

신경회로망을 이용한 전력부하의 유형분류 및 예측에 관한연구

박준호 신길재* 이화석

부산대학교 공과대학 전기공학과

A study on the Electrical Load Pattern Classification and Forecasting using Neural Network

June-Ho Park Gil-Jae Shin* Hwa-Suk Lee
Department of Electrical Engineering Pusan National University

ABSTRACT

The Application of Artificial Neural Network(ANN) to forecast a load in a power system is investigated. The load forecasting is important in the electric utility industry. This technique, methodology based on the fact that parallel structure can process very fast much information is a promising approach to a load forecasting. ANN that is highly interconnected processing element in a hierarchy activated by the each input.

The load pattern can be divided distinctively into two patterns, that is, weekday and weekend. ANN is composed of a input layer, several hidden layers, and a output layer and the past data is used to activate input layer. The output of ANN is the load forecast for a given day. The result of this simulation can be used as a reference to a electric utility operation.

1. 서론

전력회사가 수용가에게 안전하고 값싸게 양질의 전기를 공급하기 위해서 발번전 및 송배전계통을 운용, 계획, 제어하는 데는 많은 공학적, 경제적 문제가 수반된다. 이런 방대한 설비의 최적계획 및 경제적인 운용을 위하여 현대 시스템이론과 최적화 기법의 적용으로 얻어지는 경제적 이득 또한 상당한 것이다. 이런 목표를 달성하기 위해서는 가장 먼저 미래의 전력수요에 대한 자료가 필요하며, 따라서 장기 및 단기간의 전력부하예측은 매우 중요한 과제 중의 하나이다.

부하예측에는 기간에 따라, 년간 또는 월별로 예측하는 중장기의 전력부하예측[1]과 일별 또는 시간별로 예측하는 단기 전력부하예측[2-7]으로 나눌 수 있다. 중장기 전력부하예측은 발번전 및 송배전 계통의 확장 및 운용계획 등에 사용되고 단기 전력부하예측은 전력계통의 제어 및 단기계획, 전력조류, 상정사고해석 등의 입력자료로 사용된다.

전력부하의 예측기법은 전력부하를 단지 시간순서로 나열하여 그 변동특성을 분석, 수식화하는 방법[2-4]과 전력부하와 밀접한 관련요인[5]이 있는 변수와의 상관관계를 분석하여 모형화하는 방법[5-7] 등의 확률적이고 해석적인 방법 등으로 발전되어 왔다.

시계열에 의한 전자의 방법은 갈만 필터링(Kalman filtering)[3], ARMA(Auto Regressive Moving Average)[4] 등의 방법으로 발전되었고, 상관관계에 의한 모형은 날씨 등의 변수를 반영한 것으로서, 부하를 날씨 민감부하(weather sensitive load)의 예측과 비날씨민감부하(non-weather sensitive load)의 예측치를 구하여 그 두 결과를 합하여 전체부하를 예측하였다.[5-7]. 하지만, 이러

한 모델링 방법은 전력부하가 시변시스템의 특성을 지니기 때문에 모델의 파라메타가 부하의 변동에 따라 적응 수정되어야 하는 방법들이 필요하였고 불규칙한 부하데이터를 제거하거나 필터링해야 예측정확도를 높일 수 있었다. 또 날씨와 부하의 상관관계를 모델링할 때도 비선형 특성으로 인해 이를 반영하기가 매우 힘들었다. 따라서 최근 이러한 단점을 보완하기 위해 전력부하예측에 신경회로망을 이용해 보고자 하는 연구[12-14]가 시도되고 있다.

본연구에서는 평일, 휴일등 일간 전력부하의 여러 다른 유형의 데이터를 효과적으로 관리하기위해 신경회로망을 이용하여 과거부하의 형태를 자동적으로 분류하였고, 신경회로망에 의해 분류된 형태별 부하의 데이터를 이용하여 단기 전력부하를 예측하는 신경회로망을 구현하여 보았다. 실제 통의 부하데이터를 사용하여 사례연구를 하여 그 응용가능성을 보여주었다.

2. 신경회로망

신경회로망은 주어진 입력들에 대하여 가중치를 조정하여 원하는 출력을 생성하는 학습기능이 있으며, 일단 학습된 회로망은 불완전하거나 잡음이 포함된 입력에 대해서도 적절한 해를 얻을 수 있다. 입출력관계가 복잡하고 비선형 관계인 경우 신경회로망으로 이를 구할 수 있어 정확한 입출력함수관계가 쉽게 정의될 수 없는 문제에 효과적으로 응용되고 있다.

