

[研究助成 (A)]

慣性センサ搭載耳装着型デバイスを用いた重心動揺計測手法の開発

2251027

研究代表者
(助成金受領者)東京大学
空間情報科学研究センター

教授

西 山 勇 毅

共同研究者

東京大学 生産技術研究所

助教

田 谷 昭 仁

東京大学 生産技術研究所・
空間情報科学研究センター

教授

瀬 崎 薫

[研究の目的]

重心動揺 (CoP: Center of Pressure) は人間の姿勢制御能力を評価する重要な指標であり、高齢者の転倒予防・リハビリテーション・スポーツ医学など幅広い分野で活用されている。また、転倒リスクの早期発見や脳震盪後の回復管理にも有用とされる。正確な CoP 計測は、フォースプレートのような専門的で高価な固定設備を用いて計測され、計測された重心動揺の軌跡から、重心動揺の平均移動速度 (avgV)・最大移動速度 (maxV)・垂直/水平方向変位範囲 (dispAP/dispML)・信頼楕円面積 (area) の5項目が主に算出され、評価指標として広く利用されている。CoP は、開眼・閉眼や異なる姿勢 (両足や片足、タンデム) などの異なる姿勢や状態で計測されている。本研究ではこれらの評価指標を、CoP 関連指標と定義する。

一方、フォースプレートを用いた伝統的な手法は、計測機器が高価かつ固定型のため、日常中に気軽に利用するのは困難であった。そこで、ウェアラブルデバイスによる代替も提案されている。例えば腰に装着したモーションセンサから重心動揺を計測するなどの検討が行われている。しかし、既存手法では腰にセンサを固定するための専用器具を要し、日常生活へのシームレスな統合に課題があった。

本研究では、近年普及する市販の「耳装着型

デバイス (イヤホン等)」に搭載された慣性センサ (IMU) を活用し、専用機器なしに CoP を計測・推定できる手法の開発を目的とする。耳装着型デバイスはシームレスな日常統合・低コスト・継続モニタリングの面で優位性を持つ。頭部位置と重心動揺の強い連動性に着目し、機械学習によって耳装着デバイスのデータから CoP 関連指標を推定するモデルを構築する。

[研究の内容、成果]

本研究では、完全ワイヤレスイヤホン (Apple 社の AirPods シリーズ) 等の IMU が搭載された耳装着型デバイスからモーションセンサデータを収集し、そのセンサデータを用いて CoP を推定する機械学習モデルを開発する。本研究の遂行に当たって、① CoP 推定モデル開発のためのデータセットの構築、および② CoP 推定モデルの設計・実装と③その評価を行った。

まず① CoP 推定モデル開発のためのデータセット構築では、計測環境の整備と手順を確立し、20 名の実験参加者から実際に CoP 計測とイヤラブルデバイスからモーションセンサデータの計測を行った。図 1 に CoP とモーションセンサの計測環境を示す。

計測システムは、同期された3種類のデータ取得モダリティで構成した。主要なイヤラブルデバイスとして、OpenEarable 1.3 プラット




図1 CoP とモーショセンサデータの環境

フォームを使用した。このデバイスは Bosch BMX160 の 9 軸 IMU（加速度・ジャイロ・地磁気センサ）を搭載し、Web Bluetooth 接続を介して 50 Hz でサンプリングを行った。比較対象として、市販の腰部装着型 IMU システム（Sports Sensing）を用い、弾性ベルトにより第 5 腰椎（L5）付近に装着し、100 Hz でサンプリングした。

正解データとしては、フォースプレート（Sports Sensing TFP-404011B, 40 × 40 cm）を使用し、1000 Hz で 3 軸力（ F_x , F_y , F_z ）およびモーメント（ M_x , M_y , M_z ）を計測した。フォースプレート内部のハードウェアにより、力とモーメントから CoP が算出された。センサデータの時刻同期は、NTP（Network Time Protocol）を用いて同期した。また、計測時の映像を Azure Kinect の深度カメラと通常のカメラで撮影し、ラベル付けに活用した。特に Azure Kinect では三次元の頭部位置情報を記録した。

