

筆跡情報と筆圧情報の HMM を用いたサイン認証

小南 嘉史¹・西村 広光²・富川武彦²

- 1 大学院工学研究科電気電子工学専攻(kominami@ele.kanagawa-it.ac.jp)
 2 情報メディア学科({nisimura,tomikawa}@ic.kanagawa-it.ac.jp)

User Identification by using Signature Stroke and Signature Pressure

Yoshifumi KOMINAMI¹, Hiromitsu NISHIMURA², Takehiko TOMIKAWA²

Abstract

In the field of user detection, detection methods using biometrical features have been reported in recent years. In this paper, we constructed an online sign detection system using a Hidden Markov Model (HMM). Constructing our user detection system is based on two types of HMM. One HMM is calculated from writing stroke features, another HMM is calculated from writing pressures. In this paper, our constructed HMM user detection system is compared with the sign detection system using simple pattern matching. A new sign database was gathered for the comparative experiments. The sign database consists of 800 sign by 4 writers. In our experiment, the detection rate of our method performed 99.8%, which was about 3% better than the system using simple pattern matching. Moreover, HMM parameters for user detection were investigated from our experiment.

Key Words: User detection, User identification, On-line sign, pen pressure, pen stroke

1. はじめに

コンピュータの高性能化が進み、幅広いユーザが利用する機会が増えたが、本人を偽った詐欺や個人情報流出などのネット犯罪も増加している。現在最も広く利用されている情報セキュリティ対策は、ユーザ名をパスワード認証することである。しかし、人間が記憶できる文字列の長さには限界があり、現在のコンピュータでは短時間にパスワードを解読することも可能になってきている。そこで従来のパスワードよりも高いセキュリティを実現する、指紋や声紋などの生体情報をを利用するバイオメトリクス認証が注目され、多くの研究が進められている。本研究ではこれらのバイオメトリクス認証の中でも盗難に堅牢であり、認証用機器が安価で導入が容易であるサイン認証について検討を行い、オンラインサイン認証システムを構築し検討を進めた。

筆者認識の研究には、筆者照合と筆者識別がある¹⁾。筆者照合は、特定の筆者が筆記した文字を対象とし本当にその筆者が筆記したものかを判別するものであり、それに対して筆者識別は、複数人物の中からその筆者が誰であるかを判断するものである。

パスワードの代替として用いるサイン認証は筆者照合として利用されることが多い。しかし、双方の技術の根底は共通であり、筆者識別のほうが難易度は高いといえる。本研究では、ユーザビリティの向上を考慮し、筆者識別としての応用も考えている。

筆者認識には、信号パターンの重ね合わせ類似度による判定を用いた研究¹¹⁾やニューラルネットワーク、ファジイ理論を用いた研究などが報告されている²³⁾。サインを筆記した場合、同一人物が同一サインを筆記したとしてもその筆記速度には差が生じる。従来おなじみの信号パターンの重ね合わせ類似度による判定ではその速度差が認証率の低下の原因になることがあった。そこで本研究では時間的に変化する処理に対して有効だとされている HMM を用いた認証手法をサイン認証に採用し、その効果を検討した。

本研究で提案する個人認証システムは、タブレットから取得したデータをそのまま比較するのではなく、筆跡データと筆圧データをそれぞれ画数ごとに Code 化処理を行い、作成した Code 列をシンボル系列として HMM に入力し認証を行うこととした。HMMを利用して構築したシステムと昨年まで行われてきた信号パターンの重ね合わせ類似度による認証システムと

の比較をおこない、サイン認証における HMM の有効性を確認した。加えて認証性能向上のため HMM のパラメータに関しての実験・検討した。

2. サイン認証システムの概要

本章では提案するサイン認証システムの各処理を解説する。提案システムでは初めにタブレットによるサインの採取を行い、そのサインを HMM への入力シンボル系列とするための Code 化処理をおこなった後に認証を行う。図 1 はサイン認証システムの Code 化部分の流れを示したものである。図 1 に示すように、本研究では、筆跡情報と筆圧情報をそれぞれ独立に取り扱う認証システムを構築することとした。認証に用いる HMM については、3 章で詳説する。

