

지역별 증장기 강수량 예측을 위한 신경망 기법*

김호준¹ · 백희정² · 권원태³

A Neural Network for Long-Term Forecast of Regional Precipitation*

Ho-Joon Kim¹ · Hee-Jeong Paek² · Won-Tae Kwon³

요 약

본 논문에서는 한반도의 지역별 강수량 예측을 위한 신경망 기법을 소개한다. 시계열 패턴 예측 문제에 적용될 수 있는 기존의 다양한 신경망 모델의 특성을 분석하고 이로부터 강수량 예측 문제에 적합한 모델 및 학습 알고리즘을 제시한다. 본 논문에서 제시하는 모델은 계층적구조의 신경망으로 각 노드의 출력값은 일정기간동안 버퍼에 저장되어 상위계층에 입력으로 작용한다. 본 연구에서는 제안된 모델에 대하여 이중연결형태의 시냅스 구조를 채택하고, 이에 대한 네트워크의 동작특성과 학습알고리즘 등을 정의한다. 이러한 이중연결구조는 기존의 다층퍼셉트론에서 바이어스 노드의 역할을 담당하며, 노드가 갖는 특징들간의 관계를 효과적으로 반영함으로써 기존의 전형적인 시계열 예측 신경망인 FIR(Finite Impulse Response) 네트워크와 비교할 때 학습의 효율을 개선시킨다. 제시된 이론은 월별 및 계절별 강수량 예측 실험에 적용하였다. 신경망 예측기의 학습자료로서 과거 수십년동안 관측된 강수량 데이터와 해수표면온도 데이터를 사용하며 예측 실험결과로부터 제시된 이론의 타당성을 고찰한다.

주요어: 신경망, 시계열 예측, 기상 예보

ABSTRACT

In this paper, a neural network approach to forecast Korean regional precipitation is presented. We first analyze the characteristics of the conventional models for time series prediction, and then propose a new model and its learning method for the precipitation forecast. The proposed model is a layered network in which the outputs of a layer are buffered within a given period time and then fed fully connected to the upper layer. This study adopted the dual connections between two layers for the model. The network behavior and learning algorithm for the model are also described. The dual connection structure plays the role of the bias of the ordinary Multi-Layer Perceptron(MLP), and

1999년 8월 20일 접수 Received on August 20, 1999

* 이 연구는 과학기술부에서 시행하는 중점국가 연구개발사업의 하나인 자연재해방재기술개발사업으로 수행되었음.

1 한동대학교 전산전자공학부 (hjkim@han.ac.kr) School of CS and EE, Handong Univ.

2 기상청 기상연구소 예보연구실 Forecast Research Lab. METRI, KMA

3 기상청 기상연구소 수문기상연구실 Hydrometeorology Research Lab. METRI, KMA

reflects the relationships among the features effectively. From these advantageous features, the model provides the learning efficiency in comparison with the FIR network, which is the most popular model for time series prediction. We have applied the model to the monthly and seasonal forecast of precipitation. The precipitation data and SST(Sea Surface Temperature) data for several decades are used as the learning pattern for the neural network predictor. The experimental results have shown the validity of the proposed model.

