-3)-(0-1)1}{1-3} = -5$	$-\frac{79}{8}$	$-\frac{35}{4}$
1	-3	$\frac{(0-1)2-(0-5)(-3)}{5-1} = -\frac{17}{4}$	$-\frac{7}{2}$	
5	2	$\frac{(0-5)4-(0-6)2}{6-5} = -8$		
6	4			

## 1.4 Hermite Interpolation

**Gegeben:**  $x_0, \dots, x_m$  paarweise verschieden und für jede Stützstelle  $x_i$  Werte  $c_{ij} \in \mathbb{R}$  für  $0 \leq j \leq m_i - 1$ .

**Gesucht:** Ein Polynom  $p$  mit  $p^{(j)}(x_i) = c_{ij}, \forall i = 0, \dots, m, j = 0, \dots, m_i - 1$ .

Die Anzahl der Bedingungen ist  $n + 1 := m_0 + m_1 + \dots + m_m$ , d.h. es macht Sinn  $p \in \mathbb{P}_n$  zu suchen.

### Satz 1.18

Es existiert genau ein  $p_n \in \mathbb{P}_n$ , welches die Bedingungen des Hermite Interpolationspolynoms erfüllt.

*Beweis:* (analog zu Satz 1.1) □

### Satz 1.19 (Fehlerdarstellung für Hermite Interpolation)

Seien  $f \in C^{m+1}(a, b)$  und  $a \leq x_0 < \dots < x_m \leq b$ . Mit  $m_0, \dots, m_m \in \{1, \dots, n+1\}$  und  $n+1 = \sum_{j=0}^n m_j$

Sei  $p_n \in \mathbb{P}_n$  das Hermite Interpolationspolynom zu den Daten

$$\begin{aligned} & (x_0, f(x_0)), \dots, (x_0, f^{(m_0-1)}(x_0)) \\ & (x_1, f(x_1)), \dots, (x_1, f^{(m_1-1)}(x_1)) \\ & \vdots \qquad \qquad \vdots \\ & (x_m, f(x_m)), \dots, (x_m, f^{(m_m-1)}(x_m)) \end{aligned}$$

Dann existiert für alle  $x \in [a, b]$  ein  $\xi_x \in [a, b]$  mit

$$f(x) - p_n(x) = \frac{f^{(n+1)}(\xi_x)}{(n+1)!} \Omega(x)$$

wobei  $\Omega(x) := \prod_{k=0}^n (x - x_k)^{m_k}$ .

*Beweis:* (analog zu Satz 1.4) □

### Beispiel 1.20 (Newton-Form und dividierte Differenzen)

**Gesucht:**  $p \in \mathbb{P}_2$  mit  $p(x_0) = c_{00}, p'(x_0) = c_{01}, p(x_1) = c_{10}$

Durch dividierte Differenzen:

$x_i$	$f_i$	
$x_0$	$c_{00}$	$f[x_0, x_0]$
$x_0$	$c_{00}$	$f[x_0, x_1]$
$x_1$	$c_{10}$	

Nach Satz 1.14 gilt für  $t \in (a, b)$ :  $\exists \xi \in (x_0, t)$  mit  $f[x_0, t] = f'(\xi)$ .

Ist  $f' \in C^0(a, b)$  so gilt:

$$\lim_{t \rightarrow x_0} f[x_0, t] = f'(x_0)$$

Daher macht es Sinn  $f[x_0, x_0] = f'(x_0)$  zu setzen. Im Beispiel folgt dann:

$x_0$	$c_{00}$	$c_{01}$	$\frac{f[x_0, x_1] - f[x_0, x_0]}{x_1 - x_0}$
$x_0$	$c_{00}$	$\frac{c_{10} - c_{00}}{(x_1 - x_0)}$	
$x_1$	$c_{10}$		

Wir erhalten also im Beispiel  $f[x_0, x_0, x_1] = \frac{c_{10} - c_{00}}{(x_1 - x_0)^2} - \frac{c_{01}}{x_1 - x_0}$  und setzten das Interpolationspolynom in der Newtonform an:

$$p(x) = f[x_0] + f[x_0, x_0](x - x_0) + f[x_0, x_0, x_1](x - x_0)^2.$$

Dieser Ansatz lässt sich verallgemeinern zu:

$$p_n(x) = \sum_{k=0}^n f[z_0, \dots, z_k] \prod_{j=0}^{k-1} (x - z_j)$$

mit

$$\begin{aligned} z_0 &= \dots = z_{m_0-1} = x_0, \\ z_{k_0} &= \dots = z_{m_0-m_1-1} = x_1, \\ &\vdots \\ &\text{usw.} \end{aligned}$$

**Satz 1.21 (Rekursionsformel für dividierte Differenzen)**

Sei  $i_0, \dots, i_n \in \{0, \dots, n\}$  und o.B.d.A  $z_{i_0} \leq z_{i_1} \leq \dots \leq z_{i_k}$ . Dann gilt

$$f[z_{i_0}, \dots, z_{i_k}] = \begin{cases} \frac{f[z_{i_1}, \dots, z_{i_k}] - f[z_{i_0}, \dots, z_{i_{k-1}}]}{z_{i_k} - z_{i_0}} & : z_{i_k} \neq z_{i_0} \\ \frac{1}{k!} f^{(k)}(z_{i_0}) & : z_{i_k} = z_{i_0} \end{cases}$$

**Bemerkung 1.22**

- (i) Bei der Hermite Interpolation werden gerade die Werte vorgeschrieben, die bei den Dividierten Differenzen Tableau nicht durch die Rekursion gegeben sind.
- (ii) Interpolationsprobleme, bei denen nicht für alle  $j = 0, \dots, m_i - 1$  die Werte  $p^{(j)}(x_i)$  vorgeschrieben werden, sind nicht so einfach zu lösen (vergleiche Birkoff-Interpolation in den Übungsaufgaben).

## 1.5 Richardson Extrapolation

**Gegeben:** Eine Funktion  $a : (0, \infty) \rightarrow \mathbb{R}$ .

**Gesucht:**  $a(0) = \lim_{h \searrow 0} a(h)$ .

**Idee:** Wähle  $h_0, \dots, h_n$ , setze  $a_k = a(h_k)$  und bestimme das Interpolationspolynom zu  $(h_0, a_0), \dots, (h_n, a_n)$  und approximiere  $a(0)$  durch  $p(0)$ .

### Beispiel 1.23

#### (i) Regel von L'Hospital

Berechne  $\lim_{x \rightarrow 0} \frac{\cos(x)-1}{\sin(x)}$ , d.h.  $a(h) = \frac{\cos(h)-1}{\sin(h)}$ .

$$\begin{aligned} \text{Setze: } h_0 &= \frac{1}{8}, \quad a_0 = -6.258151 \cdot 10^{-2} \\ h_1 &= \frac{1}{16}, \quad a_1 = -3.126018 \cdot 10^{-2} \\ h_2 &= \frac{1}{32}, \quad a_2 = -1.562627 \cdot 10^{-2} \\ \implies p(0) &= -1.02 \dots \cdot 10^{-2} \end{aligned}$$

Es ist  $a(0) = \lim_{h \searrow 0} \frac{\cos(h)-1}{\sin(h)} = \lim_{h \searrow 0} \frac{-\sin(h)}{\cos(h)} = 0$ .

#### (ii) Numerische Verfahren (etwa Differentiation von $f \in C^1$ )

Wähle  $a(h) = \frac{f(h)-f(-h)}{2h}$ .

Ist  $f$  analytisch, so gilt die **asymptotische Entwicklung**

$$a(h) = a(0) + \sum_{i=1}^{\infty} \alpha_{2i} h^{2i} \text{ mit } a(0) = f'(0)$$

und

$$\begin{aligned} f(h) &= f(0) + \sum_{i=1}^{\infty} f^{(i)}(0) h^i, \\ f(-h) &= f(0) + \sum_{i=1}^{\infty} f^{(i)}(0) (-h)^i = \sum_{i=1}^{\infty} f^{(i)}(0) (-1)^i h^i. \end{aligned}$$

Das heißt,  $a(h)$  ist eine gerade Funktion ( $a(h) = a(-h)$ ) und das Interpolationspolynom solle nur  $h^{2k}$ -Terme enthalten.

Sei  $f(x) = \sin(x) \implies a(h) = \frac{\sin(h)-\sin(-h)}{2h} = \frac{\sin(h)}{h}$ , so folgt für  $p(x) = q(x^2), q \in \mathbb{P}_1$ :

$$\begin{aligned} h_0 &= \frac{1}{8}, \quad a_0 = 0.9973 \\ h_0 &= \frac{1}{16}, \quad a_0 = 0.99934 \\ h_0 &= \frac{1}{32}, \quad a_0 = 0.99983 \end{aligned}$$

$$\implies p(0) = 0.999999926.$$

**Satz 1.24 (Extrapolationfehler)**

Gelte für  $a : (0, \infty) \rightarrow \mathbb{R}$  die asymptotische Entwicklung

$$a(h) = a(0) + \sum_{j=1}^n \alpha_j h^{qj} + a_{n+1}(h) h^{q(n+1)}$$

mit  $q > 0$  und  $a_{n+1}(h) = \alpha_{n+1} + o(1)$ . Dabei seien  $\alpha_1, \dots, \alpha_{n+1} \in \mathbb{R}$  unabhängig von  $h$ . Sei  $(h_k)_{k \in \mathbb{N}}$  eine monoton fallende Folge,  $h_k > 0$  und  $\frac{h_{k+1}}{h_k} \leq \rho < 1$  für  $\rho > 0$  unabhängig von  $k$ . Mit  $p_n^{(k)} \in \mathbb{P}_n$  bezeichnen wir das Interpolationspolynom in  $h$  zu den Daten  $(h_k^q, a(h_k)), \dots, (h_{k+n}^q, a(h_{k+n}))$ . Dann gilt:

$$|a(0) - p_n^{(k)}(0)| = O(h_k^{q(n+1)}) \text{ für } k \rightarrow \infty.$$

*Beweis:* Setze  $z = h^q$ ,  $z_k = h_k^q$ . In der Lagrange Darstellung ist das Interpolationspolynom gegeben durch  $p_n^{(k)}(z) = \sum_{i=0}^n a(h_{k+i}) L_{k,i}^n(z)$  mit  $L_{k,i}^n(z) = \prod_{\substack{l=0 \\ l \neq i}}^n \frac{z - z_{k+l}}{z_{k+i} - z_{k+l}}$ . Mit der asymptotischen Entwicklung

von  $a$  folgt

$$\begin{aligned} p_n^{(k)}(0) &= \sum_{i=0}^n \left( a(0) + \sum_{j=1}^n \alpha_j z_{k+i}^j + \alpha_{n+1} z_{k+i}^{n+1} + o(1) z_{k+i}^{n+1} \right) L_{k,i}^n(0) \\ &= a(0) \sum_{i=0}^n L_{k,i}^n(0) + \sum_{j=1}^{n+1} \alpha_j \sum_{i=0}^n z_{k+i}^j L_{k,i}^n(0) + o(1) \sum_{i=0}^n z_{k+i}^{n+1} L_{k,i}^n(0). \end{aligned}$$

Um die Summanden  $z^r L_{k,i}^n(0)$  zu berechnen, verwenden wir die Fehlerdarstellung aus Satz 1.4 mit  $f(z) = z^r$ ,  $r = 0, \dots, n+1$  und dem Interpolationspolynom  $q_n^{(k)}$  zu den Daten  $(z_k, f(z_k)), \dots, (z_{k+n}, f(z_{k+n}))$ , d.h.  $q_n^{(k)}(z) = \sum_{i=0}^n f(z_{k+i}) L_{k,i}^n(z)$ , bzw.  $q_n^{(k)}(0) = \sum_{i=0}^n z_{k+i}^r L_{k,i}^n(0)$ .

$$\begin{aligned} \text{Es gilt } f(0) - q_n^{(k)}(0) &= \frac{1}{(n+1)!} f^{(n+1)}(\xi_0) \prod_{i=0}^n (0 - z_{k+i}) \text{ und somit folgt} \\ - \sum_{i=0}^n z_{k+i}^r L_{k,i}^n(0) &= \frac{1}{(n+1)!} f^{(n+1)}(\xi_0) (-1)^{n+1} \prod_{i=0}^n z_{k+i} - f(0) \\ &= \begin{cases} -1 & : r = 0 \\ 0 & : r = 1, \dots, n \\ (-1)^{n+1} \prod_{i=0}^n z_{k+i} & : r = n+1 \end{cases} \end{aligned}$$

Damit erhalten wir

$$p_n^{(k)}(0) = a(0) + \alpha_{n+1} (-1)^n \prod_{i=0}^n z_{k+i} + \sum_{i=0}^n o(1) z_{k+i}^{n+1} L_{k,i}^n(0).$$

Es gilt:

$$\begin{aligned} \left| \alpha_{n+1} (-1)^n \prod_{i=0}^n z_{k+i} \right| &\leq |\alpha_{n+1}| \prod_{i=0}^n z_k = |\alpha_{n+1}| z_k^{(n+1)} \\ &= |\alpha_{n+1}| h_k^{q(n+1)} = O(h_k^{q(n+1)}). \end{aligned}$$

Außerdem gilt  $|L_{k,i}^n(0)| = \prod_{\substack{l=0 \\ l \neq i}}^n \frac{1}{\left| \frac{z_{k+i}}{z_{k+l}} - 1 \right|} \leq C(\rho, n, q)$ , unabhängig von  $k$ :

$$\implies \left| \sum_{i=0}^n o(1) L_{i,k}^n(0) z_{k+i}^{n+1} \right| \leq C(\rho, n, q) o(1) z_k^{n+1} \leq C(\rho, n, q) o(1) h_k^{q(n+1)} = O(h_k^{q(n+1)}),$$

$$\implies |p_n^{(k)}(0) - a(0)| = O(h_k^{q(n+1)}).$$

**Algorithmus: (Richardson Extrapolation)**

Zur Berechnung von  $p_n^{(k)}(0)$  eignet sich das Neville Schema:

$$p_n^{(k)}(0) = p_{n-1}^{(k+1)}(0) + \frac{p_{n-1}^{(k+1)}(0) - p_{n-1}^{(k)}(0)}{\frac{z_k}{z_{k+n}} - 1}$$

mit  $p_n^{(k)}(z) = p_{k,k+1,\dots,k+n}(z)$ .

Mit  $a_{k,n} := p_n^{(k-n)}(0)$  erhält man als Rekursion für  $a_{k,n}$ :

$$a_{k,n} = a_{k,n-1} + \frac{a_{k,n-1} - a_{k-1,n-1}}{\left(\frac{h_{k-n}}{h_k}\right)^q - 1}.$$

Als Tableau mit Startwert  $a_{k,0} = a(h_k)$  ergibt sich dann

$$\begin{array}{ccccccc} h_0 & a_{0,0} & & & & & \\ h_1 & a_{1,0} & a_{1,1} & & & & \\ h_2 & a_{2,0} & a_{2,1} & a_{2,2} & & & \\ \vdots & \vdots & \vdots & \vdots & \ddots & & \\ h_k & a_{k,0} & a_{k,1} & a_{k,2} & \cdots & a_{k,k} & \\ \vdots & \vdots & \vdots & \vdots & & \vdots & \end{array}$$

### Beispiel 1.25

Berechnung von  $e = \lim_{n \rightarrow \infty} (1 + \frac{1}{n})^n = \lim_{h \rightarrow 0} (1 + h)^{\frac{1}{h}}$ , d.h.  $a(h) = (1 + h)^{\frac{1}{h}}$ .

Wähle  $h_k = 2^{-k} \implies a_{k,0} = a(h_k) = (1 + 2^{-k})^{2^k}$ .

$$\implies a_{0,0} = 2, \quad a_{1,0} = \frac{9}{4}, \quad a_{2,0} = \frac{625}{256} \approx 2.44.$$

Als Tableau:

$$\begin{array}{ccc} n = 0 & n = 1 & n = 2 \\ \begin{array}{ccc} h_0 = 1 & 2 \\ h_1 = \frac{1}{2} & \frac{9}{4} \\ h_2 = \frac{1}{4} & \frac{625}{256} & \frac{337}{128} \end{array} & \begin{array}{c} \frac{5}{2} \\ \frac{257}{96} \end{array} & \approx 2.67708 \end{array}$$

Es folgt also z.B.  $a_{22} \approx 2.67708$  als Approximation von  $e \approx 2.718281828$ . Bereits  $a_{5,5}$  liefert  $a_{5,5} \approx 2.71827$ , während  $a_{5,0} \approx 2.6769 \approx a_{22}$ .

Nebenrechnung:

$$\begin{aligned} a_{1,1} &= a_{1,0} + \frac{a_{1,0} - a_{0,0}}{\left(\frac{h_0}{h_1}\right) - 1} = \frac{9}{4} + \frac{\frac{9}{4} - 2}{\frac{1}{2} - 1} = \frac{5}{2} \\ a_{2,1} &= a_{2,0} + \frac{a_{2,0} - a_{1,0}}{2 - 1} = \frac{337}{128} \end{aligned}$$

Allgemein:  $\frac{h_{k-n}}{h_k} = 2^{-k+n+k} = 2^n$

$$a_{2,2} = a_{2,1} + \frac{a_{2,1} - a_{1,1}}{2^2 - 1} = \frac{257}{96}$$

**Aufwand:** Die Richardson Extrapolation eignet sich vor allem, falls  $a(h)$  sehr teuer zu berechnen ist, etwa falls für den Aufwand  $A(h)$  gilt  $A(h) = O(1/h)$ . In unserem Beispiel folgt dann für  $a(1/32)$  der Aufwand  $A(h) = 32$ , während der Aufwand zur Berechnung von  $a_{22}$  gegeben ist durch  $A(1) + A(1/2) + A(1/4) = 7$ .

## 1.6 Trigonometrische Interpolation

**Gegeben:**  $(x_0, y_0), \dots, (x_n, y_n)$ ,  $x_k$  paarweise verschieden,  $x_k \in [0, \omega)$ ,  $\omega > 0$ .

**Gesucht:** Periodische Funktion  $t_n : \mathbb{R} \rightarrow \mathbb{R}$  mit Periode  $\omega$ , welche die Daten interpoliert, d.h.  $\forall x \in \mathbb{R} : t_n(x + \omega) = t_n(x)$  und  $t_n(x_k) = y_k$ ,  $k = 0, \dots, n$ .

**Annahme** (O.B.d.A):  $\omega = 2\pi$ .

Die Fourier Analysis legt nahe, die gesuchte Funktion  $t_n$  aus Funktionen der Form

$$\begin{aligned} 1, \cos(x), \cos(2x), \dots \\ \sin(x), \sin(2x), \dots \end{aligned}$$

zusammensetzen.

**Ansatz:** Suche Koeffizienten  $(a_k, b_k)$  mit

$$t_n(x) = \frac{a_0}{2} + \sum_{k=1}^m (a_k \cos(kx) + b_k \sin(kx)) + \frac{\Theta}{2} a_{m+1} \cos((m+1)x),$$

wobei

$$\Theta := \begin{cases} 0 & : n \text{ gerade} \\ 1 & : n \text{ ungerade} \end{cases}, \quad m := \begin{cases} \frac{n}{2} & : n \text{ gerade} \\ \frac{n-1}{2} & : n \text{ ungerade} \end{cases}.$$

Viele Aussagen der diskreten Fourier Analysis lassen sich kompakter über  $\mathbb{C}$  formulieren, wobei die **Eulersche Formel**

$$e^{iz} = \cos(z) + i \cdot \sin(z)$$

benutzt wird.

### Definition 1.26 (Trigonometrische Polynome)

Wir definieren den Raum der Trigonometrischen Polynome vom Grad  $n$  durch

$$T_n := \left\{ t^* : \mathbb{C} \rightarrow \mathbb{C} \mid t^*(z) = \sum_{k=0}^n c_k e^{ikz} \right\}$$

$$\text{Mit } w := e^{iz} \text{ gilt } t^*(z) = \sum_{k=0}^n c_k w^k.$$

### Lemma 1.27

(i) Seien  $(a_k)_{k=0}^{\infty}$ ,  $(b_k)_{k=0}^{\infty}$  reelle Folgen. Setze  $b_0 = 0$ ,  $a_{-k} = a_k$ ,  $b_{-k} = -b_k$  und  $c_k = \frac{1}{2}(a_k - i \cdot b_k)$  für  $k \in \mathbb{Z}$ . Dann gilt:

$$\frac{a_0}{2} + \sum_{k=1}^m (a_k \cos(kx) + b_k \sin(kx)) = \sum_{k=-m}^m c_k e^{ikx}.$$

(ii) Sei  $(c_k)_{k=-m}^m$ ,  $c_k \in \mathbb{C}$ . Setze  $a_k = c_k + c_{-k}$ ,  $b_k = i \cdot (c_k - c_{-k})$ ,  $k = 0, \dots, m$ . Dann gilt:

$$\frac{1}{2}a_0 + \sum_{k=1}^m (a_k \cos(kx) + b_k \sin(kx)) = \sum_{k=-m}^m c_k e^{ikx}.$$

*Beweis:* (Ohne Beweis)

**Voraussetzungen und Notationen für diesen Abschnitt**

□

- Äquidistante Stützstellen, d.h.  $x_k = \frac{2\pi}{n+1}k$ ,  $k = 0, \dots, n$ .
- $w(x) := e^{ix}$ ,  $E_k(x) := e^{ikx} = w^k(x)$  ( $k \in \mathbb{Z}$ ).
- $\hat{w} := e^{i \cdot \frac{2\pi}{n+1}} \in \mathbb{C}$ ,  $w_k := w(x_k) = e^{ik \cdot \frac{2\pi}{n+1}} = \hat{w}^k$  ( $k \in \mathbb{Z}$ ).

**Lemma 1.28**

- (i)  $(E_k)_{k \in \mathbb{Z}}$  bilden ein **Orthonormalsystem**, d.h.  $\langle E_k, E_l \rangle = \delta_{kl}$ .
- (ii)  $w_k^{n+1} = 1$ , d.h.  $w_0, \dots, w_n$  sind die  $(n+1)$  Einheitswurzeln und  $w_0, \dots, w_n$  sind paarweise verschieden.
- (iii)  $w_k^l = w_l^k$ ,  $w_{n+1-k}^l = w_{-k}^l$ ,  $w_k^{-l} = \overline{w_k^l}$ .
- (iv)  $\frac{1}{n+1} \sum_{j=0}^n w_j^{k-l} = \delta_{kl}$ ,  $0 \leq k, l \leq n$ .
- (v) Für festes  $j \in \mathbb{N}$ :  $\sum_{k=0}^n \sin(jx_k) = 0$ ,  $\sum_{k=0}^n \cos(jx_k) = \begin{cases} n+1 & : (n+1) \mid j \\ 0 & : \text{sonst} \end{cases}$ .

*Beweis:* (Siehe Übungsaufgaben)

□

**Satz 1.29 (Trigonometrische Interpolation in  $\mathbb{C}$ )**

Zu gegebenen Daten  $y_0, \dots, y_n \in \mathbb{C}$  existiert genau ein  $t_n^* \in T_n$  mit  $t_n^*(x_k) = y_k$  für  $k = 0, \dots, n$ .

Die Koeffizienten  $c_k$  sind gegeben durch:

$$c_k = \frac{1}{n+1} \sum_{j=0}^n y_j e^{-ijx_k} = \frac{1}{n+1} \sum_{j=0}^n y_j w_k^{-j}.$$

*Beweis:* Um die Existenz und Eindeutigkeit zu zeigen, verwenden wir Satz 1.1, der auch im Komplexen gezeigt werden kann. Es existiert daher genau ein  $p \in \mathbb{P}_n$  mit  $p(x) = \sum_{k=0}^n c_k x^k$  mit  $c_k \in \mathbb{C}$  und  $p(w_k) = y_k$  ( $k = 0, \dots, n$ ) (Interpolationspolynom zu  $(w_0, y_0), \dots, (w_n, y_n)$ ).

Mit  $t_n^*(x) = \sum_{k=0}^n c_k e^{ikx}$  gilt:  $t_n^*(x_l) = \sum_{k=0}^n c_k e^{ikx_l} = \sum_{k=0}^n c_k w_l^k = p(w_l) = y_l$ .

Um die explizite Darstellung der Koeffizienten zu zeigen, verwenden wir Lemma 1.28:

$$\begin{aligned}\sum_{j=0}^n y_j w_k^{-j} &= \sum_{j=0}^n p(w_j) w_k^{-j} = \sum_{j=0}^n \left( \sum_{l=0}^n c_l w_j^l \right) w_k^{-j} \\ &= \sum_{l=0}^n c_l \left( \sum_{j=0}^n w_j^{l-k} \right) = \sum_{l=0}^n c_l (n+1) \delta_{lk} = (n+1) c_k.\end{aligned}$$

Also folgt  $c_k = \frac{1}{n+1} \sum_{j=0}^n y_j w_k^{-j}$ . □

**Satz 1.30 (Trigonometrische Interpolation in  $\mathbb{R}$ )**

Für  $n \in \mathbb{N}$  gegeben, setze  $m = \begin{cases} \frac{n}{2} & : n \text{ gerade} \\ \frac{n-1}{2} & : n \text{ ungerade} \end{cases}$ , und  $\Theta = \begin{cases} 0 & : n \text{ gerade} \\ 1 & : n \text{ ungerade} \end{cases}$ .

Zu gegebenen Daten  $y_0, \dots, y_n \in \mathbb{R}$  existiert genau eine Funktion

$$t_n(x) = \frac{a_0}{2} + \sum_{k=1}^m (a_k \cos(kx) + b_k \sin(kx)) + \frac{\Theta}{2} a_{m+1} \cos((m+1)x)$$

mit  $t_n(x_k) = y_k$ ,  $k = 0, \dots, n$ .

Für die Koeffizienten  $a_k, b_k$  gilt:

$$a_k = \frac{2}{n+1} \sum_{j=0}^n y_j \cos(jx_k),$$

$$b_k = \frac{2}{n+1} \sum_{j=0}^n y_j \sin(jx_k).$$

*Beweis:* 1. Sei  $t_n^*$  das komplexe Interpolationspolynom zu  $(x_0, y_0), \dots, (x_n, y_n)$ . Nach Satz 2.29 gilt:

$$t_n^*(x) = \sum_{k=0}^n c_k e^{ikx} \text{ mit } c_k = \frac{1}{n+1} \sum_{j=0}^n y_j w_k^{-j}.$$

Setze  $c_{-k} = c_{n+1-k}$ ,  $k = 1, \dots, m$ , d.h.  $c_{-1} = c_n$ ,  $c_{-2} = c_{n-1}, \dots, c_{-m} = \begin{cases} c_{m+1} & : n \text{ gerade} \\ c_{m+2} & : n \text{ ungerade} \end{cases}$ .

Setze  $a_k = c_k + c_{-k}$ ,  $b_k = i \cdot (c_k - c_{-k})$ ,  $k = 0, \dots, m$  und  $a_{m+1} = \begin{cases} 0 & : n \text{ gerade} \\ 2c_{m+1} & : n \text{ ungerade} \end{cases}$ .

Nach Lemma 1.27 gilt dann:

$$(*) \frac{a_0}{2} + \sum_{k=1}^m (a_k \cos(kx) + b_k \sin(kx)) = \sum_{k=-m}^m c_k e^{ikx}.$$

Es folgt

$$\begin{aligned} y_l = \sum_{k=0}^n c_k w_l^k &= \sum_{k=0}^m c_k w_l^k + \sum_{k=1}^m c_{-k} w_{n+1-k}^l + \Theta c_{m+1} w_{m+1}^l \\ &= \sum_{k=-m}^m c_k w_l^k + \Theta c_{m+1} w_{m+1}^l. \end{aligned}$$

Für  $n$  ungerade gilt:  $m+1 = \frac{n+1}{2}$  und daher

$$\begin{aligned} w_{m+1}^l &= \cos((m+1)x_l) + i \cdot \sin((m+1)x_l) \\ &= \cos((m+1)x_l) + i \cdot 0, \text{ da } (m+1)x_l = \frac{n+1}{2}l \frac{2\pi}{n+1} = l\pi. \end{aligned}$$

$$\begin{aligned} \Rightarrow y_l &= \sum_{k=-m}^m c_k w_l^k + \Theta c_{m+1} w_{m+1}^l \\ &\stackrel{(*)}{=} \frac{a_0}{2} + \sum_{k=1}^m (a_k \cos(kx_l) + b_k \sin(kx_l)) + \frac{\Theta}{2} a_{m+1} \cos((m+1)x_l) \\ &= t_n(x_l). \end{aligned}$$

2. Eindeutigkeit folgt, da das LGS, welches die Koeffizienten  $a_k, b_k$  bestimmt, für jede rechte Seite  $y_0, \dots, y_n$  lösbar ist. Daher ist die Matrix regulär.

3. Die explizite Darstellung der Koeffizienten folgt aus:

$$c_{-k} = c_{n+1-k} = \frac{1}{n+1} \sum_{j=0}^n y_j w_{n+1-k}^{-j} = \frac{1}{n+1} \sum_{j=0}^n y_j w_k^j.$$

Wir erhalten:

$$\begin{aligned} a_k &= c_k + c_{-k} = \frac{1}{n+1} \left( \sum_{j=0}^n y_j (e^{-ijx_k} + e^{ijx_k}) \right) = \frac{2}{n+1} \sum_{j=0}^n y_j \cos(jx_k), \\ b_k &= i \cdot (c_k - c_{-k}) = \frac{i}{n+1} \left( \sum_{j=0}^n y_j (e^{-ijx_k} - e^{ijx_k}) \right) = \frac{2}{n+1} \sum_{j=0}^n y_j \sin(jx_k). \end{aligned}$$

**Bemerkung:**  $t_n(x_l) = t_n^*(x_l)$ , aber im Allgemeinen ist  $t_n(x) \neq t_n^*(x)$  für  $x \neq x_l$  ( $l = 0, \dots, n$ ). Es gilt sogar  $t_n(x) \neq \operatorname{Re}(t_n^*(x))$ .  $\square$

### Beispiel 1.31

Gegeben:  $n = 2$ ,  $x_0 = 0$ ,  $x_1 = \frac{2}{3}\pi$ ,  $x_2 = \frac{4}{3}\pi$ .

Es gilt:  $\cos(x_1) = \cos(x_2) = -\frac{1}{2}$ ,  $\sin(x_1) = -\sin(x_2) =: \xi$ ,  $2x_1 = x_2$  und  $2x_2 \equiv x_1 \pmod{2\pi}$ .

$$c_0 = \frac{1}{3} (y_0 e^{-i0} + y_1 e^{-i0} + y_2 e^{-i0}) = \frac{1}{3} (y_0 + y_1 + y_2),$$

$$c_1 = \frac{1}{3} (y_0 e^{-i0} + y_1 e^{-i\frac{2}{3}\pi} + y_2 e^{-i\frac{4}{3}\pi}) = \frac{1}{3} y_0 - \frac{1}{6} (y_1 + y_2) + i \cdot \frac{\xi}{3} (y_1 - y_2),$$

$$c_2 = \frac{1}{3} (y_0 e^{-i0} + y_1 e^{-i\frac{4}{3}\pi} + y_2 e^{-i\frac{2}{3}\pi}) = \frac{1}{3} y_0 - \frac{1}{6} (y_1 + y_2) + i \cdot \frac{\xi}{3} (y_2 - y_1).$$

**Im Reellen:** ( $m = 1, \Theta = 0$ )

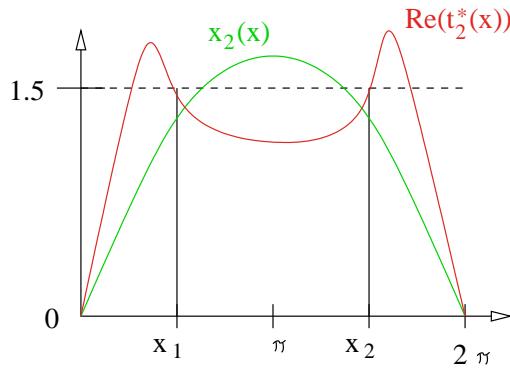


Abbildung 1.4: Beispiel 1.31

$$a_0 = \frac{2}{3} (y_0 + y_1 + y_2), \quad a_1 = \frac{2}{3} (y_0 - \frac{1}{2}y_1 - \frac{1}{2}y_2)$$

$$b_1 = \frac{2\xi}{3} (y_1 - y_2)$$

Seien  $y_0 = 0$ ,  $y_1 = y_2 = \frac{3}{2}$ , so erhalten wir

$$t_2(x) = 1 - \cos(x).$$

Dahingegen erhalten wir als Realteil des komplexen Interpolationspolynoms (siehe auch Abb. 1.4):

$$Re(t_2^*(x)) = 1 - \frac{1}{2} (\cos(x) + \cos(2x)).$$

### 1.6.1 Schnelle Fourier Transformation (FFT)

Die Schnelle Fourier Transformation wird auch **FFT** (Fast Fourier Transformation) genannt.

**Ziel:** Effiziente Berechnung von  $c_0, \dots, c_n$ . ( $a_k, b_k$ ) können dann im zweiten Schritt schnell bestimmt werden.

**Idee:** *Divide and Conquer*-Verfahren: Das Problem der Größe  $n$  wird in 2 äquivalente Probleme der Größe  $\frac{n}{2}$  aufgeteilt und separat gelöst, dann werden die beiden Lösungen wieder zu einer gesammten Lösung zusammengefügt. Am einfachsten ist die FFT darstellbar, falls  $n = 2^Q - 1$ , d.h. für  $2^Q$  Daten  $y_0, \dots, y_n$ .

Sei  $n$  ungerade und seien  $m = \frac{n-1}{2}$ ,  $l \in \{0, \dots, n\}$  fest. Dann folgt

$$\begin{aligned} c_l &= \frac{1}{n+1} \sum_{j=0}^n y_j w_j^{-l} = \frac{1}{n+1} \left( \sum_{j=0}^m y_{2j} w_{2j}^{-l} + \sum_{j=0}^m y_{2j+1} w_{2j+1}^{-l} \right) \\ &= \frac{1}{n+1} \left( \sum_{j=0}^m y_{2j} w_{2j}^{-l} + \hat{w}^{-l} \left( \sum_{j=0}^m y_{2j+1} w_{2j}^{-l} \right) \right), \quad \text{mit } \hat{w} = e^{i \frac{2\pi}{n+1}}. \end{aligned}$$

Da  $n + 1 = 2(m + 1)$  folgt:

$$c_l = \frac{1}{2} \left( \frac{1}{m+1} \sum_{j=0}^m y_{2j} w_{2j}^{-l} + \hat{w}^{-l} \frac{1}{m+1} \sum_{j=0}^m y_{2j+1} w_{2j}^{-l} \right).$$

Sei  $l_1 \equiv l \pmod{m+1}$ , d.h.  $l_1 \in \{0, \dots, m\}$  und  $l = \lambda(m+1) + l_1$   $\lambda \in \mathbb{N}$ . Dann folgt  $l = \frac{1}{2}\lambda(n+1) + l$  und somit

$$w_{2j}^{-l} = e^{-il2j\frac{2\pi}{n+1}} = e^{-i\lambda j 2\pi - i \cdot l_1 2j\frac{2\pi}{n+1}} = e^{-i\lambda j 2\pi} w_{2j}^{-l_1} = w_{2j}^{-l_1}$$

$$\implies c_l = \frac{1}{2} (c_{l_1}^{even} + c_{l_1}^{odd} \hat{w}^{-l})$$

mit

$$c_{l_1}^{even} = \frac{1}{m+1} \sum_{j=0}^m y_{2j} w_{2j}^{-l_1},$$

$$c_{l_1}^{odd} = \frac{1}{m+1} \sum_{j=0}^m y_{2j+1} w_{2j}^{-l_1}, \quad l_1 \in \{0, \dots, \frac{n+1}{2}\}.$$

Dabei sind  $c_{l_1}^{even}$ ,  $c_{l_1}^{odd}$  gerade die Koeffizienten des komplexen trigonometrischen Polynoms zu den Daten  $(x_0, y_0), (x_2, y_2), \dots, (x_{n-1}, y_{n-1})$ , bzw. zu  $(x_0, y_1), (x_2, y_3), \dots, (x_{n-1}, y_n)$ .

**Idee des Algorithmus:**

### Stützstellen ( $Q = 3$ )

$x_0, x_1, x_2, x_3, x_4, x_5, x_6, x_7$

$8 \cdot 2$

$x_0, x_2, x_4, x_6$

$4 \cdot 4$

$x_0, x_4$

$2 \cdot 8$

Rechenaufwand: 0

$48 = (3 \cdot 2 \cdot (n + 1))$

### Daten

$y_0, y_1, y_2, y_3, y_4, y_5, y_6, y_7$

$20_p \cdot 8$

$y_0, y_2, y_4, y_6$

$y_1, y_3, y_5, y_7$

$20_p \cdot 4$

$y_0, y_4$

$y_2, y_6$

$20_p \cdot 4$

$y_1, y_5$

$y_3, y_7$

$20_p \cdot 2$

$y_0$

$y_4$

$y_2$

$y_6$

$y_1$

$y_5$

$y_3$

$y_7$

**Allgemein:** Pro Level  $2(n + 1)$  Operationen bei  $\log_2(n)$  Levels  $\implies$  Anzahl der Operationen zur Berechnung von  $c_0, \dots, c_n$  beträgt  $2(n + 1) \log_2(n) = O(n \log_2 n)$ .

### Satz 1.32

Sei  $n = 2m + 1, m \in \mathbb{N}$  und  $y_0, \dots, y_n$  gegeben.  $t_n^*(x) = \sum_{j=0}^n c_j e^{ijx}$  sei das komplexe trigonometrische Interpolationspolynom zu  $(x_0, y_0), \dots, (x_n, y_n)$ .

Sei  $t_n^{even}(x) = \sum_{j=0}^m c_j^{even} e^{ijx}$  das Interpolationspolynom zu  $(x_0, y_0), (x_2, y_2), \dots, (x_{2m}, y_{2m})$  und  $t_n^{odd}(x) = \sum_{j=0}^m c_j^{odd} e^{ijx}$  zu  $(x_0, y_1), (x_2, y_3), \dots, (x_{2m}, y_{2m+1})$ . Dann gilt

$$(*) \quad t_n^*(x) = \frac{1}{2} \left( 1 + e^{i \cdot (m+1)x} \right) t_n^{even}(x) + \frac{1}{2} \left( 1 - e^{i \cdot (m+1)x} \right) t_n^{odd} \left( x - \frac{\pi}{m+1} \right)$$

und es ist  $c_l = \frac{1}{2} (c_l^{even} + \hat{w}^{-l} c_l^{odd})$ ,  $c_{l+m+1} = \frac{1}{2} (c_l^{even} - \hat{w}^{-l} c_l^{odd})$  für  $l = 0, \dots, m$  und  $\hat{w} = e^{i \frac{\pi}{m+1}}$ .

*Beweis:* Sei  $r_n$  die rechte Seite von (\*), d.h.

$$\begin{aligned}
 r_n(x) &= \frac{1}{2} \sum_{j=0}^m \left[ (1 + e^{i(m+1)x}) c_j^{even} e^{ijx} + (1 - e^{i(m+1)x}) c_j^{odd} e^{ij(x - \frac{\pi}{m+1})} \right] \\
 &= \frac{1}{2} \sum_{j=0}^m \left[ c_j^{even} (e^{ijx} + e^{i(j+m+1)x}) + c_j^{odd} (e^{ijx} - e^{i(j+m+1)x}) e^{-ij \frac{\pi}{m+1}} \right] \\
 &= \frac{1}{2} \sum_{j=0}^m \left( c_j^{even} + e^{-ij \frac{\pi}{m+1}} c_j^{odd} \right) e^{ijx} + \frac{1}{2} \sum_{j=m+1}^{2m+1} \left( c_{j-(m+1)-l}^{even} - e^{-ij \frac{\pi}{m+1}} c_{j-(m+1)}^{odd} e^{ijx} \right) \\
 &= \sum_{j=0}^n \hat{c}_j e^{ijx} \in T_n.
 \end{aligned}$$

Wegen der Eindeutigkeit des Interpolationspolynom folgt  $t_n^* = r_n$ , falls  $r_n$  die Interpolationsbedingung erfüllt. Für  $x_l = \frac{2\pi}{n+1}l$  gilt:

$$\begin{aligned}
 e^{i(m+1)x_l} &= e^{i \frac{2\pi}{n+1}(n+1)l} = e^{il\pi} = \begin{cases} 1 & : l \text{ gerade} \\ -1 & : l \text{ ungerade} \end{cases} \\
 \implies r_n(x_l) &\stackrel{(*)}{=} \begin{cases} t_n^{even}(x_l) & : l \text{ gerade} \\ t_n^{odd}\left(x_l - \frac{\pi}{m+1}\right) & : l \text{ ungerade} \end{cases} \\
 &= \begin{cases} t_n^{even}(x_l) & : l \text{ gerade} \\ t_n^{odd}(x_{l-1}) & : l \text{ ungerade} \end{cases}
 \end{aligned}$$

Also ist  $r_n(x_l) = y_l$  und damit  $t_n^* \equiv r_n \implies \hat{c}_j = c_j$ .

Da  $e^{-ij \frac{\pi}{m+1}} = \hat{w}^{-j}$ , folgt die Formel für  $c_l$  aus der Definition von  $\hat{c}_l$ .

