

Individual differences in category learning: Sometimes less working memory capacity is better than more

Marci S. DeCaro, Robin D. Thomas, Sian L. Beilock

Cognition, Vol. 107, No. 1, pp. 284–294, 2008

1. Introduction

- カテゴリ化はスキル習得・遂行に欠かせない重要な要素
 - 世界を意味のある単位に分解することを可能にする
 - 熟達者の知識構造 (Chi, Feltovich, & Glaser, 1981), 異なる刺激からの共通点抽出 (Barsalou, 1983) などの領域に深く関連
- 一方, ワーキングメモリ (WM) の個人差とカテゴリ構造発見の関係はあまり検証されていない
 - WM は記憶における情報の獲得・表象において重要な役目を果たす (Ashby & O'Brien, 2004)

1.1. Working memory

- WM は限られた情報を統制・制御・活性化維持するための短期システム (Miyake & Shah, 1999)
 - その容量には個人差がある
 - 実験環境・現実場面を問わず, 高いほど推論・問題解決・理解のパフォーマンスが高い (Conway et al., 2005)
- ただし, WM でパフォーマンスが予測できない場合もある
 - 例: 三段論法
 - > *Premises*: All mammals can walk. Dogs are mammals. *Conclusion*: Dogs can walk.
連想処理がより強く機能してしまうため, WM による差が生じない
 - > *Premises*: All mammals can walk. Dolphins are mammals. *Conclusion*: Dolphins can walk.
結論の信憑性が低いため, WM の高い人は正しく反応できる
- WM の高さがパフォーマンスを向上させる場合・させない場合は知られているが, 本研究ではカテゴリ学習における WM の影響について検証する
 - カテゴリ学習は複雑な仮説検証を伴うため, WM の高さが逆に阻害する可能性がある

1.2. Category learning

- 様々なカテゴリ構造を学習する際には, 複数の処理モードを同時並行で使い分けている (Zeithamova & Maddox, 2006)
 - ルールベースカテゴリ化 (rule-based categorization)

- > 言語的かつ論理的ルールを用いる問題解決
- > WM に依存する仮説検証による学習 (Waldron & Ashby, 2001; Zeithamova & Maddox, 2006)
- > 課題の提示直後や、ルール発見時には使用されやすいバイアスあり
- 情報統合カテゴリ化 (information-integration categorization)
 - > 複数次元の値の統合による問題解決
 - > 刺激-反応マッピングを同定する手続き学習 (Ashby & Maddox, 2005; Ashby & O'Brien, 2004)
 - > 単一ルールでパフォーマンス向上が見込めない場合に使用されやすい
- 結果の予測
 - WM の高さが、ルールベースカテゴリ構造の学習を促すだろう
 - > ルールベースカテゴリ化における仮説検証は、WM の核となる注意統制能力を必要とするため
 - WM の高さは、情報統合カテゴリ構造の学習とは無関係だろう
 - > 情報統合カテゴリ構造の手続き学習は、仮説検証をあてにしないため
 - もしくは WM の高さは、情報統合カテゴリ構造の学習を阻害するだろう
 - > WM が高いと仮説検証からルールベースカテゴリ構造の学習へ進んでしまうため
- 本研究では、WM の個人差が複雑な仮説検証・推論の処理能力に影響し、その仮説検証能力によってルールベースカテゴリ化課題と情報統合カテゴリ化課題のパフォーマンスに差が生じるかを検証する
 - WM の正の性質のみならず、負の性質にも着目

2. Current experiment

2.1. Method

2.1.1. Participants

- ミッドウェスタン大学の学部生 71 名¹

2.1.2. Procedure

Category learning task.

- キーボードを用いて、提示刺激をカテゴリ A または B に分類する課題
 - 200 試行×4 セット
 - > セット間には休憩があり、セットごとに新しいルールを学習するよう教示
 - > ルールベース課題 (R) と情報統合課題 (I) がそれぞれ 2 セットずつ
 - > セットの提示順は、セット 1・2 に R と I が含まれるよう調整し (i.e., RIRI, IRIR, RIIR, IIRI), 参加者間でランダムに割り振り

¹ おそらく外れ値除外後の人数

- 試行ごとに正誤フィードバックあり
- 提示刺激 (Waldron & Ashby, 2001)
 - 背景の四角と前景のシンボルで構成され、以下の4次元を組み合わせて全16種類の刺激を用意
 - > 背景四角の色 黄 / 青
 - > 前景シンボルの形 円 / 四角
 - > 前景シンボルの色 赤 / 緑
 - > 前景シンボルの数 1つ / 2つ
 - 課題によってカテゴリ構造が異なる
 - > ルールベース課題
 - * 1次元の値でカテゴリが決定
例: シンボルが円なら A, 四角なら B
 - * 言語化が容易
 - > 情報統合課題
 - * 3次元の値を+1 / -1に置き換え、その合計でカテゴリが決定
例: シンボルが円 (+1), 緑 (-1), 1つ (+1) で合計が0以上のため A, もし0未満なら B
 - * 言語化が困難
- 課題終了後、遂行時に感じた重圧の大きさを7件法で評定
 - 1(重圧がほぼなかった) ~ 7(重圧が非常にあった)
 - 遂行時の重圧がカテゴリ学習に影響する (Markman et al., 2006)

Working memory tasks.

