

신경망과 퍼지시스템을 이용한 일별 최대전력부하 예측

Daily Peak Electric Load Forecasting Using Neural Network and Fuzzy System

방영근* · 김재현** · 이철희*

(Young-Keun Bang · Jae-Hyoun Kim · Chul-Heui Lee)

Abstract - For efficient operating strategy of electric power system, forecasting of daily peak electric load is an important but difficult problem. Therefore a daily peak electric load forecasting system using a neural network and fuzzy system is presented in this paper. First, original peak load data is interpolated in order to overcome the shortage of data for effective prediction. Next, the prediction of peak load using these interpolated data as input is performed in parallel by a neural network predictor and a fuzzy predictor. The neural network predictor shows better performance at drastic change of peak load, while the fuzzy predictor yields better prediction results in gradual changes. Finally, the superior one of two predictors is selected by the rules based on rough sets at every prediction time. To verify the effectiveness of the proposed method, the computer simulation is performed on peak load data in 2015 provided by KPX.

Key Words : Peak load forecasting, Preprocessing by interpolation, Fuzzy Inference system, Neural Network, Rough set

1. 서론

전력에너지 수요는 급진적인 산업 발전과 경제 성장으로 인해 지속적으로 증가하고 있을 뿐만 아니라 수요 패턴도 더욱 복잡한 형태를 보이고 있다. 따라서 안정적인 전력 수급과 전력 시스템의 최적 운용을 위해 보다 정확도 높은 부하 수요 예측의 필요성이 커지고 있다[1].

일반적으로 단기 부하 예측은 주로 하루의 부하 패턴을 예측하는 데 초점이 맞추어져 있었지만 최대 부하 예측의 정확도를 향상시키는 문제가 새로운 관심의 대상이 되고 있다. 왜냐하면, 2011년 9월 우리나라 최초로 대정전이 발생했고, 2014년 최대 부하 수량 급증으로 대정전의 위기를 겪는 등의 사건으로 인해 전력 사용량이 급증하는 여름에 전력 예비율 확보와 안정적인 전력 시스템 운용을 위해 정확한 최대 전력 부하 예측이 요구되고 있기 때문이다.

전력 부하 예측에 주로 사용되는 방법들은 먼저, 통계적 수학적 모델에 기반한 선형 회귀 분석 기법들이 널리 사용되지만 수학적 모델 구현의 어려움이나 비선형성이 큰 데이터의 예측에 부정확성을 초래한다. 다음으로 지능형 시스템 기반의 모델들은 불확실성과 비선형성이 큰 부하에 대해서도 비교적 정확한 예측이 가능

하지만, 예측 결과에 대한 이유 설명이 어렵고, 학습 과정이 매우 복잡하기 때문에 모델을 구현하는데 있어 오랜 시간과 투자를 요구한다[2~5].

이들 중 신경망은 부하 수요에 영향을 미치는 다양한 변인들을 동시에 수용하는 비수학적 모델을 간편하게 수립할 수 있고 데이터에 대한 학습 능력이 우수한 장점으로 인해 단기 부하 예측에 많이 활용되었다. 또한 신경망을 퍼지 시스템과 결합한 뉴로퍼지 모델을 이용한 부하 예측에 관한 연구들도 이루어졌다[2,3]. 한편 퍼지 시스템을 이용한 부하 예측에 관한 연구들도 이루어졌으나 날씨 등의 특수 변인들의 영향을 퍼지 규칙에 적절히 수용하기 어려운 단점으로 인해 단기 부하 예측에는 제한적인 연구만 이루어졌다. 하지만 데이터의 전처리 과정을 도입하거나 오차 보상 메커니즘을 도입하여 신경망을 이용한 예측보다 우수한 성능을 제시한 연구 결과도 있다[4,5]. 최근에는 신경망이나 퍼지 시스템에 유전 알고리즘이나 러프 집합을 결합한 연구도 시도되고 있다[6,7,8].

본 논문에서는 최근 주요 이슈가 되고 있는 최대 전력 부하 예측과 관련하여 신경망과 퍼지 시스템의 병렬 결합형 예측 시스템을 제안하였다. 제안된 시스템은 독립된 각각의 시스템 학습률을 향상하기 위해 선형 보간과 퍼지 예측기를 이용한 전처리 과정을 도입함으로써 충분한 데이터 양이 확보되도록 하였다. 또한 데이터 특성에 따라 상반된 예측 성능을 보이일 수 있는 신경망 예측기와 퍼지 예측기를 러프 집합[9]을 이용하여 매 예측 순간마다 데이터 특성에 더 적합한 예측기를 선택하도록 하여 각각의 예측기를 효과적으로 운영할 수 있도록 하였으며, 제안된 시스템의 성능과 유효성을 검증하기 위하여 우리나라 2015년 여름의 최대 전력 부하 데이터에 대한 시뮬레이션을 수행하고 분석하였다.

