

# Exponentielle Approximation: Theorie und Numerische Verfahren

Franz J. Polster

15.02.2023

## *Prolog*

*Dieses Dokument ist eine “Überarbeitung” meiner Diplomarbeit vom Januar 1973<sup>1</sup>, angefertigt am Institut für Angewandte Mathematik I der Universität Erlangen-Nürnberg. Es wurde erstellt mit L<sup>A</sup>T<sub>E</sub>X in den Pandemiejahren 2020-2022.*

*Die Aufgabe bestand in der Implementierung und Erprobung von Verfahren zur Exponentiellen Approximation:*

- *Es war die Theorie der Exponentialapproximation darzustellen: “Teil I”*
- *Auf dieser Grundlage waren Verfahren zur Exponentiellen Approximation zu beschreiben: “Teil II”*
- *Diese Verfahren waren mittels numerischer Experimente zu erproben: “Teil III”.*

### ***Änderungen, Abweichungen gegenüber dem Original:***

*Teil I und Teil II dieses Dokuments sind inhaltlich identisch mit den entsprechenden Teilen der Diplomarbeit von 1973.*

- *Layout und Formatierung ergeben sich aus den Fähigkeiten und Möglichkeiten von L<sup>A</sup>T<sub>E</sub>X . Die Fehlerfunktionen wurden mit L<sup>A</sup>T<sub>E</sub>X-package “pgfplots” erstellt.<sup>2</sup>*
- *Vereinzelt wurden textuelle Änderungen zur Verbesserung der Lesbarkeit vorgenommen.*
- *Die Verwendung von L<sup>A</sup>T<sub>E</sub>X-Zählern hat Nummerierungsfehler im Original (bei Sätzen, Korollaren, ...) aufgezeigt, diese wurden korrigiert.*
- *Einige (zum Teil offensichtliche) Unstimmigkeiten im Original wurden korrigiert, auf diese weisen entsprechende Fußnoten hin.*
- *Beispiele 5.4, 5.5 von Kapitel 5 sind Erweiterungen des Originals*

*Für Teil III, Kapitel 7 und 8 gilt zusätzlich:*

*Für die Berechnungen wird auf das Original verwiesen, Anhang B enthält den Textteil von §7 des Originals.*

*Anhang A ist eine Erweiterung des Originals, ebenso wie die Quellenangaben des Literaturverzeichnisses ab [26].*

---

<sup>1</sup> *nachstehend auch “Original” genannt*

<sup>2</sup> *das Original wurde auf einer Schreibmaschine geschrieben, die Zeichnungen des Originals wurden mit dem Plotter des Rechenzentrums der Universität gezeichnet*

# Inhaltsverzeichnis

Bezeichnungen und Abkürzungen	4
<b>I Theorie der Exponentialapproximation</b>	<b>5</b>
<b>1 Einleitung, Hilfsmittel</b>	<b>5</b>
1.1 Die Mengen $V_N, V_N^0, V_N^+$	5
1.2 Darstellung der Exponentialsummen durch Differenzenquotienten	14
1.3 Vorzeichenklassen in $V_N$	20
<b>2 Existenzsätze</b>	<b>24</b>
2.1 Gleichmäßige Konvergenz im Innern	24
2.2 Abgeschlossenheit, Existenzsätze	34
<b>3 Eindeutigkeitssätze und Charakterisierung der Minimallösungen</b>	<b>47</b>
<b>4 Lokale Minima</b>	<b>65</b>
<b>II Numerische Verfahren</b>	<b>73</b>
<b>5 Konstruktion von Näherungen</b>	<b>73</b>
5.1 Näherungen nach Meinardus	73
5.1.1 Der Algorithmus	75
5.1.2 Zur Theorie des Verfahrens	77
5.2 Konstruktion einer Näherung nach Rice	86
5.3 Konstruktion einer Näherung nach Willers	89
5.4 Numerische Beispiele	91
<b>6 Iterationsverfahren</b>	<b>115</b>
6.1 Konstruktion von Minimallösungen nach Braess	115
6.1.1 Der Algorithmus	115
6.1.2 Zur Theorie des Verfahrens	118
6.1.3 Zur Anwendung des Algorithmus	124
6.2 Das Newtonsche Iterationsverfahren	127
6.3 Approximation bzgl. $V_1$ durch Bestimmung von reellen Nullstellen	129

<b>III</b>	<b>Numerische Experimente und Erprobung der Iterationsverfahren</b>	<b>134</b>
<b>7</b>	<b>Beispiele zum Verfahren von Braess</b>	<b>134</b>
7.1	Approximation von $f(x) = \sqrt{x}$ in $[0,1]$ mit $N=1$ nach Braess	134
7.2	Konstruktion von Startfunktionen . . . . .	134
7.3	Zur Konstruktion der Minimallösung für $f(x) = \sqrt{x}$ in $[0,1]$ , $N=2$ . . . . .	135
7.4	Zur Konvergenz des Algorithmus mit $f(x) = \frac{1}{1+x}$ und $N=3$ .	135
<b>8</b>	<b>Approximationen für die Riemannsche Zetafunktion nach dem Newtonschen Iterationsverfahren</b>	<b>136</b>
<b>9</b>	<b>Zur Approximation bezüglich <math>V_1</math> nach dem Verfahren von Abschnitt 6.3</b>	<b>140</b>
9.1	Approximation von $f(x) = \sqrt{x}$ auf $[0,1]$ . . . . .	140
9.2	Approximation von $f(x) = \zeta(x)$ auf $[2,3]$ . . . . .	142
9.3	Approximation von $f(x) = \zeta(x)$ auf $[2,4]$ . . . . .	144
<b>10</b>	<b>Das Lokale Kolmogoroff-Kriterium bei der Konstruktion besserer Approximationen</b>	<b>147</b>
	<b>Literatur</b>	<b>151</b>
	<b>Anhang A: Herleitung der Gleichungen (6.11)</b>	<b>155</b>
	<b>Anhang B: §7 der Diplomarbeit (<math>\text{\LaTeX}</math>-Version)</b>	<b>156</b>

## Bezeichnungen und Abkürzungen

$\mathbb{N}$	Menge der natürlichen Zahlen
$\mathbb{R}$	Menge der reellen Zahlen
$\mathbb{C}$	Menge der komplexen Zahlen
$C(X)$	Menge der auf X stetigen Funktionen
$xEy$	$x \times 10^y$
$xE \pm y$	$x \times 10^{\pm y}$
$\setminus$	Mengendifferenz
$\Re(z)$	Realteil von $z \in \mathbb{C}$
$\Im(z)$	Imaginärteil von $z \in \mathbb{C}$
$ x $	Betrag von x
$\ f\ _X$	Tschebyscheff-Norm (p. 5)
$\frac{d}{dx}, D^n$	Differentialoperator (p. 8)
$grad(P)$	Grad des Polynom P (p. 9)
$grad(E)$	Grad von $E \in V_N$ (p. 9)
$\equiv$	Gleichheit von Funktionen
$sign(x)$	Vorzeichen von x (p. 20)
$sign(E)$	Vorzeichenvektor der Exponentialsumme E (p. 20)
o.B.d.A.	ohne Beschränkung der Allgemeinheit

## Teil I

# Theorie der Exponentialapproximation

## 1 Einleitung, Hilfsmittel

### 1.1 Die Mengen $V_N, V_N^0, V_N^+$

Es sei  $X$  stets eine kompakte Teilmenge der reellen Zahlen  $\mathbb{R}$  und  $C(X)$  die Menge der auf  $X$  stetigen, reellen Funktionen;  $C(X)$  sei mit der von der Tschebyscheff-Norm  $\| \cdot \|$  induzierten Metrik versehen:

$$\| f \|_X = \sup_{x \in X} | f(x) |, \quad f \in C(X)$$

In  $\mathbb{R}^n$ ,  $n \in \mathbb{N}$ , wird die Euklidische Metrik bzw. Norm verwendet.

$I$  bezeichnet stets ein abgeschlossenes Intervall  $[a, b]$  mit  $a < b$ ,  $a, b \in \mathbb{R}$ .

In dieser Arbeit wird die Tschebyscheff-Approximation stetiger, reeller Funktionen durch Exponentialsummen - ein nichtlineares Approximationsproblem - behandelt; wie üblich sei also definiert:

#### Definition 1.1

Es sei  $V \subseteq C(X)$ .

- a.  $v_0 \in V$  heißt *beste Approximation* an  $f \in C(X)$  bezüglich  $V$  auf  $X$  oder auch *Minimallösung* für  $f$  bezüglich  $V$  auf  $X$ , wenn gilt:

$$\| f - v_0 \|_X = \inf_{v \in V} \| f - v \|_X = R(f)$$

- b.  $R(f)$  ist die *Minimalabweichung* von  $f$  bezüglich  $V$  auf  $X$ .
- c. Die Folge  $(v_n)_{n \in \mathbb{N}} \subseteq V$  ist eine *Minimalfolge* in  $V$  für  $f$  auf  $X$ , wenn gilt:

$$\lim_{n \rightarrow \infty} \| f - v_n \|_X = R(f)$$

Wenn man von Exponentialsummen spricht, denkt man zunächst an Summen

$$\sum_{i=1}^n a_i e^{t_i x} \text{ mit } a_i, t_i \in \mathbb{R} \text{ für } 1 \leq i \leq n, n \in \mathbb{N}$$

Dies soll im Folgenden präzisiert werden.

**Definition 1.2**

Es sei  $N \in \mathbb{N}$  und  $a = (a_1, \dots, a_N, t_1, \dots, t_N) \in \mathbb{R}^{2N}$ .

a.

$$E(a, x) := \sum_{i=1}^N a_i e^{t_i x} \quad x \in \mathbb{R}$$

Die hiermit auf  $\mathbb{R}$  definiert Funktion wird mit  $E(a)$  bezeichnet;  $a \in \mathbb{R}^{2N}$  ist der *Parametervektor* von  $E(a)$ <sup>3</sup>.

b.

$$V_N^0 := \{E(a) \mid a = (a_1, \dots, a_N, t_1, \dots, t_N) \in \mathbb{R}^{2N}, \\ t_i < t_{i+1} \text{ für } 1 \leq i \leq N-1, a_i = 0 \Rightarrow a_{i+1} = 0\}$$

$V_0^0$  enthält nur die Nullfunktion.

c.  $L$  ist die *Länge* von  $E(a, x) = \sum_{i=1}^L a_i e^{t_i x} \in V_N^0$ , wenn  $a_i \neq 0$  für  $1 \leq i \leq L$  erfüllt ist.

Bemerkung:

Jede Funktion  $\sum_{i=1}^N a_i e^{t_i x}$  mit  $a_i, t_i \in \mathbb{R}$  für  $1 \leq i \leq N$  ist in  $V_N^0$  enthalten;

$E(a) \in V_N^0$  bedeutet nur, daß die Indizierung der Summanden gemäß Definition 1.2b durchgeführt wird. Dies ist offensichtlich stets möglich und man sieht unmittelbar ein, daß  $E(a) \in V_N^0$  mit der Länge  $L < N$  keinen eindeutig bestimmten Parametervektor  $a \in \mathbb{R}^{2N}$  besitzt, da zum Beispiel  $t_{L+1} \in \mathbb{R}$  mit  $t_{L+1} > t_L$  beliebig gewählt werden kann.

Das folgende Beispiel zeigt, daß die Existenz einer besten Approximation bezüglich  $V_N^0$  allgemein nicht gesichert ist:

---

<sup>3</sup> der Parametervektor  $a$  umfasst also auch die  $t_i$ :  $a = (a_1, \dots, a_N, t_1, \dots, t_N)$

**Beispiel 1.1** (Meinardus, [12])

Es sei  $X = [0, 1]$ ,  $f(x) = xe^x$  und für  $m \in \mathbb{N}$  sei  $E(a_m) \in V_2^0$  gegeben durch

$$E(a_m, x) = me^{(1+\frac{1}{m})x} - me^x$$

Für  $x \in X$  gilt:

$$\begin{aligned} |f(x) - E(a_m, x)| &= e^x |x - me^{\frac{x}{m}} + m| = e^x |m \sum_{i=2}^{\infty} \frac{x^i}{i!m^i}| \\ &\leq e^x m^{-1} e^x \leq m^{-1} e^2 \end{aligned}$$

Es folgt also  $\lim_{n \rightarrow \infty} \|f - E(a_m)\|_X = 0$ .

Die Minimalabweichung von  $f$  bezüglich  $V_2^0$  ist demnach Null,  $f$  ist jedoch nicht in  $V_2^0$  enthalten. Damit gibt es keine beste Approximation für  $f$  bezüglich  $V_2^0$  auf  $X$ .

Anders formuliert besagt Beispiel 1.1, daß jede Umgebung von  $f(x) = xe^x$  in  $C([0, 1])$  eine Funktion aus  $V_2^0$  enthält.

Dies ergibt sich auch unmittelbar aus der Tatsache, daß die betrachteten Funktionen Lösungen homogener, linearer Differentialgleichungen zweiter Ordnung sind.

Allgemein für  $n \in \mathbb{N}$  entnimmt man der Theorie der linearen Differentialgleichungen  $N$ -ter Ordnung mit konstanten Koeffizienten (man vergleiche hierzu [5], [7]):

1. Die Lösungen  $h$  der Differentialgleichungen

$$(1.1) \quad \sum_{i=0}^N d_i D^i h = \prod_{i=1}^L (D - t_i)^{m_i+1} h = 0$$

$$\text{mit } t_i \in \mathbb{R} \text{ für } 1 \leq i \leq L \text{ und } \sum_{i=1}^L (m_i + 1) = N$$

sind von der Gestalt

$$h(x) = \sum_{i=1}^L P_i(x) e^{t_i x}$$

mit reellen Polynomen  $P_i(x) = \sum_{n=0}^{m_i} a_{i,n} x^n$  für  $1 \leq i \leq L$ .

Liegt ein Anfangswertproblem vor, so sind die Lösungen von (1.1) eindeutig bestimmt.

(Wie üblich wird der Differentialoperator  $\frac{d}{dx}$  mit  $D$  bezeichnet. Es ist  $D^0 f = f$  und  $D^n = D^{n-1}D$ .)

2. Die Lösungen der Differentialgleichungen (1.1) mit den Anfangswerten  $D^i h(x_0) = h_i \in \mathbb{R}$ ,  $0 \leq i \leq N-1$ , hängen stetig von den Koeffizienten  $d_i$  und den Anfangswerten ab. Dies ergibt sich aus dem entsprechenden Satz für Differentialgleichungssysteme.

Hat man also eine Funktion  $h(x) = \sum_{i=1}^L \left( \sum_{n=0}^{m_i} a_{i,n} x^n \right) e^{t_i x}$  mit  $m_i \geq 1$  für ein  $i$  und  $\sum_{i=1}^L (m_i + 1) = N$  gegeben, so ist

$$(1.2) \quad \sum_{i=0}^N d_i D^i h := \prod_{i=1}^L (D - t_i)^{m_i+1} h = 0$$

erfüllt.

Die Differentialgleichung

$$\sum_{i=0}^N c_i D^i g := \prod_{i=1}^N (D - s_i) g$$

mit  $|t_i - s_i| < \epsilon$  für  $1 \leq i \leq N$ ,  $s_i \neq s_j$  für  $i \neq j$ , besitzt Lösungen der Form

$$g(x) = \sum_{i=0}^N a_i e^{s_i x}$$

Legt man ein abgeschlossenes Intervall  $I \subset \mathbb{R}$  und die Anfangswerte

$$D^i g(x_0) = D^i h(x_0) \quad 0 \leq i \leq N-1, \quad x_0 \in I$$

zugrunde, dann kann  $\|h - g\|_I$  bei geeigneter Wahl von  $\epsilon$  beliebig klein gemacht werden, da  $\lim_{\epsilon \rightarrow 0} c_i = d_i$ ,  $0 \leq i \leq N-1$ , gilt.

Damit ist gezeigt:

(1.3) In jeder Umgebung von  $\sum_{i=1}^L P_i(x) e^{t_i x}$  in  $C(I)$  mit

$$\sum_{i=1}^L (\text{grad}(P_i) + 1) = N \text{ liegt ein Element von } V_N^0$$

Hierbei wird der Grad des Polynoms  $P(x) = \sum_{i=0}^m a_i x^i$  mit  $\text{grad}(P)$  bezeichnet;

mit  $a_m \neq 0$  gilt also  $\text{grad}(P) = m$ .

Das Nullpolynom  $P(x) \equiv 0$  habe den Grad  $-1$ .

Will man bei der Approximation stetiger Funktionen durch Exponentialsummen die Existenz einer besten Approximation sichern, so muß man also  $V_N^0$  mindestens um die oben in (1.3) betrachteten, verallgemeinerten Exponentialsummen erweitern.

### Definition 1.3

a.

$$V_N := \{E(a) \mid E(a, x) = \sum_{i=1}^L P_i(x) e^{t_i x}, P_i \text{ ist ein reelles Polynom}$$

$$\text{mit } \text{grad}(P_i) = m_i, \sum_{i=1}^L (m_i + 1) \leq N,$$

$$t_i \in \mathbb{R} \text{ für } 1 \leq i \leq L \text{ mit } t_i < t_{i+1}\}, N \in \mathbb{N} \cup \{0\}$$

b.

Für  $E(a, x) = \sum_{i=1}^L P_i(x) e^{t_i x} \in V_N$  werden folgende Bezeichnungen eingeführt:

Es sei  $\text{grad}(E(a)) := \sum_{i=1}^L (\text{grad}(P_i) + 1)$  der *Grad* von  $E(a)$ ;

ist  $\text{grad}(P_i) \geq 0$  für  $1 \leq i \leq L$  erfüllt, dann ist  $L$  die *Länge* von  $E(a)$ .

Das *Spektrum* von  $E(a)$  ist gegeben durch  $\{t_i \mid 1 \leq i \leq L\}$ , die Elemente dieser Menge seien die *Frequenzen* von  $E(a)$ .

### Bemerkung 1.1

1. Es ist nicht ohne weiteres möglich, den Elementen von  $V_N$  einen Parametervektor zuzuordnen, wie dies in Definition 1.1 für  $V_N^0$  geschah.

Dies wird deutlich wenn man bedenkt, daß neben  $(\sum_{i=0}^{N-1} a_{i+1} x^i) e^{t_1 x}$  mit

$a_N \neq 0$  auch  $\sum_{i=1}^N a_i e^{t_i x} \in V_N$  enthalten ist; im ersten Fall bestimmen

$N + 1$ , im zweiten Fall  $2N$  Parameter die Funktion.

Auch die Beschränkung auf Elemente von  $V_N$  mit einer festen Anzahl von Parametern bringt keine Änderung:

Es seien  $a, b, c, u, v \in \mathbb{R}$  mit  $u < v$  gegeben. Mit  $(a, b, c, u, v)$  als Parametervektor lassen sich die Exponentialsummen

$$ae^{ux} + (b + cx)e^{vx} \in V_3 \quad (a + bx)e^{ux} + ce^{vx} \in V_3$$

bilden, die im Spektrum übereinstimmen, im allgemeinen jedoch nicht gleich sind.

Für  $E(a) \in V_N \setminus V_N^0$  hat also der Parameter  $a$  nicht die gleiche Bedeutung wie für die Elemente von  $V_N^0$ ; es dient hier nur der Bezeichnung einer speziellen Funktion im Sinne einer Indizierung.

2. Für  $E(a) \in V_N^0$  fällt die Länge mit dem Grad zusammen. Hat  $E(a) \in V_N \setminus V_N^0$  die Länge  $L$ , so folgt  $L < \text{grad}(E(a))$  für  $N \geq 2$ .
3. Aus der Definition der Polynomgrade ergibt sich, daß  $V_0$  nur die Nullfunktion enthält.

In Kapitel 2 wird gezeigt, daß auch bei der Approximation bezüglich der in Definition 1.4 beschriebenen Teilmengen von  $V_N^0$  eine Minimallösung für  $f \in C(I)$  existiert:

**Definition 1.4**

$$V_N^+ := \{ E(a) \mid E(a, x) = \sum_{i=1}^N a_i e^{t_i x}, a_i \geq 0 \text{ für } 1 \leq i \leq N \}$$

$$V_N^- := \{ E(a) \mid -E(a) \in V_N^+ \}$$

**Bemerkung 1.2** (Werner, [21])

Für  $n \in \mathbb{N}$  ist  $E \in V_N$   $n$ -fach differenzierbar in  $\mathbb{R}$  und es gilt:

$$D^n E \in V_N$$

**Beweis:** Vollständige Induktion nach  $n$ :

$E(x) = \sum_{i=1}^L P_i(x)e^{t_i x} \in V_N$  ist in  $\mathbb{R}$  differenzierbar:

$$DE(x) = \sum_{i=1}^L (DP_i(x) + P_i(x)t_i)e^{t_i x}$$

Wegen  $\text{grad}(DP_i + P_i t_i) \leq \text{grad}(P_i)$  ist  $DE \in V_N$  erfüllt.

Gilt die Behauptung für  $n$ , also  $z = D^n h \in V_N$ , dann ist  $z$  in  $\mathbb{R}$  differenzierbar und es ist  $Dz = D^{n+1} h \in V_N$ . Damit ist die Behauptung vollständig gezeigt.

Von entscheidender Bedeutung ist der nun folgende Satz über die Nullstellen von Exponentialsummen:

**Satz 1.1** (Meinardus, [12])

Jede nicht identisch verschwindende Funktion in  $V_N$  besitzt höchstens  $N - 1$  reelle Nullstellen.

**Beweis:** Durch vollständig Induktion nach  $L$  wird gezeigt:

$$(1.4) \quad \sum_{i=1}^L P_i(x)e^{t_i x} \in V_N \text{ mit } E \not\equiv 0 \text{ hat höchstens}$$

$$\left( \sum_{i=1}^L (\text{grad}(P_i) + 1) \right) - 1 \text{ reelle Nullstellen.}$$

Für  $L = 1$  ist nichts zu zeigen:  $P(x)e^{tx} \in V_N$  besitzt höchstens  $\text{grad}(P)$  reelle Nullstellen oder verschwindet identisch.

Es gelte (1.4) für  $L - 1$ .

$E(x) = \sum_{i=1}^L P_i(x)e^{t_i x} \in V_N$  habe  $M$  reelle Nullstellen und es sei  $m_L = \text{grad}(P_L) \geq 0$  (sonst gilt die Behauptung nach Induktionsannahme).

$$\begin{aligned} E_1(x) &:= D^{m_L+1}(e^{-t_L x} E(x)) = D^{m_L+1} \left( \sum_{i=1}^{L-1} P_i(x)e^{(t_i - t_L)x} \right) = \\ &= \sum_{i=1}^{L-1} Q_i(x)e^{(t_i - t_L)x} \end{aligned}$$

Nach Bemerkung 1.2 gilt

$$\sum_{i=1}^{L-1} (\text{grad}(Q_i) + 1) \leq \sum_{i=1}^{L-1} (\text{grad}(P_i) + 1)$$

Die Funktion  $e^{-t_L} E(x)$  besitzt  $M$  reelle Nullstellen; nach dem Satz von Rolle hat dann  $E_1$  mindestens  $M - (m_L + 1)$  reelle Nullstellen. Die Induktionsannahme, auf  $E_1$  angewandt, ergibt

$$M - m_L - 1 \leq \left( \sum_{i=1}^{L-1} (\text{grad}(P_i) + 1) \right) - 1 = \left( \sum_{i=1}^L (\text{grad}(P_i) + 1) \right) - 1 - m_L - 1$$

woraus  $M \leq \left( \sum_{i=1}^L (\text{grad}(P_i) + 1) \right) - 1$  folgt.

Damit ist (1.4) vollständig bewiesen und die Behauptung des Satzes gilt.

Die Theorie der nichtlinearen Approximation, wie sie in [11] dargestellt ist, wird in Kapitel 3 zur Herleitung von Charakterisierungs- und Eindeutigkeits-sätzen für die Approximation bezüglich  $V_N$  herangezogen; die Theorie von Rice, [15], ist hier nicht anwendbar, da  $V_N$  im allgemeinen die Varisolvency-Eigenschaft nicht besitzt. Braess gibt dazu in [1] folgendes Beispiel an:

### Beispiel 1.2

Betrachtet wird  $V_2$  im Intervall  $[-3, 3]$ . In  $V_2$  besitzt  $E_0(x) = x \in V_2$  die Varisolvency-Eigenschaft nicht:

a. Es sei

$$\begin{aligned} x_1 = -2, \quad x_2 = -1, x_3 = 1, x_4 = 2 \quad \text{und} \\ y_1 = -2 + \delta, y_2 = -1, y_3 = 1, y_4 = 2 - \delta \quad \text{mit } \delta > 0 \text{ gegeben.} \end{aligned}$$

Es kann o.B.d.A.  $\delta < 1$  angenommen werden

Gesucht sind die Funktionen  $E \in V_2$ , die

$$(1.5) \quad E(x_i) = y_i \quad \text{für } 1 \leq i \leq 4$$

erfüllen.

Gilt  $E_1(x_i) = E_2(x_i) = y_i$ ,  $1 \leq i \leq 4$ , für  $E_1, E_2 \in V_2$ , so folgt  $E_1 = E_2$  nach Satz 1.1. Für jede Lösung  $E$  des Problems (1.5) gilt  $E(x_i) = -E(-x_i)$ ,  $1 \leq i \leq 4$ , und man erhält

$$(1.6) \quad E(x) = -E(-x) \quad x \in I$$

Die Funktionen in  $V_2^0$  und  $V_2 \setminus V_2^0$ , die (1.6) erfüllen, sind gegeben durch  $E(x) = a(e^{sx} - e^{-sx})$  und  $E(x) = ax$  mit  $a, s \in \mathbb{R}$ . Gilt weiter  $E(x) \geq 0$  für  $x \geq 0$ , dann sind diese Funktionen in  $[0, 3]$  konvex und lösen daher für kein  $\delta > 0$  das Problem (1.5).

b. Mit  $E(x) = \frac{1}{4}(e^x - e^{-x}) \in V_2$  besitzt  $E_0 - E$  in I drei Nullstellen:

x	-3	-1	0	+1	+3
$E_0(x) - E(x)$	+2.009	-0.412	0.0	+0.412	-2.009

Nach a. ist also der Solvency-Grad von  $E_0$  in  $V_2$  kleiner als 4, es gibt aber Elemente  $E \in V_2$ , so daß  $E_0 - E$  in I 4-1 Nullstellen hat; damit ist für  $E_0$  die Varisolvency-Eigenschaft, wie sie in [15] definiert ist, nicht erfüllt.

**Bemerkung:**

In "On Extended Varisolvent Families" zeigen R. B. Barrar und H. L. Loeb, daß die reellen Funktionen

$$\frac{1}{2\pi i} \int_K \frac{C(z)}{A(z)} e^{zx} dz, \quad x \in \mathbb{R}$$

ein Funktionensystem bilden, das die Varisolvency-Eigenschaft besitzt; hierbei gilt

1.  $C(z)$  und  $A(z)$  sind Polynome mit reellen Koeffizienten, die keine Nullstellen gemeinsam haben; es sei  $grad(c) < grad(A) = n \leq N \in \mathbb{N}$  und der Koeffizient bei  $z^n$  in A ist Eins.
2. Für den Imaginärteil  $\Im(z_0)$  jeder Nullstelle  $z_0$  von A gilt:

$$|\Im(z_0)| < r$$

3. Der geschlossene Weg K sei der Rand eines Gebietes in  $\mathbb{C}$ , das alle Nullstellen von A im Innern enthält.

Jedes Element E von  $V_N^0$  ist in dem beschriebenen Funktionensystem enthalten: Man hat hierzu das Polynom A so zu wählen, daß die n Frequenzen von E die (reellen) Nullstellen von A sind; dann kann das Polynom C so bestimmt werden, daß man (mit dem Cauchyschen Integralsatz) die restlichen Parameter von E erhält.

## 1.2 Darstellung der Exponentialsummen durch Differenzenquotienten

Die Darstellung von Funktionen aus  $V_N$  gemäß Definition 1.3 ist für topologische Untersuchungen oft nicht sehr geeignet, was auch Beispiel 1.1 zeigt. Deshalb wird nun durch Verwendung von Differenzenquotienten eine andere Darstellung für die Elemente von  $V_N$  entwickelt, die für Konvergenzbetrachtungen günstiger ist.

### Definition 1.5

Die Funktion  $f$  sei auf  $T := \{ t_i \mid t_i \in \mathbb{R}, i \in \mathbb{N}, t_i \neq t_j \text{ für } i \neq j \}$  definiert.

$$\begin{aligned} \Delta^0(t_1)f &:= f(t_1) \\ \Delta^n(t_1, \dots, t_{n+1})f &:= \frac{\Delta^{n-1}(t_1, \dots, t_n)f - \Delta^{n-1}(t_2, \dots, t_{n+1})f}{t_1 - t_{n+1}} \quad n \in \mathbb{N} \end{aligned}$$

Es werden die folgenden **Eigenschaften der Differenzenquotienten** benötigt (man vergleiche hierzu [19], [22], [23]):

1. Mit

$$\begin{aligned} P_j(t) &= \prod_{i=1, i \neq j}^{n+1} (t - t_i), \quad 1 \leq j \leq n+1 \quad \text{gilt} \\ (1.7) \quad \Delta^n(t_1, \dots, t_{n+1})f &= \sum_{j=1}^{n+1} \frac{f(t_j)}{P_j(t_j)} \end{aligned}$$

Es sei  $I \subseteq \mathbb{R}$  ein Intervall und  $f$  eine Funktion von  $t$  in  $I$ .

2. Für  $f \in C^n(I)$ , d.h.  $f$  ist in  $I$   $n$ -mal stetig differenzierbar, gilt mit  $\{t_i \mid 1 \leq i \leq n+1\} \subseteq I$ :

$$\begin{aligned} (1.8) \quad \Delta^n(t_1, \dots, t_{n+1})f &= \\ &= \int_0^1 \int_0^{s_1} \dots \int_0^{s_{n-1}} \frac{d^n}{dt^n} f\left(t_1 + \sum_{i=1}^n (t_{i+1} - t_i)s_i\right) ds_n \dots ds_1 \end{aligned}$$

$$(1.9) \quad \Delta^n(t_1, \dots, t_{n+1})f = \frac{1}{n!} \frac{d^n}{dt^n} f(\tau) \quad \text{für ein } \tau \in I$$

$$(1.10) \quad \Delta^n(t_1, \dots, t_1)f = \frac{1}{n!} \frac{d^n}{dt^n} f(t_1)$$

Die Gleichung (1.8) ermöglicht für  $f \in C^n(I)$  folgende Verallgemeinerung:

**Definition 1.6**

Es sei  $n \in \mathbb{N}$ ,  $f \in C^n(I)$  und  $\{t_i \mid 1 \leq i \leq n+1\} \subseteq I$ .

$$\Delta^m(t_1, \dots, t_{m+1})f := \int_0^1 \int_0^{s_1} \dots \int_0^{s_{m-1}} \frac{d^m}{dt^m} f\left(t_1 + \sum_{i=1}^m (t_{i+1} - t_i)s_i\right) ds_m \dots ds_1$$

mit  $m \leq n$ .

**3.** Nach (1.8) sind die Definitionen 1.5 und 1.6 äquivalent, falls  $t_i \neq t_j$  für  $i \neq j$  gilt.

Für  $t_1 \neq t_{n+1}$  folgt auch für die Differenzenquotienten nach Definition 1.6:

$$\Delta^n(t_1, \dots, t_{n+1})f = \frac{\Delta^{n-1}(t_1, \dots, t_n)f - \Delta^{n-1}(t_2, \dots, t_{n+1})f}{t_1 - t_{n+1}}, \quad f \in C^n(I)$$

Bei der Anwendung der Differenzenquotienten auf  $e^{tx}$ ,  $x \in \mathbb{R}$ , wird  $t$  als Variable betrachtet; die Differenzierbarkeitsbedingungen sind hier erfüllt und die Gleichungen (1.8), (1.9) und (1.10) sind unmittelbar anzuwenden; insbesondere hat man also:

$$(1.11) \quad \begin{aligned} \Delta^n(t_1, \dots, t_{n+1})e^{tx} &= \\ &= x^n \int_0^1 \int_0^{s_1} \dots \int_0^{s_{n-1}} e^{(t_1 + \sum_{i=1}^n (t_{i+1} - t_i)s_i)x} ds_n \dots ds_1 \end{aligned}$$

**Vereinbarung:**

Da die Differenzenquotienten unabhängig von der Anordnung der Argumente  $t_i$  sind, seien diese o.B.d.A. stets der Größe nach geordnet:  $t_1 \leq t_2 \leq t_3 \leq \dots$

**Hilfsatz 1.1** (Braess, [2])

Es sei  $N \in \mathbb{N}$  und  $t_i \in \mathbb{R}$  für  $1 \leq i \leq N$  mit  $t_i \leq t_{i+1}$  gegeben.

**Behauptung:**

$$\Delta^{N-1}(t_1, \dots, t_N)e^{tx} = \sum_{i=1}^L P_i(x)e^{T_i x} \in V_N ;$$

dabei gilt:  $T_j \in S := \{t_i \mid 1 \leq i \leq N\}$  für  $1 \leq j \leq L$  und für jedes Element  $t \in S$  gibt es ein  $j$  mit  $1 \leq j \leq L$ , so daß  $t = T_j$  erfüllt ist;  $L$  ist also die Zahl der verschiedenen Elemente von  $S$ .

Ferner gilt:

der Grad von  $P_i$  ist kleiner als die Zahl der Elemente von  $S$ , die gleich  $T_i$

sind.

**Beweis:** Vollständige Induktion nach  $N$ :

$N = 1$ :

$$\Delta^0(t_1)e^{tx} = e^{t_1x}$$

Die Behauptung gilt hier offensichtlich; sie sei auch für  $N - 1$  gezeigt.

Induktionsschluß:

1. Fall:  $t_1 = t_N$

Aus (1.10) folgt

$$\Delta^{N-1}(t_1, \dots, t_N)e^{tx} = \frac{1}{(N-1)!} x^{N-1} e^{t_1x}$$

2. Fall:  $t_1 \neq t_N$

Es wird hier

$$\Delta^{N-1}(t_1, \dots, t_N)e^{tx} = \frac{\Delta^{N-2}(t_1, \dots, t_{N-1})e^{tx} - \Delta^{N-2}(t_2, \dots, t_N)e^{tx}}{t_1 - t_N}$$

benutzt.

Aus  $t_1 \neq t_N$  folgt für  $1 \leq i \leq N$ : Gibt es  $m_i$  Komponenten in  $(t_1, \dots, t_N)$  mit dem Wert  $t_i$ , dann gilt dies mindestens für eines der  $(N-1)$ -Tupel  $(t_1, \dots, t_{N-1})$  und  $(t_2, \dots, t_N)$ . Mit der Induktionsannahme ergibt sich damit die Behauptung, da für Polynome  $Q_1, Q_2$  der Differenz auf der rechten Seite die Beziehung  $\text{grad}(Q_1+Q_2) \leq \max(\text{grad}(Q_1), \text{grad}(Q_2))$  gilt.

Die Behauptung ist somit vollständig bewiesen.

**Hilfsatz 1.2** (Braess, [2])

Für  $N \in \mathbb{N}$  und mit  $t_i \in \mathbb{R}$  für  $1 \leq i \leq N$  ist die Menge

$$B = \{\Delta^i(t_1, \dots, t_{i+1})e^{tx} \mid 0 \leq i \leq N-1\}$$

linear unabhängig.

**Beweis:**

Nach Hilfsatz 1.1 ist die Behauptung gezeigt, wenn die Wronski-Determinante der Elemente von  $B$  für  $x = 0$  von Null verschieden ist (vgl. [5], [7]).

Für  $0 \leq m < n$  gilt wegen (1.11):

$$D^m \Delta^n(t_1, \dots, t_{n+1})e^{tx} = x^{n-m} R_{mn}(x), \quad n \leq N-1,$$

wobei  $R_{mn}(x)$  bis auf den Faktor  $x^{n-m}$  die Summe darstellt, die durch  $m$ -fache Anwendung der Produktregel entsteht.

Für  $0 \leq m = n \leq N-1$  erhält man

$$D^m \Delta^n(t_1, \dots, t_{n+1})e^{tx} = n! \int_0^1 \int_0^{s_1} \dots \int_0^{s_{n-1}} e^{(t_1 + \sum_{i=1}^n (t_{i+1} - t_i) s_i)x} ds_n \dots ds_1 + x R_{mm}(x)$$

$R_{mm}(x)$  stellt bis auf den Faktor  $x$  den Rest der bei der Differentiation entstehenden Summe dar.

$$\text{Für } x=0 \text{ folgt: } D^m \Delta^n(t_1, \dots, t_{n+1})e^{tx} = \begin{cases} 0 & : 0 \leq m < n \\ 1 & : 0 \leq m = n \end{cases} \quad n \leq N-1$$

Setzt man für  $x = 0$

$$a_{ij} := D^i \Delta^j(t_1, \dots, t_{j+1})e^{tx}, \quad 0 \leq i, j \leq N-1,$$

so erhält man eine nichtsinguläre Dreiecksmatrix  $(a_{i,j})_{0 \leq i, j \leq N-1}$ , womit die lineare Unabhängigkeit von  $B$  bewiesen ist.

**Satz 1.2** (Braess, [2])

$E(x) = \sum_{i=1}^L P_i(x)e^{T_i x} \in V_N \setminus V_{N-1}$  besitzt eine eindeutige Darstellung durch

$$\text{Differenzenquotienten: } E(x) = \sum_{i=0}^{N-1} b_i \Delta^i(t_1, \dots, t_{i+1})e^x.$$

Die Koeffizienten  $b_i \in \mathbb{R}$  sind für  $0 \leq i < N-1$  eindeutig bestimmt; es gilt

$t_j = T_i$  für  $\sum_{k=1}^{i-1} (\text{grad}(P_k) + 1) \leq j \leq \sum_{k=1}^i (\text{grad}(P_k) + 1)$  und  $1 \leq i < L$ ; dabei sei  $L \in \mathbb{N}$  die Länge von  $E$ .

**Beweis:**

Die Menge

$$U_1 = \left\{ \sum_{i=1}^L Q_i(x)e^{T_i x} \mid Q_i \text{ ist ein reelles Polynom mit } \text{grad}(Q_i) \leq \text{grad}(P_i) \text{ für } 1 \leq i \leq L \right\} \subseteq V_N$$

stellt nach [5], [7] und der Definition von  $V_N$  einen  $N$ -dimensionalen Vektorraum dar. Nach Hilfsatz 1.2 ist  $\{\Delta^i(t_1, \dots, t_{i+1})e^{tx} \mid 0 \leq i \leq N-1\}$  Basis eines  $N$ -dimensionalen reellen Vektorraums  $U_2$  mit  $U_2 \subseteq U_1$  nach Hilfsatz 1.1, falls für die  $t_i$  die Beziehung der Behauptung gilt.

Daraus folgt  $U_1 = U_2$  und damit der erste Teil der Behauptung.

Nach Hilfsatz 1.1 und Satz 1.1 sind auch die  $t_i$  für  $0 \leq i \leq N$  eindeutig bestimmt. Damit ist der Satz gezeigt.

**Bemerkung:**

Es ist also möglich, jedem Element von  $V_N \setminus V_{N-1}$  die  $2N$  Parameter

$$b_0, \dots, b_{N-1}, t_1, \dots, t_N$$

gemäß Satz 1.2 zuzuordnen; verwendet man im Beispiel 1.1 die Darstellung durch Differenzenquotienten, so erhält man:

$$\begin{aligned} E(a_m, x) &= me^{(1+\frac{1}{m})x} - me^x = 0 \times \Delta^0(1)e^{tx} + 1 \times \Delta^1(1, 1 + \frac{1}{m})e^{tx} \\ f(x) &= xe^x = 0 \times \Delta^0(1)e^{tx} + 1 \times \Delta^1(1, 1) e^{tx} \end{aligned}$$

Damit ist  $E(a_m)$  der Parametervektor  $(0, 1, 1, 1 + \frac{1}{m}) \in \mathbb{R}^4$ ,  $m \in \mathbb{N}$ , und  $f$  der Parametervektor  $(0, 1, 1, 1) \in \mathbb{R}^4$  zugeordnet; die Konvergenz der Folge ist hier an den Parametern zu erkennen.

Es wird hierzu später benötigt:

### Hilfsatz 1.3

Mit  $n \in \mathbb{N}$  seien in  $\mathbb{R}$  die Folgen  $(t_{j,m})_{m \in \mathbb{N}}$ ,  $1 \leq j \leq n+1$ , mit  $t_{j,m} < t_{j+1,m}$  und  $\lim_{m \rightarrow \infty} t_{j,m} = t_j \in \mathbb{R}$ ,  $1 \leq j \leq n+1$ , gegeben; weiter sei entweder  $t_j < t_{j+1}$ ,  $1 \leq j \leq n$ , oder  $t_j = t$ ,  $1 \leq j \leq n+1$ , erfüllt.

Dann konvergiert die Folge  $(\Delta^n(t_{1,m}, \dots, t_{n+1,m})e^{tx})_{m \in \mathbb{N}}$  auf  $I = [a, b]$  gleichmäßig gegen  $\Delta^n(t_1, \dots, t_{n+1})e^{tx}$ .

**Beweis:** (nach [13])

Die Funktion  $f$  sei holomorph in  $\mathbb{C}$ .

Für  $s_j \in \mathbb{R}$ ,  $1 \leq j \leq n$ , mit  $s_j < s_{j+1}$ ,  $1 \leq j \leq n-1$ , oder  $s_j = s$ ,  $1 \leq j \leq n$ , wird durch vollständige Induktion nach  $n$  gezeigt:

$$(1.12) \quad \Delta^{n-1}(s_1, \dots, s_n)f = \frac{1}{2\pi i} \int_K f(z) \prod_{j=1}^n (z - s_j)^{-1} dz$$

wobei  $K = \{z \in \mathbb{C} \mid R = |z|\}$  mit  $\max_{1 \leq j \leq n} |s_j| < R < \infty$  sei.

$n = 1$ :

$$\Delta^0(s_1)f = f(s_1) = \frac{1}{2\pi i} \int_K f(z)(z - s_1)^{-1} dz .$$

Gilt (1.12) für  $n$ , dann folgt:

Für  $s_1 \neq s_{n+1}$  erhält man

$$\begin{aligned} \Delta^n(s_1, \dots, s_{n+1})f &= \frac{\Delta^{n-1}(s_1, \dots, s_n)f - \Delta^{n-1}(s_2, \dots, s_{n+1})f}{s_1 - s_{n+1}} = \\ &= \frac{1}{s_1 - s_{n+1}} \frac{1}{2\pi i} \int_K [f(z)(z - s_{n+1}) - f(z)(z - s_1)] \prod_{j=1}^{n+1} (z - s_j)^{-1} dz = \\ &= \frac{1}{2\pi i} \int_K f(z) \prod_{j=1}^{n+1} (z - s_j)^{-1} dz \end{aligned}$$

Aus (1.10) und dem Cauchyschen Integralsatz für Ableitungen folgt für  $s_j = s$ ,  $1 \leq j \leq n+1$ , unmittelbar

$$\Delta^n(s, \dots, s)f = \frac{1}{2\pi i} \int_K f(z) \prod_{j=1}^{n+1} (z - s_j)^{-1} dz$$

Damit ist (1.12) vollständig gezeigt.

Es sei nun  $\max\{\max_{1 \leq i \leq n+1} |t_i|, 1\} < R < \infty$ .

Es kann o.B.d.A.  $|t_{j,m}| < \frac{3}{2}R$  für  $1 \leq j \leq n+1$  angenommen werden.

Für  $x \in I$  und  $z \in \mathbb{C}$  mit  $|z| = 2R$  erhält man:

$$\begin{aligned} & \left| e^{zx} \prod_{j=1}^{n+1} (z - t_j)^{-1} - e^{zx} \prod_{j=1}^{n+1} (z - t_{j,m})^{-1} \right| = \\ & = \left| e^{zx} \left| \prod_{j=1}^{n+1} (z - t_{j,m}) - \prod_{j=1}^{n+1} (z - t_j) \right| \prod_{j=1}^{n+1} (|z - t_j| |z - t_{j,m}|)^{-1} \right| \leq \\ & \leq e^{2R(|a|+|b|)} \left(R \frac{R}{2}\right)^{-n-1} \left| \sum_{j=0}^n z^j (S_{j,m} - S_j) \right| \leq \\ & \leq e^{2R(|a|+|b|)} \left(R \frac{R}{2}\right)^{-n-1} (2R)^{n+1} \sum_{j=0}^n |S_{j,m} - S_j| := M \sum_{j=0}^n |S_{j,m} - S_j| ; \end{aligned}$$

dabei sind  $S_j$  bzw.  $S_{j,m}$  die elementarsymmetrischen Funktionen von  $t_k$ ,  $1 \leq k \leq n+1$ . Mit den Ergebnissen von oben erhält man für alle  $x \in I$

$$\begin{aligned} & \left| \Delta^n(t_1, \dots, t_{n+1})e^{tx} - \Delta^n(t_{1,m}, \dots, t_{n+1,m})e^{tx} \right| \leq \\ & \leq \frac{1}{2\pi} 4R\pi M \sum_{j=0}^n |S_{j,m} - S_j| \end{aligned}$$

Wegen  $\lim_{m \rightarrow \infty} \sum_{j=0}^n |S_{j,m} - S_j| = 0$  folgt damit die Behauptung.

### 1.3 Vorzeichenklassen in $V_N$

Ein weiteres Hilfsmittel zur Beschreibung der Struktur von  $V_N$ , soweit dies hier erforderlich ist, liefert die Einführung von Vorzeichenklassen in  $V_N$  nach Braess, [2].

Da, wie in Abschnitt 1.1 angekündigt, die Existenz einer besten Approximation einmal durch Erweiterung von  $V_N^0$  und zum anderen durch Beschränkung auf geeignete Teilmengen, zum Beispiel  $V_N^+$  oder  $V_N^-$  gesichert werden kann, liegt es nahe, die Vorzeichen der Summanden in Exponentialsummen zu untersuchen.

Jeder Exponentialsumme wird rekursiv ein *Vorzeichenvektor* zugeordnet:

#### Definition 1.7

- a.  $E(x) = \left(\sum_{i=0}^n a_i x^i\right) e^{tx}$  mit  $a_n \neq 0$  und  $s = \text{sign}(a_n)$  hat den Vorzeichenvektor  $\text{sign}(E)$  mit  $n + 1$  Komponenten:

$$\text{sign}(E) := ((-1)^n s, \dots, (-1)^1 s, s)$$

Dabei ist für  $a \in \mathbb{R}$   $\text{sign}(a) := \begin{cases} 1 & \text{für } a > 0 \\ 0 & \text{für } a = 0 \\ -1 & \text{für } a < 0 \end{cases}$

- b. Für  $E_1, E_2 \in V_N$  seien die Frequenzen von  $E_1$  kleiner als die von  $E_2$ ;  $\text{sign}(E_j)$  habe  $m_j$  Komponenten,  $j = 1, 2$ .  
Dann hat  $E_1 + E_2$  den Vorzeichenvektor  $\text{sign}(E_1 + E_2)$  mit  $m_1 + m_2$  Komponenten; dabei sind die ersten  $m_1$  Komponenten die von  $\text{sign}(E_1)$ , die restlichen  $m_2$  Komponenten die von  $\text{sign}(E_2)$ :

$$\text{sign}(E_1 + E_2) := (\text{sign}(E_1), \text{sign}(E_2))$$

Beispiele hierzu:

- $\text{sign}((x + 5)e^{-3x}) = (-1, 1)$
- $\text{sign}(4e^x) = (1)$
- $\text{sign}(-x^2 e^{2x}) = (-1, 1, -1)$
- $\text{sign}((x + 5)e^{-3x} + 4e^x - x^2 e^{2x}) = (-1, 1, 1, -1, 1, -1)$

**Bemerkung:**

- a. Die Zahl der Komponenten des Vorzeichenvektors  $sign(E)$  ist gleich dem Grad von  $E$ .
- b. Für  $E(x) = \sum_{i=1}^N a_i e^{t_i x}$  mit  $grad(E) = N$  gibt die  $i$ -te Komponente von  $sign(E)$  das Vorzeichen von  $a_i$  an.

**Definition 1.8**

Es sei  $S$  ein Vorzeichenvektor mit  $N$  Komponenten.

- a.  $V_N(S) := \{E \mid E \in V_N, (sign(E) = S) \vee (\text{man erh\u00e4lt } sign(E) \text{ aus } S \text{ durch Streichen von Komponenten in } S) \}$   
 $V_N(S)$  ist die *Vorzeichenklasse* zu  $S$  in  $V_N$ .
- b.  $V_N^0(S) := V_N(S) \cap V_N^0$

**Bemerkung 1.3**

- a.  $V_N^+ = V_N^0(1, 1, \dots, 1) = V_N(1, 1, \dots, 1)$   
Entsprechendes gilt f\u00fcr  $V_N^-$ .
- b.  $E \in V_N$  mit  $grad(E) < N$  geh\u00f6rt zu mehreren Vorzeichenklassen in  $V_N$ , wie die Beispiele zu Definition 1.6 zeigen.  
Nur die Elemente von  $V_N \setminus V_{N-1}$  geh\u00f6ren zu genau einer Vorzeichenklasse, so da\u00df damit in  $V_N \setminus V_{N-1}$  eine Einteilung in disjunkte Teilmengen erkl\u00e4rt ist.

Der folgende Satz stellt eine Beziehung zwischen der Zahl der Nullstellen einer Exponentialsumme und ihrem Vorzeichenvektor her.

**Satz 1.3** (Braess, [1])

**Voraussetzung:**

Es sei  $E \in V_N$  mit  $grad(E) = N \geq 1$  gegeben und  $E$  besitze  $m$  reelle Nullstellen.

**Behauptung:**

In  $S = sign(E)$  gibt es mindestens  $m$  Vorzeichenwechsel, d.h. es gibt mindestens  $m$  Komponenten  $S_i$  von  $S$  mit  $S_i \neq S_{i+1}$ .

**Beweis:**

Vollst\u00e4ndige Induktion nach  $N$ :

$N=1$ :  $E(x) = ae^{tx}$  besitzt nach Voraussetzung keine reelle Nullstelle.

Der Satz sei gezeigt f\u00fcr  $N-1$ .

Induktionsschluß:

$E(x) = \sum_{i=1}^L P_i(x)e^{t_i x} \in V_N$  mit der Länge  $L$  habe  $m > 0$  reelle Nullstellen; für  $m = 0$  ist nichts zu zeigen.

In  $S$  liegt damit mindestens ein Vorzeichenwechsel vor, denn sonst gilt nach Bemerkung 1.3a  $|E(x)| > 0$  für  $x \in \mathbb{R}$  im Widerspruch zu  $m > 0$ .

Es sei also  $w > 0$  die Zahl der Vorzeichenwechsel in  $S$ ;  $k$  sei der kleinste Index mit  $S_k = -S_{k+1}$ .

Fall 1:

$$E(x) = \sum_{i=1}^k a_i e^{t_i x} + \sum_{i=k+1}^L P_i(x) e^{t_i x}$$

Für  $E_1(x) = e^{-t_k x} E(x)$  gilt

$$DE_1(x) = \sum_{i=1}^{k-1} (t_i - t_k) a_i e^{(t_i - t_k)x} + \sum_{i=k+1}^L DP_i(x) + P_i(x)(t_i - t_k) e^{(t_i - t_k)x}$$

$E_1$  hat die gleichen Nullstellen wie  $E$  und  $\text{sign}(E_1) = \text{sign}(E)$ . Beachtet man  $t_i < t_k$  für  $i < k$ , so liegen in  $\text{sign}(DE_1)$   $w - 1$  Vorzeichenwechsel vor. Nach dem Satz von Rolle besitzt  $DE_1$  mindestens  $m - 1$  reelle Nullstellen. Wegen  $DE_1 \in V_{N-1}$  erhält man nach Induktionsannahme  $w - 1 \geq m - 1$ , also  $w \geq m$ .

Fall 2:

$$E(x) = \sum_{i=1}^L P_i(x) e^{t_i x} \text{ mit } \text{grad} P_1 \geq 1$$

Es ist also  $k = 1$ .

$$\begin{aligned} E_1(x) &= e^{-t_1 x} E(x) = P_1(x) + \sum_{i=2}^L P_i(x) e^{(t_i - t_1)x} \\ DE_1(x) &= DP_1(x) + \sum_{i=2}^L (DP_i(x) + (t_i - t_1)P_i(x)) e^{(t_i - t_1)x} \end{aligned}$$

In  $\text{sign}(DE_1)$  liegen  $w - 1$  Vorzeichenwechsel vor, wie man durch Vergleich mit  $E_1$  erkennt; damit folgt wie in Fall 1:  $w \geq m$ .

