

낙동강유역에서 신경망 모델을 이용한 강우예측에 관한 연구
- 다변량 모델과의 비교 -

A Study on the Rainfall Forecasting Using Neural Network
Model in Nakdong River Basin
- A Comparison with Multivariate Model -

조 현 경*, 이 증 석**
Hyeon-Kyeong Cho*, Jeung-Seok Lee**

<Abstract>

This study aims at the development of the techniques for the rainfall forecasting in river basins by applying neural network theory and compared with results of Multivariate Model (MVM). This study forecasts rainfall and compares with a observed values in the San Chung gauging stations of Nakdong river basin for the rainfall forecasting of river basin by proposed Neural Network Model(NNM). For it, a multi-layer Neural Network is constructed to forecast rainfall. The neural network learns continuous-valued input and output data. The result of rainfall forecasting by the Neural Network Model is superior to the results of Multivariate Model for rainfall forecasting in the river basin. So I think that the Neural Network Model is able to be much more reliable in the rainfall forecasting.

Key Words : *rainfall forecasting, Multivariate Model, Neural Network Model*

1. 서론

기상현상은 현대과학의 정밀성으로도 아직 정확하게 파악이 되지 않는 복잡한 영역이다. 중국에서 나비 한 마리가 일으키는 날개짓이 미국에 폭풍우를 몰고 올 수도 있다고 하는 '나비현상(Butterfly Effect)'은 대기 중 여러 요소 사이의

인과관계가 얼마나 복잡한 것인지 말해준다. 이러한 기상현상 중의 하나인 강우는 그 패턴이 갈수록 불규칙적이고 국지적인 요소에 좌우되는 경향이 강해지고 있어서 100% 정확히 예측하기는 선진국을 포함한 현재 과학수준으로는 어려운 실정이다. 우리나라는 지난 수십년간 거의 매년 크고 작은 홍수피해를 입어왔다. 물론 자연재해를 완벽히 막을 수는 없는 것이지만

* 정회원, 영남이공대학 토목과 교수·工博
영남대학교 졸업
705-037 대구광역시 남구 대명동 1737

Prof., Dept. of Civil Eng., Yeungnam College of Science & Technology, Ph.D./((053)650-9316

** 정회원, 경일대학교 토목공학과 교수·工博
영남대학교 졸업
712-701 경북 경산시 하양읍 부호리 33

Prof., Dept. of Civil Eng., Kyungil University, Ph.D. /((053)850-7225

이를 예상하고 사전대비를 하면 피해를 최소화할 수 있다. 이러한 엄청난 재앙을 초래하는 홍수를 예방하는데는 먼저 정확한 강우예측이 선행되어야만 한다는 것은 당연한 일이다.

이를 위해서 지역별로 국지적인 기후변화, 즉 비구름대의 형성이나 이동 등을 빠르고 정확하게 추적하여야만 비교적 정확한 강우량을 예측할 수 있다. 신속정확한 강우예측은 적절한 수문관리를 통해 수해예방은 물론 방류량 조절 등으로 재해대책 업무의 효율성을 높일 수 있게 하므로 필수적이라 아니할 수 없다.

이를 위하여 많은 강우예측 방법이 개발되었는데 접근방법에 따라 크게 기상학적인 방법과 수문학적 방법으로 대별할 수 있다. 먼저 기상학적인 방법은 바람, 기압, 기온 및 수분 등을 인자로 기상 물리방정식을 해석하여 수치예보를 할 수 있는 방법인데, 기상 물리학적 방정식에 사용되는 변수가 많고 비선형 결합이라는 점이 단점이라 하겠다. 한편 수문학적인 방법은 관측자료를 바탕으로 추계학적인 도구를 이용하여 강우를 예측하는 방법인데, 모델의 불확실성, 입력자료의 불확실성, 매개변수의 불확실성 및 시스템의 초기상태 등에 의해 강우예측 모델의 계산결과와 실측자료가 일치되지 않는 경향이 많기 때문에 실제 적용하기에는 무리가 따른다. 그래서 결과에 영향을 미치는 불확실성을 제거하기 위하여 최근 공학분야에서 많이 이용되는 최신정보이론인 신경망 이론을 강우예측에 적용하려는 시도가 잇따르고 있다.

지금까지의 수문학적인 관점에서의 강우예측에 관한 연구성과를 보면, 먼저 Raudkivi 등¹⁾은 1차 Markov 모형을 도입하여 뉴질랜드의 Auckland 지역 강우자료를 적용하여 강우의 지속성을 설명하였다. 그리고 Franz²⁾는 강우사상간의 시간간격은 모든 지점에서 동일하고 지속시간은 독립적이라고 가정하여 1차 Markov 모형에 의하여 강우를 발생시켰으며, Schaake 등³⁾은 분해모형을 푸에르토리코의 강우관측소에서 강우를 발생시키는데 적용하였다. 국내에서는 이재준⁴⁾이 ARP모델과 Markov 연쇄모델에 의하여 발생된 강우량을 비교하였다. 또한 조현경⁵⁾은 낙동강유역에서 다변량모델에 의해 강우예측을 수행한 바가 있다.

