

RBFを用いたNNによる時系列予測について

福田 典昭 成久 洋之*

岡山理科大学大学院工学研究科修士課程情報工学専攻

*岡山理科大学工学部情報工学科

本論文では、放射状基底関数(RBF)を用いたニューラルネットワーク(NN)としてRBFネットワーク(RBFN),回帰ニューラルネットワーク(GRNN),そしてハイブリッドRBFネットワーク(H-RBFN)を取り上げ、各NNの性能評価を行う。RBFNは、入力データの特徴付けを有効に行うRBFを入出力関数としたNNで、一般的に広く用いられている。また、RBFNを拡張させたGRNNは、荷重設定を回帰理論に基づいて行うfeed-forward型NNで、関数近似に対して優れたものとされている。これに対しH-RBFNは、一般的に知られているシグモイド関数をRBFNに結合させ、バックプロパゲーション(BP)則を用いて荷重修正を行うNNである。本実験では、時系列の予測問題を取り上げ、これらのNNおよび一般的なBPネットワーク(BPN)の予測性能について比較検討する。

Some Comments on Prediction of the Chaotic Time Series by using Radial Basis Function Type Neural Networks

NORIAKI FUKUDA HIROYUKI NARIHISA*

Graduate School of Engineering, Okayama University of Science.

*Department of Information & Computer Engineering, Faculty of Engineering,
Okayama University of Science.

In this paper, we present the performance analysis of the radial basis function (RBF) type neural networks (NN). As this RBF type NN, we consider as follows: simple RBF network (RBFN), generalized regression neural network (GRNN), and hybrid RBF network (H-RBFN). By using these RBF type NN, we execute the prediction of chaotic time series and calculate prediction errors. Finally, these prediction errors are compared and discussed with computational results of normal Back Propagation neural network.

1. まえがき

学習や認識などの分野で幅広く応用されているニューラルネットワーク(*Neural Networks*: NN)は、入力データと出力データとの写像関係を決定しているものである。すなわち、学習データを用いて入力データに対する近似出力関数の精度を向上させるアルゴリズムを見なすことができる。

一般に、階層型NNの隠れ層には、空間を超平面により線形分離を行うシグモイド関数(*Sigmoid Function*)が広く用いられているが、これとは異なる性質で、超橢円により分離を行う放射状基底関数(*Radial Basis Function*: RBF)^[1]を用いたNNに関する研究も現在盛んに行われている^{[2]~[4]}。シグモイド関数は、正の導関数をとる連続な非線形関数であり、バックプロパゲーション(*Back Propagation*: BP)による学習に適している。NNにおけるシグモイド素子は、大域的な分類をわずかな数で実現することができるが、クラスターの形状が超球に近いほど多数の素子を必要とし、更に領域内における素子間の位置的な

相互関係を把握することは困難である。

これに対しRBFは、一つの素子の決定領域が超橢円で表され、入力空間の限られた領域内に対してのみ活性化を与えるという特性を持つ。また、空間内でのクラスターの中心位置や広がりの情報を得ることも容易である^[4]。このRBFを用いたNNとしては、RBFネットワーク(*Radial Basis Function Network*: RBFN)が一般的に用いられているが、RBFNを拡張させ、非線形回帰理論を基にした回帰ニューラルネットワーク(*Generalized Regression Neural Network*: GRNN)^[1]も挙げられる。これらのNNは、シグモイド関数を用いたBPネットワーク(*BP Network*: BPN)とは相反的な特質を持つため、明らかに得意な対象が異なると考えられる。実際に、RBFを用いたNNは、関数近似のような実変数写像問題において、BPNより大変有効であるという研究報告がされている^{[9][10]}。また、ネットワーク精度の更なる向上を目指し、RBFとシグモイド関数とを混合させたハイブリッドRBFネットワーク(*Hybrid RBF Network*

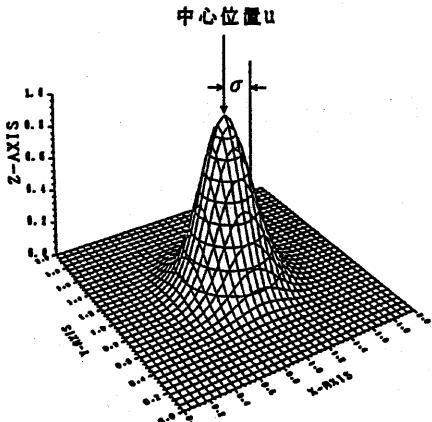


図 1. 2次元空間における RBF

: H-RBFN)^[5]も提案されており、その可能性の追求が求められている。

本論文では、RBFN, GRNN, H-RBFN およびBPN を時系列の予測問題に適用し、その動作特性の比較を行い、RBF を用いた NN の有効性について検討する。

