

기후변화, 사회경제적 및 공간적 요소를 고려한 주택용 전력 소비 예측*

Forecasting Residential Electricity Consumption Considering Climate Change, Socio-economic and Spatial Factors

신유진** · 윤희연***

Shin, Yoojin · Yoon, Heeyeun

Abstract

Residential electricity consumption is influenced by climatic, socio-economic, and regional spatial factors, underscoring the need for accurate demand forecasting and effective energy management strategies. However, research explicitly integrating the combined effects of these factors remains limited. This study examined the key determinants of residential electricity consumption in South Korea to develop a machine learning-based forecasting model. Using data from 2008 to 2022, a fixed-effects panel model was employed to identify significant climatic, socio-economic, and regional spatial variables. The SelectKBest algorithm was then applied to determine the optimal set of predictors. Subsequently, a Long Short-Term Memory (LSTM) model was used to forecast electricity demand, and Permutation Feature Importance (PFI) analysis was employed to evaluate the relative importance of each variable. The results revealed that climatic variables, including the average temperature, heatwave days, and average relative humidity, had the most substantial impact. Socio-economic variables, such as the electricity sales price and workdays, also played important roles, while the number of households was a key regional spatial factor. The proposed model achieved a Mean Absolute Percentage Error (MAPE) of 3.82%, demonstrating robust forecasting performance. These findings highlight the importance of prioritizing climatic variables while incorporating socio-economic and regional spatial factors into electricity demand forecasting. The results provide actionable insights for energy management and support the development of adaptive strategies in response to climate change.

주제어 기후변화, 주택용 전력 소비, 사회경제적 요소, 지역 공간적 요인, 장단기 메모리 신경망

Keywords Climate Change, Residential Electricity Consumption, Socio-economic Factors, Regional Spatial Factors, Long Short-Term Memory

1. 서론

지속적인 도시화, 경제 및 인구 성장으로 인해 전력 수요가 급증함에 따라, 전 세계 전력 사용량은 2000년 14,972TWh에서

2022년 28,510TWh로 두 배 가까이 증가하였다(Yoo and Lee, 2010; Global Electricity Review 2023, 2023). 한국의 1인당 전력 사용량 또한 2010년 9.5MWh에서 2020년 10.5MWh로 약 11% 증가한 것으로 나타났다(Ember, 2021).

* 이 논문은 환경부 지식기반 환경서비스 전문인력 양성사업과 한국환경산업기술원 "신기후체제 대응 환경기술 개발사업" (RS-2022-KE002152), 한국연구재단의 (NRF-2022R1A2C2093163) 지원을 받았습니다.

** Master Student, Department of Landscape Architecture and Rural Systems Engineering, Integrated Major in Smart City Global Convergence, Seoul National University (First Author: yoojins@snu.ac.kr)

*** Professor, Department of Landscape Architecture and Rural Systems Engineering, Seoul National University (Corresponding Author: hyyoon@snu.ac.kr)

전력 수요는 계절과 주간을 포함한 다양한 시간대에 걸쳐 규칙적인 패턴으로 변동한다(Barkhordar et al., 2022). 여름철과 겨울철에는 냉방과 난방 수요로 인해 봄, 가을에 비해 전력 사용량이 급증한다(Jovanović et al., 2015). 이러한 시기에는 전력 공급의 안정성을 확보하는 것이 매우 중요하다. 전력 공급이 수요를 충족하지 못할 경우, 가정 내 전자기기 사용 중단, 대중교통의 마비와 같은 일상생활의 불편이 발생할 수 있다(Haes Alhelou et al., 2019; Khosa et al., 2022). 극단적인 경우에는 대규모 정전이 발생하여 경제적 손실과 사회적 혼란을 초래할 수 있다(De Nooij et al., 2009). 실제로 2003년 미국 동북부와 캐나다에서 발생한 대규모 정전 사태는 약 5,000만 명의 생활에 직·간접적 불편을 끼쳤으며, 최소 60억 달러의 경제적 손실을 발생시켰다(Goodrich, 2005). 2021년 텍사스 정전 사태는 450만 명이 전기 공급 중단으로 불편을 겪었으며, 2,000억 달러의 경제적 손실을 초래하였다(Wu et al., 2021). 전기의 저장은 매우 한정적이기 때문에(Zhang et al., 2022), 안정적 전력 공급을 위해 수요를 예측하고 효율적인 전력 공급 전략을 수립해야 한다(Raza and Khosravi, 2015).

전력 예측에는 기상 조건, 경제 활동, 인구 분포 등 다양한 요소가 복합적으로 고려되어야 한다(Chang et al., 2011; Mamun et al., 2020; Waseem et al., 2021). 더불어 기후변화로 인한 이상 기상 현상과 도시화로 인한 인구 및 경제 활동의 밀집은 전력 예측을 더욱 어렵게 한다(Ghalekhondabi et al., 2017). 특히 최근 심각성이 대두되고 있는 기후변화는 전력 예측의 중요한 요소로 작용한다. 폭염, 한파와 같은 극단적 기상 현상은 전력 수요에 즉각적인 변화를 초래하며(Añel et al., 2017), 장기적인 기온 상승과 비정상적 강수 패턴은 전력 사용의 변동성을 증가시켜 예측의 어려움을 가중시킨다(Mideksa and Kallbekken, 2010; Qin et al., 2020; Xiong et al., 2024). 2018년부터 여름철 한시적으로 시행되고 있는 누진세 완화 조치는 이렇듯 급격한 전력 사용 변동성 속에서 소비자의 부담을 줄이기 위한 목적으로 고안되었다(Kim, 2020). 이는 주택용 전력이 기후에 밀접한 영향을 받는다는 점을 보여준다.

사회경제적 요소와 지역 공간적 요소는 전력 수요 예측에 필요한 또 다른 주요 변수이다. 산업과 경제 상황, 인구 이동, 정책 변화 등은 모두 전력 수요에 영향을 미친다(Kaur and Luthra, 2018; Mahmood et al., 2022; Allcott and Mullainathan, 2010). 경제 호황기에는 전력 수요가 증가하는 반면 경기 침체기에는 감소한다. 인구 이동과 도시화는 전력 수요의 지리적 분포를 변화시키며, 에너지 정책 변화는 전력 사용 효율성과 소비 행태에 영향을 미친다. 또한 도시 구조, 주거 밀도, 토지 이용 형태 등은 전력 수요의 절대 규모뿐 아니라 공간적 분포와 에너지 수요의 집중도에도 영향을 미친다(Ki and Yoon, 2024; Chen et al., 2018). 도심 집중 지역이나 고밀도 주거 지역은 에너지 사용

의 최대부하 시점과 양상을 결정짓는 주요 요인이 되기도 한다. 이러한 요소들은 예측 모델을 복잡하게 만들고 정확도를 낮출 수 있다(Li et al., 2024).

최근 연구들에서는 전력 수요 예측 정확성을 향상하기 위해 인공신경망(Artificial Neural Network, ANN), 심층신경망(Deep Neural Networks, DNN), 장단기 기억(Long Short-Term Memory, LSTM)과 같은 알고리즘을 활용하고 있다(Kaytez et al., 2015; Amber et al., 2018; Wang et al., 2020). 이러한 알고리즘들은 복잡한 데이터 패턴을 학습하여 예측 성능 향상에 기여한다(Montesinos López et al., 2022; Karim et al., 2018). 특히 LSTM은 순환 신경망(Recurrent Neural Network, RNN)의 발전된 형태로, 입력 게이트, 출력 게이트, 망각 게이트를 추가로 고려하여 시계열 데이터의 장기 의존성을 효과적으로 처리함으로써 높은 예측 정확도를 제공한다.

그러나 기존의 전력 수요 예측 연구들은 주로 단일 또는 일부 범주의 변수에 초점을 맞추는 경향이 있었으며, 그 결과 다양한 요소 간의 상호작용이나 변수 간 연관성을 충분히 반영하지 못하는 한계가 있었다(Grigoryan, 2021; Chapagain et al., 2020; Manowska, 2020; Torres et al., 2022). 기후 및 사회경제적 변수를 함께 고려한 사례도 일부 존재하지만(Liu et al., 2021a), 도시화 수준, 주거 밀집도 등 지역 간 공간 구조를 변수로 포함한 예측 연구는 여전히 제한적이다. 세 가지 범주에 해당하는 변수들은 전력 소비 변동을 유발하는 핵심 요소인 만큼, 이를 통합적으로 고려하지 않는다면 예측의 정밀도와 해석 가능성 모두에서 한계가 발생할 수밖에 없다.

이에 본 연구에서는 기후 요소, 사회경제적 요소, 지역 공간적 요소를 종합적으로 고려하여 변수별 영향력을 정량적으로 분석하고 전력 수요 예측의 설명력과 예측 정확도를 동시에 높이고자 하였다. 분석의 흐름은 다음과 같다. 먼저, 패널 분석을 통해 주택용 전력 사용량에 영향을 미치는 주요 요소를 식별한다. 이어서, SelectKBest 기법을 활용하여 예측 모델의 성능을 향상시킬 수 있는 변수 조합을 선정하고, LSTM 모델을 사용하여 주택용 전력 사용량을 예측한다. 마지막으로 순열 특성 중요도(Permutation Feature Importance, PFI) 기법을 적용하여 예측 모델의 성능 향상에 기여하는 변수의 중요도를 평가한다. 이러한 과정을 통해 보다 정교하고 신뢰성 있는 수요 예측 모델을 제시하고자 한다.

II. 선행연구 고찰

1. 기후 요소와 전력 수요

기후 요소는 전력 수요에 직접적인 영향을 미친다(Pilli-Sihvola et al., 2010; Georgopoulou et al., 2024). 여름철 고온은 냉방 기기 사용을 늘리고, 겨울철 저온은 난방 기기 사용을 촉진

한다. Liu et al.(2021b)에 따르면, 기온이 30℃를 초과하는 날이 하루 추가될 때 월간 전력 소비가 평균적으로 16.8% 상승하는 반면, -6℃ 미만의 온도가 하루 더 발생하면 전력 소비는 6% 증가한다. 또한 세르비아의 소규모 도시를 대상으로 2007년부터 2012년까지 분석한 연구에 따르면, 겨울철 기온이 하락할 때 전력 수요는 0.3MW를 초과한다(Savić et al., 2014). 이는 기온 변화와 함께 냉난방도일도 전력 수요에 중요한 요소임을 시사한다.

습도가 높을수록 체감 온도가 상승하여 냉방을 위한 에너지 소비가 증가한다는 연구 결과도 있다. 미국 남동부 지역을 대상으로 상대습도의 전력 수요 영향을 분석한 연구에 따르면, 습도가 높을수록 체감 온도가 상승하여 냉방 수요가 늘어나고 전력 소비가 13%에서 33%까지 증가한다(Rastogi et al., 2021). Maia-Silva et al.(2020)은 미국 본토 여름철 전력 수요 모델링에서 습도의 중요성을 강조하였으며, 공기 온도만 고려한 모델은 냉방 수요를 10%에서 15%까지 과소평가할 수 있다고 지적하였다.

일사량은 태양 복사 에너지의 양을 의미하며(Daut et al., 2012), 높은 일사량은 냉방 장치의 사용을 증가시킨다(Alahmer and Ajib, 2020). 반대로 일사량이 부족한 겨울에는 난방 수요가 높아지며 추가적인 에너지 소비가 발생한다(Vlachokostas and Madamopoulos, 2016). 따라서 계절별 일사량 변화는 전력 수요에 중요한 영향을 미치며, 에너지 관리에서 고려해야 할 요소이다.

