

オンライン特徴抽出アルゴリズムとそのマルチタスクパターン認識への応用

Online Feature Extraction Algorithms and Its Application to Multitask Pattern Recognition



小澤 誠一 (Seiichi OZAWA Dr. Eng.)
神戸大学大学院工学研究科電気電子工学専攻 教授
(Professor, Department of Electrical and Electronic Engineering,
Graduate School of Engineering, Kobe University)
IEEE 日本神経回路学会 電子情報通信学会 電気学会 計測自動制御
学会 システム制御情報学会
受賞: IEEE Computational Intelligence Society, EAIS 2011 Outstanding
Paper Award (April, 2011)
著書: 西川よし一, 北村新三編, 西川よし一, 喜多一, 堤一義, 小澤誠一,
北村新三, 江島義道, 土屋和雄, 田中健一 「ニューラルネットと計測制御」
朝倉書店 (1995) 馬場則夫, 小島史男, 小澤誠一 「ニューラルネットの
基礎と応用」 共立出版 (1994) その他, 分担執筆 6 件
研究専門分野: 機械学習 ニューラルネット ストリームデータ学習
パターン認識

あらまし データがストリーム状に時々刻々と与えられ、認識と学習を交互に行う必要のある動的環境の下で、特に画像などの高次元データに対し、優れた低次元特徴を高速に求めるオンライン特徴抽出アルゴリズムを紹介する。このようなオンライン特徴抽出を個人認証システムに組み込むことで、登録者の外観の変貌や未登録者などへの追従を容易にし、認識性能を高く維持できることが期待される。本稿では、開発された以下の5つオンライン特徴抽出アルゴリズムの中から、いくつかについて簡単に紹介する。

- (1) 追加学習型カーネル主成分分析
- (2) 追加学習型正規直交判別ベクトル
- (3) 追加学習型2方向2次元線形判別分析
- (4) 追加学習型2方向2次元カーネル主成分分析
- (5) 追加学習型2方向2次元線形判別分析のマルチタスク学習モデル

そして、個人認証への応用が最も期待できる追加学習型2方向2次元線形判別分析のマルチタスク学習モデルについて詳細に説明する。また、顔画像データベースを用いたマルチタスク個人認証に対し、既存手法との性能比較を行った結果を紹介し、知識移転を行わない従来手法に対して高い認識率が得られることを示す。

1. はじめに

近年、ネットワークや高性能な小型デバイス（監視カメラやスマートフォンなど）の普及に伴い、様々なマルチモーダル情報（テキスト、画像、音声など）がリアルタイムで生成され、ネットワークを介して共有できるようになった。これらの情報は、ネットワーク上で「ストリームデータ」として扱われ、様々な目的に利用されている。このようなストリームデータをパターン認識の目的で利用する際、一般に高次元となる入力データから認識に有効な低次元の特徴ベクトルにリアルタイムで変換するオンライン特徴抽出は、ストリームデータに対する認識精度や学習時間に影響を与える重要な処理といえる。例えば、顔画像に基づく個人認証システムでは、同一の登録者であっても、表情や健康状態、化粧の違いなどによる個人変動をすべて考慮して訓練データを事前に収集することは不可能に近い。そのため、認証に失敗したデータを収集し、これらをオンラインで学習して性能改善することが望ましい[1]。この場合、ビデオカメラで撮影され、顔領域部分を切り取った画像がストリームデータといえ、これら一連のデータから優れた特徴をオンラインで抽出できることが求められる。

データの統計的性質に基づいて特徴を抽出する方法として、一般に主成分分析 (PCA) [2] やカーネル主成分分析 (KPCA) [3]、線形判別分析 (LDA) [2] が使われてきた。PCA は入力データ分布を最小二乗の意味で最適な低次元部分空間で近似する方法として知られ、クラス情報を用いず「教師なし学習」で固有特徴空間を形成できる。KPCA は、高次元特徴空間において PCA と同じ原理で特徴抽出を行い、結果的に元の空間で非線形な特徴抽出を行う手法である。一方、LDA は各クラスの線形分離性を最大化する「教師あり学習」の特徴抽出手法であり、一般に低次元であっても、高い認識性能をもつ判別特徴空間が得られる。但し、判別特徴空間の次元がクラス数未満となる制限があり、データによっては優れた認識性能が得られないケースもあった。これに対し、判別特徴空間の補空間において有効な部分空間を探索する再帰フィッシャー判別 [4] が提案されている。これらを追加学習に拡張するには、逐次的に与えられる訓練データをすべて保存し、

