

順列インデックスを用いた1対多掌紋認証のN位認証率向上に関する検討

メタデータ	言語: ja 出版者: 情報処理学会 公開日: 2022-12-20 キーワード (Ja): キーワード (En): 作成者: 吉平, 瑞穂, 野崎, 真之介, 芹澤, 歩弥, 中原, 正隆, 馬場, 昭, 窪田, 歩, 大木, 哲史, 西垣, 正勝 メールアドレス: 所属:
URL	http://hdl.handle.net/10297/00029237

順列インデックスを用いた1対多掌紋認証の N位認証率向上に関する検討

吉平 瑞穂¹ 野崎 真之介¹ 芹澤 歩弥¹ 中原 正隆² 馬場 昭² 窪田 歩² 大木 哲史¹
西垣 正勝^{1,a)}

受付日 2022年3月9日, 採録日 2022年9月2日

概要: 生体情報は本人と他人を有意に識別しうるものの, 本人内での変動が大きく, 他人間での類似性が高いという性質を有しており, この点が本人認証を難しくしている. この問題の解決策として, 一部の生体情報を基準データ (pivot) として用いて生体情報の特徴空間を定義する手法が提案されている. また, 1対多生体認証では, ユーザ数が増えるほど本人識別のために要する1対1照合の回数が増加し, 生体認証の応答時間が長くなるという点も問題となる. これに対し, 生体情報と pivot との距離 (pivot 集合を生体情報の距離順に並べた順列) を索引情報として, 被認証者に類似した登録生体情報 (テンプレート) を高速に発見する順列インデックス法が提案されている. しかし, 先行研究では, 本人内変動に頑強な特徴量 (インデックス) や, 他人間を効率的に識別するための pivot をどのように選択もしくは生成するのかについて, 十分な検討が行われていない. そこで本研究では, 順列インデックスを用いた1対多掌紋認証に焦点を当て, N位認証率を向上させるための順列インデックスに関する改善策の提案を行う.

キーワード: 1対多生体認証, 掌紋認証, 順列インデックス

Improving Rank-N Identification Rate of Palmprint Identification Using Permutation-based Indexing

MIZUHO YOSHIHIRA¹ SHINNOSUKE NOZAKI¹ AYUMI SERIZAWA¹ MASATAKA NAKAHARA²
AKIRA BABA² AYUMU KUBOTA² TETSUSHI OHKI¹ MASAKATSU NISHIGAKI^{1,a)}

Received: March 9, 2022, Accepted: September 2, 2022

Abstract: Biometric information has variability within the same person but similarity among different people. Therefore, it is difficult to identify a person or distinguish between two people based on biometric information. One way to address these issues is to use some biometric information itself as pivots to define the feature space of biometric information. Furthermore, there is a general problem in that the time required for biometric identification increases as the number of enrollees increases. To resolve the problem, the pivot-based indexing method has been proposed that gives an index to each template to quickly sort in order of similarity. However, previous research has not sufficiently examined methods for improving the robustness of index and selecting or generating the pivots. In this study, we propose schemes for pivot selection and robust index generation that improve the rank-N identification rate.

Keywords: biometric identification, palmprint recognition, permutation-based indexing

1. はじめに

生体情報は, 記憶情報と比較して紛失や忘却という可能性がないため, それらを用いた生体認証はパスワード認証に対して利便性が高い. そのため, 近年では指紋や顔, 虹

¹ 静岡大学
Shizuoka University, Hamamatsu, Shizuoka 432-8011, Japan

² KDDI 総合研究所
KDDI Research, Inc., Fujimino, Saitama 356-8502, Japan

^{a)} nisigaki@inf.shizuoka.ac.jp




図 1 1 対多掌紋認証システムの基本方式

Fig. 1 A naive scheme of palmprint identification system.

彩などのモダリティを用いた生体認証が、スマートフォンや入退室管理、決済システムなどで利用されている。様々なモダリティの中でも、手のひらの隆線やしわの模様を用いた掌紋認証は、一般的なスマートフォンのカメラを用いることによって非接触で生体情報を取得可能であるために可用性が高く、顔認証などと比較して生体情報の取得に対するユーザの心理的負荷が小さいため、受容性にも優れている。さらに、掌紋の提示のみで当該ユーザを識別する 1 対多生体認証 (Identification) を構成することにより、ID の提示を必要としない、利便性の高い認証が実現可能である。そこで本論文では、可用性、受容性、利便性を兼ね備える 1 対多掌紋認証に着目する。

図 1 に 1 対多掌紋認証の基本方式を示す。登録時に、ユーザは生体情報 (掌紋画像) を提示し、テンプレートとしてデータベースへ登録する (以降、この画像をテンプレート画像と呼ぶ)。認証時には、ユーザは生体情報 (掌紋画像) をクエリとして提示する (以降、この画像をクエリ画像と呼ぶ)。そして、クエリ画像を受け取った掌紋認証システムは、クエリ画像とデータベースに登録されている各テンプレート画像との 1 対 1 照合を順次行い、類似度を算出する。そして、類似度が閾値を上回った場合に当該ユーザとして認証を完了とする。

生体情報は本人と他人を有意に識別しうるものの、本人内での変動が大きく、他人間での類似性が高いという性質を有しており、この点が本人認証を難しくしている。また、1 対多生体認証では、データベースに登録されたテンプレートの数が増えるほど、テンプレートとクエリの照合回数が増加し、生体認証の応答時間が長くなるという点も問題となる。

これらの問題を改善するため、いくつかのテンプレートを基準データ (以降、pivot と呼ぶ) として利用し、それをもとに生体情報の特徴空間を定義する手法が提案されている (以降、この特徴量を pivot 型特徴量と呼ぶ)。松下らは、ランダムに選択された m 個のテンプレートを pivot と

して用い、各 pivot と生体情報との類似度によって構成される m 次元ベクトル (以降、このベクトルを類似度ベクトルと呼ぶ) をもとに生体情報の特徴空間を定義する手法を提案した [1]。

また、Maeda らは、pivot と生体情報の類似度ベクトルをインデックスとして用いることで、クエリに対して類似したテンプレートを高速に見つける手法を提案した [2]。これにより、図 1 に示したような愚直な 1 対多生体認証方式と比較して 1 対 1 照合回数を削減でき、より短時間で当該ユーザを識別可能となる。村上らは、pivot との類似度の (値そのものではなく) 順位をインデックス (順列インデックス) として用い、1 対 1 照合を行う前にあらかじめ距離順にテンプレートをソートすることで 1 対多生体認証に要する処理時間をさらに削減する手法を提案した [3]。このように、索引情報 (インデックス) を用意することで、クエリとの類似度順にテンプレートを粗く高速にソートし、上位のテンプレートから 1 対 1 照合を優先して行うことで、1 対多生体認証の速度が向上する。

Maeda らのインデックス法、村上らの順列インデックス法では、生体情報の特徴空間を定義するための基底として、pivot 型特徴量を用いる (以降、両者を pivot 型インデックス法と呼ぶ)。そのため、pivot 型インデックス法を用いた生体認証の性能を向上させるためには、どのように pivot を選択あるいは生成するかが重要であるといえる。すでに述べたとおり、生体情報は本人と他人を有意に識別しうるものの、他人間での類似性が高いため、より優れた 1 対多認証の実現のためには他人間の生体情報の識別性を向上させる必要がある (以降、この識別性を空間分離性と呼ぶ)。しかし、先行研究において、pivot はテンプレートからランダムに選択 [1], [2], [3] もしくは生成 [4] されており、著者らが調べた限り、生体情報の空間分離性を考慮した pivot 選択/生成に関して十分に検討した先行研究は存在しない。一般画像検索の分野では、空間分離性を考慮した pivot 選択の有効性が確かめられている [5] ため、生体認証においてもその効果が期待できるのではないかと考えられる。

また、生体情報の本人内変動に対しても検討が必要である。生体情報の取得ごとに生じる本人内の生体情報の変動は、生体情報から生成される pivot 型インデックスに対しても影響を与える。そのため、pivot 型インデックス法による 1 対多生体認証の精度を向上させるためには、本人内の pivot 型インデックスの変動に対して頑強にする必要がある。

そこで本論文では、村上らの順列インデックス法をベースに、それを用いた 1 対多掌紋認証の精度を向上させるための手法の提案を行う。「クエリに対し、順列インデックスを用いて距離順にテンプレートのソートを行った結果、上位 N 件に該当ユーザのテンプレートが含まれる割合」を示す N 位認証率を評価指標として用い、提案手法の性能評

価を行う。さらに、提案手法を用いた際の1対多掌紋認証システムの認証精度（1位認証率，本人拒否率，他人受入率）も確認する。

本論文の構成は次のとおりである。2章では pivot 型インデックス法に関する先行研究を示す。3章では、生体情報の空間分離性と本人内変動の観点から、順列インデックス法の性能の改善手法の提案を行う。4章では検証実験に関する説明を行い、5章で実験結果を示す。最後に、6章で本論文の結論をまとめる。

