

科学研究費助成事業 研究成果報告書

平成 28 年 6 月 16 日現在

機関番号：85502

研究種目：若手研究(B)

研究期間：2013～2015

課題番号：25730153

研究課題名(和文) 最適構造へ自己組織的に成長する自己成長型モジュラーネットワークの創出

研究課題名(英文) Development of self-evolving modular network which grows to the optimal structure in self-organizing manner

研究代表者

徳永 憲洋 (Tokunaga, Kazuhiro)

独立行政法人水産大学校・その他部局等・講師

研究者番号：00432956

交付決定額(研究期間全体)：(直接経費) 3,200,000円

研究成果の概要(和文)：本研究課題の目的は、自己成長型モジュラーネットワークのバックボーンアルゴリズムとして適用でき、尚且つ、実践に即すような新しい成長型ニューラルネットワークを開発することである。研究の結果、情報量基準をベースに成長する位相表現グラフネットワークを開発し、その学習理論とアルゴリズムを確立させた。また人工データを用いた実験では、提案手法は従来の成長型ニューラルネットワークに比べて少ない学習サンプルで十分な学習結果を得ることができた。また学習結果に一貫性があり学習の安定性が示された。様々な実験の結果から、提案手法は自己成長型モジュラーネットワークのバックボーンアルゴリズムとして有効であると示唆された。

研究成果の概要(英文)：The purpose of this work is to develop new growing neural network for the backbone algorithm of a self-evolving modular network. In this work, an information criterion-based growing topology representing has been proposed. Also its theory and learning algorithm have been established. In the experiments with artificial data, the proposed method has been able to obtain a sufficient results with the less samples as compared with the conventional growing neural network. Also the stability of the learning is shown in the proposed method. From the results of various experiments, it was suggested that the proposed method is effective as a backbone algorithm of the self-evolving modular network.

研究分野：脳情報工学

キーワード：自己成長型モジュラーネットワーク 成長型自己組織化マップ

1. 研究開始当初の背景

申請者はこれまでの研究で、自己成長型モジュラーネットワーク (SEEM) の開発、およびベイズ理論ベースの成長型ニューラルネットワーク (GTR) の開発に従事してきた。

SEEM は成長型自己組織化マップ (ESOM) をバックボーンアルゴリズムとする成長するモジュラーネットワークである。グラフ構造のネットワークアーキテクチャを有し、ノード (モジュール) がオンライン学習で増殖する。またパスはノードが実現する機能の類似性を表す。ノードとパスは、逐次的に入力される情報に対し自己組織的に生成され、最終的には必要十分数のモジュールとネットワーク構造に収束する。この特徴を生かし、申請者は過去の研究で、SEEM をロボットの機能の成長メカニズムとして適用し有効性を示した。しかしバックボーンアルゴリズムである ESOM に問題があり、冗長なノードの生成やノイズに対してノードを生成するなど学習結果に一貫性がなく、実用化の面で不安要素が多かった。

一方、GTR は申請者が科研費 (若手 (B): H23-H24 年度) において提案したベイズ理論をベースに導出された成長型ニューラルネットワークである。申請者は、GTR は ESOM など従来の成長型ニューラルネットワークと比べてノイズに対する頑健性、学習の安定性などが向上することを論文で示した。

以上のことから SEEM のバックボーンアルゴリズムとして GTR を採用することで問題を解決すると考えられるが、GTR は多くの特徴次元を持つ課題では計算時間が飛躍的に増大し、ロボットなどの実時間処理が求められる実践的課題では適用が困難である。

ここで、SEEM のバックボーンアルゴリズムには従来に提案されている様々な成長型ニューラルネットワークを適用することも考えられる。例えば Fritzke の GNG や Shen らの SOINN などがあげられるが、従来手法のほとんどは、データ分布のモデル化という立場から理論と学習アルゴリズムが導出されていない。そのため冗長なノードの生成、ノイズに弱い、学習が不安定、といった問題を持つ。一方、GTR はベイズ理論に基づいて学習アルゴリズムが導出されているため、これら問題点を解決し、一貫性のある結果を得ることが実証されている。ゆえに SEEM のバックボーンアルゴリズムとして GTR を採用する。

2. 研究の目的

本研究課題の目的は、SEEM のバックボーンアルゴリズムとして適用でき、尚且つ、実践に即すような新式成長ニューラルネットワークを GTR ベースで開発し、さらにその学習アルゴリズムを組み込んだ新しい SEEM を開発することである。

