

<http://dx.doi.org/10.17703/JCCT.2024.10.4.693>

JCCT 2024-7-81

산업단지 에너지 효율화를 위한 에너지 수요/공급 예측 및 시뮬레이터 UI 설계

Energy Demand/Supply Prediction and Simulator UI Design for Energy Efficiency in the Industrial Complex

이형아*, 박종혁**, 조우진**, 김동주**, 구재회***

Hyungah Lee*, Jong-hyeok Park**, Woojin Cho**, Dongju Kim**, Jae-hoi Gu***

요약 에너지 소비 문제가 전 세계적으로 주요한 이슈로 자리잡아 다양한 부문에서 에너지 소비 및 온실가스 배출 절감에 대한 관심이 크다. 2022년 3월 말 기준 국내 산업단지 총 면적은 606 km²로, 전체 국토면적의 약 0.6 %에 불과하다. 하지만 2018년 기준, 국내 산업단지의 연간 에너지 사용량은 국가 전체 에너지 사용량의 53.5 %, 전체 산업부문 에너지 사용량의 83.1 %를 차지하는 110,866.1천 TOE임으로 확인되었다. 더불어 국가 전체 온실가스 배출량의 45.1 %, 산업부문 온실가스 배출량의 76.8 %를 차지하여 환경에 미치고 있는 영향 또한 상당한 상황임이 확인하였다. 이러한 배경 하에 본 연구에서는 산업단지 차원의 에너지 효율화에 기여하고자, 국내 한 산업단지를 대상으로 에너지 수요 및 공급의 예측을 진행하였으며, 예측 결과값을 포함하여 에너지 모니터링을 위한 시뮬레이터 UI 화면을 설계하였다. 머신러닝 알고리즘 중 다층퍼셉트론 (Multi-Layer Perceptron; MLP)을 사용하였으며, 예측 모델의 최적화 기법으로서 베이지안 최적화 (Bayesian Optimization)를 적용하였다. 본 연구에서 구축한 예측 모델은 산업단지 내 압축공기 수요 유량의 경우는 87.90 %, 공용 공기압축기 공급 가능 유량의 경우는 99.54 %의 예측 정확도를 보였다.

주요어 : 산업단지, 에너지 수요/공급 예측, 시뮬레이터, 사용자 인터페이스, 베이지안 최적화

Abstract As of the end of March 2022, the total area of domestic industrial complexes is 606 km², which is only about 0.6% of the total land area. However, as of 2018, the annual energy consumption of domestic industrial complexes is 110,866.1 thousand TOE, accounting for 53.5% of the country's total energy consumption and 83.1% of the entire industrial sector energy consumption. In addition, industrial complexes have a significant impact on the environment, accounting for 45.1% of the country's total greenhouse gas emissions and 76.8% of industrial sector greenhouse gas emissions. Under this background, in this study, in order to contribute to the energy efficiency of industrial complexes, a prediction study on energy demand and supply for an industrial complex in Korea using machine learning was conducted. In addition, a simulator UI screen was designed to more efficiently convey information on energy demand/supply prediction results and energy consumption status. Among the machine learning algorithms, Multi-Layer Perceptron (MLP) was used, and Bayesian Optimization was applied as an optimization technique for the prediction model. The energy prediction model for the industrial complex built in this study showed a prediction accuracy of 87.90% for compressed air demand and 99.54% for the flow rate available for the public air compressor.

Key words : Industrial Complex, Energy Supply/Demand Prediction, Simulator, User Interface (UI), Bayesian Optimization

*정회원, 고등기술연구원 에너지환경IT융합그룹 연구원 (제1저자) Received: May 10, 2024 / Revised: May 30, 2024

**정회원, 고등기술연구원 에너지환경IT융합그룹 연구원

Accepted: June 15, 2024

(공저자)

***Corresponding Author: jaehoi@iae.re.kr

***정회원, 고등기술연구원 에너지환경IT융합그룹 연구위원

Institute for Advanced Engineering

(교신저자)

접수일: 2024년 5월 10일, 수정완료일: 2024년 5월 30일

게재확정일: 2024년 6월 15일

I. 서론

에너지 소비 문제가 전 세계적으로 주요한 이슈가 되면서 다양한 부문에서의 에너지 소비 및 온실가스 배출 절감에 대한 관심이 증대하고 있다. 국내 산업부문의 에너지 소비는 2016년부터 2019년까지 연평균 1.6%의 증가율을 보이며, 전체 에너지 소비의 60% 이상을 차지하고 있다[1][2]. 그 중 2022년 3월 말을 기준으로 전체 국토면적의 0.6% 정도에 불과한 상태인 국내 산업단지의 에너지 소비는 110,866.1천 TOE로, 국내 산업부문 에너지 사용량의 83.1%를 차지하고 있다. 또한 산업단지의 연간 에너지 사용량이 국가 전체 에너지 사용량의 53.5%를 차지하고 있는 상황이다. 더불어 국내 산업 부문 온실가스 배출량의 76.8%를 차지하고, 국가 전체 온실가스 배출량의 45.1%를 차지하여 산업단지가 환경에 미치고 있는 영향 또한 상당한 상태임을 알 수 있다[3].