한편 신경망 이론에 의한 강우예측에 관한 국내외의 연구성과를 살펴보면, Mark 등⁶⁾이 신경망이론에 의해 시공간적으로 강우예측을 수행한 바가 있으며, 오남선 등⁷⁾이 서울지역과 소양강유역에 대해 신경망이론에 의한 강우예측을 수행한 바가 있다.

따라서 본 연구에서는 신속정확한 강우예측을 통해 낙동강유역의 수해예방은 물론 재해대책 업무의 효율성을 높일 수 있게 하기에 위하여 최신 정보이론인 신경망 이론을 이용한 강우예측모델을 개발하여 분석 검토함으로써 강우예측을 위한 신경망 모델의 적용 가능성을 제시하는데 그 목적을 두었다.

2. 강우예측 모델의 기본이론

2.1 신경망 모델

(1) 신경망 이론의 개요

인간의 두뇌는 약 10^{11} 개나 되는 뉴런(Neuron)을 조직적으로 결합한 거대한 시스템으로 구성되어 있다. 따라서 인간의 두뇌는 신경세포가 매우 복잡하게 서로 연결된 비선형시스템의 네트워크라 할 수 있는데 외부 또는 다른 신경세포로부터 시냅스(Synapse)를 통하여 입력신호를 전달받아 세포체에서 적절한 처리를 하여 그 결과를 축색돌기(Axon)를 통해 다른 신경세포에 전달하여 계산기능을 수행한다. 이러한 과정은 다음 Fig. 1에 나타난 바와 같다.

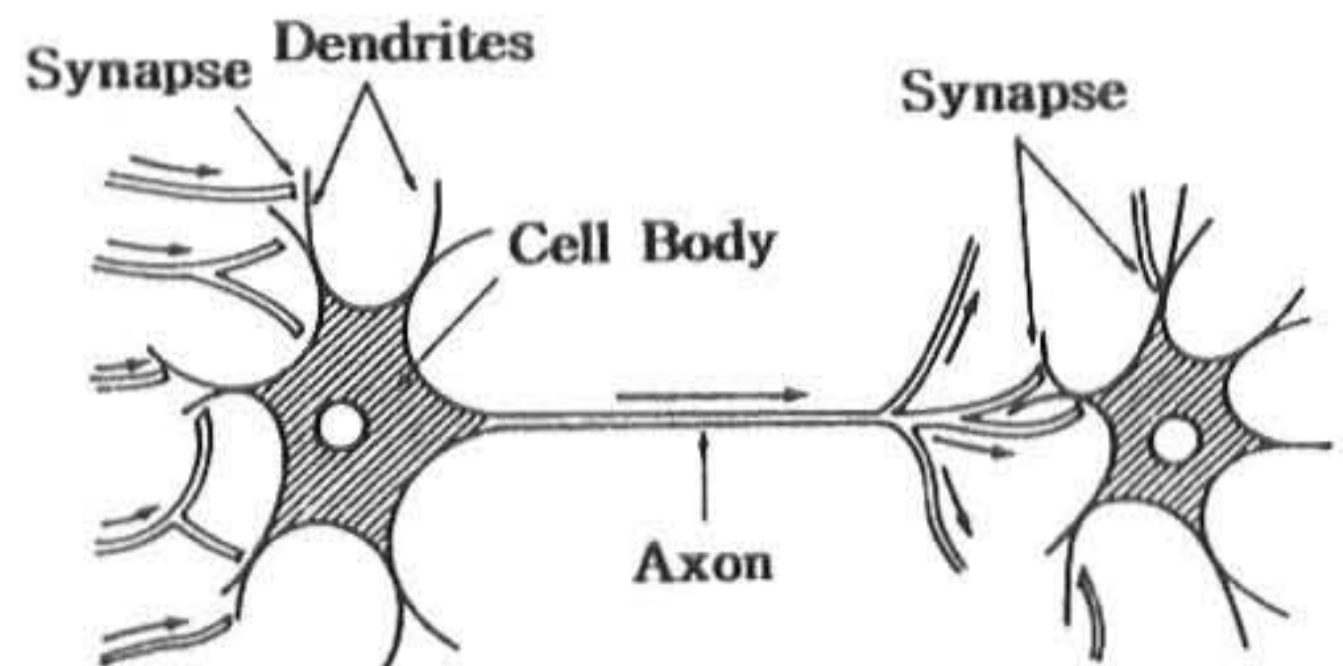


Fig. 1 Neuron

이 과정을 수학적으로 표현한 것이 신경망의 처리소자이며 신경망을 구성하는 처리소자는 입력을 통합하는 결합함수와 통합된 결과의 동작범위를 제공하는 전달함수로 구성된다. 신

경망은 수학적 연산능력을 가진 처리소자들이 상호연결된 것으로 적절한 학습규칙에 의해 동작한다.

