

Einführung
Proseminar Datenkompression
Wintersemester 2018/2019

Dr. Ralf Schlüter

Lehrstuhl für Informatik 6
RWTH Aachen
52056 Aachen

<mailto:schlueter@cs.rwth-aachen.de>

1 Überblick

- Einführung**
- **Anwendungsbereiche**
 - **Motivation**
 - **Beispiele**
- Methodik**
- **Verlustlos vs. verlustbehaftet**
 - **Performanzbewertung**
 - **Ansätze**
 - **Vorgehensweise**
- Statistik**
- **Grundbegriffe und Konzepte**
 - **Stochastische Prozesse**
- Information**
- **Definition**
 - **Modellierung**
 - **Kodierung**

2 Einführung

Anwendungen für Datenkompression:

- Internet
- Telekommunikation
- Videokommunikation

Undenkbar ohne Datenkompression:

- Bild-, Audio- und Videoinformation im Internet
- Hochqualitative Mobiltelefonie
- Digital-TV

Einführung

Warum Datenkompression?

- Ergänzung zu Verbesserungen in Speichertechnologie und Datenübertragung
- Informationsbedarf steigt stärker als verfügbare Ressourcen
- Physikalische Grenzen für Speicher- und Übertragungskapazitäten

Jedoch:



- Komprimierbarkeit ist auch begrenzt (Entropie!)

Einführung

Morse Kodierung:

- **kürzere** Repräsentationen für **häufigere** Zeichen
- z.B.: SOS ... — ... (9 bit)
 AND .- -.. (7 bit)
 DATE -.. .- - . (7 bit)

Braille Kodierung:

- 6 bit pro Zeichen sowie **häufigste Wörter**
- z.B.: AND  (6 bit)
 DATE  (24 bit)
- Anwendung: Blindenschrift

3 Methodik

Verlustlose Kompression:

notwendig für z.B.:

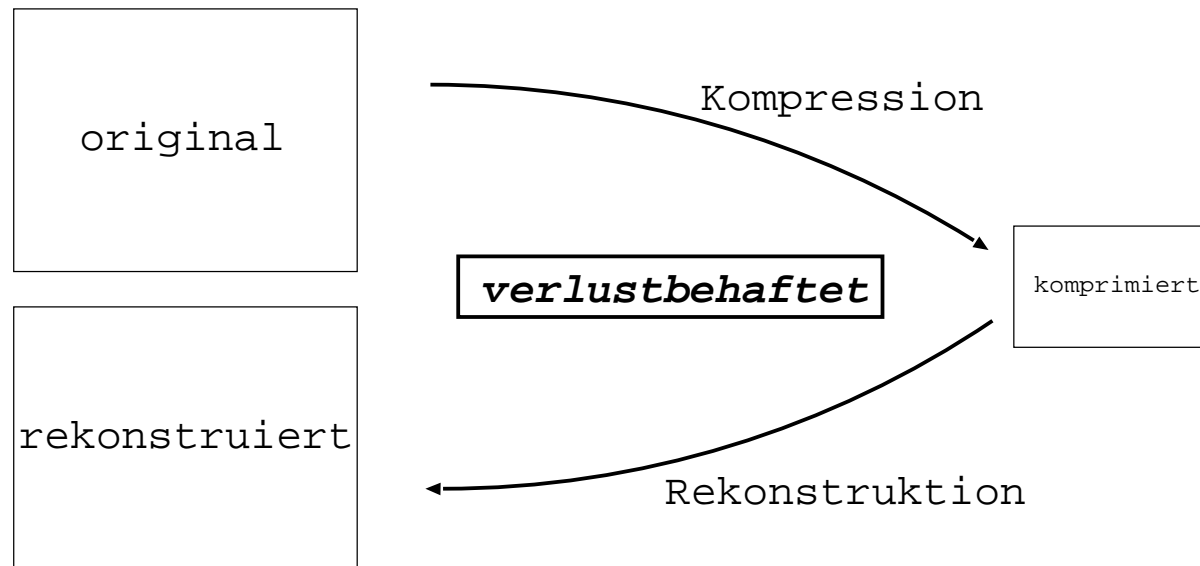
- Text-Daten (“Do not **t** jump!” vs. “Do now **w** jump!”)
- System-Daten
- Bank-Daten
- Verhinderung von Artefakten bei Weiterverarbeitung



