

インソール型歩容センサを用いた疲労推定方法の検討

深町 京佑[†] 成田 力哉[†] 佐藤 進[†] 河並 崇[†]金沢工業大学[†]

1. はじめに

近年、日本では健康寿命の延伸が重要視され、様々な取り組みが推進されている。身体活動・運動面では、日常生活における歩数の増加や運動習慣の確立など、身体活動量を増加させることが目標に掲げられている[1]。身体活動量の適度な増加は要介護リスクを軽減する一方で、過度な増加は疲労蓄積の原因となり転倒リスクを高めてしまう。高齢者は転倒により骨折にいたるほか、転倒恐怖感から日常活動が制限されると報告がある[2]。そこで、本稿では、疲労により起こる転倒を未然に防ぐことを目的とする。そのために、日常の歩行に注目し、機械学習を用いて歩容データ（歩き方）から疲労を検知する方法を検討する。

歩行分析では、歩行速度を変えると歩幅や歩行率（1分間の歩数）など歩行パラメータが変化することが明らかになっている[3,4]。日常の歩行では様々な速度で歩くことが想定されるため本稿では、機械学習で用いる特徴量に歩行速度の影響の有無が異なる2つの手法を提案する。

2. インソール型歩容センサ

歩容の計測には歩行分析センサ（NEC製、リアルタイム計測センサ、特殊ファームウェア、以後歩容センサと記す）を用いる。歩容センサは、縦40.0 mm、横30.5 mmの大きさで、これをインソールの土踏まず部分へ装着して使用する。歩容センサには3種類のデータ取得頻度が異なるものがあり、今回は毎歩計測できるリアルタイム計測センサを用いる。

表1に歩容センサより得られる歩行パラメータのデータ例と設定したしきい値を示す。センサでは慣性計測装置より計測する加速度および角速度から、歩行パラメータを算出している[5]。算出される歩行パラメータは歩行速度[km/h]、ストライド長[cm]、接地角度[度]、離地角度[度]、足上げ高さ[cm]、外回し距離[cm]、つま先の向き[度]の7つであり、これらを疲労推定のための特徴量に利用する。

今回用いる特殊ファームウェアは研究用のため、外れ値も取得できる。そのため、各歩行パラメータに表1に示すしきい値を設定し、範囲外のすべてのデータを削除する。

表1 歩行パラメータ

	データ例	しきい値
歩行速度 [km/h]	4.7	0.5 - 7.0
ストライド長 [cm]	127	50.0 - 200.0
接地角度 [度]	24	0.0 - 60.0
離地角度 [度]	85	0.0 - 100.0
足上げ高さ [cm]	12.2	0.0 - 30.0
外回し距離 [cm]	3.3	0.0 - 30.0
つま先の向き [度]	10	-15.0 - 30.0

A Study on Fatigue Estimation Method Using Insole Type Gait Sensor

[†]Kyosuke Fukamachi [†]Rikiya Narita [†]Susumu Sato

[†]Takashi Kawanami

Kanazawa Institute of Technology

3. 疲労推定方法

提案する疲労推定方法は、データの計測、データの前処理、機械学習による疲労推定よりなる。今回は個人ごとに疲労を推定する機械学習モデルを作成する。

本稿では、本学で行われた100 km歩行参加者11名および金沢マラソン参加者6名の合計17名（以後各被験者をA-Qと記す）を対象として、通常時と運動後（100 km歩行後または金沢マラソン後）のそれぞれで疲労度の評価と歩容データの計測を行った。本稿の被験者を伴うすべての実験は、金沢工業大学倫理審査専門委員会「人を対象とする研究倫理審査」による承認を得て実施した。

3.1 データの計測

本稿では疲労度の評価に図1に示すVAS(Visual Analog Scale)を用いる。VASは10 cmの直線上に現在の主観的疲労感を×印で示し、左端から×印までの長さ[cm]を疲労度とする方法である。本稿では疲労度が5.0 cm未満を通常状態、5.0 cm以上を疲労状態と定めた（以後各状態を通常、疲労と記す）。

