

Prof. Dr. H. Völz

Z80 sortiert Texte im Nu

Eine handliche Z80-Routine sortiert Zeichenketten beliebiger und unterschiedlicher Länge in Windeseile. Groß- und Kleinschreibung, auch gemischt, sind zulässig. Selbst Umlaute und „ß“ können zusätzlich eingeordnet werden. Ein ideales Hilfsprogramm für Sachwortverzeichnisse und Register.

Das Sortieren von Texten, z. B. Sachwortverzeichnissen, Namens- oder Telefonlisten kommt immer wieder vor. Vielfach wird sogar behauptet, etwa 30 % der Textverarbeitung entfallen auf dieses Problem. Dennoch fehlt in den meisten Textverarbeitungssystemen ei-

ne solche Routine. Im wesentlichen werden nur Routinen in Basic, Pascal oder anderen Hochsprachen publiziert, und dies sogar relativ häufig. Beschrieben werden viele Methoden mit sehr unterschiedlicher Effektivität. Sie tauschen meist zwei falsch geordnete Wörter. Ver-

sucht man nun eine solche Routine in Maschinensprache zu übertragen, so steht man bei jedem Austausch etwa vor folgendem Problem:

- Die Worte sind meist unterschiedlich lang.
- Sollen sie ausgetauscht werden, muß zusätzlich der zwischen ihnen liegende Teil verschoben werden.
- Dies verlangt zuvor die Auslagerung des längeren Wortes.

Die Anzahl der Berechnungen für die Adressen und die Anzahl der Vertauschungs- und Verschiebeoperation im Speicher sind folglich je Tausch sehr umfangreich. Was nimmt es da Wunder, wenn auf diese Weise die Maschinensprache gegenüber Hochsprachen keinen entscheidenden Gewinn bringt, und das abgesehen vom hohen Programmieraufwand.

