산업용 냉동창고의 LSTM 기반 소비전력 동적 부하 예측 연구

구남혁*, 지형용**, †

1. 서 론

탄소중립 및 에너지 효율 향상 요구가 확대됨에 따라, 산업용 냉동창고와 같은 에너지 다소비 시설의 운영 최적화가 기술적 과제로 부각되고 있다[1]. 냉동창고의 소비전력은 외기 및 실내 온도, 출입문 개폐, 재고량, 제상 및 냉동기 운전상태 등 다양한 요인의 영향을 받으며, 시간에 따라 복합적이고 비선형적으로 변화한다. 따라서 기존의 정적 열부하 계산 또는 선형 회귀 기반 접근만으로는 실제 운전 조건에서 발생하는 동적 부하 변동을 정밀하게 예측하는 데 한계가 있다[2, 3]. 모든 운전 변수를 실시간으로 계측하기 위해서는 인프라 구축 및 유지관리 비용이 증가하며, 과도한 입력변수 확장은 다중공선성(Multicollinearity) 문제를 유발하여 모델의 과적합 및 일반화 성능 저하로 이어질 수 있다. 따라서 현장 적용성을 고려한 예측모델에서는 취득이 용이하면서도 부하 변동과 상관성이 높은 핵심 변수를 선별하는 것이 중요하다[4-6].

본 연구에서는 산업용 냉동창고에서 장기간 수집한 현장 계측 데이터와 외기 기상 데이터를 활용하여 LSTM(Long Short-Term Memory) 기반 소비전력 예측모델을 구축하였다. 소비전력 데이터가 지닌 시계열적 장기 의존성(Long-term dependency)을 효과적으로 학습하기 위해 LSTM을 채택하였다. 특히 복잡한 신경망 구조를 지양하고 연산 부하를 최소화하여, 실시간 현장 제어에 활용될 수 있는 실용적인 예측모델을 개발하는 데 연구의 목적을 두었다. 이를 위해 실내외 온도 및 시간 주기성 등 현장 적용성이 높은 핵심 변수를 중심으로 데이터셋을 구성하였으며, K-fold 교차검증 및 앙상블(Ensemble) 기법을 적용하여 모델의 예측 정확도와 일반화 성능을 검토하였다.

2. 본 론

2-1. 냉동창고 데이터 수집 및 구성

본 연구의 실증 대상은 전라북도 전주시에 위치한 상업용 냉동창고로, 창고 면적은 약 1,690 m^2이며 내부 온도는 −18℃ 조건으로 운영된다. 주요 냉동 설비는 55 kW급 2대와 37 kW급 1대로 구성되어 있으며, 연간 누적 전력 소비량은 약 570,000 kWh 수준이다. 시계열 데이터 확보를 위해 대상 시설에 열전대(Thermocouple) 및 전력량계를 설치하고, 데이터 로거를 이용하여 내부 온도와 냉동설비의 소비전력을 1분 단위로 수집하였다.

* 한국생산기술연구원 지속가능기술연구소지역산업혁신부문 / 자체인턴 / koonh20@gmail.com
** 한국생산기술연구원 지속가능기술연구소 지역산업혁신부문(배출저감) / 선임연구원 / jhyong@kitech.re.kr / 교신저자

외부 기상 조건은 기상청 종관기상관측(ASOS) 자료를 활용하여 외기온도를 입력변수로 반영하여, 학습 데이터셋의 종속 변수는 소비전력으로, 독립 변수는 외기 온도, 내부 온도, 시간 주기성으로 설정하였다. 시간 및 계절에 따른 냉동창고의 소비전력 변화 패턴을 분석하기 위해 Python 3.13.5 기반의 시각화 라이브러리 Seaborn을 이용하여 히트맵을 작성하였다. 림 1은 원본 데이터(a)와 이상치 제거 후 데이터(b)의 히트맵을 나타내며, 이를 통해 약 18개월 동안의 소비전력 변화와 계절적 주기성을 확인할 수 있다.

