

**중규모수치예보자료의 정량적 강수추정량 개선을 위한 인공신경망기법****Application of Artificial Neural Network to Improve Quantitative Precipitation Forecasts of Meso-scale Numerical Weather Prediction**

강 부 식\* / 이 봉 기\*\*

Kang, Boosik, / Lee, Bongki

**Abstract**

For the purpose of enhancing usability of NWP (Numerical Weather Prediction), the quantitative precipitation prediction scheme was suggested. In this research, precipitation by leading time was predicted using 3-hour rainfall accumulation by meso-scale numerical weather model and AWS (Automatic Weather Station), precipitation water and relative humidity observed by atmospheric sounding station, probability of rainfall occurrence by leading time in June and July, 2001 and August, 2002. Considering the nonlinear process of rainfall producing mechanism, the ANN (Artificial Neural Network) that is useful in nonlinear fitting between rainfall and the other atmospheric variables. The feedforward multi-layer perceptron was used for neural network structure, and the nonlinear bipolaractivation function was used for neural network training for converting negative rainfall into no rain value. The ANN simulated rainfall was validated by leading time using Nash-Sutcliffe Coefficient of Efficiency (COE) and Coefficient of Correlation (CORR). As a result, the 3 hour rainfall accumulation basis shows that the COE of the areal mean of the Korean peninsula was improved from -0.04 to 0.31 for the 12 hr leading time, -0.04 to 0.38 for the 24 hr leading time, -0.03 to 0.33 for the 36 hr leading time, and -0.05 to 0.27 for the 48 hr leading time.

**Keywords** : quantitative precipitation prediction, meso-scale numerical weather prediction, artificial neural network, COE, CORR

**요 지**

수문학적 예측에 있어서 강우수치예보의 활용성을 제고하기 위하여 인공신경망을 이용한 정량강수예측기법을 제시하였다. 본 연구에서는 2001년 6월과 7월, 2002년 8월의 중규모수치예보자료와 AWS의 3시간 누적강수, 상층기상관측소에서의 가강수량과 상대습도, 각 선행시간별 강수발생확률을 이용하여 각 선행시간에 따른 강수량을 예측하였다. 강수는 대기변수의 물리적 비선형조합으로 발생하기 때문에 강수에 영향을 미치는 대기변수와 관측강수사이의 비선형관계를 고려하는데 유용한 인공신경망기법을 이용하였다. 인공신경망의 구조는 전방향 다층퍼셉트론 (feedforward multi-layer perceptron)을 선택하였으며, 신경망의 학습 시 음의 강수모의값을 고려하여 무강수로 전환하기 위하여 비선형 양극 활성화함수를 사용하였다. 중규모수치예보모형과 인공신경망에서 예측된 강수량은 Nash-Sutcliffe Coefficient of Efficiency (NS-COE)와 Coefficient of Correlation (CORR)로 선행시간별로 통계분석을 실시하였다. 3시간 누적강수를 기준으로

\* 교신저자, 단국대학교 공과대학 토목환경공학과 부교수 (e-mail: bskang@dankook.ac.kr)

Corresponding Author, Associate Pfor., Dept. of Civil & Environmental Engineering Univ., Dankook Jookjeon-dong, Suji-gu, Yongin-si Gyeonggi-do 448-701, Korea

\*\* 도화종합기술공사 사원 (e-mail: leebk@dohwa.co.kr)

Dohwa Consulting Engineers CO.,LTD., Yeoksam-dong, Gangnam-gu, Seoul 135-080, Korea

NS는 한반도영역에서 평균적으로 선행시간이 12 hr인 경우 -0.04에서 0.31로, 선행시간이 24 hr인 경우 -0.04에서 0.38로, 선행시간이 36 hr인 경우 -0.03에서 0.33으로, 선행시간이 48 hr인 경우 -0.05에서 0.27로 증가하여, 강수예측의 정확도가 향상됨을 확인할 수 있었다.

**핵심용어** : 정량적강수예측, 증규모수치예보자료, 인공신경망, COE, CORR

## 1. 서 론

홍수에정보에 있어서 신뢰성있는 강수량의 예측은 가장 중요하면서도 어려운 부분이다. 우리나라의 경우 강수량의 예측은 전적으로 기상청의 강수예보에 의존하고 있지만 수문학적으로 강우-유출해석에 정량적으로 사용하기 위해서는 지역적 오차와 시스템오차를 제거하기 위한 적절한 후처리과정이 요구된다. 이를 위하여 본 연구에서는 기상청의 수치예보자료를 기반으로하여 PoP (Probability of Precipitation; 강수발생확률예측)과 모의신뢰도를 높이기 위한 QPF (Quantitative Precipitation Forecasts; 정량적 강수예측)기법을 제시하고자 한다. 이를 위해서 한국기상청에서 제공되는 2001년 6월과 7월, 2002년 8월의 증규모 수치예보자료와 AWS의 관측자료, 상층기상관측소의 관측값을 이용하여 제시된 모형의 검보정을 수행하였다. 대상영역으로는 한반도영역을 서울·경기지역, 강원지역, 충청지역, 전라지역, 경상지역으로 구분하여 인공신경망기법을 이용하여 QPF를 수행하였다.

