

# 머신러닝 기법을 이용한 로터리 킬른 공정의 질소산화물 배출예측에 관한 연구

유제형<sup>1</sup>, 박정열<sup>2</sup>, 배재권<sup>3\*</sup>

<sup>1</sup>서울과학기술대학교 경영학과 박사과정, <sup>2</sup>서울과학기술대학교 경영학과 부교수

<sup>3</sup>계명대학교 디지털경영학부 경영정보학전공 부교수

## A Study on the Prediction of Nitrogen Oxide Emissions in Rotary Kiln Process using Machine Learning

Je-Hyeung Yoo<sup>1</sup>, Cheong-Yeul Park<sup>2</sup>, Jae Kwon Bae<sup>3\*</sup>

<sup>1</sup>Ph.D. Candidate, Seoul Business School, aSSIST University

<sup>2</sup>Associate Professor, Seoul Business School, aSSIST University

<sup>3</sup>Associate Professor, Dept. of Management Information Systems, Keimyung University

**요약** 이차전지 시장의 확대에 따라 니켈 산화광을 로터리 킬른 및 전기로 공법을 이용하여 생산하는 공정이 전 세계적으로 확대되고 있는 상황이며 지속가능한 ESG 경영 확대에 따라 배출가스 내 질소산화물 등 대기오염물질 관리가 강화되고 있다. 건식니켈제련 공정의 주요 설비 중 하나인 로터리 킬른은 광석의 건조와 예비환원을 위한 설비이며 운전 중 질소산화물이 생성되므로 질소산화물 농도 예측 운전이 필요하다. 본 연구에서는 회귀 예측을 위한 LSTM 모델과 분류 예측을 위한 LightGBM 모델을 적용한 AutoML을 사용하여 모델을 최적화 하였다. LSTM을 적용 시 5분 후 예측 값은 상관계수 0.86, MAE 5.13ppm, 40분 후 예측 값은 상관계수 0.38, MAE 10.84ppm의 결과를 얻었다. 분류 예측을 위한 LightGBM 적용 결과 Test 정확도는 5분 후 0.75에서 40분 후 0.61로 상승하여 실제 조업에 활용할 수 있는 수준까지 상승되었고 AutoML을 통한 모델 최적화 결과 5분 후 예측 값의 정확도는 0.75에서 0.80까지, 40분 후의 예측 정확도는 0.61에서 0.70까지 향상되었다. 본 연구를 통해 로터리 킬른 질소산화물 예측 값을 실제 조업에 적용하여 대기오염물질 배출규제 준수 및 ESG 경영에 기여할 수 있다.

**키워드** : 로터리 킬른, RK-EF 공정, 질소산화물, 머신러닝, LSTM, LightGBM, AutoML

**Abstract** As the secondary battery market expands, the process of producing laterite ore using the rotary kiln and electric furnace method is expanding worldwide. As ESG management expands, the management of air pollutants such as nitrogen oxides in exhaust gases is strengthened. The rotary kiln, one of the main facilities of the pyrometallurgy process, is a facility for drying and preliminary reduction of ore, and it generate nitrogen oxides, thus prediction of nitrogen oxide is important. In this study, LSTM for regression prediction and LightGBM for classification prediction were used to predict and then model optimization was performed using AutoML. When applying LSTM, the predicted value after 5 minutes was 0.86, MAE 5.13ppm, and after 40 minutes, the predicted value was 0.38 and MAE 10.84ppm. As a result of applying LightGBM for classification prediction, the test accuracy rose from 0.75 after 5 minutes to 0.61 after 40 minutes, to a level that can be used for actual operation, and as a result of model optimization through AutoML, the accuracy of the prediction after 5 minutes improved from 0.75 to 0.80 and from 0.61 to 0.70. Through this study, nitrogen oxide prediction values can be applied to actual operations to contribute to compliance with air pollutant emission regulations and ESG management.

**Key Words** : Rotary kiln, RK-EF process, NOx, Machine learning, LSTM, LightGBM, AutoML

\*Corresponding Author : Jae Kwon Bae(jkbae99@kmu.ac.kr)

