

건물스톡에너지모델 기반 수요반응모델 설계를 위한 가상스마트미터 데이터셋 분석

Analysis of Virtual Smart Meter Data Sets for Designing Demand Response Models Based on Building Stock Energy Model

김재춘* · 노광현†

Jae-Chun Kim* · Kwang-Hyun Ro†

Abstract

This study examined the possibility of developing a time-series-based electricity demand response model by applying a VSM data set model generated from 30,000 household on BSEM in Quebec, Canada, to the demand response of the domestic electricity market. The CBL method, which has been adopted as a conventional demand forecasting method, has limitations in sufficiently reflecting the nonlinearity of maximum power demand and demand response because it calculates based on the average of past power consumption data. Therefore, in this study, the structure of the VSM data set which generated BSEM and the TRNSYS-CREST simulation were analyzed, and the applicability of the demand response was evaluated through the verification of the LSTM, GRU, and CNN-LSTM models using the VSM data set. As the results, the LSTM and GRU models showed slightly higher error index than the CBL, while the CNN-LSTM structure effectively predicted short-term fluctuations through convolutional features combined with time dependency. This confirmed the possibility of more precise DR if the conventional CBL method and the AI prediction model were combined. In conclusion, this study confirmed the possibility of constructing a Korean VSM data set that reflects institutional factors such as BSEM-based energy prediction, TOU rate system, and DR, focusing on apartment complexes in Korea, and the possibility of follow-up research on simulation and empirical models based on RSM data.

Key Words : Building stock energy modeling, Customer baseline load, Demand response, Distributed energy resources, Time of use, Virtual smart meter

1. 서론

2050년 탄소중립 선언으로 전 세계적인 탈탄소정책과 신보호무역주의 강화, AI의 급속한 확대, 신재생에너지 보급 확대는 글로벌 전력산업의 급속한 구조적인 전환기를 맞이하고 있다[1]. 이러한 상황에서 분산에너지자원의

통합 운영이 전력계통 안정성을 확보하기 위한 핵심 수단으로 제시되고 있다. 이에 발맞춰 국내에서도 소규모 분산 에너지 자원을 단일 발전의 가상발전소로 도매시장에서 대형발전사와 동일한 지위를 통한 전력중개사업의 참여가 가능한 분산에너지 활성화 특별법이 시행되었다[2].

국내에서 전력사용량 데이터의 수집과 관련하여 2015년 스마트그리드 사업의 일환으로 원격검침인프라(AMI, Advanced Metering Infrastructure) 보급사업이 시작되었다. 2024년말까지 한국전력 전체 가입자 2,250만호 중 2,005만호의 구축을 완료하여 약 90% 보급한 상태이다. 다만 일반 주택수용가의 AMI 보급률은 54%로 낮은 보급률로 집계되었다[3].

국내 전력수용가 중 주택용(저압)은 공공데이터 정보를

* Corresponding Author : Professor, Department of Applied Artificial Intelligence, Hansung University, Korea
E-mail : khrho@hansung.ac.kr
https://orcid.org/0009-0002-9391-6052

† Ph.D. Candidate, Department of Smart Convergence Consulting, Hansung University, Korea
https://orcid.org/0009-0003-2388-1699

Received : August 4, 2025

Revised : September 8, 2025., September 22, 2025

Accepted : September 25, 2025

통하여 데이터의 접근 및 확보가 가능하다. 그러나 공동주택에 대한 주택용(고압) 전력데이터는 가구당 사용데이터와 공용부 전력정보가 혼재되어 있고 공동주택별로 관리사무소에서 별도로 관리되는 관계로 정보 공개에 대한 비대칭성과 실시간의 고해상도 전력사용 데이터를 확보하는데 제약이 있는 상태이다[3]. 이러한 공동주택에 대한 수요예측 모델이 실측 데이터 접근 제한으로 인해 표본의 편향성, 실증기반 데이터의 부족, 실시간으로 변화하는 수용가의 상황을 고려한 수요예측의 한계에 있다[4].

이러한 한계를 극복하고자 선행연구로 Neale et. al. 의 캐나다 퀘백주의 단독주택 가입자를 대상으로 건물스톡에너지모델(BSEM, Building Stock Energy Model)로 생성된 가상의 스마트미터 데이터 (VSM, Virtual Smart Meter)셋을 활용한 전력 수요예측 모델과 수요반응모델의 적용가능성을 검증하였다. 캐나다 단독주택의 VSM 모델을 해석하고 이를 국내 주택시장을 대상으로 국내 현실과 제도에 맞게 확장함으로써 한국형 VSM 데이터셋 개발을 위한 분석의 틀을 제공하고자 한다.

2. 이론적 배경 및 선행연구

2.1. 스마트미터와 VSM

국내에 설치된 원격검침시스템 AMI는 전력회사와 수용가 간의 양방향 데이터 통신을 통한 전기사용 데이터를 실시간으로 제공하고 전기사용에 대한 제어가 가능한 전자식 스마트 계량기(Smart Meter)로 전력회사와 수용가 간의 수요반응의 핵심이다[5]. AMI 기술은 최적의 스마트 그리드 운용을 위해 필요한 에너지 네트워크 인프라로 하드웨어, 소프트웨어, 서비스로 구분되는 계량 시스템으로, 수요관리, 요금설계, 전력 피크 제어 등 다양한 전력정책에 활용되는 기반기술이다[5].

스마트미터 데이터는 AMI에서 검침된 15분 또는 1시간 단위의 전기에너지 사용량으로 건물의 특성 및 에너지 사용과 관련된 거주자 특성 등이 전혀 반영되지 않은 실측 데이터(RSM, Real Smart Meter)이다[5]. 이에 반해 주택의 전력소비가 주택의 면적, 가구원 수, 가구원의 라이프 스타일, 날씨 등 다양한 내·외적 요인에 영향을 받는다고 확인된 바 있으나 이러한 내·외적 변수의 특성을 반영하여 생성된 VSM에 대한 연구는 부족한 상황이다[6]. 이를 위하여 캐나다 퀘백주의 주택용 건물의 세분화된 스톡특성을 반영한 15분 단위의 고해상도로 생성된 200,000개의 전력소비 데이터에 대한 분석은 현실의 스마트미터 데이터 접근의 한계를 극복하고, 이를 통해 수요반응 예측모델의 검증용으로 사용할 수 있는 장점이 있다. 또한 다양한 기후 조건과 건물 변수에 따른 전기소비량 간의 수요예

측의 명확한 연관성을 개발하는데 다양하게 활용될 수 있다[7].

