



生体電気インピーダンスを用いた手指状態 推定システムの開発

— 第 2 報機械学習システムの構築 —

Development of fingers state estimate system by bioelectrical impedance
- 2nd report: construction of machine learning system

肖 博文, 高橋 秀智⁽¹⁾

Shou Hakubunn, Takahashi Hidetomo

1) 東京工科大学 工学部機械工学科高橋研 (〒192-0982 東京都八王子市片倉町 1404-1, takahashihdtm@stf.teu.ac.jp)

概要: 手指状態の認識は HCI の分野において重要な役割を果たしている。そこで本研究では、3D 空間上に手指の姿勢情報を入力できる、データグローブに代わる手指状態計測システムの開発を目指す。本報では、計測サブシステムからの手指状態データとその状態における手首のインピーダンスデータから、機械学習によりインピーダンスから手指状態の推定を行うシステムの構築・評価を行う。

キーワード: 計測・認識、手勢認識、機械学習、生体電気インピーダンス

1. はじめに

3D 空間上に手指の姿勢情報を入力できる、データグローブに代わる手指状態計測システムの開発を目指す。その中で、生体電気インピーダンス法を用いた推定を行う。手の姿勢と腕のインピーダンス値の相関関係を求めるために、機械学習を用いた推定を行うことで手指状態の推定を行う。

2. 推定システム

2.1 システムの構築

システムを得るためには、インピーダンス測定を行い、トレーニングデータを取得して機械学習を構築する必要がある。

システムは大きく分けて、インピーダンス測定システム、測定サブシステム、ディープラーニングシステムの 3 つ部分。インピーダンス測定システムは体に付けた電極でインピーダンスを測定する。人工知能による姿勢推定の入力データとして身体情報を記録する。計測サブシステムは、手関節の角度を計測して姿勢を測定し、ai 姿勢推定の指示データとして記録する。機械学習システムは入力データのインピーダンス値と教示データの関節の角度から

学習し、そのインピーダンス値から指の関節の角度を推定する。

2.2 生体電気インピーダンスの測定

インピーダンス測定システムの概要は以下の図に示されている。




図 2-1: インピーダンス計測システムの概要図

手首には電流印加用電極が 4 つ、測定用電極が 8 つの 12 か所に取り付ける。電極は以下の図 2-2 のように掌側、手の甲側にそれぞれ 6 か所貼り付ける。赤印の電極は印加電極、青印の電極は測定電極として使用する [1]。




図 2-2: 電極の貼り付け位置

印加電極には電極 A→D に電圧を印加する。測定電極は手のひら側の 1 から手の甲側の 1 から 4 のそれぞれの電極間の電圧を測定する。これを手のひら側の電極でそれぞれ行い合計 16 の経路を測定できる。

測定回路は次の図のように。




図 2-3: 測定回路

波形発生器から交流 1v の電圧を出力し、オフ抵抗を測定してジェスチャーによる電圧の変化を得る。

抵抗の抵抗値は 2k オーム。波形生成器 (TEXIO,FGX-2220) を使って 20KHz の高周波信号を用いた、計測システムの高周波数化を行う。

2.3 機械学習システム

推定システムは深層学習を用いて姿勢を推定する。これは先の研究において、1 指 1 関節でのインピーダンス測定による姿勢推定より、多関節の推定ではインピーダンス値との相関関係が複雑になっていることがわかっているためである [2]。

本研究では順伝播型ニューラルネットワークを用いて深層学習を実装していく。順伝播型ニューラルネットワークとは図 2-4 の中央の枠内のように、ニューロンと呼ばれる複数の入力から 1 つ出力を行うものを層状に並べる。入力は入力層から中間層、出力層の順にされ、入力されたデータは順方向に伝播し、前の層に戻ることはない。各ニューロンは複数の入力を受け取った後、それらを重み付けて足し合わせ、活性化関数によって変換することで出力値を決定する。これらをネットワーク内で繰り返すことで学習をしていく [3]。

