

코호넨 신경회로망과 웨이브릿 변환을 이용한 단기부하예측

김창일* 김봉태** 김우현** 유인근**
 * 남해전문대학 ** 창원대학교

Short-term load forecasting using Kohonen neural network and wavelet transform

Chang-il Kim* Bong-Tae Kim** Woo-Hyun Kim** In-Keun Yu**
 * Namhae Provincial College ** Changwon National University

Abstract - This paper proposes a novel wavelet transform and Kohonen neural network based technique for short-time load forecasting of power systems. Firstly, Kohonen Self-organizing map(KSOM) is applied to classify the loads and then the Daubechies D2, D4 and D10 wavelet transforms are adopted in order to forecast the short-term loads. The wavelet coefficients associated with certain frequency and time localisation are adjusted using the conventional multiple regression method and then reconstructed in order to forecast the final loads through a four-scale synthesis technique. The outcome of the study clearly indicates that the proposed composite model of Kohonen neural network and wavelet transform approach can be used as an attractive and effective means for short-term load forecasting.

1. 서 론

전력부하는 예측일의 온도, 습도 및 청명도 등의 기상 요인과 계절, 요일 및 경기변동 등 다양한 경제, 사회적 요인에 의해 끊임없이 변화된다. 따라서 전력부하를 예측하기 위한 산법도 다양한 방안들이 제안되어 왔으며, 일부는 성공적으로 활용되고 있다. 단기부하예측의 주요 산법 중 현재의 부하와 기상변수 및 과거 부하사이의 관계를 비교적 잘 설명해주는 시계열 분석에 입각한 알고리즘 (AR, MA, ARMA, 지수평활법)은 많은 양의 관련 데이터를 필요로 하며, 특히 기상감응 부하모형의 성공적인 실행은 기상예측 모형의 정확도에 의존하고 기상변수를 상수로 취급할 경우 준칙적해를 기대할 수밖에 없다. 근년에는 인공지능(AI), 신경회로망(ANN), 신경회로망과 페지를 결합한 하이브리드형 등이 부하예측 산법의 주를 이루고 있으며 좋은 결과를 보여주고 있다[1-3].

본 논문에서는 코호넨 신경회로망과 웨이브릿 변환을 이용한 새로운 단기부하예측 기법을 제안하였다. 먼저 코호넨 신경회로망을 이용하여 각 계절별 과거 부하데이터를 평일, 토요일, 일요일, 월요일의 4가지 유형으로 분류한 후 분류된 부하 데이터와 온도 데이터를 이용하여 웨이브릿 변환을 통하여 다음날의 시간별 부하를 예측하였다.

웨이브릿 분석을 위한 원형함수로 Daubechies D2, D10를 사용하여 부하를 level 4까지 분해하였으며, 회귀 모델을 이용하여 온도에 민감한 고주파 성분과 온도와의 상관관계를 통해 회귀계수를 도출하였다. 예측일의 온도를 회귀계수에 적용하여 고주파 성분을 예측하였고, 전날의 저주파 성분과 예측된 고주파 성분을 합성하여 익일의 시간별 부하를 예측하였다. 웨이브릿 변환을 통한 예측치와 코호넨 신경회로망과 웨이브릿 변환을 결합한 경우의 예측 결과를 비교하였으며, 1995년의 8월의 실부하 데이터를 이용하여 제안된 기법의 효용성을 입증하였다.

2. 코호넨 신경회로망

코호넨 신경회로망은 대표적인 지도학습 알고리즘인 오파 역전파 학습과는 달리 목적값이 주어지지 않아도 자기 구성 맵(Self-organizing map)에 의해 스스로 학습하는 자율학습 알고리즘으로서 입력층과 출력층(경쟁층)으로 구성되어 있다. 이때 입력벡터는 크기가 일정하도록 정규화 하여야 하며, 연결강도는 적절하게 초기화 되어야 한다. 신경망의 학습은 주어진 입력에 대하여 가장 큰 값을 출력하는 노드를 중심으로 이루어지며, 경쟁학습에서 승리한 노드를 중심으로 가장 가까운 거리의 일부 노드만이 학습되어 진다[4].

