



정수처리 실증화 시설에서 AI 기반 사전 예측 응집제 제어 방식의 운영 성능 평가

Evaluation of operational performance of AI-based predictive coagulant control in a water treatment demonstration facility

연승재¹ · 안주석^{1,2} · 오창석¹ · 이복진¹ · 오현제^{1,3*}

Seungjae Yeon¹ · Jusuk An^{1,2} · Changseog Oh¹ · Bokjin Lee¹ · Hyun Je Oh^{1,3*}

¹한국건설기술연구원 환경연구본부

²연세대학교 건설환경공학과

³과학기술연합대학원대학교

¹Department of Environment Research, Korea Institute of Civil Engineering and Building Technology

²Department of Civil Environmental Engineering, Yonsei University

³University of Science & Technology

pp. 487-500

pp. 501-509

pp. 511-527

pp. 529-539

pp. 541-551

pp. 553-564

pp. 565-582

pp. 583-596

Received 31 March 2026, revised 19 June 2026, accepted 21 June 2026.

*Corresponding author: Hyun Je Oh (E-mail: hjoh@kict.re.kr; Fax: 031-910-0291, Tel. 031-910-0295 (010-3340-0295))

1 연승재 (박사후연구원) / Seungjae Yeon (Postdoctoral Researcher)

경기도 고양시 일산서구 고양대로 283, 10223

283, Goyang-daero, Ilsanseo-gu, Goyang-si, Gyeonggi-do, Republic of Korea, 10223

1,2 안주석 (전임연구원) / Jusuk An (Researcher)

경기도 고양시 일산서구 고양대로 283, 10223

283, Goyang-daero, Ilsanseo-gu, Goyang-si, Gyeonggi-do, Republic of Korea, 10223

서울특별시 서대문구 연세로 50, 03722

50, Yonsei-ro, Seodaemun-gu, Seoul, Republic of Korea, 03722

1 오창석 (박사후연구원) / Changseog Oh (Postdoctoral Researcher)

경기도 고양시 일산서구 고양대로 283, 10223

283, Goyang-daero, Ilsanseo-gu, Goyang-si, Gyeonggi-do, Republic of Korea, 10223

1 이복진 (박사후연구원) / Bokjin Lee (Postdoctoral Researcher)

경기도 고양시 일산서구 고양대로 283, 10223

283, Goyang-daero, Ilsanseo-gu, Goyang-si, Gyeonggi-do, Republic of Korea, 10223

1,3 오현제 (교수) / Hyun Je Oh (Professor)

경기도 고양시 일산서구 고양대로 283, 10223

283, Goyang-daero, Ilsanseo-gu, Goyang-si, Gyeonggi-do, Republic of Korea, 10223

대전광역시 유성구 가경로 217, 34113

217, Gajeong-ro, Yuseong-gu, Daejeon 34113, Republic of Korea

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

요약문

본 연구에서는 정수처리 실증화 시설을 대상으로 AI 기반 사전 예측 응집제 제어 방식의 운영 성능을 평가하였다. 제안된 시스템은 기존 자 테스트 기반 사후 대응 운영의 한계를 보완하기 위해 응집제 주입농도를 사전에 예측하고, 이를 실제 공정 제어에 적용하도록 구성하였다. 이를 위해 Ridge, Lasso, Decision Tree, Random Forest(RF), Artificial Neural Network(ANN), Deep Neural Network(DNN), LSTM-RNN으로 구성된 모델 뱅크를 구축하여 최적 응집제 주입농도를 예측하였다. 모델 성능 평가 결과, ANN 및 DNN은 낮은 RMSE와 안정적인 오차 분포를 나타냈으며, RF는 PACS 및 PACI 조건 모두에서 가장 높은 선택 빈도를 보였다. 예측된 응집제 주입농도는 실시간 유입 유량을 반영하여 주입유량으로 변환한 후 SCADA-HMI-PLC 기반 제어 시스템에 적용하였다. 실증 운전 결과, 사전 예측 방식은 기존 사후 대응 방식 대비 PACS 조건에서 39.71%, PACI 조건에서 54.08%의 응집제 사용량을 절감하였다. 또한 침전지 처리수 탁도는 운영 기간 동안 1 NTU 이하로 안정적으로 유지되었다. 이러한 결과는 AI 기반 사전 예측 응집제 제어 방식이 본 연구의 실증 운전 조건 내에서 수질 안정성을 유지하면서 약품 주입 효율을 향상시킬 수 있는 적용 가능성을 시사한다.

주제어: 정수처리 실증화시설, 사전 예측 제어, 응집제 주입, 모델 뱅크, 운영 성능

ABSTRACT

This study evaluated the operational performance of AI-based predictive coagulant control in a water treatment demonstration facility. The proposed system was designed to overcome the limitations of conventional reactive operation based on jar tests by predicting coagulant dosage in advance and applying the predicted values to actual process control. A Model Bank consisting of Ridge, Lasso, Decision Tree, Random Forest (RF), Artificial Neural Network (ANN), Deep Neural Network (DNN), and LSTM-RNN models was developed to predict the optimal coagulant dosing concentration. Among the models, ANN and DNN showed low RMSE values and stable error distributions, while RF was most frequently selected under both PACS and PACI dosing conditions. The predicted coagulant dosing concentration was converted into a dosing flow rate using real-time influent flow data and then applied to the SCADA-HMI-PLC-based control system. During demonstration operation, the predictive control reduced coagulant use by 39.71% for PACS and 54.08% for PACI compared with conventional reactive control. In addition, sedimentation basin effluent turbidity was consistently maintained below 1 NTU. These results indicate that AI-based predictive coagulant control can improve operational efficiency while maintaining stable water quality under the tested demonstration conditions.