KEYWORDS: Neural Network, Time Series Prediction, Weather Forecast

서 론

비선형 시계열 데이터 예측 문제에서 기존의 전통적인 방법에 대한 대안으로 신경망 이론을 사용할 수 있음이 알려진 바 있다. 그러나 기존의 일반적인 신경망모델의 구조적 특성은 시간에 따라 변하는 각종 패턴의 예측문제에 직접적으로 적용하기에 적합하지가 않다. 따라서 시계열 예측분야의 실질적 응용문제에 적용할 수 있는 신경망 예측기의 구현을 위해서 좀 더 개선된 형태의 모델 및 학습방법에 관한 연구가 필요하다. 이에 시계열 데이터 예측에 적용할 수 있는 몇가지 신경망 모델들이 제안된 바 있는데 그 예로 TDNN(Time Delayed Neural Network), 순환구조 신경망(recurrent neural networks) 등을 들 수 있다(Connor 등, 1994). 또한 Aussem등(1995)은 기상학이나 천문학에서의 시계열 예측 문제를 위한 동적 순환구조의 신경망 모델을 제안한 바 있다. 이 외에 시계열 예측 신경망에서 학습 과정의 복잡성과 정확도 개선을 위해 계산량이 증가하는 문제를 해결하기 위한 연구가 발표되었으며(Hsu 등 1993), 시계열의 분류를 위하여 비선형 예측기 모듈과, Bayesian 또는 비확률적 결정 규칙을 적용하는 모듈로 이루어지는 모듈구조의 신경망 모델이 제안된 바 있다(Kehagias와 Petridis, 1997). FIR network는 신경망의 시냅스를 FIR 선형 필터로서 모델링한 신경망으로 시계열 예측문제에 전형적으로 사용되는 모델이다(Wan, 1996). 본 연구에서는 기존의 FIR 네트워크가 갖는 시간 지연 효과의 구조와 더불어 노드간에 이중연

결형태의 시냅스 구조를 채택하고, 이에 대한 활성화 특성과 학습알고리즘 등을 정의한다.

본 연구에서 제시하는 신경망 모델은 기존의 FIR network에서 각 노드간에 연결형태를 이중연결구조를 취하도록 하여 학습과정에서 성능과 효율의 개선을 시도하였다. 이중연결구조의 역할에 관해서는 저자의 이전 연구(Kim과 Yang, 1994)에서 발표된 바 있는데 이는 기존의 다층퍼셉트론(MLP:Multi-Layer Perceptron)에서 바이어스 노드가 갖는 역할을 대신할 뿐만 아니라 노드가 갖는 특징들간의 관계를 효과적으로 반영하여 학습의 효율과 성능의 개선을 기대할 수 있게 한다. 또한 이들 특징간의 관계로부터 지식표현을 생성, 수용할 수 있음으로써 규칙기반형태의 지식과 신경망의 학습효과를 상호 결합할 수 있는 가능성을 제공한다. 본 연구에서는 제시된 모델을 사용한 실험 결과를 기존의 FIR 네트워크를 사용한 경우와 학습 효율 및 성능을 비교함으로써 그 유용성을 고찰한다. 실험은 한반도 지역별 중장기 강수량 예측문제를 대상으로 하였다.

신경망을 이용한 강수량 예측 시스템에서 또 다른 고려사항은 데이터 처리기법이다. 강수량 예측문제에 필요한 기상데이터의 형태는 그 종류가 다양하고 자료가 양적으로 매우 방대할 뿐만 아니라 지역 또는 시점에 따라 일부 자료가 왜곡될 수 있다. 그러므로 관측된 각종 기상 자료를 신경망의 입력에 적합한 형태로 변환하기 위하여 일련의 정규화 과정을 거쳐야 하며, 방대한 양의 데이터를 감축하는 방법 및 왜곡에 둔감한 데이터 처리기법 등이 구현되어야 한다.

본 연구에서는 이들 각각에 대한 방법론을 구현하고 실제 실험에 적용하였다.

시계열 예측 신경망

1. 제안된 신경망의 구조 및 동작특성

신경망의 응용에서 가장 일반적으로 사용되는 모델인 다층퍼셉트론(MLP)의 경우 입력 신호의 집합에서 출력신호로의 복잡한 형태의 매핑을 수행하지만, 이는 시간의 흐름이 고려되지 않은 뉴런들의 정적인 매핑이다. 이러한 다층퍼셉트론의 특성을 보완하여 뉴런 내부에 동적인 특성을 추가한 것이 FIR 네트워크이다 (Wan, 1996). 이것은 각각의 기본 뉴런을 일종의 FIR 필터로 바꾸어 줌으로써 이루어진다. 본 연구에서 대상으로 하는 강수량 예측 시스템은 그림 1과 같은 구조의 신경망 모델을 기반으로 한다. 모델의 특성을 설명하기 위해 다음과 같은 표기를 정의한다.

