

キーワード スポッティングにおける基本周波数情報の利用について

菅原孝夫¹ 山下洋一² 溝口理一郎¹

¹ 大阪大学産業科学研究所知識システム研究分野 ² 立命館大学理工学部情報学科
〒567-0047 大阪府茨木市美穂ヶ丘 8-1 〒525-8577 滋賀県草津市野路東 1-1-1

概要: 基本周波数パターンのマッチングを利用したキーワードスポットティングの高精度化には文脈・話者の意図等の要因で、様々に変化するピッチパターンの多様性を考慮する必要がある。また、基本周波数の分析エラー等にも頑健な基本周波数情報の利用法を確立する必要がある。本稿では、(1)マルチテンプレート／シングルテンプレートによる性能評価、(2)基本周波数情報として“ F_0 ”および“ $\Delta F_0 + \text{有声性}$ ”を用いて性能評価を行う。その結果マルチテンプレート化による効果はあまり見られなかった。また、 F_0 は湧き出し誤り率が少ない条件で、 ΔF_0 は湧き出し誤り率が少ない条件で認識性能を改善する傾向にあり、 F_0 、 ΔF_0 の利用効果は湧き出し誤り率に依存することが観察された。

キーワード: キーワードスポットティング、韻律、基本周波数、マルチテンプレート、湧き出し誤り

Using Fundamental Frequency Information for Keyword Spotting

Takao Sugahara¹ Yoichi Yamashita² Riichiro Mizoguchi¹

¹ Dep. of Knowledge System,
I.S.I.R.Osaka University
8-1,Mihogaoka,Ibaraki-shi,
Osaka,567-0047 Japan

² Dep. of Computer Science,
Ritsumeikan University
1-1-1,Noji-Higashi,Kusatsu-shi,
Shiga,525-8577 Japan

Abstract: The F_0 contour of a keyword is dependent on context or speaker's intention in sentences. Considering the diversity of the F_0 contour is necessary in keyword spotting using F_0 contour matching. It is important to develop a robust method for extracting F_0 information. This report describes about (1)spotting performance for different numbers of keyword F_0 template(multi template/single template), and (2)several methods for representing F_0 information(" F_0 " or " $\Delta F_0 + \text{vocalic probability}$ "). Experiment results says that the multi-template is not so effective, and that ΔF_0 is effective for low F.A.(False Alarm) rate and F_0 is effective for high F.A. rate. Effectivity of F_0 information depends on F.A. rate.

Keywords: keyword spotting, prosody, fundamental frequency, multi template, false alarm

1 はじめに

通常、キーワードスポットティングは音韻情報に基づいて行われる。そのためキーワードの音韻系列と似た音韻系列が連続音声中に存在すると、韻律的特徴が大きく異なる場合でも、キーワードであると誤って判定してしまう。このような湧き出

し誤りを抑制する為、音韻的特徴に加えて韻律的特徴を考慮した認識手法がこれまでに多く提案されており、キーワードスポットティングにおいても句境界情報を利用する手法[1]が提案されている。著者らはこれまで、キーワードのテンプレートと音声区間中のピッチパターン照合による手法を提案し、韻律情報の利用が湧き出し誤りの抑制に有

用であることを報告した [3] [4]。

従来の手法では、キーワードごとに一つのピッチバタントンプレートを視察により選択していた。ピッチバターンは文脈・話者の意図といった要因によって多様に変化するため、発話中でのピッチバターンが変形されて観測される可能性も考慮する必要がある。このようなピッチバターンの多様性に対応する方法として、本報告ではピッチバタントンプレートのマルチテンプレート化 [10] について検討する。

ピッチバターンを認識に利用する場合には、無声化・分析エラーを原因とするピッチの不連続区間をどのように取り扱うかが問題となる。これまでには、藤崎モデル [6] を用いて、この不連続区間の補間を行っていた。しかし、藤崎モデルのモデルパラメータ推定は手動で行わなければならず、コストが大きい。その為、認識対象キーワードが増加した場合を考えると藤崎モデルの利用は現実的でない。そこで、藤崎モデルを用いないで、ピッチの補間を行う方法についても検討する。