산업단지는 산업시설과 해당 시설 종사자 및 이용자를 위한 지원 시설을 집단적으로 설치하기 위해 조성된 단지이다[4]. 이러한 산업단지는 산업활동에 필요한 각종 인프라의 공통적인 사용, 그리고 생산 및 공급망의 효율적인 관리와 운영을 통해 관련 시설의 집적으로 인한 시너지 효과를 갖고, 환경에의 영향을 최소화함에 주요 목적을 둔다. 하지만 대다수 산업단지에서 이러한 조성 목적과 이점을 활용하지 못하여 개별적인 운영이 이루어지고 있는 상태이며, 산업단지가 에너지 소비 및 환경에의 영향이 상당함에도 이에 대한 관리와 효율화 방안 마련이 제대로 이루어지고 있지 않은 상태이다[5]. 이에 '산업단지 에너지 공동 네트워크 플랜트' 또는 'VUP (Virtual Utility Plant)'와 같은 개념의 도입으로 공용의 고효율 유틸리티 생산설비 및 유사 에너지 관련 설비 등 인프라의 공용 활용, 에너지 공유 거래 및 에너지 거래의 안정화, 잉여 유틸리티 에너지의 공유, 통합 관리 등을 통한 산업단지 내 에너지 효율화가 기대되고 있다[6].

이러한 배경 하에 본 연구에서는 산업단지 내의 에너지 거래 시스템에서 수요에 따른 효율적인 에너지 공급 가이드의 도출을 위해, 국내의 한 산업단지를 대상으로 에너지 수요 예측 및 공급 가능량 예측을 진행하였다. 또한 설비 및 배관의 시각화와 성능 평가 및 유지보수, 에너지 유틸리티 네트워크 라우팅 시뮬레이

션, 에너지 수요 및 공급 예측을 통한 최적 제어 등의 기능이 포함된 산업단지 VUP 플랫폼에 해당 예측 기능을 적용하기 위해 시뮬레이터 UI 화면을 구상·설계하였다. 에너지 수요 및 공급 예측에 있어서는 머신러닝을 활용하였으며, 에너지 및 환경 차원에서 가장 보편적으로 활용되고 있는 알고리즘 중 하나인 인공신경망 (Artificial Neural Network; ANN)의 층퍼셉트론 (Multi Layer Perceptron; MLP)[7][8]을 사용하였다. 예측 모델의 최적화 기법으로서 하이퍼파라미터의 오토 튜닝 방법 중 하나인 bayesian optimization을 적용하였다. 산업단지 압축공기 수요량 예측 모델 및 공용 공기 압축기 공급 가능량 예측 모델을 구축한 후, American Society of Heating, Refrigerating and Air-Conditioning Engineers (ASHRAE)[9] 및 US DOE Federal Energy Management Program (FEMP)[10]에서 제시하고 있는 예측 모델의 성능 기준을 참조하여 CvRMSE (Coefficient of Variation of Root-Mean-Square Error) 및 R2 (Coefficient of Determination)를 평가지표로서 각 예측 모델의 예측 성능을 확인하였다. 또한 각 예측 모델을 통해 도출된 예측값을 실제 계측된 값과의 비교를 통해 예측 정확도를 평가하였다.

에너지 수요량 및 공급량에 대한 예측은 효율적인 에너지 관리 및 운영에 있어 가장 기본이 되어야 할 단계 중 하나이다. 이에 본 연구의 결과는 산업단지에 실질적으로 적용하여 산업현장의 불필요한 에너지 낭비를 줄이고, VUP 플랫폼에 적용함으로써 효율적인 에너지 모니터링 및 관리에 기여할 것으로 기대된다.

