Audiokompression am Beispiel AAC

Medientechnologie IL

Andreas Unterweger

Vertiefung Medieninformatik
Studiengang ITS
FH Salzburg

Sommersemester 2014

Begriffsabgrenzung

- Schall (englisch *sound*)
  - Zeitliche und örtliche Druckschwankungen
  - Breitet sich als mechanische Welle aus (Trägermedium: zumeist Luft)
  - Schalldruck p, wobei $[p] = \frac{N}{m^2} = Pa$ (Pascal)
- Audiosignal
  - Repräsentation einer Schallwelle als Signal
  - Mikrofon: Wandelt Schall in Audiosignale um
  - Lautsprecher: Wandelt Audiosignale in Schall um
- Akustik
  - Beschäftigt sich mit Schall und dessen Ausbreitung
  - Wichtiges Teilgebiet: Psychoakustik (Schallwahrnehmung)

Menschliche Schallwahrnehmung I

- Physiologie
  - Ohren registrieren Schall, Gehirn verarbeitet Signale (ohne Details)
  - Amplituden- und Phasendifferenzen ermöglichen „Richungshören“
- Empfindlichkeit
  - Wahrnehmbarkeitsschwelle: ca. 20 µPa
  - Schmerzgrenze: ca. 200 Pa (frequenzabhängig)
  - Hörbares Frequenzspektrum: ca. 20 Hz bis 20 kHz (altersabhängig)
  - Besonders empflindlich bei 1-5 kHz (Stimme: 300 Hz bis 3,4 kHz)
- Lautstärke
  - Subjektiv wahrgenommener Schalldruck
  - Frequenzabhängig (bei gleich bleibendem Schalldruck)

Menschliche Schallwahrnehmung II

- Weber-Fechnersches Gesetz: $f' = C_f \cdot ln\left(\frac{f}{f_0}\right)$
  - Wahrgenommene Frequenz f' ist proportional zum Logarithmus der tatsächlichen Frequenz f (darum: eine Oktave $\rightarrow$ doppelte Frequenz)
  - f_0: Wahrnehmungsschwelle (ca. 20 Hz)
  - C_f: Proportionalitätskonstante
  - Auflösungsvermögen ca. 3,6 Hz zwischen 1 und 2 kHz
- Stevenssches Potenzgesetz: $p' = C_p \cdot (p - p_0)^{n_p}$
  - log(Lautstärke p') ist proportional zu log(Schalldruck p)
  - p_0: Wahrnehmungsschwelle (ca. 20 µPa)
  - C_p: Proportionalitätskonstante
  - $n_p \approx 0,6$ ($\sqrt{10}p$ entspricht $2p'$)
  - Gilt nur für mittlere bis hohe Lautstärken

  $\rightarrow$ Verwendung logarithmischer Größen (Schalldruck- und Lautstärkepegel)

  $L_p = 20log\left(\frac{p}{p_0}\right)$, wobei $[L_p] = dB$ (engl. **p***ressure* **l***evel*)

Menschliche Schallwahrnehmung III

- Frequenzmaskierung (englisch *spectral masking*) – **Demo**
  - Signale mit nahe beieinanderliegenden Frequenzen können schwerer (oder gar nicht) unterschieden werden, wenn ihre Amplituden hinreichend verschieden sind (Beispiel: Flüstern bei Rapkonzert)
  - Zahlreiche Studien durchgeführt $\rightarrow$ Mathematische Modelle verfügbar
- Zeitmaskierung (englisch *temporal masking*)
  - Signale, die hinreichend kurz vor oder nach einem anderen Signal auftreten, werden nicht wahrgenommen (Beispiel: Aufprall einer Bombe auf dem Boden kurz vor deren Explosion)
  - Abhängig vor allem von Amplituden- und Zeitdifferenz (bis zu 200 ms!)
- Weitere Maskierungseffekte (Auswahl)
  - Signal von einem Ohr maskiert das vom jeweils anderen
  - Auswirkung mehrerer gleichzeitig auftretender Maskierungssignale

