

Web実験を用いたカテゴリー学習課題における行動特性と精神疾患傾向との関連性に関する探索的研究

An Exploratory Study of the Relationship between Behavioral Characteristics in a Category Learning Task and Mental Illness Tendency Using a Web Experiment

中川 渉*, 山下 祐一†, 谷口 忠大‡, 岡田 幸之*, 高橋 英彦*

Wataru Nakagawa, Yuichi Yamashita, Tadahiro Taniguchi,
Takayuki Okada, Hidehiko Takahashi

* 東京医科歯科大学 医歯学総合研究科, † 国立精神・神経医療研究センター, ‡ 立命館大学 情報理工学部

Division of Cognitive and Behavioral Sciences, Tokyo Medical and Dental University

National Center of Neurology and Psychiatry

Information Science and Engineering, Ritsumeikan University

watnpsyc@tmd.ac.jp

概要

本研究では、混合ガウスモデルから生成した画像を用いてカテゴリー学習課題を行った。変分推論を用いて最適な行動をモデル化し、課題における行動と精神疾患傾向との関連を調査したところ、モデルとの乖離度と注意欠陥多動性障害の傾向との間に有意な負の相関を認めたほか、自閉症スペクトラム障害の傾向との間にも有意な負の相関が存在する傾向を認めた。

キーワード：カテゴリー学習, 精神疾患傾向, 計算論的表現型, 計算論的精神医学, モデル化, Web 実験

1. はじめに

自身が経験したことをカテゴリー化し分類する能力は乳児期より認められており、それは種々の認知機能の発達における基礎となっている [1, 2]。自閉症スペクトラム障害 (ASD) や注意欠陥多動性障害 (ADHD) といった認知発達に関する精神疾患においてはこの能力が障害されていることが知られており [3, 4]、特に前者においてはその障害が独特の認知や社会適応における問題と関連していることも指摘されている [3]。一方で、カテゴリー学習能力の変調との関連は統合失調症などの後天的に発症する疾患についても指摘されており [5]、患者の社会生活における困難感や、治療過程で生じる困難などとの関連が報告されている。このように、カテゴリー学習能力の障害は疾患横断的に存在しており、その解明には DSM-5 (精神疾患の診断・統計マニュアル) や ICD-10 (国際疾病分類) といった従来の疾患分類に囚われない新たな視点が求められる。

一方でカテゴリー学習能力の障害の機序に関しては、計算論的アプローチが注目を集めつつある。こ

のアプローチは従来の検査手法では観測できない個人の特性を記述できる可能性があり、例えば Huang-Pollock らは、数理モデルを用いて ADHD 児におけるカテゴリー学習能力の障害について報告を行っている [4]。このような研究はカテゴリー学習能力の障害について新たな知見を与えているものの、その障害の程度を数理的に評価することはできていない。

そこで本研究では、数理モデルを用い、疾患横断的な視点からカテゴリー学習能力の障害について評価することを目指す。本研究で用いるのは計算論的表現型同定 (computational phenotyping) [6] と呼ばれる手法であり、この手法は課題を解くに当たっての意思決定や知覚・認知プロセスを数理モデルとして記述し、行動・生理学的なデータをよく説明するパラメータを推定することを目的としている。

本研究では、カテゴリー分類課題で用いる画像を混合ガウスモデルから生成する。このように画像を特定のモデルから生成することで、分類課題をパラメータの最尤推定として表現することが可能となる。この課題における基準モデルを変分推論を用いて作成し、その基準モデルからの乖離度を算出することにより、個人の特性を評価する。また、その乖離度と精神疾患傾向との関連性を調査する。このように、カテゴリー学習能力について、数理モデルを用い疾患横断的に評価を行った研究は筆者の知る限り存在せず、カテゴリー学習能力の障害について新たな知見が得られることが期待される。

本研究の貢献は以下である。

- カテゴリー学習課題における行動を、

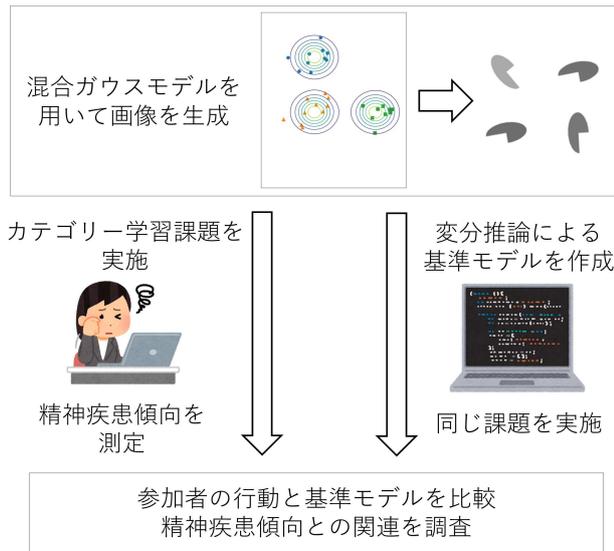


図 1: 実験の流れ

混合ガウスモデルを用いて数理的に表現した。

- カテゴリー学習能力の障害を、変分推論によるモデルからの乖離度として評価した。
- 上記の評価を疾患横断的に行い、その比較を行うことで障害の機序について説明した。

2. 準備

本研究の流れは図1のようになっており、混合ガウスモデルから生成した画像をカテゴリー学習課題で用いることにより、参加者の行動を数理モデルで表現する。モデル化にあたっては、参加者は「提示された画像は混合ガウスモデルから生成されている」という認識を予め有しており、他のモデルは想定していないものと仮定している。この仮定により、参加者の課題における行動を、混合ガウスモデルのパラメータの最適化とみなすことが可能となる。以下、実験の前提となる混合ガウスモデルについて、及び参加者の行動と比較する基準モデルについて説明する。

