

적응력을 갖는 신경회로망에 의한 성분별 부하 예측

이임재윤*, 김진수**, 김정훈**

충남 전문 대학교 전기과*, 홍익대학교 전기 공학과**

A Component-wise Load Forecasting by Adaptable Artificial Neural Network

Jae-Yoon Lim*, Jin-Soo Kim**, Jung-Hoon Kim**

* Dept. of Electrical Engineering, Chung-Nam Junior College,

** Dept. of Electrical Engineering, Hong-Ik University,

□ ABSTRACT

The degree of forecast accuracy with BP-algorithm largely depends upon the neuron number in hidden layer. In order to construct the optimal structure, first, we prescribe the error bounds of learning procedure, and then, we provide the method of incrementing the number of hidden neurons by using the derivative of errors with respect to an output neuron weights. For the case study, we apply the proposed method to forecast the component-wise residential load, and compare this results to that of time series forecasting.

1. 서론

부하 예측은 전력 계통의 계획 및 운용 전반에 걸쳐 가장 먼저 수행되어야 하는 것으로, 부하 예측 결과에 따라 효율적인 전원 계획, 운용 계획, 수급 계획, 부하 관리 방안의 수립이 가능하다. 그런데 최근 오차 역전과 학습 알고리즘(이하, BP)을 기초로 한 다층형 신경회로망이 부하 예측 연구에 적용되어 그 융용 가능성과 결과의 유용성이 제시되고 있는 실정이다. 특히 부하 예측에 이용하기 위해서는 신경회로망 구조의 최적화[1,2]와 관련된 적절한 중간층의 뉴런 수 설정이 중요하다고 할 수 있다. Tatsuya[3]는 신경회로망의 학습 한계를 규정과 함께, 학습 한계를 탈피하기 위하여 중간층의 뉴런 수를 증가 및 축소시키는 방법을 제안하고, 중간층 뉴런 수가 2개인 간이한 문제에 적용한 결과를 발표하였다.

본 논문에서는 보다 많은 뉴런을 필요로 하는 실제적인 문제에 적합한 학습 한계 규정과 함께 중간층 뉴런 수 증가 방법에 대해서도 학습 한계에 도달된 뉴런 만을 증가시키는 알고리즘을 제안하였다. 사례 연구로 주거용 부하의 6개 성분별 부하 예측 문제를 적용하였고, 또한 Box-Jenkins의 시계열 방법과 예측 결과를 비교하여 타당성과 유용성을 나타내었다.

2. BP 신경회로망의 학습 한계 규정

BP 신경회로망은 학습 횟수(iteration)마다 목적 패턴으로 세시된 값과 신경회로망의 출력값 사이의 오차가 구해지게 되는데, (1)식과 같이 학습 횟수에 따른 오차의 변화율이 임계값보다 작다면 더 이상 학습이 진행되지 않게 되므로 기존 신경회로망은 한계 상태에 도달하였다고 볼 수 있으므로 학습 횟수에 따라 학습 한계 규정의 임계값이 조정되도록 적용 상수를 도입하였다. 둘째, 신경회로망의 학습시 매 학습 횟수마다 계산되어지는 중간층 뉴런의 출력 값으로부터 중간층 뉴런 출력 상호간의 상관 계수(correlation coefficients)를 구하여 학습의 한계 규정에 이용할 수 있다. 학습 횟수 k에서 중간층 뉴런 p와 q의 상관계수 $r_{pq}(k)$, 그리고 학습 횟수 k+1에서 상관 계수 $r_{pq}(k+1)$ 일 때 (2)식과 같이 학습 횟수에 따른 변화율이 임계값보다 작다면, 중간층 각 뉴런의 가중치가 변화하지 않는 것으로서 각 뉴런의 역할이 결정된 상태를 의미하게 된다.셋째로 뉴런들 사이의 상관 계수는 선형 관계의 방향과 크기를 의미하는 것으로 상관 계수가 작은 값인 경우는 뉴런 사이에는 선형 관계가 적은 것으로 입력 패턴에 따른 각 뉴런의 출력 상태는 상이함을 나타낸다. 그러므로 학습의 한계를 규정하는 (2)식외에 (3)식을 부가하여 상관 계수가 임계치 보다 큰 경우의 뉴런은 학습 한계에 도달한 것으로

하였다.

