

기온변화에 의한 수요변동을 고려한 단기 전력수요예측 전문가시스템의 연구

김 광 호 · 이 철 희 *

A study on the short-term load forecasting expert system considering the load variations due to the change in temperature

Kwang-Ho Kim · Chul-Heui Lee*

ABSTRACT

In this paper, a short-term load forecasting expert system considering the load variation due to the change in temperature is presented. The change in temperature is an important load variation factor that varies the normal load pattern. The conventional load forecasting methods by artificial neural networks have used the technique where the temperature variables were included in the input neurons of artificial neural networks. However, simply adding the input units of temperature data may make the forecasting accuracy worse, since the accuracy of the load forecasting in this method depends on the accuracy of weather forecasting. In this paper, the fuzzy expert system that modifies the forecasted load using fuzzy rules representing the relations of load and temperature is presented and compared with a conventional load forecasting technique. In the test case of 1991, the proposed model provided a more accurate forecast than the conventional technique.

1. 서 론

최근 들어 전력 수요 예측이 전력사업에서 차지하는 중요성은 그 어느 때보다 커지고 있다. 발전설비는 그 특성상 즉각적인 전력의 공급이 불가능하고 필요로 하는 전력을 생산하는 데는 일정한 기동준비기간

이 요구된다. 따라서 효율적인 전력의 공급을 위해서는 단기적으로 향후의 전력 수요를 예측하여 이를 바탕으로 발전설비의 운전계획을 수립하여야 하는데 예측치가 공급시점의 전력수요보다 적었을 경우는 전력공급의 부족이 초래되어 제한송전이나 단가가 높은 전원을 통한 전력공급이 요구되어 경제적인 손실이 발생하고 또한 예측치가 공급시점의 전력수요보다 컸을 경우

강원대학교 전기공학과 전임강사

* 강원대학교 전기공학과 조교수

는 전력공급의 과다로 불필요한 발전설비의 운전에 따른 손실이 발생한다. 따라서 향후에 발생하게 될 전력의 수요를 보다 정확하게 예측하여 이에 맞는 전력을 공급하는 것이 필수적이다.

이러한 중요성 때문에 전력수요 예측분야에 있어서는 다양한 형태의 예측 모델이 제안되었고 현재 사용되고 있다.^[1, 2]

근래에 들어서는 전력수요에 있어서 상존 하는 불확실성 처리를 위해 인공지능 기법이 다수 도입되고 있으며, 특히 최근 들어 가장 주목을 받고 있는 것이 신경회로망을 이용한 전력 수요 예측으로서 지금까지 많은 연구 결과가 발표되고 있다^[3, 4]. 그러나 기존에 제안된 신경회로망을 이용한 단기 수요 예측 방법은 대부분이 과거의 전력수요치를 학습하여 이를 이용, 향후의 전력수요를 얻어내는 방식으로 수요변동의 가장 중요한 요인인 온도의 변화를 고려하지 않거나 신경회로망에 단순히 온도 변수를 추가하는 방식^[5]을 사용하고 있다. 그러나 후자의 방법에서는 기상 예측치의 오차가 전력수요 예측치의 정확성을 떨어뜨리는 원인을 제공하게 되어 예측 성능 면에서 단점을 갖게 된다.

이러한 기존 방법의 문제점을 해결하고자 본 논문에서는 1차적으로 신경회로망을 이용하여 일상적인 수요 패턴에 의한 전력수요 예측치를 얻어내고 일상적인 수요 패턴의 변동 요인으로 작용하는 온도변화를 퍼지 전문가 시스템에서 처리하여 보정하는 단기 전력 수요 예측 전문가시스템을 기술한다. 본 시스템에서는 온도에 의한 수요 변동을 퍼지 전문가 시스템에서 처리하여 기상 예측 오차의 영향을 최소화하고자 하였고 전문가의 경험이나 지식이 요구되는 수요 변동 요인에 대한 고려를 보다 효율적으로 수행하도록 하였다. 또한 온도 변수를 신경회로망에 직접 입력하여 수요를 예측하는 최근의 예측기법과 본 논문에서 제시된 방법과를 실제의 전력수요 실적

치에 대해 검증하고 그 예측 결과를 비교 기술한다.