QPF는 미국에서 90년대 중반부터 수문학적 하천유량예측에 활용되기 시작하였지만, 그 이전에 70년대부터 연구자들로부터 관심의 대상이 되기 시작하였다. Klein (1971)은 강수확률을 예측하기위하여 단계적 스크린회귀기법 (stepwise screening regression)을 사용하여 예측인자를 선정하고 다중회귀를 이용하여 강수확률을 예측하였으며, Glahn and Lowry (1972)는 MOS (Model Output Statistics) 기법을 이용하여 강수확률을 예측하면서 통계모형을 이용하여 예측인자와 예측변수사이의 편이보정 (bias correction)을 수행할 수 있는 체계를 제시하였다. Wilks (1989)는 강수확률과 조건부 강수모형을 이용하여 확률적 강수예측모형을 수립하였다.

수문기상분야에서의 인공신경망기법은 1990년대부터 기상과 관련된 다양한 문제를 해결하기 위하여 사용되어 왔다. Kuligowski and Barros (1998)는 강우수치예보를 기반으로 인공신경망을 이용하여 국부지역에서의 강수예측을 시도하였다. 이들 (Kuligowski et al.; 1998)은 일반적으로 인공신경망기법이 선형회귀보다 낮은 평균제곱근오차 (root mean square error)와 계통적 오차 (systematic error)를 보이고 있음을 설명하였다. 유사한 사례로 Hall et al

(1999)은 Dalas-Fort Worth지역에서 인공신경망기법을 이용하여 강수발생확률과 정량적 강수예측을 수행하였다. Schoof and Pryor (2001)는 다중회귀와 인공신경망기법을 이용하여 온도와 강수의 예측성과를 비교하였다. Valverde Ramirez and Campos Velho (2005)는 Kuligowski et al. (1998)에서 더 나아가 인공신경망과 다중회귀를 비교하였다. 그는 브라질 상파울로지역에서 강우예측을 위한 인공신경망과 다중선형회귀모형을 비교·연구한 결과 인공신경망이 다중 선형 회귀모형보다 신뢰성이 있음을 나타내었다. 국내에서는 김호준 등 (2001)은 신경망기법을 이용하여 장기 강수량예측 연구를 행하였으며, 안중배 등 (2003) 인공신경망 모형을 이용한 기온과 강수량의 규모축소연구, 차유미와 안중배 (2005)는 여름철 강수에 대한 인공신경망 보정 능력평가 연구를 수행하였다.

본 연구에서는 한반도영역을 대상으로 정량강수추정을 위하여 예측인자로 증규모 수치예보자료중 500/750/1000 hPa에서의 지위고도, 500-1000 hPa의 층후, 500/750 hPa/지표면에서의 온도, 500 hPa과 750 hPa에서의 X (혹은 Y) 방향의 바람성분, 지표면 풍속, 평균해면기압, 3시간 누적강수, AWS의 관측강수, 상층기상관측소 (upper-air sounding)에서의 가강수량과 상대습도, 인공신경망에서 계산된 강수발생확률을 이용하여 정량적강수량을 추정하였다. 또한 각 지역별로 전방향 신경망을 설정하고, 학습방법으로는 역전파알고리즘 (back-propagation)을 선택하였다. 각 레이어로부터의 출력값을 스케일링하기위하여 활성화함수를 사용하는데, 본 모형에서는 가장 일반적 형태의 일중인 양극 활성화함수 (bipolar activation function)를 사용하였다.

## 2. 인공신경망을 이용한 정량적 강수추정

### 2.1 인공신경망 개요

인공신경망은 시냅스의 결합으로 네트워크를 형성한 인공 뉴런 (노드)이 학습을 통해 시냅스의 결합 세기를 변화시켜, 문제 해결 능력을 가지는 모델 전반을 가리킨다. 인공신경망에는 교사 신호 (정답)의 입력에 의해서 문제에 최적화되어 가는 교사 학습과 교사 신호를 필요로 하지 않는 비교사 학습이 있다. 명확한 해답이 있는 경우에는

교사 학습이, 데이터 클러스터링에는 비교사 학습이 이용된다. 결과적으로 모두 차원을 줄이기 위해, 화상이나 통계 등 다차원량의 데이터로, 선형 분리 불가능한 문제에 대해서, 비교적 작은 계산량으로 양호한 회답을 얻을 수 있는 것이 많다. 그 때문에, 패턴 인식이나 데이터 마이닝 등, 다양한 분야에서 응용되고 있다.

인공신경망은 좁은 의미에서 오차역전파법 (Back-Propagation)을 이용한 다층퍼셉트론 (Multi-Layer Perceptron)을 가리키기도 한다. 정량적 강수량을 추정하기 위해서 본 연구에서도 입력층, 은닉층, 출력층으로 구성되는 다층퍼셉트론 (Multi-Layer Perceptron)의 구조를 선택하였다 (Fig. 1). 강수는 다양한 기상변수의 비선형조합으로 발생되기 때문에 활성화함수로 양극 활성화함수를 사용하여 강수량은 -1에서 1사이로 스케일링되도록 설정하여, 독립변수가 0값에 가까우면 출력되는 종속변수는 급격하게 변하게 되어 독립변수의 다양한 출력값을 고려하는 동시에 음의 출력값은 무강수를 판단하였다.