2. 関連研究

1対多生体認証の高速化の観点からの先行研究を2.1～2.3節で紹介する。順列インデックス法における空間分離性の観点からの先行研究を2.4節で紹介する。

2.1 1対多生体認証の高速化

愚直な1対多生体認証手法として、データベースの先頭から順にクエリとテンプレートとの1対1照合を行う線形探索手法があげられる。しかし、この手法では登録ユーザ数（テンプレート数）の増加にともなって1対1照合回数が線形に増加し、識別に要する時間もそれに比例して増加してしまうという問題がある。この問題の解決手法として、テンプレートをいくつかのクラスタに分割する手法 [6], [7] や、テンプレートを類似度の高い順に並べることで1対1照合回数を削減する手法 [2], [3] などが提案されている。前者の手法では、登録ユーザ数が増加すると、各クラスタ内のテンプレート数が増加するため、スケーラビリティに限界がある。一方、後者の手法では、生体情報の特徴空間をどのように定義するかが識別精度に影響する。

演繹的に特徴空間を決定する一般的な方法は知られていないが、いくつかの生体情報を基準データとして用い、それらとの類似度に基づいて生体情報の特徴空間を定義する手法が有効であることが示されている [1], [2], [3]。

2.2 類似度ベクトルによる生体認証

他人間の生体情報であっても、生体情報どうしの類似性が高い場合には（閾値以下の範囲で）高い類似度が算出され、類似性が低い場合には（閾値以下の範囲で）低い類似度が算出される。松下らは、この性質を利用し、文献 [1] において、ランダムに選択した m 人の登録ユーザのテンプレートを基準データ（pivot）として用いることで、生体情報の特徴空間を定義する手法（pivot 型特徴量）を提案した。任意の生体情報と各 pivot との類似度によって構成される m 次元の類似度ベクトルを当該生体情報の特徴量として利用し、その特徴量どうしの類似度が閾値を超えるか否かによって1対1照合を行う。また、Maeda らは、類似度ベクトルを索引情報（インデックス）として用いて、より類似度の高いテンプレートを次の1対1照合対象とし




図 2 順列インデックス

Fig. 2 Permutation-based indexing.

て選択することで、線形探索よりも照合回数と応答時間を大幅に削減することを提案している [2]。著者らが調べた限り、文献 [2] が pivot 型インデックス法による生体認証を実現した初めての試みである。

2.3 順列インデックス

村上らは m 人の登録ユーザのテンプレートを pivot として用い、任意の生体情報と各 pivot との類似度ベクトルの m 個の要素の順位によってインデックス（順列インデックス）を生成する手法を提案した [3]。順列インデックスの概要図を図 2 に示す。順列インデックスは、画像や文書などを対象とした効率的な類似検索手法として提案されており [8], [9], 村上らはこれを1対多生体認証に应用することによって、その高速化を達成した。

順列インデックス法の認証の流れを示す。事前に pivot を用意し、登録時には、pivot を用いてテンプレートから順列インデックスを生成し、テンプレートと順列インデックスをデータベースに登録する。認証時には、pivot を用いてクエリから順列インデックスを生成し、クエリの順列インデックスとの距離が近い順にデータベース内のテンプレートをソートした後に、上位のテンプレートからクエリとの1対1照合を行う。ここで、2つの順列インデックス π_a と π_b の距離は、式 (1) に示す Spearman Rho（順列インデックス間の L2 距離の 2 乗）を用いて計算する。 m は pivot の数（＝順列インデックスの次元数）、 $\pi(i)$ は順列インデックスの i 番目の要素を表す。

$$S(\pi_a, \pi_b) = \sum_{i=1}^m (\pi_a(i) - \pi_b(i))^2 \quad (1)$$

文献 [3] では、順列インデックスに逐次融合判定法 [10], [11], [12] を組み合わせることにより、認証アルゴリズムを多重化し、効率的なマルチモーダル1対多生体認証を実現している。また、文献 [4] では、pivot として用いるテンプレートからのプライバシー漏洩を防ぐことを目的とし、pivot を（登録ユーザの実際のテンプレートからランダムに選択するのではなく）Generative Adversarial Networks を用いて擬似的に生成する手法を提案している。

2.4 pivot の選択アルゴリズム

Amato らは、順列インデックス法における pivot 選択手法の比較を行った [5]。順列インデックス法を用いた 1 億 600 万枚の一般画像の画像検索において、インデックス間の距離算出に Spearman Rho を用いた場合、Farthest-first Traversal (FFT) [14] に基づく pivot の選択手法が最も優れていることが実験的に示された。ここで、FFT 法による m 個の pivot の選択アルゴリズムは次のとおりである。手順 3 の処理により、高い空間分離性を有する特徴空間を形成する pivot が生成される。

1. pivot の候補となるデータの集合 (pivot 候補集合) を用意する。
2. pivot 候補集合の中からランダムにデータを 1 つ選択し、それを pivot p_1 として、pivot 候補集合から p_1 を取り除く。
3. pivot 候補集合と pivot との類似度を算出し、いずれかの pivot との類似度の最大値が最小となるデータを pivot p_k とし、pivot 候補集合から p_k を取り除く。ここで、 k は現在算出した pivot 数とする。
4. pivot 数 k が m に達するまで 3 の操作を繰り返し、最終的に m 個のデータを pivot として選択する。

3. 提案

3.1 先行研究の問題点

Pivot 型インデックス法においては、生体情報の特徴空間を決定する基底となる pivot がテンプレートのソートの精度や 1 対多生体認証に要する処理時間に大きな影響を与える。しかし、2.2 節ならびに 2.3 節の先行研究では、pivot はテンプレートからランダムに選択、もしくは生成されており、高い空間分離性を有する特徴空間を形成する pivot をどのように決定するかについては未検討である。2.4 節で述べたように、一般画像検索においては、FFT 法を用いて空間分離性を考慮した pivot 選択を行うことに対する有効性が示されている [5] ため、その生体認証に対する効果を確かめる意義は大きい。特に、「テンプレートの中から pivot を選択する」という制約を外し、高い空間分離性を有する特徴空間を形成する pivot を生成する手法について検討を行う価値は高いと考える。

また、生体情報の取得ごとに生じる本人内の生体情報の変動は、その生体情報から生成される pivot 型インデックスに対しても影響を与え、その結果、認証精度を劣化させる。しかし、2.2、2.3 節の先行研究においては、同一人物の生体情報の変動に対する頑強性については検討が行われていない。

そこで、本論文では、pivot の空間分離性とインデックスの頑強性の観点から、有用な性質を持つ pivot 型インデックスの実現に関する検討を行う。生体情報は本人と他人を有意に識別しうるものの、(a) 本人内の変動が大きく、




図 3 インデックス尺度型テンプレート選択

Fig. 3 Index-based template selection.

(b) 他人間の類似性が高いという性質を有しており、この点が本人認証を難しくしている。そのため、(a) と (b) の双方からの改善が肝要となる。インデックスの頑強性に関する検討は、生体情報の取得ごとに生じる本人内の変動を吸収することを目的としており、(a) の観点から pivot 型インデックス法の改善に寄与している。pivot の空間分離性に関する検討は、他人間の生体情報から得られる特徴量を互いに遠ざけることを目的としており、(b) の観点から pivot 型インデックスの改善に寄与している。

以降では、まず 3.2 節で、インデックスの頑強性の観点から議論し、続いて 3.3 節で、pivot の空間分離性の観点から議論する。その後、4 章および 5 章で、順列インデックスを用いた 1 対多掌紋認証にこれらの改良を適用することで、認証精度 (N 位認証率, 1 位認証率, 本人拒否率, 他人受入率) が向上するか検証する。

3.2 本人内の変動に対する頑強性向上に関する提案

生体情報をもとに生成される順列インデックスは、生体情報の取得ごとに生じる本人内の変動にも影響を受ける。逆に、順列インデックスの頑強性を高めることができれば、生体情報の取得ごとに生じる本人内の変動も吸収することができる。

そこで、登録時に、各ユーザから複数の掌紋画像を取得し、安定した順列インデックスが得られる掌紋画像をユーザのテンプレート画像として選択する方式を提案する。本論文では以降、この方式を「インデックス尺度型テンプレート選択」と呼ぶこととする。インデックス尺度型テンプレート選択の具体的な手順は次のとおりである (図 3)。

1. 任意のユーザ u から v 枚の掌紋画像 $\{t_{u,1}, \dots, t_{u,v}\}$ を登録用のテンプレート画像として取得する。
2. 各掌紋画像 $t_{u,i}$ に対して、順列インデックス $\pi_{t_{u,i}}$ をそれぞれ生成する。
3. 生成された $\{\pi_{t_{u,1}}, \dots, \pi_{t_{u,v}}\}$ の中から、式 (2) を用い

て、同一人物の生体情報から得られた順列インデックス間の距離の和を最小にするインデックス $\pi_{t_{u,s}}$ を選択する。

4. このインデックス $\pi_{t_{u,s}}$ とそれに対応する掌紋画像 $t_{u,s}$ をユーザ u のテンプレートとしてデータベースへ登録する。

$$\pi_{T_{u,s}} = \arg \min_{\pi_{T_{u,j}} \in \{\pi_{T_{u,1}}, \dots, \pi_{T_{u,v}}\}} \sum_{i=1}^v S(\pi_{t_{u,i}}, \pi_{t_{u,j}}) \quad (2)$$

