

Application of Neural Networks to Short-Term Load Forecasting Using Electrical Load Pattern

朴厚植* · 文景俊** · 金亨洙** · 黃琪鉉** · 李和錫*** · 朴俊灝****

(Hu-Sik Park · Kyeong-Jun Mun · Hyung-Su Kim · Gi-Hyun Hwang · Hwa-Seok Lee · June Ho Park)

Abstract - This paper presents the methods of short-term load forecasting using Kohonen neural networks and back-propagation neural networks. First, historical load data is divided into 5 patterns for the each seasonal data using Kohonen neural networks and using these results, load forecasting neural network is used for next day hourly load forecasting. Next day hourly load of weekdays and weekend except holidays are forecasted. For load forecasting in summer, max-temperature and min-temperature data as well as historical hourly load data are used as inputs of load forecasting neural networks for a better forecasting accuracy. To show the possibility of the proposed method, it was tested with hourly load data of Korea Electric Power Corporation(1994-95).

Key Words : Short-term load forecasting, Kohonen neural networks, Back-propagation neural networks

1. 서론

복잡하고 대규모화된 전력 계통의 최적 운용계획을 위해서 연간 최대전력부하 및 시간별 전력부하에 대한 장기 및 단기간의 전력부하예측이 필요하다. 특히, 단기부하예측은 발전비용 및 신뢰도와 밀접한 관계를 가지며, 그 결과는 예측일 가까운 날의 수요패턴과 기상변화 등에 많은 영향을 받으며 전력계통의 제어 및 단기계획, 전력조류계산 등의 입력자료로 사용된다.

단기부하를 예측하기 위한 종래의 방법으로는 시계열 방법 [1], 지수평활화법 [2], 자기회귀 이동평균모델(autoregressive moving average model) [3], 상태공간모델 [4] 등이 있다. 그러나 이러한 방법들은 날씨와 같이 부하특성에 영향을 미치는 여러 변수를 반영하기 힘들거나, 모델링이 너무 복잡한 단점이 있다. 이러한 문제를 해결하기 위하여 전문가의 지식과 경험을 바탕으로 과거 부하 데이터, 온도, 풍속, 요일별 유형, 하루의 시간대, 계절 등의 데이터를 이용한 전문가 시스템도 많이 연구 [5] 되고 있지만 지식기반을 적절히 구축하기 어려운 문제가 있다. 이러한 문제 즉, 유연한 입력선택, 모델링의 복잡성, 지식기반구축 등과 같은 문제를 적절히 해결할 수 있는 방법으로서 신경회로망이 알려져 있으며 전력계통의 부하예측에도 신경회로망(neural network; NN)을 이용한 방법들이

계속 연구 [6-9] 되고 있다. 특히 코호넨 신경회로망을 도입한 연구 [10-11]로서, 코호넨 신경회로망으로 부하예측을 한 후 단층 delta rule로 기상요소를 보상하는 방법 [10] 및 부하분류 및 예측에 모두 코호넨 신경회로망을 이용한 방법 [11]도 수행되었다.

본 논문에서는 자기 조직화 기능을 가진 코호넨 신경회로망을 이용하여 각 계절별 부하를 평일, 월요일, 토요일, 일요일, 특수일 등의 유형별로 분류하고, 분류된 데이터를 이용하여 역전과 학습법으로 학습시킴으로써 다음날의 시간별 부하를 예측하는 방법을 제안하였다. 또한 여름철 부하예측시 날씨영향을 고려하기 위해서 최대온도, 최소온도를 부하데이터와 함께 부하예측 신경회로망의 입력으로 사용하여 부하예측의 정확도를 향상시켰다.

제안한 방법의 효용성을 평가하기 위해서 1994~1995년의 2년간 관측된 우리나라의 실제부하를 이용하여 성능평가를 해 본 결과, 각 계절별, 유형별 평균 퍼센트 오차가 평일, 월요일, 토요일, 일요일 각각에 대해 1.32[%], 1.41[%], 1.37[%], 1.76[%]로 비교적 우수한 결과를 나타내었다. 또한 여름철의 부하예측에서 온도를 고려하지 않은 경우의 유형별 평균 퍼센트 오차가 2.02[%]인 반면, 온도를 고려한 경우는 1.80[%]로 줄어 온도영향을 고려함으로써 여름철 부하예측의 정확도를 향상시킬 수 있었다.

