

避難訓練におけるセンサデータからの個人行動抽出アルゴリズム開発

高橋徹*, 高橋聡*, 北澤正樹**

*東京理科大学, **東京工業大学

1. はじめに

建物からの避難のしやすさを評価・改善する活動は、火災や地震発生時の被害を低減させるために重要な役割を果たす。これに関連して、人間の避難行動を記録して特徴的な迷い行動を分析することで、避難のしやすさの評価・改善に結び付けようとする研究が存在する。なお、ここでの避難行動とは避難訓練などの疑似的な避難におけるものを意味する[文献:1-3]。しかしながら、収集した個々人の映像データをすべて分析するには多大な人的・時間的リソースが必要となる。例えば、Shields らの実験では50台のカメラを用いて2000人の映像を撮影しているが、1度の避難訓練が10分程度だと仮定した場合、のべ500分の映像データを解析する必要がある。ここで、従来の避難者行動分析における分析フローは概ね以下のようなものとなる。

(ステップ1) 避難訓練における映像データ収集

(ステップ2) 全ての映像データを目視で分析し、実験協力者の特徴的な行動を抽出

(ステップ3) 抽出した特徴的な行動の具体的な分析

(ステップ3)における映像データに対する分析は、個々の建物における避難のしやすさを把握する上で重要なタスクである。しかし、(ステップ2)における目視による映像データの分析にかかる人的・時間的コストは、映像の時間と映像数に比例して増加するため、避難が長時間で複数のカメラを使うような大きな建物では分析にかかるコストは巨大になる。そこで、本研究では分析にかかるコストの低減を目的として、ウェアラブルセンサーと機械学習を利用することにより、避難行動における特徴的な行動の抽出を自動化する手法を提案する。

2. 提案手法

本研究では、ウェアラブルセンサーと機械学習を用いることにより、避難行動における特徴的な行動の抽出を自動化する手法を提案し、その評価を行う。提案手法における分析フローは以下のようなものとなる(Fig. 1)。

(ステップ1) 実験協力者にセンサーを装着し、避難訓練におけるセンサデータと映像データ収集

(ステップ2) センサデータを機械学習で分析し、実験協力者の特徴的な行動の時刻と場所を抽出

(ステップ3) 抽出した時刻と場所の映像データを目視で分析し、特徴的な行動の具体的な分析

提案手法では、実験協力者に装着したセンサーを機械学習で分析させることで、避難訓練における各実験協力者の特徴的な行動の時刻と場所を自動的に抽出することができる。映像データの分析者はこれらの結果を利用することで、特徴的な行動の発生している時刻と場所の映像データにのみ分析を集中させることができるため、分析にかかる人的・時間的コストの削減が可能となる。

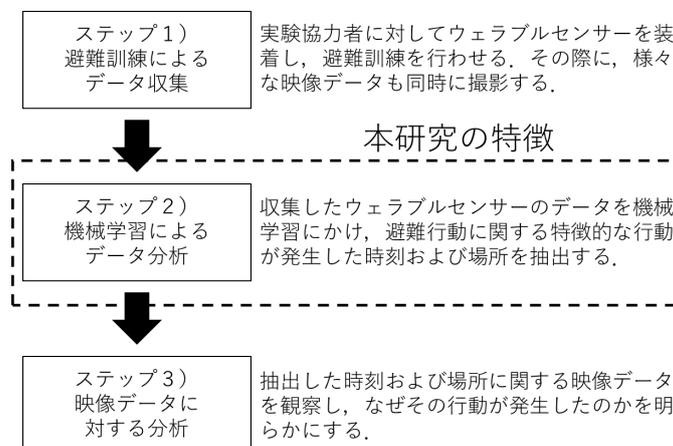


Fig. 1: 提案手法による分析フロー

2.1. ウェアラブルセンサー

提案手法では、実験協力者に対して、各部位の加速度および位置を計測するためのウェアラブルセンサーを装着する。本研究では、加速度に関してはIoT Smart Module センサネットワークモジュール開発キットを使用した[文献:4] (Fig. 2)。加速度の測定範囲は[-2, +2]G, 測定感度は0.24mG/LSB, サンプルレイトは10Hz であり、センサデータはAndroid 端末で受信して記録した。また、位置情報の測定に関しては、Bluetooth Low Energy beacon としてStickNFindを使用し、Gateway(GW)としてIGNIS 社の iGS01 を使用した[文献:5] (Fig. 3-4)。サンプルレイトは同様に10Hz であり、センサデータはGWを通じてサーバーへ送信し記録した。

