

Сжатие Аудиоданных

Общие принципы и устройство MP3

Дмитрий Ватолин

*Московский Государственный Университет
CS MSU Graphics&Media Lab*

Благодарности

- ◆ Автор выражает глубокую признательность Алексею Лукину и Александру Жиркову (Graphics&Media Lab) за предоставленные слайды лекций

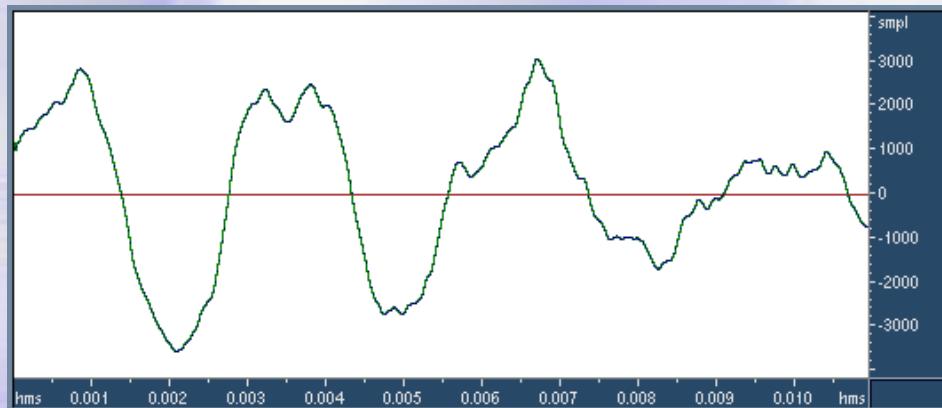
Сжатие аудио

- ◆ Общие понятия и принципы сжатия с потерями, психоакустика.
- ◆ Устройство алгоритма MP3
- ◆ Гибридные методы сжатия
- ◆ Речевые кодеки

Сигналы

- ◆ Сигнал – скалярная функция от одного или нескольких аргументов.

примеры сигналов:



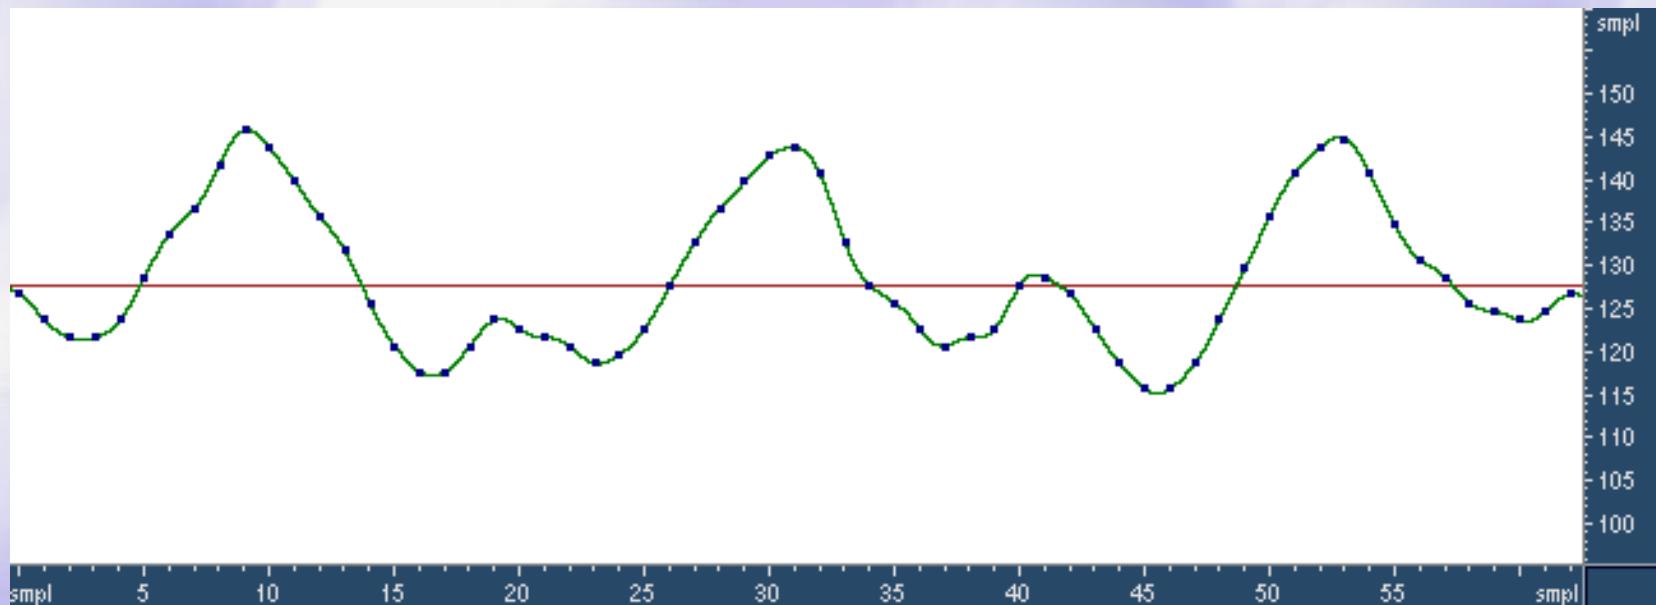
$s(t)$ – звук



$f(x,y)$ – изображение

Оцифровка сигналов

1. Дискретизация по времени
2. Квантование по амплитуде



Оцифровка сигналов

- ◆ При каких условиях по цифровому сигналу можно точно восстановить исходный аналоговый?
- ◆ Предположим, что значения амплитуд в цифровом сигнале представлены точно.
- ◆ Введем понятие спектра аналогового сигнала:

(разложение на синусоиды с различными частотами)

$$x(t) = \int_{-\infty}^{+\infty} X(\nu) \cdot e^{2\pi i \nu t} d\nu \quad X(\nu) = \int_{-\infty}^{+\infty} x(t) \cdot e^{-2\pi i \nu t} dt$$

$x(t)$ – исходный сигнал

$X(\nu)$ – спектр, т.е. коэффициенты при гармониках с частотой ν

Теорема Котельникова

- ◆ Пусть:
 1. спектр сигнала $x(t)$ не содержит частот выше F , т.е. $X(v)=0$ за пределами отрезка $[-F, F]$
 2. дискретизация сигнала $x(t)$ производится с частотой F_s , т.е. в моменты времени nT , здесь $T = F_s^{-1}$
 3. $F_s \geq 2F$
- ◆ Тогда исходный аналоговый сигнал $x(t)$ можно точно восстановить из его цифровых отсчетов $x(nT)$, пользуясь интерполяционной формулой

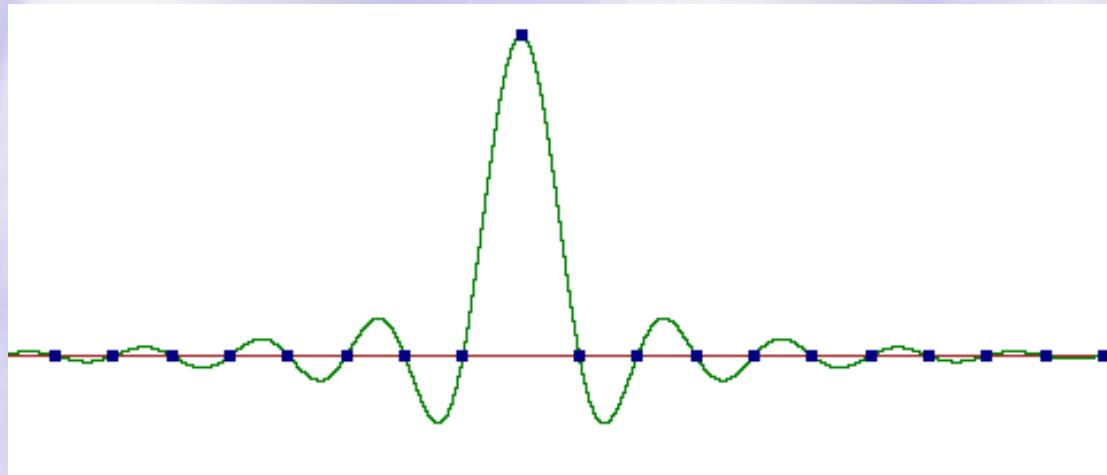
$$x(t) = \sum_{n=-\infty}^{+\infty} x(nT) \cdot Sinc(t - nT)$$

$$Sinc(t) = \frac{\sin \pi F_s t}{\pi F_s t}$$

Теорема Котельникова

- ◆ Как выглядят интерполирующие функции?

$$x(t) = \sum_{n=-\infty}^{\infty} x(nT) \cdot Sinc(t - nT) \quad Sinc(t) = \frac{\sin \pi F_s t}{\pi F_s t}$$



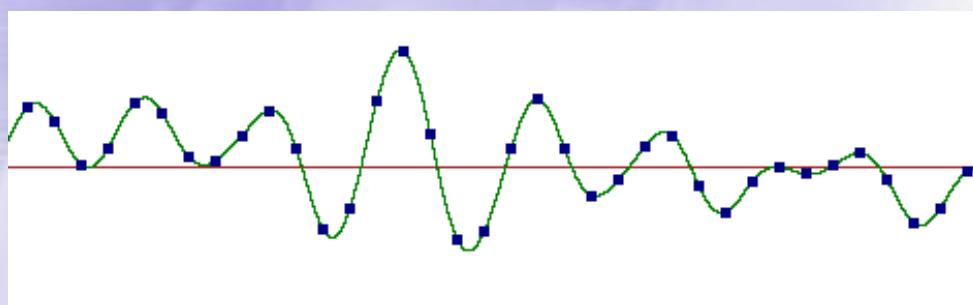
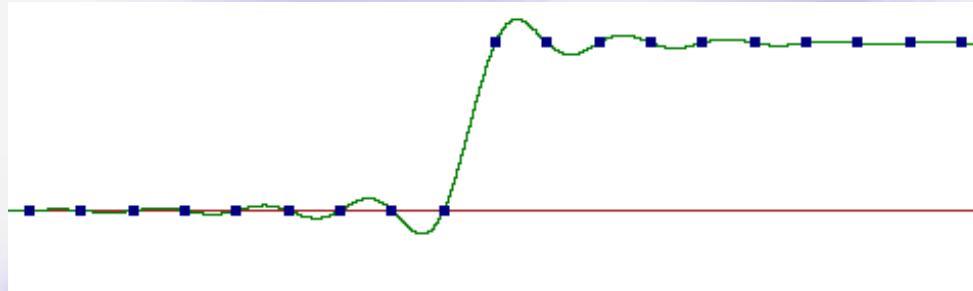
Бесконечно затухающие колебания

Теорема Котельникова

- ◆ Реконструкция аналоговых сигналов:

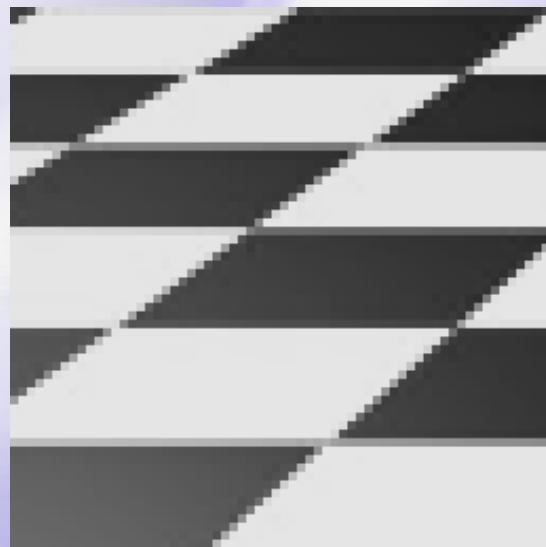
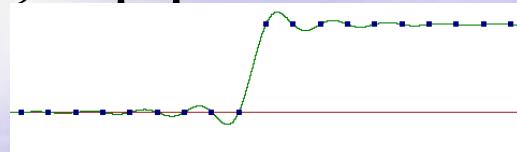
$$x(t) = \sum_{n=-\infty}^{+\infty} x(nT) \cdot Sinc(t - nT)$$

sinc-интерполяция



Теорема Котельникова

- ◆ Применимость sinc-интерполяции для изображений, эффект Гиббса



Цифровые отсчеты



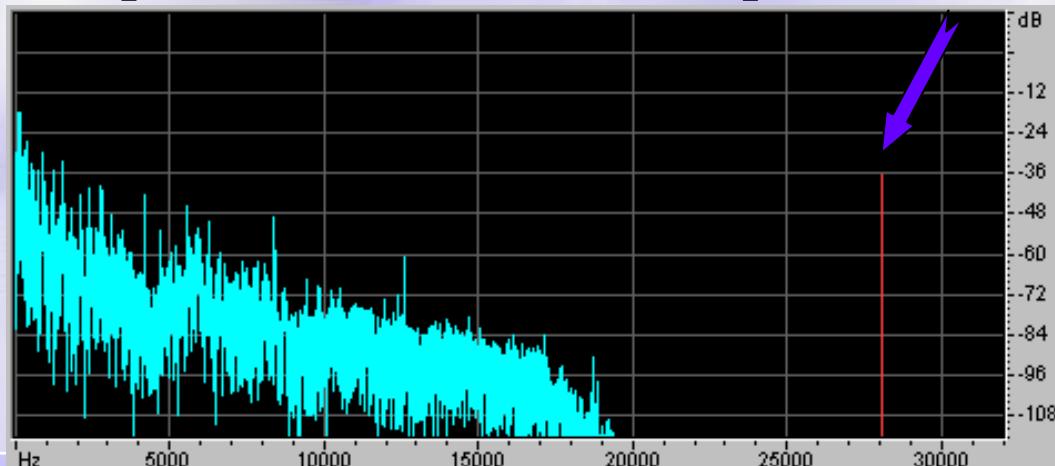
sinc-интерполяция



другая интерполяция

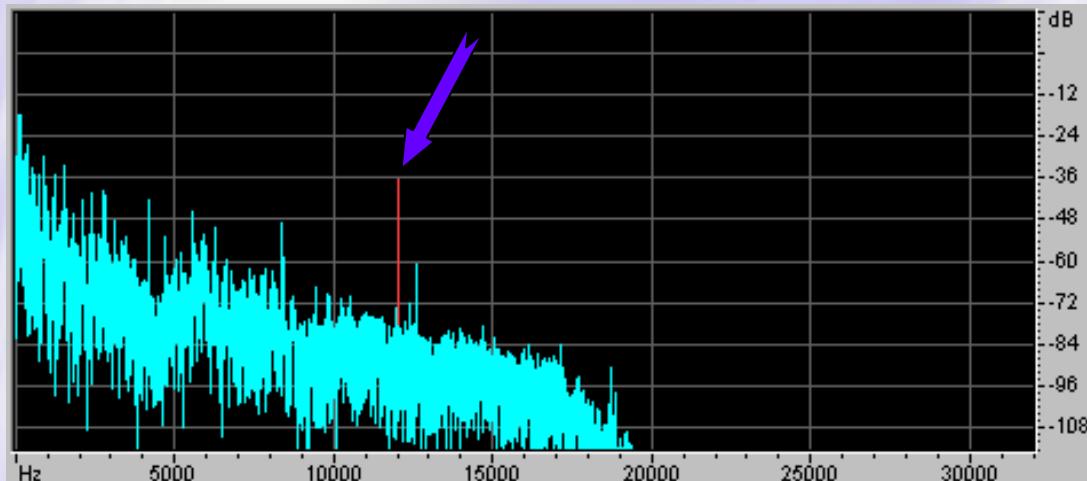
Алиасинг

- ◆ Что будет, если условия теоремы Котельникова не выполнены?
- ◆ Пусть звук не содержит частот выше 20 кГц. Тогда, по теореме Котельникова, можно выбрать частоту дискретизации 40 кГц.
- ◆ Пусть в звуке появилась помеха с частотой 28 кГц. Условия теоремы Котельникова перестали выполнятся.



Алиасинг

- ◆ Проведем дискретизацию с частотой 40 кГц, а затем – восстановим аналоговый сигнал sinc-интерполяцией.



- ◆ Помеха отразилась от половины частоты дискретизации в нижнюю часть спектра и наложилась на звук. Помеха переместилась в слышимый диапазон. Алиасинг.

Алиасинг

- ◆ Как избежать алиасинга?
- ◆ Применить перед оцифровкой анти-алиасинговый фильтр:
 - Он подавит все помехи выше половины частоты дискретизации (выше 20 кГц) и пропустит весь сигнал ниже 20 кГц.
 - После этого условия теоремы Котельникова будут выполняться и алиасинга не возникнет.
 - Следовательно, по цифровому сигналу можно будет восстановить исходный аналоговый сигнал.

Преобразование Фурье

- ◆ Зачем раскладывать сигналы на синусоиды?
 - Анализ линейных систем
 - Слух и синусоиды
 - Хорошо разработана теория и практика
- ◆ Дискретное преобразование Фурье (ДПФ)
- ◆ Ряд Фурье
- ◆ Частоты и амплитуды

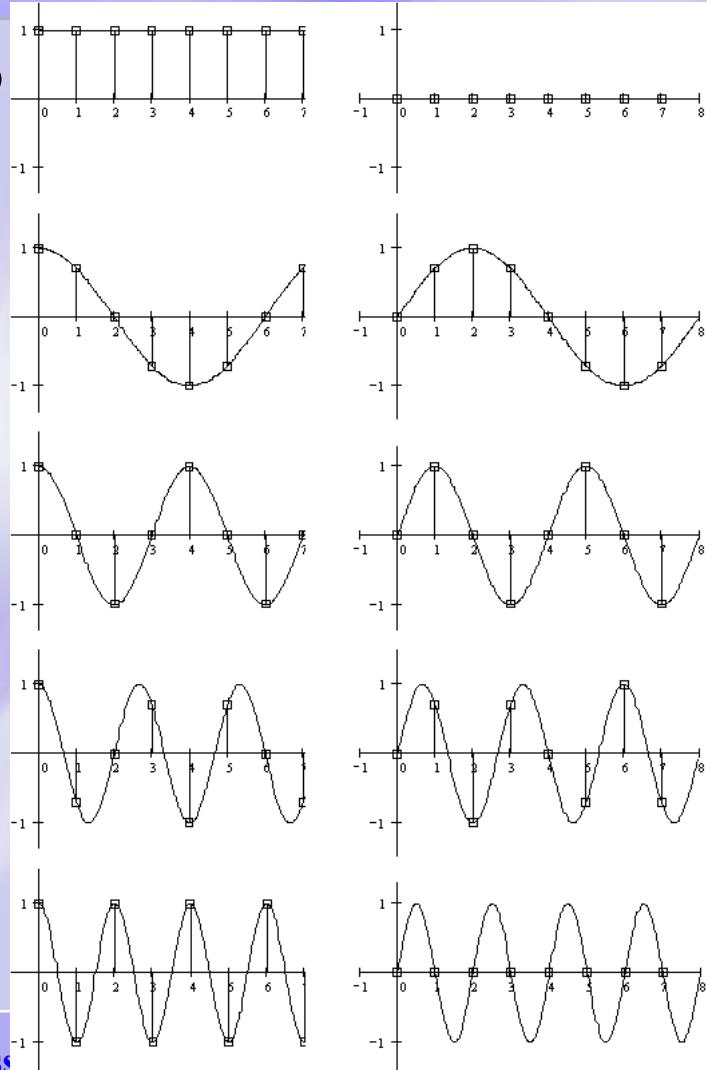
$$x[n] = \sum_{k=0}^{N/2} C_k \cos \frac{2\pi k(n + \varphi_k)}{N}$$

$$x[n] = \sum_{k=0}^{N/2} A_k \cos \frac{2\pi kn}{N} + \sum_{k=0}^{N/2} B_k \sin \frac{2\pi kn}{N}$$

- ◆ Прямое и обратное преобразования Фурье

Преобразование Фурье

- ◆ Базисные функции дискретного преобразования Фурье для сигнала длины $N = 8$.
- ◆ Имеем $N/2 + 1 = 5$ различных базисных частот.
- ◆ Имеем $N+2$ базисные функции, 2 из которых тождественно равны нулю.
- ◆ Количество информации не изменяется: N чисел



Преобразование Фурье

- ◆ Базисные функции образуют N-мерный ортогональный базис в пространстве N-мерных векторов исходных сигналов.
- ◆ Следовательно, разложение обратимо, т.е. по коэффициентам разложения (A_k, B_k) можно точно восстановить исходный дискретный сигнал.
- ◆ Обратное преобразование Фурье – вычисление суммы конечного ряда Фурье (сложить N штук N-точечных синусоид со своими коэффициентами).

Преобразование Фурье

- ◆ Прямое преобразование Фурье – вычисление скалярных произведений сигнала на базисные функции:

$$A_k = \frac{2}{N} \sum_{i=0}^{N-1} x[i] \cos \frac{2\pi k i}{N} \quad k = 1, \dots, \frac{N}{2} - 1$$

$$A_k = \frac{1}{N} \sum_{i=0}^{N-1} x[i] \cos \frac{2\pi k i}{N} \quad k = 0, \frac{N}{2}$$

$$B_k = \frac{2}{N} \sum_{i=0}^{N-1} x[i] \sin \frac{2\pi k i}{N} \quad k = 0, \dots, \frac{N}{2}$$

- ◆ Для вычисления всех коэффициентов по этому алгоритму требуется примерно N^2 умножений: очень много при больших длинах сигнала N .

Преобразование Фурье

- ◆ Быстрое преобразование Фурье (БПФ, FFT) – ускоренный алгоритм вычисления ДПФ
 - Основан на периодичности базисных функций (много одинаковых множителей)
 - Математически точен (ошибки округления даже меньше, т.к. меньше число операций)
 - Число умножений порядка $N \cdot \log_2 N$, намного меньше, чем N^2
 - Ограничение: большинство реализаций FFT принимают только массивы длиной $N = 2^m$

Существует и обратное БПФ (IFFT) – такой же быстрый алгоритм вычисления обратного ДПФ.

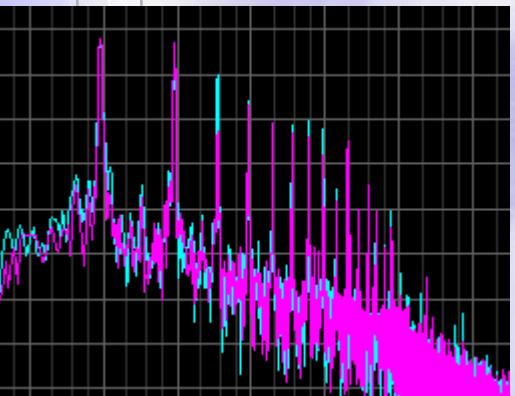
Спектральный анализ

- ◆ Отображение спектра звука: спектrogramма
 - Спектrogramма – график зависимости амплитуды от частоты
 - Низкие частоты – слева, высокие – справа
 - Часто применяется логарифмический масштаб частот и амплитуд: “log-log-спектrogramма”
 - Временное и частотное разрешение спектrogramмы

Децибелы:

$$D = 20 \lg \frac{A_1}{A_0}$$

A_1 – амплитуда измеряемого сигнала,
 A_0 – амплитуда сигнала, принятого за начало отсчета (0 дБ)

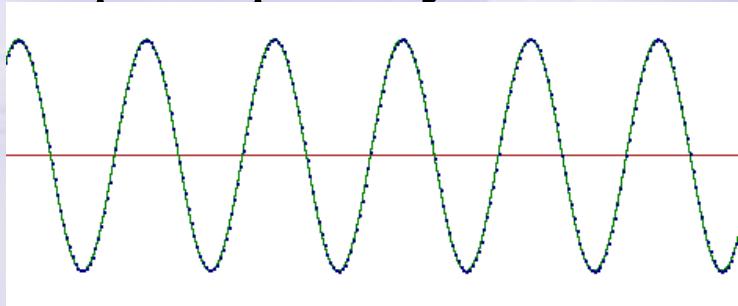


Разница на 6 дБ – разница по амплитуде в 2 раза, разница на 12 дБ – разница по амплитуде в 4 раза.