オンライン特徴抽出アルゴリズムとそのマルチタスクパターン認識への応用

Online Feature Extraction Algorithms and Its Application to Multitask Pattern Recognition

それらに対して特徴抽出手法を実行するのが最も単純である。しかし、このような単純な拡張は、計算時間やメモリ量の点で効率のよい方法とはいえない。そこで、一度学習した訓練データは、学習後に廃棄されるワンパス追加学習[1]が注目されており、追加学習型主成分分析 (IPCA) [5][6]や追加学習型線形判別分析 (ILDA) [7]、追加学習型カーネル主成分分析 (IKPCA) [8][9]や追加学習型再帰フィッシャー判別 (IRFLD) [10]などが盛んに研究されている。

本稿では、画像などの2次元データを高速に学習するために、ILDA と IKPCA を拡張した追加学習型2方向2次元線形判別分析(2D)²-ILDA を簡単に説明した後、複数の認識タスクを同時並列的に学習するマルチタスク学習問題に、(2D)²-ILDA を拡張した学習アルゴリズム[11]を紹介する。

2. 追加学習型2方向2次元線形判別分析

紙面の都合上、上述した5つのオンライン特徴抽出アルゴリズムをすべて説明することはできないため、個人認証システムへの実装が最も有望視される追加学習型2方向2次元線形判別分析について説明する。まず、基礎となる線形判別分析と2方向2次元線形判別分析について簡単に説明したあと、追加学習アルゴリズムへの拡張方法を述べる。

2.1 線形判別分析

フィッシャーが提案した線形判別分析 (Linear Discriminant Analysis: LDA) は、パターン認識の目的で広く使われている特徴抽出手法である[2]。

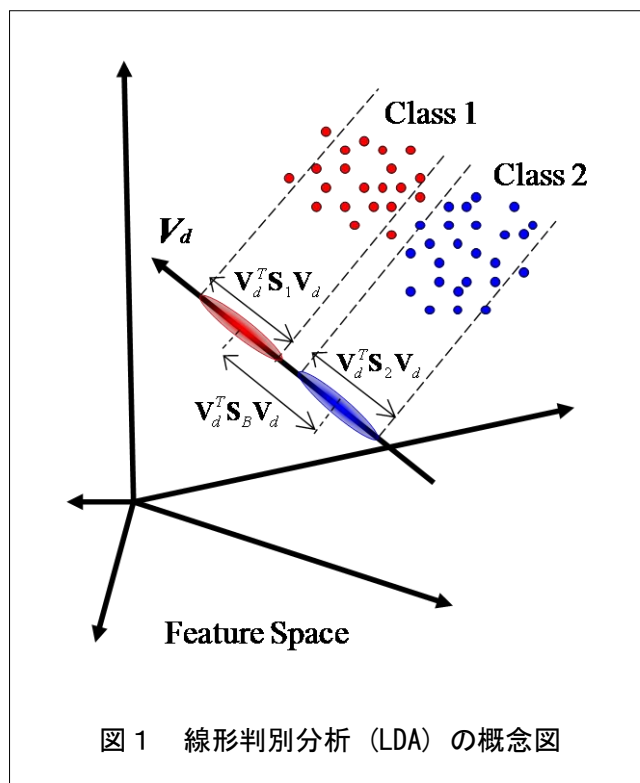
N 個の訓練データがあり、各々が K クラス中のいずれかのクラスに属するものとする。LDA の基本的な考え方は、 K クラス認識問題において、同じクラスに属するデータ内での変動を最小化し、各クラスの平均データ間の変動を最大化する ($K-1$) 個の判別ベクトル $V = \{v_1, \dots, v_{K-1}\}$ を求めることである。これには、 N 個のデータに対して、図1に示すようなクラス間変動行列 S_B とクラス内変動行列 S_W (2クラスの場合、図1の $S_1 + S_2$ に相当する) を求め、次式のクラス分離度 $J(V)$ を最大化する V を求める。