2.2. 건물에너지 시뮬레이션과 건물스톡모델

VSM 데이터셋을 통하여 건축물의 에너지 관련 다양한 건물스톡 변수와 전기소비량 간의 연관성을 파악하기 위하여 건물 열에너지 모델 컴포넌트로 열부하 해석을 지원하는 TRNSYS(천이시스템 시뮬레이션 프로그램, Transient System Simulation Program), Type 56 소프트웨어를 이용하여 3차원 단일구조의 건물 단열성능, 점유 스케줄 등을 입력하여 냉난방, 급탕, 공기침입, 조명, 가전제품 등 내부 열원을 기반으로 시뮬레이션을 수행하였다[7].

여기에서 일부 변수는 확률분포를 기반으로 건물 유형, 창호 종류, 바닥 면적 등 주거특성을 조합하여 대규모 스톡에 대응 가능한 BSEM 구조를 실현하였는데, 이는 영국 Loughborough University에서 확률적 수요모델로 배포된 CREST(재생에너지시스템기술센터, Centre for Renewable Energy Systems Technology)모델을 활용하여 물리기반 접근으로 개별건물의 특성을 하향식 BSEM(Bottom-up White-box Building Stock Energy Model)을 통한 점유자 기반의 조명, 가전, 급탕 등 부하 조건을 정교하게 에너지소비를 시뮬레이션 함으로써 해상도 높은 데이터셋을 생성하였다[7,8].

2.3. DR과 DER의 연계구조

미국 연방에너지규제위원회 (FERC, Federal Energy Regulatory Commission)에서는 DR(수요반응, Demand Response)을 전력수요의 주체가 전기요금 또는 전기요금 이외의 수용가 이익에 반응하여 전력소비패턴의 조정을 통한 전력소비시장에 참여하는 것으로서 전력시장의 가격이 높을 때에는 전기 소비를 줄이도록 유도하거나 계통 신뢰도 확보를 목적으로 전력수요를 일으키는 행위로 정의하고 있다[2].

DER(Distributed Energy Resources, 수요자원)은 BTM(Behind the Meter)에 위치한 모든 발전자원으로 태양광, 풍력, 열병합발전기, 에너지저장장치, 전기차 등의 소규모 분산형 전원을 지칭한다[9].

이러한 DER 자원 중 태양광, 풍력 발전을 중심으로 신재생에너지 자원이 급속하게 증가하고 있는데, 이러한 신재생에너지 기반의 DER 자원은 기후의 영향을 많이 받고 있어서 발전량 예측이 힘들고 편차가 큰 출력의 간헐성으로 인하여 주파수 및 전압의 변동성이 커져 전력의 품질수준을 유지하고 안정적인 전력망 운영에 큰 부담을 주고 있는 것이 현실이다[10].




Fig. 1. Classification of demand response program

Fig. 1에서와 같이 DR은 도매전력시장의 가격에 따라 반응하는 경제성DR과 전력계통의 신뢰도 확보를 목적으로 수요에 반응하는 신뢰성DR로 분류하고 있다. 가격기준 DR(PBP, Price Base Program)은 시간대별 가격제(TOU, Time of Use), 특정고부하피크요금제 (CPP, Critical Peak Pricing), 폭염/혹한/공급부족시 적용되는 극단요금제(ED-CPP, Extreme Day Critical Peak Pricing), 재해나 공급망 불안 시 계속 적용되는 극단요금제(EDP, Extreme Day Pricing), 실시간 정산형(RTD DR) 제도로 구분하고 있다[9].

3. 선행 VSM 모델 분석

3.1. 선행연구모델

Neale et al.은 캐나다 퀘벡주 단독주택 약 190만 호의 에너지 특성을 반영한 40,000개의 주택에 대한 가상 스마트미터 데이터셋을 구축하였다. CREST 모델을 기반으로 거주자 활동, 가전 부하, 급탕 및 냉난방 부하를 시뮬레이션하여 생성되었으며, 창면적비, 단열 성능, 점유자 수 등 총 19개의 건물 파라미터를 포함한다. 이 연구의 주요 목적은 VSM 데이터를 이용해 선형판별분석(LDA, Linear Discriminant Analysis) 분류 모델을 구축하고, 고해상도 에너지 소비 시계열로 각 건물 특성을 정확하게 추정할 수 있는지를 검토하였다[7,8].

이러한 선행연구는 실제 스마트미터 데이터가 건물의 물리정보를 포함하지 않는 현실에서, VSM 기반 시뮬레이션 데이터로 기계학습 모델을 학습시켜 역추론 모델을 설계하는 새로운 가능성을 제시하였으며, 이는 본 연구에서 제안하는 AI 기반 수요예측 및 수요반응 최적화 모델의 이론적 기반이 될 수 있다.

3.2. VSM 모델의 구조 분석

Neale, et al.의 선행연구에서 VSM 데이터셋은 고해상

도 RSM 데이터를 활용한 건물의 특성을 역추적하고 이를 기반으로 수요예측 모델을 구성하기 위해 Fig. 2와 같이 Generator-Classifer-Extractor의 아키텍처 구조로 각각의 구성요소가 독립적인 기능을 수행하였다. 이는 가상으로 생성된 고해상도 전력소비 데이터를 기반으로 건물의 에너지 특성과 점유자 행동을 이해하고 예측하기 위한 통합 모델링으로 제시하였다[7].




