

教師付きパレート学習型自己組織化マップの マルチモーダル生体認証への応用

堂 蘭 浩^{†1} 伊 東 信 介^{†1} 中 國 真 教^{†2}

近年、コンピュータセキュリティは重要な問題となっている。セキュリティ上重要であるユーザ認証には、ほとんどのコンピュータでパスワードが用いられている。しかし、パスワードには様々な運用上の問題が存在する。この問題に対し、マルチモーダル行動型生体情報の統合方式を適用した際の生体情報の統合方式として、教師付きパレート学習型自己組織化マップを開発した。また、本方式の有効性を、キー入力タイミングとキー入力音の組合せを用いた個人認証実験により確認を行った。

Application of the Supervised Pareto Learning Self Organizing Maps to Multi-modal Biometric Authentication

HIROSHI DOZONO,^{†1} SHINSUKE ITO^{†1}
and MASANORI NAKAKUNI^{†2}

Recently, security of the computer systems becomes an important problem. Almost all computers use the password mechanism for the user authentication. But password mechanism has many issues. For this problem, biometrics authentication is used as the solutions. In this paper, we propose the Supervised Pareto learning Self Organizing Maps which can be applicable to the integration of multi-modal behavior biometrics. The performance of this method is confirmed by the authentication experiments using the combinations of key stroke timings and key typing sound.

^{†1} 佐賀大学
Saga University

^{†2} 九州大学
Kyushu University

1. はじめに

近年、コンピュータセキュリティは重要な問題となっている。セキュリティ上重要であるユーザ認証には、ほとんどのコンピュータでパスワードが用いられている。しかし、パスワードには様々な運用上の問題が存在する。まず第1に、パスワードは静的な文字列であるため、ショルダハッキングにより盗み見されたり、生年月日や住所などの個人情報から推測されたり、忘れてしまわないようにと記録したパスワードのリストのメモなどから盗用されたりすることが考えられる。第2に、複数の異なったシステムに対し、本来、異なったパスワードを用いるべきであるが、たいていの人は同じパスワードを用いているため、1システムのパスワードがハックされると、すべてのシステムがアクセス可能となってしまう。第3に、パスワードとして適しているとされている記号、数字、大文字小文字を含んだ文字列は、入力ミスも多くなるため、人によっては面倒と感じたり、複数のシステムに対しては、覚えきれないという場合も考えられる。

このようなパスワード認証方式の問題点に対し、生体認証¹⁾が1つの解決策とされている。生体認証方式には、指紋、虹彩、静脈パターンなどの静的な生体的特徴を用いる方法と、手書き文字、キーボード入力タイミングなどの動的な行動的特徴を用いる方法がある。指紋認証方式は生体認証方式として最も普及しており、指紋認証ユニットを装備したパソコンや、USB接続による認証ユニットが販売されている。しかし、静的な生体的特徴を用いる認証方式は、正確に作成されたダミーを用いることで破られる可能性がある。実際、ディスクバリチャンネルで放送された番組²⁾で、特殊効果の専門家によってCDのケースについた指紋から作成されたダミーの指先を用いて、USBの指紋認証ユニットと指紋を鍵として用いたドアが破られている。また、生体的特徴を用いる認証方式は、なんらかの追加のハードウェアを必要とし、コンピュータにかかるコストを向上させてしまう。さらに、指紋をホストシステムに登録するのに不快感を感じるユーザも存在すると考えられる。

行動的特徴を用いた認証方式は、これらの問題点を軽減させることが可能である。まず、行動的特徴は、動的な情報であるためまねることは困難であると考えられる。また、行動的特徴によってはコンピュータに装備された機器から取得することが可能である。たとえば、キー入力タイミングはキーボードにより取得可能であり、手書き図形的特徴はTabletPCやPDAのタッチパネル、ノートパソコンのタッチパッド、また、一般的なマウスからでも取得することが可能である。本研究グループでは、PDAやTabletPCのタッチパッドを用いて計測した、ペン入力速度、筆圧を用いた認証方式や、キーボード入力タイミングを用いた

認証方式について報告している⁴⁾⁻⁷⁾。手書き図形やキーボード入力タイミングが個人認証に使用可能であることはよく知られているが⁸⁾⁻⁹⁾、提案した認証方式では、システムが提示した図形をトレースしたり、システムが提示したフレーズを入力したりすることで特徴量を抽出し、個人認証を行うことで、前述のパスワードの問題点であったユーザの記憶にたよらない認証方式を目指している。しかしながら、行動的特徴は生体的特徴と比較してあいまいさが大きく、これらの行動的特徴を用いた認証方式は、生体的特徴を用いた認証方式と比較して認証の精度が低くなってしまふ。そのため、複数の行動的特徴量の組合せで、認証精度を向上させることが可能であると考えられる。複数のタイプの生体情報を組み合わせた認証方式には、量的にも質的にも異なったタイプの生体情報からなるマルチモーダルなベクトルを統合する方法が必要となる¹⁰⁾。

