

感覚情報の次元削減による抽出情報を活用した制御モデルの提案

岡本 亮太[†] 西井 淳[†]

† 山口大学大学院理工学研究科 〒753-8512 山口県山口市吉田 1677-1

E-mail: †{okamoto,nishii}@bcl.sci.yamaguchi-u.ac.jp

あらまし 習熟した運動タスクを行うとき、脳はタスクを実現するために様々な解を身体自由度を駆使することにより臨機応変に引き出していると 20 世紀前半に活躍した生理学者 Bernstein は述べた。このような運動制御を実現するために神経系は、(1) 感覚情報からタスク達成の指標となる性能変数の抽出、(2) 性能変数を目的値に近づけるための制御、(3) 少数の性能変数に対する制御を全身の筋活動に反映させるための、筋シナジーによる複数の筋肉の同時支配を行っていることがこれまでの研究により示唆されている。本研究では、運動における目標軌道生成に単純な砂時計型ニューラルネットワークを用いることで、以上のような特徴をもつ運動制御を実現できることを説明する。

キーワード 軌道計画, 砂時計型ニューラルネットワーク, 運動制御, UCM, シナジー

A learning control model that realizes dimensional reduction in sensorimotor systems

Ryota OKAMOTO[†] and Jun NISHII[†]

† Graduate School of Science and Engineering, Yamaguchi University
1677-1 Yoshida, Yamaguchi, 753-8512, Japan

E-mail: †{okamoto,nishii}@bcl.sci.yamaguchi-u.ac.jp

Abstract Bernstein, a physiologist in 20th century, suggested that our nervous system draws out a suitable solution depending on the circumstances by utilizing our abundant degrees of freedom of our body. Previous studies have suggested that in order to realize such kinds of control (i) the nervous system extracts performance variables that show the performance of given tasks from sensory signals, (ii) controls the variables so as to bring them into desired values, and (iii) activates some muscle groups simultaneously by utilizing muscle synergy. In this study, we will explain that these characteristics will be realized by using a simple sandglass-type neural network for the generation of desired trajectories.

Key words motor planning, SNN, motor control, UCM, synergy

1. はじめに

高い身体自由度を有する生体がなんらかの運動を行うとき、この自由度を如何に拘束して運動タスクを実現する解を決定するかが問題となる。その一方で、その豊富な自由度の活用により様々な環境に柔軟に対応することができる。20 世紀前半に活躍したロシアの生理学者 Bernstein は、運動における重要な問題は自由度を操ることにあると考え「運動の巧みさ」と関連づけて議論した[1]。

豊富な身体自由度を生体が如何に拘束して運動タスクを実行しているかという問題については、腕の到達運動や歩行運動における軌道決定問題として様々な計算論的研究がなされてきた[2]～[8]。一方、熟練した運動においてもその運動軌道は試行

毎に若干異なるものになる。Bernstein はこの点に注目し、脳は習熟した運動タスクにおいて運動タスクを実現できる解を身体自由度を駆使することにより臨機応変に引き出していると考えた[9]。Scholz と Schöner は、このように自由度を活用した身体運動を定量的に評価するために Uncontrolled Manifold (UCM)[10] の概念を発表した。UCM とは、冗長な変数(関節角度等)がタスク達成という拘束下で作る多様体を指す。生体の運動制御においてはひとつに絞った解を安定化しているのではなく、この UCM を安定化する一方で、UCM 上の運動のバラツキは許容することにより冗長な自由度を活用した運動を実現している可能性がある[11]。例えば冗長リンク系である腕の場合、ある手先位置を実現する関節角の組み合わせは無数にある。したがって手先を 2 点間で移動する腕の到達運動は関節角

