Skriptum zur VL

KOMPRESSION VON MULTIMEDIA DATEN

Mag.Dr. Andreas Uhl

RIST++ und Institut für Scientific Computing

Universität Salzburg

Adresse:

Andreas Uhl
Forschungsinstitut für Softwaretechnologie
Hellbrunnerstr.34
A-5020 Salzburg
Österreich
Tel.: ++43/(0)662/8044/5308
Fax: ++43/(0)662/8044/138
E-mail: uhl@cosy.sbg.ac.at

Inhaltsverzeichnis

1 Grundlagen **1**

1.1 Was ist Kompression ? 1

1.2 Warum Kompression ? 2

1.3 Geschichte der Kompressionsverfahren 3

1.4 Entscheidungsgrundlagen zur Wahl eines Kompressionsverfahrens 3

2 Grundlegende Methoden und Verfahren **5**

2.1 Verlustfreie Kompression 5

2.1.1 Einfluß der Samplingrate auf mögliche Kompressionsrate 6

2.1.2 Predictive Coding - Differential Coding 6

2.1.3 Runlength Coding – Lauflängen Kodierung 6

2.1.4 Variable length Coding und Shannon-Fano Coding 7

2.1.5 Huffman Kodierung 7

2.1.6 Arithmetische Kodierung 8

2.1.7 Dictionary Kompression 9

2.1.8 Welcher Algorithmus für welche Anwendung ? 10

2.2 Verlustbehaftete Kompression 10

2.2.1 Quantisierung 11

2.2.2 DPCM 11

2.2.3 Transform Coding 12

2.2.4 Codebook-basierte Kompression 14

3 Bildkompression **15**

3.1 Verlustfreie Bildkompression 15

3.1.1 Faxkompression . . . 15
3.1.2 JBIG . . . 16
3.1.3 Lossless JPEG . . . 17
3.1.4 GIF, PNG, TIFF . . . 17
3.2 Verlustbehaftete Bildkompression . . . 17
3.2.1 JPEG . . . 17
3.2.2 Wavelet Kompression, JPEG2000 . . . 18
3.2.3 Fraktale Kompression . . . 18
3.2.4 Vektor Quantisierung . . . 19
3.2.5 Block Truncation Coding . . . 20
3.2.6 Hierarchical Coding . . . 20

4 Video **21**
4.1 MPEG-1 . . . 21
4.1.1 Intraframe Kompression . . . 21
4.1.2 Interframe Kompression . . . 22
4.2 MPEG-2, H.261 und H.263 . . . 23
4.2.1 MPEG-2 . . . 23
4.2.2 H.261 . . . 24
4.2.3 H.263 . . . 24
4.3 MPEG-4 . . . 24
4.3.1 Kompression von synthetischen Videoobjekten . . . 28
4.3.2 Kompression von natüerlichen Videoobjekten . . . 29
4.4 Non-standard Methoden . . . 32
4.4.1 Fraktale Kompression . . . 33
4.4.2 Wavelet-basierte Kompression . . . 33
4.5 MPEG-7 . . . 33

5 Audio **35**
5.1 Eigenschaften der menschlichen Lautwahrnehmung . . . 35
5.2 Prinzip der low-bitrate Audiokodierung . . . 37

5.3 Sprachkodierung 37
5.4 Wideband Audio Kodierung 37
5.5 Multichannel Audio Coding 39
5.6 MPEG-4 Audio 39

Kapitel 1

Grundlagen

1.1 Was ist Kompression ?

Kompression bezeichnet die kompakte Darstellung von Daten. Wir beschränken uns hier auf die Kompression von *digitalen* Daten. Solche zu komprimierenden Daten sind z.B.

- Text
- Sourcecode
- Beliebige Dateien
- Bilder
- Video
- Audio
- Sprache

Klarerweise sind diese Daten von sehr unterschiedlicher Natur was deren Menge, Struktur, Verwendungszweck u.s.w. betrifft. Deshalb liegt es sehr nahe für bestimmte Datentypen spezielle Kompressionsverfahren zu entwickeln. Nicht nur die Art der Daten ist jedoch von Bedeutung sondern auch die Umgebung in der mit den Daten operiert werden soll (z.B. Übertragung der Daten in Netzwerken, Archivierung, interaktive Multimedia Anwendungen). Aus diesen Überlegungen ergeben sich verschiedene Möglichkeiten wie Kompressionsmethoden klassifiziert werden können:

- Nach der Art der zu verarbeitenden Daten
- Nach der Art der Einsatzumgebung
- Nach dem Grundtyp der zugrundeliegenden Algorithmen

Terminologie: Oft wird unter *Kompression* die "verlustbehaftete" Speicherung verstanden (lossy compression) wogegen die "verlustfreie" Speicherung oft als *Kodierung* bezeichnet wird. Diese Unterscheidung wird leider nicht einheitlich durchgezogen. Mehr zu dieser Unterscheidung folgt später. Die "Sprache der Kompression" ist Englisch, es gibt in diesem Bereich kaum brauchbare deutschsprachige Bücher oder Zeitschriften (was ja eigentlich für den gesamten Bereich der Informatik gilt !!). Der Begriff *Codec* bezeichnet ein vollständiges Kompressionssystem bestehend aus *Encoder* und *Decoder*. *Kompressionsrate* ist das Verhältnis zwischen der ursprünglichen Datenmenge und der Datenmenge nach dem Kompressionsvorgang und mißt somit die Kompressionsleistung.

1.2 Warum Kompression ?

Kompressionsverfahren werden angewendet um Speichermedien effizient zu nutzen, um Übertragungsbandbreite zu sparen und um Übertragungszeit zu reduzieren. Trotz der gewaltigen Fortschritte im Bereich Speichermedien und Netzwerktechnologien sind effiziente Kompressionsverfahren unumgänglich, man denke nur an den Anspruch "jedem Haushalt seinen MultimediaPC auf dem Information Superhighway mit interaktiven Multimediaanwendungen und Video on Demand". Über den bloßen Anspruch einer Datenmengenreduktion hinaus gehen die neueren Standards MPEG-4 und MPEG-7 die zusätzlich zu exzellenter Kompressionsleistung auch faszinierende Funktionalitäten bieten (siehe später). (für einige Beispiele siehe Tabellen 2A.1 - 2B.3).

Insbesondere drei wichtige Trends tragen dazu bei daß Kompressionverfahren immer wichtiger werden und daß diese Entwicklung den Umgang von digitalen Systemen in Hinblick auf Text, Sprache, Audio, Bildern und Video wesentlich verändern wird was zu neuen Produkten und Dienstleistungen führen wird:

- Die Entwicklung von effizienten Methoden zur Kompression aller möglichen Daten.
- Die Verfügbarkeit von schnellen und billigen single-chip, microprocessor, DSP und VLSI basierten Hardware Kompressoren.
- Die Konvergenz von Computer-, Kommunikation-, Consumer Electronics-, Publishing- und Unterhaltungsindustrie.

Kompression wird ermöglicht weil in digitalen Daten ein hoher Grad von Redundanz vorhanden ist.

- Statistische Redundanz: alle Symbole werden mit der gleichen Anzahl von Bits dargestellt unabhängig von ihrer Autrittshäufigkeit.
- Korrelation: nebeneinanderliegende Daten haben häufig ähnliche Werte, z.B. im Bild- und Videobereich:
  - Spatial Correlation.
  - Spectral Correlation.
  - Temporal Correlation.

Zusätzlich kommt dazu daß bei vielen Datentypen große Anteile irrelevant sind, weil die menschlichen Sinne und das Gehirn nicht das gesamte Ausmaß der Information verarbeiten können. Daher können solche

Teile weggelassen werden. Darüberhinaus gibt es in manchen Datentypen bestimmte Eigenschaften auf höherer Beschreibungebene die unabhängig von Zeit, Ort und Auflösung sind und somit effizient beschrieben werden können (fraktale Eigenschaften).

1.3 Geschichte der Kompressionsverfahren

- 1. JH v. Chr.: Stenographie
- 19. JH: Morse- und Braillealphabeth
- 1950er: statistische Kompressionsverfahren - Bit-muster verschiedener Länge werden verwendet um individuelle Symbole in Abhängigkeit von ihrer Auftrittshäufigkeit darzustellen.
- 1970er: dictionary Algorithmen - Symbolfolgen werden mit Hilfe von einem Wörterbuch ("dictionary") auf kürzere Folgen abgebildet.
- 1970er: Telefonnetzwerke wurden langsam digitalisiert $--> $ die Telekommunikationsindustrie begann Verfahren für Kompression zu entwickeln um mehr Stimmkanäle über ihre Leitungen zu bringen.
- frühe 1980er: FAX über analoge Telefonkanäle.
- mittlere 1980er: Anwendungen für digitale Bilder kommen vermehrt auf den Markt, die "digitale Revolution" bringt digitale Audiokompression.
- 1990er: Video Broadcasting, Video on Demand, ...

1.4 Entscheidungsgrundlagen zur Wahl eines Kompressionsverfahrens

Wenn es klar ist daß in einem digitalen System ein Kompressionsverfahren angewendet werden soll, muß entschieden werden, welche Art von Verfahren angewandt werden soll. Häufig wird die Auswahlfreiheit durch die Existenz von Standards oder de-facto Standards eingeschränkt - durch die zunehmende Entwicklung von offenen Systemen und die in Zukunft vielleicht abnehmende Bedeutung von Standards gewinnen diese Kriterien aber wieder an Bedeutung. Wichtige Entscheidungskriterien sind z.B.:

- Datentyp: 1-D, 2-D, 3-D, ...
- Lossy or Lossless: abängig von Datentypen, Ansprüchen an Qualität oder Kompressionsrate.
- Kompressionsleistung: welche Qualität benötige ich für meine Zielanwendung ?
- Algorithmen Komplexität, Geschwindigkeit, Delay: on- oder offline, real-time Applikation ?
- Hard- oder Software Lösung: Geschwindigkeit, Preis (MPEG-karten sind teuer !)
- Encoder/Decoder Asymmetrie: oftmaliges komprimieren (z.B. Videoconferencing) vs. einmaliges komprimieren (z.B. Bilddatenbanken, CD-ROM, VoD, ...)
- Fehlertoleranz: sind bei der Übertragung/Speicherung Fehler zu erwarten ?

- Skalierbarkeit: dekodieren mit verschiedener Qualität ist möglich.
- Progressive Transmission: je mehr Daten übertragen werden, desto besser wird die Qualität.
- Wird Standard benötigt: ist es eine "geschlossene" Anwendung oder ist Datenaustausch über mehrere Systeme hinweg zu erwarten ?
- Mehrfaches encoding/decoding: wiederholte Anwendung von lossy Kompression, z.B. für Video-editing
- Adaptiv oder nicht adaptiv: sind stark unterschiedliche Eingangsdaten zu erwarten ?
- Zusammenspiel mit anderen Daten: Audio und Video sollten beide frame-basiert sein.
- Zusammenspiel mit anderen Systemen: können Daten in ein Format für andere Anwendung umgewandelt werden ? (z.B. MJPEG $--> $ MPEG).

Kapitel 2

Grundlegende Methoden und Verfahren

2.1 Verlustfreie Kompression

Bei diesen Methoden können die Daten nach der Kompression exakt rekonstruiert werden, d.h. es geht keine Information verloren. Typische Anwendungen sind Kompression von Text oder Dateien, Fax, aber z.T. auch Bildmaterial wie z.B. in der medizinischen Bildverarbeitung. Bei all diesen Verfahren gibt es einen bekannten Tradeoff: Kodierungs Effizienz - Koder Komplexität - Kodierungs Delay.

Typischerweise handelt es sich um einen dreistufigen Prozeß:

- Das Modell: analysiert die Eingangsdaten bezüglich der Struktur und der Auftrittswahrscheinlichkeiten der einzelnen Symbole.
- Der Koder: produziert einen komprimierten Bitstream unter Benutzung der Information des Modells.
- Der Adaptor: benutzt Informationen aus den Daten um das Modell oder/und den Koder stetig an die Daten anzupassen.

Verlustfreie Kompression beruht auf der Technik Codewörter zu verwenden die kürzer sind als die ihnen entsprechenden Symbole wenn diese häufig sind. Dafür sind die Codewörter länger als die entsprechenden Symbole wenn diese selten vorkommen (there's no free lunch !).

Jeder Information generierende Prozeß kann betrachtet werden als Quelle die eine Folge von Symbolen emittiert die aus einem endlichen Alphabeth gewählt werden (im Fall von computergestützter Verarbeitung ist es letztlich immer das Alphabeth 0,1). Wir bezeichnen diese "Informationsquelle" als S mit dem zugehörigen Alphabeth $\{s_1, s_2, \ldots, s_n\}$ und den entsprechenden Auftrittswahrscheinlichkeiten $\{p(s_1), p(s_2), \ldots, p(s_n)\}$. Der Einfachheit halber betrachten wir diese Auftrittswahrscheinlichkeiten als relative Häufigkeiten. Es ist wünschenswert angeben zu können was die durchschnittliche Information einer gegebenen Quelle ist. Intuitiv sollte erfüllt sein, daß das Auftreten eines weniger häufigen Symbols mehr Information liefert als das Auftreten von sehr häufigen Symbolen. Die Information von unabhängigen Symbolen wie die Summe der Information der Einzelsymbole. Wir definieren

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

als die Information die durch das Auftreten des Symbols s_i "geliefert" wird, bezogen auf dessen Auftrittswahrscheinlichkeit $p(s_i)$. Die Basis des Logarithmus bestimmt die Einheit der Menge an Information, z.B. im Fall von Basis 2 handelt es sich um Bits.

Bilden wir nun den Durchschnitt über alle möglichen Symbole der Quelle gelangen wir zur durchschnittlichen Menge an Information pro Symbol, der *Entropie*:

$$H(S) = \sum_{i=1}^{n} p(s_i)I(s_i) = -\sum_{i=1}^{n} p(s_i)\log_2 p(s_i) \quad \text{bits/symbol}$$

Im wesentlichen liefert die Entropie eine Maßzahl wieviele Bits pro Symbol im Schnitt mindestens benötigt werden um eine verlustfreie Kompression durchführen zu können. Die nächsten Abschnitte behandeln Verfahren mit deren Hilfe es gelingt mehr oder weniger nahe an diese theoretische Grenze zu gelangen.

2.1.1 Einfluß der Samplingrate auf mögliche Kompressionsrate

Vergleicht man Daten die von ein und demselben analogen Signal stammen wobei y_i zehnmal so dicht gesampled ist wie x_i, so fällt auf daß benachbarte Werte von y_i wesentlich ähnlicher sind als benachbarte Werte von x_i (weil die abtastung des analogen Signals bei höherer samplingrate "stetiger" ist also zu mehr ähnlichen Werten führt – natürlich immer vorrausgesetzt daß das analoge Signal einen gewissen Grad an Stetigkeit aufweist). Die höhere Ähnlichkeit der y_i wirkt sich auf die Entropie und damit auf die erreichbare Kompressionsrate günstig aus.

2.1.2 Predictive Coding - Differential Coding

Dieses Verfahren ist eigentlich kein Kompressionsverfahren im eigentlichen Sinn sondern eine Art Preprocessing um Daten geeigneter für eine anschließende Kompression zu machen. Die Symbol Statistik wird verändert - aufgrund der Beobachtung, daß benachbarte Daten häufig hochgradig korreliert sind, wird anstelle der Folge der eigentlichen Werte $\{x_1, x_2, \ldots, x_N\}$ die Folge der Differenzen $y_i = x_i - x_{i-1}$ komprimiert. Während die x_i häufig nahezu gleichverteilte p_i aufweisen, haben die y_i deutliche Peaks in der Nähe von 0 (immer unter der Vorraussetzung daß die Annahme der Ähnlichkeit bei Nachbarschaft gilt, was v.a. in Audio-, Bild- und Videodaten erfüllt ist). Betrachten wir z.B. ein Bild mit 999 Bildpunkten und 10 verschiedenen Symbolen. Im Fall a) gilt $p(s_i) = 1/10$, $i = 1, \ldots, 10$, im Fall b) gilt $p(s_1) = 91/100$ und $p(s_i) = 1/100$ für $i = 2, \ldots, 10$. Fall a) entspricht dem "Normalbild", Fall b) dem Differenzenbild der y_i, wobei s_1 das Nullsymbol ist. Im Fall a) erhält man $H(S) = 3.32$, im Fall b) $H(S) = 0.72$. Die wesentlich geringere Entropie zeigt also daß das Differential Coding seine Berechtigung hat.