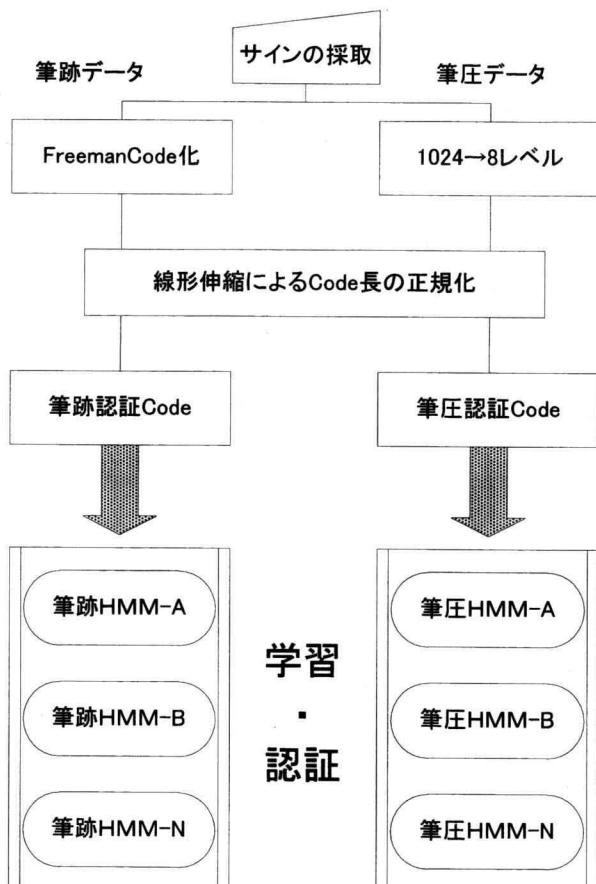


図 1 サイン認証システムの流れ

2. 1 サインデータの採取

本研究では筆圧検出タブレットを利用して文字情報を取得し、認証を行うこととした。本研究では筆圧を検出できるタブレットならどれでも対応できるような仕様としたが、筆記者の作業負担の少ない WACOM 社製 Cintiq を利用してデータ入力をを行う。Cintiq は図 2 の写真で分かるように図 3 に示すような一般的なタブレットとは違い、ディスプレイと一緒にになっている。筆記者は専用ペンを使い、ディスプレイに直接書き込むことができるので、タブレットに不慣れな人でも負担をあまり感じることなくサインを書くことができると考えられる。

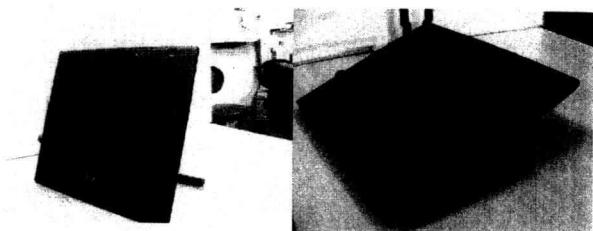


図 2 Cintiq



図 3 その他のタブレット

サイン採取の際にはタブレットによって採取できる筆圧レベルが異なる。そこでサイン採取時に筆圧の調整ができる Wintab[®]を利用する。Wintab とは、米国 LCS/Telegraphics 社が開発したタブレットの標準インターフェースで、ペンの出力する座標を遅滞無くコンピュータに入力し、筆圧やペンの傾きなどもこれによって取り入れることが可能である。Wintab は筆圧を取り込む際、タブレットの筆圧レベルがいくつであっても 1024 レベルに調整する。これによって筆圧レベルの異なるタブレットでも同様に使用することができる。今回利用した Cintiq では 512 レベルで筆圧を検知する能力があるが、この Wintab を利用することで値が 2 倍にされ、1024 レベルで筆圧情報を取得した。

サイン採取プログラムは、及川幸一氏の“オンライン文字データ採取システムの作成と筆圧情報を用いたオンライン文字認識”⁶ のなかで作成した文字採取プログラムを改良して利用した。このプログラムは、Wintab を利用して、Microsoft Visual C++によって作成したものである。サインを採取するにあたって、サイン取得画面のサイン描画範囲を 768×256 pixel とし、さらにサイン筆記時の補助線を設けた。被験者がサインを補助線の外に書いた場合や、サインの途中で補助線の枠をはみ出しまった場合には、警告メッセージが現れ、もう一度最初からサインを書き直してもらうようなシステムとなっている。

