

# 筋電信号を使った人体骨格モデルの3Dアニメーション再生

堀越 力<sup>†</sup> 野上 佳恵<sup>‡</sup>

<sup>†</sup> 湘南工科大学工学部 〒251- 8511 神奈川県藤沢市辻堂西海岸 1-1-25

E-mail: <sup>†</sup> horikoshi@info.shonan-it.ac.jp, <sup>‡</sup> nogami@mat.shonan-it.ac.jp

**あらまし** サーフィンなどのマリンスポーツでは、同じコンディションで繰り返し練習することは難しい。一方、VRは同じ体験を繰り返しできる技術であり、スポーツトレーニングでの効果が期待されている。スポーツトレーニングでは、筋肉の使い方を理解することが重要であるが、現状のVRシステムでは、モーションセンサーを用いることが主流であり、筋肉のデータは利用していない。本研究では、トレーニング時の筋肉の動きをEMGセンサーで計測し、トレーニング者の3次元的な動きを再現することを目指している。本発表では、EMGデータから3Dモーションの動きを深層学習により学習する。その学習データセットを利用し、EMGセンサーのみから、骨格モデルの3Dモーションを再生する手法を提案する。

**キーワード** スポーツトレーニング、ヴァーチャルリアリティ、筋電センサー、サーフィン、深層学習

## 3D Animation of a Humanoid Model using EMG Sensors

Tsutomu HORIKOSHI<sup>†</sup> and Yoshie NOGAMI<sup>‡</sup>

<sup>†</sup> Shonan Institute of Technology 1-1-25 Tsujido Nishi-Kaigan, Fujisawa-shi, Kanagawa, 251-8511, Japan

E-mail: <sup>†</sup> horikoshi@info.shonan-it.ac.jp, <sup>‡</sup> nogami@mat.shonan-it.ac.jp

**Abstract** In marine sports such as surfing, it is difficult to practice repeatedly under the same conditions. On the other hand, VR is a technology that can repeat the same experience, and is expected to be effective in sports training. In sports training, it is important to understand how to use muscles, but in the current VR system, the use of motion sensors is the mainstream, and muscle data is not used. In this research, we aim to reproduce the three-dimensional movements of trainees by measuring the muscle movements during surfing training with an EMG sensor. In this presentation, we learn 3D motions from EMG data by deep learning. We propose a method to reproduce 3D motion of human skeleton model using only the EMG sensor using the learning data set.

**Keyword** Sports Training, Virtual Reality, EMG Sensor, Surfing, Deep-Learning

### 1. はじめに

マリンスポーツでは、波の状態が常に変化するため、同一コンディションでの繰り返し練習が難しい。また、天候にも大きく左右されるため、トレーニングをしたくても自由な時間帯に実践的なトレーニングを行うことができないという課題がある。特にサーフィンでは、海上での個人種目であり、コーチが付き添ってのトレーニングも難しく、サーフィントレーニング方法に関しては、これまで科学的な検証が殆ど行われてきていない。

一方、バーチャルリアリティ (VR) は、体験を共有できる/再現できる技術として、スポーツトレーニングに利用する例も増えている。プロ野球ではピッチャーが投げたボールの球筋を見極める訓練などに取り入れている例がある。また、360度映像を使ってその場にいる感覚を再現したり、身体の重心移動を利用したゲームアトラクションも多い。

そこで、我々は、サーフィンのトレーニングにおいて、VRに着目している。VR技術を利用することで、同じ状況を再現した繰り返しトレーニングがサーフィンにおいても可能になると期待できる。

スポーツトレーニングにおいて動きを解析するために、モーションセンサーを利用することが一般的である。しかし、モーションセンサーは、3次元ベクトル情報 (骨格構造の動き・傾き) を計測するに留まる。サーフィンでは、ボードの上に立つという平衡感覚が非常に重要なスポーツである。サーフィンにおいては、同じ姿勢であっても、熟練者と初心者では、筋肉の使い方が大きく異なる。そのためトレーニングでは、筋肉の活性状態を計測する必要がある。

モーションキャプチャ装置を使えば、何も装着せずとも動きを解析することは可能であるが、筋電は計測できない。近年、小型ワイヤレスセンサーの開発が進み、計測対象者の動きを妨げずに動作解析が可能となって

いる。しかし、モーションセンサやEMGセンサを多数装着することは、運動の妨げという観点で望ましくない。

近年、筋電センサから動きを推定するため、筋電の時系列データを学習し、動作識別を行い、ロボット制御に利用した例や、筋電センサの時系列データの特性を活かしたNNを提案し、ポインタデバイスに利用した例などが報告されている[1, 2, 3]。また、近年の深層学習アルゴリズムの発展により、時系列データの学習に特化したアルゴリズムも提案されている[4]。

本稿では、筋電のデータから、計測部位の連続的な動き・動作を学習し、その学習データを使って、筋電データのみから3次元的な動きを推定・再現する。そして、初級者・熟練者の筋肉の使い方を可視化することを目指している。そこで、本稿では、下肢の筋電のみから、足の3次元的な動きを再現する手法を提案する。

