

画像情報特論 (5)

- デジタル圧縮とメディア表現 (2)

音声・オーディオ、SMIL、グラフィクス

情報ネットワーク専攻 甲藤二郎



E-Mail: katto@waseda.jp

音声・オーディオ圧縮の 原理

デジタルオーディオ

• キャプチャ & 圧縮


マイク サウンドキャプチャ




典型的なサンプリングレート

音声：
8 kHz、8 ビット

オーディオ：
22.5, 44.1, 48 kHz、16 ビット



音声・オーディオ符号化の歴史




音声符号化 (1)

• 音声合成モデル

以下のパラメータを推定 (予測) して送信する


- パルス列 (有声・無声)
- ピッチ周期
- ゲイン
- LPCパラメータ



音声符号化 (2)

CELP: Code Excitation Linear Prediction

- CELP



音声符号化 (3)

LPC: Linear Prediction Coding


• LPC 分析 (線形予測分析) : 声道モデル

$$s(n) = \sum_{k=1}^p a_k s(n-k) + G \cdot u(n)$$

過去の k 個のサンプル値から線形予測

(注) 通常、画像のモデルでは雑音と扱う

$s(n)$: 音声サンプル
 a_k : LPC係数
 p : LPC分析次数
 G : 励振ゲイン
 $u(n)$: 正規化励振項



予測誤差二乗平均の最小化

$$\frac{\partial e(n)}{\partial a_k} = 0$$

$$\sum_{k=1}^p r_n(i-k) \hat{a}_k = r_n(i)$$

$r(k)$: 自己相関係数
 \hat{a}_k : 推定LPC係数

自己相関法 (Durbinのアルゴリズム)

音声符号化 (4)


• ベクトル量子化：音源パルス列

励振ベクトルとゲインの探索：

$$d = \|x - gAc\| \rightarrow \min$$


となる励振ベクトルとゲインを探索

さまざまな探索手法 ...



励振ベクトル ベクトル量子化
ゲイン スカラー量子化
(声道パラメータ ベクトル量子化)


d : ひずみ
 x : 目標ベクトル (入力音声)
 A : LPC係数行列
 g : ゲイン
 c : 励振ベクトル (パルス列)



音声符号化 (5)

•ベクトル量子化 : コードブックの学習 (1)

K-平均アルゴリズム (一般化 Lloyd アルゴリズム)




欠点: 最終結果が初期ベクトルに依存

音声符号化 (6)


ベクトル量子化 : コードブックの学習 (2)

LBG アルゴリズム



オーディオ符号化 (1)

• オーディオ符号化の基本




- 周波数分割、周波数分析: FFT、サブバンド分割 (QMF)、MDCT
- 心理聴覚分析: 絶対閾値とマスキング
- 量子化、エントロピー符号化: スカラー量子化とハフマン符号


オーディオ符号化 (2)

• 心理聴覚分析

絶対閾値：人間は絶対可聴閾値よりも大きな音しか知覚できない




マスキング (相対閾値)：大きな音の周波数の近傍の小さな音の周波数は知覚できない




オーディオ符号化 (3)

- MP3 (MPEG-1 Layer III)




cf. Layer I, II



オーディオ符号化 (4)


• MPEG-2 AAC



- 時間領域ノイズ整形 (for transient signals): 一部のMDCT係数を時系列とみなして線形予測 (LPC) 分析。振幅の大きい部分に量子化雑音が集中する (ノイズ整形)。
- 予測 (for stationary signals): MDCT係数毎に、過去2フレームのMDCT係数から予測。入力が定常的な場合に有効。

オーディオ符号化 (5)

• Twin VQ



- LPC分析、ピッチ・スペクトル包絡・電力分析：MDCT係数の平坦化。ベクトル量子化のコードブック削減。
- インターリーブベクトル量子化：適応量子化に替わるひずみの最小化手法。傾向の似た変換係数のグルーピング。

音声とオーディオ、ビデオの対比

- 音声符号化

PCM 波形符号化 分析合成符号化 (音声合成モデル)

- オーディオ符号化、ビデオ符号化

PCM 波形符号化

オーディオ合成モデル: 楽器 (+ ボーカル)

ビデオ合成モデル: コンピュータグラフィックス?


分析合成手法の試み (ブレイクスルーにはなっていない):

オーディオ符号化: 音源分離

ビデオ符号化: 知的符号化 (顔画像アニメーション)

SMIL

コンテンツの進化



SMIL

* Synchronized Multimedia Integration Language


・ ストリーミングのためのレイアウト記述言語

```
<smil>
<head>
  <layout>
    レイアウト記述
  </layout>
</head>
<body>
  <par>
    メディア記述
  </par>
</body>
</smil>
```



* XML ベース... HTML に慣れていれば習得は簡単

レイアウト記述



表示画面

```
<root-layout width="500" height="400"/>  
<region id="a" top="50" left="50"  
        width="100" height="80" />  
<region id="b" top="200" left="50"  
        width="400" height="200" />
```

レイアウト記述

メディア記述

```
<par>
  <video region="b" src="rtsp://www.foo.ac.jp/guide.sdp" />
  <seq>
    
    
    
  </seq>
</par>
```

ストリーミング

<par> メディア1, メディア2, ... </par>

複数メディアの「**並列**」再生

<seq> メディア1, メディア2, ... </seq>

複数メディアの「**逐次**」再生

<video>, <audio>, , ...



