

## Forecasting daily peak load by time series model with temperature and special days effect

Jin Young Lee<sup>a</sup> · Sahm Kim<sup>a,1</sup>

<sup>a</sup>Department of Applied Statistics, Chung-Ang University

(Received January 10, 2019; Revised January 22, 2019; Accepted January 22, 2019)

---

### Abstract

Varied methods have been researched continuously because the past as the daily maximum electricity demand expectation has been a crucial task in the nation's electrical supply and demand. Forecasting the daily peak electricity demand accurately can prepare the daily operating program about the generating unit, and contribute the reduction of the consumption of the unnecessary energy source through efficient operating facilities. This method also has the advantage that can prepare anticipatively in the reserve margin reduced problem due to the power consumption superabundant by heating and air conditioning that can estimate the daily peak load. This paper researched a model that can forecast the next day's daily peak load when considering the influence of temperature and weekday, weekend, and holidays in the Seasonal ARIMA, TBATS, Seasonal Reg-ARIMA, and NNETAR model. The results of the forecasting performance test on the model of this paper for a Seasonal Reg-ARIMA model and NNETAR model that can consider the day of the week, and temperature showed better forecasting performance than a model that cannot consider these factors. The forecasting performance of the NNETAR model that utilized the artificial neural network was most outstanding.

Keywords: daily peak load, electric load forecasting, special days effect, time series model

---

### 1. 서론

과거부터 전력수요 예측은 안정적이고 효율적인 전력 계통운영, 수급, 그리고 발전 계획에 중요한 역할을 차지했다. 제 8차 전력수급기본계획에 따르면 최대전력수요와 연도별 전력소비량은 해가 갈수록 증가하고 있으나 국내의 환경변화에 따라 기존의 전력공급 위주의 정책에서 수요관리 중심의 정책으로 전환하게 되면서 더욱더 정확한 전력수요 예측이 필요하게 되었다. 또한 정확한 전력수요 예측을 하지 못할 경우 발전/송배전 설비의 갑작스러운 가동, 전력 추가 구매로 인한 비용 증가, 불필요한 전력 생산 등의 문제점을 초래 할 수 있다. 더불어 여름, 겨울철 최대전력 발생에는 냉·난방 수요가 많은 비중을 차지하고 있으나 기후의 변화에 따라 이상고온 현상으로 여름철 냉방수요가 급증하고 전력수요 변동의 폭이 커지는 등 전력수요 예측을 더욱 어렵게 하는 요인들이 발생하고 있다. 이러한 전력수요 예측의 어려움에도 불구하고 앞서 서술했듯이 예측의 중요성과 정확한 예측으로 얻게 되는 이점들로 인해 과거부터

---

This research was supported by the Chung-Ang University Research Scholarship Grants in 2018.

<sup>1</sup>Corresponding author: Department of Applied Statistics, Chung-Ang University, 84 Heukseok-ro, Dongjak-gu, Seoul 06974, Korea. E-mail: [sahm@cau.ac.kr](mailto:sahm@cau.ac.kr)

다양한 전력수요 예측 연구가 국내·외에서 활발히 이루어졌으며 다양한 모형들을 활용한 예측 모형 연구 개발들이 진행되고 있다.

