

ACT-R/PM and menu selection: applying a cognitive architecture to HCI

Introduction

- HCIにおける心理学
 - GOMS
 - ◇ タスクアナリシスの手法（ゴール，オペレータ，メソッド，選択規則（GOMS））
 - ◇ デスクトップスタイルのインターフェースに対して実りの多いアプローチ
 - GOMSの根底にはプロダクションシステムの考え方がある（Card, 1999）
 - ◇ ACT, Soar, EPIC
- HCIはデスクトップ上だけではない
 - ナビゲーションシステムなど，マルチモーダルでタイムクリティカルな課題
実用性，理論的挑戦
ハイパフォーマンスのマルチモーダルインターフェースを扱う方法の開発
- GUIとユーザとのインタラクションの理解には3つのコンポーネントの理解が必要
 - ユーザの認知的な知覚と運動能力
 - 実行されるタスク
 - タスクを実行するのに使用されるアーティファクト
- Nilsen(1991)のランダムメニューセレクションタスクのモデル化
 - インタラクティブなタスクのモデリングのために作られた知覚-運動モジュールを持ったプロダクションシステム ACT-R/PM
 - ゼロパラメータでのデータへのフィット
 - メニューセレクションとヴィジュアルサーチの根底にあるプロセスの更なる理解

1. The embodied cognition-task-artefact (ETA) triad

- the Cognition-Task-Artefact
インタラクティブな行動を理解するための初期のフレームワーク
- ETA(the embodied cognition-task-artefact) Fig. 1
 - をベースにしたフレームワーク
 - インターフェースと相互作用するユーザのインタラクティブな行動は，3つの事物の関数からなる
 - ◇ ユーザの認知と知覚と運動の能力（embodied cognition）
 - ◇ タスク（ユーザが取り組んでいるタスク）
 - ◇ アーティファクト（タスクを行う目的で従事するもの）
- 従来の研究
 - 一般的には，図のような3つ組みで考えず，ペアで考えた
 - ◇ コンピュータ科学者：タスクを支援するためにアーティファクトをデザインしたが，ユーザの能力や限界を無視した
 - ◇ 実験心理学者：ユーザに関心を持ったが，アーティファクトを最小限に抑えたり排除して

人工的タスクや文脈で実験を行った

◇ エスノグラフィック分析：アーティファクトやタスクの文脈を考えたが，人の能力や限界に根ざした問題を見過ごした

- ・ 認知モデリングは一度にこれら 3 つを考えることを要求する
 - EPIC, Soar：ユーザの能力や限界の記述を行ったが，タスクやアーティファクトは含まれていない

1：統合された認知

- ・ 伝統的 AI や認知科学システムは，人を純粋な認知的存在として取り扱うという失敗を犯した
 - チェスなどのアブストラクトなタスクではこれで十分である
 - しかし，知覚-運動の能力と限界を無視することは高パフォーマンスのアプリケーションにおいて役に立たない
 - ◇ 航空管制
 - ◇ ナビゲーションシステム
- ・ コンピュータシステムは組み込まれ，モバイル化されており，知覚-運動システムがインタラクティブな振る舞いを理解することの中心になってきた
 - 理論やその応用がリップサービス以上に必要である

2：タスク

- ・ 例：近年の WWW 上での行動の研究
- ・ 最適化されたインターフェースはデザイナーの時間とユーザの努力を浪費する
- ・ プロトコル分析のような手法は，ユーザが行っている実際のタスクの理解において貴重である

3：アーティファクト

- ・ HCI 研究において重要視されるもの
- ・ ユーザをゴールに向かわせ，現在の状況を支える
- ・ 変更が可能で，影響を受けやすい（例えば，スクリーンのスペース上制限を受ける）
- ・ 事実，コンピューテーショナルなモデリングのようなパフォーマンス分析で一番使用されるものである
- ・ インタラクティブな振る舞いの分析に対するこのフレームワークは完全に新しい物ではない
 - エージェントオリエンティッド AI 研究（e.g. Agre & Rosenschein, 1996）
 - 行動生態学（behavioral ecology）（Cohen, Greenberg, Hart & Howe, 1989）
 - これらのアプローチは良く似ているが，一般的に人の要因を背景にした行動理解に関してはあまり注目していない
- ・ 本アプローチの目的
 - エンジニアリングのアプローチとして考える
 - ◇ 認知心理学におけるモデリング研究の多くのゴールである予測の完全性が目的ではない
 - ◇ できる限りフリーパラメータを持たず，真の値の 20%以内で予測を生成する能力を持つフレームワークを作り，その後，洗練させてゆく

