

Time-Period-Aware Difficulty Assessment and Modeling Framework for Improved Building Energy Consumption Prediction

Yong-Je Ko*, Ho-Young Kwak**

*Director, Energy Center of Jeju TechnoPark, Jeju, Korea

**Professor, Dept, of Computer Engineering, Jeju National University, Jeju, Korea

[Abstract]

Building energy consumption prediction is essential for energy management and optimization, but existing research applies a single model across all time periods, failing to adequately reflect the different consumption patterns and prediction difficulties of each period. This study develops a new metric called the Prediction Difficulty Index to quantify time-period-specific prediction difficulty and empirically demonstrates the necessity and effectiveness of differentiated modeling strategies. Our analysis quantified that the PDI-based prediction difficulty of Transition periods is 4.36 times higher than Off-peak periods(MAPE-based:4.47 times) using the Prediction Difficulty Index, which integrates variability and prediction error. Statistical tests showed highly significant differences between time periods (ANOVA: $F=26.35$, $p<0.000001$; Cohen's $d=1.95$), and SHAP analysis confirmed that different features play important roles in prediction for each time period. We developed period-specific models and evaluated them using Leave-One-Out Cross-Validation (LOOCV), achieving a 30.58% improvement in MAPE compared to the baseline LightGBM model. This demonstrates that even simple models (Linear Regression, Ridge Regression) can outperform complex single models when tailored to time-period characteristics, even with small data (94 samples).

▶ **Key words:** Energy Consumption Prediction, Time-Period Modeling, Prediction Difficulty Index, LightGBM, SHAP Analysis, Differentiated Modeling

[요약]

건물 에너지 소비 예측은 에너지 관리 및 최적화에 필수적이지만, 기존 연구들은 전체 시간대에 단일 모델을 적용하여 시간대별 상이한 소비 패턴과 예측 난이도를 충분히 반영하지 못한다. 본 연구는 시간대별 예측 난이도를 정량화하는 새로운 지표인 Prediction Difficulty Index(PDI)를 개발하고, 차별화된 모델링 전략의 필요성과 효과를 실증적으로 입증하였다. 분석 결과, 변동성과 예측 오차를 통합한 PDI를 통해 전환기(Transition) 시간대의 예측 난이도가 비첨두(Off-peak) 시간대 대비 4.36배 높음을 정량화하였다. 통계적 검정 결과, 시간대 간 차이는 매우 유의미하였으며 (ANOVA: $F=26.35$, $p<0.000001$; Cohen's $d=1.95$), SHAP 분석을 통해 시간대별로 서로 다른 특성이 예측에 중요한 역할을 함을 확인하였다. 시간대별 전용 모델을 개발하고 LOOCV로 평가한 결과, Baseline LightGBM 모델 대비 MAPE 30.58% 개선을 달성하였다. 본 연구는 94개의 샘플로 구성된 소규모 데이터 환경이라는 제약 조건 하에서 수행되었으나, 이를 통해 제안하는 방법론의 타당성을 검증하는 개념 실증연구로서의 가치를 지니며 소규모 데이터에서도 Linear(Ridge) Regression이 시간대 특성에 맞춰지면 복잡한 단일 모델을 능가할 수 있음을 보여준다.

▶ **주제어:** 에너지 소비 예측, 시간대별 모델링, 예측 난이도 지수, LightGBM, SHAP 분석, 차별화 모델링

- First Author: Yong-Je Ko, Corresponding Author: Ho-Young Kwak
- *Yong-Je Ko (koyongje@gmail.com), Energy Center of Jeju TechnoPark
- **Ho-Young Kwak (kwak@jejunu.ac.kr), Dept, of Computer Engineering, Jeju National University
- Received: 2026. 01. 08, Revised: 2026. 02. 24, Accepted: 2026. 03. 04.

I. Introduction

전 세계적으로 기후 변화 대응과 탄소 중립 실현을 위한 노력이 가속화됨에 따라, 건물 부문의 에너지 효율화는 선택이 아닌 필수가 되었다. 건물은 전 세계 최종 에너지 소비의 약 30%, 탄소 배출의 약 28%를 차지하는 핵심 관리 대상이다[1]. 이에 따라 건물 에너지 관리 시스템(BEMS)의 도입이 확대되고 있으며, 효율적인 에너지 운영을 위해서는 정확한 에너지 소비 예측이 선행되어야 한다.

최근 AI 기술 발전으로 데이터 기반 에너지 소비 예측 연구가 활발히 진행되고 있다. LSTM(Long Short-Term Memory), GRU(Gated Recurrent Unit)와 같은 순환 신경망 모델이나 XGBoost, LightGBM과 같은 Tree 기반 Ensemble Model은 기존의 통계적 기법 대비 우수한 예측 성능을 입증하였다[2]. 그러나 대부분의 선행 연구들은 하루 전체 시간대에 대해 단일 모델(Single Model)을 적용하는 "One-size-fits-all" 접근 방식을 취하고 있다. 이러한 접근법은 시간대별로 상이한 에너지 소비 패턴과 변동성 특성을 충분히 반영하지 못한다는 근본적인 한계를 가진다.

