長期学習者の成長曲線に基づく 学習度合い予測モデルの開発と評価†

三谷 慶太*¹・星野 孝総*²

脳活動を測定するために脳に関するデータを取得可能な Magnetic Resonance Imaging（MRI，核磁気共鳴画像法）などの計測機器が活用されている。これらの計測機器を活用して、学習に関する様々な研究が行われている。しかし、長期間の測定は参加者への負担も大きく、また短期間で複数回の連続計測は、身体的影響が指摘されている。その場合、オフラインで学習度合いを測ることで、参加者への身体的負担と精神的負担の軽減につながると考えられる。本稿では、人間の学習過程を MRI 計測する場合を考え、事前の長期間の学習で、どのように学習が進んでいくのかを観測するパフォーマンス実験について結果を示す。それらのデータをもとにして、学習度合い予測モデルを提案する。これらのモデルから、生体計測を行うための適切なタイミングを学習度合いから議論し、モデルを検証する。

キーワード：学習度合い予測，長期学習，成長曲線，ハノイの塔

1. はじめに

近年、脳活動を測定するために脳に関するデータを取得可能な Magnetic Resonance Imaging（MRI，核磁気共鳴画像法）などの計測機器が活用されている。これらの計測機器を活用して、学習に関する様々な研究が行われている。Grafman らや Newman ら、Morris らは、人間の認知機能に含まれる「遂行機能」を解明すべく、研究を行った [1–3]。また、Lezak や福井によると、遂行機能とは「将来の目標達成のために適切な構えを維持する能力」であり、1) 目標設定、2) 計画立案、3) 計画実行、4) 効果的遂行の4段階により成り立っていると定義されている [4, 5]。遂行機能は、生活するうえで重要な役割を担っているため、遂行機能により賦活する脳部位を確認する重要性がある。一方、ハノイの塔のパズル課題を用い、人の学習機能を研究している事例は過去にも多くある。これらの研究では行動計画、問題解決、暗黙学習などとの関係性を研究しており、主に限られたタスク回数での調査を行っている [6–8]。また、小学児童の学習機能に関して調査した研究もあり、ハノイの塔のパズル課題は幅広く利用されている [9]。佐野らはハノイの塔パズル課題を用い、課題回答者の長期学習前後の脳活動と行動データの関係性を解明するための研究を行った。その結果、実験参加者のパフォーマンスから学習の収束を確認し、MRI を用いて遂行機能により賦活する脳部位を確認した [10]。

数ヶ月に及ぶ長期的な学習を観測する実験において、全学習期間の生体信号を計測することは時間的・金銭的なコストが高

くなる。解決策として、全学習期間を前期・中期・後期のように等間隔のスパンで区切り、それぞれにおいて生体信号計測を行うという方法が考えられる。しかし、学習者の学習度合いが終始線形に進むとは限らず、課題に対するコツや解法をつかんだ時に段階的な学習の進行が見られる場合が多い。そのため、実験参加者の学習が進んだタイミングを予測して生体信号計測を行うことが理想となる。また、学習度合いは実験参加者によって個人差があるため、タイミング予測が非常に困難であり、生体計測に関する研究では大きな問題として考えられる。これらの課題に対し、オフラインでの予備実験によって、課題遂行時の操作履歴や操作時間を取得し、これらをスコア化したものを指標に、おおよその期間を決めて生体計測実験が行われてきた。この場合は、実験参加者ごとの学習度合いの差は考慮できず、理想とするタイミングで正しくデータを取得できているかを定量的に測ることは困難となる。そこで、学習度合いを予測することができれば、実験参加者ごとに柔軟で適切なデータを取得できると考えられる。

本研究においては、人の遂行機能により賦活する脳部位を確認するための課題として、ハノイの塔を解く課題を選定する。ハノイの塔を解く課題は、脳の遂行機能を調査する上でよく使われており、研究事例も多くある [1, 11–13]。また、三谷らは、約二時間の学習前後の脳活動の検証を行い、fMRI 解析結果より脳活動差を確認した [14, 15]。このとき、実験参加者の学習推移を行動データの学習曲線から学習の進行は確認されたが、実験時間が短時間であったため学習の終了を示す学習曲線の収束は確認されなかった。一方、佐野らは長期間の学習課題を行い、学習の収束を確認した上で fMRI 計測を行っている。この手法では、まず予備実験として、学習全体にかかる期間や fMRI 計測を行うタイミングなどを実験的に調査する。次に予備実験で得られた結果をもとに別の実験参加者で同様の実験を行うが、この時には fMRI 計測のタイミングを予備実験の結果を元にして決定している。この手法では、fMRI 測定のためのタイミングは予備実験で設定した共通のタイミングを用いており、実

† Development and Evaluation of a Learning Level Prediction Model Based on the Growth Curve About the Long-Term Learners
Keita MITANI and Yukinobu HOSHINO

*1 高知工業高等専門学校 ソーシャルデザイン工学科
Department of Social Design Engineering, National Institute of Technology, Kochi College

*2 高知工科大学 大学院工学研究科
Graduate School of Engineering, Kochi University of Technology

図1 学習曲線を表す成長のステップ

験参加者ごとの個人差には対応できていないという問題点が報告されている。そこで本稿では、長期間の学習を観測する実験において、初期の学習度合いから、適切なタイミングで生体計測を行うための学習度合い予測モデルを作成し検証結果を示す。

本研究では、プロセス学習ではなくノウハウ学習にフォーカスを当て、ノウハウ学習により遂行機能がどのように学習していくのかを調査する。ノウハウ学習とは、課題のノウハウや解き方を学習する学習方法のことで、プロセス学習とは、課題に対するおおよそ決まった手順を学習する学習方法である。プロセス学習では、課題の解き方をその都度考えるのではなく、解き方の手順を思い出しながらか解くことになる。それに対し、ノウハウ学習では課題に対してその都度解き方を考えることになる。

成長曲線と学習曲線

成長曲線とは、人間の身体的または能力的発達の程度を、横軸を時間経過、縦軸を調べたいデータとするグラフで表した曲線である。成長曲線には指数関数的成長と対数関数的成長がある。本研究では、人間の学習度合いをグラフ化したものを成長曲線として扱う。指数関数的成長は、初期はあまり成果が見られないが、中期・後期から成果が急速に増加する成長である。学習した時間による経験的効果が習熟度を増す。この習熟度との関係性を学習曲線として定義できる。つまり、課題を反復してこなした回数が増えるほど、経験的効果により1回ごとに要する時間は減少することとなる。学習曲線では、学習成長度はタスク回数に比例し一定の割合で増加することではなく、急激に加速する。図1の正の加速曲線、S字型曲線、負の加速曲線のように習熟が急激に加速することが知られている。また、長い学習期間を要した場合は負の加速曲線のように、学習成長度が低迷している学習期間が長いほど急激に加速する。学習曲線は、横軸を試行回数や時間経過をもとにした累積経験数、縦軸に正しい反応を示した反応度合いや所要時間などをもとにした達成度合いをとる。図1に示すように、成長のステージとステップはそれぞれ3段階に分かれており、1st ステージ、2nd ステージ、3rd ステージと呼ばれる。それぞれのステージでは、

学習の成長が学習初期から成長・飽和を迎え、最終的な停滞時期に向けて成長していく。その曲線には、正の加速曲線、S字型曲線、負の加速曲線の3種類がある[16]。学習プロセスには細かな成長をするタイミングがあり、これをプラトー現象という。このプラトー現象には「準備期」「発展期」「高原期」の3つのタイミングがあり、これらのタイミングでの「急速な伸び」が成長曲線を構成していると考えられている[17]。