이러한 신경망은 패턴분류 등 여러 가지 문제들을 처리함에 있어서 기존의 방법이 순차적이고 논리적인 틀속에서 프로그램되는 것과는 달리 학습을 통해 인지하게 되고, 본질적으로 다수의 유니트들에게 서로 영향을 주며 동시에 서로 다른 처리를 행하는 병렬처리를 한다는 특징이 있다.

(2) 신경망 모델

뉴런을 정보처리소자라고 간주한다면 이는 다음 Fig. 2와 같이 n 개의 입력신호 x_1, x_2, \dots, x_n 을 받아 들이고 그 것을 가지고 계산하여 출력 z 를 답으로 내 보내는 소자이다.




Fig. 2 Unit


입출력 신호 x_1, x_2, \dots, x_n, z 는 모두 펄스 빈도를 나타내며, 그 강도는 0 또는 1 사이의 실수이다. 즉, 펄스를 보내지 않을 때는 0, 최고의 빈도로 펄스를 내보내고 있을 때는 1이고, 나머지는 중간값을 취한다. 지금 s_1, s_2, \dots, s_n 을 각각 x_1, x_2, \dots, x_n 의 입력 섬유결합의 강도 즉, 이것들의 신호의 영향도이다. 이 때 입력신호 전체의 영향은 가중치를 곱한 합계

$$\sum_{i=1}^n s_i x_i \tag{1}$$


가 된다. 여기서 h 를 임계치라고 하고 이를 빼

$$u = \sum_{i=1}^n s_i x_i - h \tag{2}$$

라 한다.



(a) 시그모이드 함수



(b) 단위 계단함수

Fig. 3 Transfer Functions

입력의 강도를 더한 것이 u 이기 때문에 출력은 u 가 클수록 강한 빈도로 펄스를 내보낼 것이다. u 가 음이라면 거의 펄스를 보내지 않는다. 한편 펄스의 최고빈도를 1로 했기 때문에, u 가 아무리 크더라도 더 이상 강한 출력이 나오지 않는다. 따라서 함수 $f(u)$ 를 생각하면 다음과 같은 입출력 관계로 나타낼 수 있다.

$$z = f(u) = f(\sum s_i x_i - h) \tag{3}$$

이 때 변환함수로 시그모이드 함수(Sigmoid Function)와 단위 계단함수가 주로 사용되며 그 형태는 다음 Fig. 3과 같다.

(3) 오차역전파 학습알고리즘

학습(Learning)은 신경망이 정보, 지식을 습득하는 방법으로 실제값과 출력값 사이의 오차를 줄이도록 반복실행하여 연결강도를 조정하는 것이다.

오차역전파 학습알고리즘은 현재 가장 많이 사용되고 있는 기법으로 크게 다음과 같은 두 단계로 구성되어 있다. 첫째는 신경망의 입력패턴에 따라 각 처리소자의 입력치와 전달함수를 사용하여 출력을 산출하는 순방향처리이

고, 두 번째는 실제값과 계산치와의 차이인 오차를 역으로 진행시키면서 오차가 최소가 되도록 층과 층사이의 연결강도를 변화조절하는 역방향처리이다.

시스템의 입출력 관계는 다음과 같이 쓸 수 있다.

$$z = f(\sum s_i x_i) \quad (4)$$

$$x_i = f(\sum w_{ij} a_j) \quad (5)$$

한편 입력신호 a 에 대해서 원하는 출력신호를 벡터 $y_d(a)$ 로 한다. 여기서 손실함수를 다음과 같이 한다.

$$l(a, \theta) = \frac{1}{2} |z - y_d(a)|^2 \quad (6)$$

가변 매개변수 θ 는 구체적으로는 s_i 와 w_{ij} 라고 하면

$$\frac{\partial l}{\partial s_i} = [z_i - y_{di}(a)] f(\sum s_j w_j) x_i \quad (7)$$

로 쓸 수 있으므로

$$r_i = (z_i - y_{di}) f(s \cdot x) \quad (8)$$

를 학습신호로 하여

$$s_i \rightarrow s_i - cr_i x_i \quad (9)$$

와 같이 s_i 를 바꾸면 된다. 중간층의 학습 w_{ij} 에 대해서는

$$\begin{aligned} \frac{\partial l}{\partial w_{ij}} &= \frac{\partial l}{\partial x_i} \frac{\partial x_i}{\partial w_{ij}} = \sum_k (z_k - y_{dk}) \frac{\partial z_k}{\partial x_i} \frac{\partial x_i}{\partial w_{ij}} \\ &= (\sum_k r_k s_k) f(\sum w_{im} a_m) a_j = \overline{r_i} a_j \quad (10) \end{aligned}$$

가 된다. 여기서 중간층의 i 번째 뉴런의 학습신호 $\overline{r_i}$ 는

$$\overline{r_i} = (\sum_k r_k s_k) f(w_i \cdot a) \quad (11)$$

에 의해 출력층의 학습신호 r_k 에 시냅스 하중 s_k 를 곱해서 더한 것에 f 를 곱하면 된다. 즉,

$$w_{ij} \rightarrow w_{ij} - cr_i a_j \quad (12)$$

로 하면 된다.

