# 2. Digitale Codierung und Übertragung

2.1 Informationstheoretische Grundlagen

- 2.1.1 Abtasttheorem
- 2.1.2 Stochastische Nachrichtenquelle, Entropie, Redundanz

2.2 Verlustfreie universelle Kompression

Medieninformatik-Buch:
Kapitel 2


**Weiterführende** Literatur zum Thema Informationstheorie:

Taschenbuch Medieninformatik Kapitel 2

Herbert Klimant, Rudi Piotraschke, Dagmar Schönfeld: Informations- und Kodierungstheorie, Teubner 2003

# Digitalisierungsfehler (Wiederholung)

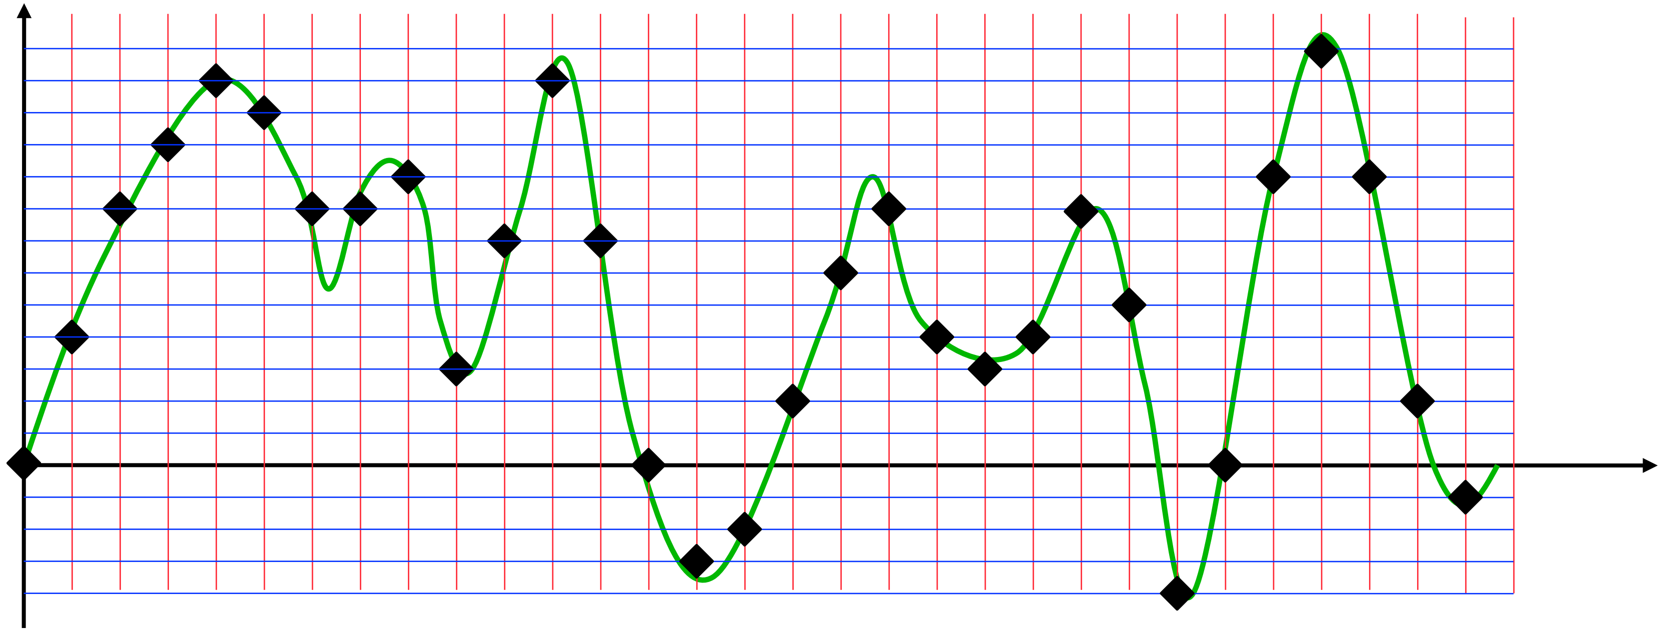

- Durch zu grobe Raster bei Diskretisierung und Quantisierung entstehen *Digitalisierungsfehler.*

# Digitalisierungsfehler

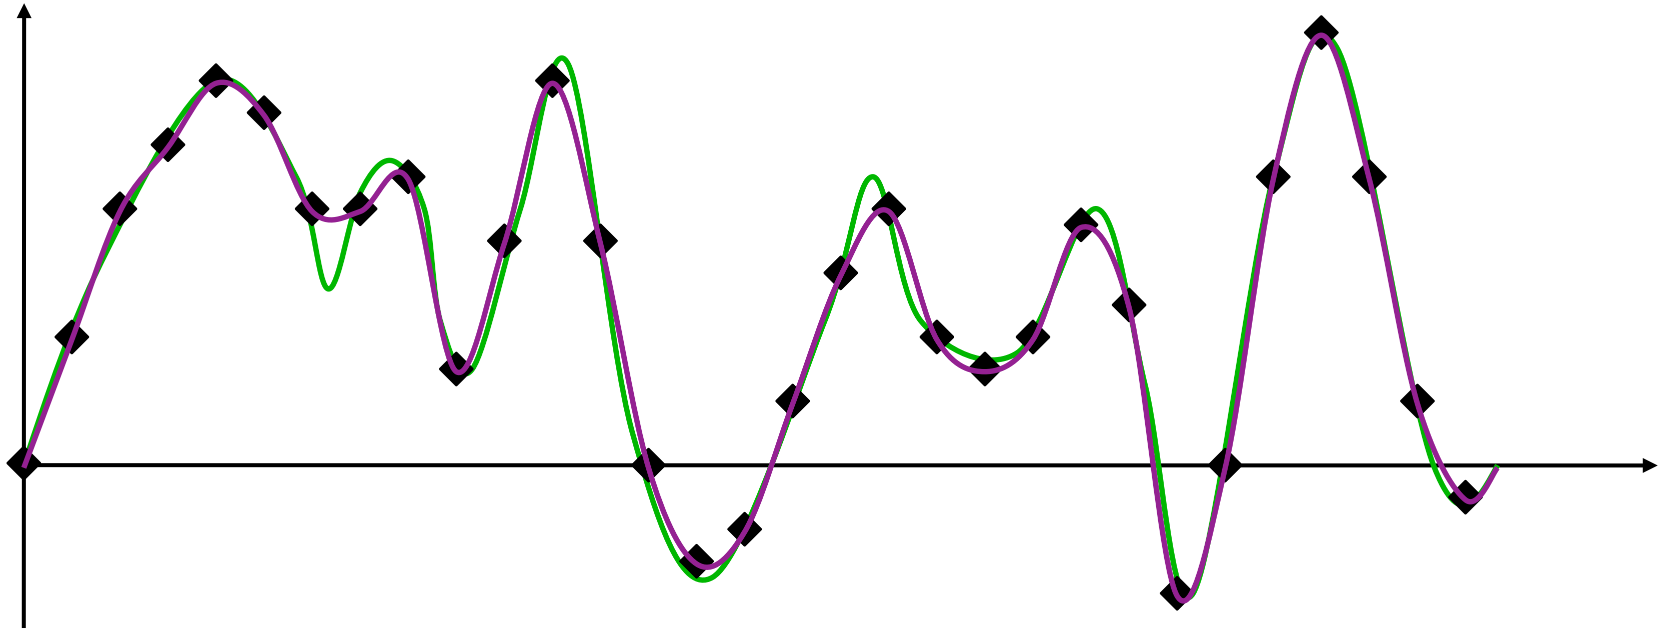

- Fehlerklassen:
  - Zu grobe Quantisierung: Schlechtere Darstellung von Abstufungen
  - Zu grobe Diskretisierung, d.h. Fehler in der Abtastrate: Zusammenhang schwerer zu verstehen; führt zu gravierenden Fehlern!

# Abtastrate: Einführendes Beispiel

***Warum drehen sich in Kinofilmen die Räder von Kutschen oft scheinbar rückwärts?***

# Abtastrate: Einführendes Beispiel

***Warum drehen sich in Kinofilmen die Räder von Kutschen oft scheinbar rückwärts?***

Rad (über die Zeit):

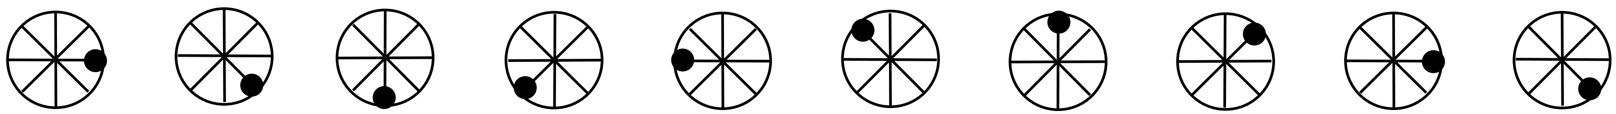

Aufnahmen (über die Zeit):