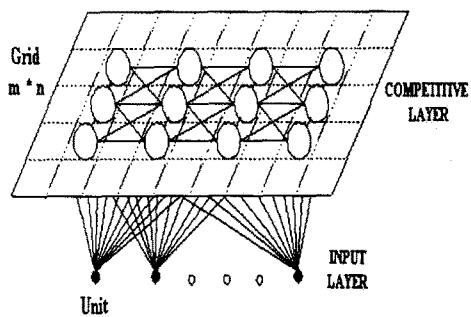


Fig.1 Kohonen feature map

연결강도 벡터와 입력벡터의 근접성은 식 (1)과 같이 유클리디안 거리를 이용하여 가장 최소값을 가지는 출력노드를 선택함으로써 결정된다.

$$D_i = \sum_{i=0}^{N-1} (X_i(t) - W_{ij}(t))^2 \quad (1)$$

승리노드 선택 후 이 노드의 학습은 식 (2)와 같이 원래의 연결강도 벡터에 연결강도와 입력벡터의 차를 수정함으로써 이루어진다.

$$W(t+1) = W(t) + \alpha(t)[X(t) - W(t)] \quad (2)$$

여기서 $\alpha(t)$ 는 학습률, $W(t)$ 는 연결강도 그리고 $X(t)$ 는 입력값을 의미한다.

3. 웨이브릿 변환

Daubechies와 Mallet 등에 의해 소개된 웨이브릿 변환은 퓨리에 변환과 같이 기저함수들의 집합으로 신호를 분해하는 하나의 방법이다. 웨이브릿 변환의 특징은 퓨리에 변환과는 달리 국부적으로 에너지가 집중되어 있는 대역통과 신호인 웨이브릿들을 기저함수로 사용한다는 점이

다. 이러한 웨이브릿들은 모 웨이브릿이라 불리는 하나의 원형 웨이브릿의 확장(Scaling)과 이동(Translation)을 통해서 얻어진다. 스케일은 신호의 주파수가 몇 배로 확장되었는가를 나타내는 확장인자이며, 이산 웨이브릿 변환에서는 구현의 용이함을 위하여 멱승(2^j)의 형태를 주로 취한다. 특성상 스케일이 증가할수록 웨이브릿 변환 신호의 공간 해상도는 떨어지고 저주파 대역의 성분을 나타내게 된다.

본 연구에서는 dyadic wavelet 변환을 통해 얻어진 웨이브릿 계수를 활용하여 단기부하예측 모형을 도출하였다. Dyadic 웨이브릿 변환은 다해상도 그림 2와 같은 피라미드형 분해기법에 의해 실행되며, 기록된 부하실적 자료를 다만 분해과정을 통하여 웨이브릿 계수로 분해하고 이를 다시 합성하여 에너지의 손실없이 본래의 신호로 복원한다.

그림 3은 신호(부하곡선)를 1단계 스케일의 저주파 성분과 고주파 성분으로 분해한 것이며, 그림 4는 분해된 신호를 합성하여 원 신호로 복원하는 과정을 보여주고 있다. 본 연구에서는 웨이브릿 변환을 이용하여 부하실적 자료를 분해 및 합성하는 과정에서 적절한 기법을 고안하여 새로운 부하 예측모형을 도출하였다.

