

# 身体的特徴と行動的特徴の組み合わせによる 圧力センサシートを用いたドライバ認証方式

有井 栞<sup>1</sup> 鶴崎 真理子<sup>1</sup> 阿倍 博信<sup>1</sup>

**概要:** ドライバの個人適合型のシステムの提供や車両のセキュリティ向上に向け、自動車の乗員認証、行動認識への要求が高まっている。これらを同時に実現可能なデバイスとして、本論文では運転座席上の圧力センサシートに着目した。圧力センサシートを用いた個人認証方式では、静止時の圧力分布から取得される身体的特徴だけでなく、動作の個人特徴である行動的特徴が表れると考えられる。そのため、本論文では、CNN (Convolutional Neural Network) と RNN (Recurrent Neural Network) を組み合わせた学習器の学習により、身体的特徴と行動的特徴を統合的に抽出する個人識別器を生成し、複数の個人識別器を用いてドライバを認証する個人認証方式を提案する。基本性能評価のため、11人のドライバについて個人認識実験を行った結果、従来の一般的手法である判別分析法の誤認識率 12.6%Error に対して、提案手法では 0.1%Error となり、提案方式の有効性を確認した。

## A Driver Authentication Method Using Pressure Sensor Sheet by Combination of Physical Features and Active Features

SHIORI ARII<sup>1</sup> MARIKO TSURUSAKI<sup>1</sup> HIRONOBU ABE<sup>1</sup>

### 1. はじめに

安全安心な道路交通の実現に向け、自動運転の実用化が進められている。自動運転は技術レベルによってレベル 0~レベル 5 に分類され [1]、段階的な導入が進められる。自動運転のレベルが低い段階では、システムの開発の主眼は、ドライバを支援する点に置かれ、ドライバに依存しない支援方法にとどまっていた。しかし、技術の高度化に伴い、自動車の自律的動作が増加すると、ドライバとシステムの協調が重要となる。このような協調運転環境の実現には、適切な役割分担とドライバ・システム間の相互理解が必要であるが、このコミュニケーション自体がドライバの認知負荷となり、運転へのディストラクションや、システムへの不信を生じる可能性がある。これらの問題に対処するため、システムはドライバの特性や状態を理解し、適切な情報提示や支援が必要となる。すなわち、システムは、ドライバを認識し、個人とその状態に応じた情報提供、運転支援をすることが求められる。

ドライバの状態を認識する取り組みには、運転行動を阻害する居眠りの検知などが多く研究されているが、多様なセンサの実用化により、これらの車両センサを用いた、ドライバの行動や状態を推定し、さらに個人差を考慮した個人性を学習し、システムに反映させる必要がある。

車両内で取得可能な個人特徴には、パスワードや鍵などの知識属性・所有物属性の特徴が挙げられるが、これらは他人と共有可能で、詐称の可能性があり十分ではない。一方、他人と共有不可能な生体情報による認証方法では、カメラ画像で認証精度の高い結果が得られるが、画角制約があることから運転行動の取得は困難である。単独のセンサで個人特徴と運転行動を取得可能な手段として、行動の個人特徴を用いた行動認証が挙げられる。行動認証は、生体認証に分類され、歩容やジェスチャーなど、特定の動作から個人特徴を抽出する。このため、運転行動を個人特徴抽出の対象動作とすることで、個人特徴と行動特徴が同時に抽出可能となる。行動認証はカメラを使用した認証方式のような高い性能が挙げられないことが予測されるが、車両を利用する数人内であれば、単独でも実用的性能が得られると考えられる。

本研究では、行動認識・運転者状態検知に用いられる、運転座席上の圧力センサシートに着目し、行動認識とドライバ認証を同時に行う事が可能なドライバ認証方式を提案する。

既存の圧力センサシートによる個人認証方式は、特徴抽出方式の設定を人の発見的手法に基づき決定しているが、圧力センサシートで得られる圧力分布データの身体的特徴と行動的特徴の特徴抽出方式は複雑なため、精度には限界

<sup>1</sup> 三菱電機株式会社 情報技術総合研究所  
Information Technology R&D Center, Mitsubishi Electric Corporation

