

肺音分類のためのスペクトル分離とロバストな類似度判定による特徴量抽出

Feature Extraction by Spectral Unmixing and Robust Similarity Detection for Lung Sound Classification

正田 備也[♥] 喜安 千弥[♥] 宮原 末治[♥]

Tomonari MASADA Senya KIYASU
Sueharu MIYAHARA

本論文では、肺音分類に有用なテンプレートを作成するために、大量の肺音データから良質な特徴量をふるい分ける手法を提案する。まず、FFTによりパワー・スペクトルを特徴ベクトルとして得る。次に、これらを部分的に重なる複数のグループにまとめてスペクトル分離を適用、各グループを少数の成分ベクトルの組で代表させる。こうして様々な各肺音から得られた成分ベクトルを集め、クラスタリングを多数回実行し、常に同じクラスターに属する成分ベクトル群を良質な特徴量として得る。実験では、看護師用教材 CD を使い、クラスタリング結果と実際の肺音のカテゴリとを比較する。

In this paper, we propose a method for extracting effective features from various lung sounds. We use those features to compose templates useful for lung sound classification. First, we obtain power spectra as feature vectors by FFT. Second, we make feature vector groups partially overlapping with each other and represent each group by a few component vectors provided by spectral unmixing. We put component vectors obtained from various lung sounds into a single set and conduct clustering repeatedly. We can regard the sets of component vectors belonging to the same cluster in all clustering results as effective features. In the experiment, we use a CD accompanying a textbook for nurses and compare clustering results with actual lung sound categories.

1. はじめに

聴診による診断は、人体にあまりダメージを与えず健康状態をチェックする非侵襲的 (noninvasive) 診断であるため、高度な医療技術の発達した現代においても頻繁に行われる。したがって、聴診による診断結果をデータ工学的に解析する手法の提案は、重要な課題である。そこで本論文では、正常な肺音と異常な肺音の分類や、異常な肺音の病態別分類に使うテンプレートを作成するために用いる、良質な特徴量を抽出する手法を提案する。肺音データは、WAV形式など通常の

音声ファイルとして与えられると仮定する。本論文では、肺音の採取位置や呼吸量・呼吸周期の情報など、音声データとしての肺音に関するメタデータは用いず、肺音分類のためのテンプレート作成に利用可能な特徴量を、様々な種類の肺音データの集合から抽出することを目的とする。その際、各肺音データが正常か異常か、異常の場合ほどの病態に対応するかの情報は用いない。つまり、教師なしの手法を提案する。

提案手法では、まず、適切な窓関数を利用し、窓を移動させながら高速フーリエ変換 (FFT: fast Fourier transform) を適用することで、1つの音声データから多数のパワー・スペクトルを得る。これらパワー・スペクトルは、周波数の種類の数と同じ次元をもつ特徴ベクトルと見なされる。次に、連続する複数の窓に対応するパワー・スペクトルを集め、これに独立成分分析 (ICA: independent component analysis) などのスペクトル分離手法を適用、スペクトルと同次元の少数のベクトルの組によって、与えられたスペクトルの集合を代表させる。ここに、提案手法の第1の特色がある。つまり、ある区間の音声データから得られる複数の特徴ベクトルについて、それらの次元を削減するのではなく、それらが少数のベクトルの混合で表されると仮定することによって、特徴量の削減をおこなう。なお、スペクトル分離が与えるこれら少数のベクトルを、成分ベクトルと呼ぶことにする。こうして、1つの音声データから、成分ベクトルが多数得られる。最後に、様々な肺音データから得られた多数の成分ベクトルを、どの肺音に由来するかに関係なく1つにまとめ、この成分ベクトルの集合に対してクラスタリングを十分に多い回数実行する。今回はクラスタリングに k -means を用いた。これは初期値に依存する手法であり、同じデータ集合に対して多数回実行することで、クラスタリングを経たデータ間の類似判定の信頼性が増すと思われる。つまり、クラスタリング結果全てにわたって同じクラスターに属する成分ベクトル群のみを、与えられた肺音群の特定の側面を良く表す特徴量とみなす。その一方、どの成分ベクトルと同じクラスターに属するかが、クラスタリング結果によって変わりうる成分ベクトルは、良質でない特徴量とみなして捨てることにする。ここに、提案手法の第2の特色がある。つまり、他の成分ベクトルとの間に本質的な類似関係があるかどうかをロバストに判定し、肺音分類のテンプレートに利用可能な成分ベクトルだけをふるい分ける。提案手法の詳細は第3節で、評価実験の結果は第4節で、それぞれ述べられる。

