

## Enhancing Summer Electricity Demand Forecasting Using Fourier Transform-Based Time Variables

Jae-Ho Shin\*, Hyun-Uk Seol\*\*, Han-Byeol Jo\*\*, Jong-Kwon Jo\*\*, Sung-Ju Kim\*\*\*,  
Byoung-Ho Jang\*\*\*\*, Young-Soon Kim\*\*\*\*\*

\*Graduate student, Dept. of Information and Statistics, Gyeongsang National University, Jinju, Korea

\*\*Senior Researcher, Big-AI Inc., Changwon, Korea

\*\*\*Senior Researcher, Interpretation Support Office, Korea Electrotechnology Research Institute, Changwon, Korea

\*\*\*\*CEO, Big-AI Inc., Changwon, Korea

\*\*\*\*\*Associate Professor, Dept. of Information and Statistics, Dept. of Bio & Medical Bigdata (BK4 program),  
Gyeongsang National University, Jinju, Korea

### [Abstract]

In the summer, when the cooling load rises due to high temperatures, the hourly demand increases during the day and is relatively less at night compared to the day. These characteristics are considered important information in predicting summer electricity demand. However, if time information is simply expressed as a dummy variable, the model simply recognizes differences between time zones rather than learning changes in time. In this study, we would like to approach this problem by using a time variable using the Fourier transform. Time variables using the Fourier transform will be able to effectively learn differences between times. As a result of evaluating the type of time variable in the summer electricity demand forecast for 2022 and 2023 using the BiGRU model, the model using the time variable using Fourier transform showed the best performance with MAPE of 2.01% and 2.04% confirmed. The results of this study are expected to improve prediction accuracy in the summer when power usage increases and prevent problems such as large-scale power outages.

▶ **Key words:** Summer Season, Load, Summer Power, Demand Forecast, Fourier transform, BiGRU

- 
- First Author: Jae-Ho Shin, Hyun-Uk Seol, Corresponding Author: Young-Soon Kim, Byoung-Ho Jang
  - \*Jae-Ho Shin (psyand123@naver.com), Dept. of Information and Statistics, Gyeongsang National University
  - \*\*Hyun-Uk Seol (seolleim@big-ai.kr), Big-AI Inc.
  - \*\*Han-Byeol Jo (hanbyeoljo98@big-ai.kr), Big-AI Inc.
  - \*\*Jong-Kwon Jo (jjkwon@big-ai.kr), Big-AI Inc.
  - \*\*\*Sung-Ju Kim (ksj800708@keri.re.kr), Interpretation Support Office, Korea Electrotechnology Research Institute
  - \*\*\*\*Byoung-Ho Jang (admin@big-ai.kr), Big-AI Inc.
  - \*\*\*\*\*Young-Soon Kim (youngsoonkim@gnu.ac.kr), Dept. of Information and Statistics, Dept. of Bio & Medical Bigdata (BK4 program), Gyeongsang National University
  - Received: 2024. 09. 20, Revised: 2024. 10. 11, Accepted: 2024. 10. 24.
  - This paper is an extension of the paper Summer Electricity Demand Forecasting Using Fourier Transform-Based Time Variables presented at the 68th Summer Conference of the Korea Society of Computer Information in 2024.

## [요 약]

높은 기온으로 인해 냉방부하가 상승하는 하절기의 낮에는 시간당 전력 수요가 증가하고 밤에는 낮에 비해 상대적으로 전력수요가 적은 특징을 보인다. 이러한 특징은 하계 전력 수요 예측에 있어 중요한 정보로 간주한다. 그러나 시간 정보를 단순히 더미변수로 표현할 경우, 모델은 시간의 변화를 학습하기보다는 단순히 시간대 간의 차이를 인식하는 데 그치게 된다. 본 연구에서는 이러한 문제를 해결하기 위해 푸리에 변환을 활용하여 시간 변수를 사용한 방식으로 접근하고자 한다. 푸리에 변환을 이용한 시간 변수는 시간 간의 차이를 효과적으로 학습할 수 있을 것이다. BiGRU 모델을 사용하여 2022년과 2023년의 하계 전력 수요예측에 시간 변수의 형식에 따른 평가를 수행한 결과 푸리에 변환을 사용한 시간 변수를 사용한 모델이 MAPE 2.01%, 2.04%로 가장 우수한 성능을 보이는 것을 확인하였다. 본 연구의 결과는 전력 사용량이 증가하는 하절기의 전력 사용량 예측 정확도를 높여, 대규모 정전 사태와 같은 문제를 방지할 수 있을 것으로 기대한다.

▶ **주제어:** 하절기, 부하, 하계 전력 수요 예측, 푸리에 변환, BiGRU

## I. Introduction

전력 수요 예측은 안정적인 전력 공급을 보장하고, 지속 가능한 전력 시스템을 구축하는 데 필수적인 요소이다. 또한, 에너지 계획 및 정책 수립에도 중요한 역할을 한다. 부정확한 전력 수요 예측은 발전/송배전 설비의 갑작스러운 가동, 전력 추가 구매로 말미암은 비용 증가, 불필요한 전력 생산 등의 문제점을 초래할 수 있다[1]. 특히, 우리나라의 여름철은 더위로 인해 에어컨 사용량이 급증하는 특성이 있어 예비 전력 부족으로 인한 대규모 정전 사태를 대비해야 한다. 이에 따라 충분한 예비 전력 확보를 위해 정확한 전력 수요 예측의 중요성이 더욱 강조되고 있다.

