

그린리모델링 활성화를 위한 기계학습 기반 EUI 예측 알고리즘 성능 비교 연구*

A Comparative Study on the Performance of Machine Learning-Based EUI Prediction Algorithms for Promoting Green Remodeling

김병민** · 강찬혁*** · 정보경**** · 임종연***** · 최창호***** · 권영철*****

Byungmin Kim** · Chanhyeok Kang*** · Bokyoung Jung**** · Jongyeon Lim***** · Changho Choi***** · Youngcheol Kwon*****

Abstract

As carbon neutrality policies gain prominence, green remodeling has become increasingly important for improving the energy performance of aging public buildings. However, ECO2-OD-based energy performance evaluation, which is widely used in practice, requires numerous input variables, thereby limiting the rapid comparison of alternatives in the early decision-making stage due to the burden of data collection and the complexity of the input process. This study used real-world data from public facilities for the elderly and children collected through the 2020-2021 Regional Hub Platform Project for Green Remodeling of Public Buildings to compare machine learning-based surrogate models for approximating annual energy use intensity (EUI). Linear models, tree-based models, and deep learning models specialized for tabular data were evaluated under identical conditions. The results showed that tree-based models generally outperformed the others, and CatBoost was selected as the representative algorithm in terms of predictive accuracy and stability after hyperparameter optimization and multi-seed evaluation. In addition, a supplementary analysis of pre- and post-remodeling EUI changes showed that the selected model generally captured the direction of energy performance changes consistently. These findings provide practical criteria for selecting algorithms for surrogate model construction based on real project data and serve as a foundation for the future development of lightweight surrogate models with reduced input requirements.

Keywords: Green Remodeling, ECO2-OD, EUI, Machine Learning, Circular Economy

*본 논문은 2026년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. RS-2023-00217322).

**㈜미래환경플랜건축사사무소 건축신기술연구소 연구원(주저자: bkim4124@energyx.co.kr)

***광운대학교 일반대학원 건축공학과 박사 수료(rkd885789@naver.com)

****에너지엑스㈜ 최고기술책임자(bjung@energyx.co.kr)

*****강원대학교 건축공학과 교수(jongyeon.lim@kangwon.ac.kr)

*****광운대학교 건축공학과 교수(choi1967@kw.ac.kr)

*****한라대학교 건축학과 교수(교신저자: yckwon@halla.ac.kr)

Received: March 26, 2026 / Accepted: May 4, 2026

1. 서론

1.1 연구의 배경 및 목적

전 세계적인 탄소 중립 기조에 대응하여 건축 부문의 에너지 소비 절감은 중요한 정책 과제로 부상하고 있다(권영철, 2023). 특히 준공 후 장기간이 경과한 노후 건축물의 비중이 증가함에 따라, 기존 건축물의 에너지 성능을 개선하는 그린리모델링의 중요성이 더욱 커지고 있다(강찬혁 외, 2024). 성공적인 그린리모델링을 위해서는 대상 건축물의 현황을 정밀하게 진단하고, 리모델링 대안에 따른 에너지 성능 변화를 사전에 신뢰성 있게 예측할 수 있어야 한다. 국내 실무에서는 이를 위해 ECO2-OD와 같은 물리 기반 에너지 성능 평가 도구가 활용되고 있으나, 이러한 방식은 다수의 상세 입력 변수를 요구하므로 데이터 수집 부담과 입력 과정의 높은 인지 부하를 수반한다. 그 결과 초기 의사결정 단계에서 다양한 대안을 신속하게 비교·검토하는 데 실질적인 제약이 발생하며, 비전문가가 이를 직접 수행하기도 쉽지 않다. 이에 따라 실무에서는 전문가 용역에 의존하게 되고, 이로 인한 추가 비용은 건축주의 자발적 참여를 저해하는 장벽으로 작용한다(문보람 외, 2023).

이와 같은 한계를 보완하기 위한 대안으로, 최근에는 물리 기반 시뮬레이션 결과를 기계학습으로 근사하는 대리모델(surrogate model) 연구가 활발히 이루어지고 있다(Westermann and Evins, 2019; Wei et al., 2018). 대리모델이 실무에서 활용되기 위해서는 우선 예측 정확도와 적용 가능성에 대한 검토가 선행될 필요가 있으며, 이러한 검토는 향후 입력 변수를 최소화한 경량화 대리모델 개발의 기초 자료로도 활용될 수 있다. 그런데 기존 연구의 상당수는 가상 시뮬레이션 데이터나 제한된 레퍼런스 모델을 바탕으로 수행되어, 실제 그린리모델링 사업 환경에서 나타나는 건축물 간 이질성, 입력 정보의 불완전성,

지역별 조건 차이를 충분히 반영하지 못했다. 특히 실제 공공건축물 그린리모델링 데이터를 활용하여 다양한 기계학습 알고리즘을 동일 조건에서 비교하고, ECO2-OD 대리모델 구축에 적합한 알고리즘을 검토한 연구는 제한적이다. 또한 실제 사업에서는 동일 건축물의 리모델링 전·후 에너지 성능을 비교하여 절감 효과를 판단하는 과정이 중요하지만, 대리모델이 이러한 변화의 방향성을 어느 정도 일관되게 포착할 수 있는지에 대한 검토 역시 충분하지 않았다.

이에 본 연구는 실제 공공건축물 그린리모델링 사업 데이터를 활용하여 ECO2-OD의 물리 기반 에너지 성능 평가를 근사하는 기계학습 기반 대리모델을 구축하고, 이에 적합한 알고리즘을 실증적으로 검토하고자 한다. 대리모델의 예측 정확도는 ECO2-OD 결과에 의해 결정되므로, 연구의 1차 질문은 실제 공공건축물 그린리모델링 데이터에서 연간 단위면적당 1차 에너지 소모량(energy use intensity, EUI)을 가장 높은 정확도로 근사하는 기계학습 알고리즘이 무엇인가에 있다. 나아가 선정된 대표 모델에 대해서는 동일 건축물의 리모델링 전·후 EUI 변화 방향을 어느 정도 일관되게 포착할 수 있는지를 보조적으로 검토함으로써, 실무 데이터 환경에서 대리모델의 활용 가능성을 추가로 살펴보고자 한다. 궁극적으로 본 연구는 경량화된 대리모델 개발을 위한 선행 연구로서, 실제 사업 데이터 기반 ECO2-OD 대리모델 구축에 적합한 알고리즘 선택 기준을 제시하는데 있다.