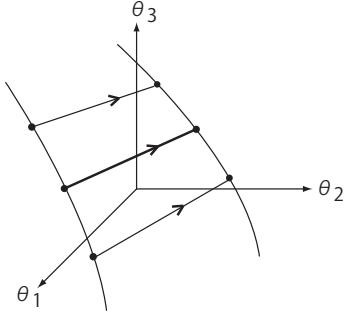


図 1 2 点間の到達運動は、関節角空間では多様体間の移動として表現される。

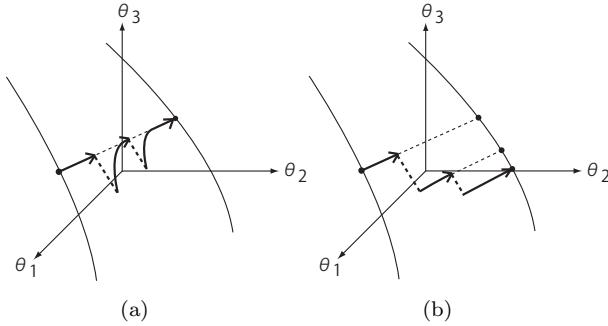


図 2 到達運動の安定化。(a) 従来の工学モデルではあらかじめ決められた軌道を安定化する手法がとられていたが、(b) のように UCM を安定化することによって、初期位置や外乱後の状態に応じて、UCM 上に（なんらかの意味で）効率よく移動できるようになる。

空間における多様体間の移動として表現される（図 1.）。生体はこの終点位置を表現する制御変数空間内の多様体を多様体を安定化しているというのが UCM の考え方である。近年、様々な運動タスクについて、神経系がこのような制御を行っていることを示唆する研究結果が報告されている [10], [12]~[14]。

このような UCM を活用した制御により、制御のために扱う変数の数を減らすことができる。例えば Ting [15] によると、ヒトの立位姿勢の制御においては感覚情報から抽出された重心位置を安定化するような身体制御が行われている可能性が高い。この重心位置のように運動タスクを実現する上で重要な変数を性能変数 (performance variable) と Latash らは呼んでいる [16]。性能変数が目的値になるように制御することで、UCM の安定化を図れることになり、任意の初期状態もしくは外乱後の状態に応じて、タスクを達成するための UCM 上の解に（なんらかの意味で）効率良く移動することができる（図 1.）。

すなわち、中枢神経系による運動制御を考えるとき、(1) 感覚情報から身体制御に必要なタスクレベルの情報（性能変数）の抽出、(2) 性能変数を目的値に近づけるための制御（UCM の安定化）が重要となる。さらに Ting は、少数の性能変数の制御を全身の筋活動に反映させる際には、(3) 筋シナジーを基底とした複数の筋肉の同時支配が重要であると述べた（図 3）[15]。その例として、立位姿勢を維持するために動員される筋活動の基底（筋シナジー）には、3 種類存在することを筋電位の主成分分析結果により示している。

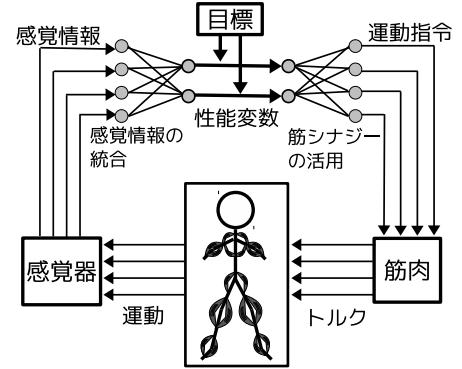


図 3 運動制御における情報の流れ (Ting [15] の Fig.8 を改変)

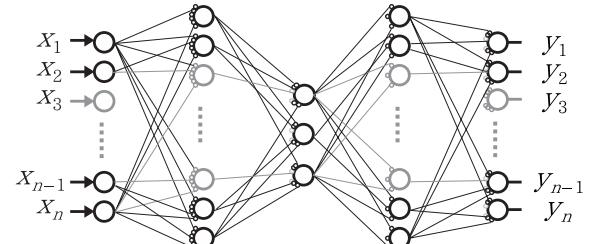


図 4 砂時計型ニューラルネットワーク

本研究報告では、運動における目標軌道生成に単純な砂時計型ニューラルネットワーク (SNN:Sandglass-type Neural Network) を用いることで、以上のような特徴をもつ制御を実現できることを説明する。

2. 砂時計型ニューラルネットワークを用いた目標軌道の生成

2.1 特徴細胞の制御による目標軌道の生成

本節では、恒等写像を学習した 5 層の SNN の第 3 層に抽出される制御対象の主成分の一部を操作することにより、冗長性を活用した目標軌道の生成が可能なことを説明する。

