論文

ニューラルネットワークを用いた話者認証システムにおけるアンサンブル学習の効果

長谷川 弘¹, 木下 健太郎^{1,2}, 岸田 悟^{1,2}

¹ 鳥取大学大学院工学研究科, 鳥取県鳥取市湖山町南 4-101

² 鳥取大学工学部附属電子ディスプレイ研究センター (TEDREC), 鳥取県鳥取市湖山町南 4-101

Effect of Ensemble Learning on Performance of Speaker Authentication Systems Using Neural Networks

Hiroshi Hasegawa¹, Kentaro Kinoshita^{1,2} and Satoru Kishida^{1,2}

¹Graduate School of Engineering, Tottori University

4-101 Koyama-minami, Tottori, Tottori 680-8552, Japan

²Tottori University Electronic Display Research Center (TEDREC)

4-101 Koyama-minami, Tottori, Tottori 680-8552, Japan

E-mail: kishida@ele.tottori-u.ac.jp

Abstract We construct a speaker authentication system, where 3-layerd neural networks with ensemble learning algorithm are used, and investigate the effect of ensemble learning on the performance of the system. From the results, we found that the authentication rates of the system for a person became to 100% by using ensemble learning. Therefore, the new ensemble leaning used in this study is thought to be useful for the speaker authentication system with layered neural networks. In addition, a new multi-step authentication system for many persons by extending the system for a person was suggested. In the system, the ensemble learning was also useful for the speaker authentication system of neural networks for many persons.

Keywords: speaker authentication system, neural network, ensemble learning

1. 序 論

近年, コンピュータや通信技術の発展に伴って様々なサービスが”個人”に提供されている。”個人”にサービスを提供するにあたり, サービスを受ける”個人”を特定するための個人認証は非常に重要である。現在, 個人認証の中でも紛失や忘却, 盗難等の様々な脆弱性に強いバイオメトリクス認証が注目されている。バイオメトリクスは具体的に, 音声 [1]-[8], 指紋 [9]-[11], 掌紋 [12], 静脈 [13], 虹彩 [14], 網膜 [15], 顔 [16], 筆

跡 [17] 等がある。バイオメトリクスの中でも特に音声信号を用いた個人認証 (話者認証) は認証時の音声の取得が容易である等の利点があり, 様々な研究がされている [1]-[8]。一般的な話者認証システムでは, 音声信号に対して複雑な処理を行い, 認証率を向上している。複雑な処理をしないで話者認証を行うには, ニューラルネットワークが有効 [6]-[8] である。これらの報告では, 母音「あ」が話者認証に適していること及び連続した短時間の音声波形をフーリエ変換して得られたパワースペクトルを用いて, ”本人”と”他人”を区別した

ことを示している。しかしながら、この報告では、認証する対象が1人であり、認証システムの処理は簡単であるが、認証率は十分に高くない。

一方、話者認証や音声認識 [18] 以外に、音声信号に含まれる様々な特徴を用いて、鬱判定 [19] や飲酒判定 [20] に関する研究が行われている。音声認識では、隠れマルコフモデル等を用いて音声信号に含まれる言葉を認識し、発話内容を得てきた。鬱判定では音声信号にカオス処理を行い、鬱患者と健常者を分類した。飲酒判定では、アルコールによる音声信号の変化を利用して飲酒状態であるかどうか判定した。音声信号には、雑音や個人の変動が含まれる。故に、話者認証の特徴量を抽出することは容易ではなく、複雑な処理を行う必要がある。

