

상층기상자료와 신경망기법을 이용한 면적강우 예측

Forecast of Areal Average Rainfall Using Radiosonde Data and Neural Networks

김 광 섭*

Kim, Gwangseob

Abstract

In this study, we developed a rainfall forecasting model using data from radiosonde and rain gauge network and neural networks. The primary hypothesis is that if we can consider the moving direction of the rain generating weather system in forecasting rainfall, we can get more accurate results. We assume that the moving direction of the rain generating weather system is same as the wind direction at 700mb which is measured at radiosonde networks. Neural networks are consisted of 8 different modules according to 8 different wind directions. The model was verified using 350 AWS data and Pohang radiosonde data. Correlation coefficient is improved from 0.41 to 0.73 and skill score is 0.35. Statistical performance measures of the Quantitative Precipitation Forecast (QPF) model show improved output compared to that of rainfall forecasting model using only AWS data.

keywords : Rainfall forecast, Automatic Weather Station, Radiosonde, Neural Networks

요지

본 연구에서는 상층기상자료, 자동 기상 관측망 자료 및 신경망기법을 사용하여 단시간 강우 예측 모형을 개발하였다. 호우를 동반한 이송 기상 시스템의 이동 경로가 라디오존데로부터 획득할 수 있는 상층기상 자료 즉 상층 풍향자료와 동일한 방향으로 이동한다는 가정 하에 원거리에서 발생하는 기상현상의 발달과정을 판단 할 수 있는 알고리즘을 개발하고, 이러한 원거리 입력 자료와 예측하고자 하는 값 사이의 비선형 상관관계를 연결하는 기법으로 인공 신경망 기법을 도입하였다. 개발된 모형을 2002년 태풍 루사로 인하여 큰 피해를 입은 감천지역에 적용하였다. 포항과 오산의 라디오존데에서 획득한 700mb에서의 풍향자료와 5년의 자료기간을 가지는 350개의 자동 기상 관측망 자료를 입력 자료로 사용하였으며 결과는 상층 풍향자료를 사용한 경우에 상관계수가 0.41에서 0.73으로 개선되었으며 숙련도도 35%향상되었다. 모형의 개선도를 나타내는 통계치의 개선을 통해 상층기상자료를 활용한 강우예측 모형이 단지 지상 강우계자료만 사용한 예측보다 개선된 결과를 보여줌을 알 수 있다.

핵심용어 : 강수량예측, 자동기상관측망, 라디오존데, 신경망기법

1. 서 론

정확한 단시간 강우량예측은 매년 막대한 인명 및

재산상의 피해를 야기시키는 홍수의 적절한 경보를 가능하게 하고 수해방지, 재해피해 예방 및 계획에 있어 가장 중요한 요소의 하나로 지난 수십년 동안의

* 정회원, 경북대학교 토목공학과 조교수

Assistant Professor, Dept. of Civil Eng., Kyungpook National Univ., Daegu, 702-701, Korea
(e-mail: kims@knu.ac.kr)

연구를 통하여 많은 발전이 있었음에도 불구하고 정확한 강우량예측에 대한 사회적 요구는 여전히 수자원 연구에 있어 해결해야 할 가장 중요한 문제의 하나이다. 최근에는 기상이론 및 예보기술의 발달과 수치계산능력의 강화로 수치모델을 이용한 각종 기상요소의 정량적인 총량예보능력의 개선에도 불구하고 강우의 공간분포에 대한 개선은 절대적으로 필요하다 하겠다. 더욱이 지구온난화로 인한 기상이변이 증가하는 가운데 우리나라의 강수현상의 장기변화는 강우강도의 증가, 호우발생빈도의 증가, 총 강수량의 증가로 요약 된다 (권원태 외, 2003). 이제까지 우리들은 해마다 겪고 있는 홍수피해를 줄여나가기 위한 대안으로서 댐이나 제방의 건설과 같은 구조적인 방법을 통한 해결방안을 수행하여 왔으나 홍수로 인한 인명 및 재산 피해 규모는 증가하고 있는 실정이다. 그러므로 수재해 방재를 위하여 구조적 대책들과 함께 비구조적인 대책 특별히 강우의 단기 예보 능력 향상을 필수적이라 하겠다.

일반적으로 현재까지 개발된 기법들은 통계적 및 추계학적 예측모형과 물리적 기반을 가진 모형으로 구분되는데 전자는 Autoregressive Moving Average (ARMA) 모형과 ARMA 모형에 외적입력자료를 포함시킨 ARMAX 모형을 포함하며 이를 모형들에서 강우량은 수문학적, 기상학적 자료들의 통계적, 추계학적 관계식으로 나타난다. 후자는 광역에 대해서 이루어지는 물리적 현상에 (연속성, 운동성 등) 대한 미분방정식 형태의 표현을 바탕으로 하여 해석한다. 이러한 모형들은 설정된 유역 내에서의 물리적 현상을 잘 재현함에도 불구하고 보다 긴 홍수 예경보시간을 필요로 할 때는 보다 큰 유역에 대하여 상관관계를 설정하고 이에 따른 입력자료들을 필요로 하므로 적용성이 한계를 가진다. 보다 긴 예경보시간의 획득을 위해서는 원거리의 입력정보를 필요로 한다. 원격측정기술의 발전은 홍수 예경보 시간의 연장 및 정확도 개선 등의 문제를 해결할 수 있는 가능성을 제시하였다. 위성영상 및 고층대기의 기압 · 기온 · 습도를 측정 하는 기상관측기계인 라디오존데로부터 획득할 수 있는 정보는 원거리 기상상태를 판단할 수 있도록 하였고 대상유역으로 접근하고 있는 기상시스템의 특성을 홍수예측에 이용할 수 있게 하였다(예를 들면 접근하고 있는 기상시스템의 종류 [모양, 온도, 생성된 시간으로부터 사멸되기까지 소요되는 시간 등에 따라 판단], 위치, 진행방향 등의 정보를 이용하여 대상유역에 영향을 줄 수 있는 기상상태를 판단). 본 연구에서는 다중센서 자료를 이용하여 원거리에서 발생하는 기상현상의 발달과정을 판단 할 수 있는 알고리즘을 개발하고자 한다. 또한 이러한 원거리 입력자료

와 예측하고자 하는 값 사이의 비선형 상관관계를 연결시켜주는 기법의 도입이 필요할 것이다. 본 연구에서는 원거리 입력자료와 예측치 사이의 비선형 상관관계를 나타내는 방법으로 인공 신경망 기법을 사용하였다. 인공 신경망 기법은 모형계수들을 개선함으로서 일차원 혹은 다차원 자료간의 상관관계를 설정하는 기법이다.

