

言語情報処理論

2007-11-28

峯松 信明

東京大学大学院新領域創成科学研究科

前回のおさらい

📌 フーリエ級数展開について + α

- 🕒 サイン君 + コサイン君 → サイン君
- 🕒 フーリエ級数展開を使った波形変形 ～フィルタリング～

📌 分節的特徴と韻律的特徴, 及びその抽出方法

- 🕒 音声生成とソース・フィルターモデル
- 🕒 スペクトル包絡特性の推定方法 ～ケプストラム法とLPC～
- 🕒 基本周波数の推定方法 ～ケプストラム法と自己相関～

📌 音声の分析合成系とその応用 ～音声変形～

- 🕒 高性能分析合成系 STRAIGHT
- 🕒 感情・年齢・性別・音韻, 色んなものを変形しちゃいます


📌 音声合成の原理と波形編集型音声合成

📌 まとめ

サイン君+コサイン君→サイン君

合成の公式

$$a \sin \theta + b \cos \theta = \sqrt{a^2 + b^2} \sin(\theta + \phi), \quad \phi = \tan^{-1} \frac{b}{a}$$



コサイン君, さようなら・・・

$$y_s = s_1 \sin(2\pi t) + s_2 \sin(2\pi 2t) + s_3 \sin(2\pi 3t) + s_4 \sin(2\pi 4t) + s_5 \sin(2\pi 5t)$$

$$y_c = c_1 \cos(2\pi t) + c_2 \cos(2\pi 2t) + c_3 \cos(2\pi 3t) + c_4 \cos(2\pi 4t) + c_5 \cos(2\pi 5t)$$

1Hz

2Hz


3Hz

4Hz


5Hz

$$y = y_s + y_c$$

$$= S_1 \sin(2\pi t + \phi_1) + S_2 \sin(2\pi 2t + \phi_2) + S_3 \sin(2\pi 3t + \phi_3) + \dots$$



$$y = \sin(2\pi 2t)$$




$$y = \sin(2\pi 2t + \frac{\pi}{3})$$

合成波 $\Leftrightarrow$ 要素波の足し合わせ


$$y \leftrightarrow (S_1, S_2, S_3, \dots, S_N)$$

- 合成波を要素波群に分解し, S_i の値を操作して元に戻す。
- フィルタリング (細かな振動だけ, 大まかな振動だけ, を取り出す)
- イコライザー



この図がちょっと違って見える？

定常波の生成 $\Leftrightarrow$ フーリエ解析&重み操作&重ね合わせ




- 音響管の形に基づいて生き残る or 死に絶えるサイン波がある
- スペクトル包絡の特性さえ与えられれば、フーリエ解析で可能
- 調音器官の形を指定するのか／所望の音響特性を指定するのか

音声の音響分析







音声（母音）生成のソース・フィルタモデル

音声 → 音源の特性 + 声道フィルタの特性

$$y \leftrightarrow (S_1, S_2, S_3, \dots, S_N)$$



$$S(\omega) = G(\omega)H(\omega)R(\omega)$$




音声の音響分析


音声（母音）生成のソース・フィルタモデル

● 対数スペクトル特性においては、音源特性 + 声道特性


音




音




音変形



音声波形を使って推定できるもの



声道特性の抽出技術




パラメトリックな手法

- モデルを仮定し，観測量がそのモデルから生成されたと解釈
- 既存の観測量が最も確率高く得られるモデルパラメータを推定
 - 最尤推定法
- 長所と短所
 - モデルによる制約がある分，推定にかかる演算量が少ない。
 - モデルが不適切であれば，全てが台無し。
- 線形予測分析（LPC, Linear Predictive Coding）

ノン・パラメトリックな手法


- モデルの仮定無し。あらゆる信号を解析可能
- 長所と短所
 - 自由度高，演算量高
- ケプストラム分析




声道特性の抽出技術

ケプストラム法

- フーリエ変換による LPF を用いたスペクトルスムージング
- スペクトルの大局的な成分と局所的な成分との分割
- スペクトル包絡と基本周波数の同時推定





DFT = Discrete Fourier Transform
IDFT = Inverse DFT



声道特性の抽出技術

ケプストラム法

● スペクトル包絡情報と基本周波数情報の分離



声道特性の抽出技術

線形予測分析（時間軸でのLPC）

- 時刻 t の信号 s_t を過去のサンプルより線形に予測（モデル化）



- $s_t \leftarrow s'_t = \alpha_1 s_{t-1} + \alpha_2 s_{t-2} + \dots + \alpha_p s_{t-p}$ （一種のFIRフィルタ）

