

# 認知アーキテクチャを用いた日常環境における個人の認知傾向の推定 Estimating Individual Cognitive Traits in Everyday Environments Using a Cognitive Architecture

新堀 耕平<sup>†</sup>, 宮田 陵司<sup>†</sup>, 金 鎮赫<sup>†</sup>, 白砂 大<sup>†</sup>, 森田 純哉<sup>†</sup>

Kohei Shimbori, Ryoji Miyata, Jinhyuk Kim, Masaru Shirasuna, Junya Morita

<sup>†</sup> 静岡大学

Shizuoka University

shimbori.kohei.21@shizuoka.ac.jp

## 概要

本研究では、経験サンプリング法により反復収集した Go/No-Go 課題成績に対し、認知アーキテクチャに基づくマインドワンダリングモデルを適用し、検索閾値パラメータの個人推定を行った。その結果、検索閾値単独では個人差の分離や複数指標の同時再現に限界があった一方、オMISSIONエラー率やコミッションエラー時の反応時間に対し一定の対応がみられ、一部の感情指標との間に相関が見られた。以上より、日常場面における認知傾向の特性または変動を潜在パラメータとして記述できる可能性が示された。

**キーワード:** 注意, 感情, 経験サンプリング法, 認知アーキテクチャ, パラメータ推定

## 1. 背景と目的

人間による外的な行動は、その個人の長期的特性および体調や気分などの短期的状態によって変化する。日常生活のなかで継続的に記録される認知課題の成績から背後にある個人差や状態変動を推定することは、人間の行動変化の機構的な理解にとって重要である。反応時間や正答率、エラー率といった行動指標は有用である一方で、それらは観測にすぎず、どのような内部過程の違いによって生じたのかを直接には示さない。この点に対して、行動データをその生成過程の観点から記述するプロセスモデルは有効な枠組みを与えられとえられる。

その代表例の1つが、認知アーキテクチャ ACT-R (Adaptive Control of Thought-Rational; Anderson, 2007) に基づく認知モデルである。ACT-R は、複数の認知資源の相互作用を if-then 形式の生成規則として表現する認知アーキテクチャであり、行動データを内部過程と結びつけて説明する。先行研究では、ACT-R を用いて、持続的注意課題 (Sustained Attention to Response Task: SART; Cheyne et al., 2009) における反応時間の変動やエラー発生を説明するモデルが提案されてきた (Peebles & Bothell, 2004)。さらに、van Vugt

et al. (2015) は、成績低下を単なるノイズによるものではなく、課題への注意状態と逸脱状態の競合過程により生じるモデルを提案した。

新堀他 (2023) は、このような認知アーキテクチャに基づく枠組みを用いて、課題成績から個人パラメータを推定し、行動指標を情動などの潜在的傾向として記述する可能性を示した。しかし、この枠組みの適用対象は主として実験的に統制された状況に限られ、日常生活に近い文脈で反復的に取得される認知課題成績に対する推定は十分に検討されていない。日常場面に近いデータを取得する方法としては、経験サンプリング法 (Ecological Momentary Assessment: EMA) が広く用いられている。この手法は、自然な環境下で感情や認知機能を反復的に測定するものであり、実験室での単発測定では捉えにくい個人内変動の把握に適している (Shiffman et al., 2008)。ただし、EMA によって得られる反応時間やエラー率などの観測指標のみから、その背後にある認知過程を直接特定することは困難である。

以上を踏まえ、本研究では、EMA 下で反復測定された認知課題成績に対して認知モデルのパラメータ推定を行い、日常生活に近い文脈で観測される行動成績を、認知アーキテクチャの潜在パラメータとして記述できるか検討する。認知課題から直接測定可能な指標を個別に比較するのではなく、それらを同時に生み出す内部状態を仮定し、その状態を参加者ごとに推定することで、観測データの機構的な解釈を試みる。本稿では、EMA 下で収集された Go/No-Go 課題成績に対して個人適合がどの程度可能かを検討する。加えて、推定された検索閾値と気分指標との対応を探索的に確認し、今後 EMA のデータから観測される個人内変動を認知アーキテクチャにおける潜在パラメータの水準から検討するための知見を得ることを目的とする。




