

Top-down versus bottom-up learning in cognitive skill acquisition

Ron Sun, Xi Zhang

Cognitive Systems Research(2003)

(in press)

0. 概要

- ・ 学習のコンピューテーショナルモデル CLARION(Sun, 1997, 1999; Sun et al., 1998, 2001)を用いて
- ・ スキルの学習の統合モデルを提供
- ・ スキル学習における潜在的(implicit)プロセスと顕在的(explicit)プロセスの間のインタラクション
 - トップダウンの学習 (顕在的 潜在的知識への学習)
 - ボトムアップの学習 (潜在的 顕在的知識への学習)
- ・ 2つのタイプの間のインタラクションを強調する .
 - 一方の獲得 他方がもたらされる
- ・ ハノイの塔における実験データをシミュレートする
 - 定量的データが ,トップダウンとボトムアップのどちらかを使うことによってどのように獲得されるのだろうか

1. 導入

[Sun, Merrill, and Peterson, 2001]

トップダウン学習 : 顕在的 潜在的知識

ボトムアップ学習 : 潜在的 顕在的知識

- ・ ハノイの塔
 - 高次認知スキルの獲得におけるベンチマーク問題
(see, e.g., Altmann & Trafton, 2002; Anderson, 1993; Anderson & Lebiere, 1998; Anzai & Simon, 1979; Fum & Missier, 2001; Simon, 1975; VanLehn, 1995; Zhang & Norman, 1994)
- ・ スキル学習の統合されたモデルを提案する
 - ボトムアップ学習
 - トップダウン学習
 - ハノイの塔の定量データをどのようにして説明できるか
- ・ この論文の流れ
 - section 2: トップダウン学習 vs. ボトムアップ学習を理論的モデルを用いて紹介する
 - section 3: モデルのコンピューテーショナルなインプリメントに対する詳細について述べる
 - section 4: トップダウン vs. ボトムアップ学習の比較のシミュレーション
 - section 5: まとめ

2. トップダウン vs. ボトムアップ : CLARION モデル

- ・ スキル獲得における潜在的学習の役割と ,潜在的学習と顕在的学習の区別は近年広く認識されてきている
(see, e.g., Aizenstein et al., 2000; Anderson, 1993; . . .)
- ・ 潜在的学習の研究は多いが ,潜在/顕在間の複雑なインタラクションが一般には認められていない
例外 : e.g., Mathews et al., 1989; Sun, Merrill, & Peterson, 1998, 2001
いくつかの実験条件におけるエクスプリシット学習の欠如を見ることに焦点を当てている
- ・ 過去研究の問題点
 - ほとんどの条件において両タイプの学習が含まれており ,各タイプからの学習への貢献の量が不明

[Reber, 1989]

現実の複雑なスキルのほとんどすべては ,顕在的プロセスと潜在的プロセスの混じったものであると指摘した

(コントロールされた実験室的統制に反対して)

[Sun et al., 2001]

潜在的学習タスクを使用した場合のパフォーマンスであっても、両方の学習プロセスを含んでいる
インタラクションを含んでしまう

[Stanley et al., 1989]

インタラクションの経験的な実証

- ・ 言語化
- ・ 顕在的なインタラクション
- ・ 二重課題

[Anderson, 1983, 1993]

認知アーキテクチャーの開発における、手続き的知識と宣言的知識の間の区別(多くの研究に導入されている)

手続き的知識 潜在的知識
宣言的知識 顕在的知識

[Sun, 1997, 1999; Sun et al., 1998, 2001]

- ・ CLARION モデル
 - 2つの表象構造を統合したモデル
 - 2つのレベル (Fig. 1)
 - ◇ トップレベル: 顕在的記憶
記号处理的, one-shot 学習 (仮説検証)
 - ◇ ボトムレベル: 潜在的記憶
分散処理 (バックプロパゲーションネットワーク)
 - モデルの各レベルにおいて、複数のモジュールが存在する (Schacter, 1987; Moscovitch & Umiltà, 1991)
 - ◇ action-centered モジュール
 - ◇ non-action-centered モジュール
この研究では action-centered モジュールのみを対象とする
 - 顕在的知識と潜在的知識の相互学習
 - ◇ ボトムレベルで獲得された潜在的知識は、ボトムアップ学習を通して、トップレベルの顕在的知識の学習で利用される (Sun et al., 1998, 2001)
 - ◇ トップレベルで獲得された顕在的知識は、トップダウン学習を通して、ボトムレベルの潜在的知識の学習で利用される

