

インソール型デバイスによる路面状況推定の 精度向上に向けた特徴量の検討

若林勇汰^{1,a)} 白石陽^{2,b)}

概要：近年、経路検索が可能なサービスが普及し、歩行者ナビゲーションの用途として広く使用されている。これらのサービスでは、目的地までの距離や所要時間を重視して経路を推薦しているため、推薦された経路が歩行者にとって必ずしも歩きやすいとは限らない。そのため、歩行者が歩道を快適に歩行することができないという問題がある。これらの問題に対して、歩道の路面状況を推定しその結果を歩行者に共有することで、歩行者が歩きやすい路面を選択し歩行することができる。そこで本研究では、歩道の路面状況推定を行う。路面状況ごとに足の裏にかかる圧力が異なることに着目し、インソール型デバイスによる足圧を用いた路面状況推定手法を提案する。本稿では、足圧を用いた路面状況推定の精度向上に向けて、特徴量抽出の手法の改善と特徴量の検討を行った。実験として、個人ごとの学習モデルと共通の学習モデルを構築し、それぞれの学習モデルを用いて精度評価を行った。実験結果として、個人ごとの学習モデルを用いた場合、推定対象とする路面を15歩歩くことで、9割程度で推定が可能であることを確認した。また、スライディングウィンドウを使用し、抽出した特徴量を利用することで、個人ごとの学習モデル、共通の学習モデルどちらを用いた場合でも、精度が向上することを確認した。

キーワード：足圧、路面状況推定、インソール、圧力センサ

1. はじめに

近年、Google Maps や Yahoo! Map, NAVITIME をはじめとする経路検索サービスが普及し、歩行者ナビゲーションの用途としても広く使用されている。これらのサービスでは、目的地までの距離や所要時間を重視して経路を推薦しているため、推薦された経路が歩行者にとって、必ずしも歩きやすいとは限らない。加えて、凍結や凹凸などの路面状況に関する情報を提供する機能が備わっていないため、歩行者は路面状況を加味した経路選択ができない。歩道において、凍結路面や凹凸路面など歩きにくい路面を推定し、歩行者にあらかじめ目的地までの経路上の路面状況を提示することで、歩行者は歩きやすい路面を選択することができる。これにより、歩行者は凍結路面による転倒や凹凸路面により足を挫くことなどのケガを回避することができる。したがって、本研究では、歩道の路面状況を歩行者に提示するため、歩行時の足圧データを用いた路面状況の推定手法を提案する。

歩道の路面状況のデータを収集する方法として、参加型センシングを想定している。参加型センシングとは、分散した多数の協力者が自身のスマートフォンなどに搭載されているセンサを用いて計測したデータを相互に共有する方法である[1]。参加型センシングを用いた研究として、スマートフォン搭載照度センサを用いて、街灯照度推定を行っている研究[2]や、車載スマートフォンから収集した動画を用いて、桜開花状況を共有する研究[3]、自転車に取り付けたスマートフォンで収集した自転車挙動データを用いて、

車道上の障害物を検出する研究[3]などが挙げられる。参加型センシングを用いたデータ収集は、複数の場所のデータを網羅的に収集することができるため、本研究の路面状況収集に適している。

本研究では、路面状況を推定するためのアプローチとして、足圧に注目する。ここで足圧とは、歩行時に足の裏にかかる圧力を指す。異なる路面状況の歩道を歩行すると、歩き方や歩行スピード、接地箇所が変化し、足圧に変化が生じる。例えば、砂利道を歩く時は、砂利を踏んだ箇所の足圧が不規則に変化する。凍結路面を歩く時は、転倒を恐れるため、アスファルト路面と比較して歩行スピードが変化し、それに伴い足圧も変化する。このように、足圧の違いに着目することで路面状況を推定できると考える。

本研究では、路面状況推定に使用するデータを収集するために、インソール型デバイスを開発する。インソールの複数箇所に圧力センサを装着したインソール型デバイスを用いることで、路面ごとによる足圧の変化を収集する。実際の路面を歩行し収集した足圧データから路面状況ごとの特徴を抽出し、分析することで路面状況を推定する。著者らの先行研究[5], [6]では、収集した足圧データを用いて路面状況の推定を行い、提案手法が路面状況推定に有効であること、冬季特有の路面状況においても提案手法が適用可能であることを示してきた。しかし、これまでの提案手法では、個人ごとに学習モデルを構築し路面状況の推定を行うため、学習コストがかかってしまう問題がある。そこで本稿では、少ない歩数での個人ごとの学習モデルの構築、被験者自身のデータを含まない共通の学習モデルの構築を行い、それぞれの学習モデルを用いて路面状況推定を行った。また、共通の学習モデルを用いた路面状況推定の精度向上のために、特徴量の検討を行った。

