

거대언어모델 기반 특징 추출을 이용한 단기 전력 수요량 예측 기법

(Large Language Models-based Feature Extraction for Short-Term Load Forecasting)

이재승¹⁾, 유제혁^{2)*}
(Jaeseung Lee and Jehyeok Rew)

요약 스마트 그리드에서 전력 시스템을 효과적으로 운영하기 위해서는 전력 수요량을 정확히 예측하는 것이 중요하다. 최근 기계학습 기술의 발달로, 인공지능 기반의 전력 수요량 예측 모델이 활발히 연구되고 있다. 하지만, 기존 모델들은 모든 입력변수를 수치화하여 입력하기 때문에, 이러한 수치들 사이의 의미론적 관계를 반영하지 못해 예측 모델의 정확도가 하락할 수 있다. 본 논문은 입력 데이터에 대하여 거대언어모델을 통해 추출한 특징을 이용하여 단기 전력 수요량을 예측하는 기법을 제안한다. 먼저, 입력변수를 문장 형식의 프롬프트로 변환한다. 이후, 가중치가 동결된 거대언어모델을 이용하여 프롬프트에 대한 특징을 나타내는 임베딩 벡터를 도출하고, 이를 입력으로 받은 모델을 학습하여 예측을 수행한다. 실험 결과, 제안 기법은 수치형 데이터에 기반한 예측 모델에 비해 높은 성능을 보였고, 프롬프트에 대한 거대언어모델의 주의집중 가중치를 시각화함으로써 예측에 있어 주요한 영향을 미친 정보를 확인하였다.

핵심주제어: 단기 전력 수요량 예측, 스마트 그리드, 거대언어모델, 특징 추출, 기계학습

Abstract Accurate electrical load forecasting is important to the effective operation of power systems in smart grids. With the recent development in machine learning, artificial intelligence-based models for predicting power demand are being actively researched. However, since existing models get input variables as numerical features, the accuracy of the forecasting model may decrease because they do not reflect the semantic relationship between these features. In this paper, we propose a scheme for short-term load forecasting by using features extracted through the large language models for input data. We firstly convert input variables into a sentence-like prompt format. Then, we use the large language model with frozen weights to derive the embedding vectors that represent the features of the prompt. These vectors are used to train the forecasting model. Experimental results show that the proposed scheme outperformed models based on numerical data, and by visualizing the attention weights in the large language models on the prompts, we identified the information that significantly influences predictions.

Keywords: Short-Term Load Forecasting, Smart Grid, Large Language Models, Feature Extraction, Machine Learning

* Corresponding Author: jhrew@duksung.ac.kr
Manuscript received May 18, 2024 / revised June 10, 2024
/ accepted June 14, 2024

1) 고려대학교 전기전자공학과, 제1저자
2) 덕성여자대학교 데이터사이언스학과, 교신저자

1. 서론

최근 지구 온난화와 에너지 수요 증속 문제에 대한 대응책으로, 기존 전력망에 정보통신 기술을 접목한 차세대 전력망 시스템인 스마트 그리드(Smart Grid)가 주목받고 있다. 스마트 그리드를 통해 전력 소비자와 공급자가 서로 실시간으로 정보를 교환함으로써 소비자는 에너지 사용을 최적화할 수 있고, 공급자는 정전과 같은 비상 상황에 신속하게 대응할 수 있다(Son, 2023). 이때, 소비자가 이용하는 전력의 양을 사전에 예측하는 기술인 전력 수요량 예측은 스마트 그리드 운영의 효율성을 높이는 데 중요한 역할을 하고 있다. 예를 들어, 전력 수요량을 정확하게 예측하면 전력 발전 설비의 생산량을 조절하여 불필요하게 생산되는 에너지의 양을 줄일 수 있고 이를 통해 전력망의 운영 비용을 절감할 수 있다. 또한, 정부 기관이 에너지 정책을 수립하고, 인프라 투자 결정을 내리는 데 있어 근거 자료로 활용됨으로써 장기적인 에너지 운영 전략과 지속 가능한 발전 목표 달성을 위한 발판을 마련할 수 있다. 따라서 전력 수요량을 정확하게 예측하기 위한 다양한 연구들이 진행되고 있다(Chodakowska et al., 2021; Oh et al., 2019; Tan et al., 2021; Dudek, 2022; Lee and Shin, 2013).

과거에는 Autoregressive (AR), Autoregressive Moving Average (ARMA), Autoregressive Integrated Moving Average (ARIMA)와 같은 통계적인 기법 기반의 예측 모델들이 연구되었다(Chodakowska et al., 2021). 이 모델들은 주로 평균값 추정 등 선형 관계의 모델링에 초점을 두기 때문에, 데이터의 전반적인 분포를 파악하는 데 한계를 보여 예측 성능이 떨어지는 모습을 보였다. 이러한 문제를 해결하기 위하여, 최근에는 XGBoost, LightGBM, Random Forest와 같은 기계학습 모델 기반의 전력 수요량 예측 모델이 연구되고 있다(Oh et al., 2019; Tan et al., 2021; Dudek, 2022). 이 모델들은 비선형 함수를 이용하여 변수 간의 복잡한 관계와 상호작용을 학습하기 때문에 통계적인 기법 기반의 예측 모델보다 우수한 성능을 보였다. 하지만

기존의 기계학습 모델은 모든 입력변수를 수치화하여 입력하기 때문에, 해당 수치가 지닌 의미론적 특징을 예측 모델에 반영하지 못하게 된다. 예를 들어, 날짜, 시간, 공휴일 여부 등은 모두 시간적 정보를 지칭하는 변수로서 해당 변수들의 논리적 연관 관계를 고려해야 하지만, 기존의 기계학습 모델은 이 변수들이 모두 같은 유형의 정보를 나타낸다는 것을 반영하지 않고 이를 단순히 수치화하여 표현한 데이터를 입력으로 받는다. 이는 입력변수로 활용되는 각 요소 간에 내재된 의미론적 관계를 포착하는 데 한계가 발생하여 전력 수요량 예측 모델의 정확도가 하락할 수 있다.

최근, 자연어 처리 모델의 급속한 발전에 따라 거대언어모델(Large Language Models, LLMs)이 많은 주목을 받고 있다. LLM은 방대한 양의 텍스트 데이터를 사전 학습한 모델이기 때문에, 주어진 텍스트 데이터로부터 주요한 특징을 추출하고 이를 활용하는 데 효과적이라는 특성이 있다(Zhu et al., 2023; Kim and Yu, 2023). 이러한 LLM의 특성은 시계열 예측에도 활용될 수 있다. LLM은 텍스트 형식의 프롬프트(Prompt)를 해석하여 시계열 예측을 수행할 수 있도록 한다. 즉, 입력변수로 활용되는 각 요소가 문장 형태로 묘사된 프롬프트를 통해 의미론적 특징을 파악하고, 이에 기반하여 최종 예측을 수행함으로써 예측 모델의 정확도를 향상시킬 수 있다. 하지만, 텍스트 데이터와 달리 데이터 간의 시간적 순서와 패턴을 추가적으로 고려해야 하는 시계열 예측의 특성상, 아직까지 LLM을 활용한 시계열 예측 연구는 미흡한 상황이다. 특히, 전력 수요량 예측 분야에서는 거의 활용되고 있지 않다.

