


Modul 1: Einführung und Wahrscheinlichkeitsrechnung



Informationstheorie

Dozent: Prof. Dr. M. Gross

E-mail: grossm@inf.ethz.ch


Assistenten: Daniel Cotting, Richard Keiser,
Martin Wicke, Cyril Flaig, Andrea
Francke, Jonas Waefler

Web Page: <http://graphics.ethz.ch>

- ❑ Zur Vorlesung
- ❑ Skript und Textbooks
- ❑ Elektronisches Material
- ❑ Tafel – Beispiele
- ❑ Übungsablauf - Gruppeneinteilung
- ❑ Testatbedingungen: 8 aus 9 Übungen
- ❑ Klausur: 2 Stunden
Hilfsmittel: keine
- ❑ Kein Midterm

Was ist neu

1. Alle früheren Tafelbeispiele nun auf Folien (nicht mehr mitschreiben)
2. Java-Applets zur Illustration der wichtigsten Algorithmen




Vorlesungsplan

Thema	Vorlesung	Uebung		
		Typ	Ausgabe	Abgabe
Einführung und Grundlagen	31.10.2005	Theorie	31.10.2005	07.11.2005
Stochastische Prozesse	07.11.2005	Theorie	07.11.2005	21.11.2005
Tag der Lehre	14.11.2005	keine		
Entropie	21.11.2005	Praxis	21.11.2005	28.12.2005
Bedingte Entropie	28.11.2005	Theorie	28.11.2005	05.12.2005
Informationsquellen	05.12.2005	Theorie	05.12.2005	12.12.2005
Codierung diskreter Quellen	12.12.2005	keine		
Optimalcodierung und Huffman Codes	19.12.2005	Theorie	19.12.2005	16.01.2006
Arithmetische Codierung/Intervalllängen/ LZ 1. Teil	09.01.2006	keine		
Arithmetische Codierung/Intervalllängen/ LZ 2. Teil	16.01.2006	Theorie	16.01.2006	23.01.2006
Binäre Kanäle	23.01.2006	Theorie	23.01.2006	30.01.2006
Codierungstheorem und Fehlerkorrektur	30.01.2006	Praxis*	30.01.2006	06.02.2006
Syndromcodierung/ Hamming Codes Polynomevaluationscodes	06.02.2006	keine		

- ❑ H. Klimant, R. Piotraschke, D. Schönfeld: *Informations- und Kommunikationstheorie*, 2. Auflage, Teubner, 2003.
- ❑ T. Cover, J. Thomas: *Elements of Information Theory*, John Wiley, 1991.
- ❑ U. Maurer: *Skript zur Vorlesung Information und Kommunikation, WS 2003/2004*.
- ❑ F. Reza: *An Introduction to Information Theory*, Dover Publications, 1994.
- ❑ H.D. Lüke: *Signalübertragung*, Springer, 6. Auflage, 1995.
- ❑ T. Bell, J. Cleary, I. Witten: *Text Compression*, Prentice Hall, 1990.
- ❑ A. Oppenheim, R. Schafer, J. Buck: *Zeitdiskrete Signalverarbeitung*, 2. Auflage Pearson, 2004.



- ❑ Einführung in die Informations- und Kodierungstheorie
- ❑ Quantifizierung von Information
- ❑ Abschätzung mathematischer Grenzen für die Kompression von Daten
- ❑ Verlustfreie Kodierungsverfahren
- ❑ Redundante, fehlerkorrigierende Kodierungsverfahren
- ❑ Praktische Beispiele

- Informationstheorie wurde von Claude Shannon begründet und 1948 publiziert
- “Mathematical theory of communication”, eine der bedeutendsten Theorien der Informatik



Begriff der Information

- ❑ **Information** bekommen wir, wenn wir etwas „Neues“ erfahren
- ❑ Altbekanntes stellt keine Information dar
- ❑ Information misst also den Neuheitsgrad einer empfangenen Meldung




Information ist also vom Kenntnisstand des Empfängers abhängig.