1.2 연구의 범위 및 방법

본 연구는 2020년부터 2021년까지 수행된 「공공건축물 그린리모델링 지역거점 플랫폼 사업」을 통해 수집된 공공 노유자시설 데이터를 활용한다. 분석 대상은 실제 공공건축물의 그린리모델링 전·후 에너지 성능 평가 결과를 포함하며, 이를 기계학습

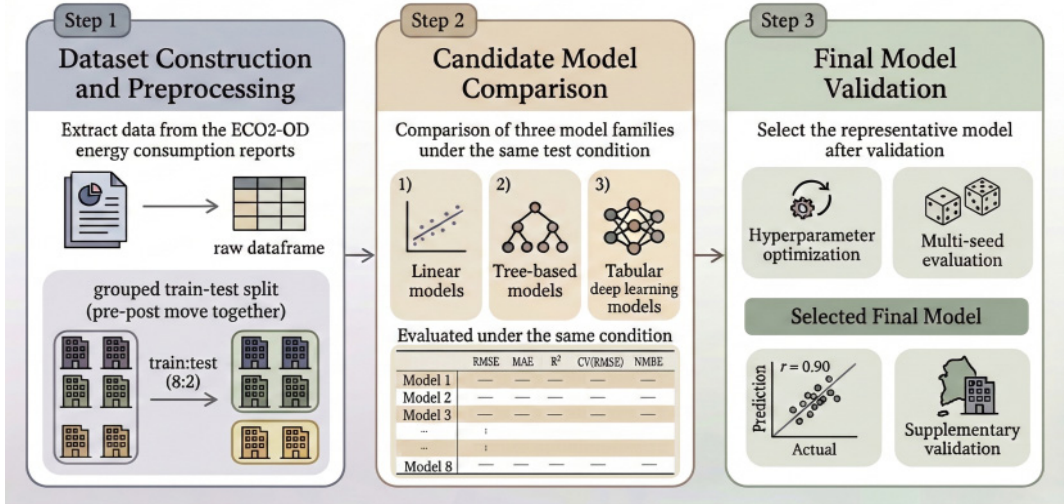


Fig. 1. Overall Research Workflow for Machine Learning-Based EUI Prediction Using ECO2-OD Green Remodeling Data (The Process Consists of Three Stages: (1) Dataset Construction and Preprocessing, (2) Candidate Model Comparison, and (3) Final Model Validation Including Building- and Regional-Level Analysis)

기반 ECO2-OD 대리모델의 학습 및 검증 데이터로 사용하였다. 예측 대상은 ECO2-OD가 산정한 EUI이며, 각 기계학습 모델이 ECO2-OD의 계산 결과를 얼마나 정확하게 근사할 수 있는지를 비교하였다.

연구의 전체 절차는 Fig. 1과 같으며, 데이터셋 구축 및 전처리, 후보모델 비교 및 최적화, 대표 모델 검증으로 구성된다. 데이터셋 구축 과정에서는 동일 건축물의 전·후 자료가 학습·테스트 세트에 동시에 포함되지 않도록 건물 단위 그룹 분할을 적용하였다. 모델 비교 단계에서는 선형 모델, 트리 기반 모델, 정형 데이터 특화 딥러닝 모델 등을 동일 조건에서 평가하였으며, 상위 모델에 대해 하이퍼파라미터 최적화와 다중 시드 평가를 수행하였다. 각 단계의 세부 사항은 제3장에서 기술한다.

본 연구의 주요 기여는 다음과 같다. 첫째, 실제 공공건축물 그린리모델링 사업 데이터를 활용하여 다양한 기계학습 알고리즘을 동일 조건에서 비교함으로써, ECO2-OD 대리모델 구축에 적합한 알고리즘 선택의 실증적 기준선을 제시하고자 한다. 둘째, 상태 기반 EUI 예측뿐 아니라 동일 건축물의 리모델링

전·후 변화 양상을 함께 검토함으로써, 대표 모델이 초기 의사결정 지원 맥락에서 보조적으로 활용될 수 있는지를 탐색하고자 한다. 셋째, 이러한 비교 결과를 바탕으로 향후 입력 변수를 최소화한 경량화 대리모델 개발을 위한 기초 자료를 제공하고자 한다.

본 논문은 다음과 같이 구성된다. 제2장에서는 그린리모델링 사업과 기계학습 기반 대리모델에 관한 선행연구 및 이론적 배경을 검토한다. 제3장에서는 데이터셋 구축, 전처리, 실험 설계와 평가 지표를 설명한다. 제4장에서는 모델별 성능 비교와 최종 대표 모델의 안정성, 건물·지역 단위 예측 양상을 제시한다. 제5장에서는 결과의 의미와 한계를 논의하고, 제6장에서는 결론과 향후 과제를 정리한다.

2. 그린리모델링 에너지 성능 평가 및 기계학습 기반 대리모델 고찰

2.1 그린리모델링 에너지 성능 평가와 ECO2-OD

정부는 기축 건축물의 에너지 성능 개선을 촉진하기 위해 공공 및 민간 건축물을 대상으로 그린리모

델링 지원사업을 추진해 왔다. 공공 부문에서는 노유자 시설을 중심으로 한 그린리모델링 사업과 지역 거점 플랫폼 사업 등을 통해 에너지 성능 향상을 지원하고 있으며, 민간 부문에 대해서도 금융 지원 중심의 정책이 병행되고 있다(문보람 외, 2023). 이러한 지원사업의 효과를 객관적으로 평가하기 위해서는 표준화된 에너지 성능 평가 도구를 활용한 정량적 검증이 필수적이다(박성남 외, 2022). 나아가 그린리모델링 적용 요소의 조합별 우선순위를 도출하거나(심성진 외, 2024), 에너지비용 시나리오에 따른 생애주기비용 분석을 통해 경제적 타당성을 검증하는 연구(임세현 외, 2026)도 수행되고 있어, 그린리모델링 의사결정을 지원하기 위한 다양한 접근이 모색되고 있다.