3. Some model details

CLARION(from Sun, 2002)モデルについて

3.1. Overall action decision making

- ・ CLARION のアクションの意思決定アルゴリズム
 1. 現在の状態 x を観察する
 2. **ボトムレベル**において、状態 x において可能な行動 a の各値を計算する
 $Q(x, a_1), Q(x, a_2), \dots$
 3. 現在の状態 x (ボトムレベルからあがってくる)と**トップレベル**において存在するルールに基づいて、可能なアクションのすべて (b_1, b_2, \dots)を見つける
ランダムに一つが選択される
 4. トップレベルまたはボトムレベルのどちらかの結果を**確率論的に選択**することによって、適切なアクション a が選択される
 5. アクション a の実行、次の状態 y を観察、強化 r

6. 適切なアルゴリズム(後述)に基づき,フェードバック情報をもとにボトムレベルをアップデートする
7. ルールの構築,洗練,削除に対する適切なアルゴリズムを使用し,トップレベルをアップデートする
8. ステップ1へ

3.2. Action-centered bottom level

3.2.1. Representation

- ・ ボトムレベルへのインプット (Fig. 2)
 - 知覚入力
感覚入力は,入力の次元数に分割され,おのおのは可能な値を持つ
 - ワーキングメモリアイテム
入力状態 x は次元-値のペア(dim1, val1), (dim2, val2),...となっている
 - ゴールスタックのトップアイテム
ゴールインプットは次元(ゴールの次元であり,値は可能なゴール)の数に分割される
- ・ ボトムレベルのアウトプット
 - ワーキングメモリのセット/リセット
 - ゴールスタックのプッシュ/ポップ
 - 外部アクション
- ・ アクションの選択
 - Q 値をもとに選択する
 - ・ Q 値:与えられた状態におけるアクションの"quality"の評価値
 - ・ $Q(x, a)$: 状態 x においてアクション a がどれほど望ましいかを示す
 - ・ 各ステップにおいて,状態 x が与えられ,すべてのアクションの Q 値が算出される
 - ・ アクションの実行において Q 値のボルツマン分布を通して確率論的な選択を行う

$$p(a|x) = \frac{\exp(Q(x,a)/\alpha)}{\sum_i \exp(Q(x,a_i))}$$

3.2.2. Learning

- ・ Q-learning アルゴリズム(Watkins, 1989)
 - 強化学習の一つ
 - $\Delta Q(x,a) = \alpha(r + \gamma e(y) - Q(x,a))$
 - γ : ディスカウント因子, y : 新しい状態, a : 状態 x から状態 y へのアクション
 - $e(y) = \max_b Q(y,b)$
 - アクション a の後に受け取られる最大の Q 値をディスカウントした値 - アクション a の Q 値
- ・ Q-learning の目的
 - ディスカウントされたの累積報酬の最大化
$$\max \left(\sum_{i=0}^{\infty} \gamma^i r_i \right)$$
- ・ Q-learning はバックプロパゲーションネットワークにおいて実装
 - バックプロパゲーションネットワークのトレーニングは,各ステップにおけるエラーを最小にすることを基礎にしている

$$err_i = \begin{cases} r + \lambda e(y) - Q(x, a_i) & \text{if } a_i = a \\ 0 & \text{その他} \end{cases}$$

i : アクション a_i を表現するアウトプットノードのインデックス

- Q 値の算出
 - 並列分散活性を通じたコネクショニストの方法においてなされる
このような活性の並列分散は潜在的なものである(Hunt and Lansman, 1986; Cleeremans and McClelland, 1991; Dienes, 1992)

3.3. Action-centered top level

- トップレベルにおいて、顕在的知識が、記号または局所表現によって捉えられる
- 各ユニットは解釈可能であり、明確な概念的意味を持つ
 - この表象はボトムレベルとは異なる。ボトムレベルでは、バックプロパゲーション学習が、分散表現で内部表象（隠れ層において）を生み出しているため