2. 신경회로망에 의한 부하유형분류 및 부하예측 방법

2.1 코호넨 신경회로망에 의한 부하유형분류

코호넨 신경회로망은 입력층과 출력층만을 가지는 단층구조로 자기조직화를 이용하여 데이터가 주어지면 자동적으로 유사한 유형끼리 분류하는 클러스터링 기능을 가지고 있다.

* 準 會 員 : 現代重工業 造船事業部 電裝設計部
 ** 正 會 員 : 釜山大 大學院 電氣工學科 博士課程
 *** 正 會 員 : 巨濟大學 電氣科 專任講師 · 工博
 **** 正 會 員 : 釜山大 工大 電氣工學科 教授 · 工博
 接手日子 : 1998年 5月 25日
 最終完了 : 1998年 11月 24日

본 논문에서는 코호넨 신경회로망을 이용하여 각 계절별 1일 부하를 평일, 월요일, 토요일, 일요일, 특수일의 유형별로 분류하였다.

1주일의 부하유형을 살펴보면, 월요일의 부하는 전날인 일요일의 영향으로 오전시간의 부하가 평일보다 낮게 나타나고, 토요일의 부하는 오전시간대는 평일과 비슷하지만 오후시간대는 평일 부하보다 낮게 나타난다. 일요일의 부하는 다른 요일의 부하보다 훨씬 낮게 나타나고, 국정공휴일이나 설날, 추석 등의 특수일은 부하값이 다른 요일유형의 부하값보다 작지만 일요일의 부하 패턴과는 다르게 나타난다. 또한 이러한 특수일을 전후로 한 날의 부하유형도 달력만으로 분류하기에는 불명확하다. 따라서 본 논문에서는 실제 부하를 자동으로 여러 유형으로 분류하는 코호넨 신경회로망을 사용하였다. 그림 1은 계절별 부하 유형분류를 위한 코호넨 신경회로망의 구성도를 나타낸다. 코호넨 신경회로망에서 입력은 식 (1)로 정규화한 1일의 시간별 부하데이터를 사용하였으며 출력은 입력데이터를 평일, 월요일, 토요일, 일요일, 특수일의 5가지 유형으로 분류하였다.

$$L(d, h)_N = \frac{L(d, h)_A}{L_{MAX}} \quad (1)$$

여기서, $L(d, h)_N$: d일 h시각의 정규화된 부하값
 $L(d, h)_A$: d일 h시각의 실제 부하값[MW]
 L_{MAX} : 계절별 시간부하의 최대 부하값[MW]

2.2 역전파 학습법에 의한 부하예측

이 절에서는 부하의 유형이 여름철에 비해 비슷한 봄, 가을, 겨울철인 경우와 온도의 영향을 많이 받는 여름철인 경우로 나누어 예측방법을 달리하였다.

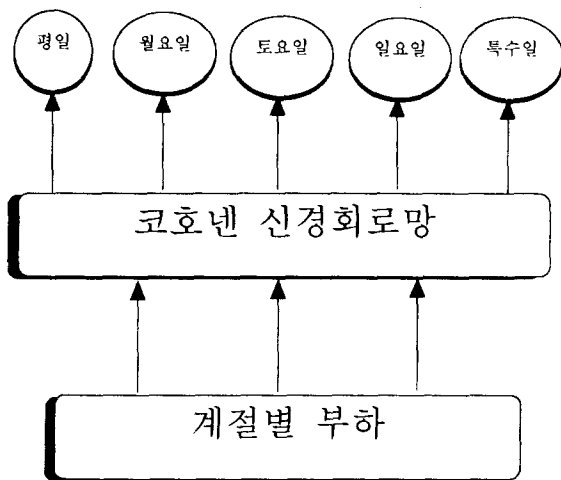


그림 1 코호넨 신경회로망을 이용한 부하 유형분류
 Fig. 1 Load pattern classification using Kohonen neural network