II. 연구방법

1. 하이퍼파라미터 최적화

하이퍼파라미터는 머신러닝에서 개발자가 모델을 설계하면서 직접 조절해야 하는 부분으로 절대적인 최적값이 정해져 있지 않은 변수이다. 하이퍼파라미터의 설정을 통해 기계학습 모델의 성능이 크게 달라지며, 다른 설정값은 다른 기계학습 모델을 결정하게 된다. 하지만 모든 하이퍼파라미터 조합에 대해 세세히 파악하기에는 셀 수 없이 많은 수의 조합이 가능하며, 모든 조합이 호환되는 것이 아니다. 따라서 하이퍼파라미터의 최적 조합을 도출하는 것은 결코 단순하지 않은 작업으로 많은 연구자들에게 하이퍼파라미터 선정은 어

려운 과제 중 하나이다. 이에 본 연구에서는 모델 성능의 극대화에 보다 효과적으로 접근 가능한 하이퍼파라미터 오토튜닝 기법을 적용하였다. 하이퍼파라미터 오토튜닝에는 여러 방법이 있고, 그 중 주요 방법에는 Grid Search, Random Search, Hyperband, Genetic Algorithms, Bayesian Optimization 등이 있다[11].

(1) Grid Search

Grid Search는 Manual Search의 불안정성 해결을 위한 방법으로, 사전에 지정된 값들에 대해 가능한 하이퍼파라미터 값의 조합을 모두 시도해 최적의 조합을 찾는 방법이다. 직관적이고 간단한 방법이나, 탐색 공간이 커질수록 계산 비용이 기하급수적으로 커진다는 단점이 있다.

(2) Random Search

Random Search는 하이퍼파라미터 값 중에서 무작위로 일부를 선택해 시도하는 방법이다. Grid Search에 비해 계산 비용이 낮지만, 특정 영역은 자세히 탐색하지 못할 가능성으로 신뢰도가 부족하다.

(3) Hyperband

Hyperband은 다양한 하이퍼파라미터 조합에 대해 모델을 학습하고 성능이 좋은 일부 조합을 선택하는 방법이다. 초기 단계에서 불안정한 결과를 보일 수 있고, 설정에 따라 결과가 크게 달라질 수 있는 단점이 있다.

(4) Genetic Algorithms

Genetic Algorithms은 여러 세대에 걸쳐 하이퍼파라미터를 진화시키는 방법이다. 다양한 조합을 탐색하여 다양성을 유지할 수 있으나, 최적화 과정이 오래 걸릴 수 있다는 단점이 있다.

(5) Bayesian Optimization

Bayesian Optimization은 이전 시도 결과에 기반해 다음 시도할 하이퍼파라미터 값의 확률 분포를 업데이트하면서 최적의 조합을 찾는 방법이다. 초기에는 불안정한 성능을 보일 수 있으나, 값을 얻을 수 있는 어떠한 함수에나 적용이 가능하고 효율적으로 검색 공간을 탐색하여 적은 시도로 비교적 좋은 결과를 얻을 수 있다는 장점이 있다.

합리적 탐색이 가능한 bayesian optimization은 머신러닝 모델의 하이퍼파라미터 최적화 방법으로서 주로 사용되고 있다. 이에 본 연구에서도 bayesian optimization을 적용하였으며, 하이퍼파라미터 관련 선행 연구를 참조하여 연구 대상의 하이퍼파라미터 종류와 하이퍼파

라미터별 탐색 구간을 설정하였다.

2. 에너지 수요/공급 예측

에너지 수요 및 공급에 대한 예측은 에너지 사용 현황 모니터링과 더불어 에너지 효율화 방안 마련을 위해 가장 기본적으로 선행되어야 하는 부분이다. 에너지 수요 및 공급 예측을 통해 에너지의 생산과 공급을 위한 방안 마련이 가능하며, 효율적인 에너지 관리를 통해 불필요한 에너지 낭비를 줄일 수 있다.

이에 다양한 분야에서 데이터 분석, 통계 모델, 인공지능 등의 다양한 기법을 적용한 에너지 예측 관련 연구가 진행되고 있다. 그 중 확보된 데이터를 활용하여 확보된 데이터를 활용하여 사람이 찾기 어려운 데이터 간의 패턴과 관계를 찾아낼 수 있으며, 시간 및 비용 측면에서 실용적이며 우수한 성능을 보이는 머신러닝을 활용한 에너지 관련 예측 연구가 활발히 진행되고 있는 추세이다[12][13].

본 연구에서도 산업단지의 에너지 수요 및 공급 예측을 위해 머신러닝을 활용하였다. 또한 이러한 에너지 예측 결과 정보가 산업 현장에서 보다 효율적으로 활용될 수 있도록 시뮬레이터 UI의 화면을 설계하였다.