サインデータを取得するプログラムを実行したときに表示されるダイアログは図 4 のようなものである。枠内にサインを書いてもらい、途中で間違えた場合は左側に表示されてある CLEAR ボタンを押すことで何度も書き直すことができる。きちんと書けた場合は右側に表示されてある NEXT/END ボタンを押すとサインの取得は完了となる。

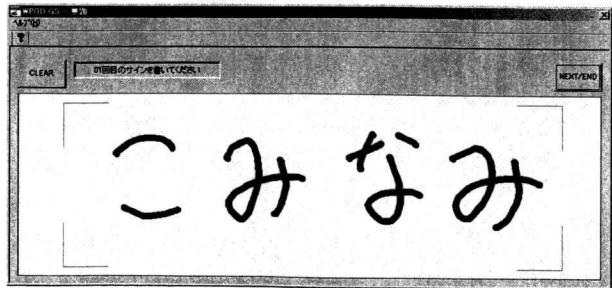


図 4 サイン採取プログラムのダイアログ

サインデータの採取の際、環境を同一とするために以下の注意を提示し、サインを筆記させた。

- (1) タブレットの液晶面をねかせた状態で筆記する。
- (2) 椅子に座って筆記する。
- (3) 丁寧な字ではなく普段のサインを筆記する。
- (4) 複数回筆記する場合すべて同じ書き方をする。
- (5) 間違えた場合、CLEARボタンを押し、書き直す。

このプログラムはタブレットから、ストローク、筆圧、横方向(x)座標、縦方向(y)座標を1パケットとして一定時間ごとにサンプリングしコンピュータに取り入れる。採取したサインデータの範囲は表1に示す。

表1 サインデータの範囲

筆圧	0~1023
描画領域	横 768、縦 256pixel

2.2 筆記情報のCode化

同一人物であっても同じ場所にサインを書くことは非常に困難である。さらにサインを比較する際、何処に書いたということよりもどのような軌跡を書いたかが重要であると考えられる。そこで、採取した座標情報を座標の位置情報から相対的な動きの情報を変換し、Code化する。このとき、単純に方向ベクトルを利用してCode化したのでは、筆記速度の情報を利用することができない。そこで、単位長さの方向ベクトルを利用して、同一方向のベクトルコードが繰り返されるようにした。

具体的なCode化は、Freeman - Code⁶を拡張した変換手法を考案し利用した。Freeman - Codeとは、サインを書いたときに移動するペンの座標データの変化を8方向の単位方向ベクトル系列に変換するためのCode化手法である。移動する座標との対応は図5のようになっており、移動方向に対して1から8までの数字を割り当てて表す。このとき、一定時間間隔でのサンプリング点に対して単位方向ベクトル系列化を行うことで、コード長により筆記速度情報を表現することができる。Freeman - Codeのみではストロークの開始終了情報やペンの停止状況を表現できないため、座標の移動が無い状態を0、ストロークの終端情報を9として定義し、Freeman - Codeを拡張した。具体的には、図6のような筆跡情報をFreeman - Code化すると図7のようになる。

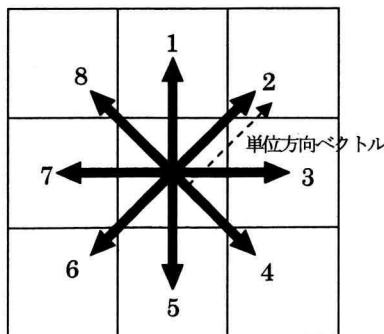


図5 Freeman - Code

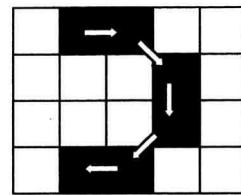


図6 Code化例(Code化前)



図7 Code化例(Code化後)

