

Problem solving: Increased planning with practice  
Glenn Gunzelmann, John R. Anderson  
Cognitive Systems Research 4 (2003) 57-76

### ■Abstract

- ・ プランニング
  - 問題解決を促進する
  - タスクの経験によって改善される
- ・ ハノイの塔を用いた心理実験と ACT-R によるモデル化
- ・ 仮説：問題解決における移動数としてのコストによってアプローチ間の比較が行われる
- ・ ACT-R モデル
  - 仮説にもとづいたメカニズムの検証
  - 被験者のパフォーマンスの詳細について調査

### ■Introduction

- ・ プランニング
  - 問題解決行動の基礎的部分
  - ゴールへの到達は、解に近づくように一度に一つの動きを選択することによって可能だが（つまり、「ヒルクライミング」）、多くの問題は「長い移動系列」をプランニングすることによってのみ最適に解決できる
  - プランニングの効果は有益だが、人は新しい問題を解く時に「長い移動系列」をプランニングしない
- ・ プランニングを行わない理由
  - 多くの場合、問題を理解することや表現することに一生懸命になるため、ワーキングメモリがプランニングに利用できない
  - プランニングの努力（余分な努力）の実際の効果が明確でないため
- ・ プランニングの増加
  - プランニングが有効であるとわかったとき

### □Planning in the Tower of Hanoi

- ・ 実験で用いるハノイの塔の同系問題 → Fig. 1
  - Monster Move
  - Paint Stripping
- ・ Isomorph Mapping
  - 配置順序
    - ◇ Tower of Hanoi：ディスクの大きい順
    - ◇ Monster Move：ボールの小さい順
    - ◇ Paint Stripping：色の薄い順
  - 同型問題を用いる理由
    - ◇ ディスク版は非常に簡単
    - ◇ ディスク版はアルゴリズムを含め被験者にとって既知（大学の授業で扱っている）
    - ◇ 同型問題は自然なカバーストーリーを持つ
  - flat 状態

- ◇ Monster Move, Paint Stripping では自然な開始状態
- ◇ //では自然な最終状態
- ◇ 全部で6つあり, 他の flat 状態への遷移は, easy, hard の2つがある → Fig. 2

## ■ Experiment 1

- 目的: 被験者によって作られる解が, five-move flat-to-flat 問題の解決でどのようにして変化するか? (問題経験のパフォーマンスへの影響)
- 予測: 「flat-to-flat ストラテジ」から「より効果的なストラテジ」へ変化
- 被験者: 大学生 24 名
- 課題
  - Mac 上に実装
  - five moves で解ける 12 個の flat-to-flat 問題を使用
  - monster(6 セット) → filler(water jug の同型問題, 6 セット) → paint(6 セット)
  - ※課題間の違いはなかったため, 以降ではこれらをつぶして考える
- 手続き
  - PC 上で課題に取り組み, カバーストーリー, ルール, インターフェースの説明が与えられた
  - オブジェクトの移動は, オブジェクトの下にあるボタンを押すことによって実行された
  - 移動が不正であったり, 問題が解決されたときに, メッセージボックスが表示される
- 結果
  - 探索部と最終パス → Fig. 3  
移動総数の減少 = 探索部の減少
  - 最終パスが減少しない理由 → Fig. 4  
five-move: 74%, six-move: 19%
  - 最終パスの潜時 → Fig. 5  
six-move: 「最初」と「4 番目」の移動で潜時が長い → three-move flat-to-flat 系列をプラン  
five-move: 「最初」と「3 番目」の移動で潜時が長い → 最初にプランニングの大半がなされる (two-move か four-move がプランニングされる)
  - タスク経験が問題解決を改善
    - ◇ 探索パスの減少 → Fig. 3
    - ◇ 最終パス: five-move の増加, six-move の減少 → Fig. 4
  - flat-to-flat プランニング
    - ◇ 最終パスデータから, flat-to-flat プランニングが行われていたことが示された
    - ◇ 被験者は flat 状態を特別に扱っていた  
ランダム移動で 4.5 移動毎に flat 状態にたどり着く (27 状態中 flat 状態は 6 つ)  
実際には, 3.42 移動毎 (有意に flat 状態に達していた)  
→ 最適なプランニングを行っていないとき, flat 状態に移動する移動系列を実行
    - ◇ flat 状態での移動潜時は他の状態よりも 2 倍以上長い  
→ flat 状態でより多くのプランニングが行われていた  
flat 状態 = 「home base」(被験者はここで進捗状況をチェックする)
    - ◇ 実験結果から 2 つのローカルストラテジの存在が明らかになった  
特に, 最終パスの 90%以上が 2 つのうちのいずれかを使っていた  
ただし, 明らかにランダムな移動も見られた