2. 放射状基底関数ネットワーク

多重バーセプトロンの派生技術として提案された放射状基底関数(RBF)は、ガウス関数(Gaussian Function)を基本とするもので、パターン空間を有効に分割する非線形関数である。ここで、図1に2次元の入力空間におけるRBFを示す。このようにRBFは、放射状対象な形状をしており、パターン空間に対して超橢円による分類を実現するものである。よって、限定された領域内の入力データに対してのみ活性化を与えるため、有効な特徴抽出を可能にしている。

次に、RBF ネットワーク(RBFN)の構成を図2に示す。図より、RBFN は3層から構成され、各層は完全結合をしていることがわかる。また、入出力関数であるRBF は、隠れ層ユニットに配置される。なお、RBFN の出力は以下の式によって計算される。

$$f_i(x) = \frac{\sum_{j=1}^L w_{ij} h_j(x)}{\sum_{j=1}^L h_j(x)} \quad (1 \leq i \leq M) \quad (1)$$

$$h_j(x) = e^{-\frac{\|x - u_j\|^2}{2\sigma_j^2}} \quad (1 \leq j \leq L) \quad (2)$$

ここで、 M は出力ユニット数、 L は隠れ層ユニット数を表し、 w_{ij} は隠れ層と出力層間の結合荷重を示す。式(1)では、正規化操作により隠れ層の動作を、入力データ x に対して正規直交形に近い形で表現している。また、 $h_j(x)$ は隠れ層ユニット j におけるRBF の

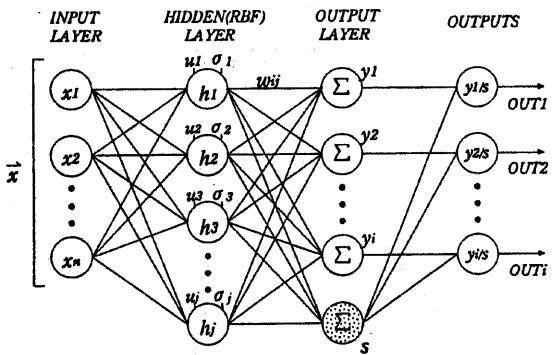


図 2. RBFN の構成

出力値で、式(2)によって求められる。なお、 u_j は隠れ層ユニット j におけるRBF の中心位置を示し、 σ_j は有意領域の制御定数、すなわち標準偏差を表す。ここで、 $x = u_j$ の場合、 $h_j(x)$ は最大 “1” を出力し、 x が u_j より離れるにつれ出力値は減少することがわかる。以下に、RBFN の処理手順を示す。

(RBFN の処理手順)

- Step1：訓練データ x をネットワークに適用。
- Step2：隠れ層ユニット j における u_j 、 σ_j を決定。
- Step3：隠れ層～出力層間の結合荷重 w_{ij} を決定。
- ※ 式(1),(2)を用いてネットワークの出力を得る。
- Step4：テストデータ x_t を適用し、出力値を得る。

ここで、Step1～3は、RBFN における訓練過程であり、各設定値はネットワークの性質を大きく左右する重要な要素となる。

2.1 中心位置の設定

隠れ層ユニット j の中心位置 $u_j^{[1] \sim [4]}$ は、入力空間におけるRBF の位置を示すもので、システムの中で最も重要な設定値である。RBF は空間を超橢円により分割するため、ネットワークの精度を向上させるためには、入力データの分布に沿って均等に配置する必要がある。一般に、入力データの分布は未知で、更に一様ではないため、入力データに対してクラスタリングを行い、得られた中心値(centroid)を u_j に割り当てる処理が必要となる。本実験では、中心位置を決定するためのクラスタリング手法に、自己組織化特徴マップ(Self-Organizing Feature Map : SOFM)を用いた。以下に、この手法の詳細を示す。

Kohonen によって提案されたSOFM^{[6][7]}は、ラ

ンダムな出発点から位相地図を組織化できる2層のNNである。ネットワークは入力層と競合層の組合せで構成され、教師なし学習により訓練される。また、競合ユニット r_i の入力空間における位置は、直接的に結合荷重 m_i で表現される。

SOFMの基本動作は、まず入力ベクトル $x(t)$ より最近隣距離にある競合ユニットを勝者ユニット r_{i^*} とし、以下の更新則をすべての競合ユニット r_i に対し適用する。

$$\Delta m_i(t) = \alpha(t) \Phi(r_i, r_{i^*}) (x(t) - m_i(t)) \quad (3)$$

$$\Phi(r_i, r_{i^*}) = e^{\left[\frac{-\|r_i - r_{i^*}\|^2}{2\sigma^2(t)} \right]} \quad (4)$$