인공신경망은 입력자료와 각 층사이의 가중치벡터 (weight vector)와 입력벡터의 내적의 가중합을 활성화함수의 독립변수로 활용함으로써 각각의 뉴런의 출력값을 얻는다. 다층 인공신경망은 입력층(input layer), 하나 이상의 은닉층(hidden layer)과 출력층(output layer)으로 구성되어 있기 때문에 입력값 ( $x_i$ )과 입력층과 은닉층사이의 가중치벡터 ( $w_{hi}$ )의 가중합의 내적이 활성화함수를 통과함으로써 출력되는 출력값 ( $f(S_{kh})$ )이 다시 입력벡터 ( $w_k$ )가 되어 은닉층과 출력층사이의 가중치 ( $w_{kh}$ )벡터의 내적의 가중합이 출력층에서의 활성화함수를 통하여 출력값 ( $f(S_{kh})$ )을 출력하게 된다 (정슬, 2004). 본 연구에서는 역전파알고리즘(Back-Propagation)을 이용하여 입력값 ( $x_i$ )과 출력값 ( $f(S_{kh})$ )사이의 비선형적관계를 학습하였다. 정량강수량추정을 위하여 인공신경망의 계산과정은 크게 2가지로 나눌 수 있다. 첫 번째 단계에서는 전방향계산




Fig. 1. Conceptual Diagram of Artificial Neural Network

(Feedforward pass phase)을 통하여 입력값(예측인자)의 패턴과 각 층사이의 가중치와 활성화함수를 통하여 출력값(예측변수)을 예측한다 (Eqs. (1)~(4)).

$$S_{hi} = \sum_h w_{hi}x_i \quad (1)$$

$$f(S_{hi}) = \frac{e^{S_{hi}} - e^{-S_{hi}}}{e^{S_{hi}} + e^{-S_{hi}}} = y_h \quad (2)$$

$$S_{hi} = \sum_h w_{hh}y_h \quad (3)$$

$$f(S_{kh}) = S_{hi} = y_k \quad (4)$$

두 번째 단계에서는 후방계산 (Backward pass phase)을 통하여 원하는 목표값 (관측강수)과 출력값(예측변수)사이의 오차를 이용하여 각 층사이의 가중치를 변화(연결강도의 변화)시키면서 출력값과 목표값사이의 오차감소를 시킨다. 이러한 일련의 과정을 인공신경망의 학습 (training 혹은 learning)이라한다. 본 연구에서는 목표값과 출력값(예측변수)사이의 오차 (Eq. (5))를 이용하여 오차함수 (error function)를 계산하기 위해서 오차의 제곱합 (sum of squared error)을 사용하였다 (Eq. (6)). 역전파알고리즘을 학습방법으로 사용하기 위해서는 활성화함수 (Activation function)로서 반드시 미분이 가능한 연속형함수를 사용하여야 하며, 가중치에 대한 오차의 변화율을 이용하여 오차가 최소값을 갖도록 하는 경사하강법 (gradient decent)을 사용하여 가중치의 변화량을 계산하게 된다 (Gupta, 2003)(Eqs. (7) and (8)).

$$e_k = d_k - y_k \quad (5)$$

$$E = \sum_k e_k^2 \quad (6)$$

$$w_{kh}(t+1) = w_{kh}(t) + \Delta w_{kh} + \alpha [w_{kh}(t) - w_{kh}(t-1)] \quad (7)$$

$$w_{hi}(t+1) = w_{hi}(t) + \Delta w_{hi} + \alpha [w_{hi}(t) - w_{hi}(t-1)] \quad (8)$$

여기서,  $d_k$ 는 목표값,  $y_k$ 는 출력값(예측변수),  $\alpha$ 는 모멘텀 (momentum)으로서 ( $t-1$ ) 단계에서의 가중치의 변화량이  $t$ 단계의 가중치 변화량에 영향을 미치는 정도를 고려하기 위한 상수,  $w_{kh}(t+1)$ (혹은  $w_{hi}(t+1)$ )은 ( $t+1$ ) 시간에서의 출력층(혹은 은닉층)과 은닉층(혹은 입력층)사이의 가중치변화이다.

## 2.2 예측인자의 구성

인공신경망의 예측인자로 사용된 자료는 한국기상청 (KMA)에서 제공되어진 2001년 7월, 8월 과 2002년 6월의 RDAPS모형의 수치예보자료, AWS 관측자료, 상층기상관

측소의 자료를 이용하였다. 본 연구에서 사용된 RDAPS의 예보시간은 하루에 2회씩 (00UTC, 12UTC) 3시간 단위로 생산되며, 예측시간은 한번 관측할 때 마다 48시간까지의 예보를 제공하고 있다. RDAPS 모형의 예측값은 3시간 단위로 생성되기 때문에 예측인자의 데이터구성을 위해 AWS 관측강수를 3시간 단위로 누적하여 배열하였으며, 또한 단위면적당 연직대기층사이의 수증기 함유량인 가강수량(precipitable water)을 예측인자로 활용하기 위하여, 상층기상관측소(upper-air sounding)에서 관측된 관측값들을 이용하였다. Fig. 2는 RDAPS 모형격자, AWS관측소, 상층기상관측소의 위치(백령도, 오산, 속초, 포항, 광주)를 설명하고 있다. 가강수량을 추정하기 위해서는 물의 증발과정에서의 잠재열, 수증기기체상수와 이슬점온도를 이용하여 증기압(vapor pressure)을 계산(Eq. (9))하고, 계산된 증기압과 대기압을 이용하여 비습도(specific humidity)(Eq. (10))를 산정한다. 가강수량은 일정고도 사이에서의 증력에 대한 비습도의 합과 같다(Eq. (11)) (Bras, 1990).

$$e = 611 \exp\left(\frac{L_v}{R_v} \left(\frac{1}{273.15} - \frac{1}{T_d}\right)\right) \quad (9)$$

$$q_h = \frac{0.622e}{p - 0.378e} \approx 0.622 \frac{e}{p} \quad (10)$$

$$w_p = \frac{1}{g} \int_p^{p_0} q_h dP \quad (11)$$

여기서,  $e$ 는 증기압,  $L_v$ 는 물의 증발과정에서의 잠재열

( $2.5 \times 10^6 \text{ J/kg}$ ),  $R_v$ 는 수증기 기체상수 ( $461.5 \text{ J/K/kg}$ ),  $T_d$ 는 이슬점 온도(K),  $q_h$ 는 비습도,  $P$ 는 대기압,  $p_0$ 와  $p$ 는 고도  $z_1$ 과  $z_2$ 에서의 압력,  $w_p$ 는 가강수량(mm)이다.

