

好奇心に基づいたELMによる連想記憶モデルの強化

Kaneko, Shohei / 金子, 昌平

(出版者 / Publisher)

法政大学大学院情報科学研究科

(雑誌名 / Journal or Publication Title)

法政大学大学院紀要. 情報科学研究科編

(巻 / Volume)

13

(開始ページ / Start Page)

1

(終了ページ / End Page)

6

(発行年 / Year)

2017-03-31

(URL)

<https://doi.org/10.15002/00021519>

好奇心に基づいた ELM による連想記憶モデルの強化

Enhancement of Associative Memory Model with Curiosity based ELM

金子 昌平

Shohei Kaneko

法政大学大学院情報科学研究科情報科学専攻

E-mail: shohei.kaneko.3a@stu.hosei.ac.jp

Abstract

Conventionally, most of AI Systems learn and decide actions based on the situations. This is a kind of logical approach without consideration of psychological factors. This research takes account of human's curiosity into memory model for intelligent things. As a learning model, it uses a network called Hopfield Network as a representation of associative memory. The associative memory is a memory system which learns and keeps associative concepts and relations between objects and concepts. This research is mainly focused on curiosity based Extreme Learning Machine (ELM) for enhancement of associative memory model. Based on the psychologist Berlyne's theory, the four elements, novelty, uncertainty, conflict, surprise are indicators of one's curiosity. The associative memory learning or updating strategy are determined by calculating quadruple curiosity vector values in Curiosity Extreme Learning Machine (C-ELM) so as to strengthen learning and memorizing of associative knowledge represented in Hopfield networks. A set of zoo data is applied to two designated scenarios of showing a child's curiosities to animals in experiments and the experimental results of associative knowledge networks are reported with the remarks from various aspects referring to the C-ELM and its implementation.

1. まえがき

従来、AI は作成者が設定した条件に基づいて学習、行動選択を行う。それは完全な論理的行動であり、心理的要素に左右されない。本研究では、AI における記憶や行動選択に好奇心を考慮するとどのような変化が起こるかを考える。好奇心に基づき記憶・行動するという、実際の人間に近い神経活動のメカニズムを再現することを目標とする。従来存在している記憶のモデルに好奇心を考慮することで、従来のモデルより優れた記憶のモデルになることを期待する。

AI は人間の知的営みを模したプログラムであり、どのように記憶をするかが重要である。その中の連想記憶モデルでは、物事を他の物事と関連させて記憶する。これにより、一部の情報から全体を補完することが可能なの

が特徴である。この連想記憶という考え方は、人間の記憶の形式を模した考え方であり、記憶のメカニズムを理解するために使用される。

従来の AI では新規性に向けて注意を向ける能力、または興味を引く能力が欠けている。人間においては、自然なモチベーション、すなわち好奇心によって駆動されるこの能力が一般的に観察されている。好奇心は、探索、調査、学習などの探索的行動に関連する重要な動機として常に認識されている。機械学習の観点からは、不規則なノイズとは対照的に、新規の学習と規則性を学習可能なアルゴリズムとして、好奇心が提案されている。

記憶のモデルとしては、ホップフィールドネットワークという物事の連想記憶を扱うネットワークを使う。それに C-ELM(Curiosity Extreme Learning Machine)という分類器の機能を組み合わせることで実装を行う。C-ELM は、ELM に好奇心の要素を追加して改良を施したものである。心理学者 Berlyne[1]の理論に基づき、物事に対してそれぞれ好奇心の指標となる四つの要素の値を算出する。その値によってどのように学習を行うかを決定する。C-ELM の好奇心と学習戦略を決定する部分を利用しホップフィールドネットワークの学習を強化することを目標とする。本論文の、2 章から 4 章にかけての好奇心に関連する部分の理論の説明は、主に Berlyne の理論や、Wu の論文[2]の 1 章から 6 章を多く参考・引用している。