이러한 학습 한계 문제는 중간층의 뉴런을 증가시켜 가중치의 변화로 해결할 수 있다. 생성된 뉴런에 대한 가중치는 초기값을 부여하고, 기존에 있던 뉴런은 증가 전까지의 학습을 통하여 수정된 가중치를 가지고 학습을 계속 진행한다.

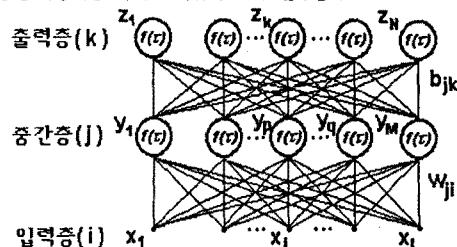


그림 1 신경회로망의 구조

Fig. 1 The ANN Structure

이와 같은 학습 한계에 따른 중간층 뉴런 수를 증가시키는 알고리즘에 대한 전체적인 흐름도(flowchart)는 그림 2와 같다.

$$\Delta E = |\log E(k) - \log E(k+1)| \leq E_k \cdot \theta_e \quad (1)$$

$$\Delta r_{pq} = |r_{pq}(k) - r_{pq}(k+1)| \leq \theta_r \quad (2)$$

$$r(k+1) \geq \varepsilon_r \quad (3)$$

단, E_k : k번 학습에서 오차

θ_e : 적응 상수

θ_r : 상관 계수 변화율 임계치

ε_r : 상관 계수 임계치

3. BP 신경회로망의 뉴런수 증가 방법

2절에서 정의된 학습 한계의 조건인 (1)(2)(3)식을 만족하는 중간층에 뉴런이 존재하는 경우, 중간층 뉴런은 학습 횟수 k째와 k+1째에 같은 입력 패턴에 대하여 일정한 출력을 발생한다. 이와 같은 중간층 뉴런의 출력은 중간층과 출력층 사이의 연결 가중치와의 곱으로 출력층 뉴런에 입력이 되고, 출력 층의 활성화 함수로부터 출력을 내게 되며 이는 목표값과의 차이인 오차를 계산하게 된다. 즉 (1)식의 오차의 감소 변화율은 중간층과 출력층 사이의 가중치가 크게 좌우하므로 가중치에 대한 오차의 감도에 따라 증가할 뉴런 수를 결정한다. 가중치에 대한 오차 감도는 연쇄 규칙(Chain Rule)에 의하여 다음과 같이 정의할 수 있다.

$$\frac{\partial E}{\partial b} = \frac{\partial E}{\partial z} \frac{\partial z}{\partial v} \frac{\partial v}{\partial b} \quad (4)$$

단, E : 학습 오차

b : 출력층과 중간층 사이의 가중치

z : 출력층 뉴런의 출력

v : 출력층 뉴런의 입력

(4)식의 우변 $\frac{\partial E}{\partial z}$ 는 출력층 뉴런의 출력에 대한 오차 감도를 의미하며, 학습 오차 E 와 오차 감도는

$$E = \frac{1}{2}(z-t)^2 \quad (5)$$

$$\frac{\partial E}{\partial z} = z-t \quad (6)$$

단, t : 목표값 (출력)

(5),(6)식과 같고, $\frac{\partial z}{\partial v}$ 는 출력층 뉴런의 입력에 대한 출력 감도인데, 출력 z 는 입력(v)의 Sigmoid함수이므로 다음과 같다.

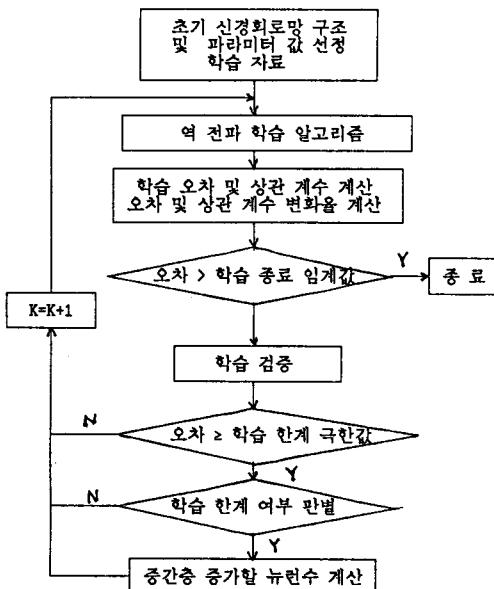


그림 2 학습 과정 중 중간층 뉴런 수의 증가에 대한 알고리즘
Fig. 2 The Algorithm for increasing the number of hidden neurons