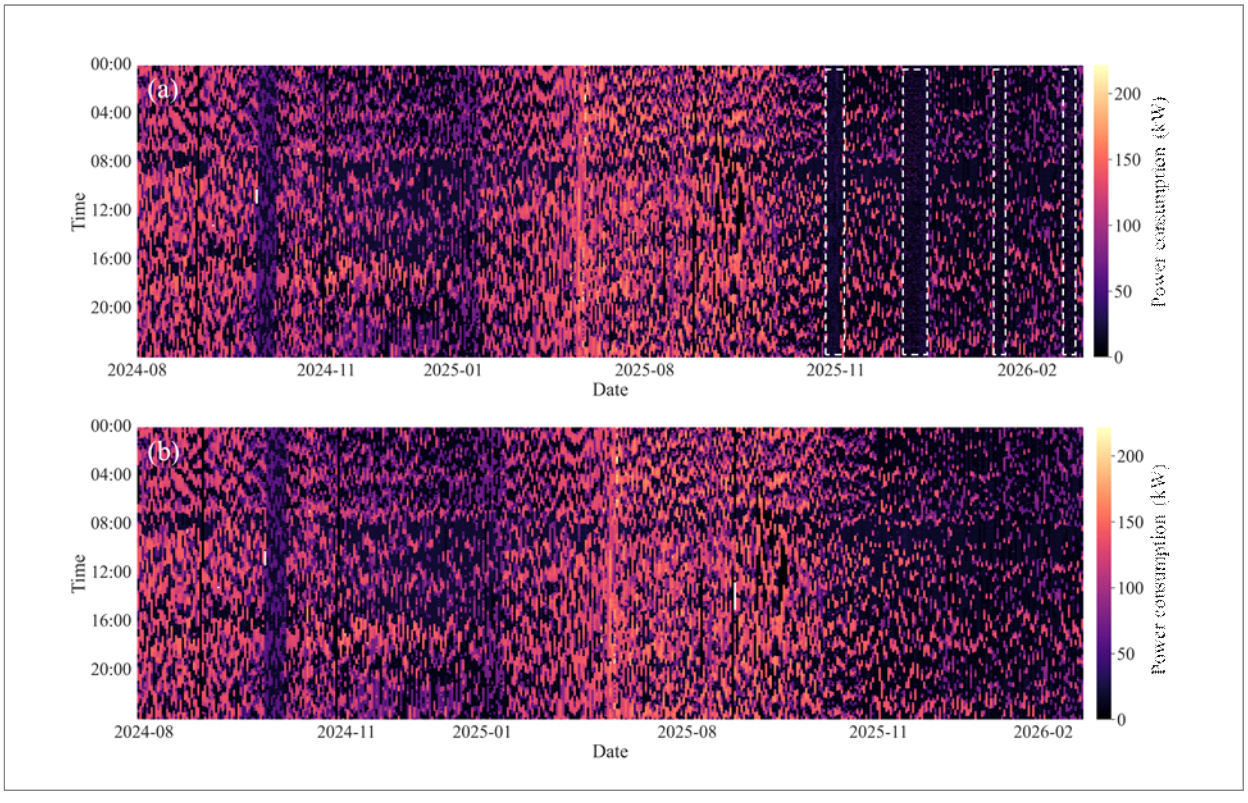


그림 1. 소비전력 측정값의 연간 일별 시간당 히트맵: (a)원본 데이터, (b)이상치 제거

표 1 예측모델의 학습 환경 및 하이퍼파라미터

Epoch	100	Scheduler	ReduceLROnPlateau (factor=0.5, patience=3)
Batch size	64	Early stopping	Patience=10
Optimizer	Adam(lr=0.001)	Dropout	0.2
Loss function	MSE	LSTM Hidden size	64, 32

센서 오류 또는 단기 결측으로 판단되는 구간은 선형보간(Linear interpolation)을 통해 보정하였다. 대기전력의 판단을 위해 Random Forest 군집화를 진행하였을 때 평균 7.91 kW의 대기전력 추정 구간을 확인하여 8 kW 이하의 소비전력 값은 이상치로 간주하여 제거하였다. 이후 입력 변수 간의 스케일 차이를

조정하기 위해 MinMaxScaler를 이용해 정규화(Normalization)하였으며, 시간 주기성은 시간과 분 단위 정보를 사인 및 코사인 함수로 치환하는 순환 연속형 변환(Cyclical encoding)을 적용하여 모델이 시간적 흐름을 인식할 수 있도록 반영하였다.