# Abtastrate: Einführendes Beispiel

***Warum drehen sich in Kinofilmen die Räder von Kutschen oft scheinbar rückwärts?***

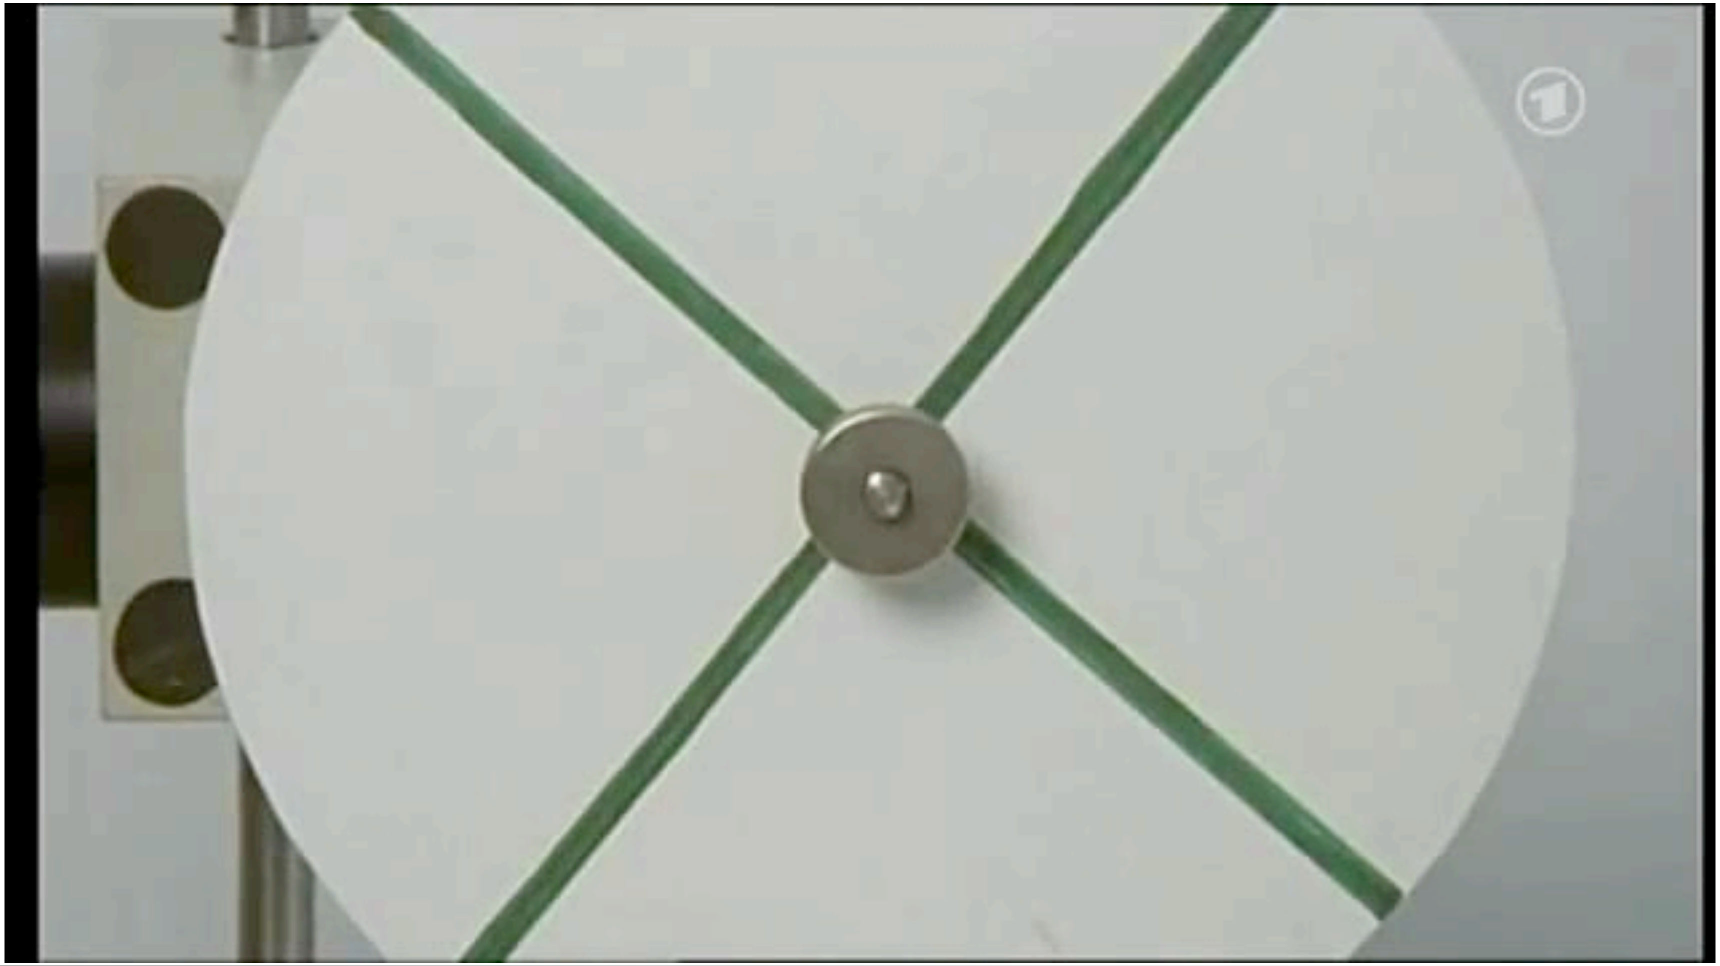

# Frequenz

- Die Frequenz ist ein Maß für die Häufigkeit eines wiederkehrenden Ereignisses
- Maßeinheit:
  - *Hertz*, 1 Hz = 1/s
  - 1 Hz bedeutet einmal pro Sekunde
- Wiederkehr
  - Länge des Signalverlaufs bis zum Beginn der nächsten Wiederholung
  - Wellenlänge bei einer Sinusfunktion
  - Wiederkehr $T$ bei gegebener Frequenz $f$:

$$T = \frac{1}{f}$$

Hier zeitabhängige Signale – aber übertragbar auf raumabhängige Signale

# Periodische Signale aus Sinus-Schwingungen

- Vereinfachung 1: Wir betrachten nur periodische Signale
  - Reale Signale sind nicht periodisch
- Vereinfachung 2: Wir betrachten nur reine Sinus-Schwingungen
  - Reale Signale können andere Kurvenformen aufweisen
- (Siehe später für die Verallgemeinerung)
- Annahme: Überlagerung mehrerer Sinus-Schwingungen

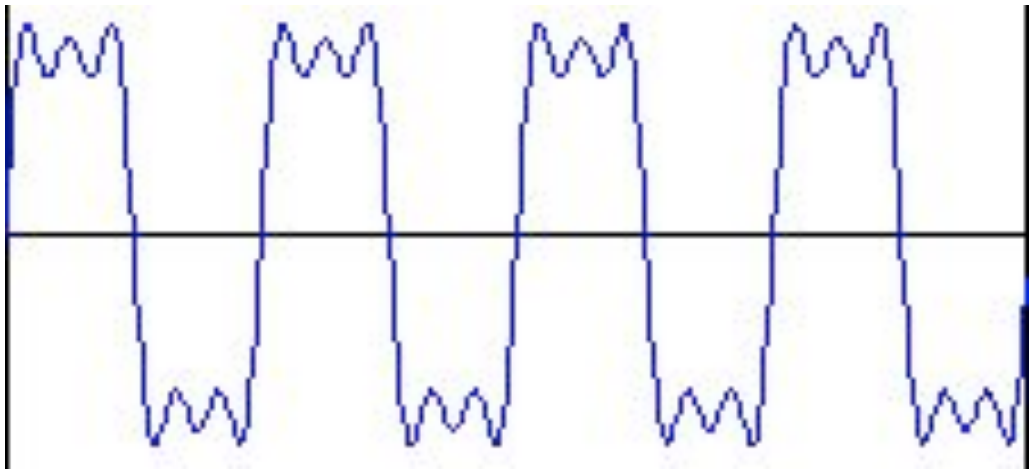

Beispiel:

Überlagerung von Signalen mit 50 Hz (Grundfrequenz), 100 Hz und 150 Hz

# Zu niedrige Abtastrate

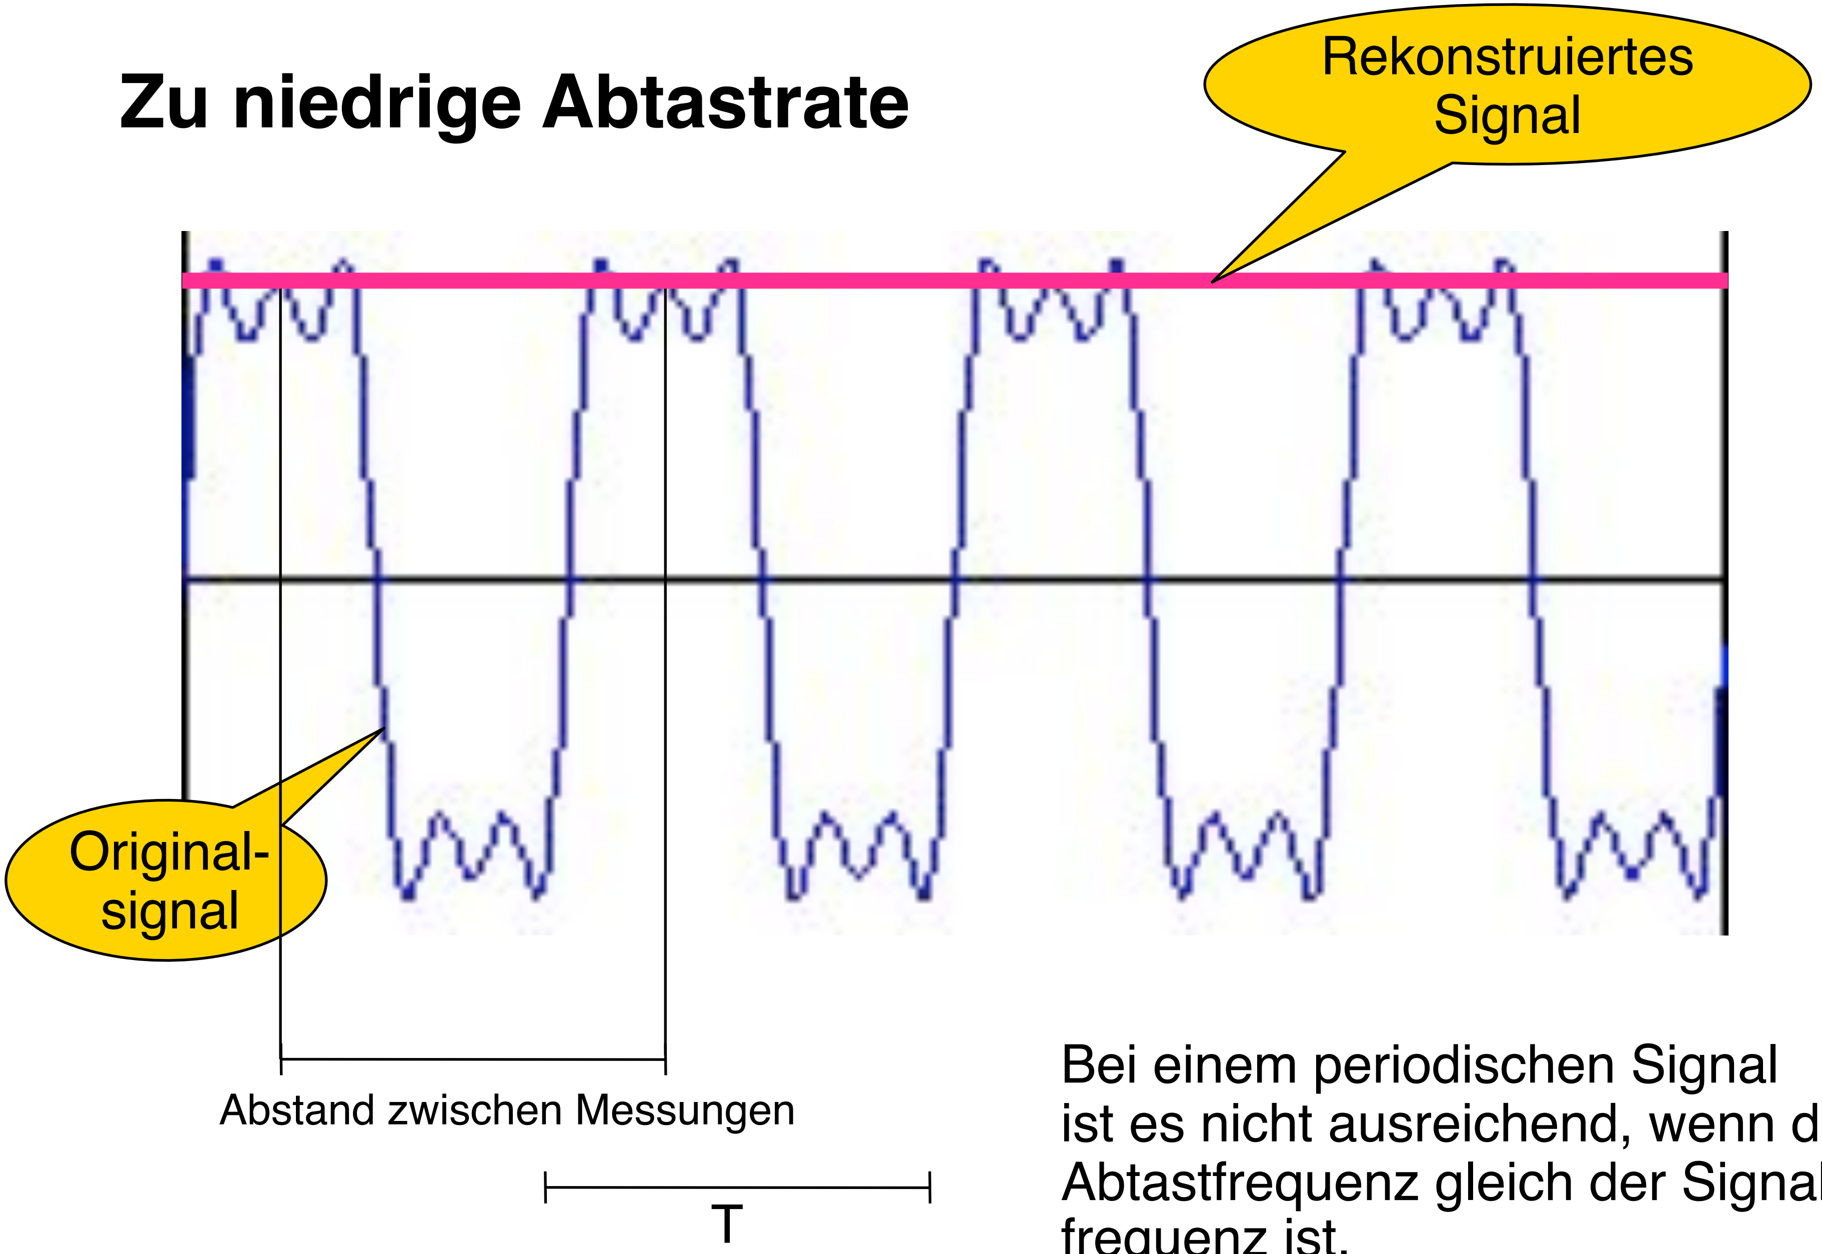


Bei einem periodischen Signal ist es nicht ausreichend, wenn die Abtastfrequenz gleich der Signal-frequenz ist.

# Immer noch zu niedrige Abtastrate

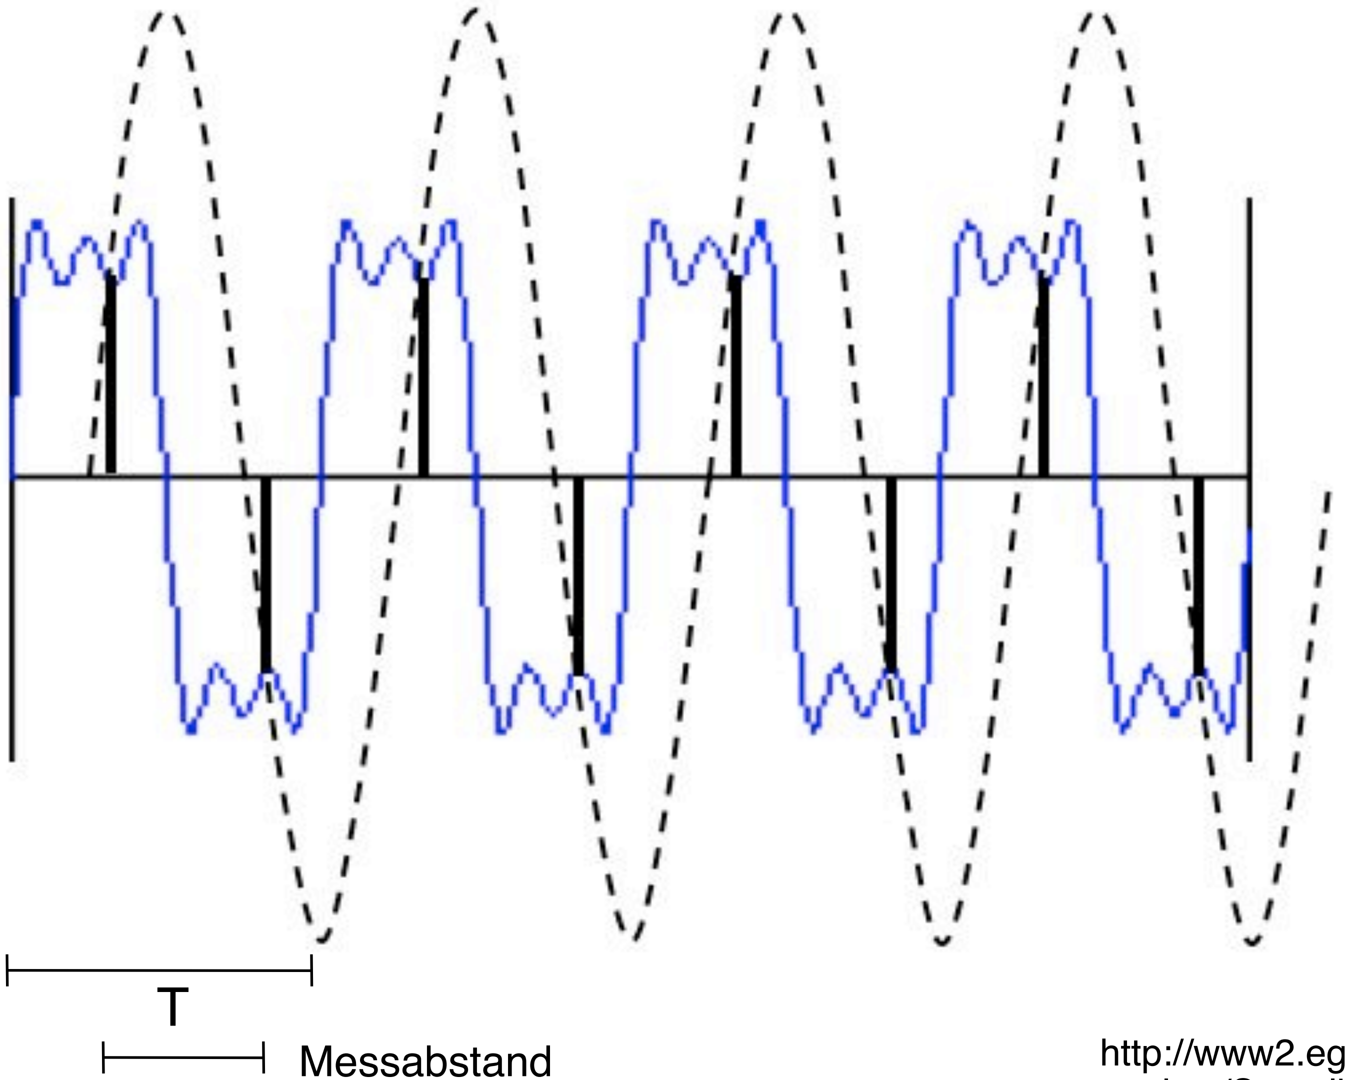


http://www2.egr.uh.edu/~glover/applets/Sampling/Sampling.html

# Bandbegrenzung

- Reale Signale bestehen immer aus einer Überlagerung von Signalanteilen verschiedener Frequenzen
- „Bandbreite“ = Bereich der niedrigsten und höchsten vorkommenden Frequenzen
  - Untere Grenzfrequenz
  - Obere Grenzfrequenz
- Grundfrequenz = Frequenz der Wiederholung des Gesamtsignals (bei periodischen Signalen)