□

**Algorithmus:**

Für  $q = 0, \dots, Q$  sei  $t_k^q(x) = \sum_{j=0}^{2^q-1} c_{k,j}^q e^{ijx}$ ,  $k = 0, \dots, 2^{Q-q} - 1$

das Interpolationspolynom zu  $(x_{j2^{Q-q}}, y_{j2^{Q-q}+k})_{j=0}^{2^q-1}$ .

Sei  $q \geq 1$ :

Nach Satz 1.32 mit  $m = 2^q - 1$ , bzw.  $n = 2^{q+1} - 1$  und den Daten

$(x_{j2^{Q-q}}, y_{j2^{Q-q}+k})_{j=0}^{2^q-1}$  gilt für  $k = 0, \dots, 2^{Q-(q+1)} - 1$ :

$$\begin{aligned} c_{k,l}^{q+1} &= \frac{1}{2} \left( c_{k,l}^q + e^{-i \frac{2\pi}{2^{q+1}} l} c_{k+2^{Q-q-1},l}^q \right) \quad l = 0, \dots, 2^q - 1, \\ c_{k,l+2^q}^{q+1} &= \frac{1}{2} \left( c_{k,l}^q - e^{-i \frac{2\pi}{2^{q+1}} l} c_{k+2^{Q-q-1},l}^q \right). \end{aligned}$$

Start der Iteration ( $q=0$ ):  $c_{k,0}^0 = y_k$  für  $k = 0, \dots, 2^Q - 1$ .

**Speicherbedarf:** Für  $q$  und  $q+1$  müssen Matrizen berechnet werden:

$$C^q = (c_{k,l}^q), \quad C^{q+1} = (c_{k,l}^{q+1})$$

$C^q \in \mathbb{C}^{2^{Q-q} \times 2^q}$  bzw.  $C^{q+1} \in \mathbb{C}^{2^{Q-q-1} \times 2^{q+1}}$

Beide Matrizen sind von der selben Dimension:  $2^{Q-q}2^q = 2^Q = n+1$  und  $2^{Q-q-1}2^{q+1} = 2^Q = n+1$

Daher sollen die Koeffizienten  $c_{k,l}^q, c_{k,l}^{q+1}$  in Vektoren der Dimension  $n+1$  gespeichert werden

$$C[2^q k + l] := c_{k,l}^q,$$

$$D[2^{q+1} k + l] := c_{k,l}^{q+1}.$$

Es gilt:  $e^{-i \frac{2\pi}{2^{q+1}} l} = e^{-il \frac{2\pi}{2^Q} 2^{Q-q-1} l} =: W[2^{Q-q-1} l]$ , wobei der Vektor  $W[l] := e^{-i \frac{2\pi}{2^Q} l}$ ,  $l = 0, \dots, 2^Q - 1$  vorab nur einmal berechnet werden muss.

Mit  $\hat{w} := e^{-i \frac{2\pi}{2^Q}}$  erhalten wir dann folgenden Algorithmus:

**Algorithmus 1.33 (FFT)**

Für  $l = 0, \dots, 2^Q - 1$ :

$$q = 0 \quad \begin{cases} C[l] = y_l \\ W[l] = \hat{w}^l \end{cases}$$

Für  $q = 0, \dots, Q - 1$

$$q \rightarrow q + 1 \quad \begin{cases} \text{Für } k = 0, \dots, 2^{Q-(q+1)} - 1 \\ \quad \begin{cases} \text{Für } l = 0, \dots, 2^q - 1 \\ \quad \begin{cases} (*) \quad \begin{cases} u = C[2^q k + l] \\ v = W[2^{Q-q-1} l] C[2^q(k + 2^{Q-q-1}) + l] \\ D[2^{q+1} k + l] = \frac{1}{2}(u + v) \\ D[2^{q+1} k + l + 2^q] = \frac{1}{2}(u - v) \end{cases} \\ \text{Für } l = 0, \dots, 2^Q - 1 \\ \quad \begin{cases} C[l] = D[l] \end{cases} \end{cases} \end{cases}$$

**Aufwand:** (\*) benötigt 3 Operationen. Anzahl der Durchläufe von (\*)

$$Q2^{Q-q-1}2^q = Q2^{Q-1} = \log_2(n+1) \frac{n+1}{2}.$$

Daher ist der gesamte Aufwand gleich

$$3 \log_2(n+1) \frac{n+1}{2} = O(n \log_2 n).$$

**Bemerkung:** Der Algorithmus kann so umgeschrieben werden, dass der Vektor  $D$  nicht gebraucht wird. Es existieren auch Varianten für den Fall  $n \neq 2^Q - 1$ .

## 1.7 Spline-Interpolation

**Motivation:** Bei großen Werten von  $n$  führt die Polynominterpolation zu stark oszillierenden Interpolationspolynomen, da  $p_n \in C^\infty(I)$ . Das Problem tritt besonders dann auf, wenn die Stützstellen vorgegeben sind. Daher verwendet man häufig stückweise polynomische Funktionen, d.h.

$$P|_{[x_{i-1}, x_i]} \in \mathbb{P}_r$$

mit  $r \ll n$ . Die Interpolationsbedingung  $p(x_i) = y_i$  führt zu  $p \in C^0(I)$ , aber  $p$  ist i.a. nicht in  $C^\infty(I)$ , sondern  $p \in C^q(I)$ . Die Parameter  $(r, q)$  sind geeignet zu wählen:

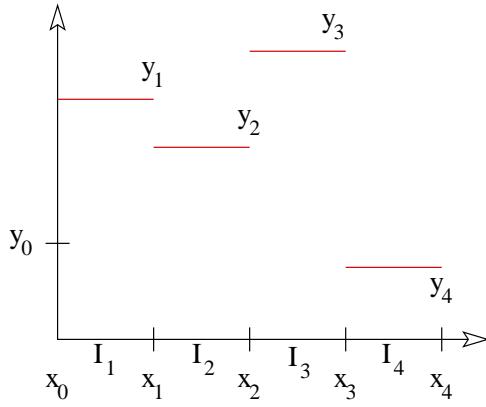


Abbildung 1.5: Beispiel 1.34: Treppenfunktionen

$$P|_{[x_{i-1}, x_i]} \in \mathbb{P}_r, \quad p(x) = \begin{cases} p_1(x) & : x \in (x_0, x_1] \\ p_2(x) & : x \in (x_1, x_2] \\ \vdots \\ p_n(x) & : x \in (x_{n-1}, x_n] \end{cases}$$

$p_i \in \mathbb{P}_r$  hat die Interpolationsbedingungen  $p_i(x_{i-1}) = y_{i-1}$ ,  $p_i(x_i) = y_i \iff p(x_k) = y_k$ ,  $k = 0, \dots, n$ .

**Notation:**  $\Delta = (x_0, \dots, x_n)$  ist eine Zerlegung von  $I = [a, b]$  mit  $x_0 = a$ ,  $x_n = b$ ,  $x_{i-1} < x_i$  ( $1 \leq i \leq n$ ).

Mit  $h_i := x_i - x_{i-1} > 0$  bezeichnen wir die Länge des Teilintervalls  $I_i := (x_{i-1}, x_i)$ ,  $I_0 := \{a\}$ ,  $i = 1, \dots, n$ . Die Feinheit der Zerlegung ist gegeben durch:

$$h = \max_{1 \leq i \leq n} h_i.$$

Für  $r, q \in \mathbb{N}$  definieren wir den Raum der Splines durch

$$S_{\Delta}^{r,q} := \left\{ P \in C^q(I) \mid P|_{I_i} =: p_i \in \mathbb{P}_r \text{ für } 1 \leq i \leq n \right\}$$

**Gegeben:** Zerlegung  $\Delta$ , Daten  $y_0, \dots, y_n$  und  $r, q \in \mathbb{N}$ .

**Gesucht:**  $P_{\Delta} \in S_{\Delta}^{r,q}$  mit  $P_{\Delta}(x_k) = y_k$ ,  $k = 0, \dots, n$ .

### Beispiel 1.34

$r = 0$ : Die einzige mögliche Interpolation durch stückweise konstante Funktionen ist gegeben durch  $P_{\Delta}(x) = y_i$  für  $x \in I_i$  bzw.  $p_i(x) = y_i$ . Für  $q \geq 0$  ist das Problem nicht lösbar.

Abbildung 1.5 zeigt die entstandene Treppenfunktion. In diesem Fall ist  $P_{\Delta}$  nicht stetig!

$r = 1$ : Es soll gelten:  $p_i \in \mathbb{P}_1$  und  $p_i(x_{i-1}) = y_{i-1}$ ,  $p(x_i) = y_i$ .

Abbildung 1.6 zeigt die eindeutig bestimmten Funktionen  $p_i$  definiert durch  $p_i(x) = y_i + \frac{y_i - y_{i-1}}{h_i}(x - x_i)$ . Damit gilt:  $P_{\Delta} \in S_{\Delta}^{1,0}$ .

$r = 3$ : Annahme:  $y_k = f(x_k)$  mit  $f \in C^4(I)$

(i) **Fall:** Wähle für  $i = 1, \dots, n$  Werte  $x_{ij} \in I_i$  für  $j = 1, 2$  und definiere  $p_i$  als Interpolationspolynom zu  $(x_{i-1}, y_{i-1}), (x_{i1}, f(x_{i1})), (x_{i2}, f(x_{i2})), (x_{i+1}, f(x_{i+1})) \implies p_i \in \mathbb{P}_3$  und  $P_\Delta \in S_\Delta^{3,0}$ . Nach Satz 1.4 gilt:

$$\begin{aligned} |f(x) - P_\Delta(x)| &= |f(x) - p_i(x)| = f^{(4)}(\xi_x) \frac{1}{4!} h_i^4 \text{ für } x \in I_i \\ &\leq \|f^{(4)}\|_\infty \frac{1}{4!} h_i^4. \end{aligned}$$

(ii) **Fall:** Wähle  $p_i \in \mathbb{P}_3$  durch Hermiteinterpolation zu  $(x_{i-1}, y_{i-1}), (x_{i-1}, f'(x_{i-1})), (x_i, y_i), (x_i, f'(x_i)) \implies P_\Delta \in S_\Delta^{3,1}$  und  $\|f - P_\Delta\|_\infty \leq h^4 \frac{1}{4!} \|f^{(4)}\|_\infty$ .

**Frage:** Existiert ein  $P_\Delta \in S_\Delta^{3,2}$ ?

**Bemerkung:** Für  $n > r$  ist das Interpolationsproblem in  $S_\Delta^{r,q}$  für  $q \geq r$  i.a. schlecht gestellt (d.h. nicht lösbar):

Freiheitsgrade:  $p_i \in \mathbb{P}_r$  führt auf  $(r+1)$  Koeffizienten, also:  $n(r+1)$  Freiheitsgrade.

Anzahl der Bedingungen:

Auf  $I_1$  : 2 Interpolationsbedingungen

$I_2$  : 2 Interpolationsbedingungen +  $q$  Stetigkeitsbedingungen in  $x_1$

⋮

$I_n$  : 2 Interpolationsbedingungen +  $q$  Stetigkeitsbedingungen in  $x_{n-1}$

$$\implies 2n + q(n-1) = n(q+2) - q \text{ Bedingungen.}$$

Ist  $q \geq r$  so folgt:  $2n + q(n-1) \geq 2n + r(n-1) = n(r+1) + n - r > n(r+1)$ . Für  $n - r > 0$  existieren also mehr Bedingungen als Freiheitsgrade und das Problem ist i.A. nicht lösbar.

**Spezialfall:**  $q = r - 1$  (Eigentliche ‘‘Spline-Interpolation’’)

Bedingungen:  $n(q+2) - q = n(r+1) - q$ , d.h. es müssen noch  $q = r - 1$  Freiheitsgrade zusätzlich festgelegt werden.

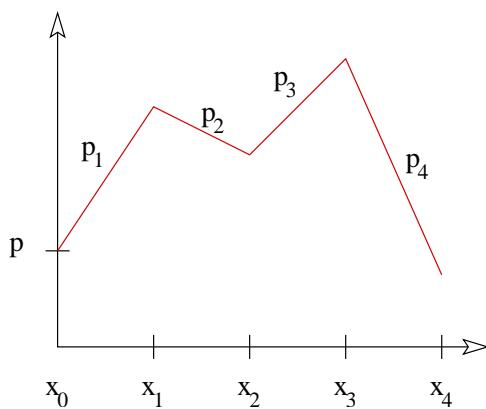


Abbildung 1.6: Beispiel 1.34: Gerade

### 1.7.1 Kubische Spline-Interpolation

**Gegeben:**  $\Delta = (x_0, \dots, x_n)$  Zerlegung des Intervalls  $I = [a, b]$  und Daten  $y_0, \dots, y_n \in \mathbb{R}$ .

**Gesucht:**  $P_\Delta \in S_\Delta^{3,2}$  mit  $P_\Delta(x_i) = y_i$  ( $0 \leq i \leq n$ ) und eine der Bedingungen a) bis d):

a)  $P_\Delta''(a) = M_a, P_\Delta''(b) = M_b$  für  $M_a, M_b \in \mathbb{R}$  gegeben.

Im Fall  $M_a = M_b = 0$  spricht man von **natürlichen kubischen Splines**.

b)  $p'(a) = g_a, p'(b) = g_b$  für  $g_a, g_b \in \mathbb{R}$  gegeben.

c)  $P_\Delta$  sei **periodisch fortsetzbar** in  $\mathbb{C}^2(\mathbb{R})$ , d.h.  $y_0 = y_n$  und  $p'(a) = p'(b), p''(a) = p''(b)$ .

d) **not-a-knot**-Bedingung:  $P_{\Delta|_{[I_1 \cup I_2]}} \in \mathbb{P}_3, P_{\Delta|_{[I_{n-1} \cup I_n]}} \in \mathbb{P}_3$ , d.h. die Zusatzbedingungen werden verwendet, um die Sprünge in  $P_\Delta'''$  für  $x = x_1, x = x_{n-1}$  zu eliminieren.

#### Satz 1.35 (Existenz und Eindeutigkeit)

Zu gegebener Zerlegung  $\Delta$  und Daten  $y_0, \dots, y_n$  existiert genau ein  $P_\Delta \in S_\Delta^{3,2}$  mit  $p(x_k) = y_k$ , welches eine der Bedingungen a), b), c), oder d) erfüllt. Im Fall c) muss gelten:  $y_0 = y_n$ .

*Beweis:* **Idee:** Stelle LGS für die Momente  $M_j := P_\Delta''(x_j)$  auf.

Da  $p_j''$  linear auf  $I_j = (x_{j-1}, x_j]$  ist, muss gelten:  $p_j''(x) = \frac{1}{h_j} (M_j(x - x_{j-1}) + M_{j-1}(x_j - x))$ .

Durch zweimalige Integration folgt für geeignete Integrationskonstanten  $a_j, b_j \in \mathbb{R}$ :

$$p_j(x) = \frac{1}{6h_j} (M_j(x - x_{j-1})^3 + M_{j-1}(x_j - x)^3) + b_j \left( x - \frac{x_j + x_{j-1}}{2} \right) + a_j. \quad (*)$$

Aus den Interpolationsbedingungen  $p_j(x_{j-1}) = y_{j-1}, p_j(x_j) = y_j$  folgt:

$$\begin{aligned} y_{j-1} &= \frac{1}{6h_j} M_{j-1} h_j^3 - b_j \frac{1}{2} h_j + a_j, \\ y_j &= \frac{1}{6h_j} M_j h_j^3 + b_j \frac{1}{2} h_j + a_j. \end{aligned}$$

Dies ist ein  $2 \times 2$  LGS für  $a_j, b_j$  mit der Lösung

$$\begin{aligned} (***) \quad a_j &= \frac{1}{2} (y_j + y_{j-1}) - \frac{1}{12} h_j^2 (M_j + M_{j-1}), \\ b_j &= \frac{1}{h_j} (y_j - y_{j-1}) - \frac{1}{6} h_j (M_j - M_{j-1}). \end{aligned}$$

Damit hängen die  $p_j$  nur von den Momenten  $M_0, \dots, M_n$  ab.

Es bleiben noch die  $n - 1$  Bedingungen  $p'(x_j) = p'_{j+1}(x_j)$  für  $j = 1, \dots, n - 1$ :

Aus (\*) und (\*\*) folgt:  $p'_j(x) = \frac{1}{2h_j} (M_j(x - x_{j-1})^2 - M_{j-1}(x_j - x)^2) + \frac{1}{h_j} (y_j - y_{j-1}) - \frac{1}{6} h_j (M_j - M_{j-1})$ .

Daher ist  $p'_j(x_j) = p'_{j+1}(x_j)$  äquivalent zu

$$\frac{1}{2} M_j (h_{j+1} + h_j) + \frac{1}{6} h_{j+1} (M_{j+1} - M_j) - \frac{1}{6} h_j (M_j - M_{j-1}) = \frac{1}{h_{j+1}} (y_{j+1} - y_j) - \frac{1}{h_j} (y_j - y_{j-1}) \quad \text{für } j = 1, \dots, n - 1,$$

bzw.

$$\frac{1}{6} h_j M_{j-1} + \frac{1}{3} (h_j + h_{j+1}) M_j + \frac{1}{6} h_j M_{j+1} = y[x_j, x_{j+1}] - y[x_{j-1}, x_j].$$

Mit der zweiten dividierten Differenz  $y[x_{j-1}, x_j, x_{j+1}] = \frac{y[x_j, x_{j+1}] - y[x_{j-1}, x_j]}{x_{j+1} - x_{j-1}}$  und  $x_{j+1} - x_{j-1} = h_j + h_{j+1}$  folgt:

$$\mu_j M_{j-1} + M_j + \lambda_j M_{j+1} = 3y[x_{j-1}, x_j, x_{j+1}]$$

mit  $\mu_j = \frac{h_j}{2(h_j + h_{j+1})}$ ,  $\lambda_j = \frac{h_{j+1}}{2(h_j + h_{j+1})}$ .

Wir erhalten ein  $(n-1) \times (n-1)$  LGS für die (n+1) Momente  $M_0, \dots, M_n$ .

**Fall a)**  $M_0 = M_a$ ,  $M_n = M_b$ .

Dies führt auf das  $(n-1) \times (n-1)$  LGS für  $M_1, \dots, M_{n-1}$  der Form

$$A \begin{pmatrix} M_1 \\ \vdots \\ M_{n-1} \end{pmatrix} = \begin{pmatrix} 3y[x_0, x_1, x_2] - \mu_1 M_a \\ 3y[x_1, x_2, x_3] \\ \vdots \\ 3y[x_{n-2}, x_{n-1}, x_n] - \lambda_{n-1} M_b \end{pmatrix}$$

mit

$$A = \begin{pmatrix} 1 & \lambda_1 & & 0 \\ \mu_2 & \ddots & \ddots & \\ & \ddots & \ddots & \lambda_{n-2} \\ 0 & & \mu_{n-1} & 1 \end{pmatrix}.$$

$A$  ist regulär nach dem folgenden Lemma 1.36, da  $\mu_j + \lambda_j = 1/2 < 1$  und  $\lambda_1 < 1$ ,  $\mu_{n-1} < 1$ .

Die Fälle b),c),d) führen analog auf einfach strukturierte LGS mit regulären Matrizen, d.h.  $p_1, \dots, p_n$  eindeutig durch  $(*)$ ,  $(**)$  festgelegt.  $\square$

### Lemma 1.36

Sei  $A \in \mathbb{R}^{n \times n}$  eine **tridiagonale Matrix**, d.h.

$$A = \text{tridiag}(b_i, a_i, c_i) = \begin{pmatrix} a_1 & c_1 & & 0 \\ b_2 & \ddots & \ddots & \\ & \ddots & \ddots & c_{n-1} \\ 0 & & b_n & a_n \end{pmatrix}$$

Es gelte:  $|a_1| > |c_1| > 0$  und  $|a_n| > |b_n| > 0$  und  $|a_i| \geq |b_i| + |c_i|$ ,  $b_i \neq 0$ ,  $c_i \neq 0$ ,  $2 \leq i \leq n-1$ .

Dann gilt:

(i)  $A$  ist regulär.

(ii)  $A = LR$  mit  $L = \text{tridiag}(b_i, \alpha_i, 0)$  und  $R = \text{tridiag}(0, 1, \gamma_i)$  mit  $\alpha_1 = a_1$ ,  $\gamma_1 = c_1 \alpha_1^{-1}$  und für  $2 \leq i \leq n$ :  $\alpha_i = a_i - b_i \gamma_{i-1}$ ,  $\gamma_i = c_i \alpha_i^{-1}$ .

Daher kann  $Ax = b$  in  $O(n)$  Operationen gelöst werden.

*Beweis:* Siehe Übungsaufgaben  $\square$

### Lemma 1.37

Die Spline-Interpolation mit kubischen Splines und einer der Zusatzbedingungen a), b), c) oder d) kann mit  $O(n)$  Operationen gelöst werden.

*Beweis:* a) folgt aus 1.35, 1.36.

b), c), d): (siehe z.B. Schaback, Werner: Numerische Mathematik, Berlin, Springer, 1992.)  $\square$

**Historisch:** Interpolation durch biegsamen Stab (engl: spline) und Brett mit Nägeln bei  $(x_k, y_k)$ . Der Stab hat minimale Krümmung, d.h. die Funktion minimiert  $\int_I \frac{(y''(t))^2}{1+(y'(t))^2} dt$  über alle glatten Funktionen  $y$  mit  $y(x_k) = y_k$ . Für den Fall kleiner erster Ableitungen entspricht dies näherungsweise  $\int_I y''(t)^2 dt$ .

**Satz 1.38 (Minimierungseigenschaft kubischer Splines)**

Sei  $\Delta = (x_0, \dots, x_n)$  eine Zerlegung von  $I = [a, b]$  und  $y_0, \dots, y_n \in \mathbb{R}$  gegeben. Sei  $P_\Delta \in S_\Delta^{3,2}$  ein kubischer Spline mit  $P_\Delta(x_k) = y_k$  und einer der Bedingungen a), b), oder c):

- a)  $P_\Delta''(a) = 0, P_\Delta''(b) = 0,$
- b)  $P_\Delta'(a) = g_a, P_\Delta'(b) = g_b,$
- c)  $P_\Delta$  periodisch fortsetzbar in  $C^2(\mathbb{R})$ .

Dann gilt für alle  $f \in C^2(a, b)$  mit denselben Interpolationsbedingungen, d.h. mit  $f(x_k) = y_k$  und a), b) oder c) und  $\int_a^b |f''|^2 \leq \infty$ :

$$\int_a^b |f''(x)|^2 dx \geq \int_a^b |P_\Delta''(x)|^2 dx.$$

*Beweis:* Zum Beweis dieser Aussage benötigen wir das folgende Lemma.  $\square$

**Lemma 1.39 (Holladay Identität)**

Sei  $f \in C^2(a, b)$  mit  $\int_a^b |f'''|^2 < \infty$  und  $P_\Delta \in S_\Delta^{3,2}$ , dann gilt:

$$\begin{aligned} \int_a^b |f'' - P_\Delta''|^2 &= \int_a^b |f''|^2 - \int_a^b |P_\Delta''|^2 \\ &\quad - 2 \left( [(f'(x) - P_\Delta'(x))P_\Delta''(x)]_{x=a}^b - \sum_{i=1}^n [(f(x) - P_\Delta(x))P_\Delta'''(x)]_{x=x_{i-1}^+}^{x_i^-} \right). \end{aligned}$$

Dabei wurden die folgenden Abkürzungen benutzt:

$$[g(x)]_{x=a}^b = g(b) - g(a),$$

$$[g(x)]_{x=x_{i-1}^+}^{x_i^-} = \lim_{x \nearrow x_i} g(x) - \lim_{x \searrow x_{i-1}} g(x). \text{ Beachte: } P_\Delta''' \text{ ist unstetig!}$$

*Beweis:* Es ist

$$\begin{aligned}
 \int_a^b |f'' - P''_\Delta|^2 &= \int_a^b |f''|^2 - 2 \int_a^b f'' P''_\Delta + \int_a^b |P''_\Delta|^2 \\
 &= \int_a^b |f''|^2 - \int_a^b |P''_\Delta|^2 - 2 \int_a^b (f'' - P''_\Delta) P''_\Delta \\
 &= \int_a^b |f''|^2 - \int_a^b |P''_\Delta|^2 - 2 \sum_{i=1}^n \underbrace{\int_{I_i} (f'' - p''_i) p''_i}_{=: A_i}.
 \end{aligned}$$

Mit partieller Integration folgt für  $A_i$ :

$$\begin{aligned}
 A_i &= \int_{x_{i-1}}^{x_i} (f'' - p''_i) p''_i = [(f' - p'_i) p''_i]_{x=x_{i-1}}^{x_i} - \int_{x_{i-1}}^{x_i} (f' - p'_i) p'''_i \\
 &= [(f' - p'_i) p''_i]_{x=x_{i-1}}^{x_i} - [(f - p_i) p'''_i]_{x_{i-1}^+}^{x_i^-} + \int_{x_{i-1}}^{x_i} (f - p_i) p_i^{(4)}.
 \end{aligned}$$

Es ist  $p_i^{(4)} \equiv 0$ , da  $p_i \in P_3$  und

$$\begin{aligned}
 \sum_{i=1}^n [(f' - p'_i) p''_i]_{x=x_{i-1}}^{x_i} &\stackrel{p''_i \in C^0}{=} \sum_{i=1}^n [(f' - P'_\Delta) P''_\Delta]_{x=x_{i-1}}^{x_i} \\
 &= \sum_{i=1}^n [(f'(x_i) - p'_\Delta(x_i)) P''_\Delta(x_i) - (f'(x_{i-1}) - P'_\Delta(x_{i-1})) P''_\Delta(x_{i-1})] \\
 &= (f'(x_n) - P'_\Delta(x_n)) P''_\Delta(x_n) - f'(x_0) - P'_\Delta(x_0) P''_\Delta(x_0) \\
 &= [(f'(x) - P'_\Delta(x)) P''_\Delta(x)]_{x=a}^b. \\
 \implies \sum_{i=1}^n A_i &= [(f'(x) - P'_\Delta(x)) P''_\Delta(x)]_{x=a}^b - \sum_{i=1}^n [(f(x) - p_i(x)) p'''_i(x)]_{x=x_{i-1}}^{x_i}.
 \end{aligned}$$

Also folgt die Holladay Identität. □

*Beweis:* (Fortsetzung des Beweises von Satz 1.38)

In den 3 Fällen a), b), c) verschwindet der Term  $2(\dots)$  in der Holladay Identität  $\implies 0 \leq \int_a^b |f'' - P''_\Delta|^2 = \int_a^b |f''|^2 - \int_a^b |P''_\Delta|^2$ . □

#### Satz 1.40 (Fehlerabschätzung)

Sei  $\Delta$  eine Zerlegung von  $I$  mit  $h \leq Kh_i$  ( $1 \leq i \leq n$ ) für ein  $K > 0$ . Sei  $f \in C^4(a, b)$  mit  $|f^{(4)}| < L$  für  $x \in (a, b)$ .

Sei  $P_\Delta \in S_\Delta^{3,2}$  mit  $P_\Delta(x_k) = f(x_k)$  und  $P'_\Delta(a) = f'(a)$ ,  $P'_\Delta(b) = f'(b)$ .

Dann gilt für  $l = 0, 1, 2, 3$ :  $|f^{(l)}(x) - P_\Delta^{(l)}(x)| \leq 2LK h^{4-l}$ .

Also insbesondere

$$|f(x) - P_\Delta(x)| \leq 2LK h^4.$$

*Beweis:* (Ohne Beweis. Siehe z.B. Stoer, Bulirsch. Numerische Mathematik 1. Berlin, Springer 2007.)

#### Basiswahl für den Splineraum $S_\Delta^{r,r-1}$ : B-Splines

□

**Ziel:** Konstruktion einer einfachen Basis von  $S_{\Delta}^{r,r-1}$  mit

1. positiven Basisfunktionen für numerische Stabilität,
2. möglichst kleinem Träger.

**Definition 1.41 (B-Splines)**

Sei  $(t_i)_{i \in \mathbb{Z}}$  eine monoton nicht-fallende Folge mit  $\lim_{i \rightarrow \pm\infty} t_i = \pm\infty$ . Dann sind die **B-Splines**  $B_{i,k} : \mathbb{R} \rightarrow \mathbb{R}$  vom Grad  $k \in \mathbb{N}$  rekursiv definiert durch

$$B_{i,0}(x) = \begin{cases} 1 & : t_i < x \leq t_{i+1} \\ 0 & : \text{sonst} \end{cases}$$

und

$$B_{i,k} = \omega_{i,k}(x)B_{i,k-1}(x) + (1 - \omega_{i+1,k}(x))B_{i+1,k-1}(x)$$

mit

$$\omega_{i,k}(x) = \begin{cases} \frac{x-t_i}{t_{i+k}-t_i} & : t_i < t_{i+k} \\ 0 & : \text{sonst} \end{cases}.$$

**Beispiel:**

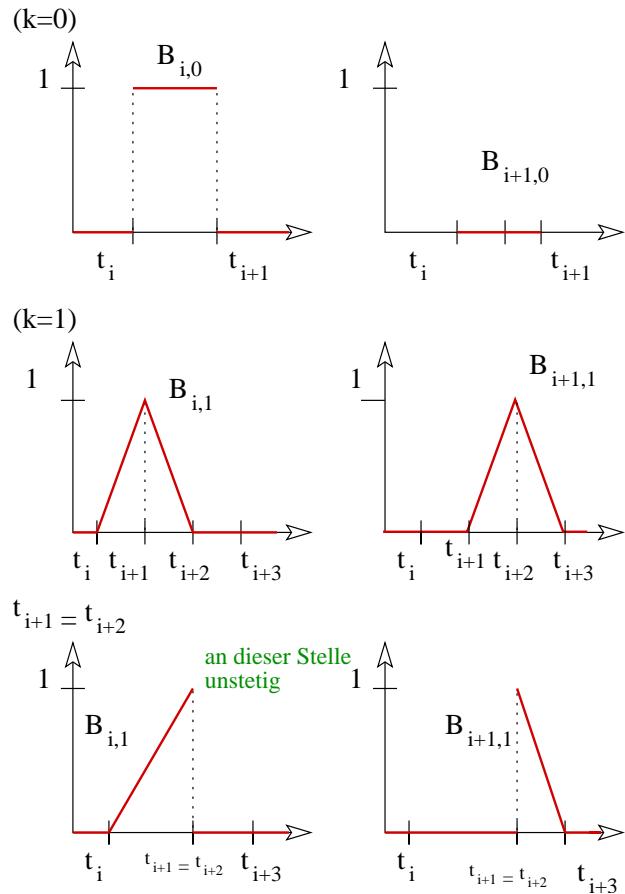


Abbildung 1.7: B-Splines

Die Abb. 1.7 zeigt 6 verschiedene Beispiele, die bei den B-Splines auftreten können.

**Satz 1.42 (Eigenschaften der B-Splines)**

Sei  $(t_i)_{i \in \mathbb{Z}}$  eine monoton nicht-fallende Knotenfolge, wie in Definition 1.41. Dann gilt:

- (i)  $B_{i,k}|_{[t_j, t_{j+1}]} \in \mathbb{P}_k \quad \forall i, j \in \mathbb{Z}, k \in \mathbb{N},$
- (ii)  $\text{supp}(B_{i,k}) \subset [t_i, t_{i+k+1}],$  falls  $t_i < t_{i+k+1}$  und  $B_{i,k} \equiv 0,$  falls  $t_i = t_{i+k+1},$
- (iii)  $B_{i,k} \geq 0, \quad \sum_{i \in \mathbb{Z}} B_{i,k}(x) = 1, \quad \forall x \in \mathbb{R}$  (Zerlegung der 1).
- (iv) Falls  $\forall i \in \mathbb{Z} : t_i < t_{i+1},$  dann ist  $B_{i,k} \in C^{k-1}$  und  $(B_{i,k})_{i \in \mathbb{Z}}$  bildet eine Basis von  $S_{\Delta}^{k,k-1}.$

*Beweis:* (Ohne Beweis)

**Beispiel** Ein Vergleich der angesprochenen Interpolationen für  $f(x) = \frac{1}{x^2+1}$  ist in Abb. 1.8 dargestellt. Die Spline-Interpolation ergibt hier das beste Ergebnis.  $\square$

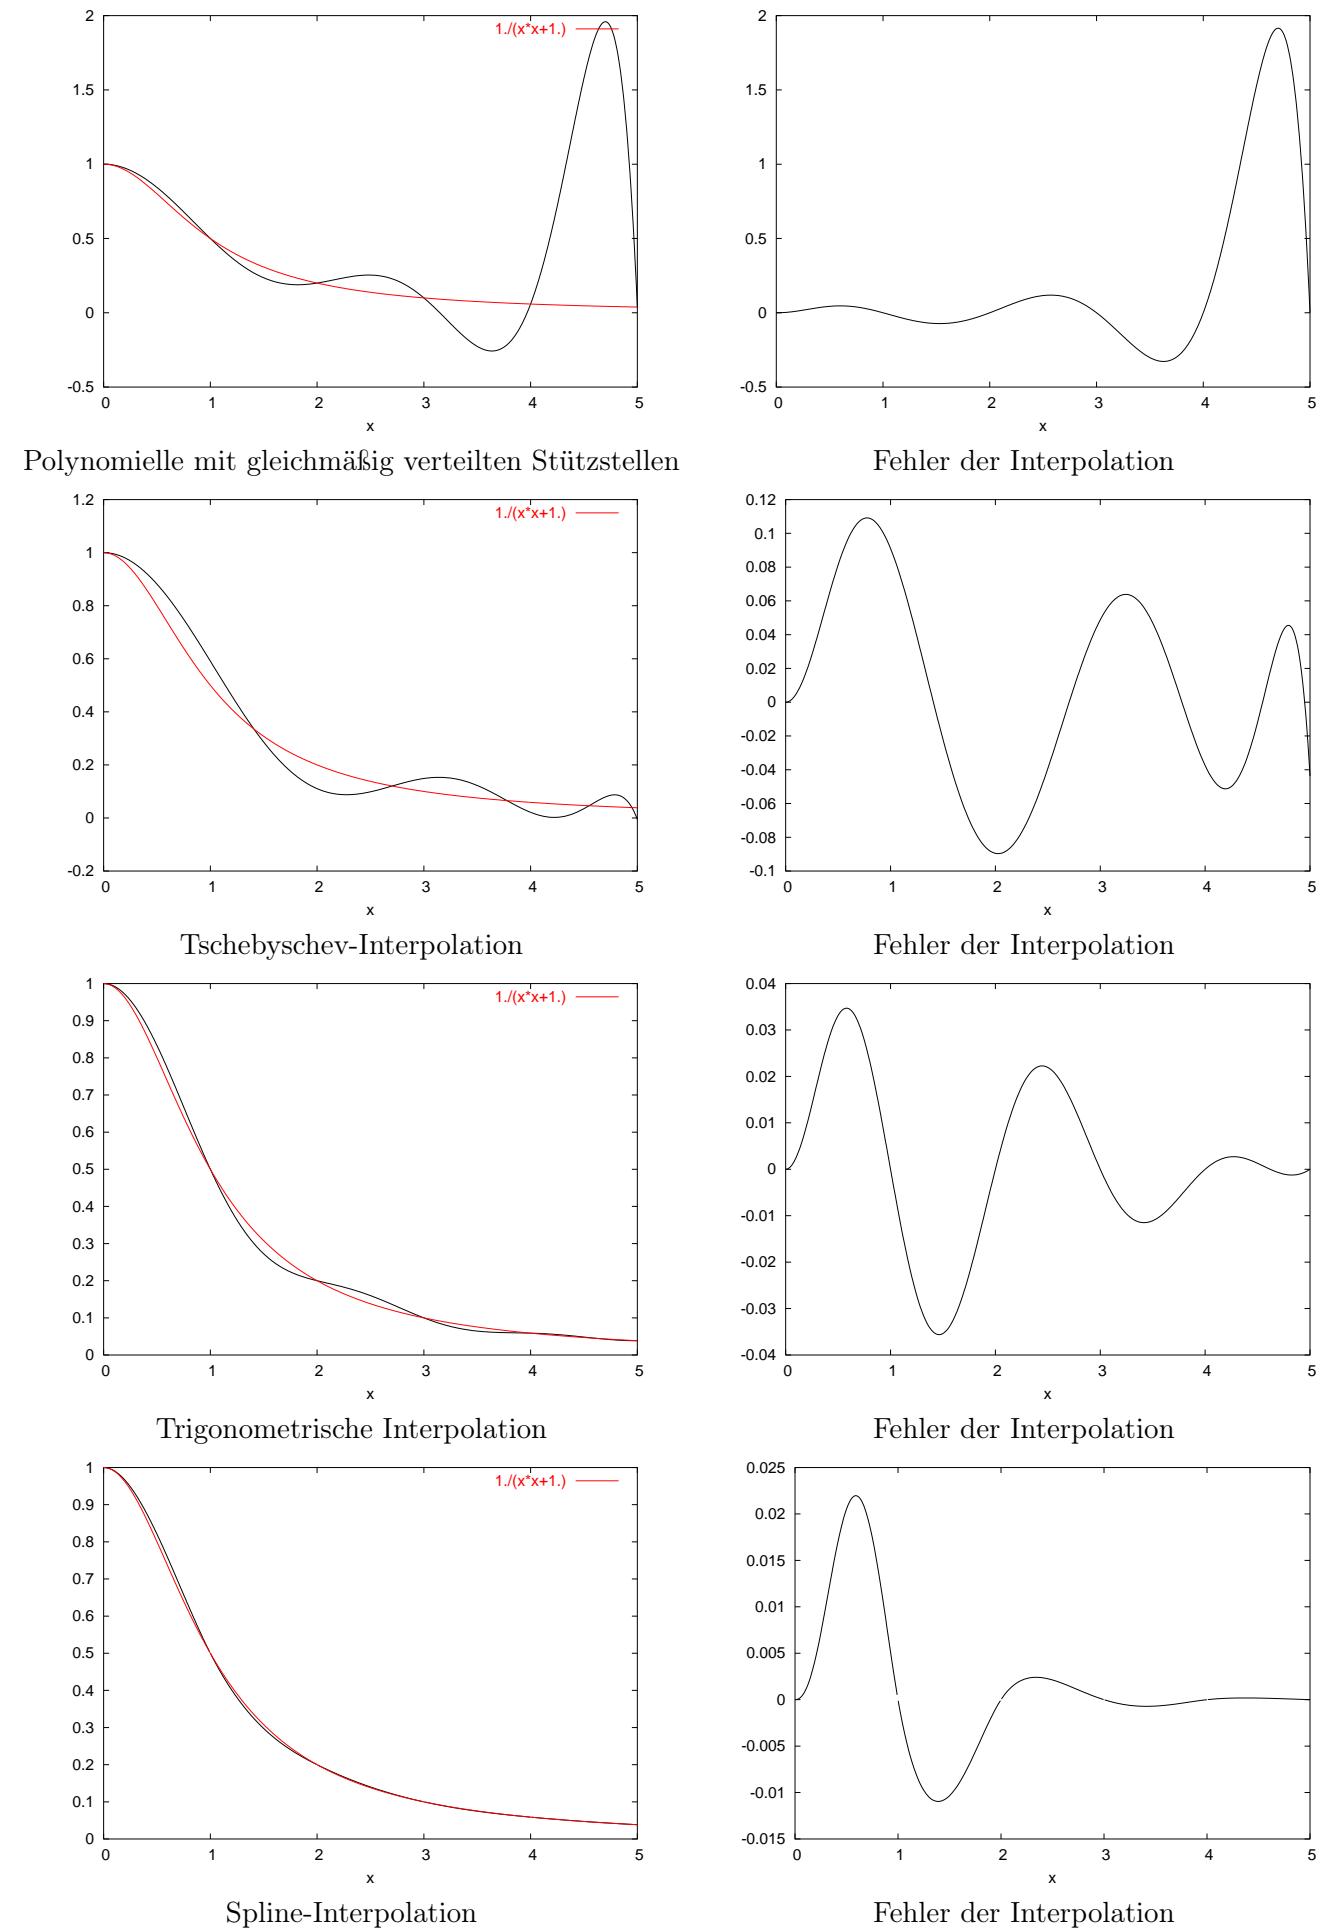


Abbildung 1.8: Unterschiede einiger Interpolationen



## Kapitel 2

# Numerische Integration

**Ziel:** Approximation von

$$I(f) := \int_a^b \omega(x) f(x) dx$$

für  $f \in C^k(a, b)$  und für eine gegebene Gewichtsfunktion  $\omega \in L^1(a, b)$ .

**Ansatz:** Approximiere  $I(f)$  durch eine Summe

$$I_n(f) := \sum_{j=0}^m \sum_{l=0}^{m_j-1} f^{(l)}(x_j) \omega_j^l$$

**Definition 2.1 (Quadratur)**

Eine Funktional  $I_n : C^k(a, b) \rightarrow \mathbb{R}$  der Form

$$I_n(f) := \sum_{j=0}^m \sum_{l=0}^{m_j-1} f^{(l)}(x_j) \omega_j^l$$

heißt **Quadraturformel** mit den Stützstellen  $x_j \in [a, b]$  und den **Gewichten**  $\omega_j^l \in \mathbb{R}$ . Dabei ist  $m \in \mathbb{N}$  und  $m_j \in \{1, \dots, k+1\}$  und  $n+1 = \sum_{j=0}^m m_j$ .

