

## 3. Woche

# Information, Entropie, Kryptographische Codierung

# Informationsgehalt einer Nachricht

**Intuitiv:** Je kleiner die Quellws, desto „wichtiger“ oder „strukturiierter“ die Information, bzw. höher der Informationsgehalt.

Zur Struktur:

Ws von „A“ ist 6,51%, Ws von „t“ ist 6,15%, Ws von „e“ ist 17,40% und Ws von „m“ ist 2,53 %.

Falls Buchstaben unabhängig (gedächtnisloser Kanal), ist Ws von „Atem“ gleich  $0,0651 \cdot 0,0615 \cdot 0,174 \cdot 0,0253 = 1,76 \cdot 10^{-5} = 0.00176\%$

(Eigentlich ist die deutsche Sprache kein gedächtnisloser Kanal: Nach den Daten im Leipziger Wortschatz: Ws von „Atem“  $< 0.0008\%$ .)

Intuitiv betrachtet, enthält „Atem“ mehr Information als „A“, „t“, „e“, oder „m“.

Wir wollen eine Informations–„abmessende“ Funktion nach dieser Intuition definieren.

# Informationsgehalt einer Nachricht

Forderungen für eine Funktion, die Information „abmessen“ soll.

- 1  $I(p) \geq 0$ : Der Informationsgehalt soll positiv sein.
- 2  $I(p)$  ist stetig in  $p$ : Kleine Änderungen in der Ws  $p$  sollen nur kleine Änderungen von  $I(p)$  bewirken.
- 3  $I(p_i) + I(p_j) = I(p_i p_j)$ :
  - ▶  $X$  = Ereignis, dass  $a_i$  und  $a_j$  nacheinander übertragen werden.  
Annahme war: gedächtnislose Quelle, also unabhängige Ereignisse.
  - ▶ Informationsgehalt von  $X$ :  $I(p_i) + I(p_j)$ ,  $W_s(X) = p_i p_j$

## Satz zur Struktur von $I(p)$

Jede Funktion  $I(p)$  für  $0 < p \leq 1$ , die obige Bedingungen erfüllt, ist der Form

$$I(p) = C \log \frac{1}{p}$$

für eine positive Konstante  $C$ .

## Beweis: Form von $I(p)$

- Forderung 3 liefert  $I(p^2) = I(p) + I(p) = 2 I(p)$ .
- Induktiv:  $I(p^n) = n I(p)$  für alle  $n \in \mathbb{N}$  und alle  $0 < p \leq 1$ .
- Substitution  $p \rightarrow p^{\frac{1}{n}}$  liefert:  $I(p) = n I(p^{\frac{1}{n}})$  bzw.  $I(p^{\frac{1}{n}}) = \frac{1}{n} I(p)$
- Damit gilt für alle  $q \in \mathbb{Q}$ :  $I(p^q) = q I(p)$ .
- Für jedes  $r \in \mathbb{R}$  gibt es eine Folge  $q_i$  mit  $\lim_{n \rightarrow \infty} q_n = r$ .  
Aus der Stetigkeit von  $I(p)$  (Annahme!) folgt

$$I(p^r) = I\left(\lim_{n \rightarrow \infty} p^{q_n}\right) = \lim_{n \rightarrow \infty} I(p^{q_n}) = \lim_{n \rightarrow \infty} q_n I(p) = r I(p)$$

- Fixiere  $0 < q < 1$ . Für jedes  $0 < p \leq 1$  gilt

$$\begin{aligned} I(p) &= I(q^{\log_q p}) = I(q) \log_q p = -I(q) \log_q \left(\frac{1}{p}\right) = -I(q) \frac{\log_2 \frac{1}{p}}{\log_2 q} \\ &= \mathbf{C} \log_2 \frac{1}{p} \quad \text{wobei} \quad C = -I(q) \cdot \frac{1}{\log_2(q)} > 0. \quad \square \end{aligned}$$

## Definition Information $I(p)$

### Definition $I(p)$

Die Information  $I(p)$  eines Symbols mit Quellws  $p > 0$  beträgt

$$I(p) = \log_2 \frac{1}{p}.$$

Die Einheit der Information bezeichnet man als Bit.

