3次元距離画像センサを用いた進化論的多目的最適化に基づく上肢関節角度推定*

大保 武慶[†]・日下 純也[†]・久保田直行[†]

Joint Angle Estimation of Upper Limb based on Evolutionary Multi-criterion Optimization using 3D Image Sensor*

Takenori OBO[†], Junya KUSAKA[†] and Naoyuki KUBOTA[†]

In this research, we have developed a rehabilitation support system for analysis of upper body motion using 3D image sensor. Such a sensor has embedded systems to detect and track joint positions, but it is difficult to directly apply the data to calculation of inverse kinematics to estimate the joint angles because of errors in measurement. To solve the issue, some researchers have proposed methods of joint angle estimation using kinematic model and search technique. In these works, objective functions were defined to evaluate the similarity of posture between a person and kinematic model, and the problem was typically considered as a single-objective optimization problem. However, the data basically includes not only feature of personal behavior patterns but also noise. Therefore, we address a multi-objective optimization problem in order to scale back the influence of noise. This paper proposes a method of joint angle estimation of upper limb base on Evolutionary Multi-criterion Optimization (EMO). Furthermore, we apply a feedforward neural network to motion pattern modeling to realize a predictive search, combining with the EMO.

1. はじめに

近年、医療技術の発展によって、脳血管障害による死亡者数は減少傾向にある。しかし、高次脳機能障害などの後遺症を発症し、介護生活を余儀なくされる患者の増加が見込まれることから、機能回復を目的とするリハビリテーションの重要性がよりいっそう高まっている。リハビリテーションは身体的・精神的・社会的な障害をもつ人の機能・能力・社会生活の回復や復帰を目的としている。とくに、上肢運動のリハビリテーションは、食事をする、物をもつ、文字を書くなど、日常生活での多くの行為と関連をもつため、運動を阻害する要因を把握することが重要となる。

リハビリテーションにおいて評価は、「評価に始まり評価に終わる」という言葉に代表されるように、きわめて重要な過程とされている。評価とはすべての処置に先行して実施されるもので、治療を始めるにあたっての必要不可欠な過程であり、さまざまな手段を用いて、情報を

収集し、さらにそれを整理・分析・統合・解釈するという作業である[1]。しかしながら、リハビリテーションの評価は、療法士が個々の経験をもとに行うことが多く、病院や施設では、個別に扱ってきたそれぞれの症例の数が非常に限定的であるため、専門的な知識や経験を共有することがむずかしい。そのため、情報の大域的な構造化に関する研究が重要となる。リハビリテーションに関するさまざまな分野の知見を取り込みながら、情報技術、計測技術、通信技術、ロボット技術、システム化技術、知能化技術などを用いた枠組みを構築することが、一つの解決策となりうる。本研究ではこのような概念を「計算論的システムリハビリテーション」とよぶ[2]。

本研究では、上肢運動の計測、分析、評価を目的としたシステムを構築する。リハビリテーションの現場において、上肢運動の動作解析には、関節可動域をセラピスト自身で計測する角度計や、モーションキャプチャが用いられる。角度計は、セラピストが容易に取り扱える計測器具ではあるが、運動中の動作姿勢をすべて計測することが困難とされている。また、モーションキャプチャは、高精度な動作解析に応用できる一方で、表面マーカの設置が必要であることや、装置が大規模で高価なことから実臨床での実用事例が少ない。そこで、本研究で

* 原稿受付 2015年6月15日

[†] 首都大学東京 大学院 システムデザイン研究科 Graduate School of System Design, Tokyo Metropolitan University; 6-6 Asahigaoka, Hino, Tokyo 191-0065, JAPAN
Key Words: health care system, evolutionary multi-criterion optimization, 3D image sensor.