2. 사회경제적 요소와 전력 수요

다양한 사회경제적 요소는 전력 수요에 영향을 미친다. 많은 연구에서 도시화 진행에 따른 가정, 상업, 산업 전력 수요 변화를 고찰하였다(Faisal et al., 2018). Xie et al.(2020)은 도시화가 외부 환경을 개선하여 에너지 소비를 줄일 수 있으나, 가계 소득 증가와 가구 규모 감소와 같은 요인으로 에너지 소비가 간접적으로 늘어나며, 결과적으로 주거용 에너지 소비가 증가한다고 밝혔다.

또한 선행연구에 따르면, 가구의 소득 수준이 높아질수록 전력 소비도 증가한다. 이는 전자제품 및 가전기기의 사용 증가와 밀접한 관련이 있다. 소득 증가는 상품과 서비스에 대한 수요를 높이고, 그 결과 에너지 소비와 탄소 배출이 증가한다(Bakirtas and Akpolat, 2018; Wang et al., 2022; Shabur and Ali, 2024). Ali et al.(2021)에 따르면, 월 소득이 높은 가구는 재정 자원이 안정적이고 가전제품을 구입할 여력이 커 더 많은 전력을 소비한다.

전력 가격의 상승은 소비자의 전기 사용 패턴에 상당한 영향을 미친다. 전기요금의 인상은 에너지 절약 행동을 유도하여 전력 사용을 감소시킨다. 경제 위기와 전기요금 급등이 전력 소비에 미친 영향을 분석한 연구에 따르면, 전력 소비는 특히 중·고소득 가구에서 더욱 두드러지게 줄어든다(Romero-Jordán et al., 2016). 전기 사용 습관 역시 전력 수요에 영향을 준다. Wang et al.(2021)에 따르면, 전기 절약 습관이 없는 가구는 전기 절약 습

관이 있는 가구보다 월평균 15.54kWh 더 많은 전력을 소비한다.

전력 소비 패턴은 시기에 따라 달라진다. Aki et al.(2018)는 주말과 공휴일의 가정 내 전력 소비가 평일보다 높다는 점을 설명하였으며, Cetin et al.(2014)은 재택근무 여부와 근무일 및 주말의 구분이 전력 소비 패턴에 미치는 영향을 발견하였다. 가정의 에너지 소비는 사람들이 집에서 보내는 시간과 활동에 크게 좌우된다(Kipping and Trømborg, 2015).

3. 지역 공간적 요소와 전력 수요

지역 공간적 요소는 전력 수요에 공간적 구조와 맥락을 통해 직접적으로 영향을 미친다. 도시화는 도시 구조 및 에너지 수요 패턴을 변화시키는 핵심 요인으로, 전력 소비의 공간적 분포에도 구조적 영향을 미치는 것으로 분석된다(Madlener and Sunak, 2011). 도시의 외연적 확산은 토지 자원의 비효율적 배분과 저밀도 확장으로 이어지며, 이에 따라 전력 수요는 도시 전역으로 확산되고 에너지 관리 효율성은 저하될 수 있다(Li et al., 2023). Shi et al.(2019)는 도시화율이 높은 지역일수록 전력 수요가 도시 내 고밀도 지역에 집중되는 경향을 보이며, 동시에 지역 간 전력 소비의 공간적 편차가 뚜렷하게 나타난다고 밝혔다. 또한, Hua et al.(2023)에 따르면, 도시화가 진행될수록 농촌 지역은 에너지 인프라 접근성과 전력 소비에서 도심과 뚜렷한 격차를 보이며, 이는 공간적 에너지 소비의 구조적 불균형으로 이어질 수 있다.

지역 인구 구조는 공간 단위의 생활 방식과 전력 소비 양상에 밀접하게 작용한다. 인구가 증가하면 지역 내 전력 수요가 늘어나며, 특히 인구 밀도가 높은 지역일수록 에너지 소비가 더욱 활발하게 이루어진다(Kaur and Luthra, 2018; Cui et al., 2019; Muzayanah et al., 2022). Huang(2015)에 따르면, 가구 규모가 커질수록 주거용 전력 소비량은 증가하지만 1인당 소비량은 오히려 감소하는 경향을 보인다. 이는 구성원 간 자원 공유를 통해 전력 사용 측면에서 규모의 경제가 작용함을 시사한다. Andersen et al.(2021)은 인구 구성과 가구 특성에 따라 전력 소비 수준뿐만 아니라 시간대별 사용 패턴에서도 뚜렷한 차이가 나타남을 밝혔다.

전력 소비 양상은 도시의 물리적 공간 구조에 따라 다르게 나타난다. 건물 밀도, 유형, 배치 등 도시 공간의 구성 요소는 전력을 포함한 건물 에너지 소비에 영향을 미치며, 이들 요소에 따라 에너지 사용의 분포와 소비 행태도 구조적으로 달라진다(Quan and Li, 2021). Li et al.(2018)은 동일한 도시 공간 내에서도 주거 유형에 따라 전력 소비 양상이 뚜렷하게 달라지며, 고밀도 공동주택 지역은 여름철 냉방 수요 증가로 인해 소비가 높고, 저밀도 단독주택 지역은 상대적으로 낮은 소비 특성을 보인다고 분석하였다. 또한, Chen et al.(2018)에 따르면, 건물 배치와 토지 이용 구성에 따라 전력 소비 양상은 달라질 수 있으며, 건물 간 거리가

좁고 공지 및 건축지 비율이 일정 수준 이상일 경우 냉방 수요가 완화되어 전력 소비가 줄어드는 경향을 보인다.

4. 전력 수요 예측에서의 기계학습 기법

전력 수요는 계절성, 비선형성, 시계열 의존성이 복합적으로 작용하는 예측 대상이다. 이러한 특성으로 인해 단순 회귀 모형이나 기존 시계열 분석 기법만으로는 안정적인 예측 정확도를 확보하는 데 한계가 있다(Divina et al., 2019; Kumar Dubey et al., 2021). 이를 보완하기 위해 전력 수요 예측에서는 ANN, 서포트 벡터 머신(Support Vector Machine, SVM), DNN, LSTM 등 다양한 기계학습 알고리즘이 도입되고 있으며, 이들은 전력 수요의 패턴을 학습하고 미래 수요를 효과적으로 예측하는데 활용된다(Kaytez et al., 2015; Amber et al., 2018). 이러한 기법들은 구조와 연산 방식에 따라 성능 차이를 보이며, 데이터 특성과 예측 목적에 적합한 기법 선택이 중요하다.

ANN은 다층 퍼셉트론 구조를 기반으로 입력 변수 간 비선형 관계를 효과적으로 모델링할 수 있는 기계학습 알고리즘으로(Soori et al., 2023), 전력 수요 예측 분야에서 비교적 이른 시기부터 활용되어 왔다. Al-Saba and El-Amin(1999)은 ANN이 기존 시계열 모델 대비 실재값에 더 근접한 결과를 산출했음을 보고하였으며, 효과적인 예측 도구로 활용될 수 있음을 제시하였다. Chae et al.(2016) 역시 시간대별 소비 데이터를 활용하여 ANN이 높은 예측 정확도를 나타냄을 실증하였다. 그러나 ANN은 시계열 데이터의 시간적 연속성과 장기 의존성을 충분히 반영하지 못하는 한계를 가지며, 훈련 데이터가 부족할 경우 과적합이 발생하기 쉽다(Chu et al., 2021; Ubal et al., 2023). 이러한 한계로 인해, 계절성과 장기 패턴이 중요한 전력 수요 예측에서는 성능이 제한될 수 있다.

SVM은 입력 데이터를 고차원 특성 공간으로 변환하여 복잡한 패턴을 분류하거나 회귀분석하는 데 효과적인 기계학습 기법이다. 비교적 적은 학습 데이터만으로도 높은 일반화 성능을 보이기 때문에 전력 수요 예측에 폭넓게 활용되어 왔다(Hong, 2009; Pallonetto et al., 2022). 다만, SVM은 커널 함수와 하이퍼파라미터 설정에 민감하여 조정이 적절히 이루어지지 않으면 과적합이나 일반화 성능 저하가 발생할 수 있다(Roman et al., 2021). 특히 계절성과 비선형성이 동시에 작용하는 전력 수요 예측에서는 이러한 민감성이 모델 튜닝을 어렵게 만들어 성능에 제약을 줄 수 있다.

DNN은 다수의 은닉층을 통해 입력 변수 간의 복잡한 비선형 관계를 학습할 수 있는 심층신경망 기법으로(Oluleye et al., 2023), 고차원 입력 변수와 대규모 데이터를 처리하는 데 강점을 지닌다. 이러한 특성 덕분에 복잡한 패턴을 갖는 전력 수요 예측에서도 활발히 적용되고 있다. 그러나 DNN은 은닉층이 깊고 파

라미터 수가 많아 훈련 데이터가 부족할 경우 과적합이 발생할 가능성이 크고, 모델 해석이 어렵다는 한계가 있다(Salman and Liu, 2019; Zhang et al., 2021). 이러한 특성은 설명 가능성과 투명성이 요구되는 전력 수요 예측에서 신뢰성을 저하시킬 수 있다.

LSTM은 RNN의 발전된 형태로, 각 시점의 출력이 다음 시점의 입력으로 전달되는 순환 구조를 통해 시계열 데이터의 복잡성과 장기 의존성을 효과적으로 처리할 수 있는 딥러닝 알고리즘이다(Panapongpakorn and Banjerdpongchai, 2019). 게이트 메커니즘을 통해 중요한 정보를 선택적으로 유지하고 불필요한 정보를 제거함으로써 예측 성능을 높일 수 있다(Thapa and Duraipandian, 2021). 이러한 특성 덕분에 LSTM은 전력 수요와 같은 시계열 기반 예측에서 높은 정확도를 제공하는 모델로 널리 활용되고 있으며(Muzaffar and Afshari, 2019), 다층 퍼셉트론(Multi-Layer Perceptron, MLP), 랜덤 포레스트(Random Forest, RF), SVM 등과 비교해 더 우수한 성능을 보이는 것으로 보고되었다(Wang et al., 2019).

다만, LSTM은 순차적 계산 구조로 인해 병렬 처리에 제약이 있고 학습 속도가 느리다는 한계가 존재한다(Al-Selwi et al., 2024). 본 연구는 기후, 사회경제적, 지역 공간적 요소 등 다양한 변수가 시계열적으로 누적되어 작용하는 주택용 전력 수요의 특성을 반영하고자 하였으며, 이러한 장기 의존성과 비선형 패턴을 효과적으로 학습할 수 있는 LSTM이 예측 목적에 가장 적합하다고 판단하였다.

III. 연구 설계

1. 연구 목적

본 연구의 목표는 대한민국 주택용 전력 사용량을 예측함에 있다. 이를 위해 패턴 분석과 SelectKBest 기반 변수 선택 기법을 활용하여 주요 변수를 선정하였고, 이후 LSTM 모델로 예측 모델을 구축하였다. 마지막으로 PFI 기법을 적용하여 모델 성능에 영향을 미치는 변수들의 기여도를 평가하였다.

