

筋骨格モデルにおけるモジュールを用いた 異なる姿勢への適応能力の効果

The Effect of Using Modules on Adaptation to a Different Posture in the Musculoskeletal Model

○ 福西彬仁*, 沓澤京*, 大脇大*, 林部充宏*

○ Akito Fukunishi*, Kyo Kutsuzawa*, Dai Owaki*, Mitsuhiro Hayashibe*

*東北大学 工学研究科

*Tohoku University, Graduate School of Engineering

キーワード： 筋骨格モデル (Musculoskeletal model), 運動学習 (Motor adaptation),
筋シナジー (Muscle synergy), ニューラルネットワーク (Neural network)

連絡先： 〒 980-8579 仙台市青葉区荒巻字青葉 6-6-01 東北大学 工学研究科 林部・沓澤/大脇研究室
福西彬仁, Tel.: (022)795-5682, E-mail: akito.fukunishi.r4@dc.tohoku.ac.jp

1. 緒言

ヒトの筋骨格系には多くの冗長性が備わっている。例えば、関節数は一般に作業空間の自由度よりも多く、動作計画において複数通りの解をもたらす。さらに、単一の関節を駆動する際には複数の筋肉が関与する。この冗長性は柔軟な運動生成や身体の故障に対する補償を可能にする一方で、計算上の不良設定性をもたらすため、身体制御を著しく困難にする一面を持つ。しかし、我々の中枢神経系 (Central Nervous System; CNS) は何らかの制御方策を採用する事でこの冗長性に対処し、迅速かつ巧みに環境や身体の変化に適応して、都度適切な制御を提供している。

現在、CNS が採用していると思われる、先述の不良設定問題を克服するような制御方策の全貌は明らかになってはいない。しかし、近年そう

いった制御方策の一仮説として、「シナジー」[1] が有力視されている。シナジーとは、脊椎動物の諸動作に見られる関節軌道の協調から着想を得たもので、CNS が関節、或いはそれらを駆動する筋制御を計画する段階で制御の自由度を実際のものより低次元のものへと落とし込む制御モジュールであり、様々な運動をそれらの組み合わせで形作る機能的制御単位である。この内、後者の筋制御における低次の制御構造は「筋シナジー」と呼ばれ、実際に CNS が採用している制御戦略として生理学的にも支持を集めつつある [2,3]。

運動学習や身体制御における筋シナジーの性質はこれまで多くの生理学的な実験やシミュレーションを通して調べられてきた [15-17]。しかし、これらの研究群の中で、運動学習に対して筋シナジーの低次性という側面 (「モジュラリ

ティ」)が果たす効果を調べた研究は少ない。この命題を調べた研究としては、Hagioの研究[4]やBornoの研究[5]等がある。Hagioは神経回路を模したニューラルネットワークと線形な筋骨格モデルを用いて、筋シナジーに相当するモジュールが視覚運動変換に対する適応を促進させる事を示した。一方、Bornoは進化戦略と非線形な筋骨格モデルを用いて、特定の動作で獲得したモジュールが異なる動作スキルの学習時にも精度を落とすことなく転用できる事を示した。しかし、これまで、姿勢に対して非線形に変化する筋骨格力学において、既知の姿勢とは異なる姿勢で運動を行おうとする際に、低次の制御構造がどのように影響を与えるのかを調べられていない。

そこで本研究は、神経回路を模したニューラルネットワークと非線形筋骨格力学から成る運動学習モデルを用いて、未知環境における運動学習タスクを設計し、モジュールを用いた低次制御がどのような影響を与えるのかを調べる。尚、ここでは運動学習モデルにとっての未知の環境を、ニューラルネットワークの学習に用いたものとは異なる姿勢での筋骨格力学として設計し、この元で運動学習における精度と学習速度への効果を検討する。

2. 運動学習モデル

本節では、本研究で用いる運動学習モデルについて説明する。運動学習モデルは神経系を模したニューラルネットワークと筋骨格モデルとの2つの要素から構成される。ニューラルネットワークは、運動前野層や一次運動野層といった上位運動ニューロンから、脊髄前角の下位運動ニューロンにかけて筋励起信号を伝達する神経回路である皮質脊髄路までをモデル化したものである。筋骨格モデルは、下位運動ニューロンから筋肉へ伝達される励起信号に従って等尺

