

XGBoost 기반 전기차 충전소 설치 예측에 따른 우선 설치 지역 분석

임소민*, 서지훈**

Priority Area Analysis for EV Charger Deployment based on XGBoost Prediction

So-min Yim*, Ji-Hoon Seo**

요약

본 연구는 서울시 25개 자치구를 대상으로 전기차 충전 인프라의 적정 공급 규모를 산정하고 지역별 확충 우선순위를 제시하기 위해 XGBoost 기반 OOF 예측 모델을 적용하였다. 예측값과 실제 설치량의 차이를 활용하여 부족 수준을 평가하고, 부족률·전기차 등록대수·인구 규모를 반영한 정책 우선순위 점수를 산출하였다. 또한 K-means 군집화를 통해 자치구를 세 유형으로 분류함으로써 지역 특성을 고려한 차등적 충전 전략의 근거를 마련하였다. 분석 결과 강북구·관악구·구로구는 단기적 확충이 요구되는 지역으로 나타났으며, 강남구·서초구·송파구는 운영 효율화 중심 접근이 적합한 것으로 확인되었다. 본 연구는 예측 기반 평가와 군집 분석을 결합해 전기차 충전 인프라 정책 수립을 위한 실증적 기초 자료를 제공한다.

Abstract

This study applies an Out-of-Fold (OOF) XGBoost regression model to analyze the supply - demand balance of Electric Vehicle (EV) charging infrastructure across 25 districts in Seoul. By comparing predicted charger counts with existing installations, shortage levels are assessed, and a policy priority score integrating shortage rate, EV registrations, and population size is derived. K-means clustering further classifies districts into three types, supporting differentiated planning strategies. The results show that Gangbuk-gu, Gwanak-gu, and Guro-gu require short-term expansion, while Gangnam-gu, Seocho-gu, and Songpa-gu better suited to operational optimization strategies. Combining predictive modeling with spatial clustering, this study provides a practical framework for identifying priority areas and guiding efficient EV charging infrastructure policies.

Keywords

EV charging infrastructure, XGBoost, policy priority analysis, K-means clustering; urban mobility planning

* 강남대학교 데이터사이언스학과 학사과정
- ORCID: <https://orcid.org/0009-0007-7642-2508>
** 강남대학교 데이터사이언스학과 교수(교신저자)
- ORCID: <https://orcid.org/0009-0000-2988-926X>

· Received: Nov. 25, 2025, Revised: Dec. 24, 2025, Accepted: Dec. 27, 2025
· Corresponding Author: Ji-Hoon Seo
Dept. of Data Science, Kangnam University
40, Gangnam-ro, Giheung-gu, Yongin-si, Gyeonggi-do, Korea
Tel.: +82-31-280-3721, Email: jihoon@kangnam.ac.kr

I. 서론

탄소중립과 기후변화 대응이 글로벌 주요 의제로 부상함에 따라, 전 세계적으로 내연기관차 중심의 자동차 산업이 전기차(EV) 중심으로 빠르게 전환되고 있다. 국제에너지기구(IEA)는 2035년 판매되는 자동차의 약 3분의 2가 전기차가 될 것으로 전망하며, 이는 각국의 에너지 및 기후 공약 이행을 전제로 한다고 밝혔다[1]. 이에 발맞춰 국내에서도 공공기관 차량의 전기차 전환과 충전 인프라 확충 정책이 추진되고 있으며, 민간 부문에서도 기업 보유 차량을 전기차로 전환하려는 움직임이 확산하고 있다[2].

이와 같은 전기차 보급 확대에도 불구하고 충전 인프라의 부족과 지역 간 불균형 문제는 여전히 전기차 확산의 주요 제약 요인으로 지적된다. 선행 연구에서는 전기차 등록 대수와 충전기 수 간의 높은 상관성이 확인되었으며, 충전 인프라의 밀도가 전기차 보급률 증가에 직접적인 영향을 미치는 것으로 분석되었다[3]. 이러한 연구 결과는 충전 인프라와 보급률 간의 상호 의존적 관계를 보여주며, 효율적인 인프라 구축과 정책적 우선순위 설정의 필요성을 뒷받침한다.

