情報処理学会論文誌 Vol.61 No.10 1578–1590 (Oct. 2020)

足音と慣性データに基づく路面状況認識手法

三嶽 寛人[1,a)] 渡邉 拓貴[1,b)] 杉本 雅則[1,c)]

受付日 2019年12月24日, 採録日 2020年7月7日

概要：季節や天候によって路面状況が大きく変化する地域では，路面状況が悪いと転倒等の危険が生じる．路面状況を事前に把握できれば，安全なルートと適切な靴を選択することで危険を回避できる．本研究では，乾燥した舗装，水たまり，土，泥等の路面状況に応じて変化する足音と慣性データに着目し，足音と慣性データを用いた路面状況認識手法を提案する．プロトタイプを実装し，8 人の被検者に対して，6 つの路面状況下で提案手法を評価した．低雑音環境下では，提案手法の認識精度が 83.0%であることを確認した．雑音環境下の場合，足音と慣性データを組み合わせた標準手法と，信号対雑音比（SNR）により足音認識結果の信頼性を変更する改善手法を比較した．評価実験の結果，車の走行音や他人の足音が混入した場合では，改善手法を用いてすべての SNR 環境下の認識精度の改善を確認した．

キーワード：足音，路面状況認識，機械学習，ウェアラブルコンピューティング

A Method for Recognizing Road Surface Condition based on Footsteps and Inertial Data

Hiroto Mitake[1,a)] Hiroki Watanabe[1,b)] Masanori Sugimoto[1,c)]

Received: December 24, 2019, Accepted: July 7, 2020

Abstract: In areas where the road surface conditions change significantly with the seasons and weather, bad road surface conditions cause dangerous such as falls. If the road surface condition can be determined in advance, danger can be averted by selecting safe routes and suitable shoes. In this study, we focus on the footsteps and inertial data that change depending on road surface conditions, such as dry pavement, puddle, soil, and mud, and propose a method for recognizing road surface conditions using footsteps and inertial data. We implemented the prototype device and evaluated the proposed method on six road surface conditions with eight participants. The evaluation results confirmed that the recognition accuracy was 83.0% in a low-noise environment. When there was noise, we compared the standard method, which combines footsteps and inertial data, and the revised method, which changes the confidence of the result of footstep recognition by the signal-noise ratio (SNR). The evaluation results confirmed that when the driving sounds of cars or the footstep of the other person were mixed, the recognition accuracy was improved in all SNR environments using the revised method.

Keywords: footstep, road surface condition recognition, machine learning, wearable computing

1. はじめに

雪が多く降る地域では，降雪による足場の悪さや路面の凍結による影響で事故が多く，問題となっている [26]．また，夏場では，雨による影響で土がぬかるみ，転倒の危険性が高まる．一方，近年のセンサの小型化により．ウェアラブル・ユビキタスコンピューティング技術が大きく発展した．最近では，靴にセンサを搭載し，人の足の動き等の情報を取得可能なスマートシューズが開発されている [5], [12], [13]．これらは自動で靴ひも調整を行ったり，スマートフォン等の端末と通信し，運動解析や地図アプリケーションと連動して行先の道案内を行うことができる．このようなスマートシューズを用いれば，転倒事故の抑制

[1] 北海道大学大学院情報科学研究院
Faculty of Information Science and Technology, Hokkaido University, Sapporo, Hokkaido 060–0814, Japan
[a)] mitake@ist.hokudai.ac.jp
[b)] hiroki.watanabe@ist.hokudai.ac.jp
[c)] sugi@ist.hokudai.ac.jp

© 2020 Information Processing Society of Japan

も可能であると考えられる．具体的には，靴に搭載されたセンサから，雪道や泥等の歩行した路面状況を認識し，スマートフォン内の地図アプリケーションに反映する．多数の人の歩行により得られた路面情報を地図に反映させ，ユーザが路面状況を把握し，道順の確認や靴の選定といった事前の対策を行うことで事故抑制につながると考える．そのためには，路面の状況を認識できる技術が重要となる．路面状況の認識手法では，慣性センサを用いた手法 [19] や画像解析による手法 [3], [14], [18] が考えられる．しかし，前者では，路面の傾斜角や路面の安定性は認識可能だが，路面の種類の識別までは考慮されていない．後者では，悪天候時や夜間等での利用は困難である．また，路面状況の画像を取得する際の歩行時のカメラの利用は，プライバシの影響が懸念される．

本研究では，路面状況によって足音が変化することに着目し，足音を用いた路面状況認識手法を提案する．靴に搭載したマイクロフォンを用いて足音を取得，解析することで路面状況を認識する．先行研究では，足音に関する研究は路面認識以外で利用されており，足音がどの程度路面認識に有効なのかは分かっていない [20], [24]．そのため，提案手法の有効性を判断する指標として，慣性センサを用いた路面認識システムも実装した．雑音が少ない環境下で評価実験を行い，慣性データ，足音データ，およびそれらを組み合わせた認識精度がそれぞれ 53.4%，74.8%，83.0%となり，両データを組み合わせることで認識精度の向上を確認した．また，未知のユーザデータが得られたときの分類モデルの汎用性も検証し，平均で 82.1%の認識精度であることを確認した．さらに，雑音の大きさによって足音データの分類結果の重みづけを変化させる改善手法を提案した．音声データに雑音が混入したときのシミュレーション実験を行い，車の走行音や他人の足音が雑音として含まれる場合では，すべての SNR 環境下にて認識精度の改善を確認した．本研究の貢献内容を以下にまとめる．

(1) 足音と慣性データを組み合わせた路面状況認識手法を提案した．
(2) 低雑音環境下の場合，83.0%の認識精度が得られた．
(3) 雑音環境下では，音声データに含まれる雑音の大きさによって足音データの優先度を変更する改善手法を提案した．車の走行音や他人の足音が混入した場合では，すべての SNR 環境下で認識精度が改善した．

なお，本論文は文献 [11] で発表した内容に雑音の種類，靴の種類の影響に対する考察を加えて発展させ，全体的に補完を行ったものである．以降，2 章で本研究に関連する研究について述べ，3 章で提案手法について述べ，4 章で実装を紹介する．5 章で評価実験について示し，6 章で想定アプリケーションについて述べ，7 章で考察を行う．最後に 8 章で結論を述べる．

2. 関連研究

2.1 路面認識に関する研究

路面の安定性や種類，物体の材質を認識する研究は多く行われている．特に，カメラを利用した画像認識ベースでの研究が行われている [3], [14], [18]．いずれの手法も，晴天時や昼間等の明るい時間帯といった理想環境下では認識精度が高い．しかし，悪天候や夜間等の時間帯での利用を考えると，カメラで撮影した画像にノイズ（雑音）が多く混じるため，認識精度が低下する可能性が考えられる．また，ウェアラブル環境でのカメラの利用はプライバシの問題も考えられる．そのため，これらの手法を用いる場合は使用期間や環境が限られる場面が多い．また，Cho らの研究 [3] では，スマートフォンベースでの利用を想定している．したがって，使用時はつねにスマートフォンを手に持って歩行する必要があり，転倒時の危険性が考えられる．

Matthies らは靴のソールに静電容量センサを搭載し，誰がどの路面を歩いているかを認識する手法を提案した [10]．センサ値の変化から，靴底にかかる圧力や路面に含む水分値を推定することで路面の認識を行った．土や芝生，舗装道路等，計 6 種類の路面を 11 人の被験者の歩行データに対して認識を行い，平均で 82.46%の認識精度となった．また，乾燥した路面と濡れた路面に対してセンサ値に大きな違いがあることを示し，水分量を考慮して路面状況を認識できる可能性も示した．しかし，この研究では，ユーザごとに分類器を作成して路面の認識を行っている．これは，圧力センサから得られるデータは路面の特徴よりも個人の特徴を多く含んでいるためだと考えられる．したがって，一般分類器による路面認識は困難だと考えられる．