2.1.1 特徴細胞の制御による目標軌道の生成方法

冗長性のある感覚情報を入力とする SNN(図 4) に、誤差逆伝播法 (BP:Back Propagation) 学習則を用いて恒等写像を学習させると、第 3 層の各細胞 (特徴細胞) に感覚情報の主成分が抽出される [17]。この第 3 層の細胞が表現する主成分が運動タスクにおける性能変数を表現する場合、その細胞の状態が目標値になるように操作することにより対応する感覚情報を想起できる。この感覚情報が筋長などを表現する場合、これを各アクチュエータの目標値とすることができる。ここで、各特徴細胞の状態は複数のアクチュエータの目標値を決定する基底をなす。SNN の出力が各筋肉への指令に変換される場合には、特徴細胞から SNN の出力値への信号が筋シナジーを決定する。また、タスクに冗長性がある場合には特徴細胞の一部の出力が対応する目標値になるよう操作すれば初期状態に近い目標軌道を想起可能と考えられる。

2.1.2 シミュレーション実験

恒等写像を学習した SNN の第 3 層に表現された主成分を制御情報とすることで目標姿勢を生成可能かを、3 関節 3 リンクの

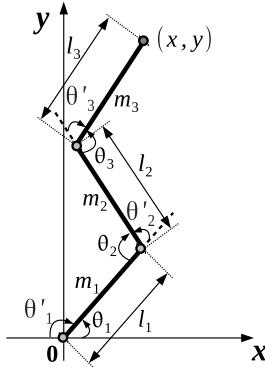


図 5 制御対象である 3 リンク 3 関節のアーム。

アーム(図 5)を用いて実験した。アームの各リンク長は 0.3 [m]とした。SNN の入力信号として、感覚情報をアームの関節角度 $\theta = (\theta_1, \theta_2, \theta_3)^T$ [rad] (可動域は $0 \leq \theta_i \leq \pi$ [rad] ($i = 1, 2, 3$)) 及び感覚情報に冗長性を持たせるため $\theta' = (\theta'_1, \theta'_2, \theta'_3)^T$ [rad] (ただし、 $\theta'_i = \pi - \theta_i$) の計 6 個を用いた。SNN の各層の細胞数は入力層から順に 6, 9, 3, 9, 6 とした。各細胞は前層の各細胞の出力値と結合重みの線形和を入力とし、標準シグモイド関数を用いて出力値を決定する。各細胞の出力値の範囲が [0.0, 1.0] であるため、SNN への入力信号である各関節角度は [0.1, 0.9] の範囲になるようスケーリングした。また、出力値も関節角度に対応づけるため同様にスケーリングした。また、 θ_j^{out} ($j = 1, 2, \dots, 6$) が 0 未満であれば 0 に、 π より大きい場合 π に補正し、各関節及び手先位置が $y < 0$ となった場合、 $y \geq 0$ となるように θ_i^{out} を補正した。SNN の出力で決定される θ_j^{out} に対応するアームの各関節角度は $\theta_i^{out,new} = (\theta_j^{out} + (\pi - \theta_{j+3}^{out})) / 2$ ($i, j = 1, 2, 3$) [rad] で決定した。学習開始時には、SNN の結合重みを $[-0.1, 0.1]$ の範囲の一様乱数で初期化し、恒等写像の学習データに用いる関節角度 θ は手先位置の偏りが少なくなる条件下で乱数により生成し、恒等写像の学習は BP 学習則により 100 万回行った。

2.1.3 結果・考察

図 6 は、2 種類の初期姿勢(灰色)に対応する入力信号を SNN に入力し、特徴細胞の一つの出力値を [0, 1] の範囲の 6 種類の値になるよう操作した際に想起させた姿勢(黒色)それぞれを表す。図 6 の (a) は初期姿勢 $\theta = (\frac{\pi}{16}, \frac{5\pi}{16}, \frac{5\pi}{16})^T$ [rad] の場合、(b) は $\theta = (\frac{5\pi}{16}, \frac{5\pi}{16}, \frac{5\pi}{16})^T$ [rad] の場合である。この場合、操作した特徴細胞には 2 つの関節角度を同時に制御するような主成分が表現されていることがわかる。また、この主成分がタスク達成に重要な性能変数を表現する場合、この値を目標値に設定することによって、目標値を達成できる無数の姿勢のうち初期姿勢に応じて異なる目標姿勢を想起可能であることがわかる。これは、特徴細胞の一部の状態を操作することでタスクを達成できる姿勢(UCM)のうち特徴細胞が構成する空間内で初期姿勢から最も近い姿勢を目標姿勢として想起しているためである(図 7)。多谷ら[18]は SNN の中間層の制御によりロボットの運動制御における情報圧縮や運動のシンボルが可能であることを示したが、さらに本研究結果は中間層の一部のみに制御を加えることで初期状態に応じた目標軌道を単純な砂時計型ネット