は、既製の類似センサと比べはるかに安価で、かつ容易にマーカレスのモーションキャプチャが可能な3次元距離画像センサを適用したシステムを構築する。

3次元距離画像センサは関節部位の位置を推定し、逐次的にデータの取得ができる一方、推定された関節座標に含まれる計測誤差のため、関節角度を推定する場合には、逆運動学を直接的に扱うことが困難になる。従来、運動学モデルと探索的な手法を用いて、関節角度を推定する手法がいくつか提案されている[5-7]。これらの手法では、被写体と運動学モデルの姿勢の類似度を評価関数とした単一目的最適化問題を扱うことが多い。本研究と関連する従来研究において、日下らは、定常状態遺伝的アルゴリズム (Steady-State Genetic Algorithm: SSGA) とニューラルネットワーク (Neural Network: NN) を用いた関節角度推定手法を提案している[10,11]。ここでは、被写体の姿勢に近似する運動学モデルの関節角度を推定するため、多点探索が可能な遺伝的アルゴリズムを適用している。一方、遺伝的アルゴリズムによる探索では、フレームごとに解を生成するため、時間的なコストがかかるとともに、場合により局所解に陥り、スムーズな関節角度の推定および追従ができない場合がある。そのため、[10,11]では、遺伝的アルゴリズムの探索空間を予測的に特定するため、NNを併用したハイブリッド手法を提案している。しかしながら、オクルージョンなどにより生じる計測データの突発的なノイズに対しては、NNによる予測モデルでも推定困難な場合があり、より適応的な推定手法が課題とされていた。本研究では、計測された関節座標から関節角度を推定するために、進化論的多目的最適化 (Evolutionary Multi-criterion Optimization: EMO) を用いた手法を提案する。さらに、EMOの探索過程において、被験者の動作パターンを学習するNNを適用し、運動動作に対する予測的な探索を実現する。

2. 関連研究

近年、3次元距離画像センサは運動解析の計測システムとしてしばしば注目されており、研究事例も多く提案されている。Gonzalez-Ortegaらは、3次元距離画像センサを適用し、上肢運動の計測および画像処理による注視領域の推定を行うことで、リハビリテーションにおける患者の認知的な評価を実現している[3]。また、Zannathaらの研究でも、同様に関節位置情報を用いて、バーチャル空間を用いたロボットとのインタラクションシステムを脳卒中患者へのリハビリテーションへ応用している[4]。これらの方法論は、興味深い結果を示しているが、ゲーム感覚のリハビリテーションプログラムの開発を目的としており、詳細な運動解析を目的とした手法ではない。運動解析を目的とした計算論的アプローチでは、ヒューマノイドロボットの模倣学習を目的とした研究事例に関連手法がみられる。Leiら[5]やZuher

ら[6]の研究では、逆運動学における幾何学的な解法を用い、人の関節角度を推定することで、ロボットの動作生成へ適用している。しかしながら、3次元距離画像センサで計測した関節座標位置は計測誤差を含むため、直接的に計測データを利用した逆運動学の解法では、計測誤差の影響を大きく受けてしまう。そのため、ほかのアプローチとして、リンク長を事前に定義した運動学モデルを適用し、計測した人の姿勢を運動学モデルを用いて近似的に求める方法論が提案されている。これらの手法では、一般的に、人の姿勢と運動学モデルの姿勢との類似度関数を定義し、類似度を高めることを目的として、運動学モデルの関節角度を推定する。つまり、類似度の最大化を目的とした、関節角度の最適化問題として扱うことができる。Wangらの研究[7]では、探索手法として、Levenberg-Marquardt algorithmを用いた方法論を提案している。しかし、人の姿勢推定を対象とした探索問題は一意に解を求めることが困難な場合が多い。そのため、勾配法に基づく方法論では、しばしば局所解に陥ることが問題となる。

そこで、本研究では、多点探索が可能な進化計算を用いた方法論を適用する。従来研究において、日下らは、人間の骨格構造を表現した運動学モデルを適用し、遺伝的アルゴリズム (Genetic Algorithm: GA) に基づき Simple GA や Steady-State GA[8,9]を用いることで、関節角度の推定を行ってきた[10,11]。これらの研究では、評価関数として、人の関節位置と運動学モデルの関節位置の空間的な誤差を適用してきたが、オクルージョンなどによる計測データの突発的なノイズに対しては適応が困難であった。このようなノイズを補正するためには、計測データの変化に対して、(1)人の動作特性として推定すべきか、(2)ノイズとして除去すべきか、というトレードオフ問題を考慮しなければならない。したがって、本研究では多目的最適化を目的とした関節角度推定手法を提案する。

