

공장 전력 절감을 위한 인공지능 기반의 에너지 관리 시스템 개발

누머너브 일리요스벡 라크힘전 우글리¹, 평보¹, 리 앤시아², 울다셰프 이자틸로², 이태오³, 김태국^{4*}

¹국립부경대학교 인공지능융합학과 학생, ²국립부경대학교 컴퓨터공학과 학생,
³국립부경대학교 컴퓨터·인공지능공학부 학생, ⁴국립부경대학교 컴퓨터·인공지능공학부 교수

Development of an AI-Based Energy Management System for Factory Power Saving

Ilyosbek Rakhimjon-Ugli Numonov¹, Bo Peng¹, Yanxia Li²,
Yuldashev Izzatillo Hakimjon Ugli², TaeO Lee³, Tae-Kook Kim^{4*}

¹Student, Department of Artificial Intelligence Convergence, Pukyong National University

²Student, Department of Computer Engineering, Pukyong National University

³Student, School of Computer and Artificial Intelligence Engineering, Pukyong National University

⁴Professor, School of Computer and Artificial Intelligence Engineering, Pukyong National University

요약 본 연구는 IoT 센싱 기술을 활용하여 구축된 빅데이터 수집 시스템을 통해 제주삼다수 공장에서 생성된 데이터를 활용하여 피크 전력 사용을 예측하는 인공지능 모델을 개발하고 비교 분석하였다. LSTM(Long Short-Term Memory) 모델은 단일 변수 시계열 데이터에서 $R^2=0.98$, RMSE=0.039, MAE=0.026으로 가장 높은 예측 정확도를 기록하였으며, XGBoost(eXtreme Gradient Boosting) 모델은 다변량 데이터를 효과적으로 처리하며 $R^2=0.93$, RMSE=0.018, MAE=0.013의 성능을 보였다. 연구 과정에서 다양한 데이터 전처리 방법과 특징 조합을 실험적으로 적용하여 모델의 성능을 최적화하였으며, 이를 통해 데이터 전처리와 변수 선택이 예측 정확도에 미치는 영향을 입증하였다. 연구 결과, 최적화된 인공지능 모델을 활용한 피크 전력 예측은 전력 비용 절감과 약 10~15%의 탄소 배출 감소 효과를 달성할 수 있음을 제시하였다. 이는 ESG(환경, 사회, 지배구조) 경영을 목표로 하는 기업들에게 지속 가능성을 실현하기 위한 실질적이고 구체적인 전략을 제공하며, 제조업, 물류, 스마트 팩토리 등 다양한 산업 분야에서 예측 모델의 적용 가능성을 확인하였다.

주제어 : 사물인터넷, 인공지능, LSTM, XGBoost, 전력사용량 예측, 시계열 데이터 예측

Abstract In this paper, AI models for predicting peak power usage were developed and comparatively analyzed using data collected from the Jeju Samdasoo factory through a big data collection system based on IoT sensing technology. The LSTM (Long Short-Term Memory) model demonstrated the highest prediction accuracy for univariate time-series data, achieving an R^2 of 0.98, RMSE of 0.039, and MAE of 0.026. Meanwhile, the XGBoost (eXtreme Gradient Boosting) model effectively handled multivariate data, achieving an R^2 of 0.93, RMSE of 0.018, and MAE of 0.013. Various data preprocessing methods and feature combinations were experimentally applied to optimize model performance, highlighting the significant impact of preprocessing and variable selection on prediction accuracy. The findings suggest that optimized AI models for peak power prediction can reduce power costs and achieve approximately 10-15% reductions in carbon emissions. This study offers companies pursuing ESG (environmental, social, and governance) management practical and specific strategies for achieving sustainability, while demonstrating the applicability of the predictive model across various industries, including manufacturing, logistics, and smart factories.

Key Words : Internet of Things, Artificial Intelligence, LSTM, XGBoost, Power Usage Prediction, Time Series Data Prediction

본 논문은 2024년 데이터산업 분야 지식연계협력 교육과정 개설 및 PBL 지원사업 연구과제로 수행되었음.