2.2.1 봄, 가을, 겨울철의 부하예측

코호넨 신경회로망에 의해 분류된 유형별 부하데이터를 이용하여 다음날 24시간 부하를 예측하기 위해 역전파 학습법을 사용하였다. 학습데이터로는 코호넨 신경회로망에 의해 각 계절별, 유형별로 분류한 부하데이터중에서 계절별 처음 두 달의 데이터를 사용하였고, 학습성능은 세 번째 달의 부하데이터로 평가하였다. 전방향 신경회로망의 각층의 뉴런수는 입력층 48개, 은닉층 48개, 출력층 24개로 구성하였다. 신경회로망의 입력데이터는 식 (2)를 이용하여 0에서 1사이로 정규화 하였으며, 학습률은 초기값 0.9에서 학습횟수의 증가에 따라 점차 감소시키고, 모멘텀 계수는 0.1에서 학습횟수가 증가함에 따라 증가시켰다.

$$L(d, h)_N = \frac{L(d, h)_A - L_{MIN}}{L_{MAX} - L_{MIN}} \quad (2)$$

여기서, $L(d, h)_A$: d일 h시각의 정규화된 부하값
 $L(d, h)_N$: d일 h시각의 실제 부하값[MW]
 L_{MAX} : 학습데이터의 최대부하값 [MW]
 L_{MIN} : 학습데이터의 최소부하값 [MW]

본 논문에서 학습에 사용된 입력 및 출력데이터의 구성은 평일, 토요일, 일요일의 부하예측시에는 표 1과 같이 결정하였다. 또한, 월요일 부하를 예측할 경우에는 표 1의 방법으로 할 경우 입력데이터가 변동이 많은 토요일, 일요일 데이터이기 때문에 표 2와 같이 평일인 금요일을 하루 더 추가하였다.

표 1 신경회로망의 입·출력 (평일, 토요일, 일요일)
 Table 1 NN inputs and outputs (weekdays, saturday, sunday)

입력뉴런	학습데이터
1-24	{ L(d-2, h), h = 1, ..., 24 }
25-48	{ L(d-1, h), h = 1, ..., 24 }
출력뉴런	학습데이터
1-24	{ L(d, h) h = 1, ..., 24 }

표 2 신경회로망의 입·출력 (월요일)
 Table 2 NN inputs and outputs (monday)

입력뉴런	학습데이터
1-24 25-48 49-72	{ L(d-3, h) h = 1, ..., 24 }
	{ L(d-2, h) h = 1, ..., 24 }
	{ L(d-1, h) h = 1, ..., 24 }
출력뉴런	학습데이터
1-24	{ L(d, h) h = 1, ..., 24 }

2. 2. 2 여름철의 부하예측

여름철의 부하예측에서는 1994년 7, 8월의 부하데이터와 온도데이터를 사용하여 1995년 7, 8월의 부하를 예측하였다. 이때 온도데이터 외에 습도, 불쾌지수, 강수량 등 여러 날씨 요소를 이용할 수 있을 것으로 사료되나 부하에 가장 많은 영향을 줄 것으로 생각되는 온도데이터를 우선 적용하였다. 이때 이용한 온도데이터는 현재 우리 나라 기상청에서 예측하고 있고, 한국전력 보고서에 나타난 전국의 대도시별 전력 수요분포를 근거로 수요가 큰 전국의 5대 도시(서울, 부산, 대전, 대구, 광주)를 선정하여 그 지역의 기상대에서 측정 및 예측한 최대, 최소온도이며, 신경회로망의 입력데이터로는 해당날짜의 최대, 최소온도와 예측할 날의 최대, 최소온도를 입력으로 사용하였다. 또한 봄, 가을, 겨울철의 부하예측시와 마찬가지로 본 논문에서 학습에 사용된 입력 및 출력데이터의 구성은 평일, 토요일, 일요일의 부하예측시에는 표 3과 같이 정하였고, 월요일 부하를 예측할 경우에는 표 4와 같이 정하였다.

그림 2는 본 논문에서 제안한 단기 부하예측 신경회로망의 전체 구성도이다. 먼저, 각 계절별(봄, 여름, 가을, 겨울) 부하를 코호넨 신경회로망을 이용하여 평일, 월요일, 토요일, 일요일, 특수일의 유형으로 분류하였고, 분류된 데이터를 이용하여 다음날의 시간별 전력부하를 예측하였다. 특히, 여름철의 부하예측시 날씨영향을 고려하기 위해서 부하데이터와 함께 최대, 최소온도를 신경회로망의 입력으로 추가하여 부하예측의 정확도를 향상시켰다.

