

単語の頻度と音響の特徴を利用した SVMによる無効入力の見捨て

藤田 洋子^{†1} 竹内 翔大^{†1} 川波 弘道^{†1}
松井 知子^{†2} 猿渡 洋^{†1} 鹿野 清宏^{†1}

実環境で、音声認識を用いた音声情報案内システムを移動させる場合には、雑音などの音声以外の入力やユーザ同士の背景会話などが混入されてくることがある。これらの入力はシステムの誤作動・誤認識を引き起こし、システムの応答性能を低下させる原因となる。そのため、システムへの入力として適当な入力（有効入力）と不適当な入力（無効入力）の識別を行い、無効入力を見捨てることにより、無効入力に対する応答処理を行わないことが重要となる。

一般的に有効入力と無効入力を識別には音響的特徴が用いられる。しかし、入力音の音声認識結果から得られる言語的な情報を使うことにより、無意味な認識結果が出力される雑音の識別に加え、システムのタスクの言語的な特徴を反映させた有効入力、無効入力を識別することが可能になると考えられる。そこで本稿では、Bag-of-Words (BOW) を特徴量とした Support Vector Machine (SVM) による無効入力の識別を検討した。実環境音声認識システム「たけまるくん」の入力データを用いた実験では、GMM に基づく無効入力の識別と比べ、分類誤り率を 23.30% から 15.90% に削減することができた。また、BOW に GMM から得られる音響尤度、発話時間や SNR を組み合わせた手法についても検討した。その結果、分類誤り率を 13.60% まで削減することができた。

Rejection of Invalid Input Using SVM based on BOW and acoustic features

YOKO FUJITA,^{†1} SHOTA TAKEUCHI,^{†1}
HIROMICHI KAWANAMI,^{†1} TOMOKO MATSUI,^{†2}
HIROSHI SARUWATARI^{†1} and KIYOHIRO SHIKANO^{†1}

On a real environment speech-oriented information guidance system, a valid and invalid input discrimination process is important as invalid inputs such as noise, laugh, cough and meaningless utterances lead to unpredictable system

responses.

Generally, acoustic features such as MFCC are used for discrimination. Comparing acoustic likelihoods of GMMs (Gaussian Mixture Models) from speech data and noise data is one of the typical methods. In addition to that, using linguistic features, such as speech recognition result, is considered to improve discrimination accuracy as it reflects the task-domain of invalid inputs and meaningless recognition results from noise inputs. In this report, the authors propose to introduce Bag-of-Words (BOW) as a feature to discriminate between valid and invalid inputs. Support Vector Machine (SVM) is also employed to realize robust classification. Experiments using real environment data from the guidance system "Takemaru-kun" were conducted. By applying BOW and SVM, the classification error rate (CER) is reduced to 15.90% , from 23.30% when using GMMs. In addition, experiments using features combining BOW with acoustic likelihoods from GMMs, SNR and duration were conducted, improving the CER to 13.6% .

1. はじめに

実環境で音声認識を行う場合には、非音声も含めたさまざまな音の入力を想定しておく必要がある。音声認識を用いた音声情報案内システムを移動させる場合には、システムの入力として適当である発話（有効入力）以外が入力があることになり、このような入力が入力システムの誤作動・誤認識の原因になる。このため、システムへの入力としては不適当な入力（無効入力）は見捨て、無効入力に対する応答は行わせないことが望ましい。

無効入力の識別には一般的に Mel-Frequency Cepstrum Coefficient (MFCC) 特徴量などの音響的特徴が使われており、混合ガウス分布モデル (Gaussian Mixture Model : GMM) による音響尤度を用いた識別手法が代表的である¹⁾。また、音声と雑音との識別においては、音声区間検出の手法として音声認識結果から得られる言語的な制約を用いる手法が提案されており²⁾、言語的な情報を用いた雑音と音声の識別がある程度可能であることが分かっている。そこで、本稿では音声認識結果から得られた Bag-of-Words (BOW) を特徴量とした Support Vector Machine (SVM) による無効入力の識別手法を検討する。音声認識結果に含まれる有効入力に出現しやすい単語や無効入力の認識結果の傾向を利用することができ

^{†1} 奈良先端科学技術大学院大学 情報科学研究科

Graduate School of Information Science, Nara Institute of Science and Technology

^{†2} 統計数理研究所

The Institute of Statistical Mathematics




図1 「たけまるくん」の応答処理の流れ
Fig. 1 Processing flow of “Takemaru-kun.”

