

The Performance of Time Series Models to Forecast Short-Term Electricity Demand

W. G. Park^a, S. Kim^{1,b}

^aDigital Inclusion Policy Division, NIA, ^bDepartment of Applied Statistics, Chung-Ang University

Abstract

In this paper, we applied seasonal time series models such as ARIMA, FARIMA, AR-GARCH and Holt-Winters in consideration of seasonality to forecast short-term electricity demand data. The results for performance evaluation on the time series models show that seasonal FARIMA and seasonal Holt-Winters models perform adequately under the criterion of Mean Absolute Percentage Error(MAPE).

Keywords: Seasonal FARIMA, AR-GARCH, ARIMA, Holt-Winters, Electricity Demand.

1. 서론

이상기온에 의한 에어컨 및 난방기기 사용량 증가와 국내 산업의 발달에 의한 전력 사용량 증가로 인하여 전력수요 예측에 중요성은 사용자들과 국가적으로 매우 중요한 문제가 되고 있다. 이러한 전력 예측이 잘못될 경우 2011년 9월 15일에 발생한 전국의 대규모 정전사태와 같이 국가적 문제가 될 수 있다. 전 세계적으로 이상고온 문제가 발생하는 상황에서 전력수요 예측은 국내만이 아니라 국제적인 문제로 대두되고 있다. 이러한 요구에 부응하여 전력수요예측 연구에 많은 연구자들이 다양한 통계적 방법을 제안하고 있다.

Ramanathan 등 (1997)는 지수평활법을 사용하여 온도와 기간을 고려한 수정 모형을 제안하였으며, Taylor (2003)는 이중 계절형 ARIMA 모형, 이중 계절형 Holt-Winters 모형을 비교분석하였다. Taylor (2010)는 삼중 계절형 모형을 통하여 다중계절형 단변량 단기 예측의 우수성을 보였다. Sohn과 Lim (2005) AR-GARCH 모형을 제안하였으며, Weron (2006)은 ARIMA 모형을 이용한 예측방법을 통하여 우수성을 보였다.

단기 전력수요예측은 자료의 측정이 짧은 단위로 이루어지며, 즉각적인 예측이 필요하다는 점에서 인터넷 트래픽 예측과 유사한 특징을 가진다. 이에 따라서 우리는 트래픽예측에서 사용된 모형을 단기 전력수요예측에 이용할 수 있다. 인터넷 트래픽 예측분야에서 Liu 등 (1996)의 Fractional ARIMA(FARIMA) 모형을 이용하여 트래픽을 예측하였으며, Kim (2011)은 seasonal AR-GARCH 모형과 다른 모형과의 성능비교를 하였다.

본 연구에서는 전력수요의 시계열 자료를 예측하는데 있어 일별과 주별 계절형을 고려한 모형들을 사용하였다. 이에 따라서 단기예측에서 많이 사용되는 계절형 ARIMA 모형과 계절형 Holt-Winters 모형, 장기 기억 특성을 설명할 수 있는 계절형 FARIMA 모형, 분산의 이분산성을 설명할 수 있는 계절형 AR-GARCH 모형을 이용하여 전력수요 예측의 성능 비교를 하고자 한다.

This research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education, Science and Technology (2012-220095).

¹ Corresponding author: Professor, Department of Applied Statistics, Chung-Ang University, 221 Heukseok-Dong, Dongjak-Gu, Seoul 156-756, Korea. E-mail: sahm@cau.ac.kr

2. 시계열 모형 소개

본 논문에서는 단변량 시계열 모형 중 대표적인 ARIMA 모형과 Holt-Winters 모형, AR-GARCH 모형을 사용하였으며, 장기기억모형 중 대표적인 FARIMA 모형을 사용하고자 한다. 또한 모형들이 일별과 주별에 따른 주기가 나타남에 따라서 이중 계절형 모형을 사용하고자 한다.

2.1. 계절형 ARIMA 모형

단변량 시계열 모형 중 수요예측에 사용하는 분석 방법 중에서 가장 널리 이용되는 방법의 하나는 Box와 Jenkins (1976)의 자기회귀누적이동평균(Autoregressive Integrated Moving Average; ARIMA) 모형이다. ARIMA 모형은 다른 설명변수의 도입이 없어도 교란항만과 과거치만으로 시계열에 적합한 모형을 설정할 수 있도록 하는 가장 기본적인 방법이다. 이 모형은 단기예측과 계절형 변동을 포함하는 시계열의 분석에 효과적이다.

