

運動内部モデルのフィードフォワード切り替え現象の認証

Recognition of Feedforward Change of Motor Internal Model

林 勲

Isao Hayashi

関西大学大学院

Kansai University

北 彩香

Sayaka Kita

潮技術コンサルタント

Ushio Consultants

荻野 正樹

Masaki Ogino

関西大学

Kansai University

Abstract In the study of the computational neural networks on learning and skill acquisition of the motion functions, MOSAIC model using the internal model proposed by Kawato is useful. The internal model based on the control model of Allen-Tsukahara is able to express physical motion by associativity of the feedback control and the feedforward control. In this paper, we give a subject a task that he/she should push a number of the button to be equal to a computer screen in order to confirm a change function between the feedback control and the feedforward control of the internal model. If the repetition motion is given to the subject several times, the feedforward control comes up conspicuously, and the ratio of the feedforward control for the feedback control rises. We discuss here the movement, the response time, and the electroencephalographic signal in this repetition control of vision-motion task. We also discuss a MOSAIC model using the neural network from the results of vision-motion task.

1. はじめに

最近、運動の学習やスキルの獲得に関する研究が活発に議論されている [1-3]。動作の学習法や制御の効率化の議論はスキルの知識化での重要なテーマの一つといえる。特に、運動の機能構造化のモデルでは、川人らが提案した内部モデル [1] や MOSAIC モデル [2] が有用である。内部モデルは Allen-Tsukahara の制御モデルを核とした計算論的神経回路モデルであり、運動指令の入力と動作軌道の出力からなる順モデルと目標軌道と誤差信号の入力と運動司令の出力からなる逆モデルから構成される。運動の開始時は、順モデルの感覚フィードバックだけで駆動し動作はなめらかではないが、逆モデルが目標軌道と運動軌道との差を誤差信号として認識しフィードフォワード経路により調整することで正確な制御が可能となる。MOSAIC モデルは、内部モデルの切り替えを構造化した計算モデルである。責任信号予測器と尤度モデルによって内部モデルの貢献度が決定され、環境が変化する場合でも、トップダウン信号とボトムアップ信号を用いて適切な内部モデルを選択してなめらかな運動が可能となる。

本論文では、内部モデルや MOSAIC モデルにおける順モデルのフィードバック制御と逆モデルのフィードフォワード制御を議論するため、視覚・運動課題での被験者の動作とその反応時間、脳波を観測し、フィードバック制御とフィードフォワード制御の特徴から MOSAIC モデルの構造化を議論する。実験では、被験者はコンピュータ画面に表示される番号を直視し、画面と合致するボタン番号を押す。画面上の番号は、一定回数の反復パターンと乱数による非反復パターンの提示からなる。反復パターンが複数回提示されるならば、フィードバック制御だけでなくフィードフォワード制御の比率が高くな

る。この状況で、反復パターン提示の直後に異なる番号の非反復パターンを与えると、そのフィードフォワード制御の特徴が顕著に現れる。また、これらの議論は動作センサによる被験者の上腕の動きや脳波計測からも支持できる。ここでは、被験者への数字パターンの提示とその反応時間、動作軌跡、脳波に注目して、これらの関連性について議論し、考察を通じて MOSAIC モデルの一つの可能性について議論する。

2. 内部モデル

川人は、Allen-Tsukahara の制御モデルを内部モデルとして提案した。図 1 に内部モデルの概要を示す。運動指令が与えられると、運動の目標軌道が運動野に伝達され、脊髄から筋骨格系へ伝えられる。小脳は、分子層、プルキンエ細胞層、顆粒層の 3 層構造からなり、運動機能に関与している。目標軌道と運動軌道に差異が生じると、下オリーブ核から起始する登上繊維の誤差信号が下小脳脚を経て小脳プルキンエ細胞に伝達され、運動出力とタイミングを制御する。プルキンエ細胞は抑制性シナプスによりフィードバック経路を確保し、苔状繊維と登上繊維が小脳核の範囲を調整して小脳の運動機能を調整する。

プルキンエ細胞には平行線維入力と登上線維入力の 2 種類が存在し、随意運動の順モデルと逆モデルを学習する。この順モデルと逆モデルを内部モデルと呼んでいる。順モデルは運動指令を入力とし動作軌道を出力とする。逆モデルは平行線維入力を目標軌道、登上線維入力を誤差信号として、出力は運動司令である。誤差が大きい場合には、登上線維から誤差信号が入力され、誤差信号によりプルキンエ細胞のシナプスの伝達効率が変化して、小脳皮質で目標軌道を実現させる運動司令を実現する。

