Algorithmus zur komprimierten Übertragung von Textdaten an mobile Endgeräte

Sven Reinck

17. Januar 2007

Motivation

Wörterbuch

Wörterbuch

- Häufig vorkommende Buchstabengruppen werden in einem Wörterbuch gespeichert

Wörterbuch

- Häufig vorkommende Buchstabengruppen werden in einem Wörterbuch gespeichert
- Im Text steht dann nur noch eine Referenz

Wörterbuch

- Häufig vorkommende Buchstabengruppen werden in einem Wörterbuch gespeichert
- Im Text steht dann nur noch eine Referenz
- ASCII-Tabelle enthält viele unnötige Zeichen

Wörterbuch

- Häufig vorkommende Buchstabengruppen werden in einem Wörterbuch gespeichert
- Im Text steht dann nur noch eine Referenz
- ASCII-Tabelle enthält viele unnötige Zeichen
- Ersparnis = (Vorkommen - 1) · (Länge - 1)

Wörterbuch

- Häufig vorkommende Buchstabengruppen werden in einem Wörterbuch gespeichert
- Im Text steht dann nur noch eine Referenz
- ASCII-Tabelle enthält viele unnötige Zeichen
- Ersparnis = (Vorkommen - 1) · (Länge - 1)
- Zweier- und Dreier-Gruppen sind am ergiebiegsten

Wörterbuch

- Häufig vorkommende Buchstabengruppen werden in einem Wörterbuch gespeichert
- Im Text steht dann nur noch eine Referenz
- ASCII-Tabelle enthält viele unnötige Zeichen
- Ersparnis = (Vorkommen - 1) · (Länge - 1)
- Zweier- und Dreier-Gruppen sind am ergiebiegsten
- Einschränkung auf Zweier-Gruppen mit Rekursion

Statistiken aus Beispieltext

```
fischers fritz fischt frische fische
```

`fischers fritz fischt frische fische`

Paar	Vorkommen	Ersparnis
'sc'	4	3
'is'	4	3
'ch'	4	3
' f'	4	3
'he'	3	2
'fi'	3	2
'ri'	2	1
'fr'	2	1

Code	Ersetzung	Rekursiv
0	'sc'	'sc'

`fi0hers fritz fi0ht fri0he fi0he`

Paar	Vorkommen	Ersparnis
'i0'	4	3
'0h'	4	3
' f'	4	3
'he'	3	2
'fi'	3	2
'ri'	2	1
'fr'	2	1

Code	Ersetzung	Rekursiv
0	'sc'	'sc'
1	'i0'	'isc'

`f1hers fritz f1ht fr1he f1he`

Paar	Vorkommen	Ersparnis
'1h'	4	3
' f'	4	3
'he'	3	2
'f1'	3	2
'fr'	2	1

Code	Ersetzung	Rekursiv
0	'sc'	'sc'
1	'i0'	'isc'
2	'1h'	'isch'

`f2ers fritz f2t fr2e f2e`

Paar	Vorkommen	Ersparnis
' f'	4	3
'f2'	3	2
'2e'	3	2
'fr'	2	1

Code	Ersetzung	Rekursiv
0	'sc'	'sc'
1	'i0'	'isc'
2	'1h'	'isch'
3	' f'	' f'

`f2ers3ritz32t3r2e32e`

Paar	Vorkommen	Ersparnis
'2e'	3	2
'3r'	2	1
'32'	2	1

Code	Ersetzung	Rekursiv
0	'sc'	'sc'
1	'i0'	'isc'
2	'1h'	'isch'
3	' f'	' f'
4	'2e'	'ische'

`f4rs3ritz32t3r434`

Paar	Vorkommen	Ersparnis
'3r'	2	1

Code	Ersetzung	Rekursiv
0	'sc'	'sc'
1	'i0'	'isc'
2	'1h'	'isch'
3	' f'	' f'
4	'2e'	'ische'
5	'3r'	' fr'

f4rs5itz32t5434

1. Abschnitt

Methode	Overhead	Daten (%)	Gesamt (%)
unkomprimiert	0	2359 (100%)	2359 (100%)

ganzer Text

Methode	Overhead	Daten (%)	Gesamt (%)
unkomprimiert	0	16896 (100%)	16896 (100%)

1. Abschnitt

Methode	Overhead	Daten (%)	Gesamt (%)
unkomprimiert	0	2359 (100%)	2359 (100%)
Wörterbuch	449	848 (36%)	1297 (55%)

ganzer Text

Methode	Overhead	Daten (%)	Gesamt (%)
unkomprimiert	0	16896 (100%)	16896 (100%)
Wörterbuch	437	7899 (47%)	8336 (49%)

