

# 설명가능 인공지능 기반 시멘트 예열 공정 온도 제어 기술 개발

이예림\* · 유보선

(주)ineeji

## Explainable Artificial Intelligence for Temperature Control in the Cement Preheating Process

Yerim Lee · Boseon Yoo

INEEJI Co., Ltd.

In cement preheating and calcination, precise control of preheater temperature is crucial for stable operation and clinker quality. However, the temperature is influenced by dynamically changing process variables with complex nonlinear relationships, which conventional control methods such as feedback control and Model Predictive Control (MPC) fail to adequately capture. This study introduces an explainable artificial intelligence (XAI)-based prediction and control framework to address these limitations. A deep learning model identifies nonlinear patterns between fuel feed rate and preheater temperature, while XAI techniques provide interpretable insights into temperature variations caused by changes in coal input. The framework automatically recommends and simulates optimal coal feed rates under diverse conditions, maintaining stable preheater temperatures even with increased alternative fuel usage, thereby supporting carbon neutrality goals. By enhancing transparency and interpretability, the proposed approach improves reliability and acceptance in industrial practice, offering a practical solution for energy efficiency and sustainability in the cement industry.

**Keywords:** Alternative Fuels, Cement Preheater, DNN(Deep Neural Network), XAI(Explainable AI), Predictive Control System

### 1. 서론

최근 들어, 탄소 중립(Carbon Neutrality)은 산업 전반에서 필수적인 경영 및 생산 전략으로 부상하고 있으며, 특히 에너지 집약적인 제조 산업에서는 온실가스 감축을 위한 실질적인 대응이 요구된다. 그 중, 시멘트 산업은 철강, 석유화학과 함께 대표적인 온실가스 다배출 산업으로 지목되고 있다. 시멘트 반제품인 클링커를 생산하기 위해서는 약 900~1,500°C의 고온의 상태에서 석회석 원료의 탄산 성분을 열분해해야 한다. 이러한 열을 제공하기 위해, 과거에는 시멘트 예열·소성 공정에서는 석탄, 석유와 같은 화석연료가 주로 사용되었다. 그러나 최근에는 탄소 배출 저감을 위해 폐기물 기반 연료(RDF,

Refuse-Derived Fuel), 바이오매스, 고로가스 등 다양한 대체연료(AF, Alternative Fuel)를 활용하는 연구, 사례가 증가하고 있다.

국내외에서는 대체연료 사용을 통한 대기 오염 물질 감소 등의 탄소 중립의 효과를 여러 방식으로 비교·분석하고 있다. Back *et al.*, (2023)에서는 대체연료를 사용하는 시멘트 설비에 다단연소 하소로를 적용하여 연료 및 배출 특성을 전후 비교하였다. 다단연소 하소로는 일차적으로 산소가 부족한 환원 분위기에서 NOx를 저감하고, 이후 산소가 풍부한 산화 분위기에서 CO 등 잔여 배출물을 제거하는 방식으로 오염물질을 줄이는 공정이다. 그 결과, 유연탄 사용은 38% 감소, 폐합성수지 사용은 122% 증가, NOx 배출은 17% 감소하였다. 이는 공정 개선을 통해 대체연료 활용 확대와 오염물 저감을 동시에

이 논문은 2025년도 산업통상자원부 및 한국산업기술기획평가원(KEIT)의 지원을 받아 수행되었음(과제번호: No. RS2023-00261157).

\* 연락저자 : 이예림 선임연구원, 13558 경기도 성남시 분당구 성남대로 331번길 8, 14층 1402호(정자동, 킨스타워), Tel : 031-8022-7535,

Fax : 031-8022-7538, E-mail : yerim@ineeji.com

2025년 9월 1일 접수; 2025년 10월 20일 수정본 접수; 2025년 12월 16일 게재 확정.

달성할 수 있음을 보여준다. Yixiang *et al.*(2024)에서는 시멘트 킬른에서 바이오매스 혼합 소각(0~30%)과 산소 농도 변화가 연소 특성과 NO<sub>x</sub> 배출에 미치는 영향을 CFD(Computational Fluid Dynamics)로 해석하였다. 그 결과, 바이오매스 혼합 연소율이 증가할수록 연소장의 온도 분포가 안정화되고 NO<sub>x</sub> 발생이 억제되는 경향을 확인하였다. 해당 연구는 시멘트 공정에서 바이오매스 혼합 소각이 오염물질 및 탄소 배출 저감에 효과적인 전략임을 뒷받침한다. Salaripoor *et al.*(2025)에서는 OpenLCA(Open Life Cycle Assessment) 소프트웨어를 활용하여 천연가스 부족 시 RDF를 대체연료로 활용하는 것이 환경에 미치는 영향을 평가하였다. 그 결과, 유기성 폐기물을 포함한 RDF가 기존 증유, 석탄 대비 CO<sub>2</sub> 배출과 GWP(Global Warming Potential)를 크게 줄이는 것으로 나타났다. 또한, 폐기물 관리와 에너지 회수의 통합 전략이 시멘트 산업의 지속가능성과 탄소 저감에 기여할 수 있음을 강조한다.

선행 연구에서 제안한 바와 같이, 대체연료 사용은 화석연료 사용량과 탄소 배출을 동시에 줄이는 데 기여할 뿐만 아니라, 폐기물 처리 문제를 완화하고 자원순환을 촉진하는 환경적 이점을 갖는다. 더 나아가 온실가스 및 대기 오염 물질 저감으로 인한 환원제 사용량 절감이 가능하고, 공공 폐기물 처리 시설에 대한 의존도 완화에 따른 폐기물 처리 비용 절감, 유연탄 수입 비용 절감 등의 경제적 효과도 이끌어낼 수 있다.

그러나 PEDERsEN(2018)에 의하면 시멘트 생산 공정에서 유연탄 대신 대체연료를 사용할 경우, 대체연료의 열량 및 연소 특성(입도, 수분함량, 화학 조성)이 일정하지 않아 공정 변동성이 커진다는 문제가 발생한다. 이는 연소 효율을 저하시킬 뿐만 아니라, 예열실과 킬른의 온도 제어를 불안정하게 만드는 문제로 이어질 수 있다. 대다수의 대체연료는 입도가 크고, 수분함량이 높으며, 저발열량(LHV, Lower Heating Value)의 특성을 가져 연소가 완료되는 시간이 증가하고, 화염 온도가 저하하여 현장 운전원으로 하여금 운전 난이도를 높인다. 또한, Hercog *et al.*(2023)는 연료 공학 실험과 모사 연구를 통해 RDF로 인한 불완전연소 발생은 예열실과 하소로 구간의 산소, 일산화탄소, 배가스 온도 변동 문제로 이어진다고 밝혔다. European Cement Research Academy(2021)는 대체원료와 대체연료의 사용량 증대가 예열실 하단과 킬른 입구(킬른 입구 덕트, 예열실 사이클론, 로터리 킬른)에서 염소, 황, 알칼리의 순환을 증대시키고, 코팅, 링 형성 가능성을 높여 운전 안정성을 저해한다고 설명한다.

이처럼, 대체연료 사용은 현장 운전원들로 하여금 예열 공정 운전을 어렵게 만든다. 따라서 시멘트 산업에서 대체연료 활용을 확대하기 위해서는, 대체연료가 공정 안정성과 제품 품질에 미치는 변동성을 최소화하기 위한 체계적인 연구가 병행되어야 한다. 이에 본 연구에서는 변동성이 높은 시멘트 예열 공정을 일관되게 운영하기 위해 예열실 온도를 정확하게 예측하고, 이를 안정적으로 제어할 수 있는 전략을 마련하고자 한다.

본 연구는 대체연료를 사용하는 예열실 온도를 일정하게 유

지하는 것을 목표로, 설명가능 인공지능(XAI, Explainable AI) 기반의 예열실 온도 예측·제어 프레임워크를 개발하고, 실제 시멘트 생산 공정 데이터를 사용하여 시뮬레이션을 통해 검증하였다. 그 결과, RMSE 기준 최소 2.0138, 최대 6.7565의 오차를 달성하였으며, 대체연료 투입 조건에서도 기존 PID 제어 대비 예열실 온도 편차를 약 19% 감소시켜 안정적인 운전이 가능함을 입증하였다.

## 2. 선행 연구 사례

시멘트 제조 공정에서 예열실 온도는 공정 안정성과 클링커 품질을 결정하는 핵심 변수로 알려져 있다. 이에 따라 예열실 온도를 안정적으로 제어하기 위한 다양한 연구가 지속적으로 진행되어 왔다.

PID(Proportional-Integral-Derivative) 제어는 구현이 간단하고 산업 현장에 광범위하게 적용된다는 장점이 있다. Tsamatsoulis *et al.*(2016)은 예열실 출구 온도를 목표값으로 두고, 유연탄 투입량을 조작 변수로 하는 PID 제어 모델을 현장에 적용하였다. 예열실 출구 온도와 주요 연료 투입량 간의 상관관계를 단순한 동적 관계로 모델링하여 PID를 조정된 결과, 공정 변동 시 예열실 온도의 과도한 증가, 감소와 진동이 줄고 목표 온도에 더 빠르고 정확하게 도달하는 효과를 보고하였다. 다만, 모델의 단순성으로 인해 실제 공정에서는 초기 파라미터 설정 수준으로 활용되고 있다는 점과 대체연료 열량 변동과 같은 외란 요인을 모델에 반영하지 못했다는 점을 한계로 제시하였다. 이처럼 예열 공정이 시간 지연, 강한 비선형성, 다양한 외란(연료 물성, 원료 및 공기 유량 변동 등)을 동반할 경우 PID 제어 성능이 저하될 수 있다. 특히 대체연료 대체율이 높아질수록 PID 파라미터의 잦은 재튜닝이 요구되고 예열실 온도의 과도한 증가, 감소와 진동 발생 가능성이 높아 보다 견고한 제어 전략이 필요하다.