현재 우리가 사용하는 신경망 기법은 McCulloch와 Pitts (1943)에 의하여 처음 수식화 되었으나 본 기법의 적용성이 증명되기까지 수자원 분야의 문제해결을 위한 사용은 늦추어져왔다. 그러나 신경망 기법의 적용에 대한 관심은 여러 분야에 있어 빠르게 증대되고 있으며 다음에서 언급되는 여러 수자원 분야의 문제해결에 탁월한 적용성이 입증되어 오고 있다: 강우 예측 (Kuligowski and Barros, 1998; Hall et al., 1999); 유출량 예측 (Shamseldin, 1997; Imrie et al., 2000; Chang and Chen, 2001); 홍수 예측 (Kim and Barros, 2001; 김성원 외, 2001); 토양 수분 예측 (김광섭, 이을래, 2004); 토네이도 예측 (Marzban and Gregory, 1996); 그리고 수질 예측 (Maier and Dandy, 1996) 등에 적용. 기존의 연구들은 신경망 기법이 수문현상들의 비선형 상관관계를 잘 나타내는 기법임을 보여주었다. 국내에서는 전경수와 김병익(2001)은 미국 기상청의 사례를 중심으로 돌발홍수 예경보 시스템을 고찰하여 최근 들어 발생빈도가 증가하는 돌발홍수의 예경보 시스템 구축 필요성에 대하여 논하였다. 특별히 우리나라에서 발생하는 홍수의 특성들 즉 도시주변지역의 개발사업으로 인한 유출특성의 변화 및 여름철에 집중되는 강우사상 등 여러 가지 복잡한 요소들 사이의 비선형 관계를 잘 나타낼 수 있는 기법임이 입증되었다. 오늘날 원격측정기술의 발달은 위성자료 및 다중센서자료를 이용한 원거리 기상현상 자료의 획득을 용이하게 하였고 이러한 정보의 사용은 보다 긴 홍수예경보시간 및 정확도를 가지는 강우량 예측 모형 개발에 대한 가능성을 제시하고 있으므로 이러한 정보를 사용하고 또한 정보간의 관계성을 보다 정확히 연계할 수 있도록 하는 것이 강우량 예측모형의 앞으로 나아가야 할 방향이라 판단된다 (Kim and Barros, 2001).

본 연구의 목적은 라디오존데로부터 관측되는 상층기상정보로부터 광역기상상태를 판단하고 기상상태에 반응하는 광역의 자동 기상 관측망 입력강우자료와 대상유역의 예측 강우량간의 비선형 상관관계를 잘 고려 할 수 있는 신경망 기법을 이용하여 보다 긴 예경보시간과 정확도를 가진 강우예측 모델을 개발하는 데에 있다. 개발된 강우 예측모형은 2002년 태풍 루사로 인하여 큰 피해를 입은 강천지역에 적용하였다.

2. 신경망 모형

전절에서 언급한 바와 같이 광역에서의 6시간 선행 강우정보와 대상유역의 면적강우량과의 선형상관관계는 상당히 낮으므로 이를 상호관계를 선형관계의 합으로 나타내는데 한계를 가진다. 그러므로 본 연구에서는 자료들간의 비선형 상관관계를 나타내는데 적합한 신경망 기법(Kim and Barros, 2001)을 이용하였다. 인공 신경망기법은 일차원뿐만 아니라 다차원 자료를 이용한 모형의 계수들에 대한 학습을 통하여 원하는 물리량을 산정하는 방법이다. 모형의 계수들로 주어진 입력자료로부터 출력자료로의 사상에 대한 가중치와 사상에 적용되는 함수에 내포된 계수들이 있다. 학습과정이란 이러한 다양한 계수들을 적용한 예측치의 오차를 최소화하는 과정으로 많은 수의 예측치와 관측치 쌍에 대한 적용을 통한 계수 산정과정이라 하겠다. 신경망 기법의 실제적인 장·단점에 대하여는 Maier and Dandy(1996) 및 Kuligowski and Barros(1998) 등 여러 연구자들에 의하여 논의되었고 특별히 Hassibi et al. (1994)은 신경망 기법이 비선형 상관관계를 가지는 여러 현상들에 대하여 왜 로버스트한 추정치가 되는지 이론적으로 규명하였다. 신경망모형은 예측하고자하는 물리과정의 완전한 이해가 없이도 자기 학습 특성으로 인하여 예측할 수 있음에도 불구하고 학습을 위하여 사용되는 자료와 자료들 사이의 상관관계에 대한 물리적 이해에 기초하여야 할 것이다. 그러므로 해결하고자하는 문제에 대한 신경망 기법의 적용에 있어 충분한 물리적 이해에

기초하여야 성공적인 예측치를 얻을 수 있을 것이다. 본 연구에서는 대상 유역에 대한 기상 시스템의 접근 방향에 따라 다른 모듈을 구성하고 이에 대한 신경망을 구성하고자 한다.

Fig. 1은 본 연구에서 사용될 입력층(input layer), 은닉층(hidden layer) 및 출력층(output layer)으로 구성된 3층 신경망의 기본구조이다. 신경망 계산의 기본 과정은 다음과 같다. 절점 j 에서 효과적인 수신 신호는 모든 입력 신호의 가중 합이다:

$$h_j = \sum_{i=0}^m w_{ji} r_i \quad (j = 1, 2, \dots, n) \quad (1)$$

여기서 m 은 입력층 절점 총 수, n 은 은닉층 절점 총 수, w_{ji} 는 i 에서 j 까지 경로에 부여된 가중치, r_i 는 unit i 로부터의 입력 값, h_j 는 은닉층의 unit j 에서 값이다. 다음으로, 조합된 신호가 출력 신호를 생성시키기 위해 변환함수(transfer function)에 의해 변환된다.

$$o_k = \sum_{j=1}^n w_{kj} f(h_j) = \sum_{j=1}^n w_{kj} f\left(\sum_{i=1}^m w_{ji} r_i\right) \quad (k = 1, 2, \dots, l) \quad (2)$$

여기서, f 는 선택된 변환함수를 나타내고, w_{kj} 는 j 에서 k 까지 경로에 부여된 가중치, o_k 는 네트워크 출력값, l 은 출력층 절점들의 총수를 나타낸다.

