

Kolmogoroffkomplexität

Teil 3

Informationstheorie und Kodierung

Informationstheorie

Information ist ...

- Δ Wahlfreiheit beim Sender
- Δ Unbestimmtheit beim Empfänger

Information ist nicht ...

- Länge der Nachricht an sich
- Aussage (Semantik) der Nachricht an sich

Kodierung

Wie kompakt können wir

Nachrichten theoretisch fassen?

- Idee: messen Wahlfreiheit / Unbestimmtheit

Wie kommen wir diesem Grenzwert möglichst nahe?

- optimale Codes

Wie können wir Nachrichten *noch* kürzer fassen?

- verlustbehaftete Kompression (siehe Buch)

Beispiel

heute gabs kartoffeln und l lachs, lamm, leber, labskaus, letscho

heute gabs kartoffeln und q quark

$$I(p(q)) > I(p(l))$$

Formalisierung I

sei X Zufallsvariable über alle Buchstaben in A
und $x=X(\omega)$ der nächste Buchstabe in der Leitung

je geringer seine Wahrscheinlichkeit $p(x)$,
desto stärker sinkt die Unbestimmtheit / Wahlfreiheit,
desto höher ist der Informationsgehalt

$$I(p(x)) := \log\left(\frac{1}{p(x)}\right) \quad \text{P.S.: } \log = \log_2$$

Einheit: Bit

Beispiel

$$I(p) := \log\left(\frac{1}{p(x)}\right)$$

heute gabs kartoffeln und l lachs, lamm, leber, labskaus, letscho

heute gabs kartoffeln und q quark

$$I(1) = 0$$

$$I(0,5) = 1$$

$$I(0,25) = 2$$

$$I(0,125) = 3$$

Formalisierung II

Entropie (Unordnung) ist

der erwartete Informationsgehalt des nächsten Zeichens

$$H(X) = \sum_{x \in A} p(x) \cdot I(p(x))$$

Einheit: Bit pro Zeichen

Beispiel

Versuch 1

a 00000

b 00001

c 00010

d 00011

e 00100

f 00101

g 00110

h 00111

...

optimal bei $p(a)=p(b)=\dots=1/32$

spiegelt nicht die

Häufigkeitsverteilung in

deutschen Texten wider

schlecht

Beispiel

Versuch 2

e 0

n 10

i 110

s 1110

r 11110

a 111110

t 1111110

d 11111110

...

optimal bei $p(e)=1/2$, $p(n)=1/4$, $p(i)=1/8$, ...

d.h. bei Wortlänge 6 und Satzlänge 11

nur alle vier Sätze ein d

und jeder zweite Buchstabe ein e

noch schlechter

Zwischending

Ziel: Abschätzung nach unten für die Länge der kodierten Nachricht. (als Referenz für mögliche Zwischendinger)

Annahme: kennen Länge der Nachricht k und genaue Häufigkeit der einzelnen Buchstaben

Ergebnis: müssen mind. $k \cdot H(X)$ Bit übertragen
(Beweis siehe nächste Folie)

Beweis

n: Anzahl verschiedener Buchstaben, k: Länge der Nachricht, k_i : abs. Häufigkeit von Buchstabe i

müssen mindestens $h(x) = \log\left(\frac{k!}{k_1! \cdot k_2! \cdot \dots \cdot k_n!}\right)$ Bit übertragen

$$h(x) = \log k! - \log k_1! - \dots - \log k_n!$$

$$\approx \log\left(\sqrt{2\pi k} \left(\frac{k}{e}\right)^k\right) - \log\left(\sqrt{2\pi k_1} \left(\frac{k_1}{e}\right)^{k_1}\right) - \dots - \log\left(\sqrt{2\pi k_n} \left(\frac{k_n}{e}\right)^{k_n}\right) \quad \text{stirlingsche Approximation:}$$