*교신저자 : 김태국(king@pknu.ac.kr)

접수일: 2024년 11월 01일 수정일: 2024년 12월 06일 심사완료일: 2024년 12월 13일

1. 서론

현대 산업 사회에서 에너지 관리는 기업 운영에 있어 중요한 요소로 자리 잡았으며, 특히 피크 시간대의 전력 과소비는 기업의 경제적 부담을 증가시키는 핵심 요인 중 하나다. 대한민국은 1978년부터 피크 시간에 따른 기본요금 피크연동제를 도입하였고[1], 기업들은 매달 측정된 피크 전력 사용량과 직전 12개월 중의 하계(7월~9월) 및 동계(12월~2월) 피크 중 최고 피크를 기준으로 기본요금을 계산하게 된다. 이는 단 한 번의 높은 피크 전력 사용이 최대 1년간 높은 요금 부담을 초래할 수 있음을 의미하며, 이에 따라 기업들은 피크 전력을 효율적으로 관리할 필요성을 강하게 느끼고 있다.

본 연구는 공장의 피크 전력을 관리하여 에너지 관리 효율성을 높이고 경제적 부담을 줄일 수 있는 방안을 모색하였다. 첫째, 피크 전력의 예측과 제어를 통해 비용 절감 가능성을 분석하고, 둘째, ESG(환경(Environment), 사회(Social), 지배구조(Governance)) 경영을 위한 CO₂ 배출 저감 방안을 제시한다. 셋째, 시간대 및 요일별 전력 사용 패턴을 분석해 이상 전력 사용을 감지하고 이를 기반으로 비용 절감 방법을 논의한다. 마지막으로, 피크 전력 발생이 예상되는 경우 우선순위가 낮은 장비의 전력 사용을 자동으로 조정하여 피크 전력을 관리하는 방법을 검토한다. 제안한 시스템을 구현하고 검증하기 위해 제주특별자치도 개발공사 제주삼다수공장 데이터셋을 사용하였다. 제주삼다수는 대한민국의 생수 생산 브랜드 이름이다. 이 데이터셋은 2023년 01월 01일부터 2023년 09월 30일까지의 시간별 전력사용량을 제공한다[2]. 또한 제주도 제주시의 분별 날씨 데이터를 사용하였다[3].

2. 관련 연구

국내에서 전력 예측과 관리에 대한 다양한 연구가 활발히 이루어지고 있다[4, 5]. 하지만 현재까지 무료로 공개된 솔루션은 없으며, 기업들은 초기 도입 비용 문제로 인해 전력 예측 모델 도입에 어려움을 겪고 있다.

여러 연구자들에 의해 에너지 예측 모델과 에너지 관리 방안을 제시해 왔다. 중앙대학교의 지능형에너지산업융합학과 연구진은 딥러닝 회귀와 라쏘 회귀 등 머신러닝 기법을 활용해 6개월 데이터를 기반으로 3개월 간의 스팀 유량을 예측하는 연구를 진행했다. 이 연구는 스팀 구

매량을 적절하게 예측하는 데 유용하다는 결론을 도출했다[6]. 또한, 고등기술연구원의 에너지환경IT융합그룹에서는 LSTM(Long Short-Term Memory, LSTM)[7, 8] 기반 전력 부하 예측 시스템을 개발하여 에너지 절감 가능성을 확인하였다. 이 모델은 전처리된 데이터를 학습시켜 평균 오차 0.26의 높은 정확도를 보이며 RNN(Recurrent Neural Network) 보다 성능이 뛰어난 결과를 얻었다[9]. 또한 재생 에너지 통합을 고려한 전력 시스템 스케줄링을 위한 데이터 기반 다중 기간 최적 전력 흐름 논문에서는 LSTM-RNN을 활용해 재생 에너지 비중이 높은 전력 시스템의 다기간 최적 전력 흐름(MP-OPF)을 효율적으로 해결하는 방법을 제안하였다. MP-OPF 문제를 시퀀스-투-시퀀스 학습 문제로 공식화하여, 입력 데이터(부하 수요, 재생 에너지 생성량)를 출력 데이터(발전기 출력, 재생 가능한 에너지원 주입량)와 매핑하도록 LSTM-RNN을 훈련시켜 전력망 제약을 충족시키는 동시에 발전기의 경제적 전력 배분을 달성하였다[10].