국내 실무에서는 이러한 그린리모델링 지원사업의 효과 분석을 위해 건축물 에너지성능 평가프로그램(ECO2-OD)이 대표적인 도구로 활용되고 있다. ECO2-OD는 한국의 기후 조건과 건축물 에너지 관련 기준을 반영한 준정상상태 기반 에너지 해석 프로그램으로, 신축 및 기축 건축물을 대상으로 단위면적당 1차 에너지 소요량을 산정하고 그린리모델링 전·후의 에너지 성능을 비교·평가하는데 활용된다(국토교통부, 2025).

그러나 ECO2-OD는 수십 개 이상의 상세 입력 변수를 요구하며, 이는 공공 및 민간 건축물 모두에서 데이터 확보의 어려움과 사용자의 높은 인지 부하로 이어진다는 한계가 지적되고 있다(서민정 외, 2025). 특히 민간 건축물의 경우 설계 및 시공 관련 자료의 체계적 관리가 이루어지지 않은 사례가 많아, 에너지 성능 평가 과정에서 입력값 불확실성이 더욱 크게 나타난다. 이러한 한계로 인해 물리 기반 시뮬레이션을 근사하면서도 입력 변수 부담을 완화할 수 있는 기계학습 기반 대리모델 개발의 필요성이 제기되고 있다(배민정 외, 2023; 이상엽·양재광, 2024).

2.2 기계학습 기반 대리모델 선행연구 검토

물리 기반 에너지 시뮬레이션은 높은 계산 비용과 다수의 상세 입력 변수를 요구하여, 반복적인 설계 검토나 초기 단계 의사결정 지원에 제약이 따른다(Westermann and Evins, 2019). 이에 최근 건축 에너지 분야에서는 기계학습을 활용하여 시뮬레이션 결과를 근사하는 대리모델 연구가 활발히 진행되고 있다. 선행연구들은 인공신경망, 랜덤 포레스트, 앙상블 학습 기법 등 다양한 알고리즘을 적용하여 건축물 에너지 성능 지표를 비교적 높은 정확도로 예측할 수 있음을 보고하였다(Seyedzadeh et al., 2018; Wei et al., 2018).

Table 1은 건축물 에너지 예측을 위한 기계학습 기반 대리모델 관련 주요 선행연구를 연구 대상 데이터, 적용 방법론, 그리고 한계 측면에서 정리한 것이다. 기존 연구의 상당수는 단일 또는 소수의 레퍼런스 건축물을 기준으로 가상 시뮬레이션 데이터를 생성하여 학습에 활용하였다(Joe et al., 2022; Zhang et al., 2015). 이러한 접근은 실제 그린리모델링 사업에서 나타나는 건축물 간 이질성과 입력 데이터의 불확실성을 충분히 반영하지 못한다는 한계를 지닌다. 또한 국내에서는 ECO2 또는 ECO2-OD를 활용한 실제 사례 분석이 일부 이루어졌으나(이상엽·양재광, 2024; 배민정 외, 2023), 물리 기반 평가 결과를 근사하기 위한 기계학습 대리모델을 구축하고 비교한 연구는 제한적이다. 나아가 실제 사업에서 중요하게 다루어지는 동일 건축물의 리모델링 전·후 에너지 성능 변화를 대리모델이 얼마나 일관되게 포착할 수 있는지에 대한 검토 역시 충분히 이루어지지 않았다. 이러한 점에서 연구 공백이 존재한다.

이에 본 연구에서는 실제 공공건축물 그린리모델링 사업 데이터를 바탕으로 기계학습 기반 대리모델의 알고리즘별 예측 성능을 비교한다. 아울러 대표 모델을 대상으로 리모델링 전·후 EUI 변화의 방향성을 포착할 수 있는지를 함께 검토함으로써, 실무

Table 1. Summary of Previous Studies on Machine Learning-Based Surrogate Models for Building Energy Prediction

Category	Study	Dataset	Methods / Models	Limitations
ML-Based Energy Prediction	Seyedzadeh et al. (2018)	Simulation-Based Datasets	Artificial Neural Networks, Support Vector Machines	Lack of Validation Using Real-World Project Data
Review of Data-Driven Approaches	Wei et al. (2018)	Literature Review	Comparative Analysis of Various ML Models	Limited Discussion on Practical Implementation
Early Simplified Modeling	Joe et al. (2022)	Single Reference Building	Simplified Physical Models	Inability to Represent Building Diversity
Inverse / Surrogate Modeling	Zhang et al. (2015)	Virtual Datasets Based on Reference Buildings	Inverse Modeling, Machine Learning	Heavy Reliance on Synthetic Simulation Data
Domestic Case Study (Public Buildings)	Lee and Yang (2024) (in Korean)	Real Public Buildings (Healthcare Centers)	ECO2 / ECO2-OD-Based Analysis	Surrogate Models Not Developed
Input Uncertainty Analysis	Bae et al. (2023) (in Korean)	Measured Data From Old Public Buildings	ECO2-based Energy Efficiency Evaluation	Machine Learning Not Applied
This Study	This Study	Real-World Green Remodeling Project Data	Comparative Evaluation of Multiple ML Surrogate Models	Identification of Optimal Surrogate Model

중심의 그린리모델링 의사결정 지원을 위한 기초 자료를 제시하고자 한다.

