

# An Electric Load Forecasting Scheme with High Time Resolution Based on Artificial Neural Network

Jinwoong Park<sup>†</sup> · Jihoon Moon<sup>†</sup> · Eenjun Hwang<sup>††</sup>

## ABSTRACT

With the recent development of smart grid industry, the necessity for efficient EMS(Energy Management System) has been increased. In particular, in order to reduce electric load and energy cost, sophisticated electric load forecasting and efficient smart grid operation strategy are required. In this paper, for more accurate electric load forecasting, we extend the data collected at demand time into high time resolution and construct an artificial neural network-based forecasting model appropriate for the high time resolution data. Furthermore, to improve the accuracy of electric load forecasting, time series data of sequence form are transformed into continuous data of two-dimensional space to solve that problem that machine learning methods cannot reflect the periodicity of time series data. In addition, to consider external factors such as temperature and humidity in accordance with the time resolution, we estimate their value at the time resolution using linear interpolation method. Finally, we apply the PCA(Principal Component Analysis) algorithm to the feature vector composed of external factors to remove data which have little correlation with the power data. Finally, we perform the evaluation of our model through 5-fold cross-validation. The results show that forecasting based on higher time resolution improve the accuracy and the best error rate of 3.71% was achieved at the 3-min resolution.

**Keywords :** Energy Management System, Smart Grid, Electric Load Forecasting, Artificial Neural Network

## 인공 신경망 기반의 고시간 해상도를 갖는 전력수요 예측기법

박진웅<sup>†</sup> · 문지훈<sup>†</sup> · 황인준<sup>††</sup>

## 요약

최근 스마트 그리드 산업의 발달과 더불어 효과적인 에너지 관리 시스템의 필요성이 커지고 있다. 특히, 전기 부하 및 에너지 요금 감소를 위해서는 정확한 전력수요 예측과 그에 따른 효과적인 스마트 그리드 운영 전략이 필요하다. 본 논문에서는 보다 정확한 전력수요 예측을 위하여, 수요 시간 기준으로 수집된 전력 사용 데이터를 고시간 해상도로 분할하고, 이에 적합한 인공 신경망 기반의 전력수요 예측 모델을 구축하고자 한다. 예측 모델의 정확도를 향상시키기 위하여 우선, 수열 형태의 시계열 데이터가 가지는 주기성을 제대로 반영하지 못하는 기계 학습 모델의 문제점을 해결하고자, 시계열 데이터를 2차원 공간의 연속적인 데이터로 변환한다. 더욱이, 고시간 해상도에 따른 온도나 습도 등 외부 요인들의 보다 정확한 반영을 위해 이들에 대해서도 선형 보간법을 사용하여 세분화된 시점에서의 값을 추정하여 반영한다. 마지막으로, 구성된 특성 벡터에 대해 주성분 분석 수행을 통하여 불필요한 외부 요인을 제거한다. 예측 모델의 성능을 평가하기 위해서 5겹 교차 검증을 수행하였다. 실험 결과 모든 고시간 해상도에서 성능 향상을 보였으며, 특히 3분 해상도의 경우 3.71%의 가장 낮은 오차율을 보였다.

**키워드 :** 에너지 관리 시스템, 스마트 그리드, 전력수요 예측, 인공 신경망

## 1. 서론

최근 기후 변화 등에 따른 에너지 부족에 대응하기 위해

서 에너지의 효율적인 관리를 위한 스마트 그리드가 주목받고 있으며, 특히 핵심 요소 중 하나인 에너지 관리 시스템(Energy Management System, EMS)에 대한 관심이 커지고 있다. EMS는 에너지 소비와 관련된 데이터의 수집 및 분석을 통하여, 수요 측면에서는 에너지 절감을 위한 방안을 모색하고, 공급 측면에서는 앞으로 사용될 에너지에 대한 예측을 바탕으로 발전 시스템의 효율적인 발전 스케줄링을 수행하여 에너지 관련 비용을 절감하고자 한다. 더욱이, 에너지 저장 시스템(Energy Storage System, ESS), 신재생

※ 본 연구는 산업통상자원부(MOTIE)와 한국에너지기술연구원(KETEP)의 지원을 받아 수행한 연구과제임(No. 20152010103060).

† 준회원: 고려대학교 전기전자공학과 석·박사통합과정

†† 종신회원: 고려대학교 전기전자공학과 교수

Manuscript Received: July 12, 2017

First Revision: August 22, 2017

Accepted: September 4, 2017

\* Corresponding Author: Eenjun Hwang(ehwang04@korea.ac.kr)

에너지, CHP (Combined Heating and Power) 등으로 구성된 연계형 전력망이 주목을 받으면서, 정확도 높은 전력수요 예측이 필수적으로 요구되고 있다.


현재 국내 전기 요금체계는 15분의 수요 시한으로 TOU (Time Of Use)와 CPP (Critical Peak Pricing)를 근거로 산출되기 때문에, 대부분의 전력수요 예측 연구는 수요 시한을 기준으로 진행되었다. 하지만 이러한 전력 예측 기반의 스마트 그리드 운영은 불필요한 에너지 생산 및 그에 따른 에너지 비효율을 야기할 수 있다. 보다 효율적인 스마트 그리드 운영을 위해서는 기존의 수요 시한보다 더 높은 시간 해상도(High Time Resolution)에서의 전력 사용량 예측이 필요하지만, 현실적으로 기존의 수요 시한보다 더 높은 시간 해상도를 가지는 데이터의 수집은 상당히 제한적이다. 따라서 본 논문에서는 효율적인 에너지 운영 전략을 수립하기 위해서 기존의 수집 데이터를 고시간 해상도의 데이터로 변환하고, 이를 기반으로 더 정확한 전력수요를 예측하는 기법을 제안하고자 한다.

