

厚生労働科学研究補助金
労働安全衛生総合研究事業
(総括・分担) 研究報告書

ICT技術を用いた転倒予防システムの開発に関する研究

研究代表者： 丸山 崇 （産業医科大学 医学部 第1生理学）

研究要旨：

労働災害における「転倒災害」は2000年代以降増加傾向が続いており、2005年以降は死傷災害の中で最も多い災害となっている。現在、「転倒災害」は休業4日以上を要する労働災害全体の約25%を占めており、さらに墜落・転落災害を含めると全体の約40%以上に達することから、早急な対策が求められている。2023年4月より開始された「第14次労働災害防止計画」においても、「転倒による労働災害」への対策が新たに重点項目として盛り込まれ、労働安全衛生上の重要課題として位置づけられている。

一方、近年ではICT（Information and Communication Technology）技術の進歩に伴い、ウェアラブルセンサーを活用した生体情報計測技術が急速に発展しており、転倒発生後の検知のみならず、転倒リスク評価や転倒予防までを含めた包括的なシステムの開発が期待されている。

本年度は、模擬転倒実験において加速度センサーにより取得されたデータを用いて、AI解析を導入し、正常歩行と転倒動作の分類や転倒前動作パターンの特徴抽出を試みた。その結果、AI解析により転倒動作を一定程度識別可能であることが示された。

さらに、一部では転倒前の歩行リズムや身体動揺変化が検出され、転倒予測技術への応用可能性が示唆された。

次に、現場研究として、駐車場巡視・監視業務を行う70歳以上の高齢労働者を対象に、勤務時間中の加速度データおよびGPS位置情報を取得した。加速度センサーと位置情報を連動させて連続測定を行った。また、作業内容、作業負荷、自覚疲労度（自覚症しらべ）、つまずき・転倒発生状況についても記録した。取得データについてSMVおよびFall indexによる解析を行った結果、測定期間中に実際の転倒事例は認められず、転倒検知イベントも確認されなかった。さらに、現場研究ではBluetooth通信不良によるデータ欠損が発生し、現場での生体情報測定における課題も見つかった。

以上より、本研究では、加速度センサーとAI解析を組み合わせることで、転倒検知および転倒予測に応用可能なシステム開発の可能性が示された。また、高齢労働者の現場環境下における身体活動や身体動揺の連続記録により、現場データの取得による転倒検知や転倒予防システムの開発の可能性が示された。今後は、対象者数および測定期間の拡大、通信安定性の改善、多種生体情報との統合解析を進めることで、労働者の安全確保と転倒予防に資する実用的システム開発につなげていく必要がある。

研究分担者：

黒坂知絵（産業医科大学）

A. 研究の背景と目的

転倒災害は2005年以降、労働災害における死傷災害の中で最も多く、休業4日以上労働災害全体の約25%を占める重要課題となっている。2023年開始の「第14次労働災害防止計画」でも重点対策として位置づけられた。近年はICTやウェアラブルセンサー技術の進展により、転倒検知だけでなく転倒予防まで含めた包括的システム開発が期待されている。

また、我が国では高齢化が進行し、高齢労働者の就業機会が拡大している。一方で、高齢者では加齢に伴う筋力低下、平衡機能低下、感覚機能低下などにより、つまずきや転倒のリスクが増加することが知られている。転倒災害は、その後の就業継続や生活機能にも大きな影響を及ぼすため、労働安全衛生上の重要課題である。

加速度センサーを用いた身体動揺や転倒検知技術の開発を目指し、本研究に取り組んでいる。昨年度は、行動解析室において取得した模擬転倒実験での3軸加速度データを用いてSignal Magnitude Vector (SMV) やFall indexなどの指標により、急激な身体動作変化を定量化する試みを行なった。

本年度（令和7年度）の研究では、①模擬転倒実験データを用いたAI解析による転倒検知・転倒予測技術の検討、②高齢労働者の現場作業中に取得した加速度データによる転倒検知の検討、の2つの研究を実施し、現場応用可能な転倒リスク評価システム構築の基礎的知見を得ることを目的とした。

B. 研究方法

1. 模擬転倒実験データを用いたAI解析

令和6年度の本研究において実験室環境下において模擬転倒動作の加速度センサーデータ収集を行った。健常成人21名を対象に、転倒動作162件と日常生活動作（ADL）184件、計346動作を収集し、手首・体幹・脚から得られる3軸加速度データを解析した。収集された模擬転倒時の加速度データを用いて、評価には、被験者独立性能を検証するため、LOSO（Leave-One-Subject-Out）法を用いた。評価指標としてAccuracy, F1-score, False Negative (FN), False Positive (FP) を算出した。

2. 高齢労働者の現場作業データ解析

現場研究では、駐車場巡視および監視業務を行う70歳以上の高齢労働者6名を対象とした測定を行った。加速度センサー（Wit motion）を左腕、胸部、足首に装着し、スマートホンと連動させて勤務時間中の加速度データを記録した。

また、GPSによる位置情報を同時取得し、巡視経路や活動状況と加速度データとの統合解析を行った。さらに、作業内容、作業負荷、自覚疲労度（自覚症しらべ）、つまずき・転倒発生状況についても記録した。

取得した加速度データについて、SMVおよびFall indexによる解析を実施し、身体動揺や異常加速度イベントの抽出を試みた。

なお、本研究は倫理委員会での承認を得た上で実施されている。（産業医科大学倫理委員会 ER23-017）

C. 研究結果

1. 模擬転倒データを用いたAI解析

模擬転倒実験では、転倒時に特徴的な急峻な加速度変化が認められ、SMVおよびFall indexにおいて、転倒検知が可能と考えられた。今回のAI解析においては、正常動作と転倒動作の分類が一定程度可能であり、転倒時特有の加速度パターンが抽出された。また、一部のデータでは、転倒直前の5秒前、3秒前で予兆パターンの変化が認められ、AIによる転倒予測の可能性が示唆された。

2. 現場作業データ解析

高齢労働者の現場調査では、勤務時間中の連続的な加速度データおよびGPSデータを取得することができた。作業に伴う身体動揺が記録され、巡視行動の可視化が可能であった。