インデックス尺度型テンプレート選択の適用により、登録時に取得される複数の掌紋画像の中から、本人の変動範囲内で中心に近い順列インデックスを選択することができるため、生体情報の変動に対して頑強な順列インデックスが生成されると期待できる。

3.3 Pivot の空間分離性改善による他人間の識別性向上に関する提案

インデックスの生成に用いる各 pivot は、特徴空間における各軸、すなわち基底であるといえる。そして、他人同士を効率的に分離できるような基底 (pivot) を張ることで、空間分離性が改善され、他人同士の生体情報を高精度に識別可能だと考えられる。よって、そのような基底となる pivot を見つける手法の検討が必要である。

原理的には、各 pivot が特徴空間上で直交 (無相関) となるようにすることで、高精度な識別を実現可能な pivot となると考えられる。そこで本研究では、そのような直交した pivot の生成手法として、主成分分析 (Principal Component Analysis: PCA) を用いて「pivot として使用する画像 (以降、pivot 画像と呼ぶ)」を生成する手法を提案する。

主成分分析 (PCA) は、線形変換を用いて高次元データを低次元データへ変換する次元削減手法として広く利用されている。主成分分析によって得られる新たな基底は、データの分散が大きくなるものから順に第 1 主成分、第 2 主成分、…、と決定される。

そこで、pivot の空間分離性を高める手法として、「全ユーザのテンプレート画像 (掌紋画像) を主成分分析することによって得られる主成分画像」を pivot として生成することを提案する。生体情報の「他人間の類似性が高い」という問題に対し、主成分分析によって得られた各主成分を pivot 画像として用いることで、生体情報の識別性を向上させ、pivot の空間分離性の改善につながると考えられる。

主成分分析を用いた pivot 画像の生成手順は次のとおりである。

1. 全ユーザのテンプレート画像を用いて主成分分析を行う。
2. 主成分分析の結果得られた第 1 主成分から第 m 主成分までを画像化し、それらを pivot 画像として用いる。

4. 実験内容

4.1 データセット

今回の実験では、523 名の実験参加者の左右の手のひら (523 名 $\times$ 2 = 1,046 件) から、各 10 枚ずつ手のひら画像を取得した (1,046 件 $\times$ 10 枚 = 10,460 枚)。また、右手の掌紋と左手の掌紋を別々のユーザとして扱うこととした (すなわち、ユーザ数は 1,046 名となる)。1,046 名のユーザを、登録ユーザ 946 名、非登録ユーザ 100 名の 2 つの群に分割した。登録ユーザ群のデータを用いて登録者他人受入率 (Enrollee False Acceptance Rate: EFAR)、登録者本人拒否率 (Enrollee False Rejection Rate: EFRR) を評価する。非登録ユーザ群のデータを用いて非登録者他人受入率 (Non-enrollee False Acceptance Rate: NFAR) を評価する [11]。登録ユーザごとに各 10 枚の手のひら画像を取得順に 5 枚ずつに分け、取得順に登録用のテンプレート画像として 5 枚、認証用のクエリ画像として 5 枚をそれぞれ用意した。

すべての手のひら画像に対して、以下の前処理を行い、掌紋認証に用いる掌紋画像を生成した。図 4 に手のひら画像と掌紋画像の例を示す。

1. 文献 [13] の手法 1 を用いて、手のひら画像から掌紋領域 (Region of Interest: ROI) を切り出す。
2. 掌紋領域の画像を 160×160 [px] にリサイズする。
3. RGB 色空間から YUV 色空間に変換し、Y 値のみの 160×160 [px] のグレースケール画像を掌紋画像とする。

4.2 実験環境

今回の検証実験に用いた実行環境を表 1 に示す。

4.3 1 対多掌紋認証システム

本研究で想定する 1 対多掌紋認証システムの概要を図 5 および図 6 に示す。

4.1 節で説明したように、今回の実験においては、1 ユーザあたり、登録時および認証時にそれぞれ 5 枚の掌紋画像




図 4 評価実験に用いる掌紋画像

Fig. 4 Example of palmprint image used in evaluation experiments.

表 1 実行環境

Table 1 Execution environment.

CPU	Intel Core i7-11375H 3.3GHz
RAM	LPDDR4X-4266 16GB
OS	Ubuntu 20.04.4 LTS (WSL2)
コンテナエンジン	Docker 20.10.16
使用言語	Python 3.6.9




図 5 検証実験における 1 対多掌紋認証システムの流れ（インデックス尺度型テンプレート選択適用なし）

Fig. 5 Pipeline of palmprint identification in this experiment (w/o index-based template selection).




図 6 検証実験における 1 対多掌紋認証システムの流れ（インデックス尺度型テンプレート選択適用あり）

Fig. 6 Pipeline of palmprint identification in this experiment (w/ index-based template selection).

を用意している．認証精度を高めるための工夫として，登録時および認証時に，それぞれ 5 枚の掌紋画像の中から最適な画像を選び，それをテンプレートおよびクエリとして用いることが一般的である．その典型的な手法の 1 つが，4.4 節で説明する「照合尺度型テンプレート/クエリ画像選択^{*1}」である．登録時および認証時に照合尺度型テンプレート/クエリ画像選択を用いる場合の掌紋認証システムが図 5 である．

^{*1} 「照合尺度型テンプレート選択」，「照合尺度型クエリ画像選択」は本論文での呼称である．

これに対し，3.2 節で提案したインデックス尺度型テンプレート選択が採用された場合には，照合尺度型テンプレート選択に加えてインデックス尺度型テンプレート選択が適用される形となる^{*2}．登録時に照合尺度型クエリ画像選択とインデックス尺度型テンプレート選択を，認証時には照合尺度型クエリ画像選択を，それぞれ用いる場合の掌紋認証システムが図 6 である．

図 5 および図 6 の 1 対多掌紋認証システムでは，まず，順列インデックス法が適用され，クエリと類似するテンプレートの候補が抽出される（図 5，図 6 の「インデックスを用いたテンプレートのソート」）．次に，類似度順にソートされたテンプレートの候補に対し，上位のテンプレートから順番にクエリとの 1 対 1 照合を行っていき，類似度が閾値 θ_d 以上のテンプレートを発見する（図 5，図 6 の「クエリ画像とテンプレート画像との 1 対 1 照合」）．ただし，1 対 1 照合を θ_N 回試しても認証閾値 θ_d 以上のテンプレートが見つからなかった場合は，認証失敗とする．今回の 1 対 1 照合は，文献 [16] で提案された掌紋認証用の照合アルゴリズムを採用した．

図 5，図 6 の「インデックスを用いたテンプレートのソート」を実行した結果に対する N 位認証率（ソートされたテンプレート画像の上位 N 件の中にクエリ画像が含まれる割合）が，順列インデックス法の精度である．図 5，図 6 の「クエリ画像とテンプレート画像との 1 対 1 照合」を実行した結果に対する 1 位認証率（1-EFRR），EFAR，NFAR が，1 対多掌紋認証システムの精度である．今回は，生体認証システムの安全性に配慮し， $\text{EFAR} = 0\%$ となるように 1 対 1 照合の認証閾値 θ_d を設定した．そのうえで， $\text{EFRR} < 5\%$ となるように，テンプレート候補数の打ち切り閾値 θ_N を設定した．ここで，打ち切り閾値 θ_N は照合回数の上限であり， θ_N 回照合しても本人テンプレートが見つからなかった場合には，認証失敗として結果を返すものとする．

4.4 照合尺度型テンプレート/クエリ画像選択

登録時における照合尺度型テンプレート選択の手順を示す．式 (3) を用い， v 枚のユーザ u のテンプレート画像 $\{t_{u,1}, \dots, t_{u,v}\}$ に対して，照合アルゴリズム M の尺度で最も中心に近い画像を 1 枚選択する．そして，そのテンプレート画像 $t_{u,s}$ ，および $t_{u,s}$ の順列インデックス $\pi_{t_{u,s}}$ をテンプレートとして認証システムのデータベースへ登録する．

$$t_{u,s} = \arg \max_{t_{u,j} \in \{t_{u,1}, \dots, t_{u,v}\}} \sum_{\substack{i=1 \\ i \neq j}}^v M(t_{u,i}, t_{u,j}) \quad (3)$$

今回の検証実験では，ユーザあたり 5 枚の登録画像が用

^{*2} インデックス尺度型テンプレート選択の実行には pivot との照合が必要となる．pivot はサーバ側に保管される情報であるため，クライアント単体ではインデックス尺度型テンプレート選択を実行することはできない．そのため，インデックス尺度型テンプレート選択はテンプレートの登録時にのみ適用される形となる．

意されているため、 $v = 5$ である。照合アルゴリズム M には帯域制限位相限定相関法 (Band-Limited Phase-Only Correlation: BLPOC) [17] を用いた。