2.1 混合ガウスモデル

混合ガウスモデルのグラフィカルモデルは、図2のようになっている。このモデルは K 個のガウス分布からなっており、観測されるデータ $\mathbf{O} = \{\mathbf{o}_1, \mathbf{o}_2, \dots, \mathbf{o}_N\}$ 1 つ 1 つに対し、分類のためのラベル $\mathbf{C} = \{c_1, c_2, \dots, c_N\}$ が割り振られている。各ガウス

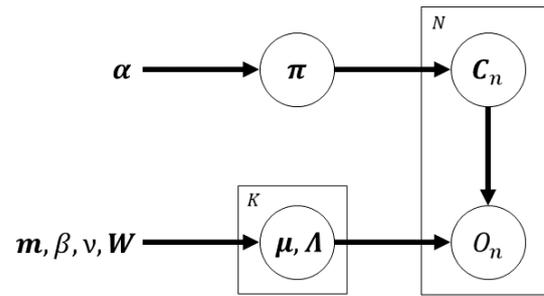


図 2: 混合ガウスモデルのグラフィカルモデル

分布での平均を $\boldsymbol{\mu} = \{\boldsymbol{\mu}_1, \boldsymbol{\mu}_2, \dots, \boldsymbol{\mu}_K\}$ 、精度行列を $\boldsymbol{\Lambda} = \{\boldsymbol{\Lambda}_1, \boldsymbol{\Lambda}_2, \dots, \boldsymbol{\Lambda}_K\}$ と表記する。また $\boldsymbol{\mu}_k, \boldsymbol{\Lambda}_k$ の分布はガウス・ウィシャート分布に従うとする。 \mathbf{C} の分布は混合率 $\boldsymbol{\pi}$ をパラメータとしたカテゴリ分布に従っており、その $\boldsymbol{\pi}$ の分布はディリクレ分布に従うとする。これを数式で表すと、

$$\begin{aligned}
 p(\mathbf{o}_n | c_n, \boldsymbol{\mu}, \boldsymbol{\Lambda}) &= \prod_{k=1}^K \mathcal{N}(\mathbf{o}_n | \boldsymbol{\mu}_k, \boldsymbol{\Lambda}_k^{-1})^{c_{n,k}} \\
 p(c_n | \boldsymbol{\pi}) &= \text{Cat}(c_n | \boldsymbol{\pi}) \\
 p(\boldsymbol{\pi} | \boldsymbol{\alpha}) &= \text{Dir}(\boldsymbol{\pi} | \boldsymbol{\alpha}) \\
 p(\boldsymbol{\mu}_k, \boldsymbol{\Lambda}_k) &= \text{NW}(\boldsymbol{\mu}_k, \boldsymbol{\Lambda}_k | m, \beta, \nu, \mathbf{W}) \\
 &= \mathcal{N}(\boldsymbol{\mu}_k | m, (\beta \boldsymbol{\Lambda}_k)^{-1}) \mathcal{W}(\boldsymbol{\Lambda}_k | \nu, \mathbf{W})
 \end{aligned}$$

となる (c_n は $c_k \in \{0, 1\}$ かつ $\sum_{k=1}^K c_k = 1$ である one-hot ベクトルで表現している)。

2.2 基準モデル

本研究では、カテゴリー学習課題における研究参加者の行動を変分推論を用いてモデル化する。すなわち参加者のカテゴリー学習課題における行動を、「各セットのデータが生成される元となった混合ガウスモデルのパラメータ、及び各画像に対するラベルの分布の最適解を、変分推論を用いて近似的に求める」と置き換える。

変分推論は、Friston によって提唱された自由エネルギー原理 (Free Energy Principle) のもととなった統計学的手法である [7]。変分推論は真の分布と近似事後分布との誤差を最適化する手法であるが、Friston はこれを自律思考するエージェントの行動に見立て、そのようなエージェントは押しなべて変分自由エネルギー、すなわち予測誤差を最小化するように行動すると考えた [7]。このように思考のプロセスを予測誤差

の最小化という情報処理として取り扱う予測符号化 (predictive coding) の理論は近年で最も有力視されている脳の計算理論であり、精神疾患の理解にも貢献が期待されている。本研究でもこれを援用し、変分推論を課題における基準モデルとして採用した。以下、具体的な計算について述べる。

i 回目の試行の開始時、研究参加者は $i - 1$ 回目の試行における混合ガウス分布の各パラメータ $\mu^{i-1}, \Lambda^{i-1}, \pi^{i-1}$ (1 回目の試行ではパラメータの初期値) をもとに、画像につけるラベル C^i の事前分布を得る。

$$c_n^i \sim \text{Cat}(c_n^i | o_n, \mu^{i-1}, \Lambda^{i-1}, \pi^{i-1})$$

次に、この分布の期待値を用いて μ^i, Λ^i, π^i の近似事後分布 $q(\mu^i | \Lambda^i), q(\Lambda^i), q(\pi^i)$ を得る。

$$\begin{aligned} q(\mu_k^i | \Lambda_k^i) &= \mathcal{N}(\mu_k^i | O, C^i, \Lambda_k^i) \\ q(\Lambda_k^i) &= \mathcal{W}(\Lambda_k^i | O, C^i) \\ q(\pi^i) &= \text{Dir}(\pi^i | C^i) \end{aligned}$$

そして、これらの近似事後分布を用いてラベル C^i の近似事後分布 $q(c_n^i)$ を得る。

$$q(c_n^i) = \text{Cat}(c_n^i | o_n, \mu^i, \Lambda^i, \pi^i)$$

以後、この近似事後分布の期待値を用いて再び $q(\mu_k^i | \Lambda_k^i), q(\Lambda_k^i), q(\pi^i)$ を更新し、それらを用いて $q(c_n^i)$ を更新する、というプロセスを既定のイテレーション数繰り返す。最終的に各画像 o_n につけるラベル c_n^i は、最終的に得られた近似事後分布 $q(c_n^i)$ の期待値が最大となるラベルとする。そして最終的なラベル C^i をもとに、各パラメータの最終的な分布を以下のように導出する。

$$\begin{aligned} \mu_k^i &= \mathcal{N}(\mu_k^i | O, C^i, \Lambda_k^i) \\ q(\Lambda_k^i) &= \mathcal{W}(\Lambda_k^i | o, C^i) \\ q(\pi^i) &= \text{Dir}(\pi^i | C^i) \end{aligned}$$

