

## 신경회로망을 이용한 변압기의 단기부하예측

(Short-Term Load Forecasting of Transformer Using Artificial Neural Networks)

김병수\* · 송경빈\*\*

(Byoung-Su Kim · Kyung-Bin Song)

### 요 약

신경회로망을 이용한 변압기의 단기 부하예측 알고리즘을 제안한다. 변압기에 대한 단기부하예측은 그 필요성에도 불구하고 연구자들에게 많은 관심을 받지 못했다. 제안된 알고리즘은 입력값으로 예측일 이전의 변압기 최대부하와 해당지역의 최고온도, 최저온도 그리고 예측일의 최고온도, 최저온도로 구성하고 적절한 학습케이스를 선택하여 신경회로망의 학습을 통해 배전용 변압기의 단기부하예측을 수행하였다. 제안된 방법은 서울 남현동의 배전용 변압기를 샘플로 추출하여 예측하였다. 예측결과 배전용 변압기의 부하예측에 대한 정확도의 우수성을 확인했다. 제안된 알고리즘은 배전용 변압기의 과부하에 의한 사고 예방에 도움을 줄 것이다

### Abstract

In this paper, the short-term load forecasting of transformers is performed by artificial neural networks. Input parameters of the proposed algorithm are peak loads of pole-transformer of previous days and their maximum and minimum temperatures. The proposed algorithm is tested for one of transformers in Seoul, Korea. Test results show that the proposed algorithm improves the accuracy of the load forecasting of transformer compared with the conventional algorithm. The proposed algorithm can help to prevent some damages by over-loads of transformers.

Key Words : load forecasting, neural networks, transformer

### 1. 서 론

배전계통의 최말단의 전력설비인 배전용 변압기는 수용가에 직접 전력을 공급하는 매개체이며 배전

용 변압기에 의한 전력공급의 중단은 수용가 및 전력회사의 신뢰 및 전력품질의 심각한 저하를 초래한다.

전력산업의 재편움직임과 배전계통에 대한 신기술 적용 추세 등은 머지않아 수용가에서의 배전 계통의 전력신뢰도 향상요구가 고조될 것임을 반증하고 있다[1].

또한 배전용 변압기의 과부하에 의한 소손 및 유분출에 의한 돌발사고가 발생되고 있으며, 이로 인해 전력공급의 신뢰도 저하와 정전에 따른 사업자 및 고

\* 주저자 : 숭실대학교 전기공학과 석사과정

\*\* 교신저자 : 숭실대학교 전기공학과 조교수

Tel : 02-817-7966, Fax : 02-817-7961

E-mail : bskim@ssu.ac.kr

접수일자 : 2005년 5월 26일

1차심사 : 2005년 6월 2일

심사완료 : 2005년 6월 21일

객 측의 경제적 손실은 물론 설비의 폭발에 의한 물질적인 손실과 정전에 의한 경제적인 손실, 그리고 배전계통 신뢰도의 저하를 가져올 수 있다. 이로 인해 배전계통의 정확한 부하 예측은 배전계통에서 신뢰도 증가와 사고의 감소를 위해 필수 불가결하다.

배전용 변압기의 단기 부하예측을 위해서는 부하데이터의 실 취득이 가장 우선시 되어야 한다. 배전용 변압기가 배전계통의 설비 중 그 수에 있어서 가장 많은 비중을 차지하고 있으며 부하관리를 위해 효율적인 투자로 운영의 효율을 개선할 필요가 있다.

본 논문에서는 최근 10동안 가장 많은 연구가 행해지고 있는 신경회로망기법을 이용하여 배전용 변압기의 부하예측을 수행한다. 예측을 수행한 변압기는 서울 지역에서 추출하였으며 신경회로망의 입력값으로 같은 수요패턴을 갖는 이전요일들의 최대부하와 온도데이터를 고려하여 그 변동 추세를 찾아 예측을 수행하였다.

## 2. 배전용 변압기의 개요

다음의 그림 1은 일반적인 배전계통의 구성을 보여준다.