認証時における照合尺度型クエリ選択の手順を示す。式 (4) を用いて、 w 枚のユーザ u のクエリ画像 $\{q_{u,1}, \dots, q_{u,w}\}$ に対して、照合アルゴリズム M の尺度で最も中心に近い画像を 1 枚選択する。そして、そのクエリ画像 $q_{u,s}$ 、および $q_{u,s}$ の順列インデックス $\pi_{q_{u,s}}$ をクエリとして認証手順を実行する。

$$q_{u,s} = \arg \max_{q_{u,j} \in \{q_{u,1}, \dots, q_{u,w}\}} \sum_{\substack{i=1 \\ i \neq j}}^w M(q_{u,i}, q_{u,j}) \quad (4)$$

照合尺度型テンプレート選択と同様に、本検証では 1 ユーザあたり 5 枚の認証画像が用意されているため、 $v = 5$ である。照合アルゴリズム M には BLPOC を用いた。

インデックス尺度型テンプレート選択が、順列インデックスの観点でより安定した掌紋画像の選択に寄与するのに対し、照合尺度型テンプレート/クエリ画像選択は、照合アルゴリズム M の観点でより安定した掌紋画像の選択に寄与するという違いがある。

4.5 インデックス尺度型テンプレート選択

インデックス尺度型テンプレート選択の効果を評価するために、登録インデックス尺度型テンプレート選択を採用した場合 (図 6) と採用しない場合 (図 5) を比較する。比較の指標として、図 5 および図 6 の「インデックスを用いたテンプレートのソート」処理の N 位認証率を用いる。インデックス尺度型テンプレート選択の手順は、3.2 節に示したとおりである。今回の検証実験では、ユーザあたり 5 枚の登録画像が用意されているため、 $v = 5$ である。

4.6 Pivot 画像の選択/生成

主成分分析法による pivot 画像の選択/生成の効果を評価するために、4.6.1～4.6.6 項の 6 つの pivot 画像選択/生成を比較する。ここで、4.6.1 項が提案手法 (主成分分析を用いた pivot 画像生成)、4.6.2, 4.6.3 項が pivot 画像選択型の比較手法、4.6.4～4.6.6 項が pivot 画像生成型の比較手法である。今回の検証実験では、 16×16 [px], 32×32 [px], 64×64 [px] の 3 種類のサイズの pivot 画像を試す。比較の指標として、各 pivot 数、pivot 画像サイズの組合せにおける N 位認証率を用いる。また、各 pivot 選択/生成手法において、100 位認証率が最良となる pivot 数および pivot 画像サイズの組合せに対し、各手法での CMC 曲線および平均処理時間の比較を行う。なお、主成分分析を用いた pivot 画像選択/生成 (4.6.2～4.6.6 項) は、すべて、乱数の選ばれ方によって pivot 画像の選択/生成の結果が異なる。そのため、乱数を変更して 5 回実験を行い、認証精度や速度の評価についてはその平均値を用いて行うこととする。




図 7 主成分分析を用いて生成した pivot 画像 (pivot 画像サイズ 32×32 [px])

Fig. 7 Pivot images generated by PCA (pivot image size 32×32 [px]).

4.6.1 主成分分析を用いた pivot 画像の生成

3.3 節で提案した主成分分析を用いた pivot 画像生成を実行した。各ユーザの登録用の掌紋画像、計 4,730 枚 (946 件 $\times$ 5 枚) を用いて以下の処理を行った。

1. 登録用の 4,730 枚の掌紋画像 (160×160 [px]) それぞれに対し、中央領域 128×128 [px] を切り出す。
2. 1 の処理を行ったそれぞれの画像を 16×16 [px], 32×32 [px], もしくは 64×64 [px] に縮小する。
3. 2 によって得られた画像 4,730 枚を用いて主成分分析を適用し、基底画像を得る。
4. 基底画像のうち、第 1 主成分画像から第 m 主成分画像までを pivot として用いる。 m は $32/64/128/256$ のいずれかとした。

主成分分析法を用いて生成された pivot 画像の例を図 7 に示す。

4.6.2 テンプレートから pivot 画像をランダムに選択

先行研究 [2], [3] では、登録されているテンプレートの中からランダムに pivot 画像を選択している。そこで、本検証の比較対象として、テンプレートからランダムに pivot 画像を選択する手法を考える。pivot 画像を選択する手順は次のとおりである。

1. データベースへ登録済みのテンプレート画像 (掌紋画像) 946 件のうちから、ランダムに 32, 64, 128, もしくは 256 件のテンプレート画像を選択する。
2. 1 で選択された掌紋画像 (160×160 [px]) それぞれに対して、中央領域 128×128 [px] を切り出す。
3. 切り出した画像を 16×16 [px], 32×32 [px], もしくは 64×64 [px] に縮小し、pivot 画像として用いる。

以上の操作により、pivot 画像サイズについては $16 \times 16/32 \times 32/64 \times 64$ [px] の 3 パターン、pivot 数 m については $32/64/128/256$ の 4 パターンの計 12 パターンの pivot 数/pivot 画像サイズを用意した。その他の pivot 選択/生成手法においても同様の 12 パターンを用意し、手法間での比較を行うこととする。ランダム選択法で用いた pivot 画像の例を図 8 に示す。

4.6.3 FFT を用いた pivot 画像の選択

2.3 節で述べたとおり、順列インデックス法を用いた一般画像検索に関する先行研究 [5] において、Spearman Rho


図 8 ランダムに選択した pivot 画像 (pivot 画像サイズ 32×32 [px])

Fig. 8 Pivot images randomly selected from templates (pivot image size 32×32 [px]).


図 9 FFT 法を用いて選択した pivot 画像 (pivot 画像サイズ 32×32 [px])

Fig. 9 Pivot images selected by FFT (pivot image size 32×32 [px]).

距離尺度型の FFT 法が最も優れた性能を示した。そこで、本検証の比較対象として、テンプレートから FFT 法を用いて pivot 画像を選択する手法を考える。pivot 画像を選択する手順は次のとおりである。

1. データベースへ登録済みの掌紋画像 (160×160 [px]) 946 件それぞれに対して、中央領域 128×128 [px] を切り出す。
2. 切り出した画像を 16×16 [px], 32×32 [px], もしくは 64×64 [px] に縮小する。
3. 2.3 節の FFT 法の手順をもとに、32, 64, 128, もしくは 256 件のテンプレート画像を pivot として選択する。

FFT 法を用いて選択された pivot 画像の例を図 9 に示す。

4.6.4 一様乱数によるランダムな pivot 画像の生成

文献 [4] では、ランダムノイズを用いて pivot 画像を生成する方法を比較対象に含めている。そこで、本検証の比較対象として、一様乱数によって生成されるランダムノイズ画像を pivot 画像として用いる手法を考える。具体的には、0~255 の一様分布の乱数を用いて pivot 画像の各画素の値を決定する。4.6.2 項と同様、pivot 画像サイズは $16 \times 16/32 \times 32/64 \times 64$ [px] の 3 パターン、pivot 数 m は $32/64/128/256$ の 4 パターンを用意した。ランダムノイズによって生成された pivot 画像の例を図 10 に示す。

4.6.5 オートエンコーダを用いた pivot 画像の生成

3.3 節で述べたように、主成分分析法の目的は「直交した pivot 画像の生成」にある。そこで、本検証の比較対象として、オートエンコーダを用いて直交した pivot 画像を生成する手法を考える。

オートエンコーダは、ニューラルネットを用いて非線形な次元削減を行う手法として知られている。入力データに


図 10 一様乱数を用いて生成した pivot 画像 (pivot 画像サイズ 32×32 [px])

Fig. 10 Pivot images generated by random numbers (pivot image size 32×32 [px]).

対して低次元データ（以降、中間表現ベクトルと呼ぶ）を出力するエンコーダと、中間表現ベクトルから入力データと同サイズのデータを出力するデコーダの 2 つから構成される。入力データに対する出力データの再構成誤差が小さくなるように学習を行うことで、中間表現ベクトルのレイヤにおいてデータの次元削減が行われる。

主成分分析が線形変換であるのに対し、オートエンコーダはニューラルネットの非線形変換を利用している。ニューラルネットの表現力の高さから、主成分分析を用いた場合と比較して、より生体情報（掌紋）の特徴をとらえた形で pivot 画像の生成が可能であると考えられる一方、pivot どうしの直交性については保証されない。

オートエンコーダを用いた pivot 画像の生成手順は次のとおりである。

1. 全登録ユーザのテンプレート画像を用いてオートエンコーダの学習を行う。中間表現ベクトルの次元数 m 枚が、手順 2 で生成される pivot 画像の枚数となる。
2. 学習済みのデコーダに対して、基底ベクトルの組 $\{e_1 = (1, 0, \dots, 0), e_2 = (0, 1, \dots, 0), \dots, e_m = (0, \dots, 0, 1)\}$ を中間表現ベクトルの組として入力し、それらに対する出力データの組を pivot 画像として用いる。

上記のオートエンコーダを用いて pivot 画像生成を実行した。掌紋認証は画像データを用いた生体認証であることから、今回の検証実験では、畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) オートエンコーダを用いた。CNN オートエンコーダの詳細な構成は付録 A.1 に示す。画像サイズは $16 \times 16/32 \times 32/64 \times 64$ [px] の 3 パターン、中間表現ベクトルの次元数（生成される pivot 数） m は $32/64/128/256$ の 4 パターンの計 12 パターンを用意した。ハイパーパラメータは、エポック数 500、バッチサイズ 256、学習率 1.0×10^{-4} とし、損失関数に Binary Cross Entropy、最適化アルゴリズムに Adam を用いて学習を行った。オートエンコーダを用いて生成された pivot 画像の例を図 11 に示す。

4.6.6 深層学習による識別器を用いた pivot 画像の生成

4.6.5 項の方法に加え、深層学習を用いて直交 pivot 画像を生成する手法についても、本検証の比較対象として採用する。




図 11 オートエンコーダを用いて生成した pivot 画像 (pivot 画像サイズ 32×32 [px], $m = 32$)

Fig. 11 Pivot images generated by autoencoder (pivot image size 32×32 [px], $m = 32$).