1 公立はこだて未来大学大学院 システム情報科学研究科
Graduate School of Systems Information Science, Future University Hakodate

2 公立はこだて未来大学 システム情報科学部
School of Systems Information Science, Future University Hakodate

a) g2120052@fun.ac.jp

b) siraisi@fun.ac.jp

2. 関連研究

本章では、本研究の関連研究について述べる。2.1 節では、歩道の路面状況推定に関する研究について述べる。2.2 節では、足圧を用いた研究について述べる。

2.1 歩道の路面状況推定に関する研究

加速度データを用いた路面状況推定の研究として、文献[7], [8]が挙げられる。佐藤らは、加速度と角速度の計測が可能な慣性センサを靴の甲に装着し、計測したデータに基づき路面の傾斜、路面の安定性、凹凸の有無を推定している[7]。この研究では、センサの傾きから、路面の傾斜を測定し、路面の傾斜の分散を複数の歩行者から集約することにより、路面の凹凸の有無を推定している。また、加速度の分散の大小によって路面の安定性を推定している。藤井らは、スマートフォンをポケット、カバンに入れた時の2種類の方法で収集した加速度データを用いて、平坦な路面、段差、坂道を推定している[8]。この研究では、その場所を歩いた時のステップのみではなく、前後のステップにも路面状況が影響していると考え、前後の各ステップに対応する加速度データから得られた平均や標準偏差などを含む53次元の特徴量を用いて路面状況の推定を行っている。実験結果として、平坦な路面、段差について70%以上、60%前後の精度で推定できることを示している。しかし、これらの加速度を用いた研究では、傾斜や凹凸の有無、段差といった平坦な路面と比較して歩き方が異なる路面の推定はできるが、砂利道のような平坦な路面と歩き方の変わらない路面を推定することは困難であると考えられる。

足圧を用いた路面状況推定の研究として、文献[9], [10]が挙げられる。大橋らは、足裏にかかる最大圧力を用いて接地部分の路面形状を識別する路面状況識別手法を提案している[9]。この研究では、足圧布センサを用いて足が接地していた時、各計測点における最大圧力値を選択することで、路面状況（平面、点ブロック、線ブロック）の識別を行っている。同じ歩行速度では平均0.826、異なる歩行速度では平均0.640の精度で識別できることを示している。Matthiesら[10]は、圧力センサを装着したインソールを用いて路面状況を推定している。センサ値から、砂利道や芝生、敷石、カーペット、タータンの6種類の路面状況を平均82%の精度で推定できることを示している。これらの研究により、路面状況推定に足圧を用いることが有効であることが確認できる。しかし、これらの研究では、アスファルト路面と歩き方の変わらない路面の推定はできるが、凍結路面のようなアスファルト路面と歩き方の異なる路面を推定することは困難であると考えられる。

他に、三獄らは、路面状況によって足音と慣性データが変化することに着目し、靴に装着したマイクロフォンと慣性センサを用いて、砂利道、アスファルト、水たまり、草

むら、土、泥の6種類の種類識別の実験を行い、低雑音環境下では認識精度が平均83%であることを確認している[11]。しかし、実際の歩道では、車が側方を通過した時の走行音や他の歩行者の足音によって識別精度が低くなると考えられる。

2.2 足圧を用いた研究

足圧を用いた個人識別の研究として、文献[12], [13]が挙げられる。Zhouらは、カーペット型の圧力センサシートを用いて、歩き方から個人を識別しており、76.9%の精度で識別している[12]。Sousaらは、圧力センサシートと加速度センサを用いて、個人を識別している[13]。これらの研究では、歩行における個人差や足底の変化に着目し、個人を特定している。しかし、これらの圧力センサシートは、屋内のある箇所に設置して利用するため、屋外でのデータ収集や歩道全体のデータを収集するには適さない。