$$z = g(v) \quad (7)$$

$$g(v) = \frac{1}{1 + \exp(-v)} \quad (8)$$

$$\frac{\partial z}{\partial v} = g(v)(1-g(v)) = z(1-z) \quad (9)$$

마지막 항인 $\frac{\partial v}{\partial b}$ 는 중간층과 출력층 사이에 연결된 가중치에 대한 출력층 뉴런의 입력 감도로 출력층 뉴런의 입력과 감도는 각각 (11),(12)와 같다.

$$v = b_0 + \sum b_i y_i \quad (10)$$

$$\frac{\partial v}{\partial b} = y_i \quad (11)$$

단, b_0 : bias

y_i : 중간층 뉴런의 출력

즉 가중치에 대한 오차의 감도는 (6)(9)(11)식으로부터 정리하면 (12)식과 같다.

$$\frac{\partial E}{\partial b} = (z-t) \cdot z \cdot (1-z) \cdot y_i \quad (12)$$

$$P = (z-t) \cdot z \cdot (1-z) \quad (13)$$

그림 1과 같이 출력 층의 뉴런수가 k 개 있는 경우, 각 가중치에 대한 출력층 오차의 감도는 다음과 같이 정리할 수 있다.

$$\frac{\partial E_k}{\partial b_{pk}} = P_k \cdot y_p \quad (14)$$

단, E_k : 출력층 k 뉴런의 오차

b_{pk} : 중간층 p 뉴런과 출력층 k 뉴런 사이의 가중치

y_p : 중간층 p 뉴런의 출력

학습 한계 상태에 도달한 중간층 뉴런이 p,q 뉴런이라 할 때, 중간층 뉴런과 출력층 뉴런이 완전히 연결되어 있으므로, p,q 뉴런과 연결된 가중치에 의한 오차 감도 S_p 와 오차 감도의 차 ΔS 는 다음과 같다.

$$S_p = \sum_{k=1}^L \left| \frac{\partial E_k}{\partial b_{pk}} \right| \quad (15)$$

$$S_q = \sum_{k=1}^L \left| \frac{\partial E_k}{\partial b_{qk}} \right| \quad (16)$$

$$\Delta S = |S_p - S_q| \quad (17)$$

단, S_p : p 뉴런과 출력층 사이의 가중치(b_{pk})에 대한 출력층 k 뉴런의 출력 오차 감도

오차의 감도차가 크면 p,q 뉴런 중 한 뉴런에 연결된 가중치에 대한 오차 감도가 적은 것으로 학습의 한계에 도달한 것으로 다음과 같은 조건에 따라 증가할 뉴런수 HN을 결정하였다.

$$HN = \begin{cases} 2 & \log \Delta S \geq 0.5 \\ 1 & \log \Delta S < 0.5 \end{cases} \quad (18)$$

또한 학습 한계에 따른 뉴런 수의 기하급수적인 증가를 방지하기 위하여 학습 오차인 학습 한계 극한값을 설정하여 오차가 극한값 범위 내에 있을 경우만 학습 한계 판별 및 뉴런수 증가를 하도록 하였다.

4. 사례 연구 결과

4.1 부하 예측을 위한 실적 자료

본 논문에서 제안한 알고리즘의 타당성과 유용성을 검증하기 위하여 그림3과 같이 참고 문헌[4]에서 얻은 주거용 부하의 월별 최대 부하시 성분별 부하 실적 자료이다. '85년부터 '89년 까지의 60개의 월별 자료를 토대로 '90년의 12개월을 예측하고자 한다.

