

Comparison of time series predictions for maximum electric power demand

Sukhui Kwon,^a Jaehoon Kim,^a SeokMan Sohn,^a SungDuck Lee^{1,a}

^aDepartment of Information & Statistics, Chungbuk National University

Abstract

Through this study, we studied how to consider environment variables (such as temperatures, weekend, holiday) closely related to electricity demand, and how to consider the characteristics of Korea electricity demand. In order to conduct this study, Smoothing method, Seasonal ARIMA model and regression model with AR-GARCH errors are compared with mean absolute error criteria. The performance comparison results of the model showed that the predictive method using AR-GARCH error regression model with environment variables had the best predictive power.

Keywords: electric power demand, smoothing method, seasonal ARIMA, weighted average model, ARCH, GARCH

1. 서론

최근 전력수요의 둔화와 신재생에너지의 계통 병입에 따른 전력불균형으로 인한 전력예비율이 최대 50%를 초과하고 있다. 신재생에너지의 간헐적 계통 병입으로 인한 계통 초과 부하를 제어하고 국가적 에너지 낭비를 줄이기 위해 잉여 전력의 2차적 에너지원으로 저장하려는 시도를 한국전력공사 주도로 하고 있다. 이를 위해 주파수 조정으로 사용하는 배터리 대신 장기 에너지 저장 시스템을 도입하고 있는 추세이다. 에너지 저장과 청정 에너지원 공급을 위해 수소에너지(연료전지, 수소연소, 암모니아 연소 등)를 잉여 전력으로 이용하여 생산하려고 하고 있다. 이를 위해서는 전력수요의 예측을 통해 잉여 전력의 정확한 계산이 필수적이다.

또한, 전력 생산은 스마트 그리드, 전기 자동차 및 재생 에너지 생산과 같은 혁신 기술의 등장으로 인해 변동성이 증가하는 추세에 있다. 신재생에너지 사용에 따라 화력 및 원자력발전과 같은 전통 전력생산의 조절이 필요하게 되어 더욱더 단기 전기 부하 예측(시간/일), 중기(월/년) 및 장기(5년/30년) 예측은 최근까지 산업계와 학계로 부터 많은 관심을 받아왔다. 전기 사업자에게 있어 전력수요 예측은 전력 시장에서 생산 계획 및 거래를 위한 가장 중요한 항목 중 하나이기 때문에 핵심 활동이다.

전력수요 예측에 대한 연구는 다양한 형태로 활발히 이루어지고 있다. 부하 예측에 관한 문헌은 풍부하며, 전체 국가, 대도시 또는 지역에 대한 집계 수준의 전력수요 예측에 관한 많은 연구가 수행되었다. 고전적인 통계 분석 방법은 (Amjady 등, 2001) seasonal autoregressive integrated moving average (SARIMA) 모형과 지수평활법을 단기적 관점에서 전기 수요 예측에 적용하였다. Taylor와 Buizza (2003)에 제시된 상태 공간 모형은 전기 데이터의 부드러운 변화에 적응하는 흥미로운 예측 능력을 보여준다. 기계 학습 방법에 기초한 다른 접근법도 Kalimoldayev 등 (2020)과 같이 좋은 결과를 제공한다.

¹ Corresponding author: Department Information & Statistics, Chungbuk National University, (28644) Chungdae-ro 1, Seowon-Gu, Cheongju, Chungbuk, Republic of Korea. E-mail: sdlee@chungbuk.ac.kr

Park 등 (2013)은 외부변수에 대한 회귀분석과 AR 모형의 가중평균을 통해 도시가스 일일 수요의 단기 예측을 수행하였다. Jung과 Kim (2014)은 온도와 계절성을 고려한 시계열모형으로 전력수요를 예측하였다. Lee 등 (2019)은 SARIMA 모형을 이용하여 한 생산시설에 수집된 전력사용량 시계열 데이터를 활용하여 최대 전력사용량 예측을 수행하여 우수한 예측성능을 보여주었다. 하지만 온도 등 외부변수 변화에 따른 기간별 특성을 고려하면 더욱 신뢰성 높은 전력수요 예측을 할 수 있으리라 기대된다.