MPC(Model Predictive Control)는 유한 예측 지평에서 공정 모델을 이용해 제약조건을 고려한 최적화를 수행하고, 산출된 조작 변수 시퀀스에서 첫 번째 값을 현재 공정에 적용하는 제어 방식이다. Ma *et al.*(2022)는 시멘트 예열 공정의 낮은 열효율 문제를 해결하기 위해 2계층 구조의 모델 예측 제어 전략을 제안하였다. 상위 계층에서는 에너지 흐름·열전환 모델과 입자 군집 최적화(PSO, Particle Swarm Optimization)를 통해 예열실 출구 온도의 최적 설정값을 실시간으로 산출하고, 하위 계층에서는 역전파(BP, Back Propagation) 신경망 기반 MPC로 온도를 안정적으로 제어하였다. Matlab 시뮬레이션 결과, 제안된 기법은 기존 PID 및 퍼지(Fuzzy) 제어 대비 정착 시간, 정상 상태 오차, 오버슈트, 외란 억제 성능에서 우수하여 장기적 안정성과 에너지 효율 향상에 기여함을 입증하였다.

또한, Hao *et al.*(2023)은 예열실 온도 제어의 변동성과 불확실성을 해결하기 위해 P-ConRNN-MPC(Parallel Cascaded

Convolutional Neural Networks and Recurrent Neural Networks-based Model Predicted Control) 기반의 예열실 온도 제어 알고리즘을 제안하였다. 제안된 예측 모델은 병렬 계단 구조의 CNN(Convolutional Neural Network)과 RNN(Recurrent Neural Network)을 결합하여 다변수 간 결합, 시간 지연, 비선형 동특성, 고차원 데이터 복잡성 문제를 해결하고 예열실 온도 예측 정확도를 향상시켰다. 또한, 석탄 투입량 변화를 최적화 함수에 반영하고 개선된 IWOA(Improved Whale Optimization Algorithm)을 활용함으로써, 에너지 절감과 함께 예열실의 효율적, 안정적 운영을 달성할 수 있음을 입증하였다.

그러나, 전통적인 딥러닝 기반 모델들은 내부 의사결정 과정을 파악하기 어려운 블랙박스(Black-Box) 모델로 간주되며, 이로 인해 MPC 기반 제어 모델이 딥러닝 기반의 예측 모델을 사용할수록 제어 결과에 대한 해석 가능성이 낮아져 현장 운전원의 신뢰 확보와 품질 문제 원인 규명에도 어려움이 따른다. 이러한 문제는 제조 산업을 포함한 전 영역에서 공통적으로 제기되어 왔고, 이를 완화하기 위해 설명가능 인공지능이 도입되고 있다. 설명가능 인공지능은 모델의 입력-출력 관계를 사람이 이해할 수 있는 설명을 제공하는 기술로, 예측에 대한 사후적 해석을 제공하는 SHAP(Shapley Additive Explanations)과 LIME(Local Interpretable Model-agnostic Explanations) 등이 널리 활용된다. Fatahi *et al.*(2023)은 시멘트 로터리 킬른 운전 변수를 XAI로 모델링 및 해석하여 운전의 사결정에 활용하였고, Fayaz *et al.*(2025)은 클링커의 품질(alite, belite, fecrite)을 예측하는 머신러닝 모델을 제안하고, SHAP 모델을 기반으로 해석 결과를 제공하였다. 다만, 이러한 사후(post-hoc) 설명 기법은 입력 변수의 기여도와 같은 예측에 대한 해석에 국한되어, 제어 관점에서 필요한 조작 변수 변경량의 정량적 산정을 지원하기 어렵다는 한계가 있다.

위와 같은 문제를 해결하기 위하여, 실시간으로 변화하는 공정 요인들의 패턴을 학습하고 최적의 연료 투입량을 제안할 수 있는 새로운 기술이 필요하다. 따라서, 본 연구는 합성곱 신경망 기반의 예측 모델과 반사실적 기반의 설명가능 인공지능을 결합한 새로운 접근 방법을 개발하였다. 이를 통해 대체연료 투입량이 증대되는 조건에서도 예열실 온도를 일정하게 유

지하고 클링커 품질과 공정 효율성을 향상시킬 수 있는 방안을 제안하고자 한다.

### 3. 시멘트 예열, 소성 공정

시멘트 생산 과정은 <Figure 1>과 같이 크게 채광(Mining) 및 조쇄(Crushing), 혼합(Mixing) 및 분쇄(Grinding), 예열(Preheating) 및 소성(Clinkerization), 분쇄(Grinding) 및 출하(Dispatch) 단계로 구분된다. 먼저 채광된 석회석(Limestone)은 세 차례의 조쇄 과정을 거쳐 직경 2.5cm 이하의 크기로 파쇄된다. 그리고, 철암, 규석, 철광석 등의 부원료들과 일정한 비율로 혼합된 뒤 미세 분말 형태로 분쇄된다. 이 미세 분말 형태의 원료(Raw Meal)는 예열 및 소성 공정을 거쳐 시멘트 반제품인 클링커(Clinker)로 생산된다. 클링커는 소성 직후 냉각 과정을 거치며, 여기에 적당량의 석고를 첨가된 후 다시 한번 미세 분말 형태로 분쇄되어 시멘트(Cement)로 생산된다. 완성된 시멘트는 저장 사일로에 보관된 뒤 포장 과정을 거쳐 출하된다.

그중 예열-소성 공정은 예열실 최상단으로부터 투입된 원료와 예열실 하단, 킬른으로부터 공급된 뜨거운 공기를 서로 열교환하여 시멘트 반제품인 클링커를 생산하는 핵심적인 생산 단계이다. <Figure 2>에 예열실과 킬른 내부에서 온도에 따라 일어나는 화학 반응을 정리하였다. 예열 공정은 예열실 하단 온도를 약 900℃ 이상 승온하여 석회석 원료를 열분해( $\text{CaCO}_3 \rightarrow \text{CaO} + \text{CO}_2$ )하고, 소성 공정은 예열된 원료를 약 1,500℃ 가까이 소성하여, 클링커를 구성하는 광물( $3\text{CaO} \cdot \text{SiO}_2$ (C3S))을 생성하고 반제품인 클링커를 생산한다.

예열실 온도를 항상 900℃ 이상의 적정 범위 이내에서 안정적으로 유지해주는 것은 매우 중요하다. 석회석은 900℃ 이상의 온도에서 열분해 반응이 일어나기 때문에, 만약 예열실 온도가 900℃ 이상 유지되지 않는다면 소성 공정에 부담이 증가하고 이는 소성 공정의 효율과 제품 품질에 부정적인 영향을 미칠 수 있다. 반대로 예열실 온도가 적정 범위를 넘어서 1000℃ 이상 과도하게 상승한다면, 예열실 내부에 원료가 적분되어 공정의 흐름을 방해할 수 있다.

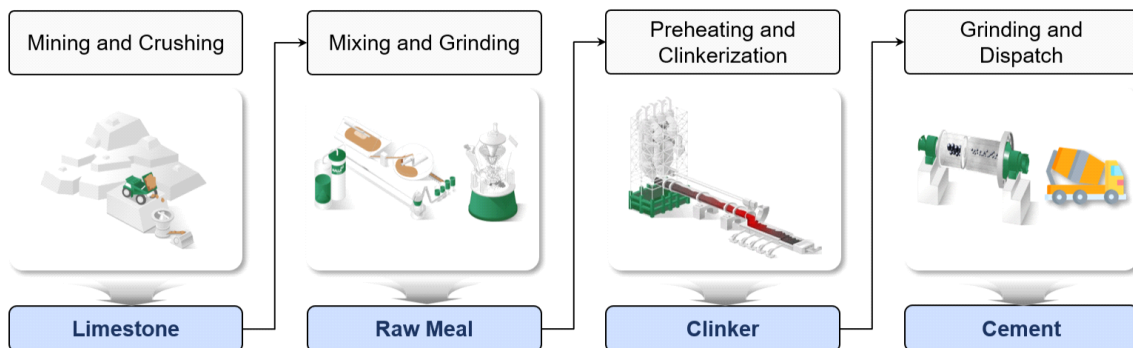


Figure 1. Overview of the Cement Manufacturing Process

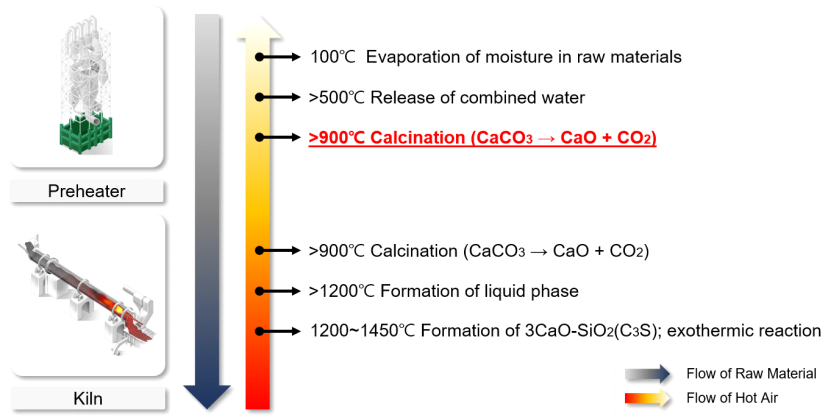


Figure 2. Temperature Profile and Chemical Reactions in the Preheating and Clinkerization Process

## 4. 데이터의 수집 및 분석

### 4.1 데이터 수집

본 연구를 위해 국내 한 시멘트 생산 업체에서 운용 중인 NSP(New Suspension Preheater) 킬른으로부터 2024년 5월부터 2025년 5월까지, 약 1년 동안의 10초 단위 데이터를 수집하였

Table 1. Major Variables in the Preheating and Clinkerization Process

Section	Variable	Unit
Feed Rate	Raw Meal Feed Rate	t/h
	Coal Feed Rate	t/h
	Waste Plastic Feed Rate	t/h
	Waste Oil Feed Rate	t/h
	Waste Tires Feed Rate	t/h
	Sludge Feed Rate	t/h
ID Fan	ID Fan Temperature	°C
	ID Fan Pressure	mmAq
Preheater	Preheater Temperature	°C
	Preheater Pressure	mmAq
Kiln	Kiln Inlet Temperature	°C
	Secondary Air Temperature	°C
	Tertiary Air Temperature	°C
	Kiln Inlet Pressure	mmAq
	Secondary Air Pressure	mmAq
	Tertiary Air Pressure	mmAq
	Kiln Rotation Speed	RPM
Kiln Motor Current	A	
Cooler	Cooler Air Flow Rate	m <sup>3</sup> /min
	Cooler Pressure	mmAq
	Cooler Fan Speed	RPM
Exhaust Gas	Exhaust Gas Composition	%

다. 수집된 데이터는 <Table 1>에 제시된 주요 공정 변수들을 포함하며, 대체연료를 연소시키기 위한 보조 연소 장치가 장착되어 폐합성수지, 폐유, 폐타이어, 유기 슬러지 등의 다양한 대체연료 투입량 데이터를 수집할 수 있었다. 주요 공정 변수들에 대한 탐색적 데이터 분석(EDA, Exploratory Data Analysis)을 통해 원료, 연료 투입량이 0t/h이고 온도가 0°C에 수렴하는 등 소성 공정이 운영되지 않은 기간의 데이터는 제외하였으며, 전체 데이터 약 316만 개를 7:2:1의 비율로 학습, 검증, 시험 데이터로 나누어서 예열 및 소성 공정의 분석과 예측 모델 학습에 활용하였다.

