

令和元年度 特別研究報告書

人の動作を記録した
加速度センサ値の解析

龍谷大学 理工学部 情報メディア学科

T160400 長田幸大

指導教員 芝公仁 助教

三好力 教授

研究概要

安価で身近に存在する加速度センサを活用し、歩行時に得られる人の動作を記録した加速度センサ値の解析による個人識別の検討を行う。学習モデルは、異なる3人の被験者によって得られた加速度データから本実験で使用する機械学習手法により学習モデルを作成する。作成した学習モデルを使用し、学習に使用した被験者から再び異なるデータを10データ取得し、学習に使用した被験者以外による異なる10人の被験者から得られたデータから予測値をそれぞれ算出し、それぞれの入力データ（実測値）と、算出した予測値の散らばり度合いをユークリッド距離とマハラノビス距離の2種類の評価手法を使用し評価した。ユークリッド距離による評価では、LSTM 法とCNN 法の両手法とも最大識別率、最小識別率がほとんど変わらない識別精度を確認した。マハラノビス距離による評価では、LSTM 法では最大識別率が85%、CNN 法では70%と確認できた。しかし、ユークリッド距離による評価は、機械学習手法問わず作成した学習モデルすべてがほとんど同じ識別精度を持ち、マハラノビス距離による評価では、機械学習手法ごとと作成した学習モデルごとに識別精度が異なるため、ユークリッド距離では識別率の低さが問題点とし、マハラノビス距離では識別精度の安定性が問題点であることが分かった。

キーワード: LSTM 法, CNN 法, ユークリッド距離, マハラノビス距離

目次

研究概要.....	
1 はじめに.....	1
2. 関連技術.....	2
2.1 関連研究.....	2
2.2 既存研究.....	2
2.3 既存手法による問題点.....	3
3. 実験手順.....	5
3.1 システム構成.....	5
3.2 加速度データの取得.....	5
3.3 三軸加速度の合成とデータの送信.....	6
3.4 本手法による識別の判定調査.....	7
3.4.1 LSTM 法(Long Short-Term Memory).....	7
3.4.2 CNN 法(Convolutional Neural Network).....	8
3.5 識別評価.....	8
4. 実験.....	10
4.1 実験環境.....	10
4.2 実験内容（目的・概要）.....	10
4.3 結果.....	12
4.3.1.....	13
4.3.2.....	14
5 考察.....	16
5.1 結果からの考察.....	16
5.2 個人識別にかかる時間の短縮化.....	17

6 まとめ.....	18
謝辞.....	19
参考文献.....	20
付録.....	21

1 はじめに

近年、顔から得られる特徴を抽出し個人を特定する研究や、カメラから得られる映像・画像から歩容特徴を抽出し、個人を特定する研究など様々な個人特徴による個人識別法の研究が注目されている。その中の一つの手法として、加速度センサなどのセンサを用いて人の動作を記録したセンサデータの解析から、個人を特定する個人識別法の研究分野が存在する。本研究では、私物の盗難防止策として、歩行特徴に注目した時の人の動作を記録した加速度センサ値の解析による個人識別法の検討をする。

食事や勉強をするときにカフェや食堂を利用することがある。大抵は席を先に確保してから、席から離れたところまで注文をしに行くことが多い。席を確保するときは、店側が何かしらの確保方法を擁していない限り、私物を机に置いて確保を行うだろう。今回は席を確保する際に使用するものとして鞆(リュックサック)を想定している。カフェなど以外でも大学では席に荷物を置いて離れることが多いため、こういったシチュエーションも含め、私物から離れているときに盗難被害が相次いでいる。

本稿では、こういったシチュエーションを想定したときの盗難被害の防止対策案として、加速度センサで取得した加速度データから本人識別を行い、盗難被害の防止につながるシステムを提案する。加速度センサとは、何かしらの衝撃により発生する振動を加速度として取得することができるセンサである。加速度センサを使用した個人識別の研究は多くあり、認証手法も多く存在する。識別の際には、歩行特徴から現れる振動特性から個人を識別することが多い。そこで、提案システムでは差別化を図るために、高価で精度の高い加速度センサではなく、安価で少し精度の低い加速度センサを使用し、加速度データの取得を行った。本人識別手法は、LSTM 法(Long Short-Term Memory)と CNN 法(Convolutional Neural Network)の2種類の機械学習手法を使用し、比較実験を行った。実際に取得した加速度の時系列データを基に、ある一定の長さの時系列データ(window)から次の1データを予測することを1ステップとして予測値を算出し、本人識別を行った。ユークリッド距離による評価では、LSTM 法と CNN 法の両手法とも最大識別率、最小識別率がほとんど変わらない識別精度を確認した。マハラノビス距離による評価では、LSTM 法では最大識別率が85%、CNN 法では70%と確認できた。