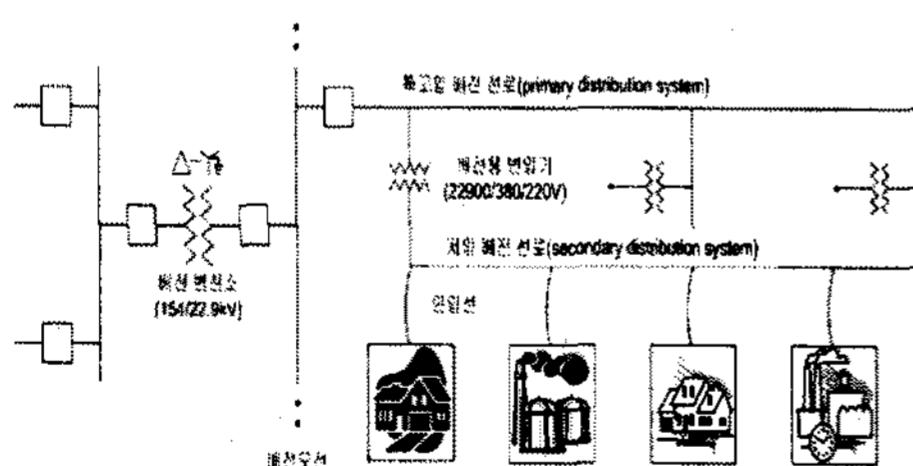


그림 1. 배전계통의 일반적인 구조  
Fig. 1. A general diagram of distribution systems

그림 1에서 보는 바와 같이 배전계통은 배전 변전소의 주 변압기(main transformer, 국내의 경우 일반적으로 45/60[MVA] 용량)에서 시작하여 배전용 변압기(국내 주상변압기의 경우, 일반적으로 30~100[KVA])에 전력을 공급하는 특고압 배전선로(primary distribution system)와 배전용 변압기 2차측에서 수용가까지 전력을 공급하는 저압 배전선로(secondary distribution system)로 구성되어 있다[1][2].

## 2.1 과부하 운전이 변압기에 주는 영향

변압기의 정상적인 수명은 정격 운전조건과 정상 주위 온도 하에서 연속 운전하는 경우에 대한 예상 값이다. 과부하 및 정격보다 높은 주위 온도로 운전하는 것은 변압기 절연에 대한 어느 정도의 위험을 내포하며 열화를 가속화시킨다. 변압기의 수명은 과전압, 계통 단락 및 비상 과부하 운전과 같은 돌발 사고에 대부분 영향을 받는다. 이런 것들은 별개로 일어나는 복합적으로 일어나는 간에 그 후의 변압기의 수명에 결정적으로 영향을 준다. 일반적으로 과부하 명판 자격을 초과하여 부하를 가할 경우의 결과는 다음과 같다.

- 권선, 지지물, 리드선, 절연물 및 절연유의 온도가 허용치 이상으로 상승할 수 있다.
- 누설 자속 밀도의 증가로 금속부분에 와전류가 흘러 금속부가 가열된다.
- 온도 변화에 따라 절연물이나 절연유 내의 수분이나 가스량이 변한다.
- 부싱, 텁 접환기, 케이블 종단 접속부 및 변류기 등 보다 높은 스트레스가 가해져서 설계 및 운용의 여유가 감소된다.

이러한 영향들이 계속하여 누적되면 절연물 수명이 단축되어 소손이 발생할 수 있다. 이 외에도 단기적, 장기적 과부하에 의한 위험요인도 존재한다.

## 2.2 과부하 사고

국내 주상변압기의 절연유 분출 사고의 연도별 발생현황은 표 1과 같고 이들의 계절별 분석은 표 2와 같다.

표 1에서 보는 바와 같이 절연유 분출사고는 80년대에 비하여 90년대로 갈수록 증가 추세에 있음을 볼 수 있다. 이는 최근 부하 밀도의 증가에 따른 주상변압기 설치 대수의 증가와 최대부하를 형성하던 부하종류가 전등부하에서 냉방부하로 변화했기 때문으로 사료된다. 또한 계절별로는 변압기 절연유는 온도 1[°C]상승에 체적이 0.075[%]씩 증가하는 온도 특성을 가지므로 표 2에서 보는 바와 같이 주위 온도

## 신경회로망을 이용한 변압기의 단기부하예측

와 태양광에 의한 복사열로 인해 절연유의 체적증가가 큰 여름철에 가장 많음을 알 수 있으며, 즉 이는 주위온도가 최고 온도로 되는 시점에 냉방부하가 가동되어 과부하를 발생시키고 변압기 온도를 최고로 상승시키기 때문이다.