$$J(V) = \text{tr}\{(V^T S_W V)^{-1} (V^T S_B V)\} \quad (1)$$

ここで、 $\text{tr}\{\cdot\}$ は行列のトレースを表す。直感的には、 S_W の項の逆行列を取っていることから、クラス内変動が小さくなり、クラス間変動が大きくなれば、式(1)が大きくなるのがわかる。式(1)を最大化する V は、次式の一般化固有値問題を解くことにより求められることが知られている。

$$S_B V_{K-1} = S_W V_{K-1} \Lambda_{K-1} \quad (2)$$

ここで、 Λ_{K-1} は ($K-1$) 個の固有値を対角要素にもつ行列である。



2.2 2方向2次元線形判別分析

画像データに対して LDA と ILDA を用いる際、画像をベクトルに変換する必要がある。例えば、112×92 ピクセルの画像は、10,304 次元のベクトルに変換する必要がある。このような高次元ベクトルから共分散行列を求めるには、大量なメモリが必要となり、一般に現実的でない。そこで、Li [12]らは 2次元 LDA

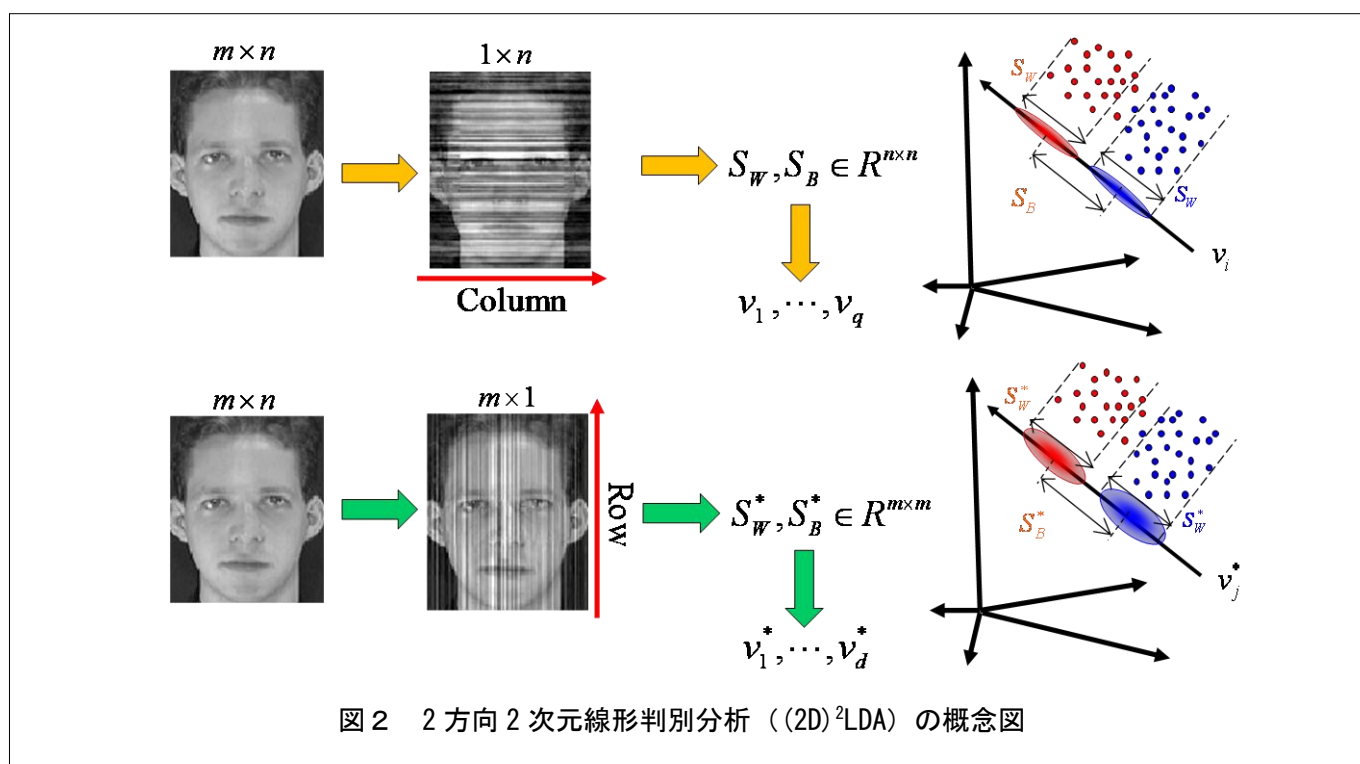
オンライン特徴抽出アルゴリズムとそのマルチタスクパターン認識への応用

Online Feature Extraction Algorithms and Its Application to Multitask Pattern Recognition