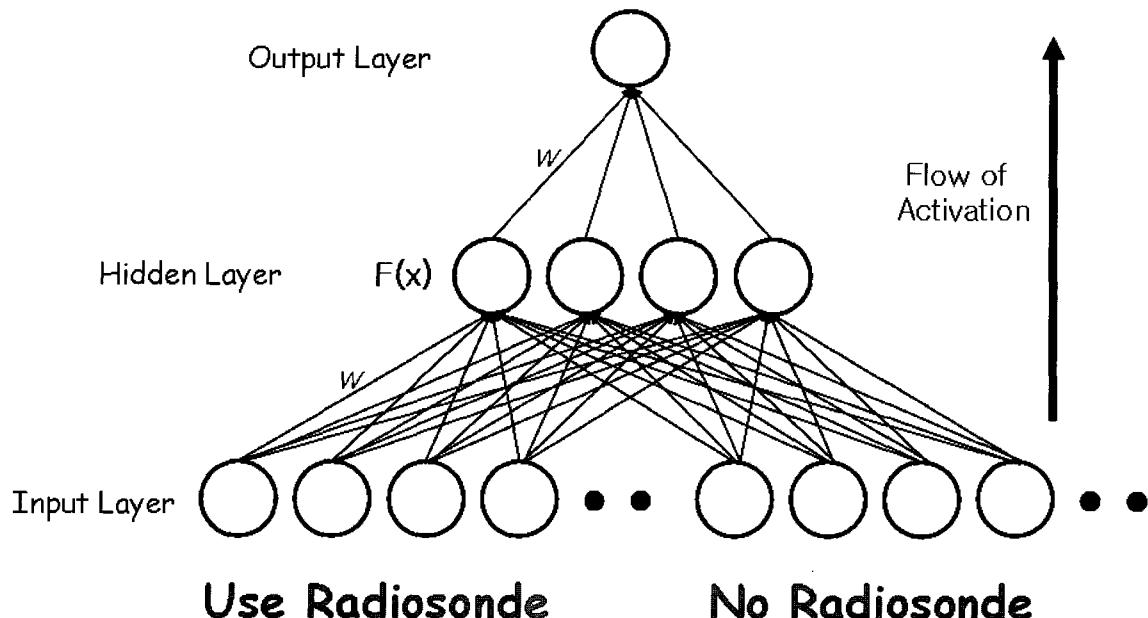


Fig. 1. Schematic of the configuration of the 3-layer artificial neural network

비선형 변환 함수(sigmoidal 함수)는 신경망에서 입력 데이터와 출력 데이터 사이에 비선형관계를 고려할 수 있도록 해 준다:

$$f(h) = \frac{2}{1+ae^{-h}} - 1 \quad (3)$$

여기서, h 는 절점 입력 값, $f(h)$ 는 절점 출력 값, a 는 입력 데이터의 비선형 거동을 고려하기 위해 사용된 증폭계수(gain)이다. training 과정은 출력에서의 평균 제곱 오차 E 를 최소화시키는 새로운 가중치들 집합을 결정하는 것으로 구성된다.

$$E = \sum_{k=1}^l (t_k - o_k)^2 \quad (4)$$

여기서, t_k 는 출력 절점 k 에서 얻고자하는 출력값이다.

변환함수가 비선형함수이기 때문에, 오차 E 는 가중치 w 의 비선형함수가 될 것이다. 최급강하법(steepest descent method)이 비선형 최소화 기법으로 채택되었다. 따라서, 가중치들은 다음과 같이 조정된다.

$$\begin{aligned} \Delta w &= -n' \frac{\partial E}{\partial w} = -(1-\beta) n' \frac{\partial E}{\partial w} + \beta(\Delta w)_{old} \\ &= n' \frac{\partial E}{\partial w_{ji}} + \beta(\Delta w)_{old} \end{aligned} \quad (5)$$

여기서, n' 는 가중치가 얼마나 빨리 바뀌는가를 네트워크에 말해주는 learning rate이고, β 는 가중치의 평균변화율이다. Momentum 부분 $\beta(\Delta w)_{old}$ 에는 지역 극소화를 막기 위해 가중치에 조정치를 더해 준다. n' 와 β 둘다 일반적으로 0과 1사이의 값을 가지고, 시행착오법에 의해 계산된다(Maier and Dandy, 1996).

본 연구에서는 먼저 라디오ゾン데 풍속 자료를 사용하여 원거리 기상상태의 이동 패턴에 따른 강우예측 신경망 모형을 구성하였다(Fig. 2). 개발된 신경망 모형은 입력층, 은닉층 및 출력층으로 구성된 multi-layered feed forward network을 형성하였으며 층간의 연결계수를 산정하기 위하여 역전파 알고리즘을 사용하였다. 입력층의 절점값은 강우자료이며 출력층의 절점값은 예측 강우량이 된다. 전절에서 언급한바와 같이 라디오ゾン데 풍향자료를 사용하여 8방향의 다른 각 모듈(NN₁, NN₂, ..., NN_n)에 대하여 학습을 수행하였으며 산정된 계수에 의하여 강우량을 산정하였다. 학습 수행의 효율성과 예측치의 정확도와 관련하여 은닉층의 절점 개수는 중요

한 변수이다. Fletcher and Goss (1993)은 $(2n+1)$ 에서 $(2n^{0.5}+m)$ 까지의 일반적인 은닉층 절점 개수 범위를 제시하였다. 여기서 n 은 입력층의 절점 개수이고 m 은 출력층의 절점 개수이다. 이것이 유용한 지침임에도 불구하고 본 연구에서는 가장 적합한 은닉층 절점 개수를 시행착오법을 이용하여 산정하였다. 본 연구에서 사용된 $n=17$, $m=1$ 이며 Fletcher와 Goss에 의해 제안된 식으로 계산한 은닉층 절점수는 35개에서 9개의 범위이다. 본 연구에서 사용된 은닉층 절점수는 18개이다.