2. 1차 전력수요 예측

온도의 변화와 같은 전력수요 변동요인이 없다면 평일의 전력수요곡선은 보통 그대로 유지가 된다. 주말의 수요곡선은 평일에 비해 낮은 전력수요치를 나타내지만 일반적으로 이전 주의 동일시간대의 전력수요 곡선과 유사한 형태를 갖기 때문에 일정한 패턴을 갖는 것은 평일과 마찬가지로이다. 따라서 변동요인을 제외시킨 전력수요 예측에는 신경회로망 기법이 유리하다. 본 시스템에서는 수요 변동요인에 대한 보정의 전 단계로 신경회로망을 이용하여 1차 전력수요 예측을 수행한다.

2.1 입출력 변수의 선정

본 논문에서는 일정 시점의 전력 수요치와 가장 상관 관계가 큰 해당 주의 동일시간대 (2시간 전까지)와 과거 주의 동일시간대의 전력수요치를 신경회로망의 입력 변수로 정하였고 과도한 입력 변수 선정을 피하기 위해 해당 주의 2일전까지와 과거 주의 2주전까지로 입력 유니트를 제한하였다. 표 1.에 입력유니트와 출력유니트에 할당된 변수를 정의하였다. 여기서 $p(i,t)$ 는 i 일, t 시간의 전력수요치를 나타낸다.

TABLE 1. Input and Output patterns

| | |
|-------|--|
| | $p(i,t-1), p(i,t-2)$ |
| 입력유니트 | $p(i-1,t), p(i-1,t-1), p(i-1,t-2),$ $p(i-2,t), p(i-2,t-1), p(i-2,t-2),$ $p(i-7,t), p(i-7,t-1), p(i-7,t-2),$ $p(i-14,t), p(i-14,t-1), p(i-14,t-2)$ |
| 출력유니트 | $p(i,t)$ |

따라서 본 논문에서 사용되는 신경회로망 모델은 입력유니트가 14개, 출력유니트가 1개로 구성되고 다수의 은닉 층을 갖는 다층형 신경회로망(Multilayer Feedforward

Neural Networks)을 사용한다. 학습 알고리즘으로는 오차 역전파 알고리즘(Error Backpropagation Algorithm)을 사용한다.

2.2 신경회로망 모델의 구조 선정

다층 신경회로망의 은닉층 및 은닉유니트 수를 결정하는 최적의 방법은 현재까지 존재하지 않는다. 따라서 과거의 실적 치에 대한 학습 및 예측 결과를 통해 신경회로망의 구조를 적절히 선정하는 것이 일반적이다. 1991년 3월에 대해 학습 및 예측을 수행한 결과에 의하면 1개의 은닉 층에 비해 2개의 은닉 층을 갖는 신경회로망의 예측결과가 우수하였으며 2개의 은닉 층의 경우 1층 은닉유니트의 수가 18개, 2층 은닉유니트의 수가 5개인 신경회로망이 가장 적은 예측오차를 나타내었다. 따라서 본 시스템에서는 1층 은닉유니트의 수가 18개, 2층 은닉유니트의 수가 5개인 다층 신경회로망을 사용한다. 표 2에 예측결과를 나타내었다.

TABLE 2. Simulation results for various artificial neural networks

| | | | |
|-------------|------|------|------|
| 1층 은닉유니트의 수 | 5 | | |
| 2층 은닉유니트의 수 | 1 | 3 | 5 |
| 평균 예측 오차(%) | 1.54 | 1.34 | 1.37 |
| 1층 은닉유니트의 수 | 18 | | |
| 2층 은닉유니트의 수 | 3 | 5 | 10 |
| 평균 예측 오차(%) | 1.35 | 1.30 | 1.59 |
| | 1.87 | | |

2.3 신경회로망을 이용한 1차 예측

위와 같이 선정된 신경회로망에 대해 매 예측 시점마다 과거의 전력수요치에서 얻어진 3개의 패턴을 이용하여 학습한 후 예측을 수행하여 온도변화에 대한 보정의 전 단계인 1차 전력수요 예측치를 얻어낸다.