Menschliche Schallwahrnehmung IV

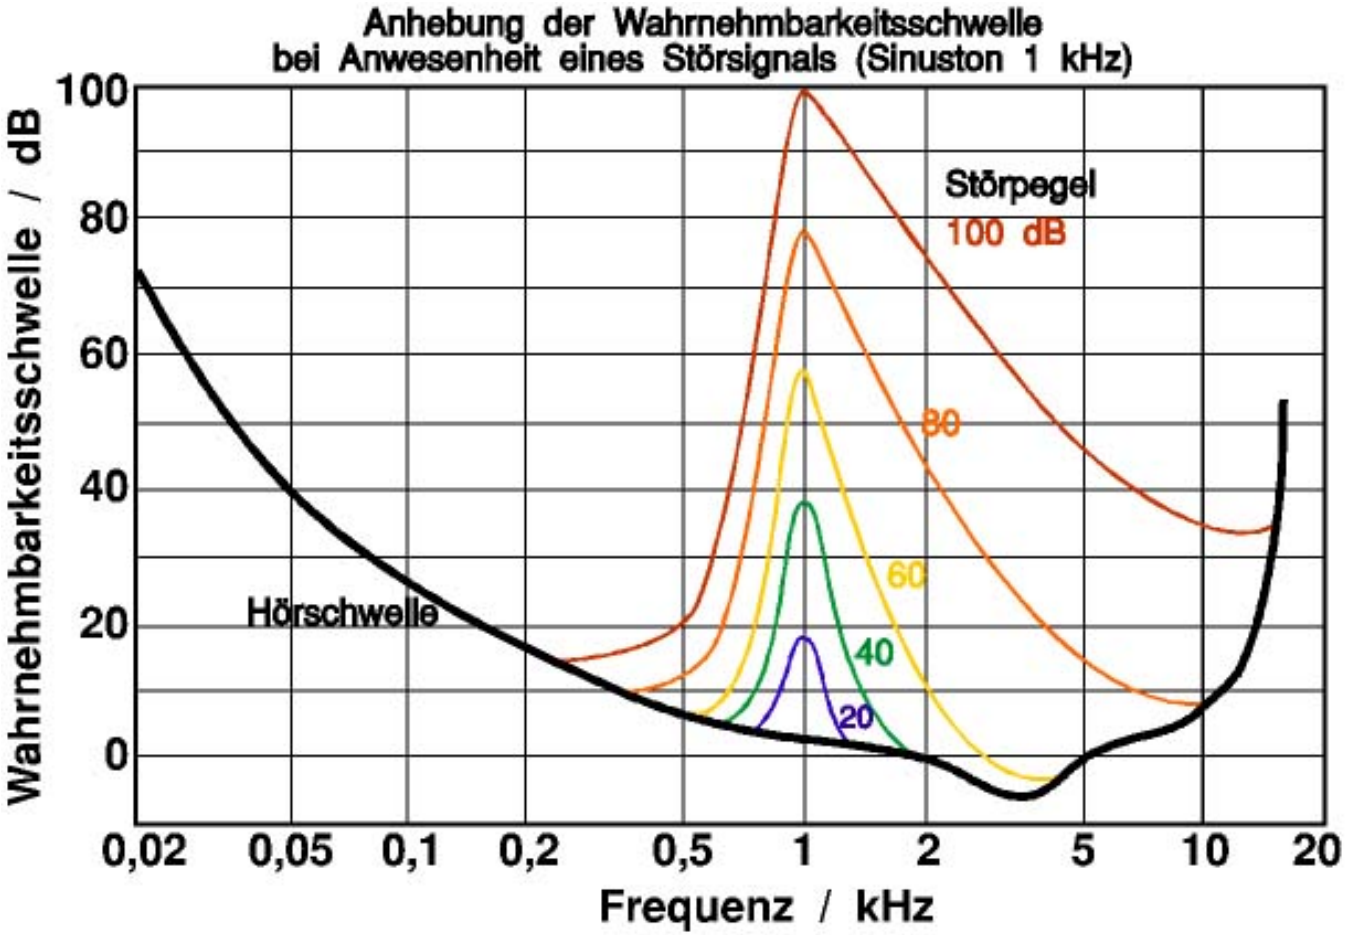

Quelle: `http://commons.wikimedia.org/wiki/File:Akustik_Mithoerschwelle2.JPG`

Überblick über AAC

- Standard für Audio(signal)kompression (Advanced Audio Coding)
- Nutzt Eigenschaften der menschlichen Schallwahrnehmung aus
- Mehrfach standardisiert (verschiedene „Ausbaustufen“)
  - MPEG-2 Part 7 (MPEG-2: Advanced Audio Coding)
  - MPEG-4 Part 3 Subpart 4 (MPEG-4 Audio: General Audio Coding)
- Konfigurierbare Komplexität über Profile
  - AAC definiert verschiedene so genannte Coding Tools
  - Profile legen fest, welche Coding Tools erlaubt sind $\rightarrow$ Anwendungsfälle
  - Fokus: Low Complexity (LC) Profile (aus MPEG-4)

