

神經網理論에 의한 降雨豫測에 관한 研究 A Study on Rainfall Prediction by Neural Network

오 남 선* · 선 우 중 호**
Oh, Nam Son · Sonu, Jungho

Abstract

The neural network is a mathematical model of theorized brain activity which attempts to exploit the parallel local processing and distributed storage properties. The neural network is a good model to be applied for the classification problem, large combinatorial optimization and nonlinear mapping. A multi-layer neural network is constructed to predict rainfall. The network learns continuous-valued input and output data. Application of neural network to 1-hour real data in Seoul metropolitan area and the Soyang River basin shows slightly good predictions. Therefore, when good data is available, the neural network is expected to predict the complicated rainfall successfully.

요 지

신경망이론은 분산기억성질과 병렬국소처리를 수행하는 뇌의 활동을 이론화한 수학적 모형이다. 이러한 신경망이론의 장점은 분류문제, 대규모로 결합된 최적화문제, 비선형 사상문제 등에서 잘 나타나므로, 이 점을 이용하여 복잡한 강우의 예측을 시도하였다. 신경망이론을 적용하기 위해서 연속적인 값으로 표시되는 입력자료와 출력자료를 학습한 후 강우예측을 시행할 수 있는 다중신경망 모형을 구성하였다. 신경망이론에 의한 강우예측은 서울지역과 소양강유역의 1 시간 단위 강우자료에 적용하였다. 그 결과는 대체로 만족할 만하였다. 따라서 신경망이론은 양질의 자료가 충분히 확보될 경우 복잡한 강우현상을 잘 예측할 것으로 기대된다.

* 목포해양대학교 해양 및 조선공학부 전임강사
** 서울대학교 총장

1. 序 論

1.1 研究의 背景 및 目的

강우의 중요성과 복잡성, 유출에 미치는 영향 등으로 인하여 강우에 관한 연구는 1980년 이후 특히 활발하게 진행되었다. 이러한 연구의 주제는 강우발생의 물리적 현상에 대한 이해와 推計學的 降雨模型의 구조에 대한 강우동역학, 기상학, 물리학적인 구성형태의 결합 등에 관한 것이었다(Foufoula-Georgiou와 Georgakakos, 1991). 강우에 관한 연구는 급격하게 발전하였으며, 특히 최근에는 레이더자료와 위성자료를 이용한 물리적-추계학적 모형의 개발과 적용이 진행되었다(French 등, 1994a, 1994b; Seo와 Smith, 1992). 이들 모형은 대부분 Kalman filter 알고리즘을 이용하여 모형의 상태가 예측을 위한 최적상태로 계속적으로 갱신될 수 있도록 하고 있다. 그러나 우리 나라의 경우 신뢰성 있는 레이더자료와 위성자료의 부족으로 이들 자료를 이용한 연구가 어렵다. 또한 레이더자료는 수문분야에서 필요로 하는 자료와 특성의 차이가 있다(이종철 등, 1992). 반면에 신경망은 복잡한 시스템 등정과정 없이 학습에 의하여 연결강도를 조절함으로써 예측모형을 구성할 수 있다(김주환, 1993). 따라서 본 연구에서는 이러한 장점을 가진 신경망이론을 강우예측에 적용하고 그 장단점 및 적용가능성을 검토하고자 한다.

1.2 研究의 内容 및 範圖

神經網(Neural network)이론은 분산기억성질과 병렬국소처리(Parallel local processing)를 수행하는 것으로 생각되는 두뇌의 활동을 이론화한 수학적모형이다. 인간의 뇌는 고도의 분산된 변환에 의해 작동하고, 병렬처리를 하며, 수천의 상호연결된 신경에 의한 분산통제를 한다. 뉴런(Neuron)은 단순한 하나의 非線形界로서, 수억의 뉴런이 고도로 상호 연결되어 뇌나 신경계를 이루게 된다. 이를 수학적으로 모형화한 신경망이론은 정보

의 분산표시, 局所的 作動(Local operation), 비선형 처리 등을 특징으로 갖게 된다. 이러한 신경망이론의 장점은 분류문제(Classification problem), 대규모로 결합된 최적화문제, 복잡한 비선형 사상(Mapping)문제 등에서 잘 나타난다.

