

쌍선형 회귀성 신경망을 이용한 전력 수요 예측에 관한 기초연구

박태훈** 최승억* 박동철***
명지대 제어계측공학과 *명지대 제어계측공학과 *명지대 제어계측공학과

A Preliminary Result on Electric Load Forecasting using BLRNN (BiLinear Recurrent Neural Network)

Tae-Hoon Park Seung-Eok Choi Dong-Chul Park
Myongji Univ. Cont. & Instr. Eng. *Myongji Univ. Cont. & Instr. Eng. *Myongji Univ. Cont. & Instr. Eng.

Abstract

In this paper, a recurrent neural network using polynomial is proposed for electric load forecasting. Since the proposed algorithm is based on the bilinear polynomial, it can model nonlinear systems with much more parsimony than the higher order neural networks based on the Volterra series. The proposed Bilinear Recurrent Neural Network(BLRNN) is compared with Multilayer Perceptron Type Neural Network(MLPNN) for electric load forecasting problems. The results show that the BLRNN is robust and outperforms the MLPNN in terms of forecasting accuracy.

으로 가능하다[5].

Volterra Series 확장은 간략화된 형태로 비선형 시스템 인식에 많이 이용되어 왔고, 쌍선형(bilinear) 다항식 모델도 회귀성 비선형 시스템의 인식에 많이 이용되어 왔다. 쌍선형 다항식 모델은 Volterra Series 표현보다 매우 적은 수의 계수를 이용해서 많은 종류의 비선형 함수를 모델링할 수 있다.

본 논문에서는 이러한 쌍선형 다항식을 이용한 회귀성 신경망을 구성하고, 어느 한 지역의 전력 수요량을 time series에 측과 비슷한 방법으로 예측하였다. 2장에서는 Volterra Series와 고차수 신경망에 관해서 다루었고, 3장에서는 제안한 쌍선형 신경망 모델의 구조와 학습알고리즘을 다루었고, 4장에서는 제안한 신경망을 이용한 전력 수요 예측 실험 결과를 다루었다.

1. 서론

선형 시스템의 성질을 알아내는 방법은 여러 학자들에 의해 많은 연구가 진행되었으며 그 시스템을 제어하기 위한 규칙성을 찾아내는 것은 그리 어렵지 않다. 그러나 time series와 같은 시간에 따라 불규칙하게 변화하는 자연계에 존재하는 어떤 현상들을 포착하고 그것을 적당한 데이터로 표현하여 앞으로 발생할 수 있는 유사한 현상을 예측하는 것, 즉 불규칙적인 변화 속에 존재하는 법칙을 찾아내거나 경험적 규칙성을 알아내는 것은 쉽지가 않다.

이렇게 비선형적인 현상들이 데이터로 표현되어 주어졌을 때, 그 데이터 속의 어떤 경험적 규칙성을 배우고 그것을 통해서 비선형 시스템의 성질을 알아내는데 있어서 인간 두뇌의 성질과 비슷한 신경망 기법이 개발된 후 많은 학자들이 활발히 연구하고 있는데[1-3], 이는 신경망이 비선형 시스템의 성질을 알아내는데 있어서 탁월한 능력을 지니고 있기 때문이다. 이러한 신경망의 성질은 특히 time series의 예측에 관한 문제에서 성능의 탁월함이 두드러지게 나타난다.

최근에 고차수 신경망(high order neural network)이 개발되었는데 메모리 요구량, 계산 시간, 패턴 인식, 그리고 학습 성질에서 많은 장점을 지니고 있다[4-5]. 특히 복잡한 비선형 판별 표면을 만들어 내는 데에 있어서는 순방향 신경망(feedforward network)보다 적은 수의 은닉층과 은닉층 뉴런

2. Volterra Series 와 고차수 신경망(High - Order Neural Network)

$x[n]$ 과 $y[n]$ 이 각각 비선형 causal 시스템의 입·출력 신호라고 가정할 때 N번까지 회귀를 제한하는 K차 Volterra Series 팽창은 다음과 같이 정의된다.

