

신경회로망과 하절기 온도 민감도를 이용한 단기 전력 수요 예측

論文
54A-6-1

Short-Term Load Forecasting Using Neural Networks and the Sensitivity of Temperatures in the Summer Season

河成琯*·宋敬彬†·金鴻來**
(Seong-Kwan Ha, Kyung-Bin Song, Hongrae Kim)

Abstract – Short-term load forecasting algorithm using neural networks and the sensitivity of temperatures in the summer season is proposed. In recent 10 years, many researchers have focused on artificial neural network approach for the load forecasting. In order to improve the accuracy of the load forecasting, input parameters of neural networks are investigated for three training cases of previous 7-days, 14-days, and 30-days. As the result of the investigation, the training case of previous 7-days is selected in the proposed algorithm. Test results show that the proposed algorithm improves the accuracy of the load forecasting.

Key Words : Load Forecasting, Neural Networks, General Exponential Smoothing, Temperature Sensitivity

1. 서 론

전력 수요 예측은 전력 계통에서 경제적이고 안정적으로 전력 에너지를 공급하기 위한 필수적인 사항이다. 전력수요의 비선형 특성이 사회, 경제적 요소와 연계되어 있으며, 기후 등의 영향으로 정확한 전력 수요예측은 세심한 노력이 요구된다. 수요 예측의 기법으로 시계열법, 회귀분석법 등과 같은 고전적 방법들이 있으며 지식기반의 인공지능기법과 퍼지 방법을 통하여 예측하는 방법이 있다.

최근에 국내외에서는 인공지능 기법을 통하여 보다 정확한 전력수요예측에 접근하려는 연구가 한창이다. 인공지능 기법은 인간의 비선형적인 사고를 연산 처리 속도가 빠른 컴퓨터를 이용하여 학습 알고리즘으로 학습 후 예측하게 된다. 인공지능 기법 중 신경회로망은 인간의 신경 체계의 기본 구조인 뉴런을 기초로 모델링하며 각 뉴런은 상호 접속되어 연결강도의 크기에 따라 전체 신경회로망의 기능을 결정한다. 이러한 신경회로망은 비선형성을 갖는 시스템인 전력 시스템에서 부하예측, 계통의 고장진단, 안정도 평가, 발전기 기동정지계획 등에서 활발히 사용되고 있다. 하지만 신경회로망은 결과에 대한 수학적인 확실한 증명이 어렵다. 결과가 수많은 가중치와 입력패턴의 연산을 통해 이루어졌고 또한 그 가중치는 복잡한 machine-learning에 의해 결정되기 때문에 기존의 프로그래밍에서와 같은 해석은 거의 불가능하다. 따라서 만일 가능한 모든 입력값을 통해 이를 평

가해 볼 수 없다면 안전성이 심각한 문제가 되거나 위험 부담을 피해야 하는 분야에 대해서는 적절치 않을 수 있다.

본 논문에서는 전력 수요 예측의 정확성을 잊지 않으면서도 적은 입력값으로 예측할 수 있는 컴팩트한 신경회로망 알고리즘을 제안한다. 최소 구조를 갖기 위해 필수적인 입력값만을 선정하였으며 학습 오차 수렴범위 안에 수렴이 잘 되도록 하기 위해 입력값의 크기 조정을 하였다. 또한 입력값과 목표값으로 이루어진 학습케이스의 구성 개수를 과거 7일, 14일, 30일로 세 케이스로 구성하여 보았다. 그리고 시뮬레이션을 통하여 이 중에서 수렴성이 높으면서 학습에 필요한 최소의 학습 케이스를 선정하였다. 그 결과 과거 7일로 이루어진 학습 케이스가 가장 좋은 결과를 보였으며 모든 전력 수요 예측 학습에 이를 선정하였다.

여름의 경우 냉방부하의 사용 급증으로 온도에 따른 수요 변동을 고려하지 않는다면 예측 정확도가 크게 떨어지게 된다. 이를 해결하기 위해 온도 민감도를 고려하여 예측된 수요값을 신경회로망의 6번째 입력값으로 추가하였으며 예측의 정확성을 향상시키고자 하였다.

제안된 알고리즘을 이용하여 1995년 3월, 8월, 12월 24시간 평균오차, 최대오차를 단기전력수요예측 논문[2]과 비교하였다.

2. 전력 수요 예측에 대한 신경회로망

신경회로망은 전통적인 선형 모델보다 복잡한 비선형 관계를 모델화하기 더 좋은 장점을 가지고 있다. 또한 데이터 처리 방법에서 임의적인 모델 가정이 필요 없고 신경회로망이 자동적으로 입력과 출력 사이의 관계를 비선형적으로 나타내어 주는 장점이 있다. 그러나 신경회로망을 이용한 예측 방법은 아직 입력과 출력 사이의 블랙박스 함수에 대한 체계적인 증명이 없어 수학적인 체계적 증명을 중시 여기는 학자들은 신경회로망에 대해 회의적인 시각을 갖고 있

* 교신저자, 正會員 : 崇實大 工大 電氣制御시스템工學部
助教授 · 工博
E-mail : kbsong@ssu.ac.kr

* 正會員 : 中부발전(주)

** 正會員 : 順天鄉大 工大 情報技術工學部 副教授 · 工博
接受日字 : 2004年 12月 16日
最終完了 : 2004年 4月 13日

다.

H. S. Hippert의 논문은 신경회로망의 문제점들을 1991년부터 1999년에 걸친 40여 편의 신경회로망을 이용한 전력 수요예측 관련 논문들을 조사하여 이슈별로 분류하고 제안된 논문들의 디자인과 테스트 방법들을 평가하였다. 표 1은 신경회로망을 이용한 논문들의 특징을 나타낸다. 표 1에서 입력 변수 L은 부하, T는 온도, H는 습도, W는 날씨변수, f(T)는 온도의 비선형함수, LP는 부하 파라미터를 나타낸다. 뉴런의 수에서 3개의 자료는 각각 입력층/ 은닉층/ 출력층의 수를 나타낸다. '...'은 논문에 나와 있지 않은 내용을 뜻한다.