LSTM 모델은 시계열 데이터의 장기 의존성과 비선형 변동성을 학습하기 위해 적용하였다. 표 1과 같이 입력 데이터는 슬라이딩 윈도우 방식으로 시퀀스를 구성하였으며, 입력 길이는 과거 16분으로 설정하고 1분 후의 소비전력을 예측하도록 하였다. 모델의 학습 및 검증을 위해 Train, Validation, Test 데이터셋은 시간 순서를 유지한 상태에서 70:15:15의 비율로 분할하였다. 또한 2차원 형태의 원시 데이터를 LSTM 입력 구조에 적합한 3차원 배열(시퀀스 수×시간 단계×변수 수, Samples×Time steps×Features) 형태로 변환하였다. 예측모델은 두 개의 LSTM 은닉 계층과 출력층으로 구성하였으며, 각 LSTM 계층의 hidden size는 각각 64와 32로 설정하였다. 학습 과정에서는 평균제곱오차(MSE)를 손실함수로 사용하고 Adam optimizer를 적용하였고, 과적합을 완화하고 학습 안정성을 확보하기 위해 dropout, early stopping 및 ReduceLROn -Plateau 기반 학습률 조정 기법을 적용하였다.

표 2 LSTM-Kfold 예측모델 구성

Model type	Features	To what	Epoch
Model 1	M1: LSTM-Kfold model	Overall power consumption forecasting	199(Fold=5) Sec/epoch: 15.1
Model 2	M2-1: ≤5℃ (row:96,886) M2-2: 5~20℃ (row:242,410) M2-3: ≥20℃ (row:271,368)	Forecasting under the low-, moderate-, and high-temperature conditions	each 169, 163, 269 (Fold=5) Sec/epoch: 4.88

본 연구에서는 냉동창고 소비전력의 동적 예측을 위해 전체 시계열 데이터를 대상으로 한 LSTM-Kfold 모델(M1)과 외기온도 조건을 반영한 기온 구간별 LSTM-Kfold 모델(M2)을 구성하였다. LSTM-Kfold 모델은 TimeSeriesSplit 기반 K-fold 교차검증과 검증 손실 기반 가중 앙상블을 적용하여 장기 시계열 데이터의 시간적 연속성과 일반화 성능을 확보하도록 설계하였다. 표 2에 명시된 바와 같이 fold 수는 5회로 설정하였다. 표 1의 설정에 따라 개별 fold 학습에 각각 100 epoch를 할당하여 5회 fold에 대한 총 누적 학습은 500 epoch로 수행되었으며, 표 2의 수치는 이를 합산하여 표기한 것이다. 기온 구간별 LSTM-Kfold 모델은 데이터 셋을 외기온도 기준 5℃ 이하(M2-1), 5-20℃(M2-2), 20℃ 이상(M2-3)의 세 구간으로 분류하고[7, 8] 동일한 학습 구조를 적용하여, 계절성 외기온도 조건이 예측 성능에 미치는 영향을 분석하고자 하였다. 모델 성능은 R^2, RMSE, MAE 및 MAPE를 통해 분석하였다.