Received May 30, 2023

Accepted July 20, 2023

Revised June 26, 2023

Published July 28, 2023

## 1. 서론

로터리 킬른(Rotary Kiln)이란 회전로(回轉爐)라고도 하며, 강철제의 긴 원통 내부에 고온에 견딜 수 있는 내화물을 시공한 설비를 회전시키며 원료를 가열, 소성하기 위한 열원을 버너를 이용하여 공급하는 노(爐)이다[1]. 최근 이차전지의 주요 소재인 니켈을 생산하기 위해 니켈산화광을 이용한 로터리 킬른, 전기로(RK-EF) 공법을 이용한 투자가 인도네시아 등의 국가에서 활발하게 진행 중이다. 국내에는 2007년부터 포스코 그룹에서는 RK-EF 공법을 적용하여 페로니켈(Ferrronickel)을 생산하고 있다. 로터리 킬른은 니켈광석을 전기로에 장입하기 위해 소결광을 생산하는 예비 환원 공정이다. 로터리 킬른의 원료는 니켈 광석과 환원제이며, 환원제의 연소를 위해 미분탄을 버너에 투입하여 열원으로 공급한다. 버너 화염 선단의 고온에 의해 공기의 질소가 해리되는데, 이 때 해리된 질소는 연소 후 잉여 연소공기의 산소와 결합하여 질소산화물을 형성한다[2]. 질소산화물은 산성비의 원인이 되며 식물을 고사시키며 화학적 미세먼지를 형성하는 영향을 미치므로 환경부에서는 '대기관리권역의 대기환경개선에 관한 특별법'에 따라 주요 대기오염물질로 관리 중이며 질소산화물의 배출농도 및 총량 기준을 점차 축소하고 있다. 과거 이차전지용 니켈소재의 생산은 니켈 황화광을 사용하여 공급이 되었으나 최근 이차전지 소요량 증가에 따라 니켈산화광을 이용한 건식제련 공법으로 황산니켈의 원료인 니켈 매트(Nickel Matte)가 제조되고 있다[3]. RK-EF 공법을 이용하여 생산된 니켈은 친환경자동차 배터리의 핵심소재로 사용되며 ESG 경영의 국제적 확산기준에 따라 RK-EF 공법에서 발생하는 질소산화물을 줄이는 연구가 필요한 시점이다. 본 논문에서는 로터리 킬른 공정에서 질소산화물의 생성, 제거 메커니즘에 따라 배출가스의 질소산화물 농도를 최적으로 결정하기 위한 머신러닝 예측 기반의 제어 방법을 제시하고자 한다.

로터리 킬른 공정에서 발생하는 질소산화물 배출 메커니즘은 석탄의 특성, 공연비, 생산량, 환원제 투입량, 동체온도 등 여러 제어변수의 복합적인 영향관계에 있기 때문에 매우 복잡하여 전통적인 Programmable Logic Controller(PLC)를 이용하는 피드백 제어로는 구현하기 어려워 로터리 킬른에서 배출되는 질소산화물을 제어하는 방법은 운전 전문가의 경험을 기반 한 표준 업무 문서

에 근거하여 운전자 경험의 신뢰성에 크게 의존하고 있다. 로터리 킬른과 같은 열을 사용하는 대형 설비의 경우 24시간 연속 가동되기 때문에 수 개의 교대 근무조에 의해 운전된다. 조업은 표준 업무 절차에 따라 이루어지지만 운전자 성향 등 인적 편차의 영향을 배제할 수 없으며 광석 성상에도 편차가 존재하는 제련업의 특성상 AI 기반의 시스템 지능화가 더욱 필요하다. 따라서, 기존의 조업 방식으로는 로터리 킬른 공정에서 발생하는 질소산화물의 배출농도를 효과적으로 제어하기는 어렵다.

로터리 킬른을 대상으로 한 질소산화물 관련 선행 연구는 질소산화물의 발생을 저감하는 방안의 도출에 집중되었으며, 저 질소함량의 연료를 사용, 연소공기량 및 연료 사용량을 하향 조절하는 방안을 공통적으로 제시하고 있으나 자동제어를 위한 접근은 하지 않았다[4,5,6]. 머신러닝 기법을 적용한 질소산화물 예측 연구는 석탄 화력발전소를 중심으로 진행되었지만, 로터리 킬른과 달리 공정상 석탄연소를 통해 질소산화물이 생성될 뿐 제거되는 반응구조가 없기 때문에 실시간 예측을 통한 최적조업으로 질소산화물 배출농도를 저감하였다. 그러나, 본 논문에서는 머신러닝 기법으로 로터리 킬른의 40분 후 질소산화물 배출농도 예측을 통해 연료의 변경, 열효율 하락 없이 최적조업조건 도출로 건식 니켈 제련사의 ESG 경영에 기여하고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 로터리 킬른 공정, 질소산화물에 대한 선행연구 및 본 연구에서 사용하는 머신러닝 모델에 대해 설명한다. 3장에서는 연구 방법 및 분석절차를 다루고, 4장에서는 연구모형 설계 및 연구결과를 기술한 후, 5장에 결론과 시사점, 그리고 향후 연구방향에 대해 정리하였다.