표 1 신경회로망을 이용한 논문의 특징

Table 1 Characteristics of papers using neural networks

논문	선택된 입력 변수	뉴런의 수	파라미터 총 수	학습 셋의 수	출력값
[3]	L, T	30/10/1	163	336	시간당 부하
[4]	L, T	46/60/1	2881	30	피크 부하
[5]	L, T	14/5/3/1	97	...	시간당 부하
[6]	L, T	6/10/1	81	840	시간당 부하
[7]	L, T	5/8/1	57	7	총 부하
[8]	L, T, H	107/35/35/48	6931	365	24시간 패턴
[9]	L, T	63/24/24	2136	240	24시간 패턴
[10][11]	L, T	86/28/24	3132	1460	24시간 패턴
[12]	L, T, H, W	81/81/24	8610	136	24시간 패턴
[13]	L, T	15/10/1	342	144	24시간 패턴
[14]	L, T, H	19:25/20:40/1	10104:25944	1095	24시간 패턴
[15]	L, T, H, W	79/30/60/24	6288:12528	1095	24시간 패턴
[16]	L, T, H	72/.../24	...	1095	24시간 패턴
[17]	L, T, f(T)	64/48/24	4296	1460	24시간 패턴
[18]	L	51/31/24	28560	31	24시간 패턴
[19]	L	48/70/24/4:10	32004	...	24시간 패턴
[20]	L, T	38/10/24	7848	365	24시간 패턴
[21]	L, T	5:15/3/1	2310:5460	1095	24시간 패턴
[22]	L, T, f(T)	77/24/24	2472	1825	24시간 패턴
[23]	L, T	10/6/6/24	552	365	24시간 패턴
[24]	L, T, H, W	26/36/24	5580	30	24시간 패턴
[25]	L, LP	38/30/25/16	2361	1440	몇 분 후의 부하

논문[1]에서 H. S. Hippert가 조사한 논문들의 신경회로망 구조는 너무 많은 데이터 샘플과 많은 파라미터들을 사용하였다. 이러한 신경회로망은 하나의 데이터 채손이나 잘못된 연결 파라미터의 업데이트로 overfitting이 일어날 수 있다. 만약 신경회로망이 모두 양질의 입력값과 데이터값, 파라미터를 사용하였다면 분명히 신경회로망은 정확한 전력 수요예측을 할 수 있을 것이다. 하지만 입력값과 데이터값, 파라미터 중 몇 개의 데이터가 오류에 의해 손상된다면 신경회로망 역시 overfitting 문제를 일으킬 가능성이 높아진다. 그러므로 많은 수의 파라미터로 구성된 신경회로망 보다 적은 수의 파라미터로 구성된 신경회로망이 overfitting이 일어날 확률이 적으며, 또한 꼭 필요한 데이터들로 학습되고 오염되지 않은 데이터로 학습된다면 이 문제를 해결할 수 있으리라 생각한다. 그러므로 본 논문에서는 오버피팅의 원인이 신경회로망의 블랙박스 안에 많은 수의 변수들과 뉴런들에 의해 일어남을 고려하여 최대한 간략하고 컴팩트한 모델을 구현하고자 하였다.

또한 신경회로망의 블랙박스 안에 변수들과 뉴런들은 입력값의 수에 의해도 오버피팅이 일어날 수 있다. 이를 해결

하기 위해 입력값 선정에 대해 조사하였다. 그리고 신경회로망이 잘못된 입력 데이터 선정에 의한 결점에 민감함을 고려하여 예측을 크게 떨어뜨리는 데이터 요소를 제거하기 위해 특수일은 제외하였으며, 입력값을 요일 특성별로 분류하고 입력값의 전처리 과정을 두어 학습 시에 수렴성을 높이도록 하였다. 또한 은닉층의 경우 뉴런의 수가 너무 적으면 그 모델은 유통성을 가지고 수요를 충분히 표현할 수 없다. 또한 너무 많은 경우 오버피팅이 일어나게 된다. 이를 위해 많은 대안 수를 선택하고 시뮬레이션하면서 그 결과를 통해 은닉층의 뉴런의 수를 선택하였다. 또한 학습 케이스 수에 따라서 예측정확도가 달라지며 수렴성도 크게 차이가 난다. 그러므로 7개, 14개, 30개의 학습 케이스를 선정, 예측하여 이중 가장 좋은 결과를 갖는 학습 케이스를 선정하도록 하였다.

출력의 경우 보통 두 가지의 경우로 나눌 수 있다. 하나는 출력의 값을 24개 갖는 병렬 형태의 신경회로망을 사용하는 경우와 하나의 전력 수요의 시간당 출력 또는 최대 전력 수요값을 내는 경우를 들 수 있다. 본 논문에서는 하나의 출력을 갖는 신경회로망을 이용하여 예측일의 최대값을 예측하였다. 그리고 예측일 전 3주의 같은 요일을 갖는 24시간 데이터를 정규화한 후 평균하여 예측값에 곱하여 24시간별 수요를 예측하였다. 이 방법은 반복 계산량이 적을 뿐 아니라 예측일의 수요 패턴 또한 정규화를 통해 나타내기 때문에 각 요일의 패턴을 안정적으로 나타낼 수 있다. 모든 과정을 통해 신경회로망이 컴팩트하면서도 높은 수렴성을 갖고, 예측 정확도에 훼손이 없도록 함으로써 정확한 단기 전력 수요예측을 이루려고 노력하였다.

3. 최소 구조 신경회로망

일주간의 수요패턴은 평일(화~금)의 경우 거의 동일하며, 토요일부터 감소하기 시작하여 일요일에 최대 감소량을 보이며 다시 월요일은 평일 수요량을 회복하려는 모습을 보이고 있다. 이러한 특징을 살려 알고리즘의 흐름도를 그림 1에 제시한다. 학습 종료 부분까지 off-line에서 이루어지며 학습되며, 실시간으로 최대 전력수요예측값과 24시간 수요를 계산한다.

