

非線型, 非定常 시계열 예측을 위한 RBF(Radial Basis Function) 회로망 구조

論 文

48A - 2 - 10

RBF Network Structure for Prediction of Non-linear, Non-stationary Time Series

金商桓* · 李鍾浩**
(Sang-Hwan Kim · Chong-Ho Lee)

Abstract - In this paper, a modified RBF(Radial Basis Function) network structure is suggested for the prediction of a time-series with non-linear, non-stationary characteristics. Conventional RBF network predicting time series by using past outputs sense the trajectory of the time series and react when there exists strong relation between input and hidden activation function's RBF center. But this response is highly sensitive to level and trend of time series. In order to overcome such dependencies, hidden activation functions are modified to react to the increments of input variable and multiplied by increment(or decrement) for prediction. When the suggested structure is applied to prediction of Mackey-Glass chaotic time series, Lorenz equation, and Rossler equation, improved performances are obtained.

Key Words : RBF(Radial Basis Function), Neural Network, Prediction, Time-Series

1. 서 론

예측이란 시스템의 동적상태를 수학적으로 표현하는 시스템 동정(system identification)에 근거하여 미래의 상태를 알아내는 것이다. 전통적인 시스템 동정 분야에서는 회귀모델(Regressive model)을 기초로하여 현재로부터 고정구간의 과거값을 종속변수로 하는 자기회귀모델(Auto-Regressive model), 자기 회귀 모델에 이동 평균항을 덧붙인 ARMA 모델(Auto-Regressive Moving Average model)등이 있고, 다변수 시스템의 경우는 다중회귀 모델(Multiple Regressive model), 벡터 자기회귀 모델(Vector Auto-Regressive model), MARMA 모델(Multiple Auto-Regressive Moving Average model)등이 있다[1]. 이러한 모델들은 각 변수들 간에 서로 선형적으로 독립이어야 한다는 조건을 필요로 한다. 그러나 실 시스템의 경우 각 변수들간에 상관관계가 존재하는 비선형 함수로 구성되므로 이를 선형 알고리즘으로 표현하기에는 많은 제약이 따르게 된다. 이에 대해 신경회로망은 sigmoid 함수 등의 비선형 전달함수를 활성화함수에 갖고 있어 실 시스템의 비선형 특성을 학습할 수 있다. 그러나 이러한 방법은 느린 학습시간과 학습자체가 실패할 경우가 많은 문제를 갖고 있다[2].

이러한 문제를 해결하는데 신경회로망 모델 중 비선형 시

스템 모델링에 탁월한 효과를 보여주는 RBF(Radial Basis Function) 회로망이 많이 사용되고 시계열의 예측에 있어 좋은 성능을 보여주고 있다. 그러나 입력이 과거 출력으로 구성되어 있기 때문에 출력값의 변화의 정도가 심하거나 유사한 경향이 반복되는 경우에는 그 결과가 만족하게 나오지 않는 문제가 있었다.

이러한 문제점을 줄이고자 과거 출력으로 이루어진 입력을 과거 출력간의 차로 구성하여 활성화함수가 그에 반응하도록 하고 각 활성화함수에 예측을 위한 증가치(혹은 감소치)를 곱한 구조를 제안하고자 한다. 그리고 이 구조의 검증을 위해 Mackey-Glass chaotic time series[3], Lorenz 방정식, Rossler 방정식 등의 대표적 비선형 비정상 시계열의 예측에 적용하고자 한다.

2. RBF(Radial Basis Function) 회로망

2.1 Radial 함수

Radial 함수는 센터에 대해서 단조 증가(혹은 감소)하는 반응을 보이는 특성을 갖는 함수이다[4]. 즉 입력과 활성화함수의 센터가 유사할수록 radial 함수는 1로 활성화된다. 이러한 특성으로 인하여 과거의 출력 경향을 시계열의 다음 단계의 예측에 이용하게 된다.

전형적인 radial 함수는 Gaussian 함수로서 다음과 같다.

$$\phi(x) = \exp\left(-\frac{(x-c)^2}{r}\right) \quad (1)$$

다음 그림은 $r=1$, $c=0$ 일 때의 Gaussian radial 함수의 예이다.

* 準 會 員 : 仁荷大 大學院 電氣工學 卒業 碩士

** 正 會 員 : 仁荷大 電氣電子計算機工學部 教授 · 工博

接受日字 : 1998年 6月 17日

最終完了 : 1998年 12月 30日

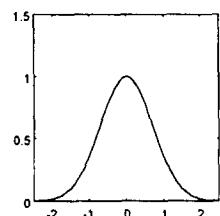


그림 1 Gaussian radial function
Fig. 1 Gaussian radial function

2.2 RBF 회로망의 구조

RBF 회로망의 구조는 n 개의 입력을 갖고 그 출력은 scalar 값을 갖는 그림 2와 같은 구조로 되어 있다.

