



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

2120014 小澤翔太 情報基盤工学講座

指導教員 奥原 浩之

要約

動径基底関数ネットワーク (Radial Basis Function Network: RBFN) は、任意の非線形関数に対し、基底関数を足し合わせることで関数近似を効果的に行うことができるニューラルネットワークのうちの一つであり、様々な問題に適用されている。しかし、RBFNには冗長なニューロンの存在や、基底関数が不足していることによって関数近似ができない場合があるといった問題点がある。そこで本研究では、このような問題に対して、ニューロン間の競合や、基底関数の複製を考慮したRBFNを提案する。そして、新たなアルゴリズムを機械学習へ適用し、さらなる効率化・改善を目的とする。

キーワード:シナップス結合荷重、シナップス可塑性方程式、競合動径基底関数ネットワーク、複製、学習の高速化

1 はじめに

関数近似問題やパターン識別に適したニューラルネットワークの一つにRBFNがある。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。

これらの問題を解決するために、適者生存型学習則に基づいたシナップス可塑性方程式を適用した、競合動径基底関数ネットワーク (Competitive RBFN: CRBFN) が提案されている[1]。CRBFNは、シナップス結合荷重間に競合を生じさせ、学習に必要なニューロンのみが自然に生き残るようになっており、冗長なニューロンの削減を図ることができる。しかし、CRBFNでは基底関数を追加する機能は無く、基底関数の数が足りない場合は、関数近似 자체が不可能となる。そこで、CRBFNに基底関数を複製して追加する機能を加えた、複製・競合動径基底関数ネットワーク (Reproductive RBFN: RC-RBFN) が提案されている[2]。

そこで本研究では、RC-RBFNが効率よく動径基底関数を削除あるいは追加するニューラルネットワークであることを示したのち、機械学習のアルゴリズムに適用して従来より学習が効率的に行われていることを示す。

2 複製・競合を考慮した動径基底関数ネットワーク

ニューラルネットワークは大きく分けて、素子であるニューロン、それらを結合するシナップス、そして動作規則により構成される。なかでも、記憶にもっとも関係した情報処理は、シナップスにおいて行われているとされる。記憶には種々のものが考えられるが、本論文では短期記憶と長期記憶に着目し、短期記憶はニューロンの発火頻度、長期記憶は細胞膜の特性の変化により生じるものとする。シナップスの可塑性を記述する方程式は、これらの要因を含んだものとなっていなければならない。また、実際の生体では、シナップス結合の性質が興奮性、抑制性であるのかは送り出すニューロンにより決まる (Dale則)。さらに、微小な領域では成長や活動に必要な神経成長因子 (Nerve Growth Factor: NGF) は競合によってシナップスに摂取される。これらの事実もシナップス可塑性のモデル化において重要な要因であると考えられる。そこで、発火頻度や膜の特性変化を生じる物質の時間変化と、生理学的拘束条件であるDale則や微小な領域での競合を考慮したシナップス間感受度の大きさの時間変化は以下の方程式に従うものとする(図1参照)。