3. 距離画像センサを用いた上肢運動計測

本研究では、Microsoft社製のKinectセンサを適用する。Kinectセンサは、カメラ画像だけでなく、対象物体に向けて赤外光を照射することで物体までの距離を計測できるアクティブセンサである。従来の距離情報を計測するレーザ式センサやCCDカメラを用いたステレオ視とは異なり、広範囲の距離情報を一度に取得できることや、暗所などでも計測が可能であるなど多くの利点がある。また、Kinectセンサは、従来のモーションキャプチャ技術のように、身体に多数のマーカをつける必要がなく人間の骨格モデルを容易に取得できるセンサでもあり、さまざまな研究事例に適用されている。Kinectセンサによって計測される骨格モデルは、内蔵されているプロセッサによって演算され、リアルタイムに各関節位置を追従することができる。

Fig. 1 Link length of skeleton detected by Kinect sensor during shoulder flexion and extension

Kinect センサによって取得される骨格モデルは 20 箇所の関節から構成されている。本研究では、これらの関節座標データを用い、患者の動作解析を行い、各関節角度を推定する。しかしながら、骨格モデルは、被写体の姿勢の変化や各関節が奥行き方向に重なってしまうときに生じるオクルージョンにより、関節座標が大きすぎてしまう問題点がある。Fig. 1 に Kinect センサを用いて肩の屈曲・伸展運動を計測した際の、上腕部、前腕部、手先の各リンク長の時間推移を示す。ここでは、まず、被験者に腕を伸ばし下ろした状態から可能な限り徐々に腕を上げてもらい（屈曲運動）、つぎに、腕を下ろした状態に戻し、体幹より後ろに可能な限り手先を上げてもらった（伸展運動）。図中より、各リンク長がそれぞれの姿勢によって大きく変化している様子がわかる。とりわけ、屈曲運動の時には、手先を前方に出したときに肘や肩に対してオクルージョンが生じてしまうためリンク長の変動が大きくなる。解決策として、複数台の Kinect センサを用いることで、オクルージョンを避けることが考えられるが、複数台用いても計測できない箇所や光学式モーションキャプチャと同様に実験環境が限定されてしまうなどの問題がある。本研究では、上記の問題を解決するため、あらかじめリンク長を定義した人間の運動学モデル（以下、人間モデル）を構築し、Kinect センサによって取得された各関節位置に人間モデルの関節座標を近似させることで、間接的に、被写体の姿勢を推定する方法を提案する。すなわち、人間モデルの姿勢を構成する各関節角度を、推定された被写体の関節角度とする。

4. 上肢関節角度推定

4.1 進化的多目的最適化に基づく関節角度推定

従来、多目的最適化問題には、もとの問題を何らかの工夫により単一目的の問題に変換するスカラー化手法が用いられてきた。しかし、多くの場合、これら複数の評価基準は互いにトレードオフの関係をもつため、おのこの評価基準を適切に重み付けしてスカラー化することが難しい。また、このようなスカラー化によってできた単一目的最適化問題の解を求めても、多目的最適化問題

の解としては不十分である場合が多い。一般的に、複数の評価基準をもつ多目的問題においては、トレードオフ関係を考慮した解の集合であるパレート最適解（Pareto optimal solution）を求めることが必要とされる。

近年、遺伝的アルゴリズムなどの進化論的計算を用いた多目的最適化問題へのアプローチである進化論的多目的最適化（Evolutionary Multi-criterion Optimization: EMO）が注目されている。その理由は、進化論的計算が多探索法であり、一度の探索で複数のパレート解を求められることにある [12–14]。本研究では、Kinect センサから得られる関節座標データに基づいて人間モデルの近似的な姿勢を推定するとともに、姿勢の変化やオクルージョンにより生じた外れ値へのフィッティングを考慮したトレードオフ問題を扱う。このような外れ値に対する処理には、しばしばフィルタリング処理が用いられているが、本研究ではノイズ処理だけではなく、被験者自身の突発的な動作を平滑化しないことを目的とし、EMO に基づく関節角度推定を提案する。以下、提案手法について述べる。

まず、EMO を用いて各関節角度の解候補を生成し、解の探索を行う。 i 番目に生成した解候補は以下のように表現される。

$$\mathbf{g}_{i,t} = (\theta_{i,t,1}, \theta_{i,t,2}, \dots, \theta_{i,t,6}) \quad (1)$$

