

モバイル端末上における行動認識のための距離関数を用いた分類モデル生成手法の提案と評価

木村 周^{†1} 猪俣 敦夫^{†1} 藤川 和利^{†1}

近年の情報技術の発展に伴い、モバイル端末を用いたコンテキストウェアサービスが注目されてきている。コンテキストウェアサービスの実現には、ユーザの行動を正確に推定することと、モバイル端末への負荷を低くする必要がある。モバイル端末上での行動認識に認識対象者から得た分類モデル(特定行動者モデル)を用いた場合は、モバイル端末への負荷が低く、高い精度で行動を認識できるが、認識対象者自身の各行動の訓練データを用いるため、ユーザ負担が高い。低いユーザ負担で、高い認識精度を実現する個人適応手法を用いた分類モデル(個人適応モデル)は、認識対象者の服装、体調、外の天候などのデータ収集環境によって、認識精度が大きく変わり、認識性能が低い。本論文では、モバイル端末上での行動認識を行うために、あらかじめ収集した認識対象者以外の不特定多数の者の訓練データから、距離関数を用いて、認識対象者の各行動と類似した者の行動データのみを抽出して分類モデルを生成する手法を提案し、無作為抽出モデルと特定行動者モデルとの比較実験を行った。実験の結果、提案手法によって、少ない訓練データと低いユーザ負担で、認識性能が高い分類モデルを生成できることを確認した。

Activity recognition on a mobile device by generation method of classification model

SHU KIMURA,^{†1} ATSUO INOMATA ^{†1}
and KAZUTOSHI FUJIKAWA ^{†1}

With the development of information technology, context-aware service on a mobile device has attract attention. For context-aware service, it is necessary to give better accuracy and reduce the load on a mobile device. While a user-specific model obtained from a subject gives high recognition rate with a little of load on a mobile device, there is the matter of an enforced load for a subject to obtain its training data. Personalized general model by personalization techniques with a little of user burden has a problem of generalization ability. We propose a generation method of classification model from extracting data

in all training data by distance method with a little of user burden and training data. We generate classification model by extracting data in all training data with distance method. We confirm that classification model by our method can give high recognition rate and generalization ability with a little of user burden and training data.

1. はじめに

現在のユビキタス環境において、ユーザのコンテキスト状態に応じて適切なサービスを提供するコンテキストウェアサービスが注目を集めている。コンテキストウェアサービスの例として、遠隔介護におけるADL(Activity of Daily Living)モニタリング¹⁾や子供の防犯・安全²⁾などが挙げられる。コンテキスト情報の中でも、行動情報は、よりユーザに密着した情報であり、現在普及している加速度センサーで推定できるため、本稿では、モバイル端末の加速度センサを用いた行動認識に取り組む。モバイル端末上での行動認識では、簡単にサービスを利用できること、モバイル端末への負荷、正確な推定が重要になる。

正確な行動推定は、サービスを実現するために不可欠な要素であり、行動認識では、分類モデルを用いて認識を行うため、分類モデルの性能が重要になる。分類モデルの性能は、ある時の認識対象者のデータセットに対する認識精度だけでなく、複数の場合でのデータセットでも高い精度で行動を認識できる(汎化能力が高い)必要がある。分類モデルの認識精度が、ある時は認識精度が高く、別の時は認識精度が低い場合は、分類モデルを様々なサービスに応用することが難しくなる。このため、分類モデルの性能は、認識対象者の複数の時の認識精度の平均とばらつき(標準偏差)で測る必要がある。

簡単なサービス利用とは、サービスの利用時に認識対象者に要求する訓練データ数が少なく、ユーザ負担が低いことである。上述したコンテキストウェアサービスでは、子供や高齢者を対象としたものが多く、サービスを利用時に、ユーザに大量のデータの収集を要求することは、ユーザ負担が高い。また、大量のデータを要求する場合、データ収集後に分類モデルを生成するため、サービスの利用に時間がかかり、現実的でない。

モバイル端末への負荷は、モバイル端末上で分類モデルを用いて行動を認識する際の計算量による電池消費量である。モバイル端末への負荷を軽減するためには、特徴量、サンプリ

^{†1} 奈良先端科学技術大学院大学
Nara Institute of Science and Technology

ング周波数, 分類モデルのサイズの削減があるが, 中でも, 分類モデルのサイズの削減が汎用性が高く最も効果的な方法である. 分類モデルのサイズを削減する方法としては, 特徴量, 分類器の選定, 訓練データ数の削減がある. 特徴量や分類器は, 扱う問題によって効果が変わるため, 分類モデルのサイズを小さくできても, 認識性能が変化する可能性があり, 汎用性が低い. 訓練データ数の削減は, 扱う問題に影響を受けないため, 汎用性が高く最も効果的な方法である.