2. ACT-R/PM

- ACT-R/PM(first presented in Byrne & Anderson, 1998)
 - 認知だけでなく，知覚と行動と認知を連携させる
- 本研究の動機
 - 現実には「知覚」や「運動」の可能性が認知的機構を大きく制限している
 - 認知システムは3者の調和を行う
 - 認知分析の焦点の変化
問題空間の純粋な分析 (e.g. Newell & Simon) リソース (認知だけではない) のコントロールや調和
- ACT-R/PM Fig. 2
 - Kieras and Meyer(1997)の EPIC システム大きな影響を受けている
 - モジュール
 - ◇ プロダクションシステムとして実装されている中央認知 (ACT-R)
 - ◇ 4つの知覚-運動モジュール
 - モジュールそれぞれはシリアルプロセスだが，多くのコンポーネントは互いにパラレルに動作する
視覚モジュールが視覚アレイに注意をシフトしている時や，運動モジュールがキーを押す準備をしている間に，宣言的メモリを検索することが可能

2.1. ACT-R PRODUCTION SYSTEM

- ACT-R の全体図(Anderson and Lebiere, 1998 を改変) Fig. 3
- 基本構造
 - 3つのメモリからなる
 - ◇ 宣言的メモリ (チャンクを含む): $3+4=7$
 - ◇ プロダクションメモリ (手続き的メモリ，プロダクションルールを含む): IF-THEN の条件-行動マッピング
 - ◇ ゴールスタック
 - カレントゴールを中心に組織化
- 動作
 - プロダクションサイクル (基本的に 50msec)
 - ◇ プロダクションルールの IF 節が，カレントゴールと宣言的メモリの内容と比較
 - ◇ 条件とマッチしたプロダクションの一つが発火のため選択
 - ◇ 選択されたプロダクションの THEN 節の実行
 - 競合解消
 - ◇ 発火させるプロダクションを決定するプロセス
 - ◇ ACT-R では，一つのサイクルで一つのプロダクションのみが発火され，Soar や EPIC では特定のサイクルでマッチしたすべてのプロダクションが発火する
 - ◇ Anderson(1990)のプロダクションの予測された有効性とそのコストの合理的分析をベースにしている 詳しくは Section4.2
 - ゴールスタック
 - ◇ 新しいゴールをプッシュする
 - ◇ 条件が満たされたゴールがポップされる

- プロダクションメモリ
 - ✧ プロダクションは宣言的メモリからチャンクを検索する
 - ✧ 検索されたチャンクの参照はカレントゴールに追加される
- 知覚-運動モジュール
 - ✧ プロダクションアクションが特定のモジュールがコマンドを実行することを要求する
 - ✧ 知覚-運動モジュールは ACT-R の宣言的メモリを修正可能
- 学習
 - ✧ ACT-R は学習システムである
 - ✧ 宣言的メモリはプロダクションにコンパイル可能

2.2. VISION MODULE Fig. 4

- HCI タスクのモデリングの中心
- ACT-R/PM が何を見たのかを表すモジュール
- ヴィジョンモジュールの ICON において 1 つ以上の特徴によって表される
- ICON 上の特徴は宣言的メモリ上のチャンクにマップされる
- 宣言的知識上のヴィジュアルチャンクがプロダクションの IF 節とマッチングされる
- 値 “ 3 ” というヴィジュアルオブジェクトチャンクは，目を通して見た “ 3 ” という文字の記憶を表しており，意味上の “ THREE ” ではない（そこには，トップ-ダウンの影響はない）

2.3. MOTOR MODULE

- ACT-R/PM の手となる
- 幅広いアクションのためのパラメータからなる
- 運動のヒエラルキー
 - style > hand > finger > direction = distance
- style(EPIC のマニュアルモータープロセッサを基礎にしている)
 - Punch：指のダウンストローク
 - Peck：指の移動
 - Peck-recoil：指を戻す
 - Ply：マウスの移動