2.1.3 Runlength Coding – Lauflängen Kodierung

Grundprinzip: Folgen von aufeinanderfolgenden identischen Symbolen werden durch 3 Elemente ersetzt: ein einzelnes Symbol, ein Lauflängenzähler und ein Indikator der angibt wie die beiden anderen Symbole zu interpretieren sind.

Als Beispiel wird der Tape Drive für IBM AS/400 erklärt: Strings von aufeinanderfolgenden Blanks (2-63 byte) werden zu Control-byte komprimiert das "Blank" und Zähler enthält. Strings von aufeinanderfolgenden identischen Character ungleich Blanks (3-63 byte) werden zu 2 byte komprimiert. Control byte ("connsecutive char" und Zähler) und Character byte. Strings von nicht-wiederkehrenden Characters werden expandiert durch Control-byte ("nicht wiederkehrend").

z.B.: b Blank, * control byte; bbbbbbABCDEFbb33GHJKbMN333333 wird zu **ABCDEF**33GHJKbMN*3

ACHTUNG: bei unpassenden Daten kommt es leicht zu Datenexpansion !!

2.1.4 Variable length Coding und Shannon-Fano Coding

Wir bezeichnen $l(s_i)$ als die Länge des Codewortes (in bits) für das Symbol s_i. Die durchschnittliche Codelänge ist definiert als: $L(S) = \sum_{i=1}^{n} p(s_i)l(s_i)$. Um diesen Ausdruck zu minimieren muß man also kurze Codewörter für Symbole mit hoher Auftrittswahrscheinlichkeit verwenden. Interessant ist hier die nahe Verbindung zur Entropie: $H(S) = \sum_{i=1}^{n} p(s_i)I(s_i)$. Klarerweise ist es also notwendig, $l(s_i) = I(s_i) = -\log_2 p(s_i)$ zu setzen um die Entropiegrenze zu erreichen. Dies ist allerdings nur möglich falls $\log_2 p(s_i)$ eine ganze Zahl liefert. Da das kaum der Fall sein wird, rundet man auf die nächste ganze Zahl auf ($->$ Hinweis auf Suboptimalität des Verfahrens !) Genau diese Vorgangsweise wird bei Shannon-Fano Coding gewählt. Als Kode-effizienz wird der Ausdruck $\frac{H(S)}{L}$ bezeichnet. Werte nahe bei 1 sind also wünschenswert.

z.B.: $S = \{s_1, s_2, s_3, s_4\}$ mit $p(s_1) = 0.6$, $p(s_2) = 0.3$, $p(s_3) = 0.05$ und $p(s_4) = 0.05$. $H(S) = 1.4$ bits/Symbol. Wählt man eine fixed length Codierung, erhält man beispielsweise 00, 01, 10, 11 als Codewörter mit einer durchschnittlichen Codelänge von 2 bits/Symbol. Bestimmt man $l(s_i)$ so kommt man auf Werte von 1, 2 und 5 und kommt zu folgendem variable length Code: 0, 10, 110 und 111. s_3 und s_4 wären mit 5 bits zu kodieren, es genügen aber 3 bit um einen eindeutigen Code zu erzeugen. Die durchschnittlichen Codelänge beträgt 1.5 bits/Symbol.

Ein häufig angewandtes Verfahren ist es, das Alphabeth bestehend aus s_i zu ersetzen durch die Erweiterung auf $s_i s_j$ (mit den entsprechenden Auftrittshäufigkeiten). Die bessere durchschnittlichen Codelänge von z.B. 1.43 bits/Symbol wird erkauft durch eine deutlich erhöhte Rechen- und Speicherkomplexität.

2.1.5 Huffman Kodierung

Angenommen es sei gegeben eine Quelle S mit einem Alphabeth der Größe n. Die zwei am wenigsten häufigen Symbole werden vereinigt, dem neuen Symbol die Summe der Auftrittshäufigkeiten zugewiesen und dann das neue Alphabeth der Größe $n-1$ analog betrachtet. Angenommen man kennt die Codewörter der neuen Symbole, so werden die beiden alten generiert durch Anhängen von 0 und 1 an der rechten Seite des neuen Symbols. Dieses Verfahren wird rekursiv angewendet. Das Beispiel auf der Folie hat Entropie $H(S) = 2.15$, der erzeugte Huffman Code hat durchschnittlichen Codelänge von 2.2 bits/Symbol, ein ad-hoc generierter Code (wie im letzten Abschnitt) , z.B. $\{0, 10, 110, 1110, 1111\}$ hat durchschnittlichen Codelänge von 2.25 bits/Symbol.

Modifikation: Wenn viele Symbole kleine Wahrscheinlichkeiten haben steigt der Codewortbedarf stark an. Die Symbole mit geringer Auftrittshäufigkeit werden in eine eigene Klasse eingeteilt, die im Huffmancode mit "ELSE" bezeichnet wird und dann getrennt kodiert wird. Bezeichnung: "modified Huffamn Code".

Probleme:

1. Hat eine Quelle ein Symbol mit $p(s)$ ca. 1 und viele andere mit kleiner Auftrittshäufigkeit $-->$ durchschnittlichen Codelänge von 1 bit/Symbol weil die kleinste Codewortlänge 1 ist obwohl die Entropie wesentlich kleiner ist (vergleiche das Kodieren von Differenzen !!!).
2. Bei wechselnder Quellstatistik kann ein fixer Code leicht zu Datenexpansion führen.
3. Da ein fixes Codebook schlecht ist $-->$ zweistufiger Algorithmus: Statistik aufbauen, Code generieren.
4. Adaptivität ist aufwendig, es wird ja immer der gesamte Baum modifiziert !

2.1.6 Arithmetische Kodierung

Während es bei der Huffman Kodierung eine Entsprechung von einem Quellensymbol zum kodierten Symbol gibt, verwendet die Arithmetische Kodierung ein Codeword für eine ganze Folge von Quellensymbolen s_m der Länge m. Damit kann das Problem der Einschränkung auf ganzzahlige bit/Symbol Werte elegant umgangen werden. Bei der Arithmetischen Kodierung können sehr ähnliche Quellfolgen zu völlig verschiedenen Kodewörtern führen.

Sei s_m eine Folge von binären Quellensymbolen mit $p(0) = p$ und $p(1) = 1 - p$. Weiters sei $I = [0, 1)$ das halboffene Intervall und $\sum p(s_m) = 1$ bei Summierung über alle 2^m möglichen Folgen der Länge m. Man kann mit diesen Angaben Intervalle I_l mit $l = 1, 2, \ldots, 2^m$ konstruieren die alle in I liegen und jeweis einer Folge s_m zugeordnet werden wobei $|I_l| = p(s_m)$ und die I_j leeren Durchschnitt haben. Das folgende Verfahren heißt "Elias Code" und dient in erster Linie der Illustration (weil es unpraktikabel für Implementierungen ist).

Das Intervall I wird geteilt entsprechend der Auftrittshäufigkeiten p und 1-p in die Intervalle [0,p) (falls 0 auftritt) und [p,1) (falls 1 auftritt). Rekursiv werden diese Intervalle (je nach Auftreten des nächsten Symbols) aufgeteilt in $[0, p^2)$ und $[p^2, p)$ bzw. in $[p, 2p - p^2)$ und $[2p - p^2, 1)$. Der Folge 01 würde z.B. das Intervall $[p^2, p)$ zugeordnet. Nach $j - 1$ Quellensymbolen wurde der Folge s_{j-1} das Intervall $[L^{j-1}, R^{j-1})$ zugewiesen.

- folgt 0: $L^j = L^{j-1}$ und $R^j = L^{j-1} + p(R^{j-1} - L^{j-1})$.
- folgt 1: $L^j = L^{j-1} + p(R^{j-1} - L^{j-1})$ und $R^j = R^{j-1}$.

Man kann nun zeigen, daß für jede Folge s_m das entsprechende Teilintervall $[L^j, R^j)$ die gleiche Länge hat wie $p(s_m)$. Sobald nun das einer Folge ensprechende Teilintervall generiert wurde, ist das Codewort für s_m schnell gefunden: es muß nur der Punkt L^j in binärer Form dargestellt und die $-\log_2 p(s_m)$ bits (aufgerundet) nach der Dezimalstelle behalten werden. Das genügt um das Teilintervall und damit die Symbolfolge eindeutig zu identifizieren.

Die tatsächlichen Implementierungen verwenden wegen des Problems der Rechengenauigkeit eine Renormalisierung auf $[0, 1)$ in jedem Schritt mit zusätzlicher Rundung.

Bonuspunkte:

1. Adaptivität ist sehr leicht machbar ! Es muß nur die Statistik mitgeführt werden und die Intervallgrenzen entsprechen angepaßt werden.
2. Schon mit wenig codierten Symbolen kann eine Dekodierung beginnen (erstes Intervall). Dann kommt es mit jedem zusätzlichen Symbol zur schrittweisen Verfeinerung.
3. Einschränkung auf ganzzahlige bits/Symbol Werte überwunden !

2.1.7 Dictionary Kompression

Grundidee aller Dictionary Algorithmen: die Redundanz von wiederholt vorkommenden Phrasen in einem Text wird eliminiert (vergleiche dazu Runlength coding: da ging es nur um wiederholt vorkommende Symbole). Allg.: wiederholt vorkommenden Symbol Strings in bel. Dateien. Ein Frontend wählt Strings aus und die Information für Kompression und Dekompression wird in einem Dictionary gespeichert, von dem der Kompressor und der Dekompressor je eine Kopie haben. Bei diesen Verfahren werden ganze Strings durch Tokens ersetzt. Gut: lookup-table Operationen sind sehr schnell !

LZ77 Dictionary Kompression

Name: von Lempel und Ziv (1977); der hier beschriebene Algorithmus ist die LZSS (Storer/Szymanski) Variante von 1982. Typisch ist ein "sliding window" bestehend aus 2 Teilen: der History buffer (das Dictionary) – enthält einen Block gerade kodierten Textes (einige 1000 Symbole) – und der Lookahead buffer – enthält zu kodierende Strings (10-20 Symbole).

Entscheidend ist die richtige Wahl der Größe der jeweiligen buffer:

- History buffer klein $->$ Match ist unwahrscheinlich.
- History buffer groß $->$ hoher Zeitbedarf und schlechte Kompressionsrate durch großen Adreßraum für die Pointer.
- Lookahead buffer klein $->$ kein Match für lange Strings.
- Lookahead buffer groß $->$ Zeit wird für Suche nach matches für lange Strings vergeudet.

Beispiel: *Text out* $<-$ ——DATA COMPRESSION—— COMPRESSES DATA—— $<-$ *Text in.* "DATA COMPRESSION" ist der Inhalt des History buffers, " COMPRESSES DATA" ist der lookahead buffer. Das folgende Beispiel benutzt den QIC-122 Standard für Bandlaufwerke mit History buffer 2048 bytes.

Am Beginn wird jedes Symbol in "DATA COMPRESSION" als 0<ASCII Char. Wert> kodiert. " COMPRESS" ist ein String der Länge 9 der 12 Symbole zurück im History buffer vorkommt. Kodierung: 1<offset=12><length=9>. Dann werden "E" und "S" wieder als 0<ASCII Char. Wert> kodiert und "DATA" als String der Länge 4 der 28 Symbole zurück im History buffer vorkommt. Kodierung: 1<offset=28><length=4>.

Man sieht:

- Algorithmus hat start-up Zeit bis der History buffer gefüllt ist.
- Asymmetrischer Algorithmus - die Sucheffizienz im History buffer ist sehr wichtig. Intelligente Datenstrukturen nötig !

LZ78 Dictionary Kompression

Der hier beschriebene Algorithmus ist die Variante LZW(elch) Coding von 1984. Dieser Algorithmus löst das Problem des relativ kleinen History buffers. Phrasen fallen nicht aus dem Dictionary und der Lookahead buffer hat keine bestimmte Größe. Es werden keine Pointer auf frühere Substrings verwendet sondern ein Verfahren namens "Phrasing". Ein Text wird dabei in Phrasen zerlegt, wobei eine Phrase der längste bisher gefundene String + 1 neuer Character ist.

Alle Symbole werden durch Tokens ersetzt die auf Einträge im Dictionary zeigen. Die ersten 256 Dictionary Einträge sind die üblichen 8 bit ASCII code Symbole. Das Dictionary wird dann schrittweise durch neue Phrasen erweitert die aus dem zu kodierenden Text entstehen.

Wesentliche/kritische Punkte:

- Wie speichert man eine variable Anzahl von Strings variabler Länge effizient ab ?
- Wie groß soll das Dictionary werden ? Was ist wenn es voll ist (z.B. neues beginnen, oder nur die Strings behalten die oft verwendet wurden) ?

2.1.8 Welcher Algorithmus für welche Anwendung ?

Diese Frage ist allgemein nicht zu beantworten, letztlich kann nur ein Testen mit den in Frage kommenden Daten diese Frage lösen !

2.2 Verlustbehaftete Kompression

Bei Verfahren zur verlustbehafteten Kompression gibt es zusätzlich zum Tradeoff zwischen Kodierungs Effizienz - Koder Komplexität - Kodierungs Delay noch den zentralen Faktor Kompressions Qualität. Dieser Faktor ist extrem schwierig zu beurteilen, weil hier der einzig wichtige Maßstab die menschliche Wahrnehmung ist. Trotz zahlreicher Versuche v.a. im Bereich der Bild- und Videoverarbeitung ist es nicht gelungen eine wirklich überzeugende Maßzahl für die Qualität eines Signales zu entwicklen, die gut mit der menschlichen Wahrnehmung von "Qualität" korreliert. Insbesondere ist zu bedenken, daß der Begriff "Qualität" intersubjektiv verschieden ist ! Die einzige Methode um wirklich verläßliche Aussagen bezüglich menschlicher Wahrnehmung treffen zu können ist eine Menge von Versuchspersonen die Signalqualität beurteilen zu lassen. Offensichtlicher Nachteil: **AUFWENDIG !**. Die klassische Maßzahl die verwendet wird ist der Signal/Rauschabstand ((P)SNR) der auf dem root-mean-squared error (RSME) beruht:

$$RMSE = \sqrt{1/N \sum_{i=1}^{N} (f(i) - f'(i))^2}$$

wobei $f'(i)$ das rekonstruierte Signal ist. Peak-signal-to-noise ratio (gemessen in DeciBel dB) ist definiert wie folgt (wobei MAX der maximal mögliche Signalwert im Originalsignal $f(i)$ ist):

$$PSNR = 20 \log_{10}(\frac{MAX}{RMSE}).$$

Je höher der Wert der PSNR ist, desto höher ist die Qualität des rekonstruierten Signals. Mit zunehmender Kompressionsrate ist also abnehmende PSNR zu erwarten (rate-distortion tradeoff). Nochmals sei darauf hingewiesen, daß ein so einfaches Fehlermaß keinesfalls auf HVS Eigenschaften oder verschiedene Arten von Störungen eingehen kann. Große Qualitätsunterschiede werden allerdings meist richtig erkannt.

2.2.1 Quantisierung

Quantisierung ist der Übergang von der Beschreibung eines Signals durch ein großes Alphabeth durch die Beschreibung durch ein kleineres Alphabeth. Notwendigerweise kommt es bei der Umkehrung zu Fehlern, häufig sind genau das die einzigen Fehler die in der verlustbehafteten Kompression gemacht werden.

z.B.: ein Grauwertbild sei mit 8 bit/Pixel gespeichert. d.h. fuer jedes Pixel stehen 256 Grauwerte zur Auswahl. Benutzt man nun eine Quantisierung auf 4 bit/Pixel (bpp) stehen nur noch 16 Grauwerte zur Verfügung. Umgekehrt kann man das 4 bpp Bild nicht mehr exakt in das Ausgangsbild zurückverwandeln.

Betrachtet man einzelne Werte eines Signals und deren entsprechende quantisierte Werte so spricht man von *skalarer* Quantisierung. *Vektor*quantisierung bezeichet eine Gruppe von Verfahren bei denen n-tupel von Signalwerten gemeinsam auf einen quantisierten n-tupel abgebildet werden. In jedem Fall kann Quantisierung auch als Approximation betrachtet werden.