- ❑ Der **Empfänger** erhält dann u. U. verfälschte Information
- ❑ Fehler können durch Einfügen von Redundanz gezielt korrigiert werden
- ❑ „Weiss“ der Empfänger mehr, so muss der Sender weniger Information übertragen
- ❑ Offenbar ist der Begriff der Information eng mit den Begriff der Kommunikation verknüpft
- ❑ **Kommunikation** ist der Austausch von Information zwischen zwei oder mehreren Partnern

Übertragungsmodell

- ❑ Der **Sender** stellt eine Informationsquelle dar
- ❑ Diese kann **kontinuierlich** oder **diskret** sein
- ❑ Der Kanal kann ideal (verlustfrei), oder nicht-ideal (verlustbehaftet) sein
- ❑ In nicht-idealen Kanälen entstehen durch Störungen Fehler




- ❑ Ziel ist die Übertragung von Information mit möglichst wenig Informationseinheiten
 - Diese werden auch als **bits** (basic information units) bezeichnet.
- ❑ Verhältnis aus überschüssigen bits zu notwendigen bits ist die Redundanz
- ❑ Kompression zielt auf die Entfernung unnötiger, redundanter bits
- ❑ Kompression kann verlustfrei oder verlustbehaftet sein



bits werden grundsätzlich von Bits (binary digits) unterschieden.
Bei Binärcodierung gilt: bits = Bits

- ❑ Verlustbehaftete Bildkompression:



- ❑ Verlustlose Textkompression:
„Dies ist ein kleiner Text“
25 ASCII-Zeichen=200 Bits

- ❑ Gibt es eine untere Grenze für die minimale Anzahl von bits zur Übertragung einer bestimmten Information?
- ❑ Können wir den „Informationsgehalt“ einer Nachricht quantitativ erfassen?
- ❑ Wie ändert sich die Betrachtung, wenn wir die Verhältnisse im statistischen Mittel über einen langen Zeitraum betrachten?
- ❑ Gibt es Möglichkeiten, diese theoretischen unteren Schranken zu erreichen?

Beispiel: Würfeln

- ❑ Würfelexperiment mit 6 gleichwahrscheinlichen Ereignissen – diskret, binärcodiert
- ❑ Um ein Ereignis zu codieren, brauchen wir offenbar

$$\lceil \log_2 6 \rceil = 3 \text{ Bits}$$

- ❑ Für k Würfe benötigen wir demnach

$$\lceil k \log_2 6 \rceil \text{ Bits}$$

- ❑ Das heisst, 3 Würfe ($6^3 = 216$) können wir mit 8 Bits codieren
- ❑ Für $k \rightarrow \infty$ erhalten wir 2.585 Bits pro Ereignis

- Um eine Zufallsvariable mit N verschiedenen, gleichwahrscheinlichen Zuständen binär zu codieren, benötigen wir offenbar

$$\lceil \log_2 N \rceil \text{ Bits}$$

- Sei $p_N = 1/N$ die Wahrscheinlichkeit eines Zustandes, so benötigen wir also

$$\lceil -\log_2 p_N \rceil \text{ Bits}$$

- Die Zustandswahrscheinlichkeit spielt also bei der Codierung eine bedeutende Rolle

- Wir verallgemeinern dieses Konzept
- Sei Z eine Zufallsvariable mit N möglichen Zuständen $\{z_1, \dots, z_N\}$
- Sei p_i die Wahrscheinlichkeit, dass $Z=z_i$, so könnte man mit folgender Verallgemeinerung die Anzahl der benötigten Bits berechnen:

$$-\sum_{i=1}^N p_i \log_2 p_i$$

- Erklärung folgt später



Man denke über die Implikationen dieser Formel gut nach.

Beispiel: Textcodierung

Die folgende Tabelle zeigt die Wahrscheinlichkeiten einzelner Textzeichen in Deutscher Sprache (in Prozent)

a	b	c	d	e	f	g	h	i	j	k	l	m
6.44	1.93	2.68	4.83	17.5	1.65	3.06	4.23	7.73	0.27	1.46	3.49	2.58
n	o	p	q	r	s	t	u	v	w	x	y	z
9.84	2.9	0.96	0.02	7.54	6.83	6.13	4.17	0.94	1.48	0.04	0.08	1.14

- Mit Hilfe der vorherigen Formel berechnen wir die Anzahl von Bits zu Codierung eines einzelnen Zeichens:

$$-\sum_{i=1}^N p_i \log_2 p_i = 4.07$$

- Diese Grösse wird auch **Entropie** genannt.
- Sie stellt einen **statistischen Mittelwert** dar, d.h. im Mittel braucht man mindestens 4.07 Bits zur Codierung eines Zeichens in Deutscher Sprache.