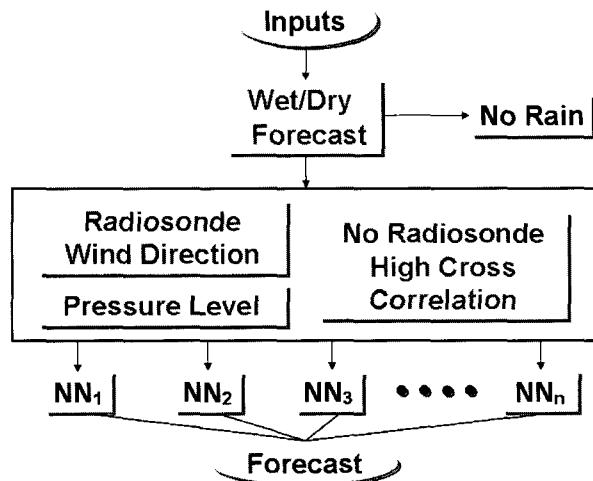


Fig. 2. Flowchart describing of the QPF model

3. 모형 적용

개발된 모형을 2002년 태풍 루사로 인하여 큰 피해를 입은 감천지역에 적용하였다. Fig. 3은 우리나라 수치지도 상에 나타낸 감천유역으로 동경 $127^{\circ}52'57''$ – $128^{\circ}06'24''$, 북위 $35^{\circ}50'45''$ – $36^{\circ}06'4'$ 에 위치하고 있으며 동쪽으로는 성주군, 칠곡군이 위치하고 있고, 서쪽으로는 전라북도 무주와 충청북도 영동군이 위치하며, 남쪽으로는 경상남도 거창군과 북쪽으로는 상주시 및 구미시가 인접하고 있다. 감천은 지방2급 하천으로 낙동강으로 유입되는 낙동강수계 제1지류이다. 하천의 하천연장은 28.5km이고 유로 연장은 30km이며 유역 면적은 325.3 km^2 으로 유역 형상은 우상과 수지상의 복합형상을 가지는 유역이다. 2002년 8월 30일부터 9월 1일 동안에 감천유역을 지나간 태풍 루사로 인한 피해는 6000여명의 이재민과 26명의 인명 피해를 포함하여 4000여억원의 재산피해를 발생시켰다. 개발된 모형이 감천 유역에 대하여 2002년 호우시기의 강수량을 잘 예측할 수 있는지에 대하여 모의 하였다.

감천지역에 대하여 라디오ゾン데 강우자료를 이용하여 적합한 모듈을 채택하고 각 모듈에 대한 신경망을 구성 강우 예측을 수행하였다. 개발된 모형이 이러한

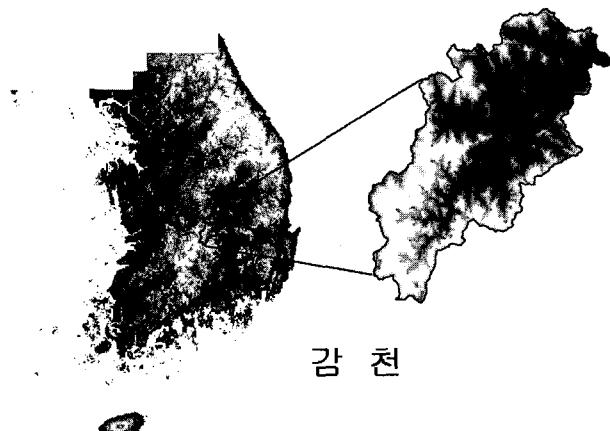


Fig. 3. Digital elevation map of Korea and target watershed (Ganchun watershed)

호우 사상에 대한 예측 개선을 위하여 호우를 동반한 강우 시스템의 이동양상을 분석하여 본 연구에서는 호우를 동반한 기상 시스템의 이동 방향을 잘 나타낼 수 있으리라 생각되는 우리나라 인접 라디오존데 관측망으로는 속초, 오산, 광주, 포항, 제주도, 후쿠오카가 있으며 각 라디오존데가 생산하는 900, 850, 750, 700, 650, 600, 500 mb 압력 레벨에서의 풍향자료를 사용하였다. 특별히 라디오존데 자료 중 대상유역의 강우이동을 가장 잘 나타내리라 판단되는 포항지역 라디오존데의 700mb 풍향자료를 사용하여 8방위로 구분하여 사용하였다(Fig. 4). 또한 그림 4에서 보는 바와 같이 700mb 상층 풍향 특성은 오산과 포항에서 비슷한 경향을 보여 준다. 이는 강우를 동반한 구름의 이동 방향이 서와 남서쪽에서 우세함에도 불구하고 대상유역과 가장 근접한 포항의 상층풍향 자료를 사용함이 타당함을 나타낸다.

각 모듈에 대한 신경망의 학습을 위한 입력 자료로 장기간의 매우 양호한 공간 분해능을 가지는 전국 자동 기상 관측망 자료가 필요함에도 불구하고 460여개의 전체 자동 기상관측망을 사용하기에는 자료기간의 한계를 가진다. 보다 정확한 강우 예측치를 가지기 위해서는 가능한 긴 학습기간을 가지는 것이 필요하다. 학습시간을 최대화 하기위하여 10년의 자료기간을 가지는 183개의 자동 기상관측망 자료를 사용하는 것이 타당하나 자동 기상관측망은 대상지역 주변 자료가 부족하다는 한계를 가지므로 5년의 자료기간을 가지는 350개의 자동 기상 관측망 자료를 사용하였다(Fig. 5).