2-2. 예측모델 학습 결과 및 분석

그림 2의 실제값-예측값 산점도에서 모든 모델은 대체로 1:1 기준선(빨간 점선)을 중심으로 분포하여 소비전력의 전반적인 수준을 비교적 안정적으로 예측하는 것으로 나타났다. 그림 2는 테스트 구간의 실제값-예측값 산점도 및 주변분포를 나타낸다. 대부분의 데이터는 1:1 기준선 주변에 집중되어 전반적인 예측 일치도를 보였으나, 일부 운전 조건에서는 현장 데이터의 변동성으로 인한 산포가 확인되었다. 다만 M1에서는 저부하 구간의 수평·수직 산포와 중·고부하 영역의 분산이 관찰되어, 단일 모델이 다양한 운전상태를 동시에 설명하는 데 한계가 있음을 보였다. 기온 구간별 M2 모델에서는 M2-1, M2-2 및 M2-3 모두 기준선 주변에 비교적 조밀한 분포를 나타냈으나, 이는 기온 구간별 학습 효과와 함께 데이터의 부하 범위 및 분산이 축소된 영향도 함께 반영된 결과로 판단된다. 특히 M2-3은 다른 구간에 비해 기준선 주변의 산포가 상대적으로 크게 나타나, 하절기 고부하 조건에서 소비전력의 변동성과 예측 불확실성이 증가하는 경향을 확인하였다. 그림 3은 각 모델의 테스트 구간에서 실제 소비전력과 예측 소비전력을 비교한 시계열 결과이다. 정량적 성능 평가는 전체 테스트 데이터셋을 대상으로 수행하였으나, 전체 구간을 하나의 그래프로 제시할 경우 데이터가 과도하게 압축되어 단기 부하 변동과 모델의 추종 특성을 식별하기 어렵다. 이에 본 연구에서는 시계열 예측 특성을 비교하기 위해 각 테스트 데이터셋의 마지막 1,000개 시점을 확대하였다. 여기서 M2-1, M2-2 및 M2-3은 각각 저온, 중온 및 고온 외기온도 구간에 해당하므로, 외기온도 조건에 따른 시계열 예측 거동의 차이를 비교할 수 있다. 산점도에서 확인한 전반적 일치도와 함께, 시계열 비교에서도 제안된 모델들은 냉동설비의 기동·정지에 따른 급격한 부하 상승과 기저부하로의 복귀 패턴을 대체로 추종하였다.