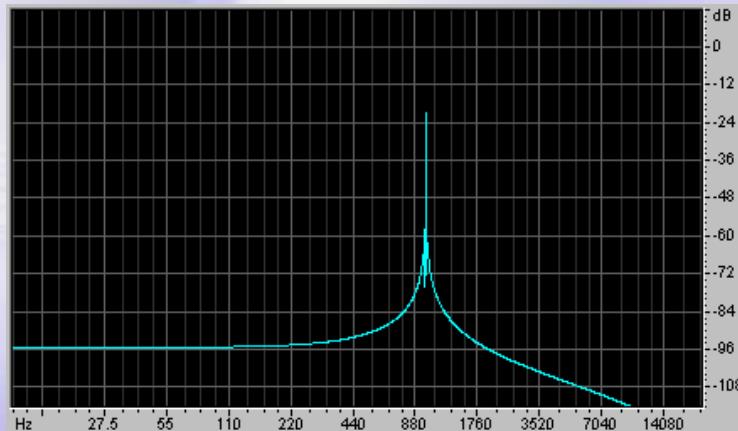
Часто за 0 дБ принимается либо самый тихий слышимый звук, либо самый громкий звук, который может воспроизвести аудио-устройство.

Спектральный анализ

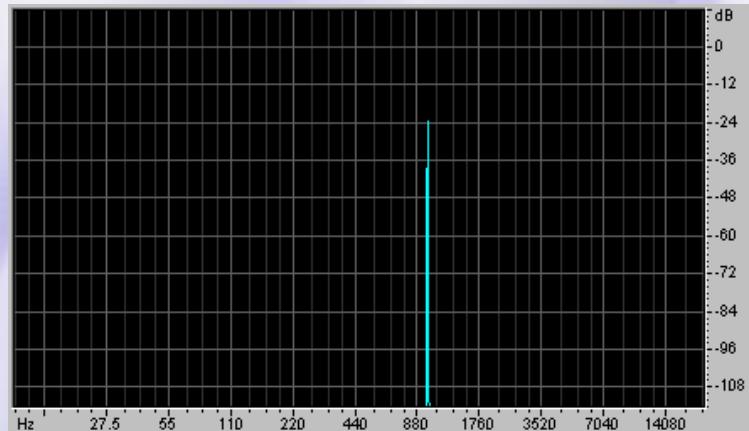
◆ Примеры звуков и их спектров



Исходная волна – синусоида



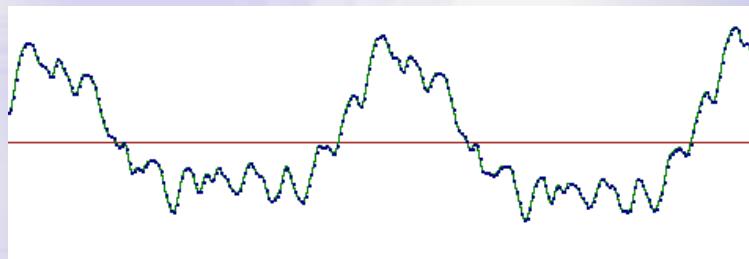
Спектр с одним весовым окном



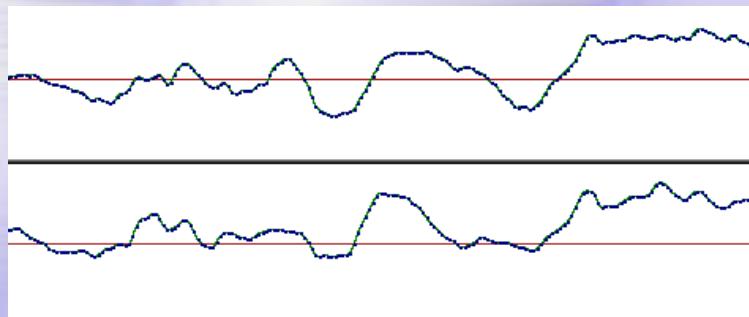
Спектр с другим весовым окном

Спектральный анализ

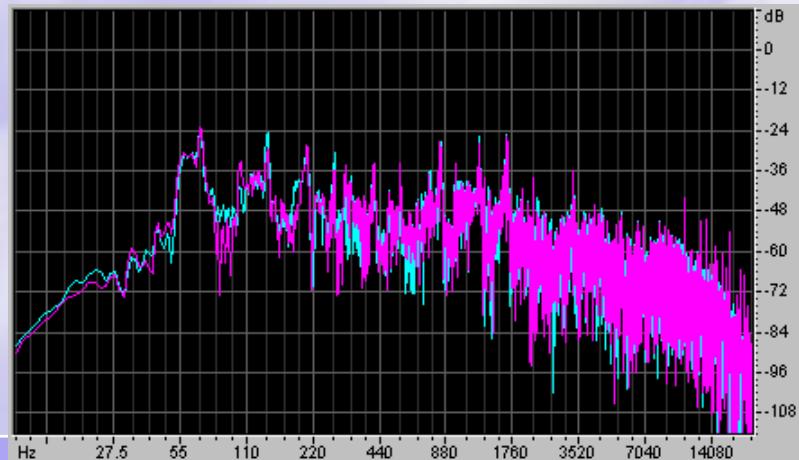
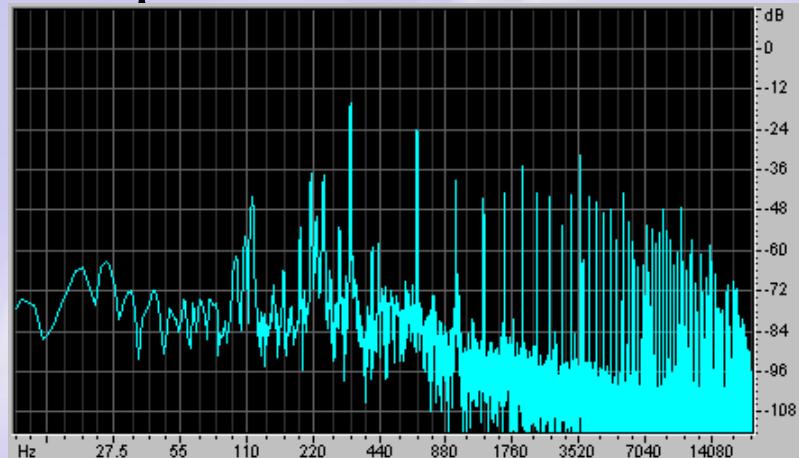
◆ Примеры звуков и их спектров



Нота на гитаре

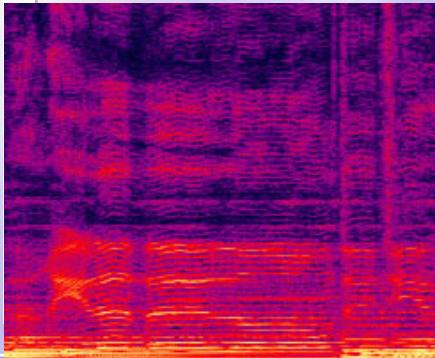


Песня (стерео запись)



Спектральный анализ

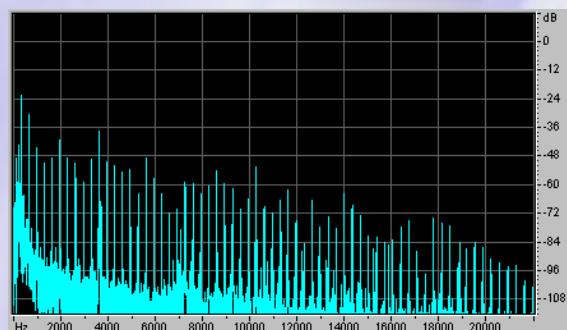
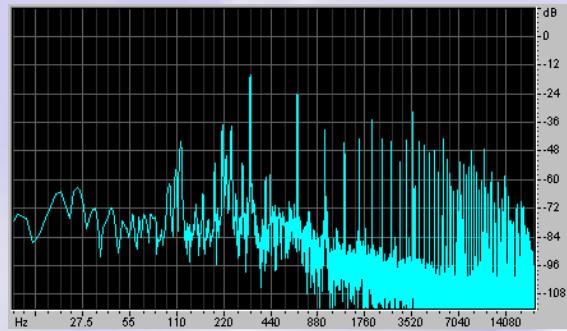
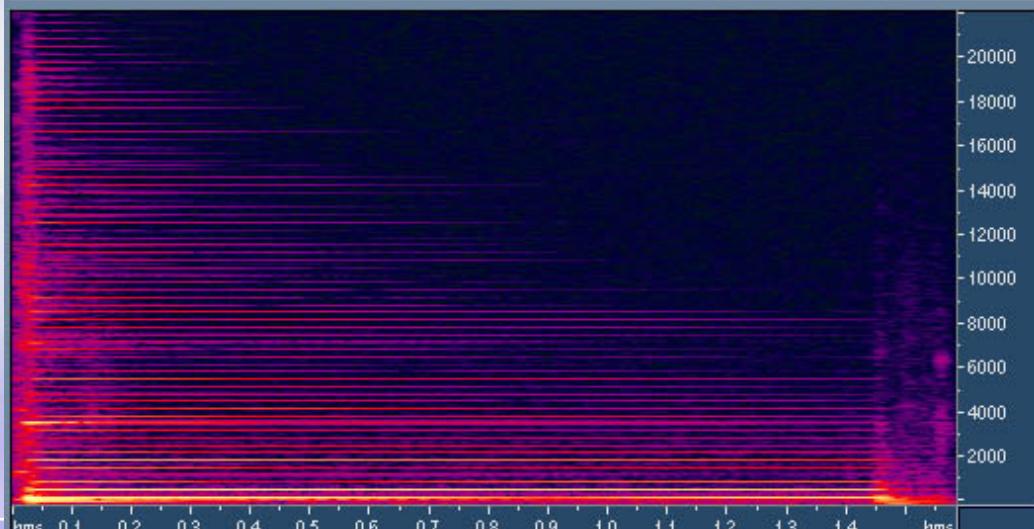
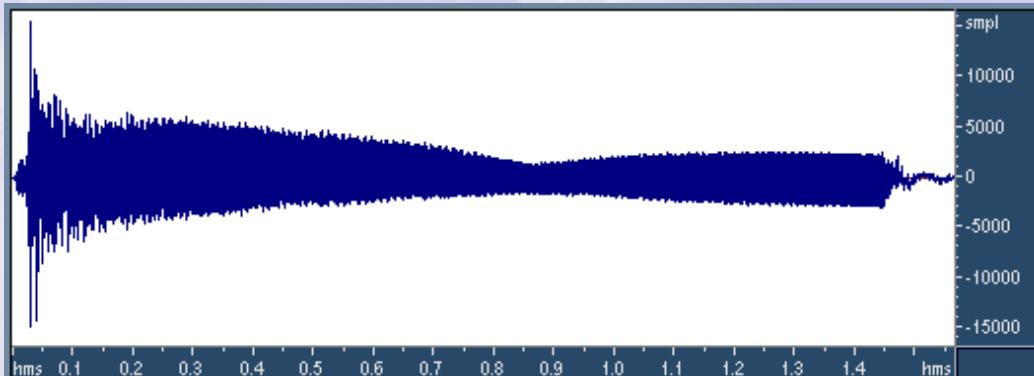
- ◆ Отображение спектра звука: сонограмма
 - Сонограмма – график зависимости амплитуды от частоты и от времени
 - Низкие частоты – снизу, высокие – сверху
 - Время идет справа налево
 - Амплитуда – яркость или цвет
 - Частотное и временное разрешение
 - Short Time Fourier Transform (STFT)



Показывает изменение спектра во времени

Спектральный анализ

◆ Примеры звуков и их сонограмм



Нота на гитаре

Форма исходного сигнала

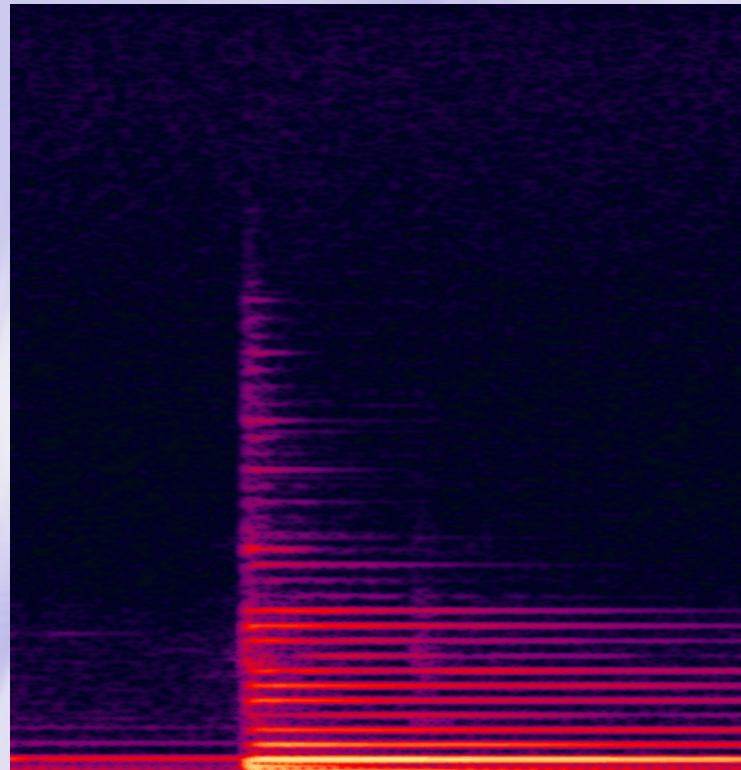
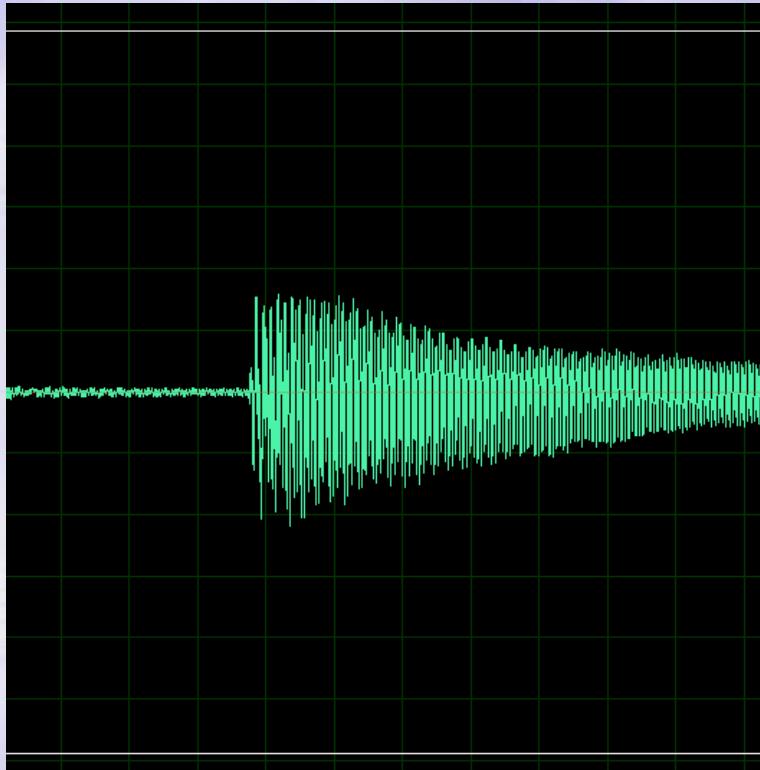
Аудио-сигнал представляют в виде:

- Набора нот и характеристик инструментов (MIDI)
- Последовательности амплитуд сэмплов (PCM)

При сэмплировании базовые частоты дискретизации от 192 КГц до 6 КГц, точность представления сэмплов – 8, 16, 24, 32 бита.

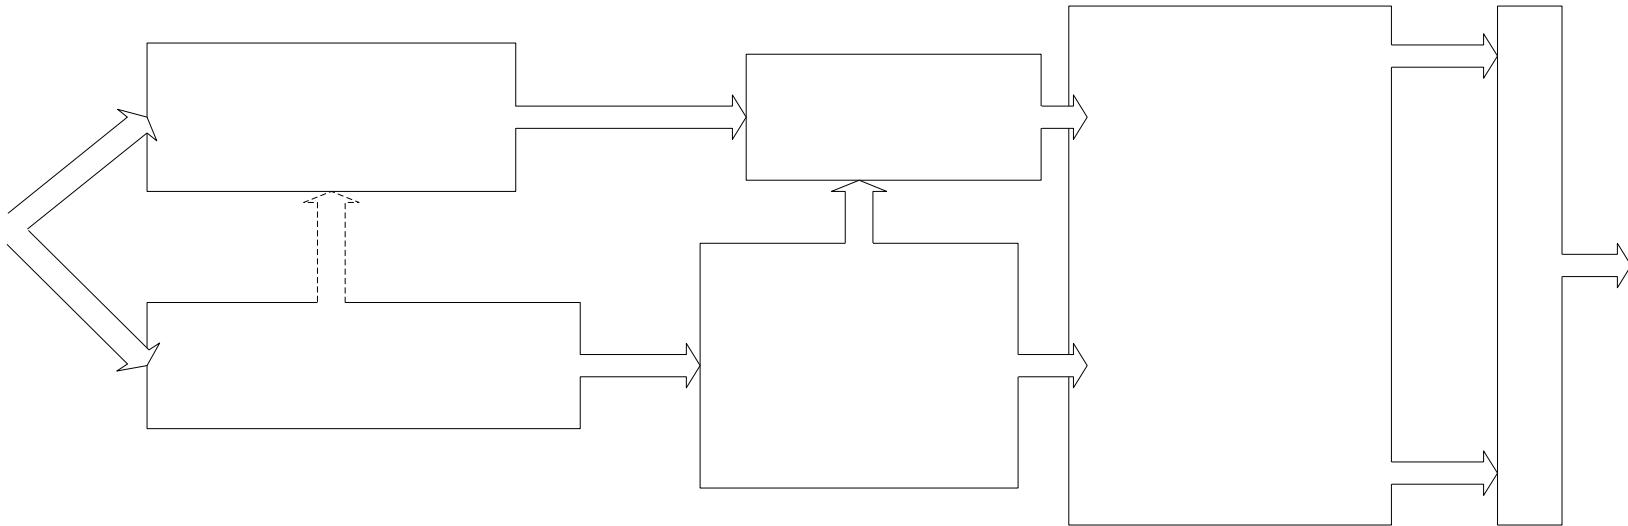
Качество Audio CD-ROM – 44 КГц, 16 бит.

Пример – гитарная струна



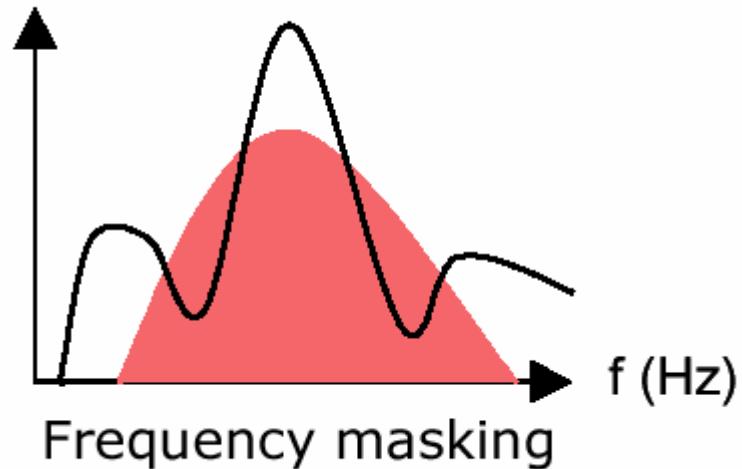
Вид сигнала в виде графика значений амплитуды
и в спектральном виде (тот же кусок)

Обобщенная схема аудио-кодека



Подавляющее количество кодеков строится по одной схеме – некая модель (психоакустика), управляет частотно-временным преобразованием (MDCT, Wavelet), а Rate control – квантованием и энтропийным кодером.

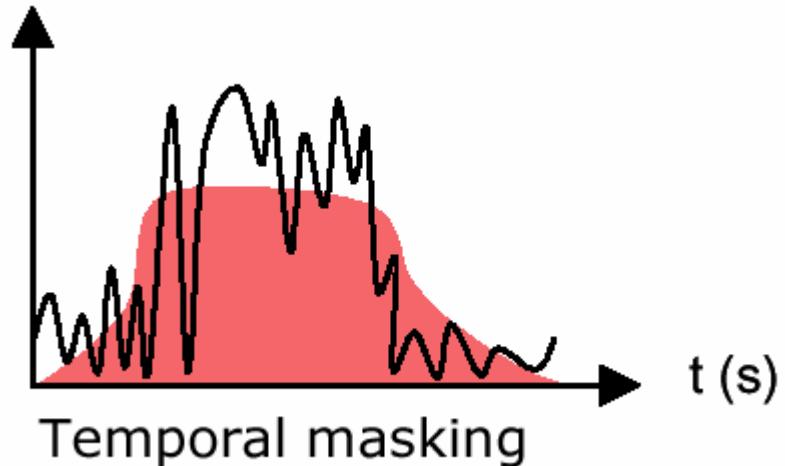
Частотная маскировка



Снижение чувствительности к амплитуде близких по частоте волн в окрестности волны большой амплитуды.

Ухо среднего человека различает порядка 20 частотных полос. При этом в каждой полосе оно чувствительно к тону (у людей со слухом), но реагирует на общую мощность сигнала.

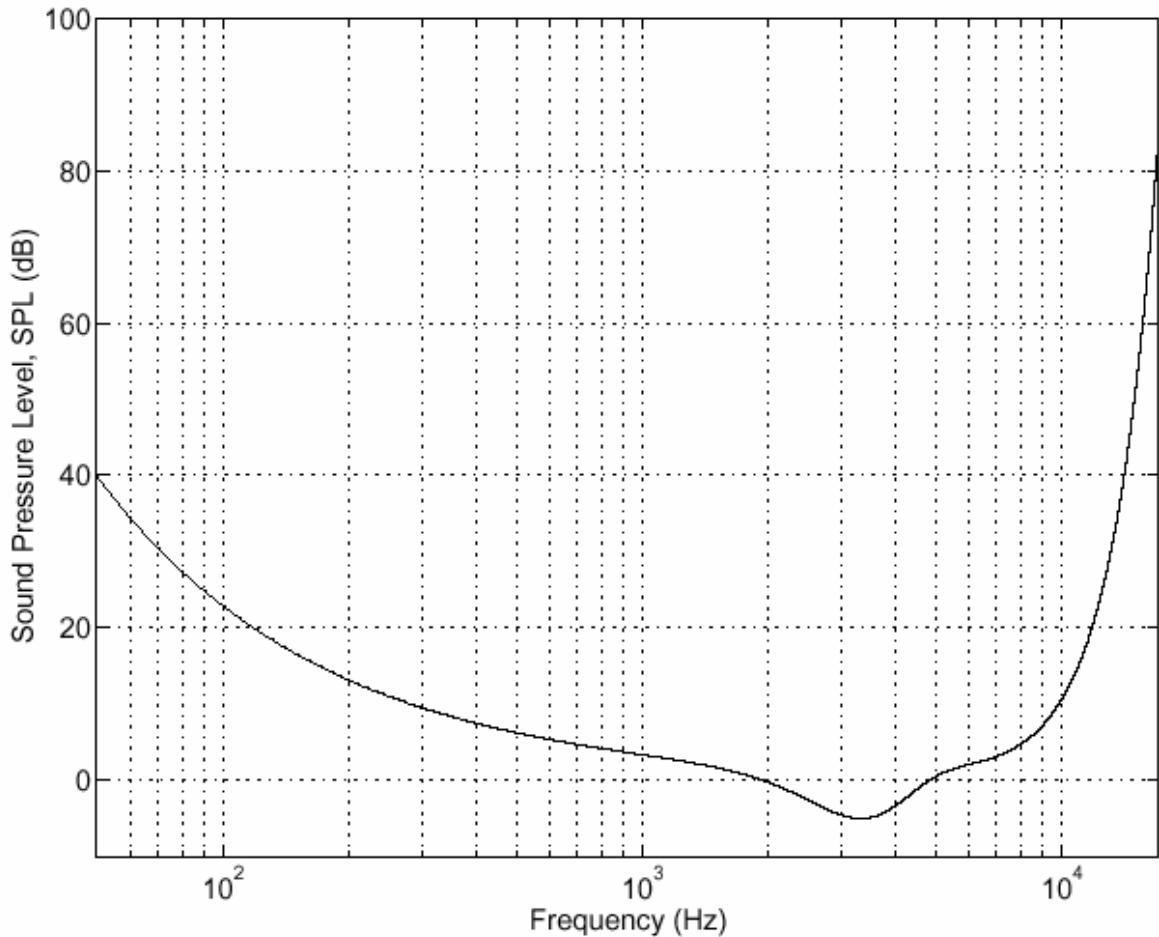
Маскировка по времени



Снижение чувствительности к амплитуде близких по времени волн в после волны большой амплитуды.