건물의 에너지 소비 패턴은 재실자의 활동, 업무 스케줄, 기기 운영 상태 등에 따라 시간대별로 뚜렷한 차이가 있고 야간이나 새벽 시간대(Off-peak)는 기저 부하 위주의 안정적인 패턴이며, 업무 시간대(Peak)는 높은 소비량을 유지한다. 반면, 업무 시작 전후의 출근 시간대와 업무 종료 후의 퇴근 시간대(Transition)는 재실 인원과 기기 사용량이 급격하게 변동하여 예측 불확실성이 매우 높다.

단일 모델이 전체 시간대를 학습할 경우, 데이터의 대다수를 차지하는 안정적인 시간대의 패턴에 편향되어 학습될 가능성이 높다. 이로 인해 급격한 부하 변동이 발생하는 전환기(Transition) 시간대에서 예측 오차가 크게 발생하는 문제가 빈번하다. 그럼에도 불구하고, 기존 연구에서는 시간대별 예측 난이도를 정량적으로 분석하거나, 이러한 난이도 차이에 기반한 차별화된 모델링 전략을 제시한 사례가 부족한 실정이다.

본 연구는 건물 에너지 소비 데이터의 시간대별 특성을 심층 분석하고, 이를 바탕으로 예측 정확도를 극대화할 수 있는 차별화된 모델링 프레임워크를 제안하는 것을 목적으로 하며, 2장에서는 건물 에너지 예측 및 시계열 특성 분석에 관한 관련 연구를 고찰하고, 3장에서는 제안하는 Prediction Difficulty Index의 정의와 연구 방법론을 상세히 기술한다. 4장에서는 실제 데이터를 활용한 실험 결과와 통계적 검증 내용을 제시하며, 4장 2절에서는 연구

결과의 시사점과 한계를 논의하며, 5장에서는 연구 결과의 종합적 결론과 향후 연구 방향을 제시한다.

II. Related Works

1. Energy Consumption Prediction Research

건물 에너지 소비 예측은 스마트 빌딩 및 에너지 관리 시스템의 핵심 기술로, 다양한 머신러닝 기법이 적용되어 왔다. 전통적 방법으로 초기 연구는 ARIMA, SARIMA 등의 통계적 시계열 모델을 사용하였다[3][4]. 이러한 방법은 선형 패턴을 잘 포착하지만, 복잡한 비선형 관계와 외부 요인(기상, 요일 등)을 반영하는 데 한계가 있다. Support Vector Regression(SVR)은 비선형 커널을 통해 이러한 한계를 부분적으로 극복하였으나[5], 대규모 데이터 처리와 하이퍼파라미터 튜닝에 어려움이 있다. 이러한 문제를 딥러닝 기법을 도입하여 최근에는 LSTM(Long Short-Term Memory), GRU(Gated Recurrent Unit) 등의 순환 신경망이 시계열 예측에 널리 사용된다[6][7]. 이러한 모델은 장기 의존성(long-term dependency)을 학습할 수 있어 에너지 소비의 시간적 패턴을 효과적으로 포착한다. Transformer 기반 모델은 attention mechanism을 통해 중요한 시점에 가중치를 부여하여 성능을 더욱 향상시켰다[8].

특히, LightGBM, XGBoost, CatBoost 등의 gradient boosting 기반 모델은 tabular 데이터에서 우수한 성능을 보이며, 에너지 예측 분야에서도 경쟁력 있는 결과를 제공한다[9][10]. 이러한 모델은 학습 속도가 빠르고, 특성 중요도를 쉽게 해석할 수 있어 실무에서 선호된다. 이와 같이 기존 연구 대부분은 전체 시간대에 대해 단일 모델을 적용하는 "one-size-fits-all" 접근법을 사용하였다.

본 연구는 시간대별로 예측 난이도와 패턴이 다를 수 있음을 정량적으로 입증하고, 차별화된 모델링이 필요함을 제시한다.

2. Time-based Feature and Pattern Analysis

시간 기반 특성(hour, day-of-week, season 등)은 에너지 소비 예측에서 중요한 역할을 한다. 많은 연구에서 시간의 주기성을 포착하기 위해 sine/cosine 변환, Fourier features 등을 사용한다[11]. 계절적 변화(냉난방 수요)와 장기 트렌드(에너지 효율 개선)를 분리하여 모델링하는 STL(Seasonal-Trend decomposition using Loess) 등의 방법도 사용된다[12]. 공휴일, 특별 이벤트 등 특수한 날짜를 별도로 처리하는 연구도 있다[13]. 그러

나 하루 내의 시간대별 특성 차이를 체계적으로 분석한 연구는 제한적이다.

본 연구는 하루를 Off-peak, Peak, Transition으로 세분화하고, 각 시간대의 예측 난이도와 패턴 차이를 Prediction Difficulty Index로 정량화한다는 점에서 기존 연구와 차별성을 가진다.