本論文の構成は、2章では関連研究の詳細の説明を行う。3章では実験手順を基に、手法概要の説明を行う。4章では、実験方法や実験環境、実験概要、実験結果を説明し、5章では結果に基づいた考察を述べ、6章でまとめとする。

2. 関連技術

個人識別には様々な手法が研究されている。よく知られている手法としては顔や指紋などの個人特有の性質から個人を認証し、個人識別を行う手法がある、この章では、認証手法について述べ、その後認証手法以外の手法を採用している既存研究の概要を述べていく。

2.1 関連研究

個人識別には様々な手法が存在する。そのうちの1つとして生体情報による個人識別手法がある。生体情報による個人識別手法は、指紋認証や顔認証、静脈認証など人間の特徴から個人認証を行い、識別を行う手法が存在する。実際に指紋認証は鍵の施錠システムに導入されていたりする。顔認証も Apple 社が販売しているスマートフォンの iPhone X 以降に顔認証によるロック解除を行っている。これらの手法によって、個人識別は可能ではあるが、生体情報を認証させる必要がある。指紋認証(1)、静脈認証(2)では、指紋・静脈情報を取得しなければならないため、利用者の協力が必要不可欠となる。顔認証では、カメラで顔を認識させる必要があり、個人識別は容易には行えない。利用者に負担を負わせることなく、容易に個人の特徴を得る必要があるため、本稿の目的には不向きである。

これらの認証による個人識別法以外に、個人の歩容動作をカメラで画像や映像として得られる情報から個人認証を行う研究がされている(3)。しかし、個人の私物の防犯対策手法としては、カメラを使用した個人認証は不可能である。

2.2 既存研究

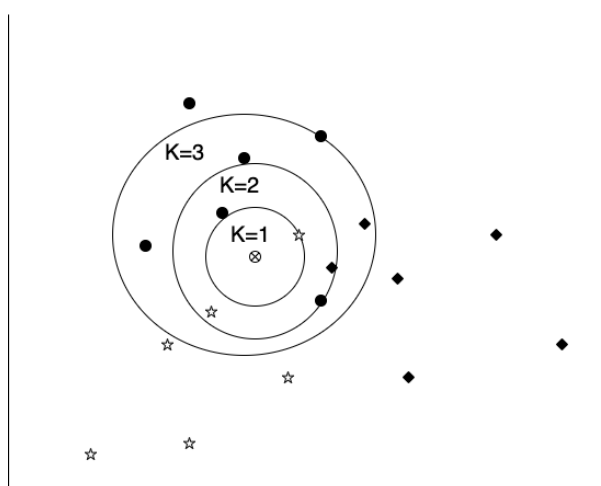


図 1, k 近傍方

認証手法による個人識別法以外にも様々な個人識別手法が研究・開発されている。その一手法として、歩行による床振動特徴を用いた個人識別手法がある(4)。バリアフリー環境を想定して木材床に設置した小型の振動センサから得られた、歩行時の床振動(歩行振動)を特徴とする個人識別方である。5人の特徴データを登録し、登録データと検証用データとのマハラノビス距離を算出し、 k 近傍方による識別を行う手法である。5人の登録データは、体重や身長、年齢など8つの特徴をデータとしている。この研究では、登録データと検証用データを照らし合わせ、データのばらつきをマハラノビス距離で算出した後に、 k 近傍方によって登録されている5人のどれかに識別される。つまり、登録されていないデータが来た場合、登録されている人のいずれかに識別されるため、未知のデータには対応していない。

登録データと検証用データのマハラノビス距離を評価する関数として、 k 近傍方を使用している。図1に k 近傍方について示す。 k 近傍方とは、クラス判別手法で学習データをベクトル空間上にプロットしておき、未知の入力データがプロットされるとそこから距離が近い順に k 個円を描き、その範囲内のデータを多数決によって即するクラスを推定する手法である。この手法のデータは、数種類の特徴をデータとするため、入力データのプロットをするためのデータの前処理が必要不可欠である。識別結果は、学習データの中のクラスのいずれかに識別されるため、が羽州データに存在しないクラスのデータを取得したとすると、学習データのクラスに識別される。つまりは、クラスが未知の場合の識別が不可能である。学習データとして登録すれば識別が可能ではあるが、その場合もデータの前処理が必要不可欠である。ネットワーク自体は、多数決によってクラス推定するといった単純な構造ではあるが、特徴とするデータが多いため、データの前処理が複雑である。

