Programmiertechnik 1

Unit 3: Informationsdarstellung

Ablauf

- Universalität binärer Daten
- Abtasttheorem
- ganze Zahlen, Binary Coded Decimals
- 1er Komplement
- 2er Komplement
- Gleitkommaformate
- ASCII, EBCDIC
- Unicode

Datenrepräsentation

- Daten
  - Aus Zeichen zusammengesetzte – Symbole
  - Zeichenmenge – Alphabet
  - Beispiele:
    - { 0, 1, 2, 3, ..., 9 } Alphabet der Dezimalziffern
    - {a, b, c, ..., A, B, C, ...} Alphabet der Buchstaben
    - {Frühling, Sommer, Herbst, Winter} Alphabet der Jahreszeiten
  - Frage: Welches ist das kleinste Alphabet?
  - Binärzahlen, bits – binary digits
    - Symbole aller denkbaren Alphabete lassen sich durch Gruppen von Binärzeichen ausdrücken.
    - Beispiel Kleinbuchstaben: $26 < 2^5$
      - a → 00000
      - b → 00001
      - c → 00010
      - ...

Morsecode
(Codierungen verschiedener Länge):
- a → . –
- b → – ...
- c → – . – .
- d → – ..
- e → .

Universalität binärer Daten

- Zuordnungsvorschrift zwischen Alphabeten → Code
- Codierung eines Alphabets durch Binärzahlen → Binärcodierung
- Stetige Größen:
  - Rasterung, Diskretisierung
  - Bei genügend großem Wertebereich bleibt Fehler unter Wahrnehmungsgrenze

  → alles, was zählbar / meßbar ist, kann codiert werden

  → Alles, was codiert werden kann, kann der Rechner verarbeiten

  → Codierung im Rechner ist immer binär
- Wieviele Binärzeichen sind für die Darstellung eines Zeichens aus dem Alphabet nötig?

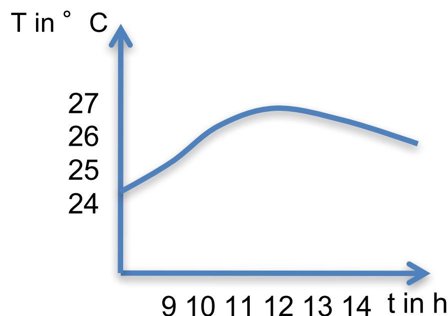

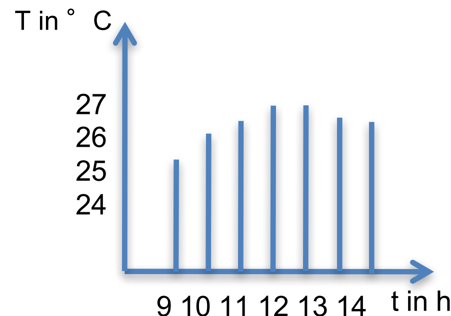

9h	25° C
10h	25,5° C
11h	26° C
12h	27° C
13h	26,5° C
14h	26° C

Nyquist-Shannon-Abtasttheorem

- Grundlegendes Theorem der Nachrichtentechnik
- Theorie der maximalen Kanalkapazität
- Das Abtasttheorem besagt:
  - ein kontinuierliches, bandbegrenztes Signal
  - mit einer Minimalfrequenz von 0 Hz und einer Maximalfrequenz f_{max}

  → Tastet man dieses Signale mit einer Frequenz größer als $2 * f_{max}$ gleichförmig ab, so lässt sich aus dem zeitdiskreten Signal das Ursprungssignal rekonstruieren
    - Exakt (ohne Informationsverlust) – mit unendlich großem Aufwand (d.h. unendlich viele Abtastpunkten)
    - Beliebig genau approximiert – mit endlichem Aufwand
- Höhere Abtastfrequenz liefert keine zusätzlichen Informationen
  - Der Aufwand für Verarbeitung, Speicherung und Übertragung steigt jedoch
  - Analoger Tiefpassfilter u.U. einfacher

Zahlendarstellungen

- Darstellung als Text
  - Üblich, wenn überhaupt keine Berechnung stattfinden soll
  - „Die Regionalbahn 18671 fährt um 15:00 in Golm ab.“
  - Die Zahlen 18671, 15 und 0 werden als Textzeichen repräsentiert
  - Speicheraufwand: 1 Byte pro Dezimalziffer

- Variante: BCD (binary coded decimal)
  - Kodierung von 10 Ziffern: 4 Bit pro Ziffer
  - 2 Ziffern pro Byte