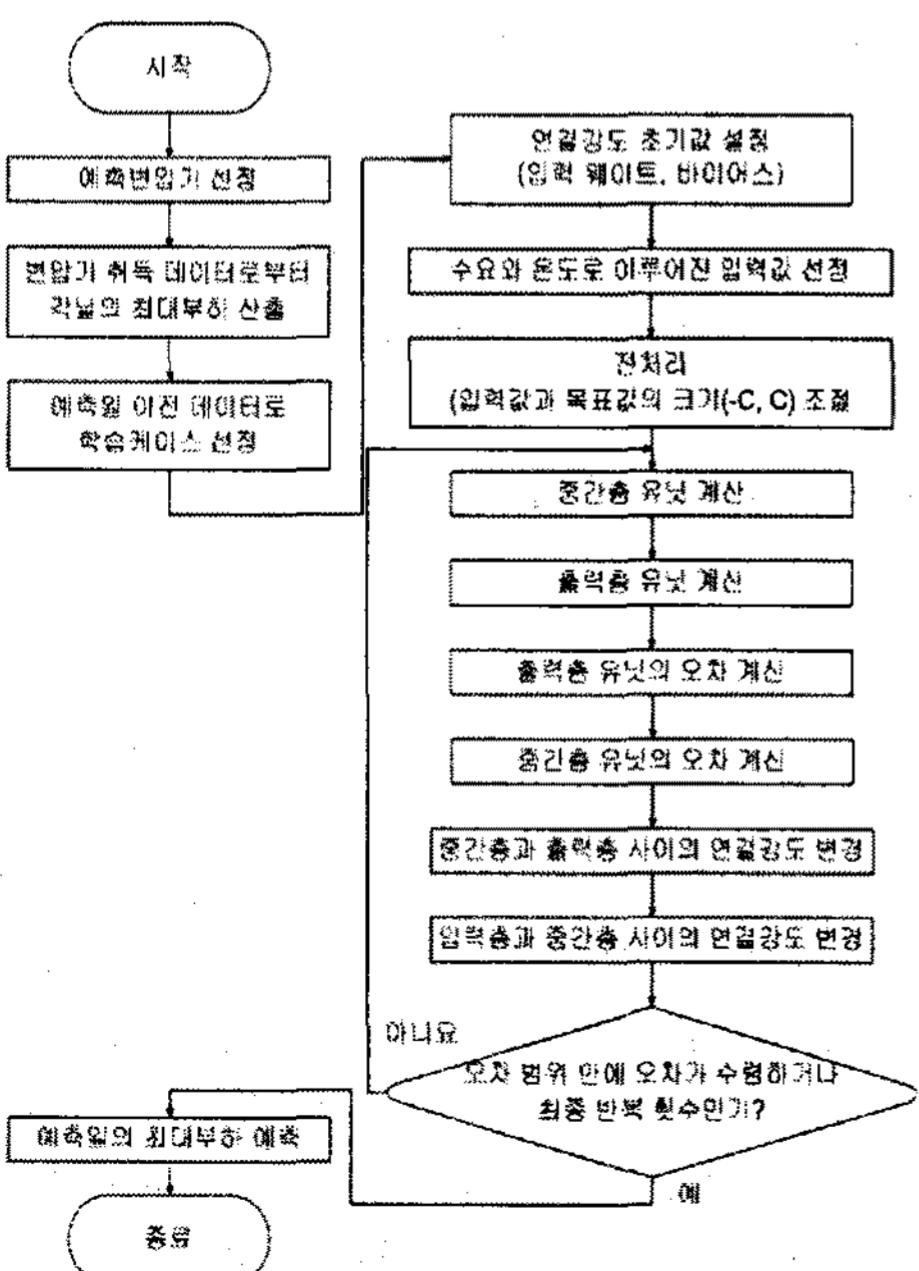
**표 1. 절연유 분출 사고의 연도별 분석**  
**Table 1. Annual analysis of spouting accidents of oil**

년도별	1982	1983	1984	1985	1986	1987	1988	1989	1990.8	합계
발생 건수	10	7	6	1	2	3	4	10	28	71

