

リハビリテーション支援のための 動作推定を用いた上肢機能評価及び可視化

鈴木 賢人^{1,a)} Luciano H O Santos¹ 劉 暢¹ 植嶋 大晃¹ 杉山 治¹ 山本 豪志朗¹
岡橋 さやか^{1,2} 黒田 知宏¹

概要: 脳卒中に伴う身体機能障害を有する患者に対し行われるリハビリテーションにおいて、医療機関への移動による身体的負荷や感染リスクを軽減するために、任意の場所でリハビリテーションを行えるシステムが望まれる。そのため動作を定量的に表す指標や患者に説明する評価理由の分析が必要である。そこで本研究では、人物の姿勢推定技術により各関節位置や可動角度の時系列情報を抽出し、定量的評価指標や評価理由の推定を試みる。具体的には、姿勢推定情報から体幹の傾斜や双肩の傾斜の二つの代償動作の度合いや肩や肘の関節の角度を算出する。また、Multi-Head Attention 層を含むニューラルネットワークを用いた評価モデルを構築し、時系列上での重要度を算出することで評価理由の推定を試みる。検証実験では、作業療法士が脳卒中後遺症の患者を模擬した動作に対し上肢機能の評価を行った。その結果、サンプル動作に対して療法士と同様の観察評価を得た。また、得られた観察評価を療法士に適切に提示する可視化方法について検討した。

1. はじめに

脳卒中の後遺症として上肢運動機能障害が発生し、療法士の同伴によるリハビリテーションが医療現場で行われている。しかしながら、病院内で行われるリハビリテーション評価には2つ問題点が存在する。1つ目は、療法士が人の目で評価をするという特性上、例えば腕の上昇速度や体幹の傾きなどを数値的に判断することが難しく、また評価が主観的になり、ばらつきなどの属人的な要素が無視できない。2つ目に、脳卒中患者は後遺症として、手足などに麻痺が残ることが多いためリハビリテーションを行うために病院に赴くのが困難なケースがある。加えて、病院内で行うリハビリテーションの実施には感染症への感染リスクが存在する。

上記の問題点に対する解決策として、コンピュータを用いたリハビリテーションシステムが考えられる。療法士の同伴を必要としないため、実施場所に囚われずにリハビリテーションを行うことが可能となり、従来の評価に含まれる属人的な要素を排した画一的な評価が可能である点において有用である。

コンピュータを用いたリハビリテーションシステムの実用化にあたり、以下の2つの機能が必要である。1つ目は

患者の身体機能のデータを自動的に取得し、評価及び分析を行うこと。2つ目は、前述の患者の動作に対する評価に基づいてシステムが対話的に情報を発信することである。しかしながら、リハビリテーションのような動的な動作に対して定量的な評価を下している手法は確立されておらず、またリハビリテーションに向けた評価の可視化システムは医療現場での実用に至っていない。本研究ではコンピュータによる患者の身体機能の解析に重点を置き、動作の定量的な評価とその評価理由の分析を行う。その中で、日常生活に与える影響が大きい上肢機能を対象とする。Kinect Azure を用いて骨格情報を取得し、角関節の位置や角度の時系列情報を抜き出し、「代償動作の度合い」という提案指数と Attention 層を含むニューラルネットワークを用いて身体機能の評価を行う。

動作を定量的に評価することにより、客観的な指標に基づいた治療を行うことができる。そのため、評価を行った後のリハビリテーションの方向性を明確にし、患者のリハビリテーションの支援が可能となる。また過去に行ったりリハビリテーションのデータを参照してリハビリテーションを進めることが可能となり、近年需要が高まっている遠隔診療への応用が期待される。