本論文では、教師付きパレート学習型 SOM を用いたマルチモーダルな生体情報の統合およびその個人認証への応用について提案する。従来の自己組織化マップ (Self Organizing Map: SOM)³⁾ もマルチモーダルなベクトルの統合に用いることができ、文献 11) においてキー入力タイミングと手書き図形のペン入力速度および筆圧情報の統合に用いられている。しかし、従来の SOM では、それぞれの特徴量を表すベクトルの重み付き結合により複数のベクトルの統合を行うため、適切な重み値の設定を行うのに、多くの試行を行う必要があった。この問題に対し、文献 12) においてパレート学習型 SOM (Pareto Learning SOM: P-SOM) を提案し、従来の SOM より良い結果が得られることを示した。パレート型の SOM においては、各ベクトルを重み値で結合することなく、それぞれのベクトルを独立のベクトルとして扱い、パレート最適性の考え方をを用いてマップを生成するため、重み値の設定は不要になる。SOM はその学習の際に、各入力ベクトルに対し、マップ上からベストマッチユニットを探索し、そのユニットとその近傍を更新する。それに対し、P-SOM ではマルチモーダルな入力ベクトルに対し、パレート最適性の考え方をを用いて、パレートの意味でベストマッチなユニットの集合をマップ上から探索し、ユニットの集合全体とその近傍を更新する。しかし、認証精度が大きく異なるマルチモーダルなベクトルから構成されたバイオメトリクス情報に P-SOM を適用したところ、認証精度が悪いベクトルに影響され、入念に試行を繰り返し重み値を調整された従来の SOM より著しく悪い結果となる場合があった。この問題に対し、P-SOM の認証精度を向上させる方式として、教師付きパレート学習型 SOM (Supervised Pareto learning SOM: SP-SOM) を開発した。SP-SOM では、P-SOM にマルチモーダルなベクトルの 1 つとしてユーザの識別情報を加えることで、認証精度の向上を図っている。また、キー入力タイミングとキー入力音からなるマルチモーダル

な生体情報を用いた個人認証方式に SP-SOM を適用し、その有効性を確認した。本論文では、2 章で SOM、および、P-SOM、SP-SOM のアルゴリズムについて述べ、3 章でキー入力タイミングとキー入力音による個人認証方式、4 章で個人認証実験結果を述べる。

2. 自己組織化マップ

2.1 自己組織化マップの概要

自己組織化マップ (SOM) はフィードフォワードタイプの教師なし学習を行う単層ニューラルネット (結合重みを数えた場合) の 1 種である。SOM は入力ベクトルの集合をその特徴に従って、出力ニューロンが配置された 2 次元平面上に組織化するように学習を行う。学習後に、入力ベクトルを写像することで、入力ベクトル間の関係を 2 次元平面上で視覚化したり、入力ベクトルのクラスタリングを行ったりすることが可能である。元々の SOM のアルゴリズムでは、1 つの入力ベクトルが与えられるたびにマップ上のニューロンの重みベクトルを更新する方法が用いられていた。最近の SOM のアルゴリズムでは、主成分分析 (Principal Component Analysis: PCA) を入力ベクトルに対して適用し、バッチ型の学習を行うことで、性能の改善が図られている。PCA は入力ベクトルの次元を縮小し、学習の効率を上げるために用いられる。また、マップの初期化の際に PCA の s 方向と t 方向を、初期マップの x 方向、 y 方向の主成分として初期化を行うことで、マップにある程度の初期情報を与え、学習の効率化を図ることができる。また、バッチ型の学習を行うことで、入力ベクトルを与える順序による学習結果の相違を吸収し、学習を高速に行うことが可能となる。バッチ型の学習は、競合フェーズと更新フェーズの 2 つのフェーズからなり、競合フェーズでは各入力ベクトルを、そのベクトルに一番近い重みベクトルを持つ出力ニューロンに関連づけ、更新フェーズでは出力ニューロンの重みベクトルを、そのニューロンと近傍のニューロンに関連づけられた入力ベクトルの値に従って更新する。

2.2 パレート学習型 SOM

自己組織化マップをマルチモーダルなベクトルの解析に用いる場合、異なる型のベクトル x_1, x_2, \dots, x_n を 1 つのベクトル x に次式のように結合する。

$$x = (w_1 x_1, w_2 x_2, \dots, w_n x_n) \quad (1)$$

ここで、 w_j はベクトル x_j に対する重み値である。なお、今後、ニューロンの保持するベクトルを重みベクトル、ベクトルの結合に用いる値を重み値と呼ぶことにする。この方法を用いると、入力ベクトル x とマップ上のニューロンの保持するベクトル $m = (m_1, m_2, \dots, m_n)$ 間の誤差は以下の式で与えられる。

$$e = \sqrt{\sum_{j=1}^n w_j^2 e_j^2} \tag{2}$$

$$e_j = |x_j - m_j| \tag{3}$$

ここで、 e_j は入力ベクトルの各要素ベクトル x_j の誤差である。SOM はこの全体の誤差 e を最小化するようにマップを構成するため、結果として得られるマップは重み値 w_j の値により、大きく異なるものとなる。また、このマップを用いて個人認証を行う場合、認証精度も w_j の設定に大きく左右される。これは、複数のベクトルに対する最適化を 1 つの誤差関数で行おうとしたためである。見方をかえると、この問題は独立のベクトルの集合 $\{x_j\}$ に対して、誤差 e_j を最小化する、多目的最適化問題ととらえることができる。多目的最適化問題においてはパレート最適性の概念が最適解を求めるのに重要である。本論文では SOM の学習にパレート最適性の概念を取り入れたパレート学習型 SOM (Pareto learning SOM: P-SOM) を用いる。従来の SOM と P-SOM の相違点は、SOM はその学習時にマップ上から入力ベクトルに最も近いベクトルを持つユニットを勝者ユニットとして選択し、そのユニットとその近傍のユニットを更新するが、P-SOM は入力ベクトルに対し、パレート最適の意味で最も近いベクトルを持つユニットの集合を選択し、その集合のすべてのユニットに対し、そのユニットとその近傍の更新を行う。また、P-SOM はマルチモーダルなベクトルをそのまま学習するため、重み値 w_j を必要としない。P-SOM の概念図を図 1 に、P-SOM のアルゴリズムを以下に示す。