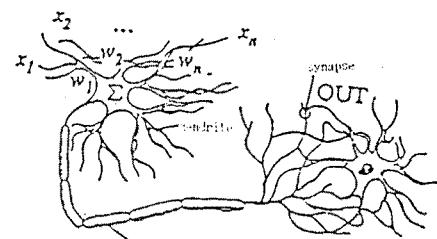


그림1. 생물학적 뉴런

그림 1과 그림 2는 각각 생물학적 뉴런과 인공뉴런의 수학적 모델을 보여주며, 인공뉴런은 생물학적 뉴런의 일차 특성을 나타내도록 모델링되어 있다. 다른뉴런의 출력을 나타내는 여러 입력이 인가되고, 각 입력은 시냅스(Synapses)의 연결강도(Connection Strength)와 유사한 가중치(Weight)가 곱해지고 이들을 전부 합하여 NET라 부르는 출력을 만든다. NET 신호는 활성함수(Activation Function)에 의해 처리되어 뉴런의 출력신호가 만들어 진다.

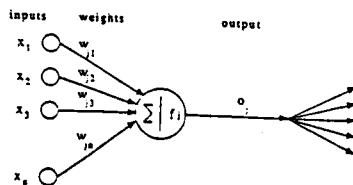


그림 2. 뉴런의 수학적 모델

하나의 인공뉴런은 단순한 기능을 갖지만, 뉴런들을 연결하여 회로망을 구현하면 계산능력을 가지게 된다. 일반적으로 크고 복잡한 회로망일수록 계산능력은 더 커진다. 그림 3은 전형적인 다층(Multilayer)의 인공신경회로망을 보여준다. 원으로 표시된 부분이 하나의 인공뉴런이고, 한 뉴런의 출력이 다음 단의 뉴런의 입력이 된다. 이런 인공뉴런들은 가중치를 가진 연결부에 의해 상호연결되어 있다.

다층의 신경회로망에 대해 Rumelhart가 개발한 역전파 학습법(Back Propagation Learning)에 의한 가중치와 임계치는 다음과 같은 학습과정에 의해 조정된다[8].

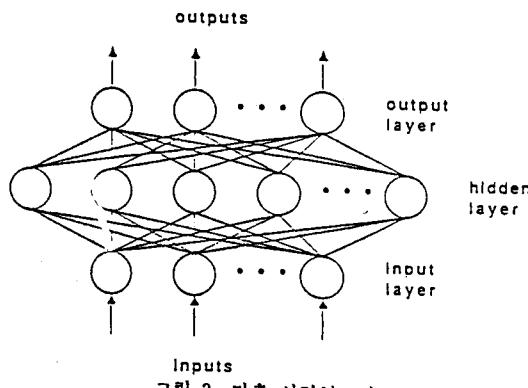


그림 3. 다층 신경회로망

각 패턴에 대한 자승오차 E_p 는

$$E_p = 1/2 \sum_j (t_{pj} - o_{pj})^2 \quad (1)$$

이고 전체의 오차는 $E = \sum E_p$ 이다. 여기서 t_{pj} 는 패턴P에 대한 j번째 출력성분의 목표치 출력이고 o_{pj} 는 패턴P에 대한 실제 출력의 j번째 성분이다.

j번째 뉴런에 대한 출력은 다음과 같이 표시되고

$$o_{pj} = f_j(\text{net}_{pj}) \quad (2)$$

$$\text{net}_{pj} = \sum_k w_{jk} o_{pk} \quad (3)$$

여기서 f_j 는 미분가능이고 단조증가성질을 가지는 활성함수이다. w_{jk} 는 학습률 가중치이고 이를 학습하는 법칙을 얻기위해 임의의 w_{ji} 에 의한 E_p 의 미분은 다음과 같고

$$-\partial E_p / \partial w_{ji} = \delta_{pj} o_{pi} \quad (4)$$

여기서 δ_{pj} 는 출력층에서는 다음과 같고

$$\delta_{pj} = (t_{pj} - o_{pj}) f'_j(\text{net}_{pj}) \quad (5)$$

중간층에서는 다음과 같이 주어진다.

$$\delta_{pj} = f'_j(\text{net}_{pj}) \sum_k \delta_{pk} w_{kj} \quad (6)$$

여기서 f'_j 는 f_j 의 미분을 나타낸다. 따라서 w_{ji} 의 학습은 다음과 같이 유도된다.

$$w_{ji}(n+1) = w_{ji}(n) + \sum_p \Delta p w_{ji} \quad (7)$$

$$\Delta p w_{ji} = \eta \delta_{pj} o_{pi}$$

여기서 η 는 학습율로서 보통 0 ~ 1이고 시뮬레이션에 의해 결정된다.