以上より, モバイル端末上での行動認識では, 以下の3点が要求事項となる.

- 分類モデルの認識性能
- ユーザ負担
- 訓練データ数

本論文では, 低いユーザ負担と少ない訓練データで性能の高い分類モデルを生成する手法を提案し, 提案手法によって, 少ない訓練データと低いユーザ負担で, 認識精度と汎化能力が高い分類モデルを生成できることを報告する.

2. 関連研究

本章では, モバイル端末上で行動認識を行う際に用いる分類モデルについて説明する.

2.1 不特定行動者モデルによる行動認識

従来のモバイル端末の加速度センサを用いた行動認識として, Lin ら³⁾の研究がある. Lin らの研究では, 認識対象者以外の不特定多数の者から収集した訓練データで分類モデル(以下: 不特定行動者モデル)を用いて, 行動認識を行っている. 不特定行動者モデルを用いた行動認識は, 事前に収集した不特定他者の行動データを訓練データとするため, 認識対象者自身の訓練データを要求しないため, ユーザ負担が低い. しかし, 訓練データ数が多い場合は, 認識性能は高いが, モバイル端末への負荷が高くなり, 訓練データ数が少ない場合は, モバイル端末への負荷は低い, 認識性能が低下する.

2.2 特定行動者モデルによる行動認識

行動認識では, 認識対象者自身の行動データを訓練データとして生成した分類モデル(特定行動者モデル)のほうが, 不特定行動者モデルよりも認識性能が高いことが橋田ら⁴⁾の研究で証明されている. 特定行動者モデルを用いた行動認識は, 不特定行動者モデルに比べて, 少ない訓練データで高い性能の分類モデルを生成できる. しかし, 分類モデルを生成するための訓練データを認識対象者自身が収集する必要があるため, ユーザ負担が高い.

2.3 個人適応モデルによる行動認識

低いユーザ負担で, 特定行動者モデルに近い性能の分類モデルを生成する手法として, 個人適応がある. Stikic ら⁵⁾や Zhao ら⁶⁾の研究では, それぞれのアルゴリズムで認識対象者の大量の教師なしデータにラベル付けを行い, ラベル付けした教師なしデータを用いて分類モデルを生成する. 教師なしデータとは, 収集したデータに対して, それが表す行動情報(クラス)を持たないデータであり, 認識対象者が各行動データにラベル付けをする必要がないため, 教師ありデータに比べてデータ収集時のユーザ負担が低い. 教師なしデータは, 教師ありデータに比べてデータ収集時のユーザ負担が低い. しかし, 教師ありデータよりは, ユーザ負担が低い, 複数日間データを収集し続ける場合は, サービスの利用に時間がかかり, ユーザ負担が高くなる. よって, 認識対象者の短時間での教師なしデータを用いて個人適応した分類モデルを生成した場合はユーザ負担は低い, 環境によって認識精度が大きく変化するため, 認識性能が低い.

3. 提案手法

本論文では, 少ない訓練データと低いユーザ負担で, 認識性能が高い分類モデルを生成する手法を提案する. 具体的には, 認識対象者以外の不特定多数の者の各行動の訓練データから, 認識対象者の各行動データと類似度の高いデータを抽出して分類モデルを生成する. 類似データとしては, 認識対象者と身体的特徴に近い者の行動データと認識対象者の服装と似た者の行動データなどが考えられる. 本論文では, これらの類似データを距離関数を用いて抽出する. 図1は, 特徴空間上での各クラスでの特徴ベクトルの分布を表している. 図1より, 同じクラスの特徴ベクトル同士は, 他のクラスの特徴量ベクトルと比べて, 各次元の特徴量が類似するため, 特徴量空間では, 近い距離に分布し, まとまり(クラスター)を作る. さらに同じクラスの特徴量ベクトルでも, 似ているデータはより近い距離に分布する. よって, 例えば同じジョギングの行動データでも, ジョギングのペースや坂でのジョギングなどにより, さらにジョギングの中でさらに複数のまとまり(クラスター)を作ると考えられる.