その結果、運動の開始時では、順モデルの感覚フィードバックだけでは動作はなめらかでないが、目標軌道と運動軌道との差を誤差信号として認識するフィードフォワード機能によって、逆モデルが誤差を調整し、なめらかで正確な制御が可能となる。




Fig. 1: Structure of Internal Model

一方、内部モデルの切り替えを構造化した計算モデルとして MOSAIC (Module Selection and Identification for Control) モデルがある。図 2 に MOSAIC モデルを示す。MOSAIC モデルは、内部モデルの切り替えが責任信号予測器と尤度モデルにより行われる。責任信号予測器は、環境情報から最も寄与度の高い順モデルを選択する。尤度モデルは、目標軌道と運動軌道との差異から順モデルと対になっている逆モデルの出力を増加させる。責任信号予測器による順モデルの選択は環境情報による事前情報としてのトップダウン信号であり、尤度モデルによる逆モデルの選択は事後に得られる感覚運動フィードバックや内部モデルの出力を利用したボトムアップ信号といえる。これらの機能により、環境情報が与えられた場合、責任信号予測器により運動開始前から予測的なモデル選択が可能である。環境情報が得られない場合には、感覚運動フィードバックのみを参照するのでモデルの切り替えは遅れる。この結果、尤度モデルのモデル選択も急激な環境変化に追従できない場合があり、学習は運動に伴い徐々に進行する。




Fig. 2: Structure of MOSAIC Model

3. 内部モデルと MOSAIC モデルにおけるフィードフォワードの認証

視覚・運動課題における繰り返し学習の実験を通して、内部モデルと MOSAIC モデルにおけるフィードフォワード信号の認証を行う。図 3 に実験の様子を示す。被験者は顎を顎乗せ台に固定し 61cm 前方のコンピュータ画面を直視する。また、前方に設置されたボタンスイッチの中から、画面に写し出される数字 (1, 2, 3) と合致するボタンを押す。中央のボタン (番号 2) は顎乗せ台から奥に 54cm, 左側に 17cm の位置に設置した。左ボタン (番号 1) は顎乗せ台から奥に 46cm, 中央のボタンから左側 27cm に設置し、右ボタン (番号 3) は同様に奥に 46cm, 中央のボタンから右側 27cm に設置した。



Fig. 3: experiment Environment




Fig. 4: Motion Sensor

被験者は 2 秒間のレストの後、画面中央の十字マークを注視し、その後、数字 (1, 2, 3) が反復パターンとして 2 秒間の繰り返し提示される間、その数字に合致するボタンを押す。反復パターンは 5 回繰り返され、反復パターンに連続して 3 回の別順序 (非反復パターン) の数字も表示される。非反復パターンは 8 種類 (反復パターンも含めて 8 種類) から任意に 3 回分を抽出する。この 5 回の反復パターンと 3 回の非反復パターンの組を提示パターンと呼ぶ。提示パターンは 3 回繰り返され 1 試行として構成する。実験では、3 試行目と 4 試行目の間に 10 分間の休憩を入れ、7 試行の計測を行った。被験者は、男性健常者 2 名 (年齢 20 代前半, 利き腕: 右), 女性健常者 3 名 (年齢 20 代前半, 利き腕: 右) の合計 5 名

とし、各被験者で 168 個のパターンに対して 504 回のボタンを押す動作を行う。各被験者の所要時間は約 40 分であった。

計測としては、被験者の合計 7 試行を実施中、被験者が画面の数字提示からボタンを押すまでの反応時間とその動作軌跡、及び、脳波の変化を記録した。解析では、反復パターン表示の際に内部モデルの逆モデルによるフィードフォワード経路の高まりが期待され、非反復パターン表示時に MOSAIC モデルの内部モデルの切り替えが反応時間として観測できる。