Fall 3:

$$E(x) = \sum_{i=1}^{k-1} a_i e^{t_i x} + \sum_{i=k}^L P_i(x) e^{t_i x} \text{ mit } \text{grad}(P_k) \geq 1$$

$$E_1(x) = e^{-t_k x} E(x) = \sum_{i=1}^{k-1} a_i e^{(t_i - t_k)x} + P_k(x) + \sum_{i=k+1}^L P_i(x) e^{(t_i - t_k)x}$$

$$\begin{aligned} DE_1(x) &= \sum_{i=1}^{k-1} a_i (t_i - t_k) e^{(t_i - t_k)x} + DP_k(x) + \\ &+ \sum_{i=k+1}^L (DP_i(x) + P_i(x)(t_i - t_k)) e^{(t_i - t_k)x} \end{aligned}$$

Mit den gleichen Überlegungen wie oben erhält man auch hier  $w \geq m$ .

Damit ist der Satz bewiesen.

## 2 Existenzsätze

### 2.1 Gleichmäßige Konvergenz im Innern

In diesem Kapitel sei  $I$  stets das Intervall  $[a, b]$  mit  $a < b$ .

Während bei linearer Approximation die Existenz einer Minimallösung stets gesichert ist, können Existenzsätze für nichtlineare Approximation nur unter einschneidenden Voraussetzungen bewiesen werden.

Für  $V \subseteq C(I)$  hat Rice in [15] gezeigt:

Es existiert eine beste Approximation an  $f \in C(I)$  bezüglich  $V$  auf  $I$ , wenn  $V$  den beiden folgenden Forderungen genügt:

1. Für  $u, v \in V$  gilt:  $u - v$  besitzt in  $I$  höchstens  $n$  Nullstellen oder verschwindet auf  $I$  identisch.
2. Jede punktweise konvergente Folge in  $V$  konvergiert gegen ein Element von  $V$ .

Aus Forderung 1 folgt für jede auf  $I$  gleichmäßig beschränkte Teilmenge von  $V$  die Existenz einer auf  $I$  punktweise konvergenten Folge und mit Forderung 2 folgt daraus die Existenz einer besten Approximation bezüglich  $V$  ([15], Theorem 7-2).

Dabei heißt  $U \subseteq C(I)$  *gleichmäßig beschränkt* auf  $I$ , wenn es ein  $K < \infty$  gibt mit

$$\|u\|_I \leq K \text{ für } u \in U$$

$V_N$  genügt der ersten Forderung mit  $n = 2N - 1$  nach Satz 1.1, nicht jedoch der zweiten:

#### Beispiel 2.1

Man betrachte in  $[0, 1]$  die Funktionen  $E(a_m, x) = e^{-mx} + e^{m(x-1)} \in V_2^0$  für  $m \in \mathbb{N}$ :

$$\lim_{m \rightarrow \infty} E(a_m, x) = \begin{cases} 1 & : x = 0 \\ 0 & : x \in (0, 1) \\ 1 & : x = 1 \end{cases}$$

Will man beim Nachweis der Existenz einer Minimallösung bezüglich  $V_N$  analog vorgehen, so muß man also einen anderen Konvergenzbegriff verwenden; es wird definiert:

**Definition 2.1**

Eine Folge von Funktionen aus  $C(I)$  *konvergiert gleichmäßig im Innern* von  $I$  gegen  $g \in C(I)$ , wenn sie auf jedem abgeschlossenen Teilintervall von  $(a, b)$  gleichmäßig gegen  $g$  konvergiert.

Die in Beispiel 2.1 gegebene Folge  $(E(a_m))_{m \in \mathbb{N}}$  konvergiert im Innern von  $[0, 1]$  gleichmäßig gegen ein Element von  $V_2$ , nämlich die Nullfunktion; es zeigt sich, daß dies allgemein für jede gleichmäßig beschränkte Folge in  $V_N$  gilt und daß diese Eigenschaft die Existenz einer besten Approximation gewährleistet. Der Beweis wird für eine allgemeinere Menge von Funktionen durchgeführt, die eine der Forderung 2 entsprechende Eigenschaft besitzt:

**Definition 2.2**

$$DZ^n(I) := \{h \mid h \in C^{n+1}(I), \quad D^{n+1}h \text{ hat in } I \text{ höchstens } n - 1 \text{ Nullstellen} \\ \text{oder verschwindet auf } I \text{ identisch } \}, \quad n \in \mathbb{N}$$

**Bemerkung 2.1**

Nach Satz 1.1 und Bemerkung 1.2 gilt  $V_N \subseteq DZ^N(I)$  für  $N \in \mathbb{N}$ .

**Definition 2.3**

Für  $d > 0$ ,  $h \in C^n(I)$  und  $n \in \mathbb{N}$  wird gesetzt:

$$Z^m(h) := \begin{cases} \emptyset & : D^m h \equiv 0 \text{ auf } I \\ \{x \in I \mid D^m h(x) = 0\} & : D^m h \not\equiv 0 \text{ auf } I \end{cases} \quad 0 \leq m \leq n$$

$$I^m(h, d) := \{x \in I \mid (m \times d) \leq |x - z| \text{ für } z \in \{a, b\} \cup \bigcup_{i=0}^{m+1} Z^i(h)\}, \\ 0 \leq m \leq n - 1$$

**Hilfsatz 2.1** (Werner, [20])

Es sei  $n \in \mathbb{N}$  und  $h \in C^{n+1}(I)$  gegeben. Mit  $d > 0$  sei  $I^i(h, d)$  nicht leer,  $0 \leq i \leq n$ .

**Behauptung:**

$$\|D^i h\|_{I^i(h, d)} \leq d^{-i} \|h\|_I \quad 0 \leq i \leq n$$

**Beweis:** Vollständige Induktion nach  $i$ :

Man setze  $K_{-1} := d^{-(i-1)} \|h\|_I$  für  $i \in \mathbb{N}$ .

Für  $i = 0$  ist nichts zu zeigen.

Die Behauptung sei für  $i - 1 < n$  gezeigt, d.h. mit  $g = D^{i-1}h$  gilt:  
 $\|g\|_{I^{i-1}(h,d)} \leq K_{i-1}$

Induktionsschluß:

In  $I$  sei  $Dg \neq 0$ , sonst ist nichts zu zeigen.

Mit den Punkten von  $Z^{i+1}(h)$  erhält man in  $I^{i-1}(h, d)$  abgeschlossene Teilintervalle  $J_k$ ; falls  $Z^{i+1}(h)$  leer ist oder für  $x \in I^{i-1}(h, d)$  stets  $D^{i+1}h(x) \neq 0$  gilt, sind die  $J_k$  die Teilintervalle, die  $I^{i-1}(h, d)$  bilden.

Die Teilintervalle, die mit  $I^i(h, d)$  einen nichtlinearen Durchschnitt besitzen, seien o.B.d.A. die Intervalle  $J_k$ ,  $1 \leq k \leq K < \infty$ . Nach Definition 2.3 gilt für  $1 \leq k \leq K$ :

- a.  $Dg$  ist in  $J_k$  monoton und wechselt sein Vorzeichen nicht.
- b. In  $J_k$  nimmt  $|Dg|$  sein Maximum in einem Randpunkt  $u_k \in J_k$  an, wobei gilt:  $u_k \in Z^{i+1}(h)$  oder  $u_k$  gehört zum Rand von  $I^{i-1}(h, d)$ .

Es sei nun  $x \in J_k$ . Nach Induktionsannahme gilt  $|g(x) - g(u_k)| \leq K_{i-1}$  und mit dem Mittelwertsatz der Integralrechnung erhält man

$$|g(x) - g(u_k)| = \left| \int_{u_k}^x Dg(t) dt \right| = |x - u_k| |Dg(t_0)|$$

für ein  $t_0 \in (u_k, x)$  bzw.  $t_0 \in (x, u_k)$ .

Da  $Dg$  in  $J_k$  sein Vorzeichen nicht wechselt, ergibt sich mit Punkt b:

$$|Dg(t_0)| \geq |Dg(x)| \text{ und damit } K_{i-1} \geq |x - u_k| |Dg(x)|.$$

Gilt insbesondere  $x \in I^i(h, d) \cap J_k$ , dann folgt  $|x - u_k| \geq d$  und damit  $K_{i-1} \geq d |Dg(x)|$ .

Für  $x \in I^i(h, d)$  hat man also erhalten:  $|D^i h(x)| \leq d^{-1} K_{i-1} = d^{-i} \|h\|_I$ ; dies war zu zeigen.

Eine weitere Abschätzung für  $Dh$  liefert Hilfssatz 2.2:

**Hilfsatz 2.2** (Schmidt, [17])

Es sei  $n \in \mathbb{N}$  und  $h \in DZ^n(I)$  gegeben. Mit  $d = b - a$  und

$$K := \max_{1 \leq i \leq n} \max\{|D^i h(a)|, |D^i h(b)|\}$$

gilt:

$$\|Dh\|_I \leq K \sum_{j=0}^{n-1} d^j$$

**Beweis:**

Nach Definition von  $K$  gilt

$$| Dh(a) | \leq K \sum_{j=0}^{n-1} d^j \geq | Dh(b) |$$

Es ist also noch zu zeigen:

$$| Dh(x) | \leq K \sum_{j=0}^{n-1} d^j \quad x \in (a, b)$$

**Beweisschritt 1:**

Rekursiv wird definiert:

$$\begin{aligned} K_1 &:= K \sum_{j=0}^{n-1} d^j \\ K_i &:= (K_{i-1} - K) d^{-1} \quad 2 \leq i \leq n \end{aligned}$$

Vollständige Induktion nach  $i$  ergibt:

$$(2.1) \quad K_i = K \sum_{j=0}^{n-i} d^j \quad 1 \leq i \leq n$$

Für  $i = 1$  ist nichts zu zeigen; es gelte (2.1) für  $i < n$ .

Induktionsschluß:

$$K_{i+1} = (K_i - K) d^{-1} = K d^{-1} \left( \sum_{j=0}^{n-i} d^j - 1 \right) = K d^{-1} \sum_{j=1}^{n-i} d^j = K \sum_{j=0}^{n-i-1} d^j$$

Damit ist (2.1) vollständig gezeigt.

Unmittelbar folgt hieraus:

$$(2.2) \quad K_i \geq K \quad 1 \leq i \leq n$$

**Beweisschritt 2:**

Annahme: die Behauptung des Satzes ist falsch, es gibt ein  $x_0 \in (a, b)$  mit

$$| Dh(x_0) | > K \sum_{j=0}^{n-1} d^j$$

Durch vollständige Induktion nach  $i$  wird gezeigt:

$$(2.3) \quad D^i h \text{ besitzt in } (a, b) \text{ } i - 1 \text{ Nullstellen } x_1^i < x_2^i < \dots < x_{i-1}^i$$

und es ist  $|D^{i-1}h(x_r^i)| > K_{i-1}$ ,  $r \in \{1, i-1\}$ , für  $2 \leq i \leq n+1$

$i = 2$ :  $|Dh(a)| \leq K_1 \leq |Dh(b)|$  gilt nach Voraussetzung.

Wegen  $|Dh(x_0)| > K_1 \geq K$  und  $h \in C^{m+1}(I)$  gibt es ein  $x_1^2 \in (a, b)$  mit  $|Dh(x_1^2)| > K_1$  und  $D^2h(x_1^2) = 0$ .

Damit ist (2.3) für  $i = 2$  gezeigt.

Induktionsannahme: (2.3) gilt für  $i < n+1$ .

Induktionsschluß: Für  $i+1$  erhält man mit dem Satz von Rolle:

$$(2.4) \quad D^{i+1}h \text{ hat in } (x_1^i, x_{i-1}^i) \text{ mindestens } i - 2$$

$$\text{Nullstellen } x_2^{i+1} < x_3^{i+1} < \dots < x_{i-1}^{i+1}$$

Der Mittelwertsatz der Differentialrechnung liefert mit der Induktionsannahme:

Es gibt ein  $x_1 \in (a, x_1^i)$  und ein  $x_2 \in (x_{i-1}^i, b)$  mit

$$D^i h(x_1) = \frac{D^{i-1}h(x_1^i) - D^{i-1}h(a)}{x_1^i - a} \quad \text{und} \quad D^i h(x_2) = \frac{D^{i-1}h(b) - D^{i-1}h(x_{i-1}^i)}{b - x_{i-1}^i}$$

Es folgt:

$$\begin{aligned} |D^i h(x_1)| &\geq \frac{|D^{i-1}h(x_1^i)| - |D^{i-1}h(a)|}{|x_1^i - a|} \quad \text{und} \\ |D^i h(x_2)| &\geq \frac{|D^{i-1}h(x_{i-1}^i)| - |D^{i-1}h(b)|}{|x_{i-1}^i - b|} \end{aligned}$$

Mit  $D^i h(x_1^i) = D^i h(x_{i-1}^i) = 0$ ,  $|D^{i-1}h(a)| \leq K \leq |D^{i-1}h(b)|$ ,  $|x_1^i - a| < d > |b - x_{i-1}^i|$  und der Induktionsannahme erhält man:

$$|D^i h(x_1)| > (K_{i-1} - K)d^{-1} = K_i < |D^i h(x_2)|$$

Wie oben folgt mit (2.2): Es gibt ein  $x_1^{i+1} \in (a, x_1^i)$  und ein  $x_i^{i+1} \in (x_{i-1}^i, b)$  mit

$$\begin{aligned} |D^i h(x_1^{i+1})| &> K_i, \quad D^{i+1}h(x_1^{i+1}) = 0 \quad \text{und} \\ |D^i h(x_i^{i+1})| &> K_i, \quad D^{i+1}h(x_i^{i+1}) = 0 \end{aligned}$$

Mit (2.4) erhält man insgesamt:  $D^{i+1}h$  besitzt in  $(a, b)$   $(i - 2) + 2 = i$  Nullstellen  $x_1^{i+1} < x_2^{i+1} < \dots < x_i^{i+1}$  mit

$$|D^i h(x_r^{i+1})| > K_i, r \in \{1, i\}$$

Damit ist (2.3) gezeigt.

Auf  $i = n + 1$  angewandt erhält man:

$D^{n+1}h$  besitzt in  $(a, b)$   $n$  Nullstellen  $x_1^{n+1} < x_2^{n+1} < \dots < x_n^{n+1}$  und  $D^{n+1}h$  verschwindet auf  $I$  nicht identisch. Dies steht im Widerspruch zu  $h \in DZ^n(I)$ . Damit ist die Annahme widerlegt und die Behauptung des Satzes gilt.

Nach Bemerkung 1.2 folgt aus Hilfssatz 2.2 wegen  $V_N \subseteq DZ^N(I)$  unmittelbar

**Korollar 2.1**

Für  $h \in V_N$  mit  $N \in \mathbb{N}$  gilt

$$\|D^m h\|_I \leq K_m \sum_{j=0}^{N-1} d^j \quad m \in \mathbb{N}$$

wobei  $d = b - a$  und  $K_m = \max_{m \leq i \leq m+N-1} \max\{|D^i h(a)|, |D^i h(b)|\}$  ist.

**Satz 2.1** (Schmidt, [17])

Es sei  $n \in \mathbb{N}$  und  $I_1 = [a_1, b_1] \subseteq (a, b)$  mit  $d_0 = \min\{a_1 - a, b - b_1\} > 0$  gegeben,  $d = b - a$ .

**Behauptung:** Es gibt ein  $K(I, I_1) < \infty$ , so daß jedes  $h \in DZ^n(I)$  erfüllt:

$$\|Dh\|_{I_1} \leq K(I, I_1) \|Dh\|_I$$

**Beweis:**

**Beweisschritt 1:**

Für  $h \in DZ^n(I)$  gilt  $|Z^{n+1}(h)| \leq n - 1$  und aus dem Satz von Rolle folgt  $|Z^i(h)| \leq |Z^{i+1}(h)| + 1$  für  $0 \leq i \leq n$ . Damit erhält man:

$$(2.5) \quad |Z^{n+1-k}(h)| \leq |Z^{n+1}(h)| + k \leq n - 1 + k \text{ für } 0 \leq k \leq n + 1$$

Für  $k = 0$  gilt (2.5) unmittelbar.

Für  $k < n + 1$  sei (2.5) gezeigt; es ergibt sich damit  $|Z^{n+1-(k+1)}(h)| \leq |Z^{n+1-k}(h)| + 1 \leq n - 1 + (k + 1)$  nach Induktionsannahme und (2.5) ist gezeigt.

Für jedes  $h \in DZ^n(I)$  erhält man damit

$$\begin{aligned} s = \sum_{k=0}^{n+1} (n - 1 + k) &= (n + 2)(n - 1) + \sum_{k=0}^{n+1} k = (n + 2) \frac{3n - 1}{2} \geq \\ &\geq \sum_{i=0}^{n+1} Z^i(h) \end{aligned}$$

**Beweisschritt 2:**

Wegen  $3 \leq s < \infty$  für  $n \in \mathbb{N}$  existieren für jedes  $h \in DZ^n(I)$  abgeschlossene Intervalle  $I_1(h)$ ,  $I_2(h)$  mit der Länge  $d_1 = \frac{d_0}{2(s+1)} > 0$ , die  $I_1(h) \subseteq (a, a_1]$ ,

$I_2(h) \subseteq [b_1, b)$  und  $I_j(h) \cap \bigcup_{i=0}^{n+1} Z^i(h) = \emptyset$  für  $j = 1, 2$  erfüllen.

(  $[a, b]$  hat die Länge  $b - a$ ,  $\frac{a+b}{2}$  ist die Intervallmitte)

Es seien  $a(h)$  bzw.  $b(h)$  die Intervallmitten von  $I_1(h)$  bzw.  $I_2(h)$  und es gilt daher

$$|a(h) - z| > \frac{d_1}{2} < |b(h) - z| \quad \text{für } z \in \bigcup_{i=0}^{n+1} Z^i(h)$$

Hilfssatz 2.1 ergibt für  $a(h), b(h)$ :

$$|D^i h(a(h))| \leq \|h\|_I \left(\frac{d_1}{2n}\right)^{-i} \geq |D^i h(b(h))|, \quad 0 \leq i \leq n$$

Mit  $K := \|h\|_I \max_{1 \leq i \leq n} \left(\frac{d_1}{2n}\right)^{-i}$  gilt also für  $1 \leq i \leq n$

$$|D^i h(a(h))| \leq K \geq |D^i h(b(h))|$$

Hilfssatz 2.2, angewandt auf  $I(h) = [a(h), b(h)]$ , ergibt

$$\|Dh\|_{I(h)} \leq K \sum_{j=0}^{n-1} (b(h) - a(h))^j \leq K \sum_{j=0}^{n-1} d^j$$

Aus  $I_1 \subseteq I(h)$  folgt

$$\|Dh\|_{I_1} \leq \|h\|_I \max_{1 \leq i \leq n} \left(\frac{d_1}{2n}\right)^{-i} \sum_{j=0}^{n-1} d^j$$

Mit  $K(I, I_1) := \max_{1 \leq i \leq n} \left(\frac{d_1}{2n}\right)^{-i} \sum_{j=0}^{n-1} d^j$  erhält man die Behauptung für jedes  $h \in$

$DZ^n(I)$ , da  $K(I, I_1)$  allein durch die Größen  $d$  und  $d_0$  und damit durch  $I$  und  $I_1$  bestimmt ist.

Speziell für  $h \in V_N$  läßt sich mehr aussagen:

**Satz 2.2** (Werner, [21])

Es sei  $n \in \mathbb{N}$  und  $I_1$ ,  $d$  und  $d_0$  wie in Satz 2.1. Für jedes  $j \in \mathbb{N}$  gibt es ein  $K(j, I, I_1) < \infty$ , so daß für  $h \in V_N$  gilt:

$$\| D^j h \|_{I_1} \leq K(j, I, I_1) \| h \|_I$$

**Beweis:** (analog zu Satz 2.1)

**Beweisschritt 1:**

Wegen Satz 1.1 gilt hier für alle  $h \in V_N$ :

$$s_n = (N - 1)(n + 2) \geq \left| \bigcup_{i=0}^{n+1} Z^i(h) \right| \quad n \in \mathbb{N}$$

**Beweisschritt 2:**

Es sei  $n \in \mathbb{N}$ .

Mit  $0 \leq s_n \leq \infty$  existieren für jedes  $h \in V_N$  Intervalle  $I_1(h)$  und  $I_2(h)$  mit

der Länge  $d_n = \frac{d_0}{2(s_n + 1)}$ , so daß gilt:

$$I_1(h) \subseteq (a, a_1], I_2(h) \subseteq [b_1, b) \text{ und } I_j(h) \cap \bigcup_{i=0}^{n+1} Z^i(h) = \emptyset, \quad j = 1, 2$$

Man erhält wieder (Bezeichnungen wie oben):

$$\left| D^i h(a(h)) \right| \leq \| h \|_I \left( \frac{d_n}{2n} \right)^{-i} \geq \left| D^i h(b(h)) \right| \quad i \in \mathbb{N}, i \leq n$$

Mit  $K_j := \max_{j \leq i \leq N+j-1} \left( \frac{d_n}{2n} \right)^{-i} \| h \|_I$  für  $j \in \mathbb{N}$  gilt für  $j \leq i \leq N + j - 1$  mit

$N + j - 1 \leq n$ :  $\left| D^i h(a(h)) \right| \leq K_j \geq \left| D^i h(b(h)) \right|$ .

Nach Korollar 2.1 folgt für  $N + j - 1 \leq n$ :

$$\begin{aligned} \| D^j h \|_{I(h)} &\leq \left[ \sum_{j=0}^{N-1} (b(h) - a(h))^j \right] K_j, \text{ also} \\ \| D^j h \|_{I_1} &\leq \| h \|_I K(j, I, I_1) \end{aligned}$$

wobei für  $j \in \mathbb{N}$  mit  $N+j-1 \leq n$  gesetzt wird:  $K(j, I, I_1) := \max_{j \leq i \leq N+j-1} \left( \frac{d_n}{2n} \right)^{-i} \sum_{j=0}^{N-1} d^j$

Da  $n \in \mathbb{N}$  beliebig angenommen war, gilt die Behauptung.

Wir sind nun in der Lage, einen Satz zu beweisen, der Theorem 7-2 in [15] entspricht:

**Satz 2.3** (Schmidt, [17])

Mit  $n \in \mathbb{N}$  sei  $M \subseteq DZ^n(I)$  auf  $I$  gleichmäßig beschränkt.

**Behauptung:**

Es gibt eine Folge von Elementen aus  $M$ , die im Innern von  $I$  gleichmäßig konvergiert.

**Beweis:**

Es sei  $(I_n)_{n \in \mathbb{N}}$  eine Intervallfolge in  $I$  mit  $(I_n) = [a_n, b_n]$ ,

$$a_n = a + \frac{b-a}{n+2}, \quad b_n = b + \frac{b-a}{n+2}$$

Nach Voraussetzung gibt es ein  $K < \infty$  mit  $\|h\|_I < K$  für alle  $h \in M$ . Damit ist  $M$  auch gleichmäßig stetig in  $I_n$  für  $n \in \mathbb{N}$ :

Denn nach Satz 2.1 gibt es ein  $K(I, I_n) < \infty$ , so daß für  $h \in M$  gilt:

$$\|Dh\|_{I_n} \leq K(I, I_n) \|h\|_I \leq K(I, I_n)K := K_n < \infty$$

Für  $n \in \mathbb{N}$  und  $x_1, x_2 \in I$  mit  $x_1 < x_2$  existiert nach dem Mittelwertsatz der Differentialrechnung ein  $x \in (x_1, x_2)$  mit  $|h(x_1) - h(x_2)| = |Dh(x)| |x_1 - x_2|$ . Hieraus folgt für alle  $h \in M$   $|h(x_1) - h(x_2)| \leq K_n |x_1 - x_2|$ , womit die gleichmäßige Stetigkeit von  $M$  auf  $I_n$ ,  $n \in \mathbb{N}$ , nachgewiesen ist.

Nach dem Satz von Ascoli ([6], S. 127) erhält man:

In  $M$  existiert eine auf  $I_1$  gleichmäßig konvergente Folge  $(h_{1,m})_{m \in \mathbb{N}}$ .

$(h_{1,m})_{m \in \mathbb{N}} \subseteq M$  ist gleichmäßig beschränkt auf  $I$  und gleichmäßig stetig auf  $I_2$ .

Damit enthält  $(h_{1,m})_{m \in \mathbb{N}}$  eine auf  $I_2$  gleichmäßig konvergente Folge  $(h_{2,m})_{m \in \mathbb{N}}$ .

Wegen  $(h_{2,m})_{m \in \mathbb{N}} \subseteq M$  enthält wiederum  $(h_{2,m})_{m \in \mathbb{N}}$  eine Folge  $(h_{3,m})_{m \in \mathbb{N}}$ , die

auf  $I_3$  gleichmäßig konvergiert, usw.; man erhält so für  $n \in \mathbb{N}$  Teilfolgen

$(h_{n,m})_{m \in \mathbb{N}} \subseteq M$ , die auf  $I_n$ , und damit auch auf  $I_j$ ,  $1 \leq j \leq n$ , gleichmäßig

konvergieren.

Wegen  $h_{m,m} \in (h_{n,j})_{j \in \mathbb{N}}$  für  $m \geq n$  folgt (Auswahl nach dem Diagonalverfahren):  $(h_{m,m})_{m \in \mathbb{N}} \subseteq M$  konvergiert gleichmäßig auf  $I_n$  für alle  $n \in \mathbb{N}$ .

Nach Konstruktion von  $(I_n)_{n \in \mathbb{N}}$  gibt es für jedes abgeschlossene Intervall  $J \subseteq (a, b)$  ein  $n_0 \in \mathbb{N}$ , so daß  $J \subseteq I_n$  für  $n \geq n_0$  erfüllt ist; damit gilt die Behauptung.

Wegen  $V_N \in DZ^N(I)$  ist der Satz unmittelbar auf gleichmäßig beschränkte Teilmengen von  $V_N$  anwendbar; es gilt sogar Korollar 2.2:

**Korollar 2.2** (Werner, [21])

Es sei  $N, J \in \mathbb{N}$ .

Ist  $V \subseteq V_N$  auf  $I$  gleichmäßig beschränkt, dann enthält  $V$  eine Folge  $(h_n)_{n \in \mathbb{N}}$ , so daß  $(D^j h_n)_{n \in \mathbb{N}}$ ,  $0 \leq j \leq J - 1$ , gleichmäßig im Innern von  $I$  konvergiert.

**Beweis:** Vollständige Induktion nach  $J$ :

Für  $J = 1$  gilt die Behauptung nach Satz 2.3.

Die Behauptung gelte für  $J \in \mathbb{N}$ :

Es gebe also eine Folge  $(h_m)_{m \in \mathbb{N}}$  in  $V$ , so daß  $(D^j h_m)_{m \in \mathbb{N}}$  für  $0 \leq j \leq J - 1$  gleichmäßig im Innern von  $I$  konvergiert.  $(I_n)_{n \in \mathbb{N}}$  sei die Intervallfolge von Satz 2.3; nach Satz 2.2 gibt es für alle  $n \in \mathbb{N}$  ein  $K(J, I, I_n) < \infty$  mit

$$\| D^j h_m \|_{I_n} \leq K(J, I, I_n) \| h_m \|_I \quad m \in \mathbb{N}$$

Da  $V$  auf  $I$  gleichmäßig beschränkt ist, ist auch  $(D^j h_m)_{m \in \mathbb{N}}$  auf  $I_n$  für  $n \in \mathbb{N}$  gleichmäßig beschränkt. Damit gibt es in  $(h_m)_{m \in \mathbb{N}}$  eine Teilfolge  $(h_{1,m})_{m \in \mathbb{N}}$ , so daß  $(D^j h_{1,m})_{m \in \mathbb{N}}$  im Innern von  $I_1$  gleichmäßig konvergiert;  $(h_{1,m})_{m \in \mathbb{N}}$  wiederum enthält eine Teilfolge  $(h_{2,m})_{m \in \mathbb{N}}$ , so daß  $(D^j h_{2,m})_{m \in \mathbb{N}}$  im Innern von  $I_2$  gleichmäßig konvergiert, usw.:

Für  $n > 1$  gibt es also eine Folge  $(h_{n,m})_{m \in \mathbb{N}} \subseteq (h_{n-1,m})_{m \in \mathbb{N}}$ , so daß  $D^j (h_{n,m})_{m \in \mathbb{N}}$  im Innern von  $I_n$  gleichmäßig konvergiert.

Die Folge  $(D^j h_{m,m})_{m \in \mathbb{N}}$  konvergiert also gleichmäßig im Innern von  $I_n$  für alle  $n \in \mathbb{N}$  und damit folgt wie in Satz 2.3 für diese Folge die gleichmäßige Konvergenz im Innern von  $I$ .

Nach Konstruktion gilt:

$(D^j h_{m,m})_{m \in \mathbb{N}}$  konvergiert im Innern von  $I$  für  $0 \leq j \leq J$  gleichmäßig.

Damit ist der Satz bewiesen.

## 2.2 Abgeschlossenheit, Existenzsätze

Mit Satz 2.3 erhält man die Existenz einer besten Approximation für  $f \in C(I)$ , wenn  $M$  abgeschlossen ist in Sinne der Definition 2.4 (man vergleiche hierzu die Forderung 2):

### Definition 2.4

Eine Menge  $V \subseteq C(I)$  heißt *abgeschlossen*, wenn gilt:

Konvergiert eine Folge von Elementen aus  $V$  auf einem abgeschlossenen Intervall  $I_1 \subseteq (a, b)$  gleichmäßig gegen  $h$ , dann stimmt  $h$  auf  $I_1$  mit einem Element von  $V$  überein.

### Satz 2.4 (Schmidt, [18])

Es sei  $M \subseteq DZ^n(I)$  mit  $n \in \mathbb{N}$  abgeschlossen.

**Behauptung:** Jede Funktion  $f \in C(I)$  besitzt eine Minimallösung bezüglich  $M$  auf  $I$ .

**Beweis:**

$(h_m)_{m \in \mathbb{N}} \subseteq M$  sei eine Minimalfolge für  $f$ :

$$\lim_{m \rightarrow \infty} \|f - h_m\|_I = \inf_{h \in M} \|f - h\|_I = R$$

Damit gibt es für  $\delta > 0$  ein  $m(\delta) \in \mathbb{N}$  mit

$$\|h_m\|_I \leq \|f\|_I + \|f - h_m\|_I \leq \|f\|_I + R + \delta \text{ für } m \geq m(\delta)$$

$(h_m)_{m \in \mathbb{N}}$  ist also auf  $I$  gleichmäßig beschränkt:

$$\|h_m\|_I \leq K, \text{ wobei}$$

$K := \max\{\max\{\|h_m\|_I \mid 1 \leq m \leq m(\delta)\}, \|f\|_I + R + \delta\}$  ist.

Nach Satz 2.3 existiert in  $(h_m)_{m \in \mathbb{N}}$  eine Teilfolge  $(h_m)_{m \in J}$ ,  $J \subseteq \mathbb{N}$ , die gleichmäßig im Innern von  $I$  konvergiert. Da  $M$  abgeschlossen ist, konvergiert  $(h_m)_{m \in J}$  auf jedem abgeschlossenen Intervall in  $(a, b)$  gleichmäßig gegen ein Element  $h \in M$ . Für  $x \in (a, b)$  gilt also:

$$|f(x) - h(x)| = \lim_{m \rightarrow \infty} |f(x) - h_m(x)| \leq \lim_{m \rightarrow \infty} \|f - h_m\|_I = R, \quad m \in J$$

Da  $|f - h|$  auf  $I$  stetig ist, folgt hieraus

$$\begin{aligned} |f(a) - h(a)| &\leq R \geq |f(b) - h(b)| \quad \text{und damit} \\ \|f - h\|_I &= \max\{|f(a) - h(a)|, \\ &|f(b) - h(b)|, \sup_{x \in (a,b)} |f(x) - h(x)|\} \leq R \end{aligned}$$

Damit ist  $h$  eine Minimallösung für  $f$  bezüglich  $M$ .

Bemerkung:

Die Stetigkeit von  $f$  geht entscheidend bei der Ermittlung von  $\|f - h\|_I$  ein.

Nach dem bisher Gezeigten ist die Aufgabe, die Existenz einer Minimallösung bezüglich  $V_N$  nachzuweisen, zurückgeführt auf das Problem, die Abgeschlossenheit von  $V_N$  zu zeigen. Es wird entscheidend benutzt, daß die Exponentialsummen Lösungen linearer Differentialgleichungen sind.

**Satz 2.5** (Schmidt, [17]; Werner, [21])

Es sei  $N \in \mathbb{N}$ ,  $(h_n)_{n \in \mathbb{N}} \subseteq V_N$  konvergiere auf  $I$  gleichmäßig gegen die Funktion  $h$ .

**Behauptung:**  $h \in V_N$

**Beweis:**

Die Länge und der Grad von  $h_n$  sind für alle  $n \in \mathbb{N}$  höchstens gleich  $N$ ; es kann daher o.B.d.A. angenommen werden:

$$h_n(x) = \sum_{i=1}^L P_{i,n}(x) e^{t_{i,n}x}$$

mit  $L \neq 0$  die Länge von  $h_n$  und  $\text{grad}(h_n) = k < N$  für  $n \in \mathbb{N}$ .

Für  $L = 0$  ist nichts zu zeigen. Aus der gleichmäßigen Konvergenz der Folge erhält man  $h \in C(I)$  und wie oben (mit  $R = 0$ ) die gleichmäßige Beschränktheit von  $(h_n)_{n \in \mathbb{N}}$ :

$$\|h_n\|_I \leq K < \infty \quad n \in \mathbb{N}$$

Nach Korollar 2.2 gibt es eine Teilfolge  $(h_n)_{n \in J_1}$ ,  $J_1 \subseteq \mathbb{N}$ , so daß die Folgen  $(D^r h_n)_{n \in J_1}$ ,  $0 \leq r \leq k$ , gleichmäßig im Innern von  $I$  konvergieren. Für jedes abgeschlossene Intervall  $I_0$  in  $(a, b)$  erhält man durch  $k$ -fache Anwendung des Satzes von der gliedweisen Differentiation:

In  $I_0$  ist  $h$   $k$ -fach differenzierbar

(2.6) und

$(D^r h_n)_{n \in J_1}$  konvergiert auf  $I_0$  gleichmäßig gegen  $D^r h$  für  $0 \leq r \leq k$

Es sei für  $1 \leq i \leq L$ ,  $n \in \mathbb{N}$  (wie üblich wird  $\sum_{j=1}^n a_j := 0$  für  $n < i$  gesetzt):

$$s_{m,n} = t_{i,n}, \quad \sum_{j=1}^{i-1} (\text{grad}(P_{j,n}) + 1) < m \leq \sum_{j=1}^i (\text{grad}(P_{j,n}) + 1)$$

Mit  $C_n(t) = \prod_{m=1}^k (t - s_{m,n})$ ,  $n \in \mathbb{N}$ , gilt also  $C_n(D)h_n = 0$ ,  $n \in \mathbb{N}$ ;  $C_n$  ist das zu  $h_n$  gehörige charakteristische Polynom.

Die Folgen  $(s_{m_i,n})_{n \in \mathbb{N}}$  seien für  $1 \leq i \leq d$  beschränkt, für  $d < i \leq k$  unbeschränkt mit  $d \in \mathbb{N} \cup \{0\}$ ; es gibt also eine (unendliche) Teilmenge  $J_2 \subseteq J_1$  mit

$$(2.7) \quad \lim_{n \rightarrow \infty} s_{m_i,n} = s_i \in \mathbb{R} \quad , \quad 1 \leq i \leq d, \text{ und}$$

$$\lim_{n \rightarrow \infty} |s_{m_i,n}| = \infty \quad , \quad d < i \leq k \quad , \quad \text{für } n \in J_2$$

Somit existiert ein  $n_0 \in \mathbb{N}$  mit  $s_{m_i,n} \neq 0$  für  $d < i \leq k$  und  $n \geq n_0$ ,  $n \in J_2$ ; für  $n \in J_2$ ,  $n \geq n_0$  gilt auf  $I$ :

$$\left( \prod_{i=d+1}^k s_{m_i,n}^{-1} \right) C_n(D)h_n = \left( \prod_{i=1}^d (D - s_{m_i,n}) \right) \left( \prod_{i=d+1}^k \left( \frac{D}{s_{m_i,n}} - 1 \right) \right) h_n = 0$$

(Für  $n < 1$  wird  $\prod_{j=1}^n a_j := 1$  gesetzt)

Aus ( 2.6) und ( 2.7) folgt auf  $I_0$ :

$$\lim_{n \rightarrow \infty} \left( \prod_{i=d+1}^k s_{m_i,n}^{-1} \right) C_n(D)h_n = (-1)^{k-d} \left( \prod_{i=1}^d (D - s_i) \right) h = 0 \quad , \quad n \in J_2$$

Da  $I_0 \subseteq (a, b)$  beliebig gewählt war, ist  $h$  in  $(a, b)$  und wegen  $h \in C(I)$  in ganz  $I$  identisch mit einem Element aus  $V_d \subseteq V_N$ ; dies war zu zeigen.

Dem Beweis zu Satz 2.5 entnimmt man unmittelbar:

**Korollar 2.3** (Schmidt, [17])

Die Folge  $(h_n)_{n \in \mathbb{N}} \subseteq V_N$  konvergiere auf  $I$  gleichmäßig gegen  $h$ ; für  $n \in \mathbb{N}$  gelte  $h_n(x) = \sum_{i=1}^L P_{i,n}(x) e^{t_{i,n}x}$ ,  $\text{grad}(h_n) = N$  und  $\text{grad}(P_{i,n}) = k_i \in \mathbb{N} \cup \{0\}$ .

Weiterhin seien in Folgen  $(t_{i_j,n})_{n \in \mathbb{N}}$  ,  $1 \leq j \leq m$ , unbeschränkt.

**Behauptung:**

Es gilt  $h \in V_{N-d}$  mit  $d = \sum_{j=1}^m (k_{i_j} + 1)$

Speziell für  $V_N^+$  folgt:

**Korollar 2.4** (Schmidt, [17]; Werner, [21])

Konvergiert  $(h_n)_{n \in \mathbb{N}} \subseteq V_N^+$  ( $(h_n)_{n \in \mathbb{N}} \subseteq V_N^-$ ) auf  $I$  gleichmäßig gegen  $h$ , dann gilt  $h \in V_N^+$  ( $h \in V_N^-$ ).

**Beweis:**

Der Beweis wird für  $(h_n)_{n \in \mathbb{N}} \subseteq V_N^+$  durchgeführt; im anderen Fall hat man nur  $a_{i_j} \geq 0$  bzw.  $a_j \geq 0$  durch  $a_{i_j} \leq 0$  bzw.  $a_j \leq 0$  zu ersetzen.

Aus der gleichmäßigen Konvergenz folgt wieder die gleichmäßige Beschränktheit von  $(h_n)_{n \in \mathbb{N}}$ :

$$\|h_n\|_I \leq K < \infty, \quad n \in \mathbb{N}$$

Mit  $h_n(x) = \sum_{i=1}^N a_{i,n} e^{t_{i,n}x}$  erhält man nach Voraussetzung

$$\|a_{i,n} e^{t_{i,n}x}\|_I \leq K \quad \text{und} \quad |a_{i,n}| \leq K e^{-t_{i,n}a} \quad \text{für } n \in \mathbb{N}$$

Nach Korollar 2.2 gibt es damit (nach  $N$ -maliger Auswahl von Teilfolgen) eine (unendliche) Teilmenge  $J \subseteq \mathbb{N}$ , so daß die Folgen  $(a_{i,n} e^{t_{i,n}x})_{n \in J}$ ,  $1 \leq i \leq N$ , im Innern von  $I$  gleichmäßig konvergieren. Die Folgen  $(t_{i_j,n})_{n \in \mathbb{N}}$  seien für  $1 \leq j \leq N-d$  beschränkt, für  $N-d < j \leq N$  unbeschränkt; es gibt daher ein  $T < \infty$  mit

$$|t_{i_j,n}| \leq T, \quad 1 \leq j \leq N-d, \quad n \in \mathbb{N};$$

damit gilt  $|a_{i_j,n}| \leq K e^{T|a|}$  für  $1 \leq j \leq N-d$ ,  $n \in \mathbb{N}$ . Es gibt daher eine Teilfolge mit

$$\begin{aligned} \lim_{n \rightarrow \infty} a_{i_j,n} &= a_j \in \mathbb{R} && \text{und} \\ \lim_{n \rightarrow \infty} t_{i_j,n} &= t_j \in \mathbb{R} && \text{für } 1 \leq j \leq N-d, \quad n \in J_1 \subseteq J; \end{aligned}$$

wegen  $a_{i_j,n} > 0$  für  $n \in \mathbb{N}$  konvergieren also die Folgen  $(a_{i_j,n} e^{t_{i_j,n}x})_{n \in J_1}$  im Innern von  $I$  gleichmäßig gegen  $a_j e^{t_j x}$  mit  $a_j \geq 0$  für  $1 \leq j \leq N-d$ , für  $N-d < j \leq N$  gegen die Nullfunktion (als einzigem Element von  $V_0$ ) nach Korollar 2.3. Damit gilt also

$$h(x) = \sum_{i=1}^{N-d} a_i e^{t_i x} \quad \text{für } x \in (a, b);$$

wegen  $h \in C(I)$  ist dies für ganz  $I$  richtig und die Behauptung ist gezeigt.

Es ist damit gezeigt:

**Korollar 2.5** (Schmidt, [17])

Die Mengen  $V_N, V_N^+, V_N^-$  sind abgeschlossen für  $N \in \mathbb{N}$ .

**Beweis:**

Es sei  $V$  eine Menge der Behauptung.

Konvergiert  $(h_n)_{n \in \mathbb{N}} \subseteq V$  im Innern von  $I$  gleichmäßig, dann konvergiert diese Folge auf jedem abgeschlossenen Intervall in  $(a, b)$  gleichmäßig gegen ein  $h \in V$ , wie oben gezeigt; damit ist  $V$  abgeschlossen.

Aus Satz 2.4 folgt somit:

**Satz 2.6** (Schmidt, [17]; Werner, [21])

Es sei  $N \in \mathbb{N}$  und  $f \subseteq C(I)$ .

**Behauptung:**

Auf  $I$  besitzt  $f$  bezüglich jeder der drei Mengen  $V_N, V_N^+, V_N^-$  eine Minimallösung.

Bemerkung:

Es ist wesentlich, daß  $I$  ein reelles Intervall  $[a, b]$  ist, wie Beispiel 6.1 zeigt.

Es folgen nun Sätze, die für spätere Untersuchungen benötigt werden, bei deren Beweis jedoch Satz 2.5 eingeht.

Wichtig sind Aussagen über den Vorzeichenvektor der Grenzfunktion einer gleichmäßig konvergenten Folge in  $V_N$ , die Verallgemeinerungen von Korollar 2.4 darstellen.

**Hilfsatz 2.3** (Braess, [2]; Werner, [21])

Es sei  $N \in \mathbb{N}$  und  $h(x) = \sum_{i=0}^{N-1} a_i x^i e^{t_0 x} \subseteq V_N \setminus V_{N-1}$  mit  $S = \text{sign}(h)$  gegeben;

die Folge  $(h_n)_{n \in \mathbb{N}} \subseteq V_N^0 \setminus V_{N-1}$  mit  $h_n(x) = \sum_{i=1}^N a_{i,n} e^{t_{i,n} x}$  konvergiere auf  $I$  gleichmäßig gegen  $h$ .

**Behauptung:**

Es gibt ein  $n_0 \in \mathbb{N}$ , so daß für  $n \geq n_0$  gilt:  $h_n \in V_N^0(S)$ .

**Beweis:**

Zum Beweis wird für  $h$  und  $h_n, n \in \mathbb{N}$ , die Darstellung durch Differenzenquotienten (nach Satz 1.2) benutzt:

$$\begin{aligned}
h(x) &= \sum_{i=0}^{N-1} b_i \Delta^i(t_0, \dots, t_0) e^{tx} \\
h_n(x) &= \sum_{i=0}^{N-1} b_{i,n} \Delta^i(t_{1,n}, \dots, t_{i+1,n}) e^{tx}
\end{aligned}$$

Aus  $\Delta^{N-1}(t_0, \dots, t_0) e^{tx} = \frac{1}{(N-1)!} x^{N-1} e^{t_0 x}$  folgt

$$\text{sign}(b_{N-1}) = \text{sign}(a_{N-1})$$

Es wird nun gezeigt: Es gibt eine Teilfolge  $(h_n)_{n \in J}$ ,  $J \subseteq \mathbb{N}$  mit

$$(2.8) \quad \lim_{n \rightarrow \infty} b_{i,n} = b_i, \quad 0 \leq i \leq N-1, \quad n \in J$$

Hierzu wähle man  $N$  Punkte  $x_j$ ,  $1 \leq j \leq N$ , mit  $x_1, x_2, \dots, x_N$  in  $I$ ; aus der gleichmäßigen Konvergenz folgt dann

$$(2.9) \quad \lim_{n \rightarrow \infty} h_n(x_j) = h(x_j), \quad 1 \leq j \leq N$$

Nach Korollar 2.3 sind die Folgen  $(t_{i,n})_{n \in \mathbb{N}}$ ,  $1 \leq i \leq N$ , beschränkt und nach dem Beweis von Satz 2.5 gibt es eine Teilfolge  $(h_n)_{n \in J}$ ,  $J \subseteq \mathbb{N}$ , mit

$$\lim_{n \rightarrow \infty} t_{i,n} = t_0, \quad n \in J, \quad 1 \leq i \leq N$$

Aus Hilfssatz 1.3 folgt für  $1 \leq j \leq N$  und  $n \in J$ :

$$(2.10) \quad \lim_{n \rightarrow \infty} \Delta^i(t_{1,n}, \dots, t_{i+1,n}) e^{tx_j} = \Delta^i(t_0, \dots, t_0) e^{tx_j}, \quad i < N$$

Für  $0 \leq i \leq N-1$  und  $1 \leq j \leq N$  wird definiert:

$$\begin{aligned}
d_{j,i+1}^n &:= \Delta^i(t_{1,n}, \dots, t_{i+1,n}) e^{tx_j}, \quad d_{j,i+1} := \Delta^i(t_0, \dots, t_0) e^{tx_j} \\
D_n &:= \begin{pmatrix} d_{1,1}^n & \dots & d_{1,N}^n \\ \vdots & \vdots & \vdots \\ d_{N,1}^n & \dots & d_{N,N}^n \end{pmatrix} \quad D := \begin{pmatrix} d_{1,1} & \dots & d_{1,N} \\ \vdots & \vdots & \vdots \\ d_{N,1} & \dots & d_{N,N} \end{pmatrix} \\
B_n &:= \begin{pmatrix} b_{0,n} \\ \vdots \\ b_{N-1,n} \end{pmatrix} \quad B := \begin{pmatrix} b_0 \\ \vdots \\ b_{N-1} \end{pmatrix} \quad H_n := \begin{pmatrix} h_n(x_1) \\ \vdots \\ h_n(x_N) \end{pmatrix} \quad H := \begin{pmatrix} h(x_1) \\ \vdots \\ h(x_N) \end{pmatrix}
\end{aligned}$$

Es gilt also:

$$(2.11) \quad D_n B_n = H_n, \quad DB = H$$

Die (N-N)-Matrix  $C_{i,n}$  bzw.  $C_i$  erhält man aus  $D_n$  bzw.  $D$ , indem in  $D_n$  bzw.  $D$  die  $i$ -te Spalte durch  $H_n$  bzw.  $H$  ersetzt wird,  $1 \leq i \leq N$ .

Die Gleichungssysteme (2.11) sind eindeutig lösbar, da der von

$$\{\Delta^i(t_0, \dots, t_0 e^{tx} \mid 0 \leq i \leq N-1\} \text{ bzw. } \{\Delta^i(t_{1,n}, \dots, t_{i+1,n} e^{tx} \mid 0 \leq i \leq N-1\}$$

erzeugte  $N$ -dimensionale reelle Vektorraum die Haarsche Bedingung erfüllt (Satz 1.1 und Hilfssatz 1.2). Damit folgt:

$$\det(D_n) \neq 0 \neq \det(D), \quad n \in \mathbb{N}$$

Nach der Cramerschen Regel gilt

$$b_{i,n} = \frac{\det(C_{i+1,n})}{\det(D_n)}, \quad n \in \mathbb{N}, \text{ und } b_i = \frac{\det(C_{i+1})}{\det(D)} \text{ für } n \in \mathbb{N}$$

Für (n-n)-Matrizen mit reellen Koeffizienten ist die Abbildung  $A \rightarrow \det(A)$  eine stetige Funktion der  $n^2$  Koeffizienten von  $A$ ; aus (2.9) und (2.10) erhält man daher für  $0 \leq i \leq N$

$$\lim_{n \rightarrow \infty} \frac{\det(C_{i+1,n})}{\det(D_n)} = \frac{\det(C_{i+1})}{\det(D)}, \quad n \in J$$

Somit ist (2.8) gezeigt.

Durch vollständige Induktion nach  $N$  ergibt sich unter Verwendung von (1.7) für  $p_i, s_i \in \mathbb{R}$ ,  $1 \leq i \leq N$ , mit  $s_i \neq s_j$  für  $i \neq j$ :

$$(2.12) \quad \sum_{i=1}^N p_{i-1} \Delta^{i-1}(s_1, \dots, s_i) e^{tx} = \sum_{i=1}^N e^{s_i x} \prod_{m=1, m \neq i}^N (s_i - s_m)^{-1} [p_{N-1} + \sum_{k=i}^{N-1} p_{k-1} \prod_{m=k+1}^N (s_i - s_m)]$$

$N = 1$ :

$$\begin{aligned} & \sum_{i=1}^1 p_{i-1} \Delta^{i-1}(s_1, \dots, s_i) e^{tx} = p_0 s^{s_1 x} = \\ & = \sum_{i=1}^1 e^{s_i x} \prod_{m=1, m \neq i}^1 (s_i - s_m)^{-1} [p_{N-1} + \sum_{k=i}^0 p_{k-1} \prod_{m=k+1}^1 (s_i - s_m)] \end{aligned}$$

Es gelte (2.12) für  $N \in \mathbb{N}$ .

Induktionsschluß:

$$\begin{aligned}
& \sum_{i=1}^N p_{i-1} \Delta^{i-1}(s_1, \dots, s_i) e^{tx} + p_N \Delta^N(s_1, \dots, s_{N+1}) e^{tx} = \\
& = \sum_{i=1}^N e^{s_i x} \prod_{m=1, m \neq i}^N (s_i - s_m)^{-1} [p_{N-1} + \sum_{k=i}^{N-1} p_{k-1} \prod_{m=k+1}^N (s_i - s_m)] + \\
& \quad + p_N \sum_{i=1}^{N+1} e^{s_i x} \prod_{m=1, m \neq i}^{N+1} (s_i - s_m)^{-1} = \\
& = \sum_{i=1}^N e^{s_i x} \prod_{m=1, m \neq i}^{N+1} (s_i - s_m)^{-1} \sum_{k=i}^N p_{k-1} \prod_{m=k+1}^{N+1} (s_i - s_m) + \\
& \quad + \sum_{i=1}^{N+1} e^{s_i x} p_N \prod_{m=1, m \neq i}^{N+1} (s_i - s_m)^{-1} = \\
& = \sum_{i=1}^{N+1} e^{s_i x} \prod_{m=1, m \neq i}^{N+1} (s_i - s_m)^{-1} [p_N + \sum_{k=i}^N p_{k-1} \prod_{m=k+1}^{N+1} (s_i - s_m)]
\end{aligned}$$

Damit ist (2.12) vollständig bewiesen.