본 논문은 LLM 기반의 특징 추출을 이용한 단기 전력 수요량 예측 기법을 제안한다. 먼저, 전력 수요량 예측에 있어 입력변수로 활용되는 날짜, 시간, 공휴일 여부, 기온 등을 반영한 프롬프트를 구축하고, 가중치가 동결된(Frozen) LLM을 이용하여 이러한 프롬프트를 해석한다. 이후, 기계학습 모델을 이용하여 LLM이 프롬프트로 파악한 입력변수의 정보를 학습하고 이를 기반으로 전력 수요량을 예측한다. 이에 더해,

주어진 프롬프트에 대한 LLM의 주의집중 가중치(Attention Weights)를 시각화함으로써 전력 수요량 예측에 있어 주요한 영향을 미친 정보를 확인한다.

본 논문의 구성은 다음과 같다. 2장에서는 전력 수요량 예측 관련 연구를 기술하고, 3장에서는 제안 기법에서 이용되는 기술과 기법의 구조에 대하여 설명한다. 4장에서는 실험에서 사용한 데이터셋을 설명하고, 제안 기법의 정량적 실험 결과를 보이며 실험 결과를 분석한다. 5장에서는 결론을 서술하며 본 논문의 끝을 맺는다.

2. 관련 연구

과거 전력 이용량 데이터의 통계적 특성을 이용하여 통계적 모델을 구축하는 것은 전력 수요량 예측의 대표적인 접근 방법이다(Lee and Ko, 2011; Wang, 2016; Chodakowska et al., 2021). 예를 들어, Lee and Ko (2011)는 웨이블릿 필터(Wavelet filter)를 여러 개의 데이터 집합으로 분해함으로써 계산 복잡도를 줄이는 방법인 리프팅 스킴(Lifting scheme)을 ARIMA와 결합하여 전력 수요량을 예측하였다. Wang (2016)은 ARMA의 초모수를 조절하여 단기 전력 수요 예측 모델의 성능을 향상시키는 기법을 제안하였다. Chodakowska et al. (2021)은 자기상관함수 등을 이용한 전력 이용량 데이터의 정상성 검정을 통해 데이터 노이즈에 강건한 ARIMA 기반의 전력 수요량 예측 기법을 제시하였다.

최근 컴퓨팅 기술의 발달로 인해 기계학습 모델 기반의 전력 수요량 예측 기법이 제안되었다(Raju and Laxmi, 2020; Saglam et al., 2024; Kumar and Pal, 2023). 이 모델들은 통계적 기법보다 우수한 성능을 보여주었다. Raju and Laxmi (2020)는 사물인터넷 환경에서 기계학습 알고리즘을 이용하여 온라인상에서 직접 전력 수요량을 예측하는 기법을 개발하였다. Saglam et al. (2024)은 다중 선형 회귀, 인공신경망 등의 기계학습 모델들과 입자 군집 최적화, 골드

러시 최적화 등의 최적화 방법론들을 결합하여 피크 시점 대의 전력 수요량을 예측하는 기법을 제안하였다. 여러 조합들에 대한 실험을 수행한 결과, 인공신경망과 골드 러시 최적화를 결합한 기법이 가장 우수한 예측 성능을 보인다는 것을 확인하였다. Kumar and Pal (2023)은 Gaussian Process Regression (GPR)을 이용하여 인도 Jaipur 지역에서의 전력 수요량을 예측하는 기법을 제시하였다. 제안 기법은 Support Vector Machine (SVM), Bagged Trees 등 타 기계학습 모델보다 더 우수함을 보였다.

이와 함께, 과거 전력 이용량 데이터뿐만 아니라 전력 이용에 영향을 미치는 외부 변수들을 함께 고려하며 전력 수요량을 예측하는 시도가 등장하였다(Moon et al., 2020a; Moon et al., 2020b; Aisyah et al., 2022; Dehalwar et al., 2016). 먼저, 전력 이용량이 수집된 시점을 2차원상에 표현하고 이를 입력변수로 활용하는 접근법이 제시되었다(Moon et al., 2020a; Moon et al., 2020b). Moon et al. (2020a)은 단기 전력 수요량 예측에서의 학습 데이터 부족 문제를 해결하기 위해, 시간 정보를 sine과 cosine 함수를 이용하여 2차원상으로 표현한 이후 Conditional Tabular Generative Adversarial Networks (CTGAN)를 이용하여 데이터를 증강하는 기법을 제시하였다. Moon et al. (2020b)은 날씨, 요일, 시간 등의 정보를 sine과 cosine 함수를 이용하여 2차원상으로 표현한 이후 Random Forest를 통해 건물에서의 단기 전력 수요량을 예측하는 기법을 제안하였다.

또한, 전력 수요량 예측에 영향을 미치는 변수인 날씨를 함께 고려하는 기법이 개발되었다(Aisyah et al., 2022; Dehalwar et al., 2016). Aisyah et al. (2022)은 SVM과 Generalized Regression Neural Network (GRNN)을 이용하여 인도네시아 발리에서의 전력 수요량 예측에 있어 날씨 변수가 미치는 영향을 분석하였다. 날씨에 대한 탐색적 데이터 분석을 통해 날씨 변수와 전력 이용량 데이터 간의 상관관계를 도출하였고, 이를 기반으로 전력 수요량 예측 모델을 구축하는 데 있어 입력변수를 선택하는 기법을 제시하였다. Dehalwar et al. (2016)은 시