3. 제안한 인공지능 시스템


3.1 데이터 전처리

인공지능 모델의 성능은 학습 데이터의 질에 크게 좌우되며, 특히 시계열 데이터를 다룰 때 데이터 전처리가 중요하다[11]. 날씨 데이터에는 기온, 누적 강수량, 풍향, 풍속, 기압, 습도, 일사량, 일조시간 등이 포함되었으며, 시간별 전력 사용량에 맞춰 60분 간격으로 평균값을 계산했다. 총 8개의 변수로 전력 사용량을 예측하기 위한 분석을 진행하였다.

3.2 모델 개발

3.2.1 LSTM

LSTM은 순환 신경망(Recurrent Neural Network, RNN)의 일종으로, 순차 데이터에서 장기적인 의존성을 효과적으로 학습할 수 있도록 설계된 모델이다[12]. Hochreiter와 Schmidhuber(1997)가 제안한 LSTM은 기존 RNN에서 흔히 발생하는 기울기 소실 문제(vanishing gradient problem)를 완화하기 위해 고안되었으며, 입력 게이트(input gate), 망각 게이트(forget gate), 출력 게이트(output gate)와 같은 게이팅 메커니즘을 통해 정보의 흐름을 조절한다 [Fig. 1].



[Fig. 1] LSTM model structure

가) 망각 게이트: 이전 숨겨진 상태와 현재 입력을 기반으로 셀 상태에서 버릴 정보를 결정한다.

$$\text{Forget gate } (f_1) = \text{Sigmoid}(W_f \cdot [h_0, x_1] + b_f) \quad (\text{식1})$$

나) 입력 게이트: 셀 상태에 새로 추가할 정보를 결정한다.

$$\text{Input gate } (i_1) = \text{Sigmoid}(W_i \cdot [h_0, x_1] + b_i) \quad (\text{식2})$$

$$\text{State update } (\hat{c}_1) = \tanh(W_g \cdot [h_0, x_1] + b_g) \quad (\text{식3})$$

다) 셀 상태: 네트워크의 기억 역할을 하며, 망각 게이트와 입력 게이트를 통해 적절히 조정된다.

$$\text{Cell state } (C_1) = f_1 \odot C_0 + i_1(t_1) \odot \hat{c}(t_1) \quad (\text{식4})$$

라) 출력 게이트: 다음 단계로 출력될 숨겨진 상태를 결정하여 이후 계산에 영향을 준다.

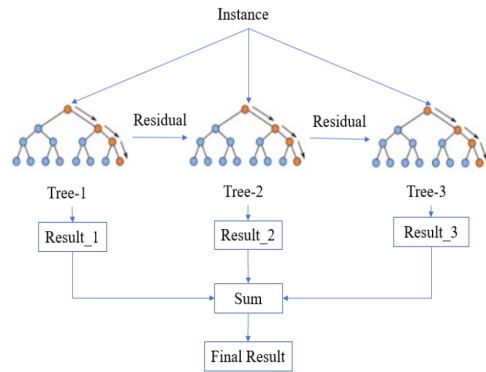
$$\text{Output gate } (o_1) = \text{Sigmoid}(W_o \cdot [h_0, x_1] + b_o) \quad (\text{식5})$$

바) 숨겨진 상태: 최종 출력으로, 이전의 셀 상태와 현재 입력 정보의 조합을 포함한다. 이 상태는 다음 시간 단계의 입력으로 사용된다.

$$\text{Hidden state } (h_1) = o_1 \odot \tanh(C_1) \quad (\text{식6})$$

3.2.2 XGBoost

XGBoost는 Gradient Boosting 알고리즘을 확장하여 고성능, 효율성, 유연성을 제공하는 기계 학습 모델이다[13]. Gradient Boosting은 약한 학습자(주로 의사결정 나무)를 순차적으로 결합하여 강력한 앙상블 모델을 생성하는 알고리즘으로, XGBoost는 이를 최적화하고 추가적인 기능을 통해 실제 문제에 더 적합하도록 개선하였다[Fig. 2].