Satoh らは，靴のつま先部分に慣性センサを搭載し，路面状況を推定する手法を提案した [19]．慣性センサから得られた値の変化量に着目し，路面の傾斜角や状態を推定できることを示した．また，Nomura らはスマートフォン内蔵加速度センサを用いて，車での走行中における路面推定手法を提案した [15]．車内にスマートフォンを設置し，センサから得られるデータの分散を利用して路面状況を推定できることを示した．しかし，いずれの研究でも，路面の安定性は認識可能だが，路面の種類の識別までは考慮されていない．以上より，本研究では，使用可能な時間帯が制限されず，路面の種類によって聞こえ方が変化する足音に着目して路面状況認識を行う．

2.2 歩行に関する研究

人の歩行データを利用した研究は多く行われている．Kim らは，歩行時におけるスマートフォンから得られるセンサデータを用いた危険推定システムの提案を行った [8]．Pan らは，歩行する際に発生する振動を利用した屋内歩行者識別システムを提案した [16]．足音による振動を検知す

© 2020 Information Processing Society of Japan

るセンサを床に設置し，振動信号の特徴から歩行者認識を行った．Wang らは，人による歩行時間間隔の違いを利用した個人認証手法を提案した [24]．人の歩行時間間隔は履物や路面の種類でほとんど変化がないことに着目し，歩行時間間隔を特徴とした歩行者認識を行った．また，人々の日常生活のサポートシステムを想定した研究も行われている．Hassan らは，電気筋肉刺激（EMS：Electrical Muscles Stimulation）デバイスと力検出抵抗器を備えたインソールからなるウェアラブルランニングアシスタントシステムを提案した [7]．ランニングでは，主に地面と踵が強くぶつかるために膝に大きな負担がかかる．そこで，ユーザのランニングパターンを検知し，EMS を介してリアルタイムフィードバックを提供することで，足に衝撃がかかりにくい運動学習プロセスを与えられる可能性を示した．その他にも，音響ドップラー効果を用いた歩行者トラッキングの研究 [2] や，歩行中に発生する音のスペクトルをリアルタイムで変更し，人の感情等を変化させる研究 [20] も行われている．しかし，足音を利用した路面認識に関する研究は我々の知る限り行われておらず，足音が路面認識にどの程度有効であるのか明らかになっていない．本研究では，足音と足音以外で路面認識に利用される手法を組み合わせた提案手法が，路面認識にどの程度有効であるのか検証を行った．

3.　提案手法

システム構成を**図 1** に示す．両足の靴にマイクロフォンと慣性センサを装着し，両足のマイクロフォンからの入力はボイスレコーダのステレオ録音で記録する．慣性センサは Bluetooth で解析用 PC へデータを送信し記録する．データ処理の流れを**図 2** に示す．まず，靴に搭載されたマイクロフォンと慣性センサでデータをそれぞれ取得する（図 2 a）．次に，取得したデータに対して前処理を行う（図 2 b）．その後，前処理を行ったデータから特徴量を抽出し，分類モデルの学習を行う（図 2 c）．最後に，構築した分類モデルを用いて認識を行う（図 2 d）．なお，音声データと慣性データは，事前動作で時刻同期を行っている．

3.1　慣性データの処理

3.1.1　前処理

文献 [19] で定義された，靴と路面が接地している時（接地状態時）のデータを抽出する．本研究では，接地状態時に慣性センサから得られる角速度の大きさが小さくなることを利用して，接地状態時のデータ抽出を行った．時刻 t における X，Y，Z 軸の角速度をそれぞれ $\omega_{x,t}$，$\omega_{y,t}$，$\omega_{z,t}$ とすると，角速度の大きさは以下の式で表される．

$$\boldsymbol{\omega_t} = \sqrt{\omega_{x,t}^2 + \omega_{y,t}^2 + \omega_{z,t}^2} \tag{1}$$

しかし，慣性センサから得られるデータは必ずしも安定しているとは限らない．そこで，n 点移動平均法を利用し，慣性センサから得られる値を平滑化する．本研究では，式 (2) で表される，n が奇数時の n 点移動平均法を使用する．本研究では，$n = 15$ として角速度の平滑化を行った．$\boldsymbol{\omega_t}$ は時刻 t における角速度値で，$\boldsymbol{\omega_{t'}}$ は時刻 t' における n 個分の角速度値を用いて移動平均した値である．また，h は慣性センサのサンプリング周期である．

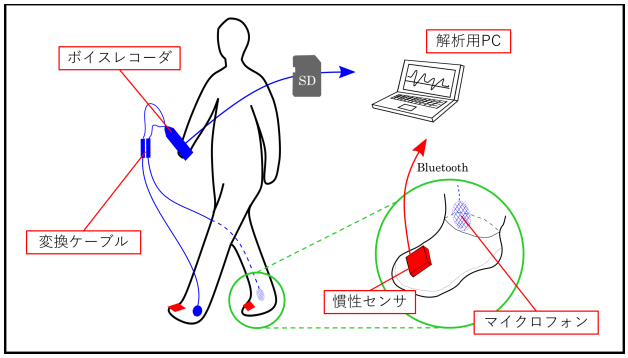

図 1　システム構成
Fig. 1　System configuration.

$$\boldsymbol{\omega_{t'}} = \frac{1}{n} \sum_{t=t'-\frac{n-1}{2}h}^{t'+\frac{n-1}{2}h} \boldsymbol{\omega_t} \tag{2}$$

3.1.2　特徴量抽出

本研究では，慣性センサから得られる加速度値を利用し特徴量を抽出する．接地状態時検出と同様に，n 点移動平均法による平滑化処理後に特徴量を抽出する．本研究では，$n = 5$ として加速度の平滑化を行った．また，慣性センサの装着誤差を考慮し，慣性データは歩行前の静止状態時との差分値を使用した．本研究で使用する慣性データと抽出する特徴量を**表 1** にまとめた．使用する慣性データは，平滑化した X，Y，Z 軸の加速度値，加速度の大きさ，慣性センサの X，Y 軸の傾きの計 6 種類である．これらの慣性データから，最大値と最小値の差（レンジ），平均，分散，標準偏差，第一四分位数，中央値，第三四分位数の 7 種類を算出し，計 42 次元の特徴量を抽出する．なお，加速度の大きさは以下の式で定義した．$a_{x,t}$，$a_{y,t}$，$a_{z,t}$ は，それぞれ時刻 t における X，Y，Z 軸の加速度である．

$$\boldsymbol{a_t} = \sqrt{a_{x,t}^2 + a_{y,t}^2 + a_{z,t}^2} \tag{3}$$

また，慣性センサの傾きは，文献 [19] で提案された手法を用いて算出した．この手法では，接地状態時のデータを利用して慣性センサの傾きを求める．慣性センサの X 軸の正の向きを人体の前方，Y 軸の正の向きを側方左側，Z 軸の正の向きを鉛直上向きとなるよう設定することで，人体前方への傾斜と側方への傾斜を求められる．慣性センサが X 軸と Y 軸方向にそれぞれ θ 度，ψ 度傾いているとき，慣性センサの傾きは以下の式で表される．a_x，a_y，a_z はそれぞれ X，Y，Z 軸の加速度である．

© 2020 Information Processing Society of Japan

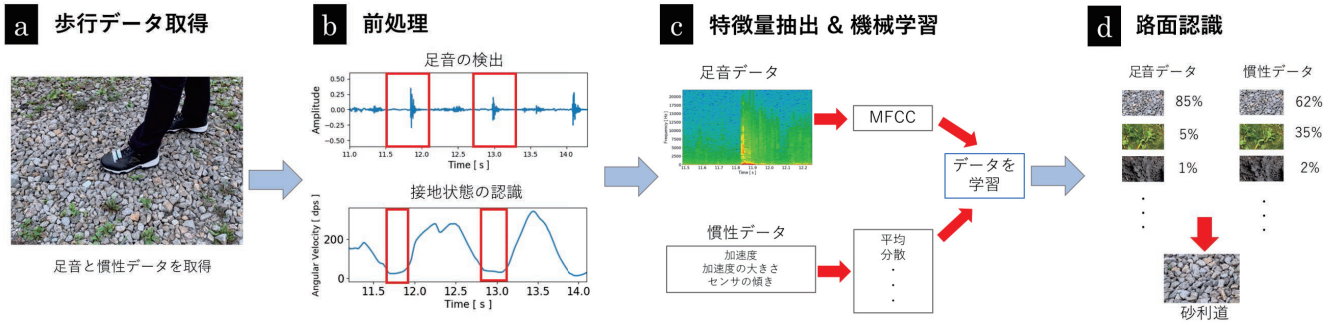

図 2　路面状況認識の全体プロセス
Fig. 2　The overall process for recognizing road surface conditions.