전력 수요예측은 국내·외를 불문하고 다양한 모형을 이용하여 각 지역에 맞게 연구되어 왔다. 국내에서 Song 등 (2013)은 지수평활법에 기반한 방법을 제안하였다. 지수평활법 자체는 비교적 간단하지만, 요일 특성 등을 고려한다면 자기상관성이 높은 일일 전력수요의 예측에 나쁘지 않은 성능을 보인다. 다음으로 시계열 모형을 활용한 연구로서 Lee 등 (2013)은 일별 최대전력 수요를 예측함에 있어 Reg-ARIMA, Seasonal AR-GARCH, Holt-Winters 방법을 이용하였으며 Jung과 Kim (2014)은 SARIMA, Reg-ARIMA, SGARCH, Reg-AR-SGARCH 모형 등 여러 가지 시계열 모형을 활용하여 일일 전력수요를 예측하고 각 모형의 예측 성능을 비교하였다. 또한 Sohn 등 (2016)은 시계열 군집분석을 활용하여 Fractional ARIMA, 이중 계절 지수평활법, TBATS 모형을 적용해 스마트 그리드하에서의 전력수요 예측 연구를 실시하였다. 다음으로 회귀분석 모형을 제안한 전력수요 예측 연구가 있다. Han과 Baek (2010)은 하절기의 전력수요에 대한 예측에 요일 요인을 고려하여 회귀모형을 통한 보다 더 우수한 성능을 보이는 예측 방법을 제안하였다. 또한 Baek과 Han (2015)는 기존에 제안한 모형에 특수일 보정의 방법을 추가하여 개선된 모형을 제안하고 있다. 최근에는 기계학습(machine learning)을 활용한 방법들이 많이 연구되고 있으며 다양한 모형들이 제안되고 있다 (Ji 등, 2013; Tak 등, 2016). 국외에서도 국내 연구 사례에서 언급한 모형들과 유사하게 통계학 모형, 기계학습 모형 등을 통한 다양한 연구가 이루어졌다. Amjady (2001)는 전력수요와 관계있는 독립변수를 고려한 ARIMA 모형을 이용해 예측력을 높였으며 Huang과 Shih (2003)의 연구에서도 ARIMA 모형을 이용하여 단기 전력수요를 예측하였다. Taylor 등 (2006)은 일별 미래 예측을 이중 계절성에 대해 지수평활법 방법 및 주성분 분석(principal component analysis; PCA)을 기반으로 하는 새로운 방법을 모형에 다른 모형과 비교했으며, Taylor (2010)는 이중 모형을 확장하여 삼중 계절성 모형을 적용시키며 초단기 삼중 계절성 모형을 개발하였다. Hong 등 (2010)은 시간별 전력수요를 예측함에 있어 다중회귀 모형을 사용하였으며 온도와 시간과의 상호작용 효과를 고려하는 방법을 제시하였다. Sigauke와 Chikobvu (2011)는 분산모형을 이용하여 일별 최대전력 수요량에 대해 예측하였다. Fan과 Hyndman (2012)은 준모수(semi-parametric) 방법을 근거로 한 단기 전력수요를 예측하였다.

본 논문에서는 확실한 계절성을 보이는 우리나라의 전력수요 특성으로 인해 계절과 시간의 흐름에 따라 변동이 큰 국내 전력수요 환경을 반영하기 위하여 계절성을 고려한 모형을 제안하였다. 또한 Jung과 Kim (2014)에서 제안한 냉·난방수요에 영향을 미치는 온도효과에 더하여 요일에 따라 달라지는 전력수요 패턴을 반영하기 위한 특수일, 요일 효과를 함께 고려한 회귀모형, Seasonal ARIMA, Seasonal Reg-ARIMA, TBATS, 인공신경망(artificial neural network)을 활용한 NNETAR 모형을 사용하여 각 모형의 성능을 비교하고자 한다.

제 2장에서는 본 논문에서 사용한 모형들에 대한 설명을, 제 3장에서는 국내 전력수요 데이터와 특징들에 대해 설명하고 각 모형별 예측력을 비교해 볼 것이다. 제 4장에서는 4가지 모형 중에서 전력수요를 예측하는데 우수한 모형과 향후 연구 방향에 대한 결론으로 끝맺음 할 것이다.

## 2. 시계열 모형

### 2.1. Seasonal ARIMA 모형과 Reg-ARIMA 모형

Seasonal ARIMA 모형은 Box 등 (2015)에 의해 제안된 모형으로 시계열  $\{Y_t | t = 1, 2, \dots, T\}$ 가 평균이  $\mu$ 인  $ARIMA(p, d, q) \times (P, D, Q)_s$ 를 따를 때의 모형은 다음과 같이 나타낸다.

$$\phi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^D(Y_t - \mu) = \theta_q(B)\Theta_Q(B^s)\epsilon_t, \quad (2.1)$$