Hier ist der Logarithmus zur Basis 2 gemeint (auch wenn nicht explizit geschrieben).

# Beispiele für Information

- $Q = \{0, 1\}$  mit  $p_1 = p_2 = \frac{1}{2}$ . Dann ist  $I(\frac{1}{2}) = 1$ , d.h. für jedes gesendete Symbol erhält der Empfänger 1 Bit an Information.
- $Q = \{0, 1\}$  mit  $p_1 = 1, p_2 = 0$ . Dann ist  $I(1) = 0$ , d.h. der Empfänger enthält 0 Bit an Information pro gesendetem Zeichen.
- Beweis für „Ein Bild sagt mehr als 1000 Worte!“
  - ▶ Beamer-Bild: Auflösung  $1024 * 768$ , 24-Bit Farben  
Ssenario: Der Dozent will Informationsfunktionen erklären.
    - ★  $2^{1024*768*24}$  mögliche Folien. Annahme: Jede gleich wahrscheinlich!
    - ★ Information in Bit:  $I(2^{-1024*768*24}) = 1024 * 768 * 24 = 18.874.368$
  - ▶ Selbe Erklärung in Worten im Buch:  
 $\leq 1000$  Worte,  $\leq 10.000$  Worte Vokabular
    - ★ Information:  $I(10.000^{-1000}) < 13.288$

# Entropie einer Quelle

## Definition Entropie einer Quelle

Sei  $Q$  eine Quelle mit Quellws  $P = \{p_1, \dots, p_n\}$ . Die Entropie von  $Q$  ist

$$H(Q) = \sum_{i=1}^n p_i I(p_i) = \sum_{i=1}^n p_i \log \frac{1}{p_i} = - \sum_{i=1}^n p_i \log p_i .$$

- Für  $p_i = 0$  definieren wir  $p_i \log \frac{1}{p_i} = 0$ . Also ist  $p_i \log \frac{1}{p_i} = 0$  gdw  $p_i = 0$  oder  $1$ .
- Entropie ist die durchschnittliche Information pro Quellsymbol.

▶  $P = \left\{ \underbrace{\frac{1}{n}, \frac{1}{n}, \dots, \frac{1}{n}}_{n \text{ Symbole}} \right\} : H(Q) = \sum_{i=1}^n \frac{1}{n} \log n = \log n$

▶  $P = \left\{ \underbrace{\frac{1}{n}, \frac{1}{n}, \dots, \frac{1}{n}}_{n \text{ Symbole}}, 0 \right\} : H(Q) = \sum_{i=1}^n \frac{1}{n} \log n = \log n$

▶  $P = \{1, 0, 0, \dots, 0\} : H(Q) = 1 \cdot \log 1 = 0$

N.B.: man kann  $H(Q)$  als auch  $H(P)$  für eine Quelle  $Q$  mit Ws-Verteilung  $P$  schreiben.

## Sätze über Entropie und Codewortlänge

Unser nächstes Ziel ist, folgende Sätze zu beweisen:

### Satz Schranken für $H(Q)$

Sei  $Q$  eine Quelle mit Ws-Verteilung  $P = \{p_1, \dots, p_n\}$ . Dann gilt

$$0 \leq H(Q) \leq \log n.$$

Weiterhin gilt  $H(Q) = \log n$  gdw alle  $p_i = \frac{1}{n}$  für  $i = 1, \dots, n$  und  $H(Q) = 0$  gdw  $p_i = 1$  für ein  $i \in \{1, \dots, n\}$ .

D.h. die Beispiele der vorigen Folie sind extremal.

