

筋肉部位の活動推定による 正しいフォームでの筋力トレーニングの研究

嶋崎 浄^{1,a)} 山口 高康^{1,2,b)}

概要: 近年、コロナ禍による運動不足を理由に自宅で筋力トレーニングを始める人が増えている。しかし、その半数以上は、正しいやり方がわからない、体を痛めた、効果が実感できない、忙しいなどを理由に挫折してしまっている。そのため、トレーナーによる対面指導によって、短時間で効果を実感できる正しいフォームでのトレーニングを身につけることが望まれる。間違ったフォームで行うと、効果が薄れたり目的と違った部位が鍛えられてしまう恐れがある。本研究では、カメラ付きデバイスでトレーニングをしている様子を撮影し、トレーニングが効いている筋肉の部位を推定して、フォームの修正を示唆するアプリケーションを提案する。アームカールのトレーニングにおいて、深層学習で姿勢と筋電位との関係を学習し、上腕二頭筋と三角筋前部の筋電位を推定し、全身の反動を使ったチートを防止して、効率の良いトレーニングをできるようにした。

キーワード: 筋力トレーニング, フォーム, 姿勢推定, 筋電位, 深層学習

Effective Exercise Form Suggestion by Estimating sEMG of Muscle Parts

JO SHIMAZAKI^{1,a)} TAKAYASU YAMAGUCHI^{1,2,b)}

Abstract: Recently, many people started to try exercising at home because of the COVID19 pandemic. However, more than half of the beginners have given up because of reasons including “not knowing how to exercise in proper forms,” “have injured themselves,” “lack of perceivable physical change,” and “being too busy.” Hence, it is desirable for them to learn the proper forms in order to perform an effective exercise as early as possible. We provide a method for beginners to objectively evaluate their exercise form by displaying the sEMG of activated muscle parts which is estimated by extracting poses from exercise videos. In the arm-curl exercise, the sEMG values of the biceps brachii and frontal deltoid were estimated by deep learning, which learned the relationship between poses and device-read sEMG values. Our method helps beginners to prevent themselves from cheating and to exercise more effectively.

Keywords: Workout, Form, Pose Estimation, sEMG, Deep Learning

1. はじめに

人にとって運動とは健康を保つためにとても重要な活動である。適度な運動は高血圧、高脂血症、心臓疾患、脳卒中、糖尿病、または癌といった身体的な病に対する予防・改善効果があるとされている [1], [2], [3], [4]。また、適度な運動は身体的健康を増進するだけでなく、うつ病の

ような精神的病に対する予防・改善効果もあるとされている [1], [2], [3]。さらに、運動を行わない人々と比べ、適度な運動を行う人々の平均寿命は 0.4 年から 6.9 年高いとされている [4]。よって、適度な運動は心身共に健康的に過ごすためにとても重要な一要素であると言える。

しかし、2018 年における世界保健機関の報告によると、世界中の青年 (11 歳-17 歳) の 75%、成人 (18 歳-) の 25% が運動不足の状態にあるとした [1]。また、2019 年以降に世界的流行をした新型コロナウイルス感染症 (Coronavirus disease 2019: COVID-19) は多くの人々の運動の機会を減

¹ 秋田県立大学 システム科学技術研究科 経営システム工学専攻

² 情報処理学会

^{a)} jo.shimazaki@cps.akita-pu.ac.jp

^{b)} takayasu@akita-pu.ac.jp

らし [5], [6], [7], [8], [9], 運動不足の問題を悪化させた。こうした中、アメリカ疾病対策予防センターは、運動不足の人は運動している人と比べ、COVID-19 感染後に重症化、入院、または死亡するリスクが高いと報告した [10]。そのため、COVID-19 対策環境下でも適度な運動を行うことが望ましいと考えられる。そんな中、児童や青少年でも安全に行え [11]、他のスポーツと比べ場所を大きく取らない筋力トレーニング（以下筋トレと呼ぶ）が人気を集めている [12]。しかし、正しく筋トレを行う知識が不足している状態、または適格な指導が受けられない状態で筋トレを行うとケガをするリスクが高まる [11], [13]。実際、[12] の調査によると、筋トレをやめた人の内 11.8% は、「筋肉や腱、関節を痛めた」からやめたと答えた。さらに、正しいやり方がわからないと、つい無理をしてしまったり、非効率的な筋トレを行ってしまう。そのため、「疲れたくない身体への負担が大きい」、「効果が実感できない」または「面倒くさい」を理由に筋トレをやめてしまう人がいた [12]。