各種メディアタグ

グラフィクス

VRML


* Virtual Reality Modeling Language

・ 三次元CGの記述フォーマット



VRML記述

```
Transform {  
  Transform {  
    translation 15 10 0  
    Shape {  
      geometry Box 2 2 2  
    }  
  }  
  Transform {  
    translation 0 0 -1  
    Shape {  
      geometry Cylinder  
    }  
  }  
}  
...
```



シーン合成

VRML 2.0 のノード一覧

グループ:

Billboard
Group
Inline
LOD
Switch
Transform

形状:

Shape
Box
Cone
Cylinder
ElevationGrid
Extrusion
IndexedFaceSet
IndexedLineSet
PointSet
Sphere
Text

形状特性:

Coordinate
Color
Normal
TextureCoordinate

アピアランス:

Appearance
Material
ImageTexture
PixelTexture
MovieTexture
TextureTransform

光源、視点:

DirectionalLight
PointLight
SpotLight
Viewpoint

センサ:

Anchor
Collision
CylinderSensor
PlaneSensor
ProximitySensor
SphereSensor
TimeSensor
TouchSensor
VisibilitySensor


インタポレーター:

ColorInterpolator
CoordinateInterpolator
NormalInterpolator
OrientationInterpolator
PositionInterpolator
ScalarInterpolator

その他:

AudioClip
Background
Fog
FontStyle
NavigationInfo
Script
Sound
WorldInfo

MPEG-4 Systems/SNHC




目的: 従来の AV 系システムへの CG、コンピュータミュージックの取り込み

(1) シーン記述 (MPEG4 BIFS)


* Binary Format for Scene



VRMLのストリーミング拡張



(2) 顔画像アニメーション



顔画像パラメータ:

FAP (Facial Animation Parameter)

顔の基本的な動きの表現。

FAP 初期値で基本的な顔を転送。以下は差分を転送 (ストリーミング)。

FAP を与えない場合には「ニュートラルフェイス」を使用。

FDP (Facial Definition Parameter)

FAP で与えられる一般的な顔画像のカスタマイズ。

セッション開始時に転送 (オプション)。

(3) 人体アニメーション



人体パラメータ:

BAP (Body Animation Parameter)

人体の基本的な動きの表現。

BAP 初期値で基本的な人体を転送、以下は差分を転送 (ストリーミング)。


BAP を与えない場合には「デフォルト人体」を使用。

BDP (Body Definition Parameter)

BAP で与えられる一般的な人体のカスタマイズ。

セッション開始時に転送 (オプション)。

(4) 三次元メッシュ符号化




三次元メッシュ:

ポリゴンの頂点座標 + 頂点間の接続情報 + 各種特性情報

三次元メッシュ符号化:

上記の三次元メッシュ記述の圧縮


メッシュ符号化のブロック図



三段階の符号化:

1. ポリゴン頂点の接続情報 (**connectivity**) の符号化
2. ポリゴン頂点の三次元座標 (**geometry**) の符号化
3. 色、法線、テクスチャ座標などの特性 (**property**) の符号化

接続情報の符号化 [1]



三次元メッシュ (A)



一頂点の選択と
頂点木の作成 (C)



二次元平面に展開 (E)
(一番外側が選択頂点)



デュアルグラフ (双対木)
の作成 (F)




双対木の符号化
(次ページ)

接続情報の符号化 [2]

ポリゴン


接続関係の符号化



ルート (開始線)

符号化結果

符号化ルール




現在のエッジ

頂点座標の符号化


(1) ポリゴンによる予測

符号化対象の頂点を、ポリゴンを構成する頂点の一つと仮定して、座標を外挿予測。
予測誤差を符号化。



(2) 平均による予測

符号化対象の頂点を、それを囲むポリゴンの重心と仮定して、座標を内挿予測。
予測誤差を符号化。



(5) 合成オーディオ



オーディオ合成パラメータ:

SAOL (Structured Audio Orchestra Language):

楽器の特徴、信号処理方法を記述する言語 ... 音源物理モデルに相当。

SASL (Structured Audio Score Language):

楽譜情報を記述するフォーマット ... MIDI に相当。

SABSF (SA Bank Sample Format):

音源波形をそのまま使うフォーマット ... PCM 音源に相当。

関連情報