次に筆圧情報のCode化を行う。0~1023の値でサンプリングされた筆圧情報は8レベルに変換する処理を行い、これらの処理から得られたデータを1つのCode列として扱う。人間は完全に同じ筆圧でサインを筆記することはできないため、サインを書いた人の筆圧変化の傾向を数値化するようにCode化することとした。ここでは、筆記情報のコード分解能とあわせるため、筆圧のコード化も、分解能を8に統一した。筆圧を8レベルに変換したことにより筆圧情報の特徴が損なわれないことは先行行った実験⁶により確認している。

2.3 Code列の正規化

前節の手法によりCode化を行った場合サイン形状等によりCode長に差が生じる。HMMに入力するシンボル系列は同じ長さである必要があるため線形伸縮を用いてCode長の正規化を行うこととした。具体的には、コード長を筆跡では500Code、筆圧では50Codeとした。これは、生成された筆跡及び筆圧のCode列からサンプルをとり、伸縮率が0.5倍から1.5倍程度の範囲に収まるように値を設定したことによる。

3 HMM (Hidden Markov Model)

本章では認証に用いるHMMの原理、モデル学習法、学習モデルを利用した認証法について解説する。

3.1 HMMの原理

HMMはいくつかの状態と入力シンボルに対する状態間の遷移確率、ある状態のときに出力されるシンボルの確率によって表される。あるシンボル系列 $O = O_1 O_2 \dots O_T$ が観測されたとき HMM λ が与えられれば、HMM λ からそのシンボル系列 O が出力される確率 $P(O | \lambda)$ を計算することができる。本研究では図8に示すようなLeft to Rightモデルを利用しHMMを構築する。

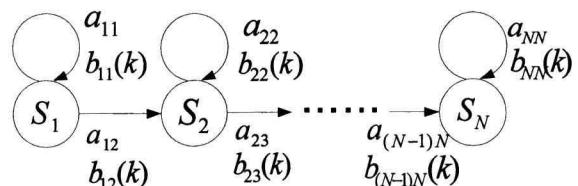


図8 HMM (Left to Right モデル)

このとき HMM λ は

$$A = \{a_{ij}\} \text{ を状態 } S_i \text{ から } S_j \text{ に遷移する確率の集合、}$$

$B = \{b_{ij}(k)\}$ を状態 S_i から S_j に遷移するときにシンボル k を出力する確率の集合、

$$\pi = \{\pi_i\} : \text{初期状態確率の集合としたとき、}$$

$$\lambda = (A, B, \pi) \text{ で表される。}$$

この HMM に対して、1 つのクラスに属する信号系列に対して出力確率が大きくなるようにパラメータ調整を行うことによりモデル学習を行う。学習したモデルに対して未知の信号系列を入力することで、未知の信号系列が学習した信号系列とどれだけ類似しているかという度合いを出力確率として得ることができる。

3.2 学習

HMM における学習の目的はモデルパラメータである遷移確率 A と B とを学習データの集合から推定することである。この学習には Baum-Welch アルゴリズムを用いる。

例として、HMM: $\lambda = (A, B, \pi)$ が与えられたとき、シンボル系列 $O = O_1 O_2 \cdots O_T$ に対して O を出力する確率が

$$P(O | \bar{\lambda}) \geq P(O | \lambda)$$

となるようなパラメータ $\bar{\lambda} = (\bar{A}, \bar{B}, \bar{\pi})$ を有する HMM を推定することができる。

さらに複数のシンボル系列の集合

$$\mathbf{O} = \{O^{(1)}, O^{(2)}, \dots, O^{(K)}\} \text{ に対して}$$

$$P(\mathbf{O} | \lambda) = \prod_{k=1}^K P(O^{(k)} | \lambda)$$

が最大になるように (A, B, π) パラメータを推定することができる。

この学習法にもとづき、登録者ごとに筆跡用 HMM と筆圧用 HMM の2つを構築する。すなわち、図 9 のように N人の登録者に対して、学習して構築する HMM の数は $2N$ 個となる。それぞれの HMM には提案 Code 化手法により Code 化された Code 列を入力シンボル系列として利用する。