III. 산업단지 압축공기 수요량 예측

1. 수요 예측 모델 구축 환경

예측 모델은 에너지 예측 차원에서 가장 보편적으로 활용되고 있는 ANN의 일종인 MLP를 사용하였다. 예측 모델의 최적화를 위해 하이퍼파라미터 튜닝 방법 중 베이지안 최적화 기법을 적용하였다. 예측 모델의 개발 및 분석은 Python 3.9.7, Tensorflow 2.3.0, Keras 2.4.3, Sklearn 1.0.2, Pandas 1.4.1, Numpy 1.19.5, Matplotlib 3.5.1 환경에서 진행하였다. 훈련 데이터셋과 테스트 데이터셋을 8:2의 비율로 구성하였으며, 15분 단위의 데이터가 사용되었다. 15분 후의 전체 압축공기 수요량 (Nm³) 예측을 위해 산업단지 내 9개 기업 각각의 압축공기 사용량과 9개 기업 전체 사용량, 그리고 15분 전의 전체 사용량 데이터가 사용되었다. Figure 1은 수요 예측 모델의 구축 환경을 정리한 그림이다.

2. Bayesian Optimization 적용 대상 하이퍼파라미터 및 탐색 구간 설정

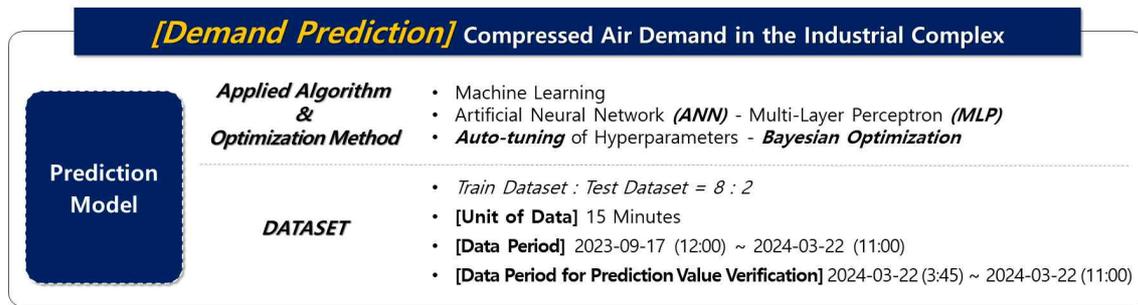


그림 1. 압축공기 수요량 예측 모델의 구축 환경
Figure 1. Construction Environment for Compressed Air Demand Prediction Model

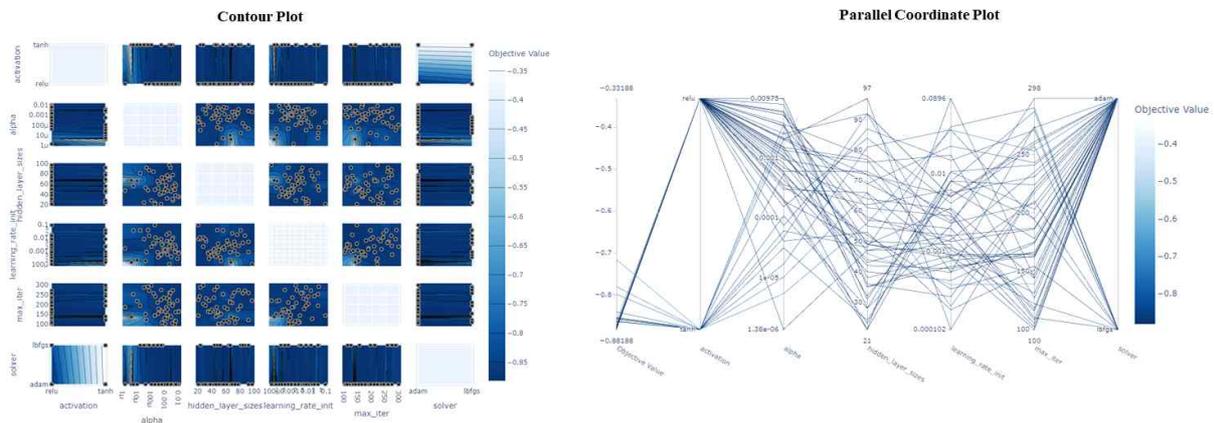


그림 2. [수요 예측] Contour Plot 및 Parallel Coordinate Plot
Figure 2. [Demand Prediction] Contour Plot and Parallel Coordinate Plot

하이퍼파라미터 최적화 기법 중 bayesian optimization 을 적용하였으며, 대상 하이퍼파라미터는 MLP의 주요 하이퍼파라미터에 해당하는 ‘hidden_layer_ sizes’, ‘activation’, ‘solver’, ‘alpha’, ‘learning_rate_init’, ‘max_ iter’ 여섯 가지를 선정하였다. Hidden layer sizes는 20 에서 100까지, activation는 relu와 tanh 중에서, 그리고 solver는 adam, lbfgs 중에서 탐색하도록 설정하였다. Alpha는 1e-06에서 1e-02까지, initial learning rate는 0.0001에서 0.1까지, 그리고 max iteration은 100에서 300까지의 구간을 탐색하도록 설정하였다.