「準備期」は、学習を始める段階であり、比較的簡単なステップになる。進捗は進みやすいが、現時点では「成果」と呼べる状態には直結しにくい。すなわち、実験参加者（主観者）的には学習が進んでいると感じているが、客観的には学習が進んでいるとは見られない状態である。「発展期」は、準備期に備えた力が発揮され、最も効率的に成長へ繋がりやすい期間となる。すなわち、学習が収束に向かっていている状態である。「高原期」は、次の発展期を迎えるための準備となる期間であり、頭打ちでなかなか伸びを実感しにくくなる。とくに、1st ステージでは、発展期への成長に対して最も時間がかかる場合があり、不安になったり学習をやめたいこともある。この期間は、次の発展期への準備期でもあり、この時期を乗り越えると、より大きな発展へ繋がりやすい。この場合は、負の加速曲線を描くと考えられている。また、「準備期」「発展期」「高原期」の3段階は一度だけ経験するものではなく、何度も繰り返し経験するものである。一般的には、周期が増えるごとに、準備期から高原期までの期間が短くなり、成果に繋がる度合いも高まる。これらはプラトー現象による繰り返しであり、加速曲線やS字型曲線を描くと考えられる。本稿で扱うハノイの塔の場合、円盤の段数が5段と少ないため、正の加速曲線とS字型曲線を描く課題であると推測され、負の加速曲線を描くとは考え難い[18]。また、一方で学習曲線は習熟度曲線と関連した研究もあり、この場合は練習量と反応時間の関係をもとに数式で表すことができ、「ピロリとアンダーソンの式」と呼ばれている。 RT が反応時間、 N が累積練習量としたとき、ピロリとアンダーソンの式を以下に示す。

$$RT = 1.40N^{-0.24} = \frac{1.40}{N^{0.24}} \quad (1)$$

学習の成長は、学習初期に成長段階が見られるが、時間が経つにつれて成果が見られなくなり、ある一定以上の成果が得られない。例として、生物の個体数や、プログラムのバグ発見数などは、初期は少なく、途中で多くなり、その後また少なくなるような現象が多くある。ピロリとアンダーソンの式から示される運動の反応時間と学習曲線（習熟曲線）の関係については、1970～1990年頃に数多く研究されて来た。これらの研究では、指数関数モデルや乗関数モデルをフィッティングさせるモデル構築において推定誤差が発生することが指摘されており、対象に合わせて数多くの指数関数モデルが提案され議論されている[19-26]。また、時間の推移と累積量でグラフにしたものが成長曲線と呼ばれ学習曲線と同様に扱われている。代表的な成長曲線で、人口増加や経済変動の過程を表すモデルとして、ゴンペルツ曲線とロジスティック曲線がよく知られており、バグの累積過程を成長曲線を用いて評価した例もある[27]。本研究では、学習度合いを手数評価と手順評価の2種類の評価法によ

図2 手数評価と手順評価の増減ルール

り評価した。ハノイの塔のゲームの性質上、ボタン押下間時間及び手数評価・手順評価による点数の特性から、正の加速曲線とS字型曲線を描くと考えられ、負の加速曲線を描かない学習課題と考えているため、それらに類似した「凸型曲線」「ゴンベルツ曲線」「ロジスティック曲線」の3つの成長曲線を用いる。なお、凸型曲線は実験データと曲線の式を参考に式を組み立てた。数式と特徴を次に示す。

• 凸型曲線

$$y = b(1 - e^{-ax}) - c \quad (2)$$

y , x が変数, a が傾き, c が y 切片を示す。 $x \rightarrow \infty$ のとき $b - c$ に収束する。

グラフは上に凸な曲線を描き, a が大きいほど傾きが大きくなり, 早く収束する。

• ゴンベルツ曲線

$$y = Kb^{e^{-cx}} \quad (3)$$

y , x が変数, b が y_0 の値を決める要素, c が傾きを示す。グラフはS字型を描き, 時間が経つにつれ, 増加が止まり一定値 K に近づく。

• ロジスティック曲線

$$y = \frac{K}{1 + be^{-cx}} \quad (4)$$

y , x は変数, b は y_0 の値を決める要素であり, c は傾きを示し正の値をとる。グラフはS字型を描き, 時間が経つにつれ, 増加が止まり一定値 K に近づく。

2. パフォーマンス実験

ハノイの塔 (Tower of Hanoi) は一人用ゲームの一種で, 19世紀にフランスの数論者 Edouard Lucas によって考案された [28]。3本の塔と中心に穴の開いた何枚かの異なる大きさの円盤で構成されている。基本的にゲームスタート時は一番左の棒に下から大きい順に円盤が積み重ねられており, 所定のルールにしたがってすべての円盤を一番右の棒に移動させるとクリアとなる。一手につき1枚しか円盤を動かすことができない,

円盤の上にはそれより大きな円盤を重ねることができない, 塔以外のところに円盤を移動させることができない等のルールがある。

学習度合いを手数評価と手順評価の2種類の評価法により評価した。手数評価と手順評価の増減についての例を図2に示す。一手ごとに評価点が増減し, 課題終了時の合計点を手数評価の評価点とする。手数評価の増減のルールを以下に示す。

- 課題達成に近づく一手: +1点
- 課題達成から遠ざかる一手: -1点
- 課題達成までの手数が変わらない一手: ±0点

実験時のログデータをもとに, 上記のルールに則って加減点した合計点で手数評価を算出する。タスクの評価として, (クリアまでの最短手数 × クリア回数) + (最短手数 - 終了時の円盤の配置からクリアまでの最短手数) で手数評価を計算する。本実験の1タスクにおいて, タスク時間40秒内であれば, 繰り返し課題を解くことを許している。したがって, 最短手数で解けていればクリア回数も上がる。また, ボタンは1アクションにつき1回押下されるため, ボタン押下と次の押下の間の時間が短ければ, タスク時間内にさらに挑戦できる回数も増える。そのため, 学習が進み短時間で解けるようになれば, この押下間時間も短くなり, 最短手数でクリア回数が増加することになる。したがって, クリアした場合の評価は, (クリアまでの最短手数 × クリア回数) となる。次に, タスク時間は40秒で区切っているため, 課題の途中で終わる場合がある。この場合の評価は残り手数に依存する。残り手の評価は, 打ち切られた終了時の円盤の配置から, 対象のパズル最短手数との差で評価する。つまり, クリアまでの残り多くの手数があれば評価とし小さくなり, クリアに近いところまで進んでいた場合, クリアまでの最短手数は少ないため評価としては大きくなる。したがって, (最短手数 - 終了時の円盤の配置からクリアまでの最短手数) を加算して評価する。この評価により, 課題時間内で正解に向けた最適手 (最短手数となる手) を何手進めることができたかを評価することができる。

手順評価の場合は, 手数評価と同様に一手ごとに評価点が増

図3 ハノイの塔の初期配置例と完成位置

減し、課題終了時の合計点を手順評価の評価点とする。ただし、手数評価では課題達成までの手数が変わらない一手を選択した際に評価点の増減はしないが、手順評価では同様の選択をした際に評価点から減点する。手順評価の増減のルールを以下に示す。

- 課題達成に近づく一手：+ 1 点
- 課題達成から遠ざかる一手：- 1 点
- 課題達成までの手数が変わらない一手：- 1 点

手順評価を計算することにより、いかに最適手を打っているかを得ることができる。

実験で用いたハノイの塔の課題画面を図3に示す。すべての円盤は左側に積み重なった状態からスタートし、配置されている円盤を1つつ移動させ、最終的にすべての円盤を右側に移動させることがゲームの目標である。 n 枚の円盤における完成までの最短手数は $2^n - 1$ であるため、本実験で用いる5枚の円盤のハノイの塔では31手が最短手数となる。ハノイの塔では、試行錯誤的に円盤を移動して展開される個々の状態（個別的事象）に基づいて、完成形を再現させる最終的方法（一般的方法）を獲得する。この学習過程の観察が重要となる。偶然に課題達成した時の操作手順のみを暗記してしまうことは、一般的方法の学習とは異なる。したがって、本実験では初期配置をランダムな配置にすることで、可能な限り操作手順のみの暗記を防いだ。また、難易度を一定にするために、課題達成までの最短手数が31手となる配置の中から、初期配置をランダムに設定した。この課題のルールを次に示す。