[Fig. 2] Simplified structure of XGBoost[13]

가) 정규화 및 과적합 방지: XGBoost는 $L1$ 및 $L2$ 정규화를 사용하여 모델의 복잡성을 제어하고 과적합을 방지한다.

나) 병렬 처리: 분할 후보를 병렬로 계산하여 학습 속도를 크게 향상시킨다.

다) 소프트웨어 최적화: 캐시 최적화 및 세그먼트 기반 트리 학습을 통해 메모리 사용량과 계산 속도를 효율적으로 관리한다.

라) 스파스(sparse) 데이터 처리: 누락값과 희소 데이터를 효과적으로 처리하기 위한 전용 알고리즘이 내장되어 있다.

마) 커스텀 오브젝티브(Custom Objective): 사용자 정의 손실 함수와 평가 지표를 지원하여 다양한 문제에 유연하게 대응할 수 있다.

$$L(\phi) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (\text{식7})$$

3.2.3 특성 엔지니어링

Lag Feature는 과거의 데이터를 활용해 새로운 변수를 생성하는 중요한 기법[14]으로, 모델이 과거 데이터가

현재나 미래에 미치는 영향을 학습할 수 있게 한다. 반복되는 패턴과 주기를 잘 포착할 수 있다는 점이 장점 중 하나다. 과거 데이터가 미래 예측에 중요할 때, Lag Feature는 시간 의존성과 연속성을 모델에 반영해 성능을 향상시킨다[15]. 또한, 모델 성능을 최적화하기 위해 다양한 변수 조합을 고려하는 것이 중요하다. 모델은 이러한 다양한 feature 조합을 바탕으로 학습하고, 검증 데이터셋에서 성능을 평가하여 최적의 변수 조합을 자동으로 선택한다[16, 17]. 최종적으로 선택된 조합은 전력 사용량 예측에 있어 가장 유의미한 변수를 포함하게 되어, 예측 성능을 극대화한다.

3.3 최종 모델

각 모델이 최적의 입력 변수와 하이퍼파라미터를 자동으로 찾아내며 모델이 데이터 학습 중 발견한 최적의 하이퍼파라미터 조합을 저장한다. 이 값들을 통해 예측 정확도를 극대화하며, 학습된 모델의 성능을 향상시키는 데 기여했다. <Table 1>은 LSTM 모델을 위한 최적의 특성 집합을 나타낸다. 모델의 최적 하이퍼파라미터와 같이 이상치 제거 여부[18]와 입력 변수에 따라 모델의 성능 차이가 명확하게 나타난다. 원본 데이터에서는 'power', 'temp', 'wind_speed_ms', 'local_atmospheric_pressure_hPa', 'sea_level_pressure_hPa' 등 8개의 변수가 최적 입력 변수로 선택되었으며, 평

균 절대 퍼센트 오차(MAPE)는 0.062로 기록되었다. 반면, 이상치를 제거한 데이터에서는 'temp_lag1', 'temp_lag2', 'sea_level_pressure_hPa', 'sea_level_pressure_hPa_lag2', 'local_atmospheric_pressure_hPa_lag1', 'local_atmospheric_pressure_hPa_lag2' 등 6개의 변수가 선택되었으며, MAPE는 0.015로 낮아졌다. 이상치 제거가 모델의 예측 성능 향상에 크게 기여한 것으로 나타났다. 두 모델 모두 100번의 학습(epoch), 은닉층 크기(hidden_dim1, hidden_dim2) 128과 64, 드롭아웃 비율 0.2, 배치 크기 64로 동일하게 학습되었다. 이를 통해 LSTM 모델에서 이상치 제거와 최적의 하이퍼파라미터 조합이 성능 최적화에 중요한 요소임을 확인할 수 있다.

