


Signale und Logik (2)

Vereinfachte (Relais-/)Schalterdarstellung:

Trennung von Nutz- u. Schaltsignal macht Adressaten „anwählbar“:


Bei zwei möglichen Empfängern genügt ein Schalter, um einen der beiden zu wählen.



(Hier: Umwidmung des Verstärker-Relais für die Adressierung - in Wirklichkeit benötigen Verstärkung u. Zuschaltung getrennte Relais!)

Signale und Logik (2)

Zur getrennten Ansteuerung von 4 Empfängern werden 2 Schalter notwendig: (... und weiter?)



Benötigt werden Aussagen darüber, wie eine gegebene Anzahl unterscheidbarer Zustände (hier: Empfängerwahl) mit möglichst wenigen binären Elementen (hier: Schaltern) eindeutig darzustellen -zu „codieren“- ist.

Das ist Gegenstand der Informationstheorie.

Die Informationstheorie untersucht **Darstellung, Speicherung** und **Übertragung** von Information.

Anmerkungen:

- Im Vergleich zur (später entstandenen) Informatik überwiegen hier formal-theoretische Aspekte wie Wesen, Erhaltung oder Wiedergewinnung von Information.
- Die Informationstheorie bedient sich meist der Methoden der Wahrscheinlichkeitsrechnung und der mathematischen Statistik.

- Information benötigt zu ihrer Darstellung **Symbole** (=unterscheidbare physikalische Zustände).
Bsp.: ' * ' (auf Schreibmaschinen- oder Telefontastatur)
auch: Gesten, Körperhaltungen, Flaggenstellungen
- Ein oder mehrere Symbole werden als **Zeichen** mit eigener Bedeutung definiert (= vereinbart).
Bsp.: ' • — ' ('a' bei Morse) oder ' ; '
auch: Schrift-, Licht-, Hand-, Vogelzeichen
- Ein geschlossen verwendeter, geordneter, verbreiteter Vorrat von mindestens zwei Zeichen bildet ein **Alphabet**.
Bsp.: Griechisches Alphabet, lateinisches ABC,
American Standard Code for Information Interchange (ASCII)

Anmerkungen:

- Es gibt Zeichen, die sich aus Symbolen zusammensetzen: ‘?’ und ‘!’ bestehen z.B. aus je 2 Symbolen, von denen das jeweils obere allein bedeutungslos ist.
- Flaggenstellungen können Nachrichten durch Flaggenalphabet aber auch Geisteshaltungen u.ä. übermitteln („Halbmast“).
- Die Frage, ob ein Alphabet auch geordnet sein muß, wird in der Literatur widersprüchlich behandelt: Gehören die ungeordneten Satzzeichen (, . ;) zum ABC?
- Zur Bezeichnung 'Alphabet' gehört eine gewisse Standardisierung, Verbreitung oder Bekanntheit; insofern kann Code auch die Entsprechungen zwischen willkürlich ausgesuchten Zeichenmengen betreffen (vgl. Verschlüsselung).
- Am Morse-Bsp. wird deutlich, wie wichtig die Code-Wahl ist: ‘E’ ist im Englischen -wie im Dt.- der häufigste Buchstabe, deshalb im Morse-Alphabet der kürzeste.

Die eindeutige Zuordnung zwischen Alphabeten wird **Code**, ihr Einsatz **Codierung** genannt.

Anmerkungen:

- Codierungen sind nicht immer umkehrbar eindeutig!
Bsp.: Der Wechsel zwischen dt. Klein- u. Großbuchstaben:
 'Gießen' \Rightarrow 'GIESSEN'
Bsp.: Der Morse-Code ist umkehrbar eindeutig, weil jedes Zeichen mit einem Leerzeichen abgeschlossen wird:
 'Eis?' \Leftrightarrow '.- -..'
- Auch die Umsetzung abstrakter Information (Gedanken) in eine Sprache erfolgt durch Codierung; Programmiersprachen sind Gegenstand (u.a.) der Praktischen Informatik, menschliche Sprachen (u.a.) der Linguistik (vgl. Soziolinguistik: restringierter, elaborierter Code) -

- Häufig verwendete oder typische Zeichenfolgen (Zeichenketten) werden oft auch als neues Zeichen aufgefaßt. Das daraus hervorgehende neue Zeichen wird auch **Codewort** (auch Wort oder Superzeichen) genannt.

Bsp.: 'u', 'n', 'd', '&' sind Zeichen (keine Wörter); 'und' ist ein Zeichen oder (Code-) Wort.

- Innerhalb eines Codewortes dienen die Zeichen, die es bilden, als **Elemente** (bei Zahlen auch: **Stellen**).