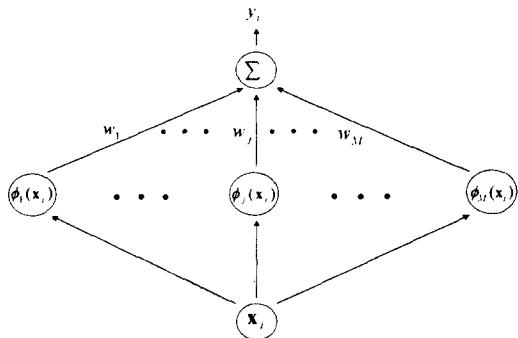


그림 2 RBF 회로망의 구조
Fig. 2 RBF network structure

이러한 구조는 식(2)에 의해서 $y_i : \mathbf{R}^n \rightarrow \mathbf{R}$ 의 매핑(mapping)을 구현한다[5].

$$y_i = \sum_{j=1}^M w_j \phi_j(\mathbf{x}_i) \quad (2)$$

$$\phi_j(\mathbf{x}_i) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{c}_j\|}{r^2}\right) \quad (j=1, 2, \dots, M) \quad (3)$$

w_j : 가중치, \mathbf{x}_i : 입력, \mathbf{c}_j : 센터, r : 너비(임의의 상수)

$\|\cdot\|$ 는 유클리디안 놈(Euclidean norm)을 나타내며 은닉 층 활성화함수 각각의 센터(\mathbf{c}_j)는 고정되어 있다.

시계열 예측을 위한 RBF 회로망의 입력은 식(4)와 같이 과거 p 개의 출력으로 이루어진다.

$$\mathbf{x}_i = [y_{i-1}, y_{i-2}, \dots, y_{i-p}] \quad (4)$$

Training set은 다음과 같다.

$$TS = \{(\mathbf{x}_i, y_i) \mid i = 1, 2, 3, \dots, M\} \quad (5)$$

3. 개선된 RBF 회로망

기존의 RBF 회로망 구조를 사용하여 시계열의 예측을 할 때 입력이 과거 출력으로 구성되어 있어서 출력값의 변화의

정도가 심하거나 유사한 경향이 반복되는 경우에는 그 결과가 만족하게 나오지 않는 문제가 있었다. 이는 입력이 과거의 출력에만 의존하여 시계열의 과거 값들의 경향에 민감하게 반응을 하기 때문이다. 이러한 단점을 개선하고자 다음의 구조를 제안한다.

3.1 구조

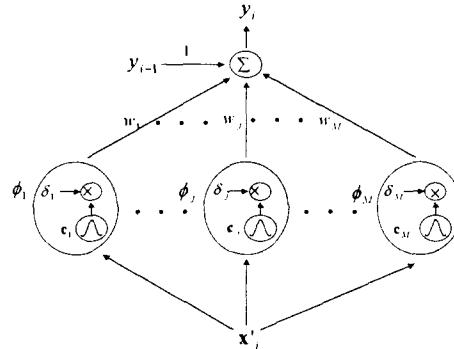


그림 3 개선된 RBF 회로망 구조
Fig. 3 Modified RBF network structure

그림 3에서 보는 바와 같이 은닉층은 기존의 활성화함수에 예측을 위한 증감치, δ_j 를 곱해준 구조로 되어 있으며 이때 입력력은 다음과 같이 표현된다.

$$\mathbf{x}'_i = [y_{i-1} - y_{i-2}, y_{i-2} - y_{i-3}, \dots, y_{i-p+1} - y_{i-p}] \quad (6)$$

$$y_i = \sum_{j=1}^M \phi_j(\mathbf{x}'_i) w_j + y_{i-1} \quad (7)$$

$$\phi_j(\mathbf{x}'_i) = \exp\left(-\frac{\|\mathbf{x}'_i - \mathbf{c}_j\|}{r^2}\right) \times \delta_j \quad (8)$$

p : 입력에 사용되는 과거 출력 개수

w_j : 가중치, \mathbf{x}'_i : 입력, \mathbf{c}_j : 센터, r : 너비(임의의 상수)

$$\delta_j = y_j - y_{j-1} \quad (9)$$

기존의 구조가 입력으로 p 개의 과거 출력을 사용하는 반면 개선된 구조에서는 식(6)과 같이 이들의 차로 구성된 $p-1$ 개의 원소를 갖는다. 개선된 RBF 회로망을 위한 Training set은 식(6)과 (7)을 사용하여 다음과 같이 구성된다

$$TS = \{(\mathbf{x}'_i, y_i) \mid i = 1, 2, 3, \dots, M\} \quad (10)$$

앞서 언급한 바와 같이 기존 RBF 회로망의 경우 그 입력 구조가 과거 출력만으로 이루어져 있기 때문에 그 반응이 시계열의 궤적을 감지하고 은닉층 활성화함수의 센터와 입력간에 강한 연관성이 있을 때 반응을 한다. 따라서 형태는 유사한 경향을 보이는 데이터의 경우에도 그 값이 다른 시간에서 수직이동이 되었다면 입력이 과거의 출력만으로 이루어졌기 때문에 전혀 다르게 인식된다. 그 결과 반응을 보이는 은닉

총의 활성화함수도 달라지게 된다. 그러나 과거 데이터간의 차로 이루어진 입력의 경우 그 크기는 다르지만 그 차이는 유사하게 이루어지므로 비슷한 경향을 보이는 데이터로 감지하게 되어 은닉층에서 동일한 활성화함수가 활성화 되게 된다. 즉 은닉층의 한 개 활성화함수가 감지하는 데이터의 수가 많아진다.