3. 온도변화를 고려한 2차 전력수요 예측

신경회로망을 통해 1차 예측된 전력수요

는 주기적인 패턴에 변동을 주는 온도변화에 대한 보정이 필요하다. 규칙적인 패턴을 갖는 전력수요치는 변동요인의 개입 정도에 따라 변화하게 되므로 온도변화에 의한 수요변동치를 예측하여 이 값만큼 1차 수요예측치에 보정을 가하면 보다 정확한 수요예측을 수행할 수 있다. 본 시스템에서는 다음 (1)식과 같이 i 일, t 시간의 변동치(relative gap)를 정의하여 이를 기본으로 퍼지 전문가시스템에 있어서의 보정 작업을 수행한다.

$$\text{변동치}(i, t) = \frac{\text{수요실적치}(i, t) - 1\text{차수요예측치}(i, t)}{1\text{차수요예측치}} \times 100(\%) \quad (1)$$

(1)식을 이용하여 과거의 전력수요 실적치에 대한 시뮬레이션을 수행하고 여기서 얻어진 변동치와 온도변화와의 관계를 추출하여 이를 바탕으로 다음과 같은 퍼지 전문가시스템을 구축한다.

3.1 퍼지 전문가시스템의 구조

온도변화를 보정 하기 위해 본 논문에서는 3가지 학습패턴에 있어서의 출력 패턴에 해당하는 날들의 평균기온을 T 로 하고 예측 일의 일 평균기온과 T 와의 차이를 ΔT 로 하여 온도 변화에 대한 보정을 위한 룰 베이스를 구성한다. 이는 신경회로망이 학습한 전력수요치의 기온환경과 실제로 예측하는 시점의 기온환경과의 차이를 보정하기 위함이다. 따라서 예측 일의 일 평균예상기온이 $AvgT(i)$ 라고 하면, T 와 ΔT 는 다음 식과 같이 얻어진다.

$$T = \frac{1}{3}(AvgT(i-7) + AvgT(i-14) + AvgT(i-21)) \quad (2)$$

$$\Delta T = AvgT(i) - T \quad (3)$$

IF/THEN 룰에서 조건부는 온도 T와 온도변화 ΔT 로 구성되고 후건부는 변동치가 된다. 퍼지 변수 T, ΔT 와 변동치는 각각 NB(Negative Big), NM(Negative Medium), NS(Negative Small), ZE (Zero), PS(Positive Small), PM (Positive Medium), PB(Positive Big)의 7가지의 퍼지 집합을 갖는다.

T 와 ΔT 에 대해서는 그림 1~3 과 같이 삼각형의 멤버십 함수를 정의하였다. 정의된 멤버십 함수는 우리나라에서 발생하는 모든 범위의 온도가 각 퍼지 집합에 일정 간격으로 포함되도록 하였다. 변동치에 대한 퍼지 집합의 멤버십 함수는 Singleton으로 정의하였다.

온도와 전력 수요와의 관계와 1989년과 1990년의 예측 결과를 참조하여 표 3과 같은 퍼지 룰 베이스를 구성하였다.

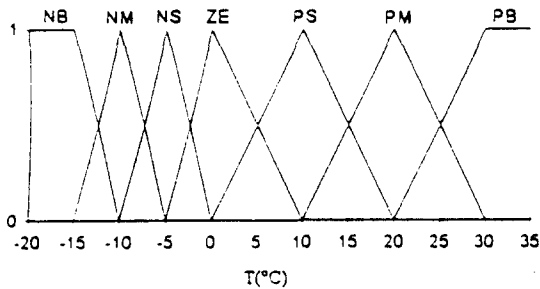


Fig. 1. Membership ftns. of T

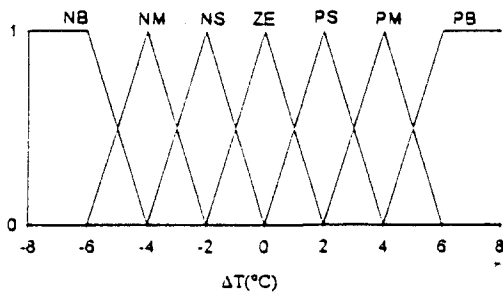


Fig. 2. Membership ftns. for ΔT




Fig. 3. Membership ftns. for relative gap

TABLE 3. Fuzzy rule base for modification

| T\ΔT | PB | PM | PS | ZE | NS | NM | NB |
|------|----|----|----|----|----|----|----|
| PB | PS | PS | PS | ZE | NS | NS | NM |
| PM | PM | PS | PS | ZE | ZE | ZE | NS |
| PS | NS | NS | ZE | ZE | ZE | PS | PM |
| ZE | NS | NS | ZE | ZE | ZE | PS | PS |
| NS | NS | ZE | ZE | ZE | ZE | ZE | PS |
| NM | ZE | ZE | ZE | ZE | ZE | ZE | ZE |
| NB | ZE | ZE | ZE | ZE | ZE | ZE | ZE |