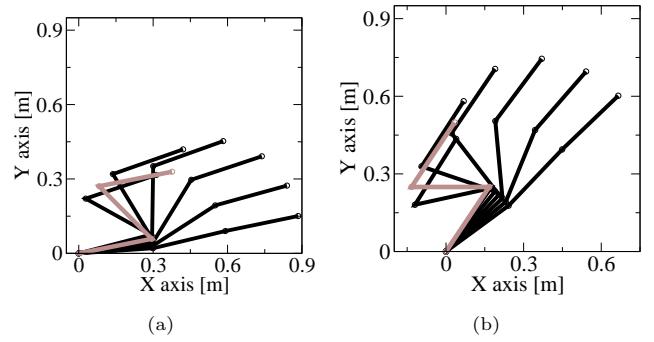


図 6 SNN の特徴細胞の 1 つの出力を変更した時に得られる SNN の出力値に対応するアームの姿勢。灰色線が初期姿勢、黒線が特徴細胞の出力を様々な値に変更した時に想起される姿勢。(a) は初期姿勢 $\theta = (\frac{\pi}{16}, \frac{5\pi}{16}, \frac{5\pi}{16})^T$ [rad] の場合、(b) は $\theta = (\frac{5\pi}{16}, \frac{5\pi}{16}, \frac{5\pi}{16})^T$ [rad] の場合である。

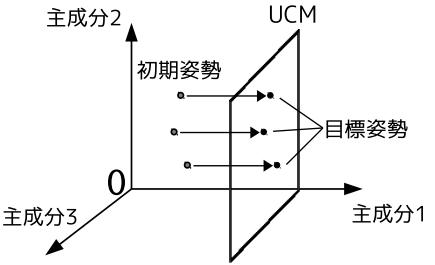


図 7 SNN の第 3 層の各特徴細胞に表現された主成分により構成された空間。3 つのうち 1 つの特徴細胞の出力が目標値になるよう制御した場合、その目標値を実現できる姿勢のうち、初期姿勢から主成分空間において最も近い目標姿勢を想起できる。

ワークで生成可能であることを示している。

2.2 特徴細胞の学習による目標軌道の生成

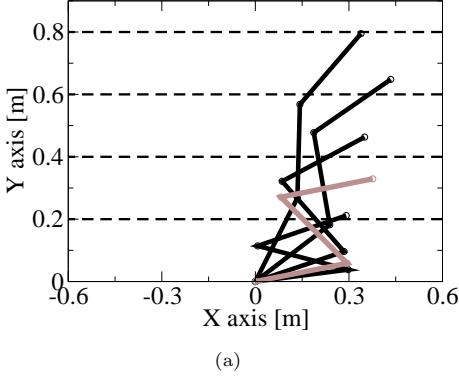
制御に必要な性能変数が SNN の特徴細胞に表現される場合は前節の方法で目標姿勢の生成が可能だが、両者が一致するとは限らない。その場合、性能変数を特徴細胞の表現に変換する方法を考えることもできるが、ここではタスク変数が特徴細胞の一つに表現されるように中間層の学習を行う方法を検討する。

2.2.1 シミュレーション実験

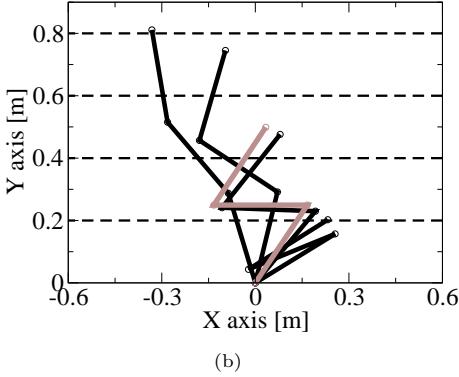
制御対象とシミュレーション条件は、2.1.2 節と同様である。ただし、特徴細胞の一つにはアームの手先の y 座標が output されるように学習させた。中間層の学習と恒等写像の学習は交互に行つた。学習後の SNN に初期姿勢を入力し、アームの y 座標を表現する特徴細胞の出力値が目標値になるよう操作し、実現される姿勢を調べた。

