

疎な移動履歴に基づく道ごとの通行可否推定方式の基礎検討

富永 詩音¹ 蔵内 雄貴² 宮田 章裕^{3,a)}

概要: 世の中には段差・坂道・階段などの様々なバリアが点在し、移動弱者の円滑な移動を妨げている。移動弱者は外出の際に自身が移動できない道に遭遇しないよう、あらかじめ移動計画を立ててから出かけることも珍しくない。移動弱者にとってそれぞれの道が自身の移動手段で通れるのか通れないのかという情報は非常に重要であると考えられる。この状況に鑑み、移動弱者が通れる道の推定を行おうとする研究がさかんに行われている。しかし、既存研究では推定に大量のセンサデータが必要、データの収集に高いコストがかかる、といった問題がある。そこで我々は、携帯電話事業者などで既に移動履歴が蓄積されていることに着目し、疎な移動履歴から道ごとの通行可否を推定する方式を提案する。提案手法は、道の周囲を格子状に区切り、各マスにおける移動履歴の数をカウントしたものを Convolutional Neural Network で学習することで、道ごとの通行可否を推定する。検証実験では一定時間おきの GPS データを用いて道ごとの通行可否推定を行い、推定を 50 回行って得られた推定精度の平均値は、移動実績のある、通行可能な道については Precision:0.56, Recall:0.42, F-measure:0.47, 移動実績のない、通行可否が不明な道については Precision:0.83, Recall:0.89, F-measure:0.86 となった。

A Study of Method for Estimating a Possibility of Passage for Each Road Based on Sparse Movement History

1. はじめに

1990年にアメリカで制定された、障害をもつアメリカ法 (Americans with Disabilities Act of 1990) [1] をきっかけに、世界中でバリアフリー社会への転換が謳われ、各国でバリアフリーに関する法律が施行されるようになった。最近の日本でも 2018 年にバリアフリー新法が改正されるなどして、バリアフリー化の動きはますます活発なものになりつつある。しかし、街中を見渡すと未だに整備されていない道路や施設が散見されるのが現状であり、移動弱者が行き当たりばったりで移動すると、自身が移動できない道に遭遇して行き詰まってしまうこともあるだろう。このような事態に陥らないよう、移動弱者は外出の際にはあらかじめ移動計画を立ててから出かけることも珍しくないとい

う。移動弱者にとってそれぞれの道が自身の移動手段で通れるのか通れないのかという情報は非常に重要であると考えられる。この状況に鑑み、移動弱者が通れる道の推定を行おうとする研究がさかんに行われている。しかし、既存研究で用いられている手法では、推定に大量のセンサデータが必要だったり、データの収集に高いコストがかかってしまったりする問題がある。そこで我々は、携帯電話事業者などで既に移動履歴が蓄積されていることに着目し、疎な移動履歴から道ごとの通行可否を推定する方式を提案する。

本稿の貢献は次のとおりである。

- なるべく収集コストをかけずに少ないデータからでも道の通行可否の推定を行えるよう、疎な移動履歴から道ごとの通行可否を推定する方式を提案した点。
- 一定時間おきの GPS データを用いて提案方式における道ごとの通行可否推定精度検証実験を実施した点。

¹ 日本大学大学院総合基礎科学研究科
Graduate School of Integrated Basic Sciences, Nihon University, Setagaya, Tokyo 156-8550, Japan

² NTT サービスエボリューション研究所
NTT Service Evolution Laboratories

³ 日本大学文理学部
College of Humanities and Sciences, Nihon University, Setagaya, Tokyo 156-8550, Japan

a) miyata.akihiro@acm.org

2. 関連研究

2.1 センサデータを機械学習することでユーザの行動推定を行う研究事例

文献 [2] は、スマートフォンをスポンのポケットに入れた状態に加え、鞆に入れた状態、手に持った状態で計測した加速度データから、ユーザが歩いているか否かを判定している。判定には HMM などの機械学習手法を用いており、利用する特徴量は Time Domain・Frequency Domain のものである。文献 [3] は、ユーザの飲酒状態（非飲酒、飲酒、大量飲酒）を、機械学習をベースとして構築したモデルを用いて識別している。モデルを構築する上でスマートフォンの各種センサデータや操作履歴などのデータを用いており、構築したモデルは 96.6% の精度でユーザの飲酒状態の識別が可能となっている。