- 予測された信号と観測された信号間の誤差を最小化

- $\sum_t |s'_t - s_t|^2$ の最小化

- ある時間区間（例えば250msec）の間は α_n は不変として、その区間において誤差が最小となるように α_n を求める。（誤差＝**残差**）

- 下記の方程式へ帰着（ $r_\tau = \frac{1}{N} \sum_{t=0}^{N-1-\tau} s_t s_{t+\tau}$, 自己相関関数）





$$\begin{bmatrix} r_0 & r_1 & \cdots & r_{p-1} \\ r_1 & r_0 & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & r_1 \\ r_{p-1} & \cdots & r_1 & r_0 \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \cdot \\ \cdot \\ \alpha_p \end{bmatrix} = - \begin{bmatrix} r_1 \\ r_2 \\ \cdot \\ \cdot \\ r_p \end{bmatrix}$$

音源特性の抽出技術

時系列信号に対する周期構造の抽出

● = 自己相関のピークの検出 ($r_\tau = \frac{1}{N} \sum_{t=0}^{N-1-\tau} s_t s_{t+\tau}$)



● 音声に対して反転フィルターを通して出力される音＝残差信号

音の心理量とその物理量

音の心理的四要素と対象となる物理量

● 心理量と物理量のマッピング

● 音の高さ

● 波形における周期の長短＝高さの低高

● 音の長さ

● 波形を見れば一目瞭然

● 音の強さ




● 波形振幅に反映される。

● 音色

● 音楽的には高・長・強以外の要素を音色と定義したりする。

● 耳が位相に鈍感であることを考慮し、対数スペクトル包絡


● 各倍音のエネルギーの強さ



音声によって伝搬される情報

言語・パラ言語・非言語情報

- 語彙（意味）・テキストの情報
 - 制御可能／動的
- 話者の感情・意図・態度
 - 制御可能／動的
- 話者の個人性・性別・年齢・健康状態
 - 制御不可能／静的



分節的特徴と超分節的特徴

- Segmental features & Supra-segmental features
 - segment＝分節音＝所謂音素のこと
 - 音声を細かい言語単位（音素）に分割するために着眼する音響特性
 - スペクトル包絡特性
 - それよりも大きな単位で観測して初めて意味を持つ音響特性
 - 基本周波数パターン，パワーパターン，継続長→**韻律的**特徴

STRAIGHT

分析（再）合成技術

- 音声 → 分析 → 包絡 + 音源 → 包絡' + 音源' → 合成（分析⁻¹） → 音声
 - 音の音色 = スペクトル包絡
 - 音の高さ = 基本周波数
 - 音の強さ = 波形振幅
 - 音の長さ = （ある音素の）継続時間長
 - これらの特徴量を色々変形して、再合成（分析と逆の処理）する

STRAIGHT


- Speech Transformation and Representation based on Adaptive Interpolation of weighted spectrogram
 - 適応的に内挿されたスペクトル表現
 - 河原英紀@和歌山大学システム工学部による開発
 - <http://www.wakayama-u.ac.jp/~kawahara/>



STRAIGHT

つまり、こうなります (SFT = 短時間フーリエ変換)


SFT-based spectrogram



STRAIGHT

ピッチに同期して窓を動かしてあげると・・・


Complementary pitch-synchronous Gaussian window removes the repetitive structure in the time domain



音声モーフィング（変形）

感情を変えてみる。平静／怒／悲／喜

- 音色・高さ・長さ・時間長のどこがどう変わっているのか？
- 操作対象の物理量に思いを馳せながら聞きましょう。



音声モーフィング（変形）

性別・年齢を変えてみる 2。

読み上げ音声に対する分析再合成

周波数軸： x 倍 $x > 1$ = フォルマント上昇


原音声

再合成音声（変形無し）

再合成音声（ F_0 ：2倍，周波数軸：1.25倍）

再合成音声（ F_0 ：3倍，周波数軸：1.44倍）

再合成音声（ F_0 ：0.5倍，周波数軸：0.8倍）



音声モーフィング (変形)

普通の声歌声に変えてみる。

- 歌声音声に対する分析再合成
 - 女声の持続母音/a/ (440Hz, 原音声)
 - 再合成音声 (変換無し)
 - 再合成音声 (ソプラノ化)
 - 再合成音声 (アルト化)
 - 男声による旋律/a/ (原音声)
 - 再合成音声 (変換無し, バリトンとして使用)
 - 再合成音声 (テノール化)
 - 再合成音声 (バス化)
- 出来上がった5声による演奏 (元は2音声)