3. Bayesian Optimization 적용 결과

Bayesian Optimization 적용 결과, hidden layer sizes는 100, activation은 relu, solver는 lbfgs가 최적 설정값으로 도출되었다. 또한 alpha는 1e-06, initial learning rate는 0.0001, max iteration은 266이 최적 설정값으로 도출되었다. Table 1은 하이퍼파라미터별 탐색 구간과 도출된 최적 설정값을 정리한 표이다.

표 1. [수요 예측] 하이퍼파라미터별 탐색 구간 및 최적 하이퍼파라미터 설정 조합

Table 1. [Demand Prediction] Search Range of Each Hyperparameter and Optimal Combination of Settings

No.	Hyperparameter	Search Range	Optimal Value
1.	Hidden Layer Sizes	20 ~ 100	100
2.	Activation	Relu, Tanh	Relu
3.	Solver	Adam, Lbfgs	Lbfgs
4.	Alpha	1e-06 ~ 1e-02	1e-06
5.	Initial Learning Rate	0.0001 ~ 0.1	0.0001
6.	Max Iteration	100 ~ 300	266

Bayesian optimization 적용을 통한 하이퍼파라미터 최적화 과정을 contour plots 및 parallel coordinate plot 으로 확인하였다. 이러한 시각화된 플롯들은 하이퍼파라미터의 최적의 값을 명확히 확인할 수는 없으나, 설정값의 변화에 따른 개략적인 영향을 확인할 수 있어 탐색 구간의 추가 조정 및 경향성 파악에 도움이 된다. Figure 2는 수요 예측 모델의 contour plot과 parallel coordinate plot이다. Contour plot은 두 개의 하이퍼파라미터 조합의 상호작용을 시각화 한 것이며, 등고선

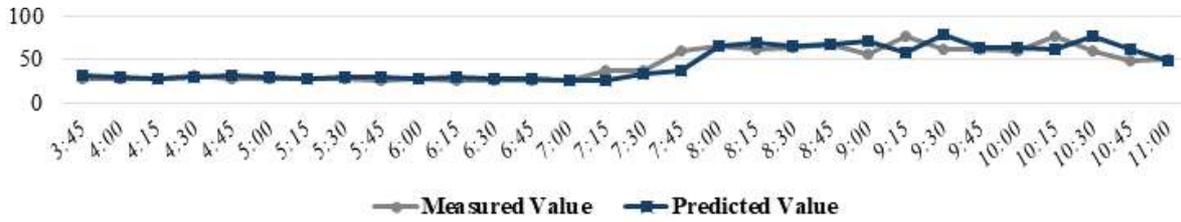


그림 3. [수요 예측] 실측값과 예측값의 비교 그래프
 Figure 3. [Demand Prediction] Comparison Graph of Measured and Predicted Values

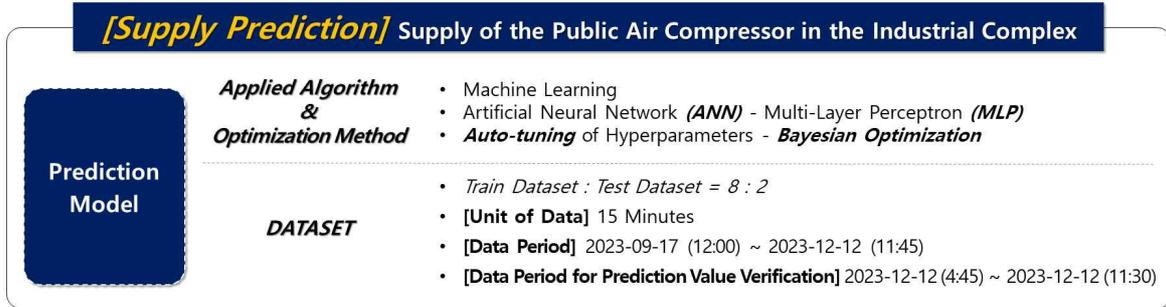


그림 4. 공용공압기 공급 가능량 예측 모델의 구축 환경
 Figure 4. Construction Environment for Public Air Compressor Supply Prediction Model

간격이 가깝고 색이 진한 부분이 최적의 하이퍼파라미터 조합이 있는 영역으로 해석할 수 있다. Parallel plot 은 여러 관측치의 값이 선으로 연결되어 있어 각 하이퍼파라미터가 목적함수에 미치는 영향을 보다 직관적으로 확인할 수 있는 것으로, 짙은 선의 부분이 최적의 하이퍼파라미터 설정값을 의미한다.