먼저 정량강수를 추정하기 위하여, 인공신경망을 2단계로 나누어 학습을 하였다. 첫 번째 단계에서는 RDAPS 모형의 예측값, AWS 관측강수, 상층기상관측소의 자료 (Table 1)를 이용하여 강수발생확률 (PoP; Probability of

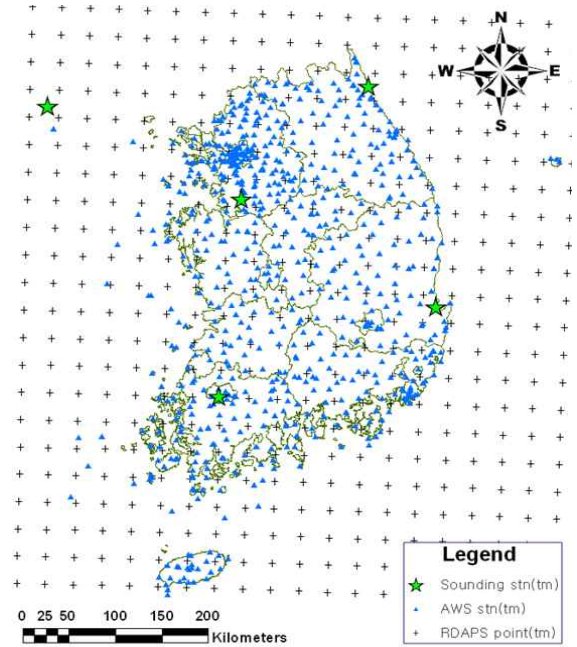


Fig. 2. Location of RDAPS Grid Point, AWS, Upper Air Sounding Stations

Table 1. Predictor Variables Used in ANN Model

Input Variables	Source
• Geopotential height 500/750/1000 hPa [m]	RDAPS
• Atmospheric thickness 500 hPa - 1000 hPa [m]	RDAPS
• X, Y-component of wind at 500 hPa [m/s]	RDAPS
• X, Y-component of wind at 750 hPa [m/s]	RDAPS
• Wind speed at surface [m/s]	RDAPS
• Temperature at 500/750 [hPa]/ surface [°K]	RDAPS
• Mean sea level pressure [hPa]	RDAPS
• 3-hr accumulated precipitation [mm/(3hr)]	RDAPS
• Precipitation accumulated in 6 [mm/(6hr)] & 12 [mm/(12hr)] hs previous to RDAPS run	AWS
• Relative humidity measured 0 & 12 hs before RDAPS run	Upper-air sounding
• Precipitable water measured 0 & 12 hs before RDAPS run [mm]	Upper-air sounding
• Precipitable water difference in 12 hs previous to RDAPS run [mm]	Upper-air sounding
• Probability of Precipitation	PoP ANN
Output Variable	Source
• Quantitative Precipitation Forecasts [mm/(3hr)]	QPF ANN

Table 2. PoP Evaluation for RDAPS and ANN Model

	Hit rate		KSS		CSI		POD	
	RDAPS	ANN	RDAPS	ANN	RDAPS	ANN	RDAPS	ANN
Seoul·Gyeonggi	0.72	0.77	0.28	0.52	0.30	0.55	0.31	0.71
Gangwon	0.63	0.73	0.17	0.44	0.21	0.52	0.22	0.69
Gyeongsang	0.63	0.67	0.19	0.34	0.22	0.47	0.24	0.64
Jeolla	0.73	0.76	0.22	0.38	0.24	0.45	0.26	0.62
Chungcheong	0.69	0.70	0.25	0.46	0.27	0.48	0.30	0.64

Precipitation)을 예측하였으며, 예측정확도의 질을 평가하기 위하여 적중률 (Hit rate; H), Kuipers Skill Score (KSS), 임계성공지수 (Critical Success Index; CSI), 탐지확률 (Probability of Detection; POD)을 이용하여 강수발생확률을 검정하였다 (Wilks, 1995). Table 2는 각 지역별 인공신경망 기법의 적용 전·후의 평가점수를 설명하고 있다. 검정된 강수발생확률은 두 번째 단계에서의 예측인자로 구성되어 정량강수 (Quantitative Precipitation Forecasts)를 추정하기 위한 예측인자로 구성되어진다.