音声モーフィング（変形）

何から何に変わっているのか，当てて下さい。

A

B

C

本日のメニュー

音声合成の原理と波形編集型音声合成

- 言語処理／音韻処理／波形処理
- 音韻処理といっても結構面倒・・・

音声認識セミナーより


- 音声特徴の分析と照合
- 隠れマルコフモデル (HMM)
- サブワードモデルを用いた音声認識
- 認識文法を用いた連続音声認識
- 日本語ディクテーションにおける基礎技術
- ビデオ鑑賞

宿題

まとめ


世界最古の音声合成器

von Kempelenの機械式音声合成器




世界最古の音声合成器

von Kempelenの機械式音声合成器



テキスト音声合成

まずは概要から



テキスト音声合成

テキスト音声合成とは

● 任意の漢字仮名混じり文を入力として音声波形を生成する技術

何が必要？

● 言語処理（文解析）

● 形態素解析器によるテキストの単語への区分

● 品詞，統語情報，係り受けの推定（意味，談話情報は難）

● 音韻処理

● 文解析結果を実際の発音の表記へと変換

● 最終的に「読み」の情報と「アクセント」の情報を推定

● 音響処理（波形生成）

● 発音表記に従って，音声波形を生成する。

● モデルベースの方法，波形素片をペタペタ貼付ける方法

● 以下，言語処理が終わった後の過程を考えます

音韻処理

音韻性に関する処理（分節的特徴）

- 音素表記の生成
 - 音訓, 長音化, 促音化, 連濁
- 単音表記の生成（異音化処理）
 - 無声化, 鼻音化, 撥音

韻律性に関する処理（超分節的・韻律的特徴）

- 単語レベルの処理
 - アクセント型, 複合語（接頭語, 接尾語）
- 句レベルの処理
 - アクセント結合
- 文レベルの処理
 - 強調, フレージング

● **単語分割語にどれだけの処理をしているのか確認せよ**

音素表記の生成

音読み・訓読み

- 文法情報：工夫する（サ変動詞），強力な（形容動詞）
- 意味素性：十分以内（数詞＋以内），関東平野（地名＋平野）
- 係り受け：講演を行なった / 方程式の根

助詞

- は→ワ，へ→エ

長音化

- 消耗（オに続くウ），映画（エに続くイ），大阪（同一母音）

促音化（特に数詞＋助数詞）

- 一卷，一本

連濁（カ，サ，タ，ハ行の語頭清音の濁音化）

- 目覚まし時計，遅咲き，ペン先

数詞＋助数詞

数詞の読み

● 03-5841-6662, 123,456円

促音化

● 一本→イッポン, 1cm→イッセンチ

濁音化（連濁）

● 三本→サンボン, 三階→サンガイ

特例

● 一日（ツイタチ）, 二日（フツカ）

単音表記の生成（異音化処理）

母音無声化（無声子音に挟まれたイとウ）

● アシカ, エンピツ, スキヤキ, シチ

鼻音化

● カブシキガイシャ

撥音

● ネンバンガン

● p, b, m の前（カンパン）, t, d, n の前（カンタン）

● k, g, ng の前（カンカク）, 語尾（カンザン）

記号・省略文字・未登録語


記号が入力されても某の音にしなければならない

- %, m, 1/s, などなど
- HMM, ICSLP, ICASSP, IT などなど
- 未知語
 - 氏名, 地名など
- 最終的には漢字毎のデフォルトの読み, デフォルトの単語アクセントでごまかすことになる。

単語アクセントとアクセント結合

nモーラ単語でn+1個のアクセント型が可能

● 基本周波数の落ちの直前のモーラ＝アクセント核



トモダチ フジサン イロガミ カガリビ オトート

アクセント結合

- アクセント核の移動

アル | ク (歩く) + マス → アルキマ | ス

- アクセント核の生起

ケイタイ (携帯) + デンワ (電話) → ケイタイデ | ンワ

- アクセント核の消失

ケ | イザイ (経済) + テキ (的) → ケイザイテキ

単語アクセントとアクセント結合

アクセント結合の規則化

- N_1 モーラ M_1 型アクセント単語と
- N_2 モーラ $\tilde{M}_2$ 型結合アクセント価をもつ後続語が接続
- N_c モーラ M_c 型アクセントとなる
 - アクセント価：接続後に伴い現れる核の位置を接続境界からのモーラ数で表現したもの。接続位置に核（落ち）があれば、0 価となる。