XGBoost 모델의 경우 <Table 2>에서 확인할 수 있듯이 이상치 제거 여부와 입력 변수에 따라 모델의 성능이 달라지는 것을 확인했다. 원본 데이터를 사용한 경우 'temp_lag1', 'temp_lag2', 'sea_level_pressure_hPa_lag1', 'sea_level_pressure_hPa_lag2', 'local_atmospheric_pressure_hPa_lag1', 'local_atmospheric_pressure_hPa_lag2'가 최적의 입력 변수로 선택되었으며, 평균 절대 퍼센트 오차(MAPE)는 0.019로 나타났다. 반면, 이상치를 제거한 데이터에서는 같은 입력 변수가 선택되었으나 MAPE는 0.036으로 오히려 성능이 감소하였다. 하이퍼파라미터 측면에서, 원본 데이터의 경우 'subsample'은 0.9, 'n_estimators'는 500, 'max_depth'는 9, 'learning_rate'는 0.05, 'colsample_bytree'는

<Table 1> Optimal feature set for LSTM model

LSTM		
Optimal feature set	Original data	Without outlier
	power	temp_lag1
	temp	temp_lag2
	wind_speed_ms	sea_level_pressure_hPa_lag1
	local_atmospheric_pressure_hPa	sea_level_pressure_hPa_lag2
	sea_level_pressure_hPa	local_atmospheric_pressure_hPa_lag1
	power_lag3	local_atmospheric_pressure_hPa_lag2
	wind_speed_ms_lag2	
	local_atmospheric_pressure_hPa_lag1	
MAPE	0.062	0.015
num_epochs	100	100
hidden_dim2	64	64
hidden_dim1	128	128
dropout_rate	0.2	0.2
batch_size	64	64

<Table 2> Optimal feature set for XGBoost model

XGBoost		
Optimal feature set	Original data	Without outlier
	temp_lag1	temp_lag1
	temp_lag2	temp_lag2
	sea_level_pressure_hPa_lag1	sea_level_pressure_hPa_lag1
	sea_level_pressure_hPa_lag2	sea_level_pressure_hPa_lag2
	local_atmospheric_pressure_hPa_lag1	local_atmospheric_pressure_hPa_lag1
	local_atmospheric_pressure_hPa_lag2	local_atmospheric_pressure_hPa_lag2
MAPE	0.019	0.036
subsample	0.9	0.8
n_estimators	500	200
max_depth	9	11
learning_rate	0.05	0.1
colsample_bytree	0.7	0.6

0.7로 설정된 반면, 이상치가 제거된 데이터에서는 `subsample` 0.8, `n_estimators` 200, `max_depth` 11, `learning_rate` 0.1, `colsample_bytree` 0.6으로 설정되었다. 이 설정은 각각의 데이터에 맞춰 최적화된 하이퍼파라미터 값으로, 모델의 일반화 성능을 높이는 데 기여한다. 이 결과를 통해 XGBoost 모델에서 이상치 제거가 항상 성능 향상에 기여하지는 않으며, 데이터의 특성과 하이퍼파라미터 조합이 모델 성능에 중요한 영향을 미친다는 점을 나타낸다.

최적의 하이퍼파라미터 조합을 사용한 예측 테스트 결과는 모델의 일반화 능력을 평가하는 중요한 단계라고 할 수 있다.

4. 모델 성능 평가

모델의 성능을 검증하기 위해서 다양한 성능지표를 사용하였다.