Man spricht von *uniform* quantization wenn der Wertebereich auf den ein Signal hin abgebildet wird gleichmäßig in Teilintervalle aufgeteilt wird. Das ist insbesondere dann sinnvoll, wenn die Auftrittshäufigkeiten im Originalsignal gleichmäßig verteilt sind. Der Wert "0" spielt in der Kompression immer eine besondere Rolle. Oft wird das Teilintervall das auf 0 abgebildet wird größer als alle anderen gewählt - man spricht dann von "uniform quantization with deadzone around 0".

Sind die Auftrittshäufigkeiten im Originalsignal nicht gleichmäßig verteilt und man kennt diese Verteilung so ist es sinnvoll in den Regionen eine feinere Aufteilung zu verwenden in denen viele Signalwerte liegen (mehr bits dort verwenden wo es Sinn macht Detail zu zeigen !). In diesem Fall spricht man von "non-uniform quantization". Kennt man diese Verteilung nicht, kann man zuerst das Signal analysieren und aufgrund der ermittelten Auftrittshäufigkeiten dann adaptiv die Quantisierung festlegen - "adaptive quantization". Insbesondere im Transformationsbereich kennt man von typischen Signalen die Auftrittshäufigkeiten die sich oft sehr ähneln - in diesem Fall kann die Quantisierung gut im Vorraus modelliert werden.

2.2.2 DPCM

Differential pulse code modulation (DPCM) ist das allgemeine Konzept hinter dem differential/predictive Kodieren. An Stelle der Differenz zweier aufeinanderfolgender Signalwerte kann auch eine Linearkombination mehrerer aufeinanderfolgender Signalwerte verwendet werden.

z.B.: $y_i = x_i - x'_i$ mit $x'_i = \alpha x_{i-1} + \beta x_{i-2} + \gamma x_{i-3}$. Die Werte α, β, γ heißen Prediktor Koeffizienten, x'_i ist die Prediction für x_i. Es handelt sich hier um einen *linearen* Prediktor der *Ordnung 3*. Abgespeichert wird die Folge der y_i.

Die Prediktorkoeffizienten können für bekannte Signalklassen fixiert werden oder aber an jedes neue Signal angepaßt werden. Die optimalen Koeffizienten α, β, γ die beispielsweise die Gesamtentropie von y_i minimieren können natürlich berechnet werden. Weiters können für jedes beliebige Signalteil eigene Koeffizienten verwendet bzw. optimiert werden ("lokal adaptive prediction"). Es ist natürlich zu beachten daß hier die jeweiligen Koeffizienten (im Gegensatz zu fix gewählten Koeffizienten) auch gespeichert werden müssen.

Die Entscheidung ob es sich bei DPCM um ein verlustfreies oder verlustbehaftetes Kompressionsverfahren handelt fällt erst mit der Entscheidung in welcher Art die y_i abgespeichert werden. Werden diese mit einem verlustfreien Verfahren abgespeichert (z.B. Huffamn kodiert) so erhält man auch insgesamt ein verlustfreies Verfahren. Wird nun *Quantisierung* auf das Differenzsignal y_i angewendet so erhält man ein verlustbehaftetes Verfahren.

Eine häufig verwendete Variante von DPCM verwendet eine fix vorgegebene Anzahl von Prediktor und Quantisierer Kombinationen die dann in Abhängigkeit von der lokalen Signalstatistik verwendet werden.

2.2.3 Transform Coding

Das klassische transformationsbasierte Kompressionsverfahren besteht aus drei Teilen:

1. Transformation
2. Quantisierung: alle vorher beprochenen Varianten kommen zum Einsatz um die Transformationskoeffizienten auf ein möglichst kleines Alphabeth abzubilden. Dieser Schritt ist nicht reversibel, hier passiert der Fehler.
3. Verlustfreie Kodierung der Transformationskoeffizienten: alle vorher beprochenen Varianten kommen zum Einsatz um die quantisierten Transformationskoeffizienten möglichst nahe an der Entropiegrenze zu kodieren. Meist eine Kombination aus Lauflängen (viele 0) und Huffman Kodierung oder Arithmetische Kodierung.

Die Transformation

Die Transformation (häufig werden sog. "Integraltransformationen" verwendet) dient dazu die Daten des Signals in eine besser zu komprimierende Form zu bringen. Meistens wird das Konzept verwendet ein Signal mit Hilfe von orthogonalen Basisfunktionen darzustellen.

z.B.: Vektoren im 2 dimensionalen Raum können durch einen Satz von orthogonalen (Def.: inneres Produkt ist 0) Basis-Vektoren dargestellt werden (Orthogonalbasis):

$$(x, y) = \alpha(1, 0) + \beta(0, 1).$$

$\{(1, 0), (0, 1)\}$ sind die orthogonalen Basisvektoren. α und β sind die Koeffizienten die angeben, wie stark jeder Basisvektor verwendet werden muß um den Vektor (x, y) darstellen zu können. Nur die Orthogonalitätseigenschaft ermöglicht eine minimale Anzahl von Basisvektoren.

Dieses Konzept kann auf Funktionen bzw. Signale übertragen werden.

$$f(x) = \sum_n < f(x), \psi_n(x) > \psi_n(x)$$

Die $\psi_n(x)$ sind die orthogonalen Basisfunktionen, $< f(x), \psi_n(x) >$ sind die Transformationskoeffizienten die angeben, wie stark jede Basisfunktion verwendet werden muß um das Signal "gut" darstellen zu können. Für eine Kompressionsanwendung werden die $< f(x), \psi_n(x) >$ berechnet und dann gespeichert. Da die $\psi_n(x)$ orthogonal sind, ist die entsprechende Anzahl minimal.

z.B.: im Falle der Fouriertransformation sind die $\psi_n(x) = e^{-\pi i n x} = \cos(nx) - i\sin(nx)$. In diesem Fall werden Frequenzen von periodischen Signalen betrachtet. Ein Fourierkoeffizient $< f(x), \psi_n(x) >$ gibt die Stärke des Frequenzanteils n in einem Signal an. Es ist klar, daß nicht alle Signale auf diese Art am effizientesten dargestellt werden können.

Für ein Transformationsbasiertes Verfahren wird nun also das Signal $f(x)$ in die Form $f(x) = \sum_n < f(x), \psi_n(x) > \psi_n(x)$ gebracht. Die Transformationskoeffizienten $< f(x), \psi_n(x) >$ werden geeignet quantisiert und dann verlustfrei gespeichert. Sind die $\psi_n(x)$ gut gewählt, sind die Transformationskoeffizienten nach der Quantisierung häufig 0 und müssen nicht gespeichert werden. Bei der Rekonstruktion ergibt sich daher nur ein geringer Fehler.

Daher ist es ganz offensichtlich, dass es wichtig ist für gegebene Signale die geeigneten Basisfunktionen zu verwenden !

Eine weitere Interpretationsmöglichkeit von Integraltransformationen ist es sie als Rotation der Koordinatenachsen zu intepretieren. Die Daten werden in ein Koordinatensystem transformiert, das eine bessere Kompression erlaubt. Als Beispiel betrachten wir die Paare $X = (x_1, x_2)$ die Paare benachbarter Pixelwerte darstellen. Trägt man diese Paare in einem entsprechenden Koordinatensystem auf so liegen die meisten Punkte auf der Hauptdiagonale. Die Varianz der x_j ist definiert als

$$\sigma_{x_j}^2 = 1/M \sum_{i=1}^{M} (x_{ji} - \mathbf{x_j})^2$$

wobei M die Anzahl der Paare und $\mathbf{x_j}$ der Mittelwert der x_j über alle Paare ist. Eine einfache Methode um Kompression zu erreichen ist es in jedem Paar eine der Komponenten durch den entsprechenden Mittelwert $\mathbf{x_j}$ zu ersetzen. Der MSE dieser Kompressionsmethode ist genau $\sigma_{x_j}^2$. Klarerweise ist aber die Varianz in beide möglichen Richtungen groß und daher das Ergebnis dieser Kompressionsart schlecht.

Betrachten wir nun die Transformation von X nach $Y = (y_1, y_2)$ durch eine Rotation der Koordinatenachsen um 45 Grad (Y = AX wobei A eine Rotationsmatrix ist). Wesentliche Eigenschaft einer geeigneten Transformation ist daß

$$\sigma_{x_1}^2 + \sigma_{x_2}^2 = \sigma_{y_1}^2 + \sigma_{y_2}^2$$

Während die Varianzen im Originalkoordinatensystem ungefähr gleich waren, ist die Varianz im neuen Koordinatensystem sehr ungleich verteilt, d.h. $\sigma_{y_1}^2 >> \sigma_{y_2}^2$. Daher macht es in dieser Darstellung viel mehr Sinn die Komponente y_2 durch ihren Mittelwert $\mathbf{y_2}$ da der Fehler durch diese Kompression genau $\sigma_{y_2}^2$ entspricht.

Beispiele für beliebte Transformationen (sollen können: Daten dekorrelieren, datenunabhängige Basisfunktionen, schnelle Algorithmen):

1. Karhunen-Loeve Transformation: optimale Transformation da in Abhängigkeit von den Daten die Basisfunktionen bestimmt werden. Nachteil: Komplexität $O(N^3)$ und keine allgemein nutzbaren Funktionen. Einsatz höchstens bei "multiple-spectral-band images" oder sehr ähnlichen Daten.

2. Fourier Transformation: der Klassiker der allerdings für Kompressionszwecke wegen der komplexen Werte und ungünstiger Periodizität weniger geeignet ist. $F(u) = 1/n \sum_{j=0}^{n-1} f(j) e^{\frac{2\pi i u j}{n}}$.

3. Discrete Cosinus Transformation: beliebt für Bildkompression, verwendet auf Blöcken. $F(u) = 1/n \sum_{j=0}^{n-1} f(j) \cos \frac{(2j+1)u\pi}{2n}$.

4. Wavelet Transformation: Verwendet Basisfunktionen die von 2 Parametern abhängen: eine Art Frequenz und Zeit. $W_{a,b}$. Näheres im Kapitel über lossy Kompression.

Die Quantisierung

Eine wesentliche Frage für die Quantisierung ist es wie die Transformationskoeffizienten zur Weiterverarbeitung ausgewählt werden.

1. Vordefinierte Zonen im Transformationsbereich: nur niederfrequente Koeffizienten werden quantisert, der Rest ignoriert (d.h. auf Null quantisiert).

2. Threshold Auswahl: Koeffizienten unterhalb einer bestimmten Schranke werden ignoriert (Nachteil: die Lokation muß gespeichert werden), oder nur die L größten Koeffizienten werden bearbeitet, u.s.w.

Wichtige Vertreter der Transformationsbasierten Kompressionsverfahren sind DCT-basierter JPEG, Wavelet Verfahren, Suband Coding.

2.2.4 Codebook-basierte Kompression

Es wird ein Dictionary verwendet um Teile des Signals durch Teile des Dictionarys darzustellen. Also konkret: Wähle einen zu komprimierenden Signalteil der Größe n und suche das im Dictionary befindliche Datenstück mit gleicher Größe das dem Signalteil am ähnlichsten ist (hier haben wir wieder die schon diskutierte Frage nach dem Ähnlichkeitsmaß/Qualitätsmaß !). Anstelle des Signalteils wird nur der Index des Datenstücks im Dictionary gespeichert. Natürlich müssen hier Coder und Decoder im Besitz des gleichen Dictionarys sein.

Wichtige Vertreter sind Vector Quantisierung und Fraktale Kompression.

Kapitel 3

Bildkompression

Wir betrachten Bilder als zweidimensionale Arrays die als Arrayelemente die jeweiligen Helligkeitsstufen beinhalten. Im Fall von Graustufenbildern hat ein Bild mit der "Farbtiefe" von 8bit $2^8 = 256$ verschiedene Graustufen, ein bilevel Bild (=Schwarz-Weiß Bild) benötigt daher 1bpp (bpp = bit per pixel). Farbbilder können in verschiedenen Darstellungen gegeben sein. Klassisch ist die RGB Darstellung, bei der jedem der Farbkanäle rot, grün und blau ein Array mit entsprechenden Helligkeitswerte ebendieser Farbe zugeordnet ist. Ein Farbbild mit 24 bit Farbtiefe entsteht so aus drei 8 bit tiefen Farbkanälen. Das menschliche Auge ist aber aus physiologischen Gründen gegenüber den drei genannten Farben nicht gleich sensitiv - am besten können wir Grüntöne wahrnehmen, am schlechtesten Blautöne. Aus diesem Grund (und einigen anderen) wurde eine alternative Darstellung entwickelt: YUV. Y ist ein Helligkeitskanal (engl. luminance channel), U und V sind die Farbkanäle (engl. chrominance channels). Y wird gewonnen aus einer Gewichtung von RGB (ca. Y = 0.3 R + 0.5 G + 0.2 B), ebenso können U und V berechnet werden - beide Farbdarstellungen können ohne wesentliche Einschränkung ineinander umgewandelt werden. Vorteil von YUV: Farb/SW TV und Subsampling der Chroma Kanäle. Alle weiteren Farbdarstellungen die im Bild- und Videobereich verwendet werden sind Varianten dieser Darstellungen.

3.1 Verlustfreie Bildkompression

Wie schon bei der abstrakten Betrachtung der verlustfreien Kompression klar wurde, ist die erreichbare Kompressionsrate sehr beschränkt. Es werden daher in der Bildverarbeitung nur dann verlustfreie Verfahren verwendet, wenn das notwendig/vorgeschrieben ist, z.B. medizinische Bildgebung, Speicherung von Plänen, wenn es um das Speichern von Texten in Form von Bildern geht (die ja lesbar sein sollen), etc.

3.1.1 Faxkompression

Es gibt hier die weitverbreiteten Standards ITU-T T.4 und T.6 für Gruppe 3 und 4 Faxgeräte. Die Kompressionsraten die hier erreicht werden können leicht 15 und mehr erreichen (allerdings wirklich nur für Dokumente, die ganz anders strukturiert sind als z.B. Bilder nach Halftoning Bearbeitung). Alle diese Standards verwenden Runlength und Huffman Coding. Eindimensionales T.4 kodieren verwendet nur die Pixel in der monentanen Zeile - zuerst werden die Runs bestimmt, der Output wird mit einem fixen (modifizierten)

Huffamn Code komprimiert. Jede Zeile wird durch ein EOL Zeichen abgeschlossen um Resynchronisierung nach Übertragungsfehlern zu garantieren. Um die Kompressionsrate zu steigern, wurde auch eine zweidimensionale Option entwickelt: nur manche Zeilen werden kodiert wie oben beschrieben, die anderen werden relativ zu den jeweils eindimensional kodierten dargestellt. Ein zusätzliches Bit nach dem EOL zeigt an ob die nächste Zeile 1-D oder 2-D kodiert wurde. Resynchronisierung nach Übertragungsfehlern ist hier nur nach 1-D kodierten Zeilen möglich. Der T.6 Standard ist für garantiert fehlerfreie Übertragung, hier gibt es keine EOL Zeichen und nur zweidimensionales Kodieren, die Kompressionsrate wird dadurch maximiert.

3.1.2 JBIG

Joint Binary Image Experts Group wurden von ITU-T and ISO mitgetragen. Es ist ein Standard zum Kodieren von Binärbildern, jedoch nicht beschränkt auf Fax (d.h. schriftliche Dokumente) sondern auch im Hinblick auf Haltoned Images entwickelt. Heißt auch ITU-T T.82 Recommendation. Ein bearbeitetes Pixel wird über 3 Zeilen "predicted", das eigentliche Kodieren übernimmt ein adaptiver Arithmetischer Koder (der IBM Q-Coder) um auf verschiedene Datentypen reagieren zu können. Daraus ergibt sich eine bessere Kompressionsrate – 5.2 und 48 versus 1.5 und 33 für Halftone Image und Dokument – aber auch 2-3 fache (Software)Verarbeitungszeit im Vergleich zu ITU-T T.4 und T.6. Darüberhinaus erlaubt JBIG hierarchische Kodierung: zuerst wird ein Bild mit geringer Auflösung kodiert, dann wird Schritt für Schritt die horizontale und Vertikale Auslösung verdoppelt.