Im Z80-Befehlsvorrat existieren nun die sehr nützlichen Verschiebe- und Vergleichsbefehle LDIR, LDIR, CPDR und CPIR. Es liegt also nahe, einen speziellen Sortieralgorithmus auf dieser Basis zu entwickeln.

```

;Schnelle Sortieroutine fuer Z-80
;mit Beruecksichtigung von
;Gross- und Kleinschreibung
;
;H.Voelz 3.1.85
;HL:=BC, BC:=HL-BC
ADR1  PUSH  BC
      OR    A
      SBC  HL,BC
      PUSH HL
      POP  BC
      RET  HL
;
;Hier ist Start
SORT  LD    HL,(ENADR)
      LD    (EN1),HL
      DEC  HL
      XOR  A
      EN2SU DEC  HL
      CP   (HL)
      JR   NZ,EN2SU-w
      INC  HL
      NWORT LD    (EN2),HL
      XOR  A
      PUSH HL
      LD   DE,(STADR)
      OR  A
      SBC HL,DE
      POP HL
      RET Z
      DEC HL
      EN3SU DEC  HL
      CP   (HL)
      JR   NZ,EN3SU-w
      INC  HL
      LD   (EN3),HL
;Vergleichen
      LD   HL,(EN2)
      LD   DE,(EN3)
      VERGL LD   A,(HL)
      AND  5FH
      LD   B,A
      LD   A,(DE)
      AND  5FH
      CP   B
;Ergebnis (DE)-(HL)
      JR   Z,GLEICH-w
      VERGL2 JR   NC,TAUSHE-w ;(DE)>(HL)
;naechstes Wort
      LD   HL,(ENADR)
      LD   DE,(EN1)
      OR   A
      SBC HL,DE
      JR   Z,ALLES-w
      PUSH HL
      POP  BC
      XOR  A
      PUSH DE
      POP  HL
      CPIR
      LD   (EN1),HL
      JR   EN1P-w
;naechstes Wort suchen
      LD   HL,(EN3)
      LD   DE,(EN1)
      AND  5FH
      LD   B,A
      LD   A,(DE)
      AND  5FH
      CP   B
;Ergebnis (DE)-(HL)
      JR   Z,GLEI2-w
      JR   NC,WORTGE-w ;(EN1)>(EN3)
;naechstes Wort
      LD   HL,(ENADR)
      LD   DE,(EN1)
      OR   A
      SBC HL,DE
      JR   Z,ALLES-w
      PUSH HL
      POP  BC
      XOR  A
      PUSH DE
      POP  HL
      CPIR
      LD   (EN1),HL
      JR   EN1P-w
;naechstes Wort
      LD   HL,(EN2)
      LD   (EN1),HL
      LD   HL,(EN3)
      JR   NWORT-w
;gleiche Worte
      GLEICH CP   0
      JR   Z,WEITER-w
      WEIT  INC  HL
      INC  DE
      JR   VERGL-w
;Entscheidung bei 00 bzw. 20
      WEITER LD  A,(DE)
      CP   0
      JR   Z,NWORT-w
      CP   (HL)
      JR   Z,WEIT-w
;Umordnen; 1.Auslagern
      TAUSHE LD  HL,(EN2)
      LD   BC,(EN3)
      CALL ADR1
      PUSH BC
      LD   DE,(ENADR)
      LDIR
;EN1 suchen
      EN1P  LD   HL,(EN3)
      LD   DE,(EN1)
      VERGL1 LD  A,(HL)
      AND  5FH
      LD   B,A
      LD   A,(DE)
      AND  5FH
      CP   B
;Ergebnis (DE)-(HL)
      JR   Z,GLEI2-w
      JR   NC,WORTGE-w ;(EN1)>(EN3)
;naechstes Wort suchen
      LD   HL,(ENADR)
      LD   DE,(EN1)
      OR   A
      SBC HL,DE
      JR   Z,ALLES-w
      PUSH HL
      POP  BC
      XOR  A
      PUSH DE
      POP  HL
      CPIR
      LD   (EN1),HL
      JR   EN1P-w
;gleiche Worte
      GLEI2  CP   0
      JR   Z,WEIT2-w
      WEIT2 INC  HL
      INC  DE
      JR   VERGL1-w
;Entscheidung ob 00 oder 20
      WEIT2 LD  A,(DE)
      CP   0
      JR   Z,NWORT2-w
      CP   (HL)
      JR   Z,WEIT2-w
;Stelle gefunden, verschoben
      WORTGE LD  HL,(EN1)
      LD   BC,(EN2)
      CALL ADR1
      LD   DE,(EN3)
      LDIR
;zurueckholen
      POP  BC
      LD   HL,(ENADR)
      JR   NVEKT-w
;alles verschoben
      ALLES LD  HL,(ENADR)
      POP  BC
      ADD  HL,BC
      LD   BC,(EN2)
      CALL ADR1
      LD   DE,(EN3)
      NVEKT LDIR
      LD   HL,(EN3)
      PUSH HL
      XOR  A
      NVEKTS CP   (HL)
      INC  HL
      JR   NZ,NVEKTS-w
      LD   (EN1),HL
      POP  HL
      JP   NWORT
;
;Speicherplaetze
;STADR DEFW 0
;Enthaelt Adresse fuer Filebeginn
;weist auf 00H
ENADR  DEFW 0
;Enthaelt Adresse fuer Fileende
;weist auf Speicherstelle hinter 00H
EN1    DEFW 0
EN2    DEFW 0
EN3    DEFW 0
;

```

Bild 1. Unglaublich schnell arbeitet diese Sortieroutine in Z80-Maschinensprache

Das in Bild 1 abgedruckte Programm arbeitet im Gegensatz zu den meisten sonstigen Sortiertechniken nicht mit Austausch-, sondern nur mit Verschiebeoperationen.

Vershobenes Wort paßt genau in die Lücke

Es sei davon ausgegangen, daß die einzelnen Wörter hintereinander nur durch 00 getrennt im Speicher vorliegen. Warum 00 und nicht 0DH (Carriage Return) verwendet wird, ist später ersichtlich.

Ein Beispiel:

00 Wort 00 Wort 200 abends 00 Hut + 00 usw.

Es werden also bewußt Groß-/Kleinschreibung, Leerraum, Zahlen und Satzzeichen zugelassen. Allgemein gilt also die Anordnung von Bild 2. Die Adresse des Textbeginns (erstes ASCII-Zeichen) sei an der 2-Byte-Speicherstelle (STADR) abgelegt, das Ende (1 Byte hinter dem letzten 00) in der 2-Byte-Speicherstelle (ENADR). Der Vorgang des Sortierens ist stark vereinfacht in Bild 2 gezeigt. Vom Ende her werden benachbarte Worte (im Bild als Zahlen dargestellt) auf die richtige Reihenfolge getestet. Beim ersten falsch angeordneten (hier die 7) wird eine Marke gesetzt, beim Vergleichswort eine zweite. Jetzt wird rückwärts nach dem nächstliegenden größeren gesucht. Anschließend

wird das falsch liegende Wort an das Textende gelegt, der Text zwischen den Marken verschoben und das Wort an die entstandene, genau passende Lücke gelegt.