- 3本の塔と大きさの異なる5枚の円盤から構成される
- 初期配置は、課題遂行までにかかる手数が31手となる配置がランダムに設定されている
- 円盤の移動は持ち上げて置くまでを一手とする
- 持ち上げられる円盤は一手につき1枚ずつとする
- 円盤の上にはそれより大きな円盤を重ねることはできない
- すべての円盤を右の塔に重ねることができれば完成となる

5段のハノイの塔の配置で最短手数となる31手の配置は32種類あり、この中から18種類の配置を実験に用いた。このとき、プロセス学習ではなくノウハウ学習になるように、選択した配置が前後に選んだ配置と近くないものを選択した。ハノイの塔課題は4ボタンコントローラによって行われた。上下左右に配置されたボタンの内、それぞれ左のボタンは左の塔、上の

図4 実験のスケジュール

図5 実験課題の流れ

ボタンは真ん中の塔、右のボタンは右の塔に対応している。また、1つの円盤を動かすには2回の操作が必要となり、一度目の操作でボタンに対応した塔の円盤を持ち上げ、二度目の操作でボタンに対応した塔に円盤を置く動作となる。

実験方法

この実験では、fMRI計測を行う場合と同様の環境、同様のタスクデザインを用いて計測する。実験参加者の学習過程を解析することで、fMRI計測向けのリピートブロックを含むタスクや、実際のfMRI計測を含めることが、学習過程に影響するかどうかの検証が目的となる。実験条件を以下に示す。

- fMRI計測ありの実験参加者：2名（20代、男性2名）
fMRI計測なしの実験参加者：6名（20代、男性3名、女性3名）
- 期間：約1.5ヶ月間（週2回、計13回）（図4参照）
- 学習：1回約40分（1タスク5分×5回）

実験デザインには、実験参加者に指定した時間・間隔で課題を遂行してもらうためにメインとなる課題ブロック（Task）と、メインとの差分をとるための課題ブロック（Repeat）、休止ブロック（rest）を交互に繰り返す形式である「ブロックデザイン方式」を採用した[29]。図5に実験課題の流れを示す。

1回の実験においてTaskブロックとRepeatブロックは、それぞれ5枚の円盤によるハノイの塔課題を3ブロックずつ行なった。各ブロックの内容について以下に示す。

- Task：ハノイの塔課題を実施する。課題が完成した場合、円盤は初期状態に戻る。実験参加者には課題が完成しても

図6 実験環境図

時間内であれば繰り返し解くように教示する。

- **Repeat**：実験参加者が Task ブロックで実際に動かした課題の再現映像を投影し、その動きに合わせてコントローラのボタン（下ボタン）を押すよう教示した。この時のボタン押下は課題の点数などには影響しない。また、Repeat ブロックにおいてスキャンした画像には、視覚野と運動野の賦活情報のみが含まれていることになる。したがって、Task ブロックの賦活画像から Repeat ブロックの賦活画像の差分をとることで、遂行機能に関する賦活情報のみ取り出すことができる。
- **Rest**：スクリーン中央に表示される十字記号を注視するように教示した。なお、十字記号はそのあとのブロックによって色が異なり、Task ブロックの前は赤色の十字、Repeat ブロックの前は水色の十字が表示される。

実験参加者は図6に示すようにベッドに横たわり、fMRI計測時と同じような姿勢をとる。正面にはモニターが設置されており、これを見ながらハノイの塔課題を解く。この時、操作に用いるコントローラはfMRIと同様のサイズ、重さ、ボタン位置のコントローラを使用し、fMRI計測時の環境と同様になるように配慮した。図5に示す実験課題は計5試行実施した。各課題間では必要に応じて適度な休憩を取り、1回の学習で課題1回5分40秒を5試行と、休憩や準備で約40分間の学習を行った。佐野らの行ったfMRI計測を併用した実験と同条件の実験回数にするために、1、4回目は計6回の課題を行い、13回目は1回のみ（5分）課題を行った。また、学習の間隔は週2回で可能な限り均等間隔（月→木、火→金など）となるようにした。学習時において、実験参加者がタスク時に押したボタンの種類（上・左・右）とその時間、終了時の塔の円盤の配置、課題達成回数と、開始から終了までの円盤の配置についてログの記録を行った。また、終了時の塔の円盤の配置と課題達成回数から、進んだ手数（手数評価）を計算し、開始から終了までの円盤の配置から手順評価の計算を行った。

解析結果

各実験参加者の1タスクずつの実験において、ログに記録されているボタン押下時間からそれぞれの押下間隔の時間を計算して、ボタン押下間時間とした。このボタン押下間時間の平均と標準偏差を求め、得られたボタン押下間時間の平均（average [ms]）、標準偏差（Standard Deviation [ms]）、手数評価（Score [点]）、手順評価（Procedure evaluation [点]）の4つのデータを用いて比較解析を行った。次に「凸型曲線」、「ゴンベルツ曲

線」、「ロジスティック曲線」の3つの成長曲線を手数評価の学習曲線に近似させた結果について検証する。さらに、凸型曲線を用いた全実験参加者におけるフィッティング結果と近似式の係数に着目し、解析した結果について述べる。

8名の実験参加者の実験データでボタン押下間平均時間と標準偏差、ボタン押下間平均時間と手数評価、ボタン押下間平均時間と手順評価、手数評価と手順評価の4つを、横軸をタスク回数（task [times, 回]）としてグラフを作成した。例として、実験参加者Aの解析結果を図7に、実験参加者Hの解析結果を図8に示す。実験参加者C、E、F、Gは実験参加者Aと、実験参加者B、Dは実験参加者Hと同様の傾向を示した。なお、以下ではボタン押下間平均時間をAVG、標準偏差をSD、手数評価をScore、手順評価をPeと表記する。

また、全実験参加者のそれぞれの結果において、おおよその収束値を確認するために、12回目の実験（タスク回数165回目から180回目）の平均を求めた。結果を表1に示す。

図7、8の(a)を見ると、初期段階においてボタン押下間時間に大きくばらつきがある。タスク100回目あたりから、ばらつきが小さくなり約200msに収束している。また、図7、8の(b)及び、図7、8の(c)を見るとボタン押下間時間が減少すると共にScoreとPeが増加していることがわかる。ScoreとPeの違いについては、図7、8の(d)を見る限り、あまり大きな差がなく同じ傾向を示しているが、PeのばらつきがScoreに比べばらつきが大きい結果となった。

Peは最適でない場合のみマイナス評価となる。したがって、極端に逆方向に進んだ場合や迷った手を繰り返した場合、低い値が顕著に得られればらつきが大きくなる。ScoreよりもPeの方が顕著に表れるため、図7、8の(d)のような結果となったと考えられる。これらは、学習探索の段階にある実験参加者に表れると考えられ、ボタン押下間時間のバラつきが操作判断の迷いと同様に、一時的に引き返す探索的行動が大きなバラつきを発生させたと考える。PeはScoreよりもその傾向が顕著に現れ、実験参加者の学習中探索の状態を示す値として有効であると考えられる。ただし、ばらつきの大きいカーブはフィッティングモデル利用には適さない。また、表1より、8名の実験参加者の12回目のAVG、SD、Score、Peの平均値は、それぞれ260.1ms、±176.3ms、70.8点、65.3点となった。実験参加者ごとのScore・Peで大きな差は確認されなかったこと、ScoreはPeに比べてばらつきが少なくなったことから、学習曲線としてScoreが扱いやすいと考えられる。