3. 研究の方法

本研究計画では、3 年間で以下の 3 パートを行うことを予定した。

GTR をベースにした新しい成長型ニューラルネットワークの開発

で開発された新成長型ニューラルネットワークの動作検証および評価

新 SEEM の開発、動作検証、および実課題を用いた評価

なお、本研究は と がメインであり、は残りの研究期間に余裕がある場合に行う。

と について

科研費 (若手 B: 平成 23 ~ 24 年度) で提案された GTR をベースに新しい成長型ニューラルネットワークの開発を行う。GTR は学習の際に入力データに対してすべてのカーネルの負担率を計算しなければならず、計算に多くの時間を要する。さらに特徴量の次元が高くなれば負担率の計算時間は飛躍的に増加する。このため、より高次の情報処理を必要とする新 SEEM ではクリティカルな問題となり、現在の GTR をそのまま利用できない。この問題を解決するため、新成長型ニューラルネットワークでは自己組織化マップにおける競合・協調メカニズムを GTR の学習理論・アルゴリズムに取り入れる。これにより、全カーネルの負担率を計算する必要がなくなり、大幅に計算時間を短縮できる。これは既にプロトタイプ作成によって確認されている。ただしプロトタイプはアドホックな改良を施しただけである。本研究パートでは、プロトタイプをもとに理論的に学習アルゴリズムを導出し、新成長型ニューラルネットワークの動作を保証させる。また人工データを用いた動作検証を行う。さらに他成長型ニューラルネットワークとの比較実験を行い、提案手法の有効性を示す。

について

新成長型ニューラルネットワークをバックボーンとする新 SEEM の開発を行う。新成長型ニューラルネットワークはデータ間の距離をもとにネットワークが成長するが、新 SEEM では機能の類似度をもとにネットワークが成長する。このため機能の類似度をどのように定義するか、などの調整を必要とする。これに関しては、申請者が提案したモジュラーネットワーク型自己組織化マップの研究論文を参考にする。モジュラーネットワーク型自己組織化マップは機能の類似度をもとに自己組織化マップを生成するメカニズムを有するため、この手法の理論をもとに新 SEEM の理論化もすすめる。動作検証では旧 SEEM で利用した人工データを用いた動作検証・評価を行う。評価は定性的かつ定量的に行う。定量的評価では適切なクラスタリングを可能とするかを Adjusted Random Index (ARI) を利用することで評価する。

4. 研究成果

GTR をベースにした新しい成長型ニューラルネットワークを提案し、そのアルゴリズムを確立させた。まず、本研究で取り扱う課題の枠組みを説明し、その後、提案した手法の枠組みおよび各種理論、そして学習アルゴリズムについて説明する。

その後、人工データを用いた実験を行っているのでその結果についても説明する。

扱う課題の枠組み

入力サンプルベクトル \mathbf{x} があるパラメータ Θ によって記述される確率分布 $p(\mathbf{x}|\Theta)$ のもとで観測されると仮定する。さらに入力サンプルは逐次的に観測され、かつ観測されたサンプルは記憶されずに次のサンプルが来た時点で消去されるものとする。本研究で扱う課題では、この条件下のもと、 $p(\mathbf{x}|\Theta)$ を記述するパラメータ Θ を求めることになる。以上の条件で、本研究では $p(\mathbf{x}|\Theta)$ は $\Theta = \{\pi, M, S\}$, $\pi = \{\pi_k\}$, $M = \{\mu_k\}$, $S = \{\Sigma_k\}$ で定義される混合ガウスモデルによって表現できるとする。すなわち、以下式となる。

$$p(\mathbf{x}|\Theta) = \sum_{k=1}^K \pi_k N(\mathbf{x}|\mu_k, \Sigma_k) \quad (1)$$

提案手法の学習理論は上式をもとに導出されている。ただし、厳密な数学解を求めることは目的とせず、実装の容易性とリアルタイム性に重点を置いて、学習アルゴリズムは導出されている。

提案手法の枠組み

式(1)の確率分布モデルを本研究では提案手法によって表現する。提案手法はガウスカーネルをノード、カーネル間の距離(類似性)を表すエッジ、からなるグラフ構造のネットワークを持つ。すなわち、グラフ構造を持った混合ガウスモデルとも言える。さらに学習にともない、ノードとエッジは自己組織的に増減する。