2.2 移動弱者の移動を妨げるバリアの推定を行う研究事例

文献 [4], [5] は、広域のバリア情報を高精度に収集するために、健常者歩行時のセンサデータから移動弱者に対するバリアの存在を機械学習を用いて推定している。文献 [6] は、Time Domain, Frequency Domain の特徴量を分析する SVM の識別器を作成し、ユーザが歩いている路面が平坦か、階段か、坂かを判定する試みを行っている。この研究ではスマートフォンの位置（例：ポケット、鞆）が未知であるとし、推定対象の時間帯の前後時間帯も分析することで推定精度を向上させている。文献 [7] は、さまざまな移動手段における移動時のセンサデータを用いてバリアの存在を推定する試みを行っている。移動手段ごとに適切なバリア推定モデルを用意する必要があり、かつ大量のセンサデータを収集する必要があるという問題を解決するために、ユーザの移動手段とバリアを 2 段階で推定するモデルと、収集したセンサデータにノイズを加えることで粗い路面をシミュレートする手法を提案している。

3. 研究課題

移動弱者が通れる道の推定に関連して、ユーザの行動や路面に存在するバリアの推定を行う研究はさかんに行われている。しかし、既存研究で用いられている手法では、推定するにあたり大量のセンサデータが必要といった問題や [2], [3], [4], [5], [7], 推定に利用するデータの収集に高いコストがかかるといった問題がある [3], [6]。

そこで本研究では、なるべく収集コストをかけずに、少ないデータからでも道の通行可否の推定を行えるようにすることを研究課題として設定する。

4. 提案方式

3 章で設定した研究課題を達成するために、携帯電話事




図 1 道（青色）の“周囲”（薄青色）

業者などで既に蓄積されている疎な移動履歴に着目する。携帯電話事業者などは、ユーザの居場所に合わせたレコメンドなどを行うサービスを展開する上で、ユーザの位置情報といった移動履歴をバックグラウンドで定期的に測位している [8]。過去に収集され、大量に蓄積されている移動履歴データを使うことができるならば、当たり前のことだが収集コストはかからない。また、蓄積されている移動履歴データの多くが、欠損部分が少なくサンプリングレートが等しい整ったデータである、といったことは稀であると思われる。疎な移動履歴からでも道の通行可否の推定を行うことができれば、蓄積されている移動履歴データのうち整っていない部分についても有効に利用することができると思われる。

以上のことから我々は、疎な移動履歴から道ごとの通行可否を推定する方式を提案する。

5. 実装

5.1 疎な移動履歴

移動履歴の候補としては、GPS, Beacon, Wi-Fi アクセスポイント、携帯電話基地局などによる測位結果が考えられる。今回は基礎検討として、まずは GPS による測位データを移動履歴として扱い、一定時間おきの GPS データを疎な移動履歴として利用することとする。

5.2 通行可否推定対象の道

本研究では、道を“2つの交差点間の道路”とし、それぞれの道には一意な識別子を割り当てる。通行可否推定対象の道を定める上で、まず、“その道の始点・終点を対角とする長方形の範囲を、東西南北に 10m ずつ拡大^{*1}した範囲”を、その道の“周囲”と定義する（図 1）。そして、周囲に 1 つ以上 GPS データが存在する道を、通行可否推定対象の道とする。

*1 10m ずつ拡大しているのは、GPS の測位誤差を考慮しているためである。

5.3 道の通行可否推定

本研究では、ユーザによる疎な移動履歴を、Deep Learning を用いて機械学習することで、それぞれの道の通行可否を推定することとする。道の周囲のGPSデータの個数は一定でないため、そのままDeep Learningのモデルに入力しようとすると、道ごとに入力の次元数が異なってしまうなどの理由から難しい。そこで、道の周囲のGPSデータの分布を、画像認識等でよく用いられるDeep Learningの代表的手法であるConvolutional Neural Network（以下、CNN）を用いて教師あり学習する手法をとる。

本実装におけるCNNは次のような構成とした。各畳み込み層の活性化関数にはReLUを用いている。

L_1 : 畳み込み層。カーネル数16, カーネルサイズは(3,3).