신경망에 대한 이론적인 개념은 1950년대에 이루어졌으나, 입력에서 출력으로의 사상을 학습하는 효과적인 훈련방법이 개발되지 않았다. 그러다가 1980년대 후반에 들어서 컴퓨터의 급속한 발달과 더불어 실질적인 학습방법이 개발되면서 활발한 연구와 적용이 다시 시작되었다. 이러한 신경망이론을 수문학에 도입하려는 시도는 최근에 시작되었으며, 국내외에 이를 적용한 연구가 있었다(French 등, 1992; Karunanthi 등, 1994; 김주환, 1993). 강우예측에 대하여 신경망이론을 이용하려는 시도는 국내에서는 없었으며, French 등(1992)이 2차원 강우장을 발생시킨 후 이에 신경망이론을 적용하였다.

본 연구에서는 신경망이론을 이용한 降雨豫測모형을 구성하고 서울지역과 소양강유역의 강우자료에 적용함으로써 그 예측능력과 적용가능성 등을 검토하고자 한다. 신경망의 학습(Learning)을 위해서 逆傳播(Back propagation) 알고리즘을 이용하였다. 역전파 알고리즘은 출력값과 기대값의 오차를 줄여 나가는 방향으로 연결강도(Interconnection weights)를 조정하고, 이는 다시 前 단계의 層(Layer)으로 역전파되며 다시 이를 근거로 연결강도를 조정해 나간다.

2. 本 論

2.1 研究動向

1960년대부터 강우현상을 설명하기 위한 활발한 연구가 진행되었고, 1980년대에 이르러서는 강우과정에 대한 이해와 강우의 예측에 관한 활발한 연구가 진행되었다. Foufoula-Georgiou와 Georgakakos(1991)에 의하면 강우에 관한 연구는 강우의 측정과 평가, 시간과 공간에 따른 강우모델링 및 강우량 예측의 세 가지 범주로 크게 분류되며, 이중 본 연구의 주요 내용인 강우량 예측

에 관한 연구동향을 살펴보면 다음과 같다.

French 등(1992)은 신경망이론을 강우예측에 적용하여 시간과 공간에 따른 강우량의 예측을 시도하였다. 신경망은 입력층(Input layer), 은닉층(Hidden layer), 출력층(Output layer)으로 구성하였으며, 학습을 위해서 역전파알고리즘을 이용하였다. 이 연구에서는 입력자료로 발생 강우를 이용하였으며 입출력함수로 단순하게 강우자료만을 이용하였다.

Seo와 Smith(1992)는 기상자료와 레이더자료를 이용하여 연직평균적분한 함수량의 질량보존을 고려하는 모형을 구성하였다. 모형을 통하여 예측된 함수량과 강우량의 관계는 경험식을 이용하여 구하였으며, 이를 통하여 短期 강우예측을 시행할 수 있도록 하였다.

French 등(1994a, 1994b)은 레이더자료, 위성자료 및 기상자료를 이용하여 강우량을 실시간 예측할 수 있는 이차원 모형을 구성하였다. 모형의 상태는 Kalman filter 알고리즘을 이용하여 예측을 위한 최적의 상태로 계속 갱신될 수 있도록 하였다.

2.2 神經網理論

2.2.1 概要

컴퓨터의 발달과 더불어 인간을 모방하여 인간과 같은 형태로 인식하고, 계산하며, 판단할 수 있도록 하려는 많은 시도가 있었다. 현재 고성능의 컴퓨터는 그 속도나 계산능력에 있어 인간의 능력으로는 상상도 못할 정도로 뛰어나다. 그러나 어떠한 물체나 사람의 얼굴 등을 구별하는데 있어서는 한 두 살의 어린이가 훨씬 빠르고 정확하다. 이와 같이 인간의 두뇌가 패턴인식, 의사결정 등에 있어 고성능의 컴퓨터보다 뛰어난 점에 착안하여 신경망이론과 같이 인간의 두뇌를 모방하고자 하는 연구가 진행되었다. 즉, 신경망에 대한 연구는 기존의 상용 컴퓨터와는 다른 새로운 정보처리기법을 이용하여 실제 두뇌의 사고과정을 모의하고자 하는 것에서 출발하였다.

2.2.2 神經網模型

신경망모형은 입력자료를 받아들이게 되는 입력층(Input layer)과 결과를 나타내는 출력층(Output layer)으로 구성되며 모형에 따라서 두개의 층 사이에 은닉층(Hidden layer)이 존재한다. 이들 층 사이에는 연결강도들이 존재하며 이 값들의 변화에 따라 입력에 따른 출력이 결정된다. 신경망에 있어서 연결강도는 임의의 초기값에서 시작하여 적절한 연결강도를 구하기 위하여 계속적이 개선이 이루어지게 되며 신경망에서는 이 과정을 學習(Learning)이라 한다.