2.2 다변량 모델

성공적인 강우예측을 위해서는 강우구조에 대한 가정과 그 가정된 구조에 대한 일관된 수치모형 및 수치모형의 매개변수 추정을 위한 진행과정 등이 필요하다. 이러한 수치모형에 있어서 어려운 점은 다음과 같은 비정상성에 대한 매개변수 추정에 있다.

$$i(t) = m(t) + r(t) \quad (13)$$

여기서, $i(t)$ 는 지점 $(x_1, y_2), (x_2, y_2), \dots, (x_N, y_N)$ 에서 시간단계 t 에 대한 강우강도 N 의 벡터, $m(t)$ 는 시간단계 t 에서 평균치의 벡터, $r(t)$ 는 시간단계 t 에서 잔차의 벡터, N 은 예측시 강우관측소의 수이다.

이 때 다음과 같이 대각선 표준편차행렬 $\Sigma(t)$ 를 정의하는 것이 편리하다.

$$\Sigma(t) = \begin{bmatrix} \sigma(x_1, y_1, t) & 0 & 0 & 0 \\ 0 & \sigma(x_2, y_2, t) & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \vdots & \sigma(x_N, y_N, t) \end{bmatrix} \quad (14)$$

식(13)에서 시간단계 t 에서 잔차벡터 $r(t)$ 는 다음과 같다.

$$r(t) = \Sigma(t) \varepsilon(t) \quad (15)$$

여기서, $\varepsilon(t)$ 는 평균이 0이고 단위분산인 무작위 벡터이다.

강우예측 방법에서 가장 어려운 것은 강우가 시간에 대해 동적거동을 한다는 점이다. 이를 나타내는 식(13)에서 시간에 대한 강우의 발달과정은 평균치의 변동과 잔차의 변동 등 두 가지 성분을 가진다. 평균치 벡터 $m(t)$ 는 시간에 따른 변동을 한다고 가정하였고, 여기서 중요한 문제인 잔차항 $r(t)$ 의 변동성을 나타내기 위해서 비정상 Markov 모델을 이용하여 잔차를 시간에 대하여 다음과 같이 전개하였다.

$$r(t+\tau) = A(t+\tau)r(t) + B(t+\tau)W(t, \tau) \quad (16)$$

여기서, $A(t, \tau)$ 는 장래의 전이 τ 단계에 대한 시간단계 t 에서의 $N \times N$ 상태 천이행렬, $W(t, \tau)$ 는 평균치 0을 가지는 $N \times 1$ 벡터, $B(t, \tau)$ 는 시간단계 $t+\tau$ 에서 잔차에 대하여 시간단계 t 에서의 잡음항의 효과를 나타내는 $N \times N$ 행렬이다.

식(16)은 선행치 τ 에 대해서 A, B, W 를 포함하고 있기 때문에 일반적인 식은 아니지만

다중치에서의 강우예측을 수행하기 위해서는 꼭 필요하다. 강우관측소가 위치한 많은 지점들에서 각 시간단계에서 측정된 강우강도의 값들이 필요하며, 전체 강우관측망을 형성함으로써 N 지점에서 타지점으로 점차 강우예측이 가능해진다. 이들 지점들에 대한 강우예측식은 다음 식(17)과 같다.

$$z(t) = q(t) - m(t) = r(t) + v(t) \quad (17)$$

여기서, $q(t)$ 는 관측강우량의 $N \times 1$ 벡터, $m(t)$ 는 평균치의 $N \times 1$ 벡터, $r(t)$ 는 참잔차의 $N \times 1$ 벡터, $v(t)$ 는 측정오차의 $N \times 1$ 벡터, $z(t)$ 는 측정오차의 $N \times 1$ 벡터, N 은 예측지점의 수이다.

다른 선행시간들에서의 예측은 다음 식(18) 및 식(19)에 지배된다.

$$r(t + \tau | t) = A(t, \tau)r(t | t) \quad (18)$$

$$P(t + \tau | t) = A(t, \tau)P(t | t)A^T(t, \tau) + Q(t, \tau) \quad (19)$$

장래의 임의의 시간 $t + \tau$ 에서의 강우예측은 다음과 같다.

$$i(t + \tau | t) = m(t + \tau) + r(t + \tau | t) \quad (20)$$

이 예측에서의 오차공분산 행렬은 $P(t + \tau | t)$ 에 의해서 주어진다.

평가하는 방법으로는 Telemeter에서 관측되는 두 지점간의 시간간격 자료를 이용하는 선형회귀분석 방법인데, 이는 Marshall⁸⁾이 제안했다.

