

Informatik II - SS 2018

(Algorithmen & Datenstrukturen)

Vorlesung 22 (16.7.2018)

Greedy Algorithmen II
(Datenkompression)



**UNI
FREIBURG**

Fabian Kuhn

Algorithmen und Komplexität

Datenkompression

- Reduziert Größen von Files
- Viele Verfahren für unterschiedliche Anwendungen: MP3, MPEG, JPEG, ...
- Wie funktioniert Datenkompression?

Zwei Typen von Kompression:

- Verlustbehaftete Kompression (Bilder, Musik, Filme,...)
- Verlustfreie Kompression (Programme, Texte, ...)

Beispiel:

- Alphabet $\Sigma = \{a, b, c, d, \dots, x, y, z, \dots, :, !, ?, \&\}$ (32 Zeichen)
- 5 Bits pro Symbol: $2^5 = 32$ Möglichkeiten

a	b	...	z		.	:	!	?	&
00000	00001		11001	11010	11011	11100	11101	11110	11111

Fragen?

- Sind 4 Bits pro Symbol nicht genug ?
- Müssen wir im Durchschnitt 5 Bits für jedes Vorkommen eines Symbols in langen Texten verwenden?

Beobachtung:

- Nicht jeder Buchstabe kommt gleich häufig vor
- z. B. kommen x, y und z in der deutschen Sprache viel seltener vor als e, n oder r

Idee:

- Benutze kurze Bitstrings für Symbole die häufig vorkommen

Effekt:

- Gesamtlänge der Kodierung einer Symbolfolge (eines Textes) wird reduziert

Präfix-Kodierung:

Eine Präfix-Kodierung für ein Alphabet Σ ist eine Funktion γ , die jeden Buchstaben $x \in \Sigma$ auf eine endliche Sequenz von 0 und 1 abbildet, so dass für $x, y \in \Sigma$, $x \neq y$, die Sequenz $\gamma(x)$ *kein* Präfix der Sequenz $\gamma(y)$ ist.

Beispiel (Präfix-Kodierung):

$x \in \Sigma$	0	1	2	3	4	5	6	7	8	9
$\gamma(x)$	00	0100	0110	0111	1001	1010	1011	1101	1110	1111

Definition (Frequenz)

- Die **Frequenz** $f[x]$ eines Buchstaben $x \in \Sigma$ bezeichnet den Bruchteil der Buchstaben im Text, die x sind.

Beispiel:

- $\Sigma = \{0,1,2\}$
- Text = „0010022001“ (10 Zeichen)
- $f[0] = 3/5$
- $f[1] = 1/5$
- $f[2] = 1/5$

Definition (Kodierungslänge)

Die **Kodierungslänge** eines Textes mit n Zeichen bzgl. einer Kodierung γ ist definiert als

$$\text{Kodierungslänge} = \sum_{x \in X} n \cdot f[x] \cdot |\gamma(x)|$$

Beispiel:

- $\Sigma = \{a,b,c,d\}$
- $\gamma(a) = 0$; $\gamma(b) = 101$; $\gamma(c) = 110$; $\gamma(d) = 111$
- Text = „aacdaabb“
- Kodierungslänge = 16

Definition (durchschn. Kodierungslänge)

Die **durchschnittliche Kodierungslänge** eines Buchstabens in einem Text mit n Zeichen und bzgl. einer Kodierung γ ist definiert als

$$\text{ABL}(\gamma) = \sum_{x \in \Sigma} f[x] \cdot |\gamma(x)|$$

Average Bits per Letter

Beispiel:

- $\Sigma = \{a,b,c,d\}$
- $\gamma(a) = 0; \gamma(b) = 101; \gamma(c) = 110; \gamma(d) = 111$
- Text = „aacdaabb“
- Durchschnittliche Kodierungslänge = $16/8 = 2$

Problem einer optimalen Präfix-Kodierung:


- **Eingabe:**

Alphabet Σ und für jedes $x \in \Sigma$ seine Frequenz $f[x]$

- **Ausgabe:**

Eine Präfix-Kodierung γ , die $ABL(\gamma)$ minimiert


Binärbäume und Präfix-Kodierungen:



$x \in \Sigma$	$\gamma(x)$
a	00
b	1
c	011
d	010


Präfix-Kodierungen und Binärbäume:

$x \in \Sigma$	$\gamma(x)$
a	11
b	01
c	00
d	10



Definition:

Die **Tiefe** eines Baumknotens ist die Länge seines Pfades zur Wurzel.



Neue Problemformulierung:


- Suche Binärbaum T , dessen Blätter die Symbole aus Σ sind und der

$$ABL(T) = \sum_{x \in X} f[x] \cdot \text{Tiefe}_T(x)$$

minimiert.

Definition:


Ein Binärbaum heißt **voll**, wenn jeder innere Knoten genau zwei Kinder hat.



Ein voller Binärbaum

Definition:


Ein Binärbaum heißt **voll**, wenn jeder innere Knoten genau zwei Kinder hat.



Ein nicht voller Binärbaum,
da der rote innere Knoten
keine zwei Kinder hat


Lemma:

Der Binärbaum, der einer optimalen Präfix-Kodierung entspricht, ist voll.



Lemma:

Der Binärbaum, der einer optimalen Präfix-Kodierung entspricht, ist voll.




Beweis:

- Annahme: T ist optimal und hat inneren Knoten u mit einem Kind v
- Ersetze u durch v
- Dies verkürzt die Tiefe einiger Knoten, erhöht aber keine Tiefe
- Damit verbessert man die Kodierung

Lemma:

Der Binärbaum, der einer optimalen Präfix-Kodierung entspricht, ist voll.



Beweis:

- Annahme: T ist optimal und hat inneren Knoten u mit einem Kind v
- Ersetze u durch v
- Dies verkürzt die Tiefe einiger Knoten, erhöht aber keine Tiefe
- Damit verbessert man die Kodierung


Ein Gedankenexperiment:

- Angenommen, jemand gibt uns den optimalen Baum T^* , aber nicht die Bezeichnung der Blätter
- Wie schwierig ist es, die Bezeichnungen zu finden?

Lemma:

Seien u und v Blätter von T^* mit $\text{Tiefe}(u) < \text{Tiefe}(v)$.

Seien u bzw. v in einer optimalen Kodierung mit $y \in \Sigma$ bzw. $z \in \Sigma$ bezeichnet. Dann gilt $f[y] \geq f[z]$.




Lemma:

Seien u und v Blätter von T^* mit $\text{Tiefe}(u) < \text{Tiefe}(v)$.

Seien u bzw. v in einer optimalen Kodierung mit $y \in \Sigma$


bzw. $z \in \Sigma$ bezeichnet. Dann gilt $f[y] \geq f[z]$.



$x \in \Sigma$	$f[x]$
a	10%
b	12%
c	18%
d	60%

Beobachtung¹


Sei v der tiefste Blattknoten in T^* . Dann hat v einen Geschwisterknoten und dieser ist ebenfalls ein Blattknoten.



(Geschwisterknoten von v)

Zusammenfassende Behauptung


- Es gibt eine optimale Präfix-Kodierung mit zugehörigem Baum T^* , so dass die beiden Blattknoten, denen die Symbole mit den kleinsten Frequenzen zugewiesen wurden, Geschwisterknoten in T^* sind.