提案手法のガウスカーネルには超球状の正規分布関数を用いる。すなわち共分散行列 Σ_k は σ_k^2 を対角要素に持つスカラー行列とする。こうすることで、更新などの計算が大幅に短縮される。

またノードおよびエッジの更新では、勝者カーネル(入力ベクトル \mathbf{x}_t に最もマハラノビス距離に近いガウスカーネル)に接続されているカーネルとエッジだけを更新する。

ノードの更新式

ノードの更新は逐次的に行われる。すなわち、混合ガウスモデルのオンラインパラメータ推定を行う。具体的には以下のような更新式になる。

$$\mu_k^{\text{new}} = \mu_k^{\text{old}} + \epsilon_\mu \frac{\gamma_k(\mathbf{x}_t)}{\sigma_k^2} \{ \mathbf{x}_t - \mu_k^{\text{old}} \} \quad (2)$$

$$\sigma_k^{\text{new}} = \sigma_k^{\text{old}} + \epsilon_\sigma \frac{\gamma_k(\mathbf{x}_t)}{\sigma_k^2} \left\{ \frac{\| \mathbf{x}_t - \mu_k^{\text{new}} \|^2}{\sigma_k^2} \right\} \quad (3)$$

$$\pi_k^{\text{new}} = \pi_k^{\text{old}} + \epsilon_\pi \left\{ \frac{\gamma_k(\mathbf{x}_t)}{\pi_k^{\text{old}}} - 1 \right\} \quad (4)$$

ここで、 $\gamma_k(\mathbf{x}_t)$ は負担率であり以下の式で定義される。

$$\gamma_k(\mathbf{x}_t) = \frac{\pi_k^{\text{old}} N(\mathbf{x}_t; \mu_k^{\text{old}}, \sigma_k^{\text{old}})}{\sum_{k \in H} \pi_k^{\text{old}} N(\mathbf{x}_t; \mu_k^{\text{old}}, \sigma_k^{\text{old}})} \quad (5)$$

新規ノードの挿入条件

次に新規ノードの挿入について定義をする。新規ノードの挿入はベイズ情報量基準(BIC)で制御される。本手法では逐次的に入力されるベクトルだけを利用しBICを評価しながら、新規ノードの追加の是非を決定する。

BICを利用した新規ノードの挿入条件の理論の導出過程については、便宜上省略するが、結局、以下の条件式で挿入を制御する。

$$\ln p_{K+1}(\mathbf{x}_T) - \ln p_K(\mathbf{x}_T) > \{C(K+1) - C(K)\} \frac{\ln \tau}{2} + 1 \quad (6)$$

ここで $p_k(\mathbf{x}_t)$ および $p_{K+1}(\mathbf{x}_t)$ は以下で計算する。

$$p(\mathbf{x}_t) = \sum_{k \in H} \pi_k N(\mathbf{x}_t; \mu_k, \sigma_k^2) \quad (7)$$

$$p_{K+1}(\mathbf{x}_T) = \sum_{k \in H} \hat{\pi}_k N(\mathbf{x}_T; \mu_k, \sigma_k) + \pi_{K+1} N(\mathbf{x}_T; \mu_{K+1}, \sigma_{K+1}) \quad (8)$$

エッジによるノード間の接続

エッジは強度を持っており、学習によって強度が増減する。エッジの強度の更新式は以下で定義される。

$$s_{k_1, k_2}^{\text{new}} = (1 - \beta) s_{k_1, k_2}^{\text{old}} + \beta p_{k_1} p_{k_2} \quad (9)$$

上式は k_1 -th ノードと k_2 -th ノード間のエッジの強度を表し、 p_{k_1} と p_{k_2} はそれぞれのカーネルの反応値を表す。は任意の定数であり、課題に合わせて設定する。また本研究では閾値を設け、強度が閾値を下回ったタイミングでエッジを削除している。

学習アルゴリズム

提案手法の学習アルゴリズムは初期プロセス、評価プロセス、挿入プロセス、更新プロセス、削除プロセス、の5プロセスに分けることができる。各プロセスについて以下に説明する。

