分散表現と神経力学系のダイナミクスに基づく手の行動推定

Estimation of Hand Motions Based on Distributed Representations and Neurodynamics

山根 健
Ken Yamane

帝京大学理工学部
Faculty of Science and Engineering, Teikyo University
yamane@ics.teikyo-u.ac.jp, <http://www.ics.teikyo-u.ac.jp/~yamane/>

keywords: dynamical system, trajectory attractor, selective desensitization method, motion estimation, surface myoelectric signal

Summary

Dynamical systems, which are described using differential equations, present numerous benefits for time-series information processing. They can accommodate continuous changes and dynamic features. However, they are not good for processing complex spatiotemporal patterns such as a temporal order of motions. Therefore, they are often combined with symbol-processing systems or discrete-event systems to produce hybrid systems. As described herein, we propose a method of processing sequences of elementary motions based only on distributed representations and a neurodynamical system. To assess the method's possibilities, we constructed a human motion estimation system using a trajectory attractor model: a recurrent neural network with continuous-time dynamics. This system can deal analogically with novel hand and arm motions based on similarity between code patterns. Additionally, it can process complex sequences of motions in a robust manner because the network state is attracted to a long trajectory attractor formed in a series of subspaces corresponding to elementary motions. Then the network makes stable state transitions along the trajectory. Experimentally obtained results obtained from surface myoelectric signals show that the system estimated 15 complex hand and arm motions with average accuracy of about 86%, demonstrating the great potential of this system.

1. はじめに

人間と機械が協調して作業するためには、機械が人間の運動情報を適切に処理し、その意図を理解しながら人間を支援することが望まれる。例えば、人間の手や腕の位置、姿勢、速度、加えようとしている力など運動に関する時系列情報を解析して運動のパターンを幾つかの動作クラスに分類することだけでなく、もともになる人間の意図や行動計画を推定することができれば、筋電義手などのインタフェースを用いて人間の運動機能を高度にサポートするシステムの実現に繋がる。

これに関して、運動情報など時系列データを処理していく代表的な方法には大きく分けて、有限オートマトン [Bobick 97, Hong 00] や隠れマルコフモデル (HMM) [稲 11, Starner 95, Yamato 92] など離散系を用いる方法とリカレントニューラルネット [Dorffner 96, Elman 90, 二見 88] など力学系を用いる方法がある。しかし、前者は連続的に複雑な運動をどのように離散化するかが大きな問題となる。自由度が高い手や腕の複雑な運動を扱う場合、離散化のための規則を手動ですべて記述することは困難

である。また、統計的学習手法を用いる場合でも、多種多様な運動を扱うなどシステムの規模が大きくなると膨大な学習サンプルや学習時間が必要になる。一方で、後者はセンサ信号に近いレベルの情報をそのまま扱えるため、連続的な変化や動的な特性が重要となるジェスチャの認識などに用いられてきた。しかし、順序構造など複雑な運動情報の扱いが難しいとされており、力学系のみで構成されるシステムの情報処理能力には限界があった。

そこで、これらを組み合わせたハイブリッドシステム [川嶋 10, 奥田 09, 鈴木 06] が提案されてきた。しかし、両者を相互補完的に動作させる方法は明らかではない。例えば、複雑な運動情報を処理するためには、複数の力学系を離散系によって切り替える必要がある。しかし、どのように力学系の集合を定めて切り替えるかは大きな問題となる。つまり、そもそも一部に離散系を用いるのであれば離散化の問題は残されたままである。

これらに対して森田らは、選択的不感化法 [森田 02, 森田 04] により従来型ニューラルネットの情報処理能力を拡張し、それをリカレントニューラルネットの1つである軌道アトラクタモデル [Morita 96] に適用したモデル

が任意の大規模有限オートマトンを模擬する能力をもつことを示した。また、離散系を一切用いずに、様々な事物や概念を高次元 2 値パターンとして分散的に表現して、軌道アトラクタモデルが作る力学系（神経力学系）だけに基づいて推論を行う方法を提案した [山根 07]。実際に、簡単な推論システムを構築して、本モデルが記号処理に基づく古典的人工知能と同等の推論能力をもつだけでなく、パターンの類似性に基づいた非常に高い汎化能力をもつことを示した。さらに、本モデルを用いてアーム型ロボットの簡単な運動など時空間パターンを処理できることを示した [Yamane 10]。

このように、本モデルは離散系が得意とするような情報処理、例えば順序構造を扱ったり抽象的な概念を操作できるだけでなく、センサ情報に比較的近い運動情報も同じ原理で扱える可能性があることから、複雑な運動情報処理の実現に向けて期待されている。しかし、複数のセンサから取得される実世界の情報をどのように内部において高次元 2 値パターンとして表現するか（情報のコード化方法や情報の階層性に関する課題）、神経力学系の利点がいかにするようなシステムの構成方法などは明らかでない。また、ノイズなど想定外の状況が発生する実世界の情報を本モデルが扱っている研究はまだ少なく、特に人間を対象とする場合にも本モデルが柔軟に対応できるかは不明である。

そこで、本研究では、図 1 に示すように 1 つの神経力学系のダイナミクスだけに基づいて複雑な運動情報を処理する方法について検討する。具体的には、軌道アトラクタモデルを用いて、分散表現と本モデルの自律的なダイナミクスに基づいて時々刻々の動作系列を処理することで一連の運動を推定する方法を提案する。本方法では、運動情報と神経力学系の状態遷移を対応付けてモデルに学習させる。また、複数の力学系を離散系によって切り替える必要はなく、1 つの力学系に複数のダイナミクスを埋め込み、それを時々刻々のセンサ情報から識別された動作によって切り替える方法をとる。ただし、識別された動作も高次元 2 値パターンとして表現されているため、ダイナミクスを離散的に変化させるだけでなく、連続的に変化させたり、複数のダイナミクスの影響を受けながら情報処理したりできる。さらに、実世界に接地させる 1 つの方法を示し、実際に多チャンネルの表面筋電位信号から複雑な手や腕の行動を推定するシステムを構築して、提案方法の可能性を示す。なお、人間の運動は複数の基本的な動作の組み合わせから構成されると考え、以降ではそのような一連の運動を行動と呼ぶ。