Huffman-Codierung

Huffman-Codierung

- unterschiedliche Häufigkeiten

Huffman-Codierung

- unterschiedliche Häufigkeiten
- häufige Buchstaben $\rightarrow$ kurze Codierung

Huffman-Codierung

- unterschiedliche Häufigkeiten
- häufige Buchstaben $\rightarrow$ kurze Codierung
- seltene Buchstaben $\rightarrow$ lange Codierung

Statistiken aus Beispieltext

Mississippi

Mississippi

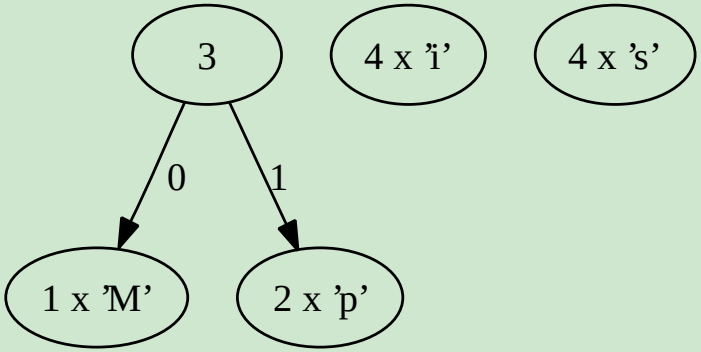

Mississippi

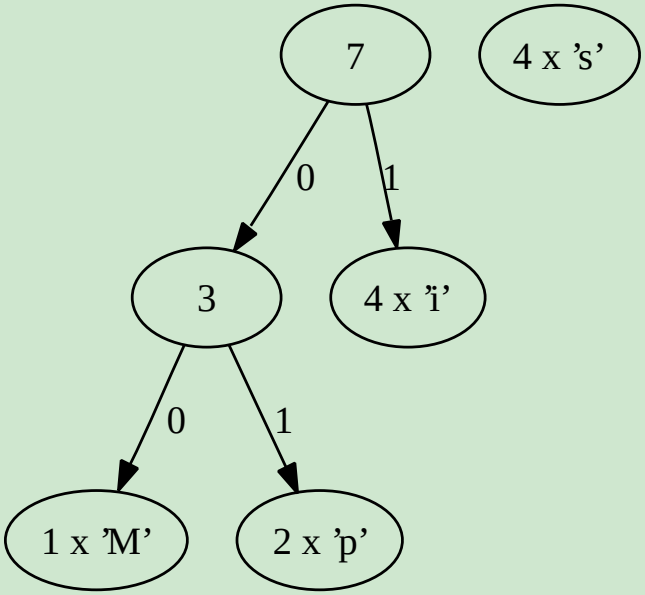

Mississippi

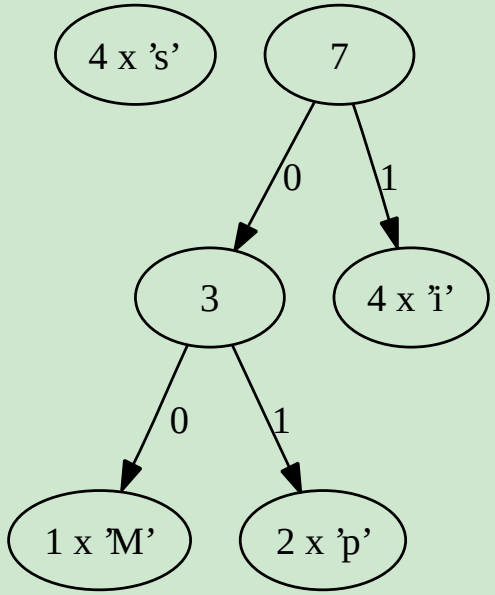

Mississippi

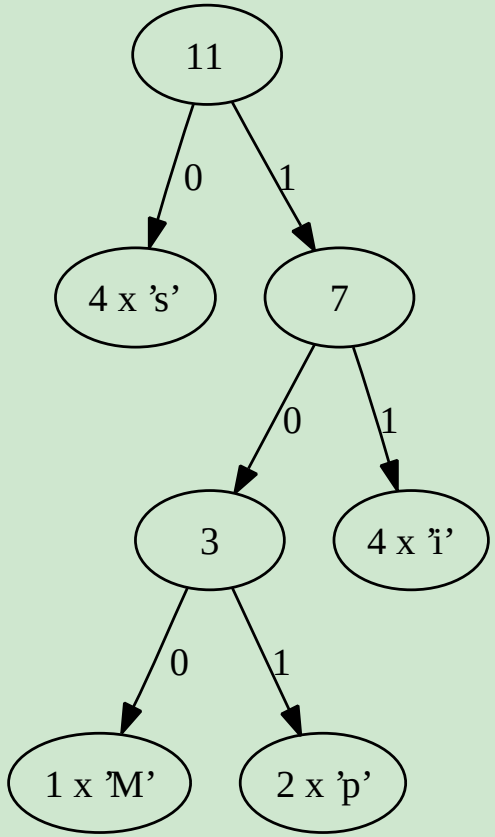

Tabelle

Zeichen	Bits
's'	0
'M'	100
'p'	101
'i'	11

Beispiel

M i s s i s s i p p i

Tabelle

Zeichen	Bits
's'	0
'M'	100
'p'	101
'i'	11

Beispiel

M i s s i s s i p p i

100

Tabelle

Zeichen	Bits
's'	0
'M'	100
'p'	101
'i'	11

Beispiel

M	i	s	s	i	s	s	i	p	p	i	
100	11										

Tabelle

Zeichen	Bits
's'	0
'M'	100
'p'	101