2. 関連研究

2.1. Berlyne の好奇心の研究

Berlyne [1]によると、伝統的な心理学的研究は、人間が一度に一つの標準的な刺激に対して行う反応を研究する応答選択の問題に集中していた。しかし、好奇心は、刺激選択と呼ばれる応答選択とは異なる問題を扱う。Berlyne は、刺激選択のプロセスを理解するための広範な実験的研究を行い、プロセスを支配する一組の副変数を発見した。それが照合変数(Collative Variables)である。照合変数とは、様々な形態の刺激選択を支配する外部要因を指す。新規性、不確実性、複雑性、驚愕性の四つの主要な変数が存在する。

2.2. ELM (Extreme Learning Machine)

ELM は、分類、回帰、クラスタリング、スパース近似、圧縮および特徴学習のためのフィードフォワードニュー

ラルネットワークである。Huang らの研究[3-5]で、これらのモデルがサポートベクターマシン (SVM) よりも優れていることが示されている。ELM は様々なフィードフォワードネットワーク(RBF, SVM等)を共通の学習アルゴリズムで処理できる。ELM においては、隠れノードにおいて中心集合、標準偏差、重み等のパラメータが存在する。これらはランダムな値で設定される。しかし、RBF において、最適化アルゴリズムを用いてパラメータを設定する研究がおこなわれている[6][7]。本研究では、単一隠れ層フィードフォワードネットワークの中の RBF ネットワークに対して適用することになる。単一とあるように、隠れ層の数は一つのネットワークとなっている。

2.3. C-ELM (Curiosity Extreme Learning Machine)

本研究では、好奇心の心理学に基づいた知的エージェントのための好奇心の一般的な計算モデルを扱う。本研究における C-ELM の作成に関しては、Wu らの研究[2]の理論に基づいて作成する。C-ELM は、好奇心の一般的な計算モデルに基づいた、神経学習エージェントに好奇心を導入した ELM である。ELM は高度な学習速度で高度な汎化性能を示しているが、ELM には以下に述べる大きな問題が残っていた。

- (1). 隠れニューロン数の手動設定：隠れニューロンの数を訓練に先験的に設定する必要があるが、隠れニューロンの数は、通常、試行錯誤によって選択される。
- (2). 固定構造：隠れニューロンの数が設定されると、ネットワーク構造は固定される。学習データに基づいて隠れニューロンを追加または削除することはできない。
- (3). ランダム化効果：隠れニューロンパラメータのラン

ダム割り当ては、生成された結果において高いランダム化効果を誘発する。

上記の三つの問題すべてに対処するため、分類問題のために C-ELM アルゴリズムが提案された。それは好奇心の理論に基づく心理学的にインスパイアされたアルゴリズムである。心理学では、好奇心は人の探索や学習を促す重要な内在的動機として一般的に知られている。好奇心の心理学的概念は、学習能力を高めるために既に計算システムに適用されている。

Berlyne によって提案された心理学の理論に従い、新規性、不確実性、複雑性、驚愕性の四つの変数に基づいて各入力データに対する好奇心査定を実施する。これらの変数は、入力データにおける好奇心刺激のレベルを反映する。好奇心刺激のレベルに基づいて、ネットワークは、ニューロン追加、ニューロン削除、およびパラメータ更新を含む、学習のための戦略を決定する。C-ELM は、隠れ層における隠れニューロンが 0 個から始まり、隠れニューロンを追加または削除し、既存のニューロンのパラメータを更新して、最適なパラメータで最適なネットワーク構造を実現する。ニューロン追加の間、入力データに基づいて新しいニューロンが追加され、それによって ELM のランダム化効果が低減される。パラメータ更新は、再帰的最小二乗法を用いて行われ、ニューロンの削除は最も競合する知識を削除することを目的とする。