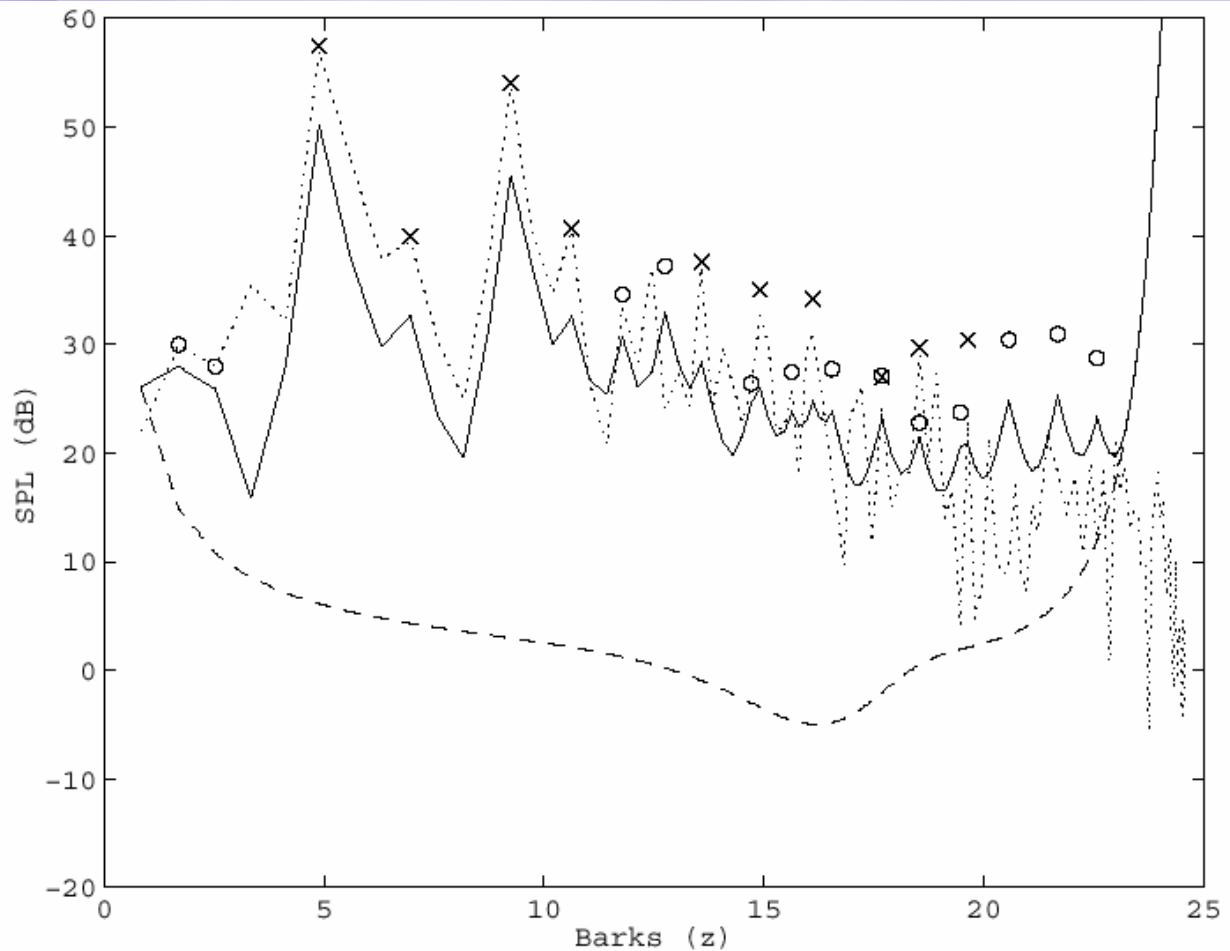
Ухо человека теряет чувствительность («оглушается») волнами большой амплитуды.

Абсолютный порог слышимости



Наивысшая
чувствитель-
ность уха –
на средних
слышимых
частотах
(район 2-3
КГц)

Порог слышимости (психоакустика)



Психоакустические пороги определяют по маскировке тоном и шумом, абсолютному порогу слышимости и областям чувствительности

Устройство уха

- ◆ Базилярная мембрана
- ◆ Различная жесткость мембранны в разных местах → различные резонансные частоты
- ◆ К различным участкам мембранны подходят различные группы нервов
- ◆ Разложение на частоты

- ◆ Описание процессов слухового восприятия в терминах частотно-временной модели

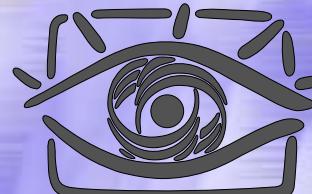
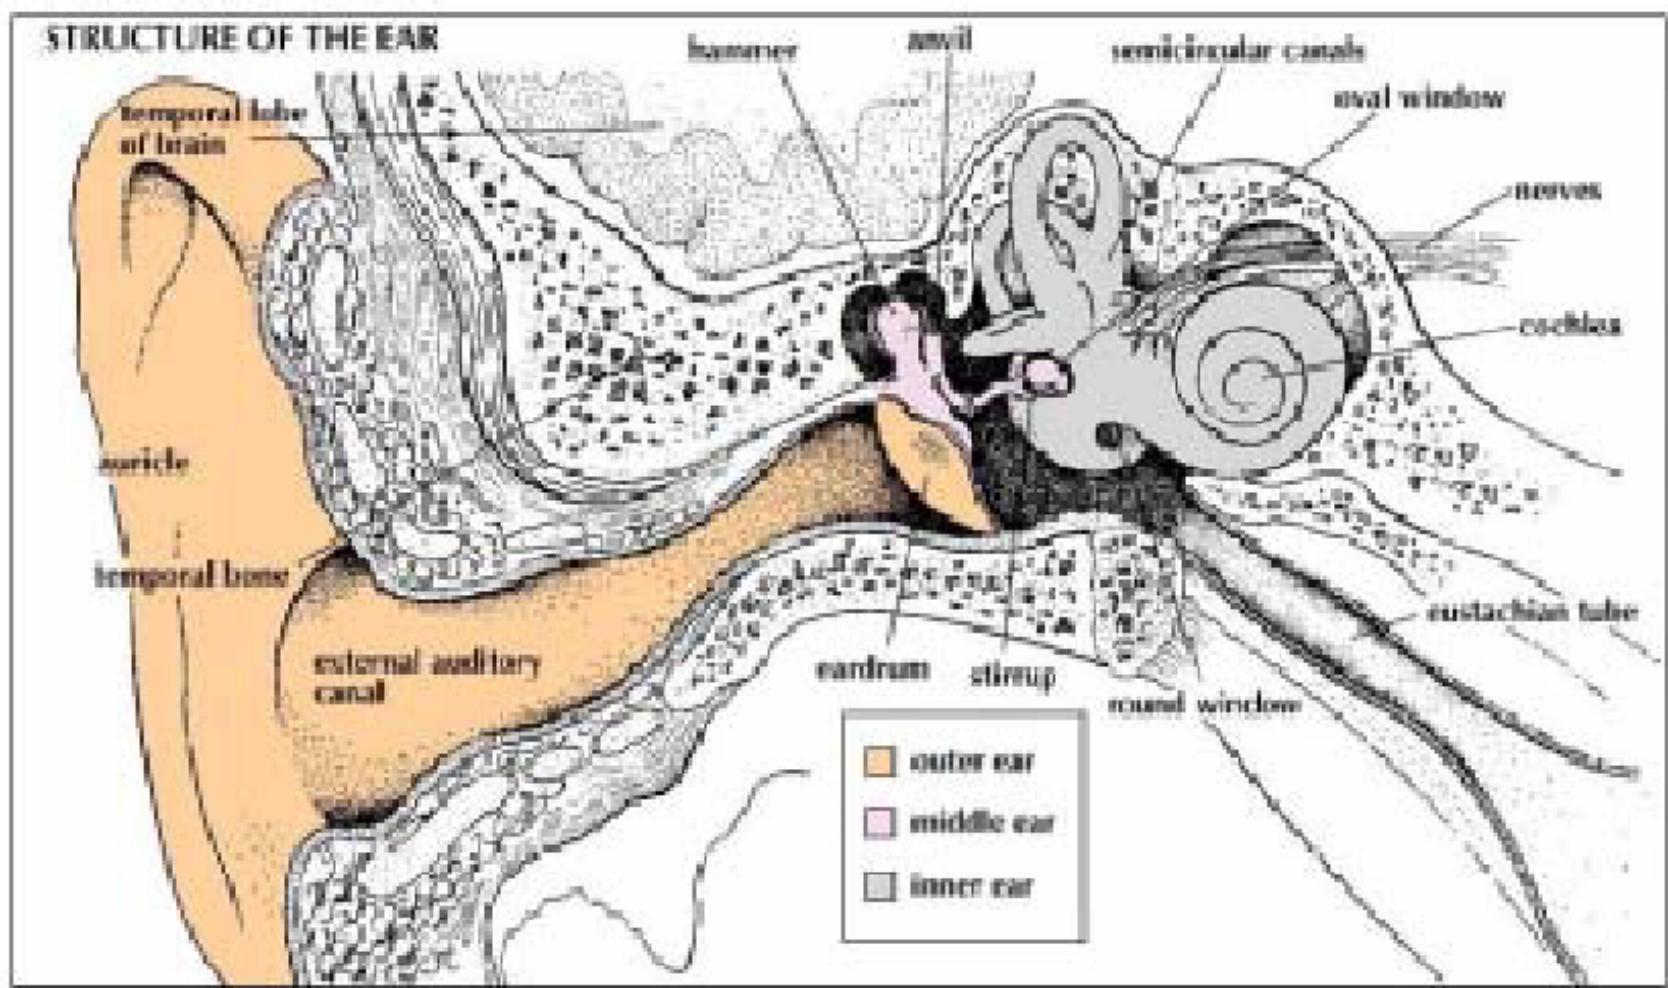


Схема уха



Основные идеи психоакустики



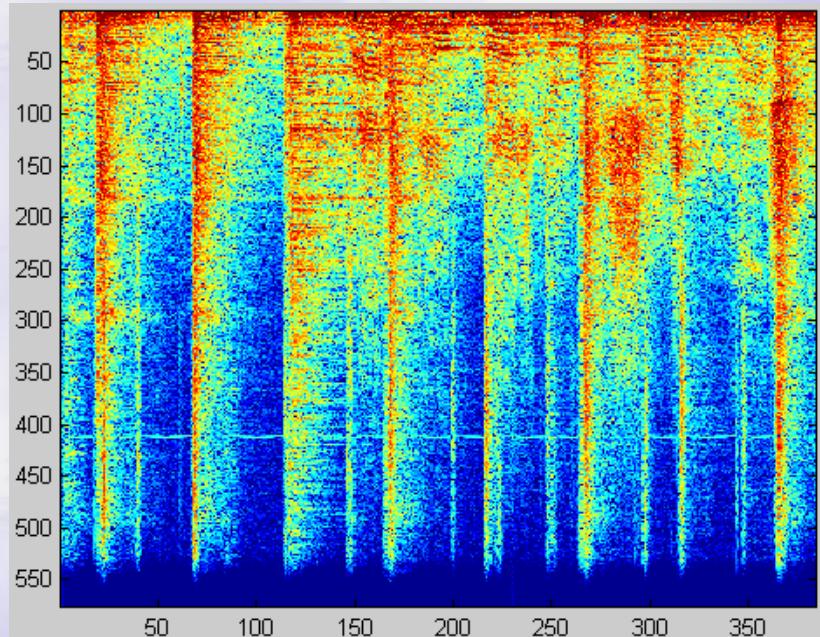
- ◆ Описание свойств слуховой системы человека, на которой основана технология кодирования
- ◆ Чувствительность человеческого слуха находится в диапазоне от 2.5 до 5 кГц
- ◆ Значимое свойство психоакустики – эффект маскирования спектральных звуковых элементов
- ◆ Неслышимые аудиосигналы несущественны для человеческого восприятия, поэтому могут быть удалены

Псиhoаккустика

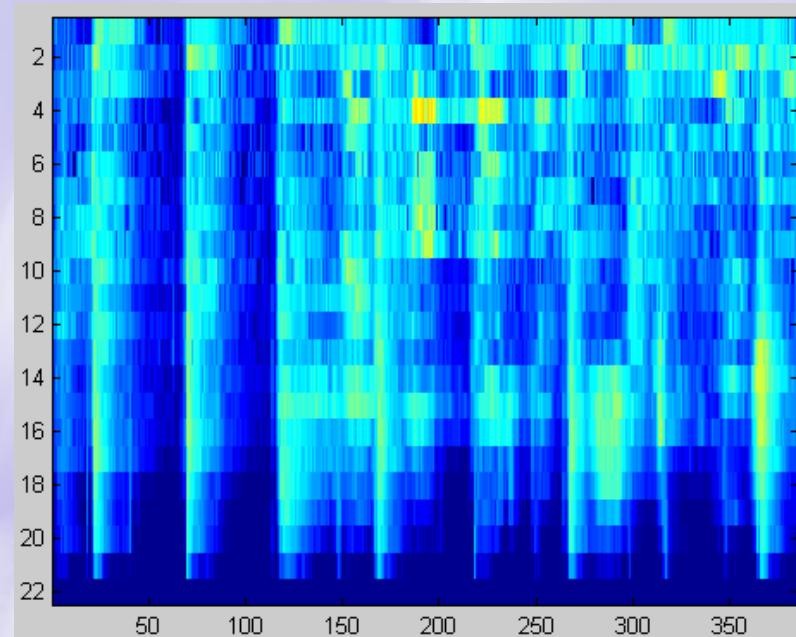
- ◆ Построение частотно-временных порогов слышимости шумов квантования в зависимости от исходного аудио-сигнала
- ◆ Абсолютные пороги слышимости
- ◆ Свойство маскирования

Психодактика

- ◆ Пример психоакустических порогов



MDCT-спектограмма



Пороги

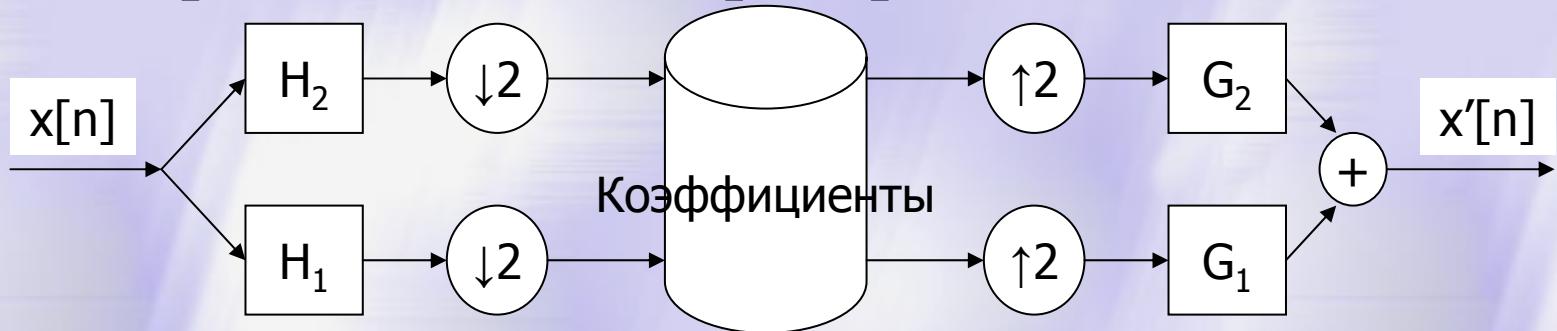
Банки фильтров

- ◆ Банк фильтров – преобразование сигнала в несколько сигналов, соответствующих частотным полосам, с возможностью обратного синтеза исходного сигнала.
 - С точным восстановлением?
 - С увеличением количества информации?
 - С гладкими пространственными свойствами?

Вейвлеты как банки фильтров



◆ Дискретное вейвлет-преобразование



Декомпозиция

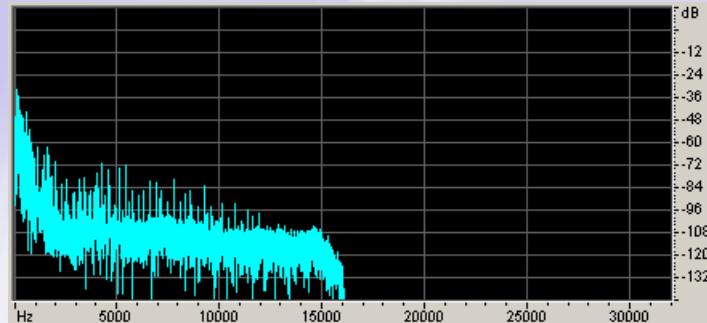
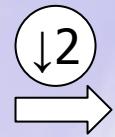
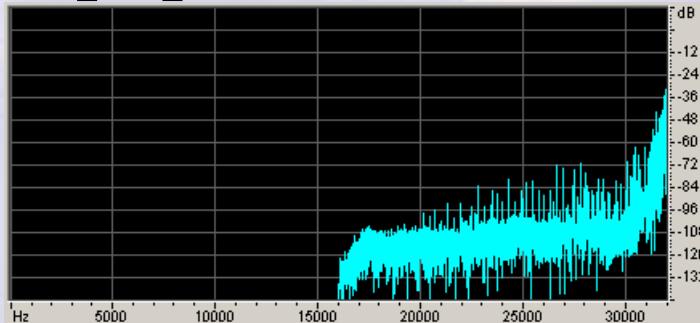
Реконструкция

- Свойство точного восстановления (PR):
- Количество информации не изменяется. $x[n] \equiv x'[n]$
- Нужно найти хорошие фильтры, обеспечивающие точное восстановление.

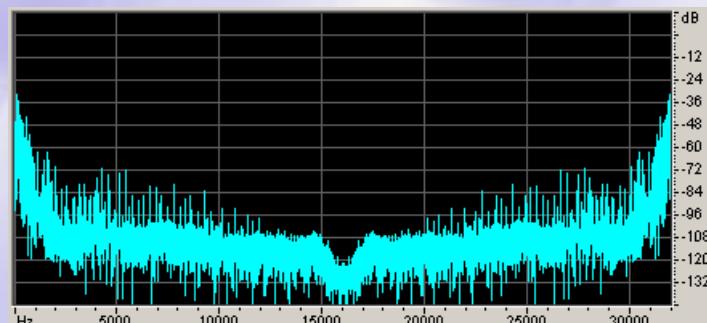
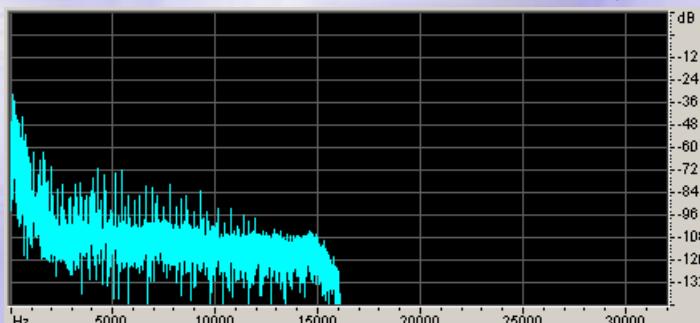
Вейвлеты как банки фильтров



◆ Прореживание ВЧ-сигнала

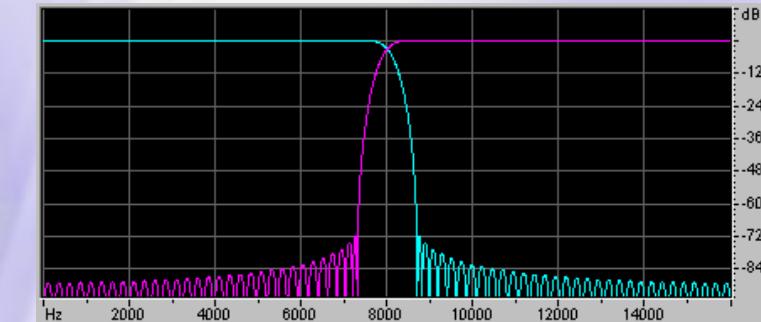


◆ Интерполяция нулями

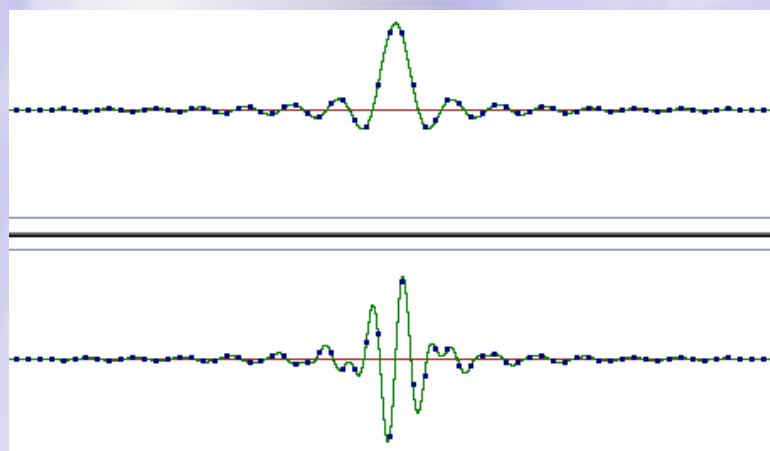


Вейвлеты как банки фильтров

- ◆ Квадратурные зеркальные фильтры (QMF)



частотные
характеристики

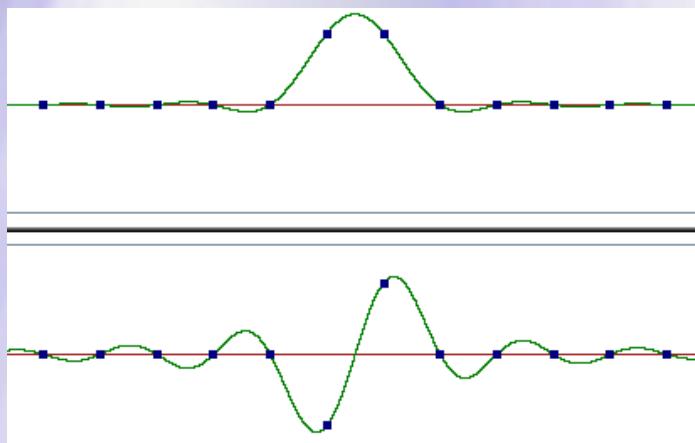
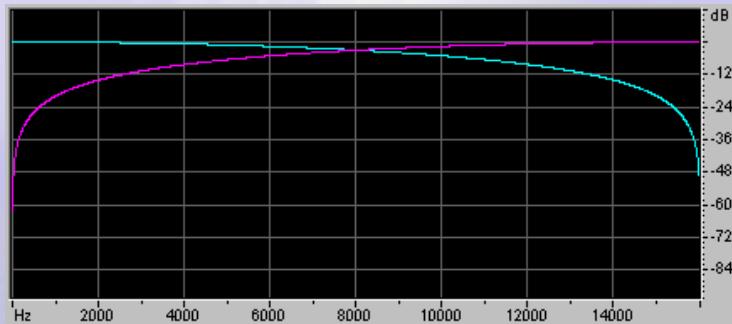