최근 몇 년간 정부의 탈원전 정책과 기후변화 및 탄소 중립 실천을 위한 재생에너지 확대 보급 등 전력 계통 운영과 관련된 주변 환경의 급격한 변화가 일어나고 있다[2]. 에너지경제연구원에서 발표한 “코로나19가 한국의 전력 수급에 미친 영향 분석” 보고서에 따르면 코로나19가 국내 유입된 이후, 재택근무 등의 증가로 가정용 전력 사용량이 증가하고, 비계량 재생에너지로 인한 전력 수요 변동성이 커지면서 이전과는 다른 전력 수요 패턴이 발생하고 있음을 확인할 수 있다[2].

기존 전력 수요예측 기법은 자기회귀(Autoregressive, AR), 이동평균(Moving average, MA), 자기회귀 누적 이동평균(ARIMA) 모델, 지수평활법과 같은 통계적 기법을 사용하거나 서포트 벡터 머신 (Support Vector Machine, SVM) 등의 시계열 데이터를 처리하는 기계학습기법을 사용한 연구가 진행되었다[1][3][4][5][6]. 이러한 예측 방법들은 통계적 기법을 사용하여 예측하기 때문에

모델 선정, 파라미터 조정에 따른 성능이 크게 좌우되었으며 특정 이벤트가 발생하거나 급작스러운 기후변화에 따른 변동성을 예측 결과에 제대로 반영하지 못하는 단점이 존재한다[1]. 또한 전력 수요 데이터는 월별, 요일별, 그리고 시간별로 각각 다른 계절성을 보이며, 이러한 변수들의 특성이 모두 달라서 전력 수요 예측을 위해서는 이러한 계절성을 고려하여 적합한 모델을 선택해야 한다[7][8].

최근에는 시계열 데이터를 처리할 수 있는 딥러닝 모델인 순환신경망 계열 모델들이 주로 사용되고 있다[9][10][11][12]. 순환신경망계열 모델에는 순환신경망(Recurrent Neural Network, RNN)이 있고, RNN의 기울기 소실 문제를 해결하기 위해 게이트 연산을 도입한 장단기 메모리(Long Term Short Memory, LSTM)과 게이트 연산을 간략화 시킨 순환 게이트 유닛(Gated Recurrent Unit, GRU)이 있다[13][14]. 또한, 순환 신경망을 양방향으로 쌓아, 양방향 학습을 가능하게 한 양방향(Bidirectional)구조가 있다[15].

하계 전력 수요예측을 위한 최적의 순환 신경망 구조를 찾기 위해서 LSTM과 GRU의 조합모델들을 고려하여 168시간으로 24시간을 예측하는 실험을 수행한 후, BiGRU가 다른 조합모델들과 비교하여 우수한 성능을 나타낸 것을 확인하였다[16]. 또한, 해당 연구에서는 기상인자에 대한 실험에서 기상인자를 모두 포함시키기보다 체감온도와 불쾌지수를 포함시키는 모델이 예측성능이 더 높았다. 해당 연구는 시간 변수는 고려하지 않았다. 전력 수요는 시간 별로 매주 일정한 패턴을 보이며, 이러한 패턴을 모델이 학습

하여 예측에 사용한다면 성능이 향상할 것으로 기대된다. 그러나 시간 변수를 그대로 포함시키면 시간의 차이를 크기의 차이로 학습할 위험이 있어 변환을 하여 사용하는데 어떠한 변환을 사용하는가에 따라 성능이 달라질 수 있다. 본 연구에서는 시간 변수의 영향력을 확인하기 위해, 시간 변수를 포함하지 않은 모델과 시간 변수를 포함하는 모델들을 비교하는 연구를 진행하였다. 평균절대비오차(Mean Absolute Percentage Error, MAPE)와 평균절대오차(Mean Absolute Error, MAE)를 평가지표로 사용하였다.

본 논문의 구성은 다음과 같다. 2절에서는 모델에 사용된 공통 변수들에 대한 설명과 BiGRU의 구조를 확인하고, 3절에서는 시간 변수가 예측에 미치는 영향과 시간 변수의 종류에 대해 살펴본다. 4절에서는 비교 실험을 수행하기 위한 환경과 실험 결과를 확인하고, 5장에서 결론을 맺는다.

## II. Preliminaries

### 1. Variables

선행 연구에서는 전력 수요 예측을 위해 사용되는 변수로 각 시간마다의 현재 전력 수요와 전력 수요에 크게 영향을 미치는 기상 요인인 현재 기온, 강수량 등의 기상 요인인 기상변수와 요일 및 특수일 유무 변수를 사용하였다.

#### 1.1 Electricity demand Variable

실험은 사용된 전력 데이터는 전력통계정보시스템(EPSS)에서 제공해주는 2017년부터 2022년까지 여름철(6월 1일에서 9월 30일)의 5분 단위 실시간 전력 공급 데이터를 사용하였다[17]. 실시간 전력 공급 데이터는 공급능력(Mega Watt, MW), 현재 수요(MW), 공급예비력(MW), 공급예비율(%)이 포함되어 있으며, 하계 전력 수요 예측이 목표이므로 특정 시간에 소비되는 전력의 양을 나타내는 현재 수요만 사용했다. 현재 수요는 특정 순간 또는 특정 시간대에 필요한 전력의 양을 의미하며, 예를 들어 A 도시의 현재 수요가 200MW이면, A 도시에서 그 시간대에는 약 200MW의 전력이 소비되고 있다는 것을 의미한다.