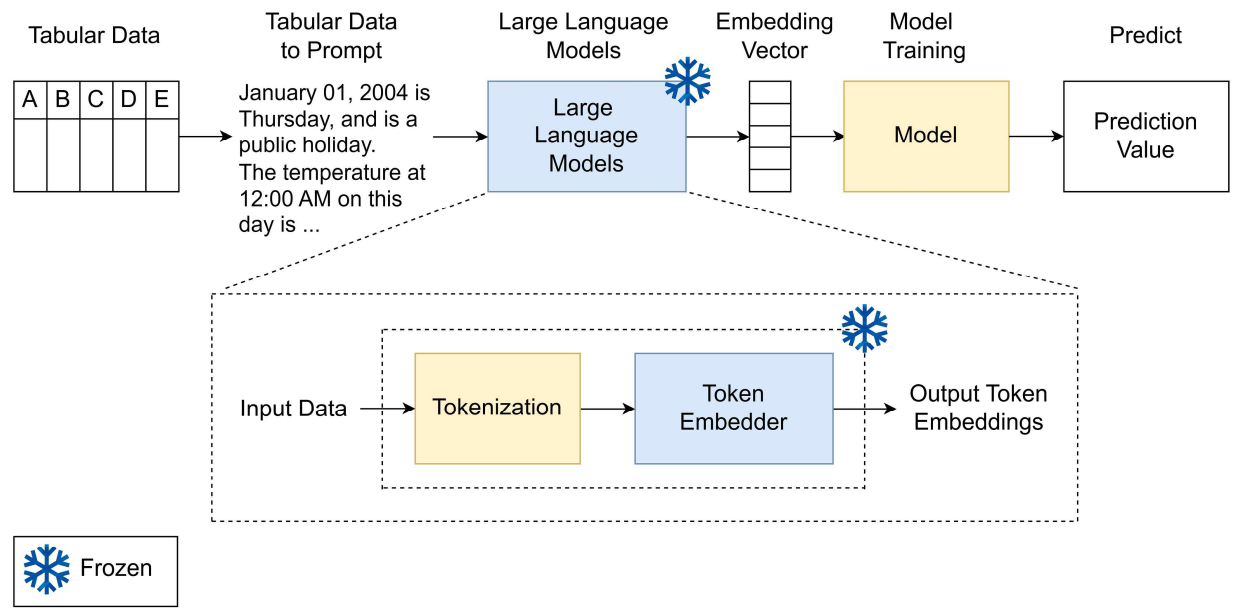


Fig. 1 Overview of the proposed scheme

Table 1 Template for transforming input data into prompt

	Template	Example
Context	$\{obs_{date}\}$ is $\{obs_{day\ of\ the\ week}\}$ and $\{obs_{holiday}\}$. The temperature at $\{obs_{hour}\}$ on this day is $\{obs_{temperature}\}$ degrees celsius.	January 01, 2004 is Thursday, and is a public holiday. The temperature at 12:00 AM on this day is 46.0 degrees celsius.
Question	What is the electric energy consumption in kWh at $\{target_{time}\}$ on $\{target_{date}\}$?	What is the electric energy consumption in kWh at 12:00 AM on January 01, 2004?

간 정보와 날씨 변수를 함께 입력변수로 활용한 Bagged Trees를 통해 도시에서의 전력 수요량을 예측하는 기법을 제안하였다.

하지만, 기존의 기계학습 모델들은 시간 정보, 날씨 변수 등의 입력변수를 모두 수치화하여 입력하기 때문에 해당 수치들이 지닌 의미론적 특징을 전력 수요량 예측 모델에 반영하지 못한다. 이는 입력변수 내 요소들 사이에 내재된 의미론적 관계를 명확히 고려하지 못하기 때문에, 예측 모델의 성능이 하락할 수 있다. 이와 반대로, 최근 많은 주목을 받고 있는 LLM은 방대한 양의 텍스트 데이터를 사전 학습한 모델이기 때

문에 주어진 텍스트 데이터로부터 의미론적인 특징을 명확히 추출할 수 있다는 장점이 있다. 입력변수로 활용되는 각 요소가 문장 형태로 묘사된 프롬프트에 대하여 LLM을 이용한다면 입력변수에서의 의미론적인 특징을 파악할 수 있고, 이를 예측 모델에 반영하면 모델의 예측 성능을 향상시킬 수 있다. 이에, 본 논문에서는 입력변수를 문장 형식으로 표현되는 프롬프트로 변환하고, 가중치가 동결된 LLM을 이용하여 프롬프트에 대한 특징인 임베딩 벡터(Embedding Vector)를 추출한다. 이후, 이러한 임베딩을 입력으로 받아 학습한 기계학습 모델을 통해 단기

전력 수요량을 정확히 예측할 수 있는 기법을 제안한다.

3. 제안하는 기법

본 단원에서는 본 논문에서 제안하는 기법의 전체적인 구조를 기술한다. Fig. 1은 제안하는 기법의 전체 구조도를 나타낸다.

3.1 정형 데이터의 프롬프트 형식 변환

주어진 입력 데이터를 프롬프트 형식으로 변환하여, LLM에 입력되기 적합한 형태로 만든다. 수치형 데이터를 자연어 처리가 가능한 문장 형식으로 변환하는 데 있어, 데이터를 일관적으로 표현하기 위해 템플릿(Template)에 기반하여 프롬프트를 구축한다. Table 1은 제안 기법에서 다루는 입력 데이터를 프롬프트로 변환하는 형식을 나타낸다. 프롬프트는 크게 Context와 Question으로 이루어진다. Context에서는 본 논문에서 전력 수요량 예측에 있어 입력변수로 활용되는 날짜, 시간, 공휴일 여부와 기온 정보를 문장으로 묘사하였다. Question에서는 예측 모델이 수행해야 하는 사항을 지시하였다. Context와 Question을 합친 것이 최종 프롬프트 형식이 된다.

3.2 LLM을 이용한 특징 추출

3.1절에서 프롬프트 형식으로 변환된 입력 데이터를 가중치가 동결된 LLM에 입력하여 특징을 추출한다. LLM은 매우 큰 모델이기에 전체 모델을 다시 학습시키려면 상당한 양의 계산 자원이 필요하다. 이때, LLM의 가중치를 동결하면서 일부 부분만 조정한다면 적은 계산 자원으로 주어진 작업을 효과적으로 수행할 수 있다. 또한, LLM은 이미 많은 양의 텍스트 데이터를 사전 학습한 모델이기에 주어진 정보의 의미를 파악한 특징인 임베딩 벡터를 도출할 수 있다. 하지만, LLM은 새로운 정보를 학습할 때 이전에 학습한 정보를 급격하게 잊어버리는 파괴적

망각(Catastrophic Forgetting) 현상이 발생할 수 있기에 이를 방지해야 한다. 이에, 제안 기법에서는 계산 자원의 효율성을 고려함과 동시에 LLM의 데이터 독립적인 표현 학습 기능을 유지하기 위해 LLM의 가중치를 동결한다.

주어진 텍스트 데이터에 대하여 가중치가 동결된 LLM을 이용하여 입력 데이터에 대한 특징을 나타내는 임베딩 벡터를 도출한다. 먼저, 텍스트 데이터를 여러 개의 토큰(Token)으로 분해하고, 각 토큰에 숫자 인덱스(Index)를 부여하는 토큰화(Tokenization)를 진행한다. 토큰은 언어모델이 처리하는 작은 단위를 나타내며, 이는 단어, 구, 또는 문자가 될 수 있다. 토큰화를 통해 텍스트 데이터를 언어모델이 이해할 수 있는 형식으로 변환한다. 하지만, 토큰화는 텍스트 데이터를 단순히 더 작은 단위로 분할하기 때문에 원시 형태의 토큰을 이용하면 주어진 텍스트 데이터의 의미를 명확히 이해하기 어렵게 된다. 따라서, 토큰 임베딩(Token Embedding)을 통해 텍스트의 의미 정보를 수치적 형태로 변환함으로써 단어나 구문과 같은 언어의 기본 요소들을 고차원의 벡터 공간에 나타낸다. 이때, 위치 인코딩(Positional Encoding)을 통해 각 토큰의 위치 정보를 토큰 임베딩에 추가함으로써, 토큰 간의 순서와 관계를 모델이 면밀히 파악할 수 있도록 한다. 이는 LLM이 텍스트 데이터의 문법적 구조와 의미론적 특징을 파악하는 기반으로 작용하게 된다.