付属語アクセント結合規則

- あそぶ + ます → あそびます

複合名詞アクセント結合規則

- とうきょう + だいがく → とうきょうだいがく

接頭辞アクセント結合規則

- ぜん + せかい → ぜんせかい

単語アクセントとアクセント結合

(N_1 モーラ M_1 型 + N_2 モーラ $\tilde{M}_2$ 価 $\rightarrow N_c$ モーラ M_c 型)

(a) 付属語アクセント結合規則

結合様式	文節のアクセント型 M_c	
	$M_1 = 0$	$M_1 \neq 0$
(F1) 従属型	M_1	
(F2) 不完全支配型	$N_1 + \tilde{M}_2$	M_1
(F3) 融合型	M_1	$N_1 + \tilde{M}_2$
(F4) 支配型	$N_1 + \tilde{M}_2$	
(F5) 平板化型	0	

(b) 複合名詞アクセント結合規則

結合様式	後続名詞の性質	複合名詞 M_c
(C1) 保存型	$N_2 \geq 2, M_2 \neq 0, N_2^\dagger$	$N_1 + M_2$
(C2) 生起型	$N_2 \geq 2, M_2 = 0, N_2^\dagger$	$N_1 + 1$
(C3) 標準型	$N_2 \leq 2$	N_1
(C4) 平板型	$N_2 \leq 2$	0

(c) 接頭辞アクセント結合規則

結合様式	文節のアクセント型 M_c	
	$M_2 = 0, N_2^\dagger$	$M_2 \neq 0, N_2^\dagger$
(P1) 一体化型	0	$N_1 + M_2$
(P2) 自立語結合型	$N_1 + 1$	$N_1 + M_2$
(P3) 分離型	M_1	M_1 (and $N_1 + M_2$)
(P4) 混合型	$N_1 + 1$ (or) M_1	M_1 (and/or) $N_1 + M_2$

単語アクセントとアクセント結合

巡回的な規則適用

- おきる＋られる＋そーな＋ので
- おきられる＋そーな＋ので
- おきられそーな＋ので
- おきられそーなので

その他の考慮

- 音節内核移動規則
 - 撥音，促音，長母音，重母音などのモーラにアクセント核がくると，アクセント核は原則として1モーラ前にずれる。
- 無声化に伴う移動規則
 - 無声化した母音にアクセント核が来ると，アクセント核は原則として1モーラ前にずれる。

テキスト音声合成

テキスト音声合成とは

● 任意の漢字仮名混じり文を入力として音声波形を生成する技術

何が必要？

● 言語処理（文解析）

● 形態素解析器によるテキストの単語への区分

● 品詞，統語情報，係り受けの推定（意味，談話情報は難）

● 音韻処理

● 文解析結果を実際の発音の表記へと変換

● 最終的に「読み」の情報と「アクセント」の情報を推定

● 音響処理（波形生成）

● 発音表記に従って，音声波形を生成する。

● モデルベースの方法，波形素片をペタペタ貼付ける方法

● 以下，言語処理が終わった後の過程を考えます

音韻処理

音韻性に関する処理（分節的特徴）

- 音素表記の生成
 - 音訓, 長音化, 促音化, 連濁
- 単音表記の生成（異音化処理）
 - 無声化, 鼻音化, 撥音

韻律性に関する処理（超分節的・韻律的特徴）

- 単語レベルの処理
 - アクセント型, 複合語（接頭語, 接尾語）
- 句レベルの処理
 - アクセント結合
- 文レベルの処理
 - 強調, フレージング

● 単語分割語にどれだけの処理をしているのか確認せよ

音響処理（波形生成）

波形編集方式

- 時間領域での音声素片加工（TD-PSOLAなど）
- 周波数領域での音声素片加工（FD-PSOLAなど）
 - ノン・パラメトリックな分析が有効

分析合成方式

- 線形予測分析法，ケプストラム分析法
- HMMに基づく合成法

ターミナルアナログ方式（フォルマント合成）


- 周波数領域での音声生成過程の模擬

声道アナログ方式

- 調音器官（メカニクス）での音声生成過程の模擬

波形編集方式

- 音声DBをある単位に基づいて素片DB化
- 与えられたテキストに対して最適な素片を求めて連結
- 必要な波形処理を施して滑らかに接続



波形編集方式

音声DBをある単位に基づいて素片DB化


● 音素, 音節, 半音節, どれを使う?