표 3 신경회로망의 입·출력 (평일, 토요일, 일요일)

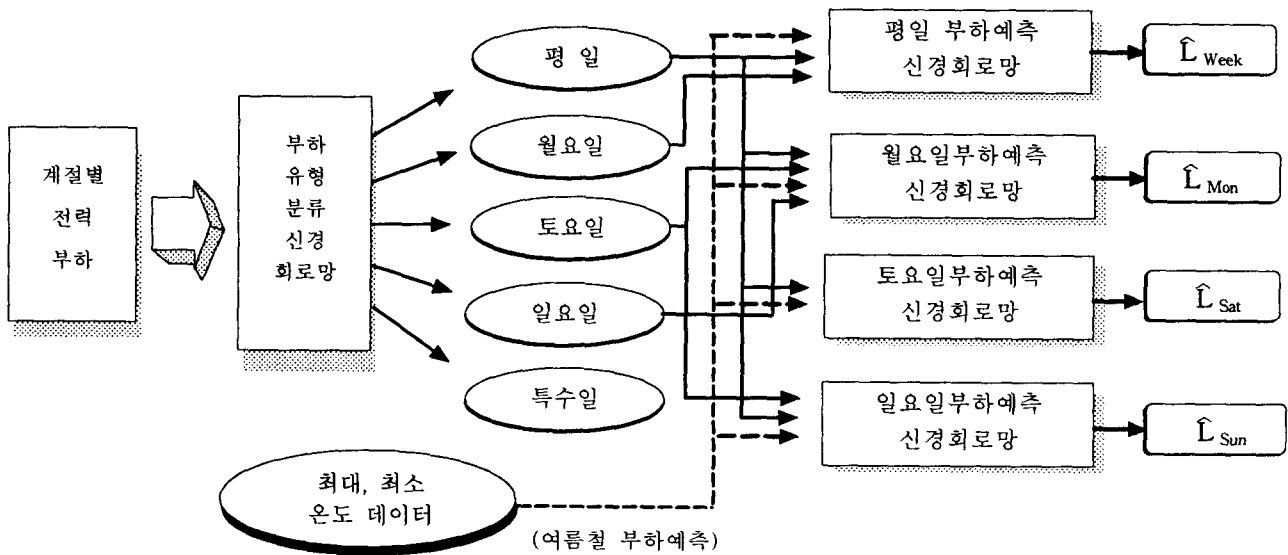
Table 3 NN inputs and outputs (weekdays ,saturday, sunday)

입력뉴런	학습데이터
1-24	{ L(d-2, h), h = 1, ..., 24 }
25-48	{ L(d-1, h), h = 1, ..., 24 }
49-63	{ T_MAX (d-2, d-1, d), 5개 도시 }
64-78	{ T_MIN (d-2, d-1, d), 5개 도시 }
출력뉴런	학습데이터
1-24	{ L(d, h) h = 1, ..., 24 }

표 4 신경회로망의 입·출력 (월요일)

Table 4 NN inputs and outputs (monday)

입력뉴런	학습데이터
1-24	{ L(d-3, h) h = 1, ..., 24 }
25-48	{ L(d-2, h) h = 1, ..., 24 }
49-72	{ L(d-1, h) h = 1, ..., 24 }
73-92	{ T_MAX (d-3, d-2, d-1, d), 5개 도시 }
93-112	{ T_MIN (d-3, d-2, d-1, d), 5개 도시 }
출력뉴런	학습데이터
1-24	{ L(d, h) h = 1, ..., 24 }



\hat{L}_{Week} : 평일의 시간별 24시간 부하예측값 \hat{L}_{Mon} : 월요일의 시간별 24시간 부하예측값
 \hat{L}_{Sat} : 토요일의 시간별 24시간 부하예측값 \hat{L}_{Sun} : 일요일의 시간별 24시간 부하예측값