2.4. AUDITION AND SPEECH MODULES

- 聴覚-発話モジュールは視覚-運動モジュールよりも発展していない
- メニューサーチタスクに対してはクリティカルではない
- 詳しくは，Byrne and Anderson(1998)を参照

2.5. THE ARTEFACT

- ヴィジョンモジュールの ICON はインターフェースオブジェクトのデータ構造をもとに生成される
- ACT-R/PM はヴァーチャルユーザであり，人が使うソフトウェアを利用する

2.6. SUMMARY

- ACT-R/PM
認知，知覚，そして運動のコンポーネントをもつインタラクティブなタスクの詳細なモデリングを可能にするようにデザインされた知覚-運動モジュールを伴ったプロダクションシステムである

- ACT-R は内在するプロダクションシステムとして利用する
 - インタラクティブな行動をモデル化するための認知理論を再発明したいわけではない
 - ACT-R の問題解決や記憶といった領域における成功を基礎にモデル化する

3. Random menu selection

- ランダムメニュー選択タスク Fig. 5 (詳しくは後ほど)
 - 単純なタスク
 - しかし, ACT-R/PM をデモンストレーションするために, 航空管制のようなより複雑なハイパフォーマンスのタスクのコンポーネントとして考えられるラピッドタスク
- 先行研究におけるモデル化
 - ヴィジュアルインターフェースを持った ACT-R(Anderson et al., 1997)
 - EPIC (Hornof & Kieras, 1997) .
- 本論文におけるモデル
 - ACT-R/PM, 学習を扱う

3.1. THE NILSEN(1991) EXPERIMENT (認知実験)

- 実験内容
 - ユーザはスクリーンに 1 つの数字と”Go”ボタンを提示される Fig. 5(a)
 - ボタンを押した後表示される数字の列から目的の数字を探す Fig. 5(b)
 - 数字列 (メニュー) の長さは 3 , 6 , 9 の 3 種類 .
- 実験結果 Fig. 6
 - 反応時間はおおよそメニューの位置に対して線形である
 - ポジション間で少なくとも約 100msec の差がある
 - 探索はシリアルであり, ”pop-out”効果は見られなかった(Triesman & Gelade, 1980)
 - Nilsen effect
 - ◇ ポジション 1 のみシリアルでなく, ポジション 2 よりもわずかに時間がかかっている
 - メニューの長さの効果がわずかにあり, 長いメニューほど反応が遅くなる
 - フィッツの法則(Fig.6 の破線)はメニューサーチプロセスを正確に捉えていないことを示した
 - ◇ フィッツの法則
現在のマウスポインタの位置から対象に移動する時間の法則
 $T = k \log(D/S + 0.5)$
T: 対象への移動時間, D: 距離, S: ターゲットの大きさ, $k \sim 100\text{msec}$
 - このタスクの時間の大部分は視覚探索に対する時間であると Nilsen は議論した

3.2. THE ACT-R VISUAL INTERFACE MODEL(ANDERSON, MATESSA & LEBIERE, 1997)

- このモデルは非常にシンプルであるが, 多くの興味深い予測を示した
- ACT-R/PM と同様のヴィジュアルシステムを持つ
 - ターゲットの文字に注意が向けられ, 文字にある特徴がランダムに選択される
 - サーチプロダクションが, 同じ特徴を含む一番近い場所に対してテストし, 注意をシフトする
 - もしターゲットがあれば, ターゲットをクリックする
 - もしなければ, サーチプロセスはメニューを下り続ける
- 2 つのプロダクションにおいて表現される

- HUNT-FEATURE
 - IF 目的が特徴 F を持つターゲットを見つけること
 - &
 - 現在の場所より下に特徴 F を伴ったオブジェクトがあるあるなら
 - THNE その場所に注意を移動し，マウスを近づける
- FOUND-TARGET
 - IF 目的がターゲットを見つけること
 - &
 - ターゲットが現在注意が向けられている場所 L であるなら
 - THEN L にマウスを移動し，クリックせよ

・ 結果

- 線形性を示す
- メニュー長や Nilsen 効果を示さない
- ヴィジュアル的な特徴によって探索がガイドされるため，数字のバックグラウンド上の文字ターゲットに対する探索は数字ターゲットよりも速くなる