3.3.1. Representation

- 表象はボトムレベルへのインプットに類似した 3 つのグループからなる
 - 感覚入力
 - ワーキングメモリアイテム
 - 現在のゴール
- アクション選択
 - ボトムレベルからのアウトプットに類似したルールのアウトプット
 - ワーキングメモリアクション
 - ゴールアクション
 - 外部アクション
- ルールの形式
 - 現在の状態 アクション
- ルールセットがネットワークで表現されている
 - 現在の状態 アクション
 - 現在の状態にマッチするルールから一つがランダムに選択される

3.3.2. Bottom-up rule learning

- RER(Rule-Extraction-Refinement)アルゴリズム
 - ボトムレベルにおける情報を用いてルールを学習する (Karmiloff-Smith, 1986; Stanley et al., 1989)
- アルゴリズムの基礎的アイデア
 - ルールの抽出
 - ボトムレベルにおいて決定されたアクションが成功したなら（幾つかの基準をクリアしたなら）
 - エージェントはルールを抽出し
 - トップレベルのルールネットワークへルールを追加する。
 - ルールの適用の結果からのルールの変更
 - 成功：より一般化するようにルールの条件を一般化する
 - 失敗：ルールの条件はより特殊化し、排他的になる

3.3.3. Fixed rules

- FR(Fixed Rule)
 - トップレベルにおけるルールのいくつかは事前にコード化され、決定されているだろう(Anderson,

1983)

- ◇ 進化の過程を通して獲得された遺伝的な知識
- ◇ 実世界における事前の経験を通じた事前知識
例：FR は教示やテキストブックから外的に与えられる

- ・ 外的に与えられた FR はトップダウン学習を可能にする
 - 学習初期にはトップレベルにおける FR によってアクションの決定が行われる
 - 徐々に、多くの知識がアクションの観察を通してボトムレベルによって獲得される
 - エージェントはますますボトムレベルに依存するようになる
(クロスレベルの確率論的選択メカニズムが適応される)
 - それゆえ、トップダウン学習が発生する

3.4. Goal stack and working memory

- ・ GS(Goal Stack) (see, e.g., Anderson, 1983)
 - GS はスタックによって構成され push と pop の処理が行われる
 - GS のトップのアイテムが現在のゴール
- ・ WM(Working Memory) (Baddeley, 1986)
 - 情報を一時的に保存するもの
 - store と remove の処理が行われる

4. 実験

- ・ ハノイの塔の4つのシミュレーション
- ・ 実験デザイン
 - top-down vs. bottom-up ボトムアップ学習，トップダウン学習
×
 - WM/GS vs. no WM/GS 伝統的スキル学習のける WM/GS の重要性
- ・ 4つのシミュレーション
 - ボトムアップシミュレーション1
WM/GS なし
ボトムアップモジュール&トップダウンモジュール
ボトムアップオンリー，トップダウンオンリー
 - ボトムアップシミュレーション2
WM/GS あり/なし
ボトムアップ&トップダウン
 - トップダウンシミュレーション1
FR の追加
ボトムアップモジュール&トップダウンモジュール
 - トップダウンシミュレーション2
異なる FR
ボトムアップモジュール&トップダウンモジュール

4.1. ハノイの塔

[Gagne and Smith(1962)]

- ・ 被験者は3ディスク，4ディスク，5ディスクのバージョンを連続して与えられた
- ・ ディスクの移動数を記録
- ・ 発話群 vs. 非発話群
パフォーマンスに対する発話の効果
- ・ 結果 (Fig. 3)

- 発話 vs. 非発話間に有意差 ($p < .001$)

[Stanley et al., 1989; Berry, 1983]

ダイナミックコントロールタスクにおいて、言語化はパフォーマンスを向上させる

[Sun et al., 2001, 2002]

一般的に、言語化は被験者をより顕在的にする。

[Anderson, 1993]

- ・ ゴール再帰手法(goal recursion approach)を促す教示を被験者に与えた
”大きなディスクになるとディスクを動かす制限が強くなるので、一番大きいディスクをボールのペグに最初に移動することが重要である。”
”より大きなディスクを動かせる状況を作り、より小さなディスクはそれが終わってからにすること”
- ・ 結果 (Fig. 4)
2, 3, 4, 5 ディスクバージョンのハノイの塔の RT(Reaction Time)を比較
ディスク 1, 3, 5 において、規則正しいパターンが存在する
各ポイントにおいてプランニングが行われていたことを示している
目標再帰 (達成されるべきサブゴールのシーケンスを定めること) とプランニングは教示によって、少なくとも部分的には起こっていた(Anderson, 1993)