P-SOM アルゴリズム

(1) 主成分解析

入力ベクトルの集合 $\{x^i\}$ の主成分ベクトルを求める。ただし、 $x^i = (x_1^i, x_2^i, \dots, x_n^i)$ はマルチモーダルなベクトル $x_j^i, 1 \leq j \leq n$ から構成された i 番目の入力ベクトルである。

(2) マップの初期化

マップ上のユニット U^{st} に与えられるベクトル m^{st} の第 1 主成分を s 方向、第 2 主成分を t 方向として線形に初期化する。

(3) バッチ競合フェーズ

- (i) すべてのユニット U^{st} の学習バッファを初期化する。
- (ii) それぞれの入力ベクトル x^i に対し、ユニットのパレート最適集合 $P = \{U^{sp^t p}\}$ を探索する。ただし、 $U^{sp^t p}$ がパレート最適集合の要素である条件は、ユニット U^{st}




図 1 P-SOM の概念図
Fig. 1 Schematic representation of P-SOM.

全体の集合 Π にすべてのベクトルの誤差 $e_h^{st}, 1 \leq h \leq n$ が $e_h^{sp^t p}$ よりも小さいユニットが存在しないことである。ここで、 $e_h^{st} = |x_h^i - m_h^{st}|$ とする。

(iii) x^i をすべてのユニット $U^{sp^t p} \in P$ の学習バッファに追加する。

(4) バッチ更新フェーズ

各ユニット U^{st} のベクトル m^{st} を U^{st} とその近傍のユニットの学習バッファに蓄えられたベクトルの重み付き平均で、以下のように更新する。

(I) U^{st} とその距離が $d \leq Sn$ の近傍ユニットの学習バッファに蓄えられたすべてのベクトル x_{buf} に対し、更新量の重み付き和 S と重みの和 W を以下の式で計算する。

$$S = S + \eta fn(d)(x_{buf} - m^{st}) \tag{4}$$

$$W = W + fn(d) \tag{5}$$

ここで、 x_{buf} は U^{st} とその近傍ユニットのバッファに格納されたベクトル、 η は学習係数、 $fn(d)$ は距離 $d=0$ で 1、 d の増加により 0 まで減少する近傍関数である。

(ii) $m^{st} = m^{st} + S/W$ と更新する。

(3) と (4) を近傍の大きさ Sn と学習係数 η を減少させながら、あらかじめ定めた回数繰

り返す。

アルゴリズム中の(2)でPCAを用いたマップの初期化を行っているが、P-SOMにおいてPCAによる初期化は重要なものとなっている。なぜなら、ランダムな初期化を行った場合、1つの入力ベクトルに対するパレート集合のユニットがマップ上に散乱し学習がうまく行われなくなるが、PCAで初期化を行うことで、パレート集合がマップ上でまとまって形成され学習がスムーズに進むと考えられるからである。なお、PCAを用いて変換したベクトルを用いて、学習を行うSOMのアルゴリズムも存在するが、変換したベクトルを用いても、重み値の設定によりマップは変化し、また、このアルゴリズムでは入力ベクトルの次元が低いため、元のベクトルをそのまま用いて学習を行っている。

また、バッチ競合フェーズにおいて、パレート最適集合を用いているため、各ユニットのそれぞれのマルチモーダルなベクトルに対し、入力ベクトルに近いベクトルを探索し、勝者ニューロンのパレート集合を生成し、ニューロンの重みベクトルの各構成ベクトルが別々の方向に更新されるように思えるが、自己組織化マップのアルゴリズムはバッチ更新フェーズにおいて近傍ユニット全体を入力ベクトルに近づける処理を行っているため、結果として、各ユニットのマルチモーダルなベクトルは入力ベクトル内のマルチモーダルなベクトルに近づくように調整され、重みベクトルを用いなくても学習が適切に行われると考えられる。また、この処理は入力ベクトルの構成要素間の相関が強いほど、更新方向が同一になるのみであり、結果として相関係数には関係なく学習が行われると考えられる。

P-SOMは教師なし学習を行うので、認証実験にP-SOMのマップを用いる際は、各ユニットにどのユーザの入力にあたるかのラベル付けを学習後に行う必要がある。ラベル付けの際は、各ユニットに対し、パレート最適の意味で最も近い入力ベクトルの集合を探索し、それらの入力ベクトルのユーザから、多数決によりそのユニットのラベルを決定する。また、テストデータに対しユーザを決定する際は、テストデータに対するパレート最適なユニットの集合を求め、そのユニットにつけられたラベルの多数決によりユーザを決定する。

2.3 教師付きパレート学習型 SOM

P-SOMを用いクラス分け(ユーザ認証の際のユーザ決定)の実験を行ったところ、マルチモーダルな入力ベクトルに認証精度が悪いベクトルが存在する場合、そのベクトルの影響を受け、全体の認証精度が落ちるという影響が見られた。実際、この後実験に用いるキーボード入力タイミングとキー入力音においては、キー入力音が、入力タイミングと比較して認証精度が大きく劣るため、P-SOMの認証精度は落ちる結果となった。そこで、P-SOMのクラス分け(ユーザ認証の際のユーザ決定)の精度を向上させるために、P-SOMにカテゴ