本論文では, 認識対象者とあらかじめ用意したユーザの行動データが類似しているかの尺度として, 距離関数を用いる. 距離関数によって, 特徴量空間上の各特徴ベクトル同士の距離を測り, 距離の近い特徴ベクトルを類似データとする. 具体的には, 谷ら⁷⁾の研究で定義されている距離関数(以下: 行動者間距離)を用いる. 行動者間距離 d は, 特徴量空間において各次元の特徴量のデータは正規分布に従うことを仮定し, 以下の式で表される.

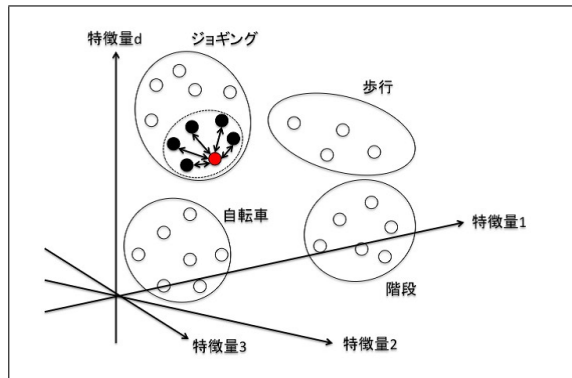


図 1 特徴空間上での特徴ベクトルの分布
Fig. 1 distribution of feature vectors in feature space

$$d = \sum_{i=1}^D \frac{(\mu_i^p - \mu_i^q)^2}{\sigma_i^p \sigma_i^q} \quad (1)$$

ここで、 μ^p, σ^p は、それぞれ、認識対象ユーザ p に対応する多次元正規分布の平均および分散であり、 μ^q, σ^q は、あらかじめ用意したユーザ q に対応する多次元正規分布の平均および分散である。また、D は、特徴量の次元数である。d の値が小さいことは、p と q の行動が類似していることを表し、d の値が大きいことは、p と q の行動が似ていないことをあらわす。

式 1 から、必要なパラメータは平均と分散だけなため、少量のデータのみでこれらのパラメータを取得できる。つまり、個人適応する際に、認識対象者に要求する教師ありデータ数が少量でよい。図 2 に、提案手法による行動認識の処理の流れを示す。図 2 について、以下に説明する。

(1) 不特定他者の教師ありデータの収集

最初に、認識対象者以外の不特定多数の者の各行動の教師ありデータを、モバイル端末の加速度センサーを用いて収集する。収集した加速度データから特徴量を抽出し、各行動のラベルを付与して訓練データを用意する。