그림 2 단기부하 예측 신경회로망의 구성
 Fig. 2 Structure of NN for Short-Term Load Forecasting

3. 사례 연구

3.1 부하유형분류

본 논문에서는 1994-95년의 봄(3, 4, 5월), 여름(6, 7, 8월), 가을(9, 10, 11월), 겨울(12, 1, 2월)의 계절별 부하데이터를 코호넨 신경회로망을 이용하여 5가지 유형으로 분류하였으며 그 결과를 표 5에 나타내었다. 표 5에서 A는 코호넨 신경회로망으로 분류한 데이터 수, B는 달력으로 분류한 데이터 수를 나타낸다. 예를 들면 봄의 경우, 달력상의 평일 수는 50일이지만 코호넨 신경회로망에 의해 분류된 평일 수는 49일이었다.

표 5 부하유형 분류 결과

Table 5 Results of load pattern classification

계절 유형	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


3.2 부하예측

본 연구에서 달력분류에 의한 부하예측도 시도하였으나 코호넨 신경회로망을 이용하여 분류된 데이터를 이용한 것 보다 예측오차 관점에서 큰 값을 나타내어, 본 논문에서는 코호넨 신경회로망을 이용한 경우에 대해서만 기술하겠다. 본 논문에서 예측부하의 정확도를 평가하기 위한 퍼센트 오차를 식 (3)과 같이 정하였다.


$$\text{Error}(\%) = \frac{1}{N} \sum_{d=1}^N \frac{|\hat{L}(d,h) - L(d,h)|}{L(d,h)} \times 100 \quad (3)$$

여기서, $\hat{L}(d,h)$: d일 h시각의 예측부하값[MW]
 $L(d,h)$: d일 h시각의 실제부하값[MW]
 N : 계절별 예측달의 해당 유형 데이터의 수

코호넨 신경회로망을 이용한 부하유형 결과로부터 봄, 가을, 겨울철의 부하를 예측하기 위한 학습데이터를 식 (2)를 사용하여 정규화 한 후 표 1 및 표 2의 형태로 구성하였다. 학습은 겨울철인 경우 1994년 12월, 1995년 1월, 봄철인 경우 1995년 3, 4월, 여름철인 경우 1994년 7, 8월, 가을철인 경우 1995년 9, 10월의 데이터를 이용하여 각 계절별, 유형별로 행하였다. 평가는 1995년 2월(겨울), 5월(봄), 7, 8월(여름), 11월(가을)의 데이터를 이용하였다. 예로서 그림 3에 1995년 봄, 여름에 대한 평일부하의 예측결과를 나타내었고, 그림 4에는 1995년 봄, 여름에 대한 월요일 부하의 예측결과를 나타내었다. 그림에서 보는 것처럼 여름철인 경우에 봄인 경우보다 오차가 많음을 알 수 있다.




(a) 평일 부하예측 (봄)




(b) 평일 부하예측 (여름)

그림 3 평일 부하예측 결과 (봄, 여름)

Fig. 3 Load forecasting results for weekdays (spring, summer)



(a) 월요일 부하예측 (봄)



(b) 월요일 부하예측 (여름)

그림 4 월요일 부하예측 결과 (봄, 여름)

Fig. 4 Monday load forecasting results (spring, summer)

그림 5에 평가에 이용한 5개월 데이터의 각 유형별 평균 퍼센트 오차를 나타내었다. 평일 부하의 평균 퍼센트 오차는 1.06[%]~1.66[%], 월요일 부하의 평균 퍼센트 오차는 약 0.80~2.13[%], 토요일 부하의 평균 퍼센트 오차는 약 0.88~1.97[%], 일요일 부하의 평균 퍼센트 오차는 약 1.41~2.30[%]으로 비교적 양호한 결과를 나타내었으며 7, 8월인 경우가 어떤 유형에서도 오차가 가장 크게 나타났다. 따라서 여름철 부하예측에서는 온도 데이터를 신경회로망의 입력으로 추가한 표 3 및 표 4의 구조로 학습데이터를 구성하여 재 학습하였다.