- Beispiel: 18671 kodiert als 0001 1000 0110 0111 0001 (Hex: 01 86 71)
  - effizienter als Textdarstellung (0,5B pro Ziffer)
  - leicht in Dezimaldarstellung umrechenbar
  - arithmetische Operationen aufwändiger in Hardware realisierbar

Dezimale Zahlendarstellung

- Binary-Coded Decimal (BCD) kann 0 bis 9 in 4 binären Bits darstellen.
- Die Arithmetik basiert auf Modulo-10-Rechnung.
  - Da 4 bit = 2^4 = 16 sind, werden bei der Addition Zahlen, die größer als 9 sind durch Addition von 6 justiert: 6 (= 0110), (16-10 = 6).
  - Kodierung des Vorzeichens: 1010 steht für "+" und 1011 für "-"
- Beispiel: 4739 + 1281 = 6020
  - in BCD-Code: 0100 0111 0011 1001 = 4739
    + 0001 0010 1000 0001 = 1281

    Zwischenresultat: (0101 1001 1011 1010)
  - Die Werte müssen angepasst werden indem man durchlaufend 0110 addiert:

```
0101 1001 1011 1010
               1 0110
     0101 1001 1100 0000
          1 0110
     0101 1010 0010 0000
        1 0110
     0110 0000 0010 0000 = 6020
```

6 0 2 0

Ganze Zahlen

- Binärdarstellung

- Ziel: Ausschöpfung aller Bitkombinationen
  - Mit N Bits sollen 2^N Zahlen repräsentiert werden
  - üblich: Zahlen von 0 .. 2^N-1 (nichtnegative Zahlen, *unsigned)*
  - Zahlen von -2^{N-1} .. 2^{N-1}-1 (ganze Zahlen, signed)
  - Darstellung reeller Zahlen wird später diskutiert

- Binärdarstellung: Bitfolgen werden im Binärsystem interpretiert
  - Bitfolge aus Null-Bits stellt die kleinste Zahl dar (0)
  - Bitfolge aus Eins-Bits stellt die größte Zahl dar (2^N-1)

Speicherung von Mehrbyte-Zahlen

- Bitpositionen innerhalb eines Bytes fest in Hardware verdrahtet
  - etwa: Bits 0 .. 7

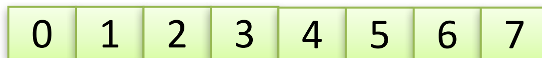

- Bitpositionen in Mehrbytezahlen abhängig von Prozessorarchitektur
- Little-endian: geringstwertiges Byte „zuerst“ im Speicher (auf kleinster Adresse)
  - Beispiel: Intel x86

18.03.2012

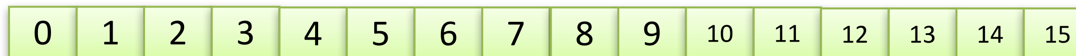

- Big-endian: geringstwertiges Byte „zuletzt im Speicher
  - Beispiel: Motorola/IBM PowerPC

2012/03/13

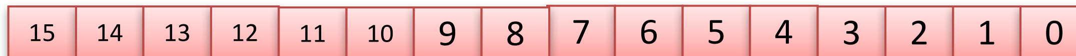

- Middle-endian:
  - Beispiel: DEC PDP-11

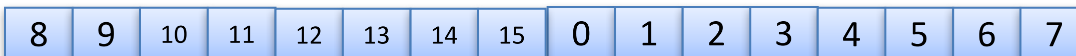

Arithmetische Operationen

- Addition analog dem Dezimalsystem
  - ```
        1 0 0 1 0
     + 1 0 0 1 1 1
     -------------
       1 1 1 0 0 1
    ```
- Allgemeiner:
  Rechenoperationen auf Basis von Assoziativ- und Distributivgesetzen
  - Beispiel: Multiplikation
    $a_2a_1a_0 * b_2b_1b_0$
  - $(4a_2+2a_1+a_0) * (4b_2+2b_1+b_0) =$
    $16a_2b_2$
    $+8(a_2b_1+a_1b_2)$
    $+4(a_2b_0+a_1b_1+a_0b_2)$
    $+2(a_1b_0+a_0b_1)$
    $+a_0b_0$
    ```

Überlauf

- Darstellbar sind Zahlen von 0.. 2^N-1
- Überlauf: Ergebnis ist größer als 2^N

- Beispiel: 11+8, 4-Bit-Zahlen