'i'	11

Beispiel

M	i	s	s	i	s	s	i	p	p	i
100	11	0								

Tabelle

Zeichen	Bits
's'	0
'M'	100
'p'	101
'i'	11

Beispiel

M	i	s	s	i	s	s	i	p	p	i
100	11	0	0							

Tabelle

Zeichen	Bits
's'	0
'M'	100
'p'	101
'i'	11

Beispiel

M	i	s	s	i	s	s	i	p	p	i
100	11	0	0	11						

Tabelle

Zeichen	Bits
's'	0
'M'	100
'p'	101
'i'	11

Beispiel

M	i	s	s	i	s	s	i	p	p	i
100	11	0	0	11	0					

Tabelle

Zeichen	Bits
's'	0
'M'	100
'p'	101
'i'	11

Beispiel

M	i	s	s	i	s	s	i	p	p	i
100	11	0	0	11	0	0				

Tabelle

Zeichen	Bits
's'	0
'M'	100
'p'	101
'i'	11

Beispiel

M	i	s	s	i	s	s	i	p	p	i
100	11	0	0	11	0	0	11			

Tabelle

Zeichen	Bits
's'	0
'M'	100
'p'	101
'i'	11

Beispiel

M	i	s	s	i	s	s	i	p	p	i
100	11	0	0	11	0	0	11	101		

Tabelle

Zeichen	Bits
's'	0
'M'	100
'p'	101
'i'	11

Beispiel

M	i	s	s	i	s	s	i	p	p	i
100	11	0	0	11	0	0	11	101	101	

Tabelle

Zeichen	Bits
's'	0
'M'	100
'p'	101
'i'	11

Beispiel

M	i	s	s	i	s	s	i	p	p	i