足圧を用いた行動認識に関する研究として、文献[14], [15], [16], [17]が挙げられる。Hayamaらは、片足に11個の圧力センサを搭載したインソール型圧力センサを用いて足圧を測定し、圧力センサの値とフォースプレートで取得した測定値を比較することで、足圧の軌跡を推定している[14]。Gonzalezらは、日常動作における歩行に焦点を当て、足圧を測定し歩行分析を行っている[15]。Maufawadらは、IMUセンサと足圧測定インソールを用いて、座位、立位、歩行を分類している[16]。Ohnishiらは、歩行やランニング、階段の上り下りなどの22種類の日常の姿勢や動作について、足圧センサの値から認識精度を評価し、認識精度の高い最適な測定部位を検討している[17]。これらの研究では、足圧を用いて行動認識することができていることから、路面状況推定にも応用可能であると考えられる。しかし、行動の違いによる足圧の変化と比較して、路面状況による足圧の変化は小さいと考えるため、小さな変化を捉えることができる特徴量の検討を行う必要がある。

以上より、足圧はあらゆる場面で使用されていることが確認できる。これらの技術を応用し、足圧を用いた路面状況推定を行う。

3. 提案手法

本章では、本研究における提案手法について述べる。3.1 節では提案システムの全体像について述べる。3.2 節では足圧データの収集について述べる。3.3 節では特徴量抽出について述べる。3.4 節では特徴量選択について述べ、3.5 節では、学習モデルの構築方法について述べる。

3.1 提案システム

本節では、提案システムの構成について述べる。提案システムの全体像を図1に示す。提案システムは学習フェー

ズと推定フェーズから構成される。学習フェーズでは、歩行者から足圧データを収集し、足圧データから特徴量を抽出する。抽出した特徴量を正解ラベルとともに学習データとし、この学習データを用いて路面状況推定モデルを構築する。

推定フェーズでは、歩行者から収集した足圧データから学習フェーズ同様に特徴量を抽出する。抽出した特徴量と構築した路面状況推定モデルを用いて路面状況を推定する。

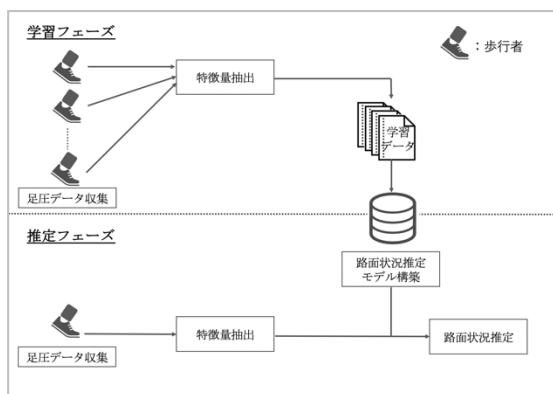


図 1 提案システムの全体像

3.2 足圧データの収集

足圧データは、開発したインソール型デバイスを用いて、対象とする路面を歩行することにより収集した。本節では、足圧データを収集するために必要となるインソール型デバイスと、推定対象とする路面について述べる。

3.2.1 インソール型デバイス

本研究では、インソール型デバイスを開発し、利用する。開発したインソール型デバイスを図 2 に示す。




図 2 インソール型デバイス

開発したインソール型デバイスは、インソールの裏側に 5 個の圧力センサを装着している。圧力センサは厚さ 0.25 ~ 1.25mm, 感圧範囲は 0.2 ~ 20N のものを使用し、各センサをジャンプワイヤーで Arduino に接続した。Arduino は 0 から 5V の入力電圧を 0 から 1023 の整数値に変換し、出力

する。この変換された整数値を本研究では、センサ値と呼ぶ。このデバイスは、センサ値が大きいほど圧力が小さく、センサ値が小さいほど圧力が大きい。1023 の時は、圧力がかからない（圧力の値が 0 である）ことを示す。

また、圧力センサの装着箇所は、つま先、母指球、付け根、小指球、かかととした。圧力センサの装着箇所について図 3 に示す。





図 3 圧力センサの装着箇所

一般的な歩行動作を考えた時、かかとから接地し、母指球、つま先という順序で接地し、路面を蹴って歩行する。加えて、日常的に使用していたインソールの擦り減っている部分が歩行時に力がかかっている部分だと考えられることから、圧力センサの装着箇所を選定している。また、文献[17]では、付け根、足の外側の部分、かかとの 3 点の足圧データを用いて日常動作を高精度に認識できることを示している。これら 5 箇所が足圧変化の大きい箇所と考えられるため、本研究における圧力センサの装着箇所として採用する。