以下では、まず、キーワードスポットティングにおける基本周波数情報の表現方法として、線形回帰直線により補間した F_0 、 ΔF_0 信頼度 [8][9] より抽出した ΔF_0 の利用について述べる。次に、キーワードごとのピッチバタントンプレートを一つ用いる場合（シングルテンプレート）と複数用いる場合（マルチテンプレート）のキーワードスポットティングについて述べる。最後に、各キーワードの韻律情報への依存性を調べる目的で、キーワードごとの認識性能を比較検討する。

2 基本周波数情報を使ったキーワードスポットティング

2.1 システム構成

今回実験に用いたシステムの全体図を図 1 に示す。認識システムは

- (1) 音韻 HMM の学習
 - (2) 音韻 HMM によるキーワードスポットティング部
 - (3) ピッチバタントンプレート生成部
 - (4) ピッチバターンマッチング部
- の 4 つのモジュールからなる。キーワードスポット

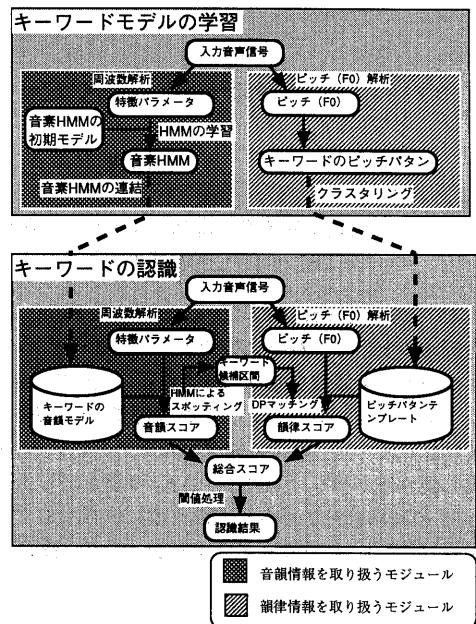


図 1: システムの全体図

ティングは、まず、モデル構築用の音声データに対して、(1) 音韻 HMM の学習 および、(3) ピッチバタントンプレートの生成を行い、次に、認識対象の音声データに対して、(2) 音韻 HMM によるキーワードスポットティングおよび、(4) ピッチバターンマッチングを行うことで、キーワードスポットティングを行う。なお本システムでは、音韻モデルの学習および、音韻モデルによるキーワードスポットティングには、Entropic 社の HTK[2] を用いている。

2.2 スポットティング手法

キーワードスポットティングは以下の手順で行う。まず、HTK を用いた認識システムを用いて音韻情報に基づくキーワードスポットティングを行い、音韻スコア $S_{\text{音韻}}$ を用いてキーワード候補区間を算出する [4]。次に、キーワード候補区間に對して、ピッチバターン DP マッチングを行って韻律スコア $S_{\text{韻律}}$ を求める。 $S_{\text{韻律}}$ は、テンプレートバターンとキーワード候補区間の DP マッチングにより算出

した距離 D_i を用いて

$$S_{\text{韻律}} = \min_i D_i \quad (1)$$

として算出する。

最終的に音韻スコアと韻律スコアからキーワード候補区間にに対する総合スコア S を

$$S = S_{\text{音韻}} + w \times S_{\text{韻律}} \quad (2)$$

として算出する。この総合スコアに対して、閾値処理を行い閾値以下のものを、キーワードとして検出する。なお $w = 0$ は、音韻情報のみを用いた認識に相当する。

2.3 基本周波数情報の抽出

2.3.1 F_0 (基本周波数) の抽出

F_0 の抽出は、

(1) ピッチの分析 [5]

(2) 分析エラー除去 [3]

(3) 無声/無音区間の補間・平滑化

の 3 ステップを経て行う。なお、補間・平滑化は、各フレームごとに前後 10 フレームを含む回帰直線を求め、そのフレームにおける直線の値をピッチとして用いることで行う。

2.3.2 ΔF_0 の抽出

ΔF_0 の抽出は、中井 [8][9] の提案している ΔF_0 信頼度パタンから求めた。この方法は、 F_0 抽出エラーの要因である F_0 決定を行わずに、時刻 t における分析フレーム内での F_0 の対数値 p の周期性の特性を $S(t, p)$ と表現して取り扱う手法である。 ΔF_0 信頼度パタン $R(t, f)$ は、 $S(t, p)$ に対して、時間軸／周波数軸方向の双方に窓掛けを行うことにより求められる。