したがって、筋トレ初心者に対し、ケガのリスクを抑えつつ効果が実感でき、時間効率の良い運動方法を示唆できる手法を提案することが望まれる。また、その手法はより多くの人々がその恩恵を受けることができるように、一般的なハードウェアのみで行えることが好ましい。さらに、COVID-19 対策環境下のような比較的隔離された環境下でも実践できることが望ましい。以上の理由により、本研究はスマートフォン上でも動作ができる、筋トレにおけるフォームの修正を示唆するアプリケーションを提案する。

2. 関連研究

この章では、本研究における提案手法のコア技術となる「筋電位」と「ニューラルネットワークを使った姿勢推定」の二つについて紹介する。また、それらのコア技術を応用した、運動におけるフォーム、パフォーマンスの測定あるいは改善を目的とする研究も紹介する。

2.1 筋電位

筋肉は収縮する時に微弱な電気が発生する [14]。そのため、筋肉の仕事量を定量的に評価する際、一般的に筋電図が使われる。また、その筋電図には大きく分けて 2 種類あり、侵襲的と非侵襲的手法に分けられる [15]。侵襲的手法の代表例は針筋電図であり、測定したい筋部位に直接、測定用の針を挿入して計測する [14], [15]。この手法は医学設備および知識が必要である。一方、非侵襲的手法の代表例は目的の筋部位の皮膚表面上にセンサを貼り付け計測する表面 EMG がある。こちらの手法は医学知識が無くても比較的手軽に行える。そのため IoT や機械学習の分野でも利用されている。したがって、本研究でも表面 EMG を使う。また、以下に記述される EMG は全て表面 EMG を示すこ

ととし、EMG で計測できた筋電位の値を EMG 値と表記する。

2.2 姿勢推定

姿勢を推定するにはさまざまな方法があるが主にスマートフォンのような一般的デバイスに搭載されたカメラ一つで姿勢推定が行えるニューラルネットワーク（以下、NN と呼ぶ）を使った方法に注目する。

NN を使った姿勢推定において「人体をどのように表現するか」という課題に対し主に 3 つのアプローチが挙げられる。一つ目の手法はキネマティックモデルと呼ばれ、任意の n 点からなる関節点群に方向の情報を付与し人体の構造を表現している。このモデルの多くは、図構造 (Pictorial Structure Model: PSM) と呼ばれる、木のような構造でそれぞれの関節点を相対的に位置付け人体の構造を表現している。また数多くの 2D・3D 姿勢推定に使用されている。さらに、非常に柔軟な表現方法とされているが、欠点として表面や形の情報を表現できない。二つ目の手法は平面モデルと呼ばれ、大まかな人間の形に沿う長方形または平面群で人体の構造を表現している。また、Kinematic モデルと同様に、体のパーツに相対性を持っている。三つ目の手法は、体積モデルと呼ばれ、人体を 3D で表し、体積情報を持たせたモデルである。代表例は Skinned Multi-Person というモデルで、それは姿勢によって変化する体の形を柔軟に表現できる [16]。

本研究では、軽量かつ 3D 姿勢推定可能な Kinematic モデルの BlazePose [17] を使うことにする。また、BlazePose はブラウザ上でも動作するため、より多くの人々が利用できると考えられる。

2.2.1 BlazePose

BlazePose [17] は Google の研究チームが 2020 年に発表した、畳み込みニューラルネットワーク (Convolutional Neural Network: 以下 CNN と呼ぶ) を使った、スマートフォン上でも作動する比較的軽量の 3D 姿勢推定モデルである。Google が過去に出した PoseNet [18] は 2D かつ 17 点の姿勢座標しか予測できなかったのに対し、BlazePose は 3D かつ 33 ヶ所の姿勢座標を予測できる。また、他の有名なモデルの OpenPose [19] と比べ、25~75 倍早く動作した [17]。

2.3 運動補助の研究

NN を使った筋トレ・運動補助を目的とした研究は数多く存在する。本研究ではその中でも「姿勢予測を使ったフォーム異常検知および回数検知の研究」と「姿勢推定情報を使った EMG 値推定の研究」の 2 つに注目する。