Box의 이중 계절형 자기회귀누적이동평균의 기본 형태를 보면 (2.1)의 모형과 같다.

$$\phi_p(B)\Phi_{P_1}(B^{s_1})\Pi_{P_2}(B^{s_2})(1-B)^d(1-B^{s_1})^{D_1}(1-B^{s_2})^{D_2}Z_t = \theta_q(B)\Theta_{Q_1}(B^{s_1})\Psi_{Q_2}(B^{s_2})\epsilon_t, \quad (2.1)$$

여기서 B 는 $B^k Y_t = Y_{t-k}$ 에 연산을 맡는 후진연산자이고, $\phi_p(B)$ 와 $\theta_q(B)$ 는 p 차 AR과 q 차 MA를 의미한다. $\Phi_{P_1}(B^{s_1})$, $\Pi_{P_2}(B^{s_2})$, $\Theta_{Q_1}(B^{s_1})$, $\Psi_{Q_2}(B^{s_2})$, s_1 , s_2 를 따르는 P_1 , P_2 , Q_1 , Q_2 차 계절성 AR과 계절성 MA를 의미한다. d , D_1 , D_2 는 차분의 차수를 말하며 ϵ_t 는 평균 0과 고정된 분산을 따르는 백색잡음과정이다. 다항식 $\phi_p(B) = 0$, $\theta_q(B) = 0$, $\theta_q(B) = 0$, $\Psi_{Q_2}(B^{s_2}) = 0$, $\Phi_{P_1}(B^{s_1}) = 0$, $\Pi_{P_2}(B^{s_2}) = 0$ 의 근은 단위원 밖에 위치한다.

2.2. 계절형 Holt-Winters 모형

Holt-Winters 지수평활법은 계절형 시계열 예측에 사용되는 잘 알려진 방법이다. 지수평활법은 계산이 쉽다는 점과 필요정보의 양이 최소화 된다는 장점을 지니고 있고, 계산이 다른 모형보다 쉽다는 장점이 있어, 자동화된 설비 분야에서 널리 사용된다. 이것은 Holt-Winters 방법이 전력수요예측 분야에서 사용될 수 있다는 것을 의미한다. Holt-Winters 지수평활법은 하나의 계절성을 적합한 방법으로 Winters에 의해 소개되었다. Y_t 는 고려할 t 시점의 전력수요량으로 계절주기를 s 라고 하면 L_t 는 t 시점의 평활수준을 나타낸다. T_t 는 t 시점의 평활가법추세를 의미하며, S_t 는 t 시점의 계절지표를 의미한다. α , β 는 수준과 추세에 대한 모수이고 γ 는 계절평활 모수이며, F_t 는 h 시점 후에 예측한 값을 의미한다.

$$\begin{aligned} L_t &= \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1}), \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}, \\ S_t &= \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s}, \\ F_{t+h} &= L_t + T_t \times h + S_{t+h-s}. \end{aligned} \quad (2.2)$$

이중 계절성을 적용시킨 계절형 Holt-Winters 지수평활법은 식 (2.3)과 같이 적용된다. 여기서 Y_t 는 고려할 t 시점의 전력수요량으로 계절주기를 S_1 과 S_2 라 하면 L_t 는 t 시점의 평활수준을 나타내며, T_t 는 t 시점의 평활가법추세를 의미하며, S_t 와 D_t 는 t 시점의 계절주기 S_1 과 S_2 의 계절지표를 의미한다.

$$\begin{aligned} L_t &= \alpha(Y_t - S_{t-s_1} - D_{t-s_2}) + (1 - \alpha)(L_{t-1} + T_{t-1}), \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}, \\ S_t &= \gamma(Y_t - L_t - D_{t-s_2}) + (1 - \gamma)S_{t-s_1}, \end{aligned}$$

$$\begin{aligned} D_t &= \delta(Y_t - L_t - S_{t-s_1}) + (1 - \delta)D_{t-s_2}, \\ F_{t+h} &= L_t + T_t \times h + S_{t+h-s_1} + D_{t+h-s_2}. \end{aligned} \quad (2.3)$$

식 (2.3)의 초기값은 식 (2.4)의 계산을 통하여 나타난다.