전력 데이터는 5분 단위로 수집하였지만, 급격한 전력 수요 변화를 더 정확하게 감지하고 예측할 수 있게 순시로 바꾸어서 연구를 진행하였다. 특정 시간대에 결측치가 발생하였을 때 전 시간과 후 시간의 평균치를 사용하여 결측치를 처리하였다. 최종적으로 순시를 사용한 2017년부터 2022년까지 하절기의 1시간 단위 현재 수요 데이터를 실험에 사용하였다.

### 1.2 Weather Variable

전력 수요는 중장기적으로는 사회·경제적 요소의 영향을 받아 변화되고, 단기적으로는 날씨 요소와 기상인자의 영향을 받아 변화된다[1][18]. 본 연구에서는 선행 연구를 참조하여 생활 기상지수인 불쾌지수와 체감온도 2가지를 선정하였다[16]. 불쾌지수는 인간이 느끼는 쾌적함의 정도로 식(1)과 같이 계산되며, 체감온도는 기온과 습도를 고려하여 인간이 느끼는 온도를 나타내며 식(2)와 같다.

$$D = 1.8T - 0.55(1 - RH)(1.8T - 26) + 32 \quad (1)$$

$$TF =$$

$$13.12 + 0.6215T - 11.37W^{0.16} + 0.3965W^{0.16}T \quad (2)$$

위 식에서, D는 불쾌지수, T는 기온(°C), RH는 상대습도(%), TF는 체감온도, W는 풍속(km/h)을 뜻한다.

기온, 상대습도, 체감온도는 기상변수로 기상청 기상자료개방 포털에서 전력 데이터와 같은 기간의 1시간 단위로 수집하였다[19]. 보다 신뢰성 있는 가중치를 반영하기 위해 위에서 언급한 한국 전력거래소에서 채택하는 8개 도시(원주, 수원, 광주, 대구, 대전, 부산, 서울, 인천)의 데이터만 추출하였다. 도시별 기온은 한국전력거래소에서 발표한 선행 연구를 참고하여 8대 도시별 가중치를 이용해 전국 대표기온으로 계산하여 사용한다[20]. 습도와 풍속 데이터도 같은 방식으로 수집해서 8개 도시별 가중치를 적용하여 전국 대표 습도와 풍속으로 계산하였다.

### 1.3 Days Variable

요일 간의 패턴의 차이가 있는지 확인하기 위해 전처리가 완료된 전력 수요 데이터를 시각화하여 확인한 결과, 평일과 주말 사이에는 유의미한 차이를 보였으며, 주말 다음으로 오는 평일인 월요일은 다른 평일(화요일, 수요일, 목요일, 금요일)과는 위아래로 큰 편차를 보이기도 하며, 새벽 시간대에도 다른 패턴을 보이는 것을 Fig. 1을 통해 확인할 수 있다.




Fig. 1. 3 weeks power demand comparison (2017.08.28. ~ 2017.09.17.)

선행 연구들에서는 이러한 패턴의 차이를 반영하기 위하여, 일주일을 (월요일), (화요일, 수요일, 목요일, 금요일) 및 (토요일, 일요일)로 분리하였다[16][21].




Fig. 2. Electricity demand during Chuseok (2019.09.09. ~ 2017.09.15.)

Fig. 2를 통해 추석 연휴에 포함된 평일인 목요일과 금요일이 다른 평일보다 전력 수요가 급격히 낮은 것을 확인할 수 있다. 공휴일이 평일일 때 다른 평일보다 전력 수요가 매우 적고, 공휴일이 토요일인 경우, 최대 전력 수요가 발생하는 시점이 다르며 보통의 토요일과는 다른 패턴을 띄는 것을 확인하였다. 선행 연구를 참고하여 국가 지정 공휴일을 구분할 수 있는 변수를 추가하였다.

2. BiGRU

하계전력수요예측을 위한 모델로 BiGRU모델을 선택하였다. BiGRU는 순환 게이트 유닛(Gated Recurrent Unit, GRU)을 양방향 학습이 가능하도록 만든 모델이다. GRU는 LSTM의 경량화된 모델이며, Reset gate와 Update gate로 이루어져 있다[14]. GRU의 연산은 다음과 같다.

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (3)$$

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (4)$$

$$\tilde{h}_t = \tanh[W_h x_t + U_h (r_t \odot h_{t-1}) + b_h] \quad (5)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (6)$$

여기서  $x_t$ 는  $t$ 시점 별 입력이고,  $W$ 와  $U$ 는 각 게이트의 가중치이고,  $b$ 는 바이어스이며,  $h_t$ 는  $t$  시점별 히든벡터이다.  $r_t$ 는 Reset gate로 과거의 정보를 얼마나 유지할지를 결정한다.  $z_t$ 는 Forget gate로 다음 시점으로 정보를 얼마나 보낼지 결정한다.