本稿で利用する ΔF_0 パタン $q(t)$ と、有声性パタン $v(t)$ は、式(3) および式(4) を用いて算出する。 ΔF_0 パタンの分析条件および分析例を表 1、図 2 に示す。

$$q(t) = \underset{f}{\operatorname{argmax}} R(t, f) \quad (3)$$

$$v(t) = \max_f R(t, f) \quad (4)$$

ここで t はフレーム ID、 f は ΔF_0 値である。

表 1: ΔF_0 の分析条件

サンプリングレート	: 16[kHz]
シフト幅	: 10[ms]
フレーム幅	: 32[ms]
ΔF_0 抽出時の窓幅	: 前後 16 フレーム (時間／周波数軸方向)
ΔF_0 抽出時の窓関数	: 矩形窓 (時間／周波数軸方向)

発話「あらゆる現実を」
の分析例

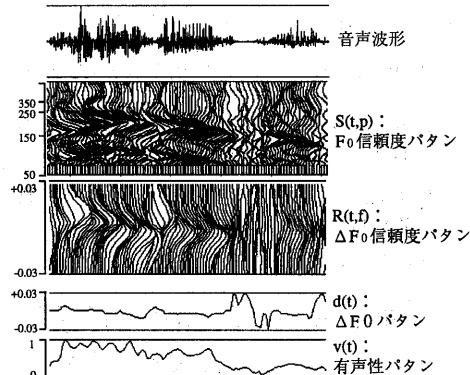


図 2: ΔF_0 の抽出例

なお、有声性パタン $v(t)$ は、そのフレームの有声音らしさを表すパラメータで 0 ~ 1 の値をとる。有声音部分に対しては 1 に近い値をとる。

3 ピッチパタンの比較

2 つのピッチパタンの類似度の尺度として、ピッチパタン DP マッチングにより算出したピッチパタン間の距離を用いる。

DP パス (図 3) には、傾斜制限 0 ~ 2 の非対称パスを用い、極端な非線形伸縮を避ける為の整合窓を用いている。この整合窓は、参照パタンとテストパタンのフレーム数の差を、テンプレート長の 10% 以内に制限している。

今回、DP マッチングの対象パラメータとして

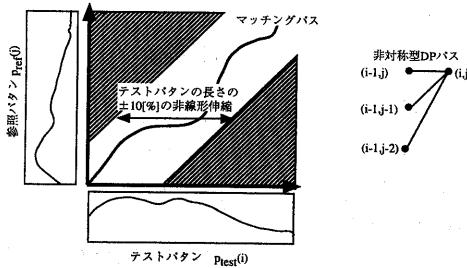


図 3: DP マッチングのマッチングパス

F_0 および ΔF_0 を用いるので、以下、それぞれについて説明する。

3.1 F_0 による DP マッチング

F_0 を用いた DP マッチングは以下の手順で行う。

1. テストパタンの F_0 値 $p_{test}(i)$ と、参照パタンの F_0 値 $p_{ref}(j)$ の平均値を揃え、それそれ $p'_{test}(i), p'_{ref}(j)$ とする。ただし平均値の計算には、無声音部分のピッチ ($p_{test}(i) = 0$ となるもの) は除去してある。

$$\begin{aligned} \text{平均の差} &= \overline{\ln p_{test}(i)} - \overline{\ln p_{ref}(j)} \\ \ln p'_{test}(i) &= \ln p_{test}(i) - \text{平均の差} \\ \ln p'_{ref}(j) &= \ln p_{ref}(j) + \text{平均の差} \end{aligned}$$

2. フレーム間距離 d_{ij} を式(5)のように定義し、DP マッチングにより、2つのピッチパタン間の距離を算出する。

$$d_{ij} = \begin{cases} (\ln p'_{test}(i) - \ln p'_{ref}(j))^2 & (p_{test}(i) \neq 0) \\ 0 & (p_{test}(i) = 0) \end{cases} \quad (5)$$

3.2 ΔF_0 による DP マッチング

ΔF_0 を用いる場合のフレーム間距離をテストパタン、参照パタンの ΔF_0 値 $q_{test}(i), q_{ref}(j)$ を用いて式(6)のように定義する。

$$d_{ij} = W_{ij} \times (q_{test}(i) - q_{ref}(j))^2 \quad (6)$$

なお、式(6)で W_{ij} は、参照パタン、テストパタンの有声性パタン $v_{ref}(i), v_{test}(j)$ に基づく重み係数である。有声性の利用に関しては、