解候補となる個体は Fig. 2 に示す腕モデルに基づき生成される。人間モデルの各関節位置は、関節角度の解候補に基づき順運動学を解くことによって求められる。ここでは、時刻 t における人間モデルの肘、手首、手先の関節位置を $\mathbf{p}_{i,j,t}^{FK}$ 、Kinect センサによって計測された関節位置を $\mathbf{p}_{i,j,t}$ とする。なお、 j は肘、手首、手先の関節番号である ($j=1,2,3$)。さらに、EMO のパレート解を $\mathbf{q}_{i,t}'$ とすると、各パラメータは以下のように表現できる。

$$\mathbf{P}_{i,t}^{FK} = (\mathbf{p}_{i,\text{elbow},t}^{FK}, \mathbf{p}_{i,\text{wrist},t}^{FK}, \mathbf{p}_{i,\text{hand},t}^{FK}) \quad (2)$$

$$\mathbf{p}_{i,j,t}^{FK} = (p_{x\ i,j,t}^{FK}, p_{y\ i,j,t}^{FK}, p_{z\ i,j,t}^{FK}) \quad (3)$$

$$\mathbf{P}_i = (\mathbf{p}_{i,\text{elbow},t}, \mathbf{p}_{i,\text{wrist},t}, \mathbf{p}_{i,\text{hand},t}) \quad (4)$$

$$\mathbf{p}_{i,j,t} = (p_{x\ i,j,t}, p_{y\ i,j,t}, p_{z\ i,j,t}), \quad (5)$$

$$\mathbf{q}_{i,t}' = (q_{i,t,1}'', q_{i,t,2}'', q_{i,t,3}'', q_{i,t,4}'', q_{i,t,5}'', q_{i,t,6}'') \quad (6)$$

ここでは、人間モデルの関節位置と Kinect センサによって計測された関節位置の近似の度合いを目的関数とし、ユークリッド距離に基づき以下のように求める。

$$o_{i,t} = \sum_{j=1}^S \|\mathbf{p}_{i,j,t}^{FK} - \mathbf{p}_{i,j,t}\| \quad (7)$$

S は各腕の関節数を示す ($S=3$)。被験者の姿勢に対して、人間モデルの姿勢を近似させることを目的とするため、最小化問題として扱うことができる。

本提案手法では、一時遅れ系の構造を適用し、時刻

Fig. 2 Kinematic model

$t-1$ および $t+1$ の推定結果を考慮しながら、時刻 t における関節角度を推定する。Fig. 3 にフローチャート、Fig. 4 に時刻 t における推定手法の概念図を示す。まず、時刻 $t+1$ において、(7) 式の目的関数を評価関数として各関節角度を推定する。時刻 $t+1$ における推定では、先に述べたトレードオフ問題を考慮せず、単一目的の最適解 $\mathbf{q}'_{best,t+1}$ を探索する。つぎに、時刻 t では、時刻 $t+1$ および $t-1$ の推定結果を踏まえ、以下の評価関数を用いてパレート最適解を求める。

$$f_i = \sum_{j=1}^S \|\mathbf{p}_{i,j,t}^{FK} - \mathbf{p}_{i,j,t}\| + R_i \quad (8)$$

$$R_i = \gamma(\|\mathbf{g}_i - \mathbf{q}'_{best,t+1}\| + \|\mathbf{g}_i - \mathbf{q}''_{best,t-1}\|) \quad (9)$$

ここで、(8) 式の第2項は、前後の推定値から大きく外れないための正則化項として用いられる。また、 γ は重み係数であり、1 時刻前との腕の長さの差が大きいほど重みを大きくする構造的適応が実現される。構造的適応とは、自らの身体性にあわせて、環境そのものをつくり変え、環境を(再)構築・構造化することによる適応で、この構造的適応を自律的に行うことができれば、かなり高いレベルの知能化が実現できる。