2.2.2 結果・考察

図 8 は、SNN に初期姿勢(灰色)を入力し、特徴細胞の一つの出力値を操作した後に想起させた姿勢(黒色)を表す。破線は各目標値を示す。図 8 の (a) が初期姿勢 $\theta = (\frac{\pi}{16}, \frac{5\pi}{16}, \frac{5\pi}{16})^T$ [rad] の場合、(b) が $\theta = (\frac{5\pi}{16}, \frac{5\pi}{16}, \frac{5\pi}{16})^T$ [rad] の場合である。初期姿勢に対し特徴細胞の出力を $y^d = 0.2, 0.4, 0.6, 0.8$ に置き換えたところ、前節同様に目標姿勢は初期姿勢から近い位置に想起されていることがわかる。



(a)



(b)

図 8 2種類の初期姿勢(灰色)から特徴細胞の出力値を変更時に想起される目標姿勢(黒線)。破線は各目標値を示す。(a)は初期姿勢 $(\frac{\pi}{16}, \frac{5\pi}{16}, \frac{5\pi}{16})^T$ [rad], (b)は $(\frac{5\pi}{16}, \frac{5\pi}{16}, \frac{5\pi}{16})^T$ [rad]の場合を表す。

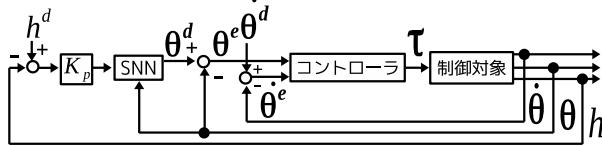


図 9 SNN を目標軌道生成部にもつ運動学習・制御モデル。

3. 冗長性を活用した運動学習制御モデル

前節までに、SNN で初期姿勢に応じた目標姿勢を生成可能であることを述べた。SNN により出力する各アクチュエータへの目標値を運動指令に変換するためのコントローラを加えることで運動制御が可能になる。以下ではこのような制御により 1 節で述べたような UCM の安定化による、冗長性を活用した制御が可能であることを示す。

3.1 冗長性を活用した運動学習制御モデル

図 9 に SNN による目標軌道生成部をもつ運動学習モデルの概要を示す。SNN はアームの関節角度を入力とし性能変数を表す特徴細胞の出力値を制御することで各関節角度の目標値を生成する。特徴細胞の出力値に対しては、その値が目標値に近づくようにフィードバック制御を行う。また SNN の出力である各関節角度の目標軌道を運動指令に変換するコントローラは、各関節角度及び角速度について目標値からの誤差を入力とし、関節トルクを出力するフィードバック制御器としている。

表 1 アームの物理パラメータ。

各パラメータ	上腕	下腕	手先
質量 (m_1, m_2, m_3) [kg]	1.5	1.5	1.0
長さ (l_1, l_2, l_3) [m]	0.3	0.3	0.3
重心位置 (l_{g1}, l_{g2}, l_{g3}) [m]	0.15	0.15	0.15
粘性 (c_1, c_2, c_3) [kgm ² /s]	1.0	1.0	1.0

3.2 シミュレーション実験

実験タスクは、手先の位置を y 座標の目標値 y^d にリーチングし静止することとする。制御対象は 2.1.2 節と同様であるが本シミュレーションではアームのダイナミクスも考慮している(表 1)。用いた SNN は 2.2.1 節と同様であるが各層の細胞数は入力層から順に 6, 12, 3, 12, 6 とした。また、手先の y 座標を表現する特徴細胞の制御にはフィードバックゲイン K_p の P 制御を用いた。ゲイン $K_p = 1$ のときには特徴細胞の出力を目標値で置き換えることになるのでタスクを達成できる目標姿勢が SNN から出力され、 $K_p < 1$ のときには目標値を達成するまでの目標軌道が時間とともに出力されることになる。SNN が生成した目標軌道を実現するための関節トルク $\tau = (\tau_1, \tau_2, \tau_3)^T$ [m·N] を発生するコントローラは、神原ら [19] と同様にして強化学習の一手法である Actor-Critic(AC) 手法 [20] を用いて獲得した。