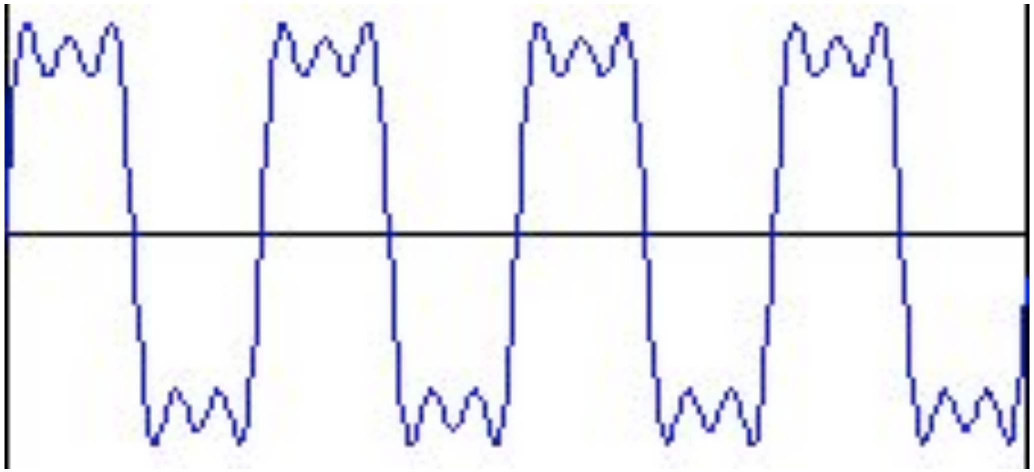

Beispiel:

Überlagerung von Signalen mit 50 Hz (Grundfrequenz), 100 Hz und 150 Hz

# Abtasttheorem

Nach Harry Nyquist (1928) oft auch Nyquist-Theorem genannt.
(Beweis von Claude Shannon)

Wenn eine Funktion

mit höchster vorkommender Frequenz $f_g$ (Bandbegrenzung)

mit einer Abtastrate $f_S$ abgetastet wird, so dass

$$f_S > 2 * f_g \ ,$$

dann kann die Funktion eindeutig aus den Abtastwerten rekonstruiert werden.

Praktisches Beispiel: Abtastrate für Audio-CDs ist 44,1 kHz
(eindeutige Rekonstruktion von Signalen bis ca. 22 kHz)

# Aliasing: Bildbeispiele

Bei Bildern liefert unzureichende Abtastung sogenannte *Moiré-Effekte.*

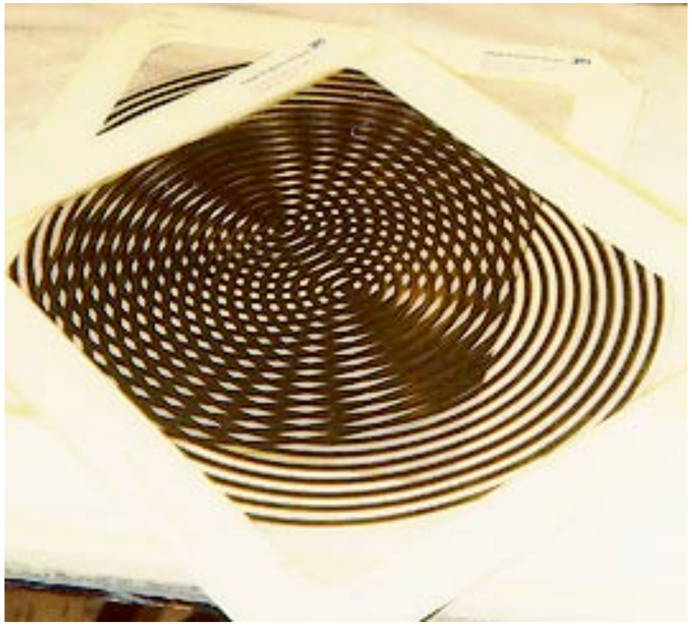

Moiré-Muster durch Überlagerung von Ringmustern (physics.uiuc.edu)

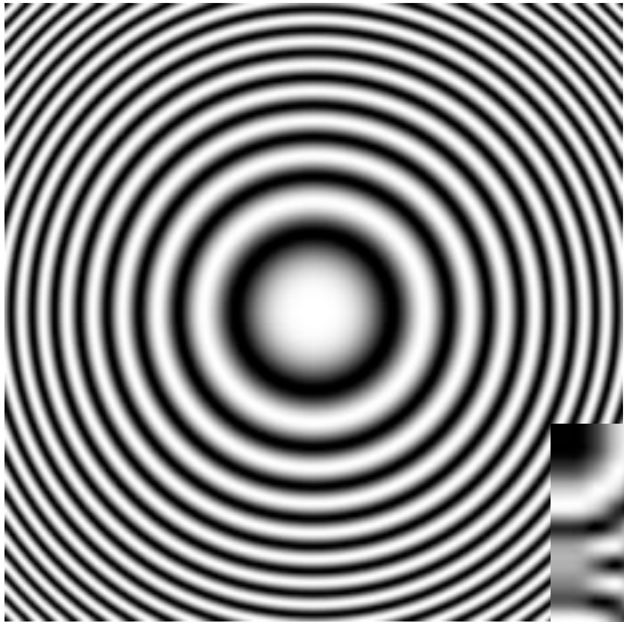

"Fresnel-Zonenplatte"