Fig. 2. Classifier-classifier-extractor model

첫 번째 구성요소인 Generator는 Fig. 3의 VSM input의 Flow와 같이 확률적 입력변수를 기반으로 TRNSYS 시뮬레이션을 수행하고, 15분 단위의 VSM 데이터를 생성한다. 이는 현실의 RSM 데이터에 근접한 정밀도와 표본 편향 없이 대량생성이 가능하다는 장점으로 200,000개의 VSM 프로파일을 출력하였다[7].

Generator 단계에서 총 19개의 입력 변수들을 기반으로 하는 건물 특성 시나리오를 구성하였는데, 각각의 변수는 확률분포(PMF:Probability Mass Function, UPD:Uniform Probability Distribution, TBD:To be determined, NYI:Not yet implemented, SHEU:Survey of household energy use)로 생성하였다[7].

Table 1. Inner structure and procedure of classifier

단계	단계별 학습 내용
{2A} Machine Learning	TRNSYS+CREST로 생성한 VSM 데이터를 기반으로, 각 데이터의 입력값(예: 면적, 점유자 수 등)과 출력값(전력 사용량)을 학습. LDA 알고리즘을 통해 클래스 구분을 위한 선형 판별식을 생성
{2B} Initial Guess	학습된 LDA 모델을 이용해 새로운 데이터(RSM 또는 실제 스마트미터 데이터)의 입력값을 추정. 이를 통해 Extractor 단계에서 초기값으로 활용

두 번째 구성요소인 Classifier는 Fig. 3에서의 Flow와 같이 Generator에서 생성된 VSM 데이터를 입력으로 받아, 건물의 창면적비, 단열성능, 면적 등 물리적 특성을 추론하는 역방향 머신러닝 모델이다. Classifier는 Table 1과 같이 아키텍처 구조 중 중추적인 학습단계로 크게 {2A} Machine Learning의 단계와 {2B} Initial Guess의 단계로 진행되었다. 이를 통해 스마트미터 데이터만으로도 건물 정보를 예측할 수 있는 가능성을 제시하였으며 LDA 신

경망 알고리즘을 적용하였다[8].

세 번째 Extractor 단계는 AMI에서 검침된 RSM 데이터를 첫 번째 Generator 단계에서 생성된 VSM 데이터와 반복적으로 비교하였다. RSM-VSM의 비교 값이 오차범위를 초과하면 입력파라미터를 반복적으로 조정하여 오차범위내의 값으로 VSM 데이터셋에 기록하고, 오차범위 내 값으로 매칭이 완료되면 건물파라미터값을 최종적으로 출력하였다[7].




Fig. 3. VSM model

이전 단계(Classifier)의 추정값을 초기값으로 활용하여 실제 건물의 물리적 특성을 통한 입력 파라미터를 추정하기 위한 역모델링 기능으로 Classifier에서 학습된 모델을 TRNSYS, CREST 모델을 사용하여 해당 입력값으로 VSM 시뮬레이션의 수행으로 시계열 데이터를 생성하는 단계로 Extractor 구조로 제시되었다[7]. 이는 실제 데이터값인 RSM 데이터를 바탕으로 VSM 데이터와 비교를 통하여 추가적인 강화학습의 보정 알고리즘의 적용을 통한 기존의 단순한 건물 시뮬레이션이나 부하 예측을 넘어, 현실기반 데이터의 해석과 예측이 가능한 융합형 데이터로 활용 가능성을 보여준다.

3.3. MATLAB-TRNSYS 연계 시뮬레이션 분석

기존 AMI를 기반으로 하는 Smart Meter 데이터는 개인정보 침해 문제, 건물 물리적 특성의 비공개성, 데이터 접근성의 한계 등의 문제로 인하여 연구와 정책 개발에 한계가 있으며 이러한 문제점을 극복하고자 VSM 데이터셋을 도입했다[11].

VSM 데이터의 변수는 MATLAB을 통한 건물의 특성,

기후조건, 점유자 수, 냉난방 조건 등 19개 변수를 생성하였다. 여기에서 건물면적, 건물위치, 유형, 면적 등의 실측 데이터를 기반으로 선택확률을 정의하는 PMF와 건물의 회전각 등 실제 사전 실측 정보데이터가 부족한 변수에 동일 확률 분포로 부여하는 UPD의 확률 분포로 VSM 변수를 생성하였다[12].

TRNSYS는 주어진 건물 구성과 날씨조건에 따라 시뮬레이션을 수행하고, 결과물을 시계열 데이터로 변환한다. 이는 한 주택당 15분 단위의 1년간 35,040개 데이터를 시뮬레이션을 통하여 출력하고, 결과값을 CSV 형식으로 저장 후 시뮬레이션을 호출하는 TRNSYS-MATLAB 연동 방식과 함께 독립적인 병렬처리(batch processing)로 총 200,000개의 가상 전력사용량 데이터를 생성하였다[12].

이상의 VSM 데이터 생성 모델은 기존의 개별 주택 시뮬레이션 방식과 달리 현실적이면서도 정량성 높은 데이터를 대량 생성할 수 있는데 기여했으며, 향후 인공지능 학습모델 개발, 수요예측 시뮬레이션 등의 후속 연구에 중요한 기초가 될 수 있을 것이다.

3.4. CREST 기반 내부 부하 모델 분석

주택 내 부하와 직접적으로 관련된 다양한 확률적 거주 행동을 보장하기 위해 CREST 모델을 사용하여 조명, 가전 기기, 급탕부하를 시뮬레이션 기반의 전력소비 프로파일을 생성하였다. CREST 부하 모델은 TRNSYS와 연계하여 독립적인 시계열 데이터를 통해 40,000개의 가상건물을 생성하고 VSM 모델을 구축하여 총 200,000개의 고해상도 전력소비 데이터를 일관되게 생성하였다. 여기서 CREST 부하 모델은 정형화된 스케줄 기반이 아닌, 점유 기반의 동적 부하 모델링이 적용되어 전력소비의 시간적 변동성과 사용자의 행동 패턴분석이 가능하다[8]. 이렇게 생성된 VSM 데이터셋은 DR기반의 시뮬레이션을 설계할 때 특정 시간대의 부하 감축 시나리오나 TOU 요금제의 반응을 통한 소비패턴의 변화분석 등에도 효과적으로 활용될 수 있다[10].