図 4 に無線動作センサの装着位置を示す。デバイスは無線動作センサ (TSND121, ATR-Promotions 社製、サンプリング周波数: $100Hz$) を用い、被験者の右腕上肢の 4 箇所 (右手の指、手首、肘、肩) の x, y, z の 3 軸の動作軌跡の加速度と角速度を計測した。また、多用途脳波計測装置 (AP216 PolymateII, TEAC 社製、サンプリング周波数: $200Hz$) を用いて、国際 10-20 法に準拠して F_{p1} , F_{p2} , C_1 , C_2 , C_z , P_z , O_1 , O_2 の 8 箇所の電極点での EEG を測定した。なお、スイッチボタン及び画面表示の制御には Java Processing と Arduino を使用し、AP216 と TSND121 の制御にはそれぞれ AP Monitor と Sensor Controller を用いた。

実験のプロセスを以下に示す。

- Step 1 被験者に実験同意書を配布し、内容を理解した上で同意書の該当項目の記入を依頼する。
- Step 2 被験者が椅子に着席した状態で顎を顎乗せ台に固定し、被験者の頭部の 8 箇所に EEG 測定電極を装着する。また、無線動作センサを利き腕 (右腕) の 4 箇所に装着する。
- Step 3 非反復パターンの提示順序を乱数で決定し、5 回の反復パターンと 3 回の非反復パターンの 3 回の提示パターンを 1 試行として 3 試行分の数字提示を行い、被験者が数字提示からボタンを押すまでの反応時間、動作センサの加速度と角速度、及び、EEG 脳波の変化を計測する。
- Step 4 10 分間の休憩後、残りの 4 試行での被験者の反応時間、加速度と角速度、及び、EEG 脳波の変化を計測する。
- Step 5 被験者にアンケートを配布し、記入後に回収して実験を終了する。

4. 計測結果

反応時間の一例として、被験者 H の 7 試行の結果を図 5～図 11 に示す。提示回数を横軸に表し、被験者が数字提示からボタンを押すまでの反応時間 (ms) を縦軸に示す。5 回の反復パターンと 3 回の非反復パターンの 3 回の提示パターンの反応時間が図示されている。反復パターンの反応時間を解析するため、回帰分析を行い反応時間の傾向を直線で推定した。

第 1 試行については、反復パターンの最初の数字提示 (提示番号「1」) に対する反応時間は、3 回分の提示パターンを比較しても差はない。一方、1 回目の提示パターンの回帰直線の傾きは 2 回目と 3 回目と比較して大きく、繰り返すことによって緩やかになっている。これは、反復パターンによる繰り返し提示により、内部モデルの




Fig. 5: Reaction Time of the 1st Display Pattern




Fig. 6: Reaction Time of the 2nd Display Pattern

フィードバック経路からフィードフォワード経路への切り替えが生じ、その結果、反応時間が短くなり、反応時間変化量も小さくなると考えられる。その他、反復パターン直後の非反復パターンに対する反応時間が遅い。例えば、最初の提示パターンの第 5 回目の反復パターン (1, 2, 3) の平均反応時間が $731ms$ であるのに対して、それに連続する非反復パターン a (1, 1, 2) の平均反応時間は $824ms$ と大きい。1 番目の数字 (番号「1」) は反復パターンの 1 番目の数字 (番号「1」) と同じであるため反応時間 $755ms$ と大差はないが、2 番目の数字 (2 番目の番号「1」) の反応時間は $950ms$ と極めて大きい。同様に、2 回目と 3 回目の提示パターンの第 5 回目の反復パターンの平均反応時間はそれぞれ $745ms$, $767ms$ であるのに対して、非反復パターンの平均反応時間はそれぞれ $789ms$, $848ms$ と大きい。これらは、MOSAIC モデルの内部モデルの切り替えが速やかに行われない現象を良く表していると思われる。

同様に、第 2 試行についても、それぞれの提示パターンの第 1 回目の反復パターンの最初の提示数字 (番号「1」) の反応時間は、反復を繰り返して徐々に低くなっている。また、反復パターンの回帰直線の傾きも繰り返




Fig. 7: Reaction Time of the 3rd Display Pattern




Fig. 9: Reaction Time of the 5th Display Pattern




Fig. 8: Reaction Time of the 4th Display Pattern




Fig. 10: Reaction Time of the 6th Display Pattern

しにより緩やかになっている。さらに、第5回目の反復パターン(1, 2, 3)の平均反応時間は688ms, 731ms, 740msであるのに対して、最初の非反復パターンの反応時間はそれぞれ693ms, 829ms, 763msと大きい。なお、1回目の非反復パターン(1, 3, 3)の平均反応時間がそう大きくないのは、提示された数字が比較的反復パターンと類似しているからと考えられる。