以上の解析結果より、ハノイの塔課題遂行によって得られたScoreとPeでは、全実験参加者において大きな差は見られなかった。したがってScoreに着目し解析を行った。Scoreの学習曲線に「凸型曲線」、「ゴンベルツ曲線」、「ロジスティック曲線」をそれぞれ近似させた。例として、実験参加者Aの近似結果をそれぞれ図9に示す。

図9において、橙色の曲線は近似曲線、横軸に平行な4本の青色の直線は上から、近似曲線の近似式から得た収束値、収束値の4分の3、収束値の2分の1、収束値の4分の1の値である。凸型曲線で実験参加者Aの学習曲線を近似した結果、収束値は84点、決定係数は0.90であった。それに対し、ゴンベル

図7 実験参加者Aの結果 (a) AVGとSD, (b) AVGとScore, (c) AVGとPe, (d) ScoreとPe

図8 実験参加者Hの結果 (a) AVGとSD, (b) AVGとScore, (c) AVGとPe, (d) ScoreとPe

表1 実験12回目における各被験者の平均データと全体の平均

実験参加者	A	B	C	D	E	F	G	H	平均
ボタン押下平均時間 [ms]	225.2	258.9	219.8	379.8	248.5	261.0	275.5	212.0	260.1
標準偏差 [ms]	140.3	194.3	122.0	401.0	100.3	149.3	142.3	161.2	176.3
手数評価 [点]	80.7	67.3	81.0	38.0	76.6	69.4	67.1	85.9	70.8
手順評価 [点]	74.2	62.9	72.3	29.8	73.5	66.8	63.6	79.3	65.3

図9 実験参加者 A の Score を各成長曲線に近似した結果。
(上) 凸型曲線, (中) ゴンベルツ曲線, (下) ロジスティック曲線

ツ曲線で近似した結果は収束値が 77 点, 決定係数が 0.90, ロジスティック曲線で近似した結果は収束値が 75 点, 決定係数が 0.89 になった。実験参加者 A の近似結果では, 収束値に違いがあったが, 近似曲線については大きな差はなかった。全実験参加者の Score に 3 つの成長曲線を近似させ, 得られた近似式において x を十分大きくしたときの y の値を収束値とした。収束値と決定係数 R^2 をまとめた結果を表 2 に示す。

表 2 より, 凸型曲線で学習曲線を近似した結果, ゴンベルツ曲線とロジスティック曲線で近似した値よりも収束値が高くなる傾向が全実験参加者で見られた。また, Score $\cdot$ Pe の結果が線形であった実験参加者 D と実験参加者 H においては, グラ

表 2 近似曲線の収束値と決定係数 R^2

実験参加者		A	B	C	D	E	F	G	H
凸型曲線	収束値	84	138	81	$10^4 >$	77	92	72	$10^4 >$
	決定係数	0.90	0.87	0.76	0.71	0.89	0.85	0.84	0.81
ゴンベルツ曲線	収束値	77	72	75	46	74	71	68	103
	決定係数	0.90	0.87	0.75	0.72	0.89	0.87	0.86	0.81
ロジスティック曲線	収束値	75	66	73	40	73	68	67	89
	決定係数	0.89	0.87	0.74	0.71	0.88	0.86	0.85	0.80

フが飽和曲線を描いておらず, 収束しなかった。図 1 に示すように, S 字型曲線は 1st ステージからの立ち上がり時間に時間がかかっている場合に適用される。本研究の実験は初見からの実験であり, 実験参加者は 40 秒のタスク時間内に得点を得ることを目指す。1st ステージにおいては, 0~数点となり制限時間で伸びないこととなる。したがって, 図 9 に示すように各プロットはほぼ 0 点となる。この期間は S 字曲線の場合低迷期になると思われる。実際には 1st ステージ付近が 0 点にフィッティングせず, ゴンベルツ曲線とロジスティック曲線では少し横軸から上部に浮いてフィッティングされている。本実験の設定としての初見からの学習に沿っておらず, この理由から凸型曲線を選択してモデルにフィッティングさせることとした。しかし, ゴンベルツ曲線とロジスティック曲線による近似では, 収束値の予測が可能であった。また, 表 2 より実験参加者ごとの決定係数には大きな差がないことが分かった。したがって, どの成長曲線を選択しても大きな差がないと考えられるため, 成長曲線の数式が扱いやすい凸型曲線について解析を進めることにした。

3. 学習度合い予測モデルの作成

人間の学習過程を MRI 計測する場合を考え, 計測を行う適切なタイミングを測るための学習度合い予測モデルを提案する。学習者の学習速度には個人差があるため, 個人ごとの学習度合いの評価, また学習収束タイミングを予測できるモデルの作成を目指す。パフォーマンス実験結果をもとに, 学習進度の個人差に対応できるモデルを作成する。

凸型曲線についての解析を進める。全実験参加者の Score を凸型曲線で近似した結果から得られた係数 a , b について常用対数を取り, それぞれ比較を行った。係数 c については全被験者ともにほぼ 0 にフィッティングしており, 学習度合いを示す係数としてはあまり適さないため用いなかった。比較結果を図 10 に示す。なお, 図 10 において, 青枠内が学習の収束が見られなかった群 (Not convergence) の各係数を示し, 赤枠内は学習の収束が見られた群 (Convergence) の各係数を示す。また, 学習収束の有無は表 2 の凸型曲線において, 収束値が大きくなった実験参加者を Not convergence, 収束値がその他比較的小さくなった実験参加者を Convergence とした。

学習曲線の傾きを示す係数 a の常用対数 $\log_{10} a$ において図 10(a) より, 学習が収束した Convergence の群の平均値は -1.88 , 収束しなかった Not convergence の群の平均値は -4.71

図 10 学習曲線を凸型曲線で近似させて得られた係数の比較. (a) 係数 $\log_{10} a$ の比較結果, (b) 係数 $\log_{10} b$ の比較結果

となった. また, 学習曲線の収束値に関する係数 b の常用対数 $\log_{10} b$ において図 10(b) より, 学習が収束した Convergence の群の平均値は 1.96, 収束しなかった Not convergence の群の平均値は 4.25 となった. 係数 a , b に関して, 学習が収束した群としなかった群では, 係数に大きな差があることが確認された.

また, ギンベルツ曲線とロジスティック曲線についても, 凸型曲線と同様に近似式の係数比較を行った. 学習曲線をギンベルツ曲線で近似させて得られた近似式の係数比較結果を図 11 に, ロジスティック曲線で近似させて得られた近似式の係数比較結果を図 12 に示す.

図 11, 12 において, ギンベルツ曲線とロジスティック曲線によって得られた近似式の係数比較では, 凸型曲線のような差が得られず, 特徴は見られなかった. 各曲線のフィッティングにおいて曲線の傾き・最終収束値・横軸方向の位置の 3 要素が最も影響すると考えられる. 学習が低調に進む場合, 得点経過は直線的であり一定値に収束しない. この場合は傾きが低いと考えられる. 次に学習がタスク時間で順調に進んでいる場合, 得点経過は正加速曲線を描くと考えられ, 立ち上がり傾きが大きくなる. 各曲線パラメータによって見分けることが可能になると考えられ, 各曲線のパラメータ特性と各実験参加者の Score 結果との関係性について考察する. 図 10 に示す凸型関数の係数 a , b に着目すると, Convergence 群と Not Convergence 群において平均と標準偏差 (SD) に違いが認められた. タスクが 1 日終了するごとに近似式の係数を作成した学習度合い予測モデルに適用した. 例として収束が見られた実験参加者 A の解析結果を図 13 に, 収束が見られなかった実験参加者 H の解析結果を図 14 に示す.