表 1　使用した慣性データと算出した基本統計量
Table 1　Used inertial data and calculated summary statistics.

慣性データ	基本統計量
平滑化した X 軸の加速度	レンジ
平滑化した Y 軸の加速度	平均
平滑化した Z 軸の加速度	分散
平滑化した加速度の大きさ	標準偏差
慣性センサの X 軸における傾き	第一四分位数
慣性センサの Y 軸における傾き	中央値
	第三四分位数

$$\theta = \tan^{-1}\left(\frac{a_x}{\sqrt{a_y^2 + a_z^2}}\right) \tag{4}$$

$$\psi = \tan^{-1}\left(\frac{a_y}{\sqrt{a_x^2 + a_z^2}}\right) \tag{5}$$

3.2　足音データの処理

3.2.1　前処理

スペクトルサブトラクション（SS：Spectral Subtraction）法を用いて背景雑音除去を行い，音声データから足音データを抽出する．一般的に，歩行時の足の動きには，以下の 4 つの状態が存在する．歩行は（W1)–(W4）の状態を段階的に経て行われる．

（W1）踵のみが路面に接している状態（足音開始時刻）
（W2）靴底全体が路面に付いている状態（接地状態）
（W3）つま先のみが路面と接している状態
（W4）靴が地面から離れている状態

足音は（W1）の状態が起きる瞬間，靴の踵部分と地面が激しく衝突することでインパルス状の大きな音を発生し，（W2）後は大きなパワーをもつ信号は発生しない性質を持っている．この性質を利用して足音の検出を行う手法が提案されている [21], [22]．しかし，検出率の低さや [21]，屋内環境に限られている [22] という点で，本研究での利用には適合しないと考えられる．そこで，本研究では（W2）の状態が認識可能な慣性データを用いて足音の検出を行った．具体的には，我々が先行研究 [27] で提案した，角速度センサを用いて接地状態を認識する手法を用いた．この手法では，6 路面に対して平均 0.3%の未検出・誤検出率で接地状態を検出可能である．検出した（W2）の状態が t_s から t_e まで続くとき，t_s の直前に足音開始時刻が存在すると考えられる．したがって，$(t_s - \alpha) \leq t \leq t_e$（$\alpha$ は 0 よりも大きい定数）の範囲に足音開始時刻が含まれると考え，この範囲の音声データを足音データとして抽出した．本研究では，α は 0.2 s に設定した．

3.2.2　特徴量抽出

屋外環境では，路面状況によって足音の聞こえ方が変化する．**図 3** は同じ被験者が異なる路面を歩行したときのスペクトログラムである．足音開始地点付近での周波数分布が路面ごとに異なっていることが分かる．したがって，本研究ではこれらの周波数情報を路面状況認識に利用した．足音の特徴量にはメル周波数ケプストラム係数（MFCC：Mel-Frequency Cepstrum Coefficients）を使用した．本研究では 20 次までの係数を利用した．ただし，MFCC の 0 次の係数は直流成分で波形の特徴を表していないため，使用する MFCC は 1 次から 20 次の 20 個の係数とし，メルフィルタバンクのチャネル数は 25 とした．

以上より，慣性データから抽出した 42 次元の特徴量と，音声データから抽出した 20 次元の特徴量を用いて分類モデルを作成した．本研究では分類モデルにサポートベクタマシン（SVM：Support Vector Machine）を使用した．

4.　実装

提案手法を評価するためにプロトタイプを実装した．慣性センサは小型無線多機能センサ TSND121（ATR-Promotions）を，マイクロフォンは AT9901（オーディオテクニカ，周波数特性：100 Hz–17 kHz）を使用した．また，ボイスレコーダはリニア PCM レコーダ DR-05（TASCAM）を用いた．本研究では，路面状況によって変化する足音と慣性データを用いた路面状況認識の可能性の調査に着目したため，靴の種類による影響でデータに変化が起きないよう，被験者の靴は 1 種類に限定した．靴の種類の影響は 7.3 節で議論を行う．本研究では，KP STM クレア

© 2020 Information Processing Society of Japan

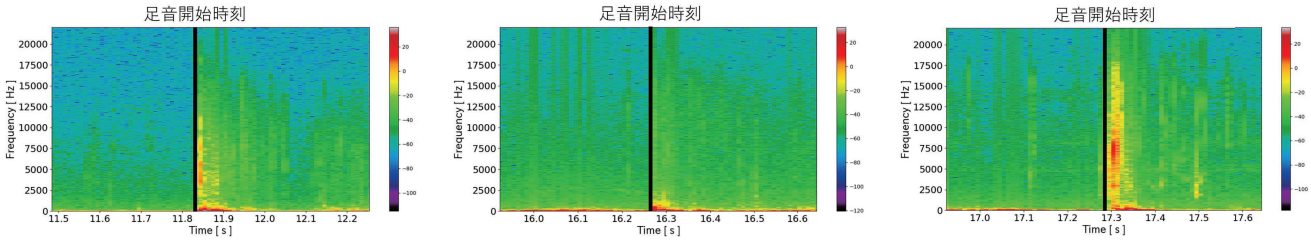

(a) 砂利道　(b) アスファルト　(c) 水たまり

図 3　足音のスペクトログラムの例

Fig. 3　Example of spectrograms of footsteps.

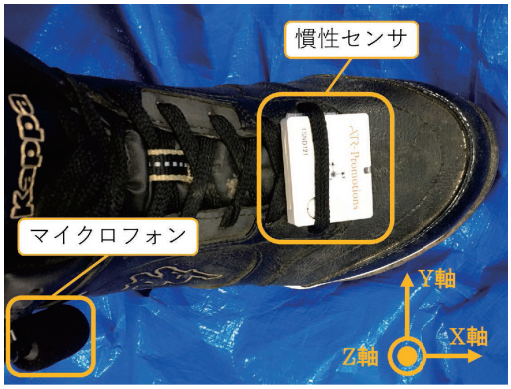

図 4　靴に搭載されたマイクロフォンと慣性センサ

Fig. 4　The microphone and inertial measurement unit (IMU) mounted on the shoe.

図 5　実験で使用した路面状況の例：(a) 砂利道，(b) アスファルト，(c) 水たまり，(d) 草むら，(e) 土，(f) 泥

Fig. 5　Evaluated road surface conditions: (a) gravel road, (b) dry pavement, (c) puddle, (d) grass, (e) soil, and (f) mud.

ティーボシリーズ（Kappa）の靴を使用した．ただし，人によって足のサイズは異なるため，靴のサイズを 2 種類（女性：24.5 cm，男性：27.5 cm）用意して測定を行った．マイクロフォンと慣性センサは左右の足にそれぞれ 1 つずつ装着した．ボイスレコーダはステレオ録音によって両足のマイクロフォンからの入力を記録する．慣性センサは靴の上で，X 軸を靴の前方，Y 軸を靴の左方向，Z 軸を鉛直上方向となるよう装着した（**図 4**）．音声データのサンプリング周波数は 44.1 kHz で，100 Hz から 17 kHz までの値を使用した．慣性データのサンプリング周波数は 50 Hz で，各軸の加速度と角速度の上限下限はそれぞれ ±8 G，±1,000 dps である．

5.　評価実験

5.1　低雑音環境下での認識

提案手法の有効性を評価するため，**図 5** に示す 6 つの路面状況を対象に評価実験を行った．実験は男性 6 人，女性 2 人の計 8 人（年齢 22–26 歳，体重 40–77 kg，身長 1.56–1.84 m）を対象に行った．全被験者に対し，それぞれの路面で 40 歩分の歩行データを取得し，これを 3 日行った．したがって，合計で 5,760 個の歩行データを取得した（6 路面 × 40 歩 × 8 被験者 × 3 セット）．本研究では，音声データに含まれる雑音は最小限に抑え，測定はすべて雨が降っていない日に行った．そのため，泥と水たまりでの実験は，乾燥路面に水を加えて行った．被験者の歩行速度は限定していないが，走らずに歩行を行うよう指示をした．また，被験者の中で，足を擦るように歩行を行う者がいた．本研究では，路面接地時に生じる足音が路面状況認識にどの程度有効であるかを検証するため，接地時の足音が生じるように，測定時は足を上げて歩行するよう指示を行った．その後，歩行データを分類モデルに適用した．本研究では，交差検証ごとにグリッドサーチを行い，各セットに対するハイパーパラメータを使用した．