ここで、 $\Phi(r_i, r_{i^*})$ は近傍関数であり、SOFMの位相特性を保証するものである。つまり、勝者ユニット r_{i^*} およびその周辺に位置する競合ユニット r_i に対して結合荷重 m_i の更新が行われるため、ユニット相互の距離関係を保持しながら写像することができる。これにより、入力空間に対して各ユニットを均等に配置することが可能になる。また、 $\alpha(t)$ は学習係数($0 < \alpha(t) < 1$)、 $\sigma(t)$ は標準偏差を表し、 t は繰り返し回数を示す。なお、学習係数 $\alpha(t)$ および標準偏差 $\sigma(t)$ は、ユニットの動作を抑制するため、 $\alpha(t) = \alpha_0 e^{-t/\alpha_1}$ 、 $\sigma(t) = \sigma_0 e^{-t/\alpha_1}$ を用い、 t が増加するにつれ徐々に減少させる。以上の処理を、ユニットの動作が収束するまで繰り返し行う。

2.2 標準偏差の設定

有効となる入力データを考慮する有意領域の幅、すなわち標準偏差 σ は、システムの正確さに深く影響を与えるパラメータである。つまり σ を最適に設定し、できるだけ均等に入力空間を有意領域でカバーする必要がある。一般に、入力空間において各RBFが等間隔に配置されている場合、すべての隠れ層ユニットにおける σ は、同一値とすることができる。しかし、各RBF間の距離が一様でない場合、隠れ層ユニット j における σ_j は、間隔に対応した値を各々設定する必要がある。本研究における σ_j の決定は、各RBFの位置関係に応じた値を設定するため、N nearest neighbor法を用いて行った。

このN nearest neighbor法^{[1][2]}は、標準偏差 σ_j の設定に大変有効であるとされている。これは、入力空間におけるユニット j とN番目までの近傍ユニットとの平均ユークリッド距離を割り当てる発見的な手法で、式(5)のように定式化される。なお、本実験では $N = 2$ として計算を行った。

$$\sigma_j = \frac{1}{N} \sum_{k=1}^N \sqrt{(x_j - x_k)^2} \quad (5)$$

2.3 結合荷重の設定

訓練過程の最終手順として、隠れ層と出力層間における結合荷重の設定を行う。この荷重設定には、さまざまな手法が考えられるが、本実験では、最も典型的な教師あり学習である勾配降下法(Gredient Descent Method)^{[1][2][5]}を用いた。この手法における荷重修正式を以下に示す。

$$\Delta w_{ij}(n) = \beta(f_i(x)' - f_i(x)) h_j(x) \quad (6)$$

ここで、 $f_i(x)'$ は、入力データ x に対する出力層ユニット i の応答期待値である。また、 β は学習係数($0 < \beta < 1$)を示す。

3. 回帰ニューラルネットワーク

先に記したRBFNを拡張させ、荷重設定を回帰理論に基づいて行うNNとして、回帰ニューラルネットワーク(GRNN)が挙げられる。このNNのトポロジーは、RBFNと基本的に同一である。しかし、GRNNは直接に入力空間からその応答期待値を結合荷重に設定するため、荷重修正の繰り返し処理の必要性が全くなく、処理の高速化が実現されている。

このようにGRNNは、入力と出力ベクトル間で任意の関数予測が直接的に行えるため、近似問題に対して十分に確立された統計的手法である。GRNNは、以下のような統計量に基づいている。

$$E[y|x] = \frac{\int_{-\infty}^{\infty} y f(x, y) dy}{\int_{-\infty}^{\infty} f(x, y) dy} \quad (7)$$

ここで、 x, y は各々入出力ベクトルであり、 $E[y|x]$ は入力ベクトル x が与えられたときの出力期待値を表す。また、 $f(x, y)$ は x と y の確率密度関数(PDF)を示す。PDFは、近似関数においての予備的な概念を何もないデータから導くため、そのシステムは完全に一般的である。よってGRNNは、本質的に学習集合のみが与えられたときの $f(x, y)$ という関数を予測する方式であるといえる。

4. ハイブリッドRBFネットワーク

ハイブリッドRBFネットワーク(H-RBFN)について記述する。これは、入力データの特徴検出を有効に行うRBFと大域的分類を行うシグモイド関数を、隠れ層に組み込むことにより、ネットワーク精度の向上が可能になると考えられるNNである。

まず、図3にH-RBFNの基本構造を示す。このように各層は完全結合しており、隠れ層にはRBF及びシグモイド関数を配置したRBF層、シグモイド層が用いられる。ここで、RBF層ユニットの出力 h_j は先