2. 関連研究

本論文で入力データとして与えられる肺音は、単一の音声データと仮定する。例えば、Murphy[1]が紹介している特殊な装置を利用すると、多重チャンネルの肺音データが得られるが、本論文では通常の聴診で得られる単一の肺音データを想定する。また、聴診位置、呼吸量・呼吸周期など肺音データに関するメタデータはないものとする。よって、特に、各肺音データが何周期分の呼吸に対応するかは未知である。

肺音解析への機械学習の利用は、ここ数年で急速に進んでいる。その様子は肺音研究に関する最新の書誌情報である R. A. L. E. Reference Collection[2]から知ることができる。だが、提案手法のように、多数のパワー・スペクトルを少数の成分の混合とみなすことによって特徴量を削減する手法はまだないようである。Gülerら[3]は平面上での視覚的分類のために、特徴空間を2次元に圧縮している。また、Pelletier[4]は、パワー・スペクトルをヒストグラムとみな

[♥] 正会員 長崎大学工学部 masada@cis.nagasaki-u.ac.jp

[♥] 非会員 長崎大学工学部 kiyasu@cis.nagasaki-u.ac.jp

[♥] 非会員 長崎大学工学部 miyahara@cis.nagasaki-u.ac.jp

し、ビンの特徴量を減らすことで特徴量を削減している。本論文では、FFT が与えるパワー・スペクトルの次元、つまり、周波数の多様性は保存し、複数のパワー・スペクトルを生成する成分の個数が少数だと仮定することで、特徴量を削減する。このように、多数の頻度分布や確率分布を、少数の成分の混合としてモデル化することで特徴量の削減をおこなうアプローチは、テキスト・マイニングでは文書集合に含まれる複数のトピックを単語の確率分布として抽出する場合[5]に、また、リモートセンシングでは多重分光画像全体を生成する少数の要素スペクトルを抽出する場合[6]に見られる。なお、時系列データ上で窓を移動させて切り出したデータ群にそのまま k -means を適用しても無意味な結果しか得られないという報告がある[7]が、提案手法はその一例ではない。

3. 提案手法

3.1 高速フーリエ変換

まず、各肺音データについて、適当な窓関数を使い、同じ幅の窓を $3/4$ 重ねながら移動させ、FFT を適用する。予備実験の結果から、今回は Hamming 窓を採用する。サンプリング周波数を f Hz、窓は $2d$ 個のデータ点を含むとすると、各窓は $2d/f$ sec の時間幅に対応し、FFT によって得られるパワー・スペクトルは、 d 次元の特徴ベクトルとみなすことができる。なお、実験ではパワーの対数を用い、稀に生じる負の値は 0 で置き換える。今回は $d = 512$ としたので、隣接する窓は 384 点で重なる。実験に用いた肺音のサンプリング周波数は 44.1 kHz だが、利用予定の他の肺音データに合わせて、11025Hz にダウンサンプリングした。よって、 $2d = 1024$ 点のデータからなる窓は、約 93 msec の幅を持つ。

3.2 スペクトル分離

次に、連続する n 個の窓について、FFT により得られた d 次元の特徴ベクトル、つまり n 個のパワー・スペクトルを、1 つのグループにまとめる。連続する n 個の窓をフレームと呼ぶ。連続する窓は $3/4$ 重なっているため、 n 個の窓からなるフレームは $(n+3)d/2f$ sec の時間幅に対応しており、この時間幅から n 個の特徴ベクトルの集合を 1 つ取り出すことになる。今回の実験では $n = 32$ と設定する。 $n = 32$ のとき、1 フレームの時間幅は約 0.81sec となる。フレームは、隣接する 2 つのフレームが $n/2$ 個の窓を共有するように、時間軸上をずらして取っていく。つまり、隣り合ったフレームは、 $n/2$ 個の特徴ベクトルを共有することになる。

そして、各フレームから得られた n 個の特徴ベクトルが、 m 個 ($m \ll n$) のベクトルの線形混合によって近似されると仮定し、その m 個のベクトルをスペクトル分離によって求める。提案手法では、スペクトル分離を ICA[8] および NMF(nonnegative matrix factorization)[9]により実現する。これら m 個のベクトルを成分ベクトルと呼ぶことにする。成分ベクトルの個数は、今回は $m = 2$ と設定する。つまり、各フレームから成分ベクトルを 2 つずつ得る。同フレームに由来する成分ベクトルを、互いに直交関係にあるとすることにする。ICA のアルゴリズムには fastICA を用い、さらに、収束が安定しやすいものとして提案されている更新式[10]で実装した。ICA の詳細は文献[8][10]に譲る。また、NMF については、予備実験において原論文[11]の更新式を用いたところ、良い評価結果を得られなかった。そのため、新しい更新式として論文[9]で提案された式(12)を、 $\varepsilon = 10^{-9}$ 、 $\beta = 2$ の