3.5. VSM 데이터셋 생성

VSM 데이터셋은 확률적 입력값을 생성하고 시뮬레이션의 자동 제어 및 데이터 후처리 및 병렬연산관리를 MATLAB 소프트웨어 환경 내에 Manage 스크립트 엔진이 전체 과정을 자동화하고 무작위로 생성된 파라미터를 TRNSYS, Type 56 모델에 캐나다 표준 외기조건(CWEC, The Canadian Weather year for Energy Calculation)과 점유 스케줄, 확률분포 입력값을 조합하여 통계적으로 의미있는 부하 패턴을 재현하였다[7].

Table 2. Building parameters used for classification

Type	Class name
QL	Location, Building type, Window, Adjacent buildings, Air conditioning, Heat pump, Auxiliary heating, DHW(Domestic Hot Water) type
QN	Load profile, Area, WWR(Window-to-wall ratio), Rotation, Occupants, Number of floors, Wall RSI, Roof RSI, Foundation RSI, Leakage, Aspect ratio

* QL: qualitative, QN: quantitative

각 주택은 고유한 19개 입력 파라미터 조합에 따라 설정되어 시뮬레이션을 통해 도출되며 Table 2와 같이 개별 변수는 설정된 범주를 질적변수인 QL과 양적변수인 QN으로 구분하였다. 구분된 19개 변수를 기반으로 시뮬레이션의 기초데이터로 VSM 데이터셋을 생성하고 LDA학습으로 연구전반에 활용되었는데, 메타데이터 구조를 기반으로 생성된 VSM 데이터셋을 기반으로 머신러닝 학습, 시계열 분석, 클러스터링 모델설계를 구성하였다[8].

이렇게 생성된 메타데이터 구조는 머신러닝 알고리즘으로 RF(Random Forest), Gradient Boosting, XGB(XGBoost) 등 앙상블 알고리즘의 예측모델 구현이 가능하다. 딥러닝 기반의 LSTM(Long Short Term Memory), CNN(Convolutional Neural Network), Transformer와 같은 모델의 Sequential 데이터 분석으로 확장은 물론이고 최근에는 autoencoder와 GAN을 활용하는 TadGAN과 같이 생성형 AI를 활용한 예측모델로 연구가 확대되고 있다[12].

VSM 데이터셋을 LDA 기법으로 데이터 그룹 간의 차이를 최대화하고 그룹 내 분산을 최소화하는 분석방법으로 각 클래스에 대해 판별함수를 정의하고, 새로운 데이터 포인트가 속할 클래스를 결정하며 다음의 방정식으로 제시되었다[8].

$$\delta_c(x) = x^T K^{-1} \mu_c - \frac{1}{2} \mu_c^T K^{-1} \mu_c + \log(P_c) \quad (1)$$

x : 입력데이터

μ_c : 클래스 c의 평균 벡터

K : 공분산 행렬

p_c : 클래스 c의 사전확률

Fig. 4는 LDA를 적용하여 건물 특성을 역추적한 수행 결과로, 40,000개의 VSM 가상건물을 생성하고 19개 건물 특성을 대상으로 Classification 모델 정확도를 확인한 Location 변수는 시나리오 A에서 약 90.2%의 정확도를 보였으나, Feature 수가 많은 시나리오 C에서는 97.7%, 시나리오 D에서 97.8%로 향상되었다.

Scenario :	A	B	C	D	E	F	G	H
Period :	1 year	1 year	1 year	1 year	Jan. 15	July15	January	July
Interval :	Monthly	Weekly	Daily	Hourly	15-min	15-min	15-min	15-min
Features(c):	12	52	365	8760	96	96	2976	2976
Classes(c):	Classification model accuracy							
Location	0.902	0.962	0.977	0.978	0.955	0.643	0.969	0.964
Building_Type	0.800	0.800	0.834	0.932	0.794	0.800	0.932	0.796
Load_Profile	0.283	0.826	1.000	1.000	0.961	0.986	1.000	1.000
Window_Type	0.497	0.537	0.692	0.921	0.475	0.406	0.914	0.532
Area	0.437	0.454	0.590	0.859	0.434	0.383	0.892	0.472
Window_to_Wall_Ratio	0.496	0.525	0.591	0.887	0.474	0.359	0.888	0.552
Rotation	0.260	0.266	0.284	0.275	0.258	0.248	0.281	0.266
Occupants	0.578	0.881	1.000	1.000	0.970	0.974	1.000	1.000
Adjacent_Buildings	0.799	0.801	0.828	0.892	0.794	0.800	0.894	0.787
Number_of_floors	0.719	0.789	0.934	0.966	0.690	0.609	0.958	0.886
Wall_RSI	0.598	0.633	0.719	0.889	0.599	0.591	0.893	0.654
Roof_RSI	0.308	0.352	0.511	0.784	0.297	0.209	0.786	0.364
Foundation_RSI	0.558	0.604	0.807	0.881	0.498	0.486	0.883	0.755
Leakage	0.419	0.493	0.715	0.680	0.430	0.205	0.796	0.526
Air_Conditioning	0.804	0.815	0.888	0.914	0.784	0.833	0.799	0.901
Heat_Pump	0.980	0.980	0.994	0.999	0.962	0.830	0.997	0.956
Aux_Heating	0.996	0.997	1.000	1.000	0.986	0.959	1.000	0.981
DHW_Type	0.985	0.987	1.000	1.000	0.981	0.978	1.000	1.000
Aspect_Ratio	0.201	0.201	0.201	0.202	0.202	0.199	0.207	0.200

* dark red=0.0 << dark green=1.0

Fig 4. Classification accuracy results

Feature 수가 8,760으로 가장 많은 시나리오 D에서 Heat pump, Auxiliary heating, DHW type 등 변수가 99% 또는 100%로 북반구의 난방중심의 부하패턴을 명확히 설명하고 있는 것을 확인할 수 있다. Rotation과 Aspect Ratio는 모든 시나리오에서 20~30%의 수준으로 예측됐는데, 이는 랜덤 추측 생성된 변수들이 BSEM에 미치는 영향력이 상대적으로 낮은 것이 원인인 것으로 해석된다[8].