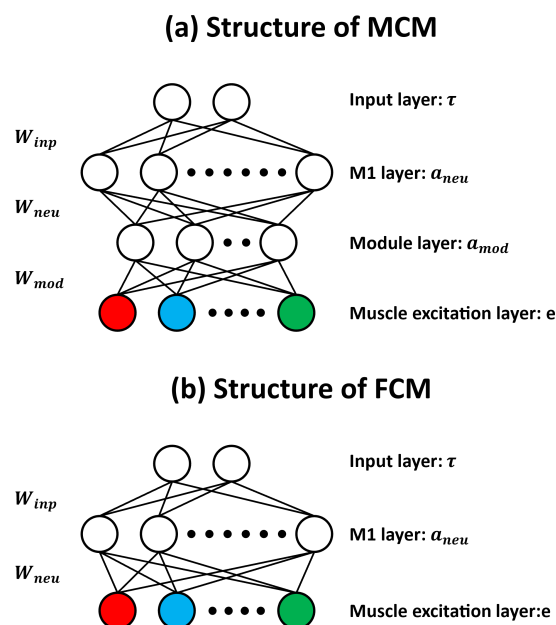


Fig. 1 ネットワークの構造:(a)MCM、(b)FCM

性の筋力を計算し、各関節トルクを出力する。この節では、この運動学習モデルをニューラルネットワークと筋骨格力学の2つに分けて説明する。

2.1 多層ニューラルネットワーク

本研究では、先行研究[4,7-9]と同じようにして、フィードフォワードニューラルネットワークによってCNSによる運動生成過程をモデル化する。本研究の興味は、低次の制御構造が運動学習にどのような効果をもたらすかであるため、ここではネットワークには筋シナジーを中継して低次に筋肉を制御するモジュール制御モデル (Modular Control Model; MCM) と、比較用のベンチマークとして筋シナジーを中継せずに個別に筋肉を制御する全次元制御モデル (Full-dimensional Control Model; FCM) の2種のネットワーク (Fig. 1) の2種を用意した。

MCM及びFCMの一次運動野層 (Primary Motor Cortex; M1) は前運動野層 (PreMotor Cortex; PMC) より目標の運動 (教師データ) の入力を受け、運動に必要な制御信号を計算し、学

習を通じて変化しない M1 より下位の神経回路を経て筋肉を励起する。ここで、PMC より指示される目標の運動の次数を N_{dim} 、目標の運動を $\tau \in \mathbb{R}^{N_{dim}}$ 、M1 層のニューロン数を N_{neu} 、PMC から M1 への重みを $W_{inp} \in \mathbb{R}^{N_{neu} \times N_{dim}}$ とそれぞれ置くと、M1 の制御信号 $a_{neu} \in \mathbb{R}^{N_{neu}}$ は次のように表される (式 1)。

$$a_{neu} = W_{inp}\tau \quad (1)$$

制御信号は神経回路を下降する中で変調し、FCM であれば運動神経へ、MCM であれば筋シナジーに相当する脊髄介在ニューロン [2,3] へと投射され、筋肉の運動ニューロンへ励起信号を与える。運動学習モデルに組み込む筋肉の数を N_{mus} とすると、FCM の筋肉の励起信号 e については次のようにして計算される (式 2)。

$$e = [W_{neu}a_{neu}]_+ \quad (2)$$

一方、MCM の筋肉の励起信号は、筋シナジーによる筋肉の励起行列を $W_{mod} \in \mathbb{R}^{N_{neu} \times N_{mod}}$ と置くと、次のようにして計算される (式 3)。

$$e = [W_{mod}W_{neu}a_{neu}]_+ \quad (3)$$

尚、式 (2-3) における $[\cdot]_+$ は任意の行列 X の成分 $X_{i,j}$ について、 $[X_{i,j}]_+ = X_{i,j} : X_{i,j} \geq 0$, $[X_{i,j}]_+ = 0 : X_{i,j} < 0$ とするような非負値の拘束を与えるオペレータである。

2.2 筋骨格力学

筋骨格モデルは骨格の形状、骨格上の筋肉の走行といった筋骨格ジオメトリと筋肉の力学モデルから構成され、本研究では運動学習に組み込む筋骨格力学を、Saul 等が提案した筋骨格モデル [10] を筋骨格シミュレーションソフトの OpenSim [11] から抽出して使用する。

筋骨格モデルに実装されている筋肉モデル [12] は基本的な Hill タイプの筋肉モデルの一つであ

り、筋肉の力学は腱に対して ψ [rad] 傾いて並ぶ筋肉の 2 つの力学的成分から記述される。1 つは制御信号に従って能動的に収縮する成分と、もう 1 つは筋肉が延ばされた際に復元力を発揮するような受動収縮成分である。筋肉とそれに接続する腱が平衡状態にある時、筋肉が発揮する力の余弦成分は腱の力、即ち骨格を駆動する力と等しくなるため、筋力の計算と各関節に対するモーメントアームが求まる事によって、単一の筋肉によってかかる関節トルクを求める事が出来る。