2.3 既存手法による問題点

2.1節で述べた様々な認証手法では、顔の特徴や、歩容特徴、指の指紋などの特徴を得るためには、カメラなどの機材が必要となるなど、特徴の取得方法が容易でない。本稿の目的としては、私物の防犯対策手法として、大掛かりなデータの取得は非現実的であるため、2.1節で述べた個人認証手法は最適ではない。

2.2節では、あらかじめ複数人の登録データを登録しておき、未知のデータに対してそれぞれの登録データとのマハラノビス距離を算出し、 k 近傍法によって評価し識別する個人識別法を採用している。しかし、 k 近傍法によって評価をする際に、登録データと予測値データを照らし合わせるための複雑な前処理が必要となる。それに加え、あらかじめ識別したいデータを登録データとして登録するため、登録データが所属するクラス以外の未知のデータに対しては対応できない。

本手法では、カメラを使用したり、大きいハードウェアを使用したりすることなく、加速

度センサのみで個人の歩行特徴を取得するため, 容易に特徴データを取得できる. それに加え, 全くの未知なデータに対しても識別を可能とする. そして, 学習用データをそのままの形で教師データとするため, 複雑なデータの前処理を行わない. 加速度センサにより個人の歩行時の特徴を簡単に得ることができる.

3. 実験手順

本章では, 実験手順を述べる.

3.1 システム構成

図2にシステム構成図を示す. 本実験では, 図2に示すように Wii リモコンと本手法を実施する計算機(以降, 計算機)との間に Raspberry Pi 3 Model B(以降, ラズベリーパイ)を中継器として使用する. 本実験での目的は, 歩行により得られる加速度から個人識別を行うことであるため, センサと計算機を中継するために, Wii リモコンと Bluetooth 通信を行うことができるラズベリーパイを使用した. ラズベリーパイと計算機の通信は, 有線 LAN によって通信を行う.

3.2 加速度データの取得

人は歩行時に歩行速度や, 歩幅, 足を地面につけたときに現れる振動など様々な個人の特徴が現れる. 本稿では人が歩行するときの加速度を, 加速度センサを用いて学習用データとテスト用データの取得を行った. 加速度センサは, 手ごろで安価である任天堂 Wii リモコン (RVL-001) (以降, Wii リモコン) に搭載されている加速度センサを使用した, Wii リモコンに搭載されている加速度センサは, Linux の標準デバイスモジュールである `xwiimote` モジュールを使用し, 加速度の所得のみを行える. 加速度の取得は, x , y , z の3軸で加速度を取得する.

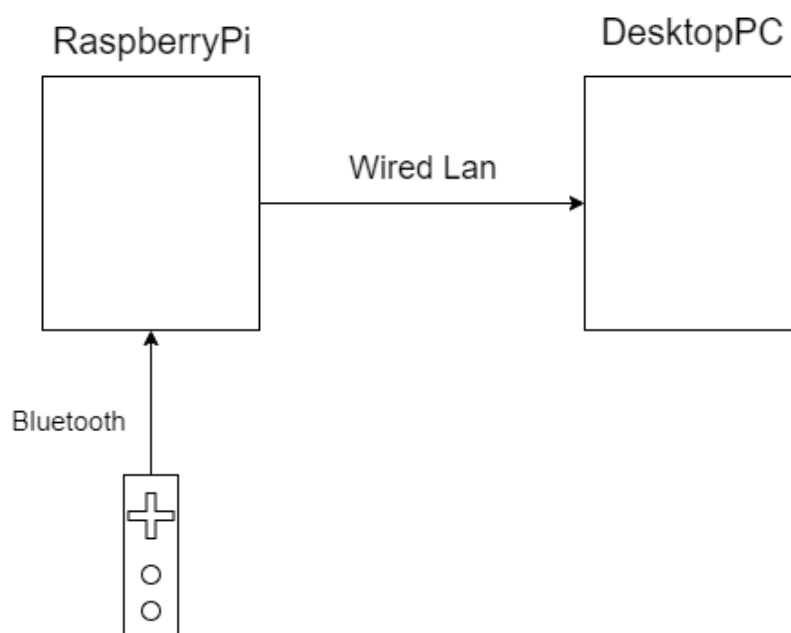


図 2, システム構成図




図3. 3軸加速度の合成

Wii リモコンで取得した加速度データは, Bluetooth 経由でラズベリーパイに送信される. ラズベリーパイと計算機は, 有線 LAN で通信を行う. 送信されたデータは, MySQL を使用し, データベース上で管理される. 管理されているデータを計算機側でインサートし, データを受け取る. MySQL の管理方法は, 三軸加速度をx, y, zそれぞれで管理する.