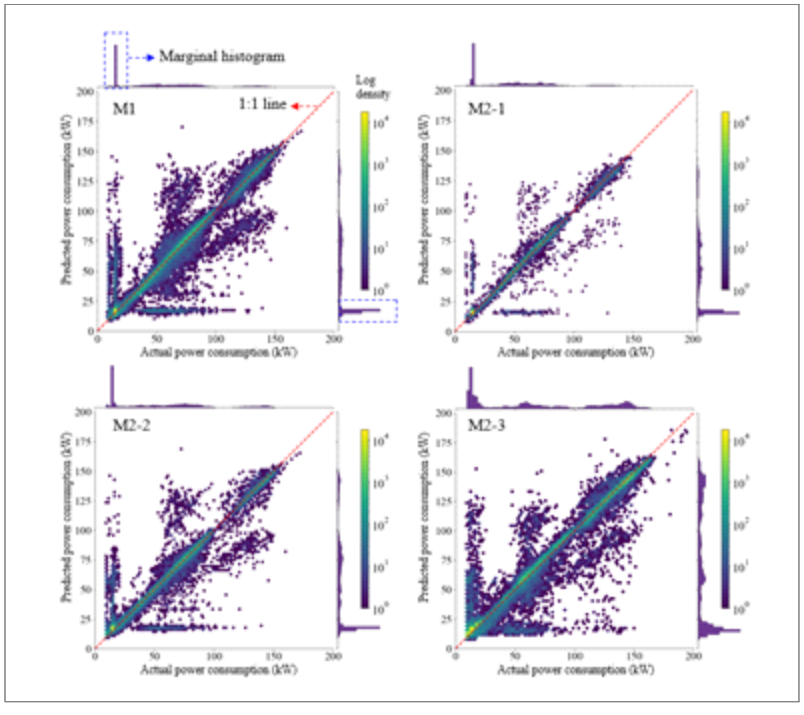


그림 2. 모델별 소비전력 예측 산점도 및 주변부 히스토그램

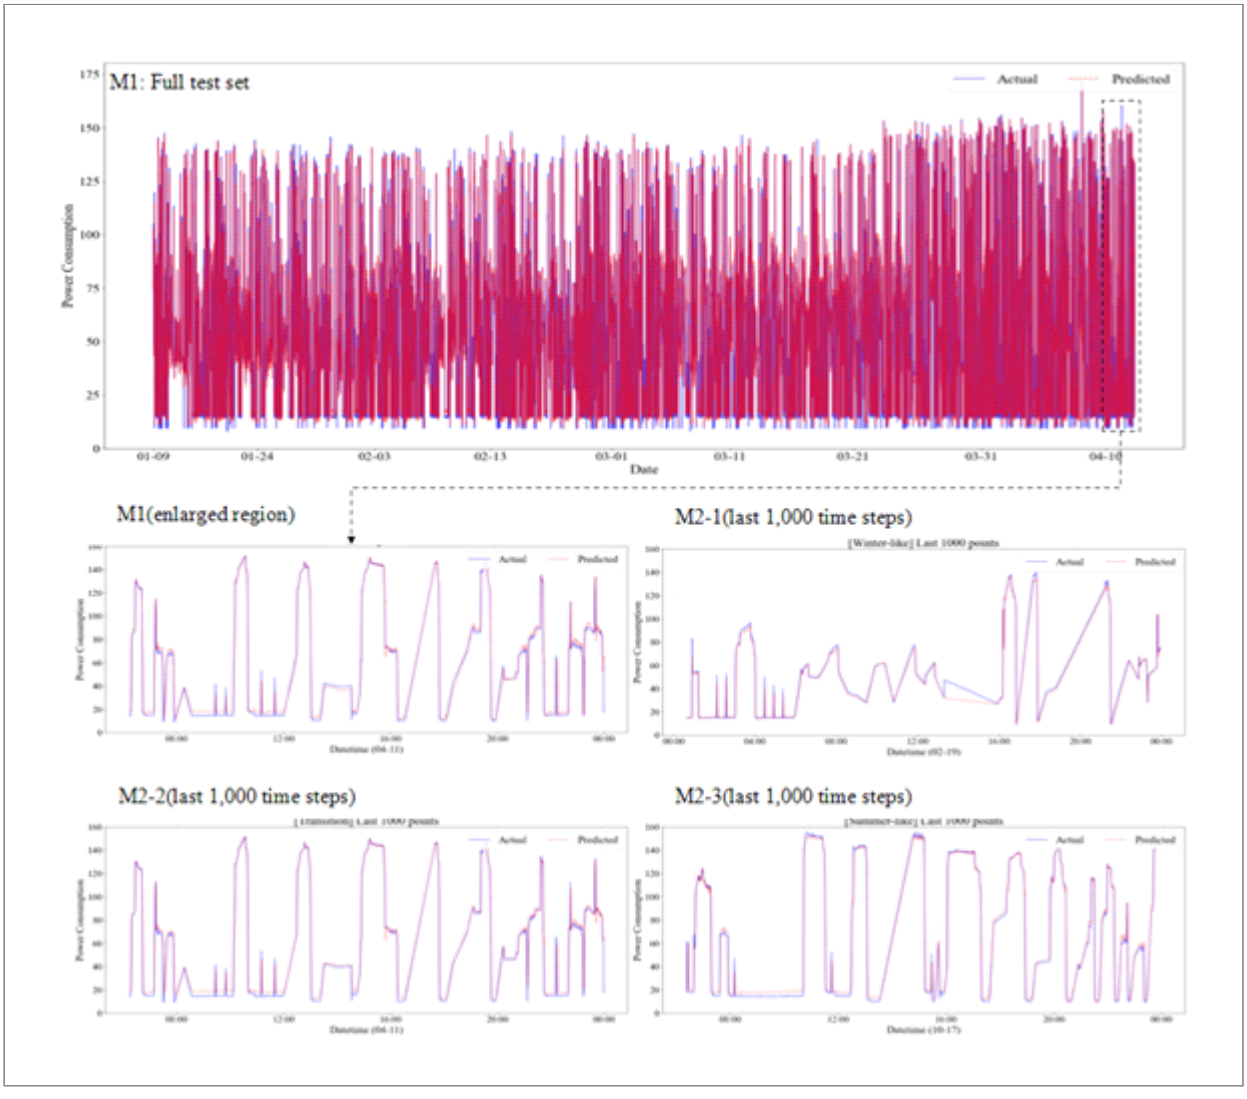


그림 3. 전체 테스트 구간 및 최근 1,000개 시점에 대한 실제 소비전력과 예측값 비교

표 3은 테스트 구간에서 산정한 LSTM-Kfold 기반 M1 및 M2 모델의 정량적 예측 성능을 나타낸 것이다. M1은 R^2 0.945, MAPE 12.38%로 다양한 운전조건을 포함하는 통합 모델로서 안정적인 예측 성능을 보였다. 기온 구간별 M2 모델에서는 저온 구간인 M2-1에서 가장 낮은 오차율(MAPE 10.18%)이 확인된 반면, 고온 구간인 M2-3에서는 R^2가 높은 수준을 유지하였음에도 M2-1 및 M2-2에 비해 MAPE와 RMSE가 증가하였다. 이는 하절기 고부하 조건에서 소비전력 변동성과 예측 불확실성이 상대적으로 커지기 때문으로 판단된다. 각 기온 구간은 데이터 범위와 분산이 서로 다르므로, M2 모델의 성능지표는 모델 간 절대적 우열보다는 외기온도 조건에 따른 예측 특성 차이로 해석하는 것이 타당하다.

표 3 예측모델 성능지표

Model	R^2	MAPE(%)	RMSE(kW)	MAE(kW)
M1	0.945	12.38	8.871	3.624
M2-1	0.938	10.18	8.402	3.015
M2-2	0.941	14.45	9.831	3.943
M2-3	0.946	18.17	11.892	5.064

3. 결 론

본 연구에서는 산업용 냉동창고의 장기 계측데이터를 기반으로 LSTM-Kfold 기반 소비전력 예측모델을 구축하고, 외기온도 구간에 따른 예측 특성을 분석하였다. 냉동창고 소비전력은 단일한 선형 관계보다는 외기온도 및 계절적 운전 조건에 따라 달라지는 비선형 부하 특성을 보였으며, 제한된 현장 계측 변수만으로도 소비전력의 주요 변동 경향과 피크 부하 패턴을 예측할 수 있음을 확인하였다. 