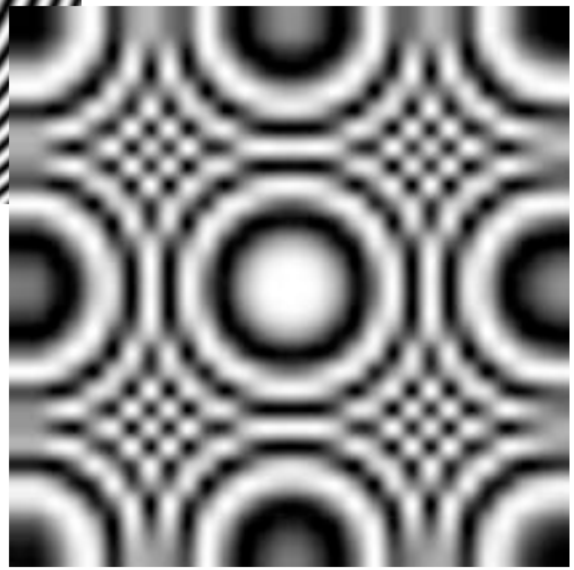

abgetastet mit 30 Punkten je Kante und rekonstruiert

# Moiré im Foto

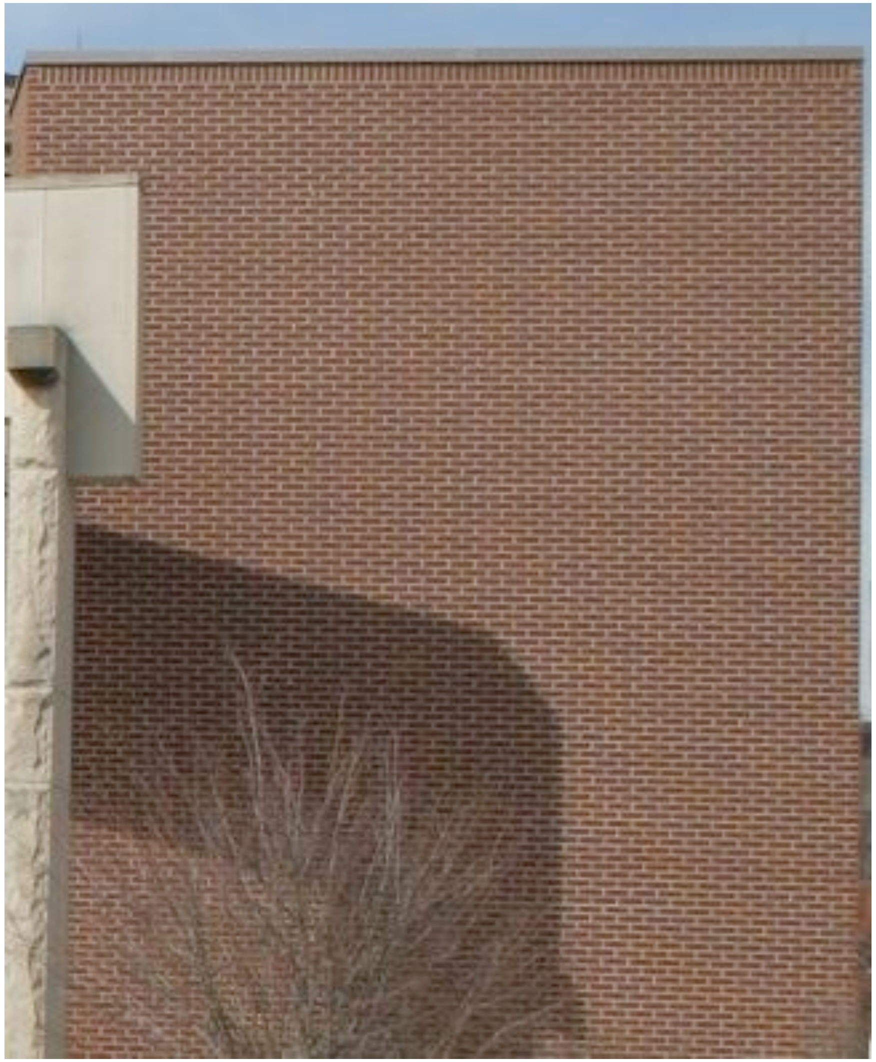

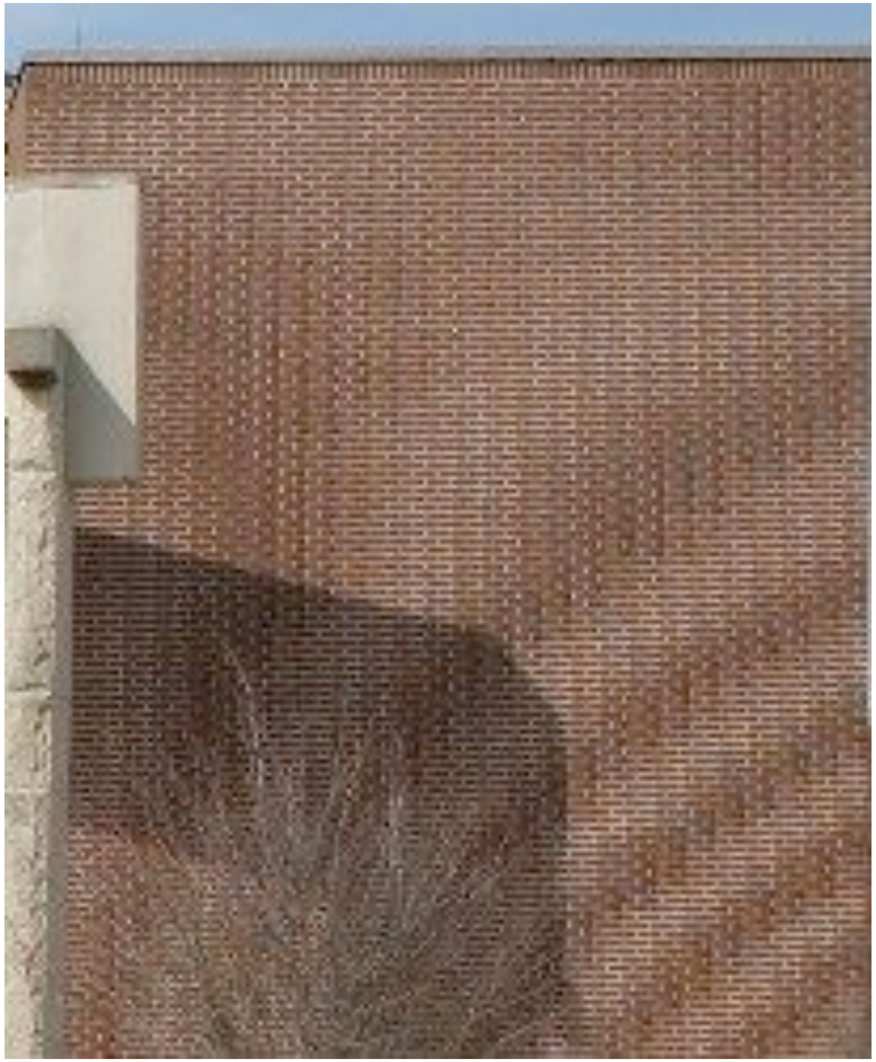

Quelle:Wikipedia

# Aliasing: Audio-Beispiel

- Bei einer nicht genügend hohen Abtastrate entstehen Fehlinterpretationen der hochfrequenten Signalanteile *(Aliasing)*
- Beispiel Audio: Hohe Töne werden als tiefe Töne rekonstruiert.

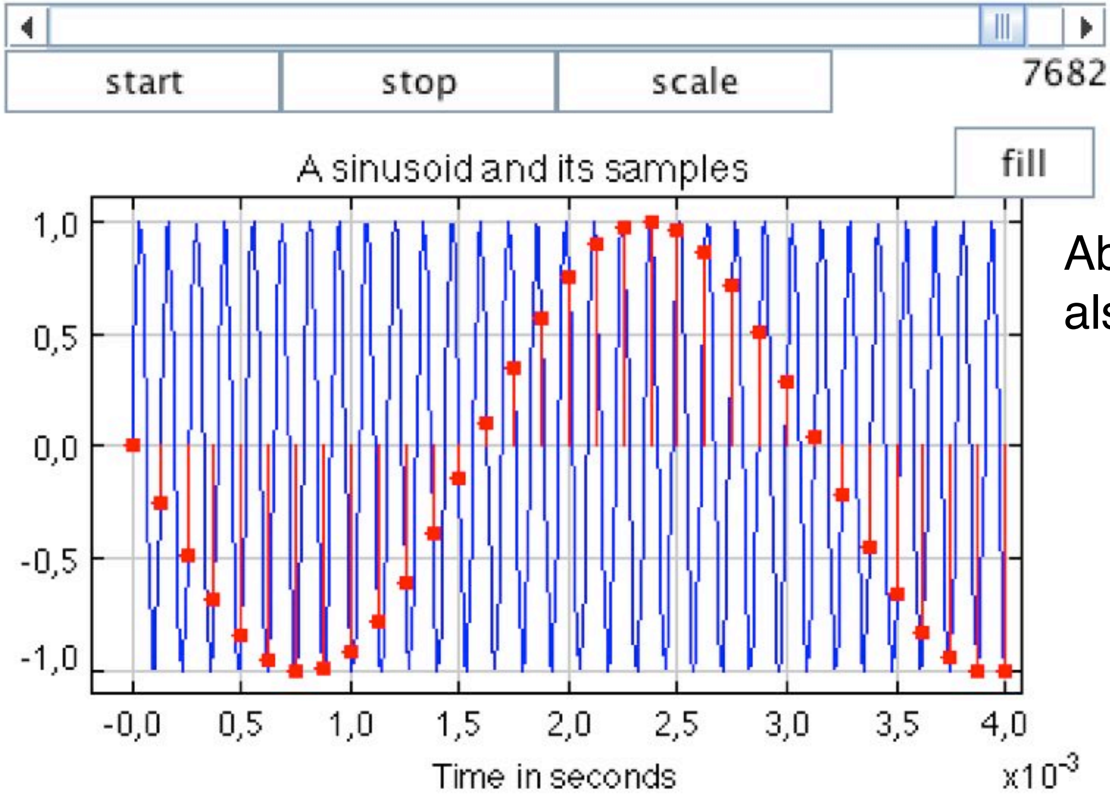


Abtastfrequenz 8 kHz,
also Aliasing oberhalb 4 kHz

http://ptolemy.eecs.berkeley.edu/eecs20/week13/aliasing.html

# Vermeidung von Aliasing: Filterung

- Vor digitaler Abtastung: Nyquist-Bedingung sicherstellen!
- Wenn höherfrequente Anteile ($\geq 1/2\ f_S$) vorhanden,
  - Entfernen!
- Filterung
  - Bei Bildern und Ton anwendbar
- Anwendungsbeispiele:
  - Hochauflösendes Bild soll neu abgetastet werden
  - Signal aus einem Tongenerator soll abgetastet werden (z.B. Sägezahnsignal)

# Wie perfekt ist die Rekonstruktion?

- Das Nyquist-Theorem ist ein mathematisches Theorem.
  - ***Keinerlei Verlust*** bei Rekonstruktion innerhalb der angegebenen Rahmenbedingungen
- Mathematische Rekonstruktion mit „idealem Tiefpass"
  - Siehe später!
- Praktische Rekonstruktion
  - Zum Teil sehr aufwändige Systeme für optimale Anpassung an Wahrnehmungsphysiologie
- Praktisches Beispiel:
  - Vergleich der Klangqualität von CD-Spielern
    (an der gleichen Stereoanlage)

# 2. Digitale Codierung und Übertragung

2.1 Informationstheoretische Grundlagen

2.1.1 Abtasttheorem

2.1.2 Stochastische Nachrichtenquelle, Entropie, Redundanz

2.2 Verlustfreie universelle Kompression

**Weiterführende** Literatur zum Thema Informationstheorie:

Taschenbuch Medieninformatik Kapitel 2

Herbert Klimant, Rudi Piotraschke, Dagmar Schönfeld: Informations- und Kodierungstheorie, Teubner 2003

# Einschub: Motivation für Informationstheorie

- Aufbau eines MPEG-Layer III (MP3) Encoders
  - Details siehe später!