設定で用いた。成分ベクトル数 m は ICA と同じく 2 である。

3.3 ふるい分けとメタクラスタリング

様々な肺音データから、スペクトル分離によって多数の成分ベクトルが得られる。 $m = 2$ であるから、どの成分ベクトルも、ちょうど 1 つの他の成分ベクトルと直交関係にあり、それらは同じ 1 つのフレームに由来する。多様な肺音データからこのようにして得られた成分ベクトルを 1 つにまとめ、この成分ベクトルの集合に対して、クラスタリングを多数回実行する。その際、どの成分ベクトルどうしが直交関係にあるかの情報は用いない。直交関係にある 2 つの成分ベクトルは、異なるクラスタに属することが期待される。なぜなら、これらはスペクトル分離によって得られているので、互いに大きく異なっているはずだからである。クラスタリングについては、 k -means を、100 個のクラスタへのランダムな割り当てにより初期化し、100 回実行する。複数回のクラスタリングは、互いに独立な処理なので、並列実行できる。なお、クラスタリングの実行中に、空のクラスタが生じることもある。よって、得られるクラスタ数は 100 個とは限らない。本論文の実験では、毎回の実行で 80 個前後のクラスタを得た。

多数回のクラスタリング全ての実行結果で、2 つの成分ベクトル \mathbf{a} と \mathbf{b} が同じクラスタに属するとき、 $\mathbf{a} \sim \mathbf{b}$ と書くことにする。 \mathbf{a}_1 と \mathbf{a}_2 、および、 \mathbf{b}_1 と \mathbf{b}_2 とを、直交関係にある成分ベクトルのペア 2 組とする。つまり、 \mathbf{a}_1 と \mathbf{a}_2 も、 \mathbf{b}_1 と \mathbf{b}_2 も、ある 32 個のパワー・スペクトルの集合にスペクトル分離を適用して得られた 2 つの成分ベクトルであるとする。どちらのペアもスペクトル分離によって得られているので、 $\mathbf{a}_1 \sim \mathbf{a}_2$ や $\mathbf{b}_1 \sim \mathbf{b}_2$ は成り立たないことが期待される。よって、このような結果を与えた成分ベクトルは捨てる。しかし、 $\mathbf{a}_1 \sim \mathbf{b}_1$ かつ $\mathbf{a}_2 \sim \mathbf{b}_2$ や、 $\mathbf{a}_1 \sim \mathbf{b}_2$ かつ $\mathbf{a}_2 \sim \mathbf{b}_1$ というケースは起こりうる。これらのケースを同時類似と呼ぶことにする。同時類似のケースは、 \mathbf{a}_1 と \mathbf{a}_2 が由来するフレームの音声データと、 \mathbf{b}_1 と \mathbf{b}_2 が由来するフレームの音声データがよく類似していることに対応すると考えられる。そこで、同時類似を 1 つでも成り立たせることがない成分ベクトルも、やはり捨てる。このようにして成分ベクトルを選び分ける過程を、以下、成分ベクトルのふるい分けと呼ぶ。そして、残った成分ベクトルを良質な特徴量とみなし、これらだけを使って「 \sim 」を同値関係とする同値類分解をおこなう。つまり、多数のクラスタリング結果から、いわば“メタクラスタ”を作成する。これが、提案手法の最終的な出力である。メタクラスタの作り方から、あるメタクラスタには、そのメンバーと直交関係にある成分ベクトルを含むような、もう 1 つの同じサイズのメタクラスタが対応することが帰結する。そこで、メタクラスタは、実際の個数の半分で数えることにする。また、各メタクラスタは、少なくとも 2 つのメンバーを含む。メタクラスタからテンプレートを作る方法は、次段階の課題である。現在、各メタクラスタに属する成分ベクトルの平均をテンプレートとする分類実験を、計画中である。

4. 評価実験

今回の実験では、看護師用教材 CD[12]に収録された肺音を利用した。この CD は 33 のトラックを含む。だが、複数の肺音が収録されているトラックもあり、また、異なるトラックの肺音で同一視できるものもある。そこで、手作業でデータを整理し、計 40 カテゴリの肺音データを得た。そこから、声音聴診、口元の聴診、胸腔ドレーン、挿管チューブの

