

# 少数の音声データによる音声標準パターン作成方法

5V-7

○佐野 常世 山本 稔 和田 肇一  
(東京電力株式会社) (沖電気工業株式会社)

## 1. はじめに

離散単語音声認識において高性能な認識を実現させるためには、単語ごとの音声波形の特徴を十分に表現させた、良好な音声標準パターンを作成する必要がある。音声標準パターンは、実際に収集した多数の音声データをクラスタリング化・平均化することにより作成される。しかし従来の音声標準パターン作成方式では、数百～千人程度もの多数の音声データを収集しなければ単語ごとの発音・発声スピード・ゆらぎ等の発声個人差を的確に表現させることができず、非常に多大な労力を費やしていた。以下本論ではこのような問題点を解決させる一手法として、音声データの正規性の検定結果に基づき、統計的な推定手法を用いることによって数十人の少数の音声データから良好な音声標準パターンを作成させる方式を開発したので、その方式と評価結果について述べる。

## 2. 音声認識方式概要

図1に音声認識方式を示す<sup>[1]</sup>。音声分析部では、サンプリング周波数12kHz、フレーム周期10.67ms、チャネル数21によるBPF分析を行う。特微量抽出部では、音声データの特徴点を強調するためにローカルピーク、スペクトル変化、子音性などの6種類の特微量を抽出し、各々の特微量を周波数軸7分割、時間軸8分割の56領域に分割することにより、 $6 \times 56 = 336$ 次元のデータを得る。マッチング部では、あらかじめ単語ごとに作成された音声標準パターンと、前述の入力音声データとの距離計算を行い、認識結果を得る。




図1 認識処理手順

このようにして32単語を認識対象とした不特定話者用離散単語音声認識を実現している。

## 3. 音声データ分布の正規性

本論では音声標準パターンの作成に統計的な推定手法を用いているが、そのためには音声データの分布状態が正規性を有することが前提条件となる。そこで認識対象語である32単語それぞれについて、今回収集した男性83人分の音声データの分布状態を調べた。具体的には、83人の男性に発声してもらった認識対象語  $x$  ( $x=1 \sim 32$ ) の実際の音声データを、前章で示した方法により全て336次元の数値データ  $x_{ij}$  ( $i=1 \sim 336, j=1 \sim 83$ ) へ変換し、任意の単語の任意の次元  $x_{ij}$  について  $x_{j1}$  (=1~83) を抽出し、その分布(すなわち、32単語 × 336次元 = 10,752種類それぞれにおける83人分の音声データ分布)の正規性を調べた。以下に正規分布の検定に用いたSkewnessとKurtosisの式を示す。

### [Skewness]

$$\text{Skewness} = \frac{1}{n} \sum \left( \frac{x_j - \bar{x}}{s} \right)^3$$

### [Kurtosis]

$$\text{Kurtosis} = \sum \left( \frac{x_j - \bar{x}}{s} \right)^4 \times \frac{n(n+1)}{(n-1)(n-2)(n-3)} - 3 \frac{(n-1)^2}{(n-2)(n-3)}$$

ここで、 $n$  はデータ数、 $\bar{x}$  はデータの平均、 $s$  は標準偏差、 $x_j$  はデータの実態 ( $j=1 \sim 83$ ) とする。一般的には、SkewnessとKurtosisの値の絶対値が双方ともに小さい値を示す場合に、その分布は標準正規分布に近いと言われている。表1に今回の計算結果を示す。なお、全要素が"0"となった440種類のデータについては区間推定の対象とならないため、計算結果から除いた。

表1 SkewnessおよびKurtosisの計算結果

$u$	1.0	1.5	2.0
対象データ数	4,426	5,597	6,202
データ比率[%]	42.9	54.3	60.1

(注1)  $| \text{Skewness} & \text{Kurtosis} | \leq u$

(注2) 調査データ数 = 10,312

この結果から、全体の約6割のデータがSkewnessとKurtosisとともに2以下の値を示しており、正規性が高いことが分かる。また、残りのデータについても、1カテゴリの分布は正規性の高い各クラスタごとの分布で構成された混合分布と見なすことができる(詳しくは他の機会に委ねる)。したがって、区間推定法による効果の期待が持てることが予想される。

