

人感センサーデータと機械学習による移動体の動線推定

岡部 亮平† 久保田 稔†

千葉工業大学†

1. はじめに

近年、センサデバイスや GPS 等を利用し、移動体の動きの軌跡（以降、動線と呼ぶ）の情報を活用したサービスの需要が拡大している。そのため、移動体がどのようなルートを通じたかを推定する技術（以降、動線推定と呼ぶ）が重要である。本稿では屋内における人を移動体とし、出発地点から目的地への移動経路を動線とする。

屋内では屋外のように技術が十分に確立されておらず、屋内の動線推定では様々な手法が検討されている。先行研究[1][2]では、赤外線センサ（以降、単にセンサと呼ぶ）を用いて、動的に動線推定を行うことにより動線をリアルタイムで利用できるようにした。また、屋内の動線推定方式の評価を容易にするため、Multi Agent Simulation である artisoc 4[3]を用いて、屋内での赤外線センサや人の動きを模擬する環境（以降、環境シミュレータと呼ぶ）を構築した。

環境シミュレータが模擬する人の移動の軌跡に関するデータを動線データ、模擬するセンサの出力値をセンサデータと呼ぶ。本稿ではこれらのデータを機械学習により学習させ動線推定を行い、実装した機械学習の性能と目的地推定の精度を評価する。

2. 関連研究

屋内の動線推定の手法には、カメラやセンサなどのデバイスを使ったものが一般的であり、データの計測は実際の環境下で行われる。文献[4]は、フィンガープリントを利用し動線推定を行っている。取得したデータを機械学習で学習させることにより推定結果を出している。

機械学習で学習させる際には多量のデータを必要とするため、本稿では環境シミュレータを用いてセンサデータを生成し、それと動線データを用いて畳込ニューラルネットワーク（以降、CNN と呼ぶ）にて学習を行う。

3. 提案手法

環境シミュレータは、人エージェント（以降、HA と呼ぶ）、チェックポイント（以降、CP と呼ぶ）、センサエージェント（以降、SA と呼ぶ）から構成される。HA は屋内環境において、CP を経由して目的地に移動する。CP は目的地までの経路の途中に存在する経由地点でありこれを用いて動線データを生成する。SA は検出範囲内に HA が存在する場合にその時刻と当該のセンサの番号を生成する。今回環境シミュレータの対象とする環境を図 1 に示す。




図 1. 提案手法の環境

センサデータは、人が通ったセンサ番号と通過時の時刻からなる。動線データは予め設定した地点情報（図 1 の■）からなる。

センサデータと動線データをあわせて CNN で学習させる。提案手法の概要を図 2 に示す。

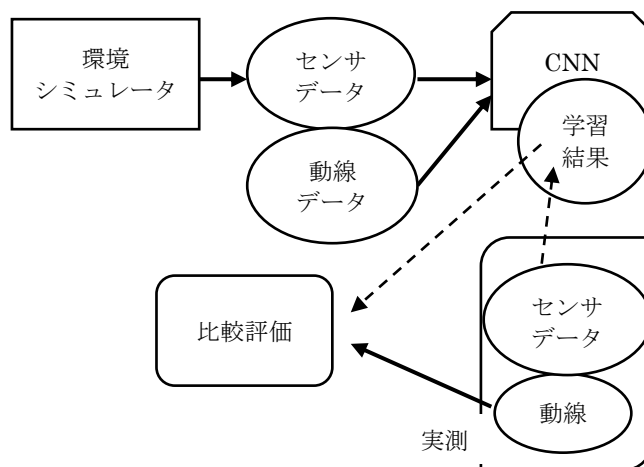


図 2. 提案手法の概要

4. 実験システム

環境シミュレータから生成したセンサデータと用意した動線データを CNN に入力し学習させていく。実装した CNN の仕様を表 1 に示す。

CNN は、順伝播型人工ニューラルネットワークの一種であり、画像、動画認識に広く使われている。CNN は最低限のデータ前処理しか必要としないように設計された多層パーセプトロンのバリエーションを使用する。

表 1. 実装した CNN の仕様

入力層のサイズ	50 (数値の根拠)
隠れ層の数	3
隠れ層のユニット数	50
出力層のサイズ	10
活性化関数	ReLU 関数※1
誤差関数	Mean_squared_error
勾配法	RMSprop※2
学習回数	1000 回

※1: 入力値が 0 以下のときは 0, 1 以上のときは入力をそのまま出力する関数

※2: 適応的学習率の方式のことであり、勾配の二乗の指数関数的減衰平均の除算

CNN の実装には、TensorFlow と Keras を用いた。TensorFlow は、Google によって開発された高速数値解析用の Python ライブラリである。Keras は、TensorFlow などのテンソル計算を高速に行うライブラリをバックエンドに持つ、ディープラーニング向けの上位ライブラリである。

5. 評価

二値分類は、入力として与えられたデータを Positive (正) か Negative (負) かを判別する評価方法である。評価指標として、正解率、適合率、再現率、特異度が利用され、精度と再現率の調和平均として F 値を利用することが多い。

本稿でも、実装した機械学習の性能を二値分類で評価を行った。環境シミュレータが生成したセンサデータと動線データを取り込んで学習させた後、実測のセンサデータを入力して推定した動線と目的地と、実際の動線と目的地を比較する。結果を図 3 に示す再現率は 0.9 を超えており、実用に耐える性能があるといえる。

また、目的地推定の精度評価も行った。図 4 に評価結果を示す。図 4 はエレベータホールからの移動先 (目的地) を示している。推定精度はどれも 0.9 を超えており、先行研究のアルゴリズムで実測を基に推定をした際の精度 (0.8 程度) より高い精度で目的地推定を行えた。




図 3. 実装した機械学習の性能評価




図 4. 目的地推定の精度

6. まとめ

本稿では、機械学習を用いて屋内における移動体の動線推定を行う方式を提案した。先行研究のアルゴリズムの推定に比べ、高い精度で目的地推定を行うことができるようになった。今後の課題は、移動体を増やし検証を行うこと、実環境下で動線データを取得し学習させる違う環境でも適応可能か検証すること、である。

参考文献

- [1] 細川了史 他, “無線センサデバイスによる屋内における移動体の動線推定,” FIT2015, Vol.14, No.4, pp.315-316.
- [2] 細川了史 他, “動線推定のための移動体環境シミュレーション,” 2016 信学ソ大, B-18-29.
- [3] 株式会社構造計画研究所, “aritsoc 4,” <https://mas.kke.co.jp/artisoc4/>
- [4] X. Gan, et al., “Deep Learning for Weights Training and Indoor Positioning Using Multi-sensor Fingerprint,” Proc. IPIN 2017, pp.1-7.