```
    1 0 1 1
+   1 0 0 0
  1 0 0 1 1
```

  – Ergebnis wieder in 4 Bit: 11+8 => 3

- Prozessor erkennt den Überlauf, zeigt ihn in „carry"-Bit an
  – abhängig von Programmiersprache wird carry-Bit verworfen oder führt zu einer Programmausnahme (exception)
- Verwerfen des Carry-Bits: Alle Operationen werden modulo 2^N ausgeführt

Vorzeichenbehaftete Zahlen

Drei Repräsentationen:

- Vorzeichen und Wert (sign and magnitude):

- 1'er-Komplement
  - $\overline{N} = (2^n-1) - N$ (Negation aller bits)
- 2'er Komplement
  - $\overline{N}^* = 2^n - N = (2^n-1) - N + 1 = \overline{N} + 1$ (Negation plus Eins)
  - Eindeutige Darstellung des Wertes 0
- Alle Rechner verwenden heute Zweier-Komplementdarstellung

Sign and Magnitude

- Repräsentation der Zahl durch zusätzliches Vorzeichenbit (0: Zahl ist nichtnegativ, 1: Zahl ist negativ)
  - bei N Bits stehen N-1 Bits für die Zahl zur Verfügung
  - Beispiel (4 Bit)
    - 0000 = +0, 0100 = +4, 1000 = -0, 1100 = -4

- Darstellbare Zahlen: - (2^{N-1}-1)... 2^{N-1}-1 (insgesamt 2^N-1 Zahlen)
  - negative Zahlen erkennt man am vordersten Bit
- Problem: Rechenoperationen sind kompliziert durchzuführen (Addition, Subtraktion: 4 verschiedene Fälle)
- Problem: zwei verschiedene Darstellungen der Zahl 0

Einer-Komplement

- negative Zahlen entstehen durch bitweise Negation aus den positiven Zahlen ($-x = \overline{x}$)
  - Beispiel (5 Bit) 01001 = 9, 10110 = -9

- Darstellbare Zahlen: $-2^{N-1}-1 \ldots 2^{N-1}-1$ (insgesamt 2^N-1 Zahlen)
  - negative Zahlen erkennt man am vordersten Bit
  - gleiche Probleme wie bei Vorzeichendarstellung
- Arithmethische Operationen sind schwierig,
  zwei Darstellungen der 0 (000000 = +0, 111111 = -0)

Zweier-Komplement

- Negative Zahl durch Subtraktion von 2^N ($-x = 2^N - x$)
- 2^N ist außerhalb des darstellbaren Bereichs; $2^N \equiv 0 \pmod{2^N}$
  - Alternative Bildungsregel: $-x = \overline{x} + 1$
  - Beispiel (4 Bit): 0011 = 3, -3 = $\overline{0011}$+1 = 1100+1 = 1101
  - negative Zahlen erkennt man am vordersten Bit
- Darstellbare Zahlen: $-2^{N-1} \ldots 2^{N-1}-1$ (insgesamt 2^N Zahlen)
- Beispiel: 8 Bit: darstellbar sind die Zahlen von -128...127

- Addition negativer Zahlen: entsprechend der Addition vorzeichenloser Zahlen
  - sowohl Überlauf als auch Unterlauf möglich
  - Subtraktion: Addition des negierten Werts (a-b = a+(-b))
- Problem: kleinste negative Zahl lässt sich nicht negieren

Basiswert-Darstellung

- Darstellung negativer Zahlen durch Basiswert (bias)
- Bits werden zunächst als nichtnegative Zahl interpretiert
  - danach wird ein Versatz V subtrahiert
  - darstellbarer Bereich: -V ... 2^N-V-1 (insgesamt 2^N Zahlen)

- Beispiel (4b, Versatz 7): 0000 = -7, 0111 = 0, 1000 = 1, 1111 = 8

- Problem: Vorzeichen der Zahl nicht leicht erkennbar