그림 4와 같이 사각형으로 표시된 부분과 타원으로 표시된 부분은 직관적으로 유사한 경향을 보인다. 그러나 이들을 그 크기 값으로만 표시된 입력에서는 서로 상이한 입력으로

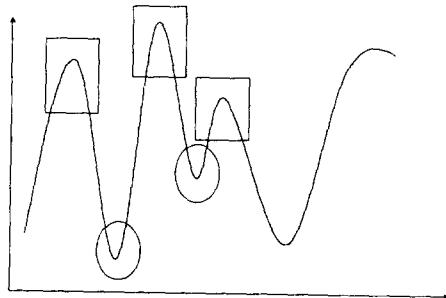


그림 4 유사한 경향을 갖는 데이터

Fig. 4 Data with similar pattern

인식된다. 이를 방지하기 위해 그 값들의 차로 입력을 구성하면 상호간에 유사한 경향을 갖는 입력 패턴으로 인식된다. 결과적으로 과거 출력의 경향에 의해 반응을 보이는 것이 아니라 출력간의 차에 의해 반응을 보이므로 보다 효과적인 활성화함수의 반응을 기대할 수 있다.

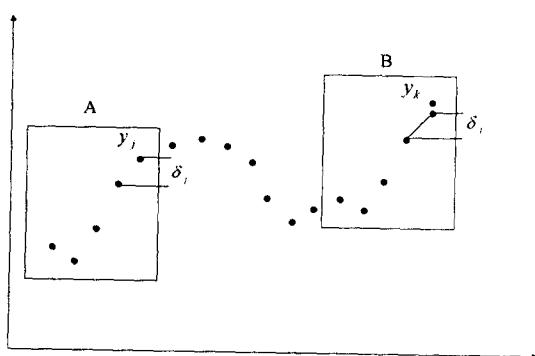


그림 5 활성화된 활성화함수에 증가치(혹은 감소치)를 곱해주는 이유

Fig. 5 The reason why hidden activation functions are multiplied by increment(or decrement)

RBF 회로망에서 은닉층의 활성화함수는 식(3)과 같이 그 센터와 유사한 경향을 갖는 입력에 대해서 1에 가까운 값으로 활성화 된다. 그림 5에서 A부분은 y_j 를 예측하기 위해 이전 출력 4개의 차로 이루어진 입력이 사용되었고, 이것이 학습을 통해 은닉층 활성화함수의 센터로 선택되었다면 그때의 증감치는 δ_j 가 된다. B 부분은 후에 y_k 를 예측하는데

있어서 입력은 A부분과 유사한 패턴을 갖게 되고 해당 활성화함수가 활성화된다. 이때의 δ_j 가 y_k 예측에 이용될 수 있도록 고려하여 예측하고자 하는 값의 입력에 의해 가장 활성화되는 활성화함수에 증감치를 곱하게 되었다.

3.2 학습 방법(Orthogonal Least Squares Learning Algorithm)[5][6]

실제적으로 은닉층 활성화함수의 센터는 학습 데이터의 입력으로 초기화된다. 이에 따라 학습 데이터의 개수가 증가할수록 그 구조의 복잡도가 증가하게 된다. 이를 줄이고자 OLS (Orthogonal least squares) 알고리즘을 이용하여 센터를 선택함으로서 적절하고 간소화된 RBF 회로망을 얻을 수 있다. 이 작업을 이해하기 위해서 RBF 회로망의 식(2)를 선형회귀모델의 특별한 경우로 고려하면

$$d(t) = \sum_{i=1}^M p_i(t) \theta_i + \epsilon(t) \quad (11)$$

또한 LS(least squares) 방법을 기하학적으로 해석하기 위하여 식(11)을 다음과 같이 행렬 형태로 나타낸다.

$$\mathbf{d} = \mathbf{P}\boldsymbol{\theta} + \mathbf{E} \quad (12)$$

여기서

$$\mathbf{d} = [d(1), d(2), \dots, d(M)]^T \quad (13)$$

$$\mathbf{P} = [\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_M],$$

$$\mathbf{p}_i = [p_i(1), p_i(2), \dots, p_i(M)]^T \quad (i=1, 2, \dots, M) \quad (14)$$