본 연구는 10년간의 전력수요 데이터를 바탕으로 제시된 외부변수를 고려한 시계열모형을 사용하여 전기수요를 15일 앞까지 예측하는 것을 고려한다. 일일 간격으로 기록된 일련의 수요에는 두 개 이상의 계절 패턴이 포함되어 있다. 한 주내 계절 주기는 하루에서 다음까지 전력수요 프로파일의 유사성에서 명백하며, 인접한 주일에 대한 수요를 비교할 때, 일 년내 계절 주기가 분명하다. 계절성을 모두 포착할 수 있는 예측 방법을 사용하는 데는 큰 매력이 있다. 이를 위해 먼저 계절지수평활법이 이 목적을 위해 적용되었다. 이 논문에서는 홀트-윈터스 지수평활법을 적용하여 두 계절성을 수용할 수 있다.

또한, 국내 수요예측 및 판매량 예측모형으로 주로 사용되는 회귀모형을 이용하여 전력수요를 예측하였다. 기존 문헌 연구를 종합해보면 에너지 수요에 영향을 미치는 요인으로는 추세적 요인, 기온, 요일 등을 들 수 있다. 물론 전력 분석은 최근의 이상 기온 변화 및 경제효과 등 많은 외부적 영향을 반영하지 못하고 있고, 시간적 흐름의 변화를 모형에 반영하여 분석하는 시계열모형에 대한 연구 방향과 개념 정립이 시급하다. 전력수요 예측에 영향을 주는 주요 인자인 온도와 같은 외부변수들을 효과적으로 반영하는 예측 모형의 개발이 필요하다.

본 논문에서는 이러한 예측을 위해 한국전력공사에서 제공하는 2010년부터 2020년까지의 전력수요 데이터를 바탕으로 평활법, SARIMA와 GARCH를 통해 전력수요의 예측을 수행하였으며, 각 결과를 비교 수행하였다. 또한, 기상청에서 제공하는 동기간의 온도 데이터와 주말과 공휴일을 고려하여 회귀분석을 수행하여 시계열 예측값과의 가중평균을 수행하여 더욱 정밀한 예측을 수행하였다. 가법적 및 승법적 계절지수평활법, seasonal ARIMA, ARCH모형과 같은 시계열모형을 이용한 전력수요 예측을 각 변수의 결정 및 정상화를 확보하면서 수행하였다. 전력수요와 외부변수와의 관계를 분석하고 이를 바탕으로 온도에 대한 회귀모형을 개발하였으며, 가중평균모형을 활용하여 온도변수를 고려한 정밀한 전력수요 예측을 수행하였다. 본 연구에서 제시한 일별 전력수요 예측치는 단기 전력수요를 예측함으로써 수소에너지 생산과 같은 에너지저장시스템의 활용에 지원할 수 있다.

2. 전력수요 예측방법

2.1. 평활법

평활법은 시계열 데이터에 대해 이동평균 등의 방법을 사용하여 불규칙변동을 평활하여 미래의 값을 예측하는 방법이며 본 논문에서는 전력수요가 계절에 따라 변하는 특성을 고려하여 계절지수평활법(seasonal exponential smoothing method)을 가법적과 승법적에 대해 각각 수행하였다. 이 프레임워크는 신뢰할 수 있는 예측을 신속하게 생성하고 광범위한 시계열에 대한 예측을 생성하는데 이는 업계의 애플리케이션에 큰 이점과 중요한 중요성을 제공한다.

