

전력부하의 유형에 따른 신경회로망의 단기부하예측에 관한 연구

*박후식, **이상성, *김형수, *문경준, **박준호

*부산대학교 전기공학과, **부산대학교 전기공학과 교수

Short-term Load Forecasting Using Neural Networks By Electrical Load Pattern

H. S. Park, S. S. Lee, H. S. Kim, K. J. Mun, J. H. Park
Department of Electrical Engineering, Pusan National University

Abstract : This paper presents the development of an Artificial Neural Networks(ANN) for Short-Term Load Forecasting(STLF). First, used historical load data is divided into 5 patterns for the each seasonal data using Kohonen networks. Second, classified data is used as inputs of Back-propagation networks for next day hourly load forecasting. The proposed method was tested with KEPCO hourly record (1994-95) and we obtained desirable results.

1. 서 론

산업이 발달함에 따라 점점 복잡해지고 대규모화되고 있는 전력계통에서 소비자에게 싸고 양질의 전력을 공급하고 계통을 안정하게 운영하기 위해 시시각각으로 변동하는 부하를 정확하게 예측하는 것이 중요한 과제이다. 이런 부하예측은 예측기간에 따라 순시예측, 단기예측, 중기예측, 장기예측으로 분류된다. 중장기 부하예측은 발전전 및 송배전 계통의 확장 및 운영계획 등에 사용되며, 1일~1주일의 시간별 부하를 예측하는 단기부하예측은 1일~1주간 발전계획, 발전기의 기동정지계획, 경제급전 등에 사용된다.

또한, 부하의 정확한 예측은 전력공급의 경제성 및 안정성에 밀접한 관계가 있어 다양한 형태의 부하예측 모델, 즉 통계적인 방법인 시계열 예측모형[1]과 중회귀적 방법[2]과 최근에는 인공지능기법인 전문가 시스템[3], 신경회로망[4-6]을 이용한 부하예측 방법이 제안되었다. 통계적인 예측방법은 예측모델의 파라메터를 부하변동에 따라 적응, 수정하는 방법이 필요하고 이 경우 입·출력관계를 모델링하기가 어렵다. 한편, 신경회로망을 이용한 방법은 학습을 통

여 부하의 입·출력관계를 모델링하기가 쉽고, 날씨, 습도등과 같은 부하에 영향을 주는 요소를 고려하기가 간단하다. 그런데 신경회로망의 학습데이터를 구성할때 달력에 의한 유형분류는 부하를 유형별로 정확하게 분류하기가 어렵다.

본 논문에서는 자기 조직화 기능을 가진 코호넨 신경회로망을 이용하여 각 계절별 부하를 평일, 토요일, 일요일, 월요일, 특수일의 유형별로 분류하고 분류된 데이터를 이용하여 역전파 학습 알고리즘으로 학습시킴으로써 다음날의 24시간 부하를 보다 정확하게 예측하는 방법을 제안하였다. 부하예측의 효용성을 입증하기 위해 1994-95년에 한국전력에서 측정한 우리나라의 실제 부하를 이용하였다.

2. 신경회로망

2.1 코호넨 신경회로망

코호넨 신경회로망은 입력층과 출력층만을 가지는 단층구조로 자기조직화(self-organizing)특성을 가지고 있다. 즉 데이터가 주어지면 자동적으로 유사한 유형끼리 분류해주는 클러스터링 기능을 갖는다. 출력 노드에서는 각 입력값에 대하여 유클리디안 거리를 계산하여 가장 가까운 노드가 승리노드(winner node)가 되며 승리노드만이 출력값을 갖는다. 그리고 코호넨 신경회로망의 학습시 입력벡터는 정규화해야 한다. 코호넨 신경망의 학습규칙은 식(1)과 같다.

$$W_{\text{NEW}} = W_{\text{OLD}} + \alpha(t)(X - W_{\text{OLD}}) \quad (1)$$

여기서, W : 연결강도

X : 입력벡터

$\alpha(t)$: 학습률

3. 신경망에 의한 부하유형 분류 및 부하 예측

3.1 코호넨 신경망에 의한 부하유형 분류

코호넨 신경회로망의 입력으로 사용한 부하데이터의 정규화(scaling)는 식 (2)와 같다

$$L(d, h) = \frac{L(d, h)_{MW}}{L_{MAX}} \quad (2)$$

$L(d, h)$: d일 h시각의 정규화된 부하값

$L(d, h)_{MW}$: d일 h시각의 실제부하값[MW]