2. 神経力学系を用いた行動推定方法

本研究で用いる軌道アトラクタモデルの動作原理について説明する。詳細は [Morita 96, 森田 02] を参照されたい。また、本モデルを用いて行動を推定する方法を提案

図 1 提案方法

する。

2.1 軌道アトラクタモデル

軌道アトラクタモデルは、リカレントニューラルネットの 1 つであり、非単調な出力特性をもつ多数の神経素子で構成される。ここでは、出力関数として

$$f(u) = \frac{1 - e^{-cu}}{1 + e^{-cu}} \cdot \frac{1 - e^{c'(|u|-h)}}{1 + e^{c'(|u|-h)}} \quad (1)$$

を用いる。ただし、 c, c', h は正の定数である。 i 番目の素子の出力 y_i は

$$\tau \frac{du_i}{dt} = -u_i + \sum_{j=1}^n w_{ij} y_j + z_i \quad (2)$$

$$y_i = f(u_i) \quad (3)$$

として与えられ、連続時間のダイナミクスに従って動作する。ここで、 n は素子数、 u_i は内部電位、 w_{ij} は j 番目の素子からの結合荷重、 z_i は外部からの入力信号、 τ は時定数を表す。

このモデルでは内部電位 u_i の正負の符号が重要である。そこで、 $x_i = \text{sgn}(u_i)$ を考え、ベクトル $\mathbf{x} = (x_1, \dots, x_n)$ のことをネットワークの状態と呼ぶ。ただし、 $\text{sgn}(u)$ は $u > 0$ のとき 1、 $u \leq 0$ で -1 をとる符号関数である。ある時刻におけるネットワークの状態 $\mathbf{x}$ は、 2^n 個の可能な状態からなる状態空間中の 1 点で表される。また、それぞれの x_i は非同期的に変化するため、 $\mathbf{x}$ が別の状態に移るときにはほとんどの場合隣の点に移動する。従って、時間とともに $\mathbf{x}$ の連続的な軌跡が状態空間中に描かれる。これを $\mathbf{x}$ の軌道と呼ぶ。

軌道アトラクタモデルは、一般的なニューラルネットにはない多くの優れた性質をもつ。特に、ネットワーク

のダイナミクスに基づいてある状態から別の状態へ状態空間中のある軌道に沿って安定して状態遷移できる．このような軌道のことを軌道アトラクタと呼び，簡単な学習によって形成することができる．

2.2 学習と行動推定方法

軌道アトラクタを用いて，ある空間パターン群 $S^1, \dots, S^m$ から対応する別の空間パターン群 $T^1, \dots, T^m$ を連想することを考える．ここで， S^μ と $T^\mu (\mu = 1, \dots, m)$ はどちらも ± 1 を成分とする n 次元ベクトルである．そのためには， S^μ を始点とし， T^μ を終点とする m 本の軌道アトラクタを形成する．

まず， S^μ から T^μ へ至るある連続的な軌道に沿って変化する時空間パターンを作成し，これを学習信号 $\mathbf{r}$ としてネットワークの学習を行う．具体的には， $\mathbf{x} = S^\mu$ を初期状態として式 (1)~(3) に従ってネットワークを動作させた上で， $\mathbf{r}$ を $z_i = \lambda r_i(t)$ の形でそれぞれの素子に入力する．ただし， r_i は $\mathbf{r}$ の成分， λ は入力強度を表す．これと同時に，全ての結合荷重 w_{ij} を次式に従って更新する．

$$\tau' \frac{dw_{ij}}{dt} = -w_{ij} + \alpha r_i y_j \quad (4)$$

ここで， τ' は学習の時定数であり， $\tau' \gg \tau$ である． α は学習係数であり定数でもよいが， $|u_i|$ の増大とともに α を減少させると学習性能が高まるため， $\alpha = \alpha' x_i y_i$ とする (α' は正定数) ．

式 (4) の学習則は $\mathbf{r}$ 周辺におけるネットワークのエネルギーを低くする．従って， $\mathbf{r}$ が S^μ から T^μ まで連続的に変化することによって，エネルギーの溝が刻まれることになる．さらに， $\mathbf{r}$ が $\mathbf{x}$ よりも少し先行することによって， S^μ から T^μ へ向かう緩やかな流れが溝の底に作られる． $\mathbf{r}$ の入力強度 λ を徐々に減らしながら全ての μ について学習を何度か繰り返すと，ネットワークの状態 $\mathbf{x}$ が S^μ から T^μ へ至る軌道に沿って状態遷移するようになる．また，その周囲にはこの軌道に引き込む流れが作られる．

このようなネットワークの状態遷移と運動に関する時系列情報を対応付けて考える．今，人間がある行動をしているとき，センサから取得される運動情報に連動してネットワークの状態が S から別の状態へ徐々に遷移して，行動終了時に状態 T^1 へ遷移していたとする．この過程をモデルが行動 1 であると推定したとみなす．同様に，人間が別の行動をしているとき，別の状態 T^2 へ遷移すれば別の行動 2 であると推定したとみなす．そうすると，人間の行動に応じて状態 S から T^1 に軌道アトラクタを形成することはモデルが行動 1 を学習することに対応する．同様に， T^2 への軌道アトラクタを形成することは行動 2 を学習することに対応する．

図2 状態遷移の模式図

2.3 選択的不感化法を用いたダイナミクスの制御

ネットワークの状態遷移とセンサから得られる運動情報を結びつける最も単純な方法は，ネットワークの入力信号としてセンサ情報を直接与えて，その時間的変化を軌道アトラクタとして埋め込む方法である．例えば，アクチュエータをもたない 2 リンク構造をしたアームの運動は，それぞれの関節の角度と角速度の 4 変数を用いて記述される．このようなアームの状態変数の変化を学習により軌道アトラクタとしてネットワークに埋め込み，再生することができる [Yamane 10]．しかし，これはセンサ情報そのものであるため人間が理解しやすいような抽象的な運動表現ではなく，推定した結果を人間に提示したり別の処理で利用したりする場合に扱いが難しい．