* Corresponding Author : Dept. of Electrical and Electronic Engineering, Kangwon National University, Korea.
E-mail: chlee@kangwon.ac.kr

* Dept. of Electrical Engineering, Kangwon National University, Korea.

** Dept. of Electrical and Electronic Engineering, Kangwon National University, Korea.

Received : July 25, 2017; Accepted : November 15, 2017

2. 제안된 최대 전력 부하 예측 시스템의 구조

제안된 시스템은 그림 1과 같이 보간에 의한 데이터 전처리, 신경망 예측기와 퍼지 예측기를 이용한 최대 부하의 병렬 예측, 러프 집합을 이용한 최적 예측 모델 선택의 세 단계로 구성된다. 1단계는 데이터의 전처리 과정으로, 2단계의 예측기의 성능을 향상시키기 위해 학습과 규칙 생성에 요구되는 충분한 데이터 양 확보를 목적으로 퍼지 시스템을 이용하여 데이터의 보간을 수행한다. 2단계에서는 신경망과 퍼지 시스템에 의한 예측기를 각각 설계하여 데이터 전처리에 의해 늘어난 양의 데이터를 입력으로 사용하여 최대 전력 부하를 병렬로 예측한다. 마지막으로 3단계에서는 2단계의 예측 결과를 바탕으로 러프집합을 이용하여 매 순간마다 예측 성능이 우수한 것으로 판단되는 예측기를 선택하여 최종적인 예측 결과를 산출한다. 이렇게 함으로써 불확실성과 비선형성이 심한 최대 부하 수요 패턴에 대해서도 정확도가 높은 예측이 이루어질 수 있도록 한다.

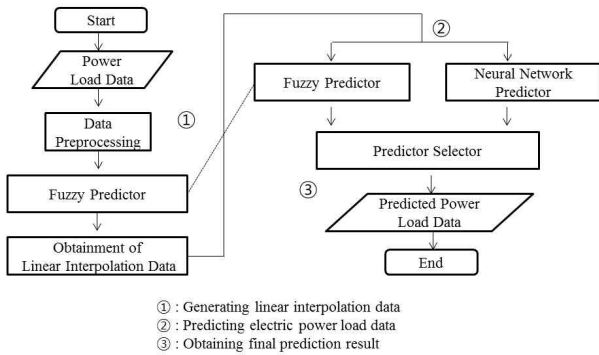


그림 1 제안된 퍼지 시스템의 구조
 Fig. 1 The Structure of the proposed fuzzy system

3. 보간에 의한 데이터 전처리

3.1 보간데이터의 선정

먼저 제안된 시스템을 설계하기 위해 선행되어야 할 부분이 보간데이터의 개수를 결정하는 부분이다. 보간데이터의 개수는 시스템의 학습을 위한 정보의 제공도 할 수 있지만, 늘어나는 데이터양으로 인해 시스템의 부담으로 작용할 수도 있다. 따라서 필요한 정보의 제공과 적절한 데이터양을 선정하는 것이 시스템의 부담이나 성능개선을 위해 요구되어진다. 이를 위해 본 논문에서는 주어진 전력 부하데이터의 초기 10개의 값을 자기 상관함수[5]를 이용하여 분석하였으며, 그림 2는 원형의 전력부하 데이터에 대하여 보간데이터의 수가 증가될 때의 자기상관함수의 변화를 보여준다.

그림 2의 자기 상관함수의 변화를 살펴보면 원형의 전력부하 데이터에 대한 자기 상관함수는 시차의 지연에 따라 급격히 변화하는 모습을 보여주고 있어 데이터 상호간 연관성이 떨어짐을 알 수 있다. 하지만 3개의 보간데이터 삽입 이후부터는 자기상관함

보간에 따른 자기 상관함수의 모양




그림 2 보간데이터에 따른 자기상관함수의 변화
 Fig. 2 Auto-correlation function corresponding to the number of interpolation data

수의 변화가 급격하지 않고 상관성 또한 높음을 보여주고 있다. 비록 4개의 보간데이터와 5개의 보간데이터를 삽입한 경우의 자기 상관함수 값들이 보다 높게 나타나지만, 보간 데이터의 양을 너무 증가시키면 그에 따른 시스템의 학습을 위한 데이터량도 증가하게 되어 시스템의 학습에 부담을 초래할 수 있으며, 또한 증가하는 보간데이터의 수만큼 시스템의 성능이 충분히 개선된다고 볼 수 없다. 따라서 본 논문에서는 비교적 자기상관함수의 변화가 완만하고 상관계수 값들도 비교적 높은 3개의 보간데이터를 삽입하여 제안된 시스템을 설계한다.