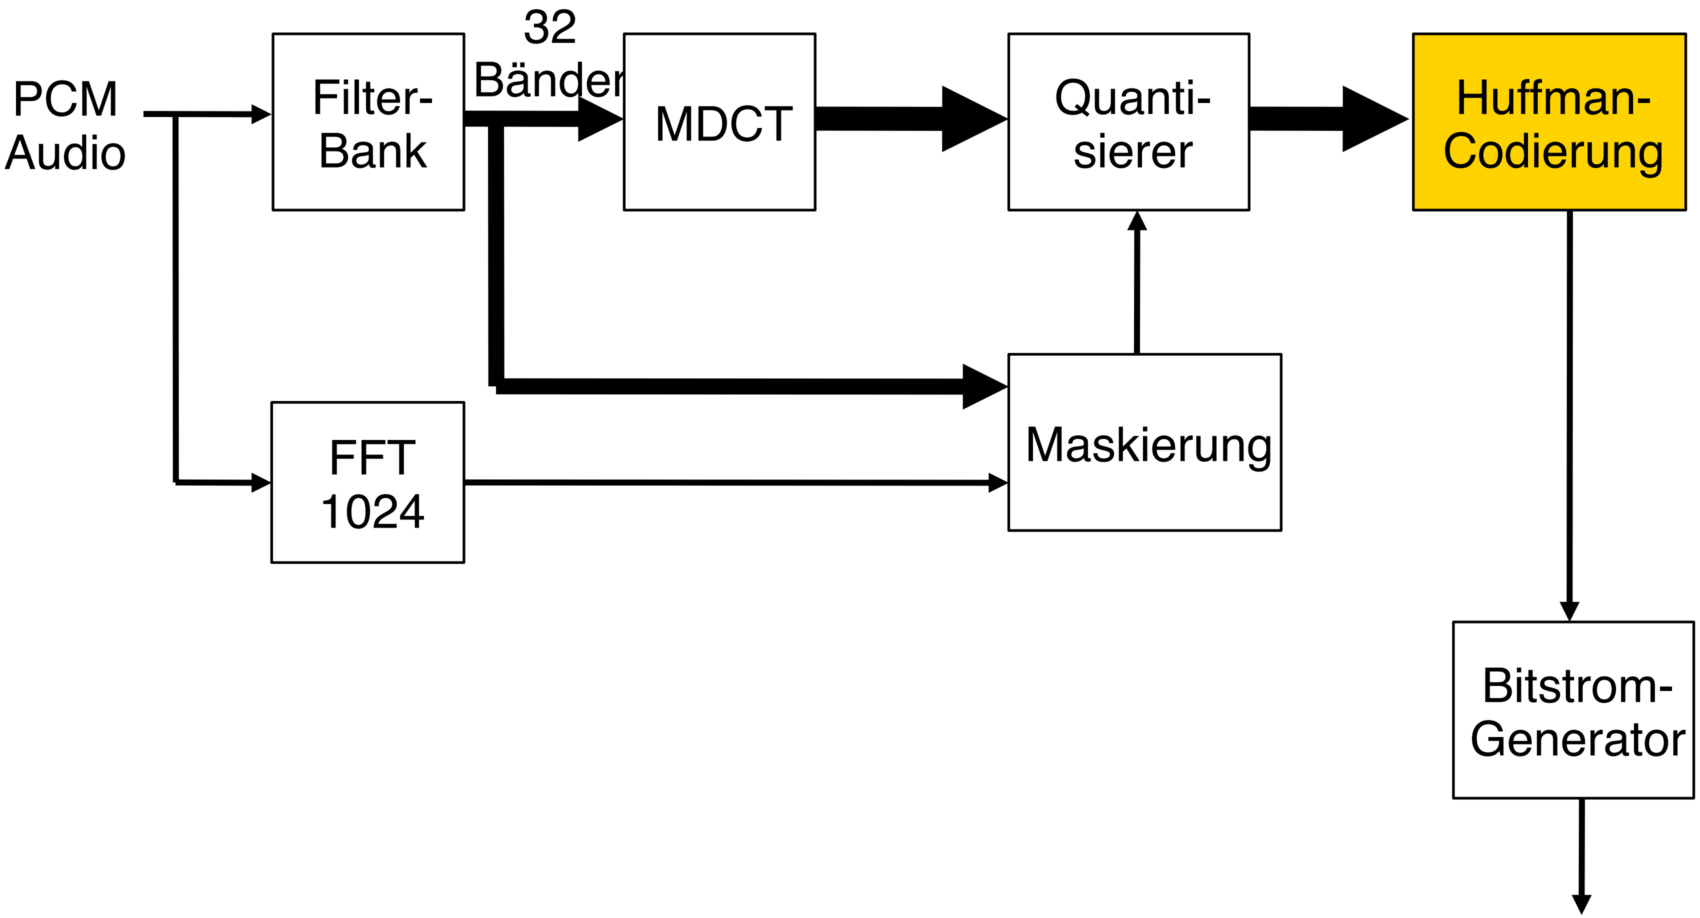

# Stochastische Informationstheorie: Zeichenvorrat und Codierung

- Ein *Zeichenvorrat* ist eine endliche Menge von *Zeichen*.
- Eine Nachricht (im Zeichenvorrat A) ist eine Sequenz von Zeichen aus A
- Seien A und B Zeichenvorräte.
  Eine *Codierung c* ist eine Abbildung von Nachrichten in A auf Nachrichten in B.

  $c: A \rightarrow B^*$ ($B^*$ : Zeichenreihen über $B$)
- Wir beschränken uns meist auf *binäre* Codierungen, d.h. B = { 0, 1 }
- *Informationstheorie* (nach *Shannon*) betrachtet die Häufigkeit des Auftretens bestimmter Zeichen(folgen) in den Nachrichten einer Nachrichtenquelle.

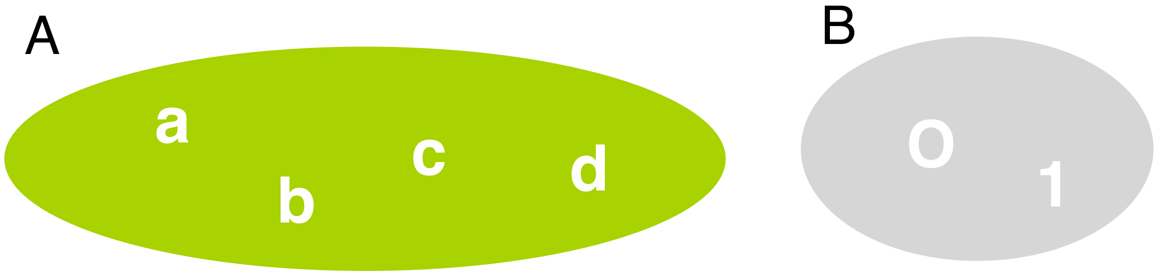


Beispiel:

abca $\rightarrow$ 00011000

ddc $\rightarrow$ 111110

# Entropie (1)

- Annahme *Stochastische Nachrichtenquelle:* Wir kennen die Häufigkeitsverteilung der Zeichen in den Nachrichten.
- *Entscheidungsgehalt* (*Entropie*) der Nachrichtenquelle:
  - Wie viele Ja/Nein-Entscheidungen ($x_a$) entsprechen dem Auftreten eines Einzelzeichens ($a$)?
  - Eine Ja/Nein-Entscheidung = 1 „bit“
- Beispiele:

Quelle 1

| Zeichen $a$ | A | B | C | D |
|---|---|---|---|---|
| Häufigk. $p_a$ | 1 | 0 | 0 | 0 |
| $x_a$ | 0 | - | - | - |

Quelle 2

| Zeichen $a$ | A | B | C | D |
|---|---|---|---|---|
| Häufigk. $p_a$ | 0.25 | 0.25 | 0.25 | 0.25 |
| $x_a$ | 2 | 2 | 2 | 2 |

$p_a$ = Häufigkeit

$x_a$ = Zahl der Entscheidungen

$$2^{x_a} = 1/p_a$$

$$x_a = \mathrm{ld}\ (1/p_a)$$

(Logarithmus zur Basis 2)

# Entropie (2)

*Durchschnittlicher* Entscheidungsgehalt je Zeichen: *Entropie H*

$$\boxed{H = \sum_{a \in A} p_a \, ld\left(\frac{1}{p_a}\right)}$$

mit $x_a$ = ld $(1/p_a)$: $H = \sum_{a \in A} p_a x_a$

Quelle 1

| Zeichen $a$ | A | B | C | D |
|---|---|---|---|---|
| Häufigk. $p_a$ | 1 | 0 | 0 | 0 |
| $x_a$ | 0 | - | - | - |

$H = 0$

Quelle 2

| Zeichen $a$ | A | B | C | D |
|---|---|---|---|---|
| Häufigk. $p_a$ | 0.25 | 0.25 | 0.25 | 0.25 |
| $x_a$ | 2 | 2 | 2 | 2 |

$H = 2$

Quelle 3

| Zeichen $a$ | A | B | C | D |
|---|---|---|---|---|
| Häufigk. $p_a$ | 0.5 | 0.25 | 0.125 | 0.125 |
| $x_a$ | 1 | 2 | 3 | 3 |

$H = 1.75$

Entropie ist Maß für „Unordnung“, „Zufälligkeit“

# Wortlängen und Redundanz

- Eine (Binär-)Codierung der Nachrichten einer stochastischen Nachrichtenquelle ergibt eine *durchschnittliche Wortlänge L*.

$$\boxed{L = \sum_{a \in A} p_a \left| c(a) \right|}$$

Quelle 2

| Zeichen $a$ | A | B | C | D |
|---|---|---|---|---|
| Häufigk. $p_a$ | 0.25 | 0.25 | 0.25 | 0.25 |
| Code $c(a)$ | 00 | 01 | 10 | 11 |

$H = 2$
$L = 2$

Quelle 3

| Zeichen $a$ | A | B | C | D |
|---|---|---|---|---|
| Häufigk. $p_a$ | 0.5 | 0.25 | 0.125 | 0.125 |
| Code $c(a)$ | 00 | 01 | 10 | 11 |

$H = 1.75$
$L = 2$

- $\boxed{\textit{Redundanz} = L - H}$
- Redundanz ist ein Maß für die Güte der Codierung: möglichst klein!