## 2. 提案手法

EMGセンサのみから3D骨格モデルのアニメーションを再現するために、EMGセンサ情報と各骨格の動き（関節の角度）の関係を深層学習により学習する。その学習ネットワークを使って、筋電データのみから動きを再現する。

動きを推定するために、まず同一部位にEMGセンサ及びモーションセンサを装着し、被験者の動きを計測する。このEMGセンサを入力側時系列データ  $f(t)$  とし、モーションセンサを出力側の時系列データ  $g(t)$  とし、再帰型ニューラルネットを使って学習を行う。この学習セットを使って、EMGセンサのみから3次元的な動きを推定する。




図1 EMGを使った動きの予測

### 2.1. 筋電図


筋電図は複数の筋繊維の電気的興奮を身体表面に設置した電極により計測したものである。筋繊維により興奮のタイミングが異なるため、これらの電位変化の総和となる表面筋電図の波形は交流信号として計測される。筋電図信号が正負の値をとるために、単純に振幅の平均値を計算しても、筋出力を評価できない。また、筋電センサで計測できる信号の周波数帯域は5

～300Hzの範囲、振幅は0.01～1mV程度であり、非常に微弱な信号であり、ノイズも多い。そこで、筋電データの前処理として、波形の絶対値をとり、一定の時間窓で平滑化処理：ARV (Average Rectified Value) 処理を行う[5]。


$$ARV(t) = \int_{-T}^T h(\tau) |e(t + \tau)| d\tau \quad (1)$$

ここで、 $\int_{-\infty}^{\infty} h(\tau) d\tau = 1$  を満たす関数  $h$  とする。今回は、関数  $h$  として、高さ  $1/2T$  の矩形波を用いた。図2(a)に、EMGセンサ（サンプリング周波数1kHz）の生データを示す。

式(1)に従い、ARV処理後の出力結果が図2(b)である。具体的には、EMGデータに対して30点の移動平均（時間窓0.03秒）により平滑化処理を行った結果である。



(a)EMG計測データ



(b) ARVデータ

図2 筋電 (EMG) センサデータの前処理

### 2.2. EMG信号を使った深層学習による動き推定

EMG信号は、非常に高周波の信号が含まれる。一方、モーションセンサのデータは、筋電に比べ低周波成分の多い信号である。複数の筋繊維の発火の総和の結果として骨格が動くことを考えると、筋電の細かな変動よりは、より低周波の筋電情報と筋肉の動きを関連付

けることが妥当といえる．そこで，EMG信号のそのまま入力データとするのではなく，入力値の移動平均のステップを100ステップ（0.1秒相当）とした．移動平均による時間の遅延を解消するために，ゼロ位相フィルタを掛け，100ステップであってもセンサデータの遅延の影響を無くし，学習を行った．

また，筋肉の動き，足の動きは，連続した時系列データであるため，時系列に沿った過去の影響が強く含まれると想定する．そこで，時系列データの時軸に沿った前後のデータの依存関係を学習できる長期短期記憶（LSTM）ネットワークを使った再帰型ニューラルネットワークによる学習を行った．

ここで，出力側の動きデータは，4次元ベクトルのクォータニオン（ $x,y,z,w$ ）を用いる．3次元空間での姿勢を表現するためには，従来オイラー角が使われているが，ジンバルロックという現象を回避できない．つまり，異なる軸の回転で，同じ姿勢（回転）を表現できてしまう現象である．4次元ベクトルのクォータニオンを用いることで回転・姿勢を一意に表すことが可能となる．本稿では，人体の3D骨格モデルを動かすためには，各骨格の関節を定義し，その関節に繋がっている骨格の傾き（回転）をクォータニオンで表現する．

### 3. EMG を使った下肢の動き推定

#### 3.1. 計測位置

サーフィンにおいては，下肢の動きが重要である．そこで，図4に示すような簡略化モデルを仮定した．大腿部では，大腿四頭筋とハムストリングス，下腿部では，下腿三頭筋，下腿全面筋群の前後の筋肉が連動して屈伸が行われると仮定している．モーションセンサは，大腿及び下腿の前面にそれぞれ1カ所で姿勢を計測する．今回使用したセンサは，スポーツセンシング社のワイヤレスモーションセンサ（サンプリング周波数 1kHz）とワイヤレス EMG センサ（サンプリング周波数 1kHz）である．





図3 下肢簡略化モデル




図4 大腿四頭筋部位に EMG センサ取り付けの様子

#### 3.2. 学習並びに予測結果

学習に用いたセンサデータの例を図5に示す．縦軸がセンサ値，横軸が計測時刻を示し，図5(a)が，大腿部四頭筋（Quad）並びにハムストリングス（Ham）の2つのEMG信号を，ARV処理後の結果である．図5(b)は，(a)と同時刻のモーションセンサで計測したクォータニオン（ $x,y,z,w$ ）の値である．



(a) EMGセンサデータ



(b) Motionセンサデータ ( $x, y, z, w$ )