カフという、通常の肺音聴診とは明らかに異質な音声を与える事例を取り除き、表 1 の 31 種類の肺音を用いることにした。表 1 には、各カテゴリから得られた成分ベクトルの総数も示している。全て偶数になっているのは、 $m=2$ より、どの成分ベクトルもちょうど 1 つの成分ベクトルと直交関係にあるからである。また、正常な肺胞呼吸音の成分ベクトル数が多いのは、他の肺音との比較のために、複数のトラックに事例が収録されているからである。成分ベクトル数の合計は 12,290 個であり、 k -means によるクラスタリングは、この 12,290 個の成分ベクトルについて実行される。ただし、NMF は、音声の開始部と終了部の音量が小さい部分で、スペクトル分離の性能に問題を示した。そのため、NMF が与えた成分ベクトルについては、音声の開始部と終了部に対応する数個の成分ベクトルを捨てた後、クラスタリングの入力とした。

提案手法は、表 1 にあるカテゴリ分けの情報を一切使わずに、成分ベクトルのメタクラスタを出力結果として構成する。このメタクラスタ群を、表 1 のカテゴリを正解として *microaveraged precision/recall* により評価する。*microaveraged precision* は、各メタクラスタで最多数を占めるカテゴリが、そのメタクラスタで占める割合の平均、*microaveraged recall* は、各メタクラスタで最多数を占めるカテゴリが、そのメタクラスタで網羅されている割合の平均である。いずれも平均値は、個々のメタクラスタの評価値を計算する際の分母と分子を、全メタクラスタにわたって可算した後、割り算をすることで求められる。

表 1 評価実験に用いた肺音データ

Table 1 Lung sounds used in evaluation experiment

ID	データ名	成分ベクトル数
1	正常な肺胞呼吸音	2150
2	正常な気管支肺胞呼吸音	330
3	正常な気管呼吸音	174
4	呼吸音の減弱（無気肺）	538
5	呼吸音の消失（血気胸の血胸の部位）	550
6	呼吸音の増強（無気肺の正常側）	636
7	気管支呼吸音化	286
8	低音性連続性ラ音（気管支狭窄）	574
9	高音性連続性ラ音	236
10	細かい断続性ラ音（間質性肺炎/肺繊維症）	708
11	粗い断続性ラ音（気管支拡張症）	790
12	自然気肺	124
13	胸水貯留（貯留部位）	180
14	胸水貯留（貯留部位の反対側）	160
15	喘息	552
16	喘息（中等度軽快時）	232
17	喘息（改善時）	184
18	ARDS・肺水腫	404
19	肺水腫（軽快時）	138
20	気管狭窄	230
21	気管狭窄（治療後）	306
22	肺炎	464
23	肺炎（中等度改善時）	244
24	肺炎（退院時）	180
25	胸膜炎	470
26	うっ血性心不全（初期）	186
27	うっ血性心不全（増悪時）	130
28	うっ血性心不全（改善時）	260
29	皮下気腫	154
30	血気胸の気胸の部位	244
31	気管気管支狭窄	476
	(成分ベクトル数の合計)	12290

本研究の目的は、各カテゴリの肺音の特徴を良く表し、テンプレート作成に有用な特徴量を取り出すことである。よって、各カテゴリの肺音に由来する成分ベクトルが、複数個のメタクラスタに散らばって含まれていても、そのカテゴリのテンプレートの個数が複数になるだけで、問題はない。しかし、同じメタクラスタに、異なるカテゴリの肺音に由来する成分ベクトルが混在する状況は、特定のカテゴリを代表するテンプレートの純粋さが失われるため、避けるべきである。つまり、*recall* よりも *precision* が高いことが望ましい。

k -means の多数回の実行結果に基づく同時類似により、成分ベクトルのふるい分けをおこなうと、いくつかのカテゴリについては、メタクラスタを作成する前に、すべての成分ベクトルが捨てられることもある。さらに、メタクラスタを作成すると、どのメタクラスタでも最多数となれないカテゴリが出てくることもある。これらのカテゴリについては、テンプレートを作ることができないため、別途の対応が必要となる。よって、このようなカテゴリは少ないほうが良い。