Aufbau eines typischen AAC-Encoders I

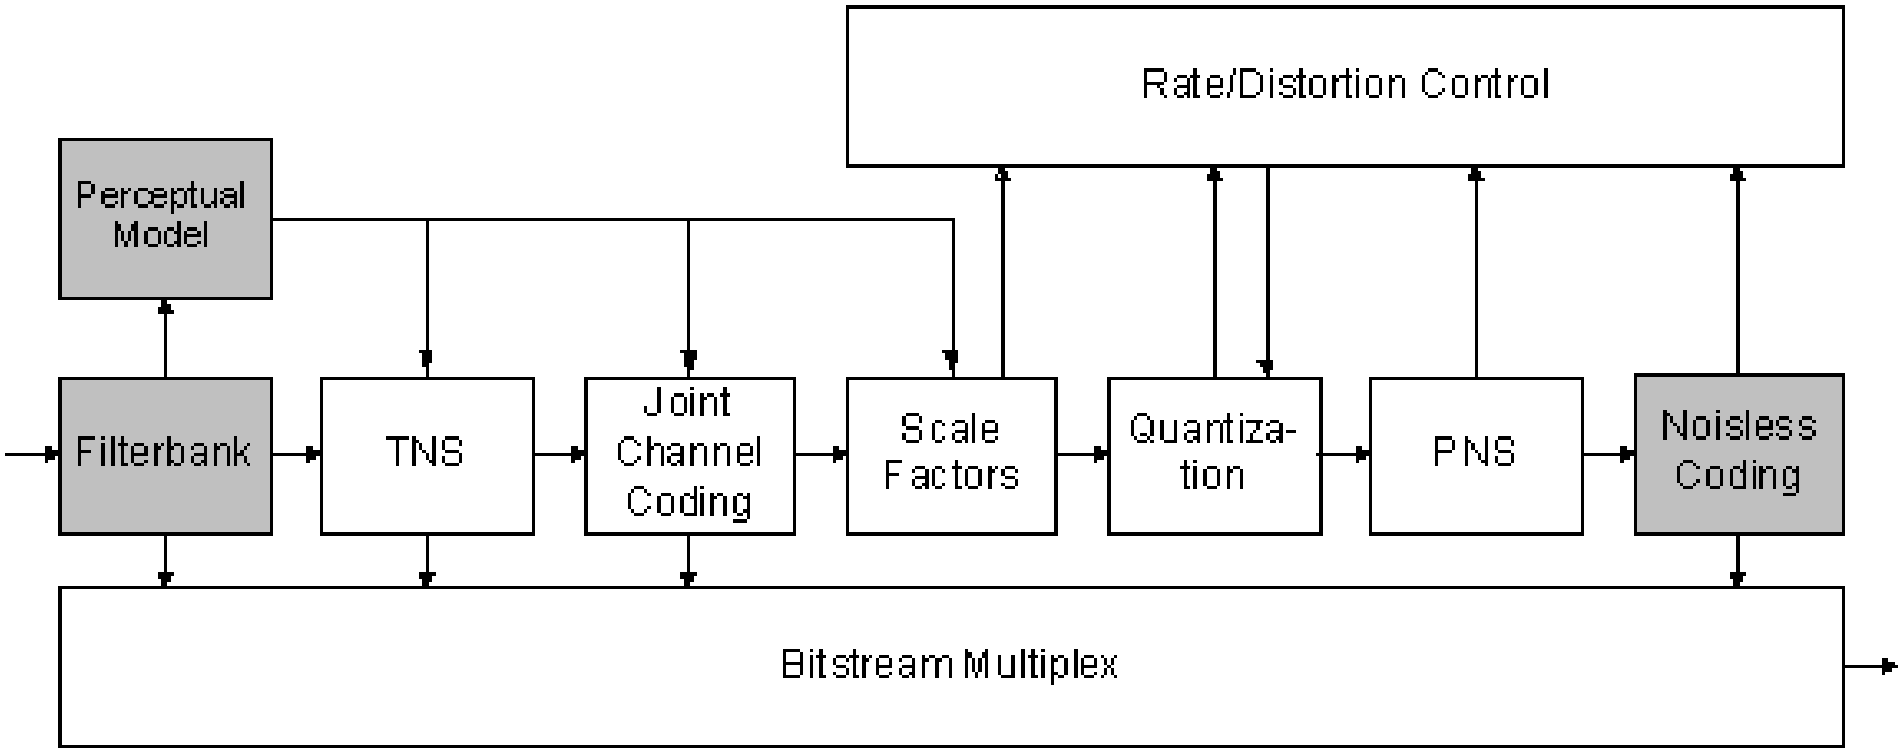

Quelle: `http://mpeg.chiariglione.org/standards/mpeg-4/audio`

TNS = Temporal Noise Shaping, PNS = Perceptual Noise Substitution

Aufbau eines typischen AAC-Encoders II

- Wahrnehmung ist frequenzabhängig $\rightarrow$ **Frequenztransformation**
- TNS: Quantisierungsfehler auf weniger hörbare Frequenzen verteilen
- Ausnutzung von Redundanzen zwischen Kanälen
- **Amplitudenskalierung** durch Maskierungseffekte
- **Quantisierung** (beeinflusst Bitrate und Qualität)
- PNS (optional): Energie von Rauschbändern kodieren, aber ohne Koeffizienten; Decoder ersetzt diese durch pseudozufällige Werte
- Entropiekodierung (Huffman-Kodierung)
- **Datenraten-/Qualitätssteuerung**
- Bitstromgenerierung aus kodierten Daten und Kodierparametern
- Anbringung von Fehlererkennungshilfen (formatabhängig)

Frequenztransformation

- Gesamtes Signal zu groß und uneinheitlich $\rightarrow$ Stückelung in Blöcke