4. 선행 VSM 모델의 국내적용가능성 분석

4.1. 지역적 한계와 국내 적용성

Table 3. Comparison of geographic, environmental, and climatic characteristics of Canada and Republic of Korea

항목	한국	캐나다
지리적 위치	동아시아, 한반도 위치	북아메리카 대륙 북부, 북극권과 인접
면적	약 100,000km ²	약 9,984,670km ²
인구	약 5,200만명(2025년)	약 4,000만명(2025년)
주거	71%가 공동주택주거	60%가 단독주택주거
기후	대륙성 기후 및 온대 기후, 여름 덥고 습함, 겨울 춥고 건조	북부: 한대 및 극지 기후, 남부: 냉대 및 온대 기후
강수량	연평균 1,000~1,500 mm	연평균 500~1,500 mm 지역별 다양
겨울 온도	평균 -5℃~3℃ (12월~다음해 2월)	북부 -30℃ 이하, 남부 -10℃~0℃ (11월~다음해 4월)
여름 온도	평균 23℃~30℃	북부 10℃ 이하, 남부 20℃~30℃(7월~8월)
주요 에너지	화석연료, 원자력, 가스, 신재생에너지	수력, 천연가스, 신재생에너지, 석유

Table 3에서 캐나다는 북위 60도 이상에 위치한 한랭 기후지역으로, 11월~4월까지 겨울이 길고 영하권의 날씨는 난방부하가 지배적으로 적용된다. 주거형태가 단독주택이 주류를 이루며 화석연료와 천연가스 수력 등이 주 에너지원으로 이루어지고 있다[13].

한국은 북위 33~37도 사이의 온대와 아열대 기후가 혼재하는 환경으로 사계절이 뚜렷한 반면 여름철 고온 다습과 겨울철 한랭의 이중적인 계절 특성이 혼재되어 있고 좁은 국토에 인구밀도가 높아 공동주택이 주요 주거형태로 구성되어 있다[14].

선행연구에서 기 생성된 VSM 데이터셋이 난방유, 천연가스, 전기, 목재 등의 난방원료를 변수로 Heating Category를 세분화하여 TRNSYS 모델링의 기초데이터로 설정하였다[7]. 이를 국내에 적용하기 위해서는 CREST 기반 내부부하 모델을 냉방변수를 추가하고 공동주택 중심의 건물 특성에 맞게 보정이 필요하다.

4.2. 전력소비특성 및 요금차이 분석

한국전력의 주택용 전력요금은 산업용에서 적용되는 계시요금제와 다른 누진제를 기본으로 하고 있다.

Table 4. Residential (Low voltage) seasonal usage rate plan, in Korea[15]

주택용 전력(계절별 선택요금) (2023년 11월 9일 기준)						
기본요금 (원/kWh)	기타계절(1/1~6/10, 9/1~12/31)		하계(7/1~8/31)			
	기본요금	전력량요금	기본요금	전력량요금		
	200kW 이하	910	120	910	120	
	201~300kW 이하	1,600	214.6			
301~400kW이하	7,300			307.3	1,600	214.6
40kW 초과		7,300	307.3		7,300	307
450kW 초과						

* 동계(12/1~2/말), 하계(7/1~8/31) 1,000kWh초과전력량요금은736.2원/kWh

Table 5. Residential (High voltage) seasonal usage rate plan, in Korea[15]

주택용 전력(계절별 선택요금) (2023년 11월 9일 기준)				
기본요금 (원/kWh)	기타계절(1/1~6/10, 9/1~12/31)		하계(7/1~8/3)	
	기본 요금	전력량 요금	기본 요금	전력량 요금
200kW 이하	730	105	730	105
201~300kW 이하	1,260	174		
301~400kW이하			1,260	174
40kW 초과	6,060	242.3		
450kW 초과				
* 동계(12/1~2/말), 하계(7/1~8/31) 1,000kWh초과전력량요금은601.3원/kWh				

Table 4의 주택용(저압)요금과 Table 5의 주택용(고압)요금체제로 구분하여 전력사용량이 증가함에 따라 높은 전력단가를 적용하는 3단계 누진요금을 기본시스템으로 전력소비가 급증하는 여름, 겨울에 높은 요금을 적용하고 봄, 가을에는 전력소비가 상대적으로 낮은 요금제를 적용하는 누진제를 기반으로 하는 계절요금체제를 적용하고 있다[15].

캐나다의 전기요금체제는 계시별 요금제(TOU, Time-of-Use)와 극단요금제(ULO, Ultra-Low Overnight) 요금제를 중심으로 설계되어 있다[16].

Table 6. Detailed reflection criteria for the heating and cooling system on Standard TOU, Canada[16]

Standard TOU						
시간구분	평일				주말·공휴일	
	여름철		겨울철		모든 계절	
	부하시간	요금(c/Wh)	부하시간	요금(c/Wh)	부하시간	요금(c/Wh)
7~11시	중간	10.2	최대	15.1	경	7.4
11~17시	최대	15.1	중간	10.2		
17~19시	중간	10.2	최대	15.1		
19~7시	경	7.4	경	7.4		

퀘벡주와 인접해 전력요금제와 전력사용 패턴이 유사한 온타리오주의 2023년 5월 기준 OEB社(캐나다 온타리오주의 전력회사)의 자료에 따르면, Table 6과 같이 TOU 요금제는 여름철/겨울철로 나누어 시간대별(최대, 중간, 경부하) 요금제로 최대부하시간대에 kWh 당 15.1센트, 초저녁 및 심야 시간대에 kWh당 7.4센트의 요금으로 최대부하시간과 경부하시간의 비율이 2배의 높은 요금으로 설계되어 있다.