3. 連想記憶モデル強化に向けた ELM に基づく好奇心モデル構成

本章においては、使用データとシステム構成の中核となる C-ELM 及び学習戦略について紹介する。本研究のシステム構成図を図 1 に示す。

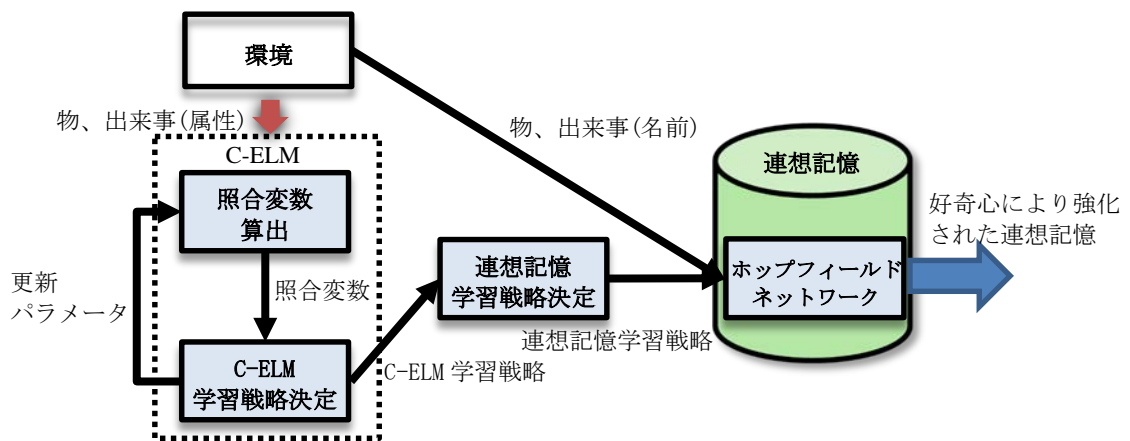


図 1 連想記憶モデル強化に向けた ELM に基づく好奇心モデルの構成。

データから好奇心の指標となる新規性・不確実性・複雑性・驚愕性の値を求める。それら 4 値の大きさによって学習の戦略を決定する。学習の戦略によって、学習に強弱を付ける。学習に強弱をつけることで、「興味のあるものは覚えやすい」といった人間の記憶メカニズムに近づける。C-ELM では好奇心の学習を行い、ホップフ

ールドネットワークではそれに基づいた実際の記憶のための学習を行う役割である。

3.1. 使用データ

本研究で使用するデータは外部環境としてのデータとなる。本研究では、UCI 機械学習リポジトリ[8]から得た

データセットを使用して実験を行う。それを式(1)に従い用意し、入力とする。

$$\{(\mathbf{x}^1, c^1), \dots, (\mathbf{x}^t, c^t), \dots\} \quad (1)$$

\mathbf{x}^t は学習データの特徴であり、 c^t はそれに対応するクラスラベルである。その中で、 \mathbf{x}^t は式(2)で表す。

$$\mathbf{x}^t = [x_1^t, \dots, x_M^t] \quad (2)$$

これは、 t 番目の入力データにおける M 次元の入力ベクトルである。対応するクラスラベルは、式(3)で表す。

$$c^t \in [1, 2, \dots, N] \quad (3)$$

N は異なるクラスの総数を表す。クラスラベルをコード化したものを式(4)で表す。

$$\mathbf{y}^t = [y_1^t, \dots, y_j^t, \dots, y_N^t] \quad (4)$$

式(4)は、クラスラベル c^t を式(5)に従って、変換することによって得られる。

$$y_j^t = \begin{cases} 1, & \text{If } j = c^t \\ -1, & \text{otherwise} \end{cases} \quad j = 1, 2, \dots, N \quad (5)$$

よって、式(4)は正解のクラス番号のインデックスが 1, それ以外は-1 というリストになる。これらとは別に、データセットはそれぞれ異なる名前を保持しており、連想記憶の際に使用する。

3.2. C-ELM

C-ELM のアーキテクチャは、 M 個の入力ニューロン、 K 個の隠れニューロンおよび N 個の出力ニューロンを有する SLFN である。活性化関数を持つ RBF 隠れニューロンの場合、入力 \mathbf{x}^t に対する k 番目の隠れニューロンの出力は式(6)で与えられる。

$$G(\mathbf{x}^t, \mathbf{a}_k, b_k) = g(b_k \|\mathbf{x}^t - \mathbf{a}_k\|), b_k \in R^+ \quad (6)$$