전력수요 예측은 예측 기간을 기준으로 네 가지로 분류할 수 있다[1]. 1일 이하의 범위에 대한 예측은 VSTLF (Very Short-Term Load Forecasting)라고 하며, 1일부터 2주일 내의 범위에 대한 예측은 STLF (Short-Term Load Forecasting)라고 한다. 2주일부터 3년 내의 전력수요 예측은 MTLF (Mid-Term Load Forecasting)라고 하고, 3년 이상의 장기 예측은 LTLF (Long-Term Load Forecasting)라고 한다. 신재생 에너지 및 CHP 등이 연계된 스마트 그리드 운영은 피크 대응을 포함한 효율적인 스케줄링을 위해, 1일 이하의 예측인 VSTLF가 적합하다.


기존의 일간 예측에 관한 연구는 대부분 1시간 또는 대부분 국가의 수요 시한인 15분을 주기로 예측을 수행하였다 [2-5]. 스마트 그리드 일간 운영 스케줄링의 경우, 예측치를 기반으로 수행하므로 예측에 사용된 해상도로 운영된다. 따라서 수요 시한과 같은 주기로 이루어질 경우, 피크 대응은 가능하나 상황에 따라서 불필요한 에너지 사용이 발생할 수 있다. 예를 들면, 신재생 에너지나 CHP 등의 발전기가 연계된 전력망에서는 사용량보다 발전량이 더 많을 경우 발전된 전력이 전기 공급업체의 전력망으로 역전송 되는 경우가 발생한다. Fig. 1에서는 CHP가 연계된 전력망에서의 수요시한에 따른 스케줄링의 예를 보여주고 있다. (a)는 15분을 수요시한으로 두고 있으며, 첫 번째 주기에서 500kWh를 예측하여 총 200kWh의 발전 스케줄링을 적용할 때, 15분간 일정한 양을 발전한다. 이때, 5분 단위로 사용량을 본다면 12:45~12:50에서는 수요보다 발전량이 절반 이상이 되어 전력망으로의 역전송하여 손실이 발생한다. 그러나, (b)와 같이 5분 해상도로 예측 및 스케줄링을 할 경우, 전력수요가 적을 것으로 예측된 12:45~12:50에는 예측치의 절반 이하로 발전하고, 수요가 많은 12:50~13:00에 집중적인 발전을 하도록 하여 좀 더 효과적인 전력 관리를 할 수 있다. 결과적으로, 불필요한 발전 및 발전비용 감소에 대한 대비와 효율적인 스케줄링을 위해 수요시한보다 높은 시간 해상도에서의 예측 모델이 필요하다.

본 논문에서 제안하는 전력수요 예측 기법은 데이터의 분할, 전처리, 모델링으로 구성된다. HTR (High Time Resolution) 예측을 수행하기 위해서는, 기온을 기반으로 하여 15분 단위의 누적된 전력수요량을 5분 단위의 전력 사용량으로 분할한다. 이때 분할된 시점의 시계열 정보와 공휴일 여부, 기상정보 등 전력수요와 밀접한 관련을 가지는 다양한 변수를 고려한다. 다음으로 전처리 과정에서 주기성을 반영할 수 있도록 데이터의 유형을 변환하고, 주성분 분석(Principal Component Analysis, PCA)을 적용한다. 마지막으로, 정확한 전력수요 예측을 위해 다양한 분야에서 적용되고 있는 ANN (Artificial Neural Network) 기반의 예측 모델을 구성한다.

본 논문의 구성은 다음과 같다. 2장은 기계 학습의 기반을 둔 전력수요 예측과 이를 적용한 스마트 그리드의 운용 사례들을 살펴본다. 3장은 높은 고시간 해상도를 갖기 위해, 시계열에 따른 데이터의 분할과 이를 이용하여 인공 신경망의 기반을 둔 전력수요 예측 모델을 기술한다. 4장은 예측 모델의 정확성을 평가하기 위한 성능 평가 지표를 제시한다. 5장은 예측 모델의 정확성을 평가하기 위한 다양한 실험을 대해서 기술한다. 마지막으로, 6장에서는 결론 및 향후 연구방향을 제시한다.



(a) 15-min resolution forecasting-based scheduling



(b) 5-min resolution forecasting-based scheduling

Fig. 1. CHP Operation Scheduling Depending on Time Resolution

## 2. 관련 연구

이 장에서는 기계 학습을 기반으로 하는 전력수요 예측 기법과 이를 적용한 스마트 그리드의 운용 사례들을 살펴본다. 이전부터 전력수요 예측을 위해서 회귀 분석과 시계열 분석 등의 통계 기법을 사용하여 전력 사용량 예측 모델을 구성하는 연구가 진행되었다[6-10]. 최근에는 기계 학습 기반의 전력수요 예측 연구가 활발히 진행되어 왔으며, 특히 인공 신경망을 적용한 다양한 연구가 진행되고 있다. 또한, 전력수요 예측의 정확성을 향상시키기 위해 과거 전력수요 데이터 외에 기상 정보나 사회적 변수 등의 외부 요인과, 건물 및 전력망의 상황을 반영하는 시도가 있었다[11-18]. 예를 들어, Bagnasco[19]는 인공 신경망을 기반으로 토리노의 첼리니 병원 건물의 전력 사용량을 예측하였고, Grolinger[20]는 기존 외부 요인에 이벤트 정보를 추가한 인공 신경망과 지지 벡터 회귀모형을 구성하여 대형 엔터테인먼트 건물의 전력 사용량을 예측하고 비교하였다. Jurado[21]는 RF (Random Forest), NN (Neural Network), FIR (Fuzzy Inductive Reasoning), ARIMA (Autoregressive Integrated Moving Average)를 포함한 다양한 기계 학습 알고리즘을 통해 바르셀로나에 있는 3개의 건물에 대한 시간대별 전력 사용량을 예측하고 평가하였다. 특히, Moon[22]은 교육기관 내의 건물 특성별 전력부하 패턴을 분석하고 SVR과 ANN을 기반으로 예측 모델을 구성하고 그 성능을 비교 평가하였다.