향후 문 개폐, 제상, 냉동기 운전대수, 재고량 및 입출고 이벤트 등의 운전 변수를 추가 반영할 경우, 고온기 및 과도부하 조건에서의 예측 정확도를 향상시킬 수 있을 것으로 기대된다. 본 예측모델은 냉동기 운전조건 최적화, 피크전력 저감 및 에너지 관리시스템 연계 제어를 위한 기초 모델로 활용될 수 있다.

참고문헌

[1] Kamath, D., Nimbalkar, S., Price, C., Wenning, T., Cresko, J., Sustainability, 15(12), 2023, 9487

[2] Marchi, B., Zanoni, S., Sustainability, 14(18), 2022, 11137

[3] Cai, H., Zhang, Y., Zhang, J., Chen, J., Liu, J., Xu, J., Electronics 15(1), 2026, 160

[4] Kadir Amasyali, Nora M. El-Gohary, Renewable and Sustainable Energy Reviews, 81(1), 2018, 1192

[5] Petr Kadlec, Bogdan Gabrys, Sibylle Strandt, Computers & Chemical Engineering, 33(4), 2009, 795

[6] Yang Zhao, Tingting Li, Xuejun Zhang, Chaobo Zhang, Renewable and Sustainable Energy Reviews, 109, 2019, 85

[7] 기상청 기후정보포털, “계절길이,” 기상청, Available: https://climate.go.kr/home/CCS/contents_2021/influence/inf_2-1.php, accessed Sep. 3, 2026.

[8] Gwangyong Choi, Won-Tae Kwon, David A. Robinson, Journal of the Korean Geographical Society, 41(4), 2006, 435