여기서  $B$ 는 후진연산자(back-shift operator)를 의미하고,  $p, d, q, P, D, Q$ 는 정수들이며,  $s$ 는 계절주기를 의미한다.  $\phi_p(B), \Phi_P(B), \theta_q(B), \Theta_Q(B)$ 는 각각  $B$ 에 대한  $p, P, q, Q$ 차 다항식이며, 각각  $\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p, \Phi_P(B) = 1 - \Phi_1 B - \dots - \Phi_P B^P, \theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ , 그리고  $\Theta_Q(B) = 1 - \Theta_1 B - \dots - \Theta_Q B^Q$ 를 의미한다.  $d$ 는 차분 차수를 의미하며,  $D$ 는 계절차분 차수를 의미한다. 또한  $Y_t$ 는  $t$ 시점 ( $t = 1, 2, \dots, T$ )에서의 관측값을 의미하며,  $\epsilon_t$ 는 평균이 0이고 분산이 고정된 백색잡음과정(white noise process)이다. Reg-ARIMA 모형은 Bell과 Hilmer (1983)에 의해 제안된 모형으로서 기존 모형에 회귀모형의 독립변수 효과를 고려한 모형으로 Regression과 ARIMA를 합친 단어이다.  $k$ 개의 독립변수를 고려한 시계열  $\{Y_t | t = 1, 2, \dots, T\}$ 이  $ARIMA(p, d, q) \times (P, D, Q)$ 를 따를 때의 모형은 다음과 같이 나타난다.

$$\phi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^D \left( Y_t - \sum_{i=1}^k \beta_i x_{it} \right) = \theta_q(B)\Theta_Q(B^s)\epsilon_t, \quad (2.2)$$

여기서  $\beta_i$ 들은 각각 독립변수  $x_{it}$ 의 계수를 의미하며 실수 값을 갖는다.

## 2.2. TBATS 모형

De Livera 등 (2011)는 기존의 지수평활법들이 변수들간의 비선형성을 고려하기 어려우며, 주기성이 정수인 한계 및 패턴의 반복주기가 배수가 되어야 한다는 한계를 감안하여, 복잡한 주기성을 고려한 일반화된 모형으로서 BATS(Box-Cox transform, ARMA errors, trend, and seasonal components) 모형과 이에 대하여 주기성을 삼각함수의 합으로 나타낸 TBATS(trigonometric, Box-Cox transform, ARMA errors, trend, and seasonal components) 모형을 제안하였다.

BATS 모형과 TBATS 모형은 명칭 그대로 식 (2.3)과 같이 Box-Cox 변환을 통하여 종속변수의 비선형성 관련 문제를 해결하며, 식 (2.4)와 같이 지수평활법을 통한 추세성분(trend components)과 계절성분(seasonal components)을 고려하였다. 식 (2.5)는 주기성을 삼각함수의 합으로 고려하는 것을 나타내며, 식 (2.6)에서 ARMA 모형을 통하여 오차항의 자기상관성을 고려한다. 이에 따라서 모형은 식 (2.7)과 같이 나타난다.

$$y_t^\omega = \frac{y_t^\omega - 1}{\omega} \omega \neq 0. \quad (2.3)$$

$$l_t = l_{t-1} + \phi b_{t-1} + \alpha d_t$$

$$b_t = (1 - \phi)\bar{b} + \phi b_{t-1} + \beta d_t \quad (2.4)$$

$$s_t^{(i)} = \sum_{j=1}^{k_t} s_{j,t}^{(i)} + \gamma_i d_t$$

$$s_{j,t}^{(i)} = s_{j,t-1}^{(i)} \cos \lambda_j^{(i)} + s_{j,t-1}^{*(i)} \sin \lambda_j^{(i)} + \gamma_1^{(i)} d_t$$

$$s_{j,t}^{*(i)} = -s_{j,t-1}^{(i)} \sin \lambda_j^{(i)} + s_{j,t-1}^{*(i)} \cos \lambda_j^{(i)} + \gamma_1^{(2)} d_t \quad (2.5)$$

$$d_t = \sum_{i=1}^p \psi_i d_{t-i} + \sum_{i=1}^q \theta_i \epsilon_{t-i} + \epsilon_t \quad (2.6)$$

$$y_t^{(\omega)} = l_{t-1} + \phi b_{t-1} + \sum_{i=1}^T s_{t-m_i}^{(i)} + d_i. \quad (2.7)$$