$$y[n] = c_{m_0} + \sum_{m_1=0}^{N-1} c_{m_1} x[n-m_1] + \sum_{m_1=0}^{N-1} \sum_{m_2=0}^{N-1} c_{m_1, m_2} x[n-m_1] x[n-m_2] + \dots + \sum_{m_1=0}^{N-1} \dots \sum_{m_k=0}^{N-1} c_{m_1, m_2, \dots, m_k} x[n-m_1] \dots x[n-m_k]$$

여기서 c_{m_1, m_2, \dots, m_k} 는 이 시스템의 K차 Volterra Kernel이라고 한다. 이 경우 $O(N^k)$ 개의 계수가 필요하며, 보통 쓰이는 N과 K에 대해서도 $O(N^k)$ 는 매우 큰 숫자가 된다. 결국 많은 수의 계수를 필요로 하는 Volterra Series에 기초를 둔 고차수 신경망은 저차수에 머물 수밖에 없게 된다[5]. 즉, 고차수 신경망 이용의 가능성은 인정되지만, 실제 상황에서 사용되기에는 계수의 과다로 인해 유용성은 제한적인 수밖에 없음을 알 수 있다. 이에 대해 복잡한 비선형 시스템을 최소한의 계수로 효율적으로 모델링하는 대안으로 회귀성 신경망

(recurrent neural network)이 있다[6]. 이것은 순방향 신경망보다 동적인 시스템의 인식이나 time series 예측에서 보다 유용함이 실제적인 문제에 응용되어 보고되고 있다[7].

3. 쌍선형 회귀성 신경망(Bilinear Recurrent Neural Network)의 구조와 학습방법

3.1 구조




그림 1 : 기본적인 쌍선형 회귀성 신경망 구조

그림 1에서는 입력 변수 2개, 은닉층 뉴런 1개, 일차의 회귀도, 그리고 한 개의 출력 변수를 가지는 쌍선형 회귀성 신경망(BLRNN)을 보여준다[3].

$$y[n] = \sum_{i=1}^{N-1} a_i y[n-i] + \sum_{i=0}^{N-1} \sum_{j=1}^{N-1} b_{ij} y[n-j] x[n-i] + \sum_{i=0}^{N-1} c_i x[n-i] \quad (1)$$

식(1)에서 $x[n]$ 은 입력, $y[n]$ 은 출력, 그리고 N 은 회귀의 차수이다. 한편, 식(1)을 더욱 발전시켜 N 개의 입력 뉴런, M 개의 은닉층 뉴런, 그리고 K 차의 다항식을 갖는 BLRNN을 일반화하면 다음과 같다.

$$\vec{x}[n] = [x_1[n], x_2[n], \dots, x_N[n]]^T$$

$$\vec{X}[n] = [\vec{x}[n]^T, \vec{x}[n-1]^T, \dots]^T$$

M 차원의 출력과 그 회귀항을 다음으로 하면 :

$$\vec{Y}[n] = [y_1[n], y_2[n], \dots, y_M[n]]^T$$

$$\vec{Z}[n] = [\vec{Y}[n-1]^T, \vec{Y}[n-2]^T, \dots]^T$$

위에서 주어진 쌍선형 다항식을 이용해 신경망을 구현한다. 즉 N 개의 입력 뉴런과 M 개의 은닉층 뉴런으로 회귀성 신경망을 구성하고, K 차의 다항식을 이용하면, 입력 뉴런의 상태를 다음과 같이 한다,

$$\vec{X}[n] = [x_1[n], x_2[n], \dots, x_N[n]]^T$$

$$\overrightarrow{NET}[n] = [net_1[n], net_2[n], \dots, net_M[n]]^T$$

각 은닉층 뉴런의 상태는 다음이 된다:

$$O_p[n] = \phi(net_p[n])$$

$$net_p[n] = w_p + \overrightarrow{A}_p^T \vec{Z}[n] + \vec{Z}[n]^T B_p \vec{X}[n] + \overrightarrow{C}_p^T \vec{X}[n]$$