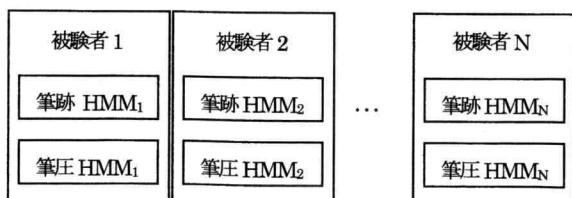


図 9 学習による HMM の構築

3.3 認証

前節の学習により構築された HMM を用いて認証をおこなう。認証対象サインから得られたシンボル系列を学習によって構築された HMM に入力する。構築された HMM が入力シンボル系列を出力する確率が Viterbi アルゴリズムを利用して計算され、出力値となる。構築された筆跡 HMM と筆圧 HMM の出力値の積をとり、最も高い確率を出力した HMM の登録者を認証結果として判断する。図 10 はサイン認証システムの HMM による認証部分の流れを示したものである。

本研究では出力値に対して特に閾値を設定していない。一般に認証システムにおいては、閾値判定を行い、正解判定とした

もののなかでも閾値以下の判定の場合は、その認証を拒否 (Reject)するような処理を導入する。しかし、この閾値の決定には非常に膨大なサンプルを利用して決定しなければ、データ依存が大きいことが知られている。そこで今回の実験の範囲では、少ない情報から偏った閾値を決めて結果を出すことはしなかった。そのため、今回の実験においては、単純に一番出力値の高いものを認証結果としたが、今後サンプル数を増やして検討を行った上で閾値設定を行えば、更なる認証性能向上が期待できる。

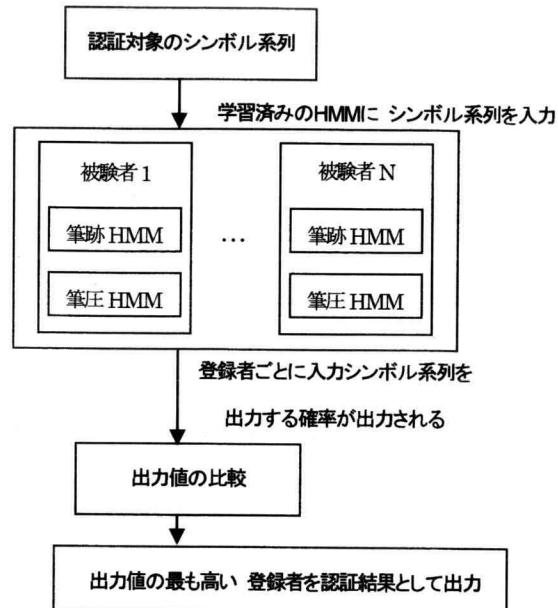


図 10 HMM による認証

4. 学習効果検討実験

初めに提案した Code 化手法によるシンボル系列の作成において学習が適切に収束しているのかを確認する学習効果検討実験を行った。

HMM は Baum-Welch アルゴリズムを用いパラメータの準最適解を学習により推定するものであるが最適解を得ることはできない。また、入力シンボル系列として用いる特徴量のとりかたや状態数などの HMM のパラメータにより結果が大きく変化することがある。このことから今後の認証性能の向上を考慮して今回採用したサインの Code 列で HMM のモデル学習が適切に収束しているかどうかを、認証実験を通して行い、検討することとした。

4 人分、各 200 個のサインデータを採取し、学習サンプル、認証テストサンプル共に同じ 200 個のサインデータを用いることとした。実験に用いた HMM のパラメータは表 2 に示す。HMM の状態数に関しては、1 文字の認識において状態数 5 を用いている¹⁰ことから複数文字を使うサインということを考え状態数を 7 から、処理速度が指標的に増加することを考慮し 12 の間で変化させ実験を行った。さらに、HMM は学習の際の初期乱数の設定によって出力結果が変動があるので 3 回試行の平均値を認証結果とした。