  - Blockgröße $N \in \{960, 1024\}$ für lange Blöcke
  - $N \in \{120, 128\}$ für kurze Blöcke (je acht hintereinander)
  - Wechsel zwischen Blockgrößen (mit Übergangsgrößen) möglich
  - Blockgrößenwahl nach Signalcharakteristika
- Frequenztransformation notwendig $\rightarrow$ DCT?
  - Einzelne Blöcke $\rightarrow$ Multiplikation mit Rechteckfenster im Zeitbereich

  $\rightarrow$ Faltung mit sinc-Funktion im Frequenzbereich

  $\rightarrow$ Zusätzliche (unerwünschte) Frequenzen

  $\rightarrow$ Andere Fensterfunktion besser (weniger starke Verzerrung)
  - Noch besser: Modifizierte DCT (MDCT) mit teilweiser Überlappung
  - Zusätzlich: Speziell an MDCT angepasste Fensterfunktion(en)

MDCT I

- Ausgangsbasis DCT-IV (andere Symmetrie als „herkömmliche“ DCT):

$$Y_k = \sum_{n=0}^{N-1} X_n cos\left(\frac{\pi\left(k+\frac{1}{2}\right)\left(n+\frac{1}{2}\right)}{N}\right), k \in \{x \in \mathbb{N} \mid 0 \leq x \leq N-1\}$$