4. 압축공기 수요량 예측 결과

도출된 하이퍼파라미터 최적 설정값을 적용한 예측 모델의 예측 성능을 CvRMSE 및 R^2 로서 확인한 결과, CvRMSE는 약 16.75 %, R^2 는 약 87.98 %임을 확인하였다. 또한 30개 데이터에 대해 실측값과 예측 모델을 통한 예측값을 비교한 결과, 평균 예측 정확도가 87.89 %임을 확인하였다. 예측 정확도는 도출한 예측값에 대한 각각의 오차율 (Error rate)을 구하고, 평균 오차율 (Average error rate)를 기반으로 예측 정확도(Prediction Accuracy)를 계산하였다. 다음은 오차율 및 예측 정확도 계산식이다.

$$Error\ Rate = \frac{|Predicted\ Value - Measured\ Value|}{Measured\ Value} \times 100 (\%)$$

$$Prediction\ Accuracy = 100 - Average\ Error\ Rate (\%)$$

Figure 3은 실측값과 예측값을 비교하는 그래프이다.

IV. 산업단지 공용 공기압축기 공급량 예측

1. 공급 예측 모델 구축 환경

공급 예측 모델은 수요 예측 모델과 동일한 조건에서 개발 및 분석을 진행하였다. 15분 후의 공용공압기 공급 가능량 예측을 위해 산업단지 내 공유압축기 유량과 15분 전의 유량 데이터가 사용되었다. 그 외의 개발 및 분석 환경은 수요 예측과 동일하다. 다음은 공급 예측 모델의 구축 환경을 정리한 그림이다 (Figure 4).

2. Bayesian Optimization 적용 대상 하이퍼파라미터 및 탐색 구간 설정

수요 예측 모델과 마찬가지로 공급 예측 모델에도 하이퍼파라미터 최적화 기법 중 bayesian optimization을 적용하였으며, 대상 하이퍼파라미터는 MLP의 주요 하이퍼파라미터에 해당하는 'hidden_layer_sizes', 'activation', 'solver', 'alpha', 'learning_rate_init', 'max_iter' 여섯 가지를 선정하였다. 하이퍼파라미터별 탐색 구간도 수요 예측 모델과 동일하게 설정하였다.

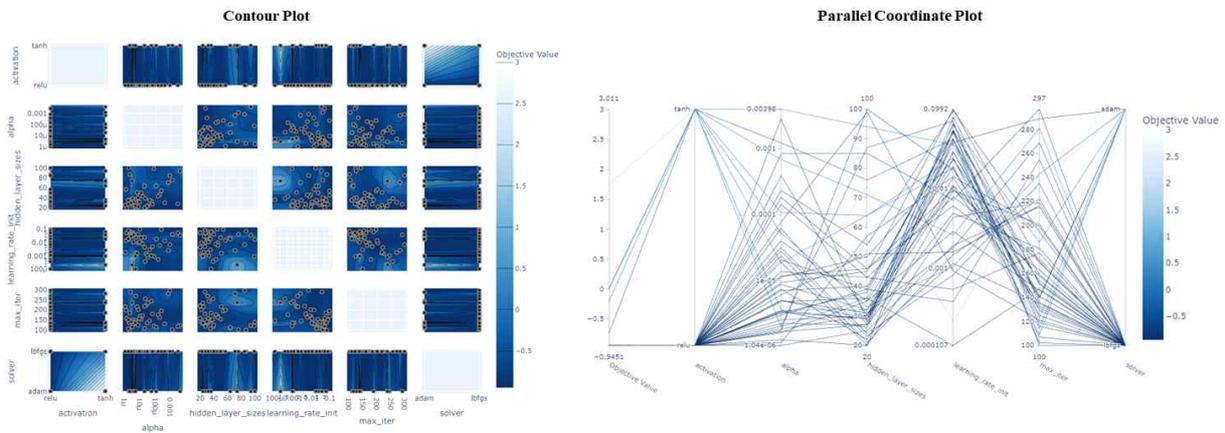


그림 5. [공급 예측] Contour Plot 및 Parallel Coordinate Plot
Figure 5. [Supply Prediction] Contour Plot and Parallel Coordinate Plot