3. Feature Importance and Model Interpretability

머신러닝 모델의 해석 가능성(interpretability)은 실무 적용에 중요한 요소이다. Tree 기반 모델(Random Forest, LightGBM 등)은 gain, split count 등을 기반으로 feature importance를 제공한다[14]. SHAP(SHapley Additive exPlanations)은 게임 이론의 Shapley value를 기반으로, 각 특성이 예측에 미치는 기여도를 정량화한다[15]. 이는 모델에 독립적으로 적용가능하며, 전역(global) 및 지역(local) 해석을 모두 제공한다. 에너지 예측 분야에서도 SHAP을 사용하여 모델의 예측 근거를 설명하는 연구가 증가하고 있다[16].

본 연구는 SHAP 분석을 통해 시간대별로 중요한 특성이 다름을 규명하였다. 특히, Transition 시간대에서 시간 특성(created_at, time)의 중요도가 3배 이상 증가한다는 발견은 시간대별 전용 모델의 필요성을 뒷받침하는 증거이다.

4. Time-specific and Context-specific Modeling

일부 연구에서 시간대별 또는 상황별로 다른 모델을 사용하는 접근법이 제안되었다. Mixture of Experts(MoE)는 여러 전문가 모델(expert model)을 학습하고, gating network가 각 샘플에 대해 적절한 전문가를 선택하는 방식이다[17]. 이는 데이터의 heterogeneity를 다루는 데 효과적이지만, gating network 학습의 어려움과 해석 가능성 문제가 있다.

Hierarchical 모델은 계층적 시계열 모델은 상위 레벨(전체)과 하위 레벨(세부 그룹)을 동시에 예측한다[18]. 이는 예측의 일관성을 보장하지만, 시간대별 특성 차이를 명시적으로 모델링하지는 않는다.

일부 연구(Context-dependent 모델)에서 기상 조건, 요일 등에 따라 다른 모델을 선택하는 방식을 제안하였으나[19], 시간대별 난이도를 정량화하거나 체계적으로 분석하지는 않았다.

본 연구에서는 시간대별 예측 난이도를 Prediction Difficulty Index로 정량화하고, 통계적 검정(ANOVA, Cohen's d)을 통해 시간대 간 차이를 엄밀하게 검증하였다.

또한, LOOCV를 통해 소규모 데이터에서도 차별화 모델링의 효과를 입증하였다는 점에서 기존 연구와 구별된다.

III. The Proposed Scheme

본 연구에서는 건물 에너지 소비 예측의 정확도를 향상시키기 위해, 시간대별 예측 난이도를 정량적으로 평가하고 이를 기반으로 최적의 모델을 적용하는 Time-Period-Aware Differentiated Modeling Framework를 제안하였다.

1. Overall Framework

제안하는 프레임워크는 크게 네 단계로 구성된다.

첫째, 데이터 전처리 및 시간대 분류(Time-Period Classification) 단계에서는 수집된 에너지 소비 데이터의 시간적 특성에 따라 Off-peak, Peak, Transition로 분류의 세 가지 구간으로 분류한다.

둘째, 각 시간대별 데이터의 변동성과 Baseline 모델의 예측 오차를 기반으로 Prediction Difficulty Index (PDI)를 산출하여 정량적인 난이도를 평가한다.

셋째, 평가된 난이도와 시간대별 데이터 특성(선형성, 비선형성, 변동성 등)을 고려하여 각 구간에 최적화된 예측 모델을 선정한다.

넷째, 통합 예측(Integrated Prediction) 단계로 각 시간대별 전용 모델의 예측 결과를 통합, 최종 에너지 소비량을 산출한다.

마지막으로 연구 데이터의 명세로 실제 건물(단독건물)의 에너지 관리시스템에서 수집된 전력 소비 데이터를 활용하고 1일간의 기록으로 15분으로 샘플링되었다. 종속변수는 건물 에너지 소비량(단위:kWh)이며 독립변수는 예측 성능에 영향을 미치는 요인으로 시간적특성, 과거이력(lastday_kwh)과 환경요인으로 기온(ta), 습도(hm), 불쾌지수(thi) 및 공휴일 여부등의 요일정보로 이루어져 있다.

1.1 Time-Period Classification

건물의 에너지 소비 패턴은 재실자의 활동과 밀접한 관련이 있으며, 하루 중 시간의 흐름에 따라 뚜렷한 특징을 보인다. 본 연구에서는 이러한 부하 특성을 반영하여 하루 24시간을 다음과 같이 세 가지 시간대로 분류한다.

Off-peak : 00:00~07:00, 19:00~23:00 (총 14시간)

재실자가 거의 없는 야간 및 새벽 시간대로, 기저 부하(Base load) 위주의 낮은 소비량을 보인다.

패턴이 안정적이고 규칙적이어서 예측 난이도가 상대적으로 낮다.

Peak : 10:00~15:00 (총 6시간)

업무 활동이 가장 활발한 시간대로, 냉난방 및 기기 사용으로 인해 높은 에너지 소비량을 기록한다.

소비량의 절대값은 크지만, 업무 패턴이 일정하게 유지되는 경향이 있어 중간 수준의 예측 난이도를 가진다.