2. 연구 범위

본 연구의 대상지인 대한민국은 위도 33°N에서 39°N, 경도 124°E에서 130°E에 위치하며(Park et al., 2015), 온대 기후 지역에 속한다. 뚜렷한 사계절이 있으며, 평년 기온은 12.8°C, 가장 더운 8월의 기온은 26.1°C에 이르며, 가장 추운 1월의 기온은 -1.9°C까지 하락한다(Hwang et al., 2023). 최근 기후변화로 인해 대한민국의 기후 패턴은 급격히 변하고 있는데, 예를 들어, 2023년 대한민국의 연평균 기온은 역대 최고인 13.7°C를 기록하였다(Korea Meteorological Administration, 2024).

연구 기간은 2008년 1월 1일부터 2022년 12월 31일까지이다. 대한민국은 2000년대 초반부터 빠른 경제 성장을 이루었으며, 이에 따라 생활 수준 향상, 소비 패턴의 변화, 기술 혁신과 디지털 전환의 가속화가 나타났다(OECD, 2022; Park, 2009). 한편, 2020년대 초반에는 COVID-19 팬데믹이 발생하여 생활 방식과 사회 전반에 큰 영향을 미쳤다.

〈그림 1〉은 연구 기간 동안 대한민국 시군구별 1인당 주택용 전력 사용량을 나타낸다. 주택용 전력 사용량은 전국적으로 전반적인 증가세를 보였으며, 지역별 공간적 특성에 따라 소비 수준의 편차도 확인할 수 있다.

3. 연구 자료

본 연구에서 사용한 주요 데이터는 한국전력공사(Korea Electric Power Corporation, KEPCO)에서 제공한 2008년부터 2022년까지의 계약종별 전력 사용량이다. KEPCO는 대한민국의 전력 공급을 담당하는 유일한 사업자로, 전력을 독점적으로 송전 및 배전한다(Jang et al., 2024). 이 데이터는 주택용, 일반용, 교육용, 산업용, 농사용, 가로등, 심야 계약 분야로 구분되며, 분야별로 고

객 호수(호), 사용량(kWh), 전기요금(원) 등의 정보를 포함한다.


기후 데이터는 기상청 기상자료개방 포털(Korea Meteorological Administration, KMA)에서 제공되었으며, 전국의 종관기상관측장비(Automated Synoptic Observing System, ASOS)에서 수집된 데이터를 활용하였다.

근무 일수 데이터는 주말과 공휴일을 고려하여 달력 효과를 반영하기 위해 활용되었다. 달력 효과란 특정 시간대, 날짜, 월에 따라 시장에서 비정상적인 가격 변동이나 수익률 변화가 나타나는 현상이다(Li et al., 2019). 코로나19 데이터는 국내 첫 확진자가 발생한 2020년 1월 20일 이후의 데이터를 포함하고, 팬데믹 기간 동안의 주요 변화를 나타낸다. 전력 판매단가 데이터는 KEPCO의 한국전력통계에서 제공되었으며, 이를 통해 계약 분야별 전력 판매단가 변화를 추적하였다.

가구 수 데이터는 행정안전부(Ministry of the Interior and Safety, MOIS)에서 제공되었으며, 주거 밀집도를 반영한다. 도시지역 비율은 한국국토정보공사(Korea Land and Geospatial InformatiX Corporation, LX)의 도시계획현황을 활용하였으며, 도시화 수준과 공간 구조의 특성을 나타낸다.

본 연구에 사용된 데이터는 공공기관에서 제공한 통계 자료로, 결측값이 없어 분석에 활용하였다.

a) 2008 Per Capita Consumption b) 2015 Per Capita Consumption



c) 2022 Per Capita Consumption




Figure 1. Per capita residential electricity consumption by si-gun-gu

4. 변수 정의

본 연구에서는 대한민국 주택용 전력 사용량을 예측하기 위해 다양한 변수를 고려하였다. 종속 변수는 월별 주택용 전력 사용량(HOUSING_ELEC)이다. 주택용 전력 사용량은 산업용 및 일반용에 비해 비중이 작지만, 누진 요금제가 적용되며, 인구, 경제, 기상 조건 등 다양한 비선형 요인의 영향을 받아 변동성이 크다(Kim, 2014; Son and Kim, 2020).

기후 변수로는 평균 기온(TEMP), 평균 상대습도(HUM), 폭염일수(HEAT) 및 한파일수(COLD)를 사용하였다. 평균 기온과 평균 상대습도는 전국 지점에서 측정된 데이터를 역거리 가중법(Inverse Distance Weighting, IDW)으로 보간하여 평균값을 계산하였다. 폭염일수는 일 최고기온이 33℃ 이상인 날의 수, 한파일수는 아침 최저기온이 영하 12℃ 이하인 날의 수로 정의한다(Korea Meteorological Administration, 2024). 기온과 상대습도는 사계절에 따라 전력 수요에 미치는 영향이 상반될 수 있어, 계절적 편차가 나타나는 변수로 가정하였다. 한편, 폭염일수와 한파일수는 극한 기후 상황을 나타내는 이상기후 변수로서, 각각 냉방 및 난방 수요를 증가시켜 전력 사용량을 높이는 요인으로 작용할 것으로 예상하였다. 〈그림 2〉는 연구 기간인 2008년부터 2022년까지 주요 기후 변수의 추세를 나타낸다.

사회경제적 변수로는 근무 일수(WORK), 코로나19(COVID) 및 전력 판매단가(PRICE)를 고려하였다. 근무 일수는 주말과 공

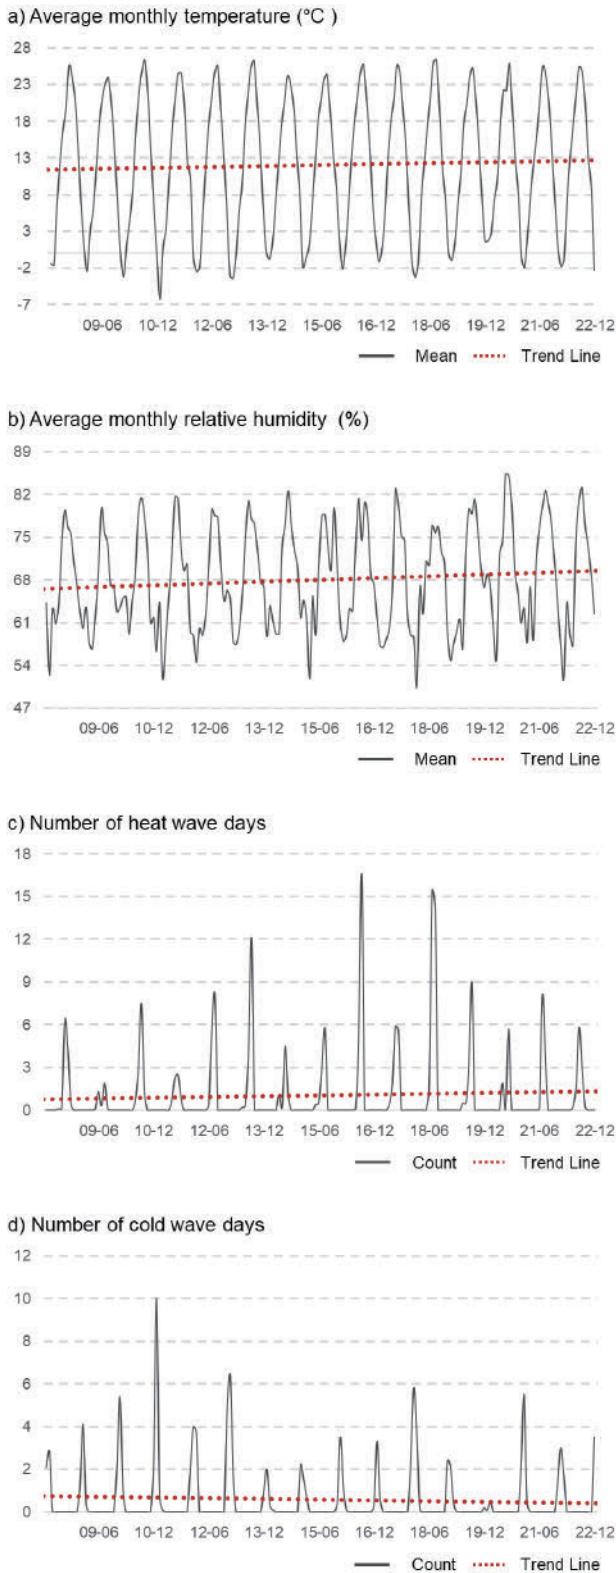


Figure 2. Monthly trends of climate variables

휴일을 제외한 실제 근무일로 정의하고, 전력 사용량의 시점별 변동성 분석에 활용하였다. 근무 일수가 증가할수록 가정 내 체류 시간은 감소하고, 이에 따라 전력 사용량도 줄어들 것으로 가정하였다. 코로나19는 팬데믹 영향을 분석하기 위해 더미 변수로 포함하였다. 재택근무 확대, 외부 활동 제한 등으로 인해 가정 내

전력 소비가 증가했을 것으로 예상하였다. 전력 판매단가는 전력 판매 수입을 판매 전력량으로 나눈 값이다. 한국에서는 전력 사용량이 측정된 후 약 보름의 시차를 두고 전기요금 청구서가 발행된다(KEPCO, 2024). 소비자는 해당 월의 전력 사용량에 대한 요금을 다음 달 중순에 인지하며, 이에 따라 전력 사용 행태를 조정할 수 있다. 그러나 이러한 조정은 즉시 이루어지기 어렵기 때문에 실제 전력 사용량 변화는 그다음 달에 반영되는 경우가 많다. 따라서 본 연구에서는 이러한 지연 효과를 반영하기 위해 2개월 시차를 적용하였다. 전력 가격이 상승하면, 소비자는 요금 부담을 줄이기 위해 전력 사용을 조절하려는 경향을 보일 것으로 가정하였다.

지역 공간적 변수로는, 가구 수(HOUSEHOLD)와 도시지역 비율(URBAN)을 사용하였다. 가구 수는 등록된 세대수를 의미하며, 가구 수가 많을수록 주거 단위 전력 수요가 누적됨에 따라 전체 전력 사용량이 증가할 것으로 가정하였다. 도시지역 비율은 행정구역 내 도시지역으로 분류된 면적이 전체 면적에서 차지하는 비율을 나타내며, 도시화 수준이 높을수록 인프라 및 주거 밀집도가 증가하여 전력 수요가 증가할 것으로 예상하였다.

〈표 1〉은 본 연구에서 사용한 변수의 정의, 단위 및 요약 통계량을 기술 통계로 정리한 것이다.

5. 분석 모형

본 연구에서는 주택용 전력 사용량의 예측을 위해 세 단계의 분석을 수행하였다(그림 3). 첫째, 패널 고정 효과 모형을 사용하여 주택용 전력 사용량에 영향을 미치는 주요 요소를 밝혀 통계적으로 유의한 변수를 선별하였다. 둘째, SelectKBest 변수 선택 기법을 적용하여 예측 성능을 최적화할 수 있는 변수 조합을 도출하였다. 이는 모든 변수를 사용하는 것이 항상 최적의 예측 성능을 보장하지 않으므로 변수 선택 과정이 필요하기 때문이다. 마지막으로, LSTM 모델을 활용하여 주택용 전력 사용량을 예측하고, PFI 기법으로 변수들의 중요도를 평가하였다.