図1 van Vugt et al. (2015) に基づき作成したモデルの処理フロー。モデルは、現在の状態を確認しながら、注意状態と逸脱状態の間を遷移する。注意状態では刺激-反対応を探索して適切な反応または反応抑制を行い、逸脱状態では任意の記憶の探索を継続しつつ習慣的な反応 (Go) を出力する。“課題に戻る”ことが探索されると、再び注意状態へ戻る。

## 2. 方法

以下では、分析対象とした実験データの概要、適用した認知モデル、個人ごとのパラメータ推定手順について述べる。

### 2.1 データセット

本研究では、宮田他 (2025) にて収集された大学生 25 名 (男性 12 名、女性 13 名、年齢  $21.44 \pm 1.70$  歳) の Go/No-Go 課題データを用いた<sup>\*1</sup>。EMA は 1 日 7 回、14 日間にわたり実施された。1 日のうち、第 1 回と第 7 回はそれぞれ起床時と就寝時に実施され、第 2 回から第 6 回は日中の指定時間枠内に送信された通知に応じて実施された。参加者は通知内の URL から調査画面にアクセスし、日常生活下で自身のスマートフォンから気分質問紙に回答した後、認知機能テストを実施した。課題の 1 セッションは 50 試行 (Go 試行 40 回、No-Go 試行 10 回) で構成された。各試行では、スマートフォンの画面中央に注視点を 750 ms 提示した後、数字刺激を最大 500 ms 提示した。No-Go 試行では“3”，Go 試行ではそれ以外の数字が提示され、前者では反応の抑制、後者では可能な限り早くタップすることが求められた。500 ms 以内に反応があった場合はその時点で試行を終了した。本研究では Go/No-Go 課題データから各個人の認知的パラメータを推定し、主観的な気分との対応を検討する。

### 2.2 モデル

van Vugt et al. (2015) によるマインドワンダリングモデルを簡略化することで上記のデータに適用した。

本モデルは、課題成績の変動を気分変動とも関連しうる注意の揺らぎや課題からの逸脱として説明する点に加え、数字“3”への反応抑制とそれ以外への反応という、本研究の EMA 課題と同様の構造をとる。

図 1 にモデルの処理フローを示す。このモデルでは、課題への注意を表す状態 (attending) と、課題からの逸脱を表す状態 (distracted) が競合し、その時点で優勢な状態に応じて行動が決定される。

刺激の提示前において、モデルは宣言記憶から現在優勢な状態を確認する。課題開始時には注意状態が優勢であるが、その活性は時間経過に伴って低下し、やがて逸脱状態が選択されやすくなる。逸脱状態に入ると、モデルは課題に関連しない任意の記憶探索を継続し、“課題に戻る”に相当する記憶が探索された時点で再び注意状態へ戻る。

注意状態が優勢な場合には、提示刺激を同定し、その刺激に対応する刺激-反対応を宣言記憶から探索したうえで、反応または反応抑制を行う。一方、逸脱状態が優勢な場合には、この課題に関連した探索が行われにくくなり、習慣的な反応が出力されやすくなる。ただし、逸脱状態では内部の記憶探索が継続しているため、反応出力は直ちには行われず、現在の探索が終了するまで遅延しうる。本モデルでは、これら二つの状態の遷移によって反応時間のばらつきや一部のエラーを説明する。

本研究では、元モデルの基本構造を維持しつつ、本研究の課題構成に合わせて Go 試行 40 試行、No-Go 試行 10 試行の計 50 試行に調整した。各試行では注視点提示に対応する 750ms の後に、刺激を最大 500ms 提示するものとし、thought probe 試行 (課題中に挿入される自己報告質問) は除外した。