Die Quadratur heißt **exakt** für  $\mathbb{P}_n$  (bezüglich  $\omega$ ), g.d.w.

$$I_n(p) = I(p) \quad \forall p \in \mathbb{P}_n$$

$$R(f) = I(f) - I_n(f)$$

ist das zu  $I_n$  gehörende **Fehlerfunktional**.

**Bemerkung:** Für die allgemeine Definition der Quadratur vergleiche mit der Definition der Hermite Interpolation. Im folgenden betrachten wir meistens Quadraturen der Form

$$I_n(f) = \sum_{l=0}^n \omega_l f(x_l), \text{ d.h. } m_j = 1.$$

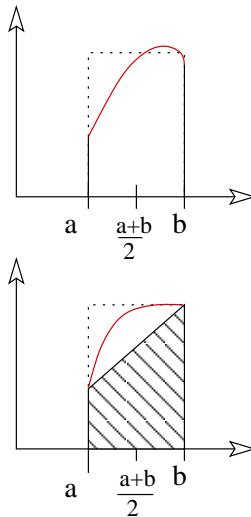


Abbildung 2.1: Beispiel 2.1

**Beispiel 2.2** ( $\omega \equiv 1$ )

Die Abbildung 2.1 verdeutlicht diese Beispiele:

- (i) Mittelpunktregel:  $I_0(f) = (b - a)f\left(\frac{a+b}{2}\right)$ .
- (ii) Trapezregel:  $I_1(f) = \frac{b-a}{2}(f(a) + f(b))$ .
- (iii) Simpsonregel:  $I_2(f) = \frac{b-a}{6}(f(a) + 4f\left(\frac{a+b}{2}\right) + f(b))$ .

**Satz 2.3**

Gegeben seien  $\omega \in L^1(a, b)$  und paarweise disjunkte Stützstellen  $x_0, \dots, x_n$ . Dann existiert genau eine Quadraturformel der Form

$$I_n(f) = \sum_{j=0}^n \omega_j f(x_j),$$

welche exakt ist auf  $\mathbb{P}_n$ . Dabei sind die Gewichte gegeben durch

$$\omega_j := \int_a^b \omega(x) L_j^n(x) dx,$$

wobei  $L_j^n(x) = \prod_{\substack{l=0 \\ l \neq j}}^n \frac{(x-x_l)}{(x_j-x_l)}$  die Lagrange Polynome sind.

*Beweis:*  $I_n$  exakt auf  $\mathbb{P}_n$

$$\iff I_n(p) = I(p) \quad \forall p \in \mathbb{P}_n$$

$$\iff I_n(L_l^n) = I(L_l^n) \text{ für } l = 0, \dots, n; \text{ da } I_n, I \text{ linear und } L_l^n \text{ Basis von } \mathbb{P}_n$$

$$\iff \int_a^b \omega(x) L_l^n(x) dx = \sum_{j=0}^n \omega_j L_l^n(x_j) = \omega_l, \text{ da } L_l^n(x_j) = \delta_{lj}.$$

**Bemerkung:** Es ist  $I_{\bar{n}}(f) = I(p_n)$ , wobei  $p_n \in \mathbb{P}_n$  das eindeutig bestimmte Interpolationspolynom zu  $(x_0, f(x_0)), \dots, (x_n, f(x_n))$  ist.  $\square$

$$\begin{aligned}
I_n(f) &= \sum_{l=0}^n \omega_l f(x_l) = \sum_{l=0}^n \int_a^b \omega(x) L_l^n(x) f(x_l) dx \\
&= \int_a^b \omega(x) \underbrace{\sum_{l=0}^n L_l^n(x) f(x_l)}_{p_n(x)} dx = \int_a^b \omega(x) p_n(x) dx = I(p_n).
\end{aligned}$$

**Definition 2.4**

Eine Quadraturformel  $I_n(f) = \sum_{l=0}^n \omega_l f(x_l)$  zu gegebenen Stützstellen  $a \leq x_0 < x_1 < \dots < x_n \leq b$  und Gewichtsfunktion  $\omega \in L^1(a, b)$  heißt **Interpolationsquadratur**, wenn sie auf  $\mathbb{P}_n$  exakt ist. Nach Satz 2.3 ist sie eindeutig.

**Satz 2.5**

Seien  $x_0, \dots, x_n \in [a, b]$  und  $\omega \in L^1(a, b)$  gegeben mit den Symmetrieeigenschaften

- (i)  $x_j - a = b - x_{n-j}$  ( $0 \leq j \leq n$ ) (Symmetrie bzgl.  $\frac{a+b}{2}$ )
- (ii)  $\omega(x) = \omega(a + b - x)$  ( $x \in [a, b]$ ) (gerade Funktion bzgl.  $\frac{a+b}{2}$ )

Dann gilt  $\omega_{n-j} = \omega_j$  ( $0 \leq j \leq n$ ), d.h. die Interpolationsquadratur ist symmetrisch. Falls  $n$  gerade ist, so ist  $I_n$  exakt auf  $\mathbb{P}_{n+1}$ .

*Beweis:* Sei  $\tilde{I}_n(f) := \sum_{j=0}^n \omega_{n-j} f(x_j)$ . Dann gilt  $\tilde{I}_n(p) = I_n(p) \forall p \in P_n$ . Damit ist aber  $\tilde{I}_n$  exakt auf  $P_n$  und nach Satz 2.3 gilt  $\tilde{I}_n = I_n$  und folglich  $\omega_{n-j} = \omega_j$ .

Sei nun  $n = 2m$  und damit  $x_m = \frac{a+b}{2}$  wegen i). Sei  $p_n \in \mathbb{P}_n$  das Interpolationspolynom zu  $(x_0, f(x_0)), \dots, (x_n, f(x_n))$  und sei  $q_{n+1} \in \mathbb{P}_{n+1}$  das Hermite Interpolationspolynom zu  $(x_0, f(x_0)), \dots, (x_{m-1}, f(x_{m-1})), (x_m, f(x_m)), (x_m, f'(x_m)), (x_{m+1}, f(x_{m+1})), \dots, (x_n, f(x_n))$ . Mit

$$c := \frac{f'(x_m) - p'_n(x_m)}{\prod_{\substack{l=0 \\ l \neq m}}^n (x_m - x_l)}$$

und  $N(x) = \prod_{l=0}^n (x - x_l) \in \mathbb{P}_{n+1}$  definiere

$$\tilde{q}_{n+1}(x) := p_n(x) + cN(x).$$

Dann ist  $\tilde{q}_{n+1} \in \mathbb{P}_{n+1}$  und  $\tilde{q}_{n+1}(x_l) = p_n(x_l) + cN(x_l) = f(x_l) + 0$ . Weiter folgt

$$\tilde{q}'_{n+1}(x_m) = p'_n(x_m) + c \prod_{\substack{l=0 \\ l \neq m}}^n (x_m - x_l) = f'(x_m).$$

Wegen der Eindeutigkeit der Hermite Interpolation gilt daher  $q_{n+1} = \tilde{q}_{n+1}$ .

Es gilt wegen i):  $N(x) = \prod_{l=0}^{m-1} (x - x_l) \left(x - \frac{a+b}{2}\right) \prod_{l=0}^{m-1} (x - (a + b - x_l))$  und somit folgt  $N(a + b - x) = (-1)^{n+1} N(x) = -N(x)$ .

Wegen ii) gilt damit:

$$\begin{aligned}
 \int_a^b \omega(x) N(x) dx &= \int_a^{x_m} \omega(x) N(x) dx + \int_{x_m}^b \omega(x) N(x) dx \\
 &\stackrel{t=a+b-x}{=} \int_a^{x_m} \omega(x) N(x) dx - \int_a^{x_m} \omega(a+b-t) N(a+b-t) dt \\
 &= \int_a^{x_m} \omega(x) N(x) dx + \int_a^{x_m} \omega(t) (-N(t)) dt = 0.
 \end{aligned}$$

Wir erhalten:  $\int_a^b q_{n+1}(x) \omega(x) dx = \int_a^b p_n(x) \omega(x) dx = I(p_n) = I_n(f)$ , da  $p_n$  Interpolationspolynom zu  $f$ .

Sei nun  $f \in \mathbb{P}_{n+1} \implies f = q_{n+1}$  und daher  $I_n(f) = I(q_{n+1}) = I(f)$ .  $\square$

### Satz 2.6 (Fehlerabschätzung)

Sei  $I_n$  eine Interpolationsquadratur (I.Q.) auf  $\mathbb{P}_n(a, b)$  mit Gewichtsfunktion  $\omega \equiv 1$ .  $R_n(f) := I_n(f) - I(f)$  sei das zugehörige Fehlerfunktional. Dann gilt:

(i)  $|R_n(f)| \leq \frac{\|f^{(n+1)}\|_{\infty}}{(n+1)!} (b-a)^{n+2}$  für alle  $f \in C^{n+1}(a, b)$ , falls  $n$  ungerade ist,

(ii)  $|R_n(f)| \leq \frac{\|f^{(n+2)}\|_{\infty}}{(n+2)!} (b-a)^{n+3}$  für alle  $f \in C^{n+2}(a, b)$ , falls  $n$  gerade ist und die Bedingung i) aus Satz 2.5 erfüllt ist.

*Beweis:*

(i) Es ist  $I_n(f) = I(p_n)$ , wobei  $p_n \in \mathbb{P}_n$  das Interpolationspolynom zu den Daten  $(x_i, f(x_i))$ ,  $i = 0, \dots, n$  ist.

$$\begin{aligned}
 \implies |R_n(f)| &= \left| \int_a^b (f - p_n) dx \right| \leq \int_a^b |f(x) - p_n(x)| dx \\
 &\stackrel{\text{Satz 4.4}}{=} \int_a^b \left| \frac{f^{(n+1)}(\xi_x)}{(n+1)!} \prod_{k=0}^n (x - x_k) \right| dx \\
 &\leq \frac{\|f^{(n+1)}\|_{\infty}}{(n+1)!} (b-a)^{n+2}
 \end{aligned}$$

(ii) Aus dem Beweis vom Satz 2.5 folgt:  $I_n(f) = I(q_{n+1})$ . Dann folgt die Behauptung mit Satz 4.19.  $\square$

**Bemerkung:**

1. Die Abschätzungen lassen sich leicht verallgemeinern auf den Fall  $\omega \in L^1(a, b)$ .

2. Die Abschätzung  $\int_a^b \left| \prod_{k=0}^n (x - x_k) \right| dx \leq (b-a)^{n+2}$  kann für gegebene  $x_0, \dots, x_n$  deutlich verbessert werden zu  $\int_a^b \left| \prod_{k=0}^n (x - x_k) \right| dx \leq K(b-a)^{n+2}$  mit  $K \ll 1$ .

**Satz 2.7 (Koordinatentransformation)**

Sei  $\hat{I}_n(\hat{f}) = \sum_{k=0}^n \hat{\omega}_k \hat{f}(t_k)$  mit  $t_k \in [-1, 1]$  eine I.Q. auf dem „Einheitsintervall“  $[-1, 1]$ . Dann wird durch

$$I_n(f) := \sum_{k=0}^n \omega_k f(x_k)$$

mit

$$\omega_k = \frac{b-a}{2} \hat{\omega}_k, \quad x_k = \frac{b-a}{2} t_k + \frac{b+a}{2}$$

eine I.Q. auf dem Intervall  $[a, b]$  definiert.

Gilt für das Fehlerfunktional  $\hat{R}_n$  zu  $\hat{I}_n$  die Abschätzung  $|R_n(f)| \leq K \|\hat{f}^{(m)}\|_{\infty} 2^{m+1}$ , so gilt für  $R_n$  zu  $I_n$ :  $|R_n(f)| = K \|f^{(m)}\|_{\infty} (b-a)^{m+1}$ .

*Beweis:* Sei  $p \in \mathbb{P}_n$  und  $\hat{p}(t) = p(x(t))$  mit  $x(t) := \frac{b-a}{2}t + \frac{b+a}{2}$ .

Da  $x(t)$  linear ist, gilt  $\hat{p} \in \mathbb{P}_n$  und

$$\begin{aligned} I(p) = \int_a^b p(x) dx &= \int_{-1}^1 p(x(t)) x'(t) dt \\ &= \frac{(b-a)^2}{2} \int_{-1}^1 \hat{p}(t) dt = \frac{b-a}{2} \hat{I}_n(\hat{p}) \\ &= \sum_{k=0}^n \frac{b-a}{2} \hat{\omega}_k \hat{p}(t_k) \\ &= \sum_{k=0}^n \omega_k p(x_k) = I_n(p). \end{aligned}$$

Daher ist  $I_n$  exakt auf  $\mathbb{P}_n$  und  $I_n(f) = \frac{b-a}{2} \hat{I}_n(\hat{f})$  mit  $\hat{f}(t) = f(x(t))$ .

Es ist dann  $\hat{f}'(t) = x'(t) f'(x(t)) = \frac{b-a}{2} f'(x(t))$  und induktiv  $\hat{f}^{(m)}(t) = \left(\frac{b-a}{2}\right)^m f^{(m)}(x(t))$ .  
Also folgt

$$\|\hat{f}^{(m)}\|_{\infty} = 2^{-m} (b-a)^m \|f^{(m)}(x(t))\|_{\infty}.$$

$$\begin{aligned} \implies |R_n(f)| &= \left| \int_a^b f(x) dx - I_n(f) \right| = \left| \frac{b-a}{2} \left[ \int_{-1}^1 \hat{f}(t) dt - \hat{I}_n(\hat{f}) \right] \right| \\ &= \frac{b-a}{2} \left| \hat{R}_n(\hat{f}) \right| \leq \frac{b-a}{2} \|\hat{f}^{(m)}\|_{\infty} K 2^{m+1} \end{aligned}$$

**Bemerkung:**  $= (b-a)^{m+1} \|f^{(m)}\|_{\infty} K$ .

□

1. Es reicht also aus I.Q.en auf  $[-1, 1]$  zu konstruieren. Zu  $-1 \leq t_0 < \dots < t_n \leq 1$  wird durch

$$\hat{\omega}_j := \int_{-1}^1 \prod_{\substack{k=0 \\ k \neq j}}^n \frac{t - t_k}{t_j - t_k} dt$$

die I.Q. für  $\omega = 1$  auf  $[-1, 1]$  zu  $\mathbb{P}_n$  definiert. Mit  $(\omega_j, x_j)_{j=0}^n$  wie im Satz 2.7 wird dann die I.Q. auf  $[a, b]$  definiert.

2. Da für jede I.Q.  $I_n(1) = (b - a)$  gilt, muss  $\sum_{k=0}^n \omega_k = (b - a)$  gelten.
3. Wie bei der Polynominterpolation treten Probleme für große Werte von  $n$  auf, wie z.B. negative Gewichte. Daher geht man dazu über, Quadraturen auf Teilintervallen aufzusummieren:

$$\int_a^b f(x) dx = \sum_{i=1}^N \int_{a_{i-1}}^{a_i} f(x) dx \quad a = a_0 < \dots < a_N = b$$

### Satz 2.8 (Zusammengesetzte Quadraturen)

Sei  $\hat{I}_n(\hat{f}) = \sum_{k=0}^n \hat{\omega}_k \hat{f}(t_k)$  eine I.Q. auf  $[-1, 1]$  mit  $|\hat{R}_n(\hat{f})| \leq K \|\hat{f}^{(m)}\|_{\infty} 2^{m+1}$ . Zu  $a < b$ ,  $N \in \mathbb{N}$  setze  $a_l := a + lH$ ,  $l = 0, \dots, N$  mit  $H := \frac{b-a}{N}$ .

Dann ist

$$I_h(f) := \frac{H}{2} \sum_{l=1}^N \sum_{k=0}^n \hat{\omega}_k f\left(\frac{H}{2}(t_k - 1) + a + lH\right)$$

eine Quadraturformel mit der Abschätzung

$$|R_h(f)| := |I(f) - I_h(f)| \leq K \|f^{(m)}\|_{\infty} (b - a) H^m.$$

*Beweis:* Wir wenden Satz 2.7 auf  $[a_{l-1}, a_l]$  an:

$$\begin{aligned} \Rightarrow I_n^l(f) &:= \sum_{k=0}^n \frac{a_l - a_{l-1}}{2} \hat{\omega}_k f\left(\frac{a_l - a_{l-1}}{2} t_k + \frac{a_l + a_{l-1}}{2}\right) \\ &= \frac{H}{2} \sum_{k=0}^n \hat{\omega}_k f\left(\frac{H}{2}(t_k - 1) + a + lH\right). \end{aligned}$$

Also gilt  $I_h(f) = \sum_{l=1}^N I_n^l(f)$  und es folgt:

$$\begin{aligned} |R_h(f)| &\leq \sum_{l=1}^N |R_n^l(f)| \stackrel{\text{Satz 2.7}}{\leq} K \|f^{(m)}\|_{\infty} \sum_{l=1}^N (a_l - a_{l-1})^{m+1} \\ &= K \|f^{(m)}\|_{\infty} \underbrace{NH}_{=(b-a)} H^m. \end{aligned}$$

□

## 2.1 Newton-Cotes Formeln

- Die Newton-Cotes Formeln sind I.Q.en mit äquidistanten Stützstellen  $x_k = a + kh$ ,  $h = \frac{b-a}{n}$ .
  - Als offene Newton-Cotes Formeln bezeichnet man I.Q.en zu äquidistanten Stützstellen  $x_k = a + (k + 1)h$ ,  $h = \frac{b-a}{n+2}$ , d.h. die Randpunkte  $a, b$  sind keine Stützstellen.
1.  $n = 1$  (Trapezregel)

$$x_0 = a, \quad x_1 = b, \quad \omega_0 = \int_a^b \frac{x-b}{a-b} dx = \frac{b-a}{2}, \quad \omega_1 = \frac{b-a}{2},$$

$$T(f) = I_1(f) = \frac{b-a}{2} (f(a) + f(b)) \text{ (vgl. Abb. 2.1).}$$

$$\begin{aligned} |R_T(f)| &\leq \frac{\|f''\|_{\infty}}{2} \int_a^b |x-a| |x-b| \\ &= \frac{\|f''\|_{\infty}}{2} \frac{(b-a)^3}{6} = \frac{\|f''\|_{\infty}}{12} (b-a)^3. \end{aligned}$$

2.  $n = 2$  (Simpson-Regel)

$$x_0 = a, x_1 = \frac{a+b}{2}, x_2 = b, \omega_0 = \omega_2 = \frac{b-a}{6}, \omega_1 = \frac{2(b-a)}{3},$$

$$S(f) = I_2(f) = \frac{b-a}{6} (f(a) + 4f\left(\frac{a+b}{2}\right) + f(b)),$$

$$|R_S(f)| \leq \frac{\|f^{(4)}\|_\infty}{2880} (b-a)^5$$

Zusammengesetzte Newton-Cotes Formeln1. **Zusammengesetzte Trapezregel** (Satz 2.8,  $n = 1$ ,  $h = H$ )

$$T_h(f) = \frac{h}{2} \sum_{l=1}^N [f(a + lh - h) + f(a + lh)] = \frac{h}{2} \left( f(a) + 2 \sum_{l=1}^{N-1} f(a + lh) + f(b) \right),$$

$$|R_h(f)| \leq \frac{\|f''\|_\infty}{12} (b-a)h^2.$$

2. **Zusammengesetzte Simpson-Regel** (Satz 2.8,  $n = 2$ ,  $h = \frac{H}{2}$ ,  $x_i := a + ih$ )

$$S_h(f) = \frac{h}{3} \left( f(a) + 2 \sum_{l=1}^{N-1} f(x_{2l}) + 4 \sum_{l=1}^N f(x_{2l-1}) + f(b) \right),$$

$$|R_n(f)| \leq \frac{\|f^{(4)}\|_\infty}{180} (b-a)h^4.$$

**Bemerkung:** Bei den Newton-Cotes Formeln bleiben die Gewichte bis  $n = 6$  positiv. Bei den offenen Newton-Cotes Formeln nur bis  $n = 2$ .

## 2.2 Gauß-Quadraturen

**Idee:** Wir suchen eine Quadratur  $Q_n$ , welche für  $\mathbb{P}_m$  mit möglichst großem  $m$  exakt ist. Dies ist nicht möglich für  $m = 2n + 2$  (Gegenbeispiel konstruierbar). Aber für  $m = 2n + 1$  wird dies mit der Gauß-Quadratur (G.Q.) erreicht.

**Definition 2.9 (Gauß-Quadraturen)**

Sei  $\omega \in L^1(a, b)$  gegeben. Eine Quadraturformel  $Q_n : C([a, b]) \rightarrow \mathbb{R}$ ,  $Q_n(f) := \sum_{k=0}^n \omega_k f(x_k)$  heißt **Gauß-Quadratur**, falls  $Q_n$  exakt ist auf  $\mathbb{P}_{2n+1}$ .

**Satz 2.10**

Sei  $\omega \in L^1(a, b)$  und eine Quadratur  $Q_n(f) := \sum_{k=0}^n \omega_k f(x_k)$  gegeben. Setze  $p_{n+1}(x) := \prod_{k=0}^n (x - x_k)$ . Dann sind äquivalent:

(i)  $Q_n$  ist Gauß-Quadratur.

(ii)  $Q_n$  ist Interpolationsquadratur und  $\int_a^b \omega(x) p_{n+1}(x) q(x) dx = 0 \quad \forall q \in \mathbb{P}_n$ .

*Beweis:* „(i)  $\Rightarrow$  (ii)“: Sei  $q \in \mathbb{P}_n$ . Dann ist

$$\int_a^b \omega(x) p_{n+1}(x) q(x) dx = Q_n(p_{n+1} q) = \sum_{k=0}^n \omega_k \underbrace{p_{n+1}(x_k)}_{=0 \text{ nach Def.}} q(x_k) = 0.$$

„(ii)  $\Rightarrow$  (i)“: Sei  $p \in \mathbb{P}_{2n+1}$ . Mit Polynomdivision gilt:  $p = qp_{n+1} + r$  mit  $q, r \in P_n$ . Damit folgt

$$\begin{aligned} \int_a^b \omega(x) p(x) dx &= \int_a^b \omega(x) \left( \underbrace{q(x)p_{n+1}(x)}_{=0} + r(x) \right) dx \\ &\stackrel{\text{Vor. (ii)}}{=} 0 + \int_a^b \omega(x) r(x) dx \\ &= 0 + Q_n(r) \\ &= Q_n(p_{n+1} q) + Q_n(r) \\ &= Q_n(p). \end{aligned}$$

□

### Definition 2.11

(i) Eine Funktion  $\omega \in L^1(a, b)$  heißt **zulässige Gewichtsfunktion**, falls gilt  $\omega \geq 0$  und  $\int_a^b \omega(x) dx > 0$ .

(ii) Ist  $\omega$  eine zulässige Gewichtsfunktion, so wird durch

$$\langle p, q \rangle_\omega := \int_a^b \omega(x) p(x) q(x) dx$$

ein Skalarprodukt auf  $\mathbb{P}_n$  definiert.

### Satz 2.12

Sei  $\omega$  eine zulässige Gewichtsfunktion. Dann liefert die durch das Gram-Schmidtsche Orthogonalisierungsverfahren definierte Folge  $(p_n)_{n \in \mathbb{N}}$

$$p_{n+1}(x) = x^{n+1} - \sum_{i=0}^n \frac{\langle x^{n+1}, p_i \rangle_\omega}{\langle p_i, p_i \rangle_\omega} p_i(x), p_0 = 1$$

das eindeutig bestimmte normierte Polynom  $p \in \mathbb{P}_{n+1}$  der Form

$$(*) \quad p(x) = \prod_{k=0}^n (x - x_k) \quad x_k \in \mathbb{C}, \quad 0 \leq k \leq n$$

mit

$$(**) \quad \langle p, q \rangle_\omega = 0 \quad \forall q \in \mathbb{P}_n.$$

Außerdem ist  $\{p_0, p_1, \dots, p_{n+1}\}$  eine **Orthogonalbasis** von  $\mathbb{P}_{n+1}$  bezüglich  $\langle \cdot, \cdot \rangle_\omega$ .

*Beweis:* (Induktion über  $n$ )

$n = 0$  : klar.

$n - 1 \longrightarrow n$  : Sei  $\{p_0, \dots, p_n\}$  eine Orthogonalbasis von  $\mathbb{P}_n$ . Setze

$$\mathbb{P}_n^\perp := \left\{ p \in \mathbb{P}_{n+1} \mid \langle p, q \rangle_\omega = 0 \quad \forall q \in \mathbb{P}_n \right\} \implies \dim(\mathbb{P}_n^\perp) = 1.$$

Da  $(*)$  verlangt, dass der Koeffizient vor  $x^{n+1}$  gleich 1 ist, gibt es genau ein  $p \in \mathbb{P}_{n+1}$ , welches  $(*)$  und  $(**)$  erfüllt. Nach Konstruktion ist  $p = p_{n+1}$ , da  $\langle p_{n+1}, p_k \rangle_\omega = 0 \quad \forall 0 \leq k \leq n$ .

Also folgt  $\langle p_{n+1}, q \rangle_\omega = 0 \quad \forall q \in \mathbb{P}_n$ . □

### Satz 2.13

Sei  $\omega$  eine zulässige Gewichtsfunktion. Dann gilt: die Nullstellen  $x_0, \dots, x_n$  von  $p_{n+1}$  aus Satz 2.12 sind reell, einfach und liegen im Intervall  $(a, b)$ .

*Beweis:* Wir setzen:

$q(x) = 1, k = -1$ , falls es keine reelle Nullstelle ungerader Vielfachheit von  $p_{n+1}$  in  $(a, b)$  gibt,

$$q(x) = \prod_{j=0}^k (x - x_j) \text{ andernfalls, wobei } x_j, 0 \leq j \leq k \text{ alle solche Nullstellen sind.}$$

Zu zeigen:  $k = n$  und somit  $q = p_{n+1}$ .

Annahme:  $k < n$ : Nach Definition hat  $p := p_{n+1}q$  kein Vorzeichenwechsel in  $(a, b)$ . Da  $k < n$ , folgt  $q \in \mathbb{P}_n$  und somit  $\langle p_{n+1}, q \rangle_\omega = 0 \implies \omega p_{n+1}q = 0$  (fast überall) und somit  $\omega = 0$  (fast überall). Dies ist ein Widerspruch zur Definition von  $\omega$ . □

### Satz 2.14

Sei  $\omega$  eine zulässige Gewichtsfunktion. Dann gibt es genau eine G.Q.  $Q_n$  für  $\omega$ , nämlich die, deren Stützstellen  $x_0, \dots, x_n$  die Nullstellen von  $p_{n+1}$  aus Satz 2.12 sind und deren Gewichte definiert sind durch

$$\omega_j := \int_a^b \omega(x) L_j(x) dx$$

mit

$$L_j(x) := \prod_{\substack{k=0 \\ k \neq j}}^n \frac{(x - x_k)}{(x_j - x_k)}$$

Es gilt  $\omega_j > 0 \quad \forall j$ .

*Beweis:* Folgt aus den Sätzen 2.10, 2.12, 2.13 und aus dem Satz 2.3.

Noch zu zeigen:  $\omega_j > 0 \quad \forall j$  : Da  $L_j^2 \in \mathbb{P}_{2n}$  ist, folgt:

$$0 < \int_a^b \omega(x) L_j^2(x) dx = Q_n(L_j^2) = \sum_{k=0}^n \omega_k L_j^2(x_k) = \omega_j.$$

□

**Satz 2.15 (Deutung der Gauß-Quadratur als Interpolationsquadratur)**

Seien  $p$  das eindeutige bestimmte Polynom in  $\mathbb{P}_{2n+1}$  mit den Eigenschaften  $p(x_i) = f(x_i)$ ,  $p'(x_i) = f'(x_i)$  für  $i = 0, \dots, n$  und  $x_i$  die Nullstellen von  $p_{n+1}$ . Dann gilt:

$$Q_n(f) = Q_n(p) = I(p).$$

*Beweis:* (Übungsaufgabe)

□

**Folgerung 2.16**

Für  $f \in C^{2n+2}(a, b)$  gibt es ein  $\xi \in (a, b)$  mit  $I(f) - Q_n(f) = \frac{f^{(2n+2)}(\xi)}{(2n+2)!} \langle p_{n+1}, p_{n+1} \rangle_{\omega}$

*Beweis:* (Übungsaufgabe)

**Bemerkung:** Die G.Q.en sind für stetige Funktionen auf kompakten Intervallen konvergent bei Graderhöhung, d.h.  $|I(f) - Q_n(f)| \xrightarrow{n} 0$ .

**Beispiel 2.17****1. Gauß-Legendre-Quadratur**

$$\omega(x) = 1, [-1, 1].$$

Es gilt  $p_n(x) = \frac{(2n)!}{2^n(n!)^2} P_n(x)$ , wobei  $P_n(x)$  die **Legendre-Polynome** sind mit  $P_0(x) = 1$ ,  $P_1(x) = x$ , und

$$P_{n+1}(x) = \frac{2n+1}{n+1} x P_n(x) - \frac{n}{n+1} P_{n-1}(x).$$

$$\text{Es gilt: } I(f) - Q_n(f) = 2^{2n} \frac{n+1}{2n+2} \frac{(n!)^4}{((2n+1)!)^3} f^{(2n+2)}(\xi).$$

$$\text{Für } n = 1: Q_1(f) = f\left(-\frac{1}{\sqrt{3}}\right) + f\left(\frac{1}{\sqrt{3}}\right) \text{ („2-Punkt-Gauß-Quadratur“).}$$

$$n = 2: Q_2(f) = \frac{1}{9} \left( 5f\left(-\sqrt{\frac{3}{5}}\right) + 8f(0) + 5f\left(\sqrt{\frac{3}{5}}\right) \right).$$

Die G.Q. auf  $[a, b]$  erhält man durch Koordinatentransformation (vgl. 2.7).

**2. Gauß-Tschebyscheff-Quadratur**

$$\omega(x) = \sqrt{1 - x^2}^{-1}, [-1, 1].$$

$p_n(x) = \frac{1}{2^{n-1}} T_n(x)$  und  $T_n$  die Tschebyscheff-Polyome 1. Art mit

$$T_0(x) = 1, T_1(x) = x \text{ und}$$

$$T_{n+1}(x) = 2xT_n(x) - T_{n-1}(x),$$

$$\implies T_n(x) = \cos(n \arccos(x)).$$

$$\text{Nullstellen von } p_{n+1}: x_j^{(n)} = \cos\left(\frac{2j+1}{2n+1}\pi\right) \quad j = 0, \dots, n.$$

$$\text{Gewichte: } \omega_j^{(n)} = \frac{\pi}{n+1}.$$

$$\text{Fehler: } I(f) - Q_n(f) = \frac{\pi}{2^{2n+1}(2n+2)!} f^{(2n+2)}(\xi).$$

### 3. Gauß-Laguerre-Quadratur

$\omega(x) = e^{-x}$ ,  $[0, \infty)$ .

$p_n(x) = (-1)^n L_n(x)$  und  $L_n$  Laguerre-Polynome mit

$L_0(x) = 1$ ,  $L_1(x) = 1 - x$  und

$$L_{n+1}(x) = (1 + 2n - x)L_n(x) - n^2 L_{n-1}(x).$$

Fehler:  $I(f) - Q_n(f) = \frac{n+1}{2} \frac{(n!)^2}{(2n+1)!} f^{(2n+2)}(\xi)$ .

### 4. Gauß-Hermite-Quadratur

$\omega(x) = e^{-x^2}$ ,  $(-\infty, \infty)$ .

$p_n(x) = 2^n H_n(x)$  und  $H_n$  die Hermite Polynome mit

$H_0(x) = 1$ ,  $H_1(x) = 2x$  und

$$H_{n+1}(x) = 2xH_n(x) - 2nH_{n-1}(x).$$

Fehler:  $I(f) - Q_n(f) = \frac{\sqrt{\pi}n!}{2^{n+1}(2n+1)!} f^{(2n+2)}(\xi)$ .

### 5. Gauß-Jacobi-Quadratur

$\alpha, \beta > -1$ ,  $\omega(x) = (1 - x)^\alpha (1 + x)^\beta$ ,  $[-1, 1]$ .

$p_n(x) = J_n(x, \alpha, \beta)$  und  $J_n(x, \alpha, \beta)$  sind die Jacobi-Polynome, definiert durch

$$J_n(x, \alpha, \beta) := \frac{1}{2^n n! \omega(x)} \frac{d^k}{dx^n} ((x^2 - 1)^n \omega(x)).$$

#### Definition 2.18 (Zusammengesetzte Gauß-Quadraturen)

Zu  $a < b$ ,  $N \in \mathbb{N}$  setze  $a_l := a + lH$ ,  $l = 0, \dots, N$  mit  $H := \frac{b-a}{N}$ . Sei  $Q_n^l(f)$ ,  $n \in \mathbb{N}$  eine Gauß-Quadratur auf  $[a_{l-1}, a_l]$ , dann ist durch

$$Q_h(f) := \sum_{l=1}^N Q_n^l(f)$$

eine zusammengesetzte Gauß-Quadratur definiert.

**Beispiel:** (Zusammengesetzte 2-Punkt G.Q. mit  $n = 1$ ,  $\omega = 1$ )

Setze  $h = \frac{b-a}{N}$ ,  $a_l = a + lh$  für  $l = 0, \dots, N$ . Dann ist die zusammengesetzte 2-Punkt G.Q. gegeben durch

$$Q_h(f) = \frac{h}{2} \sum_{j=0}^{N-1} (f(a_j + h') + f(a_{j+1} - h'))$$

mit  $h' = \frac{h}{2} \left(1 - \frac{1}{\sqrt{3}}\right)$ .

## 2.3 Romberg Verfahren

**Idee:** Anwendung der Richardson Extrapolation auf eine zusammengesetzte Quadraturformel, d.h.

$$a(h) = T_h(f)$$

wobei  $h_k = h_0 2^{-k}$  gewählt wird (Romberg Folge). Besonders geeignet ist die zusammengesetzte Trappezregel  $T_h(f)$ , da sie eine asymptotische Entwicklung in  $h^2$  erlaubt, d.h.  $q = 2$  in Satz 4.23. Um dies zu beweisen, führen wir zunächst die Bernoulli Polynome ein.

**Definition 2.19 (Bernoulli Polynome/Zahlen)**

Die durch  $B_0(t) = 1$  und  $\frac{\partial}{\partial x} B_k(t) = B_{k-1}(t)$ ,  $\int_0^1 B_k(t) dt = 0, k \geq 1$ , definierten Polynome heißen **Bernoulli Polynome**. Es ist also

$$B_0(t) = 1, \quad B_1(t) = t - \frac{1}{2}, \quad B_2(t) = \frac{1}{2}t^2 - \frac{1}{2}t + \frac{1}{12}, \quad \dots$$

Die **Bernoulli Zahlen** sind gegeben durch

$$B_k := k! \cdot B_k(0).$$

**Lemma 2.20 (Eigenschaften der Bernoulli Polynome)**

Für die Bernoulli Polynome gilt:

(i)  $B_k(0) = B_k(1)$  für  $k \geq 2$ ,

(ii)  $B_k(t) = (-1)^k B_k(1-t)$  für  $k \geq 0$ ,

(iii)  $B_{2k+1}(0) = B_{2k+1}\left(\frac{1}{2}\right) = B_{2k+1}(1) = 0$  für  $k \geq 1$ .

*Beweis:* (ohne Beweis) □

**Satz 2.21 (Euler-MacLaurin'sche Summenformel)**

Sei  $f \in C^{2m}(a, b)$ ,  $m \in \mathbb{N}$  und  $h := \frac{b-a}{n}$ ,  $n \in \mathbb{N}$ . Dann gilt:

$$T_h(f) = \int_a^b f(x) dx + \sum_{k=1}^{m-1} h^{2k} \frac{B_{2k}}{(2k)!} \left( f^{(2k-1)}(b) - f^{(2k-1)}(a) \right) + O(h^{2m}).$$

*Beweis:* Sei  $\varphi \in C^{2m}(0, 1)$  beliebig. Dann gilt mit  $B'_1 = B_0$ ,  $B_1(1) = \frac{1}{2}$ ,  $B_1(0) = -\frac{1}{2}$ :

$$\begin{aligned}
 \int_0^1 \varphi(t) dt &= \int_0^1 B_0(t) \varphi(t) dt \\
 &= [B_1(t) \varphi(t)]_{t=0}^1 - \int_0^1 B_1(t) \varphi'(t) dt \\
 &= \frac{1}{2} (\varphi(1) + \varphi(0)) - [B_2(t) \varphi'(t)]_{t=0}^1 + \int_0^1 B_2(t) \varphi''(t) dt \\
 &\stackrel{2.20.i}{=} \frac{1}{2} (\varphi(1) + \varphi(0)) - B_2(0) (\varphi'(1) - \varphi'(0)) + \underbrace{[B_3(t) \varphi''(t)]_{t=0}^1}_{=0 \text{ 2.20.iii}} - \int_0^1 B_3(t) \varphi'''(t) dt \\
 &= \dots \\
 &= \frac{1}{2} (\varphi(1) - \varphi(0)) - \sum_{k=1}^{m-1} B_{2k}(0) (\varphi^{(2k-1)}(1) - \varphi^{(2k-1)}(0)) + \int_0^1 B_{2m}(t) \varphi^{(2m)}(t) dt
 \end{aligned}$$

Setze  $\varphi_j(t) := h f(x_{j-1} + th)$ ,  $1 \leq j \leq n$ , dann gilt:

- $\int_0^1 \varphi_j(t) dt = \int_0^{x_j} f(x) dx$ ,
- $\varphi_j^{(k-1)}(t) = h^{k-1} f^{(k-1)}(x_{j-1} + th)$ ,
- $\varphi_j(1) = h f(x_j) = \varphi_{j+1}(0)$ ,
- $\varphi_j^{(2k-1)}(1) = \varphi_{j+1}^{(2k-1)}(0)$ .

Daher gilt:

$$\begin{aligned}
 \int_a^b f(x) dx &= \sum_{j=1}^n \int_{x_{j-1}}^{x_j} f(x) dx = \sum_{j=1}^n \int_0^1 \varphi_j(t) dt \\
 &= \sum_{j=1}^n \frac{1}{2} (\varphi_j(0) + \varphi_j(1)) - \sum_{j=1}^n \sum_{k=1}^{m-1} B_{2k}(0) (\varphi_j^{(2k-1)}(1) - \varphi_j^{(2k-1)}(0)) \\
 &\quad + \sum_{j=1}^n \int_0^1 B_{2m}(t) \varphi_j^{(2m)}(t) dt \\
 &= \sum_{j=1}^n \frac{h}{2} (f(x_j) + f(x_{j-1})) - \sum_{k=1}^{m-1} B_{2k}(0) (\varphi_k^{(2k-1)}(1) - \varphi_k^{(2k-1)}(0)) \\
 &\quad + \sum_{j=1}^n \int_0^1 B_{2m}(t) h^{2m+1} f^{(2m)}(x_{j-1} + th) dt \\
 &= T_h(f) - \sum_{k=0}^{m-1} B_{2k}(0) (f^{(2k-1)}(b) - f^{(2k-1)}(a)) h^{2k} \\
 &\quad + h^{2m} \left[ h \sum_{j=1}^m \int_0^1 B_{2m}(t) f^{(2m)}(x_{j-1} + (h)) dt \right].
 \end{aligned}$$

Der letzte Term ist  $O(h^{2m})$ , falls  $[\cdot]$  durch eine Konstante unabhängig von  $h$  abgeschätzt werden kann. Wir erhalten

$$\begin{aligned}
 \left| h \sum_{j=1}^m \int_0^1 B_{2m}(t) f^{(2m)}(x_{j-1} + (h)) dt \right| &\leq h \sum_{j=1}^m \|B_{2m}\|_\infty \|f^{(2m)}\|_\infty \\
 &= n \cdot h \cdot \|B_{2m}\|_\infty \cdot \|f^{(2m)}\|_\infty \\
 &= (b-a) \|B_{2m}\|_\infty \cdot \|f^{(2m)}\|_\infty = \text{konstant}.
 \end{aligned}$$

**Bemerkung:** Die Summenformel zeigt die asymptotische Entwicklung und dass die Trapezregel auch ohne Extrapolation sehr gut für die Integration periodischer Funktionen geeignet ist.  $\square$

**Definition 2.22 (Experimentelle Konvergenzordnung (EOC))**

Sei  $f \in C^k(a, b)$  und  $I : C^k(a, b) \rightarrow \mathbb{R}$  ein Funktional,  $I_h$  eine Quadraturformel, die  $I$  auf einer Zerlegung der Feinheit  $h$  approximiert. Gelte  $h_1 > h_2$ .

Die **experimentelle Konvergenz**  $EOC(e_{h_1} \rightarrow h_2)$  (engl. *experimental order of convergence*) für den Fehler  $e_h := |I(f) - I_h(f)|$  ist definiert durch

$$EOC(e_{h_1} \rightarrow h_2) := \frac{\log\left(\frac{e_{h_1}}{e_{h_2}}\right)}{\log\left(\frac{h_1}{h_2}\right)}.$$

**Bemerkung:** Für  $h \rightarrow 0$  verhält sich der Fehler wie  $h^p$ , wobei  $p$  vom angewandten Verfahren abhängt. Mit der EOC hat man die Möglichkeit,  $p$  numerisch zu bestimmen.