импульсные
характеристики

Вейвлеты как банки фильтров



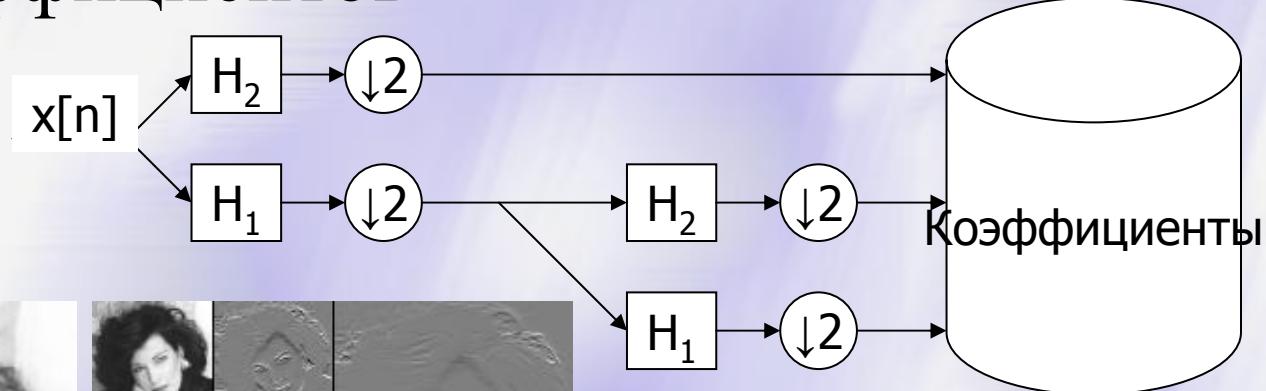
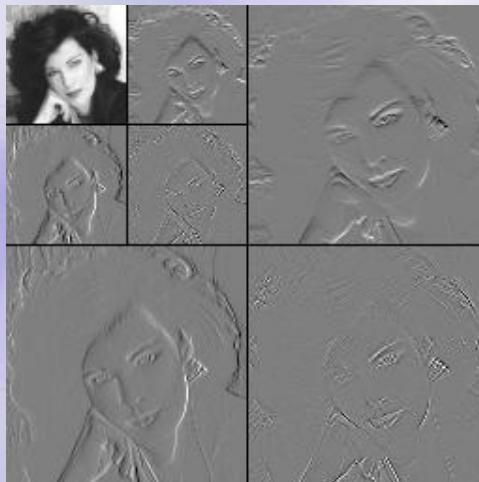
◆ QMF: базис Хаара



Плохое частотное разделение, но хорошая временная (пространственная) локализация

Пирамидальное представление

- ◆ Продолжаем вейвлет-разложение для НЧ-коэффициентов

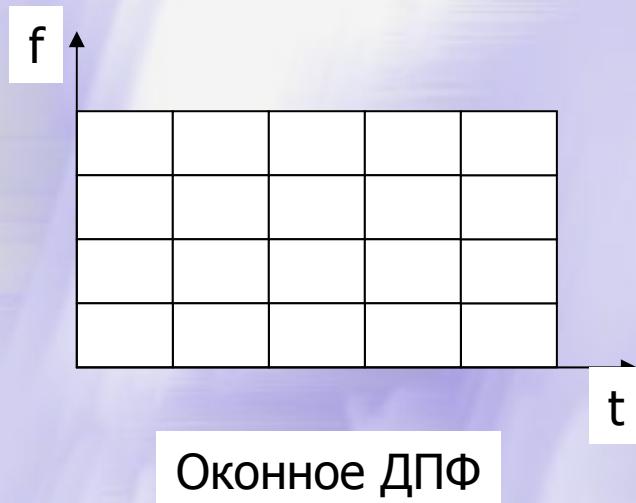


Двумерное вейвлет-преобразование

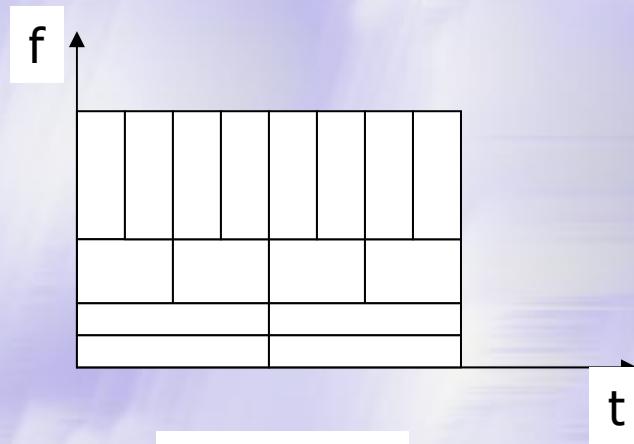
(на каждом шаге получаем 4 набора коэффициентов)

Банки фильтров

- ◆ Как банки фильтров разбивают частотно-временную плоскость?



Оконное ДПФ



Вейвлеты

Банки фильтров: FFT

- ◆ Без окон, без перекрытия
 - Плохое разделение по частотам
 - Временной алиасинг
 - Нет избыточности
- ◆ С окнами, с перекрытием
 - Хорошее разделение по частотам
 - Нет временного алиасинга (при двукратном применении окон)
 - Избыточность

Банки фильтров: MDCT

- ◆ Хорошее разделение по частотам
- ◆ С перекрытием и уничтожением временного алиасинга
- ◆ Без избыточности!

Каждое окно длины $2N$ захватывает N новых отсчетов и выдает N коэффициентов.

Банки фильтров: MDCT

- ◆ Входные блоки: $2N$ точек, из них только N новых
- ◆ Выходные коэффициенты: N действительных коэффициентов на блок
- ◆ Весовые окна:

$$h^2[n] + h^2[N-1-n] = 2, \quad 0 \leq n < N$$

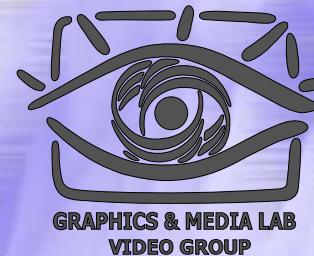
$$h^2[N+n] + h^2[2N-1-n] = 2, \quad 0 \leq n < N$$

Избыточность аудио

В аудио-сигнале избыточны:

- ◆ Амплитуды тонов, вблизи всплесков тонов (маскировка по частоте)
- ◆ Амплитуды сигнала после всплесков сигнала (маскировка по времени)
- ◆ Низкие и высокие частоты могут быть представлены менее точно
- ◆ Разные каналы в стерео и 5.1 могут быть весьма похожи

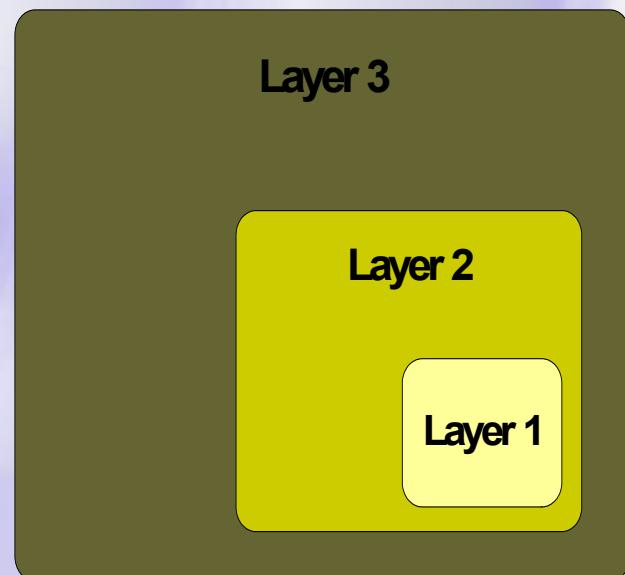
Использование стандарта аудиокодирования MPEG



- ◆ Цифровое аудиовещание (EUREKA DAB, WorldSpace, ARIB, DRM)
- ◆ Передача данных в сетях ISDN
- ◆ Архивное хранение эфирных материалов
- ◆ Звуковая дорожка в цифровом телевидении (DVB, Video CD, ARIB)
- ◆ Потоковые медиаданные в интернете (Microsoft Netshow, Apple Quicktime)
- ◆ Портативные плееры (mpman, mplayer3, Rio, Lyra, YEPP, iRiver и др.)
- ◆ Хранение и перенос музыкальных файлов

MPEG-1 Audio

- ◆ Первая фаза разработки группы MPEG. Началась в 1988 и закончилась в конце 1992 выработкой стандарта ISO/IEC IS 11172
- ◆ MPEG-1 состоит из трех уровней повышающейся сложности кодирования



MPEG-1 Audio

ISO/IEC 11172-3 (MPEG-1): 1992

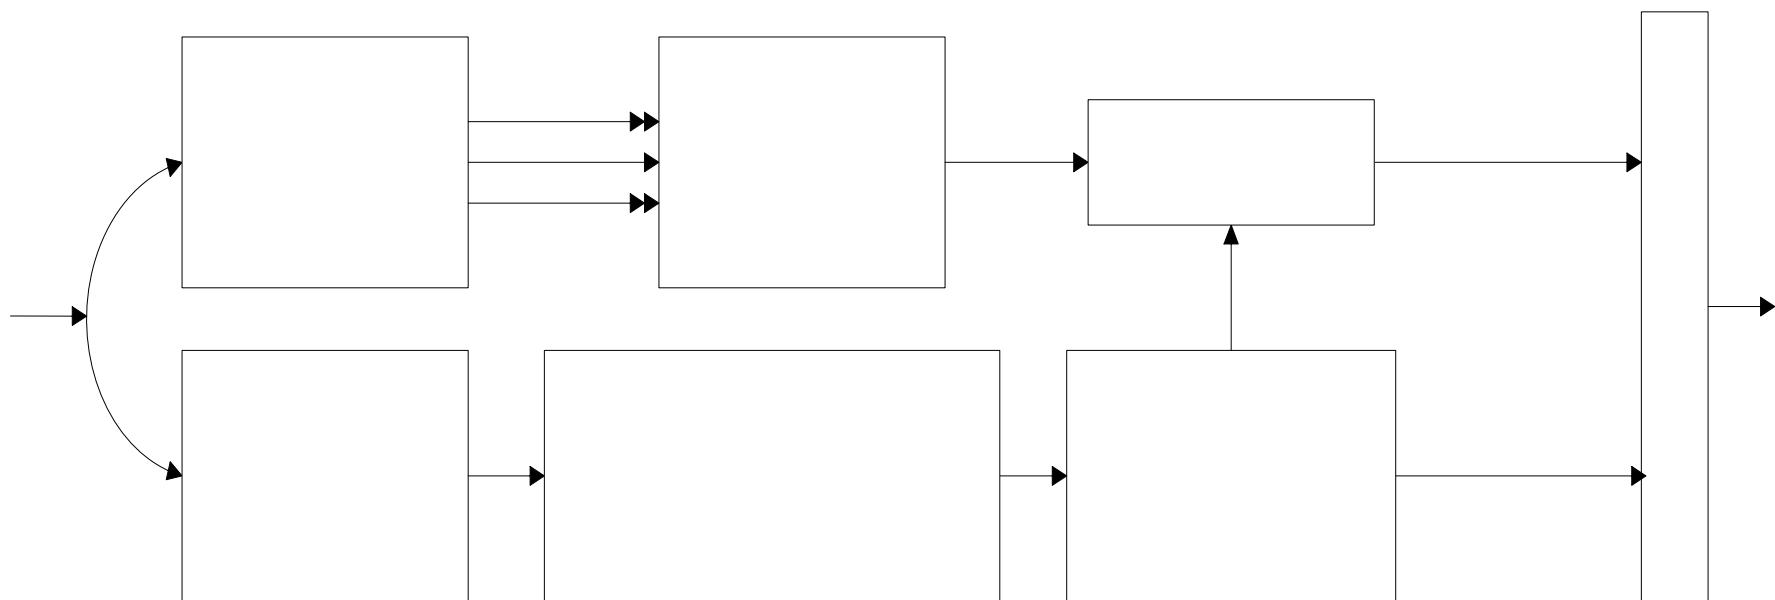
- ◆ Вход: 16-bit PCM, 32, 44.1 и 48 кГц
- ◆ Выход:
 - mono, stereo, dual independent mono и joint stereo
 - rate: 32-196 Кб/с (mono), 64-384 Кб/с (stereo)
- ◆ MPEG-1 layer III: MP3

MPEG-1

Диаграммы кодирования



◆ MPEG1 – I/II

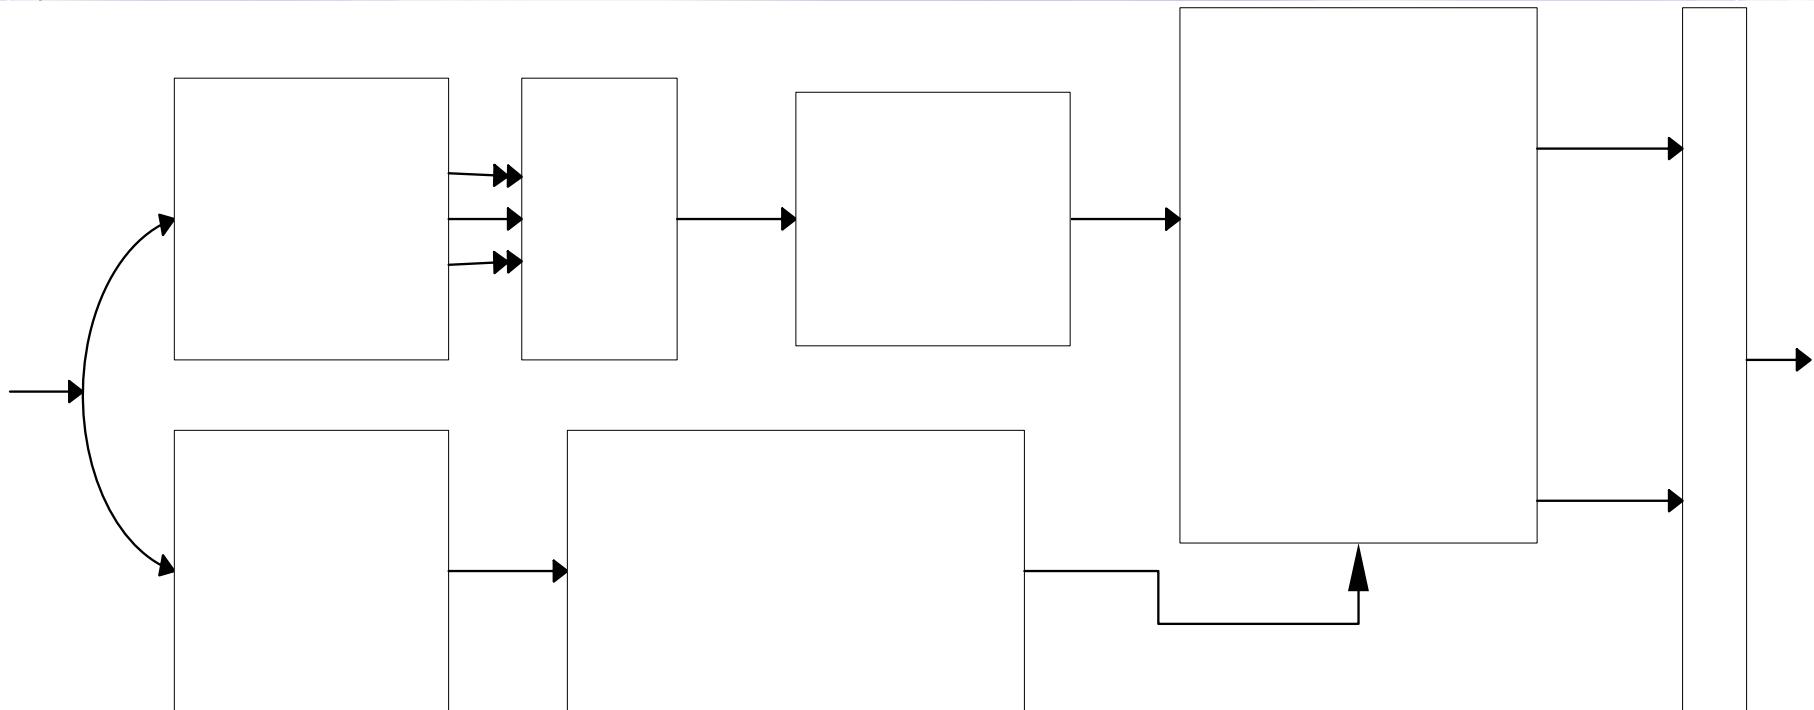


MPEG-1

Диаграммы кодирования



◆ MPEG1 – III (MP3)



MPEG-2 Audio

- ◆ Были внедрены новые понятия в MPEG кодировании видео, такие как чересстрочные видеосигналы.
- ◆ Основная область применения MPEG-2 – это цифровое телевидение
- ◆ Законченный в 1994 году стандарт MPEG-2, состоит из двух расширений MPEG-1, не предложивших новых алгоритмов кодирования

MPEG-2 Audio

ISO/IEC 13818-3 BC/LSF:

- Не исключает использование прежних версий
- Поддержка низких частот
- Кодирование стереосигналов. Известная из звуковых дорожек к фильмам конфигурация “5.1 - аудио”
- Поддержка mono, stereo 16, 22.05, 24, 32, 44.1 и 48 кГц
- Битрейт: 32-640 Кб/с

MPEG-2 AAC

В 1994 году проверочный тест показал, что предложенные новые алгоритмы кодирования (без обратной совместимости с MPEG-1) значительно повысят эффективность кодирования.

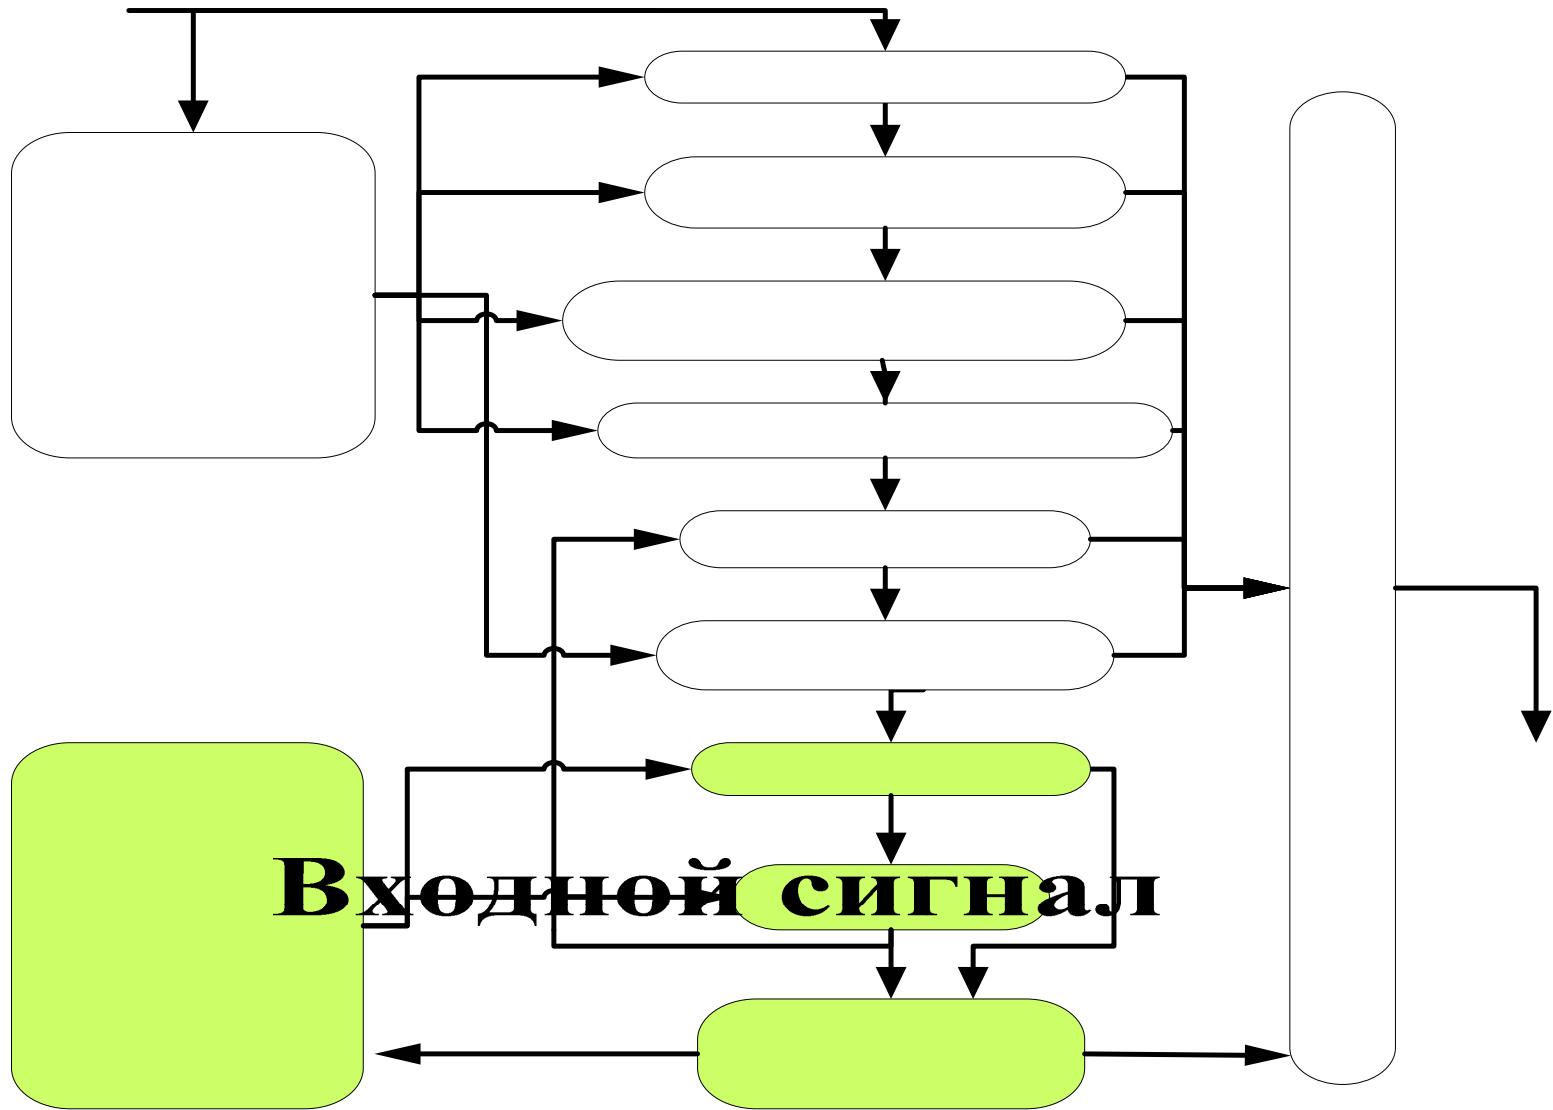
Так появился MPEG-2 Advanced Audio Coding (AAC)

MPEG-2 Advanced Audio Coding



- ◆ Основной принцип ACC кодирования аналогичен Layer-3.
- ◆ ACC имеет ряд улучшений в некоторых деталях. Использует новые средства для улучшения качества кодирования при низких битрейтах.