최근에는 전기차 충전소의 위치 선정과 수요 예측에 머신러닝 기반 접근을 적용하는 사례가 확대되고 있다. 여러 연구에서는 공간적 요인과 도시 구조를 반영한 예측 모델을 활용함으로써, 기존의 단순 거리 기반 분석에 비해 더 높은 설명력을 확보할 수 있음을 보고하였다. 또한 수요 특성과 지역별 공급 격차를 고려한 입지 선정 모델이 제안되고 있다[4].

또한 전기차 충전소 입지를 설명하는 요인을 보다 정교하게 파악하기 위해 도시 활동 패턴과 공간적 상관성을 함께 고려한 분석도 제시되고 있다. 일부 연구에서는 인구 밀도, 도로 구조, 상업·주거 활동과 같은 다양한 공간 요인이 충전 수요 형성에 유의미한 영향을 미친다는 점을 확인하였다. 또한 이러한 공간 기반 접근이 복잡한 비선형 관계를 해석하는 데 효과적임을 보고하고 있다[5].

기존 연구들은 충전소의 위치 선정이나 설치 효율성 검토에 초점을 맞춘 경우가 많았으나, 충전소

수요의 정량적 예측과 정책적 우선순위 도출에 관한 연구는 상대적으로 미흡하다. 특히 도시별 특성과 전기차 이용 행태를 함께 고려한 예측 기반 접근은 정책적 판단의 객관성을 높이는 데 이바지할 수 있다. 이러한 배경에서 본 연구는 서울시 25개 자치구를 대상으로 XGBoost 회귀모델을 활용해 전기차 충전소 설치 수를 예측하고, Ridge 및 랜덤 포레스트 모델과의 성능을 비교하였다. 예측값과 실제 충전소 수의 차이를 바탕으로 정책 우선순위를 산정하고 이를 시각화하여, 지역 간 인프라 불균형을 진단하고 효율적인 충전소 구축 전략 수립을 위한 기초 자료를 제시하고자 한다.

II. 관련 연구

2.1 머신러닝 기반 전기차 충전 인프라 수요 예측

선행 연구에서는 전기차 충전소의 입지 선정과 수요 예측을 위해 머신러닝 기법을 활용한 다양한 접근이 제시되었다. 한편, 충전 인프라 수요에 영향을 미치는 요인을 체계적으로 도출한 뒤, 이를 기반으로 입지 적합성을 평가하는 연구도 제시된 바 있다. 이 접근은 인구 특성, 건축·이용 패턴, 주변 활동 밀도 등 여러 공간 요인을 통합하여 수요 수준을 추정하고, 가중치 적용과 공간분석을 통해 설치 우선 지역을 도출한다는 점에서 의의가 있다[6]. 또한 실제 충전 데이터를 기반으로 한 머신러닝 예측 연구가 체계적으로 검토되며, 통계·모형 중심 접근의 한계를 보완하는 방향이 제시되고 있다. 해당 분석에서는 심층학습, 공간-시간 결합 모델 등 다양한 기법의 적용성과 성능을 비교하였으며, 전기차 충전 패턴의 복잡성과 지역 간 이질성을 반영하기 위해 학습 기반 방법이 특히 효과적인 것으로 확인되었다. 더하여 장기 예측, 지역 일반화, 실시간 데이터 활용 등이 향후 중요한 연구 과제로 지적된다[7]. 이러한 연구들은 충전 인프라의 공급 효율성을 높이기 위해 예측 모델을 활용하는 방법론적 기반을 제공하며, 본 연구의 전기차 충전소 정책 우선순위 분석에 이론적 토대를 마련한다.

2.2 앙상블 및 부스팅 기법을 활용한 예측 모델

앙상블(Ensemble) 학습은 다수의 약한 학습기(Weak learner)를 결합하여 단일 모델보다 높은 예측 성능을 확보하는 기법으로, 모델의 안정성과 일반화 능력을 동시에 향상한다. 이러한 방법의 하나인 부스팅(Boosting)은 개별 학습기의 예측 오차를 반복적으로 보정하면서 전체 모델의 정확도를 점진적으로 향상하는 알고리즘이다.

대표적인 부스팅 기법인 XGBoost는 의사결정나무를 기반으로 한 회귀 및 분류 예측 모델로, 다수의 회귀나무를 순차적으로 결합하여 오차를 최소화한다. 초기 모델이 예측하지 못한 부분을 다음 단계의 모델이 학습하면서, 각 단계의 결과를 누적적으로 개선해 나가는 방식으로 작동한다.