$$\begin{aligned} L_{s_1} &= \frac{1}{s_1} \sum_{t=1}^{s_1} Y_t, & L_{s_2} &= \frac{1}{s_2} \sum_{t=1}^{s_2} Y_t, \\ T_{s_1} &= \frac{1}{s_1^2} \left(\sum_{t=s_1+1}^{2s_1} Y_t - \sum_{t=1}^{s_1} Y_t \right), & T_{s_2} &= \frac{1}{s_2^2} \left(\sum_{t=s_2+1}^{2s_2} Y_t - \sum_{t=1}^{s_2} Y_t \right), \\ S_1 &= Y_1 - L_{s_1}, \dots, S_{s_1} = Y_{s_1} - L_{s_1}, \\ D_1 &= Y_1 - L_{s_2}, \dots, D_{s_2} = Y_{s_2} - L_{s_2}. \end{aligned} \quad (2.4)$$

평활 모수 $\alpha, \beta, \gamma, \delta$ 는 1차 예측단계에서 AIC(Akaike's information criterion)를 최소화하는 과정에서 계산된다.

2.3. 계절형 AR-GARCH 모형

실제적인 시계열 예측 및 모델링을 하는 데에 있어, 이분산성이 많이 발생한다. 이에 대하여 Engle (1982)과 Bollerslev (1986)는 이분산 문제점을 다루는 방법으로 ARCH와 GARCH 모형을 제안했다. GARCH 모형은 과거 변화율의 변동성의 자기상관성을 직접 모형화 하여 변동성의 계수추정을 했기 때문에 과거에 실현된 변동성을 잘 설명한다. GARCH 모형은 분산에 대한 모형을 적용함으로써 모형의 추정 및 예측을 가능하게 한다. AR(k)-GARCH(p, q) 모형은 다음과 같은 형태로 나타낸다.

$$\begin{aligned} y_t &= \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_k y_{t-k} + \epsilon_t, \\ \epsilon_t &= e_t \sqrt{h_t}, \\ h_t &= \alpha_0 + \sum_{j=1}^p \alpha_j \epsilon_{t-j}^2 + \sum_{j=1}^q \beta_j h_{t-j}, \end{aligned} \quad (2.5)$$

여기서 $e_t \sim iid N(0, \sigma^2)$, $\alpha_0 > 0$, $\alpha_1 \geq 0$, $\beta_1 \geq 0$, $\alpha_1 + \beta_1 \leq 1$ 을 가정한다. 계절요소에 의한 영향을 고려하기 위하여 우리는 식 (2.6)과 같은 형태로 계절형 AR-GARCH 모형을 정의한다.

$$\begin{aligned} \phi_p(B)\Phi_{p_1}(B^{s_1})\Pi_{p_2}(B^{s_2})Y_t &= \epsilon_t, & \epsilon_t &= e_t \sqrt{h_t}, \\ e_t &\sim iid N(0, \sigma^2), \\ h_t &= \alpha_0 + \sum_{j=1}^p \alpha_j \epsilon_{t-j}^2 + \sum_{j=1}^q \beta_j h_{t-j} + \sum_{j=1}^{p_1} \alpha_{js_1} \epsilon_{t-js_1}^2 + \sum_{j=1}^{p_2} \alpha_{js_2} \epsilon_{t-js_2}^2 + \sum_{j=1}^{q_1} \beta_{js_1} h_{t-js_1} + \sum_{j=1}^{q_2} \beta_{js_2} h_{t-js_2}, \end{aligned} \quad (2.6)$$

여기서 s_1, s_2 는 t 시점에서 계절주기를 의미하며 AIC(Akaike Information Criterion)가 최소인 모형을 최적의 모형으로 결정한다.