## 2. 선행연구

### 2.1 로터리 킬른 공정

RK-EF 공법에서 로터리 킬른은 니켈광석의 부착, 결정수분을 모두 제거하고 다음공정인 전기로에서 소요되는 전력을 저감하기 위해 소결광의 온도를 높이는 공정이다(Fig. 1 참고).

로터리 킬른의 주요설비는 버너 시스템, 동체, 배가스 처리설비로 구분할 수 있다. 버너 시스템은 로터리 킬른 동체에 투입되는 니켈광석과 함께 투입되는 환원제의 연소를 위한 열을 공급하는 설비이다.




Fig. 1. Rotary kiln process

열원으로 LNG, Oil, 미분탄 등이 사용되며 화염의 선단온도는 약 1,600℃로 고온에 의해 해리된 질소는 잉여 연소공기의 산소와 결합하여 질소산화물을 형성한다[7]. 킬른 동체는 고온에서 작동할 수 있도록 내화물이 시공되어 있으며 경사지게 설치된 로터리 킬른은 회전을 통해 장입된 니켈광석은 건조, 예비환원 과정을 거친다. 일부 로터리 킬른에는 동체에 환원제를 별도로 투입할 수 있는 장치인 스쿱 피더(Scoop Feeder)를 보유하고 있다[8]. 스쿱 피더로 투입된 환원제는 로터리 킬른 고온대의 길이를 연장시켜주며 소결광의 예비환원 정도 및 온도를 상향하는데 효과가 있다. 이렇게 로터리 킬른 내부 환원제가 연소될 수 있는 적정 온도를 형성 시 버너에서 발생한 질소산화물을 재 환원할 수 있는 환원가스가 발생하여 최종 배출되는 질소산화물의 양을 줄일 수 있다. 마지막으로 로터리 킬른의 환원제로 사용되는 석탄의 황성분과 니켈광석에서 발생한 디스트를 처리하기 위한 환경처리설비를 운영한다. 환경처리설비 중 스크러버(Scrubber)를 이용하여 황화산화물은 효과적으로 제거 되지만 질소산화물은 제거되기 힘들기 때문에 머신러닝 모델링을 통한 질소산화물량의 제어가 필요하다.

## 2.2 질소산화물 예측을 위한 머신러닝 적용 선행 연구

석탄은 상대적으로 저렴하고 손쉽게 조달할 수 있는 열원이다. 우리나라는 2020년 기준 44%를 석탄 화력발전에 의해 전력을 생산하였으며[9], 중국은 2019년 기준 전력생산 중 70%를 석탄 화력발전에 의존하고 있다. 그러나 석탄의 연소는 다량의 질소산화물을 생성한다. 이 때문에 질소산화물 관련 머신러닝 AI 기법을 적용한 선행 연구는 대부분 석탄 화력발전소에서 질소산화물의 발생량을 줄이기 위해 진행되었다.

Derrick et al., 2020는 석탄 화력발전소에 심층신경망(DNN), Least Square Support Vector Machine

(LSSVM)을 적용하여 질소산화물의 배출을 비교 예측하였다[10]. 효율성 계수는 0.9921이었으며 예측시간은 LSSVM이 DNN대비 70.48% 감소되었다. Peng et al., 2016은 700MW급 석탄 화력발전소에 Extreme Learning Machine(ELM)을 적용하여 모델링 후 Harmony Search(HS)를 이용하여 모델을 최적화하여 질소산화물 발생량을 두 가지 경우에 대하여 각각 16.5%, 19.3% 저감할 수 있었다[11]. HS 모델링시간은 0.7초 소요되어 실시간 제어를 통해 질소산화물 발생량 저감이 가능하였다. Guotian et al., 2019은 660MW급 석탄화력발전소의 데이터를 Long Short-Term Memory(LSTM)로 모델링 후 Adam Optimizer를 이용하여 질소산화물 값을 최적화하는 모델링을 하였다[12]. LSSVM 모델대비 LSTM 모델은 정확도는 3.2배, 계산 시간은 24% 수준으로 단축하는 연구결과를 얻을 수 있었다. 앞에서 살펴본 선행연구는 머신러닝 기법을 석탄 화력발전소에 적용하여 질소산화물 실시간 예측제어를 위해 예측시간 단축에 집중하였다.

## 2.3 LSTM, LightGBM 이론

본 연구에서 LSTM은 질소산화물 값 예측에 LightGBM은 구간별 나누어진 구간에 예측된 질소산화물 값을 구분하기 위해 적용하였다.