データ計測は、20 名の参加者を対象に行われた。参加者は、学習効果を最小限に抑えるため、固定された順序で 6 条件（図 2）からなる標準化されたバランス評価プロトコルを実施した。条件は、両脚立位・開眼（S2O）、両脚立位・閉眼（S2C）、タンデム立位・開眼（TO）、タンデム立位・閉眼（TC）、片脚立位・開眼（S1O）、




図2 三種類の計測姿勢：両脚（左）・タンデム（中央）・片脚（右）

片脚立位・閉眼（S1C）である。両脚立位では、参加者は足を肩幅程度に開き、腕を自然に下ろして立った。タンデム立位では、利き足を前にして、かかととつま先を一直線に並べた姿勢をとった。片脚立位では、利き足で立ち、反対側の脚をわずかに持ち上げた。

各試行は 33 秒間とし、疲労を防ぐため試行間に 17 秒間の休憩を設けた。開眼条件では、参加者は首を動かしたり回したりせず、自由に視線を保った。安全確保のため補助者が近くに待機したが、バランスを崩した場合を除き身体的な補助は行わなかった。バランスを崩した場合には、追加の休憩後に試行を再実施した。解析では、姿勢移行の影響を除去するため、各試行の最初の 3 秒間を除外し、条件ごとに 30 秒間の有効データを用いた。これは臨床的なプロトコルと整合するものである。尚、本実験は、東京大学空間情報科学研究センターの実験倫理審査委員会の承認を受けた上で実施し、すべての実験参加者から実験参加前にインフォームドコンセントを取得した。

② CoP 推定モデルの設計・実装

信号処理と座標軸アライメント：各デバイスでは、デフォルトの座標軸の向きが異なる。図 1 左に示すように、フォースプレートにおける左右方向（medio-lateral: ML）および前後方向（anterior-posterior: AP）は、それぞれ X 軸および Y 軸に対応する。一方、OpenEable の x, y, z 軸は、それぞれ概ね前方、上方、右方向に対応する。腰部 IMU の x, y, z 軸は、それぞれ概ね右方向、上方、後方に対応する。デバ

イス定義の都合上、実際の加速度ベクトルは軸方向と反対向きに定義される一方、角速度は右手系の規則に従う。本実験では、左耳用の OpenEearable を使用しており、左手系の座標系を採用している。

IMU の生信号に対して、アーティファクトの除去および座標系の標準化を目的とした前処理を行った。加速度およびジャイロスコープ信号には、姿勢揺れに関する情報を保持しつつ、高周波ノイズや振戦成分を減衰させるため、カットオフ周波数 10 Hz の 3 次 Butterworth ローパスフィルタを適用した。フォースプレートデータには、電氣的・機械的振動を除去するため、25 Hz のローパスフィルタを適用した。

特徴抽出と予測モデル：スライディングウィンドウ解析によるデータ拡張を行うことで、時系列的な関係を保持しつつ、実質的なサンプル数を増加させた。30 秒間の各試行に対して、6 秒間のウィンドウを 1 秒刻みで適用した。これにより、参加者・条件ごとに 25 個のウィンドウが得られ、モデル学習用に合計約 1,500 サンプルを生成した。ウィンドウ長は、典型的な姿勢揺れの周波数である 0.2 ～ 0.5 Hz に基づき、少なくとも 2 周期分の揺れを捉えられるように設定した。

各ウィンドウから、IMU 信号およびフォースプレート信号の双方について包括的な特徴量を抽出した。IMU 特徴量には、補正後の水平加速度 (accx, accz) の平均および標準偏差、3 軸周りの角速度 (rotx, roty, rotz) の平均および標準偏差、さらに水平面上の加速度軌跡長 (accLen) を含めた。平均値の算出では、符号付き値の平均がゼロに近づくことを避けるため、加速度および角速度の絶対値を用いた。accLen は、連続する加速度サンプル間のユークリッド距離を累積することで算出した。

フォースプレート由来の指標には、平均速度 (avgV)、最大速度 (maxV)、前後方向および左右方向の変位範囲 (dispAP, dispML)、ならびに CoP 軌跡に対して当てはめた 95% 信頼楕

円の面積 (area) を含めた。ウィンドウ長は一定であるため、CoP 軌跡長 (CoPLen) は実質的に平均速度 (avgV) と等価であり、独立した特徴量としては扱わなかった。