3.2 보간을 위한 퍼지 예측기 설계

최대 부하 예측을 위한 신경망 예측기와 퍼지 예측기의 회귀 모델에 대한 최적의 입력 길이가 3이며, 앞서 결정된 보간데이터의 수도 3으로 정의되었다. 하지만 보간데이터는 현재값과 미래값 사이의 값으로, 미래 값을 알 수 없을 경우 정의 할 수 없게 된다. 본 논문에서는 퍼지 예측기를 구현하여 보간 데이터를 예측 생성되도록 함으로써 이를 해결하였다. 퍼지 예측기로는 다음과 같은 형태의 퍼지 규칙으로 이루어진 TSK 모델을 이용하였다.

$$R^j : \text{if } s_1 \text{ is } F_1 \text{ and } s_2 \text{ is } F_2 \text{ and } s_3 \text{ is } F_3, \quad (1)$$

$$\text{then } y = a_0^j + a_1^j s_1 + a_2^j s_2 + a_3^j s_3$$

여기서 R^j 는 j 번째 퍼지 규칙을 의미하고, s 는 시스템 입력 값들, 그리고 F 는 각각의 입력이 만족하는 퍼지 집합을 의미한다. 또한 a^j 는 j 번째 퍼지 규칙에 대한 모수들로서 규칙을 만족하는 입력 데이터들로부터 추정되어진다.

식 (1)의 규칙을 생성하려면, 전건부의 퍼지 집합 F_j 를 결정하기 위한 입력 공간 분할과 후건부의 선형 출력 식의 계수 a_i 의 식별이 필요하다. 이때 사용할 입력 데이터, 즉 예측 보간이 이루어지기 전의 초기 보간 데이터는 다음과 같이 선형 보간으로 구한다.

$$m_p(t) = \frac{p}{4}(x(t) + x(t+1)), \quad p = 1, 2, 3 \quad (2)$$

여기서 m_p 는 원형의 전력 데이터 $x(t)$ 와 $x(t+1)$ 사이에서 삽입된

는 p 번째 보간데이터를 의미한다.

최대 부하 데이터가 $x(1), x(2), \dots, x(t), \dots, x(N)$ 이라면 (2)에 의해 보간된 부하 데이터의 구조는 다음과 같다.

$$x(1), m_1(1), m_2(1), m_3(1), x(2), m_1(2), m_2(2), m_3(2), \dots, x(N-1), m_1(N-1), m_2(N-1), m_3(N-1), x(N) \quad (3)$$

예측기 설계 모드에서 식 (1)의 입력 쌍은 $[s_1, s_2, s_3] = [m_1(t), m_2(t), m_3(t)]$ 이고, 출력은 $y = x(t+1)$ 이 된다. 각각의 입력 데이터 집합 $\{m_1(t)\}, \{m_2(t)\}, \{m_3(t)\}$ 에 대한 입력 공간 분할을 수행한 뒤에 같은 규칙으로 분류되는 데이터 집합에 대해 적절한 식별 기법을 적용하여 계수를 결정하면 보간을 위한 퍼지 예측기가 완성된다.

식 (1)의 전건부의 각 입력에 대한 퍼지 집합의 수는 규칙 기반이 최소화되도록 2개로 설정하였고 3차원 k-평균 군집화 알고리즘[5,6]을 이용하여 입력 공간을 분할하였다.

먼저 입력 $m_p(t)$ 에 대한 군집의 초기 중심을 $z_p^k(0), k=1, 2$ 라고 하면, 데이터의 평균값과 최솟값 및 최댓값을 이용하여 다음과 같이 선정한다.

$$\begin{aligned} z_p^1 &= \text{mean}[\min_{t=1:N} m_p(t), \text{mean}_{t=1:N} m_p(t)] \\ z_p^2 &= \text{mean}[\max_{t=1:N} m_p(t), \text{mean}_{t=1:N} m_p(t)] \end{aligned} \quad (4)$$

여기서 z_p^1 는 p 번째 보간데이터들로 구성된 입력군에서 첫 번째 군집의 중심, z_p^2 는 두 번째 군집의 중심을 의미한다.




그림 3 입력에 대한 퍼지집합

Fig. 3 Fuzzy sets for the input data

이후 $m_p(t)$ 의 $z_p^k(0)$ 에 대한 유클리드 거리(Euclidean distance) $|m_p(t) - z_p^k(0)|$ 를 계산하여 그 거리가 짧은 군집에 속하는 것으로 분류한다. 3개의 입력 $m_p(t)$ 각각에 대해 N 개의 모든 데이터에 대한 분류가 끝나면, 각 군집의 새로운 중심은 같은 군집으로 분류된 데이터들의 평균값으로 갱신되며, 이러한 갱신 과정은 K-평균 알고리즘과 같은 방법으로 반복 수행된다. 또한, 각각의 입력들에 대한 소속정도 μ 를 그림 3과 같은 가우시안 소속함수를 갖는 2개의 퍼지 집합을 정의하였다.