(2-dimensional Linear Discriminant Analysis, 2D-LDA)を、Noushath [13]らは2方向2次元LDA (2-directional 2-dimensional Linear Discriminant Analysis, (2D)²LDA)を提案している。図2に示すように、2D-LDAと(2D)²LDAでは、画像を行列のまま処理でき、ベクトルに変換する必要がない。112×92の画像の場合、共分散行列のサイズは高々112×112となる。LDAとILDAの10,304×10,304と比べると、かなり小さくなるため、学習時間やメモリコストを削減できることになる。

式(2)の一般化固有値問題を解くことにより V が求められる。上記の手順を繰り返せば、判別特徴空間モデル Ω は新しい訓練データ Y が与えられるたびに更新されることになり、追加学習型線形判別分析(ILDA)が実現される。

2方向2次元LDAの追加学習への拡張も同様に行うことができる。つまり、2次元データの列方向と行方向のクラス間変動行列 S_B とクラス内変動行列 S_W を逐次更新し、それぞれの一般固有値問題を解くことで実現される。



2.3 追加学習アルゴリズムへの拡張

まず、最初に与えられた訓練データ X に対してLDAを適用し、特徴空間を得たとする。その際、クラス間変動行列 S_B とクラス内変動行列 S_W 、クラス k の平均ベクトル \bar{x}_k とデータ数 N_k を判別特徴空間モデル Ω に保持しておく。次に L 個の訓練データ Y が追加で与えられ、クラス数が K から $K'(K \leq K' \leq K+L)$ に増えたとする。これらから、すでに与えられたデータ X と新しく追加されたデータ Y の両方を考慮したクラス間変動行列 S_B とクラス内変動行列 S_W は、 X を用いず Y と Ω を用いて逐次的に求められる。そして、