이러한 과정을 거쳐 최종적으로 도출된 특징인 임베딩 벡터는 기계학습 예측 모델이 활용하는 입력 형태와 동일한 형식으로 표현된다. 이는 예측 모델이 텍스트 데이터를 처리할 수 있도록 하기 때문에 예측 성능을 향상시킬 수 있게 된다.

3.3 기계학습 모델을 통한 예측

3.2절에서 도출된 임베딩 벡터를 입력으로 받은 기계학습 모델을 학습하여 예측을 수행한다. 본 논문에서는 보편적으로 사용되며 뛰어난 예측 성능을 보이는 모델인 XGBoost, LightGBM, Random Forest를 이용하였다(Chen and Guestrin,

Table 2 Input variables for model training

Numerical-based model			Our scheme	
Input variables	Description	Variable type	Input variables	Variable type
$Month_x$	Sine value at the month	Continuous on [-1, 1]	obs_{date}	Text
$Month_y$	Cosine value at the month	Continuous on [-1, 1]		
Day_x	Sine value at the day	Continuous on [-1, 1]		
Day_y	Cosine value at the day	Continuous on [-1, 1]	obs_{hour}	
$Hour_x$	Sine value at the hour	Continuous on [-1, 1]		
$Hour_y$	Cosine value at the hour	Continuous on [-1, 1]		
$Weekday_x$	Sine value at the weekday	Continuous on [-1, 1]	$obs_{dayoftheweek}$	
$Weekday_y$	Cosine value at the weekday	Continuous on [-1, 1]		
$Holiday$	Weekdays / holidays status	Binary [1:holiday, 0:others]	$obs_{holiday}$	
$Temp.$	Temperature value	Continuous	$obs_{temperature}$	

Table 3 Output variable for model training

Numerical-based model and Our scheme		
Output variable	Description	Variable type
$Electric\ load$	Hourly electric load	Continuous

2016; Ke et al., 2017; Louppe, 2014; Kim et al., 2023). XGBoost는 결정 트리 기반의 앙상블 학습을 이용하는 부스팅 알고리즘이다(Chen and Guestrin, 2016). 이 모델은 여러 결정 트리를 순차적으로 구축하며, 각 트리는 이전 트리의 오류를 수정하여 예측 모델의 성능을 높인다. LightGBM은 학습 데이터를 히스토그램 기반 그래디언트 부스팅 방법을 이용하여 처리함으로써 예측 성능을 높이는 모델이다(Ke et al., 2017). Random Forest는 다수의 결정 트리를 구축하여 그 결과를 통합함으로써 높은 정확도를 확보하는 모델이다(Louppe, 2014; Lee, 2023). 각 트리는 무작위로 선택된 데이터 샘플과 특성을 이용하여 독립적으로 학습되며, 최종 예측값은 트리 간의 평균 계산을 통해 이루어진다. LLM을 통해 주어진 입력 정보를 파악하였을 때 예측 성능이 향상되는 정도를 확인하기

위해, 3가지 각각의 기계학습 모델을 구축하였다.

4. 실험 및 결과

4.1 데이터 셋

본 논문에서는 미국의 20개 지역에서 2004년 1월부터 2008년 12월까지 1시간 단위로 수집된 전력 에너지 사용량 데이터인 Global Energy Forecasting Competition 2012 (GEFCom 2012)를 이용하였다(Hong et al., 2014). 데이터의 전체 지역 수는 20개이나, 데이터 구성이 다른 9개 지역을 제외한 Zone 1부터 Zone 11까지의 11개 지역을 이용하였다. 전력 사용량 변화에 영향을 미치는 날짜, 시간, 요일, 공휴일 여부, 기온 정보를 입력변수로 고려하였다.

Table 4 RMSE comparison of the performance of forecasting model using XGBoost

Model Zone	XGBoost	BERT	ALBERT	DistilBERT	XLMR	RoBERTa	Electra
	Numerical Method	XGBoost with Large Language Models					
Zone 1	4666	4317	<u>4093</u>	4203	4332	4371	3801
Zone 2	26357	22325	22246	<u>22238</u>	23709	22813	18971
Zone 3	28439	24689	<u>24365</u>	24512	25677	25453	21429
Zone 4	80	85	<u>77</u>	91	78	88	66
Zone 5	1820	1926	1696	<u>1676</u>	1905	1968	1358
Zone 6	27548	24360	24428	<u>24022</u>	26142	25550	20584
Zone 7	28439	24058	<u>23461</u>	24079	26310	25336	20796
Zone 8	799	692	<u>656</u>	679	698	702	611
Zone 9	20677	21361	20698	21059	<u>20612</u>	21547	20033
Zone 10	38885	38190	<u>36897</u>	37990	35797	37766	38540
Zone 11	24821	21656	20770	<u>20148</u>	22661	21829	18301

Table 5 MAE comparison of the performance of forecasting model using XGBoost

Model Zone	XGBoost	BERT	ALBERT	DistilBERT	XLMR	RoBERTa	Electra
	Numerical Method	XGBoost with Large Language Models					
Zone 1	3463	3391	<u>3087</u>	3234	3391	3500	2732
Zone 2	19793	17093	17283	<u>17036</u>	18909	17740	14216
Zone 3	21356	19175	18734	<u>18584</u>	20343	19896	15938
Zone 4	58	67	61	74	<u>55</u>	70	49
Zone 5	1387	1583	1347	1363	1564	1633	1055
Zone 6	20927	19089	18812	<u>18573</u>	20892	20047	15360
Zone 7	21356	18623	<u>17924</u>	18882	20948	20035	15257
Zone 8	611	543	<u>514</u>	527	548	557	461
Zone 9	14629	15090	<u>14480</u>	14662	14614	15502	13936
Zone 10	29556	28904	<u>27773</u>	28603	27077	28754	29130
Zone 11	18356	16705	15696	<u>14658</u>	17974	16962	13180

4.2 실험 환경

제안 기법의 효과성을 검증하기 위해, 타 예측 모델과의 비교 실험을 진행하였다. 수치형 데이터를 이용하여 구축한 기계학습 모델을 베이스라인으로 정하였다. Table 2는 예측 모델에