'85-'90 Component-Wise Load
(Residential Load : 15 Time)

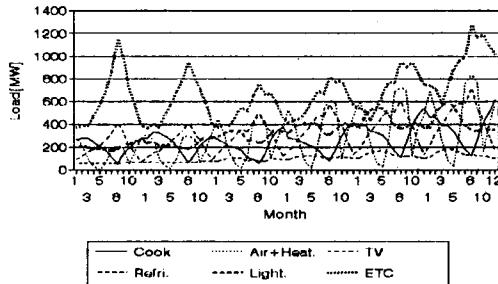


그림 3 주거용 부하의 성분별 실적 자료

Fig. 3 The historical data of component-wise loads

4.2 신경회로망에 의한 부하 예측

초기의 신경회로망은 12-12-12인 3층 구조를 설정하였다. 학습 방법은 일반화된 멜타 규칙을 적용하였다. 학습율은 0.1, 모멘텀은 0.6, 초기 가중치는 -0.5~0.5 범위의 난수를 적용하였으며, 학습의 종료 임계값은 0.0001, 오차 변화율을 적용 상수, 상관 계수 변화율의 임계값은 학습 한계의 극한값은 실현적으로 각각 0.01, 0.005, 0.02를 적용하였고, 상관 계수의 임계치는 0.9를 설정하였다. 또한, 학습 과정을 위한 입력 및 목적(출력) 패턴의 값은 정규화 하였으며, 각 패턴은 12개의 입출력으로 구성하여 총 48개 패턴을 만들었다. 입력과 출력 패턴은 학습 자료의 불규칙성을 제거하는 이동 평균의 효과를 얻기 위하여 입력 패턴으로부터 1개 이동하여 구성하였다.

4.3 부하 예측 결과 및 검토

신경회로망이 12-12-12 구조로 고정된 경우와 앞에서 설명된 알고리즘에 의하여 뉴런수가 증가되는 최적 신경회로망을 주거용 부하의 냉장고 부하 예측에 적용하기 위하여 학습한 결과 그림4와 같은 학습 오차의 변화를 보이고 있다. 최적 신경회로망의 경우 학습의 초기 단계인 140에서 400회 범위 내에서 학습 한계에 따른 뉴런의 증가를 하며, 최종적으로 중간층 뉴런 수가 44개로 되었고, 뉴런 증가시 뉴런의 증가에 따른 가중치 갯수의 증가로 일시적인 학습 오차의 증가를 보이나 끝마로 뉴런수 증가 전 상태의 오차로 감소한다. 학습 오차의 감소 또한 고정된 신경회로망의 경우 보다 빠르게 수렴하고 있음을 알 수 있다.

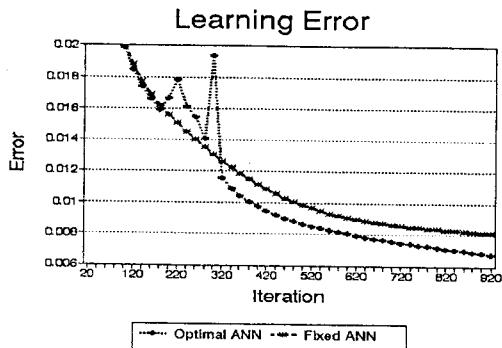


그림 4 냉장고 부하의 학습 오차 곡선
Fig. 4 Error Curves in Learning Procedure

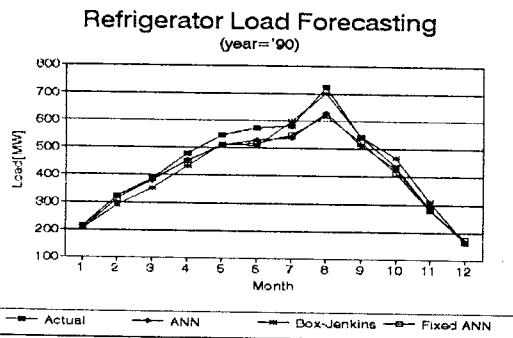


그림 5 냉장고 부하의 예측 결과
Fig. 5 Load forecasting results in refrigerator load

그림5는 최적 신경회로망과 고정된 신경회로망의 동일한 자료에 의한 학습하여 냉장고 부하를 예측한 결과이다. 또한 실적 자료의 시계열 자료를 고려하여 참고문헌[4]에서 연구된 Box-Jenkins의 시계열 방법 결과를 나타내고 있다. 실제값과 예측값의 차를 평균값으로 나누어 계산된 예측 오차는 표1과 같이 최적 신경회로망의 경우 14,700회 학습하여 5.6%, Box-Jenkins 방법은 6.0[%]로 신경회로망의 우수함을 알 수 있다. 고정된 신경회로망의 경우는 동일한 학습 횟수에서 6.4[%]로 중간층 뉴런