퍼지 규칙 식 (1)의 3개의 입력에 대해 각 2개씩의 퍼지 집합이 정의되므로 가능한 퍼지 규칙의 수는 8개가 된다. 하나의 규칙은 여러 개의 입력쌍이 만족할 수 있으므로 후건부의 파라미터는 이들을 이용하여 추정된다. 예를 들어, j 번째 규칙 R^j 를 만족

하는 입력 쌍 $[s_1^j, s_2^j, s_3^j]$ 이 n 개라면, R^j 의 후건부에 대해 다음의 등식이 성립된다.

$$\begin{aligned} \begin{bmatrix} y^j(1) \\ y^j(2) \\ \vdots \\ y^j(n) \end{bmatrix} &= \begin{bmatrix} 1 & s_1^j(1) & s_2^j(1) & s_3^j(1) \\ 1 & s_1^j(2) & s_2^j(2) & s_3^j(2) \\ \vdots & \vdots & \vdots & \vdots \\ 1 & s_1^j(n) & s_2^j(n) & s_3^j(n) \end{bmatrix} \begin{bmatrix} a_0^j \\ a_1^j \\ a_2^j \\ a_3^j \end{bmatrix} \\ Y_j &= D_j A_j \end{aligned} \quad (5)$$

여기서 Y_j 는 j 번째 퍼지 규칙에 대한 국부 출력들의 행렬이고, D_j 는 이때 규칙을 만족하는 입력들에 대한 행렬, 그리고 A_j 는 추정되어야 할 모수들의 행렬을 의미한다.

최소자승법을 적용하면 TSK 퍼지 규칙 후건부의 모수는 다음과 같이 추정된다.

$$\hat{A}_j = (D_j^T D_j)^{-1} D_j^T Y_j \quad (6)$$

3.3 퍼지 예측기를 이용한 보간 입력 데이터 생성

퍼지 예측기 설계 모드에서 사용되는 훈련 데이터에 대해서는 예측해야 할 참값을 이미 알고 있으므로 식 (2)의 선형 보간을 이용하여 보간 데이터를 생성하는 것이 가능하지만, 실제 예측 모드에서는 t 순간에서 $x(t+1)$ 를 알 수가 없으므로 불가능하다. 따라서 설계된 퍼지 예측기를 이용하여 보간 데이터 값을 예측하여야 한다.

t 시점의 원 데이터 $x(t)$ 와 보간 데이터 예측값 $\hat{m}_1(t-1), \hat{m}_2(t-1), \hat{m}_3(t-1)$ 는 알고 있으므로, 퍼지 예측기의 입력 쌍으로 $[\hat{m}_2(t-1), \hat{m}_3(t-1), x(t)]$ 을 이용하여 $\hat{m}_1(t)$ 를 구한다. 그런 다음 입력 쌍 $[\hat{m}_3(t-1), x(t), \hat{m}_1(t)]$ 을 이용하여 $\hat{m}_2(t)$ 를 구하고 마지막으로 $[x(t), \hat{m}_1(t), \hat{m}_2(t)]$ 에 의해 $\hat{m}_3(t)$ 를 얻어 $x(t+1)$ 을 예측하기 위한 입력으로 사용될 보간 데이터 쌍 $[\hat{m}_1(t), \hat{m}_2(t), \hat{m}_3(t)]$ 를 생성한다.

식 (1)의 j 번째 규칙 R^j 에 대한 입력 쌍 $[s_1, s_2, s_3]$ 의 점화강도(적합도)는 다음과 같이 정의된다.

$$f^j = \min \{ \mu^j(s_1), \mu^j(s_2), \mu^j(s_3) \} \quad (7)$$

여기서 f^j 는 j 번째 퍼지 규칙이 점화되는 점화강도를 의미하고 μ^j 는 각 입력이 j 번째 퍼지 규칙에서 각각에 상응하는 퍼지 집합을 만족하는 소속함수를 의미한다.

입력 쌍에 대한 퍼지 예측기의 출력은 다음과 같이 각 규칙에서 결정된 예측 출력값의 가중합으로 주어진다.

$$\hat{y} = \frac{\sum_{j=1}^8 f^j \hat{y}^j}{\sum_{j=1}^8 f^j} \quad (8)$$

여기서 \hat{y} 는 예측기의 출력을 의미하고 \hat{y}^j 는 j 번째 규칙의 국부

출력을 의미한다.

4. 신경망과 퍼지 시스템에 의한 병렬 예측기 구축

본 논문은 퍼지 예측기와 신경망 예측기의 병렬 구조로 구성되며, 퍼지 예측기는 앞서 보간 데이터 생성을 위해 설계된 예측기를 그대로 사용하였다.