5.1.1　足音データと慣性データの性能評価

足音データと慣性データの路面認識の有効性を検証するための評価実験を行った．足音データと慣性データそれぞれに対して分類モデルを作成し，各モデルごとに路面認識を行った．得られた歩行データを各日付ごとにデータセットに分割し，セットごとの交差検証を行った．

認識結果を**表 2** に示す．慣性データで学習を行ったモデルを使用した場合，平均認識精度は 53.4%となった．また，足音データで学習を行ったモデルを使用した場合，平均認識精度は 74.8%となり，足音データが慣性データに比べて路面認識に有効であることを確認した．足音データを使用した場合，砂利道の認識精度が 89.2%と最も高くなった．しかし，他 5 路面の認識精度は砂利道と比べて低い．特に，アスファルトと泥の認識精度は慣性データを用いた場合と比べて低くなっている．これは複数の路面の周波数特性が似ていることが原因だと考えられる．また，慣性データを

© 2020 Information Processing Society of Japan

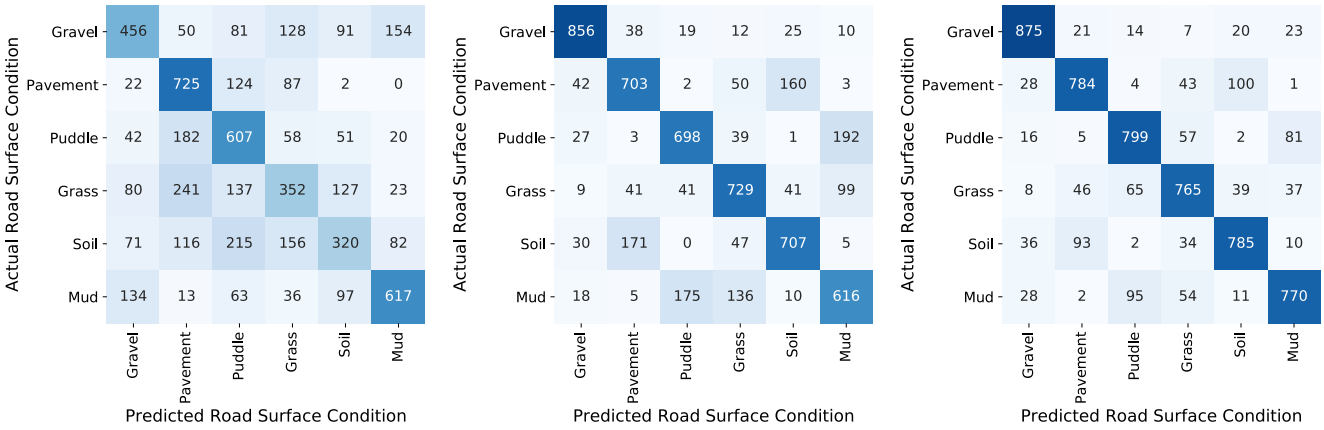

(a) 慣性データ　(b) 足音データ　(c) 慣性データ & 足音データ

図 6　異なる日付での路面認識の混同行列

Fig. 6　Confusion matrix of recognition of road surface condition for different dates.

表 3　慣性データと足音を用いて学習させた一般分類器と固有分類器の路面認識の精度［%］

Table 3　Recognition accuracies of road surface conditions using general and personal classifier trained by both inertial and footstep data [%].

路面状況	P1		P2		P3		P4		P5		P6		P7		P8		平均	
	一般	固有	一般	固有	一般	固有	一般	固有	一般	固有	一般	固有	一般	固有	一般	固有	一般	固有
砂利道	86.7	89.2	95.8	88.3	90.8	81.7	85.8	80.8	94.2	88.3	95.8	86.7	90.8	76.7	90.8	84.2	91.4	84.5
アスファルト	85.8	86.7	90.0	87.5	70.0	68.3	89.2	79.2	87.5	65.8	84.2	87.5	57.5	74.2	75.0	69.2	79.9	77.3
水たまり	90.8	82.5	83.3	87.5	80.0	83.3	59.2	71.7	84.2	80.8	99.2	93.3	85.8	78.3	76.7	75.0	82.4	81.6
草むら	76.7	76.7	80.8	71.7	77.5	57.5	83.3	77.5	69.2	70.0	80.8	77.5	75.0	76.7	84.2	75.8	78.4	72.9
土	82.5	71.7	81.7	78.3	82.5	68.3	80.0	80.0	78.3	69.2	86.7	72.5	84.2	70.0	65.0	64.2	80.1	71.8
泥	75.0	70.0	70.0	75.8	78.3	78.3	85.0	53.3	80.0	70.8	84.2	81.7	94.2	74.2	78.3	40.8	80.6	68.1
平均	82.9	79.4	83.6	81.5	79.9	72.9	80.4	73.8	82.2	74.2	88.5	83.2	81.3	75.0	78.3	68.2	82.1	76.0

表 2　異なる日付での路面認識の精度［%］

Table 2　Recognition accuracies of road surface conditions for different dates [%].

路面状況	慣性	足音	慣性 & 足音
砂利道	47.5	89.2	91.1
アスファルト	75.5	73.2	81.7
水たまり	63.2	72.7	83.2
草むら	36.7	75.9	79.7
土	33.3	73.6	81.8
泥	64.3	64.2	80.2
平均	53.4	74.8	83.0

用いた場合，アスファルトの認識精度が最も高いが，砂利道，草むら，泥の認識精度が 50%を下回っている．これは，慣性データから得られる特徴量は路面の安定性のみを表現しており，路面の種類を認識することは困難であったためと考えられる．

図 6 (a)，(b) の混同行列に注目すると，各データを使用したときに認識精度の良い路面がそれぞれ異なっていることが分かる．そこで，足音と慣性データの特徴量を組み合わせた評価を行った．認識結果を表 2，図 6 (c) に示す．全路面に対して認識精度が改善し，平均精度は 83.0%となった．したがって，低雑音環境下では，足音と慣性データの特徴量を別々に用いるよりも，組み合わせて使用することが最も効果的であることが分かった．

5.1.2　一般分類器

提案システムの実用を考えると，個人のデータの学習が必要ない一般分類器を用いた認識が望ましい．そこで，足音と慣性データの汎用性の評価を行った．分類モデルは足音と慣性データの特徴量を組み合わせたもので学習し，被験者ごとにデータセットを分けて交差検証を行った．

認識結果を**表 3** に示す．被験者によって結果に差異が生じ，P4 の水たまり，P5 の草むら，P7 のアスファルトの認識精度が低くなった．これは，被験者によってデータの外れ値が含まれていたことが原因だと考えられる．しかし，その他の認識精度は大幅に低下することなく，平均認識精度は 82.1%となった．このことから，本研究で得られた足音と慣性データには汎用性があり，被験者間でデータに大きな差がないことが確認できたと考える．しかし，5.1 節に示すように，本研究では摺り足のユーザにも足を上げて歩行するよう指示を行っている．摺り足歩行のユーザ本来の歩行に対して，本論文で得られた分類器が有効であるかは明らかでない．摺り足歩行のユーザに対する有効性の検

© 2020 Information Processing Society of Japan

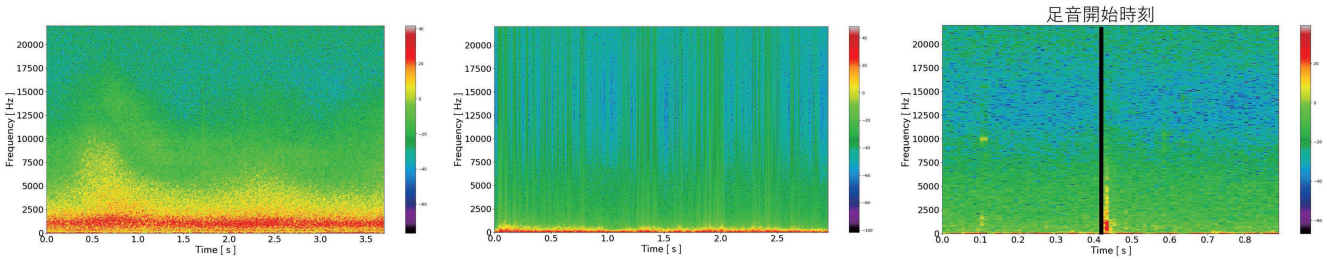

(a) 車の走行音　(b) 風　(c) 他人の足音

図 7　実験で使用した雑音のスペクトログラムの例
Fig. 7　Examples of spectrograms of noise used in the experiment.