本研究で使用する深層学習はインピーダンス計測システム、計測サブシステムで得たデータを基に学習を行う。学習には深層学習用のオープンソースライブラリである Keras を利用する。Keras は Python 環境で書かれた TensorFlow 上などで実行可能であり、深層学習の構築は容易にできる。システムでは測定したインピーダンス値を入力することで、姿勢すなわち手指の各々の関節角度を推定する。また推定には入力値であるインピーダンス値に対し

て教師データと呼ばれる正しい関節角度も入力する必要がある。これによって入力値と出力値の相関を求める。




図 2-4: 深層学習の構成

3. 手指状態の計測・推定

3.1 計測環境




図 3-1: 測定の様子

指の状態の測定にはインピーダンス測定システムを採用し、インピーダンス値を測定します。インピーダンス測定時に電極を皮膚に貼り付ける。

貼る際にはアルコールシートで肌を拭き、汚れや湿気を避ける。

また、手が乱れるのを防ぐため、机の上に本を置き、その上に腕を乗せることで、腕を動かさずに手を動かせるようにしている。

3.2 計測手順

手指のインピーダンス計測、関節角度の測定は前節のインピーダンス計測システムと計測サブシステムを用いて次の手順で行った。

1. 皮膚表面の汚れを取り除き、電極を貼り付け、A/D コンバータを接続する。
2. LeapMotion と手指を 140mm の距離を保って認識させる。
3. 手指を任意の状態に保ち、500Hz から 5kHz に変化する電圧を印加して A/D コンバータで測定、同時に LeapMotion で関節角度とカメラ画像を記録する。これを 600 回繰り返して測定した。

4. LeapMotion で記録した画像を MediaPipe に入力して、MediaPipe の測定結果を記録する。

5. A/D コンバータによる測定結果から MATLAB を用いて各測定区間の周波数ごとの入出力特性の解析をした。解析結果と LeapMotion, MediaPipe のそれぞれの測定結果は、同様に MATLAB を用いて深層学習の入力データ向けに、正規化、量子化などのデータ処理を行った。

6. 1 から 5 までの手順を腱のインピーダンス測と筋長変化のインピーダンス測定 の 2 パターンを行った。




図 3-2: 電極の貼り付け位置 パターン A



図 3-3: 電極の貼り付け位置 パターン B

3.3 インピーダンス測定および計測サブシステムでの計測

前報の手順で計測を行った。LeapMotion で撮影した状態と A/D コンバータによる計測結果の一部を示す。A/D コンバータの測定結果の判例は図 2-2 の電極の番号にあわせて番号が振られている。




図 3-4: インピーダンス計測サンプル

同時に計測サブシステムによる手指状態の関節角度の計測を行った。

表 3-5: 計測サブシステムによる測定サンプル

	親指	人差し指	中指	薬指	小指
DIP 関節		175.3	169.6	174.8	170.3
PIP 関節 (IP 関節)	173.3	156.8	164.9	180	156.8
MP 関節	169.4	172.7	175.1	170.4	172.7

これらの結果を解析し、深層学習への入力、教師データとして整理を行った。計測結果の処理は MATLAB を使用する。

MATLAB では以下の手順で深層学習のデータを作成する。

1. A/D コンバータの測定データ(入力電圧と測定電圧 15 経路)を読み込む。
2. 入力電圧と測定電圧 15 経路のそれぞれの入出力特性解析を行い、伝達関数を求める。
3. 求めた伝達関数は 50Hz ごとの区間に分割し、区間ごとに平均のゲインを求める。
4. ゲインは正規化を行い、さらに 8 ビットの量子化を行う。
5. CSV ファイルに出力する。

以下の図 3-4 は図 3-2 のデータを用いて MATLAB で処理中の途中経過を示したものである

である




図 3-6: 周波数解析の正規化・量子化サンプル

3.4 計測データと深層学習を用いた推定

深層学習の入力データの作成を行った。120 パターンの状態を 5 回測定した合計 600 のデータがあり、データ 1 つには 15 の測定結果があるため、合計 9000 の測定結果となる。これらのデータに対して、前節で述べたデータ処理を行い、数値解析には MATLAB を用いた。入力データの構成は、測定経路、周波数ごとの平均ゲイン 101 個の 102 個のパラメータで構成し、これを 9000 用意した。教師データとして手指関節角度は 15 の経路の測定結果に対して 1 つのデータとなるため、各経路に対して同値の手指関節角度のデータを割り当てた。教師データの作成も MATLAB を用いて行い、手指関節角度 14 個のパラメータで構成されている。これらのデータを CSV ファイルにまとめ、ファイルを読み込むことで学習を行う。Keras で構築したモデルの一