  - Problem: 0 ist nicht durch eine Bitfolge von Nullbits repräsentiert

- Wird verwendet. als Teil der Gleitkommadarstellung

Binäre Zahlendarstellung

Bitmuster $b_3b_2b_1b_0$	Vorzeichen und Wert	Wert	
		1'er Komplement	2'er Komplement
0111	+7	+7	+7
0110	+6	+6	+6
0101	+5	+5	+5
0100	+4	+4	+4
0011	+3	+3	+3
0010	+2	+2	+2
0001	+1	+1	+1
0000	0	+0	+0
1000	-0	-7	-8
1001	-1	-6	-7
1010	-2	-5	-6
1011	-3	-4	-5
1100	-4	-3	-4
1101	-5	-2	-3
1110	-6	-1	-2
1111	-7	-0	-1

Übliche Wertebereiche

- Größe von Datentypen abhängig von Programmiersprache
  - C: sizeof(short) ≤ sizeof(int) ≤ sizeof(long) ≤ sizeof(long long)
  - Beispiel: gcc, Linux, x86: short=2B, int=4B, long long=8B
  - Java: plattformunabhängig: byte=1B, short=2B, int=4B, long=8B
- C Datentypen:
  - char (n = 8) -128..127
  - short (n = 16) -32768..32767
  - int, long (n = 32) $-2^{31}..2^{31}-1$
-2147483648.. 2147483647
  - long long (n = 64) $-2^{63}..2^{63}-1$
-9223372036854775808.. 9223372036854775807

→ Datentypen als programmiersprachliches Konzept verbergen die zugrundeliegende Rechnerarchitektur

→ Portabilität

Große Ganze Zahlen

- Idee: Aufhebung des Wertebereichs durch Verwendung einer variablen Anzahl Bytes
  - größerer Absolutwert $\Rightarrow$ mehr Bytes
- Wertebereich nur durch Hauptspeicher eingeschränkt
- Beispiele: BigInt in Java, long in Python
- arithmetische Operationen nicht durch Prozessor unterstützt

Reelle Zahlen

- überabzählbar unendlich viele reelle Zahlen von 0..1

  $\Rightarrow$ nur endlich viele Zahlen mit endlichem Speicher unterscheidbar
- Variante 1: Darstellung rationaler Zahlen durch Zähler und Nenner
  - etwa: Zähler ist ganze Zahl, Nenner ist natürliche Zahl
  - Problem: elementare Rechenoperationen führen leicht aus dem Bereich der darstellbaren Nenner heraus
- Variante 2: Darstellung mit festem Nenner (etwa: 100)
  - Festkommazahlen
  - arithmetische Operationen müssen auf nächste darstellbare Zahl runden
- Verbreitet in Finanzmathematik
  - Beispiel: Decimal in Java
- Variante 3: Gleitkommazahlen

Gleitkommazahlen

- Ziel: möglichst großes Intervall darstellbarer Zahlen, möglichst viele Nachkommastellen
  - aber nicht gleichzeitig: für „große“ Zahlen werden meist keine Nachkommastellen benötigt
  - tatsächliche Zahl wird durch Näherungswert ersetzt
- Gleitkommadarstellung heute meist nach IEEE-754 (IEC 60559:1989)
- Idee: feste Zahl signifikanter Stellen, mit Faktor skalierbar
  - negative Zahlen durch Vorzeichenbit repräsentiert
- IEEE-754 einfache Genauigkeit:

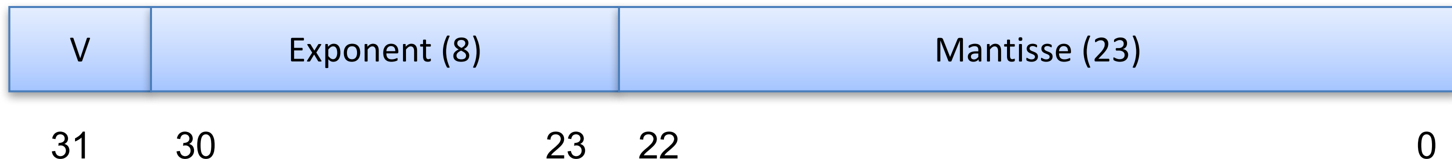

- IEEE-754 doppelte Genauigkeit:

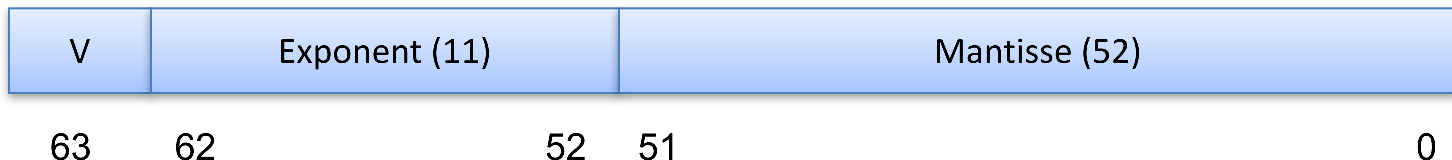

Gleitkommazahlen (contd.)

- jede Zahl hat 3 Bestandteile:
  - Vorzeichen V (1 Bit)
  - Mantisse M (signifikante Stellen)
  - Exponent E (für Faktor zur Basis 2), ganze Zahl in Binärdarstellung **mit Bias**