신경망모형은 학습의 방법에 따라 指導學習(Supervised learning)모형과 自律學習(Unsupervised learning)모형으로 크게 나눌 수 있다. 지도학습에서 신경망은 출력값과 비교할 수 있는 既知의 정답이 존재하며, 그 오차를 이용하여 학습을 수행하게 된다. 이와 반대로 자율학습에서는 정답이 존재하지 않는다. 자율학습에서는 이용 가능한 정보로 입력자료를 또는 신호(Signal)만이 제공되며 신경망은 스스로 입력자료의 흥미 있는 범주나 특징을 발견해야만 한다. 따라서 자율학습모형은 정확한 정보없이 자기조직화에 의해 훈련을 하게 되고 결과를 출력하게 된다. 또한 신경망은 입력자료와 출력자료가 이진수(Binary)의 형태를 가지거나 실수형태의 연속적인 값으로 나타나는 두 가지로 보통 나누어진다.

본 연구에서는 학습을 위한 입력자료와 출력자료로 이용되는 강우자료가 실수형태의 연속적인 값으로 존재하며 이를 바탕으로 신경망을 구성하고자 한다. 또한 신경망의 학습은 既往의 자료를 이용하는 지도학습을 이용한다. 多層神經網모형은 입력층과 출력층 사이에 하나 이상의 은닉층이 존재하는 모형이다. 다층신경망모형은 실수형태의 자료에 대하여 지도학습을 실시할 수 있으며 비선형 함수를 모의할 수 있다. 따라서 본 연구에서는 강우예측을 위하여 다층신경망모형을 구성한다. 다층신경망모형에서 은닉층의 개수가 하나일 경우 二層神經網모형이라 하며 그 구조를 Fig. 1에 제시하였다.

그림에서 출력 성분들은 O_i , 은닉층의 성분들은 V_j , 그리고 입력층의 성분들은 ξ_k 로 나타내었다. 또한 입력층에서 은닉층으로의 연결강도와 은닉층에서 출력층으로의 연결강도는 각각 w_{jk} 와 W_{ij} 로 표

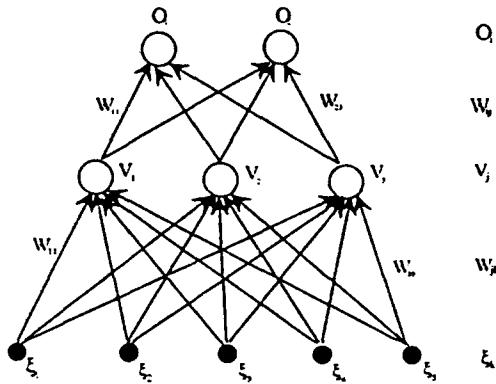


Fig. 1. Structure of Two-Layer Network

기하였다. 입력자료의 서로 다른 패턴을 위 첨자 μ 에 의하여 구분하면 번째 패턴의 입력자료 가운데 k 번째 성분은 ξ_k^μ 로 표기되며 이 경우 은닉층의 j 번째 성분으로의 입력 h_j^μ 는 식 (1)과 같이 계산 할 수 있다.

$$h_j^\mu = \sum_k w_{kj} \xi_k^\mu \quad (1)$$

그리고, 은닉층의 j 번째 성분 V_j^μ 은 傳達函數 (Transfer function) $g_1(x)$ 를 통하여 식 (2)와 같이 된다.

$$V_j^\mu = g_1(h_j^\mu) = g_1(\sum_k w_{kj} \xi_k^\mu) \quad (2)$$

같은 방법으로 출력층으로의 입력성분은 식 (3)과 같고, 이에 따른 출력성분은 전달함수 $g_2(x)$ 를 이용하면 식 (4)와 같아된다.

$$h_j^\mu = \sum_i W_{ij} V_j^\mu = \sum_i W_{ij} g_1(\sum_k w_{kj} \xi_k^\mu) \quad (3)$$

$$\begin{aligned} O_i^\mu &= g_2(h_i^\mu) = g_2(\sum_j W_{ij} V_j^\mu) \\ &= g_2(\sum_j W_{ij} g_1(\sum_k w_{kj} \xi_k^\mu)) \end{aligned} \quad (4)$$

결국, 식 (4)는 출력패턴 O_i^μ 과 입력패턴 ξ_k^μ 의 관계를 나타내는 신경망의 구조로서 이에 필요한 연결강도 w_{kj} 와 W_{ij} 를 기왕의 자료로부터 학습을 통하여 적절하게 조절하게 된다.