각 행렬의 요소는 후건부의 변동치에 대한 퍼지 집합을 나타낸다. 예를 들어 T=PS & ΔT =PB 일 경우 이것을 IF/THEN 룰로 표현하면 "IF T = PS and ΔT = PB, THEN 변동치 = NS"와 같다. 일반적으로 온도변화에 따른 수요의 변동은 해마다 다소 달라지므로 실제 예측 환경 하에서는 과거 년도의 예측결과를 통해 룰 베이스의 계속적인 수정이 필요하다.

3.2 온도변화를 고려한 2차전력수요예측

위와 같이 구성된 퍼지 전문가시스템을 이용하여 기온변화에 따른 수요 변동을 예측하고 신경회로망으로 얻어진 1차 예측치에 보정을 가하여 최종 전력 수요 예측치를 구한다. 비퍼지화는 무게중심법^[??]을 사용한다.

따라서 i일, t시간에 대한 최종 수요 예측치는 식 (1)로부터 얻어진 식 (4)를 통해 구해진다.

$$\begin{aligned} \text{최종수요예측치}(i, t) = & 1\text{차수요예측치}(i, t) \\ & + \frac{\text{예측보정치}(i, t) \times 1\text{차수요예측치}(i, t)}{100} \end{aligned} \quad (4)$$

4. 사례연구

이상과 같이 구성된 전력수요 예측 전문가시스템을 사용하여 한국전력공사의 1991년 4월의 전력수요 실적치에 대해 1시간 전 전력수요 예측을 수행하였다. 1차 전력수요예측을 위해 사용된 신경회로망의 학습률과 관성률은 0.8과 0.6으로 고정하였고 2. 2절에서 기술한대로 1층 은닉유니트의 수는 18개, 2층 은닉유니트의 수는 5개로 설정하였다. 학습의 완료는 모든 학습패턴에 대한 출력오차가 2×10^{-4} 이하가 되는 시점으로 하였다. 온도 변화에 대한 보정을 수행할 경우, 실제로 예측시점의 일평균기온은 예측치가 입력되어야 하지만 예상기온치를 구할 수 없었기 때문에 실제의 일평균기온에 -2.0°C 에서 2.0°C 사이의 난수를 더한 가상의 일평균예측치로 대신하였다.

기술된 퍼지전문가시스템의 성능을 평가하기 위해 기존에 발표되었던 신경회로망 기법과 동일한 조건에서 얻어진 결과를 비교한다.

4.1 비교모델의 구조

비교의 대상이 된 신경회로망 모델은 최근에 제안된 Weather Sensitive Short-term Load Forecasting Model Using Nonfully Connected Artificial Neural Networks^[5]로 신경회로망의 형태를 온도에 민감하게 반응하도록 구성한 것이다.

비교모델은 입력층, 은닉층, 출력층의 총 3계층으로 구성되는 다층 신경회로망으로 구현되고 은닉유니트의 갯수를 10개로 고정하였다. 입력유니트에 입력되는 변수는 예측일의 평균기온, 예측일 하루전의 평균

기온, 예측일 이틀전의 평균기온, 예측시간의 1시간 전, 2시간 전, 3시간 전의 기온을 포함하는 온도관련 6개, 요일 구분용 7개, 시간 구분용 5개, 전력수요치 관련 12개, Bias 유니트용 1개로 구성되어 입력층은 총 31개의 유니트를 갖는다. 출력층은 1시간후의 전력수요치를 출력하는 1개의 유니트를 갖는다.

4.2 비교 결과

1991년 4월에 대해 비교 모델과 본 논문에서 제시된 전문가시스템을 동일한 조건하에서 1시간 전 전력수요예측을 수행하였다. 비교 모델의 학습을 위해서 1차 전력수요예측에서 사용되는 신경회로망과 동일한 파라미터를 사용하였다.