JBIG kann aber auch (wie alle anderen Verfahren zur Kompression von Binärbildern) benutzt werden um Bilder mit größerer Bittiefe verlustfrei zu komprimieren. Dies wird erreicht durch sukzessives Kodieren von einzelnen Bitplanes (das sind ja genau Binärbilder) der entsprechenden Bilder, z.B. man beginnt mit der Bitplane die dem most significant Bit (MSB) entspricht und führt das Verfahren solange durch bis man bei der Bitplane für das least significant Bit (LSB) angekommen ist. Da die typischen Kompressionsverfahren große einheitliche Flächen gut komprimieren können, sollten diese Bitplanes möglichst so beschaffen sein. Leider führt die gewöhnliche Binärdarstellung aber genau zum entgegengesetzten Effekt. Betrachtet man z.B. ein Bild das zwischen den Werten 127 und 128 wechselt - in Binärdarstellung ist das 01111111 und 10000000. Die Zahlen unterscheiden sich in jeder Bitposition, daher sind auch die entsprechenden Bitplanes schlecht zu komprimieren. Sie sind zwar untereinander korreliert, dies wird jedoch meist nicht ausgenutzt. Eine effektive Abhilfe schafft der *Gray Code*. Das ist eine Methode eine Menge von Zahlen in ein binäres Alphabeth zu mappen sodaß sich benachbarte Zahlenwerte um genau ein Bit in der Binärdarstellung unterscheiden.

Binary Code $\longrightarrow$ Gray Code:

1. Beginnend mit dem MSB der Binärdarstellung, alle 0 werden belassen bis eine 1 kommt.
2. Die 1 wird belassen, alle folgenden Bits werden invertiert bis eine 0 kommt.
3. Die 0 wird invertiert, alle folgenden Bits werden belassen, bis eine 1 kommt.
4. Goto Step 2.

Gray Code $\longrightarrow$ Binary Code:

1. Beginnend mit dem MSB der Binärdarstellung, alle 0 werden belassen bis eine 1 kommt.

2. Die 1 wird belassen, alle folgenden Bits werden invertiert bis eine 1 kommt.
3. Die 1 wird invertiert, alle folgenden Bits werden belassen, bis eine 1 kommt.
4. Goto Step 2.

3.1.3 Lossless JPEG

Bis zu einer Bittiefe von 6 bpp gibt zukzessives JBIG kodieren gute Ergebnisse, bei einer höheren Bittiefe sollte man zu einem anderen Verfahren greifen. Hier bietet sich insbesondere der Standard zur verlustfreien Bildkomprimierung der Joint Photographic Experts Group (JPEG) an. Lossless JPEG ist ein klassischer lossless DPCM coder. Aufgrund einer Prediction für ein aktuelles Pixel wird ein Residual erstellt (das geringere Entropie aufweist) welches dann mit einem verlustfreien Verfahren kodiert wird, in diesem Fall mit einem fixen Huffman Code. Es stehen weiters 7 verschiedene Prediktoren zur Auswahl, die allerdings manuell ausgewählt werden müssen. In (nicht standardisierten) Erwieterungen wird automatisch der beste Prediktor ausgewählt - sei es für das ganze Bild, auf Blockbasis oder stetig. Das Residual ist nicht direkt Huffman kodiert: es wird als ein Symbolpaar dargestellt - Kategorie und Größe. Nur die Kategorie wird Huffman kodiert. Weiterentwicklungen gibt es im Rahmen des JPEG-LS Algorithmus.

3.1.4 GIF, PNG, TIFF

Der GIF (Graphics Interchange Format) Standard ist ein proprietärer CompuServe Standard (was zu großer Aufregung geführt hat). Aus historischen Gründen (d.h. 1987 glaubte man daß die Darstellung von 16 Farben auf einem Computerbildschirm Zukunftsmusik sei) ist die Anzahl der möglichen Farben auf 256 beschränkt (aus einer möglichen Auswahl von 16 Millionen). Das heißt das für höhere Farbtiefe ein Quantisierungseffekt auftritt (d.h. in diesem Fall verlustbehaftete Kompression). Neben einer Vielzahl von Headerinformation (u.a. für die Möglichkeit von animated GIFs und der (lokalen) Farbbeschreibungen) werden die tatsächlichen Bilddaten mit dem LZW Verfahren komprimiert (Achtung: patentrechtlich geschützt !).

PNG ist das *Portable Network Graphics* Format das als lizenzfreie Antwort auf GIF geschaffen wurde ("**P**NG **N**ot **G**IF"). PNG bunutzt eine Variante von LZ77, ist vollständig lossless und wird vom wordwide Web Konsortium (W3C) unterstützt.

TIFF (Tagged Image File Format) unterstützt verschiedene Farbdarstellungen und Bildauflösungen. Es ist jedoch **KEIN** Kompressionsstandard sondern ein Fileformat das unkomprimierte Bilder und 6 verschidene Kompressionsmethoden (5 davon lossless und lossy JPEG) unterstützt. Die verlustfreien Methoden beinhalten die Faxkompressionsmethoden ITU-T T.4 und T.6 und eine LZW Variante.

3.2 Verlustbehaftete Bildkompression

3.2.1 JPEG

JPEG ist das klassische Bildkompressionsverfahren des vergangenen Jahrzehnts. Es besteht aus einer DCT die auf 8×8 Bildblöcke angewendet wird, anschließender Quantisierung, zig-zag Umordnung und abschließender Kodierung (Mischung aus Runlength und Huffman Kodierung).

3.2.2 Wavelet Kompression, JPEG2000

Im Gegensatz zur Fouriertransformation ist die Wavelettransformation von zwei Parametern abhängig:

$$W_{a,b}(f) = |a|^{-1/2} \int_{-\infty}^{\infty} f(t)\, \psi\left(\frac{t-b}{a}\right)\, dt$$

Die Funktionen $\psi_{a,b}(s) = |a|^{-1/2}\, \psi\left(\frac{s-b}{a}\right)$ werden Wavelets genannt, $\psi(s)$ heißt oft *mother wavelet*.

Wenn sich a ändert, beschreiben $\psi_{a,b}$ unterschiedliche Frequenzbereiche, wird auch der Parameter b geändert verschiebt sich das Zeit-Lokalisierungszentrum (das in $s = b$ liegt). Alle Wavelets sind also verschobene und skalierte Versionen des Mother Wavelets.

Der Hauptunterschied zur gefensterten Fouriertransformation liegt in der Form der Basisfunktionen. Während alle Fensterfunktionen im Fourierfall gleiche Breite haben, haben die $\psi_{a,b}$ eine Breite die von der Frequenz abhängen: hochfrequente $\psi_{a,b}$ haben geringe Breite während niedefrequente $\psi_{a,b}$ breiter sind.

Beispiele für $\psi(x)$, das Mother Wavelet:

$$\psi(x) = \left(1 - x^2\right)\, e^{\frac{-x^2}{2}} \qquad \text{"Mexican hat"}$$

$$\psi(x) = \frac{\sin(2\pi x) - \sin(\pi x)}{\pi x} \qquad \text{"Shannon wavelet"}$$

$$\psi(x) = \begin{cases} 1 & : \quad 0 \le x \le 1/2 \\ -1 & : \quad 1/2 < x < 1 \\ 0 & : \quad otherwise \end{cases} \qquad \text{"Haar wavelet"}$$

Diskretisierung: Beschränkung der Parameter (a, b) auf diskrete Werte: $a = a_0^m$, $b = nb_0a_0^m$ mit $m, n \in \mathbf{Z}$ und $a_0 > 1$, $b_0 > 1$. Gern nimmt man $a_0 = 2$ and $b_0 = 1$.

$$W_{m,n}(f) = 2^{-m/2} \int_{-\infty}^{\infty} f(t)\psi(2^{-m}t - n)\, dt$$

Die schnelle Wavelettransformation beruht auf einer einfachen Subbandfilterung die höherdimensional separabel angewendet werden kann.

In Analogie zu JPEG bestehen einfache Kompressionsalgorithmen aus Transformation, Quantisierung und Kodierung. Fortgeschrittene Verfahren beruhen auf dem Konzept der Zerotrees und benutzen die Lokalität der Transformationsbereiches der Wavelettransformation.

3.2.3 Fraktale Kompression

Fraktale Kompression versucht Selbstähnlichkeiten in einem Bild zur effizienten Beschreibung auszunutzen. Die Grundidee beruht auf folgender Beobachtung: komplexe geometrische Stukturen wie etwa Farne, Apfelmännchen etc. lassen sich durch eine kleine Menge von Formeln beschreiben, obwohl der Detailreichtum unendlich groß sein kann ("Fraktale"). Um so eine Struktur platzsparend zu speichern ist es besser diese Formeln zu speichern als das entsprechende Bild. Dies soll auch mit gewöhnlichen Bildern gemacht werden. Hier gibt es allerdings zwei Probleme:

1. Gewöhnlichen Bilder sind keine Fraktale und weisen nur in einem sehr eingeschränkten Sinn Selbstähnlichkeiten auf. Daher wird das Bild unterteilt und die globale Selbstähnlichkeit wird auf Ähnlichkeiten von Blöcken reduziert.

2. Es ist sehr rechenaufwendig, zu einem gegebenen Fraktal die zugehörigen Formeln zu finden ("inverses Problem").

Fraktale Kompression bleibt in jedem Fall sehr zeitaufwendig, wogegen die Dekompression sehr schnell ist. Diese extreme Asymmetrie macht dieses Verfahren für spezielle Anwendungen sehr geeignet, für andere völlig ungeeignet (gut für off-line Anwendungen, Photo-CDROM, VoD, schlecht für VC u.s.w.).

3.2.4 Vektor Quantisierung

Das zu komprimierende Bild wird zuerst in n-dimensionale Bildvektoren zerlegt (z.B. $n = l \times m$ Pixelblock formt n-dimensionalen Vektor oder 3-dimensionaler Vektor durch RGB Komponenten eines Pixels). Jeder Bildvektor X wird mit den Codevektoren X_i, $i = 1, \ldots, N_c$ verglichen die aus einem zuvor generierten oder definierten Codebook stammen. Diese Vektoren haben auch Dimension n. Der best-passendste Vektor wird durch Distortion - Minimierung ermittelt. Nach dieser Wahl wird nur der Index des Codevektors gespeichert (mit $\log_2 N_c$ bits).

Der Decoder ist extrem schnell, mit einem look-up table Verfahren wird der Index wieder durch den entsprechenden Vektor ersetzt. Kompressionsrate = $\log_2 N_c/n$ bpp (d.h. gut ist ein kleines Codebook und eine große Vektordimension).

Probleme:

1. Wie erzeugt man das Codebook ?
   - LBG Algorithmus
   - Codebook Initialisierung
2. Wie soll Codebook strukturiert sein um effizient suchen zu können ?
   - Baumstruktur
   - Product Codes

Weitere Spielarten von Vektorquantisierung sind die folgenden:

- Mean/Residual VQ
- Interpolative/Residual VQ
- Klassifizierte VQ
- Hierarchische VQ
- Transform VQ

3.2.5 Block Truncation Coding

Nicht überlappende $n \times n$ Pixelblöcke werden mit einem one-bit Quantizer kodiert, der in Abhängigkeit von der Blockstatistik designed wird. Es wird der Mittelwert des Blockes berechnet, alle Pixel mit größerem Wert werden auf 1 gesetzt, der Rest auf 0. Die entstehende Bitmap wird kodiert. Ebenso wird der Mittelwert der beiden entstehenden Regionen berechnet und kodiert. Bei der Rekonstruktion werden die Werte 0 und 1 durch die jeweiligen Mittelwerte der Regionen ersetzt. Um eine höhere Qualität zu erzielen gibt es eine hierarchiches BTC Verfahren: liegen die Mittelwerte der beiden Regionen zu weit auseinander und ist der Fehler zu groß wird der Block aufgeteilt und das Verfahren auf die kleineren Teilblöcke angewendet.

3.2.6 Hierarchical Coding

Bilder sind so komprimiert, daß man ein Bild mit verschieden hoher Auflösung oder Qualität dekomprimieren kann. Anwendung:

- Progressive Transmission
- Multiuser Environments

Gemeinsamer Aspekt: benutzt werden Bildhierarchien mit verschiedenen Stufen, die dem rekonstruierten Bild mit verschiedener Auflösung bzw. Qualität entsprechen.

- Fixed resolution Hierarchies: Rekonstruiertes Bild ist gleich groß wie Original und der Wert eines konkreten Pixels wird Stufe für Stufe verfeinert. z.B.: Bit-Planes, Transform Based - wichtige Koeffizienten zuerst
- Variabel resolution Hierarchies: Pyramidenstruktur, Basis ist Originalbild, auf höheren Stufen nimmt die Auflösung ab. z.B.: Subsampling Pyramid, Mean Pyramid, Prediction/residual Pyramid (Gaussian-Laplacian Pyramid)

Kapitel 4

Video

Im Zusammenhang mit der Verarbeitung, mit dem Übertragen und der Speicherung von Videodaten ist es selbstverständlich, dass diese Aufgaben effizient nur mit einem reduzierten Datenvolumen zu bewältigen sind. Das ISO MPEG Kommitee (Motion Picture Experts Group) ist das wichtigste Standardisierungsorgan in diesem Bereich. Zusätzlich zur Redundanz im Bildbereich die bei Stillbildkompression ausgenutzt wird kommt im Bereich der Videoverarbeitung noch die temporale Redundanz, d.h. die Ähnlichkeit aufeinanderfolgender Frames.

4.1 MPEG-1

MPEG-1 ist ein Standard für effiziente Speicherung und Übertragung von Video und Audio mit einer Datenrate von ca. 1.5 Megabit/sec. Klassisches Hauptanwendungsgebiet ist die Speicherung auf CD-ROM. Es wird nur progressive Video mit 8 bpp und einem Luminance und zwei Chromakanälen (Subsampling 4:2:0) berücksichtigt. Wesentlich ist, dass nur der Bitstream bzw. der Decoder standardisiert ist, der Encoder Teil muss nur den entsprechenden Bitstream generieren, ansonstern kann er frei designed werden. Ein Flag im Bitstream zeigt an ob es sich um "constrained parameter" MPEG-1 handelt, der von allen MPEG-2 Decodern verarbeitet werden kann. Im MPEG-1 Standard gibt es zwei grundsätzlich verschiedene Möglichkeiten, Videomaterial zu speichern.

4.1.1 Intraframe Kompression

In diesem Modus wird jeder Frame einer Videosequenz als unabhängiges Bild betrachtet und komprimiert. Als Konsequenz werden nur Redundanzen im Bildbereich ausgenutzt, die Kompression ist ähnlich wie bei MJPEG (= Motion JPEG). Obwohl die erreichbare Kompressionsrate nicht über die eines Stillbildkompressionsverfahrens hinausgeht, werden solche Verfahren dennoch für spezielle Anwendungen benötigt: z.B. für Video editing wo random access eine wesentliche Rolle spielt. Die Kompression ist dem JPEG Verfahren sehr ähnlich, mit einem wesentlichen Unterschied:

- Adaptive Quantisierung der AC Koeffizienten wird ermöglicht, kann von Makroblock zu Makroblock wechseln (ein Makroblock besteht in MPEG-1 aus 4 8x8 Pixel Blöcken Luminance und je einem 8x8

Chroma Block). Dies wird durchgeführt in Abhängigkeit von der Aktivität (der Unruhe) des Blocks und des Buffer Status bei Applikationen mit konstanter Bitrate.

Ansonsten werden in Analogie zu JPEG 8x8 Pixel Blöcke einer DCT unterzogen, die resultierenden AC Koeffizienten durch eine Quantisierungsmatrix quantisiert, zig-zag gescannt und mit gegebenen VLC Tabellen kodiert. Die DC Koeffizienten werden gleichmässig quantisiert und die verschiedenen DC Koeffizienten innerhalb eines Makroblocks und benachbarter Makroblöcke DPCM kodiert. Die sogenannten *I-Frames* bestehen ausschliesslich aus Makroblöcken die in der beschriebenen Art komprimiert wurden.