ここで、 \mathbf{a}_k および b_k は、 k 番目の RBF ニューロンの中心(中心集合) およびインパクトファクタ(標準偏差)である。 R^+ はすべての正の実数の集合を表す。RBFは関数の中心を表すパラメータを持っており、入力ベクトルと中心を表すパラメータとの距離によって値が決まる。RBFにはさまざまなものがあるが、本研究ではその中でも最もよく用いられているガウス関数を採用する。

次に、C-ELM において使用する式を羅列する。まずは、推定クラスラベルを式(7)で表す。

$$\hat{\mathbf{y}}^t = [\hat{y}_1^t, \dots, \hat{y}_i^t, \dots, \hat{y}_N^t] \quad (7)$$

i 番目の出力ニューロンを式(8)で導く。

$$\hat{y}_i^t = \sum_{k=1}^K G(\mathbf{x}^t, \mathbf{a}_k, b_k) w_{ki} \quad (8)$$

w_{ki} は、 k 番目の隠れ層ニューロンと i 番目の出力層ニューロンを結ぶ出力重みである。

式(9)は現在の時点での全体の出力となる。

$$\hat{\mathbf{Y}} = \mathbf{H}\mathbf{W} \quad (9)$$

この \mathbf{H} と \mathbf{W} は、それぞれ式(10)と式(11)で表す。

$$\mathbf{H} = \begin{bmatrix} G(\mathbf{x}^1, \mathbf{a}_1, b_1) & \dots & G(\mathbf{x}^1, \mathbf{a}_k, b_k) \\ \vdots & \ddots & \vdots \\ G(\mathbf{x}^t, \mathbf{a}_1, b_1) & \dots & G(\mathbf{x}^t, \mathbf{a}_k, b_k) \end{bmatrix} \quad (10)$$

式(10)は、 t 個の入力データの式(6)に基づく出力である。

$$\mathbf{W} = \begin{bmatrix} w_{11} & \dots & w_{1n} \\ \vdots & \ddots & \vdots \\ w_{K1} & \dots & w_{Kn} \end{bmatrix} \quad (11)$$

式(11)は、隠れ層と出力層間の重み行列を表している。次章にて新規性、不確実性、複雑性、驚愕性の四つの導出について述べる。ここまで紹介した式はこれら導出のために用いられる。

4. 四つの照合変数と C-ELM 学習戦略

4.1. 新規性

新規性の評価は、刺激と過去の経験とを比較することによって達成され、典型性尺度の補完によって定義される。この実装は、新規性を測定するための Berlyne の基準に沿っている。新規性は、類似性に反比例する。

カーネル法では、データの新規性を決定するために球形ポテンシャルを使用する。それは次の式(12)のように定義される。

$$\Psi(\mathbf{x}^t) = \frac{1}{K} \sum_{k=1}^K G(\mathbf{x}^t, \mathbf{a}_k, b_k) \quad (12)$$

より可能性が高いほど、入力データが既存の知識に類似していることを示し、低いほど入力データが新規であることを示す。したがって、入力データ \mathbf{x}^t の新規性 N は、式(13)で表すことが出来る。

$$N(\mathbf{x}^t) = 1 - \frac{1}{K} \sum_{k=1}^K G(\mathbf{x}^t, \mathbf{a}_k, b_k) \quad (13)$$

4.2. 不確実性

不確実性は、刺激に対する明確な反応がないときに生じる。情報理論におけるエントロピーは、刺激における不確実性の程度を測定するために提案されている。

不確実性は、ネットワークが予期していない状態にあるかどうかを判断する。ネットワークの状態は、しばしば、予測の事後確率によって測定される。ヒンジ損失関数は分類問題の事後確率を正確に推定できることが理論的に証明されている。これに従い、切り捨てヒンジ損失誤差を定義する。これを使用して式(14)、式(15)の形式の予測誤差を測定し、クラス c に属する入力 \mathbf{x}^t の推定事後

