

進捗報告

小澤 翔太

富山県立大学 情報システム工学科

2024 年 10 月 8 日

中間発表のテーマ

複製・競合を考慮した動径基底関数ネットワーク（RBFN）の機械学習への適用

本研究の目的

複製・競合動径基底関数ネットワークを機械学習に適用することで、従来のアルゴリズム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）
- ・土壌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

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。

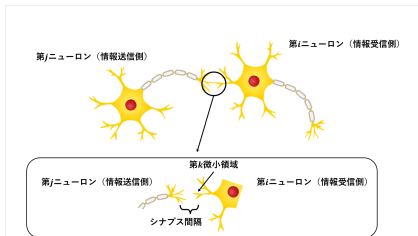


図 1: イメージ図

シナプス可塑性方程式

第 j ニューロンが発火して第 i ニューロンに情報を伝達する際の、第 i ニューロンの第 k 微小領域 B_{ik} (シナプス間隔) におけるシナプス間感度の大きさ $w_{ik}^j (> 0)$ の時間変化は以下のシナプス可塑性方程式に従う。

$$\frac{dw_{ik}^j}{dt} = (G_{ik} + \alpha_{ik}^j - \sum_h \gamma_{ik}^{jh} w_{ik}^h) w_{ik}^j + f_{ik}^j \quad (1)$$

- G_{ik} : B_{ik} への NGF の供給速度
- $\alpha_{ik}^j (> 0)$: 内的自然増加率
- $\gamma_{ik}^{jh} (> 0)$: シナプス間の競合係数
- g_{ik}^j : 第 j ニューロンのシナプスが取得できる神経成長因子 (NGF) の量
- f_{ik}^j : NGF と環境因子に依存するゆらぎ

シナプス可塑性方程式

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。

$$\alpha_{ik}^j = \int \eta_{ik}(x) \xi_{ik}^j(x) dx \quad (2)$$

$$\gamma_{ik}^{jh} = \int_{x \in B_{ik}} \xi_{ik}^j(x) \xi_{ik}^h(x) dx \quad (3)$$

・ $\eta_{ik}(x)$: シナプス後発火頻度 (情報を受け取る側のニューロン, 教師信号にあたる)

・ $\xi_{ik}^j(x)$: シナプス前発火頻度 (情報を送る側のニューロン, 第 j 基底関数にあたる)

$$\xi_{ik}^j(x) = \mu_j \exp\left\{-\frac{(x - m_j)^2}{2\sigma_j^2}\right\} \quad (4)$$

・ 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

シナプス可塑性方程式

ここでは、簡単のため NGF の摂取量が一定 ($G_{ik} = 0$) で、揺らぎのない場合 ($f_{ik}^j = 0$) を考える.

よってシナプス可塑性方程式は以下のように定義される.

$$\frac{dw_{ik}^j}{dt} = (\alpha_{ik}^j - \sum_h \gamma_{ik}^{jh} w_{ik}^h) w_{ik}^j \quad (5)$$

これは種間の競争をモデル化した一般 Lotka-Volterra 競争系であり、本研究ではシナプス間の NGF の取り合いを意味している.

内容

RBFN に競合機能を追加した競合動径基底関数ネットワーク (Competitive RBFN : CRBFN) はシナプス間に競合を生じさせることで冗長なニューロンを消滅させることが可能である.

設定

- ・ 基底関数の数 : 10
- ・ シナプス結合荷重の初期値 : 0.1~5 のランダム値
- ・ 教師信号 :

$$\eta(x) = 4N(-13, 2) + 2N(-1, 1) + 3N(8, 4) + N(4, 0.5)$$

($N(a, b)$ は正規分布に従う中心位置が a , 標準偏差が b の確率密度関数)

シミュレーション結果 (1)