2.3.1 姿勢予測を使ったフォーム異常検知および回数検知の研究

[20] は CNN を使った姿勢予測から関節角度計算して、お

手本となるフォームとの関節角度の違いを使ってフォームの異常を検知した。[21]は動画から PoseNet で姿勢予測を行い、その姿勢点から深層 NN で運動の開始と終わりを二値分類し、運動の回数を数える手法を提案した。[22]はユーザがオンラインのチュートリアル動画を見ながらフォームを修正できるよう、トレーナとユーザの姿勢を PoseNet で予測し、画面上にオーバーレイした。またその際、両者の姿勢予測点を同時に表示するのではなく、ユーザだけの姿勢予測点を表示した場合の方が、ユーザが正確にトレーナの動きを真似できるとした。[23]は対象が素早く動き回る競技(例、スキーやスケート)においての動画からアドバイスをできる手法を提案した。そのような動画では、対象が画面上を素早く動き回るので、まず深層 NN を使い対象の軌道を追従し、その追従範囲内で CNN を使った姿勢予測を行うことで測性能を高めた。そして、手本動画との関節角度およびスキー板角度の違いなどから、フォームに異常がみられる動画の箇所を検出した。さらに、ユーザへのアドバイスとして、フォーム異常箇所に手本となる動きの動画の箇所を表示した。[24]は自走ロボットが自動的にリハビリ施設にいる高齢者に対して適切な運動を示唆し記録するシステムを開発した。そのロボットは定時になると適切な運動メニューを生成しおよび示唆する。そして、高齢者がそのメニューを正常に追従できているか否かを記録する。

2.3.2 姿勢推定情報を使った EMG 値推定の研究

[25]は複数台のカメラ、加速度・角加速度センサの情報から車椅子バスケットを行う選手の5ヶ所のEMG値(深指屈筋, 上腕二頭筋, 上腕三頭筋, 三角筋後部, そして大胸筋)を推定する手法を提案した。姿勢推定は、2DのOpenPoseモデルを使ったが、複数の角度に設置された複数のカメラで同時に2D姿勢推定をし、それらの推定を合成することによって3D姿勢推定情報を得た。また、EMG値を予測するモデルは1D-CNNを使っている。さらには被験者が7人であったため、それぞれの筋力差を最大随意収縮(Maximum Voluntary Contraction: MVC)を使って正規化した。結果として、それぞれの筋肉における予測値と実測値の平均相関係数0.5以上、有意水準0.1%となった。[26]は筋トレのスクワット種目における太腿筋のEMG値をスマートフォンで撮影した動画のみから推定する手法を提案した。2D姿勢推定モデルのPoseNetを使い、それから予測された姿勢推定点を3つの異なるNNモデルに入れEMG予測値の結果を比較した。全結合の深層NN, 1D-CNN, そしてLong Short-Term Memory(以下、LSTMと呼ぶ)の3モデルの内、LSTMが最も正確であるとした。[26]は、[26]の後続研究であり、二種目の筋トレ(スクワットとバーベルプッシュアップ)における2つのEMG値(太腿筋と肩の筋肉)を予測する方法を提案した。また、特徴量として姿勢推定点と種目の二値分類予測情報の二つを使うことに

よってEMG予測の精度を向上させようと試みた。

3. 提案手法

本研究では、ダンベルを使ったアームカール一種目における筋トレの動画からEMG値を予測し、その予測されたEMG値を元に、ユーザのチートを検出する手法を提案する。

3.1 提案手法の概要

以下が本研究における提案手法の概要である。大きく分けると「モデルの学習」と「モデルの予測からのチート判定」の2部から構成される:

(1) モデルの学習:

- (a) カメラ付きデバイスでトレーニングをしている様子を撮影し、その動画をBlazePoseに入力し、n点から構成される3D姿勢座標(X, Y, Z)を推定する。また同時に、EMGセンサで実際のEMG値を測定する。
- (b) 上記の推定した3D姿勢座標を説明変数X, 実測EMG値を目的変数yとして、回帰LSTMモデルに入力し、姿勢と筋電位の関係を学習する。

(2) モデルの予測からのチート判定:

- (a) 学習済みのLSTMモデルにBlazePoseの3D姿勢座標を入力し、鍛えたい筋部位のEMGの推定値(以下、ターゲットEMG値)と、鍛えたくない筋部位のEMGの推定値(以下、非ターゲットEMG値)を得る。
- (b) 上記の推定した3D姿勢座標を説明変数X, 実測EMG値を目的変数yとして、回帰LSTMモデルに入力し、姿勢と筋電位の関係を学習する。

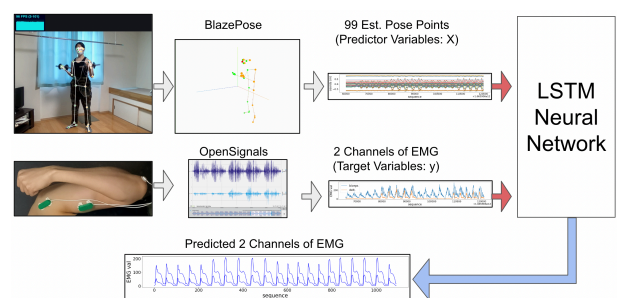


図1 提案手法概要の図その1: 動画からEMG値を予測する。

3.2 データ収集

この章では被験者とデータ収集について述べる。

3.2.1 被験者

実験は1人の被験者(筆者自身)を対象に行った。被験者は男性で、25歳、これまでに認識している持病はなく、健康な状態であった。

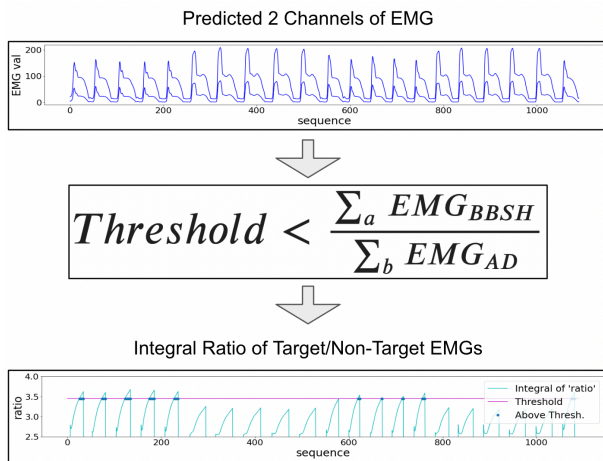


図2 提案手法概要の図その2: 予測 EMG 値からチートを検出する。

3.2.2 実験




図3 EMG センサの取り付け箇所。左から三角筋前部, 上腕二頭筋短頭, そして肘にリファレンスを設置した。

実験は2日間(モデルのトレーニング用と評価用)に分けて実施した。また、それぞれ2つの異なる家庭環境下で実施した。各実験は約30分で、被験者はカメラの前に立ち、全身がカメラのフレームに収まるようにして、二つの5kgダンベルを使いアームカール運動を約100回ずつ(約20回×5セット)行った。それを二日に分けて実施したので、合計で約200回(約20回×5セット×2日間)実施した。各セットの長さは1分間を目標としたが、毎回、記録を開始する度にEMGソフトウェアがロードし記録がしばらく開始されなかったため、実際の記録データは1分間より若干短くなった。そのため、1セットに行われる反復回数はおおよそ約20回である。各セット中、チート無しとチート有りのアームカールを5回ずつ交互(例えば、5回チート無し、5回チート有り、5回チート無し、5回チート有りという風)に行った。また同時に、ブラウザ上(TensorFlow.js)で動作するBlazePoseを使い、約96Hzで33点の相対的な3D姿勢予測点(以下、3D姿勢点と呼ぶ)を記録した。さらに、上腕二頭筋短頭(Biceps Brachii Short Head, 以下BBSHと呼ぶ)と三角筋前部(Anterior Deltoid, 以下ADと呼ぶ)のEMG値を、MuscleBITセンサーを使って1000Hzで10bit(-512~511)の範囲で記録した。

要約すると、収集されたデータは以下の2種類である：
(1) 33点の相対的な3D姿勢点(x, y, z, 単位はメートル)

および、それらの信頼度(0~1)、を約96Hzで記録し、
(2) 2チャンネル(BBSHとAD)のEMG値、を10bit(-512~511)の範囲、1000Hzで記録した。

さらに、3D姿勢点とEMG値をダウンサンプリングして同期できるように、Unixタイムスタンプ(例:1665905100130)と時間情報(YYYY:MM:DD and HH:MM:S.ms)をそれぞれ記録した。