100	11	0	0	11	0	0	11	101	101	11

Huffman-Baum

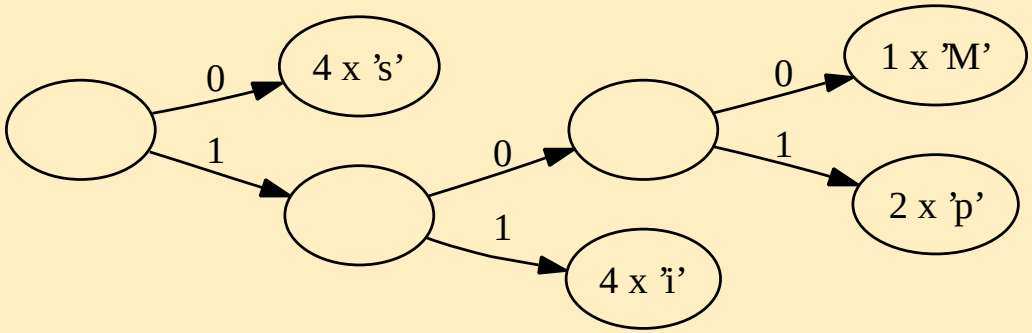

Beispiel

100 11 0 0 11 0 0 11 101 101 11

Huffman-Baum

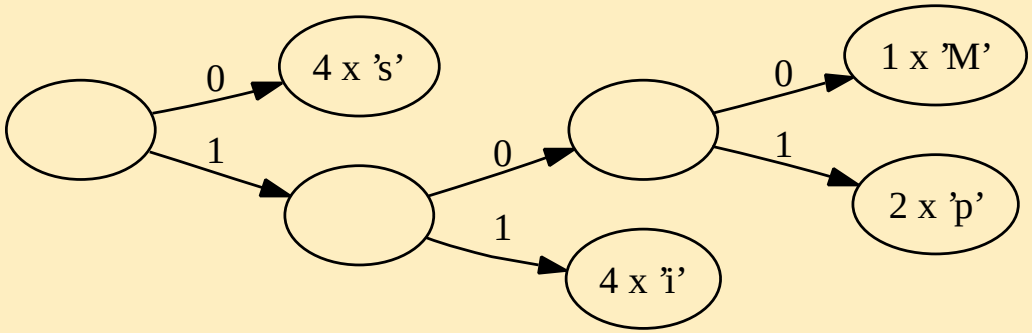

Beispiel

100	11	0	0	11	0	0	11	101	101	11
M										

Huffman-Baum

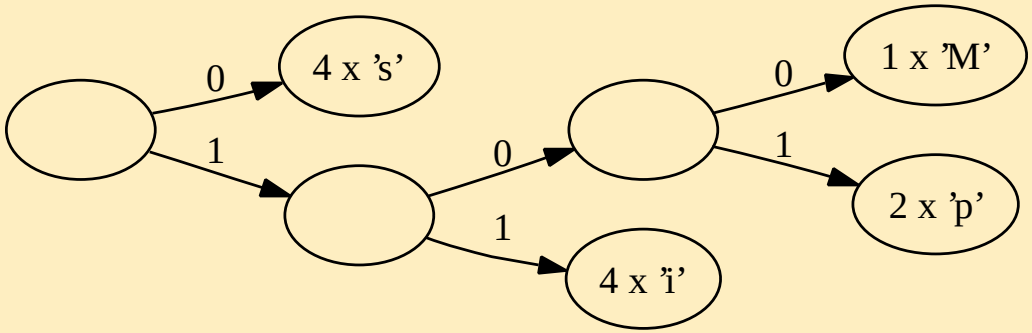

Beispiel

100	11	0	0	11	0	0	11	101	101	11
M	i									

Huffman-Baum

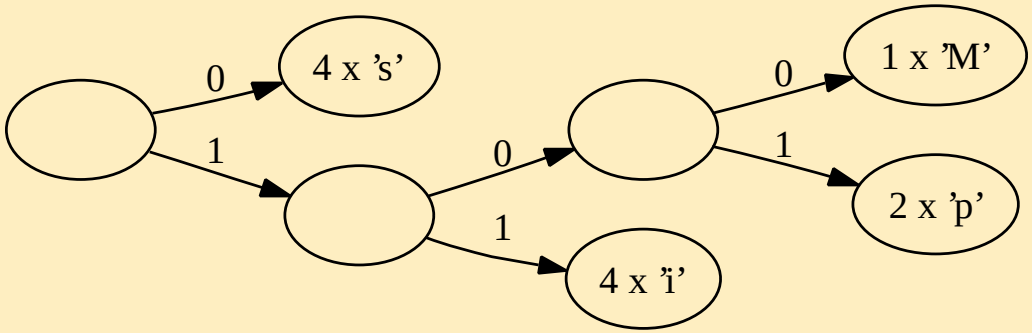

Beispiel

100	11	0	0	11	0	0	11	101	101	11
M	i	s								

Huffman-Baum

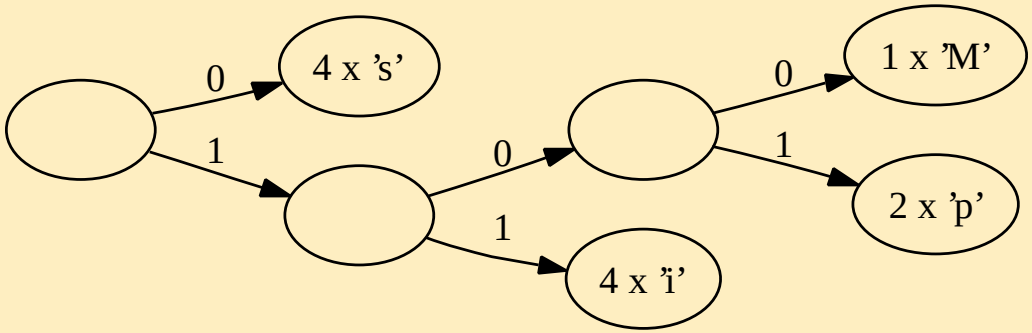

Beispiel

100	11	0	0	11	0	0	11	101	101	11
M	i	s	s							

Huffman-Baum

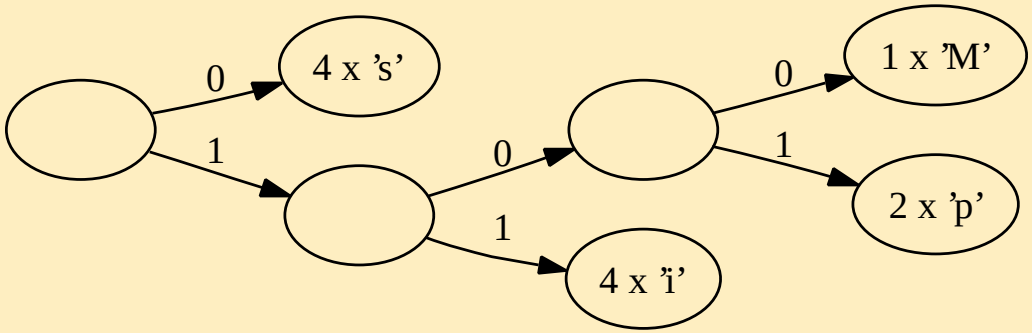

Beispiel

100	11	0	0	11	0	0	11	101	101	11
M	i	s	s	i						

Huffman-Baum

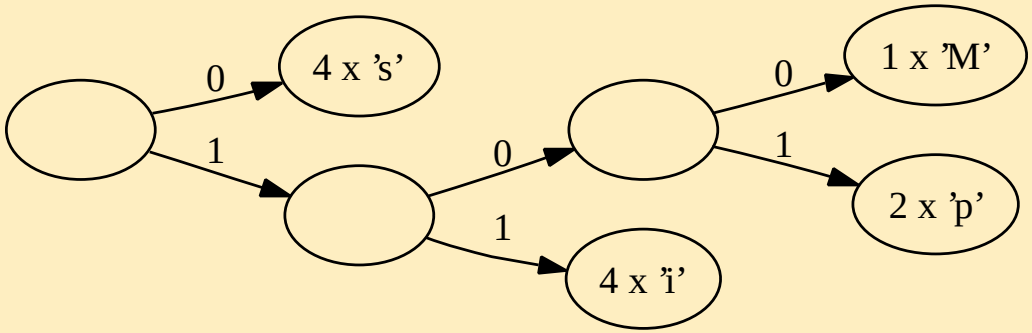

Beispiel

100	11	0	0	11	0	0	11	101	101	11
M	i	s	s	i	s					

Huffman-Baum

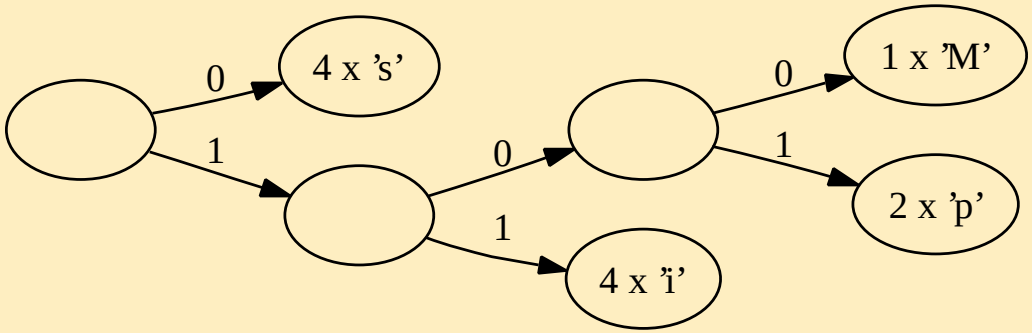

Beispiel

100	11	0	0	11	0	0	11	101	101	11