$$\boldsymbol{\theta} = [\theta_1, \theta_2, \dots, \theta_M]^T \quad (15)$$

$$\mathbf{E} = [\epsilon(1), \epsilon(2), \dots, \epsilon(M)]^T \quad (16)$$

\mathbf{d} 는 원하는 출력을 나타내고 $\boldsymbol{\theta}$ 는 가중치, \mathbf{P} 는 RBF에 해당한다. 기본 벡터(basis vector)를 형성하는 regressor \mathbf{p}_i 와 LS 해(solution)인 $\hat{\boldsymbol{\theta}}$ 는 이를 기본 벡터에 의해 확장(span)된 공간에서 $\mathbf{P}\hat{\boldsymbol{\theta}}$ 가 \mathbf{d} 의 projection이 되는 조건을 만족하여야 한다. 다시 말하면 projection $\mathbf{P}\hat{\boldsymbol{\theta}}$ 의 square는 기본 벡터에 의해 계산될 수 있는 원하는 출력 에너지의 부분이다. 일반적으로 다른 regressor들은 상호 연관되어있기 때문에 개개의 regressor가 출력 에너지에 얼마나 관련되어 있는지가 명확하지 않다. OLS 방법은 여기서 regressor \mathbf{p}_i 를 orthogonal 기본 벡터로 변환하여 개개의 기본 벡터로부터 원하는 출력에 끼치는 영향을 계산할 수 있게 한다.

회귀 행렬 \mathbf{P} 는 다음과 같이 재구성 할 수 있다.

$$\mathbf{P} = \mathbf{W}\mathbf{A} \quad (17)$$

\mathbf{A} 는 다음과 같이 대각부분은 1이과 그 아래는 0으로 이루어진 $M \times M$ 행렬이다.

$$\mathbf{A} = \begin{bmatrix} 1 & \alpha_{12} & \alpha_{13} & \dots & \alpha_{1M} \\ 0 & 1 & \alpha_{23} & \dots & \alpha_{2M} \\ 0 & 0 & \dots & \dots & \dots \\ \dots & \dots & \dots & 1 & \alpha_{(M-1)M} \\ 0 & 0 & \dots & 0 & 1 \end{bmatrix} \quad (18)$$

\mathbf{W} 행렬도 \mathbf{A} 행렬과 같이 $M \times M$ 행렬이고 orthogonal 컬럼 \mathbf{w}_i 를 갖는다. 즉,

$$\mathbf{W}^T \mathbf{W} = \mathbf{H} \quad (19)$$

\mathbf{H} 행렬은 대각부분에 원소 h_i 를 갖는다.

$$h_i = \mathbf{w}_i^T \mathbf{w}_i = \sum_{i=1}^M w_i(t) w_i(t) \quad (i=1, 2, \dots, M) \quad (20)$$

Orthogonal 기본 벡터 \mathbf{w}_i 에 의해 확장된 공간은 \mathbf{p}_i 에 의해 확장된 공간과 같다. 그러므로 식(14)를 다음과 같이 적용할 수 있다.

$$\mathbf{d} = \mathbf{Wg} + \mathbf{E} \quad (21)$$

또한 이 때의 OLS 해 $\hat{\mathbf{g}}$ 는 다음과 같이 주어진다.

$$\hat{\mathbf{g}} = \mathbf{H}^{-1} \mathbf{W}^T \mathbf{d} \quad (22)$$

혹은

$$\hat{\mathbf{g}}_i = \frac{\mathbf{w}_i^T \mathbf{d}}{\mathbf{w}_i^T \mathbf{w}_i} \quad (i=1, 2, \dots, M) \quad (23)$$

$\hat{\mathbf{g}}$ 와 $\hat{\theta}$ 는 다음의 삼각관계를 만족한다.

$$\mathbf{A} \hat{\theta} = \hat{\mathbf{g}} \quad (24)$$

잘 알려진 classical Gram-Schmidt 방법에 의해 regression 행렬을 orthogonalize 하면서 동시에 \mathbf{A} 의 열을 구해나간다. 그 계산과정은 다음과 같다.

$$\left. \begin{array}{l} \mathbf{w}_1 = \mathbf{p}_1 \\ \alpha_{ik} = \frac{\mathbf{w}_i^T \mathbf{p}_k}{(\mathbf{w}_i^T \mathbf{w}_i)} \quad i=1, 2, \dots, k-1 \\ \mathbf{w}_k = \mathbf{p}_k - \sum_{j=1}^{k-1} \alpha_{jk} \mathbf{w}_j \end{array} \right\} \quad k=2, 3, \dots, M \quad (25)$$

OLS 방법은 일반 LS 방법에 비교하여 나은 계산 특성을 갖는다. 그러나 우리의 관심은 OLS 방법을 센터를 선택하는데 이용하는 것이다. RBF 회로망의 경우 입력 데이터의 수가 매우 크기 때문에 전체 학습 데이터에서 적절한 센터를 선택하여야 한다. 일반적으로 전체 M 개의 데이터 중에서 적절한 모델링을 위한 M_s 개($\ll M$)의 센터가 요구되어진다. 이를 센터를 선택하는데 forward regression 방법에 OLS 알고리즘을 사용하였다. \mathbf{w}_i 와 \mathbf{w}_j ($i \neq j$)는 orthogonal 하기 때

문에 $\mathbf{d}(t)$ 의 에너지는 다음과 같다.

$$\mathbf{d}^T \mathbf{d} = \sum_{i=1}^M g_i^2 \mathbf{w}_i^T \mathbf{w}_i + \mathbf{E}^T \mathbf{E} \quad (26)$$

여기서 \mathbf{w}_i 에 기인하는 오차감소율(error reduction ratio)은 다음과 같이 정의할 수 있다.

$$[err]_i = \frac{g_i^2 \mathbf{w}_i^T \mathbf{w}_i}{(\mathbf{d}^T \mathbf{d})} \quad (i=1, 2, \dots, M) \quad (27)$$

이 감소율이 forward regression 방법에서 센터를 찾는데 효과적인 수단이 된다. 여기서 앞에서 언급한 classical Gram-Schmidt 방법을 다시 사용한다. 센터 선택 과정을 요약하면 다음과 같다.