$$k! \approx \sqrt{2\pi k} \left(\frac{k}{e}\right)^k$$

$$\approx \log(\sqrt{2\pi k}) - \log(\sqrt{2\pi k_1}) - \dots - \log(\sqrt{2\pi k_n}) \\ + k \log k - k_1 \log k_1 - \dots - k_n \log k_n \\ - k \log e + k_1 \log e + \dots + k_n \log e$$

$$\approx \log(\sqrt{2\pi k}) - \log(\sqrt{2\pi k_1}) - \dots - \log(\sqrt{2\pi k_n}) \\ + k \log k - k_1 \log k_1 - \dots - k_n \log k_n$$

$$\geq k \log k - k_1 \log k_1 - \dots - k_n \log k_n \quad \leftarrow$$

aus Konkavität von $\sqrt{\quad}$ und \log folgt:
 $\log \sqrt{a+b} \leq \log \sqrt{a} + \log \sqrt{b}$

$$\geq \log k^k - \log k_1^{k_1} - \dots - \log k_n^{k_n}$$

$$\geq \log k^{k_1 + \dots + k_n} - \log k_1^{k_1} - \dots - \log k_n^{k_n}$$

$$\geq \log(k^{k_1} \cdot k^{k_2} \cdot \dots \cdot k^{k_n}) - \log k_1^{k_1} - \dots - \log k_n^{k_n}$$

$$\geq \log k^{k_1 + \dots + k_n} - \log k_1^{k_1} - \dots - \log k_n^{k_n}$$

$$\geq \sum (\log k^{k_i} - \log k_i^{k_i})$$

$$\geq \sum k_i (\log k - \log k_i)$$

$$\geq k \sum \frac{k_i}{k} (\log k - \log k_i)$$

$$\geq k \sum \frac{k_i}{k} \log \frac{k}{k_i}$$

$$\geq k \sum p_i \log \frac{1}{p_i}$$

$$\geq k \cdot H(X)$$

Shannon-Fano-Code

- sortiere Buchstaben absteigend nach Wahrscheinlichkeit

$$p_e = 0,3; p_n = 0,25; p_i = 0,2; p_s = 0,15; p_r = 0,1$$

- berechne kumulative Wahrscheinlichkeiten in binär

$$P_e = 0; P_n = 0,3; P_i = 0,55; P_s = 0,75; P_r = 0,9 \quad \leftarrow \text{dezimal}$$

$$P_e = 0; P_n = 0,0100\dots; P_i = 0,1000\dots; P_s = 0,11; P_r = 0,1110\dots \quad \swarrow \text{binär}$$

- berechne aufgerundete Informationsgehalte

$$I'(p_e) = 2; I'(p_n) = 2; I'(p_i) = 3; I'(p_s) = 3; I'(p_r) = 4 \quad I(p) := \log\left(\frac{1}{p(x)}\right)$$

- schneide kumul. Wahrschk. entspr. Informationsgehalt ab

$$E(e) = 00; E(n) = 01; E(i) = 10\cancel{0}; E(s) = 110; E(r) = 111\cancel{0}$$

Shannon-Fano-Code

$$\begin{aligned}\sum_x p_x \cdot |E(x)| &= \sum_x p_x \cdot l'(p_x) \\ &< \sum_x p_x \cdot (l(p_x) + 1) \\ &< 1 + \sum_x p_x \cdot l(p_x) \\ &< 1 + H(X)\end{aligned}$$

erwartete Länge des nächsten Codewortes weicht
um max. 1 von Entropie der Nachrichtenquelle ab
asymptotisch gut

per Konstruktion präfixfrei

Quellenkodierungssatz

noiseless coding theorem

\forall Wahrscheinlichkeitsmassenfunktion p auf Quellwörtern

\exists präfixfreier Code, so dass

durchschnittliche Codewortlänge $\sum_x p_x \cdot |E(x)|$ ungefähr
gleich der Entropie der Nachrichtenquelle $H(X) = \sum_x p_x \cdot \log\left(\frac{1}{p_x}\right)$

Beweis:

- können Shannon-Fano-Code konstruieren mit $\sum_x p_x \cdot |E(x)| < 1 + H(X)$ (Folie 13)
- können keinen Code konstruieren mit $\sum_x p_x \cdot |E(x)| < H(X)$ (Folie 11)

kraftsche Ungleichung

\exists präfixfreier Code mit Codewortlängen l_1, l_2, \dots

gdw.