があり、十分な認証精度が得られていない。そこで、個人性は身体的特徴と、行動的特徴に表出されていると考え、CNN (Convolution Neural Network) と RNN (Recurrent Neural Network) を統合した学習により、身体的特徴と行動的特徴の複合的な特徴抽出による個人識別モデルを生成し、ドライバごとの個人識別モデルを用いて認証することで、認証精度の向上が可能だと考える。

本論文の構成を以下に示す。2. で本研究の関連研究について述べ、3. では動作に頑健性を持つ認証方式と認証に用いる特徴抽出方式について述べる。4. では提案方式と従来方式による比較実験について述べ、5. で実験結果の考察を述べる。最後に6. で結論と今後の課題について述べる。

## 2. 関連研究

本章では従来の圧力センサシートによる個人認証方式と、その課題について述べる。

### 2.1. 圧力センサシートによる個人認証方式

圧力センサシートによる個人認証方式の一般的なアルゴリズムを図1に示す。

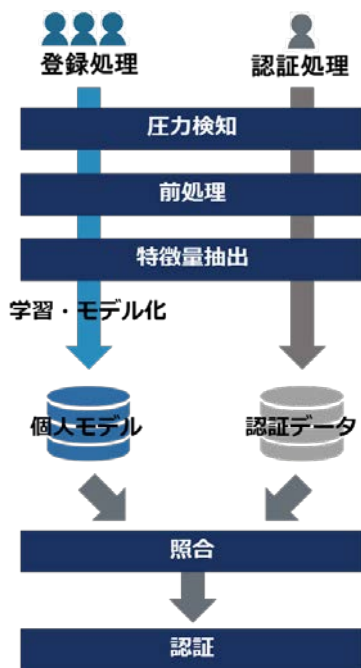


図1. 圧力センサシートによる個人認証方式

圧力センサシートは複数の圧力センサの2次元配列から成り、人が着座すると、座面にかかる圧力分布を検知して、圧力分布データを出力する。圧力分布データはサンプリング周期毎に取得され、処理される。

圧力分布データによる個人認証方式は、登録処理と認証処理により構成される。入力された圧力分布データは、特徴量抽出のため、前処理により変換される。例えば、身体

的特徴抽出であれば、静的状態の検出あるいは、一定時間の平均化処理、行動的特徴抽出であれば、行動区間の検出がこれにあたる。得られた時系列パターンから、特徴量が抽出され、登録処理ではテンプレートを生成し、登録者と関連付けて保存、認証処理では、テンプレートとの類似度が計算され、認証結果が判断される。測定された時系列圧力分布データは、抽出される特徴の選択と、その抽出方式によって認証精度が左右されるため、特徴抽出方式は、個人認証方式において重要な役割を持つ。

従来の圧力センサシートを用いた個人認証方式は、判別分析法による個人認証方式[3]や、SVMによる個人認証方式[4]が挙げられ、判別分析法で用いる身体的特徴や行動的特徴の抽出方式やSVMの入力値となる特徴の抽出方式が人の発見的手法に基づいて設定されている。

### 2.2. 判別分析法による認証方式

本節では、提案手法と比較検討するための従来手法として判別分析法について述べる。判別分析法は、データの分類が既知であるとき、新たに与えられたデータがどの分類に属するかを判別するための分析手法であり、本手法ではマハラノビス距離による判別分析法で個人を判別する。入力値は圧力センサシートから測定された時系列圧力データが用いられフレームごとの圧力値から、予め設定された手法によりN種類の特徴量を演算し、各特徴量の演算結果の平均が0且つ、標準偏差が1となるように正規化することで、単位空間を生成する。単位空間に基づいて異なる2種類の特徴の相関を表す相関行列 $R_p$ を以下の式により演算する。

$$R_p = \begin{bmatrix} 1 & r_{(1)(2)} & \cdots & r_{(1)(N)} \\ r_{(2)(1)} & 1 & \cdots & r_{(2)(N)} \\ \vdots & \vdots & \ddots & \vdots \\ r_{(N)(1)} & r_{(N)(2)} & \cdots & 1 \end{bmatrix} \quad (1)$$

このとき

$$r_{ij} = \frac{X_1 Y_1 + X_2 Y_2 + \cdots + X_M Y_M}{\left\{ (X_1^2 + X_2^2 + \cdots + X_M^2)^{\frac{1}{2}} \times (Y_1^2 + Y_2^2 + \cdots + Y_M^2)^{\frac{1}{2}} \right\}} \quad (2)$$