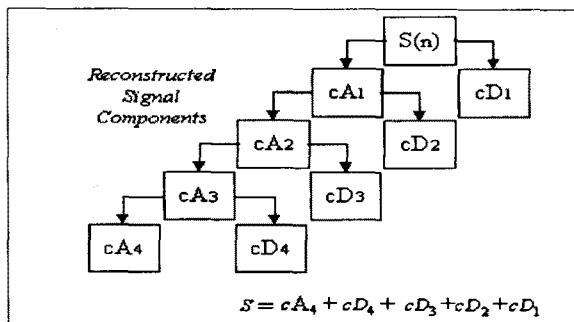


Fig.2 Reconstruction of the five scaled approximations and details

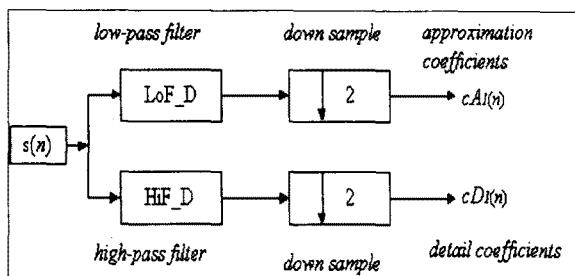


Fig.3 The first-scale signal decomposition of $S(n)$ in $cA_1(n)$ and $cD_1(n)$

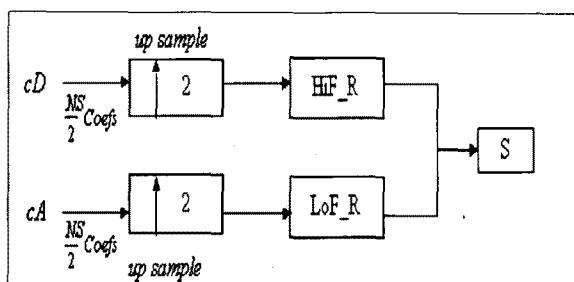


Fig.4 Reconstruction of the approximations and the details

4. 사례연구

본 연구에서 제안된 부하예측 기법의 효용성을 입증하기 위하여 1995년 8월과 12월의 과거 실적부하와 주요지역 별(서울, 부산, 대전, 대구, 광주) 가중치를 고려한 기온 데이터를 입력 데이터로 사용하였다.

그림 5는 코호넨 신경망과 웨이브릿을 이용한 부하예측 알고리즘의 순서도를 나타낸 것이다. 코호넨 신경망에 의해 부하 데이터를 평일, 토요일, 일요일 그리고 월요일의 4가지 유형으로 분류하고, 각 유형별로 분류된 부하를 입력으로 웨이브릿 변환을 통해 Daubechies D2, D10을 이용하여 level 4까지 고주파와 저주파로 분해하였다. 분해된 부하의 고주파 성분과 기온 데이터와의 관계에서 회귀계수를 구하고 익일의 각 시간대별 예상 온도를 회귀모델에 적용하여 익일의 고주파를 예측한 후 전날의 저주파 성분과 합성함으로써 익일의 부하를 최종적으로 예측하였다.