VASによる主観的評価の結果、全被験者が通常時は通常、運動後は疲労であった（以後運動後を疲労時と記す）。

歩容データは、約300 m歩いた時に歩容センサより得られる歩行パラメータとする。歩容計測は、被験者がVASへの記入を終えた直後に行き、歩く前に「普段通りに歩いてください」と指示した。なお、被験者の履きなれた靴に歩容センサを装着したインソールを入れて計測した。



図1 VAS (Visual Analog Scale)

3.2 データの前処理

日常の歩行では、通常時の場合でも日によって歩行速度に差がある。また、歩行速度と一部の歩行パラメータの間には相関があると報告されている[3,4]。そのため、機械学習で用いる特徴量に歩行速度や歩行速度と相関のある歩行パラメータをそのまま用いた場合、学習データの歩行速度に依存して通常または疲労と判定される可能性が高くなる。これは疲労推定の精度を低下させる要因になると考えるため、速度成分を取り除く前処理を行う。

速度成分を除去するために、予備実験を実施して、歩行速度とその他の各歩行パラメータの関係を調べた。予備実験では、トレッドミル（竹井機器工業株式会社製、ウェルロード 200E）を用いて速度を3 km/h、4 km/h、5 km/hの順に各2分設定後、逆順で同様に各速度2分設定した時の被験者5名の歩容データを計測した。表2に予備実験より得られた歩行速度とその他の各歩行パラメータの相関および回帰式を示す。歩行速度とストライド長、接地角度、離地角度、足上げ高さの4つの歩行パラメータの間にそれぞれ0.5以上の相関があることがわかった。その

表2 歩行速度と6つの各歩行パラメータの関係

目的変数	相関係数	回帰式
ストライド長 [cm]	0.85	$y = 19.42x + 46.38$
接地角度 [度]	0.65	$y = 5.19x + 3.50$
離地角度 [度]	0.60	$y = 7.12x + 42.88$
足上げ高さ [cm]	0.54	$y = 1.11x + 8.26$
外回し距離 [cm]	-0.04	$y = -0.10x + 4.08$
つま先の向き [度]	-0.24	$y = -1.30x + 16.66$

後, 説明変数を歩行速度, 目的変数をその他の各歩行パラメータとした回帰分析より, 回帰式を求めた(表2).

前処理では, 予備実験で求めた回帰式を利用して歩行速度と0.5以上の相関がある歩行パラメータに対して, 作成した変換式を用いる. 変換式を以下の式(1)に示す.

$$p_a(p_b, v_a, v_b) = f_p(v_a) + (p_b - f_p(v_b)) \quad (1)$$

上式で p_a は変換後の歩行パラメータ, p_b は変換前の歩行パラメータの測定値, v_a は変換後に合わせる歩行速度, v_b は歩行速度の測定値, f_p は変換する歩行パラメータ p を目的変数とする回帰式である. 今回は歩行速度を4 km/hに合わせるため, v_a を4とする.

3.3 機械学習による疲労推定

機械学習により, 歩容データから被験者が通常または疲労のどちらであるか判定を行う. 本稿では, 機械学習モデルにランダムフォレストを採用した.

特徴量には, 前処理を行わないデータ(以後手法1と記す)と行うデータ(以後手法2と記す)を用いる. 手法1では, 特徴量に7つすべての歩行パラメータと足情報(左を0, 右を1とする)の8つを用いる. 手法2では, 速度成分を除去した5つの歩行パラメータ(歩行速度, ストライド長, 接地角度, 離地角度, 足上げ高さ), 除去していない2つの歩行パラメータ(外回し距離, つま先の向き)および足情報の8つを用いる. 手法2でも歩行速度を用いるが, 前処理により, すべての歩行速度は4 km/hに変換されているため, 通常または疲労の判定へは影響しない.

4. 疲労推定の評価

評価には, 10分割交差検証を用いた. 交差検証の各分割において疲労推定の正解率を求め, すべての分割の正解率の平均値より疲労推定モデルを評価した.