서 활용한 입력변수들을 나타낸다. 날짜, 시간, 요일 등 수치형 데이터에서의 시간 정보는 식 (1)과 (2)를 이용하여 2차원상에 표현하였다(Moon et al., 2020a). 또한, 공휴일 여부는 One-Hot Encoding 방식을 적용한 이진형 변수로, 기온 정보는 연속형 변수로 설정하였다. 이러한 입력

Table 6 MAPE comparison of the performance of forecasting model

Model \ Zone	XGBoost	BERT	ALBERT	DistilBERT	XLMR	RoBERTa	Electra
	Numerical Method	XGBoost with Large Language Models					
Zone 1	16.956	18.648	<u>16.086</u>	17.339	18.349	19.617	13.417
Zone 2	10.760	9.756	10.000	<u>9.734</u>	11.150	10.346	7.883
Zone 3	10.763	10.193	9.900	<u>9.787</u>	11.047	10.642	8.127
Zone 4	33.074	36.514	34.707	38.713	<u>32.267</u>	39.165	31.845
Zone 5	19.028	24.680	20.190	21.091	24.583	25.442	15.093
Zone 6	10.942	10.762	10.422	<u>10.367</u>	11.908	11.230	8.161
Zone 7	10.763	9.898	<u>9.427</u>	10.118	11.434	10.910	7.745
Zone 8	14.498	14.122	<u>13.468</u>	13.560	14.318	14.896	11.170
Zone 9	63.994	52.722	81.025	80.237	<u>61.635</u>	76.710	64.723
Zone 10	42.793	41.739	<u>39.782</u>	40.904	39.427	42.213	41.300
Zone 11	15.661	15.688	14.572	<u>12.927</u>	17.284	16.029	11.313

변수들을 활용하여 시간별 전력 수요량을 예측하는 모델을 구축하였다. Table 3은 예측 모델에서 활용한 출력변수를 나타낸다.

$$time_x = \sin((360 / cycle) \times time) \quad (1)$$

$$time_y = \cos((360 / cycle) \times time) \quad (2)$$

제안하는 기법의 경우, 주어진 입력 데이터를 Table 1과 같이 프롬프트 형식으로 변환하였다. 이 프롬프트에 대해 BERT(Devlin et al., 2019), ALBERT(Lan et al., 2020), DistilBERT(Sanh et al., 2019), XLMR(Conneau et al., 2020), RoBERTa(Liu et al., 2019), Electra(Clark et al., 2020) 등 6가지의 LLM을 이용하여 임베딩 벡터를 추출하였다. 이후, 각각의 임베딩을 입력으로 받아 학습한 기계학습 모델을 통해 예측 결과를 도출하였다. 본 논문에서는 XGBoost, LightGBM, Random Forest 등 3가지의 기계학습 모델을 이용하였다. 훈련, 검증, 평가 데이터셋은 7:1:2의 비율로 설정하였다.

4.3 단기 전력 수요량 예측 기법 성능 평가

본 논문에서는 시계열 예측에서 주로 사용되

는 평가 지표인 Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE)를 사용하였다(Lee et al., 2022). RMSE와 MAE는 예측값과 실제값 사이의 오차를 측정하는 평가 지표로 수치가 낮을수록 높은 예측 정확도를 의미하고, MAPE는 예측값과 실제값 사이의 차이를 절대 비율로 계산하여 평균을 내는 평가 지표로 수치가 낮을수록 높은 예측 정확도를 의미한다. 실험 결과를 나타내는 Table에서는, 가장 우수한 성능을 보인 경우는 진한 색을, 2번째로 우수한 성능을 보인 경우는 밑줄을 표기하였다.

Table 4, 5, 6은 각각 RMSE, MAE, MAPE를 기준으로 XGBoost에 대하여 각 LLM 기반 임베딩을 학습한 예측 기법의 성능을 비교한 결과이다. 모든 지역에서 수치형 데이터를 학습한 XGBoost보다 LLM을 이용하여 추출한 임베딩 벡터를 학습한 XGBoost가 더 높은 예측 성능을 보였다. 그중 Electra 기반의 임베딩 벡터를 이용한 예측 기법이 가장 우수하다. 이는 제안 기법이 수치형 데이터가 지닌 의미론적 특징을 파악하고 이를 예측 모델에 반영하였기 때문이라고 설명할 수 있다. 즉, 기존의 수치형 데이터에 기반한 기계학습 모델과 다르게, 제안하는 기법에서는 입력변수로 활용되는 각 요소가 문장 형

Table 7 LightGBM Comparison of the performance of forecasting model

Model Zone	LightGBM			LightGBM with Electra		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE
Zone 1	4354	3129	14.867	3648	2606	12.706
Zone 2	23802	17237	9.190	18348	13553	7.449
Zone 3	25682	18599	9.190	20872	15260	7.702
Zone 4	70	51	31.944	62	46	30.720
Zone 5	1598	1227	17.085	1286	1017	14.862
Zone 6	24638	17805	9.128	19471	14371	7.595
Zone 7	25682	18599	9.190	19646	14407	7.261
Zone 8	734	546	12.666	595	447	10.744
Zone 9	19679	13561	61.337	18938	13185	68.813
Zone 10	38750	29195	41.446	38739	29195	41.151
Zone 11	22589	15869	13.081	17652	12573	10.704

Table 8 Random Forest Comparison of the performance of forecasting model

Model Zone	Random Forest			Random Forest with Electra		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE
Zone 1	4830	3498	16.969	4114	2984	14.552
Zone 2	26766	19682	10.622	21309	16027	8.757
Zone 3	28761	21258	10.611	23322	17277	8.738
Zone 4	79.999	58.808	33.170	70.382	52.353	33.099
Zone 5	1906	1413	19.499	1474	1156	16.905
Zone 6	28224	20686	10.722	22923	17067	8.954
Zone 7	28937	21320	10.648	23005	17175	8.651
Zone 8	779	581	13.677	675	511	12.201
Zone 9	21370	14914	71.317	19507	13897	77.851
Zone 10	38687	29292	42.086	38723	29235	41.597
Zone 11	25588	18519	15.773	20443	14518	12.285

태로 묘사된 프롬프트에 대하여 LLM을 이용하여 입력변수에서의 의미론적인 특징을 파악하고, 이를 예측 모델에 반영하였기에 모델의 예측 성능을 향상시킬 수 있었다. 특히, LLM은 방대한 양의 텍스트 데이터를 사전학습한 모델이기에, 이러한 모델을 이용하여 전력 수요량 예측 과제에 대한 정보 표현 능력을 강화한 것이 예측 모델의 성능 향상에 기여할 수 있다는 점을 확인할 수 있었다.