□ 첫 번째 단계 ($i=1, 2, \dots, M$)

$$\left. \begin{array}{l} \mathbf{w}_1^{(i)} = \mathbf{p}_i \\ g_1^{(i)} = \frac{(\mathbf{w}_1^{(i)})^T \mathbf{d}}{((\mathbf{w}_1^{(i)})^T \mathbf{w}_1^{(i)})} \\ [err]_1^{(i)} = \frac{(g_1^{(i)})^2 (\mathbf{w}_1^{(i)})^T \mathbf{w}_1^{(i)}}{(\mathbf{d}^T \mathbf{d})} \\ [err]_1^{(i)} = \max \{ [err]_1^{(i)}, i=1, 2, \dots, M \} \quad \text{을 찾아서} \\ \mathbf{w}_1 = \mathbf{w}_1^{(i)} = \mathbf{p}_{i_1} \quad \text{를 선택한다.} \end{array} \right\} \quad \text{를 계산하고}$$

□ k 번째 단계

$$(k \geq 2, i=1, 2, \dots, M, i \neq i_1, i \neq i_2, \dots, i \neq i_{k-1})$$

$$\left. \begin{array}{l} \alpha_{jk}^{(i)} = \frac{\mathbf{w}_j^T \mathbf{p}_k}{(\mathbf{w}_j^T \mathbf{w}_j)} \quad j=1, 2, \dots, k \\ \mathbf{w}_k^{(i)} = \mathbf{p}_k - \sum_{j=1}^{k-1} \alpha_{jk}^{(i)} \mathbf{w}_j \\ g_k^{(i)} = \frac{(\mathbf{w}_k^{(i)})^T \mathbf{d}}{((\mathbf{w}_k^{(i)})^T \mathbf{w}_k^{(i)})} \\ [err]_k^{(i)} = \frac{(g_k^{(i)})^2 (\mathbf{w}_k^{(i)})^T \mathbf{w}_k^{(i)}}{(\mathbf{d}^T \mathbf{d})} \end{array} \right\} \quad \text{를 계산하고}$$

$$[err]_k^{(i)} = \max \{ [err]_k^{(i)}, i=1, 2, \dots, M, i \neq i_1, \dots, i \neq i_{k-1} \} \quad \text{을 찾아서}$$

$$\left. \begin{array}{l} \mathbf{w}_k = \mathbf{w}_k^{(i)} = \mathbf{p}_{i_k} - \sum_{j=1}^{k-1} \alpha_{jk} \mathbf{w}_j \\ \alpha_{jk} = \alpha_{jk}^{(i)}, j=1, 2, \dots, k \end{array} \right\} \quad \text{를 선택한다.}$$

위의 과정은 다음 식을 만족하는 M_S 단계에서 멈춘다.

$$1 - \sum_{j=1}^{M_S} [err]_j < \rho \quad (28)$$

$$\rho = \frac{\sigma_e^2}{\sigma_d^2} \quad (29)$$

모든 과정이 끝난 후 구해진 \mathbf{A}, \mathbf{g} 를 이용하여(식(24)) 가중치(θ)를 구하고 선택된 \mathbf{W}, \mathbf{A} 를 이용하여(식(17)) 은닉층 활성화함수의 센터(\mathbf{P})를 구한다. 이 때 중감자(δ)는 각 센터에 연관된 상수형태로, 선택된 센터에 해당하는 δ 값들을 취하게 된다. 여기서 활성화함수의 폭(r)은 큰 입력 차원에 대해서는 가능하지 않지만 전통적으로 데이터 내부의 간격을 선택하게 된다[10].

4. 실험 결과 및 고찰

각 실험은 그레프의 점선 이전 부분을 회로망에 학습시켜 점선 안쪽의 데이터를 Matlab을 이용하여 모의 실험, 예측하였고 기존의 구조에 의한 예측 결과와 비교하여 그레프로 나타내었다. 고찰에서 각 실험별 구조 및 RMS(Root Mean Square) 오차를 표로 나타내었다.

4.1 Mackey-Glass chaotic time-series 예측

Mackey-Glass series는 다음과 같다.

$$\frac{dx(t)}{dt} = \frac{0.2x(t-\tau)}{(1+x(t-\tau))^{\frac{10}{3}}} - 0.1x(t) \quad (30)$$

500개의 데이터를 학습에 이용하여 이후 200개의 데이터를 예측하였다.