한편, 스마트 그리드의 효율적인 운영을 위해 전력 사용량 및 요금 예측을 적용한 EMS 관련 연구가 활발하게 진행되고 있다. Sandels[23]는 EMS에 적용하기 위한 Weather, Occupancy 및 Temporal 데이터를 외부 변수로 사용하여 Regression 기반의 day-ahead 예측 모델을 구성하고 평가하였다. Pascual[24]는 신재생 에너지가 연계된 마이크로 그리드 환경에서 전력 사용량과 신재생 에너지 발전량에 대한 예측을 기반으로 그리드 운영 계획을 수립하는 연구를 진행하였다.

Powell[25]은 CHP 연계형 에너지 시스템에서 운전 스케줄링을 위한 난방, 냉방 및 전력 부하에 대한 1시간 전 예측 모델을 구축하고 평가하였다. Wessam[26]은 CHP가 연결된 전력망에서 CHP를 이용한 DR 프로그램을 구성하여 오스트리아의 스물다섯 가구에 대한 사용 전력 요금을 예측하고 이를 기반으로 CHP 스케줄링을 수행하였다. Sun[27]은 CHP가 연계된 전력망에서 15분 해상도의 스케줄링을 수행하여 전력 에너지 비용을 절감하는 연구를 수행하였다. 앞서 살펴본 연구들에서는 예측의 주기가 수요시한과 같거나 더 높은 시간 해상도에서의 예측 및 발전 스케줄링 기법을 다루었다. 하지만, 비용면에서 보다 경제적인 스케줄링을 위해서는 고시간 해상도의 예측이 필요하다. 그리고 대부분의 예측 연구의 경우, 수요시한과 같은 시간 해상도로 예측을 수행하여, 에너지 및 요금에 대한 손실이 발생할 수 있다.

## 3. 시스템 구성

본 장에서는 좀 더 정확한 발전 스케줄링을 위해서, 고시간 해상도를 이용한 전력 사용량 예측 기법을 제안한다. 먼저, 기존 데이터보다 더 높은 시간 해상도를 가지도록 시계열 데이터를 분할하는 기법을 기술하고, 이어서 인공 신경망 기반의 전력수요 예측 모델에 대해 자세하게 기술한다. Fig. 2는 본 논문에서 제안하는 예측 모델의 전체적인 구성도이다.

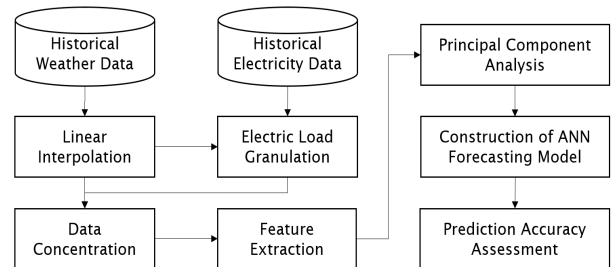


Fig. 2. Overall Architecture of High Time Resolution Forecasting Model

### 3.1 시계열 데이터 분할 기법

한국의 전력 요금 체계는 TOU와 CPP를 병행하여 사용하며, 수요시한은 15분이다. 실제 스마트 그리드 운영시, 수요시한과 같은 시간 해상도에서의 예측을 기반으로 CHP 스케줄링을 수행한다면 에너지 및 요금에 대한 손실이 발생할 수 있다. 따라서 보다 효율적인 CHP 운영을 위해서는, 수요시한보다 더 높은 해상도 기반의 전력수요 예측이 필요하다. 최근 스마트 미터가 보급되면서 실시간 및 1분 주기 등의 전력 사용 데이터 수집이 가능해졌지만, 다량의 전력 데이터를 수집하기에는 역부족이다. 이러한 점을 해결하기 위해서, 이 장에서는 수요시한 주기로 수집된 전력수요 데이터를 고시간 해상도 데이터로 분할하기 위한 방법을 제안한다.

전력수요 데이터의 분할을 위해서는, 전력수요와 상관관계가 높은 데이터가 필요하다. 기존 연구에서는 예측의 정확성을 높이기 위해, 기상 또는 전력 사용 장소의 환경적인 요인들을 추가 변수로 사용하는 다양한 시도가 있었다. 이 논문에서는 전력 데이터 분할을 위해, 전력수요와 상관관계가 높으며, 모든 시간에 발생하는 데이터인 온도(Temperature) 데이터를 사용하였다.