Key words: Water treatment demonstration facility, Predictive control, Coagulant dosing, Model Bank, Operational performance

1. 서 론

정수처리 공정 중 혼화·응집 공정은 취수된 원수에 포함된 탁질물질 및 콜로이드성 물질을 제거하기 위한 핵심 단위 공정이다 (Environmental Protection Agency, 2002). 응집제를 주입하여 미세 입자를 응집·침전시키는 방식은 국내·외 대부분의 정수장에서 널리 적용되고 있는 대표적인 수처리 기술이며, 공정의 효율은 응집제 주입량에 크게 의존한다. 적정 응집제 주입량의 결정은 안정적인 처리수 수질 확보뿐만 아니라 약품 사용량 절감을 통한 운영 경제성 확보 및 공정 운영 효율성 향상 측면에서도 매우 중요한 요소이다. 특히 정수장의 약품비는 전체 운영비에서 상당한 비중을 차지하기 때문에, 원수 수질 변화에 따라 적정 응집제 주입량을 정확하게 산정하고 제어하는

것은 경제적이고 안정적인 정수장 운영을 위한 핵심 기술 요소로 인식되고 있다 (Yu et al., 2000).

전통적으로 정수장에서 응집제 주입량은 자 테스트 (Jar-test) 또는 경험 기반의 조건표를 통해 결정되어 왔다 (Yu et al., 2000). 자 테스트는 원수 수질 특성에 따른 응집 특성을 평가하여 적정 응집제 주입량을 산정할 수 있는 대표적인 실험 방법으로, 현재까지도 많은 정수장에서 기본적인 운영 의사결정 수단으로 활용되고 있다. 그러나 자 테스트(Jar-test)는 실험 수행과 분석 과정에 상당한 시간이 소요되며, 연속적으로 변화하는 원수 수질에 즉각적으로 대응하기 어렵다는 한계가 있다 (Nam et al., 2013). 또한 실험자의 숙련도, 실험 조건, 분석 방법 등에 따라 결과의 편차가 발생할 가능성이 있으며, 이러한 특성은 실제 공정 운영



에서 응집제 주입량 결정의 불확실성을 증가시키는 요인으로 작용할 수 있다. 이를 보완하기 위한 방법으로 CAS-T(Coagulant Automatic System-Test)와 같은 자동화 기반 응집제 제어 기술이 제안된 바 있으나, 설비 구축 및 운영상의 제약으로 인해 현장은 여전히 자 테스트(Jar-test) 기반 운영이 주요 방식으로 사용되고 있다 (Kim et al., 2017).

기존 응집제 운영 방식은 원수 수질 변화가 발생한 이후 이에 대응하여 응집제 주입량을 조정하는 사후 대응(Reactive control) 기반 운영 특성을 가진다. 그러나 하천 원수와 같이 수질 변동성이 큰 환경에서는 이러한 방식만으로는 급격한 수질 변화에 신속하게 대응하는 데 한계가 있다. 이에 따라 최근에는 수질 변화를 사전에 예측하고 이를 기반으로 응집제 주입량을 선제적으로 제어하는 사전 예측(Predictive control) 기반 운영 기술의 필요성이 증가하고 있다 (Bello et al., 2014).

최근에는 이러한 한계를 극복하기 위해 인공지능(AI)을 활용한 정수처리 공정 운영 최적화 연구가 활발히 수행되고 있다. 인공지능 기반 모델은 과거의 수질 데이터와 공정 운영 데이터를 학습하여 원수 수질 변화에 대응한 최적의 응집제 주입량을 예측할 수 있으며, 이를 통해 정수처리 공정의 자동화 및 운영 효율 향상이 가능할 것으로 기대된다. 실제로 다양한 머신러닝 및 딥러닝 모델을 활용하여 유입 수질 변화에 따른 응집제 주입량을 예측하거나 처리수 수질을 예측하는 연구들이 수행되어 왔으며, 이러한 연구들은 인공지능 기반 정수처리 공정 운영 기술의 적용 가능성을 제시하고 있다 (Yu et al., 2000; Narges et al., 2021; Bressane et al., 2023; Tochio et al., 2023; Wang et al., 2023; Lin et al., 2023; Kim et al., 2024).

그러나 기존 연구의 상당수는 모델의 예측 정확도 또는 예측 성능 평가에 초점을 두고 있으며, 실제 정수처리 플랜트 운영 환경에 적용하여 공정 제어까지 연계한 연구는 제한적으로 수행되어 왔다 (Liu et al., 2024). 정수장과 같은 실제 플랜트 환경에서는 공정 안정성, 설비 제어 연동, 운영 신뢰성 등 다양한 조건이 충족되어야 하므로 단순한 예측 모델을 넘어 실제 공정 운영에 적용 가능한 통합 운영 기술이 요구된다 (Bello et al., 2014; Kim et al., 2024; Liu et al., 2024). 특히 인공지능 모델의 예측 결과를 실제 설비 제어 시스템과 연계하여 운영에 적용하고, 이를 통해 약품 사용량 절감, 공정 안정성 확보 및 운영 효율성 향상

등의 효과를 검증하는 연구가 필요하다 (Bello et al., 2014; Liu et al., 2024).