### 2.3 パラメータ推定

本研究では、刺激-反対応の探索過程に関わるパラメータとして、探索閾値パラメータを推定対象とした。前節で示した通り、本モデルでは、注意状態とマインドワンダリングに対応する逸脱状態が競合し、逸脱状態になると、モデルは課題に関連しない記憶探索を行うようになり、課題に関連した刺激-反対応の探索が阻害される。その結果、Go 試行の反応時間の増加や無反応、No-Go 試行での誤反応が生じる。探索閾値は、注意状態において課題に関連した探索が成立するかどうかの基準に関わるため、これらの指標に影響すると考えられる。そこで、各参加者について探索閾値を推定し、Go/No-Go 課題成績をこの潜在パラメータによってどの程度記述できるか検討した。

各探索閾値の候補についてシミュレーションを反

<sup>\*1</sup> 手続きの詳細は宮田 (2026) にまとめられた。

復実行し、モデル出力から Go 試行の オMISSION エラー率 (Omission error rate), No-Go 試行のコミッションエラー率 (Commission error rate), Go 試行正答時の平均反応時間 (Go RT mean), Go 試行正答時の反応時間の標準偏差 (Go RT SD), および コミッションエラー試行の平均反応時間 (Commission error RT mean) を算出した. ここで, コミッションエラーは反応を抑制すべき No-Go 試行で誤って反応した試行を指し, オMISSION エラーは反応すべき Go 試行で反応しなかった試行を指す. 本研究では, これら 5 指標に基づいて, 人間データとモデル予測とのずれを表す誤差を算出し, 参加者ごとに誤差が最小となる検索閾値を推定した. このとき, 人間データについては, 各参加者について 14 日間の EMA 期間中に得られた Go/No-Go 課題成績を集約し, 各指標の参加者内平均値をフィッティングに用いた.

各参加者  $i$  と候補パラメータ  $\theta$  に対して, 誤差は,

$$L_i(\theta) = \frac{1}{K} \sum_{k=1}^K \left( \frac{H_{ik} - M_k(\theta)}{s_k} \right)^2 \tag{1}$$

と定義した. ここで,  $H_{ik}$  は参加者  $i$  の指標  $k$  における人間データ,  $M_k(\theta)$  はパラメータ  $\theta$  におけるモデル予測,  $s_k$  は指標  $k$  における人間データの参加者間標準偏差,  $K$  は指標数 ( $K = 5$ ) である. 各参加者について, この損失が最小となる検索閾値をその参加者の推定値とした.

探索は先行研究 (新堀他, 2023) のローカルサーチ手法に基づいて行った. 現行実装では, 初期中央値と探索幅からなる検索閾値の候補集合を作成し, 各候補値についてシミュレーションと誤差の算出を行った. さらに, 中央値を前後に移動させる操作と探索幅を拡大・縮小する操作を組み合わせることで局所探索を行い, 誤差の総和の減少が認められなくなった時点で探索を終了した.

加えて探索的検討として, 参加者ごとに推定された検索閾値と, EMA 全体で平均化した気分評定および課題指標との関連を検討した. 検索閾値は離散的な推定値であったため, Spearman の順位相関係数を算出した.

3. 結果と考察

EMA 下で収集された Go/No-Go 課題データに対して, 検索閾値を推定対象とした個人適合を行った. その結果, 推定された検索閾値は 25 名中, 1.00 が 10 名, 1.11 が 12 名, 1.56 が 3 名であり, 少数の離散値に集中した. 各参加者の誤差は平均 3.78, 中央値 3.19 であった.

表 1 5 つの行動指標における人間データとモデル予測の対応 ( $n = 25$ )

| Measure       | Human, $M$ ( $SD$ ) | Model, $M$ ( $SD$ ) | Pearson's $r$ | RMSE  |
|---------------|---------------------|---------------------|---------------|-------|
| Omission      | 2.01 (1.78)         | 0.91 (0.56)         | 0.62          | 1.83  |
| Commission    | 49.37 (15.59)       | 3.52 (1.94)         | -0.20         | 48.48 |
| Go RT mean    | 319.96 (34.80)      | 274.78 (0.79)       | 0.20          | 56.51 |
| Go RT SD      | 52.96 (14.47)       | 32.02 (3.94)        | -0.23         | 26.07 |
| Commission RT | 280.69 (38.28)      | 298.78 (58.16)      | 0.65          | 46.88 |

注. 人間列, モデル列は平均値 (標準偏差) を示す. Pearson's  $r$  は各指標における人間データとモデル予測の参加者間相関を示す. RMSE は各指標の単位のままで算出した. Measure 列の各略称は, 順にオMISSION エラー率, コミッションエラー率 (%), Go 試行正答時の平均反応時間, 同反応時間の標準偏差, コミッションエラー試行の平均反応時間 (ms) を表す.