### Codierungstheorem von Shannon (1948)

Sei  $Q$  eine Quelle für  $\{a_1, \dots, a_n\}$  mit Ws-Verteilung  $P = \{p_1, \dots, p_n\}$ .  
Sei  $C$  ein kompakter Code für  $Q$ . Dann gilt für die erwartete Codewortlänge

$$H(Q) \leq E(C) < H(Q) + 1.$$



# Wechsel zu anderer Ws-Verteilung

## Lemma Wechsel Ws-Verteilung

Seien  $P = \{p_1, \dots, p_n\}$  eine Ws-Verteilung und  $Q = \{q_1, \dots, q_n\}$  mit  $\sum_{i=1}^n q_i \leq 1$ . Dann gilt

$$\sum_{i=1}^n p_i I(p_i) \leq \sum_{i=1}^n p_i I(q_i).$$

Gleichheit gilt genau dann, wenn  $p_i = q_i$  für alle  $i = 1, \dots, n$ .

Nützliche Ungleichung für das Rechnen mit logs:

$$x - 1 \geq \ln x = \log x \cdot \ln 2 \quad \text{für alle } x > 0$$

Gleichheit gilt gdw  $x = 1$ .

$\ln(x)$  bezeichnet den natürlichen Logarithmus,  $\log(x)$  ist zur Basis 2.

# Beweis des Lemmas

$$\begin{aligned}\sum_{i=1}^n p_i I(p_i) - \sum_{i=1}^n p_i I(q_i) &= \sum_{i=1}^n p_i \left( \log \frac{1}{p_i} - \log \frac{1}{q_i} \right) \\ &= \sum_{i=1}^n p_i \log \frac{q_i}{p_i} \\ &\leq \frac{1}{\ln 2} \sum_{i=1}^n p_i \left( \frac{q_i}{p_i} - 1 \right) \\ &= \frac{1}{\ln 2} \left( \underbrace{\sum_{i=1}^n q_i}_{\leq 1} - \underbrace{\sum_{i=1}^n p_i}_{=1} \right) \leq 0 .\end{aligned}$$

Gleichheit gilt gdw  $\frac{q_i}{p_i} = 1$  für alle  $i = 1, \dots, n$ .

□

## Untere und obere Schranken für $H(P)$

### Satz Schranken für $H(P)$

Sei  $Q$  eine Quelle mit Ws-Verteilung  $P = \{p_1, \dots, p_n\}$ . Dann gilt

$$0 \leq H(Q) \leq \log n.$$

Weiterhin gilt  $H(Q) = \log n$  gdw alle  $p_i = \frac{1}{n}$  für  $i = 1, \dots, n$  und  $H(Q) = 0$  gdw  $p_i = 1$  für ein  $i \in \{1, \dots, n\}$ .

- Sei  $P' = \{\frac{1}{n}, \dots, \frac{1}{n}\}$  die Gleichverteilung.
- Nach Lemma zum Wechsel von Ws-Verteilungen gilt

$$H(Q) = \sum_{i=1}^n p_i \log \frac{1}{p_i} \leq \sum_{i=1}^n p_i \log \frac{1}{p'_i} = \log n \sum_{i=1}^n p_i = \log n.$$

- Gleichheit gilt gdw  $p_i = p'_i = \frac{1}{n}$  für alle  $i$ .

## Untere Schranke für $H(P)$

Verwenden Ungleichung  $\log x \geq 0$  für  $x \geq 1$ . Gleichheit gilt gdw  $x = 1$ . Nun,


$$H(Q) = \sum_{i=1}^n p_i \log \frac{1}{p_i} \geq 0,$$

mit Gleichheit gdw alle  $p_i \log \frac{1}{p_i} = 0$ , d.h.  $p_i = 1$  für ein  $i \in \{1, \dots, n\}$  und  $p_j = 0$  für alle  $j \neq i$ . □

### Beispiel

Binäre Quelle  $Q = \{a_1, a_2\}$  mit  $P = \{p, 1 - p\}$

$$H(Q) = p \log \frac{1}{p} + (1 - p) \log \frac{1}{1 - p} .$$



$H(Q)$  heißt *binäre Entropiefunktion*.