- Dargestellte Zahl ist $(-1)^V * M * 2^E$
- Normalisierung: Durch Wahl von E kann man die Mantisse immer in die Form $1.a_1a_2a_3a_4...$ bringen
  - Zur Speicherung von M genügt es, nur die Nachkommastellen zu speichern (normalisierte Zahlen)
- Exponent: Bias-Darstellung
  - Bias-Darstellung erlaubt einfacheres Vergleichen von zwei Gleitkommazahlen
  - Muss von gespeicherter Binärdarstellung des Exponenten subtrahiert werden
  - Spezialwerte für den Exponenten: minimaler Wert (alles 0) und maximaler Wert (alles 1)

Gleitkommazahlen (contd.)

- Übliche Formate: 32 Bit, 64 Bit
- 32-Bit-Darstellung (Java float, C float)
  - 1 Vorzeichenbit, 8 Bit Exponent (Bias 127), 23 Bit Mantisse
- Wertebereich normalisierter Zahlen
  - Mantisse immer 1 <= m < 2)
  - negativ: $-(2-2^{-23})x2^{127}$ ... -2^{-126}
  - positiv: 2^{-126} ... $(2-2^{-23})x2^{127}$
- 64-Bit-Darstellung (Java double) (doppelte Genauigkeit)
  - 1 Vorzeichenbit, 11 Bit Exponent (Bias 1023), 52 Bit Mantisse

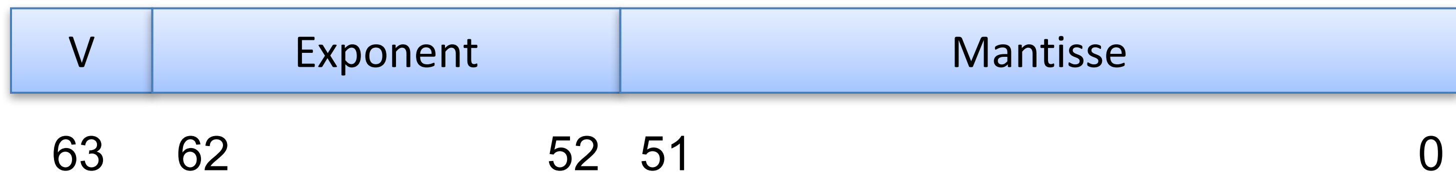

Gleitkommazahlen (contd.)

- Spezialfälle: Exponent 0000...000, 1111...111
- Zahl 0.0: Exponent 0, Mantisse 0
  - Vorzeichen 0: +0.0 (also: 0.0 wird durch 32/64 Nullbits dargestellt)
  - Vorzeichen 1: -0.0
- +/- Infinity: Exponent maximal (32-bit: FF16), Mantisse 0
  - „kanonische“ Rechenregeln für +/-∞
- Darstellung in Programmiersprachen uneinheitlich
  - Java: Float.POSITIVE_INFINITY
  - NaN (not-a-number): Exponent maximal, Mantisse ≠0
  - zur Anzeige von Bereichsverletzungen (etwa: Wurzel aus negativen Zahlen)
  - Berechnungen mit NaN als Eingabe liefern meist NaN als Ergebnis
- denormalisierte Zahlen: Exponent 0, Mantisse ≠0
  - füllen Lücke zwischen 0 und kleinster normalisierter Zahl
  - Interpretiert als $0.a_1a_2a_3a_4a_5$...

IEEE-754 - Betriebsmodi

- Rundungsmodus: Anpassung des Berechnungsergebnisses an „nächste“ darstellbare Zahl
  - towards zero
  - towards negative infinity
  - towards positive infinity
  - unbiased (zur nächstliegenden Zahl, bei Zahl in der Mitte zu der Zahl, deren letztes signifikantes Bit 0 ist)
- Fehlerbehandlung
  - Generierung von Ausnahmen
  - Generierung von Spezialwerten (infinity, NaN)
- „strikte“ Implementierung
  - Prozessorhardware weicht oft in Details von IEEE-754 ab
  - Javas Schlüsselwort `strictfp` erzwingt Konformität

Rundungseffekte

- Zahlen mit endlicher Darstellung im Dezimalsystem haben oft keine exakte Darstellung als Gleitkommazahl
  - Beispiel: 0,1 == 1/10 hat periodische Darstellung im Binärsystem 0.00011001100110011...
- Ausnahmen: Brüche, deren Nenner eine Zweierpotenz ist
  - 0,25 == ¼ == 0.01_2
- Gleitkommadarstellung sucht nächstliegende darstellbare Zahl
  - Beispiel: 0.1, float

Vorzeichen	Exponent	Mantisse	Dezimalwert
0	111011	1,0011E+22	0,0999999940..