BiGRU구조는, Fig. 3과 같이 두 개의 GRU를 활용하여, 순방향과 역방향을 학습하도록 하고, 출력을 결합하여 최

종 결과를 생성한다. 순방향 모델은 앞에서부터, 역방향 모델은 뒤에서부터 입력을 처리하기 때문에 장기 의존성을 학습할 수 있어, 더 정확한 예측을 수행할 수 있다.




Fig. 3. BiGRU structure

BiGRU의 연산은 다음과 같이 나타낼 수 있다.

$$\vec{h}_t = GRU_{fwd}(x_t, \vec{h}_{t-1}) \quad (7)$$

$$\overleftarrow{h}_t = GRU_{bwd}(x_t, \overleftarrow{h}_{t+1}) \quad (8)$$

$$h_t = \vec{h}_t \oplus \overleftarrow{h}_t \quad (9)$$

여기서  $GRU_{fwd}$ 는 정방향 연산이고,  $GRU_{bwd}$ 는 역방향 연산이다. 정방향 예측과 순방향 예측  $\vec{h}_t$ 인  $\overleftarrow{h}_t$ 과를 최종적으로 결합(Concatenate)하여 최종 예측인  $h_t$ 을 생성한다.

III. Comparison Time Variables

1. Effect of Time

시간 마다 전력 수요 분포의 차이가 있는지 확인하기 위해, 2017년부터 2020년 사이의 시간에 대한 전력수요의 Violin plot은 Fig. 4와 같다. Violin plot의 x축은 시간이며, y축은 MW 단위 전력수요이다.




Fig. 4. Violin plot of hourly demand

0시부터 8시까지의 수요는 비교적 안정적인 경향을 보이지만, 8시 이후부터 수요의 변동성이 점차 커지는 것을 확인할 수 있다. 오후 9시부터 23시까지 시간대에는 기온의 변동이 커짐에 따라 전력 수요의 변동성도 증가한다. 반면, 0시부터 8시까지는 기온 변동이 상대적으로 적어 수요의 변동성도 낮다. 이는 모델이 시간 정보를 활용할 경우, 시간대별 수요 패턴을 효과적으로 학습할 수 있음을 시사한다. 본 실험은 168시간으로 24시간을 예측하므로 수요 데이터를 192시간 씩 지연시켜 초기 168시간이 다음 24시간에 어떠한 영향을 주는지 확인하기 위해 Fig. 5와 같이 가로축에는 초기 168시간을 두고 세로축에는 이후 24시간을 두어, 이들의 상관도표를 그렸다.




Fig. 5. Comparison of correlations over time

Fig. 5에서 확인할 수 있듯이, 예측 시점과 같은 시점에서의 상관관이 높게 나오며, 전날과 전주의 동일 요일 시점에서 상관관이 높은 것을 확인할 수 있다. 이는 시점을 변수로 활용할 시 모델이 시점별 정보를 더욱 정확히 학습할 수 있을 것으로 기대된다.

## 2. Time Variables

만약 시간 변수를 시간 값 그대로 {0, 1, 2, ..., 23}과 같이 입력하여 사용한다면 모델은 매 시점의 차이를 크기 차이로 인식하여, 잘못된 학습을 하게 된다. 이를 해결하기 위해 두 가지 방식을 사용할 수 있다. 먼저, 시간 변수를 더미 변수화하여 사용하는 것이다. 시간 변수는 24가지 값을 갖고 있어서 24개 더미 특성을 가진다고 보면 Fig. 6과 같이 변환할 수 있다.




Fig. 6. Time-Based dummy variable creation

두 번째로, 시간 변수를 푸리에 특징으로 변환하여 사용할 수 있다. 푸리에의 변환은 주기적인 성질을 가진 값들을 삼각함수로 이루어진 급수로 변환하는 것을 말하며 식 (10)과 같이 나타낼 수 있다.

$$f(t) = \sum_{n=0}^{\infty} (a_n \text{Sine}(nw_0t) + b_n \text{Cosine}(nw_0t)) \quad (10)$$

푸리에의 변환을 이용하여 24의 주기를 가지는 시간을 변환하면 Cosine 좌표와 Sine 좌표 2가지로 표현할 수 있고, 각각은 식 (11)과 식 (12)를 통해 변환할 수 있다.

$$\text{Cosine}_t = \text{Cosine}\left(\frac{2\pi t}{24}\right) \quad (11)$$

$$\text{Sine}_t = \text{Sine}\left(\frac{2\pi t}{24}\right) \quad (12)$$

변환된 좌표값들을 Sine 축과 Cosine 축의 산점도를 그리면 Fig. 7과 같이 나타낼 수 있다.




Fig. 7. Fourier transform scatterplot

Fig. 7에서 확인할 수 있듯이 각 시간마다의 차이를 두 개의 변수로 표현할 수 있다. 또한 전날인 23시와 다음날인 0시의 차이를 명확하게 표현할 수 있다.

## IV. Performance experience and Results

### 1. Performance Experiments

본 논문에서는 시간 변수에 따른 BiGRU를 이용한 하계 전력 수요 예측에 대한 성능 비교를 위해 3가지 변수 모델을 비교하고자 한다. 먼저 시간 변수를 포함하지 않은 기존 모델을 Model 1, 푸리에 변환을 이용하여 시간 변수를 Cosine, Sine 더미로 변환하여 사용하는 모델을 Model 2, 24개의 시간 더미변수를 가지는 모델을 Model 3로 두어 세 가지 모델의 성능을 비교한다.