(2) 認識対象者の教師ありデータの収集

次に、認識対象者の各行動の少量の教師ありデータを、モバイル端末の加速度セン

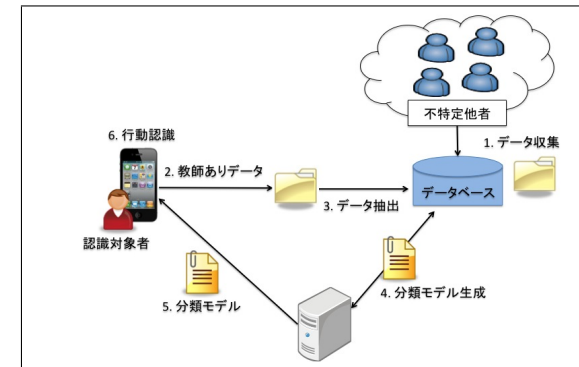


図 2 提案手法による行動認識
Fig. 2 activity recognition by proposed method

サーを用いて収集する。収集した加速度データから特徴量を抽出し、各行動のラベルを付与して訓練データを用意する。

(3) 訓練データの抽出

サーバ側で上述した距離関数を用いて、認識対象者の各行動データと不特定多数の者の各行動データの距離を計算し、距離の近いデータから順に抽出して、訓練データとする。

(4) 分類モデルの生成

認識対象者の各行動の少量の教師ありデータと、抽出された不特定他者の訓練データを用いて、分類モデルを生成する。

(5) 行動認識

認識対象者のモバイル端末の加速度センサーで各行動の加速度データを収集し、モバイル端末上で特徴量を抽出し、分類モデルを用いて行動を推定する。

4. 実験

本章では、提案手法の有効性を示すための実験について説明する。まず、実験条件を説明し、次に実験概要を示し、最後に評価を行う。

4.1 実験条件

本節では、実験条件について説明する。

4.1.1 データ収集

本論文では、モバイル端末として Samsung Galaxy S2 を用い、加速度センサーとして Samsung Galaxy S2 の 3 軸加速度センサーのみを用いる。認識対象行動は、「歩行」、「早歩き」、「ジョギング」、「階段の上り」、「階段の下り」、「自転車」の 6 つの行動を認識する。これらの行動を、モバイル端末をズボンの横ポケットに入れ、50Hz のサンプリング周波数で収集する。具体的には、67 人の被験者から上述した 6 種類の行動をそれぞれ 1 分 30 秒 ~ 2 分 30 秒収集した。また、67 人の被験者とは別に 1 名の被験者（認識対象者）から、訓練データとして 6 種類の行動を 30 ~ 50 分収集した。テストデータとして、4 日の別々の日に異なる服装、異なる場所で 6 種類の行動を 5 ~ 10 分収集した。

4.1.2 特徴量計算

加速度データからの特徴量の抽出では、データを一定時間のウィンドウに分割し、そのウィンドウごとに特徴量を抽出するスライディングウィンドウ方式を用いる。実験では、ウィンドウサイズを 128 個、オーバーラップを 50% に設定し、X, Y, Z, 合成加速度の 4 つのパラメータから、平均、分散、エネルギー、最大パワースペクトルとそれに対応した周波数、周波数領域のエントロピーの 6 つを特徴量として抽出した。平均、分散は、加速度の時系列データのものである。エネルギーは、各パラメータの時系列の加速度データに FFT を行い、その絶対値の合計として求める。合計値を求める際、直流成分と折り返しの部分を除く。1 つの軸の加速度データの FFT 成分を F_1, F_2, F_3, \dots とすると、エネルギーは式 2 で求められる。

$$Energy = \frac{1}{n} \sum_{i=2}^n |F_i|^2 \quad (n = \frac{w}{2} - 1) \quad (2)$$

最大パワースペクトルとそれに対応した周波数は、加速度の時系列データに FFT を行った際の最大値とそれに対応した周波数である。周波数領域のエントロピーは、FFT 成分 F_i から直流成分と折り返しの部分を除いた成分を、全成分の総和で正規化することによって、確立分布 p として式 3 より求める。

$$p(i) = \frac{|F_i|^2}{\sum_{j=2}^n |F_j|^2} \quad (i = 1, 2, \dots, n) \quad (3)$$

これより、エントロピーは式 4 で求める。

$$Entropy = - \sum_{i=2}^n p(i) \log p(i) \quad (4)$$

各パラメータごとに、上述した特徴量を用いるため、実験では 1 ウィンドウにつき 24 次元の特徴量（パラメータ 4 × 特徴量 6）を抽出する。

4.1.3 利用する分類器

分類モデルを生成する分類器は、オープンソースのデータマイニングツールで提供しているナイーブベイズ (NB), C4.5 の決定木 (DT), ニューラルネット (NN), LibSVM で提供しているサポートベクターマシン (SVM) を用いた。

4.2 提案手法の有効性の検証実験

4.2.1 実験 1: 訓練データ数ごとの提案モデルの認識精度の検証

この実験では、提案手法によって少ない訓練データ数でも、訓練データ数が多いときの認識精度を維持できることを実証する。実験方法としては、認識対象者の各行動の少量の教師ありデータを用いて、提案手法で定義した距離関数を用いて 67 人の被験者の中から、認識対象者の各行動データに類似した者の行動データから順に抽出して、分類モデル（提案モデル）を生成する。今回の実験では、提案手法による個人適応で認識対象者に要求する各行動の教師ありデータを 30 秒にした。抽出する被験者数は、1 人からはじめ 67 人になるまで 2 人ずつ増やす。提案モデルの比較対象として、67 人の被験者の各行動データに認識対象者の各行動の教師ありデータを加えたデータセットから無作為にデータを抽出して分類モデル（無作為抽出モデル）を生成したものをを用いる。抽出する被験者数は、提案モデルと同様である。訓練データ数が少ないときの、提案モデルと無作為抽出モデルの認識精度を比較し、提案モデルのほうが優れていることを示す。次に、比較的高い認識精度を得ることのできる最低訓練データ数を明確にし、その訓練データ数での電池消費量を測定し、訓練データ数が多いときと比較する。