(1) 有声区間／無声区間の同期 参照パタンの有声音部分とテストパタンの有声部分の距離を正しく算出できるように、参照パタンとテストパタンで有声／無声音の同期をとる。

(2) 有声区間のみの利用 無声区間のパタンは抽出エラーが存在する可能性が高いので、DP マッチングでの、距離計算に利用しない。

の 2 点を考慮して、式(7)～式(11)の 5 種類の重み係数 W_{ij} に対して比較を行う。

$$W_{ij} = 1 \quad (7)$$

$$W_{ij} = |v_{test}(i) - v_{ref}(j)| \quad (8)$$

$$W_{ij} = \max(v_{test}(i), v_{ref}(j)) \quad (9)$$

$$W_{ij} = \min(v_{test}(i), v_{ref}(j)) \quad (10)$$

$$W_{ij} = v_{test}(i) \times v_{ref}(j) \quad (11)$$

4 ピッチパタンテンプレートの選択

テンプレートパタンは各キーワードごとに以下の手順で作成した。

1. キーワードのピッチパタンを最長距離法 [7] でクラスタリング。ピッチパタン間の距離計算にはピッチパタン DP [4] を用いた。
2. 総ピッチパタン数に対する、クラスタに属するに対するピッチパタン数の割合が閾値 N [%] 以上、即ち

$$\frac{\text{クラスタに属するピッチパタン数}}{\text{全ピッチパタン数}} \times 100 > N$$

を満たすクラスタを抽出。

3. クラスタ C を代表するピッチパタンとして、他のピッチパタンへの距離の総和が最小となるピッチパタンを選択する。即ち、ピッチパタン i と j の DP 距離を $D(i, j)$ として、

$$k = \operatorname{argmin}_i \sum_j D(i, j) \quad (i, j \in C)$$

であるピッチパタン k をテンプレートとする。この手法は、類似したピッチパタンの出現頻度に基づいてテンプレート抽出を行う為、音声区間に現れる典型的なパターンを選択し、ピッチ分析エラー等による特異なピッチパタンは結果的に除

去される。なお、クラスタ数の制限がないので、キーワードによってテンプレート数が異なる。

5 評価実験

5.1 音声データ

ある一日のNHKのニュース音声を利用した。200[ms]以上の無音区間で区切られた継続時間500[ms]以上の有音区間を1発話とし、この発話単位にスポットティングを行う。なお実験は、聴取により選択したノイズの少ない発話を、データA、データBの2つに分割して行った。総発話数(A)1756発話、(B)1184発話、総継続時間(A)1.33[hour]、(B)0.92[hour]である。なお、(A)はNHKの地上波放送、(B)はNHKの衛星放送のニュースである。

スポットティングの対象であるキーワードには、ニュース音声中、多く出現した「ペルー政府」「海上保安本部」などの8音素以上の単語10種類を用いた。キーワードの平均音素数は9.5である。単位時間当たりのキーワードの平均出現回数は(A)10.9[回/hour/word]、(B)14.2[回/hour/word]であった。

5.2 評価式

スポットティング性能の評価は検出率[%]と湧き出し誤り率[/hour/keyword]を用いて行う。

$$\text{検出率} = \frac{\text{正解検出数}}{\text{総キーワード数}} \times 100$$

$$\text{湧き出し誤り率} = \frac{\text{総湧き出し誤り数}}{\text{総発話時間} \cdot \text{キーワード数}}$$

また、湧き出し誤り率が0[/hour/keyword]から10[/hour/keyword]までの、平均検出率であるFOM(Figure Of Merit)も、性能評価に用いる。