与えられたテキストに対して最適な素片を求めて連結

● 複数の素片候補のどれとどれを選び, 連結するのか?

必要な波形処理を施して滑らかに接続


● 例えば欲しい高さの音がなかった場合どうする?



波形編集方式

音声DBに対するラベリング・素片DB化



- 音韻ラベリングと韻律ラベリング
- 手動ラベリング／音声認識技術を使った自動ラベリング



波形編集方式

接続コストを最小にする素片選択

● 素片を定義する／素片候補群から最適なものを選ぶ



VCV素片番号
VCV素片 VCV単位名

----- VCV素片の接続経路
(LSP距離の重み付き)


—— LSP距離の総和が最小の経路

波形編集方式

所望の高さにしてから接続する

● TD-PSOLA

- Time Domain Pitch Synchronous OverLap and Add
- ピッチ波形を単位として、間隔を修正して切り貼り



波形編集方式

幾つかの合成サンプル

● 男声

● 女声

● その他

● http://www.ntt-it.co.jp/goods/vcj/voice/tts_demo.html

The screenshot shows the NTT IT Voice Communication website. The header features the NTT IT logo and the text "Voice Communication". A navigation menu on the left lists various services, including "音声合成" (Voice Synthesis) and "音声合成ASP". The main content area is titled "音声合成ソフトウェア" (Voice Synthesis Software) and includes a breadcrumb trail: "HOME > 製品 > CTI・音声 > 音声合成ソフトウェア". Below the title, it states "単純音声合成から音声編集ツールまで豊富なラインアップをご提供" (We provide a rich lineup from simple voice synthesis to voice editing tools). A highlighted box contains the following text: "NTT研究所の音声合成エンジン「FLUET」、
「FinalFluet」、
「Cralinet」搭載
豊富な音声データによる滑らかで高品質な音声合成を実現
最新の単語や専門用語、様々な言い回しにも対応
ライブラリ、サーバ、ツールなど用途に応じた製品ラインアップ"

NTT IT Voice Communication

HOME > 製品 > CTI・音声 > 音声合成ソフトウェア

音声合成ソフトウェア

単純音声合成から音声編集ツールまで豊富なラインアップをご提供

NTT研究所の音声合成エンジン「FLUET」、
「FinalFluet」、
「Cralinet」搭載
豊富な音声データによる滑らかで高品質な音声合成を実現
最新の単語や専門用語、様々な言い回しにも対応
ライブラリ、サーバ、ツールなど用途に応じた製品ラインアップ

本日のメニュー

音声合成の原理と波形編集型音声合成

- 言語処理／音韻処理／波形処理
- 音韻処理といっても結構面倒・・・

音声認識セミナーより



- 音声特徴の分析と照合
- 隠れマルコフモデル (HMM)
- サブワードモデルを用いた音声認識
- 認識文法を用いた連続音声認識
- 日本語ディクテーションにおける基礎技術
- ビデオ鑑賞

宿題

まとめ

幾つか確認

音声波形→スペクトラム→ケプストラム




逆フーリエ変換

→ $(c_0, c_1, \dots, c_N)$

→ $\sum_{i=0}^N (\underline{c_i} - \underline{c'_i})^2$

幾つか確認

ケプストラム空間における「点」と「点間距離」



点 = スペクトル包絡, 点間距離 = スペクトル間差異

宿題

課題 1

- 第三回「音声の音響分析 波とフーリエ級数展開」
- 第四回「音声の音響分析と分析合成系」
- 第五回「音声合成と音声認識」
 - これらの講義に対して自主的に調査したことがあれば記しなさい。
 - 既に学んだ講義との関連性について記しなさい。
 - 理解できなかったことがあれば記しなさい。
 - 来年度以降に向けた改善点などあれば、それを記しなさい。

課題 2

- 配布したスライドに対して、知るところを全て述べよ。
 - A, B, C... などとマーキングし、箇条書きにして記せ。
 - 文系の高校生に対して説明するように、自分の言葉で記述せよ。

提出日

- 12月5日の授業の開始時にマーク付きスライドと一緒に提出

本日のおさらい

音声合成の原理と波形編集型音声合成

- 言語処理／音韻処理／波形処理
- 音韻処理といっても結構面倒・・・

音声認識セミナーより

- 音声特徴の分析と照合
- 隠れマルコフモデル (HMM)
- サブワードモデルを用いた音声認識
- 認識文法を用いた連続音声認識
- 日本語ディクテーションにおける基礎技術
- ビデオ鑑賞

宿題

まとめ