表3に評価結果を示す. 紙面の都合により, 各手法および手法2と手法1の差がそれぞれ最大, 最小となった被験者の結果と全被験者の平均のみを示している. 各手法で最も正解率が高かったのはF(0.994)とK(0.993)のモデルであった(()内の数値は正解率を表す). 一方, 最も低かったのはQ(0.772)とH(0.751)のモデルであった. 両手法の正解率を比較すると, Gのモデルのみ手法2が手法1を上回った. 正解率が手法1から手法2で最も低下したのはHのモデルで, 0.160低くなった.

手法2の結果について考察する. 図2にKとHの前処理前後のストライド長および離地角度の分布を示す. 図2(a)より, Kは前処理前後ともに通常時と疲労時で分布が相違していることがわかる. 一方, 図2(b)を見ると, Hの前処理前はKと同様に通常時と疲労時で相違しているが, 前処理後はほぼ一致していることがわかる. 同様の傾向が前処理を行った他の2つの歩行パラメータでも見られた. このことより, 疲労による歩容の変化には個人差があり,

表3 10分割交差検証による疲労検知の正解率

被験者	手法1 速度あり	手法2 速度なし	手法2 - 手法1
F	0.994	0.987	-0.007
K	0.993	0.993	-0.000
G	0.790	0.791	+0.001
Q	0.772	0.761	-0.011
H	0.911	0.751	-0.160
A-Q	0.895	0.848	-0.047

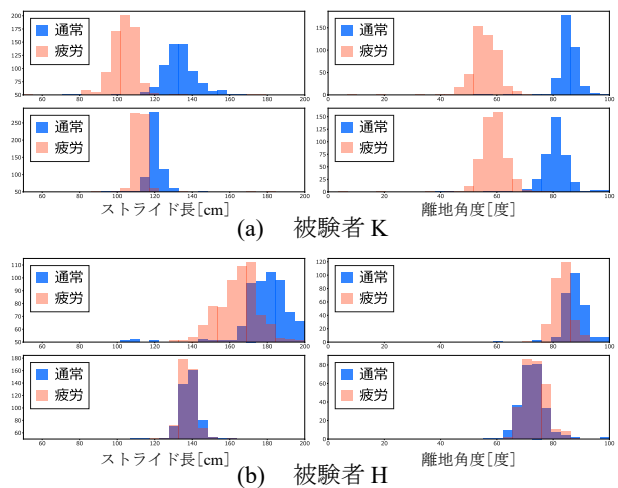


図2 ストライド長と離地角度の分布(上段:前処理前, 下段:前処理後)

通常時と比べて疲労時の歩容が, Kは変わるが, Hはほぼ変わらないと考えられる. したがって, 手法2では疲労により歩行速度以外の歩容が変化する人の疲労検知精度が高いと言える.

5. おわりに

本稿では, 歩容データから, 機械学習により疲労を推定する方法の提案と評価を行った. 特徴量に歩行速度の影響がある手法1と歩行速度の影響がない手法2の2つを比較した. その結果, 全被験者の正解率の平均は手法1より手法2の方が低い, ほぼ同等の結果が得られ, 歩行速度に依存しない疲労推定の基本モデルを開発できた. 今後は手法2を改善し, 歩行速度に依存しない疲労推定モデルの精度向上を試みたい.

参考文献

- [1] 厚生労働省: 健康日本21(身体活動・運動), 入手先<https://www.mhlw.go.jp/www1/topics/kenko21_11/b2.ht ml>, (参照2023-01-10).
- [2] 金憲経ほか: 高齢者の転倒関連恐怖感と身体機能—転倒外来受診者について—, 日本老年医学会雑誌, Vol. 24, No. 6, pp. 805-811, (2001).
- [3] 村田伸ほか: 最適歩行と最速歩行の相違—GAITRiteによる解析—, 理学療法科学, Vol. 19, No. 3, pp. 217-222, (2004).
- [4] 中江秀幸ほか: 健常女性における歩行パラメータと身体機能との関連性, ヘルスプロモーション理学療法研究, Vol. 6, No. 1, pp. 9-15, (2016).
- [5] K. Fukushi et al.: On-line algorithms of stride-parameter estimation for in-shoe motion-sensor system, *IEEE Sensors Journal*, Vol. 22, pp. 9636-9648, (2022).