1) 패널 고정 효과 모형

패널 고정 효과 모형은 지역별 특성과 같은 개체 고유 특성을 고정함으로써 개체 간 차이를 통제하고 시간에 따른 개체 내 변화를 분석할 수 있으며, 이를 통해 누락변수 편이를 최소화할 수 있다(Hill et al., 2020).

본 연구의 분석 모형은 다음과 같은 패널 분석 수식으로 표현된다.

$$\begin{aligned}
 Y_{it} = & \beta_0 + \beta_1 TEMP_{it} + \beta_2 HUM_{it} + \beta_3 HEAT_{it} + \\
 & \beta_4 COLD_{it} + \beta_5 WORK_{it} + \beta_6 COVID_{it} + \\
 & \beta_7 PRICE_{it} + \beta_8 HOUSEHOLD_{it} + \\
 & \beta_9 URBAN_{it} + u_i + e_{it}
 \end{aligned}
 \tag{1}$$

Table 1. Variable definitions and descriptive statistics

	Variable	Description	Unit	Mean	Std. dev	Min	Max
Dependent variable	HOUSING_ELEC	Monthly electricity consumption for residences	GWh	5,693.05	805.35	4,445.77	9,269.03
	TEMP	Average monthly temperature	°C	12.68	9.38	-5.53	27.00
Climate	HUM	Average monthly relative humidity	%	68.05	8.48	50.39	85.34
	HEAT	Number of days per month with maximum temperature above 33°C	days	1.06	2.72	0.00	16.60
	COLD	Number of days per month with morning minimum temperature below -12°C	days	0.60	1.44	0.00	10.00
	WORK	Actual workdays per month excluding weekends and holidays	days	20.76	1.38	16.00	23.00
Socio-economic	COVID	Period after the first confirmed COVID-19 case (0, No; 1, Yes)		0.20	0.40	0.00	1.00
	PRICE	Monthly electricity selling price lagged by two months	KRW/kWh	112.45	13.44	79.28	159.79
Regional spatial	HOUSEHOLD	Number of registered households	count	2.11e+07	1.44e+06	1.87e+07	2.37e+07
	URBAN	Share of urban area within each administrative district	%	15.81	0.15	15.42	15.99

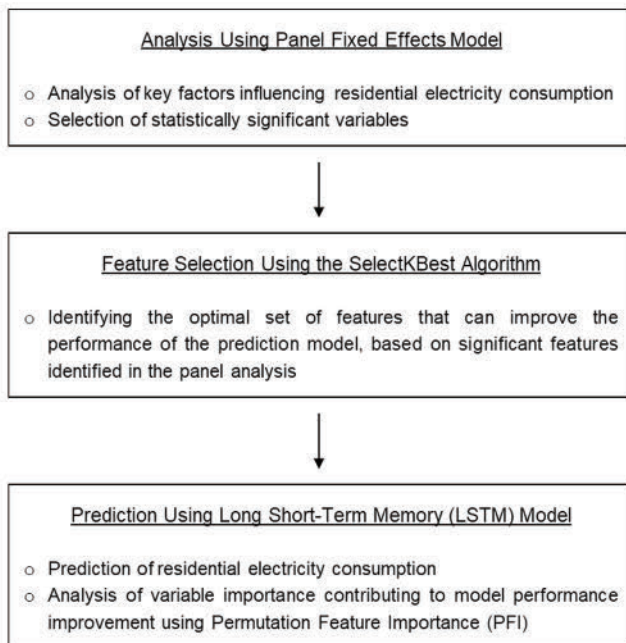


Figure 3. Flowchart of the research

이때, t 는 월을, i 는 시군구를 나타낸다. Y_{it} 는 시군구별 월별 주택용 전력 사용량을, β 는 회귀계수를, u_i 는 시군구별 개체 고유의 고정 효과를, e_{it} 는 잔차를 의미한다.

2) 변수 선택 기법(SelectKBest)

SelectKBest는 다양한 점수 함수를 활용해 예측에 유의미한 설명력을 갖는 변수를 선별하는 필터 방식(filter method)의 변수 선택 기법으로, 계산 비용이 낮고 구현이 간단하다(Desyani et al., 2020; Otchere et al., 2022). 점수 함수는 독립 변수와 종속 변수 간의 통계적 관계를 평가하여 변수 중요도를 정량적으로 측정하며(Senan et al., 2021), 본 연구에서는 선형 회귀 기반의 f -regression을 점수 함수로 적용하였다.

평가된 변수 중요도를 바탕으로 다양한 K값을 설정하여, 각 K에 대해 k-폴드 교차 검증을 수행하였다. 교차 검증은 데이터를 K개의 동일한 부분으로 나눈 뒤, 각 부분을 검증 세트로 번갈아 사용하여 모델을 훈련 및 평가하는 방식으로 진행되었고, 평균 제곱 오차(Mean Squared Error, MSE)를 기준으로 성능을 비교하였다. 최종적으로 MSE가 가장 낮은 K값을 선택하여 모델의 예측 성능을 최적화하였다.

SelectKBest는 예측 변수와 종속 변수 간의 통계적 연관성을 직접 반영할 수 있어 wrapper 방식이나 embedded 방식보다 빠르고 직관적인 변수 선택이 가능하다(Bommert et al., 2020). 이러한 특성은 다양한 예측 모델과의 호환성을 높이고, 고차원 데이터 환경에서 변수 선택의 효율성을 높인다.

3) LSTM 기반 예측 및 변수 중요도 분석

LSTM은 시계열 데이터의 장기 의존성을 효과적으로 파악할 수 있는 RNN의 한 종류로, 기울기 소실 문제를 개선하여 긴 시간 동안의 정보를 더 잘 기억하고 처리할 수 있다(Hochreiter and Schmidhuber, 1997; Karim et al., 2018; Muzaffar and Afshari, 2019). 데이터 전처리 과정에서는 모든 변수를 0과 1 사이의 범위로 조정하기 위해 Min-Max 정규화를 적용하였으며, 이를 통해 변수 간 스케일 차이를 제거하고 모델 학습의 안정성을 높였다. 또한, 12개 시점의 시계열 데이터를 입력으로 사용하여 이후 시점을 예측하도록 구성하였다. 전체 데이터는 훈련, 검증, 테스트 세트로 분할하여 모델의 일반화 성능을 평가하였으며, 이를 통해 과적합을 방지하였다. 모델 학습 과정에서는 Bayesian 최적화를 통해 배치 크기, 에폭 수, 초기 학습률, LSTM 유닛 수, Recurrent Dropout 비율 등의 주요 하이퍼파라미터를 결정하였다. 성능 향상이 없을 경우에는 조기 종료하는 Early Stopping 기법을 적용하여 과적합을 방지하였다. 이러한 전처리 및 학습 과정을 통해 모델의 예측 성능을 최적화하고 일반화 가능성을 확보하였다.

모델 예측 성능 평가는 평균 절대 오차(Mean Absolute Error, MAE), 평균 제곱근 오차(Root Mean Square Error, RMSE), 평균 절대 백분율 오차(Mean Absolute Percentage Error, MAPE)를 사용하여 수행하였다. MAE는 실제값과 예측값의 절대 차이의 평균이며(Rajagukguk et al., 2020), RMSE는 예측 오차 제곱의 평균에 대한 제곱근이다(Hodson, 2022). MAPE는 예측값과 실제값 사이의 퍼센트 오차의 평균으로(Morley et al., 2018), 모델의 예측 정확도를 직관적으로 파악하는 데 도움을 준다.

이후 LSTM 모델 예측 결과를 바탕으로, PFI를 적용하여 각 변수의 중요도를 평가하였다. PFI는 변수 중요도를 정량적으로 산

출하여, 예측 성능에 기여하는 변수를 식별하는 데 활용된다(Molnar et al., 2023). PFI 계산 방법은 다음과 같다. 먼저 기존 모델로 테스트 세트에 대한 예측을 수행하고, 기준 MSE를 측정한다. 그 후 특정 변수의 값을 무작위로 재배열한 데이터로 다시 예측하고, 성능 변화를 측정한다(Kaneko, 2022). 이 과정을 모든 변수에 대해 반복하며, 변수를 섞었을 때 성능 저하가 클수록 모델 예측에 중요한 역할을 하는 것으로 간주한다.

IV. 연구 결과

1. 패널 고정 효과 분석 결과

패널 고정 효과 모형 분석 결과는 <표 2>와 같다. 다양한 요소가 주택용 전력 소비량에 통계적으로 유의한 영향을 미치는 것으로 확인되었다.

기후 요소 중 평균 기온과 평균 상대습도는 모두 주택용 사용량에 유의한 영향을 나타냈다. 평균 기온이 1℃ 상승할 때 전력 사용량은 71.59MWh 감소하였다($TEMP\ coeff. = -71.59, p=0.00$). 높은 기온은 일반적으로 냉방 수요를 증가시키지만, 상대적으로 낮은 기온에서 난방 수요 감소 효과가 더 크게 작용하여 전체 전력 사용량이 줄어드는 결과를 보였다. 평균 상대습도가 1% 증가할 때 전력 사용량은 51.50MWh 늘어났다($HUM\ coeff. = 51.50, p=0.00$). 높은 습도 조건에서는 냉방 수요 증가로 인해 전력 소비가 확대되는 양상을 보였다. 폭염일수와 한파일수 역시 전력 사용량에 유의한 영향을 미쳤다. 폭염일수가 하루 늘어날 때 전력 사용량은 469.21MWh 증가하고($HEAT\ coeff. = 469.21, p=0.00$), 한파일수가 하루 늘어날 때 전력 사용량은 161.75MWh 증가하였다($COLD\ coeff. = 161.75, p=0.00$). 극단적인 기후 조건이 전력 사용량에 큰 영향을 미침을 보여준다.

Table 2. Results of fixed effects panel analysis

Variable	Estimate	Std. Error	t-value	p-value	
Climate	TEMP	-71.59***	3.12	-22.96	0.00
	HUM	51.50***	2.80	18.38	0.00
	HEAT	469.21***	6.77	69.31	0.00
	COLD	161.75***	11.13	14.54	0.00
Socio-economic	WORK	-295.26***	13.41	-22.02	0.00
	COVID	628.91***	49.89	12.61	0.00
	PRICE	-21.47***	1.38	-15.61	0.00
Regional spatial	HOUSEHOLD	0.35***	0.00	197.78	0.00
	URBAN	55.40***	8.99	6.16	0.00

R-squared 0.60

Adj. R-squared 0.59

***p<0.001, **p<0.01, *p<0.05.

사회경제적 요소 또한 전력 사용량에 유의한 영향을 미쳤다. 근무 일수가 하루 늘어날 때 전력 사용량은 295.26MWh 감소하였다($WORK\ coeff. = -295.26, p=0.00$). 이는 근로자들이 근무일에 외부 활동으로 인해 가정에 머무는 시간이 줄어들면서 전력 소비가 감소하는 경향을 반영한다. 코로나19 기간에는 전력 사용량이 628.91MWh 증가하였다($COVID\ coeff. = 628.91, p=0.00$). 팬데믹으로 인한 사회적 제한과 재택근무 확대가 가정 전력 사용량 증가로 이어졌음을 시사한다. 전력 판매단가가 1원 상승할 때 전력 사용량은 21.47MWh 감소하였다($PRICE\ coeff. = -21.47, p=0.00$). 전력 가격 상승이 전력 사용을 억제하는 효과를 가진다는 점을 보여준다.