Actor が扱う状態 s としては、目標関節角度 θ^d と関節角度 θ の誤差 $\theta^e = (\theta_1^e, \theta_2^e, \theta_3^e)^T$ と、目標関節角速度 $\dot{\theta}^d$ と関節角速度 $\dot{\theta}$ との誤差 $\dot{\theta}^e = (\dot{\theta}_1^e, \dot{\theta}_2^e, \dot{\theta}_3^e)^T$ を用いた。ただし、目標関節角速度 $\dot{\theta}^d$ は $\mathbf{0}$ [rad/s] とする。連続な状態空間を扱うために関数近似法の一つである NGnet(Normal Gaussian network) [21] を用いた。基底関数は、角度誤差に関する次元には $-\pi$ [rad] から $\frac{\pi}{2}$ [rad] 刻みに 5 個ずつ、角速度誤差に関する次元には -3π [rad/s] から π [rad/s] 刻みに 7 個ずつを配置した。Actor の出力値は、基底関数の線形和に探索用ノイズ σ_t を加えた値に対するシグモイド関数の出力値に最大トルク $\tau^{max} = 10$ [m·N] を掛けたものとする。探索用ノイズ σ_t は平均 0、標準偏差 1 の正規乱数を用いた。ノイズは習熟と共に減少させた。

報酬 r は次式で与えた。

$$r = \exp(-r^{ang}) + \exp(-r^{vel}) \quad (1)$$

ここで、 r^{ang} と r^{vel} はそれぞれ関節角度と関節角速度の誤差の大きさを表したもので次式の通りである。

$$\begin{aligned} r^{ang} &= \alpha^{ang} \cdot \sum_{i=1}^3 (\theta_i^e)^2 \\ r^{vel} &= \alpha^{vel} \cdot \sum_{i=1}^3 |\dot{\theta}_i^e| \end{aligned} \quad (2)$$

ここで、 α^{ang} と α^{vel} は適当な定数であり、本シミュレーションでは $\alpha^{ang} = 1$ と $\alpha^{vel} = 10$ とした。また、運動中に、関節可動域の超過、設定関節角速度の超過、距離 $h < 0$ のいずれかの状態となった場合は報酬 $r = -1.0$ を与え、その学習を行った後に運動終了とする。Actor は獲得可能な総報酬の期待値が最大となるように入出力関係を学習する。

コントローラは、1回のリーチング運動時間5 [s] の間に、0.04 [s] 毎に学習と運動指令の計算を行う。このリーチング運動学習は50000回行った。リーチング運動の初期状態は、SNNの学習時と同様にランダムな関節角度とし、各関節角速度は0とした。SNNとコントローラの学習は個別に行った。アームの動力学計算にはODE(Open Dynamics Engine)を用い、ODEの時間刻みは0.01 [s]とした。

3.3 結果・考察

SNNの中間層の特徴細胞を制御するフィードバックゲインを $K_p = 0.5$ とし、目標値を $y = 0.8$ [m]とした場合のシミュレーション結果を図10に示す。図10(a)(b)はそれぞれ初期姿勢を $\theta = (\frac{\pi}{2}, \frac{\pi}{4}, \frac{\pi}{4})^T$ [rad]及び $\theta = (\frac{\pi}{4}, \frac{\pi}{8}, \frac{\pi}{8})^T$ [rad]とした場合であるが、いずれも初期姿勢に近い目標姿勢でリーチングを実現できていることがわかる。また、図10(c)は(b)と同様の初期姿勢からリーチングを開始し、運動開始1 [s]後に0.3 [s]間手先位置が反時計回りに回転する向きに各関節角度に外乱を与えた場合を表す。外乱による姿勢変化に応じて目標軌道を生成し運動タスクを実現していることがわかる。すなわち、本制御によりUCMの安定化が実現されており、初期姿勢や外乱に応じてタスクを達成できる軌道を引き出していることがわかる。

4. まとめ

本研究では、SNNを利用することによって感覚情報から性能変数の抽出をし、性能変数に対する制御を行うことでタスク達成のための解空間となるUCMを安定化する制御を行えることを示した。このような制御により、タスクを達成できる解空間の中から初期姿勢や外乱に応じた解を随時引き出すことができる。また、本手法では、筋シナジーに相当する運動指令における基底も、SNNの中間層から出力層への結合の学習による形成とともに獲得されるものとなっている。