5.3 実験結果

データBより生成したテンプレートを用いて、データAに対してキーワードスポットティングを行い、

- (1) マルチテンプレート／シングルテンプレート
- (2) 基本周波数パラメータの利用方法
- (3) キーワードごと

について認識性能の比較を行った。以下それについて述べる。

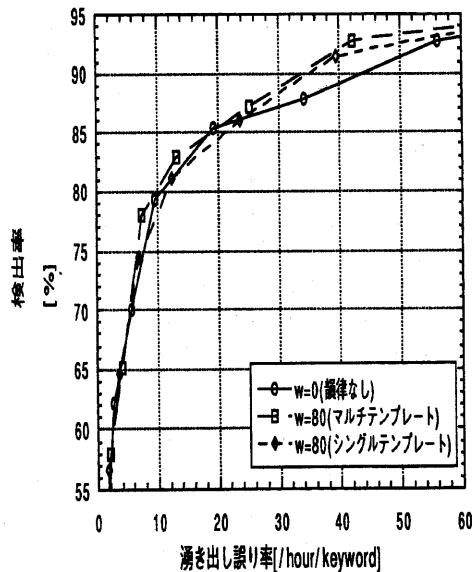


図4: マルチテンプレート／シングルテンプレートによる性能評価

5.3.1 マルチテンプレート／シングルテンプレート

ピッチパタンテンプレート数による認識性能の違いを調べるために、複数のテンプレートパタンを用いるマルチテンプレート、唯一のテンプレートパタンを用いるシングルテンプレートの2種類の認識実験を行った。その結果を図4に示す。なお、ピッチパタンの比較に用いる基本周波数パラメータとして、 ΔF_0 (有声性の差、式(8))を用いた。

図4より、韻律情報を用いる場合(シングル/マルチテンプレート)の方が、韻律情報を用いない場合よりも、同一湧き出し誤りに対して、検出率を高めることができることが分かる。また、マルチテンプレートとシングルテンプレートを比較した場合、マルチテンプレートが、シングルテンプレートの場合よりも、若干、高い検出率を示している。

5.3.2 基本周波数パラメータ

基本周波数パラメータの利用方法による、スポットティング性能の違いを調べる為、以下の7パターン

ンの基本周波数パラメータについてテンプレートの生成・認識実験を行った。なお、認識時に用いたピッチパターンテンプレートは、方法2で生成した、マルチテンプレートピッチパターンを利用した。

- 方法1: ΔF_0 (有声性無し, 式(7))
- 方法2: ΔF_0 (有声性の差, 式(8))
- 方法3: ΔF_0 (有声性の最大, 式(9))
- 方法4: ΔF_0 (有声性の最小, 式(10))
- 方法5: ΔF_0 (有声性の積, 式(11))
- 方法6: F_0 (入力音声に対する補間あり)
- 方法7: F_0 (入力音声に対する補間なし)

方法6と方法7の相違点は、方法6が入力音声の F_0 パターンに対して補間を行っているのに対し、方法7は入力音声に対して補間を行っていない点である。なお、方法6・方法7とも、テンプレートパターンに対しては F_0 の補間を行っている。

有声性の利用方法による比較 各々の有声性の利用

方法(方法1～方法5)による認識結果を図5に示す。この図より、方法2(ΔF_0 , 有声性の差分)が、方法1(ΔF_0 , 有声性なし)よりも、同一湧き出し誤り率に対して、高い検出率を示している。他の有声性の利用方法は、方法1(ΔF_0 , 有声性なし)よりも、同一湧き出し誤り率に対する検出率が悪い。

$\Delta F_0 / F_0$ の比較 基本周波数パラメータとして、 ΔF_0 を用いた場合と、 F_0 を用いた場合の違いを調べる。 ΔF_0 の認識結果は方法2(ΔF_0 , 有声性の差分)による結果を用い、 F_0 の認識結果には、方法6(F_0 , 補間あり)、方法7(F_0 , 補間なし)を用いる。このグラフを図6に示す。この3種のパラメータのなかで、方法6(F_0 , 補間あり)は、湧き出し誤り率0～20で最も、検出率が高い。方法2(ΔF_0 , 有声性の差分)は湧き出し誤り率40～60で最も検出率が良い。また、方法7(F_0 , 補間なし)は、どの湧き出し誤り率においても、韻律情報を用いない場合と、検出率に大差がない。