Methodik

Verlustbehaftete Kompression:

- höhere Kompressionsraten möglich
- Redundanz der Originaldaten
- Informationsgehalt vs. Perzeptionsgrenzen bzw. Akzeptanz



Methodik

Performanzbewertung

- **Maß der Kompression:**
 - **Kompressionsrate:** $\frac{\text{Anzahl Bits im Original}}{\text{Anzahl Bits nach Kompression}}$
 - **Normiert:** z.B. für Bilder in Bits pro Pixel
- **Verlustbehaftet: zusätzlich Qualitätsmaße**
 - **Verzerrung:** Ähnlichkeit zum Original
 - **Sprache, Video:** menschliche Perzeption
 - **Mathematische Modellierung der menschlichen Perzeption**

Methodik

Ansätze für Kompression:

- **Statistik, z.B.:**
 - Häufigkeit einzelner Symbole (z.B. Huffman, arithmetisch)
 - Häufigkeit von Symbolfolgen/Wörtern (z.B. string-basiert)
 - Berücksichtigung von Kontext (z.B. prädiktiv)
- **Physikalische Strukturierung, z.B.:**
 - Sprache: Vokaltraktparameter statt Abtastwerte
- **Wahrnehmungs-Orientierung, z.B.:**
 - Sprache: Abtastrate angepasst an Verständlichkeit
 - Bilder: Auflösung angepasst an Perzeptionsgrenzen
 - Film: Bildrate angepasst an Fähigkeit, aufeinanderfolgende Bilder explizit zu unterscheiden

Methodik

Wahl der Kompressionsmethode:

- **Finden von Redundanzen**
- **Modellierung (von Redundanzen), z.B.:**
 - **Statistisch**
 - **Gruppierung**
 - **Prädiktion**
 - **Funktional**
 - **Transformation**
- **Kodierung, z.B.:**
 - **Statistisch, z.B.:**
 - * **variable Kodewortlänge**
 - * **Gruppierung**
 - **Modellparameter**
 - + **Abweichung vom Modell (Residuum)**

4 Statistische Grundlagen

Wahrscheinlichkeit:

- Beschreibung von Ereignissen
- Erwartungsmaß; z.B. Häufigkeit
- Positivität, Normierung und Additivität
- Unabhängigkeit / Bedingtheit
- Bezeichnungen:
 - a-priori Wahrscheinlichkeit: $p(B)$
 - a-posteriori Wahrscheinlichkeit: $p(A|B)$
 - Verbundverteilung: $p(A, B) = p(A \cup B) = p(A|B) \cdot p(B)$
 - Randverteilung: $p(B) = \sum_A p(A, B)$

Ereignisse:

- mögliche Werte einer Zufallsvariablen, z.B.:
 - Ergebnisse eines Würfelwurfs
 - Zeichen, Wörter oder ganze Sätze
 - Orte eines Meteoriteneinschlags
- diskret oder kontinuierlich
- Gruppierung, z.B. $\{a, b\} \rightarrow \{aa, ab, ba, bb\}$

Wichtige Begriffe und Konzepte:

- **Bayessche Identität:**
$$p(A|B) = \frac{p(A, B)}{p(B)} = \frac{p(A \cup B)}{p(B)}$$

- **kumulative Verteilung:**
$$p(x \leq x_0) = \int_{-\infty}^{x_0} p(x) dx$$

- **Erwartungswerte:**
$$E\{f(x)\} = \int_{-\infty}^{\infty} f(x)p(x) dx \quad (\text{kontinuierlich})$$

$$E\{f(x)\} = \sum_i f(x_i)p(x_i) \quad (\text{diskret})$$

- **Mittelwert:**
$$\mu = E\{x\}$$

- **Varianz:**
$$\sigma^2 = E\{(x - \mu)^2\} = E\{x^2\} - E\{x\}^2$$

Stochastische Prozesse:

- statistische Modellierung von **Zeitreihen**, z.B.:
 - Niederschlagsmenge
 - Stromverbrauch
 - Radioaktiver Zerfall
 - Sprache
 - Video-Sequenzen
- zeitabhängige Zufallsvariable
- Autokorrelation:

$$R_{xx}(t_1, t_2) = E\{x(t_1) \cdot x(t_2)\}$$

- **Stationarität: statt expliziter nur noch relative Zeitabhängigkeit**

$$R_{xx}(t_1, t_2) = R_{xx}(t_2 - t_1)$$

5 Informationstheorie

Was ist eigentlich Information?