L_2 : プーリング層。プーリング演算時のウィンドウサイズは(2,2).

L_3 : 畳み込み層。カーネル数32, カーネルサイズは(3,3).

L_4 : プーリング層。プーリング演算時のウィンドウサイズは(2,2).

L_5 : 畳み込み層。カーネル数64, カーネルサイズは(3,3).

L_6 : プーリング層。プーリング演算時のウィンドウサイズは(2,2).

L_7 : 全結合層。

L_8 : ドロップアウト層。ドロップアウト率は0.5.

L_9 : 出力層。

推定は次の手順で行う。

Step1: 道の周囲に存在するGPSデータを抽出する(図2)。

Step2: 道の中心から東西南北に一定距離ずつ伸ばした正方形の範囲を、 $n \times n$ の格子状に区切る*2(図3)。

Step3: 格子状に区切られた各マスにおけるGPSデータの数をカウントし、 n 行 n 列の行列を生成する。

Step4: Step1~Step3を道 m 本すべてに対して行い、 (m, n, n) の3階テンソルを生成する。

Step5: 生成された (m, n, n) の3階テンソルを入力とし、それぞれの道が実際に通行可能かを教師ラベルとしてCNNで教師あり学習を行う。

Step6: 学習し作成した推定器を用いて、未知の道の通行可否を推定する。

6. 実験

6.1 実験目的

本実験の目的は、5.3節で述べた提案手法がどの程度の精度で道ごとの通行可否を推定できるのかを検証することである。




図2 道の周囲に存在するGPSデータ

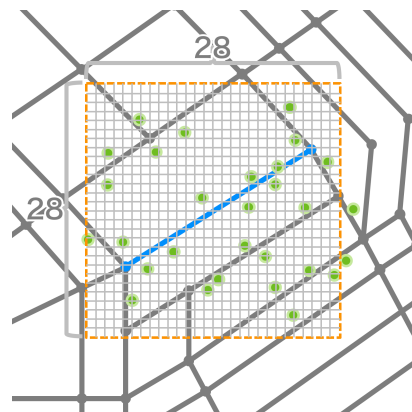


図3 格子状に区切られた正方形の範囲

6.2 データセット

本実験では10代~70代の96名(男性48名, 女性48名)の被験者の移動時GPSデータ(緯度・経度)を使用する。被験者にはスマートフォンを携帯した状態で屋外の指定のコースを歩いてもらった。GPSデータの収集には12台のスマートフォンを使い、1日あたり12人ずつ、8日間にわたり収集した。サンプリングレートは1Hzとした。スマートフォンごとの収集したGPSデータ数を表1に示す。

5.1節で述べたように、本実装では一定時間おきのGPSデータを疎な移動履歴として利用する。そこで今回は、携帯電話事業者が携帯情報端末に搭載している、現在地を自動的に測位する端末機能[8]の位置測位サイクルが5分間隔であることを参考にし、収集したGPSデータを300個とばし(1/300Hz)でサンプリングし、得られた計1081個のGPSデータを利用する。

通行可否推定対象とする道に関しては、5.2節で述べた通りに、1081個のGPSデータのうち、1つ以上のGPSデータが道の周囲に存在している道とする。

また、通行可否推定対象の道それぞれに対して、その道が、被験者に歩いてもらった指定のコースに含まれているか否か、つまり、実際に通られたか通られていないかを教師ラベルとして付与する。

*2 今回は道の中心から東西南北に25mずつ伸ばし、 $n=28$ で実装した。適切な値については今後も検証を続ける必要がある。

表 1 収集した GPS データ数

スマートフォン	GPS データ数 (1Hz)
A	24633
B	31622
C	29800
D	31074
E	23932
F	22000
G	23746
H	22799
I	25750
J	30878
K	30183
L	29027