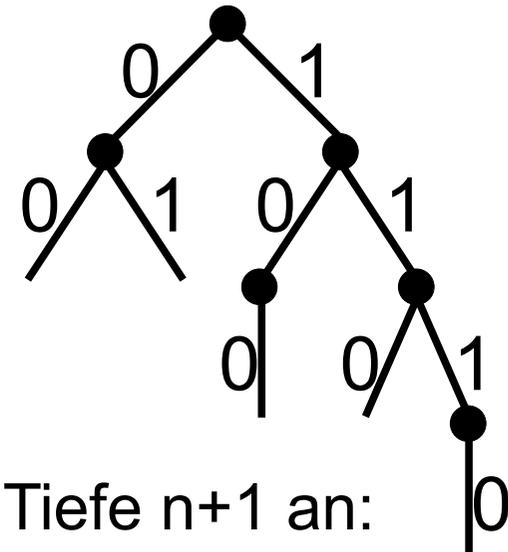
$$\sum_i 2^{-l_i} \leq 1$$

Beweis \Rightarrow

- PFC als Baum mit Codewörtern in Blättern
- Baum mit Tiefe 0: $2^{-0} = 1$
- hänge an Blatt mit Tiefe n max. 2 Blätter mit Tiefe $n+1$ an:
 - Blatt wird zu innerem Knoten: ziehe 2^{-n} ab
 - max. 2 Blätter dazu: addiere max. $2 \cdot 2^{-(n+1)} = 2^{-n}$

Beweis \Leftarrow

- gibt maximal 2^n Knoten mit Tiefe n
- ein Blatt mit Tiefe l_i verbraucht deshalb 2^{-l_i} der Breite des Baumes
- lt. Vorausstzg. verbrauchen alle Blätter max. 1 der Breite des Baumes
- also ist ein Baum mit Blättern der Tiefe l_i konstruierbar



kraftsche Ungleichung

daraus folgt:

- wenn $\sum_i 2^{-l_i} < 1$, werden Codewörter verschwendet
(der Baum ist nicht voll, *unvollständiger Code*)

aber daraus folgt nicht:

- wenn für gegebenen Code $\sum_i 2^{-l_i} \leq 1$ gilt, ist es ein PFC
(stimmt ja auch nicht)

kraftsche Ungleichung gilt nicht nur für PFC,
sondern für alle eindeutig dekodierbaren Codes

(Beweis nächste Folie)

daraus folgt:

- jeder EDC kann durch einen PFC mit
gleichen Codewortlängen ersetzt werden

Beweis

Voraussetzung: $l_1 \dots l_n$ sind die Längen der n Codewörter eines EDC

zu zeigen: es gilt die Kraftsche Ungleichung $\sum_{i=1}^n 2^{-l_i} \leq 1$

setzen die linke Seite ins Quadrat und erhalten:

$$\begin{aligned} \left(\sum_{i=1}^n 2^{-l_i} \right)^2 &= (2^{-l_1} + \dots + 2^{-l_n})^2 \\ &= 2^{-l_1} \cdot 2^{-l_1} + 2^{-l_1} \cdot 2^{-l_2} + \dots + 2^{-l_n} \cdot 2^{-l_n} \\ &= 2^{-l_1-l_1} + 2^{-l_1-l_2} + \dots + 2^{-l_n-l_n} \\ &= m_1 \cdot 2^{-1} + m_2 \cdot 2^{-2} + \dots + m_{2l} \cdot 2^{-2l} \quad \text{mit } l = \max\{l_i \mid i = 1 \dots n\} \text{ und } m_i = \text{Anzahl Paare } (l_a, l_b) \text{ mit } l_a + l_b = i \\ &= \sum_{i=1}^{2l} m_i \cdot 2^{-i} \end{aligned}$$