一方で、測定期間中に実際の転倒事例は発生せず、SMVやFall indexによる転倒検知イベントも認められなかった。

また、Bluetooth通信不良により、腕部および足首センサーのデータ欠損が生じたため、主として胸部センサーの解析を行った。胸部加速度データでは、作業時加速度が比較的安定して取得された。

D. 考察

本研究では、模擬転倒実験と実際の高齢労働者の現場データ解析を組み合わせることで、転倒検知および転倒予測技術の実用化に向けた基礎的検討を行った。

模擬転倒実験では、SMVやFall indexが転倒動作を反映する有用な指標であることが確認された。また、AI解析により、複雑な動作パターンを学習し転倒の予兆を捉えられる可能性が示された。特に、転倒直前の歩行変化や身体動揺変化を抽出できれば、将来的な転倒予測技術につながる可能性がある。

一方、現場研究では実際の転倒事例が発生しなかったため、転倒検知アルゴリズムの感度・特異度を十分に評価するには至らなかった。転倒は発生頻度が低い事象であり、実際の現場で転倒データを収集すること自体が難しいことが考えられる。そのため、今後は長期間測定や対象者数の拡大が必要である。

今後は、高齢者だけでなく、若年者のデータも取得し、加速度データの比較などを行い、転倒リスクの予測を試みる必要がある。

また、現場測定ではBluetooth通信不良によるデータ欠損が課題となった。現場環境では通信安定性や装着性が重要であり、今後はローカル保存機能を有するデバイスや通信耐性の高いシステム構築が必要であると考えられる。

胸部センサーは比較的安定したデータ取得が可能であり、身体重心近傍の動揺評価に有用であった。今後はさらに、疲労感と身体動揺との関連を解析し、疲労と転倒の相関を検討するとともに、加速度データは単なる転倒検知だけでなく、疲労蓄積や身体機能低下の早期検知への応用可能性を検討する必要がある。

今後は、加速度データに加え、心拍変動、自律神経活動、睡眠・概日リズム指標などを統合することで、より高精度な転倒予測システムの構築出来る可能性がある。

E. 結論

本研究では、模擬転倒実験データを用いたAI解析と、高齢労働者の現場加速度データ解析を統合し、転倒検知および転倒予測技術の基礎的検討を行った。

模擬転倒実験では、SMVやFall indexが転倒動作を反映する有用な指標であり、AI解析によって転倒特有の予兆パターンを予測できる可能性が示された。一方、現場研究では実転倒事例は認められなかったものの、高齢労働者の身体動揺や作業活動を連続的に記録できることが確認された。

また、疲労感と身体動揺との関連が示唆されれば、加速度センサーは転倒リスク評価や安全管理支援ツールとして有用である可能性が考えられた。

今後は、測定規模の拡大、長期観察、AI解析精度向上、多種生体情報との統合解析を進めることで、労働者の安全確保および転倒予防に資する実用的システム開発につなげられる可能性がある。

F.健康危険情報 該当なし

G.研究発表 該当なし

(別添資料)


【研究概要】

【目的】

- ①ウェアラブルセンサーによる転倒検知と転倒予測
- ②転倒リスクの個人要因と環境要因の解明
- ③労働現場における転倒予防システムの開発

令和6年度～

転倒シミュレーション実験
(産業医科大学行動解析室)



3軸加速度センサー

体幹

腕

足首



令和7年度～

労働現場データ収集
(工場、医療福祉施設等)

つまずき、転倒リスクマップ



令和8年度

転倒予防システム開発

AI解析などを用いて解明した、転倒リスクの個人要因と環境要因をもとに、転倒予防システムを開発
→ウェアラブルアプリケーション（適時介入システム）に実装

厚生労働科学研究補助金

労働安全衛生総合研究事業

(総括・分担) 研究報告書

模擬転倒実験データを用いたAI解析に基づく転倒検知と転倒予測の検討

研究分担者： 黒坂知絵（産業医科大学）

研究要旨：

職場における転倒・転落災害の予防を目的として、昨年度取得した模擬転倒実験データを用いた AI による転倒検知および転倒予測の可能性について検討した。健康成人 21 名を対象に、転倒動作 162 件と日常生活動作（ADL）184 件、計 346 動作を収集し、手首・体幹・脚に装着した加速度センサから得られる 3 軸加速度データを解析した。評価には、被験者独立性能を検証するため、LOSO（Leave-One-Subject-Out）法を用いた。転倒検知解析では、動作区間全体を対象とした AI 分類により、Accuracy 0.983, F1-score 0.981 と非常に高い精度を示した。誤警報（FP）および転倒見逃し（FN）はともに 2 件と少なく、被験者間でも安定した性能が確認された。また、特徴量解析では、体幹（Chest）由来の加速度情報の寄与が最も高く、特に鉛直方向加速度の最小値（min）が重要な指標であることが示された。これらは、転倒時の急激な重心移動や姿勢崩壊を反映していると考えられた。部位別解析では、複数部位統合時が最も高精度であったが、単一部位では体幹センサが最も有効であり、実運用における中心的センサ部位として有望であることが示唆された。さらに、転倒直前の予兆情報のみを用いた Pre-impact 解析を実施した結果、転倒 3 秒前および 5 秒前では Accuracy 約 0.89, F1-score 約 0.88 と比較的高い予測性能が得られた。一方で、2 秒前では性能低下が認められた。これは、転倒直前になるほど動作が急激かつ複雑化し、判別に必要な時系列情報が不足するためと考えられた。また、実際の転倒回避行動を考慮すると、3 秒程度の警告時間が現実的かつ実用的である可能性が示された。一方、本研究は模擬転倒データを用いた統制条件下での検討であり、実際の職場環境で自然発生する転倒とは条件が異なる点に留意が必要である。特に、本研究では転倒区間が正確に切り出されていることや、ADL に静止区間が含まれていることから、性能が過大評価されている可能性がある。今後は、連続データに対するリアルタイム解析や、実作業中の不安定動作・準転倒動作を含むデータ収集を進めることで、より実環境に近い転倒予測システムの構築が課題である。本研究は、体幹装着型ウェアラブルセンサを用いた転倒予防技術の基礎的知見を提供するものであり、今後の実用化研究への展開が期待される。