3.3 LSTMモデル学習

3.3.1 データの前処理

(1) 3D姿勢点(説明変数:x): 3D姿勢点のデータから信頼度は、カメラの写角に被験者の全身が写っているため、除外した。さらに、データを滑らかにするために、窓サイズ5の平滑化関数を適用した。最終的な予測変数の数は99(33点×3軸)である。

(2) EMG値(目的変数:y): まず、EMG値のデータに-512の値を加え、を絶対値化した。次に、データに窓サイズ100の平滑化関数を適用した。




図4 実測 EMG 値の例。




図5 -512を加え絶対値化したEMG値の例。




図6 窓サイズ100の平滑化をしたEMG値の例。

(3) xとyの同期: 3D姿勢点とEMG値データは、それぞれ約96Hzと1000Hzの異なるサンプルレートで記録されている。そのため、20Hzにダウンサンプリングし、同期した。また欠損値がある場合は、欠損値の前後の値を平均した値を使用した。

(4) xとyの窓化: LSTMはウィンドウ化されたデータを入力する必要があるため、上記のデータXとYに対して窓サイズ7のスライディングウィンドウ関数を適用した。最終的なXとyのデータの形状はそれぞれX(1092, 7, 99)とy(1092, 2)となった。

3.3.2 LSTMモデルの概要

本研究では、3D姿勢点(X)からEMG(y)を予測できるモデルを作るため、tensorflow.kerasライブラリのLSTM層[27]を使用した。図7はモデルの構造を表す。モデルの学習用データには、実験1日目で得られたデータ(20回×5セット≒約100回)を使用した。これを80-10-10の割

Model: "sequential"

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 64)	40448
dense (Dense)	(None, 32)	2080
dropout (Dropout)	(None, 32)	0
dense_1 (Dense)	(None, 16)	528
dense_2 (Dense)	(None, 2)	34

 Total params: 43,090
 Trainable params: 43,090
 Non-trainable params: 0

図7 LSTMモデルの構造.

合で、それぞれ、訓練用データ、検証用データ、そしてテスト用データに分割した。モデル全ての全結合層(以下、Dense層と呼ぶ)はReLU(Rectified Linear Unit)を活性化関数として使用した。また、モデルが過学習しないよう、Dense32層とDense16層の間に、ドロップアウト率0.5のドロップアウト層を設けた。さらに、モデルの損失関数には平均二乗誤差(Mean Squared Error)を使った。そして、エポック回数を100回に設定して学習させた。

3.4 チート検出方法

本研究は、筋力トレ中のチートを検出するために、以下のようなステップを提案する:

- (1) まずは、時系列データからアームカールが行われている区間を検出する。本研究では、2つの推定されたEMG値を加算し、適切な閾値を設定することで、アームカールが行われている区間を検出する。
- (2) チャンネル毎の区間毎のEMG値をそれぞれ積分する。
- (3) 上記の積分値を使って、鍛えたい筋部位(以下、ターゲット筋部位と呼ぶ)と鍛えたくない筋部位(以下、非ターゲット筋部位と呼ぶ)の比率を計算する。
- (4) 上記の比率が適切に設定された閾値より低い場合、そのアームカールはチートと判断する。

式1が今回のような、2箇所の筋肉部位(BBHSとAD)における、チートの検出に使用した式である:

$$\text{閾値} < \frac{\sum_a EMG_{BBHS}}{\sum_b EMG_{AD}} \quad (1)$$

また、式2が非ターゲット部位が2ヶ所以上の場合における、チート検出の一般式である:

$$\text{閾値} < \frac{\sum_t EMG_{(a,t)}}{\sum_{i \neq a} \sum_t EMG_{(i,t)}} \quad (2)$$

4. 結果と評価

この章ではLSTMモデルによる動画からのEMG値の予測の結果・評価、およびその予測値を使ったチート判定の結果・評価を行う。

4.1 LSTMによるEMG値推定

図8は、横軸をエポック数、縦軸を平均絶対誤差(MAE)としたモデルの学習経過を示したものである。このモデルは検証データで約20MAEを達成した。また、図9と図10はEMGの実測値とその予測値の例である。




図8 エポック毎の損失値.




図9 実測 EMG 値の例. 上が BBHS, 下が AD.