$T$ 개의 주기성을 가정한 TBATS 모형은  $TBATS(\omega, \phi, p, q, m_1, k_1, \dots, m_T, k_T)$ 로 표시하는데 여기서  $\omega$ 는 Box-Cox 변환 모수이고,  $\phi$ 는 Damping 모수,  $p$ 와  $q$ 는 ARMA 오차의 차수이다.  $\psi_i$ 와  $\theta_i$ 는




Figure 2.1. Multi-layer neural network.

ARMA( $p, q$ )의 계수이며, 단기적인 추세  $b_t$ 의 예측치는 장기적으로  $\bar{b}$ 로 수렴하여  $\bar{b}$ 는 장기 추세 값이다.  $\alpha, \beta$ 는 수준과 추세에 대한 모수이다.  $\gamma_1^{(i)}$ 와  $\gamma_2^{(i)}$ 는 평활(smoothing) 모수이며,  $\lambda_j^{(i)} = 2\pi/m_i$ ,  $k_i$ 는  $i$ 번째 주기성( $S_t^{(i)}$ )을 이루는 삼각함수의 수이며,  $S_{j,t}^{(i)}$ 는  $S_t^{(i)}$ 의 확률적 수준을 말하며,  $S_{j,t}^{(i)}$ 는  $S_t^{(i)}$ 의 확률적 성장부분을 나타낸다.


### 2.3. 신경망 모형

인공신경망은 기계학습의 일종으로 뇌의 뉴런구조에서 영감을 얻은 학습 알고리즘이다. 노드(node)라는 인공적인 뉴런을 시냅스의 연결을 통해 구성하고 학습 과정을 거쳐 각 뉴런을 연결하는 시냅스의 결합 세기를 변화함으로써 문제 해결 능력을 가지는 비선형 모형을 일컫는다. 신경망 모형은 여러 개의 층(layer)로 구성되어 있으며 기본적으로 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)로 구성되어 있다. 각 층은 여러 개의 노드로 구성되어 있으며 위에서 언급하였듯이 노드들은 서로 연결되어 있다. 입력층은 독립 변수들로 구성되며 은닉층은 입력층의 독립 변수로부터 입력값을 받은 후 가중합을 계산하고 은닉층의 노드들은 활성화함수를 통해 출력층에 최종 출력값을 전달하게 된다. 가중치는 랜덤으로 주어지며 훈련 과정에서 예측을 가장 잘 맞추는 방향으로 조정되며 활성화함수는 비선형함수를 사용한다. 인공신경망 모형의 개요는 다음 Figure 2.1과 같다.


본 논문에서는 R 프로그램의 forecast 패키지 중 nnetar 함수를 이용하여 신경망 모형을 적합하였다. nnetar은 전방전달 신경망(feed-forward neural network)을 적합하고 이 모형은 단일 은닉층을 가진다. 본 함수는 외부변수로 고려한 기온과 습도이외 자료의 시계열 특성을 반영하기 위하여 전력 사용량 과거 자료도 함께 외부변수로 고려한다. 모형은 NNAR( $p, k$ )로 표현되며 여기서  $p$ 는  $p$ 시점까지의 전력 사용량 과거자료( $y_{t-1}, \dots, y_{t-p}$ )를 의미하고  $k$ 는 은닉층의 노드 개수이다.