¹ 京都大学

² 国立長寿医療研究センター

a) kenrug88@kuhp.kyoto-u.ac.jp

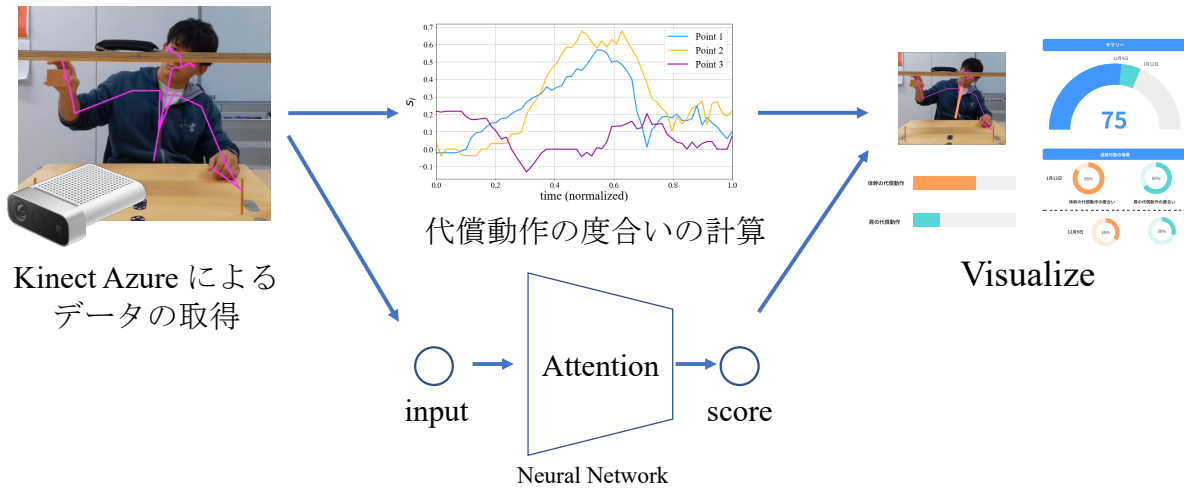


図 1: 提案手法の処理におけるフローチャート

2. 関連研究

2.1 動作に対する定量的な評価

画像処理技術, 特にディープラーニングベースの姿勢推定アルゴリズムの発達により, 骨格情報を基に人体の動きを評価する研究が行われている. Gama ら [1] は Kinect v2 (Microsoft 社製) から得られた骨格情報を基に人体骨格モデルを作成し, 首を縦に動かす動作と横に動かす動作を分類するなどの粗大動作の大別を行った. この研究では, 動作の分類や推定を行っていたものの, 動作の性質に対する定量的評価には至らなかった. Hagihara ら [2] は子供の統合能力を測定するテストである JPAN (The Japanese Playful Assessment for Neuropsychological Abilities) を用いて静止姿勢に対する定量的評価を行った. 従来指標の JPAN に変わる新たな指標を導入し, 信頼性の高いものであることが示された. しかしながら, これらの研究は動的な運動に対応していない. 上肢機能の動的な運動に対する定量的な研究も行われている. Dolatabadi ら [3] は, 肩関節, 肘関節, 手関節などの 10 の関節データの違いを比較し後遺症を持つ患者の動作と健常者の動作の分類を行った. しかしながら, データの単純な比較では判断の根拠が不明瞭になり, 動作に対するフィードバックが不十分である. 本研究では, 患者や療法士に向けた情報のフィードバックを見据えた定量的評価を目指す.

2.2 動作に対するフィードバック提示

リハビリテーション分野において主に通常のスクリーン及び VR 等を用いたアプリケーションの研究がなされている. Jaume ら [4] は自身の動作を認識しながら動作を行うことによってリハビリテーションの効果が向上することを示した. また, Dias ら [5] は, VR のゲームを通して患者自身の状態を可視化し, 早期回復へのモチベーションを向上

させた. しかしながら, リハビリテーションのような, 動作の性質に関するフィードバックを提示する研究は行われていない [6]. 従来の研究では障害の有無を検知したり, 単純に二値分類することに留まっており, 動作の性質を説明しフィードバックとして提示することに至らなかった. 現存する手法としては, 健常者と後遺症を持つ患者の動作において, 体の部位の差異を時系列上で可視化するものが主であり [7][8][9], 正しい動作の定義に膨大なアノテーションが必要となる. 本研究では, 動作に対する評価を自動的に生成し, 利用者を適切に提示できるシステムを目指す.

3. 提案手法

提案手法の流れを図 1 に示す. Kinect Azure を用いて姿勢推定を行い体の関節点情報を取得する. 関節点から肩および体幹の傾きを計算し, 上半身の回転運動に基づく評価モデルを適用することで, 代償動作の度合いを定量的に評価する. 加えて, そして Multi-Head Attention 層を持つニューラルネットワークを構築し, 学習を行う.