제안된 모델의 성능을 검증하기 위해 학습데이터로 사용된 기간 이후의 2025년 6월부터 8월까지, 약 3개월 동안의 10초 단위 데이터를 추가로 수집하여 시뮬레이션 단계에서 사용하였다. 수집된 데이터의 변수 리스트는 학습데이터와 동일하며, 약 79만 개의 데이터 샘플을 사용하여 시뮬레이션 평가를 진행하였다.

### 4.2 데이터 분석

본 연구에서는 예열실 온도를 예측 및 제어 대상으로 설정하고, 예열실 온도와 원료·연료 투입량과 같은 주요 관계변수를 분석하였다. 그 결과, 예열실 온도의 비선형성, 시간 지연, 자기상관성과 같은 특징을 확인할 수 있었다.

#### (1) 비선형성

시멘트 예열실 온도는 원료 성분, 연료의 종류 및 투입 비율, 공정 운전 조건 등에 따라 급격하게 변화하며, 이러한 변화 요인들은 원료, 연료 투입량 등 주요 공정 변수가 예열실 온도에 비선형적 영향을 미치도록 만든다. 예를 들어, 석회석의 CaCO<sub>3</sub> 함량이 높으면, 열분해 과정에서 다량의 CO<sub>2</sub>가 발생하며, 과도한 흡열 반응으로 인해 순간적인 예열실 온도 감소 혹은 온도 편차 증가로 이어질 수 있다. 또한, 원료 혹은 연료의

수분함량이 높을 경우 수분을 증발시키는 데 열을 빼앗겨 예열실 온도가 일시적으로 감소할 수 있다. 반대로, 발열량이 높은 연료가 순간적으로 많이 투입되면 예열실 온도가 급격히 상승할 수 있다.

특히, 연료 투입 비율이 달라질 때마다 이러한 비선형적인 특성은 다르게 보인다. 예열실의 유연탄 투입량 비율이 높으면, 상대적으로 연료 투입량 변화가 예열실 온도 패턴에 직관적으로 나타나며, 연료 투입량을 제어해서 예열실 온도를 적정 범위 이내로 유지하기 쉬우므로 예열실 온도 편차가 적다. 반대로 대체연료 비율이 높을수록 연소 효율의 불안정성이 커져서, 연료 투입량과 예열실 온도 간 선형적인 상관관계 패턴을 찾기 어렵고 예열실 온도 편차가 증가한다.

이러한 비선형적 특성을 확인하기 위하여, 예열실 온도(Preheater Temperature)와 주요 입력 변수인 유연탄 투입량(Coal Feed Rate), 대체연료 투입량(AF Feed Rate), 원료투입량(Raw Meal) 간의 피어슨(Pearson) 상관과 스피어만(Spearman) 순위상관을 산출하였으며, 각각 <Figure 3 (a)>와 (b)에 나타내었다. 피어슨은 직선적 선형 의존을, 스피어만은 값을 순위화하여 단조 비선형 의존까지 포착한다는 점에서 서로 보완적이다.

분석 결과, 예열실 온도-유연탄 투입량의 상관은 피어슨과 스피어만이 각각 -0.25와 -0.26으로 약한 음의 동시점 관계를 보였고, 예열실 온도-대체연료의 경우 피어슨과 스피어만 모두에서 거의 무시 가능한 수준의 상관성이 나타났다. 예열실 온도-원료투입량에서는 미약한 음의 관계를 보였다. 한편, 유연탄-대체연료는 피어슨 -0.42 대비 스피어만은 -0.58로 절대값이 유의하게 증가하여, 두 연료 투입 관계가 단순 직선형보다 단조형 비선형에 더 가까움을 시사한다. 요컨대 예열실 온도와 개별 입력 간의 선형 상관은 전반적으로 작지만, 스피어만 순위상관에서 일부 쌍의 의존성이 더 크게 평가된 점은 운전 상태에 따라 반응 기율기와 변동성이 달라지는 비선형적 특성을 뒷받침한다. 이러한 결과는 예열실 온도의 변동을 선형 가정만으로 설명하기 어려움을 의미한다.

(2) 시간 지연

과거의 공정 상태가 얼마만큼의 시간 지연 후에 예열실 온도에 영향을 미치는지 분석하여 <Figure 4>에 나타내었다. <Figure 4(a)>는 DTW(Dynamic Time Warping) 알고리즘을, <Figure 4(b)>는 교차상관을 통해 유연탄 투입량과 예열실 온도의 시차를 확인하였다. DTW는 시간축이 어긋나거나 속도가 다른 두 시계열 데이터의 패턴을 정렬하여 유사도를 계산하는 알고리즘이다. 유클리드 거리처럼 데이터 샘플을 1:1로 비교하지 않고, 한쪽 데이터 샘플을 늘이거나 줄여서 최적의 매칭 경로를 찾는다. 시멘트 예열실 온도는 단순히 현재 시점의 연소 조건에 의해 결정되지 않는다. 투입된 연료의 연소 지연, 예열실 내부 가스 및 원료의 체류 시간의 영향으로 인해 과거 공정 상태가 서로 다른 시간 지연 형태로 누적되어 나타난다. 따라서, 제조 공정 데이터와 같은 복잡한 시계열 데이터 간의 시차를 찾는 데 DTW를 활용하는 것이 적절하다(Stübinger et al., 2022).

DTW 분석 결과, 과거 2분 전 예열실 유연탄 투입량이 현재 예열실 온도에 영향을 미치는 것으로 계산되었으며, 계산 결과를 직접 확인하기 위해 <Figure 4(a)>와 같이 예열실 유연탄 투입량과 온도 데이터에 대해 최적의 경로로 매칭된 쌍을 검은색 점선으로 연결하였다. 그 결과, 시간 지연이나 속도 차이에 상관없이 유연탄 투입량과 예열실 온도 변화 시점이 일치하게 대응됨을 확인할 수 있었다.

한편, 과거 10분 전 ~ 미래 10분 후 예열실 유연탄 투입량과 현재 예열실 온도의 상관계수를 계산하여 <Figure 4(b)>과 같이 비교하였다. x축의 lag 값이 양수이면 과거 유연탄 투입량 데이터와 현재 예열실 온도를 비교했음을 의미한다. 분석 결과, 전반적으로 약한 상관관계이지만, 과거 5분 전 유연탄 투입량과 예열실 온도 간의 상관계수( $r=0.155$ )가 가장 높게 계산되었다. 즉 과거 5분 전 유연탄 투입량이 예열실 온도에 영향을 미치는 것으로 해석된다.

두 가지 방법으로 찾은 시차를 각각 유연탄 투입량 데이터

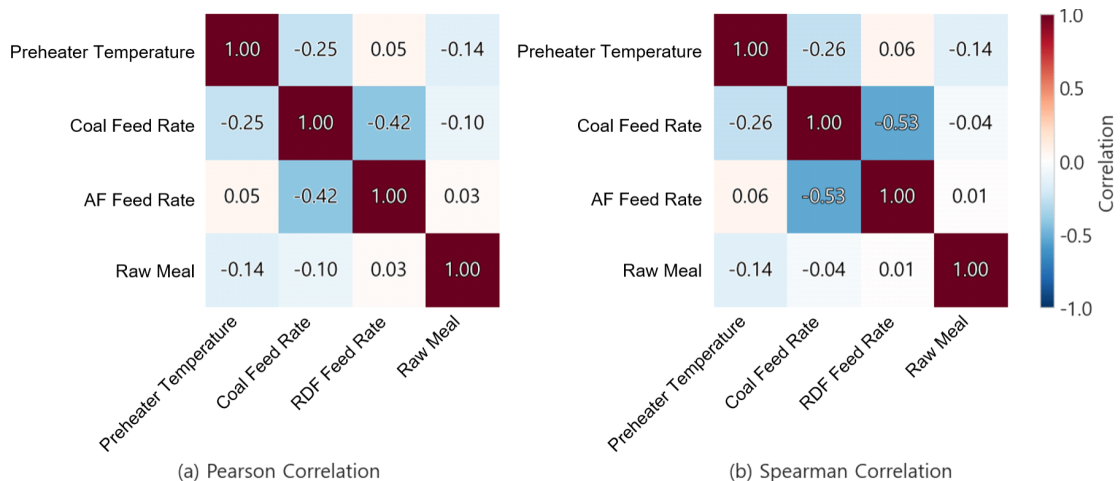


Figure 3. Heatmap of Correlation between Key Input Variables and Preheater Temperature

에 적용하여 예열실 온도 데이터와 비교 분석하고 <Figure 5> (a), (b)에 나타내었다. DTW 방법으로 찾은 시차를 적용한 경우에는, 유연탄 투입량이 증량된 시점과 예열실 온도가 상승한 시점이 일치함을 확인할 수 있었다. 반면 교차상관을 통해