確率を求める。不確実性は、ネットワークがその予測にどう対応していないかを測定するため、入力データ \mathbf{x}^t に対する予測の不確実性は、式(16)の推定事後確率を用いて表される式(17)で表される。

$$\mathbf{e}^t = [e_1^t, \dots, e_j^t, \dots, e_N^t]^T \in R^N \quad (14)$$

$$e_j^t = \begin{cases} 0, & \text{If } \hat{y}_j^t y_j^t > 1 \\ \min(\max(\hat{y}_j^t - y_j^t, -1), 1), & \text{otherwise} \end{cases} \quad (15)$$

$$p(c|\mathbf{x}^t) = \frac{e_j^t + 1}{2}, \quad c = 1, 2, \dots, N \quad (16)$$

$$U(\mathbf{x}^t) = 1 - p(\hat{c}|\mathbf{x}^t) \quad (17)$$

4.3. 複雑性

心理学では、刺激が生体内で二つ以上の矛盾する反応を引き起こすときに複雑性が検出される。程度は、両立しない対応の強みに左右される。分類においては、最も発火した二つの出力ニューロンが矛盾する強さによって表される。入力 \mathbf{x}^t が与えられた場合に、上位二つの高活性出力ニューロンの出力を抽出する。それらがより近づくほど、より高い競合強度が二つの出力ニューロン間にあり、これはネットワークの決定間のより高い矛盾を示す。よって、複雑性は式(18)で表される。

$$F(\mathbf{x}^t) = \begin{cases} 1 - \frac{|\hat{y}_{j_1}^t - \hat{y}_{j_2}^t|}{|\hat{y}_{j_1}^t + \hat{y}_{j_2}^t|}, & \text{If } \hat{y}_{j_1}^t \hat{y}_{j_2}^t > 0 \\ 0, & \text{otherwise} \end{cases} \quad (18)$$

4.4. 驚愕性

心理学では、驚愕性は期待に反している。分類の場合、予想される出力が真のクラスラベルからずれているときに驚愕性が発生する。驚愕性の程度は、正解クラスと予測されたクラスの両方の予測誤差によって決まる。それは式(19)で表される。

$$S(\mathbf{x}^t) = \begin{cases} |e_c^t \cdot e_{\hat{c}}^t|, & \text{If } \hat{c} \neq c \\ 0, & \text{otherwise} \end{cases} \quad (19)$$

4.5. C-ELM 学習戦略

四つの照合変数のすべては 0 から 1 の範囲に収まる。C-ELM には、ニューロンの追加、ニューロンの削除、パラメータの更新という三つの学習戦略が存在し、その決定は、照合変数の評価に基づいて行われる。次に、C-ELM の三つの学習戦略を紹介する。

(1). **ニューロン追加戦略**: 直感的には、入力データに対して、新規性が高く、不確実性が高く、驚愕性が高い場合にこの戦略を選択する。この場合、ネットワークはこの新しい知識を獲得するために新しいニューロンを追加すべきである。典型的な ELM においては、隠れニューロンのパラメータを無作為に選択

し、分析的に出力重みを見つける。C-ELM では、極限学習能力を損なうことないように、隠れニューロンのデータ駆動中心選択を提案する。新しいニューロンが追加されると、ランダムに中心(中心集合)を割り当てるのではなく、現在の入力データの入力特徴を中心として割り当てる。中心選択はデータ駆動であるので、新たに入力データの目標値を用意し、それに現在のクラスを与えることで、新たなニューロンにラベルを付ける。

- (2). **ニューロン削除戦略**: 直感的には、入力データに対して、驚愕性が高く、複雑性が高く、新規性が低い場合を指す。この場合、ネットワークは、正しい決定を強化し、誤った決定を弱めること、すなわち、間違ったクラスの中で最も発火したニューロンを削除することによって、意思決定を調整する。削除した後、ネットワークは入力データを用いて出力重み \mathbf{W} を再計算する。
- (3). **パラメータ更新戦略**: ニューロン追加戦略とニューロン削除戦略のどちらもトリガされない場合、それは新しい入力データが「おなじみ」であることを示す。したがって、ネットワークは、再帰最小二乗法を使用して出力重みを更新して、よく知られている知識を強化する。更新は式(22)に従い行う。式(20)と式(21)は、その際に使用する要素である。