3.2.2 路面状況推定の対象とする路面

本研究で推定対象とする路面を図 4 に示す。本研究では、アスファルト路面、凍結路面、積雪路面、圧雪路面の 4 種類を推定対象とする。積雪路面は、降雪直後の雪が積もった路面である。これらの路面状況は歩行に違いが見られると考えたため、推定対象とした。



(a)アスファルト路面 (b)凍結路面



(c)積雪路面 (d)圧雪路面

図 4 対象とする路面

3.3 特徴量の抽出

特徴量の抽出方法として、1歩分の足圧データを用いた方法とスライディングウィンドウを用いた方法の2種類を検討する。本節では、それぞれの特徴量の抽出方法について述べる。

3.3.1 1歩分の足圧データを用いた特徴量抽出

収集した足圧データから1歩分の足圧データを切り出し特徴量を抽出する。ここで1歩分とは、足が接地してから離地するまでと定義する。アスファルト路面で収集した足圧データの一例を図5に示す。縦軸はセンサ値、横軸は時系列データのサンプル番号を表す。センサ値は、圧力が大きいほど小さい値を取るため、0に近いほど圧力が大きいことを示す。




図5 アスファルト路面の足圧データ（右足）

図5から歩行時の足圧データには周期的に山と谷があることが確認できる。山の部分はセンサ値が小さく圧力がかかっているため、足が接地していることを表す。谷の部分はセンサ値が大きく圧力がかかっていないため、足が離地していることを表す。これらは歩行時の各ステップの接地と離地のサイクルと対応していると考えられることから、1つの山を1歩分のデータとして切り出す。1歩分の足圧データの切り出しは、以下の流れで行う。

- (1) Low Pass Filter によるノイズの除去
- (2) ノイズを除去したデータからの切り出し点の抽出
- (3) 切り出し点を用いて1歩分の足圧データの切り出し

(1)として、1歩分のデータを切り出すにあたり、ノイズの影響で正確に切り出すことができない場合がある。そのため、Low Pass Filter によるノイズの除去を行う。Low Pass Filter とは、特定の周波数以外の信号を遮断する機能を持つフィルタのうち、低域周波数のみを通過させるフィルタのことである。

(2)として、ノイズを除去したデータを用いて1歩分のデータの切り出し点を抽出する。切り出し点の抽出には、1歩分の足圧データの判定を行う必要がある。1歩分の足圧データの判定には、足の接地の検出が必要となる。接地の検出には、つま先またはかかとに圧力がかかっている時、

接地していると判定する。圧力がかかっているかの判定として、つま先またはかかとのセンサ値の値が800より小さく、母指球のセンサ値が600より小さい時に圧力がかかっていると判定する。判定に用いたセンサ値は、複数の値を検証し、最も切り出しに適していると考え設定する。この1歩分の足圧データの判定に基づき、ノイズを除去したデータから1歩分の足圧データの切り出し点を抽出する。

(3)として、(2)で抽出した切り出し点を用いて、ノイズ除去前の足圧データから1歩分の足圧データの切り出しを行う。この1歩分の足圧データから特徴量抽出を行った。抽出する特徴量を表1に示す。 $i/j = \{1, 2, 3, 4, 5\}$ とし、順につま先、母指球、付け根、小指球、かかると対応している。表1の特徴量は全て左足、右足のそれぞれで算出した。

表1 1歩分の足圧データから抽出した特徴量

特徴量名	説明
ave_i	各圧力センサの平均
std_dev_i	各圧力センサの標準偏差
min_i	各圧力センサの最小値
med_i	各圧力センサの中央値
$skew_i$	各圧力センサの尖度
$kurt_i$	各圧力センサの歪度
$cov_{i,j}$	2箇所の圧力センサ間の共分散
$data_count$	1歩分の足圧データのサンプル数