そこで，本研究では，センサから得られる運動のパターンを幾つかの基本動作として分類して（再利用可能な程度意味のある塊として表現して），その動作系列に応じてネットワークの状態遷移を変化させる方法を用いる．ただし，動作や行動も高次元 2 値パターンとしてコード化されているのであって，記号を用いた表現とは本質的に異なることに注意されたい．

具体的に，時々刻々と識別される動作に応じてネットワークの状態遷移を制御することを考える．そのために，選択的不感化法 [森田 02, 森田 04] を用いて動作情報をネットワークに修飾させる．選択的不感化法とは，修飾パターンに応じて約半数の素子を不感化する方法であり，不感化される素子の出力は入力に関係なく強制的に中立的な値にされる．具体的には，ネットワークの i 番目の素子の出力が式 (3) ではなく，

$$y_i = g_i f(u_i) \quad (5)$$

によって与えられる．ここで， g_i はこの素子の感度を表し，通常は 1，不感化されるときには 0 となる．一般に g_i は修飾パターン C に依存して決まる．ただし， C は n 次元のパターンであって，成分 c_i は ± 1 を確率 1/2 でとる．ここでは，最も単純に $g_i = (1 + c_i)/2$ とする．

このような修飾を加えると，ネットワークの状態が n

図3 行動推定システム

次元の状態空間から $n - k$ 次元 (k は不感化される素子の数で $k \simeq n/2$) のある部分空間に射影される。同時に、その部分空間における（不感化されない素子によって決まる）ダイナミクスに従ってネットワークが動作することになる。

ここで、動作をコードするパターンをそのまま修飾パターン C として用いる。つまり、識別された動作に対応するパターンによって素子の一部が不感化されると、図2に模式的に示すようにネットワークの状態はある部分空間に射影される。そして、そこに形成されている軌道アトラクタに沿ってネットワークの状態 x を遷移させて、最終的に行動を表す状態へ達することで推定が行われる。この方法を用いることで、動作が重複したり動作の順序や切り替えタイミングが重要となる複雑な行動を処理できるようになる。

3. 行動推定システムの構成

実際に人間の腕の表面から筋電位信号を計測し、基本動作を識別して、その動作系列から行動を推定する方法を示す。推定部を含めたシステムの構成を図3に示す。図中のセンサ部、識別部はセンサ情報が取得されるたびに動作する。推定部は軌道アトラクタモデルを用いて構成されており、その各素子は識別器として用いる選択的不感化ニューラルネット（以下、SDNN）[Kawata 10, 森田 04, 野中 11] の出力層の各素子と1対1に対応している。また、推定部はその他の部分に関係なく自律的に動作する。なお、軌道アトラクタモデルのパラメータについて、 $n = 900, c = 50.0, c' = 10.0, h = 0.5, \tau = 10.0, \tau' = 5000\tau, \alpha' = 2.0$ を用いた。以下では、具体的な構成方法について説明する。

3.1 対象とする運動

行動推定システムでは、図4に示すように前腕の運動を3つのレベルに分けて処理する。まず、多チャンネル

図4 システムが取り扱う運動情報

の筋電センサから信号を取得して前処理する。次に、6種類の基本動作（A：手首を屈曲する，B：手首を伸展する，C：手を握る，D：手を開く，E：手首を回内する，F：手首を回外する）および力を抜いた中立的な状態（N）を識別する。最後に、時々刻々と識別される基本動作から行動を推定する。例えば、手を握って（図4の $N \rightarrow C$ ）、腕を内側に回す（ $C \rightarrow C$ と E の組み合わせ）という動作の系列から「コップの飲み物を飲む」、手を握って腕を外側に回し腕を押すという動作の系列から「ドアを開ける」というような行動を推定する。

実際には机上に肘をついて実行でき、ものを握ったり操作したりしないでできる行動を対象とした。これは、計測器が有線であるため被験者が行動できる空間に制約があることや腕の姿勢や操作対象によって筋電位信号が大きく変わり動作識別自体が難しい課題になることが主な理由である。実験において用いた具体的な行動を表1に示す。例えば、行動1は手を握って腕を外側に回すような行動であり、表では $C \rightarrow F$ と表している。ただし、正確に記号で表そうとすれば、ニュートラル（N） $\rightarrow$ 握る（C） $\rightarrow$ 回外（C と F の組み合わせ） $\rightarrow$ ニュートラル（N）となり、未学習の動作（C と F の組み合わせ）などを含んだやや複雑な行動であることに注意されたい。行動は全部で15種類あり、基本動作の組み合わせからなるもの、他の行動と一部に重複があるもの、基本動作とは異なる動作で構成されているものなどを含む。

3.2 表面筋電位信号の取得

被験者の右前腕から表面筋電位信号を計測する。計測には8チャンネルの筋電計装置（P-EMG plus, (有) 追坂電子機器）を用いた。1つのチャンネルにつき1対の湿式電極（Blue Sensor M, Ambu）を使い、電極中心間

表 1 対象とする行動

番号	行動 (動作 A~C, N および未学習動作を含む)
1	握る (C) → 回外 (F)
2	回外 (F) → 握る (C)
3	回内 (E) → 開く (D)
4	回内 (E) → 握る (C)
5	回外 (F) → 握る (C) → 開く (D)
6	人差し指を伸ばす → 自分方向へ曲げる
7	握る (C) → 人差し指と中指を伸ばす → 開く (D)
8	握る (C) → 開く (D) → 握る (C)
9	指先でつまむ → 伸展 (B)
10	つかんで 2 度回転
11	親指から順番にゆっくり開く
12	小指から順番にゆっくり開く
13	屈曲 (A) → 伸展 (B) → 屈曲 (A)
14	左に振る → 右に振る → 左に振る
15	開く (D) → 回外 (F) → 回内 (E)

の距離が約 3cm となるようにして、肘から手先に向かって 10cm の範囲において腕の周囲に貼り付ける。なお、電極貼付位置については正確に位置決めする必要はなく、筋活動が検出できないようなチャンネルが存在しても他のチャンネルで動作識別に十分な筋活動を検出できればよい。