れば、システムのタスクを考えた上で有効入力と無効入力を識別することが可能になると考える。また、BOWに音響尤度などを組み合わせ、識別精度を向上させる検討も行う。

以下、2節では実験に用いた音声情報案内システム「たけまるくん」と「たけまるくん」から得られた無効入力について説明し、3節では従来手法としてGMMを用いた環境雑音の識別手法を述べる。4節では本稿で提案するSVMを用いた無効入力の識別手法を説明し、5節にてその性能評価実験の結果を示し、6節でまとめを行う。

2. 音声情報案内システム「たけまるくん」

2.1 システムの概要

「たけまるくん」³⁾とは、奈良県生駒市の北コミュニティセンターに常設されている音声情報案内システムである。「たけまるくん」は、質問と正しい応答のペアをデータベース化した質問応答データベース (Question and Answer Database: QADB) を用い、データベース検索による一問一答方式の応答を行っている。「たけまるくん」の主な応答内容としては、施設利用者に対する施設・観光案内、エージェント (たけまるくん) に対する質問、現在の時間、天気、ニュースなどがある。この時の「たけまるくん」における処理の流れを図1に示す。

2.2 使用データ

「たけまるくん」は2002年11月の運用開始以降、すべての入力データを収集している。この内、2004年10月までの2年間分のデータは聴取による年齢層、性別、有効入力/無効入力のラベル、雑音などタグの付与及び書き起こし作業が終了している。本稿における有効入力、無効入力の分類はこのラベルに従ったものである。これをより詳細に分類した結果を表1に示す。表1において、無効入力は人の音声による「無効発話」および「咳」、

表1 「たけまるくん」の入力データの分類結果 (2002.11~2004.10)
Table 1 Input data of “Takemaru-kun.”

| カテゴリ | | 発話数 | 合計 |
|------|----------|-------|--------|
| 有効入力 | 大人発話 | 20436 | 106325 |
| | 子供発話 | 85889 | |
| 無効入力 | 無効発話 | 26319 | 122939 |
| | 背景会話 | 13348 | |
| | 発話不明瞭 | 11991 | |
| | 意味のない発話 | 12937 | |
| | 音声区間検出ミス | 1417 | |
| | オーバーフロー | 7347 | |
| | レベル不足 | 727 | |
| | 咳 | 6232 | |
| 雑音 | 50756 | | |

※無効入力のタグは重複を許している。
※雑音タグが付与されていても発話内容がシステムに対する入力として有効な発話は有効入力に分類されている。

「笑い声」、それ以外の非音声の「雑音」に大きく分類している。「無効発話」におけるタグの「背景会話」とは発話者の背後で他人の会話が重なって聞こえるもの及び明らかにシステムに対する発話ではなくマイクの周辺で会話されている発話、「発話不明瞭」とは音声聞き取りづらく客観的に判別できないもの、「意味のない発話」とはフィルターや「マイクテスト」などのシステムからの情報提供が目的ではない発話、「音声区間検出ミス」とは文頭もしくは文末が欠けている発話、「オーバーフロー」は発話者の声が大きすぎて、音割れを起こしている発話であり、「レベル不足」は入力音が小さすぎて発話内容が聴取できない発話を示している。ただし、これらのタグは重複している。また、雑音タグが与えられていても、発話内容がシステムの入力として有効である場合は有効入力として分類している。

3. GMMを用いた無効入力の識別方法

無効入力を識別する先行研究としては、GMMや主成分分析を用いる手法がある¹⁾⁴⁾。今回は、代表的な手法としてGMMを用いた識別手法を取りあげる。一般的に、この手法ではMFCC特徴量から識別したい音のクラスごとにGMMを作成し、新たな音が入力されてきた場合、この入力音の各GMMに対する時間平均の尤度を計算し、入力音がどの音のクラスにもっとも類似しているかにより識別を行う(図2)。