<初期プロセス>

最初の入力ベクトル \mathbf{x}_1 に対して最初のカーネルを生成する。

<評価プロセス>

入力ベクトル \mathbf{x}_t が与えられる度に、各カー

ネルの中心 μ と入力ベクトル間のマハラノビス距離を計算し、勝者カーネルおよび第二勝者カーネルを決定する。また $p_K(\mathbf{x}_i)$ および $p_{K+1}(\mathbf{x}_i)$ をそれぞれ式(7), 式(8)で計算する。そして条件式(6)を評価し、条件式が満たされれば、挿入プロセスへ、満たされなければ更新プロセスへプロセスを進める。

<挿入プロセス>

入力ベクトル \mathbf{x}_i に対して新規カーネルを挿入する。また新規カーネル, 勝者カーネル, 第二勝者カーネルのそれぞれの間を、エッジで結合する(すなわちノードとパスで三角形ができるようにエッジを結合する)。その際、エッジの強度は式(9)における $s^{\text{old}} = 0$ として計算する。さらに、新規ノードと勝者カーネルに接続されているカーネルの混合比を総和が 1 になるように既存カーネルの $(-1)/$ で正規化する。この後、削除プロセスにプロセスを進める。

<更新プロセス>

既存する各カーネルのパラメータを式(2), (3), (4)に従って更新する。また勝者カーネルに接続されているエッジの強度を式(9)に従って更新する。その際に、勝者カーネルと第二勝者カーネルが接続されていない場合は、新規にエッジで接続する。この後、削除プロセスにプロセスを進める。

<削除プロセス>

削除プロセスでは、ノードとエッジを削除する。ノードは混合比があらかじめ設定した閾値以下になった場合に削除する。またエッジも同様に、あらかじめ設定した閾値以下になった場合に削除する。

そして新たな入力ベクトルを観測し次第、評価プロセスに戻り、学習を継続する。入力ベクトルが観測されなくなった時点で学習を終了とする。

人工データを用いた実験

本実験では人工データを用い、従来手法である GNG, ESOM との比較を行う。実験で用いる人工データは 2 クラスの螺旋データである。螺旋データは 10000 個あり、それを学習サンプルとして用いる。

学習サンプルを各手法に逐次的に与えて学習を行い、教師なしクラスタリングの結果を評価する。タスクとして教師なしクラスタリングを行うことにより、各手法が未知のデータ(しかも逐次的に与えられる)に対して良いモデルを記述できるかどうかを判断できる。ここで、教師なしクラスタリングの結果評価では Adjusted Rand Index (ARI) を用いる。ARI は望ましい分類結果と得られた分類結果の類似性を評価する指標である。本実験のようにグラフを使った教師なしクラスタリングの評価を行

う際には有効な指標といえる。ARI は 0 から 1.0 の値をとり、1.0 に近づくほど良いクラスタリングができていると評価できる。各手法の学習パラメータは、最良のパフォーマンスを出すパラメータをスクリーニングによって得ている。また ESOM においては、学習パラメータ ϵ を変えた 3 パターンの ESOM を比較実験で用いる。

まず学習によって生成された各手法のグラフネットワークの結果例を図 1 に示す。各グラフは 10000 点の学習サンプルを与えた時点でのグラフを示している。図では GNG, ESOM ($\epsilon = 0.3$), 提案手法は二つの螺旋に対してそれぞれグラフを生成しており、教師なしクラスタリングができているが、GNG, ESOM に関しては 2 クラスのグラフを生成することが少ない(定量的評価については後述)。また提案手法に比べて GNG や ESOM はノードを多数生成していることがわかる。提案手法は情報量基準をもとにノードの挿入を制御しているため、必要十分な数のノードしか生成されていないことがわかる。

次に ARI を用いた定量的評価の結果について述べる。GNG の結果では、学習サンプルが多くなるほど ARI 値が高くなった。GNG は十分な結果を得るまでに多くの学習サンプルが必要である。

ESOM においては、早い段階で ARI 値が高くなったが、学習をさせ続けると ARI 値が下がった。これは ESOM の学習の不安定さが招く結果である。ESOM は閾値を用いた単純なアルゴリズムでノード生成が制御されているためノードとエッジ数の増加にともない複雑なグラフが形成される。これにより学習結果の一貫性が欠如し、評価が下がっていると考えられる。