上記の分布の期待値を最終的な μ^i, Λ^i, π^i とし、これらを $i + 1$ 回目の試行におけるラベル C^{i+1} の事前分布の計算に用いる。このアルゴリズムを疑似コードにすると、表 1 のようになる。

本研究では、カテゴリー数 $K = 3$ 、データ数 $N = 30$ となる。ハイパーパラメータの設定は $m = (90.0, 125.0), \beta = 0.05, \nu = 2, \mathbf{W} = \begin{pmatrix} 0.005 & 0 \\ 0 & 0.05 \end{pmatrix}, \alpha = (5.0, 5.0, 5.0)$ とし、イテレーション数 $J = 50$ とする。

表 1: 基準モデルの疑似コード

```

1: Initialize all parameters
2: for i = 1 to N do
3:   for n = 1 to i do
4:      $c_n^i \sim \text{Cat}(c_n^i | o_n, \mu^{i-1}, \Lambda^{i-1}, \pi^{i-1})$ 
5:   for j = 1 to J do
6:     for k = 1 to K do
7:        $q(\Lambda_k^i) = \mathcal{W}(\Lambda_k^i | C^i, O)$ 
8:        $q(\mu_k^i | \Lambda_k^i) = \mathcal{N}(\mu_k^i | \Lambda_k^i, C^i, O)$ 
9:        $q(\pi^i) = \text{Dir}(\pi^i | C^i)$ 
10:    end for
11:   for n = 1 to i do
12:      $q(c_n^i) = \text{Cat}(c_n^i | o_n, \mu^i, \Lambda^i, \pi^i)$ 
13:   end for
14: end for
15: for n = 1 to i do
16:    $c_n^i = \text{argmax}_{c_n^i} E[q(c_n^i)]$ 
17: end for
18: for k = 1 to K do
19:    $\Lambda_k^i = E[\mathcal{W}(\Lambda_k^i | C^i, O)]$ 
20:    $\mu_k^i = E[\mathcal{N}(\mu_k^i | \Lambda_k^i, C^i, O)]$ 
21:    $\pi^i = E[\text{Dir}(\pi^i | C^i)]$ 
22: end for
23: end for

```

3. 方法

参加者は、東京医科歯科大学医歯学総合研究科、国立精神・神経医療研究センター、立命館大学情報理工学部 に所属する大学院生及び学生を対象に募集した。参加者への謝礼は無しとした。

研究参加者はカテゴリー学習課題を行った後、精神疾患傾向に関する質問紙に回答した。本研究は全て web ベースで行われ、参加者は自身の所有するコンピュータなどから研究用の web ページにアクセスし、研究に参加した。

研究に用いるアプリは oTree[8] を用いて作成した。oTree とは python を用いたフレームワークの一つであり、囚人のジレンマゲームなど、インタラクションのある経済学の実験用に web アプリを作る目的で開発されたものである。簡便に web アプリを作成できる有用さから、今回はこれを用いることとした。

3.1 カテゴリー学習課題

カテゴリー学習課題では、研究参加者は30個の画像セットを3つのカテゴリーに分類するというタスクを行った。第1、第3のセットは楕円形、第2のセットは円形の画像を用いた。

3.1.1 課題に用いる画像

データセットは3セット作成した。各セットの画像は3つの2次元ガウス分布からなる混合ガウス分布から生成しており、その分布はセットごとに設定した(図4)。本研究では大きく分けて2種類の画像を用いており、セット1・3では楕円形の画像を、セット2では円形の画像を用いた。これは、課題に用いる画像の差異による影響を検討するためである。

セット1・3での変数は、楕円の濃淡及び角度とした。角度に関しては負の数値も許容したが、 x° 回転と $(x+360)^\circ$ 回転は同じ図形となるため、データの幅が360を超えないよう調整した。また線対称性のある図形だと x° 回転と $(x+180)^\circ$ 回転も同じ図形になってしまうため、1/4が欠けた楕円形とすることで線対称性をなくした。セット2での変数は、円の濃淡及び直径とした。画像はopenCVを用いて描画した。

各セットにおけるカテゴリーごとのデータ数、変数の平均値・分散共分散行列は表2の通りである。作成した画像の一覧とその分布は、それぞれ図3と図4の通りである。カテゴリー1~3は、それぞれ図4の散布図の丸、三角、四角のプロットに対応している。散布図からわかるように本研究ではセット間で分類の難易度を変えており、セット2はセット1より各カテゴリーの平均値の差を少なく設定し、セット3は分散の大きいカテゴリーを設定することで、難易度を上げている。

3.1.2 課題の内容

課題は図5のようになっており、全30試行から構成される。表示される画像は試行が進むごとに1つずつ増え、30試行目ではすべての画像が表示される。

参加者はこの表の中に画像をドラッグし、分類を進めていく。図5は2回目の試行を表しているが、既に表の中に分類されている画像(1回目の試行で表示された画像)も分類しなおすことが可能となっている。30個すべての画像を表のどこかに分類し、結果を確

表2: 各セットのパラメータ

(a) セット 1				
	データ数	平均		分散共分散行列
		角度 ($^\circ$)	色	
カテゴリー 1	10	70	190	$\begin{pmatrix} 256 & 0 \\ 0 & 256 \end{pmatrix}$
カテゴリー 2	10	70	110	$\begin{pmatrix} 256 & 0 \\ 0 & 256 \end{pmatrix}$
カテゴリー 3	10	150	110	$\begin{pmatrix} 256 & 0 \\ 0 & 256 \end{pmatrix}$