IMU データから CoP 指標を予測するために、4 種類の回帰アルゴリズムを評価した。これらは、異なるモデルの複雑度および解釈可能性を網羅するように選定した。

- ・**線形回帰モデル**は、倒立振子モデルに基づく理論的な線形関係を表すベースラインとして用いられた。
- ・**Random Forest** 回帰モデルは、32 本の木、最大深さ 7 の設定により、アンサンブル平均を通じて非線形関係を捉えた。
- ・**AdaBoost** は、64 個の弱学習器を用い、予測が困難なサンプルに反復的に重み付けすることで性能を向上させた。
- ・**畳み込みニューラルネットワーク (CNN)** (図 3) は、生の時系列データを直接処理し、3 つの時間畳み込みブロックから構成され、それぞれのフィルタ数は 64, 64, 32 とした。カーネルサイズは順に 7, 5, 3 とし、最初の層では比較的広い時間範囲の変動を捉え、後続の層ではより局所的な時系列パターンを抽出する構成とした。各層では ReLU 活性化関数を用いた。畳み込み層の後には Global Average Pooling を適用し、時間方向の特徴を集約した。その後、2 層の全結合層を通じて、CoP に関連する各指標を回帰的に推定した。予測対象は、CoP の平均速度、最大速度、前後方向変位、左右方向変位、および 95% 信頼楕円面積である。学習には平均二乗誤差を損失関数として用い、最適化手法には Adam を




図3 提案モデル (CNN) のデータフロー

採用した。また、過学習を抑制するためにL2正則化およびドロップアウトを導入した。

各モデル性能は、正解データであるフォースプレート由来のCoP指標に対して、決定係数 R^2 およびRMSEを用いて評価した

評価実験：表1に、6種類の姿勢条件におけるCNNおよびRandom Forest (RF)の推定性能を示す。評価は5-fold cross-validationの平均値として算出し、正解値であるフォースプレート由来のCoP指標に対して、RMSEおよび決定係数 R^2 を用いて評価した。CNN以外のモデルでは、RFモデルが最も性能が高かったため、線形回帰モデルおよびAdaBoostの結果は表1からは除かれている。

まず、CoP平均速度 (avgV) は、全体として最も安定して高い予測性能を示した。avgVの R^2 はすべての姿勢条件で0.714以上であり、特にタンデム立位・閉眼条件 (TS-C) では0.869、両脚立位・開眼条件 (BS-O) では0.830、片脚立位・開眼条件 (SS-O) では0.813を示した。この結果は、イヤラブルIMUから得られる頭部運動の時系列情報が、CoPの平均的な移動速度をよく反映していることを示唆している。また、RFと比較しても、avgVに対するCNNの R^2 はすべての条件で高く、特にTS-Oでは0.417から0.714、SS-Oでは0.638から0.813へと大きく向上した。これは、CNNが時間方向の動的パターンを直接学習することで、手作業特徴量に基づくモデルよりも高い推定性能を示したことを示している。

一方で、最大速度 (maxV) の予測性能は

avgVに比べて低く、 R^2 は0.479から0.693の範囲にとどまった。maxVは短時間に生じるピーク値の影響を強く受けるため、時間窓全体の傾向を捉えるavgVに比べて、IMU信号から安定して推定することが難しいと考えられる。このことから、本モデルは瞬間的なスパイクよりも、一定時間内の全体的な姿勢揺れの特徴を捉えることに適しているといえる。

変位に関する指標では、前後方向変位 (dispAP) と左右方向変位 (dispML) のいずれについても、中程度から高い予測性能が得られた。dispAPでは、BS-Cで $R^2 = 0.838$ 、TS-Cで $R^2 = 0.671$ を示し、dispMLではTS-Cで $R^2 = 0.746$ 、BS-Cで $R^2 = 0.731$ を示した。一方で、片脚立位条件では一部の指標で性能が低下し、特にSS-OにおけるdispMLの R^2 は0.391であった。これは、片脚立位では身体動揺が大きく不安定になり、頭部IMU信号とCoP変位との対応関係がより複雑になるためと考えられる。