- MDCT nimmt doppelt so viele Eingangswerte X_n $(2N)$
- Anzahl der Ausgangswerte Y_k bleibt N (Unterabstastung!)
- MDCT verschiebt Eingangsdaten um $\frac{N}{2}$ ($\rightarrow N$ muss gerade sein)

$$Y_k = \sum_{n=0}^{2N-1} X_n cos\left(\frac{\pi\left(k+\frac{1}{2}\right)\left(n+\frac{N}{2}+\frac{1}{2}\right)}{N}\right), k \in \{x \in \mathbb{N} \mid 0 \leq x \leq N-1\}$$

MDCT II

- MDCT kann auf DCT-IV reduziert werden (vgl. separate Herleitung)
- „Rücktransformation“ (IMDCT):

$$X_n^A = \frac{1}{2N} \sum_{k=0}^{N-1} Y_k cos\left(\frac{\pi \left(k + \frac{1}{2}\right) \left(n + \frac{N}{2} + \frac{1}{2}\right)}{N} \right)$$

$$n \in \{x \in \mathbb{N} \mid 0 \leq x \leq 2N - 1\}$$

- MDCT ist **nicht** invertierbar (Unterabtastung!)

$\rightarrow$ $IMDCT(MDCT(X_n)) \neq X_n$!

$\rightarrow$ $IMDCT(MDCT(X_n)) = X_n^a$ (aliased)