図 11 学習曲線をギンベルツ曲線で近似させて得られた係数の比較. (a) $\log_{10} b$ の比較結果, (b) $\log_{10} c$ の比較結果, (c) $\log_{10} K$ の比較結果

図 12 学習曲線をロジスティック曲線で近似させて得られた係数の比較. (a) $\log_{10} b$ の比較結果, (b) $\log_{10} c$ の比較結果, (c) $\log_{10} K$ の比較結果

図 13 Convergence 群の 1 名の Score を凸型曲線で近似させて得られた近似式の係数の比較. (a) $\log_{10} a$ の比較結果, (b) $\log_{10} b$ の比較結果

図 14 Not convergence 群の 1 名の Score を凸型曲線で近似させて得られた近似式の係数の比較. (a) $\log_{10} a$ の比較結果, (b) $\log_{10} b$ の比較結果

図 13, 14 において, 赤色の実線は Score の収束が見られた群の, Score を凸型曲線で近似して得られた近似式の $\log_{10} a$, $\log_{10} b$ の平均値である. また, 赤色の破線は $+SD$, $-SD$ を示し, 赤色の一点鎖線は $+2SD$, $-2SD$ を示す. 黄色の各点はタスクが 1 日終了するごとに作成した近似曲線の係数を示す. 学習が進み, 収束した場合, 係数の値が Convergence の平均値に近づき, $\pm 2SD$ の範囲に収束すると考えられる. この平均 $\pm 2SD$ の範囲を収束範囲とする.

学習曲線収束が見られた実験参加者 (図 13) では, タスク初期の 1 回目から 4 回目の実験ではばらつきがあり, 収束していないが, 5 回目の実験あたりから収束範囲にデータが分布した. それに対し, 収束が見られなかった実験参加者 (図 14) では, タスク初期は収束範囲にデータが分布したが, 4 回目から収束範囲から外れたデータ分布となった. また, 学習曲線の収束が見られた実験参加者も見られなかった実験参加者も, 係数 a と係数 b においてそれぞれで類似したデータ分布となったため, どちらか一方の確認でよいのではないかと考えられる.

初めにボタン押下の時間について着目した. 8 名の実験参加者のうち実験参加者 D を除く 7 名は, タスク回数 100 回目あたりからばらつきが小さくなったことから, グラフにおける AVG と SD は概ね収束したと考えられる. しかし, 実験参加者 D は, 実験終盤においても AVG と SD の値が安定しなかったことから, 収束していないと考えられる. また, 表 1 より, 実

験参加者 D を除く 7 名の実験参加者は 12 回目の AVG の平均値が, Card のモデルヒューマンプロセッサにおける眼球運動にかかる時間 230 ms に近い値になったことから, Rasmussen の SRK モデルのスキルベースの行動になったと考えられる. したがって, 7 名の実験参加者は人間の特性からみたと, 学習が収束したと考えられる. しかし, 実験参加者 D は, 12 回目の SD が $\pm$ 約 400 ms であることからばらつきが大きく, AVG が約 380 ms と, 人間の運動最短時間と差があることから, 人間の特性からみると学習が収束しておらず, 学習期間が足りなかったと考えられる.

表 1 の AVG と SD が収束していると考えられた 7 名の実験参加者の平均を求めると, AVG が 243 ms, SD が ± 144 ms であることから, タスク 1 回あたりの最大ボタン押下回数と Score $\cdot$ Pe の理想限界値を予測した. 本実験において, 40 秒間の 1 回のタスク中に押すことができるボタンの最大回数は式 (5) より 164 回であった. したがって, 課題を間違いなく遂行した場合, 1 つの円盤を動かすのに必要な操作は 2 回である. したがって, Score $\cdot$ Pe の理想限界値は式 (6) より 82 点となる.

$$\begin{aligned} \text{タスク 1 回の最大ボタン押下回数} &= \frac{1 \text{ 回のタスク時間}}{\text{AVG}} \\ &= \frac{40 \text{ [s]}}{243 \text{ [ms/回]}} \\ &\approx 164 \text{ [回]} \end{aligned} \quad (5)$$

$$\begin{aligned} \text{Score} \cdot \text{Pe の理想限界値} &= \frac{164 [\text{回}]}{2 [\text{回}]} \\ &= 82 [\text{点}] \end{aligned} \quad (6)$$

また、Cardらのモデルヒューマンプロセッサより人間の運動最短時間が230 msである[30]ことから、40秒間の1回のタスク中に押すことができるボタンの最大回数は式(7)より約174回である。したがって、このときのScore・Peの理想限界値は式(8)より87点となる。

$$\begin{aligned} \text{タスク1回の最大ボタン押下回数} &= \frac{1 \text{ 回のタスク時間}}{\text{人間の運動最短時間}} \\ &= \frac{40 [\text{s}]}{230 [\text{ms} / \text{回}]} \\ &\approx 174 [\text{回}] \end{aligned} \quad (7)$$

$$\begin{aligned} \text{Score} \cdot \text{Pe の理想限界値} &= \frac{174 [\text{回}]}{2 [\text{回}]} \\ &= 87 [\text{点}] \end{aligned} \quad (8)$$

したがって、1回のタスク中でのScore・Peの理想限界値は82点から87点となる。各実験参加者の結果について、実験参加者A, C, E, F, Gの5名は、タスク100回目あたりからばらつきはあるものの、グラフから見たScoreとPeは収束したと考えられる。また、実験参加者A, C, E, F, Gの5名において、表1における12回目のScoreとPeの平均は、上記で求めたScoreとPeの理想限界値に概ね近い値となったことから、こちらも学習が収束したと考えられる。しかし、実験参加者B, Hの2名は、表1におけるScoreとPeの12回目の平均値は理想限界値に近い値になっているものの、図8(d)に示すような、ScoreとPeが線形の分布を示していたことから、学習が収束していないと考えられる。また、実験参加者DのScoreとPeの分布も実験参加者B, Hと同様に線形の分布であり、表1においてもScoreとPeの理想限界値の半分以下の値になっていることから学習が収束していないと考えられる。

以上のことから、実験参加者A, C, E, F, Gは人間の特性的にも、学習曲線からも学習しきったと考えられ、実験参加者B, Hは人間の特性的には学習しきったといえるが、学習の進度が遅かったため、学習曲線からは学習しきっていないと考えられる。また、実験参加者Dは人間の特性的にも学習曲線からも学習しきっていないことから、学習期間が足りなかったと考えられる。

表2より、凸型曲線による近似式から予測した収束値は、ゴンペルツ曲線とロジスティック曲線の近似による収束値よりも大きくなった。また、ゴンペルツ曲線による近似式から得た収束値は表1において求めた収束値と近い値であった。したがって、凸型曲線とゴンペルツ曲線は収束値の予測に使用できると考えられる。対して、ロジスティック曲線による近似式から予測した収束値は、凸型曲線やゴンペルツ曲線による近似式から得た収束値よりも小さくなること、決定係数 R^2 が最小のものが多いため、今回の実験の学習曲線には不向きな曲線であったと考えられる。以上のことから、学習度合い予測モデルの作成には凸型曲線とゴンペルツ曲線がよいと考えられるた

め、主にその2つの成長曲線について解析を行った。

図10において、凸型曲線による近似式の係数は学習が収束した群としていない群で差があったが、図11, 12において、ゴンペルツ曲線とロジスティック曲線による近似式の係数は学習が収束した群としていない群とで差がなく、特徴が得られなかった。したがって、学習度合い予測モデルを作成する際は、数式的に扱いやすく、係数に特徴が見られた凸型曲線を用いるのがよいと考えられる。