Схема кодирования AAC



MPEG-2 AAC

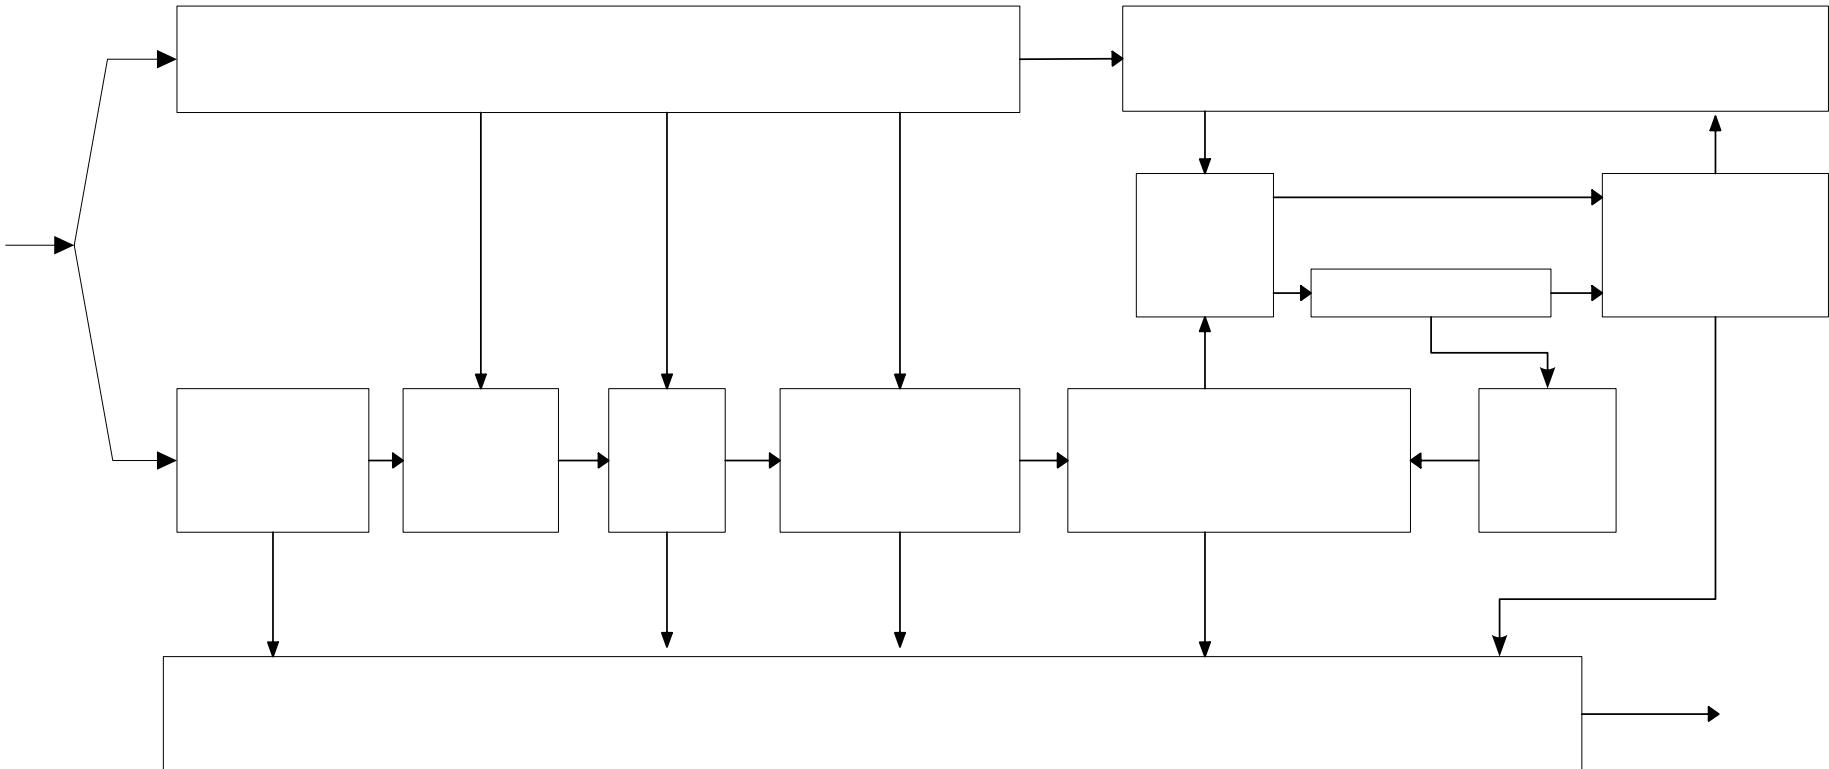
ISO/IEC 13818-7 NBC/AAC:

- NBC/AAC: Несовместим с прежними версиями / расширенное кодирование звука
- 5 каналов: левый, правый, центральный, окружающий левый, окружающий правый
- Поддержка 32, 44.1 и 48 кГц
- Частота 8-64 Кб/с на канал

MPEG-2



◆ MPEG-2 NBC/AAC диаграмма кодирования



MPEG-2 AAC

Audio Transport Formats



◆ ADIF (Audio Data Interchange Format)

Все данные контроля декодера (частота семплования, режим и т.д.) помещаются в один заголовок, идущий перед аудиопотоком. Не позволяет кодировать начиная с определенной точки, как в стандарте MPEG-1

◆ ADTS (Audio Data Transport Stream)

Пакует AAC-данные во фреймы с заголовками очень похожими на заголовки MPEG1/2. Позволяет кодировать начиная с середины потока.

Почему MP3?

- ◆ Открытый стандарт
- ◆ В течение многих лет существуют аппаратные и программные кодировщики и декодировщики
- ◆ Поддерживается многими технологиями
- ◆ Короче, MP3 – нужная технология, ставшая доступной в нужное время

MPEG-1/2 Layer-3

В заголовке файла указывается:

- ◆ Слово синхронизации
- ◆ Битрейт
- ◆ Частота семплирования
- ◆ Layer
- ◆ Режим кодирования
- ◆ SCMS (Serial Copy Management Scheme)

MP3

Гибкость применения



Рабочий режим

- Один канал
- Два независимых канала
- Stereo
- Joint stereo

Гибкость применения

◆ Частота дискретизации

- MPEG-1: 32, 44.1 и 48 кГц
- MPEG-2: 16, 22.5 и 24 кГц
- MPEG-2.5 (расширение MP3): 8, 11.05 и 12 кГц

◆ Скорость передачи битов

- Поддерживается переменная и постоянная скорость передачи битов

MP3: Введение

MPEG-1 layer-III (более широко известный как MP3) – был стандартизован в 1991 в рамках кодирования видео Moving Pictures Expert Group ISO (образована в 1988).

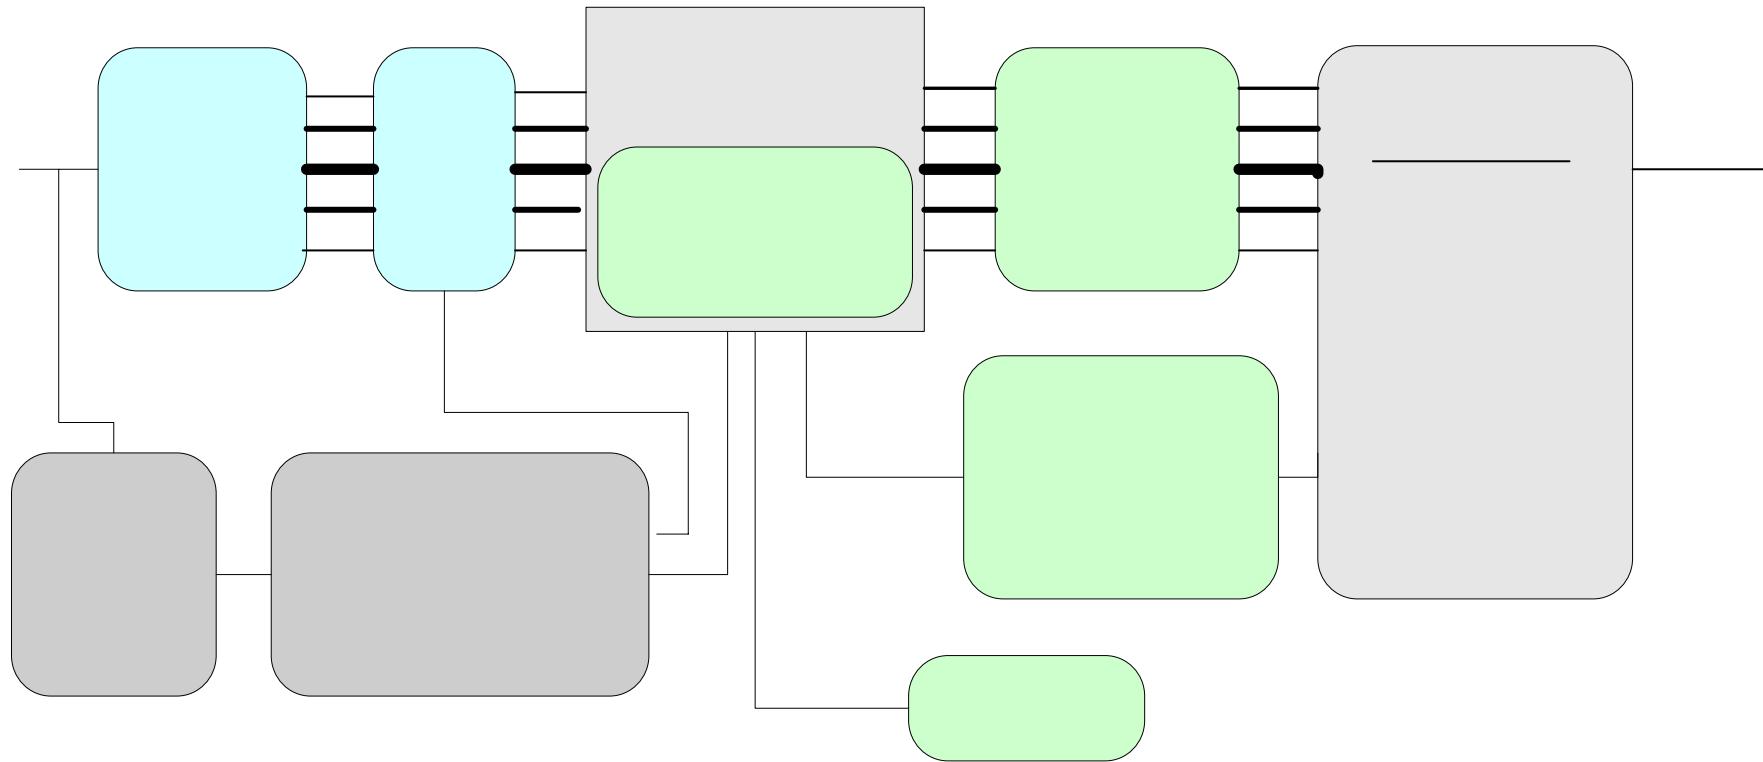
Стандарты MPEG ориентированы в т.ч. на аппаратную реализацию алгоритмов (используется сейчас в DVD и спутниковом телевидении). Включает 3 уровня сложности алгоритма I, II, III. Layer-III – самый сложный.

MP3: Введение (2)

В 1993 году, с разработкой стандарта MPEG-2, MP3 был расширен:

- ◆ Добавлена поддержка до 6 каналов (звук 5.1).
- ◆ Добавлена поддержка низких частот сэмплирования входных сигналов, что позволило повысить качество на низких битрейтах

MP3: Общая схема MP3



MP3: Схема работы

- ◆ Модифицированное косинусное преобразование (MDCT) используется для разложения сигнала.
- ◆ БПФ (FFT) – для расчета психоакустики
- ◆ кодирование по Хаффману — для сжатия без потерь.

MP3: MDCT

Ключевым преобразованием в MP3 является MDCT (суть та же, что в DCT в JPEG & MPEG-4, но преобразование берется с пересекающимися окнами). Прямое и обратное преобразование:

$$y(k) = 2 \cdot \sum_{n=0}^{N-1} x(n) \cos\left(\frac{\pi}{N}(n+n_0)(2k+1)\right), \text{ for } 0 \leq k < \frac{N}{2}$$

$$x(n) = \frac{2}{N} \cdot \sum_{k=0}^{\frac{N}{2}-1} y(k) \cos\left(\frac{\pi}{N}(n+n_0)(2k+1)\right), \text{ for } 0 \leq n < N$$

MP3: Квантование (1)

Общий смысл квантования – понижение точности представления данных, причем в аудио это делается на разную величину для разных амплитуд данных:

$$ix(i) = \text{nint} \left(\left(\frac{|xr(i)|}{\sqrt[4]{2^{qquant + quantanf}}} \right)^{0.75} - 0.0946 \right)$$

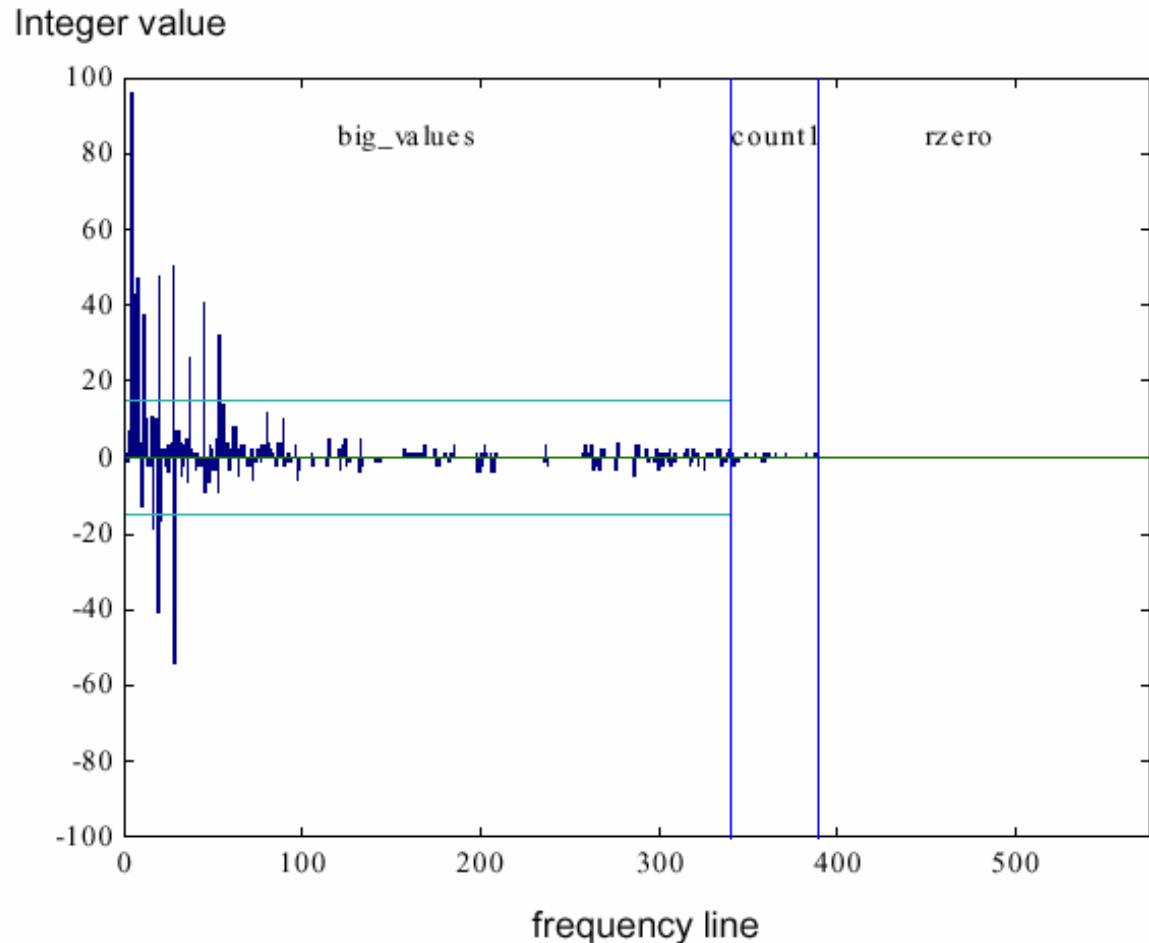
где, $xr(i)$ – исходные данные, $qquant$ и $quantanf$ – значения кванта для всего преобразования и конкретного участка, $\text{nint}()$ – округление к ближайшему целому.

MP3: Квантование (2)

Управляя квантованием – можно:

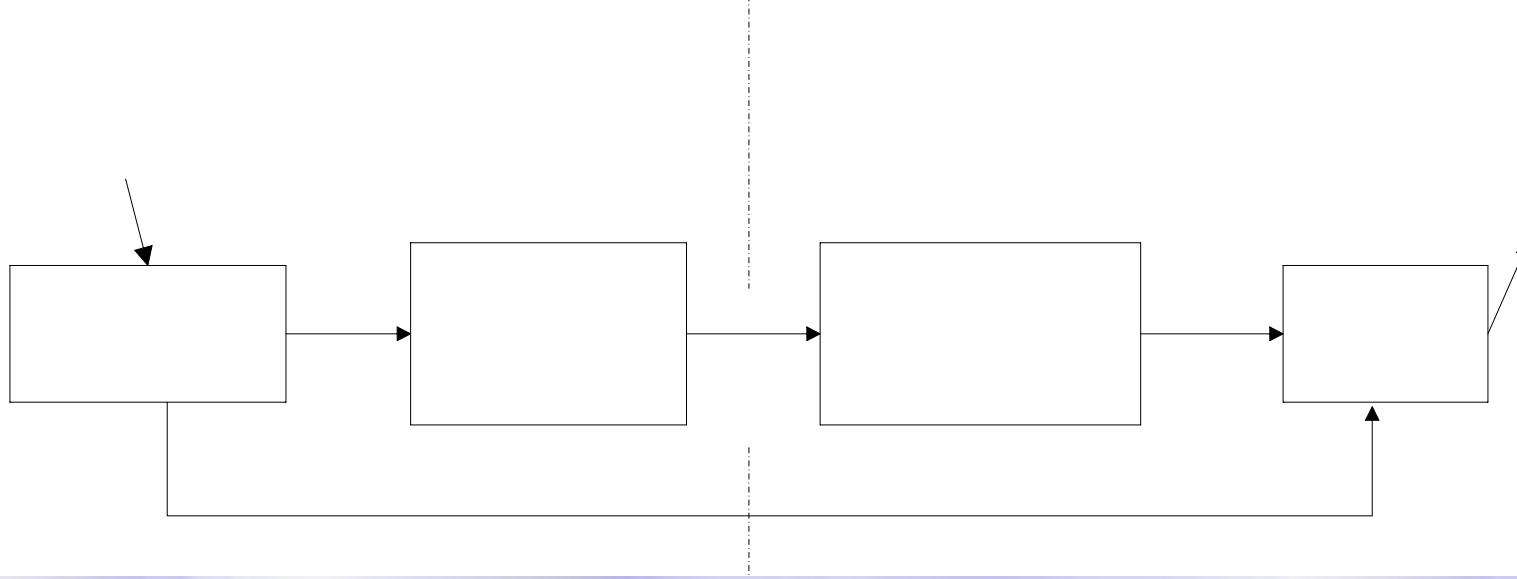
- ◆ Задавать точность представления участков спектра (использовать психоакустiku для увеличения сжатия),
- ◆ Задавать качество участков мелодии (задавать разные стратегии управления размером – CBR, VBR и т.д.)
- ◆ Управлять общим размером мелодии (задавать битрейт)

MP3: Распределение амплитуд частот



В реальных мелодиях большая амплитуда у низких частот и малая у высоких

MP3: Квантование и энтропийное сжатие



Данные после MDCT преобразования подвергаются огрублению (от которого зависит битрейт и собственно качество), и далее без потерь сжимаются по Хаффману с фиксированными таблицами.

MP3: Удаление избыточности каналов



Стерео-сигнал может кодироваться 3 способами:

- ◆ Независимое сжатие каналов
- ◆ Использование MS stereo
- ◆ Использование Intensity Processing

MP3: MS stereo

$$L_i = \frac{M_i + S_i}{\sqrt{2}} \quad \text{and} \quad R_i = \frac{M_i - S_i}{\sqrt{2}}$$

M_i – сумма значений в 2 каналах

S_i – разность значений в 2 каналах

Это наиболее простой способ
уменьшения избыточности между двумя
каналами.

MP3: Intensity stereo

$$is_ratio = \tan\left(is_pos_{sb} \cdot \frac{\pi}{12}\right)$$

$$L_i = L_i \cdot \frac{is_ratio}{1 + is_ratio}$$

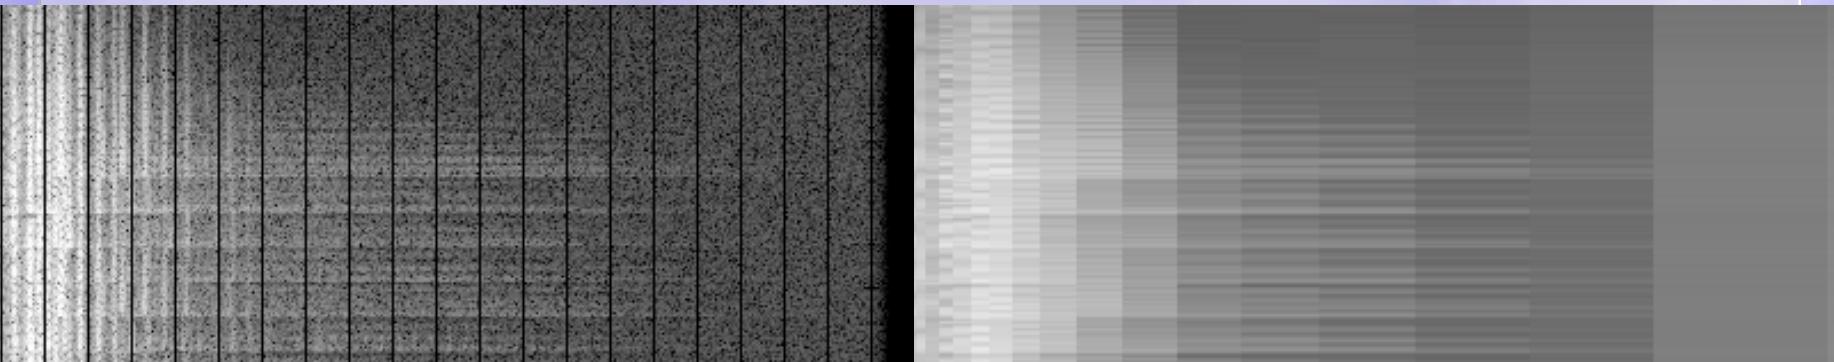
$$R_i = L_i \cdot \frac{1}{1 + is_ratio}$$

Метод работает, когда части спектра стерео-сигнала пропорциональны (как правило на высоких частотах)

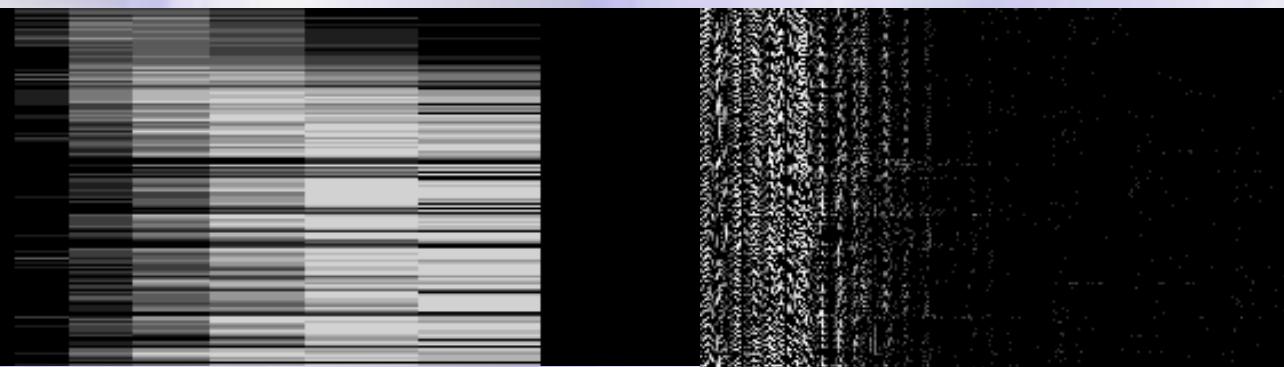
Более сложный метод, использующий разложение амплитуду и стерео часть, и сохраняющий данные is_pos_{sb} в данных коэффициентов квантования.

Приведены формулы восстановления сигнала.