표 1 신경회로망을 이용한 부하 예측 결과
Table 1 Load forecasting results by ANN

월	Actual [MW]						최적 ANN 모형 (오차)						ARIMA 모형 (오차)					
	C(H)	RI	T.V	RE	LI	ETC	C(H)	RI	T.V	RE	LI	ETC	C(H)	RI	T.V	RE	LI	ETC
1	695.8	457.5	111.9	213.6	371.6	737.8	642.3 (11.9)	436.5 (5.7)	112.3 (0.6)	211.1 (1.3)	376.4 (1.9)	755.8 (0.2)	706.6 (0.2)	456.7 (0.2)	102.8 (2.3)	203.4 (3.0)	358.6 (0.4)	729.1
2	514.4	459.6	152.9	324.1	505.1	712.6	501.0 (3.0)	441.1 (5.3)	150.5 (1.5)	324.2 (0.2)	494.0 (3.5)	746.1 (2.5)	513.3 (3.3)	450.5 (3.3)	148.3 (7.9)	289.5 (2.6)	493.6 (1.2)	679.4
3	253.6	389.4	170.9	386.3	562.2	574.6	255.6 (0.4)	380.9 (2.4)	163.4 (5.2)	378.2 (1.8)	533.3 (6.4)	602.9 (3.0)	237.5 (3.5)	397.4 (2.1)	165.9 (3.5)	352.3 (7.5)	541.9 (4.7)	525.3 (0.2)
4	75.2	385.3	182.0	478.6	584.9	744.1	62.9 (2.7)	375.9 (2.6)	168.6 (9.5)	454.6 (5.4)	542.2 (9.6)	782.5 (4.1)	73.0 (0.4)	375.1 (2.7)	174.7 (5.2)	432.7 (10.4)	559.6 (5.8)	683.4 (6.1)
5	29.3	339.8	177.3	546.4	552.7	882.7	44.4 (3.3)	351.7 (3.4)	167.2 (7.0)	507.7 (8.8)	529.3 (5.1)	893.7 (1.2)	27.8 (0.3)	344.5 (1.2)	181.9 (3.3)	515.1 (7.1)	569.1 (3.8)	871.5 (6.4)
6	274.2	261.1	156.8	572.9	470.0	957.0	275.3 (0.2)	260.9 (0.0)	154.8 (0.6)	530.5 (1.2)	472.2 (9.6)	926.5 (3.1)	266.6 (0.6)	288.9 (1.6)	170.9 (7.6)	508.2 (10.0)	524.3 (14.7)	978.8 (12.5)
7	777.8	176.9	132.2	581.3	375.8	1000.2	707.7 (0.1)	173.4 (1.3)	133.8 (1.3)	538.3 (0.8)	379.4 (1.0)	944.8 (0.6)	699.0 (1.6)	188.9 (1.6)	129.5 (1.3)	597.5 (3.3)	384.0 (1.9)	998.9 (9.6)
8	840.0	119.9	134.1	724.2	352.8	1279.3	728.4 (24.9)	122.1 (0.6)	132.9 (0.6)	629.6 (21.6)	353.3 (1.1)	1125.6 (16.2)	798.1 (9.3)	130.2 (2.8)	127.3 (4.8)	701.5 (5.2)	360.3 (17.4)	1236.3
9	769.5	254.7	121.6	544.2	341.0	1167.1	711.2 (13.0)	254.5 (0.0)	122.8 (1.1)	512.7 (7.1)	346.9 (1.4)	1029.2 (14.5)	748.6 (4.6)	285.7 (8.4)	117.2 (3.1)	543.7 (0.1)	356.3 (3.5)	1180.9 (7.8)
10	146.6	410.1	123.4	435.2	367.8	1191.5	147.6 (0.2)	396.5 (3.6)	123.3 (0.1)	427.1 (1.8)	371.1 (0.7)	1067.5 (13.0)	136.8 (16.4)	470.0 (4.7)	116.7 (12.1)	465.7 (6.9)	381.5 (4.4)	1245.1
11	416.2	509.8	111.3	284.4	351.9	1081.0	399.8 (3.6)	466.0 (12.0)	111.6 (0.5)	281.6 (0.5)	352.4 (6.0)	1023.9 (18.6)	418.3 (18.6)	577.8 (7.2)	101.1 (5.7)	309.5 (9.7)	354.9 (0.7)	1130.2 (1.7)
12	566.3	612.4	104.3	162.8	349.3	1019.7	522.2 (9.8)	527.4 (23.0)	103.7 (0.0)	164.5 (1.0)	344.0 (3.5)	985.9 (9.8)	610.2 (8.1)	641.9 (12.1)	87.3 (12.1)	165.0 (0.5)	329.1 (4.6)	1006.9 (5.0)
성분별 평균 오차 [%]						5.8	4.9	2.3	5.6	2.4	6.3	4.4	6.2	5.5	6.0	4.0	3.1	
모형별 평균 오차 [%]												4.5			4.8			