〈Table 3〉 LSTM Model performance

	LSTM			
	Multivariate model		Single variable model	
	Original data	Without outlier	Original data	Without outlier
epoch/train:test/s_eq_len	100/8:2/30	100/8:2/30	100/8:2/144	100/8:2/144
SSE	4.38	3.23	2.039	4.384
MSE	0.002	0.002	0.001	0.003
RMSE	0.047	0.045	0.039	0.06
MAE	0.037	0.042	0.026	0.044
R ²	0.96	0.66	0.98	0.76
MAPE	6.73	5.41	5.51	3.55
sMAPE	3.82	2.79	3.39	3.28

〈Table 4〉 XGBoost Model performance

	XGBoost			
	Multivariate model		Single variable model	
	Original data	Without outlier	Original data	Without outlier
N_ESTIMATORS	500	200	1000	1000
SSE	0.62	3.1	99795.9	98428.5
MSE	0.0003	0.002	0.058	0.057
RMSE	0.018	0.045	0.24	0.23
MAE	0.013	0.031	0.14	0.14
R ²	0.93	0.67	0.37	0.34
MAPE	1.73	3.85	54.67	57.76
sMAPE	0.87	1.98	12.41	12.29

〈Table 3〉은 〈Table 1〉에서 찾아낸 최적의 하이퍼파라미터 조합을 통해 구현이 된 LSTM 모델의 성능지표를 나타낸다. 원본 데이터를 사용한 LSTM 단일 변수 모델은 적합성 및 오류 지표 측면에서 가장 좋은 성능을 보였으며, 가장 높은 R²(0.98), 낮은 MSE(Mean Square Error), RMSE(Root Mean Squared Error), MAE(Mean Absolute Error)로 정확한 예측에 매우 적합함을 나타낸다. 〈Table 4〉는 〈Table 2〉에서 찾아낸 최적의 하이퍼파라미터 조합을 통해 구현된 XGBoost 모델의 성능지표를 나타낸다. XGBoost 다변량 모델의 성능이 좋았으며, 특히 이상치를 제거했을 때 오류율이 낮고 R²(0.93)이 높은 것으로 나타난다. 이 모델은 특히 다변량 시나리오에서 LSTM에 대한 경쟁력 있는 대안을 제시한다. 그러나 XGBoost 단일 변수 모델은 모든 구성에서 상당히 어려움을 겪었으며 오류가 매우 높고 R²가 낮아 이 맥락에서 단일 변수 예측 작업에 적합하지 않을 수 있음을 나타낸다.



〔Fig. 3〕 LSTM single model original data prediction visualization

결론적으로, LSTM과 XGBoost는 모두 잠재력을 보여주지만, 원본 데이터에 대한 LSTM 단일 변수 모델과 이상치가 없는 XGBoost 다변량 모델이 정확하고 신뢰할 수 있는 예측을 위한 가장 효과적인 접근 방식으로 나타났다. 예측 테스트 결과, 최적의 하이퍼파라미터 조합을 사용한 모델은 성능 지표에서 이전보다 개선된 결과를 보였다. 특히, MAPE와 sMAPE(symmetric mean absolute percentage error) 지표에서 오류율이 크게 감소하여, 모델이 데이터의 패턴을 더욱 정확히 유추하고 있음을 확인할 수 있었다. 이는 최적의 하이퍼파라미터 조합을 찾는 과정이 모델 성능 향상에 큰 영향을 나타냄을 보여준다.

5. 결론

본 연구는 기업의 피크 전력 관리를 개선하고, 효율적인 에너지 운영을 위한 전력 예측 시스템 모델을 검증하

였다. 제주삼다수공장 데이터를 바탕으로 LSTM 및 XGBoost 모델을 활용하여 피크 전력 예측을 수행하여, 다양한 데이터 조건에서 예측 성능을 비교 분석 하였다. 분석 결과, LSTM 단일 변수 모델은 원본 데이터 기준으로 R^2 값이 0.98, RMSE는 0.039, MAE는 0.026으로 모든 지표에서 가장 높은 예측 정확도를 나타냈다. XGBoost 다변량 모델은 원본 데이터에서 R^2 가 0.93, RMSE는 0.018, MAE는 0.013으로 다변량 시나리오에서 우수한 성능을 보였으며, 이 모델이 피크 전력 관리에 효과적인 대안이 될 수 있음을 시사한다. 반면, XGBoost 단일 변수 모델은 두 데이터 세트 모두에서 R^2 값이 0.34~0.37 수준으로 낮고, MAPE가 54.67을 초과하여 예측 정확도가 낮게 측정되었다.