3. ECO2-OD 대리모델의 선정

3.1 데이터셋 구축 및 전처리

본 연구에서는 ECO2-OD 대리모델의 예측 성능을 검증하기 위해, 전국 단위의 실제 사업 기반 공공건축물 데이터를 활용하였다. 분석에 사용한 기초 자료는 2020년부터 2021년까지 수행된 「공공건축물 그린리모델링 지역거점 플랫폼 사업」에서 수집된 전국 1,016개 노유자시설의 에너지 소요량 평가서이다. 해당 데이터는 「건축물의 에너지절약설계기준」(국토교통부, 2023.2.28)에서 구분하는 국내 전 기후 권

역을 포함하고 있어, 건축물의 물리적 특성과 지역별 기후 조건이 에너지 성능에 미치는 영향을 함께 반영할 수 있다. 분석에 활용된 입력 변수는 특성 범주에 따라 구분하였으며, 그 구성은 Table 2에 제시하였다.

수집 자료에는 실제 사업 데이터의 특성상 일부 결측 및 불완전 사례가 포함되어 있어, 분석 목적에 맞추어 전처리를 수행하였다. 입력 변수의 결측치는 변수 간 관계를 반영할 수 있는 반복 대체법(iterative imputation)을 통해 보완하였다. 또한 에너지 소요량 평가 항목이 누락되었거나 리모델링 전·후 데이터 쌍이 완전하지 않은 사례를 식별하였으며, 이러한 사례는 전체의 약 10.9%에 해당하였다. 모델 학습 단계에서는 모델의 일반화 성능을 높이기 위해 가용한 데이터를 최대한 활용하되, 리모델링 전·후

Table 2. Model Input Features Used in This Study

Category	Input Features
Region	Region, Sub-region
Area	Gross floor area, Conditioned floor area, Gross floor area (above and below grade), External Wall Area, Gross window and door area, Total of top floor roof and ground floor
Geometry	Floor height, Ceiling height, Number of stories (above and below grade)
Average U-Value	Weighted Average U-Value, External wall, Windows and doors, Top floor roof, Ground floor
Heating Systems	Heating capacity, COP, Heating pump power, Electric heating capacity ratio, Heating system type
Cooling Systems	Cooling capacity, COP, Electric cooling capacity ratio, Chilled water circulation pump power, Condenser water circulation pump power, Cooling system type
Domestic Hot Water (DHW) Systems	DHW capacity, Water heater efficiency, DHW pump power, Electric DHW capacity ratio, DHW system type
Air Handling Units	Supply air flow rate, Exhaust air flow rate, Supply air fan capacity, Exhaust air fan capacity, Supply air fan power, Exhaust fan power, Heating heat recovery efficiency, Cooling heat recovery efficiency
Lighting Systems	Luminaire type, LED power, Habitable room power, Habitable room area, Lighting power density
Renewable Energy Systems	Module type, Module area, Module tilt angle, Module orientation

Note: The target variable is the annual energy use intensity (kWh/m²·year).

성능 변화 비교가 필요한 분석에서는 전·후 데이터 쌍이 모두 확보된 건축물만을 사용하였다.

종속 변수의 분포는 낮은 값에 관측치가 밀집하고 일부 큰 값이 나타나는 양의 왜도(right-skewed) 양상을 보였다. 이에 따라 학습 단계에서는 종속 변수에 로그 변환을 적용하였다. 이는 분포의 왜도를 완화하고 극단값의 영향을 줄여 모델 학습의 안정성을 높이기 위한 조치이다. 최종 성능 평가는 해석의 직관성을 위해 지수 변환을 통해 원래의 물리량 스케일로 복원한 값을 기준으로 수행하였다.

3.2 실험 설계 및 평가 지표

본 연구는 특정 시점의 건축물 상태 정보를 입력받아 해당 시점의 EUI를 예측하는 상태 기반 학습(state-based learning) 방식을 채택하였다. 리모델링

전·후는 각각 서로 다른 상태로 간주하여 독립적으로 모델에 입력하였으며, 모델은 각 상태에 대한 EUI를 개별적으로 예측한다. 따라서 본 연구의 1차 평가 대상은 상태별 EUI 예측 정확도이다. 다만, 전·후 상태 정보가 모두 확보된 사례에 대해서는 예측된 EUI의 차이를 이용하여 리모델링에 따른 절감량 변화를 보조적으로 검토하였다.

데이터 분할 과정에서는 학습 세트와 테스트 세트를 8:2 비율로 구성하였으며, 동일 건축물에서 파생된 리모델링 전·후 자료가 서로 다른 세트에 동시에 포함되지 않도록 건물 단위의 그룹 분할을 적용하였다. 이는 동일 건물의 유사한 정보가 학습 세트와 테스트 세트에 함께 포함될 때 발생할 수 있는 데이터 누수 문제를 방지하기 위한 것이다. 아울러 종속 변수 분포의 불균형을 완화하기 위해, EUI 분포가 학습

세트와 테스트 세트에 유사하게 반영되도록 층화 무작위 추출을 적용하였다. 이를 통해 테스트 세트가 전체 데이터의 분포를 가능한 한 고르게 반영하면서도, 학습에 포함되지 않은 건물에 대한 일반화 성능을 객관적으로 평가할 수 있도록 구성하였다.

모델 성능 평가는 평균 제곱근 오차(RMSE), 평균 절대 오차(MAE), 결정계수(R^2)를 기본 지표로 사용하였다. RMSE와 MAE는 예측 오차의 크기를 정량적으로 평가하기 위한 지표이며, R^2 는 모델의 설명력을 파악하기 위한 지표이다. 또한 도메인 관점의 참고 지표로 ASHRAE Guideline 14(ASHRAE, 2014)에서 제시하는 변동계수(CV(RMSE))와 정규화된 평균 편향 오차(NMBE)를 함께 산출하였다. 다만 ASHRAE Guideline 14는 본래 단일 건물의 시뮬레이션 보정(calibration)을 위한 기준이므로, 본 연구에서는 이를 모델의 편향성과 오차 수준을 보조적으로 점검하기 위한 참고 지표로 활용하였다.