### 3. 모형의 성능 비교

본 논문에서 사용한 데이터는 전력거래소에서 제공하는 2014년 1월 1일 00시부터 2018년 11월 30일까



**Figure 3.1.** Time series plot of daily peak load.



**Figure 3.2.** Time series plot of daily peak load on March 2017.

지의 5년간 발전단 전력수급 데이터이다. 4년간 전력수급 데이터의 시계열 도표는 Figure 3.1과 같다. 시계열 도표를 살펴보면 5년간 최대전력수요는 증가하는 추세를 가지고 있으며 여름과 겨울철에 증가하고 봄과 가을철에 감소하는 계절성을 가짐을 알 수 있다. 또한 매년 설날과 추석에 최대전력수요가 전체 최대전력수요에 비해 매우 낮게 나타나며 이외 특수일에도 평소와는 낮은 수요를 나타냄을 알 수 있다. 또한 Figure 3.2를 살펴보면 토, 일요일은 평일에 비해 최대전력수요가 낮으며 특수일인 3·1절 또한 평일임에도 불구하고 Figure 3.1에서 살펴본 바와 같이 낮게 나타남을 알 수 있다. 이에 따라 본 논문에서는 계절성과 평일, 주말, 특수일 더미변수를 활용하여 일별 최대전력수요를 예측하였다.

데이터 중 2014년 1월 1일 00시부터 2017년 12월 31일까지의 4년 치 자료를 트레이닝 셋(training

**Table 3.1.** Parameter estimate of ARIMA

Parameter	Estimate
$\phi_1$	1.111
$\phi_2$	-0.4291
$\phi_3$	0.4461
$\phi_4$	-0.1588
$\theta_1$	-0.2752
$\theta_2$	0.1762
$\theta_3$	-0.2854
$\theta_4$	-0.1075
$\theta_5$	-0.1297
$\Phi_1$	0.0179
$\Theta_1$	-0.8058

**Table 3.2.** Parameter estimate of ARIMAX


Parameter	Estimate
$\phi_1$	0.7070
$\theta_1$	-0.9036
$\Phi_1$	0.7481
$\Theta_1$	-0.6294
$\Theta_2$	0.0392
Mean temperature	-91.7584
Minimum temperature	-1.4658
Maximum temperature	-3.3686
DSpecial day	-5965.6174
DSaturday	-8664.1792
DSunday	-12156.333

set)으로 사용하여 모형을 적합하였으며 2018년 1월 1일부터 2018년 11월 30일까지의 자료를 테스트 셋(test set)으로 이용하여 모형의 성능을 테스트하였다. 또한 본 논문에서는 일반적으로 전력수급에 영향을 미치는 것으로 알려진 기상요소를 고려하기 위하여 동 기간의 기상자료를 활용하였으며 상관분석을 통하여 전력수급에 영향을 미치는 요소들을 확인한 후 해당 기상요소들을 외부변수를 함께 고려할 수 있는 다중회귀, Reg-ARIMA, NNETAR 모형에 사용하였다. 기상자료는 기상청 기상자료개방포털(data.kma.go.kr)에서 제공되는 중관기상관측 자료를 이용했으며 국내 전체 기상을 고려하기 위해 각 지역의 주요도시인 서울, 부산, 대구, 대전, 광주, 강릉 기상관측소의 기상자료를 평균하여 사용하였다.

모형을 적합하고 예측력을 평가하는 과정은 다음과 같다. 예측력 비교를 위한 모형 적합에는 통계 소프트웨어 R에서 Hyndman (2018)의 forecast 패키지를 이용하여 arima 모형, arimax 모형에는 auto.arima 함수, TBATS 모형에는 tbats 함수 그리고 인공신경망 모형에는 nnetar 함수를 사용하였고 미래 예측에는 predict와 forecast 함수를 사용하였다. 14년 1월 1일부터 17년 12월 31일까지의 일별 최대전력 자료와 기상자료를 이용하여 위의 모형들을 적합한 후 18년 1월 1일의 기상자료를 이용해 최대전력수요를 예측한다. 그 후 다시 14년 1월 1일부터 18년 1월 1일까지의 자료를 이용하여 모형을 갱신한 후 18년 1월 2일 최대전력수요를 예측한다. 해당 과정을 334번 반복하여 18년 1월 1일부터 18년 11월 30일까지의 최대전력수요 예측값을 산출하였으며 같은 기간의 실제 최대전력수요와 비교해 MAE와 MAPE를 이용하여 각 모형의 예측 정확도를 평가하였다.