図 12 深層学習を用いた生体認証

Fig. 12 Biometric recognition with deep learning.

生体顔認証の分野においても、深層学習を用いた識別器が高いパフォーマンスを発揮している [15]。これらは一般に、生体情報から特徴量を抽出する特徴量抽出器と、抽出された特徴量からユーザの分類を行うユーザ分類器の2つを用いて学習が行われる (図 12)。認証時には、生体情報を特徴量抽出器に通して得られた特徴量どうしの類似度を用いてユーザの識別を行う [15]。

主成分分析やオートエンコーダでは、教師なし学習で掌紋の特徴空間をとらえるのに対し、深層学習では、教師あり学習によって掌紋画像から抽出される特徴量が他人同士で遠くなるように識別器が調整される。このため、より本人と他人とが識別されやすい形で特徴空間が形成され、空間分離性に優れた pivot 画像が得られると期待される。

深層学習による識別器を用いた pivot 画像の生成手順は次のとおりである。

1. 全登録ユーザのうち一部のユーザのテンプレート画像を用いて、識別器の学習を行う。学習に利用しなかったユーザのデータは識別器が過学習していないかを確認するためのテストデータとして利用する。特徴量抽出器の出力の次元数 m が、手順 2 で生成される pivot 画像の枚数となる。
2. 学習した特徴量抽出器の出力が基底ベクトルの組 $\{e_1 = (1, 0, \dots, 0), e_2 = (0, 1, \dots, 0), \dots, e_m = (0, \dots, 0, 1)\}$ となるような入力画像の組を誤差逆伝播法により求める。

上記の深層学習識別器を用いて pivot 画像生成を実行した。今回の検証実験では、深層学習識別器として、特徴量抽出器に ResNet18 [18]、ユーザ分類器に ArcFace [15] を用




図 13 深層学習識別器を用いて生成した pivot 画像 (pivot 画像サイズ 32×32 [px], $m = 32$)

Fig. 13 Pivot images generated by deep learning based palm-print identifier (pivot image size 32×32 [px], $m = 32$).

いた。画像サイズは 16×16 [px], 32×32 [px], 64×64 [px] の 3 パターン、抽出される特徴量の次元数 (生成される pivot 数) m は $32/64/128/256$ の 4 パターンの計 12 パターンを用意した。ハイパーパラメータは、エポック数 500、バッチサイズ 256、学習率 1.0×10^{-4} とし、損失関数に Cross Entropy、最適化アルゴリズムに Adam を用いて学習を行った。学習に用いた画像は、全 946 ユーザのうち、ランダムに選択した 800 ユーザの登録画像、計 4,000 枚 ($800 \text{ ユーザ} \times 5 \text{ 枚}$) とした。識別器の学習終了後、特徴量抽出器の出力が基底ベクトルの組 $\{e_1 = (1, 0, \dots, 0), e_2 = (0, 1, \dots, 0), \dots, e_m = (0, \dots, 0, 1)\}$ となるような入力画像の組を、以下の手順で求めた。

1. 全画素の値が (0 から 255 の 256 階調のうち) 128 となるようなグレースケール画像 $x_{i,1}$ を用意する。
2. 1 の画像に対する特徴量抽出器の出力を算出する。
3. 特徴量抽出器の出力と e_i との誤差を計算し、以下の式を用いて pivot 画像を生成する。ここで、 $\nabla_{x_{i,j}} \text{Loss}$ は $x_{i,j}$ に対する特徴量抽出器の出力と e_i との誤差をもとに算出した勾配である。

$$x_{i,j+1} = x_{i,j} - 0.1 \times \nabla_{x_{i,j}} \text{Loss} \quad (5)$$

pivot 画像の生成では、 $x_{i,j}$ と e_i との損失関数に Cross Entropy Loss を使い、 $j = 30000$ となるまでこの処理を反復した。深層学習識別器法で生成された pivot 画像の例を図 13 に示す。

4.7 類似度の順序化と順列インデックスの生成

掌紋画像をテンプレートとして登録する際には、テンプレートと各 pivot の類似度が算出され、その類似度の順位から順列インデックスが生成される。各 pivot (16×16 [px], 32×32 [px], 64×64 [px] のいずれかのサイズ) を用いて、掌紋画像 (160×160 [px]) に対する順列を生成する手順は以下のとおりである。この結果得られた順列を順列インデックスとして登録する。

1. 掌紋画像の中央領域 128×128 [px] を切り出す。
2. その画像を pivot と同サイズにリサイズする。
3. リサイズした画像と各 pivot 画像 (m 枚) を NCC (Normalized Cross Correlation) を用いて類似度を算出する。

4. 各 pivot との類似度を大きい順に順序化する．

掌紋画像の認証が行われる際には，クエリ画像と各 pivot の類似度が算出され，その類似度を大きい順に順序化して順列を得る．クエリ画像から算出された順列と認証システムに登録されているすべての順列インデックスを比較することによって，クエリ画像との類似度が高いテンプレートの候補を発見する．各 pivot を用いて，掌紋画像に対する順列を生成する処理は，テンプレート登録時と同様である．

5. 実験結果

5.1 インデックス尺度型テンプレート選択の効果

4.6.1～4.6.6 項で説明した主成分分析法，ランダム選択

法，FFT 法，ランダムノイズ法，オートエンコーダ法，深層学習識別器法の各 pivot 選択/生成手法について，各 pivot 数 ($m = 32/64/128/256$)，および，各 pivot 画像サイズ ($16 \times 16/32 \times 32/64 \times 64$ [px]) のそれぞれのパターンにおいて，インデックス尺度型テンプレート選択の採否による N 位認証率の違いを比較した表を表 2 および表 3 に示す．

表中，「V」がインデックス尺度型テンプレート選択を採用していない（照合尺度型テンプレート選択のみが採用されている）認証システム（図 5）を，「V+I」がインデックス尺度型テンプレート選択（と照合尺度型テンプレート選択）を採用した認証システム（図 6）を表す．なお，紙面

表 2 インデックス尺度型テンプレート選択の採否による N 位認証率の比較（ランダム選択法/FFT 法/ランダムノイズ法）

Table 2 Comparison of rank-N identification rate with and without index-based template selection (Random Selection/FFT/Random Noise).

			N 位認証率 [%]								
			ランダム選択法			FFT 法			ランダムノイズ法		
pivot 数 m	pivot 画像 サイズ [px]	テンプレ ート選択 [V/V+I]	1 位 認証率	20 位 認証率	100 位 認証率	1 位 認証率	20 位 認証率	100 位 認証率	1 位 認証率	20 位 認証率	100 位 認証率
32	16×16	V	38.82	65.67	84.08	40.7	68.08	87.23	41.44	67.55	85.22
		V+I	41.21	69.32	87.74	44.42	73.66	90.55	44.50	71.84	88.35
	32×32	V	38.82	65.35	84.55	42.11	67.72	86.66	33.28	60.57	80.53
		V+I	41.75	69.64	88.18	45.31	73.13	89.62	35.77	64.67	84.71
	64×64	V	38.03	64.61	83.55	38.86	66.24	85.90	31.52	57.93	79.20
		V+I	41.16	69.87	87.84	43.70	71.99	90.15	33.93	62.37	83.74
64	16×16	V	43.02	67.23	85.07	45.69	70.47	87.70	61.90	79.79	90.89
		V+I	46.22	71.80	88.86	49.22	75.86	90.89	65.62	83.40	93.51
	32×32	V	42.41	66.15	84.33	46.93	69.92	87.38	54.88	75.94	88.01
		V+I	46.19	72.01	89.03	51.04	76.49	91.21	60.13	80.19	91.56
	64×64	V	42.73	66.11	84.29	45.50	69.79	87.02	51.90	72.35	86.41
		V+I	46.66	71.92	88.94	49.98	76.03	91.01	56.19	77.38	90.15
128	16×16	V	45.10	68.60	85.67	48.71	72.37	88.16	69.60	83.74	92.56
		V+I	48.01	73.07	89.81	52.73	76.58	91.33	73.89	87.21	94.65
	32×32	V	45.05	67.61	85.10	47.95	70.87	87.42	66.05	80.57	90.44
		V+I	49.03	73.36	89.75	53.3	76.81	91.08	70.40	85.20	93.00
	64×64	V	45.33	67.63	85.16	48.67	71.56	87.67	61.23	78.60	89.58
		V+I	49.20	73.55	89.87	53.91	77.27	91.63	66.19	83.21	92.43
256	16×16	V	45.90	69.15	86.49	49.18	71.9	88.29	72.83	85.54	93.17
		V+I	49.47	74.06	90.23	53.13	75.54	91.27	76.19	89.11	95.20
	32×32	V	46.13	68.08	85.88	49.34	71.59	87.53	69.09	82.45	91.69
		V+I	50.44	74.33	90.21	54.02	76.79	91.42	73.78	86.98	94.27
	64×64	V	46.17	68.22	85.90	50.34	71.75	87.55	66.24	80.74	90.38
		V+I	50.61	74.40	90.25	54.69	77.36	91.65	70.42	84.50	93.23