本研究では、単一の筋肉の発揮する力の計算 f^M [N] は以下のようにして計算する。

Hill 筋肉モデルの力学は一般に次式 (4-5) で与えられる [13]。

$$f^M = f_{iso}(f^{CE} + f^{PE}) \quad (4)$$

$$f^{CE} = a(t)f_l(l^M)f_v(v^M) \quad (5)$$

式 (4) 中 f_{iso} は注目する筋肉の等尺性随意最大筋力である。また、式 4-5 における f^{PE} は筋肉の受動成分であり、 f^{CE} は筋肉の能動収縮成分である。 f^{CE} は一般に、筋肉の活性値 $a(t)$ 、正規化筋繊維長 l^M と、線維長依存の力の関係を記述する force-length relationship 関数 $f_l(l^M)$ と正規化筋繊維伸縮速度 v^M と伸縮速度依存の力の $f_v(v^M)$ の積で与えられるが、本研究では等尺性の運動タスクであることから十分な時間が経過し、筋肉と腱が十分に平衡状態に達した時; $v^M \rightarrow 0$ を仮定し、force-velocity relationship は $f_v(v^M) \rightarrow 1$ [14] として処理した。同様に、十分な時間が経過した時、任意の筋肉 k の活性値 $a_k(t)$ は励起値 e_k に収束するので、一般に式 (5) は次のように簡略化される (式 (6))。

$$f^{CE} = e f_l(l^M) \quad (6)$$

また、 f^{PE} , $f_l(l^M)$ は、OpenSim では正規化筋繊維長 l^M の陽関数で与えられており、3 次スプライ

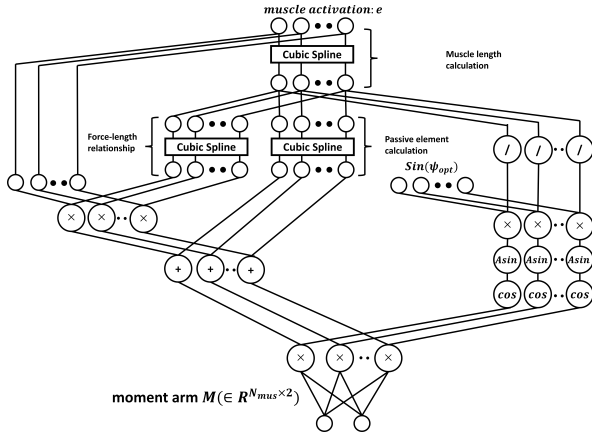


Fig. 2 筋骨格力学の実装図

ン補間で与えられている。しかし、 l^M は Open-Sim では筋骨格のジオメトリ及び筋肉活性値 $a(t)$ によって数値的に求められており、解析的に求める事が難しいため、本研究では f^{PE} , $f_l(l^M)$ のように、筋肉の筋起値 e に対する 3 次スプライン補間で近似して与えた。以上によって、地層的な等尺性タスクにおける筋力の計算を行う。

骨格に働く力 f^{MT} は、以上のようにして求めた筋力の余弦成分である (式 (7-8))。

$$f^{MT} = f^M \cos(\psi(l^M)) \quad (7)$$

$$\psi(l^M) = \cos(Asin(sin(\psi_{opt})/l^M)) \quad (8)$$

尚、式 (8) 中 ψ_{opt} は筋肉の最適羽状角である。

以上のようにして求まる筋肉の骨格の駆動力 f^{MT} を全ての筋肉について計算し、それを格納した骨格駆動力ベクトル $F^{MT} = (f_1^{MT}, f_2^{MT}, \dots, f_{N_{mus}}^{MT})^T \in \mathbb{R}^{N_{mus}}$ は筋骨格ジオメトリから得られるモーメントアーム行列 $M \in \mathbb{R}^{N_{dim} \times N_{mus}}$ と積算されることで出力関節トルク T となる (式 (9))。

$$T = MF^{FT} \quad (9)$$

尚、 T はここでは行列の転置を表す記号である。以上の計算過程は 2 節で説明したネットワークが取り扱えるように行列計算として表現され、運動学習モデル内に実装される (Fig.2)。

3. 実験方法

本節では、まず 2 節で説明した運動学習モデルにおける学習器であるニューラルネットワークの設定 (最適化手法、及び教師データの与え方、ネットワークのコスト) について説明する。次に、運動学習モデルにおける学習対象である筋骨格力学の与え方について説明する。

3.1 ニューラルネットワークの設定

本研究では、肩関節の伸展・屈曲及び肘関節の伸展・屈曲から成る上肢の 2 自由度等尺性運動タスク ($N_{dim} = 2$) を設計し、その下で、ネットワークへの教師データ (運動タスク) は $\tau_{data} = (\cos(\theta^{(i)}), \sin(\theta^{(i)}))^T \in \mathbb{R}^{N_{dim}}, \{\theta^{(i)}\} = \{0, 30, 60, \dots, 330\}[\text{deg}]$ より (Fig.3.(a)) 一様確率の下でランダムに選択して与える。また、教師データに対する過剰適合性を調べるため、ここではテストデータも用意した。テストデータは $\tau_{test} = (\cos(\theta^{(i)}), \sin(\theta^{(i)}))^T \in \mathbb{R}^{N_{dim}}, \{\theta^{(i)}\} = \{0, 15, 45, \dots, 345\}[\text{deg}]$ で与える (Fig.3.(b))。