A. 研究の背景および目的

職場における転倒・転落災害は、業種を問わず発生頻度が高く、労働災害の主要な原因の一つである。特に転倒は、骨折や靱帯損傷などの比較的重篤な外傷につながりやすく、休業を伴う労働災害の大きな割合を占めていることが報告されている（厚生労働省, 2023; Bell et al., 2008; Haslam & Bentley, 1999）。その結果、個人の就労継続に影響をおよぼすだけでなく、企業にとっても生産性低下や医療・補償コストの増大といった社会的損失をもたらす。従来の職場における転倒対策は、床材や履物の改善、作業環境の整備など事後的・環境的対策が中心であり、個々の作業者の身体動作に着目したリアルタイムな転倒検知・予測技術の導入は限定的であった。また、加速度センサを用いた転倒検知研究の多くは、転倒後の衝撃検出（post-impact detection）を主眼としており、転倒が発生した後にアラートを出す設計が主流であった（Noury et al., 2007; Igual et al., 2013）。このような手法では、転倒による負傷や休業を未然に防ぐことは困難である。一方で、作業中の身体動揺や姿勢破綻といった転倒前兆（pre-impact）を捉えることができれば、警告提示や作業中断といった介入により、転倒そのものや重篤化を防止できる可能性がある。しかしながら、職場環境を想定し、転倒前の動作に着目した予測研究は依然として少ない（Bagalà et al., 2012）。さらに、機械学習を用いた転倒検知・予測研究では、同一

作業者のデータが学習および評価に混在する個人差によって性能が過大評価される問題が指摘されている（Weiss et al., 2016）。実際の職場導入を想定した場合、学習に含まれない未知の作業者に対しても、転倒を正しく検知・予測できることが必須である。

本研究では、転倒検知および転倒予測（Pre-impact 区間）の性能を体系的に検証することを目的とし、複数部位（腕・体幹・脚）に装着した加速度センサデータを用いて、個人の独立評価（LOSO: Leave-One-Subject-Out）を実施した。

B. 研究方法

1) 参加者とデータ

参加者は健常成人21名とし、各参加者について転倒動作および日常生活動作（ADL）をそれぞれ1回ずつ計測した。各動作は表1の通りである。合計で346動作（転倒162, ADL184）を解析対象とした。

2) 測定部位

加速度センサは、手首（Arm）、体幹（Chest）、脚（Leg）の3部位に装着した。各部位について3軸加速度（X,Y,Z）を取得し、合計9チャンネルの時系列データを使用した。サンプリング周波数は50Hzであり、すべての解析においてこの周波数に統一した。

3) 動作区間の定義

転倒検知解析では、計測中の実施記録に基づき各動作の動作区間のみ（Action区間）を切り出した。このAction区間は動作前後の安定区間

を含むため、動作長は一定ではない。機械学習入力として扱うため、すべてのActionデータを固定長(500点)に線形補間した。これにより、約10秒相当の時系列データとして正規化した。

4) 転倒予測 (Pre-impact) 区間の定義

転倒予測解析では、体幹 (Chest) の3軸加速度の合成最大値を転倒インパクトの基準点とし、そこからn秒前 (n=5,3,2) の区間のみを切り出して解析を行った。

この方法により、実際の転倒衝撃を含まず、事前予兆のみを用いた予測性能を評価可能とした。

なお、Chestの3軸加速度の合成最大値は以下の数式(1)により算出した。

$$Chest_{mag} = \sqrt{x^2 + y^2 + z^2} \quad (1)$$

5) 評価方法 (LOSO)

本研究では、各参加者の独立性能を評価するため、LOSO (Leave-One-Subject-Out) 交差検証を採用した。

具体的には、1名の被験者をテストデータ、残り20名を学習データとしてモデルを構築し、これを21名分すべて繰り返す方法である。この評価方法は、実運用に近い条件での性能評価である。評価指標としてAccuracy, F1-score, False Negative (FN), False Positive (FP) を算出した。

C. 結果

動作区間を用いた転倒検知において、LOSOによる全体性能はAccuracy 0.983, F1-score 0.981であった (表2)。混同行列は表3の通りであり、転倒の見逃し (FN) および誤警報 (FP)

は極めて少なかった。

参加者別の解析では、AccuracyおよびF1-scoreは1.0に近い値を示し、最小値はAccuracy 0.882, F1-score 0.875であった。個人間のばらつきは限定的であり、本手法は個人依存性の低い安定した転倒検知性能を有することが示された。

1) 部位別および特徴量の寄与率

特徴量重要度の解析結果から、部位別の寄与率は体幹 (Chest) 約48.2%, 脚 (Leg) 約31.4%, 腕 (Arm) 約20.4%であった。体幹部の寄与が最も大きく、姿勢崩壊や重心移動を直接反映していると考えられる。また、特徴量としては、最小値 (min) 約1.3%, 最大値 (max) 約19.4%, 平均値 (mean) 約17.2%, 標準偏差 (std) 約14.6%, 二乗平均平方根 (rms) 約8.4%であった。

特徴量の重要度

転倒検知モデルにおける特徴量の重要度を算出した結果、上位10項目は、すべて加速度の統計量 (最小値, 最大値, 平均値, 標準偏差) で構成された (表5)。特に下肢 (Leg) および体感 (Chest) におけるY軸成分が高い重要度を示した。もっとも重要度が高かった特徴量は、*Leg_Y_min* (14.2%) であり、*Chest_Y_min* (12.1%), *Chest_Y_mean* (8.4%) と続いた。本実験のセンサ装着姿勢を考慮すると、Y軸は鉛直方法の加速度変化を判定している。転倒動作では、足部の滑りやつまずきに伴い、下肢や体幹が急激に下降する動きが生じるため、鉛直方向の加速度が一時的に大きく負方向に振れる。これらの結果は、転倒時に生じる身体の沈み込みや急激な上下方向加速度変化が、転倒動作を識別する上で重要な情報であることを