Es gilt also

$$h_n(x) = \sum_{i=1}^N e^{t_{i,n} x} \prod_{m=1, m \neq i}^N (t_{i,n} - t_{m,n})^{-1} [b_{N-1,n} + \sum_{k=i}^{N-1} b_{k-1,n} \prod_{m=k+1}^N (t_{i,n} - t_{m,n})]$$

Wegen  $\lim_{n \rightarrow \infty} t_{i,n} = t_0$  für  $n \in J$ ,  $1 \leq i \leq N$ , und (2.8) existiert ein  $n_0 \in \mathbb{N}$ , so daß für  $n \geq n_0$ ,  $n \in J$ , erfüllt ist:

$$\begin{aligned}
\text{sign}(b_{N-1,n} + \sum_{k=i}^{N-1} b_{k-1,n} \prod_{m=k+1}^N (t_{i,n} - t_{m,n})) &= \text{sign}(b_{N-1}) \\
&= \text{sign}(a_{N-1}) \text{ für } 1 \leq i \leq N;
\end{aligned}$$

weiter gilt für  $1 \leq i \leq N$ :

$$\text{sign}\left(\prod_{m=1, m \neq i}^N (t_{i,n} - t_{m,n})^{-1}\right) = (-1)^{N-i}, \quad n \in \mathbb{N}$$

Wegen

$$a_{i,n} = \sum_{m=1, m \neq i}^N (t_{i,n} - t_{m,n})^{-1} [b_{N-1,n} + \sum_{k=i}^{N-1} b_{k-1,n} \prod_{m=k+1}^N (t_{i,n} - t_{m,n})]$$

erhält man  $\text{sign}(a_{i,n}) = (-1)^{N-i} \text{sign}(a_{N-1})$  für  $n \geq n_0, n \in J$ ;  
 die Behauptung gilt also für die Teilfolge  $(h_n)_{n \in J}$ . Nimmt man an, daß die Behauptung nicht für die Folge  $(h_n)_{n \in \mathbb{N}}$  gilt, dann gibt es eine Teilfolge  $(h_n)_{n \in J_1} \subseteq (h_n)_{n \in \mathbb{N}}$  mit  $\text{sign}(h_n) \neq S$  für  $n \in J_1$ . Da aber  $(h_n)_{n \in J_1}$  ebenfalls gegen  $h$  gleichmäßig konvergiert, liefern die soeben durchgeführten Überlegungen die Existenz einer Teilfolge in  $(h_n)_{n \in J_1}$ , deren Elemente den Vorzeichenvektor  $S$  besitzen, was im Widerspruch zu  $\text{sign}(h_n) \neq S$  steht.  
 Damit ist die Behauptung gezeigt.

**Satz 2.7** (Braess, [2]; Werner, [21])

Es sei  $N \in \mathbb{N}$  und  $S$  ein Vorzeichenvektor mit  $N$  Komponenten; die Folge  $(h_n)_{n \in \mathbb{N}} \subseteq V_N^0(S)$  konvergiere auf  $I$  gleichmäßig gegen  $h \in V_N \setminus V_{N-1}$ .

**Behauptung:**  $h \in V_N(S)$

**Beweis:**

Es sei  $h_n(x) = \sum_{i=1}^N a_{i,n} e^{t_{i,n}x}$ ,  $n \in \mathbb{N}$ . Nach Korollar 2.3 sind die Folgen  $(t_{i,n})_{n \in \mathbb{N}}, 1 \leq i \leq N$ , beschränkt und o.B.d.A. gilt  $\text{grad}(h_n) = N$  für  $n \in \mathbb{N}$ . Es gibt also eine Teilfolge  $(h_n)_{n \in J}$  mit  $J \subseteq \mathbb{N}$ , so daß erfüllt ist:

$$\text{grad}(h_n) = N \text{ und } (t_{i,n})_{n \in J} \text{ ist konvergent für } 1 \leq i \leq N$$

Es wird nun die Folge  $(h_n)_{n \in J}$  betrachtet, es ist also stets  $n \in J$  erfüllt.

Es gebe  $L$  verschiedene Grenzwerte der Folgen  $(t_{i,n})_{n \in J}$ :

$\lim_{n \rightarrow \infty} t_{j,n} = t_i$  für  $j_i \leq j < j_{i+1}$  mit  $1 \leq i \leq L$ , wobei  $j_1 = 1, j_i < j_{i+1}$  und  $j_{L+1} - 1 = N$  sei und weiter  $t_i < t_{i+1}$  gilt. (Im allgemeinen ist hierzu für endlich viele Elemente der Folge die Indizierung der Summanden, wie sie durch Definition 1.2 gegeben ist, abzuändern.)

Mit  $h_{i,n}(x) = \sum_{j=j_i}^{j_{i+1}-1} a_{j,n} e^{t_{j,n}x}$ ,  $1 \leq i \leq L$ , erhält man  $h_n = \sum_{i=1}^L h_{i,n}(x)$  und es gibt ein  $n_0 \in \mathbb{N}$  mit  $S = (\text{sign}(h_{1,n}), \dots, \text{sign}(h_{L,n}))$  für  $n \geq n_0$ . Der Beweis von Satz 2.5 zeigt, daß  $\prod_{i=1}^L (D - t_i)^{j_{i+1} - j_i} h = 0$  und damit  $h(x) = \sum_{i=1}^L P_i(x) e^{t_i x}$  mit  $\text{grad}(P_i) = j_{i+1} - j_i - 1 := k_i$  erfüllt ist.

Mit  $h_i(x) = P_i(x)e^{t_i x}$  gilt  $h(x) = \sum_{i=1}^L h_i(x)$ .

Für  $L = 1$ , d.h.  $\lim_{n \rightarrow \infty} t_{i,n} = t_1$  für  $1 \leq i \leq N$ , liefert Hilfssatz 2.3 die Behauptung. Es gelte also  $2 \leq L \leq N$ .

Es wird nun ähnlich wie in Hilfssatz 2.3 die Darstellung durch Differenzenquotienten verwendet:

$$(2.13) \quad h_{i,n}(x) = \sum_{j=0}^{k_i} b_{i,j}^n \Delta^j(t_{j_i,n}, \dots, t_{j_i+j,n}) e^{tx}$$

$$h_i(x) = \sum_{j=0}^{k_i} b_{i,j} \Delta^j(t_i, \dots, t_i) e^{tx}$$

Es seien  $N$  Punkte  $x_i$ ,  $1 \leq i \leq N$ , in  $I$  gegeben mit  $x_1 < x_2 < \dots < x_N$ ; nach Voraussetzung gilt damit für  $1 \leq i \leq N$

$$(2.14) \quad \lim_{n \rightarrow \infty} h_n(x_i) = h(x_i)$$

Hiermit wird definiert:

$$d_{j,m,i}^n := \Delta^{m-1}(t_{j_i,n}, \dots, t_{j_i+m-1,n}) e^{tx_j} \quad \text{und} \\ d_{j,m,i} := \Delta^{m-1}(t_i, \dots, t_i) e^{tx_j}$$

für  $1 \leq m \leq k_i + 1$ ,  $1 \leq i \leq L$ ,  $1 \leq j \leq N$ ,  $n \in J$ .

Weiter sei für  $1 \leq i \leq L$

$$D_{i,n} := \begin{pmatrix} d_{1,1,i}^n & \cdots & d_{1,k_i+1,i}^n \\ \vdots & \vdots & \vdots \\ d_{N,1,i}^n & \cdots & d_{N,k_i+1,i}^n \end{pmatrix}, \quad n \in J \quad \text{und} \quad D_i := \begin{pmatrix} d_{1,1,i} & \cdots & d_{1,k_i+1,i} \\ \vdots & \vdots & \vdots \\ d_{N,1,i} & \cdots & d_{N,k_i+1,i} \end{pmatrix}$$

Mit den (N-N)-Matrizen  $D_n = (D_{1,n}, \dots, D_{L,n})$ ,  $n \in J$ , und  $D = (D_1, \dots, D_L)$  gilt nach (2.13)

$$D_n \begin{pmatrix} B_{1,n} \\ \vdots \\ B_{L,n} \end{pmatrix} = \begin{pmatrix} h_n(x_1) \\ \vdots \\ h_n(x_N) \end{pmatrix} := H_n \quad \text{und} \quad D \begin{pmatrix} B_1 \\ \vdots \\ B_L \end{pmatrix} = \begin{pmatrix} h(x_1) \\ \vdots \\ h(x_N) \end{pmatrix} := H,$$

wobei für  $1 \leq i \leq L$

$$B_{i,n} = \begin{pmatrix} b_{i,0}^n \\ \vdots \\ b_{i,k_i}^n \end{pmatrix} \quad \text{und} \quad B_i = \begin{pmatrix} b_{i,0} \\ \vdots \\ b_{i,k_i} \end{pmatrix} \quad \text{ist.}$$

Die (N-N)-Matrizen  $C_{i,n}$  und  $C_i$ ,  $1 \leq j \leq N$ , sind definiert wie in Hilfsatz 2.3. Mit (2.14) und Hilfsatz 1.3 folgt wie oben aus der Cramerschen Regel

$$\lim_{n \rightarrow \infty} b_{i,j}^n = \lim_{n \rightarrow \infty} \frac{\det(C_{j_i+j,n})}{\det(D_n)} = \frac{\det(C_{j_i+j})}{\det(D)} = b_{i,j}, \quad 0 \leq j \leq k_i, \quad 1 \leq i \leq L, \quad n \in J,$$

da die entsprechenden Gleichungssysteme wieder eindeutig lösbar sind.

Nach Hilfsatz 1.3 konvergieren daher die Folgen  $(h_{i,n})_{n \in J}$  auf I gleichmäßig gegen  $h_i$  für  $1 \leq i \leq L$ , und Hilfsatz 2.3 ergibt  $\text{sign}(h_{i,n}) = \text{sign}(h_i)$ ,  $1 \leq i \leq L$ , für  $n \geq n_0$ ,  $n \in J$ , woraus  $\text{sign}(h) = S$  folgt, was zu zeigen war.

Es gilt noch allgemeiner:

**Korollar 2.6** (Braess, [2]; Werner, [21])

Es seien die Voraussetzungen von Satz 2.7 mit  $(h_n)_{n \in \mathbb{N}} \subseteq V_N(S)$  erfüllt.

**Behauptung:**  $h \in V_N(S)$

**Beweis:**

Es sei  $n \in \mathbb{N}$ ; für jedes  $m \in \mathbb{N}$  existiert ein  $g_{m,n} \in V_N^0$  mit  $\|h_n - g_{m,n}\|_I \leq \frac{1}{m}$  und nach Satz 2.7 gibt es ein  $m(n) \in \mathbb{N}$  mit  $\text{sign}(g_{m,n}) = \text{sign}(h_n)$  für  $m \geq m(n)$ .

Mit  $m_n := \max\{n, m(n)\}$ ,  $n \in \mathbb{N}$ , erhält man so eine Folge  $(g_{m_n,n})_{n \in \mathbb{N}}$  in  $V_N^0(S)$ , die gleichmäßig auf I gegen  $h$  konvergiert; Satz 2.7 ergibt damit die Behauptung.

Es wird noch benötigt:

**Satz 2.8**

$$(h_n)_{n \in \mathbb{N}} \subseteq V_N \text{ mit } h_n(x) = \sum_{i=1}^L \sum_{j=0}^{k_i} a_{i,j}^n x^j e^{t_{i,n}x} \text{ und } L \in \mathbb{N}$$

konvergiere auf I gleichmäßig gegen

$$h(x) = \sum_{i=1}^L \sum_{j=0}^{k_i} a_{i,j} x^j e^{t_i x}$$

und es gelte

$$\lim_{n \rightarrow \infty} t_{i,n} = t_i \in \mathbb{R} \text{ für } 1 \leq i \leq L$$

**Behauptung:**

$$\lim_{n \rightarrow \infty} a_{i,n}^j = a_{i,j} \text{ für } 0 \leq j \leq k_i, 1 \leq i \leq L$$

**Beweis:**

Mit  $k = \sum_{i=1}^L (k_i + 1)$  wähle man  $k$  Punkte  $x_i$ ,  $1 \leq i \leq k$ , mit  $x_i < x_{i+1}$  in  $I$ ; es gilt

$$(2.15) \quad \sum_{i=1}^L \sum_{j=0}^{k_i} a_{i,j}^n x_m^j e^{t_{i,n} x_m} = h_n(x_m), \quad 1 \leq m \leq k, n \in \mathbb{N}$$

$$\sum_{i=1}^L \sum_{j=0}^{k_i} a_{i,j} x_m^j e^{t_i x_m} = h(x_m), \quad 1 \leq m \leq k$$

Betrachtet man wieder die Koeffizienten  $a_{i,j}^n$  bzw.  $a_{i,j}$  als die eindeutig bestimmten Lösungen der Gleichungssysteme (2.15), dann erhält man wegen  $\lim_{n \rightarrow \infty} h_n(x_j) = h(x_j)$ ,  $1 \leq j \leq k$ , und  $\lim_{n \rightarrow \infty} t_{i,n} = t_i$ ,  $1 \leq i \leq L$ , aus der Cramerschen Regel die Behauptung des Satzes.

Einen Zusammenhang zwischen der gleichmäßigen Konvergenz auf  $I$  und der gleichmäßigen Konvergenz im Innern von  $I$  gibt der folgende Satz für Exponentialsummen an:

**Satz 2.9** (Werner, [21])

Es sei  $N \in \mathbb{N}$ ; konvergiert die Folge  $(h_n)_{n \in \mathbb{N}} \subseteq V_N$  gleichmäßig im Innern von  $I$  gegen  $h \in V_N \setminus V_{N-1}$ , dann konvergiert  $(h_n)_{n \in \mathbb{N}}$  auf  $I$  gleichmäßig gegen  $h$ .

**Beweis:**

Für jedes abgeschlossene Intervall  $I_1 = [a_1, b_1] \subseteq (a, b)$  sei  $I'_1 = [\frac{a_1 + a}{2}, \frac{b_1 + b}{2}]$ ; für  $j \in \mathbb{N}$  gibt es nach Satz 2.2 ein  $K(j, I'_1, I_1) < \infty$  mit  $\|D^j(h_n - h)\|_{I_1} \leq K(j, I'_1, I_1) \|h - h_n\|_{I'_1}$ . Aus der gleichmäßigen Konvergenz im Innern von  $I$  folgt daher für  $j \in \mathbb{N}$ :

$$\lim_{n \rightarrow \infty} \|D^j h_n - D^j h\|_{I_1} = 0$$

Für  $x_0 \in (a, b)$  gilt daher

$$(2.16) \quad \lim_{n \rightarrow \infty} D^j h_n(x_0) = D^j h(x_0) \quad j \in \mathbb{N}$$

Wegen  $h \in V_N \setminus V_{N-1}$  erhält man mit dem Beweis von Satz 2.5, daß die Frequenzen der Elemente von  $(h_n)_{n \in \mathbb{N}}$  beschränkt sind: Es gilt also

$$\prod_{i=1}^N (D - t_{i,n}) h_n = 0 \quad \text{mit} \quad |t_{i,n}| < T < \infty \quad \text{für} \quad 1 \leq i \leq N \quad \text{und} \quad n \in \mathbb{N}$$

und es gibt daher eine Teilfolge mit  $\lim_{n \rightarrow \infty} t_{i,n} = t_i \in \mathbb{R}$ ,  $n \in J \subseteq \mathbb{N}$ .

Mit (2.16) ergibt der Satz von der stetigen Abhängigkeit der Lösungen eines Anfangswertproblems gewöhnlicher Differentialgleichungen die gleichmäßige Konvergenz von  $(h_n)_{n \in J}$  auf  $I$ ; da somit in jeder Teilfolge von  $(h_n)_{n \in \mathbb{N}}$  eine auf  $I$  gleichmäßig gegen  $h$  konvergente Teilfolge existiert, gilt die Behauptung.

**Bemerkung 2.2**

Entscheidend für den Beweis von Satz 2.9 ist die Beschränktheit der Folgen  $(t_{i,n})_{n \in \mathbb{N}}$ ; man beachte hierzu Beispiel 2.1. Setzt man dies voraus, dann wird die Voraussetzung  $h \in V_N \setminus V_{N-1}$  nicht benötigt.

### 3 Eindeutigkeitsätze und Charakterisierung der Minimallösungen

Nach dem Existenzproblem sollen nun folgende Fragen behandelt werden:

1. Sind die Minimallösungen bezüglich  $V_N$ ,  $V_N^0$ ,  $V_N^+$  eindeutig bestimmt?
2. Wodurch sind die Minimallösungen gekennzeichnet?
3. Unter welchen Voraussetzungen ist eine Minimallösung bezüglich  $V_N^+$  oder  $V_N^0$  auch Minimallösung bezüglich  $V_N$ ?

Da die Existenz einer Minimallösung vorausgesetzt wird, können die entsprechenden Sätze, allgemeiner als in [1] für die Approximation über kompakten, reellen Teilmengen angegeben werden.

Um, wie in Kapitel 1 angekündigt, die Ergebnisse von [11] anwenden zu können, werden folgende Begriffe benötigt:

#### Definition 3.1

Mit  $n \in \mathbb{N}$  sei  $A$  eine offene Teilmenge des  $n$ -dimensionalen Raumes  $\mathbb{R}^n$  und  $V$  sei eine Menge von Funktionen  $v(a) = v(a, x)$  aus  $C(I)$  auf dem reellen Intervall  $I$ , die von  $a \in A$  abhängen; ferner existiere für jedes  $a = (a_1, \dots, a_n) \in A$  und  $x \in I$  die partielle Ableitung

$$D_i v(a, x) = \frac{\partial v(a, x)}{\partial a_i}, 1 \leq i \leq n$$

Diese Ableitungen werden als Funktionen auf  $I$  mit  $D_i v(a)$ ,  $a \in A$ , bezeichnet und es sei  $D_i v(a) \in C(I)$  für  $a \in A$  und  $1 \leq i \leq n$  erfüllt.

a. Der *Gradient* von  $v(a) \in V$  ist gegeben durch

$$\text{grad}(v(a)) := (D_1 v(a), \dots, D_n v(a)).$$

Mit  $r = (r_1, \dots, r_n) \in \mathbb{R}^n$  sei  $(r, \text{grad}(v(a))) \in C(I)$  die Funktion

$$(r, \text{grad}(v(a))) := \sum_{i=1}^n r_i D_i v(a)$$

Für  $x \in I$  gilt also  $\text{grad}(v(a, x)) = (D_1 v(a, x), \dots, D_n v(a, x))$  und

$$(r, \text{grad}(v(a, x))) = \sum_{i=1}^n r_i D_i v(a, x)$$

- b. Der *Gradientenraum*  $W(a)$  von  $v(a) \in V$  ist der von den Funktionen  $D_i v(a), 1 \leq i \leq n$ , erzeugte lineare Raum:

$$W(a) = \{(r, \text{grad}(v(a))) \mid r \in \mathbb{R}^n\}$$

- c.  $V$  erfüllt die *lokale Haarsche Bedingung*, wenn für alle  $a \in A$  der lineare Raum  $W(a)$  der Haarschen Bedingung genügt, also:

Für  $a \in A$  besitzt jedes Element von  $W(a)$  in  $I$  höchstens  $m - 1$  Nullstellen, wenn  $m$  die Dimension von  $W(a)$  ist, oder verschwindet auf  $I$  identisch.

### Bemerkung 3.1

- a. Für die Bildung des Gradienten nach Definition 3.1a ist es also notwendig, daß für die Elemente des betrachteten Funktionensystems eine Parametrisierung wie oben angegeben ist; wie in Satz 3.1 erfordert dies für  $V = V_N$  eine Beschränkung auf geeignete Teilmengen.

- b. Es sei  $V$  das Funktionensystem von Definition 3.1; ist weiterhin die Abbildung  $a \rightarrow D_i v(a) \in C(I), 1 \leq i \leq n$ , stetig für alle  $a \in A$ , gibt es also für jedes  $\epsilon > 0$  und  $a \in A$  ein  $\delta = \delta(a, \epsilon) > 0$ , so daß  $\|D_i v(a) - D_i v(b)\|_I < \epsilon$  für  $b \in A$  mit  $\|a - b\| < \delta$  erfüllt ist, dann besitzt  $v(a)$  für jedes  $a \in A$  eine Fréchet-Ableitung (nach dem Parameter  $a$ ); dabei ist  $\|b\|$  die Euklidische Norm von  $b \in \mathbb{R}^n$ :

Wie in der Analysis gezeigt wird (z.B. H. Bauer, Differential- und Integralrechnung II, S. 97), folgt aus diesen Voraussetzungen für  $a, b \in \mathbb{R}^n, a = (a_1, \dots, a_n), b = (b_1, \dots, b_n)$ :

$$\frac{\|v(a+b) - v(a) - (b, \text{grad}(v(a)))\|_I}{\|b\|} \leq \sum_{i=1}^n \|D_i v(c_i(b)) - D_i v(a)\|_I$$

für  $\|b\|$  hinreichend klein; dabei ist

$$c_i(b) = (a_1 + b_1, \dots, a_{i-1} + b_{i-1}, c_i, a_{i+1}, \dots, a_n) \quad \text{mit } c_i \in (a_i, a_i + b_i), \\ 1 \leq i \leq n$$

Aus der Stetigkeit in den Parametervektoren folgt

$$\lim_{\|b\| \rightarrow 0} \frac{\|v(a+b) - v(a) - (b, \text{grad}(v(a)))\|_I}{\|b\|} = 0$$

Die Abbildung  $b \rightarrow (b, \text{grad}(v(a))) \in C(I)$  für  $b \in \mathbb{R}^n$  ist linear und beschränkt und stellt somit die (eindeutig bestimmte) Fréchet-Ableitung von  $v(a)$  nach dem Parametervektor  $a$  dar.

**Definition 3.2**

Gegeben sei  $F \in C(X)$ ,  $X \subseteq \mathbb{R}$ .

- a.  $x \in X$  ist ein *Extremalpunkt* von  $F$  in  $X$ , falls gilt:

$$|F(x)| = \|F\|_X$$

- b.  $F$  besitzt in  $X$  eine *Alternante* der Länge  $n$  mit  $n \in \mathbb{N}$ , falls  $F$   $n$  Extremalpunkte  $x_i$ ,  $1 \leq i \leq n$ , in  $X$  besitzt und mit  $n > 1$  gilt:

$$x_i < x_{i+1} \quad \text{und} \quad \text{sign}(F(x_i)) = -\text{sign}(F(x_{i+1})) \quad 1 \leq i \leq n-1$$

Die Punkte  $x_i$ ,  $1 \leq i \leq n$ , werden als *Alternantepunkte* von  $F$  bezeichnet.

- c.  $F$  besitzt in  $X$  eine *positive (negative) Alternante der Länge  $n$* , wenn  $F$  in  $X$  eine Alternante der Länge  $n$  besitzt, so daß im Alternantepunkt  $x_n$  gilt:

$$F(x_n) > 0 \quad (F(x_n) \leq 0)$$

**Vereinbarung:**

Ab jetzt sei  $N \in \mathbb{N}$  und  $X$  stets eine kompakte, reelle Teilmenge mit der Mächtigkeit  $|X| > 2N$ ;  $I$  sei das Intervall  $[p, q]$  mit  $p = \min X$  und  $q = \max X$ .

Weiter sei  $f \in C(I)$ .

Zunächst werden die Sätze 11 und 12 aus [11] für kompakte Mengen formuliert:

**Hilfsatz 3.1** ([11], Satz 11)

Es sei  $V \subseteq C(I)$ ; für  $v \in V$  gebe es ein  $N(v) \in \mathbb{N}$ , so daß  $u - v$  für jedes  $u \in V$  höchstens  $N(v) - 1$  Nullstellen in  $I$  besitzt oder auf  $I$  identisch verschwindet. In  $X$  gebe es  $N(v) + 1$  Punkte  $x_i$  mit  $1 \leq i \leq N(v) + 1$  und  $x_1 < x_2 < \dots < x_{N(v)+1}$ , so daß

$$\text{sign}(f(x_i) - v(x_i)) = -\text{sign}(f(x_{i+1}) - v(x_{i+1})) \neq 0$$

für  $1 \leq i \leq N(v)$  erfüllt ist;  $D := \{x_i \mid 1 \leq i \leq N(v) + 1\}$ .

**Behauptung:**

$$\inf_{u \in V} \|f - u\|_X \geq \min_{x \in D} |f(x) - v(x)|$$

**Beweis:**

Mit

$$S(u_1, u_2, x) := (f(x) - u_1(x))(u_2(x) - u_1(x)) \text{ für } u_1, u_2 \in V$$

gibt es für alle  $u \in V$  mindestens ein  $x_u \in D$ , so daß  $S(v, u, x_u) \leq 0$  erfüllt ist; denn gilt für ein  $u \in V$  und alle  $x \in D$

$$\text{sign}(f(x) - v(x)) = \text{sign}(u(x) - v(x)) \neq 0$$

dann folgt im Widerspruch zu Voraussetzung, daß  $u - v$  in  $J := (x_1, x_{N(v)+1})$  mindestens  $N(v)$  Nullstellen besitzt, aber auf  $I$  nicht identisch verschwindet. Es ist also  $\min_{x \in D} S(v, u, x) \leq 0$  für all  $u \in V$  erfüllt und Satz 1 in [11] ergibt die Behauptung.

Bemerkung:

Für den Beweis von Hilfssatz 3.1 wird eine Parametrisierung von  $V$ , wie sie in Definition 3.1 angenommen war, nicht benötigt; deshalb ist dieser Hilfssatz auf  $V_N$  mit  $N(v) \leq 2N$  für  $v \in V_N$  anzuwenden und ergibt eine **untere Schranke für die Minimalabweichung** von  $f$  bezüglich  $V_N$ .

**Bemerkung 3.2**

Zum Beweis von Hilfssatz 3.2 wird benötigt:

Der lineare Raum  $U \subseteq C(I)$  mit der Dimension  $n + 1$  erfülle die Haarsche Bedingung. Es gilt:

1. Jedes Element  $u \in U$ , das auf  $I$  nicht identisch verschwindet, besitzt in  $I$  höchstens  $n$  Nullstellen, wobei die Nullstellen im Innern von  $I$ , an denen das Vorzeichen nicht wechselt, doppelt gezählt werden. ([8], Theorem 4.2)
2. Es sei  $T = \{t_i \mid 1 \leq i \leq k\} \subseteq I$ ,  $k \in \mathbb{N}$ , eine Menge paarweise verschiedener Punkte von  $I = [p, q]$  mit  $\sum_{i=1}^k w(t_i) \leq n$ , wobei gelte:

$$w(t) = \begin{cases} 1 & : t \in \{p, q\} \\ 2 & : t \in (p, q) \end{cases}$$

Dann gibt es ein nichtnegatives Element  $u^+ \in U$ , das auf  $I$  nicht identisch verschwindet, so daß  $u^+$  genau die  $k$  Nullstellen  $t_i$ ,  $1 \leq i \leq k$ , besitzt; die einzige Ausnahme besteht darin, daß, falls genau ein Element von  $\{p, q\}$  in  $T$  enthalten und  $n$  gerade ist,  $u^+$  auch im anderen Randpunkt von  $I$  verschwinden kann. ([8], Theorem 4.1)

3. Mit diesen beiden Sätzen folgt die Existenz eines Elements  $v \in U$  mit  $v(x) > 0$  für  $x \in I$ .

**Hilfsatz 3.2** ([11], Satz 12)

Es seien  $V$  und  $A$  gegeben wie in Definition 3.1 und Bemerkung 3.1b.  $V$  erfülle die lokale Haarsche Bedingung und  $v(a) \in V$  sei eine Minimallösung für  $f$  bezüglich  $V$ ; es sei hier  $|X| > n$ .

Dann gibt es in  $X$  für  $f - v(a)$  eine Alternante der Länge  $d + 1$ , wobei der Gradientenraum  $W$  von  $v(a)$  die Dimension  $d$  besitzt.

**Beweis:**

Nach Voraussetzung ist  $v(b) \in V$  Fréchet-differenzierbar in  $b \in A$ . Es sei o.B.d.A.  $\|f - v(a)\|_X \neq 0$ .

Für  $d = 0$  ist nichts zu zeigen; es sei also  $d \geq 1$ .

Nach Satz 9 in [11] besitzt  $F := f - v(a)$  in  $X$  mindestens  $d + 1$  Extrempunkte;  $D$  sei die Menge der Extrempunkte von  $F$  in  $X$ .

Nimmt man an, daß  $F(x) = \|F\|_X$  ( $F(x) = -\|F\|_X$ ) für alle  $x \in D$  erfüllt ist, dann gilt mit der besten Approximation  $w$  an  $F$  bezüglich  $W$  auf  $D$  ( $W$  erfüllt die Haarsche Bedingung nach Voraussetzung):

$$\|F\|_X = \|F\|_D > \|F - w\|_D$$

Hieraus folgt  $w(x) > 0$  ( $w(x) < 0$ ) für  $x \in D$  und damit

$$\text{sign}(w(x)) = \text{sign}(F(x)) \neq 0 \quad x \in D$$

Dies steht im Widerspruch zur Minimalität von  $v(a)$  nach Satz 8 in [11]. Dieser Widerspruch ergibt sich auch aus der Existenz eines Elementes  $u \in W$  mit  $u(x) > 0$  ( $u(x) < 0$ ) für  $x \in I$  nach Bemerkung 3.2. Es folgt also, daß es in  $D$  mindestens zwei Punkte  $x_1, x_2$  gibt mit  $x_1 < x_2$  und  $\text{sign}(F(x_1)) = -\text{sign}(F(x_2)) \neq 0$ .

Die Behauptung ist damit für  $d = 1$  gezeigt; es sei nun  $d \geq 2$ :

$D$  ist abgeschlossen und es sei  $J = [d_1, d_2]$  mit  $d_1 = \min D$  und  $d_2 = \max D$ .

Annahme: Es gibt keine Alternante der Länge  $d + 1$  für  $F$  in  $X$ .

$F$  ist stetig in  $I$  und man kann daher  $J$  in  $m + 1 \geq 2$  Teilintervalle  $[y_i, y_{i+1}]$ ,  $0 \leq i \leq m$ , mit  $m < d$  so aufteilen, daß gilt:

1. Auf  $D \cap [y_i, y_{i+1}]$  besitzt  $F$  gleiches Vorzeichen für  $0 \leq i \leq m$
2. Für  $x \in D \cap [y_{i-1}, y_i]$  und  $y \in D \cap [y_i, y_{i+1}]$  gilt für  $1 \leq i \leq m$ :

$$\text{sign}(F(y)) = -\text{sign}(F(x))$$

3.  $F(y_i) \neq 0$  und  $y_i \notin D$  für  $1 \leq i \leq m$

In  $[y_{m-1}, d_2]$  besitzt  $F$  mindestens eine Nullstelle  $z$ :  $F(z) = 0$ .

Fall 1:  $m = d - 2r - 1$ ,  $r \in \mathbb{N} \cup \{0\}$ .

In  $J$  wähle man  $2r$  Punkte  $p_i$ ,  $1 \leq i \leq 2r$ , mit  $z < p_1 < p_2 \dots < p_{2r}$  und

$$p_{2r} - z < \min\{|z - x| \mid x \in D \cup \{y_m\}\}$$

Da  $W$  mit der Dimension  $d$  die Haarsche Bedingung erfüllt, folgt zunächst, daß es ein  $b \in \mathbb{R}^d$  gibt mit

$$(3.1) \quad (b, \text{grad}(v(a, d_1))) = \text{sign}(F(d_1))$$

$$(b, \text{grad}(v(a, y_i))) = 0 \quad 1 \leq i \leq m$$

(3.2)

$$(b, \text{grad}(v(a, p_i))) = 0 \quad 1 \leq i \leq 2r$$

Nach Bemerkung 3.2 besitzt  $(b, \text{grad}(v(a)))$  in  $I$  genau die durch (3.2) gegebenen  $d - 1$  Nullstellen und wechselt in diesen das Vorzeichen, weshalb mit (3.1) folgt:

$$(3.3) \quad \text{sign}(b, \text{grad}(v(a, x))) = \text{sign}(F(x)) \quad x \in D$$

Fall 2:  $m = d - 2r - 2$ ,  $r \in \mathbb{N} \cup \{0\}$ .

Wie oben gibt es ein  $b \in \mathbb{R}^d$ , so daß mit den Punkten  $p_i$  von oben gilt:

$$(3.4) \quad (b, \text{grad}(v(a, d_1))) = \text{sign}(F(d_1))$$

$$(b, \text{grad}(v(a, y_i))) = 0 \quad 1 \leq i \leq m$$

(3.5)

$$(b, \text{grad}(v(a, p_i))) = 0 \quad 1 \leq i \leq 2r$$

$$(3.6) \quad (b, \text{grad}(v(a, d_2))) = \text{sign}(F(d_2))$$

Nach Bemerkung 3.2 besitzt  $(b, \text{grad}(v(a)))$  wegen (3.4) und (3.6) in  $J$  genau die durch (3.5) gegebenen  $d - 2$  Nullstellen und wechselt dort sein Vorzeichen. Damit gilt auch hier (3.3).

In beiden Fällen liegt also ein Widerspruch zur Minimalität wie oben vor und die Behauptung ist bewiesen.

Wir sind nun in der Lage, eine Charakterisierung für Minimallösungen bezüglich  $V_N$  anzugeben.

**Satz 3.1** (Braess, [1]. **Minimallösung bezüglich  $V_N$** )

Es sei

$$E(x) = \sum_{i=1}^L P_i(x)e^{t_i x} \in V_N \text{ mit } \text{grad}(E)=K \text{ und der Länge } L$$

gegeben.

**Behauptung:**

- a. Besitzt  $f-E$  in  $X$  eine Alternante der Länge  $N+K+1$ , dann ist  $E$  die eindeutig bestimmte Minimallösung für  $f$  bezüglich  $V_N$  auf  $X$ .
- b. Ist  $E$  Minimallösung für  $f$  bezüglich  $V_N$  auf  $X$ , dann gibt es für  $f-E$  eine Alternante der Länge  $N+L+1$  in  $X$ .

**Beweis:**

Für jedes  $h \in V_N$  gilt  $\text{grad}(h - E) \leq N + K$  und  $h - E \neq 0$  besitzt nach Satz 1.1 höchstens  $N + K - 1$  reelle Nullstellen. Hat also  $f - E$  in  $X$  eine Alternante der Länge  $N + K + 1$ , dann folgt mit Hilfssatz 3.1

$$\inf_{h \in V_N} \|f - h\|_X \geq \|f - E\|_X$$

$E$  ist also eine Minimallösung für  $f$  auf  $X$  bezüglich  $V_N$ .

Annahme:  $E_1 \in V_N$  mit  $E_1 \neq E$  ist eine weitere Minimallösung:

$$(3.7) \quad \|f - E_1\|_X = \|f - E\|_X$$

Der Vorzeichenvektor  $S$  von  $E_1 - E$  hat maximal  $N + K$  Komponenten und damit höchstens  $N + K - 1$  Vorzeichenwechsel. Andererseits hat  $(f - E) - (f - E_1) = E_1 - E \neq 0$  in  $[x_1, x_{N+K+1}]$  wegen (3.7) mindestens  $N + K$  Nullstellen, wobei  $x_1$  bzw.  $x_{N+K+1}$  der kleinste bzw. größte Alternantenpunkt einer Alternante von  $f - E$  in  $X$  ist. Nach Satz 1.3 stellt dies einen Widerspruch dar; damit ist die erste Behauptung gezeigt.

Es gilt

$$E(x) = \sum_{i=1}^L P_i(x)e^{t_i x} + \sum_{i=K+1}^N a_i e^{t_i x}$$

mit  $a_i = 0$ ,  $K + 1 \leq i \leq N$ , und  $t_i < t_{i+1}$ ,  $K + 1 \leq i \leq N$ ,  $t_i \in \mathbb{R}$  für  $K + 1 \leq i \leq N$ .

Ist  $E$  Minimallösung für  $f$  bezüglich  $V_N$  auf  $X$ , dann ist  $E$  auch Minimallösung für bezüglich  $f$  der Menge

$$V = \left\{ E(b) \in V_N \mid E(b, x) = \sum_{i=1}^L Q_i(x) e^{s_i x} + \sum_{i=K+1}^N b_i e^{s_i x}, \right. \\ \left. \begin{aligned} &Q_i \text{ ist reelles Polynom mit } \text{grad}(Q_i) \leq m_i, \\ &s_i \in \mathbb{R}, 1 \leq i \leq L, \\ &s_i, b_i \in \mathbb{R} \text{ für } K+1 \leq i \leq N \text{ und } s_i < s_j \text{ für } i < j \end{aligned} \right\},$$

wobei  $m_i = \text{grad}(P_i)$  für  $1 \leq i \leq L$  ist.

Jedem Element  $E(b) \in V$  ist ein Parametervektor  $b \in \mathbb{R}^{2N-K+L}$  zugeordnet:

$$b = ( b_{1,0}, \dots, b_{1,m_1}, b_{2,0}, \dots, b_{L,0}, \dots, b_{L,m_L}, b_{K+1}, \dots, b_N, \\ s_1, \dots, s_L, s_{K+1}, \dots, s_N ) \longleftrightarrow \\ \longleftrightarrow E(b, x) = \sum_{i=1}^L \left( \sum_{j=0}^{m_i} b_{i,j} x^j \right) e^{s_i x} + \sum_{i=K+1}^N b_i e^{s_i x} \in V$$

Damit genügt  $V$  den Voraussetzungen von Hilfssatz 3.2. Der Gradientenraum von  $E$  als Element von  $V$  hat die Dimension  $N+L$  und es gibt daher für  $f-E$  in  $X$  eine Alternante der Länge  $N+L+1$ ; dies ist die zweite Behauptung des Satzes.

**Bemerkung: Minimallösung bezüglich  $V_N^0$**

In  $V_N$  stimmen also im allgemeinen die notwendige und hinreichende Bedingung für eine Minimallösung nicht überein; da für  $E \in V_N^0$  die Länge mit dem Grad zusammenfällt, ist in diesem Fall die Existenz einer Alternante der Länge  $N+K+1 = N+L+1$  von  $f-E$  in  $X$  notwendig *und* hinreichend dafür, daß  $E$  Minimallösung für  $f$  auf  $X$  bezüglich  $V_N$  ist.

Zu folgendem Korollar vergleiche man Satz 16 in [11].

**Korollar 3.1 (Charakterisierung & Eindeutigkeit bezüglich  $V_N^0$ )**

Es sei

$$E(a, x) = \sum_{i=1}^L a_i e^{t_i x} \in V_N^0$$

mit der Länge  $L$  gegeben.

**Behauptung:**

- a. Ist  $E(a)$  auf  $X$  Minimallösung für  $f$  bezüglich  $V_N^0$ , dann ist  $E(a)$  die eindeutig bestimmte Minimallösung für  $f$  bezüglich  $V_N$  und  $V_N^0$ .
- b.  $E(a)$  ist genau dann beste Approximation auf  $X$  an  $f$  bezüglich  $V_N^0$ , wenn  $f - E(a)$  in  $X$  eine Alternante der Länge  $N + L + 1$  besitzt.

**Beweis:**

$V_N^0$  erfüllt die Voraussetzungen von Hilfssatz 3.2 und der Gradientenraum von  $E(a)$  besitzt die Dimension  $N + L$ .

Ist daher  $E(a)$  eine Minimallösung für  $f$  auf  $X$  bezüglich  $V_N^0$ , dann besitzt  $f - E(a)$  in  $X$  eine Alternante der Länge  $N + L + 1$  und Satz 3.1a ergibt den ersten Teil der Behauptung.

Liegt umgekehrt eine solche Alternante vor, so ist  $E(a)$  Minimallösung bezüglich  $V_N$ , also insbesondere auch bezüglich  $V_N^0$ . Damit ist auch der zweite Teil der Behauptung gezeigt.

**Satz 3.2 (Braess, [1])**

$E(a) \in V_N^+$  ( $E(a) \in V_N^-$ ) mit der Länge  $L$  sei eine beste Approximation an  $f$  auf  $X$  bezüglich  $V_N^+$  ( $V_N^-$ ).

**Behauptung:**

- a.  $E(a)$  ist auch die beste Approximation an  $f$  bezüglich  $V_L^0$  und  $V_L$  auf  $X$ .
- b.  $E(a)$  ist die eindeutig bestimmte Minimallösung für  $f$  bezüglich  $V_N^+$  ( $V_N^-$ ) auf  $X$ .

**Beweis:**

**Zu a.:** Für  $L = 0$  ist nichts zu zeigen; es sei also  $L \geq 1$ .

Nach Voraussetzung ist  $E(a)$  eine beste Approximation an  $f$  bezüglich  $V := V_L^+ \setminus V_{L-1}, (V_L^- \setminus V_{L-1})$ .  $V$  erfüllt die Voraussetzungen von Hilfssatz 3.2 und der Gradientenraum von  $E(a)$  als Element von  $V$  hat die Dimension  $2L$ . Daher besitzt  $f - E(a)$  eine Alternante der Länge  $2L + 1$  in  $X$ . Aus Korollar 3.1 folgt hiermit der erste Teil der Behauptung.

**Zu b.:**  $E(a)$  ist also insbesondere die eindeutig bestimmte Minimallösung bezüglich  $V_L^+$  ( $V_L^-$ );  $E(b) \in V_N^+$  ( $E(b) \in V_N^-$ ) mit der Länge  $L_1$  sei eine

weitere Minimallösung:

$$(3.8) \quad \| f - E(b) \|_X = \| f - E(a) \|_X$$

Damit ist  $E(b)$  auch Minimallösung für  $f$  bezüglich  $V_{L_1}^0$ . Aus der Eindeutigkeitsaussage von Korollar 3.1 folgt wegen (3.8)

$$L = L_1, E(a) = E(b)$$

Damit ist auch der zweite Teil der Behauptung gezeigt.

**Bemerkung:**

1. Satz 3.2 besagt für die Approximation durch Exponentialsummen, daß ein Algorithmus, der eine beste Approximation an  $f$  bezüglich  $V_N$  ermittelt, zugleich für die Approximation bezüglich  $V_N^+$  und  $V_N^0$  zu verwenden ist. Hat man umgekehrt ein Verfahren zur Berechnung der besten Approximation bezüglich  $V_N^+$ , so erhält man damit auch die beste Approximation bezüglich  $V_L$ , wobei  $L$  nach Satz 3.2 bestimmt ist.
2. Im Beweis von Satz 3.2 wird  $V_L^+ \setminus V_{L-1}$  betrachtet, da die für  $V_L^+$  definierte Parametermenge in  $\mathbb{R}^{2L}$  nicht offen ist; Hilfssatz 3.2 ist damit nicht auf  $V_L^+$  anzuwenden. Diese Tatsache wirkt sich auch bei der Charakterisierung der Minimallösung bezüglich  $V_N^+$  in Satz 3.4 aus.

Nach Korollar 3.1 und Satz 3.2 sind also die Minimallösungen für  $f$  bezüglich  $V_N^0$  und  $V_N^+$ ,  $V_N^-$  eindeutig bestimmt; es soll nun gezeigt werden, daß dies in  $V_N$  allgemein nicht gilt<sup>4</sup>.

**Hilfsatz 3.3** Es sei  $J=[-y,y]$  und  $V \subseteq C(J)$ ; ferner sei  $v \in V$  die eindeutig bestimmte beste Approximation an  $f \in C(J)$  bezüglich  $V$  auf  $J$  und es sei die Funktion  $w$  mit  $w(x) = v(-x)$  für  $x \in J$  in  $V$  enthalten. Für  $f$  gelte  $f(x) = f(-x)$ ,  $x \in J$ .

**Behauptung:** Für  $x \in J$  gilt  $v(x) = v(-x)$

**Beweis:**

Mit  $x \in J \Rightarrow -x \in J$  erhält man

$$\begin{aligned} \| f - v \|_J &= \max_{x \in J} | f(x) - v(x) | = \max_{x \in J} | f(-x) - v(-x) | = \\ &= \max_{x \in J} | f(x) - w(x) | = \| f - w \|_J \end{aligned}$$

Aus der Eindeutigkeit der Minimallösung folgt

$$v(x) = w(x) = v(-x), x \in J$$

und damit die Behauptung.

---

<sup>4</sup> s. Satz 3.3

**Satz 3.3 (Nichteindeutigkeit; Braess, [1])**

Es sei  $J=[-1,1]$ ; ist  $f \in C(J)$  streng monoton fallend auf  $[0,1]$  und gilt  $f(x) = f(-x) > 0$  für  $x \in J$ , dann gibt es für  $f$  auf  $J$  mindestens zwei Minimallösungen bzgl  $V_2$ .

**Beweis:**

Die Existenz einer besten Approximation  $E \in V_2$  für  $f$  auf  $J$  folgt aus Satz 2.6.

Annahme:

$E$  ist die eindeutig bestimmte Minimallösung für  $f$  bezüglich  $V_2$  auf  $J$ .

Nach Hilfssatz 3.3 folgt

$$(3.9) \quad E(x) = E(-x), \quad x \in J$$

Es gilt  $E \not\equiv 0$  nach Satz 3.1 und Voraussetzung.

Fall 1:  $E(x) = (a + bx)e^{tx}$

Nach (3.9) folgt also  $(a + bx)e^{tx} - (a - bx)e^{-tx} = 0$  für  $x \in J$ . Mit Satz 1.1 erhält man daraus  $E(x) = a \in \mathbb{R}$ .

Fall 2:  $E(x) = a_1e^{t_1x} + a_2e^{t_2x}$

Aus (3.9) folgt für alle  $x \in J$

$$a_1(e^{t_1x} - e^{-t_1x}) + a_2(e^{t_2x} - e^{-t_2x}) = 0$$

Beachtet man weiter  $E \not\equiv 0$  und  $t_2 \neq t_1$ , so ergibt sich  $a_1 = a_2 = a$  und  $-t_2 = t = t_1$  und damit

$$E(x) = a(e^{tx} + e^{-tx}) \text{ oder } E(x) = a \in \mathbb{R}$$

Aus (3.9) folgt also  $E(x) = a(e^{tx} + e^{-tx})$ ,  $a, t \in \mathbb{R}$  (mit  $t = 0$  erhält man die konstante Funktion).

Wegen der Monotonie von  $f$  besitzt  $f - E$  in jedem Fall höchstens zwei Nullstellen in  $J$ . Dies steht im Widerspruch zur Aussage von Satz 3.1, wonach  $f - E$  in  $J$  eine Alternante hat, deren Länge mindestens 4 ist. Damit ist die Annahme widerlegt.

Zur Charakterisierung der Minimallösung bezüglich  $V_N^+$  beachte man die Bemerkung von oben.

**Satz 3.4 (Charakterisierung bezüglich  $V_N^+$ ; Braess, [1])**

Gegeben sei  $E(a, x) = \sum_{i=1}^L a_i e^{t_i x} \in V_N^+$  mit der Länge  $L$ .

**Behauptung:**

Für  $L = N$  ist  $E(a)$  genau dann Minimallösung für  $f$  bezüglich  $V_N^+$  auf  $X$ , wenn  $f - E(a)$  in  $X$  eine *Alternante der Länge  $2N + 1$*  besitzt.

Gilt  $L < N$ , so ist  $E(a)$  genau dann Minimallösung für  $f$  bezüglich  $V_N^+$  auf  $X$ , wenn  $f - E(a)$  in  $X$  eine *negative Alternante der Länge  $2L + 1$*  besitzt.

**Beweis:**

Es sei  $F := f - E(a)$ .

Aus Korollar 3.1 und Satz 3.2 folgt die Behauptung für  $L = N$ .

Für  $L = 0$  ist nichts zu zeigen. Es sei  $1 \leq L < N$ :  $E(a) \in V_{N-1}^+$ .

**a. ( $\Rightarrow$  ist Minimallösung)**

$F$  besitze in  $X$  eine negative Alternante der Länge  $2L + 1$

(3.10)

mit den Alternantenpunkten  $x_i \in X$ ,  $1 \leq i \leq 2L + 1$

Annahme:

$E(b, x) = \sum_{i=1}^{L_1} b_i e^{s_i x} \in V_N^+$  mit der Länge  $L_1$

(3.11) ist eine bessere Approximation an  $f$ :

$$\|F\|_X > \|f - E(b)\|_X$$

Damit gilt nach Satz 3.2  $L_1 > L$  und

$E := E(b) - E(a) = (f - E(a)) - (f - E(b))$

(3.12)

besitzt in  $(x_1, x_{2L+1})$  mindestens  $2L$  Nullstellen

Im Vorzeichenvektor  $S := \text{sign}(E)$  liegen also mindestens  $2L$  Vorzeichenwechsel vor. Da aber  $S$  genau  $L$  negative Komponenten enthält, muß gelten:

1.  $s_1 < t_1$  und  $t_L < s_{L_1}$
2. Für jedes  $i$  mit  $1 \leq i \leq L - 1$  gibt es im Spektrum von  $E(b)$  ein  $s(i)$  mit  $t_i < s(i) < t_{i+1}$ .

Damit erhält man

$$\lim_{x \rightarrow -\infty} E(x)e^{-s_1 x} = \lim_{x \rightarrow -\infty} \left( b_1 + \sum_{i=2}^{L_1} b_i e^{(s_i - s_1)x} - \sum_{i=1}^L a_i e^{(t_i - s_1)x} \right) = b_1 > 0$$

und entsprechend

$$\lim_{x \rightarrow \infty} E(x)e^{-s_{L_1} x} = b_{L_1} > 0$$

Da in  $S$  höchstens  $2L$  Vorzeichenwechsel auftreten können, besitzt  $E \neq 0$  genau  $2L$  reelle Nullstellen, die nach (3.12) in  $(x_1, x_{2L+1})$  liegen.

Damit gilt für  $i \in \{1, 2L+1\}$   $E(x_i) > 0$ , also  $E(b, x_i) > E(a, x_i)$ , und wegen Annahme (3.11)  $f(x_i) > E(a, x_i)$ <sup>5</sup>. Dies steht jedoch im Widerspruch zu (3.10)<sup>6</sup>; die Annahme (3.11) ist damit falsch und  $E(a)$  ist Minimallösung für  $f$  bezüglich  $V_N^+$ .

### b. ( $\Rightarrow$ negative Alternante der Länge $2L+1$ )

(3.13) Es sei  $E(a) \in V_{N-1}^+$  Minimallösung bezüglich  $V_N^+$  für  $f$  auf  $X$

Nach Satz 3.2a ist  $E(a)$  dann auch Minimallösung bezüglich  $V_L^0$  und  $F$  besitzt eine Alternante der Länge  $2L+1$  in  $X$ .

Annahme:

(3.14)  $F$  besitzt in  $X$  keine negative Alternante der Länge  $2L+1$

Daraus folgt, daß jede Alternante von  $F$  in  $X$  höchstens die Länge  $2L+1$  hat, denn in jeder Alternante mit größerer Länge ist eine negative Alternante der Länge  $2L+1$  enthalten.  $E(a)$  ist daher keine Minimallösung bezüglich  $V_{L+1}$ ; es gilt also

$$\inf_{v \in V_{L+1}} \|f - v\|_X < \|F\|_X = \inf_{v \in V_L^+} \|f - v\|_X$$

und  $V_{L+1}$  enthält eine bessere Approximation  $E(b)$  an  $f$  auf  $X$ :

$$\|f - E(b)\|_X < \|F\|_X$$

Es sei  $x_1$  bzw.  $x_{2L+1}$  der kleinste bzw. größte Alternantenpunkt einer Alternante der Länge  $2L+1$  von  $F$  an  $X$ .

<sup>5</sup>  $E(a) \in V_N^+, E(b) \in V_N^+ \Rightarrow E(a, x) > 0 < E(b, x)$

<sup>6</sup> die Alternante von  $F$  ist eine *negative* Alternante

Nach Satz 3.2 gilt  $\text{grad}(E(b)) = L + 1$  und mit  $E = E(b) - E(a)$  erhält man für  $i \in \{1, 2L + 1\}$  wegen (3.14)

$$(3.15) \quad E(x_i) > 0$$

Wie oben besitzt E mindestens 2L Nullstellen in  $(x_1, x_{2L+1})$  und wegen  $E \not\equiv 0$  treten in  $S = \text{sign}(E)$  mindesten 2L Vorzeichenwechsel auf. Daraus folgt, daß die Spektren von E(a) und E(b) disjunkt sind; deshalb besteht S aus  $2L + 1$  Komponenten.

(3.16) In S treten also genau 2L Vorzeichenwechsel auf und

(3.17) E besitzt daher genau 2L reelle Nullstellen, die in  $(x_1, x_{2L+1})$  liegen

Es wird gezeigt: Aus (3.16) und (3.17) folgt  $E(b) \in V_{L+1}^+ \setminus V_L^+$ .