가법적 계절지수평활에 의한 예측방법 (Winters, 1960)은 선형추세성과 가법 계절변동을 갖는 시계열에 적용하는 방법이다. 가법적 계절지수평활법(additive seasonal exponential smoothing method)에서 예측식은 시계열 패턴의 세 가지 성분인 수평성, 추세성, 계절성을 평활한 세 성분의 합으로 나타난다. 즉, 현재시점이

n 인 경우에 l 시점 후의 예측값은 식 (2.1)과 같이 나타난다.

$$\begin{aligned} F_{n+l} &= a_n + b_n l + S_{n+l-L} \quad l = 1, 2, \dots, L, \\ a_n &= \alpha (Z_n - S_{n-L}) + (1 - \alpha) (a_{n-1} + b_{n-1}), \\ b_n &= \beta (a_n - a_{n-1}) + (1 - \beta) b_{n-1}, \\ S_n &= \gamma (Z_n - a_n) + (1 - \gamma) S_{n-L}. \end{aligned} \quad (2.1)$$

여기서 L 은 계절성의 길이 S_n 은 계절인자, α, β, γ 는 평활상수를 나타낸다.

승법적 계절지수평활에 의한 예측방법 (Winters, 1960)은 홀트의 선형지수평활법을 확장시킨 방법으로, 관측된 시계열이 선형추세성과 승법적 계절변동을 나타낼 때 적용하는 방법이다. 윈터스의 승법적 계절지수 평활법(multiplicative seasonal exponential smoothing method)은 다음과 같이 시계열 패턴의 세 가지 성분인 수평성, 추세성, 계절성을 평활하는 세 개의 방정식과 예측식으로 구성된다. 즉 현재 시점이 n 인 경우에 l 시점 후의 예측값 F_{n+l} 은 식 (2.2)과 같이 나타난다.

$$\begin{aligned} F_{n+l} &= (a + b_n l) S_{n+l-L} \quad l = 1, 2, \dots, L, \\ a_n &= \alpha \frac{Z_n}{S_{n-L}} + (1 - \alpha) (a_{n-1} + b_{n-1}), \\ b_n &= \beta (a_n - a_{n-1}) + (1 - \beta) b_{n-1}, \\ S_n &= \gamma \frac{Z_n}{a_n} + (1 - \gamma) S_{n-L}. \end{aligned} \quad (2.2)$$

2.2. Seasonal ARIMA 모형

Box 등 (1994)은 시계열 자료가 계절성(seasonality)이나 주기적 특성(periodicity)이 있을 때 활용할 수 있는 시계열 분석(time series analysis) 기법 중 하나인 seasonal autoregressive integrated moving average (SARIMA)을 제안하였다. ARIMA 모형에 주기적인 특성이나 계절성을 반영한 모형이 SARIMA 모형이다. SARIMA 모형은 ARIMA 모형처럼 예측하고자 하는 시점으로부터 가까운 과거 자료들을 이용할 뿐만 아니라, 자료의 주기적인 특성, 계절성을 반영했기 때문에 이전 주기의 자료를 추가적으로 활용한다. SARIMA(p, d, q) \times (P, D, Q), 모형의 일반식은 식 (2.3)과 같다.

$$\begin{aligned} \phi_p(B)\Phi_P(B)W_t &= \theta_q(B)\Theta_Q(B)e_t, \\ \phi_p(B) &= 1 - \phi_1 B - \dots - \phi_p B^p, \\ \Phi_P(B) &= 1 - \Phi_1 B^s - \dots - \Phi_P B^{Ps}, \\ \theta_q(B) &= 1 - \theta_1 B - \dots - \theta_q B^q, \\ \Theta_Q(B) &= 1 - \Theta_1 B^s - \dots - \Theta_Q B^{Qs}, \\ W_t &= \nabla^d \nabla_s^D X_t. \end{aligned} \quad (2.3)$$

여기서, X_t 는 원시계열 자료, W_t 는 차분된 시계열 자료, t 는 시간을 나타내는 연산자, e_t 는 $N(0, \sigma^2)$ 을 따르는 오차항(백색잡음), B 는 후향연산자, p 는 AR항의 차수, q 는 MA항의 차수, d 는 차분의 차수, P 는 계절 AR항의 차수, Q 는 계절 MA항의 차수, D 는 계절차분의 차수, s 는 계절시차를 나타낸다.