2.4. 계절형 FARIMA 모형

Fractional Seasonal ARIMA(FSARIMA)는 표준 Seasonal ARIMA(p, d, q) 모형의 일종으로서 d 가 자연수가 아닌 실수를 가지는 모형이다. 이 모형은 장기기억특성을 반영한 모형이다. 이중 계절성

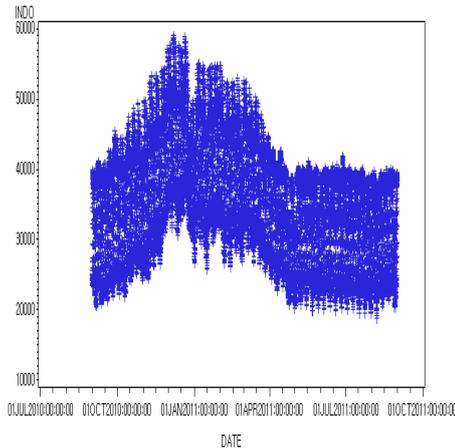


Figure 1: Time plot for original data

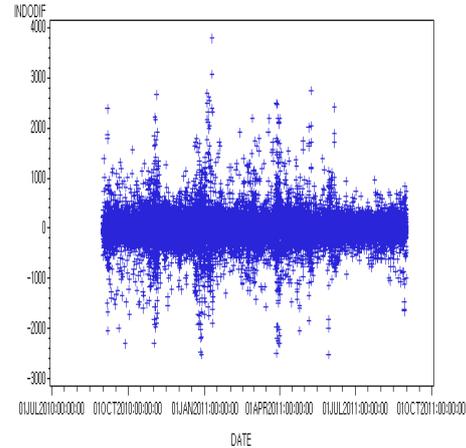


Figure 2: Time plot for differenced with lag 1 and 336

FARIMA는 seasonal ARIMA(p, d, q)에 대해 시계열 Z_t 는 식 (2.7)과 같이 정의된다.

$$\phi_p(B)\Phi_{p_1}(B^{s_1})\Pi_{p_2}(B^{s_2})\Delta^d Z_t = \theta_q(B)\Theta_{q_1}(B^{s_1})\Psi_{q_2}(B^{s_2})\epsilon_t, \quad (2.7)$$

여기서 s_1, s_2 는 계절 성분의 주기이고, ϵ_t 는 평균 0과 고정된 분산을 따르는 백색잡음과정이며 모형의 정상성을 위해 이며, $d \in (-0.5, 0.5)$ 는 분수차분 연산자(fractional differencing operator)로 식 (2.8)과 같이 정의된다.

$$\Delta^d = (1 - B)^d = \sum_{k=0}^{\infty} \binom{d}{k} (-B)^k, \quad (2.8)$$

$\binom{d}{k} = d!/(d-k)!k!$ 이다. 만약 $d = 0$ 이면, FSARIMA 모형은 일반적인 SARIMA 모형이 된다.

3. 모형의 성능분석결과

본 논문에서 이용한 자료는 UK National Grid사로부터 얻은 영국의 전력수요 자료로 1971년 4월 1일부터 현재까지 30분 단위로 측정된 자료이다. 실제 분석에는 2010년 9월 1일부터 2011년 9월 14일 까지 18192개 자료를 이용하였다. 모형 적합에 있어 계절주기는 1일에 해당하는 48과 1주일에 해당하는 336을 이용하였고, 2010년 9월 1일부터 2011년 8월 31일까지의 17520개의 자료를 이용하였다. 적합된 모형을 통하여 14일치 자료에 해당하는 2011년 9월 1일부터 2011년 9월 14일에 672개 자료를 이용하여 모형을 평가 하였다.

모형 적합과 정상성을 만족시키기 위해 원 자료를 식 (3.1)과 같이 1차 차분과 336차 차분 후 모수를 추정하였고, 계절형 Holt-Winters 모형은 원 자료를 이용하여 모수를 추정하였다.

$$Z_t = (Y_t - Y_{t-1}) - (Y_{t-336} - Y_{t-337}). \quad (3.1)$$

이와 같은 자료에 대한 시계열 그림은 Figure 1과 Figure 2와 같다. Figure 1은 18192개에 대한 원 자료이고, Figure 1은 식 (3.1)과 같이 원자료에 대해 1차 차분과 336차 차분을 실시한 자료이다.

계절형 Holt-Winters 모형의 모수는 AIC값을 최소화하는 값을 추정치로 하였으며, FARIMA 모형에서는 변환된 자료에 대하여 차분치(d)를 추정한 후, 계절형 ARIMA를 이용하여 나머지 모수를 추정 하였다.