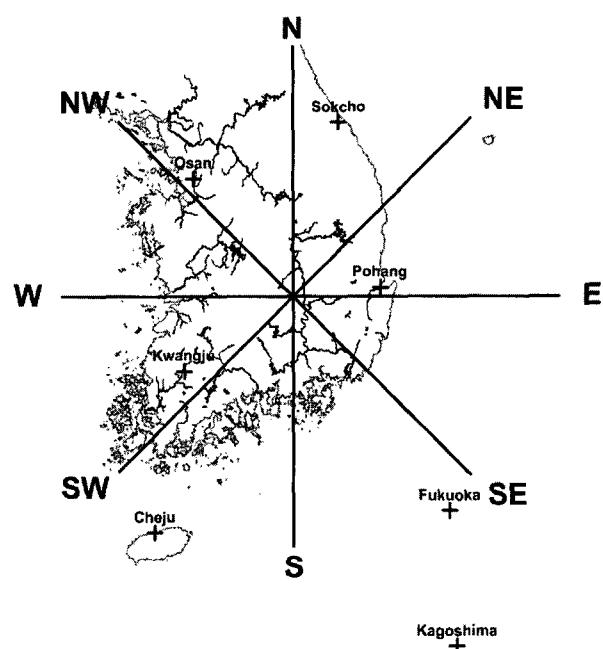


Fig. 4. Location of radiosonde network



Fig. 5. Location of rainfall gauges which have 10 year record and 5 year record

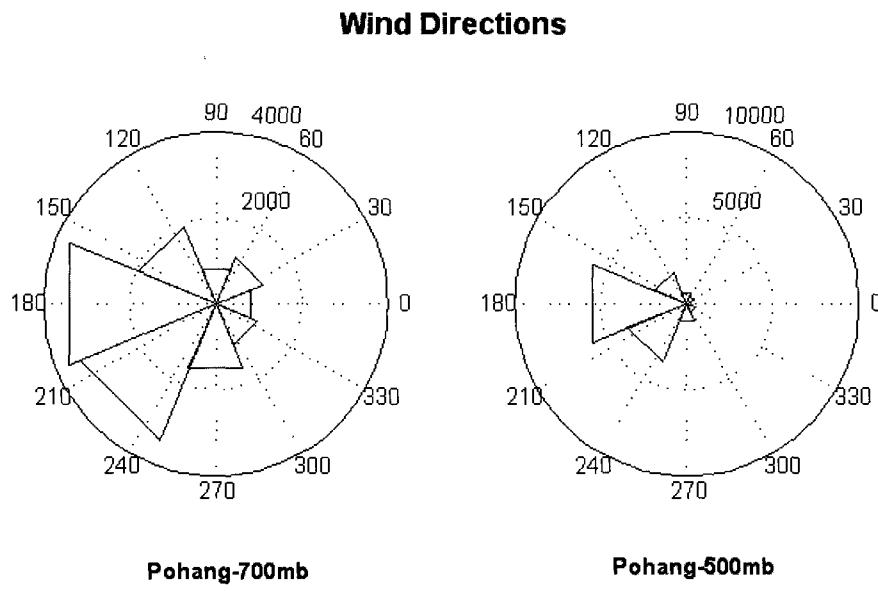


Fig. 6. Wind direction summary of Radiosonde at Pohang (700 mb, 500mb)

풍향자료는 8방향 즉 북: Dir-1, 북동: Dir-2, 동: Dir-3, 남동: Dir-4, 남: Dir-5, 남서: Dir-6, 서: Dir-7, 북서: Dir-8 방향에 대하여 각 45° 범위의 방향 범위를 각 모듈로 구분하여 신경망을 구성하였다. Fig. 6은 포항지역의 700mb와 500mb에서의 풍향자료의 평균값으로 강수를 동반한 시스템이 서쪽과 남서쪽에서 주로 대상유역으로 접근함을 알 수 있다. Table 1은 포항지역에서의 700mb 풍향자료에 따른 예측 선행 시간별 선행

강우에 대한 대상유역의 강우관측자료와 전국 자동 기상 관측망 자료 사이의 상관관계를 분석하여 제시하였다. 선택된 지상 관측자료는 신경망에서 입력층 자료를 형성한다. Fig. 7은 포항 라디오ゾ네의 700mb 풍향자료에 대한 6시간 예측 선행시간에 대하여 상층 풍향 8방향을 고려한 경우와 고려하지 않은 경우의 대상유역 평균 면적 강우량과 자동 기상 관측망의 강우량과의 상관관계 높은 상위 5개 지점에 대한 샘플 자동 기상 관

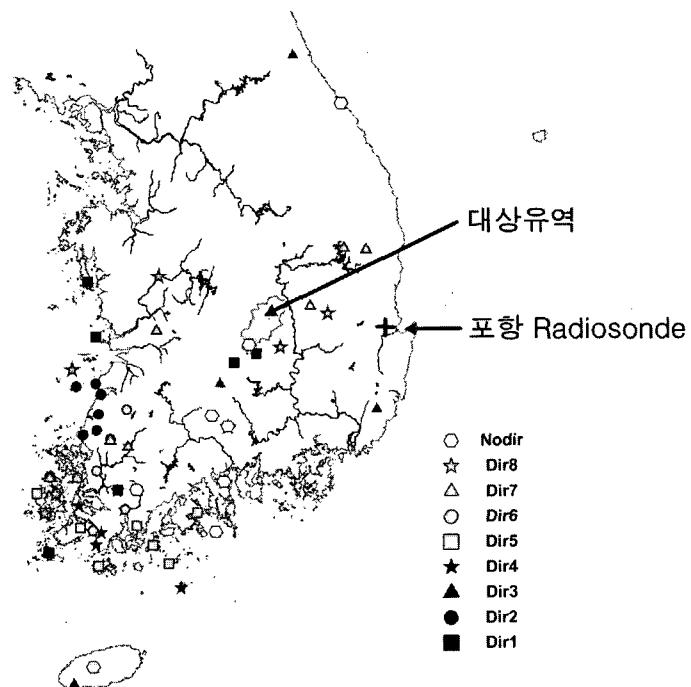


Fig. 7. Location of rainfall gauges used in the each module associated with the wind direction octant

Table 1. For forecast lead time, rain gauges used in the each module associated with 700mb wind direction data of the Pohang radiosonde. (CC: Correlation Coefficient)