2.3. k 차 자기회귀오차모형

오차들이 시간에 따른 자기상관관계를 갖는 경우에 적합하는 자기회귀오차모형(autoregressive error model)을 전력수요에 적용하면 주로 7일의 주기성을 보이므로 8차항으로 자기회귀오차모형을 만들 수 있다. 전력수

요에 log를 계산하여 정상성을 확보한다.

$$\log(x_t) = \epsilon_t = \phi_0 + \phi_1\epsilon_{t-1} + \phi_2\epsilon_{t-2} + \cdots + \phi_k\epsilon_{t-k} + \nu_t, \quad \nu_t \sim N(0, 1) \quad (2.4)$$

위의 자기회귀오차모형에 온도, 주말, 공휴일의 변수를 고려하고 AR(1)을 추가한 회귀모형은 식 (2.5)와 같다.

$$\begin{aligned} \log(x_t) &= \beta_0 + \beta_1\log(x_{t-1}) + \beta_2|\text{temp} - 15| + \beta_3\text{weekend} + \beta_4\text{holiday} + \epsilon_t, \\ \epsilon_t &= \phi_1\epsilon_{t-1} + \phi_2\epsilon_{t-2} + \cdots + \phi_k\epsilon_{t-k} + \nu_t, \quad \nu_t \sim N(0, 1). \end{aligned} \quad (2.5)$$

2.4. AR-ARCH 회귀모형

Engle (1982)은 시계열의 분산 변화를 반영하는 p 차 자기회귀 조건부 이분산모형 제안을 제시하였다. Autoregressive conditional heteroscedasticity (ARCH모형)은 시계열의 분산 변화를 반영하는 모형이다. ARCH 모형은 시계열 데이터의 조건부 변동성에 바탕으로 조건부 분산을 반응변수로 산정하여 AR(1)-ARCH(1)은 외부 설명변수를 넣어 식 (2.6)으로 계산하게 된다.

$$\begin{aligned} \log(x_t) &= \beta_0 + \beta_1\log(x_{t-1}) + \beta_2|\text{temp} - 15| + \beta_3\text{weekend} + \beta_4\text{holiday} + \epsilon_t, \\ \epsilon_t &= \phi_1\epsilon_{t-1} + \phi_2\epsilon_{t-2} + \cdots + \phi_k\epsilon_{t-k} + \nu_t, \\ \nu_t &= \sqrt{h_t}e_t, \\ h_t &= \alpha_0 + \alpha_1\nu_{t-1}^2, \quad e_t \sim N(0, 1). \end{aligned} \quad (2.6)$$

AR-ARCH모형의 정밀도를 더하기 위해 설명변수를 고려한 AR(1)-GARCH(1, 1) 회귀모형은 식 (2.7)과 같이 주어진다.

$$\begin{aligned} \log(x_t) &= \beta_0 + \beta_1\log(x_{t-1}) + \beta_2|\text{temp} - 15| + \beta_3\text{weekend} + \beta_4\text{holiday} + \epsilon_t, \\ \epsilon_t &= \phi_1\epsilon_{t-1} + \phi_2\epsilon_{t-2} + \cdots + \phi_k\epsilon_{t-k} + \nu_t, \\ \nu_t &= \sqrt{h_t}e_t, \\ h_t &= \alpha_0 + \alpha_1\nu_{t-1}^2 + \beta_1h_{t-1}, \quad e_t \sim N(0, 1). \end{aligned} \quad (2.7)$$

끝으로, 외부 변수의 영향을 비교하기 위해 설명변수를 제외한 전력수요 로그분에 대한 AR(1)-GARCH(1, 1) 시계열모형은 식 (2.8)과 같다.