시차를 찾은 경우에는, 유연탄 투입량이 증량된 시점이 예열실 온도가 상승하는 시점을 지나쳐 이미 상승하고 있는 추세와 대응되는 것을 알 수 있다. 본 연구에서 제안하는 예측 제어 모델 적용을 위해서는 현재 유연탄 투입량의 변화가 몇 분 후

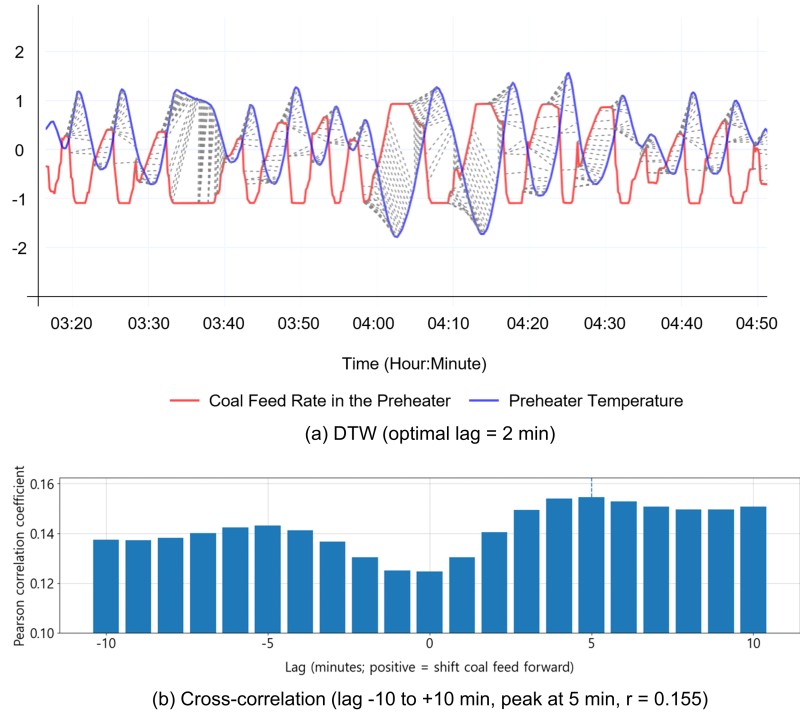


Figure 4. Identification of Time-lag between Preheater Temperature and Coal Feed Rate

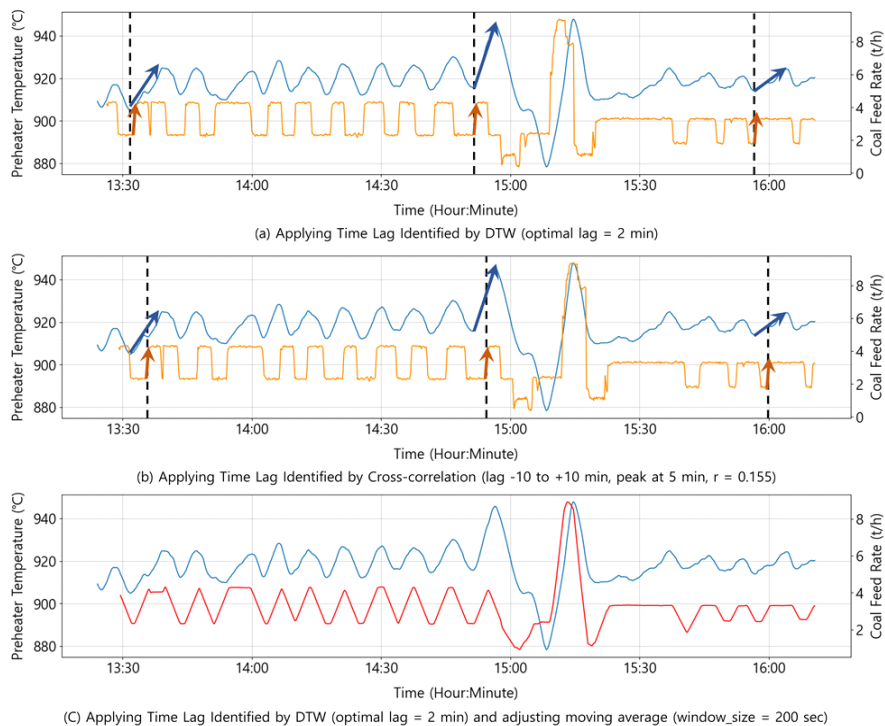


Figure 5. Comparison of Shifted Coal Feed Rate and Preheater Temperature

예열실 온도에 영향을 미치는지 확인하는 것이 중요하므로, DTW를 통해 찾은 시차가 더 적절하다고 판단되었다.

또한, 예열실 온도 센서 특성상 유연탄 투입으로 인한 온도 상승이 즉각 측정되지 않는 점을 고려하여, 유연탄 투입량 데이터에 DTW로 찾은 시차를 적용하고 과거 200초 동안의 평균을 계산하여 현재 예열실 온도와 비교하였다. 그 결과, <Figure 5(c)>과 같이 과거 2분 전 예열실 유연탄 투입량이 200초 동안 천천히 예열실 온도에 반영됨을 확인할 수 있었다. 다만, 이와 같은 시간 지연 현상은 예열실 내부 연소 상황 등에 따라서 변동성이 크다. 따라서, 본 연구는 DTW로 추정된 시간 지연을 제어 입력 타이밍 보정에 사용하고, 교차상관을 통해 찾은 시간 지연 또한 보조적 검증 지표로 활용하였다.

(3) 자기상관성

예열실, 킬른, 쿨러는 열과 물질을 상호 교환하기 때문에, 과거의 예열실 온도가 킬른 내부 연소 상태에 미친 영향이 내부 열 회수 및 재순환을 통해 다시 예열실로 전달되어 현재 온도에 반영된다. 이러한 누적 피드백 구조를 정량적으로 파악하기 위하여, 예열실 온도에 대해 자기상관함수(ACF, Autocorrelation function) 및 부분자기상관함수(PACF, Partial Autocorrelation function)를 분석하였다. ACF는 시차(Lag)  $k$ 에

대해  $x_t$ 와  $x_{t-k}$  간 전체 상관관, PACF는 중간 시차의 영향을 제거한 뒤의 직접 상관관을 측정하는 통계적 도구로서, 각각 지속성과 직접 의존 차수를 진단하는 데 주로 사용된다.

예열실 온도 데이터로부터 공정의 단·중기 메모리를 포괄하기 위해 50시차(Lag=50)까지 산출한 ACF와 PACF 결과를 각각 <Figure 6> (a)와 (b)에서 확인할 수 있다. 분석 결과, ACF는 초기 시차에서 높은 양의 상관관이 관찰된 후 완만하게 감소하였고, 수십 시차에 이르러서도 양의 상관관이 잔존하였다. 이는 예열실 온도가 열적 관성을 가져 과거 상태를 장기간 기억함을 시사한다. 반면, PACF는 1시차에서 뚜렷한 양의 스파이크가 나타났고, 2~4 시차의 작은 음의 값을 거친 뒤 0 부근으로 빠르게 수렴하였다. 이러한 ACF의 느린 감소와 PACF의 1시차 우세 조합의 결과는 예열실 온도의 단기 동학이 저차 자기회귀(AR(1)) 성분이 지배적이며, 더 먼 과거의 영향은 직접적인 효과보다 누적 혹은 간접적인 효과 형태로 반영됨을 의미한다. 즉, 예열실 온도는 강한 지속성을 보이는 시계열로 해석할 수 있다. 결과적으로 예열실 온도의 동적 변화를 설명·예측하기 위해서는, 단순한 정적 회귀 모델보다는 시계열 기반의 통계적 모델과 비선형적인 시계열 데이터의 동역학적 특성을 포착할 수 있는 딥러닝 기반 예측 모델을 통한 접근 방식이 적절하다.

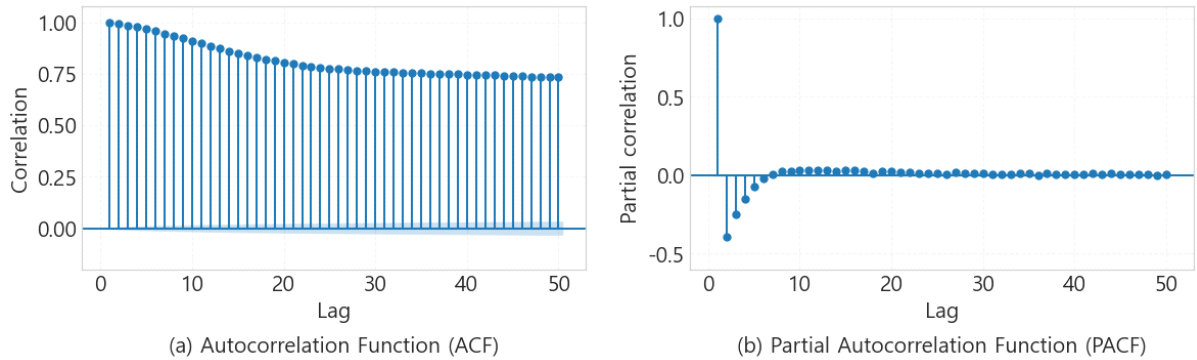


Figure 6. ACF-PACF of Preheater Temperature

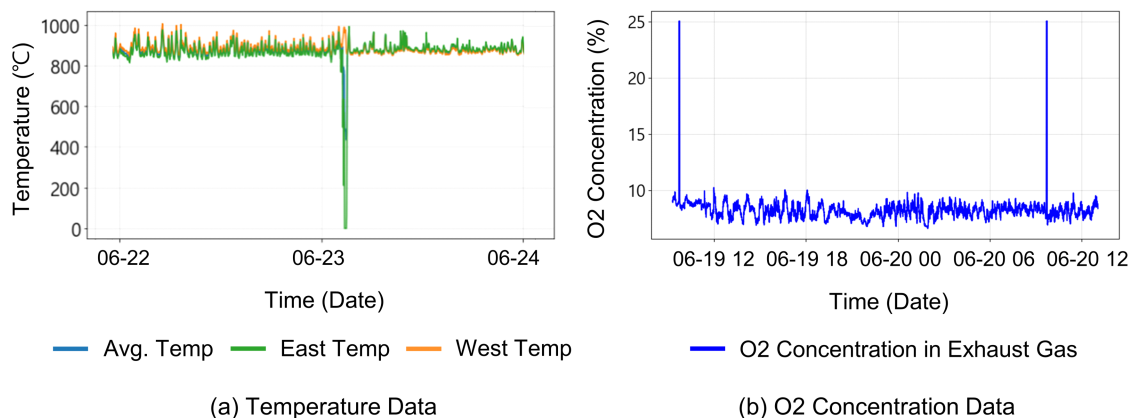


Figure 7. Outliers of Major Variables in Cement Manufacturing Data

## 5. 예측 · 제어 프레임워크 설계

### 5.1 학습 데이터 전처리

데이터의 품질을 확보하고 예측 모델 학습 안정성을 위해 수집된 데이터를 전처리하는 과정이 필요하다. 이에 본 연구에서는 이상치(Outliers) 처리, 결측치(Missing Values) 보간, 데이터 정규화(Normalization), 입출력 데이터 변환(Transform) 과정을 수행하였다.

