

Swarm Intelligence による高次認知モデリング

Modeling Human Intelligence with Swarm Intelligence

松香敏彦 (PY), 森川彰博

Toshihiko Matsuka (PY) and Akihiro Morikawa

千葉大学文学部行動科学科

{matsuka, amorikaw}@cogsci.L.chiba-u.ac.jp

Abstract—The numbers of recent research on human cognition have indicated that a key process involved in apparently complex high-order cognition is heuristic computation. Accordingly, the present research applied a Particle Swarm Optimization (PSO) method, a type of metaheuristic algorithm, in modeling high-order human cognition. The results of a simulation study indicated a model based on PSO offered much a simpler way to achieve simultaneous learning of diverse notions than other metaheuristic methods.

Keywords—Cognitive Modeling, Swarm Intelligence, Connectionists

1 序論

Particle Swarm Optimization (PSO) は昆虫の群れ等の行動形態モデルを応用した確率的最適化法で、単純な演算の集合によって複雑な関数等の解を算出することが可能であり、その有効性は多数の実用的場面での応用によって示されている [1]。本研究では、PSO を用いて人間の学習行動のモデル化を試みた。特に、一見複雑且つ、高次認知の知識ユニットと考えられる概念の学習過程が、PSO といった簡素な演算の集合によって説明可能か検証をおこなった。なお、認知科学において概念形成とは、刺激・情報のカテゴリ化の学習と見なされる場合が多く、本研究では概念形成とカテゴリ学習を同じ認知処理として考える。

人間の高次認知処理は柔軟で、高い水準で有効な解を算出し、また複雑な意味構造を理解することができるが、Gigerenzer ら [2] は簡素な Heuristicsこそが人間の高次認知の主要な処理だと主張している。また、最近では、Matsuka ら [3] が、Metaheuristics (simulated annealing, genetic algorithm, evolutionary strategy 等) を応用した認知モデルを検証している。誤差逆伝播法と比べ、これらの metaheuristics は組み込まれた学習アルゴリズムの定性的解釈の向上だけではなく、人間の行動実験のデータをより定量的に説明できることがシミュレーションによって示されている。

今回 PSO を用いた主な理由は、次の通りである。一つの swarm を一つの方略と解釈した場合、PSO では学習過程において、複数の「有用」な方略群に自然にクラ

スタ化すると考えられ、行動実験などでみられる、複数の方略の同時学習が容易かつ自然に実現できる。

2 概念モデル

これまでに、複数の概念形成の認知モデルが提案されてきたが、本研究では柔軟な内部表象機能をもつ SUPERSET [3] の Feedforward アルゴリズムを応用し、学習 (backward) アルゴリズムに PSO を用いた。SUPERSET は、ともに I 次元の特徴を保有する内部基準点 R_{ji} とインプット刺激 x_i の心理的距離に基づいてカテゴリ化をおこなう。心理的距離は式 1 によって計算される：

$$s_j^n(\mathbf{x}) = \sum_{i=1}^I \frac{(R_{ji}^n - x_i)^2}{1 + \exp(-D_{ji}^n)} + \sum_{i=1}^{I-1} \sum_{m=i+1}^I 2C_{jim}^n (R_{ji}^n - x_i)(R_{jm}^n - x_m) \quad (1)$$

$D_{ji} \in \mathcal{R}$ は各特徴次元ごとに向けられる選択的注意であるが、sigmoid 関数によって置換されているため、実質的な「特徴次元への注意」は 0 から 1 に収まると解釈できる。 C_{jim} は特徴次元 i と m の相関に向けられる選択的注意で、 C は次の条件を満たすものとする： $C_{jim} = C_{jmi}$ 、 $C_{jim}^2 \leq \left\{ (1 + \exp(-D_{ji}))^{-1} \cdot (1 + \exp(-D_{jm}))^{-1} \right\}$ 。本研究では、 D と C は学習の対象になる係数である。上付き記号 n は個別の方略、つまり各 swarm を示している。

この心理的距離に重み付けされた数値が、カテゴリノードに入力され、各カテゴリ出力が算出される。重み w は各基準点と各カテゴリノードの関連性に影響される学習可能な係数である。

$$O_k^n = \sum_k w_{kj}^n s_j^n(\mathbf{x}) \quad (2)$$

入力 \mathbf{x} がカテゴリ A と分類される確率は $P(A|\mathbf{x}) = \exp(\phi O_A) / \sum_k \exp(\phi O_k)$ とする。