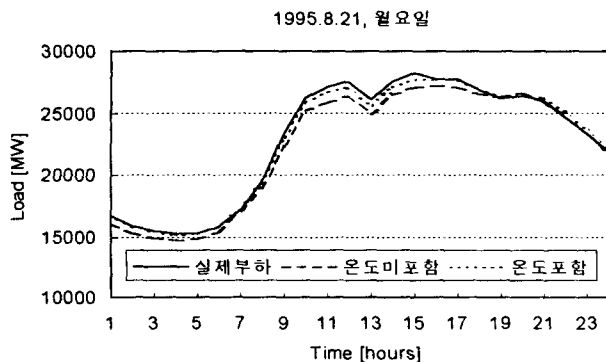


그림 5 계절별, 유형별 평균오차 비교
Fig. 5 Comparison of average error for seasons, patterns



(a) 여름 부하예측 (평일)



(b) 여름 부하예측 (월요일)

그림 6 여름 부하예측 결과 (평일, 월요일)
Fig. 6 Summer load forecasting results (weekdays, Monday)

그림 6은 온도데이터를 추가한 경우의 1995년 여름의 평일, 월요일에 대한 부하예측 결과를 나타내었다. 그림 6에서 실선은 실제부하, 굵은 점선은 온도데이터를 포함하지 않은 경우, 가는 점선은 온도데이터를 입력으로 추가한 경우의 부하예측 결과를 나타낸다. 그림 6에서 보는 것처럼 신경회로망의 입력으로 부하와 최대온도, 최소온도를 사용한 경우가 부하데이터만 입력으로 사용한 경우보다 실제부하에 더 가까움을 알 수 있다. 더 자세한 비교를 위하여 표 6에 1994년 7, 8월의 부하데이터만을 입력으로 사용하여 1995년 7, 8월의 유형별 부하를 예측한 신경회로망의 유형별, 시간별 평균오차를 나타내었고, 표 7에 같은 방법으로 부하데이터와 온도데이터를 신경회로망의 입력으로 사용한 경우의 유형별, 시간별 평균오차를 나타내었다. 표 6, 7에서 보는 것처럼 여름철 부하예측시, 온도데이터를 부하예측 신경회로망의 입력으로 사용한 경우가 온도를 사용하지 않은 경우보다 더 정확한 결과를 나타내었다. 그림 7에 온도영향에 대한 여름 부하예측의 결과를 각 유형별로 비교하였다. 부하예측의 입력으로 온도를 사용한 경우가 사용하지 않은 경우보다 모든 유형에서 더 정확하게 예측하였다.

표 6 여름부하에 대한 예측결과(온도 미포함시)
Table 6 Summer load forecasting results (temperature not included)

계절 시간	평균 퍼센트 오차[%]				
	평일	월요일	토요일	일요일	평균
1	1.16	2.06	1.33	1.08	1.41
2	0.96	2.14	1.29	1.29	1.42
3	1.02	2.45	1.55	1.34	1.59
4	1.06	1.70	1.34	1.09	1.30
5	1.22	1.84	1.42	1.20	1.42
6	1.17	1.80	1.69	1.46	1.53
7	1.19	1.36	1.17	1.72	1.36
8	1.05	1.33	1.94	1.27	1.40
9	1.07	2.18	2.37	2.64	2.07
10	1.78	2.43	2.56	2.94	2.43
11	2.07	2.93	2.61	3.07	2.67
12	2.41	2.90	2.37	3.00	2.67
13	2.35	3.02	2.52	3.02	2.73
14	2.17	2.76	2.40	2.99	2.58
15	2.32	2.98	2.44	3.09	2.71
16	2.25	2.67	2.90	3.29	2.78
17	2.15	2.75	2.79	3.07	2.69
18	2.00	2.28	2.32	2.61	2.30
19	1.71	2.22	1.99	2.92	2.21
20	2.07	2.46	1.36	2.94	2.21
21	1.68	1.55	1.42	2.47	1.78
22	1.64	1.18	1.82	2.46	1.78
23	1.59	0.96	1.66	2.26	1.62
24	1.66	1.25	2.01	1.91	1.71
평균	1.66	2.13	1.97	2.30	2.02

표 7 여름부하에 대한 예측결과(온도 포함시)

Table 7 Summer load forecasting results (temperature included)