M	i	s	s	i	s	s				

Huffman-Baum

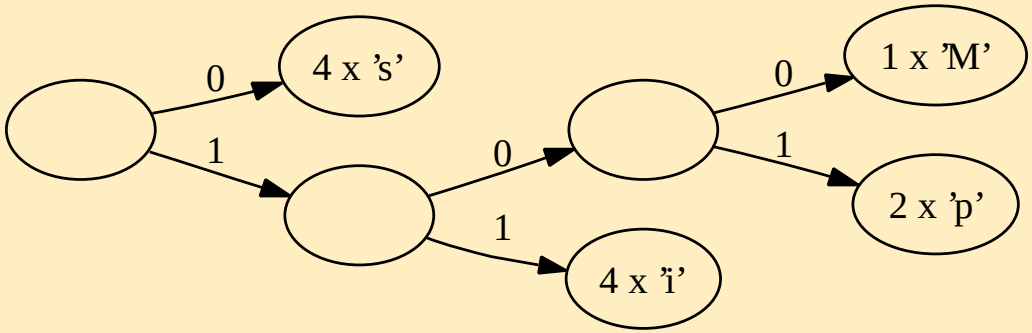

Beispiel

100	11	0	0	11	0	0	11	101	101	11
M	i	s	s	i	s	s	i			

Huffman-Baum

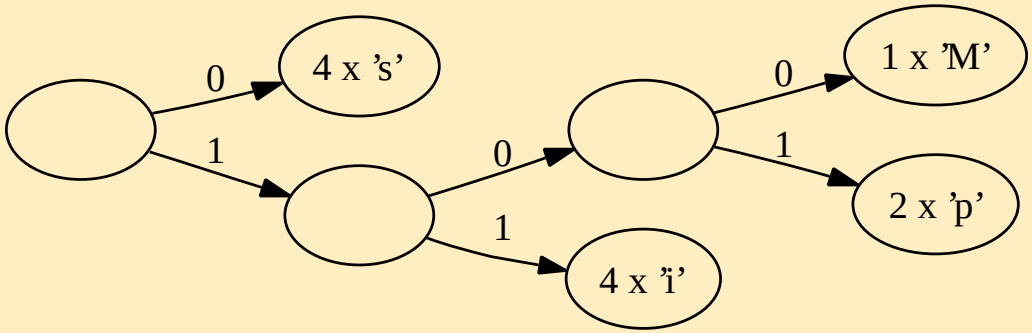

Beispiel

100	11	0	0	11	0	0	11	101	101	11
M	i	s	s	i	s	s	i	p		

Huffman-Baum

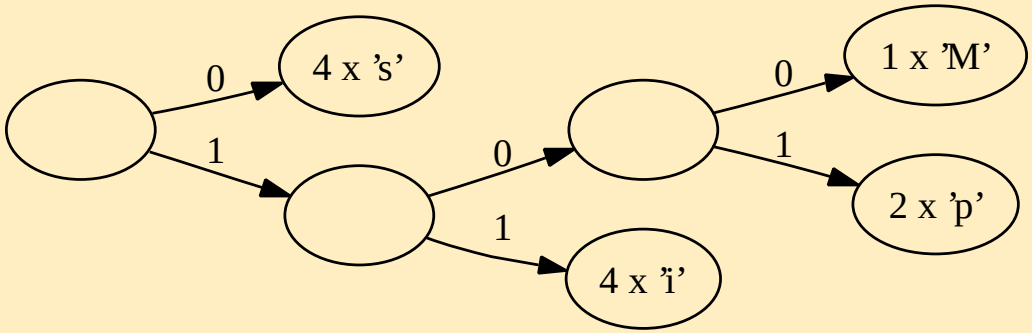

Beispiel

100	11	0	0	11	0	0	11	101	101	11
M	i	s	s	i	s	s	i	p	p	

Huffman-Baum

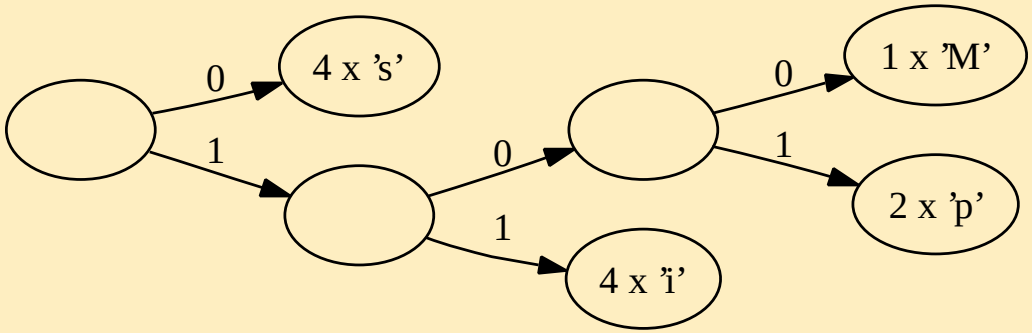

Beispiel

100	11	0	0	11	0	0	11	101	101	11
M	i	s	s	i	s	s	i	p	p	i

Tabelle

Zeichen	Länge	Bits
's'	1	0
'M'	3	100
'p'	3	101
'i'	2	11

Tabelle

Zeichen	Länge	Bits
's'	1	
'M'	3	
'p'	3	
'i'	2	

Tabelle

Zeichen	Länge	Bits
'M'	3	
'p'	3	
'i'	2	
's'	1	

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	
'i'	2	
's'	1	

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	
's'	1	

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Beispiel

M i s s i s s i p p i

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Beispiel

M i s s i s s i p p i
000

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01									

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1								

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1							

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01						

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1					

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1				

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01			

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001		

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	01

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Header

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Header

3

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Header

3 2 1 1

Tabelle

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Header

3 2 1 1 'M' 'p' 'i' 's'