表 2 HMM のパラメータ

	筆跡 HMM	筆圧 HMM
シンボル種類数	10	10
シンボル系列長	500	50
状態数	7 から 12	7 から 12

実験の結果を図11、図12に示す。図11、図12における凡例1から4は被験者ごとの認証率の推移を示していく、全体は4人の認証率の平均をとったものである。

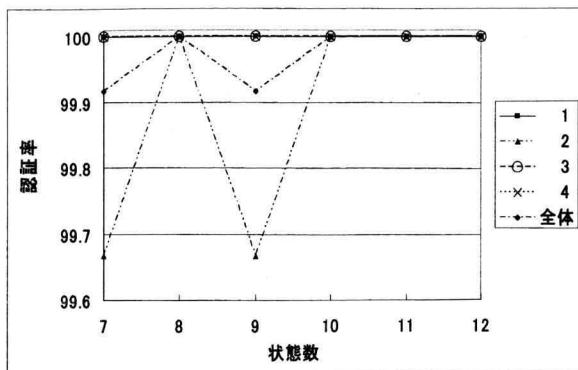


図11 筆跡HMMにおける学習効果検討実験の結果

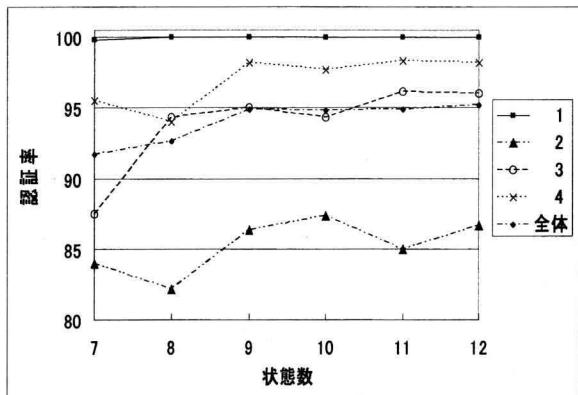


図12 筆圧HMMにおける学習効果検討実験の結果

筆跡HMMにおいて図11の1、3、4の被験者は全ての状態数で認証率は100%となっている。被験者2は状態数7と9の場合に認証率が約99.6%となっているがそれ以外の状態数では100%である。被験者2の状態数7と9の場合において100%ではない原因として、HMMの学習の際に設定する初期乱数によるものと考えられる。これらのことから筆跡HMMにおいては学習が良好に終了していることが確認できる。

筆圧HMMに関しては被験者によって学習効果にばらつきがあるといえる。被験者1はほとんどの場合で認証率は100%であり良好な学習ができているといえるが、被験者2は全ての状態数において認証率は85%前後であり学習が良好に終了していないことがわかる。筆圧HMM全体としては状態数8から12において認証率は90%以上を推移していることからHMMのモデル学習が収束に至っていることがわかる。

5. HMMパラメータの決定実験

次にHMMの状態数を変化させて認証性能を比較する実験を行った。HMMでは、状態数が増えることは本来モデル学習に必要なデータ数が指数関数的に増加することになる。そのため、可能な限り状態数を少なくし、膨大な学習用サンプル収集が困難なサイン認証において有効なHMM利用法について検討することとした。

また、HMMやNNを利用した認識系において、モデルパラメータを過度に多くすることは、未知データに対するモデルの汎化能力低減につながることがしられている⁹⁾。そのためにも、少ないパラメータで学習を行い、未知パターンに対する汎化能力を持たせるという効果も検討した。

この実験では4人各100個のサインデータを学習データとし、学習データと異なる100個のサインを認証データとして用いた。実験に用いたHMMのパラメータは4章の実験と同じく、表2の通りであり、状態数を7から12の間で変化させ最適な状態数を決定する。また、4章と同じく3回試行の平均値を認証結果とした。