- **Datenmenge:**

- n verschiedene Zeichen z : $i(z) = \log_2 n$ (Bits pro Zeichen)
- Gleichverteilung: $p(z) = \frac{1}{n} \Rightarrow i(z) = -\log_2 p(z)$
- Allgemeine Verteilung: $i(z) = -\log_2 p(z)$
- C. E. Shannon: “Eigeninformation”
- Einheit:
 - * bestimmt durch Basis des Logarithmus
 - * z.B. Anzahl Bits, Zeichen, Wörter, Seiten, etc.

- **Informationsgehalt:**

- Bezug zu Datenmenge?
- Intuitiv: minimal mögliche Datenmenge ohne Verluste
- Vorsicht: In diesem Sinne enthält eine zufällige Zeichenfolge mehr Information als z.B. eine Seminararbeit gleicher Länge!

5 Informationstheorie

Was ist eigentlich Information?

- **Datenmenge:**
 - n verschiedene Zeichen z : $i(z) = \log_2 n$ (Bits pro Zeichen)
 - Gleichverteilung: $p(z) = \frac{1}{n} \Rightarrow i(z) = -\log_2 p(z)$
 - Allgemeine Verteilung: $i(z) = -\log_2 p(z)$
 - C. E. Shannon: “Eigeninformation”
 - Einheit:
 - * bestimmt durch Basis des Logarithmus
 - * z.B. Anzahl Bits, Zeichen, Wörter, Seiten, etc.
- **Informationsgehalt:**
 - Bezug zu Datenmenge?
 - Intuitiv: minimal mögliche Datenmenge ohne Verluste
 - Vorsicht: In diesem Sinne enthält eine zufällige Zeichenfolge mehr Information als z.B. eine Seminararbeit gleicher Länge!

... d.h.: **Quantität ist nicht gleich Qualität!**

Informationstheorie

Information von Ereignissen

Ereignisse A und B seien **unabhängig**

- dann gilt $p(A, B) = p(A) \cdot p(B)$
- Information des Verbundereignisses $A \cup B$: $i(A, B) = i(A) + i(B)$
- kein Informationsgewinn durch Gruppierung
- Beispiele: Münzwurf
 - gleichverteilt: $p(Kopf) = p(Zahl) = 1/2$
 $\Rightarrow i(Kopf) = i(Zahl) = 1 \text{ Bit.}$
 - nicht gleichverteilt: $p(Kopf) = 7/8, \quad p(Zahl) = 1/8$
 $\Rightarrow i(Kopf) = 0.193 \text{ Bits, } i(Zahl) = 3 \text{ Bits.}$

Informationstheorie

Information von Ereignissen

Ereignisse A und B seien **abhängig**

- dann gilt $p(A, B) = p(A|B) \cdot p(B)$
- Information des Verbundereignisses $A \cup B$: $i(A, B) = i(A|B) + i(B)$
- Informationsgewinn durch Gruppierung möglich, z.B.:
 - Betrachte Ziffernfolge: $f = 1\ 2\ 1\ 2\ 3\ 3\ 3\ 3\ 1\ 2\ 3\ 3\ 3\ 3\ 1\ 2\ 3\ 3\ 1\ 2$
 - Gleiche Kodewortlänge für alle Symbole: $20 \cdot 2\ \text{Bits} = 40\ \text{Bits}$
 - Annahme unabhängiger Einzelsymbole:
 $p(1) = p(2) = 1/4, p(3) = 1/2 \Rightarrow i(f) = 5 \cdot 2 + 5 \cdot 2 + 10 \cdot 1\ \text{Bits} = 30\ \text{Bits}$
 - Abhängigkeit durch Gruppierung zu Blöcken 12 und 33:
 $p(1\ 2) = p(3\ 3) = 1/2 \Rightarrow i(f) = 5 \cdot 1 + 5 \cdot 1\ \text{Bits} = 10\ \text{Bits}$