### 2.3.1 LSTM(Long Short-Term Memory) 이론

Hochreiter and Schmidhuber (1997)에 의해 LSTM 모델이 개발된 후 일부 요소의 변형을 통해 LSTM의 전형적인 모델이 만들어졌다[13]. LSTM은 RNN(Recurrent Neural Network)의 일종으로 RNN은 오차정보가 과거 시점으로 역전파될 때 그레디언트가 급격하게 커지거나(Exploding) 소멸(Vanishing)되는 경향을 보인다. LSTM 모델은 하나의 Unit에서 계산된 단기간의 정보를 길게 전파하는 메모리 구조를 가짐으로써 기존의 RNN 보다 급

격하게 커지거나 소멸되는 그레디언트를 막으며 긴 시간 단계의 학습을 가능하게 한다. 장기기억 셀(Cell)인 Constant Error Carousel(CEC)을 도입하여 소멸 그레디언트를 막는다. 게이트를 사용하여 학습기반으로 입력, 출력 값을 자동으로 제어한다. 입력 값은 이전 유닛의 출력 값(ht-1)과 현재 단계의 입력 값(xt)을 Squash Function에 입력하여 출력된 값(Si)이 시그모이드(Sigmoid)를 통해 수식 2가 얼마나 셀 게이트(Cell Gate)로 들어가야 할지 결정한다.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + bias) \tag{1}$$

$$S_t = \text{squash}(W_c \cdot [h_{t-1}, x_t] + bias) \tag{2}$$

$$\text{squash} = \frac{4}{1 - e^{-z}} - 2 = 2 \cdot \tanh\left(\frac{x}{2}\right) \tag{3}$$

$$\text{sigmoid} = \frac{1}{1 + e^{-s}} \tag{4}$$

출력 값은 LSTM에서 유지되고 있는 셀 게이트 정보를 ht의 출력으로 내보내게 될 때 그 값에 대한 제어를 한다. Squash로 활성화된 셀(Cell) 정보를 이전 유닛의 출력 값(ht-1)과 현재 단계의 입력 값(xt)을 시그모이드(Sigmoid)를 통해 0과 1사이 값으로 조절한 후 수식 5의 ht값으로 출력(수식 6)한다.

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + bias) \tag{5}$$

$$h_t = O_t \times \text{squash}(C_t) \tag{6}$$

상기 두 개의 게이트를 통해서 LSTM은 장기적으로 유지되어야 할 셀 상태(Cell State)의 정보가 자동으로 업데이트 된 후 출력되어 장기기억 예측에 좋은 결과를 보여

주게 된다. 또한 Back Propagation Through Time (BPTT)와 Ream-Time Recurrent Learning(RTRL)의 변화(Variation)를 동시에 학습 사용하는 특징을 갖고 있다(Fig. 2 참고).

### 2.3.2 LightGBM 이론

기존의 의사결정나무(Decision Tree) 모델은 오버피팅(Overfitting)을 방지하기 위해 학습을 할 때 같은 단계에 있는 노드(Node)들을 모두 구분(Split)한 뒤에 다음 단계로 넘어가는 Level-Wise Tree Growth를 하는 Breadth-First Search 방법을 적용하였다. LightGBM은 Leaf-Wise Tree Growth를 적용하여 기존의 Gradient Boosting Model(GBM) 보다 빠르게 학습 할 수 있는 모델이다[14]. LightGBM은 전체 손실이 줄어드는 방향으로 노드를 선정하여 구분함으로써 기존의 GBM대비 빠른 학습이 가능하나 적은 데이터를 사용 시 오버피팅이 될 가능성이 높으며 최대 깊이(Depth)에 민감한 단점도 있다.

## 3. 연구방법 및 분석절차

### 3.1 데이터 수집 및 연구변수

본 연구에는 포스코 그룹의 건식 니켈 제련법인인 (주)에스엔엔씨의 2022년 9월 1일부터 2022년 12월 1일까지의 130,978개의 3개월 초 단위 조업 데이터를 이용하였다. 조업 전문가의 경험에 근거하여 종속변수인 로터리 킬른의 질소산화물의 농도를 예측하기 위해 모델링에는 광석 투입량, 펠렛 투입량, 환원용 석탄 투입량, 스크 피더 석탄 투입량, 미분탄 투입량, Discharge 압력, CO 농도, O2 농도, 로터리 킬른 동체 온도, 소성광 온도를 독립 변수로 사용하였다. 로터리 킬른에서 배출되는 질소산화