Bsp.: Das (Zeichen oder) Wort '**BARBARA**' enthält 7 Elemente, aber nur 3 (Zeichen oder) Symbole. ▭

- Innerhalb eines Codes kann die Anzahl der Zeichen (Symbole) in einem Codewort variieren oder für alle Wörter gleich sein.

Bsp.: Im Morse-Code sind Zeichen ungleich lang, im ASCII-Code gleich lang:

Schriftzeichen	Morse	ASCII
e	•	0110 0101
?	•• – – ••	0011 1111

- Codes mit einem Zeichenvorrat von nur zwei Zeichen (z.B. 0 und 1) werden **Binärcodes** genannt. Sie sind technisch interessant, weil sie auch mit einem Schalter (Transistor) realisiert werden können.

Der Morse-Code ist als Binärcode nicht umkehrbar eindeutig!
(Daher: Einführung des Zwischenraums als drittes Zeichen) –

- Codes und Codierung bilden einen wichtigen Teil der Informationstheorie; denn sie sind eine grundlegende Voraussetzung für die maschinelle DV.
- **Optimal** werden Codes genannt, die je Zeichen möglichst viel Information verschlüsseln (=codieren). Dazu bedarf es einer Metrik für Information.

Beispiel:

Zwei Skatspieler sprechen sich ab: Bevor einer eine Karte spielt, kann er vom anderen ein Zeichen bekommen:

- Bierglas oben / unten anfassen:
besonders hohe / niedrige Karte spielen!
- Aus dem Bierglas trinken / nicht trinken:
Partner selbst kann / kann nicht zur Lage beitragen.
- Je „selbstverständlicher“ (wahrscheinlicher) ein Zeichen für die Spielsituation ist, umso weniger interessant ist es für den anderen (Information is data which is used in decision-making).
- Die Zeichen des Spielpartners „summieren sich“ zur Gesamtkommunikation.

- Der **Informationsgehalt** h einer Nachricht bzw. eines Zeichens x hängt von der Wahrscheinlichkeit $p(x)$ seines Auftretens ab: Je unwahrscheinlicher das Auftreten eines Zeichens x ist, desto höher ist sein Informationsgehalt:

$$h(x) = f(1/p(x))$$

(f : vorerst unbekannte Funktion)

- Für den Informationsgehalt des Empfangs mehrerer voneinander unabhängiger Zeichen folgt daraus:

- Es muß gelten (Wahrscheinlichkeit gleichzeitigen Auftretens):

$$h(xy\dots) = f(p(x)^{-1} \cdot p(y)^{-1} \cdot \dots)$$

- Anschauungshalber sollte außerdem gelten:

$$h(xy\dots) = h(x) + h(y) + \dots \quad \text{d.h.:}$$

$$f(p(x)^{-1} \cdot p(y)^{-1} \cdot \dots) = f(p(x)^{-1}) + f(p(y)^{-1}) + \dots$$

Zusammenfassung:

Forderungen an den Informationsgehalt h der Nachrichten x, y, \dots :

$$h(xy\dots) = f(p(x)^{-1} \cdot p(y)^{-1} \cdot \dots) = f(p(x)^{-1}) + f(p(y)^{-1}) + \dots = h(x) + h(y) + \dots$$

frei assoziiert:

$$\log(x \cdot y \cdot \dots) = \log x + \log y + \dots$$

Definition (C. Shannon):

Der **Informationsgehalt** h eines Zeichens x ist definiert als der Logarithmus dualis des Reziprokwertes der Wahrscheinlichkeit, mit der das Zeichen auftritt:

$$\begin{aligned} h(x) &= \text{Id} [1/p(x)] \\ &= - \text{Id} [p(x)] \end{aligned}$$

Definition: $\log_B Z = L \Leftrightarrow B^{\log_B Z} \equiv B^L = Z$

Speziell:

$$\lg Z \equiv \log_{10} Z$$

$$\ln Z \equiv \log_e Z$$

$$\text{ld } Z \equiv \log_2 Z$$

$$(\text{Def.}) \Rightarrow Z_1 \cdot Z_2 = B^{L_1} \cdot B^{L_2} = B^{L_1+L_2}$$

Interessante Regeln:

$\log (Z_1 \cdot Z_2) = \log (Z_1) + \log (Z_2)$	$\log (Z^E) = E \cdot \log Z$
$\log (Z_1 / Z_2) = \log (Z_1) - \log (Z_2)$	$\log (\sqrt[W]{Z}) = (\log Z) / W$

