

音声 F_0 パターン生成過程の確率モデルに基づくテキストからの韻律生成*

門脇健人¹, 石原達馬¹, 北条伸克¹, 亀岡弘和^{1,2}

(¹ 東大院・情報理工, ² NTT CS 研)

1 はじめに

本研究では、テキスト音声合成を目的としてテキストから F_0 パターンを生成する問題を扱う。音声基本周波数 (F_0) パターンは、音声のイントネーションを表す特徴量であり、テキスト音声合成において高品質な F_0 パターンをいかに生成するかは重要課題の一つである。

テキスト音声合成において、隠れマルコフモデル (Hidden Markov Model; HMM) に基づく統計的アプローチ [1] が成功を収めている。HMM 音声合成 [1] では、各フレームの音韻的特徴量とともに F_0 、及びそれらの 1 階差分、2 階差分を組にしたベクトルが特徴量として扱われ、学習データから HMM のパラメータを学習することで、学習した HMM を用いてテキストから音韻的特徴量系列と F_0 パターンを同時生成することが可能である。

音声合成において、自然なイントネーションをもつ合成音声を実現するためには、言語的に妥当でありつつ発声器官による音声の物理的な生成プロセスに即した F_0 パターンを適切に生成することが重要である。 F_0 パターンの物理的な生成過程を模したモデルとして、藤崎らのモデル [2] (以後、藤崎モデル) が有名である。藤崎モデルは、生理学的・言語学的に意味のある少数のパラメータを用いて実測の F_0 パターンに非常によく近似できることが知られており、音声の F_0 パターンを表現するモデルとしては秀逸である。ただし、藤崎モデルはいわゆる trainable なモデルの形態をなしておらず、統計的アプローチとの親和性が必ずしも高いとは言えなかった。

このモデルを用いてテキストからあるルールを基にして韻律生成を行なった研究が [6] によって報告されているが、手動でルールを決めるには人的なコストが掛かる。我々はこれまで、藤崎モデルをベースにした F_0 パターン生成過程の確率モデルを提案しており、統計的手法に基づき観測 F_0 パターンから藤崎モデルのパラメータを推定するための基本アルゴリズムを導出するのに成功している [3, 4]。このことは、藤崎モデルを統計学習可能な形態に翻訳できたことを意味しており、本研究の目的は当該モデルをコンテンツ依存型のモデルに拡張し、統計学習を通して任意テキストから F_0 パターンを生成する手法を実現することである。

2 音声 F_0 パターンの確率モデル

2.1 藤崎モデル

藤崎モデル [2] とは、甲状軟骨の二つの独立な運動 (平行移動運動と回転運動) に伴う声帯の伸びの長さの和が声帯の固有振動数の対数 ($\log F_0$) に比例する、という仮定をもとに、甲状軟骨の運動方程式を通して F_0 パターンの生成過程を表現したモデルである。甲状軟骨の平行移動運動に関係する F_0 パターンの成分をフレーズ成分 $y_p(t)$ 、回転運動に関係する F_0 パターンの成分をアクセント成分 $y_a(t)$ と呼び (t は時刻)、対数 F_0 軌跡 $y(t)$ (以後、 F_0 パターン) はこれらの成分と声帯の物理的性質によって決まるベースライン成分と呼ぶ定数 y_b を加えたものとして表される。 $y_p(t)$ と $y_a(t)$ は、それぞれフレーズ指令と呼ば

れるパルス波の列 $u_p(t)$ とアクセント指令と呼ばれる矩形波の列 $u_a(t)$ (ただしフレーズ指令とアクセント指令は同時に生じない) を入力とした臨界制動の二次線形系により表現され、これらの値の関係は次のように書ける。

$$y(t) = y_p(t) + y_a(t) + y_b, \quad (1)$$

$$y_p(t) = G_p(t) * u_p(t), \quad y_a(t) = G_a(t) * u_a(t), \quad (2)$$

$$G_p(t) = \alpha^2 t e^{-\alpha t} (t \geq 0), \quad G_a(t) = \beta^2 t e^{-\beta t} (t \geq 0). \quad (3)$$

ここで、* は畳み込みを表す。また、 α, β はそれぞれの制御機構の固有角周波数を表し、話者の個人差や言語によらずおおよそ $\alpha = 3, \beta = 20$ [rad/s] 程度であることが経験的に知られている。日本語においては、藤崎モデルのフレーズ成分が F_0 パターン全体における緩やかな下降に相当し、フレーズ指令は主に息継ぎ、つまり呼気段落毎に生起する事がよく知られている。また、アクセント成分は主に音節単位の急激な上がり下がりに対応しており、アクセント指令の位置は音節毎のアクセント型によって決まるアクセント核と一致することが分かっている。