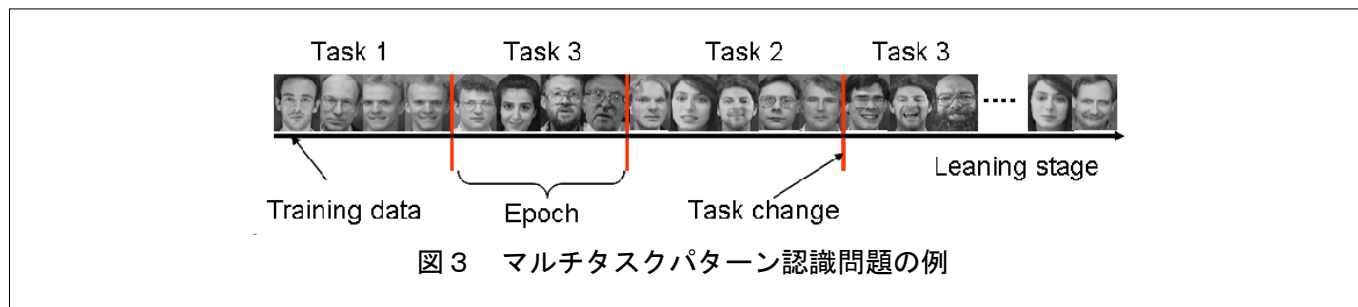
3. マルチタスクパターン認識への拡張

3.1 マルチタスクパターン認識

たとえば、個人認証だけでなく性別認識や年齢推定など、複数のタスクを同時に扱う学習は、マルチタスク学習(Multitask Learning, MTL) [14][15][16]と呼ばれる。説明を簡単にするため、以下、学習すべき問題のことを「タスク」と呼び、逐次的に訓練データが与えられて学習が行われる時刻を「学習ステージ」、同一のタスクの訓練データが連続的に与えられる期間を「エポック」と呼ぶことにする。ここでは図3に示すように、一定期間連続して同一タスクの訓練データが

オンライン特徴抽出アルゴリズムとそのマルチタスクパターン認識への応用

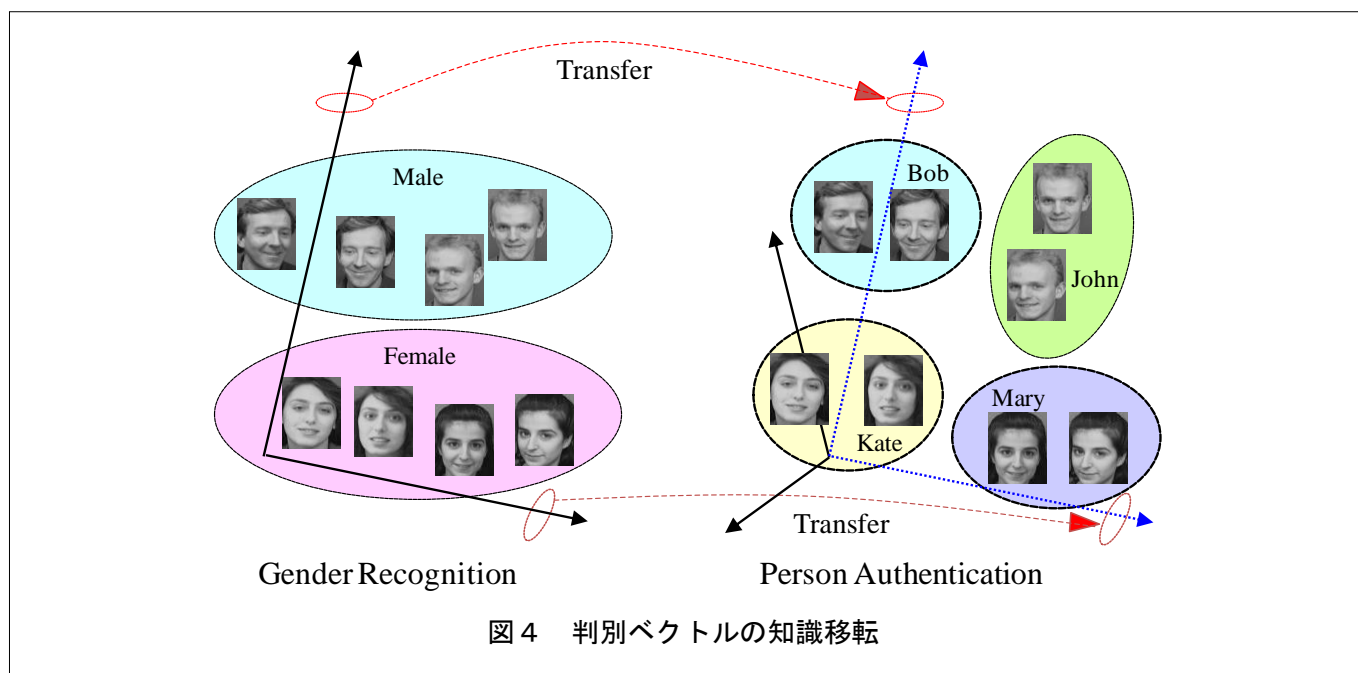
Online Feature Extraction Algorithms and Its Application to Multitask Pattern Recognition