3.3 三軸加速度の合成とデータの送信

$$|\vec{A}| = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (1)$$

Wii リモコンの加速度センサは, 3軸で加速度を取得することができる, しかし, 3軸の多次元データをそのまま使用することは困難かつ, 複雑であるため, 3軸加速度を一つのベクトルとして合成させた1次元のデータを使用する. (1)式に合成に使用した合成式を示し, 図3に取得した3軸加速度の合成方法として使用した3次元ベクトルの合成について示す. (1)式では, x, y, z それぞれの値を2乗し, 平方根した絶対値を算出する. (1)式で得られたベクトルの大きさをデータとして扱う.

合成後の加速度データは, データの紛失を防ぐためデータベースで管理する. 管理されているデータを計算機側で取得する. つまり, データベースを通じてデータの送信




図 4, 学習の様子

を行う。

3.4 本手法による識別の判定調査

図4に, 学習の過程を示す. Raw Data は, モデルを作成するために使用するデータを指している. Predict Data は, 作成した学習モデルに, モデルを作成するために使用したデータを入力データとして入れたときの予測データを指す. 本実験で用いる手法では, window を40に設定し, 40データから次の一つのデータを予測する. これを1ステップとし, 1ステップずつ予測する.

本実験では, LSTM 法による個人識別手法と CNN 法による個人識別手法を行う. 本手法では, データの前処理行わず, そのまま教師データとして扱う. 本手法により, 学習データから学習モデルを作成し, 作成した学習モデルをもとに, 検証用データの予測値を算出する. その後, 検証用データの実測値と予測値のデータの類似度をマハラノビス距離とユークリッド距離で評価し, 識別が可能か否かを調査する. 実測値とは, 実際を取得したデータを示し, 予測値は, 学習モデルから予測値を算出した値を示す. 最終出力は, 両手法ともに1次元である.

3.4.1 LSTM 法(Long Short-Term Memory)

時系列データの機械学習手法では再帰的ニューラルネットワークである RNN (Recurrent Neural Network) がよく知られている. この機械学習手法では, 時系列データに window を設定し, window 分のデータから次の1データを予測する. これらの動作を1ステップとし, それ以降のデータをよくしていく手法である. window として扱われるデータは, $1 \cdots n$ (n は window として使用するデータ数) までのデータを使用し, $n+1$ 番目を予測したあと, 1 番目のデータを取り出し $n+1$ 番目のデータを挿入し, $n+2$ の値を予測する. RNN は長期の過去依存による学習では勾配消失問題が起き, 学習の進行が不可能になることがある. LSTM 法は RNN の長期依存を可能とした学習を行える手

法である。

3.4.2 CNN法(Convolutional Neural Network)

畳み込みニューラルネットワークであるCNN法は、一般的には、画像の識別手法として使用される。学習データから特徴を抽出していき、浮き出た特徴をプーリング層でぼやけさせて、検証データの特徴から似た特徴を検知する。回帰では、どの学習手法よりも優れている手法とされている。

3.5 識別評価

個人識別における識別の評価には、ユークリッド距離とマハラノビス距離を使用する。(2)式にユークリッド距離を算出するために使用した式を示し、(3)式にマハラノビス距離を算出するために使用した式を示す。 x_i は、実測値で、 y_i は、学習モデルから予測した予測値を表している。 μ は、使用したデータの平均値ベクトルを表し、 Σ^{-1} は、実測値と予測値の分散共分散行列を表している。 $(x_i - \mu)^T$ は、 $(x_i - \mu)$ の転移行列を表している。

$$d = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_i - y_i)^2} \quad (2)$$

$$d = \sqrt{(x_i - \mu)^T \Sigma^{-1} (x_i - \mu)} \quad (3)$$

学習データとして使用した被験者A, B, Cのデータからそれぞれ学習を行い、学習モデルを作成したのち、同一被験者のデータを10データと異なる被験者のデータを10データの予測値を学習モデルから算出し、実測値と予測値の類似度をユークリッド距離とマハラノビス距離で評価する。評価例として、図5, 図6に示す。x軸の10.5を境目とし、左側のデータを同一被験者の異なる検証用データによる評価を示し、右側を異なる被験者の検証用データによる評価を示している。

学習済みモデルの作成に使用した学習データを入力としたときに算出される予測値を閾値の設定するための基準値(以降、基準値)とし、基準値を基に閾値を設定する。評価例の図5, 図6で示しているx軸に平行な線が設定した閾値を表しており、その閾値で識別判断を行う。設定方法は、4.2節の実験内容で記す。設定した閾値によって得られる識別精度を百分率で表し、識別率として評価する。




図5, ユーグリッド距離による評価




図6, マハラノビス距離による評価

4. 実験

本章では, 実験概要について説明する.