示唆している。すなわち、「最小値 (min)」は、短時間に生じる急激な姿勢破綻を鋭敏に反映する指標であり、平均値や標準偏差と比較して、転倒特有の瞬間的变化を強く捉えられる指標になりうる。本研究において min 系特徴量が上位を占めたことは、転倒動作が連続的な変化ではなく、突発的な動的事象であることを反映している可能性を考える。

体感部位の役割

体幹 (Chest) 由来の特徴量は、上位10項目中5項目を占めており、単一部位としても高い寄与を示した。体幹は身体重心に近い位置にあり、転倒時には姿勢崩壊や回旋運動が複合的に生じるため、*Chest_Y_mean* や *Chest_X_max*, *Chest_Z_min* などの複数軸・複数統計量が有効に機能したと考えられる。これらの結果は、体幹加速度が転倒検知において中心的役割を果たすことを示しており、部位別解析 (表6) において CHEST_ONLY 条件が高い性能を示した結果とも整合的である。

脚と手首部位の役割

下肢 (Leg) では *Leg_Y_min*, *Leg_Y_std*, *Leg_Y_mean* が重要度上位に含まれており、つまりきや滑りといった転倒初期の挙動を捉えている可能性がある。一方、手首 (Arm) では *Arm_X_max* が上位に位置したが、全体として体幹や下肢に比べて重要度は低く、上肢単独では転倒動作の多様性を十分に表現しきれない可能性が示唆された。

以上より、職場における転倒検知・予測システムの設計においては、体幹装着型センサを中核とし、鉛直方向の加速度変化を重点的に利用する構成が有効であると考えられる。

部位別の加速度情報の寄与

複数部位に装着した加速度センサの寄与を明らかにするため、全9軸を用いた条件 (ALL)、単一部位のみを用いた条件 (ARM_ONLY, CHEST_ONLY, LEG_ONLY)、および特定部位を除外した条件 (NO_ARM, NO_CHEST, NO_LEG) において転倒検知性能を比較した。全9軸を用いたALL条件では、Accuracy 98.8%, F1-score 98.8%と最も高い性能を示し、転倒の見逃し (FN) および誤検知 (FP) はともに2件と少なかった。この結果は、複数部位情報を統合することで転倒動作を高精度に識別可能であることを示している。単一部位のみを用いた条件では、体幹 (CHEST_ONLY) が最も高い性能を示し、Accuracy 96.0%, F1-score 95.7%, 転倒再現率 (recall_fall) 96.3%であった。一方、腕 (ARM_ONLY) および脚 (LEG_ONLY) では性能が低下し、特にARM_ONLYではFNが15件と多く、転倒の見逃しが増加する傾向が認められた。LEG_ONLY条件では、precision_fall は96.1%と高い一方で、recall_fall は90.1%に留まり、「転倒と判定した場合の信頼性は高いが、一部の転倒を見逃す」傾向が示された。これらの結果から、単一部位のみでは転倒動作の多様性を十分に捉えられない可能性が示唆された。

特定部位を除外した条件においても、NO_ARM, NO_CHEST, NO_LEG のいずれにおいてもAccuracy は96%以上を維持しており、システム全体として一定の冗長性を有していることが確認された。しかしながら、NO_CHEST条件ではF1-scoreが96.3%に低下し、FPおよびFNの増加が認められた。すなわち、体幹情報を除外することで姿勢崩壊や重心移動といった転倒特有の特徴が捉えにくくもの

と考えられる。一方、NO_ARMおよびNO_LEG条件では、ALL条件と比較して性能低下は限定的であった。以上の結果より、複数部位を統合した条件（ALL）が最も高精度であるが、単一部位では体幹（Chest）が最も高い転倒検知性能を示したこと、また、体幹情報を除外した場合に性能低下が最も顕著であることが明らかとなった。これらの知見は、実運用を想定した転倒検知・予測システムにおいて、体幹装着型センサを中核としつつ、他部位情報を補助的に統合する構成が有効であることを示唆している。

転倒予測の結果

体幹（Chest）加速度を基準として切り出したデータを用いて転倒予測を行った結果、LOSOによる全体性能は、表7の通りであり、転倒前の予兆情報のみからも一定精度での予測が可能である可能性を示唆した。5秒前、3秒前では同程度の高い予測性能が得られる一方で、2秒前では予測精度が低下する傾向がみられた。また、5秒前区間には予測性能に個人差が生じる傾向が確認された。これは、転倒に直接関与しない動作成分が含まれる可能性が考えられた。これに対し、3秒前区間では、転倒に直結する身体動揺や姿勢破綻の前兆が比較的集約されており、不要な動作成分を抑えつつ、転倒特有の情報を保持できている可能性が示唆された。2秒前条件では、Accuracy および F1-score がともに低下しており、特に転倒の見逃し（False Negative）が増加する傾向が認められた。転倒直前の極めて短い時間区間では、身体がすでに急激な姿勢変化段階に入っており、転倒と日常動作との判別に必要な時系列変化が十分に得られないことが考えられる。また、人間の反応時間や回避行動に要する時間を考

慮すると、2秒前での警告は、仮に予測精度が一定水準に達していたとしても、実際の転倒回避行動につながらない可能性が高い。この点においても、2秒前条件は実運用上の制約が大きいと考えられる。

以上より、予測性や実用性のバランスの観点から、3秒区間での予測が最も有効であると考えられる。転倒回避行動や作業中断といった介入を行うための時間的余裕を確保できる点でも、職場における転倒予測システムとして現実的かつ有効な警告タイミングであると考えられる。

D. 考察

模擬転倒データを用いた評価結果の解釈

本研究では、腕・体幹・脚の複数部位に装着した加速度センサデータを用い、転倒検知および転倒予測の性能評価を実施した。特に転倒検知では、LOSO（Leave-One-Subject-Out）評価において Accuracy および F1-score が約 0.98 と非常に高い値を示した。また、Chestの最大加速度を基準とした Pre-impact 区間を用いた転倒予測においても、5 秒前および 3 秒前では F1-score が約 0.88 と実用可能性を示す結果が得られた。

しかしながら、これらの高い性能は、本研究で用いたデータ特性を踏まえて慎重に解釈する必要がある。本研究で用いたデータは、実環境で自然発生した転倒ではなく、あらかじめ定義された動作プロトコルに基づく模擬転倒（simulated falls）データであった。先行研究においても、模擬転倒データは実転倒と比較