MP3: Визуализация значений коэффициентов

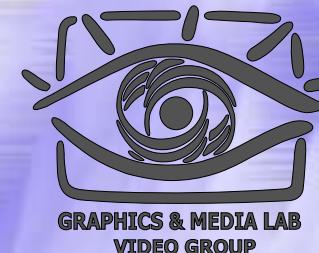


Исходные данные и пороги чувствительности



кванты и отквантованные значения

Схема преобразований MP-3



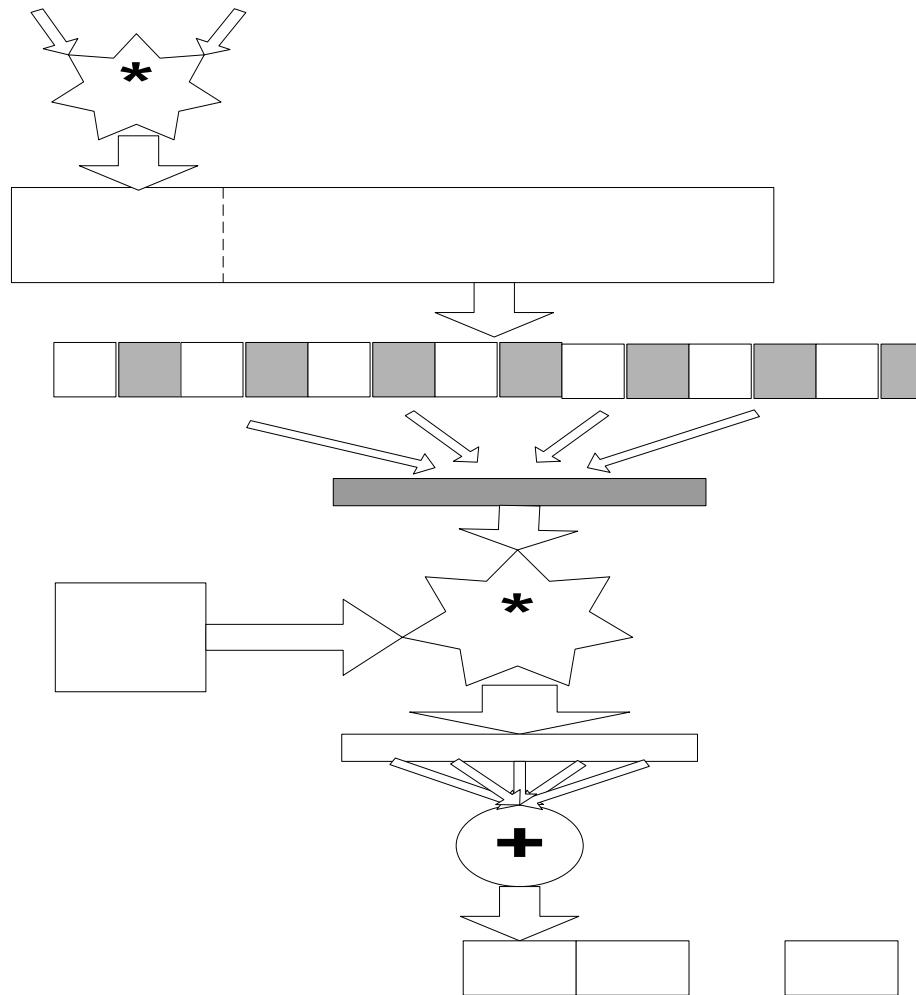
$$Y_i = \sum_{k=0}^{31} N_{ik} S_k; \quad 0 \leq i < 64$$

```
for i=1023 downto 64 do V[i]=V[i-64]  
for I=0 downto 63 do  V[i]=Y[i]
```

```
for i=0 to 7 do  
  for j=0 to 31 do  
    U[i*64+j]=V[i*128+j]  
    U[i*64+32+j]=V[i*128+96+j]
```

$$W_i = U_i D_i; \quad 0 \leq i < 512$$

$$S_j = \sum_{i=0}^{15} W_{j+32i}; \quad 0 \leq j < 32$$



Применение

- ◆ MPEG-1 layer I: 384 kb/s, цифровые кассеты (DCC)
- ◆ MPEG-1 layer II: 224 kb/s, цифровое спутниковое вещание (DBS)
- ◆ MPEG-1 layer II: 256 kb/s, трансляция цифровой звукозаписи, Eureka 147 digital
- ◆ MPEG-1layer III: MP3
- ◆ MPEG-2 BC/LSF: кино
- ◆ MPEG-2 NBC/AAC: Internet, LiquidAudio, DRM, Xradio.

MPEG-3

- ◆ Планировалось определить стандарты кодирования видео высокой четкости (HDTV) и назвать их MPEG-3. Но до этого было решено, что возможности MPEG-2 вполне подходят для HDTV. Таким образом разработки MPEG-3 были включены в MPEG-2. В результате от MPEG-3 отказались в пользу MPEG-4
- ◆ Не путать MPEG-1/2 Layer-3 (MP3) с MPEG-3!

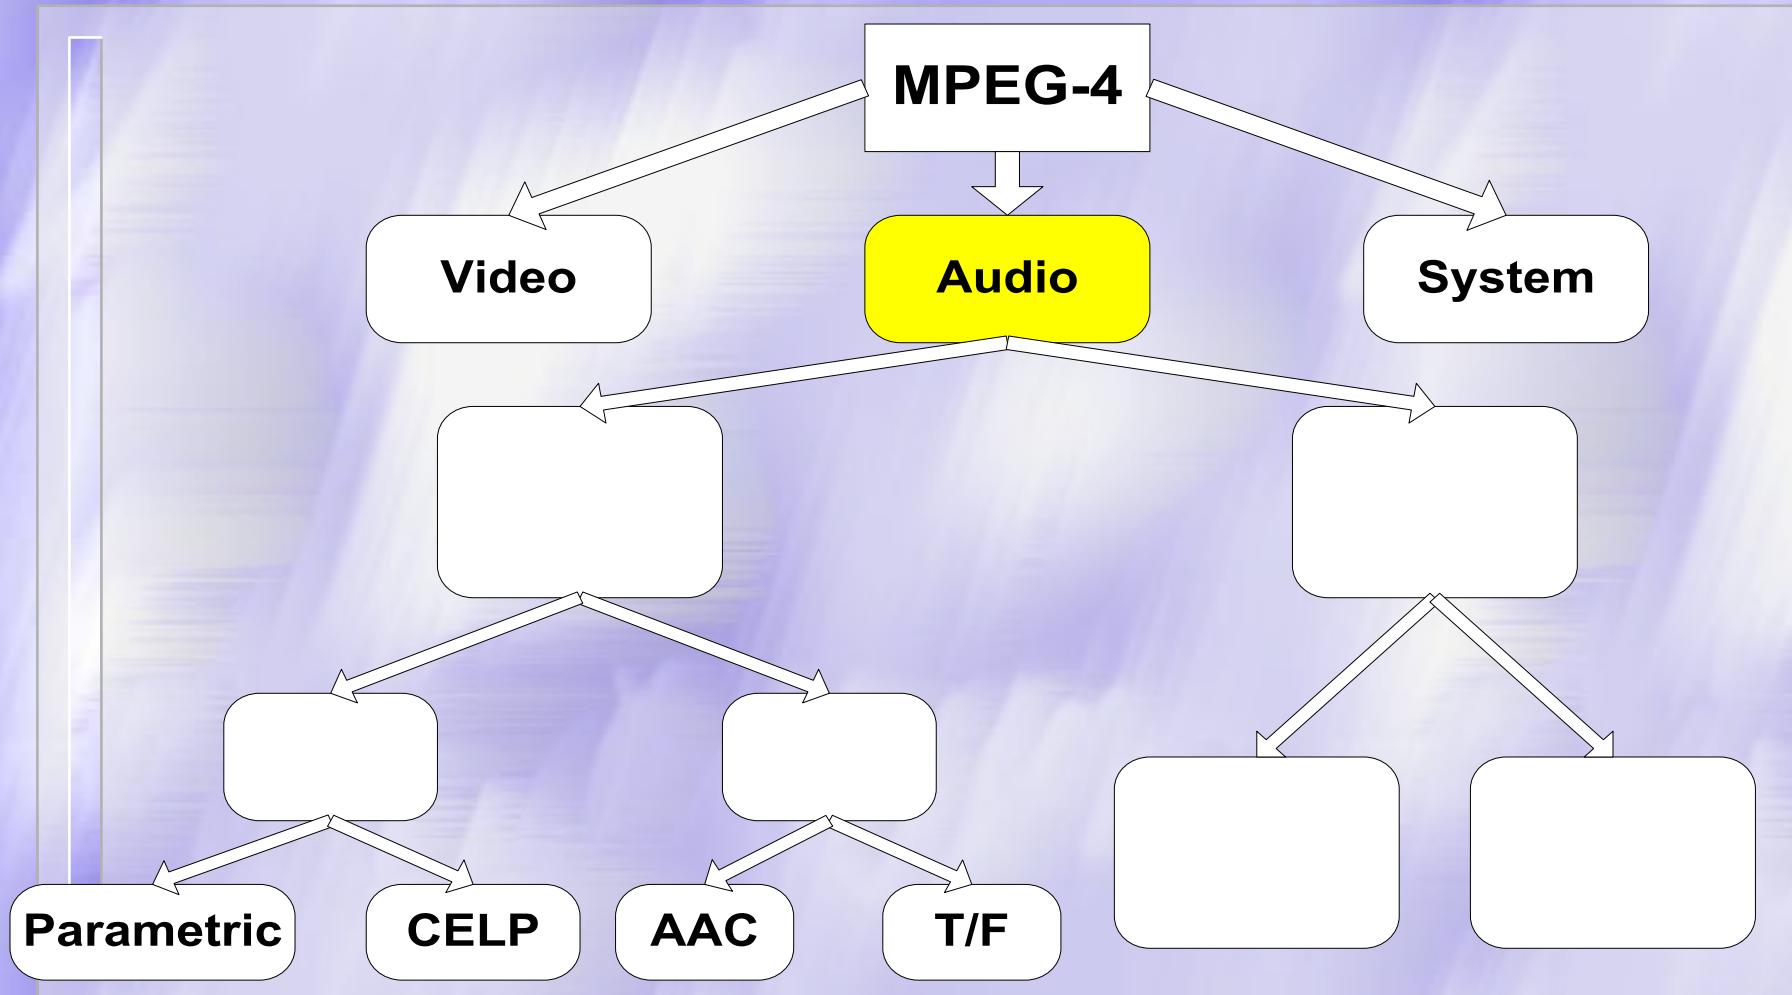
MPEG-4

Разрабатывался как очередной стандарт в мире мультимедиа и его первый Profile был закончен в 1998.

В отличие от MPEG-1 и MPEG-2, в MPEG-4 акцент сделан в основном на функциональность, а не на повышение эффективности сжатия.

MPEG-4

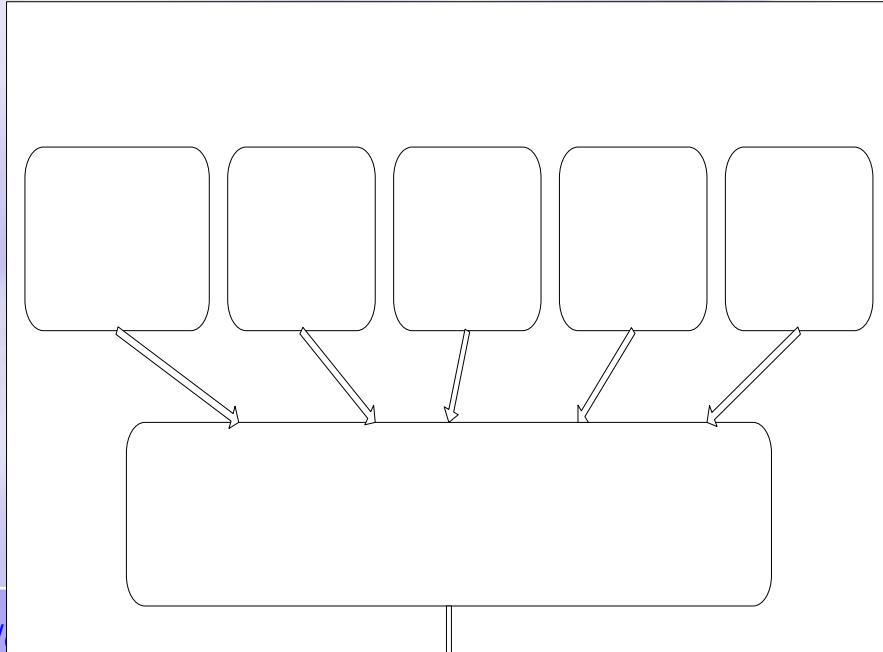
Структура стандарта



Компоненты MPEG-4 Audio



- ◆ Содержит набор различных кодек для различных типов сигналов и диапазонов частот дискретизации
 - Parametric Speech и Audio Coder
 - CELP Speech Coder
 - General Audio (G/A) Coder
- ◆ Методы синтеза звука
 - Structure Audio System
 - Text to Speech Interface



MPEG-4 Audio

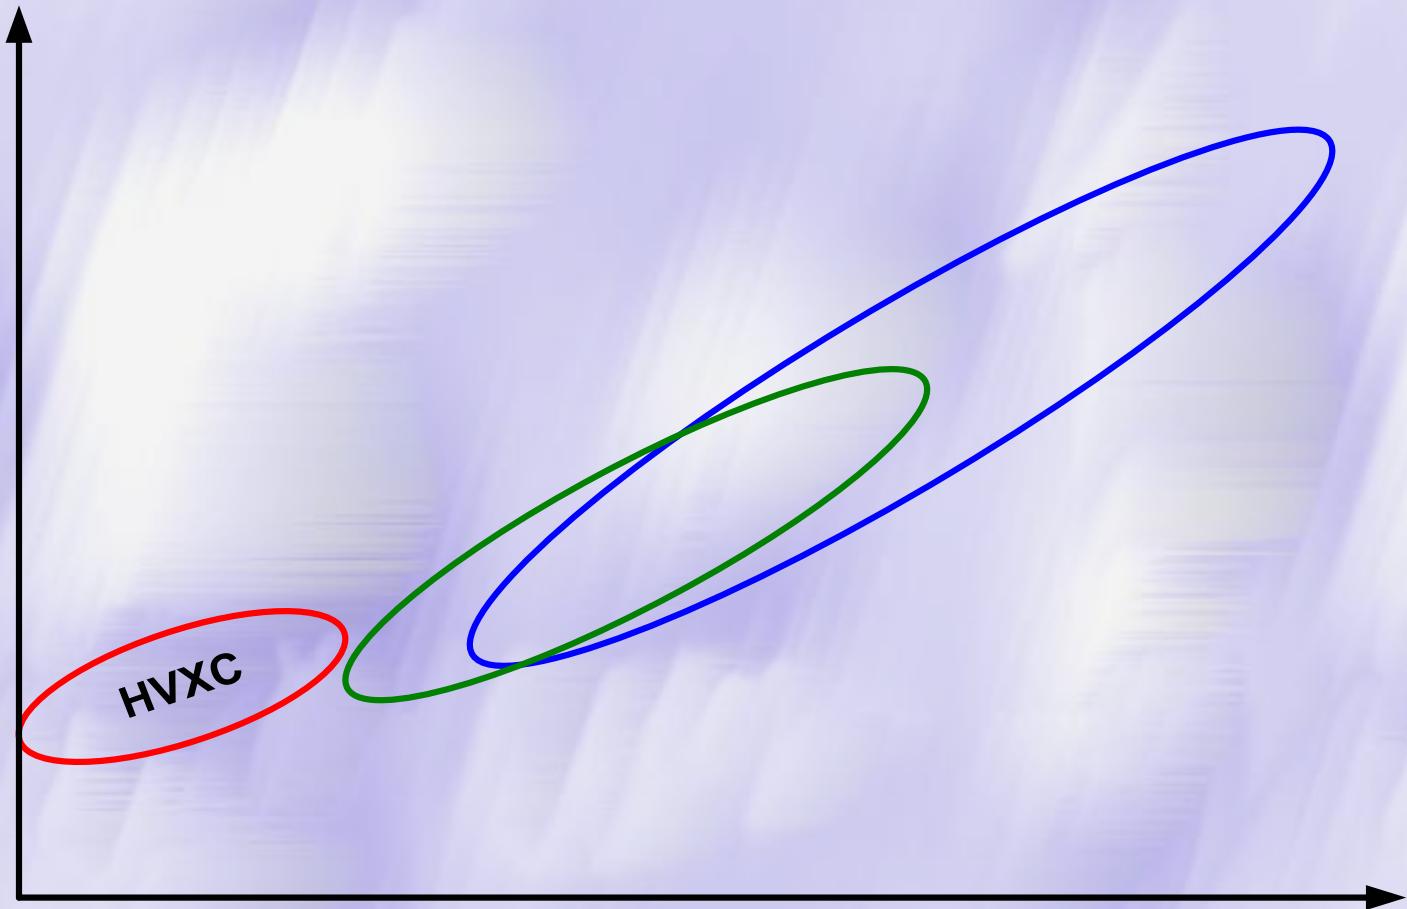
- ◆ Допустимы как synthetic coding и natural coding
- ◆ synthetic coding : вместо самого звука используется его описание. Приемник по описаниям создает похожий звук
- ◆ natural coding: Для звука используются 3 вида кодеров:
 - Параметрический кодер: для узкочастотной речи и звука частоты 2-4 кБт/с
 - CELP-кодер: для речи частоты 4-24 кбт/с
 - Перцепционный кодер: для звуковых сигналов частоты 4-24 кбт/с

Обзор natural coding

- ◆ Различные средства, зависящие от битрейта и природы сигнала
- ◆ Средства могут комбинироваться (scalable coding)
- ◆ Широко применяются как в телефонных линиях, так и в высококачественных стереосистемах

MPEG-4

Natural audio



MPEG-4

Кодирование речи



- ◆ Два основных алгоритма:
 - HVXC (Harmonic Vector eXcitation Coding)
 - CELP (Code Excited Linear Prediction)
- ◆ Широкая полоса битрейта: 1.5 – 24 кБит/с

MPEG-4

Кодирование речи



- ◆ CELP - для узкополосных и широкополосных каналов
- ◆ HVXC – как международный стандарт кодирования при самом низком битрейте (фикс. – 1.5 кБит/с и перем. – около 2.0 кБит/с)
- ◆ Новые возможности:
 - Скорость и изменение шага – HVXC
 - Регулирование битрейта – CELP, HVXC
 - Регулирование полосы частот – CELP

MPEG-4

CELP



- ◆ Узкая полоса (NB): 3.85-12.2 кБит/с; 10-40 фреймов
- ◆ Широкая полоса (WB): 10.9-23.8 кБит/с; 10-20 фреймов
- ◆ Возможность менять шаг на 200-800 Бит/с
- ◆ Регулирование битрейта:
 - NB – шаг в 2.0 кБит/с
 - WB – шаг в 4.0 кБит/с
- ◆ Регулирование полосы частот
- ◆ Точное регулирование скорости
- ◆ Один импульс: WB – низкая сложность
- ◆ Много импульсов: WB, NB – высокая эффективность кодирования

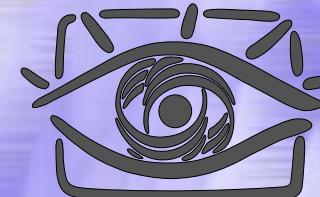
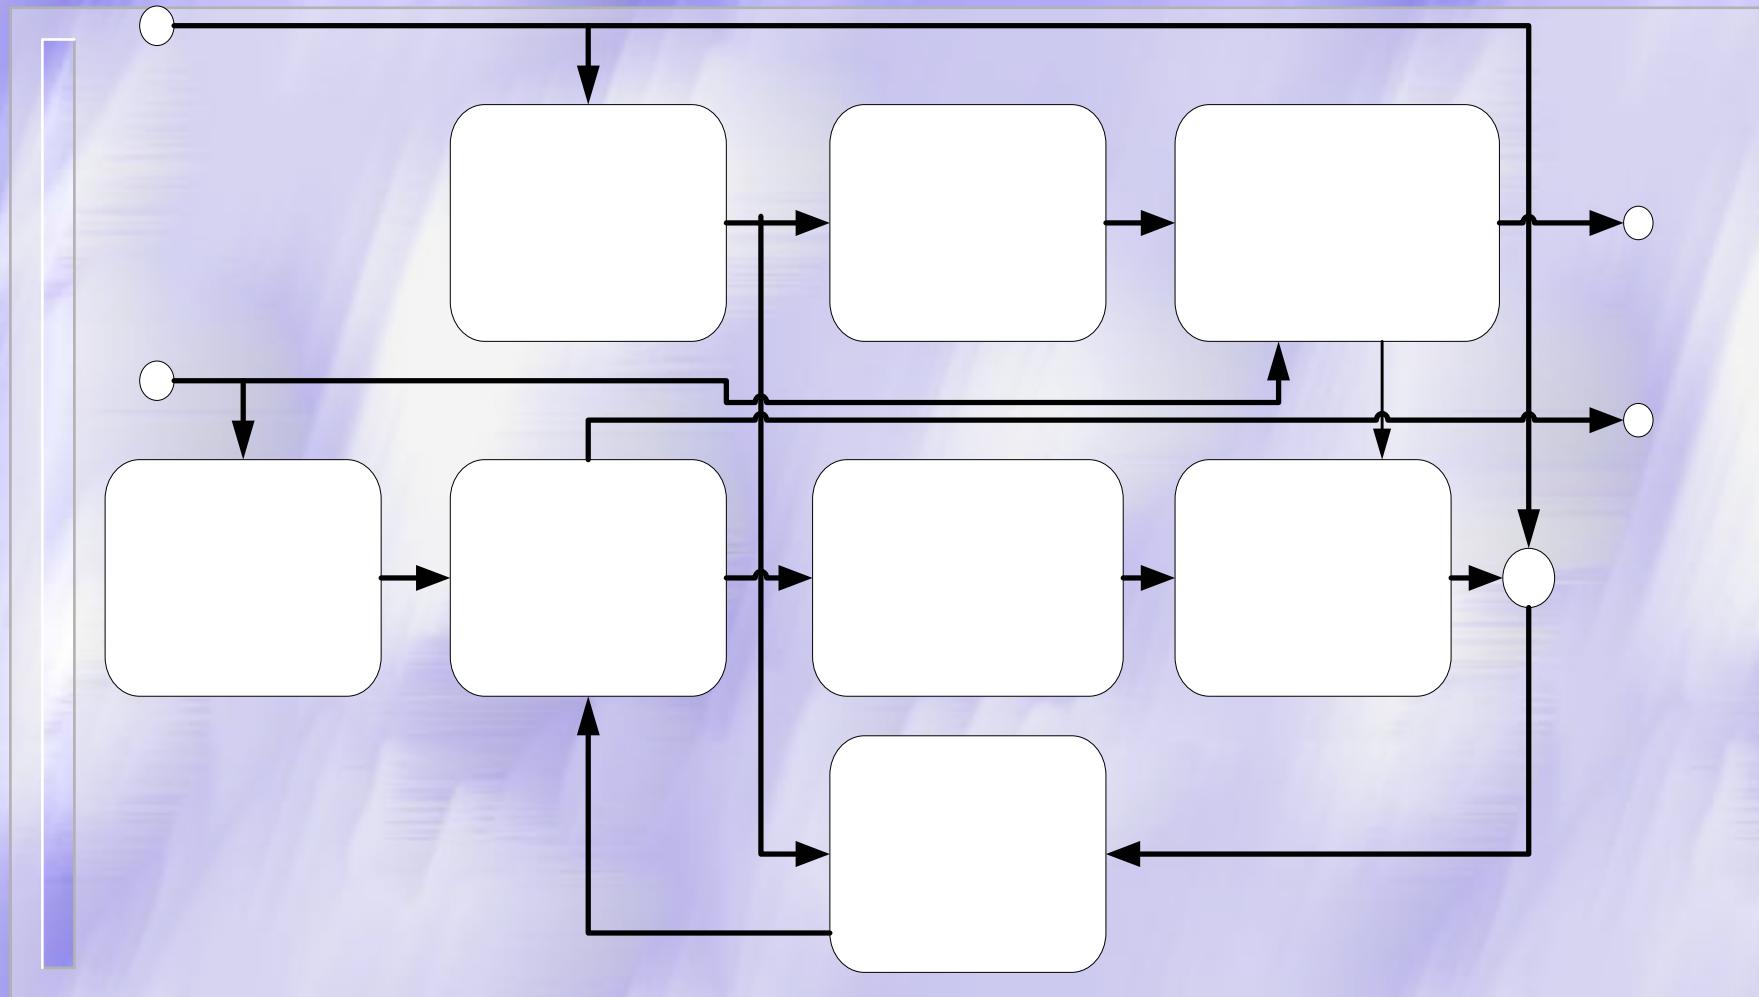
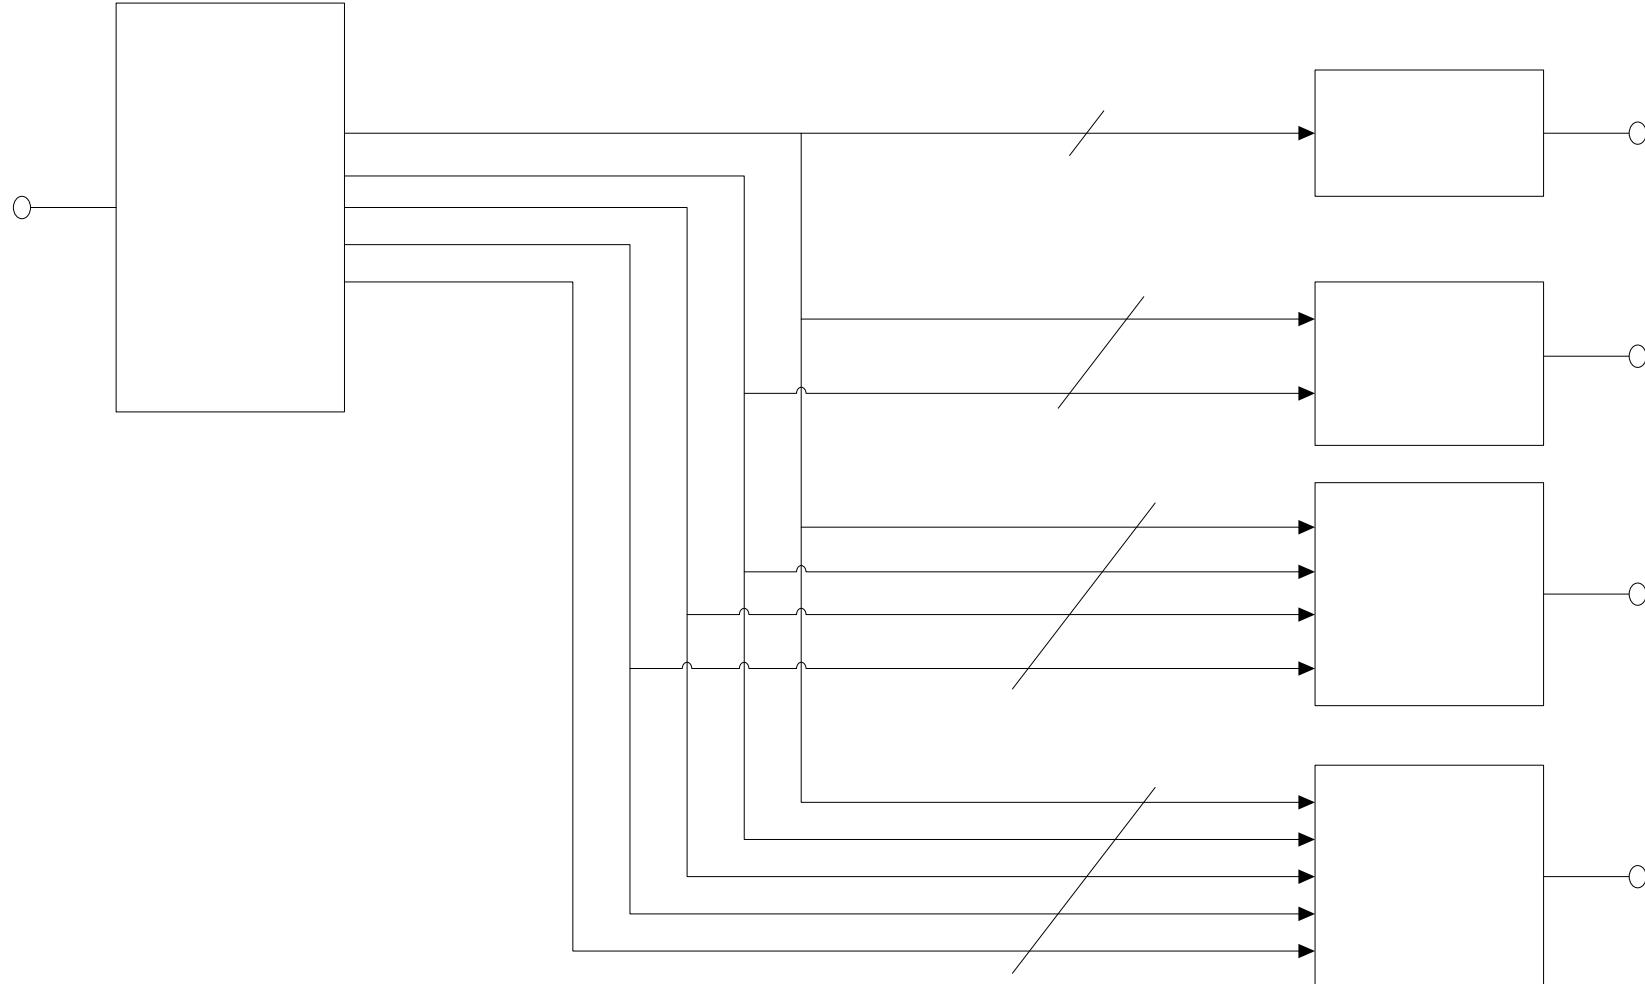