図10 予測 EMG 値の例. 上が BBHS, 下が AD.

4.2 EMG値推定からチート検出

チート検出法の評価においては、その妥当性を正しく評価するために、モデルがこれまで見たことのないデータを使用した。つまり、実験2日目のデータ(約20回×5セット≒100回)のみを使用した。

正解ラベルは、実測EMG値のグラフから目測でチートと非チートに分け、数え上げた。予測ラベルは、予測EMG値のグラフに対し3.4章で説明したステップを適用し、ターゲット筋部位と非ターゲット筋部位の積分値の比率を表すグラフと生成した。そして、正解・予測ラベルのグラフを目測で見比べ、チート検出における正解・非正解を数え上げた。上記の過程を図11に表す。結果として、本研究の

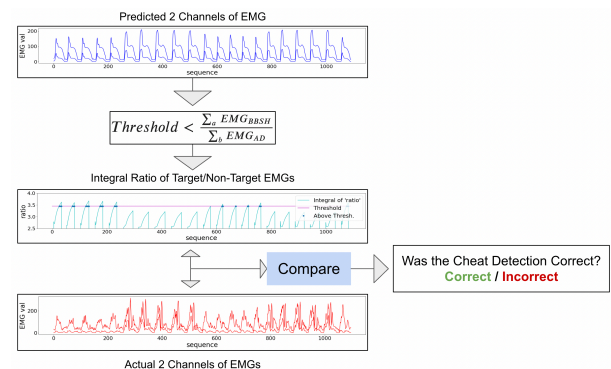


図11 チート検出の正解/不正解のラベルのロジックの図.

チート検知手法は、正解率95.1%、精度92.2%、再現率97.9%、そしてF1スコア94.9%を達成した。

	Actual Pos.	Actual Neg.	total
Predicted Pos.	47(TP)	4(FP)	51
Predicted Neg.	1(FN)	50(TF)	51
total	48	54	n=102

図 12 チート検出の混同行列による評価.

Scores:

- accuracy: 0.951
- precision: 0.922
- recall: 0.979
- f1: 0.949

図 13 モデルの正確度合い.

5. 考察

テストデータ(実験 2 日目のデータ)において, 正解率 95.1%, 精度 92.2%, 再現率 97.9%, そして F1 スコア 94.9% を達成したので, 本手法は比較的有効であると考えられる. しかし, 図 4, 5, や 6 からみてとれるように, 被験者の EMG 値がセンサの範囲 (0 1024, または -512~511) の間に収まっていないことがわかる. これは, EMG ソフトウェアの「EMG 用の設定」のゲイン初期値が大きすぎたことに原因がある. そのため, 今後はより正確な EMG 値を計測するため, 初期設定ではなくカスタム設定で適切なゲイン値に調節する必要がある. また, 今回は被験者が一人だったため, それぞれの筋部位の EMG 値を MVC で正規化しなかったが, 今後, より幅広いユーザでも正しく動作するように, 被験者毎の EMG 値を MVC で正規化する必要がある. さらに, 今回はアームカール種目, ターゲット・非ターゲット筋部位がそれぞれ一ヶ所ずつだったが, 今後, 複数の筋部位を使った種目でも, 一般式 2 を使った検証を行っていく必要がある. そして, 5kg ダンベル以外の重さでも, 手法が正しく通用するように, 文字認識または物体認識などを使って自動的に重りの種類と重量を判別できるようにする必要がある.

6. まとめ

本研究は, 5kg ダンベルを使ったアームカール種目における筋トレの動画から, ユーザのチートを検出する手法を提案した. まず BlazePose を使って動画から 3D 姿勢推定点を予測した. そして, それらの姿勢推定点を LSTM ネットワークに入れることで上腕二頭筋短頭と三角筋前部の EMG 値を予測した. そして, それらの予測 EMG 値の積分値の割合から適切な閾値を設定し, その閾値を下回ったらチートと判断した. 本研究の提案手法は, 正解率 95.1%, 精度 92.2%, 再現率 97.9%, そして F1 スコア 94.9% でアームカール時のチートを検出できた. しかし,

被験者が一人, ゲインの調節不足, 実測 EMG 値を MVC を使って正規化していない, 重りの重量が 5kg と固定されていた上, アームカール種目による検証だったので, 今後, 更なる一般化に向け研究を進めていく必要があると考えられる.