MDCT III

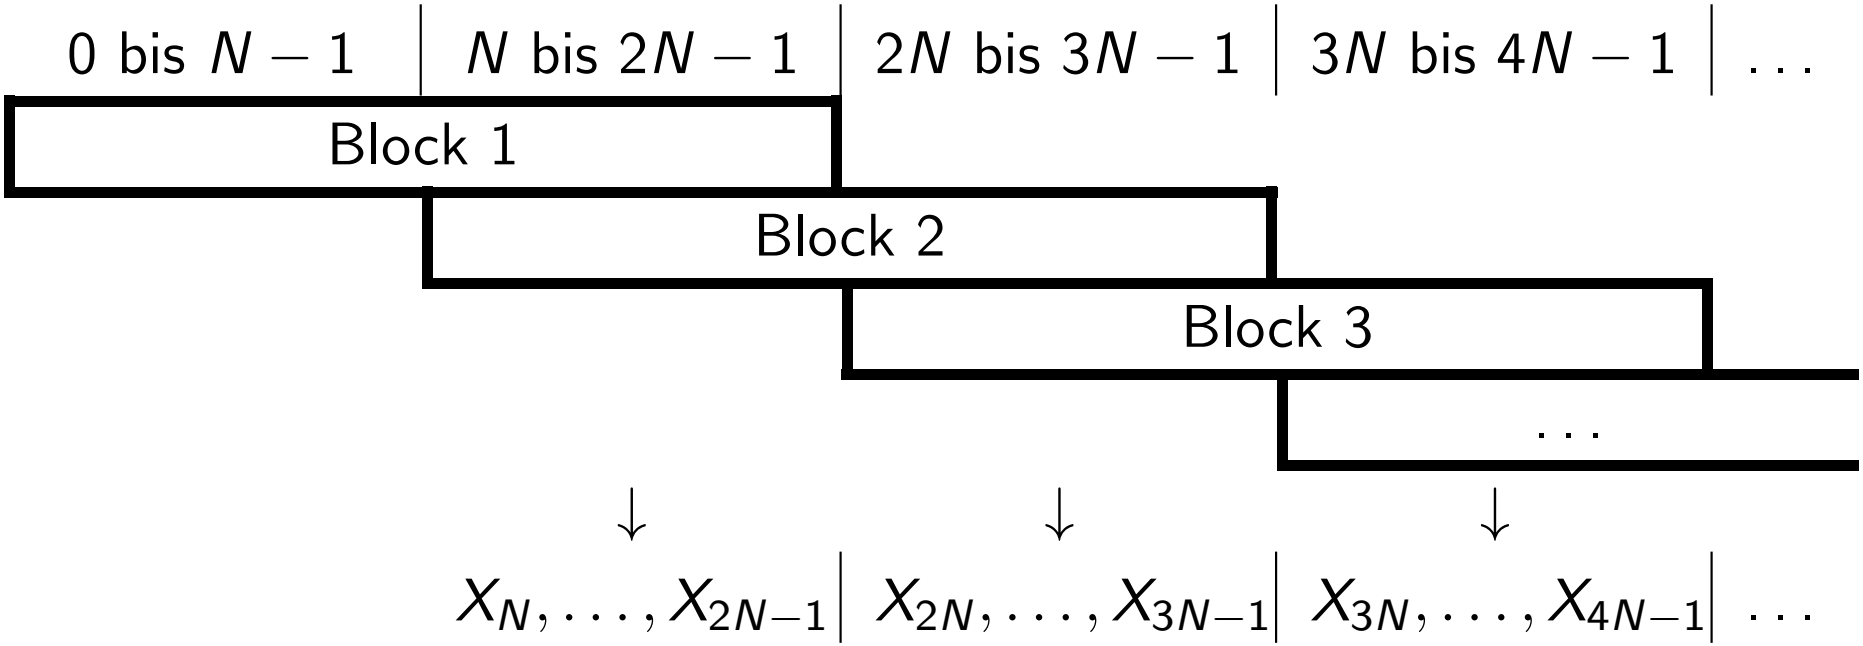

- MDCT wird erst durch rücktransformierte Nachbarblöcke umkehrbar
- Ohne Details: Addition der rücktransformierten Signale eliminiert Aliasingfehler im überlappten Bereich (*Time-Domain Aliasing Cancellation* (TDAC)) $\rightarrow$ Rücktransformation möglich

Quantisierung

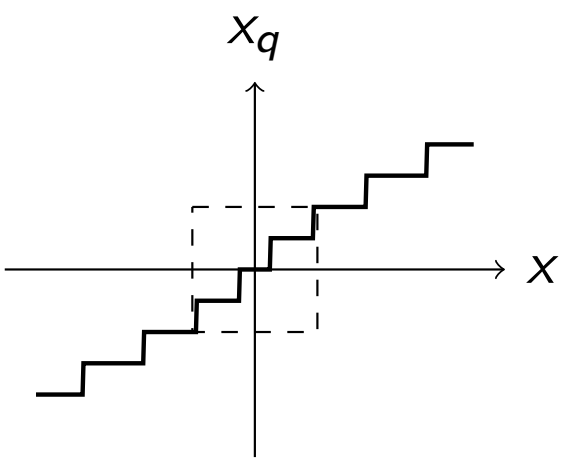

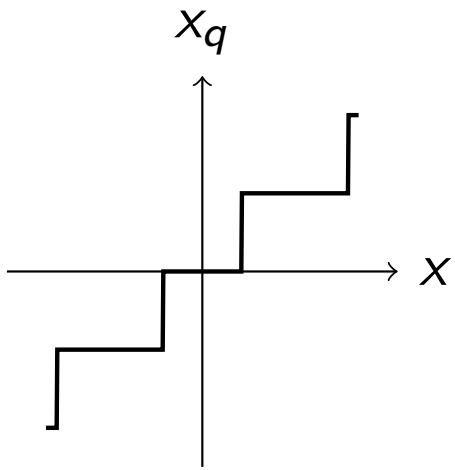

$$|x_q| = \lfloor |x|^n + M \rfloor$$
$$sgn(x_q) = sgn(x)$$
$$n_p = 0,75$$
$$M = 0,4054$$

- Nichtlinear (nach Stevensschem Potenzgesetz, aber mit anderem n_p)

$\rightarrow$ „Leise“ Frequenzanteile haben relativ kleine Quantisierungsfehler

$\rightarrow$ „Laute“ Frequenzanteile haben relativ große Quantisierungsfehler

$\rightarrow$ Teilweiser Maskierungseffekt für Quantisierungsfehler

- Mit zusätzlichem Offset M (durch Versuche ermittelt)

Amplitudenskalierung

- Amplitudenskalierung (vor Quantisierung)
  - Amplituden maskierter Frequenzanteile können verringert werden

