

1. はじめに

運動に伴う疲労には大きく2種類存在する。1つは生理学的原理に基づいて身体が直接感じる客観的疲労であり、もう1つは運動者が感じる主観的疲労である。客観的疲労に関しては、生理学的原理に基づいて運動時に発生する電気パルスの集合を記録した筋活動電位 (EMG: ElectroMyoGram) を用いた方法が提案されているが [1, 2], 主観的疲労については、この研究分野で対象とされることはなかった。

一方、主観は人間の脳内で想起されるものであり、身体内部の状態を意味する内的要因と周辺環境の状態を意味する外的要因に起因する。つまり、各々を入力、主観を出力として構成されるシステムと捉えられる。ここで、外的要因は環境条件を一定に固定化することで排除でき、内的要因のみに限定できる。内的要因には、心拍、EMG、身体的特徴などが想定される (心理面については条件を設けて排除する)。

これまで本研究室では、運動時の内的要因に基づく主観的疲労の推定を目指し、EMGの持つ揺らぎを考慮したファジィ線形回帰 (FLR: Fuzzy Linear Regression) によるモデル構築を行っていた [3]。しかし、FLRは時系列データを質的変数に変換するため情報量の欠落や、時系列情報への追従性がないことが問題であった。本研究では、従来研究の時系列解析に加えてパターン認識を可能とする CRNN (Convolutional Recurrent Neural Network) を採用することで、時系列情報をそのまま活用しつつ、主観的疲労感への時系列追従性能を確保し、主観的疲労の推定精度向上を試みる。


2. 客観的疲労と主観的疲労のデータ取得

本研究の実験環境を Fig. 1 に示す。上腕二頭筋 (非利き手) を対象とし、肘を 90 度に固定した状態で手首に 6kg の各負荷を最長 360s 加えた際の等尺性収縮を対象として EMG 取得を行う。同時に、主観的疲労について Fig. 1(a) に示す VAS (Visual Analogue Scale) 法によって取得する [4]。

3. ニューラルネットワーク

3.1 Neural Network (NN) とは

ニューラルネットワークは機械学習の手法の一種であり、人の脳のネットワーク構造をもとに考案されたものである。そのネットワークは入力層、中間層 (隠れ層)、出力層を持つ階層構造で構成され、入



(a) VAS法による主観疲労の測定 (b) EMGによる客観的疲労の測定

Fig. 1 主観疲労と客観疲労の同時測定

力層は学習データを受け取る場所、出力層は学習結果を出力する場所、中間層はデータから特徴を抽出する場所となっている。

3.2 CRNN

CRNNは、CNNによる特徴抽出とRNNによる時系列対応により高精度な時系列パターンの学習が可能である。CRNNの学習方法において、CNNとRNNを別々に学習する2段階学習があり (Fig. 2), パラメータ更新を別々に行うことで、特徴量をCNNにより抽出し、RNNにより時系列に対応した学習と識別が可能となる。ここで、本研究ではCRNNモデル構築にSONY製NNC (Neural Network Console) を使用する。NNCは、ニューラルネットワークモデルを視覚的に実装できるツールであり、複雑なパラメータを自動で調整できる利点がある [5]。

4. データセット

4.1 データ収集

EMGの測定は疲労が残らないよう日を空けて各々3セット実施する。なお、実験協力者は20代男性21名とする。測定したEMGから各種信号処理により算出されたRMS、MDF、筋線維使用割合を説明変数、運動中のVASによる回答を教師データとする。




Fig. 2 CRNN 学習

4.2 データセット選定

EMG は実験協力者の身体的特徴や体調、または細かな実験条件の変化により正確な数値を示さない場合がある。そこで外れ値データを明確化するために説明変数の評価を行う。通常 RMS は疲労と共に増加、MDF は疲労と共に徐波化、筋線維使用割合は遅筋線維が疲労と共に増加し速筋線維が疲労と共に減少する傾向がある。そこで、実験協力者 21 名 3 回分の計 63 データを評価し、RNN モデルと CRNN モデルに適用可能なデータセット選定を以下手順で行う。