Table 7. Detailed reflection criteria for the heating and cooling system on ULO, Canada[16]

ULO 요금제				
시간구분	평일		주말·공휴일	
	모든 계절		모든 계절	
	부하시간	요금(c/Wh)	부하시간	요금(c/Wh)
7~16시	중간	10.2	경	7.4
16~21시	최대	24		
21~23시	중간	10.2		
23~7시	심야	2.4		

Table 7에서 ULO 요금제는 최대부하시간대에 kWh 당 24센트, 초저녁 및 심야 시간대에 kWh당 2.4센트의 매우 저렴한 요금을 제공해 심야시간대 전력소비를 유도하고 있다[16].

이상의 전력요금 비교에서 확인할 수 있는 것과 같이 캐나다는 신재생에너지와 지역별 자원 조건을 고려한 분산

형 전원 운용과 시장 경쟁 기반의 수요반응 체계를 적용하여 전력소비 및 감축의 자율성과 실시간성이 반영된 것을 확인할 수 있다[17]. 이는 한국형 VSM 예측모델 개발을 위해서는 DR체제로 소비행동 변화를 반영한 입력변수 구조설계가 필요함을 확인할 수 있다.

4.3. DR 및 DER의 연계

국내 DR 프로그램은 Fig. 5와 같이 계통 안정을 목적으로 주로 산업용 전기를 대상으로 신뢰성DR, 경제성DR, 한전이 자체적으로 계통안정을 목적으로 주파수 조정에 대응하는 Fast DR, 수요 증가를 유도하는 Plus DR로 운영하고 있다. 경제성 DR은 도매전력시장 가격에 따른 자발적 감축으로, 신뢰성 DR은 계통의 안정성을 위해 의무적으로 전력소비를 줄이는 방식으로 구분한다. 시간대별 가격차등은 계시별 요금제로 Fig.1에서 분류된 TOU, CPP, RTD 등을 포함한다[2].






Fig. 5. Classification of domestic demand response

여기에서 Plus DR은 전력 잉여가 예상되는 특정 시간대에 전력을 추가로 사용하면 인센티브를 지급받는 프로그램이며, 국민DR은 주택용 수유가를 대상으로 시범적으로 운영하는 프로그램으로 전력 사용자가 직접 기기를 제어하는 수동반응과 달리, IoT 기술을 활용하여 원격제어를 통한 참여자의 편의성을 향상시켰다[2].

Table 8. DR standards for general residential use



국내 주택용 요금제는 계절별 누진요금제를 적용하고 있지만, 전력거래소에서 시행하는 DR프로그램은 2024년 4월 1일자 발표기준 Table 8은 주택용(저압)과 주택용(고압)에 대하여 24시간을 구간별로 분리하고 각각 구간 내에서 서로 다른 요금이 적용되는 방식의 국민DR과 플러스DR을 정해진 시간 한도 내의 DR 이벤트 발령을 운영하고 있다[1]. 즉, 주택용 DR은 캐나다 및 국내 산업용 요금제에 맞춰 계시요금제로 세분화하여 경부하 구간과 최대부하구간의 요금이 2배이상의 요금제로 DR 발령을 통하여 운영하고 있지만 한국전력의 주택용 요금체계는 부하시간을 고려하지 않는 계절별-누진 요금제로 DR 확장에 분명한 한계점이 있는 것을 확인할 수 있다.

5. 선행 VSM 데이터셋 분석


5.1.VSM 데이터셋의 CBL 분석

일반적인 기존의 수요예측모델은 고객기준 부하(CBL, Customer Baseline Load)방법으로 10-Day Adjusted Baseline을 적용하고 있으며, DR-10일 기준 최대치와 최소치를 제외한 나머지 8일 기준으로 VSM 데이터셋으로 CBL 예측을 수행하였다. 여기에서 산정된 10-Day Adjusted CBL의 방정식은 다음과 같다[18].

$$F_t = \frac{1}{8} \left(\sum_{i=1}^{10} D_{t-i} - D_{\max} - D_{\min} \right) \quad (2)$$

VSM 데이터셋 전체 200,000가구의 모든 데이터를 계산하는데 한계가 있어서 VSM000001~VSM001000까지의 1,000가구 데이터로 단축하여 산정하였다.

Table 9. CBL Prediction for 1,000 households






Table 9는 VSM 데이터셋의 예측에 대하여 대표적으로 DR+100일, DR+150일, DR+200일의 특정일을 임의로 추출하여 CBL을 산정하고 예측 일차인 101일차, 151일차, 201일차의 VSM Data 값을 비교하였다. Table 9의 수행결과에 대한 그래프에서 CBL 예측치는 VSM 데이터의 전력데이터를 수렴하지만 세밀하게 피크치에서는 크기 차이가 나는 것을 확인할 수 있었다.

CBL 예측모델에 대한 데이터의 오차를 확인하고자 MBE, MAE, RMSE를 Table 9의 모델로 산정하였다. 여기에서 오차지표 MBE, MAE, RMSE는 Table 10의 (3), (4), (5)의 방정식으로 산정하였다.

Table 10. Calculation equation of error index

구분	MBE	MAE	RMSE
오차 지표	Mean Bias Error	Mean Absolute Error	Root Mean Square Error
적용 모델	과소/과대 예측경향 측정	일반적인 정확도 측정	큰 오차에 대한 민감도 측정
적용 수식	$\frac{1}{n} \sum_{i=1}^n (D_t - F_t)$ (3)	$\frac{1}{n} \sum_{i=1}^n D_t - F_t $ (4)	$\sqrt{\frac{1}{n} \sum_{i=1}^n (D_t - F_t)^2}$ (5)
해석	Dt ; 전력사용량, Ft: 예측전력		

Table 11에서 오차지수 산정결과는 DR 101일에서 201일로 산정일수가 증가할수록 MAE가 0.206742에서 0.075477로 감소하고, RMSE도 0.232172에서 0.096406로 감소한 것은 데이터 양에 따라 CBL 기준선 추정치의 정확도가 향상되고 있는 것을 설명하고 있다. 특히 최대 부하에 대한 관리측면에서 RMSE 값의 개선은 극단적 예측실패가 줄어들고 있음을 확인하였다.