2.2 藤崎モデルの確率モデル化

ここでは、今までに我々が開発してきた、藤崎モデルをベースにした F_0 パターンの生成過程の確率モデル [3, 4] の概説を行なう。 k を離散時刻のインデックスとし、 $y_p[k], u_p[k], y_a[k], u_a[k]$ をそれぞれ $y_p(t), u_p(t), y_a(t), u_a(t)$ の離散時間表現として、観測 F_0 パターンの対数值 $y[k]$ を次のように表現する。

$$y[k] \mid u_p[k], u_a[k] \sim \mathcal{N}(x[k], v_n^2[k]), \quad (4)$$

$$x[k] = G_p[k] * u_p[k] + G_a[k] * u_a[k] + u_b. \quad (5)$$

ここで $v_n^2[k]$ は時刻 k における観測 F_0 パターンの“不確かさ”を表すために導入した変数であり、これにより全時刻で正しい F_0 の値が観測できるとは限らないという問題をノイズとして統一的に扱うことを可能にした。

次に、 $u_p[k]$ と $u_a[k]$ は、それぞれインパルス列状および矩形パルス列状の指令列関数であり、各パルスが同時刻には生じない、という制約を満たす必要がある。[3, 4] では、両指令列関数のペア $o[k] = (u_p[k], u_a[k])^T$ を以下に示す HMM (以後、指令列生成 HMM) の出力系列と見なそうというアイデアにより、上述の制約を満たした指令列関数の確率モデルが提案されている。

出力系列: $o[k] = (u_p[k], u_a[k])^T$ ($k = 1, \dots, K$)

状態集合: $\mathcal{S} = \{p_0, p_1, a_0, \dots, a_N\}$

状態系列: $s = \{s_k \in \mathcal{S} \mid k = 1, \dots, K\}$

出力分布: $P(o[k] \mid s_k = i) = \mathcal{N}(c_i[k], \Upsilon)$

$$c_i[k] = \begin{cases} (0, 0)^T & (i \in p_0, a_0) \\ (A_p[k], 0)^T & (i \in p_1) \\ (0, A_a^{(n)})^T & (i \in a_n) \end{cases} \quad \Upsilon = \begin{bmatrix} v_{p,i}^2 & 0 \\ 0 & v_{a,i}^2 \end{bmatrix}$$

遷移確率: $\phi_{i',i} = \log P(s_k = i' \mid s_{k-1} = i)$

*Text-to-speech prosody synthesis based on probabilistic model of F_0 contour by KADOWAKI Kento, ISHIHARA Tatsuma, HOJO Nobukatsu, KAMEOKA Hirokazu (The University of Tokyo)

$$b_2 = (\varphi - 1)^2, b_1 = -2\varphi(\varphi - 1), b_0 = \varphi^2,$$

$$\psi = 1 + \frac{1}{\alpha t_0}, \varphi = 1 + \frac{1}{\beta t_0},$$

である．なお，詳しい導出は [3] を参照されたい．

4 パラメータ学習と F_0 パターン生成

4.1 コンテキストクラスタリング

本章では，豊富な言語情報を用いて藤崎モデル指令列のパラメータ $\theta = \{\{A_p^{(m)}\}_{m=1}^M, \{A_a^{(n)}\}_{n=1}^N\}$ を決定木によるコンテキストクラスタリング [9] に基づき学習するアルゴリズムを提案する．これによって，学習データのあらゆる指令列パラメータを用いて統計的にモデルを学習し，未知入力データに対しても言語情報によって指令列の強度を決定することが可能になる．本手法ではノード分割の規準に対して最小記述長 (Minimum Description Length; MDL) 規準を採用する．また，MDL 規準における尤度は藤崎モデルパラメータ θ および状態系列 s が与えられた下での F_0 パターンの確率密度関数を採用する．この時，決定木の葉ノードは各指令列パラメータの自由度 M, N と一致しており，決定木が深くなるほど指令列パラメータの自由度が増える構造になっている．具体的な MDL 規準の式は，パラメータ s, θ ，学習データのインデックスを $d = 1, \dots, D$ ，データ d における観測 F_0 パターン $y^{(d)} = \{y^{(d)}[k]\}_{k=1}^{K^{(d)}}$ とすると学習データにおける対数尤度関数 $L(\theta)$ を用いて，