실제 데이터 수집은 KMA (Korea Meteorological Administration)에서 제공하는 1시간 해상도의 기상 데이터를 사용한다. 하지만, 전력수요에 대한 기상 데이터의 영향을 정확히 분석하려면, 기상 데이터 또한 고시간 해상도를 가져야 한다. 이를 위해, 기온이 모든 시간에 연속적으로 발생한다는 점을 이용하여, 1시간 해상도의 기온 데이터에 선형 보간법을 적용하여 고시간 해상도의 데이터로 변환한다. 두 시점  $T_1, T_2$ 에서의 기온을  $f(T_1), f(T_2)$ 라고 했을 때,  $T_1$

과  $T_2$  사이의 임의의 시점  $T(T_1 \leq T \leq T_2)$ 의 기온  $f(T)$ 에 대한 선형 보간법의 식은 Equation (1)과 같다.

$$f(T) = \frac{d_2}{d_1+d_2}f(T_1) + \frac{d_1}{d_1+d_2}f(T_2) \quad (1)$$

Fig. 3에서 선형보간법 예를 보여주며,  $d_1$ 은  $T$ 에서  $T_1$ 까지의 거리이고,  $d_2$ 는  $T$ 에서  $T_2$ 까지의 거리이다.




Fig. 3. Example of Linear Interpolation

선형보간법을 이용하여 추정된 각 시점의 기온 데이터를 전력수요 데이터에 대한 가중치로 적용하여 데이터를 분할한다. 기존 전력수요 데이터 시점을  $T_p$ , 전력수요 데이터를  $Power_{T_p}$ ,  $T$ 에 대한 분할 수의 합을  $n$ , 분할 시점을  $T_i$ , 기온을  $Temp$ 라고 했을 때, 전력수요 데이터 분할 식은 다음 Equation (2)와 같다.

$$EstimatedPower_{T_i} = \quad (2)$$

$$\frac{Temp_{T_i}}{Temp_{T_1} + \dots + Temp_{T_i} + \dots + Temp_{T_n}} \times Power_{T_p}$$

### 3.2 인공 신경망 기반의 전력수요 예측 모델

이 절에서는 기계 학습 알고리즘인 인공 신경망을 기반으로 고시간 해상도의 전력수요를 예측하는 모델을 구성하는 과정에 대해 서술하고자 한다. 먼저 예측모델 구성의 기반이 되는 데이터 셋에 대해 언급하고, 예측에 필요한 주요 데이터의 특징을 추출하는 방법을 서술한다. 이어서, 차원 감쇄를 위한 주성분 분석을 설명하고, 마지막으로 예측 모델에 대한 종합적인 구성에 관해 서술한다.

#### 1) 데이터 셋

과거 전력수요 데이터는 전력수요 예측 모델을 구성하는데 있어서 필수적이다. 그 외에도 예측의 정확성을 높이기 위한 다른 데이터가 필요할 수 있는데, 본 논문에서는 기상 데이터를 활용하고자 한다. 이를 위해, 한국전력공사의 i-Smart

를 통하여 15분 해상도의 전력 데이터를 수집하였고, KMA 기상자료 개방포털에서 1시간 해상도의 기상 데이터를 수집하였다. 예측에 적용할 기상 데이터를 선정하기 위해서, 전력수요에 대한 기온, 습도, 풍속 그리고 증기압의 관련성을 분석하기 위해 피어슨 상관관계 분석을 수행하였으며 그 결과는 Table 1에 나타내었다.

Table 1. Pearson-correlation Analysis of Electricity Load and Weather Information

Feature	Pearson-Correlation
Temperature	0.452
Humidity	-0.229
Wind Speed	0.059
Steam Pressure	0.279

분석 결과에 따르면, 기온, 습도 그리고 증기압은 전력수요와 상관관계가 높았으나, 풍속과는 낮은 상관계수를 보였다. 하지만 전력수요와 풍속의 관계를 분석한 Xie[28]에 근거하여, 네 가지 기상 정보를 모두 적용하였다. 데이터는 2015년 9월 1일부터 2016년 7월 17일까지 십여 개월에 걸쳐 수집하였다. 수집된 15분 해상도의 전력수요 데이터는 5분, 3분, 1분 등 세 가지 시간 해상도로 분할하였고, 기상 데이터는 선형 보간법을 이용하여 각 시간 해상도에 따라 추정하여 데이터 셋을 구성하였다.

#### 2) 특징 추출

전력수요 데이터는 시계열 데이터이므로 기계 학습 알고리즘을 적용하기에 앞서, 데이터의 주기성을 반영하도록 적절하게 처리해주어야 한다. 월, 일, 시간, 분 등의 시간 정보 데이터는 수열 형태를 보인다. 수열 형태의 데이터는 기계 학습 알고리즘에 적용 시 주기성 정보를 반영할 수 없다. 따라서 다음 Equations (3)~(11)을 이용하여 1차원 데이터를 2차원 공간의 연속적인 데이터로 증강하여 주기성을 반영한다[22, 29].

$$\min_x = \sin((360/60) \times \text{minute}) \quad (3)$$

$$\min_y = \cos((360/60) \times \text{minute}) \quad (4)$$

$$hmin = \text{hour} + (\text{minute}/60) \quad (5)$$

$$\text{hour}_x = \sin((360/24) \times hmin) \quad (6)$$

$$\text{hour}_y = \cos((360/24) \times hmin) \quad (7)$$

$$\text{day}_x = \sin((360/EoM_{\text{month}}) \times \text{day}) \quad (8)$$

$$\text{day}_y = \cos((360/EoM_{\text{month}}) \times \text{day}) \quad (9)$$

$$\text{month}_x = \sin((360/12) \times \text{month}) \quad (10)$$

$$\text{month}_y = \cos((360/12) \times \text{month}) \quad (11)$$

Equation (8)과 (9)에서  $EoM_{month}$ 는 End of Month로 속한 달의 마지막 날을 나타낸다. 또한, 각 특성은 0의 평균과 1의 표준편차를 갖도록 표준화(Standardization)를 수행하였다.