筋電計測装置によりバンドパスフィルタ (1.64~400Hz) をかけ、1000 倍に増幅して筋電位信号 (EMG 信号) を得る。この EMG 信号は、A/D 変換され、サンプリング周波数 3kHz、16bit でサンプリングされる。次に、ソフトウェアによって、EMG 信号を全波整流し、遮断周波数約 4.8Hz の 2 次ローパスフィルタ (時定数 99ms) で平滑化し、4 倍に増幅して積分筋電位信号 (IEMG 信号) を得る。

3.3 動作の識別

筋電位から動作を識別する技術として、少ない学習サンプルでも識別性能が高く使い勝手がよい方法が幾つか提案されている [Kawata 10, 吉川 09]。ここでは、事前に同じデータセット (10 名 × 6 動作 × 20 サンプル) を用いて識別実験を行い、パラメータ設定の容易さ、学習サンプル数に対する識別性能などを比較して、SDNN を識別器として用いる Kawata らの方法を採用した。なお、この方法では出力層において識別動作をパターンとして分散表現できるため提案方法との親和性も高い。

以下では、SDNN を用いて表面筋電位信号から基本動作を識別する方法について説明する。なお、基本的な構成は先行研究とほぼ同じである。しかし、本研究では、運動パターンを幾つかの動作クラスに分類するためというよりは、その汎化能力に注目し、基本動作との類似性を利用して新奇な動作を高次元 2 値パターンとして分散表現するために SDNN を用いる。そのため、ここではまず前処理、ネットワークの構成、出力層における情報表現など変更した点について述べる。そして、先行研究では

図 5 それぞれの基本動作を 3 回ずつ繰り返した場合の識別結果

調べられていない、出力層の表現を分散表現にして未学習動作時のセンサ信号を入力した場合にどのような表現が作られるかについて示す。

i. 前処理

処理時間短縮のため、計測した IEMG 信号を 50 点毎に間引いてダウンサンプリングし、 $IEMG_p(t)$ ($p = 1, \dots, 8$) と表す。また、8 チャンネルの合計値とその時間差分を計算して、それぞれ $IEMG_9(t)$, $IEMG_{10}(t)$ とする。

次に、 $IEMG_p(t)$ ($p = 1, \dots, 10$) をそれぞれ 0~1 の範囲で正規化する。具体的には、学習サンプルデータにおける動作中およびインターバルのときの最大値 $IEMG_p^{max}$ と最小値 $IEMG_p^{min}$ を用いて以下を計算する。

$$v^p(t) = \frac{IEMG_p(t) - IEMG_p^{min}}{IEMG_p^{max} - IEMG_p^{min}} \quad (6)$$

ここで、 $v^p(t)$ は正規化された各チャンネルの IEMG 信号、合計値、合計値の時間差分を表す。ただし、 $v \geq 1$ のとき 1、 $v < 0$ のとき 0 とする。

さらに、 $v^p(t)$ (ただし、 $p = 1, \dots, 8$ のみ) に対して、 $v^p(t)$ の最大値で割り、これを新たに $v^p(t)$ とする。これを SDNN の入力変数とする。

ii. 動作識別器の構成

様々な問題への応用が期待されている SDNN を動作識別器として用いる。構成した識別器は 3 層構造をしており、入力層はそれぞれ 30 個の素子からなる 10 個の素子群で構成される。 p 番目の素子群は、入力変数 v^p の値を ± 1 がほぼ同数の 2 値パターン $\mathbf{v}^p = ((v_1^p), \dots, (v_{30}^p))$ によって分散表現する。ただし、各素子群は各変数の値と対応しており、この変数の値が連続的に変化すれば、それに伴って素子群の活動パターンが徐々に変化するようにコード化されている。

図6 行動7を3回繰り返した場合の動作識別結果

中間層は、それぞれ30個の素子からなる90個の素子群からなる。各素子群は入力層のある素子群のパターン $\mathbf{v}^p$ をそのまま受けるとともに、別の素子群のパターン $\mathbf{v}^q$ による修飾を受ける（選択的不感化される）。すなわち、中間層のパターンは、入力層の素子群の全ての p, q の組み合わせ（ただし、 $p \neq q$ ）について並べたものである。

出力層は900個の素子からなり、各素子は中間層の全ての素子と結合している。この結合荷重を学習によって調整することでIEMG信号と動作パターンを対応付けることができる。なお、学習では、それぞれ無相関の2値パターンを基本動作や中立状態をコードするパターンとして用いる。また、識別結果については、これらのコードパターンと出力層のパターンの類似度（方向余弦）を計算することで解釈する。

iii. 識別性能

ここでの実験と後述する4. 行動推定実験では、被験者毎に6種類の基本動作と力を抜いた中立的な状態のデータそれぞれ10サンプルずつを用いて、それぞれ10回繰り返し学習した。なお、学習には誤り訂正学習法を用いた。

6種類の基本動作A～Fについて、中立的な状態Nから一定のインターバルを挟んで同じ動作を3回ずつ繰り返したときの識別結果（被験者1）を図5に示す。2枚組の図は動作A～Fの順番に並んでおり、それぞれにおいて上のパネルがIEMG信号（8チャンネル）、下が動作を表すそれぞれのコードパターンとSDNNの出力層のパターンとの類似度（Similarity）を表している。なお、類似度を方向余弦として算出した。また、時間の単位1フレームはおよそ 1.67×10^{-2} 秒である。この図に示すように、IEMG信号の立ち上がり付近からそれぞれの動作のコードパターンと出力層のパターンとの類似度が上昇しており、類似度0.75以上を正答とするとほぼ全ての動作を正しく識別している。

これに対して、幾つかの動作を連続で行うとき、筋電位信号は小さくなり時間的に重なるため、それぞれの動作を明確に分けることが難しくなる。また、手を握りながら腕を回す、手を開いた状態から握るなど基本動作

を組み合わせた動作については筋電位が大きく変化する。これら様々な動作を予め全て学習しておくことは膨大な学習サンプルを用意することを意味しており、人間にとっても大きな負担になる。しかし、そうしなければ基本動作として学習したものの以外の動作を従来システムで扱うことは難しい。