4.1 実験環境

表 1, 計算機の環境構成

CPU	Intel core i7-7700K CPU @ 4.20GHz
Memory	4096GB
OS	Ubuntu 18.04
Wii Remote controller	RVL-001
Raspberry Pi	3 model B

表1に, 実験環境の構成を示す. 本実験では, GPU による計算は行わず, CPU のみで機械学習の計算を行った. 機械学習は, 計算のみを行うためにホストではなくゲスト(仮想マシン)で行った.

データの取得は, 大学内の研究室で行った. 測定に使用した廊下の距離は, Wii リモコンの Bluetooth の通信範囲を考慮し, ラズベリーパイから半径15m 以内の範囲で行ったため, 歩行時の移動距離は7m に設定した. 実験では, リュックサック内で Wii リモコンを固定している.

4.2 実験内容 (目的・概要)

表 2, ハイパーパラメータ

ハイパーパラメータ	LSTM 法	CNN 法
学習回数 (epoch)	400	60
Batch size	256	256
Window	40	40
学習率	0.001	0.01

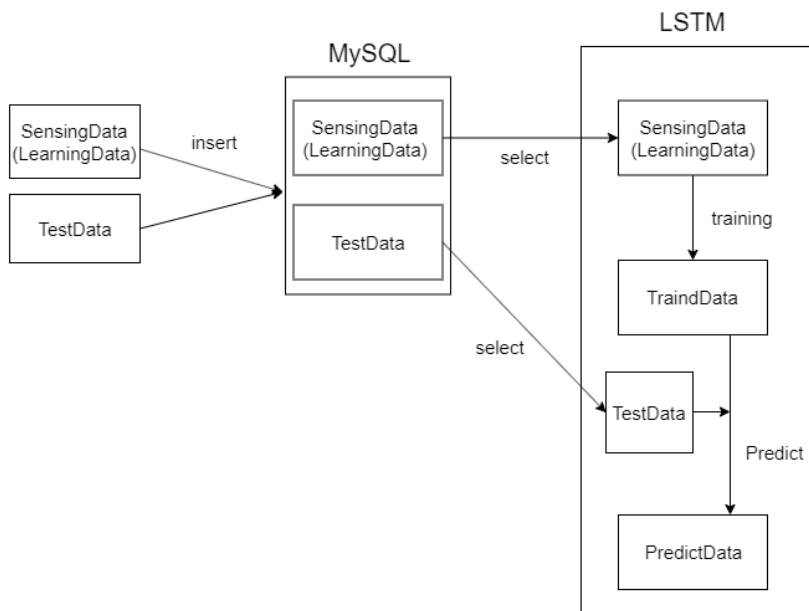


図5, システム構成図 (ソフトウェア)