반면, 신경망 예측기는 MATLAB 신경망 Tool Box의 시계열 분석 앱을 이용하였으며, 제공되는 3개의 예측기 모델 중, 최대 부하 데이터 예측에 적합한 구조의 NAR(Nonlinear Autoregressive) 모델을 선택하였다. 신경망 예측기의 구축에서 중요한 요소는 학습률, 은닉층 뉴런 수, 학습 방법의 선정으로[10], 학습률이 너무 크면 불안정해지고, 작으면 수렴하지 않기 때문에 작은 값에서 큰 값으로 점차 늘려가며 시뮬레이션하여 적절한 값인 0.9로 설정하였다. 은닉층의 뉴런 수는 데이터의 비선형성이 충분히 모형화될 수 있도록 입력층과 출력층 뉴런의 수보다 많게 2배수에서 시작하여 점점 증가시켜가며 시뮬레이션하여 적절한 값을 선정하였다. 신경망의 학습에는 Gauss-Newton 방법과 gradient descent 방법이 결합된 Levenberg-Marquardt 알고리즘을 채택하였다. 이 방법은 비선형 함수의 최적화에 널리 사용되는 방법으로, 구하고자 하는 최적해가 멀리 떨어져 있을 경우에는 gradient descent 방식으로 동작하고 최적해에 접근하면 Gauss-Newton 방식으로 동작한다[11].

5. 러프집합을 이용한 모델 선택

병렬로 구성된 신경망 예측기와 퍼지 예측기에 의해 각각 예측값이 산출되면, 이로부터 최종적인 출력을 결정해야 하며, 본 논문에서는 러프 집합을 이용하여 예측 성능이 더 우수한 예측기를 선택하도록 하였다. 러프 집합을 이용해 예측기 선택 규칙을 구하려면, 우선 조건부와 의사결정부의 속성 및 속성값을 정의해야 한다[9,12]. 조건부 속성으로는 예측기의 입력 데이터 쌍에 상응하는 3개의 속성을, 의사결정부 속성에는 퍼지 및 신경망 예측기의 예측 오차를 사용한다. 3개의 입력차원별 데이터들에 앞서 언급된 3차원 k-평균 군집화 기법을 이용하여 4개의 군집으로 분류하여 각 군집에 포함된 데이터들에 대하여 1~4로 속성값을 부여한다. 4개의 속성값을 부여하기 위해선 먼저 3개의 군집 중심을 구하고 이를 경계로 첫 번째 군집 중심 값보다 작은 범위에 포함된 데이터는 속성값이 1, 첫 번째 군집 중심과 두 번째 군집 중심 사이의 범위에 위치한 데이터들은 속성값을 2로, 두 번째 군집 중심과 세 번째 군집 중심 사이의 범위에 위치한 데이터들은 3의 속성 값, 마지막으로 세 번째 군집 중심 값보다 큰 범위에 위치한 데이터들은 속성값 4를 부여한다. 그리고 의사결정부 속성값은 예측 오차의 크기가 작은 예측기로 부여한다. 표 1은 실제 데이터의 일부 샘플에 대한 의사결정 표를 보여준다.

표 1을 살펴보면 규칙 5와 규칙 11은 같은 조건부 속성에 대하여 다른 의사결정을 보여주고 있다. 이런 비일관적인 규칙을

의사결정표에서 제거하고 선택되는 예측기의 종류에 맞춰 규칙을 재배열하여 정리하면 표 2와 같이 된다.

표 1 예측기 선택을 위한 의사결정표

Table 1 Decision table for selecting predictors

Attribute Rule	Conditional			Decisional
	$\hat{m}_1(t)$	$\hat{m}_2(t)$	$\hat{m}_3(t)$	Predictor
1	2	2	2	Fuzzy
2	1	3	2	Neural
3	3	2	1	Neural
4	3	4	4	Fuzzy
5	3	3	2	Fuzzy
6	4	2	3	Fuzzy
7	4	3	4	Fuzzy
8	3	4	3	Neural
9	3	3	1	Fuzzy
10	2	3	1	Neural
11	3	3	2	Neural

표 2 비일관적인 규칙을 제거한 의사결정표

Table 2 Decision table expressed by eliminating inconsistent rules

Attribute Rule	Conditional			Decisional
	$\hat{m}_1(t)$	$\hat{m}_2(t)$	$\hat{m}_3(t)$	Predictor
1	2	2	2	Fuzzy Predictor (FP)
2	3	3	2	
3	3	4	4	
4	3	3	1	
5	4	2	3	
6	1	3	2	Neural Network Predictor (NNP)
7	2	3	1	
8	3	2	1	
9	3	4	3	