3.3 후보 모델 구성 및 선정 기준

후보 모델은 선형 모델, 트리 기반 모델, 정형 데이터 특화 딥러닝 모델을 포함하도록 구성하였다. 구체적으로 선형 모델은 Lasso와 Ridge, 트리 기반 모델은 Random Forest(Breiman, 2001), XGBoost(Chen and Guestrin, 2016), CatBoost(Prokhorenkova et al., 2018), LightGBM(Ke et al., 2017), 정형 데이터 특화 딥러닝 모델은 TabNet(Arik and Pfister, 2021)과 FT-Transformer(Gorishniy et al., 2021)이다. 모든 후보 모델에는 동일한 입력 변수 집합과 공통 전처리 파이프라인을 적용하여 입력 조건을 통일하였으며, 모델 구조에 따른 예측 성능 차이를 비교하기 위해 동일한 테스트 세트와 단일 시드 조건에서 후보 모델 비교를 수행하였다. 최종 모델 선정은 상태별 예측 오차, 설명력, 편향을 종합적으로 고려하여 이루어졌으며, 후보 모델 비교 결과는 제4장에서 제시한다.

4. 대리모델의 성능 검토

4.1 후보 모델 성능 비교

후보 모델 비교 결과, 알고리즘 계열에 따라 예측 성능의 차이가 확인되었다. Table 3에 따르면, 개별 건축물의 EUI 예측에서는 트리 기반 모델인 LightGBM과 CatBoost가 전반적으로 우수한 성능을 보인 반면, Random Forest와 XGBoost는 상대적으로 다소 낮은 성능을 나타냈다. 반면 NMBE 측면에서는 선형 모델인 Ridge와 딥러닝 계열 모델인 TabNet과 FT-Transformer이 상대적으로 낮은 편향을 보였다. 그러나 본 연구의 1차 목적은 개별 건축물 상태에 대한 EUI 예측 정확도를 확보하는 데 있으므로, RMSE, MAE, R^2 를 중심으로 대표 모델 후보를 선정하였다. 이에 따라 기본 오차 지표 전반에서 우수한 성능을 보인 CatBoost와 LightGBM을 최종 하이퍼파라미터 최적화 대상으로 선정하였다.

4.2 최종 모델의 성능 안정성

CatBoost와 LightGBM에 대해서 시드 42에서 Optuna 기반 하이퍼파라미터 최적화를 먼저 수행한 뒤, 도출된 최적 설정을 고정하여 다중 시드 평가(4, 42, 213, 666, 999)를 실시하였다. Table 4에 따르면, CatBoost는 평균 RMSE 34.11, MAE 23.57, R^2 0.78을 기록하였으며, 표준편차는 각각 3.32, 1.53, 0.03으로 나타났다. LightGBM은 평균 RMSE 34.75, MAE 23.94, R^2 0.77을 기록하였고, 표준편차는 각각 3.53, 1.73, 0.04였다. 두 모델 모두 다중 시드 평가에서 안정적인 결과를 유지하였으나, 평균 성능 기준에서는 CatBoost가 LightGBM보다 근소하게 우수하였다.

ASHRAE Guideline 14 지표를 참고적으로 살펴본 결과, CatBoost의 평균 CV(RMSE)는 19.01%, 평균 NMBE는 1.03%였으며, LightGBM은 각각 19.36%, 1.06%로 나타났다. 두 모델 모두 평균 편향은 낮은

Table 3. Performance Comparison of Various Baseline Models Categorized by Architecture (Linear-Based, Tree-Based, and Neural-Based)

Model	RMSE	MAE	R ²	CV(RMSE)	NMBE	
Linear-based	Lasso	41.8674	29.7312	0.6582	23.4763	1.0226
	Ridge	43.9561	30.5907	0.6232	24.6474	<u>0.3736</u>
Tree-based	Random Forest	38.0007	27.4563	0.7184	21.3081	1.1960
	XGBoost	38.7968	27.2673	0.7065	21.7545	5.0287
	CatBoost	35.5383	25.5278	0.7537	19.9274	0.8665
	LightGBM	<u>37.1922</u>	<u>26.3772</u>	<u>0.7302</u>	<u>20.8548</u>	1.7534
Neural-based	TabNet	40.4622	29.1117	0.6807	22.6883	0.1927
	FT-Transformer	38.4213	27.4400	0.7121	21.5439	0.5858

Note 1: RMSE and MAE Are Reported in kWh/m²·year, and CV(RMSE) and NMBE Are Reported as Percentages (%)
 Note 2: All models were trained and evaluated under identical preprocessing conditions to ensure a fair comparison.
 The best-performing results are highlighted in **bold**, and the second-best results are underlined.

Table 4. Multi-Seed Evaluation Results for the Top-Performing Models Identified in Table 3 Following Hyperparameter Tuning

Model	RMSE	MAE	R ²	CV(RMSE)	NMBE
CatBoost	34.1131±3.32	23.5668±1.53	0.7811±0.03	19.0092±1.79	1.0333±0.90
LightGBM	34.7504±3.53	23.9439±1.73	0.7728±0.04	19.3640±1.90	1.0577±0.62

Note 1: RMSE and MAE Are Reported in kWh/m²·year, and CV(RMSE) and NMBE Are Reported as Percentages (%)
 Note 2: Hyperparameters were optimized using a representative seed and subsequently applied to five independent runs. The values represent the mean and standard deviation ($\mu \pm \sigma$).

수준을 유지하였고, 특히 NMBE는 1% 내외로 나타나 특정 방향으로의 과대 또는 과소 예측이 크지 않음을 보여주었다. 종합하면, 두 모델이 전반적으로 우수한 성능을 보였으며, 그중 CatBoost가 기본 오차 지표와 다중 시드 안정성 양면에서 가장 균형 잡힌 결과를 나타냈다. 이에 본 연구에서는 CatBoost를 최종 대표 모델로 선정하였다.