2.2.3 역전파 알고리즘

多層구조의 神經網은 뛰어난 적용성에도 불구하고 학습방법이 없어 활용되지 못하다가 1980년대 중반 역전파 알고리즘을 이용한 多層구조의 학습방법이 발표된 이후 이를 이용한 신경망에 관한 연구가 활성화되기 시작했다(Hertz 등, 1991). 역전파 알고리즘은 주어진 입력과 출력에 대한 적절한 연결강도를 구하기 위하여 費用函數(Cost function)를 정의하며 식 (5)는 주로 이용되는 비용함수의 형태이다.

$$E(W) = \frac{1}{2} \sum_i (\zeta_i^\mu - O_i^\mu)^2 \quad (5)$$

여기서 $E(W)$ 는 비용함수이고, ζ_i^μ 는 정확한 기대값이다.

역전파 알고리즘에서는 학습이 진행됨에 따라 정의된 비용함수가 0에 가까워지고 적절한 신경망이 완성되어 간다. 역전파 알고리즘은 이를 위하여 경사하강(Gradient decent) 알고리즘을 이용하며 이에 따른 연결강도들의 조정량은 각각 식 (6) 및 (8)과 같다.

$$\Delta W_{ij} = \eta \sum_i \delta_i^\mu V_j^\mu \quad (6)$$

여기서 η 는 學習率(Learning rate)이고, δ_i^μ 는 전달함수의 미분형태와 오차의 곱으로 식 (7)과 같다.

$$\delta_i'' = g'(h_i'') [\zeta_i'' - O_i''] \quad (7)$$

$$\Delta w_k = \eta \sum_{\mu} \delta_j'' \xi_k \quad (8)$$

여기서,

$$\delta_j'' = g'(h_j'') W_k \delta_i'' \quad (9)$$

식 (9)에서 입력층과 은닉층사이의 연결강도 조절에 필요한 δ 를 계산하기 위하여 출력층 O_i 로부터 계산된 δ 값들이 필요하다. 즉, 입력신호가 신경망 내에서 입력층으로부터 출력층으로 전파해 가는데 비해 오차의 값들은 역방향으로 전파해 나가기 때문에 식 (6)과 (8)에 근거하여 신경망의 연결강도를 조절해 나가는 방법을 역전파 알고리즘이라 한다.

2.3 강우예측모형의 구성

본 연구에서는 강우예측을 위한 입력층과 출력층의 성분으로 강우자료가 이용되며 이는 실수형태의 연속적인 값이다. 따라서 신경망을 이용한 강우예측을 위하여 다층신경망 모형을 이용한다. 그리고 다층신경망의 구조는 기존의 연구에서 주로 이용한 것과 같이 입력층과 출력층 사이에 하나의 은닉층이 존재하는 이층신경망을 이용한다(French 등, 1992; 김주환, 1993). 신경망 구조에 적절한 은닉층 성분의 개수를 결정하는 일반적 방법은 없으며 이에 대한 연구가 활발히 진행중이다(Hertz 등, 1991). 따라서 French 등(1992)이 연구한 바와 같이 여러 형태의 신경망구조를 설정하고 이를 적용한 후, 그 결과로부터 적절한 신경망의 구조를 설정하는 방법이 주로 이용된다. 본 연구에서는 적절한 은닉층 성분의 개수를 결정하기 위하여 입력층 성분의 개수가 N 이라 할 때 적용지역에 따라 은닉층 성분의 개수를 각각 N 개에서 $8N$ 개까지 변화시켜 가며 적용한 후 그 결과를 분석하고자 한다.

본 연구에서는 신경망모형의 구성을 위한 입력층과 출력층의 값으로 각 강우관측소에서의 강우자료를 이용하기로 한다. 즉 현재의 강우량이 선행시간의 강우량과 관련이 있는 것으로 가정하여 선행시간의 강우자료로 입력층을 구성하고 현재의 강우자료를 출력층으로 구성한다. 모형의 구성은 입력층을 선행 1시간의 강우자료로 구성하는 모형 I과 선행 1시간과 2시간의 강우자료로 구성하는 모형 II의 두 가지 형태로 한다. 이와 같이 구성된 강우예측모형의 입출력과정을 두 개의 전달함수를 이용하여 표기하면 식 (10)과 같다.

$$O_i'' = g_2(\sum_j W_{ij} g_1(\sum_k w_{jk} \xi_k'')) \quad (10)$$

여기서 $g_1(\cdot)$ 은 입력층에서 은닉층으로의 전달함수이며 $g_2(\cdot)$ 은 은닉층에서 출력층으로의 전달함수이다. 모형에서 출력층의 성분 O_i'' 는 예측하고자 하는 시간단계 t 에서 i 번째 강우관측소의 강우강도가 된다. 그리고 모형 I에서는 입력층의 성분 ξ_k'' 가 선행시간에 해당하는 시간단계 $t-1$ 에서의 k 번째 강우관측소의 강우강도로 구성되며, 모형 II에서는 선행 한 단계와 두 단계에 해당하는 시간단계 $t-1$ 과 $t-2$ 에서의 강우강도로 구성된다.