3.3.2 スライディングウィンドウを用いた特徴量抽出

スライディングウィンドウ（以降、SW）を用いた方法として、収集した足圧データを一定のウィンドウ幅で切り出し、切り出した足圧データから特徴量を抽出する。オーバーラップは50%として、ウィンドウごとに特徴量を抽出する。抽出する特徴量を表2に示す。 $i = \{1, 2, 3, 4, 5\}$ とし、順につま先、母指球、付け根、小指球、かかると対応している。

表2 SWを用いた特徴量

特徴量名	説明
w_ave_i	ウィンドウ内の各圧力センサの平均
w_std_i	ウィンドウ内の各圧力センサの標準偏差
$step_ave_i$	ウィンドウ内の1歩分のデータの平均
$step_std_i$	ウィンドウ内の1歩分のデータの標準偏差
$step_count$	ウィンドウ内の1歩の数

表2の w_ave_i, w_std_i はウィンドウ内の各圧力センサの平均、標準偏差を表す。各ウィンドウには複数歩分のデータが含まれているが、各1歩分のデータに対して基本統計量（平均、標準偏差、最小値、中央値、尖度、歪度）を算出し、それらの平均、標準偏差を計算したものを $step_ave_i, step_std_i$ で表す。 $step_count$ は、ウィンドウ内にある1歩分

のデータの数を表す。 w_ave_i , w_std_i は左足, 右足, 左足と右足の差のそれぞれで算出し, $step_ave_i$, $step_std_i$, $step_count$ は左足, 右足のそれぞれで算出した。左足と右足の差は, 同一ウィンドウに対する左足の足圧データから右足の足圧データを引いた差である。

3.4 特徴量選択

3.3 節では本研究で使用する特徴量の候補を挙げた。どの圧力センサが路面状況推定に有効であるかを調査するため, 5 個の圧力センサの組み合わせを変えることで, 特徴量選択を行った。つま先, 母指球, 付け根, 小指球, かかとのそれぞれの圧力センサに関する特徴量の組み合わせは, 全部で 31 通りである。31 通りの組み合わせと関係のない表 1 の $data_count$, 表 2 の $step_count$ は常に使用して学習モデルを構築した。

3.5 学習モデルの構築方法

学習モデルの構築方法として, 個人ごとの学習モデルと共通の学習モデルの 2 種類を検討している。

個人ごとの学習モデルは, 個人の足圧データを学習して構築した個人専用の学習モデルであり, 著者らの先行研究 [5], [6] では, この学習モデルを用いて高精度に路面状況推定ができることを示している。しかし, システムの実運用を考えた時, 学習モデルを構築するためには各個人が対象となる路面を歩行し, データを収集する必要がある。これにより, 歩行者が本研究でのシステムを利用しようと考えても, 路面状況を推定するまでの過程に時間がかかり利用への意欲を損なう恐れがある。

共通の学習モデルは, 被験者自身の足圧データを含まない複数人の足圧データを学習して構築した学習モデルである。被験者自身の足圧データを使用しないため, 個人ごとの学習モデルを使用した推定精度と比較すると, 推定精度が低くなることが予測される。しかし, 学習モデルを構築する必要がないため, システムの利用に時間がかからない。

4. 実験および考察

本章では, まず, 4.1 節では, 実験条件について述べる。4.2 節では, 個人ごとの学習モデルを用いた精度評価実験について述べる。4.3 節では, 共通学習モデルを用いた精度評価実験について述べる。4.4 節では実験の考察について述べる。

4.1 実験条件

実験条件を表 3 に示す。実験データとして, アスファルト路面, 凍結路面, 積雪路面, 圧雪路面の 4 種類の路面状況を対象に, 各路面につき右足で 150 歩分, 左足で 150 歩分, 合計 1200 歩分のデータを収集した。

表 3 実験条件

項目	詳細
計測場所	アスファルト路面, 凍結路面 積雪路面, 圧雪路面
被験者数	4 人
使用デバイス	インソール型デバイス
各路面のデータ収集数	1,200 歩分 = 300 歩 × 4 人 (右 150 歩, 左 150 歩)
サンプリングレート	60Hz