(b) セット 2				
	データ数	平均		分散共分散行列
		直径	色	
カテゴリー 1	10	140	180	$\begin{pmatrix} 256 & 0 \\ 0 & 256 \end{pmatrix}$
カテゴリー 2	10	220	180	$\begin{pmatrix} 256 & 0 \\ 0 & 256 \end{pmatrix}$
カテゴリー 3	10	220	110	$\begin{pmatrix} 256 & 0 \\ 0 & 256 \end{pmatrix}$

(c) セット 3				
	データ数	平均		分散共分散行列
		角度 ($^\circ$)	色	
カテゴリー 1	10	70	170	$\begin{pmatrix} 256 & 0 \\ 0 & 600 \end{pmatrix}$
カテゴリー 2	10	150	190	$\begin{pmatrix} 256 & 0 \\ 0 & 256 \end{pmatrix}$
カテゴリー 3	10	150	110	$\begin{pmatrix} 256 & 0 \\ 0 & 256 \end{pmatrix}$

定すると次のセットでの課題に移行する。

画像の並び順は参加者間で同一であり、その並び順は参加者をミスリードするように調整されている。例えばセット1では、色の濃さを基準に選ぶとカテゴリー2と3を、角度を基準に選ぶとカテゴリー1と2を混同する可能性があるため、それを誘発するように画像を並べている(図6)。また、セットの順序も参加者間で同一であり、セット1、2、3の順としている。

3.1.3 基準モデルとの比較

基準モデルからの乖離度は、人間と同じ初期値を用いて変分推論を行い、その結果得られたラベルと、実際の回答との Adjusted Rand Index (ARI) をもとに算出した。具体的な算出方法は以下の通りである。

まず各試行ごとに、一つ前の試行での回答 C^{i-1} からパラメータ $\mu^{i-1}, \Lambda^{i-1}, \pi^{i-1}$ を計算し、これらを用いてラベル C^i の事前分布の期待値、すなわちモデルにおける推論の初期値を算出した。この初期値を用いて変分推論を行い、最終的に得られた近似事後分布

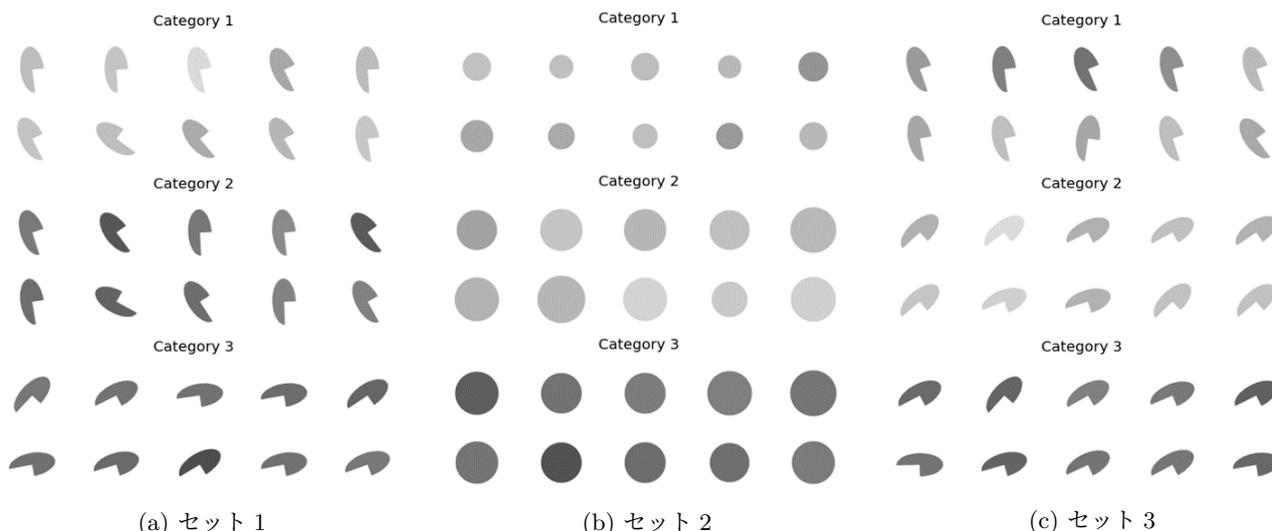


図 3: 画像一覧

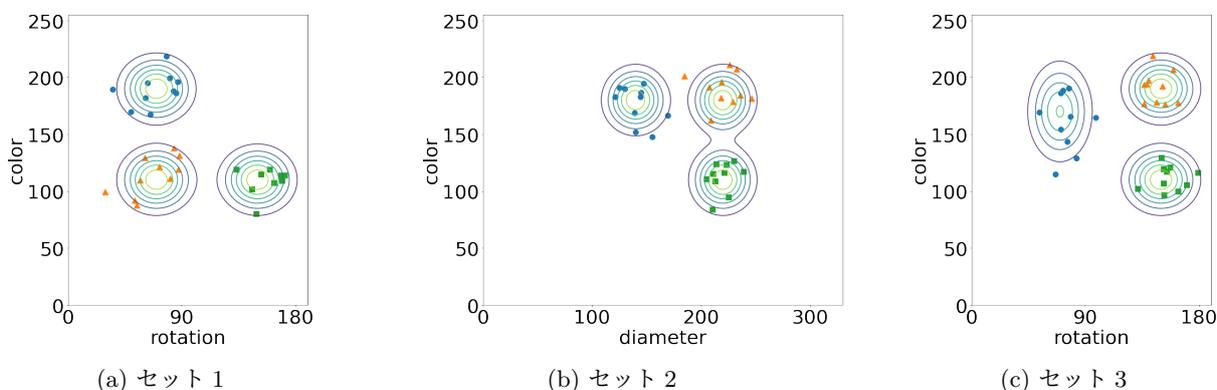


図 4: 各データセットにおけるデータの分布



図 5: 課題の例

$q(c_n^i)$ の期待値が最大となるラベルを「モデルによるラベル」とした。このラベルと、実際の回答 C^i との ARI を求め、その平均値を求めることにより、モデルからの乖離度を算出した。なお 1 回目の試行はこの方法により C^1 の分布を計算することができないため、乖離度の計算には用いなかった。