今回はこのGMMを用いた手法を従来手法と位置づける。本実験では、GMMは音響特徴量が大きく異なると考えられるクラスごとに作成した。有効入力として「大人」発話、「子




図 2 GMM による入力識別
Fig.2 Input discrimination by GMM

$$\min_{\mathbf{w}, b, \xi} \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^l \xi_i \quad (1)$$

$$\text{Subject to } y_i(\mathbf{w}^T \phi(\mathbf{x}_i) + b) \geq 1 - \xi_i,$$

$$\xi_i \geq 0, i = 1, \dots, l.$$

\mathbf{w} : 識別関数のパラメータ

C : コストパラメータ

ϕ : 非線形関数

$$\min_{\mathbf{w}, b, \xi} \frac{1}{2} \mathbf{w}^T \mathbf{w} + C_+ \sum_{\{i: y_i=1\}} \xi_i + C_- \sum_{\{i: y_i=-1\}} \xi_i \quad (2)$$

$$\text{Subject to } y_i(\mathbf{w}^T \phi(\mathbf{x}_i) + b) \geq 1 - \xi_i,$$

$$\xi_i \geq 0, i = 1, \dots, l.$$

供」発話, 無効入力として「無効発話」, 「咳」, 「笑い声」, 「雑音」の計 6 クラスがある.

4. SVM を用いた無効入力の識別方法

本稿では, BOW を特徴量とした無効入力の識別を検討する. しかし, BOW は次元が非常に大きい特徴量であるため, 学習手法によっては過学習の可能性がある. そこで, 過学習を起こすことが少ないと言われている SVM を用いる.

4.1 SVM

SVM は教師あり学習機械であり, 2 クラス分類問題を対象とする. SVM はカーネル関数を用いて, 与えられたデータを高次元へと写像し, 写像した空間において 2 クラスに分類する. その際に 2 クラス間のマージンが最大となる識別境界を求める. 今, n 次元の特徴量ベクトル $\mathbf{x}_i \in R^n, i = 1, \dots, l$ (l : サンプル数) とラベル $y_i \in \{1, -1\}$ のペア集合が与えられたとすると, 次の式 (1) に従って, 2 クラス分類のための識別境界が求められる. ξ_i はスラック変数であり, これによりある程度の誤分類を許容しつつマージンの最大化を行う. また, この式 (1) を式 (2) へと拡張することにより, 正例と負例の数がアンバランスな問題に対処できる. 具体的には, 分類誤りに対するコストパラメータ C を, 正例を負例とする誤りのコストパラメータ C_+ と負例を正例とする誤りのコストパラメータ C_- に分けて, 2 つの誤り率のバランスをとる. コストパラメータの値は事後的に設定した.

4.2 特徴量

特徴量の選択は, SVM の識別性能に大きな影響を与える. 本実験では以下の特徴量を検討した.

・ GMM による音響尤度 (GMM)

3 節において述べた従来手法においてクラスごとに作成した 6 つの GMM の音響尤度を要素とする 6 次元のベクトル.

・ Bag-of-Words (BOW)

音声認識結果に含まれている単語の出現頻度を要素とした特徴量ベクトル. 数え上げる単語は単語辞書 (Wordlist) 中にあるものだけに限る. Wordlist は学習データより作られるが, この時全データを用いず, 有効入力 (もしくは無効入力) のデータから Wordlist を作ることもできる. どのような単語がよりよい特徴量となるかを調べるため, 今回は以下のような Wordlist を用いた.

- すべての音声認識結果から作った Wordlist (4482 単語)
- 有効入力の音声認識結果から作った Wordlist (3838 単語)
- 無効入力の音声認識結果から作った Wordlist (2850 単語)

・ 発話時間

音声認識エンジン Julius⁵⁾ による振幅と零交差に基づく音声区間検出により一発話と見なされた入力音の時間.