계절 시간	평균 퍼센트 오차[%]				
	평일	월요일	토요일	일요일	평균
1	1.17	1.62	1.87	1.14	1.45
2	0.90	1.55	1.21	1.26	1.23
3	1.00	1.77	1.66	1.24	1.42
4	1.09	1.23	1.33	1.23	1.22
5	1.16	1.46	1.31	1.19	1.28
6	1.18	1.02	1.38	1.35	1.23
7	1.35	1.32	0.97	1.50	1.28
8	1.21	1.22	1.80	1.30	1.38
9	1.15	1.69	1.85	2.38	1.77
10	1.72	2.19	2.24	2.63	2.20
11	1.91	2.38	2.38	2.69	2.34
12	2.21	2.47	2.03	2.64	2.34
13	2.26	2.68	2.11	2.56	2.40
14	1.99	2.25	2.02	2.49	2.19
15	2.00	2.43	2.08	2.61	2.28
16	1.74	2.22	2.43	2.54	2.23
17	1.73	2.23	2.40	2.39	2.19
18	1.79	1.95	1.69	1.99	1.85
19	1.53	2.08	1.44	2.15	1.80
20	1.90	1.94	1.17	2.40	1.85
21	1.53	1.85	1.52	2.15	1.76
22	1.53	1.70	2.04	2.05	1.83
23	1.70	1.39	2.04	2.04	1.79
24	1.85	1.65	1.95	2.17	1.91
평균	1.57	1.85	1.79	2.00	1.80




그림 7 온도영향에 대한 여름 부하예측 결과 비교

Fig. 7 Comparison of summer load forecasting results for temperature effects

4. 결론

본 논문에서는 예측의 정확도를 높이기 위해서 코호넨 신경회로망을 사용하여 부하 데이터를 평일, 월요일, 토요일, 일

요일, 특수일로 분류하여, 각 유형별로 다음날의 시간별 전력 부하를 예측하는 방법을 제안하였다. 또한, 여름철 부하예측의 정확도를 높이기 위해 부하예측 신경회로망의 입력으로 부하데이터 뿐만 아니라 최대온도, 최소온도를 추가로 입력하였다.

제안한 방법의 효용성을 보이기 위해 1994~1995년의 2년간 한국전력의 실제부하 데이터를 이용하여 다음날의 유형별 전력부하를 예측하였다. 평일부하에서는 평균오차가 1.32[%]로 나타났고 월요일, 토요일, 일요일의 부하에서는 평균오차가 각각 1.41[%], 1.37[%], 1.76[%]로 비교적 우수한 성능을 나타내었다. 평일은 부하의 불규칙성이 작기 때문에 예측오차가 작은 반면, 일요일은 실제부하 데이터가 매우 불규칙적이어서 다른 요일에 비해 비교적 큰 예측오차를 나타내었다. 또한, 계절별 부하예측 결과를 고찰하면, 겨울철의 부하예측은 다른 계절에 비해 예측오차가 작은 반면, 온도, 습도 등의 날씨영향을 많이 받는 여름철의 부하예측은 평일뿐만 아니라 모든 유형에 대해서 다소 큰 예측오차를 나타내었다. 따라서 부하예측 신경회로망의 입력으로 온도를 고려하였고, 온도를 고려하지 않은 경우의 평균오차가 2.02[%]인데 반하여 온도 데이터를 이용한 경우는 1.80[%]로 나타나 온도를 부하예측 신경회로망의 입력으로 사용하여 부하예측의 정확도를 향상시킬 수 있었다.

향후 제안한 방법의 타당성 검토 및 부하예측의 정확도를 더욱더 개선시킬 수 있는 방법에 대한 연구가 필요하며, 온도 데이터뿐만 아니라 습도, 강우량 등 날씨 요소를 고려하여 전 계절에 걸친 정확도 개선, 특수일 부하의 예측방법, 사용자의 편리성 등에 대한 검토가 필요할 것으로 사료된다.