$$X = \begin{pmatrix} min_x, & min_y, & hour_x, & hour_y, \\ day_x, & day_y, & month_x, & month_y, \\ mon, & tues, & wed, & thu, \\ fri, & sat, & sun, & holiday, \\ temp, & humidity, & winds, & steam \end{pmatrix} \quad (12)$$

### 3) 주성분 분석

Equation (12)에서와 같이 전력수요 예측에 필요한 모든 변수의 집합을 X로 정의하였다. 이들 변수에는 기상 정보처럼 전력수요와 상관관계가 높은 데이터도 포함되지만, 시간 정보나 요일 정보처럼 전력수요 보다는 전력수요 패턴이나 주기성을 반영하기 위한 데이터도 포함된다. 따라서 주성분 분석 알고리즘을 적용하여 중요한 특성을 도출하고, 특성들이 큰 표준 편차를 갖도록 사상하는 것이 필요하다. PCA는 많은 수의 입력 변수들을 일련의 소수의 요인에 의해 설명이 가능하도록 하는 알고리즘이다. 데이터를 한 개의 축으로 사상했을 때, 분산의 크기를 기준으로 새로운 좌표계를 형성하여, 이를 선형 변환한다. 이 주성분들은 고유 벡터로 나타내어지며, 이는 인공 신경망의 입력 변수로 사용된다.

### 4) 인공 신경망 기반의 전력수요 예측 모델

본 논문에서는 Fig. 4와 같이 입력 변수들로 Input Layer를 구성하고, 1개의 Hidden Layer에서 5개부터 15개까지 노드들로 각각의 예측 모델을 구성한 다음, 1개의 Output Layer로 전력수요를 예측한다. 또한, 인공 신경망 학습시 Overfitting을 피하기 위해, 100번의 Epoch 상에서 학습하였다.




Fig. 4. Structure of 3-layer Artificial Neural Network

## 4. 평가지표

본 논문에서 구성한 예측 모델의 성능 평가를 위해, 예측 값에 대한 MAPE (Mean Absolute Percentage Error), MAE (Mean Absolute Error) 및 RMSE (Root Mean Square Error)를 계산하여 이용한다.

MAPE는 오차를 백분율로 표현하며, 계산식은 다음 Equation (13)과 같다.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100 \quad (13)$$

여기서,  $A_t$ 는 실제 값이고,  $F_t$ 는 예측 값, 그리고  $n$ 은 관측치의 수이다.

MAE는 주로 시계열에서 예측 값의 오차를 측정하는 데 사용된다. MAE를 구하는 수식은 다음 Equation (14)와 같다.

$$MAE = \frac{1}{n} \sum_{t=1}^n |F_t - A_t| = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (14)$$

여기서,  $A_t$ 는 실제 값이고,  $F_t$ 는 예측 값이며,  $n$ 은 관측치의 수이다. 예측 값은 가중치와 구간에 좌우됨으로 MAE를 통해 최적의 가중치를 구하는 작업이 필요하다.

RMSE는 예측 값과 실제 값의 차이를 다룰 때 흔히 사용하는 척도이며, 정밀도(Precision)를 표현하는 데 적합하다. 각각의 차이값은 잔차(Residual)라고도 하며, RMSE는 잔차들을 하나의 척도로 종합할 때 사용된다. RMSE는 MSE (Mean Square Error)에 루트를 취한 Equation (15)와 같이 정의되며, 추정치  $\theta$ 에 대한 추정량  $\hat{\theta}$ 의 평균 제곱 오차의 제곱근을 나타낸다.

$$RMSE(\hat{\theta}) = \sqrt{MSE(\hat{\theta})} = \sqrt{E((\hat{\theta} - \theta)^2)} \quad (15)$$

편의 추정량에서 평균 제곱근 오차는 분산의 제곱근, 즉 표준 오차가 된다.

## 5. 실험 및 평가

이 장에서는 앞에서 제안하였던 시계열 데이터 분할과 고시간 해상도 예측에 대한 성능 평가를 수행한다. 5.1절에서는 시계열 데이터 분할에 대한 결과를 MAPE를 이용하여 평가하고, 5.2절에서는 4가지 고시간 해상도에 대한 예측의 정확성에 대해서 평가한다.

### 5.1 시계열 데이터 분할 평가

본 실험에서는 1시간 단위 전력 데이터를 15분 단위로 분할한 결과를 평가하여 분할 기법의 정확성을 검증한다. 그



이유는 실제 15분보다 높은 해상도의 데이터를 얻을 수 없어 1시간 해상도 데이터에서 15분 단위로의 분할을 통해 성능이 검증되면 15분 단위 데이터에서 고시간 해상도로 분할한 데이터의 유효성을 인정할 수 있기 때문이다. 실험에서 13,371개의 1시간 단위 해상도의 데이터를 분할하였고, 분할된 데이터와 53,484개의 실제 15분 단위 데이터를 MAPE를 이용하여 비교 하였으며 그 결과는 Table 2에 나타내었다.

Table 2. MAPE of Data Segmentation by High Time Resolution


	MAPE(%)
Proposed method	2.67%

실험 결과에서 보듯이 제안하는 분할 기법은 2.67%라는 낮은 MAPE를 가지므로 고해상도로의 시간 분할은 충분히 유효한 것으로 판단된다. 또한, 고시간 해상도로 분할된 시계열 데이터는 가중치 기반으로 분할되었기 때문에, 분할된 테


이터를 합하면 기존의 데이터와 같아서 데이터에 대한 손실 또한 없다.