Table 1: Estimates of Seasonal ARIMA

모수	추정값	표준오차	모수	추정값	표준오차
θ_1	0.4235	0.088	ϕ_1	0.9132	0.0879
θ_2	0.8827	0.0175	ϕ_2	0.6445	0.0377
θ_3	-0.4322	0.0855	ϕ_3	-0.9295	0.0824
θ_4	0.1046	0.0169	ϕ_4	0.3215	0.0405
$\Theta_{1(48)}$	0.6038	0.0062	$\Pi_{1(336)}$	0.1499	0.0110
$\Psi_{1(336)}$	0.7687	0.0071			

Table 2: Estimates of Seasonal AR-GARCH

모수	추정값	표준오차	모수	추정값	표준오차
θ_1	-0.1309	0.0062	α_0	20207	389.3482
θ_2	-0.0453	0.0056	α_1	0.2888	0.0091
θ_3	-0.0331	0.0051	α_2	0.1177	0.0069
θ_4	-0.0176	0.0047	$\alpha_{1(48)}^*$	0.1692	0.0068
$\Theta_{1(48)}$	0.5436	0.0067	$\alpha_{2(48)}^*$	0.1277	0.0068
$\Theta_{2(48)}$	0.2880	0.0068			
$\Theta_{3(48)}$	0.1345	0.0052			

Table 3: Estimates of Seasonal Holt-Winters

모수	추정값	표준오차
LEVEL	0.9999	0.0059
TREND	0.7200	0.0078
SEASONAL	0.0013	0.0081

Table 4: Estimates of Seasonal FARIMA

모수	추정값	표준오차	모수	추정값	표준오차
θ_1	0.79072	0.01242	ϕ_1	0.8627	0.0087
θ_2	0.06373	0.01661	Φ_2	1.9569	0.0081
θ_3	0.09757	0.01630	Φ_3	-0.9601	0.0077
θ_4	0.04798	0.01438	$\Pi_{1(336)}$	0.0856	0.0206
$\Theta_{1(48)}$	1.71033	0.01340	$\Pi_{2(336)}$	-0.0354	0.0176
$\Theta_{2(48)}$	-0.72185	0.01186			
$\Psi_{1(336)}$	0.82540	0.01752			
추정된 차분치	\hat{d}	0.32540			

이분산 모형에서는 이분산성이 존재하는지에 대한 LM test 결과 이분산성이 존재하는 것으로 나타났으며, 이에 따라 계절형 AR-GARCH 모형을 선택하였다. 모형의 성능비교를 위하여 MAPE(Mean Absolute Percentage Error)를 사용하며, 이는 식 (3.2)와 같이 정의된다.

$$MAPE = \frac{1}{n-m} \sum_{t=m+1}^n \frac{|Y_t - F_t|}{Y_t} \times 100\%, \quad (3.2)$$

여기서 Y_t 는 실제값, F_t 는 예측값이다. MAPE는 실제값과 예측오류사이의 비율을 제공함으로써 업계에서 사람들에게 의해 선호되고 쉽게 해석된다. Hippert 등 (2001)에서 언급되었듯이 MAPE가 업계 표준으로 지정이 되었으므로 이를 사용하도록 한다. 이와 함께 RMSE(Root Mean Square Error)를 사용하도록 하겠다.

Table 5: MAPE for Half-hourly ahead forecasting

시간대(시)	ARIMA	HW	AR-GARCH	FARIMA	RW	전력변화량
0~3시	0.6032	0.6290	0.7791	0.5132	2.5873	-3633
3~6시	0.6603	0.4514	0.5854	0.7785	1.2847	1103
6~9시	1.5070	1.2681	2.1190	2.0484	6.2721	11248
9~12시	0.3627	0.4349	0.6512	0.3594	1.3010	2660
12~15시	0.3195	0.2062	0.3323	0.3610	0.5996	-1007
15~18시	0.3293	0.3521	0.5121	0.4294	0.9247	1392
18~21시	0.4767	0.6790	0.5092	0.7588	0.8931	-172
21~24시	0.3347	0.4735	0.4160	0.4253	5.7738	-10654