또한 최근 AI 기반 응집제 제어 연구들은 주로 특정 단일 모델을 적용하여 응집제 주입량 또는 처리수 수질을 예측하거나, 모델별 예측 정확도를 비교하는 방식으로 수행되어 왔다. 이러한 접근은 AI 모델의 예측 가능성을 평가하는 데 유용하지만, 실제 정수처리 공정에서는 원수 수질, 수온, pH 및 운전 조건이 시간에 따라 지속적으로 변화하므로 특정 단일 모델의 성능이 모든 운전 조건에서 항상 최적으로 유지되기 어렵다. 따라서 실제 운영 환경에서는 단일 모델의 평균 예측 성능뿐만 아니라, 시간별 운전 조건 변화에 따라 적합한 모델을 선택하고 이를 제어값으로 안정적으로 연계할 수 있는 운영 전략이 필요하다.

본 연구에서 의미하는 현장 적용성은 단순히 AI 모델의 예측 정확도를 평가하는 수준이 아니라, ① 실증화 시설에서 연속적으로 취득되는 원수 수질 및 운영자료를 기반으로 예측모델을 구동하고, ② 예측된 응집제 주입농도를 실제 유입 유량과 연계하여 응집제 주입유량으로 변환하며, ③ 산정된 제어값을 SCADA-HMI-PLC 기반 제어 시스템과 연계하여 응집제 주입 펌프 제어에 적용하고, ④ 그 결과를 응집제 사용량, 침전지 처리수 탁도 및 단위 공정 기준 만족 여부를 통해 평가하는 것을 의미한다. 즉, 본 연구의 현장 적용성은 예측모델의 성능평가, 제어 시스템 연계, 실제 약품 주입 제어 및 수질 안정성 평가를 포함하는 통합적 운영 적용 가능성으로 정의하였다.

따라서 본 연구에서는 원수 수질 변화를 사전에 예측하여 응집제 주입량을 선제적으로 제어하는 AI 기반 사전 예측 제어 시스템을 구축하고, 기존의 자 테스트 기반 사후 대응 운영 방식과 비교하여 실제 정수처리 공정에서의 적용 가능성을 평가하고자 하였다. 이를 위해 실증화 시설 운영 환경에서 인공지능 기반 응집제 주입 제어 시스템을 구축하고, 응집제 종류 및 제어 방식에 따른 비교를 통해 약품 사용량 절감, 공정 운영 안정성 및 운영 효율성 측면에서의 적용 가능성을 검증하였다. 특히 본 연구는 Ridge, Lasso, DT, RF, ANN, DNN 및 LSTM-RNN으로 구성된 Model Bank를 구축하고, 시간별 RMSE를 기준으로 최적 모델을 선택하여 응집제 주입농도를 산정하였다는 점에서 기존 단일 모델 기반 연구와 차별성을 가진다. 또한 산정된 예측값을 SCADA-HMI-PLC 기반 제어 시스템과 연계하여 실

pp. 487-500

pp. 501-509

pp. 511-527

pp. 529-539

pp. 541-551

pp. 553-564

pp. 565-582

pp. 583-596

제 응집제 주입 펌프 제어에 적용하고, 사후 대응 방식과 사전 예측 기반 방식의 응집제 사용량 및 침전지 처리수 탁도를 비교함으로써 AI 예측모델의 실제 운영 적용성을 검토하였다. 본 연구 결과는 인공지능 기반 정수처리 공정 자율제어 기술의 현장 적용 가능성을 평가하고 향후 스마트 정수장 운영 기술 개발을 위한 기초 자료로 활용될 수 있을 것으로 기대된다.

2. 연구방법

2.1 실증화 시설 구성 및 운영조건

본 연구는 2024년 8월부터 10월까지 D시에 위치한 정수 실증화 시설 1계열을 대상으로 수행되었다. 실증화 시설은 총 2,000 m³/d 규모(1,000 m³/d × 2계열)로 구성되어 있으며, 본 연구에서는 착수정-혼화·응집·침전-급속여과 공정을 대상으로 응집제 제어 성

능을 평가하였다.

정수 실증화 시설의 유입원수는 낙동강 수계에서 취수된다. 취수된 원수는 착수정을 거쳐 전 오존 공정을 통과한 후 혼화공정으로 유입된다. 다만 본 연구 수행 기간 동안에는 전 오존 공정을 가동하지 않고 운영하였다.

본 연구에서는 혼화공정에 주입되는 응집제 주입량 결정 방식과 응집제 종류를 달리하여 운전하였으며, 이에 따른 침전지 처리수 탁도의 단위 공정 목표 탁도 기준 만족 여부와 응집제 주입량 절감 효과를 평가하였다.

응집제 주입 방식은 사후 대응 방식과 사전 예측 방식으로 구분하였다. 사후 대응 방식은 국내 I정수장에서 운영되는 방식과 동일하게 1일 2회 자 테스트를 통해 적정 응집제 주입농도를 결정하여 유량에 따라 응집제 주입량을 제어하는 방식이다. 그러나 이러한 방식은 인력 중심의 평가 방법이기 때문에 분석자의 숙련도 및 판단에 따라 결과 편차가 발생할 수 있다.




Fig. 1. Operational schematic of the demonstration-scale water treatment plant under different coagulant dosing control strategies.



또한 국내 주요 취수원의 수질은 평상시 비교적 안정적인 특성을 보이나, 강우에 따른 토사 유입이나 조류 대발생 등으로 인해 간헐적으로 급격한 수질 변동이 발생할 수 있으며, 이러한 상황에서는 사후 대응 방식으로 신속하게 최적의 대응이 어려울 수 있다.

사전 예측 방식은 인공지능 기반 예측 모델을 통해 산정된 응집제 주입농도를 기반으로 공정을 제어하는 방식이다. 본 연구에서는 매일 00시에 응집제 주입농도 예측 모델을 재학습하고, 01시부터 24시까지의 시간별 응집제 주입농도를 예측하여 서버에 저장하였다.