5.2 인공 신경망 기반의 전력수요 예측 평가

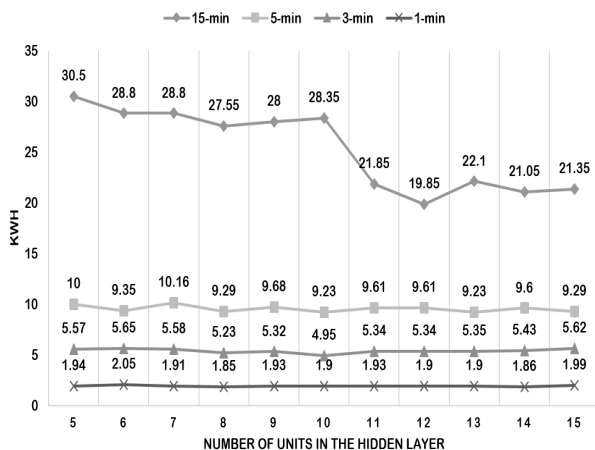
본 실험에서는 실제 15분 단위 데이터를 5분, 3분, 1분 단위로 분할하여, 총 4가지 시간 해상도에 대한 전력수요 예측을 수행하고, 주성분 분석 사용 여부에 따른 결과의 비교 및 Hidden Layer의 유닛 수에 따른 예측 성능의 차이를 비교한다. 앞서 제시한 시계열 데이터 분할 기법을 거친 후, 인공 신경망으로 구성된 전력수요 예측 모델을 각 시간 해상도별로 실험을 진행하였으며, 5-fold cross-validation을 통하여 평가를 진행하였다. 데이터의 수는 15분은 30,140, 5분은 90,420, 3분은 150,700, 1분은 452,100개를 사용하였고, 트레이닝 셋과 테스트 셋의 비율은 80:20로 하였다. Hidden Layer의 유닛 수별, 각 시간 해상도별 MAE와 RMSE는 Fig. 5에 나타내었고, MAPE는 Fig. 6에는 나타내었다.



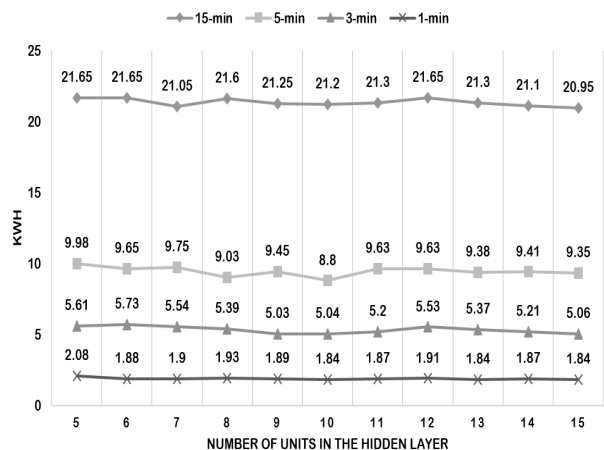
(a) MAE of model without PCA



(b) MAE of model with PCA




(c) RMSE of model without PCA




(d) RMSE of model with PCA


Fig. 5. MAE and RMSE by Time Resolution and PCA




(a) MAPE by number of units in 15-min resolution



(b) MAPE by number of units in 5-min resolution



(c) MAPE by number of units in 3-min resolution



(d) MAPE by number of units in 1-min resolution

Fig. 6. MAPE by Time Resolution and PCA

실험 결과에서 각 해상도별 성능은 달랐지만, 대체로 10개의 유닛으로 구성된 모델이 가장 좋은 성능을 보였으며, 주성분 분석을 적용한 모델이 더 높은 성능을 보였다. MAPE를 기준으로 비교하였을 때, 고해상도 예측일수록 더 높은 정확성을 보였지만, 1분 해상도에서 성능이 하락함을 보였다. 이 같은 결과가 나타나는 이유로는 선형 보간법을 이용하여 추정된 기상 데이터를 예측 모델에 반영함으로써 고시간 해상도 예측의 성능이 높아졌지만, 1분 해상도에서는 각 기상 테

이터의 편차와 상관관계가 낮아져 예측 성능 하락함을 보였다. 전체적으로 3분 해상도에서 가장 좋은 성능을 보였으며, MAE와 RMSE 측면에서도 다른 고시간 해상도에 비해 높은 성능을 보였다. 추가적으로 예측 모델의 우수성을 확인하기 위해, 가장 정확성이 높은 노드 수인 인공 신경망 예측과 지지벡터회귀분석 기반의 예측을 수행하고 결과를 비교하였다. 지지벡터회귀분석에서도 인공 신경망과 동일한 데이터를 사용하였고, 커널은 RBF를 사용하였으며,  $C=0.1$ ,  $\epsilon=0.1$ 에서 최

Table 3. Comparison of Proposed Model and SVR Forecasting Results

	ANN						SVR					
	PCA			non-PCA			PCA			non-PCA		
	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE
15-min	4.24%	21.14	21.20	4.24%	21.14	28.35	4.20%	20.94	29.01	4.20%	20.94	29.01
5-min	4.01%	6.41	8.80	4.19%	6.69	9.23	4.26%	7.07	9.98	4.26%	7.07	9.98
3-min	3.71%	3.56	5.04	3.61%	3.45	4.95	4.30%	4.27	5.95	4.30%	4.27	5.95
1-min	4.03%	1.31	1.84	4.28%	1.39	1.90	4.45%	1.47	2.05	4.45%	1.47	2.05

적의 성능을 보였다. 비교실험 결과는 Table 3에 나타내었다.