## ■Experiment 2

- 目的：ストラテジの転移の効果を明らかにする
- 被験者：Paint 群, Monster 群(大学生計 60 人)
  - 問題間に差がなかったため, 以降ではつぶして考える
- 課題：トレーニング課題 12 問(five-move) → 転移課題 6 問(seven-move)
- 結果(トレーニングフェーズ)
  - 移動数データ(トレーニングフェーズ～転移フェーズ) → Fig. 6  
実験 1 と同様の結果
  - トレーニングフェーズの最終パス → Fig. 7
    - ◇ five-move(最適パス): 74%
    - ◇ six-move(flat-to-flat): 19%実験 1 と同様の結果(90%以上がこの 2 つのストラテジで説明される)
  - 12 問の問題を通して解法が改善された → Fig. 6, 7
  - flat-to-flat ストラテジ
    - ◇ flat 状態へチャンスレベル以上に到達している → Table. 1
- 結果(転移フェーズ)
  - flat 状態において決定時間を多く費やし, チャンスレベル以上に flat 状態に到達 → Table. 1
  - 最終パス
    - ◇ 3 つのストラテジで 90%以上が説明される → Fig. 8
      - seven-moves: 最適パス
      - nine-moves: flat-to-flat ストラテジ
      - eight-moves: 最適パスと flat-to-flat ストラテジの組み合わせ
    - ◇ 6 つの問題を通して final パスは改善される (有意傾向)

## ■ACT-R Model

- パフォーマンスとストラテジの利用を説明する認知モデルを ACT-R 4.0 で記述
- 心理実験の結果を反映
  - 問題解決経験 → 徐々に移動のより長い系列をプランニングする傾向が増加 → 探索パスの減少
  - 2 つのローカルプランニングストラテジが互いに競争しながら final パス長が改善
- 目的：問題方略の選択に関して明らかにする
- ACT-R
  - コンピューターシミュレーションによって事例化可能な人の認知の理論(Anderson, 1993; Anderson & Lebiere, 1998)
  - 特徴：「宣言的知識」と「手続き的知識」の分離
    - ◇ 宣言的知識：事実について保持
    - ◇ 手続き的知識：プロダクションルール
  - 初期状態～ゴール状態

- ◇ 各サイクルにおいて利用可能なプロダクションが現在のゴール状態をもとに実行される
  - ◇ 各サイクルのゴールでは「コンテンツの変化」または「新しいゴールへのフォーカス」が行われる
    - 新しいゴールへのフォーカス
      - 現在のゴールを満足する (popping on success)
      - 現在のゴールをあきらめる (popping on failure)
      - 現在のゴールをもとにサブゴールを作る (pushing)
      - 新しいゴールを選択する (基本的に, push の後に pop)
- これらのサイクルを通して ACT-R は多くの領域において人と同様の行動を生み出すことに成功 (see Anderson & Lebiere, 1998 for a review)

• ACT-R におけるサブシンボリックなメカニズム

- 経験からの学習を可能にする
- 宣言的メモリ
  - ◇ チャンクの活性化
  - ◇ アクセスのしやすさ
    - 本研究では, タスク情報の全てが常にディスプレイ上で入手可能であるため考慮せず
- 手続き的メモリ
  - ◇ 特定のプロダクションの使用によるゴールまでの所要時間
  - ◇ 特定のプロダクションを使った場合のゴールへの到達の程度
    - 本研究のモデルではこれらのコストがクリティカルに効く

□ Model design and mechanisms

- モデル化における 2 つの観点
  - モデルのパフォーマンスはいくつかの利用可能なプロダクションの中から一つが選択されることが基礎となる
    - ◇ 「期待利得 (E)」
      - 各サイクルにおいて各プロダクションに対して計算され, 現在のゴールへの到達を予測する
      - 高い E(コストが低い)を持つプロダクションが各サイクルで選択される
  - 有用性の学習
    - ◇ モデルが経験を積み, E の値が調節される
    - ◇ ゴールがポップした各時間で, 使用されたプロダクションに対するパラメータが更新される
    - ◇ 経験の積み重ねを通して, E の値がモデルの経験によって変化する
- 移動プロダクション → Table 2
  - オプション 1 : ランダム移動
  - オプション 2 : 選択された対象を正確に移動 (1~4 の移動)
  - オプション 3 : flat-to-flat ストラテジをベースにした移動
    - それぞれのオプションから 1 つずつ (全 3 つ) 選択され, その中から E の値によって決定する (タワー状態では, 全 2 つ)