$$\begin{aligned} MDL &= -L(\theta) + c(N + M) \log W + C, \\ L(\theta) &= \sum_{d=1}^D \left\{ \frac{1}{2} \log |\Sigma^{-1}| - \frac{K^{(d)}}{2} \log 2\pi \right. \\ &\quad \left. - \frac{1}{2} (y^{(d)} - \mu^{(d)})^T \Sigma^{-1} (y^{(d)} - \mu^{(d)}) \right\}, \quad (7) \\ \mu^{(d)} &= A^{-1} \mu_p^{(d)} + B^{-1} \mu_a^{(d)} + \mu_b \mathbf{1}, \\ \Sigma &= A^{-1} \Sigma_p (A^T)^{-1} + B^{-1} \Sigma_a (B^T)^{-1} + \Sigma_b, \end{aligned}$$

で与えられる．なお式 (7) におけるパラメータ c はモデルの大きさを調整する為の重みパラメータであり，小さいほど決定木が深くなるように調節できる．また， C はモデルを決める際に必要な符号長であり，ここでは常に定数である．ここで，ノードが増える度に，指令列パラメータ θ を再推定する必要がある．各学習データに対して θ を推定するアルゴリズムは [3] において提案されているが，本手法においては状態系列 s が言語情報によって固定されている点，及び，モデルパラメータ θ が [3] とは異なる点に注意されたい．

4.2 パラメータ学習アルゴリズム

本節では，コンテキストに依存する藤崎モデル指令列パラメータ θ を反復計算し，決定木におけるモデルパラメータ θ を学習するアルゴリズムについて説明する．これは，[3] で示されたように，学習データ d における観測 F_0 パターン $y^{(d)}$ が与えられたとき $P(\theta|y^{(d)})$ をパラメータ θ に関して最大化する問題として定式化出来る．これにより学習データの F_0 パターンに最もフィットする様にモデルパラメータ θ が再推定される．ここで $P(\theta|y^{(d)})$ を最大化する問題を解析的に解くのは難しいが，[3] で示されるように $x^{(d)} = (y_p^{(d)T}, y_a^{(d)T}, y_b^{(d)T})^T$ を完全データとみなすことで EM アルゴリズムによる不完全データ問題に帰

着し，局所最適解を得ることが出来る．この時，本モデルにおける Q 関数は，

$$\begin{aligned} Q(\theta, \theta') &\stackrel{c}{=} \frac{1}{2} \left[\log |\Lambda^{-1}| - \text{tr}(\Lambda^{-1} \mathbb{E}[x^{(d)} x^{(d)T} | y^{(d)}; \theta']) \right. \\ &\quad \left. + 2m^{(d)T} \Lambda^{-1} \mathbb{E}[x^{(d)} | y^{(d)}; \theta'] - m^{(d)T} \Lambda^{-1} m^{(d)} \right], \quad (8) \end{aligned}$$

と書ける．ただし， $\stackrel{c}{=}$ は定数部分を除いて一致する事を意味する．ここで， θ が一様に分布する事，及び状態系列 $s^{(d)}$ が固定されている事からモデルパラメータの事前確率は定数である．また，

$$\begin{aligned} x^{(d)} &= \begin{bmatrix} y_p^{(d)} \\ y_a^{(d)} \\ y_b^{(d)} \end{bmatrix}, \quad m^{(d)} = \begin{bmatrix} A^{-1} \mu_p^{(d)} \\ B^{-1} \mu_a^{(d)} \\ \mu_b \mathbf{1} \end{bmatrix}, \\ \Lambda^{-1} &= \begin{bmatrix} A^T \Sigma_p^{-1} A & O & O \\ O & B^T \Sigma_a^{-1} B & O \\ O & O & \Sigma_b^{-1} \end{bmatrix}. \end{aligned}$$