作成した学習度合い予測モデルでは、学習が進み、収束した場合、係数の値がConvergenceの平均値に近づき、 $\pm 2\text{SD}$ の範囲（収束範囲）に収束すると考えられる。学習曲線収束が見られた実験参加者（図13）では、タスク初期の1回目から4回目の実験ではばらつきがあるが、5回目の実験あたりから収束範囲にデータが分布した。それに対し、収束が見られなかった実験参加者（図14）では、タスク初期は収束範囲にデータが分布したが、4回目の実験から収束範囲から外れたデータ分布となった。このことから作成した学習度合い予測モデルでは、学習曲線の収束予測に役立つと考えられる。また、学習曲線の収束が見られた実験参加者も見られなかった実験参加者も、係数 a と係数 b においてそれぞれで類似したデータ分布となったため、どちらか一方の確認でよいのではないかと考えられる。

以上の結果を受け、実験と同様の実験環境、実験内容で学習度合いの予測モデルの検証実験を行った。また、収束値を確認しながら、MRI測定タイミングの検討も行う。

4. 学習度合い予測モデルの検証

作成した学習度合い予測モデルの検証実験について述べる。モデルの性能を測るために、これまでの実験と同条件での追加実験を行った。実験参加者は過去の実験に参加していない者を対象とし、そこから得られたデータに対する予測モデルの検証を行った。実験課題、実験装置に関しては過去の実験と同様である。本実験の実験条件を以下に示す。

- 参加者：5名（20代、男性5名）
- 期間：約1.5ヶ月間（週2回、計13回）
- 学習：1回あたり約40分（1タスク5分×5回）
- 佐野らの実験と等しい実験回数にするために、fMRI計測を行った1, 4回目（図4参照）は計6回タスクを行った。13回目は1回のみ（5分）実験を行った。

実験スケジュールと実験デザインは図4, 5に示したものと同一である。各実験参加者の1タスクずつの学習においてボタン押下間時間の平均、ボタン押下間時間の標準偏差を求め、得られたボタン押下間時間の平均時間（average [ms]）、標準偏差（Standard Deviation [ms]）、手数評価（Score [point, 点]）、手順評価（Procedure evaluation [point, 点]）の4つのデータの比較を行った結果について述べる。実験後、各実験参加者のデータを過去の実験と比較した結果、ほぼ同様のデータが得られ同様のプロット結果を示した。全実験参加者において特異的なデータは見受けられなかったため、全実験参加者のデータを対象に「凸型曲線」を用いた予測モデルについての検証が可能であると考えた。次にハノイの塔課題遂行によって得られた手

図 15 実験参加者 1 の結果. (a) ボタン押下間時間の平均 AVG と標準偏差 SD, (b) AVG と Score, (c) AVG と Pe, (d) Score と Pe

図 16 実験参加者 2 の結果. (a) ボタン押下間の平均時間と標準偏差, (b) ボタン押下間の平均時間と Score の平均値, (c) ボタン押下間の平均時間と Pe の平均値, (d) Score と Pe のそれぞれ平均値

数評価について着目し、「凸型曲線」で近似させた結果について述べる。最後に作成した学習度合い予測モデルの検証結果について述べる。

5 名の実験参加者による実験データから、ボタン押下平均時間と標準偏差、ボタン押下平均時間と手順評価、ボタン押下平

均時間と手順評価、手数評価と手順評価の 4 つを、横軸をタスク回数 (task [times, 回]) としてグラフを作成した。なお、以下ではボタン押下平均時間を AVG、標準偏差を SD、手数評価を Score、手順評価を Pe と表記する。例として、実験参加者 1 の結果を図 15 に、実験参加者 2 の結果を図 16 に示す。また、

表3 全実験参加者の12回目の実験データの平均と全員の平均

実験参加者番号	1	2	3	4	5	平均
ボタン押下 平均時間 [ms]	240.7	351.2	211.7	250.9	235.5	258.0
標準偏差 [ms]	168.2	241.1	107.0	138.9	147.9	160.6
手数評価 [点]	75.8	27.7	80.3	69.5	75.6	65.8
手順評価 [点]	71.1	3.7	67.9	61.5	68.1	54.5

全実験参加者のそれぞれの結果において、おおよその収束値を確認するために12回目の実験（タスク回数165回目から180回目）の平均を求めた。結果を表3に示す。

図15、16の(a)より、実験初期段階では、ボタン押下間の平均時間と標準偏差がかなり大きく、ばらつきも大きかったが、タスク回数100回目あたりからばらつきが小さくなり収束している。また、図15、16の(b)及び(c)を見ると、ボタン押下間の平均時間が小さくなるほど、ScoreとPeの値が大きくなった。この傾向は、前回の実験と同様に全実験参加者に共通して見られた。図15、16の(d)の結果をみると、ScoreとPeにはあまり大きな差がなく同じ傾向を示しているが、Scoreに比べてPeはばらつきが大きかった。これも前回の実験と同様に、今回の他の実験参加者においても同様の傾向を示した。表3より、5名の実験参加者の12回目のボタン押下間の平均時間、標準偏差、Score、Peの平均値は、それぞれ258.0 ms、 ± 160.6 ms、65.8点、54.5点となった。また、実験参加者2を除く4名の実験参加者のScore・Peは、3章で求めたScore・Peの理想限界値に近い値になった。

次に各実験参加者のScoreについて着目し、解析を行った。ここでは、学習が1日終了するごとに凸型曲線をScoreに近似させ、近似曲線を求めた。例として実験参加者1と実験参加者2の近似結果を図17に示す。図17から、実験参加者1は4回目でタスク終了時の近似曲線に近い近似式が得られた。実験参加者3、4、5の結果は実験参加者1とおおよそ同様の傾向を示した。実験参加者2はScoreの収束値が低いものの11回目で収束したように見えたが、12回目で収束しなかった。

一日ごとの近似曲線の係数を用いて、作成した学習度合い予測モデルの検証を行った。求めた近似曲線の係数において常用対数を取り、求めた学習予測モデルに適用した。実験回数ごとの近似式の係数の平均と標準偏差をグラフ化したものを図18に示す。

図18において、赤色の実線は予備実験でScoreの収束が見られた群の、Scoreを凸型曲線で近似して得られた近似式の $\log_{10} a$ の平均値である。また、赤色の破線は $+\text{SD}$ 、 $-\text{SD}$ を示し、赤色の一点鎖線は $+2\text{SD}$ 、 -2SD を示す。黄色の各点はタスクが1日終了するごとに作成した近似曲線の係数を示す。実験参加者1、実験参加者5では、実験初期から後期まで一貫して係数が収束範囲に分布した。実験参加者3、実験参加者4では、実験初期は収束範囲に分布しなかったが、中盤から収束範囲に分布した。それに対して実験参加者2は11回目まで他の実験参加者と似た分布となったが、12回目に収束範囲から外

れてしまった。また図18において、実験初期は値が小さく、ばらつきも大きかったが次第に収束範囲に分布した。

考察

初めにボタン押下間時間について着目した。5名の実験参加者のうち実験参加者2を除く4名は、タスク回数100回目あたりからばらつきが小さくなったことから、グラフにおけるAVGとSDは概ね収束したと考えられる。しかし、実験参加者2は、値が小さくなったもののAVGとSDの値が安定せず、ばらつきが大きかったことから、収束していないと考えられる。また、表3より、実験参加者2を除く4名は、12回目のAVGの平均値が、Cardのモデルヒューマンプロセッサにおける眼球運動にかかる時間230 msに近い値になったことから、RasmussenのSPKモデルのスキルベースの行動になったと考えられる。したがって、4名の実験参加者は、人間の特性から見たとき学習が収束したと考えられる。実験参加者2は、12回目のSDが $\pm$ 約240であることからばらつきが大きく、AVGが約351 msと、人間の運動最短時間と差があることから、人間の特性から見たとき学習が収束していないと考えられる。したがって実験参加者2は、学習期間が足りなかったと考えられる。