각 알고리즘의 흐름도를 살펴보면, 우선 예측일의 요일 타입에 따라 신경회로망의 학습 케이스를 다르게 만들어야 한다. ① 평일(화~금), ② 토요일, ③ 일요일, ④ 월요일 각각의 학습 케이스를 만들어 요일타입에 따라 학습을 한다. 또한 계절에 따라서도 여름의 경우에는 온도 민감도를 고려한 예측값을 6번재 입력값으로 추가하여야 한다. 여름은 온도와 수요와의 상관관계가 크므로 이를 고려해 줄 때 더욱 정확한 예측이 가능하기 때문이다. [26] 온도민감도를 사용하여 최대 전력수요 예측값을 구하고 그 값을 신경회로망의 6번재 입력값으로 사용하여 학습하여 예측하였다.

이렇게 요일별 학습 케이스와 계절별 온도 민감도 고려를 결정한 후, 신경회로망의 학습시 수렴성을 높이기 위해 표준 편차를 이용해 입력값과 목표값의 크기를 $(-C, C)$ 로 조정한다. 이렇게 조정된 입력값과 목표값은 오차 역전파 알고리즘을 통해 학습된다. 신경회로망이 학습 오차 내에 수렴하게 되면 예측일의 최대 전력 수요 예측값을 출력하게

된다. 예측일 전 같은 요일을 갖는 3주간의 데이터를 통해 24시간별 정규화값을 만든다. 이 값을 예측일의 최대 전력 수요 예측값에 곱하여 예측일 24시간별 수요 예측값을 구하게 된다.

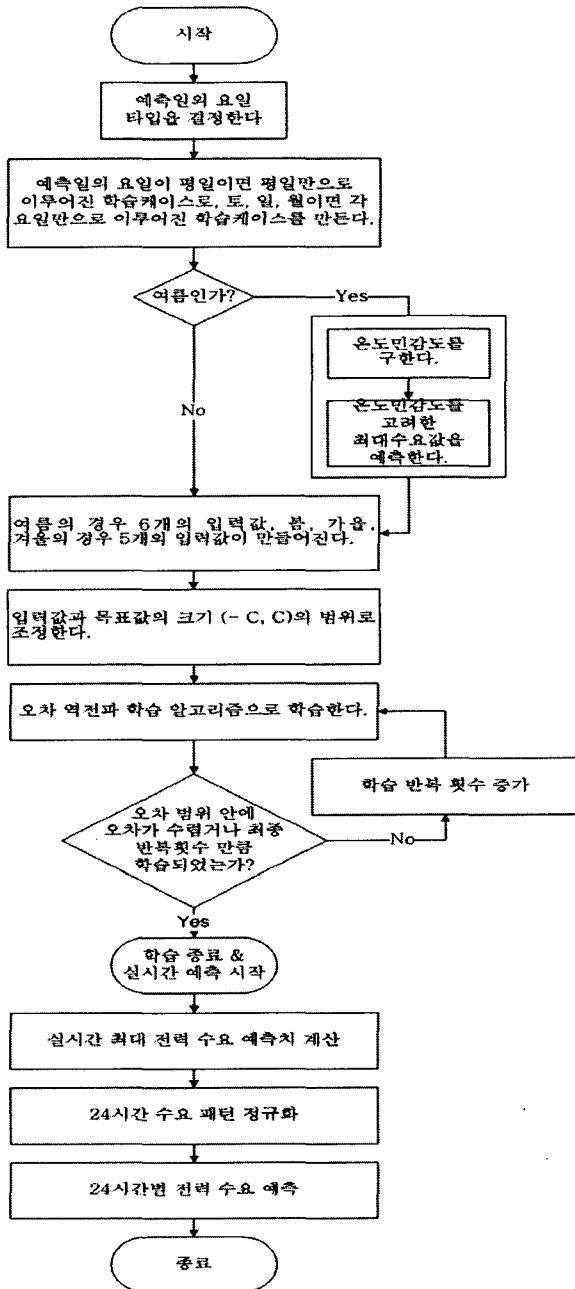


그림 1 전력수요예측 알고리즘의 흐름도

Fig. 1 The flowchart of load forecasting algorithm

3.1 최소 구조 신경회로망 알고리즘

입력층, 은닉층, 출력층으로 구성된 신경회로망은 봄, 가을, 겨울의 경우 5개의 입력값을 사용하여 예측한다. 다섯 개의 입력 요소는 다음과 같다.

- x_1 - 예측일 이전 날의 최대 수요 $L_{\max}(d-1)$

- x_2 - 예측일 이전 날의 최고 온도 $T_{\max}(d-1)$
- x_3 - 예측일 이전 날의 최저 온도 $T_{\min}(d-1)$
- x_4 - 예측일 당일의 최고 온도 $T_{\max}(d)$
- x_5 - 예측일 당일의 최저 온도 $T_{\min}(d)$

여기서, d 는 예측일을 나타낸다.

신경회로망은 입력값 x 와 목표값 o 로 나타낼 수 있다. 여기서 모든 입력값과 목표값은 스케일링이 되어진다. 신경회로망은 앞에서 설명한 방법처럼 출력값과 목표값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위 층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해 나간다. 식으로 표현하면 다음과 같다. [7]

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

여기서 W_{ij} ($i = 1, \dots, n$, $j = 1, \dots, 5$)는 입력 노드와 은닉 노드 사이의 연결 가중치 벡터이고 θ 는 은닉층의 바이어스를 나타낸다. 그리고 x_j ($j = 1, \dots, 5$)는 입력 요소이다. y_i 는 은닉층의 시그모이드의 전달함수의 입력값으로 대입된다.

$$F(y_i) = \frac{1}{1 + \exp(-y_i)} \quad (2)$$

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

$$o = \sum_{i=1}^n W_i F(y_i) \quad (3)$$

은닉층의 개수의 경우 T. M. Peng의 논문[7]을 참고하였다. 본 논문의 신경회로망 구조가 [7]의 논문을 참고하고 있으므로 이를 적용함이 최적으로 생각하였다. 참고 논문 [7]은 은닉층의 개수를 6, 8, 10, 12개로 케이스를 구성하여 시뮬레이션하였다. 그 중에서 8개의 은닉층을 갖는 구조가 가장 좋은 정확도를 보이므로 이를 본 논문도 똑같이 사용하였다.