3.1 代償動作の定量的評価

正対の映像において, 代償動作の度合いを定量的に評価するために, 仮定の最大代償動作を定義する. 仮定では, 体を傾けるという代償動作のみで物品を持ち上げた際の体の傾きを「仮定の最大代償動作」と定義し, 実際の動作は最大代償動作に対する度合いによって評価される. 最大代償動作及び実際の動作に対する評価計算方法を以下に記す. なお, 計算に用いるパラメータは全てカメラ座標系に基づく.

STEP1: 図 2(a) に示す首 p_n , 右手首 p_{rw} , 腰 p_w を求める. 腰を軸に体を傾けることを代償動作と仮定し, 腰と挙上腕の手首 p_{rw} を結ぶベクトル h_{rw} が腰を中心に回転し物品を持ち上げると想定する.




図 2: 最大の代償動作の計算方法. (a) は動作開始時の物体を机の上で掴んでいる状態. (b) は物体を台の上に向かって拳上し h_t の長さと h_{rw} の長さが一致した時点. (c) は h_{rw} が高さ h_t に達する瞬間から, 体幹の代償動作のみを用いて物体を持ち上げた状態.

STEP2: 図 2(b) に示す体幹の傾き θ_i を

$$\theta_i = \arccos \left(\frac{h_n \cdot h_t}{|h_n| |h_t|} \right) \quad (1)$$

により算出する. また, 図 2(c) に示す h_{rw} が高さ h_t に達するフレームを仮定し, その時の体幹の代償動作を最大代償動作 θ_{max} とする. なお, h_t は事前に設定された木枠上側面までの高さ, h_n は腰から首までのベクトルである.

STEP3: 図 2(c) において, 水平面と左右の肩との成す角度を肩の最大代償動作, ϕ_{max} とする. このとき, 図 2(b) における肩の傾きを ϕ_b と置くと, 以下のように表すことができる.

$$\phi_{max} = \phi_b + \theta_{max} \quad (2)$$

STEP4: 最大代償動作 θ_{max}, ϕ_{max} に対し, 各フレームの代償動作の度合い b_i, s_i を算出する.

$$b_i = \frac{\theta_i}{\theta_{max}}, s_i = \frac{\phi_i}{\phi_{max}} \quad (3)$$

ここで, ϕ_i は各フレームにおける肩の傾きとする. また, s_i と b_i の最大値をそれぞれの代償動作の最終スコア (CM(S), CM(B)) とする.

3.2 Multi-Head Attention 層を用いたニューラルネットワークによる評価

本研究では前述の代償動作の度合いに加え, Multi-Head Attention 層 [10] を持つニューラルネットワークを用いてデータの評価も行った. 提案モデル (図 3) の設計について説明する. Multi-Head Attention はディープラーニングモデルで用いられる層の一種であり, 入力されたベクトル同士の関係性の強さによって重みを計算して, その重みに基づいて出力を調整することのできる層のことである. Multi-Head Attention 層は主に自然言語の機械翻訳に用いられていたが, 近年時系列データに対する分析にも有効的であると示されている [11][12]. 動作の評価において, 時系列上の動作の重要な部分を可視化できるという仮説に基づき本研究は Multi-Head Attention 層を採用

した. Multi-Head Attention 層に入力として時系列データ query, key, value を入力する. その際, 時系列データの最初にスコアリング用の変数 (head) を挿入しておく. その後 Multi-Head Attention 層からの出力の内, 挿入した head のみを次の全結合層 (Dense) に入力する. 全結合層からの出力を 0 1 の範囲にするため softmax 層を通して最終的なアウトプットとする.

Multi-Head Attention は Scaled Dot-Product Attention が基になっており, Scaled Dot-Product Attention を

$$\text{Attention}(Q, K, V) = \text{softmax} \left(\frac{QK^T}{\sqrt{d}} \right) V \quad (4)$$

と表すと, 式 (4) を用いて, Multi-Head Attention は次の式で表される.

$$\text{MultiHead}(Q, K, V) = \text{concat}(\text{head}_i) W^0 \quad (5)$$

$$\text{head}_i = \text{Attention}(QW_Q^i, KW_K^i, VW_V^i) \quad (6)$$

(6) の i は Attention モデルにおける head の数を表している. head の数が増えると, 予測の精度が上がる代わりに, ブラックボックス化してしまう. 単純化し変数の時系列上の重要度を可視化するため, 本研究では head の数を 1 とした.

