

# 背もたれのある椅子での座位姿勢画像を用いた AIによる腰部負荷推定

システム工学群  
ヒューマンメカトロダイナミクス研究室 松下 朋生

## 1. 緒言

令和4年に厚生労働省によって発表された国民生活基礎調査<sup>(1)</sup>によると症状別にみた有訴者率では男女ともに腰痛が最も高い。このことから、腰痛は年齢や性別にかかわらず国民の健康問題として重要な課題であることを示している。腰痛の原因の一つとして、負荷が大きい不良姿勢の習慣化が挙げられる。そこで、本研究では腰部にかかる負荷を定量的に推定する手法を確立することで、腰部への負担の大きな姿勢を回避し姿勢改善、腰痛予防につながると考えた。

既報<sup>(2)</sup>では、単一のWebカメラから取得した画像に対して骨格検出AI (VisionPose:ネクストシステム社製)により得た骨格位置座標を筋骨格モデルによるバイオメカニクス解析ソフト(AnyBody: AnyBody Technology社製)に入力することで、腰部負荷と定義した椎間板圧縮力を算出した。この値を正解値とし画像にラベリングして深層学習CNN(畳み込みニューラルネットワーク)を用いて学習モデルを構築し、画像のみから腰部負荷を推定する手法を提案した。結果、立位時における前傾姿勢に伴う腰部負荷の増加傾向がAnyBodyによる算出結果と概ね一致することを示した。既報<sup>(2)</sup>では単一Webカメラによる骨格検出を行ったが、一般に、単一Webカメラによる骨格検出では自己遮蔽や深度情報の不足により、検出精度に限界があることが指摘されている<sup>(3)</sup>。そこで本研究では、Webカメラを2台使用したマルチビュー計測を採用し、骨格検出の安定性向上と、これに伴う腰部負荷の精度向上を図る。さらに、デスクワークなどにおいて一般的である背もたれ付き椅子での座位姿勢に着目した。背もたれは身体支持を補助する一方で、背もたれへの依存や骨盤後傾に伴う姿勢を誘発しやすく、腰部負荷の増大につながる可能性がある。しかし、背もたれ使用時の姿勢特性を考慮した腰部負荷評価は十分に検討されていない。そこで本研究では、背もたれ角度を変化させた座位姿勢を対象とし、機械学習を用いた個人特化型の学習モデルを作成することで、姿勢情報に基づいた腰部負荷推定手法を確立することを目的とする。

## 2. 機械学習モデルによる腰部負荷推定

### 2.1 画像データ取得実験

実験対象者は、本学倫理審査委員会の承認を得たうえで、事前に内容を説明し同意を得た1名(男性:22歳,1.78[m],64[kg])とする。VisionPoseによって検出した骨格情報を基に腰部負荷を取得するために、背もたれ付きの椅子に着座した状態で動画を取得する。使用機材はWebカメラ(Logicool HD Pro Webcam C920r:logicool社製)を2台用いる。Webカメラを実験対象者の正面及び左側に体中心から距離2.5[m]、床からの高さ0.85[m]の位置に設置して撮影をする。使用した椅子は自作であり、座面高さを0.465[m]、背もたれ角度が鉛直方向を0[°]として15[°]から90[°]まで5[°]刻みで調整可能な構造とした。対象とする姿勢は背もたれを用いた座位にお

ける姿勢変化とし、実験対象者に坐骨座位の状態から仙骨座位へと約5秒間で連続に移行するよう指示し、この一連の動作を動画として撮影しする背もたれ角度の条件は15[°],20[°],25[°],30[°]の4条件とし、各条件について3試行ずつ撮影を行う。試行間には十分な休憩時間を設け、実験協力者の疲労による影響を低減した。取得した動画をPythonモジュールのOpenCV(画像処理ライブラリ)を使用し、フレームレートに応じた画像に変換する。画像データは各条件につき30fps×5s×3試行×4条件=1800画像となった。