신경회로망의 수학적인 학습 절차는 목표값과 출력값 사이의 오차를 줄이는 방향으로 반복 계산된다. 오차식은 다음과 같다.

$$E = \frac{1}{2} \sum_{k=1}^K (o^{(k)} - \hat{o}^{(k)})^2 \quad (4)$$

여기서 K 는 학습 케이스 수이며, $o^{(k)}$ 는 학습 케이스 k 의 실제 출력값, 그리고 $\hat{o}^{(k)}$ 는 신경회로망의 목표값이다. 범위는 10^{-4} 이며 오차의 값이 이 범위 안에 들면 학습을 종료한다. 만약 학습 과정에서 오차가 오차 범위 안에 들지 않으면 10^5 만큼 반복하며 학습하고 종료하게 된다.

오차 역전파 알고리즘에 의해 아래와 같이 역 방향으로

연결 가중치 값이 바뀌게 된다.

$$T_{p+1} = T_p - \alpha \frac{\partial E}{\partial T_p}, \quad T = \{w_j, W_i, \theta_i\} \\ (i=1, \dots, n; j=1, \dots, 5) \quad (5)$$

여기서, p 는 반복 횟수, α 는 학습률로 0.01값을 사용하였다. 그리고 $\frac{\partial E}{\partial T_p}$ 는 앞에서 자세히 설명하였듯이 오차제곱 E 에 대한 웨이트 T 의 편미분 값이다.

3.2 입력값 선정과 크기 조절

I. Drezga의 논문[13]에서 입력값은 500개의 입력 변수를 사용하는 경우에서부터 과거의 수요만을 사용하여 예측하는 다양한 경우를 갖는다. Drezga의 논문[13]에서는 신경회로망의 입력변수 선택을 위해 부하 시계열의 Phase-space embedding을 기본으로 사용하여 입력을 선정하였다. 그 결과 수요, 온도, 시간별 주기값이 필수 입력값으로 선정되었다. 이는 수학적으로도 필수 입력값만으로도 정확한 수요 예측을 이를 수 있음을 증명한다. 또한 최소 구조 신경회로망을 통해 단기 전력 수요예측이 가능함을 보이는 것이다.

우리는 이 값 중 시간별 주기는 이미 평일, 토, 일, 월로 4개의 수요 패턴으로 나누어져 있음으로 입력값에서 제외하였다. 본 논문에서는 필수 입력값으로 수요와 온도를 사용하여 예측하였다.

입력값의 요소인 수요와 온도는 그 범위가 다르기 때문에 학습 시에 수렴하지 않는 경우가 발생한다. 수요의 경우 양의 값을 가지며 그 크기도 천만kW 단위를 갖는다. 이에 반해 온도의 범위는 -10에서 40 정도의 값을 갖는다. 그러므로 목표값이 최대수요로 나와야 하기 때문에 원본 데이터를 사용하여 예측하는 경우 수렴이 안 되는 경우가 대부분이다. 이러한 문제를 피하기 위해 원본 데이터의 크기를 조절하는 것이 필요하다. 우리는 이를 위해 두가지 경우를 가지고 크기를 조절하여 보았다.

첫 번째 경우로 변수의 범위를 0에서 1사이의 값으로 정규화 한다. 과정은 다음과 같다.

$$x_{i,base} = \max(x_i^{(k)}), \quad k \in [1, 7], \quad (i=1, \dots, 5) \quad (6)$$

$$o_{base} = \max(o^{(k)}), \quad k \in [1, 7] \quad (7)$$

윗 식과 같이 각 학습 케이스의 값중 최대값을 찾는다.

$$x_{i,m}^{(k)} = x_i^{(k)} / x_{i,base}, \quad (i=1, \dots, 5), \quad (k=1, \dots, 7) \quad (8)$$

$$o_i^{(k)} = o^{(k)} / o_{base} \quad (9)$$

구한 최대값으로 각 k 의 값을 나누어 주었다.

두 번째 경우는 표준편차를 사용하여 크기를 조절하는 경우이다.

$$x_{i,m}^{(k)} = \frac{x_i^{(k)} - \bar{x}_i}{s_i} \quad (i=1, \dots, 5), \quad (k=1, \dots, 7) \quad (10)$$

$$o_{i,m}^{(k)} = \frac{o^{(k)} - \bar{o}}{s_o} \quad (11)$$

여기서 s_i ($i=1, \dots, 5$)는 $x_i^{(k)}$ 의 표준 편차 값이다. 그리고 s_o 는 $o^{(k)}$ 의 표준 편차 값이다. \bar{x}_i 와 \bar{o} 는 각각 입력값과 목표값의 ($k=1, \dots, 7$)의 평균값이다. 두 경우로 모두 예측을 하였다. 첫 번째 경우는 학습 과정에서 수렴하지 않고 일정값 이하로 오차가 줄어들지 않았다. 이에 반해 두 번째 경우는 반복회수 동안 오차 범위 안으로 오차값이 수렴하였다. 그러므로 두 번째 방법, 즉 입력값과 목표값의 크기 범위는 $(-C, C)$ 의 값을 갖는 경우로 선택하고 학습 전에 입력값과 목표값을 조절한 후 학습하였다.

3.3 학습 케이스 선정

신경회로망에서 학습 되어진 정보를 기초로 전력수요를 예측하게 된다. 일반적으로 단기 전력 수요는 주기적인 패턴이 반복되는 형태를 갖는다. 각 계절별 한주간의 수요를 정규화 하였을 때 거의 같은 패턴을 가지고 있음을 알 수 있다. 그러므로 우리는 우선 평일(화~금), 월, 토, 일 각 요일별로 학습 케이스를 분류하였다. 그리고 각 케이스별로 학습 케이스의 개수를 7개, 14개, 30개로 하여 신경회로망 알고리즘을 이용하여 예측하여 비교 하였다. 이와 같이 3가지로 나누어 예측한 이유는 학습 케이스의 개수에 따라 예측의 정확도가 얼마만큼 차이가 나는지 알기 위해서이다. 다음은 평일과 토, 일, 월의 경우 7개의 학습 케이스에 따른 학습케이스 선정을 표 2와 3에 제시하였다.