표 2의 의사결정표에서 불필요한 속성을 제거하기 위해선 다음의 탐색 과정을 거친다. 먼저, 속성 $\hat{m}_1(t)$ 을 제거하면 2번과 6번 규칙이 비일관적인 규칙이 되므로 이 속성은 의사결정에 반드시 필요한 속성이다. $\hat{m}_2(t)$ 와 $\hat{m}_3(t)$ 에 대해서도 조사해보면 필요한 속성임을 알 수 있다. 다음으로는 각 규칙의 속성값들에 러프 집합의 하한 근사와 상한 근사를 이용하여 코어와 리덕트를 탐색하여 의사결정에 불필요한 속성값을 감축하여야 한다[9,12]. 예를 들어, 규칙 2에 대하여 상한 근사를 탐색하면

$$S(\bar{R}_2, \hat{m}_1(t)) = \{R_2, R_8, R_9\}, \quad S(\bar{R}_2, \hat{m}_2(t)) = \{R_2, R_6, R_7\}$$

$$S(\bar{R}_2, \hat{m}_3(t)) = \{R_2, R_6\}, \quad D(R_2) = \{R_1, R_2, R_3, R_4, R_5\} \quad (9)$$

여기서 $S(\bar{R}_2, \hat{m}_1(t))$ 은 $\hat{m}_1(t)$ 에 대하여 규칙 R_2 (2번 규칙)과 같은 속성 값을 가지는 규칙을 탐색하는 것을 의미한다. 또한 $D(R_2)$ 은 규칙 2과 동일한 의사 결정을 내리는 규칙들의 집합을 의미한다.

이러한 탐색 과정에서 중요한 것은 동일한 의사 결정을 내리는 규칙은 탐색하지 않고 다른 의사 결정을 내리는 규칙들에 대해서만 탐색을 수행하는 것이다.

다음으로 규칙 R_2 의 하한 근사는 다음과 같다

$$\begin{aligned}
 S_{12}(R_2) &= S(\bar{R}_2, \hat{m}_1(t)) \cap S(\bar{R}_2, \hat{m}_2(t)) = \{R_2\} \\
 S_{23}(R_2) &= S(\bar{R}_2, \hat{m}_2(t)) \cap S(\bar{R}_2, \hat{m}_3(t)) = \{R_2, R_6\} \\
 S_{13}(R_2) &= S(\bar{R}_2, \hat{m}_1(t)) \cap S(\bar{R}_2, \hat{m}_3(t)) = \{R_2\}
 \end{aligned}
 \tag{10}$$

$S_{23}(R_2)$ 는 의사결정 집합 $D(R_2)$ 의 부분집합이 되지 못하므로 의미가 없게 된다. 따라서 규칙 2의 경우에는 S_{12} 와 S_{13} 의 공통 값인 $\hat{m}_1(t)$ 이 코어 속성이 되고 나머지 속성인 $\hat{m}_2(t)$ 와 $\hat{m}_3(t)$ 는 리덕트 속성이 된다. 같은 방법으로 모든 규칙에 대하여 탐색하면 예측기 선택을 위한 최종 규칙은 표 3와 같이 간략화 된다.

표 3 예측기 선택을 위한 최종 의사결정표


Table 3 Final decision table for selecting predictors

Attribute \ Rule	Conditional			Decisional Predictor
	$\hat{m}_1(t)$	$\hat{m}_2(t)$	$\hat{m}_3(t)$	
1	2	2	2	Fuzzy Predictor (FP)
2		(3)	2	
3	3		(4)	
4	3	3		
5	4	2	3	
6	(1)		2	Neural Network Predictor (NNP)
7	(2)	3		
8	3	(2)		
9		4	(3)	

표 3에서 괄호로 표현된 속성이 각 규칙의 코어 속성이고 나머지는 리덕트 속성이며, 예측을 위한 입력 데이터쌍 $\hat{m}_1(t+1)$, $\hat{m}_2(t+1)$, $\hat{m}_3(t+1)$ 의 속성 값이 2, 3, 3으로 정의가 되었다면, 코어 속성을 만족하는 규칙은 3번과 7번 규칙이 되며, 이때 리덕트 속성까지 만족하는 규칙은 7번이 되므로 신경망 예측기가 이 입력을 위해 예측을 수행하게 된다는 것을 의미한다.