세 가지 모델에 공통으로 포함되는 변수는 수요 데이터와 불쾌지수, 체감온도, 요일 더미, 특수일 모델이며, 각 모델의 변수에 대한 요약은 Table 1과 같다.

Table 1. Three Model Variable Summary

	variables	summary
Common to All Models	Electricity Demand(MW)	min : 42489 max : 92337
	Discomfort index	min : 54.35 max : 86.28
	perceived temperature	min : 14.02 max : 40.37
	day dummy	3 variables
	holiday dummy	1 variables
Model 2 Only	Cosine-Sine Dummy	2 variables
Model 3 Only	24 hour Dummy	24 variables

Table 2는 Table 1의 변수들을 포함하면서, 연구에 사용할 데이터를 기간 단위로 나누어, 훈련데이터, 검증데이터, 평가데이터로 구분한 것이다.

Table 2. Variable Term

Train	2017.06.01. ~ 2017.09.30
	2018.06.01. ~ 2018.09.30
	2019.06.01. ~ 2019.09.30
	2020.06.01. ~ 2020.09.30
Validation	2021.06.01. ~ 2021.09.30
Test	2022.06.01. ~ 2022.09.30
	2023.06.01. ~ 2023.09.30

학습을 위한 입력( $X$ )인 윈도우 크기(window size)는 일주일 시간인 168시간 즉 168이고, 예측을 수행할 출력( $Y$ )의 인터벌 크기(interval size)는 하루 시간인 24시간 즉 24이다. 168시간이 입력되면 모델은 다음 24시간을 예측하는 구조이다. 데이터를 구성하기 위해 윈도우와 인터벌을 슬라이딩(sliding)하여 데이터를 생성할 수 있는데, 하계데이터만 추출하였기 때문에 매년 마지막 시점에서 슬라이딩을 멈추고, 다음 연도부터는 새로 슬라이딩하도록 하였다. 이때, 학습 시 년도 구분 없이 한 번에 학습하도록 하였다. 구해진 최종 데이터 세트의  $X$ 는 (윈도우 크기, 모델별 특징 수),  $Y$ 는 (인터벌 크기, 1)로 구해지며 각 모델에 대한 데이터 세트 크기는 Table 3과 같다.

Table 3. Data shape

Model 1	$X : (168,7),$ $Y : (24,1)$
Model 2	$X : (168,9),$ $Y : (24,1)$
Model 3	$X : (168,31),$ $Y : (24,1)$

BiGRU 모델의 하이퍼 파라미터는 선행 연구를 참조하여, 2개의 BiGRU를 사용하였고, 배치크기는 128, 옵티마이저는 Adam, 학습률은 0.001이다. 에포크는 500회를 두었고, 검증셋에서 손실이 가장 적게 나왔던 모델을 최적 모델로 선택하도록 하였다[16].

최적 모델을 선택하기 위한 평가지표로 MAPE를, 선택된 모델의 예측 성능을 더욱 정확히 평가하기 위해 MAE를 사용하였으며 각각은 식(13)과 식(14)으로 구할 수 있다.

$$MAPE = \frac{100}{n} \times \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (13)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - x| \quad (14)$$

본 실험에서는 모델의 불확실성을 평가하기 위하여 각 변수 모델별로 10개의 모델을 만들고 이 모델들의 평균오차(Average Error, AVGE)와 표준오차(Standard Error, STE)를 평가한다. 최종 흐름도는 Fig. 8과 같다.




Fig. 8. Flow chart

Table 4는 실험환경을 나타낸다.

Table 4. Experimental environment

Factors	Specifications
CPU	12 th Gen Intel(R) Core(TM) i7-12700
GPU	NVIDIA GeForce RTX 4070 Ti
Memory	64GB
Tools	Windows 11 CUDA 11.7 Python 3.10.12 Tensorflow, Keras 2.10.0

연구에 사용된 하드웨어는 12th Intel(R) Core(TM) i7-12700 CPU와 NVIDIA GeForce RTX 4070 Ti GPU이다. 소프트웨어 환경은 Windows 11 운영체제에서 수행되었으며, 딥러닝 가속을 위한 CUDA는 11.7 버전이다.

모델 구현 및 실험에는 Python 3.10.12 버전이 사용되었으며, 딥러닝 라이브러리는 TensorFlow와 Keras 2.10.0이 활용되었다. TensorFlow와 Keras는 전력 수요 예측 모델을 구축한 후, 시계열 데이터를 처리하고 신경망 모델을 설계 및 평가하는 과정에서 사용되었다.

## 2. Performance Experiments

시간 더미가 BiGRU를 이용한 2022년과 2023년도의 하계 전력 수요예측에 미치는 영향을 확인하기 위해 시간 더미를 사용하지 않은 모델인 Model 1, Model 1의 변수와 푸리에 변환을 이용하여 시간 변수를 2개의 변수 (Cosine,

Sin)을 가지는 Model 2, 시간 변수를 24개의 더미로 변환한 Model 3의 성능을 비교한 결과는 Table 5와 같다.