시멘트 예열 공정 데이터에는 제조 공정 시계열 데이터에서 일반적으로 발생하는 센서 측정 오차, 원료 및 연료의 불균질성 등으로 인한 잡음(noise)이 존재한다. 예를 들어, 예열실의 양쪽 온도 센서 중 하나의 온도 센서 위에 순환 물질이 정착되면, <Figure 7(a)>와 같이 한쪽 온도가 잘못 측정될 수 있다. 또한, 배출 가스 성분 측정기는 공정 설비에서 발생하는 먼지에 취약하므로 Figure 7(b)와 같이 비정상적으로 큰 값의 데이터가 나타날 수 있다. 이러한 이상치는 도메인 지식과 통계 지표(IQR, 정규분포 등)를 활용하여 검출 및 제거하였으며, 제거된 이상치들은 시계열 데이터의 연속성을 보존하도록 선형 보간, spline 보간, forward/backward filling, Kalman filter 등의 방법으로 보간하였다.

공정 변수마다 값의 범위와 단위가 상이하여 학습 편향이 생기지 않도록, 모든 연속형 입력 변수들은 수식 (1)에 제시된 표준화(Standardization) 방법을 적용하여 데이터를 정규화하였다.  $x$ 는 원본 입력 데이터,  $\mu$ 는 평균(mean),  $\sigma$ 는 표준편차(standard deviation), 그리고  $z$ 는 정규화된 데이터를 의미한다. 이때, 평균과 표준편차는 학습 구간에서만 계산하여 정보 누출을 방지하였다.

$$z = \frac{(x - \mu)}{\sigma} \tag{1}$$

본 연구에서는 과거 공정 데이터의 패턴을 학습하여 미래 예열실 온도의 변화를 예측하기 위해, 과거 공정 변수들을 입력으로, 미래 예열실 온도를 출력으로 재구성하는 데이터 변환 과정을 수행했으며, 변환하는 방법은 <Figure 8>에 나타내었다. 과거부터 현재까지의 데이터를 입력으로 정의했을 때, 예측하고자 하는 미래 시점에 따라 <Figure 8> (a)~(c)와 같이 데이터를 변환할 수 있다. 출력 데이터를 <Figure 8> (a)와 같이 구성하면, 미래 3개 시점을 동시에 예측할 수 있고, 출력 데이터를 <Figure 8> (b)와 같이 구성하면, 미래 5개 시점을 예측하도록 구성하여 상대적으로 장기적인 미래를 예측할 수 있다. 또한, <Figure 8> (c)와 같이 과거 입력 데이터와 미래 출력 데이터 간에 시간 간격을 설정하여 원하는 미래 예측 시점을 조정할 수 있다. 본 연구에서는, 데이터 분석을 통한 시간 지연, 자기 상관 결과를 반영하여 과거 입력 데이터와 미래 출력 데이터의 크기를 설정하였다. 이를 통해 모델은 과거 공정 데

이터에 대한 시계열적 의존성을 반영할 수 있으며, 향후 예열실 온도의 동적 변화를 예측할 수 있다.

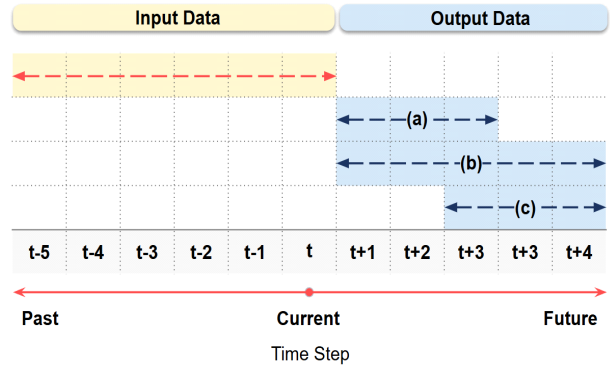


Figure 8. Transformation of Past Input Data and Future Output Data for Time-series Prediction

### 5.2 예측 모델 구조 설계 및 학습

데이터 분석 결과에 따라 시멘트 예열실 온도의 비선형성, 시간 지연을 반영할 수 있는 데이터 기반 예측 모델 구조를 설계하였다.

#### (1) 입력 변수 선정

시멘트 예열 공정의 특성을 반영하여 예열실 온도에 영향을 주는 입력 변수를 선정하기 위해 도메인 지식을 기반으로 주요 공정 변수들을 선정하였다. 일반적으로 시멘트 예열 공정에서 원료(Raw Meal)는 예열실 상단에 투입, 하부로 이동하며 연료와 뜨거운 공기에 의해 예열된다. 이때 예열실 내부를 고온의 상태로 유지하기 위해 유연탄(Coal), 대체연료(AF)가 주요 열원으로 사용된다. 그 중, 대체연료는 폐합성수지, 폐유, 페타이어, 폐섬유, 유기 슬러지 등의 다양한 종류가 사용되고 있다. 다양한 종류만큼이나 연료의 특성에 따라 예열실 온도에 미치는 영향력이 달라진다. 예열실 내부에서 원료와 연료를 가열하기 위해서는 충분한 연소 공기(Combustion Air) 또한 필요하다. 쿨러를 통해 들어온 외부 공기는 예열실 상부로 재순환되어 연소에 필요한 산소를 제공한다. 이와 같은 과정에서 예열-소성-냉각 공정은 서로 열과 물질을 상호 교환하며, 공정 변수 간에 시간 지연을 동반한 인과적 상관성이 나타난다. 본 연구에서는 이러한 공정 원리에 의거하여 입력 변수를 선정하였다.

입력 변수로 선정된 주요 공정 변수들은 예열실과 소성로의 도면상에 측정 위치를 표시하여 <Figure 9> (a)에 나타내었다. 이를 기반으로, 공정 변수 간 물리적인 거리와 인과적 관계를 <Figure 9> (b)의 인과관계 그래프로 나타내었고, 여러 공정 변수 간 복잡한 상호작용과 시계열적 패턴을 함께 학습할 수 있도록 입력 데이터를 구성하였다.

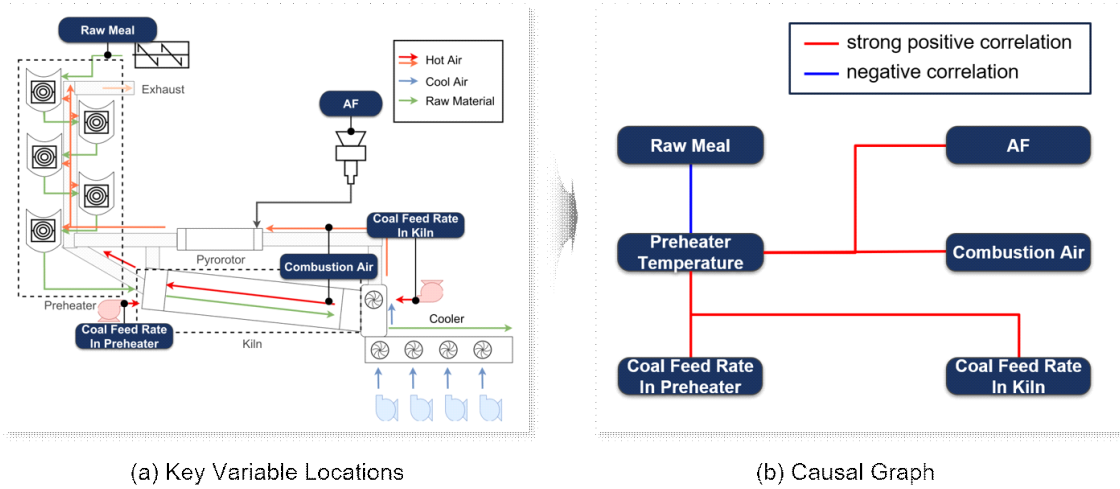


Figure 9. Key Variable Locations and Causal Graph in the Preheating and Clinkerization Process

(2) 네트워크 구조

본 연구에서는 미래 예열실 온도 예측을 위해 합성곱 신경망 기반 예측 모델을 사용하였다. 합성곱 신경망 모델은 시계열 데이터의 국부적인 패턴을 효과적으로 학습할 수 있기 때문에, 산업 데이터 예측 분야에서 널리 사용되고 있다(Du *et al.*, 2019). 시멘트 예열 공정에도 대체연료 열량에 따라 단시간 내에 변화하는 예열실 온도를 예측하기 위해 합성곱 신경망 모델이 활용될 수 있으며, 본 연구에서 사용한 네트워크 구조는 <Figure 10>에 나타내었다. 입력 데이터(Input Data)의  $d_{in}$ 은 입력 변수 개수를,  $n_{hist}$ 는 입력 데이터의 크기를 의미하며, 출력 결과(Output)의  $n_{pred}$ 는 출력 데이터의 크기, 즉 예측하고자 하는 미래 예열실 온도 예측값의 개수를 의미한다. 또한, 학습의 안정성과 빠른 수렴 속도를 확보하기 위해 손실 함수는 MSE를, 최적화 알고리즘으로는 Adam을 사용하였고, 모델의 학습 과정에서 과적합(Overfitting)을 방지하기 위하여 조기 종료(Early Stopping) 기법을 적용하였다. 따라서, 본 연구에서 제안된 예측 모델은 다양한 공정 조건에서 수집된 데이터를 바탕으로 예열실 온도의 동적 변화를 효과적으로 설명할 수 있었으며, 검증 데이터에 대해서도 비교적 뛰어난 예측 정확도를 보였다.