Damit für  $E(b) \in V_{L+1} \setminus V_{L+1}^0$  (3.16) gilt, muß erfüllt sein:

$$(3.18) \quad E(b, x) = (b_1 + b_2 x)e^{s_1 x} + \sum_{i=2}^L b_{i+1} e^{s_i x} \quad \text{mit } b_2 > 0 \text{ und} \\ s_1 < t_1 < s_2 < t_2 < \dots < s_L < t_L$$

oder

$$(3.19) \quad E(b, x) = \sum_{i=1}^{L-1} b_i e^{s_i x} + (b_L + b_{L+1} x)e^{s_L x} \quad \text{mit } b_{L+1} < 0 \text{ und} \\ t_1 < s_1 < t_2 < s_2 < \dots < t_L < s_L$$

oder o.B.d.A.

$$(3.20) \quad E(b, x) = \sum_{i=0}^2 b_{i+1} x^i e^{s_1 x} + \sum_{i=2}^{L-1} b_{i+2} e^{s_i x} \quad \text{mit } b_3 > 0 \text{ und} \\ t_1 < s_1 < t_2 < s_2 < \dots < s_{L-1} < t_L \\ (\text{wesentlich für das Folgende ist nur } t_1 < s_1 < t_L)$$

Die Vorzeichen der übrigen Parameter sind damit, ebenso wie weiter unten, positiv, was jedoch nicht benötigt wird.

E(b) nach (3.18) ergibt

$$\begin{aligned}\lim_{x \rightarrow \infty} E(x)e^{-t_L x} &= \lim_{x \rightarrow \infty} ((b_1 + b_2 x)e^{(s_1 - t_L)x} + \sum_{i=2}^L b_{i+1}e^{(s_i - t_L)x} - \\ &\quad - \sum_{i=1}^{L-1} a_i e^{(t_i - t_L)x} - a_L) = -a_L < 0 \\ \lim_{x \rightarrow \infty} E(x)e^{-s_1 x} &= \lim_{x \rightarrow \infty} ((b_1 + b_2 x) + \sum_{i=2}^L b_{i+1}e^{(s_i - s_1)x} - \\ &\quad - \sum_{i=1}^L a_i e^{(t_i - s_1)x}) = -\infty\end{aligned}$$

Mit E(b) gemäß (3.19) erhält man entsprechend

$$\lim_{x \rightarrow \infty} E(x)e^{-s_L x} = -\infty \text{ und } \lim_{x \rightarrow \infty} E(x)e^{-t_1 x} = a_1 < 0$$

und mit E(b) nach (3.20)

$$\lim_{x \rightarrow \infty} E(x)e^{-t_L x} = -a_L < 0 \text{ und } \lim_{x \rightarrow \infty} E(x)e^{-t_1 x} = a_1 < 0$$

Dies steht im Widerspruch zu (3.15) und (3.17) und damit ist gezeigt:

$$\mathbf{E(b)} \notin \mathbf{V_{L+1}} \setminus \mathbf{V_{L+1}^0}.$$

Für  $E(b, x) = \sum_{i=1}^{L+1} b_i e^{s_i x} \in V_{L+1}^0$  gibt es genau drei Möglichkeiten, so daß (3.16) erfüllt ist:

1. Es gilt  $s_1 < s_2 < t_1 < s_3 < \dots < s_{L+1} < t_L$  und  $b_1 < 0, b_2 > 0$ .  
Damit folgt aber

$$(3.21) \quad \lim_{x \rightarrow \infty} E(x)e^{-t_L x} = a_L < 0 \text{ und } \lim_{x \rightarrow \infty} E(x)e^{-s_1 x} = b_1 < 0$$

2. Es gilt  $t_1 < s_1 < t_2 < \dots < s_{L-1} < t_L < s_{L+1}$  mit  $b_L > 0, b_{L+1} < 0$ .  
Man erhält hier analog:

$$(3.22) \quad \lim_{x \rightarrow \infty} E(x)e^{-s_{L+1} x} = b_{L+1} < 0, \quad \lim_{x \rightarrow \infty} E(x)e^{-t_1 x} = -a_1 < 0$$

Wie oben liefern (3.21) und (3.22) den gewünschten **Widerspruch**.

3. Es ist  $s_1 < t_1 < s_2 < \dots < s_L < t_L < s_{L+1}$ . Hier enthält S genau dann 2L Vorzeichenwechsel, wenn  $E(b) \in V_{L+1}^+$  erfüllt ist.

Damit ist gezeigt:

- Unter der Annahme, daß (3.14) gilt, gibt es in  $V_{L+1}$   
 (3.23) eine bessere Approximation an  $f$  auf  $X$  und jede  
 bessere Approximation in  $V_{L+1}$  ist Element von  $V_{L+1}^+ \subseteq V_N^+$

Dies steht aber im Widerspruch zur Voraussetzung (3.13) und die Annahme (3.14) ist daher falsch.

Damit ist der Satz ganz gezeigt.

Aus Satz 3.4 erhält man unmittelbar:

**Korollar 3.2** (Braess, [1])

$E(a) \in V_N^+$  mit dem Grad  $L$  sei Minimallösung für  $f$  auf  $X$  bezüglich  $V_N^+$ .

**Behauptung:**

- a. Gilt  $L < N$ , dann ist  $E(a)$  beste Approximation an  $f$  auf  $X$  bezüglich  $V_n^+$  für alle  $n > L$ ,  $n \in \mathbb{N}$ .
- b. Gilt  $L = N$ , dann hat für  $n < L$  die beste Approximation an  $f$  auf  $X$  bezüglich  $V_n^+$  die Länge  $n$ .

**Beweis:**

Für  $L < N$  besitzt  $f - E(a)$  in  $X$  nach Satz 3.4 eine negative Alternante der Länge  $2L + 1$ , woraus unmittelbar die erste Teilbehauptung folgt.

Es sei  $L = N$ ; ist für ein  $i \in \mathbb{N}$  mit  $i < N$   $E(b) \in V_i^+$  mit der Länge  $i - 1$  Minimallösung für  $f$  bezüglich  $V_i^+$ , dann ist  $E(b)$  also auch beste Approximation an  $f$  bezüglich  $V_N^+$ . Wegen  $E(b) \neq E(a)$  steht dies im Widerspruch zu Satz 3.2.

**Korollar 3.3** (Braess<sup>7</sup>)

$E(a) \in V_{N-1}^+$  sei Minimallösung für  $f$  auf  $X$  bezüglich  $V_{N-1}^+$ , nicht aber bezüglich  $V_N^+$ ;  $E(b) \in V_N$  sei eine bessere Approximation an  $f$ .

**Behauptung:**

a. 
$$E(b) \in V_N^+ \setminus V_{N-1}^+$$

b.

Mit  $E(a, x) = \sum_{i=1}^{N-1} a_i e^{t_i x}$  und  $E(b, x) = \sum_{i=1}^N b_i e^{s_i x}$  gilt

$$s_1 < t_1 < s_2 < t_2 < \dots < t_{N-1} < s_N$$

---

<sup>7</sup> wahrscheinlich [1]

**Beweis:**

Nach der Voraussetzung folgt:  $E(a)$  besitzt nach Korollar 3.2 die Länge  $2N - 1$  und  $f - E(a)$  hat in  $X$  eine Alternante der Länge  $2N - 1$ ; jede Alternante der Länge  $2N - 1$  von  $f - E(a)$  in  $X$  ist nicht negativ und es gibt keine Alternante größerer Länge in  $X$  für  $f - E(a)$ .

Daraus ergibt sich wie im Beweis zu Satz 3.4 die Behauptung<sup>8</sup>.

Es wird nun eine Verallgemeinerung von Korollar 3.3 angegeben, die Aussagen über die Vorzeichenvektoren von besten Approximationen ermöglicht<sup>9</sup>. Es wird hierzu benötigt:

**Bemerkung 3.3** (Braess, [1])

Besitzt ein Vorzeichenvektor mit  $k$  Komponenten  $w$  Vorzeichenwechsel, so gilt  $|k^+ - k^-| \leq k - w$ , wobei  $k^+$  bzw.  $k^-$  die Zahl der positiven bzw. negativen Komponenten ist.

**Beweis:**

1. Fall:  $k^- \leq k^+$

Es gilt  $w \leq 2k$ ; unter Beachtung von  $k^+ + k^- = k$  folgt damit

$$|k^+ - k^-| = k^+ - k^- = k^+ + k^- - 2k^- \leq k - w$$

2. Fall:  $k^- > k^+$

Es gilt entsprechend  $w \leq 2k^+$  und daher wie oben

$$|k^+ - k^-| = k^- - k^+ = k^- + k^+ - 2k^+ \leq k - w$$

**Satz 3.5** (Braess, [1])

$E(a) \in V_N^0$  mit  $S_1 = \text{sign}(E(a))$  und  $\text{grad}(E(a)) = N$  sei Minimallösung für  $f$  bezüglich  $V_N^0$  auf  $X$ .  $E(b) \in V_M$  mit  $\text{grad}(E(b)) = M$  und  $S_2 = \text{sign}(E(b))$  sei eine bessere Approximation an  $f$ .

**Behauptung:**

$S_2$  enthält mindestens ebensoviele positive und negative Komponenten wie  $S_1$ .

**Beweis:**

Da  $E(b)$  besser als  $E(a)$  approximiert, gilt  $M > N$  und  $E := E(b) - E(a) \neq 0$  besitzt mindestens  $2N$  reelle Nullstellen (man vergleiche hierzu (3.12)).

Daher besitzt  $S = \text{sign}(E)$  mindestens  $2N$  Vorzeichenwechsel.

---

<sup>8</sup> s. Feststellung (3.23) im Beweis zu Satz 3.4

<sup>9</sup> s. Satz 3.5

Die Zahl der positiven (negativen) Komponenten in  $S_1$  bzw.  $S_2$  bzw.  $S$  sei gegeben durch  $p_1$  ( $n_1$ ) bzw.  $p_2$  ( $n_2$ )  $p$  ( $n$ ). Es gilt also

$$(3.24) \quad p = n_1 + p_2 \quad \text{und} \quad n = n_2 + p_1$$

Mit  $\text{grad}(E) \leq M + N$  erhält man nach Bemerkung 3.3

$$(3.25) \quad |p - n| \leq M + N - 2N = M - N$$

Fall 1:  $p - n = |p - n|$

Mit (3.25) gilt also

$$(3.26) \quad N - M \leq n_1 + p_2 - n_2 - p_1 \leq M - N$$

Aus der ersten Ungleichung ergibt sich

$$\begin{aligned} p_2 - n_2 + p_2 - p_2 &\geq N - M - n_1 + p_1 = N - M - n_1 - p_1 + 2p_1 \\ 2p_2 - M &\geq -M + 2p_1 \\ p_2 &\geq p_1 \end{aligned}$$

Entsprechend ergibt die zweite Ungleichung in (3.26)

$$\begin{aligned} 2n_1 - N &\leq M - N - p_2 - n_2 + 2n_2 = -N + 2n_2 \\ n_1 &\leq n_2 \end{aligned}$$

Fall 2:  $p - n = -|p - n|$

Auch hier gilt (3.26) wegen  $p - n \leq |p - n|$ ; es folgt also

$$p_2 \geq p_1 \quad \text{und} \quad n_1 \leq n_2$$

Damit ist die Behauptung gezeigt.

### **Bemerkungen:**

1. Es sei darauf hingewiesen, daß für  $V_N^-$  die Satz 3.4, Korollar 3.2 und Korollar 3.3 entsprechenden Aussagen gelten; die Beweise verlaufen analog, man hat nur die Vorzeichen zu vertauschen.
2. Für Fragestellungen, wie sie zum Beispiel in der Physik oder Chemie auftreten (Behandlung von Abklingvorgängen, radioaktiver Zerfall), sind besonders die Ergebnisse wichtig, die die Approximation bezüglich  $V_N^+$  betreffen, da hier die linearen Koeffizienten  $a_i$  meist Massen darstellen und damit im allgemeinen nicht negativ sein sollen.

## 4 Lokale Minima

Es sei hier wieder  $I \subseteq \mathbb{R}$  ein kompaktes Intervall und  $f \in C(I)$ ; weiter gelte  $N \in \mathbb{N}$ .

### Definition 4.1

Eine Funktion  $E_0 \in V_N$  ( $E_0 \in V_N^0$ ) heißt ein *lokales Minimum* für  $f$  in  $V_N$  ( $V_N^0$ ), wenn es eine Umgebung  $U$  von  $E_0$  gibt, so daß für alle  $E \in U$  erfüllt ist:

$$\|f - E_0\|_I \leq \|f - E\|_I$$

Es wird gezeigt, daß im allgemeinen bei der Approximation von  $f$  durch Exponentialsummen mit der Existenz lokaler Minima nach Definition 4.1 zu rechnen ist; dies ist von großer Bedeutung für die Konstruktion einer Minimalösung durch Iterationsverfahren.

Einfache Verhältnisse liegen in  $V_N^0$  vor:

### Satz 4.1 (Werner, [21])

Jedes lokale Minimum für  $f$  in  $V_N^0$  ist die beste Approximation an  $f$  bezüglich  $V_N^0$  auf  $I$ .

### Beweis:

Es sei  $E(a, x) = \sum_{i=1}^N a_i e^{t_i x} \in V_N^0$  mit  $\text{grad}(E(a)) = K$  ein lokales Minimum für  $f$ . Wählt man  $\epsilon > 0$  hinreichend klein, dann ist  $E(a)$  nach Voraussetzung beste Approximation an  $f$  auf  $I$  bezüglich

$$V := \left\{ \sum_{i=1}^N b_i e^{s_i x} \in V_N^0 \mid \begin{array}{l} |a_i - b_i| < \epsilon > |s_i - t_i| \text{ für } 1 \leq K, \\ |b_i| < \epsilon > |s_i| \text{ für } K < i \leq N \end{array} \right\}$$

$V$  erfüllt die Voraussetzungen von Hilfssatz 3.2 und der Gradientenraum von  $E(a)$  als Element von  $V$  hat die Dimension  $N + K$ . Damit besitzt  $f - E(a)$  in  $I$  eine Alternante der Länge  $N + K + 1$  und nach Korollar 3.1 ist  $E(a)$  die (eindeutig bestimmte) beste Approximation an  $f$  bezüglich  $V_N^0$ .

Aus Satz 4.1 folgt mit Korollar 3.1 unmittelbar

### Korollar 4.1

Ist  $E(a) \in V_N^0$  ein lokales Minimum für  $f$  in  $V_N$ , dann ist  $E(a)$  die beste Approximation für  $f$  bezüglich  $V_N$

Damit ist gezeigt, daß lokale Minima für  $f$  in  $V_N$ , die nicht zugleich Minimallösungen sind, nur in  $V_N \setminus V_N^0$  enthalten sein können.

**Hilfsatz 4.1** (Braess, [2])

Es sei  $E(a)$  mit  $\text{grad}(E(a)) = K$  auf  $I$  Minimallösung für  $f$  bezüglich  $V_{N-1}^0$ , nicht aber bezüglich  $V_N^0$ . Die Menge

$$\{t_i \mid t_i \in \mathbb{R}, K+1 \leq i \leq N, t_i < t_{i+1}\}$$

sei so gegeben, daß sie mit dem Spektrum von  $E(a)$  kein Element gemeinsam hat.

**Behauptung:**

In jeder Umgebung von  $E(a)$  in  $V_N$  gibt es ein  $E(b) \in V_K^0$  und es gibt ein  $a_i \in \mathbb{R}$ ,  $K+1 \leq i \leq N$ , so daß für  $E(\bar{a}, x) := E(b, x) + \sum_{i=K+1}^N a_i e^{t_i x}$  gilt:

$$\|f - E(a)\|_I > \|f - E(\bar{a})\|_I$$

**Beweis:** (Man vergleiche hierzu den Beweis von Satz 8 und 9 in [11] und Satz 2.10 in [24].)

Man betrachte die Menge

$$V := \left\{ E(d) \in V_N \mid E(d, x) = \sum_{i=1}^N d_i e^{s_i x}, \quad (d_1, \dots, d_N, s_1, \dots, s_K) \in \mathbb{R}^{N+K}, \right. \\ \left. s_i = t_i \text{ für } K < i \leq N \right\}$$

Die Elemente von  $V$  werden mit  $v(p)$  bezeichnet, wobei der Parametervektor  $p \in \mathbb{R}^{N+K}$  dem Element  $v(p) \in V$  zugeordnet ist durch

$$p = (d_1, \dots, d_N, s_1, \dots, s_K) \in \mathbb{R}^{N+K} \leftrightarrow v(p, x) = \sum_{i=1}^K d_i e^{s_i x} + \sum_{i=K+1}^N d_i e^{t_i x} \in V$$

$E(a)$  ist ein Element von  $V$  und der dazugehörige Parametervektor sei wieder mit  $a$  bezeichnet:  $E(a) = v(a) \in V$ .

Der Gradientenraum  $W$  von  $v(a)$  hat die Dimension  $N+K$ ; nach Hilfsatz 3.2 ist daher  $v(a)$  nicht Minimallösung für  $f$  bezüglich  $V$ , da  $F = f - v(a)$  in diesem Fall, im Widerspruch zur Voraussetzung über  $E(a)$ , eine Alternante der Länge  $N+K+1$  hätte.

Die Punkte  $x_i \in I$ ,  $1 \leq i \leq N+K$ , seien Alternantenpunkte einer Alternante der Länge  $N+K$  von  $F$  in  $I$ , die nach Voraussetzung existiert;  $D$  sei die Menge der Extrempunkte von  $F$  in  $I$ :

$$D = \{x \in I \mid |F(x)| = \|F\|_I\}$$

Aus  $F \in C(I)$  folgt die Existenz von  $N+K-1$  Nullstellen  $z_1 < z_2 < \dots < z_{N+K-1}$  von  $F$  in  $I$ , so daß  $F$  auf  $D \cap [z_i, z_{i+1}]$  für  $0 \leq i \leq N+K-1$  das Vorzeichen nicht wechselt; dabei sei  $z_0 = q_1, z_{N+K} = q_2$  mit  $I = [q_1, q_2]$ .

Da  $W$  die Haarsche Bedingung erfüllt, gibt es mit  $d_1 = \min D$  ( $D$  ist kompakt) ein  $b \in \mathbb{R}^{N+K}$ , so daß gilt:

$$\begin{aligned} (b, \text{grad}(v(a, d_1))) &= \text{sign}(F(d_1)) \\ (b, \text{grad}(v(a, z_i))) &= 0 \quad 1 \leq i \leq N+K-1 \end{aligned}$$

Nach Bemerkung 3.2 hat  $(b, \text{grad}(v(a)))$  in  $I$  genau die  $N+K-1$  Nullstellen  $z_i, 1 \leq i \leq N+K-1$ , und wechselt dort sein Vorzeichen. Daraus folgt wie im Hilfsatz 3.2:

$$(4.1) \quad \min_{x \in D} (F(x) \times (b, \text{grad}(v(a, x)))) > 0$$

Es wird nun benutzt, daß  $v(a)$  Fréchet-differenzierbar ist:

$$\|v(a+r) - v(a) - (r, \text{grad}(v(a)))\|_I = o(\|r\|)$$

wobei  $r \in \mathbb{R}^{N+K}$  und  $\|r\|$  die Euklidische Norm von  $r$  ist.

Da  $D$  kompakt ist, gibt es eine offene Umgebung  $U$  von  $D$  in  $I$ , so daß wegen (4.1) für ein  $c > 0$ ,  $c \in \mathbb{R}$ , gilt:

$$F(x)(b, \text{grad}(v(a, x))) \geq 2c > 0 \quad x \in U$$

Für  $x \in U$  folgt mit  $t \in \mathbb{R}$ ,  $t > 0$

$$\begin{aligned} F(x)(v(a+tb, x) - v(a, x)) &= \\ &= F(x)t(b, \text{grad}(v(a, x))) + \\ &\quad + F(x)v(a+tb, x) - v(a, x) - (tb, \text{grad}(v(a, x))) \geq \\ &\geq 2ct - \|F\|_I \|v(a+tb) - v(a) - (tb, \text{grad}(v(a)))\|_I \end{aligned}$$

Daher gibt es ein  $T_1 > 0$ , so daß für  $t \in (0, T_1]$  für alle  $x \in U$  gilt:

$$F(x)(v(a+tb, x) - v(a, x)) \geq ct$$

Die Menge  $I \setminus U$  ist abgeschlossen in  $I$  und für  $x \in I \setminus U$  gilt

$$|F(x)| < \|F\|_I ;$$

daraus folgt  $h := \|F\|_I - \|F\|_{I \setminus U} > 0$  .

Die Dreiecksungleichung ergibt für  $t \in \mathbb{R}$

$$\begin{aligned} \|v(a+tb) - v(a)\|_I &\leq \| (tb, \text{grad}(v(a))) \|_I + \\ &\quad + \|v(a+tb) - v(a) - (tb, \text{grad}(v(a)))\|_I ; \end{aligned}$$

daher gibt es ein  $T_2 > 0$ , so daß für  $t \in (0, T_2]$  gilt:

$$\|v(a+tb) - v(a)\|_I \leq 2t \| (b, \text{grad}(v(a))) \|_I$$

Für  $T \in \mathbb{R}$  gelte

$$0 < T < \min \left\{ T_1, T_2, \frac{c}{4 \| (b, \text{grad}(v(a))) \|_I^2}, \frac{h}{4 \| (b, \text{grad}(v(a))) \|_I} \right\}$$

Für  $x \in U$  erhält man also

$$\begin{aligned} |f(x) - v(a+Tb, x)|^2 &= \\ &= |f(x) - v(a, x)|^2 - 2F(x)(v(a+Tb, x) - v(a, x)) + \\ &\quad + |v(a, x) - v(a+Tb, x)|^2 \leq \\ &\leq \|F\|_I^2 - 2cT + 4T^2 \| (b, \text{grad}(v(a))) \|_I^2 \leq \\ &\leq \|F\|_I^2 - 2cT + cT < \\ &< \|f - v(a)\|_I^2 \end{aligned}$$

Für  $x \in I \setminus U$  gilt die Abschätzung

$$\begin{aligned} |f(x) - v(a+Tb, x)| &\leq \\ &\leq |F(x)| + |v(a, x) - v(a+Tb, x)| \leq \\ &\leq \|F\|_I - \|F\|_I + \|F\|_{I \setminus U} + \|v(a) - v(a+Tb)\|_I \leq \\ &\leq \|F\|_I - h + 2T \| (b, \text{grad}(v(a))) \|_I \leq \|F\|_I - h + \frac{h}{2} < \\ &< \|f - v(a)\|_I \end{aligned}$$

Da  $T > 0$  beliebig klein gewählt werden kann, ist die Behauptung nach Definition von  $V$  gezeigt.

**Satz 4.2** (Braess, [2])

$E(a, x) = \sum_{i=1}^K a_i e^{t_i x}$  mit dem Grad  $K$  und  $S(a) = \text{sign}(E(a))$  sei Minimal-  
 lösung für  $f$  bezüglich  $V_{N-1}^0$ , nicht aber bezüglich  $V_N$ . In  $I$  habe  $f - E(a)$   
 eine positive (negative) Alternante der Länge  $N + K$ , deren Alternanten-  
 punkte mit  $x_i$ ,  $1 \leq i \leq N + K$ , bezeichnet werden.  $S = (S_1, \dots, S_N)$  sei ein  
 Vorzeichenvektor mit  $N$  Komponenten, so daß erfüllt ist:

1. Durch Streichen von  $N - K$  Komponenten  $S_{i_k}$ ,  $1 \leq k \leq N - K$ , in  $S$   
 erhält man  $S(a)$  und es gilt  $i_{k-1} < i_k$ .
2.  $S_{i_{N-K}} = +1$  ( $S_{i_{N-K}} = -1$ ) und  $\text{sign}(S_{i_{k-1}}) = -\text{sign}(S_{i_k})$ ,  $1 < k \leq N - K$ .

**Behauptung:**

$V_N(S)$  enthält eine bessere Approximation als  $E(a)$ .

**Beweis:**

(4.2) Die Menge  $T = \{s_i \mid K + 1 \leq i \leq N, s_i < s_j \text{ für } i < j\} \subseteq \mathbb{R}$   
 sei so gegeben, daß  $T$  und das Spektrum von  $E(a)$  disjunkt sind.

Ordnet man die Frequenzen von  $E(a)$  und die Elemente von  $T$  der Größe  
 nach, so erhält man eine aufsteigende Kette  $s'_1 < s'_2 < s'_3 < \dots < s'_N$  ;  
 für die Elemente von  $T$  gelte hierbei

$$(4.3) \quad s'_{i_k} = s_{K+k}, \quad 1 \leq k \leq N - K$$

Nach Hilfssatz 4.1 gibt es in  $V_N$  eine bessere Approximation

$$E(c, x) = E(b, x) + \sum_{i=K+1}^N c_i e^{s_i x} \text{ mit } E(b, x) = \sum_{i=1}^K b_i e^{s_i x}, \text{ so daß gilt:}$$

1.  $\text{sign}(E(a)) = \text{sign}(E(b))$
- (4.4) 2.  $|s_i - t_i| < |s_i - t|$  für alle  $t \in T$  und für alle  $i$  mit  $1 \leq i \leq K$

Dies ergibt sich aus der Konstruktion der besseren Approximation  $E(c)$  nach  
 Hilfssatz 4.1. Nach einem mehrfach benutzten Schluß besitzt  $E := E(c) - E(a) \neq 0$   
 in  $(x_1, x_{N+K})$  mindestens  $N + K - 1$  Nullstellen und  $S(E) = \text{sign}(E)$   
 hat nach Satz 1.3 daher mindestens  $N + K - 1$  Vorzeichenwechsel;

(4.5)  $S(E)$  besteht also aus genau  $N + K$  Komponenten, die abwechselnd  
 positiv und negativ sind.

Nach Satz 1.1 hat  $E$  genau  $N + K - 1$  reelle Nullstellen. Ist die Alternante der Voraussetzung positiv (negativ), so gilt

$$E(x_{N+K}) > 0 \quad ( E(x_{N+K}) < 0 )$$

Man beachte hierbei, daß nach Voraussetzung alle Alternanten von  $f - E(a)$  in  $I$  mit der Länge  $N + K$  positiv (negativ) sind, falls eine Alternante dieser Länge positiv (negativ) ist.

Aus (4.5) folgt weiter  $c_i \neq 0$  für  $K + 1 \leq i \leq N$ .

Wie im ersten Teil des Beweises zu Satz 3.4 erhält man damit

$$\begin{aligned} \text{für } s_N > t_K: & \quad \text{sign}(c_N) = +1 \quad (\text{sign}(c_N) = -1) \\ \text{für } s_N < t_K: & \quad \begin{cases} \text{sign}(b_K) = +1 & (\text{sign}(b_K) = -1) & \text{falls } s_K > t_K \text{ gilt} \\ \text{sign}(a_K) = -1 & (\text{sign}(a_K) = +1) & \text{falls } s_K < t_K \text{ gilt.} \end{cases} \end{aligned}$$

Die  $(N+K)$ -te Komponente von  $S(E)$  ist damit positiv (negativ).

In  $(s_i, s_{i+1})$  liegt für  $K + 1 \leq i \leq N - 1$  stets eine gerade Anzahl von Elementen aus dem Spektrum von  $E(a)+E(b)$ ; dies folgt aus (4.4). Mit (4.5) erhält man also für  $K + 1 \leq i \leq N$ :

$$\text{sign}(c_i) = -\text{sign}(c_{i+1}) \text{ und } \text{sign}(c_N) = +1 \quad (\text{sign}(c_N) = -1).$$

Damit ist die Behauptung gezeigt, denn  $E(c) \in V_N(\bar{S})$  ist eine bessere Approximation an  $f$  und wegen (4.3) erfüllt  $\bar{S} = \text{sign}(E(c))$  die Voraussetzung des Satzes.

**Bemerkung 4.1** (Braess, [2])

Für  $K = N - 1$  läßt sich die Zahl der verschiedenen Vorzeichenvektoren  $S$ , die man nach der in Satz 4.2 verwandten Konstruktion erhalten kann, genau bestimmen:

Es liege eine positive Alternante von  $f - E(a)$  vor und  $S(a)$  habe genau  $k^-$  negative Komponenten; die entsprechenden Frequenzen von  $E(a)$  teilen  $\mathbb{R}$  in  $k^- + 1$  Intervalle. Die Menge  $T$  besteht hier nur aus dem Element  $s_N$  und die Wahl von  $s_N$  bestimmt, wie oben gezeigt, den Vorzeichenvektor  $S$  der besseren Approximation  $E(c)$ . Daher gibt es also  $k^- + 1$  verschiedene Vorzeichenklassen, die bessere Approximationen enthalten.

Ist die betrachtete Alternante negativ, so ergeben sich analog  $k^+ + 1$  Vorzeichenklassen, wenn  $S(a)$  genau  $k^+$  positive Komponeten enthält.

**Satz 4.3** (Braess, [2])

$E(a) \in V_{N-1}^0$  mit  $grad(E(a)) = K \neq 0$  und dem Vorzeichenvektor  $S(a) = (S_1, \dots, S_K)$  sei die Minimallösung bezüglich  $V_{N-1}$  für  $f$  auf  $I$ .

Erfüllt jede Minimallösung  $E$  für  $f$  bezüglich  $V_N$  die Beziehung  $E \notin V_{N-1} \cup V_N^+ \cup V_N^-$ , dann gibt es in  $V_N$  mindestens zwei lokale Minima für  $f$ .

**Beweis:**

Es sei wieder  $F = f - E(a)$ . Nach Voraussetzung besitzt  $F$  in  $I$  eine Alternante der Länge  $N + K$  und falls diese positiv (negativ) ist, sind alle Alternanten von  $F$  in  $I$  mit dieser Länge positiv (negativ).

In  $V_N$  werden zwei verschiedene Vorzeichenklassen angegeben, die bessere Approximationen als  $E(a)$  enthalten:

Fall 1:  $K < N - 1$

Es sei  $s = +1$ , falls  $F$  in  $I$  eine positive Alternante der Länge  $N + K$  besitzt, und  $s = -1$ , falls diese negativ ist. Die  $N - K$  Komponenten von

$$( (-1)^{N-K-1}s, \dots, (-1)^1s, (-1)^0s )$$

lassen sich auf mindestens zwei Arten in  $S(a)$  einfügen, so daß man die verschiedenen Vorzeichenvektoren

$$\begin{aligned} & ( S_1, (-1)^{N-K-1}s, \dots ) \\ & ( (-1)^{N-K-1}s, (-1)^{N-K-2}s, S_1, \dots ) \end{aligned}$$

erhält

Fall 2:  $K = N - 1$

$F$  habe in  $I$  eine positive Alternante der Länge  $N + K$ . Hieraus folgt  $E(a) \notin V_{N-1}^+$ : Denn mit  $E(a) \in V_{N-1}^+$  erhält man durch Einfügen von  $s = +1$  in  $S(a)$  stets einen Vorzeichenvektor mit  $N$  positiven Komponenten, so daß nach Satz 4.2 in  $V_N^+ \setminus V_{N-1}$  eine bessere Approximation als  $E(a)$  enthalten ist; da  $f$  bezüglich  $V_N^+$  eine beste Approximation auf  $I$  besitzt und diese nach Satz 3.2 Element von  $V_N^+ \setminus V_{N-1}$  und auch beste Approximation bezüglich  $V_N$  ist, erhält man einen Widerspruch zur Voraussetzung.

Es gibt also ein  $i \in \{1, \dots, N - 1\}$  mit  $S_i = -1$ .

Durch Einfügen von  $s = +1$  in  $S(a)$  erhält man die Vorzeichenvektoren

$$\begin{aligned} & ( S_1, \dots, S_{i-1}, -1, S_{i+1}, \dots, S_{N-1}, +1 ) \\ & ( S_1, \dots, S_{i-1}, +1, -1, \dots, S_{N-1} ) \end{aligned}$$

Hat  $F$  eine negative Alternante der Länge  $N + K$  in  $I$ , so erhält man analog  $E(a) \notin V_{N-1}^-$ ; es gibt also ein  $i \in \{1, \dots, N - 1\}$  mit  $S_i = +1$  und man erhält

durch Einfügen von  $s = -1$  entsprechend die Vorzeichenvektoren

$$\begin{aligned} & ( S_1, \dots, S_{i-1}, +1, S_{i+1}, \dots, S_{N-1}, -1 ) \\ & ( S_1, \dots, S_{i-1}, -1, +1, \dots, S_{N-1} ) \end{aligned}$$

Es gibt somit für  $K = N - 1$  und  $K < N - 1$  nach Satz 4.2 mindestens zwei verschiedene Vorzeichenklassen in  $V_N$ , die bessere Approximationen an  $f$  als  $E(a)$  enthalten.

Nun wird gezeigt, daß es bezüglich jeder der soeben konstruierten Vorzeichenklassen eine beste Approximation an  $f$  gibt:

Es sei also  $V := V_N(S)$  so gegeben, daß  $V$  eine bessere Approximation an  $f$  enthält als  $E(a)$ ; nach Voraussetzung hat diese den Grad  $N$ . Die Folge  $(h_m)_{m \in \mathbb{N}}$  sei eine Minimalfolge in  $V$ ; es gilt also

$$\lim_{m \rightarrow \infty} \| f - h_m \|_I = \inf_{v \in V} \| f - v \|_I$$

und es kann o.B.d.A.  $\text{grad}(h_m) = N$  für  $m \in \mathbb{N}$  angenommen werden.

Nach Satz 2.3 gibt es eine Teilfolge  $(h_m)_{m \in \mathbb{N}}$ , die auf jedem abgeschlossenen Teilintervall von  $I$  gleichmäßig konvergiert und die Grenzfunktion ist ein Element von  $V$  nach Korollar 2.5; daraus folgt mit  $f \in C(I)$  wie im Beweis zu Satz 2.4 die Existenz einer besten Approximation  $h$  bezüglich  $V$ . Nach Voraussetzung gilt  $\| f - E(a) \|_I > \| f - h \|_I$  und mit

$$0 < \epsilon = \| f - E(a) \|_I - \| f - h \|_I$$

gilt für  $h_1 \in V_N$  mit  $\| h - h_1 \|_I < \epsilon$

$$\| f - h_1 \|_I \leq \| f - h \|_I + \| h - h_1 \|_I < \| f - E(a) \|_I$$

Es gibt es also eine Umgebung  $U$  von  $h$  in  $V_N$  mit  $U \subseteq V_N(S) \setminus V_{N-1}$ , so daß gilt<sup>10</sup>:

$$\| f - h_1 \|_I \geq \| f - h \|_I \quad h_1 \in U$$

Dies war zu zeigen.

---

<sup>10</sup> Korrektur von [26]: dort wird an dieser Stelle auf ein (in [26] nicht existierendes) "Korollar 2.7" Bezug genommen.

## Teil II

# Numerische Verfahren

## 5 Konstruktion von Näherungen

Es sei  $I$  das Intervall  $[a, b] \in \mathbb{R}$  und  $f \in C(I)$ ;  $N \in \mathbb{N}$ .

Es werden nun Verfahren zur Konstruktion von Näherungen beschrieben; das entscheidende Problem hierbei ist die Behandlung eines nichtlinearen Gleichungssystems.

### 5.1 Näherungen nach Meinardus

Gegeben sei eine Punktmenge  $X = \{x_i \mid 0 \leq i \leq 2N - 1\} \subseteq I$ ; gesucht ist eine Funktion

$$(5.1) \quad \begin{aligned} E(x) &= \sum_{i=1}^N a_i e^{t_i x} \in V_N^0 && \text{mit} \\ E(x_i) &= f(x_i) && 0 \leq i \leq 2N - 1 \end{aligned}$$

Nach [13] wird eine zumindest formale Lösung dieses Interpolationsproblems angegeben; hierzu wird  $X$  als äquidistante Punktmenge angenommen:

$$x_i = a + ih \quad 0 \leq i \leq 2N - 1, \quad h > 0 .$$

Setzt man für  $1 \leq j \leq N$

$$\begin{aligned} A_j &:= a_j e^{t_j a}, \quad E_j := e^{t_j h} \\ f_j &:= f(x_j) \quad \text{für } 0 \leq j \leq 2N - 1, \end{aligned}$$

so erhält man aus (5.1)

$$(5.2) \quad \sum_{j=1}^N A_j E_j^i = f_i \quad 0 \leq i \leq 2N - 1$$

Zur Lösung dieses nichtlinearen Gleichungssystems mit den  $2N$  Unbekannten  $A_j$  und  $E_j$  wird ein Verfahren angewandt, das auf Srinvasa Ramanujan, [14], zurückgeht:

Die rationale Funktion

$$R(x) := \sum_{j=1}^N \frac{A_j}{1 - E_j x}$$

besitzt für  $x \in U$ ,  $U = \{x \in \mathbb{R} \mid \max_{1 \leq j \leq N} |E_j x| < 1\}$ , die Darstellung <sup>11</sup>

$$R(x) = \sum_{j=1}^N A_j \sum_{i=0}^{\infty} E_j^i x^i = \sum_{i=0}^{\infty} x^i \sum_{j=1}^N A_j E_j^i$$

Mit  $f_i := \sum_{j=1}^N A_j E_j^i$  für  $i \geq 2N$  erhält man unter Beachtung von (5.2) für  $x \in U$ :

$$R(x) = \sum_{i=0}^{\infty} x^i f_i$$

R lässt sich weiter schreiben in der Form  $R(x) = \frac{P(x)}{Q(x)}$  mit

$$(5.3) \quad P(x) := \sum_{i=0}^{N-1} p_i x^i := \sum_{j=1}^N A_j \prod_{i=1, i \neq j}^N (1 - E_i x) \quad \text{und}$$

$$(5.4) \quad Q(x) := \sum_{i=0}^N q_i x^i := \prod_{i=1}^N (1 - E_i x)$$

Es gilt somit für  $x \in U$ :

$$\sum_{i=0}^{N-1} p_i x^i = \left( \sum_{i=0}^N q_i x^i \right) \left( \sum_{i=0}^{\infty} x^i f_i \right) = \sum_{i=0}^{\infty} x^i \sum_{\substack{k+j=i \\ k \geq 0 \\ 0 \leq j \leq N}} q_i f_k$$

und Koeffizientenvergleich ergibt

$$\begin{aligned} \sum_{j=0}^i q_j f_{i-j} &= p_i & 0 \leq i \leq N-1 \\ \sum_{j=0}^N q_j f_{i-j} &= 0 & N \leq i \leq 2N-1 \end{aligned}$$

---

<sup>11</sup> wegen:  $\frac{1}{1-x} = \sum_{n=0}^{\infty} x^n$

Aus (5.4) folgt  $q_0 = 1$  und man erhält so ein lineares Gleichungssystem mit den  $2N$  Unbekannten  $q_i$ ,  $1 \leq i \leq N$ , und  $p_i$ ,  $0 \leq i \leq N - 1$ :

$$(5.5) \quad \begin{aligned} p_0 &= f_0 \\ \sum_{j=1}^i q_j f_{i-j} - p_i &= -f_i \quad 1 \leq i \leq N - 1 \end{aligned}$$

$$(5.6) \quad \sum_{j=1}^N q_j f_{i-j} = -f_i \quad N \leq i \leq 2N - 1$$

Die in (5.5) auftretende Dreiecksmatrix mit  $N-1$  Zeilen und Spalten sei mit  $L_{N-1}$  bezeichnet; die  $(N-N)$ -Matrix  $F_N$  des Systems (5.6) ist eine Hankelsche Matrix:

$$L_{N-1} = \begin{pmatrix} f_0 & 0 & 0 & 0 & \dots & 0 \\ f_1 & f_0 & 0 & 0 & \dots & 0 \\ f_2 & f_1 & f_0 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & 0 \\ f_{N-3} & f_{N-4} & \dots & \dots & f_0 & 0 \\ f_{N-2} & f_{N-3} & f_{N-4} & f_{N-5} & \dots & f_0 \end{pmatrix}$$

$$F_N = \begin{pmatrix} f_{N-1} & f_{N-2} & \dots & f_0 \\ f_N & f_{N-1} & \dots & f_1 \\ \vdots & \vdots & \vdots & \vdots \\ f_{2N-2} & f_{2N-3} & \dots & f_{N-1} \end{pmatrix}$$

### 5.1.1 Der Algorithmus

Zur Lösung von (5.2) und damit des Ausgangsproblems geht man vor wie folgt:

#### 1. Ermittlung der Frequenzen

Zuerst bestimmt man eine Lösung  $q$  des linearen Gleichungssystems (5.6):

$$F_N \times q = - \begin{pmatrix} f_N \\ f_{N+1} \\ \vdots \\ f_{2N-1} \end{pmatrix} \quad \text{mit } q = \begin{pmatrix} q_1 \\ q_2 \\ \vdots \\ q_N \end{pmatrix}$$

Existiert eine Lösung  $q$ , so werden die Nullstellen des Polynoms  $Q(x) = \sum_{i=0}^N q_i x^i$  mit  $q_0 = 1$  ermittelt.

Besitzt  $Q$  die  $N$  Nullstellen  $z_i$ ,  $1 \leq i \leq N$ , so sind diese wegen  $q_0 = 1$  von Null verschieden und nach (5.4) sei o.B.d.A.

$$(5.7) \quad E_i = z_i^{-1} \quad 1 \leq i \leq N$$

Besitzt  $Q$  nur einfache, reelle Nullstellen und ist weiter  $z_i > 0$  für  $1 \leq i \leq N$  erfüllt, so erhält man die reellen Frequenzen

$$t_i = h^{-1} \ln E_i = -h^{-1} \ln z_i, \quad 1 \leq i \leq N$$

2. Die Koeffizienten  $A_i$  und  $a_i$

Die Koeffizienten  $p_i$ ,  $1 \leq i \leq N-1$ , erhält man aus Gleichungssystem (5.5):

$$L_{N-1} \times \begin{pmatrix} q_1 \\ q_2 \\ \vdots \\ q_{N-1} \end{pmatrix} + \begin{pmatrix} f_1 \\ f_2 \\ \vdots \\ f_{N-1} \end{pmatrix} = \begin{pmatrix} p_1 \\ p_2 \\ \vdots \\ p_{N-1} \end{pmatrix}$$

Mit  $p_0 = f_0$  ergeben sich nunmehr aus (5.3) und (5.7) durch Koeffizientenvergleich die Größen  $A_i$ ,  $1 \leq i \leq N$ ; es genügt dazu, daß  $Q$  genau  $N$  reelle Nullstellen besitzt und so  $E_i$ ,  $1 \leq i \leq N$ , nach (5.7) bestimmt ist.

Für den Fall, daß  $Q$  nur einfache, reelle Nullstellen besitzt, kann man nach Satz 5.1  $A_i$  explizit angeben.

Sind  $N$  Frequenzen  $t_i \in \mathbb{R}$ ,  $1 \leq i \leq N$ , ermittelt, so gilt

$$a_i = A_i e^{-t_i a} \in \mathbb{R}, \quad 1 \leq i \leq N$$

### Bemerkungen:

1. Sind die Frequenzen  $t_i$ ,  $1 \leq i \leq N$  bekannt, dann können die Koeffizienten  $a_i$ ,  $1 \leq i \leq N$  auch durch Lösung des (nunmehr linearen) Gleichungssystems (5.1) bestimmt werden.
2. Ein nichtlineares Gleichungssystem wie (5.2) erhält man, wenn man an Stelle des Interpolationsproblems (5.1) ein Approximationsproblem auf einer Punktmenge

$$\{x_i \mid 0 \leq i \leq 2N, x_i = x_0 + ih\}$$

zu lösen versucht; man vergleiche hierzu Abschnitt 5.2.

3. Kelly beschreibt in [9] zur Lösung von (5.1) ein Verfahren von Prony ("Prony's method"):

Es wird benutzt, daß die  $f_i$ ,  $0 \leq i \leq 2N - 1$ , falls  $f_i = E(x_i)$  mit  $E \in V_N^0$  erfüllt ist, einer Differenzgleichung N-ter Ordnung genügen. Die Bestimmung der Koeffizienten dieser Differenzgleichung führt auf das Gleichungssystem (5.6) und die Frequenzen ergeben sich wie oben beschrieben.

### 5.1.2 Zur Theorie des Verfahrens

Die Bezeichnungen von oben werden beibehalten.

Formeln zur direkten Bestimmung der  $A_i$  gibt Satz 5.1 an:

#### Satz 5.1

$Q$  besitze die  $N$  einfachen, reellen Nullstellen  $E_j^{-1}$ ,  $1 \leq j \leq N$ ;  $E_j$  ist für  $1 \leq j \leq N$  wegen  $q_0 = 1$  definiert.

**Behauptung:**

$$A_k = \frac{\sum_{j=0}^{N-1} p_j E_k^{N-1-j}}{N \prod_{\substack{j=1 \\ j \neq k}} (E_k - E_j)} \quad 1 \leq k \leq N$$

**Beweis:**

Wegen  $E_j^{-1} \neq 0$  für  $1 \leq j \leq N$  erhält man aus (5.3) für  $1 \leq k \leq N$ :

$$\begin{aligned} \sum_{j=0}^{N-1} p_j E_k^{-j} &= \sum_{i=1}^N A_i \prod_{\substack{j=1 \\ j \neq i}}^N \left(1 - \frac{E_j}{E_k}\right) = A_k \prod_{\substack{j=1 \\ j \neq k}}^N \left(1 - \frac{E_j}{E_k}\right) \\ A_k &= \sum_{j=0}^{N-1} p_j E_k^{-j} \prod_{\substack{j=1 \\ j \neq k}}^N E_k (E_k - E_j)^{-1} = \sum_{j=0}^{N-1} p_j E_k^{N-1-j} \prod_{\substack{j=1 \\ j \neq k}}^N (E_k - E_j)^{-1} \end{aligned}$$

Damit ist die Behauptung gezeigt.

Es folgen nun Aussagen zur Existenz von Lösungen für das Gleichungssystem (5.6) und deren Eindeutigkeit.

**Hilfsatz 5.1**

Es sei  $n \in \mathbb{N}$ ; besitzt das Polynom  $\sum_{i=0}^n c_i x^i$  eine Nullstelle  $z \neq 0$ , dann ist  $z^{-1}$  eine Nullstelle des Polynoms  $\sum_{i=0}^n c_{n-i} x^i$ .

**Beweis:**

Nach Voraussetzung gilt

$$z^n \sum_{i=0}^n c_{n-i} (z^{-1})^i = \sum_{i=0}^n c_{n-i} (z^{n-i}) = 0$$

Wegen  $z^n \neq 0$  folgt daraus die Behauptung.

**Satz 5.2**

Es gelte  $f_i = E(x_i) = \sum_{j=1}^n a_j e^{t_j x_i}$  für  $0 \leq i \leq 2N - 1$  mit  $\text{grad}(E) = n \leq N$ ;

$A_i$  und  $E_i$  sind für  $1 \leq i \leq n$  definiert wie oben. Es sei  $z_i \in \mathbb{R}$  mit  $z_i \neq 0$  für  $n + 1 \leq i \leq N$  beliebig gewählt. Die Koeffizienten  $q_i$ ,  $0 \leq i \leq N$ , seien gegeben durch

$$\sum_{i=0}^N q_i x^i := \prod_{i=1}^n (1 - E_i x) \prod_{i=n+1}^N (1 - z_i x)$$

**Behauptung:**

$$(5.8) \quad \text{Es gilt} \quad F_N \begin{pmatrix} q_1 \\ q_2 \\ \vdots \\ q_N \end{pmatrix} = - \begin{pmatrix} f_N \\ f_{N+1} \\ \vdots \\ f_{2N-1} \end{pmatrix} \quad \text{und}$$

für  $n = N$  bilden die Koeffizienten  $q_i$ ,  $1 \leq i \leq N$  die eindeutig bestimmte Lösung von (5.8).

**Beweis:**

Das Polynom  $\sum_{i=0}^N q_i x^i$  besitzt nach Voraussetzung die  $n$  Nullstellen  $E_i^{-1}$ ,  $1 \leq$

$i \leq n$  ( $E_i^{-1}$  ist wegen  $E_i = e^{t_i h}$  stets definiert). Nach Hilfsatz 5.1 gilt für  $1 \leq k \leq n$ :

$$0 = \sum_{i=0}^N q_{N-i} E_k^i = \sum_{i=1}^N q_i E_k^{N-i} + q_0 E_k^N ;$$

wegen  $q_0 = 1$  folgt für  $1 \leq k \leq n$ :

$$\sum_{i=1}^N q_i E_k^{N-i} = -E_k^N$$

Für  $1 \leq j \leq N$  gilt hiermit

$$\begin{aligned} \sum_{i=1}^N f_{N+j-1-i} q_i &= \sum_{i=1}^N \left( \sum_{k=1}^n A_k E_k^{N+j-1-i} \right) q_i = \sum_{k=1}^n \left( \sum_{i=1}^N q_i E_k^{N-i} \right) A_k E_k^{j-1} = \\ &= \sum_{k=1}^n A_k E_k^{j-1} (-E_k^N) = f_{N+j-1} ; \end{aligned}$$

damit ist (5.8) gezeigt.

Es sei nun  $n = N$ ; es gilt also  $\sum_{i=0}^N q_i x^i = \prod_{i=1}^N (1 - E_i x)$  und es sei  $\begin{pmatrix} v_1 \\ v_2 \\ \vdots \\ v_N \end{pmatrix}$

eine zweite Lösung von (5.8); für  $1 \leq j \leq N$  folgt also

$$(5.9) \quad \sum_{i=1}^N f_{N+j-1-i} v_i = \sum_{k=1}^N A_k E_k^{j-1} \left( \sum_{i=1}^N v_i E_k^{N-i} \right) = -f_{N+j-1}$$

Die (N-N)-Matrix dieses Gleichungssystems besteht aus den Elementen  $A_k E_k^{j-1}$ ,  $1 \leq k, j \leq N$ . Wegen  $E \in V_N^0 \setminus V_{N-1}$  gilt

$$(5.10) \quad A_k \neq 0, \quad 1 \leq k \leq N, \quad \text{und} \quad 0 < E_k < E_{k+1}, \quad 1 \leq k \leq N-1.$$

Somit erhält man

$$\begin{aligned} &\det \begin{pmatrix} A_1 E_1^0 & A_2 E_2^0 & \dots & A_N E_N^0 \\ A_1 E_1^1 & A_2 E_2^1 & \dots & A_N E_N^1 \\ \vdots & \vdots & \vdots & \vdots \\ A_1 E_1^{N-1} & A_2 E_2^{N-1} & \dots & A_N E_N^{N-1} \end{pmatrix} = \\ &= \left( \prod_{i=1}^N A_i \right) \det \begin{pmatrix} 1 & 1 & \dots & 1 \\ E_1 & E_2 & \dots & E_N \\ \vdots & \vdots & \vdots & \vdots \\ E_1^{N-1} & E_2^{N-1} & \dots & E_N^{N-1} \end{pmatrix} \neq 0, \end{aligned}$$

da eine Vandermondesche Determinante vorliegt und die Ungleichungen (5.10) bestehen. Das Gleichungssystem (5.9) ist also eindeutig lösbar und es gilt daher für  $1 \leq k \leq N$

$$\sum_{i=1}^N v_i E_k^{N-i} = -E_k^N ,$$

da  $-\begin{pmatrix} E_1^N \\ \vdots \\ E_N^N \end{pmatrix}$  eine Lösung von (5.9) ist.

Das Polynom  $\sum_{i=0}^N v_i x^{N-i} = \sum_{i=0}^N v_{N-i} x^i$  mit  $v_0 = 1$  besitzt damit die  $N$  Nullstellen  $E_k$ ,  $1 \leq k \leq N$ , und nach Hilfssatz 5.1 gilt für  $x = E_k^{-1}$ :

$$\sum_{i=0}^N v_i x^i = 0 \quad 1 \leq k \leq N$$

Nach Voraussetzung stimmen die Nullstellen von  $\sum_{i=0}^N v_i x^i$  und  $\sum_{i=0}^N q_i x^i$  überein, womit die Eindeutigkeit gezeigt ist:

$$q_i = v_i , \quad 1 \leq i \leq N$$

**Bemerkung:**

Nimmt man an, daß  $f_i = E(x_i)$  für  $0 \leq i \leq 2N - 1$  mit  $E \in V_N^0 \setminus V_{N-1}$  erfüllt ist - (5.1) besitze also die eindeutig bestimmte Lösung  $E$  -, so folgt mit Satz 5.2, daß das beschriebene Verfahren die Lösung des Interpolationsproblems (5.1) ergibt.

Es soll nun noch gezeigt werden, daß die Aussage von Satz 5.2 zur Existenz einer Lösung nicht nur für  $E \in V_N^0$  richtig ist.