지역 공간적 요소 역시 주택용 전력 사용량에 유의한 영향을 나타냈다. 가구 수가 한 가구 증가할 때 전력 사용량은 0.35 MWh 증가하였다($HOUSEHOLD\ coeff. = 0.35, p=0.00$). 가구 수 증가로 인해 전력 수요가 누적되며 전체 소비가 늘어나는 경향이 보였다. 도시지역 비율이 1%p 증가할 때 전력 사용량은 55.40MWh 증가하였다($URBAN\ coeff. = 55.40, p=0.00$). 전력 소비가 많은 생활 구조가 일반화된 도시지역에서 상대적으로 높은 소비 양상이 나타났다.

2. SelectKBest 분석 결과

패널 고정 효과 분석을 통해 통계적으로 유의한 변수를 도출한 뒤, SelectKBest 기법을 적용하여 전력 사용량 예측에 중요한 변수를 식별하였다. <그림 4>는 선택된 변수 개수에 따른 MSE의 변화를 보여준다. 변수 개수가 증가함에 따라 MSE가 점차 감소하여 모델 예측 정확도가 향상되는 경향을 확인할 수 있다.

다양한 K 값을 비교한 결과, K가 9일 때 MSE가 242,559로 가장 낮았다. 이를 통해 패널 분석에서 도출된 9개의 변수를 모두 포함하는 것이 모델 성능을 최적화하는 데 가장 효과적임을 확인하였다.

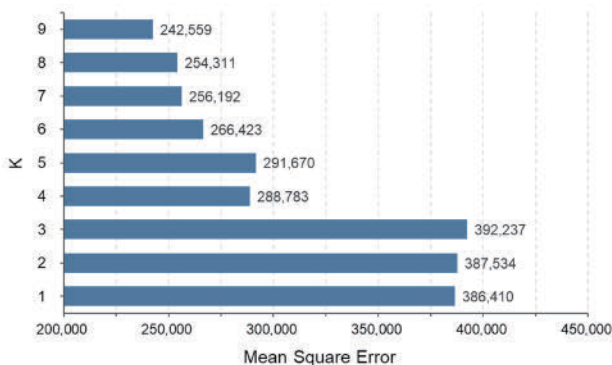


Figure 4. MSE changes with number of features

3. LSTM 기반 예측 및 변수 중요도 분석 결과

1) LSTM 예측 성능 평가

SelectKBest 기법으로 선택된 9개의 변수를 바탕으로 LSTM 모델을 학습하여 주택용 전력 사용량을 예측하였다. <표 3>은 LSTM 모델의 예측 성능 평가 결과를 나타낸다. 훈련 세트에서 LSTM 모델은 MAE 184.97, RMSE 238.51, MAPE 3.35%의 성능을 보이며, 안정적으로 학습되었음을 확인할 수 있었다.

검증 세트의 예측 결과는 실젯값과 높은 일치도를 보였다(그림 5). 검증 세트에서 MAE는 155.95, RMSE는 203.50, MAPE는 2.66%였으며, 대부분의 기간에서 예측값이 실젯값에 근접하였다. 이는 모델이 데이터의 주요 경향성을 잘 포착했음을 보여준다. 다만, 검증 구간 7월에는 예측값이 실젯값보다 높아 과대 예측이 발생하였다. 이는 훈련 구간에서 여름철 수요 급증 패턴을 모델이 강하게 학습한 결과로 해석된다. 그러나 해당 시점의 실제 수요는 이전과 달리 급증하지 않았고, 이로 인해 일반화가 과도하게 작용한 것으로 보인다.

테스트 세트에서도 유사한 패턴이 나타났다(그림 6). 테스트 세트에서 MAE는 263.72, RMSE는 346.76, MAPE는 3.82%로 측

Table 3. LSTM performance metrics by phase

Phase	MAE	RMSE	MAPE
Train	184.97	238.51	3.35
Validation	155.95	203.50	2.66
Test	263.72	346.76	3.82




Figure 5. Validation result: predicted vs. actual consumption




Figure 6. Test result: predicted vs. actual consumption

정되었으며, 모델이 새로운 데이터에서도 안정적인 예측 성능을 유지했음을 확인할 수 있었다. 이러한 결과는 LSTM 모델이 복잡한 시계열 데이터에서도 효과적으로 패턴을 학습하고, 실젯값과 유사한 예측값을 생성할 수 있음을 시사한다. 다만, 일부 시점에서는 예측값과 실젯값 사이에 뚜렷한 괴리가 나타났다. 2020년 9월과 2022년 8월에는 실젯값이 이례적으로 급증하였으나, 모델은 이를 충분히 반영하지 못해 과소 예측이 발생하였다. 2020년 9월의 경우 예측값은 실젯값보다 낮았으며, 이는 훈련 구간에서 9월이 대체로 하락세로 전환되는 시점으로 모델이 학습했기 때문으로 판단된다. 2022년 8월에도 실제 소비가 높은 수준으로 급증하였으나 예측값은 상승 폭을 따라가지 못하였다. 이는 훈련 구간에서 6월부터 점진적인 상승 흐름이 이어지고, 7월과 8월 사이 급격한 소비 증가가 반복적으로 나타난 반면, 2022년에는 6월까지 소비가 정체된 뒤 7월에 단기 급증, 8월에도 이례적 수준이 지속된 점이 영향을 준 것으로 해석된다. 모델은 반복적이고 점진적인 수요 변화에는 민감하지만, 급격하거나 예외적인 변동에는 상대적으로 둔감할 수 있음을 시사한다.

2) 변수 중요도 분석

〈그림 7〉은 PFI 분석 결과를 박스 플롯으로 나타낸 것이다. 분석 결과, 폭염일수, 평균 기온 그리고 평균 상대습도가 높은 중요도를 보였으며, 이는 극단적인 기후 조건이 전력 수요 예측 모델의 성능에 중요한 기후적 요소임을 보여준다. 각각의 중요도 값은 폭염일수가 486,622.49, 평균 기온이 180,786.67, 평균 상대습도가 151,857.21로 나타났다. 한파일수는 60,533.70으로, 다른 기후 요소에 비해 상대적으로 낮은 중요도를 보였다. 이는 한파일수가 다른 기후 변수보다 모델 성능에 덜 기여했음을 의미한다.

반면, 사회경제 및 지역 공간 변수인 전력 판매단가, 근무 일수, 코로나19, 가구 수, 도시지역 비율은 기후 변수보다 상대적으로 낮은 중요도를 보였다. 이들의 중요도 값은 전력 판매단가 37,653.33, 근무 일수 16,563.37, 코로나19 1,631.53, 가구 수 28,578.30, 도시지역 비율 1,024.08로 나타났다.

이러한 결과는 사회경제 및 지역 공간적 요소들이 예측 모델의 성능 향상에 기여하는 정도가 상대적으로 낮았음을 시사한다. 전

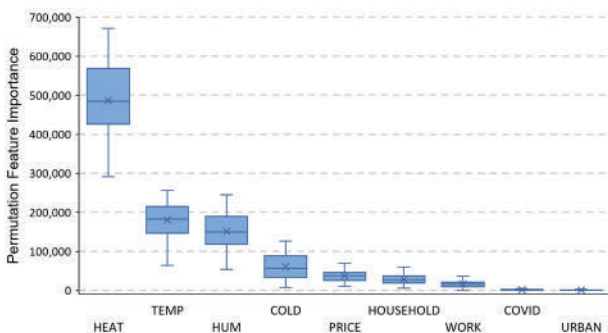


Figure 7. Permutation feature importance (LSTM)

력 판매단가는 정부 정책이나 요금 체계에 따라 일정 기간 유지되거나 변동 폭이 제한된 채 분기 단위로 조정되는 경우가 많아, 모델이 유의미한 입력 변수로 활용하기에는 구조적인 제약이 있었던 것으로 해석된다. 근무 일수는 규칙적인 달력 기반 구조를 따르는 변수로, 주간 수요 변동에 일정한 영향을 줄 수는 있으나 기후 요소에 비해 변화 폭이 작고 반복적 특성을 지니므로 주요 예측 신호로 활용되기에는 한계가 있었던 것으로 보인다. 코로나19는 예외적 사건 기반 변수로, 특정 시점에서는 수요 변화에 영향을 미쳤으나 해당 기간 외에는 영향이 없거나 미미하여 모델이 유의미한 패턴으로 학습하기에는 제한적이었던 것으로 추정된다. 한편, 도시지역 비율과 가구 수는 행정구역 단위의 비교적 고정적인 지표로, 변화 폭이 작고 뚜렷한 계절성이나 주기성을 보이지 않아 시계열 입력 변수로 활용하기에는 한계가 있었던 것으로 판단된다.

V. 결론

본 연구는 대한민국 주택용 전력 사용량의 예측을 목적으로 한다. 이를 위해 기후, 사회경제적, 지역 공간적 요소를 종합적으로 분석하고, 패널 분석을 통해 주택용 전력 소비에 영향을 미치는 변수를 도출하였다. 이어서 SelectKBest 기법을 적용하여 예측 모델 향상에 기여하는 변수 조합을 선정하고, 이를 바탕으로 LSTM 모델을 구축하여 미래 전력 사용량을 예측하였다. 마지막으로 PFI 기법을 활용하여 변수 중요도를 정량적으로 평가함으로써, 예측 모델 성능에 큰 영향을 미치는 주요 요소를 확인하였다.

패널 분석 결과, 기후, 사회경제적, 지역 공간적 요소에 속하는 다양한 변수가 주택용 전력 사용량을 설명하는 것으로 나타났다. 평균 기온 상승은 겨울철 난방 수요 감소와 관련이 있으며(Pilli-Sihvola et al., 2010), 이는 기온 상승으로 인한 냉방 수요 증가보다 난방 감소 효과가 더 크게 작용하기 때문이다. 평균 상대습도가 높아지면 체감 온도가 상승하여 냉방 에너지 소비가 증가하고 (Rastogi et al., 2021), 폭염일수와 한파일수가 늘어날수록 냉방 및 냉각 장치와 난방 기기의 사용이 모두 증가하여 전력 소비가 급증한다(Zuo et al., 2015; Kim et al., 2022; Añel et al., 2017). 이러한 날씨 조건에서는 사람들이 집에 머무는 시간이 길어지고, 다양한 전기 기기의 사용이 늘어나면서 전력 소비가 추가로 증가한다(Guo et al., 2018).

사회경제적 요소 중 근무 일수는 전력 사용량을 줄이는 요인으로 작용하였다. 근무 일수가 많을수록 가정에서의 전력 사용은 감소한다(Lórinçz et al., 2021). 한편, 코로나19 기간에는 재택근무와 가정 활동 증가로 인해 주택 전력 사용량은 크게 증가하였다(Krarti and Aldubyan, 2021). 또한, 전력 판매단가가 상승하면 소비자는 전기요금에 부담을 느끼고 에너지 절약형 가전제품을 도입하거나 불필요한 전력 사용을 줄이는 등의 조치를 통해 전

력 소비를 절감하려는 경향을 보인다(Kwon et al., 2016; Sudarshan, 2017).