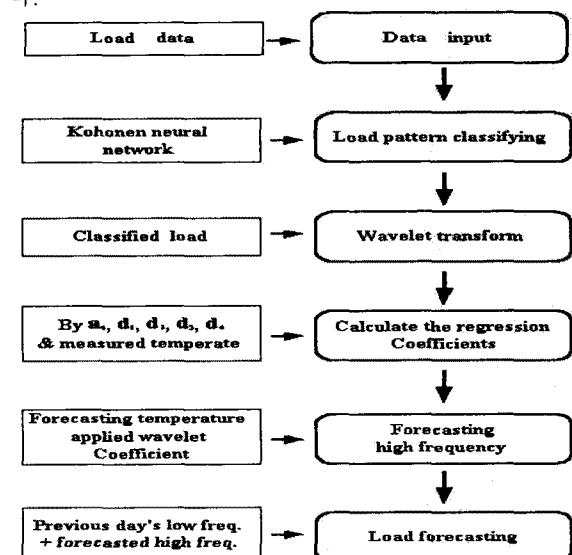


Fig.5 Flow of the proposed load forecasting method

Table 1 The results of load forecasting

Method	level	월요일	평요일	토요일	일요일	평균
W · T (DB10)	lev 1	3.54	2.12	4.84	4.01	3.63
	lev 2	3.50	2.00	4.60	3.78	3.47
	lev 3	3.05	1.68	3.66	3.37	2.94
	lev 4	1.74	1.48	2.48	2.08	1.95
W · T + KSOM (DB10)	lev 1	3.54	2.14	3.61	4.01	3.32
	lev 2	3.50	2.00	3.21	3.78	3.12
	lev 3	3.05	1.67	2.11	3.37	2.55
	lev 4	1.74	1.10	0.97	2.08	1.47

표 1은 연간(1995년)을 통하여 부하의 변동이 가장 심하게 나타나는 8월에 대해 Daubechies 10을 이용하여 level 1부터 level 4까지 부하곡선을 분해하여 각 패턴별로 부하를 예측한 결과를 보여주고 있다. 결과에서 알 수 있듯이 달력에 의존하여 입력부하를 결정하는 것 보다 코호넨 신경회로망을 이용하여 부하 유형을 분류한 후 부하가 유사한 그룹을 입력하여 부하를 예측한 결과가 우수함

이 입증되었다. 같은 level 4에서 하이브리드형을 이용한 경우의 오차가 약 0.48% 정도 감소하였다. 일요일과 월요일은 같은 그룹으로 분류되어 오차율이 같고 토요일은 한 주가 다르게 분류되었다. 같은 평일이라도 휴가철과 특수일의 영향으로 부하가 다르게 나타났으며, 코호넨 신경망으로 분류한 결과 0.38%정도의 오차가 감소하였다.

Table 2 The results of one-day load forecasting (Aug. 24, 1995)

시간	실측치[MW]	예측치[MW]	오차[MW]	오차율[%]
3	18559	18371.77	187.23	1.02
6	18748	18206.88	541.12	2.97
9	24536	24222.69	313.31	1.29
12	27676	27792.91	-116.91	0.42
15	28047	28248.56	-201.56	0.71
18	27598	27550.87	47.13	0.17
21	26502	26327.17	174.83	0.66
24	22271	22224.28	46.72	0.21
평균	24242.13	24118.14	123.98	0.93

표 2는 1995년 8월 24일의 각 시간대별 부하예측 결과를 보여주고 있다. 3시간 간격의 부하 데이터를 이용하여 3시간별 부하를 예측하였으며, Daubechies10-Lev4를 적용한 결과 평균 오차율은 0.93[%]로 나타났다. 상대적으로 기온의 영향이 적은 새벽 시간대에서 오차율이 크게 나타났다. 최고 오차는 오전 6시대의 541.12[MW]이며 최저오차는 자정 무렵에서 46.72[MW]로 나타났다.

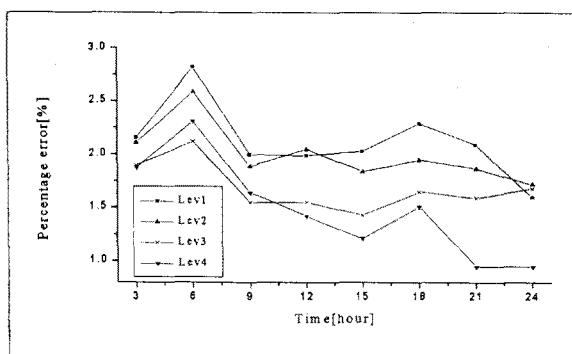


Fig.6 The mean percentage error by wavelet tran of weekdays(Aug. 1995)