4.1.2 Interframe Kompression

In diesem Modus werden spatiale und temporale Redundanzen ausgenutzt und es wird versucht im Video auftretende Bewegungen (Objekt- oder Kamerabewegungen) durch vorausgehende Bildanalyse zu kompensieren. Die Bewegungsanalyse wird auf der Basis von Makroblöcken durchgeführt, d.h. für einen Makroblock gibt es einen sg. Displacementvektor, der angibt, wohin sich der entsprechende Makroblock bewegt hat. Das bedeutet, dass das erlaubte Bewegungsmodell auf Translation von Blöcken eingeschränkt ist. Die Art der Berechnung des Displacementvektors ist nicht standardisiert und ist spezifisch für die jeweilige Implementierung. Das klassische Verfahren zur Bewegungsschätzung (Motion estimation) ist sg. Blockmatching das in allen Hardwareimplementierungen verwendet wird. Bei diesem Verfahren wird ein Block im zu kodierenden Frame mit allen möglichen Blöcken in einem Suchfenster bestimmter Grösse im bereits *rekonstruierten* Frame verglichen und auf den ähnlichsten Block zeigt dann der Displacementvektor. (Es ist wichtig, dass ein bereits rekonstruierter Frame verwendet wird, denn der Decoder hat ja nur solche Frames zur Verfügung - daraus folgt, dass ein Encoder immer auch einen Decoder entrhalten muss). Sind für alle Blöcke im zu kodierenden Frame die entsprechenden Displacementvektoren gefunden, wird der "predicted" Frame aus den Blöcken des reference Frame berechnet (die "motion compensated prediction") und der Differenzframe zum zu kodierenden Frame berechnet. Gespeichert werden im MPEG-1 Bitstream dann die Displacementvektoren (wobei durch DPCM Kodierung weitere Redundanz zwischen benachbarten Vektoren - entsprechend grösseren sich bewegenden objekten - ausgenutzt wird) und die Differenzframes (welche wieder in 8x8 Pixelblöcke zerlegt einer DCT unterzogen werden. Die Quantisierungsmatrix weist an allen Stellen gleiche Werte auf, da keinesfalls hochfrequente Inhalte bei Errorframes unterdrückt werden dürfen, ausserdem wird der DC Koeffizient nicht gesondert behandelt.) Interessanterweise ist für die Motionvektoren Halbpixel-Genauigkeit erlaubt (die fehlenden Werte werden interpoliert, was insbesondere bei starken Bewegungen deutliche Qualitätsverbesserung bringt).

In Entsprechung zu den I-Frames gibt es zwei Frame-typen im interframe Kompressionsmodus:

- P-Frames: pro Makroblock gibt es maximal einen Displacementvektor der in die "Vergangenheit" zeigt. Je nach Qualität der erreichten Prediction werden Makroblöcke in P-Frames als Errorblöcke mit Displacementvektoren oder als I-Frame Blöcke gespeichert.
- B-Frames: pro Makroblock kann es bis zu zwei Displacementvektoren geben. Im Fall der bidirektionalen Prediktion werden als Reference Frames rekonstruierte I oder P Frames in der Zukunft und Vergangenheit verwendet, die Prediktion entsteht durch Mittelung. Ebenso können B-Frame Makroblöcke aber nur durch Prediction auf zukünftige oder vergangene Frames dargestellt werden, oder sie werden bei schlechter Prediktion als I-Frame Blöcke gespeichert.

Die in einem MPEG-1 Bitstream tatsächlich vorkommenden Muster von I, P, und B-Frames hängen ab von

- Anforderungen bezüglich Zugriff und Dekodierungsverzögerung
- Benötigter Kompressionsrate
- Inhalt des Videos

Eine GOP (group of Pictures) enhält zumindest ein I-Frame und beliebig viele P und B-Frames. Der maximale Abstand zwischen zwei I-Frames beträgt in MPEG-1 132 Frames !

4.2 MPEG-2, H.261 und H.263

4.2.1 MPEG-2

MPEG-2 zielt auf höhere Bitraten und damit höhere Qualität als MPEG-1. Erlaubt ist 4:2:2 und auch 4:4:4 Ausgangsmaterial. Tyische Anwendungen sind digitales Fernsehen (HDTV - High Definition TV) und Video auf DVD. Durch die Ausweitung auf den TV Bereich wird nun auch interlaced Video erlaubt (Interlaced Video besteht aus Paaren von sg. "Fields", die die halbe Zeilenauflösung eines gesamten Frames haben und zeitversetzt sind. Ursprünglich hatten sie die Aufgabe, flimmerfreies Fernsehen bei geringer Datenrate zu ermöglichen - in jedem Zeitschritt wurde nur jede zweite Zeile upgedatet). Daraus ergeben sich neue Möglichkeiten Bilder zusammenzusetzen: die sg. "Frame Pictures" entstehen durch Interleaving der even und odd Fields, "Field Pictures" sind nur halb so gross und sind entweder das even oder das odd Field. Diese beiden Typen können in einem MPEG-2 Bitstream beliebig abgewechselt werden. MPEG-2 hat eine Profile (Funktionalität) und Level (Parameterwerte) Struktur und könnte eher als Algorithmensammlung gesehen werden. Typische Schriebweise: Main Profile at Mail Level: MP@ML (z.B. DVD).

Zusätzliche Unterschiede zu MPEG-1 sind:

- Feinere Quantisierung der DC und AC Koeffizienten, unterschiedliche Quantisierung von Luma und Chroma
- Feinere Anpassung der adaptiven Quantisierung
- Displacementvektoren müssen mindestens mit Halbpixelgenauigkeit berechnet werden
- Durch das Interlacing gibt es viele zusätzlich erlaubte Arten Displacementvektoren zu berechnen wobei adaptiv zwischen Frame Picture basierter und Field Picture basierter Berechnungsart gewechslt werden kann (siehe auch dual-prime Prediction).
- Error Concealment: Es gibt Strategien wie durch Übertragungsfehler verlorengegangene Daten (Blöcke oder Displacementvektoren) interpoliert werden können, z.B. können für diesen Zweck auch für Intrakodierte Blöcke Displacementvektoren gespeichert werden).
- Scalability (Skalierbarkeit): hier geht es darum aus ein und demselben Bitstream Videos unterschedlicher Auflösung, Qualität und Frameraten dekodieren zu können. In MPEG-2 wird das (im Vergleich zu Wavelet Methoden) sehr artifiziell durch sg. Base- und Enhancementlayer realisiert.

4.2.2 H.261

Ist der Videoteil des H.320 Standards, hauptsächlich vorgesehen für Videoconferencing und Bildtelephonie über ISDN Kanäle mit $p \times 64$ kbits/sec. H.261 ist MPEG/1 sehr ähnlich, erlaubt aber aus Komplexitätsgründen keine B-Frames (denn sowohl Encoder als auch Decoder müssen real-time fähig sein !). Ein H.261 Encoder kann auch Frames weglassen oder die Auflösung reduzieren um die Bildqualität bei gegebener Bitrate aufrechterhalten zu können. Zwei Bildformate werden unterstützt: Q(uater)CIF und CIF (common interchange format), chroma sampling ist 4:2:0.

4.2.3 H.263

Ist der Videoteil des H.324 Standards (Terminal for low-bit rate Multimedia Communications), hauptsächlich vorgesehen für Videoconferencing und Bildtelephonie über Telephonkanäle mit 28.8 kbits/sec.

Unterschide zu H.261:

- Zusätzliche Bildformate
- Displacementvektoren können mit Halbpixelgenauigkeit berechnet werden.
- Besseres Kodieren der Displacementvektoren.
- Optionales Arithmetisches Kodieren.
- Optionales Verwenden von überlappenden Blöcken bei der Berechnung der Displacementvektoren.
- Möglichkeit zur bidirektionalen Prediktion.

Weiter Verbesserungen in H.263+ wo u.a. ein grosser Bereich von Framegrössen erlaubt ist und das Intracoding durch Prediction von benachbarten Blöcken verbessert ist.

4.3 MPEG-4

MPEG-4 ist ein Standard für Videokompression im Multimediabereich. Da ein wesentlicher Aspekt von vielen Multimedia-Anwendungen die Interaktivität ist, ist eines der Hauptzüge dieses Standards Methoden bereitzustellen, um Interaktivität zu ermöglichen. In bisherigen Standards ist Interaktivität durch die framebasierte Verarbeitung nicht möglich. In MPEG-4 wird das durch eine Objektbasierung ermöglicht.

MPEG-4 baut auf dem Erfolg in folgenden drei Feldern auf:

- Digitales Fernsehen
- Interaktive Graphik Anwendungen (z.B. Computerspiele)
- Interaktive Multimedia Anwendungen (z.B. WWW, Verteilung von/und Zugang zu Inhalt)

Dieser relativ neue Standard verbessert die Anwendungs/Verwendungsmöglichkeiten von Autoren, Service Providern und Verbrauchern.

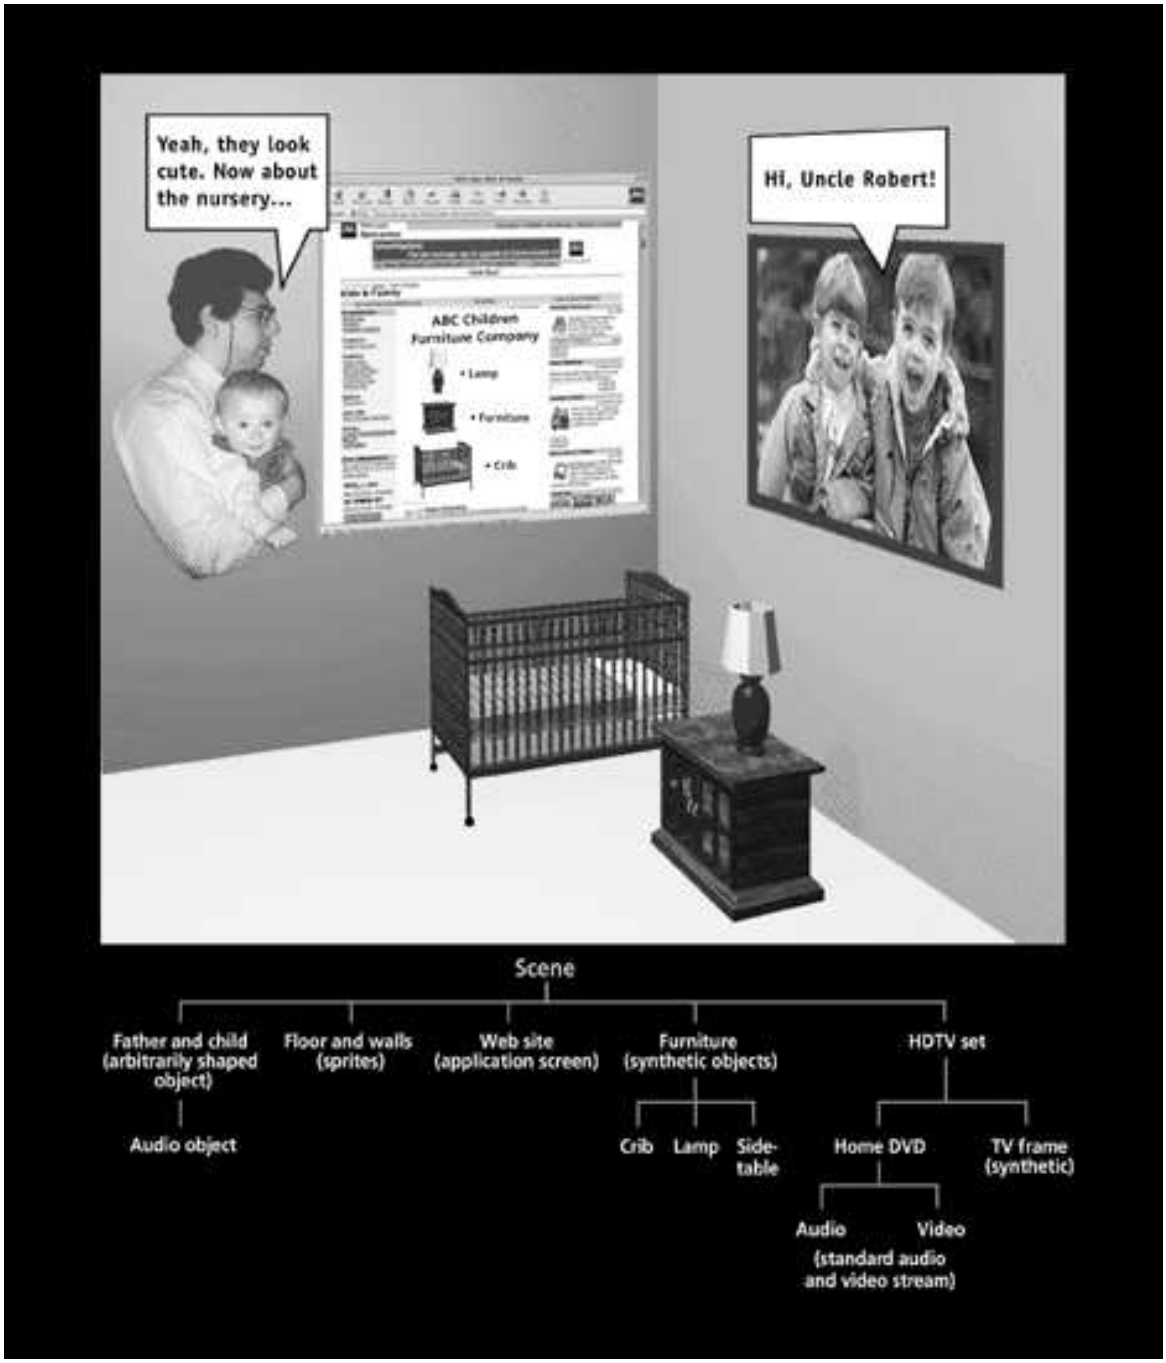
Yeah, they look cute. Now about the nursery...
Hi, Uncle Robert!
ABC Children Furniture Company
Scene
Father and child (arbitrarily shaped object)
Audio object
Floor and walls (sprites)
Web site (application screen)
Furniture (synthetic objects)
Crib
Lamp
Side-table
HDTV set
Home DVD
Audio
Video
(standard audio and video stream)
TV frame (synthetic)