実験の結果を図13、図14に示す。図13、図14における凡例1から4は被験者ごとの認証率の推移を示していく、全体は4人の認証率の平均をとったものである。

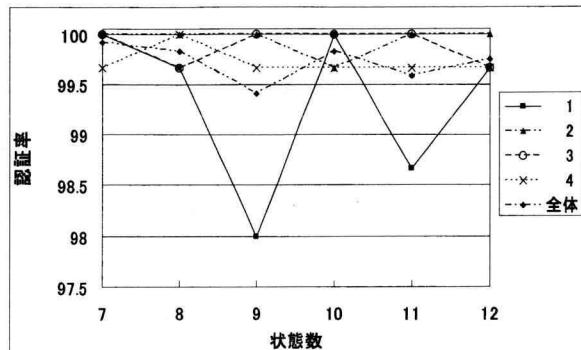


図13 筆跡HMMにおける認証性能比較実験の結果

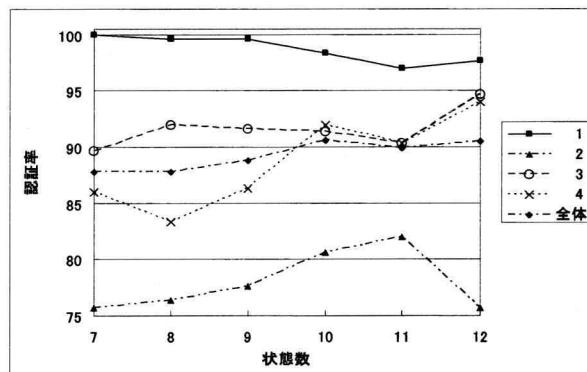


図14 筆圧HMMにおける認証性能比較実験の結果

筆跡HMMにおいては、被験者毎の変動があるものの、全体の認証率は99.4%から99.9%と非常に高い認証精度が得られた。また、状態数を変化させたことにより認証率の変動が起こっているがその変化はHMMの初期乱数による変動によるものが大きいと考えられる。そのため、筆跡HMMについては状態数7で十分な精度が得られることがわかった。

筆圧HMMにおいては、被験者1の状態数7の場合の認証率100%、被験者2の状態数7場合の認証率75%と被験者によるばらつきが大きい。これは4章の実験結果でも述べているように被験者2に関しては学習が良好に終了していない等、被験者によって学習効果に差があるためだと考えられる。状態数の変化における認証率の変動に関しては被験者2及び4の結果をみると状態数が増えるにしたがって認証率も向上していると考えられる。しかし被験者3は状態数が変化しても認証率にほとんど変化はなく被験者1においては低下している。

以上のことから今回の実験においては最適な筆圧HMMの状態数を決定するには至らなかった。筆圧HMMについては状態数によって認証率が変化することは考えられるがサンプル数が少ないのでその傾向を読み取ることが難しいといえる。しかし、図13、図14より状態数10が高い認証率となっていることから状態数10前後に最適値があるのではないかとも考えられる。よって、状態数10を用いて次の認証性能比較実験を行う。

6. 認証性能比較実験

提案システムの評価実験として、先に報告した研究¹¹⁾の認証システムとの認証性能比較実験を行い、HMM を用いた認証システムの有効性を検証した。実験には 4 人分各 100 個のサインを用いた。図 15 に採取した 4 人分のサインの例を示す。

採取したサインは、図 15 のように漢字やひらがなを特定せず用意し、同一被験者においても左右の図からわかるように文字の大きさや書き位置、細部の形状の違いがある。

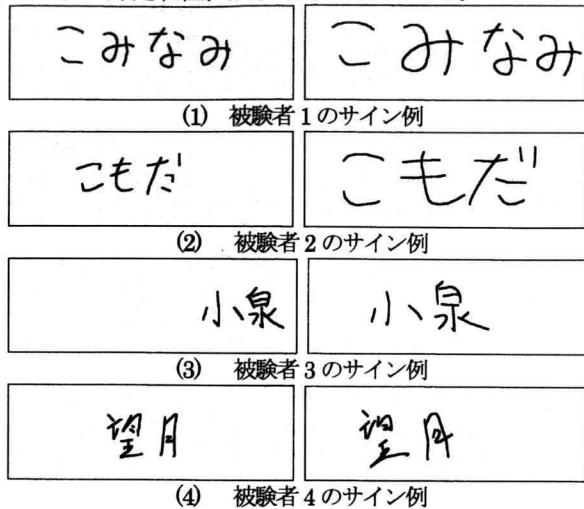


図 15 実験に使用したサインの例

実験に用いる HMM の実験に用いた HMM のパラメータは表 3 に示す。実験の結果を表 4 に示す。

表 3 HMM のパラメータ

	筆跡 HMM	筆圧 HMM
シンボル種類数	10	10
シンボル系列長	500	50
状態数	10	10

表 4 認証性能比較実験の結果

	類似度を用いた 認証システム	提案システム
認証率	96.7%	99.8%

表 4 の結果から今回の実験の範囲では、信号パターンの重ね合わせ類似度を用いた認証よりも HMM を用いた認証の方が約 3% 程度認証率の高いことから HMM を用いた認証の方が有効であることがわかる。