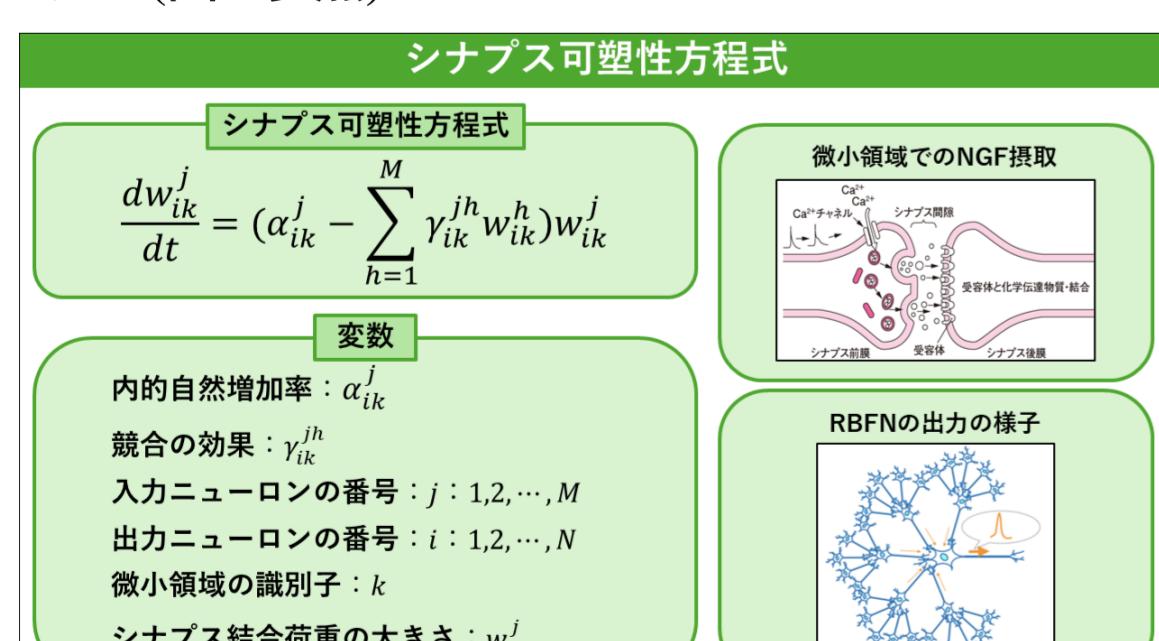


図1 シナップス可塑性方程式

このような、競合を考慮したシナップス可塑性方程式に従うRBFNがCRBFNである。また、方程式内のパラメータを調整することによって生存・分岐特性を示すことも示されている[4][5]。

2.2 ターミナルアトラクタ

先ほど述べたCRBFNでは、競合に負けたシナッ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數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。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 t^* で平衡解へ収束するように修正されたシナップス可塑性方程式を以下のように定める(図2参照)。

TAを適用したシナップス可塑性方程式	
$\frac{dw_{ik}^j}{dt} = \frac{(\alpha_{ik}^j - \sum_{h=1}^M \gamma_{ik}^{jh} w_{ik}^h) w_{ik}^j - V(w_{ik}^0)^R V(w_{ik})^{\frac{1}{R}}}{\sum_{j=1}^M w_{ik}^j (\alpha_{ik}^j - \sum_{h=1}^M \gamma_{ik}^{jh} w_{ik}^h)^2}$	望ましい時刻で収束するシナップス可塑性方程式
$V(w_{ik}) = \frac{1}{2} \int \{\eta_{ik}(x) - s_{ik}(x)\}^2 dx$	Lyapunov関数
$\frac{dV(w_{ik})}{dt} = -\frac{V(w_{ik}^0)^R V(w_{ik})^{\frac{1}{R}}}{R t^*}$	Lyapunov関数の時間変化
変数	
第 <i>j</i> 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2 TAを適用したシナップス可塑性方程式

ここで、動的システムの安定性を解析するために使われる数学的なツールであるLyapunov関数 V は常に正であり、その時間変化である $\frac{dV}{dt}$ は常に負である。したがって、このシステムは漸近安定であり、平衡点に漸近的に収束することが示されている。

2.3 基底関数の複製

ここまで、シナップス結合荷重間の競合を考慮したシナップス可塑性方程式を利用することにより学習の効率化を図る手法が提案されてきた。ところが、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。

そこで、新しい動径基底関数を追加する能力を備えたニューラルネットワークとしてRC-RBFNが提案されている。このRC-RBFNはシナップス可塑性方程式に関する考察から得られるものであり、必要な動径基底関数を効率的に追加することができる。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3参照)。簡単のため以降はとある i と k についてのみ考えるものとし、添え字の i, k は省略する。