$$\mathbf{h}^t = [G(\mathbf{x}^t, \mathbf{a}_1, b_1), \dots, G(\mathbf{x}^t, \mathbf{a}_k, b_k)] \quad (20)$$

$$\mathbf{P}^t = \mathbf{P}^{t-1} - \frac{\mathbf{P}^{t-1} \mathbf{h}^t (\mathbf{h}^t)^T \mathbf{P}^{t-1}}{1 + (\mathbf{h}^t)^T \mathbf{P}^{t-1} \mathbf{h}^t} \quad (21)$$

$$\mathbf{W}^t = \mathbf{W}^{t-1} + \mathbf{P}^t \mathbf{h}^t ((\mathbf{y}^t)^T - (\mathbf{h}^t)^T \mathbf{W}^{t-1}) \quad (22)$$

5. 連想記憶ネットワークと連想記憶学習戦略

5.1. ホップフィールドネットワーク

ホップフィールドネットワークは、John Hopfield [9] が提案した相互結合型ネットワークである。相互結合型ネットワークは入力層、出力層がなく、それぞれのユニットは自分以外の全てのユニットと結合している。ユニット数が 4 の時のネットワークを図 2 に示す。




図2 ユニット数 4 のホップフィールドネットワーク。

ホップフィールドネットワークは、何か入力を与えた時に、それと近いパターンに収束する特徴を持つ。そのため、一部の入力情報から、記憶したパターンの全体を呼び出すことが可能であり、これが連想記憶である。

ホップフィールドネットワークの動作に関してだが、ニューロンとニューロンの結びつきを行列式で表し、初期状態は全て 0 とする。自分から自分への結合はないので、自分から自分への結びつきは常に 0 であり不変である。また、ユニット間に対称性があるため、図 2 を例にするとニューロン 1 からニューロン 2 への結びつきと、ニューロン 2 からニューロン 1 への結びつきは常に同値である。ネットワークへの入力としては、ユニットに初期値を「1」か「-1」で与えることで行う。「1」がそのユニットが活動している状態であり、「-1」が活動していない状態である。このユニットの状態の組み合わせを基にネットワークの結びつきの更新、記憶の連想を行う。

5.2. ホップフィールドネットワーク学習戦略

データに対して C-ELM の学習戦略(1)が出た場合、興味があるものとみなして、連想記憶を強くすることを考える。(2)の場合は、興味が無いものとして記憶を弱めることを考える。(3)の場合は、強めも弱めもしないことを考える。実験を行う前に、仮のデータを用いて強め具合弱め具合を検証して決定しておく(6.1 節にて後述)。

5.3. ホップフィールドネットワークの改良

実験でデータを環境から観測すると考えた時に、ホップフィールドネットワークには問題があり、ネットワークを最初に完成させておかなければならない。つまり、後からネットワーク拡張が出来ない。そのため、登場する事物を絞ったシナリオを設定する。また、データ一つのみでの学習は出来ないという問題もあるため、二つ以上の集まりで連想して記憶するという操作が必要である。また、人間は似ている物は脳の中で混同してしまうように、記憶には結びつきが存在する。そのため、本研究では環境上に既に複数の物が存在する状態を想定し、どれかを観測した際に、今まで見たことのある物の中から一番似たものを関連付けるようにする。似たものの判定はユークリッド距離を用いる。

6. 実験方法・実験結果

6.1. 実験方法・実験の準備

実験を行うにあたり、どのように事物を観測するかシナリオを立てる。シナリオは二つ用意する。設定シナリオにて、従来のホップフィールドネットワークと提案手法にて実験を行い、結果を比較する。設定シナリオは、環境下における観測物への興味が低くはないことを前提として設定する。そのため、ニューロン追加戦略がトリガされることを念頭に置くと、後述の式(23)より新規性、不確実性、驚愕性が高い事物を用意することとなる。選択データは、事前に C-ELM へ入力した際に初回は C-ELM のニューロン追加戦略がトリガされた興味を示す好奇心の高いデータ、またはパラメータ更新戦略がトリガされたそこまで好奇心が高くないデータである。その際、C-ELM において設定しなければならないパラメータがある。4.5 節で説明した C-ELM 学習戦略は、四つの照合変