ここで、 $r_{ij}$ は第*i*特徴量と第*j*特徴量の相互関係、 $X_1 \sim X_M$ は第*i*特徴量、 $Y_1 \sim Y_{MN}$ は第*j*特徴量、 $M$ は被験者1人あたりの試験回数を表す。演算された相関行列 $R_p$ は被験者ごとに関連付けられ、個人データとして登録される。

認証は相関行列 $R_p$ を用いて演算されるマハラノビス距離が予め定められた閾値 $S_p$ 以下であるか否かを判別することにより行われる。マハラノビス距離 $D_p$ は相関行列 $R_p$ から次式により算出される。

$$D_p^2 =$$

$$\begin{bmatrix} u_{1q} & u_{2q} & \cdots & u_{Nq} \end{bmatrix} \begin{bmatrix} 1 & r_{(1)(2)} & \cdots & r_{(1)(N)} \\ r_{(2)(1)} & 1 & \cdots & r_{(2)(N)} \\ \vdots & \vdots & \ddots & \vdots \\ r_{(N)(1)} & r_{(N)(2)} & \cdots & 1 \end{bmatrix}^{-1} \begin{bmatrix} u_{1q} \\ u_{2q} \\ \vdots \\ u_{Nq} \end{bmatrix} \quad (3)$$

このとき

$$u_{iq} = \frac{(v_i - \mu_{iq})}{\sigma_{iq}} \quad (4)$$

ここで、 $i$ は  $1 \sim N$ までの任意の自然数、 $\mu_{ip}$ は $q$ 人目の使用者の第 $i$ 特徴量の平均、 $\sigma_{iq}$ は $q$ 人目の使用者の第 $i$ 特徴量の標準偏差、 $v_i$ は演算された被験者の各特徴量、 $u_{iq}$ は基準化された被験者の各特徴量を表す。個人認証は被験者のマハラノビス距離 $D_p$ が閾値 $S_D$ 以下である場合に、被験者がマハラノビス距離 $D_p$ の演算に使用された相関行列 $R_p$ に関連付けられた $p$ 人目の使用者と認証される。

### 2.3. 既存方式の課題

従来の圧力センサシートによる個人認証技術の課題として、以下の2つが挙げられる。

#### (1) 特徴量抽出

バイオメトリクス認証に用いられる特徴は普遍性（誰もが持っている特徴）、唯一性（人により異なる特徴）、永続性（生涯変わらない特徴）が基本要件となる。

生体認証で用いられる個人特徴は、生体が本体持つ物理的な特徴である身体的特徴と、動作の特徴である行動的特徴に大きく分けられる。身体的特徴は、物理的な普遍性を持つ特徴であることが前提とされるため再現性が高いが、尻部や腿部の体圧である圧力センサシートのデータは被測定者の体形の経時的変化や着座位置のずれに影響を受けやすく、身体的特徴を持つ部分は限定されていることから、個人認証には不十分であると考えられる。一方、行動的特徴は体形の経時的変化や着座位置の影響を受けにくい、同一の被験者が同じ動作を行った場合であっても、その再現性が乏しく、個人認証に適応可能な特徴の抽出が困難である。

#### (2) 認証方式

既存の認証方式は全使用者から一意的に特徴を抽出し、登録された個人モデルと測定データとの類似度により個人を認証する。しかし、普遍性と唯一性が表現される特徴は個人によって異なることから、全使用者に一律の特徴抽出方式を用いた場合、ドライバごとの認証精度に個人差が生じる。そのため、ドライバ個人の特性に合わせた特徴抽出方式を用いた演算結果により照合・認証することが、適切な認証方式であり、個人に適合した特徴抽出方式を用いることで、認証精度が向上可能であると考えられる。

## 3. 提案方式

本章では、圧力シートセンサを用いた、測定環境に頑健性のある個人認証のための認証方式と、提案する認証方式で用いる個人識別モデルの生成方法について述べる。提案方式の概要を図2に示す。