**Beispiel 2.23 (Fehler der Approximierung der Integration)**

Gegeben seien  $I = [0, 1]$  und  $f(x) := \frac{1}{x+1}$ ,  $g(x) := \frac{3}{2}\sqrt{x}$ . Es gilt  $\int_0^1 \frac{1}{x+1} dx = \ln(2)$ ,  $\int_0^1 \frac{3}{2}\sqrt{x} dx = 1$ .

Die Abbildung 2.2 zeigt das Verhalten des Approximationsfehlers von 4 Verfahren: Trapezregel (rot), Simpson-Regel (grün), zwei-Punkt Quadratur (blau) und Romberg Verfahren (lila). **Typ 1** ist der Fehler im Vergleich zu der Anzahl der Funktionauswertungen, im Prinzip ein Maß für den Berechnungsaufwand. **Typ 2** ist der Fehler im Vergleich zu  $h$ , d.h. zu der Unterteilung bei den zusammengesetzten Quadraturen. **Typ 3** ist die EOC im Verhältnis zu  $h$ .

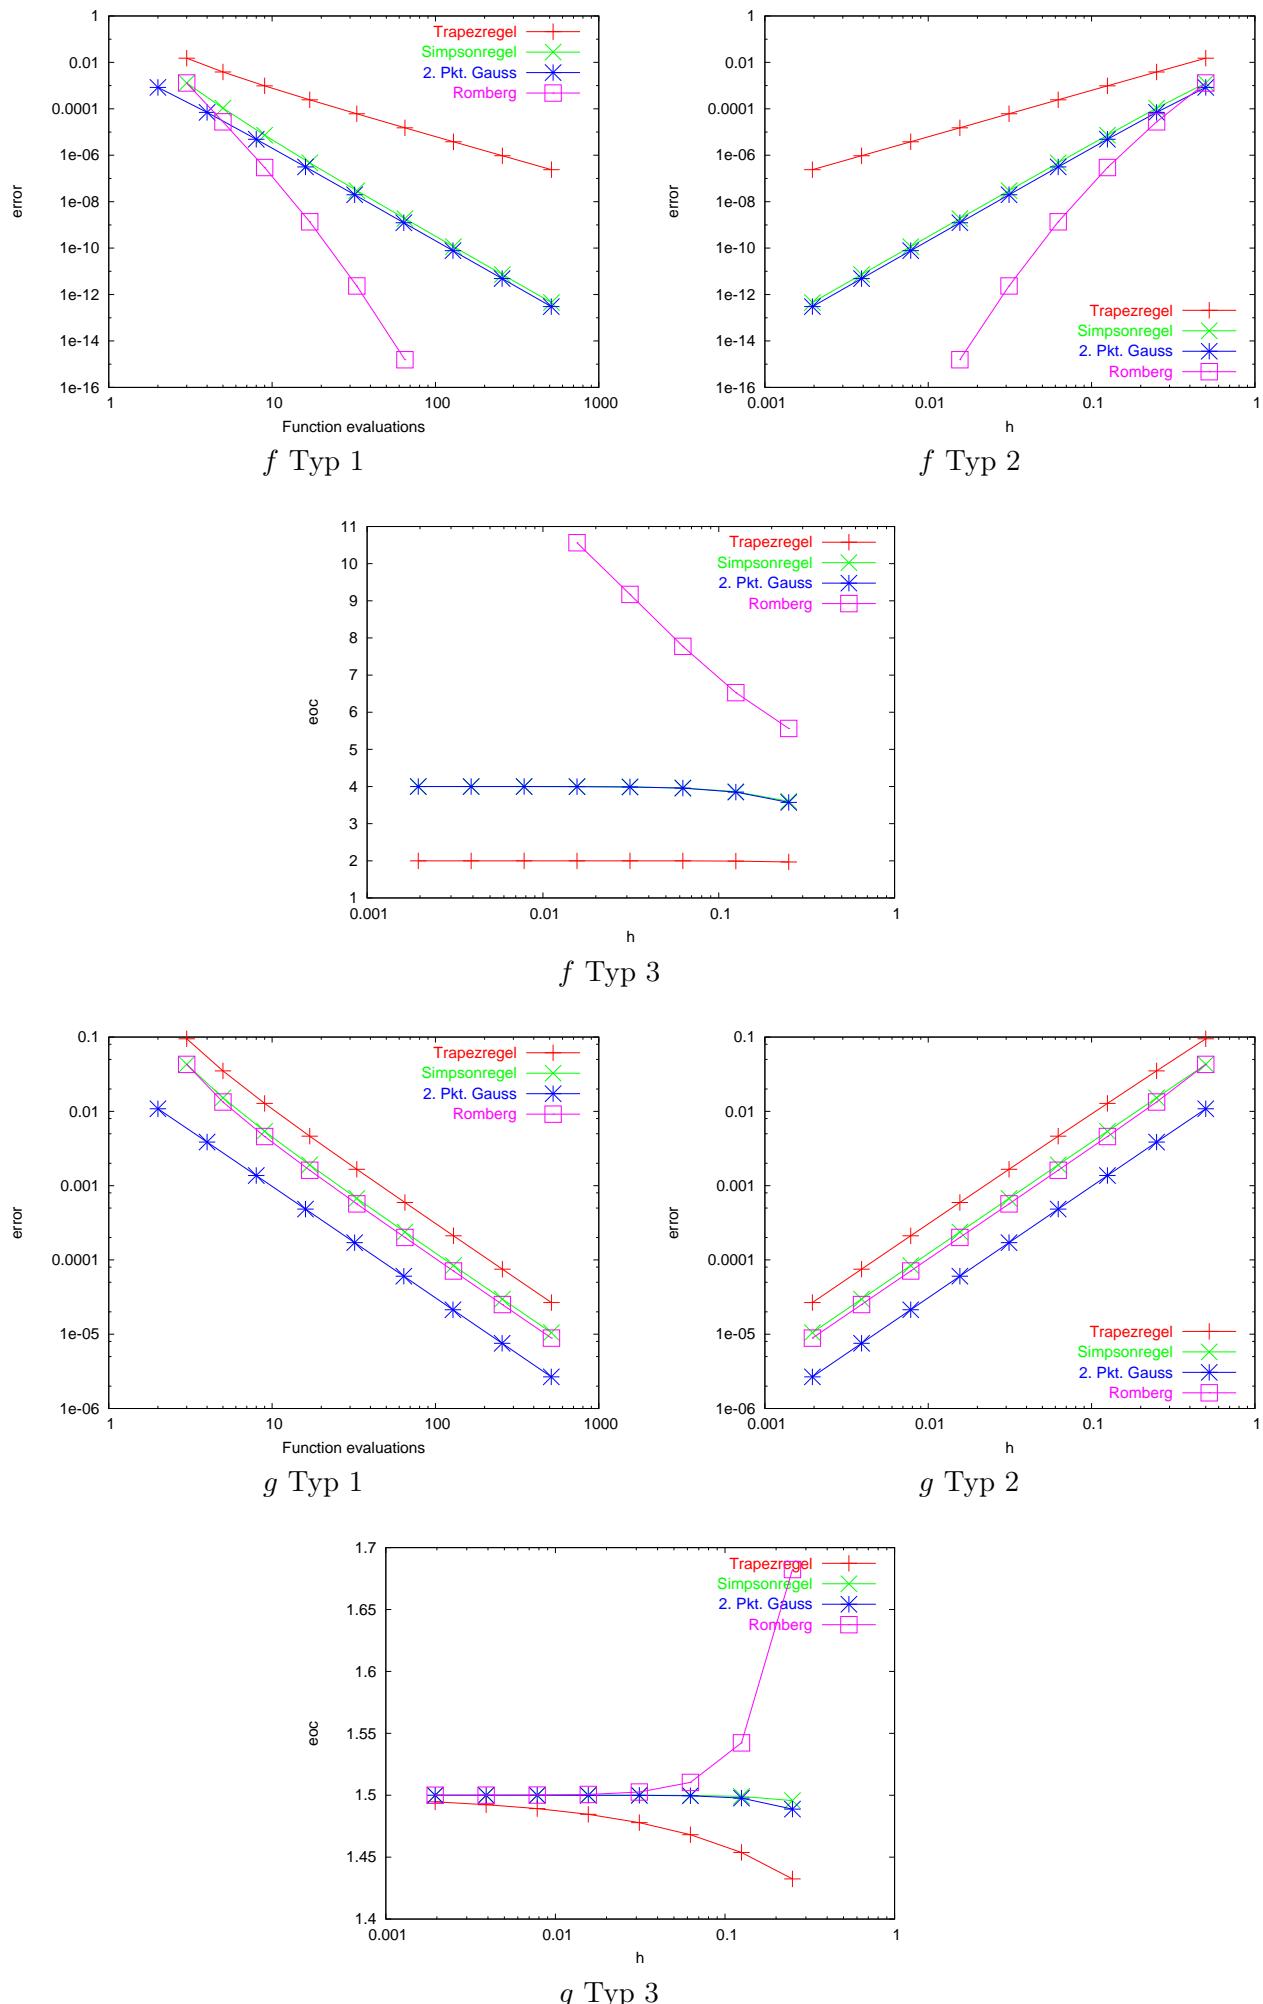


Abbildung 2.2: Fehler der Quadraturen

## Kapitel 3

# Numerik Gewöhnlicher Differentialgleichungen

### 3.1 Einleitung

Viele Fragestellungen aus den Naturwissenschaften, der Ökonomie und Medizin führen auf mathematische Probleme, die numerisch gelöst werden müssen. In dieser Vorlesung wird die Theorie und Praxis grundlegender numerischer Algorithmen zur Behandlung gewöhnlicher Differentialgleichungen behandelt. Dazu gehören Einschritt- und Mehrschrittverfahren zur Approximation von Anfangswertproblemen, sowie Finite Differenzen und Finite Elemente Verfahren zur Diskretisierung von Randwertproblemen. Weitere Themen sind Gradientenverfahren, Eigenwertprobleme und Grundzüge der Approximation.

Beginnen wir mit ein paar Grundbegriffen und Beispielen zu gewöhnlichen Differentialgleichungen:

#### Definition 3.1 (Gewöhnliche Differentialgleichung)

Seien  $n \in \mathbb{N}$  und  $I \subset \mathbb{R}$  ein Intervall und  $F : I \times \mathbb{R}^{n+1} \rightarrow \mathbb{R}$  gegeben.

Unter einer skalaren gewöhnlichen Differentialgleichung (DGL)  $n$ -ter Ordnung für eine Funktion  $y \in C^n(I)$  versteht man eine Gleichung der Form

$$F(x, y(x), y'(x), y''(x), \dots, y^{(n)}(x)) = 0, \quad (x \in I). \quad (3.1)$$

Falls eine Funktion  $f : I \times \mathbb{R}^n \rightarrow \mathbb{R}$  existiert, so dass (3.1) in der Form

$$y^{(n)}(x) = f(x, y(x), y'(x), y''(x), \dots, y^{(n-1)}(x)), \quad (x \in I) \quad (3.2)$$

geschrieben werden kann, so heißt (3.1) explizit (sonst implizit). Ein Funktion  $y \in C^n(I)$ , die (3.1) erfüllt, heißt Lösung der gewöhnlichen Differentialgleichung.

#### Beispiel 3.2 (Freier Fall/Gravitation)

Sei  $t \in I := [0, \infty]$  die Zeit,  $x(t) \in \mathbb{R}$  der Ort eines Massepunktes zur Zeit  $t$ ,  $v(t) = x'(t)$  die Geschwindigkeit des Massepunktes und  $a(t) = v'(t) = x''(t)$  die Beschleunigung des Massepunktes, sowie  $K = K(t, x(t), v(t))$  eine äußere Kraft, die auf den Massepunkt wirkt.

**Newton'sches Kraftgesetz:**

$$\begin{aligned} mx''(t) &= K(t, x(t), x'(t)), \\ \implies x''(t) &= \frac{1}{m} K(t, x(t), x'(t)). \end{aligned} \quad (3.3)$$

Für gegebene Kraft  $K$  ist (3.3) eine explizite DGL zweiter Ordnung.

**A) Freier Fall ohne Luftwiderstand:**

Erbeschleunigung:  $g = 9.81 \frac{m}{s^2} \implies K(t, x(t), x'(t)) = -mg$ .  
Einsetzen in (3.3) ergibt:

$$\begin{aligned} x''(t) &= -\frac{1}{m} mg = -g, \\ \implies x'(t) &= -gt + c_1, \\ \implies x(t) &= -\frac{1}{2}gt^2 + c_1t + c_2, \quad \text{mit } c_1, c_2 \in \mathbb{R}. \end{aligned}$$

Die Lösung dieser DGL ist also nicht eindeutig bestimmt.

**B) Freier Fall mit Luftwiderstand:**

Hier ist die Kraft gegeben durch:

$$K(t, x(t), x'(t)) = -\sigma x'(t) - mg, \quad \text{mit } \sigma > 0.$$

Wir erhalten die DGL:

$$x''(t) = -\frac{\sigma}{m}x'(t) - g.$$

Mit  $x'(t) = v(t)$  ergibt sich eine DGL erster Ordnung für  $v$ :

$$v'(t) = -\frac{\sigma}{m}v(t) - g. \quad (3.4)$$

Die Funktionen  $v(t) = c_1 \exp(-\frac{\sigma}{m}t) - \frac{mg}{\sigma}$  sind für alle  $c_1 \in \mathbb{R}$  Lösungen von (3.4), denn

$$\begin{aligned} v'(t) &= -c_1 \frac{\sigma}{m} \exp(-\frac{\sigma}{m}t), \\ \text{und } -\frac{\sigma}{m}v(t) - g &= -c_1 \frac{\sigma}{m} \exp(-\frac{\sigma}{m}t) + g - g. \end{aligned}$$

**Bemerkung:** Man kann zeigen, dass alle Lösungen von (3.4) von dieser Form sein müssen.

Für die Lösung von (3.3) gilt nach Integration:

$$x(t) = -c_1 \frac{m}{\sigma} \exp(-\frac{\sigma}{m}t) - \frac{mg}{\sigma}t + c_2.$$

Auch hier ist die Lösung nicht eindeutig.

**C) Freier Fall aus großer Höhe:**

Da sich die Gravitation mit der Höhe ändert, müssen wir in diesem Fall das Gravitationsgesetz ansetzen als:

$$K(t, x(t), x'(t)) = -mg \frac{R^2}{x^2(t)}$$

Dabei bezeichnet  $R$  den Erddurchmesser. Wir erhalten die explizite DGL zweiter Ordnung:

$$x''(t) = -g \frac{R^2}{x^2(t)}. \quad (3.5)$$

**Ansatz zur Lösung:**  $x(t) = at^b$ . Damit erhalten wir:  $x'(t) = abt^{b-1}$  und  $x''(t) = ab(b-1)t^{b-2}$ . Einsetzen in (3.5) ergibt:

$$ab(b-1)t^{b-2} = -gR^2 \frac{1}{a^2 t^{2b}} = -\frac{gR^2}{a^2} t^{-2b}.$$

Also muß gelten:

$$\begin{aligned} 1.) \ b-2 &= -2b \implies b = \frac{2}{3}, \\ 2.) \ ab(b-1) &= -\frac{gR^2}{a^2} \implies a = \left(\frac{9gR^2}{2}\right)^{1/3}. \end{aligned}$$

Also ist

$$x(t) = \left(\frac{9gR^2}{2}\right)^{1/3} t^{2/3}$$

eine Lösung von (3.5).

### Beispiel 3.3

Für die explizite DGL erster Ordnung

$$y'(x) = x^2 + (y(x))^2$$

kann keine Lösung in geschlossener Form angegeben werden. Es existieren jedoch Lösungen!

**Bemerkung:** Wir halten fest:

1. Die Bestimmung einer Lösung (in Formelgestalt) ist sehr oft nicht möglich.
2. Falls eine Lösung existiert, ist sie i.A. nicht eindeutig.
3. Die *freien Konstanten* ( $c_1, c_2, \dots$ ) können durch zusätzliche Bedingungen festgelegt werden: Anfangswerte oder Randwerte.

In diesem Kapitel werden wir uns mit numerischen Verfahren zur Lösung von gewöhnlichen Differentialgleichungen beschäftigen. Dabei werden wir uns zunächst mit Anfangswertproblemen auseinandersetzen.

## 3.2 Exkurs zur Theorie gewöhnlicher Differentialgleichungen

### Definition 3.4 (Anfangswertproblem (AWP))

Sei folgende Voraussetzung erfüllt:

(V) Seien  $I := [a, b]$ ,  $b < a$ ,  $G \subset \mathbb{R}^n$  zusammenhängende und offene Teilmenge (Gebiet),  $S := I \times G$  und  $f : S \rightarrow \mathbb{R}^n$  stetig und  $y_0 \in G$ .

Dann heißt  $y : I \rightarrow \mathbb{R}^n$  Lösung des AWP, g.d.w.

(i)  $y \in C^1(I, \mathbb{R}^n)$  und  $y(I) \subseteq G$

(ii)  $y'(x) = f(y, y(x)) \quad \forall x \in I$

(iii)  $y(a) = y_0$

**Satz 3.5**

Unter der Voraussetzung (V) sind folgende Aussagen äquivalent:

- a)  $y : I \rightarrow \mathbb{R}^n$  löst (AWP).
- b)  $y \in C^0(I, G)$  und  $y(x) = y_0 + \int_a^x f(s, y(s))ds \quad \forall x \in I$ .

*Beweis:* siehe Ü.A. □

**Definition 3.6 (Picard-Lindelöf Iteration)**

Definiere Operator  $T : C^0(I, \mathbb{R}^n) \rightarrow C^0(I, \mathbb{R}^n)$  durch

$$(Ty)(x) := y_0 + \int_a^x f(s, y(s))ds.$$

Dann ist 3.2 b) äquivalent zu  $Ty = y$ .

Fixpunktiteration:  $y^{(0)} \in C^0(I, \mathbb{R}^n)$  gegeben,  $y^{(n+1)} = Ty^{(n)}$ .

**Frage:** Wann konvergiert diese Iteration?

**Satz 3.7 (Picard-Lindelöf, lokale Version)**

Es gelten die Voraussetzungen (V). Erfüllt  $f$  auf  $S$  die Lipschitzbedingung

$$(L) \quad \|f(x, y) - f(x, z)\|_{\infty} \leq L \|y - z\|_{\infty} \quad \forall (x, y), (x, z) \in S,$$

so hat das AWP lokal eine eindeutige Lösung  $\tilde{y}$ , d.h.  $\exists \varepsilon > 0$ ,  $\exists \tilde{y} \in C^1(I_{\varepsilon}, \mathbb{R}^n)$  mit  $\tilde{y}$  löst AWP auf  $I_{\varepsilon} := [a, a + \varepsilon]$ .

*Beweis:* Es ist

$$\begin{aligned} \|(Ty)(x) - (Tz)(x)\|_{\infty} &\stackrel{(L)}{\leq} L \int_a^x \|y(s) - z(s)\|_{\infty} ds \\ &\leq L \|y - z\|_{\infty} (x - a) \\ &\leq L \varepsilon \|y - z\|_{\infty}, \text{ für } x \in I_{\varepsilon}. \end{aligned}$$

Wähle  $\varepsilon > 0$ , so dass  $L\varepsilon < 1$ . Dann folgt, dass  $T$  Kontraktion ist und die Aussage folgt mit dem Banachschen Fixpunktsatz. □

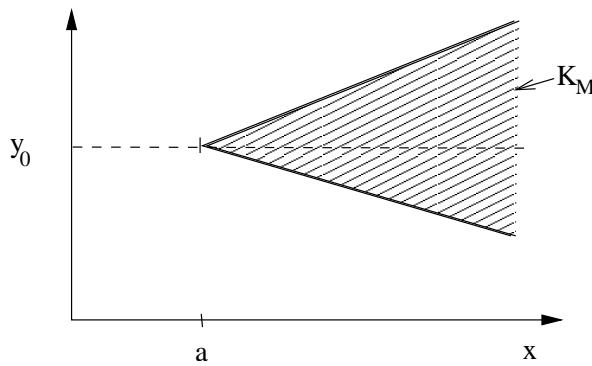
**Satz 3.8 (Picard-Lindelöf, globale Version)**

Gelte (V) und (L). Erfüllt  $f$  auf  $S$  die Bedingung

$$(M) \quad \|f(x, y)\|_{\infty} \leq M \quad \forall (x, y) \in S$$

und  $G$  erfülle zusätzlich  $G \supseteq \overline{B_{\sigma}(y_0)} := \{x \in \mathbb{R}^n \mid \|x - y_0\|_{\infty} \leq \sigma\}$ , wobei  $\sigma \geq (b - a)M$  sei. Dann gilt:

- a) Das AWP hat auf  $I$  genau eine Lösung  $\tilde{y}$ .
- b)  $\forall x \in I$  gilt  $(x, \tilde{y}(x)) \in K_M = K_M(a, y_0) := \{(x, y) \in \mathbb{R} \times \mathbb{R}^n \mid \|y - y_0\|_{\infty} \leq M|x - a|\} \cap S$  (siehe Abb. 3.1)).

Abbildung 3.1: Picard-Lindelöf: Grafische Darstellung von  $K_M$ .

- c) Die Fixpunktiteration von Picard-Lindelöf konvergiert gleichmäßig auf  $I$  gegen  $\tilde{y}$ . Für den Fehler gilt:

$$\|\tilde{y}(x) - y^{(k)}(x)\|_{\infty} \leq \frac{L^k(x-a)^k}{k!} e^{L(x-a)} \quad \forall x \in I.$$

*Beweis:* siehe Ü.A. □

**Satz 3.9 (Satz von Peano)**

Sei  $S$  ein Rechteckgebiet, das  $K_M(a, y_0)$  enthält und es gelten (V) und (M). Dann ex. eine Lösung  $\tilde{y}$  des AWP auf  $I$ .

*Beweis:* (siehe z.B. Walter [9])

**Lemma 3.10 (Lemma von Gronwall)** □

Sei  $p, q \in C^0([a, b])$  mit  $p, q \geq 0$ . Erfüllt die Funktion  $e : [a, b] \rightarrow \mathbb{R}$  die Integralbedingung

$$0 \leq e(x) \leq p(x) + \int_a^x q(s)e(s)ds \quad \forall x \in [a, b],$$

so gilt:

$$0 \leq e(x) \leq p(x) + \int_a^x q(s)p(s) \exp\left(\int_s^x q(t)dt\right) ds.$$

*Beweis:* siehe Ü.A. □

**Satz 3.11 (Stetigkeitssatz für AWP)**

Es gelten die Vor. (V) und (L). Sei  $\tilde{y}$  Lösung des AWP und  $\tilde{z}$  sei Lösung des gestörten AWP:

$$z'(x) = f(x, z(x)) + \varepsilon(x), \quad z(a) = z_0 \in G.$$

Gelte  $z_0 - y_0 \leq \tilde{\varepsilon}$  und sei  $\varepsilon(x) \in C^0(I, \mathbb{R}^n)$  mit  $\|\varepsilon(x)\|_{\infty} \leq \varepsilon \quad \forall x \in I$ .

Dann gilt:

$$\|\tilde{z}(x) - \tilde{y}(x)\|_{\infty} \leq (\tilde{\varepsilon} + \varepsilon(x-a))e^{L(x-a)}.$$

*Beweis:* Folgt direkt aus 3.7 mit  $e(x) := \|\tilde{z}(x) - \tilde{y}(x)\|_\infty$ .

$$\begin{aligned}
 \implies e(x) &= \left\| z_0 + \int_a^x f(\tau, \tilde{z}(\tau)) - \varepsilon(\tau) d\tau - y_0 - \int_a^x f(\tau, \tilde{y}(\tau)) d\tau \right\| \\
 &\leq \|z_0 - y_0\| + \varepsilon(x-a) + \int_a^x L e(\tau) d\tau \\
 &= p(t) + \int_a^t q(\tau) e(\tau) d\tau \text{ mit} \\
 &\quad p(\tau) = \tilde{\varepsilon} + \varepsilon(x-a), \quad q(\tau) = L
 \end{aligned}$$

Aus dem Lemma von Gronwall folgt:

$$e(x) \leq \tilde{\varepsilon} + \varepsilon(x-a) + L \int_a^x (\tilde{\varepsilon} + \varepsilon(\tau-a)) e^{L(\tau-a)} d\tau.$$

Durch Berechnung des Integrals folgt die Behauptung.  $\square$

### Satz 3.12 Methode der Trennung der Variablen

Läßt sich die Differentialgleichung  $y' = f(x, y)$  als  $y' = \frac{p(x)}{q(y)}$  schreiben und ist  $\frac{dq}{dx} = \frac{dp}{dy}$  erfüllt, so gilt:  $y(x)$  ist gegeben durch

$$F(x, y(x)) = \text{konst}$$

mit

$$F(x, y) = \int_a^x p(t) dt + \int_{y_0}^y q(s) ds.$$

*Beweis:* Nachrechnen.  $\square$

### Definition 3.13 (Lineare AWP)

Sei  $I = [a, b]$ . Gesucht  $y \in C^1(I, \mathbb{R})$ :

$$(L\text{-AWP}) \quad \begin{cases} y'(x) = \alpha y(x) + \beta, & \alpha, \beta \in \mathbb{R} \\ y(a) = y_0 \end{cases}$$

Die Lösung des homogenen AWPs  $z' = \alpha z$ ,  $z(a) = z_0$  ist dann gegeben durch  $z(x) = z_0 e^{\alpha(x-a)}$ .

Durch "Variation der Konstanten" folgt:

$$\text{Ansatz: } y(x) = z(x)v(x) \implies y(x) = \left(\frac{\beta}{\alpha} + y_0\right) e^{\alpha(x-a)} - \frac{\beta}{\alpha}.$$

### Anwendung: Bakterienwachstum

$y_0 \hat{=} \#$  Bakterien am Anfang,  $-\beta > 0$  Sterberate,  $\alpha > 0$  Wachstumsfaktor. Das qualitative Verhalten der Lösung ist in Abb. 3.2 dargestellt.

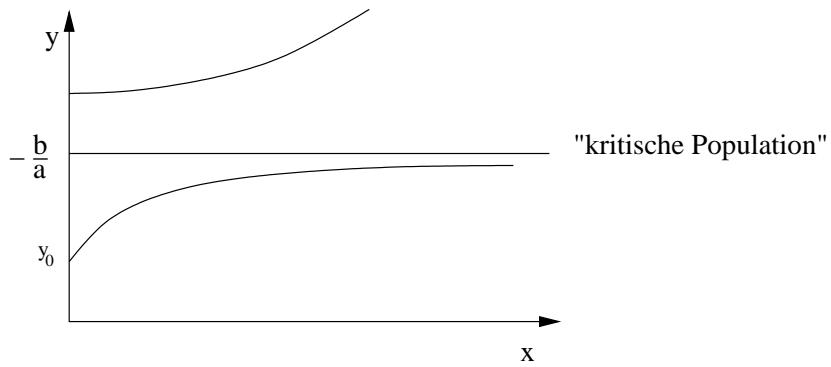


Abbildung 3.2: Lineare (AWP):Anwendung, Bakterienwachstum.

**Definition 3.14 (Systeme linearer AWP)**

Sei  $I = [a, b]$  und  $A \in \mathbb{R}^{n \times n}$  diagonalisierbar,  $y_0, B \in \mathbb{R}^n$ . Gesucht  $y \in C^1(I, \mathbb{R}^n)$ :

$$(SL\text{-}AWP) \quad \begin{cases} y'(x) = Ay(x) + B \\ y(a) = y_0 \end{cases}$$

Wir definieren die "Matrixexponentielle"  $\exp(A)$  durch

$$\exp(A) := \sum_{k=0}^{\infty} \frac{A^k}{k!}.$$

Dann löst auch hier  $z(x) = z_0 \exp(A(x - a))$  das homogene System  $z' = Az$ ,  $z(a) = z_0$ . Eine Lösung von SL-AWP erhält man durch Variation der Konstanten mit dem Ansatz:

$$y(x) = \exp(A(x - a))v(x).$$

**Definition 3.15 (Differentialgleichungen höherer Ordnung)**

Geg:  $I = [a, b]$ ;  $G \subset \mathbb{R}^{m-1}$  Gebiet;  $S = I \times G$ ,  $f : S \rightarrow \mathbb{R}$ .

Ges:  $y \in C^m(I, \mathbb{R}^n)$ ;  $y^{(k)}(I) \subseteq P_k(G)$ ;  $P_k$  Projektion

$$\begin{aligned} y^{(m)}(x) &= f(x, y'(x), \dots, y^{(m-1)}(x)) \quad \forall x \in I, \\ y^{(k)}(a) &= y_0^{(k)} \subset P_k(G), k = 0, \dots, m-1. \end{aligned}$$

**Reduktion auf System 1. Ordnung:**

Setze  $y_k := y^{(k)}$ ;  $k = 0, \dots, m-1$

und  $F(x, y_0, \dots, y_{m-1}) = (y_0, \dots, y_{m-1}, f(x, y_0, \dots, y_{m-1}))^T$ .

Dann folgt mit  $y = (y_0, \dots, y_{m-1})^T$ :

$$\begin{aligned} y' &= F(x, y), \\ y(a) &= (y_0^{(0)}, \dots, y_0^{(m-1)})^T. \end{aligned}$$

**Generalvereinbarung:**

- 1) Alle Sätze werden im Folgenden für skalare AWP 1. Ordnung formuliert.
- 2) Sollte ein Satz für Systeme nicht gelten, so wird dies explizit angegeben.

### 3.3 Einschrittverfahren

Wir betrachten das skalare AWP:

$$(AWP) \quad \begin{cases} y'(x) = f(x, y), \\ y(a) = y_0. \end{cases}$$

Es seien stets die Bedingungen (V), (M), (L) erfüllt und es sei stets  $S \subseteq K_M(a, y_0)$  ein Rechteckgebiet, wobei

$$K_M = K_M(a, y_0) := \{(x, y) \in I \times \mathbb{R} \mid |y - y_0| \leq M(x - a) + \varepsilon_0\}, \quad \varepsilon_0 > 0.$$

Wir bezeichnen mit  $\tilde{y}$  die eindeutig bestimmte Lösung von (AWP).

**Definition 3.16 (Diskretes Verfahren zur Lösung von (AWP))**

Definiere Gitter  $I_h = \{x_0, \dots, x_n\} \subseteq I$ ,  $x_{j+1} = x_j + h_j$ ,  $h_j > 0$ ,  $j = 0, \dots, n-1$ . Setze  $x_0 = a$ ,  $x_n = b$ .

Schrittweitenvektor:  $\bar{h} = (h_0, \dots, h_{n-1})^T$ .

$I_h$  heisst zulässiges Gitter auf  $I$ . Definiere  $h := \max_{j=0, \dots, n-1} h_j$  als Feinheit von  $I_h$ .

Ein numerisches Verfahren  $\Phi$

- findet ein Gitter  $I_h$
- ordnet  $I_h$  eine Gitterfunktion  $u_h : I_h \rightarrow \mathbb{R}$  zu.

$u_h$  ist auf  $I_h$  diskrete Näherungslösung von  $\tilde{y}$ .

**Definition 3.17 (Globaler Fehler von Verfahren  $\Phi$ )**

Für  $x \in I_h$  setze  $e_h(x) := \tilde{y}(x) - u_h(x)$  ("Fehlerfunktion"). Definiere

- 1)  $e_i := e_h(x_i)$ ,  $x_i \in I_h$ ,
- 2)  $\|e_h\|_h := \max_{x \in I_h} |e_h(x)|$ .

$\|e_h\|_h$  heist Diskretisierungsfehler von  $\Phi$  auf  $I_h$ .

**Definition 3.18 (Konvergenz/Konvergenzordnung)**

- 1)  $\Phi$  heisst konvergent auf  $I$ , falls  $\|e_h\|_h \rightarrow 0$  für  $h \rightarrow 0$ .

- 2)  $\Phi$  hat auf  $I$  die Konvergenzordnung  $p > 0$ , falls für genügend glattes  $f$  gilt:

$$\|e_h\|_h = O(h^p) \quad \text{für } h \rightarrow 0.$$

**Definition 3.19 (Explizite Einschrittverfahren (ESV))**

Ein Verfahren  $\Phi$  heisst explizites Einschrittverfahren, falls es eine Verfahrensfunktion  $\varphi = \varphi(x, u, h)$ ,  $(x, u) \in K_M(a, y_0)$ ,  $h \in (0, b - a]$ ,  $\varphi(x, u, h) \in [-M, M]$  gibt, so dass  $u_h$  auf zulässigem Gitter  $I_h$  definiert ist durch:

$$\begin{cases} u_0 &:= y_0 + \varepsilon_0, \\ u_{j+1} &:= u_j + h_j \varphi(x_j, u_j, h_j), \quad j = 0, \dots, n-1, \\ u_h(x_j) &:= u_j, \quad \forall x_j \in I_h. \end{cases}$$

**Beispiel 3.20**

- 1) Eulerverfahren (explizit):  $\varphi(x, u, h) = f(x, u)$ .
- 2) Verbessertes Eulerverfahren:  $\varphi(x, u, h) = f(x + \frac{h}{2}, u + \frac{h}{2}f(x, u))$ .

**Definition 3.21 (Abschneidefehler/Konsistenz)**

- 1) Für  $h \in (0, b - a]$ ,  $x \in [a, b - h]$ ,  $y : [x, x + h] \rightarrow \mathbb{R}$  mit  $y'(\xi) = f(\xi, y(\xi))$  für  $\xi \in [x, x + h]$  sowie  $(x, y(x)) \in K_M$ , heißt

$$\tau_h(x, y) := \frac{y(x + h) - y(x)}{h} - \varphi(x, y(x), h)$$

lokaler Abschneidefehler oder Diskretisierungsfehler von  $\varphi$ .

- 2)  $\varphi$  heißt konsistent mit (AWP), falls gilt

$$|\tau_h(x, \tilde{y})| \xrightarrow{h \rightarrow 0} 0 \quad \forall x \in I \setminus \{b\}.$$

$\varphi$  hat Konsistenzordnung  $p \in \mathbb{N}$ , falls für genügend glattes  $f$  gilt:  $|\tau_h(x, \tilde{y})| = O(h^p)$ ,  $h \rightarrow 0 \quad \forall x \in I \setminus \{0\}$

- 3) Das ESV  $\Phi$  heißt konsistent mit (AWP), falls  $e_0 \xrightarrow{h \rightarrow 0} 0$  und  $\varphi$  konsistent mit (AWP) ist.

$\Phi$  hat Konsistenzordnung  $p \in \mathbb{N}$ , falls

$$|e_0| = O(h^p), \quad h \rightarrow 0$$

und  $\varphi$  die Konsistenzordnung  $p$  hat.

**Lemma 3.22 (Diskretes Lemma von Gronwall)**

Seien  $(p_n)_{n \in \mathbb{N}}, (q_n)_{n \in \mathbb{N}}, (e_n)_{n \in \mathbb{N}}$  positive Folgen mit  $e_{n+1} \leq (1 + q_n)e_n + p_n$  für  $n < N$ . Dann gilt:

$$e_n \leq \left( e_0 + \sum_{j=1}^{n-1} p_j \right) \exp \left( \sum_{j=0}^{n-1} q_j \right) \quad \text{für } n < N.$$

*Beweis:* Durch vollständige Induktion. □

**Satz 3.23 (Konvergenzsatz für ESV)**

$\Phi$  sei ESV mit Verfahrensfunktion  $\varphi = \varphi(x, u, h)$ .  $\varphi$  sei bzgl.  $u$  auf  $K_M$  global Lipschitz stetig. Dann gilt:

Ist  $\Phi$  mit (AWP) konsistent (mit Ordnung  $p$ ), so ist  $\Phi$  auf  $I$  konvergent (mit Ordnung  $p$ ).

*Beweis:* Sei  $a \leq x < x + h \leq b$ . Es ist

$$\frac{\tilde{y}(x+h) - \tilde{y}(x)}{h} = \varphi(x, \tilde{y}(x), h) + \tau_h(x, \tilde{y}).$$

Für  $\tilde{y}_j = \tilde{y}(x_j)$ ;  $x_j \in I_h$ ;  $\tau_j := \tau_h(x_j, \tilde{y}_j)$  gilt also

$$\tilde{y}_{j+1} - \tilde{y}_j = h_j \varphi(x_j, \tilde{y}_j, h_j) + h_j \tau_j \quad ; \quad j = 0, \dots, n-1$$

Ist  $\tilde{L}$  die Lipschitzkonstante von  $\varphi$  bzgl.  $u$ , so gilt:

$$\begin{aligned} |e_{j+1}| &\leq |e_j|(1 + h_j \tilde{L}) + |\tau_j| h_j \\ \xrightarrow{3.22} \quad \|e_h\|_h &\leq (|e_0| + (b-a) \max_{j=0, \dots, n-1} |\tau_j|) e^{(b-a)\tilde{L}} \end{aligned}$$

Nach Voraussetzung ist  $\Phi$  konsistent (Ordnung  $p$ ), also folgt

$$1) \max_{j=0, \dots, n-1} |\tau_j| \longrightarrow 0 \quad (= O(h^p))$$

$$2) |e_0| \longrightarrow 0 \quad (= O(h^p))$$

$\implies$  Behauptung. □

**Beispiel 3.24**

1) Das Eulerverfahren ist konvergent mit der Ordnung 1. ( $\varphi(x, u, h) = f(x, u)$ )

2) Das verbesserte Eulerverfahren ist konvergent mit Ordnung 2.

**Definition 3.25 (Implizites ESV)**

Ein Verfahren  $\Phi$  zur Lösung von (AWP) heißt implizites ESV, falls es eine Verfahrensfunktion  $\tilde{\varphi} = \tilde{\varphi}(x, u, v, h)$ ,  $(x, u), (x+h, v) \in K_M$ ,  $h \in (0, b-a]$ ,  $\tilde{\varphi}(x, u, v, h) \in [-M, M]$  gibt, so dass für zulässige Gitter  $I_h$  mit genügend kleiner Feinheit  $h$   $u_h$  definiert ist durch:

$$\begin{cases} u_0 &= y_0 + \varepsilon_0, \\ u_{j+1} &= u_j + h_j \tilde{\varphi}(x_j, u_j, u_{j+1}, h_j), \quad j = 0, \dots, n-1, \\ u_h(x_j) &:= u_j, \quad \forall x_j \in I_h. \end{cases}$$

**Beispiel 3.26**

1) Implizites Eulerverfahren:

$$\tilde{\varphi}(x, u, v, h) = f(x+h, v) \implies u_{j+1} = u_j + h_j f(x_{j+1}, u_{j+1}).$$

Dies entspricht der Rechteckregel:

$$\frac{1}{h} \int_x^{x+h} f(t, y(t)) dt \approx f(x+h, y(x+h)).$$

2) Crank-Nicholson-Verfahren oder Trapezverfahren:

$$\tilde{\varphi}(x, u, v, h) = \frac{1}{2}[f(x, u) + f(x + h, v)].$$

Dies entspricht einer Integration mit der Trapezregel.

**Satz 3.27**

Sei  $\Phi$  ein implizites ESV mit  $\tilde{\varphi} = \tilde{\varphi}(x, u, v, h)$  Lipschitz-stetig bzgl.  $u$  und  $v$  auf dem Definitionsbereich von  $\tilde{\varphi}$ . Dann existiert für genügend kleines  $h$  eine bzgl.  $u$  global Lipschitz-stetige Funktion  $v(x, u, h)$ , so das gilt:

$$u_{j+1} = u_j + h_j \tilde{\varphi}(x_j, u_j, v(x_j, u_j, h_j), h_j) \quad j = 0, \dots, n-1.$$

D.h.  $\Phi$  ist mit  $\varphi(x, u, h) := \tilde{\varphi}(x, u, v(x, u, h), h)$  lokal ein explizites ESV im Sinne von 3.16.

*Beweis:*

1) Für feste  $x, u, h$  sei  $T_u$  definiert als

$$T_u : \mathbb{R} \longrightarrow \mathbb{R}, \quad v \longmapsto u + h \tilde{\varphi}(x, u, v, h)$$

Sei  $L_1$  die Lipschitzkonstante von  $\tilde{\varphi}$  bzgl.  $v$ .

$$|T_u v_1 - T_u v_2| \leq \underbrace{h \cdot L_1}_{< 1, \text{ falls } h \text{ klein genug}} |v_1 - v_2|$$

$\implies T_u$  ist kontrahierende Selbstabb. auf  $\mathbb{R}$ .

Nach Banachschen Fixpunktsatz existiert genau ein  $\tilde{v}$ , so dass  $T_u \tilde{v} = \tilde{v}$

$\implies \tilde{v} = \tilde{v}(x, u, h)$  ist wohldefiniert und  $(x + h, \tilde{v}) \in K_M$ .

2) Seien  $v_1, v_2$  die eindeutigen Fixpunkte von  $T_{u_1}, T_{u_2}$ .  $L_2$  sei die Lipschitzkonstante von  $\tilde{\varphi}$  bzgl.

