

인공신경망 기법을 이용한 태풍 강도 및 진로 예측

최기선¹ · 강기룡^{2,*} · 김도우¹ · 김태룡²

¹부경대학교 환경대기과학과, 608-737, 부산광역시 남구 대연3동 599-1

²기상청 국가태풍센터, 699-942, 제주특별자치도 서귀포시 남원읍 한남리 1622-1

Prediction of Tropical Cyclone Intensity and Track Over the Western North Pacific using the Artificial Neural Network Method

Ki-Seon Choi¹, KiRyong Kang^{2,*}, Do-Woo Kim¹, and Tae-Ryong Kim²

¹Department of Environmental Atmospheric Sciences, Pukyong National University, Busan 608-737, Korea

²National Typhoon Center, Korea Meteorological Administration, Jeju 699-942, Korea

Abstract: A statistical prediction model for the typhoon intensity and track in the Northwestern Pacific area was developed based on the artificial neural network scheme. Specifically, this model is focused on the 5-day prediction after tropical cyclone genesis, and used the CLIPPER parameters (genesis location, intensity, and date), dynamic parameters (vertical wind shear between 200 and 850 hPa, upper-level divergence, and lower-level relative vorticity), and thermal parameters (upper-level equivalent potential temperature, ENSO, 200-hPa air temperature, mid-level relative humidity). Based on the characteristics of predictors, a total of seven artificial neural network models were developed. The best one was the case that combined the CLIPPER parameters and thermal parameters. This case showed higher predictability during the summer season than the winter season, and the forecast error also depended on the location: The intensity error rate increases when the genesis location moves to Southeastern area and the track error increases when it moves to Northwestern area. Comparing the predictability with the multiple linear regression model, the artificial neural network model showed better performance.

Keywords: Tropical cyclone, artificial neural network, predictor, multiple linear regression model

요약: 북서태평양에서 발생한 태풍에 대해 발생 후 5일 동안 12시간 간격으로 태풍의 강도 및 진로를 예측할 수 있는 인공신경망 모델을 개발하였다. 사용되어진 예측인자는 CLIPER(발생 위치·강도·일자), 운동학적 파라미터(연직바람시어, 상층발산, 하층상대와도), 열적 파라미터(상층 상당온위, ENSO, 상층온도, 중층 상대습도)로 구성되어졌다. 예측인자의 특성에 따라 일곱개의 인공신경망 모델들이 개발되었으며, CLIPER와 열적 파라미터가 조합된(CLIPER-THERM) 모델이 가장 좋은 예측성능을 보였다. 이 CLIPER-THERM 모델은 강도 및 진로 모두에서 동절기보다 하절기에 더 나은 예측성능을 나타내었다. 또한 태풍의 발생이 아열대 서태평양의 남동쪽에 위치할수록 강도예측에서는 큰 오차를 보였고, 진로예측에서는 아열대 서태평양의 북서쪽에서 발생할수록 큰 오차를 보였다. 이후 인공신경망 모델의 예측성능을 검증하기 위해 같은 예측인자들을 이용하여 다중선형회귀모델을 개발하였으며, 결과로서 비선형 통계기법인 인공신경망 모델이 다중선형회귀모형보다는 더 나은 예측성능을 보였다.

주요어: 열대성 저기압, 인공신경망, 예측인자, 다중선형회귀모델

*Corresponding author: krkang@kma.go.kr

Tel: 82-64-801-0224

Fax: 82-64-805-0366

서 론

태풍에 의한 재해를 줄이기 위해서는 태풍의 이동 경로 및 강도를 정확하게 예측하는 것이 무엇보다도 중요하다. 따라서 많은 이전연구들에서는 태풍예측전용 수치모델이나 통계모델을 이용하여 이를 정확하게 예측하기 위한 시도가 이루어졌다. 지금까지의 연구용 또는 현업용 수치모델들은 대부분은 열대지역의 평균대기에 모조태풍(bogus typhoon)을 삽입하여 열대 저기압으로 성장시킨 후, 열대저기압의 생성부터 발달·소멸에 이르기까지의 역학적·운동학적 특성을 분석하고 이를 예측하는데 중점을 두었다(장동언과 이동규, 1989; 권인혁과 정형빈, 2003; 김주혜 외, 2007; Kwon et al. 2002). 또한 종관자료를 이용한 실제 태풍의 사례연구들은 태풍 주변장의 변화 및 지형효과 등에 의해 초래되는 태풍으로부터의 강수·강풍 및 진로 특성을 잘 모의하였다(정병석 외, 2002; 김진원과 이재규, 2007; Park and Lee, 2007). 무엇보다도 태풍 예측의 가장 큰 목적은 한반도 상륙 및 영향 가능성의 유무를 판단하는 것이므로 연구용 또는 현업용 수치모델들은 태풍과 실제태풍 사이의 진로 오차를 줄이는데 목표를 두었다. 이로 인해 진로 예측의 향상은 지금까지 두드러졌다. 그러나 태풍의 중심기압, 바람, 강수량과 같은 태풍 강도의 예측은 진로예측에 비해 그다지 큰 진보가 없었다.

지금까지 이러한 태풍예측을 위한 수치모델들은 태풍의 초기위치에 따라 예보 가능구역의 제한이 있을 뿐 아니라, 많은 계산이 요구되어 이러한 계산을 위해서는 고성능 컴퓨터의 사용이 필수적이었다. 태풍의 강도 및 진로를 예측하는 다른 방법으로는 CLIPER(Climatology and Persistent model) 모델이 이용되고 있다. 이 모델은 수치모델에 비해서 그 계산이 비교적 간단하고 비용이 적게 든다는 장점이 있다. 윤순창과 박경선(1990)은 CLIPER 모델을 이용하여 한국에 접근하는 태풍의 진로예보 성능을 분석한 바 있다. 하지만 이 모델은 저위도에서의 예측 성능은 뛰어난 반면, 전향 후 중위도 경압지역에서 큰 오차를 보였다. 특히, 계절에 따라 다른 오차범위를 보여 전체적으로는 수치모델의 예측성능보다 좋지 못한 결과를 나타내었다. 이 결과에 대해 권혁조와 이상호(1993)는 CLIPER 모델의 개발시 태풍의 전향 전·후로 구분하여 모델을 개발할 것을 제안하였다. 이 연구 이후 DeMaria and Kaplan(1999), Petty(1999)는

기존의 CLIPER 모델에 종관 예측인자의 변수를 추가 할 경우 태풍 강도 및 진로의 예측 성능이 개선되었음을 보였다. 하지만, 태풍의 강도 및 진로는 본래 비선형적 특성을 가지기 때문에, 이 연구들에서 개발된 다중선형회귀모형들은 급격하게 발달하거나 약해지는 태풍의 강도를 예측하는데 한계를 보였다.

이에 반해 인공신경망 모델은 기존의 수치모델이나 CLIPER모델 등과 같은 통계적인 방법보다 태풍의 비선형적 특성을 다루는데 효과적이며, 예측의 정확도나 예측하는데 소요되는 시간 등의 관점에서 많은 이점을 가지고 있다(Neumann and Randrianarison, 1976). Baik and Hwang(1998)은 CLIPER 예측인자를 인공신경망 모델에 적용하여 기존의 다중선형회귀모델보다 예측성능이 더 뛰어남을 보였으며, Baik and Paek(2000a)은 이 인공신경망 모델에 종관 예측인자를 더할 경우, Baik and Hwang(1998)의 인공신경망 모델의 예측성능이 개선되었음을 증명하였다. 하지만, 이 연구들은 14년(1983-1996)의 짧은 태풍 자료를 이용하여 태풍의 발생 후 3일(72시간)동안의 강도예측만을 다루고 있으며, 특히 국내에서 인공신경망 모델을 이용하여 태풍의 강도 및 진로예측을 시도한 연구는 찾아보기 힘들다. 단지, Baik and Paek(2000b)이 Baik and Paek(2000a)의 연구에서 태풍의 자료를 약간 추가하여 태풍의 강도와 함께 진로 예측을 시도한 정도이다. 따라서 이 연구는 Regional Specialized Meteorological Center(RSMC) Tokyo에서 제공하는 57년(1951-2007년) 동안의 모든 태풍을 대상으로 CLIPER 및 종관 예측인자를 이용하여 인공신경망 모델을 개발하고, 태풍 발생 후 5일 동안의 강도 및 진로 예측을 시도해 보고자 한다. 또한 같은 예측인자를 사용하여 구축된 다중선형회귀모델의 예측결과와 비교함으로서 인공신경망 모델의 예측성능을 알아본다.

자료 및 분석방법

자료

RSMC Tokyo에서 제공하는 1951-2007년 (57년)동안의 태풍의 best track(최적경로) 자료를 사용하였다. 이 자료는 6시간 간격으로 된 태풍의 이동경로(위·경도), 중심 기압 및 최대 풍속으로 구성되어 있다. 또한 National Centers for Environmental Prediction-National Center for Atmospheric Research(NCEP-

Table 1. Possible predictors for artificial neural network model (ANNM) and multiple linear regression model (MLRM)

Model	Predictor	Description
Climatology and Persistent model (CLIPER)	LAT	Initial storm latitude
	LON	Initial storm longitude
	JDATE	Absolute value of Julian date-244
	PMIN	Initial storm intensity (hPa)
Dynamic model (DYN)	VWS	Magnitude of vertical wind shear between 850-200 hPa
	DIV200	200-hPa divergence
	VOR850	850-hPa relative vorticity
Thermal model (THERM)	EPT300	300-hPa equivalent potential temperature
	ENSO	Niño 3.4 index before a month of storm genesis
	T200	200-hPa air temperature
	HUM700	700-hPa relative humidity

NCAR)(Kalnay et al., 1996; Kistler et al., 2001)에서 제공하는 동서·남북류 및 상대습도, 온도, 비습 등의 자료가 사용되었다. 이 자료는 위·경도 $2.5^{\circ} \times 2.5^{\circ}$, 연적 17층(비습의 경우 16층) 및 월 평균의 시공간 해상도로 구성되어 있다. NOAA 산하의 Climate Prediction Center(CPC)에서 제공하는 Niño 3.4 지수도 사용되었다.

분석방법

이 연구는 Table 1과 같이 11가지 예측인자를 이용하여 태풍의 발생으로부터 120시간(5일)동안 12시간 간격의 강도 및 진로를 예측하기 위해 인공신경망 모델을 개발한다. Fig. 1에서 볼 수 있듯이, 57년 동안 총 1514사례의 태풍들은 평균적으로는 120시간 동안 25°N 부근까지 북상하지만, 발생 후 96시간이 되면 전체태풍의 약 30%가 30°N 이상에 위치해 있는 것을 알 수 있다(Fig. 1a). 또한 같은 시간에 태풍은 북서진에서 북동진으로 전향하는 경향이 약하게 보인다(Fig. 1b). 따라서 태풍의 발생 후 5일 동안의 강도 및 진로의 정확한 예측은 동아시아의 중위도에 위치하는 국가들에게 있어 중요하다. 따라서 이 연구는 인공신경망 모델을 개발한 후, 예측 오차가 가장 적은 인공신경망 모델로부터 계산된 오차를 시·공간적으로 분석한다. 또한 인공신경망 모델에 사용된 예측인자를 이용하여 다중선형회귀모델을 개발하고, 두 모델 사이에 예측결과의 비교를 통해 인공신경망 모델의 예측성능을 살펴본다. 이 연구에서의 인공신경망 및 다중선형회귀모델은 PC용 통계분석 소프트웨어인 SPSS(Statistical Package for the Social Sciences Ver.16)을 이용하여 개발되었다.

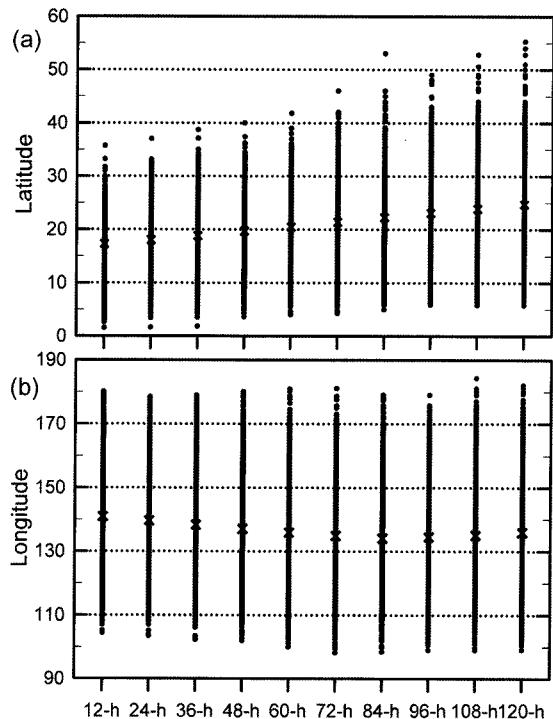


Fig. 1. Variation of tropical cyclone position every 12-hour for 5 days from the formation stage in the Northwestern Pacific area during the period of 1951-2007.

인공신경망

개요

인공신경망은 컴퓨터가 사람의 학습 기능을 갖게 하기 위해 사람 뇌의 구조를 모방한 데이터 모델링 기법으로 과거에 수집된 자료로부터 반복적인 학습과정을 거쳐 자료에 내재되어 있는 패턴을 찾아내는

비선형 통계기법이다. 이와 같은 인공신경망은 생물학적 뉴런을 모델링한 유닛과 그 유닛 사이의 가중치 연결들로 이루어지며, 각 인공신경망 모델에 따라 다양한 구조와 각기 독특한 학습 규칙을 갖는 특성이 있다. Rumelhart et al.(1986)ⁱ⁾ 역전파(back-propagating) 알고리즘을 소개한 이후, 과거자료로 부터의 패턴 학습을 통해 예측을 목적으로 하는 인공신경망 기법이 발전되어 왔다. 인공신경망의 구조는 크게 선택된 예측인자가 입력되어지는 최하위의 층인 입력층(input layer), 외부와의 직접연결이 전혀 이루어지지 않는 은닉층(hidden layer), 은닉층의 모든 뉴론들과 연결되어 있고 신경망에 의해 처리된 예측결과를 출력해주는 출력층(output layer)과 같이 세 개의 층으로 구성되어진다. 인공신경망은 다음과 같은 학습수행과정을 통해 최적의 예측결과를 산출하게 된다.

- i) 인공신경망이 사용될 목적을 선정하고 신경망을 적절하게 구성한다. 즉, 목적에 적합하도록 층의 수, 각 층에 해당된 뉴론의 수를 결정한다.
- ii) 목적에 따른 학습 패턴을 산출한다.
- iii) 신경망의 연결가중치를 초기화한다.
- iv) 신경망의 입력패턴을 입력한다.
- v) 출력패턴을 계산한다.
- vi) 출력패턴과 목적패턴을 비교하여 오차를 구한다.
- vii) 오차가 적정수준이면 학습을 마치고 그렇지 않을 경우 다음을 실행한다.
- viii) 선택한 학습규칙을 이용해 연결가중치를 조절한다.
- ix) iv)번으로 이동하여 반복 수행한다.

이 연구에서는 인공신경망에 대해 위와 같이 간단히 소개하며, 기상학에서 인공신경망의 응용에 대한 자세한 내용은 Hsieh and Tang(1998)의 연구를 참고하기 바란다.

모델의 개발

이 연구는 인공신경망 모델을 구축하기 위해 전체 57년의 기간 중 트레이닝 기간은 70%(1951-1990년), 테스트 기간은 30%(1991-2007년)으로 설정하였다. 사용된 예측인자들은 Table 1과 같이 CLIPER, Dynamic 및 Thermal 예측인자들로 구성된다. 이 예측 인자로부터 총 7가지의 인공신경망 모델을 구축하였다. 즉, i) 11가지의 모든 예측인자를 이용한 CDT(Clipper-Dynamic-Thermal model) 모델, ii) CLIPER 모델, iii) DYN(Dynamic) 모델, iv)

THERM(Thermal) 모델, v) CLIPER-DYN(CLIPER-Dynamic) 모델, vi) CLIPER-THERM(CLIPER-Thermal) 모델, vii) DYN-THERM(Dynamic-Thermal) 모델 등이다. 여기서 DYN 및 THERM 모델들에 사용된 예측인자들은 각각 Gray(1975)의 ‘dynamic parameter’와 ‘thermal parameter’들에 속하는 인자들이다. 특히, THERM 모델에서 ENSO 인자가 사용된 것은 ENSO의 변동에 따라 북서태평양에서의 태풍 발생위치가 달라지며, 달라진 태풍의 발생위치는 태풍 일생 동안의 진로 및 강도에 영향을 미치기 때문이다(Wang and Chan, 2002). 또한 CLIPER 모델에서 JDATE 인자의 ‘244’는 북서태평양에서 태풍발생 빈도의 최정점이 되는 시즌(9월 초순)을 반영한 것이다(Baik and Paek, 2000a). 한편, 종관 예측인자들은 12시간 간격으로 된 RSMC Tokyo 최적경로 자료에서의 태풍 중심으로부터 반경 500 km를 평균하여 구한 값이다. 이 500 km 반경은 Hanley (2002)가 태풍-중위도 시스템 상호작용의 분석시 태풍의 영역으로 정의한 것이다. 또한 연직바람시어(VWS) 인자는 식(1)과 같은 방법으로 계산되었다.

$$VWS = \sqrt{(uwnd_{200} - uwnd_{850})^2 + (vwnd_{200} - vwind_{850})^2} \quad (1)$$

이 식에서, ‘uwnd’, ‘vwind’는 각각 동서류 및 남북류를 나타내며, ‘200’, ‘850’은 200-hPa, 850-hPa의 층들을 의미한다.

인공신경망 모델의 입력 자료로 사용되어진 태풍은 RSMC Tokyo 최적경로 자료로부터 1951-2007년(57년) 동안 12시간 간격으로 된 총 1514사례의 태풍들이다. 이 자료는 태풍의 강도 및 진로 예측을 위해 학습·검증·테스트 자료군으로 나뉘게 된다. 한편, 이 연구에서의 인공신경망 모델은 세 개의 층으로 구성된 인공신경망이 사용되었으며, 입력층과 은닉층의 유닛수는 각 인공신경망 모델에 사용된 예측인자의 수와 같고 출력층의 유닛수는 7개 인공신경망 모델 모두 1이다.

예측결과 분석

일반 오차: Fig. 2a는 태풍의 강도(중심기압)에 대해 태풍의 발생으로부터 120시간 동안(5일) 12시간 간격으로 7개 인공신경망 모델들의 평균절대오차(Mean Absolute Error; MAE)를 나타낸 것이다. 여기서 MAE는 식(2)와 같이 계산되어진다.

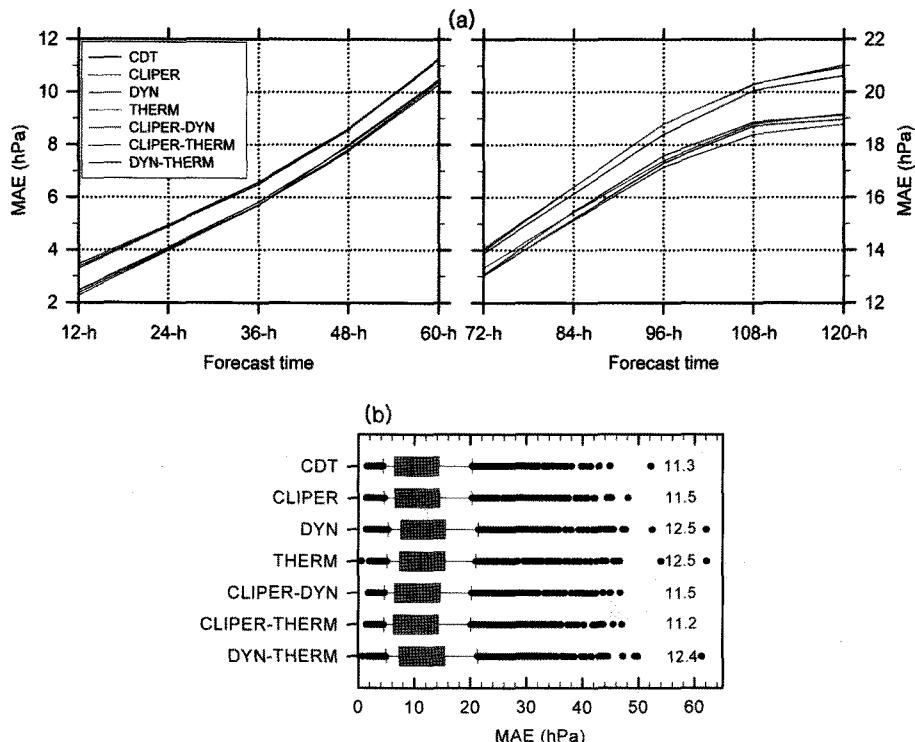


Fig. 2. (a) 12-hour interval mean absolute error (MAE) and (b) MAE of tropical cyclone (TC) intensity (central pressure) predicted by ANNNMs during 5 days from the formation stage. In (b), the boxes show the 25th and 75th percentiles, the lines in the boxes mark the median and the circles the values below (above) the 25th (75th) percentiles of the distributions. Figures denote averages in each model.

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \quad (2)$$

이 식에서 n 은 총 태풍의 사례수이고, f_i , y_i 는 각각 예측값과 관측값을 나타낸다.

그림으로부터 7개의 인공신경망 모델들은 CLIPER 예측인자의 계열과 비 CLIPER 예측인자의 계열과 같이 크게 두 종류의 모델로 나뉘어짐을 볼 수 있다. 즉, CLIPER 예측인자가 포함된 모델(CDT, CLIPER, CLIPER-DYN, CLIPER-THERM 모델들)이 그렇지 않은 모델(DYN, THERM, DYN-THERM 모델들)보다, 비록 큰 차이는 아니지만, 좀 더 나은 예측성능을 보여주고 있다. 특히, CLIPER 예측인자 계열의 모델들 중 CLIPER-THERM 모델이 가장 우수한 성능을 보인 것으로 분석되었다(Fig. 2b). 이것은 태풍의 강도예측에 있어 태풍 초기 강도의 중요성을 보여주는 것이며, 태풍 강도 변화는 태풍의 열적구조가 더욱 중요한 관계가 있음을 의미한다(DeMaria and Kaplan, 1999).

태풍의 진로예측에서도 CLIPER 예측인자가 포함되지 않은 모델들이 큰 오차를 나타내었다(Fig. 3a). 그 중에서도 DYN모델이 가장 좋지 않은 예측성능을 보였다. CLIPER 예측인자 계열의 모델들 중 가장 좋은 예측성능은 강도예측에서와 같이 CLIPER-THERM 모델에서 나타났다(Fig. 3b). 이는 태풍의 진로 예측 시 태풍의 초기위치가 중요함을 의미한다. 또한 태풍의 강도뿐만 아니라 태풍의 진로에서도 태풍의 열적 구조가 중요한 관계에 있음을 알 수 있다.

요약하면, 태풍의 강도 및 진로 예측 시 태풍의 초기강도 및 위치가 중요하며, 여기에 태풍의 열적효과가 반영된 모델(이 연구에서는 CLIPER-THERM)이 가장 우수한 예측성능을 가진 것으로 결론지을 수 있다.

시공간 오차: Fig. 4는 매달 태풍 강도(Fig. 4a) 및 진로(Fig. 4b)에 대해 태풍의 발생으로부터 120시간(5일) 동안 12시간 간격으로 CLIPER-THERM모델의 MAE를 나타낸 것이다. 이 CLIPER-THERM 모델은

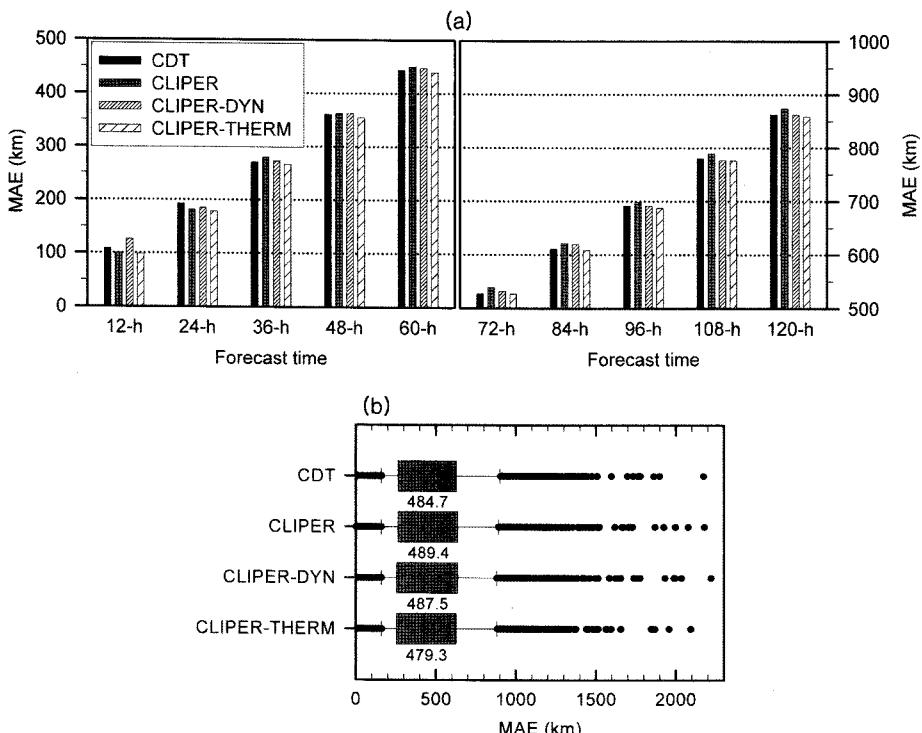


Fig. 3. Same as Fig. 2, except for MAE of track forecast. Here, ANNM that is not related to CLIPER predictor was excluded, because of a large difference with an observation.

앞장에서 7개의 인공신경망 모델 중 예측 성능이 가장 우수한 모델이다. 12시간 변화에 따른 월 사이의 오차변동은 뚜렷한 특징이 보이지는 않지만, 평균적으로 강도 및 진로 모두에서 동절기와 비교하여 하절기에 더 좋은 성능을 나타낸다. 따라서 강도 및 진로예측이 어려운 하절기에 좀 더 나은 예측성능을 가진다는 것은 이 모델의 긍정적인 면이라고 할 수 있다.

Fig. 5는 태풍의 강도(Fig. 5a) 및 진로(Fig. 5b)에 대해 15°N 이상과 미만에서 발생한 태풍의 MAE(왼쪽), 140°E의 동쪽과 서쪽에서 발생한 태풍의 MAE(오른쪽)를 태풍의 발생으로부터 120시간(5일) 동안 12시간 간격으로 나타낸 것이다. 여기서 15°N와 140°E는 57년 기후학적 평균 태풍 발생의 위·경도이다. 먼저 15°N 이상과 미만에서 발생한 태풍의 MAE의 경우, 15°N 미만에서 발생한 태풍의 강도가 이상에서 발생한 태풍의 강도보다 오차가 더 큰 반면, 진로에서는 더 낮은 오차를 나타낸다. 이는 저위도에서 발생하는 태풍일수록 비교적 강한 강도를 유지하는데 (Wang and Chan, 2002), 이 모델이 강한 강도를 제

대로 예측하지 못하였기 때문인 것으로 판단된다. 이것은 앞서 서론에서 설명하였듯이 대부분의 통계(회귀)모델이 가지는 취약점이다. 또한 통계모형은 설명분산이 100%가 되지 못하기 때문에 강도예측이 저평 가되는 것으로 판단된다. 진로예측에서는 고위도에서 발생한 태풍일수록 비정상적인 진로를 나타내는 경우가 있으므로 저위도에서 발생한 태풍보다 더 큰 오차를 나타냈을 것이다. 한편, 140°E의 동쪽에서 발생한 태풍의 강도가 더 큰 오차를 보이는 반면, 진로에서는 140°E의 서쪽에서 발생한 태풍의 오차가 더 크다. 강도의 경우 서태평양의 남동쪽에서 발생하는 태풍일수록 비교적 강한 강도를 가지게 되므로(Wang and Chan, 2002), 역시 이 모델이 강한 강도의 예측에 어려움을 겪었기 때문인 것으로 판단된다. 진로에서는 북서태평양의 서쪽에서 발생한 태풍이 태풍의 일반적인 진로(전향전 북서방향, 전향후 북동방향으로의 이동)를 따르지 못하고 주로 남중국해 및 베트남으로 서진하는 경향이 있기 때문일 것이다(Chan et al., 1998).

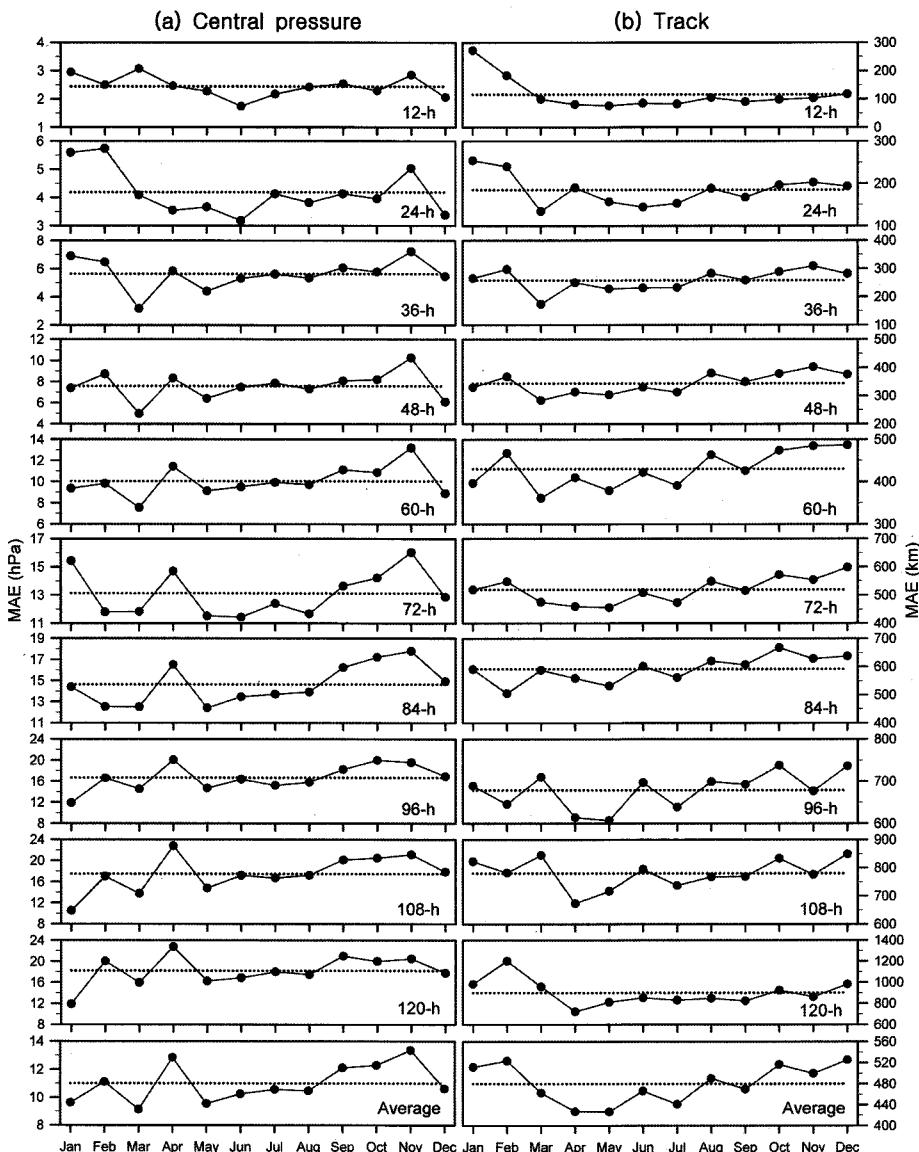


Fig. 4. Monthly MAEs of (a) TC intensity and (b) track predicted by CLIPER-THERM ANNM during 5 days from the formation stage.

강도 오차: Fig. 6은 태풍의 일생 중 한번이라도 그 중심기압이 970 hPa 이하를 기록했던 태풍(점선)과 그렇지 않았던 태풍(실선)에 대해 태풍의 발생으로부터 120시간(5일) 동안 12시간 간격으로 CLIPER-THERM모델의 MAE를 나타낸 것이다. 여기서 970 hPa의 중심기압은 Saffir-Simpson Hurricane Scale의 category 3과, 세계기상기구에서 정의한 TS (tropical storm)등급의 강도기준에 해당한다. 앞 단락에서 설명한 바와 같이 태풍의 강도가 강하면 MAE가 큼을

볼 수 있다(Fig. 6a). 하지만 진로에서는 태풍의 강도와 상관없이 진로오차가 서로 비슷하다(Fig. 6b).

다중선형회귀모형과의 비교·검증

앞서 7개의 인공신경망 모델에 사용된 예측인자를 이용하여 역시 7개의 다중선형회귀모형을 구축하였다. 이들 다중선형회귀모델에서의 회귀계수들은 대부분 90% 이상의 신뢰수준을 보여 이 회귀모형들이 유의

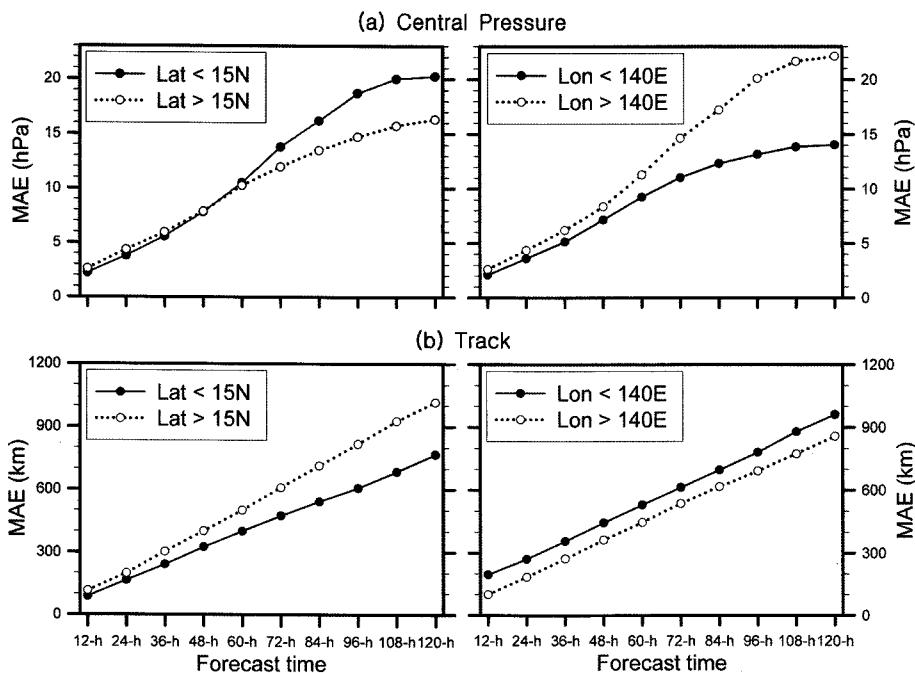


Fig. 5. MAEs of 12-hour interval (a) TC intensity and (b) track that predicted by CLIPER-THERM ANNM during the period from genesis until 5-day for TCs occurred to the south (solid line) and north (dotted line) of 15°N (left panel) and TCs occurred to the west (solid line) and east (dotted line) of 140°E (right panel).

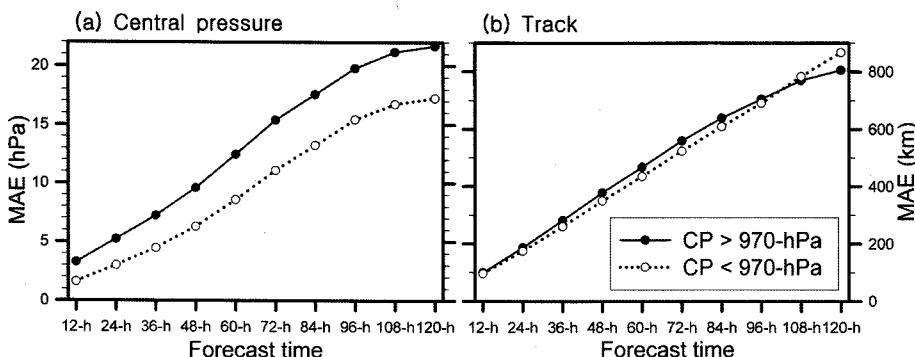


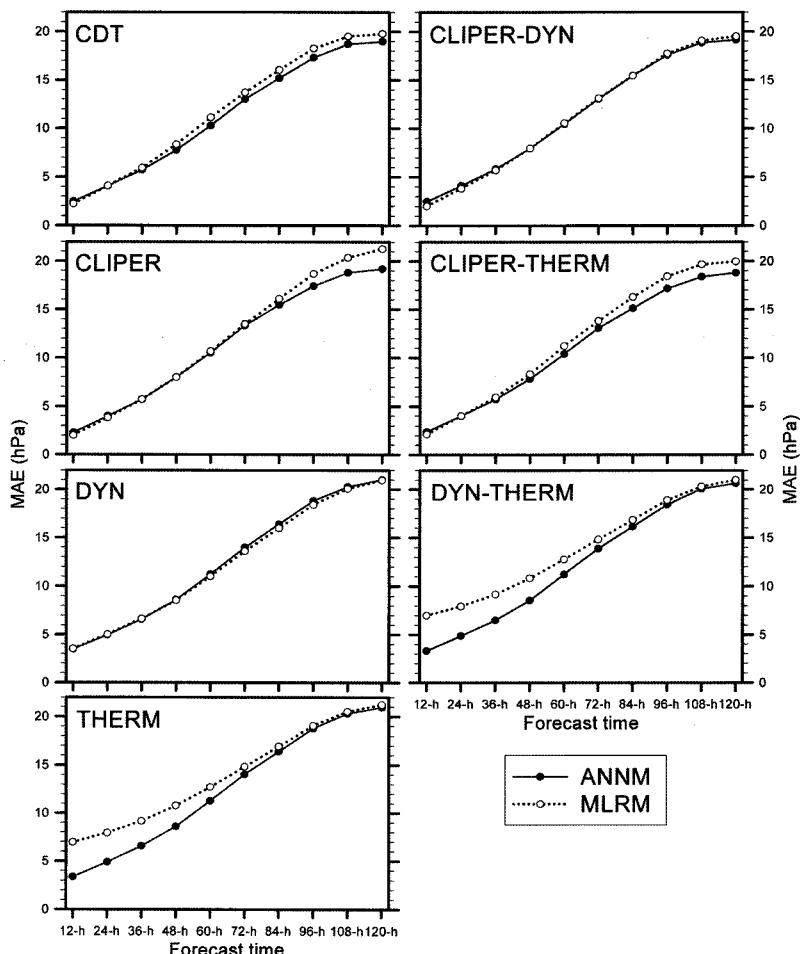
Fig. 6. MAEs of (a) TC intensity (central pressure (CP)) and (b) track predicted by CLIPER-THERM ANNM during the period from genesis until 5-day for TCs that TC central pressure fell below 970 hPa for the TC lifetime or not.

함을 알 수 있었다(Table 2). 강도의 경우, 전체적으로 두 모델들 사이에 비슷한 오차를 보인다(Fig. 7). 그러나, 큰 차이는 아니지만, CLIPER 예측인자 계열의 모델에서는 시간이 지남에 따라, 그리고 비 CLIPER 예측인자 계열의 모델에서는 초기에 인공신경망 모델들이 좀 더 나은 예측성능을 나타낸다. 특히 CLIPER 예측인자가 포함되지 않은 회귀모델들(THERM, DYN-THERM)의 초기 예측성능이 더 낮게 나타난다. 이는 다중선형회귀모델의 경우 초기치

가 정확하지 않거나 정보가 포함되지 않으면 모델의 회귀계수가 달라져 예측성능이 감소되는 특징이 있다. 이로 인해 Fig. 7에서 태풍의 초기 강도가 포함되지 않았던 다중선형회귀모델들이 ANNM보다 초기의 예측성능이 더 낮게 나타난 것으로 판단된다. 한편 진로예측에서는 인공신경망 모델들이 훨씬 더 뛰어난 결과를 보인다(Fig. 8). 그러므로 Baik and Paek (2000a)의 연구결과에서처럼 다중선형회귀모델보다는 비선형통계기법 모델인 인공신경망 모델이 태풍의 강

Table 2. Significant level (%) of regression coefficients in MLRM. A parenthesis indicates one of regression coefficients on TC track forecast

Regression coefficient	MLRM						
	CDT	CLIPER	DYN	THERM	CLIPER-DYN	CLIPER-THERM	DYN-THERM
LAT	94(96)	93(97)			93(95)	94(97)	
LON	95(96)	94(95)			94(96)	93(95)	
JDATE	92(91)	92(92)			91(89)	90(90)	
PMIN	96(93)	95(92)			96(91)	95(90)	
VWS	91(90)		90		92(90)		90
DIV200	89(90)		88		89(88)		88
VOR850	92(91)		90		90(91)		91
EPT300	90(89)			91		89(90)	89
ENSO	92(92)			93		92(91)	92
T200	88(89)			89		90(89)	90
HUM700	90(88)			89		88(88)	90

**Fig. 7.** Comparison of MAEs' every 12-hour TC intensity change predicted by 7 ANNM models and 7 multiple linear regression models (MLRMs) for 5days from the formation stage.

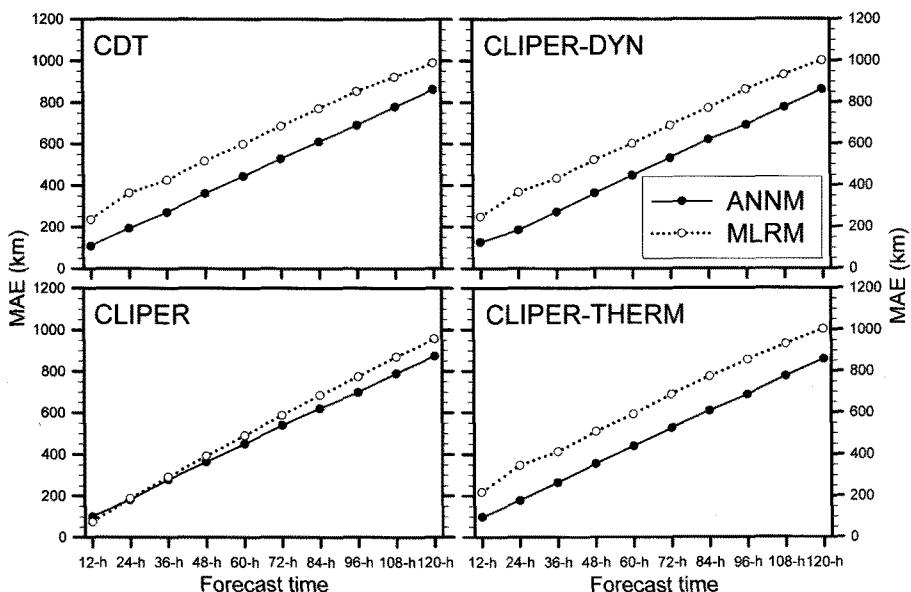


Fig. 8. Same as Fig. 7, except for TC track forecast.

도 및 진로 예측에 더 뛰어남을 알 수 있다.

요약 및 결론

이 연구는 북서태평양에서 발생한 태풍에 대해 발생 12시간 후부터 120시간(5일)동안 12시간 간격으로 태풍의 강도 및 진로를 예측하기 위한 인공신경망 모델을 개발하였다. 사용되어진 11개의 예측인자는 특성에 따라 세 개의 군집[CLIPER, dynamic (DYN), thermal(THERM)]으로 분류되었으며, 분류된 예측인자를 이용하여 일곱개의 인공신경망 모델들 [CDT(CLIPER-dynamic-thermal), CLIPER, DYN, THERM, CLIPER-DYN, CLIPER-THERM, DYN-THERM 모델]로 나누었다. 이 일곱개의 인공신경망 모델들의 오차분석을 통해, 강도와 진로예측 모두에서 CLIPER-THERM 모델이 가장 좋은 예측성능을 가졌다. 이는 태풍의 강도 및 진로예측시에 태풍의 초기치가 반드시 필요하며 특히, 태풍의 열적 상태가 예측성능에 중요한 위치를 차지함을 알 수 있었다.

CLIPER-THERM 모델의 시·공간적 오차분석 결과 강도 및 진로 모두 동절기보다는 하절기에 더 나은 예측성능을 나타내었다. 또한 태풍의 발생이 아열대 서태평양의 남동쪽에 위치할수록 강도예측에서는 큰 오차를, 진로예측에서는 아열대 서태평양의 북서

쪽에서 발생할수록 큰 오차를 보였다. 진로오차의 경우, Chan et al.(1998)이 언급하였듯이, 태풍의 발생이 아열대 서태평양의 서쪽에 위치하면 태풍의 정상적인 진로보다는 서진하는 경향이 있어 이러한 큰 진로 오차를 보인 것으로 판단되었다. 강도오차의 경우에는 태풍의 강도에 따른 오차 특성의 분석으로부터 그 원인을 찾을 수 있었다. 즉, Wang and Chan(2002)이 강조하였듯이, 태풍의 발생이 아열대 서태평양의 남동쪽에 위치할수록 태풍의 강도는 강해지므로 대부분의 통계(회귀)모델이 가지는 단점인 강한 태풍의 예측을 하지 못했기 때문이었다.

또한, 인공신경망 모델에서 사용된 예측인자들을 사용하여 다중선형회귀모델을 만들어 그 예측 결과를 비교한 결과 태풍의 강도 및 진로 모두 인공신경망 모델이 더 나은 예측성을 보여 주었다. 그러나, 인공신경망 모델은 결과의 도출과정이 명확하게 설명될 수 없다는 큰 측약점을 가지고 있다. 즉, 분류나 예측 결과만을 제공할 뿐이며 어떻게 그러한 결과가 산출되었는가에 대한 명확한 근거를 설명하지 못한다. 사실, 통계적인 방법을 이용하여 예측모델을 개발할 때 예측능력을 결정하는 최적의 인자를 찾는 것이 큰 비중을 차지하는 일이기 때문에 본 연구에서 개발된 모델에 대해 이러한 약점을 보강시켜나가는 것이 또 하나의 과제이다.

감사의 글

본 연구는 기상청 예보국 국가태풍센터 주요과제 “국가태풍센터 운영(1131-301-210)”의 한 일환으로 수행되었습니다. 리뷰를 해주신 익명의 두 심사위원님들께 감사드립니다.

참고문헌

- 김진원, 이재규, 2007, 태풍 루사와 관련된 WRF의 수치모의 결과 분석. 대기지, 17, 393-405.
- 김주혜, 추교명, 김백조, 원성희, 권혁조, 2007, 이동격자태풍모델을 이용한 2006년 태풍의 진로 및 강도 예측성능 평가. 대기지, 17, 207-216.
- 권인혁, 정형빈, 2003, DFS 전구순압 모델을 이용한 태풍 진로 예측. 대기지, 13, 98-99.
- 권혁조, 이상호, 1993, 태풍진로 예보에 있어서 지역적으로 강화된 CLIPER 모델의 개발에 관한 연구. 한국기상학회지, 29, 195-204.
- 윤순창, 박경선, 1990, 한국에 접근하는 태풍의 특성과 통계 지속 모델의 신뢰도에 관한 연구. 한국기상학회지, 6, 104-110.
- 장동언, 이동규, 1989, 중간규모 모델을 이용한 태풍 Vera의 수치 실험. 한국기상학회지, 25, 148-167.
- 정병석, 박광호, 유승아, 정준석, 2002, 2002년 제15호 태풍 “루사”에 의하여 야기된 영동지방 호우 분석. 대기지, 12, 414-417.
- Baik, J.J. and Hwang, H.S., 1998, Tropical cyclone intensity prediction using regression method and neural network. Journal of Meteorological Society of Japan, 76, 711-717.
- Baik, J.J. and Paek, J.S., 2000a, A neural network model for predicting typhoon intensity. Journal of Meteorological Society of Japan, 78, 857-867.
- Baik, J.J. and Paek, J.S., 2000b, Performance test of back-propagation neural network in typhoon track and intensity prediction. Korean Journal of Atmospheric Science, 3, 33-38.
- Chan, J.C.L., Shi, J.E., and Lam, C.M., 1998, Seasonal Forecasting of Tropical Cyclone Activity over the Western North Pacific and the South China Sea. Weather and Forecasting, 13, 997-1004.
- DeMaria, M. and Kaplan, J., 1999, An updated Statistical Hurricane Intensity Prediction Scheme (SHIPS) for the Atlantic and eastern North Pacific basins. Weather and Forecasting, 14, 326-337.
- Gray, W.M., 1975, Tropical cyclone genesis. Department of Atmospheric Science Paper 234, Colorado State University, CO, USA, 121 p.
- Hanley, D.E., 2002, The Evolution of a hurricane-trough Interaction from a Satellite Perspective. Weather and Forecasting, 17, 916-926.
- Hsieh, W.W. and Tang, B., 1998, Applying neural network models to prediction and data analysis in meteorology and oceanography. Bulletin of American Meteorological Society, 79, 1855-1870.
- Kalnay, E., Kanamitsu, M., Kistler, R., Collins, W., Deaven, D., Gandin, L., Iredell, M., Saha, S., White, G., Woollen, J., Zhu, Y., Leetmaa, A., Reynolds, R., Chelliah, M., Ebisuzaki, W., Higgins, W., Janowiak, J., Mo, K.C., Ropelewski, C., Wang, J., Jenne, R., and Joseph, D., 1996, The NCEP/NCAR 40-Year reanalysis project. Bulletin of American Meteorological Society, 77, 437-471.
- Kistler, R., Kalnay, E., Collins, W., Saha, S., White, G., Woollen, J., Chelliah, M., Ebisuzaki, W., Kanamitsu, M., Kousky, V., Dool, H., Jenne, R., and Fiorino, M., 2001, The NCEP/NCAR 50-year reanalysis. Bulletin of American Meteorological Society, 82, 247-267.
- Kwon, H.J., Won, S.H., Ahn, M.H., Suh, A.S., and Chung, H.S., 2002, GFDL-type typhoon initialization in MM5. Monthly Weather Review, 130, 2966-2974.
- Neumann, C. and Randrianarison, E., 1976, Statistical prediction of tropical cyclone motion over the southeast Indian Ocean. Monthly Weather Review, 104, 76-85.
- Park, S.K. and Lee, E.H., 2007, Synoptic features of orographically enhanced heavy rainfall on the east coast of Korea associated with typhoon Rusa (2002). Geophysical Research Letters, 34, L02803, doi:10.1029/2006GL028592.
- Petty, K.R., 1999, Statistically forecasting tropical cyclone intensity change in the eastern North Pacific. 23rd conference of Hurricane and tropical meteorology, Dallas, TX, American Meterological Society, 600-602.
- Rumelhart, D.E., Hinton, G.E., and Williams, R.J., 1986, Learning representations by back-propagating errors. Nature, 323, 533-536.
- Wang, B. and Chan, J.C.L., 2002, How strong ENSO events affect tropical storm activity over the western North Pacific. Journal of Climate, 15, 1643-1658.

2009년 3월 27일 접수

2009년 4월 27일 수정원고 접수

2009년 5월 11일 채택