4. 評価実験

本実験では, 提案した代償動作についての指標と Attention 層を含むニューラルネットワークを用いた評価を通して, 動作を定量的に評価可能であるという仮説を検証する. 具体的には提案指数と専門家による評価とが一致するのかを検証する. 以下では実験の環境やセットアップや用いた変数, 分析手法について述べる.

4.1 対象動作

対象動作は ARAT(Action Research Arm Test) とする. ARAT は片麻痺患者に対する上肢機能評価のための標準化された検査であり, 上肢機能を短時間で評価できるようにシンプルに設計されている評価指標の 1 つである. ARAT は Grasp(つかみ), Grip(握り), Pinch(つまみ), Gross Movement(粗大動作) という 4 つのサブテストで構成されている. それぞれのサブテストは複数の種目から構成されており, 全て合わせて 19 個の種目からなっている. 通常では全ての種目は 0~3 点の 4 段階で評価がされ, それぞれの段階で基準となる動作の目安のようなものが設定されている. 例として, Grasp 動作の採点は下記の基準によって行われる [13].

- 3点: タスクを完璧に行った. つかむ, 移動させる, 置く, 離すという動作が滞り無く行われ, すべての動作が 5 秒以内に完結させられる必要がある.
- 2点: 全てのタスクを完了させる事ができるが, その

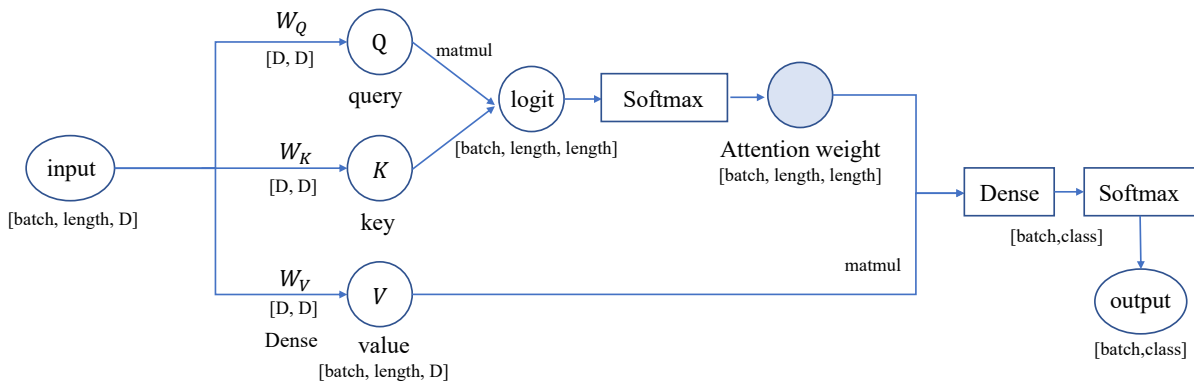


図 3: Attention 層を含むニューラルネットワークのアーキテクチャ




図 4: 代償動作の度合いと点数の分布

動作に大きな困難が伴っていた。目安として 50 秒から 60 秒で動作が完了することも必要である。

- 1 点：物品をつかみ、持ち上げることはできたが、目標位置まで移動させることができなかった。
- 0 点：物品をつかむことができなかった。

Grasp 動作とは図 1 (左) のようなプラットフォーム平面上にある物品を手のひらで掴み、木枠上側面まで持ち上げる課題である。この動作において、「つかむ→移動→置く→離す」という一連の流れの中で、患者が適切な軌道や速度で腕を挙上できているか、また代償動作を用いずに持ち上げられているかといった点での評価がなされる。

4.2 対象被験者

代償動作の度合いを計測するため 10 年程度の実務経験を持つ療法士 1 人に経験に基づき患者を模した動作を行ってもらった。また、ニューラルネットワークへの入力のためのデータの取得のため 2~23 年の経験を持つ作業療法士 3 人に経験に基づき患者を模した動作を行ってもらい、データを取得した。