ここでは、ネットワークの性能は学習終了時の教師データ或いはテストデータに対する損失関数 L の値と、教師データの学習に伴う L の減少過程の近似式によって定義される学習速度で評価した。

損失関数はデータと運動学習モデルの出力に関する二乗和誤差で与えられ、例えば教師データに対する損失関数は、教師データ数 N_{data} を用いて次式で表される (式 (10))。

$$L := \frac{1}{2N_{data}} \sum_{i=1}^{N_{data}} t(T^{(i)} - \tau^{(i)})(T^{(i)} - \tau^{(i)}) \quad (10)$$

以上の損失関数を用いて、ネットワークは確率的勾配法及び weight decay によって最適化される。即ち、 n 回目の学習試行における PMC-M1 間の重みを $W_{inp}^{(n)}$ とすると、 $n + 1$ 回目の学習




Fig. 3 (a) 教師データ、(b) テストデータ

試行において、重み $W_{inp}^{(n+1)}$ は次式(式(11))によって更新される。

$$W_{inp}^{(n+1)} = W_{inp}^{(n)} - \alpha_{inp} \frac{\partial L}{\partial W_{inp}^{(n)}} - \beta_{inp} W_{inp}^{(n)} \quad (11)$$

ここで、式中 α_{inp} 、 β_{inp} はそれぞれ順にネットワークの学習率と減衰率であり、本研究では $\alpha_{inp} = 2$ 、 $\beta_{inp} = 10^{-5}$ として与えた。

学習速度は、ネットワークの最大学習試行回数を n_{max} とし、試行回数の系列を $n = (1, 2, 3, \dots, n_{max})$ とした時の n に対する損失関数 L の系列 $l = (L^{(1)}, L^{(2)}, L^{(3)}, \dots, L^{(n_{max})})$ に対して、次の式(式(12)) [9] で近似を行い、その内 b の値で与えるものとした。

$$l \simeq a * \exp(-bn) + c \quad (12)$$

また、ネットワークのコスト C は、ここではネットワークが教師データにおける N_{data} 種の運動を達成するために伝達する筋筋起量の総和 (motor cost) で評価し、次式で与える (式(13))。

$$C = \frac{1}{N_{data}} \sum_{i=1}^{N_{data}} \sum_{j=1}^{N_{mus}} (e(\tau^{(i)})_j)^2 \quad (13)$$




Fig. 4 学習姿勢: (a) θ^{pre} 、(b) θ^{learn}

3.2 学習対象の筋骨格力学

2節で説明した筋骨格力学において、筋繊維長 l^M 及び筋肉のモーメントアーム行列 M は姿勢によって変化する。そのため、異なる2つの姿勢において、それらの筋骨格力学もまた互いに異なる。この下で、本研究の興味は、既知の姿勢とは異なる姿勢の運動学習において、モジュールが学習にどのように影響を及ぼすのかにあるため、ここでは二つの姿勢を用意する。

一つはモジュールを用意するためのものであり、FCMのみが学習する。この姿勢は筋骨格モデルにおいて肩部水平屈曲角 $\phi_{SF} = 30[\text{deg}]$ 、肩部水平外転角 $\phi_{SA} = 90[\text{deg}]$ 、肩部内旋角 $\phi_{SF} = 12[\text{deg}]$ 、肘部屈曲角 $\phi_{EF} = 80[\text{deg}]$ で規定されるものであり、本論文では以降 Φ^{pre} と呼称する (Fig.4.(a))。モジュールは、FCM による Φ^{pre} の学習において、学習終了 ($n = n_{max}$) から過去 100 試行分の筋筋起値の系列データ $E = (e^{(n_{max}-99)}, e^{(n_{max}-98)}, \dots, e^{n_{max}}) \in \mathbb{R}^{N_{mus} \times 100}$ に対して非負値行列因子分解を用いて抽出した [18]。尚、筋シナジー数は VAF (; Variance Accounted For) が 0.95 以上となるような最小の数で決定した。VAF は次の式(14-15) で与えられる。

$$VAF = 1 - \frac{\sum_{i=1}^{N_{mus}} \sum_{j=(n_{max}-99)}^{n_{max}} g_{i,j}^2}{\sum_{i=1}^{N_{mus}} \sum_{j=(n_{max}-99)}^{n_{max}} E_{i,j}^2} \quad (14)$$

$$g = WH - E \quad (15)$$

尚、式(15)中 $W \in \mathbb{R}^{N_{mus} \times N_{mod}}$ 、 $H \in \mathbb{R}^{N_{mod} \times 100}$ はそれぞれ E に非負値行列因子分解を用いる事