Wechsel der Logarithmenbasis:

$$Z = B_1^{\log_{B_1} Z}$$

$$\log_{B_2} Z = \log_{B_2} (B_1^{\log_{B_1} Z})$$

$$= \log_{B_1} Z \cdot \log_{B_2} B_1$$

$$\log_{B_1} Z = \log_{B_2} Z / \log_{B_2} B_1$$

Oft benötigte Umrechnungen:

$$\lg 10 = \ln e = \text{ld } 2 = 1$$

$$\lg 1 = \ln 1 = \text{ld } 1 = 0$$

$$\text{ld } (1/x) = -\text{ld } x \quad ; \quad \lg (1/x) = -\lg x$$

$$\lg (10^x) = \ln (e^x) = \text{ld } (2^x) = x$$

$$10^{\lg x} = e^{\ln x} = 2^{\text{ld } x} = x$$

$$\text{ld } x = \lg x / \lg 2 = \ln x / \ln 2$$

Aus der Definition des Informationsgehalts

$$h(x) = -\text{ld} [p(x)]$$

folgt:

Der Informationsgehalt einer aus mehreren (voneinander unabhängigen) Zeichen bestehenden **Sequenz** ist gleich der **Summe** der Informationsgehalte der einzelnen Zeichen:

$$h(xy\dots) = -\text{ld} [p(x) \cdot p(y) \cdot \dots]$$

$$= -\text{ld} [p(x)] - \text{ld} [p(y)] - \dots$$

$$= h(x) + h(y) + \dots$$

A blue-outlined callout box with a tail pointing towards the top-left, containing the text 'ursprüngliche Forderung'.

ursprüngliche Forderung

Was bedeutet: „Informationsgehalt von x ist eins“?

$$h(x) = -\text{Id} [p(x)] = \text{Id} [1/p(x)] = 1,$$

woraus folgt:

$$1/p(x) = 2^1 \text{ bzw. } p(x) = 1/2 ,$$

d.h.:

- Der Informationsgehalt der Antwort auf eine Frage, die nur zwei (gleich wahrscheinliche) Möglichkeiten zulässt, ist die Einheit des Informationsgehalts; sie wird **bit** genannt (**b**asic **i**ndissoluble **i**nformation **u**nit).
- Ein bit ist der Informationsgehalt eines Zeichens in einem binären Alphabet mit gleicher Auftretungswahrscheinlichkeit. Das binäre Alphabet kann aus den Wertepaaren bestehen: ja/nein; wahr/falsch; schwarz/weiß ; hell/dunkel etc. -

- Haben alle n Zeichen eines Zeichenvorrats die gleiche Auftretungswahrscheinlichkeit $p=1/n$, so beträgt d. Informationsgehalt jedes einzelnen Zeichens: $h = \text{Id} [1/p] = \text{Id} n = \lg n / \lg 2$

Beispiel:

Informationsgehalt jedes der 10 Dezimalzeichen:

$$h = \text{Id} 10 = \lg 10 / \lg 2 = 3,322 \text{ bit}$$

- Bei Zeichenvorräten mit unterschiedlich wahrscheinlichen Zeichen bezeichnet man als **mittleren Informationsgehalt** H die Summe der mit den individuellen Auftretungswahrscheinlichkeiten p_i ($\sum p_i=1$; $i=1, \dots, n$) gewichteten Informationsgehalte h_i der einzelnen Zeichen :

$$H = \sum (p_i \cdot h_i) = \sum (p_i \cdot \text{Id} [1/p_i]) = - \sum (p_i \cdot \text{Id} p_i)$$

Beispiel:

Untersuchungen ergeben für d. dt. Sprache $H \approx 4,15$ bit/Zeichen;
Berücksichtigung typischer Kombinationen („qu“, „ung“ etc.)
reduziert das auf $H \approx 1,6$ bit/Zeichen

Beispiel: Häufigkeit von Buchstaben im Deutschen




Bild: H.Breuer: „dtv-Atlas zur Informatik“, dtv 1995

Ist die Wahrscheinlichkeit für das Auftreten des Buchstabens E: $p(E)=0,147$ und die für H: $p(H)=0,045$, so ist der Informationsgehalt der Zeichenkette 'EHE' ¹⁾:

$$-\text{Id} (0,147 * 0,045 * 0,147) \text{ bit} \approx [-\lg (0,000972405) / \lg 2] \text{ bit} \\ \approx [3,012 / 0,30] \text{ bit} \approx 10,006 \text{ bit}$$


1) (Zeichenkette gebildet mit zufällig aus einem Text herausgegriffenen Zeichen) ↪

- Die Einheit zur binären Darstellung von Daten heißt **Bit** (**B**inary **d**igit). Ihr Inhalt wird meist mit 0 bzw. 1 codiert.
- Mit n Bit lassen sich 2^n Zustände darstellen.
- Es gibt nur ganzzahlige Bit – im Gegensatz zu bit.
- Zur Darstellung von n bit benötigt eine elektronische Rechananlage mindestens n Bit.
- Informationsgehalt wird in bit **berechnet**: Es gibt keine Instrumente zu seiner Messung.