- Ein **Wahrscheinlichkeitsmass** auf einer Menge Ω ist eine Funktion P von Untermengen von Ω auf \mathbb{R} , welche die folgenden Axiome erfüllt:

- $P(\Omega) = 1$
- Wenn $A \subset \Omega$, dann $P(A) \geq 0$
- Wenn A_1 und A_2 disjunkt, dann

$$P(A_1 \cup A_2) = P(A_1) + P(A_2)$$

- Allgemein (Summenformel):

$$P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i)$$

- Additionsgesetz

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

Beispiel: 2 Münzwürfe

- Praktische Berechnung von Wahrscheinlichkeiten durch Zählen:

$$P(A) = \frac{\text{Anzahl Ereignisse mit } A}{\text{Gesamtzahl Ereignisse}}$$

- $P(A)$: Kopf im ersten Wurf
- $P(B)$: Kopf im zweiten Wurf

$$\Omega = \{kk, kz, zk, zz\}$$

- $P(C)$: Kopf im ersten oder zweiten Wurf

$$\begin{aligned} P(C) &\neq P(A) + P(B), \\ P(C) &= P(A) + P(B) - P(A \cap B) \\ &= 0.5 + 0.5 - 0.25 \\ &= 0.75 \end{aligned}$$

Bedingte Wahrscheinlichkeit **ETH**

- Die bedingte Wahrscheinlichkeit ist die Wahrscheinlichkeit von A gegeben B :

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

- Daraus folgt das Multiplikationsgesetz

$$P(A \cap B) = P(A|B) P(B)$$

Beispiel: Urne (1)

- Urne mit 3 roten und einem blauen Ball.
Zwei mal ziehen ohne zurücklegen.
 - R_1 : rot im ersten Zug
 - R_2 : rot im zweiten Zug

$$\begin{aligned} P(R_1 \cap R_2) &= P(R_1) \cdot P(R_2 | R_1) \\ &= \frac{3}{4} \cdot \frac{2}{3} \\ &= \frac{1}{2} \end{aligned}$$

- Seien B_1, \dots, B_n so, dass

$$\bigcup_{i=1}^n B_i = \Omega, \text{ und } B_i \cap B_j = \emptyset, i \neq j$$

- Sowie $P(B_i) > 0$ für alle i . Dann gilt für ein beliebiges Ereignis A

$$P(A) = \sum_{i=1}^n P(A|B_i) P(B_i)$$

Beispiel: Urne (2)

- Wahrscheinlichkeit, rot im zweiten Zug zu ziehen.

$$\begin{aligned} P(R_2) &= P(R_2 | R_1) \cdot P(R_1) + P(R_2 | \bar{R}_1) \cdot P(\bar{R}_1) \\ &= \frac{2}{3} \cdot \frac{3}{4} + 1 \cdot \frac{1}{4} \\ &= \frac{3}{4} \end{aligned}$$

- Die Bayessche Regel ist von fundamentaler Bedeutung in der Wahrscheinlichkeitstheorie
- Seien B_1, \dots, B_n Ereignisse so, dass

$$\bigcup_{i=1}^n B_i = \Omega, \text{ und } B_i \cap B_j = \emptyset, i \neq j$$

- Sowie $P(B_i) > 0$ für alle i . Dann gilt:

$$P(B_j|A) = \frac{P(A|B_j)P(B_j)}{\sum_{i=1}^n P(A|B_i)P(B_i)} \quad P(B|A) = \frac{P(A|B)P(B)}{P(A)}$$

Beispiel: Bayes (1)

- Spam-Filter
 - + : Keyword in Mail
 - - : Keyword in Mail
 - S : Mail ist Spam
 - N : Mail ist kein Spam