지점자료로부터 호우속도를 추정하기는 매우 어려우므로 극대 상호공분산(Cross-Covariance)의 값을 아는 것이 비선형 매개변수 추정에 있어서 가장 중요한 문제이다.

거리가 d 인 두개의 강우관측소 i 와 j 가 있다고 생각하면 속도 V 로 이동하고 방향 θ 를 가진 호우가 i 와 j 사이를 이동하면 호우이동시간은 t_{ij} 이다.

$$t_{ij} = \frac{d \cos(\alpha - \theta)}{V} \quad (21)$$

만약 t_{ij} 가 관측자료로부터 추정할 수 있다면 식(21)의 매개변수는 선형회귀로부터 추정될 수 있다. 추정된 매개변수 b_1 과 b_2 로부터 V 와 θ 의 추정치는 다음 식에 의해서 구할 수 있다.

$$V = (b_1^2 + b_2^2)^{-1/2} \quad (22)$$

$$\theta = \tan^{-1}\left(\frac{b_2}{b_1}\right) \quad (23)$$

여기서, x , y 방향의 속도성분은 다음과 같이 추정될 수 있다.

$$U_x = -V \cdot \sin \theta \quad (24)$$

$$U_y = V \cdot \cos \theta \quad (25)$$




Fig. 4 Storm Passing Overgages i and j

그리고 본 모델을 수행하기 위해 필요한 강우진행 속도와 방향을 실용적이면서도 쉽게

3. 모델의 적용 및 분석

3.1 신경망 모델의 구성

강우예측을 위한 신경망 모델은 다음 Fig. 5와 같이 입력층, 은닉층 및 출력층으로 구성된 전형적인 구조로 작성하였다.




Fig. 5 Structures of Neural Networks

학습자료는 입력층을 선행 1, 2시간의 강우자료로 구성하는 방법 1과 선행 1, 2, 3, 4시간의 강우자료로 구성하는 방법 2, 선행 1, 2, 3, 4, 5, 6시간의 강우자료로 구성하는 방법 3의 세 가지로 하였다. 이에 따른 강우예측을 위한 신경망 모델의 입력층, 은닉층 및 출력층의 구조는 다음 Table 1과 같다.

Table 1. Numbers of Layer for Each Method

Method	Layer		
	Input	Hidden	Output
1	2	5	1
2	4	9	1
3	6	13	1

이 때 신경망의 출력치는 변환함수인 시그모이드 함수를 통해 0에서 1 사이의 값으로만 주어지기 때문에 적절한 정규화(Normalization) 과정이 필요하다. 일반적인 정규화 과정은 다음과 같이 식(26)을 이용한다.

$$T_{ar} = T_{min} + \left[\frac{V_{at} - V_{min}}{V_{max} - V_{min}} (T_{max} - T_{min}) \right] \quad (26)$$

여기서, V_{max} 와 V_{min} 은 변환되기전 출력값의 최대값과 최소값이고, T_{max} 와 T_{min} 은 변환된 출력값의 최대값과 최소값으로 일반적으로 0.9와 0.1을 사용하며, T_{ar} 은 변환된 출력값, V_{at} 은 변환되기 전의 출력값으로 T_{ar} 함수의 입력값이다.

3.2 대상유역 및 분석자료

본 연구의 적용 대상유역은 Fig. 6과 같이 한반도의 동남단에 위치한 낙동강유역을 대상으로 하였으며, 유역의 대부분이 경상남북도 지역을 점유하고 있고, 강원도와 전라도의 일부분을 포함하고 있다. 유역의 형태는 대략 장방형으로서 남북의 길이는 200km에서 240km 정도이고 동서의 폭은 약 130km이며 북위 35°03'~37°13', 동경 127°29'~129°18'에 위치하고 있다. 본 연구를 위하여 선정한 유역내의 강우관측소는 Fig. 6에서 나타난 바와 같이 10개 T/M 관측소를 선정하여 분석하고 본 논문에서는 그 중 산청지점에 대해 나타내었다.




Fig. 6 Study River Basin(Nakdong River Basin)

그리고 낙동강유역에 대한 신경망 학습자료는 1990년부터 1995년까지의 강우자료를 이용하였고 학습에 사용되지 않은 1996년부터 1998년까지의 실측 강우자료에 대해 검증자료(Checking Data)로 사용하였다. 반복횟수는 500회에서 5,000회 정도까지 변화시켜 가면서 적절한 값을 구하고자 하였다.

3.3 적용결과와 비교분석

(1) 신경망 모델

전절에서 구성된 신경망 모델을 적용하기 위해 1990년부터 1995년까지의 강우자료를 이용하여 학습을 수행하였으며, 각 방법별로 강우총량에 대해 계산치와 관측치를 비교하였다. 그 결과 총강우량이 작을 때는 계산치와 관측치가 대체로 일치하였으나 강우량이 커질수록 오차가 다소 크게 나타났다. 여기서는 방법 3에 대해서만 Fig. 7에 나타내었다.