3.2 精神疾患傾向の調査

精神疾患傾向の調査には、Schizotypal Personality Questionnaire-Brief (SPQ-B)、Autism-Spectrum Quotient (AQ)、Adult ADHD Self-Reports Scale (ASRS) の 3 種の自記式検査を用いた。

3.2.1 SPQ-B

SPQ-B は統合失調型パーソナリティ障害のスクリーニングに用いられる検査である。統合失調型パーソナリティ障害は、統合失調症の診断基準に当てはまるほどではないが、風変りな行動や疎通性の乏しさ、猜疑的な態度など、それに準ずる性格傾向を有するという特徴がある。DSM-5[9] では「統合失調症スペクトラム障害」の一部として記載されており、この障害が統

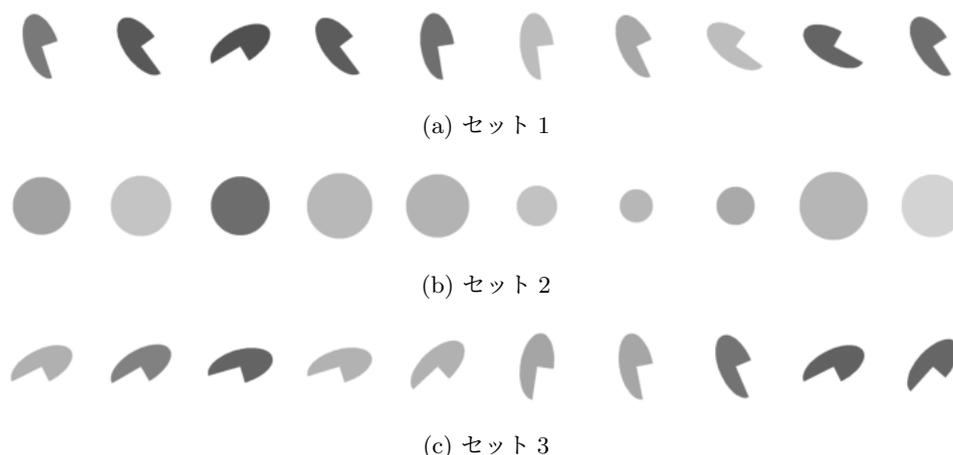


図 6: 並び順の例（最初の 10 個ずつを抜粋）
例えばセット 1 では、最初の 5 個で色の濃淡に意識が向くように並べてある。

合失調症と共通の遺伝基盤を持つことも示唆されている [10]。本研究でもこの考えに基づき、SPQ-B の得点は統合失調症スペクトラム障害の程度を示すものとみなす。

3.2.2 AQ

AQ は ASD のスクリーニングに用いられる検査である。ASD とは、コミュニケーションの質的障害、興味・関心の限局、常同的・反復的行動を特徴としている。50 点中 26 点以上であれば ASD の疑いがあるとされるが、この疾患は疾患名が表しているようにスペクトラムをなしているため、本研究ではカットオフ値で区切るのではなく、得点が障害の程度に比例すると考え、連続する変数として用いる。

3.2.3 ASRS

ASRS は ADHD のスクリーニングに用いられる検査である。ADHD は、不注意症状と衝動制御の困難さを特徴としている。72 点中 36 点以上であれば ADHD の疑いがあるとされるが、こちらも AQ と同様、得点は連続する変数として用いる。

4. 結果

4.1 参加者

13 名が実験に参加したが、うち 2 名が心理検査を完遂できなかったため、11 名分のデータを解析に用いた。

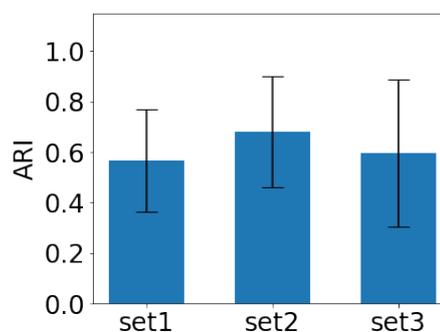


図 7: 参加者の分類精度

表 3: 参加者の ARI の平均値及び標準偏差

	平均	標準偏差
セット 1	0.57	0.20
セット 2	0.68	0.22
セット 3	0.59	0.29

4.2 カテゴリー学習課題での成績

4.2.1 分類精度

分類結果の精度評価には、正解ラベルと、各試行において参加者がつけたラベルとの ARI を用いた。各セットにおける正解ラベルとの ARI の平均値は図 7 及び表 3 の通りであり、各セット間で有意差は見られなかった。

4.3 精神疾患傾向との関連性

4.3.1 分類精度との関連

最終的な分類精度（最終の試行におけるラベルと正解ラベルとの ARI）と、精神疾患傾向との関連を調査した結果は図 8 及び表 4 の通りであり、どのデータセットにおいても、いずれの精神疾患傾向とも有意な相関は認められなかった。

4.3.2 基準モデルとの比較

基準モデルからの乖離度と精神疾患傾向との相関関係を調査したところ、結果は図 9 及び表 5 のようになり、セット 3 において、ASRS スコアとの間に有意な負の相関を認めた ($r = -0.636, p = 0.035$)。また AQ スコアに関しても、有意な相関は得られなかったが、セット 1 ($r = -0.589, p = 0.056$) とセット 3 ($r = -0.543, p = 0.085$) において負の相関が存在する傾向を認めた。

5. 考察

モデルからの乖離度と精神疾患傾向との関連に関しては、セット 3 において ASRS スコアとの間に有意な負の相関が認められた。Huang-Pollock らは COVIS モデル (the Competition between Verbal and Implicit Systems model) [11] に基づき、カテゴリー学習能力を、明確に言語化できるルールに基づいて分類する機構 (rule-based) と、潜在的な情報を統合して分類する機構 (information-integration) に分け [12]、ADHD を有する小児のカテゴリー学習能力について実験を行った [4]。その結果、ADHD を有する小児は健常群と比べてその能力に障害がみられるという結果が得られ、その理由として、ADHD 者は突出した特徴に固執してしまいがちであること (rule-based の機構の障害)、及び複数の特徴を同時に考慮に入れて分類を行