이후 각 정시에 예측된 응집제 주입농도 값을 SCADA-HMI-PLC 기반 제어 시스템과 연계하여 응집제 주입 펌프에 적용하였다. 이를 통해 응집제 주입 펌프의 주파수(Hz)를 자동 제어하여 실제 주입량을 조절하였다.

본 연구에서 사용된 응집제는 국내 정수처리 공정에서 널리 사용되는 Poly-Aluminum Chloride Sulfate (PACS)와 Poly-Aluminum Chloride (PACl)이다. PACS는 황산 이온이 포함된 고분자 알루미늄 응집제로, 응집 및 침전 성능이 우수하고 저온 조건에서도 비교적 안정적인 응집 효과를 나타내는 특징이 있다. 반면 PACl은 염기화도가 높은 알루미늄계 응집제로, 빠른 플록 형성과 높은 탁도 제거 효율을 나타내는 특징이 있어 국내 정수처리 시설에서 널리 활용되고 있다. 본 연구에서는 국내 정수처리 공정에서 널리 사용되는 PACS와 PACl을 적용하여, 응집제 종류 변화에 따른 사전 예측 제어 방식의 운영 성능 및 적용 가능성을 비교·평가하였다.

2.2 데이터 및 전처리

본 연구에서 사용된 데이터 수집 항목, 수집 방식 및 제어 입력 변수는 표 1과 같다. 유입 유량 및 유입수 수질 정보(탁도, 수온, pH, 전기전도도)는 정수 실증화 시설의 계측 데이터를 API 기반 온라인 방식으로 수집하였으며, 응집제 주입 관련 운영자료는 PLC 기반 제어 신호를 통해 실시간 수집하였다. 수집된 정보는 KICT-CPS 서버에 저장되어 활용되었다.

적정 응집제 주입농도를 사전에 예측하기 위하여 유입 유량(L/min), 유입수 탁도(NTU), 수온(°C), pH, 전기전도도($\mu\text{S}/\text{cm}$) 및 과거 응집제 주입농도(mg/L)를 입력 변수로 하는 예측 모델을 구축하였다. 입력 변수는 선행 연구 및 사전 검토 결과를 바탕으로 응집제 주

입농도 예측에 활용 가능성이 높고, 실증화 시설에서 안정적으로 연속 취득 가능한 온라인 계측자료를 중심으로 선정하였다. 유입수 탁도는 입자성 물질 및 응집제 요구량 변화와 직접적으로 관련된 주요 수질 인자이며, pH와 수온은 응집 반응 및 플록 형성 조건에 영향을 미치는 운전 인자로 고려하였다. 전기전도도는 원수의 이온성 조성 변화를 간접적으로 반영할 수 있는 지표로 활용하였으며, 과거 응집제 주입농도는 기존 운전조건 및 원수 수질 변화에 대한 운영 이력을 반영하기 위한 입력 변수로 포함하였다.

TOC, UV₂₅₄, 알칼리도 및 조류 관련 인자는 응집제 주입량 결정에 영향을 미칠 수 있는 중요한 수질 인자이나, 본 연구의 실증 운전기간 동안 모델 입력자료와 동일한 시간 해상도 및 연속성을 갖는 온라인 자료로 확보되지 않았다. 특히 본 연구의 제어 시스템은 시간별 응집제 주입농도를 산정하여 SCADA-HMI-PLC 기반으로 적용하는 구조이므로, 제어 입력변수는 현장에서 안정적으로 연속 취득 가능한 항목으로 제한하였다. 따라서 해당 인자들은 본 연구의 입력 변수에서는 제외하였으며, 향후 연구에서는 TOC, UV₂₅₄, 알칼리도 및 조류 관련 온라인 계측자료를 추가하여 입력 변수 확장 및 변수 중요도 분석을 수행할 필요가 있다.

본 연구에서 예측 모델의 목표 변수는 시간별 최적 응집제 주입농도(mg/L)로 설정하였다. 온라인 계측자료는 1분 단위로 수집되었으나, 예측 모델은 1시간 간격의 응집제 주입농도를 산정하도록 구성하였다. 따라서 1분 단위로 수집된 유입 유량 및 수질자료는 시간 평균값으로 집계하여 모델 입력자료로 사용하였으며, 과거 응집제 주입농도 또한 동일한 1시간 해상도로 정렬하여 모델 학습 및 예측에 활용하였다. 예측된 응집제 주입농도(mg/L)는 이후 실시간 유입 유량을 반영하여 응집제 주입유량(mL/min)으로 변환하였으며, 해당 값은 SCADA-HMI-PLC 기반 제어 시스템을 통해 응집제 주입 펌프 제어에 적용하였다.