6.3 実験手順

用意した 1081 個の GPS データと、通行可否推定対象の全ての道を用いて、5.3 節で述べた手順で推定を行う。

はじめに、教師ラベルが付与されている教師あり道データのうち、75%を訓練データとして無作為に抽出する。次に、訓練データを CNN で学習^{*3}して推定器を作成する。この推定器を用い、教師あり道データの残り 25%の教師ラベルを推定し、推定精度 (Recall, Precision, F-measure) を測定する。上記試行を、無作為に抽出する訓練データを毎回変えながら、50 回繰り返す。

そして、分類するクラスが、その道が実際に通られたか通られていないかの 2 クラス存在するため、それぞれのクラスにおける推定精度を測定する。

6.4 結果・考察

実験の結果を図 4, 図 5 に示す。推定を 50 回行って得られた推定精度の平均値は、移動実績のある、通行可能な道については Precision:0.56, Recall:0.42, F-measure:0.47, 移動実績のない、通行可否が不明な道については Precision:0.83, Recall:0.89, F-measure:0.86 となった。

今後研究を進める上で、どの評価指標に着目したうえで推定精度向上を図るべきかについて、それぞれのクラスにおける誤判定の望ましさの観点で考察を述べる。通行可能クラスの道に関しては、実際は通行可能な道を検出しきれずに取りこぼしてしまうことはあってもいいが、実際には通行可否不明な道を通行可能な道であると推定してしまうような誤検出があることは望ましくない。よって、通行可能クラスにおいては Precision が高くなるのが望ましいと考えられる。通行可否不明クラスの道に関しては、実際は通行可否不明な道を検出しきれずに取りこぼしてしまうこと、実際は通行可能な道を通行可否不明な道として誤検出すること、どちらも同程度に望ましくない。よって、通行可否不明クラスにおいては F-measure が高くなるのが

^{*3} 今回の CNN のハイパーパラメータは、Optimizer は Adam, Minibatch Size は 100, Epoch 数は 40, とした。




図 4 実験結果 (通行可能クラス)




図 5 実験結果 (通行可否不明クラス)

望ましいと考えられる。

7. おわりに

本稿では、携帯電話事業者などで既に移動履歴が蓄積されていることに着目し、疎な移動履歴から道ごとの通行可否を推定する方式を提案した。道の周囲を格子状に区切り、各マスにおける移動履歴の数をカウントしたものを CNN で学習することで、道ごとの通行可否を推定する手法を提案し、一定時間おきの GPS データを用いて道ごとの通行可否を推定する検証実験を行った。

参考文献

- [1] AMERICANS WITH DISABILITIES ACT of 1990, 入手先 <https://www.ada.gov/pubs/ada.htm> (2020.02.21).
- [2] Brajdic, A. and Harle, R.: Walk Detection and Step Counting on Unconstrained Smartphones, Proc. UbiComp '13, pp.225–234, ACM (2013).
- [3] Bae, S., Ferreira, D., Suffoletto, B., Puyana, J.C., Kurtz, R., Chung, T. and Dey, A.K.: Detecting Drinking Episodes in Young Adults Using Smartphone-based Sensors, Proc. IMWUT '17, Vol.1, No.2, Article No.5, 36pages, ACM (2017).
- [4] 宮田章裕, 王 統順, 荒木伊織, 篠崎涼太: 健常歩行者センサーデータからのバリア検出のための屋内外別機械学習方式, 情報処理学会論文誌, Vol.59, No.9, pp.1774–1782 (2018).
- [5] Akihiro Miyata, Iori Araki and Tongshun Wang: Barrier Detection Using Sensor Data from Unimpaired Pedestrians, Proc. HCI '18, Vol.10908, pp.308–319, Springer (2018).

- [6] 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態の推定, DEIM '16 (2016).
- [7] Kurauchi, Y., Abe, N., Konishi, H. and Seshimo, H.: Barrier Detection Using Sensor Data from Multiple Modes of Transportation with Data Augmentation, Proc. COMPSAC '19, pp.667–675, IEEE (2019).
- [8] オート GPS — サービス・機能 — NTT ドコモ, 入手先 <<https://www.nttdocomo.co.jp/service/auto-gps/>> (2020.02.21).