9/14

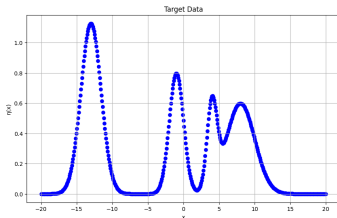


図 2: 教師信号 $\eta(x)$

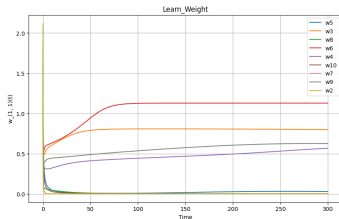


図 3: シナプス間感度 w の学習結果

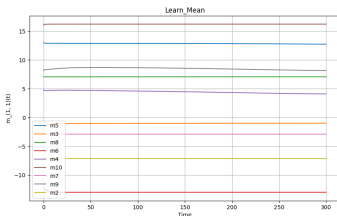


図 4: 中心位置 m の学習結果

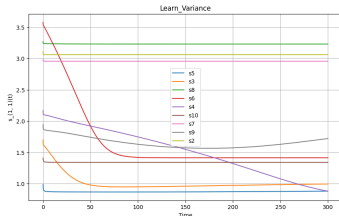


図 5: 標準偏差 σ の学習結果

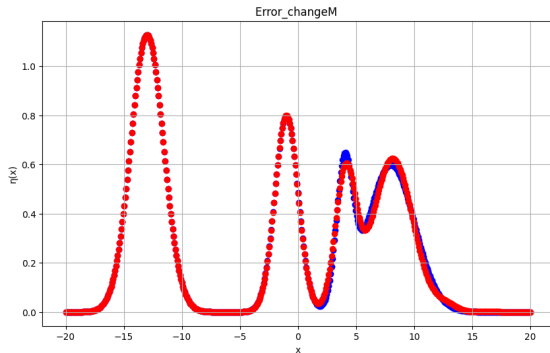


図 6: 出力結果

ターミナルアトラクタ

望ましい時刻 t^* でとある解に収束する（この概念をターミナルアトラクタと呼ぶ）シナプス結合荷重の時間変化を Lyapunov 関数を用いて定める．そこで，Lyapunov 関数とその時間変化を以下のように定義する．

$$V(\mathbf{w}_{ik}) = \frac{1}{2} \int_{x \in B_{ik}} \{\eta_{ik}(x) - s_{ik}(x)\}^2 dx \quad (6)$$

$$\frac{dV(\mathbf{w}_{ik})}{dt} = - \frac{V(\mathbf{w}_{ik}^0)^R V(\mathbf{w}_{ik})^{\frac{1}{r}}}{R t^*} \quad (7)$$

- $\mathbf{w}_{ik} \equiv [w_{ik}^1, w_{ik}^2, \dots, w_{ik}^{N_{ik}}]^T \in R^{N_{ik}}$
- r : 任意の奇数
- R : $R = \frac{(r-1)}{r}$
- \mathbf{w}_{ik}^0 : \mathbf{w}_{ik} の初期値

望ましい時間で平衡解へ収束するシナプス可塑性方程式

$$s_{ik}(x) = \sum_{j=1}^{N_{ik}} w_{ik}^j \xi_{ik}^j(x) \quad (8)$$

ここで, Lyapunov 関数 $V(\mathbf{w}_{ik})$ が常に正で, Lyapunov 関数の時間変化 $\frac{dV(\mathbf{w}_{ik})}{dt}$ が常に負である. よってこのシステムは漸近安定であり, 時間とともに平衡点に収束する.

そして, このように定めた Lyapunov 関数をシナプス結合荷重の時間変化に適用すると以下のように定義される.

$$\frac{dw_{ik}^j}{dt} = \frac{(\alpha_{ik}^j - \sum_{h=1}^{N_{ik}} \gamma_{ik}^{jh} w_{ik}^h) w_{ik}^j}{\sum_{j=1}^{N_{ik}} w_{ik}^j (\alpha_{ik}^j - \sum_{h=1}^{N_{ik}} \gamma_{ik}^{jh} w_{ik}^h)^2} \times \frac{V(\mathbf{w}_{ik}^0)^R V(\mathbf{w}_{ik})^{\frac{1}{r}}}{Rt^*} \quad (9)$$

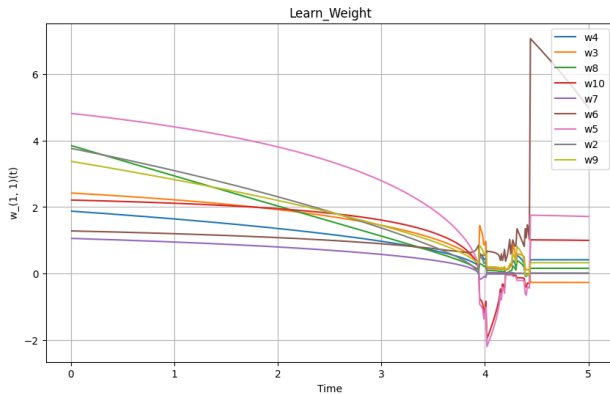


図 7: 出力結果

中間に向けて行うこと

14/14

- ターミナルアトラクタと基底関数の複製を行うプログラムを作成し、シミュレーションを行う
- どんな機械学習に適用するか検討
- 中間発表のポスター作成