Table 7, 8은 각각 LightGBM과 Random

Forest를 이용하여 Electra 기반의 임베딩을 학습한 예측 기법의 성능을 나타낸다. 두 모델 모두 모든 지역에 대해 수치형 데이터를 이용하여 구축한 모델에 비해 제안하는 기법이 더욱 우수한 예측 성능을 보여주었다. 이를 통해, 제안하는 기법을 이용하여 입력변수가 지닌 의미론적 특징을 파악하고 이를 모델에 반영하는 것이 기계학습 모델의 예측 성능을 향상시킬 수 있음을 확인하였다.

제안 기법의 우수성을 더욱 자세히 검증하기

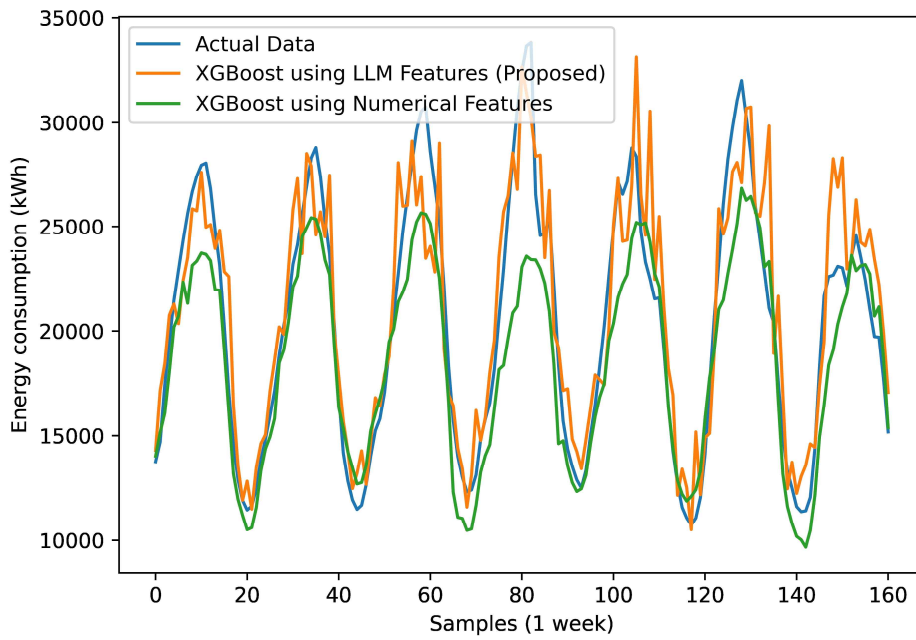


Fig. 2 Comparison of proposed scheme and numerical method with actual data - 1 week

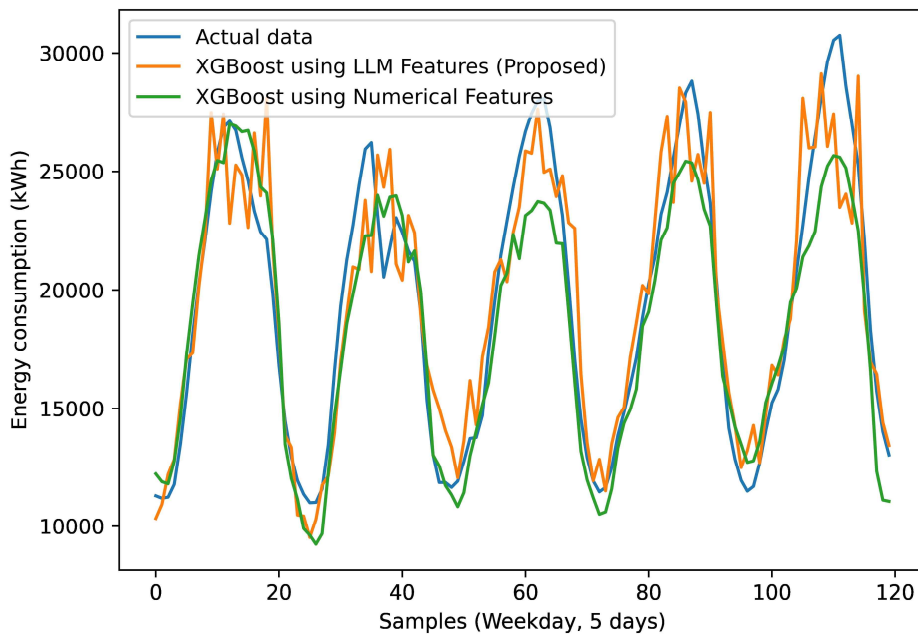


Fig. 3 Comparison of proposed scheme and numerical method with actual data - Weekday, 5 days

위해, 실제 전력 수요량 데이터에 대하여 제안하는 기법과 수치형 데이터에 기반한 기계학습 모델의 예측 결과를 서로 비교하였다. Fig. 2, 3, 4는 각각 Zone 1에 대하여 XGBoost를 이용하

였을 때 1주일, 평일, 주말 시점에서의 예측 결과를 비교한 모습을 나타낸다. 전반적으로, 제안하는 기법이 수치형 데이터에 기반한 기계학습 모델보다 전반적인 추세와 최댓값 및 최솟값을

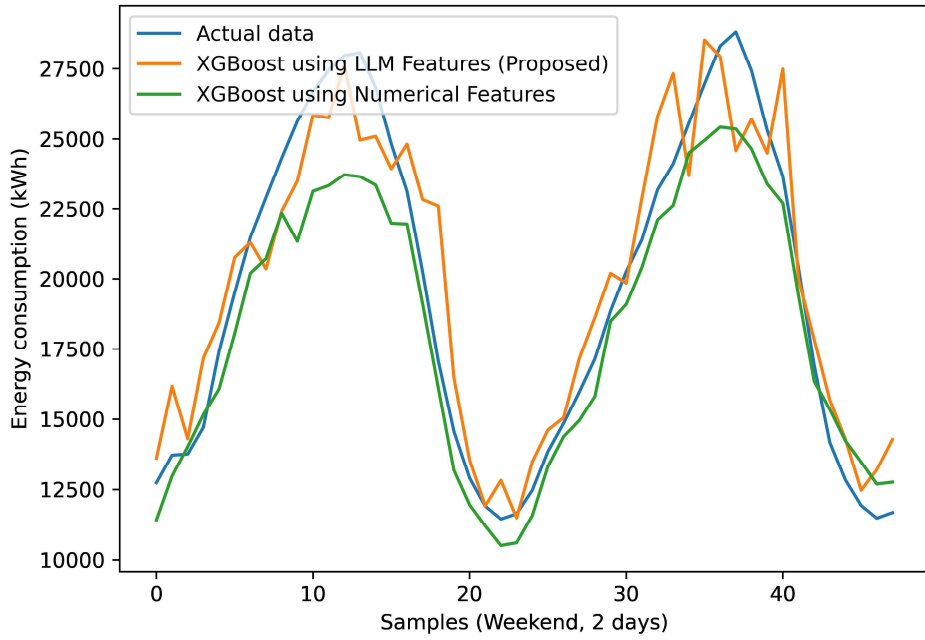


Fig. 4 Comparison of proposed scheme and numerical method with actual data - Weekend, 2 days




Fig. 5 Attention Weights in Electra

더욱 정확하게 예측한다는 점을 확인할 수 있다.

