

[研究助成 (A)]

実現場での階段昇降時動作データに基づいた転倒を検知するための機械学習的アプローチ

2241010



研究代表者
(助成金受領者)
共同研究者

豊田工業高等専門学校 一般学科

准教授

加 藤 貴 英

豊田工業高等専門学校
情報工学科

教 授

早 坂 太 一

愛知医科大学 医学部

講 師

川 越 隆

国立長寿医療研究センター
フレイル研究部

副部長

大須賀 洋 祐

豊田工業高等専門学校

校 長

山 田 陽 滋

[研究の目的]

加齢に伴い、転倒の頻度は増加する（WHO, newsroom “Falls”, 2021）。今日の超高齢社会において、転倒による骨折や転倒後症候群（精神的なダメージ）は医療費と要介護者の増加に拍車をかけ、延いては我が国の経済的負担をさらに増幅させることとなる。このような医療介護の負のスパイラルに歯止めをかけるためにも、科学的エビデンスに基づいた転倒検知システムを構築することは社会的にも重要な意義を持つ。事実、諸外国だけでなく我が国においても高齢者の身体機能データと転倒履歴（Hasegawa et al., 2023）や自己報告式問診票データ（Ikeda et al., 2022）を基に機械学習を用いた転倒診断モデルの検証が進められている。

転倒の発生率が高い場所の1つに階段があげられる。階段昇降時は、片足で踏み昇る動作と片足で踏み降りる動作を左右交互に、かつバランスを保持しながら行わなければならない。また、視覚からの踏み位置情報を即座に、かつ自動的に処理して動作する必要がある。この様に歩行動作よりも複雑なメカニズムを持つ階段昇降動作の3次元解析は、転倒検知の観点から欠かせない課題である。しかしながら、解析機器

の仕組み上、屋外や実現場での階段昇降時の3次元動作解析は寡少である。また、加齢に伴う筋力やバランス能力の低下、視覚認知機能の低下が転倒リスクの増加に起因していることから、あらゆる世代の階段昇降時の動作データを収集し、比較・検証する必要がある。

そこで、本研究では体力テストによる客観データと問診による主観データから見た転倒リスクに対する加齢の影響を検証するとともに、幅広い年齢層の階段昇降時の3次元動作データを収集して機械学習的アプローチによる解析を行い、階段昇降時の動作パターンの識別を行うことを目的とした。そのために60歳代（高齢者）、40歳代（中年者）、20歳代（若年者）を対象に形態計測と体力測定、および転倒に関する問診を実施した。さらに最新の9軸慣性センサ式モーションキャプチャーシステムを用いて実現場での階段昇降時の3次元動作データを収集し、動作パターンの識別を試みた。

[研究の内容、成果]

1. 研究参加者

本研究は、「ヘルシンキ宣言」および「人を対象とする医学系研究に関する倫理指針」（文

部科学省，厚生労働省，経済産業省制定）を遵守し，豊田工業高等専門学校「ヒトを対象とする研究倫理審査」より承認を得て実施した。

参加者は，高齢者群 10 名（ 65 ± 3 歳），中年者群 10 名（ 45 ± 2 歳），若年者群 12 名（ 25 ± 2 歳）の計 32 名であった。研究参加者には事前に実験によって生じる負担や予測されるリスク等を口頭および書面にて説明し，研究参加者から同意書に署名を受けた。

2. 問診，形態計測および体力テスト

研究参加者は，転倒ハイリスク者の発見のための問診（鳥羽ら，2005）に回答した。この問診は，「過去 1 年間に転んだことはありますか」，「つまづくことはありますか」等，22 の設問に対し，「はい，いいえ」の 2 件法で回答するものである。問診後，自動血圧計による安静時血圧（収縮期，拡張期，脈拍），身長，体重，インピーダンス法による体脂肪率の測定を行った。その後，体力測定として握力，開眼片脚立ち，5 m 歩行速度，Timed up and go test（TUG）を測定した。握力は立位姿勢で左右 2 回ずつ測定し，それぞれ良い値の平均値を評価値とした。開眼片脚立ちは 2 回計測し，平均値を評価値とした。ただし，180 秒を上限とし，1 回目で 180 秒に達した場合は評価値を 180 秒とした。5 m 歩行速度は，両端に 3 m の加速路と減速路，計測区間を 5 m とした 11 m 歩行を通常速度で 2 回，最大努力で 2 回計測した。それぞれ平均値を評価値とした。TUG は，背もたれにもたれた状態で椅子に座り，手は膝の上に置いた状態を初期姿勢とした。最大努力速度で初期姿勢から立ち上がって，3 m 先に設置してあるコーンで U ターンし再び初期姿勢に戻るまでの時間を 2 回計測し，平均値を評価値とした。

3. 階段昇降動作データ収集


研究代表者の所属先校内にある階段を利用した。研究参加者は，専用ストラップおよびアンダーラップテープを使用して身体 17 箇所（①

頭，② 右肩，③ 右上腕，④ 右前腕，⑤ 右手，⑥ 左肩，⑦ 左上腕，⑧ 左前腕，⑨ 左手，⑩ 右大腿，⑪ 右下腿，⑫ 右足，⑬ 左大腿，⑭ 左下腿，⑮ 左足，⑯ 胸，⑰ 腰）に 9 軸慣性ワイヤレスセンサ（Movella 社製，Xsens MVN Awinda，通信距離 50 m，出力レート 60 Hz）を装着した（画像 1）。