Fig. 7 Comparisons of Computed and Observed Value(Method 3)

또한 1996년부터 1998년까지의 강우자료 중 1996년 6월 24일 호우와 1998년 8월 13일 호우에 대해 각 방법별 신경망 모델을 적용하였으며, 그 결과는 Fig. 8 및 9와 같다.




Fig. 8 Results of Rainfall Forecasting by Neural Network Model(1996. 6. 24)




Fig. 9 Results of Rainfall Forecasting by Neural Network Model(1998. 8. 13)

그리고 결과의 적합성을 판정하기 위하여 검정을 실시한 결과 Table 2와 같이 나타났다.

먼저, 우량도의 전체적인 검정에 사용된 적합성 검정방법 중 모델의 효율도(Model Efficient : ME)는 0.910~0.936, 평균제곱오차(Mean Square Error : MSE)는 3.2~9.1mm, 상대오차의 평균을 나타내는 Bias는 1.9~3.8mm 및 체적오차의 백분율(Volume Error : VER)는 1.211~1.662% 등을 나타내었다.

Table 2. Results of the Statistical Test for Actual Storm

Method	Date	ME	MSE (mm)	Bias (mm)	VER (%)
1	1996.6.24	0.910	8.4	3.6	1.662
	1998.8.13	0.919	9.1	3.8	1.420
2	1996.6.24	0.916	7.4	2.1	1.387
	1998.8.13	0.923	6.4	2.3	1.268
3	1996.6.24	0.927	4.5	2.0	1.310
	1998.8.13	0.936	3.2	1.9	1.211

이와 같이 Fig. 7~9 및 Table 2의 결과를 비교해 볼 때 본 모델은 실측우량값에 대해 매우 근사한 것으로 나타났다. 또한 3가지 방법을 비교해 보면 방법 3이 방법 1 및 방법 2에 비해 실측치에 더욱 근사한 것으로 나타났다. 그 이유는 방법 3이 다른 방법들에 비해 더욱 구체적인 자료(선행 1, 2, 3, 4, 5, 6시간의 강우자료)로 구성되어 학습에서 다른 방법에 비해 추세를 좀더 정확히 반영하였기 때문이라고 추정된다.

(2) 다변량 모델

낙동강유역에서 다변량 모델을 적용하기 위하여 중심호우 자료와 관측지점의 선정, 관측점 간의 거리산정, 최대 지체시간수의 계산 등을 실시하여 회귀모형을 검토하고 회귀계수 및 강우 진행속도와 방향을 추정한 결과, Table 3 및 4와 같았다.

Table 3. Regression Coefficient of Each Storm

Storm	b_1	b_2
1996.6.24	0.19298	0.17281
1998.8.13	0.16124	-0.13249

Table 4. Movement Velocity and Direction of Each Storm

Storm	Variables			
	U_x (km/hr)	U_y (km/hr)	V (km/hr)	θ
1996.6.24	2.782	1.263	3.055	182°18'
1998.8.13	1.326	2.318	2.670	112°15'

위 결과를 이용하여 낙동강유역의 산청지점에서 1996년 6월 24일 호우와 1998년 8월 13일 호우에 대해 다변량 모델을 적용한 결과 Fig. 10 및 11과 같았다. 분석 결과를 볼 때 시간별 실측 및 예측 강우량에서 호우 발생패턴은 전체적으로 그 양상이 서로 비슷하게 분석되었으나, 강우총량으로 볼 때 전체적으로 실제 강우량보다 예측 강우량의 발생량이 다소 크게 추정됨을 알 수 있다.




Fig. 10 Results of Rainfall Forecasting by Multivariate Model(1996. 6. 24)