### 2.2 作成する機械学習モデル

本研究では、姿勢特徴量から腰部負荷を推定する回帰モデルを構築するため、学習アルゴリズムには、L2正則化項を含む最小二乗法に基づくリッジ回帰を用いる。

目的変数として使用する腰部負荷は、2.1節で取得した動画からVisionPoseを使用して骨格位置座標を検出し、その骨格位置座標をAnyBodyに入力してフレームレートごとの第4第5腰椎間の椎間板圧縮力を算出する。先行研究によるとL4L5椎間板は腰椎において上半身荷重が集中的に作用する部位であり、日常動作や姿勢条件にかかわらず高い力学的負荷を受けると示されている<sup>(4)</sup>。よって、本研究でも腰部負荷をL4L5椎間板圧縮力と定義する。算出した椎間板圧縮力を実験協力者固有の身体特性による影響を低減するために身長と身体質量で除算して標準化し、学習データの各フレーム画像に正解値としてラベル付けすることで機械学習モデルを作成する。推定時には、作成した機械学習モデルによる推定値に身長と身体質量を乗算することで椎間板圧縮力[N]に変換する。

学習モデルの入力特徴量には座位姿勢を表す骨格座標情報及び関節角度情報を用いる。まず、Google社が開発したMediaPipe Poseを用いてRGB画像から人体の主要関節位置を検出し、各関節の2次元座標を取得する。検出対象とした関節は肩関節、股関節、膝関節、足関節及び肘関節である。各関節について画像サイズに正規化されたx座標及びy座標を抽出し骨格配置を表す特徴量として用いた。解析には左側の関節座標を用い、体幹及び下肢の姿勢変化が骨格構造として反映されるようにした。さらに、骨格座標のみでは捉えにくい姿勢の傾きや屈曲状態を表現するため、座標情報から関節角度に基づく特徴量を導出した。体幹前後傾角は肩関節、股関節、股関節の直上に設定した仮想点の3点によって構成される角度として定義した。また、股関節屈曲角は肩関節、股関節、膝関節の3点がなす角として算出した。以上の骨格座標及び関節角度を姿勢ごとに同一の特徴量ベクトルとしてまとめ、座位姿勢を表す説明変数として機械学習モデルに入力した。これらの特徴量と対応する正解値である正規化された腰部負荷を用いてリッジ回帰モデルの学習を行い、回帰係数を算出し、学習済みモデルを構築した。




Fig.1 Comparison of values calculated by AnyBody and estimates derived from machine learning




Fig.2 Comparison of values calculated by AnyBody and estimates from machine learning after adjusting the training data distribution

Table 1 Evaluation results using machine learning model

Mean absolute error [N]	Root mean squared error [N]	Pearson's correlation coefficient
24.7	31.6	0.948

Table 2 Evaluation results using machine learning model after adjusting data distribution

Mean absolute error [N]	Root mean squared error [N]	Pearson's correlation coefficient
18.7	24.5	0.940

### 2.3 推定結果と考察

作成した機械学習モデルにより、特定の個人に対して提案法が適用可能であるかを検証する。機械学習モデルは各角度条件の1, 2 試行目の画像を学習データ、3 試行目の画像をテストデータとし、学習データは 30fps×5s×4 条件×2 試行=1200 画像、テストデータは 30fps×5s×4 条件×1 試行=600 画像となる。