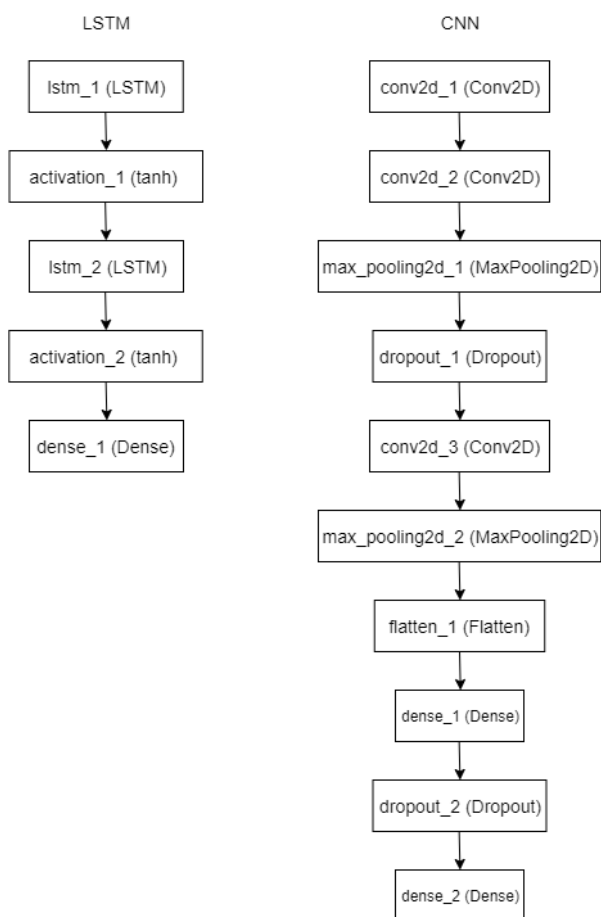


図6, LSTM法とCNN法のニューラルネットワーク構成

表2に, LSTM 法と CNN 法のニューラルネットワークのハイパーパラメータを示す. 図5に本実験で使用するシステムのソフトウェア構成図を示し, 図6に LSTM 法と CNN 法のニューラルネットワーク構成を示す.

(実験目的)

人が歩行動作を行う時, 必ず加速度が発生する. 加速度は, 歩く速度や歩幅, 体型などによって変わってくるため, 個人の特徴データとなる. 本実験では, 加速度センサを使用し, 歩行時の加速度データを取得する. 取得した加速度データを基に, LSTM 法と CNN 法の解析による識別率を確認し, 歩行特徴による個人識別法の検討をする.

(実験概要)

被験者は13人で, そのうちの3名(学習用データとして使用する被験者のそれぞれを A, B, C とする.)を学習用データとして使用し, 残りの10名を検証用データとして使用する. 学習用データとして使用する被験者には, 7m の歩行を1試行とし10試行分のデータを取得する. 検証用データとして使用する被験者には, 3試行分のデータを取得する. 検証用データとしては, 3試行分のデータの中から1データを選択し, 検証用データとして使用する. 基本的には, 最初に測定したデータを使用するが, 歩行以外の動作が入る場合があるため, そういった動作が入ったデータは使用せず, 次に測定したデータを使用することとする. 今回は, 加速度を特徴量としているため, 歩行距離のみ定義し, 歩行時にかかる時間は実験に不必要なため測定は行っていない.

識別評価は, ユーグリッド距離とマハラノビス距離を使用する. 識別時の閾値は, 基準値に対して, ユーグリッド距離では+1から+6まで加算したそれぞれの値で設定し, マハラノビス距離では+1から+3まで加算したそれぞれの値で設定する. 識別に使用するデータは, 同一被験者の異なる10データと, 異なる被験者から得られた異なる10データを使用する.

4.3 結果

LSTM 法による解析の評価結果を 4.3.1 節で説明し, CNN 法による解析の評価結果を 4.3.2 節で説明する. 表3, 4, 5, 6は, 付録に図示している結果を基に識別率をまとめている.

4.3.1 LSTM 法によるデータ解析

表 3, LSTM 法でのユーグリッド距離による識別率

閾値	A	B	C
+1	50%	50%	50%
+2	50%	50%	50%
+3	50%	50%	50%
+4	55%	50%	50%
+5	60%	50%	65%
+6	50%	50%	65%
MAX	60%	50%	65%
MIN	50%	50%	50%

表 4, LSTM 法でのマハラノビス距離による識別率

閾値	A	B	C
+1	85%	60%	60%
+2	85%	55%	60%
+3	80%	65%	60%
MAX	85%	65%	60%
MIN	80%	55%	60%

学習用データとして使用する被験者 A, B, C それぞれのデータから LSTM 法で学習した学習モデルを使用し、「同一被験者の学習に使用したデータ以外の10データの実測値と、それぞれのデータを学習モデルより算出した予測値とのデータの類似度」と、「異なる被験者の10データの実測値と、それぞれのデータを学習モデルより算出した予測値のデータの類似度」をユーグリッド距離とマハラノビス距離で評価した。表3, 表4では、ユーグリッド距離・マハラノビス距離で評価したときの識別率を示している。

表3から、ユーグリッド距離による評価の識別率は、学習モデル A, B, C いずれも場合でも、ほとんどが50%の識別率であることが確認できた。A のモデルでは、閾値が+4で設定した場合、識別率55%で、閾値が+5で設定した場合、識別率60%であることが確認できた。C の学習モデルでは、閾値が+5, +6で設定した場合、識別率65%であることが確認できた。

表4から、マハラノビス距離による評価の識別率は、学習モデル A の場合が設定したどの閾値でも80%以上の識別率が確認できた。学習モデル B, C では、学習モデル A での識別率よりは劣るが、学習モデル B の閾値を+2で設定した場合を除いて、ほ

とんどの場合で60%以上であることが確認できた。

設定した閾値での最大識別率と最小識別率を表3, 表4のMAXで最大識別率, MINで最小識別率を示している. ユーグリッド距離では, どの学習モデルにおいても精度は同じようにみられるが, マハラノビス距離では学習モデル A の場合のみ最大識別率85%で最小識別率80%が得られた.