V：照合尺度型テンプレート選択 / I：インデックス尺度型テンプレート選択

表 3 インデックス尺度型テンプレート選択の採否による N 位認証率の比較（主成分分析法/オートエンコーダ法/深層学習識別器法）

Table 3 Comparison of rank-N identification rate with and without index-based template selection (PCA/Autoencoder/Deep Learning Classifier).

			N 位認証率 [%]								
pivot 数 m	pivot 画像 サイズ [px]	テンプレ ート選択 [V/V+I]	主成分分析法			オートエンコーダ法			深層学習識別器法		
			1 位 認証率	20 位 認証率	100 位 認証率	1 位 認証率	20 位 認証率	100 位 認証率	1 位 認証率	20 位 認証率	100 位 認証率
32	16×16	V	75.58	87.74	94.82	43.26	69.89	87.17	27.72	58.58	82.03
		V+I	78.86	91.01	96.62	47.21	74.02	90.15	30.70	62.28	85.52
	32×32	V	73.57	88.16	94.40	47.93	74.21	90.17	44.31	71.31	87.38
		V+I	78.22	91.12	95.98	54.57	80.19	93.36	49.07	76.79	91.42
	64×64	V	73.26	86.68	94.61	56.96	78.08	91.23	52.28	75.45	88.82
		V+I	78.22	91.12	95.88	62.39	82.75	93.78	58.14	81.33	93.17
64	16×16	V	78.86	88.37	94.40	64.50	83.36	92.66	50.08	73.72	89.07
		V+I	82.98	90.80	94.82	69.18	86.89	95.54	54.46	78.94	92.79
	32×32	V	75.90	87.63	93.45	70.13	84.40	93.21	58.86	79.77	90.85
		V+I	80.23	90.38	94.82	74.57	89.79	95.81	64.27	84.48	94.84
	64×64	V	76.32	86.58	93.45	63.85	81.10	92.92	64.08	80.91	91.90
		V+I	80.23	89.64	94.71	69.22	85.35	95.33	69.47	86.07	95.12
128	16×16	V	76.96	85.62	90.49	69.47	83.68	93.34	58.27	78.73	91.01
		V+I	80.66	88.69	92.28	73.66	87.70	95.35	62.22	83.15	94.33
	32×32	V	76.11	84.36	89.32	69.45	84.48	93.17	64.12	81.95	91.99
		V+I	79.49	88.27	92.28	75.29	89.75	96.07	68.75	86.72	95.67
	64×64	V	74.74	83.30	88.79	72.43	85.67	93.55	68.52	83.59	93.02
		V+I	78.12	86.68	91.75	75.58	89.51	96.00	74.86	89.18	96.28
256	16×16	V	72.30	80.34	85.52	71.42	84.82	93.23	58.54	78.33	90.78
		V+I	74.95	83.40	88.69	75.05	88.92	96.13	63.85	83.21	94.29
	32×32	V	69.77	77.27	84.46	66.49	81.86	92.05	64.67	81.14	91.56
		V+I	73.47	80.55	86.05	70.85	86.55	95.31	69.41	86.45	95.67
	64×64	V	68.08	76.96	84.36	64.88	81.35	91.71	70.93	84.71	93.64
		V+I	71.88	80.55	86.36	70.44	86.91	95.22	76.55	89.85	96.43

V : 照合尺度型テンプレート選択 / I : インデックス尺度型テンプレート選択

の制約上、表 2 および表 3 においては具体的な N の値として、1/20/100 の 3 つの場合のみを示している。

表 2 および表 3 の結果より、いずれの pivot 数、pivot 画像サイズ、pivot 選択/生成手法においても、インデックス尺度型テンプレート選択の採用により、順列インデックスを用いた 1 対多掌紋認証の N 位認証率が向上する結果となった。すなわち、インデックス尺度型テンプレート選択によって、順列インデックスの頑強性が高まり、生体情報の本人内の変動が引き起こす認証精度の低下が緩和されることが確かめられた。

5.2 pivot の選択/生成手法の比較

5.1 節の検証より、インデックス尺度型テンプレート選択の性能が確かめられた。そこで本節では、インデックス尺度型テンプレート選択を採用した認証システム（図 6）のみを対象として以降の分析を行うこととした。

主成分分析法、ランダム選択法、FFT 法、ランダムノイズ法、オートエンコーダ法、深層学習識別器法の各 pivot 選択/生成手法について、各 pivot 数 ($m = 32/64/128/256$)、各 pivot 画像サイズ (16×16 [px]/ 32×32 [px]/ 64×64 [px]) の 12 パターンにおける N 位認証率を CMC 曲線で比較した結果を図 14 に示す。

pivot 数が比較的少ない $m = 32$ や $m = 64$ の場合、主成




図 14 CMC 曲線を用いた pivot 選択/生成手法の比較

Fig. 14 Comparison of each pivot selection/generation method with CMC curve.

分分析法がその他の pivot 選択/生成手法と比較して精度が高いという傾向が見られる。一方で、主成分分析法は、pivot 画像数を増やすほど CMC 曲線が下に位置していき、N 位認証率が低下してしまう傾向が見られた。

対して、主成分分析法以外の pivot 選択/生成手法では、pivot 数を増やしていくことで、CMC 曲線が全体的に上に張るようになり、N 位認証精度が高まる傾向が見られた。しかし、認証精度を高めるために pivot 数を増加させると、各 pivot との類似度を計算する回数が増加してしまうため、コストと精度がトレードオフの関係となる。より少ない pivot 数で高い精度を出すことが理想的であるとすると、主成分分析法が他の手法よりも優位であると結論付けることができる。

また、画像サイズの変化に着目すると、主成分分析法は pivot 画像サイズを変更しても CMC 曲線がほぼ変わらないのに対し、深層学習識別器法では、pivot 画像サイズを大きくするほど、CMC 曲線が上に位置する傾向が顕著に見られた。一方、それとは対照に、ランダムノイズ法では、pivot 画像サイズを小さくするほど CMC 曲線が上に位置する傾向が見られた。pivot 画像サイズを増加させる

と、各 pivot との類似度を計算する時間が増加してしまうため、コストと精度がトレードオフの関係となる。より小さい pivot 画像で高い精度を出すことが理想的であるとすると、主成分分析法が他の手法よりも優位であると結論付けることができる。

留意が必要な点として、今回の実験結果においては、ランダムノイズ法（乱数による pivot 画像生成）の認証精度が、文献 [4] で得られている結果よりも高かったことがあげられる。先行研究ならびに本研究のこれまでの実験結果を通じた知見として、pivot 選択/生成の方法によって認証精度が変わりうるということが分かっているが、これは、精度の向上に良い作用をする pivot（好作用 pivot）が存在することを暗示している。ランダムノイズによって pivot を生成する場合、生成する pivot の数を増やすほど、好作用 pivot が偶然生成される可能性が高まることになる。一方で、文献 [4] の図 4 で示されているように、意味のある順列の生成に寄与しない pivot（非作用 pivot）も存在する。生成する pivot の数を増やすと、非作用 pivot も数多く生成されるが、寄与の小さい非作用 pivot が順列を大きく変動させる結果に至ることは少ないのではないかと予想される。その

表 4 各 pivot 選択/生成手法における 100 位認証率の比較

Table 4 Comparison of rank-100 identification rate for each pivot selection/generation method.

pivot 選択/生成手法	pivot 数 m	pivot 画像 サイズ [px]	100 位 認証率 [%]
ランダム選択	256	64×64	90.25
FFT	256	64×64	91.65
ランダムノイズ	256	16×16	95.20
主成分分析	32	16×16	96.62
オートエンコーダ	256	16×16	96.13
深層学習識別器	256	64×64	96.43




図 15 100 位認証率が最良となる組合せでの比較

Fig. 15 Comparison of the combinations with the best rank-100 identification rate.