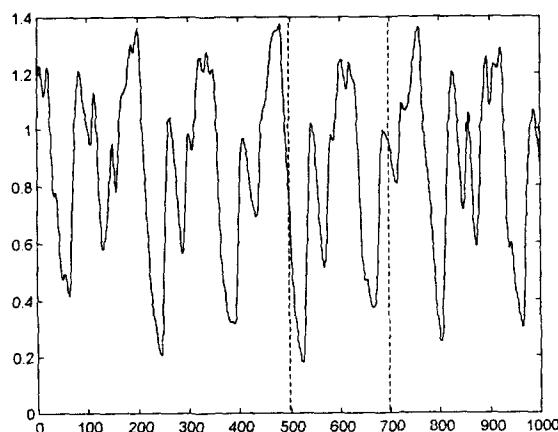


그림 6 Mackey-Glass chaotic time series ($\tau = 40$)

Fig. 6 Mackey-Glass chaotic time series ($\tau = 40$)

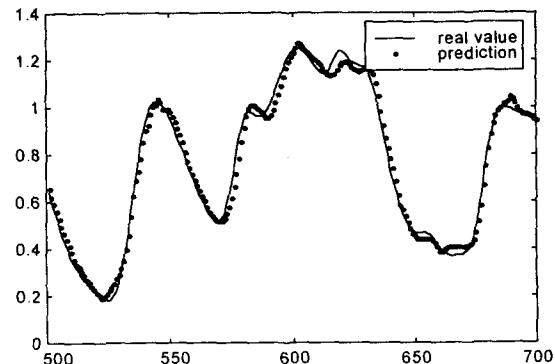


그림 7 기존 RBF 회로망 구조를 이용한 Mackey-Glass series 예측

Fig. 7 Mackey-Glass series prediction using original RBF network structure

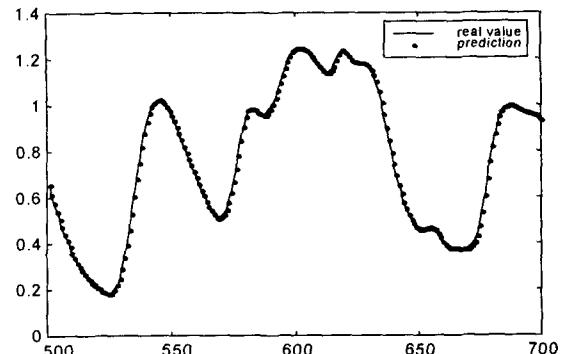


그림 8 개선된 RBF 회로망 구조를 이용한 Mackey-Glass series 예측

Fig. 8 Mackey-Glass series prediction using modified RBF network structure

4.2 Lorenz equation 예측

Lorenz equation은 다음과 같다.

$$\begin{aligned} \frac{dx}{dt} &= \sigma(y-x) & \frac{dy}{dt} &= rx - v - xz & \frac{dz}{dt} &= sy - bz \\ \sigma &= 10, \quad r = 28, \quad b = \frac{8}{3} \end{aligned} \quad (31)$$

600개의 데이터를 학습에 이용하여 이후 200개의 데이터를 예측하였다.

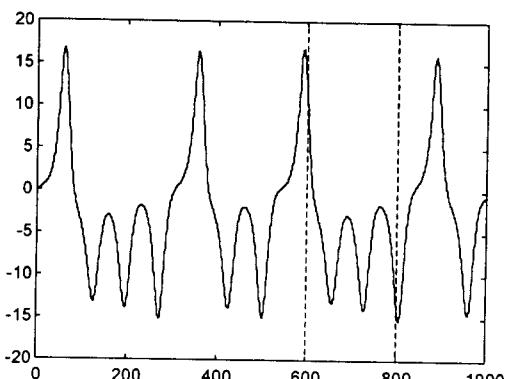


그림 9 Lorenz equation의 그래프
Fig. 9 Plot of the Lorenz equation

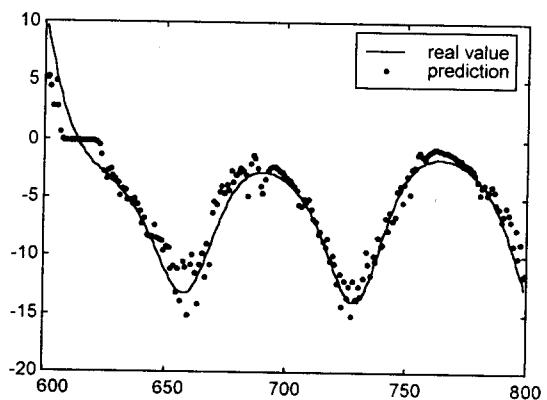


그림 10 기존 RBF 회로망 구조를 이용한 Lorenz equation 예측
Fig. 10 Lorenz equation prediction using original RBF network structure