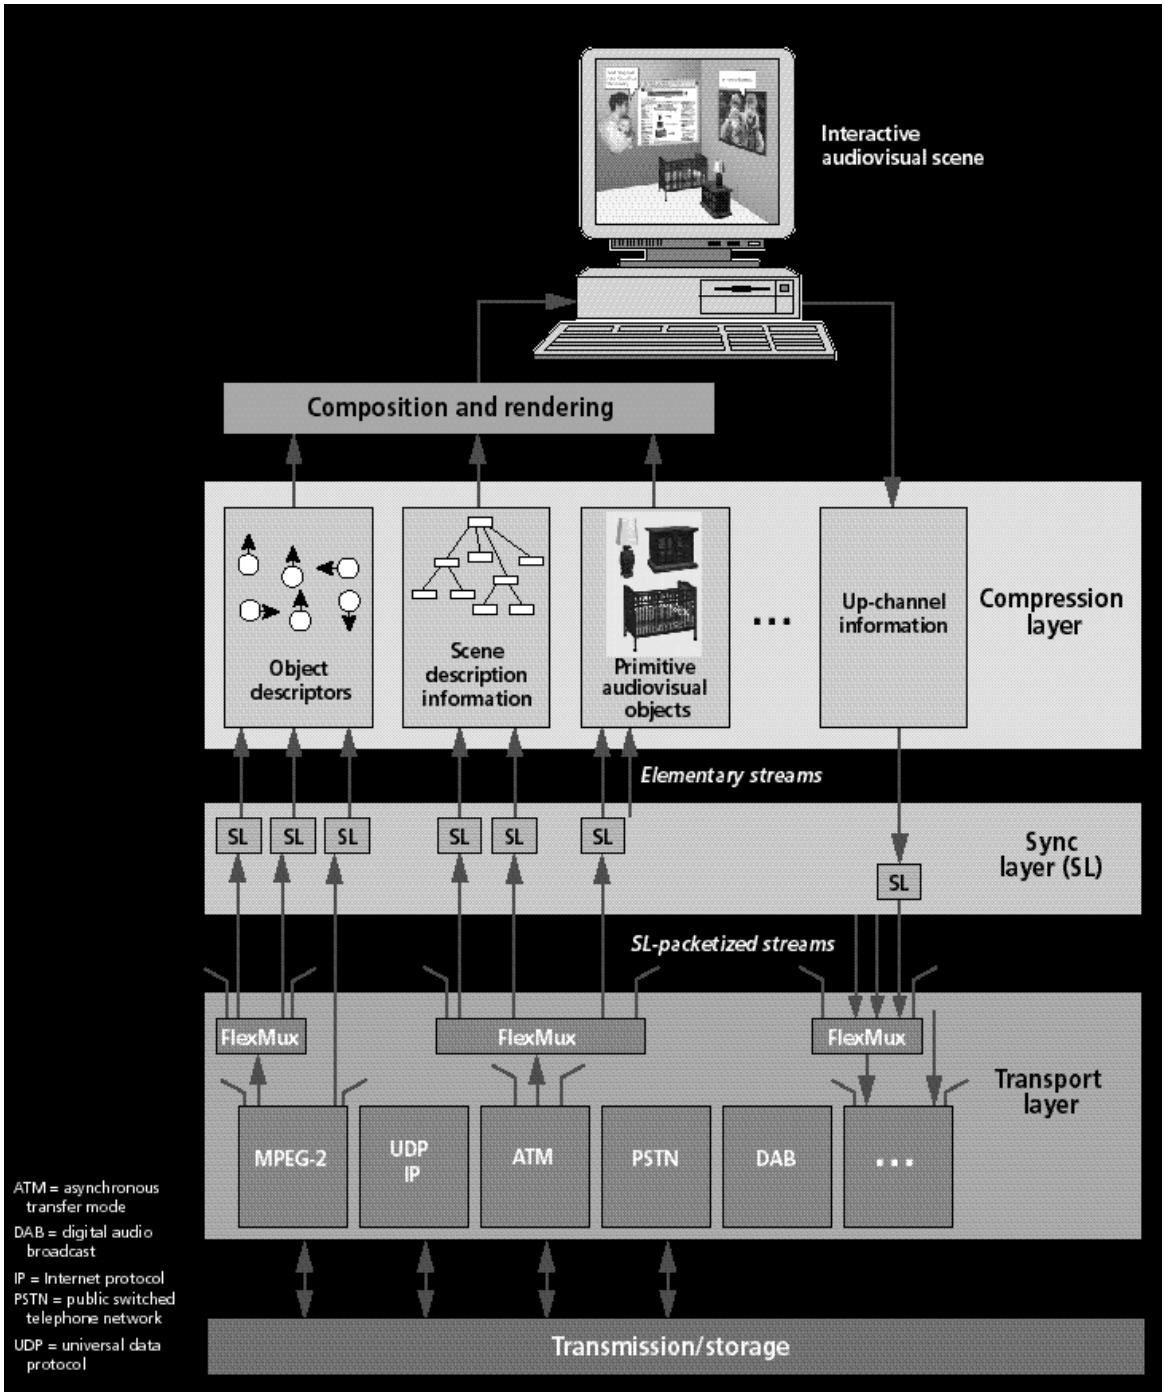
Interactive audiovisual scene
Composition and rendering
Object descriptors
Scene description information
Primitive audiovisual objects
...
Up-channel information
Compression layer
Elementary streams
SL
Sync layer (SL)
SL-packetized streams
FlexMux
Transport layer
MPEG-2
UDP IP
ATM
PSTN
DAB
...
ATM = asynchronous transfer mode
DAB = digital audio broadcast
IP = Internet protocol
PSTN = public switched telephone network
UDP = universal data protocol
Transmission/storage

- Autoren: Wiederverwertbarkeit von Information wird durch die Objektbasierung wesentlich verbessert, besserer Schutz von Copyright, etc.
- Service Provider: bessere Netzwerkauslastung durch MPEG-4 QoS Deskriptoren
- Verbraucher: erstmalige Möglichkeit von Interaktion mit Multimedialen Daten, von Standardnetzwerken bis hin zu mobilen Netzwerken (z.B. Interaktives Video Über Satellit auf personal organizer - die Frage bleibt: wer braucht das ;-)

MPEG-4 beinhaltet daher nicht nur (oder in erster Linie) Kompressionsverbesserung sondern Funktionalitätserhöhung. Das wird erreicht durch Standardisierung in folgenden Bereichen:

- Repräsentierung von "Media Objekten", die Einheiten von visuellen, audiovisuellen oder Audio Daten sind, die natürlichen oder künstlichen Ursprungs sein können.
- Zusammensetzung von media objekten zu einer audiovisuellen Szene.
- Multiplexing und Synchronisierung der Daten entsprechend den Media Objekten um sie über Netzwerke mit ihnen entsprechenden QoS Anforderungen transportieren zu können.
- Interaktion mit der audiovisuellen Szene beim Verbraucher.

MPEG-4 audioviduelle Szenen sind zusammengesetzt aus mehreren Media Objekten die in einer hierarchischen Art und Weise organisiert sind. Als Endknoten dieser Hierarchien findet man "primitive Mediaobjekte" wie Stillbilder, Video Objekte, Audio Objekte, u.s.w.

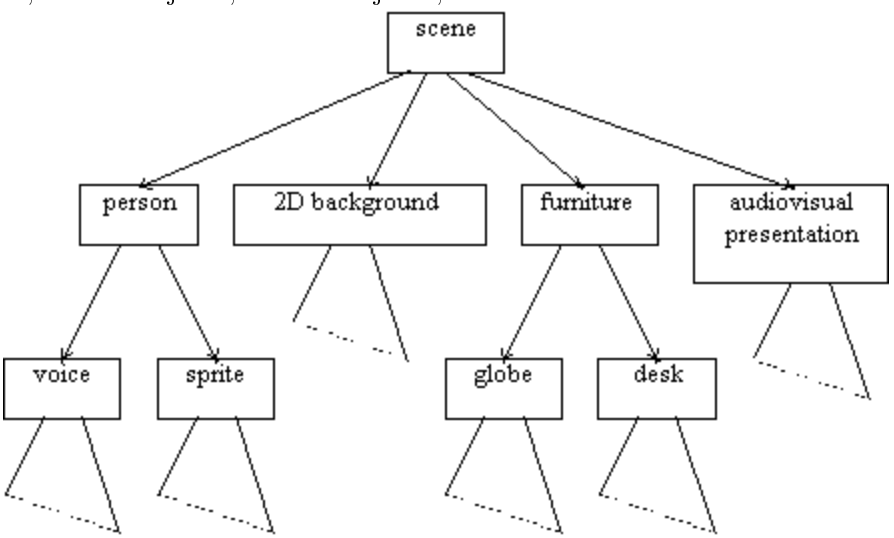

Zusätzlich gibt es noch Definition von speziellen Objekten, wie z.B. Text und Graphiken, sprechende synthetische Köpfe mit assoziiertem Text um die Sprache zu synthetisieren und den Kopf zu animieren, synthetischer Klang, etc.

Die Szenenbeschreibung ist standardisiert (mit einer grossen Nähe zur Computergraphik oder Virtual Reality - VRML) und erlaubt folgendes:

- Media Objekte können an beliebiger Plazierung in einem Koordinatensystem positioniert werden.
- Media Objekte können Transformationen unterzogen werden die die geometrische oder akustische Erscheinung verändern.
- Primitive Media Objekte können zu einem grossen media objekt zusammengefasst werden.
- Streamed Data kann auf Media Objekte angewendet werden um die Eigenschaften zu verändern (z.B. ein Klang, eine sich bewegende Textur, Animationsparameter für ein Gesicht, ...)
- Veränderung des Blick- und Hörpunkts des Benutzers in der Szene

Die synchronisierte Übertragung von streaming Data über ein Netzwerk mit verschiedenen QoS wird durch eine Synchonisierungsschicht und eine Übertragungsschicht mit einem zwei-Schicht Multiplexer geregelt.

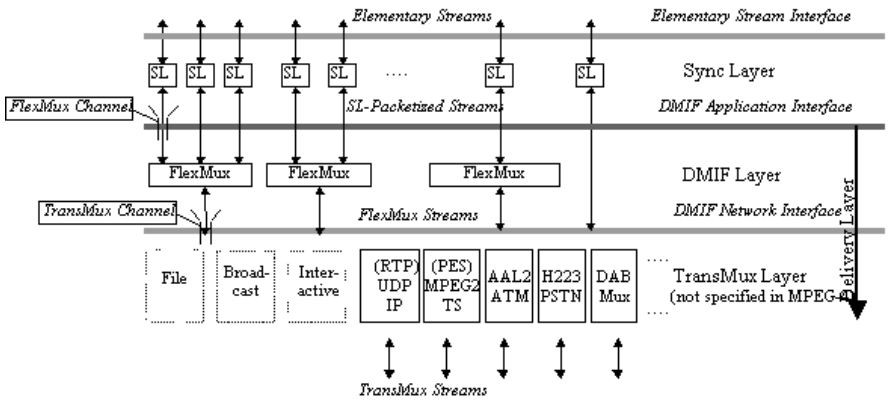

Die erste Multiplexerschicht wird entsprechend der DMIF (Delivery Multimedia Integration Framework) Spezifikation implementiert. DMIF ist ein Sitzungsprotokoll für Multimedia Streaming Daten ähnlich wie FTP. Mit dem MPEG FlexMux Tool können z.B. elemetary streams mit ähnlichen QoS Anforderungen zusammengefasst werden. TransMux wird schliesslich verwendet um verschiedenen QoS Anforderungen gerecht werden zu können. Nur das Interface zu dieser Schicht ist standardisiert, die Umsetzung muss über das Netzwerk Transport Protokoll geschehen.

Möglichkeiten für Interaktion:

- Blick- und Hörwinkel verändern
- Objekte in einer Szene verschieben/entfernen
- Eine Kaskade von Ereignissen auslösen, durch “Mausklick” - Abspielen eines Videos oder animierter Graphik, ...
- Auswahl der geeigneten Sprache oder Ansicht bei Multiview/listen Ausnahmen

4.3.1 Kompression von synthetischen Videoobjekten

Exemplarisch werden hier Gisichtsanimation und mesh-coding mit Textur Mapping behandelt.

Ein "facial animation object" kann verwendet werden um ein bewegtes künstliches Gesicht zu generieren. Form, Aussehen und Ausdruck des Gesichts werden von den "Facial Description Parameters (FDP)" und "Facial Animation Parameters" (FAP) bestimmt. In MPEG-4 sind dann Methoden standardisiert wie FDP und FAP effizient kodiert und auch interpoliert (bei Datenverlust) werden können. In MPEG-4 Version 2 sind analoge Methoden für parametrische Körperbeschreibung und Animation enthalten.

Ein "2-D Mesh" ist eine Unterteilung einer 2-D planaren Region in polygonale Teile. Die Eckpunkte der Teile heissen "node points" des Meshs. MPEG-4 lässt nur Triangulierung zu. Ein 2-D dynamisches Mesh bezeichnet die geometrische Mesh Information und der Bewegung der node points in einer bestimmten Zeitspanne. Für das Mappen von Textur auf so ein Mesh werden die ursprünglich dreieckigen Teile des Mesh und der Textur durch die Bewegung verformt. Die Textur wird dann auf das entsprechende Teil des neuen Meshes durch "warping" angepasst. Wird die Möglichkeit der Abbildung auf eine affine beschränkt kann die Bewegung mit nur wenigen Parametern shr effizient gespeichert werden. Diese Art der Darstellung bietet einige interessante Features:

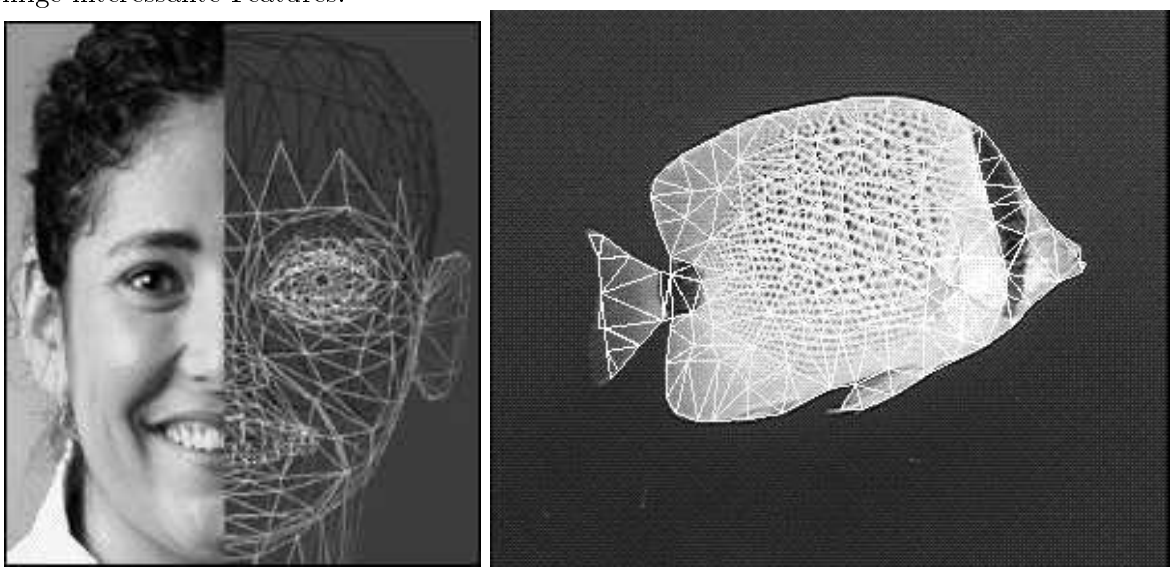

- Augmented Reality: Vermischung von computergenerierten Daten mit wirklichen bewegten Objekten
- Ersetzen eines natürlichen Videoobjekt durch ein synthetisches
- Verbesserte Kompression@low bit rates: nur die Textur wird komprimiert (und einige "Animationsparameter")
- Verbesserte Darstellung der Umrisse eines Objektes (Polygone statt Bitmaps)

4.3.2 Kompression von natüerlichen Videoobjekten

Die beliebige Form der Videoobjekte legt die Frage nahe, wie man Datenmaterial generieren kann, dass eine objektorientierte Segmentierung aufweist. Der MPEG-4 Standard legt hier nichts fest, jedoch sind folgende Varianten denkbar:

- Vollautomatische Segmentierung von vorhandenem Videomaterial: klappt nur bei einfachen head-and-shoulder Sequenzen, ansonsten ist das Problem der semantisch korrekten Segmentierung ein ungelöstes !
- Semiautomatische Segmentierung von vorhandenem Videomaterial mit manueller Segmentierung von Keyframes und temporal Tracking der Objektgrenzen.
- Neugenerierung von MPEG-4 konformen Videomaterial mit "blue-screen" ähnlichen Verfahren.

Bitstreamhierarchie

Ein MPEG-4 Bitstream liefert eine hierarchische Szenenbeschreibung: die komplette Szene heisst Visual Object Scene (VS) und enthält 2-D oder 3-D Objekte und die ensprechenden Enhancement Layers. Ein Video Objekt (VO) entspricht einem konkreten Objekt in der Szene, im einfachsten Fall ein rechteckiger Frame, oder eben ein Objekt beliebiger Gestalt, das Vorder- oder Hintergrund sein kann. Die nächste Ebene ist die der Video Object Layer (VOL): je nachdem ob das Objekt in skalierbarer oder nicht-skalierbarer Form gespeichert ist. Jedes Zeit Sample eines Video Objekts ist eine Video Object Plane (VOP), mehrere können zu einer Group of Video Object Planes (GOV) zusammengefasst sein.

Eine VOP kann verschieden kodiert sein. Im "klassischen" Fall enthält sie Bewegungsparameter, Gestaltinformation und Textur. Ebenso kann ein "Sprite" (siehe später) als VOP gespeichert sein. In MPEG-4 wird das 4:2:0 Chromasampling und die gutbekannte Makroblockstruktur unterstützt. Die unterschiedlichen Videoobjekte werden unabhängig verarbeitet und gespeichert.