$u$ . Dann gilt:

$$\begin{aligned} |v_1 - v_2| &= |T_{u_1} v_1 - T_{u_2} v_2| \leq |T_{u_1} v_1 - T_{u_1} v_2| + |T_{u_1} v_2 - T_{u_2} v_2| \\ &\leq h L_1 |v_1 - v_2| + |u_1 - u_2| + h \cdot L_2 |u_1 - u_2| \\ \implies |v_1 - v_2| &= \underbrace{\frac{1 + h L_2}{1 - h L_1}}_{:= \tilde{L}_H} |u_1 - u_2|. \end{aligned}$$

Also folgt für  $v_1 = v(x, u_1, h), v_2 = v(x, u_2, h)$ :

$$|v(x, u_1, h) - v(x, u_2, h)| \leq \tilde{L}_H |u_1 - u_2|, \quad h \leq H < \frac{1}{L_1}.$$

□

**Definition 3.28 Taylorverfahren**

Das Taylorverfahren der Ordnung  $p$  ist gegeben durch:

$$\varphi_p(x, u(x), h) := f(x, u(x)) + \frac{h}{2} \frac{d}{dx} f(x, u(x)) + \dots + \frac{h^{p-1}}{p!} \frac{d^{p-1}}{dx^{p-1}} f(x, u(x)).$$

**Satz 3.29**

Sei  $f \in C^p(S)$  mit  $p \in \mathbb{N}$ . Dann ist das Taylorverfahren  $\Phi_p$  mit Verfahrensfunktion  $\varphi_p$  konvergent mit Ordnung  $p$ , falls  $|e_0| = O(h^p)$ ,  $h \rightarrow 0$ .

*Beweis:*

1) Für  $x, y, h$  folgt mit der Taylorentwicklung mit Integralrestglied:

$$\begin{aligned}\tau_h(x, y) &= \frac{y(x+h)-y(x)}{h} - \varphi_p(x, y(x), h) = \frac{1}{h} \frac{1}{p!} \int_x^{x+h} (x-\xi)^p y^{(p+1)}(\xi) d\xi \\ &= \frac{h^p}{p!} \int_0^1 (1-t)^p y^{(p+1)}(x+th) dt \\ &= O(h^p)\end{aligned}$$

2)  $\frac{d^k}{dx^k} f(x, u, h)$  habe Lipschitz-Konstante  $L_k$ ,  $k = 0, \dots, p-1$ .  
Dann gilt:

$$|\varphi_p(x, u_1(x), h) - \varphi_p(x, u_2(x), h)| \leq \underbrace{\sum_{j=0}^{p-1} \frac{(b-a)^j}{j!} L_j}_{=:L} |u_1(x) - u_2(x)|.$$

Aus 1) und 2) folgt die Behauptung mit Satz 3.23. □

**Bemerkung:**

1) Satz 3.26 zeigt, dass es ESV mit beliebig hoher Konvergenzordnung gibt.

2) Taylorverfahren sind in der Praxis unbedeutend, da

-  $\varphi_p$  nicht unabhängig vom Richtungsfeld  $f$  ist,

- höhere Ableitungen von  $f$  "teuer" auszurechnen sind.

**Definition 3.30 (Explizite Runge-Kutta Verfahren)**

Das ESV  $\Phi$  mit Verfahrensfunktion  $\varphi$  heißt explizites Runge-Kutta Verfahren, falls gilt:

$$\begin{aligned}
 u_0 &:= y_0 + \varepsilon_0, \\
 u_{j+1} &:= u_j + h_j \varphi(x_j, u_j, h_j), \quad j = 0, \dots, n-1, \\
 \varphi(x, u, h) &:= \sum_{i=1}^m \gamma_i k_i(x, u, h) \text{ mit } \gamma_i \in \mathbb{R}, \quad \sum_{i=1}^m \gamma_i = 1, \\
 k_1(x, u, h) &:= f(x, u), \\
 k_2(x, u, h) &:= f(x + \alpha_2 h, u + \beta_{2,1} k_1(x, u, h)), \\
 &\vdots \\
 k_m(x, u, h) &:= f\left(x + \alpha_m h, u + h \sum_{l=1}^{m-1} \beta_{m,l} k_l(x, u, h)\right), \\
 \text{mit } \alpha_i &\in [0, 1].
 \end{aligned}$$

Die Koeffizienten  $\alpha_i, \gamma_i, \beta_{m,l}$  sind von  $x, u, h$  unabhängig und so gewählt, dass die Konsistenzordnung von  $\varphi$  maximal wird.  $m$  heißt Stufenzahl des Runge-Kutta-Verfahrens und  $k_i$  heißt  $i$ -te Stufenfunktion des Verfahrens  $\Phi$ .

**Notation:** (Butcher-Tableau)

$$\begin{array}{c|ccc}
 \alpha_1 & 0 & & 0 \\
 \alpha_2 & \beta_{2,1} & \ddots & \\
 \vdots & \vdots & \ddots & \ddots \\
 \alpha_m & \beta_{m,1} & \dots & \beta_{m,m-1} & 0 \\
 \hline
 & \gamma_1 & & \gamma_{m-1} & \gamma_m
 \end{array}
 \quad \text{bzw.} \quad \begin{array}{c|c}
 \alpha & \beta \\
 \hline
 & \gamma^t
 \end{array}$$

**Bemerkung 3.31**

- 1)  $\sum_{i=1}^m \gamma_i = 1 \iff$  Konsistenz des entsprechenden R.-K. Verfahrens.
- 2) Oft wird zusätzlich gefordert, dass  $\sum_{i=0}^{l-1} \beta_{l,i} = \alpha_l \quad \forall l = 2, \dots, m$  gilt, damit  $k_l(x_j, u_j, h_j)$  bei genügend glattem  $f$  die Ableitung  $\tilde{y}'(x_j + \alpha_l h)$  bis auf Größen der Ordnung  $O(h^2)$  annähert.

**Beispiel 3.32**

$$\begin{aligned}
 1) \text{ Eulerverfahren: } m = p = 1 & \quad \begin{array}{c|c}
 0 & 0 \\
 \hline
 1
 \end{array} \\
 \implies k_1(x, u, h) &= f(x, u); \quad \varphi(x, u, h) = k_1(x, u, h) = f(x, u)
 \end{aligned}$$

$$2) \text{ Verbessertes Eulerverfahren: } m = p = 2 \quad \begin{array}{c|c}
 0 & \\
 \hline
 \frac{1}{2} & \frac{1}{2} \\
 \hline
 0 & 1
 \end{array}$$

$$\begin{aligned}
 k_1(x, u, h) &= f(x, u) \\
 k_2(x, u, h) &= f\left(x + \frac{1}{2}h, u + \frac{1}{2}h k_1(x, u, h)\right) \\
 \varphi(x, u, h) &= 1 \cdot k_2(x, u, h) = f\left(x + \frac{h}{2}, u + \frac{h}{2} f(x, u)\right)
 \end{aligned}$$

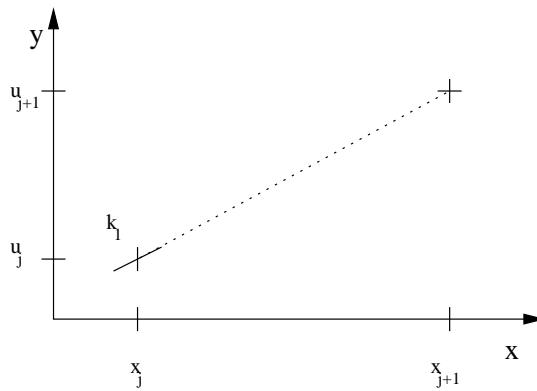


Abbildung 3.3: Runge-Kutta: Eulerverfahren

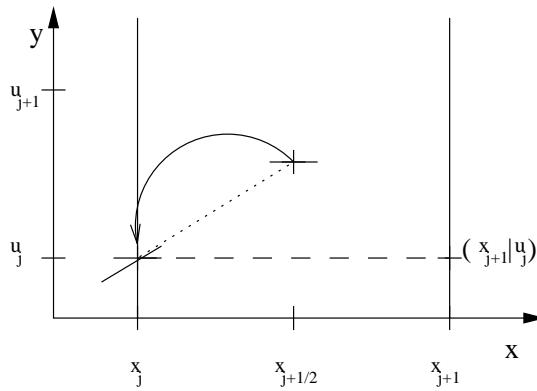


Abbildung 3.4: Runge-Kutta: verbessertes Eulerverfahren

3) Verfahren von Heun:  $m = p = 3$ 

0	$\frac{1}{3}$	$\frac{1}{3}$
$\frac{1}{3}$	0	$\frac{2}{3}$
$-\frac{2}{3}$	$\frac{1}{4}$	$0$

$$\begin{aligned}
 k_1(x, u, h) &= f(x, u) \\
 k_2(x, u, h) &= f(x + \frac{1}{3}h, u + \frac{1}{3}hk_1) \\
 k_3(x, u, h) &= f(x + \frac{2}{3}h, u + \frac{2}{3}hk_2) \\
 \varphi(x, u, h) &= \frac{1}{4}k_1 + \frac{3}{4}k_3
 \end{aligned}$$

4) Klassisches R.-K. Verfahren:  $m = p = 4$ 

0	$\frac{1}{2}$	$\frac{1}{2}$	
$\frac{1}{2}$	0	$\frac{1}{2}$	
1	0	0	1

**Bemerkung 3.33**

- 1) Im Spezialfall  $f(x, y) = f(x)$  werden expl. R.-K. Verfahren zu zusammengesetzten Quadraturen auf  $I$ : z.B.

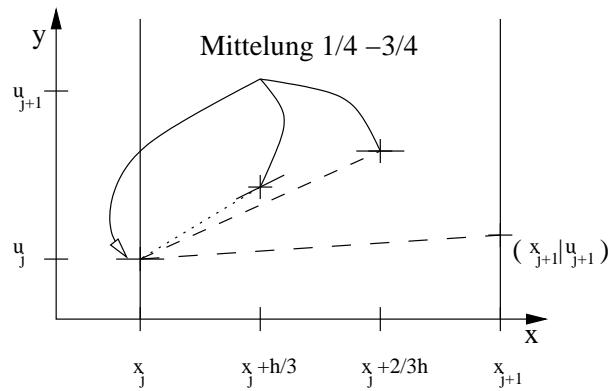


Abbildung 3.5: Runge-Kutta: Verfahren von Heun

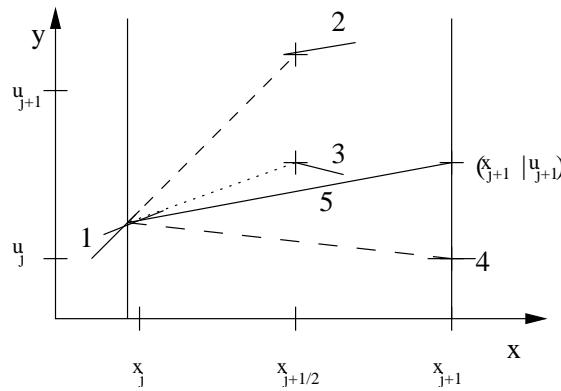


Abbildung 3.6: Runge-Kutta: klassisch

Eulerverfahren  $\longleftrightarrow$  Rechteckregel

verb. Eulerverfahren  $\longleftrightarrow$  Tangententrapezregel

klass. R.-K. Verfahren  $\longleftrightarrow$  Simpsonregel

Idee:  $\frac{1}{h_j} \int_{x_j}^{x_{j+1}} f(t) dt$  wird ersetzt durch  $\frac{1}{6}f(x_j) + \frac{2}{3}f(x_j + \frac{h_j}{2}) + \frac{1}{6}f(x_{j+1})$ .

- 2) Zur Konstruktion von R.-K. Verfahren genügt es Spezialfälle  $f(x, y) = f(y)$  zu betrachten (autonome Differentialgleichungen). Denn
- Koeff. von R.-K. Verfahren bleiben für Systeme von Differentialgleichungen 1. Ordnung unverändert.
  - Jede skalare Differentialgleichung 1. Ordnung lässt sich als autonomes System schreiben:

$$y'(x) = f(x, y(x)), \quad y(a) = y_0$$

$$\iff \begin{cases} y'_1(x) = f(y_2, y_1) & , y_1(a) = y_0 \\ y'_2(x) = 1 & , y_2(a) = a \end{cases}$$

Hinweis: i) gilt nur wenn  $\sum_{i=0}^{l-1} \beta_{e,i} = \alpha_l$ .

- 3) Stufenzahl  $m$  und Konsistenzordnung  $p = p(m)$  sind im Allgemeinen nicht korreliert:

$m$	1	2	3	4	5	6	7	8	9	10	11
$p(m)$	1	2	3	4	4	5	6	6	7	7	8

Für  $m \geq 10$  gilt immer  $p(m) \leq m - 3$ . z.B.  $m = 17, p = 10$ .

### 3.34 Konstruktion von R.-K. Verfahren mit zwei Stufen

Es gilt für ESV:  $\tau_h(x, y) := \frac{y(x+h) - y(x)}{h} - \varphi(x, y(x), h)$ .

Ansatz für  $m = 2$  und  $f(x, y) = f(y)$  :

$$\begin{aligned}\varphi(x, y(x), h) &= \gamma_1 k_1(x, y(x), h) + \gamma_2 k_2(x, y(x), h) \\ &= \gamma_1 f(y(x)) + \gamma_2 f(y(x) + h\beta_{2,1}f(y(x)))\end{aligned}$$

$$\xrightarrow{\text{Taylor}} \varphi(x, y, h) = (\gamma_1 + \gamma_2)f(y) + h\beta_{2,1}\gamma_2(f'f')(y) + \frac{h^2}{2}\gamma_2\beta_{2,1}^2(f^2f'')(y) + O(h^3)$$

wobei  $y = y(x)$ ,  $(f \cdot g)(y) = f(y)g(y)$ ;  $f^{(k)} = \frac{d^k}{dy^k}f(y)$ .

Andererseits folgt auch mit Taylorentwicklung

$$\frac{y(x+h) - y(x)}{h} = f(y) + \frac{h}{2}(ff')(y) + \frac{h^2}{6}(f''f^2 + f'^2f)(y) + O(h^3)$$

Also folgt:

$$\begin{aligned}\tau_h(x, y) &= \left(1 - (\gamma_1 + \gamma_2)\right)f(y) + h\left(\frac{1}{2} - \beta_{2,1}\gamma_2\right)(f'f)(y) \\ &\quad + \frac{h^2}{2}\left(\frac{1}{3}(f''f^2 + f'^2f) - \gamma_2\beta_{2,1}(f^2f'')\right)(y) + O(h^3)\end{aligned}$$

Bedingungen:

$$\text{Für } p = 1: \gamma_1 + \gamma_2 = 1$$

$$\text{Für } p = 2: \frac{1}{2} - \beta_{2,1}\gamma_2 = 0$$

Für  $p = 3$ : nicht möglich.

Wähle  $\alpha_2 = \beta_{2,1} \in [0, 1]$  frei!

Spezialfälle:

$$1) \gamma_1 = 0, \gamma_2 = 1 \implies \beta_{2,1} = \frac{1}{2},$$

$$2) \gamma_1 = \gamma_2 = \frac{1}{2} \implies \beta_{2,1} = 1.$$

### Bemerkung 3.35

Die Vorgehensweise für  $m > 2$  ist analog, wobei für den Aufwand gilt:

Ordnung $p$	1	2	3	4	5	6	7	8	9	10
# Bedingungen	1	2	4	8	16	37	85	200	486	1205

Diese Bedingungen sind nichtlineare Gleichungen!

↔ Systematisch Behandlung von Butcher 1964: "grafische Methode".

### Satz 3.36

1) Hat ein Runge-Kutta Verfahren die Konsistenzordnung  $p$ , so gilt für hinreichend glattes  $f$ :

$$\tau_h(x, y) = h^p \bar{\tau}(x, y) + O(h^{p+1}), \quad h \longrightarrow 0$$

wobei  $\bar{\tau}(x, y) = \sum_k \varepsilon_k D_k f(x, y)$  mit  $D_k f \doteq$  Produkt partieller Ableitungen,  $\varepsilon_k \doteq$  Fehlerkoeffizient.

- 2) Explizite R.-K. Verfahren mit Konistenzordnung  $p$  sind konvergent mit Ordnung  $p$ .

*Beweis:*

- 1) Klar nach Konstruktion in 3.31.
- 2) Es genügt zu zeigen, dass die  $k_l$ ,  $l = 1, \dots, n$  Lipschitz-stetig sind (dann folgt die Beh. mit Satz 3.23).

Beweis durch Induktion über  $l$ :

I.A.  $l = 1$ :  $k_1(x, u, h) = f(x, y) \implies L_1 = L$

I.S.  $l \rightarrow l + 1$ : Seien  $k_1, \dots, k_l$  Lipschitz-stetig mit Konstanten  $L_1, \dots, L_l$ . Dann folgt:

$$\begin{aligned}
 & |k_{l+1}(x, u_1, h) - k_{l+1}(x, u_2, h)| \\
 &= |f(x + \alpha_{l+1}h, u_1 + h \sum_{j=1}^l k_j(x, u_1, h) \beta_{l+1,j}) - \\
 &\quad f(x + \alpha_{l+1}h, u_2 + h \sum_{j=1}^l k_j(x, u_2, h) \beta_{l+1,j})| \\
 &\stackrel{\text{I.V.}}{\leq} L|u_1 - u_2| + Lh \sum_{j=1}^l |\beta_{l+1,j}| L_j |u_1 - u_2| \\
 &\leq L(1 + (b-a) \underbrace{\sum_{j=1}^l |\beta_{l+1,j}| L_j}_{=: L_{l+1}}) |u_1 - u_2|.
 \end{aligned}$$

Damit folgt die Behauptung. □

### Definition 3.37 (Implizite Runge-Kutta Verfahren)

$\Phi$  sei ESV mit Verfahrensfunktion  $\varphi$  gegeben durch

$$\varphi(x, u, h) := \sum_{i=1}^m \gamma_i k_i(x, u, h) \text{ mit } \sum_{i=1}^m \gamma_i = 1.$$

$\Phi$  heißt implizites R.-K. Verfahren mit  $m$  Stufen, falls

$$k_j(x, u, h) = f \left( x + \alpha_j h, u + h \sum_{l=1}^m \beta_{j,l} k_l(x, u, h) \right), \quad j = 1, \dots, m$$

wobei  $\gamma_j, \alpha_j, \beta_{j,l}$  für optimale Runge-Kutta Verfahren so gewählt sind, dass  $\varphi$  maximale Konistenzordnung hat.

### Satz 3.38

- a) Das implizite R.-K. Verfahren mit  $m$  Stufen ist wohldefiniert, falls für die Schrittweite  $h$  gilt:

$$hL \max_{k=1, \dots, m} \sum_{j=1}^m |\beta_{k,j}| < 1,$$

wobei  $L$  die Lipschitz Konstante von  $f$  bzgl.  $y$  ist.

- b) Sei  $f(x, y) = f(x)$ . Dann stimmt das optimale implizite R.-K. Verfahren mit  $m$  Stufen überein mit zusammengesetzten Gauß'schen Quadraturformeln auf  $I$  mit jeweils  $m$  Knoten in den Teilintervallen  $[x_j, x_{j+1}], j = 0, \dots, n - 1$ .
- c) Optimale  $m$ -stufige implizite R.-K. Verfahren haben Konsistenz- und Konvergenzordnung  $2m$ ,  $m \geq 1$ .

*Beweis:*

- a) folgt aus der Kontraktionseigenschaft im Banach'schem Fixpunktsatz.  
 b) & c) siehe Deuflhard/Bornemann §6.2 und §6.3.

□

**Bemerkung 3.39 (Vorteil impliziter R.-K. Verfahren)**

Qualitative Eigenschaften der Lösung von (AWP), wie etwa das Monotonieverhalten, werden bei größeren Gittern bereits wiedergegeben und die Konvergenzordnung ist sehr hoch. (Nachteil: Es ist ein System von  $m$  gekoppelten nicht-linearen Gleichungen zu lösen).

Ein Kompromiss zwischen Vor- und Nachteilen sind die sogenannten diagonal impliziten Rung-Kutta Verfahren (DIRK-Verfahren). Sie zeichnen sich dadurch aus, dass gilt  $\beta_{j,l} = 0$  für  $l > j$ , d.h. es müssen nur  $m$  skalare nicht-lineare Gleichungen gelöst werden.

**Beispiel 3.40**

$$1) \ m = 1, \ p = 2: \quad \begin{array}{c|c} \frac{1}{2} & \frac{1}{2} \\ \hline 1 & \end{array}$$

$$2) \ m = 2, \ p = 4: \quad \begin{array}{c|cc} \frac{1}{2} - \frac{1}{\sqrt{12}} & \frac{1}{4} & \frac{1}{4} - \frac{1}{\sqrt{12}} \\ \hline \frac{1}{2} + \frac{1}{\sqrt{12}} & \frac{1}{4} + \frac{1}{\sqrt{12}} & \frac{1}{4} \\ \hline & \frac{1}{2} & \frac{1}{2} \end{array}$$

**Nächstes Ziel:** Schrittweitensteuerung bei ESV.

Dazu ist es notwendig eine genauere Abschätzung des globalen Fehlers zu erhalten, als diejenige, die durch das Lemma von Gronwall entsteht (vgl. Beweis von Satz 3.23).

Wir benötigen eine asymptotische Entwicklung von  $e_h$ , um

- 1.) den tatsächlichen Fehler zu schätzen,
- 2.) Extrapolation anwenden zu können,
- 3.) Schrittweiten steuern zu können.

**Satz 3.41 (Hauptterm der asymptotischen Fehlerentwicklung bei ESV)**

Φ Sei ein ESV auf äquidistantem Gitter  $I_h$ . Φ habe Konsistenzordnung  $p$  mit

$$e_0 = \rho_0 h^p + \mathcal{O}(h^{p+1}) \quad (h \rightarrow 0),$$

$$\tau_h(x, y) = \bar{\tau}(x)h^p + \mathcal{O}(h^{p+1}).$$

$\varphi$  und  $f$  seien auf ihrem Definitionsbereich in  $C^2$ ,  $\bar{y}$  sei die eindeutig bestimmte Lösung der linearen Störgleichung

$$(\text{SG}) \left| \begin{array}{l} \bar{y}'(x) = \rho(x)\bar{y}(x) - \bar{\tau}(x), \\ \bar{y}(a) = \rho_0, \end{array} \right|$$

mit  $\rho(x) := f_y(x, \tilde{y}(x)) \quad \forall x \in I$

Dann gilt für  $x_j \in I_h$ :

$$u_j = \tilde{y}(x_j) + \bar{y}(x_j)h^p + \mathcal{O}(h^{p+1}) \quad (h \rightarrow 0).$$

*Beweis:* Für  $e_j := u_j - \tilde{y}(x_j)$ ,  $\bar{\tau}_j = \bar{\tau}(x_j)$  gilt (vgl 3.23)

$$e_{j+1} = e_j + h(\varphi(x_j, u_j, h) - \varphi(x_j, \tilde{y}_j, h)) - h^{p+1}\bar{\tau}_j + \mathcal{O}(h^{p+2}).$$

Mit Taylorentwicklung folgt:

$$\varphi(x_j, u_j, h) = \varphi(x_j, \tilde{y}_j + e_j, h) = \varphi(x_j, \tilde{y}_j, h) + e_j \varphi_y(x_j, \tilde{y}_j, h) + \frac{1}{2}e_j^2 \varphi_{yy}(x_j, \eta_j, h)$$

für ein  $\eta_j \in I(\tilde{y}_j, \tilde{y}_j + e_j)$ .

Wegen der Konsistenz gilt weiter:  $\lim_{h \rightarrow 0} \varphi(x, y, h) = f(x, y)$

$$\begin{aligned} \varphi_y(x, y, 0) &= f_y(x, y) \\ \varphi_y(x_j, \tilde{y}_j, h) &\stackrel{\text{Taylor}}{=} \varphi_y(x_j, \tilde{y}_j, 0) + O(h) \\ &= f_y(x_j, \tilde{y}_j) + O(h) \\ &\stackrel{\text{Vor.}}{=} \rho(x_j) + O(h). \end{aligned}$$

Einsetzen in die Gleichung für  $e_{j+1}$  ergibt:

$$e_{j+1} = e_j(1 + h\rho(x_j)) - h^{p+1}\bar{\tau}_j + O(h^2e_j) + O(he_j^2) + O(h^{p+2}).$$

Setze  $\bar{e}_j = h^{-p}e_j$ , so folgt

$$\underbrace{\bar{e}_{j+1} = \bar{e}_j(1 + h\rho(x_j)) - h\bar{\tau}_j}_{\triangleq \text{Euler-Verfahren angewendet auf (SG)}} + O(h^2\bar{e}_j) + O(h^{p+1}\bar{e}_j^2) + O(h^2)$$

Konsistenz des Euler-Verfahrens

$$\implies \bar{e}_j = \bar{y}(x_j) + O(h).$$

Also folgt

$$e_j = u_j - \tilde{y}(x_j) = h^p\bar{e}_j = h^p\bar{y}(x_j) + O(h^{p+1}).$$

□

### Beispiel 3.42

Sei  $\Phi$  das Eulerverfahren und  $f(x, y) = \lambda y$ ,  $\lambda \in \mathbb{R}$   $y_0$  gegeben. Sei  $I = [0, b]$ ,  $b > 0$  und  $u_0 = y_0$ .

$$\implies \tilde{y}(x) = y_0 e^{\lambda x}. \quad (*)$$

Für den Abschneidefehler gilt:

$$\begin{aligned}\tau_h(x, \tilde{y}) &= \frac{h}{2} \tilde{y}''(x) + O(h^2) \\ (*) &= h \underbrace{\frac{1}{2} \lambda^2 y_0 e^{\lambda x}}_{=: \bar{\tau}(x)} + O(h^2)\end{aligned}$$

sowie  $\rho(x) = f_y(x, \tilde{y}) = \lambda$  und  $\rho_0 = 0$ .

Also lautet (SG):

$$\begin{cases} \bar{y}'(x) = \lambda \bar{y}(x) - y_0 \frac{\lambda^2}{2} e^{\lambda x} \\ y(0) = 0 \end{cases}$$

Lösung von (SG) ist  $\bar{y}(x) = -y_0 \frac{\lambda^2}{2} x e^{\lambda x}$

Mit Satz 3.41 folgt:

$$\begin{aligned}u_j &= \tilde{y}_j + \bar{y}(x_j)h + O(h^2) \\ &= \tilde{y}_j - y_0 \frac{\lambda^2}{2} x_j e^{\lambda x_j} h + O(h^2)\end{aligned}$$

Direkte Verifikation: Nach dem Euler-Verfahren ist

$$u_{j+1} = (1 + \lambda h)u_j.$$

Induktion  $\implies u_{j+1} = (1 + \lambda h)^j y_0$  für  $j = 1, \dots, n-1$ .

Weiter ist

$$\begin{aligned}(1 + h\lambda) &\stackrel{\text{Taylor für } e^{\lambda h}}{=} e^{\lambda h} - \frac{h^2}{2} \lambda^2 + O(h^3) \\ \implies (1 + h\lambda)^j &\stackrel{\text{Binomi}}{=} e^{\lambda x_j} - x_j \frac{\lambda^2}{2} e^{\lambda x_j} h + O(h^2) \\ \implies \underbrace{(1 + h\lambda)^j y_0}_{=u_j} &= \underbrace{e^{\lambda x_j} y_0}_{=\tilde{y}(x_j)} - \underbrace{y_0 x_j \frac{\lambda^2}{2} e^{\lambda x_j} \cdot h}_{=\bar{y}(x_j)} + O(h^2).\end{aligned}$$

### Folgerung 3.43

Gilt spezieller als in Satz 3.41

$$e_0 = \rho_0 h^p + \rho_1 h^{p+1} + \dots + \rho_k h^{p+k} + O(h^{p+k+1})$$

und

$$\tau_n(x, y) = \bar{\tau}_0(x)h^p + \bar{\tau}_1(x)h^{p+1} + \dots + \bar{\tau}_k h^{p+k} + O(h^{p+k+1}),$$

so gibt es Funktionen  $\bar{y}_0, \dots, \bar{y}_k$ , so dass

$$u_j = \tilde{y}(x_j) + \bar{y}_0(x_j)h^p + \dots + \bar{y}_k(x_j)h^{p+k} + O(h^{p+k+1}) .$$

Die Funktionen  $\bar{y}_0, \dots, \bar{y}_k$  genügen den Störgleichungen

$$(SG_i) \left| \begin{array}{l} \bar{y}_i(x) = \rho(x)\bar{y}_i(x) - \bar{\tau}_i(x), \\ \bar{y}_i(a) = \rho_i, \end{array} \right. \quad \forall i = 0, \dots, k.$$

*Beweis:* Die Behauptung folgt induktiv unter Verwendung von 3.41. □

### 3.44 Extrapolation

Seien  $I_h, I_{h'}$  zwei äquidistante Gitter auf  $I$  mit  $h' = qh$ ,  $0 < q < 1$ . Sei weiter  $x \in I_h \cap I_{h'}$  und es gelten die Voraussetzungen von Satz 3.41.

Seien  $u_h, u_{h'}$  die Nährungslösungen des gleichen Verfahrens  $\Phi$  auf  $I_h$  bzw.  $I_{h'}$ . Dann gelten:

- 1)  $u_h(x) = \tilde{y}(x) + \bar{y}(x)h^p + O(h^{p+1}),$
- 2)  $u_{h'}(x) = \tilde{y}(x) + \bar{y}(x)q^p h^p + O(h^{p+1}).$

Setzt man nun  $u_h^{(1)} := \alpha u_h(x) + \beta u_{h'}(x)$  mit  $\alpha = -\frac{q^p}{1-q^p}$  und  $\beta = 1 - \alpha$ , so folgt

$$u_h^{(1)}(x) = \tilde{y}(x) + O(h^{p+1}).$$

(Dies ist die Idee der Richardson-Extrapolation!)

### 3.45 Schrittweitensteuerung beim ESV

$\Phi$  sei ESV mit Verfahrensfunktion  $\varphi$ ,  $I_h$  Gitter auf  $I$  und  $u_h : I_h \rightarrow \mathbb{R}$  Näherungslösung. Nach Beweis von Satz 3.23 gilt:

$$\|e_h\|_h \leq \frac{1}{L} \tau e^{L(b-a)} + |e_0| e^{L(b-a)},$$

wobei  $\tau$  obere Schranke für den Abschneidefehler ist.

Sei  $|e_0| \leq \varepsilon$ . Ist dann  $\tau \leq \frac{1}{2} \frac{L\tilde{\varepsilon}}{e^{L(b-a)}} =: \eta$  und  $e_0 \leq \frac{1}{2} \frac{\tilde{\varepsilon}}{e^{L(b-a)}}$ , so gilt:

$$\|e_h\|_h \leq \tilde{\varepsilon}.$$

**Idee:** Wähle in jedem Schritt die Gitterweite  $h_j > 0$  so, dass  $h_j$  maximal ist und  $\tau \leq \eta$  erfüllt ist!

#### Darstellung des Verfahrensfehlers:

$\hat{y}$  genüge dem lokalen AWP

$$\begin{cases} y' = f(x, y), \\ y(x^*) = z^*, \end{cases}$$

wobei  $f$  die Voraussetzungen aus Satz 3.41 erfülle.

Dann gilt für  $x \in \{x^*, x^* + h\}$

$$u_h = \hat{y}(x) + \bar{y}_0(x)h^p + \bar{y}_1(x)h^{p+1} + O(h^{p+2}).$$

Es folgt:

$$\begin{aligned} \tau_h(x^*, y) &= -\bar{y}_0(x^* + h)h^{p-1} - \bar{y}_1(x^* + h)h^p + O(h^{p+1}) \\ &\stackrel{\text{Taylor}}{=} -h^p \bar{y}'_0(x^*) + O(h^{p+1}). \end{aligned}$$

**Ansatz:** Berechne  $h$  näherungsweise durch

$$h^p |\bar{y}'_0(x^*)| = \eta \quad (A)$$

**1. Variante:** Schätzung von  $h$  mittels Extrapolation.

- 1.) Bestimme Näherungslösung  $v_1$  in  $x^* + \tilde{h}$  ausgehend von  $(x^*, z^*)$  bei Schrittweite  $\tilde{h}$ .
- 2.) Bestimme Näherungslösung  $v_2$  in  $x^* + \tilde{h}$  ausgehend von  $(x^*, z^*)$  bei Schrittweite  $\frac{\tilde{h}}{2}$ .

Mit 3.41 folgt

- (1)  $\hat{y}(x^* + \tilde{h}) - v_1 = -\bar{y}'_0(x^*)\tilde{h}^{p+1} + O(\tilde{h}^{p+2}),$
- (2)  $\hat{y}(x^* + \tilde{h}) - v_2 = -\bar{y}'_0(x^*) \left(\frac{\tilde{h}}{2}\right)^{p+1} + O(\tilde{h}^{p+2}).$

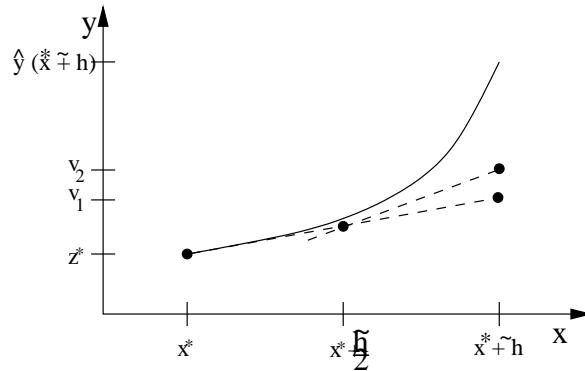


Abbildung 3.7: Schätzung mittels Extrapolation

$$\begin{aligned} \stackrel{(2)-(1)}{\Rightarrow} \tilde{h}^{p+1} \bar{y}'_0(x^*) &= \frac{v_1 - v_2}{1 - 2^{-(p+1)}} + O(\tilde{h}^{p+2}), \\ \Rightarrow \bar{y}'_0(x^*) &= \tilde{h}^{-(p+1)} \frac{v_1 - v_2}{1 - 2^{-(p+1)}} + O(\tilde{h}). \end{aligned}$$

Einsetzen in (A) ergibt für  $h$  die Schätzung

$$h = \tilde{h} \sqrt[p]{\frac{2^{p+1} - 1}{2^{p+1}} \frac{\eta \tilde{h}}{|v_1 - v_2|}}.$$

Empfehlung:

Ist  $h \in \left[\frac{\tilde{h}}{2}, 2\tilde{h}\right]$ , so arbeite weiter mit  $h_j := h$ ,  
andernfalls führe eine neue Schätzung mit  $\tilde{h} := h$  durch.

Grund: Die Schrittweite soll nicht zu stark schwanken.

Sinnvoll: Abbruchbedingung: Wenn  $h < 10^{-d}$ ,  $d > 0$ , dann Abbruch.

2. Variante: Schätzung von  $h$  mit Verfahren höherer Konsistenzordnung.

Seien  $\Phi, \tilde{\Phi}$  Verfahren mit Konsistenzordnung  $p, q, q > p$  und seien für  $\Phi, \tilde{\Phi}$  die Voraussetzungen von Satz 3.41 erfüllt.

- 1.) Berechne  $v_1$  in  $x^* + \tilde{h}$  ausgehend von  $(x^*, z^*)$  mit  $\Phi$  und Schrittweite  $\tilde{h}$ .
- 2.) Berechne  $v_2$  in  $x^* + \tilde{h}$  ausgehend von  $(x^*, z^*)$  mit  $\tilde{\Phi}$  und Schrittweite  $\tilde{h}$ .

Mit Satz 3.41 folgt:

- (1)  $\hat{y}(x^* + \tilde{h}) - v_1 = -\bar{y}'_0(x^*) \tilde{h}^{p+1} + O(h^{p+2})$ ,
- (2)  $\hat{y}(x^* + \tilde{h}) - v_2 = -\bar{y}'_0(x^*) \tilde{h}^{q+1} + O(h^{q+2})$ .

$$\stackrel{(2)-(1)}{\Rightarrow} \bar{y}'_0(x^*) = \tilde{h}^{-(p+1)} \frac{v_1 - v_2}{1 - \tilde{h}^{q-p}} + O(\tilde{h}).$$

Einsetzen in (A) ergibt:

$$h = \tilde{h} \sqrt[p]{\frac{\tilde{h} \eta (1 - \tilde{h}^{q-p})}{|v_1 - v_2|}}.$$

**Aufwandsvergleich:**

Variante 1: 100% Mehraufwand (Zwischenpunkt)

Variante 2: Bei verschiedenen Verfahren i.A. Summe aus Aufwand von  $\Phi$  und  $\tilde{\Phi}$  (für die Praxis besser!).

**Realisierung von Variante 2 mit eingebetteten R.-K. Verfahren**

**Idee:** m-Stufen

0							
$\alpha_2$	$\beta_{2,1}$						
$\vdots$	$\vdots$	$\ddots$					
$\alpha_m$	$\beta_{m,1}$	$\dots$	$\beta_{m,m-1}$				
	$\gamma_1$	$\dots$	$\gamma_{m-1}$	$\gamma_m$			
	$\tilde{\gamma}_1$	$\dots$	$\tilde{\gamma}_{m-1}$	$\tilde{\gamma}_m$			

wobei  $\tilde{\Phi}$  definiert durch  $\tilde{\gamma}_i, i = 1, \dots, m$  die optimale Konsistenzordnung und  $\Phi$  definiert durch  $\gamma_i, i = 1, \dots, m$  eine um 1 kleinere Konsistenzordnung liefert.

**Vorteil:** Die Stufenfunktionen  $k_i$  müssen für  $\Phi$  und  $\tilde{\Phi}$  nur einmal berechnet werden.

**Beispiel:** Das Verfahren von Dormand-Prince ( $m = 7$ )

0							
$\frac{1}{5}$	$\frac{1}{5}$						
$\frac{3}{10}$	$\frac{3}{40}$	$\frac{9}{40}$					
$\frac{4}{5}$	$\frac{44}{45}$	$-\frac{56}{15}$	$\frac{32}{9}$				
$\frac{8}{9}$	$\frac{19372}{6561}$	$-\frac{25360}{2187}$	$\frac{64448}{6561}$	$-\frac{212}{729}$			
1	$\frac{9017}{3168}$	$-\frac{355}{33}$	$\frac{46732}{5247}$	$\frac{49}{176}$	$-\frac{5130}{18656}$		
1	$\frac{35}{348}$	0	$\frac{500}{1113}$	$\frac{125}{192}$	$-\frac{2187}{6784}$	$\frac{11}{84}$	
$\gamma$	$\frac{5179}{57900}$	0	$\frac{7571}{16695}$	$\frac{393}{640}$	$-\frac{92097}{339200}$	$\frac{187}{2100}$	$\frac{1}{40}$
$\tilde{\gamma}$	$\frac{35}{348}$	0	$\frac{500}{1113}$	$\frac{125}{192}$	$-\frac{2187}{6784}$	$\frac{11}{84}$	0

$\Rightarrow p(\gamma) = 4, p(\tilde{\gamma}) = 5.$

## 3.4 Mehrschrittverfahren

Um Mehrschrittverfahren zu untersuchen benötigen wir einige Sätze aus der Theorie linearer Differenzengleichungen, die wir im folgenden Abschnitt formulieren.

### 3.4.1 Theorie der linearen Differenzengleichungen

#### Definition 3.46 (Differenzengleichung)

Sei  $U := \{u : \mathbb{N}_0 \longrightarrow \mathbb{C}\}$  die Menge der komplexen Zahlenfolgen mit  $u_i = u(i)$ . Seien  $k \in \mathbb{N}_0$ ,  $f \in U$ ,  $\alpha_i \in \mathbb{C}$ ,  $i = 0, \dots, k-1$  gegeben. Dann heißt:

$$(DG_k) \quad u_{n+k} + \alpha_{k-1}u_{n+k-1} + \dots + \alpha_0u_n = f_n ; \quad n \in \mathbb{N}_0$$

Differenzengleichung der Ordnung  $k$ .

$(DG_k)$  heißt homogen, falls  $f = 0$ , sonst inhomogen.

#### Lemma 3.47

Sei eine homogene Differenzengleichung mit Ordnung  $k$  gegeben.

- 1) Seien  $u_0, \dots, u_{k-1} \in \mathbb{C}$  gegebene Anfangswerte einer Folge  $u \in U$ . Dann gilt: Es gibt genau eine Folge  $u \in U$  mit diesen Anfangsdaten, welche der Differenzengleichung genügt.
- 2) Die Menge aller Lösungen der Differenzengleichungen bildet einen  $k$ -dimensionalen Unterraum von  $U$ . Basislösungen sind definiert durch:

$$\begin{cases} u^{(j)} = (u_n^{(j)})_{n \in \mathbb{N}_0}, \\ u_n^{(j)} = \delta_{nj} \quad 0 \leq n, j \leq k-1, \\ u^{(j)} \text{ erfüllt die Differenzengleichung für } 0 \leq j \leq k-1, \end{cases}$$

*Beweis:* 1) Durch vollständige Induktion, 2) nachrechnen.