또한 XGBoost는 기존 그래디언트 부스팅 기법에 L1·L2 정규화를 추가하여 과적합을 방지하고, 학습률을 조정해 모델의 안정성을 확보한다. 더불어 병렬 학습을 지원함으로써 대규모 데이터의 학습 효율성을 높이고, 하이퍼파라미터 최적화에 따라 다양한 환경에서 유연하게 적용될 수 있다. 이러한 특성 덕분에 XGBoost는 예측 정확도와 연산 효율성이 요구되는 회귀 기반 분석에서 특히 효과적인 알고리즘으로 평가된다[8]. 특히 실사용 데이터 기반 비교연구에서 XGBoost는 다른 회귀 기법 대비 일관된 성능 우위를 보인 바 있다[9].

2.3 정책 우선순위 분석을 위한 정량적 모델링 접근

전기차 충전 인프라 확충 과정에서 핵심적인 과제는 한정된 자원하에서 설치 우선순위를 과학적으로 산정하는 것이다. 정책적 판단이 정성적 기준에 의존할 경우 지역 간 편차가 심화될 수 있으므로, 최근에는 머신러닝 기반의 정량 분석을 활용한 의사결정 체계가 주목받고 있다.

정책 우선순위 분석은 예측된 충전 수요와 실제 공급 간의 격차를 기반으로, 인구, 차량 보급률, 접근성 등 다양한 변수들을 통합하여 지역별 설치 필요성을 수치화하는 과정이다. 이러한 접근은 데이터

의 다차원적 특성을 반영하고, 예측 결과에 따른 자원 배분의 효율성을 극대화할 수 있다는 점에서 의미가 크다.

머신러닝을 활용한 인프라 계획 관련 연구에서는 충전소 배치, 충전 수요 예측, 충전 일정 조정 등 여러 의사결정 요소를 정량적으로 다루는 접근이 제시되고 있다. 해당 연구는 충전 수요의 변동성과 운행 행태의 불확실성을 고려하기 위해 다양한 머신러닝 기법을 비교하고, 실제 데이터 기반 분석이 충전 거점 탐색과 수요 패턴 파악에 효과적임을 보고한다. 또한 충전소 배치 사례를 통해 충전 수요 예측과 위치 선정이 상호 연계된 계획 문제임을 보여주며, 머신러닝 기반 분석이 지역별 설치 필요도를 구조적으로 평가하는 데 활용될 수 있음을 제시하였다. 이러한 결과는 인프라 확충 과정에서 데이터 기반 기준을 마련하기 위한 정량적 모델링의 유용성을 뒷받침한다[10]. 특히 공간적 특성과 지역 간 수요 격차를 반영해 충전소 배치를 최적화한 국제 연구에서도 정량 기반 접근의 중요성이 강조된 바 있다[11]. 이는 본 연구에서 수행한 부족률·전기차 보급 규모에 기반한 정책 우선순위 산정과 방향성을 공유한다. 또한 자치구별 충전 인프라를 군집화해 공급 취약지역을 식별한 연구도 보고된 바 있다. 핵심 변수로 지역을 유형화해 수요 구조를 비교한 결과, 충전소 배치의 불균형을 정량적으로 확인할 수 있었고, 이를 통해 단계적 확충 방향을 도출하는 방식이 제시되었다.

III. 연구 방법 및 분석 결과

3.1 데이터 구성 및 변수 정의

본 연구에서는 서울특별시 25개 자치구를 분석 단위로 하여 전기차 충전 인프라의 지역별 분포와 수요 예측을 수행하였다. 데이터는 공공데이터포털과 서울 열린데이터광장에서 제공하는 행정통계 및 인프라 현황 자료를 활용하였다[12][13]. 표 1은 종속변수인 자치구별 충전소 개수와 독립변수(전기차 수, 인구 수, 주차면 수, 도로 연장, 월평균 소득, 버스노선 수)의 구성을 요약한다.

표 1. 분석에 사용된 변수 정의

Table 1. Definition of variables used in the analysis

Dependent variable	Number of EV chargers
Independent variables	Number of EVs, population, parking spaces, road length (m), average income, number of bus routes

선정된 변수들은 전기차 이용 규모, 잠재 수요, 설치 가능 물리적 여건, 지역의 경제적 특성, 대중교통 접근성을 종합적으로 반영한다. 이를 통해 단일 지표에 의존하지 않고 자치구별 전기차 이용 환경과 인프라 특성을 입체적으로 분석하며, 군집 간 차이를 정책적으로 해석하고자 하였다.