証は今後の課題である．

5.1.3　固有分類器

人間の歩行には個人差があり，歩行の違いに基づく個人識別を行う研究が多くなされている [4], [10], [24]．実験 5.1.2 で，足音と慣性データの汎用性が確認できたが，ユーザの歩行の違いは歩行データに影響を与えている可能性が考えられる．そのため，各被験者ごとに個別に取得した歩行データを用いて，各々に合った分類器を作成することで路面認識の精度を向上できると考えた．各被験者ごとに固有分類器を作成し，評価実験を行った．得られた各被験者の歩行データを各日付ごとにデータセットに分割し，セットごとに交差検証を行った．

認識結果を表 3 に示す．実験 5.1.2 と比較して，全被験者の平均認識精度が低下した．これは分類モデルの学習データの量が異なったためだと考える．実験 5.1.2 では，分類モデルの学習に 5,040 個のデータを用いたが，固有分類器の実験では，480 個のデータのみで分類モデルの学習を行っている．そのため，分類モデルの学習がうまくできずに，認識精度が低下したと考える．今後は，各ユーザの歩行データをさらに収集し，固有分類器による路面認識の精度の調査を行う必要がある．

5.2　雑音環境下での認識

実験 5.1 にて，低雑音環境下では足音データが慣性データよりも路面認識に有効であり，足音と慣性データを組み合わせることが最も効果的であることが分かった．しかし，実環境下では他人の足音や車の走行音等の雑音の混入が考えられ，雑音付加による音声データの劣化が路面認識の精度に大きく影響する可能性がある．そのため，足音以外の雑音の影響を減らす必要がある．雑音抑制技術の中で，SS 法は雑音抑制によく利用されている [9], [17], [23]．しかし，SS 法は雑音の推定レベルの誤差が大きくなると十分な雑音除去効果が得られない問題がある．

雑音による影響を評価するため，雑音が付加された音声データを用いた路面認識の実験を行った．この実験はシミュレーション実験であり，録音した雑音のみの音声データを，実験 5.1 で用いた音声データに付加して疑似的な雑音入り足音データを作成した．実験環境は実験 5.1 と同様である．使用した雑音は，街中でのデバイス使用を想定し，路面認識精度に影響を及ぼすと考えられるものを採用した．本研究では，車の走行音，風，他人の足音の 3 つの雑音（**図 7**）を用いて実験を行った．実験では，それぞれの雑音単体を足音データに付加して雑音入りデータを作成した．他人の足音は，背景雑音も同時に付加されないよう，足音開始時刻付近のデータのみを抽出して音声データに付加した．足音と雑音の SNR として，20 dB，10 dB，6 dB，3 dB，1 dB の 5 種類を用いた．予備調査から，道路脇で得られた足音と車の走行音の SNR は平均 20 dB 程度であり，最小でも 10 dB 程度であることが確認できた．しかし，環境やマイク感度によっては，より SNR が悪化する可能性も考えられる．したがって，SNR が低い時をより詳細に調査するため，評価する SNR を上記の 5 種類とした．予備調査より，評価した雑音のうち認識精度に最も影響を与えるのは車の走行音であることが確認できたため，本研究では車の走行音の SNR を基準として設定し，実験環境統一のため風と他人の足音についても同様の SNR を用いた．なお，本研究では足音のようなインパルス音に対して SNR を計算するため，式 (6) で SNR を定義した．$\max\{A_S\}$ と $\max\{A_N\}$ は，それぞれ足音と雑音の最大振幅値を表している．実験 5.1 と同様に，交差検証ごとにグリッドサーチを行い，各セットに対するハイパーパラメータを使用した．

$$SNR = 20\log_{10}\frac{\max\{A_S\}}{\max\{A_N\}} \tag{6}$$

5.2.1　標準手法

単純に足音と慣性データの特徴量を組み合わせる標準手法の認識実験を行った．また，既存手法である SS 法を用いた認識精度の調査も行った．ただし，雑音が足音のようなインパルス音である場合，SS 法の適用が困難になるため，雑音が他人の足音のときの実験では SS 法を適用しなかった．

標準手法での平均認識精度の結果を**表 4**，**表 5**，**表 6** に示す．足音と慣性データの特徴量を組み合わせることで，足音データのみを使用した時と比べて認識精度が向上した．また，SS 法を適用したことで，車の走行音が雑音と

© 2020 Information Processing Society of Japan

表 4 雑音環境下での路面認識の精度（車の走行音）[%]
Table 4 Recognition accuracies of road surface conditions under noisy environment (driving sounds of cars) [%].

SNR [dB]	足音		慣性 & 足音		改善手法
	SS 法無	SS 法有	SS 法無	SS 法有	
20	50.5	59.0	58.4	69.5	70.4
10	35.4	43.3	42.6	51.1	62.5
6	28.6	36.4	36.5	45.0	58.5
3	25.3	32.3	32.4	40.8	55.8
1	23.0	30.0	29.6	37.5	53.9

表 5 雑音環境下での路面認識の精度（風）[%]
Table 5 Recognition accuracies of road surface conditions under noisy environment (wind) [%].

SNR [dB]	足音		慣性 & 足音		改善手法
	SS 法無	SS 法有	SS 法無	SS 法有	
20	74.3	73.6	82.9	82.1	83.0
10	72.6	71.5	82.5	81.6	80.6
6	70.6	70.0	81.0	80.0	78.9
3	67.7	67.4	78.9	78.7	75.9
1	64.7	64.7	76.1	76.9	74.0

表 6 雑音環境下での路面認識の精度（他人の足音）[%]
Table 6 Recognition accuracies of road surface conditions under noisy environment (footstep of others) [%].

SNR [dB]	足音		慣性 & 足音		改善手法
	SS 法無	SS 法有	SS 法無	SS 法有	
20	65.7	—	75.3	—	78.8
10	52.4	—	60.7	—	67.9
6	45.6	—	53.8	—	60.7
3	41.0	—	49.4	—	56.3
1	37.7	—	45.9	—	52.4

して含まれている場合（表 4）は認識精度の向上が確認できた．ただし，風が雑音として含まれる場合（表 5）は，SNR が 3 dB 以上の環境下では認識精度の低下が確認された．図 7 から，風は車の走行音よりも足音データに影響する周波数帯が少ないことが分かる．SS 法を適用したことで，影響していない周波数のパワーを引きすぎたことが認識精度低下の原因だと考えられる．また，どの雑音環境下でも，実験 5.1 と比べて，SNR が低い時は平均認識精度が低下している．特に，車の走行音が雑音の場合，評価した雑音の中で最も減少幅が大きい．したがって，単純に足音データと慣性データの特徴量を組み合わせるだけでは十分な認識精度が見込めないことが分かった．