이러한 결과를 통해, 기업은 최적의 예측 모델을 선택하여 피크 전력 사용량을 효율적으로 관리하고, 이에 따른 전력 비용 부담을 감소시킬 수 있는 전략을 수립할 수 있을 것으로 기대한다.

REFERENCES

- [1] Korea Electric Power Corporation introduces base rate peak-linking system[Internet], <https://home.kepco.co.kr/kepco/CY/K/htmlView/CYKAHP00301.do?menuCd=FN0207010103>.
- [2] Korea Public Data Portal. Jeju Special Self-Governing Province Development Corporation_Jeju Samdasoo Factory Hourly Power Consumption[Internet], <https://www.data.go.kr/data/15124355/fileData.do>
- [3] Korea. Korea Meteorological Administration Weather Data Open Portal, Asynoptic Surface Observation-Fileset[Internet], <https://data.kma.go.kr/data/grnd/selectAsosRltnList.do?pgmNo=36&tabNo=1>.
- [4] S.H.Kim, T.W.Heo, I.W.Lee, "Electricity Consumption Analysis and Prediction with Quality Control Charts in Factory Energy Management Systems," Proceedings of the Korean Institute of Electrical Engineers conference, 2023.
- [5] S.M.Yoo, S.W.Baek, J.M.Lim, CH.J.Moon, "A Study on the Construction of FEMS in Chemical Industrial Complexes," Journal of the Korea Institute of Electronics and Communication Engineering, Vol.18, No.2, pp.277-284, 2023.
- [6] J.W.Song, D.I.Ku, S.J.Bae, G.J.Seo, H.M.Yang, M.S.Kim, "A Study on the Prediction of Steam Usage in the Factory Energy Management System (FEMS) through Regression Analysis Model," Korean Society of Mechanical Engineers Spring and Autumn Conference, 2023.
- [7] W.Song, C.Gao, Y.Zhao, "A Time Series Data Filling Method Based on LSTM—Taking the Stem Moisture as an Example," Sensors, Vol.20, No.18, pp.5045, 2020.
- [8] M.T.Ngo, M.Ch.Dinh, V.Q.Dao, C.S.Kim, M.W.Park, "Design of a day-ahead power consumption prediction model for a factory energy management system based on long short-term memory and recurrent neural network," Proceedings of the Korean Institute of Electrical Engineers conference, 2022.
- [9] H.A.Lee, D.J.Kim, W.J.Cho, J.H.Gu, "Optimization of Energy Consumption Prediction Model of Food Factory based on LSTM for Application to FEMS," Journal of Environmental & Thermal Engineering, Vol.18, No.1, pp.7-19, 2023.
- [10] R.Zafar, I.Y.Chung, "Data-Driven Multiperiod Optimal Power Flow for Power System Scheduling Considering Renewable Energy Integration," in IEEE Access, Vol. 12, pp.95278-95290, 2024.
- [11] X.Wang, "Two-phase outlier detection in multivariate time series," Eighth International Conference on Fuzzy Systems and Knowledge Discovery (FSKD), Shanghai, China, pp.1555-1559, 2011.
- [12] V.Suresh, F.Aksan, P.Janik, T.Sikorski, B.S.Revathi, "Probabilistic LSTM-Autoencoder Based Hour-Ahead Solar Power Forecasting Model for Intra-Day Electricity Market Participation: A Polish Case Study," IEEE Access, Vol.10, pp.110628-110638, 2022.
- [13] W.Wang, G.Chakraborty, B.Chakraborty, "Predicting the Risk of Chronic Kidney Disease (CKD) Using Machine Learning Algorithm," Applied Science, Vol.11, No.1, pp.1-17, 2021.
- [14] L.Li, Y.Ou, Y.Wu, Q.Li, D.Chen, "Research on feature engineering for time series data mining," International Conference on Network Infrastructure and Digital Content (IC-NIDC), Guiyang, China, pp.431-435, 2018.
- [15] Y.Trardi, B.Ananou, P.Tchatchoua, M.Ouladsine, "Ensemble Machine Learning Algorithms for Anomaly Detection in Multivariate Time-Series," 2022 International Conference on Control, Automation and Diagnosis (ICCAD), Lisbon, Portugal, pp.1-6, 2022.
- [16] J.Y.Shin, J.H.Jeong, Y.T.Chae, "Performance Improvement Technique of Automatic Fault Detection and Diagnosis (AFDD) Module through Parameter Optimization of Artificial Neural Network Model," Journal of the Korean Society for Living Environment, Vol.31, No.4, pp.270-277, 2024.
- [17] A.Poornima, K.Archana, P.Dhivya, N.Sangavi, "LSTM with Bayesian Slide Optimization for Time Series Forecasting in Real Time," International Conference on Sustainable Computing and Data Communication Systems (ICSCDS), Erode, India, pp.774-777, 2023.
- [18] H.Y.Park, S.I.Seo, K.CH.Cho, J.W.Jang, S.J.Ki, "Performance Evaluation of Long and Short-Term