うことが困難であること (information-integration の機構の障害) が挙げられた [4]。本研究の分類課題は色と角度、もしくは色と直径という 2 つの分類基準を両方用いなければ正しい分類はできないため、後者の理由は本研究にも当てはまる可能性がある。しかし、単に分類基準が複数あることが乖離度が増加した理由であるならばセット 2 においてもある程度の相関関係があつて然るべきであり、セット 2 で有意な相関がみられなかったことからすれば、本研究における結果を説明できるのは前者の「突出した特徴に固執する」という傾向であると考えられる。図 6 の通り、セット 3 では初めに傾きが同じ画像を連続して表示している (図 6a) のに対し、セット 2 (図 6b) では初めに直径が同じ画像を連続して表示している。前者の「角度」という刺激はその後の判断をある程度拘束するほど強く、後者の「直径」の方はそれほどではなかったと考えれば、本研究の結果は主に rule-based の機構の障害の文脈で説明ができる。

また AQ スコアに関しても、モデルからの乖離度との有意な相関は認められなかったが、セット 1 とセット 3 において負の相関が存在する傾向を認めた。ASD を持つ者は顔の認識が苦手であったり、漠然とした概念を獲得していくことが困難であったりすることはよく知られているが、Mercado らの報告によれば、人工的に形成されたカテゴリーを学習するという課題において、ASD 者が健常者より劣っているかについては明確な結論が出ていない [3]。しかし一方で、ASD 者は認知の切り替えが健常者に比して困難であることが言われており、それは言い換えれば、突出した刺激にその後の分類基準が拘束されてしまうことを意味する。AQ スコアについても、ASRS スコアと同様、セット 2 では有意な相関がみられなかった一方でセット 3 においては有意な負の相関が存在する傾向が認められており、この差を考えれば上記の議論と同様に、ASD 者におけるカテゴリー学習能力の障害もまた、rule-based

表 4: 精神疾患傾向と分類精度との関係

		相関係数	p 値
セット 1	SPQ-B	-0.145	0.671
	AQ	-0.124	0.716
	ASRS	-0.252	0.454
セット 2	SPQ-B	-0.433	0.183
	AQ	0.050	0.885
	ASRS	0.108	0.751
セット 3	SPQ-B	-0.388	0.238
	AQ	-0.259	0.441
	ASRS	-0.541	0.086

表 5: 精神疾患傾向と基準モデルとの乖離度の関係

		相関係数	p 値
セット 1	SPQ-B	-0.117	0.732
	AQ	-0.589	0.056†
	ASRS	-0.304	0.363
セット 2	SPQ-B	0.001	0.998
	AQ	-0.133	0.696
	ASRS	-0.045	0.896
セット 3	SPQ-B	-0.444	0.172
	AQ	-0.543	0.085†
	ASRS	-0.636	0.035*