テストデータの各画像から得た骨格情報を学習済み機械学習モデルに入力することで腰部負荷を推定し、精度を評価する。図 1 に AnyBody により算出した正解値と学習モデルによって推定した腰部負荷の関係を示す。図中の実線は正解値と推定値が一致する場合を示す基準直線であり、この直線にプロットが近いほど推定精度が高いことを示す。表 1 に機械学習モデルによる推定精度を示す。この結果より、ピアソンの相関係数が 0.965 となり推定値と正解値の間に高い相関を得た。また、学習モデルによる推定値と AnyBody によって算出した正解値との平均絶対誤差(以下 MAE)は 24.7[N]、二乗平均平方根誤差(以下 RMSE)は 31.6[N]となった。RMSE が MAE よりも大きいことから、一部のデータにおいて比較的大きな推定誤差が生じていることがわかる。この傾向は図 1 からも確認でき、多くのデータ点が基準直線近傍に分布している一方で、正解値の 400~500[N]の範囲のデータでは基準直線から大きく乖離したデータ点が多在している。また、正解値である腰部負荷の最大値と最小値の差は 391.37[N]と大きく、この変動幅と比較すると MAE は 6.32[%]、RMSE は 8.08[%]に相当する。一般に回帰問題では、学習データにおける正解値の分布に偏りが存在すると、特定の領域に対する学習が不十分となり、その領域において推定誤差が増大することが知られている<sup>6)</sup>。そのため、全体として誤差が相対的に小さい場合であっても、正解値分布の偏りは推定精度向上の妨げとなる可能性がある。

そこで、学習データを人為的に拡張することで学習データ分布の偏りを低減し、推定精度の改善を図る。画像データの拡張には Python ライブラリの OpenCV 及び NumPy を使用し、2.1 節で学習データとして用いた 1, 2 試行目の座位姿勢画像において、正規化された腰部負荷の分布に偏りが見られた負荷領域に対応する姿勢画像に対し、明るさ及びコントラストのランダムな調整、ガウスノイズの負荷、ならびにガウスぼかし処理を組み合わせて実施する。結果、編集画像を追加した後の学習データ総数は 2115 画像となった。

図 2 に学習データ分布を調整した条件における推定値と正解値の関係を示す。表 2 に示す推定精度より、表 1 と比較して高い相関係数を保ちながら MAE が 6.3[N]、RMSE が 7.1[N]とそれぞれ減少させることができた。この結果から、学習データ分布の偏りを低減させることで図 1 の基準線から大きく乖離したデータ点に対し十分な学習が行われ、推定精度の改善につながったと考えられる。

### 3. 結言

本研究では背もたれのある椅子での座位姿勢における腰部負荷を高精度に推定することを目的として、入力画像を基に得た骨格情報を用いた機械学習モデルを構築した。その結果、未学習データに対する推定においてピアソンの相関係数、MAE、RMSE の全てで高い精度を得ることができた。また、学習データの分布を調整することで MAE 及び RMSE の低減が確認され、推定精度がより改善した。

本研究では実験対象者 1 名で学習を行った。今後は複数名のデータを用いて学習及び推定を行い、汎化性を持たせたい。

### 文献

- (1) 令和 4 年度国民生活基礎調査の概要, 厚生労働省 <https://www.mhlw.go.jp/toukei/saikin/hw/k-tyosa/k-tyosa22/dl/04.pdf> 閲覧 2026.1.6
- (2) Riku Nishimoto and Kyoko Shibata: "Study of Generalization Performance on Non-Contact Estimation of Lumbar Load Using Webcam Image by Deep Learning for Stationary Standing Forward Bending Posture", International Journal on Advances in Life Sciences, vol. 15, no. 3&4, pp. 62-71, 2023.
- (3) Gong, Wenjuan, et al. "Human pose estimation from monocular images: A comprehensive survey." Sensors 16.12 (2016): 1966.
- (4) Menon, Rajiv G., et al. "Measurement of three-dimensional internal dynamic strains in the intervertebral disc of the lumbar spine with mechanical loading and golden-angle radial sparse parallel-magnetic resonance imaging." Journal of Magnetic Resonance Imaging 54.2 (2021): 486-496.
- (5) Hakky AI, "データセットの偏りを理解する | AI 精度向上のための対策", Hakky Handbook [https://book.st-hakky.com/data-science/what-is-dataset-bias?utm\\_source=chatgpt.com](https://book.st-hakky.com/data-science/what-is-dataset-bias?utm_source=chatgpt.com) 閲覧 2026.1.28