# Optimale Codierung

- Eine Codierung ist *optimal*, wenn die Redundanz 0 ist.
- Durch geeignete Codierung (z.B. Wortcodierung statt Einzelzeichencodierung) kann man die Redundanz beliebig niedrig wählen.
- Redundanz ermöglicht andererseits die Rekonstruktion fehlender Nachrichtenteile!
  - B ispi l: Natürlich  Sprach
  - Beispiel: Fehlererkennende und -korrigierende Codes (z.B. Paritätsbits)

Quelle 3

| Zeichen $a$ | A | B | C | D |
|---|---|---|---|---|
| Häufigk. $p_a$ | 0.5 | 0.25 | 0.125 | 0.125 |
| Code $c(a)$ | 00 | 01 | 10 | 11 |

$H =$ 1.75
$L =$ 2

Quelle 3

| Zeichen $a$ | A | B | C | D |
|---|---|---|---|---|
| Häufigk. $p_a$ | 0.5 | 0.25 | 0.125 | 0.125 |
| Code $c'(a)$ | 0 | 10 | 110 | 111 |

$H =$ 1.75
$L =$ 1.75

# 2. Digitale Codierung und Übertragung

2.1 Informationstheoretische Grundlagen

2.2 Verlustfreie universelle Kompression

Weiterführende Literatur zum Thema Kompression:

Taschenbuch Medieninformatik Kapitel 2

Herbert Klimant, Rudi Piotraschke, Dagmar Schönfeld: Informations- und Kodierungstheorie, Teubner 2003

Khalid Sayood: Introduction to Data Compression, 2nd. ed., Morgan Kaufmann 2000

# Kompressionsverfahren: Übersicht

- Klassifikationen:
  - Universell vs. speziell
    - Speziell für bestimmte technische Medien (Bild, Ton, Bewegtbild)
  - Verlustfrei vs. Verlustbehaftet
  - In diesem Kapitel: nur universelle & verlustfreie Verfahren

- Im folgenden vorgestellte Verfahren:
  - Statistische Verfahren:
    - Huffman-Codierung
    - Arithmetische Codierung
  - Zeichenorientierte Verfahren:
    - Lauflängencodierung (RLE Run Length Encoding)
    - LZW-Codierung

# Grundidee zur Huffman-Codierung

- Zeichen größerer Häufigkeit werden durch kürzere Codes repräsentiert
  - vgl. Morse-Code
- Das führt zu einem *Code variabler Wortlänge*:
  - Kein Codewort darf Anfang eines anderen sein *(Fano-Bedingung)*
- In optimalem Code müssen die beiden Symbole der niedrigsten Häufigkeit mit gleicher Länge codiert sein.

  "Beweis"-Skizze:
  - Wären die Längen verschieden, könnte man das längere Wort bei der Länge des kürzeren abschneiden
    - » Dann sind die beiden entstehenden Codes verschieden (sonst wäre Fano-Bedingung vorher verletzt gewesen)
    - » Kein anderes Codewort kann länger sein (da Zeichen niedrigster Häufigkeit), also kann die Kürzung nicht die Fano-Bedingung verletzen
  - Dann hätten wir einen neuen Code mit kleinerer durchschnittlicher Wortlänge!

# Huffman-Codierung (1)

- Gegeben: Zeichenvorrat und Häufigkeitsverteilung
- Ergebnis: Codierung
  (optimal, wenn alle Häufigkeiten Kehrwerte von Zweierpotenzen sind)
- Wiederholte Anwendung dieses Schritts auf die Häufigkeitstabelle:
  - Ersetze die beiden Einträge niedrigster Häufigkeit durch einen Codebaum mit zwei Ästen „0“ und „1“ und trage die Summe der Häufigkeiten als Häufigkeit dafür ein.

| Zeichen | A | B | C | D |
|---|---|---|---|---|
| Häufigkeit | 0.5 | 0.25 | 0.125 | 0.125 |

| | | | |
|---|---|---|---|
| | | | **0** **1** |
| Zeichen | A | B | C D |
| Häufigkeit | 0.5 | 0.25 | 0.25 |

David Huffman 1951

# Huffman-Codierung (2)

| Zeichen | A | B | C D |
|---|---|---|---|
| Häufigkeit | 0.5 | 0.25 | 0.25 |

| Zeichen | A | B C D |
|---|---|---|
| Häufigkeit | 0.5 | 0.5 |

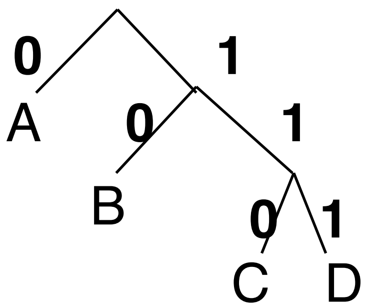


Resultierender Codebaum

# Huffman-Codierung (3)

- Eine Nachricht, die sich an die gegebene Häufigkeitsverteilung hält:
  - ababacadaabacdba (Länge = 16 Zeichen)
- Codierung mit festen Wortlängen (z.B. a = 00, b = 01, c = 10, d = 11)
  - Länge 32 bit
- Huffman-Codierung ( a = 0, b = 10, c = 110, d = 111)
  - 0100100110011100100110111100
  - Länge 28 bit (d.h. ca. 12.5% Reduktion)

# Experiment: Huffman-Kompression von Bildern

- Grautonbild, 256 x 256 Pixel, 8 bit (d.h. 256 Graustufen)

- Unkomprimiert: 65.536 Bytes
- Mit Huffman kodiert: 40.543 Bytes ca. 38% Reduktion

- Einfacher "Zusatztrick":
  – *Differenz* zwischen benachbarten Pixeln speichern und Huffman dann anwenden

    33.880 Bytes ca. 51% Reduktion
  – Keine universelle Kompression mehr, sondern speziell für Pixelbilder
  – Solche "semantischen Kodierungen" siehe später!

# Kompressionsverfahren: Übersicht

- Klassifikationen:
  - Universell vs. speziell (für bestimmte Informationstypen)
  - Verlustfrei vs. verlustbehaftet
  - In diesem Kapitel: nur universelle & verlustfreie Verfahren

- Im folgenden vorgestellte Verfahren:
  - Statistische Verfahren:
    - » Huffman-Codierung
    - » Arithmetische Codierung
  - Zeichenorientierte Verfahren:
    - » Lauflängencodierung (RLE Run Length Encoding)
    - » LZW-Codierung

# Arithmetische Codierung (1)

- Gegeben: Zeichenvorrat und Häufigkeitsverteilung
- Ziel: Bessere Eignung für Häufigkeiten, die keine Kehrwerte von Zweierpotenzen sind
- Patentiertes Verfahren; nur mit Lizenz verwendbar
- Grundidee:
  – Code = Gleitkommazahl berechnet aus den Zeichenhäufigkeiten
  – Jedes Eingabezeichen bestimmt ein Teilintervall

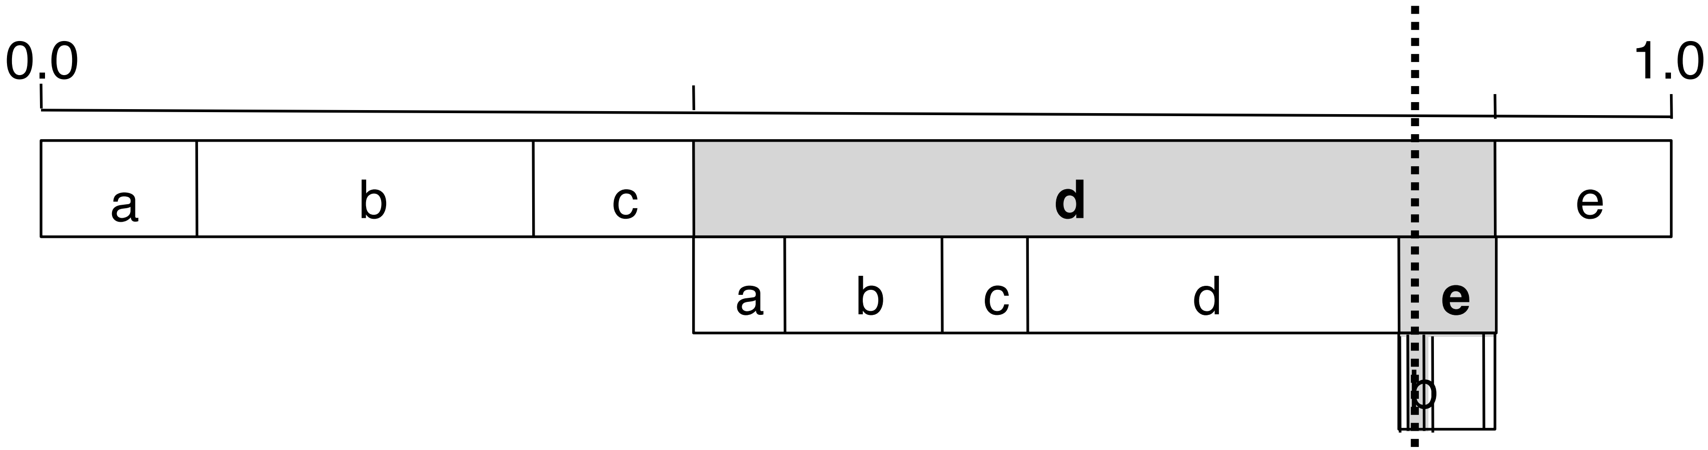

# Arithmetische Codierung (2)

Beispiel:

| Zeichenindex i | 1≙Leerz. | 2≙I | 3≙M | 4≙S | 5≙W |
|---|---|---|---|---|---|
| Häufigkeit $p_i$ | 0.1 | 0.2 | 0.1 | 0.5 | 0.1 |
| linker Rand $L_i$ | 0.0 | 0.1 | 0.3 | 0.4 | 0.9 |
| rechter Rand $R_i$ | 0.1 | 0.3 | 0.4 | 0.9 | 1.0 |

Allgemein: $L_i = \sum_{j=1}^{i-1} p_j \quad R_i = \sum_{j=1}^{i} p_j$

Algorithmus:

**real** L = 0.0; **real** R = 1.0;
**Solange** Zeichen vorhanden **wiederhole**
  Lies Zeichen und bestimme Zeichenindex i;
  **real** B = (R–L);
  R = L + B*$R_i$;
  L = L + B*$L_i$;
**Ende Wiederholung**;
*Code des Textes ist Zahl im Intervall (L, R]*

Algorithmus in "Pseudocode":

"**real**" Datentyp (Gleitkommazahl)

"=" Zuweisung an Variable

# Arithmetische Codierung (3)

- Beispieltext-Codierung ("SWISS_MISS")

| Zeichen | L | R |
|---|---|---|
| | 0,0 | 1,0 |
| S | 0,4 | 0,9 |
| W | 0,85 | 0,9 |
| I | 0,855 | 0,865 |
| S | 0,859 | 0,864 |
| S | 0,861 | 0,8635 |
| Leerz. | 0,861 | 0,86125 |
| M | 0,861075 | 0,8611 |
| I | 0,8610775 | 0,8610825 |
| S | 0,8610795 | 0,861082 |
| S | 0,8610805 | 0,86108175 |