4.4 LLM의 주의집중 가중치 시각화

LLM을 이용한 프롬프트에 대한 임베딩 벡터의 추출 과정을 확인하기 위해, LLM의 주의집중 가중치를 시각화하였다. Fig. 5, 6, 7은 각각

Electra, RoBERTa, DistilBERT를 이용하여 프롬프트에 대한 임베딩 벡터를 추출하는 데 있어서의 주의집중 가중치를 나타낸다. 프롬프트의 토큰 형식에 대하여, LLM의 기반이 되는 모델인 Transformer의 Head 각각에서의 주의집중 가중치를 평균화하여 시각화하였다. 3개의 LLM이 공통적으로 프롬프트에서 입력 데이터의 시점을 나타내는 ‘January’를 확인함과 동시에, 지




Fig. 6 Attention Weights in RoBERTa




Fig. 7 Attention Weights in DistilBERT

시 사항을 기술한 부분인 ‘What is the electric energy consumption’을 크게 주목하고 있음을 확인하였다. 이를 통해, LLM이 시간에 대한 특성과 예측 과제에 대한 설명을 시작하는 부분에 많은 주의집중 가중치를 부여하고 있으며, 이러한 정보가 예측에 있어 주요한 영향을 미쳤다는 점을 파악할 수 있었다. 특히, 본 예측 과제가 특정 시점에서의 전력 수요량을 예측한다는 것을 인식함으로써 시계열 예측 배경에 대한 이해도를 높인 것이 모델의 예측 성능 향상에 도움을 줄 수 있다는 점을 확인할 수 있었다.

5. 결론

본 논문에서는 LLM 기반의 특징 추출을 이용하여 단기 전력 수요량을 예측하는 기법을 제안하였다. 정형 데이터 형태로 표현된 데이터를 프롬프트 형식으로 변환하였으며, 가중치가 동결된 LLM을 이용하여 프롬프트에 대한 임베딩 벡터를 도출하였다. 이후, 기계학습 모델을 이용하여 임베딩을 학습시키고 예측을 수행하였다. 실험 결과, 제안 기법은 수치형 데이터에 기반하여 학습한 기계학습 모델에 비해 높은 성능을 보였고, 그중에서도 Electra에 기반하여 임베딩 벡터를 도출한 것이 가장 우수한 성능을 보였

다. 이를 통해, 입력변수의 수치적 특성을 파악하는 데에만 초점을 둔 기존의 기계학습 모델을 넘어, LLM을 이용하여 입력변수로 활용되는 각 요소 간에 내재된 의미론적 관계를 포착하고 이를 예측 모델에 반영하면 모델의 예측 성능을 높일 수 있다는 점을 확인할 수 있었다. 또한, 프롬프트에 대한 LLM의 주의집중 가중치를 시각화한 결과, LLM이 프롬프트에서 시간에 대한 특성과 주어진 지시 사항을 주목하고 있음을 확인하였다.

이러한 연구 결과는 향후 LLM을 이용하여 주어진 전력 수요량 예측 상황을 명확히 파악하고 입력변수에 대한 모델의 정보 표현 능력을 향상시킴으로써 전력 수요량 예측 모델의 성능 역시 높이는 방안에 대한 연구를 촉진시킬 수 있을 것으로 기대된다. 또한, 본 연구에서는 전력 수요량 예측에 있어 입력변수로 시간적 정보와 기온을 활용하였지만, 실제 전력 수요량 예측에 있어서는 이 변수들뿐만 아니라 예측 환경을 나타내는 여러 변수들을 입력변수로 활용할 수 있다. 예컨대, 지역의 위치 및 면적, 유동 인구, 지역 내 산업 활동 등은 전력 이용량의 패턴에 큰 영향을 끼칠 수 있다. 따라서, 실무적인 관점에서는 이러한 변수들을 반영하여 구축한 프롬프트에 대하여 LLM을 이용하여 특징을 추출하고, 이를 기반으로 전력 수요량을 예측함으로써 LLM을 통해 지역의 특성을 의미론적으로 고려한 전력 수요량 예측 모델을 구축할 수 있을 것으로 기대된다.

제안하는 기법은 기존의 수치형 데이터 기반의 기계학습 모델보다 더욱 우수한 예측 성능을 보여주었지만, 이를 검증하기 위해 본 논문에서 활용한 실험 데이터 셋은 단일 출처로 한정되어 있다는 한계점이 있다. 이에, 향후 연구로 여러 유형의 전력 에너지 사용량 데이터 셋을 이용하여 제안하는 기법의 우수성을 확인해볼 예정이다. 또한, 방대한 양의 텍스트 데이터를 사전 학습한 LLM은 주어진 프롬프트에 대한 의미론적 특징을 파악하는 임베딩 벡터를 도출할 수 있을 뿐만 아니라, 직접적으로 주어진 문제를 해결하기 위한 모델로 활용됨으로써 해당 문제에서의 성능을 개선할 수 있다(Zhu et al., 2023). 이를

반영하여, 향후 연구에서는 학습 데이터가 부족한 상황에서 LLM 자체를 예측 모델로 이용하여 전력 수요량을 예측하는 방법을 연구할 계획이다.

References

- Aisyah, S., Simaremare, A., Adytia, D., Aditya, I. and Alamsyah, A. (2022). Exploratory Weather Data Analysis for Electricity Load Forecasting Using SVM and GRNN, Case Study in Bali, Indonesia. *Energies*, 15(10), <https://doi.org/10.3390/en15103566>
- Chen, T. and Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Aug. 13 - 17, San Francisco, CA, USA, pp. 785-794.
- Chodakowska, E., Nazarko, J. and Nazarko, L. (2021). ARIMA Models in Electrical Load Forecasting and Their Robustness to Noise. *Energies*, 14(23), <https://doi.org/10.3390/en14237952>
- Clark, K., Luong, M., Le, Q. and Manning, C. (2020). ELECTRA: Pre-training Text Encoders as Discriminators Rather Than Generators. *International Conference on Learning Representations*, Apr. 26 - 30, Virtual, pp. 1-18.
- Conneau, A., Khandelwal, K., Goyal, N., Chaudhary, V., Wenzek, G., Guzman, F., Grave, E., Ott, M., Zettlemoyer, L. and Stoyanov, V. (2020). Unsupervised Cross-lingual Representation Learning at Scale. *Annual Meeting of the Association for Computational Linguistics*, Jul. 06 - 08, Online, pp. 8440-8451.
- Dehalwar, V., Kalam, A., Kolhe, M. and Zayegh, A. (2016). Electricity Load Forecasting for Urban Area Using Weather Forecast