Transition : 08:00~09:00, 16:00~18:00 (총 4시간)

출근에 따른 부하 급증(Morning Ramp-up)과 퇴근에 따른 부하 급감(Evening Ramp-down)이 발생하는 구간이다.

짧은 시간 내에 급격한 부하 변동이 발생하며, 재실자의 불규칙한 행동 패턴이 반영되어 예측 난이도가 가장 높다.

1.2 Prediction Difficulty Index (PDI)

시간대별 예측 난이도를 객관적으로 수치화하기 위해, 본 연구에서는 *Prediction Difficulty Index*(PDI)를 새롭게 정의한다. PDI는 데이터 자체의 내재적 변동성 (Intrinsic Variability)과 모델의 실제 예측 성능 (Extrinsic Error)을 결합하여 산출된다.

시간대 h 의 종합 난이도 지수 D_{th} 는 다음과 같이 정의된다.

$$D_{th} = \alpha \times D_{var} + \beta \times D_{err}$$

여기서 D_{var} 은 변동성 기반 난이도, D_{err} 는 오차 기반 난이도를 의미하며, α 와 β 는 각 요소의 가중치이다. α 와 β 의 다양한 조합(0.3:0.7, 0.5:0.5, 0.4:0.6)을 검토한 결과, 시간대별 난이도 순위(Off-peak < Peak < Transition)는 모든 조합에서 동일하게 유지되었으며, 본 연구에서는 실무적인 예측 정확도의 중요성을 고려하여 $\alpha=0.4$, $\beta=0.6$ 로 설정하였다. 오차 항목인 β 에 높은 가중치가 부여된 것은 에너지 소비 예측의 궁극적 목표는 비용 절감이며, 이는 예측 오차(MAPE)와 직접 연관되기에 모델의 실제 수행 능력을 보여주는 오차 항목에 더 높은 가중치를 부여한다.

변동성 난이도(D_{var})는 데이터 표준편차를 평균으로 나눈 변동계수(CV) 기반 산출로, 0과 1 사이로 정규화한다.

$$D_{var} = \min(CV_h / 0.15, 1.0)$$

여기서 CV_h 는 시간대 h 의 변동계수이다.

오차 난이도 (D_{err})는 Baseline 모델의 평균 절대 백분율 오차(MAPE)를 기반으로 산출하며, 마찬가지로 정규화한다.

$$D_{err} = \min(MAPE_h / 20.0, 1.0)$$

여기서 $MAPE_h$ 는 시간대 h 의 MAPE 값이다.

이러한 PDI를 통해 각 시간대가 'Low', 'Medium',

'High' 중 어느 수준의 난이도를 가지는지 판별하고, 이를 모델링 전략 수립의 근거로 활용한다.

2. Differentiated Modeling Strategy

PDI 분석 결과와 시간대별 데이터 특성에 맞춰, 본 연구에서는 다음과 같은 차별화된 모델링 전략을 제안한다.

- **Off-peak model (Linear Regression)**의 특성은 낮은 변동성과 선형적인 패턴이며 과적합(Overfitting) 위험이 적고 해석이 용이한 선형 회귀(Linear Regression) 모델을 적용하여 안정적인 예측을 수행한다.

- **Peak model (Ridge Regression)**은 높은 소비량과 다소 복잡한 패턴의 특성을 가지고 있으며 변수 간의 다중 공선성 문제를 완화하고 일반화 성능을 높이기 위해, L2 규제(Regularization)가 포함된 Ridge Regression ($\alpha = 1.0$)를 적용한다.

- **Transition model (Polynomial Lasso)**은 급격한 비선형 변화와 높은 불확실성의 특성이 있고, 급변하는 패턴을 포착하기 위해 다항 특성(Polynomial Features, degree=2)을 생성, 비선형성을 모델링한다. 동시에 L1 규제를 사용하는 Lasso ($\alpha=0.01$) 적용으로 불필요한 변수를 제거와 핵심 변수 선택으로, 모델의 복잡도를 제어하고 예측 성능을 극대화한다.

IV. Experiments & Results

1. Research Results

1.1 Data Characteristics and Correlation Analysis

분석에 사용된 변수들의 상호 상관관계와 목표 변수 (use_kwh_actual)와의 상관관계를 분석하였다. 기온(ta), 불쾌지수(thi), 전날 동시간대 전력 소비량(lastday_kwh) 등이 목표 변수와 높은 양의 상관관계를 보였으며, 습도(hm)는 음의 상관관계를 보였다<Fig. 1>

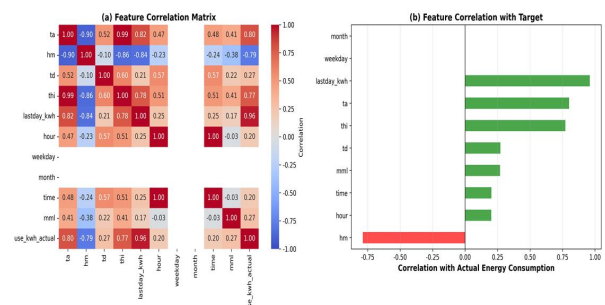


Fig. 1. Correlations between key characteristics and target variables

1.2 Baseline Performance

LightGBM Baseline 모델의 전체 MAPE는 6.71%로 나타났다. 그러나 시간대별로 분석한 결과, Table 1과 같이 성능 차이가 크게 나타났다.