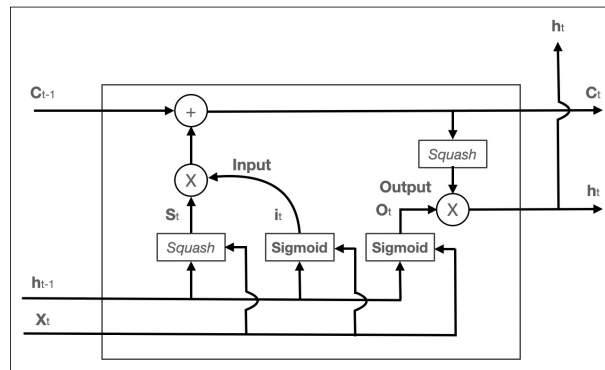


Fig. 2. Long short-term memory

물 농도는 버너 화염선단의 온도에 직접적 영향을 받기 때문에 미분탄량, Discharge 압력, O<sub>2</sub> 농도의 데이터의 독립변수 10개를 사용하였다. 질소산화물은 로터리 킬른 동체에서 발생한 CO 가스에 의해 일부가 환원되는데 이 메커니즘을 고려하기 위해 CO 농도, 로터리 킬른 동체 온도, 소성광 온도의 변수가 사용되었다.

**Table 1. Variables for prediction model of nitrogen oxide emissions**

Variables	Range	Unit
Ore Input	80~160	WMT/min
Pellet Input	10~35	ton/min
Reductant Input	3~10	ton/min
Scoop Feeder Input	2~12	ton/min
Pulverized Coal Input	3~7	ton/min
Discharge Pressure	-5~-1	mmAq
CO%	0.1~0.4	%
O <sub>2</sub> %	5~8	%
NOx	30~105	ppm
Kiln Temperature	500~900	°C
Calcine Temperature	600~900	°C


그리고 로터리 킬른은 광석에 포함된 수분 건조, 예비 환원, 원료 승온의 기능을 발휘해야 하기 때문에 원료인 광석과 펠릿의 투입량을 변수로 포함하였다. 추출된 데이터에서 질소산화물은 정상조업 범위인 30~105ppm, 광석처리량은 80~160t/h의 값을 사용하였으며 기타 변수의 범위 정보는 Table 1과 같다.

### 3.2 데이터 전처리

자연에서 생산된 원광을 원료로 사용하는 제련업의 특성상 조업 데이터의 변화폭이 크다. 질소산화물 농도 및 광석 투입량, 펠릿 투입량, 환원제 투입량 등 무게 변수의 데이터 Smoothing을 위해 5분 단위 Roll-up을 Fig. 3과 같이 진행하였다. 모든 변수에 대해 중앙값을 적용하였으며 상기 Roll-up 후 버너 공기비, 스크 피더 석탄 투입비율의 파생변수를 재산출하였다. 이렇게 전처리된 데이터의 80%는 훈련용(Training)으로 20%는 검증용(Testing)으로 구분하여 준비하였다.

### 3.3 성능 측정 지표

머신러닝 모델이 얼마나 훈련이 잘 되었는지 확인하기 위해 성능 측정 지표의 정의가 필요하다. 모델의 성능 측정은 모델의 정확도를 측정하는 적합성 함수를 정의하거나 모형의 불량 정도를 측정하는 비용함수를 정의할 수 있다. 본 연구에서는 손실함수를 이용하여 훈련 과정을 통해 모델이 얼마나 실제 데이터를 잘 추종하는지 평가하고자 하며, 성능 측정 지표로 평균절대오차(Mean Absolute Error, 이하 MAE)를 사용하였다. MAE는 n개의 데이터 예측값과 관측값의 평균편차이며, 절대 오차에 대한 선형적인 관계를 표현할 수 있다. MAE가 낮은 경우 더 정확한 모델을 의미한다. 상관계수는 두 값에 대한 회귀분석모델이 얼마나 데이터를 잘 설명해주는지를 대변하는 값으로, 0에서 1사이의 범위를 가진다. 즉, 오차범위를 설명해주



**Fig. 3. Data roll-up**

는 MAE는 값이 작을수록 예측 오차가 적은 것을 의미하고, 상관계수는 1에 가까운 값일수록 두 변수 간의 정확도가 높은 것을 의미한다.

#### 4. 연구모형 설계 및 연구결과

앞서 살펴본 바와 같이 로터리 킬른 설비에서 질소산화물은 미분탄의 연소를 통해 발생한 고온의 화염에서 공기의 질소가 해리되며, 연소를 위해 버너에 공급된 잉여의 연소공기의 산소와 반응하여 질소산화물이 형성된다. 또한 질소산화물은 킬른에 공급된 환원제의 연소과정에서 발생한 CO 가스와의 환원반응을 통해 제거되기도 한다. 버너에서 질소산화물의 생성은 즉각적인 반응이며 버너에 투입하는 미분탄량을 늘릴 경우 바로 상승한다. 반면에 로터리 킬른 동체에서 발생하는 환원반응은 지연 반응 메커니즘을 보인다. 대부분의 로터리 킬른은 4~6미터의 지름과 100~140미터의 길이의 대형 설비로 로터리 킬른 동체의 온도를 환원제가 연소될 수 있는 온도조건을 확보하는데 약 40분의 시간이 소요된다. 현재 로터리 킬른에서 배출되고 있는 질소산화물의 양은 버너에서 생성된 질소산화물의 양과 킬른 동체에서 제거되는 질소산화물의 양이 반영된 것으로 제거되는 질소산화물의 양은 약 40분 전 로터리 킬른 동체 온도에 영향을 받는다. 이런 이유로 40분 후의 질소산화물 농도를 예측하는 것이 중요하며 본 연구에서는 회귀 및 분류의 두 가지 방법으로 질소산화물량을 예측하였으며, 각각에 LSTM 모델과 Light GBM 모델을 적용하였다.