上述のような、様々な情報や雑音が含まれる音声信号の場合、アンサンブル学習が有効であると思われる [21]-[24]。医療支援システムでは、胸部 X 線画像を種々の前処理をすることにより、多くの入力パターンを作成し、それらを用いてアンサンブル学習を行った [24]。話者認証システムでは、boosting, bagging 及び CWP(combination of weak perceptrons) を適用し、認証率が向上した [22]。回帰問題に対して非線形予測器としてフィードフォワード型の3階層ニューラルネットワークを用いてアンサンブル学習の汎化誤差を解析したことが報告されている [21]。従って、ニューラルネットワークにはアンサンブル学習が適していると思われる。また、アンサンブル学習を階層型ニューラルネットワークで行うには、多くの学習パターンが必要である。さらに、アンサンブル学習が階層型ニューラルネットワークに与える効果は十分には明らかにされていない。

本研究では、音声信号を用いて、バックプロパゲーション法の階層型ニューラルネットワークに新アンサンブル学習を適用することにより、話者認証システムを構築し、アンサンブル学習の効果を明らかにした。さらに、本人認証システムを拡張することによって、マルチステップの個人認証システムを構築し、その性能を評価した。

2. 認証システム

図1は、本研究で用いたニューラルネットワークの構成を示している。図に示されるように、入力層、出力層、および1層の中間層から構成される3階層型ニューラルネットワークを使用した。入力層ユニッ

図1 本研究で用いた階層型ニューラルネットワーク
Fig.1 Layered neural network used in this study

図2 アンサンブル学習の概要
Fig.2 Outline of ensemble learning

ト I と中間層ユニット J 及び中間層ユニット J と出力層ユニット K の間は、それぞれ結合荷重 $W_{ji}^{(12)}$ と $W_{kj}^{(23)}$ で構成されている。これらの結合荷重 $W_{ji}^{(12)}$ と $W_{kj}^{(23)}$ の集合を結合荷重行列と呼ぶ。この結合荷重行列は、学習パターンと教師信号で更新される。このことをニューラルネットワークの学習と言う。1つの入力層ユニットは、入力された値を出力値 O_i として全ての中間層ユニットに出力する。1つの中間層ユニットでは、全ての入力層ユニットからの出力値と結合荷重 $W_{ji}^{(12)}$ を積和演算 ($\sum_{i=1}^I O_i W_{ji}^{(12)}$) する。この値をシグモイド関数で0~1の値に変換し、出力値 O_j として全ての出力層ユニットに出力する。1つの出力層ユニットでは、中間層ユニットと同様に全ての中間層ユニットからの出力値と結合荷重 $W_{kj}^{(23)}$ を積和演算 ($\sum_{j=1}^J O_j W_{kj}^{(23)}$) する。この値をシグモイド関数で0~1の値に変換し、出力する。

本研究では、学習アルゴリズムにバックプロパゲーション法 [25] を用いた。学習後の結合荷重行列は、学

図3 マルチステップの個人認証システムの概要
Fig.3 Outline of multi-step authentication system

学習パターンやネットワークパラメータが同じでも学習毎に異なる。これは、結合荷重行列の初期値が乱数で与えられることによる。

図2は、アンサンブル学習の概要を示している。図に示されるように、認証されるパターン(テストパターン)は各ニューラルネットワーク(NN#1~NN#M)にされる。各ニューラルネットワークは異なる結合荷重行列を持っているので、各ニューラルネットワークに同じパターンを入力しても異なった出力値 $g_1(x) \sim g_M(x)$ を持つ。これらの出力値 $g_1(x) \sim g_M(x)$ を平均することで出力値 $g(x)$ を得る。アンサンブル学習の手法には、異なった学習パターンを用いてニューラルネットワークを作成する方法等[21][24]があるが、本研究では同一の学習パターンを用いてニューラルネットワークを作成する方法を用いた。後者の場合では、少ない学習パターンでも異なった結合荷重行列を持つ多くのニューラルネットワークを生成することができる。

本人認証システムを拡張してマルチステップの個人認証システムを構築した。マルチステップの個人認証システムには、N. Fakotakisらの報告がある[2]。ここでは、1人の被認証者に対して、取得音声を一定間隔で分割した複数の学習パターンを用いて、それぞれ