与えられ、その後、異なるタスクに切り替わるような動的な環境を仮定する。但し、訓練データはクラス情報とタスク情報を教師信号としてもっているものと仮定し、タスク変動を検知する必要はないとする。図3の例では、最初の学習ステージで個人認証タスク (Task 1) の訓練画像データが与えられ、2番目の学習ステージでも個人認証タスクの訓練データが与えられる。4番目の訓練データを学習した後、学習タスクが年齢推定タスク (Task 3) に変動し、引き続き4つの訓練データについて学習が行われる。そして、9番目の学習ステージで性別認識タスク (Task 2) に切り替わり、14番目で年齢推定タスク (Task 3) に再び切り替わる。このように、あるタスクを一度だけ学習するのではなく、逐次的に学習データを与えながら変動するタスクを学習していく。

3. 2 判別特徴空間の知識移転

マルチタスク学習では、異なるタスク間の関連性を求め、その関連性に基づいて共有知識を抽出し、それを学習に利用できることが求められる。特定タスクの共有知識を異なる関連タスクの学習に利用する仕組みは「知識移転 (knowledge transfer)」と呼ばれる。ここで、一般に共有知識を抽出するタスクは「元タスク」と呼ばれ、移転先のタスクは「目的タスク」と呼ばれる。また、共有知識は帰納学習を通して学習されることが多く、異なるタスクを学習する際の初期値として利用されることから、「帰納バイアス (inductive bias)」とも呼ばれる[14]。判別特徴空間の追加学習アルゴリズムである(2D)²-ILDA をマルチタスク学習問題に拡張する際、移転すべき知識は判別ベクトルに対応する。例えば、図4に示す性別認識タスクから個人認証タスクへの知識移転を考えてみよう。



オンライン特徴抽出アルゴリズムとそのマルチタスクパターン認識への応用

Online Feature Extraction Algorithms and Its Application to Multitask Pattern Recognition

性別認識タスクで既に2本の判別軸が得られているとして(図4左側)、それらを個人認証タスクで得られた2本の判別軸に加える(図4右側)ことで認識率の向上が期待できるかどうかを調べてみる。これは、クラス分離度[2]という基準に基づき判定し、性別認識タスクの判別軸のクラス分離度が、個人認証タスクの判別軸のクラス分離よりも一定量大きいとき、性別認識タスクの判別軸を直交化した上で個人認証タスクに追加する。ここで、追加する判別軸が元々と異なるタスクで得られたものであることに注意する。

このように、元タスクの有効な判別軸を目的タスクに追加することを、本研究では「知識移転」と呼んでいる。

4. マルチタスク顔画像認識への適用と性能評価

4.1 実験方法

ORL顔データ[17]を用いて、マルチタスク用データを作成する。ORL顔データセットは40人の112×92顔画像から構成され、各人10枚の顔画像が含まれている。しかし、これだけでは十分でないため、原画像データのミラー画像を作成して訓練データ数を増やし、総数800枚とした。実験では、個人認証(タスク1)、性別認識(タスク2)、年齢推定(タスク3)の3つのタスクを定義した。タスク1では、クラスごとに15枚画像データをランダムに選んで訓練データとし、残ったデータをテストデータとする。タスク2は2クラス問題であり、クラス1(女性)とクラス2(男性)に分けられる。同様に、タスク3も2クラス問題であり、クラス1(高年齢)とクラス2(低年齢)に分けられる。

学習は初期学習と追加学習の2つのフェーズに分けられ、初期学習フェーズでは各タスクの訓練データを一定数与え、LDAを用いて判別特徴空間の学習を行う。そして、追加学習フェーズに入るが、これは15個のデータをチャンクとして追加学習し、2チャンクごと、つまり30データずつでタスクが切り替わるものとした。学習ステージごとに知識移転を行うが、これに伴って判別特徴空間の次元が変動する。つまり、識別器の入力変数が変動することになり、ニューラルネットやサポートベクトルマシンなどの適用は簡単ではない。そこで、プロトタイプベースの識別器である最近傍法を導入する。また、知識移転の効果を調べるため、知識移転なしの場合の認識評価も行う。なお、最近傍法に用いるプロトタイプには、学習開始から与えられた200個の訓練データとする。

