

신경망 모델을 이용한 적도 태평양 표층 수온 예측

장유순* · 이대운 · 서장원 · 윤용훈

기상청 기상연구소 해양기상지진연구소, 156-720, 서울특별시 동작구 신대방2동 460-18

Forecasting the Sea Surface Temperature in the Tropical Pacific by Neural Network Model

You-Soon Chang*, Da-Un Lee, Jang-Won Seo and Yong-Hoon Youn

Marine Meteorology & Earthquake Research Laboratory, Meteorological Research Institute, 460-18, Dongjak-gu, Shindaebang-2-dong, Seoul, 156-720, Korea

Abstract: One of the nonlinear statistical modelling, neural network method was applied to predict the Sea Surface Temperature Anomalies (SSTA) in the Nifio regions, which represent El Nifio indices. The data used as inputs in the training step of neural network model were the first seven empirical orthogonal functions in the tropical Pacific (120° E-290° E, 20° S-20° N) obtained from the NCEP/NCAR reanalysis data. The period of 1951 to 1993 was adopted for the training of neural network model, and the period 1994 to 2003 for the forecasting validation. Forecasting results suggested that neural network models were reasonable for SSTA forecasting until 9-month lead time. They also predicted greatly the development and decay of strong El Nifio occurred in 1997-1998 years. Especially, Nifio3 region appeared to be the best forecast region, while the forecast skills rapidly decreased since 9-month lead time. However, in the Nifio1+2 region where they are relatively low by the influence of local effects, they did not decrease even after 9-month lead time.

Keywords: neural network, Nifio regions, SSTA, forecast skill

요약: 대표적인 엘니뇨 지수인 태평양 Nifio 해역의 표층 수온을 예측하기 위해 비선형 통계모델 중의 하나인 신경망 기법을 적용하였다. 신경망 모델 학습 과정의 입력 자료로 1951년부터 1993년까지의 태평양 해역(120° E-290° E, 20° S-20° N) NCEP/NCAR의 재분석 표층 수온 편차의 경험적 직교함수 7개 주모드를 사용하였고, 그 중 1994년부터 2003년까지의 10년 결과를 분석하였다. 모든 해역에서의 9개월까지의 신경망 모델의 예측력은 비교적 우수하였으며, 특히 1997년과 1998년의 강한 엘니뇨의 발달 및 소멸도 잘 예측함을 확인할 수 있었다. 해역별로는 Nifio3 지역의 예측성능이 가장 높았으며, 9개월 이후부터는 그 예측력이 급격히 감소하였다. 한편 지역적인 영향이 커 예측력이 낮은 동태평양 연안의 Nifio1+2 지역은 9개월 이후에도 예측력의 감소가 관찰되지 않았다.

주요어: 신경망 모델, Nifio 해역, 표층 수온 편차, 예측력

서론

기상 및 해양학 분야에서 자료 분석 및 예측에 주로 적용되는 경험적 또는 통계적인 접근법에는 다음과 같은 방법들이 있다. 1) 두쌍의 일차원 변수에 대한 선형적 관계를 조사하는 회귀분석(단순 상관분석)(Galton, 1885), 2) 한가지 변수의 서로 독립된 시, 공

간 패턴을 추출하는 주성분 분석(경험적 직교함수)(Lorenz, 1956), 3) 두 변수간의 시/공간 패턴의 선형적 상관 모드를 분석하는 정준상관분석(Hotelling, 1936; Barnett and Preisendorfer, 1987) 및 4) 입력변수와 목표변수와의 비선형적 해를 구하는 신경망 기법 등이다.