4.3 건물 및 지역 단위 예측 양상

전체 수준의 예측 성능과 안정성을 확인한 후, 평균 지표만으로는 파악하기 어려운 건물 및 지역 단위의 예측 양상을 추가로 검토하였다. 이하의 분석 역시 앞선 성능평가와 동일하게 테스트 세트에 해당하는 사례만을 대상으로 한다. 다만 실제 사업 데이터의 특성상 EUI 분포가 특정 구간에 편중되어 있고

지역별 표본 수에도 차이가 있다는 점을 고려하여 해석할 필요가 있다. 먼저 건물 수준에서 리모델링 전·후 EUI 변화 재현 정도를 살펴보았다. Fig. 2에 따르면, 테스트 세트에서 실제 절감량과 예측 절감량 사이에는 높은 상관관계($r = 0.90$)가 나타났으며, 리모델링 전 EUI 분포를 30개 구간으로 나누어 각 구간에서 대표 건물을 무작위 추출하여 시각적으로 비교한 결과에서도 다수의 건물에서 리모델링 이후 EUI 감소 경향이 실제와 부합하였다.

지역 단위에서는 전·후 데이터 쌍이 확보된 건축물 163개를 대상으로 지역별 평균 EUI 절감량의 실제값과 예측값을 비교하였다. Fig. 3에 따르면, 표본 수가 상대적으로 충분한 서울($n=34$), 강원($n=31$), 전남($n=22$), 경기($n=19$)에서는 실제값과 예측값이 전반적으로 유사한 경향을 보였다.

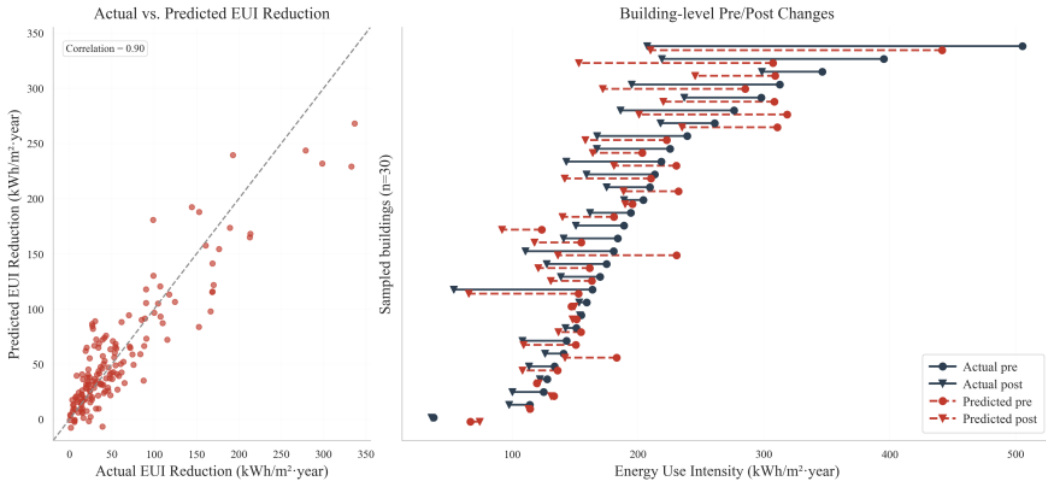


Fig. 2. Building-Level Comparison of Actual and Predicted EUI Reduction due to Green Remodeling (The Left Panel Shows Actual Versus Predicted EUI Reduction for All Buildings in the Test Set, While the Right Panel Shows Pre- and Post-Remodeling EUI Values for 30 Sampled Buildings Spanning a Broad Range of Pre-Remodeling EUI Levels)




Fig. 3. Regional Comparison of Actual and Predicted Mean EUI Reduction for Buildings with Paired Pre- and Post-Remodeling Data (Regions Are Ordered by Sample Size, and the Absolute Difference between Actual and Predicted Mean Reduction Is Annotated for Each Region)

5. 논 의

본 연구의 결과는 실제 공공건축물 그린리모델링 데이터에 기반한 ECO2-OD 대리모델 구축에서 트리 기반 모델이 상대적으로 적합한 선택지임을 보여준

다. CatBoost와 LightGBM은 선형 모델 및 정형 데이터 특화 딥러닝 모델보다 전반적으로 우수한 성능을 보였으며, 최종적으로는 CatBoost가 예측 오차, 설명력, 편향, 반복 안정성의 균형 측면에서 가장 적합한 대표 모델로 선정되었다. 이는 건축물 에너지 성

능이 외피, 설비, 지역 기후 등 다양한 변수의 비선형적 상호작용에 의해 결정된다는 점에서, 트리 기반 모델이 이러한 관계를 효과적으로 학습했기 때문으로 해석할 수 있다. 반면 일부 선형 또는 딥러닝 모델은 평균 편향 측면에서 양호한 결과를 보였으나, 개별 사례 수준의 예측 정확도에서는 상대적으로 한계를 보였다. 이는 대리모델 선정 시 단일 지표에 의해 결정되어서는 안 되며, 오차, 설명력, 편향, 그리고 반복 실험에서의 일관성을 함께 고려해야 함을 시사한다.

본 연구에서 확인된 CatBoost의 성능은 실제 그린 리모델링 사업 데이터를 활용한 ECO2-OD 대리모델 구축의 가능성을 실증적으로 보여준다는 점에서 의미가 있다. 본 연구의 데이터는 전국 단위의 서로 다른 공공건축물로부터 수집되었으며, 건축물 간 물리적 이질성, 입력 정보의 불완전성, 지역별 조건 차이를 포함한다. 이러한 조건에서도 CatBoost는 다중 시드 평가에서 R^2 0.78, CV(RMSE) 19%, NMBE 1% 수준의 안정적인 성능을 보였으며, 이는 기존의 통제된 시뮬레이션 기반 연구와 달리 실제 사업 환경의 불확실성을 반영한 조건에서 달성된 결과라는 점에서 주목할 필요가 있다. 특히 NMBE가 1% 수준으로 나타난 것은 대표 모델의 예측이 특정 방향으로 크게 치우치지 않았음을 보여주며, CV(RMSE)는 본 연구와 같은 다건물 예측 환경에서 오차 규모를 해석하는 보조 지표로 활용될 수 있다.