1. 実験協力者 21 名 3 回分の計 63 データの説明変数 (RMS, MDF, 筋線維使用割合) をそれぞれ閾値を定めて分類
2. RNN モデルと CRNN モデル各々に 1 で分類したグループをそれぞれ入力、全ての説明変数が正常値のものをテストデータにして学習
3. EMG の再現誤差は 16% [6] であるため 2 で算出した推定値と真値の平均誤差 16% 以内のものをデータセットとして選定

以上の手順で選定を行なった結果、RNN モデルのデータセット条件として“3つの説明変数の内 RMS と MDF が正常に計測できているもの”、CRNN モデルのデータセット条件として“3つの説明変数の内いずれの組み合わせにおいても 2 つが正確に測定できているもの”が主観的疲労推定に必要なデータセットの条件として選定された。

4.3 選定データセットでの学習

4.2 で分類した選定外のデータセット (Group1)、選定中のデータセット (Group2)、両方を合わせたデータセット (Group3) の 3 種類のデータセットで学習を行なった結果を Table 1 に示す。結果として、Group1 は誤差が多く EMG の再現誤差以内に収まっていないことがわかる。また、Group2 が最も平均誤差が少ない推定結果を示しており、Group3 については、平均誤差が 16% 以内であるものの、Group2 より平均誤差が大きいことがわかる。つまり、4.2 に示したデータセットの選定手法が、CRNN モデルの精度を高めること、すなわち過半数のデータが正確であれば精度を損なうことなく推定できるということがわかった。

Table 1 推定結果

Model	Group1[%]	Group2[%]	Group3[%]
CRNN	18.83	10.08	11.25

Table 2 一致割合

一致割合	○ [%]	△ [%]	● [%]	▲ [%]
CRNN	68.39	78.65	29.28	64.64
FLR	56.00	72.28	29.28	64.64




Fig. 3 CRNN モデル時系列追従推定結果
(区間 30s で移動平均フィルタ適用)

5. 検証

4.3 から、CRNN はデータセットが正確であるほど推定精度が良くなると考えた。そこで、全ての説明変数が正確に取得できている実験協力者をデータセットとして学習を行ない、FLR による推定と比較した結果を Table 2 に示す。ここで、○は真値と推定値が完全に一致している割合、△は推定値が真値を上回る割合、すなわち実利用を考慮した際のオーバーワーク防止の観点であるフェルセーフを含めた割合であり、黒印は各々の期待値を示している。この結果から、FLR と比較して、CRNN モデルによる推定の一致率の方が上回っていることがわかる。また、CRNN モデルにおける主観的疲労への時系列追従推定を確認した結果を Fig. 3 に示す。これは導出した推定値の高周波成分を除去するため移動平均フィルタを適用したものであり、真値と推定値の平均誤差は 2.8% となっている。

6. おわりに

主観的疲労推定の精度向上を目指し、先行研究と同様に EMG の各種処理データを説明変数、VAS による主観的疲労の回答を教師信号としてニューラルネットワークモデルを構築した。結果として、先行研究からの推定精度向上に加えて、誤差を EMG の再現誤差以内に収めた主観的疲労への時系列追従推定が可能であることを示唆した。

参考文献

- [1] 木塚, 他: バイオメカニズム・ライブラリー 表面筋電図, (2006)
- [2] 中島, 他: EMG を用いた筋線維タイプに基づく筋疲労推定モデルの構築, 電学論 C, **140** (7), 697/704 (2020)
- [3] 角脇: EMG を用いた主観的な筋疲労の定量化に関する研究 身体的特徴による分類とファジィ線形回帰によるモデリング, 鳥取大学修士論文, 1/45 (2021)
- [4] Sara de la Rosa de Sáa, et.al, “Fuzzy rating scale-based questionnaires and their statistical analysis”, *IEEE Transactions on Fuzzy Systems*, **23** (1), 111/126, (2015)
- [5] 足立, 他: ソニー開発の NeuralNetworkConsole 入門, (2017)
- [6] 櫛田, 他: 身体的特徴と EMG に基づく下肢リハビリシステムの構築, 電学論 C, **130** (7), 1132/1138, (2010)