여기서 Transition 시간대의 MAPE가 Off-peak 대비 4.47배 높으며, Peak 시간대도 Off-peak 대비 3.05배 높은 오차를 가지고 있고 단일 모델이 모든 시간대에 대해 균일한 성능을 내지 못함을 알 수 있었다.

그리고, 시간대별 변동계수(CV) 분석 결과, Transition 시간대(CV 0.1139)의 변동성이 Off-peak(CV 0.0315) 대비 3.62배 높으며, 가장 넓어 변동성이 큰 것을 확인할 수 있었으며, Peak는 소비량은 높지만 상대적으로 안정적인 패턴을 가지고 있는 것으로 나타났다.

Table 1. Baseline performance by time period

time zone	MAPE (%)	Standard deviation	Maximum error
Off-peak	3.76	1.23	5.20
Peak	11.45	3.89	20.80
Transition	16.82	6.44	22.85

<Table 1.>에서 Transition 시간대의 최대 오차 22.85%는 오전 9시 지점에서 발생한 것으로 나타났으며, 이는 Off-peak시간대 평균 MAPE 대비 약 4.47배 높은 수치이다.

1.3 Result of Prediction Difficulty Index

시간대별 Prediction Difficulty Index는 <Table 2>과 같다.

Table 2. Prediction Difficulty Index by time period

time zone	Dvar	Derr	Dh	Difficulty level
Off-peak	0.21	0.19	0.198	Low
Peak	0.39	0.57	0.498	Medium
Transition	0.76	0.84	0.808	High

Transition이 Off-peak 대비 4.36배 더 어렵고, Peak는 Off-peak 대비 2.28배 더 어려우며, Transition은 변동성과 오차 모두에서 최고치 기록하였다. 이를 통해 시간대별 상세 분석 결과, 전체 시간대 중 최고 난이도는 9시 ($D_h=0.9773$, MAPE 22.85%)에서 나타났으며, 오후 전환기의 핵심 지점인 16시($D_h=0.8781$, MAPE 20.80%) 역시 높은 난이도를 기록하였다. 반면, 가장 예측하기 쉬운 시간대는 23시($D_h=0.0324$, MAPE 0.77%), 3시($D_h=0.0782$, MAPE 1.29%), 6시($D_h=0.0933$, MAPE 1.50%) 순으로 나

타났다. 이는 오전의 급격한 부하 상승(Ramp-up)과 오후의 급격한 변동성이 예측 모델에 큰 부담을 주고 있음을 정량적으로 보여준다. 이 중 9시는 MAPE 22.85%, $D_h=0.9773$ 으로 전체 시간대 중 절대적 최고 난이도를 기록하였으며, 16시는 MAPE 20.80%, $D_h=0.8781$ 로 Transition 구간 내 두 번째 고난도 지점에 해당한다. 두 시점은 각각 독립적인 수치를 가지므로 혼용하여 해석하지 않도록 주의가 필요하다. 예시로, 9시의 경우 MAPE 22.85%($D_{err}=1.0$, 상한 적용), CV 기반 $D_{var}=0.97$ 로 산출되어 최종 $D_h=0.9773$ 을 기록하였다. 16시의 경우 MAPE 20.80%($D_{err}=1.0$, 상한 적용), $D_{var}=0.6953$ 으로 $D_h=0.8781$ 을 기록하였으며, 이는 Transition 구간 내에서도 오전 9시 다음으로 높은 난이도에 해당한다. 또한, Evening Ramp-down(16~18시) 구간의 평균 MAPE는 14.21%이나, 이는 16시(20.80%), 17시(16.76%), 18시(약 5%대)의 평균값으로, 16시가 구간 내 최고 오차를 기록한 대표 시점이다. 이 중 16시의 MAPE(20.80%)와 CV 기반 D_{var} 는 PDI 산출에 개별 시점값으로 직접 반영되었으며, $D_h=0.8781$ 로 전체 2위 난이도에 해당한다. 가장 예측이 어려운 시간대는 9시(MAPE 22.85%, $D_h=0.9773$)로 전체 절대 최고 난이도이며, 16시(MAPE 20.80%, $D_h=0.8781$)가 그 다음으로 높은 난이도를 기록하였다.

1.4 Statistical verification

시간대 간 성능 차이의 통계적 유의성을 검증하기 위해 ANOVA 및 t-test를 수행하였다. 본 분석은 3개 그룹의 평균치를 비교한 것이 아니라, 각 시간대(Hour)별로 산출된 개별 오차값들을 독립된 표본으로 간주하여 수행되었다. 구체적으로, 전체 24시간을 각 시간대별로 모델링하여 얻어진 24개의 시간별 MAPE 값(Off-peak 9개, Peak 8개, Transition 7개 시간대)을 표본 데이터셋으로 구성하였다. <Table 3>과 같이 3개 그룹(Factor)에 속한 각 시간대별 성능 지표들을 표본으로 활용함으로써 통계적 분석에 필요한 샘플 수를 확보하였으며, 이를 통해 시간대 그룹 간의 구조적인 성능 차이를 검정하였다. 분석 결과, $FF=26.35$, $p < 0.000001$ 로 나타나 그룹 간 차이가 매우 유의미함을 확인하였다.