□

#### Definition und Satz 3.48 (Charakteristisches Polynom)

Für  $(DG_k)$  homogen heißt

$$\rho(t) = t^k + \alpha_{k-1}t^{k-1} + \dots + \alpha_0$$

charakteristisches Polynom. Seien  $\lambda_1, \dots, \lambda_m$  Nullstellen des Polynoms  $\rho$  mit Vielfachheit  $m_1, \dots, m_m$  mit  $\sum_{i=1}^m m_i = k$ . Dann sind äquivalent:

- 1)  $u$  ist eine Lösung von  $(DG_k)$ ,
- 2)  $u = (u_n)_{n \in \mathbb{N}_0}$ ,  $u_n = \sum_{i=1}^m p_i(n) \lambda_i^n$ ,  $n \in \mathbb{N}_0$ , wobei  $p_i \in \mathbb{P}_{m_i-1}$  sind für  $i = 1, \dots, m$ .

*Beweis:*

1)  $\Rightarrow$  2)  $u_0, \dots, u_{k-1}$  seien Anfangswerte einer gegebenen Lösung von  $(DG_k)$ . Setze

$$A := \begin{pmatrix} 0 & 1 & & 0 \\ & \ddots & \ddots & \\ 0 & & 0 & 1 \\ -\alpha_0 & \dots & \dots & -\alpha_{k-1} \end{pmatrix} \in \mathbb{C}^{k \times k} \text{ "Begleitmatrix von } \rho$$

$$\text{und } \vec{u}_n := \begin{pmatrix} u_n \\ \vdots \\ u_{n+k-1} \end{pmatrix} \in \mathbb{C}^k \text{ "Folgenabschnitt } n\text{".}$$

Dann gilt:

$$\vec{u}_n = A \vec{u}_{n-1} \xrightarrow{\text{Induktion}} \vec{u}_n = A^n \vec{u}_0.$$

Nach linearer Algebra ex. eine invertierbare Matrix  $S$ , so dass  $A = SJS^{-1}$ , wobei  $J$  die Jordansche Normalform von  $A$  ist.

$$\text{Also } J = \begin{pmatrix} J_1 & & 0 \\ & \ddots & \\ 0 & & J_n \end{pmatrix} \text{ mit } J_i = \begin{pmatrix} \lambda_i & 1 & & 0 \\ & \ddots & \ddots & \\ & & \ddots & 1 \\ 0 & & & \lambda_i \end{pmatrix} \in \mathbb{C}^{m_i \times m_i}.$$

Dann folgt induktiv:  $A^n = SJ^nS^{-1}$ , wobei

$$J_i^n = \begin{pmatrix} \lambda_i^n & \binom{n}{1} \lambda_i^{n-1} & \binom{n}{2} \lambda_i^{n-2} & \dots & \binom{n}{m_i-1} \lambda_i^{n-m_i+1} \\ 0 & \ddots & \binom{n}{1} \lambda_i^{n-1} & \dots & \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ 0 & \dots & \dots & 0 & \lambda_i^n \end{pmatrix}$$

mit  $\binom{n}{j} = 0$  für  $j > n$ .

$\binom{n}{j}$  ist für festes  $j$  und  $n \in \mathbb{N}_0$  ein Polynom vom Grad  $j$  in  $n$ .

$\Rightarrow J_i^n$  enthält Koeffizienten nur vom Typ  $p_i(n) \lambda_i^n$  mit Grad von  $p_i \leq m_i - 1$ .

Also hat  $u_n$  die angegebene Form.

2)  $\Rightarrow$  1) Ü.A.

□

### Beispiel 3.49

$u_{n+3} - 4u_{n+2} + 5u_{n+1} - 2u_n = 0$  mit Startwerten  $u_0 = 1, u_1 = 2, u_2 = -1$ .

Das charakteristische Polynom ist:

$$\begin{aligned} \rho(t) &= t^3 - 4t^2 + 5t - 2 \\ &= (t-1)^2(t-2), \end{aligned}$$

$\Rightarrow \lambda_1 = 1$  mit  $m_1 = 2, \lambda_2 = 2$  mit  $m_2 = 1$ .

Mit Satz 3.45 folgt:

$$u_n = p_1(n)1^n + p_2(n)2^n.$$

Mit  $p_1(n) = \alpha + \beta n$  und  $p_2(n) = \gamma$  folgen die Bedingungen:

$$\left. \begin{array}{l} 1 = u_0 = \alpha + \gamma \\ 2 = u_1 = \alpha + \beta + 2\gamma \\ -1 = u_2 = \alpha + 2\beta + 4\gamma \end{array} \right\} \Rightarrow \begin{array}{l} \alpha = 5 \\ \beta = 5 \\ \gamma = -4 \end{array}$$

Also ist die eindeutige Lösung der Differenzengleichung gegeben durch:

$$u_n = 5(1 + n) - 2^{n+2}.$$

**Bemerkung 3.50**

Für die Matrix  $A$  gilt stets  $Rg(A - \lambda I) \geq k - 1$  für  $\lambda \in \mathbb{C}$ .

Ist  $\lambda$  Eigenwert von  $A$ , so gilt  $\dim \text{Eig}(\lambda) = \dim \ker(A - \lambda I) \leq 1$ .

$\Rightarrow$  Für jeden Eigenwert  $\lambda$  gibt es höchstens einen Jordanblock.

**Satz 3.51 (Wurzelbedingung von Dahlquist)**

Sei  $(DG_k)$  eine homogene, lineare Differenzengleichung mit charakteristischem Polynom  $\rho$ . Dann sind äquivalent:

- 1) Jede Lösung von  $(DG_k)$  ist beschränkt.
- 2) Die Nullstellen  $\lambda_i$  von  $\rho$  erfüllen
  - (i)  $|\lambda_i| \leq 1$ ,
  - (ii)  $|\lambda_i| = 1 \Rightarrow \lambda_i$  ist einfache Nullstelle.

*Beweis:*

- 2)  $\Rightarrow$  1) Die Behauptung folgt direkt aus Satz 3.48, da

$$\lim_{n \rightarrow \infty} |u_n| = \lim_{n \rightarrow \infty} \sum_{i=1}^m |p_i(n)| |\lambda_i|^n \leq C.$$

- 1)  $\Rightarrow$  2) Sei  $u_n = \lambda_i^n$ . Dann folgt aus  $\lim_{n \rightarrow \infty} |u_n| \leq C$  auch  $\lim_{n \rightarrow \infty} |\lambda_i|^n \leq C$  und somit  $|\lambda_i| \leq 1$ .

Sei weiter  $\lambda_i$  NST mit Vielfachheit  $m_i \geq 2$ . Dann ist  $u_n = n\lambda_i^n$  eine Lösung und mit Satz 3.48 folgt:

$$\lim_{n \rightarrow \infty} |u_n| \leq C \Rightarrow \lim_{n \rightarrow \infty} n|\lambda_i^n| \leq C \Rightarrow |\lambda_i| < 1.$$

□

**Definition 3.52 (Verschiebeoperatoren)**

$$E : U \longrightarrow U, \quad u \longmapsto Eu \text{ mit } (Eu)_n = u_{n+1}$$

$$\Rightarrow (u_0, u_1, u_2, \dots) \longmapsto (u_1, u_2, u_3, \dots)$$

$$E^{-1} : U \longrightarrow U, \quad u \longmapsto E^{-1}u \text{ mit } (E^{-1}u)_n = \begin{cases} u_{n-1}, & n \geq 1 \\ 0, & n = 0 \end{cases}$$

$$\Rightarrow (u_0, u_1, u_2, \dots) \longmapsto (0, u_0, u_1, u_2, \dots)$$

**Bemerkung 3.53**

1)  $EE^{-1}u = u$ , aber  $E^{-1}Eu = u - u_0e^{(0)}$  mit  $e_n^{(j)} := \delta_{jn}$  für  $j, n \in \mathbb{N}_0$ .

2) Es ist  $E^j := \underbrace{E \cdot \dots \cdot E}_{j-\text{mal}}$   
 $\implies \rho(E)u = f$  "Differenzengleichung" ( $DG_k$ ).

### Lemma 3.54

Sei  $(DG_k)$  gegeben. Definiere  $v^{(j)} := E^{-j-1}u^{(k-1)}$  mit  $u^{(k-1)}$  Basislösung von  $\rho(E)u = 0$ . Dann gilt:

$$\rho(E)v^{(j)} = e^{(j)}, \quad \text{für } j \in \mathbb{N}_0.$$

*Beweis:* Ü.A. □

### Satz 3.55

Sei  $\rho(E)u = f$  inhomogene Differenzengleichung der Ordnung  $k$ . Dann gilt:

(i)  $\bar{u} := \sum_{n=0}^{\infty} f_n v^{(n)}$  ist eine Lösung.

(ii) Alle Lösungen haben die Gestalt:

$$u = \tilde{u} + \bar{u} \text{ mit } \tilde{u} \text{ ist Lösung von } \rho(E)u = 0.$$

( $\implies$  Lösungsmenge ist  $k$ -dimensionale Untermannigfaltigkeit von  $U$ )

(iii) Für gegebenes AWP  $\rho(E)u = f$  mit  $u_i = \beta_i$  für  $i = 0, \dots, k-1$  gilt:

$$u = \tilde{u} + \bar{u},$$

wobei  $\tilde{u}$  Lösung von  $\rho(E)u = 0$  ist mit  $\tilde{u}_i = \beta_i$ ,  $i = 0, \dots, k-1$ .

*Beweis:* Nachrechnen. □

### Bemerkung 3.56

Es gilt  $v_n^{(j)} = 0$  für  $n \leq k+j-1$ , also insbesondere  $\bar{u}_n := \sum_{j=0}^{n-k} f_j u_{n-j-1}^{(k-1)}$ .

### Beispiel 3.57

1) Sei  $\rho(t) = t^2 - 1$ ;  $f = (f_n)_{n \in \mathbb{N}}$  mit  $f_n := n$   
 $\implies$  NST von  $\rho(t)$ :  $\lambda_{1/2} = \pm 1$

a) Homogene Lösung:  $\tilde{u}_n = \alpha 1^n + \beta (-1)^n$  (nach Satz 3.48).

b) Spezielle Lösung des inhomogenen Problems:

$$\begin{aligned} 1. \text{ Ansatz: } \bar{u}_n &= An + B \\ \implies n = f_n &= (\rho(E)\bar{u})_n = \bar{u}_{n+2} - \bar{u}_n \\ &= A(n+2) + B - An - B = 2A \end{aligned}$$

Ansatz schlägt fehl, da  $A$  unabhängig von  $n$  gewählt werden muss!

2. Ansatz:  $\bar{u}_n = An^2 + Bn$

$$\implies n = f_n = \bar{u}_{n+2} - \bar{u}_n = A \cdot (n+2)^2 + B(n+2) - An^2 - Bn$$

Sortiere Terme mit Faktor  $n^2, n, 1$ . Dann folgt durch Koeffizientenvergleich:

$$\left. \begin{array}{l} \text{Terme mit } n^2: \quad / \\ \text{Terme mit } n: \quad 4A + B - B = 1 \\ \text{Terme mit } 1: \quad 4A + 2B = 0 \end{array} \right\} \implies \begin{array}{l} A = \frac{1}{4} \\ B = -\frac{1}{2} \end{array}$$

Eine spezielle Lösung ist also:

$$\bar{u}_n = \frac{1}{4}n^2 - \frac{1}{2}n$$

c) Wir erhalten eine allgemeinere Lösung:  $u = \tilde{u} + \bar{u}$

$$u_n = \frac{1}{4}n^2 - \frac{1}{2}n + \alpha + \beta(-1)^n$$

2) Sei  $\rho(t) = t^2 - 1$  und  $f_n = n + 2^n$

a) Homogene Lösung wie in 1).

b) Inhomogene Lösung:

$$\text{Ansatz: } \bar{u}_n = An^2 + Bn + C2^n$$

$$\text{Koeffizientenvergleich: } c = \frac{1}{3}, \quad A = \frac{1}{4}, \quad B = -\frac{1}{2}$$

c) Allgemeine Lösung:

$$u_n = \frac{1}{4}n^2 - \frac{1}{2}n + \frac{1}{3}2^n + \alpha + \beta(-1)^n$$

### Lösung von Differenzengleichungen im Hauptfall:

Seien  $f_n := \sum_{j=1}^i q_j(n) \mu_j^n$  mit  $\mu_j \in \mathbb{C}$   $q_j \in \mathbb{P}$  mit  $\text{Grad}(q_j) =: g_j$ .  $\mu_j$  sei  $m_j$ -fache NST von  $\rho$  mit  $0 \leq m_j \leq k$  ( $m_j = 0 \implies \mu_j$  keine NST von  $\rho$ ).

**Ansatz:**  $\bar{u}_n = \sum_{j=1}^i n^{m_j} \tilde{q}_j(n) \mu_j^n$  mit  $\tilde{q}_j$  allgemeines Polynom vom Grad  $g_j$ .

In Beispiel 1):  $i = 1$ ;  $\mu_1 = 1$ ;  $q_1(n) = n$ .

In Beispiel 2):  $i = 2$ ;  $\mu_1 = 1$ ;  $\mu_2 = 2$ ;  $q_1(n) = n$ ;  $q_2(n) = 1$ .

3) Weiteres Beispiel:  $f_n = n^2(-1)^n + n^4 + n^5 2^n$ .

$$\implies i = 3; \mu_1 = -1; \mu_2 = 1, \mu_3 = 2, q_1(n) = n^2, q_2(n) = n^4, q_3(n) = n^5.$$

### 3.4.2 Lineare k-Schrittverfahren

Es gelten die Voraussetzungen aus Abschnitt 3.3 für (AWP) und zusätzlich sei  $I_h$  äquidistant, d.h.  $h_j = h \quad \forall j$ .

**Definition 3.58 (k-Schrittverfahren)**

- a) Ein Verfahren  $\Phi$  zur Lösung des (AWP) auf  $I$  heißt  $k$ -Schrittverfahren mit  $k \in \mathbb{N}$ , falls es eine Verfahrensfunktion  $\varphi = \varphi(x, v_0, v_1, \dots, v_k, h)$  mit  $(x + hi, v_i) \in K_M \quad \forall i = 0, \dots, k$ ,  $h \in (0, \frac{b-a}{k}]$ ,  $\varphi(x, v_0, v_1, \dots, v_k, h) \in [-M, M]$  gibt, so dass für (äquidistante) zulässige Gitter  $I_h$  mit genügend kleiner Feinheit die Näherungslösung  $u_h(x_j) =: u_j$  durch die Differenzengleichung  $k$ -ter Ordnung

$$\sum_{i=0}^k a_i u_{j+i} = h \varphi(x_j, u_j, u_{j+1}, \dots, u_{j+k}, h)$$

wohldefiniert ist für geeignete Startwerte,  $u_0, \dots, u_{k-1}$ .

- b) Ein  $k$ -Schrittverfahren heißt linear, falls  $\varphi$  die Form

$$\varphi(x, v_0, v_1, \dots, v_k, h) = \sum_{i=0}^k b_i f(x + ih, v_i)$$

hat.

**Definition und Bemerkung 3.59**

- 1) Ist  $\rho(t) = \sum_{i=0}^k a_i t^i$  das sogenannte 1. charakteristische Polynom von  $\Phi$ , so schreiben wir

$$\Phi = (\rho, \varphi).$$

Ist das Verfahren linear und  $\sigma(t) := \sum_{i=0}^k b_i t^i$  das so genannte 2. charakteristische Polynom von  $\Phi$ , so schreiben wir

$$\Phi = (\rho, \sigma).$$

- 2) Implizitheit ist grundsätzlich zulässig.  
 3) Für  $k = 1$  erhalten wir die Definition von Einschrittverfahren.

**Definition 3.60 (Abschneidefehler und Konsistenz)**

- 1) Für  $h \in (0, \frac{b-a}{k}]$ ,  $x \in [a, b - kh]$  und  $y \in C^1(I) : y'(\xi) = f(\xi, y(\xi))$  auf  $[x, x + kh]$  mit  $(x + hi, y(x + hi)) \in K_M, j = 0, \dots, k$  heißt

$$\tau_h(x, y) := \frac{1}{h} \sum_{i=0}^k a_i y(x + hi) - \varphi(x, y(x), y(x + h), \dots, y(x + kh), h)$$

der lokale Abschneidefehler.

- b) Ist  $\tau_h(x, \tilde{y}) = o(1)$  für  $h \rightarrow 0$ , so heißt  $\Phi$  konsistent mit (AWP), falls die Anfangswerte  $u_0, \dots, u_{k-1}$  konsistent sind, d.h.  $u_i \xrightarrow{h \rightarrow 0} y_0$  für  $i = 0, \dots, k-1$ .  
 Ist  $\tau_h(x, \tilde{y}) = O(h^p)$ ,  $p \in \mathbb{N}$  für  $h \rightarrow 0$ , so hat  $\Phi$  die Konsistenzordnung  $p$ , falls die Anfangswerte die Konsistenzordnung  $p$  haben, d.h.  $|u_i - y_0| = O(h^p)$  für  $i = 0, \dots, k-1$ .

### 3.61 Mehrschrittverfahren resultierend aus Quadraturen

**Ansatz:** Interpolationsquadratur des Richtungsfeldes.

Aus  $y' = f(x, y)$  folgt für  $x_j, x_{j+k} \in [a, b]$

$$y(x_{j+k}) = y(x_{j+q}) + \int_{x_{j+q}}^{x_{j+k}} f(t, y(t)) dt$$

für  $0 \leq q \leq k - 1$ .

**Idee:** Approximation mit geeigneter Quadraturformel (siehe Abb. 3.8).

Approximiere  $\int_{x_{j+q}}^{x_{j+k}} f(t, y(t)) dt \approx h \sum_{i=0}^s b_i \underbrace{f(x_{j+i}, u_{j+i})}_{=: f_{j+i}}$  mit  $0 \leq s \leq k$ .

Erhalte MSV:

$$u_{j+k} = u_{j+q} + h \sum_{i=0}^s b_i f_{j+i}.$$

Ist  $s < k$ , oder  $b_k = 0 \implies$  Verfahren ist explizit.

Ist  $s = k$  und  $b_k \neq 0 \implies$  Verfahren ist implizit.

**Ansatz zu Bestimmung der  $b_i$ :** Ersetze  $f(t, y(t))$  durch Polynom  $p_j$  vom Grad  $s$ ,  $0 \leq s \leq k$ , so dass  $p_j$  die Daten  $(x_{j+i}, f_{j+i})$   $i = 0, \dots, s$  interpoliert.

Berechne die Koeffizienten  $b_i$  durch Lagrange-Ansatz:

$$p_j(t) = \sum_{i=0}^s L_{ij}(t) f_{j+i} \text{ mit } L_{ij}(t) = \prod_{l=0, l \neq i}^s \frac{t - x_{j+l}}{x_{j+i} - x_{j+l}} \implies L_{ij}(x_{j+l}) = \delta_{il}$$

Dann ist:

$$b_i = \frac{1}{h} \int_{x_{j+q}}^{x_{j+k}} L_{ij}(t) dt.$$

**Bemerke:** Auf äquidistanten Gittern hängen die  $b_i$  nicht von  $h$  und  $j$  ab.

Im Sinne von 3.58 und 3.59 folgt:

$$u_{j+k} - u_{j+q} = h \varphi(x_j, u_j, \dots, u_{j+k}, h)$$

mit  $\varphi(x, v_0, v_1, \dots, v_k, h) = \sum_{i=0}^s b_i f(x + ih, v_i)$ .

$$\implies \rho(t) = t^k - t^q \quad 1. \text{ charakteristisches Polynom},$$

$$\implies \sigma(t) = \sum_{i=0}^s b_i t^i \quad 2. \text{ charakteristisches Polynom},$$

$$\implies \Phi = (\rho, \sigma).$$

#### Satz 3.62

Seien  $f \in C^{s+1}(S)$  und  $\Phi = (\rho, \sigma)$  ein  $k$ -Schrittverfahren der Klasse 3.61. Dann hat  $\Phi$  die Konsistenzordnung  $s + 1$ , falls die Anfangswerte diese Konsistenzordnung haben.

(Für  $k$  gerade,  $q = 0$  und  $s = k$  gilt sogar "s+2"!)

*Beweis:* Setze  $t_i = x + ih$ ,  $i = 0, \dots, s$ . Sei  $p(t_i) = y'(t_i) = f(t_i, y(t_i))$

$$\implies p(t) - f(t, y(t)) \stackrel{\text{Satz 1.4}}{=} \frac{1}{(s+1)!} \prod_{i=0}^s (t - t_i) y^{(s+2)}(\xi_t) \quad (*)$$

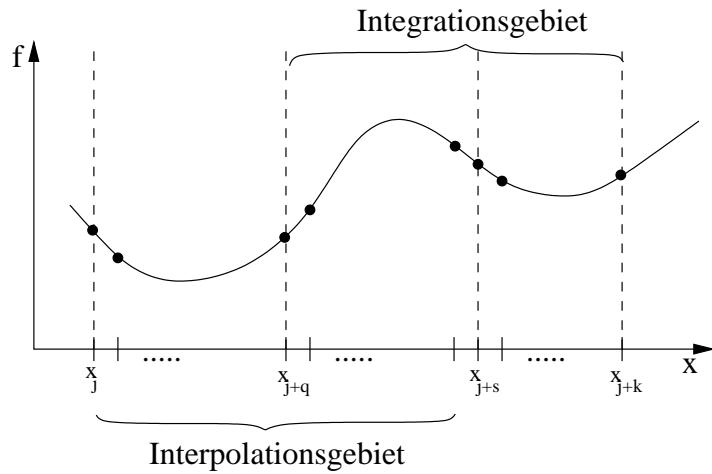


Abbildung 3.8: spezielle lineare Mehrschrittverfahren

für ein  $\xi_t \in (t_0, t_s)$ .

$$\begin{aligned}
 \Rightarrow \tau_h(x, \tilde{y}(x)) &= \frac{1}{h} [\tilde{y}(x + kh) - \tilde{y}(x + qh)] - \frac{1}{h} \sum_{i=0}^s b_i f(x + ih, \tilde{y}(x + ih)) \\
 &= \frac{1}{h} \int_{x+qh}^{x+kh} \tilde{y}'(t) dt - \frac{1}{h} \int_{x+qh}^{x+kh} p(t) dt \\
 &= \frac{1}{h} \int_{x+qh}^{x+kh} (f(t, \tilde{y}(t)) - p(t)) dt \\
 &\stackrel{(*)}{=} \frac{1}{h} \frac{1}{(s+1)!} \int_{x+qh}^{x+kh} \prod_{i=0}^s (t - t_i) \tilde{y}^{(s+2)}(\xi_t) dt,
 \end{aligned}$$

$$\begin{aligned}
 \Rightarrow |\tau_h(x, \tilde{y}(x))| &\leq \frac{1}{h} \frac{1}{(s+1)!} \|\tilde{y}^{(s+2)}\|_{\infty, I} (sh)^{s+1} (k - q) h \\
 &\leq \underbrace{C(\tilde{y}, s)}_{\text{konstant}} h^{s+1}.
 \end{aligned}$$

□

### 3.63 Berechnung der Koeffizienten $b_i$

Es ist  $b_{s-r} = (-1)^r \sum_{i=r}^s \binom{i}{r} b_i^*$ ,  $0 \leq r \leq s$  mit  $b_i^* = \int_{q-k}^{k-s} \binom{t+i-1}{i} dt$ .

Mit  $a := q - k$ ,  $b := k - s$  entstehen die  $b_i^* = b_i^*(a, b)$  als Taylorkoeffizienten der Funktion  $g(z, a, b)$  bei der Entwicklung um  $z = 0$ , wobei

$$g(z, a, b) := \frac{(1-z)^{-a}}{\ln(1-z)} - \frac{(1-z)^{-b}}{\ln(1-z)}$$

$$\Rightarrow g(z, a, b) = \sum_{i=0}^{\infty} b_i^*(a, b) z^i \text{ mit } a < b \leq 1, |z| \leq R < 1. g \text{ heißt erzeugende Funktion für } b_i^*.$$

**Definition 3.64**

- 1)  $q = k - 1$  "Adams-Verfahren"
- 2)  $q = k - 1, s = k - 1$  "Adams-Bashforth-Verfahren", explizit
- 3)  $q = k - 1, s = k$  "Adams-Moulton-Verfahren", implizit
- 4)  $q = k - 2, s = k - 1$  "Nyström-Verfahren", explizit
- 5)  $q = k - 2, s = k$  "Milne-Simpson-Verfahren", implizit

**3.65 MSV resultierend aus Differentiationsformeln (BDF-Verfahren)**

**Ansatz:** Interpoliere die Daten  $(x_j, u_j), \dots, (x_{j+k}, u_{j+k})$  mit  $p(x)$  und verwende  $p'(x_{j+q})$  als Approximation für  $y'(x_{j+q}) = f(x_{j+q}, y(x_{j+q}))$ .

$$\begin{aligned} q = k &\implies \text{implizites Verfahren} \\ 0 \leq q \leq k - 1 &\implies \text{explizites Verfahren} \end{aligned}$$

Lagrangeansatz für  $p(x)$ :

$$h \cdot p'(x_{j+q}) = \sum_{i=0}^k \underbrace{L'_{ij}(x_{j+q})h}_{=:a_i} \cdot u_{j+i} = h \underbrace{f(x_{j+q}, u_{j+q})}_{=: \varphi},$$

wobei  $a_i$  unabhängig von  $j$  und von  $h$  ist.

$$\implies \rho(t) = \sum_{i=0}^k a_i t^i, \quad \sigma(t) = t^q, \quad \implies \Phi = (\rho, \sigma) \quad \text{"BDF-k Verfahren".}$$

**Satz 3.66**

Sei  $f \in C^k(S)$ . Dann gilt für das BDF-k Verfahren aus 3.65:

Die Konsistenzordnung ist  $p = k$  bei hinreichend konsistenten Startwerten.

*Beweis:* Ü.A. □

**Satz 3.67 (Charakterisierung der Konsistenz von MSV)**

Sei  $\Phi(\rho, \varphi)$  k-Schrittverfahren mit  $k \geq 1$ . Seien  $u_0, \dots, u_{k-1}$  Startwerte. Dann sind äquivalent:

- 1)  $\Phi$  ist konsistent mit (AWP).
- 2) a)  $u_i \rightarrow y_0$  für  $h \rightarrow 0$ ;  $i = 0, \dots, k - 1$ ,  
 b)  $\rho(1)\tilde{y}(x) = 0$ ,  
 c)  $\varphi(x, \tilde{y}(x), \dots, \tilde{y}(x + kh), h) - \rho'(1)f(x, \tilde{y}(x)) \rightarrow 0$  für  $h \rightarrow 0$ .

*Beweis:*

"1)  $\implies$  2)"

a) folgt direkt aus der Definition von Konsistenz.

b) & c):

$$\begin{aligned}\sum_{i=0}^k a_i \tilde{y}(x + ih) &= \sum_{i=0}^k a_i (\tilde{y}(x) + ih\tilde{y}'(x) + o(h)) \\ &= \rho(1)\tilde{y}(x) + \rho'(1)h\tilde{y}'(x) + o(h)\end{aligned}$$

Es folgt:

$$\tau_h(x, \tilde{y}(x)) = \frac{1}{h} [\rho(1)\tilde{y}(x) + \rho'(1)h\tilde{y}'(x)] - \varphi(x, \tilde{y}(x), \dots, \tilde{y}(x + kh), h) + o(1) \quad (*)$$

$$\begin{aligned}\left| \frac{\rho(1)\tilde{y}(x)}{h} \right| &\leq |\tau_h(x, \tilde{y}(x))| + |\rho'(1)f(x, \tilde{y}(x)) - \varphi(\dots)| + o(1) \\ &\leq C \text{ unabhängig von } h\end{aligned}$$

Also folgt  $\rho(1)\tilde{y}(x) = 0$ .

Einsetzen in (\*) ergibt dann:

$$\rho'(1)f(x, \tilde{y}(x)) - \varphi(x, \tilde{y}(x), \dots, \tilde{y}(x + kh), h) = o(1) \quad (h \rightarrow 0). \implies 2c).$$

”2)  $\implies$  1)” Folgt direkt aus (\*).

□

### Folgerung 3.68

Ist  $\Phi = (\rho, \sigma)$  ein lineares k-Schrittverfahren, so gilt:

$\Phi$  ist konsistent mit (AWP), genau dann wenn 3.67 2a) und  $\rho(1) = 0, \rho'(1) = \sigma(1)$  erfüllt ist.

*Beweis:* Zu zeigen:  $\rho'(1) = \sigma(1) \iff 3.67 \text{ 2c) gilt ( 2a) und 2b) gelten sofort.}$

$$\text{Da } \varphi(x, \tilde{y}(x), \dots, \tilde{y}(x + kh), h) = \sum_{i=0}^k b_i f(x + ih, \tilde{y}(x + ih)) \implies \underbrace{\sum_{i=0}^k b_i f(x, \tilde{y}(x))}_{=\sigma(1)}$$

für  $h \rightarrow 0$ , da  $f, \tilde{y}$  stetig.

$$\implies 2c) \text{ ist erfüllt} \iff \rho'(1) = \sigma(1).$$

□

### Bemerkung 3.69

Konsistenz und Lipschitzstetigkeit von  $\varphi$  bzgl.  $v_0, \dots, v_k$  ist nur für  $k = 1$  hinreichend für die Konvergenz! (vgl. Übungsaufgabe).

### Definition 3.70 (Asymptotische Stabilität)

Sei  $\Phi = (\rho, \varphi)$  k-Schrittverfahren mit  $k \geq 1$ . Sei  $C_h := \{u : I_h \rightarrow \mathbb{R}\}$  der Funktionenraum der Gitterfunktionen. Sei  $F_h : C_h \rightarrow C_h$  für  $v \in C_h$  definiert durch

$$\begin{aligned}(F_h(v))_i &:= v_i - u_i, \quad i = 0 \dots k-1, \quad u_i \text{ Startwerte,} \\ (F_h(v))_{j+k} &:= \frac{1}{h} \sum_{i=0}^k a_i v_{i+j} - \varphi(x_j, v_j, \dots, v_{j+k}, h) \text{ für } j = 0, \dots, n-k.\end{aligned}$$

$F_h$  heißt Defektfunktion.

Das Verfahren  $\Phi$  heißt asymptotisch stabil, genau dann wenn  $\exists K, H > 0 : \forall h \in (0, H) \text{ und } \forall v, w \in C_h$ :

$$\|v - w\|_h \leq K \|F_h(v) - F_h(w)\|_h.$$

**Bemerkung 3.71**

- 1) Durch  $F_h(u) = 0$  wird die Verfahrenslösung des  $k$ -Schrittverfahrens  $\Phi$  für (AWP) implizit beschrieben, falls  $u_0, \dots, u_{k-1}$  Startwerte sind.
- 2) Ist  $F_h(v_h) = \varepsilon_h$  mit  $\varepsilon_h$  Störterm (etwa durch Rundungsfehler), so folgt aus der Stabilität:

$$\|u_h - v_h\|_h \leq K \underbrace{\|F(u_h)\|_h}_{=0} - \underbrace{\|F(v_h)\|_h}_{=\varepsilon_h} = K \|\varepsilon_h\|_h$$

- 3)  $F_h(\tilde{y}_{j+k}) = \tau_h(x_{j+k}, \tilde{y})$

**Satz 3.72 (Charakterisierung stabiler  $k$ -Schrittverfahren)**

Sei  $\Phi = (\rho, \varphi)$   $k$ -Schrittverfahren mit  $k \geq 1$ . Gelte:

- (i)  $f = 0 \implies \varphi = 0$  (bei linearen Verfahren stets erfüllt),
- (ii)  $\varphi$  sei Lipschitzstetig bzgl.  $v_0, \dots, v_k$ , d.h. es ex. ein  $\tilde{L} > 0$  mit

$$|\varphi(x, v_0, \dots, v_k, h) - \varphi(x, w_0, \dots, w_k, h)| \leq \tilde{L} \max_{0 \leq i \leq k} |v_i - w_i|$$

(bei linearen Verfahren erfüllt, falls L-Bedingung gilt.)

Dann sind äquivalent:

- a)  $\Phi$  ist asymptotisch stabil.
- b)  $\rho$  erfüllt die Wurzelbedingung von Dahlquist (vgl. Satz 3.51).

*Beweis:* Gelte stets (i), (ii).

- a)  $\implies$  b) Sei  $\Phi$  asymptotisch stabil. Dann folgt für  $f = 0$   $\varphi = 0$  nach (i) und es ist

$$(F_h(v))_i = v_i - u_i, \quad i = 0, \dots, k-1,$$

$$(F_h(v))_{j+k} = \frac{1}{h} \sum_{i=0}^k a_i v_{j+i}, \quad j = 0, \dots, n-k.$$

Nach a)  $\exists K, H > 0$  :

$$\|u - v\|_h \leq K \|F_h(u) - F_h(v)\|_h = K \|F_h(u - v)\|_h$$

$\forall h \in (0, H)$  und  $\forall u, v \in C_h$ .

Also gilt für alle  $w \in C_h$  :  $\|w\|_h \leq K \|F_h(w)\|_h$ .

Für die Lösung  $\tilde{u}$  der Gleichung  $F_h(\tilde{u})_{j+k} = 0$ ,  $j = 0, \dots, n-k$  (homogene Gleichung) folgt:

$$\|\tilde{u}\|_h \leq K \max_{0 \leq i \leq k-1} |\tilde{u}_i|.$$

$\implies$  Für beliebige Startwerte  $\tilde{u}_0, \dots, \tilde{u}_{k-1}$  ist die Lösung der homogenen  $k$ -stufigen Differenzengleichung  $\sum_{i=0}^k a_i v_{j+i} = 0$  und  $v_i = \tilde{u}_i$  für  $i = 0, \dots, k-1$  beschränkt.  
Also folgt mit Satz 3.51, dass  $\rho$  die Wurzelbedingung von Dahlquist erfüllt.

b)  $\implies$  a) Seien  $v, w \in C_h$ , dann gilt:

$$(F_h(v) - F_h(w))_i = v_i - w_i, \quad i = 0, \dots, k-1$$

$$(F_h(v) - F_h(w))_{j+k} = \frac{1}{h} \sum_{i=0}^k a_i (v_{j+i} - w_{j+i})$$

$$-\varphi(x_j, v_j, \dots, v_{j+k}, h) + \varphi(x_j, w_j, \dots, w_{j+k}, h) \text{ für } j = 0, \dots, n-k.$$

Setze  $\delta_\mu := v_\mu - w_\mu$ ,  $\mu = 0, \dots, n$  und  $d_\mu := (F_h(v) - F_h(w))_\mu$ ,  $\mu = 0, \dots, n$  sowie

$$(*) \quad \eta_\mu := d_{\mu+k} + \varphi(x_\mu, v_\mu, \dots, v_{\mu+k}, h) - \varphi(x_\mu, w_\mu, \dots, w_{\mu+k}, h)$$

Dann gilt  $\sum_{i=0}^k a_i \delta_{i+j} = h \eta_j$  für  $j = 0, \dots, n-k$ .

Sei  $\delta_\mu$  vorgegeben für  $\mu = 0, \dots, k-1$ . Mit Satz 3.55 folgt

$$(**) \quad \delta_{j+k} = \sum_{i=0}^{k-1} \delta_i u_{j+k}^{(i)} + \sum_{\mu=0}^j h \eta_\mu u_{j+k-\mu-1}^{(k-1)},$$

wobei  $u^{(\nu)}$  für  $\nu = 0, \dots, k-1$  Basislösung der homogenen Differenzengleichung ist, d.h.  $\sum_{i=0}^k a_i u_{j+i}^{(\nu)} = 0$  und  $u_n^{(\nu)} = \delta_{n,\mu}$  für  $0 \leq n, \mu \leq k-1$ .

Nach Voraussetzung a) und Satz 3.51 folgt  $|u_n^{(\nu)}| \leq M$ ,  $n \in \mathbb{N}_0$ ,  $0 \leq \nu \leq k-1$ . Mit (\*) gilt

$$|\eta_\mu| \stackrel{(ii)}{\leq} |d_{\mu+k}| + \tilde{L} \underbrace{\max_{0 \leq i \leq k} |\delta_{\mu+i}|}_{=: \varepsilon_\mu}.$$

Also folgt aus (\*\*) und  $\delta_i = d_i$  für  $i = 0, \dots, k-1$ :

$$|\delta_{j+k}| \leq Mdk + Mh \sum_{\mu=0}^j (d + \tilde{L} \varepsilon_\mu) = Md(k + (j+1)h) + Mh\tilde{L} \sum_{\mu=0}^j \varepsilon_\mu,$$

mit  $d := \|F_h(v) - F_h(w)\|_h = \max_{0 \leq \mu \leq n} |d_\mu|$ .

Beachte: Die rechte Seite ist monoton wachsend in  $j$ . Also folgt

$$\varepsilon_j \leq Md(k + (j+1)h) + hM\tilde{L} \sum_{\mu=0}^j \varepsilon_\mu,$$

$$\implies \varepsilon_j (1 - hM\tilde{L}) \leq Md(k + (j+1)h) + hM\tilde{L} \sum_{\mu=0}^{j-1} \varepsilon_\mu.$$

Für  $h \leq H := \frac{1}{2M\tilde{L}}$  ist  $hM\tilde{L} \leq \frac{1}{2}$  und wir erhalten

$$\varepsilon_j \leq \underbrace{2M(k + (b-a))}_=: c d + \underbrace{2M\tilde{L}}_{=: D} \sum_{\mu=0}^{j-1} h \varepsilon_\mu.$$

Mit diskretem Lemma von Gronwall folgt:

$$\varepsilon_j \leq ce^{D(b-a)} d, \quad \text{für } j = 0, \dots, n-k.$$

Mit  $K := ce^{D(b-a)}$  folgt hieraus schließlich

$$\|v - w\|_h \leq K \|F_h(v) - F_h(w)\|_h.$$

□

**Folgerung 3.73**

- (i) Für L-stetige  $\varphi$  sind ESV stabil.
- (ii)  $\Phi(\rho, \varphi)$  und  $\varphi$  L-stetig, dann gilt:  
 $\Phi$  stabil  $\iff \Phi_0 = (\rho, 0)$  stabil.

**Satz 3.74 (Konvergenzsatz von Dahlquist)**

Sei  $\Phi = (\rho, \varphi)$  k-Schrittverfahren mit  $k \geq 1$ . Sei  $\Phi$  konsistent mit (AWP) von der Ordnung  $p \geq 1$  und seien die Voraussetzungen aus Satz 3.72 erfüllt. Dann sind äquivalent:

- (i)  $\Phi$  ist konvergent mit Ordnung  $p$ .
- (ii)  $\Phi$  ist asymptotisch stabil.

*Beweis:*

- (i)  $\implies$  (ii) Indirekter Beweis. Annahme:  $\Phi$  ist nicht stabil.

Dann folgt mit den Sätzen 3.51 und 3.72, dass  $\rho$  die Wurzelbedingung nicht erfüllt. Folglich hat  $\rho(E)u = 0$  eine unbeschränkte Lösung.

Wähle  $f = 0, \varphi = 0$  und konsistente Startwerte, so dass  $u_n$  divergiert für  $h \rightarrow 0$ . Dies ist ein Widerspruch zu (i).

- (ii)  $\implies$  (i) Sei  $\tilde{y}_h := \tilde{y}|_{I_h}$  Dann gilt:

$$(F_h(\tilde{y}_h))_i = \tilde{y}(x_i) - u_i, \quad 0 \leq i \leq k-1,$$

$$(F_h(\tilde{y}_h))_{j+k} = \tau_h(x_j, \tilde{y}), \quad j = 0, \dots, n-k.$$

Also folgt:

$$F_h(\tilde{y}_h) - F_h(u_h) = F_h(\tilde{y}_h) - 0$$

und somit

$$\|\tilde{y} - u_h\|_h \stackrel{\Phi\text{stabil}}{\leq} K \|F_h(\tilde{y}_h) - F_h(u_h)\|_h = K \|F_h(\tilde{y}_h)\|_h = (O(h^p)),$$

da  $\Phi$  konsistent von der Ordnung  $p$  ist.

**Bemerke:** Aus dem Beweis des Konvergenzsatzes von Dahlquist folgt für ein asymptotisch stabiles k-Schrittverfahren  $\Phi = (\rho, \varphi)$  die Fehlerabschätzung □

$$\|\tilde{y} - u_h\|_h \leq K \max \left( \max_{i=0}^{k-1} |\tilde{y}_i - u_i|, \max_{i=0}^{n-k} \tau_h(x_i, \tilde{y}) \right).$$

**Folgerung 3.75**

- 1) Für MSV der Klasse 3.61 gilt:

Ist  $0 \leq q < k$  und  $k-1 \leq s \leq k$ , so ist das Verfahren konvergent mit Ordnung  $s+1$ .

2) Für BDF-Verfahren (3.65) gilt:

Die Verfahren sind konvergent, falls

- a)  $q = k \leq 6$  (implizit),
- b)  $q = k - 1 \leq 1$  (explizit).

*Beweis:*

1) Nach Satz 3.62 sind die MSV mit Ordnung  $s + 1$  konsistent für  $f \in C^{s+1}(S)$  und es ist  $\rho(t) = t^k - t^q = t^q(t^{k-q} - 1)$ .

$\implies$  NST von  $\rho$  sind:  $\lambda_1 = 0$  (q-fache NST) und  $\lambda_{j+2} = e^{i\frac{2\pi}{k-q}j}$  für  $j = 0, \dots, k - q - 1$  (einfache NSTen).