4.3 用いた変数

4.3.1 前処理

取得したデータの長さは可変であり、長さの影響により予測の精度の低下が懸念されるため、バイキュービック補間を行い全サンプルの長さを 200 とした。また、個々の

データ x^i に対し、式 (4) による Z-Score 標準化を行い x'^i に変換した。

$$x'^i = \frac{x^i - \mu}{\sigma} \quad (7)$$

なお、 μ はデータの平均、 σ は標準偏差とする。

4.3.2 作業療法士の経験に基づく ARAT ベースの指標

4.1 で述べた、従来から用いられている ARAT の指標をベースとした。2 点の動作は「動作に困難を持ち、5 秒~60 秒で動作が完了する」とされているが、基準の粒度が大きいため、2 点の中でも次のような文言で療法士に動作を依頼し、それぞれ 2A, 2B, 2C と定義する。

- 2A：少しだけ動かしにくさがあるものの動作を完了できる。
- 2B：大きな動かしにくさはあるが動作は完了できる。
- 2C：かろうじて動作が完了できる。ARAT での評価で 2 点と評価する下限。

4.4 データ分析

Multi-Head Attention を含むニューラルネットワークを構築し、3 人の療法士のデータを利用しクロスドテストを行う。

5. 実験結果と考察

5.1 代償動作の度合い

療法士 1 人に 3 点の動作と、2 点の動作 (4.3.2 中 2B と 2C) を演じてもらい、データを取得した。各サンプルに対して体幹の代償動作度合いを計算し時系列に沿って計算する。上記 3 段階の動作に対し、代償動作の度合いの特徴が異なっているという仮説を検証する。

各サンプルにおける肩の代償動作の度合いの最大値を横軸に、体幹の代償動作度合いの最大値を縦軸にとり、その散布図を図 4 に示す。この結果より、それぞれのスコアにおいて混じりのないデータ群となり、適切にしきい値を設定した場合、高い精度での 3 段階への分類が可能であると




図 5: ランキング付けと予測結果との比較. (a) 動作の実行時間のみを用いた予測結果. (b) 動作の実行時間に加えて代償動作の度合いを用いた予測結果.




図 6: 学習のクローズドテストの結果

考えられる。

また、専門家が手動で行うランキング付けと比較した結果を図 5 に示す。従来の動作完了時間のみに基づく分類 (図 5(a)) よりで強い相関がある (図 5(b)) ことが見られた。

5.2 Attention 層を含むニューラルネットワークによる評価

療法士 3 人に 3 点の動作と、2 点の動作 (4.3.2 に従う 3 段階) を演じてもらい、データを取得した。上記 4 段階の動作に対して、代償動作の度合いの特徴はニューラルネットワークで捕捉できるという仮説を検証する。Head の数が 1 の Multi-Head Attention 層を含むニューラルネットワークを用いて、動作を評価した。モデルのアーキテクチャは図 3 の通りである。出力層には全結合層を用いて ARAT におけるスコアを出力とした。骨盤の中心から首までのベクトルの時系列上の差分ベクトルを入力としモデルを構築し、3 人の療法士のデータを用いて学習を行った。学習の結果を図 6 に示す。モデルの *precision* は 0.6 であった。

学習したモデルは 3 の動作と判別することがおおく、2A であると判断したサンプルはない。また 2C と判別したサンプルの内半分は誤りであり、2A, 2B と判別している。一方療法士が行った 3 の動作、2C の動作は全てモデルでの予測も 3、2C となっていた。

5.3 考察

既存のリハビリテーション評価と照らし合わせて、本研究で提案した代償動作の度合いの有効性について考察する。本研究では、Multi-Head Attention 層を含むニューラルネットワークを用いて、療法士の経験による演じ分けを判別できるかを検証した。その結果を基にニューラルネットワークの有効性について考察する。その後、提案手法のリハビリテーションにおける応用可能性と制限について考察する。

5.4 代償動作の度合いの有効性

従来の ARAT では動作の完了時間という定量的指標と、代償動作がないかという定性的所見によって点数が定められるが本研究では体幹の傾き、肩の傾きを基とした指数を提案した。図 5 に示すように、実際の専門家によるランキング付けに近い予測ができた。しかしながら、本研究で提案した代償動作の度合いを表した 2 つの変数 CM(B) と、CM(S) の間にも強い相関が現れている。これは Structural Multicollinearity であり、回帰分析等を行う上で特徴量の影響度を測る際に正しい影響度を理解する上で障害となる [14]。このような高い相関関係になったのは肩の代償動作が体幹の代償動作をベースに計算されたことが原因である。そのため、肩の代償動作の求め方を変更することや、新たな代償動作を導入することが求められる。体幹や肩の代償動作以外の代償動作の追加や提案手法の数値の時系列を考慮した分析により、リハビリテーション動作を総合的