표 2 평일 예측을 위한 7일의 학습 케이스 선정

Table 2 Selection of 7-days training case for load forecasting of a weekday

일	월	화	수	목	금	토
20	21	22	23	24	25	26
27	28	29	30	1	2	3
4	5	6	7	8	9	10
11	12	13	14 (d-7)	15 (d-6)	16 (d-5)	17
18	19	20 (d-4)	21 (d-3)	22 (d-2)	23 (d-1)	24
25	26	27 (d예측일)	28	29	30	31

표 3 토, 일, 월 예측을 위한 7일의 학습 케이스 선정

Table 3 Selection of 7-days training case for load forecasting of Saturday, Sunday, and Monday

일	월	화	수	목	금	토
6 (d-7)	7	8	9	10	11	12
13 (d-6)	14	15	16	17	18	19
20 (d-5)	21	22	23	24	25	26
27 (d-4)	28	29	30	1	2	3
4 (d-3)	5	6	7	8	9	10
11 (d-2)	12	13	14	15	16	17
18 (d-1)	19	20	21	22	23	24
25 (d예측일)	26	27	28	29	30	31

토, 일, 월의 경우 학습 케이스의 데이터 수가 많으면 예측일과 참고가 되는 데이터가 너무 멀어 예측 정확도가 떨어질 수 있다. 또한 예측에 같은 계절을 사용하여 학습하면 예측 정확도가 좋으나 계절이 바뀌는 시기에는 데이터 수가 많으므로 인해 다른 계절의 데이터로 학습하게 된다. 또한 학습 케이스 선정 중 특수일이나 이벤트가 들어갈 경우 학습오차에 큰 영향을 끼치게 되므로 이를 제외한다. 본 논문은 학습 케이스를 3가지로 두었을 때 비교해 본 결과 7개의 학습 케이스의 경우, 수렴성 가장 좋았으며 오차도 정확하였다.

3.4 온도 민감도를 이용한 여름 수요 예측

단기 전력 수요 예측은 계절마다 예측 정확도가 다르다. 특히 여름은 냉방 부하 사용의 급증으로 온도에 따라 수요가 민감하게 변하게 된다. 이를 위해 본 논문에서는 여름기간 동안에 수요 예측의 정확성을 증가시키기 위하여 온도의 민감도를 도입하여 예측한 값을 신경회로망의 입력값으로 추가하여 사용한다.

여름기간동안에 수요예측의 정확성을 증가시키기 위하여 온도의 민감도를 도입하였다. 온도민감도를 고려한 상세한 예측과정은 다음과 같다.

ΔT (온도의 변화량)와 Δd (수요의 변화량)를 사용하여 온도민감도를 계산한다.

$$\Delta D = \frac{\Delta d}{\Delta T \times d_{\max}^{\text{before}}} \quad (12)$$

여기서, ΔD 는 온도 민감도이다.

7월과 8월 각각의 ΔD 의 값 중 양의 값과 음의 값을 갖는 것을 조사하고 양과 음 각각의 값들을 모두 합한 뒤 평균한다. 온도 민감도의 불량정보는 제거한다.

$$S_+ = \frac{1}{N} \sum_i^N \Delta D_+, \text{ 단 } \Delta T \geq 0$$

$$S_- = \frac{1}{N} \sum_i^N \Delta D_-, \text{ 단 } \Delta T < 0 \quad (13)$$

여기서, S_+ 와 S_- 는 온도민감도 ΔD 의 양의 값과 음의 값의 각각의 총합을 평균한 값이다. N 은 온도민감도 ΔD 의 양과 음의 관찰된 개수이다.

S_+ 와 S_- 를 이용하여 최대값을 예측한다.

$$F_{\max}^{WD} = F_{\max}^{before} + S_+ \times \Delta T \times F_{\max}^{before}, \text{ 단 } \Delta T \geq 0$$

$$F_{\max}^{WD} = F_{\max}^{before} + S_- \times \Delta T \times F_{\max}^{before}, \text{ 단 } \Delta T < 0 \quad (14)$$

여기서, F_{\max}^{WD} 는 예측일의 최대수요 예측값이고, F_{\max}^{before} 는 예측일 직전일의 최대수요 실제값이다. 온도민감도를 사용한 최대수요예측값은 (F_{\max}^{WD}) 신경회로망의 6번째 입력값으로 사용한다.

4. 사례 연구

신경회로망에 있어서 학습률 α 는 0.01로 고정하였고 은행총 안에 뉴런의 수는 8개로 하였다. 학습은 모든 학습 케이스를 통해 수행되며, 오차가 10^{-4} 범위 안에 들어가면 학습을 멈추도록 하였다. 오차범위 안에 수렴하지 않을 경우 10^5 만큼 학습한 뒤 수행을 멈추도록 하였다. 프로그램은 MATLAB으로 코딩했으며, 입력 데이터는 txt 파일 형식으로 입력되었다.

모든 예측값은 다음 식과 같이 절대값 평균오차를 가지고 비교 분석하였다.

$$\text{Error (\%)} = \frac{|o^{\text{Actual}} - o^{\text{forecast}}|}{o^{\text{Actual}}} \times 100 \quad (15)$$

여기서, o^{Actual} 은 예측일의 실측값이고 o^{forecast} 는 예측일의 예측값이다.

4.1 학습 케이스에 따른 결과 도출

신경회로망의 경우 학습 케이스의 수에 따라 예측 정확도가 다르게 나타난다. 너무 적은 학습 케이스를 선정할 경우 정확한 파라미터를 학습 시키지 못해 예측 정확도가 떨어지게 된다. 이에 반해 필요 이상으로 많은 학습 케이스를 선정하면 그 많은 케이스 중 불필요한 데이터가 들어가게 되며 이것이 또한 파라미터를 정확하게 학습 시키지 못하게 한다. 그러므로 적당한 학습 케이스의 수를 선정하는 것이 중요하다. 이를 위해, 봄과 여름의 2003년, 1996년 한 주 평일만을 학습 케이스의 개수 7개, 14개, 30개로 다르게 하여 예측하여 보았다.

표 4 학습 케이스에 따른 예측 오차 (%)

Table 4 Load forecasting errors(%) of training cases

날짜	7개 학습 케이스	14개 학습 케이스	30개 학습 케이스
평균	1.28	1.65	1.22

4주의 결과를 보면 30개의 경우 오차가 1.22%로 가장 낮게 나왔다. 다음으로 7개의 학습 케이스를 선정했을 경우 1.28%였고, 14개의 학습 케이스를 선정하였을 경우가 1.65%이었다.