#### 4. 音声標準パターンの作成

図2に音声標準パターンの作成処理手順を示す。まず全データを所定のマルチテンプレート数と同数になるようにクラスタリングを行い、各クラスタごとのデータを平均化し、仮の標準パターンとする。データ




図2 音声標準パターン作成手順

のデータを平均化し、仮の標準パターンとする。データ数が多ければこれを標準パターンとしても充分な結果を得られることが報告されている<sup>[2]</sup>。今回は、次にテン

プレートごとの位置関係を壊さぬよ

うに仮の標準パターンを区間推定法によって拡張させ、その結果を真の標準パターンとして登録する。

図3に区間推定法によるパターン分布推定方式の概念図を示す。ここで、分布1は今回使用した実データの分布、分布2は分布1を区間推定法によって拡張した分布、分布3は多数の学習データを用いた場合に予想される分布、 $t_1$ ,  $t_2$ は信頼区間、a, b, cは各クラスタを代表する仮の標準パターン、A, B, Cは仮の標準パターンの位置関係を壊さぬように拡張して作成した真の標準パターンとする。なお図3は説明の便宜上、次元数1、マルチテンプレート数3で示してある。




図3 標準パターンの分布推定

具体的な計算方法は、学習データ  $x_j$  ( $j=1 \sim 83$ ) を正規分布と仮定した母集団からの任意標本集団と見なせ

ば、母集団分布  $p(x: \theta)$  から抽出した母平均  $\mu$  の  $(1-\alpha) \times 100\%$  の信頼区間を、以下に示す区間推定法の式によって求める。

$$\bar{x} - t_{\alpha/2} \frac{s}{\sqrt{n-1}} < \mu < \bar{x} + t_{\alpha/2} \frac{s}{\sqrt{n-1}}$$

ここで、 $t_{\alpha/2}$  は推定の信頼度を示し、自由度  $(n-1)$  の  $t$  分布に従う係数とする。ここで求めた母平均の推定区間の範囲内で学習データの位置関係を崩さぬよう学習データ分布を拡張し、パターン a, b, c をそれぞれ A, B, C に置き換え、それを標準パターンとして登録する。

#### 5. 認識評価

第2章で述べた認識方式を用いて、各クラスタごとのデータを平均化して作成した標準パターン(図3の a, b, c)と、統計的推定手法を用いて作成した標準パターン(図3の A, B, C)の認識評価実験を行った。実験条件は、認識カテゴリを10数字、ハイ、イイ、制御語等の32単語、マルチテンプレート数を1カテゴリあたり8パターンとし、男性83名の音声データを用いたオープンおよびクローズによる評価である。その結果を表2に示す。

表2 認識評価実験結果

標準パターン種類	オープン	クローズ
従来方式で作成	89.69 %	98.09 %
推定法を利用して作成	92.77 %	98.84 %

いずれも統計的推定手法を用いて学習データ分布を拡張させた場合のほうが良好な認識結果となっていることが分かる。

#### 6. まとめ

音声データが正規性の高い分布状態を示していることに基づき、少数の音声データから統計的推定手法を利用して不特定話者離散単語音声認識用の音声標準パターンを作成する方法を提案し、その有効性を示した。今後は、この方式を組み込んで開発したアプリケーションシステムを利用して、実フィールドにおける本方式の有効性を検証し、更なる認識率の向上を目指したい。

#### 参考文献

- [1] 和田,梅澤,山本：“少数の学習データによる不特定話者用標準パターン作成方法”，日本音響学会講演論文集,2-Q-13,pp.183-184,1992
- [2] 山田他：“複数マッチング特徴による不特定話者音声認識方式の検討”，音響学会講演論文集,1987