・信号対雑音比 (Signal to Noise Ratio: SNR)

一発話ごとに算出した SNR の値. 入力音をフレームに分割し, 便宜的にそのフレームの中で平均パワーの大きいフレームの上位 10% を信号区間, 平均パワーの小さいフレームの下位 10% を雑音区間と考え, 式 (3) より求める. P_S は信号区間の平均パワー, P_N は雑音区間の平均パワーを表す.

$$SNR = 10 \log_{10} \frac{P_S - P_N}{P_N} \quad (3)$$

4.3 マルチカーネル法

一般的に SVM ではすべての特徴量ベクトルから各データのカーネル値を計算し, 識別境界を求める. しかし, 傾向の異なる複数の特徴量を用いる場合, 各特徴量間の値の大きさの違いや次元数の違いを考慮する必要がある. そこで本稿ではマルチカーネル法を用いる.

データ $\mathbf{x}_i, \mathbf{x}_j$ のカーネル値 $k(\mathbf{x}_i, \mathbf{x}_j)$ を i, j 成分とする行列のことをグラム行列と呼ぶ. このグラム行列を特徴量ごとに算出し, 足し合わせてから識別境界を求める手法をマルチカーネル法と呼ぶ. 特徴量の種類が M 個の時, マルチカーネル法は式 (4) により表すことができる.

$$K(\mathbf{x}_i, \mathbf{x}_j) = \sum_{c=1}^M k_c(\mathbf{x}_i, \mathbf{x}_j) \quad (4)$$

5. 評価実験

本実験における目的は, 次の 2 つである.

- 4 節で挙げた BOW などの特徴量を用いた SVM による有効入力と無効入力の識別精度を評価すること
- 複数の特徴量を組み合わせて, 識別精度の向上をはかること

そこで以降のような実験を行った.

5.1 実験データ

本実験において使用するデータを表 2 に示す. なお, 表 2 の学習データと GMM の学習データは一致させているが, そのより詳細なデータを表 3 に示す.

5.2 評価方法

本実験における評価尺度に分類誤り率 (Classification Error Rate: CER) を用いる. また,

表 2 実験データ

Table 2 Experiment data

| | 有効入力 | 無効入力 | 計 |
|--------|------|------|-------|
| 学習データ | 7607 | 7274 | 14881 |
| テストデータ | 3782 | 3902 | 7684 |

表 3 GMM の学習条件

Table 3 Training conditions of GMM

| | | | |
|------------|---|------|------|
| 学習 データ数 | 有効入力 | 大人 | 1053 |
| | | 子供 | 6554 |
| | 無効入力 | 無効発話 | 3640 |
| | | 咳 | 29 |
| | 笑い声 | 287 | |
| | | 雑音 | 3318 |
| 標準化/量子化 | 16kHz/16bit | | |
| 窓長 | 25msec | | |
| 窓シフト長 | 10msec | | |
| 特徴量 | MFCC (12 次元), Δ MFCC, Δ パワー | | |
| 混合数 | 128 | | |

表 4 実験条件

Table 4 Experiment condition

| | |
|----------|-----------------------------|
| 音声認識エンジン | Julius4.0.2 ⁵⁾ |
| 形態素解析器 | Chasen2.3.3 |
| SVM ツール | LIBSVM ⁶⁾ |
| カーネル関数 | Radial Basis Function (RBF) |
| パラメータ C | 0.01~10000 (10 倍刻み) |

誤り傾向などを調べるための尺度として, 無効入力を有効入力に誤分類する誤り率 (False Acceptance Rate: FAR) と有効入力を無効入力と誤分類する誤り率 (False Rejection Rate: FRR) を用いる (式 (5)-(7)).

$$CER = \frac{\text{誤分類したデータ数}}{\text{全データ数}} \times 100 \quad (5)$$

$$FAR = \frac{\text{無効入力を有効入力として誤分類した数}}{\text{無効入力のデータ数}} \times 100 \quad (6)$$

$$FRR = \frac{\text{有効入力を無効入力として誤分類した数}}{\text{有効入力のデータ数}} \times 100 \quad (7)$$