Схема CELP-кодера



Структура регулирования битрейта



MPEG-4

HVXC



- ◆ Низкий битрейт / хорошее качество
2.0 / 4.0 кБит/с (фикс.); 1.5 / 3.0 кБит/с (перем.)
HVXC при 2.0 кБит/с имеет более высокое качество, чем FS1016 CELP при 4.8 кБит/с
- ◆ Регулирование битрейта
Декодирование при 2.0 кБит/с может использовать поток при 4.0 кБит/с
- ◆ Регулирование скорости и шага
Очень подходит для быстрого поиска в голосовой базе данных и для быстрых просмотров

MPEG-4

HVXC (подход)



Объединены две схемы кодирования разных типов. Одна подходит для звучных участков. Другая – для глухих. Звонкие участки – предсказанная волна вычитается из сигнала, а ошибка сжимается в частотную область. Глухие участки – обрабатываются кодером CELP.

Обзор synthetic coding

- ◆ Вместо самого звука передает его параметрическое представление
- ◆ Допускает передачу со сверхнизкой полосой частот
- ◆ Музыка: Structured Audio (SA)
- ◆ Речь: Text-To-Speech interface

Structured Audio

SA был изобретен компанией :
Machine Listening Group

Основная идея SA: передача звука
осуществляется скорее по его описанию,
чем с помощью его сжатия.

Structured Audio

(В чем проблема?)



Существует ряд форматов сжатия аудио таких, как RealAudio, MP3, Liquid Audio, для передачи музыкальных файлов в интернете. Но у всех есть проблема: несоизмеримость качества звука с объемом музыкального файла. Формат SA подразумевал приемлемое качество при достаточно небольшом объеме файла.

Structured Audio

Принцип генерации аудио на ходу, который используется в SA, называют кодированием Колмогорова.

SA включает в себя мощный язык обработки звука SAOL (произносится «сэил») и язык оценки музыки SASL (произносится «сэссил»), с поддержкой существующего MIDI-формата.

Structured Audio

Также в SA определено эффективное кодирование его элементов в удобный для хранения и передачи файл с двоичным форматом.

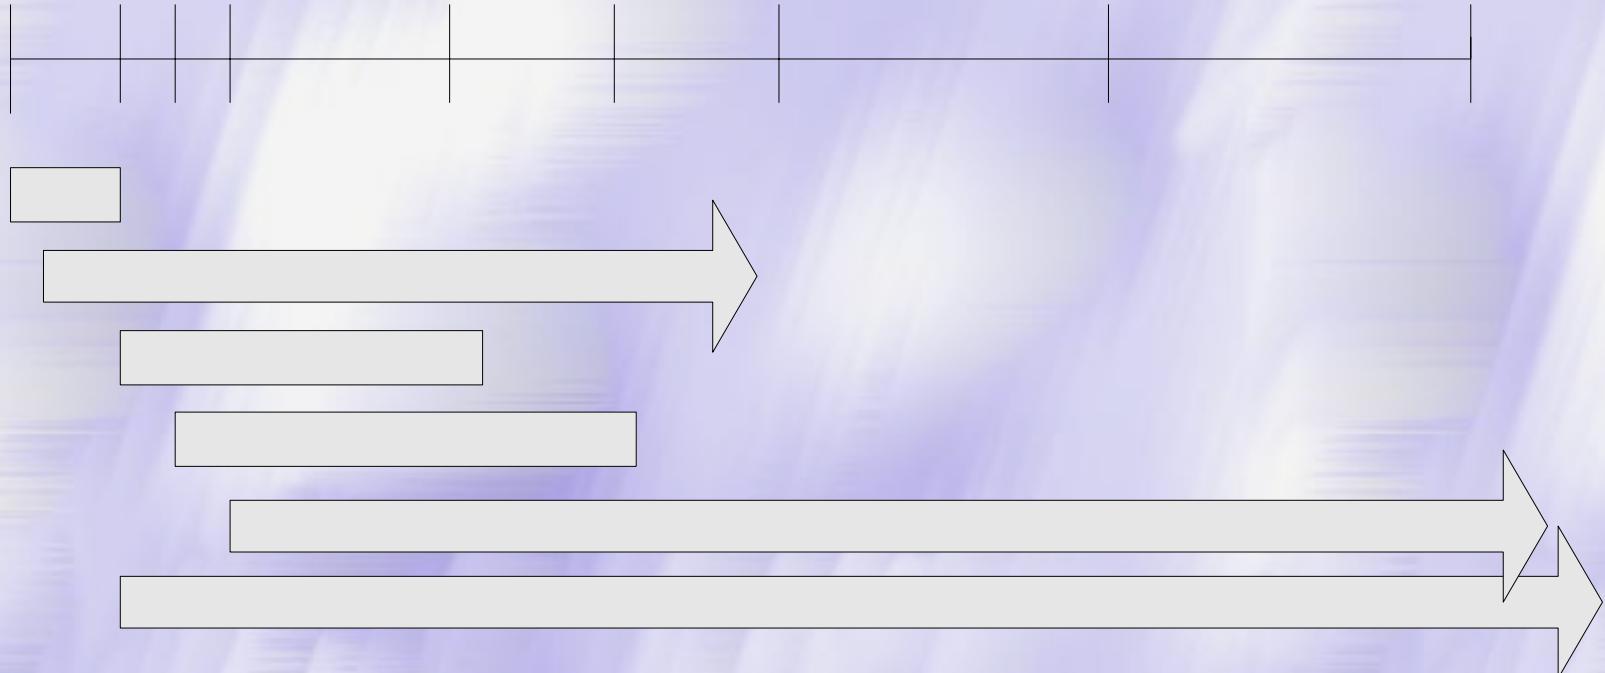
SA отличается от других форматов типа MIDI тем, что в нем задаются не только ноты, которые нужно проиграть, но и способы преобразования этих нот.

Structured Audio

В то время, как инструментальные модели используют алгоритм синтеза вместо таблиц сигналов, файл SA может описать реалистичное музыкальное представление без использование аудиоданных.

Таким образом SA-файл звучит, как WAV, но имеет меньший в 50-1000 раз объем.

Параметры Audio-компонентов



**Спутниковый
телефон**

**Сотовая
связь**

MPEG-7

- ◆ Был утвержден в июле 2001 года.
- ◆ В отличие от MPEG-1/2/4, MPEG-7 не определял алгоритмов сжатия.
- ◆ MPEG-7 стал стандартом поиска, фильтрации, управления и обработки мультимедиа-информации.

Сжатие Dolby Audio

Области применения:

- Спутниковое FM вещание, передача звука на TV (Dolby AC-1)
- Обычный стандарт кодирования в компьютерных звуковых картах (Dolby AC-2)
- Высококачественный стандарт ATV (advanced television). Область конкурирования MPEG (Dolby AC-3)

Отличия от MPEG

- ◆ MPEG-кодеры контролируют точность квантования путем вычисления количества бит для каждого сэмпла.
- ◆ MPEG должен хранить каждое значение квантования вместе с каждым сэмплом
- ◆ MPEG-декодеры используют эту информацию для деквантования: forward adaptive bit allocation
- ◆ Преимущество MPEG состоит в том, что психоакустическая модель не требуется в декодировании, где хранятся значения квантования

Отличия от MPEG

DOLBY: используется фиксированное распределение битрейта.

- Не нужно посыпать с каждым фреймом, как в MPEG
- Кодеры и декодеры DOLBY используют эту информацию. Фиксированное распределение битрейта определяется исходя из свойств и характеристик чувствительности человеческого уха.

Различные стандарты

Dolby AC-1



- ◆ Простая психоакустическая модель
- ◆ 40 частотных подполос в семплировании при 32 кБит/с
- ◆ Пропорционально большее число частотных подполос при 44.1 кБит/с и 48 кБит/с
- ◆ Обычное сжатие для 512 кБит/с для стерео

Различные стандарты

Dolby AC-2

- ◆ Возможность варьирования распределения битрейта
- ◆ Теперь декодер требует копии психоакустической модели
- ◆ Encoded spectral envelope
- ◆ Backward adaptive bit allocation mode
- ◆ Высокое (hi-fi) качество звука при 256 кБит/с
- ◆ Не подходит для приложений вещания: кодер не может менять модель, не меняя декодера
- ◆ Обычное кодирование в компьютерных аудиокартах

Различные стандарты

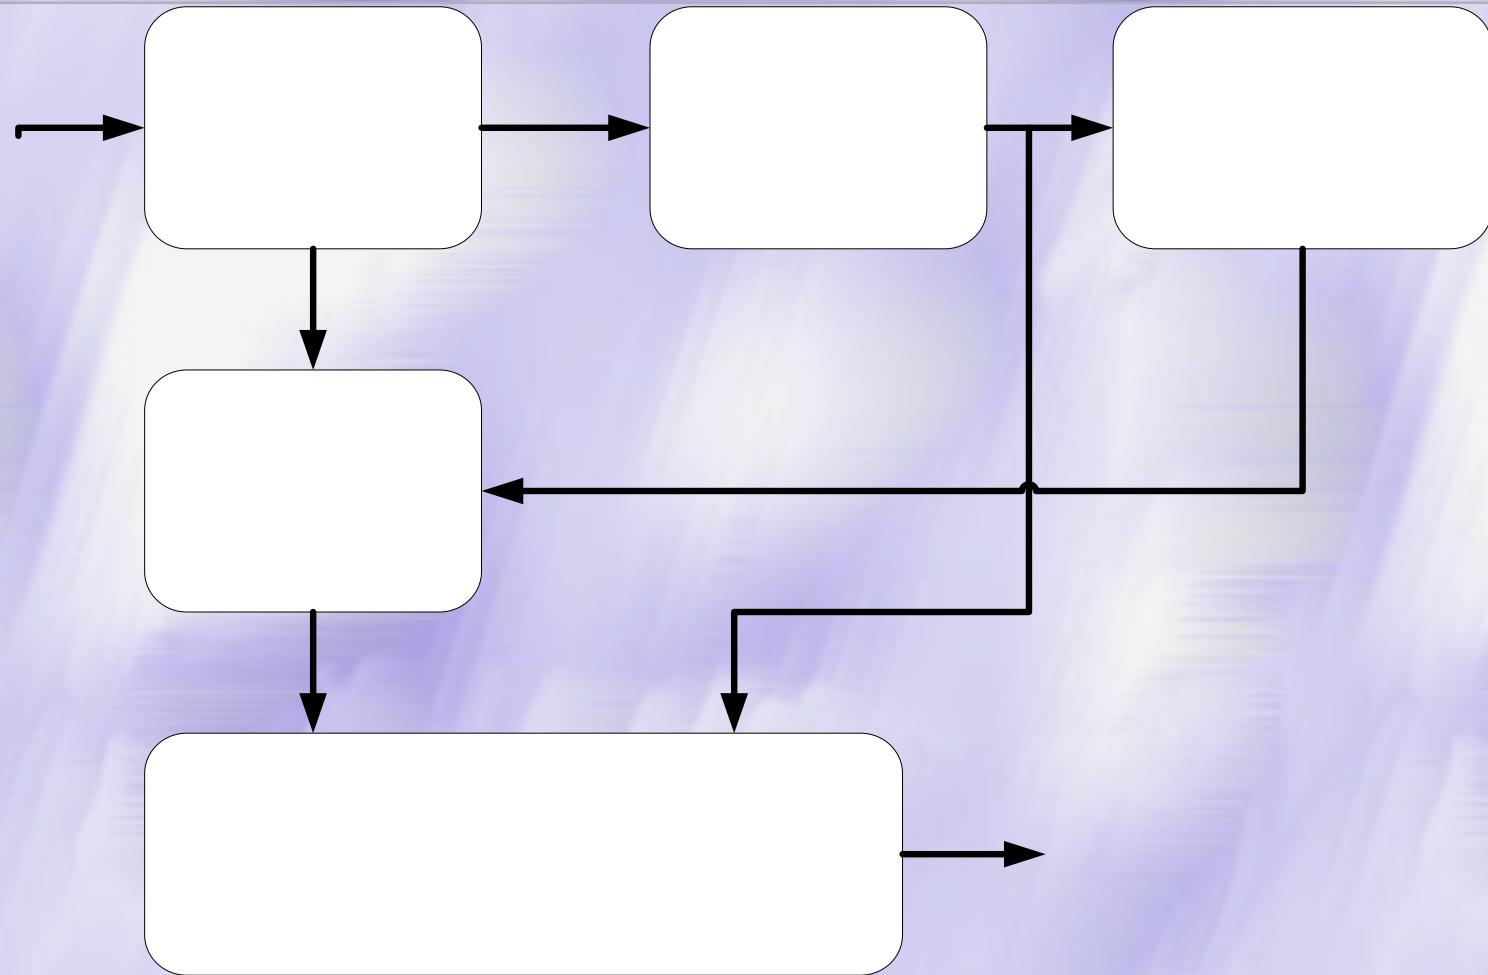
Dolby AC-3

Может кодировать от 1 до 5.1 каналов исходного звука из представления PCM в закодированный поток от 32 кБит/с до 640 кБит/с. Поддержка зависимости от ширины частотной полосы исходного сигнала

Использование смешанного режима:
backward/forward adaptive bit allocation. Любая информация модификации модели кодируется во фрейме.

Используется в высокоточных АТВ-стандартах. Алгоритм AC-3 достигает высокой степени сжатия путем грубого квантования представления частотной полосы аудиосигнала.

AC-3 (схема кодирования)



AC-3 кодирование



Первый шаг в кодировании – это преобразование представления аудио из PCM семплов в последователь блоков частотных коэффициентов. Это происходит при анализе банком фильтров. Из перекрывающихся блоков по 512 семплов выделяется временное окно и переводится в частотную область.

AC-3 кодирование



Из-за перекрытия блоков, каждый сэмпл представлен в двух последовательных преобразованных блоках. Представление частотной области может быть урезано до степени двойки, так что в каждом блоке будет содержаться 256 частотных коэффициентов.

AC-3 кодирование



Каждый частотный коэффициент представляется в формат с плавающей точкой. Последовательности порядков образуют грубое представление спектра сигнала, которое называется спектральная огибающая. Она используется центральной процедурой размещения битов, которая определяет, сколько битов нужно использовать для кодирования каждой мантиссы.

AC-3 кодирование



Спектральная огибающая и грубо квантованные мантиссы для 6 аудиоблоков (1536 семплов) кодируются в один AC-3 фрейм. Поток AC-3 представляет собой последовательность AC-3 фреймов.

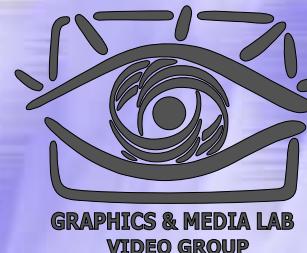
AC-3

кодирование (чего нет в схеме)



- ◆ Фреймовый заголовок
- ◆ Коды обнаружения ошибок
- ◆ Анализ банка фильтров
- ◆ Спектральная огибающая
- ◆ Размещение битов
- ◆ На высоких частотах каналы могут использовать общую информацию
- ◆ Matrixing (в двухканальном режиме)

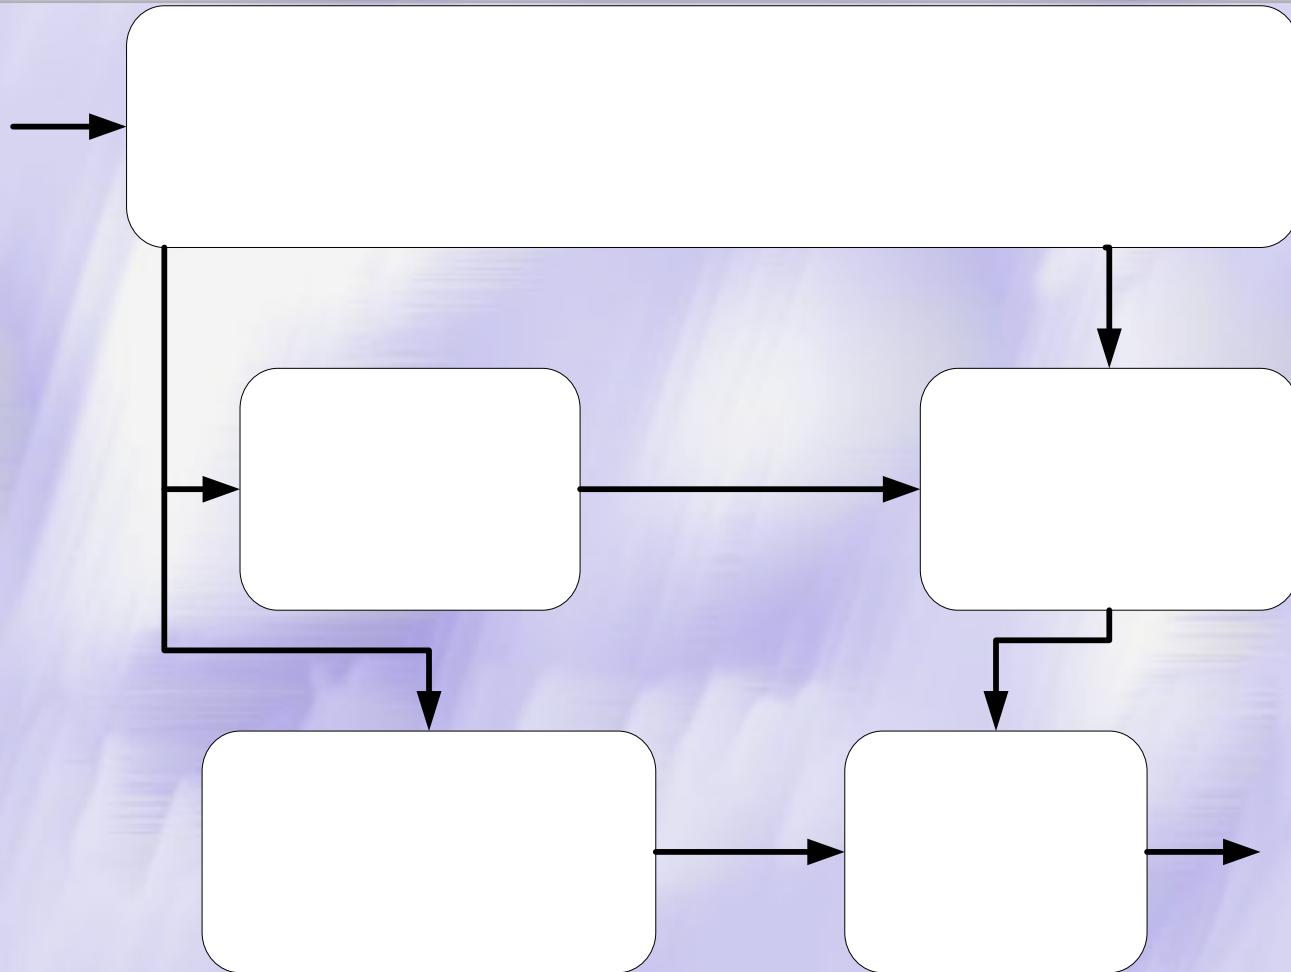
AC-3 (декодирование)



Процесс декодирования обратный к процессу кодирования. Декодер должен синхронизироваться по входному потоку, контролировать ошибки, преобразовывать разные типы данных, таких как закодированная спектральная огибающая и квантованные мантиссы. Из спектральной огибающей получаются порядки. Полученные плавающие числа преобразуются обратно во временную область.