- $x_j(k)$: j번째 노드에 대한 k시점의 값
- $w_{ij}(k)$: 노드 i와 j간의 k시점의 가중치
- T : 시간 지연 효과를 반영하는 범위 (과거 T개의 시점을 고려)

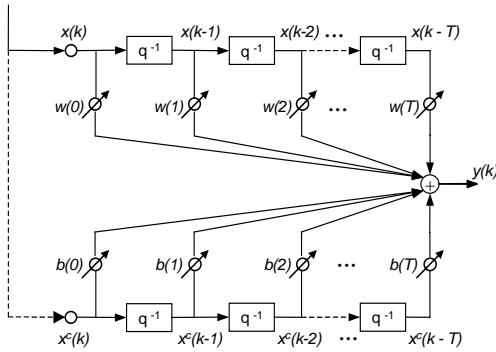


FIGURE 1. A neural network architecture for time series prediction

그림에 보인 바와 같이 노드간에 두 가지 형태의 연결구조로부터 서로 다른 가중치

(weight)가 반영되어 상위 노드로의 입력이 결정된다. 이를 위하여 $x_j^c(k)$ 와 $b_{ij}(k)$ 의 표기를 추가로 정의한다. $x_j^c(k)$ 은 $x_j(k)$ 에 대한 보수값으로서 신경망의 활성화 특성이 단극성(unipolar)인가 또는 양극성(bipolar)인가에 따라 다음과 같이 정의될 수 있는데, 본 연구에서는 단극성의 특성만을 고려한다.

$$x_j^c(k) = \begin{cases} 1 - x_j(k) & : \text{unipolar} \\ -x_j(k) & : \text{bipolar} \end{cases} \quad (1)$$

그리고 $b_{ij}(k)$ 는 $x_j^c(k)$ 와 연관된 가중치 값을 의미한다. 즉 제안된 모델은 그림 1에 보인 바와 같이 FIR 네트워크가 갖는 시간지연 요소를 반영할 뿐 만 아니라 두 종류의 연결구조로서 상하위 노드에 해당되는 특징들간의 관계를 보다 효과적으로 반영한다. 제안된 모델에서 각 노드의 활성화 특성은 다음 식으로 정의된다.

$$x_j(k) = f\left(\sum_i \mathbf{w}_{ij} \cdot \mathbf{x}_i(k) + \sum_i \mathbf{b}_{ij} \cdot \mathbf{x}_i^c(k)\right) \quad (2)$$

여기서 \mathbf{w}_{ij} , $\mathbf{x}_i(k)$, \mathbf{b}_{ij} , 및 $\mathbf{x}_i^c(k)$ 는 벡터 표현으로 다음과 같이 정의된다.

$$\mathbf{w}_{ij} = [w_{ij}(0), w_{ij}(1), \dots, w_{ij}(T)] \quad (3)$$

$$\mathbf{x}_i(k) = [x_i(k), x_i(k-1), \dots, x_i(k-T)] \quad (4)$$

$$\mathbf{b}_{ij} = [b_{ij}(0), b_{ij}(1), \dots, b_{ij}(T)] \quad (5)$$

$$\begin{aligned} \mathbf{x}_i^c(k) &= [x_i^c(k), x_i^c(k-1), \dots, x_i^c(k-T)] \\ &= [1 - x_i(k), 1 - x_i(k-1), \dots, 1 - x_i(k-T)] \end{aligned} \quad (6)$$

다시 말해서 노드의 활성화 특성을 표현한 식(2)는 다음과 같이 재정의 될 수 있다.

$$\begin{aligned} x_j(k) &= f\left(\sum_{i=0}^N \sum_{m=0}^T w_{ij}(m) x_i(k-m) + \right. \\ &\quad \left. \sum_{i=0}^N \sum_{m=0}^T b_{ij}(m) x_i^c(k-m)\right) \end{aligned} \quad (7)$$

여기서 함수 f 신경망의 활성화 함수(activation

function)로서 다음과 같은 sigmoid 함수를 사용한다.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

식에서 알수 있듯이 제안된 신경망에서 하위노드의 활성화정도와 비활성화정도에 따라 각각 서로 다른 가중치가 결합되어 상위노드의 활성화에 반영된다. 식(7)에서 만약 $x_j(k)$ 가 모든 j 및 k 에 대하여 0이라면 남은 성분은 $T \cdot \sum b_{ij}$ 가 된다. 이는 다층퍼셉트론에서 바이어스(bias)에 해당되는 값(Rumelhart 등, 1988)으로, 각 노드에 분산된 가중치의 형태로 표현됨을 알 수 있다.