第3試行についても、反復パターンの反応時間は繰り返しによって低くなり、回帰直線の傾きも緩やかになっている。第4試行以降では、それぞれの反復パターンの反応時間は数字提示の繰り返しを重ねて全般的に低くなり、回帰直線の傾きも小さいことがわかる。特に、各試行の最初と2番目の反復パターンの傾きはほぼゼロであり、第4試行では正に転じている。さらに、第7試行では、3番目の反復パターンの傾きもなだらかになり、非反復パターンと大差はなくなっている。

反復パターンと非反復パターンの平均反応時間の推移を表1に示す。反復パターンの平均反応時間は試行回数を重ねて短くなり、特に、第4試行以降の2番目と3番目の反復パターンでは、反応時間が低くなっている。一方、非反復パターンでは、大きな差は認められない。

動作軌跡の一例として、被験者Hの第1試行の3回の提示パターンの指の動作センサ(S_1)のZ軸方向の角速度を図12～図14に示す。横軸に時間(ms)を示し、縦軸に角速度(dps)を示す。反復パターンは破線から左側に示され、非反復パターンは右側に示されている。図12は最初の提示パターンである。破線から右側の非反復パターンの最初の提示数字は(1, 1, 2)であり、最初の数字「1」は反復パターンと同じ「1」であるため、指がニュートラル位置からボタンスイッチ方向に移動する際、角速度が反復パターンと同じ正方向(反時計回り)になっていることがわかる。また、ボタンを押した後、元のニュートラル位置に戻る際にも指動作の角速度は反復パターンと同じ負方向(時計回り)に振れている。しかし、2番目の数字提示に対する反応動作では、動作開始時には反復パターンと混同し「2」と同様な負方向(時計回り)に動くが、数字が「1」であることに気づき、急に反転して大きく正方向(反時計回り)に回転している。この混乱は図13の2回目の提示パターンでは若干見られるものの、図14の3回目の提示パターンではほとんど見られず、被験者が繰り返し学習により間違いを修正していることがわかる。MOSAICモデルの内部モデル




Fig. 11: Reaction Time of the 7th Display Pattern




Fig. 12: Angular Velocity of the 1st Pattern of the 1st Trial

Table 1: Response Time

試行	反復パターン				非反復パターン			
	1	2	3	平均	1	2	3	平均
1	800.1	765.9	746.0	770.7	844.7	782.9	770.1	799.2
2	765.1	734.2	752.9	750.7	767.3	795.7	795.0	786.0
3	813.5	776.1	820.4	803.3	850.8	829.1	837.3	839.1
4	820.3	763.2	772.1	785.2	771.9	792.1	806.1	790.0
5	740.3	790.1	777.4	769.3	781.7	817.0	834.0	810.9
6	791.5	754.4	714.5	753.5	805.6	771.6	840.1	805.7
7	777.7	753.5	747.1	759.4	815.4	785.4	779.9	793.6
平均	786.9	762.5	761.5	770.3	805.3	796.3	808.9	803.5

の切り替えと解釈できる。

最後に、被験者の脳波の一例として、被験者HのEEG脳波の結果を図15に示す。7試行21回の反復パターンを数字提示の開始時刻で揃えることでノイズを除去した。脳波の形状は5回の反復パターンとも類似している。しかし、各反復パターンの平均値は0.16, 0.06, 0.11, -0.06, 0.11であり、分散値は40.5, 49.8, 34.5, 22.4, 32.9である。1回目と2回目の反復パターンは分散値が大きく、反復を繰り返すことによって3回目や4回目で脳波が安定してくることがわかる。ただし、5回目の脳波の分散値は上昇している。これは、繰り返し学習によって非反復パターンへの事前準備が陽に出現しているからと考えられる。これらの結果から、パターンの繰り返し提示によって被験者の学習がすみやかに進み、その結果が脳波に出現していると考えられる。この学習の即効性は、内部モデルにおける順モデルから逆モデルへの切り替えによるものと考えられる。