**Hilfsatz 5.2**

Für  $n \in \mathbb{N}$  und  $t \in \mathbb{R}$  gilt mit  $0 \leq m < n$ :

$$\sum_{k=0}^n (-1)^k \binom{n}{k} (t - k)^m = 0$$

**Beweis** (Meinardus, [13]):

Es sei  $K_r = \{z \in \mathbb{C} \mid |z| = r\}$ ,  $r \in \mathbb{R}$ . Unter Verwendung des Residuenkalküls erhält man für  $r > n$ :

$$\begin{aligned} \frac{1}{2\pi i} \int_{K_r} (t-z)^m \prod_{j=0}^n (z-j)^{-1} dz &= \sum_{k=0}^n \operatorname{Res}_{z=k} (t-z)^m \prod_{j=0}^n (z-j)^{-1} = \\ &= \sum_{k=0}^n \lim_{\substack{z \rightarrow k \\ z \neq k}} (z-k)(t-z)^m \prod_{\substack{j=0 \\ j \neq k}}^n (z-j)^{-1} = \sum_{k=0}^n (t-k)^m \prod_{\substack{j=0 \\ j \neq k}}^n (k-j)^{-1} = \\ &= \sum_{k=0}^n \frac{(t-k)^m}{k!(n-k)!} (-1)^{n-k} = (-1)^n \frac{1}{n!} \sum_{k=0}^n (-1)^k (t-k)^m \binom{n}{k} \end{aligned}$$

Es sei  $A(z) := \sum_{j=0}^m a_j z^j := (t-z)^m$  und  $B(z) := \sum_{j=0}^{n+1} b_j z^j := \prod_{j=0}^n (z-j)$ .

Es gilt  $a_m = (-1)^m$ ,  $b_{n+1} = 1$  und man erhält für  $z \in \mathbb{C}$ ,  $z \neq 0$ :

$$\begin{aligned} |A(z)| &\leq |z|^m \left(1 + \sum_{j=0}^{m-1} |a_j| |z|^{i-m}\right) \\ |B(z)| &\geq |z|^{n+1} \left(1 - \sum_{i=0}^n |b_i| |z|^{i-n-1}\right) \end{aligned}$$

Wählt man daher  $r_0 \in \mathbb{R}$ ,  $r_0 > n$ , hinreichend groß, so gilt  $|A(z)| \leq 2|z|^m$  und  $|B(z)| \geq \frac{1}{2}|z|^{n+1}$  für  $z \in \mathbb{C}$  mit  $|z| \geq r_0$ . Daraus folgt mit  $r \geq r_0$ :

$$\left| \int_{K_r} \frac{A(z)}{B(z)} dz \right| \leq 8\pi r^{m-n}$$

Wegen  $m < n$  erhält man somit für alle  $r \in \mathbb{R}$  mit  $r \geq r_0$

$$\frac{1}{n!} \left| \sum_{k=0}^n (-1)^k (t-k)^m \binom{n}{k} \right| \leq 4r^{-1},$$

woraus die Behauptung folgt.

**Bemerkung:**

Diesen Hilfssatz erhält man auch aus der Beziehung (s. Willers, [23], S. 73)

$$\Delta^n(0, 1, \dots, n)q = \frac{1}{n!} \sum_{k=0}^n (-1)^{n-k} \binom{n}{k} q(k)$$

mit  $q(x) = (t - x)^m$ ; denn aus  $m < n$  folgt nach (1.9)  $\Delta^n(0, 1, \dots, n)q = 0$  und damit  $\sum_{k=0}^n (-1)^k \binom{n}{k} (t - k)^m = 0$ .

**Satz 5.3**

Es sei  $N \geq 2$  und  $f_i = E(x_i)$  mit  $E(x) = \left(\sum_{i=0}^{N-1} a_i x^i\right) e^{tx} \in V_N \setminus V_{N-1}$  für  $0 \leq i \leq 2N - 1$ ; ferner sei mit  $E_1 = e^{tx}$  für  $0 \leq i \leq N$   $q_i$  gegeben durch  $\sum_{i=0}^N q_i x^i = (1 - E_1 x)^N$ .

**Behauptung:**

$$F_N \begin{pmatrix} q_1 \\ q_2 \\ \vdots \\ q_N \end{pmatrix} = - \begin{pmatrix} f_N \\ f_{N+1} \\ \vdots \\ f_{2N-1} \end{pmatrix}$$

**Beweis:**

Mit dem binomischen Lehrsatz erhält man

$$\sum_{i=0}^N q_i x^i = \sum_{i=0}^N (-1)^i \binom{N}{i} E_1^i x^i$$

und daraus durch Koeffizientenvergleich

$$q_i = (-1)^i \binom{N}{i} E_1^i, \quad 0 \leq i \leq N$$

Für  $1 \leq j \leq N$  gilt daher mit  $A = e^{ta}$ :

$$\begin{aligned} \sum_{i=1}^N f_{N+j-1-i} q_i &= A \sum_{i=1}^N \left(\sum_{k=0}^{N-1} a_k x_{N+j-1-i}^k\right) E_1^{N+j-1-i} q_i = \\ &= A E_1^{N+j-1} \sum_{k=0}^{N-1} a_k \left(\sum_{i=1}^N E_1^{-i} q_i x_{N+j-1-i}^k\right) = \\ &= A E_1^{N+j-1} \sum_{k=0}^{N-1} a_k \left(\sum_{i=1}^N (-1)^i \binom{N}{i} x_{N+j-1-i}^k\right) \end{aligned}$$

Mit  $0 \leq k < N$  erhält man durch Anwendung von Hilfssatz 5.2:

$$\begin{aligned}
\sum_{i=1}^N (-1)^i \binom{N}{i} x_{N+j-1-i}^k &= \sum_{i=1}^N (-1)^i \binom{N}{i} \sum_{m=0}^k \binom{k}{m} a^{k-m} (N+j-1-i)^m h^m = \\
&= \sum_{m=0}^k h^m \binom{k}{m} a^{k-m} \sum_{i=1}^N (-1)^i \binom{N}{i} ((N+j-1)-i)^m = \\
&= - \sum_{m=0}^k \binom{k}{m} a^{k-m} (N+j-1)^m h^m = \\
&= -x_{N+j-1}^k
\end{aligned}$$

Damit gilt

$$\sum_{i=1}^N f_{N+j-1-i} q_i = A E_1^{N+j-1} \sum_{k=0}^{N-1} a_k (-x_{N+j-1}^k) = -f_{N+j-1},$$

was zu zeigen war.

**Bemerkung:**

Versucht man (5.2) mit  $A_i > 0$  für  $1 \leq i \leq N$  zu lösen ( $0 < E_i < E_{i+1}$  gilt nach Definition), dann liegt ein endliches Momentenproblem vor (Gantmacher, [25], S. 211); nach [25] besitzt (5.2) in diesem Fall genau dann eine

Lösung, wenn die quadratischen Formen  $\sum_{j,k=0}^{N-1} f_{j+k} y_j y_k$ ,  $\sum_{j,k=0}^{N-1} f_{j+k+1} y_j y_k$  positiv definit sind. Läßt sich  $f$  als Dirichletsche Reihe mit positiven Koeffizienten darstellen, gilt also

$$f(x) = \sum_{n=1}^{\infty} c_n e^{s_n x} \text{ mit } c_n, s_n \in \mathbb{R}, c_i > 0 \text{ für } 1 \leq i \leq N \text{ und } c_n \geq 0, n \in \mathbb{N},$$

dann ist (5.2) lösbar, wie in [11] gezeigt ist:

Es gilt  $f_i > 0$  für  $0 \leq i \leq 2N-1$ ; mit  $f_{j+k} = \sum_{n=1}^{\infty} c_n e^{s_n a} e^{(j+k)h s_n}$  gilt

$$\begin{aligned}
\sum_{j,k=0}^{N-1} f_{j+k} y_j y_k &= \sum_{n=1}^{\infty} c_n e^{s_n a} \sum_{j,k=0}^{N-1} e^{j h s_n} y_j e^{k h s_n} y_k = \\
&= \sum_{n=1}^{\infty} c_n s^{s_n a} \left( \sum_{j=0}^{N-1} e^{j s_n h} y_j \right)^2,
\end{aligned}$$

so daß  $\sum_{j,k=0}^{N-1} f_{j+k} y_j y_k > 0$  gilt, falls nicht  $y_i = 0$ ,  $0 \leq j \leq N-1$  erfüllt ist (wegen  $c_i > 0$  für  $1 \leq i \leq N$ ).

Ebenso folgt die positive Definitheit der zweiten quadratischen Form. Man beachte hierzu die Beispiele von Kapitel 8.

Beispiel 5.1 zeigt, daß die Bestimmung von  $\det F_N$  keine Aussage über die Durchführbarkeit des Verfahrens zuläßt:

### Beispiel 5.1

Es sei  $N = 2$ ,  $X = \{0, 1, 2, 3\}$ .

1.  $f_0 = 1$ ,  $f_1 = e$ ,  $f_2 = e^2$ ,  $f_3 = e^3$ .

Es gilt

$$\det F_2 = \det \begin{pmatrix} e & 1 \\ e^2 & e \end{pmatrix} = 0,$$

jedoch lassen sich Lösungen von

$$F_2 \begin{pmatrix} q_1 \\ q_2 \end{pmatrix} = - \begin{pmatrix} e^2 \\ e^3 \end{pmatrix}$$

angeben: Die Lösungsmenge des Systems ist gegeben durch:

$$\left\{ \begin{pmatrix} -r \\ -e^{2+er} \end{pmatrix} \mid r \in \mathbb{R} \right\}.$$

Es sei nun  $r \in \mathbb{R}$ ,  $r \neq e$ , fest gewählt:

Damit folgt  $Q(x) = (-e^2 + er)x^2 - rx + 1$ ; die Nullstellen von  $Q$  sind  $z_1 = e^{-1}$  und  $z_2 = (r - e)^{-1}$ . Damit folgt  $E_1 = e$  und  $E_2 = r - e$ . Es gilt  $L_{N-1} = L_1 = 1$  und daher  $p_1 = -r + e$  und  $p_0 = 1$ .

Die Gleichung (5.3) lautet hier

$$1 + (e - r)x = A_1 + A_2 + x(e - r)A_1 - A_2ex$$

Dies ergibt:  $A_2 = 1 - A_1$  und  $e - r = (e - r)A_1 - (1 - A_1)e$

$$2e - r = A_1(2e - r) \implies A_1 = 1, A_2 = 0$$

Von Bedeutung ist also nur die Bestimmung von  $t_1$ :  $t_1 = \ln E_1 = 1$ . Man erhält  $E(x) = e^x$ ; dies ist die Lösung des Interpolationsproblems.

**2.**  $f_0 = 1, f_1 = -1, f_2 = 1, f_3 = 1.$

Hierfür gibt es keine Lösung  $E \in V_2$  mit  $E(i) = f_i, 1 \leq i \leq 3$ , da  $E \neq 0$  höchstens eine reelle Nullstelle besitzt. Die Gleichungen

$$\begin{aligned} -q_1 + q_2 &= -1 \\ q_1 - q_2 &= -1 \end{aligned}$$

sind unverträglich und es gilt

$$\det F_2 = \det \begin{pmatrix} -1 & 1 \\ 1 & -1 \end{pmatrix} = 0$$

## 5.2 Konstruktion einer Näherung nach Rice

Es sei in  $I = [a, b]$  die äquidistante Punktmenge

$$X = \{x_i \mid x_i \in I, x_i = a + ih, 1 \leq i \leq 2N + 1, h > 0\}$$

gegeben.

Unter der Annahme, daß es eine beste Approximation  $E \in V_N^0 \setminus V_{N-1}$  an  $f \in C(I)$  gibt, wird ein Verfahren zur Bestimmung von E nach Rice, [16], hergeleitet.

Man kann hoffen, auf diesem Wege Näherungen für die beste Approximation an f bezüglich  $V_N^0$  zu erhalten, da diese, sofern sie existiert und die Länge N besitzt, in I eine Alternante der Länge 2N+1 hat.

Es sei also  $E(x) = \sum_{i=1}^N a_i e^{t_i x} \in V_N^0 \setminus V_{N-1}$  die beste Approximation an f auf X; es gilt daher

$$(5.11) \quad E(x_i) = f(x_i) + (-1)^i r \quad 1 \leq i \leq 2N + 1$$

$|r|$  ist also die Minimalabweichung von f auf X; eliminiert man r durch Addition aufeinanderfolgender Gleichungen, so erhält man das Gleichungssystem

$$(5.12) \quad \sum_{i=1}^N a_i e^{t_i a} (e^{t_i h} + 1) e^{t_i j h} = f(x_j) + f(x_{j+1}) \quad 1 \leq j \leq 2N$$

Die Bestimmung der Koeffizienten und Frequenzen von E aus (5.12) wird nun nach Cesàro, [4], zurückgeführt auf die Ermittlung von Nullstellen eines Polynoms und die anschließende Lösung eines linearen Gleichungssystems. Hierzu werden die folgenden Bezeichnungen eingeführt:

$$\begin{aligned} f_j &:= f(x_j) + f(x_{j+1}) & 1 \leq j \leq 2N \\ A_i &:= a_i e^{t_i a} (e^{t_i h} + 1), \quad E_i := e^{t_i h} & 1 \leq i \leq N \end{aligned}$$

Damit erhält man aus (5.12)

$$\sum_{i=1}^N A_i E_i^j = f_j \quad 1 \leq j \leq 2N$$

und da nach Voraussetzung  $A_i \neq 0$  für  $1 \leq i \leq N$  erfüllt ist, gilt für  $1 \leq k \leq N$  (wegen der linearen Abhängigkeit der ersten Spalte):

$$\det \begin{pmatrix} f_k & E_1^k & \dots & E_N^k \\ f_{k+1} & E_1^{k+1} & \dots & E_N^{k+1} \\ \vdots & \vdots & \dots & \vdots \\ f_{k+N} & E_1^{k+N} & \dots & E_N^{k+N} \end{pmatrix} = 0$$

Wegen  $E_i \neq 0$ ,  $1 \leq i \leq N$ , folgt daher

$$(5.13) \quad \det \begin{pmatrix} f_k & 1 & \dots & 1 \\ f_{k+1} & E_1^1 & \dots & E_N^1 \\ \vdots & \vdots & \dots & \vdots \\ f_{k+N} & E_1^N & \dots & E_N^N \end{pmatrix} = 0 \quad 1 \leq k \leq N$$

Entwickelt man die Determinanten in (5.13) nach der ersten Spalte und ist  $D_i$  für  $0 \leq i \leq N$  die Adjunkte von  $f_{k+i}$ , so gilt (da  $D_i$  unabhängig ist von  $k$ ):

$$(5.14) \quad \sum_{i=0}^N f_{k+i} D_i = 0 \quad 1 \leq k \leq N$$

Ebenso erhält man

$$(5.15) \quad \sum_{i=0}^N E_j^i D_i = 0 \quad 1 \leq j \leq N$$

da in den entsprechenden Matrizen zwei Spalten übereinstimmen.

Aus  $E_i < E_{i+1}$  folgt

$$(5.16) \quad D_0 \neq 0 \quad D_N \neq 0$$

Je eine Gleichung aus dem System (5.15) ergibt zusammen mit (5.14) ein lineares, homogenes Gleichungssystem mit den Unbekannten  $D_i$ ,  $0 \leq i \leq N$ :

Es sei  $j \in \{1, \dots, N\}$ :

$$(5.17) \quad \begin{aligned} \sum_{i=0}^N E_j^i D_i &= 0 \\ \sum_{i=0}^N f_{k+i} D_i &= 0 \quad 1 \leq k \leq N \end{aligned}$$

Wegen (5.16) folgt hieraus für  $1 \leq j \leq N$ :

$$\det \begin{pmatrix} 1 & E_j^1 & \dots & E_j^N \\ f_1 & f_2 & \dots & f_{N+1} \\ f_2 & f_3 & \dots & f_{N+2} \\ \vdots & \vdots & \dots & \vdots \\ f_N & f_{N+1} & \dots & f_{2N} \end{pmatrix} = 0$$

Dies bedeutet, daß das Polynom

$$P(x) := \det \begin{pmatrix} x^0 & x^1 & \dots & x^N \\ f_1 & f_2 & \dots & f_{N+1} \\ f_2 & f_3 & \dots & f_{N+2} \\ \vdots & \vdots & \dots & \vdots \\ f_N & f_{N+1} & \dots & f_{2N} \end{pmatrix}$$

die  $N$  Nullstellen  $E_i = e^{t_i h}$ ,  $1 \leq i \leq N$ , besitzt.

Dieses Ergebnis legt folgendes Vorgehen zur Ermittlung der Parameter einer Näherung  $E$  nahe:

Man bestimmt die Nullstellen von  $P$ ; besitzt  $P$  die  $N$  Nullstellen  $E_i$ ,  $1 \leq i \leq N$ , und sind diese reell und weiterhin einfach und positiv, dann erhält man die  $N$  reellen Frequenzen

$$t_i = h^{-1} \ln E_i, \quad 1 \leq i \leq N$$

Mit diesen Werten löst man das lineare Gleichungssystem (5.11) oder (5.12), so daß damit die restlichen Parameter bestimmt sind.

Bemerkung:

Die Lösung von (5.11) ist vorteilhaft, falls  $\|f - E\|_X$  von Bedeutung ist, etwa zur Bestimmung einer unteren Schranke für  $\|f - E\|_I$ .

Da die Koeffizienten von  $P$  sich aus der Berechnung von Determinanten ergeben, können hier Rundungsfehler das Ergebnis besonders leicht beeinflussen.

### 5.3 Konstruktion einer Näherung nach Willers

In [23] behandelt Willers ein Verfahren zur “Annäherung” von Funktionen durch Elemente von  $V_N^0$ , falls  $m$  Funktionswerte (Messwerte) mit  $m \geq 2N$  gegeben sind.

Für die Konstruktion einer Näherung aus  $V_N^0$  für eine gegebene Funktion  $f \in C(I)$ ,  $I = [a, b]$ , bietet sich also mit diesem Verfahren die Möglichkeit, die Zahl der Funktionswerte, die in die Rechnung eingehen, zu variieren; mit  $m = 2N$  erhält man das in Abschnitt 5.1 beschriebene Verfahren.

Es sei also  $m \geq 2N$  und  $X = \{x_i \mid x_i = a + ih, h > 0, 1 \leq i \leq m\} \subseteq I$  gegeben. Nimmt man an daß

$$E(x_j) = f(x_j) \quad 1 \leq j \leq m$$

mit  $E(x) = \sum_{i=1}^N a_i e^{t_i x} \in V_N^0 \setminus V_{N-1}$  erfüllt ist, so erhält man mit  $A_i := a_i e^{t_i a}$ ,  $E_i := e^{t_i h}$  für  $1 \leq i \leq N$  und  $f_j := f(x_j)$  für  $1 \leq j \leq m$ :

$$(5.18) \quad \sum_{i=1}^N A_i E_i^j = f_j \quad 1 \leq j \leq m$$

Durch  $Q(x) := \sum_{j=0}^N q_j x^j := \prod_{j=1}^N (x - E_j)$  sei  $q_i$  für  $0 \leq i \leq N$  gegeben. Es gilt also

$$(5.19) \quad Q(E_j) = 0 \quad 1 \leq j \leq N$$

Es sei nun  $k \in \{1, \dots, m - N\}$  fest und man betrachte in (5.18) die  $N + 1$  Gleichungen

$$(5.20) \quad \sum_{i=1}^N A_i E_i^{j+k} = f_{j+k} \quad 0 \leq j \leq N$$

Multipliziert man für  $0 \leq j \leq N$  die  $(j+1)$ -te Gleichung von (5.20) auf beiden Seiten mit  $q_j$ , so erhält man mit (5.19) durch anschließende Addition der  $N+1$  Gleichungen:

$$\sum_{j=0}^N f_{j+k} q_j = \sum_{j=0}^N (q_j \sum_{i=1}^N (A_i E_i^{k+j})) = \sum_{i=1}^N (A_i E_i^k \sum_{j=0}^N q_j E_i^j) = 0$$

Da diese Beziehung für  $1 \leq k \leq m - N$  gilt, erhält man auf diese Weise ein lineares Gleichungssystem mit  $m - N$  Gleichungen und  $N$  Unbekannten  $q_i$ ,  $0 \leq i \leq N - 1$ , wegen  $q_N = 1$ :

$$(5.21) \quad \sum_{j=0}^{N-1} f_{j+k} q_j = -f_{N+k} \quad 1 \leq k \leq m - N$$

Es wird daher folgendes *Verfahren* vorgeschlagen:

Für  $m = 2N$  bestimme man die Unbekannten  $q_i$ ,  $0 \leq i \leq N - 1$ , durch Lösen des Gleichungssystems (5.21), falls dieses lösbar ist.

Für  $m > 2N$  bestimme man  $q_i$ ,  $0 \leq i \leq N - 1$ , durch Anwendung der Methode der kleinsten Quadrate.

Hat man so Koeffizienten  $q_i$ ,  $0 \leq i \leq N - 1$ , gefunden, so bestimmt man die Nullstellen  $E_i$ ,  $1 \leq i \leq N$  von  $\sum_{i=0}^N q_i x^i$  mit  $q_N = 1$ .

Gilt  $E_i \in \mathbb{R}$  und  $E_i > 0$  für  $1 \leq i \leq N$ , dann erhält man die  $N$  Frequenzen

$$t_i = h^{-1} \ln E_i \quad 1 \leq i \leq N$$

Sind die Nullstellen des Polynoms einfach, gilt also  $t_i \neq t_j$  für  $i \neq j$ , dann bestimmt man  $a_i$  für  $1 \leq i \leq N$  durch Lösung eines linearen Gleichungssystems, das aus  $N$  Gleichungen von (5.18) besteht.

## 5.4 Numerische Beispiele

Zur numerischen Erprobung der drei beschriebenen Verfahren sind mit der CD 3300 des Rechenzentrums der Universität Erlangen-Nürnberg Berechnungen durchgeföhrt worden; die Programme sind in FORTRAN IV geschrieben und es ist stets mit doppelter Genauigkeit gerechnet worden. Alle Zahlenangaben sind daher gerundete Größen.

*Anmerkung (Februar 2023):*

*Diese Berechnungen wurden nochmals mit MEINARDUS [27] durchgeföhrt.*

In den folgenden Beispielen werden die Bezeichnungen benutzt, wie sie bei der Herleitung der Verfahren eingeföhrt worden sind.

Für  $1 \leq N \leq 4$  treten mit  $f(x) = \frac{1}{x+1}$ ,  $f(x) = \sqrt{x}$  in  $I = [0, 1]$  oder der Riemannschen Zetafunktion in  $I = [2, 3]$ ,  $I = [2, 4]$  keine Schwierigkeiten auf: Es wurden keine Punktmenge  $X$  gefunden, so daß hier ein Verfahren gescheitert wäre. Die Güte der jeweiligen Näherung  $E$ , d.h.  $\|f - E\|_I$ , hängt wesentlich von der Menge  $X$  ab und man wird daher im allgemeinen, um gute Näherungen zu erhalten, verschiedene Punktfolgen  $X$  verwenden. In den Zeichnungen sind stets die jeweiligen Fehlerfunktionen  $f - E$  dargestellt.

### Beispiel 5.2

Es sei  $f(x) = \sqrt{x}$ ,  $I = [0, 1]$  und  $N=2$ .

Zu bestimmen ist also eine Näherung  $E(x) = a_1 e^{t_1 x} + a_2 e^{t_2 x}$ ; zur Beurteilung der folgenden Ergebnisse beachte man die Resultate von [26], §7.

Eine günstige Näherung liefert das **Verfahren von Meinardus**, Abschnitt 5.1, mit den Punkten  $x_i = 0.01 + ih$ ,  $0 \leq i \leq 3$ , wobei  $x_3 = 0.800$  und damit  $h = 0.2633$  ist. Man erhält die Polynomkoeffizienten

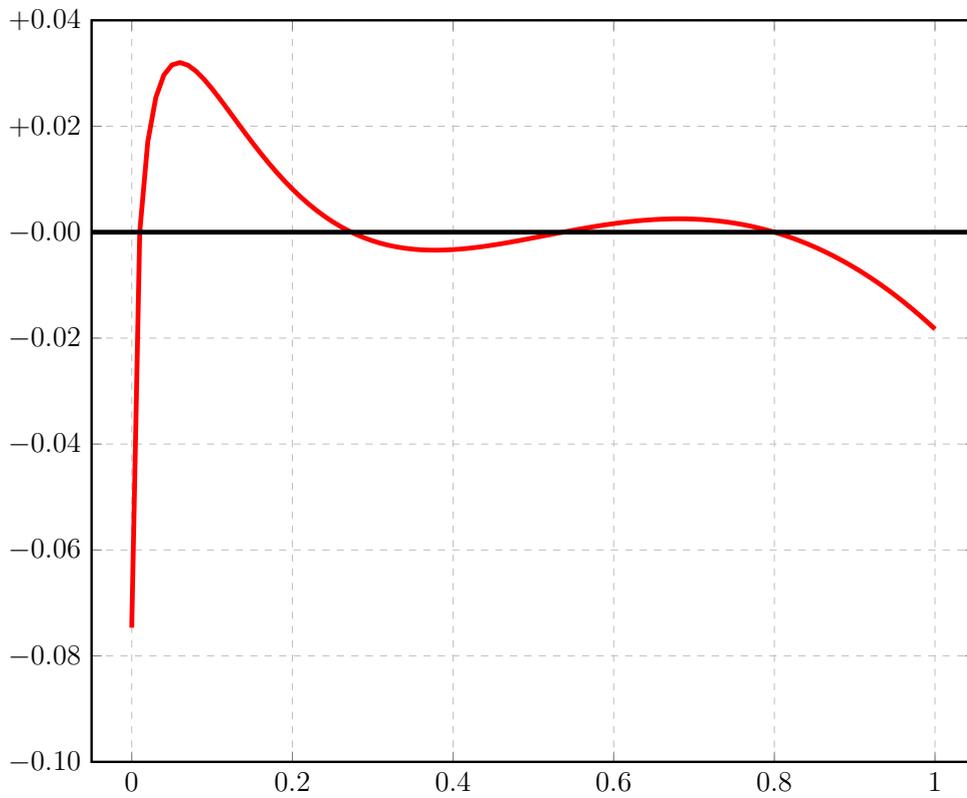
q2=+0.345 112 153 , q1=-1.467 229 623 , q0=+1.000 000 000 ,  
p1=+0.376 089 942 , p0=+1.000 000 000 .

Die Nullstellen von  $Q$  sind 3.398 958 380 und 0.852 499 044 .

Es ergeben sich die Parameter

a1=-0.483 373 717 , t1=-4.646 084 908  
a2= 0.558 037 443 , t2= 0.606 012 117

Zeichnung 5.1 stellt die Fehlerfunktion dar. Die Norm der Fehlerfunktion ist 0.07466.



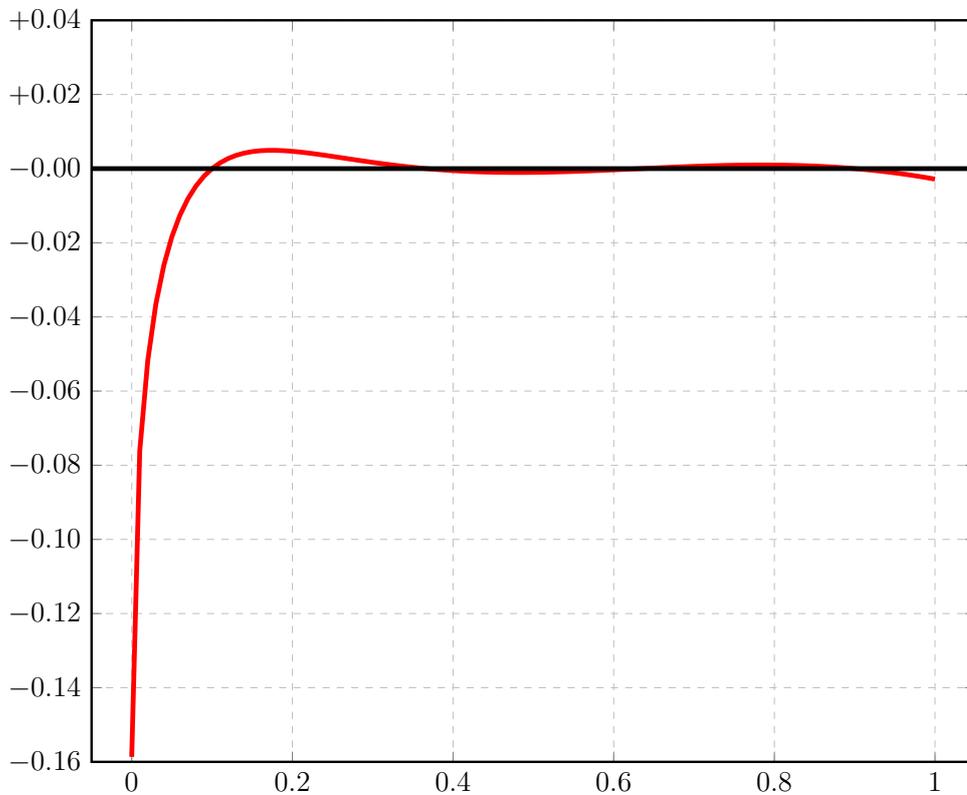
Zeichnung 5.1

Mit  $x_0 = 0.1$ ,  $x_3 = 0.9$ ,  $h = 0.2666$  erhält man

$a_1 = -0.496\ 967\ 379$  ,  $t_1 = -2.961\ 059\ 561$

$a_2 = +0.655\ 627\ 088$  ,  $t_2 = +0.450\ 327\ 955$

Zeichnung 5.2 stellt die Fehlerfunktion dar. Die Norm der Fehlerfunktion auf  $I$  ist hier 0.15866, womit die Abhängigkeit von  $X$  demonstriert sei.



Zeichnung 5.2

Das **Verfahren von Rice**, Abschnitt 5.2, ergibt mit  $x_i = \frac{i-1}{4}$ ,  $1 \leq i \leq 5$ , das Polynom  $P(x) = p_2x^2 + p_1x + p_0$  mit

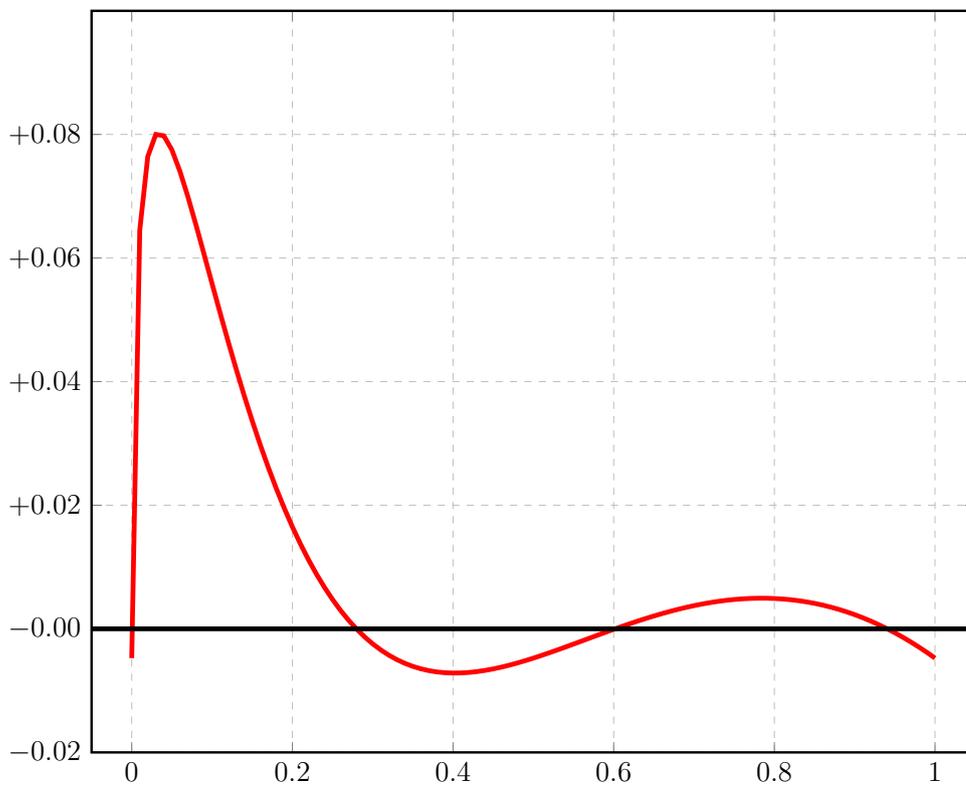
$p_2 = -0.670\ 540\ 689$  ,  $p_1 = +0.965\ 925\ 826$  ,  $p_0 = -0.222\ 252\ 952$

und den Nullstellen 1.153 063 231, 0.287 454 610. Man erhält so die Parameter

$a_1 = -0.565\ 826\ 602$  ,  $t_1 = -4.986\ 761\ 225$

$a_2 = +0.570\ 571\ 292$  ,  $t_2 = +0.569\ 688\ 323$

Zeichnung 5.3 stellt die Fehlerfunktion dar.



**Zeichnung 5.3**

Für  $1 \leq i \leq 5$  gilt

$$|\sqrt{x} - a_1 e^{t_1 x_i} - a_2 e^{t_2 x_i}| = 0.004\,744\,688$$

Damit ist gezeigt, daß, obwohl  $x_1 = 0.0$  und  $x_5 = 1.0$  Alternantenpunkte der Fehlerfunktion für die beste Approximation an  $f$  bezüglich  $V_2$  auf  $I$  sind, die Näherung nach Rice, die ja die beste Approximation auf  $\{x_i \mid 1 \leq i \leq 5\}$  für  $F$  ist, in  $x_1$  und  $x_5$  wesentlich von der Minimallösung für  $f$  bezüglich  $V_2$  verschieden sein kann.

Mit dem **Verfahren von Willers**, Abschnitt 5.3, kann man oft bessere Näherungen für die Frequenzen erhalten; es werden  $m$  Punkte

$$x_i = 0.0 + (i - 1) * h, 1 \leq i \leq m \text{ mit } x_m = 1.0$$

verwendet.

**m = 10:**

Es ist also  $h = \frac{1}{9}$ ; man errechnet die Koeffizienten

$$q_2 = +1.000\ 000\ 000, \quad q_1 = -1.456\ 251\ 707, \quad q_0 = +0.406\ 468\ 037$$

und damit die Nullstellen 1.079 834 854 und 0.376 414 853 .

Die Frequenzen sind also  $t_1 = -8.793\ 522\ 892$  ,  $t_2 = +0.691\ 273\ 052$  .

Durch Lösung des Systems

$$\sum_{i=1}^2 a_i e^{t_i x_k} = \sqrt{x_k} \quad k = 2, 3$$

folgt

$$a_1 = -0.420\ 954\ 177, \quad a_2 = +0.455\ 428\ 511$$

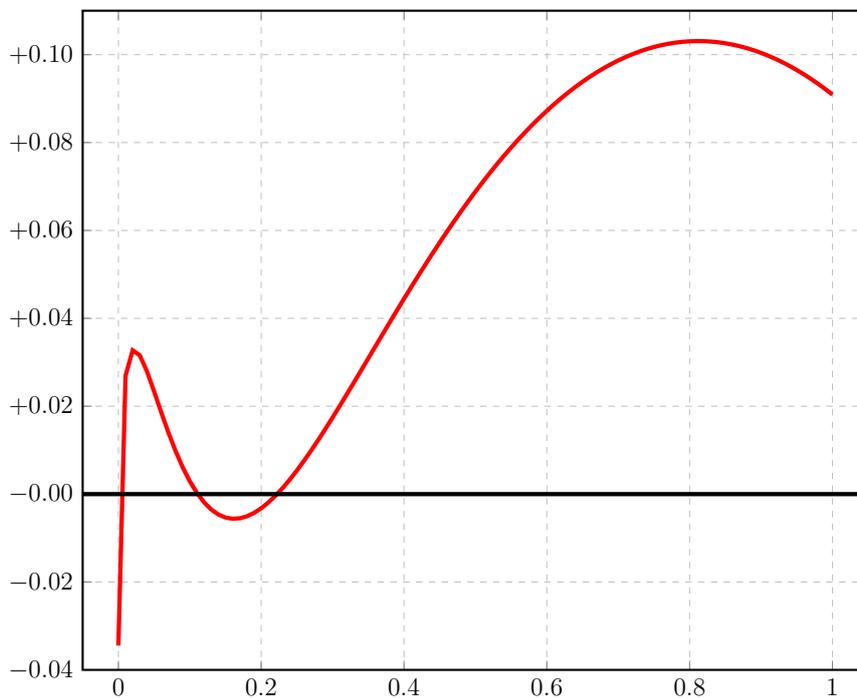
Zeichnung 5.4 stellt die Fehlerfunktion dar.

Durch Vergrößern von  $m$  erhält man nicht unbedingt bessere Werte:

m	t1	t2
22	-15.928 838	+0.799 146
32	-21.251 001	+0.838 908

*Anmerkung (Februar 2023):*

*Nach Neu-Implementierung des Verfahrens von Willers werden Zeichnungen der zugehörigen Fehlerfunktionen der Vollständigkeit halber nachgetragen.*



Zeichnung 5.4

Schwierigkeiten ergeben sich mit  $X \subseteq [-1, +1]$  für die Funktionen

- $f(x) = |x|$  bei  $N \geq 3$
- $f(x) = \begin{cases} -5 & : x \leq -0.5 \\ 10x & : x \in (-0.5, +0.5) \\ +5 & : x \geq +0.5 \end{cases}$  bei  $N \geq 2$
- $f(x) = \begin{cases} 2 + x & : x \leq 0 \\ 2 - x & : x \geq 0 \end{cases}$  bei  $N \geq 2$

Für die letzte Funktion wird dies nachfolgend in Beispiel 5.3 ausgeführt.

**Beispiel 5.3**

$$I = [-1, +1], N = 2, f(x) = \begin{cases} 2 + x & : x \leq 0 \\ 2 - x & : x \geq 0 \end{cases}$$

Bei der **Berechnung nach Meinardus** von Abschnitt 5.1 erhält man für  $Q$  meist komplexe Nullstellen, wie die folgende Tabelle zeigt<sup>12</sup>:

		<i>Die Nullstellen von <math>Q</math></i>	
$x_0$	$x_3$	<i>Realteil <math>\Re</math></i>	<i>Imaginärteile <math>\Im</math></i>
-1.0	1.0	0.8000	$\pm 0.6000$
-0.9	0.9	0.8235	$\pm 0.5673$
-0.8	0.8	0.8462	$\pm 0.5329$
-0.7	0.7	0.8679	$\pm 0.4967$
-0.5	0.5	0.9091	$\pm 0.4166$
-0.8	0.7	0.7282	$\pm 0.4225$
-0.7	0.8	1.0274	$\pm 0.5962$
-0.5	0.4	0.6986	$\pm 0.2149$

Mit  $\mathbf{x}_0 = -0.5$  und  $\mathbf{x}_3 = +0.35$  jedoch ist das Verfahren durchführbar und man erhält die Polynomkoeffizienten

$$q_2 = +2.837\ 462\ 834, \quad q_1 = -3.470\ 763\ 132, \quad q_0 = +1.000\ 000\ 000$$

$$p_1 = -3.422\ 811\ 364, \quad p_0 = +1.500\ 000\ 000$$

und damit die Nullstellen 0.758 641 874 und 0.464 550 581 .

Es folgt damit

$$a_1 = +2.820\ 549\ 263, \quad t_1 = +0.974\ 913\ 359$$

$$a_2 = -0.898\ 915\ 427, \quad t_2 = +2.705\ 946\ 470$$

Zeichnung 5.5 stellt die Fehlerfunktion dar:

- auf Intervall  $I$
- auf Teilintervall  $[-1.0, +0.4]$ .

Die Minimalabweichung für  $f$  in  $I$  bezüglich  $V_1$  ist 0.5<sup>13</sup>: diese Näherung approximiert also schlechter als die beste Approximation bezüglich  $V_1$ .

<sup>12</sup>  $x_0/x_3$  ist der erste/letzte der äquidistanten Punkte

<sup>13</sup> die beste Approximation ist die konstante Funktion  $E(x) \equiv 1.5 \in V_1$

Weitere Ergebnisse:

- Mit  $\mathbf{x}_0 = -0.5$ ,  $\mathbf{x}_3 = +0.3$  erhält man

$a_1 = +2.138\ 865\ 180$  ,  $t_1 = -0.692\ 894\ 768$

$a_2 = -0.185\ 691\ 049$  ,  $t_2 = +5.381\ 257\ 439$

Zeichnung 5.6 stellt die Fehlerfunktion dar:

– auf Intervall I

– auf Teilintervall  $[-0.2, +0.2]$ .

Die Norm der Fehlerfunktion ist größer als 37.0 .

- Mit  $\mathbf{x}_0 = -0.5$ ,  $\mathbf{x}_3 = +0.25$  erhält man

$a_1 = +2.050\ 428\ 834$  ,  $t_1 = +0.624\ 759\ 329$

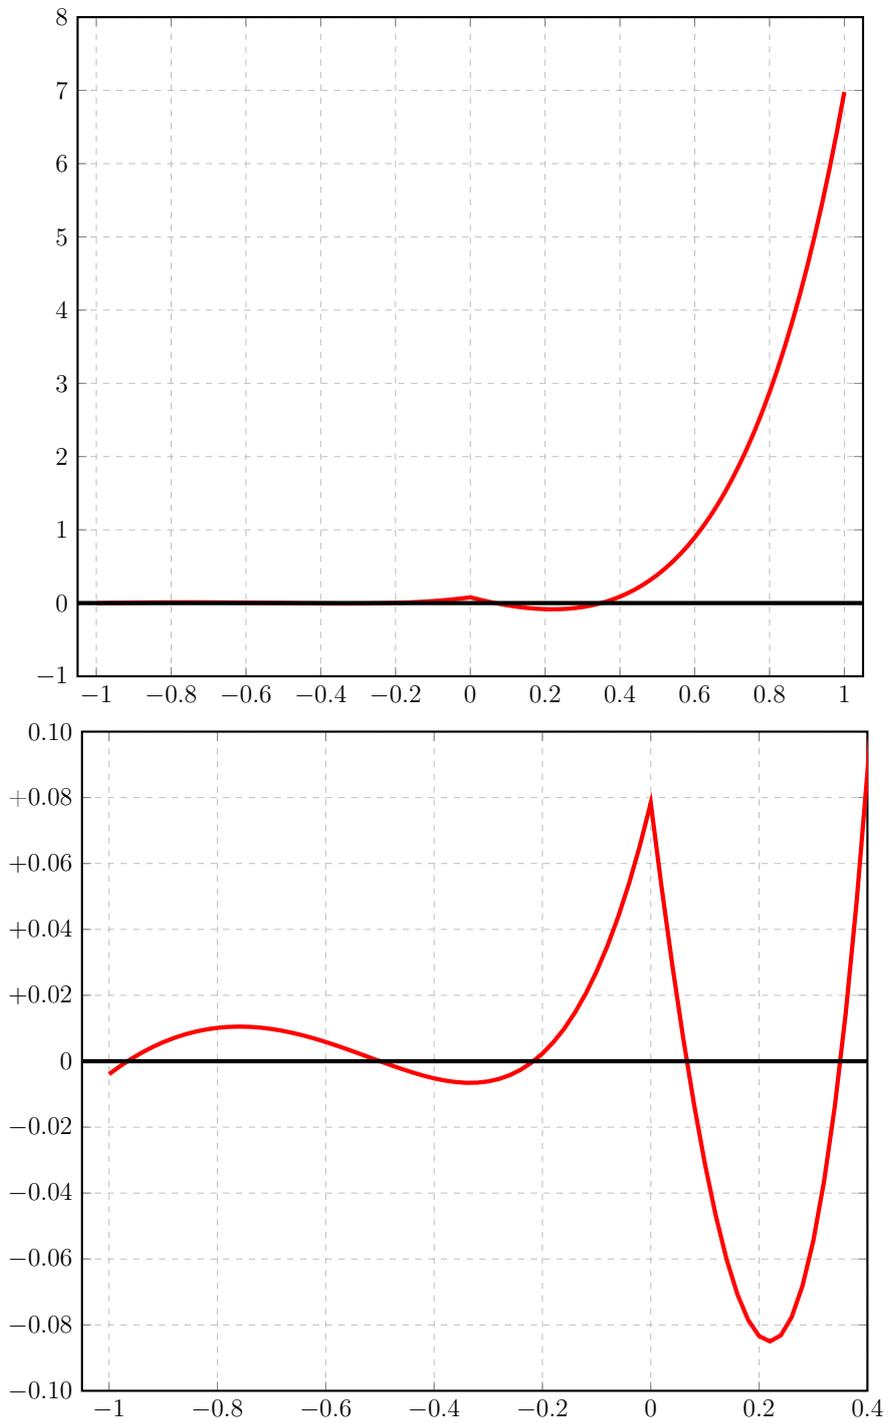
$a_2 = -0.050\ 428\ 834$  ,  $t_2 = +10.207\ 441\ 475$

Zeichnung 5.7 stellt die Fehlerfunktion dar

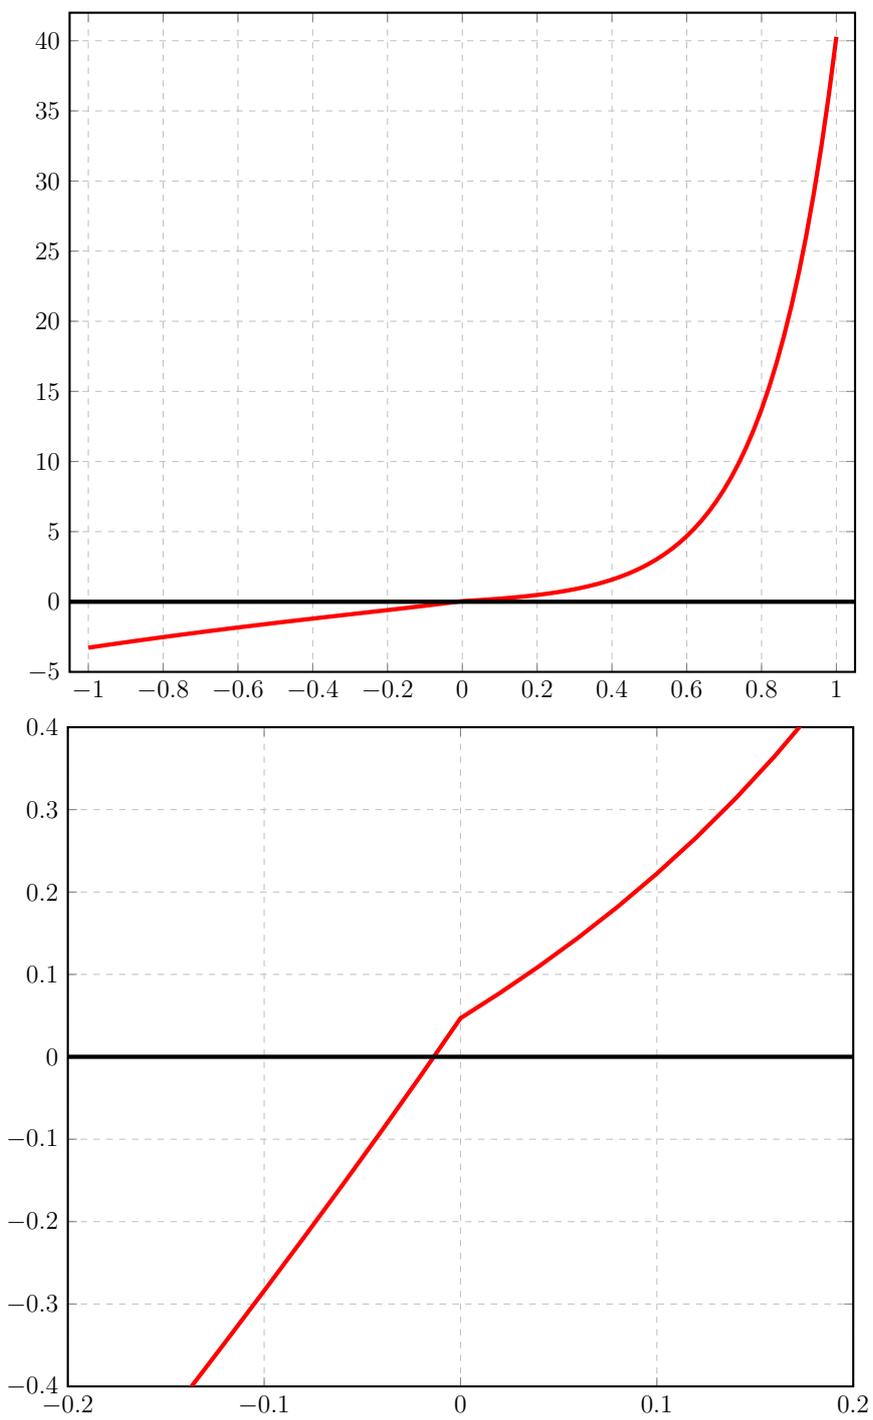
– auf Intervall I

– auf Teilintervall  $[-1.05, +0.3]$ .

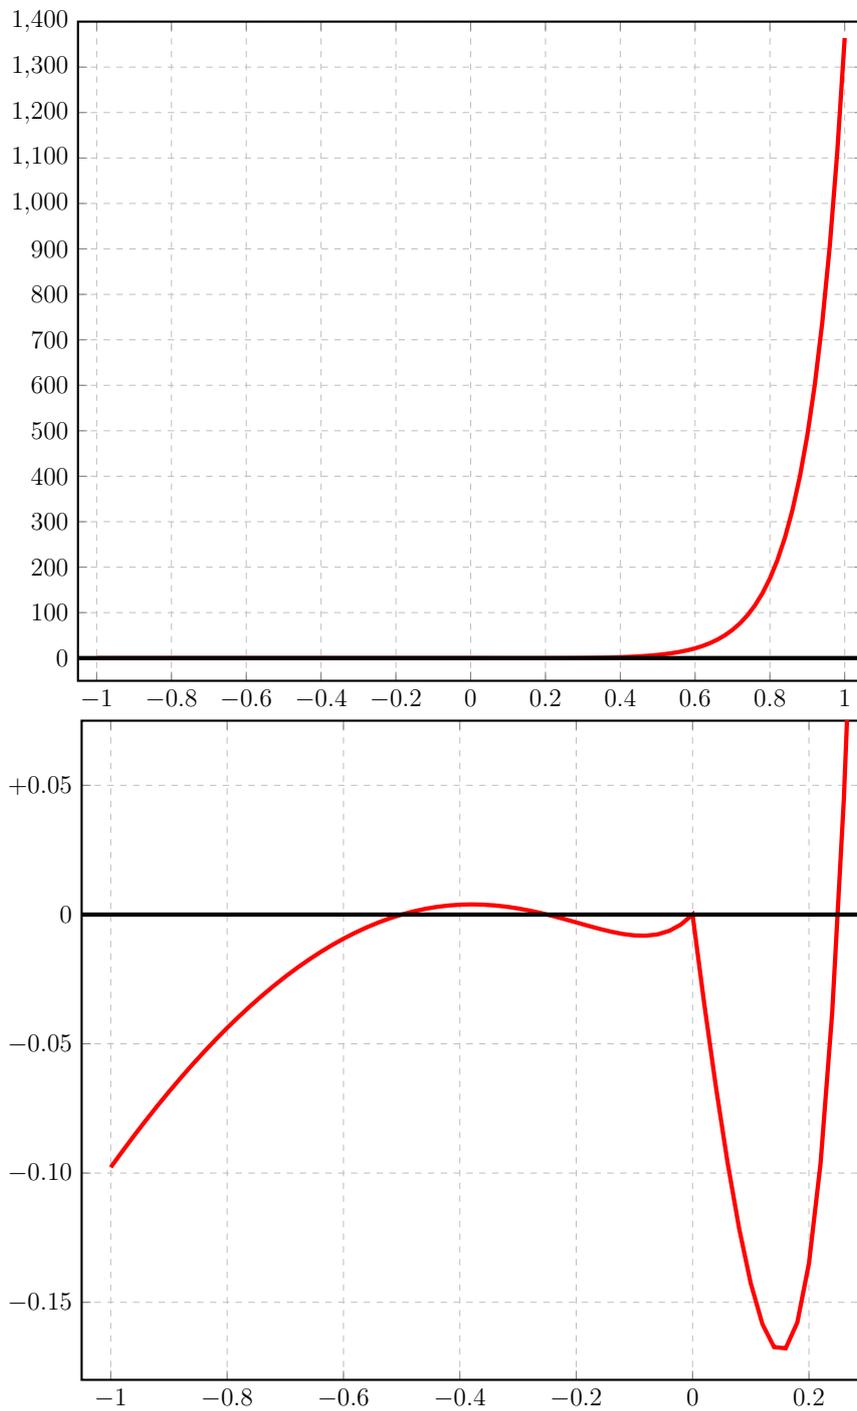
Für diese drei Fehlerfunktionen ist  $x = 1.0$  der Extrempunkt.