4.2 階層型ニューラルネットワークに基づく動作学習

上記で述べた EMO による解候補の探索では、フレームごとに解を生成するため、スムーズな追従ができない場合がある。そこで、本研究では、NN を EMO の探索過程における初期個体生成に適用したハイブリッド手法について検討する。具体的には、NN は EMO によって生成される最良個体を教師値として学習を行い、EMO は NN による出力値に基づき、次世代の遺伝子個体を生成する。つまり、解の探索と入出力関係のモデル化を並行的に行う統合的手法を適用する。

NN には、3 層型の階層構造を適用する。 l 番目の階層における i 番目のニューロンの出力は以下のように算出される。

$$\begin{aligned} y_i^l &= f(z_i^l) = f\left(\sum_{j=0}^{n_2} w_{j,i}^l x_j^l\right) \\ &= f\left(\sum_{j=0}^{n_2} w_{j,i}^l f\left(\sum_{k=0}^{n_1} w_{k,j}^{l-1} x_k^{l-1}\right)\right) \end{aligned} \quad (10)$$

Fig. 3 Processing flow of joint angle estimation

Fig. 4 Joint angle estimation based on EMO

x_j^l は l 番目の階層における j 番目のニューロンへの入力であり、 $w_{i,j}^l$ はその入力に対する重みである。また、 n_2 は l 番目の階層におけるニューロン数、 n_1 は $l-1$ 番目の階層におけるニューロン数を示す。ここでは、 $w_{0,j}^l$ は各ニューロンの閾値とし、入力 x_0^l は -1 とする。また、内部関数にはシグモイド関数を適用し、誤差関数は以下のように定める。

Fig. 5 Hybrid approach for joint angle estimation

$$E = \frac{1}{2} \sum_{i=1}^N (y_i^* - y_i^l)^2 \quad (11)$$

y_i^* は i 番目の出力値に対する教師データ, N は出力の数である. 重みの更新は誤差関数を用いて以下のように行う.

$$w_{j,i}^l \leftarrow w_{j,i}^l + \Delta w_{j,i}^l = w_{j,i}^l - \eta \frac{\partial E}{\partial w_{j,i}^l} \quad (12)$$

学習アルゴリズムには誤差逆伝播法を適用する. 出力層のニューロンへの入力に付加される重みの更新は偏微分を行い以下のように計算される.

$$\frac{\partial E}{\partial w_{j,i}^l} = \frac{\partial E}{\partial y_i^l} \frac{\partial y_i^l}{\partial z_i^l} \frac{\partial z_i^l}{\partial w_{j,i}^l} = -(y_i^* - y_i^l) f'(z_i^l) x_i^l \quad (13)$$

$$\delta_i^l = -\frac{\partial E}{\partial z_i^l} = -\frac{\partial E}{\partial y_i^l} \frac{\partial y_i^l}{\partial z_i^l} = (y_i^* - y_i^l) f'(z_i^l) \quad (14)$$

学習係数を η とすると, 重みの修正量は以下のようになる.

$$\Delta w_{j,i}^l = -\eta \frac{\partial E}{\partial w_{j,i}^l} = \eta \delta_i^l x_j^l \quad (15)$$

また, 中間層のニューロンへの入力に付加される重みも同様に偏微分を行い以下のように更新される.

$$\begin{aligned} \frac{\partial E}{\partial w_{k,j}^{l-1}} &= \frac{\partial E}{\partial z_i^l} \frac{\partial z_i^l}{\partial x_j^l} \frac{\partial x_j^l}{\partial z_j^{l-1}} \frac{\partial z_j^{l-1}}{\partial w_{k,j}^{l-1}} \\ &= -\sum_{i=1}^N \delta_i^l w_{j,i}^l f'(z_j^{l-1}) x_k^{l-1} \end{aligned} \quad (16)$$

$$\delta_j^{l-1} = -\frac{\partial E}{\partial z_j^{l-1}} = \sum_{i=1}^N \delta_i^l w_{j,i}^l f'(z_j^{l-1}) \quad (17)$$

$$\Delta w_{k,j}^{l-1} = -\eta \frac{\partial E}{\partial w_{k,j}^{l-1}} = \eta \delta_j^{l-1} x_k^{l-1} \quad (18)$$

NNへの入力には Kinect センサによって計測される各関節位置の単位ベクトルと 1 時刻前の推定角度が与えられる. また, 出力では Fig. 2 に示す腕モデルに対応する各関節角度が推定される ($N=6$). 学習時における教師データには, EMO によって推定された解候補が適用され, NN の出力は, 次世代の遺伝子個体の生成に確率的に適用される (Fig. 5).