$$\begin{aligned} \log(x_t) &= \beta_0 + \beta_1\log(x_{t-1}) + \epsilon_t, \\ \epsilon_t &= \phi_1\epsilon_{t-1} + \phi_2\epsilon_{t-2} + \cdots + \phi_k\epsilon_{t-k} + \nu_t, \\ \nu_t &= \sqrt{h_t}e_t, \\ h_t &= \alpha_0 + \alpha_1\nu_{t-1}^2 + \beta_1h_{t-1}, \quad e_t \sim N(0, 1). \end{aligned} \quad (2.8)$$

2.5. 온도에 대한 모형 및 가중평균모형

전력수요 예측에 있어 설명변수인 온도, 주말, 공휴일이 중요한 설명변수로 이에 대한 가중평균모형들을 다음과 같이 고려한다.

$$y_t = \beta_0 + \beta_1|T - T_0| + \beta_2\text{Weekend} + \beta_3\text{holiday} + \epsilon_t, \quad \epsilon_t \sim N(0, \sigma^2). \quad (2.9)$$

Figure 1에서 보이듯이 전력수요와 온도는 15도를 경계로 대칭을 보이므로 T_0 는 15로 설정하였다. 식 (2.9)

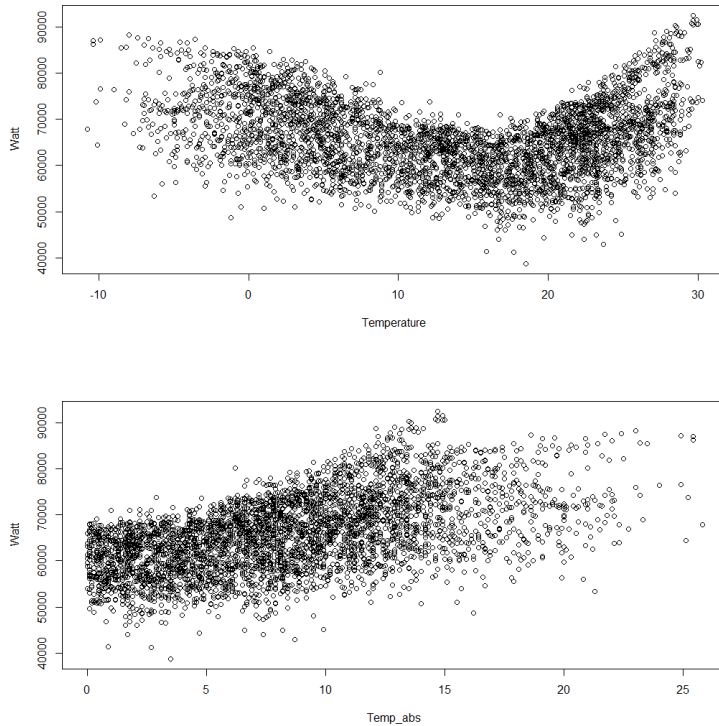


Figure 1: Daily maximum electricity demand vs. temperature.

에서 y 는 최대전력수요, T 는 온도, T_0 는 중심온도이다. weekend와 holiday는 가변수로서 1 또는 0을 배당한다. 최대전력수요는 Figure 2에서 보이는 바와 같이 해가 지날수록 증가하는 추세를 보인다. 이러한 추세는 온도모형만으로는 설명하기 어렵기 때문에 가장 최근의 데이터를 이용하여 회귀계수를 수정해 주어야 한다. 따라서 온도 모형에 의한 결과에 추세를 적용한 시계열 예측 결과를 적절히 혼합하여 전력수요를 설명하면 보다 정확한 예측이 가능할 것이다. 이를 위해 본 논문에서는 시계열 예측 결과에 회귀모형 예측결과를 반영한 가중평균모형을 제안한다.