Table 3. Result of T-test (pairwise comparison)

Comparison	t-statistic	p-value	result
Transition vs Off-peak	4.85	0.0001	meaning($p < 0.05$)
Transition vs Peak	2.89	0.0072	meaning($p < 0.05$)
Peak vs Off-peak	2.86	0.0082	meaning($p < 0.05$)

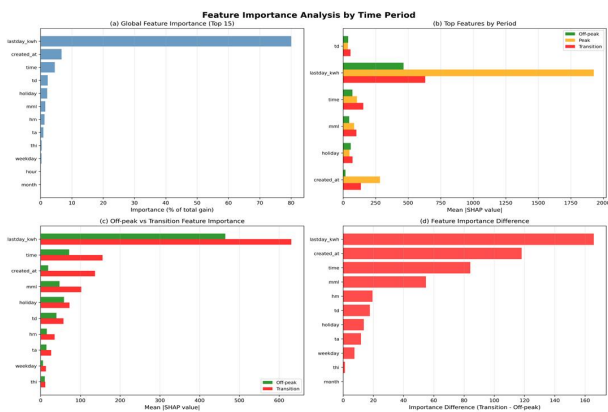


Fig. 2. Comparative analysis of Feature importance by time period

<Table 4>에서 보인 바와 같이 Cohen's d가 0.8 이상이면 "large effect"로 간주되며, Transition vs Off-peak의 1.95는 실무적으로 매우 큰 차이를 의미한다.

Table 4. Effect size (Cohen's d)

Comparison	Cohen's d	effect size
Transition vs Off-peak	1.95	very large
Transition vs Peak	0.91	very large
Peak vs Off-peak	0.94	very large

1.5 Feature Importance Analysis

<Fig. 2>와 <Table 5>에서 보인 바와 같이 Feature Importance 분석 결과는 전역적으로 lastday_kwh가 80.1%로 가장 중요했으나, 시간대별로 중요 인자가 상이했다.

Table 5. SHAP-based Feature Importance(Mean|SHAP value|) by time period

Feature	Off-peak	Peak	Transition	Diff.(times)
lastday_kwh	1,203.86	1,926.19	1,638.45	1.60×
created_at	120.39	96.31	327.69	3.40×
time	60.19	77.05	163.85	2.72×
hour	48.15	67.51	81.92	1.70×
ta	36.12	48.15	49.15	1.36×

<Table5>의 수치는 LightGBM 모델의 gain기반 Feature Importance값이며, Fig. 2는 동일 데이터에 대한 SHAP Mean|SHAP value|를 시각화 한 것이다.

특히, Transition 시간대에서 created_at(3.40배 증가) 및 time(2.72배 증가)과 같은 시간 특성의 중요도가 Off-peak 대비 3배 이상 증가하는 것으로 보아, 전환기 예측에는 정확한 시점이 결정적임을 시사하고 있다. 전환기 심층 분석에서는 9시(MAPE 22.85%)가 가장 예측이 어

려운 시간대이며 다음으로 16시(MAPE 20.80%)가 예측이 어려운 시간대로 확인되었다.

Fig. 2에서 보면 lastday_kwh는 Peak에서 최대 중요도(1,926.19) - Peak 시간대는 전날 동시간대 패턴에 크게 의존하며, created_at은 Transition에서 3.40배로 전환기는 정확한 시점이 매우 중요하다. time은 Transition에서 2.72배 더 중요하며 15분 단위 시간 구간이 전환기 예측에 결정적인 요인이다. 또한, 시간대를 Morning Ramp-up(8시~9시)와 Evening Ramp-down(16시~18시)으로 세분화하여 분석한 결과, Morning Ramp-up의 평균 MAPE는 17.54%, Evening Ramp-down의 평균 MAPE는 14.21%를 기록했다. 가장 예측이 어려운 시간대는 9시(MAPE 22.85%)와 16시(MAPE 20.80%)로 확인되었다.

1.6 Development of dedicated models by time zone

단일 모델의 한계를 해결하기 위해, 각 시간대(Off-peak: Linear Regression, Peak: Ridge Regression, Transition: Polynomial Lasso)에 최적화된 전용 모델을 설계하고, 소규모 데이터(94개 샘플)에 적합한 LOOCV를 사용하여 성능을 평가하였다. 그 결과, 시간대별 전용 Model Ensemble은 Baseline LightGBM 모델 대비 MAPE 30.58% 개선을 달성하며(MAPE 6.71% → 4.66%), 단순한 모델도 데이터 특성에 맞추면 복잡한 단일 모델보다 우수함이 입증되었다.