# Codierungstheorem von Shannon

## Codierungstheorem von Shannon (1948)

Sei  $Q$  eine Quelle für  $\{a_1, \dots, a_n\}$  mit Ws-Verteilung  $P = \{p_1, \dots, p_n\}$ .  
Sei  $C$  ein kompakter Code für  $Q$ . Dann gilt für die erwartete Codewortlänge

$$H(Q) \leq E(C) < H(Q) + 1.$$

**Beweis:**  $H(Q) \leq E(C)$

- Bezeichnen Codewortlängen  $\ell_i := |C(a_i)|$  und  $q_i := 2^{-\ell_i}$ .
- Satz von McMillan:  $\sum_{i=1}^n q_i = \sum_{i=1}^n 2^{-\ell_i} \leq 1$ .
- Lemma Wechsel Ws-Verteilung liefert

$$\begin{aligned} H(Q) &= \sum_{i=1}^n p_i \log \frac{1}{p_i} \leq \sum_{i=1}^n p_i \log \frac{1}{q_i} \\ &= \sum_{i=1}^n p_i \log 2^{\ell_i} = \sum_{i=1}^n p_i \ell_i = E(C). \end{aligned}$$

## $E(C) < H(Q) + 1$

- Seien  $l_1, \dots, l_n$  Codewortlängen mit  $\sum_{i=1}^n 2^{-l_i} \leq 1 = \sum_{i=1}^n p_i$ .
- Satz von McMillan garantiert Existenz von Code  $C'$  für

$$2^{-l_i} \leq p_i \Leftrightarrow -l_i \leq \log p_i \Leftrightarrow l_i \geq \log \frac{1}{p_i}.$$

- Wählen  $l_i \in \mathbb{N}$  für alle  $i$  minimal mit obiger Eigenschaft, d.h.

$$\log \frac{1}{p_i} \leq l_i < \log \frac{1}{p_i} + 1.$$

Ein Code  $C'$  mit dieser Eigenschaft heißt *Shannon-Fano Code*.

- Für jeden kompakten Code  $C$  gilt

$$\begin{aligned} E(C) &\leq E(C') = \sum_{i=1}^n p_i l_i < \sum_{i=1}^n p_i \left( \log \frac{1}{p_i} + 1 \right) \\ &= \sum_{i=1}^n p_i \log \frac{1}{p_i} + \sum_{i=1}^n p_i = H(Q) + 1. \quad \square \end{aligned}$$

# Besser als kompakte Codes?

Nun wissen wir:

- 1 Die Huffman-Codierung liefert einen kompakten Code  $C$ .
- 2 Für diesen code  $C$  gilt  $H(Q) \leq E(C) < H(Q) + 1$ .

Falls wir Pech haben ist  $E(C)$  fast gleich  $H(Q) + 1$ .

Können wir Codes bauen, die eine „kompaktere als eine kompakte“ Codierung liefern?

Wir fangen mit einem Beispiel an.

# Codieren einer binären Quelle

**Szenario:** Binäre Quelle  $Q$  mit  $P = \{\frac{1}{4}, \frac{3}{4}\}$  mit

$$H(Q) = \frac{1}{4} \cdot \log 4 + \frac{3}{4} \cdot \log \frac{4}{3} \approx 0.811.$$

- Huffman-Codierung von  $Q$ :  
 $C(a_1) = 0, C(a_2) = 1$  mit  $E(C) = 1$ .
- **Problem:** Jedes Symbol hat Codewortlänge  $\geq 1$ . Also  $E(C) \geq 1$ .  
Wie kann man die Ungleichheit der Wahrscheinlichkeiten ausnutzen, um die erwartete Codewortlänge zu reduzieren?
- **Idee:** Codieren *Zweierblöcke* von Quellsymbolen.