Zeichnung 5.5



Zeichnung 5.6



Zeichnung 5.7

Bei der Ermittlung einer **Näherung nach Rice**, Abschnitt 5.2, treten die gleichen Schwierigkeiten auf, da auch  $P$  meist komplexe Nullstellen besitzt:

		<i>Die Nullstellen von <math>P</math></i>	
$x_1$	$x_5$	<i>Realteil <math>\Re</math></i>	<i>Imaginärteile <math>\Im</math></i>
-1.0	1.0	0.8571	$\pm 0.5151$
-0.9	0.9	0.8732	$\pm 0.4873$
-0.8	0.8	0.8888	$\pm 0.4581$
-0.5	0.5	0.9333	$\pm 0.3590$

Für  $x_1 = -0.5$  und  $x_5 = -0.25$  erhält man das Polynom  $P(x) = \sum_{i=0}^2 p_i x^i$  mit

$p_2 = -0.539\ 062\ 500$  ,  $p_1 = -1.828\ 125\ 000$  ,  $p_0 = -1.398\ 437\ 500$

und den Nullstellen  $2.225\ 778\ 005$ ,  $1.165\ 526\ 343$  . Damit folgt

$a_1 = +2.314\ 520\ 833$  ,  $t_1 = +0.816\ 921\ 503$

$a_2 = -0.376\ 853\ 596$  ,  $t_2 = +4.267\ 234\ 771$

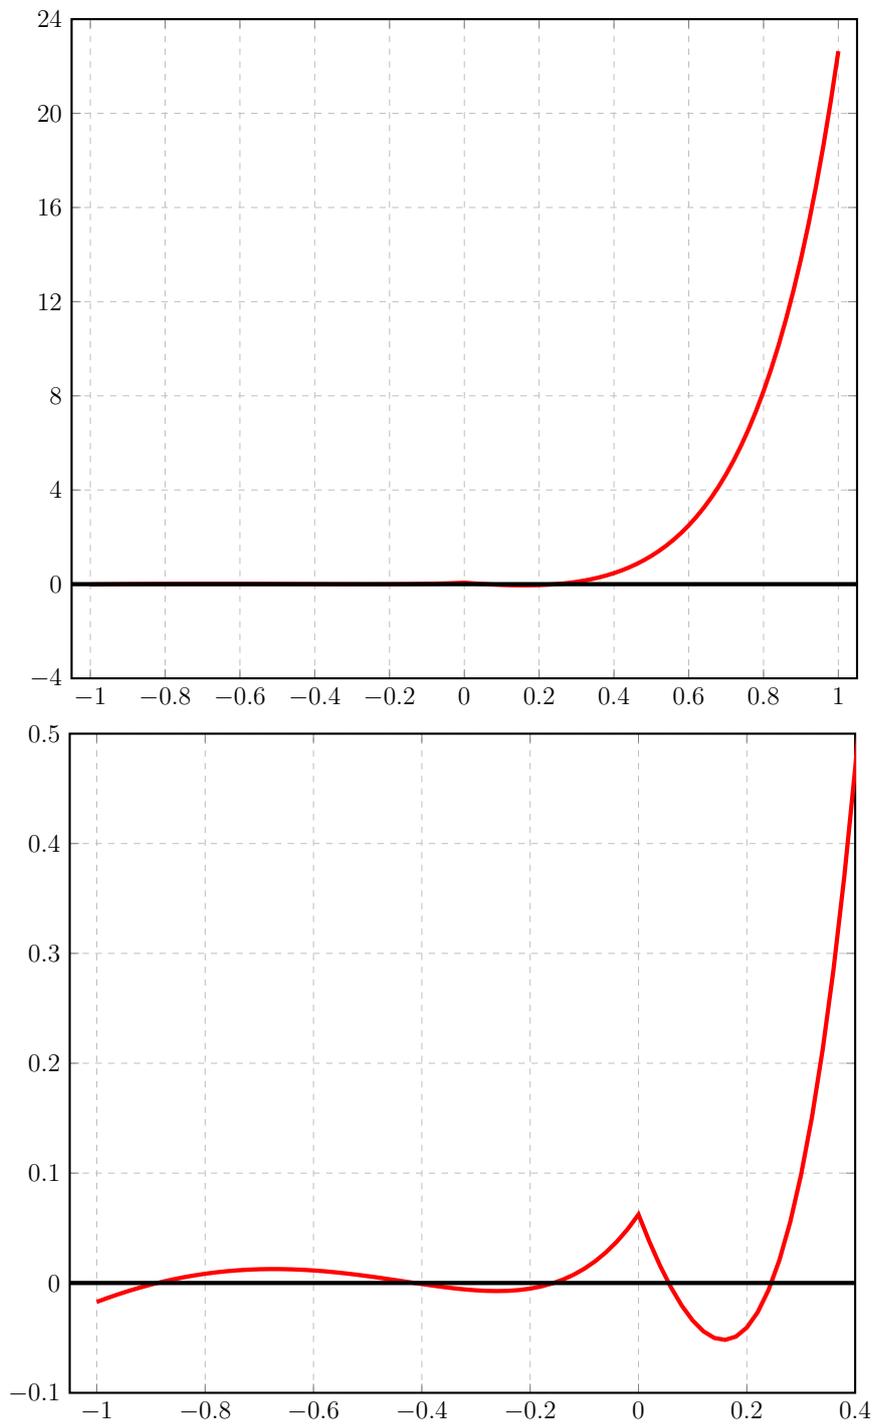
Zeichnung 5.8 stellt die Fehlerfunktion dar:

- auf Intervall I
- auf Teilintervall  $[-1.0, +0.4]$ .

Auch die Berechnung einer **Näherung nach Willers**, Abschnitt 5.3, mit verschiedenen Werten für  $m$  führt auf komplexe Nullstellen; es sei  $x_1 = -1.0$  und  $x_m = -1.0$ :

			<i>Die Nullstellen von <math>Q</math></i>	
$m$	<i>Realteil <math>\Re</math></i>	<i>Imaginärteile <math>\Im</math></i>		
10	0.9329	$\pm 0.1892$		
22	0.9740	$\pm 0.0831$		
32	0.9828	$\pm 0.0567$		

Die hier auftretenden Schwierigkeiten dürften darin begründet sein, daß es für  $f$  in  $[-1, +1]$  nach Satz 3.3 zwei Minimallösungen  $E_1, E_2$  bezüglich  $V_2$  gibt und daher keine beste Approximation bezüglich  $V_2^0$  existiert; es liegt also nahe zu vermuten, daß  $f - E_i, i = 1, 2$ , in I keine Alternante der Länge 5 besitzt, was sich besonders auf die Verfahren von Meinardus, Abschnitt 5.1, und Willers, Abschnitt 5.2, auswirkt.



Zeichnung 5.8

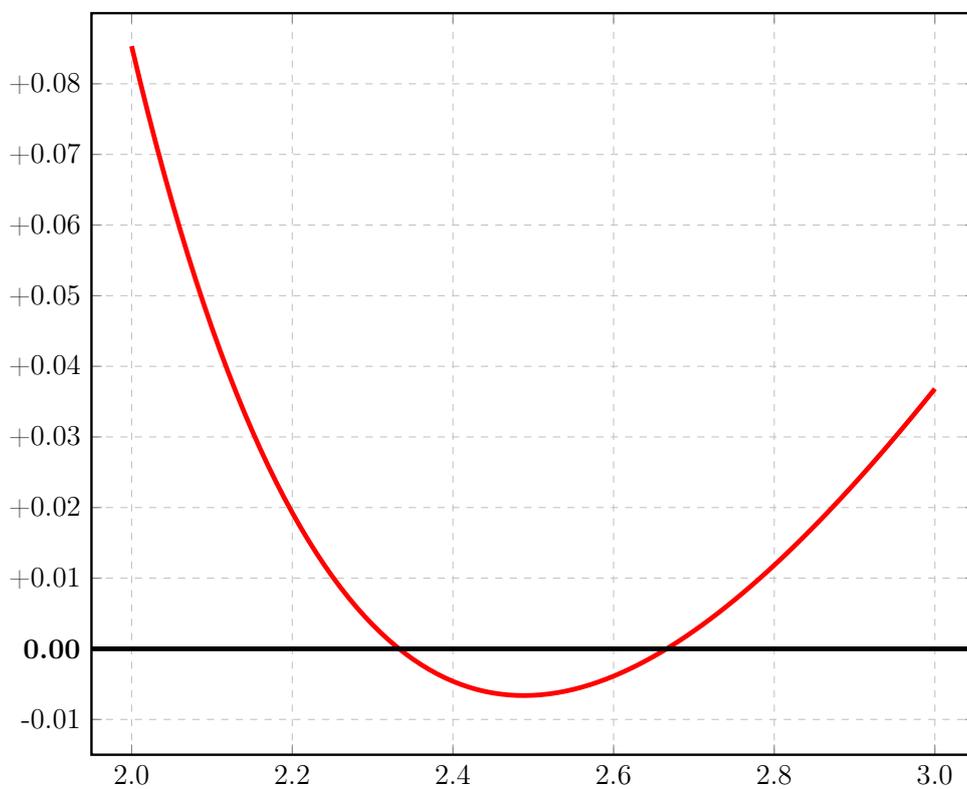
### Beispiel 5.4 Näherungen für die Riemannsche Zetafunktion <sup>14</sup>

Es werden Näherungen für die Riemannsche Zetafunktion nach dem **Verfahren von Meinardus**, Abschnitt 5.1, für  $1 \leq N \leq 4$  jeweils auf den Intervallen  $[2, 3]$ ,  $[2, 4]$  angegeben.<sup>15</sup>

Für  $I = [2, 3]$ ,  $N = 1$  erhält man mit  $x_0 = 2.333$ ,  $x_1 = 2.666$  die Parameter

$$a_1 = +2.793\ 905\ 734 \quad , \quad t_1 = -0.291\ 505\ 518$$

Zeichnung 5.9 stellt die Fehlerfunktion dar <sup>16</sup>.



Zeichnung 5.9

<sup>14</sup> Dieses Beispiel ist eine Erweiterung der Diplomarbeit [26], §5.

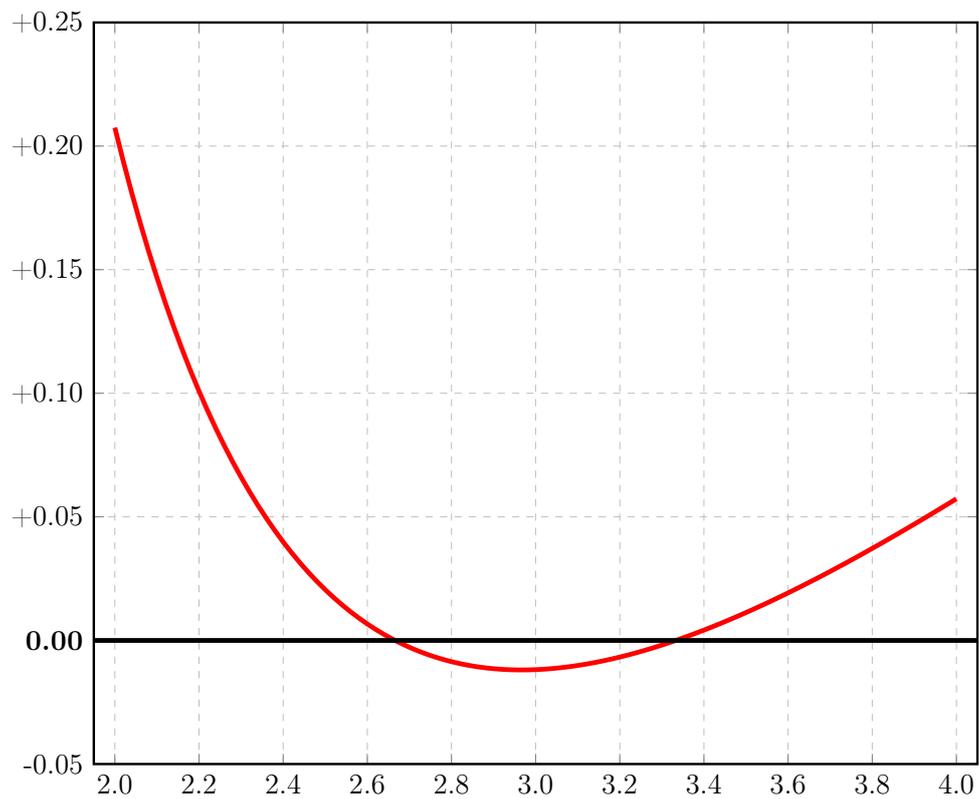
<sup>15</sup> Es sind dies die Startfunktionen für die Berechnungen von Minimallösungen für die Zetafunktion von [26], §8

<sup>16</sup> Zeichnung 48 von [26], §8

Für  $I = [2, 4]$ ,  $N = 1$  erhält man mit  $x_0 = 2.666$ ,  $x_1 = 3.333$  die Parameter

$$a_1 = +2.015\ 963\ 567, \quad t_1 = -0.169\ 096\ 199$$

Zeichnung 5.10 stellt die Fehlerfunktion dar <sup>17</sup>.



Zeichnung 5.10

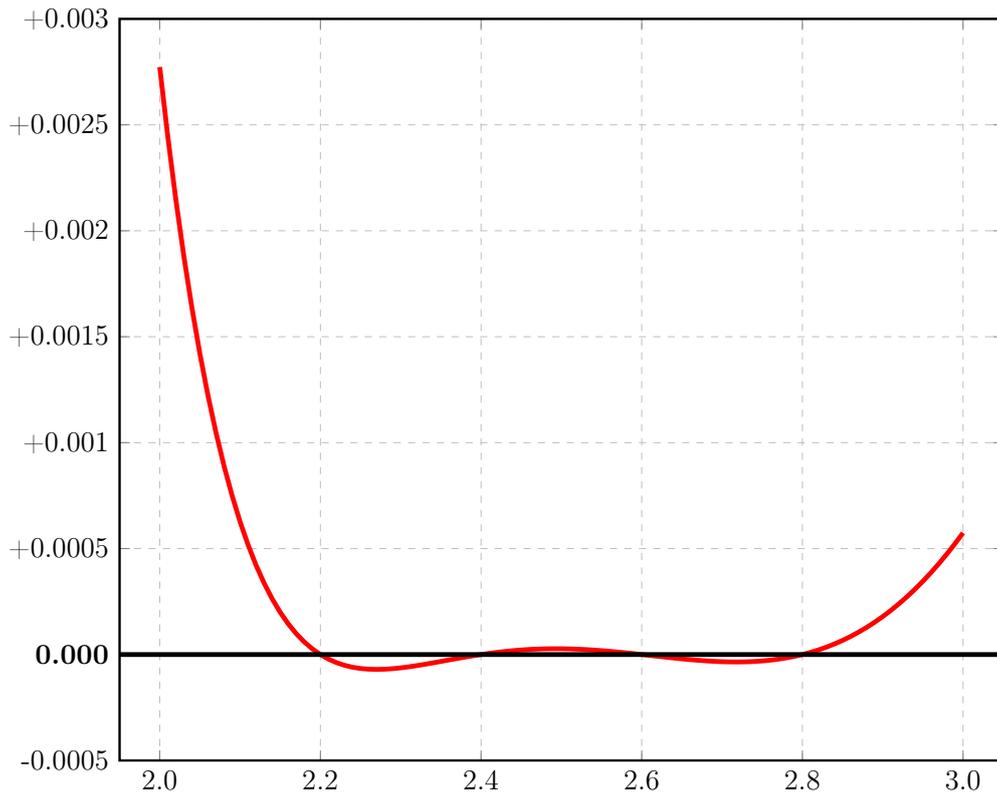
---

<sup>17</sup> Zeichnung 52 von [26], §8

Für  $I = [2, 3]$ ,  $N = 2$  erhält man mit  $\mathbf{x}_0 = 2.200$ ,  $\mathbf{x}_3 = 2.800$  die Parameter

$$\begin{aligned} a_1 &= +1.525\ 165\ 278, & t_1 &= -0.092\ 521\ 466 \\ a_2 &= +24.876\ 184\ 782, & t_2 &= -2.097\ 844\ 336 \end{aligned}$$

Zeichnung 5.11 stellt die Fehlerfunktion dar<sup>18</sup>.



Zeichnung 5.11

---

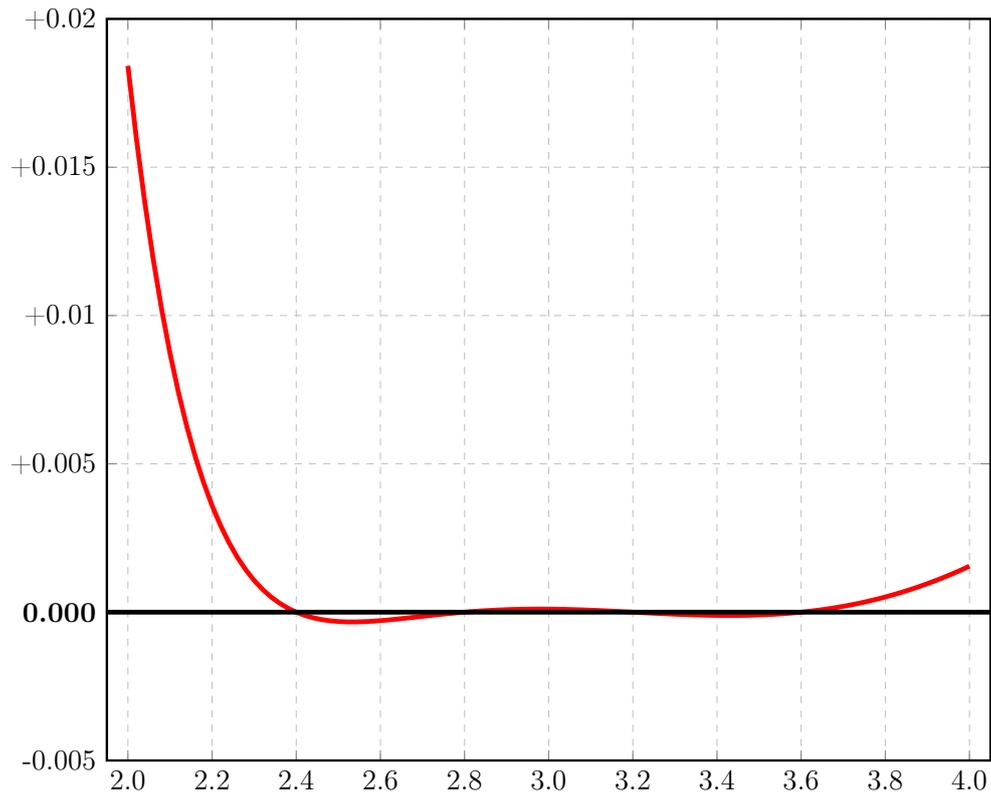
<sup>18</sup> Zeichnung 56 von [26], §8

Für  $I = [2, 4]$ ,  $N = 2$  erhält man mit  $x_0 = 2.400$ ,  $x_3 = 3.600$  die Parameter

$$a_1 = +1.262\ 562\ 853, \quad t_1 = -0.043\ 145\ 667$$

$$a_2 = +11.959\ 298\ 968, \quad t_2 = -1.620\ 042\ 255$$

Zeichnung 5.12 stellt die Fehlerfunktion dar <sup>19</sup>.



Zeichnung 5.12

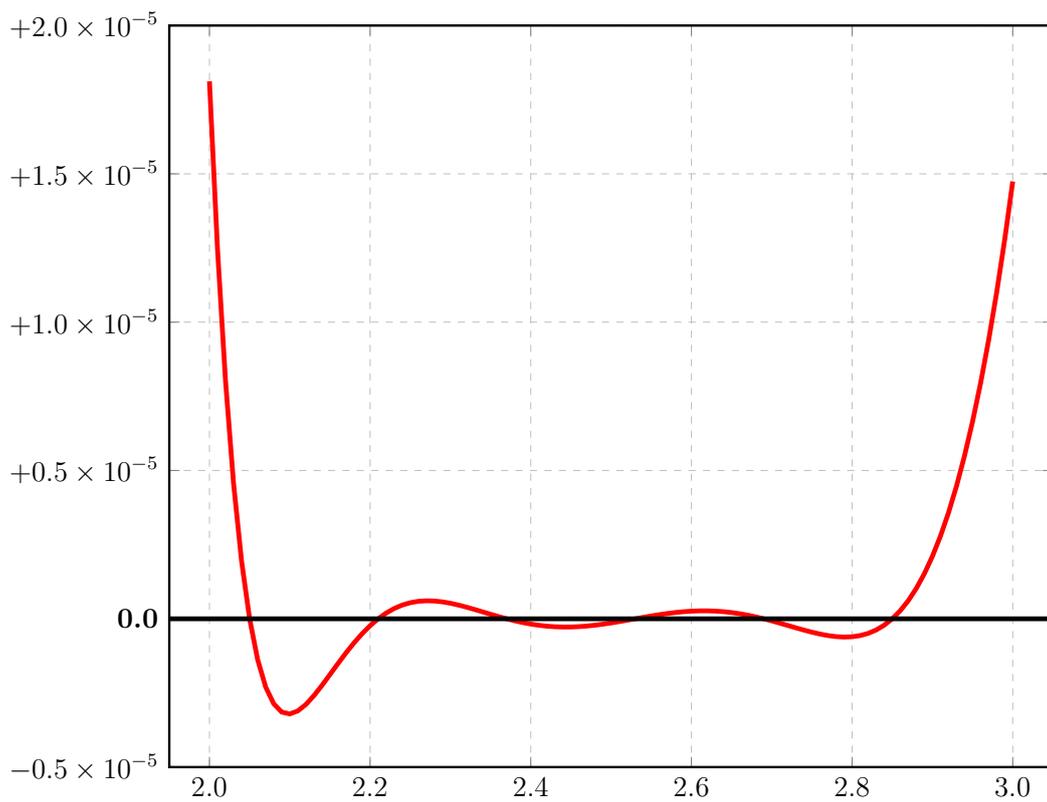
---

<sup>19</sup> Zeichnung 62 von [26], §8

Für  $I = [2, 3]$ ,  $N = 3$  erhält man mit  $\mathbf{x}_0 = 2.050$ ,  $\mathbf{x}_5 = 2.850$  die Parameter

$$\begin{aligned} a_1 &= +1.236\ 018\ 240 \quad , \quad t_1 = -0.039\ 532\ 424 \\ a_2 &= +8.421\ 439\ 207 \quad , \quad t_2 = -1.466\ 241\ 490 \\ a_3 &= +301.455\ 919\ 776 \quad , \quad t_3 = -4.310\ 972\ 926 \end{aligned}$$

Zeichnung 5.13 stellt die Fehlerfunktion dar <sup>20</sup>.



Zeichnung 5.13

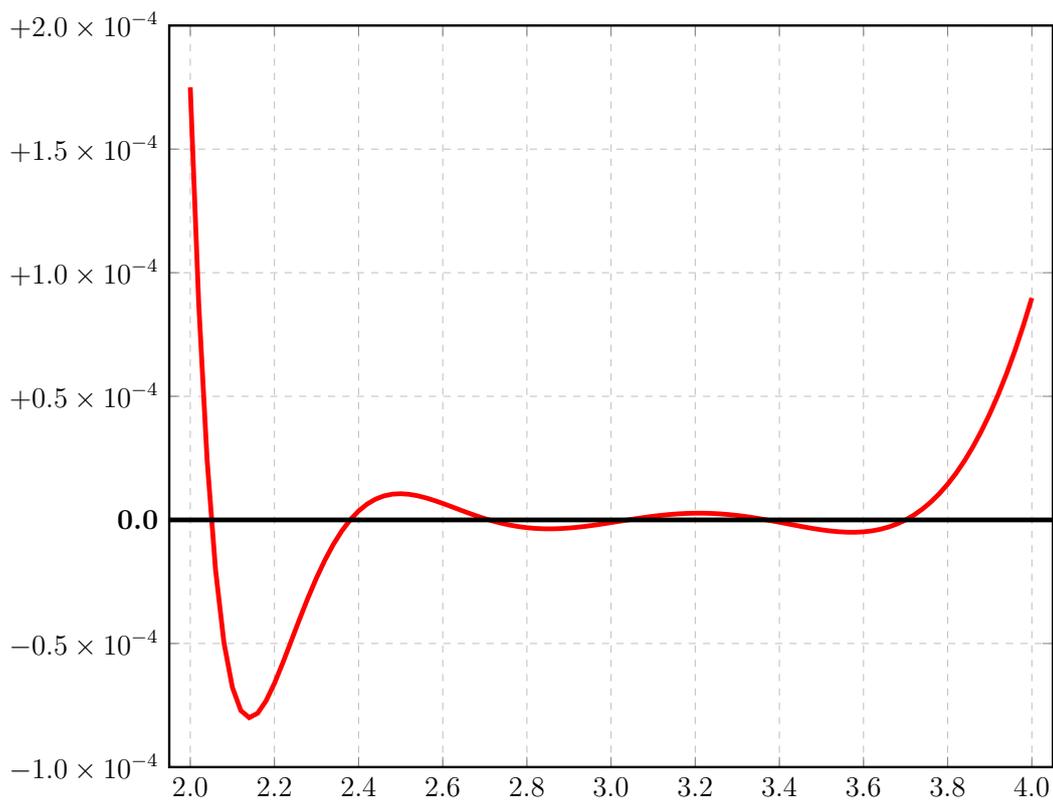
---

<sup>20</sup> Zeichnung 69 von [26], §8

Für  $I = [2, 4]$ ,  $N = 3$  erhält man mit  $x_0 = 2.050$ ,  $x_5 = 3.700$  die Parameter

$$\begin{aligned} a_1 &= +1.112\ 198\ 403 \quad , \quad t_1 = -0.017\ 032\ 105 \\ a_2 &= +5.076\ 875\ 370 \quad , \quad t_2 = -1.191\ 695\ 146 \\ a_3 &= +113.053\ 478\ 781 \quad , \quad t_3 = -3.507\ 624\ 270 \end{aligned}$$

Zeichnung 5.14 stellt die Fehlerfunktion dar <sup>21</sup>.



Zeichnung 5.14

---

<sup>21</sup> Zeichnung 75 von [26], §8

Für  $I = [2, 3]$ ,  $N = 4$  erhält man mit  $\mathbf{x}_0 = \mathbf{2.100}$ ,  $\mathbf{x}_7 = \mathbf{2.800}$  die Parameter

a1= +1.108 917 301 , t1=-0.016 846 093  
a2= +4.516 500 699 , t2=-1.151 831 800  
a3= +56.338 107 956 , t3=-3.097 712 958  
a4=+3183.222 936 114 , t4=-6.533 155 909

Zeichnung 5.15 stellt die Fehlerfunktion dar:

- auf Intervall I
- auf Teilintervall [+2.1, +2.8].

(Entsprechen Zeichnungen 82, 82A von [26], §8)

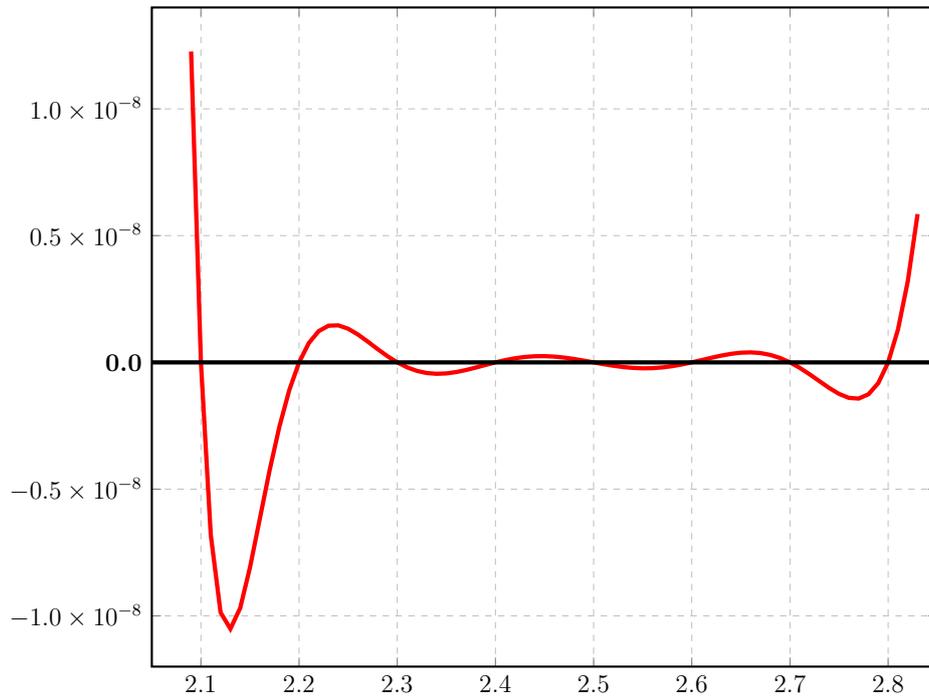
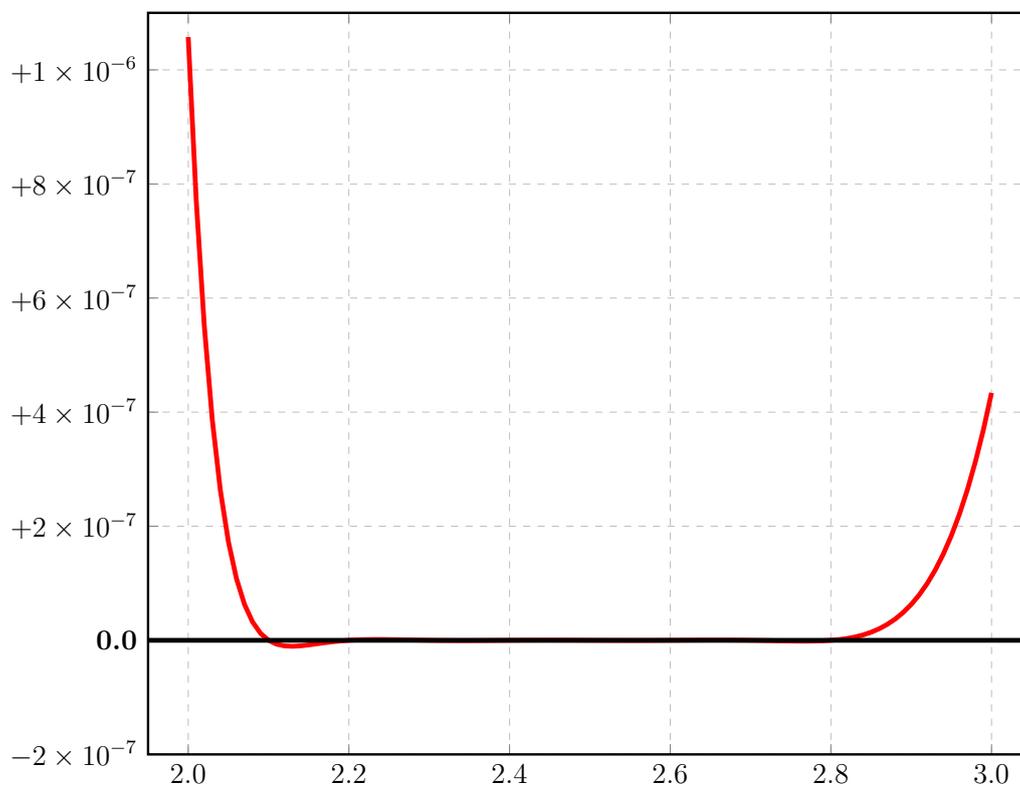
Für  $I = [2, 4]$ ,  $N = 4$  erhält man mit  $\mathbf{x}_0 = \mathbf{2.050}$ ,  $\mathbf{x}_7 = \mathbf{3.600}$  die Parameter

a1= +1.048 520 425 , t1=-0.006 758 602  
a2= +3.067 446 915 , t2=-0.980 260 258  
a3= +27.094 443 001 , t3=-2.561 189 494  
a4= +928.206 585 131 , t4=-5.450 993 513

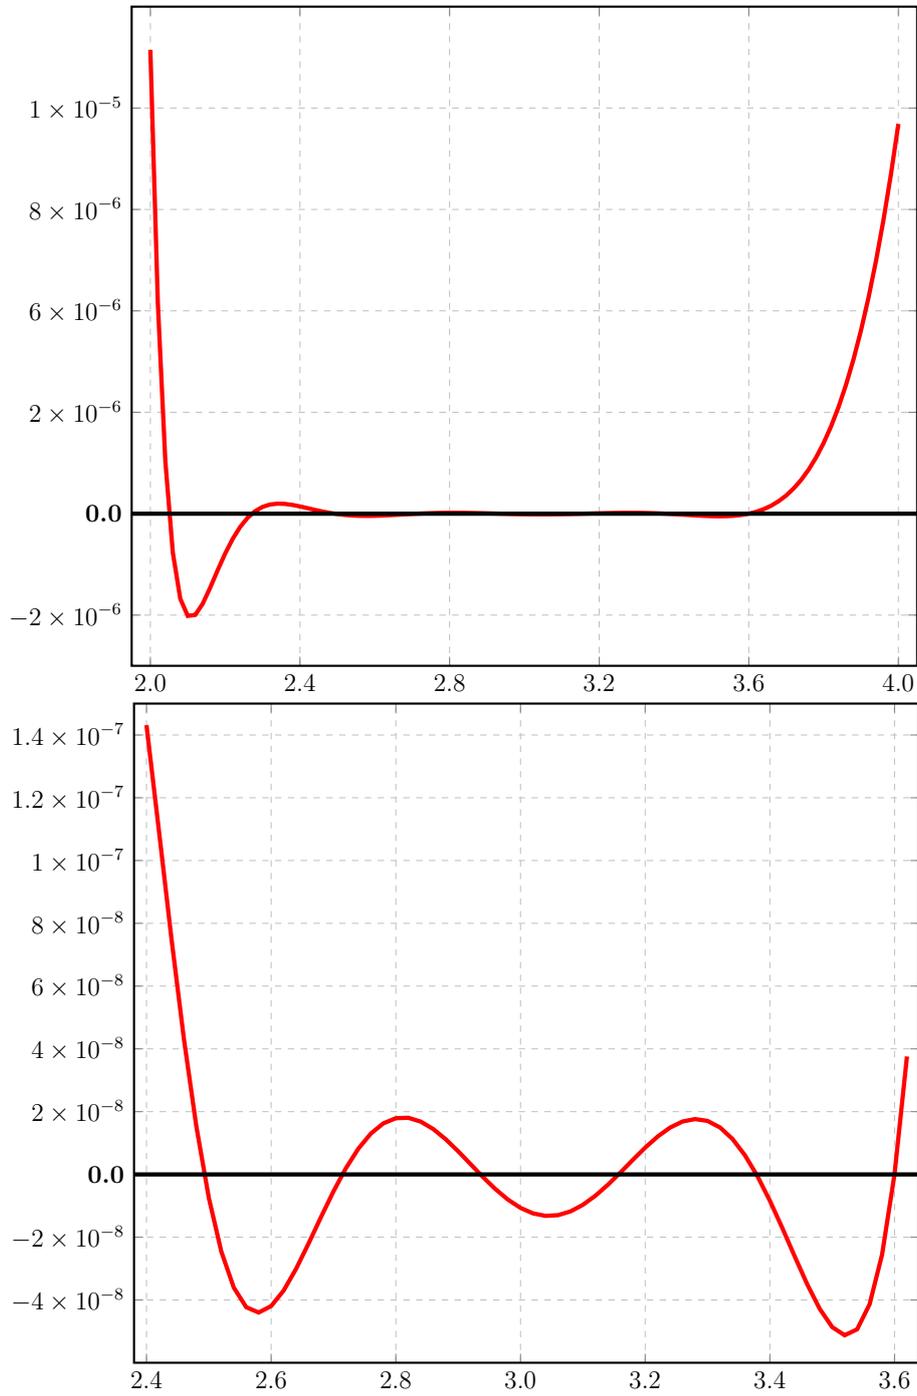
Zeichnung 5.16 stellt die Fehlerfunktion dar:

- auf Intervall I
- auf Teilintervall [+2.4, +3.6].

(Entsprechen Zeichnungen 91, 91A von [26], §8)



Zeichnung 5.15



Zeichnung 5.16

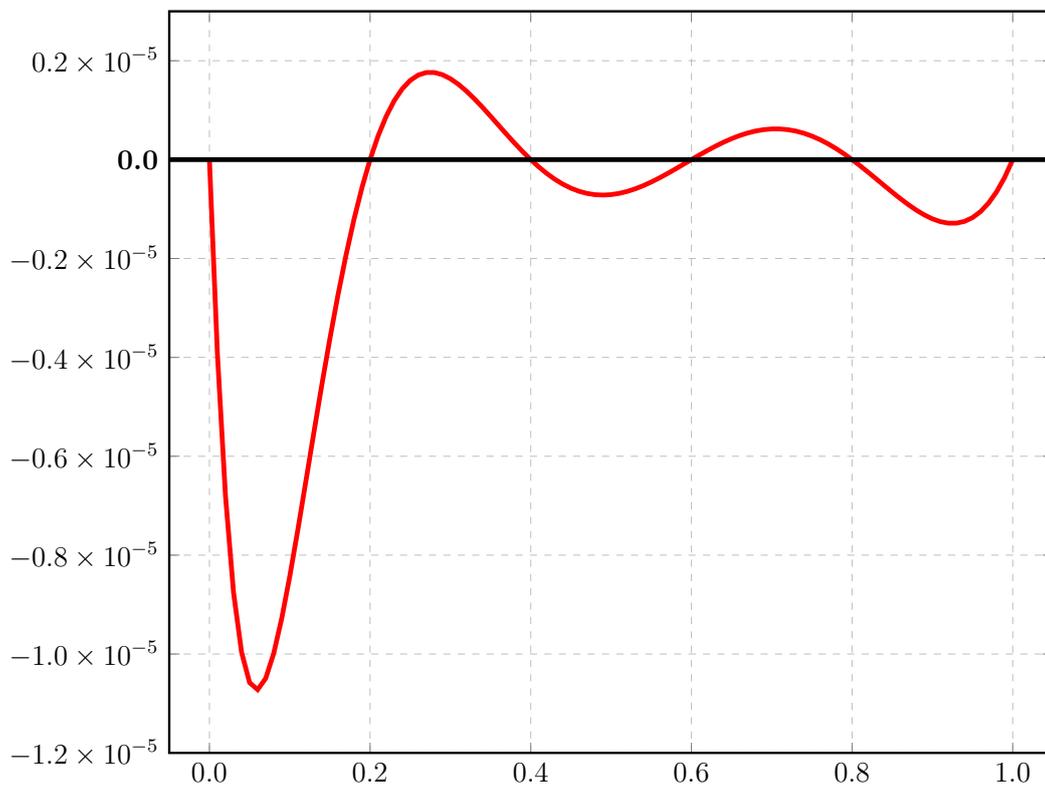
**Beispiel 5.5** Näherungen für  $f(x) = \frac{1}{1+x}$  <sup>22</sup>

Es werden zwei Näherungen für  $f(x) = \frac{1}{1+x}$  nach dem **Verfahren von Meinardus** von Abschnitt 5.1 für  $N = 3$  auf  $I = [0, 1]$  mit unterschiedlichen Werten für  $x_0, x_5$  angegeben.<sup>23</sup>

Mit  $\mathbf{x}_0 = \mathbf{0.0}$ ,  $\mathbf{x}_5 = \mathbf{1.0}$  erhält man die Parameter

$$\begin{aligned} a_1 &= +0.546\ 271\ 421, & t_1 &= -0.277\ 576\ 311 \\ a_2 &= +0.401\ 383\ 367, & t_2 &= -1.546\ 985\ 019 \\ a_3 &= +0.052\ 345\ 210, & t_3 &= -4.336\ 157\ 075 \end{aligned}$$

Zeichnung 5.17 stellt die Fehlerfunktion dar <sup>24</sup>.



**Zeichnung 5.17**

<sup>22</sup> Dieses Beispiel ist eine Erweiterung der Diplomarbeit [26], §5.

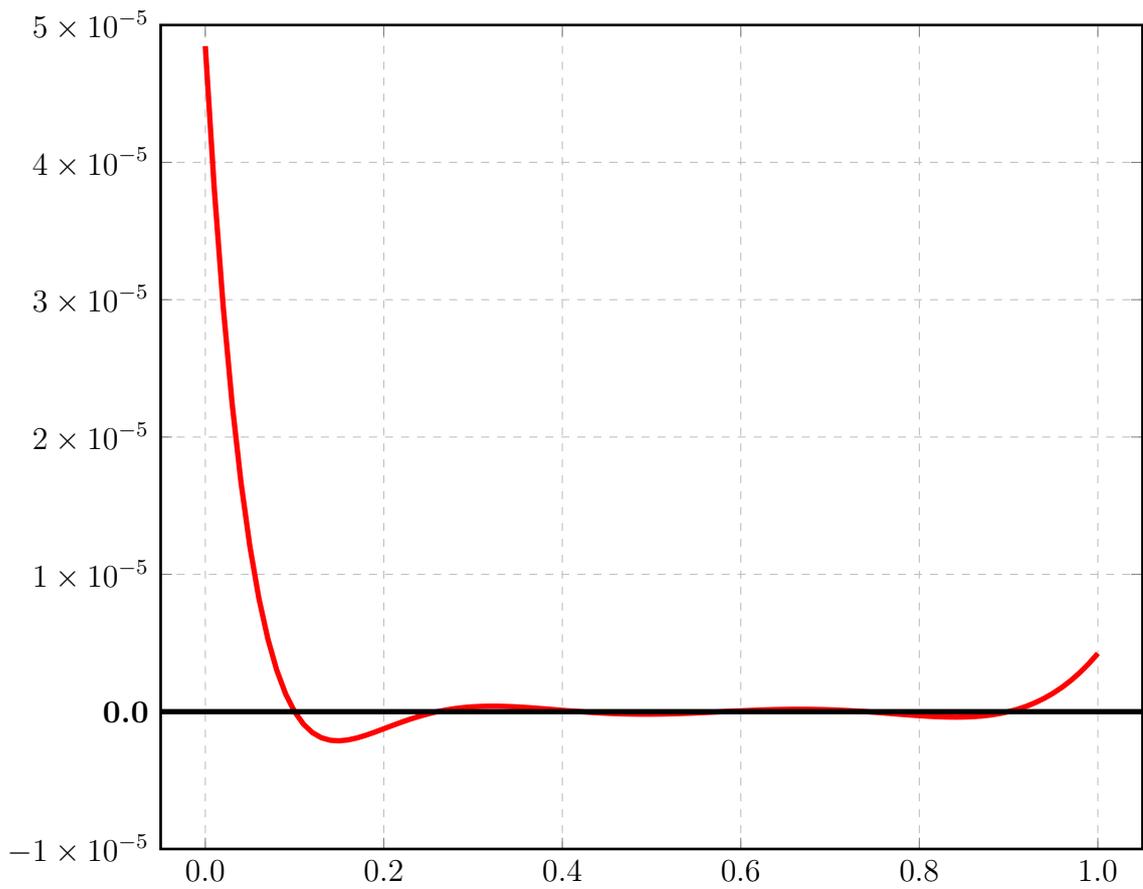
<sup>23</sup> Es sind dies die Startfunktionen für die Berechnungen von Minimallösungen in [26], §7

<sup>24</sup> Zeichnung 27 von [26], §7

Mit  $\mathbf{x}_0 = 0.1$ ,  $\mathbf{x}_5 = 0.9$  erhält man die Parameter

$$\begin{aligned} a_1 &= +0.545\ 644\ 214, & t_1 &= -0.277\ 434\ 496 \\ a_2 &= +0.400\ 482\ 842, & t_2 &= -1.540\ 603\ 343 \\ a_3 &= +0.053\ 824\ 480, & t_3 &= -4.282\ 493\ 872 \end{aligned}$$

Zeichnung 5.18 stellt die Fehlerfunktion dar <sup>25</sup>.



Zeichnung 5.18

---

<sup>25</sup> Zeichnung 36 von [26], §7

## 6 Iterationsverfahren

### 6.1 Konstruktion von Minimallösungen nach Braess

Es sei  $I \subseteq \mathbb{R}$  ein kompaktes Intervall,  $N \in \mathbb{N}$ ,  $f \in C(I)$ .

In [3] behandelt Braess einen Algorithmus, der, von einer Minimallösung  $E$  bezüglich  $V_{N-1}^0$  ausgehend, eine Folge besserer Approximationen  $((E(a_n))_{n \in \mathbb{N}})$  liefert, falls  $E$  nicht die beste Approximation bezüglich  $V_N$  ist; zur Konstruktion einer Minimallösung bezüglich  $V_N$  wird mit diesem Algorithmus sukzessive die Minimallösung bezüglich  $V_1^0, V_2^0, \dots$  ermittelt.

#### Vereinbarung:

In diesem Abschnitt wird die Parametrisierung von  $V_N^0$  nach Definition 1.2 benutzt und es ist zweckmäßig, die folgende Schreibweise einzuführen:

Für  $u = \begin{pmatrix} u_1 \\ \vdots \\ u_m \end{pmatrix} \in \mathbb{R}^m$  und  $v = \begin{pmatrix} v_1 \\ \vdots \\ v_n \end{pmatrix} \in \mathbb{R}^n$  mit  $m \geq n$  sei  $u + v$  gegeben

durch

$$u + v := \begin{pmatrix} u_1 + v_1 \\ \vdots \\ u_n + v_n \\ \vdots \\ u_{m-1} \\ u_m \end{pmatrix} \in \mathbb{R}^m$$

#### 6.1.1 Der Algorithmus

Mit  $n \in \mathbb{N}$  sei  $E(a_n) \in V_N^0$  nicht Minimallösung für  $f$  bezüglich  $V_N$ .

Es sei

- $d_n$  die Dimension des Gradientenraumes<sup>26</sup>  $W_n$  von  $E(a_n)$
- $F_n := f - E(a_n)$ .

Ferner seien  $J \in \mathbb{N}$  mit  $J \geq 2N+1$  und  $z \in (0, \frac{1}{2})$  fest vorgegeben.

---

<sup>26</sup> s. Definition 3.1 a,b

**Schritt 1:** Bestimmung einer Teilmenge  $X$  von  $I$

Man untersuche, ob (6.1) erfüllt ist:

(6.1) Die Menge  $\{x \in I \mid (1-z) \|F_n\|_I \leq |F_n(x)|\}$  besteht aus  $j$  Teilintervallen mit  $j \leq J$  und in jedem Teilintervall ist das Maximum von  $|F_n|$  eindeutig bestimmt.

Die Maximalpunkte von  $|F_n|$  in diesen Teilintervallen seien die Punkte  $x_k$ ,  $1 \leq k \leq j$ .

**Fall 1:** Es ist (6.1) erfüllt.

Die Menge der Maximalpunkte sei  $X_1 := \{x_k \mid 1 \leq k \leq j\}$ .

Weiter zerlege man  $I$  in *Vorzeichenintervalle*:

Dies sind Teilintervalle von  $I$ , in denen  $F_n$  das Vorzeichen nicht wechselt, im Innern benachbarter Teilintervalle jedoch verschiedenes Vorzeichen besitzt. Abweichend von Definition 1.7 gelte hier zur Bestimmung der Vorzeichenintervalle  $\text{sign}(0) = +1$ .

In jedem dieser Vorzeichenintervalle wird ein Punkt - günstig ist eine lokales Extremum von  $F_n$  - ausgezeichnet, die somit gegebene Punktmenge sei  $X_2$ .  $X_3$  sei eine beliebige Teilmenge von  $I$  mit  $|X_3| = d_n + 1$ .

Man bestimme nun Teilmengen  $\overline{X_2}$  und  $\overline{X_3}$  mit  $\overline{X_2} \subseteq X_2$  und  $\overline{X_3} \subseteq X_3$  so, daß für

$$\mathbf{X} := \mathbf{X}_1 \cup \overline{\mathbf{X}_2} \cup \overline{\mathbf{X}_3}$$

gilt:

$$d_n + 1 \leq |X| \leq J$$

**Fall 2:** Es ist (6.1) nicht erfüllt.

Hier wird definiert:  $\mathbf{X} := \mathbf{I}$

**Schritt 2:**

Man bestimme die *beste Approximation*  $e_n$  an  $F_n = f - E(a_n)$  auf  $X$  bezüglich

$W_n$ , d.h.: für  $E(a_n, x) = \sum_{i=1}^N a_{i,n} e^{t_{i,n} x}$  ist gesucht

$$r_n = (r_{1,n}, \dots, r_{d_n,n}) \in \mathbb{R}^{d_n}$$

mit

- $e_n(x) = \sum_{i=1}^N r_{i,n} e^{t_{i,n} x} + \sum_{i=N+1}^{d_n} r_{i,n} a_{i-N,n} x e^{t_{i-N,n} x}$  und

- $\|F_n - e_n\|_I \leq \|F_n - e\|_I$  für  $e \in W_n$

Mit den Bezeichnungen von Definition 3.1 gilt für  $d_n = 2N$ :

$$e_n = (r_n, \text{grad}(E(a_n)))$$

Die *Verbesserung* für  $E(a_n)$  sei  $\epsilon_n := \|F_n\|_I - \|F_n - e_n\|_X$ .

**Schritt 3:**

Man setze  $c := 1$  und bestimme durch fortlaufendes Halbieren von  $c$  ein  $c_n \in (0, 1]$  so, daß gilt:

$$\|f - E(a_n + c_n r_n)\|_I \leq \|f - E(a_n)\|_I - \frac{1}{3} c_n \epsilon_n$$

Liegt Fall 1 vor und gilt  $c_n < z$ , dann werden Schritt 2 und Schritt 3 mit  $X = I$  durchgeführt.

Der Parametervektor  $a_{n+1}$  und damit  $E(a_{n+1})$  ist gegeben durch

$$a_{n+1} := a_n + c_n r_n$$

**Bemerkungen:**

1. Die Durchführung von Schritt 2 erfordert die Lösung eines linearen Approximationsproblems;  $e_n$  existiert damit und ist stets eindeutig bestimmt, da  $W_n$  die Haarsche Bedingung erfüllt.
2. Wie die folgenden Untersuchungen zeigen, wird die Fallunterscheidung nach Schritt 1 durchgeführt, um durch Lösung eines diskreten, linearen Approximationsproblems den Rechenaufwand möglichst gering zu halten. Speziell für  $d_{n+1} = J$  ist hier ein lineares Gleichungssystem zu lösen.
3. Obwohl  $X$  von  $F_n$  abhängt, wird dies bei der Bezeichnung nicht berücksichtigt, da diese Tatsache für die weiteren Ausführungen nicht benötigt wird.

### 6.1.2 Zur Theorie des Verfahrens

Es ist nun die Frage zu beantworten, unter welchen Voraussetzungen der Algorithmus durchführbar ist und damit bessere Approximationen liefert; hierzu der folgende Hilfssatz:

#### Hilfsatz 6.1

Ist  $E(a_n)$  nicht beste Approximation an  $f$  auf  $I$ , dann gilt

$$\epsilon_{n1} \geq \epsilon_{n2} > 0 ,$$

wobei  $\epsilon_{n1}$  ( $\epsilon_{n2}$ ) die nach Fall 1 (Fall 2) ermittelte Verbesserung für  $E(a_n)$  ist.

#### Beweis:

Es sei  $X \subseteq I$  eine nach Fall 1 ermittelte Punktmenge. Mit  $e_{n1}$  sei die beste Approximation an  $F_n$  auf  $X$  und mit  $e_{n2}$  die beste Approximation an  $F_n$  auf  $I$  jeweils bezüglich  $W_n$  bezeichnet.

Es folgt  $\|F_n - e_{n2}\|_I \geq \|F_n - e_{n2}\|_X \geq \|F_n - e_{n1}\|_X$  und damit  $\epsilon_{n1} \geq \epsilon_{n2}$ .

Nach Voraussetzung besitzt  $F_n$  in  $I$  keine Alternante der Länge  $d_n + 1$  und die beste Approximation  $e_{n2}$  an  $F_n$  bezüglich  $W_n$  auf  $I$  approximiert daher besser als die Nullfunktion:

$$\|F_n - e_{n2}\|_I < \|F_n\|_I$$

Dies ergibt  $\epsilon_{n2} > 0$ , womit der Rest der Behauptung gezeigt ist.

#### Satz 6.1 (Braess, [3])

Ist  $E(a_n) \in V_N^0$  nicht Minimallösung für  $f$  auf  $I$  bezüglich  $V_N^0$ , dann gibt es ein  $C > 0$ , so daß für  $c \in (0, C)$  erfüllt ist:

$$\|f - E(a_n + cr_n)\|_I \leq \|f - E(a_n)\|_I - \frac{1}{3}c\epsilon_n$$

#### Beweis:

Nach Voraussetzung besitzt  $F_n$  in  $I$  keine Alternante der Länge  $d_n + 1$  und nach Hilfssatz 6.1 gilt (für beide Fälle)  $\epsilon_n > 0$ .