4.2 個人ごとの学習モデルを用いた精度評価

本節では, 個人ごとの学習モデルを用いた精度評価実験について述べる。個人モデルの学習コストの低減のため, 学習に使用するデータ数を減少させ推定精度を比較した。SVM による 10-分割交差検証を行い, F 値による評価を行った。4.2.1 項では, 1 歩分の特徴量 (表 1) を使用した路面状況推定の精度評価実験について述べる。4.2.2 項では, SW を用いた特徴量 (表 2) を使用した路面状況推定の精度評価実験について述べる。4.2.3 項では, 実験の考察について述べる。

4.2.1 1 歩分の足圧データから抽出した特徴量を使用した推定精度評価実験

実験結果を表 4 に示す。この表は, 学習に用いる歩数を 60 歩から 15 歩ずつ減少させた 4 パターンを表している。実験結果として, 学習に用いた歩数が 15 歩の場合, 被験者 B を除いて 9 割程度で推定できることを確認した。

表 4 実験結果

	被験者 A	被験者 B	被験者 C	被験者 D
60 歩	0.986	0.888	0.941	0.953
45 歩	0.980	0.882	0.927	0.947
30 歩	0.968	0.869	0.921	0.934
15 歩	0.938	0.832	0.895	0.912

4.2.2 SW を用いた特徴量を使用した推定精度評価実験

実験結果を表 5 に示す。実験結果として, 表 5 より SW を用いた特徴量を使用した場合, 学習に用いた歩数が 15 歩の場合, 9 割を超える精度で推定できることを確認した。

表 5 SW を用いた特徴量を使用した実験結果

	被験者 A	被験者 B	被験者 C	被験者 D
60 歩	0.998	0.991	0.993	0.989
45 歩	0.997	0.989	0.988	0.987
30 歩	0.997	0.984	0.986	0.971
15 歩	0.994	0.962	0.973	0.956

4.2.3 考察

学習データとして15歩分の足圧データを用いることで、1歩分の特徴量(表1)を使用した場合は9割前後、SWを用いた特徴量(表2)を使用した場合は9割を超える精度で推定できることを確認した。この理由として、個人の歩行動作は歩数に関わらずあまり変化しないことが考えられる。路面状況の変化によって歩行スピードや歩行動作が変化することはあるが、疲労や体重の大幅な増減などの影響がない限り、個人ごとの歩行動作は変化しない。よって、少ない歩数でも高い精度で推定できたと考える。

4.3 共通の学習モデルを用いた精度評価

実験では、被験者4人の路面状況ごとの足圧データを用いて、SVMによるLeave One Person Out交差検証を行い、F値による評価を行った。Leave One Person Out交差検証とは、各被験者をテストデータとする方法である。この方法を使用して学習データを作成することで、個人に依存しない共通の学習モデルを作成することができる。しかし、学習に被験者自身のデータを使用しないため、個人ごとの学習モデルを使用する場合と比較して推定精度は低下することが予測される。そこで、3.4節の特徴量を用いることで、共通の学習モデルに適した特徴量の組み合わせを調査する。4.3.1項では、共通の学習モデルを用いた精度評価実験について述べる。4.3.2項では、実験の考察について述べる。

4.3.1 精度評価実験

3.4節で述べた組み合わせ31通りそれぞれにおけるF値を比較し、全ての圧力センサを使用した組み合わせとF値が0.450以上となった組み合わせの結果を表6に示す。また、全ての組み合わせの中で最も精度の高かったSWを用いた特徴量を使用したつま先、かかとの組み合わせについて、被験者別の精度を表7に示す。SWのウィンドウ幅は300とした。

表6 各組み合わせの推定精度

	1歩分	SW
つま先	0.418	0.544
つま先, 付け根	0.401	0.466
つま先, 小指球	0.362	0.524
つま先, かかと	0.398	0.592
つま先, 母指球, 付け根	0.473	0.425
つま先, 付け根, 小指球	0.419	0.473
つま先, 付け根, かかと	0.373	0.490
つま先, 母指球, 付け根, 小指球, かかと	0.407	0.418

表7 つま先とかかとの特徴量を使用した実験結果


学習データ	テストデータ	F値
被験者 B, C, D	被験者 A	0.811
被験者 A, C, D	被験者 B	0.345
被験者 A, B, D	被験者 C	0.610
被験者 A, B, C	被験者 D	0.603
平均		0.592