analoge Überlegungen führen zu:

$$\begin{aligned} \left(\sum_{i=1}^n 2^{-l_i} \right)^r &= \sum_{i=1}^{r \cdot l} m_i \cdot 2^{-i} \\ &\leq \sum_{i=1}^{r \cdot l} 2^i \cdot 2^{-i} \quad (\text{nach Voraussetzung: } m_i \leq |\{0,1\}^i| = 2^i \text{ (für jede Bitkette höchstens ein Codewortpaar)}) \\ &\leq \sum_{i=1}^{r \cdot l} 1 \\ &\leq r \cdot l \end{aligned}$$

setzen $r \rightarrow \infty$

$$\begin{aligned} \sum_{i=1}^n 2^{-l_i} &\leq \sqrt[r]{r \cdot l} \\ &\leq 1 \end{aligned}$$

optimale Codes

Quellenkodierungssatz und Kraftsche Ungleichung liefern Konstruktion eines relativ guten PFC

„gut“ = Erwartungswert der Codewortlänge ist klein

Further Reading: Huffman-Code liefert Konstruktion eines besten (optimalen) PFC

A ist optimaler Code (PFC, EDC) $\Leftrightarrow \nexists$ Code (PFC, EDC) B, sodass $\sum_x p_x |B(x)| < \sum_x p_x |A(x)|$

Achtung: vollständig \neq optimal

universelle Codes

kodieren die Nachrichtenquelle

in Unkenntnis der Wahrscheinlichkeitsverteilung p ,

sodass die erwartete Codewortlänge

linear von der Entropie abhängt

$$\sum_x p_x \cdot |E(x)| \leq c \cdot \max\{H(X), 1\}$$

sind zusätzlich *asymptotisch optimal*, wenn

$$\sum_x p_x \cdot |E(x)| \leq f(H(X)) \cdot \max\{H(X), 1\} \text{ mit } \lim_{H(X) \rightarrow \infty} f(H(X)) = 1$$

Beispiel

$A: n \rightarrow \bar{n}$

ist universell

(da die Codewortlänge nur linear mit der Entropie zunimmt)

$B: n \rightarrow \overline{l(n)}n$

ist universell

und asymptotisch optimal

(da die Codewortlänge nur logarithmisch mit der Entropie zunimmt)

Fragen?

- Ming Li, Paul Vitány.

An Introduction to Kolmogorov Complexity and Its Applications.

Springer. 2008

- Claude Shannon.

A Mathematical Theory of Communication. 1948

<http://plan9.bell-labs.com/cm/ms/what/shannonday/shannon1948.pdf>

- Alexander May.

Diskrete Mathematik 2.

Vorlesungsskript Ruhr-Universität Bochum. 2009

<http://www.cits.rub.de/lehre/dismath2ss09.html>

Glossar

complete code	vollständiger Code	abhängig	dependent
conditional	bedingt	abzählbar	countable
countable	abzählbar	bedingt	conditional
dependent	abhängig	Blockcode	fixed-length code
distribution	Verteilung	Definitionsbereich	domain
domain	Definitionsbereich	effizient	efficient
efficient	effizient	eindeutig	unique
event	Ereignis	Ereignis	event
fixed-length code	Blockcode	Ergebnis	sample
independent	unabhängig	gemeinsam	joint, mutual
joint	gemeinsam	gleich-	uniform
marginal	rand-	präfixfreier Code	prefix-code
mutual	gemeinsam	rand-	marginal
noiseless	rauschfrei	rauschfrei	noiseless
prefix-code	präfixfreier Code	überabzählbar	uncountable
random variable	Zufallsvariable	unabhängig	independent
range	Wertebereich	unbestimmt	uncertain
sample	Ergebnis	Verteilung	distribution
uncertain	unbestimmt	vollständiger Code	complete code
uncountable	überabzählbar	Wertebereich	range
uniform	gleich-	Zufallsvariable	random variable
unique	eindeutig		