$x \in \Sigma$	$f[x]$
a	10%
b	12%
c	18%
d	60%

Idee des Algorithmus:

- Die beiden Symbole y^* und z^* mit den niedrigsten Frequenzen sind Geschwisterknoten
- Fasse y^* und z^* zu einem neuen Symbol zusammen
- Löse das Problem für die übrigen $n-1$ Symbole (z.B. rekursiv)



Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

Huffman(Σ)


1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%




Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=1$




Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=1$




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=1$




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=1$




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=1$




Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=1$




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=2$




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=2$




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=2$




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=2$




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=2$




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$i=2$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=3$



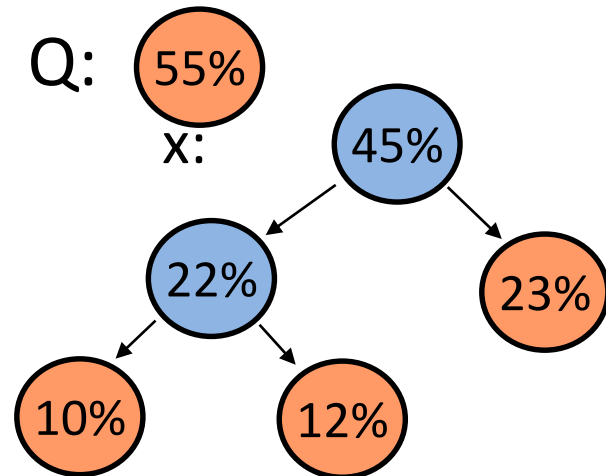
Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=3$




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=3$




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=3$




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$i=3$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=3$




Greedy Algorithmen – Datenkompression

Huffman(Σ)

1. $n \leftarrow |\Sigma|$
2. $Q \leftarrow \Sigma$ /* Priority Queue bzgl. $f[x]$ */
3. **for** $i \leftarrow 1$ **to** $n-1$ **do**
4. $x \leftarrow \text{deleteMin}(Q)$
5. $y \leftarrow \text{deleteMin}(Q)$
6. $z \leftarrow \text{new BinTree}(x, f[x]+f[y], y)$
7. $f[z] \leftarrow f[x] + f[y]$
8. $Q \leftarrow Q \cup \{z\}$
9. **return** $\text{deleteMin}(Q)$

$x \in \Sigma$	$f[x]$
a	23%
b	12%
c	55%
d	10%

$i=3$



Theorem

Der Huffman(Σ)-Alg. berechnet eine optimale Präfix-Kodierung.

Theorem

Der Huffman(Σ)-Alg. berechnet eine optimale Präfix-Kodierung.

Optimale durchschn. Codewortlänge

- Was ist die durchschnittliche Codewortlänge der Huffman-Codierung?
- Zur Einfachheit nehmen wir an, dass alle Frequenzen (rel. Häufigkeiten) von der Form $1/2^k$ sind

Beobachtung: Falls alle Frequenzen von der Form $1/2^k$ sind und $1/2^{k_{\min}}$ die kleinste Frequenz ist, dann hat es mindestens zwei Zeichen mit Frequenz $1/2^{k_{\min}}$.

Optimale durchschn. Codewortlänge

Lemma: Falls alle Frequenzen von der Form $1/2^k$ sind, dann hat ein Zeichen mit Frequenz $1/2^k$ ein Codewort der Länge genau k .

Optimale durchschn. Codewortlänge

Durchschnittliche Codewortlänge eines Huffman-Codes

- Annahme: Alle Frequenzen von der Form $1/2^k$

Häufigkeitsverteilung / Wahrscheinlichkeitsvert. $p(x)$

- Elemente X , Element $x \in X$ hat Frequenz $p(x)$

Entropie $H(X)$

$$H(X) := - \sum_{x \in X} p(x) \log_2 p(x)$$

- Untere Schranke für die optimale durchschn. Codewortlänge
- Im Grenzwert (genug lange Zeichenketten) kann man mit durchschn. Codewortlänge $H(X)$ codieren
- **Idee:**
 - Für genug grosses (konstantes) k , bestimme Codewort für jedes k -Tupel von Zeichen aus X
 - Verwende Huffman-Codierung

The End 😊