リ(ユーザの分類)を教師データとして学習させる改良を行ったものが教師付きパレート学習型 SOM (Supervised Pareto learning SOM: SP-SOM) である。具体的には、P-SOMはマップ上にマルチモーダルなベクトルを統合できるので、入力ベクトルの一部として、カテゴリを表すベクトルを加えて学習を行うものである。SP-SOMに与えられる入力ベクトル \hat{x}^i は以下の式で与えられる。

$$\hat{x}^i = (\mathbf{x}^i, \mathbf{c}^i) \quad (6)$$

$$c_j^i = \begin{cases} 1 & \mathbf{x}^i \in C_k \\ 0 & \text{otherwise} \end{cases} \quad (7)$$

ここで C_k は k 番目のカテゴリを表す。入力ベクトルの変更以外は、SP-SOMの学習アルゴリズムは前述のP-SOMのアルゴリズムと同じである。ここで、ニューロンに学習される重みベクトルは $\hat{\mathbf{m}}^{st} = (\mathbf{x}^{st}, \mathbf{c}^{st})$ となる。SP-SOMにおいてはカテゴリベクトルも入力ベクトルとして扱うため、各ユーザごとの入力ベクトルが、マップ上でより近づくように調整され、P-SOMより高い識別能力を有すると考えられる。また、カテゴリ込みで学習を行うため、学習後のユニットのラベル付けは不要であり、以下のアルゴリズムを用いてカテゴリの決定を行う。

SP-SOMの想起アルゴリズム

- (1) パレート最適ユニット集合の探索
与えられたテスト入力ベクトル \mathbf{x}^a に対し、パレート最適なユニットの集合 $P = \{U^{sp^t p}\}$ を求める。
- (2) カテゴリの決定
パレート最適集合内のユニット全てに対して、カテゴリベクトルの和を計算する。

$$f_k^a = \sum_{U^{st} \in P} c_k^{st} \quad (8)$$

ここで、 $l = \text{argmax}_k (f_k^a)$ (カテゴリベクトルの和が最大となる番号 k) のとき、 \mathbf{x}^a のカテゴリを C_l とする。

3. キーボード入力タイミングとキー入力音を用いた個人認証方式

3.1 概要

前述のように、本研究室ではパスワードにおける認証方式の問題点、および、静的な生体

的な特徴を用いた生体認証方式の問題点を補う方法として、動的な行動的特徴を用いた生体認証方式を研究してきた。その中で本論文では、キーボード入力タイミングとキー入力音を組み合わせた個人認証方式について実験例として使用する。キーボード入力タイミングがバイオメトリクスとして有用であることはすでによく知られている。また、さらに認証精度を上げるために、他の情報を組み合わせて認証を行う研究が行われており、タイミングの情報にキーコード（シフト、CAPS など含む）を加え、統計的な分類法で個人認証を行う方法で、より高い認証精度が得られることが示されている¹³⁾。ただ、キーコードはパスワードと同じくある程度静的な情報であるため、不正ユーザによるなりすましが可能であると考えられる。また、キー入力タイミングとキーボードの下に敷かれた圧力センサを用いて計測した打鍵時の圧力を Fuzzy ART MAP を用いて情報の統合を行う研究¹⁴⁾が行われている。しかし、圧力センサを用いるには、圧力センサ自体やアナログ値の取り込みを用いる AD 変換器など多くの追加ハードウェアが必要となり、これらのハードウェアは一般的なコンピュータには不要であることから、普及は難しいと考えられる。自己組織化マップを用いてキー入力タイミングのみを用いた認証を行う方法も研究されているが¹⁵⁾、認証精度は低いものとなっている。

そこで、本論文では圧力センサの代わりに、キー入力音をサンプリングして使用する方法を提案する。特に、ノートパソコンにはマイク内蔵のものも多く、外付けにしてもほとんどコストは上昇しないと考えられる。また、認証に用いる文字列は、全ユーザに対して単一のものとし、ユーザの記憶には頼らないものとした。

3.2 実験環境

実験環境は図 2 のように、キーボードの中心かつタイピング時に邪魔にならない場所に固定したマイクからキー入力音を取り解析する。なお、キーボードはノート型パソコン本体のものを利用した。

3.3 サンプルデータの取得

作成した記録用プログラムを用いて被験者に文字列を入力してもらい、学習に用いる入力タイミングおよびキー入力音を取得する。キー入力音を録音する際の条件は、サンプリング周波数を 44,100 [Hz]、ビットレートを 16 [bit/s] とする。

また、入力タイミングの記録として、キー入力音のサンプリングタイミングに合わせ、キーボードの英数字が押されている場合 “5000” を出力し、その他のキーが押されたとき、あるいは、キー入力されていない場合には “0” を出力するようにする。

これらの結果をテキストファイルに出力し、データ解析および個人認証実験に使用する。




図 2 実験環境
Fig. 2 Experimental setting.