0	111011	1,0011E+22	0,100000002

Weitere Zahlendarstellungen

- komplexe Zahlen: Darstellung als Paar (Realteil, Imaginärteil)
- Intervallarithmethik: Darstellung einer Zahl als Intervall
  - Berücksichtigung von Rundungen in vorigen Operationen

- „Preliminary Discussion of the logical designs of an Electronic Computing Instrument“, Burks, Goldstine, von Neumann, 1946:
  - Gleitkommazahlen seine nicht nötig / zu aufwendig;
  - Sie dienten nur als Skalierungsfaktor um den Zahlenbereich der Maschine einzuhalten;
  - Diese Skalierung könne der geschulte Benutzer (Mathematiker) aber von Hand vorab durchführen

Plain Text

- Abstraktion: Text wird durch eine Folge von Symbolen (Buchstaben, Zahlen, Interpunktion) dargestellt
  - Verzicht auf Informationen über Schriftart, Schriftgröße, Schriftfarbe, Seitenstruktur
  - Eingeschränkte Unterstützung für Zeilen- und Absatzstruktur (Zeilenumbrüche, Tabulatorzeichen)

- Alternativen:
  - „rich text“: zuzüglich typographischer Informationen
  - strukturierter Text: zuzüglich editorieller/semantischer Informationen (Kapitelstruktur, Querverweise, Auszeichnung von Zitaten, ...)

Codes für Zeichen – historischer Werdegang

- EBCDIC (Extended Binary Coded Decimal Interchange Code)
  - Eingeführt durch IBM, Lochkarten
  - Nicht alle Bitkombinationen besetzt
  - Buchstabenund Ziffern liegen dicht
- ASCII (American Standard Code for Information Interchange
  - 7-bit Code
  - Englisches Alphabet mit Steuerzeichen
  - Buchstaben und Ziffern liegen dicht
- ISO 8859
  - Erweiterung auf nationale Alphabete
- Unicode
  - Einheitlicher Code
  - Zwei-Byte-Code

ASCII

- American Standard Code for Information Interchange
  - 1963 erstmalig vorgeschlagen, 1968 normiert (ANSI X3.4-1968)
  - später auch (in Varianten) internationaler Standard
- ISO 646, CCITT International Alphabet #5
- international reference version, nationale Varianten
  - DIN 66003: @ vs. § , [vs. Ä, \ vs. Ö,] vs. Ü, …
- 7-Bit-Zeichensatz (128 Zeichen)
  - 32(34) Steuerzeichen, 96(94) druckbare Zeichen
  - heute immer in 8 Bit kodiert (MSB ist dann immer 0)
- systematisch strukturiert
  - Ziffern (0..9), Großbuchstaben (A..Z), Kleinbuchstaben (a..z) sind jeweils durchgehend nummeriert (48..57, 65..90, 97..122)
- Steuerzeichen: 0..31
  - üblich: 7 (BEL), 9 (TAB), 10 (NL), 13 (CR)

ASCII und ISO 8859

- American Standard Code for Information Interchange

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	NUL	SOH	STX	ETX	EOT	ENQ	ACK	BEL	BS	HAT	LF	VT	FF	CR	SO	SI
1	DLE	DC1	XON	DC3	XOF	NAK	SYN	ETB	CAN	EM	SUB	ESC	FS	GS	RS	US
2		!	"	#	$	%	&	'	(	)	*	+	,	-	.	/
3	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5	P	Q	R	S	T	U	V	W	X	Y	Z	[	\	]	^	_
6	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7	p	q	r	s	t	u	v	w	x	y	z	{	|	}	~	DEL