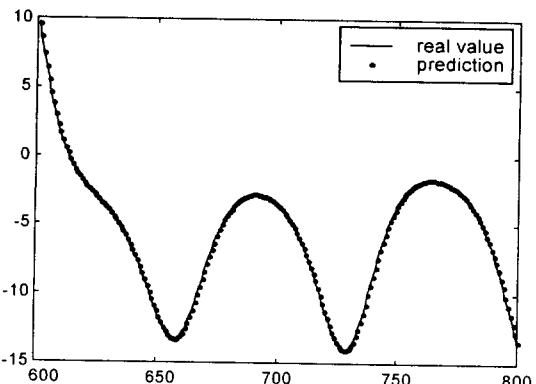


그림 11 개선된 RBF 회로망 구조를 이용한 Lorenz equation 예측
Fig. 11 Lorenz equation prediction using modified RBF network structure

4.3 Rossler equation 예측

Rossler equation은 다음과 같다.

$$\begin{aligned} \frac{dx}{dt} &= -z - y, & \frac{dy}{dt} &= x + ay, & \frac{dz}{dt} &= -b + z(x - c) \\ a &= 0.15, & b &= 0.2, & c &= 10 \end{aligned} \quad (32)$$

400개의 데이터를 학습에 이용하여 200개의 데이터를 예측하였다.

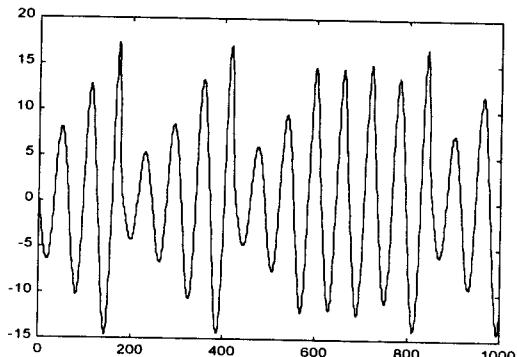


그림 12 Rossler equation의 그래프
Fig. 12 Plot of the Rossler equation

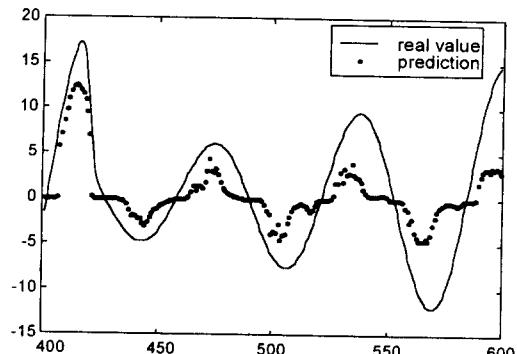


그림 13 기존 RBF 회로망 구조를 이용한 Rossler equation 예측
Fig. 13 Rossler equation prediction using original RBF network structure

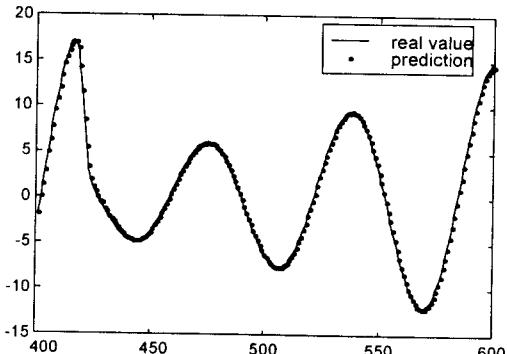


그림 14 개선된 RBF 회로망 구조를 이용한 Rossler equation 예측
Fig. 14 Rossler equation prediction using modified RBF network structure

4.4 고찰

위의 여러 실험 결과와 같이 개선된 RBF 회로망 구조가 기존의 구조에 비해 좋은 결과를 보임을 알 수 있다. 각 실험 결과의 구조 및 RMS 오차를 다음 표에 정리하였다.

표 1 실험별 구조 및 RMS 오차
Table 1 Structure and RMS(Root Mean Square) error for each experiment

실험 대상	Mackey-Glass		Lorenz		Rossler	
	기존 구조	제안 구조	기존 구조	제안 구조	기존 구조	제안 구조
온닉증						
활성화함수 개수	37	33	67	38	51	32
입력에 사용된 과거출력 개수	20	20	10	20	10	20
RMS 오차	0.02 90	0.00 37	2.77 56	0.02 52	4.73 72	0.12 36

각 실험 결과에서와 같이 기존구조에 비하여 좋은 결과를 나타낼 수 있다. 이는 기존 구조가 시계열의 궤적, 그 출력 크기의 경향에 민감하게 반응하는 성향을 줄이기 위해 그 입력의 구성을 충분으로 하고 각 뉴런에 중간치를 곱함으로 성능향상이 이루어졌다고 생각합니다. 그러나 입력시 사용되는 과거 출력의 개수의 임의성 때문에 실험에 대한 뉴런의 개수나 센터들이 최적화되어 있지는 않을 것이라고 생각합니다. 그리고 이는 실 시스템이 아닌 데이터만으로의 결과이기 때문에 실 시스템에 적용되었을 때 그 차에의한 잡음에 대한 문제를 고려해야 할 것으로 생각됩니다. 이에 대해 이미 학습을 위한 과거 데이터의 경우 RBF 회로망을 이용한 시스템 동정[11]을 통하여 어느정도의 잡음극복이 가능하리라 생각을 합니다. 그러나 이후 예측을 위한 실 출력에 대해서는 시스템의 적용대상에 따라 잡음을 극복할 수 있는 방안이 필요하리라 생각됩니다.