엘니뇨 자체의 비주기성 및 비선형적인 특징은 역학 및 통계 모델을 이용한 엘니뇨 예측을 더욱 어렵게 하고 있다(Lorenz, 1984). 최근 비선형성을 가지는 대용량의 자료로부터 일정한 패턴을 찾아내는 데이터 마이닝 분류 기법 중의 하나인 신경망 모델이

*Corresponding author: you@metri.re.kr

Tel: 82-2-847-2495

Fax: 82-2-847-2496

기상 및 해양 기후 분야의 시계열 자료 예측에 있어서 그 가능성이 크게 주목받고 있다. Bamston et al. (1994)은 3개의 역학모델과 2개의 통계모델에 대해 1982년부터 1993년까지의 열대 태평양 표층 수온 편차에 대한 6개월 예측 성능을 비교하였다. 6개월 예측 결과 모든 모델에서 평균 0.6(correlation skill)의 비슷한 예측 성능을 보이고 있으며, 단지 예측 시간(lead time)이 증가 할수록 역학모델의 예측 성능이 우수하다는 가능성만 제시하고 있다. 그러나 Elsner and Tsonis(1992), Derr and Slutz(1994), Tang et al. (1994)은 신경망모델은 학습과정(training process)이 잘 조직화 되면 자료의 선형 및 비선형 특성까지 잘 예측할 수 있다는 장점이 있다고 발표하고 있다.

최근에 Tangang et al.(1997, 1998)은 신경망 모델에 태평양 표층 수온, 해상풍, 해수면 기압 자료의 주성분 모드를 입력 자료로 사용하여 열대 태평양 표층 수온 편차를 예측하였고, Bamston et al.(1994)의 역학 모델 및 통계모델의 비교 결과에 그 예측 성능을 새롭게 추가하였다.

하지만, 비교적 방대한 공간 스케일의 관측 자료를 다루어야 한다는 점과, 관측된 데이터의 양과 질의 문제로 신경망 학습과정에서 비선형 불안정성을 유발할 수 있다는 한계로 현재까지도 많은 기후예측 분야에서 신경망 모델의 활용은 아직까지 초보적인 수준이다. 또한 국내의 관련 연구도 단주기 스케일의 국지적 현상인 강수 및 해일 예측 분야에만 국한되어 있는 실정이다(김호준 등, 2001; 강용균, 2004; 이호만 등, 2004).

이에 본 연구에서는 태평양 해역의 표층 수온 자료를 사용하여 엘니뇨 지수(Niño Indices)의 정량적 예측 값을 신경망 모델을 통하여 예측, 평가 후 그 활용 가능성을 토의할 것이다.

모델 개요

신경망은 대용량의 데이터로부터 일정한 규칙 또는 패턴을 찾아내는 데이터 마이닝 분류 기법의 하나로써 복잡한 구조를 가진 자료에서의 예측 문제를 해결하기 위해서 사용되는 비선형 모델(nonlinear model)이다. 이 방법은 입력변수와 목표변수 사이의 물리적 관계를 설명하기는 어렵다는 단점이 있으나 예측력이 매우 높다는 장점을 가지고 있다. 신경망에는 여러 가지 다양한 모형이 있으며 그 중에서도 시계열 자

료 분석을 위해 가장 일반적으로 사용되는 모형은 다중 퍼셉트론(MLP: Multi-Layer Perceptron) 신경망이다(Rumelhart et al., 1985).

MLP는 입력층(input layer)과 출력층(output layer) 사이에 한개 또는 그이상의 은닉층(hidden layer)으로 구성된 전방향(feed-forward) 신경망의 형태를 취한다. 입력층은 입력마디들(input units)로 구성되어 있는데 각각의 입력마디는 연구 목적에 맞게 전처리 과정을 거쳐 생산된 입력 자료들로 구성된다. 입력마디에 입력된 변수들은 결합함수(combination function)를 통해 선형적으로 결합되어 상위층인 은닉층에 전달된다. 은닉층에서는 입력변수들의 선형결합을 비선형함수로 처리하기 위한 활성화함수(activation function)를 거치게 되며, 활성화함수로는 주로 하이퍼볼릭 탄젠트(hyperbolic tangent) 함수, 로지스틱(logistic) 함수 등의 시그모이드 함수를 사용한다. 입력변수는 은닉층을 지나 최종적으로 출력층에까지 전달되어 목표변수인 예측값을 결정하게 된다.

입력마디와 출력마디의 개수는 각각의 입력변수와 목표변수의 개수에 의존하지만, 은닉층의 개수와 은닉마디의 수는 예측하고자 하는 변수의 복잡성과 연관되어 있다(Tangang et al., 1997). 본 연구에서는 Tangang et al.(1997)이 제시한 것과 같은 1개의 은닉층과 3개의 은닉마디를 지니는 MLP 구조를 사용하였다.

Fig. 1은 본 연구에 사용된 개의 입력마디를 가진 입력층, 3개의 은닉마디를 가진 하나의 은닉층, 1개의 출력층으로 이루어진 MLP 신경망 구조를 나타내며 이를 수식으로 표현하면 다음과 같다.

$$\begin{aligned}
 H_1 &= f_1(w_{10} + w_{11}X_1 + \dots + w_{1p}X_p) \\
 H_2 &= f_2(w_{20} + w_{21}X_1 + \dots + w_{2p}X_p) \\
 H_3 &= f_3(w_{30} + w_{31}X_1 + \dots + w_{3p}X_p) \\
 Y &= g(w_0 + w_1H_1 + \dots + w_pH_p)
 \end{aligned}
 \tag{1}$$

입력층 또는 은닉층의 마디들을 결합하는 결합함수

는 식(1)의 $w_0 + \sum_n w_n X_n$ 과 같은 선형함수를 이용하였고, 은닉층의 활성화함수인 f_1, f_2, f_3 로는 하이퍼볼릭 탄젠트(hyperbolic tangent) 함수를, 출력단계의 활성화함수인 g 로는 항등함수(identity function)를 사용하였다.

모델의 학습과정은 입력변수들과 출력변수의 관계를 가장 적절하게 설명해 주는 비선형식의 연결강도




Fig. 1. Feed-forward neural network model used in this study, where there are p neurons in the input layer, three in the hidden layer, and one in the output layer.

(weights, 식 (1)의 w)를 찾아가는 과정이라 말할 수 있다. 연결강도는 예측 에러의 제곱합(SSE: Sum of the Squared Error)을 최소화하여 구할 수 있으며 최종 출력값과 실제값이 어느 정도 비슷한지 확인하기 위해서 학습용 자료(training data)의 SSE를 측정한다. 즉, 학습 과정동안 연결강도는 SSE가 최소가 될 때까지 반복적으로 변하게 된다.

자료 및 전처리 과정

서론에서 언급한 것처럼 이러한 MLP 구조를 예측 시스템에 적용하기 위하여 우선 학습과정의 패턴을 생성해야 한다. 계산과정의 효율성을 고려할 때, 방대한 양의 관측 자료로부터 불필요한 자료를 제거하거나 통합하여 보다 압축된 형태의 특징 집합을 생성함으로써 이들이 시스템에서 구체적으로 역할하고자 하는 정보와의 관련성을 규명해나가는 학습과정이 필요한 것이다.

이에 본 연구에서는 1951년부터 1993년까지의 NCEP/NCAR 월평균 태평양 표층 수온 자료의 경험적 직교함수 결과의 주모드 7개의 시계열을 신경망 모델의

입력 자료로 사용하였다. 경험적 직교함수는 복잡한 역학계의 자유도를 최소화 하면서 원시 자료를 포함하는 현상을 간단히 묘사하여 신경망 모델 등 복잡한 계산 과정을 필요로 하는 입력 자료로 충분히 활용가능하다.

또한, 엘니뇨 현상 재현 및 예측에 지역적 예리도 작용할 수 있는 원시자료의 단주기 성분을 제거하기 위해 24개월의 저주파 필터(Lanning 필터)에 통과된 자료의 정규화된 결과를 모든 입력 자료로 사용하였다. Fig. 2에 보이는 연구 영역(120° E- 200° E, 20° S- 20° N)은 Niño 해역(Niño1+2, Niño3, Niño3.4, Niño4) 및 적도 쾨펜과 및 아치도 로스비와의 전파 영역을 모두 포함하고 있다.

Fig. 3은 신경망 예측 모델에 입력 자료로 사용된 일대 태평양 표층 수온의 주성분 분석 결과의 주요 4모드의 시, 공간 분포이다. 총분산의 36.3%를 설명하는 첫번째 모드는 Weare et al.(1971)에 의해 최초로 정의되었던 일대 태평양 해역의 표층 수온 편차의 전형적인 부에랄 형태의 공간 패턴을 잘 묘사하고 있다. 시계열로 표현되는 고유치 변동도 엘니뇨 시기와 밀접히 연관되어 있으며, 약 2-7년 사이의 장년변동 주기를 잘 재현하고 있다. 2모드는 수성년 주기변동 범위에 속하는 1970년대 후반에 발생한 Regime shift 현상과 관계가 있으며(Sugu et al., 2000), 강한 엘니뇨 시기(1982-1983, 1997-1998)를 설명할 수 있는 3모드에서는 동, 서 태평양 간의 해수면 편차가 강화되면서 전체적인 기후 시스템이 1 모드에 비해 상당히 동진한 공간 분포가 특징적이다(Chang et al., 2002, 2004).

3모드 이후로 구분된 나머지 모드들은 현재까지 알려진 물리과정으로 설명할 수 없으나 엘니뇨 현상과 관계된 기타의 비선형 효과들을 포함하고 있는 것으




Fig. 2. Regions of interest in the tropical Pacific.

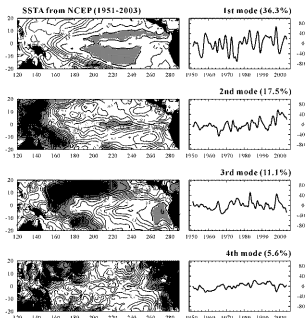


Fig. 3. Left panels are spatial distribution of EOF four modes of SSTA convoluted by a 24-month Hanning filter. Right panels indicate associated time series of each mode, which are used as the input data in the neural network model.

로 사료된다. 본 연구에서는 전체 변동성의 80% 이상을 설명하며 엘니뇨 현상의 비선형 효과까지 포함된 7개 모드(81.3%)까지를 입력 변수에 포함시켰다.

또한 이를 계절 예보(3개월, 6개월, 9개월, 12개월 예측)에 활용하기 위해서 본 연구에서는 1개월씩의 시간 지연을 가지는 1년(12개월) 동안의 자료를 반복 입력하여 신경망 모델의 학습과정에 참가시켰다(Fig. 4). 즉, 3개월 예측을 위해서는 입력변수로 3개월 전~14개월 전까지의 적도 태평양 해역의 표층 수온 자료의 7개의 주성분을 사용하여 모델링 하였으며, 6개월 예측을 위한 모델에서는 입력변수로 6개월 전~17개월 전까지, 9개월 예측에서는 9개월 전~20개월 전까지, 12개월 예측에서는 12개월 전~23개월 전까지의 적도 태평양 해역의 표층 수온 자료의 7개의 주성분 값을 각각 입력변수로 사용하였다. 그러므로 각각의 모델의 입력변수는 적도 태평양 해역의 표층 수온 자료의 7개의 주성분 시계열과 그에 해당하는



Fig. 4. Schematic of the timing of the predictor and predictand periods for the 4 lead times used in this study, for the example of forecasting January in 1998.

12개월의 시간지연 결과 자료인 84개로 구성된다.

결과 분석

위절에서 언급한 신경망 모델 및 입력 자료들 중

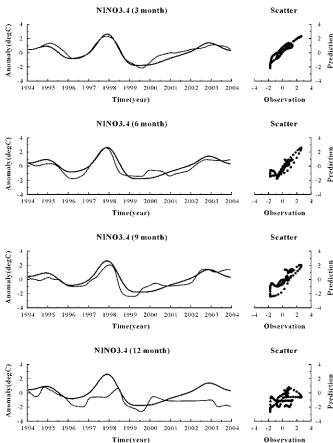


Fig. 5. SSTA of the neural network forecasts (red line) of the Niño3.4 region compared with the observed anomalies (black line) during 1994-2003 at lead time of 3, 6, 9 and 12 months. Right panels indicate scatter plot between observed and predicted ones.

해 1994년부터 2003년까지 10년 동안 Niño 해역의 표층 수온 편차의 예측 결과에 대한 검증으로 BIAS (mean error), RMSE(Root Mean Square Error), SI (Scatter Index), CORR(Correlation Coefficient) 등의 통계적 요소들이 사용되었다. BIAS, RMSE, SI, CORR 등은 다음과 같이 정의된다.

$$BIAS = \frac{1}{N} \sum (Y_{pre} - Y_{obs})$$

$$RMSE = \sqrt{\frac{1}{N} \sum (Y_{pre} - Y_{obs})^2}$$

$$SI = \sqrt{\frac{\frac{1}{N} \sum (Y_{pre} - Y_{obs} - BIAS)^2}{Y_{obs}}} \quad (2)$$

$$CORR = \frac{\frac{1}{N} \sum (Y_{prc} - \bar{Y}_{prc})(Y_{obs} - \bar{Y}_{obs})}{\sqrt{\frac{1}{N-1} \sum (Y_{prc} - \bar{Y}_{prc})^2} \sqrt{\frac{1}{N-1} \sum (Y_{obs} - \bar{Y}_{obs})^2}}$$

식(2)에서 N은 10년 동안의 월별 검증 자료의 개수(120개)이며, \bar{Y}_{prc} , \bar{Y}_{obs} 는 신경망 모델 예측(관측) 값의 시계열 평균을 의미한다.

Fig. 5는 열대 중앙 태평양의 변동을 대표하는 Niño3.4 해역의 표층 수온 편차의 시간대별 예측 결과이다. 검은 실선으로 표시된 관측 값과 비교해 보았을 때 3개월, 6개월, 9개월까지 신경망 모델의 예측력은 매우 우수하다고 판단된다. 특히 1997년과 1998년의 강한 엘니뇨의 발달 및 소멸도 잘 예측함을 확인할 수 있다. 그러나 12개월 장기 예측에서는 그 예측력이 크게 떨어지는 양상이 나타나는데 이러한 경향은 태평양 다른 지역(Niño3, Niño4)에서도 동일한 결과를 보인다. 이는 역학 과정을 고려치 않은 모든 통계 모델의 계통적 한계이며, 예측 시간(lead time)이 증가 할수록 역학모델의 예측 성능이 우수해진다는 Barnston et al.(1994) 결과와 일치한다.

해역별, 예측 시간별 상관계수와 RMSE를 도시화 하면 Fig. 6과 Table 1과 같다. 예측 시간이 증가하면서 대부분의 해역에서 예측력이 떨어지고 있으며, 6개월 이상의 예측에서는 음의 편차(BIAS) 값을 보이는 것으로 판단할 때, 본 연구에 사용된 신경망 모델은 예측시간이 증가하면서 관측보다 엘니뇨 강도를 낮게 모의하고 있는 것을 알 수 있다.

3개월 예측에서는 열대 동태평양의 Niño3 지역의 예측성능(CORR = 0.986, RMSE = 0.281)이 가장 우수했으며, 9개월(CORR = 0.680, RMSE = 0.985)부터 상관계수가 떨어지는 결과를 확인할 수 있다. 이러한 현상은 열대 서태평양 엘니뇨 지수인 Niño4 지역에서도 동일한 패턴으로 분석된다.

그러나 다른 해역에 비해 3개월 예측(CORR = 0.881, RMSE = 0.764)에서도 비교적 예측 성능이 떨어지는




Fig. 6. A comparison of forecast correlation coefficient (upper panel) and RMSE (lower panel) for various interesting region at 3, 6, and 9-month time leads.

동태평양 연안의 Niño+2 지역은 9개월 이후에도 0.8 이상의 상관계수를 유지하면서 상대적으로 예측률이 크게 떨어지고 있지 않으며, 오히려 9개월 이후에는 다른 지역(Niño3, Niño3.4, Niño4) 보다 높은 예측 성능을 보이고 있다. 적도 동태평양 연안에 위치한 Niño+2 지역의 표층 수온은 다른 해역에 비해 해상풍 및 이에 수반되는 연안 용승 등과 관계된 지역적 효과에 크게 영향을 받는다. 이렇게 지역성을 많이 포함하고 있는 동태평양 연안의 Niño+2 지역의 예측률을 높이기 위해서는 동태평양 연안의 풍계 및 해류 패턴 등의 다양한 비선형 시계열 관측 자료를 확보하여 신경망 예측 모델의 입력 자료로 활용하여야 할 것이다.

Table 1. Statistics for the forecasting of SSTa

Region	Niño4			Niño3.4			Niño3			Niño+2		
	3	6	9	3	6	9	3	6	9	3	6	9
BIAS (°C)	0.006	-0.612	-0.828	0.191	-0.234	-0.223	0.073	-0.441	-0.175	0.418	0.364	-0.064
RMSE (°C)	0.453	0.868	1.276	0.409	0.581	0.625	0.281	0.612	0.985	0.764	0.826	0.631
CORR	0.959	0.852	0.667	0.949	0.888	0.867	0.986	0.946	0.680	0.881	0.838	0.887
SI (°C)	1.936	2.631	4.151	7.348	10.782	11.835	1.989	3.111	7.692	3.518	4.072	3.453

또한, 입력 자료의 전처리 과정에서 언급한 것처럼 본 예측 모델의 초기 입력 자료는 태평양 해역(120° E-290° E, 20° S-20° N) 표층 수온 자료의 EOF 7개 모드만을 사용하였다. 그러나, 현재까지 엘니노의 발달 및 소멸은 열대 태평양 표층 수온 외에, 해상풍, 해면기압, 해양 아표층 물성 변화 등 많은 변수의 비선형적인 복합 작용으로 설명되고 있다. 또한 최근에 태평양의 해황변화 뿐만 아니라, 인도양의 수온 변화 및 북반구의 대기 대순환 변동 또한 태평양 적도 해역에서 발생하는 엘니노의 특성을 지배한다는 연구결과가 많이 발표되고 있다. 그러므로, 보다 효과적인 6개월 이상의 장기 예측을 위해서는 태평양의 표층 수온 외에 일정한 시간 지연을 두고 영향을 미칠 수 있는 보다 넓은 지역의 다양한 입력 자료를 신경망 모델에 적용하여 그 성능 평가가 이루어져야 할 것이다.

본 연구에서는 신경망 모델의 구조를 3개의 은닉마디를 가진 1개의 은닉층을 포함하는 MLP 구조를 사용하였지만 좀더 성능이 뛰어난 최적의 모델을 찾아가기 위해서 은닉층과 은닉노드의 개수, 활성화함수 등의 모델 구조를 달리하여 다양한 실험을 실시해야 할 것이다.

요 약

본 연구에서는 태평양 Niño 해역의 표층 수온 편차를 예측하기 위해 1개의 은닉층과 3개의 은닉마디를 지니는 신경망 예측 모델을 구축하여 검증하였다. 태평양 해역의 NCEP/NCAR 재분석 열대 태평양 표층 수온 자료의 경험적 직교함수 7개 주모드에 대한 1개월씩 1년까지의 시간 지연을 가지는 84개의 시계열을 신경망 모델의 입력 자료로 사용하였다. 1951년부터 1993년까지의 자료를 분석용 자료(training data)로, 1994년부터 2003년 자료를 평가용 자료(test data)로 이용하였으며, 실행 가능한 예보를 위해서 3개월, 6개월, 9개월, 12개월의 계절 예측기간에 대한 결과를 비교하였다.

그 결과 1) 3개월, 6개월, 9개월 시간 지연 예측에 있어서 매우 높은 상관계수와 낮은 RMSE를 보였으며 2) 특히 강한 엘니노 발달 및 소멸이 있었던 시기의 표층 수온 편차를 잘 예측하였다. 그러나 3) 6개월 이상의 시간 지연에 대해서는 음의 편차를 나타내어 시간 지연이 길어질수록 대부분의 기간에서 과

소평가(underestimate)하는 것을 확인할 수 있었다. 4) 3개월(CORR - 0.986)과 6개월(CORR - 0.946) 예측에서 Niño3 지역의 예측성능이 가장 우수하였으며 5) 9개월 예측에서는 3, 6개월에서도 가장 낮은 예측성능을 보인 Niño1+2 지역에서의 결과가 오히려 우수하게 나타났다.

향후 기후예측을 위한 보다 넓은 지역의 다양한 시/공간 스케일의 자료를 효율적으로 객관화하여 신경망 모델의 입력 자료로 사용하는 확장경험직교함수(Extended empirical orthogonal function), 비선형직교함수(Nonlinear empirical orthogonal function) 등의 기술 확보를 통해 보다 향상된 결과를 도출할 수 있을 것이다. 또한 기존의 역학 모델의 결과 자료를 신경망 모델의 입력 자료로 추가함으로 역학모델의 계통적 오차 등을 줄일 수 있을 것으로 기대한다.

감사의 글

본 논문을 심사하여 주시고 많은 조언을 해주신 신홍철 교수님과 익명의 심사자분들께 감사드립니다. 본 연구는 기상청 기상연구소 주요사업 “전지구 해양 변화 감시 시스템 구축(ARGO)”과 기상지진기술 개발사업의 “해양기상변화 탐지기술개발”과제의 일환으로 수행되었습니다.

참고문헌

- 강용균, 2004, 연안 실시간 정보를 이용한 태풍해일 예측. 2004년도 춘계해양학회 요약집, 7-17.
- 김호준, 백회정, 권원태, 최병철, 2001, 구간 연산 신경망을 이용한 강수량 장기예측 기법. 한국기상학회지, 37 (5), 443-452.
- 이호만, 이다운, 장유순, 서장원, 2004, 인공신경망 모델을 이용한 폭풍해일 예측 연구. 2004년도 추계기상학회 요약집, 348-349.
- Barnett, T.P., Preisendorfer, R., 1987, Origins and levels of monthly and seasonal forecast skill for United States surface air temperatures determined by canonical correlation analysis. Monthly Weather Review, 115, 1825-1850.
- Barnston, A.G., and Coauthors, 1994, Long-lead seasonal forecasts-where do we stand?. Bulletin of the American Meteorological Society, 75, 2097-2114.
- Chang, Y.-S., An, H.S., Jeon, D., Nam, J.-C., and Seo, J.-W., 2002, El Niño signals contained in precipitation at the East China Sea. Climate Research, 23 (1), 31-38.
- Chang, Y.-S., Jeon, D., Lee, H., An, H.S., Seo, J.-W., and

- Youn, Y.-H., 2004, Interannual variability and lagged correlation during strong El Niño events in the Pacific Ocean. *Climate Research*, 27 (1), 51-58.
- Derr, V.E., and Slutz, R.J., 1994, Prediction of El Niño events in the Pacific by means of neural networks. *AI Application*, 8, 51-63.
- Elsner, J.B., and Tsonis, A.A., 1992, Nonlinear prediction, chaos, and noise. *Bulletin of the American Meteorological Society*, 73, 49-60.
- Galton, F. J., 1885, Regression towards mediocrity in hereditary stature. *The Journal of the Royal Anthropological Institute*, 15, 246-263.
- Hotelling, H., 1936, Relations between two sets of variates. *Biometrika*, 28, 321-366.
- Lorenz, E.N., 1956, Empirical orthogonal functions and statistical weather prediction. *Statistical Forecasting Project, Department of the Meteorology, Massachusetts Institute of Technology, Cambridge, MA*, 49pp.
- Lorenz, E.N., 1984, Irregularity: a fundamental property of the atmosphere. *Tellus*, 36A, 98-110.
- Suga, T., Kato, A., and Hanawa, K., 2000, North Pacific Tropical Water: its climatology and temporal changes associated with the climate regime shift in the 1970s. *Progress in Oceanography*, 47, 223-256.
- Tang, B., Flato, G.M., and Holloway, G., 1994, A study of Arctic sea ice and sea-level pressure using POP and neural network methods. *Atmosphere-Ocean*, 32, 507-529.
- Tangang, F.T., Hsieh, W.W., and Tang, B., 1997, Forecasting the equatorial Pacific sea surface temperature by neural network model. *Climate Dynamics*, 13, 135-147.
- Tangang, F.T., Hsieh, W.W., and Tang, B., 1998, Forecasting the regional sea surface temperature of the tropical Pacific by neural network models, with wind stress and sea level pressure as predictors. *Journal of Geophysical Research*, 103, 7511-7522.
- Weare, B.C., Navato, A.R., and Newell, R.E., 1976, Empirical orthogonal analysis of Pacific sea surface temperature. *Journal of Physical Oceanography*, 6, 671-678.

2004년 12월 30일 원고 접수
 2005년 3월 23일 수정원고 접수
 2005년 3월 23일 원고 채택