して動作の再現性が高く、転倒動作と日常動作（ADL）との境界が明瞭になりやすいことが指摘されている（Bagalà et al., 2012；Karantonis et al., 2006）。このため、模擬転倒データを用いた場合、分類性能が過大評価される可能性がある。

加えて、本研究では転倒区間および転倒直前区間（Pre-impact 区間）が、実験時刻記録の情報に基づいて正確に切り出されており、「転倒が含まれることが保証された区間」と「転倒が含まれない区間」との識別を行っている。これは、アルゴリズムの識別能力を検証する上では有効であるが、実運用を想定した場合には、転倒発生時刻が未知である状況とは条件が大きく異なる。実環境では、連続データの中から転倒兆候を検出する必要があり、この点でも本研究の評価は、理想的な統制された条件下で実施されたデータの評価である。

さらに、ADL データの内容にも留意が必要である。本研究における ADL データには、歩行や立位動作に加え、明確に静止状態とみなせる区間が含まれている。先行研究では、静止区間を含む ADL は転倒との識別が容易であり、検知性能を押し上げる要因となることが報告されている（Gjoreski et al., 2016）。したがって、今後は作業中の姿勢変化や不安定動作など、転倒と外見上類似した非転倒動作を含めた評価が求められる。

一方で、本研究において被験者独立評価（LOSO）を採用した点は重要である。本研究に

おいて未知の参加者に対しても高い性能が維持されたことから、模擬転倒条件下においては、身体各部位の加速度特徴が参加者間で一定の共通性を有している可能性が示唆される。特に体幹部（Chest）の寄与が大きかった点は、体幹の急激な姿勢変化や重心移動が転倒動作の本質的特徴であるという既存知見（Bourke et al., 2007）とも整合性がある。

Pre-impact 解析においては、5 秒前および 3 秒前で比較的高い予測性能が得られたが、2 秒前では性能低下が観察された。これは、転倒直前になるほど身体動作が急激かつ多様化し、個人差や動作間差が大きくなるためと考えられる。人間の反応時間や姿勢制御特性を踏まえると、転倒回避介入の観点では 3 秒程度が現実的な上限であると考えられ、本結果はその妥当性を支持するものと解釈できる。

本研究で得られた転倒検知（動作区間）における高い識別性能は、模擬転倒条件下ではあるものの、身体動作に含まれる転倒特有の運動パターンが作業者間で一定の共通性を有している可能性を示唆している。特に、体幹部（Chest）の加速度特徴が高い寄与を示した点は、職場転倒においても重心の急激な移動や体幹姿勢の破綻が重要な指標となり得ることを示しており、既存の安全工学的知見とも整合性がある。作業現場では、工具操作や荷物運搬などにより上肢動作は多様化するが体幹動作は比較的安定しているため、体幹部センサ

は装着位置としても必要な部位であると考えられる。

一方、本研究の転倒予測（Pre-impact）解析では、5 秒前および 3 秒前で一定の予測性能が得られたものの、2 秒前では性能低下が認められた。職場での転倒予防を考える場合、アラート提示や補助装置の作動、あるいは作業者自身の姿勢修正を促すためには、一定の時間的余裕が不可欠である。人間の反応時間や作業中の注意配分を考慮すると、2 秒前では回避行動に結びつけることが難しい場面が多く、3 秒程度が現実的な下限である可能性が高い。ただし、本研究で用いたデータは、模擬動作を対象としており、さらにその区間が正確に切り出されている。しかし、実作業現場では、段差昇降、不整地歩行、荷物保持中の姿勢変化、注意分散下での動作など、転倒と非転倒の境界が曖昧な動作が連続的に出現する。この点を踏まえると、本研究で得られた高い精度は、「模擬転倒」「理想的な区間切り出し」「静止を含む ADL」という条件が重なった結果である可能性が高い。その点に十分に留意して、本研究で得られた結果を解釈する必要がある。すなわち、今回の検討は、今後につながるための予備的な検証という位置づけである。

今後は、第一に、未来予測タスクとしての問題設定の拡張を検討する必要がある。本研究で用いた統制された条件下のデータではなく、実運用を想定した評価方法が必要である。

例えば、連続的に取得されるデータから、直近の一定時間窓（例えば、3 秒窓）を用いて「今後数秒以内に転倒が発生するか」を推定する枠組みが求められる。今後は、連続データに対してスライディングウィンドウを用いたリアルタイム解析を行なうなどして連続予測モデルを構築すること、また、早期警告時間（lead time）を考慮した評価指標の導入が課題となる。

第二に、実職場環境を想定したデータの拡張については重要である。本研究の ADL データには静止区間が含まれており、転倒との識別が比較的容易な条件が含まれていた。今後は、作業中の姿勢変化、不安定動作、準転倒動作など、転倒と外見上類似した非転倒動作を含むデータを収集し、誤警報を抑制しつつ転倒兆候を検出できるかを検証する必要がある。

E. 結論

本成果は、体幹装着型ウェアラブルセンサを用いた転倒予防システム設計に有用な基礎知見を提供するものであり、次年度以降には、より実用性を念頭においた検討を進める予定である。

F. 研究発表 該当なし

表 1 解析対象とした動作一覧

転倒動作	日常生活動作
Slip_fwd	Walking
Slip_back	Standing
Trip	Lying
Misstep	Sit_chair
From_sit	Rising
From_stand	Picking
Bump	Ascending／Descending
Collapse	Running

表 2 転倒検知の結果

	precision	recall	f1-score	support
ADL(0)	0.99	0.99	0.99	184
Fall(1)	0.99	0.98	0.99	162
accuracy			0.99	346
macro avg	0.99	0.99	0.99	346
weighted avg	0.99	0.99	0.99	346

表 3 混同行列

	予測 ADL	予測 Fall
実際 ADL	TN=182	FP=2
実際 Fall	FN=2	TP=160

表 4 参加者別の検知結果

subject	件数	Acc	F1	FN	FP
KR01	17	1	1	0	0
KR02	9	0.888889	0.909091	0	1
KR03	16	1	1	0	0
KR04	15	1	1	0	0
KR05	17	1	1	0	0
KR06	17	1	1	0	0
KR07	17	1	1	0	0
KR08	17	1	1	0	0
KR09	17	1	1	0	0