4.2 実験結果

表1は、知識移転の起こりやすさのパラメータである η が変化したときの認識率への影響を調べた結果である。なお、 η が小さいほど知識移転が起こりやすく、判別特徴空間の次元も高くなる。表1より、知識移転ありの場合は、知識移転なしの場合より認識率が向上することがわかる。特に、タスク2とタスク3は η の減少とともに認識率が向上し、知識移転なしと比べると大幅に認識率が向上しているのがわかる。一方、タスク1(個人認証)の認識率が、 η に対してあまり変わっていないのは、タスク2(性別認識)とタスク3(年齢推定)から移転される判別軸が、タスク1(個人認証)で有効でなかったためと考えられる。

表1 知識移転の起こりやすさに対する認識率(%)の推移

η	知識移転あり				知識移転なし
	0.2	0.4	0.6	0.8	∞
個人認証タスク	93.0 ± 2.6	92.9 ± 2.4	92.7 ± 2.5	2.6 ± 2.7	92.7 ± 3.0
性別認識タスク	99.1 ± 1.2	97.7 ± 1.9	97.1 ± 2.0	96.7 ± 1.8	95.1 ± 3.0
年齢推定タスク	98.0 ± 1.1	95.8 ± 2.8	95.3 ± 3.0	94.6 ± 2.6	92.8 ± 2.2
平均認識率	96.7 ± 1.8	95.5 ± 2.3	95.0 ± 2.5	94.6 ± 2.3	93.5 ± 2.7

オンライン特徴抽出アルゴリズムとそのマルチタスクパターン認識への応用

Online Feature Extraction Algorithms and Its Application to Multitask Pattern Recognition

また、図5は学習ステージごとの各タスクの認識率の移り変わりを表しており、いわゆる学習曲線に相当する。これからわかるように、追加学習や知識移転を通して、判別特徴空間の追加学習が安定して行われており、オンライン特徴抽出の有効性が確認された。