の学習パターンに対するニューラルネットワークを構築し、話者認証を行っている。しかし、単一の学習パターンを用いて複数のニューラルネットワークを構築し、本人を認証する報告はなく、それらを組み合わせて個人を認証する報告もない。

図3は、 n 人の個人認証システムの概要を示している。図に示されるように、入力パターンは、A, ..., Nを認証するシステムに同時に入力される。各本人認証システムでアンサンブル学習を行い、個々の本人認証システムの出力値を得る。これらの出力値で個人を認証する。また、これらの本人認証システムはそれぞれ独立である。個人認証システムに新しい人を加える場合は、その人を本人とする本人認証システムを構築し、追加することで実現できる。この場合、ニューラルネットワークの学習に使用する他人のパターンは同一なので、本人のパターンのみで学習パターンを構築できる。さらに、学習に使用していない未知の他人が個人認証システムに入力された場合、事前に記録した各ニューラルネットワークの出力値と比較すれば、本人以外を拒否できる。

Voice collection and division

図 4 前処理の流れ

Fig.4 Flowchart of pre-processing used in this study

3. 実験方法

図 4 は、音声信号の処理の流れを示している。ここでは、母音「あ」を用いた。図に示されるように、母音は周期性を持った波形の繰り返しで構成されている。この波形の 1 周期を取り出し、1 周期を繰り返して、5 周期とした。これを 1 組とし、一人あたり計 10 組を取り出し、それらを高速フーリエ変換を行うために各組が 512 ポイントになるように再サンプリングした。次に、これらを高速フーリエ変換することでパワースペクトルとなり、ポイント数は 256 となる。これがニューラルネットワークへの入力パターンとなる。

表 1 は、音声コーパス [26] に収録されている音声の各種条件を示している。本研究で用いた音声は国立情報学研究所の音声資源コンソーシアム「日本語方言音声コーパス」に収録されている「あいうえお」と発

表 1 音声コーパス [26] に収録されている音声の各種条件

Table 1 Condition for voice signals from voice corpus [26]

Sampling frequency	16[kHz]
Sampling bit rate	16[bit]
Channel	1[ch](monaural)

表 2 ニューラルネットワークの各種パラメータ

Table 2 Experimental parameters of neural network

Number of input layer units	256
Number of hidden layer units	100
Number of output layer unit	1
Momentum coefficient	0.02
Learning coefficient	0.02
End condition(square error)	10^{-4}

音している音声中の「あ」を抽出して使用した。音声コーパスの採取条件はサンプリング周波数は 16kHz、ビット長は 16bit、モノラル音声である。本研究では、この音声の採取条件を変更せずに使用した。

表 2 は、ニューラルネットワークの学習における各種パラメータを示している。入力層、中間層及び出力層のユニット数はそれぞれ、256、100、1 であり、学習係数と慣性係数は共に 0.02、学習の終了条件となる教師信号と出力層ユニットの出力値との誤差 2 乗和は 10^{-4} 以下とした。学習には教師信号として他人パターンには“0”を与え、本人パターンには“1”を与えた。実験に用いた人数は 14 人で 1 人あたり 10 パターンの計 140 パターンを準備した。この内、学習パターンの本人として 5 パターンを、他人として 4 人計 20 パターンを使用した。残りの 115 パターンをテストパターンとして用いた。

バイオメトリクス認証に対するシステムの評価は、他人受入率 (FAR:False Acceptance Rate) と本人拒否率 (FRR:False Rejection Rate) を用いた。また、FAR と FRR が両方共に 0%となる閾値の範囲を閾値長 (Length of threshold value) として定義した。

図5 学習パターンにおける学習回数に対するニューラルネットワークの誤差2乗和

Fig.5 Square error of a neural network as a function of number of learning iterations for learning patterns