##### 4.1 LSTM 기반 질소산화물 농도예측

시계열 LSTM 모델을 이용하여 질소산화물 농도를 예

측한 결과는 Table 2와 같다. 5분 후 상관계수는 0.86, MAE는 5.13ppm, 10분 후 상관계수는 0.72, MAE는 7.39ppm, 20분 후 상관계수는 0.54, MAE는 9.46ppm, 30분 후 상관계수는 0.47, MAE는 10.02ppm, 40분 후 상관계수는 0.38, MAE는 10.84ppm로 도출되었다. Fig. 4에서와 같이 40분 후 질소산화물 값의 예측결과(빨간색)는 학습데이터(검정색)와 비슷한 패턴을 보이지만 상관계수 값은 0.38, MAE는 10.84ppm으로 실제 조업에 사용하기에는 제한되는 결과를 얻었다.

Table 2. Prediction results of nitrogen oxide concentration of LSTM

Time(Min)	Correlation Coefficient	MAE, ppm
t + 5	0.86	5.13
t + 10	0.72	7.39
t + 20	0.54	9.46
t + 30	0.47	10.02
t + 40	0.38	10.84

##### 4.2 LightGBM 질소산화물 농도예측

앞서 LSTM 모델을 통한 질소산화물 농도 예측결과를 고려하여 LightGBM 모델을 이용한 분류 모델링을 진행하였다. 질소산화물의 경우 40분 후 질소산화물 농도가 높아질 것인지, 낮아질 것인지 파악할 수 있다면 실제 조업 변수 제어를 통해 최적치를 유지할 수 있다. Class의 구분은 Fig. 5, Fig. 6과 같이 F-value를 통해 50ppm 미만, 50ppm 이상 70ppm 미만, 70ppm 이상 90ppm 미만, 90ppm 이상의 네 단계로 구분하였다. 환경부의 대기관리권역 총량규제에 따라 총량규제 대상 기업의 경우 1차 계획년도('20년~'24년) 오염물질 배출량 및 Best Available Control Technology(BACT)에 근거하여 2차

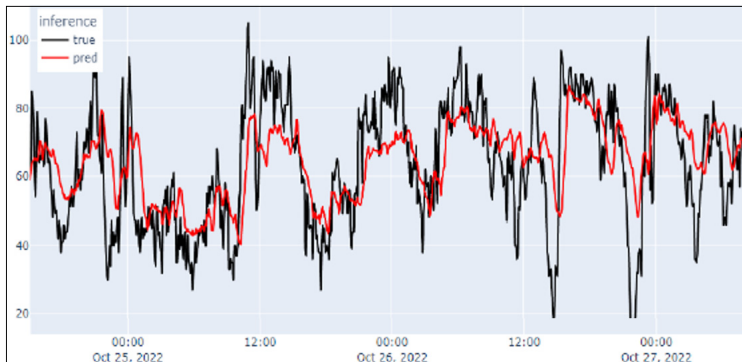


Fig. 4. Prediction results of nitrogen oxide concentration of LSTM after 40 minutes

계획년도(‘25년~’29년) 황산화물, 질소산화물의 배출기준이 결정된다. 친환경 경영을 위해서는 오염물질 배출량을 최소화 하는 것이 필요하나, 기업의 지속가능한 경영을 위해서는 규제치 내에서 안정적인 조업이 필요하다. 배출량 목표를 준수하는 예측조업을 위해서 네 단계의 다분류 예측을 진행하였다.

LightGBM 모델을 이용한 40분 후 로터리 킬른 질소산화물 농도를 Class별 구분한 결과는 Fig. 6과 같다. 질소산화물 예측 Test 정확도는 5분 후 0.75, 10분 후 0.71, 20분 후 0.68, 30분 후 0.63, 40분 후 0.61로 실제 조업에서 수용할 만한 수준의 정확도를 얻을 수 있었다. 그리고 질소산화물에 영향을 주는 주요 변수는 5분 후 Discharge 압력, 버너 공기비 등 질소산화물 생성과 관련

된 변수에서 40분 후에는 소성광 온도, 동체 54m 온도의 질소산화물 환원과 관련된 변수로 변함이 확인되었다 (Fig. 7 참고).