このようにUCMの安定化を行うための制御手法は、TodorovとJordan[22]や、有本[23]により制御工学の立場からも議論されているが、本研究のように比較的単純な方法でも実現可能であることは興味深い点と思われる。ただし、この方法には以下のような欠点もある。与えられた運動タスクの実現に重要と思われる性能変数をSNNの中間層に学習させたとき、中間層で表現される特徴が互いに独立でなくなる可能性がある。実際、本シミュレーション実験において中間層の一つの特徴細胞がアームの手先のy座標を表現するように学習した場合、手先のy座標の取りうる最大値($y^d = 0.9$ [m])を目標値とするようなリーチング運動は、しばしば困難であった。このような問題を回避するためには、SNNの一部の特徴細胞の表現を拘束しながら、各特徴細胞の状態の直交性を保つための学習上の手法を検討することも重要である。また、例えばヒトのリーチング運動においては、トルク変化最小規範や終点分散最小規範等の規範に基づく最適軌道に近い軌道をとることが知られているが、この特徴細胞の状態空間における運動計画の結果が、このような規範に基づく解を生成しうるかに関する議論も必要であろう。さらに重要な課題としては、そもそもタスクの実現において重要と考えられる評価変数を学習過程においてどのように

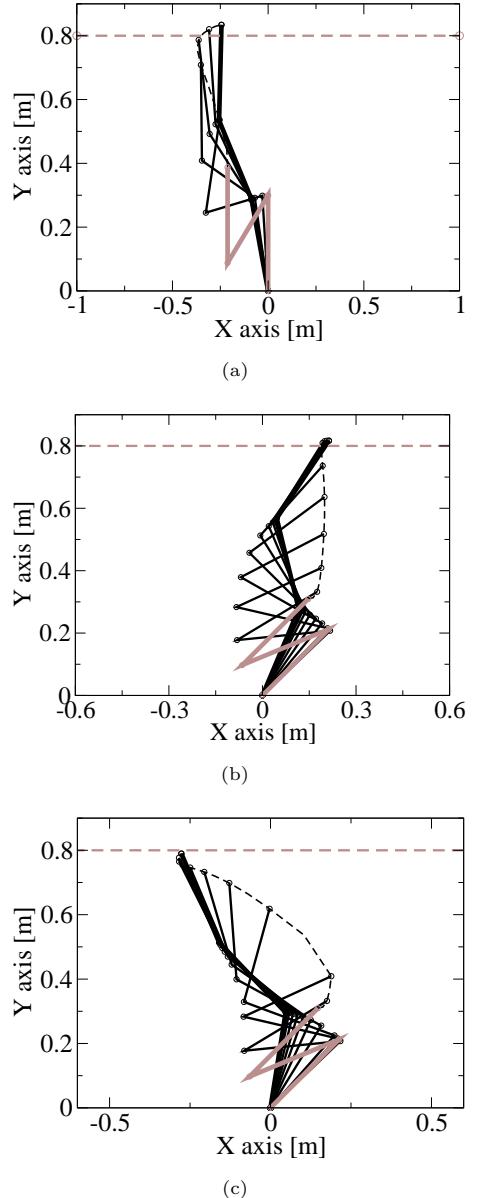


図10 初期姿勢(灰色実線)から目標距離(灰色破線)0.8 [m]までリーチングしたアーム(黒色実線)の軌道(黒色破線)を表す。(a)は初期姿勢 $\theta = (\frac{\pi}{2}, \frac{\pi}{4}, \frac{\pi}{4})^T$ [rad]の場合、(b)は $\theta = (\frac{\pi}{4}, \frac{\pi}{8}, \frac{\pi}{8})^T$ [rad]とした場合を表す。また、(b)は外乱を与えない場合、(c)は運動開始後1 [s]後に0.3 [s]間手先位置が反時計回りに回転する向きに各関節角度に外乱を与えた場合を表す。

発見しうるかという問題を検討していく必要もある。

謝 詞

本研究の成果の一部は科研費(22500526)の助成によるものである。

文 獻

- [1] N. A. ベルンシュタイン, デクステリティ 巧みさとその発達(訳:工藤和俊, 佐々木正人), 金子書房, 2003.
- [2] T. Flash, and N. Hogan, "The coordination of arm movements: An experimentally confirmed mathematical model," J Neurosci, vol.5, pp.1688-1703, 1985.
- [3] Y. Uno, M. Kawato, and R. Suzuki, "Formation and control of optimal trajectory in human multijoint arm move-