で得られる、筋シナジー成分、或いは試行系列における筋シナジの制御行列である。

もう一つの姿勢はFCMとMCMで学習パフォーマンスに関する比較を行うためのものであり、筋骨格モデルにおいて肩部水平屈曲角 $\phi_{SF} = 30[\text{deg}]$ 、肩部水平外転角 $\phi_{SA} = 60[\text{deg}]$ 、肩部内旋角 $\phi_{SF} = 0[\text{deg}]$ 、肘部屈曲角 $\phi_{EF} = 60[\text{deg}]$ で規定される。以降、この姿勢を Φ^{learn} と呼称する (Fig.4.(b))。

また、以上の二姿勢の学習について、運動学習には肩関節及び肘関節の運動に強く関連する22個の筋肉(三角筋1-3、棘上筋、棘下筋、肩甲下筋、小円筋、大円筋、大胸筋1-3、広背筋1-3、烏口腕筋、上腕三頭筋、上腕二頭筋長頭・短頭、上腕三頭筋外側頭、上腕三頭筋中頭、上腕筋、腕橈骨筋)を組み込んだ。

4. 学習結果

この節では3節で述べた実験設定の下で運動学習を行った結果を示す。運動学習は Φ^{pre} 、 Φ^{learn} 共に学習試行を1万回として、これを15セット行い、統計的検定にはbootstrap検定をリサンプリング数を2000として行った。以下では、まず、FCMによる θ^{pre} とモジュールの抽出に関する結果を示し、その後 θ^{learn} の学習におけるFCMとMCMの比較結果を示す。

4.1 θ^{pre} の学習とモジュールの抽出

Φ^{pre} のFCMによる学習結果は (Fig.5) に示すとおりである。Fig.5.(a)において、赤の実線は学習に伴う教師データに対するFCMの損失関数の減少過程を、青の実線は学習に伴うテストデータに対するFCMの損失関数の減少過程をそれぞれ15セットの平均で示したものである。また、実線周りのシェードはそれぞれの標準偏差をそれぞれ示している。学習終了時、即ち

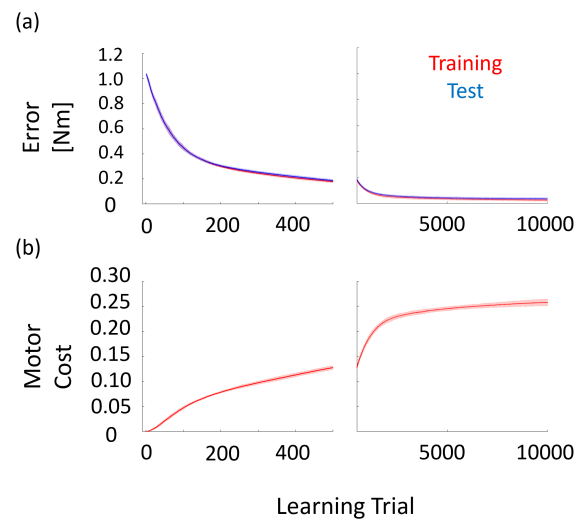


Fig. 5 FCMによる θ^{pre} の学習結果: (a) テストデータ及び教師データに対する損失、(b) 運動コスト

$n = n_{max} = 10000$ の時、教師データに対する損失は教師データに対して $(2.70 \pm 0.90) \times 10^{-2}$ 、テストデータに対する損失は $(3.71 \pm 0.85) \times 10^{-2}$ であり、両者で有意差が認められた ($p < 0.05$)。以上の事から、FCMによる θ^{pre} の学習には、教師データに対する過剰適合の傾向があると言える。

モジュールの抽出に用いるデータの開始地点である $n = n_{max} - 99$ における損失は、教師データに対しては $(2.71 \pm 0.88) \times 10^{-2}$ 、テストデータに対しては $(3.67 \pm 0.83) \times 10^{-2}$ であり、教師データ、テストデータそれぞれに対してデータ抽出開始点とデータ抽出終了点に有意差はみられなかった ($p = 0.49, p = 0.47$)。運動コスト (Fig.5.(b)) についても、 $n = n_{max} - 99$ と $n = n_{max}$ でそれぞれ順に、 $(2.58 \pm 0.07) \times 10^{-1}$ 、 $(2.58 \pm 0.07) \times 10^{-1}$ で有意差は認められなかった ($p = 0.45$)。以上の事から、モジュールの抽出に用いる運動学習の系列は精度、及び運動コストの観点で十分に収束していると言える。