4.3.2 CNN 法によるデータ解析

表5, CNN 法でのユーグリッド距離による識別率

閾値	A	B	C
+1	50%	50%	50%
+2	60%	50%	50%
+3	65%	50%	50%
+4	55%	55%	50%
+5	50%	50%	60%
+6	55%	50%	50%
MAX	65%	55%	60%
MIN	50%	50%	50%

表6, CNN 法でのマハラノビス距離による識別率

閾値	A	B	C
+1	60%	40%	65%
+2	65%	60%	70%
+2	65%	65%	70%
MAX	65%	65%	70%
MIN	60%	40%	65%

学習用データとして使用する被験者 A, B, C それぞれのデータから CNN 法で学習した学習モデルを使用し, 「同一被験者の学習に使用したデータ以外の10データの実測値と, それぞれのデータを学習モデルより算出した予測値との類似度」と, 「異なる被験者の10データの実測値と, それぞれのデータを学習モデルより算出した予測値の類似度」ユーグリッド距離とマハラノビス距離で評価した. 表5, 表6では, ユーグリッド距離・マハラノビス距離で評価したときの識別率を示している.

表5から, ユーグリッド距離による評価の識別率は, 学習モデル B, C の場合ほとんどが50%の識別率であることが確認できた. A の学習モデルでは, 閾値が+2, +3で

設定した場合、識別率60%以上で、閾値が+4, +6で設定した場合、識別率55%であることが確認できた。B の学習モデルでは、閾値が+4で設定した場合のみ識別率55%を確認できた。C の学習モデルでは、閾値が+5で設定した場合、識別率60%であることが確認できた。

表6から、マハラノビス距離による評価の識別率は、学習モデル A, C の場合、設定した閾値の全ての場合で60%以上の識別率が確認できた。学習モデルCでは、設定した閾値が+2, +3の場合、70%であることが確認できた。学習モデルBでは、閾値が+1で設定した場合、識別率40%が確認でき、それ以外の場合では、識別率60%以上を確認できた。

設定した閾値での最大識別率と最小識別率は、表5, 表6の MAX で最大識別率, MIN で最小識別率を示している。ユーグリッド距離では、学習モデルごとに最大識別率が異なるが、最小識別率はどの学習モデルにおいても同じであることが確認できた、マハラノビス距離では、最小識別率はどの学習モデルにおいてもほとんど同じであり、最小識別率では学習モデルBのみ40%と低い識別率が確認できた。

5 考察

5.1 結果からの考察

図7に、手法ごとの評価指標による識別率の最大識別率と最小識別率を示す。本実験で得られた識別率をみると、ユークリッド距離による評価では、どちらの学習手法においても最大識別率は65%が限界であった。それに対し、マハラノビス距離による評価では、LSTM 法を使用したときの学習モデル A で最大識別率85%を得られ、CNN 法でも学習モデル C で最大識別率70%を得られた。この点で見ると、マハラノビス距離で評価した場合の識別率が高く、個人識別が可能であると考えられる。しかし、ユークリッド距離の評価によれば、どの学習モデルでも識別精度がほとんど同じであり、それに比べマハラノビス距離による評価では、学習モデルごとに識別精度が異なっていることが確認できる。つまり、ユークリッド距離は安定して識別することができるが、マハラノビス距離では識別精度が不安定である。すなわち、安定面ではユークリッド距離による評価が望ましく、識別率ではマハラノビス距離による評価が望ましい。

安定面の問題点としては、学習パラメータの調整が不完全であることが考えられる。学習モデルごとに識別率が異なるのは、学習モデルに問題があり、正しく識別できていない可能性が考えられる。識別率の問題点としては、歩行特徴を取得するための加速度センサの精度の低さによるものだと考えられる。本実験で使用した加速度センサの精度では、個人の特徴を得られにくい可能性がある。