- 期待利得 (E)
  - $E = PG - C + \text{noise}$ 
    - ◇ P: プロダクションを使用し、最終的にゴールにたどり着く可能性  
フォーカスされた対象は最終的にゴールに到達するため、常に  $P = 1$
    - ◇ C: プロダクションを使用し、最終的にゴールにたどり着く予測されるコスト (時間 (秒))
    - ◇ G: 問題を解決する全体的時間  
 $G = 50\text{sec}$
  - C と noise が E に直接関係する
  
- コストパラメータ (C)
  - そのプロダクションが使われ、最終的にゴールにたどり着くまでのトータル時間を見積もる量
  - $C = \text{total efforts}/\text{history} \rightarrow \text{Table 2.}$ 
    - ◇ total efforts: 過去のコストの和
    - ◇ history: 過去の経験
  - ※初期のコストは移動に対して線形:  $C = 6.25 + 0.75 * \text{moves}$
  
- E の安定性: 成功の履歴(history)
  - 初期値  
ランダム移動以外: 2  
ランダム移動: 200 (被験者がプランニングを嫌うことを反映)
  
- ノイズパラメータ
  - 平均 0, 分散 1.81 秒 (約 1/2 移動) から選択
  
- モデルの初期値の特徴 (被験者のデータをもとに設定, Fig. 3, 6)
  - ほとんどの被験者は、実験を開始したとき前もって計画することは少ない  
→ random move, 1 move
  - 経験を積み、より効果的なプロダクションの選択に向かう (4 moves)
  
- 問題解決の例
  - モデルが最初に 2 回ランダム移動を行い、three-moves プロダクションでゴールに到達
    - ◇ 全体の移動時間: 20sec (5 回移動×4sec)
    - ◇ ランダム移動プロダクションのコスト: 36 (一回目の移動: 20sec, 二回目の移動: 16sec)
    - ◇ three-moves プロダクションのコスト: 12 (3 回移動×4sec)
  
- モデルの経験
  - ランダム移動プロダクションは経験を積むに従い、コストが増加する
  - flat-to-flat プロダクションは常に 1 つまたは 2 つの余分な移動を含む  
→ 最終的に、最適にプランニングされるようになる  
プランニングが価値のあることを学習する
  
- モデルのパフォーマンス
  - 実験 1: 相関係数 0.96
  - 実験 2: 相関係数 0.95

- flat 状態への到達 : Table 1.  
→ 被験者のデータと非常に高い一致を示す

#### □Model's fit to exploratory and final paths

- 探索的パスの漸進的減少 → Fig. 3, 6
  - モデルがプランニングを行うようになる  
経験により, 正しい経路 (final パス) で解に至る
  - 転移課題ではよりこの点がクリアになった  
被験者が転移課題に移ったとき探索的パスの長さが減少し続ける  
探索パスの減少 = ランダムサーチの減少
- 使用ストラテジ
  - final パスデータから, どんなストラテジが使われていたかを推論することが可能
    - ◇ five-move パス
    - ◇ flat-to-flat final パス (flat-to-flat 変形のペア)
  - 最適な final パスは最適なプランニングの結果であると予想される
- ストラテジの変化
  - 最適な final パスへ移行
    - ◇ 実験 1 : 相関係数 0.996 → Fig. 4
    - ◇ 実験 2 : 相関係数 0.993 → Fig. 7
    - ◇ 実験 2 (転移課題) : 相関係数 0.981 → Fig. 8
    - ◇ final path 長が安定で, nine-move final パスのみ減少  
→ 転移課題では最適パスと比べ nine-move は 2 つ分移動が多くコストが増加するため
- 問題の難易度による差異 → Fig. 2
  - “Start 2” : easy
  - “Start 1” : hard
  - ∴ 小さな球に最初フォーカスすると, hard 問題は easy 問題よりも 1 回のプランニングでより多くの移動 (2 回) が必要
    - ◇ Hard 条件 : 実験 1 の 4 分の 1 (6 人), 実験 2 の半分 (30 人)
    - ◇ Easy 条件 : 実験 1 の 4 分の 1 (6 人), 実験 2 の半分 (30 人)
  - hard 問題だけを行った被験者はゴール状態へより多くの移動を必要とした (有意傾向,  $p = 0.09$ ) → Fig. 9
    - ◇ モデルが easy な問題を解く場合 : 一度に 2 回移動のみのプランニングで成功する
    - ◇ モデルが hard な問題を解く場合 : 2 回移動よりも 4 回移動をプランニングすることが少ないため, hard 問題を解いている間に誤った移動を行う傾向がより大きくなる  
→ トレーニング問題の中で 4 回移動の価値が学習され, 転移課題でよりシンプルなアプローチ (flat-to-flat ストラテジ) に頼らずに問題を解くことが可能となる (Fig. 9 下)
- 全体的に, データは経験を通してパフォーマンスが徐々に改善することを示した
  - 本当に漸進的な改善があったのか?  
個々人は飛躍的な変化をしていた可能性が考えられる
  - 後方学習曲線 (backwards learning curve, Bower & Trabasso, 1963) → Fig. 10