St.#	C.C.	St.#	C.C.	St.#	C.C.	St.#	C.C.	St.#	C.C.	St.#	C.C.	St.#	C.C.	St.#	C.C.
Lead time =0															
Dir-1 Dir-2 Dir-3 Dir-4 Dir-5 Dir-6 Dir-7 Dir-8															
809	0.7755	809	0.8828	809	0.9653	809	0.9229	809	0.8548	945	0.7927	822	0.7707	945	0.8212
822	0.7469	945	0.815	822	0.9232	945	0.9216	945	0.8268	809	0.7802	809	0.7551	809	0.7593
945	0.7324	914	0.7746	945	0.9195	946	0.8655	822	0.7844	822	0.74	945	0.6884	822	0.702
810	0.719	946	0.7591	810	0.9109	735	0.8437	946	0.7523	946	0.651	810	0.6383	826	0.6923
912	0.6872	822	0.7547	824	0.8749	822	0.8403	735	0.6805	806	0.6041	806	0.6294	824	0.6691
Lead time =1															
Dir-1 Dir-2 Dir-3 Dir-4 Dir-5 Dir-6 Dir-7 Dir-8															
945	0.6868	701	0.7033	809	0.9254	912	0.8635	946	0.6725	946	0.5577	822	0.5843	809	0.6734
810	0.5917	809	0.6927	927	0.8818	945	0.8243	912	0.6687	809	0.5552	701	0.5807	810	0.6662
902	0.5773	758	0.6596	945	0.8654	759	0.8124	902	0.6565	759	0.5275	605	0.5719	825	0.6474
916	0.5673	757	0.6486	759	0.8623	902	0.8123	759	0.6547	902	0.5178	823	0.5577	728	0.6365
758	0.5632	711	0.6444	824	0.8572	946	0.8099	809	0.6459	758	0.508	647	0.5554	824	0.6323
Lead time =2															
Dir-1 Dir-2 Dir-3 Dir-4 Dir-5 Dir-6 Dir-7 Dir-8															
824	0.5492	788	0.6571	809	0.8676	902	0.784	902	0.5873	755	0.4908	605	0.5373	810	0.6543
810	0.544	711	0.6427	927	0.8549	912	0.7833	912	0.5452	768	0.4869	822	0.531	807	0.6063
619	0.5325	778	0.6402	759	0.8534	759	0.7756	768	0.543	759	0.4846	701	0.508	641	0.5996
825	0.5307	762	0.639	842	0.8321	906	0.7718	759	0.5415	741	0.4674	647	0.4999	736	0.5814
602	0.5118	722	0.6372	824	0.8244	933	0.7515	729	0.5217	902	0.4541	823	0.4867	800	0.5759
Lead time =3															
Dir-1 Dir-2 Dir-3 Dir-4 Dir-5 Dir-6 Dir-7 Dir-8															
825	0.5719	772	0.6423	759	0.831	902	0.7195	788	0.5025	902	0.4567	823	0.4532	946	0.6327
810	0.5676	762	0.6211	809	0.8074	759	0.6964	755	0.5001	768	0.4298	701	0.4288	823	0.6304
914	0.5437	701	0.6202	842	0.7979	770	0.6962	760	0.4967	755	0.423	836	0.4162	809	0.6252
832	0.5359	758	0.6176	927	0.7958	933	0.6944	741	0.4916	759	0.4185	775	0.41	821	0.6184
735	0.5008	757	0.6047	917	0.787	906	0.6882	730	0.4886	711	0.4102	806	0.4055	810	0.6097
Lead time =4															
Dir-1 Dir-2 Dir-3 Dir-4 Dir-5 Dir-6 Dir-7 Dir-8															
810	0.5603	772	0.5565	759	0.8068	765	0.6415	712	0.47	711	0.3995	823	0.4279	810	0.5853
735	0.5578	703	0.5329	750	0.7685	732	0.6393	778	0.4656	902	0.3864	707	0.4037	821	0.583
632	0.5429	717	0.525	932	0.7403	778	0.635	710	0.4645	774	0.3774	821	0.3924	946	0.577
946	0.5152	762	0.5236	914	0.7401	902	0.6273	748	0.4602	738	0.3538	701	0.3914	823	0.5548
825	0.4906	784	0.5172	809	0.7377	731	0.6087	765	0.4489	778	0.3494	742	0.384	626	0.5522
Lead time =5															
Dir-1 Dir-2 Dir-3 Dir-4 Dir-5 Dir-6 Dir-7 Dir-8															
735	0.6105	756	0.5814	759	0.7634	731	0.5832	732	0.445	774	0.3633	823	0.4219	705	0.5458
609	0.5909	719	0.5555	766	0.6838	777	0.5751	778	0.4384	902	0.3393	714	0.3846	809	0.5454
718	0.5393	704	0.5428	524	0.6827	778	0.5468	790	0.4268	778	0.3393	847	0.3783	902	0.5279
946	0.5364	705	0.5415	914	0.6826	745	0.5418	721	0.4246	789	0.3394	742	0.3558	800	0.5164
765	0.5173	775	0.5195	750	0.6807	732	0.5385	745	0.4207	711	0.3374	707	0.3516	612	0.5148
Lead time =6															
Dir-1 Dir-2 Dir-3 Dir-4 Dir-5 Dir-6 Dir-7 Dir-8															
719	0.6339	705	0.5562	759	0.7023	785	0.4946	777	0.4008	902	0.3529	714	0.3385	902	0.5503
946	0.5494	740	0.5039	524	0.6975	731	0.4646	721	0.3815	778	0.3201	823	0.3221	716	0.5452
718	0.5308	769	0.4756	753	0.6851	746	0.463	720	0.3751	785	0.3164	789	0.3201	766	0.513
772	0.5308	775	0.4596	554	0.6634	776	0.4591	767	0.3647	771	0.3045	775	0.3132	812	0.4967
945	0.5193	756	0.4412	752	0.6555	723	0.4591	743	0.3622	789	0.3044	763	0.3102	807	0.4769
Lead time =12															
Dir-1 Dir-2 Dir-3 Dir-4 Dir-5 Dir-6 Dir-7 Dir-8															
785	0.511	782	0.3926	753	0.6915	753	0.3966	753	0.2512	592	0.2202	742	0.1939	731	0.4155
732	0.4285	912	0.3899	752	0.5846	751	0.3892	752	0.2327	537	0.2165	714	0.1826	773	0.4137
720	0.4279	812	0.3895	727	0.5603	782	0.3867	724	0.2256	743	0.2106	614	0.1807	745	0.3918
750	0.4144	708	0.3813	715	0.5143	718	0.3352	727	0.1963	579	0.2082	762	0.1776	766	0.388
749	0.3803	810	0.3581	717	0.5005	781	0.3332	746	0.1849	584	0.2066	646	0.1658	778	0.3847