감사의 글

본 연구(관리번호: 96-중-05)는 한국전력공사의 지원에 의해 기초전력공학공동연구소 주관으로 수행되었음

참고 문헌

- [1] M. Hagan and S. Behr, "The Time Series Approach to Short-Term Load Forecasting," IEEE Trans. on Power System, Vol. PWRS-2, No. 3, pp. 785-791, Aug., 1987.
- [2] J. H. Park, Y. M. Park and K. Y. Lee, "Composite Modeling for Adaptive Short-Term Load Forecasting," IEEE Trans. on Power Systems, Vol. 6, No 2, pp. 450-456, May, 1991.
- [3] A. D. Papalexopoulos and T. C. Hesterberg, "A Regression-Based Approach to Short-Term System Load Forecasting," IEEE Trans. on PWRS, Vol. PWRS-5, No. 4, pp. 1535-1544, Nov., 1996.
- [4] R. Campo and P. Ruiz, "Adaptive Weather-Sensitive Short-Term Load Forecast," IEEE Trans. on PWRS, Vol. PWRS-2, No. 3, pp. 592-600, Aug., 1987.
- [5] S. Rahman, and R. Bhatnagar, "An Expert System Based Algorithm for Short-Term Load Forecast,"

IEEE Trans. on Power Systems, Vol. 3, No. 1, pp. 50-55, 1987.

- [6] T. M. Peng, N. F. Hubele and G. G. Karady, "An Adaptive Neural Network Approach to One-week Ahead Forecasting," IEEE Trans. on Power Systems, Vol. 8, pp. 1195-1203, 1993.
- [7] J. H. Park and K. Y. Lee, "Short-Term Load Forecasting Using an Artificial Neural Network," IEEE Trans. on Power System, Vol. 7, No. 1, pp. 124-132, Feb., 1992.
- [8] A. G. Bakirtzis, V. Petridis, S. J. Kiartzis, M. C. Alexiadis, and A. H. Maissis, "A Neural Network Short Term Load Forecasting Model for the Greek Power System," IEEE Trans. on Power Systems, Vol. 11, No. 2, pp. 858-863, May, 1996.
- [9] A. Khotanzad, M. H. Davis, A. Abaye, and D. J. Maratukulam, "An Artificial Neural Network Hourly Temperature Forecaster with Applications in Load Forecasting," IEEE Trans. on Power Systems, Vol. 11, No. 2, pp. 870-876, May, 1996.
- [10] T. Bauman, A. J. Germond, "Applications of the Kohonen Network to Short-Term Load Forecasting", ANNPS, pp. 407-412, 1993.
- [11] 조승우, 황갑주, 김성학, "코호넨 신경망을 이용한 단기 전력수요 예측", 대한전기학회논문지, Vol. 46, No. 3, Mar., 1997.

저 자 소 개



박 후 식(朴 厚 植)

1970년 8월 9일생. 1996년 동아대 공대 전기공학과 졸업. 1998년 부산대 일반대학원 전기공학과 졸업(석사). 현재 현대중공업 선박사업부 전장설계부 재직.



문 경 준(文 景 俊)

1972년 10월 25일생. 1994년 부산대 공대 전기공학과 졸업. 1996년 부산대 일반대학원 전기공학과 졸업(석사). 현재 동 대학원 박사과정 수료.



김 형 수(金 亨 洙)

1972년 1월 26일생. 1994년 부산대 공대 전기공학과 졸업. 1997년 부산대 일반대학원 전기공학과 졸업(석사). 현재 동 대학원 박사과정.



황 기 현(黃 琪 鉉)

1968년 3월 1일생. 1994년 경성대 공대 전기공학과 졸업. 1996년 부산대 일반대학원 전기공학과 졸업(석사). 현재 동 대학원 박사과정 수료.



이 화 석(李 和 錫)

1966년 7월 10일생. 1991년 부산대 공대 전기공학과 졸업. 1993년 동 대학원 전기공학과 졸업(석사). 1997년 동 대학원 전기공학과 졸업(공학). 현재 거제대학 전기과 전임강사.



박 준 호(朴 俊 灝)

1955년 9월 17일생. 1978년 서울대 공대 전기공학과 졸업. 1980년 동 대학원 전기공학과 졸업(석사). 1987년 동 대학원 전기공학과 졸업(공학). 1978년~1981년 한국전기연구소 연구원. 1981년~1984년 충남대 공대 전기공학과 전임강사 및 조교수. 1989년~1990년 Pen. State Univ. Visiting Scholar. 현재 부산대 공대 전기공학과 교수