以上のネットワークによる運動学習の系列に非負値行列因子分解を施し、計算された VAF

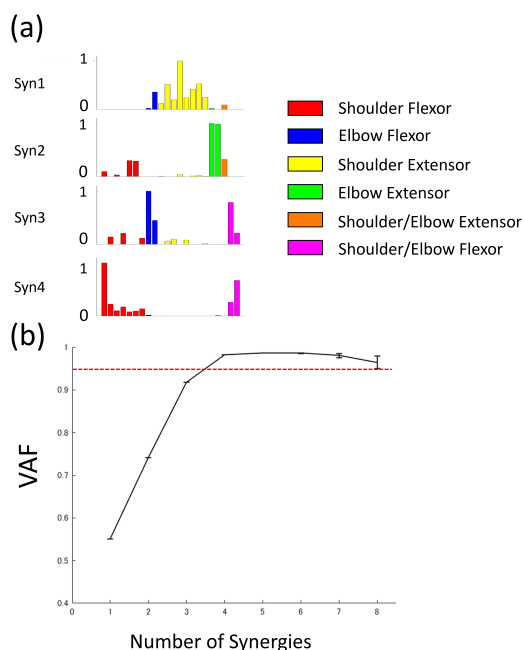


Fig. 6 筋シナジーの抽出: (a) 筋シナジー成分、(b) 筋シナジー数と VAF

は Fig.6.(b) に示す通りである。図に示されている通り、本実験より抽出された筋シナジーの数は4つであり、この時の筋シナジーの成分は (Fig.6.(a)) に示す。図中において、赤で示された筋肉は肩関節の屈曲、青で示された筋肉は肘関節の屈曲、黄で示された筋肉は肩関節の伸展、緑で示された筋肉は肘関節の伸展、オレンジで示された筋肉は肩関節及び肘関節の伸展、紫で示された筋肉は肩関節及び肘関節の屈曲の働きをそれぞれ持つ。

4.2 θ^{learn} の学習と FCM と MCM の比較

FCM 及び MCM による θ^{learn} の学習結果は Fig.7 に示される。Fig.7.(a) は θ^{learn} の教師データに対する損失関数の減衰過程を示しており、図中の赤の実線とシェードは FCM の平均と標準偏差、青の実線とシェードは MCM の平均と標準偏差を示している。学習終了時の教師データに対する損失は、FCM は $(1.56 \pm 0.33) \times 10^{-2}$ で、MCM は $(1.11 \pm 0.27) \times 10^{-1}$ であり、FCM

が有意に高精度で学習を行えていることが認められた ($p < 0.05$)。テストデータに対する損失についても、FCM は $(2.01 \pm 0.45) \times 10^{-2}$ で、MCM は $(1.13 \pm 0.05) \times 10^{-1}$ であり、FCM が有意に高精度であった ($p < 0.05$)。これに合わせて、テストデータと教師データの損失値に関して、FCM では有意にテストデータに対する損失が大きかった ($p < 0.05$) 一方で、MCM では有意な差が認められなかった ($p = 5.95 \times 10^{-2}$)。運動コストについては Fig.7.(b) に示される。学習終了時 ($n = n_{max}$) の FCM の運動コストは $(2.60 \pm 0.02) \times 10^{-1}$ 、MCM の運動コストは $(3.36 \pm 0.08) \times 10^{-1}$ であり、有意に FCM が MCM よりも運動コストの観点で優れる事が認められた ($p < 0.05$)。一方、学習速度 (Fig.7.(c)) に関しては、MCM が FCM よりも有意に高速である事が認められた ($p < 0.05$)。以上の事から、MCM は FCM と比べて、過剰適合の程度が低い (汎化性が高い) 事、学習精度及び運動コストで劣る事、学習速度で優れる事がわかる。

5. 考察及び今後の展望

今回の実験からは、MCM が学習速度や汎化性の観点で FCM より優れる一方で、運動生成に関する精度や運動コストの観点で劣る性質が確認された。学習速度については、他運動学習タスクにおけるモジュールの効果を調べた先行研究 [4,5] と同様の結果が得られた一方、運動生成の精度や運動コストに関する劣化はそれらの研究と一致しなかった。これは、学習対象のタスクが異なるという事の他に、先行研究との運動学習モデルにおける相違が主原因だと思われる。本研究の運動学習モデルで組み込んだ Hill タイプの筋肉モデルでは、式 (4-5) に見られるように、筋力の計算が能動的な収縮成分にネットワークの出力を陽に含まない筋肉の受動成分が線形加算して行われる。本研究と同じように等