なお、出力したデータを波形化したものを図 3 に示す。

各キーの打鍵時およびキーから指を離すタイミングごとにキー入力音が発生している。また、キー入力音の波形は入力キーごとに異なっていることが確認できる。また、外部からの音によるノイズは打鍵時の音に比べると小さく、問題にならないと考えられる。キー入力音の特徴量としては各入力ごとのキー入力音の最大値を用いるものとした。このとき、キー入力音とキー入力タイミングのキーが押されている時間間の相関係数の平均は約 0.372 となり、ある程度の相関はあるが、ほぼ独立な成分を含むベクトルとして扱うことができると考えられる。

実際の実験においては 10 人の被験者に、“kirakira” という文字列を 10 回ずつ入力してもらい、次章で述べる自己組織化マップによる解析と個人認証実験に使用した。このとき入力ベクトルは、文字列長が L のとき、キー入力タイミングが、キーを押している時間が L 個、間隔が $L - 1$ 個で合計 $2L - 1$ 次元、キー入力音が L 次元の 2 つベクトルの組合せと

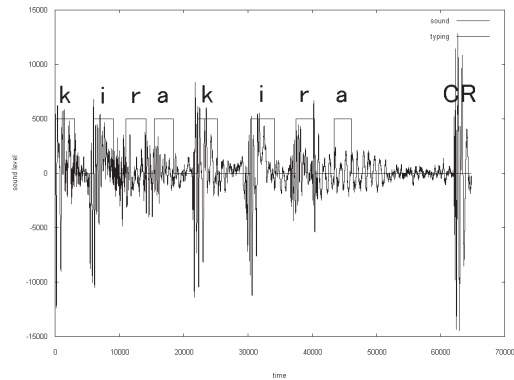


図3 キーボード入力タイミングおよびキー入力音の出力波形
Fig.3 Wave form of keystroke timings and key typing sound.

なる。また、この文字列は、文献7)において、単一の文字列のキー入力タイミングでユーザを識別可能な文字列を自己組織化マップを用いて解析するという研究において、最も識別率が高かった文字列である。また、このような文字列を用いることで、ユーザは文字列を意識することなくタイピングが行え、キー入力タイミングやキー入力音をバイオメトリクス情報として用いるうえで有利になると考えられる。1人ごとの入力回数が少ないように思えるが、これまでの同種の実験から、入力回数が多いと被験者が実験中に飽きてしまい、正確なデータがとれなくなる傾向があるからである。

4. 自己組織化マップを用いた解析および個人認証実験

4.1 自己組織化マップを用いた解析

次に自己組織化マップを用いたデータの解析および認証実験について述べる。まず最初に、得られたキー入力タイミングとキー入力音のユーザごとの特徴を見るために、自己組織化マップを用いて、ユーザごとのデータ間の関係の視覚化を行った。次にその結果を示す。マップのサイズは16×16で初期近傍サイズが4、マップ上の番号はユーザ番号を表し、各番号がまとまってクラスタリングされているものが、より望ましい結果となる。ユーザ番号は、SOMに対しては各ユニットのベクトルに対し最も近い入力ベクトルのユーザ番号とし、SP-SOMに関してはカテゴリベクトルが最大のユーザ番号とした。学習回数はSOMのマップがバッチで全データを22回ずつ、SP-SOMのマップが55回ずつ学習したもので




図4 ユーザ番号でラベル付けしたキー入力タイミングのマップ(SOM)
Fig.4 Map of keystroke timings organized by SOM labeled with user numbers.




図5 ユーザ番号でラベル付けしたキー入力音のマップ(SOM)
Fig.5 Map of key typing sound organized by SOM labeled with user numbers.

ある。学習回数は後に述べる個人認証実験において良い結果が得られた回数を用いた。また、これらのマップは循環型のマップとなっており、マップの上下、左右は結合されている。1つ1つのマップを見てみると、図4のキー入力タイミングのマップは、比較的ユーザ番号がまとまっているが、一部のユーザには複数のクラスタがみられる。図5のキー入力音のマップに関しては、ある程度はまとまっているが、ほとんどのユーザに対して複数のクラスタがみられる。図6のSP-SOMを用いて生成したマップはほとんどのユーザに対してユーザ番号がまとまっており、一番良好なマップが生成されている。次にSP-SOMの収束性を見るために、パレート集合のサイズの変化を学習ステップごとにグラフ化したものを図7に示す。パレート集合のサイズが学習が進むにつれ6まで収束しており、パレート型SOMの学習の収束性が確認できた。




図 6 ユーザ番号でラベル付けしたキー入力タイミングとキー入力音のマップ (SP-SOM)

Fig. 6 Map of keystroke timing and key typing sound organized by SP-SOM labeled with user numbers.




図 7 パレート集合の平均サイズの変化

Fig. 7 Average number of size of pareto sets.

4.2 個人認証実験

次に自己組織化マップを用いた個人認証実験について述べる．今回の個人認証実験はオンラインではなく，前節で取得したデータを用いて行う．各ユーザごとに 10 回ずつデータを取得しているので，その中で 5 つのデータを学習用に，5 つのデータをテスト用に使用して，学習用とテスト用のデータのすべての組合せについて実験を行った．すなわち，実験の回数は ${}_{10}C_5=252$ 回，テストデータの総数は 1 ユーザにつき， $5 \times {}_{10}C_5=1260$ となる．まず，最初にキー入力タイミング，キー入力音それぞれに対し，個人認証実験を行った結果を表 1

表 1 各特徴量に対する認証実験の結果 (SOM)

Table 1 Result of authentication experiment with each feature (SOM).