Fig. 6 Misdetction during shoulder flexion and extension

Fig. 7 Misdetction during elbow flexion and extension

5. 実験

本提案手法の有用性を検討するため, 関節角度の推定実験を行った. Kinect センサを被験者の正面から約 1.8m 離れた位置に設置する. 被験者は, 椅子に座った状態で, 肩および肘の基本動作を行う. なお, 本実験における被験者は健常者である.

5.1 EMO を適用した関節角度推定実験

本実験では, 従来手法である SSGA を用いた際の関節角度推定と EMO を用いた際の関節角度推定結果を比較することで, 提案手法の有効性を議論する. まず, Fig. 6, Fig. 7 のようにオクルージョンによる外れ値が生じた時系列データを用い, 追従精度に関する議論を行う. つぎに, 被験者自身が突発的に動くような動作に対する関節角度推定に関しても議論を行う. 具体的には, 被験者が肩の屈曲運動を行う過程で, 肩の関節を急に素早く動かした場合のデータを用いる.

5.1.1 実験結果

まず, Fig. 8 に, 肩の屈曲運動に対して, SSGA を用いて関節角度推定を用いた結果を示す. 図中より, (a) において, オクルージョンの発生に伴い, 局所的に関節角度が大きく下がっていることがわかる. つぎに, Fig. 9 に, 本提案手法である EMO を用いた推定結果を示す. SSGA を用いた結果に比べ, オクルージョンによるノイズに追従しにくくなっていることがわかる. また, Fig. 10 と Fig. 11 には, 肘の屈曲運動における, SSGA と EMO のそれぞれの推定結果を示す. 肘の屈曲運動では, 手先が肘を隠蔽することでオクルージョンが発生するため, SSGA を用いた従来手法では, Fig. 10 中 (b) や (c) に示すような外れ値がしばしば生じる. しかし, EMO による推定結果では, (b), (c) の時点において, 大きな外れ値は現れておらず, これらを補正できたと考えられる.

Fig. 12 に, 肩の屈曲運動において, 意図的に突発的な動作を生じさせた場合における EMO の推定結果を示

Fig. 8 Joint angle estimation based on SSGA during shoulder flexion

Fig. 10 Joint angle estimation based on SSGA during elbow flexion

Fig. 9 Joint angle estimation based on EMO during shoulder flexion

Fig. 11 Joint angle estimation based on EMO during elbow flexion

す。(d)の位置が突発的に動いた際の関節角度であるが、突発的な動作は除去されずに推定できていることがわかる。本提案手法では、現在時刻前後のリンク長を考慮した構造的適応を適用しているため、オクルージョンによって発生した外れ値のみを除去できる。

5.1.2 考察

肩の屈曲運動において、SSGAを用いた角度推定結果では、(a)の位置でオクルージョンによるノイズによって局所的に関節角度が大きく下がってしまった。これは前後の関節角度を考慮せず、計測データに追従するような目的関数を使用しているためであると考えられる。一方、EMOを用いた推定結果では、SSGAを用いた従来手法に比べ、オクルージョンによる外れ値の影響を受けにくいことがわかった。また、肘の屈曲運動では、手先が肘を隠蔽することでオクルージョンが生じやすかったため、SSGAを用いた推定結果では、大きく影響を受けてしまった。これに対して、EMOを用いた推定結果では、外れ値を補正して動作軌道を推定することができた。これは、オクルージョンにより関節座標が大きくずれた場合でも、現在時刻前後の各リンク長、関節位置や速度を考慮したためである。しかし、EMOの結果では、Fig. 11中(c)の終端部分で関節角度がSSGAを用いた際の結果より10度程度小さくなっていることがわかつ

Fig. 12 Joint angle estimation based on EMO against a sudden behavioral change

た。これは、前後の時系列データを考慮していることにより、補正の影響を受けてしまったためであると考えられる。

また、被験者が突発的に動いたデータに対してEMOを用いた関節角度推定では、突発的な動作による関節角度の変化は除去されなかった。本提案手法では、現在時刻前後の関節位置、リンク長の変化を考慮した構造的適応を適用しているため、推定角度の変化が小さい場合は現在時刻のデータに重みをおき、大きい場合は時間的