5.3 설명가능 인공지능 기반 제어 모델 구조 설계

본 연구에서 제안하는 제어 모델은 설명가능 인공지능의 입

력 변수 중요도 정량화 기술을 기반으로 실시간으로 변화하는 예열실 온도에 대한 유연탄 투입량의 영향력을 판단하고, 다양한 공정 상황에 따라 최적의 유연탄 투입량을 제시하도록 설계되었다.

설명가능 인공지능은 입력 변수의 중요도를 정량화하기 위해 반사실적 기반의 국소적 민감도 분석(Counterfactual-based Local Sensitivity Analysis) 방법을 활용하였다. 반사실적이란, 입력 데이터의 조건을 다르게 했을 때 산출된 가상의 결과로서, 현재 입력 데이터에서 유연탄 투입량 입력값을 인위적으로 변경하는 시나리오를 구성하고, 예열실 온도 출력값의 변화를 확인하여 유연탄 투입량의 중요도를 탐색한다. 이때, 유연탄 투입량의 중요도는 예열실 온도를 1℃만큼 변경하는 데 필요한 유연탄 투입량을 의미한다. 이와 같이, 반사실적 기반의 시뮬레이션은 시계열 데이터의 시간 흐름을 따라 입력 변수 조작이 가능하므로, 시멘트 예열 공정과 같이 연료 투입량에 대한 온도 반응이 지연된 형태로 나타나는 공정에서 직관적이고 현실적인 제어 설계로 연결될 수 있다. 다양한 공정 상태에서 예열실 온도가 유연탄 투입량으로 인해 얼마만큼 변화하는지를 정량적으로 판단할 수 있으며, 이에 따라 공정 현장 운전원에게 AI가 제시한 유연탄 제어값에 대한 해석을 제공하고, 목표 온도에 도달하기 위한 유연탄 제어값의 타당성을 향상시킬 수 있다.

따라서, 본 연구에서는 예측 모델의 반사실적 입력 시나리오를 구성하고, 이로부터 도출된 유연탄 투입량의 입력 중요




Figure 10. Architecture of the Proposed Prediction Network

도를 <Figure 11>의 유연탄 제어값 산출 과정에 활용하였다. 먼저, 과거 유연탄 투입량(Past Coal (Controlled))을 예측 모델(Prediction Model)에 입력하여 미래 예열실 온도(Future Temp (Predicted))를 예측한다. 그리고 미래 예열실 온도와 적정 온도에 도달하기 위한 경로(Trajectory)의 차이값( $\Delta$ Temp)을 구하고, 유연탄 투입량의 입력 중요도를 적용하여, 미래 예열실 온도가 적정 온도에 도달하기 위해 필요한 유연탄 변경량( $\Delta$ Coal)을 계산한다.






Figure 11. Workflow of Determining Coal Feed Control Values

유연탄 제어값을 산출하는 방법에 대한 이해를 돕기 위해 특정 시점의 데이터에 대한 시뮬레이션 결과를 <Figure 12>로 시각화하였다. 먼저, 과거 유연탄 투입량(Past Coal(Measured))을 사용하여 미래 예열실 온도(Future Temp(Predicted))를 예측했다면, 미래 예열실 온도가 적정 예열실 온도(Target Temp)에 도달하기 위한 가이드라인(Trajectory)을 설정한다. 가이드라인은 유연탄 투입량과 예열실 온도 간의 시간 지연 현상을 고려하여 단계적으로 적정 온도에 도달하기 위해 제시한 방법으로, <Figure 12>에서 예열실 적정 온도 값은 900℃이므로, 미래 예열실 온도 예측값이 900℃까지 상승하는 방향으로 가이드라인을 제시하였다. 그리고 앞서 언급했던 바와 같이, 미래 예열실 온도 예측값과 가이드라인의 차이값( $\Delta$ Temp)을 계산해서, 미래 예열실 온도가 가이드라인에 도달하기 위한 온도 변화량을 확인한다. 이때 설명가능 인공지능이 계산한 유연탄 투입량의 입력 중요도를 사용하여 미래 예열실 온도 예측값을 차이값( $\Delta$ Temp)만큼 변화시키기 위해 필요한 유연탄 투입량의 변경량( $\Delta$ Coal)을 산출한다. 최종적으로 산출된 제어값은



Label	Description
Past Temp (Measured)	Measured past preheater temperature
Future Temp (Measured)	Measured future preheater temperature
Future Temp (Predicted)	Predicted future preheater temperature
Future Temp (Controlled)	Predicted preheater temperature when operated under the controlled coal feed rate
Trajectory	Guideline trajectory for the future preheater temperature to reach the target value
Target Temp	Desired setpoint for the preheater; the controller aims to keep the measured temperature at this level.



Label	Description
Past Coal (Measured)	Measured past coal feed rate in the preheater
Future Coal (Measured)	Measured future coal feed rate in the preheater
Past Coal (Controlled)	Controlled past coal feed rate in the preheater

Figure 12. Preheater Temperature Prediction and Coal Feed Control Results

설명가능 인공지능이 제시한 유연탄 투입량의 입력 중요도에 대한 오차로 인해 예열실 온도가 잘못 제어되는 문제를 최소화하기 위해서 경우에 따라 가중치를 설정하여 보정한다. 만약 산출된 제어값을 사용하여 예열실 온도의 변화를 시뮬레이션했을 때, 예열실 온도가 적정 온도에 도달하지 않는다면 유연탄 투입량의 변경량에 더 큰 가중치를 부여하고, 반대로 적정 온도 이상으로 과도하게 제어된다면 유연탄 투입량 변경량에 작은 가중치를 부여하여 적정 온도에 수렴할 수 있도록 보정하였다.

위와 같은 과정으로 산출된 유연탄 투입량의 변경량( $\Delta$ Coal)은 과거 유연탄 투입량(Past Coal(Measured))에 더하여 유연탄 투입량 제어값(Past Coal(Controlled))으로 공정에 적용된다. 동시에 유연탄 제어값을 공정에 적용했을 때의 미래 예열실 온도 예측값(Future Temp(Controlled))을 제공하여, 제안된 제어 모델을 적용했을 때 미래 예열실 온도가 적정 온도에 수렴하는지 확인할 수 있다. 이를 통해 현장 운전원은 제안된 모델의 유연탄 제어값에 대한 의사결정 과정을 직관적으로 이해할 수 있고, 미래 예열실 온도 제어의 적절성을 직접 판단할 수 있다.

## 6. 시뮬레이션 및 모델 검증

본 연구에서 제안된 설명가능 인공지능 기반 예측 제어 시스템의 성능을 평가하고자 예측 모델의 정확도를 측정하고 과거 시멘트 예열 공정 데이터를 사용하여 시뮬레이션을 진행하였다. 평가의 공정성을 위해 모델 개발 과정에서 참고하지 않은 신규 데이터를 사용하였으며, 실제 공정의 외란 상황을 구현하고자 예측 제어 결과 데이터에 무작위로 잡음을 생성하여 시뮬레이션 환경을 구축하였다.

### 6.1 정량적 성능 평가 및 개선 효과

예측 모델의 정확도를 평가하기 위해, 예측 시점(forecast horizon)에 따라 네 가지 정량적 성능 지표를 측정하였다. <Table 2>와 같이 예측 시점은 단기(short-term), 중기(mid-term), 장기(long-term)로 구분하였고, 일반적으로 사용되는 MAE, RMSE, MAPE,  $R^2$ 를 평가 지표로 선정하였다. 그 결과, 모델의 단기 예측 성능은 MAE 1.48, RMSE 2.01, MAPE 0.16,  $R^2$  0.97로 매우 우수하게 나타났다. 이는, 모델이 학습한 과거 입력 데이터가 가까운 미래의 예열실 온도 변화를 설명할 수 있으며, 데이터 분석 과정에서 도출한 과거 입력 데이터와 미래 예열실 온도 간의 시차가 적절함을 의미한다. 반면, 예측 시점이 멀어질수록 MAE, RMSE, MAPE가 점진적으로 증가하고  $R^2$ 는 감소하는 경향을 보였다. 이와 같은 결과는, 현재와 미래 시점 사이에 발생한 공정 조건 변화 등으로 인해 장기 미래의 예측 정확도가 상대적으로 저하되었음을 의미한다. 다만, 예열실 평균 온도가 약 900℃임을 고려할 때, RMSE를 기준으로 6℃ 내외의

오차는 상대적으로 작은 편이며 장기 미래에 대한 예측 성능도 우수한 편이다. 또한, 온도를 제어할 때에는 장기 시점의 예측 정확도가 비교적 낮더라도, 현재 온도로부터 미래 온도까지의 증감 방향을 판단하여 유연탄 제어값을 결정하는 것이 중요하다. 따라서 제안한 모델은 가까운 미래의 예열실 온도를 높은 정확도로 예측할 수 있고, 장기 미래 온도 변화의 방향성과 추세를 예측하여, 예열실의 안정적인 운전 및 연료 투입 제어 의사결정 지원에 유용하게 활용될 수 있음을 시사한다.