## Quellenerweiterungen von $Q$

- Betrachten  $Q^2 = \{a_1 a_1, a_1 a_2, a_2 a_1, a_2 a_2\}$  mit Quellws

$$p_1 = \frac{1}{16}, p_2 = p_3 = \frac{3}{16}, p_4 = \frac{9}{16}.$$

- Huffman-Codierung von  $Q^2$  liefert

$$C(a_1 a_1) = 000, C(a_1 a_2) = 001, C(a_2 a_1) = 01, C(a_2 a_2) = 1$$

$$\text{mit } E(C) = 3 \cdot \frac{4}{16} + 2 \cdot \frac{3}{16} + \frac{9}{16} = \frac{27}{16}.$$

- Jedes Codewort codiert zwei Quellsymbole, d.h. die durchschnittliche Codewortlänge pro Quellsymbol ist

$$E(C)/2 = \frac{27}{32} = 0.84375.$$

- *Übung:* Für  $Q^3$  erhält man 0.82292.

Wie viel können wir dies noch verbessern?

Wie nah kommen wir zur Entropie?

## $k$ -te Quellenerweiterung $Q^k$

### **Definition** $k$ -te Quellenerweiterung

Sei  $Q$  eine Quelle mit Alphabet  $A = \{a_1, \dots, a_n\}$  und Ws-Verteilung  $P = \{p_1, \dots, p_n\}$ . Die  $k$ -te Quellenerweiterung  $Q^k$  von  $Q$  ist definiert über dem Alphabet  $A^k$ , wobei  $a = a_{i_1} \dots a_{i_k} \in A^k$  die Quellws  $p_{i_1} \cdot p_{i_2} \cdot \dots \cdot p_{i_k}$  besitzt.

### **Satz** Entropie von $Q^k$

Sei  $Q$  eine Quelle mit  $k$ -ter Quellenerweiterung  $Q^k$ . Dann gilt

$$H(Q^k) = k \cdot H(Q).$$

## Beweis für $H(Q^k)$

$$\begin{aligned} H(Q^k) &= \sum_{(i_1, \dots, i_k) \in [1..n]^k} p_{i_1} \cdots p_{i_k} \log \frac{1}{p_{i_1} \cdots p_{i_k}} \\ &= \sum_{(i_1, \dots, i_k) \in [1..n]^k} p_{i_1} \cdots p_{i_k} \left( \log \frac{1}{p_{i_1}} + \cdots + \log \frac{1}{p_{i_k}} \right) \\ &= \sum_{(i_1, \dots, i_k) \in [1..n]^k} p_{i_1} \cdots p_{i_k} \log \frac{1}{p_{i_1}} + \cdots + \sum_{(i_1, \dots, i_k) \in [1..n]^k} p_{i_1} \cdots p_{i_k} \log \frac{1}{p_{i_k}} \end{aligned}$$

Betrachten wir den ersten Summanden

$$\begin{aligned} \sum_{(i_1, \dots, i_k) \in [1..n]^k} p_{i_1} \cdots p_{i_k} \log \frac{1}{p_{i_1}} &= \sum_{i_1 \in [1..n]} p_{i_1} \log \frac{1}{p_{i_1}} \cdot \sum_{i_2 \in [1..n]} p_{i_2} \cdots \sum_{i_k \in [1..n]} p_{i_k} \\ &= \sum_{i_1 \in [1..n]} p_{i_1} \log \frac{1}{p_{i_1}} \cdot 1 \cdots 1 = H(Q). \end{aligned}$$

Analog liefern die anderen  $n - 1$  Summanden jeweils  $H(Q)$ . □.

# Anwendung des Satzes von Shannon auf Quellenerweiterungen

## Korollar zu Shannons Codierungstheorem

Sei  $Q$  eine Quelle mit  $k$ -ter Quellenerweiterung  $Q^k$ . Sei  $C$  ein kompakter Code für  $Q^k$ . Dann gilt

$$H(Q) \leq \frac{E(C)}{k} < H(Q) + \frac{1}{k}.$$

- Anwendung von Shannon's Codierungstheorem auf  $Q^k$  liefert

$$H(Q^k) \leq E(C) < H(Q^k) + 1.$$

Anwenden von  $H(Q^k) = kH(Q)$  und teilen durch  $k$  liefert die Behauptung.