3. 신경회로망에 의한 부하유형분류

우리나라의 전력부하특성은 그림 4와 같이 나타난다. 그림 4에서 보는 바와같이 화, 수, 목, 금요일의 평일의 부하곡선이 서로 같은 형태이고 토, 일, 월요일의 부하형태가 다르게 나타난다. 1, 3주의 일요일과 2, 4, 5주의 일요일이 각각 다르고 이에 따라 1, 3주의 월요일 오전부하와 2, 4, 5주의 월요일의 오후부하로 각각 다른 형태로 나타난다. 특히 특수일(설날, 노동절, 추석등)의 부하는 공휴일의 요일 및 종류에 따라 많은 차이를 나타내고 있다. 본 논문에서는 이러한 부하유형을 달력에 의존하지 않고 ANN을 이용하여 자동으로 분류하고자 한다. 본 절에서 1개의 입력 데이터 집합을 8개의 유형으로 분류하기 위해 다음과 같은 인공신경회로망을 사용하였다.

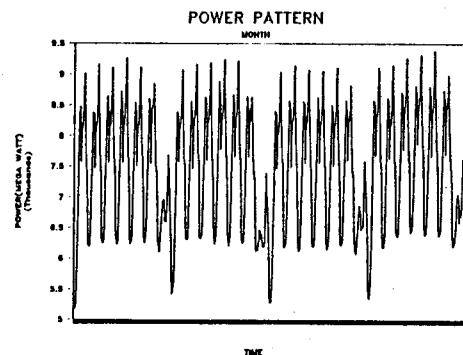


그림 4. 전력 부하 유형

$$X = [x_1, x_2, \dots, x_l]$$

$$Y = [y_1, y_2, \dots, y_m]$$

여기서 X는 입력벡터, Y는 출력벡터이다.

입력데이터의 갯수를 l, 중간층 뉴런의 갯수를 h, 출력층의 뉴런의 갯수를 m이라 하고, 은닉층의 가중치행렬을 $W(h \times l)$, 출력층의 가중치행렬을 $V(m \times h)$ 라 하면 중간층과 출력층의 출력은 각각 식(8), (9)와 같이 구해진다.

$$H = f_a[WX] \quad (8)$$

$$Y = f_b[VH] \quad (9)$$

이때 H는 은닉층의 출력벡터, Y는 출력층의 출력벡터이고 f_a , f_b (여기서는 시그모이드 함수)는 활성함수이다.

여기서 중간층과 출력층의 가중치 행렬을 구하는 것이 중요한 문제인데, 이는 앞의 2장에서 설명한 역전파 학습 알고리즘을 이용하여 구할 수 있다.

4 전력부하예측

현재부하는 과거의 부하데이터와 예측되는 부하가 속해져 있는 요일에 영향을 받는다. 예를 들면 월요일 부하는 과거의 월요일 부하의 패턴과 일요일, 토요일 부하데이터의 영향을 받는다. 따라서 부하유형을 구분하여 부하를 예측한다. 전력부하예측을 위해 다음과 같은 비선형 부하모델을 제시한다.

$$y(i,t) = F(W(i,t), y(i,t-1), y(i,t-2), \dots, y(i,t-m), \\ y(i-1,t), y(i-1,t-1), \dots, y(i-1,t-m)), \\ \vdots \\ (10)$$

$$y(i-n,t), y(i-n,t-1), \dots, y(i-n,t-m))$$

여기서,

$y(i, t)$: 1일의 t 시각의 실제부하,

1 : 예측하고자 하는 날

t : 시간 ($t = 1, 2, 3, \dots, 24$)

$n \times m$: 데이터 수

$W(i, t)$: 가중치 벡터

$F(\cdot, \cdot)$: 인공신경회로망이 나타내는 비선형 벡터함수

부하패턴은 평일패턴과 주말패턴으로 구분되었고, 가중치 벡터 $W(i, t)$ 는 각 패턴에 대해 과거의 부하데이터를 사용하여 각 시각에서 추정한다. 1일의 t 시각에서 가중치 벡터가 추정된 후 과거 데이터를 이용하여 다음과 같이 부하를 예측한다.

$$\hat{y}(i,t) = F(\hat{W}(i,t), y(i,t-1), y(i,t-2), \dots, y(i,t-m), \\ y(i-1,t), y(i-1,t-1), \dots, y(i-1,t-m)), \\ \vdots \\ (11)$$

$$y(i-n,t), y(i-n,t-1), \dots, y(i-n,t-m))$$

여기서 $\hat{y}(i,t)$ 는 1일, t 시각의 예측부하이다.