・ 注意のシフト=サッカードと仮定すると，ACT-R のビジョンインターフェースモジュールは以下を仮定している

- 眼球運動は排他的にトップからボトムへの運動であり，バックトラックしない
- 各サッカードにおける移動距離はトライアル毎に様々である．ターゲットと特徴を共有しないアイテムはスキップされ，すべてのアイテムがテストされることは無い．探索は網羅的ではなく，多くのアイテムはスキップされる．
- 眼球はターゲットをオーバーシュートすることは無い

3.3. THE EPIC MODEL(HORNOF & KIERAS, 1997)

・ ACT-R/PM との 2 つの本質的違い

- ヴィジュアルシステム
 - ◇ 特徴情報を用いない
- 認知システム
 - ◇ EPIC は複数のプロダクションを一度に発火可能
 - ◇ ヴィジュアルシステムによって複数のアイテムがワーキングメモリに置かれ、すべてを評価することが可能（同時に中心窩にとられえられるアイテムは制限されている）
 - ◇ 15/85 でアイテム一つしか捕らえない場合と 3 つ捉えられる場合とした（距離の変化に対応，15/85 の定義は不明，おそらくフリーパラメータ）
 - Nilsen の実験ではモニタの距離を測定しなかったため，2 度の中心窩(EPIC の中心窩の角度)にとられえられるメニューアイテムの数がいくつだったのかは正確にはわからない
 - ◇ デュアルストラテジ
 - 50/50 でランダムストラテジと体系的探索ストラテジを用いる（おそらくフリーパラメータ） Fig. 7
 - 体系的探索方略：メニューを上から下に探索する
 - ランダム探索方略：ランダムに探索する
- 眼球運動に対する予測

- ◇ 眼球運動のパターンはトップからボトムへの探索とランダムな探索が半々
- ◇ 探索者が平行に複数のアイテムを探索しているため、サッカードにおいてターゲットアイテムをオーバーシュートする可能性がある
- ACT-R のヴィジュアルインターフェースモデルよりもより複雑だが、オリジナルデータに対してよい説明を与えている
 - ◇ 距離の効果を再現
 - ◇ Nilsen 効果を再現
 - ◇ 特徴情報を用いていないため、数字のデストラクタを伴った文字の探索が速い場合を表現できていない

3.4. EYE-TRACKING DATA (BYRNE et al., 1999)

3.4.1. Methods

- ・ タスク Fig. 8
 - 矩形の中にターゲットである数字が表示され、クリックするとメニューが表示される
 - メニューの中のターゲットを探索し、クリックする
- ・ 被験者：大学生 11 名
- ・ 被験者内要因
 - メニュー長 (6, 9, 12) 3 アイテムのメニューで眼球運動の興味深いものが無かったため
 - ターゲット位置 (各メニューに対してすべての位置について調べられた)
 - ターゲットタイプ (文字, 数字)
 - デストラクタタイプ (文字, 数字)
- ・ 全 108 試行

3.4.2. Results

- ・ 反応時間 Fig. 9(a)
 - 反応時間はターゲット位置の関数となっている
 - Nilsen 効果
 - しかし、他の Nilsen の結果は明確に再現できなかった
 - ◇ 傾きが緩やか
 - ◇ メニュー長の主効果が少ない (75msec, Nilsen の実験では 103msec)
 - メニュー間の距離が長いことが関係しているかも?
 - 練習効果 (Nilsen はより多くの練習を行わせた)?
- ・ 停留 Fig.9(b)
- ・ 反応時間の決定要因はヴィジュアルサーチプロセス
 - 停留と反応時間がお互いによく一致する: $r(26) = 0.97, p < 0.001$
- ・ initial サッカードのヒストグラム Fig. 10
 - Fig. 10 に対する ACT-R と EPIC モデルが予測と実測値 (Tab. 2)
 - どちらのモデルも特別良い予測ではない、決定係数は EPIC : 0.37, ACT-R : 0.52
- ・ middle サッカード Fig. 11(a)
 - + : メニューを下がる動き, - : メニューを上がる動き
 - モデルと実験データとの不一致
 - ◇ ACT-R モデルではボトム トップを想定していない
 - ◇ EPIC モデルでは 50% の確率でランダムストラテジをとるため分布は矩形となる