Table 2. Performance Metrics According to Forecast Horizons

	MAE	RMSE	MAPE	$R^2$
short-term	1.4757	2.0138	0.1602	0.9734
mid-term	3.2382	4.4166	0.3512	0.8806
long-term	4.9422	6.7565	0.5358	0.7253

본 연구에서 수집된 데이터는 PID 제어를 사용하여 예열실 온도를 제어하는 공정으로부터 수집되었다. 따라서, 과거 예열실 온도 실측값과 시뮬레이션 결과를 비교하여 대체연료가 투입되고 있는 상황에서 제안하는 모델이 예열실 온도를 안정적으로 제어할 수 있는지 정량적으로 평가하고자 하였다. 대체연료 투입량에 따라 공정 효율이 떨어지고 예열실 온도 편차가 커지는 경향이 있으므로, <Table 3>과 같이 대체연료 투입량에 따라 데이터를 구분하여 예열실 온도 편차를 비교하였다. 대체연료가 5t/h 미만인 데이터는 대체연료가 거의 사용되지 않는 경우이기 때문에 비교 대상에서 제외하였다. 그 결과, 모든 경우에 대해서 제안한 모델이 운전한 데이터의 예열실 온도 편차가 더 작다는 결과를 얻을 수 있었다. 특히 대체연료가 15.5t/h 이상 17.6t/h 미만으로 투입되는 경우에 PID 제어를 사용한 실제 운전 데이터보다 약 40%에 가까이 온도 편차를 줄임으로써 가장 높은 개선율을 보였다. 대체연료 투입량이 많을수록 예열실 온도 편차 감소율은 낮아졌지만, 평균적으로 36℃만큼 편차가 발생하였으며, PID 제어가 적용되었을 때 평균 예열실 온도 편차(44.4℃)보다 약 19% 개선되었다.

Table 3. Preheater Temperature Deviations by AF Feed Rate into the Preheater

AF Feed Rate into Preheater (t/h)	PID-Controlled	AI-Controlled	Improvement Rate with AI Control (%)
$5 \leq AF < 15.5$	59	49	-16.95
$15.5 \leq AF < 17.6$	48	29	-39.58
$17.6 \leq AF < 19.8$	41	35	-14.63
$19.8 \leq AF < 21.6$	40	34	-15.00
$21.6 \leq AF$	34	33	-2.94
Average	44.4	36	-18.92

### 6.2 PID 운전 데이터와 AI 제어 결과 비교

기존 PID 제어 데이터와 비교하여 제안한 모델을 사용했을 때 사전 예측 제어 효과를 확인하기 위해 <Figure 13>과 같이 비교하였다. <Figure 13> (a)는 실제 시멘트 예열 공정에서 PID 제어를 적용한 결과를, <Figure 13> (b)는 본 연구에서 제안하는 설명가능 인공지능 기반의 예열실 온도 예측 제어 모델을 시뮬레이션한 결과를 나타낸다. 동등한 조건에서 비교하기 위해, 두 가지 경우 모두 예열실 적정 온도가 890°C인 구간을 선택하였다.

PID 제어 데이터에서는, 이미 상승 혹은 하강한 예열실 온도에 대해서 피드백 제어를 통해 비효율적인 유연탄 제어 패턴이 이어지는 상황을 확인할 수 있었다. 먼저, A 시점에서 예열실 온도가 적정 온도(Target Temperature) 이하로 감소하였을 때 유연탄 투입량을 증가시키는 제어가 적용되었다. 그리고, B 시점에서 대체연료 투입량 증가로 인한 미래 예열실 온도의 상승을 예측하지 못하고 유연탄 투입량을 충분하게 감소하지 못했다. 이로 인해, C 시점에서 예열실 온도가 적정 온도 이상으로 과도하게 상승하였고, 이미 예열실 온도가 과도하게 상승한 상태에서 유연탄 투입량을 감소시켰으므로, D 시점에서 또다시 예열실 온도가 과도하게 상승하였다. 결국, 과도하게 상승한 예열실 온도를 바로잡기 위해 유연탄 투입 설비의 전원을 꺼서 유연탄 투입량을 0t/h로 제어하고, 대체연료 투입량도 감소시켰다. 이와 같은 제어는 유연탄 투입 설비에 부하를 줄 수 있으며, 급변하는 온도를 제어하기 위해 대체연료 사용량을 줄이고 유연탄 사용량을 증가시키는 문제를 야기한다.

반면, 제안한 모델을 적용했을 때에는 미래 예열실 온도를

예측하고 적정량의 유연탄 제어값을 제시하여, 예열실 온도를 적정 범위 이내에서 안정적으로 유지되도록 제어하였다. 먼저, A 시점에서 미래 예열실 온도가 감소할 것을 예측하여 현재 예열실 온도가 적정 온도 이상임에도 불구하고 유연탄 투입량을 소폭 상승시키는 제어를 하였다. 이로 인해, 예열실 온도가 과도하게 감소하지 않고 적정 온도 범위 이내로 유지될 수 있었다. 그리고 B 시점에서 대체연료 투입량이 증가하는 패턴을 학습하여 미래 예열실 온도가 상승할 것을 예측하였고, 이에 따라 유연탄 투입량도 단계적으로 감소시키도록 제어하였다. 그러나, B 시점에서 대체연료 투입량을 증가시킴으로 인해 예열 공정 상태가 불안정해졌고 C, D 시점에서 예열실 온도가 갑작스럽게 상승하는 경우가 생겼다. 이 경우에는, 단기 미래의 예열실 온도가 증가함을 정확하게 예측하여 사전에 유연탄 투입량을 충분히 감소시켰고, 예열실 온도가 적정 온도 범위 이내에 도달하도록 제어하였다. 이와 같은 결과는 제안한 제어 모델이 다른 공정 변수들의 변화에도 유연하게 대응하여 예열실 온도를 일정하게 유지할 수 있음을 의미한다.

### 6.3 다양한 공정 상황의 AI 제어 결과 분석

본 연구에서 제안한 모델의 강건성을 확인하기 위해 실제 공정 운영에 적용되었을 때 마주할 수 있는 다양한 공정 외란 상황에 대해서 시뮬레이션 결과를 분석하였다.

먼저, <Figure 14> (a)는 킬른 내부 원료 소성 상태가 악화된 상황에 대한 시뮬레이션 결과이다. 킬른 내부 원료가 충분히 소성되지 않으면 킬른 동체를 회전시키는 메인모터의 전류량이 감소하고, 소성 상태가 회복될 때까지 예열실 온도를 높이

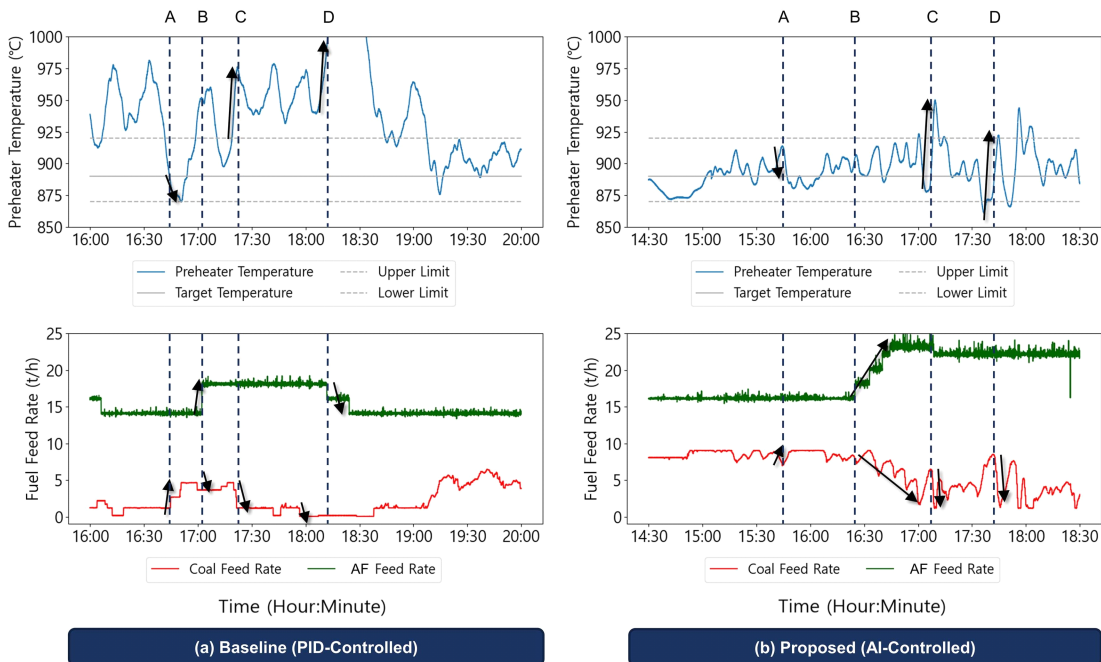


Figure 13. Preheater Temperature and Coal Feed: PID-Controlled vs AI-Controlled

거나 원료 투입량을 감소시켜서 제한적인 상태로 운전한다. 1시 30분경 소성 상태 불량으로 인해 킬른 모터 전류가 서서히 감소하자, 예열실 적정 온도가 높아졌다. 이에 따라 제안된 모델은 유연탄 투입량을 증가하여 예열실 온도를 적정 범위 이내에 유지하고 소성 상태를 회복할 수 있도록 충분한 열량을 공급하는 방안을 제시하였다. 그러나, 당시에는 소성 상태가 충분히 회복되지 않아서 2시 25분경부터 메인 모터 전류가 낮아졌고 4시 30분경 공정 내부 연소 상태의 불안정함을 줄이고자 예열실 대체연료 투입량을 낮춰서 제어하였다. 그럼에도 불구하고 5시 15분경 메인모터 전류가 급격히 감소하여 원료 투입량을 제한하여 예열 소성 공정을 운전하였다. 이와 같은 상황에서 제안된 모델은 대체연료 투입량의 감소로 인한 미래 예열실 온도의 하강을 예측하여 사전에 유연탄 투입량을 증가시키고, 적정 온도에 따라 단계적으로 예열실 온도를 상승시켜 회복하는 방안을 제시하였다.