  → Amplitudenwertebereich vor Abrundung wird verringert

  → Maskierte Frequenzanteile werden gröber quantisiert

  → Steuerungsmöglichkeit für die Quantisierungsfehlerenergie

→ Quantisierung von Koeffizient x mit Skalierungsfaktor $s \in \mathbb{N}$:

$$x_q = sgn(x) \left\lfloor \left(\frac{|x|}{2^{\frac{s}{4}}} \right)^{\frac{3}{4}} + 0,4054 \right\rfloor$$

- Koeffizienten werden Skalierungsfaktor„bändern“ zugeordnet
- Nachfolgende Entropiekodierung kodiert Koeffizientengruppen

Datenraten- und Qualitätssteuerung I

- Quantisierung verursacht über Skalierungsfaktoren Fehler
  - Kleine Skalierungsfaktoren $\rightarrow$ Feine Quantisierung

  $\rightarrow$ Hohe Datenraten und hohe Qualität
  - Große Skalierungsfaktoren $\rightarrow$ Grobe Quantisierung

  $\rightarrow$ Niedrige Datenraten und niedrige Qualität

$\rightarrow$ Skalierungsfaktorsteuerung erlaubt:
  - Datenratensteuerung (Bitrate)
  - Qualitätssteuerung
- Übliche Vorgehensweise im Encoder:
  - Mit „initial guess“ (Skalierungsfaktoren) kodieren
  - Qualität und/oder Datenrate ermitteln (inkl. Entropiekodierung!)
  - Ergebnis mit Benutzervorgaben vergleichen
  - Bei Abweichung Skalierungsfaktoren anpassen und wiederholen

Datenraten- und Qualitätssteuerung II

- Übliche Benutzervorgaben für den Encoder
  - Konstante oder beschränkte Datenrate (z.B. bei fixer Kanalbandbreite)
  - Konstante Qualität
- CBR (Constant Bit Rate) Encoding
  - Datenrate vorgegeben und konstant
  - Ziel: Qualität unter Vorgabe maximieren
  - Nachteil: Qualität schwankt über die Zeit hinweg
- VBR (Variable Bit Rate) Encoding
  - Qualität vorgegeben
  - Ziel: Datenrate unter Vorgabe minimieren
  - Nachteil: Datenrate nicht vorhersagbar
- Constrained VBR bzw. ABR (Average Bit Rate) Encoding
  - Min./max. bzw. durchschnittliche Datenrate(n) vorgegeben
  - Ziel: Qualität unter Vorgabe(n) maximieren
  - Nachteil: Qualität durch Einschränkungen nicht optimal