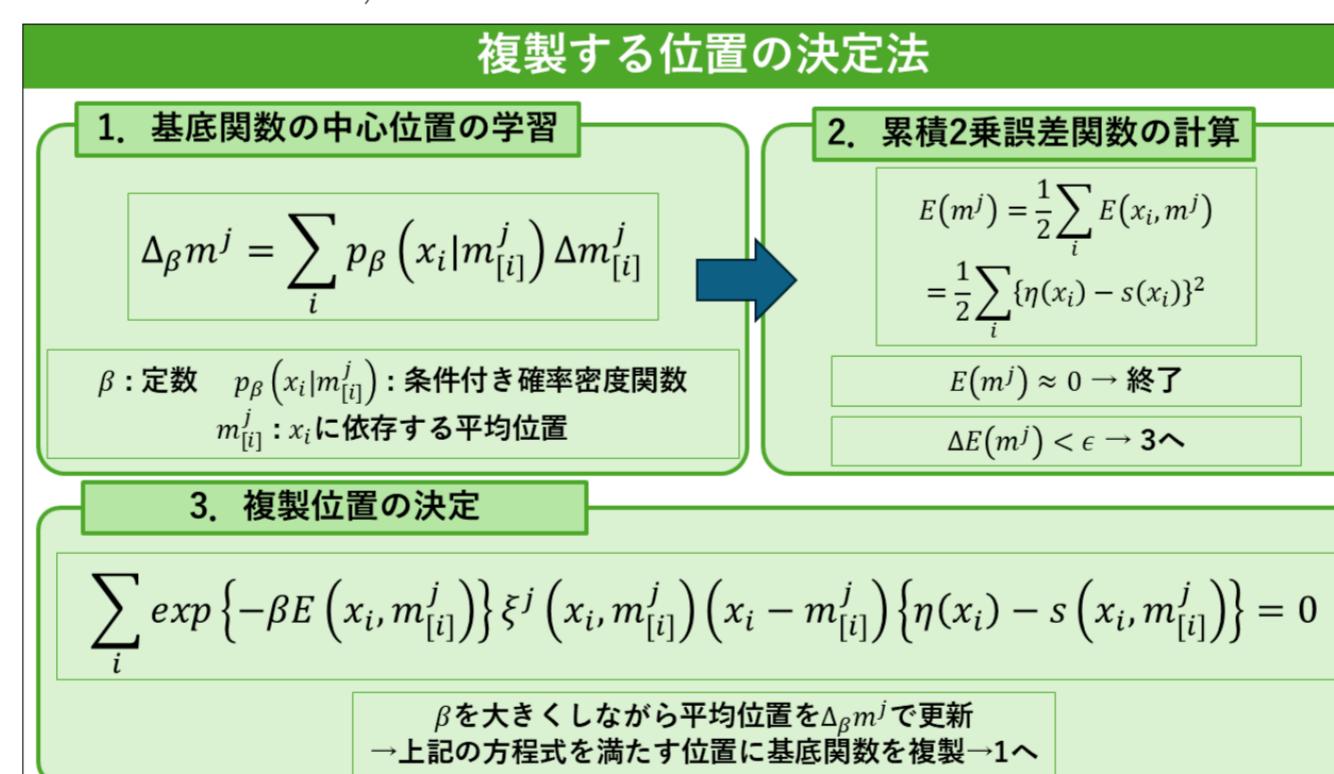


図3 複製する位置の決定法

また、この複製アルゴリズムにおける自由エネルギーは、データのクラスタリングのための手法であるメルティング[6]と同様に定義されている。メルティングとは、 $m = x$ かつ $\beta \rightarrow \infty$ である初期状態から、徐々に β を 0 へ近づけていきながら、パラメータ m を自由エネルギー $F_\beta(m)$ の最急降下方向に更新していくものである。その結果、パラメータ m は徐々に同じ値をとりはじめ、最終的に一つの値に収束する。本研究の複製アルゴリズムでは β を大きくしながらパラメータ m を更新することでメルティングとは逆に、一つの m の値から $x_i (\forall i)$ に分岐させることで基底関数の複製を行っている。