다음으로, <Figure 14> (b)는 예열실 포킹 작업으로 인해 소성 공정 상태가 불안정해진 상황에 대해 시뮬레이션한 결과를 시각화하였다. 포킹은 예열실 내부에 차가운 공기나 물을 주입하여 적분된 원료를 제거하고 막혀있던 흐름을 뚫어주는 작업이다. 따라서, 일반적으로 예열실 포킹 작업 시에는 유연탄 투입량을 증가시켜 정상적인 구간보다 더 많은 열량을 공급해야 한다. 제안된 모델은 이러한 공정 상황을 고려하여 원료를 열분해하기 위한 충분한 열량을 공급하기 위해 5시 30분경 포킹 작업이 발생했을 때 예열실 유연탄 투입량을 증가하도록 제어하였다. 그 결과, 예열실 온도가 적정 온도 범위보다 소폭 상승하였고, 만약 실제 공정에 적용되었다면 이로 인해 예열 소성 공정 상태가 회복되어 6시 이후 메인 모터 전류가 600A 이상 유지될 수 있었을 것으로 기대된다.

마지막으로, <Figure 14> (c)는 킬른 운전을 중단하기 직전의 공정 상황에 대한 시뮬레이션 결과이며, 킬른 모터 전류와 원료 투입량이 동시에 감소하고 있다. 이 경우에는 <Figure 14> (a)처럼 소성 상태 악화로 인한 원료 제한 운전이 아니라, 원료 투입량이 감소하여 킬른 모터 전류가 감소하는 상황이다. 따라서 감소한 원료 투입량만큼 비교적 적은 열량이 필요한데, 대체연료 투입량을 유지하고 있으므로, 제안된 모델은 원료 투입량 감소로 인한 미래 예열실 온도의 하강을 예측하고 유연탄 투입량을 적정량 감소시켜 예열실 온도가 적정 범위 이상 과도하게 상승하지 않도록 제어하였다.

### 7. 결론 및 고찰

본 연구에서는 탄소 중립 실현을 위해 시멘트 생산 공정에서 대체연료 사용량이 증가함에 따라 발생하는 예열 공정의 불안정성을 해소하기 위하여, 설명가능 인공지능 기반 예열실 온도 예측 제어 모델을 제안하였다. 제안된 모델은 미래 공정 상황을 사전에 예측하여 선제적으로 대응할 수 있다는 점에서 기존의 전통적인 제어 기법들과 차별성을 가지며, 특히 제어 결과에 대한 설명을 함께 제공함으로써 블랙박스 문제를 완화하고 신뢰성과 현장 적용성을 높였다.

실제 시멘트 생산 기업의 예열실과 킬른 운전 데이터를 활용한 시뮬레이션을 통해 대체연료가 5t/h 이상 투입되는 조건에서 예열실 온도 편차를 약 19% 줄이며 예열 공정을 안정적으로 제어할 수 있음을 증명하였다. 이는 제안된 모델이 대체연료 사용으로 인한 예열 공정의 불안정한 변화에 효과적으로 대응하며, 공정 최적화와 에너지 효율 향상에 기여할 수 있음

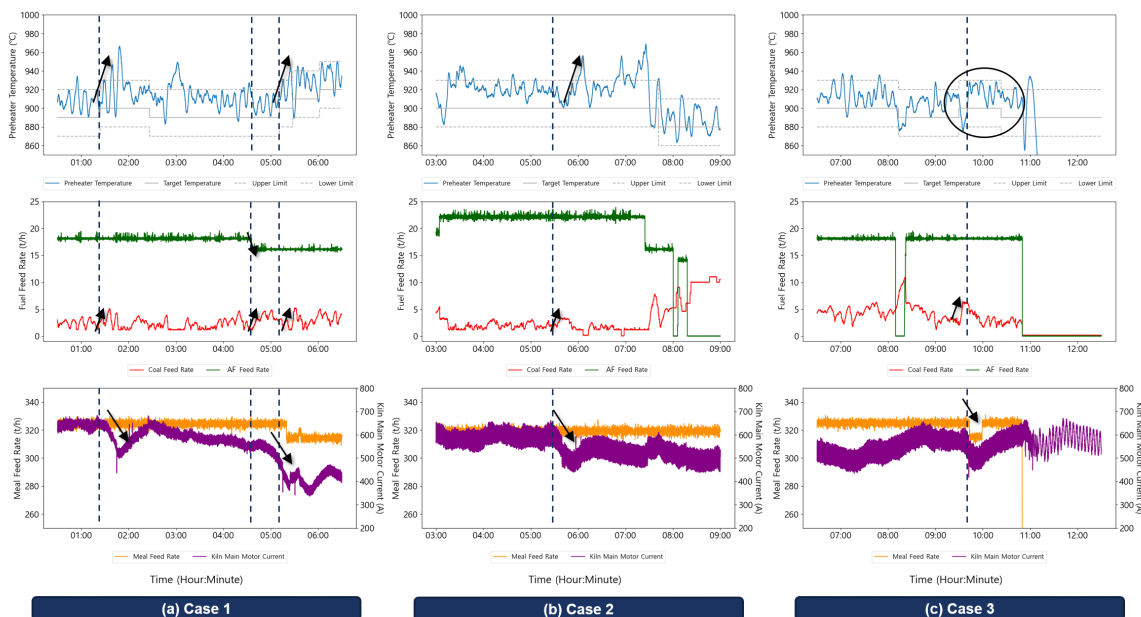


Figure 14. Preheater Temperature and Coal Feed: AI-Controlled Responses to Disturbances

을 보여준다.

더 나아가 본 연구는 설명가능 인공지능을 제조 공정에 접목함으로써 제어 결과의 투명성을 확보하여 현장 운전원이 모델의 의사결정을 신뢰하고 실제 운전에서 활용할 수 있는 기반이 될 수 있다. 이에 따라, 탄소 중립을 위한 시멘트 산업의 지속가능한 운영에 기여할 수 있는 가능성을 제시하였다.

향후 연구에서는 제안된 모델을 실시간 제어 시스템과 통합하여, 다양한 공정 환경에서 즉각적인 피드백과 제어가 가능하도록 확장하는 것을 목표로 한다. 이를 통해 본 연구에서 제안한 모델은 실제 산업 현장에서의 적용성과 실용성을 한층 더 높일 수 있을 것으로 기대된다.

## 참고문헌

- Back, J. I., Kim, J. J., and Won, P. S. (2023), Case Study on NO<sub>x</sub> Emissions from Cement Kiln before and after Applying Multi-stage Combustion Technology, *Journal of the Korean Recycled Construction Resources Institute*, **11**(3), 267-275.
- Du, S., Li, T., Yang, Y., Hornig, S. J. (2019), Deep air quality forecasting using hybrid deep learning framework, *IEEE Transactions on Knowledge and Data Engineering*, **33**(6), 2412-2424.
- European Cement Research Academy (2021), Sulphur and chloride cycles and the use of alternative fuels or raw materials, ECRA Newsletter, 4/2021. <https://www.ecra-online.org/newsletters/sulphur-and-chloride-cycles-and-the-use-of-alternative-fuels-or-raw-materials>.
- Fatahi, R., Nasiri, H., Homafar, A., Khosravi, R., Siavoshi, H., and Chehreh Chelgani, S. (2023), Modeling operational cement rotary kiln variables with explainable artificial intelligence methods-a "conscious lab" development, *Particulate Science and Technology*, **41**(5), 715-724.
- Fayaz, S. J., Montiel-Bohórquez, N., Bishnoi, S., Romano, M., Gatti, M., and Krishnan, N. A. (2025), Industrial-scale prediction of cement clinker phases using machine learning, *Communications Engineering*, **4**(1), 94.
- Hao, X., Wang, X., Liu, P., Wang, X., and Liu, J. (2023), Control of Cement Pre-Decomposition System: A Parallel Cascade Neural Network Model Predictive Control Method, *SSRN Electronic Journal*. [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=4590](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4590)
- 797.
- Hercog, J., Lewtak, R., Glot, B., Józwiak, P., Nehring, G., Tavares, V. D., Nunes, A. M., and Gaspar, D. (2023), Pilot testing and numerical simulations of the multifuel burner for the cement kiln, *Fuel*, **342**, 127801.
- Ma, H., Liu, Z., Wang, X., and Ma, H. (2022), Optimization control of thermal efficiency for cement raw meal pre-decomposition based on two-layer structure model predictive control, *IEEE Access*, **11**, 4057-4065.
- PEDERSEN, M. N. (2018), Co-firing of alternative fuels in cement kiln burners, Ph.D. thesis, Technical University of Denmark (DTU), Kgs. Lyngby, Denmark, **283**.
- Salaripoor, H., Yousefi, H., and Abdoos, M. (2025), Life cycle environmental assessment of Refuse-Derived Fuel (RDF) as an alternative to fossil fuels in cement production: A sustainable approach for mitigating carbon emissions, *Fuel Communications*, **22**, 100135.
- Stübinger, J. and Walter, D. (2022), Using multi-dimensional dynamic time warping to identify time-varying lead-lag relationships, *Sensors*, **22**(18), 6884.
- Tsamatsoulis, D. C. and Zlatev, G. (2016), PID parameterization of cement kiln precalciner based on simplified modeling, *Int. J. Neural Netw. Adv. Appl.*, **3**, 41-45.
- Yixiang, S. H. U., Zhang, H., Zhang, J., Wei, X. U., Cheng, Y., Zhang, S., Mikulčić, H., Liao, Y., Shi, Z., and Guo, Y. (2024), Numerical study on oxy-biomass co-firing in a cement rotary kiln, *Thermal Science*, **28**(5 Part B), 4407-4419.

## 저자소개

**이예림** : 부산대학교 수학과에서 2022년 학사학위를 취득하고 인이지에서 인공지능연구소 선임연구원으로 재직 중이다. 연구 분야는 인공지능 기반 시계열 데이터 예측 및 설명가능 인공지능 기반 최적화이다.

**유보선** : 인하대학교 정보통신공학과에서 2008년 학사, 2010년 석사, 2015년 박사학위를 취득하고 인이지에서 개발팀장급 기술이사로 재직 중이다. 연구 분야는 인공지능 기반 시계열 데이터 예측 및 설명가능 인공지능 기반 최적화이다.