5 시뮬레이션

1. 유형분류

유형분류를 위해 입력층은 24개의 뉴런을, 은닉층은 18~26개의 뉴런을, 출력층은 3~6개의 뉴런을 가진 신경회로망을 구성하였다. 입력데이터는 87년도 11월 전력부하데이터를 사용하여 각 유형마다 2개의 입력데이터열을 선택하고 목표출력은 평일(유형 1), 토요일(유형 2), 1,3주의 일요일(유형 3), 2,4,5주 일요일(유형 4), 1,3주 월요일(유형 5), 2,4,5주 월요일(유형 6)으로 분류하고 그 각각의 유형들은 표1과 같이 목표출력데이터로하여 학습층을 구성하였다.

표 1. 목표 출력의 예

유형	목표 출력	유형	목표 출력
1	0 0 0 0 0 1	1	0 0 1
2	0 0 0 0 1 0	2	0 1 0
3	0 0 0 1 0 0	3	0 1 1
4	0 0 1 0 0 0	4	1 0 0
5	0 1 0 0 0 0	5	1 0 1
6	1 0 0 0 0 0	6	1 1 0

평가(Estimation)는 87년도 1월에서 4월까지 실행하였고 그 결과는 표2가 보여주는 바와같이 나타났다. 4월의 경우에 있어 유형 1을 유형 2로 구분(14개중의 12)하였는데 87년의 시국불안에 기인한 파업 등의 이유로 오후전력부하가 평일보다 떨어짐을 알 수 있었다.

표 2. 부하유형 인식률

유형	인식률				
	1월	2월	3월	4월	합계
1	12/13	13/16	11/15	3/17	39/61
2	1/3	4/4	4/4	4/4	13/13
3	0/1	1/1	2/2	0/2	3/6
4	1/1	2/2	2/2	2/2	7/7
5	1/1	1/1	1/2	1/2	4/6
6	1/1	2/2	2/3	2/2	7/8
	16/20	23/26	22/28	12/29	74/101

2. 부하예측

부하예측을 위해서는 입력층은 8개, 은닉층은 8개, 출력층은 1개의 뉴런을 가지는 신경회로망을 구성하였다.

1일 t시각의 부하, $y(i,t)$ 를 목표출력을 $y(i,t-1), y(i,t-2), y(i-1,t), y(i-1,t-1), y(i-1,t-2), \dots, y(i-2,t-2)$ 의 입력으로 구성된 학습층을 구성하고 그 학습층으로 24시간 각각에 대하여 신경회로망을 학습하였다. 학습된 신경회로망에 대하여 한 시간앞의 부하를 예측하고 실제 부하값과 비교하여 퍼센트오차(percent error)를 구하였다.

표 3. 전력부하의 실제치와 예측치의 퍼센트오차

시간	퍼센트오차(% error)				
	1월	2월	3월	4월	합계
1	1.8076	1.0631	1.0714	1.0706	1.2381
2	0.4486	1.1768	0.9562	1.4993	1.0197
3	1.1540	0.8897	1.5218	0.8202	1.0959
4	1.0558	0.6959	1.1992	1.3838	1.0596
5	0.8245	0.6934	0.8421	1.2558	0.9039
6	1.6413	1.3408	2.8421	1.8662	1.9226
7	4.8092	0.8701	3.8141	0.5690	2.5158
8	0.9558	1.5564	1.5543	1.6142	1.4201
9	1.7280	2.2263	0.8105	0.6873	1.3631
10	3.3564	1.8008	1.0342	0.4141	1.6513
11	1.9645	2.3531	0.8324	0.6314	1.4453
12	2.1845	0.4865	0.8273	1.5377	1.2590
13	4.8186	2.3277	3.3865	0.8787	2.8528
14	2.7186	1.0124	1.4507	0.9646	1.5366
15	1.6551	1.0125	1.6144	0.6377	1.2299
16	2.0648	0.6729	1.7828	0.5260	1.2616
17	1.2230	1.1901	1.0031	0.8034	1.0549
18	1.4680	2.2576	1.4102	0.8509	1.4966
19	1.3134	1.3973	1.3134	1.4259	1.3625
20	2.0549	1.2723	2.0549	1.1514	1.6333
21	2.4550	1.9010	2.4551	1.3283	1.8863
22	1.8609	0.9209	1.8609	1.1140	1.4391
23	1.3143	2.0420	1.1186	0.9409	1.3539
24	1.4661	1.0840	1.4828	1.5646	1.3993
합계	1.9312	1.3410	1.7142	1.0640	1.5126