5.2.2 改善手法

実験 5.2.1 の結果から，足音データは低雑音環境下では有効であるが，雑音が含まれると認識に影響を及ぼすことが分かった．また，単純に足音と慣性データの特徴量を組み合わせるだけでは十分な認識精度向上にはつながらないことも確認できた．そこで，本研究では，低雑音環境下では足音データを優先して利用し，雑音が多く含まれる環境下では足音データの優先度を低下させる改善手法を提案する．具体的には，分類モデルを用いて足音と慣性データそれぞれが，どのクラスに属しているのかを判定するスコアを算出する関数を利用する．本研究では，python の scikit–learn に含まれるメソッド decision_function を利用し，各サンプルごとにクラスごとのスコアを算出する．その後，式 (7) を用いて値 $c(k)$ を算出する．この値をクラス k における信頼度と定義する．$s_i(k)$，$s_f(k)$ は，それぞれクラス k における慣性データと足音データのスコアを表し，式 (8) により 0 から 1 の値に正規化している．ただし，X は正規化するスコア，Y は正規化後のスコア，x_{max} はスコアの最大値，x_{min} はスコアの最小値を表す．また，a は足音データのスコアを制御する正の変数である．

$$c(k) = s_i(k) + as_f(k) \tag{7}$$

$$Y = \frac{X - x_{min}}{x_{max} - x_{min}} \tag{8}$$

a は取得した雑音の大きさに対応する関数値で定義する．足音は始めにインパルス状の大きな音を発するが，その後は大きなパワーを持つ信号は発生しないことが多い．そのため，足音開始時刻を除くフレーム間に含まれる信号のパワーは雑音の大きさを示すと考えた．そこで，取得した足音データの分散の変化で雑音レベルを推定し，雑音レベルの大きさによって a の値を決定した．ただし，足音開始時刻は大きなパワーを持つ信号が発生し，分散値が高くなるため，取得した分散値の四分位範囲内のデータのみを用いることで外れ値を除去した．足音データの分散値を等フレーム間隔で算出し，四分位範囲内の値の平均値を v とし，これを足音データの雑音レベルとした．このとき，a を式 (9) のような v の条件式で定義する．なお，本研究で評価した雑音のなかでは，車の走行音が最も認識に影響を与えることが事前に確認できた．したがって，v の値は車の走行音の SNR と分散値の関係を基準に定めた．

$$a = \begin{cases} 2.0 & (v \leq 0.00015) \\ 1.0 & (0.00015 < v \leq 0.001) \\ 0.5 & (0.001 < v) \end{cases} \tag{9}$$

$c(k)$ が最も大きくなる k を，モデルが出力する予測ラベルとし，最終的な認識結果と定義する．

改善手法を用いた平均認識精度の結果を表 4–表 6 に示す．車の走行音が雑音として含まれる場合（表 4）では，どの SNR でも改善手法での認識精度の向上が確認でき，SNR が 20 dB のときでは認識精度を 70.4%まで改善することができた．また，SS 法を適用した足音と慣性データを組み合わせた場合と比較して，SNR が 1 dB のときでは，37.5%から 53.9%まで認識精度を改善できた．風が雑音として含まれる場合（表 5）は，SNR が 20 dB のときでは認識精度が

© 2020 Information Processing Society of Japan

最も高くなったが，SNR が 10 dB 以下では認識精度が低下した．しかし，雑音が車の走行音の場合の標準手法と改善手法の減少幅の差と比較すると，雑音が風の場合の標準手法と改善手法の減少幅の差は小さく，システム全体として見ると，改善手法によって認識精度が向上すると考える．また，パラメータ a の調整を行うことで対策は可能だと考える．他人の足音が雑音として含まれる場合（表 6）では，どの SNR でも認識精度の向上が確認できた．改善手法では，雑音レベルを推定する際に，突発的な分散値の変化は外れ値として除去している．そのため，他人の足音のような突発的な雑音では，認識精度の改善は見込めないと想定していたが，想定とは異なる結果が得られた．このような結果となった原因については 7.2 節で議論を行う．

6. 想定アプリケーション

提案システムは，降雨や降雪により路面状況が大幅に変化する地域での利用を想定している．このような地域で詳細な路面状況を事前に把握することは，目的地までのルート設定や適切な靴の選択のために重要だといえる [3], [25]．

提案システムの想定アプリケーションを**図 8** に示す．スマートフォンの GPS と提案手法を使用することで，ユーザの歩行した位置情報と路面状況が同時に認識可能である．これにより，路面状況を考慮した道案内アプリケーションが考えられる（図 8 (a)）．最短ルートも示しつつ，路面状況も踏まえた安全ルートを示し，どちらの道が安全に効率よく目的地までたどり着くことができるかをユーザに提示することにより，転倒事故等の抑制につながると考える．しかし，このシステムは少なくとも 1 回以上ユーザが歩行しなければ路面状況を地図上に反映させることができない．そのため，一度も歩行していない場所の周辺の路面状況を考慮し，それに合わせて路面状況を推定するシステムを導入する等の対策を考える必要がある．

また，路面状況を認識することで，ユーザが出かける前に靴の選定を行うことが可能になる．地域ごとに天気が異なり，靴の選定が難しい場合に，目的地付近の路面状況を認識し，事前に靴の選定を行わせることで，ストレスなく目的地までたどり着くことができると考える（図 8 (b)）．

これらの想定アプリケーションでは，多数のユーザがスマートシューズを履いてデータを取得する必要があるが，提案システムの普及を考えると，スマートシューズを履いてデータを取得するユーザにとっての恩恵を考慮する必要がある．ユーザがスマートシューズを用いてデータを取得することの動機付けとして，ゲーミフィケーションによる手法が考えられる．位置情報を利用したゲームと連携し，スマートシューズを履いて特定の場所（まだ路面状況が十分に収集できていない場所）に行くことに高い報酬を設定することで，スマートシューズを履くことへの価値を創出できると考える．また，ユーザへの恩恵の 1 つとして，

図 8　想定アプリケーションの例：(a) 最短ルートと安全ルートをマップ上に示す，(b) 路面状況に応じて推奨靴の変更を行う

Fig. 8　Assumed applications: (a) the shortest route and the safe route are shown on the map and (b) the recommended shoes types are changed depending on the road conditions.

ユーザ自身へのサービスの質の向上が考えられる．システムへデータを提供することで学習データが増加し，それにともない路面識別性能や多様なユーザ（摺り足等の歩行の違い，性別，年齢）への対応が可能になると考える．結果的に，データを提供することは，ユーザ自身が享受するサービスの質の向上につながると考えられる．

7. 考察

7.1 プライバシの問題

スマートフォンには，すでに Siri [1] や Google Assistant [6] 等のように，アプリケーション起動のためにマイクロフォンを常時利用したサービスが提供されており，マイクロフォンはカメラと比較するとプライバシの懸念へのハードルが低いと考えられる．しかし，音声データにもプライバシ情報は含まれる．本研究では，音声データから抽出された特徴量のみが路面認識のために重要となっている．したがって，足音データから特徴量を抽出した後に音声データを破棄することで，プライバシ保護につながると考える．また，GPS と慣性センサを併用すれば，屋外での歩行を検知できる．屋外での歩行時のみマイクを有効にす

© 2020 Information Processing Society of Japan

ることで，プライバシの懸念を減少できると考える．

7.2　雑音環境下での路面状況認識

本研究では，雑音が混じり合う実環境を想定し，複数の雑音データを用いたシミュレーション実験を行った．車の走行音や他人の足音が雑音として含まれる場合では，改善手法を用いることですべての SNR 環境下で認識精度を改善できた．しかし，改善手法は他人の足音のような突発的な雑音では分散値からは雑音レベルが上手く推定できず，認識精度の改善は見込めないと想定していた．この改善の要因は，信頼度のパラメータ a により，足音データの信頼度の上限を設定したことだと考えられる．本研究では，分類モデルは低雑音環境下のデータを基に作成される．低雑音環境下では，表 2 に示すように足音データが慣性データよりも有効であるため，足音の重要度が慣性データよりも大幅に高くなると考えられる．そのため，足音と慣性データを単純に組み合わせた標準手法では，分類モデル中の足音の重要度が高く，雑音があったときに大幅に影響されたといえる．一方，改善手法では，足音の信頼度をパラメータ a により最大でも 2.0 までと設定した．そのため，標準手法よりも足音データへの依存が少なくなっている．以上より，他人の足音のような突発的な雑音の場合，分散値から雑音レベルを適切に推定できていないが，足音データへの依存を少なくしたことで認識精度が向上したと考える．

また，風が雑音として含まれる場合では，改善手法を用いると，SNR が 10 dB 以下の環境下で認識精度が低下してしまった．これは，パラメータ a を車の走行音を基準にして設定したためだと考えられる．雑音の種類ごとに改善手法で用いたパラメータ a の調整を行うことで認識精度の向上が行えると考える．図 7 から分かるように，雑音の種類によって周波数特性が大きく異なる．今後は，雑音の種類を推定した後に改善手法を適用し，認識精度向上につながるのか調査を行う必要がある．