4.2. ボトムアップシミュレーション 1

被験者ははじめに潜在的に学習し、そして、その上で、顕在的な知識を獲得したと考えられる

- ・ 最初にボトムレベルで潜在的知識が獲得され、練習を通して、顕在的知識がボトムレベルから抽出され、そして、トップレベルが作り出される(cf. Gunzelmann & Anderson, 2003) .
- ・ 本研究で用いた構成
 - ボトムレベル：Q-learning
 - トップレベル：RER learning

4.2.1. モデルのセットアップ

- ・ ボトムレベル
 - バックプロパゲーションを組み合わせた Q-learning
 - 報酬：ゴールに到達したら、1 .
ターゲットペグにない一番大きなディスクがターゲットペグに移動したら、0.8 .
間違った移動 (上にディスクが乗っている状態で動かすなど) が選択されたら、-0.1
 - No WM and GS
- ・ トップレベル
 - RER
 - 非発話群：ルール抽出の閾値 0.1, ルールの一般化閾値 3.6, ルールの特殊化閾値 1.0
 - 発話群：ルール抽出の閾値 0.1, ルールの一般化閾値 2.0, ルールの特殊化閾値 0.5
発話状態を捉えるため、トップレベルにおけるより多くの活性を促すため各閾値を下げる
- ・ ボトムレベルとトップレベルの結論の選択率
 - 非発話群： BL = 5, RER = 1
 - 発話群： BL = 2, RER = 2
発話群のトップレベルに対する選択率の向上 (より顕在的にになる, Sun et al., 2001)

4.2.2. 被験者データとの比較

- ・ 20 のモデル被験者が各グループでシミュレートされた (Fig. 6)
- ・ ANOVA (ディスク数 × 発話 vs. 非発話)

- 発話と非発話の間に主効果 ($p < .01$)
- 人の発話の効果をシミュレーションで確認
- ・ ボトムアップシミュレーションとボトムオンリー、トップオンリーシミュレーション(トップレベル、ボトムレベルを停止)を比較
 - ボトムオンリーシミュレーションは学習を常に失敗
 - この結果は、トップレベルの顕在的知識とボトムアップ学習の重要性を強く示唆する。
 - なぜなら、それらがないと、タスクは学習することが非常に困難である。
 - トップオンリーシミュレーションも、同様に能率的に学習できない、なぜならランダムサーチに頼るため
 - これらの2つの事実は著者らの相互作用仮説と一致する(Sun & Peterson, 1998; Sun et al., 2001)
 - 2つのレベルのインタラクションは学習を向上することを助け、パフォーマンスを促進する(Sun et al., 2001)。

しかしながら、ボトムアップシミュレーション(ボトムオンリーやトップオンリーと同様に)は、人間の被験者データで見られたRTデータのピークを捉えることができなかった。

4.3. ボトムアップシミュレーション2

- ・ WM/GS あり/なし
- ・ WM/GS に注目する理由
 - WM/GS の使用は認知スキル獲得における理論化において広く認知されているからである
 - ハノイの塔の先行研究におけるモデリングにおいては特に

4.3.1. モデルのセットアップ

- ・ シミュレーションのインプリメント
 - (1) 各タイプのアクション(外部, GS, WM アクション)における決定に対して、ネットワークへの一致や RER ルールセットへの一致
 - (2) 各ネットワークへのインプット(感覚入力, GS アイテム, WM アイテムを含む)は同じである、
 - (3) ネットワークのアウトプットは、外部アクション, GS アクション, WM アクションを含む
 - (4) 各ステップにおいて、もしアクションがトップレベルによって決定されたなら、現存の RER ルールセットを3つのアクション(外部, GS, WM アクション)を得るために使用する。もしアクションがボトムレベルによって実行されたなら、各ネットワークのアウトプット(外部, WM, GS アクションから)からアクションを選択する。
 - (5) 選択されたアクションは実行において、コーディネートされ、トップレベルとボトムレベルがアップデートされる
- ・ GS に含まれるアイテム
 - DSIZE: SUBTOWER のサイズ
 - FROM: SUBTOWER の現在のペグ
 - TO: SUBTOWER のターゲットペグ
 - DSIZE1: FOCAL-DISK のサイズ
 - FROM1: FOCAL-DISK の現在のペグ
 - TO1: FOCAL-DISK のターゲットペグ

 - SUBTOWER: ペグのトップにおけるディスクのセット
 - FOCAL-DISK: subtower の下のディスク
 - 各 GS アイテム TO と TO1 は、意図されたオペレーションを示し、他のアイテムは現在の状態を示す。
 - 複数のゴールアイテムが GS にストアできる。
- ・ シンプルでもっともらしいゴール再帰ルール(coal recursion(帰納?) rules)のセットは以下のようである

(cf. Anderson, 1993).