$\implies$   $\rho$  erfüllt die Wuzelbedingung.

$\stackrel{3.72}{\implies}$  Verfahren ist asymptotisch stabil.

$\stackrel{3.74}{\implies}$  Konvergenz mit Ordnung  $s + 1$ .

2) Ü.A. □

**Beispiel 3.76 (Milne-Simpson für  $k = 2$ )**

Verfahren:

$$u_{j+2} - u_j = \frac{h}{3}[f(x_{j+2}, u_{j+2}) + 4f(x_{j+1}, u_{j+1}) + f(x_j, u_j)]$$

Betrachten wir dieses Verfahren für  $y' = \lambda y, \lambda < 0, y(0) = 1$ :

$$\implies \tilde{y}(x) = e^{\lambda x}.$$

Für  $t := \lambda h$  folgt für das Verfahren:

$$u_{j+2}(1 - \frac{t}{3}) - \frac{4}{3}tu_{j+1} - (1 + \frac{t}{3})u_j = 0,$$

$$\implies \rho_t(\mu) = \mu^2(1 - \frac{t}{3}) - \mu \frac{4}{3}t - (1 + \frac{t}{3}).$$

Nullstellen:

$$\begin{aligned} \mu_1 &= 1 + t + O(t^2) = e^t(1 + O(t^2)), \\ \mu_2 &= -1 + \frac{t}{3} + O(t^2) = -e^{-\frac{t}{3}}(1 + O(t^2)) \end{aligned}$$

Mit den Startwerten  $u_0 = 1, u_1 = 1 + t$  folgt:

$$\begin{aligned} u_j &= [1 + \frac{\lambda h}{2} + O(\lambda^2 h^2)] \underbrace{e^{\lambda x_j}}_{\text{guter Term (konvergent)}} (1 + O(\lambda h)) \\ &\quad + [-\frac{\lambda h}{2} + O(\lambda^2 h^2)] \underbrace{e^{-\lambda x_j} (-1)^j}_{\text{parazitärer Term (divergent)}} (1 + O(\lambda h)). \end{aligned}$$

Der parazitäre Term wird für  $\lambda < 0$  exponentiell groß und dominiert das Verhalten.

**Satz 3.77 (Konsistenzordnungskriterien für lineare MSV)**

Sei  $\Phi = (\rho, \sigma)$  lineares MSV mit  $k \geq 1$ , d.h.

$$\sum_{i=0}^k a_i u_{j+i} = h \sum_{i=0}^k b_i f_{j+i} \quad \text{mit} \quad f_{j+i} := f(x_{j+1}, u_{j+i}).$$

Für  $g \in C^1(\tilde{I})$ ,  $\tilde{I} = [0, b-a]$  definiere Operator

$$K(g, h) := \frac{1}{h} \sum_{i=0}^k (a_i g(ih) - h b_i g'(ih)).$$

Sei  $f \in C^p(S)$ . Dann sind äquivalent:

- (i)  $\tau_h(x, \tilde{y}) = O(h^p)$ ,
- (ii)  $K(t^s, 1) = 0$  für  $s = 0, \dots, p$ ,
- (iii)  $\lambda = 0$  ist  $(p+1)$ -fache NST von  $\rho(e^\lambda) - \lambda \sigma(e^\lambda)$ ,
- (iv)  $\lambda = 1$  ist  $p$ -fache NST von  $\frac{\rho(\lambda)}{\ln(\lambda)} - \sigma(\lambda)$
- (v) Die Konsistenzordnung für  $y' = y, y(0) = 1$  ist  $p$ .
- (vi) Die Konsistenzordnung für  $y' = sx^{s-1}, y(0) = 1$  ist  $p$  für alle  $s = 0, \dots, p$ .

*Beweis:* Wir zeigen die Äquivalenz von (i), (ii) und (iii). Für die Äquivalenz zu (iv), (v) und (vi) siehe Ü.A.

- (i)  $\iff$  (ii): Ist  $f \in C^p(S)$ , so folgt  $\tilde{y} \in C^{p+1}(I)$

Taylorentwicklung von  $\tilde{y}$  und  $\tilde{y}'$  liefert:

$$(*) \quad \begin{cases} \tilde{y}(x + ih) = \sum_{s=0}^p \frac{\tilde{y}^{(s)}(x)}{s!} i^s h^s + O(h^{p+1}), \\ \tilde{y}'(x + ih) = \sum_{s=1}^p \frac{\tilde{y}^{(s)}(x)}{s!} \cdot s i^{s-1} h^{s-1} + O(h^p). \end{cases}$$

Mit  $x_i = x + ih$  folgt für den Abschneidefehler:

$$\begin{aligned} h\tau_h(x, \tilde{y}) &= \sum_{i=0}^k a_i \tilde{y}(x_i) - h b_i \tilde{y}'(x_i) \\ &\stackrel{(*)}{=} \rho(1) \tilde{y}(x) + \sum_{s=1}^p \left( \frac{\tilde{y}^{(s)}(x)}{s!} h^s \left( \sum_{i=0}^k (a_i i^s - b_i s i^{s-1}) \right) \right) + O(h^{p+1}) \\ &\stackrel{\text{Def. } K(g, h)}{=} \sum_{s=0}^p h^s \tilde{y}^{(s)}(x) \frac{1}{s!} K(t^s, 1) + O(h^{p+1}). \end{aligned}$$

Also folgt die Behauptung.

- (ii)  $\iff$  (iii): Nach Teil 1 gilt:

$$h\tau_h(x, e^x) = e^x \sum_{s=0}^p \frac{h^s}{s!} K(t^s, 1) + O(h^{p+1}).$$

Andererseits folgt aus der Definition:

$$\begin{aligned} h\tau_h(x, e^x) = hK(e^{x+t}, h) &= e^x \sum_{i=0}^k (a_i e^{ih} - h b_i e^{ih}) \\ &= e^x (\rho(e^h) - h\sigma(e^h)). \end{aligned}$$

Also folgt

$$\underbrace{\rho(e^h) - h\sigma(e^h)}_{=:I(h)} = \sum_{s=0}^p \frac{h^s}{s!} K(t^s, 1) + O(h^{p+1}).$$

Entwicklung von  $I$  in  $h = 0$  ergibt die Behauptung. □

### Folgerung 3.78

- 1) Ist  $g(t) = y(x+t)$ , so folgt  $K(g, h) = \tau_h(x, y)$ .
- 2) Ist  $f \in C^q(S)$  und  $q \geq p$ ,  $p$  Konsistenzordnung, so gilt:

$$\tau_h(x, \tilde{y}) = \sum_{s=p+1}^q h^{s-1} \frac{\tilde{y}^{(s)}(x)}{s!} K(t^s, 1) + O(h^q).$$

$K(t^{p+1}, 1)$  heißt "Hauptfehlerkoeffizient".

### Bemerkung 3.79

- 1) Für *spezielle Klassen* von linearen MSV kann analog zu Satz 3.41 eine asymptotische Entwicklung des globalen Fehlers angegeben werden.
- 2) Insbesondere gilt bei MSV: Die Existenz einer asymptotischen Entwicklung hängt von der Wahl der Startwerte ab.  
Siehe hierzu auch Stoer/Bulirsch: Numerische Mathematik II [8].

### 3.4.3 Das Extrapolationsverfahren von Gragg

**Idee:** Anwendung der Richardsonextrapolation auf Mehrschrittverfahren.

#### Definition 3.80 (Mittelpunktverfahren)

Sei  $u_h : I_h \longrightarrow \mathbb{R}$  definiert durch  $u_h(x_i) = u_i$ ,  $i = 0, \dots, n$  mit

$$\left| \begin{array}{l} u_0 = y_0, \\ u_1 = u_0 + hf(x_0, u_0), \\ u_{i+1} - u_{i-1} = 2hf(x_i, u_i), \quad i = 1, \dots, n-1. \end{array} \right.$$

**Satz 3.81 (Satz von Gragg)**

Für genügend glattes  $f$  gilt für den globalen Fehler des Mittelpunktverfahrens:

$$u_j = \tilde{y}(x_j) + \sum_{i=1}^N h^{2i} (v_{2i}(x_j) + \underbrace{(-1)^j w_{2i}(x_j)}_{\text{"oszillierender Term"})} + \mathcal{O}(h^{2N+2})$$

mit  $n \in \mathbb{N}$  und  $v_{2i}, w_{2i}$  unabhängig von  $h$ .

(ohne Beweis)

Problem: Der oszillierende Term führt zu numerischer Auslöschung.

**Definition 3.82 (Graggsche Funktion)**

Setze

$$s_j := S(x_j, h) := \frac{1}{2}[u_j + u_{j-1} + h f(x_j, u_j)],$$

wobei  $u_j$  Lösung des Mittelpunktverfahrens ist.

Dann folgt aus Satz 3.81:

$$s_j = \tilde{y}(x_j) + h^2 [v_{21}(x_j) + \frac{1}{4} \tilde{y}''(x_j)] + \mathcal{O}(h^4)$$

D.h. die Graggsche Funktion "glättet" den oszillierenden Term.

**Algorithmus 3.83 (Algorithmus von Gragg)**

Seien  $f(x, y), x_0, y_0, H > 0$  und  $n \in \mathbb{N}$  gegeben.

Setze  $\bar{x} = x_0 + H, h := \frac{H}{n}, x_i := x_0 + ih$ , also  $x_n = \bar{x}$ .

Gesucht ist eine Näherung für  $\tilde{y}(\bar{x})$ .

Definiere dazu:

$$\begin{aligned} u_0 &= y_0, \\ u_1 &= u_0 + hf(x_0, u_0), \\ u_{i+1} &= u_{i-1} + 2hf(x_i, u_i). \end{aligned}$$

Dann ist

$$S(\bar{x}, h) = \frac{1}{2}[u_n - u_{n-1} + hf(x_n, u_n)]$$

eine gute Näherung von  $\tilde{y}(\bar{x})$ .

Extrapolationsschema:

Sei  $(n_i)_{i \in \mathbb{N}}$  eine Folge mit  $0 < n_0 < n_1 < n_2 < \dots$ , z.B. Rombergfolge  $n_i := 2^i$ .

Setze  $h_i = \frac{H}{n_i}$  für  $i \in \mathbb{N}_0$

Berechne:  $S(\bar{x}, h_0), S(\bar{x}, h_1), S(\bar{x}, h_2), \dots$

Mit dem Neville-Aitken Schema berechnet man dann

$$\begin{array}{ll} S(\bar{x}, h_0) = & T_{00} \searrow \\ S(\bar{x}, h_1) = & T_{10} \rightarrow T_{11} \\ \vdots & \vdots \quad \ddots \\ S(\bar{x}, h_i) = & T_{i0} \rightarrow T_{1i} \dots T_{ii} \end{array}$$

$$T_{ij} = \frac{-h_{i-j}T_{i,j-1} + h_i T_{i-1,j-1}}{h_i - h_{i-j}}$$

$T_{ii}$  ist Extrapolation in  $h = 0 \implies T_{ii} \approx \tilde{y}(\bar{x})$ .

### 3.4.4 Prädiktor-Korrektor-Verfahren

#### Definition 3.84

Sei  $\Phi^* = (\rho^*, \sigma^*)$  ein explizites lineares  $k$ -Schrittverfahren

$$\sum_{i=0}^k a_i^* u_{j+i} = h \sum_{i=0}^{k-1} b_i^* f_{j+i}$$

mit  $a_k^* = 1$ .  $\Phi^*$  heißt Prädiktorformel.

Sei  $\Phi = (\rho, \sigma)$  implizites lineares  $k$ -Schrittverfahren

$$\sum_{i=0}^k a_i u_{j+i} = h \sum_{i=0}^{k-1} b_i f_{j+i}$$

mit  $a_k = 1, b_k \neq 0$ .  $\Phi$  heißt Korrektorformel

Algorithmus:

$$(P) \quad u_{j+k}^{(0)} + \sum_{i=0}^{k-1} a_i^* u_{j+i} = h \sum_{i=0}^{k-1} b_i^* f_{j+i}$$

Für  $\mu = 1, \dots, l$ :

$$(E) \quad f_{j+k}^{(\mu-1)} := f(x_{j+k}, u_{j+k}^{(\mu-1)})$$

$$(C) \quad u_{j+k}^{(\mu)} + \sum_{i=0}^{k-1} a_i u_{j+i} = h b_k f_{j+k}^{(\mu-1)} + h \sum_{i=0}^{k-1} b_i f_{j+i}$$

$$(E) \quad \text{Setze } u_{j+k} := u_{j+k}^{(l)}; \quad f_{j+k} := f(x_{j+k}, u_{j+k}^{(l)})$$

Das Verfahren heißt  $P(EC)^l E$ -Verfahren.  $(P) \hat{=} \text{explizite Näherung}$ ,  $(EC)^l \hat{=} \text{Fixpunktiteration für das implizite Verfahren}$ .

#### Bemerkung 3.85

1) Die  $P(EC)^l E$ -Verfahren sind explizite, i. A. nichtlineare Mehrschrittverfahren.

2) Alternativ zum letzten E-Schritt kann man setzen:

$$u_{j+k} := u_{j+k}^{(l)}, \quad f_{j+k} := f(x_{j+k}, u_{j+k}^{(l-1)}) = f_{j+k}^{(l-1)}.$$

Dieses Verfahren heißt  $P(EC)^l$ -Verfahren und ist für die Praxis wichtiger.

#### Satz 3.86

Sei  $\Phi^*$  explizites  $k$ -Schrittverfahren mit Konsistenzordnung  $p^* \geq 1$  und  $\Phi$  sei implizites  $k$ -Schrittverfahren mit Konsistenzordnung  $p \geq 1$ . Dann gilt für das zugehörige  $P(EC)^l E$ -Verfahren:

- 1)  $P(EC)^l E$  ist konsistent mit Ordnung  $\bar{p} := \min\{p^* + l, p\}$
- 2) Erfüllt  $\rho$  die Wurzelbedingung, so ist das  $P(EC)^l E$ -Verfahren konvergent mit Ordnung  $\bar{p}$ , falls die Startwerte konvergent mit Ordnung  $\bar{p}$  sind.

- 3) Ist  $p < p^* + l$ , so hat das  $P(EC)^l E$ -Verfahren den Hauptfehlerkoeffizienten des Korrektorverfahrens.  
(ohne Beweis)

**Bemerkung 3.87**

- 1) Eine analoge Aussage zu Satz 3.86 gilt auch für die  $P(EC)^l$ -Verfahren.
- 2) In der Praxis wählt man häufig Adams-Bashforth (P) und Adams-Moulton (C) der gleichen Konsistenzordnung und führt nur  $l = 1$  Iterationen durch. Man profitiert von dem deutlich kleineren Hauptfehlerkoeffizienten.
- 3) Kennt man die Hauptfehlerkoeffizienten zu (P) und (C), so kann man analog zum Vorgehen bei ESV eine Schrittweitenkontrolle für die  $P(EC)^l E$  erhalten.

### 3.5 Steife Differentialgleichungen und Stabilitätsbegriffe

#### Beispiel 3.88

Betrachte AWP

$$\left| \begin{array}{l} y'(x) = q(y - g(x)) + g'(x) \\ y(a = 0) = y_0; \quad g_0 := g(a) \end{array} \right.$$

Sei  $q < 0$ ,  $|q| \gg 0$ ,  $|g'(x)| \ll 1$ .

Dann ist die exakte Lösung gegeben durch:

$$\tilde{y}(x) = g(x) + e^{qx}(y_0 - g_0).$$

Für  $\tilde{y}_j := \tilde{y}(x_j)$ ;  $g_j := g(x_j)$  folgt:

$$\tilde{y}_{j+1} - g_{j+1} = \underbrace{e^{qh}}_{<1} (\tilde{y}_j - g_j).$$

⇒ Für die exakte Lösung wird der Abstand von  $\tilde{y}$  und  $g$  monoton kleiner.

Ziel: Das numerische Verfahren soll dieses Verhalten reproduzieren.

a) Euler explizit: Startwert  $u_0 = y_0$  und  $h > 0$ :

$$\Rightarrow u_{j+1} - g_{j+1} = (1 + hq)(u_j - g_j) + O(h^2)$$

Bei der Näherung erhält man nur dann eine Dämpfung, wenn  $|1 + hq| < 1 \Rightarrow$  Bedingung an  $h$  ( $h < -1/q$ ).

b) Euler implizit: Startwert  $u_0 = y_0$  und  $h > 0$ :

$$\Rightarrow u_{j+1} - g_{j+1} = \underbrace{\frac{1}{1 - hq}}_{<1, \forall h > 0} (u_j - g_j) + O(h^2)$$

⇒ Immer Dämpfung, unabhängig von  $h$ !

#### Allgemeine Situation 3.89

Seien  $u$  und  $v$  Lösungen des Systems

$$y' = f(x, y) \text{ im } \mathbb{R}^n$$

mit  $u(a) = u_0$ ,  $v(a) = v_0$ . Dann ist:

$$u'(x) - v'(x) = J(x)(u(x) - v(x))$$

mit

$$J(x) = \int_0^1 f_y(x, tu(x) + (1 - t)v(x)) dt.$$

[ Für  $n = 1$ , z.B.  $f(x, y) = qy$ ,  $v(x) = g(x)$  (siehe Beispiel 3.85) ]

**Definition 3.90 (Steife Differentialgleichung)**

Das AWP  $y' = f(x, y)$  heißt steife Differentialgleichung rechts von  $a$ , falls gilt:

1)  $\lambda$  EW von  $J(x) \implies \operatorname{Re} \lambda < 0$ .

2) Für  $n \geq 2$  gilt:

$\exists$  EW  $\lambda_1$  mit  $\lambda_1 < 0$  und  $|\lambda_1| \gg 0$  und  $\exists$  EW  $\lambda_2$  mit  $|\lambda_2| \ll |\lambda_1|$ .

**Beispiel 3.91**

$y_i$   $i = 1, 2, 3$  seien Konzentrationen von Substanzen zur Zeit  $t$ ,  $k_i$  seien Reaktionsraten:

$$\begin{aligned} y'_1 &= -k_1 y_1 + k_2 y_2 y_3, \\ y'_2 &= k_1 y_1 - k_2 y_2 y_3 - k_3 y_2^2, \\ y'_3 &= k_3 y_2^2. \end{aligned}$$

Seien  $y_1(0) = 1$ ,  $y_2(0) = y_3(0) = 0$ .

Dann folgt für die EW von  $J(x)$

$x$	$\lambda_1$	$\lambda_2$	$\lambda_3$	
0	0	0	-0,04	
$10^{-2}$	0	-0,36	-2180	$\implies$ "sehr steifes System"
100	0	-0,0048	-4240	
$\infty$	0	0	$-10^4$	

**Definition 3.92 ((Absolute Stabilität))**

Sei  $y' = qy$  Testgleichung. Sei  $\Phi = (\rho, \sigma)$  lineares  $k$ -Schrittverfahren, d.h.

$$(*) \quad \sum_{i=0}^k (a_i - hqb_i)u_{j+i} = 0 ; \quad j = k, \dots, n-k$$

und  $u_0, \dots, u_{k-1}$  gegeben.

Definiere das Stabilitätspolynom

$$\rho_t(\lambda) = \rho(\lambda) - t \cdot \sigma(\lambda)$$

D.h.  $\rho_t(\lambda)$  ist charakteristisches Polynom von  $(*)$  mit  $t = hq$ .

$\Phi$  heißt absolut stabil für  $t \in \mathbb{C}$  falls gilt:

$$t \in D_s := \{t \in \mathbb{C} \mid \rho_t(\lambda) = 0 \text{ für ein } \lambda \in \mathbb{C} \implies |\lambda| < 1\}.$$

$D_s$  heißt Stabilitätsgebiet von  $\Phi$ .

Für ESV  $\Phi = \varphi$  der Form  $u_{j+1} = g(t)u_j$  ist das Stabilitätspolynom gegeben durch

$$\rho_t(\lambda) = \lambda - g(t).$$

**Beispiel 3.93 (Stabilitätsgebiete für explizite Runge-Kutta-Verfahren)**

Siehe Folie aus Deuflhard, Bornemann [4, Seite 230].

**Beispiel 3.94**

Das Verfahren von Milne-Simpson ist asymptotisch stabil, aber nicht absolut stabil. Dies wurde in Beispiel 3.73 gezeigt.

**Weitere Forderung an "gute" numerische Verfahren:**

- A) Ein fallender Exponentialterm der Lösung von  $y' = qy$  soll stets (für alle  $h$ ) fallend genähert werden

Dies führt auf den Begriff der A-Stabilität

**Definition 3.95 ((A-Stabilität))**

$\Phi$  heißt A-stabil, gdw.  $D_s \supset H_- = \{t \in \mathbb{C} \mid \operatorname{Re} t < 0\}$ .

Abschwächungen dazu sind:

$$\begin{aligned} A(\alpha)\text{-Stabilität:} &\iff D_s \supset \{t \in \mathbb{C} \mid |\arg(-t)| < a\} \\ A(0)\text{-Stabilität:} &\iff D_s \supset \mathbb{R}^- \end{aligned}$$

**Satz 3.96**

Sei  $\Phi = (\rho, \sigma)$  lineares MSV mit  $k \geq 2$  und  $\Phi$  sei A-stabil. Dann gilt

- 1)  $\Phi$  ist implizit,
- 2)  $\Phi$  hat Konvergenzordnung 2.

Das Trapezverfahren hat unter allen A-stabilen MSV die kleinste Fehlerschranke.

(ohne Beweis)

**Satz 3.97**

- 1) Die BDF-k Verfahren sind A-stabil für  $1 \leq k = s \leq 2$ .
- 2) Implizite Runge-Kutta Verfahren sind A-stabil.

(ohne Beweis)

### 3.6 Numerische Lösung von Randwertproblemen

#### Beispiel 3.98 (Wärmeleitender Stab)

Gegeben: Stab  $\hat{=} [a, b]$

Wärmequellendichte  $f(x)$ ,  $x \in [a, b]$

Randwerte:  $y(a) = y_l, y(b) = y_r$

Wärmeleitfähigkeitskoeffizient  $k(x)$ ,  $x \in [a, b]$

Gesucht: Temperatur  $y(x)$  mit

$$(*) \quad \begin{cases} -(k(x)y'(x))' = f(x) & \forall x \in (a, b), \\ y \in C^2((a, b)) \cap C^0([a, b]), \\ y(a) = u_l, y(b) = u_r. \end{cases}$$

Formulierung als System 1. Ordnung: Setze  $y_1 = y(x)$ ,  $y_2(x) = y'(x)$

$$(*) \implies \begin{cases} y_1'(x) = y_2(x), \\ y_2'(x) = -\frac{k'(x)}{k(x)}y_2(x) - \frac{f(x)}{k(x)} \end{cases}$$

mit  $y_1(a) = u_l, y_1(b) = u_r$ .

#### Definition 3.99 (Lineare Randwertprobleme)

Seien  $B_a, B_b \in \mathbb{R}^{n \times n}$ ,  $A \in C^0(I, \mathbb{R}^{n \times n})$ ,  $I := [a, b]$ ,  $f \in C^0(I, \mathbb{R}^n)$ ,  $g \in \mathbb{R}^n$ .

Dann heißt  $y : I \rightarrow \mathbb{R}^n$  Lösung des linearen Randwertproblems (RWP), falls gilt:

- 1)  $y \in C^1(I, \mathbb{R}^n)$ ,
- 2)  $y'(x) = Ay + f$  in  $I$ ,
- 3)  $B_a y(a) + B_b y(b) = g$ .

#### Beispiel 3.100

Die Differentialgleichung

$$y''(x) + y(x) = 0, \quad x \in [0, \pi] \iff \begin{cases} y_1'(x) - y_2(x) = 0 \\ y_2'(x) + y_1(x) = 0 \end{cases}$$

hat die allgemeine Lösung  $y(x) = c_1 \sin(x) + c_2 \cos(x)$ .

Für verschiedene Randbedingungen ergibt sich unterschiedliches Verhalten:

- 1)  $y(0) = y(\pi)$ ;  $y'(0) = y'(\pi)$   $\implies$  ergibt die eindeutige Lösung  $y \equiv 0$ .
- 2)  $y(0) = y(\pi) = 0$   $\implies$  ergibt unendlich viele Lösungen  $y(x) = c_1 \sin(x)$ .
- 3)  $y(0) = 0, y(\pi) = 1$   $\implies$  ergibt keine Lösung.

Ziel: Bedingung für eindeutige Lösbarkeit!

**Definition 3.101 (Fundamentalsystem)**

Für

$$(*) \quad y' = Ay + f \quad \text{in } I$$

definiere das Fundamentalsystem  $\{y_1, \dots, y_n\}$ ,  $y_i : I \rightarrow \mathbb{R}^n$ , durch

- 1)  $y_i \in C^1(I, \mathbb{R}^n)$ ,
- 2)  $y'_i = Ay_i$  in  $I$ ,
- 3)  $y_i(a) = e_i$ , mit  $e_i$   $i$ -ter Einheitsvektor im  $\mathbb{R}^n$ .

Die Matrix

$$Y(x) := \begin{pmatrix} y_{11}(x) & \dots & y_{n1}(x) \\ \vdots & \ddots & \vdots \\ y_{1n}(x) & \dots & y_{nn}(x) \end{pmatrix}$$

heißt Fundamentalmatrix.

Ist  $y_0 \in C^1(I, \mathbb{R}^n)$ ,  $y_0(a) = 0$  eine spezielle Lösung von  $(*)$ , so lässt sich jede Lösung von  $(*)$  darstellen als

$$y(x) = y_0(x) + Y(x) \cdot s$$

mit einem Vektors  $s \in \mathbb{R}^n$ .**Satz 3.102 (Existenz und Eindeutigkeit linearer RWPe)**

Die folgenden Aussagen sind äquivalent:

- 1) (RWP) besitzt eine eindeutige Lösung.
- 2) Das zugehörige homogene RWP mit  $f = 0$ ,  $g = 0$  besitzt nur die triviale Lösung.
- 3) Die Matrix  $B_a + B_b Y(b) \in \mathbb{R}^{n \times n}$  ist regulär.

Beweis: Seien  $y_0(x)$  und  $Y(x)$  wie in Definition 3.98 definiert.Dann gilt  $y_0(a) = 0$  und  $Y(a) = I$ .Also ist  $y(x) = y_0(x) + Y(x)s$  genau dann Lösung von (RWP), wenn gilt

$$[B_a + B_b Y(b)]s = g - B_b y_0(b)$$

Also ist  $s \in \mathbb{R}^n$  genau dann eindeutig bestimmt, wenn 2) oder 3) gelten. □

### 3.6.1 Sturm-Liouville Probleme

#### Definition 3.103 (Sturm-Liouville Probleme)

Seien  $p \in C^1(I)$ ,  $q, f \in C^0([a, b])$ ,  $I = [a, b]$  gegeben mit

$$q(x) \geq 0 \quad \forall x \in I, \quad p(x) \geq p_0 > 0 \quad \forall x \in I$$

Dann heißt  $y \in C^2((a, b)) \cap C^0([a, b]) \cap C^1((a, b))$  Lösung des Sturm-Liouville Problems (SLP) mit homogenen Dirichlet und Neumann Randwerten, falls gilt:

$$(SLP) \quad \begin{cases} -(p(x)y'(x))' + q(x)y(x) = f(x) & \forall x \in I \\ y(a) = 0; \quad y'(b) = 0 \end{cases}$$

Bemerkung: Allgemein Randbedingungen sind:  $\begin{cases} \alpha_1 y'(a) + \alpha_0 y(a) = g_a \\ \beta_1 y'(b) + \beta_0 y(b) = g_b \end{cases}$

#### Definition 3.104 (Variationsproblem)

Für  $v \in X := \{u \in C^1([a, b]) \mid u(a) = 0\}$  definiere das sogenannte Energiefunktional  $I : X \rightarrow \mathbb{R}$  durch

$$I(v) = \frac{1}{2} \int_a^b p(x)(v'(x))^2 dx + \frac{1}{2} \int_a^b q(x)(v(x))^2 dx - \int_a^b f(x)v(x) dx.$$

$y \in X$  heißt Lösung des mit Variationsproblems, falls gilt

$$I(y) = \inf_{v \in X} I(v).$$

#### Lemma 3.105 (Eulergleichung und natürliche Randbedingung)

Ist  $y \in X$ , so dass

$$I(y) \leq I(v) \quad \forall v \in X,$$

so gilt  $\forall \varphi \in X$ :

$$(*) \quad \int_a^b p y' \varphi' + q y \varphi = \int_a^b f \varphi$$

(\*) heißt schwache Formulierung der Eulergleichung.

Ist zusätzlich  $y \in C^2((a, b))$ , so folgt weiter:

$$(**) \quad \begin{cases} -(p y')' + q y = f & \text{in } I, \\ y(a) = 0; \quad y'(b) = 0. \end{cases}$$

Beweis:

Teil 1: Sei  $y \in X$  mit  $I(y) \leq I(v) \quad \forall v \in X$ .

$$\implies I(y) \leq I(y + \varepsilon \varphi) \quad \forall \varepsilon \in \mathbb{R}; \quad \forall \varphi \in X.$$

$$\implies G(0) \leq G(\varepsilon) \quad \forall \varepsilon \in \mathbb{R}, \text{ wobei } G(\varepsilon) := I(y + \varepsilon \varphi).$$

Da  $G$  differezierbar in  $\varepsilon$  ist, folgt  $G'(0) = 0$ .

Es ist

$$\begin{aligned}
G(\varepsilon) &= \frac{1}{2} \int_a^b p(y' + \varepsilon\varphi')^2 + q(y + \varepsilon\varphi)^2 - 2f(y + \varepsilon\varphi) \\
&= I(y) + \varepsilon \int_a^b py'\varphi' + qy\varphi - f\varphi + \varepsilon^2(I(\varphi) + \int_a^b f\varphi) \\
\implies G'(0) &= \int_a^b py'\varphi' + qy\varphi - f\varphi \stackrel{!}{=} 0, \quad \forall \varphi \in X.
\end{aligned}$$

Teil 2: Ist  $y \in C^2((a, b))$ , so folgt mit partieller Integration

$$\int_a^b py'\varphi' = - \int_a^b (py')'\varphi + [py'\varphi]_a^b.$$

Einsetzen in  $(*)$  ergibt

$$(\dagger) \quad - \int_a^b (py')'\varphi + \int_a^b qy\varphi - f\varphi + [py'\varphi]_a^b = 0.$$

Also folgt für alle  $\varphi \in C_0^1((a, b))$ :

$$\int_a^b [-(py')' + qy - f]\varphi = 0.$$

$$\implies -(py')' + qy = f.$$

Durch Einsetzen in  $(\dagger)$  erhält man für alle  $\varphi \in X$ :

$$0 = [py'\varphi]_a^b = p(b)y'(b)\varphi(b) - p(a)y'(a)\underbrace{\varphi(a)}_{=0} = p(b)y'(b)\varphi(b)$$

Wähle  $\varphi(b) \neq 0 \implies$ , so folgt  $y'(b) = 0$ , da  $p(b) > 0$ .  $y'(b) = 0$  heißt natürliche Randbedingung.

Nächstes Ziel: Existenz einer schwachen Lösung, d.h.  $\square$

$$\exists y \in X \text{ mit } I(y) = \inf_{v \in X} I(v).$$

Dazu benötigen wir folgenden Hilfssatz.

### Satz 3.106 (Poincaré Ungleichung)

Für alle  $v \in X$  gilt mit einer Konstanten  $c_p \leq \frac{1}{2}(b-a)^2$ :

$$\int_a^b (v(x))^2 dx \leq c_p \int_a^b (v'(x))^2 dx$$

*Beweis:* Es ist  $|v(x)| = |v(x) - \underbrace{v(a)}_{=0}| \leq \int_a^x |v'(s)| ds$ .

$$\implies (v(x))^2 \leq \left( \int_a^x |v'(s)| ds \right)^2 \leq (x-a) \int_a^x |v'(s)|^2 ds.$$

$$\implies \int_a^b (v(x))^2 dx \leq \int_a^b (x-a) \int_a^b |v'(s)|^2 ds = \frac{1}{2}(b-a)^2 \int_a^b |v'(s)|^2 ds. \quad \square$$

### Lemma und Definition 3.107

Definiere auf  $X$  die Norm

$$\|v\|_X := \left( \int_0^1 (v(x))^2 + (v'(x))^2 dx \right)^{\frac{1}{2}}.$$

Sei  $(v_n)_{n \in \mathbb{N}}$ ,  $v_n \in X$  eine Minimalfolge, d.h.

$$\lim_{n \rightarrow \infty} I(v_n) = \inf_{v \in X} I(v).$$

Dann ist  $(v_n)_{n \in \mathbb{N}}$  eine Cauchyfolge in  $X$ , d.h.

$$\|v_n - v_m\|_X \rightarrow 0 \quad (n, m \rightarrow \infty).$$

*Beweis:* Setze  $d := \inf_{v \in X} I(v)$ .

1. Schritt: Zeige  $d > -\infty$ : Es ist

$$\begin{aligned} I(v) &\stackrel{\text{Vor. in (SLP)}}{\geq} \frac{p_0}{2} \int_a^b (v'(x))^2 dx - \left( \int_a^b (f(x))^2 \right)^{\frac{1}{2}} \left( \int_a^b (v(x))^2 \right)^{\frac{1}{2}} \\ &\geq \frac{p_0}{2} \int_a^b (v'(x))^2 dx - \underbrace{\sqrt{c_p} \left( \int_a^b (f(x))^2 \right)^{\frac{1}{2}}}_{=:a} \underbrace{\left( \int_a^b (v'(x))^2 \right)^{\frac{1}{2}}}_{=:b}. \end{aligned}$$

Mit der Ungleichung  $|ab| \leq \frac{\delta}{2} a^2 + \frac{1}{2\delta} b^2 \quad \forall a, b \in \mathbb{R}$  folgt

$$I(v) \geq \left( \frac{p_0}{2} - \frac{\delta}{2} \right) \int_a^b (v'(x))^2 dx - \frac{\sqrt{c_p}}{2\delta} \|f\|_{L^2(a,b)}^2.$$

Für  $\delta = p_0$  folgt:  $I(v) \geq -\frac{\sqrt{c_p}}{2p_0} \|f\|_{L^2(a,b)}^2$ . Also folgt  $d > -\infty$ , da  $f \in C^0([a, b])$ .

2. Schritt: Sei  $(v_n)_{n \in \mathbb{N}}$  Folge in  $X$  mit  $\lim_{n \rightarrow \infty} I(v_n) = d > -\infty$ .

Zeige:  $(v_n)$  ist Cauchyfolge in  $X$ .

Notation: Definiere die Bilinearform  $B : X \times X \rightarrow \mathbb{R}$  durch

$$B(v, w) := \int_a^b p v' w' + \int_a^b q v w.$$

Dann gilt  $B(v, v) = \int_a^b p (v')^2 + \int_a^b q v^2 \geq p_0 \int_a^b (v'(x))^2 dx$ .

Aufgrund der Poincaré Ungleichung gilt weiter:

$$\begin{aligned} B(v, v) &\geq p_0 \left( \int_a^b (v'(x))^2 dx + c_p \int_a^b (v'(x))^2 dx \right) \frac{1}{1+c_p} \\ &\geq \frac{p_0}{1+c_p} \|v\|_X^2. \end{aligned}$$

Damit folgt:

$$\begin{aligned} \frac{p_0}{1+c_p} \|v_n - v_m\|_X &\leq B(v_n - v_m, v_n - v_m) \\ &\stackrel{\text{Parallelogrammidentität}}{=} 2B(v_n, v_n) + 2B(v_m, v_m) - 4B\left(\frac{v_n+v_m}{2}, \frac{v_n+v_m}{2}\right) \\ &\stackrel{I(v)=\frac{1}{2}B(v,v)-\int_a^b f v}{=} 4[I(v_n) + I(v_m) - 2I\left(\frac{v_n+v_m}{2}\right)] \\ &\leq 4[I(v_n) + I(v_m) - 2d] \\ &\rightarrow 4[d + d - 2d] = 0 \quad \text{für } n, m \rightarrow \infty. \end{aligned}$$

Also ist  $(v_n)_{n \in \mathbb{N}}$  Cauchyfolge.

**Problem:** Der Raum  $(X, \|\cdot\|_X)$  ist nicht vollständig! □

**Lösung:** Vervollständige  $X$  bzgl. der Norm  $\|\cdot\|_X$  und erhalte vollständigen Raum  $\bar{X}^{\|\cdot\|_X}$ .

**Beispiel aus der Analysis III:** Ist  $Y = C^0([a, b])$ , so ist  $\bar{Y} = L^2((a, b))$  die Vervollständigung von  $Y$  bzgl.  $\|v\|_Y = \left(\int_a^b v^2\right)^{\frac{1}{2}}$ .

Um  $\bar{X}$  zu charakterisieren, benötigen wir den Begriff der schwachen Ableitung.

**Definition 3.108 (Schwache Ableitung)**

$v \in L^1(a, b)$  besitzt eine schwache Ableitung  $k$ -ter Ordnung  $D^k v \in L^1(a, b)$ , falls für alle  $\varphi \in C_0^\infty(a, b)$  gilt:

$$\int_a^b v(x) \varphi^{(k)}(x) dx = (-1)^k \int_a^b (D^k v)(x) \varphi(x) dx.$$

**Beispiel 3.109**

Sei  $v(x) = |x|$  mit  $x \in [-1, 1]$ .

Dann gilt:  $D^1(v)(x) = \text{sign}(x)$ , denn für  $\varphi \in C_0^\infty(-1, 1)$  gilt:

$$\begin{aligned} \int_{-1}^1 v(x) \varphi'(x) dx &= \int_{-1}^0 (-x) \varphi'(x) dx + \int_0^1 x \varphi(x) dx \\ &= [(-x) \varphi(x)]_{-1}^0 + \int_{-1}^0 \varphi(x) dx + [x \varphi(x)]_0^1 - \int_0^1 \varphi(x) dx \\ &= - \int_{-1}^0 (-1) \varphi(x) dx - \int_0^1 \varphi(x) dx \\ &= - \int_{-1}^1 \text{sign}(x) \varphi(x) dx. \end{aligned}$$

↔ Allgemein gilt in einer Raumdimension: Stückweise differenzierbare Funktionen, die global stetig sind, sind schwach differenzierbar. Die schwache Ableitung ist durch die stückweise definierte Ableitung gegeben.

**Satz 3.110 (Eindimensionale Sobolevräume)**

1) Der Sobolevraum

$$\begin{aligned} H^m(a, b) &:= \{v \in L^2(a, b) \mid v \text{ hat schwache Ableitungen} \\ &\quad D^k v \in L^2(a, b) \ \forall k = 0, \dots, m\} \end{aligned}$$

ist mit dem Skalarprodukt

$$(u, v)_{H^m(a, b)} := \sum_{k=0}^m \int_a^b D^k u D^k v$$

ein Hilbertraum. Durch  $\|u\|_{H^m(a, b)} := \sqrt{(u, u)_{H^m(a, b)}}$  erhalten wir eine Norm auf  $H^m(a, b)$ .

2)  $u \in H^m(a, b)$  ist fast überall gleich einer Funktion  $\tilde{u} \in C^{m-1}([a, b])$  und es ist

$$\|\tilde{u}\|_{C^{m-1}([a, b])} \leq c \|u\|_{H^m(a, b)}.$$

3) Zu  $u \in H^m(a, b)$  gibt es eine Folge  $(u_j)_{j \in \mathbb{N}}$ ,  $u_j \in C^m([a, b])$ , so dass

$$\|u - u_j\|_{H^m(a, b)} \longrightarrow 0 \quad (j \rightarrow \infty).$$

Ist  $\tilde{u}(a) = 0$ , so kann man  $u_j$  so wählen, dass  $u_j(a) = 0$  ist.

*Beweis:* z.B [Alt. Lineare Funktionalanalysis, Springer, 1992]. □

**Folgerung 3.111**

Die Vervollständigung von  $X$  bzgl.  $\|\cdot\|_X$  ist gegeben durch

$$\bar{X} = \{v \in H^1(a, b) \mid v(a) = 0\}.$$

**Satz 3.112 (Existenz und Eindeutigkeit einer schwachen Lösung von (SLP))**

Seien die Voraussetzungen aus Definition 3.100 erfüllt. Dann gibt es genau ein  $y \in \bar{X}$ , so dass  $\forall \varphi \in \bar{X}$  gilt:

$$\int_a^b py'\varphi' + \int_a^b qy\varphi = \int_a^b f\varphi.$$

*Beweis:*

Existenz: Sei  $(v_n)_{n \in \mathbb{N}}$  Minimalfolge in  $\bar{X}$  (anstelle von  $X$ ).

Analog zu Lemma 3.104 folgern wir, dass  $(v_n)_{n \in \mathbb{N}}$  Cauchyfolge in  $\bar{X}$  ist.

Da  $\bar{X}$  vollständig ist (Satz 3.107)  $\exists y \in \bar{X}$  mit  $\|v_n - y\|_{\bar{X}} \rightarrow 0$  ( $n \rightarrow \infty$ ).

Zeige:  $I(y) = d$  ( $= \inf_{v \in \bar{X}} I(v)$ ).