表6の結果から、1歩分の足圧データから抽出した特徴量を使用した場合、つま先、母指球、付け根の組み合わせの時、F値が0.473と最も高い精度となった。加えて、SWを用いた特徴量を使用した場合は、つま先、かかとの組み合わせの時、F値が0.592と最も高い精度となった。また、全体的に1歩分の足圧データから抽出した特徴量を使用したF値と比較して、SWを用いた特徴量を使用したF値の方が高い傾向にあることが確認できる。


表7の結果から、各被験者の路面状況推定の精度は、被験者Aが最も高い0.811となり、被験者Bが最も高い0.345となった。

4.3.2 考察

個人の学習モデルを使用した実験結果(表4,5)と比較して、精度が0.3~0.4低下した。推定精度が著しく低下した理由として、個人差が影響していると考えられる。個人差が大きく見られた路面として、被験者A, Bの凍結路面で収集した足圧データの一例を図6に示す。



被験者 A



被験者 B

図6 凍結路面の足圧データ(右足)

被験者Aと被験者Bのデータを比較してみると、同じ路面状況でも足圧のかかり方に違いがあることが確認できる。

他の被験者も同様で、同じ路面状況でも個人によって歩き方は変化し、それに伴い足圧も変化する。そのため、同じ路面であっても異なる特徴が抽出されたと考える。また、個人によって、身長や体重、足を上げる高さ、また出身地による歩き方の違いなども推定精度に影響すると考える。

また、表 7 の結果から被験者 B の推定精度が他の被験者と比較し、著しく低いことが確認できる。被験者 B の推定精度が低い理由として、被験者 B の歩き方が今回の被験者の中では、例外であったことが考えられる。図 6 から、被験者 A と被験者 B の歩行周期は異なり、足圧データの類似度が小さいことが確認できる。このように、足圧データの類似度が小さいと精度は低下すると考える。足圧データの類似度によって共通の学習モデルを用いた路面状況推定の精度は上下するため、共通の学習モデルを用いた路面状況推定の精度向上には、足圧データの類似度が近いデータを使用する必要がある。

4.4 考察

4.2, 4.3 節の結果から、1 歩分の特徴量 (表 1) を使用した推定精度と比較して、SW を用いた特徴量 (表 2) を使用した推定精度の方が高い傾向にあることが確認できる。このことから、SW を用いた特徴量は足圧を用いた路面状況推定に有効であることが示唆された。SW を用いた特徴量を使用した場合の方が精度が高くなった理由として、複数歩の特徴量を使用していることが考えられる。1 歩分の特徴量では、1 歩分の範囲内でしか特徴量を抽出できない。しかし、SW を用いることで、ウィンドウ内の複数歩を比較することや、離地している間の特徴量も抽出することができるため、精度が高くなったと考える。

5. まとめ

本研究の目的は、歩道の路面状況を歩行者に提示するため、歩行時の足圧データを用いて路面状況を推定することである。本稿では、路面状況推定の精度向上に向けて、特徴量抽出手法の改善と特徴量の検討を行った。実験では、アスファルト路面、凍結路面、積雪路面、圧雪路面の 4 種類の路面状況を対象に、個人ごとの学習モデルと共通の学習モデルを構築し、それぞれの学習モデルを用いて精度評価を行った。その結果、個人ごとの学習モデルを使用した場合、各路面を 15 歩歩くことで、9 割程度の推定が可能であることを確認した。また、個人ごとの学習モデル、共通の学習モデルのどちらを使用した場合でも、1 歩分の足圧データから抽出した特徴量を使用した推定精度と比較して、スライディングウィンドウを用いた特徴量を使用した推定の方が高い精度となった。このことから、スライディングウィンドウを用いた特徴量が足圧を用いた路面状況推定に有効であると示唆された。

今後の課題として、被験者とデータ数を増やし、同様の結果が得られるかを確認する。また、共通の学習モデルを用いた路面状況推定では、推定精度向上のため、足圧データの類似度により被験者をグルーピングし、精度評価を行うことを検討している。

