

온도 및 습도의 단기 예측에 있어서 역전파 알고리즘의 적용

정효준 · 황원태 · 서경석 · 김은한 · 한문희

한국원자력연구소 환경연구부

(2003년 5월 9일 접수, 2003년 7월 29일 승인)

Application of Back-propagation Algorithm for the forecasting of Temperature and Humidity

Hyo-Joon Jeong · Won-Tae Hwang · Kyung-Suk Suh · Eun-Han Kim · Moon-Hee Han

Nuclear Environmental Research Division, Korea Atomic Energy Research Institute

(Manuscript received 9 May 2003; accepted 29 July 2003)

Abstract

Temperature and humidity forecasting have been performed using artificial neural networks model(ANN). We composed ANN with multi-layer perceptron which is 2 input layers, 2 hidden layers and 1 output layer. Back propagation algorithm was used to train the ANN. 6 nodes and 12 nodes in the middle layers were appropriate to the temperature model for training. And 9 nodes and 6 nodes were also appropriate to the humidity model respectively. 90% of the all data was used learning set, and the extra 10% was used to model verification. In the case of temperature, average temperature before 15 minute and humidity at present constituted input layer, and temperature at present constituted out-layer and humidity model was vice versa. The sensitivity analysis revealed that previous value data contributed to forecasting target value than the other variable. Temperature was pseudo-linearly related to the previous 15 minute average value. We confirmed that ANN with multi-layer perceptron could support pollutant dispersion model by computing meteorological data at real time.

Key words : Artificial neural networks, back propagation algorithm, sensitivity analysis, dispersion model

I. 서론

대기안정도는 고도에 따른 온도의 변화에 의해 크게 좌우된다. 대기중의 오염물질이 누출되었을 경우, 지형적인 영향으로 기인한 미기상 상태의 변화에 따른 오염농도를 모델링하기 위해서는 온도 및 습도를 비롯한 풍향, 풍속 등을 고려한 대기 안정도의 변화를 실시간으로 계산할 필요가 있다.

연속측정된 대기질에 대한 데이터를 이용하여 이들 데이터의 특성을 모형화 하려는 통계적인 기법들이 대기현상의 해석에 많이 도입되어 왔다. 대표적으로 박스-젠킨슨의 ARIMA모형이 특정지역에서 일어나는 오염물질의 농도 추적이나, 기상현상의 추계에 사용되고 있다(Box *et al.*, 1994).

그러나 박스-젠킨슨의 시계열 모형은 모형의 차수가 증가하면, 모형식이 지나치게 복잡해지는 문제점이 있어, 예측에 대한 신뢰도가 떨어지는 경향이 지적되고 있다(Hwang and Ang, 2001). 이러한 문제점을 극복하기 위해, 전이함수 모형이나 유전자 알고리즘 및 인공신경망 등의 비선형 알고리즘을 이용한 실시간 데이터 예측기법들이 환경상태의 모델링에 도입되고 있다.

인공신경망은 인간의 두뇌를 모형화한 것으로 반복된 학습을 통해 시냅스의 강도를 조절하여 동일하거나 비슷한 사상이 발생했을 때, 학습된 논리에 의하여 반응을 보이는 과정을 수학적으로 수식화한 데이터마이닝(data mining) 기법의 일종이다.

대기중에서 오염물질의 확산과 관련하여 Abdul-Wahab and Al-Alawi(2002)는 연속측정된 오존 시계열을 이용하여 단기 오존예측을 수행하여 인공신경망의 적용가능성을 평가하였으며, Podnar *et al.*(2002)은 추적자 확산실험 자료를 이용하여 특정지점에서의 풍향, 풍속 및 1시간전의 추적자 농도를 이용하여 추적자 농도예측에 인공신경망을 이용하였다. 또한 Kolehmainen *et al.*(2001)과 Gardner and Dorling(1999)는 대기중의 질소화합물의 농도 예측시 질소화합물의 전구물

질의 거동별 인공신경망 모형의 설정 방법 등을 제시하였다. 한편, 실험데이터의 최적 예측 모델링 등에도 비선형 최적화 알고리즘이 많이 이용되고 있는데, 정효준(2002)등은 광촉매의 농도가 염색폐수의 제거효율에 미치는 영향 평가에 인공신경망 모형이 적절함을 보였다. 이렇듯, 인공신경망 모형은 최근에 환경관리 전반에 많이 적용되고 있다.

본 연구는 인공신경망의 역전파 알고리즘을 이용하여 한국원자력연구소 기상탑에서 관측된 기상자료 중 온도 및 습도에 대한 모형을 설정하여 온·습도의 단기예측에 있어서 다층 인식자 신경망 모델과 오류 역전파 학습 알고리즘의 적용가능성을 평가하였다.

II. 연구방법

신경망이론은 인간 신경세포인 뉴런의 시스템을 컴퓨터를 이용하여 구현한 인공지능 분야의 하나로서, 패턴 인식, 식별 및 분류, 의사결정 등에 응용되고 있는 기술이다. 이러한 신경망은 인간의 두뇌와 비슷한 병렬처리(parallel processing) 기능으로 인해 분명하지 않은 애매 모호한 정보를 외부 목표인자에 맞도록 자신을 변화시켜 자기조직화 하는 학습능력을 가지고 있다. 따라서 내부에서 일어나는 일련의 과정보다는 나타나는 결과에 중요성을 둘 경우 신경망은 큰 힘을 발휘하게 된다(Maier *et al.*, 1998).

인간의 뇌에 존재하는 신경망의 뉴런은 세포체, 수상돌기, 축삭돌기 및 축삭돌기의 연결부인 시냅스라는 부분으로 구성되어 있다. 인간의 뇌는 신경세포가 매우 복잡하게 연결된 네트워크로서 외부 혹은 다른 신경세포로부터 시냅스를 통하여 입력신호를 받아 세포체에서 적절한 처리를 하여 그 결과를 축삭돌기를 통해 다른 신경세포에 전달하는 기능을 수행한다. 이를 수학적으로 표현한 것이 인공신경망 모형이다.

인간 뇌의 학습에 해당하는 신경망의 훈련에는 자율학습과 지도학습의 두 가지로 구별할 수 있다. 자율학습(self organized learning)은 정확한 정보없이 자기조직화에 의해 훈련을 하게 되고, 지도학습(supervised learning)은 입력데이터를 목표데이터에 근접하도록 훈련시키는 것이다. 전형적인 인공신경망은 뉴런을 나타내는 노드(node)의 집합으로 이루어지며 입력노드는 입력신호를 받고, 출력노드는 출력신호를 내보내며 임의의 개수의 은닉층(혹은 중간층)은 중간노드의 집합으로 이루어진다.

퍼셉트론은 입력값, 출력값, 가중치 및 임계치 벡터를 구성요소로 한다. 입력값은 가중치와 곱하고 임계값을 더하여 전이함수(transfer function)에 보내지고 전이함수를 통과한 값은 은닉층을 거쳐 출력값으로 보내지게 된다. 가중치는 인간 뇌의 뉴런에서 시냅스의 강도에 해당하며 임계값은 전달함수가 0으로부터 벗어나는 역할을 하게 된다. 신경망에서 입력층의 값은 어떠한 작용도 일어나지 않으며, 단순히 값을 다음 층에 있는 값에 가중치를 곱하여 전달하는 역할을 하게 된다. 이렇게 입력층과 출력층 사이에 하나의 층만이 존재하는 것을 단층 퍼셉트론이라고 하며, 2개 이상의 층으로 구성되어 있는 것을 다층 퍼셉트론이라 한다. 2층 신경망은 볼록 다각형의 해 영역을 분리해 낼 수 있으며, 3층 이상일 경우는 일반적인 해영역을 분리할 수 있는 것으로 알려져 있다. 단층 퍼셉트론은 선형분리 가능한 입력패턴만을 분리할 수 있는 한계로 인해, 1969년 민스키와 파퍼트에 의해 그 한계성이 밝혀진 이후로 거의 사용되지 않고 있으며, 1980년대 이후 등장한 다층 퍼셉트론이 최근 연구의 근간을 이루고 있다(Skapura, 1996).

Fig. 1은 인공신경망의 구조를 설명하고 있는 것으로 입력값(I_j)은 식 1과 같이 가중치와 임계값을 이용하여 구해진다.

$$I_j = \sum w_{ji} x_i + B_j \quad (식 1)$$

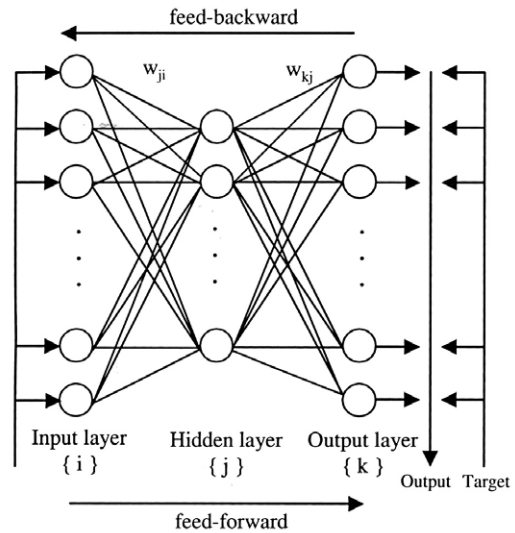


Fig. 1. Schematic diagram of multi-layer perceptron (김대수, 1999).

여기서 x_i : 입력층의 데이터, w_{ji} : 가중치 즉 연결강도, B_j : 임계값 벡터를 나타낸다. 이렇게 계산된 값은 미리 설계된 전이함수에 의해 식 2와 같이 계산되어 값을 출력하게 된다.

$$y_j = f(I_j) \quad (식 2)$$

은닉층에서는 y_j 값을 전달받아 식 3과 같이 반응벡터(L_k)가 구해지고, 전이함수를 거쳐 출력층으로 보내지게 된다.

$$L_k = \sum w_{kj} y_j + B_k \quad (식 3)$$

여기서 y_j : 은닉층의 출력데이터, w_{kj} : 은닉층의 가중치, B_k : 은닉층에서의 임계값에 해당된다. 이런 다층신경망에 의해 출력된 값은 목표값과 비교하여 식 4와 같은 과정을 거쳐 오차의 값을 계산하게 된다.

$$MSE = \frac{1}{n} \sum (O_d - O_p)^2 \quad (식 4)$$

여기서 O_d : 목표값, O_p : 신경망에 의한 계산값, n : 데이터의 수를 나타낸다. 계산된 MSE (mean square error)를 줄이기 위해 가중치벡터(Δ)

$w(t)$ 를 식 5와 같이 조정하여 신경망의 학습을 반복하게 된다.

$$\Delta w(t) = -\eta \frac{\partial \text{MSE}}{\partial w} + \mu \Delta w(t-1) \quad (\text{식 5})$$

여기서 η : 학습율, w : 가중치, μ : 모멘트 항을 나타내며, 가중치 벡터의 전향은 일반적인 경사하강법 (gradient decent method)을 나타내며, 후향은 학습속도를 증가시키기 위해 모멘트항을 추가시킨 모멘트법 (moment method)을 나타내고 있다.

출력값의 가중치들은 가중치에 관한 오차제곱의 음의 기울기에 비례하여 변화하면서 그 값을 역전파하게 되는 것이다. 따라서 신경망의 입력 데이터는 전방향 (feedforward)으로 진행하고, 신경망의 출력값과 목표값의 차이를 줄이기 위해서 Δw 의 값은 역전파하게 되는데 이것이 이른바 다층퍼셉트론에 있어서의 오류 역전파 학습 (back propagation) 알고리즘이다.

위의 식 5에서 학습율 η 의 값이 작으면 신경망은 매우 안정적인 경사강하를 하지만, 값이 지나치게 적으면 신경망의 학습에 걸리는 시간이 증가하는 단점을 가진다. 이러한 역전파알고리즘의 효율을 배가시키기 위하여 가중치와 임계값을 구하는 여러 가지 방법들이 제안되고 있는데 이중

에서 많이 이용되고 있는 것으로는 Levenberg-Marquart Algorithm, Quasi-Newton Algorithm, Scaled Conjugate Gradient Method 등이 있다.

III. 연구결과

1. 기상시계열

본 연구에 사용된 기상데이터는 2002년 3월 1일부터 3월 3일까지 매 15분 간격으로 한국원자력연구소 기상탑에서 관측된 기온과 습도의 자료를 사용하였다. 3일간 관측된 온도 및 습도에 대

Table 1. Characteristics of temperature and humidity

	Temperature	Humidity
Number of samples	287	287
Mean	6.890	49.368
Variance	13.230	284.646
Std Dev.	3.637	16.871
Abs Dev.	3.054	14.205
Skewness	0.22	-0.015
Kurtosis	-0.772	-0.776
Range	14.23	72.310
Q3-Q1	5.225	26.390

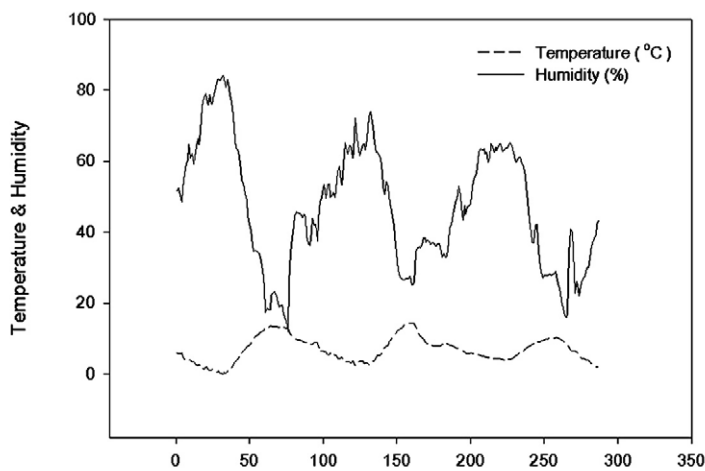


Fig. 2. Time series plot of temperature and humidity

한 통계량은 Table 1에 나타난 바와 같이 온도에 비해 습도의 분산이 상대적으로 크며, 자료의 변동도 습도가 크게 나타나고 있음을 알 수 있다.

한편, 관측된 온도시계열과 습도시계열의 대략적인 관계를 파악하기 위해 시도표(time series plot)를 생성하였다. Fig. 2를 보면 온도가 높을 경우 습도는 낮아지는 경향을 나타내며, 반대로 습도가 높아지면 온도는 감소하는 부의 상관관계를 보이고 있다.

2. 인공신경망의 구성

인공신경망의 입력레이어에는 먼저, 15분전에 관측된 온도값과 현재의 습도값을 2개의 노드로 배열하였으며, 인공신경망의 학습 효과를 향상시키기 위해 은닉층을 2개로 설계하였다. 은닉층의 갯수와 노드수를 결정하는 뚜렷한 이론은 아직까지 밝혀지지 않았으나 대부분의 경우 1개 혹은 2개로 설계하고 있고, 경험적으로 2개 이상의 은닉층에서는 학습의 증가효과를 거의 나타내고 있지 않는 것으로 나타나(Kung, 1993), 본 연구에서도 은닉층의 갯수는 2개로 하였다. 한편, 출력층의 목표값에는 현재의 온도값을 1개의 노드로 구성하였다. 습도모형의 경우 입력층에 15분 전의 습도값과 현재의 온도를 입력층으로 설계하고, 현재의 습도를 목표층으로 하였다. 온도와 습도 모형은 동일하게 전체데이터의 전반부 90% 시간대를 인공신경망의 훈련에 이용하였으며, 나머지 후반부 10% 시간대의 데이터는 모형의 신뢰도 검증에 사용하였다.

한편, 첫 번째 은닉층의 전이함수로 시그모이드(sigmoid)함수를 사용하였으며, 두 번째 레이어에는 선형(linear)함수를 사용하여 해가 안정적으로 수렴할 수 있도록 하였다. 신경망에서 사용되는 대표적인 전이함수는 시그모이드(sigmoid)형, 계단함수(hard limiter), 임계논리(threshold logic)함수 등이 있다. 특히 식 6와 같은 시그모이드 함수

는 최대값과 최소값 부근에서는 응답값의 변화가 적고 평균부분에서는 응답값의 변화가 크며 미분 가능한 함수이기 때문에 비선형시스템의 구현에 가장 널리 이용되고 있다.

$$f(y) = \frac{1}{1 + e^{-y}} \quad (식 6)$$

한편, 시그모이드함수의 미분함수는 다음과 같이 나타낼 수 있다.

$$f'(y) = f(y)(1 - f(y)) \quad (식 7)$$

인공신경망의 입력자료는 각 전이함수의 특징에 맞게 적절히 변환하여 줄 필요가 있다. 본 연구의 은닉층에 사용된 시그모이드 함수의 경우, 최소값과 최대값이 0.0-1.0의 사이를 변동하는 특성을 가지므로 신경망에 입력되는 데이터를 변환하여 시그모이드 함수의 특징에 맞도록 전처리(preprocessing)를 할 필요가 있다. 시그모이드 전이함수의 특성을 고려한 입력데이터의 변환에는 입력데이터의 최대값과 최소값을 이용한 선형변환과 대수변환이 사용될 수 있다(Balkin and Ord, 2000).

본 연구에서는 온도 및 습도 시계열 데이터의 변화폭을 최소화 하기 위해 대수변환을 이용하여 식 8와 같이 입력데이터를 변환하여 사용하였다.

$$z = a \log_{10}(x + b) \quad (식 8)$$

여기서 z : 변환된 데이터, a : 임의의 상수, b : 입력데이터가 0인 경우를 고려한 0이 아닌 상수이다. a 값은 0.5를 사용하였으며, b 의 값은 1을 사용하였다.

이렇게 변환되어 인공신경망을 통하여 학습된




Fig. 3. Transfer function of the artificial neural networks

Table 2. Data transformation for transfer function

	Temperature		Humidity	
	Actual	Transformed	Actual	Transformed
1	5.88	0.418794	51.51	0.860121
2	5.63	0.410757	52.28	0.863282
3	5.72	0.413685	50.31	0.855101
4	5.84	0.417528	48.64	0.847916
5	4.73	0.379077	52.45	0.863974
6	4.12	0.354635	56.65	0.880400
7	3.84	0.342423	59.56	0.891093
8	3.52	0.327569	60.40	0.894084
9	3.76	0.338803	64.70	0.908783
10	3.69	0.335586	60.85	0.895670

후 출력된 식 9와 같은 역변환을 거쳐 원래의 값으로 환원하였다. Table 2에 온도 및 습도의 입력 데이터 변환과정의 예를 제시하였다.

$$x = 10^{(z/a)} - b \tag{식 9}$$

3. 인공신경망의 훈련

15분 후의 온도 및 습도 거동 특성을 예측하기 위하여 2절과 같이 인공신경망의 훈련자료를 준비하고, 은닉층에 설계된 전이함수에 맞게 자료를 변환한 후 인공신경망의 입력층을 구성하였

다. 인공신경망 학습에서 자료가 입력층에서 은닉층을 거쳐 출력층으로 출력되어 목표값과 비교된 MSE를 이용하여 은닉층의 매트릭스를 조정하는 과정을 1주기(epoch)이라고 하는데, 본 연구에서 퍼셉트론의 효과적인 학습을 위해 사용된 Scaled Conjugate Gradient Method의 최대 학습 주기를 2,000회로 제한하였다.

한편, 가중치벡터와 임계치 벡터는 랜덤함수를 이용하여 초기화 시켰으며, MSE가 0.001에 도달하면 학습을 강제 종료시키도록 하였다. 따라서 MSE가 0.001보다 작은 값으로 근접하든지 혹은 학습 주기가 2,000에 도달하면 인공신경망의 훈련은 자동 종료된다.

다층퍼셉트론의 은닉층에 존재하는 노드수를 결정하는 데는 일반적으로 시행착오법(trial and error method)를 통해 구하게 된다. 본 연구에서는 2중으로 존재하는 은닉층의 노드수를 3N(N=1, 2...)으로 증가시켜 가면서 인공신경망의 학습능력을 관찰하여 인간의 뇌에서 뉴런에 해당하는 노드수를 Table 3과 같이 결정하였다. 은닉층의 노드수는 온도 모형의 경우, 첫 번째 은닉층의 노드수가 증가하면 모형의 적합능력이 어느정도까지는 상승하지만, 9이상에서는 큰 차이를 보이지

Table 3. Comparison of tentative temperature models and humidity models

Temperature			Humidity		
Model	Percentage correct	RMS error	Model	Percentage correct	RMSE
2-3-3-1	78.21	7.45	2-3-3-1	83.64	4.21
2-3-6-1	76.31	8.23	2-3-6-1	80.43	5.56
2-3-9-1	79.53	7.67	2-3-9-1	85.79	3.20
2-3-12-1	75.31	8.79	2-3-12-1	83.78	4.20
2-6-3-1	80.36	5.45	2-6-3-1	84.54	3.45
2-6-6-1	84.76	5.23	2-6-6-1	85.34	3.44
2-6-9-1	85.64	4.68	2-6-9-1	84.32	3.54
2-6-12-1	89.91	3.50	2-6-12-1	87.34	2.97
2-9-3-1	88.23	3.79	2-9-3-1	87.54	2.86
2-9-6-1	87.78	4.02	2-9-6-1	90.50	2.78
2-9-9-1	86.65	4.23	2-9-9-1	88.32	2.43
2-9-12-1	85.65	4.78	2-9-12-1	87.56	2.89




Fig 4. Plotting of the observed value and the computed value by artificial neural networks

않았다. 두 번째 은닉층의 노드수는 12에서 모형의 추정능력이 가장 뛰어났다. 따라서 온도의 인공신경망은 2-6-12-1 모형이 가장 좋은 학습능력을 보였다.

한편, 습도의 인공신경망에서는 첫 번째 은닉층의 노드수가 증가할수록 퍼센트 RMS(root mean square)오차는 줄어드는 경향을 나타내었으며, 두 번째 은닉층의 수는 6보가 증가하면 오히려 RMS 오차가 증가했다. 따라서 습도의 인공신경망 모형으로는 2-9-6-1모형이 타당함을 알 수 있었다.

위와 같이 훈련된 인공신경망을 3월 3일 4시 30분부터 저녁 11시 45분까지의 온도 및 습도를 훈련된 인공신경망의 입력층에 구성하여 예측한 값을 Fig. 4에 표시하였다. 인공신경망에 의해 예측된 온도가 실제값에 비해 일부구간에서 과추정하는 경향이 있지만 RMSE(root mean square error)는 0.5437, MAPE(mean absolute percent error)는 8.5706%로 대체적으로 만족할 결과를 보였다.

습도 예측결과 RMSE는 0.7821, MAPE는 9.7802%로 온도의 결과에 비해서는 다소 떨어지는 결과를 나타냈으나, 전체적인 추세를 잘 반영하고 있음을 알 수 있다.

4. 목표변수에 미치는 입력변수의 민감도분석

온도의 예측에 있어서 입력층에 구성된 15분전

의 온도와 현재습도, 그리고 습도의 예측에 있어서 인공신경망의 입력층에 구성된 15분전의 습도와 현재의 온도가 각각의 출력층에 구성된 목표변수인 온도 및 습도에 미치는 영향을 관찰하기 위하여 훈련된 신경망을 이용하여 Fig. 5와 같이 3차원 등고그래프를 생성하였다. Fig 5(a)는 온도를 나타내고 있으며 15분전의 온도가 현재습도에 비해서 더 큰 영향을 미치고 있음을 알 수 있다. 마찬가지로 Fig 5(b)에 나타난 습도의 경우도 15분전의 습도가 현재의 온도에 비해서 영향이 클 수 있다. 그리고 습도가 높아지면 상대적으로 온도는 낮아지는 현상을 확인할 수 있으며, 그 반대의 경우도 같게 나타남을 확인할 수 있었다. 또한 온도의 예측에 있어서 15분전의 온도가 높고 현재습도가 낮은 경우 비선형성이 증가하며, 습도의 경우는 15분전의 습도가 낮고 현재온도가 높은 경우 비선형성이 증가함을 나타내었다.

또한, 15분전의 온도와 현재습도가 현재의 온도에 미치는 영향의 상대적 정도를 평가하기 위하여 입력변수인 15분전의 온도와 현재의 습도중 한 변수는 중간값에 고정하고, 다른 변수를 변화시켜 가며 목표변수인 현재온도의 변화정도를 Table 4와 같이 관찰하였다.

온도에 영향을 미치는 입력층의 변수 중에서 15분전의 온도변화는 현재의 온도에 근사적 선형 관계가 있으며, 습도의 변화는 15분전의 온도에

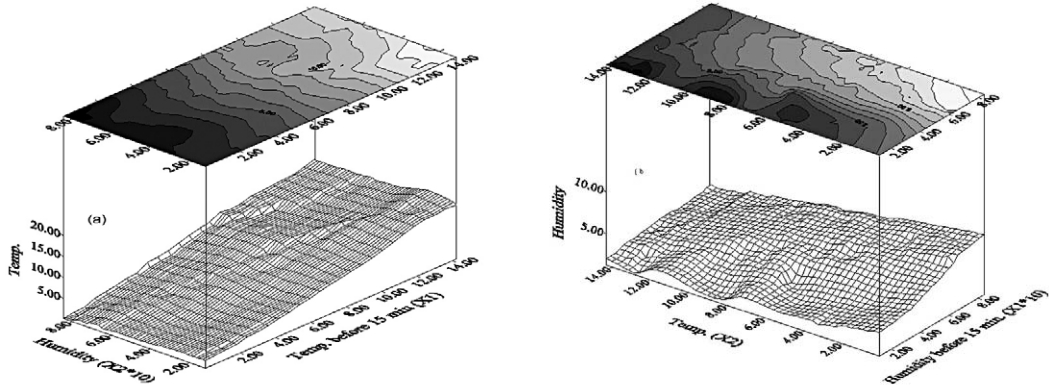


Fig. 5. Surface and contour plot to compute sensitivity by the input variables

Table 4. Variation of the target value according to the input variables

Percent change of input variables (%)	Temperature		Humidity	
	Variation by X1(%)	Variation by X2(%)	Variation by X1(%)	Variation by X2(%)
-40	38.15	3.86	32.99	13.89
-30	29.64	1.73	23.91	8.97
-20	20.41	0.26	15.92	5.23
-10	10.06	0.73	8.42	2.26
10	9.72	0.31	5.94	1.41
20	20.34	1.28	11.90	2.73
30	29.78	3.06	17.58	3.93
40	39.52	2.47	23.14	5.08

비해 현재온도에 미치는 영향이 미미함을 알 수 있다. 한편, 습도에 영향을 미치는 입력변수는 현재의 온도보다는 15분전의 습도가 2-3배 이상 크게 나타나고 있으며, 온도가 음의 방향으로 변할 때, 다시 말해 온도가 낮은 쪽에서 영향을 더 큼을 확인할 수 있었다.

IV. 결론

대덕연구단지 내 한국원자력연구소에서 측정된 온도 및 습도에 대한 시계열 자료를 이용하여 인

공신경망 모형을 구성하고, 인공신경망을 훈련시킨 후 온도 및 습도의 예측에 적용한 결과 다음과 같은 결론을 얻었다.

- 온도 및 습도의 인공신경망 훈련과정에서 학습의 효율성과 관련된 은닉층의 노드수는 온도의 경우는 시그모이드 함수의 노드가 적절하며, 선형함수의 경우 12개가 적절한 2-6-12-1으로 구성된 모형이, 습도의 2-9-6-1로 구성된 모형이 학습 효과가 가장 우수하였다.

- 훈련된 인공신경망의 민감도 분석을 통하여, 온도 모형에서는 입력변수 중 현재습도보다는 15분전의 온도가, 습도모형의 경우 현재온도보다는 15분전의 습도가 목표값인 온도 및 습도에 더 큰 영향을 미치고 있음을 확인할 수 있었다.

- 인공신경망 모형으로 예측된 온도 및 습도는 실제값보다 다소 과대 적합하는 경향이 있는 것으로 나타났으나, 온도와 습도의 변화 추세를 비교적 잘 반영하고 있는 것으로 나타났다.

위와같은 오류 역전파 인공신경망 학습알고리즘은 미결측 기상 혹은 특이성 분석 뿐만아니라 기상현상과 오염물질의 확산 거동의 연관성 등을 규명하는데 폭넓게 사용될 수 있을 것으로 사료된다.

참고문헌

- 김대수, 1999, 신경망이론과 응용(1), 하이테크정보, 92-93.
- 정효준, 조일형, 이홍근, 2002, 인공신경망을 이용한 TiO_2 및 H_2O_2 의 유기물 제거효율 평가, 대한환경공학회지, 24(10), 1785-1795.
- Abdul-Wahab, S. A., Al-Alawi, S. M., 2002, Assessment and prediction of tropospheric ozone concentration levels using artificial neural networks, Environmental Modelling & Software, 17(3), 219-228.
- Balkin, S. D., Ord, J. K., 2000, Automatic neural network modelling for univariate time series, International Journal of Forecasting, 16, 509-515.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., 1994, Time Series Analysis, Forecasting and control, Prentice-Hall Inc, 19-45.
- Gardner, M. W., Dorling, S. R., 1999, Neural network modelling and prediction of hourly NO_x and NO_2 concentrations in urban air in London, Atmospheric Environment, 33(5), 709-719.
- Hwang, H. B., Ang, H. T., 2001, A simple neural network for ARMA(p, q) time series, The International Journal of Management Science, 29, 319-333.
- Kolehmainen, M., Martikainen, H., Ruuskanen, J., 2001, Neural networks and periodic components used in air quality forecasting, Atmospheric Environment, 35, 815-825.
- Kung, S. Y., 1993, Digital Neural Networks, Prentice Hall International Inc, 30-33.
- Maier, H. R., Dandy, G. C., Burch, M. D., 1998, Use of artificial neural networks for modelling cyanobacteria Anabaena spp. in the River Murray, South Australia, Ecological Modelling, 105, 257-272.
- Podnar, D., Korain, D., Panorska, A., 2002, Application of artificial neural networks to modeling the transport and dispersion of tracers in complex terrain, Atmospheric Environment, 36(3), 561-570.
- Skapura, D. M., 1996, Building Neural Networks, Addison Wesley, 1-5.