参考文献

- [1] World Health Organization. Global action plan on physical activity 2018–2030: more active people for a healthier world. <https://apps.who.int/iris/bitstream/handle/10665/272722/9789241514187-eng.pdf>, 2018. Accessed: 2022/10/21.
- [2] 森谷 敏夫. 生活習慣病における運動療法の役割. *リハビリテーション医学*, Vol. 40, No. 7, pp. 430–435, 2003. Online available at: https://www.jstage.jst.go.jp/article/jjrm1964/40/7/40_7_430/_article/-char/ja/; Accessed: 2022/10/21.
- [3] F. Penedo and J. Dahn. Exercise and well-being: a review of mental and physical health benefits associated with physical activity. *Current Opinion in Psychiatry*, Vol. 18, No. 2, pp. 189–193, 2005. Online available at: https://journals.lww.com/co-psychiatry/Abstract/2005/03000/Exercise_and_well_being__a_review_of_mental_and.13.aspx; Accessed: 2022/10/21.
- [4] G. Knapp C. Reimers and A. Reimers. Does physical activity increase life expectancy? a review of the literature. *Journal of Aging Research*, Vol. 2012, No. 243958, 2012. Online available at: <https://www.hindawi.com/journals/jar/2012/243958/>; Accessed: 2022/10/30.
- [5] World Health Organization/Europe. Considering physical activity and covid-19. <https://www.who.int/europe/activities/considering-physical-activity-and-covid-19>. Accessed: 2022/10/22.
- [6] A. Ammar *et al.* Effects of covid-19 home confinement on eating behaviour and physical activity: Results of the eclb-covid19 international online survey. *Nutrients*, Vol. 12, No. 6, 2020. Online available at: <https://www.mdpi.com/2072-6643/12/6/1583>; Accessed: 2022/10/22.
- [7] G. Lucas Y. Xiao, B. Becerik-Gerber and S. Roll. Impacts of working from home during covid-19 pandemic on physical and mental well-being of office workstation users. *Journal of Occupational and Environmental Medicine*, Vol. 63, No. 3, pp. 181–190, 2020. Online available at: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7934324/>; Accessed: 2022/10/22.
- [8] A. Pavlovic *et al.* Keeping children healthy during and after covid-19 pandemic: meeting youth physical activity needs. *BMC Public Health*, Vol. 21, No. 485, 2021. Online available at: <https://bmcpublihealth.biomedcentral.com/articles/10.1186/s12889-021-10545-x>; Accessed: 2022/10/22.
- [9] H. Oka S. Kasahara K. Kawamata T. Yoshimoto, T. Fujii and K. Matudaira. Pain status and its association with physical activity, psychological stress, and telework among japanese workers with pain during the covid-19 pandemic. *International Journal of Environmental Research and Public Health*, Vol. 18, No. 11, 2021. Online available at: <https://www.mdpi.com/1660-4601/18/11/5595>; Accessed: 2022/10/22.