2. 학습 알고리즘

본 절에서는 앞 절의 식 (2),(7),(8)로서 정의되는 활성화 특성으로부터 신경망의 학습 알고리즘을 정의한다. 일반화된 델타법칙(generalized delta rule)을 적용하기 위하여 시점 k 에서 임의의 노드 j 에 대한 기대출력값(desired output)과 실제출력값(actual output)을 각각 $t_j(k)$ 및 $z_j(k)$ 로 표기하고, 다음 식과 같이 총 에러값을 $e^2(k)$ 로 표기하면 이로부터 모든 시점에 대해 고려한 에러값 E 를 정의할 수 있다.

$$e^2(k) = \| t_j(k) - z_j(k) \|^2 \quad (9)$$

$$E = \sum_{k=0}^K e^2(k) \quad (10)$$

노드 j 의 활성화 함수에 대한 입력값을 식(11)과 같이 편이상 s_j 라 정의하면 학습 단계에서 가중치 벡터 $\mathbf{w}_{ij}(k)$ 에 가해질 변화분 $\Delta \mathbf{w}_{ij}(k)$ 은 식(12)로 정해진다.

$$s_j(k) = \sum_i \mathbf{w}_{ij} \cdot \mathbf{x}_i(k) + \sum_i \mathbf{b}_{ij} \cdot \mathbf{x}_i^c(k) \quad (11)$$

$$\begin{aligned} \Delta \mathbf{w}_{ij}(k) &= -\eta \frac{\partial E}{\partial s_j(k)} \cdot \frac{\partial s_j(k)}{\partial \mathbf{w}_{ij}(k)} \\ &= -\eta \delta_j(k) \cdot \mathbf{x}_i(k) \end{aligned} \quad (12)$$

여기서 $\delta_j(k)$ 는 다음과 같이 노드 j 가 중간노드인 경우와 출력노드인 경우가 서로 다르게 정의된다.

$$\delta_j(k) = \begin{cases} -2e_j(k) f'(s_j(k)) & : \text{출력노드} \\ f'(s_j(k)) \cdot \sum_m \delta_m(k) \cdot (\mathbf{w}_{jm}(k) - \mathbf{b}_{jm}(k)) & : \text{중간노드} \end{cases} \quad (13)$$

위 식에서 $f'()$ 은 식(8)과 같이 주어지는 활성화함수, 즉 여기서는 sigmoid 함수의 미분이며, 상수 η 는 학습률(learning rate)로서 양의 상수이다. 같은 방법으로 가중치 벡터 $\mathbf{b}_{ij}(k)$ 에 가해질 변화분 $\Delta \mathbf{b}_{ij}(k)$ 은 식(14)로 정해진다.

$$\Delta \mathbf{b}_{ij}(k) = -\eta \delta_j(k) \cdot \mathbf{x}_i^c(k) \quad (14)$$

강수량 예측을 위한 학습 자료 생성

기상정보 예측 문제에서 관측된 데이터의 값은 매우 다양한 형태로 나타난다. 때문에 이들이 신경망 예측기의 입력이 되기 위해서 적절한 전처리 과정이 필요하게 된다. 앞 절에서 설명한 바와 같이 본 연구에서 대상으로 하는 신경망 모델의 특성을 고려하여 데이터의 종류와 대상 범위를 결정하고, 정규화 과정 등의 전처리 방법론을 적용한다. 본 연구의 실험은 한반도의 지역별로 월별 및 계절별 강수량 예측 문제를 대상으로 하였다. 이를 위한 학습데이터는 일차적으로 지역에 따라 현시점기준 최고 80년에서 최저 40년동안의 월별로 관측된 자료값을 사용하였다.