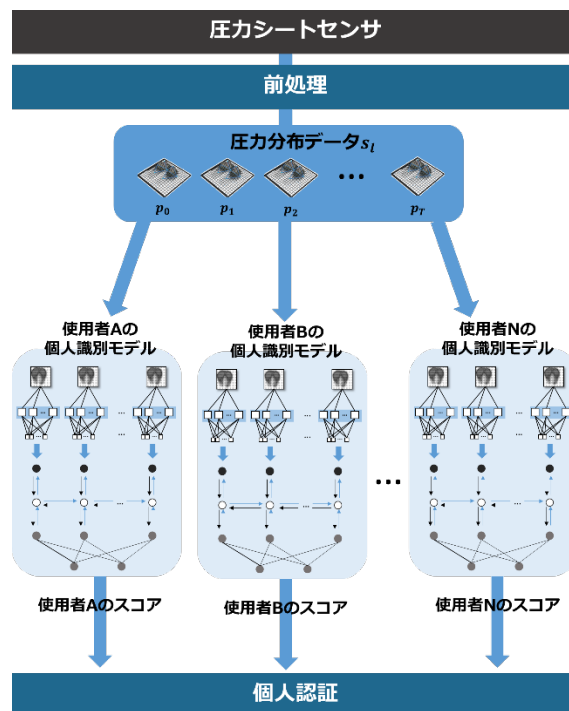


図2. 提案方式概要

### 3.1 前処理

被測定者が運転席に着座した状態で一定時間測定を行い、圧力センサシートにより取得される時系列圧力データから図3に示すように、一定のフレーム間隔で切り出しを行う。

行動認証の前処理は、特徴を持つ行動区間を抽出する処理を示すが、本研究では、個人特徴抽出のため、区間検出せず、行動による動的特徴が含まれる一定時間の切り出しを前処理とする。

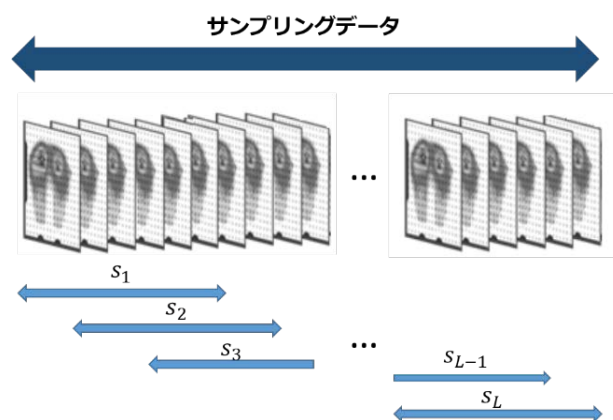


図3. 前処理



め, CNN が身体的特徴を, RNN が行動的特徴を抽出する. このため, CNN と RNN を統合したニューラルネットワークでは身体的特徴と行動的特徴を複合した特徴量が抽出可能である. ニューラルネットワークによる学習を繰り返して, 一定の学習を終えると, 登録者の個人識別モデルが生成される. 生成された個人識別モデルは使用者と関連付けて登録される.

### 3.4. 認証処理

認証処理では, 新たに測定した時系列圧力分布データを, 登録処理の入力データと同様に前処理を行い, 全使用者の個人識別モデルに入力する. 個人識別モデルでは認証者が登録者か登録者以外の使用者かを表すスコアが出力される. 各使用者のスコアを比較し, 閾値以上且つ全使用者の最大値のスコアを出力する個人識別モデルの使用者を認証する.

## 4. 評価実験

本章では判別分析法と, 提案手法を比較する. なお, 性能の初期評価として, モデル外の利用者データを含む, FRR, FAR 評価は行わず, モデル内利用者の個人認識の性能で評価する.

バイオメトリクス認証の精度は, 一般的に FRR (本人拒否率: False Rejection Rate) と FAR (他人受入率: False Acceptance Rate) [7]で表されるが, 本実験は個人モデルに登録された使用者のみによるものであるため, 認識率  $\epsilon$  (%Error) によって精度を評価する.

### 4.1 実験条件

実験では認証精度比較のため, 提案方式による実験と判別分析法による認証方式による実験で同一のデータを用いる. 使用する圧力センサシートは縦 16, 横 16, 計 256 個のセンサにより構成され, 0~200 の値を階調値 1 で取得する. 表 1 に圧力センサシートの条件を示す.