3.2 예측 모델 설계 및 성능 비교

본 연구에서는 서울시 자치구별 전기차 충전 인프라의 지역 간 불균형을 예측하기 위해 회귀 기반 머신러닝 모델을 적용하였다. 표 2는 분석에 사용된 주요 변수들의 기술통계량을 제시한다. 분석 단위는 서울시 25개 자치구(n=25)이며, 모든 변수에서 결측치는 발생하지 않았다. 종속변수는 자치구별 충전소 개수이고, 독립변수는 전기차 수, 인구 수, 주차면 수, 도로 연장, 월평균 소득, 버스노선 수로 구성하였다. 모델 학습과 평가는 전체 데이터의 80%를 학습용, 20%를 검증용으로 분할하여 수행하였다.

표 2. 변수의 기술통계량

Table 2. Descriptive Statistics of Variables

Variable	Mean	Std	Min	Max
EV	3752.68	2854.26	1389	14117
Parking	201726.24	85634.25	96070	436740
Bus	1506.44	444.75	844	2738
Pop	384655.36	130107.95	125765	672439
Income	3411962.40	626036.48	2547460	4943841
Road	316125.28	76652.71	114232	441986
Chagers	2182.64	944.14	915	4781

모델은 총 세 가지 회귀 알고리즘으로 구성되었다.

Ridge 회귀는 선형회귀에 L2 정규화를 적용해 계수 안정성을 확보하는 방식이며, 랜덤 포레스트는 다수의 의사결정나무를 결합해 비선형 관계를 학습

하는 앙상블 모델이다. XGBoost는 그래디언트 부스팅 계열 모델로, 순차적 오차 보정 구조와 정규화 기반의 하이퍼파라미터 조정을 통해 비교적 높은 예측 성능을 제공한다.

표 3는 Ridge, Random Forest, XGBoost 회귀모델의 예측 성능(MSE, RMSE, R²)을 비교한 결과를 제시한다. 모든 모델은 동일한 변수 세트로 학습되었으며 모델의 성능은 평균제곱오차(Mean Squared Error, MSE), 평균제곱근오차(Root Mean Squared Error, RMSE), 결정계수(Coefficient of Determination, R²)를 사용하여 평가하였다.

표 3. 예측 모델별 성능 비교

Table 3. Model performance comparison

Model	MSE	RMSE	R ²
Ridge	257630.97	507.57	0.8067
Random forest	358235.62	598.53	0.7312
XGBoost	307767.50	554.77	0.7691

분석 결과, Ridge 회귀모델이 가장 높은 결정계수(R²=0.8067)를 보였으나, 해당 모델은 독립 변수와 종속 변수 간의 선형 관계를 가정한다는 한계가 있다. 자치구 단위의 전기차 충전 수요는 전기차 보급 수준, 주차 여건, 교통 접근성 등 다양한 요인이 상호작용하며 비선형적으로 나타나는 경향이 있어 단일 선형 구조로 충분히 설명하기 어렵다. 반면 XGBoost는 비선형 관계와 변수 간 상호작용을 효과적으로 학습할 수 있는 트리 기반 앙상블 모델로, 지역 간 이질성을 반영하는 데 보다 적합하다. 이에 본 연구는 예측 성능뿐 아니라 해석 가능성과 정책 활용성을 종합적으로 고려하여 XGBoost를 최종 분석 모델로 선정하였다.

3.3 XGBoost 회귀모델 분석

충전소 개수의 예측에는 그래디언트 부스팅 알고리즘 기반의 XGBoost 회귀모델을 선정하였다. 이 모델은 다수의 약한 결정트리를 결합하여 예측 성능을 극대화하며, 아래와 같이 최적화된다.

$$Obj = \sum_{(i=1)}^n (y_i - \hat{y}_i)^2 + \sum_{(k=1)}^K \Omega(f_k) \quad (1)$$

$$\text{where } \Omega(f_k) = \gamma T + \frac{1}{2} \lambda \|w\text{vert}\|^2$$

y_i : 실제 충전소개수

\hat{y}_i : 예측값

$\Omega(f_k)$: 트리복잡도 규제 항

그림 1은 XGBoost 모델에서 변수 중요도를 산출한 결과를 보여준다. 이를 통해 전기차수와 주차면수가 충전소개수 예측에 가장 크게 기여함을 확인할 수 있다. 모델 학습 결과 전기차 수와 주차면수가 충전소 설치에 가장 큰 영향을 미치는 변수로 나타났다.