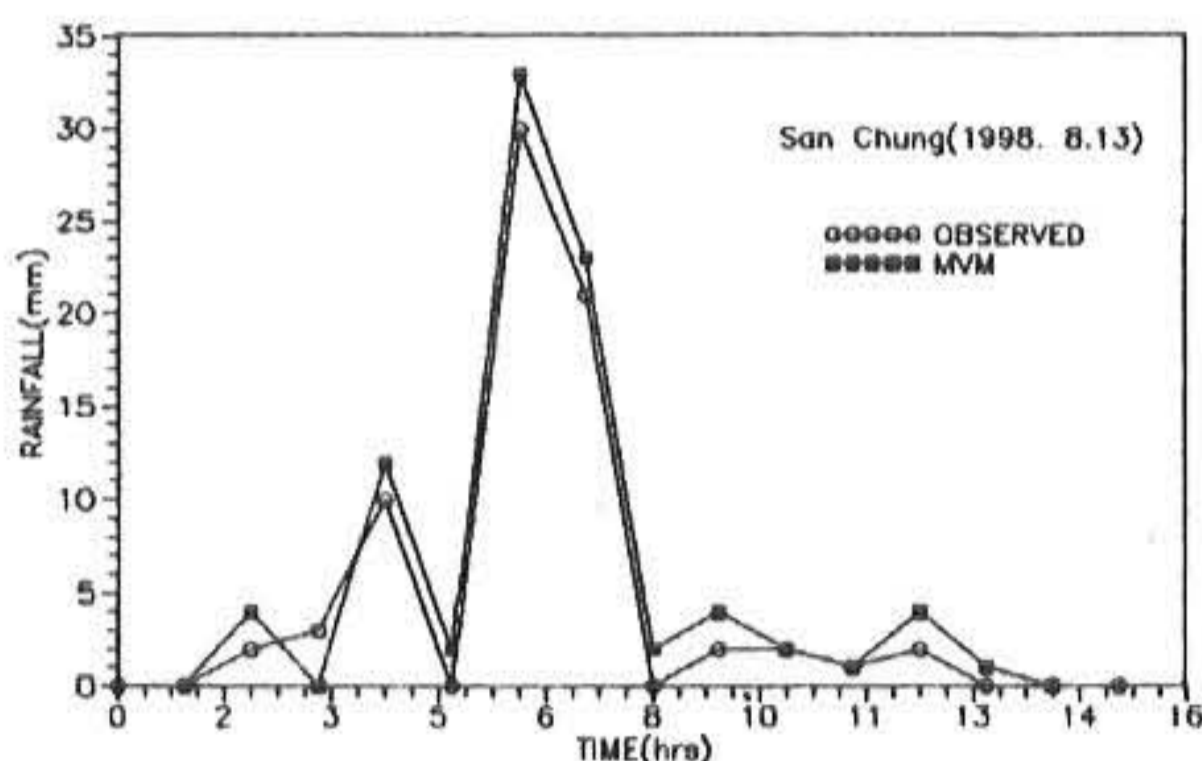


Fig. 11 Results of Rainfall Forecasting by Multivariate Model(1998. 8. 13)

3.4 모델의 비교 고찰

위에서 세 가지 신경망 모델 중에서 방법

3이 더욱 적합성이 큰 것으로 나타났으므로 여기서는 신경망 모델 중 방법 3과 다변량 모델을 비교 고찰하였다.




Fig. 12 A Comparison of Results of Rainfall Forecasting by Models(1996. 6. 24)

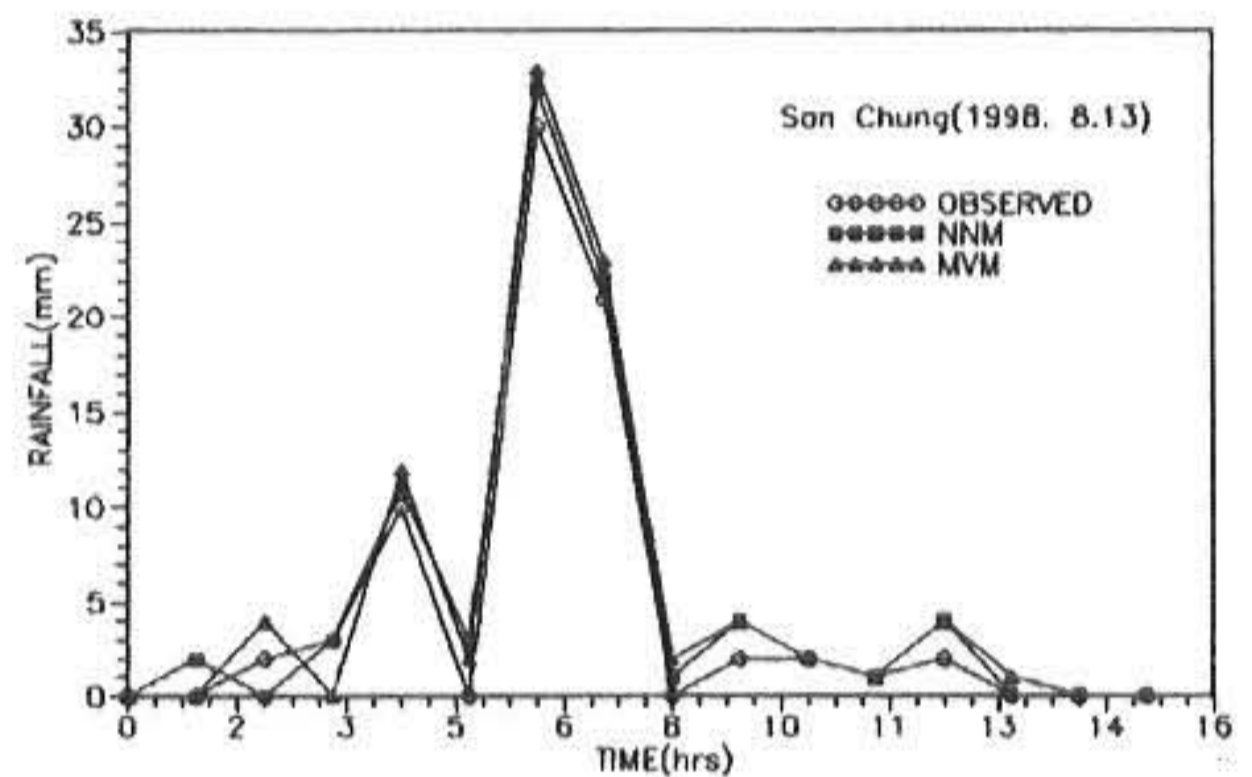


Fig. 13 A Comparison of Results of Rainfall Forecasting by Models(1998. 8. 13)