Table 11. Calculation of error index

DR Day	MBE	MAE	RMSE
101	-0.021889	0.206742	0.232172
151	-0.038810	0.092094	0.109224
201	+0.018607	0.075477	0.096406

Table 11에서 MBE101(-0.021889), MBE151 (-0.038810)은 음수 값으로 과대예측이 일관되게 이루어졌으며 MBE201(+0.018607)로 경미한 과소예측 경향을 확인하였다. 다만 MBE 절대값이 줄어든 것은 예측값이 소비패턴을 설명하고 있음을 의미하며 이는 기존 예측모델로 넓게 활용되는 CBL 접근법이 데이터량의 증가에 따라 전력수요를 합리적으로 적용 가능한 예측방법임을 확인할 수 있었다.

5.2.VSM 데이터셋 모델학습

이와 관련하여 동일한 VSM 데이터셋이 전력수요에 대하여 시간에 따라 변화하는 연속적인 데이터에 대한 처리로 Table 12와 같이 LSTM, GRU, CNN-LSTM의 방법으로 VSM 데이터셋을 검증하였다. 여기서 적용된 LSTM, GRU, CNN-LSTM은 비선형 학습에 대한 가중치를 적용하여 장기 의존성 파악으로 보다 정교한 예측이 가능하며, 특히 CNN-LSTM은 미세 패턴까지 반영할 수 있는 장점이 있다[18].

Table 12. Comparison of structure and logic

구분	LSTM	GRU	CNN-LSTM
목적	시계열데이터 학습	LSTM의 구조 간소화	LSTM+Conv1D로 패턴추출
동작 원리	입력 과, 출력을 망각 게이트로 데이터의 흐름을 제어	업데이트 (z)와 리셋 (r)으로 데이터의 흐름 제어	Conv1D로 피쳐맵생성->차원축소->LSTM학습
연산 함수	Sequential([LSTM(64), Dense(1)])	Sequential([GRU(64), Dense(1)])	Sequential([Conv1D(32, kernel=3), MaxPooling1D(2), LSTM(64), Dense(1)])
특징	장기적 정보 보존이 가능하며 필요시 삭제	계산량은 적고 성능은 LSTM과 유사	급격한 단기 변동 패턴에 강하고 노이즈억제 효과

학습의 실행은 Jupyter Notebook Version 7.0.8, Jupyter Server 2.14.1 환경에서 Python 3.12 Version으로 수행하였으며, 삼성전자 NT960XGL-XD94G, Intel Core Ultra 9(CPU), 5.1GHz(Process), 64G LPDDR5 (Memory)모델에서 수행하였으며 수행된 학습조건은 Table 13과 같이 설정하였다.

Table 13. Common training condition (LSTM, GRU, CNN-LSTM)

항목	설정값
Inputs	VSM 시계열 0001~1000가구 평균
Prediction target day	DR+201일
Scaler	MinMaxScaler()로 0-1로 정규화
학습구간	DR+1일~DR+200일
반복구간	epochs=10
배치크기	batch_size=32
Optimizer	Loss Function ; MSE

VSM 데이터셋을 DR+201일차에 대하여 DR+200일까지의 전력사용량 데이터의 평균값을 기반으로 기존 VSM Data, CBL 예측데이터와 함께 LSTM, GRU, CNN-LSTM의 예측모델을 구현하였다.




Fig. 6. DR Prediction on DR+201 day

총 200,000개의 VSM 데이터 처리의 한계로 전체 데이터에서 VSM0001~VSM1000 가구를 샘플링으로 하였으며, 학습은 epochs=10으로 제한하였다.

학습을 수행한 결과 Fig. 6과 같이 기존의 CBL(Green)은 200일 기준 10 Day-Adjusted 기준 DR+201에 대한 1,000가구의 평균 부하 프로파일에 적용했을 때 실제 VSM 데이터(Black)에 비하여 08:00의 피크치 전력에서 가장 큰 예측 오차를 확인했다.

LSTM, GRU, CNN-LSTM모델은 DR+1일~ DR+200일까지의 데이터 학습으로 DR+201일에 대한 예측에서 약간의 예측 오류를 보였지만 08:00 기준 피크치에서 실제 데이터 VSM DR+201 곡선과 예측모델이 근접하고 있음을 확인할 수 있다.

Table 14. Comparison of MAE and RMSE

구분	MAE	RMSE
CBL	0.0732	0.0931
LSTM	0.0767	0.0996
GRU	0.0794	0.1012
CNN+LSTM	0.0775	0.0998

데이터의 오차를 각각의 예측모델 MAE와 RMSE로 비교한 Table 14의 결과 CBL이 Fig. 6에서 피크치 데이터 예측오류는 크지만 전체 평균 데이터 오차는 MAE(0.0732),

RMSE(0.0931)로 가장 낮게 기록하였다. LSTM은 MAE(0.0767), RMSE(0.0966)로 CBL보다 소폭 높았지만 피크구간에서 패턴 예측이 CBL보다 좀더 정밀하였으며 CNN-LSTM은 MAE (0.0775), RMSE(0.0998)로 LSTM 보다는 소폭 높았지만 GRU보다는 안정적인 예측 경향을 나타냈다.

6. 결 론

본 연구는 캐나다 퀘벡주의 단독주택 수용가로 설계된 VSM 데이터셋 기반의 전력수요예측 모델을 분석하고 이를 한국형 환경에 적용가능성을 연구하였다. VSM 데이터셋의 연구모델 구조와 CREST 기반 내부 부하 시뮬레이션을 통해, RSM 데이터의 한계를 극복하고 고해상도의 VSM 데이터셋 생성의 선행연구를 분석하고 이렇게 생성된 데이터를 AI 샘플링 학습으로 실제 전력현장에서 사용되는 CBL 예측모델과 비교분석하였다.