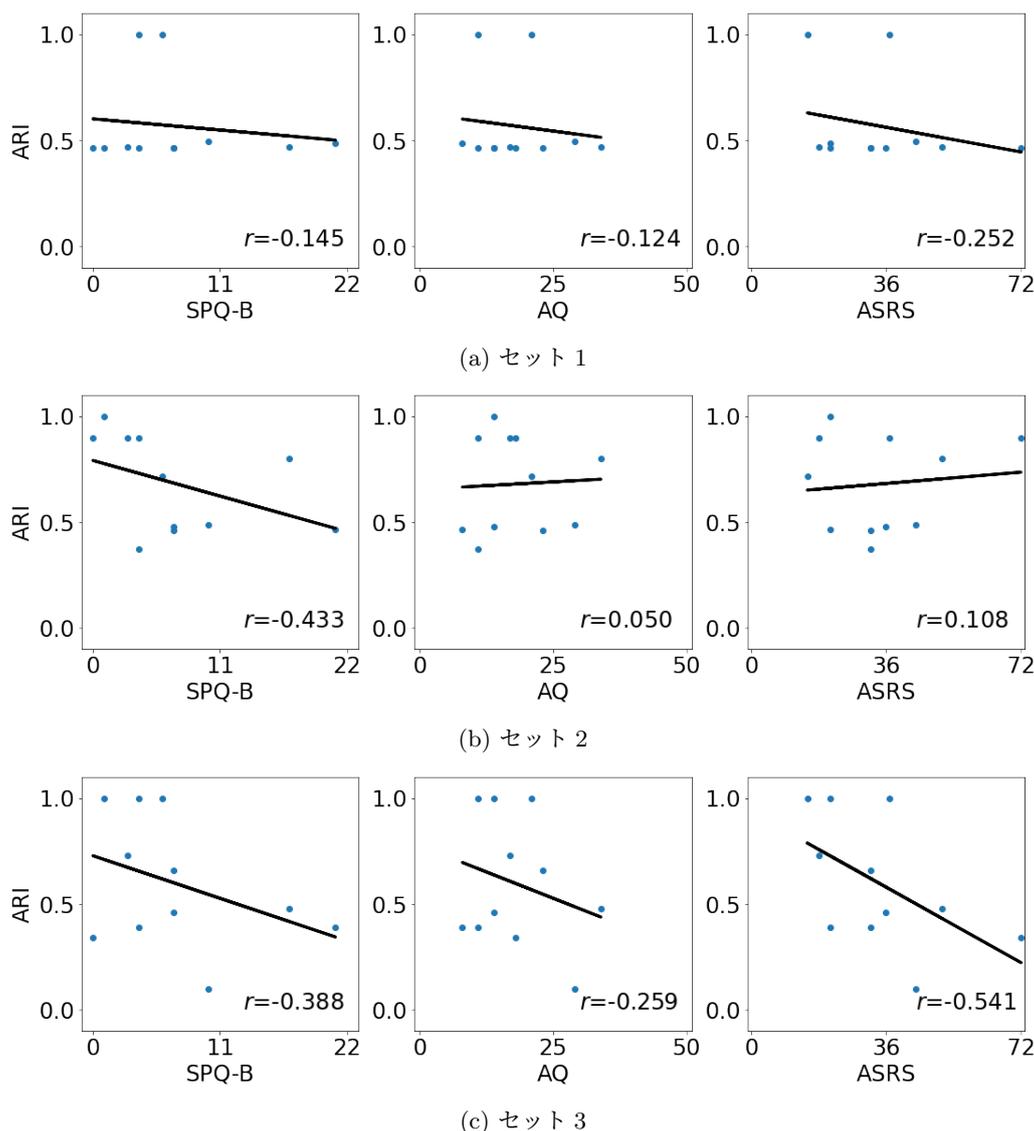


図 8: 精神疾患傾向と分類精度との関係
 分類精度は、いずれの精神疾患傾向とも有意な相関を認めなかった。

の機構の障害として説明することができる。

この rule-based の機構の障害は、数理モデルを用いて説明することが可能である。セット 3 において、ASRS が高値 (72/72 点) であった参加者と低値 (21/72 点) であった参加者の、各試行ごとの分類精度の推移は図 10a 及び図 10b のようになっている。本研究の課題を遂行するにあたっては、途中でそれまでの分類基準を一度考え直す必要があり、モデル上ではこれはパラメータの初期化にあたる。この観点から改めて図 10 を見てみると、図 10b では終盤で急激に ARI が上昇しており、ここで誤った分類基準を破棄し、正解の分布を導き出したと考えられる。実際に一切パラメータをリセットしないモデルを用いてセット 3 の分類を計算機上で行うと、ARI の推移は図 10c のよう

になり、図 10a との類似性が認められる。このことから、rule-based の機構の障害は、パラメータのリセットが困難であることと表現することができる。本研究における比較は各試行ごとに初期値をそろえて行われているため、結果に表れているのは試行ごとにパラメータを初期化するかどうかではなく、変分推論の過程でパラメータが更新される際、どの程度前の試行におけるパラメータの影響を受けるかという点であると推測される。ただしこの点に関しては本研究におけるモデルでは表現できないため、今後この点を考慮したモデルを用いてさらなる研究を行う必要がある。

なお、上記のような傾向はみられながらも、ASRS スコアも AQ スコアも分類精度そのものとの有意な相関は得られていない。これは、サンプル数が足りな

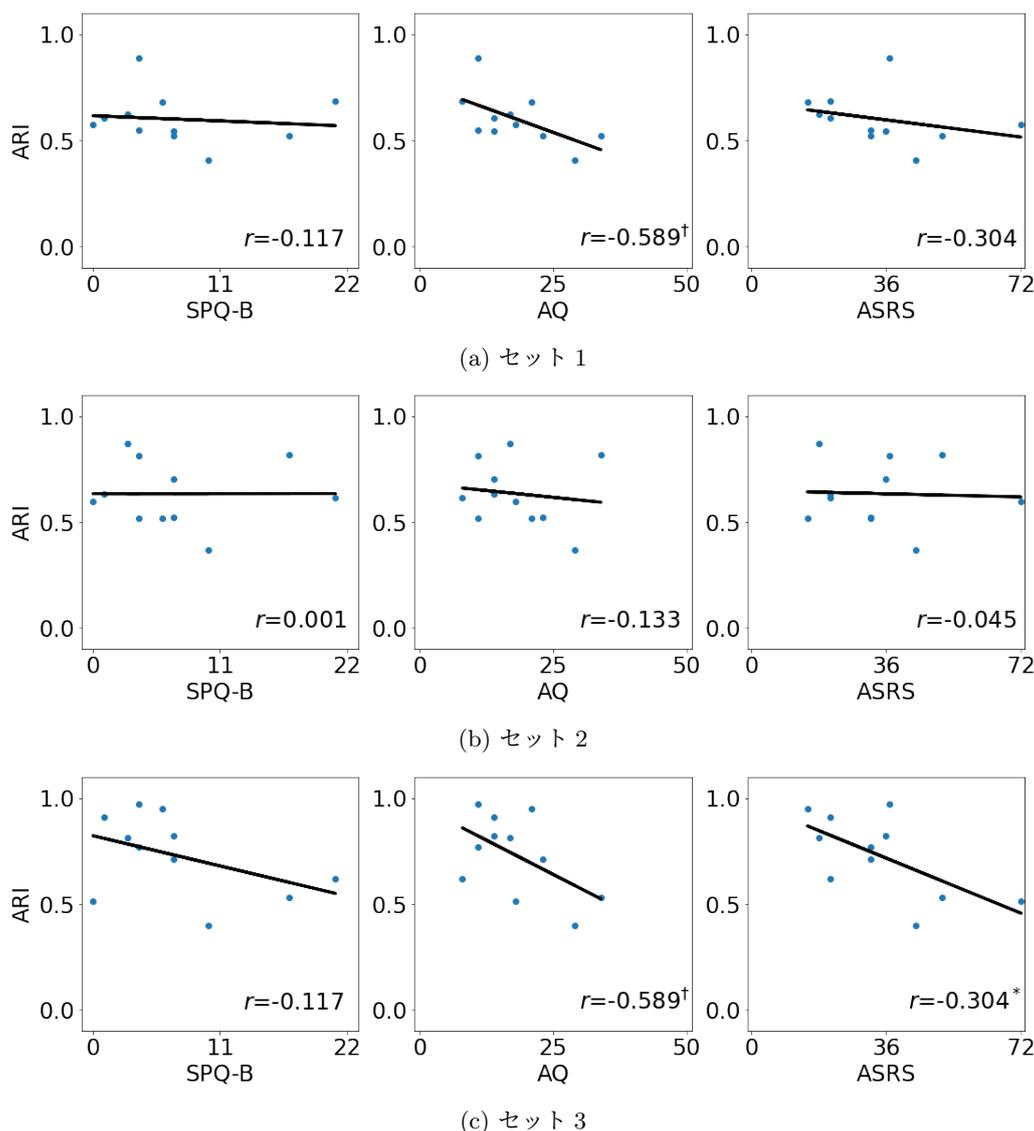


図 9: 精神疾患傾向と基準モデルとの乖離度の関係

セット 3 において、ASRS と有意な負の相関を認めた ($r = -0.636, p = 0.035$) (*). また、セット 1・3 において、AQ と有意な負の相関がある傾向を認めた (セット 1: $r = -0.589, p = 0.056$ 、セット 3: $r = -0.543, p = 0.085$) (†).