L_{MAX} : 계절별 시간부하의 최대부하값[MW]

코호넨 신경회로망으로 1일 부하를 평일, 월요일, 토요일, 일요일, 특수일의 유형별로 분류하기 위해 출력층의 노드수를 5개로 정하였고, 입력데이터는 1일의 각 시각 부하데이터를 식 (2)로 정규화한 데이터를 이용하였으므로 입력층의 노드수는 24개로 정하였다. 또한 학습률은 초기에는 0.5로 설정한 후 점차 감소시켰다. 부하유형 분류를 위해 먼저 1994-5년의 부하데이터를 계절별로 봄(3, 4, 5월), 여름(6, 7, 8월), 가을(9, 10, 11월), 겨울(12, 1, 2월)로 구분하였다. 코호넨 신경회로망에 의한 부하유형을 분류한 결과는 표 1과 같다. 예를 들면 봄의 경우, 달력상의 평일 데이터수는 50개이지만 코호넨 신경회로망에 의한 평일 데이터수는 49개이다.

표 1 코호넨 신경회로망에 의한 부하유형 분류의 결과

계절 유형 (A/B)	봄 (A/B)	여름 (A/B)	가을 (A/B)	겨울 (A/B)	합계 (A/B)
평일	49/50	46/51	36/40	56/59	187/200
월요일	13/12	16/12	13/11	15/13	57/48
토요일	12/13	12/13	11/10	14/15	49/51
일요일	13/13	15/13	11/10	14/13	53/49
특수일	5/4	3/3	4/4	7/6	19/17
합계	92/92	92/92	75/75	106/106	365/365

A = 코호넨 신경회로망으로 분류한 데이터 수

B = 달력으로 분류한 데이터 수

3.2 역전파 학습 알고리즘에 의한 부하예측

부하예측은 각 계절별, 유형별로 분류한 부하데이터중에서 계절별의 처음 두달에 속하는 데이터를 학습데이터로 구성하였고, 세 번째 달의 데이터로 학습성능을 평가하였다. 부하예측에 사용한 전방향 신경회로망의 입력층의 노드수 48개, 은닉층의 노드수 48개, 출력층의 노드수 24개로

구성하였다. 그리고 신경회로망의 학습알고리즘으로 모멘텀을 포함한 델타규칙을 사용하였고, 학습률은 초기값 0.9에서 학습횟수에 따라 점차 감소시키고, 모멘텀계수는 0.1에서 학습횟수에 따라 증가시켰다. 학습에 사용된 입력과 출력은 표 2와 같다.

표 2 신경망의 입력과 출력

입력노드	학습데이터
1-24	{ $L(d-2, h)$ $h = 1, \dots, 24$ }
25-48	{ $L(d-1, h)$ $h = 1, \dots, 24$ }
출력노드	학습데이터
1-24	{ $L(d, h)$ $h = 1, \dots, 24$ }

신경회로망의 입력은 식 (3)을 이용하여 0에서 1사이로 정규화된 값을 사용하였다.

$$L(d, h) = \frac{L(d, h)_{MW} - L_{MIN}}{L_{MAX} - L_{MIN}} \quad (3)$$

$L(d, h)$: d일 h시각의 정규화된 부하값

$L(d, h)_{MW}$: d일 h시각의 실제 부하값[MW]

L_{MAX} : 학습데이터의 최대부하값 [MW]

L_{MIN} : 학습데이터의 최소부하값 [MW]

각 계절별, 평일 데이터로 학습된 신경회로망으로 다음날의 24시간 부하를 예측하였고, 실제부하값과 비교하여 퍼센트오차를 구하였다. 퍼센트 오차는 식 (4)와 같다.

$$Err(\%) = \frac{1}{N} \sum_{d=1}^N \frac{|\hat{L}(d, h) - L(d, h)|}{L(d, h)} \times 100 \quad (4)$$

$\hat{L}(d, h)$: d일 h시각의 예측부하값[MW]

$L(d, h)$: d일 h시각의 실제부하값[MW]

N : 계절별 예측달의 평일의 개수

표 3은 1994년 12월, 1995년 1월, 1995년 3, 4월, 1995년 6, 7월, 1995년 9, 10월의 데이터를 이용하여 각 계절별로 학습한 부하예측 신경회로망을 이용하여 1995년 2월, 5월, 8월, 11월의 부하를 예측한 후 월 평균, 시간별 평균오차를 나타내었다. 표 3에서 보는 바와 같이 계절별로 1개월씩 예측한 4개월동안의 평균 시간별 오차는 약 1.5~2.0[%]이고 평균오차는 1.55[%]로 나타났다.