**표 2. 절연유 분출 사고의 계절별 분석**  
**Table 2. Seasonal analysis of spouting accidents of oil**

구 분	봄	여름	가을	겨울	합계
발생건수	6	58	3	4	71
점유율[%]	8.5	81.7	4.2	5.6	100

## 3. 신경회로망을 이용한 배전용 변압기의 단기 부하예측



**그림 2. 변압기 단기부하예측 알고리즘 흐름도**  
**Fig. 2. The flowchart of short-term load forecasting for transformers**

제안된 논문에서 부하예측을 위한 신경회로망의 입력값은 변압기 부하와 온도로 구성되었다. 부하와 온도를 사용하여 부하예측을 한 것은 I. Drezga의 논문에서 중요하게 다루어졌을 뿐 아니라 변압기의 과부하는 온도와 밀접한 관련이 있기 때문이다[3].

그림 2는 제안된 변압기 단기부하예측 알고리즘의 흐름도를 보여주며, 본 알고리즘은 신경회로망기법 중 출력층과 목표값의 비교를 통해 연결강도를 조절해 나가는 오차역전파 알고리즘을 사용하였다.

배전용 변압기의 단기 부하예측 알고리즘에 대한 자세한 설명은 다음에 설명한다.

### 3.1 제안된 신경회로망

제안된 신경회로망은 입력층과 은닉층 그리고 출력층으로 구성되며 5개의 입력값을 사용하여 예측하였다. 5개의 입력요소는 다음과 같다.

- $x_1$ -예측일 이전 동일요일의 최대부하  $L_{\max}(d-7)$
- $x_2$ -예측일 이전 동일요일의 최대온도  $T_{\max}(d-7)$
- $x_3$ -예측일 이전 동일요일의 최소온도  $T_{\min}(d-7)$
- $x_4$ -예측일의 최대온도  $T_{\max}(d)$
- $x_5$ -예측일의 최소온도  $T_{\min}(d)$

여기서  $d$ 는 예측일이다.

신경회로망의 입력값  $x$ 와 목표값  $o$ 로 나타낼 수 있다. 그리고 입력값의 요소인 부하와 온도는 그 범위가 매우 다르기 때문에 학습시에 수렴하지 않는 경우가 발생한다. 이러한 문제를 해결하기 위해 원본 데이터의 크기를 조절하는 것이 필요하다.

크기의 조절에 대한 방법은 여러 가지가 있을 수 있으나 다음과 같은 방법에 의해 스케일링 될 수 있다[4].

$$x_i^{(k)} = \frac{x_i^{(k)} - \bar{x}_i}{s_i}, \quad (i=1, \dots, 5; k=1, \dots, 7) \quad (1)$$

$$o_e^{(k)} = \frac{o^{(k)} - \bar{o}}{s_o} \quad (2)$$

여기서  $k$ 는 학습케이스의 수이며  $s_i (i=1, \dots, 5)$ 는  $x_i^{(k)}$ 의 표준 편차 값이다. 그리고  $s_o$ 는  $o^{(k)}$ 의 표준편차 값이다.  $\bar{x}_i$ 와  $\bar{o}$ 는 각각 입력값과 목표값

( $k=1, \dots, 7$ )의 평균값이다.

신경회로망은 출력값과 목표값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해 나간다. 그 식은 다음과 같다[5].

$$y_i = \sum_{j=1}^5 W_{ij}x_j + \theta \quad (3)$$

여기서  $W_{ij}$  ( $i=1, \dots, n$ ,  $j=1, \dots, 5$ )는 입력 노드와 은닉 노드사이의 연결 가중치 벡터이고  $\theta$ 는 은닉층의 바이어스를 나타낸다. 그리고  $x_j$  ( $j=1, \dots, 5$ )는 입력요소이다.  $y_i$ 는 은닉층의 시그모이드 전달함수의 출력값으로 대입된다.

$$F(y_i) = \frac{1}{1 + \exp(-y_i)} \quad (4)$$

은닉층의 각 노드에서 출력된 값들은 최종적으로 출력층에서 연결 가중치와 곱해진 후 모두 더해서 출력값으로 나오게 된다. 출력층이 전달함수는 선형 함수이기 때문에 최종 출력값과 같아지게 된다.

$$\hat{o} = \sum_{i=1}^n W_i F(y_i) \quad (5)$$

제안된 신경회로망 그림은 다음과 같다.