今回の実験では、多数のパワー・スペクトルを少数の成分ベクトルで代表させる方法として、ICA と NMF 以外に、単純平均を比較のために用いた。つまり、各フレームから得られる n 個のパワー・スペクトルを、それらの平均で代表させる。この場合、各フレームから 1 つだけベクトルが得られる。便宜上、これも成分ベクトルと呼ぶ。この場合、 k -means の入力となるベクトル数は、ICA や NMF の半数である。

さらに、ICA、NMF、単純平均すべての場合で、得られた成分ベクトル群を k -means の入力とするとき、使用する周波数領域について複数の設定を試みた。成分ベクトルは $d=512$ 次元ベクトルで、第 k エントリ ($1 \leq k \leq 512$) は周波数 $kf/2d$ のパワーに対応する。1~512 番目のエントリのうち 9~128, 9~192, 9~256, 9~384, 17~128, 17~192, 17~256, 17~384 という 8 種類の領域で実験した。1~8 の低周波領域を用いないのは、この領域のパワーが録音条件によって大きく異なるからである。この領域を除くことで、録音条件の違いを緩和しようとしている。385~512 の高周波領域を使わないのは、この領域が雑音の影響を強く受けるためである。

表 2 に評価実験の結果をまとめた。例えば、スペクトル分離に ICA を使い、成分ベクトルを 9~128 番目のエントリに制限して得られたメタクラスタの評価は、表 2 の最も左上のセルにある。0.9387 と 0.0068 はそれぞれ *microaveraged precision*, *microaveraged recall* である。その下に「(186:24)」とあるのは、メタクラスタが 186 個であること、また、テンプレートを作成できるカテゴリが 24 個あることを意味する。

上で述べたように、高い *precision* が望ましい。表 2 のいずれの場合も、成分ベクトルの単純平均（「MEAN」と書かれた行）の *precision* は、ICA や NMF よりかなり低い。これは、ICA や NMF では、フレームどうしの類似性が、互いに十分に異なった 2 つのベクトルの同時類似で判定されており、平均ベクトル 1 つによる場合より判定が厳しいためである。 $m > 2$ と設定すると、類似性判定が厳しくなりすぎると予想されるが、この点は今後検証が必要であろう。

最高の *precision* は、スペクトル分離に NMF を用い、成分ベクトルを 17~256 番目のエントリに制限した場合に得られた。このときのメタクラスタを詳しく調べると、ふるい分け後に残った成分ベクトルの数、つまり、メタクラスタを構成するために使われた成分ベクトルの数は 3,116 個だった。ふるい分けの際、「胸水貯留（貯留部位の反対側）」の成分ベクトルが、全て失われた。残る 30 カテゴリのうち、29 のカ

カテゴリが少なくとも1つのメタクラスタで多数派を占めていた。これら 29 のカテゴリについてはテンプレートを作成できる。全てのメタクラスタで少数派となってしまったカテゴリは、「肺炎(中等度改善時)」であった。この場合の precision が良かったので、同じ設定で、100 回より少ないクラスタリング結果から得られるメタクラスタを評価した。その結果が表 3 である。回数を減らすほど、成分ベクトル間の類似性判定が緩くなり、precision はやや低下する。40 回のクラスタリング結果を利用するケースで、全てのカテゴリについてテンプレートを作成できるという結果を得た。これは、ふるい分けの条件が緩くなり、全カテゴリの成分ベクトルがメタクラスタの構成に使われたためである。Precision も大きく下がってはならず、良い結果と言える。なお、このケースでふるい分け後に残った成分ベクトルは、4,614 個だった。

表 2 評価実験の結果
Table 2 Results of evaluation experiment

	9 [~] 128	9 [~] 192	9 [~] 256	9 [~] 384
ICA	0.9387	0.9609	0.9605	0.9779
	0.0668	0.0698	0.0615	0.0523
	(186:24)	(212:24)	(215:26)	(246:28)
NMF	0.9718	0.9880	0.9856	0.9484
	0.0451	0.0373	0.0375	0.0396
	(198:27)	(245:26)	(299:28)	(326:29)
MEAN	0.8469	0.8697	0.8588	0.8365
	0.0281	0.0309	0.0361	0.0425
	(556:31)	(601:31)	(547:28)	(467:27)
	17 [~] 128	17 [~] 192	17 [~] 256	17 [~] 384
ICA	0.9642	0.9560	0.9644	0.9696
	0.0702	0.0693	0.0685	0.0575
	(161:23)	(165:19)	(192:25)	(195:28)
NMF	0.9245	0.9721	0.9929	0.9015
	0.0497	0.0534	0.0348	0.0408
	(204:25)	(204:24)	(305:29)	(294:27)
MEAN	0.8112	0.8434	0.8505	0.8452
	0.0316	0.0334	0.0346	0.0396
	(511:31)	(562:31)	(535:29)	(455:28)