実験協力者への装着例を Fig. 5 に示す。加速度センサーは頭部・右手首・腰・右足首に装着する (Fig. 5 ①②③④)。また、beacon はカードホルダーを利用して首から下げる (Fig. 5 ⑤)。GW は避難経路上の分かれ道や案内板などの各所へ配置する。



Fig. 2: IoT Smart Module センサネットワークモジュール開発キット



Fig. 3: ビーコン



Fig. 4: ゲートウェイ

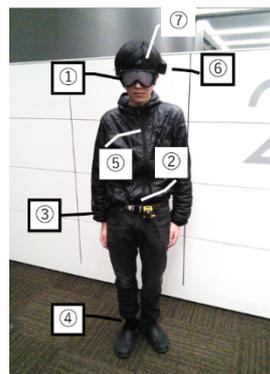


Fig. 5: センサー, カメラの装着例

①②③④: 三軸加速度センサー, ⑤: beacon, ⑥: ビデオカメラ, ⑦: 視覚障害ゴーグル

2.2. 機械学習による特徴的な行動の抽出

(ステップ1)において収集した加速度センサーのデータを用いて、避難訓練における特徴的な行動を抽出する。本研究は評価手法の分析フローの提案を行っている。そのため、行動の分析が高精度で行えるのであれば、どのような機械学習を用いても問題ない。本研究では、近年精度の向上が著しい deep neural network の一種で、時系列データを扱うのに使用されている Long Short Term Memory (LSTM) を用いて収集したセンサデータの解析を行った[文献:6]。

2.3. 映像データによる特徴的な行動の分析

(ステップ2)で抽出した特徴的な行動の発生している時刻と場所に関する映像データを観察し、その特徴的な迷い行動がなぜ発生したのかを明らかにする。提案手法では、時刻と beacon データおよび GW 設置位置を紐づけることにより、どの場所で発生したのかについても把握することができる。映像データとしては実験協力者の頭部に装着するウェアラブルビデオカメラの映像と実験協力者の全体が撮影された映像の2種類を利用する。頭部ウェアラブルビデオカメラの映像により、実験協力者が何を見ていたのかを把握することができる。さらに、全体が撮影された映像から、実験協力者がどのような行動を取っていたのかを把握することができる。これらの映像の分析により、実験協力者が具体的に何をきっかけに迷い行動を引き起こした

のかを明らかにする。

3. 実験環境および結果

本章では、機械学習の教師データの作成手法について述べた後に、実施した実験環境と実験結果を(ステップ 1)から(ステップ 3)に分けて説明する。

3.1. 機械学習の教師データの作成手法

提案手法では、実験協力者に装着した4つの3軸加速度センサーから得られる加速度を入力して、機械学習によって特徴的な行動を抽出する。実際の提案手法の利用時は既に学習済みの分類器を利用して特徴的な行動を抽出することを想定しているが、本研究ではデータ収集の他に、収集したデータを分類器に学習させるための教師データを作る必要がある。

本研究では映像データに対して施した真値タグ付けによる動作ラベルを教師データとして用いた。McAtamney らは工場における作業者の行動パターンを身体の部位の角度によって定義している[文献：7]。そこでMcAtamney らの手法を参考に、0.1秒ごとの実験協力者の「体全体」「頭部」「手首」それぞれの角度を基準として Table 1 に示すタグ付けを行った。「体全体」のタグに関しては、直立不動かつ重心の移動が無い状態を“stop”，それ以外で直進しているものを“move_straight”，他のパターンは“move_turn”とした。また「頭部」のタグに関しては、顔の向きが体と進行方向に直角な円錐から20度ほど外れた場合を“browse”，それ以外を“usual”とした(Fig. 6)。さらに「手首」のタグに関しては、鉛直からおおよそ45度の場合に“low”，45度から90度の場合に“mid”，90度以上の場合に“high”とした(Fig. 7)。分類器に学習させる教師データでは、これらのタグの直積を用いて stop@usual@low や move_straight@browse@low のように表現する動作ラベルを用いた。