Decodierer

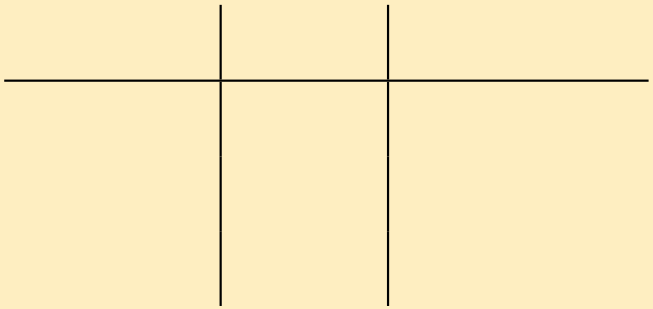

Codierer

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Header

3 2 1 1 'M' 'p' 'i' 's'

Decodierer

Länge		
3		
2		
1		

Codierer

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Header

3 2 1 1 'M' 'p' 'i' 's'

Decodierer

Länge	Bits	
3	000	
2	01	
1	1	

Codierer

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Header

3 2 1 1 'M' 'p' 'i' 's'

Decodierer

Länge	Bits	Zeichen
3	000	'M' 'p'
2	01	'i'
1	1	's'

Codierer

Zeichen	Länge	Bits
'M'	3	000
'p'	3	001
'i'	2	01
's'	1	1

Header

3 2 1 1 'M' 'p' 'i' 's'

Decodierer

Länge	Bits	Zeichen
3	000	'M' 'p'
2	01	'i'
1	1	's'

Beispiel

000 01 1 1 01 1 1 01 001 001 01

Decodierer

Länge	Bits	Zeichen
3	000	'M' 'p'
2	01	'i'
1	1	's'

Beispiel

000	01	1	1	01	1	1	01	001	001	01
M										

Decodierer

Länge	Bits	Zeichen
3	000	'M' 'p'
2	01	'i'
1	1	's'

Beispiel

000	01	1	1	01	1	1	01	001	001	01
M	i									

Decodierer

Länge	Bits	Zeichen
3	000	'M' 'p'
2	01	'i'
1	1	's'

Beispiel

000	01	1	1	01	1	1	01	001	001	01
M	i	s								

Decodierer

Länge	Bits	Zeichen
3	000	'M' 'p'
2	01	'i'
1	1	's'

Beispiel

000	01	1	1	01	1	1	01	001	001	01
M	i	s	s							

Decodierer

Länge	Bits	Zeichen
3	000	'M' 'p'
2	01	'i'
1	1	's'

Beispiel

000	01	1	1	01	1	1	01	001	001	01
M	i	s	s	i						

Decodierer

Länge	Bits	Zeichen
3	000	'M' 'p'
2	01	'i'
1	1	's'

Beispiel

000	01	1	1	01	1	1	01	001	001	01
M	i	s	s	i	s					

Decodierer

Länge	Bits	Zeichen
3	000	'M' 'p'
2	01	'i'
1	1	's'

Beispiel

000	01	1	1	01	1	1	01	001	001	01
M	i	s	s	i	s	s				

Decodierer

Länge	Bits	Zeichen
3	000	'M' 'p'
2	01	'i'
1	1	's'

Beispiel

000	01	1	1	01	1	1	01	001	001	01
M	i	s	s	i	s	s	i			

Decodierer

Länge	Bits	Zeichen
3	000	'M' 'p'
2	01	'i'
1	1	's'

Beispiel

000	01	1	1	01	1	1	01	001	001	01
M	i	s	s	i	s	s	i	p		

Decodierer

Länge	Bits	Zeichen
3	000	'M' 'p'
2	01	'i'
1	1	's'

Beispiel

000	01	1	1	01	1	1	01	001	001	01
M	i	s	s	i	s	s	i	p	p	

Decodierer

Länge	Bits	Zeichen
3	000	'M' 'p'
2	01	'i'
1	1	's'

Beispiel

000	01	1	1	01	1	1	01	001	001	01
M	i	s	s	i	s	s	i	p	p	i

1. Abschnitt

Methode	Overhead	Daten (%)	Gesamt (%)
unkomprimiert	0	2359 (100%)	2359 (100%)
Wörterbuch	449	848 (36%)	1297 (55%)

ganzer Text

Methode	Overhead	Daten (%)	Gesamt (%)
unkomprimiert	0	16896 (100%)	16896 (100%)
Wörterbuch	437	7899 (47%)	8336 (49%)

1. Abschnitt

Methode	Overhead	Daten (%)	Gesamt (%)
unkomprimiert	0	2359 (100%)	2359 (100%)
Wörterbuch	449	848 (36%)	1297 (55%)
Wb. + Huffman	672	773 (33%)	1445 (61%)

ganzer Text

Methode	Overhead	Daten (%)	Gesamt (%)
unkomprimiert	0	16896 (100%)	16896 (100%)
Wörterbuch	437	7899 (47%)	8336 (49%)
Wb. + Huffman	705	7282 (43%)	7987 (47%)

vorhersagendes Codieren

- bisher: kein Kontext

vorhersagendes Codieren

- bisher: kein Kontext
- In einigen Kontexten können nur bestimmte Zeichen folgen

vorhersagendes Codieren

- bisher: kein Kontext
- In einigen Kontexten können nur bestimmte Zeichen folgen
- Kombination mit Wörterbuch

vorhersagendes Codieren

- bisher: kein Kontext
- In einigen Kontexten können nur bestimmte Zeichen folgen
- Kombination mit Wörterbuch
- nur das letzte Zeichen eines Eintrags wird verwendet