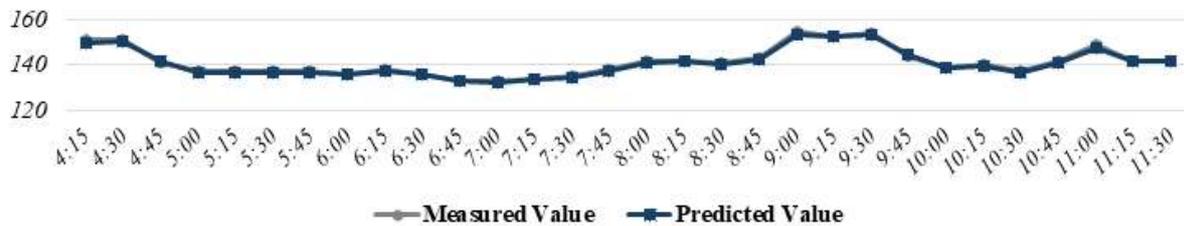


그림 6. [공급 예측] 실측값과 예측값의 비교 그래프
Figure 6. [Supply Prediction] Comparison Graph of Measured and Predicted Values

3. Bayesian Optimization 적용 결과

Bayesian Optimization 적용 결과, hidden layer sizes는 25, activation은 relu, solver는 lbfgs가 최적 설정값으로 도출되었다. 또한 alpha는 1e-06, initial learning rate는 0.1, max iteration은 100이 최적 설정값으로 도출되었다. Table 2는 하이퍼파라미터별 탐색 구간과 도출된 최적 설정값을 정리한 표이다.

표 2. [공급 예측] 하이퍼파라미터별 탐색 구간 및 최적 하이퍼파라미터 설정 조합

Table 2. [Supply Prediction] Search Range of Each Hyperparameter and Optimal Combination of Settings

No.	Hyperparameter	Search Range	Optimal Value
1.	Hidden Layer Sizes	20 ~ 100	25
2.	Activation	Relu, Tanh	Relu
3.	Solver	Adam, Lbfgs	Lbfgs
4.	Alpha	1e-06 ~ 1e-02	1e-06
5.	Initial Learning Rate	0.0001 ~ 0.1	0.1
6.	Max Iteration	100 ~ 300	100

Bayesian optimization 적용을 통한 하이퍼파라미터 최적화 과정을 contour plots 및 parallel coordinate plot

으로 확인하였다. Figure 5는 공급 예측 모델의 contour plot과 parallel coordinate plot이다.

4. 공용 공기압축기 공급량 예측 결과

도출된 하이퍼파라미터 최적 설정값을 적용한 예측 모델의 예측 성능을 CvRMSE (Coefficient of Variation of Root-Mean-Square Error) 및 R^2 (Coefficient of Determination)로서 확인한 결과, CvRMSE는 약 5.87%, R^2 는 약 94.40%임을 확인하였다. 또한 30개 데이터에 대해 실측값과 예측 모델을 통한 예측값을 비교한 결과, 평균 예측 정확도가 99.54%임을 확인하였다. Figure 6은 실측값과 예측값을 비교하는 그래프이다.

V. 에너지 수요/공급 예측 시뮬레이터 UI 설계

에너지 예측과 관련된 연구가 활발히 진행되고 있으나, 이를 활용하는 방안에 대한 연구는 비교적 미비한 상태이다. 본 연구에서는 산업 현장에서 이와 같은 예



그림 7. 시뮬레이터 UI 화면 설계 - 수요 예측 화면
 Figure 7. Design of Simulator UI - Screen for Demand Prediction

너지 수요 및 공급 예측 결과 정보가 보다 효율적으로 활용될 수 있도록 시뮬레이터 UI 화면을 설계하였다. Figure 7은 에너지 사용량 모니터링 화면(a), 에너지 사용량 예측 결과 화면(b), 그리고 에너지 사용량 예측의 정확도 분석 화면(c)의 예시화면이다. 에너지 사용량 모니터링 화면에서 산업단지, 확인하고자 하는 에너지 종류, 조회 단위(15분 단위, 일 단위 등), 조회하고자 하는 사이트(개별 기업, 또는 산업단지 전체)를 선택할 수 있고, 전 일의 사용량 현황과 오늘 현 시점까지의 사용량 현황을 확인할 수 있다. 에너지 사용량 예측 결과 화면에서도 산업단지, 확인하고자 하는 에너지 종류, 조회 단위, 조회하고자 하는 사이트를 선택할 수 있으며, 에너지 사용량 예측값과 누적 예측 정확도를 확인할 수 있다. 예측 정확도 분석 화면에서도 산업단지, 확인하고자 하는 에너지 종류, 조회 단위, 조회하고자 하는 사이트를 선택할 수 있으며, 분석하고자 하는 기간을 선택할 수 있다. 선택한 기간에 대한 에너지 실측값과 예측값의 막대 그래프로서 직관적 비교가 가능하며, 각 일자의 예측 오차율과 조회 기간의 평균 예측 오차율과 평균 예측 정확도를 확인하고 엑셀 파일로 다운로드할 수 있도록 구성하였다.