次にScoreとPeについて着目した。実験参加者2を除く4名は100回目あたりからばらつきはあるが、おおよその値に収束していることから、学習が収束していると考えられる。また、表3より、AVGとSDの値から収束していると考えられる4名の実験参加者のScore・Peの値は、3章で求めたScore・Peの理想限界値に近い値になっていることから、学習曲線からみても学習が収束しきつたと考えられる。しかし、実験参加者2は序盤から終盤にかけてばらつきが大きく、Score・Peの値も理想限界値の半分以下の値になっていることから、学習曲線から見ても収束しきつておらず、学習期間が足りなかったと考えられる。

図17に示すように、実験参加者1、3、4、5の結果から、実験の中盤（実験回数5回目から8回目）に学習曲線が線形を示したのは、Hermann Ebbinghausの学習曲線における二度目の発展期にあたり、さらに成長（学習）しているからであると考えられる。それに対して、実験参加者2は、実験回数11回目で収束したと考えられたが、12回目で線形の近似式となったことから、ここでHermann Ebbinghausの学習曲線における二度目の発展期にあたったのではないかと考えられる。

最終的に近似式の係数が収束範囲に分布した実験参加者1、3、4、5は学習度合い予測モデルから見ても学習したと考えられる。それに対して、実験回数12回目で、近似式の係数が収束範囲から外れた実験参加者2は、AVGとSDが収束せず、Score・Peの点数が低かった。そのため、ゴールまでの道のりを自己の中で解き方のノウハウ学習が確立できていないため収束せず、学習期間が引き続き必要であったと考えられる。また、図18の実験回数ごとの近似式の係数の平均値が、序盤は収束範囲から外れているが5回目あたりから収束範囲に分布したことから、生体計測のタイミングは、実験初期は1回目、中期は5回目、後期は13回目がよいと考えられる。

実験参加者 1

実験参加者 2

図 17 実験参加者の Score を凸型曲線でフィッティングした結果。(上) 実験参加者 1, (下) 実験参加者 2

図 18 各実験回数の平均グラフ (エラーバー：標準偏差)

5. おわりに

本研究では、長期学習の行動データの解析と学習度合い予測モデルの開発と評価を行った。数か月に及ぶ長期的な学習を観測する実験において、全学習期間の生体信号を計測することは時間的・金銭的なコストが高くなり困難である。また、実験参加者ごとの個人差に対応しているとはいえない。この問題点を解決するために実験参加者ごとの学習度合いを初期データから予測し、適切なタイミングでの生体計測を行うための学習度合い予測モデルの作成を目的として研究を行った。8 名の実験参加者によるハノイの塔遂行によって得られた実験データを解析した。ボタン押下平均時間 (AVG)、標準偏差 (SD)、手数評価 (Score)、手順評価 (Pe) による解析の結果、8 名の実験参加者のうち 7 名の AVG は、Card らが提唱するモデルヒューマンプロセッサの人間の運動最短時間 230 ms に近い値

となった。また1回のタスク中(40s)でのScore・Peの理想限界値は82点から87点であり、AVGが収束した実験参加者のScore・Peがこの値に近い値になることを確認した。また、ScoreとPeにはあまり差が確認できなかったため、Scoreについて解析を行い、学習度合い予測モデルを作成するための成長曲線の選択を行った。Scoreのデータを、「凸型曲線」、「ゴンベルツ曲線」、「ロジスティック曲線」の3つの成長曲線を近似させた。近似した結果、凸型曲線とゴンベルツ曲線が収束値の予測、学習度合い予測モデルの作成に使用できそうだと考えた。凸型曲線をScoreに近似して得られた近似式の係数に常用対数をとると、収束値が大きくなった実験参加者群と収束値が100に近い実験参加者群で差が見られた。これらの群をNot convergence, Convergenceとした。同様に、ゴンベルツ曲線とロジスティック曲線の近似によって得られた近似式の係数は凸型曲線のように特徴が見られなかった。したがって、凸型曲線の近似結果を用いて学習度合い予測モデルを作成した。予測モデルは、Convergence群の係数の平均値とSDを使用しており、学習が進み、学習曲線が収束すると係数が平均値 $\pm 2SD$ に近い値に収束すると考えられる。次に、この予測モデルの検証実験を行った。過去の実験と同様の環境下での実験を行った結果、5名の実験参加者のうち4名のAVGは、Cardらのモデルヒューマンプロセッサの人間の運動最短時間230msに近い値となった。また、Score・Peはタスク回数100回目あたりから収束しており、過去の実験から求めた理想限界値に近い値となった。凸型曲線を5名のScoreに近似して得られた近似式の係数を、作成した学習度合い予測モデルに適用した結果、AVGが230msに、Scoreが理想限界値に近い値になった4名の実験参加者では、係数がConvergenceの平均値 $\pm 2SD$ に収束した。それに対し、AVGが人間の運動最短時間よりも大きく、Scoreが理想限界値の半分以下となった実験参加者は、係数がConvergenceの平均値 $\pm 2SD$ の範囲に分布しなかった。したがって、作成した学習度合い予測モデルはおおよその予測の可能性があると考えられる。

今後の課題として、ハノイの塔と比べ学習収束期間が異なる課題に対し、今回開発した学習度合い予測モデルが適応可能か、汎化性の検証があげられる。また、今回開発したモデルにより学習度合いを予測し、そのタイミングに基づいた生体信号によって測定された遂行機能部位の活動との検証が挙げられる。

参 考 文 献

- [1] J. Grafman, I. Litvan, S. Massaquoi, M. Stewart, A. Sirigu, and M. Hallett: "Cognitive planning deficit in patients with cerebellar atrophy," *Neurology*, Vol.42, No.8, pp. 1493-1492, 1992.
- [2] S. D. Newman, P. A. Carpenter, S. Varma, and M. A. Just: "Frontal and parietal participation in problem solving in the Tower of London: fMRI and computational modeling of planning and high-level perception," *Neuropsychologia*, Vol.41, No.12, pp. 1668-1682, 2003.
- [3] R. G. Morris, S. Ahmed, G. M. Syed, and B. K. Toone: "Neural correlates of planning ability: Frontal lobe activation during the Tower of London test," *Neuropsychologia*, Vol.31, No.12, pp. 1367-1378, 1993.
- [4] M. D. Lezak: "The problem of assessing executive functions,"