입력 변수의 이상치는 계측기 오류, 통신 이상, 설비 정지 또는 비정상 운전 상태에서 발생할 수 있는 비현실적 값을 제거하기 위해 설정하였다. 이상치 기준은 단순 통계적 절단값이 아니라, 실증화 시설의 정상 운전 가능 범위, 연구기간 동안 관측된 원수 수질 범위, 정수처리 공정에서 물리적으로 발생 가능한 수질 조건 및 계측기 이상 가능성을 종합적으로 고려하여 유입 유량 $\leq 0.05 \text{ L/min}$, 수온 $\leq 1^\circ\text{C}$, 탁도 > 500

pp. 487-500

pp. 501-509

pp. 511-527

pp. 529-539

pp. 541-551

pp. 553-564

pp. 565-582

pp. 583-596

Table 1. Summary of data acquisition methods, control inputs, and model prediction variables

Parameter	Unit	Acquisition Method	Raw data frequency	Model/control resolution	Remarks
Influent Flow Rate	L/min	API (Online)	1 min	1 h average	Input variable
Influent Turbidity	NTU	API (Online)	1 min	1 h average	Input variable
Temperature	°C	API (Online)	1 min	1 h average	Input variable
pH	-	API (Online)	1 min	1 h average	Input variable
Electrical Conductivity	μS/cm	API (Online)	1 min	1 h average	Input variable
Reactive Control Dosing Concentration	mg/L	Jar-test	2 times/day	Hourly aligned	Input/operation record
Reactive Control Dosing Flow Rate	mL/min	PLC	1 min	Operation record	Reactive control output
Predictive Control Dosing Concentration	mg/L	Model prediction	1 h	1 h	Model output
Predictive Control Dosing Flow Rate	mL/min	PLC	1 h command	1 h control	Predictive control output
Sedimentation Basin Effluent Turbidity	NTU	API (Online)	1 min	1 h average	Process performance evaluation
Model Selection	-	Server (Online)	1 h	1 h	Lowest RMSE model

*Online monitoring data collected at 1-min intervals were aggregated as hourly averages for model input and performance evaluation. Reactive control dosing concentration was determined by jar tests twice per day and aligned to the hourly time step. Predictive control dosing concentration was generated hourly by the AI model. Dosing flow rates were applied and recorded through the PLC-based control system.

NTU, pH < 4, 전기전도도 < 100 μS/cm로 설정하였다. 유입 유량 ≤ 0.05 L/min은 설비 정지 또는 유입수 공급 중단 상태로 판단하였으며, 수온 ≤ 1°C 및 pH < 4는 본 연구 대상 원수 조건에서 물리적으로 발생 가능성이 낮은 계측 이상값으로 판단하였다. 또한 탁도 > 500 NTU 및 전기전도도 < 100 μS/cm는 연구기간 동안의 정상 운전 범위를 벗어난 값으로, 계측기 이상 또는 통신 오류 가능성이 높은 자료로 판단하여 제거 또는 보정하였다. 결측값은 시간 순서에 따른 선형보간(linear interpolation)을 적용하여 보정하였으며, 보간 후에도 연속 결측 또는 설비 정지로 인해 정상 운전 자료로 판단하기 어려운 구간은 모델 학습자료에서 제외하였다.

모델 데이터는 학습/검증/시험으로 구분하여 각각 60:20:20의 비율로 분할하였다. PACS 조건에서는 총 960개의 시간별 자료를 사용하였으며, 학습, 검증 및 시험 데이터는 각각 576개, 192개 및 192개로 구성하였다. PACI 조건에서는 총 1,104개의 시간별 자료를 사용하였으며, 학습, 검증 및 시험 데이터는 각각 662개, 221개 및 221개로 구성하였다. 모델 성능 평가는 검증 데이터 기준 RMSE(Root Mean Square Error)를

활용하여 수행하였으며, 시간별 최저 RMSE 모델을 해당 시간의 제어 설정값 산정에 활용하였다.

2.3 인공지능 모델

실험에 활용된 모든 수질/운영정보는 API 통신 및 전용회선을 통해 중앙서버에 수집되었다. 수집된 데이터는 PostgreSQL 기반 데이터베이스에 저장·관리되었다.

최적의 응집제 주입농도를 예측하기 위해 Ridge Regression (Ridge), Lasso Regression (Lasso), Decision Tree (DT), Random Forest (RF), Artificial Neural Network (ANN), Deep Neural Network (DNN), Long Short-Term Memory Recurrent Neural Network (LSTM-RNN)으로 구성된 총 7개 알고리즘의 모델뱅크(Model Bank)를 구축하였다 (Breiman, 2001; Hochreiter and Schmidhuber, 1997; Yu et al., 2000; Kim et al., 2024). 모델뱅크 기반 구조는 단일 모델에 의존하지 않고 다양한 모델의 예측 성능을 비교·평가함으로써, 원수 수질 변동 특성에 따라 최적의 예측 모델을 선택할 수 있는 장점이 있다 (Bello et al., 2014;



Kim et al., 2024). 이를 통해 수질 변동성이 큰 환경에서도 보다 안정적인 사전 예측 기반 제어가 가능하도록 하였다.

이 중 선형 회귀 기반 모델로는 다항 특징(degree 5)과 표준화를 적용한 Ridge($\alpha = 1 \times 10^{-5}$, random_state = 42)와 Lasso($\alpha = 1 \times 10^{-5}$, random_state = 42)를 적용하였다. 또한 비선형 모델로는 Decision Tree 및 Random Forest(scikit-learn 기본 설정, random_state = 42)를 고려하였다. 신경망 모델은 MSE 손실함수와 Adam 옵티마이저(epoch = 300, batch size = 30)를 사용하여 3종의 신경망 모델을 아래와 같이 학습하였다.