図7, 評価指標ごとの識別率




図 1 2, データ数ごとの平均値ベクトルの変化

5.2 個人識別にかかる時間の短縮化

図12に、マハラノビス距離を算出するときに使用する平均値ベクトルの値の変化を示す。本実験では、7mの距離の歩行で得られる加速度データを個人の特徴としている。判定フェーズは、データの取得フェーズが終了後に開始する。図12では、マハラノビス距離を算出する際に必要となる実測値と予測値の差の平均値ベクトル μ が、データ数が増えていくにつれて変化している様子をグラフで示している。平均値ベクトルがある一定の値に収束していくところがグラフで示されているが、平均値ベクトルが収束すると、それ以上のデータが得られたとしても、大きな異常値が得られなければ平均値ベクトルの値が大きく変化することはない。つまり、マハラノビス距離で評価を行う場合、平均値ベクトルが収束したときのデータ数で判定フェーズに入り識別することは、すべてのデータを取得し、得られた平均値ベクトルを基に判定フェーズに入り識別することは同じことであると考えられる。歩く速度などは個人によって異なるため、判定フェーズに入るまでの時間はそれぞれ異なるが、本実験で言えば7mの歩行をしている途中で、個人の識別が可能であるため、本人を特定するまでの時間が短縮され、素早い防犯対策が可能であると考えられる。

6 まとめ

本稿では, 安価な加速度センサを活用し, 人の動作(歩行特徴)を記録した加速度センサ値の解析による個人識別法の検討をした. 3名の被験者データ(A, B, C)で学習したそれぞれの学習モデルで, 同一被験者の異なる10データと, 異なる被験者の10データから実測値と予測値の類似度をユークリッド距離, マハラノビス距離で評価した. 算出された距離を, 基準値から異なる閾値を設定し, それぞれの閾値の場合での識別率を確認した.

識別率はマハラノビス距離による評価の場合が高い識別率を得られることが確認できた. 識別の安定面では, ユークリッド距離による評価の場合が安定して識別が可能であることが確認できた. しかしながら, ユークリッド距離による評価では, 識別率の低さに問題があり, マハラノビス距離による評価では, 安定性に問題があった.

以上のことから, 識別率の向上と安定性の向上の検討が今後の課題としてあげられる. 識別率の向上では, 本実験で使用した加速度センサよりも精度の高いセンサを使用し, 歩行特徴を取得する必要がある. 安定性の向上では, 学習パラメータの調整を改め, 識別のための学習モデルの精度を上げていく必要がある.

それに加え, 5.2 節で述べた識別時間の短縮化を考慮すると, 実際に取得した加速度データの平均値の収束点をもとめ, 識別時間の短縮化を検討する必要も考えられるため, 加速度の取得開始から識別完了までの時間の測定実験も必要とである.

今後の展望として, 識別率の向上と安定性の向上の検討をしつつ, 識別時間の短縮化を図ることが今後の課題となることが考えられる.

謝辞

本研究を行うにあたり、終始熱心なご指導とご鞭撻をいただいた三好力教授、芝公仁助教に心から感謝し致します。また、本研究に被験者としてご協力いただいた皆様に心から感謝いたします。最後に、日ごろ参考となる貴重な意見や、ご協力いただいた芝研究室及び三好研究室の皆様に感謝いたします。

参考文献

- 1) L. Zhai and Q. Hu: The Research of Double-Biometric Identification Technology Based on Finger Geometry & Palm Print, Communications in Information Science and Management Engineering, **3**-2, 100/105 (2013)
- 2) X. Meng, G. Yang, Y. Yin and R. Xiao: Finger Vein Recognition Based on Local Directional Code, Sensors, **12**-11, 14937/14952 (2012)
- 3) 村松 大吾・岩間 晴之・木村 卓弘・槇原 靖・八木 康史(2014)
「歩行映像から取得される複数特徴を用いた個人認証」
電子情報通信学会論文誌A Vol.J97-A, No.12, pp.735-748
- 4) 杉本涼輔・中島一樹(2018) 「歩行による床振動特徴を用いた個人識別」
計測自動制御学会論文集 Vol.54, No.6, 533/537

付録

以下に示す図は、実験結果によるものである。図名の model は、機械学習手法によって作成した学習モデルを指しており、modelA は、被験者 A のデータから作成した学習モデルを意味する。(以下省略)




図 1, LSTM(Mahalanobis Distance) modelA




図 2, LSTM(Euclidean Distance) modelA




図 3, LSTM(Mahalanobis Distance) modelB




図 4, LSTM(Euclidean Distance) modelB




図 5, LSTM(Mahalanobis Distance) modelC







図 6, LSTM(Euclidean Distance) modelC




7, CNN (Mahalanobis Distance) modelA




8, CNN (Euclidean Distance) modelA




9, CNN (Mahalanobis Distance) modelB



10, CNN (Euclidean Distance) modelB



11, CNN (Mahalanobis Distance) modelC



12, CNN (Euclidean Distance) modelC