6. 시뮬레이션 및 검토

시스템의 성능 검증을 위해 2015년의 여름(6월~8월)의 최대 전력 부하 데이터를 이용하였다. 주말과 공휴일 등은 주중의 부하 패턴과 너무 다르므로 이를 제외하고 64개의 데이터 중, 훈련에 54개 및 검증에 10개의 데이터를 이용하였으며, 평가 지표로는 RMSE(Root Mean Square Error)와 MRE(Mean Relative Error)를 사용하였다[4,5]. 그림 4는 선형 보간된 데이터에 대해 3차원 k-평균 군집화 알고리즘을 이용하여 입력 공간을 분할하여 얻어진 퍼지 집합의 중심 이동을 보여준다. 반복 횟수 4에서 수렴하였으며, 데이터의 군집 분류가 더 명확해짐을 보여준다.



a) 초기 군집 모양 b) 4회 반복 후 군집 모양
a) Initial form of clusters b) after iterating 4 times

그림 4 3차원-k평균 군집화

Fig. 4 3D K-means clustering algorithm




그림 5 선형 보간데이터에 의한 예측 결과

Fig. 5 Prediction result for the linear interpolation data

그림 5는 설계된 퍼지 예측기를 이용하여 3.3절의 설명과 같이 식 (3)의 선형 보간 데이터를 예측한 결과로, 붉은 색은 원형의 전력부하 데이터, 파란색은 선형 보간데이터를 예측한 결과이다. 예측 데이터가 보간 데이터와 거의 동일한 패턴을 가지므로 병렬 예측기의 입력으로 활용하는데 문제가 없음을 보여주고 있다.

그림 6과 7은 각각 퍼지 예측기 및 신경망 예측기가 원형의 전력 부하 데이터에 대하여 예측을 수행한 결과를 보여준다. 두 예측기 모두 전반적으로 양호한 예측 결과를 보이고 있으나, 예측기들의 특징을 살펴보면 퍼지 예측기의 경우 그림 6에서 원으로 표시된 것처럼 변동이 적은 부하에 대한 예측 성능이 좋으며, 신경망 예측기의 경우 그림 7의 원으로 표시된 것처럼 변동이 큰 부하에 대하여 비교적 좋은 예측 성능을 보임을 알 수 있다. 그림 8은 러프 집합에 의해 데이터마다 최적 예측기 선택이 이루어진 최종 예측 결과를 보여준다. 그림 8을 살펴보면 원으로 표시된 부분처럼 각각의 예측기의 좋은 특성이 예측기 선택을 통해 최종 성능에 영향을 미쳤음을 알 수 있다. 또한 우측의 원으로 표시된 부분처럼 최종 검증데이터에 대한 예측 구간에도 두 예측기의 예측 성능이 반영되었음을 알 수 있으며, 원형의 전력 부하 데이터에 대하여 우수한 예측을 수행하였음을 알 수 있다. 그림 9는 특히 전력 예비율이 심각해질 수 있는 75,000[MWh] 이상의 큰 값에 대한 제안된 예측기의 성능을 보여주고 있으며, 75,000[MWh]이상의 전력 부하에 대해서도 예측 오차(MRE)가 0.5% 이하로 나타난다.

표 5는 제안된 시스템의 예측 성능에 대한 지표를 계산한 결과이다. 검증 구간에서 RMSE 지표는 신경망 예측기의 성능이 퍼




그림 6 퍼지예측기의 예측결과 (원형 데이터)
 Fig. 6 Prediction result of FP (Original data)




그림 7 신경망 예측기의 예측결과 (원형 데이터)
 Fig. 7 Prediction result of NNP (Original)




그림 8 제안된 시스템의 최종 출력
 Fig. 8 Final Prediction result of the proposed system



그림 9 75,000[MWh]이상의 전력부하에 대한 성능
 Fig. 9 Electric power load above 75,000[MWh]

표 5 제안된 예측 시스템의 성능 분석표

Table 5 Performance analysis table of the proposed prediction system

Index	Learning		Testing		
	Neural	Fuzzy	Neural	Fuzzy	Proposed
RMSE	47.71	48.77	36.33	39.31	34.15
MRE(%)	0.526	0.543	0.453	0.422	0.402

지 예측기의 성능보다 좋았으나 MRE 지표에서는 퍼지 예측기의 성능이 신경망 예측기의 성능 보다 좋게 나타났다. 러프 집합에 의한 최적 예측기 선택을 결합한 제안된 시스템의 성능 지표는 두 지표 모두에서 각각의 예측기를 단독으로 운영할 경우보다 상당히 개선되었음을 볼 수 있다. 그러므로 예측기 선택 기법이 유효하게 작용함을 알 수 있다.

2. 결 론

제안된 시스템은 보간에 의한 데이터 전처리, 신경망 예측기와 퍼지 예측기를 이용한 병렬 예측, 러프 집합을 이용한 최적 예측기 선택의 세 단계로 구성된다. 데이터 전처리에서는 예측 시스템 설계에 사용할 데이터 양의 부족을 극복하고 부하 패턴의 비선형성을 잘 반영한 예측 모델이 수립될 수 있도록 보간을 통해 신경망 예측기의 학습과 퍼지 예측기의 규칙 생성에 충분한 데이터를 확보할 수 있도록 하였다. 또한 일반적인 부하 패턴에 대한 예측 성능이 더 우수한 퍼지 예측기와 급격한 변화를 보이는 부하 패턴에 대해서 더 우수한 예측 성능을 보이는 신경망 예측기를 병렬로 구성하여 각각 최대 부하 예측을 수행한 뒤 러프 집합을 이용하여 입력 데이터의 속성에 의해 예측 성능이 더 좋을 것으로 추정되는 예측기를 선택하여 최종 예측 결과를 도출하도록 하였다. 이렇게 함으로써 퍼지 예측기나 신경망 예측기를 단독으로 운영하는 것보다 부하 패턴의 특성이 더 잘 반영될 수 있게 하여 예측 성능을 향상시켰다.