数の値によってどれをトリガするか決定する。ニューロン追加戦略は式(23)に、削除戦略は式(24)に基づく。

$$N(x^t) > \theta_{Nadd} \text{ AND } U(x^t) > \theta_u \text{ AND } S(x^t) > \theta_s \quad (23)$$

$$S(x^t) > \theta_s \text{ AND } F(x^t) > \theta_F \text{ AND } N(x^t) < \theta_{Ndel} \quad (24)$$

事前に調整を行った結果、 θ_{Nadd} は 0.1、 θ_u は 0.1、 θ_s は 0.2、 θ_F は 0.1、 θ_{Ndel} は 0.1 と本研究においては設定した。

また、別の事前に設定する必要がある値として連想記憶の結びつきの強め弱め具合が存在する。これに関しては、表 1 の横軸と縦軸の組み合わせで該当部分の値に設定する。なお、C-ELM の学習戦略の選択は、そのデータを最後に観測した際のものを用いる。

表 1 結びつきの強弱対応表。

	戦略(1)	戦略(2)	戦略(3)
戦略(1)	+4	+1	+2
戦略(2)	+1	-4	-2
戦略(3)	+2	-2	± 0

シナリオ 1 の設定としては、ある小さな子供が動物園に来た時の状況とする。設定環境にはフラミンゴ、キーウィ、チーター、クマ(データ 1~4)が存在する環境とする。この子供は今までこれら動物を見たことがないこととする。シナリオの構成としては、子供は鳥類に興味があり、フラミンゴ、キーウィの順に興味を持つ。チーターやクマにはは然程興味を示さない。シナリオ 1 の詳細な流れは、時間の流れに沿って、時刻 t における行動(観測するデータ)を記した表 2 に示す。

表 2 シナリオ 1 (行動)の時系列。

時間	行動
$t_1 \sim t_{10}$	動物園で、まずはフラミンゴを長く見た
$t_{11} \sim t_{16}$	キーウィの所へ移動し、見た
$t_{17} \sim t_{24}$	フラミンゴを初回ほどではないが長く見た
$t_{25} \sim t_{28}$	チーターを少しだけ見た
$t_{29} \sim t_{30}$	クマを少しだけ見た
$t_{31} \sim t_{35}$	キーウィを初回ほどではないが見た
$t_{36} \sim t_{40}$	最後にフラミンゴを見て動物園を後にした

シナリオ 2 は、子供の状況は、シナリオ 1 と同条件で、設定環境にはフラミンゴ、キーウィ、ペンギン、チーター、クマ、ゴリラ、カメ(順にデータ 1~7 とする)が存在する環境で、この順に興味を持つ。詳細な流れは表 3 に示す。

表 3 シナリオ(行動)の時系列。

時間	行動
$t_1 \sim t_{10}$	鳥類の場所へ行き、フラミンゴを長く見た
$t_{11} \sim t_{16}$	キーウィを見た
$t_{17} \sim t_{24}$	フラミンゴを初回ほどではないが長く見た
$t_{25} \sim t_{29}$	ペンギンを見た
$t_{30} \sim t_{33}$	哺乳類の場所で、チーターを少しだけ見た

$t_{34} \sim t_{37}$	クマを少しだけ見た
$t_{38} \sim t_{40}$	ゴリラを少しだけ見た
$t_{41} \sim t_{43}$	チーターを再度少しだけ見た
$t_{44} \sim t_{45}$	爬虫類の場所で、少しだけカメを見た
$t_{46} \sim t_{50}$	鳥類の場所へ戻り、フラミンゴを見た
$t_{51} \sim t_{53}$	ペンギンを初回ほど長く見ないが見た
$t_{54} \sim t_{59}$	キーウィを初回ほど長く見ないが見た
$t_{60} \sim t_{63}$	最後にフラミンゴを見て動物園を後にした