4.2.2 実験 2: 提案モデルの認識性能の高さの検証

この実験では、提案モデルが認識性能が高いことを実証する。実験方法は、提案モデルと特定行動者モデルの複数のテストデータに対する認識精度を比較する。提案モデルは、実験 1 と同じ条件で生成したものをを用いる。特定行動者モデルは認識対象者が複数日間収集したデータセットを用いて生成する。また、提案モデルと事前実験 2 で生成した特定行動者モデルとの 4 つのテストデータに対する認識精度とその標準偏差を比較し、提案モデルが特定行動者モデルと認識精度と標準偏差と近いことを示し、提案手法により生成される分類モデル




図 3 訓練データ数ごとの提案モデルと無作為抽出モデルの認識精度の遷移

Fig. 3 recognition rate transition of proposed models and random extraction models each training data




図 4 訓練データ数ごとの提案モデルと無作為抽出モデルの認識精度

Fig. 4 recognition rate of proposed models and random extraction models each training data

ル (提案モデル) の認識性能の高さを実証する。

4.3 実験結果

4.3.1 実験 1 の実験結果と評価

図 3 に, SVM を用いたときの提案モデルと無作為抽出モデルの訓練データ数ごとの認識精度の遷移を示す. 図 3 の横軸は訓練データ数, 縦軸は認識精度を表す. また, 図 4 に, 訓練データ数が 2000, 5000, 8000, 11000 個のときの提案モデルと無作為抽出モデルの認識精度を示す. 図 4 の横軸は訓練データ数, 縦軸は認識精度を表す. 図 3, 4 より, 訓練データ数が少ないときに, 提案モデルのほうが, 無作為抽出モデルよりも認識精度が優れていることがわかる. これは, 提案手法によって, 認識対象者により類似した者のデータから順に抽出され, 分類モデルが生成されたためだと考えられる. また, 図 3, 4 より, 訓練データ数が多いときは, 提案モデルと無作為抽出モデルの認識精度がほぼ同じになっていることがわかる. これは, 提案モデルと無作為抽出モデルは同じデータセットから訓練データを抽出しているため, 訓練データ数が多いとき, 同じ訓練データを抽出する可能性が高くなるためである. よって, 提案手法を用いることで, 少ない訓練データ数でも訓練データ数が多いときと比べて認識精度を維持できることが示された.

次に, 訓練データ数ごとの提案モデルと無作為抽出モデルの電池消費量を比較した結果を図 5 に示す. 図 5 は, 2000, 5000, 8000, 11000 個の訓練データで生成した提案モデルの電池消費量であり, 横軸が経過時間 (分), 縦軸は電池残量 (%) を表す. 図 4 より, 2000 個




図 5 訓練データ数ごとの電池消費量

Fig. 5 battery consumption each the number of training data

の訓練データで生成した提案モデルと, 11000 個の訓練データ数で生成した無作為抽出モデルの認識精度は, どちらも約 82% であり, 同じである. しかし, 図 5 より, 11000 個の訓練データ数の無作為抽出モデルは 3 時間で電池が切れるのに対して, 提案モデルは 9 時間電池が持つことがわかる. 以上より, 提案手法によって, 認識精度を維持したまま, 訓練データ数を減らすことで, 大幅に電池消費量を軽減することができることが示された.

4.3.2 実験 2 の実験結果と評価

図 6 に, SVM を用いたときの提案モデルと特定行動者モデルの訓練データ数ごとの 4 つ

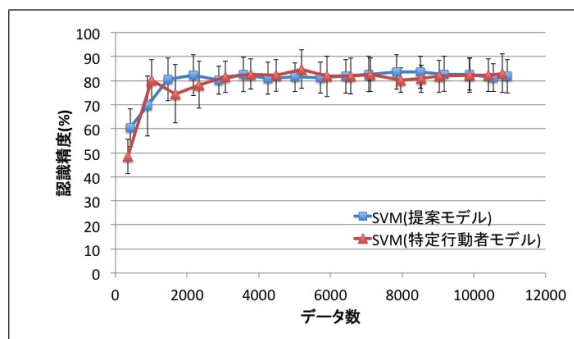


図 6 訓練データ数ごと提案モデルと特定行動者モデルの認識精度

Fig. 6 recognition rate of proposed models and user-specific models each training data