である．

E ステップでは直前のステップで更新されたモデルパラメータを θ' に代入し Q 関数を更新する．紙面の都合上詳細は省くが詳しくは [3] を参照されたい．M ステップでは，E ステップの Q 関数を基に各パラメータを更新するが，ここで $s^{(d)}$ はコンテキストにより一意に決定出来る為，最尤状態系列 $s^{(d)}$ を計算し，更新するステップを必要としない．従って M ステップは，Q 関数をフレーズ指令の振幅平均 $A_p^{(m)}$ とアクセント指令の振幅平均 $A_a^{(n)}$ に関して最大化するステップとなり，それぞれの更新則は，

$$\begin{aligned} A_p^{(m)} &= \frac{1}{|\mathcal{T}_{p_m}|} \sum_{k \in \mathcal{T}_{p_m}} [A \bar{x}_p^{(d)}]_k, \quad \mathcal{T}_{p_m} = \{k | s_k = p_m\}, \\ A_a^{(n)} &= \frac{1}{|\mathcal{T}_{a_n}|} \sum_{k \in \mathcal{T}_{a_n}} [B \bar{x}_a^{(d)}]_k, \quad \mathcal{T}_{a_n} = \{k | s_k = a_n\}, \end{aligned}$$

で与えられる．E ステップと M ステップの反復計算により， $P(\theta|y^{(d)})$ を局所最大化する θ を得る事が出来る．

4.3 テキストからの F_0 パターン生成

ここでは，入力テキストが与えられた時に対応する F_0 パターンを生成する手順について説明する．まず入力テキストが与えられた時に，言語情報を保持した呼気段落および音節を抽出する．次に，それぞれの呼気段落及び音節に対して，言語情報を基に学習された決定木をたどっていき，対応する葉ノードの指令列パラメータを呼気段落の先頭，及び各音節のアクセント核に立て， $\bar{o} = \{(\bar{u}_p[k], \bar{u}_a[k])^T\}_{k=1}^K$ を求める．後は式 (4), (5) に従って F_0 パターンを生成すればよい．

5 提案法の動作実験

本章では，3 章，4 章で述べたモデル及び学習アルゴリズムに基づくテキストからの韻律生成手法に関して，フレーズ指令が各呼気段落の先頭に立ち，アクセント指令が各音節毎に立つという仮定と，フレーズ，アクセントの各パラメータがコンテキストに基づいて決定出来るという仮定の妥当性を検証する為に行なった動作実験について述べる．

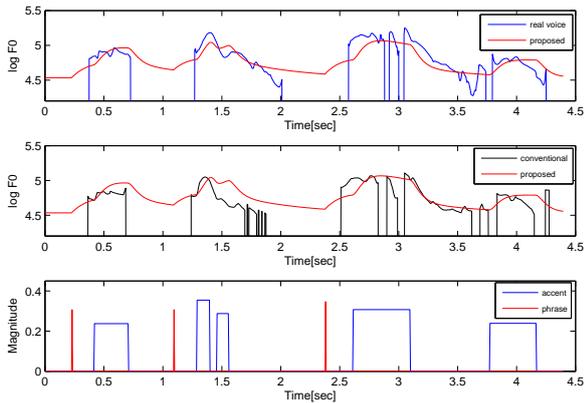


Fig. 2 上から, J09 文における学習データの肉声を STRAIGHT 分析 [8] して得られた F_0 パターンと実験手法によって生成された F_0 パターンを比較した図, HTS によって生成された F_0 パターンと実験手法によって生成された F_0 パターンを比較した図. 最下部の図は J09 文に対して実験手法によって生成された藤崎モデルの指令列である.

5.1 実験手法

今回行った動作実験では, フレーズ, アクセントの各パラメータの学習アルゴリズムにおいて, MDL 規準の式において (7) を用いるのではなく, 以下の式を用いてコンテキストクラスタリングを行い, 決定木を学習した.

$$MDL = \frac{1}{2} \sum_{d=1}^{D_j} \left\{ \log(2\pi\sigma_j^2) + \frac{(x_i - \mu_j)^2}{\sigma_j^2} \right\} + cJ \log W. \quad (9)$$

上式において, x_i は各ノードにおけるフレーズ, アクセント成分の強度を表し, J は葉ノード数, j は選択されたノードインデックス, D_j はノード j における占有状態数である. また, 4 章において述べたような, MDL 規準を計算する度に [4] を用いて再推定するのではなく, 初期ノードを計算する段階で全てのフレーズ及びアクセントパラメータを推定しておき, クラスタリングによって強度が最も近い指令列パラメータが同じクラスタに選ばれていくような分割方法で決定木を構築した. また, テキストから呼吸段落の先頭位置や各音節のアクセント核位置を抽出する必要があるが, 今回は HTS2.1 デモスクリプト [7] に含まれるラベルデータを用いてそのような位置を決定した.