제안된 시스템의 유효성을 우리나라의 2015년 여름의 최대 전력 부하 데이터에 대해 시뮬레이션하여 검증하였다. 시뮬레이션 결과를 보면 제안된 시스템이 두 예측기를 단독으로 운영할 경우보다 우수한 예측 성능을 보이고, 특히 전력 예비율이 문제가 되는 부하 수요가 매우 큰 경우에 대해서도 0.5% 이하의 예측 오차를 나타내어 안정적인 전력 시스템 운용에 매우 유용하게 활용될 수 있음을 알 수 있다.

감사의 글

본 연구는 2015년도 강원대학교 대학회계 학술연구조성비로 연구하였음(과제번호-520150457)

References

- [1] Taylor, James W., and Roberto Buizza. "Neural network load forecasting with weather ensemble predictions." IEEE Trans. on Power Systems, Vol. 17, No. 3, (2002) : 626-632.
- [2] Hippert, Henrique Steinherz, Carlos Eduardo Pedreira, and Reinaldo Castro Souza. "Neural networks for short-term load forecasting: A review and evaluation." IEEE Trans. on Power Systems, Vol. 16, No. 1, (2001) : 44-55.
- [3] Park, Yong-Jin, and Bo-Hyeun Wang. "Neuro-Fuzzy Model based Electrical Load Forecasting System: Hourly, Daily, and Weekly Forecasting." Journal of Korean Institute of Intelligent Systems, Vol. 14, No. 5, (2004) : 533-538.
- [4] Y.K. Bang and C.H. Lee, IT2TSKFLS and HCBKA -Based Fuzzy Prediction System for Load Forecasting, 16th Int'l Conf. on Electrical Eng.(ICEE 2010), LF-01, Busan Korea, (2010).
- [5] Bang, Young-Keun, A Study on Design of Multiple Model Fuzzy Systems for Nonlinear Time Series Prediction, Ph.D. Dissertation, Dept. of Electrical and Electronic Engineering, Kangwon National Univ., Korea, 2010.
- [6] Bang, Young-Keun, and Jae-Sun Shim. "Electric Power Load Forecasting using Fuzzy Prediction System." The Transactions of The Korean Institute of Electrical Engineers, Vol. 62, No. 11, (2013) : 1590-1597.
- [7] Feng, Li, and Ziyang Liu. "Genetic algorithms and rough fuzzy neural network-based hybrid approach for short-term load forecasting." Power Engineering Society General Meeting, 2006. IEEE. IEEE, 2006.
- [8] Xiao, Zhi, et al. "BP neural network with rough set for short term load forecasting." Expert Systems with Applications Vol. 36, No. 1, (2009) : 273-279.
- [9] Jeung-Nam Byeon, Won-Chul Bang, Theory and Application of Rough Sets, CheongMoon, 2001.
- [10] Seul Jung, Artificial Intelligence System I : Structure and Usage of Neural Network, Chungnam National University, 2004.
- [11] Wilamowski, Bogdan M., and Hao Yu. "Improved computation for Levenberg-Marquardt training." IEEE Trans. on Neural Networks, Vol. 21, No. 6, (2010) : 930-937.
- [12] Y. S. Joo, Fuzzy System Modeling Using Genetic Algorithm and Rough Set Theory, M. S. Thesis, Dept. of Electrical and Electronic Engineering, Kangwon Univ., Korea, 2003.

저 자 소 개



방 영 근 (Young-Keun Bang)

1974년 4월 7일생. 2003년 강원대(삼척) 전기공학과 졸업(석사). 2010년 강원대(춘천) 전기전자공학과 졸업(박사)

E-mail: b2y2c1@hanmail.net



김 재 현 (Jae-Hyoun Kim)

1989년 4월 1일생. 2014년 강원대 전기전자공학과 졸업(학사). 2016년 강원대 전기전자공학과 졸업(석사)

E-mail: jae31142@naver.com



이 철 희 (Chul-Heui Lee)

1959년 7월 4일생. 1985년 서울대학교 전기공학과 졸업(석사). 1989년 서울대학교 전기공학과 졸업(박사). 현재 강원대학교 전기전자공학과 교수

E-mail: chlee@kangwon.ac.kr