Table 5. Results of Sensitivity Analysis for Model(Sanchung)

Model	Date	ME	MSE (mm)	Bias (mm)	VER (%)
NNM	1996.6.24	0.927	4.5	2.0	1.310
	1998.8.13	0.936	3.2	1.9	1.211
MVM	1996.6.24	0.914	6.5	2.6	1.238
	1998.8.13	0.926	4.7	2.8	1.676

낙동강유역의 산청지점에서 1996년 6월 24일 호우와 1998년 8월 13일 호우에 대해 신경망 모델(방법 3)과 다변량 모델을 적용한 결과 Fig. 12 및 13과 같았다. 또한 모델을 비교하기 위하여 각 호우사상에 대한 지점별 예측강우량의 모델의 적합도를 검토를 위하여 모델의 효용도(ME), 평균제곱오차(MSE), 상대오차의 평

균(Bias) 및 최적오차의 백분율(VER)을 분석하였으며, 그 결과는 Table 5와 같았다. 그리고 호우사상별 분석 결과로 볼 때 강우예측 모델은 신경망 모델이 다변량 모델보다 그 결과가 약간 더 우수함을 알 수 있었다.

4. 결론

본 연구에서는 하천유역의 강우예측을 위하여 낙동강유역의 10개 T/M 관측소를 선정 분석하였다. 그리고 본 논문에서는 그 중 산청지점을 대상으로 신경망 모델을 적용하여 강우량을 예측하고 다변량 모델에 의한 값 및 실측치와 비교하였으며, 그 결과 다음과 같은 결론을 얻었다.

1) 현재 낙동강 유역의 T/M관측소를 중심으로 획득할 수 있는 자료로부터 강우예측을 수행할 수 있는 신경망 모델을 입력층, 은닉층 및 출력층으로 구성하고 신경망 모델의 학습에 의한 강우예측 모델을 구성하였다.

2) 신경망 모델에서 여러 가지 경우(방법 1, 2, 3)를 제시하였으며, 자료가 구체적(입력층의 처리소자의 수가 많은 것)이어서 관측치의 추세를 좀더 잘 반영한 방법 3이 실측치에 더욱 가까운 결과를 얻었다.

3) 모델 적용결과 신경망 모델에 의한 강우예측 결과가 다변량 모델에 의한 강우예측 결과보다 실제의 강우발생 결과와 강우의 발생분포 및 총량에 좀더 접근함을 알 수 있었다.

이상과 같이 하천유역의 강우예측을 위한 모델들을 분석한 결과 신경망 모델에 의한 강우예측 결과가 다소 우수한 것을 알 수 있었으나, 자료에서 시간별 선행강우량 이외의 기상인자들을 입력자료로 사용할 경우 더욱 신뢰성 높은 강우예측 결과를 얻을 수 있을 것으로 판단된다.

참고문헌

1. Raudkivi, A.J., and N. Lawgun, Synthesis of Urban Rainfall, Water Res. Research., 6(2), pp. 455~464, (1970)
2. Franz, D.D., Hourly Rainfall Synthesis for a Network of Stations, Stanford Univ., Dept. of Civil Eng., Techn. Report No.

- 126, Stanford, Cal., (1970)
3. Schaake, J.C., M.J. Ganslaw, J.W. Fothergill, and T.E. Harbaugh, Multivariate Rainfall Generator for Annual, Seasonal, Monthly and Daily Events, Presented at the Int. Sympos. on Math. Modelling Techniques in Water Res. Systems, Ottawa, May 9~12., (1972)
4. 이재준, 강수계열의 모의발생 모델 개발, 연세대학원 박사학위논문, (1987)
5. 조현경, 하천유역의 강우예측에 관한 연구, 영남대학교 석사학위논문, (1991)
6. Mark N. French, Witold F. Frajewski, Robert R. Cuykendall, rainfall Forecasting in Space and Time Using Neural Network, Journal of Hydrology Vol.137, pp.1~31, (1992)
7. 오남선, 선우중호, 신경망이론에 의한 강우예측에 관한 연구, 한국수자원학회지 제29권 제4호, pp.109~118, (1996)
8. Marshall, R.J., A stochastic Models to Simulating Moving Storms. In ; Precipitation Analysis for Hydrologic Modelling, Nat. Symp. Am. Geophys. Union Hydrol. Sect., June, 26~28, Univ. Calif., pp. 259~300, (1975)

(1999년 7월15일 접수, 1999년 10월10일 채택)