5.3.3 キーワードごとの認識性能

認識性能および、韻律情報の利用効果は各キーワードの特徴(音韻認識の容易さ、テンプレート

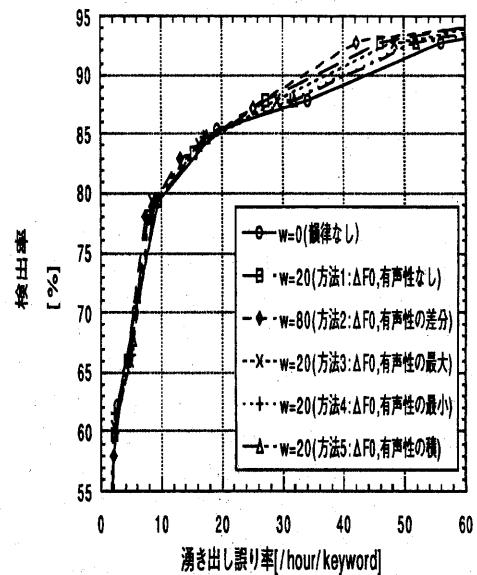


図5: 有声性パラメータの違いによる性能評価

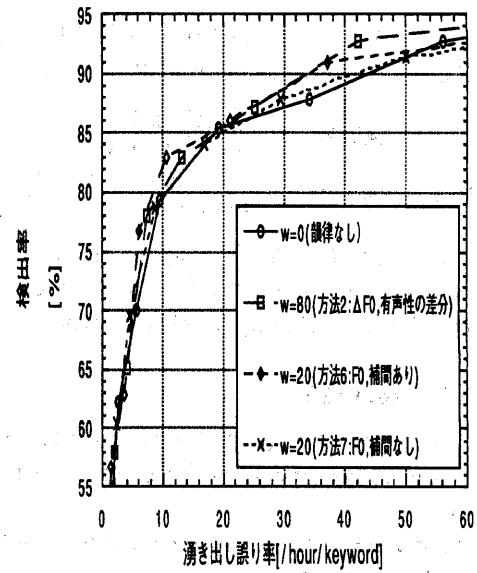


図6: $F_0 / \Delta F_0$ の違いによる性能評価

表 2: キーワードごとの FOM

キーワード名	FOM[%]					出現回数	
	韻律 なし (w=0)	ΔF_0 (有声性の差)		F_0 (補間あり)		データ A	データ B
		multi (w=70)	single (w=20)	multi (w=60)	single (w=50)		
大統領	92.94	90.00(2)	91.94	86.47(3)	91.76	21	70
協力	3.85	2.82(2)	3.59	9.74(5)	7.69	42	24
回収作業	97.00	97.50(1)	97.00	97.50(5)	97.00	23	11
武装グループ	92.22	92.22(1)	92.22	88.89(4)	93.33	19	36
海上保安本部	100.00	100.00(1)	100.00	100.00(3)	100.00	10	8
警察本部	100.00	90.00(1)	97.50	100.00(2)	100.00	8	3
北日本	90.00	90.00(1)	90.00	90.00(1)	90.00	11	7
日本海	70.00	71.54(1)	70.38	79.23(3)	79.23	27	16
日本政府	57.50	68.75(1)	62.50	80.00(1)	83.75	8	9
ペルー政府	95.71	97.14(1)	97.14	95.71(2)	95.00	14	11
Total	68.41	69.39	68.66	72.13	71.77	183	186

multi:マルチテンプレート、single:シングルテンプレート

データ A:認識対象データ、データ B:テンプレート抽出データ

() 内の数字はマルチテンプレートでのテンプレート数

の概形)に依存する為、キーワードごとに算出した FOM を表 2 に示す。

まず、「音韻認識の容易さ」という観点から、各キーワードを観察する。キーワード「海上保安本部」「警察本部」では、音韻認識のみによる認識で、FOM が 100[%] という理想的な認識結果であるので、これ以上の性能改善は有り得ず、韻律情報を利用する必要性がないことが分かる。

次に、「テンプレートの概形」に着目する。例えば、「北日本」、「回収作業」といったキーワードは、 F_0 が 200[Hz] から 300[Hz] まで、100[Hz] 程度変動する F_0 変化量の大きい起伏型のキーワードであり、 $F_0 \cdot \Delta F_0$ とともに、湧き出し誤り率が 10 から 20 までの、検出率が向上している。このようなキーワードは韻律情報の利用により、認識性能が向上する傾向にある。

しかし、起伏型のキーワードであっても、「大統領」のように、 F_0 の変動幅が少ないキーワードは、韻律情報を利用した場合でも、大きな認識性能の向上は見られないことが観察された。

6 考察

基本周波数パラメータとして、 ΔF_0 と F_0 を比較した場合、 F_0 は湧き出し誤り率が低い状況で、 ΔF_0 よりも、良い性能を示す。しかし、 F_0 は、湧き出し誤り率が大きくなると、韻律情報を利用しない場合と、性能差が変わらなくなる。それに対して ΔF_0 は、湧き出し誤り率が多い状況であっても、韻律情報を利用しない場合よりも、良い性能を示している。