학습데이터 집합의 크기는 신경망 모델의 구조에서 입력노드의 수와 연관되어 결정된다. 학습데이터 집합은 자료의 종류별로 일정 시간범위 창(window)의 크기를 매개변수로 설정하여 이를 예측규모 단위로 중첩 이동시킴으로써 학습을 위한 입력패턴과 기대출력값을 결정한다. 예를 들어 학습자료로 선택된 기상자료의 종류가 n 개의 값으로 이루어진 시계열 데이터를 $S = (s_1, s_2, s_3, \dots, s_n)$ 이라 하고 학습패

턴 설정을 위한 창 크기를 W 라 할 때 학습 패턴 $P = (p_1, p_2, \dots, p_{n-w})$, 즉 $(n-W)$ 개의 학습 패턴이 결정된다. 다시 말해서 i 번째 학습 패턴 p_i 에 대하여 입력패턴의 내용은 $(s_i, s_{i+1}, \dots, s_{i+W})$ 로 결정되고 이에 대한 기대 출력값은 s_{i+W} 이 된다.

이는 예측범위가 관측주기와 일치하는 경우에 가장 자연스럽게 적용할 수 있다. 그러나 관측주기보다 긴 범위의 예측을 위해서는 인식과정을 위한 신경망 동작특성의 변형이 필요하다. 그에 대한 한가지 방법으로 예측결과 값을 다음 단계의 예측을 위한 입력 데이터로 다시 활용하도록 하는 방법을 채택하였다. 다시 말해서 출력값은 일정크기의 버퍼에 저장되고 이 버퍼는 신경망의 입력자료로서 활용된다. 이 때 버퍼는 학습에 사용한 입력패턴의 시간단위와 비교한 예측주기의 비율에 의해 크기가 결정된다. 이러한 버퍼의 크기는 앞서의 학습패턴 생성을 위한 창 크기와 더불어 신경망 학습을 위한 중요 파라미터로 설정된다. 본 연구에서는 이와 같이 학습과정에서 데이터의 종류, 범위 및 신경망의 구조에서 입력 및 출력 노드 수, 버퍼의 크기 등을 매개변수로 설정하고 여러회의 반복실험을 통하여 적절한 값을 찾아내도록 하였다.

시계열 형태로 표현된 기상데이터가 제안된 신경망 모델의 학습이나 예측을 위한 입력 신호가 되도록 하기 위하여, 관측된 원시 데이터는 신경망의 특성에 적합한 형태로 정규화 과정을 거쳐야 한다. 본 연구에서는 0과 1사이의 값을 수용하는 신경망을 고려하였으며, 이를 위하여 관측된 데이터에 대하여 다음과 같은 식으로 정규화 하였다. 앞서의 경우처럼 n 회에 걸쳐 일정 주기로 관측된 자료를 $S = (s_1, s_2, s_3, \dots, s_n)$ 라 하고, 관측된 값에서 최대 및 최소값을 각각 s_{\max} 및 s_{\min} 이라 할 때 임의의 시점에서 관측값 s_i 에 대하여 신경망 입력을 위해 산출되는 값 x_i 는 다음 식으로 정해진다.

$$x_i = \frac{s_i - s_{\min}}{s_{\max} - s_{\min}} \quad (15)$$

즉 관측된 값은 0과 1사이의 범위로 선형 매핑되는데, 이는 일정 기간 동안의 최대 및 최소치의 범위 내에서 정규화한 값이다. 이들은 대상기간이 달라질 때마다 값이 재적용되며 이들 값은 각 학습 과정 및 예측단계에서 동적으로 변화하여 적용된다.

또한 신경망의 출력값으로부터 예측 강수량의 값을 산출하는 과정은 위의 식을 역으로 적용하면 된다. 즉 신경망의 수행에 의해 결정된 출력값이 y_j 라면 이에 해당하는 예측값 s_j 는 다음과 같이 위의 식을 역적용함으로써 산출된다.