user	timing		sound	
	FRR	FAR	FRR	FAR
User 1	0.552	0.0000	0.191	0.0000
User 2	0.226	0.0375	0.432	0.0414
User 3	0.188	0.0231	0.570	0.0604
User 4	0.006	0.0401	0.573	0.0442
User 5	0.070	0.0043	0.253	0.0847
User 6	0.187	0.0356	0.761	0.0045
User 7	0.145	0.0165	0.216	0.0314
User 8	0.257	0.0366	0.365	0.0332
User 9	0.311	0.0144	0.397	0.0235
User10	0.189	0.0054	0.096	0.0404
Average	0.213	0.0213	0.386	0.0363

に示す．ここで FRR は False Reject Rate (本人拒否率) で，正規ユーザを認証できない率，FAR は False Accept Rate (他人受け入れ率) で，他人がそのユーザと認証されてしまう率を表し，どちらも低い方が望ましい指標である．また， $1.0-FRR$ が本人の認証の成功率を表す．キーボード入力タイミングにおいては平均で成功率が約 79% であり，ある程度良好な結果といえるが，キー入力音に関しては，約 61% でありキー入力音のみでは，キー入力タイミングよりかなり劣る結果となっている．また，認証の成功率はそれぞれのデータに対して個人差が大きいことが分かり，全体としてはキー入力タイミングの方が良いが，逆転しているユーザもみられる．他人受け入れ率に関しても，キー入力タイミングの方が良好な結果となっている．次に，各特徴量に対し，カテゴリベクトルのみを加えた SP-SOM を用いて認証実験を行った結果を表 2 に示す．一部のユーザに関しては，SOM の方が良い結果を示しているが，平均としては SP-SOM の方が良い結果を示しており，SOM にカテゴリベクトルを加えるのみでも，識別精度は向上していると考えられる．

次にタイミングとキー入力音を統合して認証を行った結果を表 3 に示す．特徴量の統合には SOM, P-SOM, SP-SOM を用いて実験を行った．前述のように SOM に関しては重み値の決定が必要であるが，今回は，何回かの実験を繰り返して重み値を選択し，キー入力タイミング 1.0 に対して，キー入力音の重みを $w = 0.0028$ とした．この重み値は一見すると小さいように思えるが，キー入力音ベクトルとキー入力タイミングベクトルの平均ノルムの差が大きいため，このような値となった．結果を見てみると，SOM と SP-SOM がほぼ同等で約 89%，P-SOM がやや劣り 84% となり，どの場合に関してもキー入力タイミング

表 2 各特徴量に対する認証実験の結果 (SP-SOM)

Table 2 Result of authentication experiment with each feature (SP-SOM).

user	timing		sound	
	FRR	FAR	FRR	FAR
User 1	0.507	0.0000	0.123	0.0000
User 2	0.182	0.0270	0.333	0.0282
User 3	0.189	0.0228	0.290	0.0297
User 4	0.010	0.0347	0.434	0.0353
User 5	0.067	0.0037	0.136	0.0392
User 6	0.104	0.0239	0.714	0.0104
User 7	0.121	0.0154	0.230	0.0559
User 8	0.209	0.0281	0.068	0.0179
User 9	0.226	0.0138	0.480	0.0221
User10	0.134	0.0108	0.511	0.0552
Average	0.175	0.0181	0.332	0.0294

表 3 特徴量を統合した認証実験の結果

Table 3 Result of authentication experiment with integrated features.

user	SOM		P-SOM		SP-SOM	
	FRR	FAR	FRR	FAR	FRR	FAR
User 1	0.342	0.0000	0.231	0.0000	0.182	0.0000
User 2	0.117	0.0080	0.140	0.0116	0.121	0.0128
User 3	0.087	0.0088	0.101	0.0257	0.093	0.0056
User 4	0.079	0.0239	0.096	0.0242	0.073	0.0178
User 5	0.017	0.0127	0.060	0.0177	0.033	0.0064
User 6	0.170	0.0144	0.380	0.0194	0.202	0.0189
User 7	0.103	0.0036	0.080	0.0128	0.062	0.0103
User 8	0.056	0.0213	0.023	0.0146	0.017	0.0085
User 9	0.090	0.0122	0.302	0.0089	0.169	0.0073
User10	0.115	0.0023	0.172	0.0103	0.127	0.0092
Average	0.110	0.0107	0.159	0.0145	0.108	0.0097

のみの認証よりも良い結果となった。SP-SOM は重み値の調整が不要であることを考えると、SP-SOM の有用性が確認できたと考えられる。この結果は指紋などの生体的特徴を用いた認証方式と比較すると劣るものであるが、キー入力ミスなどの行動的特徴のあいまいさ、および、FAR を低めに設定し安全性を確保するという観点からすると、妥当なものであると考えられる。また、SP-SOM を用いて、各特徴量ごとの認証結果の AND と OR を用いて認証実験を行ったところ、AND の場合は FRR=0.470, FAR=0.0003 と本人拒否率が高くなり、OR の場合は FRR=0.068, FAR=0.0257 と他人受け入れ率が高くなる。一般

的には FAR=FRR となるように生体認証におけるパラメータの調整が行われるが、本方式においては、一番 FAR=FRR に近い OR においても FAR が約 2.5% と高く、実用性を考えると SP-SOM はバランスのとれた特徴量の統合を行っていると考えられる。また、キー入力タイミングのみを用いた場合とキー入力音を統合した場合を比較すると一部のユーザではキー入力タイミングのみを用いた場合の方が良い認証精度を示しており、運用上はキー入力タイミングのみを用いて認証を行うユーザとキー入力音を統合して認証を行うユーザを分類した方が良いと考えられる。