Table 5. Evaluation of Prediction Models

		Model 1		Model 2		Model 3	
2022	MAPE (%)	AVG	2.32	<b>2.01</b>	2.07		
		STE	0.06	0.03	0.03		
	MAE (MW)	AVG	1554	<b>1355</b>	1395		
STE		33.47	18.11	20.83			
2023	MAPE (%)	AVG	2.21	<b>2.04</b>	2.08		
		STE	0.06	0.03	0.09		
	MAE (MW)	AVG	1506	<b>1379</b>	1405		
STE		38.69	18.35	52.49			

Table 5에서 확인할 수 있듯이, 시간 변수를 추가하여 사용한 model 2, model 3이 사용하지 않은 model 1과 비교하였을 때, 2022년과 2023년 모두 우수한 성능을 보였다. 시간 변수를 가진 모델 간의 비교에서는, 2022년에는 Model 2가 MAPE는  $2.01 \pm 0.03\%$ , MAE는  $1355 \pm 18.11\text{MW}$ 로 우수한 성능을 보였고, 마찬가지로 2023년도 Model 2가 MAPE는  $2.04 \pm 0.03\%$ , MAE는  $1379 \pm 18.35\text{MW}$ 로 가장 우수한 성능을 보였다.

세가지 모델을 비교한 결과 Model 2가 MAPE와 MAE 관점에서 우수한 성능을 보였기 때문에, model 2의 예측 분포와 실제 수요의 분포가 얼마나 일치하는지 확인할 필요가 있다. Fig. 9는 Model 2의 예측과 실제 데이터의 분포를 그린 그림이다.




Fig. 9. Model 2 Prediction Data Distribution

Model 2의 예측 결과와 실제 수요와 비슷한 분포를 가지며, 또한, 수요가 큰 구간의 예측 데이터가 실제 데이터 분포를 완벽하게 커버하는 것을 확인할 수 있다. Fig. 10은 모델의 예측을 1개월 단위로 구별하여 예측값을 그린 그래프이다.

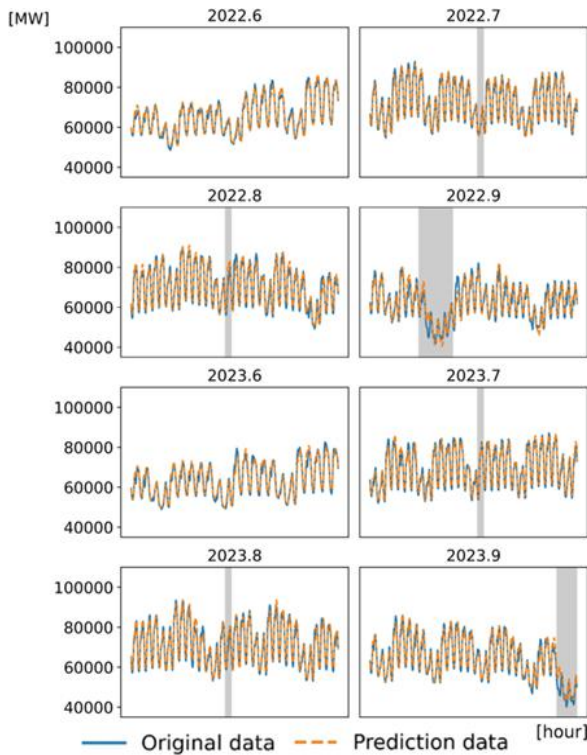


Fig. 10. Model 2 Prediction Graph

Fig. 10에서 확인할 수 있듯이, 모델이 수요를 정확하게 예측하는 것을 확인할 수 있다. 2022년도와 2023년도 하계에는 총 3번의 공휴일이 있다. 7월 제헌절과, 8월 광복절, 9월 추석 연휴이다. Fig. 10의 회색으로 색칠한 부분을 확인하면, 공휴일의 기간이 하루인 광복절과 제헌절은 모델이 예측을 잘하고 있다. 그러나 연휴 기간이 하루를 넘어가는 추석 연휴일 경우 전력 수요가 급격히 감소하는 패턴은 잘 예측하였지만 정확한 예측은 잘 수행하지 못하고 있음을 확인할 수 있다.

모델은 168시간을 입력받으면 그 이후 24시간을 예측하는 역할을 한다. 따라서 매 시점 얼마나 오차가 누적되는지 확인할 필요가 있다. Fig. 11는 매 예측 시점마다의 오류율을 나타낸 결과이다.




Fig. 11. Hourly Evaluation of Prediction Model 2

Fig. 11에서 확인할 수 있듯이 예측구간이 늘어남에 따라 오차가 누적되어 예측성능이 떨어지는 것을 확인할 수 있다. 2022년에는 MAPE는 0.79%에서 2.81%로, MAE는 522.7MW에서 1870.26MW로 증가한다. 그리고 2023년도에는 MAPE는 0.92%에서 2.49%로, MAE는 608.84MW에서 1709.24MW로 증가하며 예측구간이 18시간 이상에서 MAPE와 MAE가 유지된다.

### V. Conclusions

본 논문은 전력 사용량이 급증하는 하절기에 부정확한 수요 예측이 야기할 수 있는 비용 증가, 불필요한 전력 생산, 대규모 정전 사태 등을 예방하기 위해, 6월부터 9월 사이 하계 전력 수요 예측을 분석하였다.