$$s_j = y_j \cdot (s_{\max} - s_{\min}) + s_{\min} \quad (16)$$

이러한 내용은 한반도의 지역별로 관측된 강수량이나 기온의 변화 등 몇몇 기상 데이터에 공통적으로 적용될 수 있다. 그런데 실제 강수량의 예측문제에서 성능에 영향을 주는 요인으로 자료의 표현이나 예측의 방법론의 측면도 매우 중요하지만 궁극적으로 그 데이터가 표현하는 정보의 한계로 인해 일정 수준 이상의 성능향상이 불가능할 수도 있다. 이러한 점에서 다양한 종류의 가상 데이터를 신경망예측기의 학습자료로 활용하는 방안에 대한 검토가 필요하다. 이에 본 연구에서는 별도의 학습자료로서 태평양의 해수표면온도(SST)의 관측치를 사용하는 방법을 고려하였다. 이는 매우 방대한 양의 자료로서 원시데이터의 상태로 신경망에 직접 적용하는 것은 불가능하다. 따라서 이러한 특성을 보완하여 신경망의 학습데이터로서 효과적으로 활용하는 방안을 연구하였다. 본 연구에서는 SST 데이터의 양을 감축하는 방법과 이를 앞의 내용과 같은 형태의 데이터, 즉 강수량 또는 기온 데이터를 정규화한 형태와 병행하여 사용할 수 있는 방법론을 제시하였다. 우선 SST 데이터에 대하여 관측지점별로 장기적 및 단기적인 값의 변

화와 분포를 분석하여 유사성을 기준으로 그룹화하고 각 그룹에 대한 평균치로서 대표값을 취하여 전체 영역을 분할(segmentation)하였다. 이러한 공간적 분할방식에서 분할의 크기나 형태는 관측값의 분포와 특성에 따라 다양하게 나타나며 분할의 평균 크기는 궁극적으로 신경망 입력이 되는 자료의 양을 결정하게 된다. 그러므로 분할에 사용되는 각종 상수값을 시스템의 매개변수로 채택하여 적응적으로 조정할 수 있게 하였다.

이와 같이 공간적 분할이 결정되면 각 분할에 대하여 관측값의 시간적 변화를 관찰하여 데이터의 표현을 생성한다. 즉 단순히 데이터의 수치값에 의존하는 것이 아니라 변화의 추이 즉 '상승', '하강' 등의 정보로서 표현한다. 또한 공간적 정보와 시간적 정보를 조합하여 종합적인 추이와 공간적 이동에 관한 정보를 생성한다.

요약하면 수치형태로 표현된 최초의 SST 자료값의 형태는 신경망의 입력이 되기 위하여 시간적, 공간적 변화를 의미하는 정보로서 표현이 단순화되고 그 양이 현격하게 감축되어 신경망의 입력으로 사용될 수 있게 한다. 이 과정에서 최초자료가 갖는 유용한 정보의 소실을 최대한 보완하기 위하여 정보생성과정에 사용되는 각종 상수값들을 시스템의 매개변수화하여 실험적으로 최적화할 수 있게 한다.

강수량 예측 실험결과 및 고찰

앞 절까지 기술한 각 이론들을 적용하여 한반도 지역별 강수량 예측 실험을 수행하였다. 실험은 크게 두가지 방향에서 시도하였다. 첫 번째는 강수량 예측 성능에 초점을 둔 실험으로 한반도의 지역별, 월별, 계절별 강수량 예측문제에 제시된 모델을 적용하고, 최적의 성능을 위한 데이터 처리기법의 개선, 매개변수의 조정을 시도하였다. 이어서 두 번째 실험은 제시된 모델의 유용성 평가를 위한 실험으

로 동일환경에서 학습 효과와 성능을 FIR 네트워크를 사용한 경우와 비교하였다.

학습에 사용한 데이터는 지역별로 관측된 과거 강수량 데이터를 기본으로 하였는데 대상지역을 중심으로 영역범위를 조정하여 인접지역을 포함하도록 하였다. 이와 더불어 SST 데이터로부터 신경망 입력을 학습자료를 생성하여 사용하였다. 강수량 데이터로부터 학습자료를 생성하기 위한 시간범위 창의 크기는 20년으로 하였으며 영역범위는 두 종류를 이중으로 적용하여 자료를 생성하였다. 실험에 사용된 신경망은 총 3개의 계층구조를 가지며 각 신호 및 중간 노드에 대하여 시간지연 유닛의 수를 5개로 하였다. 신경망은 총 84개의 입력노드와 120개 및 80개의 중간노드로 구성하였다.