かっただけでサンプル数を増やせば有意な相関が得られるか、もしくはモデルからの乖離はあってもその影響度は最終的な分類精度を下げるほど強くはなかったかのいずれかであると考えられる。この点を検証するためには、サンプル数を増やして研究を行っていく必要がある。

6. 結語

本研究においては、ADHD の傾向と変分推論を用いたモデルからの乖離度に負の相関がみられたほか、ASD の傾向とモデルからの乖離度にも有意な負の相関が存在する傾向を認めた。しかし一方で、各精神疾患傾向と分類精度との間に有意な相関はみられなかつ

た。本研究はカテゴリ学習での行動を、疾患横断的な視点から、数理モデルで可視化した点に新規性があり、ADHD にみられる突出した特徴に固執してしまう傾向、および ASD にみられる認知の切り替えの困難さを、rule-based の機構の障害として説明した。

本研究ではサンプル数が少なく、そのサンプル集団も一般人口を代表しているとは言えない。今回得られた結果が一般人口においても得られるかどうかは、サンプル数を増やして研究を行う必要がある。また、本研究の課題におけるカテゴリはあくまで人工的に形成されたものであり、得られた結果を日常生活の中で用いられるカテゴリ学習能力にまで一般化することには慎重になる必要がある。

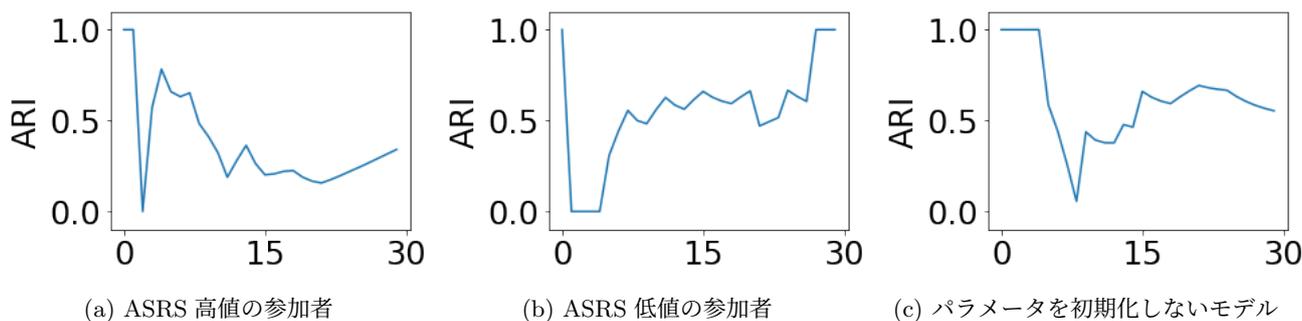


図 10: ASRS が高値である参加者と低値である参加者、及び計算機上の結果の比較

(a) は ASRS=72 点、(b) は ASRS = 21 点。(a) の ARI の推移は、パラメータを初期化しないモデル (c) と類似している。

今後は、1000 人程度の大規模なサンプルを対象に研究を行っていく。また、カテゴリー学習能力の障害は本研究で取り上げた精神疾患以外にも、例えば摂食障害 [13] などの疾患についても指摘されているため、今後の研究においては摂食障害や不安障害、抑うつ状態などの心理検査も施行し、より広範に精神疾患傾向との関連を調査する。

ropsychologia 48, 2998–3008, 2010

- [13] Filoteo J.V. et al. : Simulating category learning and set shifting deficits in patients weight-restored from anorexia nervosa. *Neuropsychology*. Sep;28(5), 741-51, 2014

文献

- [1] Gopnik A. et al. : The development of categorization in the second year and its relation to other cognitive and linguistic development. *Child Dev.* 58, 1523–1531, 1987
- [2] Mareschal D. et al. : Categorization in infancy. *Trends Cogn. Sci* 5(10), 443-450, 2001
- [3] Mercado E. et al. : Perceptual category learning in autism spectrum disorder: Truth and consequences. *Neurosci. Biobehav. Rev.* 118, 2020
- [4] Huang-Pollock CL et al. : Rule-based and information-integration perceptual category learning in children with attention-deficit/hyperactivity disorder. *Neuropsychology*. Jul;28(4), 594-604, 2014
- [5] Weickert T.W. et al. Neural Correlates of Probabilistic Category Learning in Patients with Schizophrenia. *J. Neurosci.* 29(4), 1244 –1254, 2009
- [6] Montague P. et al. : Computational psychiatry. *Trends cogn Sci.* 16(1), 72-80, 2012
- [7] Friston K et al. : World model learning and inference. *Neural Netw* 144, 573-590, 2021
- [8] Chen D.L. et al. : oTree - An Open-Source Platform for Laboratory, Online, and Field Experiments. *J. Behav. Exp. Finance.* 9(1), 88-97, 2016
- [9] American Psychiatric Association : Diagnostic and Statistical Manual of Mental Disorders, fifth edition. American Psychiatric Association, Washington DC, 2013
- [10] Raine A. : Schizotypal personality: neurodevelopmental and psychosocial trajectories. *Annu Rev Clin Psychol.* 2, 291-326, 2006
- [11] Ashby F.G. et al. : A Neuropsychological Theory of Multiple Systems in Category Learning. *Psychol Rev* 105(3), 442-481, 1998
- [12] Maddox W.T. et al. : Rule-based and information-integration category learning in normal aging. *Neu-*