- ANN: Dense(10, ReLU) → Dropout(0.1, 은닉층 이후 적용) → Dense(1, Linear)
- DNN: Dense(10, ReLU) → Dense(50, ReLU) → Dense(25, ReLU) → Dense(10, ReLU) → Dropout(0.1, 마지막 은닉층 이후 적용) → Dense(1, Linear)
- LSTM-RNN: LSTM(50, dropout = 0.1, return_sequences = True) → LSTM(25, dropout = 0.1, return_sequences = True) → LSTM(10, dropout = 0.1, return_sequences = False) → Dropout(0.1) → Dense(1, Linear)

ANN, DNN 및 LSTM-RNN의 하이퍼파라미터는 선행 연구에서 정수처리 공정 수질 예측 및 응집제 주입량 예측에 적용된 신경망 구조를 참고하고, 본 연구 데이터에 대한 사전 반복 학습 결과를 고려하여 설정하였다. ANN은 비교적 단순한 비선형 관계를 학습하기 위한 기본 신경망 구조로, DNN은 다층 은닉층을 통해 복잡한 비선형 수질 변동 특성을 반영하기 위한 구조로 설정하였다. LSTM-RNN은 시간 순서에 따른 수질 및 운영자료의 연속적 변화를 반영하기 위하여 적용하였다. Dropout 비율은 0.1로 설정하여 과적합 가능성을 완화하였으며, MSE 손실함수와 Adam 옵티마이저는 연속형 목표 변수인 응집제 주입농도 예측에 적합한 학습 조건으로 적용하였다. Epoch와 batch size는 모델 간 성능 비교가 동일한 조건에서 수행될 수 있도록 동일하게 적용하였다.

매일 수행되는 재학습 과정에서 모델 뱅크는 향후 24시간($t+1 \sim t+24$)에 대한 시간별 응집제 주입농도 예측값을 생성하였다. 각 시간대별로 검증 데이터 기준 RMSE가 가장 낮은 모델을 선택하였으며, 해당 모델의 시간별 제어 설정값(setpoint)을 저장하여 실제 제

어에 활용하였다.

본 연구에서는 시간별 최적 제어값 산정을 위한 모델 선택 기준으로 RMSE를 사용하였다. RMSE는 예측값과 실제값 간 오차의 크기를 응집제 주입농도와 동일한 단위(mg/L)로 제시할 수 있어, 실제 운영자가 예측 오차의 크기를 직관적으로 해석하는 데 적합하다. 또한 RMSE는 큰 예측 오차에 상대적으로 높은 가중치를 부여하므로, 응집제 과소 또는 과다 주입 가능성을 줄이기 위한 보수적인 모델 선택 기준으로 활용될 수 있다.

RMSE는 식 (1)과 같이 산정하였다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

여기서 y_i 는 실제 응집제 주입농도, $\hat{y}_i$ 는 예측 응집제 주입농도, n 은 데이터 수를 의미한다. 본 연구에서는 AI 모델을 통해 응집제 주입농도(mg/L)를 예측하고, 이를 실시간 유입 유량과 연계하여 응집제 주입유량(mL/min)으로 변환한 후 SCADA-HMI-PLC 기반 제어 시스템을 통해 실제 설비 제어에 적용하였다.

2.4 제어 로직

사전 예측 방식에서는 AI 모델을 통해 산정된 응집제 주입농도(mg/L)를 현재 유입 유량 정보와 연계하여 응집제 주입유량(mL/min)으로 변환하였다. 변환된 주입유량은 펌프 주파수 설정값으로 환산하였으며, 펌프 주파수 x (Hz)와 응집제 주입유량 Y (mL/min) 간의 관계는 식 (2)와 같이 나타내었다.

$$Y = 0.1651x + 0.0509 \quad (2)$$

여기서 Y 는 응집제 주입유량(mL/min), x 는 펌프 주파수(Hz)를 의미한다.

제어 명령의 정상 동작 여부를 확인하기 위하여 펌프 Hz의 설정값과 실제 운영값의 일치 여부를 모니터링하였다. 1분 간격으로 두 값이 일치하는지 확인하여 5회 연속 일치하지 않을 경우, 운영자에게 알람을 발생시키고 수동 운전이 되도록 설정하였다. 수동 운전 시에는 조건표를 활용하여 유입 탁도에 따라 응집제 주입량이 결정되도록 사전에 구현하였다.

사후 대응 방식은 매일 오전 10시와 오후 4시에 자 테스트를 수행하여 적정 응집제 주입농도(mg/L)를 확인하고 설비 유입 유량 정보를 반영하여 적정 응집제 주입량(mL/min)을 결정하도록 하여, 해당 값에 대응하는 펌프 주파수(Hz)를 설정하였다.

2.5 평가 기준

본 연구에서는 D시에 위치한 정수 실증화 시설을 대상으로 사후 대응 기반 제어 방식과 사전 예측 기반 제어 방식의 운영 성능을 비교·평가하기 위하여 교차 운전(cross operation)을 수행하였다. 각 운전 기간 동안 응집제 주입량과 침전지 처리수 수질을 비교함으로써, 사전 예측 기반 제어 방식의 응집제 절감 효과 및 처리수 수질 안정성을 평가하였다.

평가 지표는 응집제 사용량 절감률과 침전지 처리수의 단위 공정 탁도 기준 충족 여부로 설정하였다. 응집제 사용량 절감률은 동일한 수질 조건을 만족하는 범위 내에서 사전 예측 기반 제어 방식이 사후 대응 방식 대비 얼마나 응집제 사용량을 저감할 수 있는지를 정량적으로 평가하기 위한 지표로 활용하였다.

수질 측면에서는 침전공정 유출수의 탁도를 주요 평가 기준으로 설정하였다. 국내의 경우 침전공정에 대한 명확한 관리 기준은 존재하지 않으나, 미국 환경보호청(U.S. EPA)의 지표수 처리 관련 탁도 관리 지침에서는 정수처리 공정의 탁도 관리 중요성을 제시하고 있다. 이에 본 연구에서는 침전지 처리수 탁도 1 NTU를 단위 공정 관리 기준으로 설정하고, 해당 기준의 초과 여부 및 준수율을 평가하였다 (U.S. Environmental Protection Agency, 2020).