측망을 나타낸다. Fig. 7에서 보는 바와 같이 풍향을 고려한 경우 상관성이 높은 기상 관측소가 중복 되는 경우도 있으나 대부분 서로 다른 관측망을 보여준다. 이는 상층 풍향 정보를 사용할 경우 개선된 예측치를 얻을 수 있음을 나타낸다. 또한 강우를 동반한 시스템이 주로 남서쪽에서 이동하는 것을 보여준다.

모형 적용에 사용된 자료 기간은 2000년에서 2004년 까지의 6,7,8,9월 자료로 2000~2001년 및 2003~2004년의 4년간 자료는 모형 학습에 사용되었고 2002년에 대하여 예측하였다. Fig. 8은 대상유역의 6시간 선행 강우를 예측하기 위하여 persistence 예측을 한 경우와(Fig. 8a), 풍향자료 없이 자동 기상 관측망 자료만을 이용한 신경망 모형을 이용한 강우예측의 경우와(Fig. 8b) 라디오존데로부터 획득한 풍향자료와 자동 기상 관측망 자료를 사용한 신경망 모형에 의한 강우예측 경우를(Fig. 8c) 나타낸다. 결과는 상층기상자료를 사용하지 않고 예측한 결과에 비하여 개선된 강우 예측결과를 보여주었다. 예측모형이 개선된 결과를 보여줌에도 불구하고 과대추정에 의한 false alarm을 보여주는 이유는 본 모형이 선행시간 6시간 강우예측에 있어서 표현할 수 있는 모형능력의 한계이다. 모형의 예측 능력 판정을 위

한 정량적 통계치로 예측치와 관측치의 선형상관관계를 나타내는 상관계수 (correlation coefficient)와 persistence 예측에 대하여 평균제곱오차의 개선정도를 나타내는 숙련도 (skill score)를 제시하였다.

Table 2에 제시한 바와 같이 상층 풍향자료를 사용하지 않고 자동 기상 관측망 자료만을 사용한 신경망 모형의 예측은 persistence 예측보다 상관계수가 0.41에서 0.71로 개선되었으며 숙련도도 29%향상되었다. 또한 포항의 라디오존데로부터 획득한 상층 풍향자료와 자동 기상 관측망 자료를 사용한 경우는 persistence 예측보다 상관계수가 0.41에서 0.73으로 개선되었으며 숙련도도 35%향상되었다. 이는 상층기상자료가 가용할 경우 단지 자동 기상 관측망 자료만을 사용한 신경망 모형보다 개선된 예측 결과를 보여줄 수 있다. 그러나 모형의 개선 여지는 여전히 크게 존재하는바 가용한 자료의 기간이 증가되고 또한 인공위성자료 등 각종 센서 자료를 활용할 경우 예측성 향상을 기대할 수 있겠다. 개발된 강우예측모형은 기상이변의 증가와 함께 우리나라에서 빈번히 발생하는 호우에 기인한 대표적인 자연 재해의 하나인 홍수로 인한 인명피해 및 경제적 피해를 줄이고 방재, 수자원관리 및 계획에 크게 기여하리라

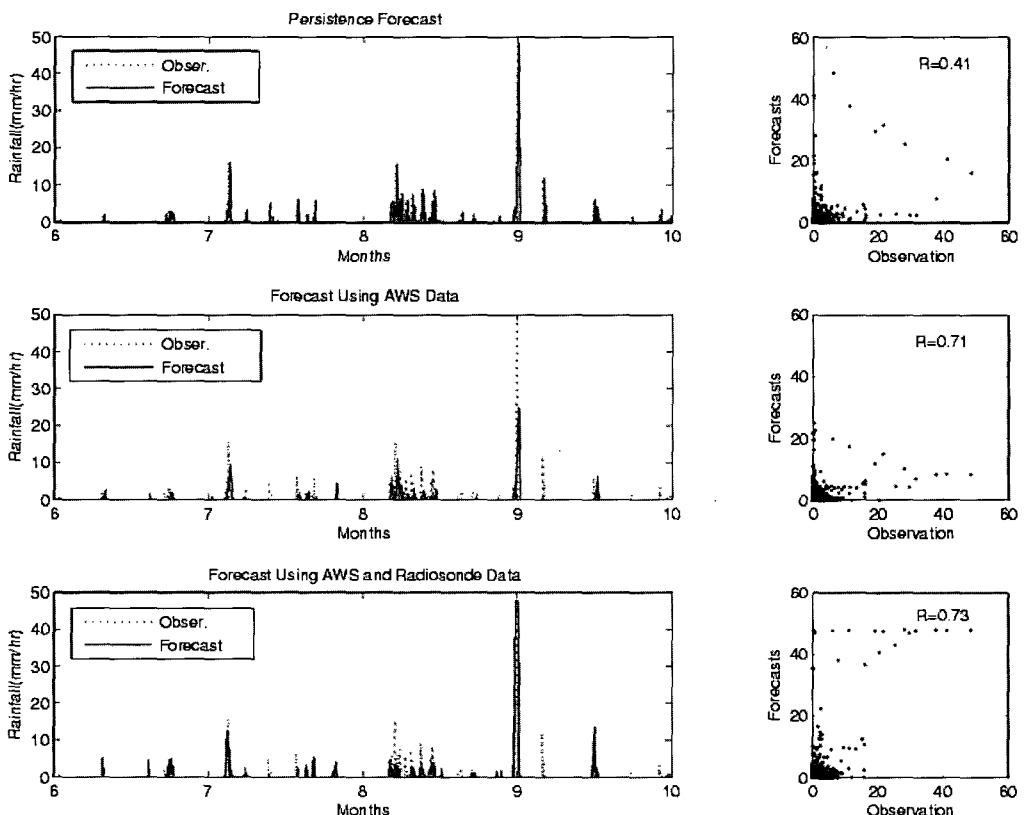


Fig. 8. Time series and scatter plots of 6 hour lead time forecasts and observation data at Gamchun from June, 2002 to September, 2002 (a) persistence forecast, (b) forecast using AWS data (c) forecast using AWS data and wind direction data of the radiosonde at Pohang