センサ装着後，キャリブレーションを行いセンサが良好状態であることを確認して計測を 2 回行った。研究参加者は校舎 3 階から 4 階までの階段を昇り，4 階廊下で U ターンした後，4 階から 3 階まで階段を降りた。階段の段数は 3 階から途中の踊り場まで 10 段，同様に踊り場から 4 階まで 10 段であった。1 段の高さは 18 cm であった。専用レシーバを介して階段昇降時のデータを取り込み，専用解析ソフトウェア（Movella 社製，Xsens MVN Analyze Pro）で 1 次処理を行った。得られた加速度・角速度・方位情報を 3 次元身体モデルに反映させ，数値データは CSV ファイル形式で，3 次元身体モデル動画は MPEG-4 ファイル形式で保存した（画像 2）。



画像 1 センサ装着の様子



画像 2 階段昇降動作中の 3 次元身体モデル

4. 機械学習手法

まず、動作識別の機械学習に利用できるオープンデータセット (Anguita, et al. 2013, Human Activity Recognition Using Smartphones: HAR) を用いて歩行動作予測モデルを構築した。HAR データセットでは、協力者が腰部にスマートフォンを着用し、3 軸の加速度が 50 Hz のサンプリング周波数で計測されている。各データは、Walking, Upstairs, Downstairs, Sitting, Standing, Laying の 6 つの動作別にラベリングされている。これらのセンサデータを 128 点ごとに、50% のオーバーラップを設けて抽出した。さらに、3 軸の加速度を直列に結合し、384 次元のデータとすることで、学習用およびテスト用データとした。機械学習は、Python 3.7, Scikit-learn 1.0.2 ライブラリを用いた決定木 500 本のランダムフォレストによって行った。

HAR データセットのセンサデータについて、構築した歩行動作予測モデルのテスト結果は、全体の F1-score が 0.819 となったものの、動きの小さい Sitting, Standing, および Laying では誤分類が多い結果となった (表 1)。しかしながら、本実験で取得したデータは、Walking, Upstairs, Downstairs の動作が主であるため、歩行動作予測に十分利用できると思われる。

表 1 推論モデルの学習結果

	Walk	Up	Down	Sit	Stand	Lay	F1-score
Walking	489	2	5	0	0	0	0.90
Upstairs	87	378	6	0	0	0	0.86
Downstairs	10	22	388	0	0	0	0.95
Sitting	0	2	0	279	177	33	0.61
Standing	3	0	0	71	441	17	0.75
Laying	0	0	0	71	26	440	0.86
全 体							0.819

テストデータ：2,947 件

5. 体力テストと問診から見た転倒リスクに対する加齢の影響

高齢者群、中年者群、若年者群の身長、体重、BMI (Body Mass Index)、体脂肪率を対応の

無い 1 元配置分散分析および Bonferroni 法による多重比較検定を行った結果、3 群に有意差はなかった。

次に、過去 1 年間に転倒したと回答した転倒群 9 名と転倒は無かったと回答した非転倒群 23 名に群分けした。そして、形態計測と体力測定データについて群間比較するために対応のない t 検定を行った。結果、形態計測項目である身長、体重、BMI、体脂肪率は両群間で有意差はなかった。体力テスト項目については、転倒群において安静時収縮期血圧が有意に高く、開眼片脚立ち時間が有意に短かった (表 2)。

表 2 形態計測および体力測定データの比較

	転倒群 n=9	非転倒群 n=23	対応のない t 判定
年齢 (歳)	53±18*	40±15	$t_{(30)}=2.206, p=0.035, d=0.833$
身長 (cm)	171.3±4.2	170.8±3.6	$t_{(30)}=0.398, p=0.693, d=0.151$
体重 (kg)	70.2±12.1	71.0±11.6	$t_{(30)}=0.167, p=0.868, d=0.065$
BMI (kg/m ²)	24.0±4.6	24.3±3.6	$t_{(30)}=0.204, p=0.840, d=0.075$
体脂肪率 (%)	20.9±9.7	20.5±5.5	$t_{(30)}=0.124, p=0.902, d=0.043$
収縮期血圧 (mmHg)	135.3±26.2*	118.6±12.1	$t_{(30)}=2.495, p=0.018, d=0.819$
拡張期血圧 (mmHg)	84.4±19.4	74.7±9.0	$t_{(30)}=1.953, p=0.060, d=0.642$
脈拍 (beats/min)	72.7±14.2	67.5±9.9	$t_{(30)}=1.179, p=0.248, d=0.424$
握力 (kg)	39.2±5.3	40.3±6.0	$t_{(30)}=0.498, p=0.622, d=0.201$
開眼片脚立ち (sec)	104.5±79.0*	158.2±48.4	$t_{(30)}=2.345, p=0.026, d=0.818$
5 m 通常歩行速度 (sec/m)	0.72±0.12	0.68±0.08	$t_{(30)}=1.227, p=0.229, d=0.431$
5 m 最大動力歩行速度 (sec/m)	0.43±0.09	0.41±0.07	$t_{(30)}=0.727, p=0.473, d=0.271$
Timed up and go test (sec)	5.30±0.92	4.85±0.60	$t_{(30)}=1.672, p=0.105, d=0.592$