분석결과 기존에 산업현장에서 널리 사용되고 있는 CBL 예측모델과 AI기반 강화학습의 예측모델의 보안을 통해 수요 반응을 예측한다면 더욱 정밀한 예측이 가능할 수 있음을 확인하였다. 다만 VSM 데이터의 확률적 생성 방식과 건물 특성, 점유 패턴, 기후 조건 입력 변수의 차이, 캐나다와 대한민국 간의 지리적 한계, DR 및 DER 운영에 대한 파라미터 등이 보완된다면 국내 주택용 전력시장에 부합되는 VSM 데이터셋의 구축이 가능할 것이다. 이는 VSM 데이터셋 활용은 개인정보의 보호와 관련하여 한층 강화된 데이터 처리 방법으로, 실증 데이터 부족 문제를 보완하여 한국형 VSM 데이터셋의 구축 가능성의 확인은 중요한 정책적 의미가 있다.

향후 AMI 데이터와의 연계를 통해 주택용 요금제로 확대 적용될 예정인 계시요금제에 대비하여 한국형 VSM 모델 설계와 한국형VSM 실증모델 구축, 효율적인 DER/DR 운영 알고리즘과 연계된 하이브리드형 예측모델 개발과 생성형 AI를 통한 학습기반의 성능검증 등의 후속 연구로 발전 가능할 것이다.

Acknowledgement

본 연구는 한성대학교 학술연구비 지원과제임.

References

- [1] J. Y. Jeong, "A study on the operation direction and economic feasibility of power demand response based on the participation in the DR market of residential ESS," Master's Thesis, Department of Electrical Engineering, Gachon University, 2024.
- [2] Korea Energy News, "Environmental changes and opportunity factors in the demand response (DR) market," [online].

- Available: <http://www.keaj.kr/news/articleView.html?idxno=4900> (Accessed 16 Feb. 2023)
- [3] Electric Times, “After the end of the public-private AMI deployment project... the next step is collaboration of various services,” [online]. Available: <https://www.electimes.com/news/articleView.html?idxno=337390> (Accessed 23 May 2024)
- [4] J. M. Lee, “Development of a real-time based peak-shaving algorithm for consumer-installed ESS,” Master’s Thesis, Department of Electrical and Electronic Engineering, Hongik University, 2019.
- [5] Korea Technology Finance Corporation, “Analysis of strategic products: Smart meters (AMI),” [online]. Available: https://tb.kibo.or.kr/ktbs/board/tech-trend/tech_trend.do?mode=download&articleNo=563&attachNo=1441 (Accessed 27 May 2025)
- [6] S. Han, “An analysis of the impact of weather factors on residential electricity consumption using AMI data in Korea,” Ph.D. Thesis, Department of Economics, Soongsil University, 2024.
- [7] A. Neale, “Development of a bottom-up white-box residential building stock energy model for Québec single-family dwellings,” Ph.D. Thesis, PolyPublic Institutional Repository, Polytechnique Montréal, 2021.
- [8] A. Neale, M. Kummert, and M. Bernier, “Linear discriminant analysis for classification of a large virtual smart meter data set with known building parameters,” in *Proc. of 16th IBPSA international Conference and Exhibition*, pp. 3393-3400, 2019.
- [9] Korea Power Exchange, “Concept and current status of demand response systems,” [online]. Available: https://www.kpx.or.kr/boardDownload.es?bid=0045&list_no=51262&seq=16199 (Accessed 23 May 2024)
- [10] K. B. Han, “A study on the operation strategy of energy storage systems for real-time load management,” Master’s Thesis, Department of Electrical Engineering, Dong-A University, 2020.
- [11] S. G. Kang and S. G. Kim, “Log generation and collection methods for smart meters to respond to security breach incidents,” *Korea Institute of Information Security & Cryptology*, vol. 24, no. 5, pp. 66-74, 2014.
- [12] J. Y. Lee, et al., “Implementation of a smart meter applying power consumption prediction based on GRU model,” *Journal of the Korea Internet, Broadcasting and Communication(IIBC)*, vol. 19, no. 5, pp. 93-99, 2019.
- [13] Wikipedia Contributors, “Canada,” [online]. Available: <https://ko.wikipedia.org/wiki/Canada> (Accessed 27 May 2025)
- [14] Wikipedia Contributors, “Republic of Korea,” [online]. Available: <https://ko.wikipedia.org/wiki/Korea> (Accessed 27 May 2025)
- [15] Korea Electric Power Corporation, “Online KEPCO,” [online]. Available: <https://online.kepcoco.kr> (Accessed 27 May 2025)
- [16] Ontario Energy Board, “OEB Electricity rate,” [online]. Available: <http://www.oeb.ca/consumer-information-and-protection/electricity-rates#types> (Accessed 27 May 2025)
- [17] Y. J. Heo and J. H. Kim, “Trends and analysis ; Time-of-use (TOU) pricing trends for residential customers in the U.S. and Canada and implications for Korea,” pp. 90-103, [online]. Available : https://www.keei.re.kr/keei/download/focus/ef2310/ef2310_80.pdf (Accessed 27 May 2025)
- [18] J. M. Ko, I. K. Yang, and J. J. Song, “A study on Forecasting method for Short-Term Demand Forecasting of Customer’s Electric Demand,” *Journal of the Korean Institute of Electrical Engineers*, vol. 58, no. 1, pp. 1-6, 2008.

Biography



Jae-Chun Kim

He is a Ph.D. Candidate, Department of Smart Convergence Consulting, Hansung University. He received the B.S. degree in Electrical Engineering from Kwangwoon University, Korea, in 1992. He received M.S. degree in Graduate School of Business Administration from Dankook University, Korea, in 2023. His research interests are microgrid and VPP on electricity.



Kwang-Hyun Ro

He is a Professor, Department of Applied Artificial Intelligence, Hansung University. He received his B.S. degree in Industrial Engineering from Korea University, South Korea, in 1995. He received his M.S. degree in Industrial Engineering from Korea University in 1997. He received his Ph.D. degree in Industrial Engineering from Korea University in 2001. His research interests include smart mobility and AI application technology.