또한, 두 제어 방식 간 비교 시 단순 평균값뿐만 아니라 시간에 따른 탁도 변동 특성 및 기준 초과 빈도를 함께 분석함으로써, 응집제 절감 효과와 수질 안정성 간의 균형을 종합적으로 평가하였다.

3. 결과 및 고찰

3.1 유입수질 특성

실험이 진행되는 동안의 유입원수 수질 특성은 표 2와 같다. 낙동강에서 취수되어 정수 실증화 시설로 유입되는 원수는 계절적 변화 및 강우 영향에 따라

높은 변동성을 나타내는 전형적인 하천형 원수 특성을 보였다. 특히 탁도는 전체 기간 평균 10.78 NTU였으나, 최소 0.07 NTU에서 최대 156 NTU까지 매우 넓은 범위를 나타내어 단기간의 고탁도 유입 이벤트가 빈번하게 발생하였음이 확인되었다. 이러한 현상은 강우 유출, 하천 내 재부유, 유역 유입부하 증가 등에 기인한 것으로 판단되며, 대규모 하천 수계에서 나타나는 급격한 탁도 변화는 응집·침전 공정의 운영 안정성에 직접적인 영향을 미치는 주요 인자로 알려져 있다 (Nam et al., 2013; Kim et al., 2017).

PACS 주입 기간 동안의 평균 탁도는 9.50 NTU였으며, 최대값은 77.2 NTU로 나타났다. 반면 PACI 주입 기간에는 평균 탁도가 11.89 NTU로 증가하였고, 최대 156 NTU까지 상승하였다. 이는 PACI 적용 기간 동안 상대적으로 불리한 원수 조건이 형성되었음을 의미한다. 따라서 동일 수준의 처리수 안정성을 확보하였다면, PACI은 보다 높은 원수 부하 조건에서도 안정적인 처리 성능을 유지한 것으로 해석할 수 있다.

운영기간은 여름철에서 가을철로 전환되는 시기를 포함하고 있어, 수온은 전체 평균 27.7°C로 비교적 높게 나타났다. 고수온 조건에서는 응집 반응 및 플록 형성이 상대적으로 활성화될 수 있으므로, 본 연구 기간 동안 응집 반응에 유리한 조건이 형성된 것으로 판단된다.

pH는 전체 기간 평균 7.61 수준으로 비교적 안정적으로 유지되었으며, 응집 반응에 적합한 범위를 나타냈다. 또한 운영기간 동안 pH 변동 폭이 크지 않아 응집제 종류별 성능 비교에 미치는 영향은 제한적이었던 것으로 판단된다.

전기전도도는 전체 평균 448.6 $\mu\text{S}/\text{cm}$ 로 비교적 안정적인 경향을 보였으나, 고탁도 유입 시기에는 최대 996 $\mu\text{S}/\text{cm}$ 까지 증가하였다. 이는 강우 유출 및 하천 유입 특성 변화에 따른 용존 이온 농도 증가의 영향으로 판단된다.

종합적으로, PACS 및 PACI 주입 기간 간 원수 특성 차이가 존재하므로, 두 응집제 조건의 절감률을 직접 비교하여 특정 응집제 또는 제어 방식의 우수성을 단정하기에는 한계가 있다. 따라서 본 연구에서는 PACS와 PACI 간 절감률을 단순 비교하기보다, 각 응집제 운전기간 내에서 사후 대응 방식과 사전 예측 기반 방식의 상대적 응집제 사용량 차이를 중심으로

**Table 2.** Influent raw water quality characteristics

Parameter	Unit	Operating Period		
		Entire (08/05-10/31)	PACS Dosing (08/05 ~ 09/13)	PACl Dosing (09/16 ~ 10/31)
Turbidity	NTU	10.78 (0.07-156)	9.50 (1.64-77.2)	11.89 (0.07-156)
Temperature	°C	27.7 (20.6-35.2)	30.7 (29.2-35.2)	25.0 (20.6-31.0)
pH	-	7.61 (6.83-8.63)	7.70 (6.83-8.63)	7.53 (7.07-8.13)
Electrical Conductivity	μS/cm	448.6 (0-996)	433.4 (0-996)	461.8 (0-875)

*Values are presented as mean (min-max) of raw monitoring data before preprocessing. Abnormal or non-operational values were removed or corrected according to the preprocessing criteria described in Section 2.2 before model training and performance evaluation.

해석하였다. 특히 PACl 운전기간에는 최대 156 NTU의 고탁도 유입 조건이 포함되어 있어, 해당 기간의 절감률은 원수 조건 차이를 고려한 제한적 결과로 해석할 필요가 있다.

3.2 응집제 주입농도 예측 모델 성능

응집제 주입농도 예측 모델의 성능 비교를 위하여 Ridge, Lasso, DT, RF, ANN, DNN 및 LSTM-RNN 기반 AI 모델에 대한 학습 및 성능평가를 수행하였다. 본 연구에서는 실제 제어 시스템에 적용할 시간별 최적 모델을 선정하기 위한 기준 지표로 RMSE를 활용하였으며, 응집제 종류(PACS, PACl)에 따라 각각 분석하였다. 모델 성능 비교의 정량성을 보완하기 위하여 RMSE 분포뿐만 아니라 각 모델별 RMSE의 평균, 표준편차, 중앙값, 최소값 및 최대값을 산정하였다. 또한 시간별 최저 RMSE 모델로 선택된 횟수를 함께 제시하여 모델별 예측 안정성과 모델뱅크 내 선택 특성을 비교하였다. Table 3의 Selection count는 각 시간대에서 해당 모델이 최저 RMSE 모델로 선택된 횟수를 의미하며, 이를 통해 단일 모델 고정 적용 시 확인하기 어려운 시간별 모델 선택 특성을 정량적으로 평가하였다.