지지벡터회귀분석 기반의 예측 모델의 경우, 주성분 분석 적용 여부에 관계없이 같은 결과를 보였으며, 15분의 해상도 예측에서는 인공 신경망과 지지벡터회귀분석이 비슷한 성능을 보였다. 하지만, 모든 평가지표에서 지지벡터회귀분석은 고시간 해상도일수록 성능이 낮아지는 반면에, 인공신경망에서는 시간 해상도가 높아짐에도 불구하고 더 높은 정확성을 보였다.

## 6. 결 론

본 논문은 스마트 그리드 환경에서 기존 수요시한 기준의 예측치를 기반한 CHP 스케줄링에서 발생할 수 있는 에너지 및 요금에 대한 손실을 최소화할 수 있는 고시간 해상도 기반의 전력수요 예측 기법을 제안하였다. 현실적으로 고시간 해상도의 전력수요 데이터 수집이 어려운 문제를 해결하기 위해, 전력 공급 회사의 수요시한인 15분 해상도로 수집된 기존 전력 사용량 데이터를 더 높은 시간 해상도로 분할하는 방법을 제시하고, 각 시간 해상도에 따른 전력 사용량 예측 모델을 기계 학습 알고리즘인 인공 신경망을 적용하여 구축하였다. 실험에서는 15분, 5분, 3분, 1분 등 네 가지 시간 해상도 전력수요 데이터를 이용하여, 수요예측에서 주성분 분석 알고리즘의 효과를 평가하였으며, 평가 지표로는 MAPE, MAE 및 RMSE를 사용하였다. 예측 모델은 주성분 분석 알고리즘을 적용하였을 때 보다 나은 성능을 보였고, 모든 시간 해상도에서 10개 유닛으로 예측 모델을 구성하였을 때 가장 좋은 성능을 보였다. 또한, 지지벡터회귀분석 기반의 예측 알고리즘과의 비교를 통하여, 인공 신경망 기반 예측 모델이 더 우수한 성능을 보임을 알 수 있었다. 또한, 고시간 해상도에 대한 예측 수행시 대부분 크게 성능이 낮아지게 되는 데 비해, 본 논문에서는 시간 해상도에 알맞은 기상 정보를 선형 보간법으로 추정하고, 예측에 적용함으로써 고시간 해상도에서도 높은 예측 성능을 보였다. 향후 전력 사용량 예측의 정확성 향상을 위해, 다양한 외부 환경 데이터를 반영하여 학습 및 예측 기법에 적용하는 연구를 수행할 계획이다. 또한, 예측치 기반 에너지 운영 스케줄링이나 수요 반응 등을 추가로 연구함으로써 더욱 정확하고 신뢰성 높은 에너지 관리 시스템을 실현할 수 있을 것으로 기대한다.

## References

- [1] T. Hong and S. Fan, "Probabilistic electric load forecasting: A tutorial review," *International Journal of Forecasting*, Vol.32, No.3, pp.914-938, 2016.
- [2] A. Ahmad and T. Anderson, "Hourly power consumption prediction for New Zealand residential houses using artificial neural network models," in *Proceedings of Asia-Pacific Solar Research Conference*, Sydney, 2014.
- [3] F. Rodrigues, C. Cardeira, and J.M.F. Calado, "The daily and hourly energy consumption and load forecasting using artificial neural network method: a case study using a set of 93 households in Portugal," *Energy Procedia*, Vol.62, pp.220-229, 2014.
- [4] L. Hernandez, C. Baladrón, J. M. Aguiar, B. Carro, A. J. Sanchez, and J. Lloret, "Short-term load forecasting for microgrids based on artificial neural networks," *Energies*, Vol.6, No.3, pp.1385-1408, 2013.
- [5] A. Selakov, D. Cvjetinović, L. Milović, S. Mellon, and D. Bekut, "Hybrid PSO - SVM method for short-term load forecasting during periods with significant temperature variations in city of Burbank," *Applied Soft Computing*, Vol.16, pp.80-88, 2014.
- [6] A. Vaghefi, M. Jafari, E. Bisse, Y. Lu, and J. Brouwer, "Modeling and forecasting of cooling and electricity load demand," *Applied Energy*, Vol.136, pp.186-196, 2014.
- [7] M. R. Sarkar, M. G. Rabbani, A. R. Khan, and M. M. Hossain, "Electricity demand forecasting of Rajshahi City in Bangladesh using fuzzy linear regression model," in *Electrical Engineering and Information Communication Technology (ICEEICT)*, 2015.
- [8] G. Dudek, "Pattern-based local linear regression models for short-term load forecasting," *Electric Power Systems Research*, Vol.130, pp.139-147, 2016.
- [9] A.K. Fard and M.-R. Akbari-Zadeh, "A hybrid method based on wavelet, ANN and ARIMA model for short-term load forecasting," *Journal of Experimental & Theoretical Artificial Intelligence*, Vol.26, No.2, pp.167-182, 2014.