KR10	17	1	1	0	0
KR11	17	1	1	1	0
KR12	17	1	1	0	0
KR13	17	1	1	0	0
KR14	17	0.941176	0.933333	1	0
KR15	17	1	1	0	0
KR16	17	1	1	0	0
KR17	17	1	1	0	0
KR18	17	1	1	0	0
KR19	17	1	1	0	0
KR20	17	1	1	0	0
KR21	17	0.882353	0.875	1	1

Acc：正解率 ／ F1：適合率 ／ FN：転倒を見逃した回数 ／ FP：日常動作を転倒と誤検出した回数

表 5 重要度上位の特徴量

Feature	importance
Leg_Y_min	0.1416
Chest_Y_min	0.1209
Chest_Y_mean	0.0838
Arm_X_max	0.0667
Chest_Z_min	0.0515
Leg_Y_std	0.0498
Chest_X_max	0.0473
Leg_Y_mean	0.0349
Chest_X_min	0.0305
Chest_Y_std	0.0301

表 6 部位×軸別の寄与率

tag	acc	f1	recall_fall	precision_fall	TN	FP	FN	TP
ALL	98.8%	98.8%	98.8%	98.8%	182	2	2	160
ARM_ONLY	91.3%	90.7%	90.7%	90.7%	169	15	15	147
CHEST_ONLY	96.0%	95.7%	96.3%	95.1%	176	8	6	156
LEG_ONLY	93.6%	93.0%	90.1%	96.1%	178	6	16	146
NO_ARM	96.8%	96.6%	95.1%	98.1%	181	3	8	154
NO_CHEST	96.5%	96.3%	96.9%	95.7%	177	7	5	157
NO_LEG	96.2%	96.0%	96.9%	95.2%	176	8	5	157

表 7 Pre-impact 秒数別転倒予測性能

区間	Accuracy	F1-score
5 秒前	約 0.89	約 0.88
3 秒前	約 0.89	約 0.87
2 秒前	約 0.86	約 0.83

表 8 参加者別の予測性能

	acc			f1			FN			FP		
sub	5s	3s	2s	5s	3s	2s	5s	3s	2s	5s	3s	2s
KR01	88.2%	88.2%	88.2%	88.9%	88.9%	88.9%	0	0	0	2	2	2
KR02	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	0	0	0	0	0	0
KR03	93.8%	93.8%	93.8%	92.3%	92.3%	92.3%	1	1	1	0	0	0
KR04	93.3%	86.7%	86.7%	92.3%	85.7%	85.7%	0	0	0	1	2	2
KR05	82.4%	88.2%	94.1%	76.9%	85.7%	93.3%	3	2	1	0	0	0
KR06	94.1%	100.0%	100.0%	94.1%	100.0%	100.0%	0	0	0	1	0	0
KR07	82.4%	82.4%	82.4%	80.0%	80.0%	80.0%	2	2	2	1	1	1
KR08	100.0%	94.1%	100.0%	100.0%	93.3%	100.0%	0	1	0	0	0	0
KR09	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	0	0	0	0	0	0
KR10	82.4%	82.4%	82.4%	76.9%	76.9%	76.9%	3	3	3	0	0	0
KR11	82.4%	82.4%	76.5%	76.9%	76.9%	66.7%	3	3	4	0	0	0
KR12	94.1%	94.1%	94.1%	94.1%	94.1%	94.1%	0	0	0	1	1	1
KR13	94.1%	94.1%	94.1%	93.3%	93.3%	93.3%	1	1	1	0	0	0
KR14	88.2%	82.4%	82.4%	85.7%	76.9%	76.9%	2	3	3	0	0	0
KR15	76.5%	76.5%	76.5%	71.4%	71.4%	71.4%	3	3	3	1	1	1
KR16	94.1%	100.0%	94.1%	93.3%	100.0%	93.3%	1	0	1	0	0	0
KR17	88.2%	88.2%	88.2%	85.7%	85.7%	85.7%	2	2	2	0	0	0
KR18	88.2%	94.1%	94.1%	85.7%	93.3%	93.3%	2	1	1	0	0	0
KR19	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	0	0	0	0	0	0
KR20	94.1%	94.1%	94.1%	93.3%	93.3%	93.3%	1	1	1	0	0	0
KR21	82.4%	82.4%	76.5%	80.0%	80.0%	75.0%	2	2	2	1	1	2

【参考文献一覧】

- 厚生労働省. (2023). 令和 4 年 労働災害発生状況の分析.
<https://www.mhlw.go.jp/content/11302000/001257469.pdf> (2025.12.23 参照)
- Bagalà, F., et al. (2012). Evaluation of accelerometer-based fall detection algorithms on real-world falls. PLoS ONE, 7(5), e37062. <https://doi.org/10.1371/journal.pone.0037062>.
- Bell, J. L., et al. (2008). Evaluation of a comprehensive slip, trip and fall prevention programme for hospital employees. Ergonomics, 51(12), 1906–1925. <https://doi.org/10.1080/00140130802567029>
- Bourke, A. K., O'Brien, J. V., & Lyons, G. M. (2007). Evaluation of a threshold-based tri-axial accelerometer fall detection algorithm. Gait & Posture, 26(2), 194–199.
<https://doi.org/10.1016/j.gaitpost.2006.09.012>
- Gjoreski, H., Lustrek, M., & Gams, M. (2016). Accelerometer placement for posture recognition and fall detection. IEEE Sensors Journal, 16(7), 2230–2238. Doi: 10.1109/IE.2011.11
- Haslam, R. A., & Bentley, T. A. (1999). Follow-up investigations of slip, trip and fall accidents among postal delivery workers. Safety Science, 32(1), 33–47. [https://doi.org/10.1016/S0925-7535\(99\)00009-0](https://doi.org/10.1016/S0925-7535(99)00009-0)
- Igual, R., Medrano, C., & Plaza, I. (2013). Challenges, issues and trends in fall detection systems. Biomedical Engineering Online, 12, 66. <https://doi.org/10.1186/1475-925X-12-66>
- Karantonis, D. M., Narayanan, M. R., Mathie, M., Lovell, N. H., & Celler, B. G. (2006). Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring. IEEE Transactions on Information Technology in Biomedicine, 10(1), 156–167.
<https://doi.org/10.1109/TITB.2005.856864>
- Noury, N., et al. (2007). Fall detection--principles and methods. Annu Int Conf IEEE Eng Med Biol Soc. 2007, 1663-1666. doi: 10.1109/IEMBS.2007.4352627
- Weiss, G. M., Yoneda, K., & Hayajneh, T. (2016). Smartphone and smartwatch-based biometrics using ADL. IEEE Access, 4, 552–568. <https://doi.org/10.1109/ACCESS.2019.2940729>