Von der Marke (ganz links) wird nun der Vergleichsvorgang benachbarter Wörter wiederholt, und falsch angeordnete Wörter werden wieder an die richtige Stelle gelegt.

Wenn dieser Vorgang an der Startadresse anlangt, ist der Text sortiert.

Es sei betont, daß der wirkliche Sortiervorgang erheblich komplizierter ist. Die Wörter müssen ASCII-Zeichen für ASCII-Zeichen verglichen werden. Das Ende 00 muß erkannt werden. Sonderoperationen sind notwendig, damit an den

Enden, d. h. bezüglich erster und letzter Wörter nichts passiert usw. Dies sind die Gründe, daß normalerweise nur Textketten genau formatierter Länge sortiert werden.

Sie würden aber zusätzlich oft sehr wertvollen Speicherplatz beanspruchen und sind, wie das beschriebene Programm zeigt, keineswegs notwendig.

Einen lauffähigen Speicherauszug (ab Adresse 0000H zeigt Bild 3. Bei der Kürze des Programms kann es auch leicht als Maschinenroutine von Hochsprachen aus mit CALL, USR oder ähnlichen Befehlen aufgerufen werden.

Für die Textsortierung ist das Unterprogramm SORT entscheidend. Es schaltet über die Maske 5FH die Bits für die Großschreibung und die Grafikzeichen zum Vergleich aus. Dadurch werden einmal die Klein- und Großbuchstaben gleichrangig behandelt, zum anderen ist es dadurch möglich, auch die Umlaute und „ß“ gleichrangig zu behandeln. Sie sind durch eine kurze Zusatzroutine nur auf die passenden Grafikzeichen zu transformieren und am Ende wieder zurückzuwandeln. Durch diese Maske entstehen aber Probleme, wenn CR = 0DH bestehen bleibt. Es wird deshalb entgegen üblichen Zeichenketten in 00 gewandelt. Dann entsteht nach der Maskierung mit 5FH ein Leerzeichen. Deshalb sind Teilroutinen zur Unterscheidung von 00 = Ende und 20H = Space notwendig.

Der Vorteil dieser Operation ist, daß somit auch alle Satzzeichen und Zahlen optimal angeordnet werden, ja selbst alle Steuerzeichen sind verwendbar.

Angefügte Wörter schnell eingereiht

Das Programm benötigt zum Sortieren im ungünstigsten Fall $n(n-1)/2$ Vergleiche und $n-1$ Verschiebungen. Diese Werte sehen im Vergleich zu den bekannten

ADDR	0	1	2	3	4	5	6	7	8	9	A	B	C	D	E	F
0000:	C5	B7	ED	42	E5	C1	E1	C9	2A	E0	00	22	E2	00	2B	AF
0010:	2B	BE	20	FC	23	22	E4	00	AF	E5	ED	5B	DE	00	B7	ED
0020:	52	E1	C8	2B	2B	BE	20	FC	23	22	E6	00	2A	E4	00	ED
0030:	5B	E6	00	7E	E6	5F	47	1A	E6	5F	B8	28	0D	30	1B	2A
0040:	E4	00	22	E2	00	2A	E6	00	18	CB	FE	00	28	04	23	13
0050:	18	E1	1A	FE	00	28	E8	BE	28	F4	2A	E4	00	ED	4B	E6
0060:	00	CD	00	00	C5	ED	5B	E0	00	ED	B0	2A	E6	00	ED	5B
0070:	E2	00	7E	E6	5F	47	1A	E6	5F	B8	28	1A	30	28	2A	E0
0080:	00	ED	5B	E2	00	B7	ED	52	28	32	E5	C1	AF	D5	E1	ED
0090:	B1	22	E2	00	18	D5	FE	00	28	04	23	13	18	D4	1A	FE
00A0:	00	28	DB	BE	28	F4	2A	E2	00	ED	4B	E4	00	CD	00	00
00B0:	ED	5B	E6	00	ED	B0	C1	2A	E0	00	18	10	2A	E0	00	C1
00C0:	09	ED	4B	E4	00	CD	00	00	ED	5B	E6	00	ED	B0	2A	E6
00D0:	00	E5	AF	BE	23	20	FC	22	E2	00	E1	C3	15	00	00	00
00E0:	00	00	00	00	00	00	00	00								