표3. 전력부하의 실제값과 예측값의 퍼센트 오차

계절	평균 퍼센트 오차[%]				
	2월	5월	8월	11월	평균
1	1.022	0.491	2.031	1.205	1.437
2	0.807	0.620	2.240	2.032	1.425
3	1.082	0.602	2.317	1.862	1.466
4	1.180	0.712	2.624	1.654	1.542
5	1.253	0.625	2.655	1.308	1.460
6	0.789	0.648	3.068	1.807	1.578
7	1.031	0.964	2.293	2.014	1.575
8	1.179	0.862	1.986	1.700	1.432
9	0.587	0.744	2.220	1.495	1.262
10	0.733	1.097	2.338	1.439	1.402
11	0.590	0.925	2.500	1.536	1.388
12	0.762	1.471	3.160	0.495	1.472
13	0.766	1.355	3.218	2.281	1.905
14	1.190	1.552	3.437	1.619	1.950
15	0.762	1.310	2.672	1.519	1.566
16	0.616	2.117	2.724	1.163	1.655
17	1.159	1.442	3.306	1.144	1.763
18	2.383	1.088	2.859	2.161	2.123
19	1.181	1.305	2.430	1.691	1.652
20	1.133	1.660	1.979	0.819	1.398
21	0.794	1.043	2.910	0.583	1.333
22	0.954	1.782	1.804	1.381	1.480
23	2.088	0.649	1.798	1.376	1.478
24	1.435	0.952	1.817	1.716	1.480
평균	1.061	1.126	2.516	1.500	1.551

그림 1은 1995년 2월의 11개의 평일데이터의 실제부하와 예측된 부하를 나타내었다.

5. 결론

본 논문에서는 예측의 정확도를 높이기 위해 코호넨 신경회로망을 사용하여 부하 데이터를

평일, 월요일, 토요일, 일요일, 특수일 등의 유형별로 먼저 분류하고, 분류된 데이터를 이용하여 역전파 학습 알고리즘으로 학습시킴으로써 다음날의 시간별 전력부하를 예측하는 방법을 제안하였다.

실제통의 부하데이터를 사용한 사례연구를 통하여 제안한 방법의 응용가능성을 입증하였다. 제안한 방법에서 여름철에는 날씨요소(최대온도, 최소온도, 평균온도, 습도 등)를 고려하면 부하의 예측오차를 더욱 감소시킬 수 있으리라 생각된다.

(참고문헌)

- [1] H. J. Park, et al, "Composite Modeling for Adaptive Short-Term Load Forecasting", IEEE Trans. on Power Systems, Vol.3, pp. 392-399, 1988.
- [2] N. F. Hubele, C. S. Cheng, "Identification of Seasonal Short-term Forecasting Models Using Statistical Decision Function", IEEE Trans. on Power Sys., Vol.8, No.1, pp. 42-46, 1986.
- [3] K. I. Ho, et al, "Short Term Load Forecasting of Taiwan Power System Using a Knowledge-Based Expert System", IEEE Trans. on Power Systems, Vol. 5, No.4, pp. 1214-1219, 1990.
- [4] K. Y. Lee, et al, "Short-term Load Forecasting Using an Artificial Neural Network", IEEE Trans. on Power Systems, Vol.7, No.1, pp. 125-132, Feb. 1992.
- [5] A. G. Bakirtzis, et al., "A Neural Network Short Term Load Forecasting Model For The Greek Power System", IEEE Trans. on Power Systems, Vol.11, No.2, May 1996.
- [6] T. Bauman, et al, "Application of the Kohonen Network to Short-Term Load Forecasting", IEEE Trans. PWRS, pp. 407-412, 1993.