ため、非作用 pivot が増えるデメリットよりも好作用 pivot が増えるメリットのほうが優位となったのではないだろうか*3。

次に、各 pivot 選択/生成手法において、100 位認証率が最も優れていた pivot 数および pivot 画像サイズの組合せを表 4 に示す。また、表 4 の条件で各手法を比較した CMC 曲線を図 15 に示す。100 位認証率はランダム選択法が 90.25%、FFT 法が 91.65%となっているが、その他の手法はどれも 95%以上となっており、CMC 曲線がほぼ重なっていることから、いずれも同程度の高い水準であるといえる。以上の結果より、提案手法によって空間分離性が向上したことが確かめられた。

続いて、表 4 に示した pivot 数および pivot 画像サイズの組合せで、各 pivot 選択/手法の処理時間の比較を行っ

*3 文献 [4] では、ランダムノイズ法による pivot 生成の効果がそれほど顕著ではない。しかし、文献 [4] の図 10 においても、pivot 数 m を 50 から 100 に増加させた場合に、ランダムノイズ法の認証精度の向上が見て取れる。これは、今回の実験で得られた傾向 (pivot 数を増加させた場合に、ランダムノイズ法の認証精度が向上する) と同じである、という考え方もできる可能性もある。文献 [4] の実験結果と今回の実験結果の相違については、今後の課題としてさらに検討していきたい。




図 16 表 4 の条件における各 pivot 選択/生成手法での順列インデックスの平均処理時間の比較

Fig. 16 Comparison of average processing times of permutation-based indexes for each pivot selection/generation method under conditions in Table 4.

た。処理時間の内訳として、テンプレート画像と m 枚の pivot 画像との類似度を算出し、それを順序化して順列を生成するのに要する時間「順列生成」、および、生成した順列と全テンプレートの順列インデックスとの距離を計算し、全テンプレートを類似度順にソートする時間「ソート」の 2 つの平均処理時間を対象とした。一般的に、pivot 数および pivot 画像サイズが大きくなるほど、クエリ画像と各 pivot 画像の類似度の計算時間が増え、順列生成の所要時間は増加する。また、pivot 数が大きくなるほど、順列 (および順列インデックス) の次元が増え、ソートの所要時間が増加する。

順列生成ならびにソートの所要時間の計測結果を図 16 に示す。ソート所要時間 (緑色) については、各 pivot 選択/生成手法で大差は見られない。一方、順列生成所要時間 (オレンジ色) は、主成分分析法が一番短く、次いでランダムノイズ法およびオートエンコーダ法、深層学習識別器法、FFT 法およびランダム選択法という結果となった。各 pivot 選択/生成手法で明らかな差が見られた理由として、表 4 に着目すると、主成分分析法は他の手法よりも小さい pivot 数および pivot 画像サイズで高い精度を達成しており、それが処理時間の短縮にも貢献していると考えられる。また、ランダムノイズ法およびオートエンコーダ法は、pivot 数は主成分分析法よりも多いものの pivot 画像サイズが小さいために、図 16 における処理時間も同様の順番となっているのだと考えられる。これらの結果から、pivot 数および pivot 画像サイズの削減によって、処理時間の削減につながる事が示された。

以上の結果から考えると、精度および計算コストの両面から、pivot 画像の選択/生成手法としては主成分分析法が優れていると結論付けられる。

表 5 認証成功率 95%以上を満たす表 4 の各手法の 1 対 1 照合打ち切り閾値 θ_N

Table 5 The number of times the verification was fixed to ensure that the success rate of identification would be 95%.

pivot 選択/生成手法	打ち切り閾値 θ_N
ランダム選択	198
FFT	170
ランダムノイズ	119
主成分分析	76
オートエンコーダ	94
深層学習識別器	86

5.3 1 対多掌紋認証システムの性能検証

1 対多掌紋認証システム (図 6) の「クエリ画像とテンプレート画像との 1 対 1 照合」処理までを実行した結果について、認証誤り率および認証時間の観点から検証を行った。

表 4 に示した pivot 数および pivot 画像サイズの組合せによる順列インデックスを用いた 1 対多掌紋認証システムについて、EFAR が 0% となるように 1 対 1 照合アルゴリズムの認証閾値 θ_d を設定したうえで、認証成功率 95% 以上 (EFRR が 5% 未満) を満たすように 1 対 1 照合の打ち切り閾値 θ_N を設定した。表 4 の各手法の pivot 数および pivot 画像サイズの組合せにおいて、認証成功率 95% 以上を満たす打ち切り閾値 θ_N を表 5 に示す。

表 5 より、各手法で同じ 95% という認証成功率を達成するための 1 対 1 照合の打ち切り閾値 θ_N に違いが見られた。提案手法である主成分分析法、オートエンコーダ法、深層学習識別器法、ランダムノイズ法、FFT 法、ランダム選択法の順に θ_N が増加していった。テンプレートのソートの精度が良いほど 1 対 1 照合の打ち切り閾値 θ_N も小さく済む。そして、 θ_N が小さいほど、認証システムの応答時間が高速化され、認証時間の観点での利便性が向上することが期待される。すなわち、 θ_N の小さい順に認証が高速であることが期待される。

なお、非登録者に対する他人受入率 (N FAR) については、1 対 1 照合の打ち切り閾値 θ_N をいかなる値に設定した場合でもつねに 0% であった。これは、今回は登録者他人受入率 (EFAR) が 0% となるように 1 対 1 照合の認証閾値 θ_d を厳しく設定したために、非登録者に対する他人受入率 (N FAR) も抑えられたと考えられる。

続いて、1 対多掌紋認証システムの認証平均時間を比較した図を図 17 に示す。認証時間の内訳として、① 手のひら画像から掌紋画像を取得 (図 4)、② 掌紋画像から順列インデックスを生成、③ 順列インデックスに基づく距離索引によりテンプレートをソート、④ ソートされた順にテンプレート画像とクエリ画像との 1 対 1 照合の 4 つに分かれる。図 17 の比較から、順列インデックスの処理時間が最




図 17 認証成功率を 95% に揃えた際の 1 対多掌紋認証システムの平均認証時間

Fig. 17 The time required for selecting/generating the pivots.

表 6 pivot の生成/選択にかかる時間

Table 6 The time required for pivot selection/generation.

pivot 選択/生成手法		Pivot 選択/生成に要する時間 (概算)
pivot 選択型	ランダム選択	0.1 秒
	FFT	1 分
Pivot 生成型	ランダムノイズ	1 秒
	主成分分析	5 秒
	オートエンコーダ	18 分
	深層学習識別器	42 分

も短く、N 位認証率も優れていた主成分分析法が最も平均認証時間が短いという結果となった。

以上、1 対多掌紋認証システムの認証性能および認証時間の観点からも、pivot の選択/生成手法として主成分分析法が優れていると結論付けられる。なお、pivot の選択/生成処理においてもコスト (時間) がかかり、それらは手法ごとに異なる。これについて、今回の実験で実測した概算値は表 6 のとおりであった^{*4}。ただし、本研究においてはテンプレートのソートをより高速に、より高精度で行うための手法の検討に焦点を当てており、実際のユーザ利用時 (認証フェーズ) において発生するコストに重きを置いている。

6. まとめ

本論文では、順列インデックスを用いた 1 対多掌紋認証に対し、先行研究の問題点であった本人内の生体情報の変動に対するインデックスの頑強性、他人間の生体情報を識

^{*4} オートエンコーダおよび深層学習識別器による pivot 生成手法については、Intel Core i9-9900K および NVIDIA GeForce RTX 2080 SUPER を搭載したコンピュータを用いた。

別するための pivot の空間分離性の観点から検討を行い、N 位認証率を向上させるための提案を行った。

本人内の生体情報の変動に対するインデックスの頑強性の向上手法として、インデックス尺度型テンプレート選択を提案した。複数の登録用生体情報の中から、インデックスが最も安定するテンプレートを選択することにより、実際に N 位認証率が向上することが確かめられた。

また、他人同士の生体情報の識別性向上について、主成分分析やその他の手法を用いて pivot を生成する手法の提案を行った。実験結果より、主成分分析を用いた pivot の生成手法であれば、インデックスの次元数や pivot に関するデータ量をより小さく収めることができるため、N 位認証率だけでなく、コストの面からも優れている手法であることが確かめられた。