전력 수요의 시간별 분포는 각기 달랐으며, 모델이 이러한 분포를 학습한다면 예측 결과에 차이가 있을 것으로 예상되었다. 이를 검증하기 위해 시간 변수를 추가하지 않은 모델, 푸리에 변환을 통해 두 개의 더미 변수를 추가한 모델, 그리고 24개의 시간 더미 변수를 모두 추가한 모델을 비교하여 성능을 분석하였다. 그 결과, 푸리에 변환을 사용한 모델이 MAPE와 MAE 기준에서 최적의 성능을 보였다.

본 연구는 168시간(일주일)의 데이터를 입력으로 하여 24시간(하루)의 전력 수요를 예측하는 실험을 수행하였다. 그러나 모든 168시간의 데이터를 사용하는 것이 항상 적절하지는 않을 수 있다. 상관관계가 낮은 데이터는 예측에 불필요한 노이즈를 추가할 수 있으므로, 이러한 데이터를 제거하거나 낮은 상관 구간에 대한 추가적인 처리가 필요할 수 있다.

또한, 본 연구는 하계 전력 데이터만을 사용했기 때문에 예측 모델은 하계에만 적용 가능하며, 다른 계절에서는 성능이 저하될 수 있다. 이를 개선하기 위해서는 하계 이외의 계절 데이터를 추가로 확보하여 모델을 학습시킴으로써, 하계에서 학습할 수 없는 패턴을 학습하고 다른 계절의 특수한 상황에도 대응할 수 있을 것으로 기대된다.

## ACKNOWLEDGEMENT

This research was supported by the MSIT(Ministry of Science and ICT), Korea, under the ICAN(ICT Challenge and Advanced Network of HRD) support program(IITP-2024-RS-2022-00156409) supervised by the IITP(Institute for Information & Communications Technology Planning & Evaluation) and This work was supported by the Regional Innovation Strategy (RIS) program funded by the Ministry of Education in 2024 and managed by the National Research Foundation of Korea. (NRF Project Management Number: 2021RIS-003)

## REFERENCES

- [1] J. D. Park, "Development of real-time demand forecasting techniques and research on online demand forecasting methods", [https://new.kpx.or.kr/board.es?mid=a1050200000&bid=0045&act=view&list\\_no=51480&tag=&nPage=34](https://new.kpx.or.kr/board.es?mid=a1050200000&bid=0045&act=view&list_no=51480&tag=&nPage=34)
- [2] S. I. Kim, "Analysis of the impact of COVID-19 on electricity supply and demand in Korea", [https://www.keei.re.kr/main.nsf/index.html?open&p=%2Fweb\\_keei%2Ffd\\_results.nsf%2F0%2F89832dbd2f1f0c24492587a4002ddc3a&s=%3FOpenDocument%26is\\_popup%3D1%26menucode%3D1%26menucode%3DSS18%26Click%3D](https://www.keei.re.kr/main.nsf/index.html?open&p=%2Fweb_keei%2Ffd_results.nsf%2F0%2F89832dbd2f1f0c24492587a4002ddc3a&s=%3FOpenDocument%26is_popup%3D1%26menucode%3D1%26menucode%3DSS18%26Click%3D)
- [3] H. W. Jung and K. B. Song, "Daily Maximum Electric Load Forecasting for the Next 4 Weeks for Power System Maintenance and Operation," The transactions of The Korean Institute of Electrical Engineers, Vol. 63, No. 11, pp. 1497-1502, Nov. 2014. DOI: 10.5370/KIEE.2014.63.11.1497
- [4] B. H. Ahn, H. R. Choi and H. C. Lee, "Regional Long-term/Mid-term Load Forecasting using SARIMA in South Korea," Journal of the Korea Academia-Industrial cooperation Society, Vol. 16, No. 12, pp. 8576-8584, Dec. 2015. DOI: 10.5762/KAIS.2015.16.12.8576
- [5] D. H. Shin and C. B. Kim, "A Study on Deep Learning Input Pattern for Summer Power Demand Prediction," The Journal of Korean Institute of Information Technology, Vol. 14, No. 11, pp. 127-134, 2016. DOI: 10.14801/jkiit.2016.14.11.127
- [6] H. B. Moon, J. K. Ahn and C. Y. Lee, "Forecasting electricity demand of Jeju island using machine learning," Innovation studies, Vol. 18, No. 4, pp. 49-63, Nov. 2023. DOI: 10.46251/INNOS.2023.11.18.4.49
- [7] P. S. Ji and J. Y. Lim, "Development of Daily Peak Power Demand Forecasting Algorithm Considering of Characteristics of Day of Week," THE TRANSACTION OF THE KOREAN INSTITUTE OF ELECTRICAL ENGINEERS P, Vol. 63P, No. 4, pp. 307-311, Dec. 2014, Doi: 10.5370/KIEEP.2014.63.4.307
- [8] J. H. Han and J. K. Baek, "The Load Forecasting in Summer Considering Day Factor," Journal of the Korea Academia-Industrial cooperation Society, Vol. 11, No. 8, pp. 2793-2800, Aug. 2010, DOI: 10.5762/KAIS.2010.11.8.2793
- [9] Y. S. Kim and H. J. Park, "Modeling and Predicting South Korea's Daily Electric Demand Using DNN and LSTM," Journal of Climate Change Research, Vol. 12, No. 3, pp. 241-253, Jun. 2021. DOI: 10.15531/KSCCR.2021.12.3.241
- [10] Hoyong Eom, and Seung-Mook Baek, "Optimal Model Selection of Long Short-Term Memory for Mid-Term Electric Load Forecasting," The transactions of The Korean Institute of Electrical Engineers, Vol. 71, No. 11, pp. 1658-1665, Nov. 2022. DOI: 10.5370/KIEE.2022.71.11.1658
- [11] C. H. Moon, B. S. Kwon and K. B. Song, "A Deep Learning Model and Training Technique for 240 Hours Load Forecasting in Korea Power System," The transactions of The Korean Institute of Electrical Engineers, Vol. 71, No. 4, pp. 585-591, Apr. 2022. DOI: 10.5370/KIEE.2022.71.4.585
- [12] S. J. Ko, H. Y. Yoon and D. M. Shin, "Electronic Demand Data Prediction using Bidirectional Long Short Term Memory Networks," Journal of Software Assessment and Valuation, Vol. 14, No. 1, pp. 33-40, 2018.
- [13] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," in Neural Computation, vol. 9, no. 8, pp. 1735-1780, 15 Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [14] K. Cho, B. V. Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio, "Learning phrase representations using RNN Encoder-Decoder for statistical machine translation," arXiv:1406.1078, pp.1724-1734, Jun. 2014.
- [15] K. Cho, B. V. Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio, "Learning phrase representations using RNN Encoder-Decoder for statistical machine translation," arXiv:1406.1078, pp.1724-1734, Jun. 2014.
- [16] H. U. Seol, "Comparison Study of LSTM and GRU Combination Models to Improve Summer Power Demand Prediction Performance" Graduate School of Gyeongsang National University, Feb. 2022, UCI: 1804:48003-000000034410
- [17] EPSIS, <https://epsis.kpx.or.kr>
- [18] Y. R. Shin and S. H. Yoon, "Evaluation of weather information for electricity demand forecasting," Journal of the Korean Data And Information Science Society, Vol. 27, No. 6, pp. 1601-1607, Jul. 2016, DOI: <https://doi.org/10.7465/jkdi.2016.27.6.1601>
- [19] Korea Meteorological Administration, <https://data.kma.go.kr>
- [20] B. C. Oh, H. J. Seo, H. K. Kank, S. Y. Kim, and M. A. Acquah, "Comparative Analysis of Artificial Intelligent Prediction Models