Table 6: MAPE for the 2-week post-sample period

일자	ARIMA	HW	AR-GARCH	FARIMA	RW
1일(목)	1.3283	1.2430	1.3715	1.1974	2.4681
2일(금)	1.6923	1.6196	2.3140	1.4829	2.4088
3일(토)	1.3181	11.2280	1.8811	1.8344	2.3186
4일(일)	1.8841	12.9690	2.1438	4.7078	2.4627
5일(월)	4.1849	2.3077	8.9841	9.9534	2.6511
6일(화)	4.2507	4.0642	5.6956	3.5208	2.6635
7일(수)	6.4936	4.6329	10.5813	2.2166	2.6471
8일(목)	5.7115	7.5125	9.3928	2.4070	2.6141
9일(금)	5.6787	7.9785	11.4035	1.6762	2.4027
10일(토)	8.8388	7.7241	17.4108	1.6644	2.4723
11일(일)	13.0843	10.6774	22.4170	2.0491	2.6288
12일(월)	9.8975	7.1232	14.3128	8.8339	2.8313
13일(화)	14.8470	9.0825	26.7111	2.5429	2.6237
14일(수)	14.3926	11.9580	30.0017	2.3449	2.5423

Table 7: RMSE for Half-hourly ahead forecasting

시간대(시)	ARIMA	HW	AR-GARCH	FARIMA	RW	전력변화량
0~3시	268.6586	280.1497	347.0026	228.5736	1152.3550	-3633
3~6시	294.0904	201.0486	260.7307	346.7353	572.1912	1103
6~9시	671.2012	564.7978	943.7793	912.3348	2793.5243	11248
9~12시	161.5426	193.6997	290.0373	160.0728	579.4511	2660
12~15시	142.3018	91.8392	148.0028	160.7854	267.0552	-1007
15~18시	146.6666	156.8215	228.0837	191.2500	411.8512	1392
18~21시	212.3169	302.4191	226.7921	337.9612	397.7769	-172
21~24시	149.0717	210.8917	185.2818	189.4239	2571.5870	-10654

계절형 ARIMA 모형은 $ARIMA(p, d, q) \times (P_1, D_1, Q_1)_{s_1} \times (P_2, D_2, Q_2)_{s_2}$ 와 같이 표기되는데, 예측된 모형은 $ARIMA(4, 1, 4) \times (0, 1, 1)_{48} \times (1, 1, 1)_{336}$ 와 같이 나타났다. 계절형 AR-GARCH 모형도 AIC가 최소인 모형을 선택하였다. GARCH 모형만을 적용 시에 적용이 되지 않음에 따라서 변수간의 상관성을 보정하기 위하여 $AR(4)(3)_{48}$ 를 적용시킨 $AR(4)(3)_{48}$ -GARCH(2, 0)(2, 0)₄₈ 모형을 선택하며, 계절형 Holt-Winters 모형은 최적화된 가중치를 적용하여 모형을 결정한다. FARIMA에 경우 d 의 추정값은 0.3254이다. 이에 따라 결정된 모형들의 모수추정량은 Table 1에서 Table 4와 같이 나타난다.

Table 6과 Table 8은 Multi-step 미래예측을 하기위하여 14일까지의 미래 예측을 MAPE와 RMSE로 실시하였다. Holt-Winters의 경우 2일까지는 우수한 모형을 보였으나 예측 중간에 주말이 있을 경우 예

Table 8: RMSE for the 2-week post-sample period

일자	ARIMA	HW	AR-GARCH	FARIMA	RW
1일(목)	591.6112	491.744	566.8468	503.9547	1103.5370
2일(금)	601.0732	622.846	821.5312	508.4176	1072.2870
3일(토)	427.7703	4070.020	622.4852	670.0374	875.4839
4일(일)	629.3098	4609.210	697.3460	1490.7180	911.8677
5일(월)	1508.7670	1032.587	3828.6230	4102.0920	1180.9090
6일(화)	1490.9730	1681.163	2059.2560	1205.2840	1214.7640
7일(수)	2100.7810	1768.693	3364.7410	816.2610	1227.5690
8일(목)	1885.9310	2704.782	3124.7720	1005.6110	1234.1170
9일(금)	1891.7450	2684.508	3844.6410	924.5726	1136.2600
10일(토)	2648.9150	2542.193	5116.4140	627.3937	913.2766
11일(일)	3518.9280	3848.007	6003.0010	793.9792	930.0724
12일(월)	3195.8030	2642.386	4866.5030	3858.0810	1257.6950
13일(화)	4750.7560	3005.556	8597.4830	975.2963	1222.0330
14일(수)	4582.1520	4086.845	9588.4680	927.9320	1228.2160

측에서 저조한 수치를 보였다. ARIMA 모형의 경우는 4일까지의 예측에서 RW보다 나은 수치를 보였으나 그 이후에는 예측이 저조하였다. AR-GARCH 모형 또한 이와 비슷하게 나타났다. 이에 대한 장기 예측 방법으로 FARIMA 모형이 장기예측에 경우에는 우수한 결과가 나타난다고 할 수 있다.