3 学習モデル

学習モデルには単純な PSO を用いた。特に、学習可能な係数を $\theta^n \in \{D_{ji}^n, C_{jim}^n, w_{kj}^n\}$ とした場合、

$$\theta_i^n(t+1) = \theta_i^n(t) + v_i^n(t+1) \quad (3)$$

のように各係数は更新される。 v は各方略の学習の軌道で式 4 によって導かれる：

$$v_i^n(t+1) = v_i^n(t) + \omega_1 UNI(M_i^n - \theta_i^n) + \omega_2 UNI(M_i^* - \theta_i^n) \quad (4)$$

UNI は一様乱数で、 M_i^n は方略 n の学習軌道上にある最適な方略、 M_i^* は全ての方略の中で最適な方略である。最適な方略とは、式 5 の学習目的関数によって定義される。

$$\Upsilon(\theta^n) = E(\theta^n) + \lambda_w S(\mathbf{w}^n) + \lambda_D S(\mathbf{D}^n) + \lambda_C S(\mathbf{C}^n) \quad (5)$$

第 1 項は方略の精度、第 2 から 4 項は各係数群に課せられた複雑性へのペナルティーで、 λ によって重み付けをされている。学習は簡素で正しい方略の習得とみなしている。

4 シミュレーション

本研究では、Matsuka ら [4] がおこなった行動実験シミュレーションを、PSO を用いた認知モデルで再現し、その妥当性について検証をおこなった。対象となる行動実験では、重複する特徴次元の認知処理を分析した結果、多くの被験者は重複する次元の一方のみをカテゴリ化に利用していた。興味深いのは、それら被験者の内数名は行動的には重複する一方の特徴次元のみを利用しているが、他方の特徴次元が有効ということも認識していることだった。つまり、学習時に複数の有効な方略群を習得していたことが対象となる行動実験では解った。

Matsuka ら [4] は、この行動パターンを Evolutionary Strategy (ES) を用いて説明したが、複数の方略群の習得には、能動的に方略群の多様化をすることが必要であった。具体的には、例えば n 個の方略を保持している場合、フィードバックがある度に全ての方略対の距離を計算し、近似する方略にペナルティを与えていた。しかし、今回用いた PSO では式 4 の ω_1 と ω_2 に適切な値を割り当てると、ごく自然に方略群が多様化されることが予想される。

4.1 手続き

学習過程の設定は、Matsuka ら [4] と一致させた。Swarm の数は 30 とし、 $\omega_1 = 0.2$ 、 $\omega_2 = 0.55$ 、 $\lambda_w = 0.2$ 、 $\lambda_D = 0.5$ 、 $\lambda_C = 1.0$ とした。式 5 の E 関数はリハーシング学習 [4] を応用し、 S 関数は weight decay (\mathbf{w} & \mathbf{C}) と weight elimination を用いた。

4.2 結果と考察

シミュレーションの結果は表 1 のとおりである。Matsuka ら [4] の ES を用いた認知モデルの結果も比較のため掲載してある。二つのモデルは共に似たような正答率を得たが、方略の多様性においては相違がみられた。

表 1: シミュレーション結果

Model	AVG diff.	MAX diff.	accuracy
PSO	1	1	0.92
ES	0.24	0.67	0.94

ここでの、「方略の多様性」とは、行動的には選択的注意は払われていない特徴次元が、潜在的には他の有益な次元より重用視している方略を保持していることである。すなわち、行動に現れる swarm と行動に現れない swarm 間で係数 D の違いを方略の多様性と定義した。PSO では、多様性指数の平均値は 0.51 で、最大値は 0.86 であったが、ES では平均値が 0.24、最大値が 0.67 であった。この結果から PSO は、複数の方略の同時学習が再現できることが解った。

興味深いのは、PSO においては特別な目的関数を一切用いることなく、多様性のある方略群が学習可能であったが、ES ではフィードバックがあることに $\binom{n}{2}$ 回追加の計算をおこなって多様性のある方略群を学習しようとしていたことだ。PSO は受動的な多様性のある方略群の学習であり、ES は能動的な学習と解釈できるであろう。計算処理的には受動的な学習のほうが簡素だが、全ての人間の学習は受動的とは思えないので、この点では PSO の改善・改良が求められるだろう。

謝辞

本研究はテレコム先端技術研究支援センター (SCAT) および科研費 (20700235) の助成を受けたものである。

参考文献

- [1] A. P. Engelbrecht (2005) “Fundamentals of Computational Swarm Intelligence.” Chichester: Wiley
- [2] G. Gigerenzer, P. M. Todd, and the ABC Research Group (1999) “Simple heuristics that make us smart.” New York: Oxford
- [3] T. Matsuka, Y. Sakamoto, & Chouchourelou, A (2008) “Modeling a flexible representation machinery of human concept learning.” *Neural Networks*, **21**, 289–302.
- [4] T. Matsuka, Y. Sakamoto, A. Chouchourelou, & J. V. Nickerson (In press). “Toward a descriptive cognitive model of human learning.” *Neurocomputing*