に評価することが可能であると考えられる。

本研究では体幹の代償動作や肩の代償動作は時系列データとして得られた。しかしながら、その後の相関関係の分析や回帰分析モデルによる分析ではデータの最大値のみを利用し、時系列を考慮した分析は行わなかった。動的な挙動において動作のどの部分で困難を持っているのか、動作全体としてどのような性質を持っているのかを理解する上で時系列を考慮することは必要である。時系列データに対しては LSTM や異常値分析などが有効であるため今後検討したい。

5.4.1 ニューラルネットワークの有効性

本研究で提案したニューラルネットワークの精度は予備実験で被験者 1 人のみで行った際よりも低くなった。これは複数人のデータを用いたことによる個人差に起因するものだと考えられ、4.3.2 で定めたような曖昧さを含んだ条件で依頼したからであると考えられる。

また、データの利用範囲と使用した変数も影響していると思われる。データとしてモデルに入力した範囲が、動作の開始から終了までの範囲よりも広がっており、動作中の特徴量をうまく抽出できていなかったと考えられる。Attention モデルの時系列上での重要度を抽出できるという強みが補間によって失われた可能性があるため、補間の方法を改良する及び使用しない等が今後の課題として挙げられる。また、時系列上で動作を行っている部分だけをトリミングし、動作の認識手法についても検討する予定である。使用した変数に関して、今回は骨盤の中心から首までのベクトルを用いたが、腕や肩についてのデータを用いていないため、上肢関節の位置の差分ベクトルや関節角度のデータを用いることについても検討する。

5.5 制限

本提案手法の制限について考察する。本研究は体幹の代償動作と肩の代償動作を提案したが、これは身体の冠状面(図 1 のような身体の正面)での動きのみを考慮しており、矢状面(身体側面)や横断面(直立した際の地面と平行な面)からの動きを考慮していない。本提案手法と実際の評価の相関は高く、有効性は認められた一方、専門家からのヒアリングによると、順位付けの際に注目する点は身体を前に倒して台まで挙上する動作、すなわち矢状面での動きに着目するとのことだったので、横からの映像や、Kinect 等 3D のデータを取得できるデバイスの使用により詳細に評価が可能となると考えられる。

6. リハビリテーション可視化の検討

本研究で提案した代償動作の大きさやニューラルネットワークを用いて解析を行った情報をリアルタイムで可視化する(図 7)。具体的には、代償動作の大きさやニューラルネットワークの入力となる関節の位置の変位や関節角度な

どの時系列データをリアルタイムに表示する。動作が終了した後、ニューラルネットワークによる解析を行い、最終的な点数と判断の根拠をフィードバックとして提示する。

動作への評価及び根拠を可視化することで、特に療法士への貢献が期待できる。治療においてコンピュータと療法士の分業により、例えば手の速さや関節の角度等の人間が目視で測定できないパラメータの把握や従来の評価をコンピュータが行い、療法士は患者の動作の補助やモチベーション向上に注力することが可能になると考えられる。また、この可視化手法の更なる応用例として、新人の作業療法士の教育への応用が考えられる。新人の療法士は患者の動作の評価について、どのように点数をつけたら良いのか分からない、どの要素が所見につながっているのか分からない恐れがある。そのため提案手法を用いて実際に療法士が演じて評価を行うことで、評価方法や基準を実践的に学ぶことができる。

また患者への貢献も期待できる。患者と療法士の都合をあわせる必要がなく、家でもリハビリテーションを行えるという利点から、効率的に治療を行うことが可能となる。また、データに基づいた評価が可能になるため、患者自身が改善度を把握することが可能となり、モチベーションの向上に繋がる。本研究では可視化の内容として療法士に向けての可視化について検討したが、患者が見るのに適した可視化の内容は今後検討が必要である。

7. 結論

本研究では、動作分析による上肢機能の機械的な評価手法を提案し、評価結果の適切な可視化手法について検討した。実験を行った結果、上肢機能において療法士の経験に基づく評価とコンピュータによる評価は一致し、加えて人間では定量的に評価しにくい代償動作などの情報を基に動作を評価することが可能であることが示された。