関数 LOC : ディスクが位置するペグ

関数 SIZE : ディスクのサイズ

- If $DSIZE > 0$, then スペアのペグにサイズ $DSIZE1$ の subtower を動かす新しいゴールと, ターゲットペグへのサイズ $DSIZE$ のディスクを動かす新しいゴールをプッシュする
- If $DSIZE = 0$, then FOCAL-DISK のターゲットペグへの移動を行う
- If $LOC(SUBTOWER) = TO$ and $LOC(FOCAL-DISK) = TO1$, then FOCAL-DISK をターゲットペグへ移動する
- If $LOC(SUBTOWER) = TO$ and $LOC(FOCAL-DISK) = TO1$, then 現在のゴールをポップする .
これらはハンドコードされたルールであり(ACT-R において使用されている),本モデルではkのようなA・プリアリなルールは用いず,同様の効果が学習されることを望んでいる

4.3.2. 被験者データとの比較

- 結果 Fig. 7
- ANOVA(ディスクの数×発話 vs. 非発話)
 - 発話と非発話の間に主効果 ($p < .01$)
発話の効果を再確認
- しかしながら, ボトムアップシミュレーション 1 同様, 被験者の RT データ (プランニングとゴール再帰を表しているかも知れないピーク) を捉えることはできなかった
- ボトムアップ学習(トップレベルにおける RER)におけるこの比較(GS/WM のあり・なし)では, GS/WM による差は現れなかった
他の条件において, GS/WM は有意な違いを生む可能性がある
続く 2 つのシミュレーション

4.4. トップダウンシミュレーション 1

- Anderson(1993)のモデルにしたがって, 被験者が FR(fixed rules)を使用していることを示す .
 - このシミュレーションはトップレベルの RF と干渉するボトムレベルを含む .
 - Anderson(1993)に比較して, より複雑なシミュレーションを構成し, より複雑な (顕在的知識, 潜在的知識を含む) 認知モデルを用いる
- トップダウンシミュレーション 2 (異なる FR) との比較

4.4.1. モデルのセットアップ

- FR(fixed rules)の使用
- GS/WM に関する FR をインプリメント (CLARION のトップレベルにおいて)
- ボトムレベルからの干渉を扱わなければならないため, トップレベルオンリー(ルールベースオンリー)のシミュレーションと比較してより複雑である,
- ボトムレベルはトップレベルのルールとパラレルに動き, 異なるアクションが提示される . そして, トップレベルのゴール再帰プロセスに干渉する .
- 主な変更は, ボトムレベルにおいて作られた移動(move)が GS におけるトップゴールと一致しなかったとき, GS からのゴールシークエンスのポッピングのプロセスにある
GS のゴールが達成されるまで, ゴールのポッピングを保持する
- ボトムレベルにおいて, Q-learning を使用
 - 強化に対するスケジュール (報酬)
 - ◇ ゴールに到達したとき : 1.0
 - ◇ ボトムレベルによる移動が現在のゴールと一致したとき : 0.1
 - ◇ ボトムレベルの移動が現在のゴールと不一致で, しかしアクションは適正なとき : 0
 - ◇ 移動が不適切な時 : -0.1
 - FR よって, ボトムレベルの Q-learning はトップレベルのガイドの下で実行される

- ・ ボトムレベルとトップレベルの結論の選択率
 - 非発話群： $\beta_{FR} = 1, \beta_{BL} = 1$
 - 発話群： $\beta_{FR} = 10, \beta_{BL} = 1$
- ・ RER ルールは使用しない
 - RER ルールの追加を行った結果，有意な差は見られなかったため