このような動作に関してもSDNNを用いることで学習しなくても無理なく扱えることが分かった。例えば、行動7を一定のインターバルを挟んで3回繰り返したときの識別結果（被験者1）を図6に示す。この行動は「握る（C）→人差し指と中指を伸ばす→開く（D）」という動作で構成されており、途中に「人差し指と中指を伸ばす」という学習していない動作が含まれる。この未学習の動作に対しても、行動1回目2番目の動作（図6の80～100フレームあたり）では開く（D）を表すコードパターンとの方向余弦が0.75～1.0程度、2回目（270～290フレーム）は握る（C）、開く（D）、回外（F）それぞれと0.5程度、3回目（470～480フレーム）は開く（D）と0.5程度となった。行動7では握っている状態から人差し指と中指を伸ばすため、握る（C）や開く（D）などに類似したパターンとして表現されることは妥当だと考えられる。また、被験者によっては、指を伸ばしやすいように腕を少し外側に回転させることがあり、さらに回外（F）とも類似したパターンとして表現される場合もあった。

ただし、ここでの基本動作以外についての解釈は説明の分かりやすさを優先した結果であり、以降の実験においてもそれぞれの動作を積極的に解釈しない（むしろ、解釈が難しいことの方が多い）。そうではなくて、それぞれの基本動作が高次元2値パターンとして分散表現されていることによって、未学習の動作に関しても基本動作のパターンと類似したパターンとしてSDNNの出力層において自然に表現されていることが重要である。このような動作パターンを行動推定においてうまくいかすことができる。

4. 行動推定実験

実データを用いて本システムの行動推定能力を調べるため、8チャンネルの表面筋電位信号から右前腕の行動を推定する実験を行った。なお、年齢20～39歳の健康な成人5名（男性4名、女性1名）の協力のもと実施した。ただし、被験者1は予備実験に数回参加しており、それ以外の被験者は初めて参加した。また、実施計画について帝京大学医学部倫理委員会の審査を受けて、計測は人権保護および被験者の倫理面に十分配慮して行った。

4.1 実験結果

まず、表1に示す行動についてそれぞれ1サンプルだけ本システムに与えて学習させた。その後、学習サンプルを増やし、改めて学習することを繰り返した。その結

表 2 推定部の学習回数

学習サンプル数	1	2	3	4	5
被験者 1	27	27	33	33	34
被験者 2	44	46	136	168	311
被験者 3	31	33	54	47	74
被験者 4	36	59	57	78	91
被験者 5	39	39	52	94	140
平均	35.4	40.8	66.4	84	130

果, それぞれの行動に関するデータを 5 サンプルずつ与えた場合でも平均 95% 程度を正しく学習できることを確かめた。

推論部の学習では, ネットワークの状態 $\mathbf{x}$ が正しい行動を表すパターンへ十分近づいていれば終了し (方向余弦 0.75 以上), そうでない場合は再度全て学習し直す方法をとった. 被験者毎の学習回数を表 2 に示す. 全く学習できないような行動はなく, 何度も学習に失敗したサンプルに関しても他の行動への悪影響は限定的であった.

次に, 学習済みのシステムに未学習サンプルを与えて, その推定過程および推定精度を調べた. なお, 行動終了時のネットワークの状態 $\mathbf{x}$ とそれぞれの行動を表すコードパターンとの方向余弦を計算して 0.5 を超えている, かつ最大値の行動として推定結果を解釈する. もし, 方向余弦が 0.5 を超えていれば, 学習によって行動を表す状態がアトラクタになっているため, その後ほぼその状態へ引き込まれる. 未学習サンプルに関する正答率を図 7 に示す. どの被験者についても学習サンプル数が増えれば正答率が高まり, 5 サンプルずつ与えて学習させた場合, 正答率は平均 85.9% であった (全サンプルに対しては 90.7%). また, 学習サンプルの組み合わせやネットワークの初期化などに用いた乱数列を様々に変えて実験した結果も同様であった.

また, 5 サンプルずつ学習したときの行動別正答率を図 8 に示す. 軌道アトラクタ間の干渉が大きい行動 2 や 5 などに関して, 正答率は 6~7 割程度とやや低かった. しかし, 基本動作を全く含まない行動 (例えば行動 10) など従来の手法では処理が難しいものを含めて, それ以外の行動に関して正答率は 8 割を超えていた.

4.2 考 察

この結果を詳細に見ると, 以下のようなことが分かる.

i. 未学習サンプルへの対応

被験者が同じように手や腕を動かしているつもりでも, 身体の高い冗長性やセンサノイズのため, 筋電位信号は毎回変化する. また, 連続的に動作しているときの筋電位信号は空間的にも時間的にも複雑に重なるため, どのような識別器を用いるにしても動作の安定した識別自体が難しい. さらに, 同じ行動でも, 構成する動作の切り替えタイミングが少しずれたり, 行動開始から終了までの時間が伸びたり縮んだりする. 例えば, それぞれの行動について時間の伸縮を調べると, 平均 8.8%, 行動に

図 7 学習サンプル数に対する正答率

図 8 未学習サンプルに関する行動別の正答率

よっては平均 23.4% (被験者 1 の行動 6) の伸縮があった. しかし, 本システムは比較的少ないサンプルの学習だけで, 未学習サンプルに関しても行動を正しく推定できた.

これには, 大きく 2 つの理由がある. 1 つ目は, 学習によって形成した軌道アトラクタへの引き込み現象を効果的に利用できたためである. 時々刻々の動作が正しく識別されている場合, それら動作に対応する部分空間では学習によって形成された軌道アトラクタが必ず存在する. 従って, これに沿って安定的に状態を遷移させることで正しく行動を推定できる. もし, 行動の途中で動作のタイミングが少しずれたとしても, ネットワークの状態 $\mathbf{x}$ はその軌道アトラクタに十分近いいため, 正しい軌道に引き込まれることでタイミングのずれを修正できる.