AC-3

(схема декодирования)



AC-3

(чего нет в схеме декодирования)



- ◆ «Приглушение» ошибок при их обнаружении
- ◆ Высокочастотные каналы, которые были склеены разъединяются
- ◆ Dematrixing
- ◆ Разрешение синтезированного банка фильтров должно динамически изменяться аналогично процессу кодирования

ГИБРИДНОЕ СЖАТИЕ АУДИО

Недостатки традиционной схемы кодирования



◆ Кодирование формы волны

Сигналы с разной формой волны могут звучать одинаково:

- Шумовые сигналы
- Инвертированный сигнал
- Смещенный сигнал

◆ Независимое кодирования фреймов

- Музыка – совокупность повторяющихся видеоизменяющихся звуков

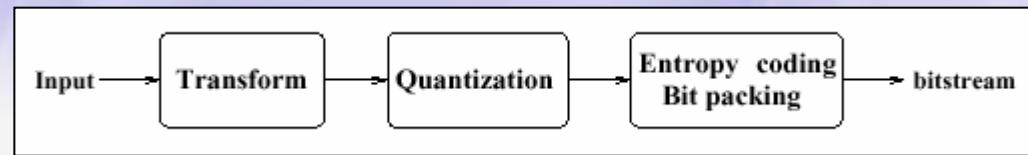
Гибридный кодер: идеи

- ◆ Разделение сигнала на три компоненты и использование разных типов кодирования в зависимости от специфики компоненты:
 - Гармоническую, используя преобразования, хорошо локализирующие частоты, основанные на Фурье
 - Ударные, используя Вейвлет преобразование, имеющее лучшую временную локализацию
 - Шумовую, используя кодирования энергетических огибающих спектра

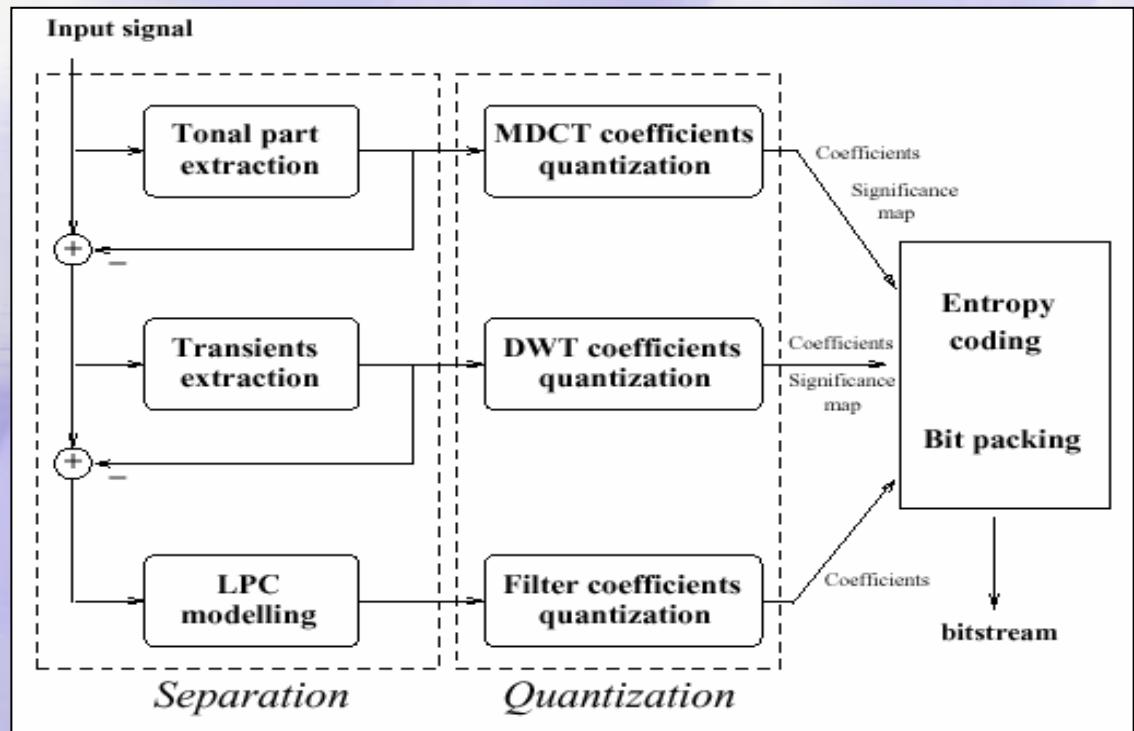
Схема гибридного и обычного аудио-кодера



Обычный
аудио-кодер



Пример
гибридного
кодека



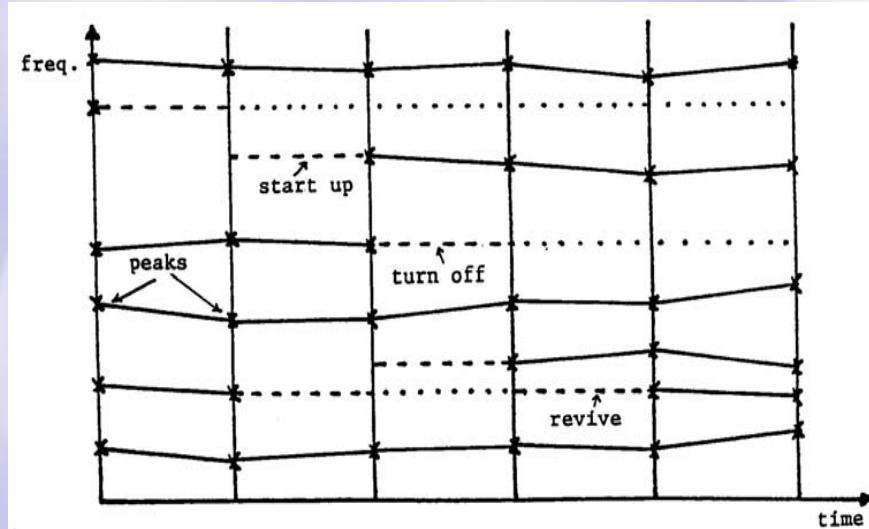
Гибридный кодер: подходы к гармонической компоненте



GRAPHICS & MEDIA LAB
VIDEO GROUP

- ◆ Представление, основанное на MDCT-маске:
 - Гармоника –локально стационарная по времени выделяющаяся часть MDCT-квазиспектра
 - Обнуление не ‘гармонических’ коэффициентов
 - Традиционное сжатие гармонической части

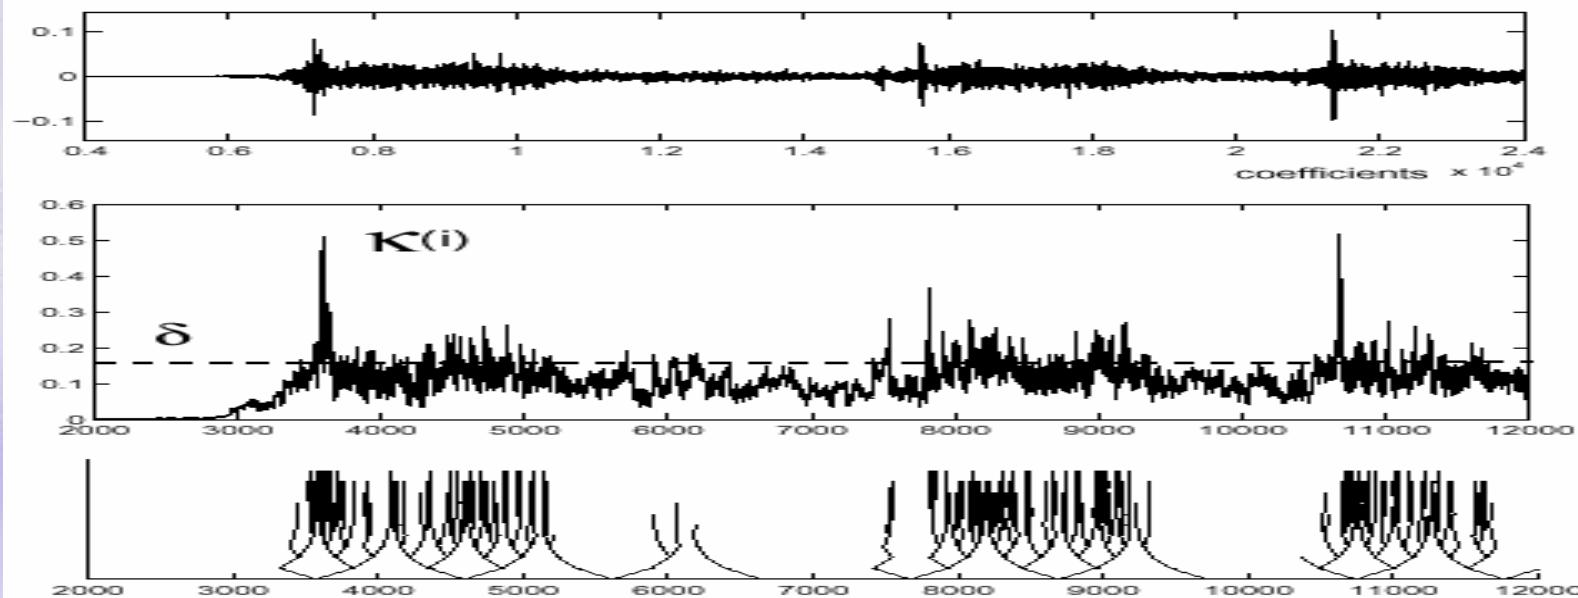
- ◆ Векторное представление и сжатие гармоник:
 - При восстановлении используется интерполяция



Гибридный кодер: переходные сигналы (удары)



- ◆ Выделение высоко амплитудных выбросов в сигнале с удаленными гармониками
- ◆ Разложение и сжатие на основе одномерных ортогональных вейвлетов



Гибридный кодер: представление остатка



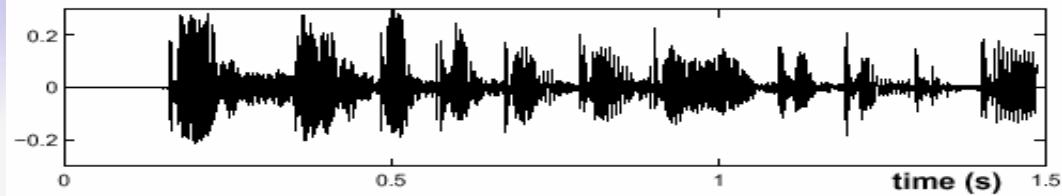
Остаток = Сигнал – Гармоники – Переходные

- Гипотеза: остаток = шумовой сигнал
- Для кодирования шума используются LPC
кодирование спектральной огибающей
- Для реконструкции используется фильтрация
белого шума

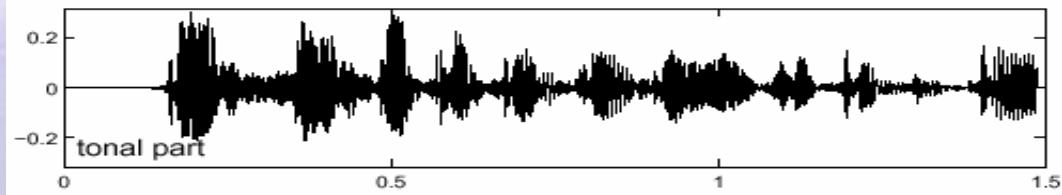
Компоненты: формы сигнала



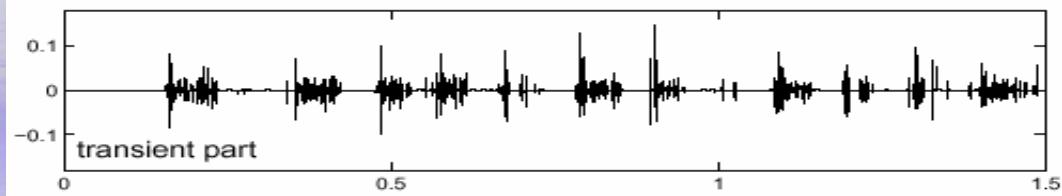
Сигнал



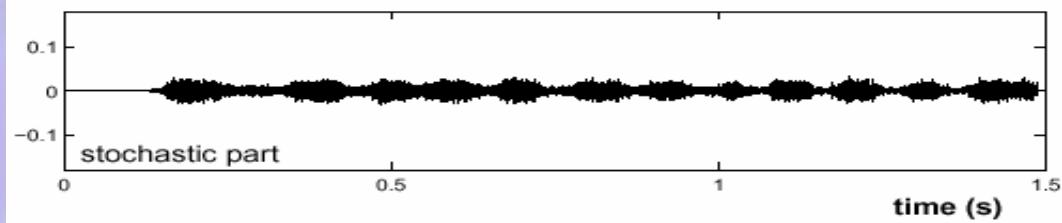
Гармоники



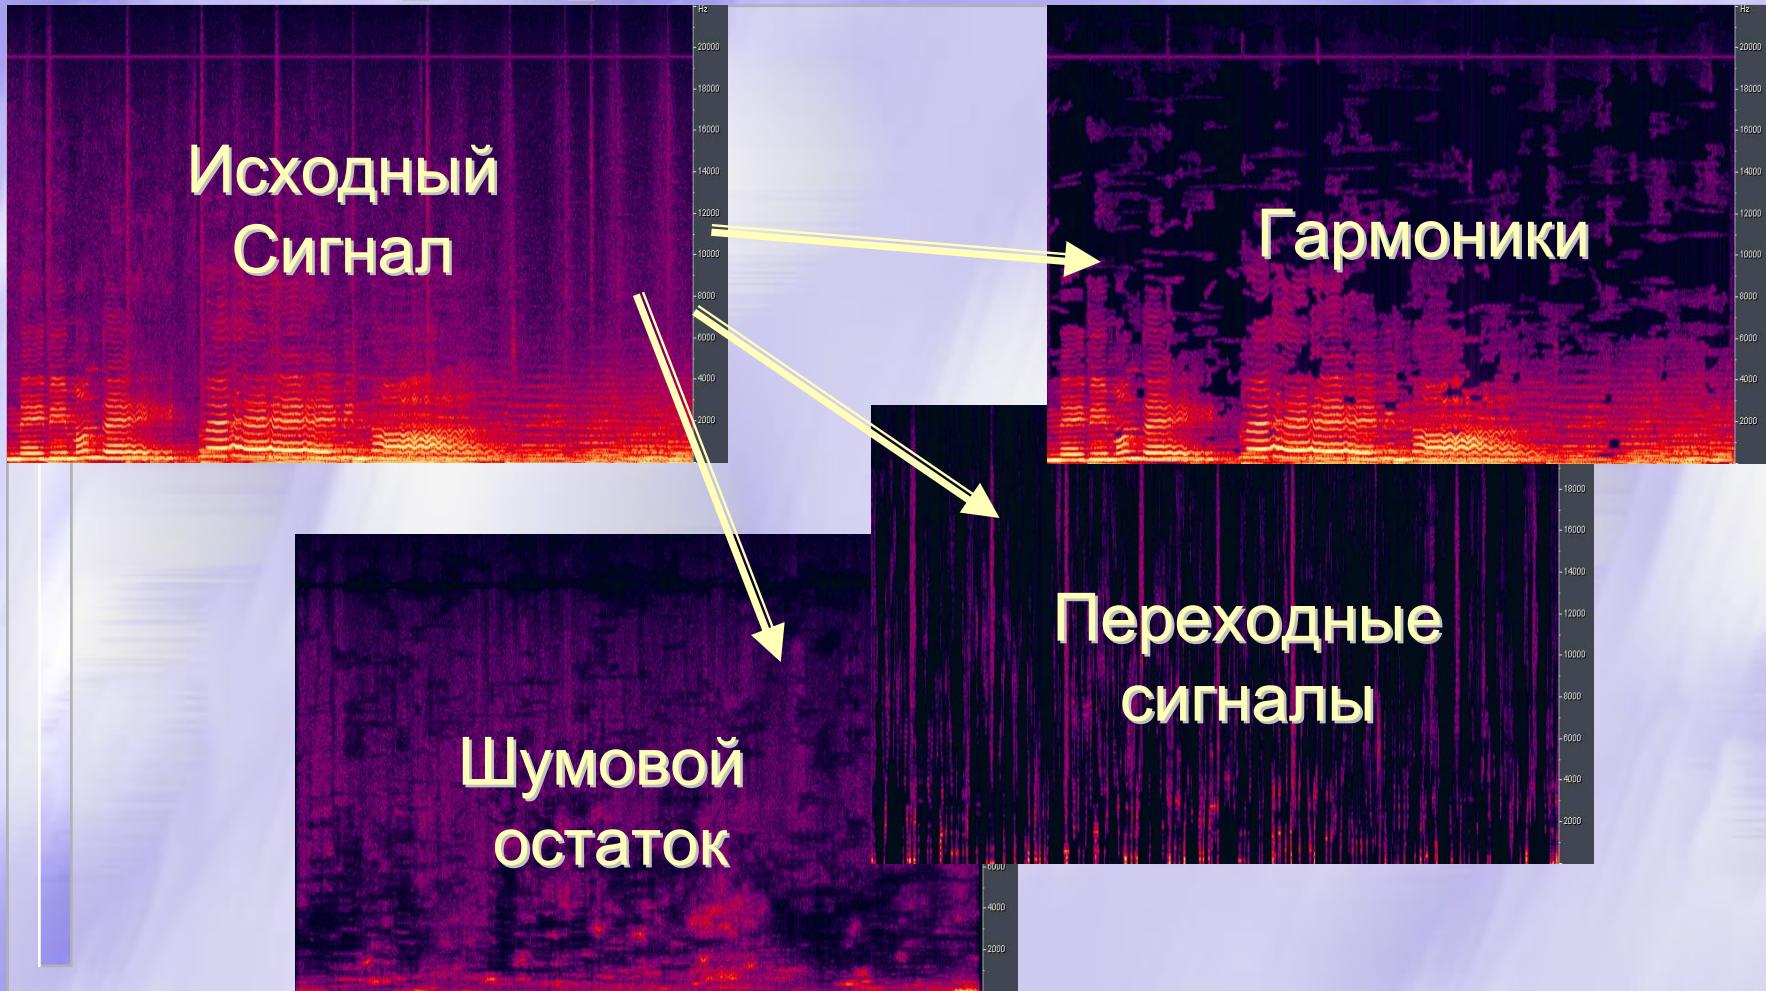
Переходная
компоненты



Шумовой
остаток



Компоненты: спектрограммы



Гибридное кодирование: Выводы

- ◆ Преимущества:
 - Адаптивное кодирование, зависящее от конкретных свойств компонент
- ◆ Недостатки:
 - Избыточное представление
 - Аддитивный синтез шума – не устойчивость при итерационном применении
 - Ориентация на большое сжатие, но в настоящее время, абсолютно прозрачное кодирования с CD-качеством не достигнуто

СЖАТИЕ РЕЧИ

*Специфика
Физическая и математическая модели
Пример кодека*

Сжатие речи: Специфика

◆ Музыка:

- Стандартный формат для представления музыки **Stereo 16 bit 44KHz** позволяет передавать весь диапазон слышимых человеком частот ~ 20Гц-20КГц
- Несжатый поток: 1408 kb
- Прозрачное кодирование (MP3): 128 kb (~10 раз)

◆ Речь:

- Узкий частотный диапазон, реально от 70 до 3КГц, для передачи информативной части голоса достаточно: **Mono 8 bit 8KHz**
- Несжатый поток: 64 kb
- Прозрачное кодирование (GSM 6.1): 8 kb (8 раз)

Критерии кодирования речи

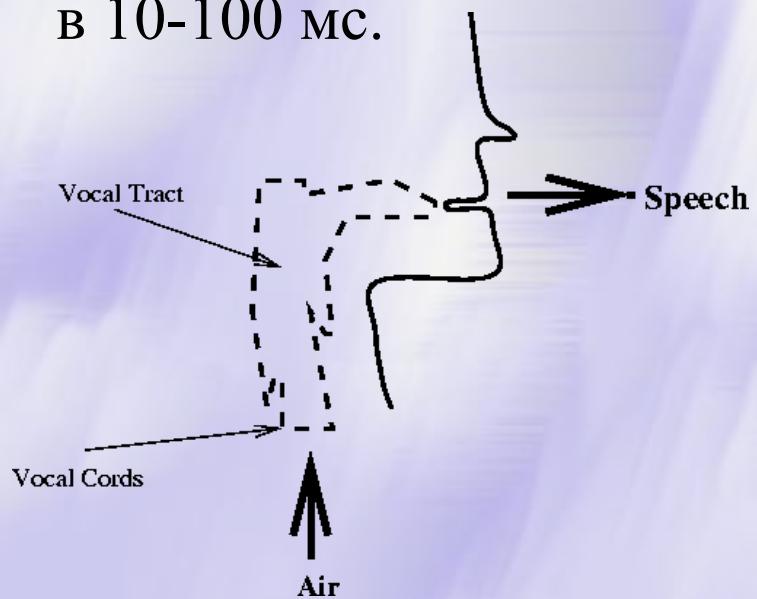


- ◆ Скорость передачи данных:
 - ◆ Фонематическая скорость: примерно 50 б/с
 - ◆ Познавательная скорость: примерно 400 б/с
 - ◆ Как к этим скоростям прилизиться?
- ◆ Понятность
- ◆ Естественность, качественность
- ◆ Вычислительная сложность
- ◆ Сложность реализации
- ◆ Максимальное время между получением замера и выходом закодированного значения
- ◆ Устойчивость к ошибкам

Физическая модель речи

- ◆ Гласные звуки заставляют вибраторовать звуковой тракт. Скорость вибрации определяет *основной тон* голоса. Женщины и дети имеют высокий основной тон, мужчины низкий.
- ◆ Согласные оставляют голосовые связки стационарно открытыми

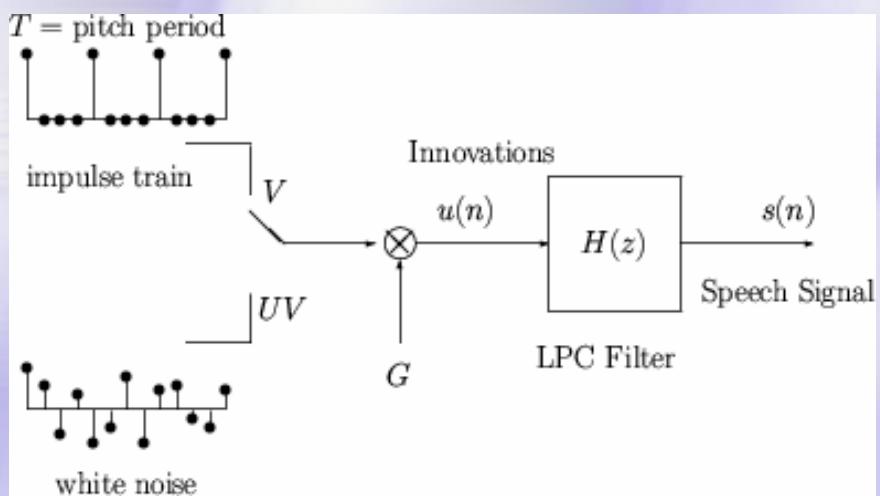
- ◆ При смене звука меняется форма речевого тракта. Смена происходит обычно раз в 10-100 мс.



Математическая модель речи



- ◆ Сигнал разбивается на фреймы, внутри которых считается что физическая модель постоянна
- ◆ Продолжительность фрейма обычно 20 мс, что соответствует 160 сэмплам



$$H(z) = \frac{1}{1 + a_1z^{-1} + a_2z^{-2} + \dots + a_{10}z^{-10}}$$

$$s(n) + \sum_{i=1}^{10} a_i s(n-i) = u(n)$$

13 параметров/фрейм:

$$\mathbf{A} = (a_1, a_2, a_3, a_4, a_5, a_6, a_7, a_8, a_9, a_{10}, G, V/UV, T)$$

Сжатие речи: пример 2.4 kb LPC Vocoder

- ◆ Для повышения устойчивости к квантованию, вместо LPC используют LSP(line spectrum pair), получающиеся преобразованием LPC
- ◆ Распределение бит:

Parameter Name	Parameter Notation	Rate (bits/frame)
LPC (LSP)	$\{a_k\}_{k=1}^{10}$ ($\{\omega_k\}_{k=1}^{10}$)	34
Gain	G	7
Voiced/Unvoiced & Period	$V/UV, T$	7
Total		48

LSP	No. of Bits
ω_1	3
ω_2	4
ω_3	4
ω_4	4
ω_5	4
ω_6	3
ω_7	3
ω_8	3
ω_9	3
ω_{10}	3
Total	34

V/UV	T	Encoded Value
UV	—	0
V	20	1
V	21	2
V	22	3
V	23	4
:	:	:
:	:	:
V	146	127