次に、登録ユーザ以外の他人識別率について実験を行った。自己組織化マップを用いた分類は入力データに対し最も近いベクトルを求めるとのみで、登録ユーザ以外のデータに対しても学習データのいずれかのユーザと認証してしまう。そのため文献 2) においては、入力ベクトルとマップ上のベクトルの誤差の値に閾値を設けることで、登録ユーザ以外の排除を行った。SP-SOM を用いた場合、カテゴリベクトルの値がその分類の確信度を表していると考えられるため、この値を用いて排除を試みた。閾値としてパレート集合のカテゴリベクトルの値の平均が 0.5 以上と設定した。また、未学習データや未登録ユーザのデータに対してはパレート集合のサイズが大きくなると考えられるため、前述の学習データのパレート集合の平均値 6 に対して、閾値 10 を超えた場合は認証不能とした。ただし、閾値を設けることで認証精度も変化し、10 人全体に対しては平均で FRR=0.229, FAR=0.0025 となった。実験方法としては、計測データの中から SP-SOM で FRR の低い 7 人分のデータを登録し、残り 3 人分のデータを未登録ユーザのデータとして認証実験を行った。これは FRR が高いユーザの入力ほどばらつきが大きく、様々なパターンをテストするための未登録ユーザの入力のサンプルとしては適していると考えたからである。登録ユーザ 7 人に対しては平均で FRR=0.187, FAR=0.0045 となった。一見すると FRR が低いユーザ 7 人に対して FAR が悪化するのとは不自然に思えるが、FRR が低いユーザほど安定した入力を行っており、FRR が高いユーザの大きく外れた入力(どのユーザとも認証されない入力)が減ったこと、および、SOM ベースのシステムでは基本的に登録ユーザのいずれかに分類を行おうとするため、ベースとなる FRR に元々 10/7 倍の差がつくと考えられることから、FAR が悪化していると考えられる。未登録ユーザ 3 人の入力に対しては、閾値を設定した場合は平均で FAR=0.0065 となり、登録ユーザよりもはやや劣る結果となったが、閾値を設定しない場合の登録ユーザ 7 人に対する、未登録ユーザの FAR=0.0183 と比較すると、大きく改善された結果となった。

また、もう 1 つの例題として、文献 10) のキー入力タイミングとタブレットへの図形(螺

表 4 各特徴量に対する認証実験結果の平均 (キー入力+タブレット)

Table 4 Result of average of authentication experiment with each feature (key+tablet).

user	key		pen speed		pen pressure	
	FRR	FAR	FRR	FAR	FRR	FAR
Average	0.076	0.0022	0.436	0.0202	0.376	0.0173

表 5 特徴量を統合した認証実験の結果の平均 (キー入力+タブレット)

Table 5 Result of average of authentication experiment with integrated features (key+tablet).

user	SOM		P-SOM		SP-SOM	
	FRR	FAR	FRR	FAR	FRR	FAR
Average	0.045	0.0008	0.170	0.0080	0.045	0.0020

旋形)を入力した際の筆速と筆圧の3つのベクトルを用いたマルチモーダルな入力に対する認証実験の結果を示す。実験は11人の被験者に対して10回ずつキー入力タイミングとタブレットへの図形入力を測定し、6回分を学習用、4回分をテスト用に使い、すべての組合せについて認証実験を行った。各特徴量に関する認証実験の結果(平均)を表4に、特徴量を統合した認証実験の結果を表5に示す。

この場合においては、被験者が前実験と異なるため、キー入力タイミングのみでもある程度良い認証結果が得られているが、認証情報としてはより曖昧である筆速、筆圧を加えることで、SOMとSP-SOMはキー入力タイミングのみの認証実験よりも良い結果を示しており、キー入力タイミング、筆速、筆圧の3つのベクトルの統合により認証精度の向上が可能になったと考えられる。また、この実験においてはSP-SOMのFARがSOMのFARと比較すると劣っているが、キー入力タイミングのみと比較すると改善されていること、また、キー入力タイミングとキー入力音の組合せと比較するとFARが十分低いことから、この認証実験においてはSOMの適用時は2つ(筆速、筆圧)の重み値を調整する必要があることを考えると、実用上はSP-SOMの方が適用しやすいと考えられる。

5. おわりに

本論文では、教師付きパレート学習型自己組織化マップ(SP-SOM)を用いた、マルチモーダルなバイオメトリクス情報の統合方法を提案し、キーボード入力タイミングとキー入力音を用いた個人認証実験を通して、その有効性を示した。本研究の手法は、他の行動的特徴を用いたバイオメトリクス情報の統合にも有効であると考えられ、本論文においても、キー入力タイミングとタブレットへの図形描画時の筆速と筆圧を統合して個人認証を行う例