### 2.3 통계적 검증

인공신경망에서 예측된 강수량은 중규모수치예보모형의 3시간 누적강수를 상관계수(CORR; Coefficient of Correlation)와 Nash-Sutcliffe Coefficient of Efficiency (NS-COE)로 선행시간별로 통계분석을 실시하였다. CORR은 예측강수와 관측강수사이의 상관성을 분석하기 위하여 사용되며, 예측강수와 관측강수가 일치하는 경우, 1값을 가진다 (Eq. (12)). Nash and Sutcliffe (1970)은 관측유량과 모의유출량의 관계를 이용하여 모형의 효율을 계산하였지만, 본 연구에서는 유량대신 예측한 강수와 관측강수사이의 관계를 이용하여 모형의 효율을 계산하였다. COE는  $-\infty \sim 1$  사이의 값을 가지며, 인공신경망에서 예측된 강수와 관측강수가 일치할 경우 1값을 가지며, COE가 0에 가까우면 예측된 강수와 관측값의 평균이 정확하게 일치하는 것을 말한다. 만약 예측된 강수량이 관측강수의 평균보다 큰 경우 COE는  $-\infty \sim 0$  사이의 값을 가진다. COE의 수학적 방정식은 Eq. (13)과 같다.

$$CORR = \frac{\sum_{t=1}^T (F_m^t - \bar{F}_m)(O_0^t - \bar{O}_0)}{\sqrt{\sum_{t=1}^T (F_m^t - \bar{F}_m)^2} \sqrt{\sum_{t=1}^T (O_0^t - \bar{O}_0)^2}} \quad (12)$$

$$COE = 1 - \frac{\sum_{t=1}^T (O_0^t - F_m^t)^2}{\sum_{t=1}^T (O_0^t - \bar{O}_0)^2} \quad (13)$$

여기서,  $F_m^t$ 은 시간 t에서의 신경망 학습후의 예측강수,  $\bar{F}_m$ 은 신경망 학습후의 평균 예측강수,  $O_0^t$ 는 시간 t에서의 관측강수,  $\bar{O}_0$ 는 평균관측강수이다.

본 연구에서는 수치예보모형의 선행시간에 따른 예측값을 비교하기 위하여, 선행시간 (lead time)을 12 hr, 24 hr, 36 hr, 48 hr로 구분하여 시계열로 작성하였다. 또한 누적시간에 따른 통계적 특성의 변화를 알아보기 위하여 누적시간을 3시간, 6시간, 9시간, 12시간, 24시간 48시간으로 구분하여 COE와 CORR를 비교 하여보았다 (Table 3(a)~(d)). 한반도영역에서는 24hr 선행시간에서 검증계수가 가장 양호하게 나타나는데, 이때 신경망예측값의 평균 COE가 0.38, CORR이 0.64로 나타났다. 강수수치예보의 정확도가 12hr이 아닌 24hr에서 가장 크게 나타난 것은 이것이 예측선행시간에 반드시 역비례하지 않는다는 것을 보여주며, 이는 스핀업의 영향으로 보여진다. RDAPS의 경우 누적시간이 길어질수록 COE가 작아지지만, 이와는 반대로 신경망예측의 경우 누적시간이 길어질수록 COE가 향상되고 있다. 따라서 인공신경망을 이용하여 강수량을 추정하는 경우, 누적시간에 따라 강수량값의 신뢰도가 높아짐을 확인할 수 있다.

### 3. 정량적 강수추정도의 평가

정량적인 3시간 누적강수를 비교하기 위하여, 인공신경망으로 예측된 3시간 누적강수, 중규모수치예보모형의 3시간 누적강수, AWS에서 관측된 3시간 누적강수를 비교하였다. Figs. 3~7은 선행시간에 따른 시계열 분류의 4가지 방법을 이용하여 2001년 7월 8일부터 2001년 8월 20일까지 시계열로 도시하였다. 서울·경기지역에서는 인공신경망의 학습결과 Fig. 3(a)에서 RDAPS의 예측강수량은 42 mm, 인공신경망에서 예측된 강수총량은 299 mm, 총 관측강수량은 623 mm로 신경망 학습결과 강수량이 257 mm 증가하였으며, CORR이 0.67로 가장 높게 나타났다. Fig. 3(d)의 경우, 관측강수의 시계열과 신경망에서 예측된 강수와 비교해보았을 때 다른 선행시간의 시계열에

**Table 3. Simulation Performance by the Forecast Lead Time and Accumulation Time**

(a) 12 hr Lead Time

Accumulation time		3 hr	6 hr	9 hr	12 hr	24 hr	48 hr
RDAPS	COE	-0.04	-0.06	-0.07	-0.09	-0.14	-0.28
ANN	COE	0.31	0.39	0.46	0.46	0.52	0.50
RDAPS	CORR	0.41	0.47	0.53	0.54	0.61	0.64
ANN	CORR	0.59	0.66	0.73	0.73	0.79	0.82

(b) 24 hr Lead Time


Accumulation time		3 hr	6 hr	9 hr	12 hr	24 hr	48 hr
RDAPS	COE	-0.04	-0.05	-0.06	-0.08	-0.14	-0.23
ANN	COE	0.38	0.43	0.48	0.48	0.55	0.57
RDAPS	CORR	0.40	0.45	0.49	0.49	0.61	0.72
ANN	CORR	0.64	0.68	0.74	0.74	0.81	0.86

(c) 36 hr Lead Time


Accumulation time		3 hr	6 hr	9 hr	12 hr	24 hr	48 hr
RDAPS	COE	-0.03	-0.04	-0.05	-0.07	-0.12	-0.22
ANN	COE	0.33	0.38	0.49	0.49	0.52	0.54
RDAPS	CORR	0.40	0.46	0.52	0.51	0.60	0.69
ANN	CORR	0.60	0.64	0.74	0.74	0.79	0.85

(d) 48 hr Lead Time


Accumulation time		3 hr	6 hr	9 hr	12 hr	24 hr	48 hr
RDAPS	COE	-0.05	-0.06	-0.08	-0.09	-0.15	-0.30
ANN	COE	0.27	0.32	0.33	0.36	0.38	0.35
RDAPS	CORR	0.37	0.42	0.48	0.47	0.59	0.61
ANN	CORR	0.54	0.61	0.64	0.69	0.77	0.79