- Information. *IEEE International Conference on Power and Renewable Energy*, Oct. 21 - 23, Shanghai, China, pp. 355-359.
- Devlin, J., Chang, M., Lee, K. and Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *Conference of the North American Chapter of the Association for Computational Linguistics*, Minneapolis, MN, USA, pp. 4171-4186.
- Dudek, G. (2022). A Comprehensive Study of Random Forest for Short-Term Load Forecasting. *Energies*, 15(20), <https://doi.org/10.3390/en15207547>
- Hong, T., Pinson, P. and Fan, S. (2014). Global Energy Forecasting Competition 2012. *International Journal of Forecasting*, 30(2), 357-363, <https://doi.org/10.1016/j.ijforecast.2013.07.001>
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q. and Liu, T. (2017). LightGBM: A Highly Efficient Gradient Boosting Decision Tree. *International Conference on Neural Information Processing Systems*, Dec. 04 - 09, Long Beach, CA, USA, pp. 3149-3157.
- Kim, H. and Yu, Y. (2023). Development of a Regulatory Q&A System for KAERI Utilizing Document Search Algorithms and Large Language Model. *Journal of Korea Society of Industrial Information Systems*, 28(5), 31-39, <http://doi.org/10.9723/jksiiis.2023.28.5.031>
- Kim, H., Jang, J., Kim, J. and Kim, K. (2023). Predicting Forest Fires Using Machine Learning Considering Human Factors. *Journal of Korea Society of Industrial Information Systems*, 28(5), 109-126, <https://doi.org/10.9723/jksiiis.2023.28.5.109>
- Kumar, M. and Pal, N. (2023). Machine Learning-based Electric Load Forecasting for Peak Demand Control in Smart Grid. *Computers, Materials & Continua*, 74(3), <https://doi.org/10.32604/cmc.2022.032971>
- Lan, Z., Chen, M., Goodman, S., Gimpel, K., Sharma, P. and Soricut, R. (2020). ALBERT: A Lite BERT for Self-supervised Learning of Language Representations. *International Conference on Learning Representations*, Apr. 26 - 30, Virtual, pp. 1-17.
- Lee, C. and Ko, C. (2011). Short-term Load Forecasting Using Lifting Scheme and ARIMA Models. *Expert Systems with Applications*, 38(5), 5902-5911, <https://doi.org/10.1016/j.eswa.2010.11.033>
- Lee, D. (2023). The Prediction of Survival of Breast Cancer Patients Based on Machine Learning Using Health Insurance Claim Data. *Journal of Korea Society of Industrial Information Systems*, 28(2), 1-9, <https://doi.org/10.9723/jksiiis.2023.28.2.001>
- Lee, H. and Shin, Y. (2013). Forecasting Electric Power Demand Using Census Information and Electric Power Load. *Journal of Korea Society of Industrial Information Systems*, 18(3), 35-46, <https://doi.org/10.9723/jksiiis.2013.18.3.035>
- Lee, J., Moon, J., Park, S. and Hwang, E. (2022). Photovoltaic Power Forecasting Scheme Based on CTGAN Oversampling Considering Weather Data Imbalance Problem. *Korea Software Congress*, Dec. 20 - 23, Jeju, Republic of Korea, pp. 1379-1381.
- Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., Levy, O., Lewis, M., Zettlemoyer, L. and Stoyanov, V. (2019). RoBERTa: A Robustly Optimized BERT Pretraining Approach. *arXiv preprint*, arXiv:1907.11692
- Louppe, G. (2014). Understanding Random Forests: From Theory to Practice. *University of Liege, Belgium*, Ph.D. Dissertation.
- Moon, J., Jung, S., Park, S. and Hwang, E. (2020a). Conditional Tabular GAN-Based

- Two-Stage Data Generation Scheme for Short-Term Load Forecasting. *IEEE Access*, 8, 205327-205339, <https://doi.org/10.1109/ACCESS.2020.3037063>
- Moon, J., Kim, J., Kang, P. and Hwang, E. (2020b). Solving the Cold-Start Problem in Short-Term Load Forecasting Using Tree-Based Methods. *Energies*, 13(4), <https://doi.org/10.3390/en13040886>
- Oh, J., Ham, D., Lee, Y. and Kim, G. (2019). Short-term Load Forecasting Using XGBoost and the Analysis of Hyperparameters. *The Transactions of the Korean Institute of Electrical Engineers*, 68(9), 1073-1078, <https://doi.org/10.5370/KIEE.2019.68.9.1073>
- Raju, M. and Laxmi, A. (2020). IOT Based Online Load Forecasting Using Machine Learning Algorithms. *Procedia Computer Science*, 171, 551-560, <https://doi.org/10.1016/j.procs.2020.04.059>
- Saglam, M., Lv, X., Spataru, C. and Karama, O. (2024). Instantaneous Electricity Peak Load Forecasting Using Optimization and Machine Learning. *Energies*, 17(4), <https://doi.org/10.3390/en17040777>
- Sanh, V., Debut, L., Chaumond, J. and Wolf, T. (2019). DistilBERT, A Distilled Version of BERT: Smaller, Faster, Cheaper and Lighter. *arXiv preprint*, arXiv:1910.01108.
- Son, S. (2023). The Evolution and Future Role of Smart Grids. *Fall Conference on Smart Grid Research*, Oct. 20, Seoul, Republic of Korea, pp. 1-12.
- Tan, Y., Teng, Z., Zhang, C., Zuo, G., Wang, Z. and Zhao, Z. (2021). Long-Term Load Forecasting Based on Feature Fusion and LightGBM. *IEEE International Conference on Power and Energy Applications*, Oct. 09-11, Busan, Republic of Korea, pp. 104-109.
- Wang, W. (2016). Improved Short Term Load Forecasting of Power System Based on ARMA model. *International Conference on Engineering Management*, Nov. 26 - 27, Guangzhou, China, pp. 12 - 19.
- Zhu, Y., Yuan, H., Wang, S., Liu, J., Liu, W., Deng, C., Chen, H., Dou, Z. and Wen, J. (2023). Large Language Models for Information Retrieval: A Survey. *arXiv preprint*, arXiv:2308.07107



이 재 승 (Jaeseung Lee)

- 고려대학교 통계학과 학사
- (현재) 고려대학교 전기전자공학과 석사과정
- 관심분야: 통계적 머신러닝, 빅데이터, 거대언어모델



유 제 혁 (Jehyeok Rew)

- 정회원
- 경희대학교 전자전파공학과 학사
- 고려대학교 전기전자컴퓨터공학과 박사
- 덕성여자대학교 데이터사이언스학과 조교수
- 관심분야: GIS, 정보검색, 빅데이터, 인공지능