**Table 3.3.** Parameter estimate of TBATS

Parameter	Estimate
$\alpha$	0.7725
$\beta$	-0.1602
$\phi$	0.8120
$\gamma_1^{(1)}$	-0.0105
$\gamma_1^{(2)}$	0.0199
$\gamma_2^{(1)}$	-0.0384
$\gamma_2^{(2)}$	-0.0198


**Figure 3.3.** Daily peak load forecast of ARIMA.

ARIMA, ARIMAX, TBATS 모형의 최적 모형은 Akaike information criteria (AIC)를 기준으로 선정하였으며 모형의 모수 추정치는 Table 3.1에서 Table 3.3과 같으며 각 모형의 예측 결과와 실제 결과를 비교한 그림은 Figure 3.3에서 Figure 3.6이다. 그림에서 검은색 선은 실제 일 최대전력을, 빨간색 선은 각 모형을 이용하여 예측한 일 최대 전력을 나타낸다. 인공신경망 모형은 각 층들이 가중치의 결합으로 이루어져있어 모수에 대한 추정치가 존재하지 않아 제외하였다. ARIMA 모형의 경우  $ARIMA(4, 0, 5) \times (1, 1, 1)_7$ , ARIMAX 모형의 경우  $ARIMAX(1, 1, 1) \times (1, 0, 2)_7$ , TBATS의 경우  $TBATS(0, \{0, 0\}, 0.812, \{< 7, 3 >, < 365.25, 4 >\})$ 가 최적 모형으로 선정되었다.


각 모형의 성능을 비교하기 위하여 accuracy 함수를 이용해 mean absolute error (MAE)와 mean absolute percentage error (MAPE)를 산출하였다. MAE와 MAPE의 식은 다음 (3.1), (3.2)와 같다. 식에서  $n$ 은 모형의 예측 기간을 나타내며,  $Y_t$ 는 실제값,  $F_t$ 는 예측값을 의미한다. MAE와 MAPE 값이 작을수록 예측성능이 우수함을 의미한다.

$$MAE = \frac{\sum_{i=1}^n |Y_t - F_t|}{n}, \quad (3.1)$$

$$MAPE = \frac{\sum_{i=1}^n \frac{|Y_t - F_t|}{Y_t}}{n} \times 100. \quad (3.2)$$



**Figure 3.4.** Daily peak load forecast of ARIMAX.



**Figure 3.5.** Daily peak load forecast of TBATS.

각 모형들을 이용하여 2018년 1월 1일부터 2018년 11월 30일까지 총 334일을 예측하였으며 동 기간의 실제 자료와 비교하여 나타난 각 모형의 예측 성능은 다음 Table 3.4와 같다. 표에서 MAE는 실제 최대전력과 예측 최대전력의 오차 평균을 의미하고 단위는 이다. MAPE는 실제 최대전력과 예측 최대전력의 오차율의 평균을 의미한다.

예측 결과를 살펴보면 NNETAR 모형의 MAE와 MAPE가 각각 1631.865, 2.27%로 본 논문에서 비교 분석한 4가지 시계열 모형 중 가장 우수한 성능을 나타냄을 알 수 있으며 그 뒤로 ARIMAX, ARIMA, TBATS 순으로 예측 성능이 우수하다. 또한 외부 변수를 고려할 수 있었던 ARIMAX와 NNETAR 모형이 외부 변수를 고려할 수 없는 ARIMA, TBATS보다 모두 우수한 성능을 보이고 있음을 알 수 있다.






Figure 3.6. Daily peak load forecast of NNETAR.