4. 結果と検討

4.1 本人認証システム

図5は、学習パターンにおける学習回数に対するニューラルネットワークの誤差2乗和を示している。ここでは、中間層ユニット数、慣性係数、学習係数及び終了条件はそれぞれ100, 0.02, 0.02, 10^{-4} である。図に示されるように、学習回数が増加すると、ニューラルネットワークの誤差2乗和は単調に減少した。これらの結果より、ニューラルネットワークは学習パターンに対して収束することがわかった。

図6は、学習パターンにおける閾値に対するFARとFRRの結果を示している。図に示されるように、FARの値は閾値の増加に対して急激に減少し、閾値が0付近で0%となった。また、FRRの値は閾値の増加に対して変化せず0%となり、閾値が1付近で急激に増加した。これらの結果から、閾値に対するFARとFRRが同時に0%となる領域があることがわかった。従って、学習パターンに対してニューラルネットワークは本人と他人を明確に区別できる。図5と図6の結果は、学習パターンに対してニューラルネットワークは正常に動作していることを示している。理想的な認証システムでは閾値に対するFARとFRRの振る舞いは、(1)FARの閾値の増加に対する減少、FRRの閾値の増加に対する増加、(2)FARとFRRが同時に0%となり、また閾値長が十分に大きいことである。

図7は、種々の結合荷重行列を持つニューラルネットワークを用いたテストパターンにおける閾値に対す

図6 学習パターンにおける閾値に対するFARとFRR

Fig.6 Error rate values of a neural network as a function of threshold value in an output layer unit for learning patterns

るFARとFRRの典型的な例を示している。ここでは、テストパターンとして学習で使用する人の未学習パターンを用いた。図に示されるように、(a)~(d)の異なる結合荷重行列を持つニューラルネットワークでは閾値に対するFARとFRRの振る舞いは異なった。(a)では、FARとFRRが同時に0%となる領域は存在しなかった。(b)~(d)では閾値長は0.1~0.9程度となった。これらの結果は、異なる結合荷重行列を持つニューラルネットワークの閾値に対するFARとFRRの振る舞いは、テストパターンに対して異なることを示している。

図8は、学習に使用する人のテストパターンにおける閾値に対するFARとFRRを示している。ここでは、異なる結合荷重行列のニューラルネットワークを20個作成し、それぞれにテストパターンを入力して得られた結果を閾値別に認証及び拒否に分類し、誤り率を算出した。図に示されるように、FARは閾値の増加に対して減少した。FRRは、閾値の増加に対して増加した。FARとFRRの値が同時に0%となる領域は存在しなかった。これらの結果より、20個のニューラルネットワークの総計は、典型的な閾値に対するFAR、FRRの振る舞いを示すが、FARとFRRの値が同時に0%になる領域が存在しなかった。従って、認証システムの性能としては、不十分であると考えられる。

学習に使用していない人のテストパターンを用いることによって、認証システムの性能に与える影響を調べた。図9はこれらの結果を示している。ここでは、図8と同じ20個のニューラルネットワークと学習に

図7 種々の結合荷重行列を持つニューラルネットワークを用いたテストパターンにおける閾値に対する FAR と FRR の典型的な例

Fig.7 Error rate values of neural networks with various weights as a function of threshold value in an output layer unit for test patterns

使用していない人のパターンを用いた。故に、図9においてFRRの値は図8と同じ値を使用した。図に示されるように、FARは閾値の増加に対して減少した。図9を図8と比較すると、図9の方が閾値に対するFARの傾きが緩やかであった。これらの結果は、学習に使用していない人をテストパターンとして使用した場合は、学習に使用する人をテストパターンに使用した場合よりFARの値が大きいこと、すなわちを認証システムの性能が低いことを示している。

4.2 アンサンブル学習を用いた本人認証システム

図10は、学習に使用した人のテストパターン(未学習)におけるアンサンブル学習での閾値に対するFARとFRRを示している。図に示されるように、FRRは閾値が0.8付近まで0%でその後増加した。FARは閾値の増加に対して減少し、閾値が0.1付近で0%となり、FARとFRRが共に0%となる閾値長が存在した。これらの結果より、アンサンブル学習を用いるとテストパターンに対して本人と他人を確実に区別できる。