Die technische Darstellung erfolgt u.a. mit Hilfe von:

- Ladung
 - 0 = ungeladen
 - 1 = geladen
- Spannung
 - 0 = 0 Volt
 - 1 = ca. 6 Volt
- Magnetisierung
 - 0 = gleichbleibende Magnetisierung
 - 1 = Magnetisierungswechsel
- Licht
 - 0 = kein Licht
 - 1 = Licht
- ...



- Aus bestimmten technischen Gründen wie:
 - Geschwindigkeit von Lese- und Schreiboperationen
 - Darstellungsmöglichkeit „häufiger“ Zeichen (z.B. Alphabet)
 - Darstellungsmöglichkeiten von Zahlen, etc.

werden in der Informatik oft Vielfache von 8-Bit-Gruppen verwendet (8Bit, 16Bit, ...)

Eine 8-Bit-Sequenz heißt ein **Byte**.

- Bestimmte 2er-Potenzen werden in der Informatik häufig als Maßzahlen (z.B. für Speichergrößen) verwendet:
 - 1 KByte = 2^{10} Byte = 1024 Byte (1 Kilobyte)
 - 1 Mbyte = $2^{10} \cdot 2^{10}$ Byte (1 Megabyte)
 - 1 Gbyte = $2^{10} \cdot 2^{10} \cdot 2^{10}$ Byte (1 Gigabyte)
 - 1 Tbyte = $2^{10} \cdot 2^{10} \cdot 2^{10} \cdot 2^{10}$ Byte (1 Terabyte)

- Eine Zeichenfolge zur Codierung eines bestimmten Informationsgehalts wird als **Wort** bezeichnet, die Anzahl der darin enthaltenen Zeichen als **Wortlänge**.
- Mit einer Wortlänge von **L** Zeichen, von denen jedes **B** unterscheidbare Zustände annehmen kann, lassen sich insg. **N** unterschiedliche Zustände codieren, mit

$$\mathbf{N} = \mathbf{B}^{\mathbf{L}} \quad (\mathbf{B} > 1 !)$$

Die Binärcodierung von n Zuständen benötigt eine Wortlänge von l Bit:

$$2^l \geq n \Rightarrow l \cdot \lg 2 \geq \lg n \Rightarrow l \geq \lg n \quad (\lg 2 = 1)$$

Beispiel:

Codierung der Himmelsrichtungen (N,O,S,W – d.h.: $n=4$)

$$I \geq \log_2 4 = \log_2 (2^2) = 2 * \log_2 2 \Rightarrow I \geq 2 \text{ Bit}$$

- Eine mögliche Codierung ist:

00 = Norden

01 = Osten

10 = Süden

11 = Westen

- Obige Codierung läßt sich in zwei Fragen umsetzen:

- Weht der Wind aus S bzw. W (ja / nein) ?

- Weht der Wind aus O bzw. W (ja / nein) ?

- Nimmt man noch die Zwischenrichtungen NO, SO, SW und NW hinzu, so können die 8 Zustände mit 3 Bit codiert werden

- **Redundanz** ist ein Maß für die Nicht-Nutzung der Möglichkeiten eines Codes bzw. Maß für den Anteil einer Nachricht, der keine Information enthält.
- Im Falle gleich wahrscheinlicher, gleich lang codierter Wörter (l binäre Zeichen [Bit]) ist die Redundanz r definiert als Differenz zwischen der Wortlänge und Informationsgehalt h [bit]:

$$r = l - h$$

Redundanz wird oft genutzt zur Erstellung prüfbarer und korrigierbarer Codierungen.

Ein Beispiel:

Die Binärcodierung eines Tripels (3 Zustände, 3 Spieler,...) benötigt eine Wortlänge von $l=2$ Bit; denn es ist gefordert:

$$2^l \geq 3 \Rightarrow \lg(2^l) \geq \lg 3 \Rightarrow l \cdot \lg 2 \geq \lg 3$$

($\lg 2=1$)

$$\Rightarrow l \geq \lg 3 = \lg 3 / \lg 2 = 0,477/0,301 = 1,585 \text{ Bit}$$

d.h., die kleinste ganze Zahl Bit, die ausreicht, ist 2.