식 (10)의 신경망모형을 적용하기 위해서 전달함수의 선정이 필요하다. 이층신경망모형에서는 French 등(1992)이 이용한 것과 같이 입력층에서 은닉층으로의 전달함수로 log-sigmoid 함수를 주로 이용하며 은닉층에서 출력층으로의 전달함수로 선형함수를 주로 이용한다. 따라서 본 연구에서도 log-sigmoid 함수와 선형함수를 각각 이용하기로 하며 이를 수식으로 나타내면 다음과 같다.

$$g_1(h) = \frac{1}{1 + \exp(-h)} \quad (11)$$

$$g_2(h) = h \quad (12)$$

이 때 은닉층으로부터 출력층으로의 전달함수로 식 (12)의 선형함수를 이용하기 때문에 작은 값의

음의 강우강도가 예측될 수 있다. 때문에 Karunamithi 등(1994)은 변형된 형태의 선형함수를 이용하였으며, 본 연구에서는 예측결과로 나타나는 음의 강우강도가 크지 않고 작은 값의 강우강도가 큰 의미가 없기 때문에 식 (13) 형태의 전달함수를 이용한다.

$$g_2(h) = \begin{cases} h & \text{if } h \geq 0 \\ 0 & \text{otherwise} \end{cases} \quad (13)$$

구성된 신경망모형의 학습은 역전파알고리즘을 이용하였다. 그리고 학습속도를 향상시키기 위하여 momentum 방법과 적용학습율을 병행하였다. Momentum 방법은 역전파 알고리즘에 의한 학습에서 국소최소값문제를 해결하기 위하여 주로 이용되는 방법이다(Hertz 등, 1991). Momentum 방법은 간단하면서도 효율적이기 때문에 자주 이용되는 방법으로 momentum항을 학습에 포함시키게 된다. 이를 수식으로 나타내면 아래와 같다.

$$\Delta w_{ij}(t+1) = (1-\alpha_m) \times \left(-\eta \frac{\partial E}{\partial w_{ij}} \right) + \alpha_m \Delta w_{ij}(t) \quad (14)$$

여기서 α_m 은 momentum 변수로 0과 1사이의 값을 가진다. 그리고 t 와 $t+1$ 은 학습의 진행단계를 나타낸다. Momentum 변수 α_m 의 값은 일반적으로 0.95가 이용되므로(Little과 Shure, 1992), 이 값을 이용하기로 한다.

적용학습율(adaptive learning rate)은 적절한 학습율을 설정하고 학습속도를 향상시키기 위하여 momentum 방법과 함께 주로 이용된다(Little과 Shure, 1992). 적용학습율에서는 실제 학습에 의해 오차함수가 감소하였는지를 확인하게 된다. 학습의 결과 오차함수의 크기가 감소하였을 때 학습율을 일정 비율만큼 증가시키게 된다. 반대로 학습 결과 오차함수의 크기가 정해진 비율이상 증가하였을 때, 즉 최소값을 지나쳤을 때는 학습율을 정해진 비율만큼 감소시키게 된다. 이러한 과정을 수식으로 나타내면 아래와 같다.

$$\eta(t+1) = \begin{cases} a_1 \eta(t) & E(t+1) < E(t) \\ a_2 \eta(t) & E(t+1) > a_3 E(t) \\ \eta(t) & \text{otherwise} \end{cases} \quad (15)$$

여기서 a_1 , a_2 및 a_3 는 적용학습율에 따른 매개변수로서 일반적으로 a_1 은 1.04, a_2 는 0.7 그리고 a_3 는 1.05의 값이 이용된다(Little과 Shure, 1992). 학습율의 초기값은 0.01을 이용하였으며 반복회수를 설정하여 학습을 중단할 수 있도록 하였다.

2.4 모형의 적용 및 결과

구성된 강우예측모형을 서울지역과 소양강유역의 강우자료에 적용하고 그 결과를 분석하였다. 서울시의 각 구청별로 보관되어 있는 강우자료중 이용가능한 16개 구청의 1994년도 강우자료를 이용하였다. 그리고 건설교통부와 한국수자원공사의 강우관측소에서 관측한 1987년부터 1995년까지의 소양강유역 6개 강우관측소의 강우자료를 이용하였다. 각 자료의 관측시간 간격은 1시간으로 되어 있다. 서울지역에 대한 신경망의 학습은 1994년 9월까지의 강우자료를 이용하였고 학습에 이용되지 않은 1994년 10월의 강우자료에 대한 강우예측을 시행하였다. 소양강유역에 대한 학습은 1987년부터 1993년까지의 강우자료를 이용하였으며 1994년과 1995년의 강우자료에 대한 예측을 시행하였다.