- Die Werte über 127 werden im ISO 8859 genutzt, um nationale Sonderzeichen darzustellen
  - Deutsche Umlaute, etc.

8-bit Zeichensätze

- Oft Erweiterungen von ASCII: weitere druckbare Zeichen im Bereich 128..255
  - ISO 8859: weitere Zeichen im Bereich 160..255 für Europa und den Nahen Osten
    - ISO-8859-1: Westeuropa (Latin-1)
    - ISO-8859-2: Mitteleuropa (Latin-2)
    - ISO-8859-3: Südeuropa (Latin-3)
    - ISO-8859-4: Nordeuropa (Latin-4)
    - ISO-8859-5: Kyrillisch
    - ISO-8859-6: Arabisch
    - ISO-8859-7: Griechisch
    - ISO-8859-8: Hebräisch
    - ISO-8859-9: Türkisch (Latin-5; Austausch der isländischen Zeichen mit türkischen)
    - ISO-8859-10: Nordisch (Latin-6; Latin 4 + Inuit, Nicht-Skolt Sami)
    - ISO-8859-11 (1999): Thai
    - ISO-8859-13: Ostseeraum (Latin-7)
    - ISO-8859-14: Keltisch (Latin-8)
    - ISO-8859-15: Westeuropa (Latin-9, Latin-1 ohne Bruchzeichen, plus €, Š, Ž, Œ, Ÿ)
    - ISO-8859-16: Europa (Latin-10, Verzicht auf Symbole zugunsten von Buchstaben)

Andere Zeichensätze

- Viele proprietäre 8-Bit-Zeichensätze:
  - IBM-Codepages (z.B. CP437)
  - Windows-Codepages (z.B. windows-1252)
  - Mac-Zeichensätze (z.B. mac-roman)
  - Auch EBCDIC; heute nur noch für Großrechner im Einsatz
- Mehrbytezeichensätze: ein oder zwei Bytes pro Zeichen
  - Chinesisch: Big5 (traditional Chinese), GB-2312 (simplified Chinese)
  - Japanisch: JIS 0208, JIS 0212
  - Koreanisch, Vietnamesisch
- Standards zur Kombination von Kodierungen: ISO-2022
  - z.B. iso-2022-jp (RFC 1554): kombiniert ASCII, JIS X 0208-1978, GB2312-1980, …

Unicode

- Problem: Verschiedene Sprachen benutzen unterschiedliche Alphabete
- Lösungsidee:
  Eindeutige Codierung für jedes Zeichen, unabhängig von der Plattform, dem Programm oder der Sprache

- Unicode als „Über"-Alphabet
- Ursprünglich 16 bit-Zeichensatz, heute 31 bit-Zeichensatz
  - Mit $17*2^{16}$ Zeichen
- Organisation von Alphabeten in „Blocks"
- Steuerzeichen, z.B. für Schreibrichtungen, Ligaturen
- Aktuelle Version: Unicode 6.0

Unicode (contd.)

- Unicode 6.0: ISO/IEC 10646-2003 (einschließlich Amendments 1 bis 8)
  - 109242 graphische Zeichen
  - 142 Formatierungszeichen
  - 65 Steuerzeichen
  - 865081 reservierte Zeichen
- Zeichensatz wird UCS-4 genannt
  - UCS-2 ist eine Teilmenge mit < 65536 Zeichen

Beispiele für Unicode

Georgisch (10A0..10FF)

	10A	10B	10C	10D	10E	10F
0	Ⴀ	Ⴐ	Ⴠ	ა	რ	ჰ
1	Ⴁ	Ⴑ	Ⴡ	ბ	ს	ჱ
2	Ⴂ	Ⴒ	Ⴢ	გ	ტ	ჲ
3	Ⴃ	Ⴓ	Ⴣ	დ	უ	ჳ
4	Ⴄ	Ⴔ	Ⴤ	ე	ფ	ჴ
5	Ⴅ	Ⴕ	Ⴥ	ვ	ქ	ჵ
6	Ⴆ	Ⴖ		ზ	ღ	ჶ
7	Ⴇ	Ⴗ		თ	ყ	
8	Ⴈ	Ⴘ		ი	შ	
9	Ⴉ	Ⴙ		კ	ჩ	
A	Ⴊ	Ⴚ		ლ	ც	
B	Ⴋ	Ⴛ		მ	ძ	჻
C	Ⴌ	Ⴜ		ნ	წ	
D	Ⴍ	Ⴝ		ო	ჭ	
E	Ⴎ	Ⴞ		პ	ხ	
F	Ⴏ	Ⴟ		ჟ	ჯ	

Pfeilsymbole (2190..21FF)

	219	21A	21B	21C	21D	21E	21F
0	←	↠	↰	⇀	⇐	⇠	⇰
1	↑	↡	↱	⇁	⇑	⇡	⇱
2	→	↢	↲	⇂	⇒	⇢	⇲
3	↓	↣	↳	⇃	⇓	⇣	⇳
4	↔	↤	↴	⇄	⇔	⇤	
5	↕	↥	↵	⇅	⇕	⇥	
6	↖	↦	↶	⇆	⇖	⇦	
7	↗	↧	↷	⇇	⇗	⇧	
8	↘	↨	↸	⇈	⇘	⇨	
9	↙	↩	↹	⇉	⇙	⇩	
A	↚	↪	↺	⇊	⇚	⇪	
B	↛	↫	↻	⇋	⇛	⇫	