を示した。

今後の課題としては、今回の実験は10人の被験者で行ったが、もっと多くのユーザに対して有用であるか確認を行う必要があると考えられる。また、現方式は、基本的にクラス分けを行うニューラルネットを用いており、パラメータの調整できる範囲のみではFAR=FRRとなる平衡点に認証システムを調整するのは不可能であるため、認証に適したテストデータからの想起方式を考える必要があると考えられる。また、実際のシステムに適用する際は、初期の登録データのみでなく、認証時の入力を学習していくことでユーザのタイピング特性の変化にも追従できると考えられるため、追加型の学習を自己組織化マップに行う手法を取り入れる必要があると考えられる。また、本方式を応用し、ログイン時だけでなくコンピュータを使用している最中の振舞いを常時監視することで、なりすましによる不正ユーザの継続的かつリアルタイムな検出を試みるシステムについて検討したい。そのため、今後は、本方式の即応性についての評価を実施し、本手法のさらなる改善と応用について検討を重ねたい。

参考文献

- 1) Bolle, R., Connell, J., Pankanti, S., Ratha, N. and Senior, A.: *Guide to Biometrics*, Springer (2004).
- 2) ディスカバリーチャンネル, 怪しい伝説(原題 MythBusters) Crime and Myth-Demeanors 2, Episode 59, 5月16日放送(2007).
- 3) Kohonen, T.: *Self Organizing Maps*, Springer, ISBN 3-540-67921-9 (2001).
- 4) 堂園 浩, 中国真教ほか: 自己組織化マップによるPDAにおける手書き図形の筆圧解析, 情報処理学会論文誌, Vol.47, No.8, pp.2593-2601 (2006).
- 5) Dozono, H., Nakakuni, M., et al.: The Analysis of Pen Pressures of Handwritten Symbols on PDA Touch Panel using Self Organizing Maps, *Proc. International Conference on Security and Management 2005*, pp.440-445 (2005).
- 6) Dozono, H., Nakakuni, M., et al.: The Analysis of Pen Inputs of Handwritten Symbols using Self Organizing Maps and its Application to User Authentication, *Proc. 2006 International Joint Conference on Neural Networks*, pp.4884-4889 (2006).
- 7) Dozono, H., Nakakuni, M., et al.: The Analysis of Key Stroke Timings using Self Organizing Maps and its Application to Authentication, *Proc. International Conference on Security and Management 2006*, pp.100-105 (2006).
- 8) Monroe, F. and Rubin, A.D.: Keystroke Dynamics as a Biometric for Authentication, *Future Generation Computer Systems* (Mar. 2000).
- 9) Brault, J.J. and Plamondon, R.: A Complexity Measure of Handwritten Curves: Modelling of Dynamic Signature Forgery, *IEEE Trans. Systems, Man and Cyber-*

netics, Vol.23, pp.400–413 (1993).

- 10) Dokic, S., Kulesh, A., et al.: An Overview of Multi-modal Biometrics for Authentication, *Proc. 2007 International Conference on Security and Management*, pp.39–44 (2007).
- 11) Nakakuni, M., Dozono, H., et al.: Application of Self Organizing Maps for the Integrated Authentication using Keystroke Timings and Handwritten Symbols, *WSEAS TRANSACTIONS on INFORMATION SCIENCE & APPLICATIONS*, Vol.2, No.4, pp.413–420 (2006).
- 12) Dozono, H., Nakakuni, M., et al.: Application of Self Organizing Maps to User Authentication Using Combination of Key Stroke Timings and Pen Calligraphy, *Proc. 5th WSEAS Int. Conf. on COMPUTATIONAL INTELLIGENCE*, pp.105–110 (2006).
- 13) Araujo, L.C.F., Sucupira, L.H.R., et al.: User Authentication Through Typing Biometrics Features, *IEEE Trans. Signal Processing*, Vol.53, No.2, pp.851–855 (2005).
- 14) Loy, C.C., Lim, C.P. and Lai, W.K.: Pressure-Based Typing Biometrics User Authentication Using the Fuzzy ARTMAP Neural Network, *Proc. 12th International Conference on Neural Information Processing* (2005).
- 15) 納富一宏：臨床症例文書を対象とした疾患系分類と症例データベース構築に関する研究，8章バイオメトリクス認証，早稲田大学大学院理工学研究科博士論文，pp.129–143 (2002). <http://hdl.handle.net/2065/425>

(平成 19 年 11 月 29 日受付)

(平成 20 年 6 月 3 日採録)



堂園 浩 (正会員)

1961年生。1984年3月京都大学工学部数理工学科卒業。1986年3月同大学大学院工学研究科数理工学専攻修士課程修了。1989年3月同博士課程単位取得退学。1991年3月同大学工学博士。1989年4月徳島大学情報工学科助手。1991年4月熊本大学機械工学科助手。1992年7月同講師。1994年4月佐賀大学理工学部電気電子工学科助教授。1998年4月同大学大学院生体機能システム制御工学専攻助教授。現在に至る。ソフトコンピューティングのバイオインフォマティクスおよび、コンピュータセキュリティ分野への応用に関する研究に従事。計測自動制御学会，IEEE 各会員。



伊東 信介

1984年生。2007年3月佐賀大学理工学部電気電子工学科卒業。2007年4月同大学大学院工学系研究科博士前期課程生体機能システム制御工学専攻入学。個人認証に関する研究に従事。電子情報通信学会学生員。



中國 真教 (正会員)

1975年生。1998年3月佐賀大学理工学部物理学科卒業。2000年3月同大学大学院工学系研究科博士前期課程修了。2001年11月宮崎大学情報処理センター助手。2007年3月佐賀大学博士(工学)。2007年4月宮崎大学総合情報処理センター助教。2008年4月九州大学情報基盤研究開発センター特任准教授。現在に至る。認証基盤，個人認証に関する研究に従事。