결과적으로 30개의 학습 케이스가 7개의 학습 케이스를 사용한 것보다 약간 더 좋은 결과를 보여지만 그렇게 큰 차이가 없으므로 7개의 학습 케이스를 선정하여도 무방하다. 또한 30개의 학습 케이스와 14개의 학습 케이스를 사용하여 학습하는 경우는 정해진 반복횟수 안에서 오차범위 안에 들어가지 못하는 경우가 대부분이였다. 즉, 오차범위 안에 수렴하지 못하여 반복 횟수 10^5 을 다 반복하고 나오는 경우가 대부분이였다. 이는 데이터양이 많기 때문에 연결 강도의 변화량을 계속 주게 되어 오차가 줄어들지 못하고 반복하게 되는 것이다. 또한 이로 인해 계산 시간이 많이 걸린다는 단점을 가지고 있다. 하지만 7일의 경우 데이터가 적어 정해진 반복횟수 안에서 오차범위를 수렴하게 된다. 또한 빠르게 계산 결과를 도출한다. 30일 학습 케이스의 경우 초여

름의 경우를 예측한다고 하면 봄의 중순 데이터가 사용되기 때문에 부정확한 예측을 갖게 된다. 또한 14일의 경우는 7일보다 예측 정확도가 떨어지므로 학습 케이스로 선정하지 않았다. 그러므로 예측일에 가장 가까운 학습 케이스만으로 이루어진 7일 케이스가 가장 적절한 방법으로 사료된다. 그리하여 본 논문에서는 이 학습 케이스를 선정하였다.

4.2 계절별 입력값의 개수에 따른 결과 도출

신경회로망을 이용한 단기 전력수요예측 방법을 통하여 1996년을 봄, 여름, 가을로 한 주씩 평일을 선택하여 예측하여 보았다. 이를 비교하기 위하여 한국전력공사 전력연구원의 “탑다운 방식”을 통하여 예측한 예측값과 비교하여 정확도를 개선하였다. 그리고 각 계절마다 온도 민감도를 고려하여 예측한 예측값을 추가하여 6개의 입력값으로 신경회로망으로 학습한 후의 최종 결과값도 비교하여 개선된 예측의 정확도를 확인하였다. 봄, 여름, 가을 계절에 따라 보았을 때 온도에 영향을 받는 여름의 예측 오차가 가장 커다. 그리고 특이한 점은 봄과 가을의 경우 온도민감도를 고려한 예측값을 신경회로망의 입력값으로 추가하지 않고 5개의 입력값으로만 예측하였을 경우 더욱 좋은 예측결과를 보임을 알 수 있었다. 이는 봄과 가을과 같이 온도와 부하 사이의 상관관계가 적은 시기에 온도 민감도를 고려한 예측값을 추가하여도 신경회로망의 학습을 향상시키지 못함을 알 수 있다.

4.3 온도 민감도를 고려한 예측값 추가에 따른 결과 도출

이에 반해, 여름의 경우 온도 민감도를 고려한 예측값을 추가하였을 때 더욱 좋은 결과를 보였다. 여름은 온도와 부하 사이의 상관관계가 큼으로 이 값을 입력값에 추가하는 것은 예측의 정확도를 향상시키게 된다. 이에 대한 결과를 알아보기 위해, 2003년과 2002년의 7월부터 8월까지의 기간을 5개의 입력을 갖는 경우와 6개의 입력을 갖는 경우 두 가지로 예측하여 보았다.

7월과 8월 사이에 있는 제헌절, 광복절은 특수일로 예측 정확도를 떨어뜨린다. 그러므로 학습 케이스를 만들 때에 특수일 데이터는 제외하였다.

표 5 5개의 입력과 6개의 입력에 대한 평균 예측 오차

Table 5 Average load forecasting errors of 5 and 6 input values

	5개 입력	6개 입력
2003년도 여름 평균 오차	2.71	2.12
2002년도 여름 평균 오차	3.20	2.51
두 해의 평균 오차	2.96	2.31

예측 오차가 5개의 입력값을 가질 때 2.96%이고 6개의 입력값의 경우는 2.31%이었다. 이 결과로 여름의 경우 온도 민감도를 고려하여 예측한 값을 입력값에 추가시킴으로써 더 나은 결과를 보이는 것을 알 수 있다. 이는 온도민감도 안에 온도와 수요와의 상관관계를 나타내고 있으며 이를 입력으로 사용함으로써 더욱 정확한 예측이 이루어진다.

또한 살펴볼 것은 7월 마지막 주와 8월 첫째 주 기간은 일반적으로 휴가기간이다. 이 기간 동안은 예측 오차가 큰

것을 볼 수 있었다. 이는 산업체의 생산 활동 중단으로 인해 전력수요가 감소하기 때문이다. 휴가 기간과 같이 사회적인 이벤트를 고려한 예측에 대한 연구가 이루어져야 한다. 이를 위해서는 사회적인 이벤트별 지수개발이 필요하다고 할 수 있다.

4.4 1995년 3월, 8월, 12월 예측과 비교

결과를 더욱 자세히 알아보기 위해 1995년도 3월, 8월, 12월의 24시간별 예측을 한 후 예측 오차를 논문[2]와 비교하였다. 표 6에 24시간 평균오차를 표 7에 최대오차를 나타내었다.

표 6 1995년 3월, 8월, 12월의 24시간 평균 예측 오차

Table 6 Average forecasting errors(%) of the 24 hourly loads for March, August and December in 1995

예측 대상 일	3월		8월		12월		24시간 평균오차	
	제안된 알고리즘	논문[2]	제안된 알고리즘	논문[2]	제안된 알고리즘	논문[2]	제안된 알고리즘	논문[2]
평균	1.21	1.80		2.23	2.24		1.69	1.77

1995년 3월의 경우 논문[2]에 비해 24시간 평균오차는 1.21%로 약 0.59% 정도 정확도를 개선하였으며, 최대오차의 경우 2.76%로 약 0.81%정도 정확도가 개선되었다. 8월의 경우 논문[2]에 비해 24시간 평균오차는 2.23%로 크게 향상되지는 않았으나 최대오차의 경우 약 0.14%정도 정확도가 향상되었음을 볼 수 있다. 12월의 경우 논문[2]에 비해 24시간 오차는 1.69%로 약 0.08%정도 정확도가 향상되었으며 최대오차도 3.40%로 약 0.42%정도 정확도가 향상되었다.