このことより、認識条件に応じて、 F_0 、 ΔF_0 を使い分ける必要があると言える。また、 F_0 と ΔF_0 の 2 つのパラメータを考慮して、テンプレートマッチングを行う方法も考えられる。

ΔF_0 の抽出時に算出される、有声性バタンの利用方法としては、現在のところ、有声／無声の同期をとるという観点から、DP のフレーム間距離の重み W_{ij} に「有声性の差分」を用いる方法が最も、良い認識性能を示している。性能向上のためには、有声性バタンの有声部と無声部の違いが、より顕著に現れるように、 ΔF_0 抽出時のパラメータを調整していく必要がある。

今回、テンプレートパターンの選択は「キーワードの典型的なピッチパターンを選択する」ことを考慮して行った。しかし、以下に述べる事柄から、テンプレートパターンの選択基準として、これだけでは、不十分である。

例えば、キーワード「警察本部」のように、音韻情報のみでも十分な認識性能があるキーワードに対しては、韻律情報を用いても、これ以上の性能向上が望め無いばかりか、逆に、韻律情報を利用することにより、性能を悪化させる恐れがあることが伺える。このことから、テンプレート選択時には、「韻律情報を全く利用しない場合が良い」ことも、考慮する必要があると考えられる。

また、ピッチの変化が大きい起伏型のキーワードに対しては、韻律情報の利用により、認識性能が向上するが、起伏型であってもピッチの変化の少ないキーワードに対しては、韻律情報を利用しても、効果がない、もしくは、認識性能を悪化させることもある。この為、テンプレートの選択時には、「ピッチの変化量」も考慮する必要がある。

以上より、テンプレートパターンの選択時には、「音韻情報のみによる認識性能」「キーワードのピッチパターンの変化量」の2点も考慮する必要があると考えられる。

7 おわりに

本稿では、ピッチパターンテンプレート数の違いによる認識性能の違いを調べ、テンプレート数の違いによる認識性能の違いを調査した。また、基本周波数の利用方法 F_0 、 ΔF_0 および有声性の利用方法による認識性能の違いを調査し、 F_0 は、湧き出し誤り率の少ない状況で有効であるのに対して、 ΔF_0 は湧き出し誤り率の多い状況で効果があることが観察された。

今回の実験では、韻律情報の利用により、若干の認識性能の向上が見られたが、我々が期待したほどの効果が得られていない。そこで、今後は、認識エラー・湧き出し誤りの事例の定性的分析と共に、基本周波数情報の利用方法の再検討を行う予定である。

謝辞 本研究では、音声認識システムの学習に日本音響学会研究用連続音声データベースを使用

した。

参考文献

- [1] T.Hanazawa, et.al. : "Phrase spotting using pitch pattern information", Proc. of EUROSPEECH, pp.2137-2140 (1995).
- [2] HTK: Hidden Markov Model Toolkit V1.5 , Entropic Research Laboratories Inc.,1993.
- [3] 岩橋, 山下, 他: "キーワードスポットティングにおけるピッチパターンの利用", 信学技報, SP96-106, pp.79-85(1997).
- [4] 山下, 他: "ワードスポットティングにおけるピッチ情報を利用した湧きだし誤りの抑制" 音講論, 3-6-18 , pp123-124 (1997-3) .
- [5] 高橋, 溝口, 他: "残差相関の形状識別に基づいたピッチ抽出", 音講論, 2-1-5, pp.125-126 (1984-10).
- [6] 藤崎, 他: "基本周波数パターン生成過程モデルに基づく文章音声の合成", 信学論, J-72A, 1, pp.43-40 (1989).
- [7] 河口 著: "多変量解析入門 II", 森北出版.
- [8] 中井, 他: " F_0 決定を要しない F_0 パターン整合を用いたアクセント句境界の自動推定", 音講論, 3-6-16, pp.119-120 (1997-3).
- [9] Nakai,et.al: "On representation of fundamental frequency of speech for prosody analysis using reliability function" ,Proc of EUROSPEECH ,pp.243-246 (1997)
- [10] 菅原, 山下, 他: "ピッチパターンのマルチテンプレートを利用したキーワードスポットティング", 音講論,2-1-15,pp.77-78 (1997-9).