謝辞 本研究の一部は JSPS 科研費 JP20K11793 の助成を受けたものである。

参考文献

- [1] Burke, J., Estrin, D., Hansen, M., Parker, A., Nithya, R., Rebbly, S and Srivastava, M.: Participatory Sensing, Workshop on World-Sensor-Web (WSW): Mobile Device Centric Sensor Networks and Applications, pp1-6 (2006).
- [2] 松田裕貴, 新井イスマイル: スマートフォン搭載照度センサの集合知による網羅的な街灯情報収集システムの開発, 情報処理学会論文誌, Vol.55, No.2, pp.750-760 (2014).
- [3] 前中省吾, 森下慈也, 永田大地, 玉井森彦, 安本慶一, 福倉寿信, 佐藤啓太: 桜センサ: 車載スマートフォンを用いた桜開花状況の収集・共有システム, 情報処理学会論文集, Vol.57, No.2, pp.629-642 (2016).
- [4] 武安裕輔, 白石陽, 自転車道の障害物回避挙動検出における異常検知に基づく障害物回避区間の抽出手法の検討, 情報処理学会第 26 回マルチメディア通信と分散処理ワークショップ論文集, pp.108-116 (2018).
- [5] 若林勇汰, 白石陽: 足圧センサ付きインソールを用いた路面状況推定手法の提案と評価, 情報処理学会マルチメディア, 分散, 協調とモバイルシンポジウム 2020 論文集, Vol.2020, pp.338-345 (2020).
- [6] 若林勇汰, 白石陽: インソール型デバイスによる路面状況推定手法の冬季環境への適用, 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), Vol.2021-UBI-69, No.30, pp.1-7 (2021).
- [7] 佐藤匠, 廣森聡仁, 山口弘純, 東野輝夫: 靴型ウェアラブルセンサによる通行路状況推定手法の提案, 情報処理学会研究報告 コンシューマ・デバイス & システム (CDS), Vol.2015-CDS-12, No.9, pp.1-8 (2015).
- [8] 藤井海斗, 羽田野真由美, 西田京介, 戸田浩之, 澤田宏, 鹿島久嗣: 歩行者クラウドセンシングによる路面状況の推定, DEIM Forum 2016, D6-5 (2016).
- [9] 大橋勇介, 榎堀優, 間瀬健二: 歩行時の最大圧選択足圧データを用いた路面コンテキストの識別, 情報処理学会研究報告 ヒューマンコンピュータインタラクション (HCI), Vol.2014-HCI-160, pp.1-8 (2014).
- [10] Matthies, D. J. C., Roumen, T., Kuijper, A. and Urban, B.: CapSoles: Who is Walking on What Kind of Floor?, Proc. 19th International Conference on Human-Computer Interaction with Mobile Devices and Services (MobileHCI), No.9, pp.1-14 (2017).
- [11] 三嶽寛人, 渡邊拓貴, 杉本雅則: 足音と慣性データに基づく路面状況認識手法, 情報処理学会論文誌, Vol.61, No.10, pp.1578-1590 (2020).
- [12] Zhou, B., Singh, M., Doda, S., Yildirim, M., Cheng, J. and Lukowicz, P.: The Carpet Knows: Identifying People in a Smart Environment from a Single Step, Proc. 1st International Workshop on Pervasive Smart Living Spaces 2017 (PerLS2017), pp.527-532 (2017).
- [13] Sousa, M., Techmer, A., Steinhage, A., Lauterbach, C. and Lukowicz, P.: Human Tracking and Identification Using a Sensitive Floor and Wearable Accelerometers, Proc. 2013 IEEE International Conference on Pervasive Computing and Communications (PerCom), pp.166-171 (2013).

- [14]葉山浩樹, 福田博也: インソール型フォースセンサによる足圧中心軌跡の推定, 生体医工学, Vol.54, No.1, pp.15-21 (2016).
- [15]Gonzalez, I., Fontecha, J., Hervas, R. and Bravo, J.: An Ambulatory System for Gait Monitoring Based on Wireless Sensorized Insoles, Journal of Sensors, Vol.15, pp.16589–16613 (2015).
- [16]Moufawad El Achkar, C., Lenoble-Hoskovec, C., Paraschiv-Ionescu, A., Major, K., Bu'la, C. and Aminian, K.: Physical Behavior in Older Persons during Daily Life: Insights from Instrumented Shoes, Journal of Sensors, Vol.16, No.8, pp.1225–1243 (Aug. 2016).
- [17]Ohnishi, A., Tsutomu, T., Tsukamoto, M.: A Method for Recognizing Postures and Gestures Using Foot Pressure Sensors, Journal of Information Processing, Vol.27, pp348-358 (2019).