Informationstheorie

Mittlere Information:

- betrachte Zufallsprozess \mathcal{Z} , mögliche Ereignisse: A_i
- Ereignis A_i tritt ein mit Wahrscheinlichkeit $p(A_i)$
- mittlere Information eines Ereignisses dieses Zufallsprozesses: Erwartungswert des Informationsgehalts

$$\begin{aligned} H(\mathcal{Z}) = E\{i(A)\} &= \sum_i p(A_i) \cdot i(A_i) \\ &= - \sum_i p(A_i) \cdot \log_2 p(A_i) \end{aligned}$$

C. E. Shannon: Entropie H gibt minimale Anzahl von Bits zur verlustlosen Kodierung des Zufallsprozesses an

- Qualität einer Kompressionsmethode: Vergleich mit Entropie
- **Vorsicht:** Entropie abhängig vom Modell (bzgl. Kontextabhängigkeit)!

Informationstheorie

Mittlere Information im allgemeinen Fall:

- betrachte stochastischen Prozess \mathcal{S} , der Folge von Ereignissen A_i erzeugt
- Ereignisse seien aus Alphabet $\{A_1, \dots, A_m\}$
- Entropie:

$$H(\mathcal{S}) = - \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i_1=1}^m \sum_{i_2=1}^m \cdots \sum_{i_n=1}^m p(A_{i_1}, \dots, A_{i_n}) \cdot \log_2 p(A_{i_1}, \dots, A_{i_n})$$

- Reichweite von Korrelationen/Redundanzen unbekannt:
Betrachtung im Limes unendlich langer Folgen
- Verteilung bzw. Strukturierung der Daten
im Allgemeinen nicht (exakt) bekannt
- Notwendigkeit der Modellierung

Informationstheorie

Herleitung der Entropie

- Informationstheoretische Basis: C. E. Shannon
- Herleitung der mittleren Information allein über Axiome
- Betrachte unabhängige Ereignisse A_i mit Wahrscheinlichkeiten $p_i = p(A_i)$

- Axiome:

1. Mittlere Information H ist stetige Funktion der Wahrscheinlichkeiten p_i ; kleine Änderungen in den Wahrscheinlichkeiten führen zu kleinen Änderungen in der mittleren Information.
2. Für gleichverteilte Ereignisse mit $p_i = 1/n$ ist mittlere Information eine monotone Funktion von n , der Anzahl der möglichen Ereignisse.
3. Konsistenz der mittleren Information unter Gruppierung. Betrachte $A_2 \vee A_3$ als neues Ereignis:

$$H(p_1, p_2, p_3) = H(p_1, p_2 + p_3) + p_1 \cdot H\left(\frac{p_1}{p_1} = 1\right) + (p_2 + p_3) \cdot H\left(\frac{p_2}{p_2 + p_3}, \frac{p_3}{p_2 + p_3}\right)$$

Informationstheorie

Modellierung:

- **Physikalisch**

- Wissen über die Strukturierung der Quelle
- Vorhersage von Werten mittels Modell
- Kodierung des Residuums: Abweichung vom Modell

- **Statistisch**

- Steuerung von Kodewortlänge, Gruppierung, etc. anhand der Wahrscheinlichkeiten

- **Beispiele:**

- * **Unabhängigkeit:**
$$p(A_1, \dots, A_n) = \prod_{i=1}^n p(A_i)$$


- * **Markov Annahme: Abhängigkeit endlicher Reichweite m ,**

$$\begin{aligned} p(A_1, \dots, A_n) &= \prod_{i=1}^n p(A_i | A_1, \dots, A_{i-1}) \\ &= \prod_{i=1}^n p(A_i | A_{i-m}, \dots, A_{i-1}) \end{aligned}$$

Informationstheorie

Markov-Prozesse:


- **Einfachster nicht-trivialer Fall:**
Abhängigkeit allein vom direkt vorhergehenden Ereignis
- $p(A_i | A_1, \dots, A_{i-1}) = p(A_i | A_{i-1})$
- **Vgl. stochastischen endlichen Automaten, z.B.:**