Table 1과 2는 서울지역에 대한 예측결과로부터 나온 오차와 상관계수를 정리한 것이며 Table 3과 4는 소양강유역에 대한 예측결과를 분석한 것이다. 그리고 Fig. 2와 3은 서울지역의 은평구청과 소양강유역의 인제관측소에서 측정된 결과와 예측결과를 비교한 것이다. 신경망모형의 적용에 있어 입력층성분의 개수가 N 개일 때 은닉층성분의 개수는 N 개에서 8N개까지 수행하면서 적절한 은닉층성분의 개수를 구하고자 하였으며, 반복회수는 50회에서 5,000회 정도까지 변화시켜 가며 적절한 값을 구하고자 하였다. 그 결과 은닉층 성분의 개수는 서울지역의 2N개, 소양강유역의 경우 4N개 이상에서 모형의 성능향상이 거의 없는 것으로 나타났다. 또한 반복회수가 100회 이내에서는 오차

의 감소가 급격히 진행되고, 500회 정도까지 서서히 감소하다가 그 이상에서는 거의 변화가 없는 것으로 나타났다. 은닉층 성분의 개수 N 개에서 $4N$

개, 반복회수는 100회에서 500회 정도에 대한 예측결과를 표로 비교하였다.

Table 1. Comparison of Errors (Seoul)

Prediction Model		Configuration of Network			Errors			
		Number of Nodes		Training Iterations	Normalized Max. Error	Normalized Mean Error	Normalized RMSE Error	Relative Error in the 0 th Moment
Type of Neural Network	Input Layer (N)	Hidden Layer	Output Layer					
	I-1	16	16(N)	16	100	0.6467	0.6146	0.5590 -0.1633
	I-2		16(N)		500	0.5439	0.5518	0.5050 0.0362
	I-3		32(2 N)		100	0.4824	0.5749	0.4897 0.0933
	I-4		32(2 N)		500	0.6618	0.5530	0.5104 -0.0692
	II-1	32	32(N)		100	0.5512	0.6462	0.5516 0.1288
	II-2		32(N)		500	0.6297	0.6341	0.5637 0.0973
	II-3		64(2 N)		100	0.6727	0.6526	0.5808 -0.1196
	II-4		64(2 N)		500	0.6067	0.5811	0.5139 0.0102

Table 2. Comparison of Correlation Coefficients (Seoul)

Prediction Model		Configuration of Network			Correlation Coefficient	
		Number of Nodes		Training Iterations		
Type of Neural Network	Input Layer (N)	Hidden Layer	Output Layer			
	I-1	16	16(N)	16	100	0.7015
	I-2		16(N)		500	0.7111
	I-3		32(2 N)		100	0.7544
	I-4		32(2 N)		500	0.7271
	II-1	32	32(N)		100	0.6468
	II-2		32(N)		500	0.6375
	II-3		64(2 N)		100	0.6123
	II-4		64(2 N)		500	0.7039

Table 3. Comparison of Errors (Soyang River Basin)

Prediction Model		Configuration of Network			Errors			
		Number of Nodes		Training Iterations	Normalized Max. Error	Normalized Mean Error	Normalized RMSE Error	Relative Error in the 0 th Moment
Type of Neural Network	Input Layer (N)	Hidden Layer	Output Layer					
	I-1	6	12(2 N)	6	100	0.7977	0.8985	0.7751 -0.0415
	I-2		12(2 N)		500	0.7657	0.9078	0.7504 -0.0099
	I-3		24(4 N)		100	0.8233	0.9398	0.7830 0.0118
	I-4		24(4 N)		500	0.8002	0.8557	0.7362 -0.0445
	II-1	12	24(2 N)		100	0.8499	0.8508	0.7741 -0.2269
	II-2		24(2 N)		500	0.8255	0.8690	0.7663 -0.0935
	II-3		48(4 N)		100	0.9107	0.8049	0.8208 -0.6393
	II-4		48(4 N)		500	0.8690	0.8010	0.7847 -0.1246

Table 4. Comparison of Correlation Coefficients (Soyang River Basin)