3 強化学習について

3.1 強化学習

強化学習 (Reinforcement Learning: RL) は、エージェントが環境と相互作用し、行動の結果として得られる報酬をもとに最適な行動を学習する手法である。エージェントは状態に応じた行動を選択し、環境から報酬と次の状態を得て、そのフィードバックを用いて方策 (ポリシー)

を改善しながら報酬を最大化するように学習する。強化学習の手法は、主に価値ベース、方策ベース、およびアクター・クリティックの3種類に分かれ、連続的または大規模な状態空間に対しては、関数近似がよく用いられる。深層強化学習 (Deep Reinforcement Learning: DRL) ではニューラルネットワークを使って関数近似を行い、複雑なタスクの学習を可能にしている。強化学習は、探索と利用のバランスを取りながら効率的に最適な行動方針を学ぶ点が特徴である。

3.2 複製・競合を考慮した強化学習

強化学習における関数近似では、基底関数の複製や冗長な基底関数の削除機能を活用することで、モデルの汎化性能と学習効率を向上させることができると考える。通常の関数近似では、状態や行動の空間が大規模になると、必要な基底関数が増加し、冗長な関数が含まれることで計算効率が低下する問題が生じる。そこで、基底関数の複製機能を導入し、特定の状態や行動に適応できるよう基底関数を増やすことで、局所的なパターンに対しても柔軟に対応できるようになる。同時に、冗長な基底関数を削除することで、モデルの軽量化と学習速度の向上が実現が可能になると考えられる。これによって、複雑な環境での最適方策の探索を効率化し、エージェントが少ない計算資源で報酬を最大化できるようになる。

4 提案手法

本研究では学習アルゴリズムとして、RC-RBFNを提案し、実際に基底関数の複製や冗長なニューロンが削除されていることを確認した。この学習アルゴリズムを既存の機械学習の学習アルゴリズムとして適用することで、学習速度の向上を図る。

5 数値実験並びに考察

シナップス結合荷重の競合とそれにターミナルアトラクタを適用した結果を図4の左側に示す。基底関数の複製を行った結果を右側に示す。

TA適用前のシナップス結合荷重の学習過程では、ほとんどのシナップス結合荷重が学習回数が80回以降は値の変化が見られず、収束したと判断した。それに対して、望ましい収束時間を50回で指定したTA適用後の学習過程では、適用前の収束した結果に学習回数が50回の時点で到達していることが分かる。TA適用前後のシナップス結合荷重の大きさを数値で比較してみると、 w_{10} 以外のシナップス結合荷重の差は0.1以下であり誤差であると考えられる。以上のことから学習回数を少なくしながら、同様の結果を得られていることが分かる。