しかし、本実験では被験者数が 4 人と大変少ないため、被験者による偏りが無いとは断定できないため、今後サンプル数を増やし追試する必要がある。

どのようなサインパターンの場合に誤認証が発生するかを調べるために追試として HMM による認証を 5 回行った。このときの認証率を表 5 に示す。

表 5 複数回実行における認証率

回数	1 回目	2 回目	3 回目	4 回目	5 回目
認証率	99.8%	99.5%	99.8%	99.8%	100%

誤認証が発生するサインパターンとしては、特定のサインではなく実行回毎に異なるサインが誤認証となっている。これは学習データが少ないと学習結果に差異が生じるためだと考えられる。

7. まとめ

本研究では HMM を用いた認証システムを提案し、その認証性能の検証を行った。

HMM に用いるための筆記情報の Code 化手法では学習サンプルの認証実験で安定した認証性能が確認でき、未知学習サンプルの認証実験でも高い認証性能が確認できた。このことから、提案 Code 化手法によって生成されたシンボル系列を利用して、HMM のパラメータの膨大化させること無く、認証システムに利用できることを確認した。

被験者 4 人のサインを用いた、信号パターンの重ね合わせ類似度による認証システムの比較実験においては閾値の設定や誤認証率を考慮していない場合において信号パターンの重ね合わせ類似度を用いた認証システムでの認証率が 96.7%、提案システムによる認証率が 99.8%となり、本提案システムが有効であることを確認した。

以上のことより信号パターンの重ね合わせ類似度による認証システムよりも高精度のサイン認証システムを HMM を利用して構築することができたといえる。

しかし、HMM を用いた認証システムでは、HMM の学習に多くのサインサンプルを用意する必要がある。このため、多数の事前サインサンプルが採取できる状況に利用用途が限定されている。今後の課題として、より一般的な場面での活用を考え、少数サインサンプルによる認証モデル構築法の検討がある。

参考文献

- 1) 吉村ミツ 吉村功, “筆者認識研究の現段階と今後の動向”, 電子通信学会技術研究報告 PRMU96-06 pp61-80,(1996)
- 2) 梅田三千雄 三好健生 三崎揮市, “自己想起型ニューラルネットワークによる筆者識別と照合”, 電気学会論文誌 Vol.122-C No.11 pp1869-1875,(2002)
- 3) 尾崎正弘 足達義則 石井直宏, “ファジィ理論を用いた筆者識別”, 電気学会論文誌 Vol.120-C No.12 pp1933-1939(2000)
- 4) R.Poyner, “Wintab Interface specification 1.1”, LCS/Telegraphics, (1996)
- 5) 安居院猛 中嶋正之, “画像工学の基礎”, 昭晃堂,(1986)
- 6) Richard O.Duda Peter E.Hart David G.Stork 尾上守夫, “パターン識別”, 新技術コミュニケーションズ,(2001)
- 7) 及川幸一, “オンライン文字データ採取システムの作成と筆圧情報を用いたオンライン文字認識”, 神奈川工科大学工学部情報工学科 卒業論文,(2001)
- 8) 中島洋行, “筆圧検出タブレットを利用したオンライン個人認証システムの試作”, 神奈川工科大学工学部電気電子工学科 卒業論文(2002)
- 9) 西村広光, “統合的手法を用いた手書き文字切り出しと認識の研究” 信州大学 博士(工学)学位論文,(2000)
- 10) 西村広光, 堤正義 “複合 1 次元 HMM を利用した手書き文字認識の研究”, 神奈川工科大学研究報告 B No.25Page63-68,(2001)
- 11) 小南嘉史 西村広光 富川武彦, “筆圧タブレットによるオンラインサイン認証の改良” 神奈川工科大学研究報告 B No.29 Page47-54, (2005)