参考文献

- [1] 松下雅仁, 前田卓志, 笹川耕一: 基準データとの相関を用いたバイオメトリクス個人識別方法, 電子情報通信学会技術研究報告, PRMU100-312, pp.21–26 (2000).
- [2] Maeda, T., Matsushita, M. and Sasakawa, K.: Identification Algorithm Using a Matching Score Matrix, *IEICE Trans. Information and Systems*, Vol.E84-D, No.7, pp.819–824 (2001).
- [3] 村上隆夫, 高橋健太, 松浦幹太: 大規模 ID レス生体認証に向けた逐次索引融合判定の提案, 電子情報通信学会論文誌 A (バイオメトリクス小特集), Vol.J96-A, No.12, pp.801–814 (2013).
- [4] Murakami, T., Fujita, R., Ohki, T., Kaga, Y., Fujio, M. and Takahashi, K.: Cancelable Permutation-based Indexing for Secure and Efficient Biometric Identification, *IEEE Access*, Vol.7, pp.45563–45582 (2019).
- [5] Amato, G., Esuli, A. and Falchi, F.: A comparison of pivot selection techniques for permutation-based indexing, *Information Systems*, Vol.52, pp.176–188 (2015).
- [6] Kamei, T. and Mizoguchi, M.: Fingerprint preselection using eigenfeatures, *Proc. IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp.918–923 (1998).
- [7] Germain, R.S., Califano, A. and Colville, S.: Fingerprint matching using transformation parameter clustering, *IEEE Computational Science and Engineering*, Vol.4, No.4, pp.42–49 (1997).
- [8] Chávez, E., Figueroa and Navarro, G.: Effective proximity retrieval by ordering permutations, *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol.30, No.9, pp.1647–1658 (2008).
- [9] Amato, G. and Savino, P.: Approximate Similarity Search in Metric Spaces using Inverted Files, *Proc. 3rd International Conference on Scalable Information Systems (InfoScale '08)*, pp.1–10 (2008).
- [10] Bolle, R.M., Connell, J.H., Pankanti, S., Ratha, N.K. and Senior, A.W.: *Guide to Biometrics*, Springer (2003).
- [11] 村上隆夫, 高橋健太: 多重仮説における逐次確率比検定を用いた ID レス生体認証の高精度化, 情報処理学会論文誌, Vol.50, No.12, pp.1234–1242 (2009).
- [12] Noda, H. and Kawaguchi, E.: Adaptive speaker identification using sequential probability ratio test, *Proc. 15th International Conference on Pattern Recognition (ICPR '00)*, pp.262–265 (2000).

- [13] 新田修也, 中原正隆, 馬場 昭, 三宅 優: 掌紋認証システムにおける骨格情報を用いた掌紋領域推定手法の提案, 暗号と情報セキュリティシンポジウム (SCIS2021) 予稿集, 3F3-2, pp.1–6 (2021).
- [14] Dasgupta, S. and Long, P.M.: Performance guarantees for hierarchical clustering, *Journal of Computer and System Sciences*, Vol.70, No.4, pp.555–569 (2005).
- [15] Deng, J., Guo, J., Xue, N. and Zafeiriou, S.: Arcface: Additive angular margin loss for deep face recognition, *CVPR*, pp.4690–4699 (2019).
- [16] Ito, K., Nakajima, H., Kobayashi, K., Aoki, T. and Higuchi, T.: A fingerprint matching algorithm using phase-only correlation, *IEICE Trans. Fundamentals*, Vol.E87-A, No.3, pp.682–691 (2004).
- [17] 青山章一郎, 伊藤康一, 青木孝文, 太田陽基: 携帯電話向け非接触掌紋認証アルゴリズム, 電子情報通信学会論文誌, Vol.J96-A, No.5, pp.250–263 (2013).
- [18] He, K., Zhang, X., Ren, S. and Sun, J.: Deep residual learning for image recognition, *IEEE Conference on Computer Vision and Pattern Recognition*, pp.770–778 (2016).

付 録

A.1 CNN オートエンコーダの構造

16×16 [px] の pivot 画像サイズの生成に用いた CNN オートエンコーダを表 A.1 に示す。ここで、表中の m の

表 A.1 オートエンコーダの構成 (16×16 [px])

Table A.1 An architecture of autoencoder (16×16 [px]).

層	stride	kernel	padding	output
input	-	-	-	$16 \times 16 \times 1$
conv+bn+PReLU	2	4×4	1	$8 \times 8 \times 16$
conv+bn+PReLU	2	4×4	1	$4 \times 4 \times 32$
conv+PReLU	1	4×4	0	$1 \times 1 \times m$
中間表現	-	-	-	$1 \times 1 \times m$
convT+bn+PReLU	1	4×4	0	$4 \times 4 \times 32$
convT+bn+PReLU	2	4×4	1	$8 \times 8 \times 16$
convT+Sigmoid	2	4×4	1	$16 \times 16 \times 1$

表 A.2 オートエンコーダの (32×32 [px])

Table A.2 An architecture of autoencoder (32×32 [px]).

層	stride	kernel	padding	output
input	-	-	-	$32 \times 32 \times 1$
conv+bn+PReLU	2	4×4	1	$16 \times 16 \times 16$
conv+bn+PReLU	2	4×4	1	$8 \times 8 \times 32$
conv+bn+PReLU	2	4×4	1	$4 \times 4 \times 64$
conv+PReLU	1	4×4	0	$1 \times 1 \times m$
中間表現	-	-	-	$1 \times 1 \times m$
convT+bn+PReLU	1	4×4	0	$4 \times 4 \times 64$
convT+bn+PReLU	2	4×4	1	$8 \times 8 \times 32$
convT+bn+PReLU	2	4×4	1	$16 \times 16 \times 16$
convT+Sigmoid	2	4×4	1	$32 \times 32 \times 1$

表 A.3 オートエンコーダの構成 (64×64 [px])Table A.3 An architecture of autoencoder (64×64 [px]).

層	stride	kernel	padding	output
input	-	-	-	$64 \times 64 \times 1$
conv+bn+PReLU	2	4×4	1	$32 \times 32 \times 16$
conv+bn+PReLU	2	4×4	1	$16 \times 16 \times 32$
conv+bn+PReLU	2	4×4	1	$8 \times 8 \times 64$
conv+bn+PReLU	2	4×4	1	$4 \times 4 \times 128$
conv+PReLU	1	4×4	0	$1 \times 1 \times m$
中間表現	-	-	-	$1 \times 1 \times m$
convT+bn+PReLU	1	4×4	0	$4 \times 4 \times 128$
convT+bn+PReLU	2	4×4	1	$8 \times 8 \times 64$
convT+bn+PReLU	2	4×4	1	$16 \times 16 \times 32$
convT+bn+PReLU	2	4×4	1	$32 \times 32 \times 16$
convT+Sigmoid	2	4×4	1	$64 \times 64 \times 1$

値は生成したい pivot の個数, conv は畳み込み層, convT は転置畳み込み層, bn はバッチ正規化である.

32×32 [px] の pivot 画像サイズの生成に用いた CNN オートエンコーダを表 A.2 に示す. 64×64 [px] の pivot 画像サイズの生成に用いた CNN オートエンコーダを表 A.3 に示す.



吉平 瑞穂

2021 年静岡大学情報学部情報科学科卒業. 現在, 同大学院総合科学技術研究科情報学専攻. 情報セキュリティに関する研究に従事.



野崎 真之介

2022 年静岡大学情報学部情報科学科卒業. 現在, 同大学院総合科学技術研究科情報学専攻. 情報セキュリティに関する研究に従事.



芹澤 歩弥

2021 年静岡大学情報学部情報科学科卒業. 現在, 同大学院総合科学技術研究科情報学専攻. 情報セキュリティに関する研究に従事.



中原 正隆

1990 年生. 2014 年京都大学工学部電気電子工学科卒業. 2016 年同大学院情報学研究科修士課程修了. 同年 KDDI (株) 入社. 現在, (株) KDDI 総合研究所でサイバーセキュリティの研究開発に従事.



馬場 昭

1966 年生. 1989 年横浜国立大学工学部建設学科卒業. 1991 年同大学院工学研究科博士前期課程修了. 2002 年 KDDI (株) 入社. 現在, (株) KDDI 総合研究所でサイバーセキュリティの研究開発に従事.



窪田 歩

1995 年京都大学大学院情報工学専攻博士前期課程修了. 同年国際電信電話株式会社 (現, KDDI) 入社. 2003 ~ 2004 年米国 UC Berkeley 客員研究員. 現在, (株) KDDI 総合研究所でサイバーセキュリティの研究開発に従事.



大木 哲史 (正会員)

2002 年早稲田大学理工学部電子情報通信学科卒業. 2004 年同大学院理工学研究科電子・情報通信学専攻修士課程修了. 2010 年早稲田大学理工学術院情報・ネットワーク専攻博士 (工学) 取得. 2010 年早稲田大学理工学総合研究所次席研究員, 2013 年産業技術総合研究所特別研究員を経て, 2017 年静岡大学大学院総合科学技術研究科講師, 2020 年同大学准教授. 情報セキュリティ全般, 特に個人認証を中心としたネットワークセキュリティに関する研究に従事. 電子情報通信学会会員.



西垣 正勝 (正会員)

1990 年静岡大学工学部光電機械工学科卒業。1995 年同大学院博士課程修了。日本学術振興会特別研究員 (PD) を経て、1996 年静岡大学情報学部助手。同講師、助教授の後、2010 年より同創造科学技術大学院教授。博士 (工

学)。情報セキュリティ全般、特にヒューマニクスセキュリティ、メディアセキュリティ、ネットワークセキュリティ等に関する研究に従事。2013～2014 年情報処理学会コンピュータセキュリティ研究会主査、2019～2020 年情報環境領域委員長、2020 年調査研究運営委員長、2015～2016 年電子情報通信学会バイオメトリクス研究専門委員会委員長。2016～2020 年日本セキュリティマネジメント学会編集部会長、2021 年より副会長。本会フェロー。