C	↜	↬	↼	⇌	⇜	⇬	
D	↝	↭	↽	⇍	⇝	⇭	
E	↞	↮	↾	⇎	⇞	⇮	
F	↟	↯	↿	⇏	⇟	⇯	

Unicode-Prinzipien

- Universalität: Ein Zeichensatz für alle Schriftsysteme
  - Effizienz: Einfach zu verarbeiten
  - Zeichen, nicht Glyphen
  - Semantik: Alle Zeichen haben klare Bedeutung
  - Reiner Text: Unicode-Zeichen stellen nur Text dar
  - Logische Ordnung: Reihenfolge im Speicher folgt der „logischen“ Ordnung
- Vereinheitlichung (unification): Doppelte Zeichen in verschiedenen Schriftsystemen werden nur einmal in Unicode aufgenommen
- Dynamische Komponierung: Neue Zeichen können durch Komposition aus bestehenden entstehen
- Zeichenäquivalenz: Vorkomponierte Zeichen sind „äquivalent“ zu dekomponierten Zeichenfolgen
- Konvertierbarkeit: Unicode kann verlustfrei in andere Zeichensätze konvertiert werden (und zurück)

Unicode-Zeichen

- haben stabilen Code (code point)
  - z.B. U+00DF
- haben stabilen Zeichennamen
  - z.B. LATIN SMALL LETTER SHARP S
- Unicode-Standard enthält Demo-Glyphen
  - z.B. „ß“
- Unicode-Datenbank gibt Zeicheneigenschaften an
  - z.B. „Letter, lower case“ (Ll)

UTF-8

- Kodierung von Unicode in Bytes: mehrere Bytes pro Zeichen
  - Variante 1: jedes Zeichen benötigt mehrere Bytes (UTF-16, UTF-32)
- Probleme: Rückwärtskompatibilität, Byte Order
  - Variante 2: Jedes Zeichen benötigt eine variable Zahl von Bytes
  - UTF-8: 1 bis 4 Bytes pro Zeichen
- Zeichen <128: 1 Byte (äquivalent zu ASCII)
- Nullbytefrei
- Jede Bytefolge unterliegt bestimmtem Muster, um die Dekodierung zu erleichtern

UTF-8 (contd.)

Bitmuster	Anzahl kodierter Zeichen	Bereich kodierter Zeichen
0xxxxxxx	128	0..7F
110xxxxx 10xxxxxx	2048	80..7FF
1110xxxx 10xxxxxx	65536	800..FFFF
11110xxx 10xxxxxx ...	2097152 (nur 1114112)	10000..10FFFF

Zeichenketten

- Kodierung von Zeichenfolgen: Verkettung der Kodierungen der einzelnen Zeichen
- Zeichenkette: engl. „character string“ oder einfach „string“
- Zwei Modi: Bytefolgen oder Zeichenfolgen
  - C, C++, (Python): Strings sind Folgen von Bytes; Interpretation der Bytes entsprechend dem Zeichensatz obliegt der Anwendung
  - Java, C#, (Python): Strings sind Folgen von Unicode-Zeichen; jedes Unicodezeichen ist intern durch mehrere Bytes repräsentiert

- Stringlänge: mehrere Repräsentationen
  - Datei: Stringende = Dateiende
  - C, C++: Stringende wird durch Null-Byte angezeigt
  - Pascal, Java, Python,...: Zusammen mit dem String wird die Länge gespeichert

Zusammenfassung

- Universalität binärer Daten
- Abtasttheorem
  → Erfassung stetiger Größen impliziert Ungenauigkeiten
- ganze Zahlen, Binary Coded Decimals
- 1er Komplement
- 2er Komplement
- Gleitkommaformate
  → Nur mit Festkomma-Formaten rechnet ein Computer „genau"
- ASCII, EBCDIC
- Unicode
  → Darstellung von „plain text" gelöst;
  Verarbeitung von Zeichenketten je nach Programmiersprache schwierig