図11は、学習に使用していない人のテストパター

ン(未学習)におけるアンサンブル学習での閾値に対するFARとFRRを示している。図のFRRは図10の結果を示している。図に示されるように、FARは閾値の増加に対して減少し、閾値が0.4付近で0%となり、FARとFRRが共に0%となる閾値長が存在した。これらの結果より、アンサンブル学習を用いると学習に使用していない人に対して本人と確実に区別できる。また、図10を図8と比較すると、アンサンブル学習の効果が明らかになった。さらに、図11を図10と比較すると、図11の閾値長は、図10より小さかった。この結果より、学習に使用する人あるいは使用しない人の未学習パターンの利用は、閾値に対するFARの振る舞いに影響を与えることがわかった。従って、アンサンブル学習は、個人認証に必要な情報以外を含む音声に対しても有効であることがわかった。このことは、アンサンブル学習において音声信号に含まれる雑音の影響が抑制されたことによると考えられる。

図12は、学習に使用する他人の数に対する閾値長を示している。ここでは、テストパターンとして学習に使用していない人のパターンを用いた。図に示されるように、閾値長は学習に使用する他人の数が3人ま

図 8 学習に使用する人の未学習パターンを用いたテストパターンにおける閾値に対する FAR と FRR

Fig.8 Error rate values of neural networks as a function of threshold value in an output layer unit for test patterns of persons used in learning

では大きな変化がなく、ほぼ一定で 0 付近であるが 4 人で増加した。

アンサンブル学習に使用するニューラルネットワークの数が閾値長に与える影響を調べた。図 13 は閾値長に対するアンサンブル学習に使用するニューラルネットワークの数を示している。ここでは、テストパターンとして学習に使用する人の未学習パターンを用いた。また、学習を同条件で 100 回行い、一定数のニューラルネットワークで組を作り、アンサンブル学習を行った。つまり、アンサンブル学習に使用するニューラルネットワークの個数が 4 個ならば 25 組のアンサンブル学習を行った結果が得られる。図にはアンサンブル学習した場合の閾値長の平均値と最小値及び最大値を誤差範囲として表している。図に示されるように、閾値長の平均値はニューラルネットワークの数に対してほぼ変化せず一定で、閾値長の誤差範囲はニューラルネットワーク数の増加に対して減少した。これらの結果より、ニューラルネットワークの数が増加すれば、閾値長は平均値に収束することがわかった。

図 12, 13 の結果より、図 13 のアンサンブル学習に使用するニューラルネットワークの数が 20 の場合、閾値長に約 0.06 の誤差範囲が存在する。図 12 の学習に使用する他人の数が 1~3 人の場合、閾値長が 0.06 に達していないため、認証システムを構築する際に、閾値長が 0 以下、すなわち FAR と FRR が共に 0 % の領域が存在しない可能性がある。これらの結果より、学習に使用する他人の数は 4 人以上が必要であることがわかった。学習に使用する他人の数は、少ない方が

図 9 学習に使用していない人を用いたテストパターンにおける閾値に対する FAR と FRR

Fig.9 Error rate values of neural networks as a function of threshold value in an output layer unit for test patterns of persons, who were not used in learning

良いので 4 人を最適値とした。故に、本研究では、学習に使用する他人の数は 4 人とした。また、使用した他人の数が 4 人の場合の閾値長は、0.06 以上なので、本研究で用いたニューラルネットワークの数は妥当である。