그림 1. XGBoost 변수 중요도 분석 결과
Fig. 1. XGBoost feature importance

버스 노선 수, 인구 수 등은 중간 수준의 중요도를 보였고, 월평균 소득과 도로 연장은 상대적으로 낮았다. 이는 충전소 인프라가 전기차 보급 수와 주차 여건에 가장 크게 의존하고 있음을 의미한다. 특히 교통 접근성과 대중 교통망(버스 노선 수) 변수도 일정 부분 이바지하는 것으로 나타났다.

3.4 정책 우선순위 분석

XGBoost 기반의 교차검증(Out-of-Fold, OOF) 예측을 통해 각 자치구별 전기차 충전소의 적정 설치 규모를 추정하고 실제 값과의 차이를 비교하여 충전 인프라 확충이 필요한 지역을 도출했다.

모델 입력 변수로는 전기차 수, 인구 수, 주차면 수, 도로 연장, 월평균 소득, 버스 노선 수를 사용하였다. 예측값이 실제보다 큰 지역은 충전소가 부족한 곳으로 판단했으며, 부족 규모·전기차 등록 수·인구수를 함께 고려해 정책 우선순위 점수를 산출했다.

3.4.1 우선순위 계산 방식

우선순위 점수는 부족 규모(0.6), 전기차 등록 수(0.3), 인구수(0.1)에 가중치를 부여하여 산출하였다. 부족 규모를 가장 크게 반영한 것은 충전기 수요-공급의 불균형이 정책적 시급성을 가장 직접적으로 나타내기 때문이다. 전기차 등록 수와 인구 수는 지역별 잠재 수요를 보완적으로 반영한다는 점에서 상대적으로 낮은 비중을 적용하였다. 모든 항목은 z-score로 표준화해 자치구 간 비교 가능성을 확보했으며, 점수가 높을수록 충전 인프라 확충 필요성이 큰 지역으로 해석된다. 상위 30% 지역에 대해서는 부족 규모를 기준으로 권장 설치 대수를 함께 제시하였다.

3.4.2 분석 결과

표 4는 OOF 예측값과 실제 설치량의 차이(Gap) 및 부족률(Shortage)을 기반으로 산출한 정책 우선순위 점수(priority)와 권장 설치대수를 정리한 결과이다.

OOF 기반 분석 결과, 강북구, 관악구, 구로구가 최상위 3개 지역으로 나타났으며, 각각 180개, 160개, 90개의 신규 충전소 설치가 권장되었다. 이 지역은 예측값 대비 실제 설치 수의 부족률이 매우 높고, 전기차 보급량과 인구 규모 또한 상위권에 속한다.

표 4. OOF 기반 전기차 충전소 정책 우선순위 분석 결과
Table 4. Policy priority results for EV charger installation (OOF-based model)

district	chargers	Predicted	Gap	Shortage	priority	Recom
Gangbuk-gu	915	1530.48	615.48	0.67	1.73	180
Gwanak-gu	1172	1781.95	609.95	0.52	1.43	160
Guro-gu	2545	3267.3	722.3	0.28	0.89	90
Gangnam-gu	4781	3752.17	-1028.82	0	0.88	5
Songpa-gu	3948	4166.64	218.64	0.05	0.48	35

3.5 군집 기반 정책 유형화

전기차 수, 인구수, 주차면수, 도로연장, 평균소득, 버스노선수 등을 표준화한 후 K-means 군집화를 수행하였다. 그림 2는 k 값에 따른 관성(inertia) 변화를 기반으로 엘보 분석을 통해 최적 군집 수를 3으로 결정한 결과를 보여준다. 도출된 세 개의 군집은 자치구 특성 차이를 반영하며, 예측 기반 우선순위 분석과 함께 정책적 시사점을 제공한다. 그림 3은 군집 결과를 서울시 자치구 지도에 시각화하여 지역별 유형 분포를 나타낸다.