- [10] Centers for Disease Control and Prevention. Physical activity and covid-19. <https://www.cdc.gov/physicalactivity/physical-activity-and-COVID-19.html>, 2022. Accessed: 2022/10/23.
- [11] A. Faigenbaum and G. Myer. Resistance training among young athletes: safety, efficacy and injury prevention effects. *British Journal of Sports Medicine*, Vol. 44, No. 1, pp. 56–63, 2009. Online available at: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3483033/>; Accessed: 2022/10/30.
- [12] ショップジャパン(株式会社オークローンマーケティング). 習慣的な運動・筋トレに関する調査. <https://prtmes.jp/main/html/rd/p/000000373.000001915.html>, 2020. Accessed: 2022/10/30.
- [13] D. Bonilla *et al.* Exercise selection and common injuries in fitness centers: A systematic integrative review and practical recommendations. *International Journal of Environmental Research and Public Health*, Vol. 19, No. 19, 2022. Online available at: <https://www.mdpi.com/1660-4601/19/19/12710>; Accessed: 2022/10/30.
- [14] J. Cram. The history of surface electromyography. *Applied Psychophysiology and Biofeedback*, Vol. 28, No. 2, pp. 81–91, 2003. Online available at: <https://pubmed.ncbi.nlm.nih.gov/12827987/>; Accessed: 2022/10/30.
- [15] H. Nakamura. Back to basics series: Biomedical measurement 1(electromyography). *Transactions of Japanese Society for Medical and Biological Engineering*, Vol. 57, No. 4-5, pp. 149–157, 2019. Online available at: https://www.jstage.jst.go.jp/article/jsmbe/57/4-5/57_149/_article/-char/en; Accessed: 2022/10/30.
- [16] C. Zheng *et al.* Deep learning-based human pose estimation: A survey. *J. ACM*, Vol. 37, No. 4, 111, 2018. Online available at: <https://arxiv.org/abs/2012.13392>; Accessed: 2022/10/28.
- [17] K. Raveendran T. Zhu F. Zhang V. Bazarevsky, I. Grishchenko and M. Grundmann. BlazePose: On-device real-time body pose tracking. *Computer Vision and Pattern Recognition: Workshop on Computer Vision for Augmented and Virtual Reality*, 2020. Online available at: <https://arxiv.org/abs/2006.10204>; Accessed: 2022/10/27.
- [18] M. Grimes A. Kendall and R. Cipolla. PoseNet: A convolutional network for real-time 6-dof camera relocalization. *IEEE International Conference on Computer Vision*, 2015. Online available at: <https://arxiv.org/abs/1505.07427>; Accessed: 2022/10/31.
- [19] T. Simon S. Wei Z. Cao, G. Hidalgo and Y. Sheikh. OpenPose: Realtime multi-person 2d pose estimation using part affinity fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 43, No. 1, pp. 172–186, 2019. Online available at: <https://ieeexplore.ieee.org/document/8765346/authors#authors>; Accessed: 2022/10/31.
- [20] D. Shi and X. Jiang. Sport training action correction by using convolutional neural network. *Internet Technology Letters*, Vol. 4, No. 3, 2020. Online available at: <https://onlinelibrary.wiley.com/doi/abs/10.1002/itl2.261>; Accessed: 2022/10/28.
- [21] Auto.fit: Workout tracking using pose-estimation and dnn. *International Journal of Engineering Applied Sciences and Technology*, Vol. 5, No. 2455-2143, 2020. Online available at: https://www.ijeast.com/papers/167-173_Tesma501_IJEAST.pdf; Accessed: 2022/10/28.
- [22] K. Choo A. Tharatipyakul and S. Perrault. Pose estimation for facilitating movement learning from online videos. No. 64 in *AVI '20: Proceedings of the International Conference on Advanced Visual Interfaces*, pp. 1–5, 2020. Online available at: <https://dl.acm.org/doi/10.1145/3399715.3399835>; Accessed: 2022/10/28.
- [23] H. Peng J. Fu J. Wang, K. Qiu and J. Zhu. Ai coach: Deep human pose estimation and analysis for personalized athletic training assistance. *MM '19: Proceedings of the 27th ACM International Conference on Multimedia*, pp. 374–382, 2019. Online available at: <https://dl.acm.org/doi/10.1145/3343031.3350910>; Accessed: 2022/10/28.
- [24] M. Cazorla A. Costa, E. MartinezMartin and V. Julian. Pharosphysical assistant robot system. *Sensors* 2018, Vol. 18, No. 8, 2633, 2018. Online available at: <https://www.mdpi.com/1424-8220/18/8/2633>; Accessed: 2022/10/28.
- [25] R. Mizukami T. Sakai S. Aihara, R. Shibata and A. Shionoya. Deep learning-based myoelectric potential estimation method for wheelchair operation. *Sensors* 2022, Vol. 22, No. 4, 2022. Online available at: <https://www.mdpi.com/1424-8220/22/4/1615>; Accessed: 2022/10/28.
- [26] 藤本彬仁, 牛尼剛聡. トレーニング支援のための動画からの運動効果の推定. *Data Engineering and Information Management*, 2021. Online available at: <https://proceedings-of-deim.github.io/DEIM2021/papers/C21-1.pdf>; Accessed: 2022/10/28.
- [27] 2019 The TensorFlow Authors. Tensorflow v2.10.0: [tf.keras.layers.LSTM](https://www.tensorflow.org/api_docs/python/tf/keras/layers/LSTM). https://www.tensorflow.org/api_docs/python/tf/keras/layers/LSTM, 2022. Accessed: 2022/10/28.