

進歩報告

小澤 翔太

富山県立大学 情報システム工学科

2024年10月29日

はじめに

2/12

中間発表のテーマ

ターミナルアトラクタを組み込んだ複製・競合メカニズムによる効率的な機械学習の構築

本研究の目的

複製・競合動径基底関数ネットワーク (RC-RBFN) を機械学習に適用することで、従来の場合と比較したときの処理速度の向上を図る。

RBFN とは

動径基底関数ネットワーク (Radial Basis Function Network : RBFN) は階層型ニューラルネットワークに比較して、ニューロンごとの局所的な学習が可能であるなどの優れた点を持つ。しかし、RBFN では未知の非線形関数を近似するため、あらかじめ必要なニューロン数が不明であり冗長なニューロンを必要とする。一般に、ニューロンの増加は学習の遅延化や過学習の問題を生じることが知られている。

RBFN の応用例

- ・土砂災害発生危険基準線の高度化（公益社団法人砂防学会）
- ・土壤雨量指数の確率評価（公益社団法人砂防学会）

シナプス可塑性

4/12

シナプス可塑性

生体の脳内には、ニューロンと呼ばれる神経細胞がシナプスを介して繋がっており、ネットワークを形成して情報伝達を行っている。ニューロン同士を接続するシナプスはニューロンからの情報をそのまま伝達するのではなく、シナプスを大きくしたり小さくしたりして情報の伝達効率を制御している。このシナプスの大きさの変化をシナプス可塑性と呼び、それをモデル化したものをシナプス可塑性方程式と呼ぶ。

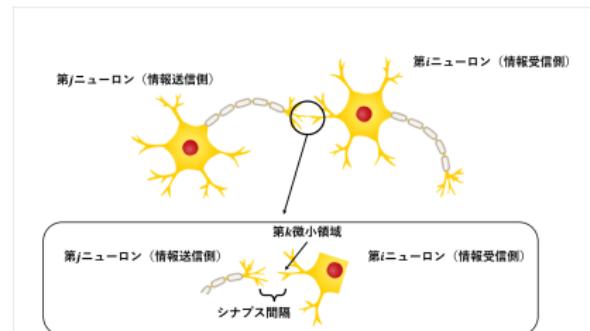


図 1: イメージ図

シナプス可塑性方程式

競合動径基底関数ネットワーク

シナプス結合荷重の大きさ $w_{ik}^j (> 0)$ の時間変化は以下のシナプス可塑性方程式に従う。このような、競合を考慮したシナプス可塑性方程式に従う RBFN が競合動径基底関数ネットワーク (Competitive RBFN: CRBFN) である。




図 2: シナプス可塑性方程式

シナプス可塑性方程式

パラメータ

内的自然増加率 α_{ik}^j , 競合係数 γ_{ik}^{jh} は以下の式に従う.

$$\alpha_{ik}^j = \int \eta_{ik}(x) \xi_{ik}^j(x) dx \quad (1)$$

$$\gamma_{ik}^{jh} = \int_{x \in B_{ik}} \xi_{ik}^j(x) \xi_{ik}^h(x) dx \quad (2)$$

- $\eta_{ik}(x)$: 教師信号
- $\xi_{ik}^j(x)$: 動径基底関数

$$\xi_{ik}^j(x) = \mu_j \exp\left\{-\frac{(x - m_j)^2}{2\sigma_j^2}\right\} \quad (3)$$

- μ_j : 第 j ニューロンが興奮性の場合に $\mu_j = 1$, 抑制性の場合に $\mu_j = -1$ となる識別子

シミュレーション結果と問題点

7/12




図 3: CRBFN による近似結果

問題点

CRBFN では、競合に負けたシナプス結合荷重は平衡状態で 0 になる。しかし、平衡解への漸近は指数関数的に行われる所以原理的には有限時間で平衡状態へ到達することはできない。

ターミナルアトラクタを適用した シナプス可塑性方程式

8/12

ターミナルアトラクタ

そこで、望ましい出力が動径基底関数を定数倍して足し合わせることで実現できる特別の場合に、あるシステムが最終的に安定した学習結果に収束する、ターミナルアトラクタ (Terminal Attractor: TA) の概念を適用して、与えられた時刻で平衡解へ収束するように修正されたシナプス可塑性方程式を以下のように定める。

TAを適用したシナプス可塑性方程式

$$\frac{dw_{ik}^j}{dt} = \frac{\left(\alpha_{ik}^j - \sum_{h=1}^M \gamma_{ik}^{jh} w_{ik}^h \right) w_{ik}^j}{\sum_{j=1}^M w_{ik}^j} \cdot \frac{V(\mathbf{w}_{ik}^0)^R V(\mathbf{w}_{ik})^{\frac{1}{r}}}{Rt^*}$$

**望ましい時刻で収束する
シナプス可塑性方程式**

$$V(\mathbf{w}_{ik}) = \frac{1}{2} \int \{ \eta_{ik}(x) - s_{ik}(x) \}^2 dx$$

Lyapunov関数

$$\frac{dV(\mathbf{w}_{ik})}{dt} = - \frac{V(\mathbf{w}_{ik}^0)^R V(\mathbf{w}_{ik})^{\frac{1}{r}}}{Rt^*}$$

**Lyapunov関数の
時間変化**

変数

第*j*基底関数 : $\xi_{ik}^j(x)$ 基底関数の重み付き和 : $s_{ik}(x)$ 教師信号 : $\eta_{ik}(x)$

任意の奇数 : r 定数 : $R = \frac{(r-1)}{r}$ 収束してほしい時刻 : t^*

図 4: TA を適用したシナプス可塑性方程式

シミュレーション結果

9/12




図 5: TA 適用前後の比較

基底関数の複製

10/12

CRBFN は冗長な動径基底関数を削除する能力をもつものの、必要とされる動径基底関数を追加する能力は備えていない。ニューラルネットワークに関数近似を行うために必要な数のニューロンが存在しない場合は、関数近似を行うこと自体が不可能となる。




図 6: 基底関数が一つだけで近似した場合

基底関数の複製

新しい動径基底関数を追加する能力を備えた CRBFN として複製・競合動径基底関数ネットワーク (Reproductive CRBFN: RC-RBFN) が提案されている。この RC-RBFN の新しい動径基底関数を複製するアルゴリズムを以下のように定義する。




図 7: 複製する位置の決定法

中間に向けて行うこと

12/12

- 基底関数の複製を行うプログラムの改良, シミュレーション
- 強化学習の学習アルゴリズムの勉強
- 中間発表のポスター作成