Fig. 5. F-value verification for class classification




Fig. 6. Classification of predicted values of nitrogen oxides after 40 minutes

Table 3. Prediction results of nitrogen oxide concentration of lightGBM (max depth = 4)

Time(Min)	Train Accuracy	Test Accuracy
t + 5	0.86	0.75
t + 10	0.82	0.71
t + 20	0.80	0.68
t + 30	0.80	0.63
t + 40	0.79	0.61

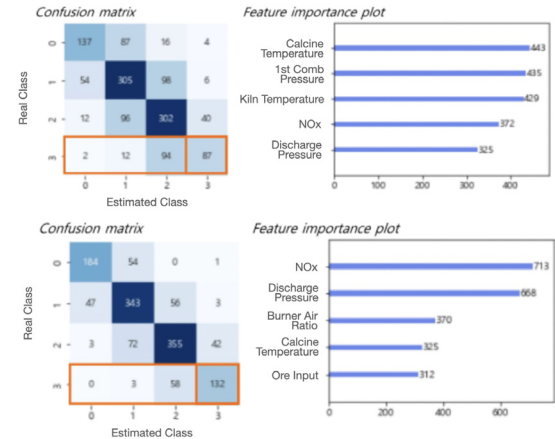


Fig. 7. Key variables after 5 minutes (top) and 40 minutes (bottom) using lightgbm

### 4.3 AutoML을 이용한 모델성능 개선

LightGBM을 이용한 모델의 예측 정확도를 높이기 위해 AutoML(Automatic Machine Learning)을 적용하였다. AutoML은 머신러닝 모델을 자동으로 구축하고 최적화하는 과정을 자동화 하는 기술이다[15]. AutoML은 다음의 과정을 통해 적용하였다. Dataset(변수)과 Target(질소산화물)을 투입하고 교호작용, 변환, 구간화 변수의 파생변수를 생성한다. F-test 등 변수선택기법에 기반 하여 모델에 활용한 변수의 Input Pool을 구성한 후 적용된 알고리즘에 대해 Random & Bayesian Search의 Hyper Parameter Optimization(HPO)를 적용하였다. 적용결과 5분 후 질소산화물 예측 Test 정확도는 0.75에서 0.80으로 상승하였고, 40분 후 질소산화물 예측 Test 정확도는 0.61에서 0.70으로 상승하였다(Table 4 참고).

Table 4. Prediction results of nitrogen oxide concentration of lightGBM(max depth = 4)

Time(Min)	Test Accuracy	
	Before AutoML	After AutoML
t + 5	0.75	0.80
t + 40	0.61	0.70

## 5. 결론 및 시사점

이차전지 시장의 확대에 따라 니켈 산화광을 RK-EF

공법을 이용하여 생산하는 공정이 전세계적으로 확대되고 있는 상황이다. 지속가능한 ESG 경영 요구에 따라 배출가스내의 온실가스, 황산화물, 질소산화물의 배출농도 뿐만 아니라 배출 총량의 관리가 강화되고 있는 실정이다. 이에 본 연구는 머신러닝 기법을 로터리 킬른 공정에 적용하여 질소산화물 농도 예측을 진행하였다. 니켈 광석을 제련하는 로터리 킬른 조업의 특성상 40분 후의 질소산화물 농도 예측이 필요하였다. 대부분의 조업데이터는 시계열이기 때문에 LSTM 모델을 적용한 결과 5분 후의 상관계수는 0.86, MAE는 5.13ppm 이었으나, 40분 후의 질소산화물 예측 상관계수는 0.38, MAE는 10.84로 하락하였다. 이에 구분 예측하기에 용이한 LightGBM 모델을 적용하였다. 예측결과 Test 정확도는 5분 후 0.75에서 40분 후 0.61로 상승하여 실제 조업에 활용할 수 있는 수준까지 상승되었고 AutoML을 통한 모델 최적화 결과 5분 후 예측 값의 정확도는 0.75에서 0.80까지, 40분 후의 예측 정확도는 0.61에서 0.70까지 상승하였다.