に前後の推定関節角度に重みがおかれ、適応的な推定が実現できていることが考えられる。

5.2 NN を適用した関節角度推定実験

本実験では、EMO における適応度の収束に関する議論を行うため、NN を EMO の初期個体生成に用いない場合と初期個体生成に用いた場合の適応度の収束性の比較を行う。NN を用いない場合では、初期個体生成が乱数値のみに依存する場合と現在時刻より 1 時刻前の関節角度を初期個体生成に用いる場合の比較結果を示す。NN の学習試行回数は 100 回あり、学習係数は 0.01 である。NN には、各動作において 2 回ずつ計測したデータのうち、一つを学習用データ、もう一方をテスト用データとして適用する。

5.2.1 実験結果

Fig. 13 は、NN の出力値を EMO の初期個体生成に用いた場合と乱数値に基づき生成した場合の適応度の推移である。初期個体生成が乱数値依存の場合では世代数が 100 回あたりで収束がみられた。しかし、NN を用いた場合と比較すると収束値が大きいことがわかる。

Fig. 14 は、NN の出力値を初期個体生成に用いた場合と 1 時刻前の最適解を初期個体生成に用いた場合の適応度の推移である。1 時刻前の最適解を用いた場合でも、EMO の世代数が 50 を過ぎたあたりから適応度が収束していることが確認できたが、NN を用いた場合と比較すると、この場合も収束値が大きいことがわかった。

5.2.2 考察

NN を EMO の初期個体生成に用いた場合と初期個体生成を乱数値のみに依存させる場合の適応度の比較では、NN を用いた場合のほうが、収束が早く、収束値も小さいことがわかった。これは、乱数値のみに依存させると解候補の空間が膨大になり、収束に時間がかかるためであると考えられる。1 時刻前の関節角度を初期個体生成に用いることで、収束速度は NN を初期個体生成に用いた場合と同程度にはなったが、収束値は NN を用いた場合のほうが小さくなった。EMO の評価関数には、1 時刻前の関節角度だけでなく 1 時刻後の関節角度との差を小さくするような項が設けられているため、NN を初期個体生成に用いた場合のほうが適応度の収束値が小さくなったと考えられる。

6. おわりに

本研究では、関節座標位置の推定が可能な 3 次元距離画像センサを適用し、上肢の関節角度推定を行った。EMO に基づく関節角度推定実験では、オクルージョンにより関節角度が大きくずれたデータに関しては外れ値を除去し補間することができ、さらに、被験者自身の突発的な動作に対しては、動作軌道を表現できることを示した。また、NN を適用した関節角度推定実験では、NN を EMO の初期個体生成に用いた場合において、乱数値

Fig. 13 Comparison of fitness value convergence between randomly initialized population and NN-based population

Fig. 14 Comparison of fitness value convergence between population initialized based on the best candidate at $t-1$ and NN-based population

依存の場合と 1 時刻前の最適解を初期個体生成に用いた場合と比べ、この最小化問題における適応度の収束値をより小さくできることを示した。

今後の課題としては、EMO の評価関数の改良があげられる。本実験では、1 時刻前の関節角度を考慮することでオクルージョンによる関節座標位置の補正を行ったが、補正処理による影響でオクルージョンが生じていない箇所での精度が悪化する場合があった。このような問題解決を行うためには、動的環境に対してより柔軟に対応するための評価関数を検討する必要がある。

参考文献

- [1] 木下：評価とは；日本作業療法士協会作業療法学会全書改訂 2 版第 3 巻，協同医書出版（2000）
- [2] 久保田，大保：計算論的システムリハビリテーションと情報構造化空間；第 57 回システム制御情報学会研究発表講演会（SCI2013），講演会論文集（CD-ROM）（2013）
- [3] D. Gonzalez-Ortega, F. Diaz-Pernas and M. Martinez-Zarzuela and M. Anton-Rodriguez : Accuracy and robustness of kinect pose estimation in the context of coaching of elderly population; *Proceedings of Engineering in Medicine and Biology Society (EMBC)*, pp. 1188–1193 (2012)