Prediction Model		Configuration of Network			Correlation Coefficients			
		Number of Nodes		Training Iterations	Maximum	Minimum	Mean	
Type of Neural Network	Input Layer (N)	Hidden Layer	Output Layer					
	I-1	6	12(2 N)	6	200	0.5636	0.3886	0.4447
	I-2		12(2 N)		200	0.5651	0.3567	0.4887
	I-3		24(4 N)		500	0.6035	0.3311	0.4271
	I-4		24(4 N)		200	0.6492	0.4082	0.5088
	II-1	12	24(2 N)		500	0.6437	0.3023	0.4372
	II-2		24(2 N)		200	0.5298	0.3059	0.4418
	II-3		48(4 N)		200	0.4817	0.3054	0.4133
	II-4		48(4 N)		500	0.4981	0.2405	0.4464

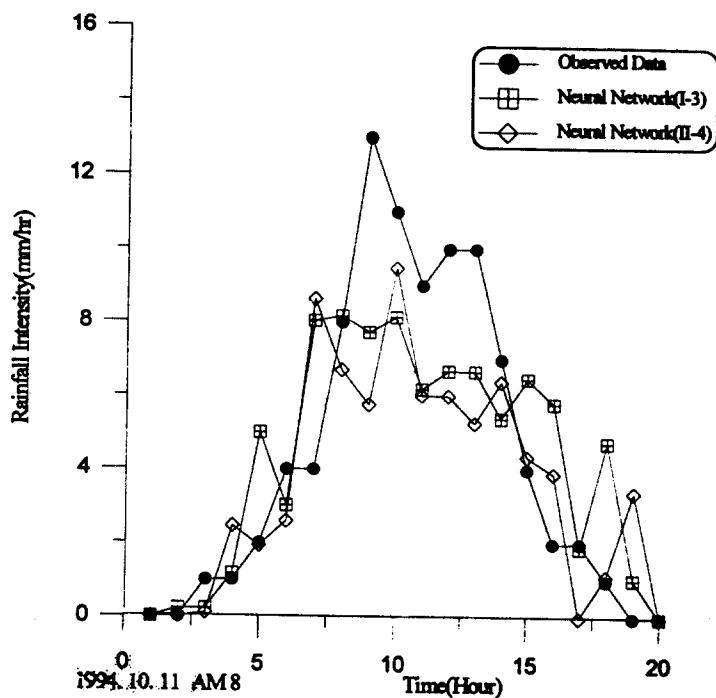


Fig. 2. Comparison of Prediction Results (at Eunpyung Gu in Seoul)

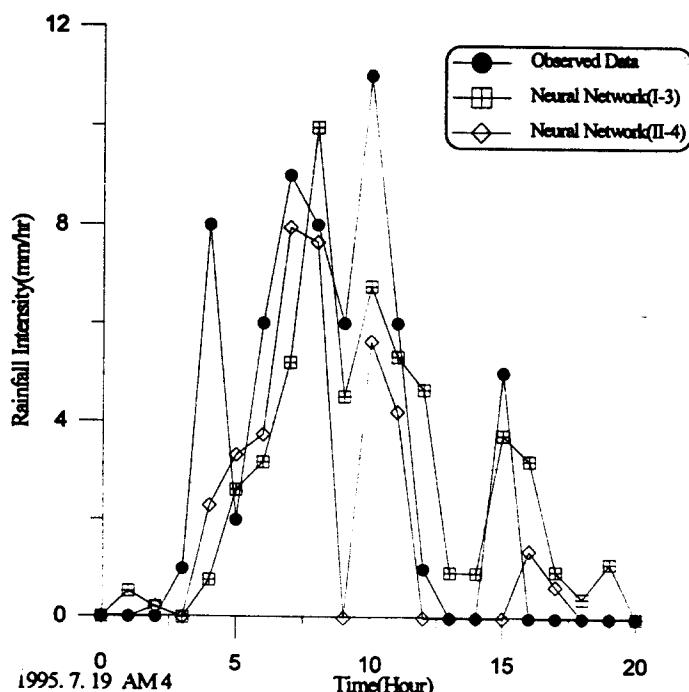


Fig. 3. Comparison of Prediction Results (at Inje)

표와 그림에서 나타난 결과를 종합하여 볼 때 서울지역에 대한 신경망모형의 적용은 만족스러운 것으로 판단된다. 그림에서 신경망모형에 의한 예측 결과는 강우의 진행을 잘 포착하는 것으로 나타났다. 특히 총강우량에 대한 오차를 의미하는 정규화된 0차모멘트의 상대오차로 판단할 때 총강우량의 크기를 정확하게 예측하는 것으로 나타났다. 그러나 첨두강우에 대해서는 과소추정하는 경향을 나타내었다.