Table 3.4. Forecast accuracy of models

Model	MAE	MAPE
ARIMA	2266.686	3.2258
ARIMAX	1793.282	2.5906
TBATS	3483.703	4.8662
NNETAR	1631.865	2.2741

#### 4. 결론

본 연구는 과거부터 매우 중요한 과제로 여겨졌으며 향후에는 그 중요성이 더욱 증가할 국내 최대전력을 예측하기 위하여 시계열 모형을 활용하였다. 본 연구에서는 ARIMA, ARIMAX, TBATS, 인공신경망 모형을 활용하여 각 모형의 예측 성능을 비교하였으며 최대전력에 크게 영향을 미치는 기상요소를 외부 변수로 사용하여 최대전력과 연관성이 높은 기온을 입력 변수로 선정하였다. 또한 일 최대전력의 경우 특수일이나 주말에 평소에 비해 낮게 나타나는 경향을 가지고 있어 해당 일의 특수일 혹은 주말 유무를 함께 고려하였다.

MAE와 MAPE를 각 모형의 예측 성능을 평가하는 지표로 사용하였으며 모형 별 MAE, MAPE 비교 결과 NNETAR 모형이 가장 우수한 성능을 나타냄을 알 수 있었다. 또한 모형 별 성능 비교를 통해 단 변량을 이용한 ARIMA, TBATS 모형보다 외부 변수를 함께 고려할 수 있는 ARIMAX, NNETAR의 성능이 우수함을 확인하였고 이에 따라 향후 일 최대전력 예측을 함에 있어 시계열 모형을 활용할 경우 외부 변수의 영향을 고려해야함을 알 수 있다.

본 연구에서 예측에 활용한 기간은 2018년 1월 1일부터 2018년 11월 30일까지로 2014-2017년 자료를 사용하여 2018년의 대부분을 예측하였고 이 중에는 예측이 어려운 것으로 알려진 추석, 설날 등의 특수일과 여름철 휴가 기간이 포함되어 있다. 모형의 예측 성능을 산출함에 있어 해당 기간을 포함하였음에도 불구하고 인공신경망 기준 약 2.27%의 예측 오차를 보이고 있어 향후 인공신경망 모형을 일 최대전력 수요 예측에 실사용할 수 있을 것으로 보인다.

향후 기상요소 뿐만 아니라 일 최대전력에 영향을 미칠 수 있는 영향 요소를 추가적으로 분석하고 이를

모형에 적용하여 본 논문에서 사용한 인공신경망 모형과 ARIMAX 모형을 개선할 경우 보다 더 우수한 예측 성능을 가지는 모형의 개발이 가능할 것으로 보인다.