for Nationwide Short-Term Electricity Demand," THE TRANSACTION OF THE KOREAN INSTITUTE OF ELECTRICAL ENGINEERS P, Vol. 69P, No. 4, pp. 253-259, 2020, DOI: 10.5370/KIEEP.253

- [21] S. h. Kwon. "A study of algorithms for predicting daily short-term electricity demand based on machine learning techniques." Graduate School of Wiedok University, Feb. 2021, UCI: 1804:47032-200000508913



He obtained his M.S degree in Control & Instrumentation Engineering form Changwon National University, South Korea in 2008. He joined KERI(Korea Electrotechnology Research Institute), in 2018, where he is currently senior research associate with Numerical Analysis Technology Support Department. His research interests include Simulation and Digital Twin.



Byoung-Ho Jang received the B.S. in Electrical Engineering from Pusan National University, South Korea, in 1990. He is currently the CEO of Big-ai Company, South Korea.

He is interests lie in developing AI solutions in the fields of manufacturing, energy, and environment.



Young-Soon Kim received the B.S., and M.S., and Ph.D. degree in statistics from Gyeongsang National University, South Korea, in 1994, 1998 and 2005, respectively. From 2009 to 2020, she was as senior

researcher at GyeongNam Institute, South Korea, and she was a postdoctoral researcher and part-time Assistant Professor at Kennesaw State University from 2017 to 2019. Kim is currently an Associate Professor with Department of Information and Statistics and Department of Bio & Medical Bigdata (BK4 program), Gyeongsang National University, South Korea. Her research interests include bioinformatics, machine learning, data mining, and big data analytics.

## Authors



Jae-Ho Shin received the B.S degree in industrial system engineering from Gyeongsang National University, South Korea, in 2023. He is currently pursuing M.S degree in Information and Statistics

from Gyeongsang National University. He is interested in deep learning, data mining, and big data analytics.



Hyun-Uk Seol received the B.S., M.S. degrees in Information and Statistics from Gyeongsang National University, South Korea, in 2022 and 2024, respectively. He is currently a researcher working in the fields

of data analysis and Vision AI. His research interests include image processing, machine learning, and data-driven AI applications.



Han-Byeol Jo received the B.S. and M.S. degrees in Information and Statistics from Gyeongsang National University, South Korea, in 2022 and 2024 respectively. Han-Byeol Jo joined Big-AI Inc. in

Changwon, Gyeongnam in 2024. He is currently a senior researcher researching natural language processing. He is interested in machine learning and data-driven AI applications, as well as natural language processing.



Jong-Kwon Jo received the B.S. and M.S. degrees in Information and Statistics from Gyeongsang National University, South Korea, in 2018 and 2023, respectively. He is currently pursuing a Ph.D. at Gyeongsang

National University. He is interested in artificial intelligence models for manufacturing applications.