Table1:真値タグ付け用タグ

体全体	頭部	手首
stop move_straight move_turn	usual browse	low mid high

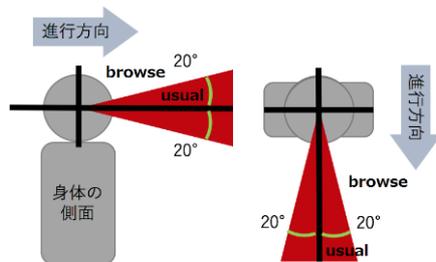


Fig. 6: 頭部の基準

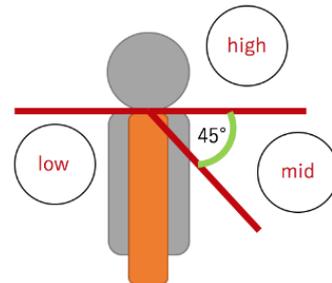


Fig. 7: 手首の基準



Fig. 8: 中2階の映像

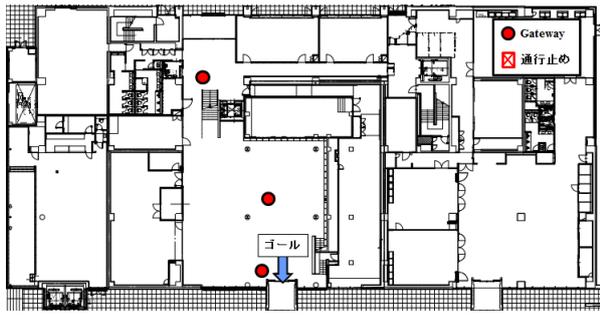


Fig. 9: 図書館1階の平面図

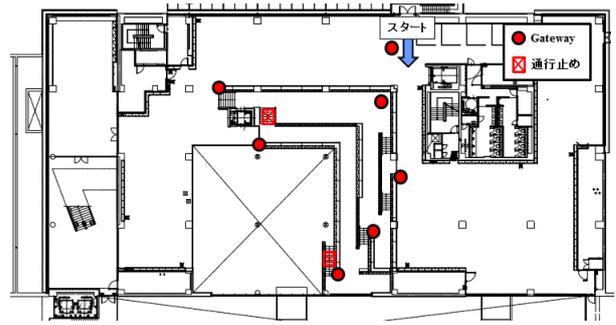


Fig. 10: 図書館2階の平面図

3.2. (ステップ1)避難訓練におけるデータ収集

ある図書館において、火災による避難訓練の形式で実験を実施した。実験を行った図書館は1階および2階とその間に2つの階層が存在する4階層で構成されている (Fig. 8-10)。実験協力者の経路を特定するため、図書館内にはスタートからゴールに至る過程での分岐点に対してGWを10個設置した。さらに、実験協力者の迷い行動を引き起こすため、2か所通行止めを追加した。

本研究で対象とした実験協力者は20代の男性7人である。まず、実験協力者を入り口から避難のスタート地点へ移動させる際は目隠しをさせ、避難経路を把握させないようにした。次に、実験協力者にウェアラブルセンサーと、火災により煙幕が発生した状況を想定して視覚障害ゴーグル [文献:8] を着用させた (Fig. 5 ⑦)。そして、1階正面入り口を目指すように指示して2階の奥からスタートさせた。

Table 2: 各動作ラベルのレコード数

動作ラベル	レコード数
move_straight@usual@low	6802
move_straight@browse@low	4264
move_turn@browse@low	1735
move_straight@browse@mid	926
stop@usual@low	681
move_straight@usual@mid	384
move_turn@browse@high	298
stop@browse@low	219
move_turn@usual@low	172
move_turn@browse@high	71
move_straight@browse@high	41
move_straight@usual@high	19
move_turn@usual@mid	18
stop@browse@mid	7

Table 3: 統合後の動作ラベルとレコード数

動作ラベル	レコード数
move_straight@browse@low (C ₁)	6802
move_straight@usual@low (C ₂)	4264
serious browse (異常行動)	4571

Table 4: 混同行列

教師 \ 予測	C ₁	C ₂	C ₃
C ₁	126	166	51
C ₂	293	477	81
C ₃	185	118	203

実験の結果、7人分の加速度、ビーコン強度、映像データの収集に成功した。データのサイズは全部で15637レコードであった。なお、加速度と beacon のデータは10Hz ごとに収集されているため、1レコードは0.1秒に対応している。収集した全レコードに対して事前に定めた手法で真値タグ付けを行い、各動作ラベルのレコード数をカウントした結果を Table 2 に示す。Table 2 より、極一部の動作ラベルが非常に多い不均衡データであることが確認できた。データ数が少ない動作ラベルは学習がしにくく機械学習の精度が低下するため、まれに起こる動作ラベルを1つに統合してレコード数を補正することで高精度化をはかった。具体的には、レコード数が非常に多い move_straight@usual@low と move_straight@browse@low を除いた動作ラベルを serious_browse (異常行動) としてまとめた (Table 3)。なお、Table 3 の各動作ラベルの横に記載された C₁, C₂, C₃ はそれぞれの動作ラベルの略称を示す。