Cluster 0은 도심 및 구도심 지역을 중심으로 형성된 군집으로 주거지와 상업·업무 기능이 혼재된 지역이 다수 포함되어 있다. 해당 군집은 전기차 수요 대비 충전 인프라 부족이 상대적으로 크게 나타나, 충전 인프라의 단기적 확충이 요구되는 ‘확충 필요형 지역’으로 해석할 수 있다. 강북구, 종로구, 중구, 성동구 등 도심·구도심 지역이 포함되며 예측 대비 실제 설치량이 부족한 구가 상대적으로 많았다. 부족률이 높은 지역과도 크게 겹쳐 단기적 확충 필요성이 크며, 주거·업무 기능이 혼재된 특성상 생활권 중심의 충전 인프라 보완이 요구된다.

Cluster 1은 강남권을 중심으로 한 고소득·고밀도 상업 및 업무 중심 지역이 포함된 군집으로 전기차 보급 수준과 잠재 수요는 높으나 예측 대비 실제 충전소 설치 부족률은 상대적으로 낮게 나타난다. 이 군집은 신규 설치 확대보다는 기존 충전 인프라의 운영 효율 제고 및 고속 충전기 중심의 질적 개선이 효과적인 ‘운영 효율화 중심 지역’으로 분류할 수 있다. 강남구, 서초구, 송파구 등 남동권 대규모 주거·상업지역으로 구성된다.

Cluster 2는 주거 중심 지역과 생활권 지역이 혼합된 형태의 군집으로 일부 자치구에서 향후 전기차 수요 증가에 따른 충전 인프라 부족 가능성이 관측된다. 이에 따라 해당 군집은 거점 중심의 단계적 확충 전략이 요구되는 ‘중간 유형 지역’으로 해석된다. 관악구, 구로구, 강서구, 양천구, 영등포구 등 인구 밀집도와 교통량이 높은 중서부 생활권이 포함되며 현재 설치 규모는 일정 수준 확보되어 있으나, 일부 지역에서 부족률이 증가하는 경향이 확

인되었다.

이와 같은 군집 기반 유형화는 개별 자치구 평가를 넘어, 유사 특성을 지닌 지역군을 식별하여 정책 개입을 세분화할 수 있다는 점에서 의의가 있다. 특히 정책 우선순위 결과와 결합하면 단기 확충 지역과 중·장기 관리 지역을 구분할 수 있어, 충전 인프라 구축의 효율성을 높일 수 있다.




그림 2. 최적 군집 수 결정 결과

Fig. 2. Elbow method for determining the optimal number of clusters




그림 3. 서울시 자치구별 전기차 충전소인프라 클러스터 유형 지도시각화

Fig. 3. Spatial visualization of EV charging infrastructure clusters by district in Seoul

IV. 결 론

본 연구는 서울시 25개 자치구를 대상으로 전기차 충전 인프라의 지역별 수요-공급 불균형을 정량적으로 진단하기 위해 XGBoost 기반 OOF 예측을 적용하였다[14]. 예측된 적정 설치 규모와 실제 설치량의 차이를 통해 부족 수준을 산출하고, 부족률·전기차 등록대수·인구 규모를 통합한 우선순위 점

수를 통해 확충 필요 지역을 도출하였다.

분석 결과, 강북구·관악구·구로구는 예측 대비 실제 설치량 격차가 커 단기 확충 필요성이 높은 지역으로 확인되었다. 반면 강남구·서초구·송파구는 신규 설치 확대보다 운영 효율화 및 고속충전 중심의 질적 개선이 더 적합한 지역으로 해석되었다. 또한 K-means 군집화를 통해 자치구를 3개 유형으로 분류함으로써, 개별 지표 비교를 넘어 유사한 지역군 단위의 차등적 정책 설계 근거를 제시하였다.

향후 연구에서는 교통량·유동인구·토지이용(상업/주거 비율) 등 행태 기반 변수를 추가하여 예측 정밀도를 개선하고, 충전기 이용률·가동률·회전을 등 운영 데이터까지 결합해 ‘설치 대수’ 중심 분석의 한계를 보완할 계획이다. 더 나아가 시간적 변화(시계열)와 공간적 자기상관을 동시에 고려하는 공간회귀/공간-시간 모델을 적용하여 지역 간 상호영향까지 반영한 수요 예측 및 정책 시뮬레이션으로 확장하고자 한다.