5.3 実験 1: 各特徴量の性能

5.3.1 実験方法

実験 1 では 4 節で述べた特徴量を用い, SVM を用いて有効入力と無効入力の識別を試み

表 5 SVM による有効入力と無効入力の識別結果
Table 5 Result of invalid input identification by SVM

| | | CER(%) | FRR(%) | FAR(%) |
|-------------------------|----------------------|--------------|--------|--------|
| 従来手法 (GMM の最大音響尤度による識別) | | 23.30 | 13.96 | 32.34 |
| SVM による識別 | GMM | 19.59 | 10.97 | 27.93 |
| | BOW(Wordlist:すべての入力) | 15.94 | 18.14 | 13.81 |
| | BOW(Wordlist:有効入力のみ) | 15.90 | 18.11 | 13.76 |
| | BOW(Wordlist:無効入力のみ) | 16.20 | 18.38 | 14.10 |
| | 発話時間 | 22.44 | 17.93 | 26.81 |
| SNR | | 32.20 | 25.62 | 38.57 |

る。3節で述べた「大人」発話、「子供」発話、「無効発話」、「咳」、「笑い声」、「雑音」の6クラスのGMMを用いた無効入力の識別手法を従来手法として考え、SVMによる識別手法の結果と比較する。実験条件は表4の通りである。

5.3.2 実験結果

実験1の結果を表5に示す。SVMを用いた識別においては、SNRを特徴量としたSVMを除くすべての場合でCERを従来手法よりも低く抑えられた。BOWを特徴量としたSVMが最良の結果であり、従来手法と比較しCERを23.30%から15.90%に改善できた。またGMMの音響尤度を特徴量としたSVMと比べてもCERを19.59%から15.90%に改善できている。このことから、無効入力の識別におけるBOWの有効性が示された。

またBOWに着目すると、3種類のWordlistの内、有効入力から作成したWordlistによるBOWのCERがもっとも低かった。ただし、これらの差は小さく、各Wordlistに含まれている単語も類似していたことから、どれを用いても問題はなかったと思われる。なお、以降のBOWでは有効入力から作られたWordlistを用いている。

5.4 実験2: 複数の特徴量の組み合わせ

5.4.1 実験方法

マルチカーネル法を用いて複数の特徴量を組み合わせた無効入力の識別を行う。今回は特徴量を加えるごとに、識別精度がどのように変動していくのを見るため、実験1において有効であった特徴量を順番に加えていく実験方法を採用した。なお、実験条件は実験1と同じく表4の通りである。

5.4.2 実験結果

実験2の結果を図3に示す。本実験では「BOW, GMM, 発話時間, SNR」のすべての特徴量を用いた結果が最良であり、CERを13.60%に抑えることができた。これは従来手法




図 3 マルチカーネル法を用いた場合の識別性能
Fig. 3 Result of invalid input identification by Multiple kernel

表 6 学習データとテストデータの CER
Table 6 CER of training data and test data

| | 学習データ | テストデータ |
|---------------------------|-------|--------|
| 従来手法 (GMM を用いた識別) | 18.83 | 23.30 |
| SVM (GMM) | 14.29 | 19.59 |
| SVM (BOW) | 7.71 | 15.90 |
| SVM (BOW, GMM, 発話時間, SNR) | 5.14 | 13.60 |

と比較すると9.7ポイント削減できている。また、表6に学習データ、テストデータのCERを比較した結果を示す。GMMの尤度を用いた場合は5%程度だった学習データとテストデータのCERの差がBOWを用いると8%程度に上がっているため、過学習が起こっている可能性が考えられる。この影響を減らすためには学習データを増やすことが効果的である。

5.5 考察

本実験ではCERによる識別精度の評価を行ってきたが、FARとFRRにばらつきがあり、表5における従来手法とBOWを特徴量にしたSVMのFRRを比較するとBOWの方が劣化している。そこで、4節で説明したコストパラメータ C_+ , C_- を調整し、このFARとFRRのバランスを変動させ、FARとFRRの両方を削減することができないか調べる。コストパラメータ C と C_+ , C_- を式(8)によって表し、パラメータを変動させることによって得られた曲線を図4に示す。




図 4 重みかけた場合における FAR と FRR の変化
Fig. 4 Transition of FAR and FRR using cost-parameter

$$C = C_+ + C_- \quad (8)$$

今回は従来手法と GMM を特徴量にした SVM, BOW を特徴量にした SVM, 「BOW, GMM, 発話時間, SNR」を特徴量にした SVM の比較を行う。図 4 により FRR を従来手法と同程度に固定した場合であっても, 他の手法の FAR は改善できていることが確認された。また, FAR と FRR が等しくなる点においても, 「BOW, GMM, 発話時間, SNR」を特徴量にした SVM の結果がもっとも良い。