High Efficiency (HE) AAC I

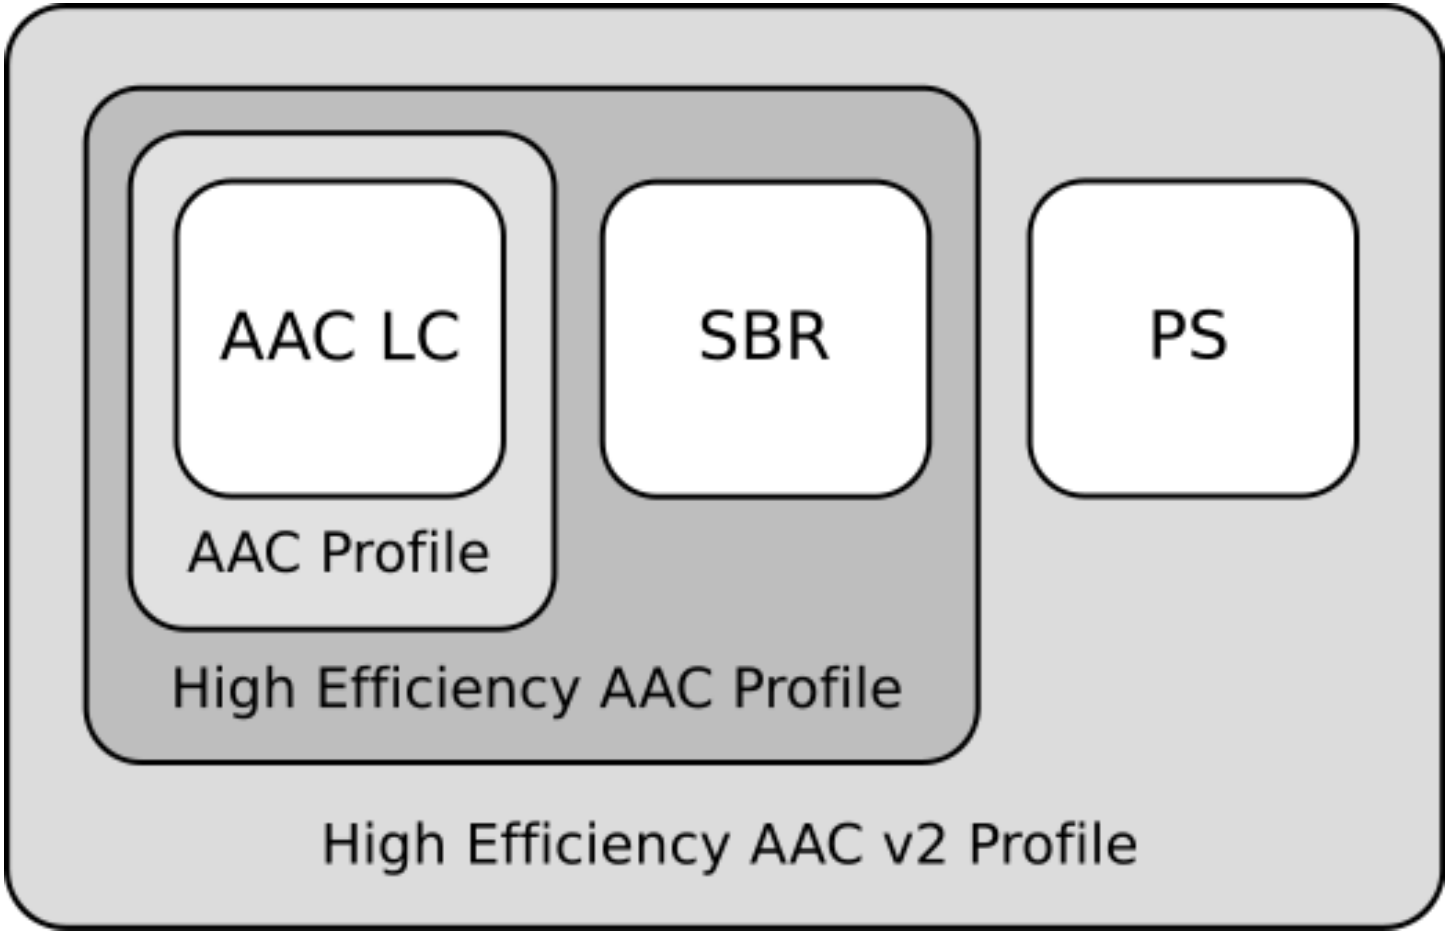

Quelle: `http://en.wikipedia.org/wiki/File:HE-AAC_and_HE-AAC_v2.svg`

High Efficiency (HE) AAC II

- SBR (Spectral Band Replication)
  - Verlauf hochfrequenter Amplituden oft ähnlich dem niederfrequenter Amplituden (durch Oberwellen und deren Periodizität)
  - Genaue Unterscheidung hoher Frequenzen schwer/kaum möglich
  - Rauschtoleranz bei hochfrequenten Koeffizienten sehr hoch

  → Hochfrequente Koeffizienten aus niederfrequenten extrapolieren (mit minimaler Zusatzinformation zur „Form“ der hochfrequenten)
  - Nachteil: Extrapolation eventuell falsch → nur für niedrige Datenraten
- PS (Parametric Stereo)
  - Stereosignal (zwei Kanäle) wird als Monosignal (ein Kanal) kodiert
  - Minimale Zusatzinformation zur ursprünglichen Amplitudenverteilung auf die beiden ursprünglichen Kanäle wird mitgeschickt

  → Decoder kann Stereosignal teilweise rekonstruieren
  - Vorteil: Sehr geringer Overhead (wenige kbps)
  - Nachteil: Nur bei sehr niedrigen Datenraten akzeptabel (aber deutlich besser als „echtes“ Stereo mit gleicher Datenrate)

Danke für die Aufmerksamkeit!

Fragen?