지역 공간적 요소에서는 가구 수와 도시지역 비율이 모두 주택용 전력 사용량 증가와 밀접한 관련을 보였다. 가구 수가 증가하면 전력 사용이 개별 가구 단위로 분산되며, 이로 인해 전체 주택용 전력 수요가 증가하는 경향을 보인다(Park and Yun, 2022; Zeng et al., 2021). 도시지역 비율이 높은 지역은 고밀도 주거 환경에서 냉난방기기와 전자기기 사용이 활발하여 전력 소비 수준이 상대적으로 높게 나타난다(Li et al., 2018). 이러한 결과는 기후변화, 사회경제적 변동, 지역 특성이 주택용 전력 소비 패턴에 중요한 영향을 미친다는 점을 보여주며, 이를 반영한 맞춤형 전력 수요 관리 정책의 필요성을 시사한다.

SelectKBest 알고리즘을 적용하여 패널 분석에서 도출된 변수 중 최적의 조합을 선정하였다. 변수 개수가 증가할수록 MSE가 감소하여 모델의 예측 정확도가 향상되는 경향을 보였다. 특히 도출된 9개의 변수를 모두 활용하였을 때 MSE가 가장 낮게 나타났으며, 이는 각 변수가 전력 수요 예측에 필수적인 정보를 제공하고 LSTM 모델의 예측 성능 향상에 기여함을 확인할 수 있다.

선정된 변수 조합을 바탕으로 구축한 LSTM 모델은 훈련 세트에서 낮은 오차율을 기록하였으며, 검증 및 테스트 세트에서도 안정적인 예측 성능을 유지하였다. 테스트 세트에서 오차가 다소 증가하였으나 모델은 새로운 데이터에서도 일정 수준의 일반화 능력을 유지하여 MAE, RMSE, MAPE 모두 낮은 값을 기록하였다. 이는 LSTM 모델이 데이터의 복잡한 패턴을 효과적으로 학습하여 전력 수요 예측 정확도를 높일 수 있음을 보여준다.

LSTM을 활용한 PFI 분석 결과, 기후 요소가 사회경제적 및 지역 공간적 요소보다 전력 수요 예측에 더 중요한 영향을 미치는 것으로 확인되었다. 특히 평균 기온, 폭염일수, 평균 상대습도는 높은 중요도를 보였으며, 이는 이러한 기후 조건들이 전력 수요에 직접적으로 큰 영향을 미치기 때문이다(Pilli-Sihvola et al., 2010). 반면, 한파일수는 다른 기후 변수에 비해 중요도가 낮게 나타나 비교적 영향력이 제한적이었다. 사회경제적 및 지역 공간적 요소 중 전력 판매단가, 가구 수, 근무 일수는 상대적으로 높은 중요도를 보였다. 전력 판매단가는 에너지 가격 수준 및 경제적 부담을 반영하고, 가구 수는 지역의 전력 수요 규모를 나타내며, 근무 일수는 사람들의 생활 방식과 밀접히 연관되어 전력 소비에 영향을 미칠 수 있음을 시사한다(Lőrincz et al., 2021). 반면, 코로나19와 도시지역 비율은 상대적으로 중요도가 낮게 평가되었다. 코로나19의 영향은 특정 시기에 국한되어 나타나며, 도시지역 비율은 분석 기간 동안 변동 폭이 작아 예측 변수로서의 설명력이 제한적일 가능성이 있다.

이러한 분석 결과는 전력 수요 예측 모델 개발 시 기후 요소에 보다 큰 비중을 두어야 함을 보여준다. 특히 평균 기온, 폭염일수, 평균 상대습도 등 직접적 영향을 미치는 기후 변수를 중심으

로 모델을 최적화하면 예측 정확도를 높일 수 있다. 동시에 사회경제적 및 지역 공간적 변수들도 전력 수요에 영향을 미치므로 보완적으로 고려해야 하며, 이를 통해 모델의 예측력을 강화할 수 있다. 이는 복합적 요인들이 상호작용하는 실제 상황에서 전력 수요를 더욱 정밀하게 예측하기 위해 다양한 변수를 통합적으로 반영해야 함을 의미한다.

본 연구의 결과는 에너지 정책 결정자와 관리자에게 보다 효과적인 수요 관리 및 계획 수립에 필요한 기초자료로 제공된다는 점에서 의의가 있다. 기후변화뿐만 아니라 사회경제적 및 지역 공간적 요소가 주택용 전력 사용량에 미치는 영향을 실증적으로 확인함으로써, 지역 맞춤형 에너지 관리 방안을 설계하는 데 기여할 수 있다. 평균 기온, 폭염일수 등 기후 변수는 전력 사용량에 직접적인 영향을 미치므로, 기후변화에 대응한 정책적 수요 관리와 계절별 냉난방 수요 변화에 유연하게 대응할 수 있는 관리 체계의 구축이 요구된다. 또한 사회경제적, 지역 공간적 요소의 영향 역시 무시할 수 없으므로, 지역의 공간 구조와 사회·경제적 맥락을 반영한 수요 예측 및 대응 방안이 마련되어야 한다. 예를 들어, 고밀도 도시지역은 에너지 소비가 높은 생활양식이 일반화되어 있으므로, 도시계획 단계에서 에너지 효율을 고려한 건물 배치와 인프라 설계, 스마트 그리드 기반 수요 분산 정책 등을 연계하는 접근이 요구된다. 더불어 전력 판매단가, 근무 일수 등 사회경제적 요소에 따른 수요 변동도 고려되어야 하며, 이는 경제 여건 변화에 대응한 인센티브 제공이나 공급 조정 전략으로 연결될 수 있다. 이러한 결과는 향후 국토 및 도시계획 차원의 에너지 수요 관리 정책에서 다층적 요인을 통합적으로 고려해야 함을 시사한다.

한편, 본 연구는 몇 가지 한계를 지니고 있으며, 이를 바탕으로 다음과 같은 향후 연구 방향을 제시한다. LSTM 모델은 반복적이고 점진적인 수요 변화에는 민감하게 반응하였으나, 예외적인 급등과 급감과 같은 비정형적 상황에서는 예측력이 다소 낮았다. 이는 훈련 데이터에 존재하지 않았던 특이 패턴에 대한 일반화의 한계로 해석될 수 있으며, 향후 연구에서는 다양한 예외 패턴에 유연하게 대응할 수 있는 하이브리드 모델이나 앙상블 기법의 도입이 필요하다. 또한 본 연구는 주택용 전력 사용량에 초점을 맞추었으나, 향후에는 상업 및 산업 부문과의 비교 분석을 통해 보다 거시적이고 종합적인 에너지 소비 구조를 파악할 필요가 있다. 이러한 확장은 부문 간 상이한 소비 특성과 기후, 사회경제적, 지역 공간적 요소에 대한 반응 차이를 규명하는 데 기여할 것이며, 다양한 변수 조합과 예측 기법의 적용, 분석 범위의 확대를 통해 전력 수요 예측의 정확성과 정책적 활용 가능성을 높일 것으로 기대된다.

인용문헌
References

1. Aki, H., Iitaka, H., Tamura, I., Kegasa, A., Hayakawa, H., Ishikawa, Y., Yamamoto, S., and Sugimoto, I., 2018. "Analysis of Measured Data on Energy Demand and Activity Patterns in Residential Dwellings in Japan", *IEEE Transactions on Electrical and Electronic Engineering*, 13(1): 157-167.
2. Alahmer, A., and Ajib, S., 2020. "Solar Cooling Technologies: State of Art and Perspectives", *Energy Conversion and Management*, 214: 112896.
3. Ali, S.S.S., Razman, M.R., Awang, A., Asyraf, M.R.M., Ishak, M.R., Ilyas, R.A., and Lawrence, R.J., 2021. "Critical Determinants of Household Electricity Consumption in a Rapidly Growing City", *Sustainability*, 13(8): 4441.
4. Allcott, H., and Mullainathan, S., 2010. "Behavior and Energy Policy", *Science*, 327: 1204-1205.
5. Al-Saba, T. and El-Amin, I., 1999. "Artificial Neural Networks as Applied to Long-term Demand Forecasting", *Artificial Intelligence in Engineering*, 13(2): 189-197.
6. Al-Selwi, S.M., Hassan, M.F., Abdulkadir, S.J., Muneer, A., Sumiea, H., Alqushaibi, A., and Ragab, M.G., 2024. "RNN-LSTM: From Applications to Modeling Techniques and beyond—Systematic Review", *Journal of King Saud University-Computer and Information Sciences*, 36(5): 102068.
7. Amber, K.P., Ahmad, R., Aslam, M.W., Kousar, A., Usman, M., and Khan, M.S., 2018. "Intelligent Techniques for Forecasting Electricity Consumption of Buildings", *Energy*, 157: 886-893.
8. Andersen, F.M., Gunkel, P.A., Jacobsen, H.K., and Kitzing, L., 2021. "Residential Electricity Consumption and Household Characteristics: An Econometric Analysis of Danish Smart-meter Data", *Energy Economics*, 100: 105341.
9. Añel, J.A., Fernández-González, M., Labandeira, X., López-Otero, X., and De la Torre, L., 2017. "Impact of Cold Waves and Heat Waves on the Energy Production Sector", *Atmosphere*, 8(11): 209
10. Bakirtas, T. and Akpolat, A.G., 2018. "The Relationship between Energy Consumption, Urbanization, and Economic Growth in New Emerging-market Countries", *Energy*, 147: 110-121.
11. Barkhordar, Z.A., Habibzadeh, S., and Alizadeh, N., 2022. "Deriving Electricity Consumption Patterns Using a Decomposition Approach", *Results in Engineering*, 16: 100628.
12. Bommert, A., Sun, X., Bischl, B., Rahnenführer, J., and Lang, M., 2020. "Benchmark for Filter Methods for Feature Selection in High-dimensional Classification Data", *Computational Statistics & Data Analysis*, 143: 106839.
13. Cetin, K.S., Tabares-Velasco, P.C., and Novoselac, A., 2014. "Appliance Daily Energy Use in New Residential Buildings: Use Profiles and Variation in Time-of-use", *Energy and Buildings*, 84: 716-726.
14. Chae, Y.T., Horesh, R., Hwang, Y., and Lee, Y.M., 2016. "Artificial Neural Network Model for Forecasting Sub-hourly Electricity Usage in Commercial Buildings", *Energy and Buildings*, 111: 184-194.
15. Chang, P.C., Fan, C.Y., and Lin, J.J., 2011. "Monthly Electricity Demand Forecasting Based on a Weighted Evolving Fuzzy Neural Network Approach", *International Journal of Electrical Power & Energy Systems*, 33(1): 17-27.
16. Chapagain, K., Kittipiyakul, S., and Kulthanavit, P., 2020. "Short-Term Electricity Demand Forecasting: Impact Analysis of Temperature for Thailand", *Energies*, 13(10): 2498
17. Chen, Y.J., Matsuoka, R.H., and Liang, T.M., 2018. "Urban Form, Building Characteristics, and Residential Electricity Consumption: A Case Study in Tainan City", *Environment and Planning B: Urban Analytics and City Science*, 45(5): 933-952.
18. Chu, J., Liu, X., Zhang, Z., Zhang, Y., and He, M., 2021. "A Novel Method Overcoming Overfitting of Artificial Neural Network for Accurate Prediction: Application on Thermophysical Property of Natural Gas", *Case Studies in Thermal Engineering*, 28: 101406.
19. Cui, P., Xia, S., and Hao, L., 2019. "Do Different Sizes of Urban Population Matter Differently to CO2 Emission in Different Regions? Evidence from Electricity Consumption Behavior of Urban Residents in China", *Journal of Cleaner Production*, 240: 118207.
20. Daut, I., Zainuddin, F., Irwan, Y.M., and Razliana, A.R.N., 2012. "Analysis of Solar Irradiance and Solar Energy in Perlis, Northern of Peninsular Malaysia", *Energy Procedia*, 18: 1421-1427.
21. De Nooij, M., Lieshout, R., and Koopmans, C., 2009. "Optimal Blackouts: Empirical Results on Reducing the Social Cost of Electricity Outages through Efficient Regional Rationing", *Energy Economics*, 31(3): 342-347.
22. Desyani, T., Saifudin, A., and Yulianti, Y., 2020. "Feature Selection Based on Naive Bayes for Caesarean Section Prediction", *IOP Conference Series: Materials Science and Engineering*, 879(1): 012091.
23. Divina, F., García Torres, M., Gómez Vela, F.A., and Vázquez Noguera, J.L., 2019. "A Comparative Study of Time Series Forecasting Methods for Short Term Electric Energy Consumption Prediction in Smart Buildings", *Energies*, 12(10): 1934.
24. Faisal, F., Tursoy, T., Günsel Resatoglu, N., and Berk, N., 2018. "Electricity Consumption, Economic Growth, Urbanisation and Trade Nexus: Empirical Evidence from Iceland", *Economic Research-Ekonomiska Istraživanja*, 31(1): 664-680.
25. Georgopoulou, E., Mirasgedis, S., Sarafidis, Y., Giannakopoulos, C., Varotsos, K.V., and Gakis, N., 2024. "Climate Change Impacts on the Energy System of a Climate-Vulnerable Mediterranean Country (Greece)", *Atmosphere*, 15(3): 286.
26. Ghalekhondabi, I., Ardjmand, E., Weckman, G.R., and Young, W.A., 2017. "An Overview of Energy Demand Forecasting Methods Published in 2005-2015", *Energy Systems*, 8(2): 411-447.