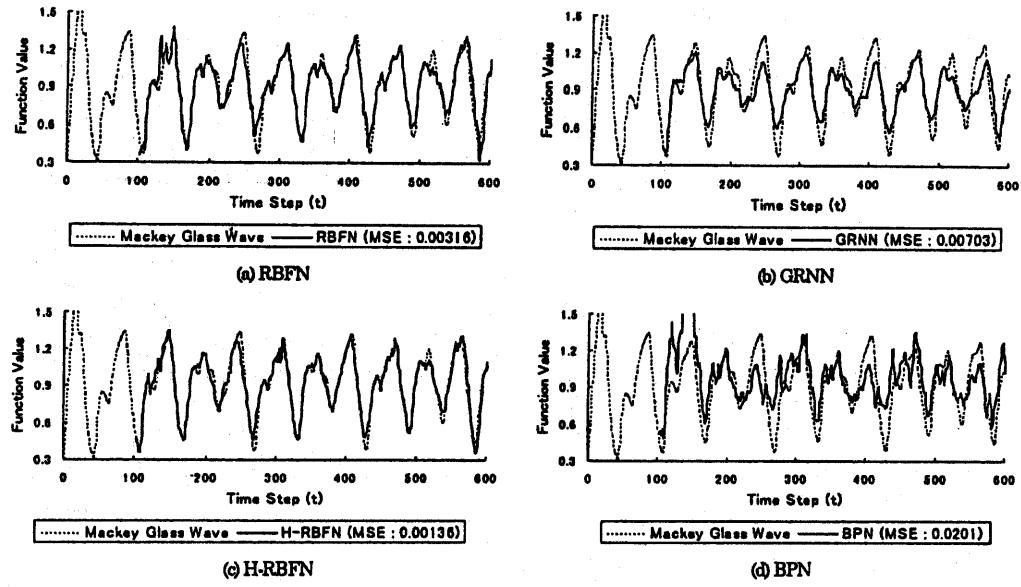


図4. 各NNによる予測波形(入力パターン数: 500個)

一般的なBPNより優れており、その中でもH-RBFNは大変有効であることを示した。

RBFを用いたNNは、空間における入力データの特徴抽出をRBFの超精円性によって有効に行い、特徴付けされた情報を直接的に実数値へ写像するため、高精度の予測が容易に実行される。また、BPNより、荷重設定の処理が効率的であるため、より高速に動作するといえる。更に、H-RBFNは、隠れ層にRBFとシグモイド関数を用いることで、より精密な入力データの分割を可能にするため、より高いネットワーク精度を得ることができる。

しかし、RBFを用いたNNの問題点としては、訓練過程が非常に複雑であることが挙げられる。ネットワークの動作、精度に大きく影響を与える多数のパラメータは、問題に応じた経験的な設定を必要とする。特に中心位置 u_j 、標準偏差 σ は、システムにおける重要な要素であり、用いるクラスタリング手法、 σ の決定法によって解の精度は大きく左右される。また、これら一連の決定法には多大な処理時間を要するため、更なる効率化が求められる。次に、ロバスト性が低いということも問題点として挙げられる。適用する問題およびその規模によって最適なネットワーク構成(隠れ層のユニット数など)が異なるため、汎用性に対する考慮も求められる。

現在、RBFを用いたNNは、音声認識、システム設計などへの応用が可能であり、さまざまな研究結果が報告されている。これらの応用に対して、処理を

より効率的にするためのアプローチとしては、処理の並列化などが挙げられ、今後の展開が期待される。

参考文献

- [1] P.D. Wasserman "Advanced Methods in Neural Computing," pp.147-176, 1993.
- [2] J. Moody, and C.J. Darken "Fast Learning in Networks of Locally-Tuned Processing Unit," Neural Computation, vol.1, pp.281-294, 1989.
- [3] E.J. Hartman, and J.D. Keeler "Layered Neural Networks with Gaussian Hidden Unit as Universal Approximations," Neural Computation, vol.2, pp.210-215, 1990.
- [4] J. Park, and I.W. Sandberg "Universal Approximation Using Radial-Basis-Function Networks," Neural Computation, vol.3, pp.246-257, 1991.
- [5] M. Ceccarelli, and J.T. Hounson "RBF Networks vs. Multilayer Perceptron for Sequence recognition," IEEE Technology Update Series. Neural Networks Theory, Technology and Applications(P.K. Simpson ED), pp.391-396, 1996.
- [6] M.H. Hassoun "Fundamentals of Artificial Neural Networks," pp.103-133, 1995.
- [7] T. Kohonen "自己組織化マップ," シェブリンガ・フェアラーク東京, 1996.
- [8] J. ハーツ, A. クロー, R.G. バレマー "ニューラルコンピュータ 統計学からのアプローチ," トッパン, 1994.
- [9] 成久洋之, 福田典昭, "ニューラルネットによる関数近似について," 岡山理科大学紀要, 第32号, A, pp.239-252, 1997.
- [10] 福田典昭, 成久洋之, "放射状基底関数を用いたニューラルネットワーク特性について," 第32回SSOR予稿集, pp.28-33, 1997.