- 分類課題を終了後、WM測定を実施
- 2種類の測定方法を使用
 - Automated Operation Span (Aospan; Turner & Engle, 1989; Unsworth, Heitz, Schrock, & Engle, 2005)
 - > 計算の真偽判定をしながら文字を記憶し、その後に文字を系列再認
例: $(1 * 2) + 1 = ?$ “M”
 - Automated Reading Span (Arspan; Daneman & Carpenter, 1980)
 - > 文章の真偽判定をしながら文字を記憶し、その後に文字を系列再認
例: Stacey stopped dating the light when she found out he had a wife. “L”
- 1セットの流れ
 - 提示された計算または文章について、真偽をマウスクリックで回答

- > 練習試行の回答時間に基づいた制限時間あり (リハーサル防止のため)
- > 正誤フィードバックあり
- 800 ms 提示される文字を記憶
- 上記を 3~7 試行繰り返した後, 記憶した文字の系列再認
 - > 提示された 12 文字から提示順に選択
 - > 正誤フィードバックあり
- 15 セット (全 75 試行) をランダム順で実施
- 真偽判定・系列再認ともに正答率 85%以上を目指すように事前に教示

3. Results

- WM 得点 (系列再認の正答試行数) $M = 45.49$, $SE = 1.9$
 - 正答率が 85%未満の 11 名を除外
 - > 除外前後でデータパターンに変化なし
- WM 得点と重圧評定 ($M = 3.82$, $SE = .16$) に相関なし ($r = .13$, $p = .29$)
 - WM 得点を重圧評定から説明することは困難
- カテゴリ構造発見までに要した試行数について, 回帰分析を実施 (Figure 1)
 - 説明変数: WM 得点, カテゴリ構造 (ルールベース / 情報統合; ダミー変数を使用)
 - 4 種類のルールすべてを 200 施行までに発見し, かつ発見までの試行数が平均から 2 標準偏差以内の参加者のみを分析対象
- WM 得点×カテゴリ構造の交互作用が有意 ($\beta = .609$, $t = 3.11$, $p < .01$)
 - ルールベース WM 得点が高いほど, 発見試行数が少ない ($\beta = -.236$, $t = -2.02$, $p < .05$)
 - 情報統合 WM 得点が高いほど, 発見試行数が多い ($\beta = .274$, $t = 2.36$, $p < .03$)
- 相関係数による分析でも同様の結果
 - ルールベース WM 得点と発見試行数に有意な負の相関 ($r = -.236$, $t(69) = -2.02$, $p < .05$)
 - 情報統合 WM 得点と発見試行数に有意な正の相関 ($r = .274$, $t(69) = 2.36$, $p < .03$)
- 各カテゴリ構造の相関係数を分析しても同様の結果 ($z = 3.075$, $p < .01$, two-tailed)
 - WM 得点が両相関係数に影響する“重なり”を比較する分析方法 (Meng, Rosenthal, & Rubin 1992)

4. Discussion

- WM が高いほどルールベースカテゴリの学習は早く, 情報統合カテゴリの学習は遅かった
 - 前者は仮説検証, 後者は手続き学習に関連
 - WM の個人差がそれぞれのカテゴリ構造の学習に色濃く反映された




Fig. 1. Mean trials to criterion as a function of category structure and individual differences in working memory. Nonstandardized regression coefficients are plotted at $\pm 1 SD$.

- WM が高いほど情報統合カテゴリーの学習が遅いという結果は、WM の正の側面を強調する先行研究 (Beilock, Kulp, Holt, & Carr, 2004; Engle, 2002) に反しているように見える
 - しかしながら、上述の三段論法のように、WM よりも強く働く機構がある場合はパフォーマンスを必ずしも予測できるわけではない
- 個人の能力の高さがパフォーマンスに関係がないどころか、むしろ効率的な学習を阻害しパフォーマンスを低下させることを示した
 - 仮説検証が、手続き学習に基づく情報統合のパフォーマンスを抑制した (Ashby et al., 1998)
 - 様々な課題のパフォーマンスを予測する標準規格としてWMを用いることに疑問が生じた (De Neys, 2006; Stanovich & West, 2000)
- 先行研究では、サブタスクの追加はルールベース学習を阻害するが、情報統合学習には影響しないとされていた (Waldron & Ashby, 2001)
 - ただ、サブタスクは情報統合学習に必要な刺激特徴の記録に影響するかもしれない

- 刺激特徴は記銘できるが、それにルールベース推論を適用することが難しい人 (例: WM の低い人) は、サブタスクが情報統合学習に影響する可能性がある
- WM とパフォーマンスが常に正の関係ではないことから、カテゴリ学習において個人差に言及することの重要性が増した
- 本研究では、新たなカテゴリを学習する際、そのカテゴリ構造の性質に応じて WM の個人差がパフォーマンスに様々な影響をもたらすことを示した
 - 情報統合カテゴリ構造の学習では、WM とパフォーマンスは負の関係、つまり WM が高いほど学習パフォーマンスが低いことが示された
- カテゴリ学習を包括的に理解するには、認知・神経基質の処理に関する知識と、その処理が個人の認知能力とどのように相互作用するかを考える必要がある