또한 일년을 기준으로 월별 및 계절별 예측을 위하여 각각 12개 및 4개의 출력노드를 갖는 경우를 별도로 학습하여 가중치 집합을 생성하고 각각의 예측실험을 수행하였다. 학습률과 초기가중치 등의 매개변수는 반복학습을 통하여 적정값으로 조정하였다. 그림 2와 그림 3은 이러한 모델을 적용한 예측 실험 결과의 예로서 1998년 서울지역의 월별 강수량에 대한 예측값과 실제값의 비교이다. 여기서 보인 결과는 보다 객관적인 평가를 위하여 서로 다른 가중치 초기값으로부터 실험한 20회의 결과값에 대하여 평균을 취한 값이다.

그림 2는 동일 환경에 대하여 FIR 네트워크를 사용한 결과이고 그림 3은 본 연구에서 제시한 신경망을 사용한 실험 결과이다. 두 경우 모두 동일한 구조로서 구성하였으며 각종 매개변수를 동일한 값으로 설정하였다. 그림에서 알 수 있듯이 월별 예측실험에 대하여 기존의 FIR 네트워크 모델의 성능에 근사하거나 다소 나은 결과를 보였다. 그림 4와 그림 5는 서울지역 계절별 강수량 예측실험의 결과 비교로서 월별 예측실험의 결과와 유사한 성능을 보였다.

본 연구의 주 초점중의 하나는 기존의 모델과 비교한 학습의 효율개선이다. 제안된 모델은 노드간의 이중연결구조가 특징들간의 관계를 효과적으로 반영하여 상대적으로 적은

횟수의 반복으로 수렴됨을 보였다. 그림 6은 FIR 네트워크의 경우와 학습속도를 비교한 그래프로서 아래쪽 곡선이 제안된 모델을 사용한 결과이다. 그림에서 알 수 있듯이 동일 구




FIGURE 2. The graph representation of monthly precipitation forecast using the FIR networks




FIGURE 3. The graph representation of monthly precipitation forecast using the proposed model




FIGURE 4. The graph representation of seasonal precipitation forecast using the FIR networks
 조를 갖는 기존의 FIR네트워크에 비해 보다 효율적인 학습이 이루어 짐을 알 수 있다.




FIGURE 5. The graph representation of seasonal precipitation forecast using the proposed model

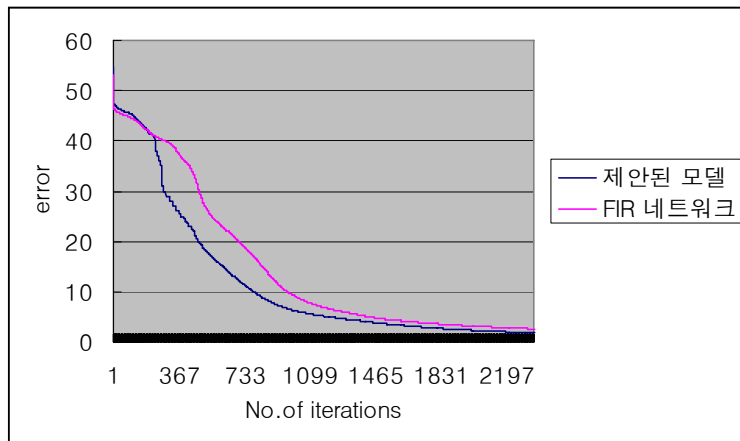


FIGURE 6. Learning speed comparison with the FIR networks

결론

강수량 예측문제를 위한 신경망 기법으로서 본 연구에서 제시한 신경망 모델의 특징은 시계열 예측을 위한 시간지연요소와 노드들 간의 이중연결구조이다. 이는 강수량 예측에 사용되는 대부분의 데이터가 시계열 형태를 갖는다는 점에서 유용하며, 이중연결로서 모델링한 시냅스의 구조는 특징들간의 관계를 보다 효과적으로 반영하여 학습의 효율을 개선시킨다.