一方、提案手法は学習サンプルが少ない段階(2000 サンプル)で ARI 値が 0.9 を超え、その後、どれだけ学習してもほぼ 1.0 に近い値となった。この結果は提案手法が少ない学習サンプルで十分に結果を得ることができるだけでなく、学習が安定していることを意味している。また提案手法は必要十分なノード数を生成した後はノード数が一定となった。このことも提案手法の学習の安定性を裏付ける結果である。

以上の実験により、提案手法は従来の成長型自己組織化マップに比べて高いパフォーマンスを示すことが分かった。

本手法をバックボーンアルゴリズムとした SEEM については現在、開発中である。

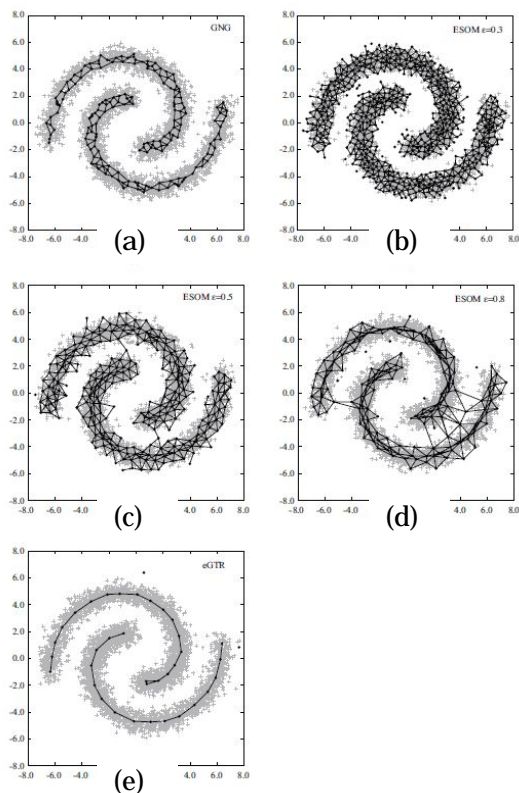


図1. 人工データを用いた実験において, 各手法が生成したグラフネットワークの結果例. 灰色の“+”は学習サンプルを示す. 黒い丸は各手法におけるノード(参照ベクトルユニット)を示し, 黒線はエッジを示す. (a)GNG が生成したグラフネットワーク. (b)ESOM ($\epsilon = 0.3$) が生成したグラフネットワーク. (c)ESOM ($\epsilon = 0.5$) が生成したグラフネットワーク. (d) ESOM ($\epsilon = 0.8$) が生成したグラフネットワーク. (e) eGTR が生成したグラフネットワーク.

5. 主な発表論文等

(研究代表者、研究分担者及び連携研究者には下線)

〔雑誌論文〕(計 1件)

K. Tokunaga, Growing topology representing network, Applied Soft Computing, vol.22, pp.311-322, 2014, 査読有

〔学会発表〕(計 6件)

K. Tokunaga, Color quantization and image segmentation by enhanced evolving self-organizing map, International Workshop on Smart Info-Media Systems in Asia (SISA2014), ベトナム, 2014年10月

徳永憲洋, 末竹規哲, 自己成長型自己組織化マップを用いた色量子化, 電子情報通信学会技術研究報告 スマートインフ

オメディアシステム研究会, 2014年12月

徳永憲洋, 松田成午, 佐藤文彦, Evolving self-organizing map を用いた自己成長型ニューラルネットワークの提案, 第19回日本知能情報ファジィ学会中国・四国支部大会, 2015年3月

徳永憲洋, 松田成午, 佐藤文彦, 成長型自己組織化マップを利用した成長する感覚運動者増の実現, 2015年電子情報通信学会総合大会, 2015年3月

徳永憲洋, 混合ガウスモデルをもとにした成長型自己組織化マップのアルゴリズム提案, ファジィシステムシンポジウム, 2015年9月

徳永憲洋, 情報量基準をベースに成長する位相表現ネットワークの有効性検証に関する研究, 電子情報通信学会技術研究報告 スマートインフォメディアシステム研究会, 2016年3月

〔図書〕(計 0件)

〔産業財産権〕

出願状況(計 0件)

取得状況(計 0件)

〔その他〕

ホームページ等

6. 研究組織

(1) 研究代表者

徳永 憲洋 (TOKUNAGA KAZUHIRO)
水産大学校・海洋機械工学科・講師
研究者番号: 00432956

(2) 研究分担者

()

研究者番号:

(3) 連携研究者

()

研究者番号: