

신경망의 선별학습 집중화를 이용한 효율적 온도변화예측모델 구현

정회원 이기준*, 강경아*, 정채영*

Implementation of Efficient Weather Forecasting Model Using the Selecting Concentration Learning of Neural Network

Kee Jun Lee*, Kyung A Kang*, Chae Young Chung* *Regular Members*

요약

최근 자연세계에서 발생하는 시계열 문제를 분석하기 위하여 전형적인 통계분석방법보다 신경회로망을 이용하여 분석하는 방법이 연구되어지고 있다. 신경회로망은 모집단의 학습을 통하여 비학습데이터에 대한 예측 및 분석이 가능한 일반화 성능을 지니고 있다. 본 논문에서는 1987년부터 1996년까지 수집된 기상데이터를 수집한 후 구축된 모집단을 학습하여 미래의 기후를 예측분석하기 위한 기상예측시스템을 제안하고자 한다. 제안된 기상예측시스템은 $28 \times 30 \times 1$ 의 신경망 구조를 사용하며, Descending Epsilon 학습방법을 이용하여 수렴되지 않은 패턴에 대해서만 선별적인 집중학습을 시켜 전체학습횟수와 정확도를 높였다. 또한 전형적인 시계열분석방법과의 비교실험을 통하여 제안된 기상예측시스템이 기존의 통계적분석방법에 비하여 미래예측능력면에서 더 우수함을 보였다.

ABSTRACT

Recently, in order to analyze the time series problems that occur in the nature word, an analyzing method using a neural electric network is being studied more than a typical statistical analysis method. A neural electric network has a generalization performance that is possible to estimate and analyze about non-learning data through the learning of a population. In this paper, after collecting weather datum that was collected from 1987 to 1996 and learning a population established, it suggests the weather forecasting system for an estimation and analysis the future weather. The suggested weather forecasting system uses $28 \times 30 \times 1$ neural network structure, raises the total learning numbers and accuracy letting the selecting concentration learning about the pattern, that is not collected, using the descending epsilon learning method. Also, the weather forecasting system, that is suggested through a comparative experiment of the typical time series analysis method shows more superior than the existing statistical analysis method in the part of future estimation capacity.

I. 서론

미래란 본질적으로 미지의 기간이므로 인간은 항상 장래의 일에 대하여 일상의 불안감을 가지고 있고, 따라서 예측을 통하여 미래에 발생될 일에 대한

대비를 하고자 한다. 인간의 활동이 개입되는 많은 분야 중 사회과학 분야는 해당 현상의 본질을 어느 정도 파악하면 일정기간 정도까지는 장래의 일을 예측할 수도 있다. 그러나 인간생활에 밀접한 영향을 미치는 자연과학 특히, 기후 변화의 경우, 장기 간의 예측은 타 분야에 비하여 정확도가 많이 떨어

* 조선대학교 전산통계학과 (cholee@shimbiro.com)
접수번호: 99424-1019 접수일자: 1999년 10월 19일

진다. 그것은 지구환경이 6300km인데 반하여 기후 예측을 위해 다루는 대기의 두께는 10km 밖에 되지 않기 때문이다. 더구나 대기는 지구표면의 영향을 심하게 받고 있으므로 적절한 초기값이 주어져도 시간의 흐름에 따른 대기표면의 변화정도를 예측하는 일은 매우 어렵다.^[1]

최근에는 기존의 시계열 예측분야의 통계적인 방법보다는 입력과 출력사이의 함수관계에 신경망 모델을 적용한 예측기법에 대한 연구가 활발히 진행되고 있다.^[2]

Shin은 신경망을 이용하여 지역적 가뭄에 대한 분석방법을 연구하였고^[3], 특히 실시간 기상자료와 신경망 이론을 이용한 강우예측에 관한 연구들이 광범위하게 진행되고 있다.^{[4][5]}

본 논문에서는 신경망을 이용하여 기상변화, 특히 온도변화에 대한 예측을 위한 것으로, 과거의 연속적인 기상데이터의 분석을 통하여 미래의 기상변화에 대한 예측모델을 제작하고자 한다.

기존 방법에 따라 기상자료를 신경망으로 처리할 경우, 자료 자체의 방대함 때문에 원하는 학습 패턴을 유도해내는데 많은 계산량과 그에 따른 반복횟수의 증가가 필수적으로 수반된다. 특히 모든 자료를 고정된 반복횟수로 수렴시킬 경우 최종 오차율은 정해진 범위로 귀결되지만 이 학습패턴이 각각의 예측값에 적용될 때는 큰 편차를 갖게된다.

따라서 본 논문에서는 먼저 학습횟수를 지정하고 학습을 수행하다 예측값이 교사값에 수렴할 때 해당 패턴을 학습에서 제외시키고, 수렴되지 않은 패턴에 대해서만 집중적으로 학습시키는 Descending Epsilon 학습방법^[6]을 이용함으로써 전체적인 학습 횟수를 줄이고, 정확도를 높일 수 있는 온도변화예측 시스템을 구현하며, 시계열 분석을 통한 예측자료와의 비교를 통하여 구현된 시스템의 효율성을 검증하고자 한다.

실험에 사용된 자료는 최근 10년간 총 22,080건의 6,7,8월 기상데이터를 사용하였으며, 이중 1987년 88년, 89년, 92년도의 8,832건의 자료를 학습데이터로 사용하고, 나머지 년도의 13,248건 자료를 테스트데이터로 사용하고자 한다.

본 논문의 구성은 2장에서는 시계열 모형설정을 위한 방법에 관하여 기술하고 3장에서 Descending Epsilon 학습방법을, 4장에서는 기후예측을 위해 제안한 기상변화예측모델을 설명한다. 그리고 5장에서는 실험을 통하여 제안한 모델의 타당성을 검증하며, 마지막 6장에서 결론을 맺는다.

II. 시계열 모형설정

N 개의 관찰개체로부터 p 개의 독립변수 x_1, x_2, \dots, x_p 와 하나의 종속변수 y 가 있다고 하면, 이중 i 번째 관찰개체의 값, $(y_i, x_{1i}, x_{2i}, \dots, x_{pi})$, $i=1, 2, \dots, N$ 에 대하여 다음 식(1)과 같은 선형회귀모형을 갖는다.

$$y_i = \beta_0 + \beta_1 x_{1i} + \dots + \beta_p x_{pi} + \varepsilon_i \quad (1)$$

여기서 $\beta_0, \beta_1, \dots, \beta_p$ 는 회귀계수이며, 오차항 ε_i 은 확률변량으로 (2)와 같은 성질을 갖는다.

$$\begin{cases} \cdot E(\varepsilon_i) = 0 \\ \cdot \text{Var}(\varepsilon_i) = \sigma^2 \\ \cdot \text{Cov}(\varepsilon_i, \varepsilon_j) = 0, i \neq j \end{cases} \quad (2)$$

i) 일반적인 선형모형을 행렬로 표시하면

$$Y = X\beta + \varepsilon \quad (3)$$

로 표시할 수 있으며, 확률오차벡터 ε 에 대한 (2)의 조건은 다음 (4)와 같다.

$$\begin{cases} \cdot E(\varepsilon) = 0 \\ \cdot \text{Cov}(\varepsilon) = \sigma^2 I_N \end{cases} \quad (4)$$

위의 선형 회귀모형에서 회귀계수벡터 $\beta = (\beta_0, \beta_1, \beta_2, \dots, \beta_p)'$ 는 오차제곱합을 최소화하는 최소제곱법에 의해 추정될 수 있다. 이때 관찰값과 모형의 차이를 측정한 오차제곱합은 식(5)이다.

$$\begin{aligned} S(\beta_0, \beta_1, \beta_2, \dots, \beta_p) &= \sum_{i=1}^N (Y_i - \beta_0 - \beta_1 x_{1i} - \dots - \beta_p x_{pi})^2 \\ &= (Y - X\beta)'(Y - X\beta) \end{aligned} \quad (5)$$

위 식은 행렬과 벡터의 미분을 이용하면 회귀계수 추정량 $\hat{\beta}$ 는 정규방정식 $(Y - X\beta)'X = 0$ 의 해로

$$\hat{\beta} = (X'X)^{-1}X'Y \quad (6)$$

이 된다.

이때 자료를 통하여 얻어진 선형모형에 대한 적합정도를 검증하기 위하여 식(7)의 결정계수 R^2 을 이용한다.

$$R^2 = \frac{\sum_{i=1}^N (Y_i - \bar{Y})^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2} \quad (7)$$

III. Descending Epsilon 학습알고리즘

신경망 학습알고리즘은 각 출력노드에서 출력값과 교사레이터의 값의 차가 최소화되도록 연결강도의 값을 조절하는 오류 역전파 학습 알고리즘을 주로 사용된다. 오류 역전파 학습알고리즘은 현재 패턴인식분야에서 널리 사용되고 있는 학습알고리즘이지만 순수 오류 역전파 알고리즘의 경우 전체 오차가 적은 값을 갖더라도 일부 출력 뉴런은 상대적으로 높은 오차를 가진 상태에서 학습을 종료하는 경우가 있으므로, 소수의 학습패턴이 정확히 학습되지 못하고, 전체적으로 인식률을 저하시킬 수 있는 문제점을 가지고 있다.

따라서, 본 연구에서는 이러한 문제점을 해결하기 위하여 Descending Epsilon 방법^[8]을 이용하였다. Descending Epsilon 학습은 기증치를 조절하는 방법으로 기존의 오류 역전파 알고리즘과 동일하지만 학습과정을 수행하는 면에 있어서는 차이가 있다. ⓠ Descending Epsilon 학습방법의 주 내용은 학습되지 않은 출력뉴런의 오차를 역전파하여 기증치를 조절하는 것으로 학습패턴의 오차와 크기가 학습 중에 허용할 수 있는 오차의 크기인 Epsilon보다 작으면, 그 학습패턴은 학습에 참여시키지 않는다. 따라서 학습이 잘 되지 않은 패턴에 대해서는 집중적인 학습을 수행할 수 있다는 장점을 지니고 있다.

따라서 신경망의 학습된 정도를 나타내는 척도로

$$E = \sum_{j=1}^P \sum_{i=1}^N (T_{ji} - O_{ji})^2 \quad (6)$$

으로 계산되는 오차를 사용하는 대신

$$E = \sum_{j=1}^P \sum_{i=1}^N (\text{Number of } |t_{ji} - O_{ji}| > \epsilon) \quad (7)$$

을 사용한다.

Epsilon Descending 방법의 전체 알고리즘은 다음과 같다. 먼저 임의의 Epsilon값을 초기화하여 각 출력노드에서의 오차가 이 값보다 작을 경우 오차를 0으로 한다. 따라서 이 출력노드의 오차는 학습

에 반영하지 않는다. 이 방법에 따라 신경망을 학습시키면 모든 활성화 출력노드와 비활성화 출력노드가 일정 범위내의 값을 가지므로 비활성화되어야 할 어떤 출력노드가 높은 출력값을 나타내는 것을 방지할 수 있다. 또한 각 입력에 대하여 모든 출력노드에서의 오차가 현재 Epsilon 값보다 작으면 그 입력은 학습에 참여시키지 않는다. 따라서 오차가 큰 입력에 대한 집중적인 학습이 이루어지므로 학습되지 않은 소수의 입력이 전체 인식률을 저하시키는 문제를 해결할 수 있다. 특히 이 경우 변화된 연결강도로 인하여 다음 epoch에서는 학습에 참여하는 입력 패턴의 집합이 변화하므로 선별적 재학습에서 발생하는 학습된 입력패턴과 학습되지 않은 입력패턴의 혼합에 따른 문제를 자동적으로 해결할 수 있다.

현재의 Epsilon에 대하여 모든 입력패턴이 학습되면 Epsilon을 감소시켜 다시 학습을 시키며 Epsilon이 원하는 값까지 감소되었을 때 학습을 마친다.

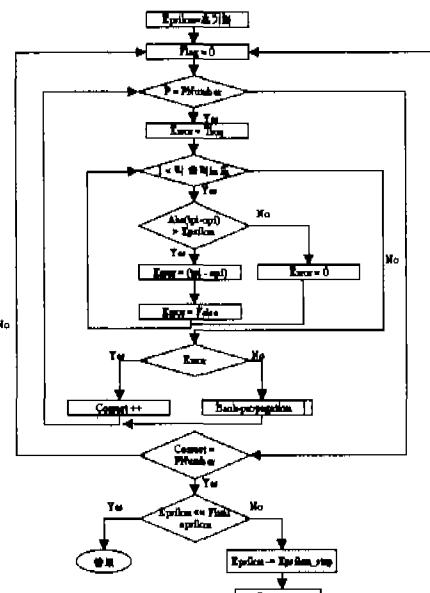


그림 1. Descending Epsilon 알고리즘

IV. 기후예측 시스템

본 기후 예측 시스템은 과거의 연속적인 기상데이터를 분석함으로써 미래의 기후변화에 대한 예측을 가능케 한다. 모델의 입력메이터로는 1987년도부터 1996년까지의 6, 7, 8월의 22,080건 데이터중

87, 88, 89, 91년의 자료를 학습데이터로 사용한다. 각 데이터는 년(Y), 월(M), 일(D), 시(T), 풍향(A), 풍속(B), 총운량(C), 온도(D), 노점온도(E), CEILING 고도(F), 해면기압(G), 상대습도(H)로, 이 12개 필드로 구성된 레코드단위로 구성되어 있다.

Y	M	D	T	A	B	C	D	E	F	G	H
..
87	6	29	19	16	3	1	28	22	0	1008.3	74
87	6	29	20	17	1	3	26	22	0	1009.7	80
..
91	7	26	6	18	0	6	21	17	2000	1002.4	74
..

그림 2. 기상데이터 레코드 단위

신경회로망의 입력노드의 값으로는 한 단위 시간씩 움직여가며 학습패턴을 구성하는 슬라이딩 윈도우기법(Sliding Window Method)을 이용하여, 연결된 두 레코드와 예측일의 년월일시를 사용하였다. 출력노드의 값은 예측일의 해당시간별 온도값으로 설정하였다. 입출력시 사용될 데이터는 0~1사이의 값으로 정규화되어 계산된다.

[그림 3]은 제안된 기상예측시스템의 개략도를 보여주고 있다.

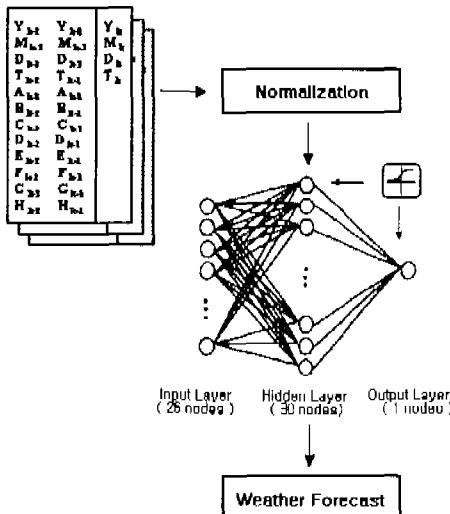


그림 3. 기후예측을 위한 신경망 모델

초기 구성된 신경망 네트워크는 28개의 입력노드, 30개의 은닉노드 그리고 1개의 출력노드로 구성된 $28 \times 30 \times 1$ 신경방을 사용하고, 각종의 입력총합을 활성화함수에 적용시켜 각 노드의 출력값을 정한다. 이때 사용하는 활성화함수로는 식(8)의 양극성 시그

모이드 함수를 사용하여 -1(음) 또는 1(양)의 값에 근사하게 되는 출력값을 갖도록 조정된다.

$$x_j = \frac{1 - \exp(-\sum_i x_{ji})}{1 + \exp(-\sum_i x_{ji})} \quad (8)$$

V. 실험 및 결과

시계열 분석과 제안한 기온예측시스템에서 사용된 학습데이터는 1987년부터 1996년 동안의 자료중 1987년, 88년, 89년, 91년의 6, 7, 8월 8,832건의 데이터를 이용하였으며,奔터엄 200MHz 시스템에서 각각 SAS 패키지와 VC++을 이용하여 실험하였다.

5.1 시계열을 이용한 분석

기온예측을 위한 수집된 자료(87년~97년)들중 4년간의 자료(87, 88, 89, 91년) 총 8,832건을 SAS 패키지를 이용하여 분석한 결과 F 통계량값이 5920.545이고 유의확률이 0.0001로 나타났다. 이는 유의수준 0.1보다 극히 적유으로 적합된 회귀모형은 유의하다 할 수 있고, 또한 전체변동에서 회귀변동이 차지하는 비율을 나타내는 결정계수(R-square)의 값이 0.9459값을 가짐으로 적합된 회귀모형은 전체 데이터의 약 95%정도를 설명한다고 말할 수 있다.

아래의 [그림 4]는 회귀모형의 모수추정치 및 모수들에 대한 검정결과이다.

Variable	DF	Parameter Estimates		T for H0	Prob > T
		Parameter Estimate	Standard Error		
INTERCEP	1	-43.66419	2.78773645	4.902	0.0001
X1	1	0.03471	0.00839313	4.137	0.0001
X2	1	18.10403	20.38069298	0.890	0.3737
X3	1	0.59376	0.66714835	0.875	0.3816
X4	1	0.00089	0.02789280	0.032	0.9743
X5	1	-0.00536	0.00120827	-4.442	0.0001
X6	1	-0.04946	0.01032177	-0.475	0.6346
X7	1	0.03151	0.01016265	3.101	0.0019
X8	1	0.38649	0.01121555	-34.460	0.0001
X9	1	-0.01840	0.01409836	-1.306	0.1917
X10	1	-0.00000587	0.00000247	-2.389	0.0179
X11	1	0.03878	0.02238194	1.698	0.0896
X12	1	0.00280	0.00106170	2.451	0.0143
X13	0	0			
X14	1	-27.40213	28.77822214	-0.952	0.3410
X15	1	-0.87919	0.94341962	0.932	0.3514
X16	1	0.03922	0.03941859	-0.995	0.3197
X17	1	-0.00225	0.00121578	-1.855	0.0637
X18	1	-0.02174	0.01033966	2.103	0.0355
X19	1	-0.01677	0.01009940	-1.661	0.0988
X20	1	1.34126	0.01070502	125.293	0.0001
X21	1	0.03903	0.01419333	2.750	0.0080
X22	1	0.00000135	0.00000247	0.559	0.5759
X23	1	-0.02740	0.02289981	-1.197	0.2315
X24	1	-0.00272	0.00106049	-2.585	0.0103
X25	0	0			
X26	1	9.33117	20.34937750	0.459	0.6466
X27	1	0.29687	0.66709697	0.445	0.6563
X28	1	0.01329	0.02790363	0.476	0.6338

그림 4. 모수추정치 및 검정결과

위 그림 (1)에서 독립변수로 사용된 X1부터 X28 변수는 각각 예측시간대의 온도를 얻기 위하여 (T-2)시간과 (T-1)시간대의 년(Y), 월(M), 일(D), 시(T), 풍향(A), 풍속(B), 총운량(C), 온도(D), 노점온도(E), CEILING 고도(F), 해면기압(G), 상대습도(H) 변수와 (T)시간대의 년(Y), 월(M), 일(D), 시(T)를 나타낸다. 총 28개의 독립변수중 유의하다고(Prob > |T|) 할 수 있는 변수는 14개(X1, X5, X7, X8, X10, X11, X12, X17, X18, X19, X20, X21, X24)로 추정된 회귀직선은식 (11)과 같다.

$$\begin{aligned}
 Y = & -43.67 + 0.035X_1 - 0.005X_5 + 0.032X_7 \\
 & - 0.39X_8 - 0.0001X_{10} + 0.04X_{11} + 0.003X_{12} \\
 & - 0.0023X_{17} - 0.022X_{18} - 0.02X_{19} + 1.34X_{20} \\
 & + 0.04X_{21} - 0.003X_{24}
 \end{aligned} \quad (11)$$

추정된 회귀직선 [식 11]을 이용하여 87년부터 96년간의 데이터를 추정 및 예측한 결과는 [표 1]과 같다.

표 1. 추정된 회귀직선을 이용한 오차온도별 수령률과 수령횟수

연도	예측온도						
	±0.5°C	±1°C	±1.5°C	±2°C	±2.5°C	±3°C	
1987년	수령률(%)	31.59	64.77	89.19	92.07	97.41	99.04
	수령횟수	637	1429	1825	2061	2166	2186
1988년	수령률(%)	29.89	61.37	79.67	91.76	98.54	98.18
	수령횟수	588	1384	1792	2024	2132	2166
1989년	수령률(%)	29.28	60.47	86.32	91.06	96.10	98.41
	수령횟수	540	1388	1772	2008	2120	2171
1990년	수령률(%)	30.64	62.55	80.32	91.84	96.6	98.32
	수령횟수	676	1380	1772	2026	2131	2169
1991년	수령률(%)	35.81	65.35	83.14	94.51	97.77	98.82
	수령횟수	780	1442	1835	2035	2157	2181
1992년	수령률(%)	32.13	62.23	81.18	92.02	97.14	99.09
	수령횟수	709	1373	1791	2030	2143	2186
1993년	수령률(%)	31.27	62.87	82.45	92.56	97.23	99.22
	수령횟수	690	1387	1819	2042	2145	2189
1994년	수령률(%)	30.50	59.65	77.28	1977	95.33	98.09
	수령횟수	673	1316	1705	89.81	2103	2164
1995년	수령률(%)	28.83	58.38	78.39	91.38	96.91	98.73
	수령횟수	636	1288	1729	2016	2138	2178
1996년	수령률(%)	27.74	58.34	79.64	91.61	97.41	98.82
	수령횟수	612	1287	1757	2021	2149	2180

5.2 제안한 예측시스템을 이용한 분석

학습데이터는 1987년, 88년, 89년, 92년 동안의 6. 7. 8월 8,832건의 데이터를 사용하였고, 구성된 신경회로망의 성능을 테스트하기 위하여 나머지 연도의 데이터 13,248건을 테스트 자료로 사용하였다.

신경망 학습방법은 Descending Epsilon 학습 알고리즘을 사용하여 미학습 패턴에 대하여 집중적인 학습을 시도하였고, 학습율은 0.4, 모멘텀값은 0.7로, 학습횟수는 200회로 지정하였다.

학습 후 예측된 온도의 값과 실제 측정된 온도의 차가 ±1°C 이내이면 수령된 것으로 간주하였고 이때 학습오차가 0.25이면 학습이 완료된 것으로 간주하고 학습을 종료하였다.

먼저 학습패턴에 대한 학습을 수행한 후 구성된 신경망의 수령도를 측정하기 위하여 학습패턴(87년, 88년, 89년, 91년)과 테스트 패턴(90년, 92년, 93년, 94년, 95년, 96년)에 대하여 적합도 검사를 실행하였다. 실측온도와 예측온도의 차를 각각 ±0.5°C에서 ±3°C 까지 0.5°C 범위로 측정한 결과는 [표 2]와 같다.

표 2. 오차온도별 수령률과 수령횟수

온도	수령률(%)						
	±0.5°C	±1°C	±1.5°C	±2°C	±2.5°C	±3°C	
1987년	수령률(%)	21.59	41.49	56.09	69.39	81.65	94.91
	수령횟수	471	914	1471	1778	1951	2297
1988년	수령률(%)	27.93	51.31	75.22	80.44	91.75	95.42
	수령횟수	597	1130	1681	1925	2028	2107
1989년	수령률(%)	25.11	53.04	76.48	80.78	93.07	95.71
	수령횟수	576	1181	1733	1948	2048	2115
1991년	수령률(%)	32.15	65.80	83.46	95.01	98.55	99.27
	수령횟수	710	1453	1843	2098	2176	2195
1992년	수령률(%)	33.50	60.29	79.23	89.97	98.45	99.05
	수령횟수	743	1496	1745	2037	2145	2171
1993년	수령률(%)	36.53	66.57	85.09	95.38	97.28	99.41
	수령횟수	806	1470	1879	2106	2146	2195
1994년	수령률(%)	38.44	69.80	87.57	94.96	98.86	99.68
	수령횟수	848	1540	1932	2095	2181	2199
1995년	수령률(%)	32.13	64.31	78.66	90.80	96.78	99.04
	수령횟수	709	1420	1737	2005	2137	2187
1996년	수령률(%)	37.44	68.35	84.85	94.19	98.09	99.18
	수령횟수	826	1508	1872	2078	2164	2188
1997년	수령률(%)	32.00	60.01	81.74	94.89	97.55	99.45
	수령횟수	706	1324	1805	2095	2154	2196

아래의 [그림 5]는 각 연도에 대한 오차온도별 패턴 수령률을 그래프로 표현하였다.

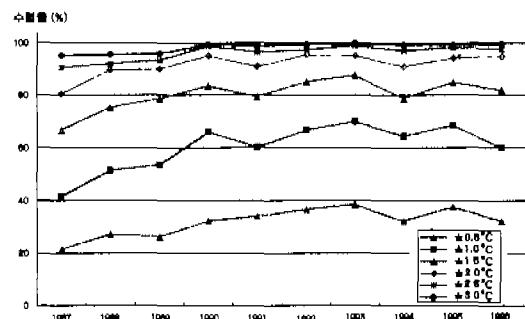


그림 5. 오차온도별 신경망 모델의 수령률

위의 결과에서 볼 수 있듯이 학습패턴으로 사용하였던 1987년, 88년, 89년, 91년의 수렴률의 경우 오차범위 $\pm 1^{\circ}\text{C}$ 를 기준으로 각각 41.39%, 51.31%, 53.44%, 60.29%를 기록하였고, 테스트 패턴의 경우 각각 65.80%, 66.57%, 69.80%, 64.31%, 68.35%, 8.8 60.01%의 수렴률을 나타내었다. 또한 다른 오차범위내에서도 각 연도별 차이가 이와 비슷한 비율로 나타났다. 이와같이 같은 학습패턴이라도 연도별로 수렴률 차이가 나타나는 이유는 신경망 학습시 학습패턴의 순서에 의하여, 초기학습패턴보다 마지막 학습패턴의 수정값이 신경망 결정에 큰 영향을 미치는 것으로 분석할 수 있다.

또한 [그림 5]의 연도별 신경망 모델의 예측 그래프를 살펴보면 다른 패턴분석에 비하여 테스트 패턴의 수렴율이 학습패턴 수렴률에 비하여 전체적으로 우수하게 나타나는 것을 볼 수 있다. 이것은 신경망 학습을 위한 기상패턴의 모델이 각 연도별의 특정월에 걸쳐 변동의 범위가 크지않고 일정한 범위내에서 유지되었기 때문에 테스트 자료로 사용된 연도외 예측률이 오히려 학습패턴에 비하여 우수한 결과를 얻을 수 있는 것이라 분석된다.

5.3 시계열 분석과 예측시스템의 결과 비교

실생활에 적용할 수 있는 오차범위인 $\pm 0.5^{\circ}\text{C}$ 와 $\pm 1^{\circ}\text{C}$ 를 기준으로 시계열분석방법과 제안한 예측시스템의 결과를 [그림 6]으로 표현하였다.

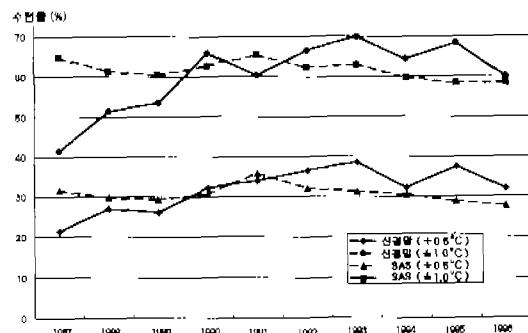


그림 6. 수렴오차 $\pm 0.5^{\circ}\text{C}$, $\pm 1^{\circ}\text{C}$ 일 때 시계열예측과 예측시스템의 각 연도별 수렴률

위 [그림 6]에서 학습 패턴(87, 88, 89, 91년)데이터를 이용한 기온예측의 경우를 살펴보면 시계열 분석을 이용한 예측결과는 각각 $\pm 0.5^{\circ}\text{C}$ 의 경우 평균 31.57%, $\pm 1.0^{\circ}\text{C}$ 의 경우 평균 62.99%의 수렴율을 기록하였고 제안한 예측시스템의 경우 평균 27.09%, 61.95%의 수렴율을 얻었다. 따라서 위의

수렴결과만을 살펴보면 학습패턴 데이터를 이용한 예측결과에 있어서는 신경망을 이용한 예측기법에 비하여 시계열 예측방법이 더 우수한 결과를 얻을 수 있는 것으로 분석할 수 있다. 하지만 테스트 패턴(90, 92, 93, 94, 95, 96년)의 경우 오히려 제안한 예측시스템의 결과 각각 평균 34.62%($\pm 0.5^{\circ}\text{C}$), 65.44%($\pm 1.0^{\circ}\text{C}$)로 시계열분석을 이용한 예측값 30.19%($\pm 0.5^{\circ}\text{C}$), 60.67% ($\pm 1.0^{\circ}\text{C}$)에 비하여 더 우수한 결과를 보였다. 이는 시계열 분석을 통한 예측값들은 학습패턴들내의 회귀관계를 이용하기 때문에 한정된 표본내의 데이터에 대해서는 신경망에 비하여 더 나은 결과를 유추해 내지만 학습표본이 외의 데이터에 대해서는 신경망을 이용한 추정방법에 비하여 예측률이 떨어지는 것을 확인할 수 있다. 따라서 미래의 예측능력에 있어서는 신경망을 이용한 예측시스템이 더 우수한 성능을 나타낸다 할 수 있다.

VI. 결 론

본 논문에서는 신경망모델을 이용한 기후변화예측을 위하여 기온예측시스템모델의 구성과 함께 미래 예측률의 일반성을 보였다. 신경회로망은 학습데이터를 통하여 일반성의 특징이 부여되고, 미 학습 기상정보에 대한 일반적 예측을 가능케 하였다. 또한 학습패턴 데이터(87, 88, 89, 91년)를 실험한 결과, 시계열 분석을 이용한 경우 수렴오차 $\pm 0.5^{\circ}\text{C}$ 에서 31.57%, $\pm 1.0^{\circ}\text{C}$ 의 경우 평균 62.99 %의 수렴율을 기록한데 반하여, 제안한 예측시스템의 경우 평균 27.09%, 61.95%의 수렴율을 얻어서 학습패턴의 경우 시계열 예측의 결과가 우수하였지만 비 학습데이터인 테스트 패턴(90, 92, 93, 94, 95, 96년)을 실험한 경우 제안한 예측시스템에서는 수렴온도 오차 $\pm 0.5^{\circ}\text{C}$ 에서 평균 34.62%, $\pm 1.0^{\circ}\text{C}$ 의 경우 65.44%의 수렴율을 얻어 시계열 분석방법을 이용한 평균수렴율 30.19%, 60.67%에 비하여 우수함을 보였다.

이는 시계열 예측방법에 비하여 신경망을 이용한 제안된 예측시스템이 미래 예측능력에서 더 우수한 성능을 보인다는 결론을 내릴수 있다.

향후 타 기상요인에 대한 예측과 함께 기후결정 요인에 대한 정확한 선별과 기상데이터의 효율적 관리가 선결되어야하며, 기상예측을 위한 신경망 최적화 설계에 대한 연구가 이루어져야 할 것이다.

참 고 문 헌

- [1] 박성진, “신경망을 이용한 태풍진로예측”, 포항공대, 1996.
- [2] 윤여창, “시계열자료에서 신경망이론의 적용”, 박사학위, 성균관대학교, 1995.
- [3] H.-S. Shin, “Regional drought analysis based on neural network in southwestern colorado”, ASCE J. of Hydrologic Engineering, accepted., 1998.
- [4] 정재성, “실시간 기상자료와 신경망이론에 의한 다자점 강우예측 모형연구”, 박사학위, 전북대학교, 1996.
- [5] 오남선 외, “신경망 이론에 의한 강우예측에 관한 연구”, 한국수자원학회지, 제29권, 제4호 pp.109-118.
- [6] 이성덕, “시계열 모형의 적합도 검정에 관한 시뮬레이션 연구”, 용융통계학회 1권 1호 pp 131-140. 1994.
- [7] 조신섭, “시계열 모형을 이용한 측우기 자료와 분석”, 용융통계학회 9권 2호 PP25-43, 1996.
- [8] Y.H.Yu, R.F.Simmons, “Descending Epsilon in Back-Propagation : A Technique for Better Generalization”, IEEE IJCNN, Vol. 3. pp.167-172, 1990.

이기준(Kee-Jun Lee)



정회원

- 1994년 : 조선대학교 전산통계학과(이학사)
1997년 : 조선대학교 일반대학원 전산통계학과 (이학석사)
1999년 3월 ~ 현재 : 조선대학교 일반대학원 전산통계학과 박사과정

«주관심 분야» 신경망, 패턴인식, 인공지능, 분산네트워크 시스템

e-mail : cholee@shinbiro.com

강경아(Kyung-A Kang)



정회원

- 1993년 : 동신대학교 물리학과 (이학사)
1998년 : 조선대학교 일반대학원 전산통계학과(이학석사)
1999년 3월 ~ 현재 : 조선대학교 일반대학원 전산통계학과 박사과정

«주관심 분야» 신경망, 영상처리, 패턴인식, 유전자암 고리즘

e-mail : kkangel@hanmail.net

정채영(Chae-Young Chung)



정회원

- 1983년 : 조선대학교 컴퓨터공학과 (공학사)
1986년 : 조선대학교 일반대학원 전자과 전산전공 (공학석사)
1989년 : 조선대학교 일반대학원 전자과 전산전공 (공학박사)

1986년 ~ 현재 : 조선대학교 자연과학대학 수학 · 전산 통계학부 부교수

«주관심 분야» 영상처리, 신경망, 데이터베이스, 멀티미디어 컨벤션

e-mail : cyjung@mail.chosun.ac.kr