95%信頼楕円面積 (area) については、BS-Cで $R^2 = 0.831$ 、TS-Cで $R^2 = 0.745$ と比較的高い値を示した一方、TS-Oでは0.479、SS-Oでは0.542にとどまった。areaは前後・左右方向のCoP変位の共分散に基づく二次的な指標であり、姿勢条件の違いや大きな揺れの影響を受けやすい。そのため、avgVのような単純な時間的指標と比較して、推定が難しくなったと考えられる。

RMSEの観点から見ると、全体として両脚立位条件で誤差が小さく、片脚立位・閉眼条件 (SS-C) で誤差が大きくなる傾向が確認された。例えばavgVのRMSEは、BS-Oで0.853 cm/s、BS-Cで1.076 cm/sであったのに対し、SS-Cでは6.184 cm/sまで増加した。同様に、areaのRMSEもBS-Oでは0.788 cm²であったが、SS-Cでは11.769 cm²と大きく増加した。これは、片脚立位や閉眼条件では姿勢制御が難しくなり、CoPの変動が大きく複雑になるため、CNNによる推定も難しくなることを示している。

以上より、提案したCNNモデルは、イヤラ

表1 実験結果 [1]

		BS-O	BS-C	TS-O	TS-C	SS-O	SS-C
RMSE	avgV(cm/s)	0.853	1.076	2.118	4.078	2.412	6.184
	maxV(cm/s)	1.777	0.861	3.082	11.037	2.939	12.179
	dispAP(cm)	0.327	0.422	0.315	0.624	0.29	1.205
	dispML(cm)	0.303	0.424	0.462	0.567	0.494	0.897
	area(cm ²)	0.788	1.792	0.895	5.163	1.038	11.769
R^2 (RF)	avgV(cm/s)	0.735	0.693	0.417	0.694	0.638	0.654
	avgV(cm/s)	0.830	0.747	0.714	0.869	0.813	0.777
R^2	maxV(cm/s)	0.586	0.604	0.479	0.618	0.648	0.693
	dispAP(cm)	0.636	0.838	0.369	0.671	0.586	0.548
	dispML(cm)	0.617	0.731	0.411	0.746	0.391	0.597
	area(cm ²)	0.724	0.831	0.479	0.745	0.542	0.657

ブル IMU 信号から複数の CoP 関連指標を推定可能であり、特に CoP 平均速度の推定において高い性能を示した。一方で、最大速度や楕円面積、片脚立位・閉眼条件のように揺れが大きく不安定な条件では予測誤差が増加する傾向が見られた。これらの結果は、イヤラブル IMU がフォースプレートを用いない姿勢揺れ評価の代替手段となり得る一方で、より困難な姿勢条件に対する推定精度向上には、さらなるデータ拡張やモデル改善が必要であることを示している。

今後の展望：現在の CoP 特徴量推定に加えて、CoP 軌跡そのものを時系列として直接推定する手法へ拡張する。予備的な検討[2]では、頭部位置情報のみから CoP 変位を推定し、複数の姿勢条件で 30 mm 未満の RMSE を達成しており、頭部運動が CoP 変動を反映する可能性が示されている。今後は、イヤラブル IMU

から得られる加速度・角速度信号を用いて、ML 方向および AP 方向の連続的な CoP 変位を推定するモデルを構築し、CoP 特徴量推定から CoP 軌跡推定へと発展させる。

[成果の発表、論文など]

- [1] Yanzhi Li, Qize Feng, Xuefu Dong, Akihito Taya, Kaoru Sezaki, Yuuki Nishiyama, "Estimation of the Center of Pressure Using Head Position During Balance Maintenance," 2026 International Conference on Activity and Behavior Computing (ABC), Hokkaido, Japan, pp. 1-7, 2026.
- [2] Yanzhi Li, Qize Feng, Xuefu Dong, Akihito Taya, Kaoru Sezaki, Yuuki Nishiyama, "Poster Abstract: Toward Earable Device-Based Postural Sway Estimation Using Convolutional Neural Networks," SenSys '26: Proceedings of the 2026 ACM/IEEE International Conference on Embedded Artificial Intelligence and Sensing Systems, pp. 1-2, 2026.