7.3　靴の種類の影響

本論文ではマイクと慣性センサが組み込まれたスマートシューズの利用を想定したが，幅広いユーザへの普及を考えると，専用のシューズを必要としない方が望ましい．既存の靴へ装着型のデバイスを用いれば実現は可能であるが，靴によって足音に差が生じる可能性がある．そこで，本節では靴の種類の影響について予備調査を行った．5 章で使用したものとは異なる靴（**図 9** (b)）を用意し，路面認識における靴の影響の予備調査を行った．測定の都合上，歩行路面は，図 5 の路面のうち，アスファルト，水たまり，草むらの 3 路面とした．データは 1 日分のみで，120 歩分の歩行データを用いた．分類モデルは足音データのみを用いて学習し，5 章で利用した全 5,760 個のデータで学習を行った．被験者は男性 1 人のみである．

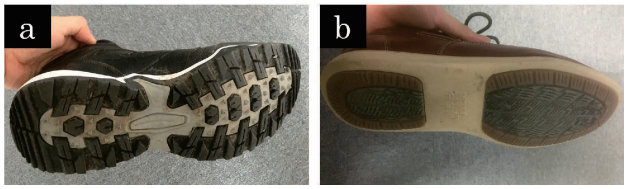

図 9　靴の種類：(a) KP STM クレアティーボシリーズ，(b) トラベラーアイステック TR IT LW OX 2 HL82051

Fig. 9　Type of shoe: (a) KP STM Creativo series and (b) Traveler ICE-TECH TR IT LW OX 2 HL82051.

表 7　異なる靴を用いた路面認識の精度［%］

Table 7　Recognition accuracy of road surface conditions using different shoes [%].

路面状況	再現率
アスファルト	67.5
水たまり	81.7
草むら	83.3

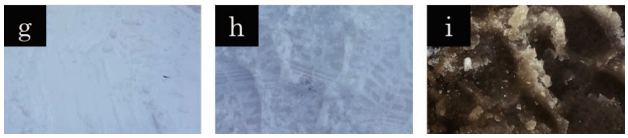

図 10　検証した冬の路面：(g) 新雪，(h) 圧雪，(i) シャーベット

Fig. 10　Tested snow roads: (g) fresh showy road, (h) compacted snowy road, and (i) sherbet.

認識結果を**表 7** にまとめる．アスファルトの認識精度は低いが，水たまりと草むらの認識精度は高くなった．このため，路面によって靴の種類による影響の大きさに違いがあると考えられる．しかし，本研究で使用した靴の種類やデータ数は多くないため，さらなる調査が必要だと考える．

7.4　冬時期の路面認識

冬場の路面は凍結等によって転倒事故につながる路面が多く，夏場の路面よりも路面認識の重要性がより高いと考える．しかし，冬場の路面はデータ取得期間の制限から十分なデータを収集できなかったため，本研究では夏場を想定した 6 路面を対象とし，足音と慣性データによる路面認識性能を議論した．本節では，今後の提案手法の拡張を想定し，より重要度の高い冬場の路面認識のための予備的な調査を行った．冬時期の路面認識の有効性を検証するために，冬場に集めた 3 人分の被検者（男性 2 人，女性 1 人）のデータに対して路面認識の予備実験を行った．認識する路面は，5 章の評価実験で使用した路面（図 5）から草むらを除いた 5 路面と，**図 10** の 3 路面の計 8 路面とした．なお，砂利道，土，泥の 3 路面は，降雪等による影響で実験が困難であったため，研究室内に測定場所を設置し，屋内で測定を行った．実験は 1 日のみで行い，30 歩を 1 セットとして全路面で 4 セット分の測定を行った．本予備実験では足音開始時刻を手動で検出し，足音開始時刻から 0.186 s

© 2020 Information Processing Society of Japan

表 8　足音データのみを用いた冬の路面認識の精度［%］
Table 8　Recognition accuracies of road surface conditions of winter using only footstep data [%].

路面状況	再現率
砂利道	82.5
アスファルト	89.2
水たまり	75.8
土	66.4
泥	77.5
新雪	73.6
圧雪	84.4
シャーベット	75.3
平均	78.1

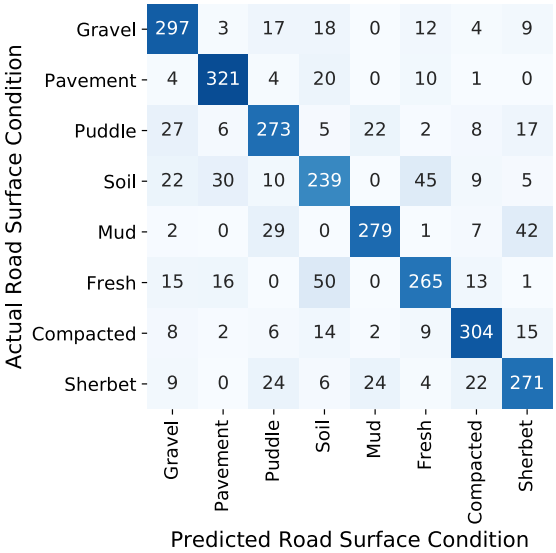

図 11　足音データのみを用いた冬の路面認識の混同行列
Fig. 11　Confusion matrix of road surface recognition of winter using only footstep data.

までのデータを特徴量抽出に使用した．分類モデルは足音データのみで学習したものを用いた．

認識結果を**表 8** と**図 11** に示す．平均認識精度が78.1%となり，冬時期の路面状況を認識できる可能性があると考える．しかし，本予備実験では被検者が少ないこと，屋内で測定したデータが含まれていること，測定日数が 1 日のみであること等の測定の制限がある．被験者の増加，異なる日付でのデータを用いた実験は今後の課題である．

7.5　路面状況に対するロバスト性

本研究では，6 種類の路面状況に対して評価を行ったが，同じ路面状況でも条件が異なれば得られる歩行データが異なる可能性がある．たとえば，砂利道の砂利の大きさ，アスファルトの種類，水たまりの深さ，草の種類，路面の傾き等は歩行データに影響を与える可能性がある．本研究では，一定の路面状況に対して足音と慣性データが路面状況認識にどの程度有効であるのかの調査に着目したため，同じ路面状況の異なる条件までは考慮できていない．同路面の異なる条件における提案手法の性能調査は今後の課題である．

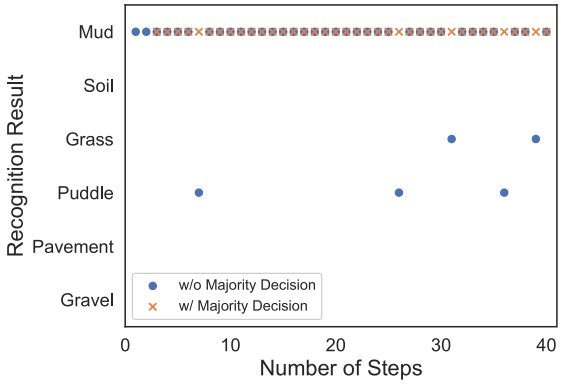

図 12　P6 の 1 セット目の泥路面 40 歩に対する認識結果
Fig. 12　Recognition results for 40 steps on mud of set 1 of P6.

表 9　多数決適用の有無による認識精度の比較［%］
Table 9　Comparison of recognition accuracy with and without majority decision [%].