(a) Forecasting with 12 hr Lead Time



(b) Forecasting with 24 hr Lead Time




(c) Forecasting with 36 hr Lead Time




(d) Forecasting with 48 hr Lead Time


**Fig. 3. Forecast with Different Lead Time in Seoul/Gyeonggi Region**



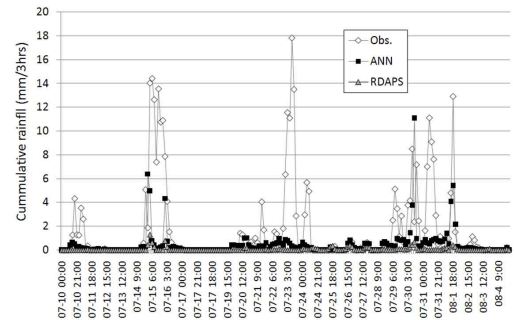
(a) Forecasting with 12 hr Lead Time



(b) Forecasting with 24 hr Lead Time




(c) Forecasting with 36 hr Lead Time




(d) Forecasting with 48 hr Lead Time


Fig. 4. Forecast with Different Lead Time in Gangwon Region




(a) Forecasting with 12 hr Lead Time



(b) Forecasting with 24 hr Lead Time



(c) Forecasting with 36 hr Lead Time




(d) Forecasting with 48 hr Lead Time


Fig. 5. Forecast with Different Lead Time in Chungcheong Region

비하여 강수모의값이 다소 낮게 예측되었으며, 통계적 분석결과도 NS가 0.14, CORR이 0.45로 가장 낮게 나타났다.


강원지역에서는 인공지능망의 학습결과 Fig. 4(b)에서 RDAPS의 예측강수량은 26 mm, 인공지능망에서 예측된




(a) Forecasting with 12 hr Lead Time



(b) Forecasting with 24 hr Lead Time



(c) Forecasting with 36 hr Lead Time



(d) Forecasting with 48 hr Lead Time

Fig. 6. Forecast with Different Lead Time in Jeolla Region

강수총량은 237 mm, 총 관측강수량은 408 mm로 총 강수량의 예측에 있어서 다른 선행시간의 모의값보다 향상된 결과를 보이고 있으며, 신경망 학습 후 COE가 -0.06에서 0.38, CORR이 0.51에서 0.63으로 향상되었다. 강원지역에서는 예측강수의 시계열이 관측강수의 시계열을 잘 모의하고 있으나, 선행시간이 48 hr인 경우 COE가 0.08, CORR이 0.37로 다른 선행시간에 비하여 낮은 통계적 특성을 나타내고 있으며, 낮은 모의시계열을 나타내고 있다.

충청지역에서는 선행시간이 36 hr인 경우와 선행시간이 48 hr인 경우에 관측강수의 시계열을 잘 모의하는 것을 확인할 수 있다 (Fig. 5(c) and 5(d)). 인공신경망의 학습결과 Fig. 5(c)에서 총 관측강수량은 325 mm, RDAPS의 예측강수량은 30 mm, 인공신경망에서 예측된 강수총량은 229 mm로 199 mm의 강수량이 증가하였으며 COE가 0.61, CORR이 0.80으로 다른 지역에 비하여 우수한 통계적 특성을 가지고 있다. Fig. 5(a)와 5(b)는 선행시간이 36 hr과 48 hr에 비하여 예측된 강수량은 작지만, 관측강수의 시계열을 잘 모의하고 있다. 선행시간이 12 hr인 경우에 COE는 -0.06에서 0.51로 향상되었으며 CORR은 0.24에서 0.76으로 향상되었다. 선행시간이 24 hr인 경우에 COE는 -0.06에서 0.59로 향상되었으며 CORR은 0.19에서 0.83으로 향상되었다.

전라지역에서는 선행시간이 36 hr인 경우 (Fig. 6(b)),


강수총량은 282 mm이며 중규모수치예보모형의 예측값은 24 mm로 과소예측을 하는 경향을 보이고 있으나, 인공신경망의 학습결과 135 mm로 강수량이 121 mm로 증가하였다. 신경망 학습후 선행시간이 12 hr인 경우 COE가 0.10, CORR이 0.38로 나타났으며, 선행시간이 36 hr인 경우 COE는 0.17, CORR이 0.46, 선행시간이 48 hr의 경우 COE는 0.21, CORR이 0.49로 나타났다. 전라지역은 서울·경기지역, 강원지역, 충청지역, 경상지역과 비교하였을 때, 낮은 통계적 특성을 가지고 있다. 신경망은 목표값과 출력값 사이의 오차를 감소시키고 일반화시키기 위하여, 예측인자를 케이스별로 학습·선택 : 검정의 비율을 2 : 1 : 1로 구분하게 되는데, 전라지역에서는 예측변수와 목표값 사이의 선택오차가 0.216, 검정오차가 0.238로 오차가 0.022인 서울·경기지역, 강원지역, 충청지역과 비교하여 큰 오차를 가지고 있기 때문에 관측값과 모의값의 선행시간별 시계열형상을 잘 모의하지 못하는 것으로 판단된다 (Fig. 6). 이는 태풍과 돌발홍수의 빈도가 잦은 지역적 특성이 원인일 수 있으나, 단순한 자료신뢰도의 문제인지 물리적 원인이 있는지 여부에 대한 추가적인 연구가 필요하다.

경상지역에서는 선행시간이 12 hr인 경우 (Fig. 7(a)), 자료기간동안의 총관측강수량은 243 mm, RDAPS의 예측강수량은 24 mm였지만 신경망의 학습을 통하여 128 mm가




Table 4. Comparison of ANN Prediction with RDAPS by Region for Different Lead Time


Area	Lead Time (hr)	Total Obs. Rainfall	RDAPS					
			Total Rainfall	Rate for Obs. (%)	NS	CORR		
Seoul/ Gyeonggi	12	153.4	7.57	4.93	-0.01	0.69		
	24	153.4	6.06	3.95	-0.02	0.62		
	36	153.4	9.96	6.49	-0.01	0.66		
	48	153.4	3.00	1.96	-0.05	0.52		
Gangwon	12	120.9	4.84	4.00	0.05	0.50		
	24	120.9	3.93	3.25	-0.06	0.51		
	36	120.9	11.31	9.36	-0.05	0.42		
	48	120.9	3.93	3.25	-0.08	0.36		
Chungcheong	12	59.4	4.25	7.16	-0.06	0.24		
	24	59.3	5.89	9.94	-0.06	0.19		
	36	59.2	7.12	12.03	-0.05	0.24		
	48	59.2	5.19	8.77	-0.06	0.27		
Jeolla	12	134.2	6.06	4.51	-0.06	0.33		
	24	127.8	6.99	5.47	-0.04	0.35		
	36	124.6	8.55	6.86	-0.05	0.28		
	48	124.5	8.84	7.10	-0.03	0.43		
Gyeongsang	12	107.1	6.29	5.88	-0.03	0.35		
	24	106.1	6.22	5.86	-0.04	0.32		
	36	105.6	7.15	6.77	-0.02	0.39		
	48	105.6	5.12	4.85	-0.04	0.27		
Area	Lead Time (hr)	Total Obs. Rainfall	ANN					
			Total Rainfall	Rate for Obs. (%)	NS	Rate for RDAPS	CORR	Rate for RDAPS
Seoul/ Gyeonggi	12	153.4	74.4	48.50	0.39	▼ 0.40	0.69	0.00
	24	153.4	49.4	32.21	0.32	▼ 0.34	0.59	△ 0.03
	36	153.4	112.5	73.36	0.40	▼ 0.41	0.66	0.00
	48	153.4	22.2	14.48	0.14	▼ 0.19	0.45	△ 0.07
Gangwon	12	120.9	76.9	63.63	0.36	▼ 0.31	0.60	▼ 0.10
	24	120.9	64.6	53.45	0.38	▼ 0.44	0.63	▼ 0.12
	36	120.9	83.0	68.67	0.18	▼ 0.23	0.50	▼ 0.08
	48	120.9	23.4	19.36	0.08	▼ 0.16	0.37	▼ 0.01
Chungcheong	12	59.4	39.1	65.84	0.51	▼ 0.57	0.76	▼ 0.52
	24	59.3	36.3	61.27	0.59	▼ 0.65	0.83	▼ 0.64
	36	59.2	44.5	75.18	0.61	▼ 0.66	0.80	▼ 0.56
	48	59.2	25.7	43.42	0.70	▼ 0.76	0.85	▼ 0.58
Jeolla	12	134.2	64.7	48.20	0.10	▼ 0.16	0.38	▼ 0.05
	24	127.8	33.5	26.21	0.29	▼ 0.33	0.57	▼ 0.22
	36	124.6	44.3	35.56	0.17	▼ 0.22	0.46	▼ 0.18
	48	124.5	62.7	50.35	0.21	▼ 0.24	0.49	▼ 0.06
Gyeongsang	12	107.1	73.0	68.19	0.29	▼ 0.32	0.57	▼ 0.22
	24	106.1	37.2	35.05	0.30	▼ 0.34	0.58	▼ 0.26
	36	105.6	63.3	59.92	0.30	▼ 0.32	0.59	▼ 0.20
	48	105.6	23.0	21.77	0.22	▼ 0.26	0.56	▼ 0.29




(a) Forecasting with 12 hr Lead Time



(b) Forecasting with 24 hr Lead Time



(c) Forecasting with 36 hr Lead Time



(d) Forecasting with 48 hr Lead Time

Fig. 7. Forecast with Different Lead Time in Gyeongsang Region

지 예측강수량은 증가하였다. Fig. 7(d)는 2001년 7월 11일부터 7월 16일까지는 Fig. 7(a)~(c)와 비교하였을 때 COE가 0.22, CORR이 0.56으로 낮은 통계적특성을 가지고 있으며, 관측강수량과의 시계열도 잘 모의하지 못하고 있다.

#### 4. 결론

한반도 영역에서의 정량강수추정을 위하여 중규모 수치예보자료, 상층기상관측소, AWS의 관측자료를 이용하여, 역전과 알고리즘학습을 통한 신경망기법의 적용을 통하여 지역별로 중규모 수치예보모형의 3시간 누적강수에 대한 보정효과가 뚜렷이 향상되었음을 확인할 수 있다. 각 지역별로 중규모수치예보자료, 상층기상관측소의 관측값, AWS의 관측값을 이용하여 강수량을 예측하기 위해서, 선행시간별로 시계열 데이터를 구성하고 선행시간에 따른 예측값을 생성하여 비교하였다. 본 연구에서 사용된 방법을 통하여 예측된 강수량값을 실제적으로 적용하기 위해서, 중규모 수치예보모형은 하루에 2회(00UTC, 12UTC)에 걸쳐 예측자료를 생성하기 때문에 00UTC에서 생성된 선행시간이 12~48 hr까지의 예측자료와 12UTC에서 생성된 00~36 hr까지의 예측자료 중 어떤 것을 사용해야 하는지에 대한 연구가 더 진행된다면 예측된 강수량을 이용하여 연구대상구역의 강우-유출모의를 이용하여 홍

수 및 국지성호우로 인한 경제적 손실과 인명피해를 줄이는데 도움이 될 것이다.

인공신경망기법을 이용하여 정량강수를 예측한 결과를 요약하면 다음과 같이 설명할 수 있다.

1. 다양한 기상변수들을 예측인자로 사용하여 예측변수와의 비선형성을 고려하는 양극 활성화 함수를 이용하여 신경망학습결과, 서울·경기지역, 강원지역, 충청지역, 전라지역, 경상지역에서 중규모수치예보 모형의 예측값에 비하여 총강수량이 향상되었음을 알 수 있었다.
  - 서울·경기지역에서는 선행시간이 24~36 hr인 경우 강수가 46 mm에서 288 mm로 증가
  - 강원지역에서는 선행시간이 12~24 hr인 경우 강수가 26 mm에서 237 mm로 증가
  - 충청지역에서는 선행시간이 36~48hr인 경우 강수가 25mm에서 205mm로 증가.
  - 전라지역에서는 선행시간이 12~24 hr인 경우 강수가 26 mm에서 135 mm로 증가.
  - 경상지역에서는 선행시간이 24~36 hr인 경우 강수가 28 mm에서 115 mm로 증가.
2. 본 연구에서는 한반도 영역을 5개의 영역으로 구분하여 각 지역별 강수량을 예측하였지만, RDAPS 모형 격자에 따른 강수량을 추정한다면 유역규모의 강

수량추정에 도움이 될 것이다. 또한 중규모수치예보 모형을 이용하여 예측된 강수량을 효과적으로 사용하기 위해서는 선행시간에 따른 강수추정량의 변화가 있기 때문에 선행시간의 선택이 중요한 과제이며, 계속 연구되어야 할 것이다.

### 참고문헌

- 김호준, 백희정, 권원태, 최병철(2001). “구간 연산 신경망을 이용한 강수량 장기예측 기법.” **한국기상학회지**, 한국기상학회, 제37권, 제5호, pp. 443-452.
- 안중배, 박정규, 임은순, 차유미(2003). “인공신경망 모형을 이용한 기온과 강수량 규모축소 연구.” **한국기상학회지**, 한국기상학회, 제13권, 제1호, pp. 476-477.
- 정슬(2004). “인공지능시스템 I(신경회로망의 구조 및 사용법).” 충남대학교 출판부. pp. 76-106.
- 차유미, 안중배(2005). “역학적으로 규모축소된 남한의 여름철 강수에 대한 인공신경망 보정 능력평가.” **한국기상학회지**, 한국기상학회, 제41권, 제6호, pp. 1125-1135.
- Bras, R.L. (1990). *Hydrology: An Introduction to Hydrologic Science*, Addison-Wesley Publishing company, pp. 82-92.
- Glahn, H.R., and Lowry, D.A. (1972). “The use of model output statistics(mos) in objective weather forecasting.” *J. Appl. Meteor.* Vol. 11, No. 8, pp. 1203-1211.
- Gupta, M.M. (2003). *Static and Dynamic Neural Networks from Fundamental to Advanced Theory*, Wiley-Interscience, IEEE Press. pp. 80-118.
- Hall, T., Brooks, H.E., and Doswell, III C.A. (1999). “Precipitation forecasting using a neural network.” *Wea. Forecasting*, Vol. 14, No. 3, pp. 338-345.
- Klein, W.H. (1971). “Computer prediction of precipitation probability in the united states.” *J. Appl. Meteor.* Vol. 10, No. 5, pp. 903-915.
- Kuligowski, R.J., and Barros, A.P. (1998). “Localized precipitation forecasts from a numerical weather prediction model using artificial neural networks.” *Wea. Forecasting*, Vol. 13, No. 4, pp. 1194-1204.
- Kuligowski, R.J., Barros, A.P., and Ferreira, N.J. (1998). “Experiments in short-term precipitation using artificial neural networks.” *Mon. Wea. Rev.*, Vol. 126, No. 2, pp. 470-482.
- Nash, J.E., and Sutcliffe, J.V. (1970). “River flow forecasting through conceptual models part I-A discussion of principles.” *Journal of Hydrology*, Vol. 10, No. 3, pp. 282-290.
- Schoof, J.T., and Pryor, S.C. (2001). “Downscaling Temperature and Precipitation: A Comparison of Regression-Based Methods and Artificial Neural Networks.” *Int. J. Climatol.* Vol. 21, No. 7, pp. 773-790.
- Valverde Ramírez, M.C., and de Campos Velho, H.F. (2005). “Artificial neural network technique for rainfall forecasting applied to the São Paulo region.” *J. Hydrol.* Vol. 301, No. 1-4, pp. 146-162.
- Wilks, D.S. (1989). “Probabilistic quantitative precipitation forecasts derived from PoPs and conditional precipitation amount climatologies.” *Mon. Wea. Rev.*, Vol. 118, No. 4, pp. 874-882.
- Wilks, D.S. (1995). *Statistical methods in the Atmospheric Sciences*. Academic Press, pp. 233-250.

논문번호: 10-106	접수: 2010.12.22
수정일자: 2011.01.18	심사완료: 2011.01.18