- [10] G. Sudheer and A. Suseelatha, "Short term load forecasting using wavelet transform combined with Holt - Winters and weighted nearest neighbor models," *International Journal of Electrical Power & Energy Systems*, Vol.64, pp.340-346, 2015.
- [11] P. Bunnoon, K. Chalermyanont, and C. Limsakul, "The Comparison of Mid Term Load Forecasting between Multi-Regional and Whole Country Area Using Artificial Neural Network," *International Journal of Computer and Electrical Engineering*, Vol.2, No.2, pp.334-338, 2010.
- [12] T. N. Lam, K. K. Wan, S. Wong, and J. C. Lam, "Impact of climate change on commercial sector air conditioning energy consumption in subtropical Hong Kong," *Applied Energy*, Vol.87, No.7, pp.2321-2327, 2010.
- [13] K. Pilli-Sihvola, P. Aatola, M. Ollikainen, and H. Tuomenvirta, "Climate change and electricity consumption - Witnessing increasing or decreasing use and costs?" *Energy Policy*, Vol.38, No.5, pp.2409-2419, 2010.
- [14] N. B. Adam, M. Elahee, and M. Dauhoo, "Forecasting of peak electricity demand in Mauritius using the non-homogeneous Gompertz diffusion process," *Energy*, Vol.36, No.12 pp.6763-6769, 2011 .
- [15] P.-C. Chang, C.-Y. Fan, and J.-J. Lin, "Monthly electricity demand forecasting based on a weighted evolving fuzzy neural network approach," *International Journal of Electrical Power & Energy Systems*, Vol.33, No.1, pp.17-27, 2011.
- [16] P. Bunnoon, "The Multi-Point Values of Appropriate Smoothing Parameters Opt  $\lambda$ . of HP-filter for Mid-Term Load Forecasting based on Neural Network," *International Journal of Engineering and Technology*, Vol.5, No.4 pp.3533-3543, 2013.
- [17] P. Bunnoon, K. Chalermyanont, and C. Limsakul, "Multi-substation control central load area forecasting by using HP-filter and double neural networks (HP-DNNs)," *International Journal of Electrical Power & Energy Systems*, Vol.44, No.1, pp.561-570, 2013.
- [18] Z. Chen, S. Yang, and X. Wang, "PLS-SVR optimized by PSO algorithm for electricity consumption forecasting," *Applied Mathematics & Information Sciences*, Vol.7, No.1L, pp.331-338, 2013.
- [19] A. Bagnasco, F. Fresi, M. Saviozzi, F. Silvestro, and A. Vinci, "Electrical consumption forecasting in hospital facilities: An application case," *Energy and Buildings*, Vol.103, pp.261-270, 2015.
- [20] K. Grolinger, A. L'Heureux, M. A. Capretz, and L. Seewald, "Energy forecasting for event venues: Big data and prediction accuracy," *Energy and Buildings*, Vol.112, pp.222-233, 2016.
- [21] S. Jurado, À. Nebot, F. Mugica, and N. Avellana, "Hybrid methodologies for electricity load forecasting: Entropy-based feature selection with machine learning and soft computing techniques," *Energy*, Vol.86, pp.276-291, 2015.
- [22] J. Moon, J. Park, E. Hwang, and S. Jun, "Forecasting power consumption for higher educational institutions based on machine learning," *Journal of Supercomputing*, pp.1-23, 2017.
- [23] C. Sandels, J. Widén, L. Nordström, and E. Andersson, "Day-ahead predictions of electricity consumption in a Swedish office building from weather, occupancy, and temporal data," *Energy and Buildings*, Vol.108, pp.279-290, 2015.
- [24] J. Pascual, J. Barricarte, P. Sanchis, and L. Marroyo, "Energy management strategy for a renewable-based residential microgrid with generation and demand forecasting," *Applied Energy*, Vol.158, pp.12-25, 2015.
- [25] K. M. Powell, A. Sriprasad, W. Cole, and T. F. Edgar, "Heating, cooling, and electrical load forecasting for a large-scale district energy system," *Energy*, Vol.74, pp.877-885, 2014.
- [26] E. Wessam, and P. Tzscheutschler, "Short-term smart learning electrical load prediction algorithm for home energy management systems," *Applied Energy*, Vol.147, pp.10-19, 2015.
- [27] Z. Sun, L. Li, A. Bego, and F. Dababneh, "Customer-side electricity load management for sustainable manufacturing systems utilizing combined heat and power generation system," *International Journal of Production Economics*, Vol.165, pp.112-119, 2015.
- [28] J. Xie and T. Hong, "Wind Speed for Load Forecasting Models," *Sustainability*, Vol.9, No.5, pp.795-806, 2017.
- [29] J. Moon, S. Jun, J. Park, Y. Choi, and E. Hwang, "An Electric Load Forecasting Scheme for University Campus Buildings Using Artificial Neural Network and Support Vector Regression," *KIPS Transactions on Computer and Communication Systems*, Vol.5, No.10, pp.293-302, 2016.



### 박진웅

e-mail : timeless@korea.ac.kr

2013년 조선대학교 제어계측로봇공학과  
(학사)

2013년~현재 고려대학교 전기전자공학과  
석·박사통합과정

관심분야 : 수요 예측, 에너지 운영 계획,  
스마트 그리드



**문 지 훈**

e-mail : johnny89@korea.ac.kr  
2015년 한성대학교 정보통신공학과(학사)  
2015년~현 재 고려대학교 전기전자공학과  
석·박사통합과정  
관심분야: 스마트 그리드, 데이터 마이닝,  
수요 예측, 기계 학습



**황 인 준**

e-mail : ehwang04@korea.ac.kr  
1988년 서울대학교 컴퓨터공학과(학사)  
1990년 서울대학교 컴퓨터공학과(석사)  
1998년 Univ. of Maryland at College  
Park 전산학과(박사)  
1998년~1999년 Bowie State Univ. 조교수  
1999년~1999년 Hughes Research Lab. 연구교수  
1999년~2004년 아주대학교 정보통신전문대학원 조/부교수  
2004년~현 재 고려대학교 전기전자공학과 교수  
관심분야: 데이터베이스, 빅데이터 처리, 영상 처리, 음악 검색,  
멀티미디어 검색, 소셜 네트워크 데이터 분석