- ◇ しかし、どちらかといえば EPIC モデルは実験データに近い
- ・ final サッカーカード Fig. 11(b)
 - モデルと実験データとの不一致
 - ◇ 上記と同様
- ・ リプレイデータの結果に対してモデルが示していないこと
 - 両モデルは最後まで同じ方略を用いていた（グローバルストラテジ）
 - 完全なトップ ダウンはほとんどない
 - 完全にランダムなトライアルもほとんどない
 - initial サッカーカードでは、完全にランダムだと思われる
- ・ ACT-R/PM モデル
 - ACT-R/PM モデルによるより良いデータへのフィッティング
 - どのようにしてローカルで複雑なストラテジが構築されえるのかを理解する

4. An ACT-R/PM model of random menu selection

4.1. THE EPIC-INSPIRED MODEL

- ・ ACT-R モデルや EPIC モデルのようなグローバルストラテジを使う代わりに、各サッカーカードのレベルにおける複合的なオプションを持ったモデルを構築
 - ・ タスクを 2 つのフェーズに分ける
 - 初期のサッカーカード
 - ◇ 5 つのプロダクションによってコントロール
 - それぞれ、単純に最初の 5 つの位置のうちの一つに注意を向ける
 - 初期以外のサッカーカード
 - ◇ 続くすべてのサッカーカードは、2 つのプロダクションが競合する
 - ◇ 2 つのプロダクションは 2 つのローカルストラテジを表現する
 - DOWN-NEAREST-HIT
 - 特徴が一致し近くてまだ見ていない文字まで移動
 - IF ゴールが特徴 F を持つターゲットを発見することであり
 - 今の場所より下に特徴 F を持つまだ注意を向けていないオブジェクトがある
 - THEN その場所に注意を向ける
 - LOOK-ANYWHERE
 - ランダムにまだ見ていない文字まで移動
 - IF ゴールがターゲットを見つけることであり
 - どこかに注意を向けていないオブジェクトがあるなら
 - THEN 注意をその場所に向ける
- このモデルは EPIC モデルに類似しているが、意思決定はグローバルレベル（トライアルレベル）ではなく、ローカルレベル（サッカーカード）で行われると予想される
- ACT-R における競合解消について
 - ◇ 各プロダクションは期待値 E を持ち、PG-C 式をもとに計算される
 - P：プロダクションが発火したときに、ゴールが満足するものである可能性

- G : ゴールの値 , デフォルトで 20
- C : コスト , ゴールに到達するコスト (単位は時間)
- ◇ デフォルトで各プロダクションは同じ PG-C 値を持つが , 学習を通して変化する
- ◇ ACT-R はある程度の確率的な値を持つ
 - 各サイクルにおいて , PG-C 値はノイズ (平均ゼロ) で乱される
 - プロダクション i が各サイクルで選択される確率は期待利得 E_i の関数
 - 各モデルにおいて , 競合解消においてすべてのプロダクションは同じ期待利得を持たため , すべてのプロダクションは等しい確率を持つ
 - 初期の停留に対して競合する 5 つのプロダクションは各々 20% の確率で発火する
 - それ以降の 2 つのプロダクションは 50% の確率で発火する

- 学習前の結果 Fig. 13, 14
 - ◇ フラットなグラフになるため初期のサッカーのヒストグラムについては議論しない
 - ◇ データに対して全体的に説明が poor
 - ◇ 反応時間と停留
 - 反応時間に対する平均絶対誤差 : 24.38%
 - 停留の数に対する平均絶対誤差 : 22.80%
 - ◇ サッカーパターン
 - ACT-R モデルと EPIC モデルよりもよくフィットする
 - 実験データと同様 , 最頻度値は 1 つメニューを下がったところで , メニューを下がる側の分散が大きい