部を以下に示す。学習モデルでは、作成した 9000 のデータのうち 10% をテストデータとして使用する。入力データのパラメータは 102、教師データのパラメータは 14 である。よって入力層は 102 のニューロン、出力層は 14 のパラメータで構成されている。中間層は 1 層を用意し、408 のニューロンで構成されている。また、ニューロンの過学習を防止する目的で中間層と出力層には、ランダムでニューロンの活性を抑えるドロップアウトを設けた。中間層では 70%、出力層では 60% のドロップアウト率を設定した。最適化関数はデータ 1 つだけをサンプルして使うことで、損失関数が最小になるようにパラメータ調整をする最急降下法にランダム性を含めて安定した結果が得られる SGD 関数を使用した。また、レイヤーの重みの初期化は "he_normal" を使用し、平均を 0、標準偏差を $\sqrt{2/fan_in}$ とする正規分布による初期化を返す。ただし fan_in は入力ユニット数を指す。正則化には "regularizers.l2(0.001)" を使用した。これは L2 正則化で、重み係数の二乗に比例するコストを加えることで正則化する。活性化関数は "linear" を使用し、これは入力と出力を線形変換する関数である[4]。

図内の青線は訓練データを使用した結果を示し、橙色はテストデータを使用した結果である。横軸は学習回数、縦軸は正解率を示す。学習率は 0.0001、学習回数を 1000 回とした。




図 3-7: 学習曲線

手首—手首は正解率が 20% と低すぎるので考慮しない。試作システムでの正答率は、手首-腕電極で約 60% であり、さらなる精度向上が必要である。

ノイズなどで測定データに影響が出ていると考えられたため、5kHz から 40kHz の高い周波数で計測を行うことでより特徴の出やすい測定ができるのではないかと考えた。5kHz から 40kHz を 100Hz の区間ごとに区切り、その平均を求めた 350 個に変更する。これによって入力データは 350 x 15 の合計 5250 個となる。これらの改善を行って、実際に学習を行った。




図 3-8: 改善を行った学習結果

以上の結果から、まずインピーダンスの計測については低周波によるインピーダンスの計測に比べ高周波成分の方が、手指状態推定の特徴があることがわかった。次に深層学習モデルは、入力層を 5250 個のニューロンで構成し、1 指 3 関節ずつの推定にするなど大規模なモデルでないとは推定が困難であることがわかった。

4. まとめ

手指状態の推定を行うシステムの開発を目指した。システムは生体電気インピーダンスを用いて推定を行い、静止状態の手指の状態推定を行った。インピーダンス値と手指の複数の関節角度と相関関係は複雑であるので推定は深層学習を用いて推定を行った。

5. 今後の課題

始めに学習モデルの検討を行う。学習結果はニューロンの数や中間層の追加、ドロップアウト率などを変更するなど複数回の試行した上で、学習結果が向上したものである。しかし、学習モデルはドロップアウト率が 70% であったが、一般的には 20% から 50% 程度であり適切なパラメータの設定であるか検討する必要がある。

次に、必要のない周波数成分を無くし、測定周波数を 20kHz 以上の高周波数化を行い、高精度化をはかる。

参考文献

- [1] 鈴木雄太郎. 電気インピーダンス法を用いた前腕におけるタッチ位置および手形状の識別. 筑波大学, 2018, 卒業論文.
- [2] 星野篤, 生体電気インピーダンスを用いた手指状態推定システムの開発—1 指 3 関節の推定—, 第 25 回日本バーチャルリアリティ学会大会論文集, 3C3-1, 2020.
- [3] 太田満久, 須藤広大, 黒澤匠雅, 小田大輔, 現場で使える! TensorFlow 開発入門, 翔泳社, 2018, pp.90.
- [4] Keras, Keras: Python の深層学習ライブラリ, <<https://keras.io/ja/>>, 2022/1/18 アクセス.