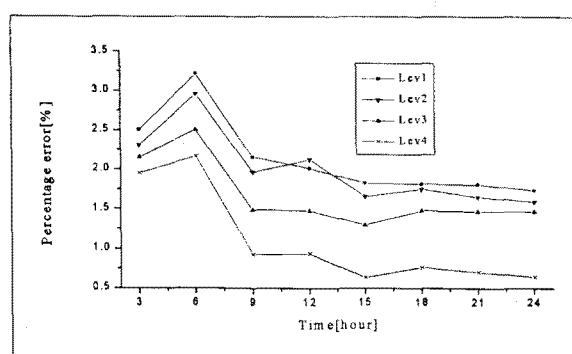


Fig.7 The mean percentage error by KSOM & wavelet transform of weekdays(Aug. 1995)

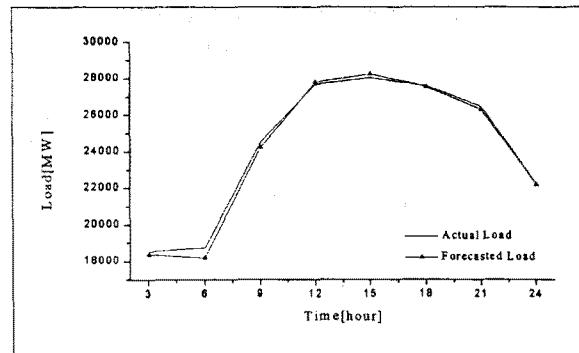


Fig.8 Comparision of the actual and the forecasted load for one-day(Aug. 24, 1995)

그림 6은 웨이브릿 변환을 이용한 1995년 8월 평일의 평균 예측오차를 도시한 것이다. 레벨수가 늘어날수록 예측오차가 감소함을 알 수 있으며, 6시간대에서 오차가 가장 높게 나타났다. 그림 7은 코호넨 신경회로망과 웨이브릿 변환을 하이브리드형으로 적용한 경우 8월 평일의 예측오차를 보여주고 있다. 특히 Lev 4에서 오차가 현저히 감소함을 알 수 있다. 그림 8은 8월 24일 하루의 부하예측 결과를 나타낸 것이다. 예측곡선이 실측곡선을 거의 추종하고 있음을 보여주고 있다.

5. 결 론

본 연구에서는 코호넨 신경회로망과 웨이브릿 변환을 이용한 단기부하 예측기법을 제안하였다. 코호넨 신경회로망을 이용하여 부하를 4가지 유형으로 분류하고, 분류된 유형을 입력데이터로 웨이브릿 변환을 이용하여 여름철(8월)과 겨울철(12월)의 일간부하를 예측하였다. 1995년 실적 데이터를 이용하여 level 4까지 웨이브릿 변환하여 1년 중 부하의 변동이 가장 심한 8월에 대하여 예측한 결과 DB10 - level 1에서 3.32[%], DB10 - level 2에서 3.12[%], DB10 - level 3에서 2.55[%] 그리고 DB10 - level 4에서 1.47[%]의 비교적 우수한 예측 결과를 도출하였다. 따라서 오차율의 비교에서 알 수 있듯이 웨이브릿 변환만을 이용하여 부하를 예측한 경우보다 코호넨 신경회로망과 웨이브릿 변환을 혼합한 기법이 부하예측에 더욱 유용함을 입증하였다.

본 연구는 '99년 에너지절약 학술진흥사업과 한국과학재단 지정 청원대학교 공작기계기술 연구센터의 일부 지원에 의한 것임

【참 고 문 헌】

- [1] 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. 450-457, 1991
- [2] D. C. Park, M.A. El-Sharkawi, R. J. Marks II, L. E. Atlas and M. J. Damborg, "Electric load forecasting using an artificial neural network", IEEE Trans. on Power Delivery, Vol. 6, No. 2, pp. 442-449, 1991
- [3] K. Y. Lee, Y. T Cha and J. H. Park "Short-term load forecasting using an artificial neural network", IEEE Trans. on Power Delivery, Vol. 7, No. 1, pp. 124-131, 1992
- [4] 황갑주 외, "코호넨 신경망을 이용한 단기 전력수요 예측", 대한전기학회 논문지, 제46권 3호, pp 312-316, 1997. 3