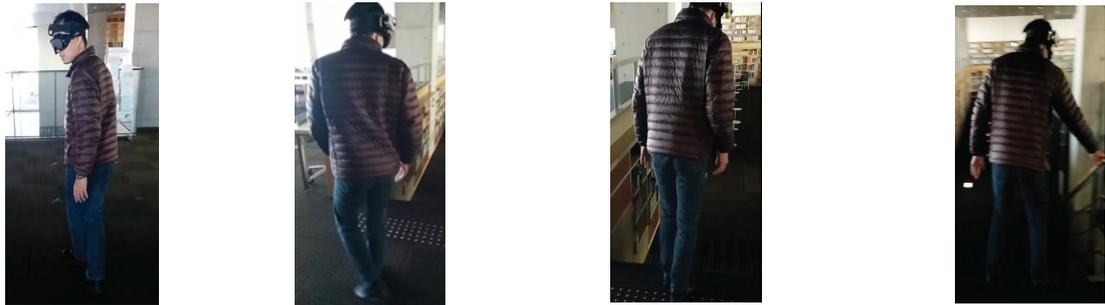
3.3. (ステップ2)機械学習による特徴的な行動の抽出

(ステップ1)で収集した加速度データに対して、機械学習による行動抽出を行った。本研究では機械学習のモデルとして dropout 無しの単層 LSTM に続いて分類器の学習をするために softmax 層を繋げたものを使

用した。また、誤差関数は `cross_entropy` に正則化項として中間層の重み行列の L2 ノルムに係数をかけたものを採用した。なお、今回は分析する `Window_Size` を 15 と設定したため、各実験協力者の初め 15 レコードはデータ数不足により予測することができない。

本研究では、まず 7 人の実験協力者(総レコード数 15637)のうち、1715 レコードを持つ 1 人の実験協力者を分類器の予測精度計算のための評価用データとして分割した。そして、残りの 13922 レコードのうち予測可能な 13832 レコードを、10%を検証用データ、90%を訓練用データと分割して、加速度データから動作ラベルを分類する学習を行った。100000 ステップの学習により、検証用データに対して分類精度 76.4%を達成した分類器を用いて評価用データを予測した結果、46.8%の精度を達成した。評価用データに対する予測の `precision` と `recall` は共に 47.4%を達成した。Table 4 に予測を行った 1700 レコードの混同行列を示す。

評価用データの実験協力者においては、全部で 172 秒のうち、35 秒から 55 秒、85 秒から 115 秒、135 秒から 145 秒の合計 60 秒の行動が `serious_browse` (異常行動) と判定された。この該当時間がどのような迷いの行動のタイミングであるか、映像データから確認する。



(a) 方向の探索 1 (b) 方向の探索 2 (c) 階段を見に顔を下げる (d) 手すりに腕を伸ばす

Fig. 11: 評価用データの実験協力者の 35 秒から 55 秒に見られる特徴的な行動

3.4. (ステップ3)映像データによる特徴的な行動の分析

(ステップ2)で抽出した `serious_browse` (異常行動) が、実際の迷い行動と対応しているか映像データをもとに確認する。ここでは評価用データの実験協力者の 35 秒から 55 秒のあいだの行動に注目する。映像データより抽出した特徴的な行動を Fig. 11 に示す。この時間の実験協力者は図書館の廊下をゆっくりと歩いていたが、立ち止まると今まで進んできた道を少し戻って進むべき方向を探索した。その後、階段を見つけて階段の手前まで進むと、階段の先を下方向にのぞき込むような行動を取り、さらに、大きく手を伸ばして手すりを掴んでからゆっくりと階段を降りだした。これらの特徴的な行動は、該当地点に屋外に出られる 1 階正面入り口への誘導がないことと、階段の段差の境目が判別しづらいことが原因だと考えられる。よって、避難誘導灯の設置や階段の段差ごとに色を変更するといった対策の提案に繋げることができる。

このように、提案手法の特徴的な行動の自動抽出で、実験協力者の迷い行動のタイミングが実際に抽出できていることが確認できた。他の `serious_browse` (異常行動) と判定された時間帯においても迷い行動が確認されており、提案手法によって動画確認が必要な時間を評価用データの実験協力者の避難時間 172 秒から特徴的な行動があると抽出された合計 60 秒へと短縮できた。