表 3 クラスタリング回数とメタクラスタの質の相関
Table 3 Correlation between the number of clustering executions and the quality of metaclusters

100 回	80 回	60 回	40 回	20 回
0.9929	0.9880	0.9769	0.9619	0.8958
0.0348	0.0345	0.0351	0.0328	0.0298
(305:29)	(320:28)	(351:29)	(411:31)	(494:30)

5. おわりに

本論文では、スペクトル分離と、成分ベクトル間のロバストな類似性判定とを通じて、肺音分類のためのテンプレート作成に利用できる、良質な特徴量を抽出する手法を提案した。問題は、成分ベクトル間の類似性判定の厳しさを、どのように設定するかである。クラスタリングの実行回数を増やすと、成分ベクトル間の類似性判定が厳しくなり、メタクラスタの precision が高まるかわりに、ふるい分けによって特定のカテゴリの成分ベクトルが全て失われる場合が生じる。つまり、

テンプレートを作成できないカテゴリが生じる。提案手法の利用にあたっては、成分ベクトル間の類似性判定の厳密さと、メタクラスタにおけるカテゴリの網羅性とのバランスを、うまく探る必要がある。また、今回の実験結果をふまえ、実際に各カテゴリのテンプレートを作成し、肺音分類した場合の評価実験も、今後おこなう予定である。

【謝辞】

データ工学関連手法の適用について蓄積の多くない応用分野では、それによって評価した提案手法が大きな変更なく現実的な状況に転用できる程度に real で、提案手法のふるまいを学術的に分析できる程度に ideal なデータの存在が望ましい。この意味で文献[12]の肺音データは大変有用だった。

【文献】

[1] Murphy, R.: "Computerized multichannel lung sound analysis", IEEE Engineering in Medicine and Biology Magazine, Vol.26, Issue 1, pp.6-19 (2007).
 [2] <http://www.rale.ca/pub/RRC.PDF>
 [3] Güler, E. C., Sankur, B., Kahya, Y. P., Raudys, S.: "Visual classification of medical data using MLP mapping". Computers in Biology and Medicine, Vol.28, pp.275-287 (1998).
 [4] Pelletier, C.: "Classification des sons respiratoires en vue d'une détection automatique des sibilants", Université du Québec à Chicoutimi (2006).
 [5] Hofmann, T.: "Probabilistic latent semantic indexing". in Proc. of SIGIR'98, pp.50-57 (1999).
 [6] Miao, L., Qi, H., Szu, H.: "Unsupervised decomposition of mixed pixels using the maximum entropy principle", in Proc. of ICPR'06, pp.1067-1070 (2006).
 [7] Ide, T.: "Translational symmetry in subsequence time-series clustering", in Proc. of JSAI2006 (LNAI Vol.4384), pp.5-18, 2006.
 [8] Hyvärinen, A., Karhunen, J., Oja, E.: 詳解 独立成分分析 (根本幾, 川勝真喜 訳), 東京電機大学出版局 (2005).
 [9] Cichocki, A., Zdunek, R., Amari, S.-I.: "Csiszar's Divergences for Non-Negative Matrix Factorization: Family of New Algorithms", in Proc. of ICA2006 (LNCS Vol. 3889), pp.32-39 (2006).
 [10] Hyvärinen, A.: "Fast and robust fixed-point algorithms for independent component analysis", IEEE Trans. on Neural Networks, Vol.10, No.3, pp.626-634 (1999).
 [11] Lee, D.-D., Seung, H.-S.: "Algorithms for non-negative matrix factorization", in Proc. of NIPS2000, pp.556-562 (2001).
 [12] 米丸亮, 櫻井利江: ナースのための CD による呼吸音聴診トレーニング, 南江堂 (2001).

正田 備也 Tomonari MASADA

長崎大学工学部情報システム工学科助教. 博士 (情報理工学). データマイニング, 情報検索の研究に従事.

喜安 千弥 Senya KIYASU

長崎大学工学部情報システム工学科准教授. 博士 (工学). パターン認識, リモートセンシングなどの研究に従事.

宮原 末治 Sueharu MIYAHARA

長崎大学工学部情報システム工学科教授. 博士 (工学). パターン認識, 画像処理, 情報検索の研究・開発に従事.