被験者は a~k の 11 名で, 1 人あたり 3 回の着座状態を計測する. この時, 測定時間は 11 秒, 1 秒当たりのフレームレートを 30fps とする. 実験は 3 回の測定データのうち, 2 回を学習データに, 1 回を評価データとした. 表 2 に実験に用いるデータの取得方式を示す.

表 1. 圧力センサシート

計測サイズ (mm)	センサ数	センササイズ (mm)	標準計測範囲 (mmHg)	階調値 (mmHg)
455*455	256 (16*16)	25.4*25.4	5-200	1

表 2. 測定条件

登録者数	測定回数	測定時間	フレーム周期
11名	3回/人	11秒/回	30/秒

### 4.2 認証結果

判別分析法による方式と提案方式による, 同一のデータを用いた認証実験の結果を表 3 に示す.

表 3. 提案方式と判別分析法による認証方式の認証結果

登録者	提案方式 (%Error)	従来方式 (%Error)
a	0.0	0.0
b	0.0	45.0
c	0.1	16.7
d	0.0	21.7
e	0.0	16.7
f	0.0	0.0
g	0.0	3.4
h	0.0	1.7
i	0.0	0.0
j	0.0	16.7
k	0.0	16.7
平均	0.1	12.6

認識率  $\epsilon$  は式(15)によって算出される.

$$\text{認識率 } \epsilon(\%Error) = \frac{\text{誤認証回数}}{\text{認証回数}} * 100 \quad (15)$$

## 5. 考察

本章では認証に使用したデータの特徴と認証精度について検討する.

### 5.1. 判別分析法による認証方式の認証結果

図 6 に判別分析法による認証方式の認証精度の結果と, 同一の利用者による測定ごとの圧力値変動  $S_T$  の分散  $V_p$  との関係を表す. ここで, 分散  $V_p$  は測定データ間の圧力値変動  $S_T$  の分散を表す. 圧力値変動  $S_T$  は時系列圧力分布データのフレーム毎の 2 次元ベクトル値  $p_i$  を用いて式(16)により演算される.

$$S_T = \frac{\sum_{n=1}^N |p_t - p_{t-1}|}{N} \quad (16)$$

使用者 a, i, f は判別分析法を用いた個人認証方式による認証実験結果の認証率  $\epsilon$  が 0.0%Error の使用者を示す。

図 6 のグラフから、データ間の動作量変化が一定の範囲外の使用者データによる認証で、認識精度が低下していることが確認できる。この原因として、判別分析は、クラス内とクラス間のデータ分散を考慮した判別方式であるが、結果的に、分散が大きい使用者は、パラメータ空間で他の使用者とオーバーラップしていることが考えられる。

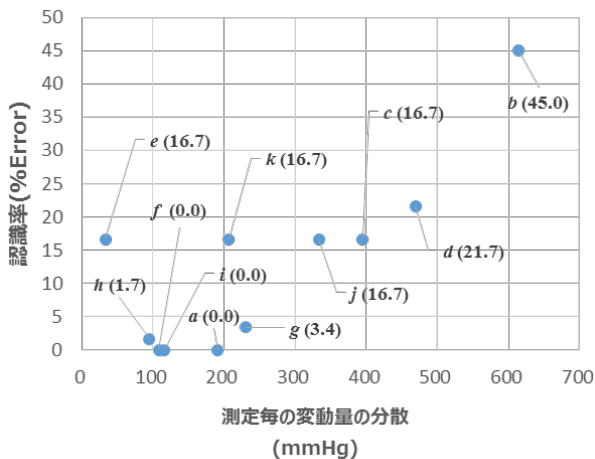


図 6. 測定ごとの圧力値変動の分散  $V_p$  と認識率の関係

## 5.2. 提案方式の認証結果

認証精度の収束と使用者の標準偏差  $\sigma$  とエポック数との関係を図 7 に示す。このとき、収束条件は認証率  $\epsilon \leq 0.1$  とする。