- Statistische Auswertungen ergeben:
 - $P(+ | S) = 0.88$
 - $P(- | S) = 0.12$
 - $P(+ | N) = 0.14$
 - $P(- | N) = 0.86$

Beispiel: Bayes (2)

- Formel von Bayes angewandt:

$$P(N | +) = \frac{P(+ | N) \cdot P(N)}{P(+ | N) \cdot P(N) + P(+ | S) \cdot P(S)}$$

- $P(N) = 0.5$ und $P(S) = 0.5$

$$P(N | +) = \frac{0.14 \cdot 0.5}{0.14 \cdot 0.5 + 0.88 \cdot 0.5} \approx 0.13$$

- Eine Zufallsvariable X ist im Wesentlichen eine Zufallszahl
- Sie kann entweder **kontinuierlich** oder **diskret** sein
- Diskrete Zufallsvariablen nehmen nur endlich viele, oder unendlich viele, aber abzählbare Zustände an!

- **Beispiel: Der Würfelwurf als Zufallsvariable X mit Werten 1,2,3,4,5,6**

- Die Wahrscheinlichkeit auf einer (diskreten) Zufallsvariable wird wie folgt definiert:

Seien x_1, x_2, \dots die möglichen Werte von X , dann ist die Funktion $p(x_j) = P(X=x_j)$ die Häufigkeitsfunktion (frequency function)


- Es gilt:
$$\sum_{i=1}^n p(x_i) = 1$$

- Zwei Zufallsvariablen X und Y sind **unabhängig**, wenn

$$P(X = x_i, Y = y_i) = P(X = x_i)P(Y = y_i)$$

- Zufallsvariablen sind oft charakteristisch verteilt
- Eine bekannte Funktion ist die Binomialverteilung

$$\binom{n}{k} p^k (1-p)^{n-k}$$



- Ebenso kann man die gemeinsame Wahrscheinlichkeitsverteilung mehrerer Zufallsvariablen untersuchen
- Die Verbundwahrscheinlichkeit von X und Y

$$p(x_i, y_i) = P(X = x_i, Y = y_i)$$

oder

$$p(x_1 \cdots x_n) = \prod_{i=1}^n P(X = x_i)$$

- Notation:

$$p_X(x_i) = P(X = x_i)$$

- Die Wahrscheinlichkeit eines Zustandes x von X kann durch **Marginalisierung** (Summation) aus Verbundwahrscheinlichkeit berechnet werden

$$p_X(x) = \sum_i p(x, y_i)$$

- Für m Zufallsvariablen gilt entsprechend

$$p_{X_1}(x_1) = \sum_{x_2 \dots x_m} p(x_1 \dots x_m)$$

$$p_{X_1 X_2}(x_1, x_2) = \sum_{x_3 \dots x_m} p(x_1 \dots x_m)$$

- Die bedingte Verteilung von X und Y
- Die Verbundwahrscheinlichkeit von X und Y ist

$$P(X = x_i | Y = y_i) = \frac{P(X = x_i, Y = y_i)}{P(Y = y_i)} = \frac{p_{XY}(x_i, y_i)}{p_Y(y_i)}$$

- Vergleiche mit Bayesschem Gesetz!
- Oder auch $p_{XY}(x, y) = p_{X|Y}(x|y) p_Y(y)$
- Marginalisierung

$$p_X(x) = \sum_y p_{X|Y}(x|y) p_Y(y)$$

Beispiel: Bed. Verteilungen

- Gegeben X und Y mit Verteilungen:

$x \backslash y$	0	1	2	3
0	1/8	2/8	1/8	0
1	0	1/8	2/8	1/8

- Marginalisierung:
$$P_Y(1) = P_{XY}(0,1) + P_{XY}(1,1)$$
$$= \frac{2}{8} + \frac{1}{8} = \frac{3}{8}$$

- $$P_{X|Y}(0|1) = \frac{P_{XY}(0,1)}{P_Y(1)} = \frac{2/8}{3/8} = \frac{2}{3}$$

- $$P_{X|Y}(1|1) = \frac{P_{XY}(1,1)}{P_Y(1)} = \frac{1/8}{3/8} = \frac{1}{3}$$