Statistiken aus Beispieltext

Tabellen

Anfang	
'M'	

M	
'i'	

i	
'p'	0
's'	1

p	
'i'	0
'p'	1

s	
'i'	0
's'	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	01

Tabellen

Anfang	
'M'	

M	
'i'	

i	
'p'	0
's'	1

p	
'i'	0
'p'	1

s	
'i'	0
's'	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	01
x										

Tabellen

Anfang	
'M'	

M	
'i'	

i	
'p'	0
's'	1

p	
'i'	0
'p'	1

s	
'i'	0
's'	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	01
x	x									

Tabellen

Anfang	
'M'	

M	
'i'	

i	
'p'	0
's'	1

p	
'i'	0
'p'	1

s	
'i'	0
's'	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	01
x	x	1								

Tabellen

Anfang	
'M'	

M	
'i'	

i	
'p'	0
's'	1

p	
'i'	0
'p'	1

s	
'i'	0
's'	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	01
x	x	1	1							

Tabellen

Anfang	
'M'	

M	
'i'	

i	
'p'	0
's'	1

p	
'i'	0
'p'	1

s	
'i'	0
's'	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	01
x	x	1	1	0						

Tabellen

Anfang	
'M'	

M	
'i'	

i	
'p'	0
's'	1

p	
'i'	0
'p'	1

s	
'i'	0
's'	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	01
x	x	1	1	0	1					

Tabellen

Anfang	
'M'	

M	
'i'	

i	
'p'	0
's'	1

p	
'i'	0
'p'	1

s	
'i'	0
's'	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	01
x	x	1	1	0	1	1				

Tabellen

Anfang
'M'	

M
'i'	

i	
'p'	0
's'	1

p	
'i'	0
'p'	1

s	
'i'	0
's'	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	01
x	x	1	1	0	1	1	0			

Tabellen

Anfang	
'M'	

M	
'i'	

i	
'p'	0
's'	1

p	
'i'	0
'p'	1

s	
'i'	0
's'	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	01
x	x	1	1	0	1	1	0	0		

Tabellen

Anfang
'M'	

M
'i'	

i	
'p'	0
's'	1

p	
'i'	0
'p'	1

s	
'i'	0
's'	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	01
x	x	1	1	0	1	1	0	0	1	

Tabellen

Anfang	
'M'	

M	
'i'	

i	
'p'	0
's'	1

p	
'i'	0
'p'	1

s	
'i'	0
's'	1

Beispiel

M	i	s	s	i	s	s	i	p	p	i
000	01	1	1	01	1	1	01	001	001	01
x	x	1	1	0	1	1	0	0	1	0

1. Abschnitt

Methode	Overhead	Daten (%)	Gesamt (%)
unkomprimiert	0	2359 (100%)	2359 (100%)
Wörterbuch	449	848 (36%)	1297 (55%)
Wb. + Huffman	672	773 (33%)	1445 (61%)

ganzer Text

Methode	Overhead	Daten (%)	Gesamt (%)
unkomprimiert	0	16896 (100%)	16896 (100%)
Wörterbuch	437	7899 (47%)	8336 (49%)
Wb. + Huffman	705	7282 (43%)	7987 (47%)

1. Abschnitt

Methode	Overhead	Daten (%)	Gesamt (%)
unkomprimiert	0	2359 (100%)	2359 (100%)
Wörterbuch	449	848 (36%)	1297 (55%)
Wb. + Huffman	672	773 (33%)	1445 (61%)
Wb. + Context	1216	464 (20%)	1680 (71%)

ganzer Text

Methode	Overhead	Daten (%)	Gesamt (%)
unkomprimiert	0	16896 (100%)	16896 (100%)
Wörterbuch	437	7899 (47%)	8336 (49%)
Wb. + Huffman	705	7282 (43%)	7987 (47%)
Wb. + Context	2446	5253 (31%)	7699 (46%)

Xenia: Komprimierung von XML

Xenia: Komprimierung von XML

computerwoche.de (18.12.2006):
"Mit 'Xenia' können XML-Daten auf 1 bis 15 Prozent ihrer ursprünglichen Größe komprimiert werden"