Table 2. Statistical performance measures of the QPF model (CC-correlation coefficient; SS-skill score)

Model	Correlation Coefficient	Skill Score
Persistence model	0.41	-
NN model using AWS data	0.71	29%
NN model using AWS and radiosonde data	0.73	35%

사료된다. 본 모형은 향후 호우로 인한 돌발 홍수 발생 등에 따른 수공구조물 위험도 분석 및 주민의 대피체계 확립 등의 종합 방재 업무시스템으로 확장가능하며 특히, 전국 홍수예보망 구축을 통해 중·소규모 유역과 도시유역에서의 침수예측과 재난업무 시스템으로 발전 시킬 수 있으리라 사료된다.

4. 결 론

본 연구에서는 신경망기법과 상층기상자료를 사용하여 단시간 강우 예측 모형을 개발하였다. 호우를 동반한 이송 기상 시스템의 이동 경로가 라디오존데로부터 획득할 수 있는 상층기상 자료 즉 상층 풍향자료와 동일한 방향으로 이동한다는 가정 하에 포항에서 획득한 700mb에서의 풍향자료를 사용하여 모형을 구성하였다. 장기간의 풍향자료를 이용하여 여름철 풍향자료에 따른 대상유역 면적평균 강우량과 자동 기상관측망의 강우자료와의 상관관계를 분석하여 반응 모듈을 구분하고 각 모듈에 대하여 신경망과 이에 따른 입력자료 구성하였다. 개발된 모형을 2002년 태풍 루사로 인하여 큰 피해를 입은 감천지역에 적용하였다. 감천지역에 대하여 라디오존데와 자동 기상 관측망 자료를 이용하여 적합한 모듈을 채택하고 각 모듈에 대한 신경망을 구성 예측을 수행하였다. 상층 풍향자료를 사용한 경우에 상관계수가 0.41에서 0.73으로 개선되었으며 숙련도도 35%향상되는 등 상층기상자료를 사용하지 않고 예측한 결과에 대하여 개선된 예측결과를 보여주었다. 개발된 강우예측모형은 기상이변의 증가와 함께 우리나라에서 빈번히 발생하는 호우에 기인한 대표적인 자연재해의 하나인 홍수로 인한 인명피해 및 경제적 피해를 줄이고 방재, 수자원관리 및 계획에 크게 기여하리라 사료된다.

감사의 글

이 논문은 2003년도 경북대학교 학술진흥연구비(KNURF)에 의하여 연구되었음.

참 고 문 헌

권원태, 최영은, 오재호, 민승기 (2003). “우리나라 기후 변화의 과거와 미래”, 한국수자원학회 학술발표 논

- 문집, 한국수자원학회, Vol. 1, pp. 463-466.
- 김광섭, 이을래 (2004). “신경망기법과 보조자료를 사용한 원격측정 토양수분자료의 Downscaling기법 개발”, 한국수자원학회논문집, 한국수자원학회, Vol. 37, No. 1, pp. 21-29
- 김성원, 이순탁, 조정식 (2001). “중소하천유역에서 Hybrid Neural Networks에 의한 수문학적 예측”, 한국수자원학회논문집, 한국수자원학회, Vol. 34, No. 4, pp. 303-316.
- 전경수, 김병익 (2001). “돌발홍수 예경보 시스템” 한국수자원학회지, 한국수자원학회, Vol. 34, No. 2, pp. 48-56.
- Chang, F., Chen, Y. (2001). “A counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction” *Journal of Hydrology*, Elsevier, Vol. 245, pp. 153-164.
- Fletcher, D.S., Goss, E. (1993). “Forecasting with neural networks: an application using bankruptcy data” *Information Management*, Elsevier, Vol. 24, pp. 159-167
- Hall, T., Brooks, H.E., Doswell C.A.III. (1999). “Precipitation forecasting using neural network” *Weather and Forecasting*, AMS, Vol. 14, pp. 338-345.
- Hassibi, B., Sayed, A.H., Kailath, T. (1994). “H optimality criteria for LMS and backpropagation” *Advances in Neural Information Processing Systems*, Morgan-Kaufmann, Vol. 6, pp. 351-359.
- Imrie, C.E., Durucan, S., Korre, A. (2000). “River flow prediction using artificial neural networks : generation beyond the calibration range” *Journal of Hydrology*, Elsevier, Vol. 233, pp. 138-153.
- Kim, G.S. and Barros, A.P. (2001). “Quantitative flood forecasting using multisensor data and neural networks” *Journal of Hydrology*, Elsevier, Vol. 246, pp. 45-62.
- Kuligowski, R.J. and Barros, A.P. (1998). “Experiments in short-term precipitation forecasting using artificial neural networks” *Monthly Weather Review*, AMS, Vol. 126, pp. 470-482.

- Maier, H.R., Dandy, G.C. (1996). "The use of artificial neural networks for the prediction of water quality parameters" *Water Resources Research*, AGU, Vol. 32, No. 4, pp. 1013-1022.
- Marzban, C., Gregory, J.S. (1996). "A neural network for tornado prediction based on Doppler radar derived attributes" *Journal of Applied Meteorology*, AMS, Vol 35, pp. 617-626.
- McCulloch, W.S., Pitts, W. (1943). "A logical calculus of the ideas immanent in nervous activity" *Bulletin of Mathematical Biophysics*, SMB, Vol. 5, pp. 115-133.
- Shanseldin, A.Y. (1997). "Application of a neural network technique to rainfall-runoff modeling" *Journal of Hydrology*, Elsevier, Vol. 199, pp. 272-294.

(논문번호:05-111/접수:2005.08.02/심사완료:2006.07.24)