27. Goodrich, J.N., 2005. "The Big American Blackout of 2003: A Record of the Events and Impacts on USA Travel and Tourism", *Journal of Travel & Tourism Marketing*, 18(2): 31-37.
28. Grigoryan, H., 2021. "Electricity Consumption Prediction using Energy Data, Socio-economic and Weather Indicators. A Case Study of Spain", Paper presented at the 2021 9th International Conference on Control, Mechatronics and Automation (ICCMA), 158-164, Belval, Luxembourg.
29. Guo, Z., Zhou, K., Zhang, X., Yang, S., and Shao, Z., 2018. "Data Mining Based Framework for Exploring Household Electricity Consumption Patterns: A Case Study in China Context", *Journal of Cleaner Production*, 195: 773-785.
30. Haes Alhelou, H., Hamedani-Golshan, M.E., Njenda, T.C., and Siano, P., 2019. "A Survey on Power System Blackout and Cascading Events: Research Motivations and Challenges", *Energies*, 12(4): 682.
31. Hill, T.D., Davis, A.P., Roos, J.M., and French, M.T., 2020. "Limitations of Fixed-Effects Models for Panel Data", *Sociological Perspectives*, 63(3): 357-369.
32. Hochreiter, S. and Schmidhuber, J., 1997. "Long Short-Term Memory", *Neural Computation*, 9(8): 1735-1780.
33. Hodson, T.O., 2022. "Root-mean-square Error (RMSE) or Mean Absolute Error (MAE): When to Use Them or Not", *Geoscientific Model Development*, 15(14): 5481-5487.
34. Hong, W.C., 2009. "Electric Load Forecasting by Support Vector Model", *Applied Mathematical Modelling*, 33(5): 2444-2454.
35. Hua, W., Wang, L., Fang, X., and Luo, L., 2023. "Urbanization and Energy Equity: An Urban-rural Gap Perspective", *Environmental Science and Pollution Research*, 30(16): 46847-46868.
36. Huang, W.H., 2015. "The Determinants of Household Electricity Consumption in Taiwan: Evidence from Quantile Regression", *Energy*, 87: 120-133.
37. Hwang, B., Sou, H.D., Oh, J.H., and Park, C.R., 2023. "Cooling Effect of Urban Forests on the Urban Heat Island in Seoul, South Korea", *PLOS ONE*, 18(7): e0288774.
38. Jang, H., Moon, S., and Kim, J., 2024. "Effects of Time-of-use Pricing for Residential Customers and Wholesale Market Consequences in South Korea", *Energy Economics*, 134: 107557.
39. Jovanović, S., Savić, S., Bojić, M., Djordjević, Z., and Nikolić, D., 2015. "The Impact of the Mean Daily Air Temperature Change on Electricity Consumption", *Energy*, 88: 604-609.
40. Kaneko, H., 2022. "Cross-validated Permutation Feature Importance Considering Correlation between Features", *Analytical Science Advances*, 3(9-10): 278-287.
41. Karim, F., Majumdar, S., Darabi, H., and Chen, S., 2018. "LSTM Fully Convolutional Networks for Time Series Classification", *IEEE Access*, 6: 1662-1669.
42. Kaur, R.R. and Luthra, A., 2018. "Population Growth, Urbanization and Electricity—Challenges and Initiatives in the State of Punjab, India", *Energy Strategy Reviews*, 21: 50-61.
43. Kaytez, F., Taplamacioglu, M.C., Cam, E., and Hardalac, F., 2015. "Forecasting Electricity Consumption: A Comparison of Regression Analysis, Neural Networks and Least Squares Support Vector Machines", *International Journal of Electrical Power & Energy Systems*, 67: 431-438.
44. Khosa, I., Taimoor, N., Akhtar, J., Ali, K., Rehman, A.U., Bajaj, M., Elgbaily, M., Shouran, M., and Kamel, S., 2022. "Financial Hazard Assessment for Electricity Suppliers Due to Power Outages: The Revenue Loss Perspective", *Energies*, 15(12): 4327.
45. Ki, J. and Yoon, D.K., 2024. "The Impact of Urban Form on Residential Electricity Consumption: Panel Data Analyses of South Korean Urban Municipalities", *Energy Policy*, 186: 113986.
46. Kim, M.J., 2014. "A Study of Restructured Residential Electricity Pricing toward the Competitive Power Market", *The Transactions of The Korean Institute of Electrical Engineers*, 63(7): 889-895.
47. Kim, M.J., 2020. "Determining the Relationship between Residential Electricity Consumption and Factors: Case of Seoul", *Sustainability*, 12(20): 8590.
48. Kim, Y., Choi, Y., and Min, S.K., 2022. "Future Changes in Heat Wave Characteristics and Their Impacts on the Electricity Demand in South Korea", *Weather and Climate Extremes*, 37: 100485.
49. Kipping, A. and Trømborg, E., 2015. "Hourly Electricity Consumption in Norwegian Households - Assessing the Impacts of Different Heating Systems", *Energy*, 93: 655-671.
50. Krarti, M. and Aldubyan, M., 2021. "Review Analysis of COVID-19 Impact on Electricity Demand for Residential Buildings", *Renewable and Sustainable Energy Reviews*, 143: 110888.
51. Kumar Dubey, A., Kumar, A., García-Díaz, V., Kumar Sharma, A., and Kanhaiya, K., 2021. "Study and Analysis of SARIMA and LSTM in Forecasting Time Series Data", *Sustainable Energy Technologies and Assessments*, 47: 101474.
52. Kwon, S., Cho, S.H., Roberts, R.K., Kim, H.J., Park, K., and Edward Yu, T.H., 2016. "Short-run and the Long-run Effects of Electricity Price on Electricity Intensity Across Regions", *Applied Energy*, 172: 372-382.
53. Li, C., Song, Y., and Kaza, N., 2018. "Urban Form and Household Electricity Consumption: A Multilevel Study", *Energy and Buildings*, 158: 181-193.
54. Li, K., Cursio, J.D., Jiang, M., and Liang, X., 2019. "The Significance of Calendar Effects in the Electricity Market", *Applied Energy*, 235: 487-494.
55. Li, Q., Yang, L., Huang, S., Liu, Y., and Guo, C., 2023. "The Effects of Urban Sprawl on Electricity Consumption: Empirical Evidence from 283 Prefecture-Level Cities in China", *Land*, 12(8): 1609.
56. Li, X., Wang, Z., Yang, C., and Bozkurt, A., 2024. "An Advanced Framework for Net Electricity Consumption Prediction: Incorporating Novel Machine Learning Models and Optimization Algorithms", *Energy*, 296: 131259.
57. Liu, S., Zeng, A., Lau, K., Ren, C., Chan, P., and Ng, E., 2021.