- [4] J. M. I. Zannatha, A. J. M. Tamayo, A. D. G. Sanchez, J. E. L. Delgado, L. E. R. Cheu and W. A. S. Arevalo : Development of a system based on 3D vision, interactive virtual environments, ergonomic signals and a humanoid for stroke rehabilitation; *Computer Methods and Programs in Biomedicine*, Vol. 112, No. 2, pp. 236–249 (2013)
- [5] J. Lei, M. Song, Z. N. Li and C. Chen : Whole-body humanoid robot imitation with pose similarity evaluation; *Signal Processing*, Vol. 108, pp. 136–146 (2015)
- [6] F. Zuher and R. Romero : Recognition of human motions for imitation and control of a humanoid robot; *Proceedings of Robotics Symposium and Latin American Robotics Symposium (SBR-LARS)*, pp. 190–195 (2012)
- [7] F. Wang, C. Tang, Y. Ou and Y. Xu : A real-time human imitation system; *Proceedings of the 10th World Congress on Intelligent Control and Automation (WCICA)*, pp. 3692–3697 (2012)
- [8] G. Syswerda : A study of reproduction in generational and steady-state genetic algorithms; *Foundations of Genetic Algorithms*, Morgan Kaufmann, pp. 94–101 (1991)
- [9] M. Mitchell : *An Introduction to Genetic Algorithms*, The MIT Press (1996)
- [10] 日下, 大保, 久保田 : 計算論的システムリハビリテーションのための距離画像センサを用いた関節角度推定; システム制御情報学会論文誌, Vol. 28, No. 5, pp. 56–63 (2015)
- [11] J. Kusaka, T. Obo, J. Botzheim and N. Kubota : Joint angle estimation system for rehabilitation evaluation support; *Proceedings of the IEEE International Conference on Fuzzy Systems (FUZZ-IEEE 2014)*, pp. 1456–1462 (2014)
- [12] 電気学会進化技術応用調査専門委員会 : 進化技術ハンドブック < 第1巻 > 基礎編, 近代科学社 (2010)
- [13] K. Deb : *Multi-Objective Optimization using Evolutionary Algorithms*, Wiley (2001)
- [14] A. Konak, D. W. Coit and A. E. Smith : Multi-objective optimization using genetic algorithms: A tutorial; *Reliability Engineering & System Safety*, Vol. 91, No. 9, pp. 992–1007 (2006)

著者略歴

おおほ 武 慶 (正会員)

2014年首都大学東京システムデザイン研究科ヒューマンメカトロニクスシステム学域博士後期過程修了。同年4月首都大学東京大学院システムデザイン研究科ヒューマンメカトロニクスシステム学域特任助教, 同年10月マレーシア, マラヤ大学博士研究員, 2015年10月より首都大学東京システムデザイン研究科知能機械システム学域特任助教となり, 現在に至る。主として, 知能化計算を用いた計測技術や信号処理に関する研究に従事。博士(工学)。計測自動制御学会, 日本ロボット学会, IEEEなどの会員。

くさ か 純 也

2013年首都大学東京システムデザイン学部ヒューマンメカトロニクスシステムコース卒業, 2015年首都大学東京大学院システムデザイン研究科ヒューマンメカトロニクスシステム学域博士前期過程修了。主として, リハビリテーションにおける動作解析に関する研究に従事。日本ロボット学会の会員。

くほ た 直 行 (正会員)

1997年名古屋大学大学院工学研究科マイクロシステム工学専攻博士後期課程修了。同年4月大阪工業大学工学部機械工学科助手, 1999年同講師, 2000年福井大学工学部知能システム工学科助教授, 2004年東京都立大学大学院工学研究科機械工学専攻助教授, 2005年首都大学東京システムデザイン学部ヒューマンメカトロニクスシステムコース准教授, 2012年同大学教授, 現在に至る。また, 2002年から2007年まで科学技術振興機構研究員, 2007年から英国ボーツマス大学客員教授, 2009年から2012年まで韓国ソウル国立大学客員教授。おもに計算的知能, 知能ロボットに関する研究に従事。博士(工学)。計測自動制御学会, 日本知能情報ファジィ学会, 日本ロボット学会, 日本機械学会, IEEEなどの会員。