本研究の制限として、実験ではデータセットの質や量、測定環境は非常に限られたものであるため、更にデータを取得し評価の汎用性を高めることが求められる。また今後の課題として、利用者である療法士及び患者に対し適切に情報を提示する方法を模索することに加え、インタラクティブな機能を持つフィードバックシステムを開発することが挙げられる。

謝辞 本研究は、実験にご協力いただいた作業療法士の方々から多大なる助力を頂いたものであり、ここに深く感謝の意を表します。

参考文献

- [1] Da Gama, A. E. F., Chaves, T. d. M., Fallavollita, P., Figueiredo, L. S. and Teichrieb, V.: Rehabilitation motion recognition based on the international biomechanical standards, *Expert Syst. Appl.*, Vol. 116, pp. 396-409 (2019).



図 7: 可視化のデモ図

- [2] Hagihara, H., Ienaga, N., Enomoto, D., Takahata, S., Ishihara, H., Noda, H., Tsuda, K. and Terayama, K.: Computer Vision-Based Approach for Quantifying Occupational Therapists' Qualitative Evaluations of Postural Control, *Occup. Ther. Int.*, Vol. 2020 (2020).
- [3] Dolatabadi, E., Zhi, Y. X., Ye, B., Coahran, M., Lupinacci, G., Mihailidis, A., Wang, R. and Taati, B.: The toronto rehab stroke pose dataset to detect compensation during stroke rehabilitation therapy, *Proceedings of the 11th EAI International Conference on Pervasive Computing Technologies for Healthcare, Pervasive-Health '17*, New York, NY, USA, Association for Computing Machinery, pp. 375–381 (2017).
- [4] Jaume-i Capó, A., Martínez-Bueso, P., Moyà-Alcover, B. and Varona, J.: Improving vision-based motor rehabilitation interactive systems for users with disabilities using mirror feedback, *ScientificWorldJournal*, Vol. 2014, p. 964576 (2014).
- [5] Dias, P., Silva, R., Amorim, P., Lains, J., Roque, E., Pereira, I. S. F., Pereira, F., Santos, B. S. and Potel, M.: Using Virtual Reality to Increase Motivation in Poststroke Rehabilitation, *IEEE Comput. Graph. Appl.*, Vol. 39, No. 1, pp. 64–70 (2019).
- [6] Hakim, T.: A Comprehensive Review of Skeleton-based Movement Assessment Methods (2020).
- [7] Parisi, G. I., Magg, S. and Wermter, S.: Human motion assessment in real time using recurrent self-organization, *2016 25th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*, pp. 71–76 (2016).
- [8] Devanne, M., Wannous, H., Berretti, S. and Del Bimbo, A.: Learning Shape Variations of Motion Trajectories for Gait Analysis, *23rd International Conference on Pattern Recognition*, unknown (2016).
- [9] Dressler, D., Liapota, P. and Lowe, W.: Data Driven Human Movement Assessment, *11th International KES Conference on Intelligent Decision Technologies*, 17–19 June 2019, Malta, Springer, pp. 317–327 (2019).
- [10] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. and Polosukhin, I.: Attention is all you need, *Advances in neural information processing systems*, pp. 5998–6008 (2017).
- [11] Li, S., Jin, X., Xuan, Y., Zhou, X., Chen, W., Wang, Y.-X. and Yan, X.: Enhancing the Locality and Breaking the Memory Bottleneck of Transformer on Time Series Forecasting, *Advances in Neural Information Processing Systems*, Vol. 32, Curran Associates, Inc. (2019).
- [12] Song, H., Rajan, D., Thiagarajan, J. J. and Spanias, A.: Attend and Diagnose: Clinical Time Series Analysis Using Attention Models, *Thirty-Second AAAI Conference on Artificial Intelligence*, aaii.org (2018).
- [13] 安保雅博, 中野枝里子, 田中智子: 脳卒中上肢機能評価 ARAT パーフェクトマニュアル, 金原出版, 東京 (2015).
- [14] Farrar, D. E. and Glauber, R. R.: Multicollinearity in Regression Analysis: The Problem Revisited, *Rev. Econ. Stat.*, Vol. 49, No. 1, pp. 92–107 (1967).