- “Predicting Long-term Monthly Electricity Demand Under Future Climatic and Socioeconomic Changes Using Data-Driven Methods: A Case Study of Hong Kong”, *Sustainable Cities and Society*, 70: 102936.
58. Liu, X.Q., Zhang, C., Zhou, Y., and Liao, H., 2021. “Temperature Change and Electricity Consumption of the Group Living: A Case Study of College Students”, *Science of The Total Environment*, 781: 146574.
 59. Lőrincz, M.J., Ramírez-Mendiola, J.L., and Torriti, J., 2021. “Impact of Time-Use Behaviour on Residential Energy Consumption in the United Kingdom”, *Energies*, 14(19): 6286.
 60. Madlener, R. and Sunak, Y., 2011. “Impacts of Urbanization on Urban Structures and Energy Demand: What Can We Learn for Urban Energy Planning and Urbanization Management?”, *Sustainable Cities and Society*, 1(1): 45-53.
 61. Mahmood, H., Wen, J., Zakaria, M., and Khalid, S., 2022. “Linking Electricity Demand and Economic Growth in China: Evidence from Wavelet Analysis”, *Environmental Science and Pollution Research*, 29(26): 39473-39485.
 62. Maia-Silva, D., Kumar, R., and Nateghi, R., 2020. “The Critical Role of Humidity in Modeling Summer Electricity Demand across the United States”, *Nature Communications*, 11(1): 1686.
 63. Mamun, A.A., Sohel, M.D., Mohammad, N., Haque Sunny, S., Dipta, D.R., and Hossain, E., 2020. “A Comprehensive Review of the Load Forecasting Techniques Using Single and Hybrid Predictive Models”, *IEEE Access*, 8: 134911-134939.
 64. Manowska, A., 2020. “Using the LSTM Network to Forecast the Demand for Electricity in Poland”, *Applied Sciences*, 10(23): 8455.
 65. Mideksa, T.K. and Kallbekken, S., 2010. “The Impact of Climate Change on the Electricity Market: A Review”, *Energy Policy*, 38(7): 3579-3585.
 66. Molnar, C., Freiesleben, T., König, G., Herbringer, J., Reisinger, T., Casalicchio, G., Wright, M.N., and Bischl, B., 2023. “Relating the Partial Dependence Plot and Permutation Feature Importance to the Data Generating Process”, In *Explainable Artificial Intelligence*, edited by Longo, L., 456-479, Springer Nature Switzerland.
 67. Montesinos López, O.A., Montesinos López, A., and Crossa, J., 2022. “Fundamentals of Artificial Neural Networks and Deep Learning”, In *Multivariate Statistical Machine Learning Methods for Genomic Prediction*, edited by Montesinos López, O.A., Montesinos López, A., and Crossa, J., 379-425, Springer International Publishing.
 68. Morley, S.K., Brito, T.V., and Welling, D.T., 2018. “Measures of Model Performance Based on the Log Accuracy Ratio”, *Space Weather*, 16(1): 69-88.
 69. Muzaffar, S. and Afshari, A., 2019. “Short-Term Load Forecasts Using LSTM Networks”, *Energy Procedia*, 158: 2922-2927.
 70. Muzayanah, I.F.U., Lean, H.H., Hartono, D., Indraswari, K.D., and Partama, R., 2022. “Population Density and Energy Consumption: A Study in Indonesian Provinces”, *Heliyon*, 8(9): e10634.
 71. OECD, 2022. *OECD Economic Surveys: Korea 2022*, OECD.
 72. Oluleye, B.I., Chan, D.W.M., and Antwi-Afari, P., 2023. “Adopting Artificial Intelligence for Enhancing the Implementation of Systemic Circularity in the Construction Industry: A Critical Review”, *Sustainable Production and Consumption*, 35: 509-524.
 73. Otchere, D.A., Ganat, T.O.A., Ojero, J.O., Tackie-Otoo, B.N., and Taki, M.Y., 2022. “Application of Gradient Boosting Regression Model for the Evaluation of Feature Selection Techniques in Improving Reservoir Characterisation Predictions”, *Journal of Petroleum Science and Engineering*, 208: 109244.
 74. Pallonetto, F., Jin, C., and Mangina, E., 2022. “Forecast Electricity Demand in Commercial Building with Machine Learning Models to Enable Demand Response Programs”, *Energy and AI*, 7: 100121.
 75. Panapongpakorn, T. and Banjerdpongchai, D., 2019. “Short-Term Load Forecast for Energy Management Systems Using Time Series Analysis and Neural Network Method with Average True Range”, Paper presented at the 2019 First International Symposium on Instrumentation, Control, Artificial Intelligence, and Robotics (ICA-SYMP), 86-89, Bangkok, Thailand.
 76. Park, C.M., 2009. “The Quality of Life in South Korea”, *Social Indicators Research*, 92(2): 263-294.
 77. Park, J.K., Das, A., and Park, J.H., 2015. “A New Approach to Estimate the Spatial Distribution of Solar Radiation Using Topographic Factor and Sunshine Duration in South Korea”, *Energy Conversion and Management*, 101: 30-39.
 78. Park, J. and Yun, S.J., 2022. “Social Determinants of Residential Electricity Consumption in Korea: Findings from a Spatial Panel Mode”, *Energy*, 239: 122272.
 79. Pilli-Sihvola, K., Aatola, P., Ollikainen, M., and Tuomenvirta, H., 2010. “Climate Change and Electricity Consumption—Witnessing Increasing or Decreasing Use and Costs?”, *Energy Policy*, 38(5): 2409-2419.
 80. Qin, P., Xu, H., Liu, M., Xiao, C., Forrest, K.E., Samuelsen, S., and Tarroja, B., 2020. “Assessing Concurrent Effects of Climate Change on Hydropower Supply, Electricity Demand, and Greenhouse Gas Emissions in the Upper Yangtze River Basin of China”, *Applied Energy*, 279: 115694.
 81. Quan, S.J. and Li, C., 2021. “Urban Form and Building Energy Use: A Systematic Review of Measures, Mechanisms, and Methodologies”, *Renewable and Sustainable Energy Reviews*, 139: 110662.
 82. Rajagukguk, R.A., Ramadhan, R.A.A., and Lee, H.J., 2020. “A Review on Deep Learning Models for Forecasting Time Series Data of Solar Irradiance and Photovoltaic Power”, *Energies*, 13(24): 6623
 83. Rastogi, D., Lehner, F., Kuruganti, T., Evans, K.J., Kurte, K., and Sanyal, J., 2021. “The Role of Humidity in Determining Future Electricity Demand in the Southeastern United States”, *Environmental Research Letters*, 16(11): 114017.

84. Raza, M.Q. and Khosravi, A., 2015. "A Review on Artificial Intelligence Based Load Demand Forecasting Techniques for Smart Grid and Buildings", *Renewable and Sustainable Energy Reviews*, 50: 1352-1372.
85. Roman, I., Santana, R., Mendiburu, A., and Lozano, J.A., 2021. "In-depth Analysis of SVM Kernel Learning and Its Components", *Neural Computing and Applications*, 33(12): 6575-6594.
86. Romero-Jordán, D., del Río, P., and Peñasco, C., 2016. "An Analysis of the Welfare and Distributive Implications of Factors Influencing Household Electricity Consumption", *Energy Policy*, 88: 361-370.
87. Salman, S. and Liu, X., 2019. "Overfitting Mechanism and Avoidance in Deep Neural Networks", arXiv:1901.06566.
88. Savić, S., Selakov, A., and Milošević, D., 2014. "Cold and Warm Air Temperature Spells during the Winter and Summer Seasons and their Impact on Energy Consumption in Urban Areas", *Natural Hazards*, 73(2): 373-387.
89. Senan, E.M., Abunadi, I., Jadhav, M.E., and Fati, S.M., 2021. "Score and Correlation Coefficient-Based Feature Selection for Predicting Heart Failure Diagnosis by Using Machine Learning Algorithms", *Computational and Mathematical Methods in Medicine*, 2021(1): 8500314.
90. Shabur, A. and Ali, F., 2024. "An Analysis of the Correlation between Income and the Consumption of Energy in Bangladesh", *Energy Informatics*, 7(1): 17.
91. Shi, K., Yang, Q., Fang, G., Yu, B., Chen, Z., Yang, C., and Wu, J., 2019. "Evaluating Spatiotemporal Patterns of Urban Electricity Consumption within Different Spatial Boundaries: A Case Study of Chongqing, China", *Energy*, 167: 641-653.
92. Son, H. and Kim, C., 2020. "A Deep Learning Approach to Forecasting Monthly Demand for Residential-Sector Electricity", *Sustainability*, 12(8): 3103.
93. Soori, M., Arezoo, B., and Dastres, R., 2023. "Artificial Neural Networks in Supply Chain Management, A Review", *Journal of Economy and Technology*, 1: 179-196.
94. Sudarshan, A., 2017. "Nudges in the Marketplace: The Response of Household Electricity Consumption to Information and Monetary Incentives", *Journal of Economic Behavior & Organization*, 134: 320-335.
95. Thapa, K.N.K. and Duraipandian, N., 2021. "Malicious Traffic classification Using Long Short-Term Memory (LSTM) Mode", *Wireless Personal Communications*, 119(3): 2707-2724.
96. Torres, J.F., Martínez-Álvarez, F., and Troncoso, A., 2022. "A Deep LSTM Network for the Spanish Electricity Consumption Forecasting", *Neural Computing and Applications*, 34(13): 10533-10545.
97. Ubal, C., Di-Giorgi, G., Contreras-Reyes, J.E., and Salas, R., 2023. "Predicting the Long-Term Dependencies in Time Series Using Recurrent Artificial Neural Networks", *Machine Learning and Knowledge Extraction*, 5(4): 1340-1358.
98. Vlachokostas, A. and Madamopoulos, N., 2016. "Quantification of Energy Savings from Dynamic Solar Radiation Regulation Strategies in Office Buildings", *Energy and Buildings*, 122: 140-149.
99. Wang, B., Yuan, Z., Liu, X., Sun, Y., Zhang, B., and Wang, Z., 2021. "Electricity Price and Habits: Which Would Affect Household Electricity Consumption?", *Energy and Buildings*, 240: 110888.
100. Wang, J.Q., Du, Y., and Wang, J., 2020. "LSTM Based Long-term Energy Consumption Prediction with Periodicity", *Energy*, 197: 117197.
101. Wang, X., Fang, F., Zhang, X., Liu, Y., Wei, L., and Shi, Y., 2019. "LSTM-based Short-term Load Forecasting for Building Electricity Consumption", Paper presented at the 2019 IEEE 28th International Symposium on Industrial Electronics (ISIE), 1418-1423, Vancouver, BC, Canada.
102. Wang, Z., Yang, Z., Zhang, B., Li, H., and He, W., 2022. "How Does Urbanization Affect Energy Consumption for Central Heating: Historical Analysis and Future Prospects", *Energy and Buildings*, 255: 111631.
103. Waseem, M., Lin, Z., Liu, S., Jinai, Z., Rizwan, M., and Sajjad, I.A., 2021. "Optimal BRA Based Electric Demand Prediction Strategy Considering Instance-based Learning of the Forecast Factors", *International Transactions on Electrical Energy Systems*, 31(9): e12967.
104. Wu, D., Zheng, X., Xu, Y., Olsen, D., Xia, B., Singh, C., and Xie, L., 2021. "An Open-source Extendable Model and Corrective Measure Assessment of the 2021 Texas Power Outage", *Advances in Applied Energy*, 4: 100056.
105. Xie, L., Yan, H., Zhang, S., and Wei, C., 2020. "Does Urbanization Increase Residential Energy Use? Evidence from the Chinese residential Energy Consumption Survey 2012", *China Economic Review*, 59: 101374.
106. Xiong, D., Yan, Y., Qin, M., Wu, S., and Liu, R., 2024. "Quantitative Assessment of the Impact of Extreme Events on Electricity Consumption", *Energies*, 17(1): 45.
107. Yoo, S.H. and Lee, J.S., 2010. "Electricity Consumption and Economic Growth: A Cross-country Analysis", *Energy Policy*, 38(1): 622-625.
108. Zeng, Y., Yang, H., Wang, Z., and Li, L., 2021. "Impacts of Family Household Dynamics on Residential Energy Demands in Hebei Province of China", *Genus*, 77(1): 35.
109. Zhang, H., Chen, B., Li, Y., Geng, J., Li, C., Zhao, W., and Yan, H., 2022. "Research on Medium- and Long-term Electricity Demand Forecasting under Climate Change", *Energy Reports*, 8: 1585-1600.
110. Zhang, Y., Tiño, P., Leonardi, A., and Tang, K., 2021. "A Survey on Neural Network Interpretability", *IEEE Transactions on Emerging Topics in Computational Intelligence*, 5(5): 726-742.
111. Zuo, J., Pullen, S., Palmer, J., Bennetts, H., Chileshe, N., and Ma, T., 2015. "Impacts of Heat Waves and Corresponding Measures: A Review", *Journal of Cleaner Production*, 92: 1-12.
112. Ember, 2021, March 25. "G20 Profile - South Korea - Global Electricity Review 2021", Policy Commons. <https://policy-commons.net/artifacts/3755638/g20-profile/4561133/>

- 113. Global Electricity Review 2023, 2023. <https://ember-climate.org/latest-insights/global-electricity-review-2023>
- 114. KEPCO. Electricity Meter Reading and Bill Payment Due Date, Accessed July 31, 2024. <https://online.kepco.co.kr/PRM088D00>
- 115. Korea Meteorological Administration. Open MET Data Portal, Accessed July 3, 2024. <https://data.kma.go.kr/cmmn/main.do>

Date Received	2025-01-23
Reviewed(1 st)	2025-04-15
Date Revised	2025-06-06
Reviewed(2 nd)	2025-09-14
Date Accepted	2025-09-14
Final Received	2025-09-25