소양강유역에 대한 신경망모형의 적용결과는 서울지역에 비하여 예측능력이 떨어지는 것으로 나타났다. 그러나 French 등(1992)의 연구결과에서 강우예측에 따른 상관계수가 0.38 - 0.78의 범위를 갖는 것으로 나타났고, French 등(1994)의 연구에서 0.625의 값을 가진 것과 비교할 때 소양강유역의 특성을 감안하면 대체로 만족스러운 것으로 판단된다. 소양강유역은 서울지역에 비하여 유역이 크고, 산악지방을 포함하고 있어 강우관측소간의 기상학적 동질성이 적은 것으로 판단되며 일부 관측소에서만 강우가 진행되는 경우도 많다. 또한 결측치와 이상치로 판단되는 관측오차를 포함하고 있어 예측의 정확도가 떨어진 것으로 판단된다.

예측결과로 판단할 때 신경망모형의 구조에서는 모형 I과 모형 II의 커다란 성능차이는 없는 것으로 나타났다. 온닉층 성분의 개수에 있어서는 서울지역의 경우 N 개보다 $2N$ 개일 때 상관계수에 있어 약간 나은 결과를 나타내었으며, 소양강유역의 경우 뚜렷한 차이가 나타나지 않아 입력층 성분의 개수가 N 개일 때 온닉층 성분의 개수는 $2N$ 개 정도가 충분한 것으로 판단된다. 반복회수의 경우 서울지역의 경우 반복회수의 증가에 따른 모형의 성능향상이 없는 것으로 나타나 100회 정도의 학습으로 충분한 것으로 나타났으며, 소양강유역의 경우 100회에 비하여 500회일 때 모형의 예측결과가 좋게 나타났다. 이는 소양강유역의 강우자료의 수가 크기 때문으로 판단되어 반복회수는 강우자료의 수에 따라 결정되어야 할 것이다.

3. 結 論

서울지역과 소양강유역에 대한 신경망이론을 이

용한 강우예측모형을 적용하였으며 이로부터 얻은 결론은 다음과 같다.

예측결과로부터 나온 오차와 상관계수로 판단할 때 신경망모형은 강우의 예측에 대하여 적용성이 뛰어난 것으로 나타났다. 즉, 신경망이론은 학습을 통하여 강우의 진행을 잘 파악하는 것으로 나타났다. 전체 강우량의 크기는 정확하게 예측하는 것으로 나타났으나 첨두강우량은 과소추정하는 경향을 나타내었다. 그리고 온닉층 성분의 개수는 $2N$ 개 정도로 충분한 것으로 나타났으며, 반복회수는 자료의 수에 따라 결정되어야 한다.

參 考 文 獻

- 김주환 (1993). “신경회로망을 이용한 하천유출량의 수문학적 예측에 관한 연구,” 박사학위논문, 인하대학교.
- 이종철 등 (1992). “기상위성 및 레이다 자료를 이용한 실시간 우량 추정 연구.” 소양강댐의 수문학적 안정성 검토 및 다목적 댐의 치수 능력 향상 방안 연구, Vol. 2, 한국수자원공사.
- Foufoula-Georgiou, E., and Georgakatos, K.P. (1991). “Hydrologic advances in space-time precipitation.” *Recent advances in the modeling of hydrologic systems*, D.S. Bowles and P.E. O’Connell, eds., pp. 47-65.
- French, M.N., Andrieu, H., and Krajewski, W.F. (1994a). “A model for real-time quantitative rainfall forecasting using remote sensing: 1. Formulations.” *Water Resources Research*, Vol. 30, No. 4, pp. 1075-1083.
- French, M.N., Andrieu, H., and Krajewski, W.F. (1994b). “A model for real-time quantitative rainfall forecasting using remote sensing: 2. Case studies.” *Water Resources Research*, Vol. 30, No. 4, pp. 1085-1097.
- French, M.N., Krajewski, W.F., and Cuykendall, R.R. (1992). “Rainfall forecasting in space and time using a neural network.” *J. of Hydrology*, Vol. 137, pp. 1-31.
- Hertz, J., Krogh, A., and Palmer, R.G. (1991). *Introduction to the theory of neural computation*.

- tion.* Addison Wesley.
- Karunananithi, N., Grenney, W.J., Whitley, D., and Bovee, K. (1994). "Neural networks for river flow prediction." *J. of Comp. in Civil Engr.*, ASCE, Vol. 8, No. 2, pp. 201-220.
- Little, J.N., and Shure, L. (1992). *Signal Process-*ing, neural network. The Math Works Inc.
- Seo, D.J., and Smith, J.A. (1992). "Radar-based short-term rainfall prediction." *J. of Hydrology*, Vol. 131, pp. 341-367.

〈접수: 1995년 10월 16일〉