6.2. 実験結果

シナリオ1のユニット間結合結果の数値の一例を図3に示す。それらを図示したものを図4に示す。図4はユニット間の結びつきの強さを、線の太さで表現し、視覚的に分かりやすくしたものである。

output	flamingo	kiwi	cheetah	bear	output	flamingo	kiwi	cheetah	bear
input					input				
flamingo	0.0	-14.0	-6.0	-6.0	flamingo	0.0	72.0	-30.0	-22.0
kiwi	-14.0	0.0	-6.0	2.0	kiwi	72.0	0.0	-14.0	-30.0
cheetah	-6.0	-6.0	0.0	18.0	cheetah	-30.0	-14.0	0.0	22.0
bear	-6.0	2.0	18.0	0.0	bear	-22.0	-30.0	22.0	0.0

図3 シナリオ1ユニット結合具合。ホップフィールド(左), 提案手法(右)




図4 シナリオ1ユニット結合図。ホップフィールド(左), 提案手法(右)

次に、シナリオ2のユニット間結合結果を図示したものを図5に示す。




図5 シナリオ2ユニット結合図。ホップフィールド(左), 提案手法(右)

7. 考察

図4と図5より、シナリオ1、シナリオ2のどちらにおいても特に興味のあるフラミンゴとキーウィの結合強

化はうまくいった。しかし、登場回数が少なく関係性の薄いもの同士の結合が強いという結果が目立っている。これは、ホップフィールドネットワークの性質上、回避することが難しい問題である。最初にネットワークを完成させ、活動した神経同士の結合を強めるが、一方で活動していないもの同士も強めてしまうことにより引き起こされる問題である。しかし、図5を見ると、シナリオ2の提案手法の結果では、キーウィやペンギン等からの結合において、クマ等に対する結合がホップフィールドネットワークのみの結果より弱まっている。これは、提案手法により特にキーウィが一番似ていると判断されたフラミンゴとの結合を強化する回数が増え、他ユニットとの結合強化回数が減少したためと言える。

8. むすび

本研究の提案手法により、設定シナリオ下において、従来のホップフィールドネットワークと比較して、ネットワークの結合をより人間らしく強化することが出来た。今回使用したホップフィールドネットワーク以外の連想記憶を扱うネットワークとして、Pathnet, EWC, DNC等が存在する。それらにおいても、好奇心部分を導入し、効果を期待したい。ホップフィールドネットワーク以外のネットワークにおいて、最初から全てのネットワークを構成するのではなく、時間経過と共に動的に要素を追加することが可能なネットワークにて、より汎用的な実験を行うことを今後の課題とする。人間らしい記憶モデルを完成させ、ロボットに導入しシミュレーションを行うことも展開として視野に入れる。

文献

- [1] Berlyne, D. E., "Conflict, arousal, and curiosity. McGraw-Hill Book Company", 1960.
- [2] Qiong Wu, "Computational Curiosity", Feb. 2015.
- [3] Huang, Guang-Bin, Hongming Zhou, Xiaojian Ding, Rui Zhang, "Extreme Learning Machine for Regression and Multiclass Classification" (PDF). IEEE Transactions on Systems, Man and Cybernetics - Part B: Cybernetics. 42: 513-529, 2012
- [4] Huang, Guang-Bin, "What are Extreme Learning Machines? Filling the Gap Between Frank Rosenblatt's Dream and John von Neumann's Puzzle", Cognitive Computing. 7., 2015.
- [5] Huang, Guang-Bin, "An Insight into Extreme Learning Machines: Random Neurons, Random Features and Kernels", Cognitive Computation. 6: 376-390, 2014.
- [6] 畠中利治, 近藤伸彦, 魚崎勝司, "多目的進化計算によるパレート最適なRBFネットワークの構成法", 21st Fuzzy System Symposium, Sept. 2005.
- [7] 福田典昭, 成久洋之, "RBFを用いたニューラルネットワーク特性について", 岡山理科大学紀要自然科学, 1998.
- [8] UCI 機械学習リポジトリ, <https://archive.ics.uci.edu/ml/index.php>, (参照 2017-10-17).
- [9] J J Hopfield, "Neural network and physical systems with emergent collective computational abilities", Proceedings of the National Academy of Sciences of the United States of America 79 (13): 2554-8., 1982.