C(H) : 냉난방 RI : 취사 T.V : T.V RE : 냉장고 LI : 조명 ETC : 기타

수의 부족으로 불충분한 학습을 초래한 결과로 생각된다. 그리고 냉난방 부하의 결과 표1과 같이 최적 신경회로망의 경우와 Box-Jenkins 방법의 예측 오차가 각각 5.6%, 4.4%인 것은 부하의 특성상 냉방 부하와 난방 부하의 혼합으로 인한 실적 자료의 많은 불규칙성이 포함되어 불충분한 학습의 결과이며, 또한 냉난방 부하와 같은 특성을 갖는 기타 부하의 경우도 큰 예측 오차를 보이고 있다. 주거용 부하 중 냉난방 부하와 기타 부하를 제외한 냉장고 부하, 취사 부하, TV 부하, 조명 부하는 최적 신경회로망을 이용한 예측 결과가 양호함을 알 수 있다.

5. 결 론

본 논문은 전력 계통의 부하 예측을 위한 최적의 신경회로망 구축에 관한 연구로 정리하면 첫째, 적용 상수와 상관 계수 임계치를 도입하여 복잡한 문제에 부합하는 학습 한계를 규정하였으며, 둘째, 학습 한계에 따른 중간층 뉴런 수의 증가는 학습 한계와 적절적인 관계이 있는 가중치에 대한 오차의 감소에 의한 논리적인 방법을 제안하였고, 셋째, 학습이 진전된 후 뉴런 수의 과대한 증가를 방지하기 위해 학습 한계 극한값을 제시하였고, 넷째, 필요에 따라 학습의 정도를 용이하게 검증할 수 있도록 알고리즘을 구성하였으며, 그리고 제안된 알고리즘을 실제적인 부하 예측에 적용하고, 시계열 방법에 의한 예측 결과와 비교하여 본 결과, 단위 부하인 성분별 부하 예측에 유용성과 용이성이 입증되었다.

□ 참고 문헌

- [1] T. Ash, 'Dynamic Node Creation in Backpropagation Networks', ICS Report 8901, UC San Diego, 1989.
- [2] M. Mezard, J. P. Nadal, 'Learning in Feedforward Layered Networks:the Tiling Algorithm', J. Phys. A, Math. Gen., 22, 1989.
- [3] Tatsuya Masuda, Hirohiko Ikeya, Yoshiyuki Fujii, 'A Method for Obtaining the Suitable Sized Neural Network Structure by Multiplication and Combination of Hidden Units', JIEE, Vol. 113-C, No. 10, 1993.
- [4] Jae-YoonLim, Jung-HoonKim, Seung-ChanChang, 'Developing the Method of Load Composition Estimation and Load Forecasting for Each Load Group using Artificial Neural Network', JIEE, 3, 1994.
- [5] Y. Chauvin, 'A Backpropagation Algorithm with Optimal Use of Hidden Units', Advances in Neural Information Processing Systems, 1, 1989.
- [6] Jacek M. Zurada, Introduction to Artificial Neural Systems, West, 1992.
- [7] David E. Rumelhart, James L. McClelland and the PDP Research Group, Parallel Distributed Processing Vol. 1, The MIT Press, London, 1986.