로터리 킬른의 질소산화물 농도 저감을 위해서 질소함량이 낮은 원료의 적용과 공연비(Air Fuel Ratio) 하향 조정을 통한 방법을 제시하거나, 석탄 화력발전소를 대상으로 머신러닝 기법을 적용하여 질소산화물 예측시간 단축에 집중한 연구가 진행되었으나 본 연구에서는 로터리 킬른의 질소산화물 생성, 제거 메커니즘을 고려하여 40분 후의 질소산화물 예측모델을 구축했다는데 학술적 시사점이 있다. 또한 이번 연구를 통해 질소산화물 농도 제어 능력 향상으로 질소산화물 관리 상한치 초과건수 감소 등 실질적 성과가 창출되고 있다. 하지만, 구축된 분류기반의 40분 후 질소산화물 예측 정확도는 0.70으로 현재는 예측 값을 조업자가 참고하여 조업을 진행하지만, 향후에는 예측 값에 기반한 자동 제어에 대한 추가 연구가 필요하다.

## REFERENCES

- [1] BISULANDU, B. J. R. M., & HUCHET, F. (2022). Rotary kiln process: An overview of physical mechanisms, models and applications. *Applied Thermal Engineering*, 119637.
- [2] Kambara, S., Takarada, T., Toyoshima, M., & Kato, K. (1995). Relation between functional forms of coal nitrogen and NOx emissions from pulverized coal combustion. *Fuel*, 74(9), 1247-1253.
- [3] Sohn, H. S. (2021). Current Status of Nickel Smelting Technology. *Resources Recycling*, 30(2), 3-13.
- [4] Cai, J., Wu, H., Ren, Q., Lin, L., Zhou, T., & Lyu, Q. (2020). Innovative NOx reduction from cement kiln and pilot-scale experimental verification. *Fuel Processing Technology*, 199, 106306.
- [5] Edland, R., Normann, F., Fredriksson, C., & Andersson, K. (2017). Implications of fuel choice and burner settings for combustion efficiency and NOx formation in PF-fired iron ore rotary kilns. *Energy & Fuels*, 31(3), 3253-3261.
- [6] Orooji, Y., Javadi, M., Karimi-Maleh, H., Aghaie, A. Z., Shayan, K., Sanati, A. L., & Darabi, R. (2021). Numerical and experimental investigation of natural gas injection effects on NOx reburning at the rotary cement kiln exhaust. *Process Safety and Environmental Protection*, 151, 290-298.
- [7] Muzio, L. J., & Quartucy, G. C. (1997). Implementing NOx control: research to application. *Progress in Energy and Combustion Science*, 23(3), 233-266.
- [8] KAIKAKE, A. (2007). Recent ferronickel smelting operation at Hyuga Smelting Co., Ltd. *Journal of MMIJ*, 123(12), 686-688.
- [9] Korea Energy Economics Institutes (2022). *2021 Annual Energy Statistics*, Ulsan : Korea Energy Economics Institutes.
- [10] Adams, D., Oh, D. H., Kim, D. W., Lee, C. H., & Oh, M. (2020). Prediction of SOx-NOx emission from a coal-fired CFB power plant with machine learning: Plant data learned by deep neural network and least square support vector machine. *Journal of Cleaner Production*, 270, 122310.
- [11] Tan, P., Xia, J., Zhang, C., Fang, Q., & Chen, G. (2016). Modeling and reduction of NOx emissions for a 700 MW coal-fired boiler with the advanced machine learning method. *Energy*, 94, 672-679.
- [12] Yang, G., Wang, Y., & Li, X. (2020). Prediction of the NOx emissions from thermal power plant using long-short term memory neural network,



*Energy*, 192, 116597.

- [13] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory, *Neural Computation*, 9(8), 1735-1780.
- [14] Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T. Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree, *Advances in Neural Information Processing Systems*, 30.
- [15] He, X., Zhao, K., & Chu, X. (2021). AutoML: A survey of the state-of-the-art, *Knowledge-Based Systems*, 212, 106622.

유 제 형(Je-Hyeung Yoo)

[정회원]



- 2020년 2월 : 뉴욕주립대학교 기술경영학과(MSTM)
- 2022년 3월~현재 : 서울과학종합대학원대학교 박사과정

- 관심분야 : 기술경영, 머신러닝
- E-Mail : yjhrkawl@naver.com

박 정 열(Cheong-Yeul Park)

[정회원]



- 2003년 8월 : 중앙대학교 심리학과 (박사)
- 2013년 3월~현재 : 한국여가문화학회 상임이사
- 2013년 3월~현재 : 서울과학종합대학원대학교 경영학과 부교수

- 관심분야 : 조직몰입, 긍정심리학, 연구방법론
- E-Mail : cypark@assist.ac.kr

배 재 권(Jae Kwon Bae)

[정회원]



- 2009년 8월 : 서강대학교 경영학과 (경영정보학 박사)
- 2023년 1월~현재 : 글로벌경영학회 편집위원장
- 2012년 3월~현재 : 계명대학교 경영정보학전공 부교수

- 관심분야 : 인공지능, 데이터마이닝, 금융빅데이터분석
- E-Mail : jkbae99@kmu.ac.kr