Diese Codierung hat damit eine Redundanz von:

$$r = l - h = 2 - 1,585 = 0,415 \text{ bit}$$

(i.d.R.: $r < 1$!?) -

- **ASCII (American Standard Code for Information Interchange):**
 - 7 Bit / Zeichen;
 - erweiterte Version mit 8 Bit / Zeichen;
 - Breiteste Verwendung (Unix, MS-DOS, Programmiersprachen, ...)
- **ANSI-Code (American National Standards Institute):**
 - 8 Bit (=1 Byte) / Zeichen;
 - Positionen 32-127 wie bei ASCII (Buchstaben, Ziffern, Satzzeichen);
 - Verwendung in Windows95 ff. *
- **Unicode:**
 - 16 Bit (=2 Byte) / Zeichen;
 - Erweiterung des ASCII-Codes: Buchstaben und Symbole aus allen bekannten geschriebenen Sprachen der Welt
 - Verwendung ab Windows NT

American Standard Code for Information Interchange

@	NUL	000	T	DC4	020	(040	<	060	P	080	d	100	x	120
A	SOH	001	U	NAK	021)	041	=	061	Q	081	e	101	y	121
B	STX	002	V	SYN	022	*	042	>	062	R	082	f	102	z	122
C	ETX	003	W	ETB	023	+	043	?	063	S	083	g	103	{	123
D	EOT	004	X	CAN	024	,	044	@	064	T	084	h	104		124
E	ENQ	005	Y	EM	025	-	045	A	065	U	085	i	105	}	125
F	ACK	006	Z	SUB	026	.	046	B	066	V	086	j	106	~	126
G	BEL	007	[ESC	027	/	047	C	067	W	087	k	107	DEL	127
H	BS	008	\	FS	028	0	048	D	068	X	088	l	108		
I	HT	009]	GS	029	1	049	E	069	Y	089	m	109		
J	LF	010	^	RS	030	2	050	F	070	Z	090	n	110		
K	VT	011	_	US	031	3	051	G	071	[091	o	111		
L	FF	012	SP		032	4	052	H	072	\	092	p	112		
M	CR	013	!		033	5	053	I	073]	093	q	113		
N	SO	014	"		034	6	054	J	074	^	094	r	114		
O	SI	015	#		035	7	055	K	075	_	095	s	115		
P	DLE	016	\$		036	8	056	L	076	`	096	t	116		
Q	DC1	017	%		037	9	057	M	077	a	097	u	117		
R	DC2	018	&		038	:	058	N	078	b	098	v	118		
S	DC3	019	'		039	;	059	O	079	c	099	w	119		

Bedeutung der Sonderzeichen im ASCII-Code:

@	NUL	Null, or all zeros	R	DC2	DeviceControl2
A	SOH	StartHeading	S	DC3	DeviceControl3(XOFF)
B	STX	StartText	T	DC4	DeviceControl4
C	ETX	EndText	U	NAK	Neg.Acknowledge
D	EOT	EndTransmission	V	SYM	SynchronousIdle
E	ENQ	Enquiry	W	ETB	EndTrans.Block
F	ACK	Acknowledge	X	CAN	Cancel
G	BEL	Bell	Y	EM	EndofMedium
H	BS	Backspace	Z	SUB	Substitute
I	HT	HorizontalTab	[ESC	Escape
J	LF	LineFeed	\	FS	FileSeparator
K	VT	VerticalTab]	GS	GroupSeparator
L	FF	FormFeed	^	RS	RecordSeparator
M	CR	CarriageReturn	_	US	UnitSeparator
N	SO	ShiftOut		SP	Space
O	SI	ShiftIn			
P	DLE	DataLinkEscape	?	DEL	Delete
Q	DC1	DeviceControl1(XON)			

Unicode:


- 1991: Version 1.0
- Sept. 2013: Version 6.3 (110.187 Zeichen)
- 2 Byte/Zeichen: Buchstaben und Symbole aus allen bekannten geschriebenen Sprachen der Welt
 - Amerika, Europa, Mittlerer Osten, Afrika, Indien, Asien, Pazifik
 - Symbole
 - Satzzeichen
 - Sonderzeichen
 - Währungszeichen ...
- Unterstützt max. 1.114.112 Zeichen
- Genormt in ISO/IEC 10646

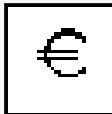


Unicode:

- 05F1 

- FA0E 

- 2603 

- 20AC 

- xxD0 - xxDF

	xxD	xxE	xxF		xxD	xxE	xxF
0				8			
1				9			
2				A			
3				B			
4				C			
5				D			
6				E			
7				F			