4. おわりに

本研究では、避難時の行動分析を用いた建物の避難安全性評価手法において、ウェアラブルセンサーと機械学習を利用して避難行動における特徴的な行動抽出を自動化することで、分析の時間的コストを減少させる手法を提案し、評価を行った。提案手法は、実験協力者の頭部・手首・腰・足首に加速度センサーを装着して避難時の行動の加速度データを収集し、収集したデータに機械学習の LSTM を適用して特徴的な行動の発生タイミングを自動で抽出する手法である。提案手法の評価実験として、図書館を舞台にした避難訓練で実験協力者 7 人の避難行動データを収集して分析を行った結果、評価用データとした実験協力者の避難行動 172 秒から合計 60 秒の特徴的な行動部分を抽出し、該当時間は実際に実験協力者の迷い行動のタイミングであることが確認できた。本提案手法の展開により、異常行動分析を用いた建物の避難安全性評価において、分析の時間的コストの減少が期待できる。

謝辞

本研究は中部大学問題複合体を対象とするデジタルアース共同利用・共同研究 IDEAS201613 の助成を受けたものです。

参考文献

- 1) Shields, T.J. and Boyce, K.E.: "A study of evacuation from large retail stores", *Fire Safety Journal*, **35**-1, 25/49 (2000)
- 2) 佐野友紀, 竹市尚広, 木村謙, 大宮屈文, 吉田克之, 渡辺仁史: "高層建築物避難を想定した階段室における在館者群集の合流特性", *日本建築学会計画系論文集*, **598**, 51/56 (2005)
- 3) 横山秀史, 永田茂, 山崎文雄, 海老原学: "迷路実験による緊急時の人間行動特性", *土木学会論文集*, **441**, 107/115 (1992)
- 4) アルプス電気株式会社: "センサネットワークモジュール開発キット(国内・法人使用限定)", <http://www.alps.com/j/iot-smart-network/index.html> (2017年1月8日参照)
- 5) INGICS TECHNOLOGY CO., LTD. : "BLE_WiFi Gateway iGS01 User Guide Ver. 3", https://www.ingics.com/doc/iGS01/BLE_WiFi_Gateway_iGS01_User_Guide.pdf (2017年1月8日参照)
- 6) Zaremba, W., Sutskever, I. and Vinyals, O.: "RECURRENT NEURAL NETWORK REGULARIZATION" (2015)
- 7) McAtamney, L. and Corlett, E.N.: "RULA: a survey method for the investigation of work-related upper limb disorders", *Applied Ergonomics*, **24**-2, 91/99 (1993)
- 8) 株式会社三和製作所: "高齢者疑似体験教材", <https://www.sanwa303.co.jp/products/medicare/teaching-material/104-994> (2017年1月10日参照)

発表論文

- 1) Masaki Kitazawa, Satoshi Takahashi, Toru B. Takahashi, Atsushi Yoshikawa, Takao Terano: "Improving a Cellular Manufacturing System through Real Time-Simulation and -Measurement", *The 3rd IEEE International Workshop on Social Services through Human and Artificial Agent Models (SSERV2016) on The 40th IEEE Computer Society International Conference on Computers, Software & Applications (COMPSAC2016)*, Atlanta, USA, pp. 117-122 (Jun. 2016).
- 2) Masaki Kitazawa, Satoshi Takahashi, Toru B. Takahashi, Atsushi Yoshikawa, Takao Terano: "Combining Workers' Behavior Data and Real Time Simulator for a Cellular Manufacturing System", *10th International Forum on Biomedicine, Multimedia and Image Processing (IFMIP2016) on World Automation Congress 2016 (WAC2016)*, Rio Grande, Puerto Rico, (Himeji, Japan : Satellite), pp. 1-6 (Aug. 2016).
- 3) Masaki Kitazawa, Satoshi Takahashi, Toru B. Takahashi, Atsushi Yoshikawa, Takao Terano: "Real Time Simulator with Multiple Worker's Behavior Data for a Cellular Manufacturing System", *Korea-Japan Social Simulation Workshop 2016 (JaKoSS 2016)*, Seoul, Korea, pp. 337-344 (Oct. 2016).
- 4) 黄冬陽, 相田晋, 北澤正樹, 高橋聡, 高橋 B. 徹, 吉川厚, 寺野隆雄: "ウェアラブルセンサーを用いた機械学習による避難評価手法", 第12回社会システム部会研究会, 計測自動制御学会, Guam, USA, pp. 52-61 (Mar. 2017) .
- 5) 北澤正樹, 高橋聡, 高橋 B. 徹, 吉川厚, 寺野隆雄: "ウェアラブルセンサーを用いた作業員動作分析によるセル生産ラインのリアルタイム生産進捗計測システムの提案", 第12回社会システム部会研究会, 計測自動制御学会, Guam, USA, pp. 228-235 (Mar. 2017) .