예측 수요를 살펴보면, 일간마다 약간 차이는 있을 수 있으나 3월은 20시, 8월은 15시, 12월은 19시로 계절별로 수요 피크 시간이 다르게 나타난다. 이는 계절적으로 냉난방의 사용으로 인한 수요 변동이 원인이라 할 수 있으며, 심야부하 정책과 같은 수요관리 정책에 의해서도 변동될 수 있다.

특수일의 경우, 3월 1일(삼일절), 8월 15일(광복절), 12월 25일(성탄절)인 특수일은 각각 마다 수요 특징을 갖으나, 본 논문에서는 제안한 신경회로망 알고리즘이 특수일에 대한 고려가 없었음으로 퍼지선형회귀분석법을 사용하여 예측하였다. [28]

표 7 1995년 3월, 8월, 12월의 최대 예측 오차 비교

Table 7 Maximum errors(%) of forecasting for March, August and December in 1995

예측 대상 일	3월		8월		12월		최대오차	
	제안된 알고리즘	논문[2]						
평균	2.76	3.57		4.44	4.58		3.40	3.82

하지만 특수일 이전 날과 특수일 다음 날은 신경회로망을 이용하여 예측하였으며, 이 경우 특수일이 마치 일요일과 같은 효과를 주어 일반적인 평일 수요 패턴에 변동요인으로 작용하였다. 그리하여 특수일이 아니지만 예측 오차가 크게 나타남을 알 수 있다. 또한 토요일과 월요일이 특수일이 되면 연휴가 되어 수요패턴이 변동이 크게 된다. 이 기간에는 예측 정확도가 평소보다 떨어지게 된다. 이를 해결하기 위해서는 특수일 전후 일에 대한 학습케이스만을 만들어 평일에 대한 특수일 전후일의 변동량으로 학습하는 새로운 알고리즘의 개발이 필요하다 하겠다.

12월 30일과 31일의 경우, 연말연시와 신정의 영향으로 평소 수요 보다 낮은 것을 알 수 있다. 이는 연말연시가 사회적 이벤트로써 수요에 변동 요인으로 작용하기 때문이다. 한 해마다 발생하는 이벤트는 선거, 태풍, 연말연시 등이 있으며 이로 인해 전력 수요 예측 오차는 커지게 된다. 향후에 이벤트와 수요와의 상관관계를 조사하고 해결 방안을 연구하여 더욱 정확한 예측이 이루어져야 할 것이다.

5. 결 론

신경회로망은 비선형적인 특성을 갖는 전력 수요 패턴을 예측하는 매우 적합하다. 본 논문은 이러한 신경회로망의 특징을 살리고 입력값 설정과 학습 케이스 설정 등과 같이 예측 정확성에 영향을 주는 요인에 대해 과거 논문을 조사하고 평가하여 최소 신경회로망을 제안한다.

1995년 3월, 8월, 12월을 예측해 본 결과, 각각 24시간 평균 오차는 1.21%, 2.23%, 1.69%로 정확하였으며 최대오차 역시 2.76%, 4.44%, 3.40%로 정확하였다.

미래의 전력 산업구조는 전력시장구조로 변화될 것이다. 미래의 전력시장에서 전력수요예측은 시장운용자에게는 안정적이고 경제적인 시장 운영, 발전사와 수요자에게는 경쟁적인 시장에서의 입찰전략을 세우는데 중요한 정보를 제공한다. 본 알고리즘은 최소 구조를 사용하여 빠른 시간에 정확한 예측이 가능함으로써 미래의 전력시장에서 실시간 단기 전력수요 예측 데이터를 제공할 것이다.

향후에는 월드컵과 같은 사회적 이벤트가 전력 수요에 끼치는 영향을 고려한 단기 전력수요예측 알고리즘을 개발한다면 보다 정확한 미래의 수요를 예측할 수 있을 것이다.