次に各カテゴリ別に見た CER を表 7 に示す。GMM の音響尤度を用いた従来手法と SVM では, 「意味のない発話」や「音声区間検出ミス」における CER が 50% 前後だったが, BOW を用いることにより 20% 程度に改善できている。また, 従来手法と BOW を用いた SVM を比較すると, BOW を用いることにより「有効入力」, 「オーバーフロー」, 「咳」の誤りが増えていたが, これは音声認識誤りによるものだと考えられる。なお, 従来手法と「BOW, GMM, 発話時間, SNR」を特徴量にした SVM を比較すると, CER が悪化しているのは「オーバーフロー」のみであり, 残りはすべて改善されていた。

6. ま と め

無効入力を識別する手法として BOW を特徴量とした SVM を提案し, GMM による識別手法と比較して CER を 23.30% から 15.90% に改善できた。また, 複数の特徴量を組み合わせることにより識別性能を高め, CER を 13.6% まで減少させることができた。

表 7 各カテゴリごとの分類誤り率の傾向調査
Table 7 Classification error rate of each category

| | | テストに含まれる データ数 | 従来手法 (GMM) | SVM | | Multiple Kernel+SVM BOW, GMM, 発話時間, SNR |
|-------------------|----------|------------------|---------------|-------|-------|---|
| | | | | GMM | BOW | |
| 有効入力 | | 3782 | 13.96 | 10.97 | 18.11 | 10.60 |
| 無効 発 入 力 | 背景会話 | 926 | 25.49 | 20.30 | 16.41 | 12.85 |
| | 発話不明瞭 | 329 | 38.60 | 41.64 | 24.32 | 28.88 |
| | 意味のない言葉 | 907 | 50.28 | 47.30 | 19.18 | 28.67 |
| | 音声区間検出ミス | 547 | 58.32 | 58.68 | 22.12 | 27.24 |
| | オーバーフロー | 63 | 19.05 | 38.10 | 42.86 | 46.03 |
| | レベル不足 | 215 | 35.81 | 6.98 | 0 | 0 |
| | 咳 | 30 | 10.00 | 0 | 3.33 | 3.33 |
| 笑い声 | 160 | 7.50 | 5.63 | 8.75 | 5.63 | |
| 雑音 | 1395 | 12.90 | 8.67 | 3.66 | 5.02 | |

謝辞 本研究の一部は, 戦略的創造研究推進事業「共生社会に向けた人間調和型情報技術の構築」(JST/CREST) および文部科学省科学研究費基盤研究 (A) “新しい音声メディアによるユニバーサルコミュニケーションの研究”(研究課題番号: 19200009) の援助を受けて行われた。

参 考 文 献

- 1) 中村敬介, 西村竜一, 李晃伸, 猿渡洋, 鹿野清宏, “実環境音声情報案内システムにおける環境雑音および不要発話の識別,” 電子情報通信学会技術研究報告 SP2003-172, pp13-18, 2004.
- 2) 酒井啓行, ツインツアレク トビアス, 川波弘道, 猿渡洋, 鹿野清宏, 李晃伸, “実環境ハンズフリー音声認識のための音響モデルと言語モデルに基づく音声区間検出と認識アルゴリズム,” 電子情報通信学会技術研究報告 SP2007-17, vol.107, pp.55-60, 2007.
- 3) R. Nisimura, A. Lee, H. Saruwatari, K. Shikano, “Public Speech-oriented Guidance System with Adult and Child Discrimination Capability,” *In Proc. ICASSP 2004*, pp.433-436, 2004.
- 4) 鈴木智詞, 竹内義則, 松本哲也, 工藤博章, 大西昇, “聴覚障害者のための警告音の識別,” 電子情報通信学会技術研究報告 SP2004-156, Vol.2004, No.154-163, 2005.
- 5) A. Lee, T. Kawahara and K. Shikano, “Julius - an open source real-time large vocabulary recognition engine,” *Proc. of Eurospeech*, pp1691-1694, 2001.
- 6) Chih-Chung Chang, Chih-Jen Lin: LIBSVM : a library for support vector machines, <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.