4.4.2. 被験者データとの比較

- ・ 結果 Fig. 8
- ・ ANOVA(ディスクの数 × 発話 vs. 非発話)
 - 発話と非発話間に有意差($p < .01$)
再び，発話と非発話の効果を確認
- ・ Anderson(1993)の RT データを捉える(Fig. 9, 10)
 - 被験者データは特殊な状況で得られた
= CLARION のトップレベルにおいて使用され FR によって具体化されたような，ゴール再帰を促進するよな教示
 - 発話，非発話のシミュレーションにおける RT がかなり被験者データに近い
relative MSE において人のデータとの有意差あり
- ・ Anderson(1998)の RT データとの比較(Fig. 12, 13)
よく一致する
- ・ 被験者データの RT ピークの特徴(Fig. 9, 11, 12)が，各々のポイントそれぞれにおけるゴールのプッシュの系列によるシミュレーションにおいて捉えられた
各ポイントにおいて，複数のゴールが GS の上にプッシュされる（プランニング）
プランニングは RT ピークの原因となる
- ・ ボトムレベルの学習
 - (1) 移動数からの検証
Fig. 14
 - (2) ボトムレベルから提案される移動とトップレベルから提案される移動の一致数からの検証
Fig. 15
 - (3) ポップ数の変化からの検証（ゴールへの到達が失敗することによりポップの数が増える）
Fig. 16
 - (4) ボトムレベルの選択率の向上からの検証
もしボトムレベルで学習が起こっているなら，パフォーマンスが向上する
Fig. 17
 以上の結果は，トップレベルにおける FR によってガイドされた，ボトムレベルの漸進的な学習を示している
- ・ 学習はトップレベルにより提供されるガイドによりなされる
シミュレーションにより，CLARION（ボトムアップ学習にフォーカスをおいている）が，学習のこの方向性に適応することが示された．
- ・ いくつかの論点
 - トップダウン学習がかなり遅い
 - ◇ コンピュータ科学としては，バックプロパゲーション学習は人と比べて長いトレーニング時間を要する
 - ◇ 心理学的には，トライアルの繰り返しをベースにしたモデルと人の比較を必要としない

人にとっていくつかのトライアルが一つの試行に等しい可能性がある
リハーサルと記憶の連結(consolidation)はモデルにおける多数のトライアルを説明するかもしれない(McClelland, McNaughton, & O'Reilly, 1995)

- ・ まとめ

- CLARION フレームワークがハノイの塔における被験者のパフォーマンスを説明することができた
- 顕在的(トップレベルにおける), 潜在的(ボトムレベルにおける)プロセスを組み込むことによってそれらの説明を拡張できた
- このタスク(そして他のハイレベルな認知スキルタスク)におけるボトムレベルの"quick-and-dirty(早くていい加減な, にわか仕立ての)"な反応は, 最初はトップレベルのルールのガイドによる妨害のため悪いパフォーマンスに導くが, 十分なトレーニングを与えた後に, パフォーマンスが改善されることが示された
- 人の RT データのに対する説明は重要である, RT のようなデータに対する説明は, 成功するシミュレーションの品質証明としてみることができるからである(CLARION ではそれができた)

4.5. トップダウンシミュレーション 2

- ・ トップダウンシミュレーション 1 との比較
- ・ 異なる FR の使用

ルールセット: 移動の決定(どのディスクを, どの方向へ動かすか)において GS/WM を使用しない
現在のペグ/ディスク状態以外の情報なしに意思決定可能なアルゴリズムを用いる

4.5.1. The model setup

- ・ 3つのペグを定義
 - ペグ0: スタートペグ
 - ペグ1: 中間ペグ
 - ペグ2: ゴールペグ
- ・ ディスクの定義
 - ディスク: 0 から n
- ・ ディスクの移動
 - (1) 時計回り
 - ペグ2 から 1, ペグ1 から 0, ペグ0 から 2
 - (2) 反時計回り
 - ペグ0 から 1, ペグ1 から 2, ペグ2 から 0
- ・ ディスク移動の最適手続き
 - (1) 最も大きいディスク n を時計回りに動かす
 - (2) 2番目に大きいディスク n-1 を反時計回りに動かす
 - (3) 3番目に大きいディスク n-2 を時計回りに動かす
 - (4) . . .