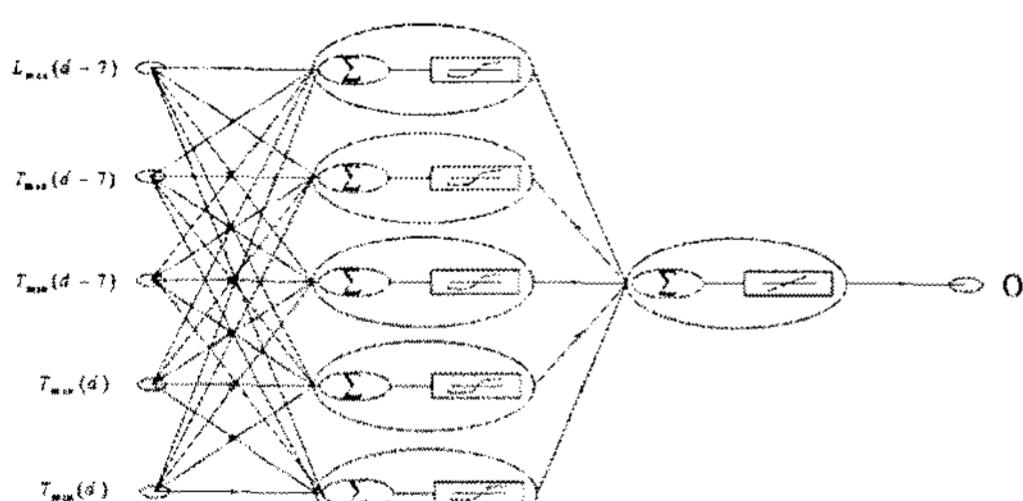


그림 3. 제안된 신경회로망의 구조

Fig. 3. Structure of proposed artificial neural network

신경회로망의 오차식은 다음과 같다.

$$E = \frac{1}{2} \sum_{k=1}^K (o^{(k)} - \hat{o}^{(k)})^2 \quad (6)$$

여기서  $K$ 는 신경회로망 학습에 사용된 케이스의 수이며,  $o^{(k)}$ 는 학습 케이스  $k$ 의 실제 출력값, 그리고  $\hat{o}^{(k)}$ 는 신경회로망의 목표값이다. 오차의 범위는  $10^{-4}$ 이며 오차값이 이 범위에 만족되면 학습은 종료된다. 만약 학습과정이 오차 범위 안에 들지 않으면  $10^5$ 의 반복학습 후 종료하게 된다.

오차역전파 알고리즘에 의해 아래와 같이 역 방향으로 연결 가중치 값이 바뀌게 된다.

$$T_{p+1} = T_p - \alpha \frac{\partial E}{\partial T_p} \quad (7)$$

$$T = w_{ij}, W_i, \theta_i \quad (i=1, \dots, n; j=1, \dots, 5) \quad (8)$$

여기서  $p$ 는 반복횟수,  $\alpha$ 는 학습률로 0.01값을 사용하였다. 그리고  $\frac{\partial E}{\partial T_p}$ 는 오차제곱  $E$ 에 대한 웨이트  $T$ 의 편미분 값이다.

### 3.2 학습케이스의 선택

본 신경회로망 알고리즘의 정확도를 개선하기 위해 몇 가지 경우의 학습 케이스를 선택하였다. 선택된 케이스는 예측일 이전 7일의 데이터를 사용하는 것과 예측일 이전 평상일 7일, 예측일 이전 동일 요일 7일, 그리고 예측일 이전 평상일 14일의 데이터이며 표 3, 4, 5, 6와 같다.

부하예측에 사용되는 데이터는 여러 가지의 날짜 요인이나 날씨 등에 영향을 받는다. 이러한 여러 가지 상황을 놓고 비교해 본 결과 예측일 이전 동일요일 7일의 학습 케이스가 가장 우수함을 보였다.

표 3. 예측일 이전 7일 선정

Table 3. Selection of the previous 7 days of the forecasting day

일	월	화	수	목	금	토
17	18	19	20	21	22	23
24	25	26	27	28	1	2
3	4	5	6	7	8	9
10	11	12	13	14	15	16
17	18	19 (d-7)	20 (d-6)	21 (d-5)	22 (d-4)	23 (d-3)
24 (d-2)	25 (d-1)	26 d day	27	28	29	30