2 つ目は, 類似した別の部分空間において形成した軌道アトラクタの影響を利用することができたためである. 動作が正しく識別されていない場合, その動作に対応する部分空間には状態をその軌道に完全に引き込むだけの軌道アトラクタは存在しない. しかし, 類似した別の部分空間で形成している複数の軌道アトラクタの影響を様々に受けて状態遷移することができる. たとえ全く軌道アトラクタの影響を受けない場合があったとしても, ネットワークの状態がそのまま停滞するだけで, 正しい動作

が識別されて対応する部分空間へ射影されたときに再び状態が軌道アトラクタに引き込まれて遷移することができる。

ii. 誤推定の分析

正答率が低い行動について調べると、行動 1~5 や 15 など回転系の動作 (E, F) を含む行動の推定精度は低く、図 8 に示すように未学習サンプルに対する正答率は 6~8 割程度である。また、回転動作を含む全ての行動に関する誤推定の結果を分類すると、別の行動であると推定したものが 54.5%，行動終了時の最終的なネットワークの状態 $\mathbf{x}$ が初期状態 S から全く遷移していないか行動 1~15 を表すパターン全てと類似度が 0.5 以下であるものが 45.5% であった。

そこで、回転動作を含む行動について学習および推定過程をさらに詳しく調べた。その結果、回転動作 E, F を単独で行った場合と比べて、行動中は筋電位信号が極端に弱く、持続時間も短いため、被験者によってはそもそも回転動作の識別が正しくできていないことが分かった。加えて、被験者 2 については、行動中の筋電位を繰り返し計測しているときに、集中力が低下して回内と回外を間違えたため訂正するような動作をすることがあり、学習サンプルやテストサンプルに不適切なものが入り込んだ可能性があることが分かった。これらにより、学習時に幾つかの軌道が互いに大きく干渉して正しく軌道アトラクタが形成できないものがあった。つまり、これらの行動で正答率が低かったことに関しては動作識別部や計測方法の問題である。なお、前者については回転動作を識別しやすいうに追加で上腕に筋電センサを貼り付けることである程度改善でき、後者については行動毎に被験者に確認する必要がある。

回転動作の識別が正しくできない問題は、推定部における学習回数にも大きく影響した。例えば、表 2 に示すように、被験者 5 においてそれぞれの行動を 5 サンプル学習するのに 140 回もかかった。これは行動中の回外 (F) が識別できなかったためであった。未学習サンプルを与えた場合のシステムの出力について、行動 1 の結果を図 9 に、行動 2 を図 10 に示す。それぞれの図中の上のパネルは行動中の IEMG 信号を、中央は SDNN によって識別された動作を、下は神経力学系の状態を表している。なお、類似度 (Similarity) について、中央のパネルでは図 5 などと同様に動作を表すコードパターンと SDNN の出力層のパターンとの方向余弦として、下は行動を表すコードパターンと神経力学系の状態との方向余弦として算出した。また、それぞれの図上に行動区間を両矢印で表している。図に示すように、SDNN の出力層において行動 1 と 2 を構成する動作はどちらも「ニュートラル (N) → 握る (C) → ニュートラル (N)」と識別されていた。本来は、図 9 に示す行動 1 については握る (C) の後 100 フレームあたりから回外 (F) の動作が、図 10 に示す行動 2 については握る (C) に先立って 30 フレームあたり

から回外 (F) の動作が識別され、それぞれの動作に対応する部分空間においてそれぞれの軌道アトラクタが形成される。しかし、被験者 5 については回外 (F) の信号が相対的に弱くニュートラル (N) であると識別されたため、同じ部分空間においてほぼ同じ状態 $\mathbf{x}$ からそれぞれ別の状態へ遷移するような軌道を無理に学習しようとして失敗するものがあつた。

しかし、どの被験者においても、回転動作を含む行動を全く学習できない、あるいはある行動の未学習サンプルに関して全く推定できないということはなかった。これは、回転動作自体を識別できなくても動作の切り替え部分において少し別の動作パターンとして表現されればそれに対応する部分空間に軌道アトラクタを形成することができるし、動作を実行している時間や切り替わりのタイミングの違いにより状態 $\mathbf{x}$ に違いが生じていればそこから軌道アトラクタを形成できるからである。図 9 では、中央パネルの 80~120 フレームにおいて握る (C) とは少し異なる動作パターン (動作 D, E, F などと少し類似したパターン) として表現されている。そのため、類似しているが別の部分空間にネットワークの状態が射影されている。従って、下パネルの 100~200 フレームにおいてその部分空間において T^1 へ向かう軌道アトラクタを形成できた。

同様に、図 10 に示す行動 2 では、回外 (F) が正しく識別されていないため、他の行動に対応する軌道と接近して新たに軌道アトラクタを形成する必要があり、学習回数が増加した。しかし、中央パネルの 30~40 フレームにおいて回内 (E) と、60~70 フレームにおいて開く (D) や回内 (E) と少し類似したパターンとして表現されており、これらの区間で状態 $\mathbf{x}$ が少し遷移することで、学習サンプルの中で他と干渉せずに T^2 へ向かう軌道アトラクタを形成できたものがあつた。

iii. 一部重複する行動の推定

対象とする行動の中には、一部の動作が他と重複しているものが多く含まれている。このような行動は従来のシステムでは扱いが難しい。例えば、行動 7, 8 はそれぞれ「握る (C) → 人差し指と中指を伸ばす → 開く (D)」, 「握る (C) → 開く (D) → 握る (C)」で構成され、一部に同じ動作が含まれている。このような行動に関しても本システムは問題なく処理できる。

被験者 4 の推定過程を詳しく見てみよう。行動 7 の未学習サンプルを与えた場合の推定過程を図 11 に示す。まず、ネットワークの状態 $\mathbf{x}$ は初期状態 S 付近で停滞しており、40 フレーム付近において行動が開始されると少しずつ状態を遷移させている。次に、40~80 フレームにおいて握る (C) が識別されると、対応する部分空間に形成された複数の軌道アトラクタの影響を受けながら状態を遷移させ、行動 7 と 8 を表すパターン T^7, T^8 に近い状態に遷移する (それぞれとの類似度 0.25 程度)。その後、80~100 フレームにおいて次の動作 (人差し指と中指を

図9 行動1の推定過程 (被験者5)

図10 行動2の推定過程 (被験者5)