대표 모델에 대한 건물 단위 분석 결과, 리모델링 전·후 EUI 변화의 방향성은 대체로 포착되었다. 실제 절감량과 예측 절감량 사이에 높은 상관성이 나타났고, 다수의 건물에서 리모델링 이후 EUI 감소 경향이 실제와 유사하게 재현되었다. 다만 일부 사례에서는 실측값과 예측값 사이에 차이가 관찰되었으며, 이는 특정 EUI 구간에 국한된 현상이라기보다 입력 정보의 구조화 수준이 사례별로 상이한 데서 비롯된 것으로 판단된다. 이러한 개별 사례 수준의 오차 특

성에 대한 체계적 분류는 후속 연구 과제로 남긴다. 본 연구의 데이터는 기존의 단일 건물 또는 레퍼런스 모델 기반 연구와 달리 다수의 실제 공공건축물을 포함하여 건축물 간 이질성을 분석 대상에 반영하였으며, 이러한 조건에서도 대표 모델이 전·후 변화의 방향성과 상대적 크기를 포착할 수 있었다는 점에서 의의가 있다. 지역 단위 분석에서도 시·도 및 군 단위 지역 변수를 모델 입력에 반영하여 다지역 비교를 수행하였으며, 표본 수가 충분한 지역에서는 실제값과 예측값 간 차이가 크지 않았다. 다만 보다 세분화된 수준의 적용을 위해서는 추가 데이터 확보와 지역 조건에 대한 보완적 검증이 필요하다.

본 연구에는 몇 가지 한계가 존재한다. 첫째, 예측 대상은 실제 운영 에너지 사용량이 아니라 ECO2-OD를 통해 산정된 EUI이므로, 재실자 행태나 운영 스케줄과 같은 운용 단계 변동성은 직접 반영되지 않았다. 둘째, 실제 사업 과정에서 축적된 데이터의 특성상 일부 설비 성능, 시스템 용량, 리모델링 공법 정보가 충분히 구조화되지 않았으며, 이러한 입력 수준의 편차가 일부 사례에서 예측 오차를 확대시키는 요인으로 작용하였을 수 있다. 셋째, 전·후 데이터 쌍과 지역별 표본 수가 균형적이지 않아, 절감량 및 지역 평균 비교 결과의 안정성에 한계가 존재하였다. 따라서 향후 연구에서는 상세한 설비 및 공법 변수를 포함하고, 균형 잡힌 표본 구성을 확보함으로써 대리모델의 설명력과 적용 가능성을 함께 높일 필요가 있다.

6. 결론

본 연구는 실제 공공건축물 그린리모델링 사업 데이터를 활용하여, ECO2-OD가 산정한 EUI를 근사하는 기계학습 기반 대리모델의 알고리즘 성능을 비교·평가하였다. 다양한 후보 모델을 동일한 입력 조건과 평가 체계에서 검토한 결과, 트리 기반 계열

모델이 전반적으로 우수한 성능을 보였으며, 그중 CatBoost가 예측 정확도와 반복 안정성의 균형 측면에서 가장 적합한 대표 알고리즘으로 선정되었다.

본 연구의 기여는 다음과 같이 정리할 수 있다. 첫째, 실제 공공건축물 그린리모델링 사업 데이터를 활용하여 다양한 기계학습 알고리즘을 동일한 입력 조건과 평가 체계에서 비교함으로써, ECO2-OD 대리모델 구축에 적합한 알고리즘 선택의 실증적 기준선을 제시하였다. 둘째, 상대 기반 EUI 예측뿐 아니라 동일 건축물의 리모델링 전·후 변화 양상을 함께 검토함으로써, 대표 모델의 초기 의사결정 지원 관점에서의 활용 가능성을 확인하였다. 셋째, 이러한 비교 결과를 바탕으로 향후 입력 변수를 최소화한 경량화 대리모델 개발을 위한 기초 자료를 제공하였다.

이러한 점에서 본 연구는 경량화 대리모델 개발을 위한 선행 기초 연구로서의 의의를 지닌다. 향후 연구에서는 본 연구에서 도출된 CatBoost 기반 대리모델을 바탕으로, 설명 가능한 인공지능(XAI)을 활용한 입력 변수 중요도 분석과 민감도 분석을 수행하여 사용자의 입력 부담을 최소화한 경량화 대리모델을 탐구하고자 한다. 이는 데이터 확보가 어려운 건축물 환경에서도 신속하고 신뢰도 높은 에너지 성능 예측을 가능하게 함으로써 그린리모델링 활성화에 기여할 수 있을 것으로 기대된다.