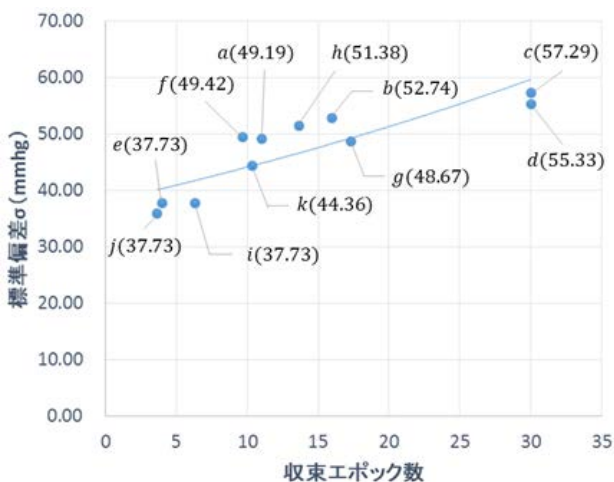


図 7. 標準偏差  $\sigma$  と収束までのエポック数の比較

標準偏差  $\sigma$  は分散の平方根を表し、式(17)によって演算される。

$$\sigma = \sqrt{\left(\frac{\sum_{t=1}^N p_t^2}{N}\right) - p_{ave}^2} \quad (17)$$

図 6 に示されるように、標準偏差の値が小さいほど、収束までのエポック数が減少する傾向がある。すなわち、動作に頑健性のある特徴量抽出モデルの生成には、動作量に応じた学習量が必要であることがわかる。

提案方式による認証結果の認識率は、全使用者の認識率  $\epsilon$  が 0.1%Error 以下に収束していることから標準偏差によらない認証精度が得られており、標準偏差が大きい場合、学習回数が増加するが、個人性を表す特徴量が学習により得られていることを示す。

## 6. おわりに

本研究では、圧力センサシートを用いたバイオメトリクス認証の認証精度向上のため、判別分析法による認証方式の認証精度低下の原因を明らかにし、身体的特徴と行動的特徴を抽出する使用者ごとの個人識別モデルを用いた認証方式を検討した。

判別分析法による認証方式の認証精度低下の原因は、変動  $S_T$  と認識率の関係から、使用者の測定毎の動作量の変化が認証精度を低下させる原因であると考えられる。提案方式と判別分析法による認証方式で、同一のデータを用いた認証実験の結果、判別分析法による認証方式の認識率が 12.6%Error だったのに対し、提案方式の認識率は 0.1%Error と改善された。

以上の結果から、提案方式は判別分析法による認証方式と比較すると、動作に対しても認証精度が低下しにくく、被測定者の動作に頑健性のある認証方式であることが示された。

一方、特徴量の演算方式が予め設定されている判別分析法による認証方式と比較し、CNN と RNN を用いたニューラルネットワークを用いる提案方式は、複数の中間層による演算量の増大により、特に学習時において処理時間が増大する。そのため、提案方式では入力層や中間層の削減による学習の効率化が課題となる。

今後は、登録者以外の使用者のデータを用いた提案方式のリジェクト性能を確認するとともに、身体的特徴と行動的特徴について効果を確認し、行動認識・ドライバ状態検出への応用について検討する。

## 参考文献

- [1] SAE International, "Automated Driving" <[http://www.sae.org/misc/pdfs/automated\\_driving.pdf](http://www.sae.org/misc/pdfs/automated_driving.pdf)> (参照 2017-04-04)
- [2] 紙谷一啓, et al. "圧力センサを用いた着席者の姿勢識

別に関する研究." 情報処理学会研究報告ユビキタスコンピューティングシステム (UBI) 2007.74 (2007-UBI-015) (2007): 41-46.

[3] Koshimizu, S., and A. Koizumi. "Authentication Based on Seating Pressure Distribution Using the MT System." *Editorial Board* (2013): 11.

[4] Yamada Masafumi, et al. "Soft authentication and behavior analysis using a chair with sensors attached hipprint authentication." *Pattern Analysis and Applications* 12.3 (2009): 251-260.

[5] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." *Advances in neural information processing systems*. 2012.

[6] Gers, Felix A., Jürgen Schmidhuber, and Fred Cummins. "Learning to forget: Continual prediction with LSTM." *Neural computation* 12.10 (2000): 2451-2471.

[7] 鷺見 和彦ほか, “高精度化する個人認証技術: 身体的、行動的認証からシステム開発、事例、国際標準化まで”, エヌティーエス(2014)