伸ばす)が実行されると、この動作を基本動作として学習していないけれど開く (D)に近い動作パターンとして表現されており、それに対応する部分空間で形成された軌道アトラクタに状態が引き込まれて T^7 へ遷移している (類似度 0.75 以上)。つまり、行動7と8を区別する動作が識別された時点で力学系のダイナミクスを適切に切り替えて、行動7を正しく推定することができる。

同様に、行動8の推定過程を図12に示す。行動が始まった20～90フレームまでは、行動7と8を表すパターン T^7, T^8 に近い状態に遷移している。その後、「開く (D) → 握る (C)」と動作が切り替わる90～120フレームにおいて T^8 へ向かう軌道へネットワークの状態が引き込まれて、行動8を正しく推定することができる。

本システムではより長い動作系列からなる行動やより重複が多い複雑な行動を扱うこともできる。そのために

は、行動を構成する動作を予め分析しておき、どの部分空間でどの軌道に引き込まれるかについて設計し、有限オートマトンを模擬する形で神経力学系の中に埋め込めばよい。しかし、この実験においてはそのような設計は全くしていない。ここで対象としているような行動であれば、そのような設計をしなくても形成した軌道アトラクタがお互いに影響を及ぼし合って行動を正しく推定できる。行動7の推定では2番目の動作で、行動8では2番目の動作ではなくその後の「開く (D) → 握る (C)」の動作の切り替わり付近において、それぞれの軌道へ引き込まれて推定することが自然に実現されている。

iv. 基本動作を含まない行動の推定

基本動作として学習していない動作によって大部分が構成される行動についても問題なく処理できる。例えば、行動10は蓋を開けるような行動、行動14は手のひらを

図 11 行動 7 の推定過程 (被験者 4)

図 12 行動 8 の推定過程 (被験者 4)

横方向に振る行動であるが、未学習サンプルに関してどちらも 9 割以上正しく推定することができた。

図 13 に行動 10 の未学習サンプルを与えたときの推定過程 (被験者 4) の例を 2 つ示す。中央のパネルを見ると、どちらの場合もはっきりと動作 A~F あるいは N などと識別されてはいない。しかし、それら基本動作に似たパターンとして自然に表現されており、そのパターンに対応する部分空間に形成されている軌道アトラクタに沿って状態遷移している。それぞれ行動 10 を表す T^{10} へ向かう軌道アトラクタに引き込まれるタイミングは異なっているが正しく推定できている。このような柔軟な推定を離散系で実現することは難しい。

5. お わ り に

本研究では、軌道アトラクタモデルが作る神経力学系のダイナミクスに基づいて運動情報を処理する方法を提案した。また、人間の腕の表面筋電位信号から手や腕の行動を推定するシステムを構築して、複数動作の組み合わせからなる行動を推定する実験を行った。その結果、本システムはネットワークの状態を軌道アトラクタへ引き込むことにより複雑な行動を柔軟に推定できることが分かった。

本研究のように分散表現と神経力学系だけにに基づいて運動情報処理するシステムには以下のような特性および可能性がある。

(1) パターンによる分散表現: 本システムでは、もともとパターンであるセンサ情報をそのまま高次元 2 値パ

図 13 行動 10 の推定過程 (被験者 4)

ターンとして分散的に表現することで、運動などの時系列情報をパターンの時空間的变化として扱う。また、センサ情報よりも抽象的な情報である動作や行動も記号を用いずにパターンとして分散表現して処理する。このようなパターンベースの情報処理系は、あらゆる情報表現レベルにおいてパターンの類似性に基づいて類推したり、パターンに暗黙的に埋め込まれている構造を利用することができる。これが記号のような縮約的表現を利用する離散系と本質的に異なる点である。このような情報処理系は、いわゆるシンボルグラウンディング問題 [Harnad 90] を回避しているし、さらに発展させていくことで解決困難とされるフレーム問題 [松原 87, McCarty 69] についても深刻な問題にならない程度に対処できる大きな可能性がある [山根 07]。

(2) 神経力学系の自律的なダイナミクス：神経力学系の自律的なダイナミクスを利用して推定部が実現されて

いることも重要である。ネットワークの動作は微分方程式で表されるためその状態遷移と運動情報を対応付けて扱うことができ、離散系よりも相性がよい。また、本システムでは、選択的不感化法を用いることで 1 つの神経力学系のダイナミクスを様々に変化させている。確かに、予め設定した幾つかの基本動作をコードするパターンに応じてダイナミクスを変化させるだけでは離散的な操作であり、複数の力学系を状況に応じて切り替えるハイブリッドシステムと大きな違いはない。しかし、この方法はダイナミクスを連続的に変化させることもできる。例えば、本システムでは基本動作以外の新奇な動作に関しても何らかのパターンとして自然に表現されることから、ダイナミクスを離散的に切り替えたり徐々に切り替えたり、複数のダイナミクスの影響を受けながら状態を遷移させたりすることが予め設計していなくても実現されている。今後、さらにこの方法を発展させることでより複

雑な運動情報処理を実現できる可能性がある。

(3) 処理のリアルタイム性: 将来的にシステムをリアルタイムに動かすことを考えると計算コストも重要である。これに関して、本システムでは原理的に全ての素子は並列に動作するので、対象とする動作や行動を増やし、それに伴って素子数を増やした場合でも、学習や動作に必要なとされるメモリ容量や計算時間が爆発的に増大することはない。実際に、画像処理用演算資源を汎用目的で利用する技術 (GPGPU 技術) を利用すれば実時間で十分動作することを確認している。

(4) システムの拡張性: 本システムでは、センサ部、識別部、推定部を別々に開発して統合した。また、複数の軌道アトラクタモデルを効果的に連動させる方法 [Hasuo 08] が提案されており、これを用いることで神経力学系だけに基づいて様々な機能を実現することができる。このように、本システムはモジュール性も高く拡張が容易である。

推定部の学習の効率化、推定精度の向上、筋電位以外の画像などを用いた運動情報処理への応用など残された課題は多いが、以上のことから神経力学系を用いた運動情報処理に大きな可能性があると考えられる。