4.3 マルチステップの個人認証システム

表 3 は、マルチステップの個人認証システムの結果を示している。このシステムは 5 人の認証を行うため、5 ステップで構成されている。また各ステップのニューラルネットワークのパラメータには、前項までの最適値を用いた。横方向は人 A,B,C,D,E をそれぞれ認証する本人認証システム (ステップ a~e) を示し、縦方向はテストに用いた人 A,B,C,D,E,X,Y,Z の音声から得られた入力パターンを示している。ここでは、人 A,B,C,D,E は認証する人 (本人) で人 X,Y,Z は学習に使用しておらず、認証するステップを持たない人 (未学習の他人) である。A の音声のパターン (パターン A) が、ステップ a~e に入力され、各ステップから出力値を得る。その出力値を表の横方向に数値で示した。同様に、パターン B~Z も各ステップに入力され、それぞれから出力値を得る。表に示されるように、パターン A が入力された場合、各ステップ a~e の出力値はステップ a が最大となった。パターン B~E が入力された場合、パターン A の場合と同様に、それぞれのパターンを認証するステップの出力値が最大

表 3 マルチステップの個人認証システムの結果

Table 3 Results of the multi-step authentication sysytem used in this study

		Steps				
		a	b	c	d	e
Input patterns	A	0.88124	0.01073	0.00125	0.00297	0.05327
	B	0.00848	0.44645	0.32684	0.00206	0.08732
	C	0.00526	0.00732	0.94845	0.05615	0.00099
	D	0.00351	0.00145	0.00751	0.96380	0.03691
	E	0.02856	0.01464	0.00273	0.29763	0.77969
	X	0.03947	0.05041	0.31856	0.05005	0.08615
	Y	0.19779	0.13136	0.07860	0.00205	0.04018
	Z	0.00162	0.33714	0.48372	0.00708	0.20822

図 10 学習に使用する人の未学習パターンを用いたテストパターンにおける閾値に対するアンサンブル学習での FAR と FRR

Fig.10 Error rate values with ensemble learning of neural networks as a function of threshold value in an output layer unit for test patterns of persons used in learning

となった。これらの結果より、パターン A～E が入力された場合、それぞれを認証するステップで出力値が最大となるので、個人認証できることがわかった。

他人のパターン X, Y, Z が各ステップに入力された場合、それぞれステップ c, a, c の出力値が最大となった。また、システムを持たないパターン X が入力された場合、ステップ c の出力値が最大となるが、この値はステップ c の本人パターンである C の出力値以上とまらない。故に、人 C でないと判定できる。パターン Y, Z が入力される場合でもパターン X と同様となり、A～E でないと判断できる。これらの結果より、個人

図 11 学習に使用していない人を用いたテストパターンにおける閾値に対するアンサンブル学習での FAR と FRR

Fig.11 Error rate values with ensemble learning of neural networks as a function of threshold value in an output layer unit for test patterns of persons, who were not used in learning

認証システムは本人を正しく認証し、他人を認証しない。また、未学習の他人が増加すると間違った認証を行う可能性がある。このことは、本人と他人の境界線の学習が不十分であると考えられる。従って、「アンサンブルするニューラルネットワーク数を増加」または「学習に使用する他人の数を増加」を行えば、認証システムはより正確に本人と他人の境界線を学習し、正しく認証することが可能になると思われる。

図 12 学習に使用する他人の数に対する閾値長

Fig.12 Length of threshold values as a function of number of others used for learning of neural networks

図 13 アンサンブル学習に使用するニューラルネットワーク数に対する閾値長

Fig.13 Length of threshold values as a function of number of neural networks for ensemble learning

5. 結 論

音声コーパスに収録されている音声「あ」を使用して、階層型ニューラルネットワークを用いた話者認証システムの性能に新しいアンサンブル学習が与える効果を明らかにした。それらの結果から、以下のことがわかった。ニューラルネットワークの学習において、結合荷重行列の初期値は乱数で与えられるため同じ学習パターンを用いても異なる結合荷重行列を持つニューラルネットワークが作成される。このため、学習毎にニューラルネットワークの出力値が異なる。これらのニューラルネットワークを用いてアンサンブル学習を行った。アンサンブル学習を用いた本人認証システムでは、FAR と FRR が共に 0% となった。故に、ニュー