Kodierung von Gestaltinformation

Im Fall der binären Variante wird die Gestalt durch eine binäre Matrix definiert. Die Gestalt einer VOP wird von einer rechteckigen Maske umschrieben, die 16x16 Blöcke (BAB - binary alpha block) aufgeteilt wird. Die Werte ausserhalt der VOP werden auf 0 gesetzt, die anderen auf 1 (oder 255). Es gibt dann Blöcke mit lauter gleichen Werten (transparent - alle 0, opaque - alle 255) und natüerlich sloche die an der Grenze der VOP liegen. Die BABs werden gespeichert durch arithmetische Kodierung und block matching mation estimation und DPCM Kodierung der Motion Vektoren. Im Fall des gray scale coding wird zusätzliche Transparenzinformation gespeichert, hier werden 8bpp verwendet. In diesem Fall wird mit lossy DCT coding gearbeitet (anstelle von arithmetischer Kodierung).

Bewegungskompensation

Motion Compensation verwendet Grundideen von früheren Standards, adaptiert an das VOP Konzept. Es gibt I-VOPs, P-VOPs und B-VOPs. Motion estimation wird natürelich nur für Makroblocks durchgeführt, die im die VOP umgebenden Rechteck liegen. Im Fall von Makroblöcken die ganz in der VOP liegen, wird alles so gemacht wie in MPEG-2 (es kann auch für jeden 8x8 Block ein Displacementvektor berechnet werden). Für nur teilweise in der VOP gelegene Makroblöcke wird die "modified block (polygon) matching technique" verwendet. Nur Pixelwerte inerhalb der VOP werden für die Differenzberechnung verwendet; wenn der Referenzblock ausserhalb liegt, werden Pixelwerte nach vorgegebenen Schema eingefüllt. Überlappende Motion Compensation ist ebenfalls erlaubt.

Textur Kodierung

Für Blöcke in der VOP wird alles gemacht wie in MPEG-1 oder 2. Andere Behandlung erfordern natürlich wieder Blöcke die an der Grenze der VOP liegen. Solche Blöcke werden mit Werten befüllt, bis sie "normale" Blöcke sind und dann entsprechend verarbeitet. Im Falle von B oder P-VOPs werden 0 befüllt, bei einer I-VOP wird der Durchschnittswert der VOP mit einigen zusätzlichen Änderungen verwendet. Um zusätzlich die Kodierungseffizienz zu erhöhen, können die Koeffizienten von benachbarten Blöcken zur Prediktion verwendet werden, entweder nur die DC oder auch wichtige AC Koeffizienten. Es gibt drei scan-Varianten, neben dem zig-zag scan auch alternate-horizontal und alternate-vertical scan (muss mit der Prediction der Koeffizienten übereinstimmen.

Eine Besonderheit in MPEG-4 ist, dass es einen eigenen Kompressionsmodus für sg. "statische Texturen" gibt, das sind solche, die auf 2-D (oder 3-D) Meshes gemapped werden. Diese Variante bietet *wesentlich* bessere Skalierbarkeit und ist mit einem Wavelet Verfahren realisiert. Das low-pass suband wird DPCM kodiert, die anderen subbands mit einem zerotree ähnlichem Verfahren. Da es in den früheren MPEG Standards keine Entsprechnung zu statischen Texturen gibt, konnte hier die Forderung nach Rückwärtskompatibilität unter den Tisch gefallen lassen werden.

Fehlerbehandlung, Sprites und Skalierbarkeit

Da auch an mobile Environments gedacht ist, ist die Möglichkeit der Fehlerbehandlung besonders wichtig.

- Resynchronisierung: eindeutige Marker werden in den Bitstream eingebettet, ab denen wieder (nach datenverlust) unabhängig dekodiert werden kann.
- Datenaufteilung: Daten für Bewegungsinformation und texturinformation werden getrennt, erlaubt effizienteren Einsatz von Error Concealment.
- Header extension Code: Zusätzlicher Einbau von redundanter Headerinformation (zum Dekodieren natürlich extrem wichtig)
- Reversible VLC: hier handelt es sich um Codewörter, die auch ein Rückwärtsdekodieren erlauben.

Ein "Sprite" ist ein besonders grosses Video Objekt, das während einer ganzen Szene vorhanden ist und meist grösser ist als der momentane Bildausschnitt. Klassisches Beispiel ist natüerlich ein Hintergrundsprite. Ein solches VO wird am Beginn einer Szene übertragen und während der Szene entsprechend modifiziert. Kodierung erfolgt wie bei I-VOPs.

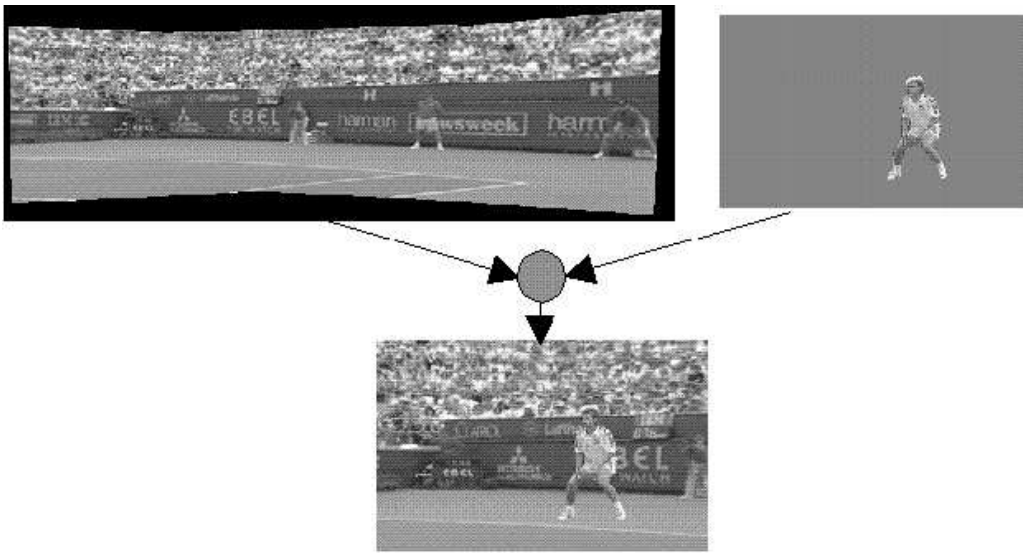

Skalierbarkeit bezüglich der Auflösung im Bildbereich und Zeitbereich werden durch multiple VOL implementiert. Objektskalierbarkeit wird natürlicherweise durch das VO Konzept unterstützt. Im Bereich der temporalen Skalierbarkeit gibt es zwei Typen:

- Enhancement Layer verbessert nur die Auflösung eines Teils des Base-layers
- Enhancement Layer verbessert die Auflösung des gesamten Base-layers

4.4 Non-standard Methoden

Es gibt sehr viele nicht-standardisierte Lösungen im Bereich MJPEG, da häufig aus Kostengründen auf motion estimation/compensation verzichtet wird, z.B. das DVCR Industrial Consortium (Digital Video Camera Recorder): ist eine vollständige Spezifikation das das Band, Audio und Videokompression beinhaltet. Es gibt drei Modi, standard definition (SD), high definition (HD) und advanced TV (ATV), wobei SD und HD DCT basierte intraframe Kompression (mit VLC Kodierung) verwendet, wogegen ATV MPEG-2 ähnlich ist.

Im Bereich "echter" Videokompression kann man grundsätzlich drei Arten unterscheiden:

- 2 dimensionale Kompression mit Bewegungskompensation (wie MPEG-1-4, H.261/3)
- 3 dimensionale Kompression ohne Bewegungskompensation
- 3 dimensionale Kompression mit Bewegungskompensation

Verfahren die den letzten beiden Punkten entsprechen haben meist hohe Anforderungen an die Hardware u.a. bezüglich Speicherumfang und CPU-Leistung und sind daher für die Massenproduktion nicht geeignet obwohl sie oft bessere Kompressionsleistung aufweisen.

4.4.1 Fraktale Kompression

Ist nur sinnvoll, wenn nicht Fehlerbilder fraktal komprimiert werden (denn die dominierenden hochfrequenten Anteile sind extrem schlecht mit fraktaler Technologie exakt darstellbar), also z.B.

- Fraktale Kompression von 3 dimensionalen Datenblöcken; hier gibt es dann eine Vielzahl von Möglichkeiten zur adaptiven Unterteilung.
- "Fraktales" Mapping von Blöcken zwischen Frames (das ist Blockmatching mit Grauwertkorrektur) und eventuellem Kodieren der Fehlerbilder.

4.4.2 Wavelet-basierte Kompression

Ist grundsätzlich in einem analogen Setting wie MPEG verwendbar, da aber hier keien 8×8 Pixelblöcke verwendet werden ist beim Blockmatching ein Überlappen der Blöcke sehr empfehlenswert. Die Vorteile im Hinblick auf reine Kompressionsleistung sind geringer im Vergleich zu Stillbildkompression. Verwendet man ein 3 dimensionales Modell, ist es z.B. sinnvoll kürzere Filter in die Zeitrichtung zu verwenden um Fehler nicht über mehrere Frames zu verteilen. Sehr effizient bezüglich Kompressionsleistung ist natüerlich die Verwendung von 3 dimensionalen Zerotrees, aber natürlich auch sehr zeitaufwendig.

4.5 MPEG-7

Im Moment sind effiziente Lösungen zur Suche nach Informationen beschränkt auf Text-basierte Daten (siehe Internet Suchmaschinen), in Multimedia Datenbanken (MMDB) kann man bezüglich Farben, Texturen, und Formen suchen, Ähnlich ist auch denkbar für Audio, Kontext und Semantik fehlt allerdings völlig. Es geht nicht nur um Suche in MMDBs sondern auch z.B. um Auswahl aus einer grossen Menge von TV Sendern.

MPEG-7 hat nichts mit Kompressionsalgorithmen zu tun sondern ist eine *Multimedia Content Description Language*: es geht um die Definition einer standardisierten Menge von Deskriptoren, um Methoden neue Deskriptoren zu definieren und um Strukturen und Relationen zwischen Deskriptoren. Für dieses Ziel wird eine eigene Sprache entwickelt: *Description Definition Language*. MPEG-7 ist nicht beschränkt auf die Beschreibung von MPEG-1-4 kodierter Daten sondern kann auch an einen analogen Film oder ein gedruckted Bild "angehängt" werden.

Es gibt verschiedene Beschreibungsebenen

- low: Form, Grösse, Farbe, Position
- high: semantische Ebene, Kontext

und damit verbunden die Frage wie das extrahiert werden kann (mit oder ohne menschliche Hilfe).

Zusätzlich zur rein inhaltlichen Ebene kann auch noch folgendes erfasst werden:

- Form der Darstellung, z.B. wie kodiert, Datenmenge

- Bedingungen für Zugriff (Copyright, Preis)
- Klassifizierung (Kategorisierung, parental guidance)
- Links zu anderem relevanten Material
- Kontext (wann, wo, unter welchen Bedingungen aufgenommen)

MPEG-7 Verarbeitungskette: Feature Extraction (nicht definiert) => Beschreibung (MPEG-7) => Suche (nicht definiert)

Anwendungsbeispiele:

- Musik: einige Noten am Keyboard spielen und Musik angeboten bekommen, die irgendwie ähnlich ist, z.B. bezüglich der hervorgerufenen Emotionen
- Grafik: einige Linien auf einem sensiblen Schirm zeichnen und Bilder mit ähnlichen Grafiken, Logos angeboten bekommen
- Bilder: textuelle Eingabe ("Bild aus Terminator II wo .....") oder Angabe von Strukturelementen (z.B. Textur)
- Bewegung: Definition von einer Anzahl und der Bewegung zwischen Objekten (z.B. viele kleine Objekte fahren im Kreis)
- Stimme: Stimmsample von Pavarotti => Musik, Videos von/über ihn werden angeboten

Timeline: Call for Proposals Oktober 1998, Working Draft Dezember 1999, International Standard September 2001

Kapitel 5

Audio

Interessanterweise wird im Audiobereich schon seit langer Zeit auf die Eigenschaften der menschlichen Wahrnehmung mehr Rücksicht genommen als dies im visuellen Bereich der Fall ist. Es werden praktisch keine numerischen Fehlermasse verwendet um Kompressionsverfahren zu vergleichen. Aus diesem Grund ist es hier wichtig, die menschliche Lautwahrnehmung zu studieren.

5.1 Eigenschaften der menschlichen Lautwahrnehmung

Im Audio Bereich gibt es eigene Masszahlen die der Wahrnehmung entsprechen und die sich von den analogen "objektiven" Massen unterscheiden (Frequenz vs. Pitch, Intensität vs. Loudness). Eine Möglichkeit einen "transparenten" Koder zu definieren, ist zu sagen, hier muss das codierte Signal vom Original nicht unterscheidbar sein. Wesentlich schwieriger ist es zu sagen, welches von zwei kodierten Samples zu bevorzugen ist ("nicht-transparente Koder"). Methoden zum Coder-design:

- Feedforward Paradigm: das zu kodierende Signal wird analysiert und das mögliche Ausmass von Coding Noise so bestimmt.
- Feedback Paradigm: iterativ wird immer wieder bestimmt, welches von zwei (oder mehreren) codierten Signalen das bessere ist.

Loudness: Wird die Intensität eines Signals erhöht, steigt auch die Loudness, trotzdem sind die Terme nicht gleichbedeutend. Während Intensität mit einem Messinstrument gemessen werden kann, ist Loudness eine Wahrnehmungseinheit und kann nicht direkt gemessen werden sondern nur durch rating von Testpersonen bestimmt werden (daher wegen Subjektivität problematisch). Es gibt zwei Einheiten: Loudness level (in phon) und Loudness (in sone). Phon ist die Loudness eines 1 kHz Tones mit entsprechender Intensität in dB SPL (sound pressure level). Ein sone ist definiert als die Loudness eines 1 kHz Tones mit 40 dB SPL, ein Signal das als halb so laut empfunden wird hat 0.5 sone, etc. Zu beachten ist, dass die Messung durch Matching passiert wobei bei unterschiedlichen Frequenzen oder komplexen Signalen die Ergebnisse uneinheitlich werden können. Sone kann ebenfalls durch Matching bestimmt werden, wenn die Loudness Additivität ausgenutzt wird.

Pitch: Pitch verhält sich zu Frequenz ähnlich wie Intensität zu Loudness. Unter gewissen Bedingungen nimmt Loudness ab mit abnehmender Frequenz (bei konstanter Intensität) und Pitch nimmt ab bei steigender Intensität (bei konstanter Frequenz).

Hörschwelle: Schwellen werden nicht nur bestimmt durch Signal und Beobachter sondern auch durch die Methode der Messung. Die einfachste Definition von Hörschwelle ist die geringste Intensität die ein Hörer wahrnehmen kann. Das ist jedoch nicht adaquat, weil man die Wahrnehmung nicht direkt messen kann. D.h., es geht um die geringste Intensität, die einen Hörer zu einer Reaktion veranlasst. Es gibt zwar auf identische Signale nicht immer identische Responses, aber die Wahrscheinlichkeit eines positiven Responses nimmt mit der Signalintnesität zu. Man könnte hier die Schranke bei 50% Wahrscheinlichkeit fixieren. problematisch ist dabei, dass man keinerlei Kontrolle über die Kriterien der Testperson hat (z.B. ja wenn Signal sicher da ist, oder wenn es da sein könnte u.s.w.). Einen Ausweg bietet die Methode zwei Beobachtungsintervalle anzubieten in einem zufällig das Signal dargeboten wird. Der Beobachter muss entscheiden, in welchem das Signal war. Hier ist eine vernünftige Wahl der Schwelle bei 75% Wahrscheinlichkeit. Die Anzahl der Intervalle kann auch noch erhöht werden.

Unterscheidungsschwelle: oft bezeichnet als JND (just noticable difference), ist das Aussmass um das ein Attribut eines Signals sich verändern muss sodass ein Hörer die Änderung bemerkt (kann bezogen sein auf Frequenz, Intensität, Dauer, ...). Wieder gibt es die einfache Möglichkeit nur die Unterschiedlichkeit festzustellen, dann die Ausprägung der Unterschiedlichkeit (welches Signal hat höhere Frequenz) oder die Einteilung in N Intervalle und nur eines enthält ein unterschiedliches Signal.