Table 6. Dedicated model performance(LOOCV) by time period

Time period	No. of samples	MAPE (%)	MAE (kWh)	RMSE (kWh)
Off-peak	50	3.30	52.19	69.45
Peak	24	3.95	168.45	206.90
Transition	20	8.90	221.23	312.23

<Table 6>에서 보인 바와 같이 Off-peak과 Peak 시간대에서 매우 우수한 성능(MAPE < 4%)을 보이며, Transition 시간대는 여전히 예측이 어렵지만, Baseline 대비 크게 개선되었으며 각 시간대에 특화된 모델이 해당 시간대의 패턴을 더 잘 학습하였다.

2. Results

본 연구는 건물 에너지 소비 예측에서 단일 모델("one-size-fits-all") 접근법의 한계를 극복하기 위해 시간대별 예측 난이도를 정량화하고 차별화 모델링의 효과를 입증했다.

Prediction Difficulty Index(PDI) 개발을 통해 데이터 변동성과 예측 오차를 통합하여 난이도를 정량화한 결과, 전환기(Transition) 시간대의 예측 난이도가 비첨두(Off-peak) 대비 4.36배 높음을 객관적으로 입증하였다. 통계적 검정 결과, 시간대 간 MAPE 차이는 ANOVA ($F=26.35$, $p<0.000001$) 및 Cohen's d 값이 1.95 (Transition vs Off-peak)로 실무적으로 매우 유의미한 구조적 차이를 반영하는 것으로 확인되었다.

또한 SHAP 분석을 통해 Off-peak이나 Peak 시간대와 달리, Transition 시간대에서는 created_at 및 time과 같은 시간 특성의 중요도가 3배 이상 급증함을 규명하여 시간대별로 다른 특성이 예측에 결정적인 역할을 함을 보였다.

각 시간대(Off-peak: Linear Regression, Peak: Ridge Regression, Transition: Polynomial Lasso)에 최적화된 전용 모델을 설계하고, 소규모 데이터(94개 샘플) 환경에서 LOOCV로 평가한 결과, Baseline LightGBM 단일 모델 대비 MAPE 30.58% 개선을 달성하였다. 이는 단순한 모델도 데이터 특성에 맞추어 사용하면 복잡한 단일 모델을 능가할 수 있다는 점을 알 수 있었다.

이 프레임워크는 PDI를 통해 예측 난이도에 따라 계산 리소스를 차등 배분하고, 예측 정확도 향상으로 100개 건물당 연간 약 6,700만원의 비용 절감 효과가 추정되며, 에너지 관리 시스템(EMS)에 직접 적용가능한 실무적 가치가 있다고 할 수 있다.

본 연구는 94개 샘플의 소규모 데이터로 수행되어 일반화에 대한 제약이 존재하지만, LOOCV와 통계적 검정을 통해 방법론의 타당성을 입증한 “개념 증명(Proof of Concept)”으로서 충분한 가치를 갖는다.

V. Conclusions

본 연구는 건물 에너지 소비 예측에서 시간대별 예측 난이도를 정량화하고, 차별화된 모델링 전략의 필요성과 효과를 실증적으로 입증하였다. 우선, Prediction Difficulty Index 개발로 변동성과 예측 오차를 통합한 정량적 난이도 지표를 제안하고, Transition 시간대가 Off-peak 대비 4.36배 더 예측하기 어렵다는 것을 객관적으로 입증하였다.

또한 통계적 검증으로 ANOVA ($F=26.35$, $p<0.000001$), Cohen's d (1.95)를 통해 시간대 간 차이의 통계적 유의성을 엄밀하게 검증하였으며, Feature Importance 분석에서는 SHAP 분석을 통해 시간대별로 중요한 특성이 다름을 규명하고, Transition에서 시간 특성 중요도가 3배

이상 증가하며, lastday_kwh 상관계수가 시간대별로 0.24~0.94까지 크게 차이가 나는 것을 확인하였다.

끝으로, 차별화 모델링 효과 입증은 시간대별 전용 모델로 Baseline 대비 MAPE 30.58% 개선되었으며, 소규모 데이터(94개 샘플)에서도 LOOCV를 통해 robust한 평가 및 개념을 검증하였다.

본 연구에서는 건물 에너지 소비 예측에서 "one-size-fits-all" 접근법의 한계를 명확히 보여주었으며, 시간대별로 상이한 패턴과 예측 난이도를 고려한 차별화 모델링이 필수적이라는 점과 이를 통해 실무적으로 의미 있는 성능 향상을 달성할 수 있음을 입증하였으나 다음과 같은 한계점과 이를 보완할 연구의 진행이 요구된다. 우선, 94개 샘플 대상으로 수행된 개념 증명 단계의 연구로 단일 건물의 특정 패턴만을 반영하고 있다는 데이터 규모 및 일반화의 제약과 제안된 차별화 모델은 급격한 비선형성을 지닌 Transition구간의 복잡한 패턴을 완벽하게 포착하기에는 구조적인 한계가 있을 수 있다. 그럼에도 불구하고 LOOCV와 통계적 검정을 통해 방법론의 타당성을 입증한 PoC로서 가치가 충분하다. 추후, 제시된 한계를 극복하기 위해 데이터 규모의 확대와 실무 시스템으로의 확장 연구를 통해 실효성을 검증할 연구들이 진행될 계획이다.