5. 考察

実験計測から得られた結果や事項を考察し、MASAICモデルの実証構造を構築する際の論点などについてまとめる。まず、反応時間の結果からは次のことが明らかになった。

- (1) 反復パターンの開始時は反応時間に大差はなく、内部モデルのフィードバック経路の初期学習は一定といえる。




Fig. 13: Angular Velocity of the 2nd Pattern of the 1st Trial

- (2) 反復パターンの繰り返しによる回帰直線の傾きの変化が緩やかであることから、内部モデルのフィードバック経路からフィードフォワード経路への切り替えはスムーズに行われる。
- (3) 繰り返し試行を規則的に反復すると回帰直線の傾きがほぼゼロとなることから、内部モデルのフィードフォワード機能は安定的に働く。
- (4) 非反復パターンの反応時間の繰り返しによる変化は認められず、MOSAICモデルは安定的に働く。また、非反復パターンへの順応は比較的遅く、MOSAICモデルの内部モデルの切り替えは速やかではない。

次に、動作反応時間の結果からは次のことが明らかになった。

- (5) 反復パターンの被験者の動きは反復が繰り返されることで規則が固定化し、内部モデルは安定化する。
- (6) 反復パターンと非反復パターンが類似している場合、動きの混乱が見られ、MOSAICモデルの内部モデルの切り替えは速やかではない。

最後に、脳波の結果からは次のことが明らかになった。




Fig. 14: Angular Velocity of the 3rd Pattern of the 1st Trial




Fig. 15: EEG of Recurring Pattern at FP1

(7) 脳波の形状は反復パターンで類似しており、反復提示のパターンを学習することにより脳波の分散値が小さくなることから、内部モデルによる順モデルから逆モデルへの切り替えは効率的に機能する。

これらの考察から、内部モデルのフィードバック経路の初期学習は一定であり、内部モデルはすみやかに安定化する。また、内部モデルのフィードフォワード機能は安定的に働き、フィードバック経路からフィードフォワード経路への切り替えはスムーズに行われる。一方、MOSAIC モデルも安定的に働くが、環境変化に伴う内部モデルの切り替えは速やかではないといえる。

これらの特徴から MOSAIC モデルの一例として、TAM (Topographic Attentive Mapping) Network を用いた MOSAIC モデルの具体的構造を図 16 に示す。このモデルは、入力層、基盤層、カテゴリー層、出力層の 4 層からなる。入力を与えられると、特徴マップ層から基盤層への興奮性学習のボトムアップ学習とカテゴリー層から出力層への順モデルの選択が機動し、最適な順モデルが駆動する。与えられた指示と出力値に差がある場合は、出力層から基盤層への共振学習の抑制機能によるトップダウン学習とビジランス機能を用いた最適な順モデル以外のモデル抑制により、最適な逆モデルが時間経過とともに出現する。なお、カテゴリー層では、ノード生成法によって順モデルが自動生成される。




Fig. 16: MOSAIC Model by TAM Network

6. おわりに

本研究では、視覚・運動課題を通して、被験者の動作軌跡とその反応時間、脳波との関連から内部モデルの順モデルのフィードバック機能と逆モデルのフィードフォワード機能、及び、MOSAIC モデルの内部モデルの切り替え機能について議論した。また、内部モデルと MOSAIC モデルの特徴について考察し、MOSAIC モデルの具体例を示した。

今後、MOSAIC モデルの具体的な数値検証や他の動作軌跡での脳波と反応時間との関連性について、さらに詳細に議論する必要がある。

参考文献

- [1] 川人：小脳内部モデルとモザイクの計算論的神経科学，人工知能学会誌，Vol.17，No.6，pp.720-731 (2002)
- [2] 杉本，鯨島，銅谷，川人：MOSAIC モデルにより環境を抽象化する階層型強化学習，電子情報通信学会論文誌 D，Vol.J89-D，No.7，pp.1577-1587 (2006)
- [3] 今水：動作の意識的理解と内部モデルの学習・切り替え，日本ロボット学会誌，Vol.25，No.5，pp.699-705 (2007)
- [4] 林，Williamson：TAM Network のプルーニング手法の提案，システム制御情報学会論文誌，Vol.17，No.2，pp.81-88 (2004)

[連絡先]

林 勲 関西大学大学院 総合情報学研究科
〒569-1095 大阪府高槻市霊仙寺町 2-1-1
tel. 072-690-2448
fax. 072-690-2491
e.mail ihaya@cbii.kut.ac.jp