のテストデータに対する認識精度の平均を示し、図中の各点の上下方向の線は、4つのテストデータに対するの識別精度のばらつき(標準偏差)を表している。図6の横軸は訓練データ数、縦軸は認識精度を表す。図6より、全訓練データ数でも提案モデルと特定行動者モデルの認識精度に近いことがわかる。また、4つのテストデータに対する認識精度のばらつきも各訓練データで近いことがわかる。この結果から、認識対象者に類似した者のデータの認識精度へ与える影響は、認識対象者自身の行動データの認識精度へ与える影響とも類似していることがわかる。以上より、提案手法によって生成される分類モデルは、特定行動者モデルに近い性能であるため、性能が高い分類モデルであることが示せた。

4.4 考 察

今回の実験で、提案モデルが特定行動者モデルに近い性能を発揮したのは、67人の被験者の行動データの認識対象者との類似度が比較的高い者の訓練データを抽出したためだと考えられる。類似データの抽出の際、67人の被験者の行動データに認識対象者と類似度の高いものがない場合は、認識性能の高い分類モデルを生成することは難しい。反対に、67人の被験者の行動データが認識対象者と類似度が極端に高い場合は、過剰適応によって、分類モデルの認識性能が低くなる。また、今回の実験では、提案手法によって、訓練データ数を削減しても認識性能を維持できることを証明したが、最適な訓練データセットを抽出することは実現できていない。最適な訓練データセットとは高い認識性能を維持した上での最小のデータセットである。この最適な訓練データセットを抽出するためには、訓練データセットを動的に決定する仕組みが必要になる。これを実現するためには、認識性能に貢献する訓練

データの類似度の閾値を定め、その閾値までの訓練データをバランスよく抽出する方法が考えられる。

5. 結 論

本論文では、モバイル端末上での行動認識を実現するために、少ない訓練データ数と低いユーザ負担で認識性能の高い分類モデルの生成手法を提案した。本提案手法によって、認識性能を低下させずに大幅な訓練データの削減が可能であることを示した。また、本提案手法によって生成される分類モデルは、特定行動者モデルと同等の認識性能があるため、認識性能が高い分類モデルであるといえる。これらの結果より、提案手法により生成された分類モデルは、モバイル端末上での行動認識を実現できた。

参 考 文 献

- 1) Thi V. Duong, Hung H. Bui, Dinh Q. Phung, and Svetha Venkatesh. Activity recognition and abnormality detection with the switching hidden semimarkov model. Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition - Volume 1 - Volume 01, pp. 838-845, 2005.
- 2) 神崎啓. 携帯電話による GPS と加速度センサを用いた子どもの防犯・安全のためのコンテキスト推定の提案と実装. 修士学位論文, 奈良先端科学技術大学院大学, 2010-09/24.
- 3) Lin Sun, Daqing Zhang, Bin Li, Bin Guo, and Shijian Li. Activity recognition on an accelerometer embedded mobile phone with varying positions and orientations. In Proceedings of the 7th international conference on Ubiquitous intelligence and computing, pp. 548-562. Springer-Verlag, 2010.
- 4) 橋田尚幸, 大村廉, 今井倫太. 加速度センサを用いた日常行動識別における個人適応技術の識別精度への貢献. 情報処理学会研究報告. UBI, Vol. 2008, No. 66, pp. 69-74, 2008-07-10.
- 5) Maja Stikic, Kristof Van Laerhoven, and Bernt Schiele. Exploring semisupervised and active learning for activity recognition. In Proceedings of the 2008 12th IEEE International Symposium on Wearable Computers, pp. 81-88. IEEE Computer Society, 2008.
- 6) Zhongtang Zhao, Yiqiang Chen, Junfa Liu, Zhiqi Shen, and Mingjie Liu. Cross-people mobile-phone based activity recognition. In Proceedings of International Joing Conferences on Artificial Intelligence, pp. 2545-2550, 2011.
- 7) 谷真宏, 江森正, 大西洋史, 越仲孝文, 篠田浩一. 十分統計量を用いた教師なし話者適応における話者選択法. 情報処理学会研究報告. SLP, 音声言語情報処理, Vol. 2007, No. 129, pp. 85-89, 2007-12-20.