本実験の初期推定において [4] を用いたが, その際の確率モデルにおける定数パラメータは以下のようにセットした. $t_0 = 8 \text{ ms}$, $\alpha = 3.0 \text{ rad/s}$, $\beta = 20.0 \text{ rad/s}$, $v_p^2[k] = 3^2$, $v_a^2[k] = 0.03^2$, $v_b^2 = 10^{-8}$, 有声区間において $v_n^2[k] = 10^{15}$, 無声区間において $v_n^2[k] = 0.1^2$. μ_b は全 $\log F_0$ の有声区間の値の最低値にセットし, EM アルゴリズムの反復回数は 20 回とした. 今回取り扱ったデータに関しては, HTS2.1 のデモスクリプト [7] に同梱された男性話者の音声のうち, 450 文を学習データとして使い, 残りの 53 文を評価の為に用いた.

5.2 実験結果及び考察

ATR503 の J09 文「これが広い意味での金属疲労による破壊である」において前節で述べた手法を用いて生成した F_0 パターンと肉声を STRAIGHT 分析 [8] によって得られた F_0 パターンと比較した図, 同文に対して前節の手法と HTS[1] を用いて生成した F_0

パターンを比較した図, それらに対して本実験手法によって生成された藤崎モデルの指令列パラメータを描画した図を上から順に掲載した結果を Fig. 2 に示す. Fig. 2 に示された結果は, 肉声における F_0 パターンが必ずしも言語情報と対応している訳ではないので, 立ち上がりなどに多少の誤差は有るものの, 明らかなピッチのずれが生じていない事から, 本手法における仮定は妥当であると示唆される. 故に, 本手法において立てた「フレーズ指令が各呼吸段落の先頭に立ち, アクセント指令が各音節のアクセント核毎に立つ」という仮定, 及び藤崎モデルのパラメータをコンテキストに基づいて学習できる」という仮定は妥当なものであると考えられる.

6 おわりに

本稿では, テキストから韻律を生成する手法として, 本研究室で開発してきた F_0 パターン生成過程の確率モデルを用いた新たな手法を考案し, その有効性を検証する為の動作実験を行った. 本手法によって生成された F_0 パターンは大域的な特徴をうまく表現できており, 音声合成における自然性の向上に有効な手法である事が確認された. 今後の課題は, MDL 規準の計算式を 4 章で提案した観測 F_0 パターンにフィットする様な尤度規準に置き換えて提案したアルゴリズムによって学習を行い, 最終的に自然な音声合成を達成する事である. それとともに, 合成音声の主観評価実験を行い, HTS[7] 等の従来法と比較するなど, 定量評価を行なう予定である.

参考文献

- [1] K. Tokuda, T. Yoshimura, T. Masuko, T. Kobayashi, and T. Kitamura, "Speech parameter generation algorithms for HMM-based speech synthesis," in Proc. ICASSP, vol. 3, pp. 1315–1318, 2000.
- [2] H. Fujisaki, "In Vocal Physiology: Voice Production, Mechanisms and Functions," Raven Press, 1988.
- [3] H. Kameoka, J. Le Roux, and Y. Ohishi, "A statistical model of speech F_0 contours," in Proc. SAPA, pp. 43–48, 2010.
- [4] K. Yoshizato, H. Kameoka, D. Saito, and S. Sagayama, "Hidden Markov convolutive mixture model for pitch contour analysis of speech," in Proc. Interspeech, 2012.
- [5] T. Masuko, *et al*, "Multi-Space Probability Distribution HMM," IEIC Technical Report, vol. 101, no. 323, pp. 41–42, 2001.
- [6] 橋本, 広瀬, 峯松, "HMM 音声合成を想定した基本周波数パターン生成過程モデルパラメータの自動抽出の高精度化," 音講論 (春), 1-R-7, 2012.
- [7] "HMM-based Speech Synthesis System (HTS)," <http://hts.sp.nitech.ac.jp/>
- [8] H. Kawahara, I. Masuda-Katsuse, and A. de Cheveigné, "Restructuring speech representations using a pitch-adaptive time-frequency smoothing and an instantaneous-frequency-based F_0 extraction: Possible role of a repetitive structure in sounds," Speech Communication, vol. 27, no. 3, pp. 187–207, 1999.
- [9] T. Yoshimura, K. Tokuda, T. Masuko, T. Kobayashi, T. Kitamura, "Simultaneous modeling of spectrum, pitch and duration in HMM-based speech synthesis," Proc. of Eurospeech, pp. 2347–2350, 1999.