新しい FR

 - (1) ディスクが3つのペグのどれかのトップにあり
 - (2) ディスクは動いた直後でない
 - (3) (1)と(2)に適合するすべてのディスクで一番小さいなら
 - ディスクをそのディスクの番号にしたがって, 時計回りか反時計回りに動かす.
 - この FR はどのような番号のディスクについても適切に働くことを容易に証明できる.
 - このルールは, シンプルなため, かなり魅力的であるが, 被験者自身がそれを発見するのは難しい(Gagne & Smith, 1962).
- ・ bottom-level の学習は前のシミュレーションと同様
- ・ GS/WM なし
- ・ RER ルールなし

4.5.2 被験者データとの比較

- ・ トップレベルのみの場合：上記の FR のセットを使用したシミュレーションは最適なパフォーマンスに直ちに到達した
- ・ ボトムレベルが含まれていた場合：最初に，準最適パフォーマンスを示した．
そのうち，ボトムレベルのパフォーマンスは改善し，そして，最終的に，トップレベルのパフォーマンスに追いついた．
- ・ RT は捉えられない
ゴール再帰プロセスの欠如のため（直前のシミュレーションとは異なる，最初の2つとは一緒）
もともと RT のデータは実験条件として明示的にゴール再帰手続きを用いるようにした場合のデータであるため，他の実験条件によって，シミュレーション 1, 2, 3 と似たアプローチを取るかもしれない（未解決の問題）

5. 討論

5.1. 4つのシミュレーションの比較

- ・ ボトムレベルのみ vs. トップレベルを伴ったボトムレベル
 - ボトムレベルのみでは人のパフォーマンスを捉えられない
 - ボトムレベルによって具体化されたものとしての暗黙的な学習は，人が行うようにこのタスクを学習することに対しては十分ではない．
 - トップレベルにおける明示的な知識の追加により（ボトムレベルから抽出された RER ルールや，ア・プリオリにハンドコードされた FR），モデルは人間のデータを捉えることにおいて十分に機能した
- ・ トップダウンシミュレーション 1 (RF あり) とボトムアップシミュレーション 1 (FR なし) の比較
 - FR がゴール再帰を捉えることに対して良好な結果を示した
 - RER がゴール再帰手続きでなぜ学習できなかったのか
 - ◇ 人間の被験者は，人生を通して学んだ多くの発見的問題解決テクニックや事前知識を多く持っており，ハノイの塔で，ゴール再帰手続きを考えつくためにそれらの事前知識を用いた可能性が高い．
 - ◇ CLARION はゴール再帰に近いものを見つけ出すために応用できる事前知識を持たずにスタートするため，そのような手続きを学ぶのが遅い
- ・ RF + ボトムレベルと RF オンリーの比較（トップダウンシミュレーション 1 と 2）
 - RF オンリー (Anderson, 1993) はシンプルであり，プログラムが容易で，被験者の RT データへモデルをフィットさせることが容易である
 - しかし，潜在的認知プロセスのような，認知の重要な側面を無視してしまう
- ・ RF の 2 つの異なるバージョン（トップダウンシミュレーション 1 と 2）
 - 被験者がゴール再帰を学ぶことは必要条件ではないことを示した（トップダウンシミュレーション 2）
 - ゴール再帰を重視することを避けるように被験者に教示を与えたとしたら，より代わりの知識や手続きを生成する可能性が高い，可能性がある
future work

5.2. 評価

- ・ CLARION はボトムアップとトップダウンの学習の能力がある
- ・ 手間取った問題点
 - 同じモデルが異なる学習の方向性を説明できるか？
（CLARION はボトムアップ学習モデルとして構築されたため）

5.3. まとめ

- ・ 本研究は、スキル獲得において重要だが無視されてきた、顕在的学習と潜在的学習の問題に対して取り組んだ
- ・ シミュレーションにおいて、被験者データを多くの方法で捉えることができた
 - スキル学習に対して実行可能な方法としての2つの方向性
 - トップダウン学習がより被験者のパフォーマンスを捉える事ができた
(ハノイの塔が高いレベルで構造化されたており、高次の認知スキルタスクだから)
 - しかしながら、トップダウン学習が有力な方法とはいえ、ボトムアップ学習は、シミュレーションで示したように、存在している可能性があった
 - 支配的なトップダウン学習の状況におけるボトムアップ学習の可能性を示した
ボトムアップ学習の広がり
 - モデルの観点から、このタスクのシミュレーションが CLARION の適用範囲を広げた
低次から高次へ
 - それゆえ、CLARION は、潜在的/顕在的プロセスの一般的な機械的説明を提供する