謝 辞

本研究の一部は、文部科学省学術研究助成基金助成金若手研究 (B) (No.24760213) の補助を受けた。

◇ 参 考 文 献 ◇

- [Bobick 97] Bobick, A. F. and Wilson, A. D.: A State-Based Approach to the Representation and Recognition of Gesture, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol.19, No.12, pp.1325–1337 (1997)
- [Dorffner 96] Dorffner, G.: Neural Networks for Time Series Processing, *Neural Network World*, Vol.6, pp.447–468 (1996)
- [Elman 90] Elman, J. L.: Finding Structure in Time, *Cognitive Science*, Vol.14, pp.179–211 (1990)
- [二見 88] 二見亮弘, 星宮望: 相互結合型神経回路網の状態遷移に基礎をおく時系列パターン認識の神経回路モデル, *電子情報通信学会論文誌 (D)*, Vol.71-D, No.10, pp.2181–2190 (1988)
- [Harnad 90] Harnad, S.: The Symbol Grounding Problem, *Physica D*, Vol.42, pp.335–346 (1990)
- [Hasuo 08] Hasuo, T., Yamane, K. and Morita, M.: Context-Dependent Processing of Spatiotemporal Patterns Based on Interaction Between Neurodynamical Systems, *Advances in Cognitive Neurodynamics*, pp.231–236 (2008)
- [Hong 00] Hong, P., Turk, M. and Huang, T. S.: Gesture Modeling and Recognition Using Finite State Machines, in *Proc. IEEE Int. Conf. on Automatic Face and Gesture Recognition*, pp.410–415 (2000)
- [稲邑 11] 稲邑哲也: HMM と人間の動作認識・教示・生成, *日本ロボット学会誌*, Vol.29, No.5, pp.419–422 (2011)
- [川嶋 10] 川嶋宏彰, 松山隆司: ハイブリッドダイナミカルシステムによる動的現象のモデル化と認識, *システム/制御/情報 (システム制御情報学会誌)*, Vol.54, No.1, pp.28–33 (2010)
- [Kawata 10] Kawata, H., Tanaka, F., Suemitsu, A. and Morita, M.: Practical Surface EMG Pattern Classification by Using a Selective Desensitization Neural Network, *Neural Information Processing (Part II)*, *Lecture Notes in Computer Science*, Vol.6444, pp.42–49 (2010)

- [松原 87] 松原仁, 山本和彦: フレーム問題について, *人工知能学会誌*, Vol.2, No.3, pp.266–272 (1987)
- [McCarty 69] McCarty, J. and Hayes, P. J.: Some Philosophical Problems from the Standpoint of Artificial Intelligence, *Machine Intelligence*, Vol.4, pp.463–502 (1969)
- [Morita 96] Morita, M.: Memory and Learning of Sequential Patterns by Nonmonotone Neural Networks, *Neural Networks*, Vol.9, No.8, pp.1477–1489 (1996)
- [森田 02] 森田昌彦, 松沢浩平, 諸上茂光: 非単調神経素子の選択的不感化を用いた文脈依存的連想モデル, *電子情報通信学会論文誌 (D-II)*, Vol.J85-D-II, No.10, pp.1602–1612 (2002)
- [森田 04] 森田昌彦, 村田和彦, 諸上茂光, 末光厚夫: 選択的不感化法を適用した層状ニューラルネットの情報統合能力, *電子情報通信学会論文誌 (D-II)*, Vol.J87-D-II, No.12, pp.2242–2252 (2004)
- [野中 11] 野中和明, 田中文英, 森田昌彦: 階層型ニューラルネットの 2 変数関数近似能力の比較, *電子情報通信学会論文誌 (D)*, Vol.J94-D, No.12, pp.2114–2125 (2011)
- [奥田 09] 奥田裕之, 鈴木達也: ハイブリッドシステムモデルに基づく人間の高次行動理解, *システム/制御/情報 (システム制御情報学会誌)*, Vol.53, No.10, pp.426–433 (2009)
- [Starner 95] Starner, T. and Pentland, A.: Real-Time American Sign Language Recognition from Video Using Hidden Markov Models, in *Proc. Int. Symp. on Computer Vision*, pp.265–270 (1995)
- [鈴木 06] 鈴木達也, 井村順一: ハイブリッドシステムとして捉える人間行動モデル, 計測と制御 (計測自動制御学会誌), Vol.45, No.12, pp.1055–1061 (2006)
- [山根 07] 山根健, 蓮尾高志, 末光厚夫, 森田昌彦: 軌道アトラクタを用いたパターンベース推論, *電子情報通信学会論文誌 (D)*, Vol.J90-D, No.3, pp.933–944 (2007)
- [Yamane 10] Yamane, K. and Morita, M.: Brain-like Computing Based on Distributed Representations and Neurodynamics, *New Generation Computing*, Vol.28, No.4, pp.321–338 (2010)
- [Yamato 92] Yamato, J., Ohya, J. and Ishii, K.: Recognizing Human Action in Time-Sequential Images Using Hidden Markov Model, in *Proc. IEEE Computer Society Conf. on Computer Vision and Pattern Recognition*, pp.379–385 (1992)
- [吉川 09] 吉川雅博, 三河正彦, 田中和世: 筋電位を利用したサポートベクターマシンによる手のリアルタイム動作識別, *電子情報通信学会論文誌 (D)*, Vol.J92-D, No.1, pp.93–103 (2009)

[担当委員: 小林 亮太]

2016 年 4 月 6 日 受理

著 者 紹 介

山根 健(正会員)

1980 年 10 月 4 日生。2007 年 3 月筑波大学第三学群工学システム学類卒業。2010 年 3 月同大学院システム情報工学研究科知能機能システム専攻博士課程修了, 博士 (工学)。同大学サイバニクス・プログラム単位取得。2010 年 4 月愛知淑徳大学人間情報学部常勤講師を経て, 2011 年 4 月帝京大学理工学部および大学院理工学研究科助教, 2016 年 4 月講師となり現在に至る。神経回路モデル, 人支援システム, 屋外自律移動ロボットなどの研究に従事。日本神経回路学会, 電子情報通信学会, 情報処理学会の会員。