가중평균모형을 시계열 분석에 적용하기 위해서 여러가지 시계열모형(가법 계절지수평활법, 승법 계절지수평활법, Seasonal ARIMA 모형)의 예측 결과 X_t 와 온도에 대한 회귀모형의 예측 결과 Y_t 에 적절한 가중치를 부여한다면 추세와 설명변수에 의한 변화를 동시에 반영할 수 있다. 이때, 가중평균에 의한 최종 수요 Z_t 는 식 (2.10)과 같이 표현된다.

$$Z_t = w_t \hat{X}_t + (1 - w_t) \hat{Y}_t. \tag{2.10}$$

여기서 \hat{X}_t 와 \hat{Y}_t 는 각각 Seasonal ARIMA 모형과 온도에 대한 회귀모형에 의한 수요의 추정치를 나타낸다. 최근 n 일 간의 상대오차제곱합(sum of squared errors)를 최소화하여 식 (2.11)를 유도하였다.

$$w_t = \frac{\sum_{k=t-1}^{t+n} \frac{(Z_k - \hat{Y}_k)(\hat{X}_k - \hat{Y}_k)}{Z_k^2}}{\sum_{k=t-1}^{t+n} \frac{(\hat{X}_k - \hat{Y}_k)^2}{Z_k^2}}. \tag{2.11}$$




Figure 2: Daily maximum electricity demand(10 years, year 2020.)

식 (2.11)의 사용은 실제 예측에 있어 매우 우수한 성능을 보인다. 여기서 중요한 것은 바로 n 값에 따라 예측 성능이 결정된다는 점이다. 따라서 n 값의 선택이 매우 중요하다. 본 연구에서는 경험적인 방법을 통해 연간 평균절대오차(mean absolute error, MAE)를 최소화하는 n 값을 최적의 값으로 결정하였다. 가중평균모형은 w , 의 값이 음이거나 1보다 큰 경우가 발생하는데 이는 가중평균의 개념과는 거리가 있다. 이 경우, 음에 대해서는 0, 1보다 큰 값에 대해서는 1을 취하면 된다.

3. 전력수요 예측모형의 개발

본 논문에서는 총 8가지의 데이터 모형을 바탕으로 일별 최대전력수요를 15일간 예측하여 비교하였다. 본 논문에서 식 (2.1)–(2.8)을 이용한 모형은 다음과 같다.

- 1) 가중평균모형을 사용한 가법적 지수평활법(additive smoothing + weighted average)
- 2) 가중평균모형을 사용한 승법적 지수평활법(multiplicative smoothing + weighted average)
- 3) 가중평균모형을 사용한 계절 ARIMA(SARIMA + weighted average)
- 4) 자기회귀오차모형(autoregressive error model)
- 5) 설명변수를 고려한 회귀모형(regression)
- 6) 설명변수를 고려한 AR-ARCH 회귀모형(AR-ARCH regression)
- 7) 설명변수를 고려한 AR-GARCH 회귀모형(AR-GARCH regression)
- 8) 시차만 설명변수로 고려한 AR-GARCH모형(AR-GARCH)

위 8가지 모형에 대해 시계열모형 적합성을 살펴보고 15일간 예측에 대해 평균잔차를 계산함으로써 각 모형의 예측력을 MAE 기준에서 비교하였다.

3.1. 데이터설명

본 논문에서 이용한 데이터는 2010년 1월부터 2020년 12월까지 일별 최대 전력수요 데이터이다. 이 중 2010년 1월 1일부터 2020년 12월 17일까지의 데이터를 트레이닝 데이터(training data)로써 모형 적합에 사용하고 2020년 12월 17일부터 2020년 12월 31일까지 15일치의 데이터를 테스트 데이터(test data)로써 모형 성능을 평가하는데 사용하였다. Figure 2로부터 전력수요 데이터는 시간의 흐름에 따라서 변동이 증가하고 계절성을 나타내는 특징을 갖고 있는 것을 알 수 있다. 또한, Figure 2에서 1년간의 전력수요를 보면 주말과 공휴일에 전력수요가 낮아지는 경향을 보이고 있다. 따라서 본 논문에서는 일별 전력수요를 예측하기 위한 수리적 모형을 전개한다. 본 논문에서 제시하는 모형은 온도, 주말, 공휴일의 설명변수를 고려한 시계열 분석과 가중평균법을 기반으로