## References

- Amjady, N. (2001). Short-term hourly load forecasting using time-series modeling with peak load estimation capability, *IEEE Transactions on Power Systems*, **16**, 498–505.
- Baek, J. K. and Han, J. H. (2015). A study on calibrating the forecasted load of electric power considering special day factor, *Journal of Industrial Economics and Business*, **28**, 191–203.
- Bell, W. R. and Hillmer, S. C. (1983). Modeling time series with calendar variation, *Journal of the American statistical Association*, **78**, 526–534.
- Box, G. E., Jenkins, G. M., Reinsel, G. C., and Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control* (5th ed), John Wiley & Sons, New York.
- De Livera, A. M., Hyndman, R. J., and Snyder, R. D. (2011). Forecasting time series with complex seasonal patterns using exponential smoothing, *Journal of the American Statistical Association*, **106**, 1513–1527.
- Fan, S. and Hyndman, R. J. (2012). Short-term load forecasting based on a semi-parametric additive model, *IEEE Transactions on Power Systems*, **27**, 134–141.
- Han, J. H. and Baek, J. K. (2010). The load forecasting in summer considering day factor, *Journal of the Korea Academia-Industrial Cooperation Society*, **11**, 2793–2800.
- Hong, T., Gui, M., Baran, M. E., and Willis, H. L. (2010). Modeling and forecasting hourly electric load by multiple linear regression with interactions, *In Power and Energy Society General Meeting, 2010 IEEE*, 1–8.
- Huang, S. J. and Shih, K. R. (2003). Short-term load forecasting via ARMA model identification including non-Gaussian process considerations, *IEEE Transactions on Power Systems*, **18**, 673–679.
- Hyndman, R., Athanasopoulos, G., Bergmeir, C., Caceres, G., Chhay, L., O'Hara-Wild, M., Petropoulos, F., Razbash, S., Wang, E., and Yasmeen, F. (2018). *\_forecast: Forecasting functions for time series and linear models\_*. R package version 8.4. <http://pkg.robjhyndman.com/forecast/>
- Ji, P. S., Kim, S. K., and Lim, J. Y. (2013). Development of daily peak power demand forecasting algorithm using ELM, *The Transactions of the Korean Institute of Electrical Engineers P*, **62**, 169–174.
- Jung, S. W. and Kim, S. (2014). Electricity demand forecasting for daily peak load with seasonality and temperature effects, *The Korean Journal of Applied Statistics*, **27**, 843–853.
- Lee, J. S., Sohn, H. G., and Kim, S. (2013). Daily peak load forecasting for electricity demand by time series models, *The Korean Journal of Applied Statistics*, **26**, 349–360.
- Sigauke, C. and Chikobvu, D. (2011). Prediction of daily peak electricity demand in South Africa using volatility forecasting models, *Energy Economics*, **33**, 882–888.
- Sohn, H., Jung, S., and Kim, S. (2016). A study on electricity demand forecasting based on time series clustering in smart grid, *The Korean Journal of Applied Statistics*, **29**, 190–203.
- Song, K. B., Kwon, O. S., and Park, J. D. (2013). Optimal coefficient selection of exponential smoothing model in short term load forecasting on weekdays, *The Transactions of the Korean Institute of Electrical Engineers*, **62**, 149–154.
- Tak, H., Kim, T., Cho, H. G., and Kim, H. (2016). A new prediction model for power consumption with local weather information, *Journal of the Korea Contents Association*, **16**, 488–498.
- Taylor, J. W. (2010). Triple seasonal methods for short-term electricity demand forecasting, *European Journal of Operational Research*, **204**, 139–152.
- Taylor, J. W., De Menezes, L. M., and McSharry, P. E. (2006). A comparison of univariate methods for forecasting electricity demand up to a day ahead, *International Journal of Forecasting*, **22**, 1–16.

# 기온과 특수일 효과를 고려하여 시계열 모형을 활용한 일별 최대 전력 수요 예측 연구

이진영<sup>a</sup> · 김삼용<sup>a,1</sup>

<sup>a</sup>중앙대학교 응용통계학과

(2019년 1월 10일 접수, 2019년 1월 22일 수정, 2019년 1월 22일 채택)

---

## 요약

일별 최대전력 수요 예측은 국가의 전력 수급운영에 중요한 과제로서 과거부터 다양한 방법들이 끊임없이 연구되어 왔다. 일별 최대전력 수요를 정확히 예측함으로써 발전설비에 대한 일일 운용계획을 작성하고 효율적인 설비 운용을 통해 불필요한 에너지 자원의 소비를 감소하는데 기여할 수 있으며 여름·겨울철 냉난방수요로 인해 발생하는 전력소비 과다로 인한 전력예비율 감소 문제 등에 선제적으로 대비할 수 있는 장점을 가진다. 이러한 일별 최대전력 수요 예측을 위하여 본 논문에서는 Seasonal ARIMA, TBATS, Seasonal Reg-ARIMA, NNETAR 모형에 평일, 주말, 특수일에 대한 효과와 온도에 대한 영향을 함께 고려하여 다음날의 일별 최대전력을 예측하는 모형을 연구하였다. 본 논문을 통한 모형들의 예측 성능 평가 결과 요일, 온도를 고려할 수 있는 Seasonal Reg-ARIMA 모형과 NNETAR 모형이 이를 고려할 수 없는 다른 시계열 모형보다 우수한 예측 성능을 나타내었고 그 중 인공지능망을 활용한 NNETAR 모형의 예측 성능이 가장 우수하였다.

주요용어: 일별최대전력, 전력수요예측, 특수일 효과, 시계열 모형

---

이 논문은 2018년도 중앙대학교 연구장학기금 지원에 의한 것임.

<sup>1</sup>교신저자: (06974) 서울특별시 동작구 흑석로 84, 중앙대학교 응용통계학과 교수. E-mail: sahm@cau.ac.kr