여기서 $Z[n]$ 은 $M \times K$ 행렬로 회귀항이 되며, W_p 는 바이어스(bias)값이고, A_p 는 회귀항의 weight, B_p 는 쌍선형 회귀항 weight 행렬, C_p 는 은닉층과 출력을 연결시키는 weight 벡터이며, ϕ 는 은닉층 뉴런의 활성화함수(active function)이다. 여기서는 가장 전형적으로 많이 쓰이는 활성화함수중 하나인 (0,1)의 범위를 가지는 sigmoid 함수를 사용하였다. BLRNN에서 은닉층과 출력층 사이의 연결은 보통의 순방향형 신경망에서 쓰이는 관계식과 같다[3].

3.2 BLRNN의 학습 알고리즘과 그의 수렴

주어진 BLRNN에 대해 그의 학습 알고리즘은 기본적으로 steepest gradient descent 방법에 의해 구해진다. 먼저 그 오차 함수를 다음으로 정의하면,

$$\sum_{n=1}^{N_{frame}} E[n] = \sum_{n=1}^{N_{frame}} \frac{1}{2} \sum_{l=1}^{N_o} (d_l[n] - o_l[n])^2 \quad (2)$$

여기서 N_{frame} 은 학습 데이터의 수이며, N_o 는 출력 뉴런의 수, 그리고 $d_l[n]$ 은 n 번째 데이터에 대한 목표값이다.

이제 steepest gradient descent 방법에 의한 weight 조정은 다음식으로 다시 표현된다.

$$w_{ij}^{new} = w_{ij}^{old} - \eta \sum_{n=1}^{N_{frame}} \frac{\partial E[n]}{\partial w_{ij}^{old}} \quad (3)$$

여기서 η 는 학습 이득(learning gain)이다. 식(3)의 적당한 미분값을 구하여 대입하면, 매 학습마다의 weight 변화는 다음 식들로 요약된다.

$$w_{ij}^{new} = w_{ij}^{old} + \eta \delta_l[n] o_p[n]$$

$$C_p^{new} = C_p^{old} + \eta \delta_p[n] X[n]$$

$$A_p^{new} = A_p^{old} + \eta \delta_p[n] Z[n]$$

$$B_p^{new} = B_p^{old} + \eta \delta_p[n] Z[n] X[n]^T$$

여기서,

$$\delta_l[n] = (d_l[n] - o_l[n]) \phi'(net_l[n])$$

$$\delta_p[n] = \sum_{l=1}^{N_o} \delta_l[n] w_{lp} \phi'(net_p[n])$$

여기에서 이 알고리즘에 대한 수렴 조건은 앞에서 정의한 오차함수가 음의 방향으로 가기 위해 필요한 조건이다. 이를 구해 정리하면 다음의 식으로 요약된다.

$$0 < \eta < \frac{2N_{frame}N_o}{\sum_{n=1}^{N_{frame}} \sum_{l=1}^{N_o} \text{stuf} \left(\frac{\partial o_l(n)}{\partial w} \right)^2}$$

본 논문에서는 학습 이득을 8/10 비율로 감소시켰다.

4. 쌍선형 회귀성 신경망을 이용한 전력 수요

본 논문에서 사용한 쌍선형 회귀성 신경망은 앞에서도 언

급한 것처럼 causal 시스템이기 때문에 과거의 입력이 현재의 출력에 영향을 미치게 된다[3]. 그러므로 시간 지연(time delay)이 입력에 사용된다. 다음의 식은 쌍선형 회귀성 신경망의 구현에 있어서 입력과 출력을 나타내는 것이다.