References

- [1] M. S. Cho, "Rapid Growth of the Electric Vehicle Market: 'Two Out of Three Cars Sold Will Be EVs by 2035' - IEA Outlook and Global Climate Commitments", *Computer World Korea*, No. 491, pp. 58-61, Sep. 2024.
- [2] H. J. Lee, "All Company Vehicles to Be 100% EVs", *Insight Korea*, Vol. 336, p. 70, Oct. 2025.
- [3] J. Hwang, H. Lim, and E. Park, "Infrastructure Construction using the Correlation between Electric Vehicle Charging Infrastructure and Electric Vehicle Registration", *Journal of KIIT*, Vol. 21, No. 3, pp. 1-9, Mar. 2023. <http://dx.doi.org/10.14801/jkiit.2023.21.3.1>.
- [4] J. A. Kim, "An Electric Vehicle Charging Station Location Optimization Model Based on Demand Forecasting", *Asia-pacific Journal of Convergent Research Interchange*, Vol. 10, No. 12, pp. 397-406, Dec. 2024. <http://dx.doi.org/10.47116/apjcri.2024.12.27>.
- [5] Y. Huang, H. Ren, X. Jia, X. Yu, D. Xie, Y. Zou, D. Chen, and Y. Yang, "A Spatially Aware Machine Learning Method for Locating Electric Vehicle Charging Stations", *World Electric Vehicle Journal*, Vol. 16, No. 8, p. 445, Aug. 2025. <https://doi.org/10.3390/wevj16080445>.
- [6] J. G. Kim, D. M. Lee, and S. H. Kim, "A Study to Determine the Optimized Location for Fast Electric Vehicle Charging Station Considering Charging Demand in Seoul", *Journal of Korea Institute of Intelligent Transportation Systems*, Vol. 21, No. 6, pp. 57-69, Dec. 2022. <https://doi.org/10.12815/kits.2022.21.6.57>.
- [7] M. Alaraj, M. Radi, E. Alsisi, M. Majdalawieh, and M. Darwish, "Machine Learning-Based Electric Vehicle Charging Demand Forecasting: A Systematized Literature Review", *Energies*, Vol. 18, No. 17, pp. 4779, Sep. 2025. <https://doi.org/10.3390/en18174779>.
- [8] J. Kim and G. Kim, "Prediction of Festival Visitors Using Multi-Modal LLM and XGBoost", *Korean Journal of Marketing*, Vol. 40, No. 3, pp. 25-44, Aug. 2025. <http://dx.doi.org/10.15830/kjm.2025.40.3.25>.
- [9] A. Almaghrebi, F. Aljuheshi, M. Rafaie, K. James, and M. Alahmad, "Data-Driven Charging Demand Prediction at Public Charging Stations Using Supervised Machine Learning Regression Methods", *Energies*, Vol. 13, No. 16, Article 4231, Aug. 2020. <https://doi.org/10.3390/en13164231>.
- [10] S. Deb, "Machine Learning for Solving Charging Infrastructure Planning Problems: A Comprehensive Review", *Energies*, Vol. 14, No. 23, pp. 7833, 2021. <https://doi.org/10.3390/en14237833>.
- [11] J. Lee, "Optimal Allocation for Electric Vehicle Charging Stations", *Energies*, Vol. 14, No. 18, Article 5781, pp. 1-15, Sep. 2021. <https://doi.org/10.3390/en14185781>.
- [12] Public Data Portal: <https://www.data.go.kr/>. [accessed: Jun. 15, 2025]

[13] Seoul Open Data Plaza: <https://data.seoul.go.kr/>.
[accessed: Nov. 15, 2025]

[14] S. M. Yim and J. H. Seo, "XGBoost-Based Optimization and Spatial Clustering of EV Charging Infrastructure", Proc. Conference on Electronics, Semiconductor, and AI 2025, Gangneung, Korea, pp. 124-126, Aug. 2025.

저자소개

임 소 민 (So-Min Yim)



2023년 3월 ~ 현재 : 강남대학교
인공지능융합공학부
데이터사이언스학과 학부과정
관심분야 : 머신러닝 예측모델,
공간데이터 분석, 영상기반
객체인식

서 지 훈 (Ji-Hoon Seo)



2008년 2월 :서울과학기술대학교
안전공학과(공학사)
2010년 8월 : 인천대학교
컴퓨터공학과(공학석사)
2015년 2월 : 인천대학교
컴퓨터공학과(공학박사)
2019년 9월 ~ 2023년 2월 :

인천대학교 기초교육원 객원교수

2023년 3월 ~ 현재 : 강남대학교 인공지능융합공학부

데이터사이언스학과 조교수

관심분야 : 데이터베이스, AI