4. 결론

본 연구에서는 계절주기를 일별과 주별로 48과 336의 2개의 계절주기를 이용한 이중 계절형 ARIMA, Holt-Winters, AR-GARCH, FARIMA 모형을 사용하였다. 추가적으로 RW 모델을 사용한 예측값을 기준으로 다른 모형들과 비교를 하였다. 3일간의 자료에 대하여 1차 시점 미래예측과 Multi-step 예측을 통하여 6시간 예측과 2주간의 예측을 실시하였으며, 이에 대하여 MAPE를 통하여 비교하였다.

1차 시점 예측을 통한 30분 단위 예측의 경우 전체적으로 RW보다 우수하였으며, 이는 시간대별 전력수요 변화량에 따라 우수한 모형들이 다르게 나타났다. 계절형 AR-GARCH 모형의 경우 변동성이 강한 경우 잘 예측을 해 주었고, 계절형 ARIMA 모형과 계절형 Holt-Winters 모형은 대부분의 시간에서 좋은 예측을 했다. 또한 계절형 FARIMA 모형은 급격하게 전력수요가 증가하는 경우, 계절형 ARIMA 모형이나 계절형 Holt-Winters 모형보다 반응하지 못하였지만 대체적으로 잘 예측하였다.

2주 내의 예측 결과를 보면 대부분 2일 예측 이후에는 급격히 예측을 잘 못하는 것으로 나타났지만, 계절형 FARIMA 모형에 경우는 예측이 대부분 우수하게 나타났다. 하루에 단기 전력수요 예측에 대한 추가적인 연구가 필요할 것이며, 향후에 본연구의 결과를 통대로 국내자료를 이용하여 다양한 수요예측 방법의 비교 분석을 실시할 필요성이 있다고 사료된다. 추가적으로, 본 연구에서는 단기 수요예측에 집중하여, 년도 별 계절성은 고려하지 않았다. 이에 대하여는 차후에 5년 이상에 증장기 시계열 자료를 확보하여 분석 시 고려할 필요성이 있다.

References

- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity, *Journal of Econometrics*, **31**, 307–327.
- Box, G. E. P. and Jenkins, G. M. (1976). *Time Series Analysis Forecasting and Control, 1st, Holden-Day, Inc, San Francisco.*

- Engle, R. F. (1982). Autoregressive conditional heteroskedasticity with estimates of the variance of U. K. Inflation, *Econometrica*, **50**, 987–1008.
- Hippert, H. S., Pedreira, C. E. and Souza, R. C. (2001). Neural networks for short term load forecasting: A review and evaluation, *IEEE Transactions on Power Systems*, **16**, 44–55.
- Kim, S. (2011). Forecasting internet traffic by using seasonal GARCH models, *Journal of Communications and Network*, **13**, 621–624.
- Liu, J., Shu, Y., Zhang, L. and Xue, F. (1999). Traffic modeling based on FARIMA models, *IEEE Canadian Conference on Electrical and Computer Engineering*, 621–624.
- National Grid: Nationalgrid UK - Metered half-hourly electricity demands (2010). *Nationalgrid*, Available from: <http://www.nationalgrid.com/uk/Electricity/Data/Demand+Data/>
- Ramanathan, R., Engle R., Granger, C. W. J., Vahid-Araghi, F. and Brace, C. (1997). Short-run forecasts of electricity loads and peaks, *International Journal of Forecasting*, **13**, 161–174.
- Sohn, S. Y. and Lim, M. (2005). Hierarchical forecasting based on ar-garch model in a coherent structure European, *Journal of Operational Research*, **176**, 1033–1040.
- Taylor, J. W. (2003). Short-term electricity demand forecasting using double seasonal exponential smoothing, *Journal of the Operational Research Society*, *JSTOR*, 799–805.
- Taylor, J. W. (2010). Triple seasonal methods for short-term electricity demand forecasting, *European Journal of Operational Research*, **204**, 139–152.
- Weron, R. (2006). Modeling and forecasting electricity loads and prices: A statistical approach, *Wiley*, Chichester.