ラルネットワークを用いた音声の本人認証システムにはアンサンブル学習が有効であることがわかった。さらに、この本人認証システムを拡張して、個人認証システムを構築した。アンサンブル学習を用いた階層型ニューラルネットワークでは、音声信号に含まれる雑音を抑制することができると思われる。

参考文献

- [1] D. P. Morgan and C.L.Scofield: Neural networks and speech processing, Kluwer Academic Publisher, 1991.
- [2] N.Fakotakis and J.Sirigos: A high performance text independent speaker recognition system based on vowel spotting and neural nets, IEEE International Conference on Acoustics, Speech, and Signal Processing(ICASSP), pp.661-664, 1996.
- [3] J.P.Campbell Jr.: Speaker recognition: A tutorial, Proc.IEEE, Vol.85, No.9, pp.1437-1462, 1997.
- [4] D.O'Shaughnessy: Speech communications, IEEE Press, 2000.
- [5] K.Amit and B.Biswas: Speaker identification from voice using neural networks, Scientific & Industrial Research, Vol.61, No.8, pp.599-606, 2002.
- [6] 田中章浩, 小林光, 岸田悟, 長谷川弘, 渡邊徹: 階層型ニューラルネットワークを用いた声紋による個人認証システムの構築, 電子情報通信学会技術研究報告, ニューロコンピューティング, Vol.107, No.542, pp.427-431, 2008.
- [7] 小林光, 田中章浩, 木下健太郎, 岸田悟: 声紋による個人認証システムの構築, 電子情報通信学会技術研究報告, ニューロコンピューティング, Vol.108, No.480, pp.13-17, 2009.
- [8] S.Onishi, A.Tanaka, H.Hasegawa, K.Kinoshita and S.Kishida: Construction of individual identification system using voice in three-layered neural networks, International Symposium on Intelligent Signal Processing and Communication Systems(ISPACS), pp.635-637, 2009.
- [9] F.N.Tuang, J.L.W.Radmaker, E.C.Alocilja, F.J.Louws and F.J.Bruijn: Identification of bacterial rep-PCR genomic fingerprints using a backpropagation neural network, FEMS Microbiology Letters, Vol.177, pp.249-256, 1999.
- [10] H.Hasegawa, A.Tanaka, S.Kishida and K.Nishimura: Preprocessing method of fingerprint images in layered neural networks for individual identification, International Symposium on Intelligent Signal Processing and Communication Systems(ISPACS), pp.267-270, 2006.
- [11] 田中章浩, 大西俊輔, 木下健太郎, 岸田悟: マニューシャ法により得られた指紋の特徴点とニューラルネットワークを用いた認証システムの構築, 電子情報通信学会技術研究報告, ニューロコンピューティング, Vol.109, No.461, pp.237-242, 2010.
- [12] K.Ito, T.Aoki, H.Nakajima, K.Kobayashi and T.Higuchi: A palmprint recognition algorithm using phase-only correlation, IEICE Trans. Fundamentals, Vol.E91-A, No.4, pp.1023-1030, 2008.