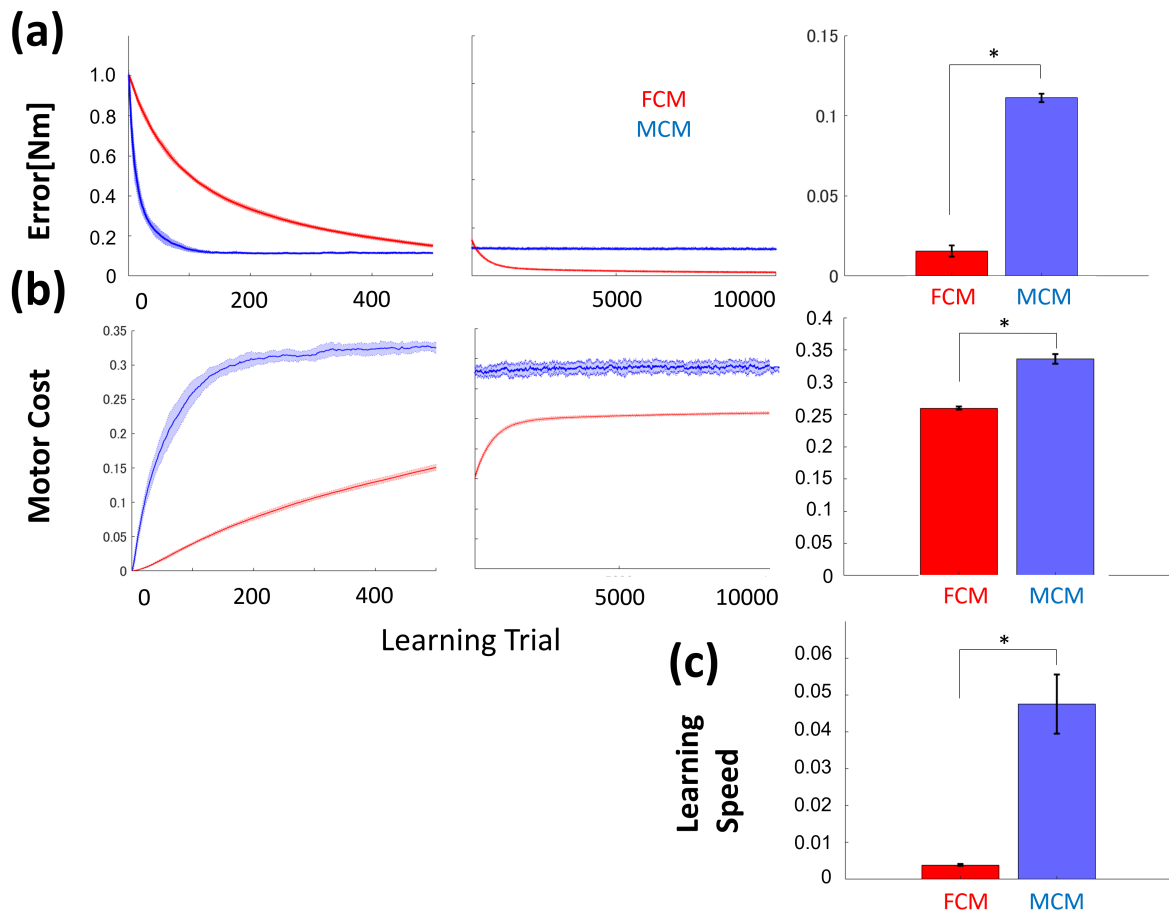


Fig. 7 FCM と MCM の比較: (a) 教師データに対する損失、(b) 運動コスト、(c) 学習速度

尺性運動を組み込んだ先行研究 (Hagio) ではこの受動成分は除外して、 e に関する線形関数として筋骨格力学をモデル化していたため、ネットワークが行うのは線形関数の非線形回帰であり、MCM が十分な次数のモジュールを持っていれば、FCM と同等の精度で学習が行える。一方、本研究で運動学習モデルに組み込んだように、実際の人の筋骨格力学に近い筋モデルでは、 e に関する非線形性、及び受動成分の線形加算が筋骨格力学に含められると、ネットワークが行うのは2つの非線形関数の非線形回帰となり、十分な数のモジュールが無ければ FCM と同等の精度で学習を行うのは難しくなる。また、運動コストについてもやはり運動学習モデルの相違が主原因と考えられる。所望の運動精度を達

成した後、FCM では式 (11) における偏微分は常に0となり、 W_{inp} の weight decay による L1 ノルム減衰作用が働く事で結果的に運動コストは最小化され、収束する。しかし、MCM では、先述の回帰困難性に因る残差が生じ、式 (11) における偏微分項が0にならず、 W_{inp} は収束しない。そのため、weight decay によるノルムの最小化も十分に機能せず、而して運動コストは常に振動して小さくならない (Fig.7.(b))。故に、今後の研究では、今回行わなかったモジュールの数による学習精度への影響の調査や、生理学的な観点から運動学習モデルを再検討してゆく事が必要であると考えられる。その下で、もう一度実験を行い、改めてモジュールの効果を調べる事が当面の目標である。