Table 1: AIC, BIC on SARIMA model

	AIC	BIC
SARIMA (1, 1, 0) × (1, 1, 0) ₇	-13283.87	-13264.99
SARIMA (1, 1, 1) × (1, 1, 0) ₇	-13745.92	-13720.75
SARIMA (2, 1, 0) × (1, 1, 0) ₇	-13307.38	-13282.21
SARIMA (1, 1, 1) × (1, 0, 0) ₇	-12631.78	-12606.60

Table 2: Coefficients on SARIMA(1, 1, 1) × (1, 1, 0)₇ model

Parameter	Estimate	Standard Error	z Value	Approx Pr > z
ϕ_1	0.7765745	0.00100161	77.533	< 0.0001
θ_1	-0.9999994	0.00090592	-1103.8	< 0.0001
Φ_7	-0.4612164	0.01406122	-32.801	< 0.0001




Figure 3: MAE according to weight.

하고 있어 모형의 이해가 쉽고 사용이 용이하다는 장점이 있다.

3.2. 시계열모형

8가지 모형에 대해 시계열 적합성을 보기 위해 각 모형에 대한 최적화를 수행하였다. 모형3)인 seasonal ARIMA 모형은 변동이 시간에 따라 증가하는 경향이 있어 log 변환을 하여 분산을 안정화 시키고 계절성이 보여 계절 차분을 하였다. Seasonal ARIAM 모형에서 Akaike's information criterion (AIC)가 최소인 모형으로 식별하였다. Table 1과 같이 AIC를 고려한 최적 모형은 SARIMA(1, 1, 1) × (1, 1, 0)₇ 였다. 전력수요량에 대하여 조건부 최소제곱법에 의해 추정된 결과는 Table 2와 같다. 추정된 모든 모수의 p-value 는 0.05보다 작아 유의하게 나타났다.

또한, 시계열분석과 회귀분석의 가중치를 결정하기 위해 가중치별 잔차 평균은 Figure 3에서 보여 가중치 (w)는 0.8로 결정하였다.

3.3. 예측

모형의 예측 성능을 비교하기 위하여 mean absolute error (MAE)와 mean absolute percentage error (MAPE)를 사용하였으며 각 모형에 대한 값은 Table 3과 같다.

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - F_t|, \quad MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - F_t}{F_t} \right| \times 100(\%). \quad (3.1)$$

Table 3: MAE according to model

	MAE	MAPE
1) Additive smoothing + weighted average	2791	0.037
2) Multiplicative smoothing + weighted average	2614	0.035
3) SARIMA + weighted average	2049	0.028
4) Autoregressive error model	2329	0.032
5) Regression	1464	0.019
6) AR-ARCH regression	1408	0.019
7) AR-GARCH regression	1289	0.017
8) AR-GARCH	2494	0.034

Table 4: Estimates of model 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t
Intercept	7.848	0.099	79.5	< 0.0001
Lag1watt	0.286	0.009	32.2	< 0.0001
Temp-15	0.005	0.000	40.2	< 0.0001
Weekend	-0.160	0.002	-92.1	< 0.0001
Holiday	-0.105	0.001	-87.8	< 0.0001
AR(1)	-0.353	0.019	-19.0	< 0.0001
AR(2)	-0.162	0.014	-11.9	< 0.0001
AR(4)	0.057	0.012	4.8	< 0.0001
AR(5)	-0.123	0.012	-10.7	< 0.0001
AR(7)	-0.617	0.011	-55.9	< 0.0001
AR(8)	0.252	0.017	15.1	< 0.0001
ARCH(0)	0.000	0.000	15.8	< 0.0001
ARCH(1)	0.275	0.013	20.5	< 0.0001
GARCH(1)	0.660	0.013	49.8	< 0.0001
R^2	0.931			




Figure 4: Prediction of model 7.