입력 : $x[n-t]$, $t=0,12,24,48$
 출력 : $x[n+k]$, $k=1,2,6,12$

제한한 신경망 구현에 있어서 사용된 데이터는 한 시간 간격으로 측정된 Florida Power and Light 회사의 1989년 1월-2월의 전력 수요량을 기록한 것이고, 그중 1000 개의 데이터를 학습용으로, 200 개를 테스트용으로 사용하였다. 전력 수요 정확도를 비교하기 위해 BLRNN(2-1-1 구조)과 MLPNN(2-2-1 구조)에 같은 초기 상태, 같은 수의 weight들(모두 8 개의 weight), 그리고 같은 학습 이득을 적용하였다. 신경망의 출력은 12시간 앞의 것까지 예측하는 것으로 하였고, 입력은 현재 입력과 과거 입력 및 바이어스를 이용하였다. 그림 2 는 학습에 사용된 전력 수요 데이터를 보여주고 있다.




그림 2 : 시간에 따른 전력 수요량의 변화

그림 3은 예측 단계에 대한 두 신경망의 평균 오차를 보여주고 있다. 그림 4는 학습이 이루어진 두 신경망에 적용한 200개의 테스트 데이터에 대한 출력 결과를 보여준다.




그림 3 : 쌍선형 회귀성 신경망에 의한 전력 수요 예측




그림 4: 다층형 퍼셉트론 신경망에 의한 전력수요 예측

표 1은 두 신경망의 예측시간(lead time) 변화에 따른 학습 결과를 보여주고 있다.

예측 단계	1	6	12
BLRNN	0.00134	0.00579	0.00585
MLPNN	0.00149	0.00984	0.00592

표 1 : 예측시간(lead time)의 변화에 따른 예측의 결과

5. 결론

본 논문에서는 전력 수요를 위해 이용한 쌍선형 회귀성 신경망(BLRNN)을 소개하였고, 이 신경망의 학습 결과와 다층형 퍼셉트론 신경망(MLPNN)의 학습 결과를 비교하였는데, 소개한 BLRNN이 MLPNN보다 학습 시간, 평균 오차, 정확도 면에서 더 뛰어난 것을 보였다. 또한 MLPNN과는 달리 적은 수의 파라미터만을 가지고 더 뛰어난 결과를 가져온 것을 보여준다.

전력 수요를 예측하기 위해 BLRNN에서 입력 변수가 하나인 구조를 가지는 신경망을 직접 사용하는 것은 실제 상황에서 쓸 수는 없지만 BLRNN이 전력 수요의 예측에 응용될 수 있다는 가능성을 보여준다. 더욱 많은 수의 입력 변수를 가지는 BLRNN을 사용하면 실제 상황에서 쓸 수 있을 것이다.

Acknowledgement

본 연구는 한국과학기술원 95핵심전문연구(과제번호 951 - 0906 - 062 - 2)의 연구비 지원으로 수행되었습니다.

참고 문헌

1. A. Lapedes and R. Farber; "Nonlinear signal processing using neural networks : Prediction and Modeling", Technical Report, LA-Ur87-2662, Los Alamos National Laboratory, Los Alamos, New Mexico, (1987)
2. Dong Chul Park, M.El-sharkawi, R. Marks; "Adaptively Trained Neural Networks", *IEEE TR. on Neural Network*, Vol. 2, No. 3, pp. 334-345, (1991)
3. Dong C. Park and Yan Zhu, "BiLinear Recurrent Neural Network", *IEEE Int. Conf. on Neural Networks*, *ICNN-94* vol. 3, pp 1459-1464, (1994)
4. Y. Shin, et.al.; "The pi-sigma network: An efficient higher-order neural network for pattern classification and function approximation", *IEEE on Communication Neural Network*, 1-13-I-19, (1991)
5. R. Asim; "A Polynomial Time Algorithm for Construction and Training of a Class of Multilayer Perceptrons", *Neural Networks*, Vol. 6, No. 4, pp. 535-538, (1993)
6. F.J. Pineda; "Generalization of backpropagation to recurrent and higher order neural networks", *Neural Information Processing Systems*, Dana Anderson, ed. *American Institute of Physics*, pp. 602-661, (1988)
7. J. Connor, R. Martin, and L. Atlas; "Recurrent Neural Networks and Robust Time Series Prediction", *IEEE Tr. on Neural Networks*, vol. 5, No. 2, pp. 240-254, March(1994)