- Int. J. of Psychology*, Vol.17, Nos.1-4, pp. 281-297, 1982.
- [5] 福井俊哉: "遂行(実行)機能をめぐって," *認知神経科学*, Vol.12, Nos.3-4, pp. 156-164, 2010.
- [6] M. A. Guevara, L. E. R. Martínez, F. A. R. Aguirre, and M. H. Gonzáles, "Prefrontal-partial correlation during performance of the Towers of Hanoi task in male children, adolescents and young adults," *Developmental Cognitive Neuroscience*, Vol.2, No.1, pp. 129-138, 2012.
- [7] G. Ward and A. Allport: "Planning and problem-solving using the five-disc Tower of London task," *The Quarterly J. of Experimental Psychology A: Human Experimental Psychology*, Vol.50A, No.1, pp. 49-78, 1997.
- [8] J. Karat: "A model of problem solving with incomplete constraint knowledge," *Cognitive Psychology*, Vol.14, No.4, pp. 538-559, 1982.
- [9] D. Klahr and M. Robinson: "Formal assessment of problem-solving and planning process in preschool children," *Cognitive Psychology*, Vol.13, No.1, pp. 113-148, 1981.
- [10] Y. Sano, R. Hayasaka, K. Mitani, and Y. Hoshino: "Transition in long-term learning curves and fMRI analysis on Tower of Hanoi task," *2018 Joint 10th Int. Conf. on Soft Computing and Intelligent Systems (SCIS) and 19th Int. Symp. on Advanced Intelligent Systems (ISIS)*, pp. 1185-1189, 2018.
- [11] J. R. Anderson, M. V. Albert, and J. M. Fincham: "Tracing problem solving in real time: fMRI analysis of the subject-paced Tower of Hanoi," *J. of Cognitive Neuroscience*, Vol.17, No.8, pp. 1261-1274, 2005.
- [12] N. A. Zook, D. B. Davalos, E. L. DeLosh, and H. P. Davis: "Working memory, inhibition, and fluid intelligence as predictors of performance on Tower of Hanoi and London tasks," *Brain and Cognition*, Vol.56, No.3, pp. 286-292, 2004.
- [13] J. M. Fincham, C. S. Carter, V. van Veen, V. Andrew Stenger, and J. R. Anderson: "Neural mechanisms of planning: a computational analysis using event-related fMRI," *Proc. of the National Academy of Sciences*, Vol.99, No.5, pp. 3346-3351, 2002.
- [14] 三谷慶太, 星野孝総: "iPadにおけるジェスチャコントロールの改良とユーザビリティ評価," 第54回自動制御連合講演会講演論文集, 11月19-20日, 豊橋, pp. 477-479, 2011.
- [15] 三谷慶太, 星野孝総: "計画ゲームを用いた遂行機能タスクに関する脳賦活の検証," 第31回ファジィシステムシンポジウム講演論文集, 9月2-4日, 調布, pp. 733-736, 2015.
- [16] 中村 隆一: "運動学習について," *理学療法のための運動生理*, Vol.9, No.3, pp. 149-156, 1994.
- [17] 辻ちえ, 小笠原知枝, 竹田千佐子, 片山由加里, 井村香積, 永山弘子: "中堅看護師の看護実践能力の発達過程におけるプラトー現象とその要因," *日本看護研究学会雑誌*, Vol.30, No.5, pp. 5_31-5_38, 2007.
- [18] D. R. Towill and J. E. Cherrington: "Learning curve models for predicting the performance of AMT," *The Int. J. of Advanced Manufacturing Technology*, Vol.9, No.3, pp. 195-203, 1994.
- [19] A. B. Badiru: "Computational Survey of Univariate and Multivariate Learning Curve Models," *IEEE Trans. on Engineering Management*, Vol.39, No.2, pp. 176-188, 1992.
- [20] N. Baloff: "Extension of the learning curve - Some empirical results," *Operational Research Quarterly*, Vol.22, No.4, pp. 329-340, 1971.
- [21] W. S. Jewell: "A generalized framework for learning curve reliability growth models," *Operational Research Quarterly*, Vol.32, No.3, pp. 547-558, 1984.
- [22] D. P. Kopcsó and W. C. Nemitz: "Learning curves and lot sizing for independent and dependent demand," *J. of Operations Management*, Vol.4, No.1, pp. 73-83, 1983.
- [23] T. L. Smunt: "A comparison of learning curve analysis and moving average ratio analysis for detailed operational planning," *Decision Sciences*, Vol.17, No.4, pp. 475-495, 1986.
- [24] D. R. Towill and U. Kaloo: "Productivity drift in extended learning curves," *Omega - Int. J. of Management Science*, Vol.6,

No.4, pp. 295-304, 1978.

- [25] T. P. Wright: "Factors affecting the cost of airplanes," *J. of Aeronautical Science*, Vol.3, No.2, pp. 122-128, 1936.
- [26] L. E. Yelle: "Adding life cycles to learning curves," *Long Range Planning*, Vol.16, No.6, pp. 82-87, 1983.
- [27] 山田茂, 尾崎俊治: "ソフトウェアエラー発見過程の確率モデルとその応用," 情報処理学会研究報告ソフトウェア工学 (SE), Vol.21, No.3, pp. 1-8, 1981.
- [28] A. M. Hinz, S. Klavžar, U. Milutinović, C. Petr, and I. Stewart: *The Tower of Hanoi – Myths and Maths*, Springer, 2013.
- [29] 杉下守弘: "機能的 MRI における心理的課題," 認知神経科学, Vol.1, No.1, pp. 56-59, 1999.
- [30] S. K. Card: *The Psychology of Human-Computer Interaction*, CRC Press, 2018.

(2020 年 6 月 22 日 受付)
(2021 年 7 月 9 日 採録)

[問い合わせ先]

〒783-8508 高知県南国市物部 200-1

高知工業高等専門学校 ソーシャルデザイン工学科

三谷 慶太

E-mail: kmitani@kochi-ct.ac.jp

—— 著 者 紹 介 ——

三谷 慶太 [非会員]

2011 年高知工科大学工学部電子・光システム工学科卒業。2013 年同大学大学院電子・光システム工学コース博士前期課程修了。同年、同大学特任研究員。2015 年同大学基盤工学専攻博士後期課程進学。2019 年高知工業高等専門学校ソーシャルデザイン工学科特命助教。現在に至る。感性工学、ヒューマンインタフェース、認知神経科学の研究に従事。

星野 孝総 [正会員]

1970 年 9 月 7 日生。1995 年、米国 Westmar University, Natural Science Division, Department of Computer Science and Mathematics 卒業。1997 年、立命館大学大学院理工学研究科情報学専攻博士前期課程修了。同年、立命館大学大学院理工学研究科総合理工学専攻博士後期課程入学。2001 年 3 月同課程単位取得退学。2002 年博士号 (工学) 取得 (立命館大学)。2002 年立命館大学講師。2007 年高知工科大学工学部電子・光システム工学科助教授。2008 年同大学システム工学群准教授となり現在に至る。ファジィシステム、進化計算、知能ロボティクス、知能システム、知的画像処理、機械学習、感性工学の研究開発に従事。また、近年では知能システム (インテリジェントシステム) のハードウェア化に興味を持ち、リアルタイム知的画像処理システムをベースに SISoC (Soft Intelligent System On Chip) の研究/開発に従事。日本知能情報ファジィ学会員、システム制御情報学会員、計測自動制御学会員、電子情報通信学会員、IEEE 会員。

Development and Evaluation of a Learning Level Prediction Model Based on the Growth Curve About the Long-Term Learners

by

Keita MITANI and Yukinobu HOSHINO

Abstract:

There are measurement devices such as magnetic resonance imaging (MRI), which can acquire brain activity. The case of MRI can use to investigate brain function. In addition, other physiological measurement techniques are used as supportive measures in this area of research. Various studies on the learning process have been carried out using these instruments. However, long-term measurement is hard for participants and researchers. The multiple measurements of short periods are consecutive mostly. Concerning this style, the medical risk of these measurements has been pointed out. In this case, one solution is measuring the learning level offline, mean outside MRI. It is considered to reduce the physical and psychological strain on the participants. In this study, we conducted an experiment to observe how to learn about solving puzzles over a long period of time. The obtained learning curve shows the possibility to choose the best period to measure on MRI. Based on these data, we propose a model for predicting the learning level. From these models, we discuss the appropriate timing for biometric measurements in terms of the learning level and validate the curve models.

Keywords: learning level prediction, long-term learning, growth curve, Tower of Hanoi

Contact Address: Keita MITANI

Department of Social Design Engineering, National Institute of Technology, Kochi College

200-1 Monobe, Nankoku-shi, Kochi 783-8508, Japan

E-mail: kmitani@kochi-ct.ac.jp