각 모형별 예측력이 가장 좋은 모형은 모형7)로서 설명변수를 고려한 AR(1)-GARCH(1, 1) 회귀모형이며 이때 평균 절대 예측오차는 1,289로 나타나며 이때 MAPE는 0.017로 낮은 오차 비율을 보여준다. 모형7)의 모수 추정치는 Table 4와 같고 예측치를 실제값과 비교한 그림은 Figure 4와 같다.

이 때, n 은 예측에 사용한 데이터의 수이고($n=15$), Y_t 는 t 시점에서의 실제 값, F_t 는 t 시점에서의 예측 값을 의미한다.

4. 결론

본 연구는 여러 가지 시계열 예측방법에 대하여 비교분석하였다. 즉 가법 및 승법 Smoothing, SARIMA 모형을 이용하였고 또한 최대전력수요에 대한 예측을 보다 정확하게 하기 위하여 설명변수를 고려한 회귀모형을 이용하여 모형의 적합성을 높였다. 또한 시계열 모형을 보완하도록 가중평균모형을 제안하여 온도, 주말, 공휴일 변수를 추가하였으며 종합적으로 예측비교를 수행한 결과 AR-GARCH 회귀모형이 가장 좋은 예측력을 보여 주었다. 한편, 온도와 추세성을 고려한 가중중평균모형에서 가중치 0.8로서 시계열 모형의 예측부분이 온도의 회귀모형 예측값 보다 큰 영향을 미침을 보였다.

Acknowledgements

분석을 도와준 숙명여자대학교 정선아 대학원생에게 진심으로 감사드립니다.

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.
- Box GEP, Jenkins GM, and Reinsel GC (1994). *Time Series Analysis: Forecasting and Control*, Princeton-Hall International.
- Engle RF (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation, *Econometrica: Journal of the Econometric Society*, **50**, 987–1007.
- Jung S and Kim S (2014). Electricity demand forecasting for daily peak load with seasonality and temperature effects, *Journal of the Korean Data And Information Science Society*, **27**, 843–853.
- Kalimoldayev M, Drozdenko A, Kopyk I, Marinich T, Abdildayeva A, and Zhukabayeva T (2020). Analysis of modern approaches for the prediction of electric energy consumption, *Open Engineering*, **10**, 350–361.
- Lee JH, Oh SJ, Yoon Y, Ahn YH, Kim JS, Cho WS, and Lee SD (2019). Analysis of time series to support decision making on V2G using energy consumption data, *Journal of the Korean Data And Information Science Society*, **30**, 401–414.
- Park J, Kim YB, and Jung CW (2013). Short-term forecasting of city gas daily demand, *Journal of Korean Institute of Industrial Engineers*, **39**, 247–252.
- Taylor JW and Buizza R (2003). Using weather ensemble predictions in electricity demand forecasting, *International Journal of Forecasting*, **19**, 57–70.
- Winters PR (1960). Forecasting sales by exponentially weighted moving averages, *Management Science*, **6**, 324–342.

Received June 15, 2021; Revised July 6, 2021; Accepted July 7, 2021

최대 전력수요 예측을 위한 시계열모형 비교

권숙희,^a 김재훈,^a 손석만,^a 이성덕^{1,a}

^a충북대학교 정보통계학과

요 약

본 연구에서는 여러가지 시계열 모형 중 평활법(가법계절지수, 승법계절지수), 계절 ARIMA 모형, AR-ARCH 그리고 AR-GARCH 회귀모형을 이용하여 최대 전력수요를 예측하는 방법을 연구하였다. 이 때 가중 평균모형으로 추세를 갖는 시계열 모형과 온도에 대한 회귀 모형을 적절한 가중치로 예측 정확도를 높이는 방법도 연구하였다. 결과적으로 AR-GARCH 회귀모형으로 예측하는 것이 가장 우수함을 보였다.

주요용어: 최대 전력수요, 계절지수평활법, 가중평균모형, 계절 ARIMA 모형, ARCH, GARCH

¹¹교신저자: (28644) 충북 청주시 서원구 충대로 1, 교수, 충북대학교 정보통계학과. E-mail: sdlee@chungbuk.ac.kr