厚生労働科学研究補助金
労働安全衛生総合研究事業
(総括・分担) 研究報告書

高齢者の作業中加速度データによる転倒検知の検討

研究代表者： 丸山 崇 (産業医科大学 医学部 第1生理学)

研究要旨：

昨年度（令和6年度）は、実験室環境下において転倒シミュレーション実験を実施し、加速度センサーを用いた基本的な転倒検知アルゴリズムの構築を行った。本年度（令和7年度）は、実際の現場環境における転倒検知の有用性を検証するため、転倒リスクの高い高齢労働者を対象とした現場調査を実施した。対象は、駐車場の巡視および監視業務を行う70歳以上の高年齢労働者6名とした。測定には加速度センサー（Wit motion）を用い、左腕、胸部、足首にセンサーを装着し、スマートフォンと連動させて勤務時間中の加速度データを連続記録した。また、GPSによる位置情報も同時に取得し、巡視経路や移動状況と加速度情報との関連解析を可能とした。さらに、当日の作業内容、作業負荷、疲労度（自覚症しらべ）、ならびに実際のつまずき・転倒発生状況についても記録を行った。

取得した加速度データについては、転倒検知指標として Signal Magnitude Vector（SMV）および Fall index を用いて解析を行った。その結果、本研究期間中には実際のつまずき・転倒事例は認められず、SMV や Fall index による転倒検知イベントも検出されなかった。一方で、歩行や方向転換に伴う身体動揺は加速度データ上で確認された。また、測定中に Bluetooth 通信不良が発生し、左腕および足首センサーのデータ欠損が認められたため、主として胸部装着センサーのデータを用いた解析を行った。現在、胸部加速度データを中心に、疲労度や作業負荷と身体動揺との関連について解析を進めている。

本研究により、現場環境下における高年齢労働者の身体活動データ取得の可能性が示された一方で、実際の転倒事例収集の困難性や通信安定性など、現場運用上の課題も明らかとなった。今後は対象者数や測定期間を拡大し、転倒予測および転倒リスク評価技術の高度化を目指す予定である。

研究分担者：

黒坂知絵（産業医科大学）

倉岡宏幸（公立千歳科学技術大学）

A. 研究の背景と目的

我が国では高齢化が急速に進行しており、高年齢労働者の就業機会が拡大している。特に警備業務、巡視業務、施設管理業務などでは、70歳を超える高齢労働者が現場で活動する機会も増加している。一方で、高齢者では加齢に伴う筋力低下、平衡機能低下、感覚機能低下などにより、つまずきや転倒のリスクが増加することが知られている。転倒災害は骨折や頭部外傷など重篤な健康障害につながるだけでなく、その後の就労継続や生活機能にも大きな影響を及ぼすため、労働安全衛生上の重要課題となっている。

近年では、ウェアラブルデバイスやIoT技術の発展により、加速度センサーを用いた身体動揺や転倒のリアルタイム検知技術が注目されている。特に3軸加速度センサーを用いることで、歩行時の身体動揺や急激な姿勢変化を定量的に評価できる可能性が示されている。また、スマートホンとの連携により、現場作業中の長時間連続記録や位置情報との統合解析も可能となってきた。

昨年度（令和6年度）の本研究では、行動解析室環境下において転倒シミュレーション実験を実施し、基本的な転倒検知アルゴリズムの構築を行った。その結果、Signal Magnitude of Vector (SMV) やFall indexなどの指標が、急激な身体加速度変化を捉える上で有用である可能性が示された。しかし、実験室環境で得

られたアルゴリズムが、実際の高齢労働者の現場環境において適用可能であるかについては十分な検証が行われていなかった。

そこで本年度（令和7年度）は、実際の現場作業を行う高年齢労働者を対象として、加速度センサーを用いたデータ収集を実施し、現場環境における転倒検知指標の有用性と課題を検討することを目的とした。また、作業負荷や疲労感と身体動揺との関連についても検討を行った。

B. 研究方法

対象者は、駐車場の巡視および監視業務を行う70歳以上の高年齢労働者6名とした。対象者には研究内容を説明し、同意を得た上で測定を実施した。

測定には、3軸加速度センサーを搭載したウェアラブルセンサー（Wit motion）を用いた。センサーは左腕、胸部、足首の3部位に装着（図1）し、Bluetooth通信によりスマートホンへリアルタイムにデータを送信した。測定は実際の勤務時間中に行い、作業環境下での自然な身体活動を連続記録した。

さらに、スマートホンのGPS機能を用いて位置情報を同時記録し、巡視経路や移動状況と加速度データとの対応を解析可能とした。加えて、当日の作業内容、作業負荷、休憩状況、気象条件などを記録した。また、測定期間中に実際のつまずきや転倒が発生した場合には、その状況を詳細に記録するよう指示した。

疲労評価としては、「自覚症しらべ」を用い、作業前後に疲労感を評価した。取得した加速

度データについては、転倒検知指標として以下の解析を実施した。

1. Signal Magnitude Vector (SMV)

3軸加速度データから合成加速度を算出し、身体動揺や急激な加速度変化を評価した。

$$SMV_i = \sqrt{|A_{x_i}|^2 + |A_{y_i}|^2 + |A_{z_i}|^2}$$

2. Fall index

急激な姿勢変化や衝撃性加速度変化を指標化し、転倒検知アルゴリズムとして解析を行った。

$$FI_i = \sqrt{\sum_{k=x,y,z} \sum_{i=19}^i (A_{ki} - A_{ki-1})^2}$$

C. 研究結果

本研究では、高年齢労働者6名(表1)に対して現場測定を実施し、実際の巡視・監視業務中の加速度データおよびGPSデータを取得した(図2,3)。

測定期間中、実際のつまずき転倒事例は認められなかった。そのため、SMVやFall indexによる転倒検知アルゴリズムについても、実際の転倒イベントの検出には至らなかった。