Masking: hier kann zwischen gleichzeitigem und temporalem Masking unterschieden werden. Gleichzeitiges Masking ist ein Phänomen im Freuqenzbereich wo ein schwaches Signal durch ein gleichzeitiges stärkeres Signal unhörbar gemacht wird, wenn die beiden Signale ähnliche Frequenz haben. Die Maskierungs Schwelle ist diejenige Schwelle, unter der das schwächere Signal nicht wahrgenommen wird und hängt ab von der Frequenz, dem SPL, u.s.w. Das Phänomen des Masking ist ein wesentlicher Faktor beim Verstecken von Kodierungs Artefakten. Höhere Frequenzen werden leichter maskiert als niedere. Kodierungsrauschen ist nicht hörbar, solange SNR (m) grösser ist als SMR. Temporales Masking tritt auf wenn zwei Signale zeitlich nahe sind, wobei das stärkere das schwächere maskieren kann sogar wenn das Schwächere vorher kommt (wichtig um plötzlich auftretende grosse Quantisierungsfehler maskieren zu können) ! Premasking ist wesentlich kürzer als Postmasking.

Critical Bands: Das Hörsystem arbeitet wie eine Bandpass Filterbank. Der Frequenzraum ist in 25 kritische Frequenzbänder eingeteilt, die getrennt analysiert werden (energy detection) - diese Bänder sind 100 Hz breit unterhalb von 500 Hz und bis zu 5000 Hz für hochfrequente Signalteile. Zwei Signale die innerhalb solche Bänder liegen werden anders beurteilt als zwei Signale in verschiedenen Bändern. Die Eigenschaften im Bezug auf critical bands sind auch sehr wichtig im Hinblick auf das Design von Kodern, z.B. wegen des Zusammenhangs zwischen Bandbreite und Loudness und zwischen Bandbreite und Masking.

Einige Zusammenhänge: Loudness hängt stark von der Frequenz ab - am empfindlichsten ist die Region 2-3 kHz, Loudness wächst schneller mit der Intensität bei niederer Frequenz als bei höherer. Ist die Bandbreite eines Klanges innerhalb eines kritischen Bandes, ist die Loudness nicht von der Bandbreite abhängig. Wird die Bandbreite grösser, nimmt die Loudness mit zunehmender Bandbreite zu. In der Nähe der Hörschwelle kehrt sich diese Eigenschaft bei grosser Bandbreite um. Critical Duration: ist die Zeitdauer eines akustischen Signals, unterhalb der Loudness mit zunehmender Dauer ansteigt. Masking ist am stärksten ausgeprägt im Bereich von 400 Hz, aber nicht zu nahe bei 400. Bei geringer Intensität ist das Masking frequenzsymmetrisch, bei hoher Intensität gibt es starke Asymmetrie zugunsten der hohen Frequenzen. Ein Signal mir Bandbreite

innerhalb eines critical Bands erhöht das Masking bei sich erhöhender Bandbreite, ausserhalb eines critical Band gilt das nicht mehr.

5.2 Prinzip der low-bitrate Audiokodierung

Die Abhängigkeit der menschlichen Hörwahrnehmung von diversen Parametern wird ausgenutzt. Insbesondere werden Artefakte in Frequenzbänder geshiftet, wo sie nicht oder kaum wahrgenommen werden können. Dieses Shifting wird den Ergebnissen bezüglich SMR von Kurzzeit Spektralanalyse angepasst. Bei diesem Verfahren sind natürlich grundsätzlich Methoden im Fourierbereich von Vorteil, die hier eventuell keine getrennte Analyse und Kodierung durchgeführt werden muss.

5.3 Sprachkodierung

Die meisten Verfahren in diesem Bereich basieren auf linear predictive coding.

- ADPCM: die Differenz zwischen der adaptiv generierten prediction und dem Signal wird gespeichert. Der Prediktor ist rückwärtsadaptiv, d.h. die Koeffizienten werden nachadjustiert unter den Ergebnissen der Analyse der bereits kodierten Teilsignale. Ebenso ist die Quantisierung rückwärtsadaptiv. Die Variante *embedded* ADPCM ist für paketorientierte Netzwerke optimiert: das Netzwerk kann least significant bits bei Überlastung skippen, um packetloss zu vermeiden. GSM beutzt einen sog. Regular-pulse-excited long-term prediction linear predictive coder (RPE-LTP-LP Coder) bei dem das subgesampled Fehlersignal mit Kandidaten aus einem Codebook verglichen werden und die Adresse des besten übertragen wird.
- Analysis-by-Synthesis Coding: In einem Codebook gibt es eine Menge von Referenzsignalen die von einem Filter zusammengesetzt und skaliert werden. In einer Feedbackschleife werden alle möglichen Kandidaten getestet, die Adresse des ähnlichsten Signals wird übertragen. Der Filter und der Skalierungsfaktor weden während der Kodierung in Abhängigkeit von einer Fehleranalyse nachadjustiert. Der sog. CELP Coder benutzt zwei Codebooks: ein adaptives Codebook dass die am meisten verwendeten Signale beinhaltet und ein stochastisches Fehlercodebook, das dem eher zufällig strukturierten Restsignal angepasst ist.
- Füer Wideband Sprachkodierung (16 kHz Sampling statt 8) basiert auf dem Aufsplitten des Signals in zwei kritisch gesampled Subbands wobei das low Subband weniger quantisiert wird (6-bit statt 2-bit) und einem Narrowband Signal ähnelt. Die beiden Subband Sequenzen werden mit einem ADPCM Coder kodiert, Adaptation basiert auf einer Anpassung der 4 most significant bits (embedded coding).

5.4 Wideband Audio Kodierung

Wideband Audio Kodierung beruht in allen Varianten auf einer Form von Frequenzzerlegung die anschliessend quantisiert wird. Zwei Grundtypen können unterschieden werden, nämlich *adaptive transform coding* (ATC) und *subband coding* (SBC). Beide Verfahren benutzen eine Transformation die das Signal in Spektalkomponenten zerlegt. Haben diese Spektalkomponenten eine geringe Frequenzauflösung, spricht man von

subbands, andernfalls von Tranformationskoeffizienten. Beide Verfahren ermöglichen es auf natürliche Art auf Eigenschaften des Hörens einzugehen, da die im Frequenzbereich operieren. Ein wichtiger Punkt bei diesen Verfahren ist das Auftreten von sog. Pre-echoes (ähnlich zu Kopiereffekten auf Analogbänder). Folgt auf eine ruhige Periode heftiger Klang im selben zu verarbeitenden Block, so kommt es zu grossen Quantisierungsfehlern in diesem Bereich. Bei beiden Algorithmenklassen werden diese Fehler über einen grösseren Bereich gestreut, was besonders im low-bitrate Bereich zu hörbaren Fehlern führt. Solche Artefakte können maskiert werden, wenn die Zeitspanne ihres Auftretens kurz ist. Daher können sie reduziert werden wenn man kleine Blöcke des Signals verarbeitet. Andererseits ist die Sideinformation bei kleinen Blöcken sehr gross, sodass man die Technik des Window-switching verwendet: kleine Blöcke werden verwendet um das Auftreten von pre-echos zu kontrollieren, ansonsten werden grössere verwendet.

- **Subband Coding**: das Signal wird durch eine Filterbank bestehend aus M Bandpassfiltern geschickt, der Output wird downgesampled. Die Zusammensetzung ergibt wieder das Originalsignal wenn keine Quantisierung durchgeführt wird. Der klassische Vertreter ist MPEG-1 Audio Layer I und II. Durch eine FFT werden die Signal-to-Mask ratios bestimmt die dann im Quantisierungsprozess der Subbands umgesetzt werden. Wie im visuellen Teil von MPEG ist auch hier nur der Decoder standardisiert, sodass immer wieder verbesserte psychoakustische Modelle und Bit-allozierungsmethoden in den Encodern eingesetzt werden können. MPEG-1 hat die Modi Mono, Stereo, Dual (mit zwei separaten Kanälen für bilinguale Programme), und joint Stereo. Im letzten Modus werden Abhängigkeiten zwischen den einzelnen Kanälen ausgenutzt und bei hohen Freuqenzen wird nur die Summe L+R übertragen/gespeichert. Layer I benutzt 32 Subbands und fixe Blocklängen (8ms bei 48 kHz Sampling), die SMR wird mit 512 Punkt FFT ermittelt. Wird z.B. für Philips DCC verwendet. Layer II ist sehr ähnlich, benutzt 1024 Punkt FFT, Redundanzen in der Sideinformation bei benachbarten Blöcken wird ausgenutzt und eine feinere Quantisierung wird durchgeführt. Wird z.B. für ADR (Astra Digital Radio) verwendet.

- **Transform Coding**: für die Transformation wird hier meist FFT oder DCT verwendet die auf einen Datenblock angewendet werden. Diese Koeffizienten werden dann (entsprechen einem psychoakustischen Modell) quantisiert. Durch die Blockbildung kommt es zu Artefakten, die durch ein Überlappen der Datenblöcke kontrolliert wird (*modified DCT - MDCT*, die Technik heisst *time domain aliasing cancellation*. AC-2 Coding (Dolby) verwendet eine 512 Punkt MDCT und MDST (abwechselnd), die alle 256 Punkte durchgeführt wird. Benachbarte Koeffizienten werden dann so gruppiert, dass sie den critical Bands entsprechen. Ausser dieser Gruppierung verwendet der Coder kein psychoakustisches Modell. Die Bit-allocation wird direkt aus den Koeffizeinten ermittelt. PAC Coding (AT& T) verwendet L/R und M/S (mean/sum) Kodierung in einer signalabhängigen Weise.

- **Hybrid Coding**: Diese Kombinationen bieten den Vorteil, dass bei verschiedenen Frequenzen verschiedene Frequenzauflösungen verwendet werden können. nach einer Subband Zerlegung werden die Subbands mit einer MDCT weiter aufgespalten um hohe Frequenzauflösung zu erreichen. Der ATRAC Coder (Sony) verwendet drei Subbands und eine anschliessende MDCT mit 50% Überlappung. Dynamisches Window switching zwischen 512 Samples und 128 Samples (64 bei hohen Frequenzen) wird durchgeführt. Dieser Koder mit 44.1 kHz Samplingrate und 256 kb/s stereo Bitrate wurde für die Minidisc entwickelt (die ca. 20% der Speicherkapazität einer CD hat). DER Algorithmus in dieser Klasse ist momentan MPEG-1 Layer III (auch bekannt als MP-3). 32 Subbands werden durch eine 6 bzw. 18 Punkt MDCT mit 50% Überlappung weiterverarbeitet. Die 6 Punkt MDCT wird durchgeführt, falls Pre-echoes zu erwarten sind. Als einziger MPEG-1 Layer wird hier variable bit-rate coding und

non-uniform Quantisierung eingesetzt. Ausserdem wird ein iteratives Verfahren zur Optimierung von Quantisierung verwendet (iterative analysis-by-synthesis). Eutelsat SaRa verwendet dieses System.

5.5 Multichannel Audio Coding

Ein logischer Schritt in der Weiterentwicklung von Audio ist Multichannel Audio. Solche Systeme können nicht nur die üblichen Lautsprechnerkombinationen unterstützen (wie z.B. das 5.1 System), sondern auch eigene Kanäle für Seh- und Hörbehinderte bereitstellen. Die verschiedenen Kanäle werden in den effizienteren Algorithmen nicht unabhängig kodiert, es werden sogar Stereo irrelevante Teile des Signals identifiziert und als Mono kodiert. Der wichtigste Algorithmus in dieser Klasse ist MPEG-2. Es gibt hier zwei Algorithmen: einer davon ist forwärts kopatibel (d.h. er kann MPEG-1 Mono und Stereosignale dekodieren) und rückwärtskompatibel (d.h. ein MPEG-1 stereo Decoder kann einen MPEG-2 bitstream korrekt interpretieren), der andere weder noch.

- **Rückwärtskompatibles MPEG-2 Coding**: die Kompatibilität wird durch Matrizen erreicht, die ein Mischen der 5 Kanäle in 2 definieren (z.B. L0 = L + 0.7 C + 0.7 LS). Zwei der Signale (L0 und R0) werden in MPEG-1 Format kodiert. Die restlichen Kanäle werden so belegt, dass ein vollständiges 5 Kanal Signal wiederhergestellt werden kann. Diese werden in einem speziellen Feld des MPEG-1 Stroms transportiert, der vom MPEG-1 Decoder ignoriert wird.
- **MPEG-2 Advanced Audio Coding (AAC)**: Ist ein fortgeschrittener ATC mit einer 1024 Punkt MDCT, M/S coding und einem rückwärts adaptiven Prediktor im Transformationsbereich. Iterative Methode wird für Quantisierung und Bit-Allocation verwendet. Es gibt 3 Profiles: Main (mit dynamischen, adaptiven window switching), Low-complexity (ohne Prediction) und Sampling-rate-scalable (mit hybrider filterbank). Bis zu 46 Kanäle werden unterstützt, Standard 1997 finalisiert.
- **Dolby AC-3 Coding**: ist ein multichannel Coder mit der AC-2 Filterbank. Maskierung wird eingesetzt, wenn der Bitbedarf zu hoch wird, hierbei werden Koeffizienten ähnlicher Frequenz von verschiedenen Kanälen zu einem kombiniert. Wird in US HDTV Audio und bei DVD NTSC verwendet.

5.6 MPEG-4 Audio

MPEG-4 stell Tools für die Kodierung von Natural Sound (Sprache und Musik) als auch für die Generierung von synthetischen Sound aus parametrischen Modellen zur Verfügung. Die Representierung von synthetischen Sound kann von Text oder Instrument Beschreibungen stammen.

In MPEG-4 sind bereits existierende Standards zur Audiokodierung inkludiert, in diesen Fällen stellt MPEG-4 nur die Bitstream syntax und Dekodierungsverfahren als Tools zur Verfügung. An die jeweiligen Anwendungen und Bitraten angepasst, wird so ein einheitliches Framework für verschiedene Koder geschaffen. Für Sprachkodierung gibt es einen CELP Koder, für low-bitrate Sprachkodierung den sog. Harmonic Vector eXitation Coder (HVXC - hier wird nur die Frequenzcharakteristik eines Predictionfehlers kodiert), für generelle Audiokodierung wird MPEG-2 AAC und TwinVQ (die Kodierung des Spektrums erfolgt durch einen VQ) verwendet. Es kann bespielsweise ein base layer durch CELP erzeugt werden, der enhancement layer ist AAC kodiert.

Besonders interessant (und gänzlich analog zum visuellen Teil) ist die Standardisierung im Bereich synthetisierter Sound.

- **Text to Speech (TTS)**: Text oder ein Text mit bestimmten zusätzlichen Parametern (z.B. Phonem Dauer, Pitch Gestalt) kann verwendet werden um synthetische Sprache zu generieren. Es können Parameter erzeugt werden, die eine Synchronisation mit künstlichen animierten Gesichtern erlaubt. MPEG-4 standardisiert das Interface für die Operation eines TTS Systems (das TTSI), nicht aber das TTS System selbst !

- **Structured Audio Tools**: diese Tools dekodieren Input daten und produzieren Klänge. Die Dekodierung wird gesteuert von einer eigenen Synthesesprache genannt SAOL (Structured Audio Orchestra Language) die in MPEG-4 standardisiert ist. Diese Sprache wird benutzt um ein *Orchester* aus *Instrumenten* zu definieren (die im Bitstream geladen werden und nicht am terminal vorhanden sind). Ein Instrument ist eine kleine Menge von Signalverarbeitungsroutinen, die spezielle Klänge (ev. von Instrumenten) emulieren. Kontrolle über die Klangsynthese wird erreicht durch laden von Scripts/Scores, die verschiedene Instrumente aufrufen und zeitlich miteinander verknüpfen. Diese Beschreibung wird in der Sprache SASL (Structured Audio Score Language) geladen und kann auch benutzt werden, neue Klänge zu kreieren und existierende Klänge zu verändern. Für Synthese Prozesse die eine weniger starke und feine Kontrolle benötigen kann auch das etablierte MIDI Protokoll verendet werden (wurde im Synthisizer Bereich entwickelt). Auf diese Art können simple Audio Effekte wie Schritte oder Türenschlagen, aber auch wesentlich komplexere Audioevents wie Musik auf konventionellen Instrumenten oder futuristische Musik erzeugt werden. Für Terminals mit weniger Funktionalität oder weniger anspruchsvollen Anwendungen können auch Soundtabellen (wavetable bank format) und einfache Verarbeitungsmethoden (Filterung etc.) verwendet werden.