감사의 글

본 연구는 송실대학교 교내연구비 지원으로 이루어졌음

참 고 문 헌

- [1] H. S. Hippert, C. E. Pedriera, and R. C. Souza, "Neural Networks for Short-term Load forecasting: A Review and Evaluation", IEEE Trans. Power Systems, vol. 16, no. 1, pp. 44-55, 2001.
- [2] 지평식, 남상천, 임재윤, 김정훈, "분류된 부하패턴을 근거로 한 단기 전력 수요 예측", 대한전기학회논문지, 제 47권, 제 3호, pp. 269-275, 1998년 3월
- [3] S. T. Chen, D. C. Yu, and A. R. Moghaddamjo, "Weather sensitive short-term load forecasting using nonfully connected artificial neural network," IEEE Trans. Power Systems, vol. 7, no. 3, pp. 1098-1105, 1992.
- [4] K. L. Ho, Y. Y. Hsu, and C. C. Yang, "Short-term load forecasting using a multilayer neural network with an adaptive learning algorithm," IEEE Trans. Power Systems, vol. 7, no. 1, pp. 141-149, 1992.
- [5] K. H. Kim, J. K. Park, K. J. Hwang, and S. H. Kim, "Implementation of hybrid short-term load forecasting in an autonomous power system using artificial neural networks," IEEE Trans. Power Systems, vol. 10, no. 3, pp. 1534-1539, 1995.
- [6] 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. Power Systems, vol. 6, no. 2, pp. 442-449, 1991.
- [7] T. M. Peng, N. F. Hubele, and G. G. Karady, "Advancement in the application of neural networks for short-term load forecasting," IEEE Trans. Power Systems, vol. 7, no. 1, pp. 250-257, 1992.
- [8] A. S. Alfuhaid, M. A. El-Sayed, and M. S. Mahmoud, "Cascaded artificial neural networks for short-term load forecasting," IEEE Trans. Power Systems, vol. 12, no. 4, pp. 1524-1529, 1997.
- [9] A. G. Bakirtzis, V. Petridis, S. J. Kiartzis, M. C. Alexiadis, and A. H. Maassis, "A neural network short term load forecasting model for the Greek power system," IEEE Trans. Power Systems, vol. 11, no. 2, pp. 858-863, 1996.
- [10] M. H. Choueiki, C. A. Mount-Campbell, and S. C. Ahalt, "Building a 'Quasi Optimal' neural network to solve the short-term load forecasting problem," IEEE Trans. Power Systems, vol. 12, no. 4, pp. 1432-1439, 1997.
- [11] M. H. Choueiki, C. A. Mount-Campbell, and S. C. Ahalt, "Implementing a weighted least squares procedure in training a neural network to solve the short-term load forecasting problem," IEEE Trans. Power Systems, vol. 12, no. 4, pp. 1689-1694, 1997.
- [12] T. W. S. Chow and C. T. Leung, "Neural network based short-term load forecasting using weather compensation," IEEE Trans. Power Systems, vol. 11, no. 4, pp. 1736-1742, 1996.
- [13] I. Drezga and S. Rahman, "Input variable selection for ANN-based short-term load forecasting," IEEE Trans. Power Systems, vol. 13, no. 4, pp. 1238-144, 1998.
- [14] A. Khotanzad, R. Afkhami-Rohani, T. L. Lu, A. Abaye, M. Davis, and D. J. Maratukulam, "ANNSTLF-A neural-network-based electric load forecasting system," IEEE T. Neural Nets., vol. 8, no. 4, pp. 835-846, 1997.
- [15] A. Khotanzad, R. Afkhami-Rohani, and D. Maratukulam, "ANNSTLF-Artificial neural network short-term load forecasting-Generation three," IEEE Trans. Power Systems, vol. 13, no. 4, pp. 1413-1422, 1998.
- [16] A. Khotanzad, R. C. Hwang, A. Abaye, and D. Maratukulam, "An adaptive modular artificial neural

- network hourly load forecaster and its implementation at electric utilities," IEEE Trans. Power Systems, vol. 10, no. 3, pp. 1716-1722, 1995.
- [17] S. J. Kiartzis, C. E. Zoumas, J. B. Theocharis, A. G. Bakirtzis, and V. Petridis, "Short-term load forecasting in an autonomous power system using artificial neural networks," IEEE Trans. Power systems, vol. 12, no. 4, pp. 1591-1596, 1997.
- [18] R. Lamedica, A. Prudenzi, M. Sforza, M. Caciotta, and V. O. Cencelli, "A neural network based technique for short-term forecasting of anomalous load periods," IEEE Trans. Power Systems, vol. 11, no. 4, pp. 1749-1756, 1996.
- [19] K. Y. Lee, Y. T. Cha, and J. H. Park, "Short-term load forecasting using an artificial neural network," IEEE Trans. Power Systems, vol. 7, no. 1, pp. 124-132, 1992.
- [20] C. N. Lu, H. T. Wu, and S. Vermuri, "Neural network based short term load forecasting," IEEE Trans. Power Systems, vol. 8, no. 1, pp. 336-342, 1993.
- [21] O. Mohammed, D. Park, R. Mercant, T. Dinh, C. Tong, A. Azeem, J. Farah, and C. Drake, "Practical experiences with an adaptive and neural network short-term load forecasting system," IEEE Trans. Power Systems, vol. 10, no. 1, pp. 254-265, 1995.
- [22] A. D. Papalexopoulos, S. Hao, and T. M. Peng, "And implementation of a neural network based load forecasting model for the EMS," IEEE Trans. Power Systems, vol. 9, no. 4, pp. 1956-1962, 1994.
- [23] A. Piras, A. Germond, B. Buchenel, K. Imhof, and Y. Jaccard, "Heterogeneous artificial neural network for short term electrical load forecasting," IEEE Trans. Power Systems, vol. 11, no. 1, pp. 397-402, 1996.
- [24] D. Srinivasan, A. C. Liew, and C. S. Chang, "Forecasting daily load curves using a hybrid fuzzy-neural approach," IEE Proc.-Gener. Transm. Distrib., vol. 141, no. 6, pp. 561-567, 1994.
- [25] K. Liu, S. Subbarayan, R. R. Shoultz, M. T. Manry, C. Kwan, F. L. Lewis, and J. Naccari, "Comparison of very short-term load forecasting techniques," IEEE Trans. Power Systems, vol. 11, no. 2, pp. 877-992, 1996.
- [26] 송경빈, 하성관, "단기수요예측 알고리즘", 대한전기학회논문지, 제 53A권, 제 10호, pp. 529-535, 2004년 10월
- [27] 전력수급계획 및 운용해석 종합시스템 개발에 관한 연구 (2차년도 중간보고서), 전력연구원, TM94YJ15.9705, 1996
- [28] K.-B. Song, Y.-S. Baek, D. H. Hong, and G. Jang, "Short-Term Load Forecasting for the Holidays Using Fuzzy Linear Regression Method", IEEE Transactions on Power Systems, Vol. 20, No. 1, pp. 96-101, February 2005.

저 자 소 개



하 성 관 (河 成 瑫)

1980년 4월 14일생. 2003년 숭실대 전기공학과 졸업. 2005년 동 대학원 전기공학과 졸업(석사). 2005년-현재 중부발전(주)



송 경 빈 (宋 敬 彬)

1963년 9월 15일생. 1986년 연세대학교 공과대학 전기공학과 졸업(공학사). 1988년 동 대학원 전기공학과 졸업(공학석사). 1995년 텍사스 A&M University 전기공학과 졸업(공박). 1996년 한전전력연구원 선임연구원. 2002년-현재 숭실대학교 전기제어시스템공학부 조교수.



김 흥 래 (金 鴻 來)

1963년 10월 9일생. 1986년 연세대학교 공과대학 전기공학과 졸업(공학사). 1989년 동 대학원 전기공학과 졸업(공학석사). 1995년 Texas A&M University 전기공학과 졸업(공학박사). 1995년~현재 순천향대학교 공과대학 전기전자공학부 부교수.