표 4에 예측 결과를 나타내었다. 결과에

TABLE 4. Test Results

| | 제안 시스템 | 비교 모델 |
|---------|--------|-------|
| 예측오차(%) | 1.72 | 3.13 |

서 보는 것과 같이 온도변화를 신경회로망에서 처리하는 것에 비해 본 논문에서 기술된 방식대로 퍼지전문가시스템에서 보정하는 것이 보다 정확한 예측결과를 얻어낼 수 있다.




Fig. 4. Test Results (April 8~14, 1991)

이와 같이 온도변수를 입력유닛에 직접 인가하는 방법은 기상예측오차가 신경회로망에 직접 영향을 미치기 때문에 오히려 전력수요예측의 정확성을 떨어뜨릴 가능성이 있다고 보여진다. 기상예측의 부정확에서 오는 영향을 피하기 위해서는 퍼지전문가시스템에서와 같이 온도 및 온도변화에 의한 수요변동을 간접적으로 처리하는 모델이 유리하다고 할 수 있다.

5. 결 론

본 논문에서는 온도변화에 의해 일상적인 수요 패턴이 변동하는 정도를 퍼지전문가 시스템에서 예측하여 보정하는 단기 전력수요예측 전문가시스템을 기술하였다.

퍼지전문가시스템의 성능을 평가하기 위해 온도변화에 의한 수요변동을 신경회로망에서 처리하는 기존의 기법과 동일한 조건 하에서 비교 검증을 수행하였다. 비교결과 온도변화를 신경회로망에서 처리하는 것에 비해 본 논문에서 기술된 방식 데로 퍼지전문가시스템에서 보정하는 것이 보다 정확한 예측결과를 얻어냄을 볼 수가 있다. 본 논문에서 기술된 퍼지전문가시스템은 온도의 변화에 의한 수요 변동에 대해 과거의 경향과 경험을 룰 베이스화 하여 보정을 하기 때문에 기존의 방법에 비해 기상 예측 오차에 의한 영향을 줄일 수가 있고 예측을 진행하면서 얻어진 근사적인 수요변동 경향을 고려하여 룰의 변경 및 갱신을 용이하게 할 수 있기 때문에 전력수요 예측의 정확도를 더욱 향상시킬 수 있게 된다.

참 고 문 헌

- [1] IEEE Committee Report, "Load Forecasting Bibliography Phase I," *IEEE Trans. on Power Apparatus and Systems*, vol. PAS-99, pp. 53-58, 1980
- [2] G.Gross, F.D.Galiana, "Short-Term Load Forecasting," *Proceedings of IEEE*, vol.75, no.12, pp. 1558-1573, Dec. 1987
- [3] D.C.Park, M.A.El-Sharkawi, R.J.Mark II, "Electric Load Forecasting Using An Artificial Neural Network," *IEEE Trans. on Power Systems*, vol.6, no.2, pp.442-449, May 1991
- [4] K.Y.Lee, Y.T.Cha, J.H.Park, "Short-Term Load Forecasting Using An Artificial Neural Network," *IEEE Trans. on Power Systems*, vol.7, no.1, pp.124-132, Feb. 1992
- [5] S.T.Chen, D.C.Yu, A.R.Moghaddamjo, "Weather Sensitive Short-Term Load Forecasting Using Nonfully Connected Artificial Neural Network," *IEEE Trans. on Power Systems*, vol.7, no.3, pp.1098-1105, Aug. 1992
- [6] 김 광호, 박 종근, 황 갑주, "신경회로망과 퍼지전문가시스템을 적용한 하이브리드형 단기 전력수요 예측모델," 대한전기학회논문지, 43권 12호, pp.2002-2009, 1994년
- [7] K.H.Kim, J.K.Park, K.J.Hwang, S.H.Kim, "Implementation of Hybrid Short-term Load Forecasting System Using A.N.N. and Fuzzy Expert

Systems," *IEEE Trans. on Power Systems*, Vol.10, No.3, pp.1534-1539, Aug. 1995

- [8] J.L.McClelland, D.E.Rumelhart, *Parallel Distributed Processing*, vol 1, MIT Press, 1986.
- [9] G.J.Klir, T.A.Folger, *Fuzzy Sets, Uncertainty and Information*, Prentice Hall, 1988.
- [10] B.Kosko, *Neural Networks and Fuzzy Systems*, Prentice Hall, 1992