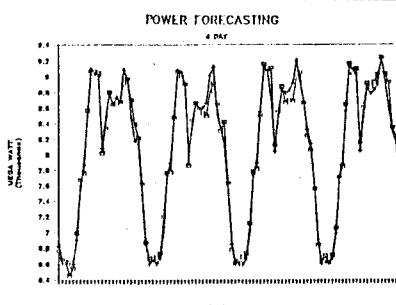


그림 5. 전력 부하의 예측치와 실제치

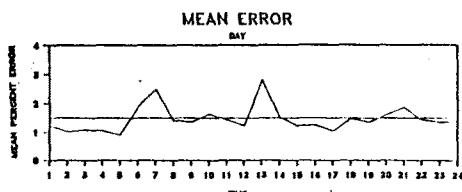


그림 6. 평균 퍼센트 오차 (1월~4월)

그림 5은 4월 7일에서 4월 10일사이의 실제 부하와 예측부하를 나타내고 그림 6은 1월에서 4월까지의 각 시각에 대한 평균 퍼센트오차를 나타낸다. 이상과 같이 신경회로망을 적용해본 결과 87년 1월에서 4월까지의 평균 퍼센트오차가 1.5%로 나타났다.

6. 결 론

본연구에서는 평일, 휴일등 일간 전력부하의 여러 다른 유형의 데이터를 효과적으로 관리하기위해 신경회로망을 이용하여 과거부하의 형태를 자동적으로 분류하였고, 신경회로망에 의해 분류된 형태별 부하의 데이터를 이용하여 단기 전력부하를 예측하는 신경회로망을 구현하여 보았다. 실제 풍의 부하데이터를 사용하여 사례연구를 하여 그 응용가능성을 보여주었다.

7. 참고문헌

- [1] C. E. Asbury, "Weather load model for electric demand and energy forecasting," IEEE Trans. on Power Appr. and Sys., vol.Pas-94,pp.1111-1116,1975.
- [2] W. R. Christiaanse, "Short-term load forecasting using general exponential smoothing," IEEE Trans. on Power Appr. and Sys., vol. PAS-90, pp. 900-910, 1971.
- [3] K. L. S. Sharma and A. K. Mahalanabis, "Recursive short-term load forecasting algorithm," Proc. IEE, vol.121,pp.59-62,1974.
- [4] S. Venuri, W. L. Huang and D. J. Nelson, "On-line algorithms for forecasting hourly loads of an electric utility," IEEE Trans. on Power Appr. and Sys., vol. PAS-100,pp.3775-3784,1981.
- [5] M. Nakamura, "Short term load forecasting using weekday load models and bias models," Proc. PICA Conference,pp.37-42,1984.
- [6] D. P. Lijesen and J. Rosing, "Adaptive forecasting of hourly loads based on load measurements and weather information," IEEE Trans.on Power Appr.and Sys.,vol.PAS-90,pp.1757-1767,1971.
- [7] H.P.Van Meeteren and P.J.M.Van Son, "Short-term load prediction with a combination of different models," Proc.PICA Conference,pp.192-197 ,1979.
- [8] D.E.Rumelhart, G.E. Hinton and R.J. Williams, "Learning internal representation by error propagation," Parallel Distributed Processing, vol.1, pp.318-361, Cambridge, MA:MIT Press,1986.
- [9] P.Werbos, "Generalization of backpropagation with application to recurrent gas model," neural Networks, vol.1,pp.339-356,1988.
- [10] P.Fishwick,"Neural network modelling in simulation: A comparison with traditional modelling approaches," Working Paper, University of Florida, Gainesville,FL, 1989.
- [11] J.H.Park, Y.M.Park and K.Y.Lee, "Composite modelling for adaptive short term load forecasting," IEEE trans. on Power System, vol.6,No.2, May,pp450-457,1991
- [12] K.Y.Lee, Y.T.Cha and J.H. Park "Artificial neural network methodology for short-term load forecasting," NSF Workshop on Artificial Neural Network

Methodology in Power System engineering, Clemson University,SC,Apr. 9-10,1990.

- [13] K.Y.Lee, Y.T.Cha and J.H.park,"Short-Term load Forecasting Using an Artificial Neural Network", IEEE PES Winter Meeting,#91 WM 199-0,PWRS.,Feb.,1991.
- [14] D.C.Park, M.A.El-Sharkawi "Electric Load Forecasting Using An Artificial Neural Network", IEEE Trans. on Power System, Vol.6,No.2,May,pp442-448,1991.