참고문헌

- 강찬혁·박창영·권영철·최창호(2024), “개구부 요소의 시험성적서 반영 여부가 그린리모델링의 에너지 성능 평가에 미치는 영향”, 『한국건축친환경설비학회 논문집』, 18(4): 292~301.
- 국토교통부(2023.2.28), “건축물의 에너지절약설계 기준” 제2023-104호.
- 국토교통부(2025), 「공공건축물 그린리모델링 사업 가이드라인」, 세종.
- 권영철(2023), 「건축물에너지평가사 필기시리즈② 건축환경계획」, 서울: 한솔아카데미.
- 문보람·박성남·권혜인·손동욱·정유미·장경은·김소연(2023), “민간건축물 그린리모델링 사업 활성화를 위한 제도 개선방안 연구”, 『대한건축학회논문집』, 39(4): 199~210.
- 박성남·문보람·권혜인·김성준(2022), 「민간 건축물 그린리모델링 활성화 방안」, 세종: 건축공간연구원.
- 배민정·안호상·강재식(2023), “노후 공공건축물의 현장 조사 결과에 따른 에너지효율등급 평가 결과 분석”, 『한국태양에너지학회 논문집』, 43(6): 39~49.
Bae, M. J., H. S. Ahn and J. S. Kang (2023), “Analysis of Energy Efficiency Rating Evaluation Results According to Field Survey Results of Old Public Buildings”, *Journal of the Korean Solar Energy Society*, 43(6): 39~49 (in Korean).
- 서민정·박창영·양창윤·정보경·권영철·최창호(2025), “그린리모델링 건축물 정보 공유 및 에너지 소요량 분석 지원을 위한 정보 체계 구축 방안 연구”, 『한국건축친환경설비학회 논문집』, 19(6): 297~310.
- 심성진·임세현·김성은·송용우(2024), “노후 공공도서관의 그린리모델링 적용 요소 조합에 따른 우선순위 도출”, 『토지주택연구』, 15(2): 1~7.
- 이상엽·양재광(2024), “공공건축물(보건소) 대상으로 한 그린리모델링 적용 건축물의 에너지 성능 분석”, 『한국건축친환경설비학회 논문집』, 18(6): 551~563.
Lee, S. Y. and J. G. Yang (2024), “Energy Performance Analysis of Green-Remodeled Public Buildings: A Case Study of Public Health Centers”, *Journal of Korean Institute of Architectural Sustainable Environment and Building Systems*, 18(6): 551~563 (in Korean).
- 임세현·김준규·송용우(2026), “그린리모델링 건축물의 에너지비용 시나리오에 따른 LCC 예측 및 분석: 공공어린이집을 대상으로”, 『토지주택연구』, 17(1): 137~146.
- Arik, S. O. and T. Pfister (2021), “TabNet: Attentive Interpretable Tabular Learning”, *Proceedings of the AAAI Conference on Artificial Intelligence*, 35(8): 6679~6687.
- ASHRAE (2014), *ASHRAE Guideline 14-2014: Measurement of Energy, Demand, and Water Savings*,

- Peachtree Corners: American Society of Heating, Refrigerating and Air-Conditioning Engineers.
14. Breiman, L. (2001), "Random Forests", *Machine Learning*, 45(1): 5~32.
 15. Chen, T. and C. Guestrin (2016), "XGBoost: A Scalable Tree Boosting System", *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785~794.
 16. Gorishniy, Y., I. Rubachev, V. Khurlov and A. Babenko (2021), "Revisiting Deep Learning Models for Tabular Data", *Advances in Neural Information Processing Systems*, 34: 18932~18943.
 17. Joe, J., S. Min, S. Oh, B. Jung, Y. M. Kim, D. W. Kim, S. E. Lee and D. H. Yi (2022), "Development of Simplified Building Energy Prediction Model to Support Policymaking in South Korea: Case Study for Office Buildings", *Sustainability*, 14(10): 6000.
 18. Ke, G., Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye and T.-Y. Liu (2017), "LightGBM: A Highly Efficient Gradient Boosting Decision Tree", *Advances in Neural Information Processing Systems*, 30: 1~9.
 19. Prokhorenkova, L., G. Gusev, A. Vorobev, A. V. Drogush and A. Gulin (2018), "CatBoost: Unbiased Boosting with Categorical Features", *Advances in Neural Information Processing Systems*, 31: 1~11.
 20. Seyedzadeh, S., F. Rahimian, I. Glesk and M. Roper (2018), "Machine Learning for Estimation of Building Energy Consumption and Performance: A Review", *Visualization in Engineering*, 6(1): 5.
 21. Wei, Y., X. Zhang, Y. Shi, L. Xia, S. Pan, J. Wu and M. Han (2018), "A Review of Data-Driven Approaches for Prediction and Classification of Building Energy Consumption", *Renewable and Sustainable Energy Reviews*, 82: 1027~1047.
 22. Westermann, P. and R. Evins (2019), "Surrogate Modelling for Sustainable Building Design: A Review", *Energy and Buildings*, 198: 170~186.
 23. Zhang, Y., Z. O'Neill, B. Dong and G. Augenbroe (2015), "Comparisons of Inverse Modeling Approaches for Predicting Building Energy Performance", *Building and Environment*, 86: 177~190.

요약

탄소중립 정책 기조에 따라 노후 공공건축물의 에너지 성능 개선을 위한 그린리모델링의 중요성이 확대되고 있다. 그러나 국내 실무에서 활용되는 ECO2-OD 기반 에너지 성능 평가는 많은 입력 변수를 요구하므로, 데이터 수집 부담과 입력 과정의 높은 복잡성으로 인해 초기 단계에서 다양한 대안을 신속하게 비교·검토하는 데 한계가 있다. 이에 본 연구는 2020~2021년 공공건축물 그린리모델링 지역거점 플랫폼 사업을 통해 수집된 실제 공공 노유자시설 데이터를 활용하여, 연간 단위면적당 에너지 소요량(EUI)을 근사하는 기계학습 기반 대리모델의 알고리즘 성능을 비교·평가하였다. 선형 모델, 트리 기반 모델, 정형 데이터 특화 딥러닝 모델을 동일한 조건에서 비교한 결과, 트리 기반 계열이 전반적으로 우수한 성능을 보였으며, 하이퍼파라미터 최적화와 다중 시드 평가를 거친 CatBoost가 예측 정확도와 반복 안정성 측면에서 최종 대표 알고리즘으로 선정되었다. 또한 선정된 모델을 대상으로 리모델링 전·후 EUI 변화 양상을 보조적으로 검토한 결과, 에너지 성능 변화의 방향성을 대체로 일관되게 포착하는 것으로 나타났다. 본 연구는 실제 사업 데이터를 바탕으로 대리모델 구축에 적합한 알고리즘 선택 기준을 제시하였으며, 향후 입력 부담을 줄인 경량화 대리모델 개발의 기초 자료로 활용될 수 있다.

주제어: 그린리모델링, ECO2-OD, EUI, 기계학습, 순환경제