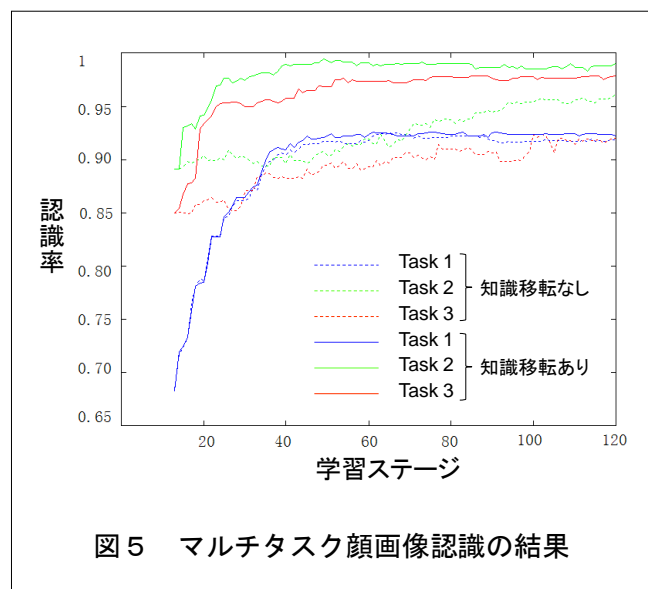


図5 マルチタスク顔画像認識の結果

5. さいごに

本稿では、時々刻々と発生するストリームデータから、有効な特徴をオンラインで抽出する方法として、線形判別分析とカーネル主成分分析を拡張した5つの学習アルゴリズムを紹介した。特に、個人認証への応用を意図し、画像などの2次元データから高速に有効な特徴を得ることのできる追加学習型2方向2次元線形判別分析を説明し、複数の認識タスクを同時並行的に学習するマルチタスク学習問題への拡張についても取り上げた。計算機実験では、個人認証、性別認識、年齢推定の3つの異なるタスクを逐次的に学習するマルチタスク個人認証に応用し、判別軸を知識移転することで認識率が向上することを示した。一方、判別特徴空間の更新スピードは、知識移転する判別軸が多ければ遅くなるため、一般に認識率と更新スピードはトレードオフの関係にある。よって、リアルタイムでの更新が可能になるよう線形判別分析で固有値問題を解く回数を減らすなどして、さらに学習を高速化する必要がある。今後の課題としたい。

参考文献

- [1] N. Kasabov, Evolving connectionist systems: methods and applications in bioinformatics, brain study and intelligent machines, Springer, 2002.
- [2] 石井, 上田, 前田, 村瀬, わかりやすいパターン認識, オーム社, 1998.
- [3] S. Abe, Support vector machines for pattern classification, Springer, 2005.
- [4] C. Xiang, X. Fan, and T. Lee, "Face Recognition Using Recursive Fisher Linear Discriminant," IEEE Trans. on Image Processing, vol. 15, no. 8, pp. 2097-2105, 2006.
- [5] P. Hall and R. Martin, "Incremental Eigenanalysis for Classification," Proc. British Machine Vision Conference, vol. 1, 286-295, 1998.
- [6] S. Ozawa, S.-L. Toh, S. Abe, S. Pang, and N. Kasabov, "Incremental learning of feature space and classifier for face recognition," Neural Networks, vol. 18, nos. 5-6, pp. 575-584, 2005.
- [7] S. Pang, S. Ozawa, and N. Kasabov, "Incremental linear discriminant analysis for classification of data streams," IEEE Trans. on System, Man, and Cybernetics - Part B, vol. 35, no. 5, pp. 905-914, 2005.
- [8] Y. Takeuchi, S. Ozawa, and S. Abe, "An efficient incremental kernel principal component analysis for online feature selection," Proc. Int. Joint Conf. on Neural Networks, pp 1603-1608, 2007.
- [9] 小澤, 竹内, 阿部, "追加学習型カーネル主成分分析によるオンライン特徴抽出," 電子情報通信学会論文誌 D, vol. J93-D, no. 6, pp. 826-836, 2010.
- [10] 太田, 小澤, "オンライン特徴抽出を行う追加型再帰フィッシャー線形判別の改良," 電気学会論文誌 C, vol. 131, no. 7, pp. 1368-1376, 2011.
- [11] C. Liu, Y.-M. Jang, S. Ozawa, and M. Lee, "Incremental 2-Directional 2-Dimensional Linear Discriminant Analysis for Multitask

オンライン特徴抽出アルゴリズムとそのマルチタスクパターン認識への応用

Online Feature Extraction Algorithms and Its Application to Multitask Pattern Recognition

- Pattern Recognition,” Proc. Int. Joint Conf. on Neural Networks 2011, pp. 2911-2916, 2011.
- [12] L. Ming, B. Yuan, “2D-LDA: A Statistical Linear Discriminant Analysis for Image Matrix,” Pattern Recognition Letters, vol. 26, no. 5, pp. 527-532, 2005.
- [13] S. Noushatha, G. H. Kumara, and P. Shivakumara, “(2D)²LDA: An efficient approach for face recognition,” Pattern Recognition, vol. 39, no. 7, pp. 1396-1400, 2006.
- [14] S. Thrun and L. Pratt, Learning to learn, Kluwer Academic Pub., 1998.
- [15] Y. S. Abu-Mostafa, “Learning from hints in neural networks,” Journal of Complexity, vol. 6, no.2, pp. 192-198, 1990.
- [16] R. Caruana, “Multitask learning,” Machine Learning, vol. 28, no.1, pp. 41-75, 1997.
- [17] <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>

この研究は、平成20年度SCAT研究助成の対象として採用され、平成21～23年度に実施されたものです。