Informationstheorie

Markov-Prozesse:

- Vgl. stochastischen endlichen Automaten, z.B.:



- Binärer Zufallsprozess, Ereignisse $X \in \{A, B\}$
 - Zustände des Automaten: s_A, s_B
 - Zustand s_X “emittiert” Ereignis X
 - Übergangswahrscheinlichkeiten: $p(X_i|X_{i-1})$
- Bezüge: Sprachmodell in der Spracherkennung, Hidden Markov Modelle

Informationstheorie

Kodierung

- Zuweisung binärer Folgen zu Elementen eines Alphabets
- Kode: Menge der binärer Folgen
- Zeichen: Element eines Alphabets
- Kodewörter: Elemente eines Kodes
- Problem: **Welche Kodewörter bzw. Kodewortlängen sind den Elementen des Alphabets zuzuordnen, um eine möglichst hohe Kompressionsrate auf den zu erwartenden Datensätzen zu erreichen?**

Informationstheorie

Eindeutige Dekodierbarkeit: Beispiele

Zeichen	Wahrscheinlichkeit	Kode 1	Kode 2	Kode 3	Kode 4
a_1	0.5	0	0	0	0
a_2	0.25	0	1	10	01
a_3	0.125	1	00	110	011
a_4	0.125	10	11	111	0111
mittlere Länge		1.125	1.25	1.75	1.875

- mittlere Länge: $\sum_i p(a_i)n(a_i)$, mit Kodewortlänge $n(a_i)$
- Entropie: 1.75
- **Kode 1: Identische Kodierung für a_1 und a_2 : Kode 1 nicht eindeutig!**
- **Kode 2: Dekod. von 100 liefert a_2a_3 oder $a_2a_1a_1$: Kode 2 nicht eindeutig!**
- **Notwendig: Eindeutige Dekodierbarkeit**
- **Kode 3: Präfix-Kode – Ende des Kodeworts direkt erkennbar!**
- **Kode 4: ähnlich Kode 3, Kodewort-Ende aber erst zu Beginn des Folge-Kodeworts erkennbar!**

Informationstheorie

Eindeutige Dekodierbarkeit: Beispiele (2)

Zeichen	Wahrscheinlichkeit	Kode 5	Kode 6
a_1	0.5	0	0
a_2	0.25	01	01
a_3	0.125	11	10
...

- **Kode 5: Dekodierung erst am Ende eindeutig**
 - z.B.: Dekodiere $0 \underbrace{11111111111111111}_{17 \text{ Einsen}}$
 - a_1 mit 8 folgenden a_3 : “baumelndes” Bit am Ende – nicht möglich!
 - Korrekt: a_2 gefolgt von 8 a_3
- **Kode 6: Dekodierung von 0 1 0 liefert $a_1 a_3$ oder $a_2 a_1$: nicht eindeutig!**

Informationstheorie

Präfix-Kodes

- **Definition:** Kein Kodewort darf Präfix eines anderen Kodeworts sein.
- **Binärbaum-Darstellung:**
 - Verzweigung: rechts entspricht 1, links 0
 - mögliche Kodewörter: Knoten
 - Präfix-Kode: Kodewörter nur an Blättern (Endknoten)
- **Kraft-McMillan Ungleichung:**

Für jeden eindeutig dekodierbaren Code gibt es einen entsprechenden Präfix-Kode mit gleichen Kodewortlängen.
--

6 Zusammenfassung

Grundlagen

- Motivation
- Anwendungen
- Beispiele

Kompressionskonzepte

- Kompressionsmethoden
- Unterscheidung verlustlos/verlustbehaftet
- Statistische Betrachtungsweise, Grundkonzepte
- Bewertungsmöglichkeiten

Informationstheorie

- Grundkonzepte, Shannon
- Kodierung

7 Weiterer Ablauf

Ausführung

- Literatur
- Recherveschulung/Info-Bibliothek
- Bearbeitungshinweise
- L^AT_EX, Vorlagen

Organisatorisches

- Ablauf/Fristen
- Probevortrag
- Vortrag
- Korrektur/Benotung

Themen

- Kurzvorstellung
- Wünsche
- Vergabe