6. 結言

本研究は、姿勢変化に伴う筋骨格力学変化への適応学習において、筋シナジーによる低次のモジュール制御が学習にどのような影響をもたらすのかを調べるものであった。そのために、ここでは筋骨格モデル及びニューラルネットワークから成る等尺性の運動学習モデルを用いて、異なる姿勢の運動学習における制御の低次化の効果をモジュール制御と非モジュール制御の比較から検討した。その結果、モジュールによる低次制御は汎化や学習速度の観点で非モジュール制御よりも優れる一方で、学習精度と運動コストの観点では非モジュール制御に劣る事が確認された。

この結果は先行研究の報告と一部異なる点があるため、今後は運動学習モデルの再検討とモジュール数の比較を交えつつ、モジュールによる低次制御の効果を引き続き調べる事であると考えられる。

参考文献

- 1) N. Bernstein: Chapter II The Problem of the Interrelation of Co-Ordination and Localization, Human Motor Actions Bernstein Reassessed, pp.77-119, Elsevier, 1984.
- 2) CB. Hart and SF Giszter: A neural basis for motor primitives in the spinal cord, J. Neurosci., **30**-4, 1322/1336 (2010)
- 3) T. Takei, J. Condais, S. Tomatsu, and T. Oya, K. Seki: Neural basis for hand muscle synergies in the primate spinal cord, Proc Natl Acad Sci U S A, **114**-32, 8643/8648 (2017)
- 4) S. Hagio and M. Kouzaki: Modularity speeds up motor learning by overcoming mechanical bias in musculoskeletal geometry, J R Soc Interface, **15**-147 (2018)
- 5) MA. Borno, JL. Hicks and SL. Delp: The effects of motor modularity on performance, learning and generalizability in upper-extremity reaching: a computational analysis, J R Soc Interface, **17**-167 (2020)
- 6) M. Yoshizaki, H. Takeshita, M. Ohsawa and Y. Saki: A frequency domain hypothesis for human postural control characteristics, IEEE Eng. in Med. and Biol. Magazine, **11**-4, 60/63 (1992)
- 7) U.Rokni, AG. Richardson, E. Bizzi and HS. Seung: Motor learning with unstable neural representations, Neuron., **54**-4, 653/666 (2007)
- 8) M. Hirashima and D. Nozaki: Learning with slight forgetting optimizes sensorimotor transformation in redundant motor systems, PLoS Comput. Biol., **8** e1002590 (2012)
- 9) K. Takiyama and M. Okada: Maximization of learning speed in the motor cortex due to neuronal redundancy, PLoS Comput. Biol., **8** e1002348 (2012)
- 10) KR. Saul, X. Hu, CM. Goehler, ME. Vidt, M. Daly, A. Velisar and WM Murray: Benchmarking of dynamic simulation predictions in two software platforms using an upper limb musculoskeletal model, Comput Methods Biomech Engin., **18**-13, 1445/1458 (2015)

- 11) SL. Delp, FC. Anderson, AS. Arnold, P. Loan, A. Habib, E. Guendelman and DG. Thelen: OpenSim: open-source software to create and analyze dynamic simulations of movement, *IEEE Trans Biomed Eng.*, **54**-11, 1940/1950 (2007)
- 12) LM. Schutte, MM. Rodgers, FE. Zajac and RM. Glaser: Improving the efficacy of electrical stimulation-induced leg cycle ergometry: an analysis based on a dynamic musculoskeletal model, *IEEE Trans Rehab Eng.*, **1**, 109/125 (1993)
- 13) FE. Zajac: Muscle and tendon: Properties, models, scaling and applications to biomechanics and motor control, *Crit Rev Biomed Eng.*, **17**, 359/411 (1989)
- 14) JM. Winters: An Improved Muscle-Reflex Actuator for Use in Neuromusculoskeletal Models, *Ann Biomed Eng.*, **23**, 359/379 (1995)
- 15) Y. Song, M. Hirashima and T. Takei: Neural network models for spinal implementation of muscle synergies, *Front. Neurosci.*, **16** (2022)
- 16) DJ. Berger, R. Genter, T. Edmunds, DK. Pai and A. d'Avella: Difference in adaptation rates after virtual surgeries provide direct evidence for modularity, *J Neurosci.*, **33**-30, 12384/12394 (2013)
- 17) VCK. Cheung, BMF. Cheung, JH. Zhang, ZYS. Chan, SCW. Ha, CY. Chen, RTH. Cheung: Plasticity of muscle synergies through fractionation and merging during development and training of human runners, *Nat Commun.*, **11**-1, 4356 (2020)
- 18) M. Hirashima, T. Oya: How does the brain solve muscle redundancy? Filling the gap between optimization and muscle synergy hypotheses, *Neurosci Res.*, **104**, 80/87 (2016)