- Für wachsenden  $k$ ,  $E(C)/k$  wird beliebig nah zu  $H(Q)$ .

# Bedingte Entropie

- Sei  $X, Y$  Zufallsvariablen
- Definieren  $W_S(x) = W_S(X = x)$  und  $W_S(x, y) = W_S(X = x, Y = y)$ .
- $X, Y$  heißen unabhängig  $\Leftrightarrow W_S(x, y) = W_S(x) \cdot W_S(y)$

## Definition Bedingte Entropie

Wir bezeichnen die Größe  $H(Y | X)$

$$\begin{aligned} &:= \sum_x W_S(x) H(Y | X = x) = \sum_x W_S(x) \left( \sum_y W_S(y | x) \log \frac{1}{W_S(y | x)} \right) \\ &= \sum_x \sum_y W_S(x, y) \log \frac{1}{W_S(y | x)} \end{aligned}$$

als bedingte Entropie von  $Y$  gegeben  $X$ .

# Eigenschaften bedingter Entropie

## Rechenregeln für die bedingte Entropie

- 1 Kettenregel:

$$H(X, Y) = \sum_x \sum_y w_s(x, y) \log \frac{1}{w_s(x, y)} = H(X) + H(Y | X)$$

(Übung)

- 2  $H(Y | X) \leq H(Y)$ . Gleichheit gilt gdw  $X, Y$  unabhängig sind.  
(ohne Beweis)
- 3 Folgerung aus 1. und 2.:  $H(X, Y) \leq H(X) + H(Y)$ .

# Kryptographische Codierung

## Szenario:

- Drei Klartexte:  $a, b, c$  mit Ws  $p_1 = 0.5, p_2 = 0.3, p_3 = 0.2$ .
- Zwei Schlüssel  $k_1, k_2$  gewählt mit Ws jeweils  $\frac{1}{2}$
- Verschlüsselungsfunktionen:
  - ▶  $e_{k_1}: a \mapsto d, b \mapsto e, c \mapsto f$
  - ▶  $e_{k_2}: a \mapsto d, b \mapsto f, c \mapsto e$
- Seien  $P, C$  Zufallsvariablen für den Klar- und Chiffretext.
- Erhalten Chiffretext  $d$ , Plaintext muss  $a$  sein.
- Erhalten Chiffretext  $e$ , Plaintext muss  $b$  oder  $c$  sein.

$$W_s(b | e) = \frac{W_s(b \cap e)}{W_s(e)} = \frac{W_s(b \cap k_1)}{W_s(b \cap k_1) + W_s(c \cap k_2)} = \frac{0.15}{0.15 + 0.1} = 0.6$$

Lernen Information über zugrundeliegenden Klartext.

- $H(P) = \sum_i p_i \log \frac{1}{p_i} = 1.485$  und  $H(P | C) = 0.485$ .
- D.h. für gegebenen Chiffretext sinkt die Unsicherheit.

# Perfekte Sicherheit, das One-Time Pad

## Definition Perfekte Sicherheit

Ein Kryptosystem ist perfekt sicher, falls  $H(P | C) = H(P)$ .

## One-Time Pad

- Plaintextrraum  $\mathcal{P}$ :  $\{0, 1\}^n$  mit Ws-Verteilung  $p_1, \dots, p_{2^n}$
- Schlüsselraum  $\mathcal{K}$ :  $\{0, 1\}^n$  mit Ws  $\frac{1}{2^n}$  für alle Schlüssel
- Verschlüsselung:  $c = e_k(x) = x \oplus k$  für  $x \in \mathcal{P}, k \in \mathcal{K}$ .

## Satz One-Time Pad

Das One-Time Pad ist perfekt sicher.

Beweis: Übung.