Es sei  $a_n(c) := a_n + cr_n$  und  $F(c, x) = f(x) - E(a_n(c), x)$ ,  $c \in \mathbb{R}$ .

Wegen  $\|E(a_n(c)) - E(a_n) - ce_n\|_I = o(|c|)$  (man vergleiche hierzu Kapitel 4) gibt es ein  $C > 0$ , mit

$$(6.2) \quad \|E(a_n(c)) - E(a_n) - ce_n\|_I \leq \frac{2}{3}c\epsilon_n \text{ für } c \in (0, C) .$$

Weiter gilt

$$\| E(a_n(c)) - f \|_I \leq \| E(a_n) + ce_n - f \|_I + \| E(a_n(c)) - E(a_n) - ce_n \|_I .$$

Für die Berechnung nach Fall 2 folgt aus (6.2) für  $c \in (0, C)$ :

$$\begin{aligned} \| f - E(a_n(c)) \|_I &\leq \| E(a_n) + ce_n - f \|_I + \frac{2}{3}c\epsilon_n = \\ &= \| cE(a_n) + ce_n - cf + (1-c)(E(a_n) - f) \|_I + \frac{2}{3}c\epsilon_n \leq \\ &\leq c \| F_n - e_n \|_I + (1-c) \| F_n \|_I + \frac{2}{3}c\epsilon_n = \\ &= -c\epsilon_n + \| F_n \|_I + \frac{2}{3}c\epsilon_n \leq \| F_n \|_I - \frac{1}{3}c\epsilon_n \end{aligned}$$

Damit ist die Behauptung für die Durchführung des Algorithmus nach *Fall 2* gezeigt.

Zu *Fall 1*: Hier gilt also  $|X| \leq J$ .

Es sei

$$\begin{aligned} X^+ &:= \{x \in X \mid F_n(x) = \| F_n \|_I\} \\ X^- &:= \{x \in X \mid F_n(x) = - \| F_n \|_I\} \end{aligned}$$

Für  $x \in X^+$  erhält man  $0 < \epsilon_n \leq \| F_n \|_I - (F_n(x) - e_n(x)) = e_n(x)$  und entsprechend für  $x \in X^-$   $0 > -\epsilon_n \geq - \| F_n \|_I - (F_n(x) - e_n(x)) = e_n(x)$ .

Es gibt somit eine offene Umgebung  $U$  von  $X^+ \cup X^-$  in  $I$ , so daß  $|e_n(x)| \leq \frac{2}{3}\epsilon_n > 0$  für  $x \in U$  erfüllt ist.

Da  $F(c, x)$  in  $c$  und  $x$  stetig ist, gibt es eine offene Umgebung  $U^+$  von  $X^+$  und  $U^-$  von  $X^-$  in  $I$  und ein  $C_1 > 0$ , so daß für  $c \in (0, C_1)$  gilt:  $F(c, x) > 0$  für  $x \in U^+$  und  $F(c, x) < 0$  für  $x \in U^-$ .

Ferner gibt es ein  $C_2 > 0$  mit  $|E(a_n(c), x) - E(a_n, x) - ce_n(x)| \leq \frac{1}{3}c\epsilon_n$  für  $c \in (0, C_2)$  und  $x \in I$ . Damit folgt für  $x \in U \cap U^+$  und  $c \in (0, \min\{C_1, C_2\})$

$$\begin{aligned} F(c, x) - F_n(x) &= E(a_n, x) - E(a_n(c), x) \leq \\ &\leq -ce_n(x) + \frac{1}{3}c\epsilon_n \leq -\frac{2}{3}c\epsilon_n + \frac{1}{3}c\epsilon_n = -\frac{1}{3}c\epsilon_n , \end{aligned}$$

also

$$0 < f(x) - E(a_n(c), x) \leq \| F_n \|_I - \frac{1}{3}c\epsilon_n .$$

Für  $x \in U \cap U^-$  erhält man analog für  $c \in (0, \min\{C_1, C_2\})$

$$\begin{aligned} -F(c, x) + F_n(x) &= E(a_n(c), x) - E(a_n, x) \leq \\ &\leq ce_n(x) + \frac{1}{3}c\epsilon_n \leq -\frac{2}{3}c\epsilon_n + \frac{1}{3}c\epsilon_n = -\frac{1}{3}c\epsilon_n, \end{aligned}$$

also

$$-F(c, x) = |f(x) - E(a_n(c), x)| \leq \|F_n\|_I - \frac{1}{3}c\epsilon_n.$$

Die Menge  $V = (U^+ \cap U) \cup (U^- \cap U)$  ist offen in  $I$ ;  $I_0 = I \setminus V$  ist kompakt und es gilt für  $c_0 = 0$ :

$$\|F(c_0)\|_{I_0} - \|F_n\|_I + \frac{1}{3}c_0\epsilon_n = \|F_n\|_{I_0} - \|F_n\|_I < 0.$$

Dies gilt wegen Stetigkeit für eine Umgebung von  $c_0$ :

Es gibt ein  $C_0 > 0$  mit  $\|F(c)\|_{I_0} \leq \|F_n\|_I - \frac{1}{3}c\epsilon_n$  für  $c \in (0, C_0)$ . Mit  $0 < C := \min\{C_0, C_1, C_2, \}$  hat man somit für  $c \in (0, C)$  erhalten:

$$|f(x) - E(a_n(c), x)| \leq \|F_n\|_I - \frac{1}{3}c\epsilon_n \quad x \in I.$$

Damit ist auch für Fall 1 die Behauptung bewiesen,

Nach Satz 6.1 ergibt also der Algorithmus eine bessere Approximation als  $E(a_n)$ , falls dies möglich ist.

**Hilfsatz 6.2** (Braess, [3])

$(E(a_n))_{n \in \mathbb{N}} \subseteq V_N^0$  konvergiere auf  $I$  gleichmäßig gegen  $E(a_0) \in V_N^0 \setminus V_{N-1}$ . Es sei  $e_n$  bzw.  $e$  die nach Schritt 2 berechnete beste Approximation an  $F_n$  bzw.  $F := f - E(a_0)$  bezüglich  $W_n$  bzw.  $W$  auf  $X = I$ ; ( $W$  ist der Gradientenraum von  $E(a_0)$ ); es liege also stets Fall 2 vor.

**Behauptung:**  $(e_n)_{n \in \mathbb{N}}$  konvergiert auf  $I$  gleichmäßig gegen  $e$ .

Beweis:

Es kann o.B.d.A. angenommen werden:

$$\|E(a_n)\|_I \leq K < \infty \text{ und } E(a_n, x) = \sum_{i=1}^N a_{i,n} e^{t_{i,n}x} \in V_N^0 \setminus V_{N-1} \text{ für } n \in \mathbb{N}$$

Nach Korollar 2.3 sind die Frequenzen der Folge beschränkt; nach Satz 2.5

gibt es eine Teilfolge  $(E(a_n))_{n \in J}$ ,  $J \subseteq \mathbb{N}$  mit

$$(6.3) \quad \lim_{n \rightarrow \infty} t_{i,n} = t_i \in \mathbb{R} \quad n \in J$$

und

$$E(a_0, x) = \sum_{i=1}^N a_{0,i} e^{t_{i,n} x}$$

Weiter gilt für  $n \in \mathbb{N}$

$$e_{in}(x) = \sum_{i=1}^N (b_{i,n} + d_{i,n} x) e^{t_{i,n} x} \in V_{2N}$$

und  $(e_n)_{n \in \mathbb{N}}$  ist auf  $I = [u, v]$  gleichmäßig beschränkt:

$$\|e_n\|_I \leq \|e_n - F_n\|_I + \|F_n\|_I \leq 2 \|F_n\|_I \leq 2(K + \|f\|_I)$$

Nach Satz 2.3 und Satz 2.5 gibt es daher eine im Innern von  $I$  gleichmäßig konvergente Teilfolge  $(c_n)_{n \in J_1}$ ,  $J_1 \subseteq J$ , und auf jedem abgeschlossenen Teilintervall von  $(u, v)$  gilt

$$\lim_{n \rightarrow \infty} c_n = e_0, \quad n \in J_1$$

mit  $e_0 \in V_{2N}$ ; wegen (6.4) folgt nach Satz 2.9 und Bemerkung 2.2 die gleichmäßige Konvergenz von  $(e_n)_{n \in J_1}$  gegen  $e_0$  auf ganz  $I$ .

Aus  $\|F_n - e_n\|_I \leq \|F_n - e\|_I$  für  $n \in \mathbb{N}$  folgt

$$\|F - e_0\|_I = \lim_{n \rightarrow \infty} \|F_n - e_n\|_I \leq \lim_{n \rightarrow \infty} \|F_n - e\|_I = \|F - e\|_I, \quad n \in J_1$$

Die Eindeutigkeit der Minimallösung bei linearer Approximation und  $e_0 \in W$ ,  $e \in W$  ergeben:  $e_0 = e$ .

Es ist noch zu zeigen, daß die ganze Folge  $(e_n)_{n \in \mathbb{N}}$  gleichmäßig gegen  $e$  konvergiert:

Annahme: Es gibt ein  $s > 0$ , so daß es für jedes  $n \in \mathbb{N}$  ein  $m_n \geq n$  und ein  $x_{m_n} \in I$  gibt mit  $|e_{m_n}(x_{m_n}) - e(x_{m_n})| > s$ .

$I$  ist kompakt, daher gibt es in  $(x_{m_n})_{n \in \mathbb{N}}$  eine konvergente Folge  $(x_{n_j})_{j \in \mathbb{N}}$  mit

$$(6.4) \quad |e_{n_j}(x_{n_j}) - e(x_{n_j})| > s \quad j \in \mathbb{N}$$

Für  $(e_{n_j})_{j \in \mathbb{N}}$  folgt wie oben für  $(e_n)_{n \in \mathbb{N}}$  die Existenz einer auf ganz  $I$  gleichmäßig gegen  $e$  konvergenten Teilfolge und dies steht im Widerspruch zu (6.4). Damit ist die Annahme widerlegt und die Behauptung vollständig gezeigt.

**Satz 6.2** (Braess, [3])

Ergibt der Algorithmus eine Teilfolge  $(E(a_n))_{n \in J} \subseteq V_N^0$ ,  $J \subseteq \mathbb{N}$ , die auf  $I$  gleichmäßig gegen ein Element  $E(a_0) \in V_N^0 \setminus V_{N-1}$  konvergiert, dann konvergiert die ganze Folge  $(E(a_n))_{n \in \mathbb{N}}$  gleichmäßig auf  $I$  und  $E(a_0)$  ist die Minimallösung für  $f$  bezüglich  $V_N$  auf  $I$ .

**Beweis:**

Es kann nach Voraussetzung o.B.d.A.  $\text{grad}(E(a_n)) = N$  für  $n \in \mathbb{N}$  angenommen werden.

Es sei  $F_0 := f - E(a_0)$ .

Annahme:  $E(a_0)$  ist nicht Minimallösung für  $f$  bezüglich  $V_N$ .

Wendet man den Algorithmus auf  $E(a_0)$  nach Fall 2 (also mit  $X = I$ ) an, dann erhält man nach Hilfssatz 6.1:

$$\epsilon = \| F_0 \|_I - \| F_0 - (r_0, \text{grad}(E(a_0))) \|_X > 0$$

(  $e_0 = (r_0, \text{grad}(E(a_0)))$  ist die beste Approximation an  $F_0$  bezüglich des Gradientenraums von  $E(a_0)$ . )

Ist bei der Konstruktion von  $(E(a_n))_{n \in \mathbb{N}}$  stets gemäß Fall 2 verfahren worden, dann folgt nach Hilfssatz 6.2

$$\lim_{n \rightarrow \infty} \epsilon_n = \epsilon \text{ für } n \in J$$

und es gibt damit ein  $n_0 \in \mathbb{N}$ , so daß für  $n \in J$  und  $n \geq n_0$  gilt:

$$(6.5) \quad \epsilon_n \geq \frac{1}{2} < \epsilon$$

Nach Hilfssatz 6.1 gilt (6.5) auch, falls  $\epsilon_n$  gemäß Fall 1 berechnet wird.

Fallunterscheidung:

**Fall a:** Bei der Teilfolge  $(E(a_n))_{n \in J}$  sei **stets nach Fall 2** verfahren worden. Aus der gleichmäßigen Konvergenz ergibt sich wieder die Beschränktheit der Frequenzen von  $(E(a_n))_{n \in J}$  (man vergleiche hierzu (6.4) im Beweis zu Hilfssatz 6.2), woraus nach Satz 2.8 für  $n \in J$  (wegen  $\text{grad}(E(a_n)) = N$ )

$$(6.6) \quad \lim_{n \rightarrow \infty} a_n = a_0 \quad \text{und}$$

$$(6.7) \quad \lim_{n \rightarrow \infty} r_n = r_0 \quad (\text{nach Hilfssatz 6.2})$$

folgt.

Auf Grund der stetigen Differenzierbarkeit der Exponentialsummen gibt es ein  $M < \infty$  mit

$$\| E(a_n(c)) - E(a_n) - ce_n \|_I \leq c^2 M \text{ für } n \in J, |c| \leq 1 ;$$

$a_n(c)$  ist definiert wie in Satz 6.1.

Folglich gibt es ein  $C$  mit  $0 < C \leq 1$ , so daß mit (6.5) für  $c \in (0, C)$  erfüllt ist:

$$\| E(a_n(c)) - E(a_n) - ce_n \|_I \leq \frac{1}{3}c\epsilon \leq \frac{2}{3}c\epsilon_n, \quad n \in J, \quad n \geq n_0.$$

Wie in Satz 6.1 gezeigt, folgt daraus  $c_n \geq \frac{C}{2}$ ,  $n \in J$ ,  $n \geq n_0$ ; man erhält somit für  $n \in J$ ,  $n \geq n_0$ :

$$\| E(a_{n+1}) - E(a_n) \|_I \geq \| F_n \|_I - \| F_{n+1} \|_I \geq \frac{1}{3}c_n\epsilon_n \geq \frac{1}{3} \frac{C}{2} \epsilon > 0$$

Dies steht im Widerspruch zur gleichmäßigen Konvergenz der Folge.

**Fall b:** Es gebe eine Teilfolge  $(E(a_n))_{n \in J_1}$ ,  $J_1 \subseteq J$ , bei der **gemäß Fall 1** verfahren wird.

Wegen  $c_n \geq z$  folgt hier im Widerspruch zur gleichmäßigen Konvergenz

$$\| F_n \|_I - \| F_{n+1} \|_I \geq \frac{1}{3}z\epsilon_n \geq \frac{1}{3}z\frac{1}{2}\epsilon > 0 \quad n \in J_1, \quad n \geq n_0.$$

Damit konvergiert die ganze Folge  $(E(a_n))_{n \in \mathbb{N}}$  gleichmäßig gegen  $E(a_0)$ :

Es sei  $(E(a_n))_{n \in J_2}$ ,  $J_2 \subseteq \mathbb{N}$ , eine beliebige (unendliche) Teilfolge. Da  $(E(a_n))_{n \in J_2}$  eine Minimalfolge ist, ist sie gleichmäßig auf  $I$  beschränkt; es gibt also eine im Innern von  $I = [u, v]$  gleichmäßig konvergente Teilfolge, die auf jedem abgeschlossenen Intervall in  $(u, v)$  gleichmäßig gegen ein Element von  $V_N \setminus V_{N-1}$  konvergiert, da nach Voraussetzung

$$\inf_{E \in V_{N-1}} \| f - E \|_I > \| f - E(a_n) \|_I$$

für hinreichend großes  $n \in J_2$  gilt. Somit konvergiert diese Teilfolge auf  $I$  gleichmäßig gegen ein  $E \in V_N \setminus V_{N-1}$ .

$E$  ist aber, wie gezeigt, Minimallösung und aus der Eindeutigkeit der besten Approximation folgt  $E = E(a_0)$ .

### 6.1.3 Zur Anwendung des Algorithmus

Zur Konstruktion bester Approximationen geht man nach Braess vor wie folgt, vgl. [3], Kapitel 14 (p. 267 ff):

#### a. Approximation bezüglich $V_N^+$

Um die Voraussetzungen von Satz 6.2 immer erfüllen zu können, geht man bei der Konstruktion der besten Approximation bezüglich  $V_N^+$  induktiv vor: Die beste Approximation bezüglich  $V_0^+ = V_0$  ist die Nullfunktion; die Minimallösung  $E(a)$  für  $f$  bezüglich  $V_{N-1}^+$  sei bekannt und nicht die beste Approximation bezüglich  $V_N^+$ . Jede Alternante von  $f - E(a)$  in  $I$  hat also höchstens die Länge  $2N - 1$  und jede bessere Approximation in  $V_N$  ist nach Korollar 3.3 Element von  $V_N^+ \setminus V_{N-1}$ .

Die Iteration beginnt man mit

$$E(a_1, x) = E(a, x) + a_{N,1} e^{t_{N,1}x},$$

wobei  $a_{N,1} = 0$  und  $t_{N,1} \in \mathbb{R}$  nicht im Spektrum von  $E(a)$  enthalten ist. Es gilt also  $d_1 = 2N - 1$  und die Durchführung des Algorithmus ergibt eine bessere Approximation  $E(a_2) \in V_N^+ \setminus V_{N-1}$  nach Satz 6.1; man erhält so eine Folge  $(E(a_n))_{n \in \mathbb{N}}$ , die in

$$V = \{E \mid E \in V_N^+ \setminus V_{N-1}, \|f - E\|_I \leq \|f - E(a_2)\|_I < \|f - E(a)\|_I\}$$

enthalten ist.

Falls  $q := \frac{\max_{x \in I} f(x) + \min_{x \in I} f(x)}{2} > 0$  gilt, ist die beste Approximation an  $f$  auf  $I$  bezüglich  $V_1^+$  in  $V_1 \setminus V_0$  enthalten, und man kann die Iteration in  $V_1^+$  sofort mit  $E(a_1, x) = q \in V_1 \setminus V_0$  beginnen.

Nach Satz 2.3, Satz 2.5 und Satz 2.9 gibt es eine auf  $I$  gleichmäßig konvergente Teilfolge, deren Grenzfunktion nach Satz 2.7 in  $V$  enthalten ist.

Bei der Konstruktion der besten Approximation bezüglich  $V_N^+$  ist auf diese Weise die Voraussetzung von Satz 6.2 erfüllt und die bei der Iteration ermittelte Folge  $(E(a_n))_{n \in \mathbb{N}}$  konvergiert gleichmäßig gegen die beste Approximation an  $f$  bezüglich  $V_N^+$ .

Bemerkung:

Diese Ausführungen zur Approximation bezüglich  $V_N^+$  mit diesem Verfahren gelten analog auch für die Approximation bezüglich  $V_N^-$ .

### b. Approximation bezüglich $V_N^0$ ohne Vorzeichenbeschränkung

Liegt die beste Approximation bezüglich  $V_N^0$  (sofern sie existiert) nicht in  $V_N^+$ , dann ist im allgemeinen die Voraussetzung von Satz 6.2 nicht erfüllt<sup>27</sup> und man hat eine *Modifikation des Verfahrens*<sup>28</sup> durchzuführen, um den Algorithmus auch hier noch sinnvoll anzuwenden.

Es sei also  $E(a) \in V_{N-1}^0$  die Minimallösung bezüglich  $V_{N-1}^0$  an  $f$  und die beste Approximation bezüglich  $V_N^0$ , deren Existenz angenommen wird, sei nicht in  $V_N^+$  oder  $V_N^-$  enthalten; bei induktivem Vorgehen kann man mit Satz 3.4 überprüfen, ob diese Voraussetzung erfüllt ist.

Wie oben beginnt man mit

$$E(a_1, x) = E(a, x) + \sum_{i=K+1}^N a_{i,1} e^{t_{i,1}x},$$

wobei  $a_{i,1} = 0$  für  $K < i \leq N$  und  $K = \text{grad}(E(a))$  gilt und ferner  $t_{i,1} \in \mathbb{R}$ ,  $K < i \leq N$ , nicht im Spektrum von  $E(a)$  enthalten ist und  $t_{i,1} < t_{i+1,1}$  ist. Man erhält eine bessere Approximation  $E(a_2) \in V_N^0$  nach Satz 6.1 mit dem Vorzeichenvektor  $S = \text{sign}(E(a_2))$ . Die Modifikation besteht nun darin, daß bei der Konstruktion einer Folge besserer Approximationen  $(E(a_n))_{n \in \mathbb{N}}$  im Schritt 3 des Algorithmus der Faktor  $c_n$  für  $n \in \mathbb{N}$  so klein gewählt wird, daß stets  $\text{sign}(E(a_n)) = S$  gilt. Dies ist nach Satz 6.1 möglich; in der Regel ist diese Zusatzforderung bereits bei der Bestimmung von  $c_n$  nach Schritt 3 erfüllt.

Erhält man auf diese Weise eine gegen  $E(a_0) \in V_N^0 \setminus V_{N-1}$  gleichmäßig konvergente Teilfolge, dann ist  $E(a_0)$  Minimallösung, da diese Zusatzforderung am Beweis von Satz 6.2 wegen (6.6) und (6.7) nichts ändert:  $C > 0$  kann hinreichend klein gewählt werden.

Für  $N \geq 2$  tritt dieser Fall im allgemeinen jedoch nicht ein, da es nach Bemerkung 4.1 und Satz 4.3 verschiedene Vorzeichenklassen mit besseren Approximationen als  $E(a)$  und damit mehrere lokale Minima gibt. Da die lokalen Minima, abgesehen von der besten Approximation bezüglich  $V_N^0$ , Elemente von  $V_N \setminus V_N^0$  sind (Korollar 4.1), geht man nach Braess vor wie folgt:

---

<sup>27</sup> "wenn die beste Exponentialsumme sowohl positive als auch negative Faktoren enthält", [3], Kap 14, p. 268

<sup>28</sup> in [3], Kap 14, p. 269: "Erweiterung des Algorithmus"

Erhält man bei der Iteration von  $V_N^0(S)$  zwei oder mehrere Folgen von Frequenzen, die gegen einen gemeinsamen Grenzwert konvergieren, so breche man die Iteration ab und bestimme durch geeignete Wahl der Frequenzen  $t_{i,1}$ ,  $K < i \leq N$ , nach Hilfssatz 4.1 und Satz 4.2 eine neue Startfunktion  $E(a_i)$ , die in einer anderen Vorzeichenklasse enthalten ist, und führe hier eine neue Iteration durch.

Für  $K = N - 1$  gibt Bemerkung 4.1 die Zahl der Vorzeichenklassen an, in denen auf diese Weise der Algorithmus angewandt werden kann. Es ist allerdings nicht gesichert, daß so sämtliche Vorzeichenklassen mit besseren Approximationen erreicht werden und ob nicht mehr lokale Minima existieren, als Satz 4.3 angibt.

## 6.2 Das Newtonsche Iterationsverfahren

Das Newtonsche Iterationsverfahren, das allgemein für nichtlineare Approximation in [11] beschrieben ist, läßt sich nach den Ergebnissen von Kapitel 3 insbesondere bei der Approximation durch Exponentialsummen anwenden.

Es sei  $E(a) \in V_N^0 \setminus V_{N-1}$  die beste Approximation an  $f \in C(I)$  auf  $I = [u, v]$  bezüglich  $V_N$ ;  $E(a)$  ist also nach Satz 3.1 eindeutig bestimmt und  $F := f - E(a)$  besitzt in  $I$  eine Alternante der Länge  $2N+1$ .

Der Gradientenraum von  $E(a)$  hat die Dimension  $2N$  und dies gilt für alle Elemente von  $\{E \in V_N^0 \mid \|f - E\|_I < \inf_{w \in V_{N-1}} \|f - w\|_I\}$ , da diese den Grad  $N$  besitzen. Es existiert also eine Umgebung von  $E(a)$  in  $V_N^0$ , so daß die Elemente dieser Umgebung stets einen Gradientenraum der Dimension  $2N$  besitzen.

Es sei  $E(a_0) \in V_N^0$  eine Näherung für  $E(a)$ , so daß es in  $I$   $2N+1$  Punkte  $x_{1,k}$ ,  $0 \leq k \leq 2N$ , gibt mit

$$(6.8) \quad 0 \neq \text{sign}(F_0(x_{1,k})) \neq \text{sign}(F_0(x_{1,k+1})) \neq 0 \quad 0 \leq k \leq 2N - 1 ;$$

dabei sei  $F_0 := f - E(a_0)$ . In den Punkten  $x_{1,k}$  nehme  $|F_0|$  möglichst große Werte an.

Nach Hilfssatz 3.1 gilt  $\min_{0 \leq k \leq 2N} |F_0(x_{1,k})| \leq \inf_{E \in V_N} \|f - E\|_I$ .

In Analogie zum Remez-Verfahren wird man daher versuchen, einen Parametervektor  $a_1 \in \mathbb{R}^{2N}$  so zu bestimmen, daß mit  $F_1 := f - E(a_1)$  gilt:

$$(6.9) \quad F_1(x_{1,k}) = (-1)^k r_1 \quad 0 \leq k \leq 2N$$

Existiert dieser Parametervektor, dann ist  $E(a_1)$  die beste Approximation an  $f$  auf  $\{x_{1,k} \mid 0 \leq k \leq 2N\}$  und  $|r_1|$  eine weitere untere Abschätzung für die Minimalabweichung von  $f$  auf  $I$ . Gesucht ist also  $(a_1, r_1) \in \mathbb{R}^{2N+1}$  mit

$$g_k(a_1, r_1) := E(a_1, x_{1,k}) - f(x_{1,k}) + (-1)^k r_1 = 0 \quad 0 \leq k \leq 2N$$

Demnach ist  $(a_1, r_1)$  eine Nullstelle von

$$G(b, q) := \begin{pmatrix} g_0(b, q) \\ \vdots \\ g_{2N}(b, q) \end{pmatrix}, \quad (b, q) \in \mathbb{R}^{2N+1}, \quad b \in \mathbb{R}^{2N},$$

Verwendet man das Newton-Verfahren (im  $\mathbb{R}^{2N+1}$ ) mit dem Startwert  $(b_1, q_1) = (a_0, q_1)$ ,  $q_1$  geht in die Berechnung nicht ein, so erhält man zunächst formal für  $n \in \mathbb{N}$ :

$$J_G(b_n, q_n) \times (b_{n+1}, q_{n+1})^t = J_G(b_n, q_n) \times (b_n, q_n)^t - G(b_n, q_n) ;$$

$J_G$  ist die Jacobi-Matrix von  $G$ .

Es folgt also explizit für  $0 \leq k \leq 2N$ :

$$\begin{aligned} \sum_{j=1}^{2N} b_{n+1,j} D_j E(b_n, x_{1,k}) + (-1)^k q_{n+1} &= \\ &= \sum_{j=1}^{2N} b_{n,j} D_j E(b_n, x_{1,k}) + (-1)^k q_n - E(b_n, x_{1,k}) + f(x_{1,k}) - (-1)^k q_n \end{aligned}$$

$D_j E(b)$  ist die partielle Ableitung von  $E(b)$  nach  $b_j$  mit  $b = (b_1, \dots, b_{2N})$ ; ferner gilt  $b_n = (b_{n,1}, \dots, b_{n,2N})$ . Es folgt damit für  $0 \leq k \leq 2N$ :

$$\sum_{j=1}^{2N} (b_{n+1,j} - b_{n,j}) D_j E(b_n, x_{1,k}) + (-1)^k q_{n+1} = f(x_{1,k}) - E(b_n, x_{1,k})$$

Hat der Gradientenraum von  $E(a_0)$  die Dimension  $2N$ , dann ist für  $n=1$  dieses Gleichungssystem eindeutig lösbar und man erhält den Vektor  $b_2 - b_1 = b_2 - a_0 \in \mathbb{R}^{2N}$ . Ist  $E(a_0)$  weiterhin eine hinreichend gute Näherung für  $E(a)$ , dann kann  $a_1 = b_2$  gesetzt werden, d.h.  $E(a_1) = E(b_2)$  erfüllt (6.9) für numerische Zwecke hinreichend gut.

Im allgemeinen ist dies jedoch nicht der Fall (man vergleiche hierzu Kapitel 8); man hat dann das Newton-Verfahren mindestens soweit durchzuführen, daß für ein  $n \in \mathbb{N}$

$$\text{sign}(f(x_{1,k}) - E(b_n, x_{1,k})) \neq \text{sign}(f(x_{1,k+1}) - E(b_n, x_{1,k+1})) , 0 \leq k < 2N$$

erfüllt ist.

Da auf diskreten Punktmengen nicht allgemein eine beste Approximation bezüglich  $V_N^0$  existiert, ist nicht gesichert, daß dies stets möglich ist. Es ist jedenfalls erforderlich, daß der Gradientenraum der bei der Newton-Iteration berechneten Elemente  $E(b_n)$  die Dimension  $2N$  hat.

Ist eine Funktion  $E(a_1)$  ermittelt worden und approximiert diese  $f$  besser als  $E(a_0)$ , dann verfährt man mit  $E(a_1)$ , falls  $E(a) \neq E(a_1)$  ist, wie mit  $E(a_0)$  und erhält so  $E(a_2)$ , wenn die entsprechenden Voraussetzungen erfüllt sind, usw.

Da Konvergenzaussagen für dieses Verfahren nicht möglich sind, wird man nach jedem Schritt überprüfen, ob man eine bessere Approximation erhalten hat.

### 6.3 Approximation bzgl. $V_1$ durch Bestimmung von reellen Nullstellen

Gegeben sei das Intervall  $I$  und  $f \in C(I)$ .

Zur Bestimmung der besten Approximation an  $f$  auf  $I$  bzgl.  $V_1$  wird ein Verfahren beschrieben, das eine Übertragung des Remez-Algorithmus darstellt; im Gegensatz zum Newton-Verfahren von Abschnitt 6.2 ist hier nur eine reelle Nullstelle, etwa nach Newton-Raphson, zu ermitteln.

Ohne Beschränkung der Allgemeinheit sei die Minimallösung  $E$  für  $f$  bzgl.  $V_1$ , sofern sie existiert, Element von  $V_1 \setminus V_0$ .<sup>29</sup>

In  $I$  besitzt also  $f - E$  eine Alternante der Länge 3; es liegt daher nahe zu versuchen, durch Konstruktion der Minimallösung  $E_1$  für  $f$  auf einer Menge  $X \subseteq I$  mit  $|X| = 3$  die beste Approximation  $E$  auf  $I$  zu ermitteln.

Es sei  $X = \{x_1, x_2, x_3\} \subseteq I$  mit  $x_1 < x_2 < x_3$  so gegeben, daß für  $f$  auf  $X$  die Minimallösung  $E(x) = ae^{sx} \in V_1$  existiert und weiter  $a \neq 0$  erfüllt ist. Es gilt also

$$(6.10) \quad ae^{sx_i} + (-1)^i r = f(x_i) \quad 1 \leq i \leq 3 ;$$

die Minimalabweichung von  $f$  auf  $X$  sei also  $|r|$ ,  $r \in \mathbb{R}$ .

Nach Voraussetzung gilt

$$f(x_3) + f(x_2) = a(e^{sx_3} + e^{sx_2}) \neq 0 ,$$

so daß man durch Elimination von  $r$  und  $a$  aus (6.10) das äquivalente Gleichungssystem (6.11) erhält (vgl. Anhang A):

$$(6.11) \quad \begin{aligned} -r &= f(x_3) - ae^{sx_3} \\ a &= \frac{f(x_3) + f(x_2)}{e^{sx_3} + e^{sx_2}} \\ \frac{e^{sx_3} - e^{sx_1}}{e^{sx_3} + e^{sx_2}} &= \frac{f(x_3) - f(x_1)}{f(x_3) + f(x_2)} \end{aligned}$$

Setzt man

$$F(t) := \frac{e^{tx_3} - e^{tx_1}}{e^{tx_3} + e^{tx_2}} \quad \text{für } t \in \mathbb{R} , \quad w := \frac{f(x_3) - f(x_1)}{f(x_3) + f(x_2)}$$

so ist die Lösung des Gleichungssystems 6.10 zurückgeführt auf die Bestimmung einer reellen Nullstelle von  $F(t) - w$ :

<sup>29</sup>  $V_0$  enthält nur die Nullfunktion, s. Bemerkung 1.1, Punkt 3. Nach Korollar 3.1b ist die Nullfunktion 0 genau dann die beste Approximation an  $F$  auf  $I$  bezüglich  $V_1$ , wenn  $f - 0$ , also die Funktion  $f$  selbst, in  $I$  eine Alternante der Länge 2 besitzt.

- die Frequenz  $s$  ergibt sich aus  $F(s) = w$
- der Koeffizient  $a$  ergibt sich aus der zweiten Gleichung von (6.11):  

$$a = \frac{f(x_3) + f(x_2)}{e^{sx_3} + e^{sx_2}}$$

Eine Charakterisierung der Nullstellen von  $F(t) - w$  liefert Satz 6.3:

**Satz 6.3** Es gibt genau dann ein  $s \in \mathbb{R}$  mit  $F(s) = w$ , wenn  $w < 1$  erfüllt ist, und  $s$  ist dann eindeutig bestimmt.

**Beweis:**

Wegen  $x_1 < x_2 < x_3$  gilt für  $t \in \mathbb{R}$

$$\frac{dF(t)}{dt} = \frac{(x_3 - x_1)e^{t(x_1+x_3)} + (x_3 - x_2)e^{t(x_3+x_2)} + (x_2 - x_1)e^{t(x_1+x_2)}}{(e^{tx_3} + e^{tx_2})^2} > 0$$

$F(t)$  ist also in  $\mathbb{R}$  streng monoton wachsend.

Weiter erhält man

$$\lim_{t \rightarrow \infty} F(t) = \lim_{t \rightarrow \infty} \left( \frac{1}{1 + e^{t(x_2-x_3)}} - \frac{1}{e^{t(x_3-x_1)} + e^{t(x_2-x_1)}} \right) = 1$$

und analog

$$\lim_{t \rightarrow -\infty} F(t) = -\infty$$

$F(t)$  nimmt also für  $t \in \mathbb{R}$  jeden Wert aus  $(-\infty, +1)$  genau einmal an.

Damit ist der Satz gezeigt.

Bemerkung 6.1 gibt eine nicht-leere Menge von Funktionen an, für die das Gleichungssystem 6.10 lösbar ist:

**Bemerkung 6.1**

Genügt  $f \in C(I)$  den beiden Eigenschaften

- $\text{sign}(f(x)) \geq 0$  oder  $\text{sign}(f(x)) \leq 0$  für  $x \in I$   
(d.h.:  $f$  ändert in  $I$  sein Vorzeichen nicht)
- $f$  ist in  $I$  entweder streng monoton wachsend oder streng monoton fallend

dann gilt für  $x_i \in I$ ,  $1 \leq i \leq 3$ , mit  $x_1 < x_2 < x_3$

$$\frac{f(x_3) - f(x_1)}{f(x_3) + f(x_2)} < 1$$

Damit läßt sich der folgende **Algorithmus** formulieren für den (“normalen”) Fall, daß die Minimallösung  $E$  für  $f$  auf  $I$  bezüglich  $V_1$  nicht in  $V_0$  enthalten ist.

### Schritt 1: Ermittlung einer Startfunktion

Zur Ermittlung einer Startfunktion  $E_1(x) = a_1 e^{t_1 x}$  bestimme man drei Punkte  $x_{1,i} \in I$ ,  $1 \leq i \leq 3$ , mit  $x_{1,1} < x_{1,2} < x_{1,3}$ , so daß  $f$  in  $\{x_{1,1}, x_{1,2}, x_{1,3}\}$  keine Alternante der Länge 2 besitzt; nach Voraussetzung ist dies möglich.

Mit

$$w_1 = \frac{f(x_{1,3}) - f(x_{1,1})}{f(x_{1,3}) + f(x_{1,2})} < 1$$

ist  $t_1$  die reelle Nullstelle von

$$F_1(t) - w_1 = \frac{e^{tx_{1,3}} - e^{tx_{1,1}}}{e^{tx_{1,3}} + e^{tx_{1,2}}} - w_1$$

Man erhält  $a_1$  aus

$$a_1 = \frac{f(x_{1,3}) + f(x_{1,2})}{e^{t_1 x_{1,3}} + e^{t_1 x_{1,2}}}$$

Falls für die Punkte  $x_{1,i}$ ,  $1 \leq i \leq 3$ ,

$$|r_1| = |f(x_{1,3}) - a_1 e^{t_1 x_{1,i}}| > 0$$

erfüllt ist, wird mit Schritt 2 fortgefahren.

Andernfalls sind neue Punkte  $x_{1,i}$  zu so wählen, daß mit diesen  $|r_1| > 0$  gilt. Nach Bemerkung 6.2 ist dies möglich.

### Schritt 2: Iterative Berechnung besserer Approximationen

Ausgehend von der in Schritt 1 ermittelten Startfunktion  $E_1$  werden iterativ bessere Approximationen  $E_2, E_3, E_4, \dots$  errechnet. Es sei also  $n \geq 2$ .

Ist  $E_{n-1}(x) = a_{n-1} e^{t_{n-1} x}$  nicht bereits die beste Approximation für  $f$  auf  $I$ , dann bestimme man Punkte  $x_{n,i} \in I$ ,  $1 \leq i \leq 3$ , so daß

- $0 \neq \text{sign}(f(x_{n,i}) - E_{n-1}(x_{n,i})) = -\text{sign}(f(x_{n,i+1}) - E_{n-1}(x_{n,i+1}))$  für  $i \in \{1, 2\}$  erfüllt ist und weiterhin
- $f - E_{n-1}$  in  $x_{n,i}$  für  $1 \leq i \leq 3$  dem Betrage nach einen möglichst großen Wert annimmt

Nach Konstruktion von  $E_{n-1}$  ist dies möglich.

Mit

$$w_n := \frac{f(x_{n,3}) - f(x_{n,1})}{f(x_{n,3}) + f(x_{n,2})} < 1$$

ist  $t_n$  die reelle Nullstelle von

$$F_n(t) - w_n := \frac{e^{tx_{n,3}} - e^{tx_{n,1}}}{e^{tx_{n,3}} + e^{tx_{n,2}}} - w_n$$

Man erhält  $a_n$  aus

$$a_n = \frac{f(x_{n,3}) + f(x_{n,2})}{e^{tx_{n,3}} + e^{tx_{n,2}}}$$

Ist  $E_n(x) = a_n e^{t_n x}$  nicht die beste Approximation, dann wird dieser Schritt mit  $n+1$  erneut durchgeführt.

Falls  $\|f - E_n\|_I \geq \|f - E_{n-1}\|_I$  gilt, wird das Verfahren beendet.

### Bemerkung 6.2

Für jedes Element  $f$  der in Bemerkung 6.1 beschriebenen Funktionenklasse ist das Verfahren stets durchführbar:

Zunächst besitzt  $f$  nach Voraussetzung in keiner Punktmenge  $X \subseteq I$  eine Alternante der Länge zwei.

Nimmt man an, daß bei der Ermittlung einer Startfunktion für jede Menge  $X \subseteq I$ ,  $|X| = 3$ , stets  $|r_1| = 0$  gilt, dann folgt mit Satz 1.1:  $f \in V_1$ :

denn dann gibt es für  $\{x_1, x_2, x_3\} \subseteq I$ ,  $x_1 < x_2 < x_3$ , ein  $E_1 \in V_1$  mit  $E_1(x_i) = f(x_i)$ ,  $1 \leq i \leq 3$ , und für jede Menge  $\{x_1, x_2, \bar{x}\}$ ,  $\bar{x} \in I$ ,  $x_1 \neq \bar{x} \neq x_2$ , ein  $E_{\bar{x}} \in V_1$  mit  $E_{\bar{x}}(x_i) = f(x_i)$ ,  $i = 1, 2$  und  $E_{\bar{x}}(\bar{x}) = f(\bar{x})$ , woraus  $E_{\bar{x}} = E_1 = f$  folgt.

Die Existenz einer Minimallösung  $E \in V_1$  für beliebiges  $X$  ist aber nicht gewährleistet wie Beispiel 6.1 zeigt. Es können somit auch hier Schwierigkeiten, ähnlich wie beim Newtonsche Iterationsverfahren von Abschnitt 6.2, auftreten.

### Beispiel 6.1

$$X = \{0, \frac{1}{2}, 1\}, \quad f(0) = f(\frac{1}{2}) = 0, \quad f(1) = 1$$

Es sei  $a_n = e^{-n}$ ,  $t_n = n$  für  $n \in \mathbb{N}$ ; mit  $E_n(x) = a_n e^{t_n x}$  ist  $(E_n)_{n \in \mathbb{N}} \subseteq V_1$  eine Minimalfolge für  $f$  auf  $X$  bzgl.  $V_1$ , denn es gilt

$$\lim_{n \rightarrow \infty} \|f - E_n\|_X = 0$$

Es gibt jedoch keine beste Approximation an  $f$  auf  $X$  bzgl.  $V_1$ .

**Bemerkungen:**

1. Weitergehende Untersuchungen, etwa Aussagen zur Konvergenz waren mir hier nicht möglich.
2. Es stellt sich die Frage, inwieweit man dieses Verfahren für die Approximation in  $V_N$  mit  $N \geq 2$  verallgemeinern kann und somit, im Gegensatz zum Newtonschen Iterationsverfahren, nur die Frequenzen von Näherungen durch Bestimmung von Nullstellen ermittelt und dann die linearen Parameter direkt berechnet; eventuell kann man auf diesem Wege wie hier für  $N = 1$  Aussagen über die Existenz bester Approximationen auf diskreten Punktmengen  $X$  mit  $|X| = 2N + 1$  erhalten.
3. Zur numerischen Durchführung des Algorithmus, insbesondere zur Bestimmung der Nullstellen  $t_n$  beachte man Kapitel 9; die dort angegebenen Beispiele lassen das Verfahren als brauchbar erscheinen.
4. Die Idee zur Lösung des Gleichungssystems 6.10 geht zurück auf H.J. Maehly, Numerical Solution of a Certain Transcendental Equation Involving Exponentials (A Remark on a Paper of J.R.Rice), J.Soc.Indust.Appl.Math., Vol. 10 (1962).

## Teil III

# Numerische Experimente und Erprobung der Iterationsverfahren

## 7 Beispiele zum Verfahren von Braess

Für den Textteil von §7 von [26] wird auf Anhang B verwiesen.

In den Abschnitten 7.1, 7.2 und 7.3 von [26] wird das Verfahren von Braess für  $f(x) = \sqrt{x}$  auf dem Intervall  $I = [0, 1]$  mit  $N=1$  und  $N=2$  durchgeführt:

- In Abschnitt 7.1 erfolgt die Approximation bezüglich  $V_1$  nach Fall 1 und Fall 2
- In Abschnitt 7.2 werden Startfunktionen für die Iteration in  $V_2$  berechnet, ebenfalls nach Fall 1 und Fall 2
- In Abschnitt 7.3 wird die Konstruktion einer Minimallösung für  $f$  bezüglich  $V_2$  durchgeführt.

In Abschnitt 7.4 von [26] wird in das Konvergenzverhalten des Verfahrens von Braess anhand der Funktion  $f(x) = (1+x)^{-1}$  in  $V_3$  behandelt.

Anmerkung:

Diese Berechnungen wurden auch mit dem Programm BRAESS [28] durchgeführt, stets nach Fall 2, s. [29]

### 7.1 Approximation von $f(x) = \sqrt{x}$ in $[0,1]$ mit $N=1$ nach Braess

Siehe §7.1 von [26]

### 7.2 Konstruktion von Startfunktionen

Siehe §7.2 von [26]

**7.3 Zur Konstruktion der Minimallösung für  $f(x) = \sqrt{x}$   
in  $[0,1]$ ,  $N=2$**

*Siehe §7.3 von [26]*

**7.4 Zur Konvergenz des Algorithmus mit  $f(x) = \frac{1}{1+x}$   
und  $N=3$**

*Siehe §7.4 von [26]*

## 8 Approximationen für die Riemannsche Zetafunktion nach dem Newtonschen Iterationsverfahren

Zur Erprobung des Newtonschen Iterationsverfahrens von Abschnitt 6.2 werden für die Riemannsche Zetafunktion

$$\zeta(x) = \sum_{n=1}^{\infty} \frac{1}{n^x}$$

in den Intervallen  $[2, 3]$  und  $[2, 4]$  Approximationen aus  $V_N$  für  $1 \leq N \leq 4$  ermittelt.

Die Startfunktionen, die die Voraussetzung (6.8) erfüllen, sind nach dem Verfahren von Meinardus berechnet worden; es werden jeweils die Punkte  $x_0$  und  $x_{2N-1}$  mit  $h$  angegeben.

Aus den gleichen Gründen wie in [26], §7 wird auch hier die Approximation auf einer diskreten Punktmenge  $X$  durchgeführt:

$$X = \left\{ 2 + i \times \frac{1}{256} \mid 0 \leq i \leq 256 \times d \right\}$$

Dabei ist  $d = 1$ , falls auf  $[2, 3]$ , und  $d = 2$ , falls auf  $[2, 4]$  approximiert wird.

Für jeden Iterationsschritt werden die Punkte  $x_0, \dots, x_{2N}$  aus  $X$  (ohne zu runden) angegeben, mit denen das Newtonsche Verfahren zur Lösung von (6.9) durchgeführt wird; in diesen Punkten hat die durch die Startfunktion bzw. die durch die im vorausgehenden Iterationsschritt ermittelte Näherung  $F$  gegebenen Fehlerfunktion  $F = \zeta - E$  ein lokales Extremum für  $x \in X$ . Nach jedem Schritt mit dem Newton-Verfahren werden die neu ermittelten Parameter  $a_i, t_i$  für  $1 \leq i \leq N$  und die Werte  $F_i$  der entsprechenden Fehlerfunktion angegeben:

$$F_i = \zeta(x_i) - \sum_{j=1}^N a_j e^{t_j x_i} \quad 0 \leq i \leq 2N$$

Dabei wird zur Durchführung eines jeden Iterationsschrittes nach Newton verfahren, bis erfüllt ist:

$$\frac{\max_{0 \leq j \leq 2N} |F_j|}{\min_{0 \leq j \leq 2N} |F_j|} \leq 1.2$$

Eine derartige Vorschrift ist wesentlich, wie die Approximationen für  $N \geq 2$  zeigen.

Wie in [26], §7 wird im Anschluß an jede Iteration eine Auswertung der letzten Fehlerfunktion (für das ganze Intervall) zur Abschätzung der Minimalabweichung und der erreichten Genauigkeit angegeben. Es sind dabei die Abschätzungen (8.3) zu berücksichtigen: für die Nullstellen und die lokalen Extrema im Innern des betreffenden Intervalles werden in Klammern eine obere Schranke für den Betrag des Fehlers angegeben. Abschätzungen für die Genauigkeit der Funktionswerte sind durch (8.3) gegeben.

### Numerische Auswertung von $\zeta(\mathbf{x})$

Die Auswertung von  $\zeta(x) = \sum_{n=1}^{\infty} \frac{1}{n^x}$  für  $x > 1$  wird durch Anwendung der Eulerschen Summenformel nach K.Knopp, [10], vorgenommen; alle Seitenangaben beziehen sich auf [10].

Es gilt für  $k \in \mathbb{N}$  ([10], p. 549):

$$\zeta(x) = \frac{1}{x-1} + \frac{1}{2} + \sum_{i=1}^k \left( \frac{B_{2i}}{(2i)!} \prod_{j=0}^{2i-2} (x+j) \right) - R_k(x), \quad x > 1, \text{ mit}$$

$$R_k(x) = \prod_{i=0}^{2k} (x+i) \int_1^{\infty} \frac{P_{2k+1}(t)}{t^{x+2k+1}} dt.$$

Die Größen  $B_i$  sind die Bernoulli-Zahlen ([10], p. 185)

$$B_0 = 1, B_1 = \frac{1}{2}, B_2 = \frac{1}{6}, B_3 = B_5 = B_7 = \dots = 0, B_4 = \frac{1}{30}, B_6 = \frac{1}{42}, \dots;$$

Die Bernoulli-Polynome  $P_{2k}$  und  $P_{2k+1}$  sind gegeben durch ([10], p. 541)

$$(8.1) \quad P_{2k}(t) = (-1)^{k-1} \sum_{n=1}^{\infty} \frac{2 \cos 2n\pi t}{(2n\pi)^{2k}} \quad k \in \mathbb{N}$$

$$P_{2k+1}(t) = (-1)^{k-1} \sum_{n=1}^{\infty} \frac{2 \sin 2n\pi t}{(2n\pi)^{2k+1}}$$

Es wird  $k = 3$  verwendet:

$$(8.2) \quad R_3(x) = \prod_{i=0}^6 (x+i) \left[ \int_1^{10} \frac{P_7(t)}{t^{x+7}} dt + \int_{10}^{\infty} \frac{P_7(t)}{t^{x+7}} dt \right]$$

Mit  $P_7(t) = \frac{1}{7!} \sum_{i=0}^7 \binom{7}{i} B_i x^{7-i}$  ([10], p. 542) erhält man nach umfangreicher, jedoch elementarer Rechnung

$$\begin{aligned} \int_1^{10} \frac{P_7(t)}{t^{x+7}} dt &= \sum_{n=1}^9 \int_n^{n+1} \frac{P_7(t)}{t^{x+7}} dt \\ &= - \sum_{n=1}^9 \frac{(n+1)^{-x}}{\prod_{i=0}^6 (x+i)} + \frac{1-10^{-x-5}}{7!6(x+6)(x+5)} + \frac{10^{-x-3}-1}{6! \prod_{i=3}^6 (x+i)} + \\ &\quad + \frac{1-10^{-x-1}}{12 \prod_{i=1}^6 (x+i)} + \frac{10^{-x}-1}{2 \prod_{i=0}^6 (x+i)} + \frac{1-10^{-x+1}}{(x-1) \prod_{i=0}^6 (x+i)} \end{aligned}$$

Zur Abschätzung von

$$R(x) := \prod_{i=0}^6 (x+i) \int_{10}^{\infty} \frac{P_7(t)}{t^{x+7}} dt$$

wird  $|P_k(t)| \leq \frac{2}{(2\pi)^k} \sum_{n=1}^{\infty} \frac{1}{n^k}$ ,  $k \in \mathbb{N}$ , benutzt, was aus (8.1) folgt.

Mit  $\sum_{n=1}^{\infty} \frac{1}{n^{2k}} = (-1)^{k-1} \frac{B_{2k}(2\pi)^{2k}}{2(2k)!}$  ([10], p. 245) für  $k \in \mathbb{N}$  erhält man speziell für  $P_{2k+1}$ :

$$|P_{2k+1}(t)| \leq \frac{2}{(2\pi)^{2k+1}} \sum_{n=1}^{\infty} \frac{1}{n^{2k+1}} < \frac{2}{(2\pi)^{2k+1}} \sum_{n=1}^{\infty} \frac{1}{n^{2k}} \leq \frac{1}{2\pi} \frac{B_{2k}}{(2k)!} \quad k \in \mathbb{N}$$

Es folgt:

$$\begin{aligned} |R(x)| &< \prod_{i=0}^6 (x+i) \frac{B_6}{2\pi 6!} \int_{10}^{\infty} t^{-x-7} dt = \prod_{i=0}^6 (x+i) \frac{B_6}{2\pi 6!} \frac{1}{x+6} 10^{-x-6} = \\ &= \frac{B_6}{2\pi 6!} \prod_{i=0}^5 (x+i) 10^{-x-6} \end{aligned}$$

$|R(x)|$  ist im Intervall  $(1.1072, \infty)$  monoton fallend; spezielle Werte:

$$(8.3) \quad |R(x)| < \begin{cases} 2.7 \times 10^{-10} & : x \geq 2.0 \\ 1.8 \times 10^{-10} & : x \geq 2.5 \\ 1.1 \times 10^{-10} & : x \geq 3.0 \\ 0.6 \times 10^{-10} & : x \geq 3.5 \\ 3.2 \times 10^{-11} & : x \geq 4.0 \end{cases}$$

Mit (8.2) erhält man nach einigen Zwischenrechnungen:

$$\begin{aligned}
\zeta(x) &= \frac{1}{x-1} + \frac{1}{2} + \frac{B_2}{2!}x + \frac{B_4}{4!}x(x+1)(x+2) + \frac{B_6}{6!}x(x+1)(x+2)(x+3)(x+4) - \\
&\quad - \prod_{i=0}^6 (x+i) \int_1^{10} \frac{P_7(t)}{t^{x+7}} dt - R(x) = \\
&= 1 + \sum_{n=2}^9 \frac{1}{n^x} + \frac{x(x+1)(x+2)[(x+3)(x+4) - 4200]}{30240 \times 10^{x+5}} + \\
&\quad + \frac{1}{10^{x+1}} \left( \frac{x}{12} + \frac{5x+95}{x-1} \right) - R(x), \quad x > 1.
\end{aligned}$$

Für die folgenden Berechnungen von  $\zeta(x)$ ,  $x \in [2, 4]$ , wird  $R(x)$  vernachlässigt. Abschätzungen für den hierdurch entstehenden Fehler sind also mit (8.3) gegeben.