表 2 推定された検索閾値と気分評定・課題指標との探索的関連 (未補正  $p < .10$ )

| 変数             | Spearman's $\rho$ | $p$  |
|----------------|-------------------|------|
| satisfied      | .39               | .055 |
| Commission     | .37               | .071 |
| Go RT mean     | -.34              | .092 |
| Short RT trial | .34               | .098 |

次に, 5 指標それぞれについて, 人間データとシミュレーション結果の対応を検討した. 表 1 に, 各指標における人間データとモデル予測の平均値, 参加者間相関, および RMSE を示す. その結果, オMISSION エラー率では中程度の正の相関がみられ ( $r = .62$ ,  $RMSE = 1.83$ ), コミッションエラー時反応時間についても比較的高い対応がみられた ( $r = .65$ ,  $RMSE = 46.88ms$ ). 一方で, コミッションエラー率 ( $r = -.20$ ,  $RMSE = 48.48$ ), Go 試行平均反応時間 ( $r = .20$ ,  $RMSE = 56.51ms$ ), および Go 試行反応時間標準偏差 ( $r = -.23$ ,  $RMSE = 26.07ms$ ) の対応は限定的であった. 平均値レベルでみると, コミッションエラー率は人間データで 49.37% であったのに対し, モデルでは 3.52% にとどまり, 抑制失敗を大きく過小推定した. また, Go 試行平均反応時間およびその標準偏差についても, モデルは人間データより速く, かつ安定しすぎる方向に予測した.

これらの結果は, 検索閾値単独の推定では Go/No-Go 課題成績の全側面を十分には再現できないものの, 少なくともオMISSION エラー率やコミッションエラー時反応時間のような一部の側面については, 一定の対応を与えうることを示している.

さらに探索的検討として, 推定された検索閾値と参加者平均の気分評定および課題指標との関連を検討した. 検索閾値が少数の離散値に集中しており, 気分評定も段階尺度に基づいていたことから, Spearman の順位相関係数を算出した. 有意性については, 未補正の  $p < .10$  を探索的な関連の目安として解釈した. そ

の結果、検索閾値は満足した気分 (satisfied) と正の相関を示した。また、うれしい気分 (pleased) についても有意水準には達しなかったものの、同方向の関連がみられた ( $\rho = 0.335, p = 0.101$ )。また、課題成績との関連では、コミッションエラー率 (Commission) および反応時間が極端に短い試行の回数 (Short RT count) と正の相関、Go 試行平均反応時間 (Go RT mean) と負の相関がみられた。詳細を表 2 に示す。

これらの結果は探索的かつ未補正であるため慎重な解釈が必要であるが、本データでは、高い検索閾値は抑制失敗が生じやすく、Go 試行では比較的速く反応しやすい状態と結びついていた可能性がある。本モデルでは、検索閾値は刺激-反応対応の検索の成立基準に関わるため、その上昇は課題に関連した検索が成立しにくくなり、結果として習慣的反応が相対的に出やすくなる状態を反映している可能性がある。

また、気分評定との関連では、satisfied が有意であり、pleased も同方向の関連を示したことから、検索閾値の上昇は一部の肯定的気分状態と結びついていた可能性がある。先行研究においても、ポジティブ感情は注意制御に様な効果をもつのではなく、状況によっては選択的注意の低下や目標対象への過度な焦点化と結びつくことが示されている (Rowe et al., 2007; Gable & Harmon-Jones, 2008)。このことは、肯定的気分が常に認知制御を促進するのではなく、課題目標への注意を弱め、自動的・習慣的な処理を促進する場合があることを示唆している。したがって本研究の結果は、肯定的気分が高い参加者では、課題に関連した検索よりも自動的・習慣的な反応が相対的に出やすくなり、そのことが高い検索閾値として表れた可能性を示唆している。