**real** L = 0.0; **real** R = 1.0;
**Solange** Zeichen vorhanden **wiederhole**
    Lies Zeichen und bestimme Zeichenindex i;
    **real** B = (R–L);
    R = L + B*$R_i$;
    L = L + B*$L_i$;
**Ende Wiederholung**;

| 1=Leerz. | 2=I | 3=M | 4=S | 5=W |
|---|---|---|---|---|
| 0.1 | 0.2 | 0.1 | 0.5 | 0.1 |
| 0.0 | 0.1 | 0.3 | 0.4 | 0.9 |
| 0.1 | 0.3 | 0.4 | 0.9 | 1.0 |

# Arithmetische Kodierung (4)

- Problem Gleitkomma-Arithmetik:
  – Konversion in Ganzzahl-Bereich durch "Skalieren"
- Welcher Binärcode:
  – Ober- und Untergrenze binär codieren
  – Code = Oberer Wert, abgebrochen nach der ersten Stelle, die verschieden vom unteren Wert ist

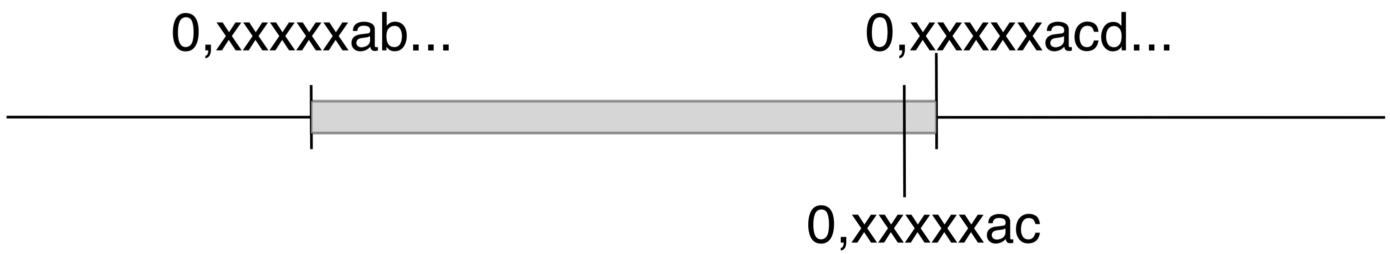

# Kompressionsverfahren: Übersicht

- Klassifikationen:
  - Universell vs. speziell (für bestimmte Informationstypen)
  - Verlustfrei vs. verlustbehaftet
  - In diesem Kapitel: nur universelle & verlustfreie Verfahren

- Im folgenden vorgestellte Verfahren:
  - Statistische Verfahren:
    - » Huffman-Codierung
    - » Arithmetische Codierung
  - Zeichenorientierte Verfahren:
    - » Lauflängencodierung (RLE Run Length Encoding)
    - » LZW-Codierung

# Lauflängencodierung

- Unkomprimierte Repräsentationen von Information enthalten häufig Wiederholungen desselben Zeichens
(z.B. lange Folgen von x00- oder xFF-Bytes)
- Idee: Ersetzen einer Folge gleicher Zeichen durch 1 Zeichen + Zähler
- Eingesetzt z.B. in Fax-Standards

- Beispiel:

  aaaabcdeeefggggghiabtttiikkkddde

  ersetzt durch

  #a4bcd#e3f#g4hiab#t3#i2#k3#d3e

- Probleme:
  - Bei geringer Häufigkeit von Wiederholungen ineffektiv (verschlechternd)
  - Syntaktische Trennung von Wiederholungsindikatoren und Code
  - Lösung oft durch Codierung in Maschinenworten
    - » z.B. 1 Byte Zeichen, 1 Byte Zähler

# Kompressionsverfahren: Übersicht

- Klassifikationen:
  - Universell vs. speziell (für bestimmte Informationstypen)
  - Verlustfrei vs. verlustbehaftet
  - In diesem Kapitel: nur universelle & verlustfreie Verfahren

- Im folgenden vorgestellte Verfahren:
  - Statistische Verfahren:
    - » Huffman-Codierung
    - » Arithmetische Codierung
  - Zeichenorientierte Verfahren:
    - » Lauflängencodierung (RLE Run Length Encoding)
    - » LZW-Codierung

# Wörterbuch-Kompressionen

- Grundidee:
  - Suche nach dem „Vokabular“ des Dokuments, d.h. nach sich wiederholenden Teilsequenzen
  - Erstelle Tabelle: Index --> Teilsequenz („Wort“)
  - Tabelle wird dynamisch während der Kodierung aufgebaut
  - Codiere Original als Folge von Indizes

- Praktische Algorithmen:
  - Abraham Lempel, Jacob Ziv (Israel), Ende 70er-Jahre
    - » LZ77- und LZ78-Algorithmen
  - Verbessert 1984 von A. Welch = „LZW“-Algorithmus (Lempel/Ziv/Welch)
  - Basis vieler semantikunabhängiger Kompressionsverfahren (z.B. UNIX „compress“, Zip, gzip, V42.bis)
  - Verwendet in vielen Multimedia-Datenformaten (z.B. GIF)

# Prinzip der LZW-Codierung

- Nicht alle Teilworte ins Wörterbuch, sondern nur eine "Kette" von Teilworten, die sich um je ein Zeichen überschneiden.
- Sequentieller Aufbau:
  Neu einzutragendes Teilwort =
  Kürzestes ("erstes") noch nicht eingetragenes Teilwort
- Beispiel:

```
b a n a n e n a n b a u
```

| ba | an | na | ane | en | nan | nb | bau |
|---|---|---|---|---|---|---|---|

# “Wörterbuch” für LZW

- Abbildung von Zeichenreihen auf Zahlen (Code)
- Annahme:
  - Vorbesetzung der Tabelle mit fest vereinbarten Codes für Einzelzeichen (muß nicht explizit gespeichert und übertragen werden)

Startzustand:

| Zeichenreihe | Code |
|---|---|
| “a” | 97 |
| “b” | 98 |
| “c” | 99 |
| … | |
| “z” | 122 |

Während Berechnung:

| Zeichenreihe | Code |
|---|---|
| “a” | 97 |
| … | |
| “z” | 122 |
| “ba” | 256 |
| “an” | 257 |
| ... | |

Für “neue” Codes Bereich verwendet, der von den vorbesetzen Codes verschieden ist (z.B. > 255)

# Aufbau des LZW-Wörterbuchs

b a n a n e ...

Neu einzutragendes Teilwort = Kürzestes ("erstes") noch nicht eingetragenes Teilwort

| Gelesenes Zeichen | Bereits in Wörterbuch? | Neueinträge mit Code |
|---|---|---|
| **b** | “b”: Ja | |
| **a** | “b”: Ja<br>“ba”: Nein | “ba” - neuer Code (256) |
| **n** | “a”: Ja<br>“an”: Nein | “an” - neuer Code (257) |
| **a** | “n”: Ja<br>“na”: Nein | “na” - neuer Code (258) |
| **n** | “a”: Ja<br>“an”: Ja | |
| **e** | … “ane”: Nein | “ane” - neuer Code (259) |

# LZW-Codierung (1)

Prinzipieller Ablauf:

**SeqChar** *p* = < NächstesEingabezeichen >;
**Char** *k* = NächstesEingabezeichen;
**Wiederhole:**
  **Falls** *p* & < *k* > in Tabelle enthalten
    **dann** *p* = *p* & < *k* >
    **sonst** trage *p* & <*k*> neu in Tabelle ein
      (und erzeuge neuen Index dafür);
      Schreibe Tabellenindex von *p* auf Ausgabe;
      *p* = < *k* >;
  **Ende Fallunterscheidung;**
  *k* = NächstesEingabezeichen;
**solange bis** Eingabeende
Schreibe Tabellenindex von *p* auf Ausgabe;

# Algorithmus-Beschreibung (“Pseudo-Code”)

- Variablen (ähnlich zu C/Java-Syntax):
  - Datentyp fett geschrieben, gefolgt vom Namen der Variablen
  - Zuweisung an Variable mit “=“
- Datentypen:
  - **int**: Ganze Zahlen
  - **Char**: Zeichen (Buchstaben, Zahlen, Sonderzeichen)
  - **SeqChar**: Zeichenreihen (Sequenzen von Zeichen)
    - » Einelementige Zeichenreihe aus einem Zeichen: < x >
    - » Aneinanderreihung (Konkatenation) mit &
- NächstesEingabezeichen:
  - Liefert nächstes Zeichen der Eingabe und schaltet Leseposition im Eingabepuffer um ein Zeichen weiter

# LZW-Codierung (3)

Beispieltext: “bananenanbau"

Ablauf:

**Wiederhole:**
**Falls** *p* & < *k* > in Tabelle enthalten
**dann** *p* = *p* & < *k* >
**sonst** trage *p* & <*k*> neu in Tabelle ein
(und erzeuge neuen Index dafür);
Schreibe Tabellenindex von *p* auf Ausgabe;
*p* = < *k* >;
**Ende Fallunterscheidung;**
*k* = NächstesEingabezeichen;
**solange bis** Eingabeende

| Lesen (k) | Codetabelle schreiben (p & <k>) | Ausgabe | Puffer füllen (p) |
|---|---|---|---|
| | | | <b> |
| a | (<ba>, 256) | 98 | <a> |
| n | (<an>, 257) | 97 | <n> |
| a | (<na>, 258) | 110 | <a> |
| n | | | <an> |
| e | (<ane>, 259) | 257 | <e> |
| n | (<en>, 260) | 101 | <n> |
| a | | | <na> |
| n | (<nan>, 261) | 258 | <n> |
| b | (<nb>, 262) | 110 | <b> |
| a | | | <ba> |
| u | (<bau>, 263) | 256 | <u> |
| EOF | | 117 | |