Bild 3. Lauffähiger Maschinencode mit Startadresse 0000H

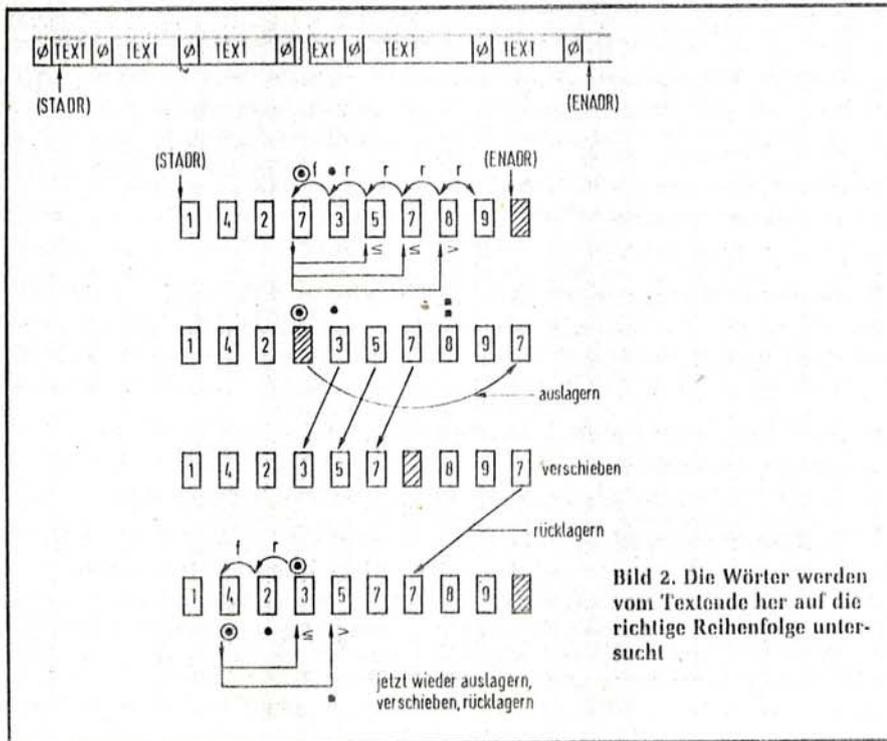


Bild 2. Die Wörter werden vom Textende her auf die richtige Reihenfolge untersucht

Gemessene Sortierzeiten mit einer 2-MHz-CPU

Wörter ¹⁾ *	200	500	1000	2000
Zeit/s	3	15	60	200
1) * Wortlänge max. 10 Zeichen				
Wortlänge ²⁾ Zeichen	5	10	20	40
Zeit/s	13	15	22	35
2) * Zahl der Wörter: 500				

sonstigen Werten sehr günstig aus. Deshalb wurden gerichtete Zeitmessungen mit Zufallswörtern aller ASCII-Zeichen von 20H bis 7FH und Zufallslängen (1 bis Nmax) durchgeführt. Dabei ergaben sich für eine mit 2 MHz betriebene CPU die in der Tabelle dargestellten Werte. Sie sind, verglichen mit den Werten aus der Literatur, beachtlich kurz.

In brauchbarer Näherung gilt für die Sortierzeit bei Zufallswörtern und 2 MHz die folgende Formel:

$$T/s = 2 \cdot 10^{-5} \cdot \sqrt{\text{Wortlänge}} \cdot (\text{Wortanzahl})^2$$

Es überwiegen hiernach also eindeutig die Vergleichsoperationen, und das, ob-

wohl sie bereits zeitoptimal gestaltet wurden.

Es sei aber betont, daß ein bereits sortiertes Feld extrem schnell erkannt wird. Wenn das Feld mit den 2000 Wörtern der maximalen Länge 10 sortiert ist, durchläuft der Algorithmus in 0,8 s (!) das Feld. Dies hat zur Folge, daß auch einzelne hinten (!) angefügte Wörter extrem schnell eingeordnet werden. Im wesentlichen sind also die Werte der Formel bereits Maximalzeiten. Dies bedeutet, daß der Algorithmus eigentlich alle normalen Sortieroperationen in vorbildlicher Weise realisiert.

Der Autor ist Bereichsleiter an der Akademie für Wissenschaften, Ostberlin, DDR.

Literatur

- [1] Wehringner, A.: Sortieren in Basic. *Elektronikschau* 11 (1981), Heft 4, Seite 34...39.
- [2] Kollmann, M.: Sortieren in Sekundenschnelle. *Chip* 1981, Heft 7, Seite 45...52.
- [3] Turalski, N., Hansohm, J.: Ein empirischer Vergleich von Sortieralgorithmen auf Microcomputern. *Angewandte Informatik* 1984, Heft 5, Seite 375...378.