- 学習後の結果
 - ◇ ACT-R は競合解消をコントロールするパラメータを学習できる
 - P : 成功の確率 (一定)
 - q と r からなる
 - q : 競合解消によって選ばれた場合に発火できる確率 . プロダクションは , 閾値以下の宣言的メモリからチャンクを検索しようとしたときに失敗する . このモデルはそのような検索をしようとするのがないため , q は常に 1.0 .
 - r : プロダクションが発火したときに , ゴールが最終的にポップする確率 . モデルは最終的にターゲットを発見するので , r は 1.0 に固定 .
 - C : ゴール到達へのコスト
 - a と b の 2 つのパラメータの和でトータルコストを表す
 - a : プロダクションが発火するために必要なコスト . デフォルトで 50ms . 宣言的知識からの検索に対してとられる時間がプラスされる . このモデルでは宣言的知識からの検索も行わないため , すべてのプロダクションに対して a は変化しない .
 - b : プロダクションが発火しゴールがポップするまでの見積み時間 . プロダクション発火の “ 下流 ” コスト .
 - ◇ 5000 トライアルに対する初期のサッカーのプロダクションのそれぞれに対する b 値 Fig. 15
 - 各トライアルでは , メニュー長 , メニュー位置 , ターゲットタイプ (数字 , 文字) , デストラクタタイプ (数字 , 文字) をランダムに選択
 - 初期のトライアルにおける発散

800 あたりで収束

- ATTEND-FIRST-POSITION プロダクション
 - 3000 トライアルまでは明確ではないが最終的に優先される（一番下の曲線）
- ◇ 各プロダクションの最終的な b 値によって計算された選択確率 Tab. 3
 - 初期のサッカーでは、メニューを少し下がる動きを示すプロダクションが選択される
 - 実際の初期のサッカーのデータとの適合は改善された (r 二乗: 0.89) が、モデルの最頻値はまだ正確ではない
- ◇ 5000 トライアル後の初期以外のサッカープロダクションに対する b 値 Fig. 16
 - モデルはLOOK-ANYWHEREよりもDOWN-NEAREST-HITプロダクションを選択
 - 競合解消の比率
 - DOWN-NEAREST-HIT: 66.5%
 - LOOK-ANYWHERE: 33.5%
- ◇ Middle サッカーと Final サッカー Fig. 17
 - middle サッカー: わずかにフィット率が悪い (r 二乗: 0.83 0.81)
 - final サッカー: フィット率は悪い (r 二乗: 0.62)
 - サッカーのフィット率の変化: 反応時間と停留数の改善に伴ったもの
- ◇ 反応時間と停留へのフィット Fig. 18
 - 学習することによってモデルのパフォーマンスが少し改善したが、全体的にまだフィット率は低い (反応時間の絶対誤差: 21.27%, 停留の絶対誤差: 21.28%), 特にトップ近くのターゲットに対してフィット率が低い
 - ターゲットがメニューの上の方にあり、スキップした場合に時間がかかる
 - モデルの2つのプロダクションの不自然さ
 - DOWN-NEAREST-HIT プロダクションの3つの制約
 - ◇ 今のアイテムよりも下になければならない (方向)
 - ◇ トライアルの最初にランダムに選択される特徴を含まなければならない (特徴)
 - ◇ 近くになければならない (距離)
 - LOOK-ANYWHERE プロダクション
 - ◇ 制約なし
 - 狭いストラテジ空間の探索
 - 次のモデルはより完全な空間を探索することを試みる

4.2. THE INCLUSIVE MODEL

- ・ 前モデルの2つのプロダクションは極端なプロダクションである
 - DOWN-NEAREST-HIT: 3つの制約 (方向, 特徴, 距離) を持つ
 - LOOK-ANYWHERE: 制約なし
- ・ 3つの制約 (方向, 距離, 特徴) の組み合わせで8種類のプロダクションを考える
 - DOWN-NEAREST-HIT:
 - DOWN-NEAREST:
 - DOWN-ANY-HIT:
 - DOWN-ANYWHERE:
 - ANY-NEAREST-HIT:

- ANY-NEAREST :
- ANY-HIT :
- ANYWHERE :
- 目的 : 大きなストラテジ空間をモデルに与え , モデルに学習を行わせる
- 学習前の結果
 - 学習前の反応時間と停留 Fig. 19
 - ◇ 反応時間の平均標準誤差 : 17.86% , 近いターゲットでは反応が遅いが , フィット率は良い
 - ◇ 停留の標準平均誤差 : 14.46% , フィット率は良い
 - サッカーの分布 Fig. 20
 - ◇ サッカーの分布は非常に良いわけではない
 - ◇ middle と final サッカーの s 二乗 : 0.68, 0.79
 - ◇ 反応時間と停留は学習前でよい値を示したが , サッカーの分布は正確ではなく , 特に middle サッカーの位置 1 でははるかに大きな値を示している
- 学習後の結果
 - 初期のサッカーに対する 5 つのプロダクションの学習曲線 Fig. 21
 - ◇ 1000 トライアル付近で収束する
 - ◇ 5000 トライアル後
 - 最も好まれるプロダクション : 最初のアイテムを選択 (全体の 21.9%)
 - 最も好まれないプロダクション : 2 番目のアイテムを選択 (全体の 18.0%)
 - ◇ 全体的に初期のプロダクションに対するパフォーマンスに関してほとんど変化なし , 実際のデータよりもわずかに悪い (s 二乗 : 0.76)
 - 8 つのプロダクションに対する学習曲線と選択確率 Fig. 22, Tab. 4
 - ◇ はっきりとした優先傾向が現れた
 - パフォーマンス 1
 - 特徴とのマッチングをとるプロダクションが優先される
 - 制限の少ないプロダクションが実用的でないことを学ばなかった . 約 4 分の 1 の確率で 4 つ (Down-nearest, Down-Anywhere, Nearest, Anywhere) のうちの 1 つを発火する (26.4%)
 - パフォーマンス 2
 - ANY-* > DOWN-*
 - もし , DOWN-* が行き過ぎた場合 , ANY-* プロダクションがそれを補う方法になっているため
 - Any-* はメニューを up , down 可能
驚くべき結果ではない
EPIC-inspired モデルは DOWN-NEAREST-HIT に対するパフォーマンスを構築した , これは驚くべきこと
 - *-HIT の効果は他のパフォーマンスに優先する
 - パフォーマンス 3
 - NEAREST の付いているプロダクションのパフォーマンスが少し良くなる
 - ◇ ACT-R モデルの振る舞いは , 最も好まれるプロダクションに依存するだけでなく , その他の競合する他のプロダクションにも依存する

- 反応時間 Fig. 23(a)
 - ◇ 全体的に向上：平均標準誤差：12.96% (1/3 減少)
 - ◇ Nilsen effect を示す (実際のデータよりははっきりしないが)
 - 停留 Fig. 23(b)
 - ◇ 向上せず：平均標準誤差：16.77%
 - ◇ 距離が遠い場所で停留回数が多くなっている
 - middle サッカー ド Fig. 24(a)
 - ◇ s-squared : 0.68 0.84
 - ◇ 最頻値が近づいた
 - final サッカー ド Fig. 24(b)
 - ◇ s-squared : 0.79 0.84
 - ◇ 全体的に向上した
- モデルの成功の鍵
 - グローバルストラテジよりもローカルストラテジに注目
 - 眼球運動データは確かにグローバルストラテジに従っておらず，ローカルな意思決定が支配的である

5. General discussion

- このモデルは確かに完全なモデルではなく，他のモデルを置き換えるモノではないが，グローバルストラテジよりもローカルストラテジによって駆動されるようなタスクを考えることにおいては非常に強力であるということは示唆される
- 本研究のタスクは任意のディスプレイをサーチすることを要求するタスクに共通である
- ACT-R/PM アプローチのアドバンテージ
 - フリーパラメータの排除
モデルとデータをフィット率を最適にするために操作される数値的パラメータはない
Nilsen のデータの EPIC モデルと対照的 (2つのパラメータが操作されていた)
 - ACT-R/PM のデフォルトパラメータは他の文脈においても機能する (e.g. Byrne & Anderson, 1998; in press; Ehret, 1999; Gray, Scholles & Fu, 2000)
- ETA 分解は，ACT-R/PM のような洗練されたモデリングシステムとともに，シンプルメニューセレクションよりも多くの要求を持つインタラクティブなシステムの分析を記述できるだろう (軍事関連，民間航空機の完成コントロール，ナビゲーションシステム，救急治療室，ウェアラブルコンピュータ，など)
- ACT-R/PM や EPIC-Soar のようなシステムの出現は，インタラクティブなタスクにおける認知，知覚，行動の協調やどのように協調を作るのかについて，理論的および実用的両面で，追いつけることを提供する