- ◇ もし、学習が **all-or-none** ならば、最適な **final** パスの **likelihood** は、トライアル数の関数として変化しないはずである (see Bower & Trabass, 1963)

## □ Variability among individuals

- 個人間のパフォーマンスにおけるばらつき → Fig. 11, Fig. 12
  - 問題を解くプランの個人の傾向に関連している
  - 最適な **five-move final** パスと非最適な **six-move final** パスで解いた問題数の違い
  - すべての問題で最適な **final** パスを何人かの被験者が生成したが、モデルでは再現できなかった
    - 被験者の幾人かが問題に対する知識を持っていたため  
事後アンケートでハノイの塔の変形問題であることを認識していた

## ■ Conclusion

- 実験結果
  - より多くのプランニングへの転移や、より頻繁に最適な解のパスを生み出すプランニングの証拠を示した
  - 経験がない状態では、多くの移動を伴い、より頻繁に効果が少ない **flat-to-flat** ストラテジを使用した
  - 経験を積むに従い、探索パスの長さは十分に減少し、解の多くが最適な最終パスに取り込んでいた
    - タスクにおけるプランニングの増加は、タスクについての学習よりも、プランニングの利点について学習を示している (e.g. Svendsen, 1991)
- ACT-R モデル
  - プランニングとストラテジにおける転移の解釈を提供した
  - ストラテジの **cost and benefit** の関係の学習  
ランダムと **flat-to-flat** ストラテジ → 最適なプランニングストラテジへシフト
  - ACT-R のコストメカニズムが、これらの現象に対する説明を与える
    - ◇ どれだけの試み（時間）が各アプローチに対して必要とされると見積もられたかをベースに比較を行う
    - ◇ 経験を積むに従い、見積もりは、正確にコストを反映するようになる
    - ◇ E へのノイズの追加
      - 効果の小さいプランからより効果的なプランへノイジーなシフトを与える  
※ 実験における被験者とほぼ同じ振る舞い
  - パフォーマンスの漸進的なシフト
    - ◇ 表象の突然の永続的シフトを求める理論とは対照的(e.g., Anzai & Simon)
    - ◇ 漸進的に変化する
  - **five-move** 問題の 2 つのタイプでの差異を予測
    - ◇ もし、プランニングが小さな球へのフォーカスで始まっていたなら、**hard** 問題は **easy** 問題よりも 2 つ移動数が多くなる
    - ◇ 簡単な問題を行った場合、転移問題において、初期に **flat-to-flat** ストラテジにより依存することを説明する
    - ◇ 2 つの移動のプランニングが簡単なトレーニング問題において最適な解を見つけるのに十分であったため、転移問題においてより長い系列（4 つの移動）をプランしなかった →

flat-to-flat ストラテジが多くなる

- 被験者のパフォーマンスにおける variability
  - ✧ モデルは、被験者の行動の範囲をよく捉え、ストラテジの使用における変動を示した (Fig.10, 11)
  - ✧ 人の振る舞いの可変性を捕らえることにしばしば失敗するという (e.g. Roberts & Pashler, 2000), コンピューテーショナルモデルの主な批判の一つに対してよい結果を示した