平均値±標準偏差

* $p<0.05$, 転倒群 vs. 非転倒群

問診結果については、転倒歴の有無および各質問項目の回答からクロス集計を行い、Pearson のカイ 2 乗検定を行った。しかしながら、期待度数が条件を満たしていなかったため、Fisher の直接法による確率値を確認した。結果、転倒歴と有意な関係性を示す質問項目は確認できなかった。

これらの結果から、過去 1 年間の転倒経験率は高齢になるほど高まることが明らかとなり、これまでどおりの見解と一致した (WHO, newsroom “Falls”, 2021)。転倒経験率と体格との間に関係はみられなかった。そして、転倒経験者は安静時の血圧が高く、バランス能力が衰えていることも確認できた。一方、問診デー

タ間に統計的有意性を示す結果は得られなかったため、今後の研究ではさらなる検証を目的とした追加実験が必要である。

6. 機械学習的アプローチによる階段昇降動作パターンの識別

構築した歩行動作予測モデルについて、9軸慣性センサ式モーションキャプチャシステムによって収集したデータにおける腰部の3軸加速度のみを抽出し、予測を行った。これは、HAR データセットが腰部にスマートフォンを着用して3軸加速度を計測していることから、1箇所のセンサで動作パターンの識別が可能であることを確認するためであった。

図1に高齢者、図2に中年者、図3に若年者、それぞれ動作パターン識別の推定結果の代表例




図1 高齢者群参加者 A の動作パターン識別




図2 中年者群参加者 B の動作パターン識別




図3 若年者群参加者 C の動作パターン識別

を示す。機械学習に用いたデータは、19歳から48歳までの30名の協力者のものであったが、本実験においては、そうした年代に含まれない高齢者群（61～71歳）の参加者に対するWalking, Upstairs, Downstairs 状態の推定結果が比較的良好であった。

推定結果により参加者を2群に分け、各質問項目の回答からクロス集計を行い、Fisherの直接法による確率値を確認したが、有意な関係性を示す質問項目は確認できなかった。本研究における機械学習的アプローチによって、中年者および若年者のデータから構築されたモデルにより、高齢者の動作をある程度予測できることがわかった。しかしながら、腰部の3軸加速度データのみでは、問診および形態計測データや体力テスト結果との連関を見出すことはできなかった。今後は、他の16箇所のセンサデータや、それらの中の角速度および地磁気データを参照することで、動作パターンのさらなる予測精度向上を目指すとともに、転倒リスクの有無を判別できるモデルの構築に繋げていく。

[謝 辞]

本研究の実施にあたり、公益財団法人立石科学技術振興財団から格別のご支援を賜りましたことに、心より感謝申し上げます。また、機械学習的アプローチに多大なるご協力をいただいた豊田工業高等専門学校専攻科情報科学専攻修了生の山田活樹さん、ならびに現専攻科生の川原遼介さんには、深く感謝の意を表します。

[参考文献]

- ・ World Health Organization, newsroom “Falls”, 2021. <https://www.who.int/news-room/fact-sheets/detail/falls/> (最終アクセス日: 2025年5月26日)
- ・ Hasegawa S, Mizokami F, Kameya Y, Hayakawa Y, Watanabe T, Matsui Y. Machine learning versus binomial logistic regression analysis for fall risk based on SPPB scores in older adult outpatients. Digit Health. 2023, 11; 9: 20552076231219438.
- ・ Ikeda T, Cooray U, Hariyama M, Aida J, Kondo K, Murakami M, Osaka K. An Interpretable Machine Learning Approach to Predict Fall Risk Among

Community-Dwelling Older Adults: a Three-Year Longitudinal Study. J Gen Intern Med. 2022, 37(11): 2727-2735.

- ・ 鳥羽研二, 大河内二郎, 高橋泰, 松林公蔵, 西永正典, 山田思鶴, 高橋龍太郎, 西島令子, 小林義雄, 町田綾子, 秋下雅弘, 佐々木英忠. 転倒リスク予測のための「転倒スコア」の開発と妥当性の検証. 日本老年医学会雑誌, 2005, 42(3): 346-352.
- ・ Anguita D, Ghio A, Oneto L, Parra X, Reyes-Ortiz JL. A Public Domain Dataset for Human Activity Recognition using Smartphones, Proceedings of

European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, 2013, pp. 437-442.

[成果の発表, 論文など]

- ・ 加藤貴英, 早坂太一, 近藤雅哉, 川越隆, 大須賀洋祐. 体力テストによる客観データと問診による主観データから見た転倒リスクに対する加齢の影響. 日本体育・スポーツ・健康学会第75回大会. 2025年8月(発表予定)