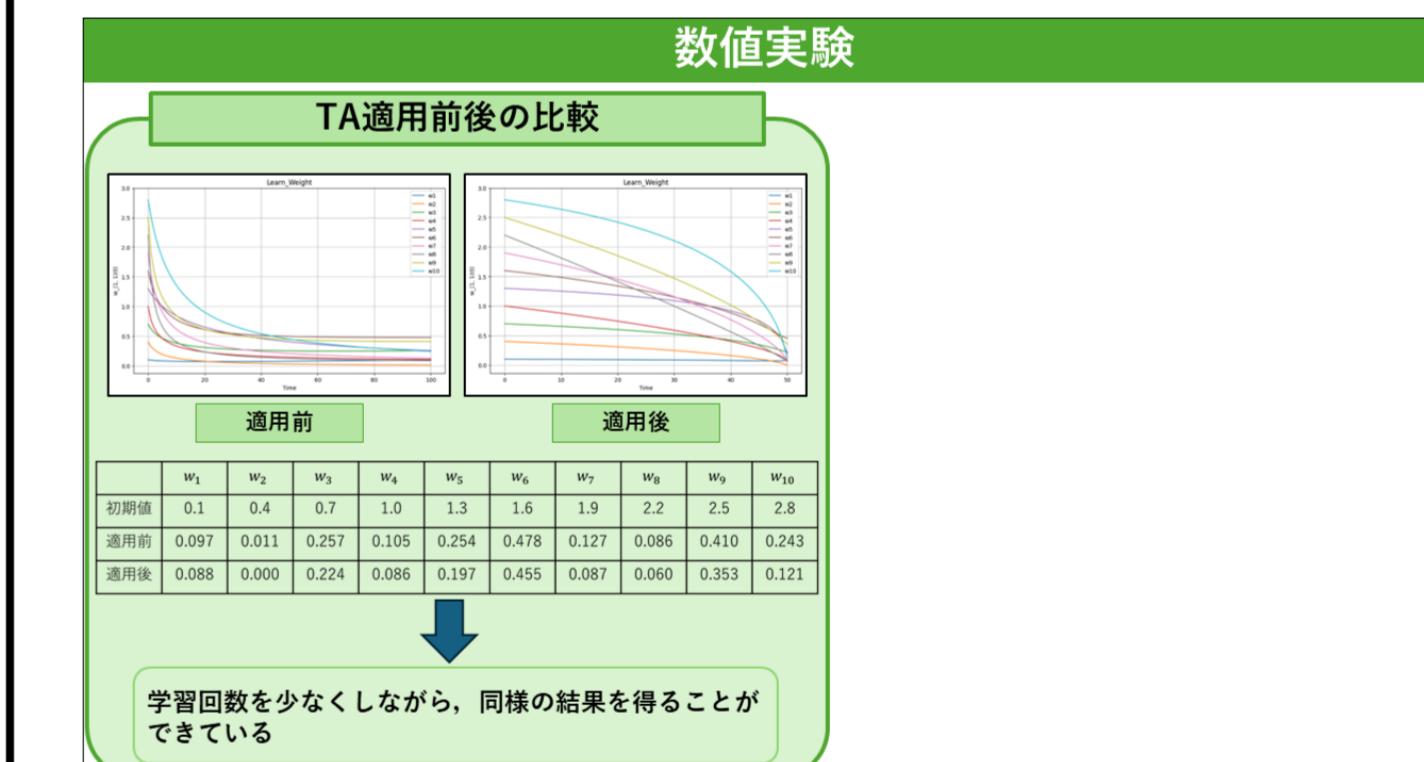


図4 TA適用前・適用後のシナップス結合荷重

6 おわりに

ここまで、冗長なニューロンの削除を行うCRBFNや、基底関数が不足していた場合に必要な基底関数の追加を行うRC-RBFNが実際にニューロンの削除や複製を行っていることを示してきた。また、ターミナルアトラクタの概念を導入することで、シナップス結合荷重が望ましい時刻で収束することも確認した。今後の方針として、強化学習の学習アルゴリズムに適用することと、負の教師信号に対しても従来のRC-RNFMと同様の近似を行えるようにすることが挙げられる。

参考文献

- [1] 奥原 浩之, 尾崎 俊治, “適者生存型学習則を適用した競合動径基底関数ネットワーク”, 電子情報通信学会論文誌, pp. 3191-3199, 1997
- [2] 奥原 浩之, 佐々木 浩二, 尾崎 俊治, “環境の変化に適応できる複製・競合動径基底関数ネットワーク”, 電子情報通信学会論文誌, pp. 941-951, 1999
- [3] 奥原 浩之, 尾崎 俊治, “Dale則を考慮したシナップス可塑性方程式の解析”, システム制御情報学会論文誌, pp. 718-720, 1995
- [4] 土屋:複雑系の動力学とその機能;システム/制御/情報, Vol.39, No.1, pp.29~34 (1995)
- [5] Mikhailov
- [6] Wong, Y.-fai, Clustering Data by Melting, Neural Computation 1993, 5 (1), 89-104. https://doi.org/10.1162/neco.1993.5.1.89.