路面状況	多数決無	多数決有
砂利道	100	100
アスファルト	85.0	97.4
水たまり	92.5	97.4
草むら	95.0	100
土	90.0	92.1
泥	87.5	100
平均	91.7	97.8

7.6　連続した複数歩を用いた認識

本研究では提案手法の基本的な性能調査のため，各歩行データに対しての認識精度を求めた．しかし，実際の路面を考慮すると，路面は一定の範囲で広がっており，連続する数歩は同じ路面であることが考えられる．そのため，連続する複数歩の認識結果を用いれば，認識精度を改善できると考える．**図 12** に，5.1.1 項で示した慣性データと足音データを用いた認識結果のうち，P6 の 1 セット目の泥路面 40 歩に対する認識結果を示す．この図より，誤認識は散発的に発生していることが確認できるため，直近数歩の認識結果の多数決をとることで誤認識を防ぎ，認識精度が改善可能と考えられる．ここでは直近 3 歩の認識結果を用いることで，誤認識の改善が確認できた．また，**表 9** に同セットの全路面に対する多数決の有無による認識精度の比較を示す．この表に示すように，もとより誤認識のなかった砂利道を除くすべての路面で，多数決により認識精度の改善が確認できた．なお，直近 3 歩の認識結果がすべて異なる場合は認識不可能とした．以上より，実際の環境を考慮すると，連続した複数歩を用いた認識精度の向上が可能と考える．

© 2020 Information Processing Society of Japan

8. 結論

本研究では，足音と慣性データを利用した路面状況認識手法を提案した．評価実験の結果，低雑音環境下では平均83.0%の認識精度が得られた．しかし，雑音環境下では，足音データに雑音が付加することで認識精度に影響を及ぼすことが分かった．そこで，付加した雑音の大きさに応じて足音データの優先度を変更させる改善手法を提案した．実環境を想定したシミュレーション実験の結果，車の走行音と他人の足音が含まれる場合は，すべてのSNR環境下で認識精度が改善したことを確認した．

謝辞 本研究はJSPS科研費JP19H04222，JP18K18084の助成を受けたものである．

参考文献

[1] Apple: Siri, available from ⟨https://www.apple.com/siri/⟩.

[2] Chiang, T., Ou, K., Qiu, J. and Tseng, Y.: Pedestrian Tracking by Acoustic Doppler Effects, *IEEE Sensors Journal*, Vol.19, No.10, pp.3893–3901 (2019).

[3] Cho, Y., Bianchi-Berthouze, N., Marquardt, N. and Julier, S.J.: Deep Thermal Imaging: Proximate Material Type Recognition in the Wild Through Deep Learning of Spatial Surface Temperature Patterns, *Proc. 2018 CHI Conference on Human Factors in Computing Systems, CHI '18*, pp.2:1–2:13 (2018).

[4] Cola, G., Avvenuti, M., Musso, F. and Vecchio, A.: Gait-based authentication using a wrist-worn device, *Proc. 13th International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, pp.208–217, ACM (2016).

[5] Ducere: Lechal, available from ⟨http://lechal.com/shoe-design.html⟩ (2014).

[6] Google: Google Assistant, available from ⟨https://assistant.google.com/intl/en_uk/⟩.

[7] Hassan, M., Daiber, F., Wiehr, F., Kosmalla, F. and Krüger, A.: FootStriker: An EMS-based Foot Strike Assistant for Running, *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol.1, No.1, pp.2:1–2:18 (2017).

[8] Kim, K., Zabihi, H., Kim, H. and Lee, U.: TrailSense: A Crowdsensing System for Detecting Risky Mountain Trail Segments with Walking Pattern Analysis, *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol.1, No.3, pp.65:1–65:31 (2017).

[9] Lu, C., Tseng, K., Chen, Y., Wang, L. and Lei, C.: Speech enhancement using spectral subtraction algorithm with over-subtraction and reservation factors adapted by harmonic properties, *2016 International Conference on Applied System Innovation* (*ICASI*), pp.1–5 (2016).

[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 '17*, pp.9:1–9:14, ACM (2017).

[11] Mitake, H., Watanabe, H. and Sugimoto, M.: Footsteps and Inertial Data-based Road Surface Condition Recognition Method, *Proc. 18th International Conference on Mobile and Ubiquitous Multimedia, MUM '19*, pp.22:1–22:10, ACM (2019).

[12] Nike, I.: HyperAdapt (2018), available from ⟨https://www.nike.com/us/en_us/c/innovation/hyperadapt⟩.

[13] no new folk studio Inc.: Orphe (2017), available from ⟨https://orphe.shoes/⟩.

[14] Nolte, M., Kister, N. and Maurer, M.: Assessment of Deep Convolutional Neural Networks for Road Surface Classification, *2018 21st International Conference on Intelligent Transportation Systems* (*ITSC*), pp.381–386 (2018).

[15] Nomura, T. and Shiraishi, Y.: A method for estimating road surface conditions with a smartphone, *Int. J. Inform. Soc.*, Vol.7, No.1, pp.29–36 (2015).

[16] Pan, S., Yu, T., Mirshekari, M., Fagert, J., Bonde, A., Mengshoel, O.J., Noh, H.Y. and Zhang, P.: FootprintID: Indoor Pedestrian Identification Through Ambient Structural Vibration Sensing, *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol.1, No.3, pp.89:1–89:31 (2017).

[17] Prabhakaran, G., Indra, J. and Kasthuri, N.: Tamil speech enhancement using non-linear spectral subtraction, *Proc. International Conference on Communication and Signal Processing, ICCSP 2014*, pp.1482–1485 (2014).

[18] Roychowdhury, S., Zhao, M., Wallin, A., Ohlsson, N. and Jonasson, M.: Machine Learning Models for Road Surface and Friction Estimation using Front-Camera Images, *2018 International Joint Conference on Neural Networks* (*IJCNN*), pp.1–8 (2018).

[19] Satoh, T., Hiromori, A., Yamaguchi, H. and Higashino, T.: A novel estimation method of road condition for pedestrian navigation, *Proc. IEEE PerMoby 2015*, pp.427–432, IEEE (2015).

[20] Tajadura-Jiménez, A., Basia, M., Deroy, O., Fairhurst, M., Marquardt, N. and Bianchi-Berthouze, N.: As Light As Your Footsteps: Altering Walking Sounds to Change Perceived Body Weight, Emotional State and Gait, *Proc. 33rd Annual ACM Conference on Human Factors in Computing Systems, CHI '15*, pp.2943–2952, ACM (2015).

[21] Tanaka, S., Itai, A. and Yasukawa, H.: A study on footstep detection in outdoor environment using Itakura-Saito distance, *2014 IEEE Asia Pacific Conference on Circuits and Systems* (*APCCAS*), pp.93–96 (2014).

[22] Tanaka, S., Mizuno, K. and Itai, A.: Footstep modeling and detection using locally stationary autoregressive model, *2015 10th International Conference on Information, Communications and Signal Processing* (*ICICS*), pp.1–5 (2015).

[23] Upadhyay, N. and Karmakar, A.: An Improved Multi-Band Spectral Subtraction Algorithm for Enhancing Speech in Various Noise Environments, *Procedia Engineering*, Vol.64, pp.312–321 (2013).

[24] Wang, X., Yang, T., Yu, Y., Zhang, R. and Guo, F.: Footstep-Identification System Based on Walking Interval, *IEEE Intelligent Systems*, Vol.30, No.2, pp.46–52 (2015).

[25] ウインターライフ推進協議会：「つるばん tsuru-ban」つるつる路面で転ばんためのWebサイト，入手先 ⟨https://sp.tsurutsuru.jp/⟩.

[26] ウインターライフ推進協議会：冬道転倒による救急搬送統計，入手先 ⟨http://tsurutsuru.jp/toukei1.html⟩.

[27] 三嶽寛人，渡邉拓貴，杉本雅則：足音を用いた路面状況推定手法，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（DICOMO 2018）論文集，*DICOMO '18*，Vol.2018, pp.999–1007 (2018).

© 2020 Information Processing Society of Japan

三嶽 寛人

2018 年北海道大学工学部情報エレクトロニクス学科卒業．現在，北海道大学情報科学研究院修士課程在学中．ウェアラブルコンピューティングに関する研究に従事．

渡邉 拓貴　（正会員）

2012 年神戸大学電気電子工学科卒業．2017 年同大学院工学研究科博士課程修了．博士（工学）．同年より北海道大学助教となり，現在に至る．

杉本 雅則　（正会員）

1990 年東京大学工学部航空学科卒業．1995 年同大学院工学系研究科博士課程修了．博士（工学）．同年学術情報センター（現，国立情報学研究所）助手．1999 年東京大学助教授．2012 年より北海道大学教授となり，現在に至る．

© 2020 Information Processing Society of Japan