図5 学習に使用したセンサデータ例

深層学習ツールは，MATLAB Deep-Learning Toolboxを使用している．今回は，異なる屈伸動作のシーケンスを4パターン用意し，学習に用いた．

大腿部，下腿部それぞれに2箇所，EMGのセンサデータを計測し，その2つのデータを入力値とし，当該

部位のクォータニオン4値を出力値として全結合型NNとして設計した。LSTMブロックにおける隠れユニット層数は100, 学習回数100回で学習を行ったときの下腿部のセンサデータの学習曲線を図6に示す。横軸が繰り返し回数, 縦軸がエラー値を表している。収束が早く, 比較的安定して学習が出来ていることがわかる。

まず学習ネットワークの精度検証として, 学習に使ったEMGを入力にして, モーションセンサの値を推定した結果を図7に示す。図7は, 屈伸運動を4回繰り返したときの計測データであり, (a)は, 大腿部の予測データと実測データ, (b)は, 下腿部の予測と実データを重畳表示している。実測のモーションデータに近い動きを再現できていることが確認出来る。






図6 学習エラー曲線



(a) 大腿部モーションセンサ値x

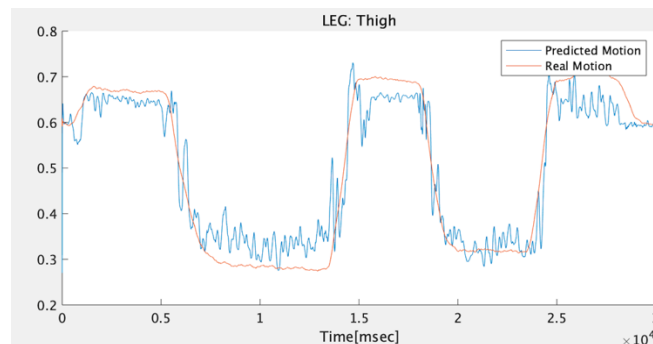


(b) 下腿部モーションセンサ値x

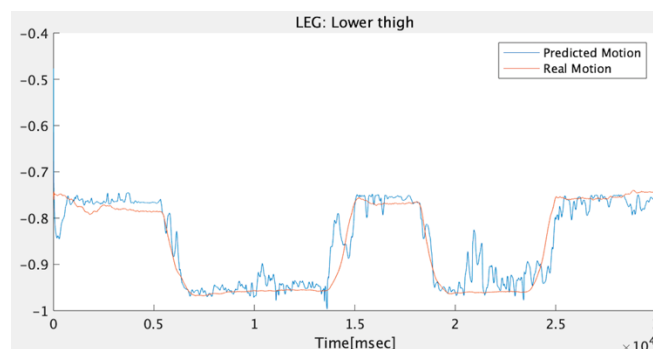
図7 学習データによる予測と実測の比較

図8は, 足を曲げた状態を一定時間保持した運動を2回繰り返した動きを計測したデータであり, 事前学習には使用していない。図7と同様に(a), (b)が予測と実測データを重畳して表示している。

図8を見てわかるように, EMGセンサのみで, 良好に動きベクトルの値を再現できていることが確認出来る。



(a) 大腿部モーションセンサ値x



(b) 下腿部モーションセンサ値x

図8 未学習データによる予測結果比較

#### 4. 考察

屈伸運動に関しては, EMG信号のみから, 動きを予測可能であることが明らかとなった。今回の運動は屈伸運動のみであり, 図3の簡略化モデルでも十分に表現できる動きであった。しかし, サーフィンでは, 重心移動などの動きも多く, 今回の筋肉モデルで表現し切れていない。学習によりどの程度の動きを推定できるかは, 計測部位の検証も含め, より多くの調査が必要である。

また, 今回学習したネットワークは, 一人の被験者のみでの検証である。筋肉の使い方は個人差が大きく, 筋電データの値は, 個人により大きく異なる。そのため, 個人間で筋電を比較する場合は, 筋電の最大値で正規化する必要がある。学習においても, 正規化による学習精度の影響等も検討していく必要がある。

## 5. まとめ

EMGセンサの値から下肢の動き推定を行う手法を提案した。LSTMブロックを使ったNN学習により、推定が可能であり、筋肉の弛緩状態の可視化が可能であることがわかった。今後、トレーニングへの適用可能性を検討していく。

## 謝辞

本研究はJSPS科研費 JP18K10977の助成を受けたものです。

## 文 献

- [1] 北村 徹,辻 内伸好,小泉孝之:“筋電信号による動作推定に基づくロボットハンドのマニピュレーション”,日本機械学会論文集(C編)73巻735号(2007-11) pp.152-158(2007)
- [2] A. Hiraiwa, N. Uchida, K. Shimohara, and N. Sonehara, “EMG Recognition with a Neural Network Model for Cyber Finger Control”, Trans. of Society of Instrument and Control Engineers, Vol.30, No.2, pp.216-22(1994).
- [3] 福田修, 有田潤, 辻敏夫:“EMG 信号を利用した全方位型ポインティングデバイス”, 電子情報通信学会論文誌, J87-D-II,10,pp.1996-2003, (2004).
- [4] 巢籠悠輔著:“詳解ディープラーニング第2版”,マイナビ出版(2019).
- [5] 小野弓著:“MATLAB で学ぶ生体信号処理”,コロナ社(2018).