한반도 지역별 중장기 강수량 예측 실험의 결과는 제안된 모델이 기존의 전형적인 시계열 예측 신경망인 FIR 네트워크에 비교해 동등 또는 다수 우수한 성능을 가지며 학습효율의 측면에서는 현격하게 성능을 개선시킬 수 있음을 보였다.

그러나 월별 예측실험의 결과에서는 오차의 편차가 많아 실용적 기상 예측 시스템 구현의 측면에서는 문제점으로 지적되었다. 이는 기상 예측시스템에 대한 방법론으로서 제안된 신경망 예측기만을 전적으로 사용하기에는 아

직 부족함을 시사한다. 이는 이변성 기상 등의 예측에서 특히 미흡한 성능을 보이는데 이러한 점은 신경망의 구조적 특성이나 학습방법 뿐만 아니라 학습에 사용한 데이터의 양과 질에 지대한 영향을 받는다. 따라서 이러한 모델이 보다 유용하게 사용되기 위해서는 다양한 종류의 기상 데이터로부터 보다 효과적으로 정보를 추출하여 신경망의 학습에 적용하는 기술의 연구가 병행되어야 한다. 구체적으로 자료분석기술, 자료처리방법, 학습데이터 표현 방법 등의 연구가 이루어지면 제시된 모델로서 좀더 나은 성능을 갖는 시스템 구현이 가능할 것으로 기대된다. **KAGIS**

참고문헌

- Andreas S. W. M. Mangeas and A. N. Srivastava. 1995. Nonlinear gated experts for time series: Discovering regimes and avoiding overfitting. *International Journal of Neural System* 6(4): 373-399
- Aussem, A., F. Murtagh and M. Sarazin. 1995. Dynamical Recurrent Neural Networks—Towards Environmental Time Series Prediction. *International Journal of Neural*

- System 6(2):145-170.
- Badran, F. and S. Thiria. 1997. Neural network smoothing in correlated time series context. *Neural Networks* 10(8):1445-1453.
- Cohen, B., D. Saad and E. Marom. 1997. Efficient training of recurrent neural network with time delays. *Neural Networks* 10(1): 51-59.
- Connor, J.T., R.D. Martin and L.E. Atlas. 1994. Recurrent Neural Networks and Robust Time Series Prediction. *IEEE Transaction on Neural Networks* 5(2)
- Craven, M. W. and J. W. Shavlik. 1997. Understanding Time series networks: A case study in rule extraction. *International Journal of Neural System* 8(4):373-384.
- Deco, G., R. Neuneier and B. Schurmann. 1997. Non-parametric data selection for neural learning in nonstationary time series. *Neural Networks* 10(3):401-407.
- Ginzberg, I. and D. Horn. 1992. Learning the rule of time series. *International Journal of Neural Systems* 3(2):167-177.
- Hsu, W., L.S. Hsu and M.F. Tenorio. 1993. The ClusNet Algorithm and Time Series Prediction. *International Journal of Neural Systems* 4(3):247-255.
- Kehagias, A. and V. Petridis. 1997. Predictive modular neural networks for time series classification. *Neural Networks* 10(1):31-49.
- Kim, H. J. and H. S. Yang. 1994. A neural network capable of learning and inferencing for visual pattern recognition. *Pattern Recognition* 27(10):1291-1302.
- Matsumoto, T., H. Hamagishi and Y. Chonan. 1997. A hierarchical bayes approach to nonlinear time series prediction with neural nets. *Proceeding of IJCNN-97:2028-2033.*
- Rumelhart, D.E., J. L. McClelland and PDP Research Group. 1988. *Parallel Distributed Processing*, MIT Press, Cambridge.
- Wan, E. A. 1996. Time series prediction by using a connectionist network with internal delay lines. *Time Series Prediction:195-217.*
- Wang, Z.S., Y.S. Xia, W.H. Li, Z.Y. He and J. D. Z. Chen. 1997. A neural network solver for basis pursuit and its application to time-frequency analysis of biomedical signals. *Proceeding of IJCNN-97:2057-2060.*
- Yu, H. Y. and S. Y. Bang. 1997. An improved time series prediction by applying the layer-by-layer learning method to FIR neural networks. *Neural networks* 10(9):1717-1729. 