5. 결 론

시계열이나 그 외의 비선형 특성을 보이는 데이터에 대한 예측에 RBF 회로망이 사용되고 있습니다. 예로 적용형 RBF 신경회로망, Evolving RBF 신경회로망등의 방법 및 Fast Orthogonal Search rule(FSO) 알고리즘을 적용한 방법등이 있습니다. 이러한 방법들은 학습 알고리즘의 변화에 중점을 두었다면 본 논문은 그 구조를 개선하는데 중점을 두었습니다.

본 논문에서 제안한 RBF 회로망 구조는 기존의 RBF 회로망의 구조가 시계열의 궤적을 감지, 그 출력의 절대적 크기의 경향에 민감하게 반응하는 성향을 줄이고자 그 입력의 구성을 충분으로 삼고 각 뉴런 출력에 중간치를 곱해주었다. 실험에서도 보여지는 바와 같이 Mackey-Glass time series의

예측에 있어 좋은 성능을 보여주고 있고 Lorenz, Rossler equation의 경우에는 기존의 구조와 비교하여 상당히 좋은 성능을 보여줄 수 있다. 그러나 입력에 이용되는 과거 출력개수를 결정함에 임의성이 있고, 제안하는 구조가 기존의 구조에 비해 그 계산량의 증가는 필연적이지만 그 성능을 비교하였을 때 보상이 되리라 생각된다. 실제적인 측면에서 이러한 예측 방법이 적용될 수 있는 많은 응용분야가 있을 것이다. 한 예로 좋은 필터를 생성하기 위하여 동적 시스템의 잡음 예측에 적용할 수 있다. 이 방법은 또한 진동하는 테이블 위에서 뛰는 꿩의 움직임과 같은 카오스 행동을 보이는 시스템의 예측에도 적용될 수 있을 것이다. 또한 비선형 시스템의 예측을 필요로 하는 많은 분야에서 활용할 수 있으리라 생각된다.

본 연구는 96년도 인하대학교 연구비 지원에 의하여 수행되었습니다.

참 고 문 헌

- [1] Spyros Markidakis and Steven C. Wheelwright, Interactive Forecasting, Hodel-Dey, Inc., 1978.
- [2] Herz, John A., Richard G. Palmer and Anders S.Krogh, Introduction to The Theory of Neural Computation, Addison Wesley, 1991, pp.115-141.
- [3] Mackey, M. and Glass, L. "Oscillation and Chaos in Physiological Control Systems". Science 197, pp.287-289, 1977.
- [4] Mark J.L.Orr, Introduction to Radial Basis Function Networks, 1996, <http://www.cns.ed.ac.uk/people/mark/rbf.tar.Z>
- [5] S.Chen, C.F.N. Cowan, and P.M. Grant, "Orthogonal Least Squares Learning Algorithm for Radial Basis Function Networks", IEEE Trans. on Neural Networks, Vol.2, No.2, pp.302-309, 1991.
- [6] S.Chen, S.A.Billings, and W. Luo, "Orthogonal least squares methods and their application to non-linear system identification", International Journal of Control, Vol.50, No.5, pp.1873-1896, 1989.
- [7] Tomaso Poggio and Federico Girosi, "Networks for Approximation and Learning", Proceedings of the IEEE, Vol.78, No.9, pp.1481-1496, 1990.
- [8] Sunil Elanayar V.T. and Yung C. Shin, "Radial Basis Function Neural Network of Approximation and Estimation of Nonlinear Stochastic Dynamic Systems", IEEE Trans. on Neural Networks, Vol.5, No.4, pp. 594-603, 1994.
- [9] Simon Haykin, Neural Networks a Comprehensive Foundation, Prentice Hall, 1994, pp.236-281.
- [10] Sean Mcloone and George Irwin, "Nonlinear optimization of RBF networks", International Journal

of Systems Science, vol.29, No. 2, pp.179-189, 1998

- [11] 이형엽, “개선된 RBF 신경회로망에 의한 잡음을 갖는 비선형 시스템의 예측”, 대한전기학회 하계학술대회
논문집 G, pp.2362-2364, 1997

저 자 소 개



김 상 환 (金 商 桓)

1971년 1월 18일생. 1996년 인하대 공대 전기공학과 졸업. 1998년 인하대 대학원 전기공학과 졸업(석사).



이 종 호 (李 鐘 浩)

1953년 4월 14일생. 1976년 서울대 공대 전기공학과 졸업. 1978년 동 대학원 전기공학과 졸업(석사). 1986년 미 아이오 와주립대 전기 및 컴퓨터공학 졸업(박). 1986~1989년 미 노트담대 조교수. 1994~1995년 미 브라운대 방문교수. 현재 인하대 공대 전자전기컴퓨터공학부 교수.