Es ist

$$\begin{aligned} |I(y) - I(v_n)| &= \\ &= \left| \frac{1}{2} \int_a^b p((y')^2 - (v'_n)^2) + q(y^2 - v_n^2) - \int_a^b f(y - v_n) \right| \\ &\leq \frac{1}{2} \|p\|_{\infty} \int_a^b |y'^2 - v_n'^2| + \frac{1}{2} \|q\|_{\infty} \int_a^b |y^2 - v_n^2| + \int_a^b |f| |y - v_n| \\ &\leq \frac{1}{2} \|p\|_{\infty} \int_a^b |y' - v'_n| (|y'| + |v'_n|) + \frac{1}{2} \|q\|_{\infty} \int_a^b |y - v_n| (|y| + |v_n|) \\ &\quad + \int_a^b |f| |y - v_n| \\ &\leq \underbrace{\left[ \left( \frac{1}{2} \|p\|_{\infty} + \frac{1}{2} \|q\|_{\infty} \right) (\|y\|_{\bar{X}} + \|v_n\|_{\bar{X}}) + \|f\|_{L^2(a,b)} \right]}_{\leq C < \infty} \underbrace{\|y - v_n\|_{\bar{X}}}_{\rightarrow 0 \ (n \rightarrow \infty)} \end{aligned}$$

Also folgt  $I(y) = \lim_{n \rightarrow \infty} I(v_n) = d$  und damit die Existenz der Lösung.

Eindeutigkeit: Seien  $y_1, y_2$  Lösungen, so folgt für  $v = y_1 - y_2$ :

$$\int_a^b p v' \varphi' + \int_a^b q v \varphi \quad \forall \varphi \in \bar{X}.$$

Wähle  $\varphi = v$ :

$$\begin{aligned} \xrightarrow{3.106} 0 &= B(v, v) \geq \frac{p_0}{1 + c_p} \|v\|_X \implies \|v\|_X = 0 \\ \implies v &= 0 \implies y_1 = y_2. \end{aligned}$$

□

**Satz 3.113 (A priori Abschätzung)**Für jede schwache Lösung  $y \in \bar{X}$  von (SLP) gilt:

1)  $\|y'\|_{L^2(a,b)} \leq C_1 \|f\|_{L^2(a,b)}.$

2) Ist  $y \in H^2(a,b)$ , so gilt

$$\|y''\|_{L^2(a,b)} \leq C_2 \|f\|_{L^2(a,b)}.$$

Dabei sind  $C_1 = \frac{\sqrt{c_p}}{p_0}$ ,  $C_2 = \frac{\sqrt{3}}{p_0} \left( \frac{\sqrt{c_p}}{p_0} \|p'\|_\infty + \frac{c_p}{p_0} \|q\|_\infty + 1 \right)$ *Beweis:* Ü.A.

□

**3.6.2 Das Ritz-Galerkin Vefahren****Definition 3.114 (Ritz-Galerkin Verfahren für (SLP))**Sei  $X := \{v \in H^1(a,b) \mid v(a) = 0\}$  und  $I : X \rightarrow \mathbb{R}$  das Energiefunktional aus Definition 3.101. Sei  $X_h \in X$  ein endlichdimensionaler Teilraum. Dann heißt  $u_h \in X_h$  Ritz-Galerkin Approximation der schwachen Lösung  $y \in X$  von (SLP), g.d.w

$$I(u_h) = \inf_{v_h \in X_h} I(v_h).$$

*Idee:* Minimierung von  $I$  auf endlichen Teilräumen.**Folgerung 3.115 (Schwache diskrete Differentialgleichung)**1) Da  $X_h \in X$  ist, folgt  $I(u) \leq I(u_h)$ .2) Ist  $u_h \in X_h$  Ritz-Galerkin Approximation von (SLP), so gilt:

$$(D - SLP) \quad B(u_h, \varphi_h) = \int_a^b f \varphi_h, \quad \forall \varphi_h \in X_h$$

mit  $B(u, v) := \int_a^b p u' v' + \int_a^b q u v$ .*Beweis:* Analog zum kontinuierlichen Fall in Lemma 3.102.

□

**Bemerkung 3.116 (Formulierung von (D-SLP) als lineares Gleichungssystem)**Seien  $N := \dim(X_h)$  und  $\{\varphi_1, \dots, \varphi_N\}$  eine Basis von  $X_h$ . Dann lässt sich  $u_h$  darstellen als

$$u_h(x) = \sum_{j=1}^N u_j \varphi_j(x)$$

mit Koeffizienten  $u_j \in \mathbb{R}$ ,  $j = 1, \dots, N$ .

Damit ist (D-SLP) äquivalent zu

$$\sum_{j=1}^N B(\varphi_j, \varphi_k) u_j = \int_a^b f \varphi_k \quad \forall k = 1, \dots, N.$$

Mit den Definitionen  $u := (u_1, \dots, u_N)$ ;  $S_{kj} := B(\varphi_j, \varphi_k)$ ,  $k, j = 1, \dots, N$ ;  $b_k := \int_a^b f \varphi_k$ ;  $b := (b_1, \dots, b_N)$  ist somit (D-SLP) äquivalent zu dem linearen Gleichungssystem

$$\mathbf{S}\mathbf{u} = \mathbf{b}$$

Die Matrix  $S$  wird "Steifigkeitsmatrix" genannt.

**Satz 3.117 (Abstrakte Fehlerabschätzung)**

Seien  $X$  ein normierter Raum,  $X_h \subset X$  ein Teilraum. Weiter sei  $f \in X' = L(X; \mathbb{R})$  ein lineares Funktional auf  $X$ .

Gilt dann

$$\begin{aligned} u \in X : B(u, \varphi) &= f(\varphi), \quad \forall \varphi \in X, \\ u_h \in X_h : B(u_h, \varphi_h) &= f(\varphi_h) \quad \forall \varphi_h \in X_h \end{aligned}$$

mit einer Bilinearform  $B : X \times X \rightarrow \mathbb{R}$  die koerziv ist, d.h.

$$\exists C_0 > 0, \text{ so dass } \forall \varphi \in X : B(\varphi, \varphi) \geq C_0 \|\varphi\|_X^2$$

und stetig, d.h.

$$\exists C_1 \geq 0, \text{ so dass } \forall \varphi, \psi \in X : |B(\varphi, \psi)| \leq C_1 \|\varphi\|_X \cdot \|\psi\|_X,$$

so gilt die Fehlerabschätzung

$$\|u - u_h\|_X \leq \frac{C_1}{C_0} \inf_{v_h \in X_h} \|u - v_h\|_X$$

und es ist

$$B(u - u_h, \varphi_h) = 0 \quad \forall \varphi_h \in X_h. \quad \text{"Galerkin-Orthogonalität"}$$

*Beweis:* Wegen  $X_h \subset X$ , folgt  $\forall \varphi_h \in X_h$   
 $B(u, \varphi_h) = f(\varphi_h)$  und  $B(u_h, \varphi_h) = f(\varphi_h)$   
 $\implies B(u - u_h, \varphi_h) = 0 \quad \forall \varphi_h \in X_h$  (Galerkin-Orthogonalität  $\checkmark$ ).

Mit Koerzivität und Stetigkeit von  $B$  folgt nun:

$$\begin{aligned} C_0 \|u - u_h\|_X^2 &\leq B(u - u_h, u - u_h) \\ &= B(u - u_h, u) - \underbrace{B(u - u_h, u_h)}_{=0} \\ &\stackrel{v_h \in X_h}{=} B(u - u_h, u) - \underbrace{B(u - u_h, v_h)}_{=0} \\ &= B(u - u_h, u - v_h) \\ &\stackrel{\text{stetig}}{\leq} C_1 \|u - u_h\|_X \|u - v_h\|_X \end{aligned}$$

Also folgt:  $\|u - u_h\|_X \leq \frac{C_1}{C_0} \|u - v_h\|_X \quad \forall v_h \in X_h$ . □

**Bemerkung 3.118**

Für (SLP) ist

$$B(u, v) = \int_a^b p u' v' + \int_a^b q u v$$

und

$$f(v) := \int_a^b fv.$$

Ist  $X := \{v \in H^1(a, b) \mid v(a) = 0\}$ , so ist  $f \in X'$ , falls  $f \in L^2(a, b)$ , da  $\forall v \in X$  gilt

$$|f(v)| \leq \|f\|_{L^2(a,b)} \|v\|_{L^2(a,b)} \leq \|f\|_{L^2(a,b)} \|v\|_X.$$

### Beispiel 3.119 (Wahl von $X_h$ )

1) Polynomapproximation:  $X_h = \mathbb{P}_k$  ( $\hat{=}$  Polynome von Grad  $\leq k$ )  
 $\implies N = \dim(X_h) = k + 1$ .

2) Eigenräume:  $X_h := \text{span}\{\varphi_1, \dots, \varphi_N\}$ , wobei  $\varphi_1, \dots, \varphi_N$  die ersten  $N$  normierten Eigenfunktionen des Operators

$$Lu := -(pu')' + qu, \quad u(a) = 0, \quad u'(b) = 0$$

sind, d.h.

$$L\varphi_j = \lambda_j \varphi_j; \quad 0 < \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_N.$$

3) Stückweise Polynome:  $X_h = \{\varphi_h \in C^0([a, b]) \mid \varphi_h(a) = 0, \varphi_h|_{[x_j, x_{j+1}]} \in \mathbb{P}_k\}$  wobei  $a = x_0 < x_1 < \dots < x_n = b$  eine Zerlegung von  $[a, b]$  ist.  
 $\implies$  Finite Elemente!

### 3.6.3 Finite Elemente Verfahren

#### Definition 3.120 (Finite Elemente Verfahren)

1) Sei  $I := [a, b]$  und  $I_h := \{x_0, \dots, x_n\} \subset I$  ein Gitter mit  $x_0 = a$ ,  $x_n = b$ ,  $x_{j+1} = x_j + h_j$ ,  $h_j > 0$ . Definiere  $I_j := (x_j, x_{j+1})$  und  $h := \max_{j=0, \dots, n-1} h_j$ . Für festes  $k \in \mathbb{N}$  wählen wir

$$X_h := \{\varphi_h \in C^0([a, b]) \mid \varphi_h(a) = 0, \varphi_h \downarrow |_{I_j} \in \mathbb{P}_k \ \forall j = 0, \dots, n-1\}.$$

Ein  $u_h \in X$  heißt Finite Elemente Approximation von (SLP), falls für alle  $\varphi_h \in X_h$  gilt:

$$B(u_h, \varphi_h) = f(\varphi_h) \quad \forall \varphi_h \in X_h.$$

Dabei sind  $B, f$  wie in Bemerkung 3.115 definiert.

2) (Finite Elemente Basis für  $k = 1$ )

Sei  $k = 1$ . Für  $j = 1, \dots, n$  sei  $\varphi_j \in X_h$  definiert durch

$$\varphi_j(x_i) = \delta_{ij} \quad \forall x_i \in I_h.$$

D.h. für  $j = 1, \dots, n$  ist

$$\varphi_j(x) = \begin{cases} \frac{x-x_{j-1}}{h_{j-1}} & x \in I_{j-1} \\ \frac{x_{j+1}-x}{h_j} & x \in I_j \\ 0 & \text{sonst} \end{cases}.$$

Es ist  $\text{supp}(\varphi_j) = I_j \cup I_{j-1}$  und somit folgt für die Steifigkeitsmatrix  $S_{kj} := B(\varphi_j, \varphi_k) = 0$ , falls  $|j - k| \geq 2$ .

3) (Fehlerabschätzung für  $k = 1$ )

Sei  $k = 1$ . Definiere Interpolierende  $\tilde{u}_h \in X_h$  zu  $y \in X$  durch

$$\tilde{u}_h(x_j) := y(x_j) \quad \forall j = 0, \dots, n \implies \tilde{u}_h(x) = \sum_{j=1}^n y(x_j) \varphi_j(x).$$

Dann gilt die Fehlerabschätzung (nach Satz 3.114)

$$\|y - u_h\|_X \leq \frac{C_1}{C_0} \inf_{v_h \in X_h} \|y - v_h\|_X \leq \frac{C_1}{C_0} \|y - \tilde{u}_h\|_X.$$

D.h. der Fehler der Finite Elemente Approximation ist durch den Interpolationsfehler abgeschätzt.

#### Satz 3.121 (Interpolationsfehler auf dem Einheitselement)

Für  $v \in H^1(0, 1)$  sei  $\tilde{v}_h \in \mathbb{P}_1$  die lineare Interpolierende zu  $v$ , d.h.  $\tilde{v}_h \in \mathbb{P}_1$ ,  $\tilde{v}_h(0) = v(0)$ ,  $\tilde{v}_h(1) = v(1)$ . Dann gilt:

$$1) \|v - \tilde{v}_h\|_{L^2(0,1)} \leq \sqrt{c_p} \|v'\|_{L^2(0,1)},$$

$$2) \|\tilde{v}_h'\|_{L^2(0,1)} \leq \|v'\|_{L^2(0,1)}.$$

Ist zusätzlich  $v \in H^2(0, 1)$ , so ist

- 3)  $\|v - \tilde{v}_h\|_{L^2(0,1)} \leq c_p \|v''\|_{L^2(0,1)}$ ,  
 4)  $\|(v' - \tilde{v}'_h)\|_{L^2(0,1)} \leq \sqrt{c_p} \|v''\|_{L^2(0,1)}$ .

*Beweis:* Analog zu Hilfssatz 3.103 (Poincaré Ungleichung) zeigt man, dass für alle  $w \in H^1(0,1)$  mit  $w(0) = w(1) = 0$  gilt

$$(*) \quad \|w\|_{L^2(0,1)}^2 \leq c_p \|w'\|_{L^2(0,1)}^2,$$

wobei  $c_p \leq \frac{1}{2}$  ist. Setze  $w = v - \tilde{v}_h$ . Dann folgt aus  $(*)$  unter Verwendung von

$$(**) \quad \tilde{v}'_h(x) = v(1) - v(0) = \int_0^1 v'(s)ds :$$

$$\begin{aligned} \|v - \tilde{v}_h\|_{L^2(0,1)}^2 &\leq c_p \|v - \tilde{v}_h\|_{L^2(0,1)}^2 = c_p \int_0^1 (v'(x) - \tilde{v}'_h(x))^2 dx \\ &= c_p \int_0^1 (v'(x))^2 - 2\tilde{v}'_h(x)v'(x) + (\tilde{v}'_h(x))^2 dx \\ &\stackrel{(**)}{=} c_p \int_0^1 (v'(x))^2 dx - 2(v(1) - v(0))^2 + (v(1) - v(0))^2 \\ &= c_p \int_0^1 (v'(x))^2 dx - (v(1) - v(0))^2 \\ &\leq c_p \int_0^1 (v'(x))^2 dx \end{aligned}$$

Also haben wir 1) gezeigt.

2) folgt direkt aus  $(**)$ , da

$$\|\tilde{v}'_h\|_{L^2(0,1)} = |v(1) - v(0)| \leq \|v'\|_{L^2(0,1)}$$

3) folgt aus 1) und  $(*)$ , da  $(*)$  auch für  $w \in H^1(0,1)$  mit  $\int_0^1 w(x)dx = 0$  gilt.

4) folgt analog zur Herleitung von Gleichung 2), wenn man beachtet, dass  $\tilde{v}''_h = 0$  gilt.  $\square$

### Folgerung 3.122 (Interpolationsabschätzung)

Sei  $y \in X$  und  $\tilde{u}_h \in X_h$  die Interpolierende von  $y$  für  $k = 1$  aus Definition 3.117, 3). Dann gilt, falls  $y \in H^2(a, b)$ :

- 1)  $\|y - \tilde{u}_h\|_{L^2(a,b)} \leq c_p h^2 \|y''\|_{L^2(a,b)}$ ,  
 2)  $\|(y - \tilde{u}_h)'\|_{L^2(a,b)} \leq \sqrt{c_p} h \|y''\|_{L^2(a,b)}$ .

*Beweis:* (Folgt aus 3.118 mit Skalierungsargument)

zu 1): Es ist  $\|y - \tilde{u}_h\|_{L^2(a,b)}^2 = \sum_{j=0}^{n-1} \|y - \tilde{u}_h\|_{L^2(I_j)}^2$ .

Durch die Transformation  $x = F(\bar{x}) = h_j \bar{x} + x_j$  und  $\bar{y}(\bar{x}) = y(F(\bar{x}))$  folgt

$$I_j = F((0, 1))$$

und

$$\begin{aligned} \tilde{u}_h|_{I_j} &= y(x_j) + \frac{x - x_j}{h_j} (y(x_{j+1}) - y(x_j)) \\ &= \bar{y}(0) + \bar{x}(\bar{y}(1) - \bar{y}(0)) =: \tilde{y}(\bar{x}) \end{aligned}$$

Also gilt wegen  $F'(\bar{x}) = h_j$  und  $\bar{y}''(\bar{x}) = y''(F(\bar{x})) \cdot (F'(\bar{x}))^2$

$$\begin{aligned} \|y - \tilde{u}_h\|_{L^2(I_j)}^2 &= h_j \|\bar{y} - \tilde{y}_h\|_{L^2(0,1)}^2 \\ &\stackrel{3.118 \ 3)}{\leq} c_p^2 h_j \|\bar{y}''\|_{L^2(0,1)}^2 \\ &\leq c_p^2 h_j^4 \|y''\|_{L^2(I_j)}^2. \\ \implies \|y - \tilde{u}_h\|_{L^2(a,b)}^2 &\leq c_p^2 \sum_{j=0}^{n-1} h_j^4 \|\bar{y}''\|_{L^2(I_j)}^2 \\ &\leq c_p^2 h^4 \|y''\|_{L^2(a,b)}^2. \end{aligned}$$

Also ist 1) gezeigt.

zu 2): (Analoge Vorgehensweise!)

$$\begin{aligned} \|(y - \tilde{u}_h)'\|_{L^2(a,b)}^2 &= \sum_{j=0}^{n-1} \|(y - \tilde{u}_h)'\|_{L^2(I_j)}^2. \\ \|(y - \tilde{u}_h)'\|_{L^2(I_j)}^2 &= \frac{1}{h_j} \|(\bar{y} - \tilde{u}_h)\|_{L^2(0,1)}^2 \\ &\stackrel{3.118 \ 4)}{\leq} c_p \frac{1}{h_j} \|\bar{y}''\|_{L^2(0,1)}^2 \\ &= c_p h_j^2 \|y''\|_{L^2(I_j)}^2. \\ \implies \|(y - \tilde{u}_h)'\|_{L^2(a,b)}^2 &\leq c_p \sum_{j=0}^{n-1} h_j^2 \|y''\|_{L^2(I_j)}^2 \\ &\leq c_p h^2 \|y''\|_{L^2(a,b)}^2. \end{aligned}$$

□

### Satz 3.123 (Fehlerabschätzung für lineare Finite Elemente)

Sei  $y \in X$  die schwache Lösung von (SLP) und es gelten die Voraussetzungen aus Definition 3.100.

Sei zusätzlich  $f \in L^2(a,b)$ ,  $p, p', q \in L^\infty(a,b)$  und es gelte  $y \in H^2(a,b)$ .

Dann existiert eine Konstante  $c > 0$ , so dass für die stückweise lineare Finite Elemente Approximation  $u_h \in X_h$  (mit  $k = 1$ ) gilt:

$$\|y - u_h\|_X \leq c h \|f\|_{L^2(a,b)}$$

*Beweis:* Nach 3.117, 3) gilt  $\|y - u_h\|_X \leq \frac{c_1}{c_0} \|y - \tilde{u}_h\|_X$ , wobei  $\tilde{u}_h$  die Interpolierende von  $y$  in  $X_h$  ist und

$$c_1 := \max\{\|p\|_\infty, \|q\|_\infty\}, \quad c_0 := \frac{p_0}{1 + c_p}.$$

Dann folgt weiter mit Interpolationsfehlerabschätzung 3.119:

$$\begin{aligned} \|y - u_h\|_X &\leq \frac{c_1}{c_0} \left( \|y - \tilde{u}_h\|_{L^2(a,b)}^2 + \|(y - \tilde{u}_h)'\|_{L^2(a,b)}^2 \right)^{\frac{1}{2}} \\ &\stackrel{3.119}{\leq} \frac{c_1}{c_0} (c_p^2 h^4 + c_p h^2)^{1/2} \|y''\|_{L^2(a,b)} \\ &\stackrel{3.110}{\leq} \underbrace{\frac{c_1 c_2}{c_0} \sqrt{c_p} (c_p h^2 + 1)^{1/2} h \|f\|_{L^2(a,b)}}_{\leq C \text{ (z.B. für } h \leq h_{\max})} \end{aligned}$$

□

**Bemerkung 3.124**

- 1) Man kann zeigen, dass mit den Voraussetzungen  $p \in C^1(a, b)$ ,  $q, f \in C^0(a, b)$ ;  $p, p', q \in L^\infty(a, b)$  und  $f \in L^2(a, b)$  folgt, dass  $y \in H^2(a, b)$  ist.
- 2) Für  $k > 1$  gilt die Fehlerabschätzung:

$$\|y - u_h\|_X \leq c \cdot h^k \left\| y^{(k+1)} \right\|_{L^2(a, b)}$$

falls  $p, q, f$  und  $y$  regulär genug sind.

- 3) Weiteres zu Finiten Elementen findet man z.B. in den Büchern von Ciarlet [3] oder Braess [2].

**Bemerkung 3.125 (Weitere Diskretisierungsverfahren für (SLP))**

- 1) Finite Differenzenverfahren:

Idee: Ersetze Ableitungen durch Differenzenquotienten, z.B.

$$y' \approx \frac{y_j - y_{j-1}}{h}, \quad y'' \approx \frac{y_{j+1} - 2y_j + y_{j-1}}{h^2}.$$

- 2) Schießverfahren:

Berechne mit ESV oder MSV Approximationen der Anfangswertprobleme für  $y_0$ ,  $Y$  aus Definition 3.98 und erhalte  $y_{0,h}$ ,  $Y_h$ .

Wie im kontinuierlichen Fall ist dann

$$y_h := y_{0,h} + Y_h s_h$$

wobei  $s_h$  Lösung des Gleichungssystems

$$[B_a + B_b Y_h(b)]s_h = g - B_b y_{0,h}(b)$$

ist (vgl. Satz 3.99 mit Beweis).



## Kapitel 4

# Ausblick: Partielle Differentialgleichungen

Partielle Differentialgleichungen sind Gleichungen, die eine Funktion mit mehreren Variablen mit ihren partiellen Ableitungen in Beziehung setzt.

**Beispiel:** (Wärmeleitungsgleichung in drei Raumdimensionen)

Gesucht ist die zeitabhängige Temperaturverteilung  $T = T(x, t)$  in einem Gebiet  $\Omega \subset \mathbb{R}^3$  und Zeitintervall  $[0, T_{\max}]$ .

Im folgenden sei  $\Omega \subset \mathbb{R}^n$  ein Gebiet. Wir beschränken uns auf skalare partielle Differentialgleichungen zweiter Ordnung vom linearen Typ für  $u \in C^2(\Omega)$ .

**Definition 4.1 (Partielle Differentialgleichung zweiter Ordnung)**

$u \in C^2(\Omega)$  heißt klassische Lösung einer linearen partiellen Differentialgleichung zweiter Ordnung, falls gilt:

$$\sum_{i,j=1}^n a_{ij}(x)u_{x_i x_j}(x) + \sum_{i=1}^n b_i(x)u_{x_i}(x) + c(x)u(x) = f(x), \quad \forall x \in \Omega. \quad (4.1)$$

Dabei sind  $a_{ij}, b_i, c, f \in C^0(\Omega)$  für  $i, j = 1, \dots, n$ ,  $x = (x_1, \dots, x_n) \in \Omega$  und  $u_{x_i} := \frac{\partial u}{\partial x_i}(x)$ . Da  $u \in C^2(\Omega)$  ist, gilt  $u_{x_i x_j}(x) = u_{x_j x_i}(x)$  und wir können ohne Beschränkung der Allgemeinheit annehmen, dass  $a_{ij}(x) = a_{ji}(x)$  gilt. Dann ist

$$A(x) = \left( a_{ij}(x) \right)_{i,j=1,\dots,n}$$

symmetrisch und hat  $n$  reelle Eigenwerte.

Wir setzen  $\mathbf{b}(x) := (b_1(x), \dots, b_n(x))$ .

**Definition 4.2 (Klassifizierung für Partielle Differentialgleichungen zweiter Ordnung)**

- (i) Die Partielle Differentialgleichung (4.1) heißt hyperbolisch in  $x \in \Omega$ , falls  $n - 1$  Eigenwerte von  $A(x)$  gleiches Vorzeichen besitzen und ein Eigenwert das entgegengesetzte Vorzeichen hat.
- (ii) Die Partielle Differentialgleichung (4.1) heißt elliptisch in  $x \in \Omega$ , falls alle Eigenwerte von  $A(x)$  das gleiche Vorzeichen besitzen.
- (iii) Die Partielle Differentialgleichung (4.1) heißt parabolisch in  $x \in \Omega$ , falls  $n - 1$  Eigenwerte von  $A(x)$  gleiches Vorzeichen haben, ein Eigenwert verschwindet und zusätzlich gilt:

$$Rg(A(x), \mathbf{b}(x)) = n.$$

**Bemerkung 4.3**

Definition 4.2 deckt nicht alle denkbaren Typen ab. Allerdings sind die definierten Typen die wichtigsten in den Anwendungen.

## 4.1 Die Wellengleichung

**Definition 4.4 (Wellengleichung)**

Seien  $u_0, u_1, a \in \mathbb{R}$  und  $g, h : [0, \pi] \rightarrow \mathbb{R}$  mit

$$\begin{aligned} g(0) &= u_0, & g(\pi) &= u_1, \\ h(0) &= 0, & h(\pi) &= 0. \end{aligned} \tag{4.2}$$

$u : [0, \pi] \times \mathbb{R}_{\geq 0} \rightarrow \mathbb{R}$  heißt Lösung der Wellengleichung, falls gilt:

$$u_{tt}(x, t) = a^2 u_{xx}(x, t), \quad \forall (x, t) \in (0, \pi) \times (0, \infty) \tag{4.3}$$

und

$$u(0, t) = u_0, u(\pi, t) = u_1, \quad \forall t \geq 0, \tag{4.4}$$

$$u(x, 0) = g(x), \quad \forall x \in [0, \pi], \tag{4.5}$$

$$u_t(x, 0) = h(x), \quad \forall x \in [0, \pi]. \tag{4.6}$$

Die Wellengleichung beschreibt für  $u_0, u_1 = 0$  die Auslenkung einer in  $x = 0$  und  $x = \pi$  fest eingespannten Saite:

**Bemerkung 4.5**

- Die Wellengleichung ist hyperbolisch. Es ist

$$A(x, t) = \begin{pmatrix} -a^2 & 0 \\ 0 & 1 \end{pmatrix}.$$

- Die Bedingungen (4.2) heißen Verträglichkeitsbedingungen.

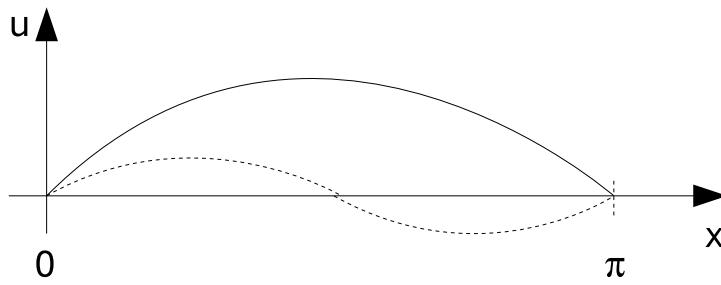
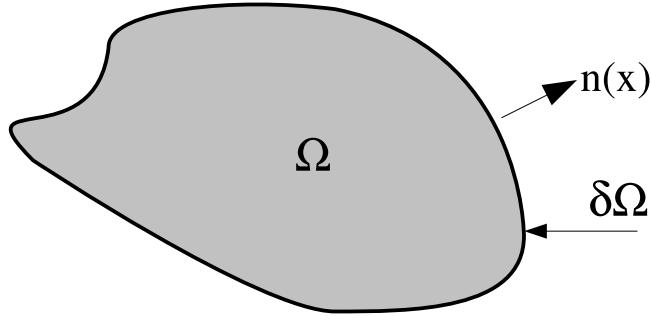


Abbildung 4.1: Erste und zweite Mode einer schwingenden Saite.

## 4.2 Die Poisson Gleichung

Sei  $\Omega \subset \mathbb{R}^2$  ein Gebiet mit glattem Rand  $\partial\Omega$  und  $\bar{\Omega} = \Omega \cup \partial\Omega$ .

Abbildung 4.2: Skizze eines Gebietes  $\Omega$  mit glattem Rand.

### Definition 4.6 (Poisson Gleichung)

Seien  $f : \Omega \rightarrow \mathbb{R}$  und  $g : \partial\Omega \rightarrow \mathbb{R}$  gegebene Funktionen. Dann heißt eine Funktion  $u \in C^2(\Omega) \cap C(\bar{\Omega})$  Lösung des Dirichletproblems für die Poisson Gleichung, falls gilt

$$\Delta u(x) := \sum_{i=1,2} u_{x_i, x_i} = f(x), \quad \forall x \in \Omega, \quad (4.7)$$

und

$$u(x) = g(x), \quad \forall x \in \partial\Omega. \quad (4.8)$$

Falls  $f \equiv 0$  gilt, so heißt Gleichung (4.7) auch Laplace Gleichung.

### Bemerkung 4.7

- Die Poisson Gleichung ist elliptisch. Es ist

$$A(x) = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}.$$

- Neben dem Dirichlet-Problem betrachtet man auch das Neumann-Problem, d.h. (4.8) wird ersetzt durch

$$\nabla u(x) \cdot \mathbf{n}(x) = g(x), \quad \forall x \in \partial\Omega.$$

Dabei ist  $\mathbf{n}(x)$  die äußere Normale an den Rand von  $\Omega$ .

- Die Poisson Gleichung modelliert z. B. die stationäre Wärmeverteilung, oder die Verteilung eines elektrischen Potentials.

### 4.3 Die Wärmeleitungsgleichung

Sei  $\Omega \subset \mathbb{R}^2$  ein Gebiet mit glattem Rand  $\partial\Omega$ .

#### Definition 4.8 (Wärmeleitungsgleichung)

Seien  $u_0 : \Omega \rightarrow \mathbb{R}$  und  $g : \partial\Omega \times [0, \infty) \rightarrow \mathbb{R}$  mit folgender Verträglichkeitsbedingung gegeben:

$$u_0(x) = g(x, 0), \quad \forall x \in \partial\Omega. \quad (4.9)$$

Weiter seien  $a > 0$  und  $f : \Omega \times [0, \infty) \rightarrow \mathbb{R}$  gegeben.

Dann heißt eine Funktion  $u \in C^2(\Omega \times (0, \infty)) \cap C(\bar{\Omega} \times (0, \infty))$  Lösung der Wärmeleitungsgleichung, falls gilt

$$u_t(x) = a\Delta u(x) + f(x), \quad \forall x \in \Omega \times (0, \infty) \quad (4.10)$$

und

$$u(x, 0) = u_0(x), \quad \forall x \in \Omega, \quad (4.11)$$

$$u(x, t) = g(x, t), \quad \forall (x, t) \in \partial\Omega \times [0, \infty). \quad (4.12)$$

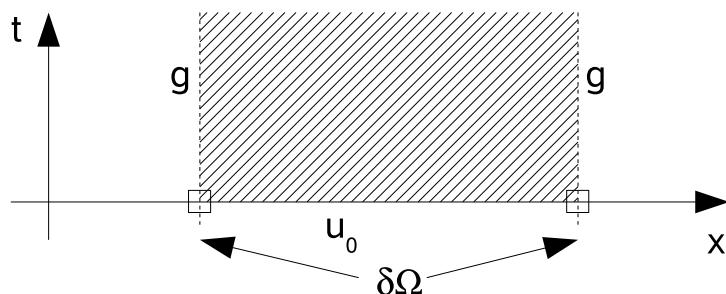


Abbildung 4.3: Skizze zu der Verträglichkeitsbedingung (4.9).

#### Bemerkung 4.9

- Die Wärmeleitungsgleichung ist parabolisch. Es ist

$$A(x) = \begin{pmatrix} a & 0 & 0 \\ 0 & a & 0 \\ 0 & 0 & 0 \end{pmatrix}$$

und

$$\operatorname{Rg}(A, (0, 0, 1)^t) = 3.$$

# Index

- $P(EC)^l E$ -Verfahren, 100  
2-Punkt-Gauß-Quadratur, 52
- A priori Abschätzung, 113  
A-Stabilität, 104  
Absolute Stabilität, 104  
Abstrakte Fehlerabschätzung, 114  
analytisch, 19  
Anfangswertproblem  
    Definition, 61  
    Diskretes Lösungsverfahren, 66  
    globaler Fehler numerischer Verfahren, 66  
    linear, 64  
    lineare Systeme, 65  
    Stetigkeitssatz, 63  
asymptotische Entwicklung, 19
- B-Splines, 38, 39  
Bernoulli Polynome, 54  
Bernoulli Zahlen, 54  
Birkoff-Interpolation, 18  
Butcher-Tableau, 71
- Dahlquist  
    Konvergenzssatz, 94  
Defektfunktion, 91  
Differentialgleichungen  
    Theorie, 61  
    autonome, 73  
    höherer Ordnung, 65  
    Reduktion auf System 1. Ordnung, 65  
Differenzengleichung  
    Definition, 82  
Differenzengleichungen  
    Theorie der linearen, 82  
Divide and conquer, 27  
dividierte Differenz, 13  
    - der Ordnung  $k$ , 13  
    Algorithmus, 15  
    weitere Eigenschaften, 14  
dividierte Differenzen, 9, 13  
    Rekursionsformel für -, 18  
Dormand-Prince
- Verfahren, 81
- Eindimensionale Sobolevräume, 111  
Einschrittverfahren, 66  
    asymptotische Fehlerentwicklung, 76  
    explizite, 67  
    implizites, 68  
    Konvergenzsatz, 68  
    Schrittweitensteuerung, 79  
Energiefunktional, 108  
Energieminimierung, 1  
Euler-MacLaurin'sche Summenformel, 54  
Eulergleichung und natürliche Randbedingung, 108  
Eulersche Formel, 23  
Eulerverfahren, 67  
exakt, 43  
Experimentelle Konvergenzordnung, 57  
Extrapolation, 19, 78  
    Richardson Extrapolation, 19, 54  
Extrapolationfehler, 20
- Fehlerfunktional, 43  
FFT, 27  
Finite Elemente Verfahren, 116  
Fundamentalsystem, 107  
Funktionsinterpolation durch Polynome, 10
- Gauß-Hermite-Quadratur, 53  
Gauß-Jacobi-Quadratur, 53  
Gauß-Laguerre-Quadratur, 53  
Gauß-Legendre-Quadratur, 52  
Gauß-Quadratur, 49  
    zusammengesetzt -, 53  
Gauß-Quadraturen, 49  
Gauß-Tschebyscheff-Quadratur, 52  
Gebiet, 61  
Gewöhnliche Differentialgleichung, 59  
Gewichstfunktion  
    Skalarprodukt, 50  
Gewichte, 43  
Gewichtsfunktion  
    zulässige -, 50

- Gragg
  - Algorithmus, 99
  - Extrapolationsverfahren, 97
  - Funktion, Graggsche, 98
  - Satz von, 98
- Gram-Schmidtsches Orthogonalisierungsverfahren, 50
- Gronwall, Lemma von, 63
  - diskret, 67
- Hermite Interpolation, 17
- Holladay Identität, 37
- Horner-Schema, 15
- Interpolation, 5
  - exponentielle -, 5
  - Hermite -, 5, 17
  - Kubische Spline-, 35
    - natürlicher kubischer Spline, 35
  - rationale -, 5
  - Spline -, 6, 32
  - Trigonometrische -, 23
  - trigonometrische -, 5
- Interpolationsabschätzung, 117
- Interpolationspolynom
  - Normalform, 8
- Interpolationsproblem
  - Lagrange-Form des -, 8
  - Newton-Form des -, 9
- Interpolationsquadratur, 45, 49
- k-Schrittverfahren
  - Charakterisierung stabiler, 92
- Knotenpolynom, 10
  - $\omega$ , 10
- Konditioniert
  - schlecht konditioniert, 8
- Konsistenz, 67
- Konvergenz
  - numerischer Verfahren für AWP, 66
- Konvergenzordnung, 66
  - EOC, 57
  - Experimentelle, 57
- Koordinatentransformation, 47, 52
- Korrektorformel, 100
- Lagrange-Polynome, 8
- Legendre-Polynome, 52
- lineare k-Schrittverfahren, 86
- lineare Mehrschrittverfahren
  - Konsistenzordnungskriterien, 96
- lineares Interpolationsproblem, 5
- Matrix
  - Vandermondsche Matrix, 8
- Matrixexponentielle, 65
- Mehrschrittverfahren, 82
  - Mehrschrittverfahren, lineare
    - Abschneidefehler, 87
    - BDF-Verfahren, 90
    - Konsistenz, 87
    - spezielle, 88
  - Methode der Variablenentrennung, 64
  - Milne-Simpson Verfahren, 95
  - Mittelpunktverfahren, 97
- Neville-Aitken Schema, 99
- Neville-Schema, 15
- Newton-Cotes Formel
  - Simpson-Regel, 49
    - zusammengegesetzte -, 49
  - Trapezregel, 48
    - zusammengesetzte -, 49
- Newton-Cotes Formeln, 48
- Newton-Form, 9
- Newton-Polynome, 9
- Normalform, 8
- not-a-knot-Bedingung, 35
- Numerische Integration, 43
  - Romberg Verfahren, 54
- Numerische Intergration
  - Mittelpunktregel, 44
  - Simpsonregel, 44
  - Trapezregel, 44
- Orthogonalbasis, 50
- Orthonormalsystem, 24
- Peano, Satz von , 63
- periodisch fortsetzbar, 35
- Picard-Lindelöf
  - Iteration, 62
  - Satz global, 62
  - Satz lokal, 62
- Poincaré Ungleichung, 109
- Poisson Gleichung, 123
- Polynom
  - 2. charakteristisches, 87
- Polynom, charakteristisches, 82
- Polynominterpolation, 7
- Prädiktor-Korrektor-Verfahren, 100
- Prädiktorformel, 100

- Quadratur, 49
  - Gauß-, 49
- Quadraturformel, 43, 57
  - exakte -, 43
  - Gewichte, 43
- Randwertprobleme, lineare, 106
- Ritz-Galerkin Verfahren für (SLP), 113
- Romberg Verfahren, 54, 57
- Runge-Kutta Verfahren
  - eingebettete, 81
  - explizit, 71
  - implizite, 75
  - Konstruktion, 74
  - Vorteil impliziter, 76
- Schnelle Fourier Transformation, 27
- schwache Ableitung, 111
- Schwache diskrete Differentialgleichung, 113
- Simpson-Regel, 57
- Simpson-Regel, 49
  - zusammengesetzte -, 49
- Stützstellen, 5
- Stabilität
  - asymptotische, 91
- steife Differentialgleichung, 103
- Sturm-Liouville Probleme, 108
- Taylorverfahren, 69
- Trapezregel, 48, 57
  - zusammengesetzte -, 49, 54
- Tridiagonale Matrix, 36
- Trigonometrische Interpolation, 23
- Trigonometrische Polynome, 23
- Tschebyschev-Polynome, 11
- Vandermondsche Matrix, 8
- Variationsgleichungen und Galerkinapproximation, 1
- Variationsproblem, 108
- Verschiebeoperatoren, 84
- Wärmeleitungsgleichung, 124
- Wellengleichung, 122
- Wurzelbedingung von Dahlquist, 84
- Zahlenfolgen
  - komplexe, 82
- zulässige Gewichtsfunktion, 50
- Zusammengesetzte Newton-Cotes Formeln, 49
- Zusammengesetzte Quadraturen, 48
- Zusammengesetzte Simpson-Regel, 49
- Zusammengesetzte Trapezregel, 49
- Zusammengesetzte Trappezregel, 54

# Literaturverzeichnis

- [1] M. Bollhöfer und V. Mehrmann. *Numerische Mathematik*, Vieweg Verlag, Wiesbaden 2004.
- [2] P. Braess. *Finite Elemente*, Springer, Berlin 1992.
- [3] P.G. Ciarlet. *The finite element methods for elliptic problems*, North-Holland, Amsterdam 1987.
- [4] P. Deuflhard und F. Bornemann. *Numerische Mathematik II*, 3. Auflage, Walter de Gruyter, Berlin 2002.
- [5] R. D. Grigorieff. *Numerik gewöhnlicher Differentialgleichungen*, 2 Auflage, Teubner, Stuttgart 1977.
- [6] W. Hackbusch. *Iterative Lösung großer schwachbesetzter Gleichungssysteme. Leitfäden der Angewandten Mathematik und Mechanik*, 69, Teubner Studienbücher Mathematik, Teubner, Stuttgart 1991.
- [7] G. Hämmerlin und K.-H. Hoffmann. *Numerische Mathematik*, Springer, Berlin 1989.
- [8] J. Stoer und R. Bulirsch. *Einführung in die Theorie der Numerischen Mathematik I & II*, Heidelberg Taschenbücher, Springer, Berlin 2000.
- [9] W. Walter. *Gewöhnliche Differentialgleichungen*, 5. Auflage, Springer, Berlin, 1993.