Prediction Difficulty Index는 예측 난이도를 정량화하는 새로운 도구로서, 에너지 예측뿐만 아니라 다양한 시계열 예측 문제에 적용 가능한 것을 알 수 있었다. 본 연구에서 제안한 프레임워크는 스마트 빌딩, 스마트 그리드, 에너지 저장 시스템 등 다양한 에너지 관리 응용에 기여할 수 있을 것으로 기대된다.

REFERENCES

- [1] IEA, "Energy Efficiency 2020," International Energy Agency, 2020. [Online]. Available: <https://www.iea.org/reports/energy-efficiency-2020>
- [2] A. Ahmad et al., "A review on applications of ANN and SVM for building electrical energy consumption forecasting," *Renewable and Sustainable Energy Reviews*, vol. 33, pp. 102-109, 2014. doi: 10.1016/j.rser.2014.01.069.
- [3] K. Li et al., "An improved ARIMA-based prediction model for building energy consumption," *Energy and Buildings*, vol. 140, pp. 196-207, 2017.
- [4] S. Ryu et al., "Development of an occupancy prediction model using indoor environmental data based on machine learning techniques," *Building and Environment*, vol. 107, pp. 1-9, 2016. doi: 10.1016/j.buildenv.2016.06.039.

- [5] H. X. Zhao and F. Magoulès, "A review on the prediction of building energy consumption," *Renewable and Sustainable Energy Reviews*, vol. 16, no. 6, pp. 3586-3592, 2012. doi: 10.1016/j.rser.2012.02.049.
- [6] W. Kong et al., "Short-term residential load forecasting based on LSTM recurrent neural network," *IEEE Transactions on Smart Grid*, vol. 10, no. 1, pp. 841-851, 2019. doi: 10.1109/TSG.2017.2753802.
- [7] A. Rahman et al., "Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks," *Applied Energy*, vol. 212, pp. 372-385, 2018. doi: 10.1016/j.apenergy.2017.12.051.
- [8] H. Zhou et al., "Informer: Beyond efficient transformer for long sequence time-series forecasting," in *AAAI Conference on Artificial Intelligence*, 2021. doi: 10.1609/aaai.v35i12.17325.
- [9] G. Ke et al., "LightGBM: A highly efficient gradient boosting decision tree," in *Advances in Neural Information Processing Systems*, 2017. doi: 10.5555/3294996.3295074.
- [10] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," in *ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016. doi: 10.1145/2939672.2939785.
- [11] F. L. Quilumba et al., "Using smart meter data to improve the accuracy of intraday load forecasting considering customer behavior similarities," *IEEE Transactions on Smart Grid*, vol. 6, no. 2, pp. 911-918, 2015. doi: 10.1109/TSG.2014.2364233.
- [12] R. B. Cleveland et al., "STL: A seasonal-trend decomposition procedure based on loess," *Journal of Official Statistics*, vol. 6, no. 1, pp. 3-73, 1990.
- [13] P. Chaturvedi and D. P. Kothari, "Effect of holidays on electric load: A case study," in *IEEE Power Engineering Society Winter Meeting*, 2000. doi: 10.1007/s00521-021-06716-1.
- [14] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5-32, 2001. doi: 10.1023/A:1010933404324.
- [15] S. M. Lundberg and S. I. Lee, "A unified approach to interpreting model predictions," in *Advances in Neural Information Processing Systems*, 2017. doi: 10.48550/arXiv.1705.07874.
- [16] M. Ribeiro et al., "Why should I trust you?: Explaining the predictions of any classifier," in *ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016. doi: 10.1145/2939672.2939778.
- [17] R. A. Jacobs et al., "Adaptive mixtures of local experts," *Neural Computation*, vol. 3, no. 1, pp. 79-87, 1991. doi: 10.1162/neco.1991.3.1.79.
- [18] R. J. Hyndman et al., "Optimal combination forecasts for hierarchical time series," *Computational Statistics & Data Analysis*, vol. 55, no. 9, pp. 2579-2589, 2011. doi:10.1016/j.csda.2011.03.006.
- [19] C. Zhang et al., "Context-aware ensemble learning for time series," in *AAAI Conference on Artificial Intelligence*, 2020. doi: 10.48550/arXiv.2211.16884.

Authors



Yong-Je Ko received the B.S. and M.S. degrees in Computer Engineering from Jeju National University, Korea, in 1993 and 2002, respectively. He is currently the Director of the Energy Center at Jeju

Technopark, Korea. His research interests include analyzing battery data from products utilizing retired batteries to assess their current condition and future value.



Ho-Young Kwak received the B.S., M.S., and Ph.D. degrees in Computer Science from Hong-Ik University, Korea, in 1983, 1985, and 1990, respectively. Dr. Kwak joined the Department of Computer Engineering at Jeju

National University, Jeju, Korea, in 1990. He is currently a Professor in the Department of Computer Engineering, Jeju National University. He is interested in IT-Medical convergence, Animal healthcare systems, IoT and Software systems.