- ment: minimum torque-change model," *Biol Cybern*, vol.61, pp.89-101, 1989.
- [4] A.E. Minetti, and R.M. Alexander, "A theory of metabolic costs for bipedal gaits," *J Theor Biol*, vol.186, pp.467-476, 1997.
 - [5] H. Hoppeler, and E.R. Weibel, "Limits for oxygen and substrate transport in mammals," *J Exp Biol*, vol.201, pp.1051-1064, 1998.
 - [6] J. Nishii, "Legged insects select the optimal locomotor pattern based on energetic cost," *Biol Cybern*, vol.83, no.5, pp.435-442, 2000.
 - [7] J. Nishii, "An analytical estimation of the energy cost for legged locomotion," *J Theor Biol*, vol.238, no.3, pp.636-645, 2006.
 - [8] J. Nishii, and Y. Taniai, "Evaluation of trajectory planning models for arm reaching movements based on energy cost," *Neural Comp*, vol.21, no.9, pp.2634-2657, 9 2009.
 - [9] M.L. Latash, J.P. Scholz, and G. Schöner, "Toward a new theory of motor synergies," *Motor Control*, vol.11, pp.276-308, 2007.
 - [10] J.P. Scholz, and G. Schöner, "The uncontrolled manifold concept: Identifying control variables for a functional task," *Exp Brain Res*, vol.126, pp.289-306, 1999.
 - [11] M.L. Latash, J.P. Scholz, and G. Schöner, "Motor control strategies revealed in the structure of motor variability," *Exerc Sport Sci Rev*, vol.30, no.1, pp.26-31, 2002.
 - [12] J.F. Yang, J.P. Scholz, and M.L. Latash, "The role of kinematic redundancy in adaptation of reaching," *Exp Brain Res*, vol.176, pp.54-69, 2007.
 - [13] S. Kaichida, Y. Hashizume, N. Ogihara, and J. Nishii, "An analysis of leg joint synergy during bipedal walking in Japanese macaques," *Proc. of IEEE EMBC*, pp.8183-8186, 2011.
 - [14] J. Nishii, Y. Hashizume, S. Kaichida, H. Suenaga, and Y. Tanaka, "Constraint and exploitation of redundant degrees of freedom during walking," *Robot Auton Syst*, in press.
 - [15] L. Ting, "Dimensional reduction in sensorimotor systems:a framework for understanding muscle coordination of posture," *Prog Brain Res*, vol.165, pp.299-321, 2007.
 - [16] M.L. Latash, and J.G. Anson, "Synergies in health and disease: relations to adaptive changes in motor coordination," *Physical Therapy*, vol.86, no.8, pp.1151-1160, 2006.
 - [17] 入江文平, 川人光男, "多層パーセプトロンによる内部表現の獲得," *電子情報通信学会誌*, vol.73, no.8, pp.1173-1178, 1990.
 - [18] 多谷浩嗣, 中村仁彦, "ヒューマノイドロボットの運動パターンの縮約とそれに基づく運動生成," 第 16 回人工知能学会全国大会論文集, vol.16, pp.1D1.01.1-1D1.01.3, 2002.
 - [19] 神原裕行, 金載杰, 佐藤誠, 小池康晴, "強化学習とフィードバック誤差学習を用いた腕の姿勢制御," *電子情報通信学会論文誌*, vol.89, no.5, pp.1036-1048, 2006.
 - [20] R. Sutton, and A. Barto, *強化学習* (訳:三上貞芳, 皆川雅章), 森北出版株式会社, 2000.
 - [21] J. Moody, and C. Darken, "Fast learning in networks of locally-tuned processing unit," *Neural Comp*, vol.1, pp.281-294, 1989.
 - [22] E. Todorov, and M.I. Jordan, "Optimal feedback control as a theory of motor coordination," *nature neuroscience*, vol.5, no.11, pp.1226-1235, 2002.
 - [23] 有本卓, 関本昌紘, "巧みさ"とロボットの力学, *毎日コミュニケーションズ*, 2008.