Memory Algorithms in Data Sets Including Missing Values," Journal of the Korean Society of Environmental Engineers, Vol.44, No.12, pp.636-642, 2022.

누머너브 일리요스벡 라크힘전 우글리
(Ilyosbek Rakhimjon-Ugli Numonov) [준회원]



- 2023년 8월 : 국립부경대학교 컴퓨터공학부(공학사)
- 2023년 9월 ~ 현재 : 국립부경대학교 인공지능융합학과 석사과정

<관심분야>
사물인터넷(IoT), 인공지능(AI)

펑 보(Bo Peng) [준회원]



- 2023년 2월 : 국립부경대학교 컴퓨터공학부(공학사)
- 2023년 3월 ~ 현재 : 국립부경대학교 인공지능융합학과 석사과정

<관심분야>
사물인터넷(IoT), 인공지능(AI)

리 앤시아(Yanxia Li) [준회원]



- 2023년 9월~ 현재 : 국립부경대학교 컴퓨터공학과 박사과정

<관심분야>
사물인터넷(IoT), 인공지능(AI)

율다셰프 이자틸로
(Yuldashev Izzatillo Hakimjon Ugli) [준회원]



- 2022년 6월 : Tashkent University Of Information Technologies 컴퓨터공학부(공학사)
- 2023년 9월 ~ 현재 : 국립부경대학교 컴퓨터공학과 석사과정

<관심분야>
딥러닝, 대형 언어 모델(LLM)

이 태 오(TaeO Lee) [준회원]



- 2020년 2월 ~ 현재 : 국립부경대학교 컴퓨터공학부 학사과정

<관심분야>
데이터 사이언스(DS), 인공지능(AI)

김 태 국(Tae-Kook Kim) [종신회원]



- 2004년 8월 : 고려대학교 전기전자전파공학부(공학사)
- 2006년 8월 : 고려대학교 메카트로닉스학과(공학석사)
- 2014년 8월 : 고려대학교 모바일솔루션학과(공학박사)

- 2016년 3월 ~ 2022년 2월 : 동명대학교 AI학부 교수
- 2022년 3월 ~ 현재 : 국립부경대학교 컴퓨터-인공지능공학부 교수

<관심분야>
사물인터넷(IoT), 콘텐츠 전송 네트워크(CDN), 이동성, 인공지능(AI), 빅데이터, 모바일 서비스