- [13] N.Miura, A.Nagasaka and T.Miyatake: Feature extraction of finger-vein patterns based on repeated line tracking and its application to personal identification, *Machine Vision and Applications*, Vol.15, No.4, pp.194-203, 2004.
- [14] Y.Zhu, T.Tan and Y.Wang: Biometric personal identification based on iris patterns, *IEEE International Conference on Pattern Recognition(ICPR)*, Vol.2, pp.801-804, 2000.
- [15] C.Kanali, H.Murase and N.Honami: Shape identification using a charge simulation retina model, *Mathematics and Computers in Simulation*, Vol.48, pp.103-118, 1998.
- [16] A.Martinez and H.Jia: Support vector machines in face recognition with occlusions, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition(CVPR)*, Neural Networks, Vol.14, pp.795-803, 2001.
- [17] I.Nakanishi, N.Nishiguchi, Y.Ito and Y.Fukui: On-line signature verification method using adaptive algorithm in wavelet transform domain, *International Technical Conference on Circuits/Systems, Computers and Communications(ITC-CSCC)*, Vol.1, pp.385-388, 2002.
- [18] 三村正人, 河原達也: CSJ を用いた日本語講演音声認識への DNN-HMM の適用と話者適応の検討, *情報処理学会研究報告, 音声言語情報処理*, Vol.2013-SLP-97, No.9, pp.1-6, 2013.
- [19] T.Shimizu, N.Furuse, T.Yamazaki, Y.Ueta, T.Sato and S.Nagata: Chaos of vowel /a/ in Japanese patients with depression: A Preliminary Study, *Journal of Occupational Health*, Vol.47, pp.267-269, 2005.
- [20] N.Fujiwara, A.Tanaka, K.Kinoshita and S.Kishida: Effect of alcohol concentrations in blood on voice signals from human body, *International Workshop on Nonlinear Circuits, Communication and Signal Processing(NCSP)*, pp.712-715, 2012.
- [21] 上田修功, 中野良平: アンサンブル学習における汎化誤差解析, *電子情報通信学会論文誌 D-2*, Vol.J80-D-2, No.9, pp.2512-2521, 1997.
- [22] D.Luo and C.Ke: A comparative study of statistical ensemble methods on mismatch conditions, *Proc. IJCNN2002*, pp.59-64, 2002.
- [23] 上田修功: アンサンブル学習の新展開, *電子情報通信学会技術研究報告, ニューロコンピューティング*, Vol.102, No.381, pp.31-36, 2002.
- [24] T.Sasaki, K.Kinoshita, S.Kishida, Y.Hirata and S.Yamada: Ensemble learning in the systems of neural networks for detection of abnormal shadows from X-ray images of lungs, *International Workshop on Nonlinear Circuits, Communication and Signal Processing(NCSP)*, pp.712-715, 2012.
- [25] D.E.Rumelhart, G.E.Hinton and R.J.Williams: Learning representations by back-propagating errors, *Nature*, Vol.323, No.9, pp.533-536, 1986.
- [26] 大学共同利用機関法人 情報・システム研究機構 国立情報学研究所 音声資源コンソーシアム 基盤研究「日本語方言の地域差」方言音声コーパス (GSR-JD), 板橋秀一, 筑波大学, 2006.

長谷川 弘 1980 年 3 月鳥取大学工学部電子工学科卒業。1982 年 3 月同大学大学院工学研究科修士課程修了。1982 年 3 月富士通第一ソフトウェア株式会社 (現: 富士通株式会社) 入社 電話交換機関連システム開発に従事。1998 年 2 月セコム山陰株式会社入社。インターネットサービス開発とともにセキュリティコミュニケーションの研究に従事。現在, セコム山陰株式会社シニアマネージャー。2006 年 4 月鳥取大学大学院工学研究科博士後期課程入学, 現在に至る。

木下 健太郎 1999 年立教大学理学部物理学科卒業。2001 年東京大学大学院理学系研究科博士前期課程修了。2004 年同博士後期課程修了。博士 (学術)。同年 (株) 富士通研究所入社。2013 年鳥取大学大学院工学研究科情報エレクトロニクス専攻准教授, 現在に至る。主に抵抗変化型メモリの物性に関する研究に従事。MRS, 応用物理学会会員。

岸田 悟 1975 年鳥取大学工学部電子工学科卒業。1977 年同大学大学院工学研究科修士課程修了。学術博士。現在, 鳥取大学工学部附属電子ディスプレイ研究センター (TEDREC) 長, および同大学院工学研究科情報エレクトロニクス専攻教授。ニューラルネットワークの基礎と応用に関する研究に従事。電気学会, 電子情報通信学会, 日本液晶学会会員。

(2013 年 4 月 11 日受付; 2013 年 8 月 17 日再受付)