一方で、巡視中(歩行)、監視中(動作減弱)などに伴う身体活動の状況は加速度データ上で確認された。腕、胸部センサーでは、歩行時に周期的な加速度変化が認められるなど行動との関連が示唆された。

本研究ではBluetooth通信の不安定性やセンサー接続不良が生じ、左腕および足首に装着したセンサーのデータ収集に欠損が認められ

た。その結果、主に胸部センサーのデータを用いた解析が中心となった。

疲労評価との関連では、自覚疲労感と転倒リスクに関する明らかな関連は解析出来なかった。(表2)

GPSデータからは、巡視経路や移動距離の把握が可能であり、加速度データとの統合により、身体活動量や作業強度を推定できる可能性が示された。

D. 考察

本研究では、高年齢労働者を対象として、実際の現場環境下で加速度センサーによる身体動揺および転倒検知の検討を行った。その結果、現場環境における連続的な身体活動データ取得の可能性が示された一方で、実運用上の複数の課題も明らかとなった。

まず、本研究期間中には実際の転倒事例が発生しなかったため、転倒検知アルゴリズムの感度や特異度を十分に評価するには至らなかった。しかし、これは対象現場における安全管理が一定程度機能していたことを示す結果とも考えられる。一方で、転倒発生頻度は一般に低いため、実転倒データのみを用いた解析には長期間の観察やデータ集積が必要であることが改めて示唆された。

また、通信不良によるデータ欠損は、本研究における大きな課題であった。特にBluetooth通信は、身体動作や周囲環境の影響を受けやすく、現場環境下では安定性に課題が残ることが明らかとなった。今後は、センサー内蔵メモリによるローカル保存機能の必要性や、通信

安定性の高いデバイス選定が必要であると考えられる。

胸部センサーについては比較的安定したデータ取得が可能であり、歩行周期や身体動揺を把握する上で有用であると考えられる。胸部は身体重心に近い部位であるため、体幹状態の評価に適している可能性が考えられる。一方で、足首や腕部センサーとの統合解析が実現すれば、歩容変化や局所的動作異常の検出精度向上が期待される。

本研究では疲労感の増加と身体動揺との関連を示唆する結果は得られなかった。高齢労働者では疲労蓄積に伴い姿勢制御能力が低下する可能性があり、加速度データを用いることで、転倒リスク上昇の予兆を検出できる可能性がある。今後は、加速度変動と疲労度、作業負荷との関連について探索的解析を実施したい。さらに、心拍変動、自律神経指標、睡眠データなどと統合した解析を行うことで、より包括的な転倒リスク評価システムの構築につながると考えられる。

E. 結論

本研究では、高年齢労働者を対象として、加速度センサーを用いた現場環境下での転倒検知に関する検討を行った。その結果、胸部装着型センサーを中心として、実作業環境における身体活動および身体動揺データを取得可能であることが示された。

一方で、実際の転倒事例は観察されず、転倒検知アルゴリズムの有効性評価には至らなかった。また、通信不良によるデータ欠損など、現場運用上の技術的課題も明らかとなった。

しかしながら、疲労感や作業負荷と身体動揺との関連を示唆する結果が得られたことから、加速度センサーは高齢労働者の転倒リスク評価や安全管理支援ツールとして活用可能性を有すると考えられた。

今後は、対象者数の拡大、長期間観察、複数センサー統合解析、さらに自律神経指標や生体リズム指標との組み合わせを進めることで、高齢労働者の安全確保に資する転倒予測システムの開発につながることが期待される。

F. 研究発表 該当なし

(別添資料 2)

図1. センサー装着の状況



腕に装着した加速度センサー



胸に装着した加速度センサーとスマートフォン

図 2. 各被験者の位置情報

TM002



2025-09-17 08:22:56
記録開始: 2025-09-17 08:22:56
記録終了: 2025-09-17 15:00:01
距離: 6.2km 時間: 06:37:04

TM003




2025-10-08 08:12:43
記録開始: 2025-10-08 08:12:43
記録終了: 2025-10-08 14:58:54
距離: 9.3km 時間: 06:46:11

TM004



2025-10-14 08:09:31
記録開始: 2025-10-14 08:09:31
記録終了: 2025-10-14 15:55:54
距離: 12.42km 時間: 07:46:23

TM005



2025-10-15 08:09:25
記録開始: 2025-10-15 08:09:25
記録終了: 2025-10-15 14:32:57
距離: 9.07km 時間: 06:23:32

TM006



2025-10-27 08:08:36
記録開始: 2025-10-27 08:08:36
記録終了: 2025-10-27 15:15:58
距離: 6.83km 時間: 07:07:21

TM007



2025-11-17 08:01:53
記録開始: 2025-11-17 08:01:53
記録終了: 2025-11-17 15:11:43
距離: 9.77km 時間: 07:09:49


表 1. 被験者リスト

No.	性別	年齢	身長	体重	加速度測定部位		
					腕	胸	脚
TM002	男	71	168	76	○	○	×
TM003	男	77	161	60	○	○	×
TM004	男	72	158	66	×	○	×
TM005	男	78	158.5	57	×	○	×
TM006	男	77	166	53	×	○	×
TM007	男	72	165	57	○	○	





表 2. 自覚症しらべ（合計スコア）

No.	I 群	II 群	III 群	IV 群	V 群
TM002	6	6	7	5	7
TM003	5	6	7	6	7
TM004	7	7	8	7	9
TM005	6	7	9	6	7
TM006	8	8	7	8	12
TM007	6	8	7	8	10





図 3.3 軸加速度センサーデータ







TM002_Chest







TM003_ArmL







TM003_Chest







TM004_Chest







TM005_Chest



TM006_Chest



TM007_ArML



TM007_Chest