VI. 결론

본 연구에서는 산업단지 내 에너지 수요 및 공급 예측을 위해 머신러닝 MLP 알고리즘을 활용하였다. 각각의 예측 모델에 bayesian optimization을 적용하여 에너지 수요 및 공급 예측을 진행하였다. 더불어 이러한 예측 정보의 실질적인 활용을 위해 시뮬레이터 UI 화면을 구상하였다. 연구 결과, 산업단지 압축공기 수요량 예측 모델의 경우는 CvRMSE 16.75 %, R^2 87.98 %이며, 실측값과 예측값의 비교에서 87.90 %의 예측 정확도를 보였다. 또한 산업단지 공용 공기압축기 공급량 예측 모델의 경우는 CvRMSE 5.87 %, R^2 94.40 %이며, 실측값과 예측값의 비교에서 99.54 %의 예측 정확도를 보였다.

본 연구의 결과는 VUP 플랫폼 등을 통한 산업단지에의 적용으로, 산업현장의 불필요한 에너지 낭비를 줄이고 보다 효율적인 에너지 관리 및 운영을 도모할 수 있을 것으로 기대된다. 후속 연구에서는 추가적인 모델 고도화 작업과 예측값 도출의 자동화 기능을 추가함으로써 연구를 보완하고자 한다.

References

- [1] Ministry of Trade, Industry and Energy (MOTIE), “2020 Energy Survey Results”, 2022, <http://english.motie.kr/www.main.do>
- [2] Hyungah Lee, Dongju Kim, Jae-Hoi Gu, “Prediction of Food Factory Energy Consumption in Using MLP and SVR Algorithms”, *Energies*, 16(3), 1550, 2023, <https://doi.org/10.3390/en16031550>
- [3] SK ecoplant NEWSROOM, “The reason why industrial complexes are centers of carbon neutrality - How far has the Industrial Complex ‘Green New Deal’ come?”, 2022, <https://news.skecoplant.com/plant-tomorrow/3079/>
- [4] Doopedia, “산업단지”, <https://terms.naver.com/entry.naver?docId=1063507&cid=40942&categoryId=31868>
- [5] Woojin Cho, Jae-hoi Gu, “Evaluation of Edge-Based Data Collection System through Time Series Data Optimization Techniques and Universal Benchmark Development”, *The Journal of the Convergence on Culture Technology (JCCT)*, 10(1), 453-458, 2024, <http://dx.doi.org/10.17703/JCCT.2024.10.1.453>
- [6] Chul Hee Cho, ‘Energy Saving Transaction Network Establishment of Industrial Complex and Integrated Design Method’, *Journal of Energy Engineering*, 32(2), 11-22, 2023, <https://doi.org/10.5855/ENERGY.2023.32.2.011>
- [7] Jason Runge, Rada Zmeureanu, “Forecasting Energy Use in Buildings Using Artificial Neural Networks: A Review”, *Energies*, 12(17), 3254, 2019, <https://doi.org/10.3390/en12173254>
- [8] Sahuck Oh, “Comparison of a Response Surface Method and Artificial Neural Network in Predicting the Aerodynamic Performance of a Wind Turbine Airfoil and Its Optimization”, *Applied Sciences*, 10(18), 6277, 2020, <https://doi.org/10.3390/app10186277>
- [9] ASHRAE (American Society of Heating, Refrigerating and Air Conditioning Engineers), “ASHRAE Guideline 14: Measurement of Energy and Demand Savings”; ASHRAE: Atlanta, GA, USA, 4 - 165, 2022
- [10] Efficiency Valuation Organization, “International Performance Measurement & Verification Protocol; EVO: North Georgia, AL”, USA, 2016
- [11] Hyungah Lee, Woojin Cho, Jong-hyeok Park, Jae-hoi Gu, “Predicting Liquid Natural Gas Consumption via the Multilayer Perceptron Algorithm Using Bayesian Hyperparameter Autotuning”, *Energies*, 17(10), 2290, 2024, <https://doi.org/10.3390/en17102290>
- [12] Hyungah Lee, Dongju Kim, Woojin Cho, “Optimization of Energy Consumption Prediction Model of Food Factory based on LSTM for Application to FEMS”, *Journal of Environmental & Energy Engineering*, 18(1), 7-19, 2023, <https://doi.org/10.55079/jtee.2023.18.1.7>
- [13] Miguel Martínez Comesaña, Lara Febrero-Garrido, Francisco Troncoso-Pastoriza, Javier Martínez-Torres, “Prediction of Building’s Thermal Performance Using LSTM and MLP Neural Networks”, *Applied Sciences*, 10(21), 7439, 2020, <https://doi.org/10.3390/app10217439>

※ 본 연구는 산업통상자원부(MOTIE)의 재원으로 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구입니다. (No.2020202900170)