#### 4. まとめ

本研究では、EMA 下で収集された Go/No-Go 課題データに対して、認知アーキテクチャに基づく個人適合を試み、検索閾値を対象としたパラメータ推定を行った。その結果、検索閾値単独の推定では、参加者間の個人差や複数指標の同時再現には限界があった一方で、オMISSIONエラー率やコミッションエラー時の反応時間など、一部の指標では一定の対応が認められた。これは、EMA で取得された Go/No-Go 課題成績の一部において、単なる反応時間やエラー率の集合としてではなく、個人ごとの潜在的な認知傾向および状態として表現しうる可能性を示すものである。すなわち、参加者ごとの課題成績の違いを、日常場面における個人の認知特性に関する内部パラメータを通じて

解釈するための出発点を与えるものといえる。

さらに、本研究では、推定された検索閾値と EMA において計測された気分指標との対応関係についても探索的に検討した。結果、一部のポジティブ感情指標と検索閾値の対応が示唆された。今後、個人内変動の水準も含め、より詳細な検討を行っていく必要がある。これにより、気分の変化が単に課題成績に影響するだけでなく、どのような内部パラメータを介して抑制制御に影響しているのかを定量的に議論できるようになる可能性がある。

ただし、本研究には、推定対象を検索閾値のみに限定したこと、用いた課題がモデルで前提とされていた課題よりも短時間であったこと、およびパラメータ探索範囲やシミュレーション回数が限定的であったことなどの限界がある。また、回答時刻や睡眠時間、実施場所などの文脈変数の扱いも今後の課題である。

今後は、抑制失敗により直接関与する別のパラメータや、注意状態の変動を適切に表現できる構成を導入するとともに、探索条件を改善することで、Go/No-Go 課題成績の個人差をより包括的に記述できるモデルへと発展させる必要がある。それにより、EMA 下で反復測定される認知課題の成績を、日常場面における潜在的な認知傾向として記述する枠組みの構築につながると考えられる。

#### 文 献

- Anderson, J. R. (2007). *How Can the Human Mind Occur in the Physical Universe?* Oxford University Press.
- Cheyne, J. A., Carriere, J. S., & Smilek, D. (2009). Absent minds and absent agents: Attention-lapse induced alienation of agency. *Consciousness and Cognition*, 18 (2), 481–493.
- Gable, P. A., & Harmon-Jones, E. (2008). Approach-motivated positive affect reduces breadth of attention. *Psychological science*, 19 (5), 476–482.
- 宮田 陵司・岡田 享大・大崎 拓・河田 進雅・David Marcusson-Clavertz・金 鎮赫 (2025). 日常変動からみる気分と認知機能の双方向性 第 23 回情報学ワークショップ (WiNF2025) 抄録集, p. 45.
- 宮田 陵司 (2026). 日常変動からみる気分と認知機能の双方向性 修士論文, 静岡大学総合科学技術研究科.
- Peebles, D., & Bothell, D. (2004). Modelling Performance in the Sustained Attention to Response Task. *Proceedings of the Sixth International Conference on Cognitive Modeling*, pp. 231–236.
- Rowe, G., Hirsh, J. B., & Anderson, A. K. (2007). Positive affect increases the breadth of attentional selection. *Proceedings of the National Academy of Sciences*, 104 (1), 383–388.
- Shiffman, S., Stone, A. A., & Hufford, M. R. (2008). Ecological Momentary Assessment. *Annual Review of Clinical Psychology*, 4, 1–32.
- 新堀 耕平・西川 純平・長島 一真・森田 純哉 (2023). ACT-R を用いた記憶エラーのモデル化による人間の内部状態推定 日本認知科学会第 40 回大会論文集, pp. 558–561.
- van Vugt, M., Taatgen, N., Sackur, J., & Bastian, M. (2015). Modeling Mind-Wandering: A Tool to Better Understand Distraction. In N. Taatgen, M. van Vugt, J. Borst, & K. Mehlhorn (Eds.), *Proceedings of the 13th International Conference on Cognitive Modeling*, pp. 252–257.