*Die Berechnungen: Siehe §8 von [26]*

## 9 Zur Approximation bezüglich $V_1$ nach dem Verfahren von Abschnitt 6.3

Mit dem Verfahren von Abschnitt 6.3 ist die Approximation von  $f(x) = \sqrt{x}$  auf  $[0,1]$  und der Riemannschen Zetafunktion  $\zeta$  auf  $[2,3]$  und  $[2,4]$  durchgeführt worden; Man beachte hierzu Bemerkung 6.1.

Zur Konstruktion einer Startfunktion auf Intervall  $[a,b]$  werden die Punkte  $x_1 = a$ ,  $x_2 = \frac{a+b}{2}$ ,  $x_3 = b$  verwendet.

Die Frequenzen  $t_n$  werden iterativ nach Newton-Raphson ermittelt: der Startwert für die Bestimmung von  $t_1$  ist stets 0, für  $n \geq 2$  wird  $t_{n-1}$  als Startwert für die iterative Bestimmung von  $t_n$  verwendet.

Die Approximationen werden wie oben auf diskreten Punktmengen  $X$  durchgeführt. Die Auswertungen der Fehlerfunktionen erfolgen wieder für das gesamte Intervall.

In den Abschnitten 9.2 und 9.3 erfolgt die Auswertung der Riemannschen Zetafunktion wie in Kapitel 8; entsprechend gelten die Bemerkungen über die Genauigkeit der angegebenen Werte.

Für den Vergleich der Ergebnisse mit denen von Kapitel 8 beachte man, daß  $X$  in den Abschnitten 9.2 und 9.3 weniger Punkte enthält als in Kapitel 8.

*Anmerkung (Februar 2023):*

*Diese Berechnungen wurden nochmals mit EXPFJP [30] durchgeführt.*

### 9.1 Approximation von $f(x) = \sqrt{x}$ auf $[0,1]$

Es ist  $X = \{\frac{i}{100} \mid 0 \leq i \leq 100\}$ .

#### 1. Iterationsschritt:

$$x_1 = 0.0 \quad x_2 = 0.5 \quad x_3 = 1.0$$

5 Schritte nach Newton-Raphson ergeben:

$$t_1 = +1.762\ 747\ 174\ 038 ; \text{ Fehler: } \pm 10^{-12}$$

Es folgt:

$$a_1 = 0.207\ 106\ 781\ 186$$

Zeichung 9.1 zeigt die Fehlerfunktion.

## 2. Iterationsschritt:

$$x_1 = 0.0 \quad x_2 = 0.42 \quad x_3 = 1.0$$

3 Schritte nach Newton-Raphson ergeben:

$t_2 = +1.751\ 452\ 157\ 150$  ; Fehler:  $\pm 10^{-12}$

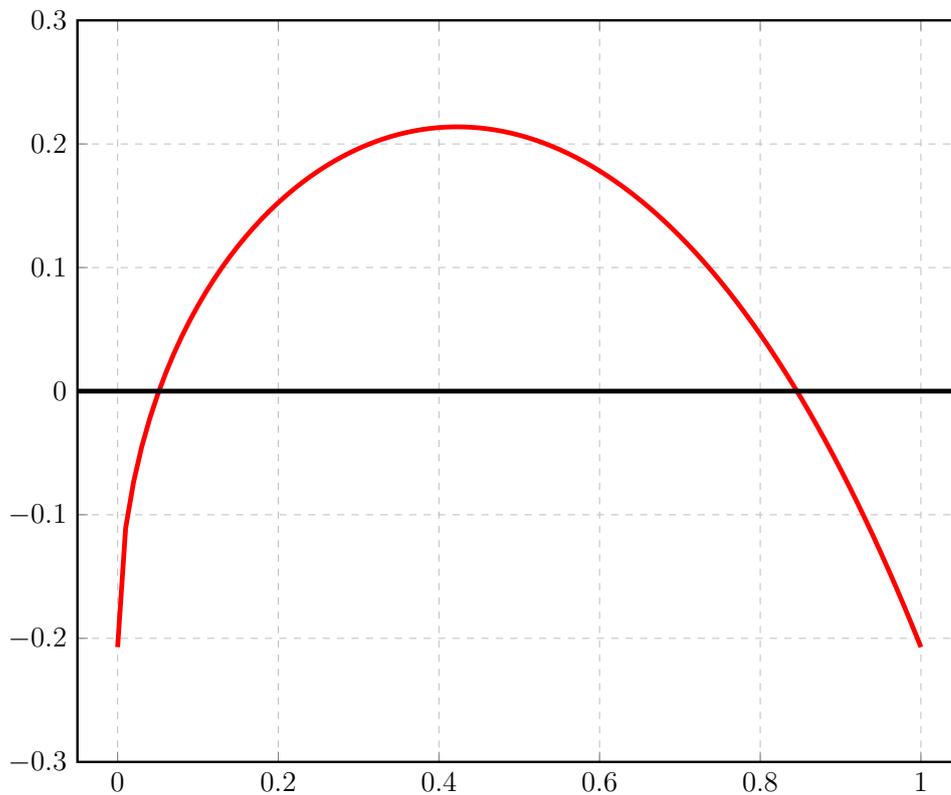
Es folgt:

$$a_2 = 0.209\ 953\ 239\ 189$$

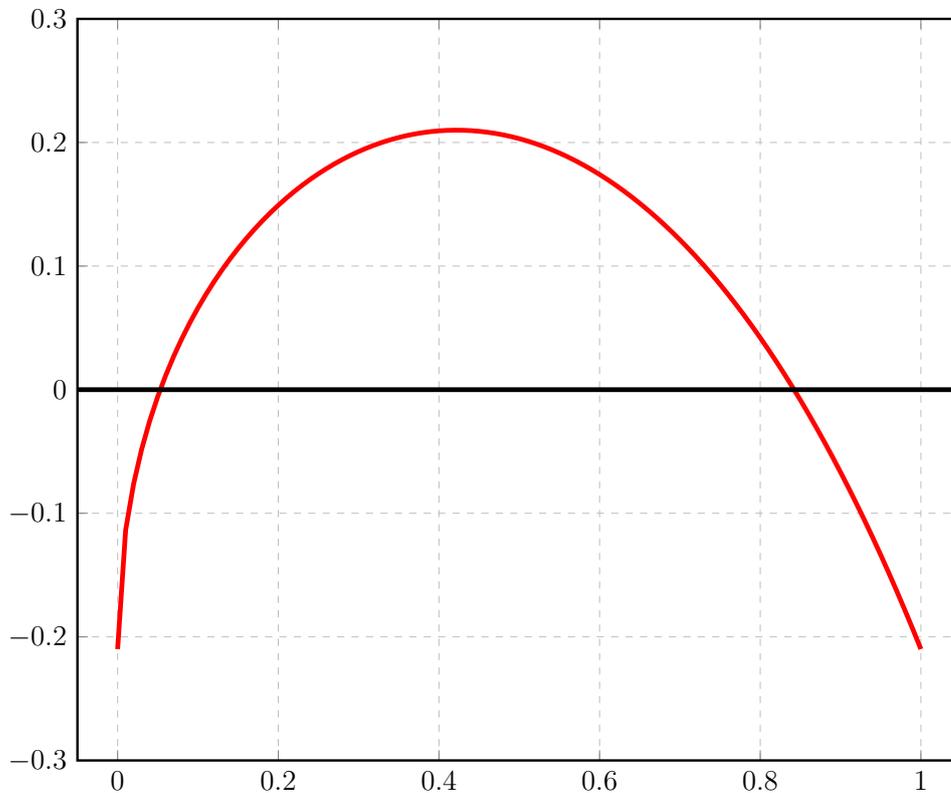
Zeichnung 9.2 zeigt die Fehlerfunktion.

**Ende der Iteration**

Auswertung der Fehlerfunktion		
Die Nullstellen	Lokale Extrema und Funktionswerte	
	0.0	-0.2099532392
0.0530896736		
	0.4218434150	+0.2099570814
0.8421382898		
	1.0	-0.2099532392



**Zeichnung 9.1**



Zeichnung 9.2

## 9.2 Approximation von $f(x) = \zeta(x)$ auf $[2,3]$

Es ist  $X = \{2.0 + \frac{i}{128} \mid 0 \leq i \leq 128\}$ .

### 1. Iterationsschritt:

$$x_i = 2.0 \quad x_2 = 2.5 \quad x_3 = 3.0$$

4 Schritte nach Newton-Raphson ergeben:

t1=-0.321 034 683 610 ; Fehler:  $\pm 10^{-12}$

Es folgt:

a1=+3.064 974 872 707

Zeichnung 9.3 zeigt die Fehlerfunktion.

**2. Iterationsschritt:**

$$x_1 = 2.0 \quad x_2 = 2.390625 \quad x_3 = 3.0$$

3 Schritte nach Newton-Raphson ergeben:

$$t_2 = -0.321\ 380\ 719\ 310 ; \text{ Fehler: } \pm 10^{-12}$$

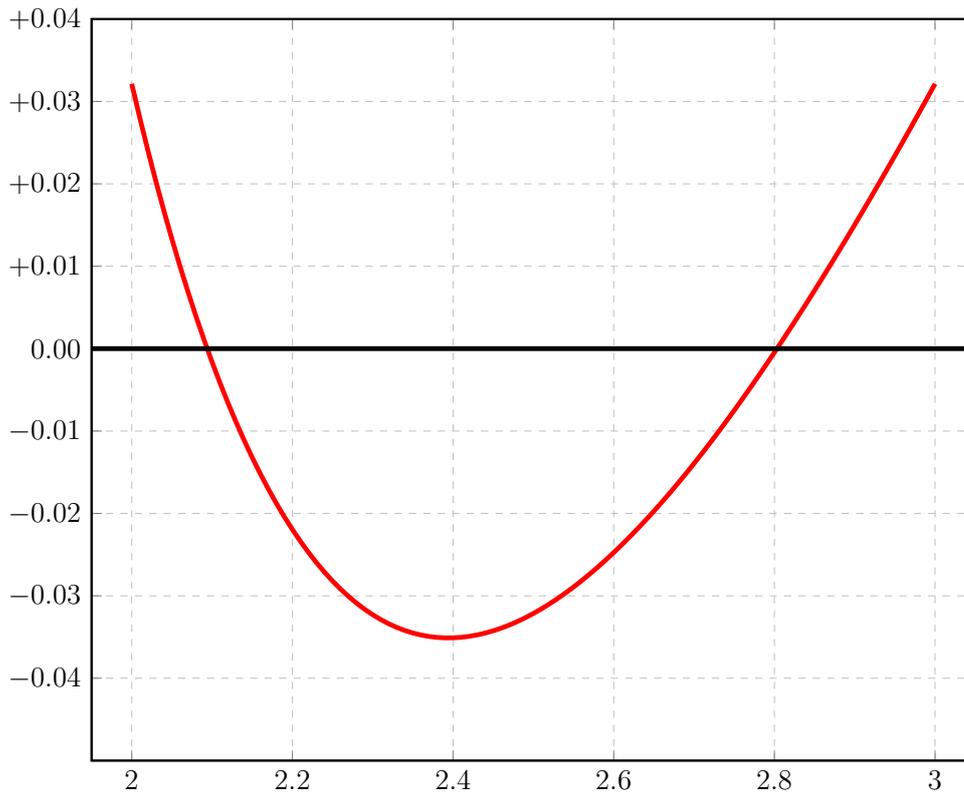
Es folgt:

$$a_2 = +3.064\ 296\ 199\ 406$$

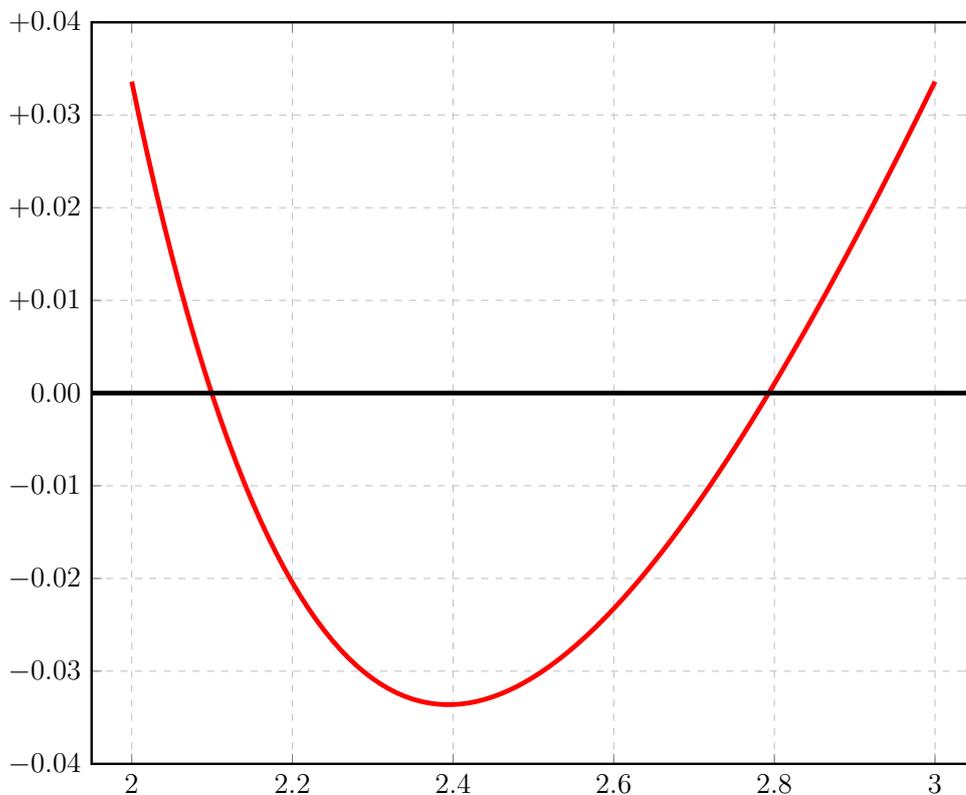
Zeichnung 9.4 zeigt die Fehlerfunktion.

**Ende der Iteration**

Auswertung der Fehlerfunktion	
Die Nullstellen	Lokale Extrema und Funktionswerte
	2.0                    +0.033 609 618 743
2.09944560	2.394200(3.4e-5)    -0.033 613 341 238
2.79300401	3.0                    +0.033 609 618 743



**Zeichnung 9.3**



Zeichnung 9.4

### 9.3 Approximation von $f(x) = \zeta(x)$ auf $[2,4]$

Es ist  $X = \{2.0 + \frac{i}{128} \mid 0 \leq i \leq 256\}$ .

#### 1. Iterationsschritt:

$$x_i = 2.0 \quad x_2 = 3.0 \quad x_3 = 4.0$$

4 Schritte nach Newton-Raphson ergeben:

$$t1 = -0.220\ 167\ 923\ 889 ; \text{ Fehler: } \pm 10^{-12}$$

Es folgt:

$$a1 = +2.453\ 432\ 894\ 140$$

Zeichnung 9.5 zeigt die Fehlerfunktion.

#### 2. Iterationsschritt:

$$x_i = 2.0 \quad x_2 = 2.6796875 \quad x_3 = 4.0$$

3 Schritte nach Newton-Raphson ergeben:

$$t2 = -0.221\ 422\ 241\ 102 ; \text{ Fehler: } \pm 10^{-12}$$

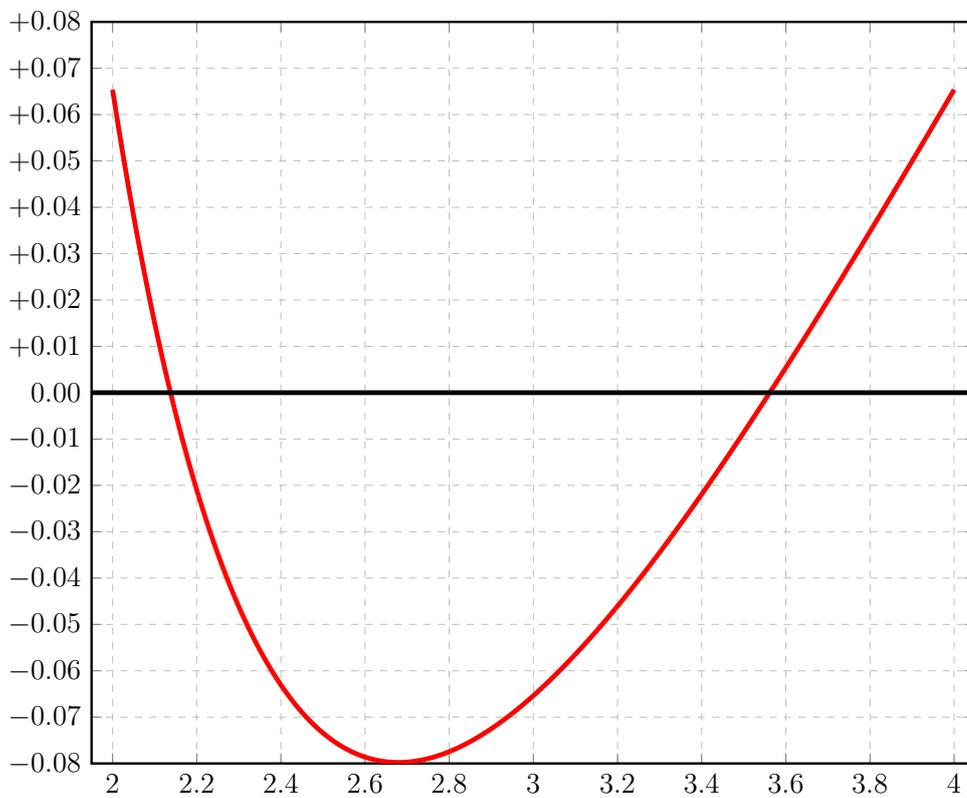
Es folgt:

a2=+2.448 506 467 119

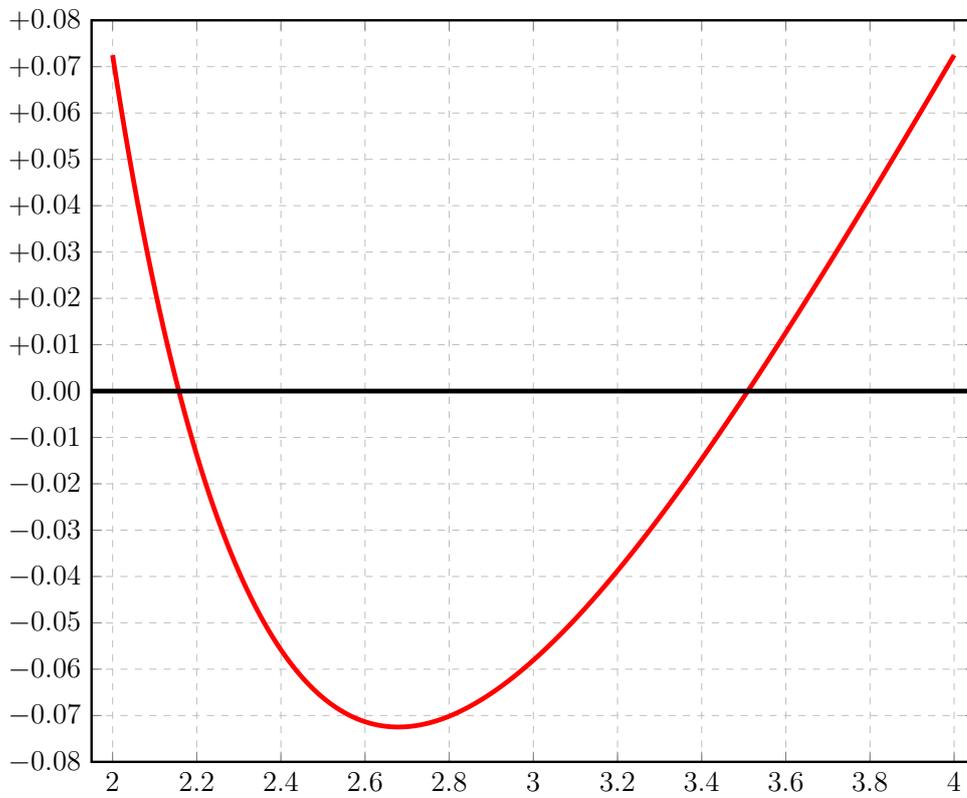
Zeichnung 9.6 zeigt die Fehlerfunktion.

**Ende der Iteration**

Auswertung der Fehlerfunktion		
Die Nullstellen	Lokale Extrema und Funktionswerte	
	2.0	+0.072 485 893 085
2.15753518	2.678848(3.2e-5)	-0.072 486 014 988
3.50969112	4.0	+0.072 485 893 085



**Zeichnung 9.5**



**Zeichnung 9.6**

## 10 Das Lokale Kolmogoroff-Kriterium bei der Konstruktion besserer Approximationen

Es sei  $f \in C(I)$  und  $E(s) \in V_N$  gegeben.

Im Beweis von Theorem 89 in [12] (Satz 2.10 in [12]) wird gezeigt:

Gibt es ein  $b \in \mathbb{R}^{2N}$  mit  $(b, \text{grad}(E(a, x_k))(f(x_k) - E(a, x_k))) > 0$  für  $1 \leq k \leq m$ , wobei  $\{x_k \mid 1 \leq k \leq m\}$  die Menge der Extremalpunkte von  $f - E(a)$  in  $I$  ist, dann gibt es ein  $C > 0$ , so dass

$$\| f - E(a + cb) \|_I < \| f - E(a) \|_I$$

für  $c \in (0, C)$  ist.

Es sei  $E(a, x) = \sum_{i=1}^N a_i e^{t_i x}$ . Gibt es in  $V_N^0$  bessere Approximationen als  $E(a)$  für  $f$ , so wird zur Konstruktion besserer Approximationen folgender Ansatz nahegelegt, falls  $f - E(a)$  endlich viele Extremalpunkte in  $I$  besitzt:

1. Man löse die lineare Optimierungsaufgabe

$$(10.1) \quad (f(x_k) - E(a, x_k)) \sum_{i=1}^N (b_i + b_{N+i} a_i x_k) e^{t_i x_k} - \mu \geq 0 \quad 1 \leq k \leq m$$

$$(10.2) \quad \begin{aligned} b_i &\geq -1 \\ &1 \leq i \leq 2N \\ b_i &\leq +1 \end{aligned}$$

$$\mu = \text{Max!}$$

mit den Unbekannten  $\mu, b_i, 1 \leq i \leq 2N$ ; dabei besitzt  $f - E(a)$  in  $I$  genau  $m$  Extremalpunkte  $x_k, 1 \leq k \leq m < \infty$ .

2. Erhält man eine Lösung mit  $\mu > 0$ , dann setze man  $c = 1$  und bestimme durch sukzessives Halbieren ein  $c > 0$  mit

$$\| f - E(a + cb) \|_I < \| f - E(a) \|_I ,$$

wobei  $b = (b_1, \dots, b_{2N})$  ist.

Hierzu ein **Beispiel**:

Es ist  $N = 3$ ,  $f(x) = \frac{1}{1+x}$ ,  $I = [0, 1]$ ; die Approximation wird auf  $X = \{\frac{i}{100} \mid 0 \leq i \leq 100\}$  durchgeführt<sup>30</sup>.

Die Ausgangsfunktion  $E(a)$  ist gegeben durch die Parameter

a1=+0.053 824 480 , t1=-4.282 493 872  
a2=+0.400 482 842 , t2=-1.540 603 343  
a3=+0.545 644 214 , t3=-0.277 434 496

Zeichnung 10.1 stellt die Fehlerfunktion dar.

1. Iterationsschritt:

Es ist hier  $m = 1$  und  $x_1 = 0.0$ ; als Lösung der Optimierungsaufgabe erhält man  $b_1 = b_2 = b_3 = 1.0$ ,  $b_4 = b_5 = b_6 = 0.0$ ,  $\mu = 0.000145$ .

Eine bessere Approximation erhält man mit  $c = 2^{-17}$ :

a1=+0.053 832 109 , t1=-4.282 493 872  
a2=+0.400 490 472 , t2=-1.540 603 343  
a3=+0.545 651 843 , t3=-0.277 434 496

Zeichnung 10.2 stellt die Fehlerfunktion dar.

2. Iterationsschritt:

Es wird hier  $m = 2$  und  $x_1 = 0.0$ ,  $x_2 = 0.13$  verwendet. Als Lösung der Optimierungsaufgabe erhält man  $b_1 = b_2 = b_3 = 1.0$ ,  $b_4 = b_5 = b_6 = 0.0$ ,  $\mu = 0.000077$ . Eine bessere Approximation erhält man mit  $c = 2^{-20}$ :

a1=+0.053 833 063 , t1=-4.282 493 872  
a2=+0.400 491 426 , t2=-1.540 603 343  
a3=+0.545 652 797 , t3=-0.277 434 496

Zeichnung 10.3 stellt die Fehlerfunktion dar.

Bei Fortsetzung der Iteration erhält man keine wesentlich bessere Approximation mehr:  $c$  muss von Schritt zu Schritt kleiner gewählt werden und als Lösung der Optimierungsaufgabe erhält man  $b_1 = b_2 = b_3 = 1.0$ ,  $b_4 = b_5 = b_6 = 0.0$ ; an den Frequenzen wird also nichts geändert. Dies gilt auch dann, wenn man  $m$  größer wählt.

Es sei  $E(a)$  die hier gegebene Startfunktion,  $E(a')$  die mit dem achten Iterationsschritt von 7,4A gegebene Lösung und  $(b_1, \dots, b_6) = a' - a$ ; die  $b_i$  erfüllen

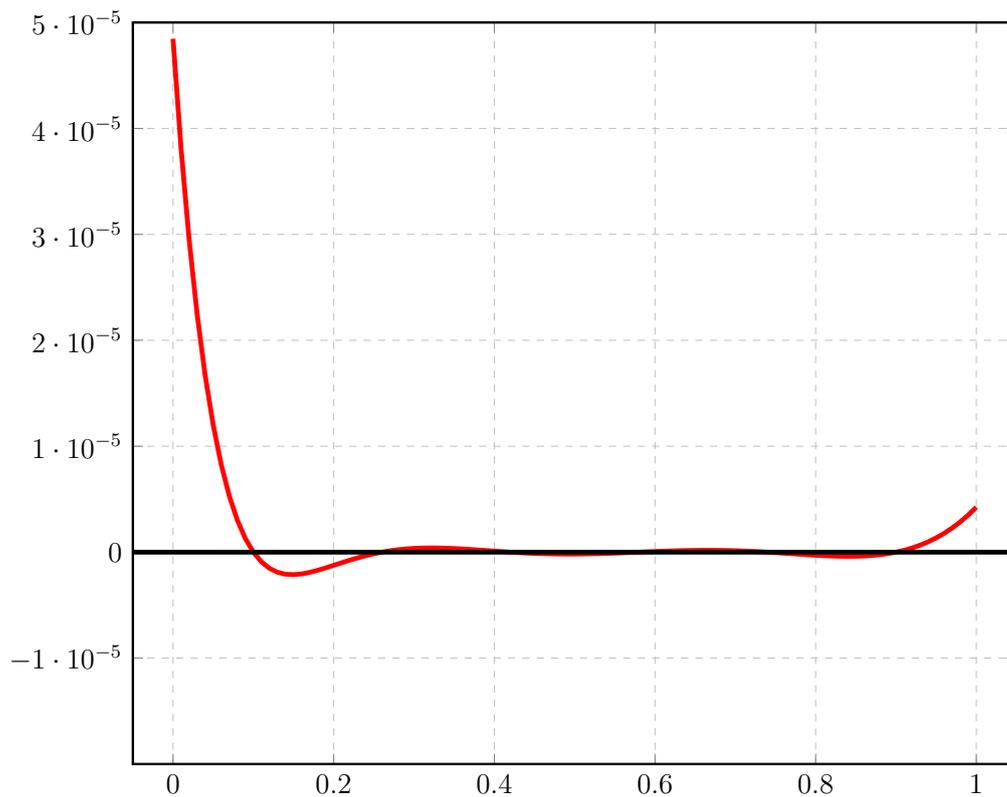
---

<sup>30</sup> Die Optimierungsaufgabe ist nach dem Simplex-Algorithmus mit dem FORTRAN-Unterprogramm SIMPX des Rechenzentrums gelöst worden

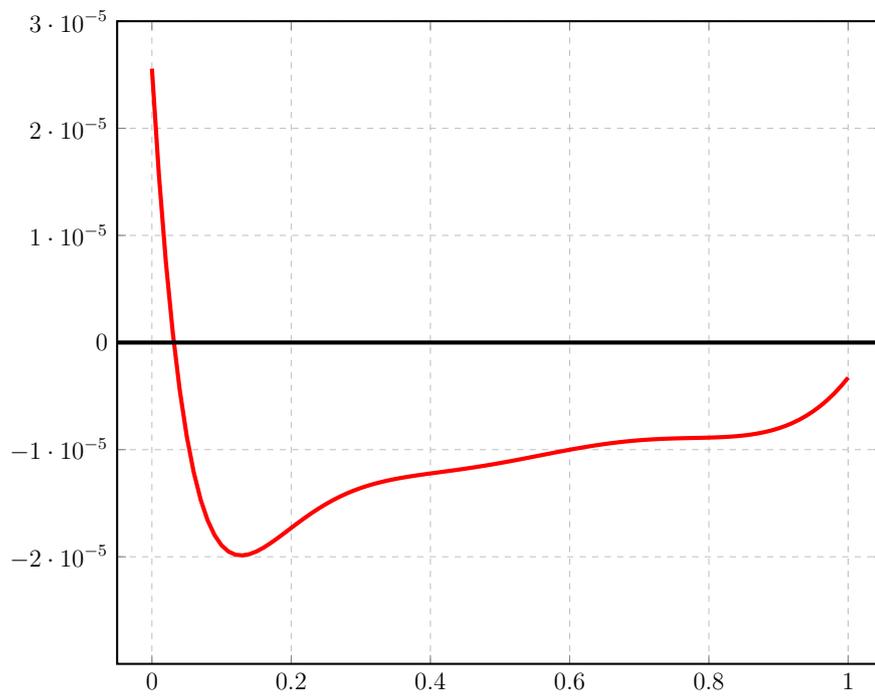
die Restriktionen (10.2) und mit diesen Werten folgt aus (10.1) für  $\mu$ :

$$\mu \leq 2.4 \times 10^{-9}$$

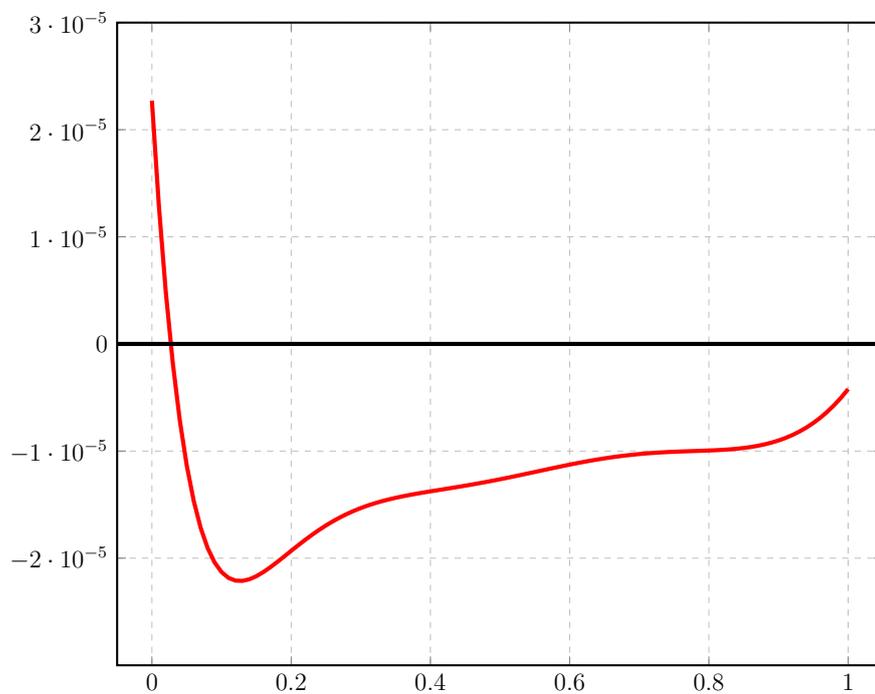
Aus diesen Ergebnissen kann man folgern, dass im allgemeinen das Verfahren in dieser Form für die praktische Ermittlung von Minimallösungen wenig brauchbar ist, da hierfür  $\mu$  nicht minimal sein muss.



**Zeichnung 10.1**



**Zeichnung 10.2**



**Zeichnung 10.3**

## Literatur

- [1] D. Braess.  
Approximation mit Exponentialsummen.  
Computing 2 (1967), 309-321
- [2] D. Braess.  
Über die Vorzeichenstruktur der Exponentialsummen.  
J.Approximation Theory 3 (1970), 101-113
- [3] D. Braess.  
Die Konstruktion der Tschebyscheff-Approximierenden bei der Anpassung mit Exponentialsummen.  
J.Approximation Theory 3 (1970), 261-273
- [4] E. Cesàro.  
Elementares Lehrbuch der algebraischen Analysis und der Infinitesimalrechnung.  
Leipzig, 1904, pp 77-79
- [5] F. Erwe.  
Gewöhnliche Differentialgleichungen.  
Bibliographisches Institut, Mannheim.
- [6] H. Grauert - W. Fischer.  
Differential- und Integralrechnung II.  
Springer-Verlag, Berlin-Heidelberg-New York, 1968.
- [7] E. Kamke.  
Differentialgleichungen I.  
Leipzig, 1964
- [8] S. Karlin - W. J. Studden.  
Tchebycheff Systems: With Applications in Analysis and Statistics.  
Interscience Publ., New York-London-Sydney, 1966
- [9] L. G. Kelly.  
Handbook of Numerical Methods and Applications.  
Addison-Wesely Publishing Company, 1967

- [10] K. Knopp.  
Theorie und Anwendung der Unendlichen Reihen.  
Springer-Verlag, Berlin-Göttingen-Heidelberg-New York, 1964
- [11] G. Meinardus u. D. Schwedt.  
Nichtlineare Approximationen.  
Arch.Rat.Mech.Anal. 17 (1967), 297-326
- [12] G. Meinardus.  
Approximation of Functions: Theory and Numerical Methods.  
Springer-Verlag, Berlin-Heidelberg-New York, 1967
- [13] G. Meinardus.  
Die unter [13] zitierten Angaben gehen auf *mündliche Mitteilungen* zurück.
- [14] S. Ramanujan.  
Note on a Set of Simultaneous Equations. In: Collected Papers of Srinivasa Ramanujan. Chelsea Publishing Company, New York, 1962
- [15] J. R. Rice.  
The Approximation of Functions, Vol. II.  
Addison-Wesely Publishing Company, 1969
- [16] John R. Rice.  
Chebyshev Approximation by Exponentials.  
J.Soc.Indust.Appl.Math. Vol. 10, No. 1 (March 1962), 149-161
- [17] E. Schmidt.  
Zur Kompaktheit bei Exponentialsummen.  
J.Approximation Theory 3 (1970), 445-454
- [18] E. Schmidt.  
Normalität und Stetigkeit bei der Tschebyscheff-Approximation mit Exponentialsummen.  
Dissertation, Münster 1968
- [19] J. F. Steffenson.  
Interpolation.  
Chelsea Publishing Company, New York, 1965

- [20] H. Werner.  
 Der Existenzsatz für das Tschebyscheffsche Approximationsproblem mit Exponentialsummen.  
 In: Funktionalanalytische Methoden der numerischen Mathematik, Vortragsauszüge der Tagung über funktionalanalytische Methoden der numerischen Mathematik vom 19. bis 25. November 1967 im Mathematischen Forschungsinstitut Oberwolfach, herausgegeben von L. Collatz und H. Unger.  
 Birkhäuser Verlag Basel und Stuttgart, 1969
- [21] H. Werner.  
 Tschebyscheff-Approximationsproblem with Sums of Exponentials.  
 In: Approximation Theory, Proceedings of a Symposium held at Lancaster, July 1969. Edited by A. Talbot.  
 Academic Press, London and New York, 1970
- [22] H. Werner - R. Schaback.  
 Praktische Mathematik II.  
 Springer-Verlag, Berlin-Heidelberg-New York, 1972
- [23] F. A. Willers.  
 Methoden der praktischen Analysis.  
 Berlin, 1971
- [24] B. Brosowski.  
 Nicht-lineare Tschebyscheff-Approximation.  
 Bibliographisches Institut, Mannheim, 1968
- [25] F. R. Gantmacher.  
 Matrizenrechnung II.  
 Berlin, 1959
- [26] F. J. Polster.  
 Exponentielle Approximation: Theorie und Numerische Verfahren.  
 Diplomarbeit, FAU Erlangen, 1973
- [27] F. J. Polster.  
 MEINARDUS: Ein Programm zur Exponentiellen Approximation bzgl.  $V_N$ .  
 Januar 2023
- [28] F. J. Polster.  
 BRAESS: Ein Programm zur Exponentiellen Approximation bzgl.  $V_N$ .  
 Januar 2023

- [29] F. J. Polster.  
BRAESS: Berechnungen  
Januar 2023
- [30] F. J. Polster.  
EXPFJP: Ein Programm zur Exponentiellen Approximation bzgl.  $V_1$ .  
Januar 2023

## Anhang A: Herleitung der Gleichungen (6.11)

1. Aus der Gleichung (6.10) mit  $i = 3$  folgt unmittelbar

$$-r = f(x_3) - ae^{sx_3}$$

2. Ersetzen von  $r$  in der Gleichung (6.10) mit  $i = 2$ :

$$\begin{aligned} ae^{sx_2} &= f(x_2) - r = f(x_2) + f(x_3) - ae^{sx_3} \\ \Rightarrow ae^{sx_3} + ae^{sx_2} &= f(x_3) + f(x_2) \\ \Rightarrow a &= \frac{f(x_3) + f(x_2)}{e^{sx_3} + e^{sx_2}} \end{aligned}$$

3. Ersetzen von  $r$  und  $a$  in der Gleichung (6.10) mit  $i = 1$ :

$$\begin{aligned} ae^{sx_1} - r &= f(x_1) \\ \frac{f(x_3) + f(x_2)}{e^{sx_3} + e^{sx_2}} e^{sx_1} + f(x_3) - ae^{sx_3} &= f(x_1) \\ \frac{f(x_3) + f(x_2)}{e^{sx_3} + e^{sx_2}} e^{sx_1} + f(x_3) - \frac{f(x_3) + f(x_2)}{e^{sx_3} + e^{sx_2}} e^{sx_3} &= f(x_1) \\ \frac{e^{sx_1}(f(x_3) + f(x_2)) - e^{sx_3}(f(x_3) + f(x_2))}{e^{sx_3} + e^{sx_2}} &= f(x_1) - f(x_3) \\ \frac{(e^{sx_1} - e^{sx_3})(f(x_3) + f(x_2))}{e^{sx_3} + e^{sx_2}} &= f(x_1) - f(x_3) \\ \Rightarrow (-1) \times \frac{(e^{sx_1} - e^{sx_3})}{e^{sx_3} + e^{sx_2}} &= \frac{f(x_1) - f(x_3)}{f(x_3) + f(x_2)} \times (-1) \\ \text{also: } \frac{(e^{sx_3} - e^{sx_1})}{e^{sx_3} + e^{sx_2}} &= \frac{f(x_3) - f(x_1)}{f(x_3) + f(x_2)} \end{aligned}$$

## Anhang B:

### §7 der Diplomarbeit (L<sup>A</sup>T<sub>E</sub>X-Version)<sup>31</sup>

#### Vorbemerkung:

Zur technischen Durchführung der folgenden Berechnungen gelten die Angaben von Abschnitt 5.4; da hier direkt Listen des Rechenzentrums verwendet werden, sind die Zahlen in Gleitkommadarstellung angegeben. Wie in Abschnitt 5.4 werden in den Zeichnungen die jeweiligen Fehlerfunktionen dargestellt; weiter werden die Bezeichnungen, wie sie zur Herleitung der Verfahren benutzt worden sind, beibehalten.

## §7 Beispiele zum Verfahren von Braess

### Bemerkungen, Erläuterungen

1. Es ist hier stets  $I = [0, 1]$ .
2. Der Algorithmus von Braess wird, falls nicht anders angegeben, gemäß Fall 2 durchgeführt; die lineare Approximation nach Schritt 2 des Verfahrens wird mit dem *allgemeinen Remez-Algorithmus* (s. z.B. [12], Abschnitt 7.1, p. 107) ermittelt.

Um dabei nicht die Differenzierbarkeit der hier zur Demonstration benutzten Funktionen  $f$  zu verwenden, wird die Approximation auf den Punkten

$$x_i = \frac{i}{100}, \quad 0 \leq i \leq 100$$

durchgeführt; der hierbei entstehende Diskretisierungsfehler kann vernachlässigt werden. Es wird so nach Remez iteriert, daß

$$(7.1) \quad \frac{\max_{0 \leq i \leq 100} |F(x_i) - e'(x_i)|}{\max_{0 \leq i \leq 100} |F(x_i) - e(x_i)|} \leq 1.01$$

erfüllt ist, wobei  $e$  die beste lineare Approximation an  $F$  auf  $x_i$ ,  $0 \leq i \leq 100$ , und  $e'$  eine durch die Remez-Iteration gegebene Näherung für  $e$  sei.  $F$  ist die nach Schritt 2 des Braess-Verfahrens zu approximierende Fehlerfunktion.

---

<sup>31</sup> dies ist der Textteil von [26], §7, inkl. der einleitenden "Vorbemerkung" von "Teil III"

Zu jedem Iterationsschritt werden zunächst die Parameter  $r_i$  der linearen Approximation  $\sum_{i=1}^N (r_i + r_{N+i} a_i x) e^{t_i x}$  angegeben, wobei  $\sum_{i=1}^N a_i e^{t_i x}$  die entsprechende Startfunktion bzw. die im vorhergehenden Iterationsschritt ermittelte Näherung ist.

3. Der nach Schritt 3 des Braess-Verfahrens ermittelte Faktor, mit dem eine bessere Approximation berechnet wird, ist mit C bezeichnet und wird als Bruch angegeben, so daß dem Nenner leicht entnommen werden kann, wie oft zur Durchführung von Schritt 3 die Norm der Fehlerfunktion bestimmt werden muß; dann folgen als Resultat des Iterationsschrittes die Parameter der somit gegebenen besseren Approximation, die wieder mit  $a_i, t_i, 1 \leq i \leq N$ , bezeichnet werden. (Bei der Indizierung wird der Iterationsschritt nicht angegeben, da keine Verwechslungen zu befürchten sind.)
4. An jede Iteration schließt sich eine Auswertung der Fehlerfunktion  $f - E$  auf ganz I an, wobei E die im letzten Iterationsschritt ermittelte Näherung sei; es werden die Nullstellen und lokalen Extrema von  $f - E$  mit den dazugehörigen Funktionswerten angegeben, so daß eine Abschätzung der Minimalabweichung von f möglich ist.

## Die Experimente

In den Abschnitten 7.1, 7.2 und 7.3 wird der Algorithmus für  $f(x) = \sqrt{x}$  mit  $N=1$  und  $N=2$  durchgeführt, Abschnitt 7.4 behandelt das Konvergenzverhalten dieses Verfahrens anhand  $f(x) = (1 + x)^{-1}$  und  $N = 3$ .

In **Abschnitt 7.1** erfolgt zunächst die Approximation bezüglich  $V_1$  nach Fall 2. Während die Iteration von 7.1A wie oben beschrieben durchgeführt ist, wird in 7.1B die Remez-Iteration bereits beendet, wenn der Quotient von (7.1) kleiner als 2 ist. Für die Rechnung bedeutet dies, daß in jedem Iterationsschritt von 7.1B nur 2-mal, in den beiden ersten Schritten von 7.1A jedoch 4-mal und in den folgenden 3-mal nach Remez iteriert wird.

In 7.1B ist daher der Rechenaufwand beachtlich kleiner als in 7.1A, nach dem dritten Iterationsschritt ist aber mit den so bestimmten Parametern  $r_1$  und  $r_2$  keine Verbesserung nach Schritt 3 mehr möglich; andererseits dürfte für viele Zwecke die erreichte Genauigkeit genügen.

In den Abschnitten 7.2 und 7.3 werden zur Approximation von  $f$  bezüglich  $V_2$  die Berechnungen des Algorithmus sowohl für Fall 2 als auch Fall 1 durchgeführt:

In **Abschnitt 7.2** werden Startfunktionen für die Iteration in  $V_2$  angegeben, wobei aus Platzgründen die Parameter der linearen Approximation nicht aufgeführt werden.

Wie in §6 beschrieben, geht man zur Ermittlung von Startfunktionen aus von

$$a_1 e^{t_1 x} + a_2 e^{t_2 x}, \quad a_2 = 0, t_2 \neq t_1,$$

wobei  $a_1, t_1$  die im 5-ten Iterationsschritt von 7.1A ermittelten Parameter sind.

In **7.2A** sind die Ergebnisse für die Berechnung nach Fall 2 angegeben.

Für die Berechnung von **7.2B** nach Fall 1 ist

$$X = \{ 0.0, 0.3, 0.415, 0.6, 1.0 \}$$

benutzt worden; man beachte hierzu Zeichnung 10.

Es sind die Startfunktionen für  $t_2 \in \mathbb{N}$  mit  $-15 \leq t_2 \leq 14$  angegeben:

- für  $t_2 \leq 1$  liegen die Startfunktionen in  $V_2(-, +)$
- für  $t_2 \geq 2$  liegen die Startfunktionen in  $V_2(+, -)$ ,

was auch aus §4 folgt.

Die Norm der mit diesen Startfunktionen gegebenen Fehlerfunktionen ist auf ganz  $I$  ermittelt worden; sowohl in 7.2A wie in 7.2B erhält man bei  $t_2 = -10$  ein Minimum für die Norm der Fehlerfunktion.

In **Abschnitt 7.3** wird die Konstruktion einer Minimallösung für  $f$  bezüglich  $V_2$  durchgeführt.

Die Ergebnisse von Abschnitt 7.2 legen es nahe, Startfunktionen mit  $t_2 \leq 1.0$  zu verwenden; die Iteration von 7.3A bzw. 7.3B geht von der Startfunktion mit  $t_2 = -5.0$  von 7.2A bzw. 7.2B aus:

- in 7.3A erfolgt die Berechnung nach Fall 2
- in 7.3B wird gemäß Fall 1 mit  $|X| = 5$  verfahren, so daß man die lineare Approximation nach Schritt 2 durch Lösung eines linearen Gleichungssystems erhält.

Es zeigt sich, daß bei Verwendung der Startfunktionen mit

$$t_2 \in \{-7.0, -9.0, -11.0, -13.0, -15.0\}$$

ebenfalls 5 Iterationsschritte nötig sind, um die Genauigkeit zu erhalten, wie sie in 7.3A bzw. 7.3B erzielt worden ist; die Iterationen, die von den

Startfunktionen mit  $t_2 = -9.0$  oder  $t_2 = -11.0$  ausgehen, konvergieren also nicht schneller, was man (nachträglich) wohl erwarten würde.

Verwendet man wie in 7.3C und 7.3D die Startfunktionen mit  $t_2 = 0.0$ , so muß der Faktor C zur Verbesserung so klein gewählt werden, daß die Folgen schlecht konvergieren; dies ist unabhängig davon, ob nach Fall 2 wie in 7.3C oder nach Fall 1 wie in 7.3D gerechnet wird. Die Iteration von 7.3C ergibt erst mit dem 25. Iterationsschritt eine Lösung mit der Genauigkeit, wie sie in 7.3A gegeben ist.

Geht man von den Startfunktionen mit  $t_2 \geq 2.0$  aus, so erhält man Iterationen, die äußerst langsam konvergieren. Die Startfunktion mit  $t_2 = 7.0$  in 7.2A ergibt (nach Fall 2 berechnet) nach 180 Iterationsschritten eine Näherung mit den Parametern

$$\begin{array}{ll} a_1 = +0.191596 & t_1 = +2.514113 \\ a_2 = -0.007498 & t_2 = +5.072941 \end{array}$$

(Zeichnung 26)

In jedem Iterationsschritt ist der Faktor C kleiner als  $\frac{1}{4096}$ <sup>32</sup>. Da man hier nur vermuten kann, daß die beiden Frequenzen bei Fortsetzung der Iteration gegen einen gemeinsamen Grenzwert konvergieren, werden die Schwierigkeiten deutlich, die die Anwendung des Algorithmus bei der Approximation ohne Vorzeichenbeschränkung mit sich bringen kann.

Die Iterationen in  $V_2$  verlaufen bereits bei Bestimmung von C nach Schritt 3 stets in nur einer Vorzeichenklasse von  $V_2$ .

Diese Ergebnisse lassen es sinnvoll erscheinen, bei der Konstruktion einer Minimallösung nach Braess im allgemeinen mehrere Startfunktionen zu konstruieren und zunächst mehrere Iterationen nebeneinander durchzuführen. So kann man hoffen, eine Iteration zu erhalten, die mit vertretbarem Aufwand eine Lösung liefert. Hätte man sich bei der Approximation von f bezüglich  $V_2$  in  $V_2(-, +)$  auf die Iteration von 7.3C und in  $V_2(+, -)$  auf die oben angegebene Iteration beschränkt, so wäre trotz enormen Rechenaufwands lange ungeklärt geblieben, in welcher Vorzeichenklasse die Lösung enthalten ist.

---

<sup>32</sup>  $\frac{1}{4096} = 0.0002441, 4096 = 2^{-12}$

In **Abschnitt 7.4** wird in das Konvergenzverhalten dieses Verfahrens anhand der Funktion  $f(x) = (1 + x)^{-1}$  mit  $N = 3$  behandelt:

Für die Iterationen in 7.4A und 7.4B werden die Parameter der Startfunktionen mit dem Verfahren von Meinardus unter Verwendung der angegebenen Punktemengen ermittelt; es genügt die Angabe von  $x_0$  und  $x_5$ . Die Startfunktion von 7.4A sei  $E_1$ , die von 7.4B sei  $E_2$ ; es gilt also (vgl. Zeichnungen 27, 36)

$$4 \| f - E_2 \|_I < \| f - E_1 \|_I$$

Dennoch benötigt man von  $E_2$  ausgehend doppelt so viele Iterationsschritte wie in 7.3A, um die gleiche Genauigkeit zu erhalten.

Neben der Konstruktion der besten linearen Approximation nach Schritt 2 erfordert die Bestimmung des Faktor C in Schritt 3 den größten Teil des Rechenaufwandes. Beachtet man dies, dann wird an diesen Beispielen die Bedeutung der Startfunktion deutlich. Es zeigt sich, daß in der Regel der Faktor C im Verlauf der Iteration wächst, falls eine Minimallösung ermittelt wird. Um den Rechenaufwand möglichst klein zu halten, wird daher zur Ermittlung des Faktors C vorgeschlagen:

- Bei Beginn der Iteration verfähre man wie in Abschnitt 6.1 beschrieben. Bei den weiteren Iterationsschritten gehe man vom Faktor C des vorhergehenden Iterationsschrittes aus und prüfe, ob man hiermit eine bessere Approximation erhält.
- Gilt dies, dann bestimme man durch sukzessives Verdoppeln den gesuchten Faktor, den man nach Schritt 3 von 1 ausgehend durch (häufigeres) Halbieren erhält.
- Andernfalls hat man mit diesem Faktor nach Schritt 3 zu verfahren.

Die Iterationen werden dann abgebrochen, wenn die Parameter  $r_i$  der linearen Approximation einen kleineren Betrag als  $5 \times 10^{-10}$  haben. Quadratische Konvergenz ist dabei nur bei den letzten Iterationsschritten zu beobachten.

Diese Beispiele zeigen weiter, daß die Konvergenzgeschwindigkeit der ermittelten Folgen im allgemeinen unabhängig davon ist, ob nach Fall 1 oder Fall 2 verfahren wird.