모델 학습 결과, Lasso 및 DT 모델은 다른 모델 대비 상대적으로 높은 RMSE를 나타내어 실제 시간별 제어값 산정 과정에서 최저 RMSE 모델로 선택되지 않았다. 그러나 모델 간 성능 차이를 정량적으로 비교하기 위하여 Table 3에는 Ridge, Lasso, DT, RF, ANN,

DNN 및 LSTM-RNN의 RMSE 기반 성능지표를 모두 제시하였다. 그림 2에는 RMSE 분포 비교의 가독성을 고려하여 실제 모델뱅크 내에서 주로 선택되거나 상대적으로 우수한 성능을 보인 Ridge, RF, ANN, DNN 및 LSTM-RNN의 결과를 제시하였다. Lasso 및 DT를 포함한 전체 7개 모델의 RMSE 기반 성능지표는 Table 3에 함께 제시하였다.

그림 2는 응집제 종류별 AI 기반 주입농도 예측 모델의 RMSE 분포를 박스플롯 형태로 나타낸 결과이다. PACS 조건에서는 전체적으로 RMSE 약 0.5-0.7 수준의 분포를 나타냈다. RF 모델은 일부 구간에서 1.0 이상의 이상치가 발생하여 다른 모델 대비 상대적으로 높은 변동성을 나타냈으며, 특정 운전 조건 또는 고탁도 유입 상황에서 예측 오차가 증가하는 경향을 보였다. 반면 ANN, DNN 및 LSTM-RNN 모델은 비교적 좁은 사분위 범위와 안정적인 분포 특성을 나타냈다. 특히 ANN 및 DNN 모델은 상대적으로 낮은 RMSE와 작은 분산 특성을 나타내어 안정적인 예측 성능을 보였다.

PACl 조건에서는 전체적으로 PACS 대비 낮은 RMSE 분포가 확인되었다. 대부분의 모델이 RMSE 약 0.4-0.55 범위 내에서 안정적인 분포를 나타냈으며, ANN 모델은 작은 변동 폭과 낮은 RMSE 수준을 보여 높은 예측 안정성을 나타냈다. RF 모델은 PACS 조건 대비 이상치 발생 수준은 감소하였으나 일부 구간에서는 상대적으로 높은 오차 값이 확인되었다. Ridge 및 LSTM-RNN 모델은 전체적으로 유사한 중앙값과 분포 범위를 나타내며 안정적인 예측 성능을 유지하였다.


Table 3. RMSE-based performance comparison of coagulant dosing concentration prediction models

Coagulant	Model	RMSE					Selection count
		Mean	SD	Median	Min	Max	
PACS	Ridge	0.685	0.307	0.598	0.445	4.810	18
	Lasso	0.677	0.209	0.605	0.461	1.300	0
	DT	0.922	0.295	0.779	0.524	2.330	0
	RF	0.650	0.209	0.584	0.406	1.240	711
	ANN	0.663	0.212	0.589	0.455	1.290	93
	DNN	0.661	0.212	0.586	0.441	1.290	83
	LSTM-RNN	0.667	0.211	0.593	0.432	1.290	55
PACI	Ridge	0.515	0.063	0.498	0.398	0.752	14
	Lasso	0.524	0.062	0.508	0.405	0.756	0
	DT	0.650	0.087	0.643	0.480	0.969	0
	RF	0.484	0.063	0.467	0.359	0.721	1013
	ANN	0.521	0.063	0.505	0.398	0.758	3
	DNN	0.515	0.063	0.499	0.389	0.758	8
	LSTM-RNN	0.507	0.062	0.494	0.386	0.747	66

*DT: Decision Tree; RF: Random Forest; ANN: Artificial Neural Network; DNN: Deep Neural Network; LSTM-RNN: Long Short-Term Memory Recurrent Neural Network. RMSE statistics were calculated from all hourly evaluation results for each model, regardless of model selection. Selection count indicates the number of times each model was selected as the lowest-RMSE model for hourly predictive control.

또한 Fig. 2에는 각 모델별 선택 횟수(n)를 함께 제시하였다. PACS 조건에서는 RF 모델이 n=711로 가장 높은 선택 빈도를 나타냈으며, PACI 조건에서도 RF 모델이 n=1013으로 가장 높은 선택 빈도를 보였다. 이는 RF 모델이 다양한 운전 조건 및 비선형 수질 변동 특성에 대해 상대적으로 높은 적응성을 나타냈기 때문으로 판단된다. 특히 응집제 주입농도는 유입 탁도, pH, 수온 등 다양한 인자의 복합적 영향을 받는 비선

형 특성을 가지므로, 다수의 의사결정트리를 기반으로 학습하는 RF 모델이 전반적인 예측 성능 확보에 유리하게 작용한 것으로 판단된다(Breiman, 2001). 다만 RF 모델은 일부 구간에서 상대적으로 높은 이상치와 넓은 RMSE 분포를 나타내어 특정 운전 조건에서는 예측 오차가 증가하는 경향도 함께 확인되었다. 따라서 RF 모델은 전체 운전기간에서 가장 빈번하게 선택되었으나, 모든 시간대에서 항상 최저 RMSE를 나

**Fig. 2.** Comparison of RMSE distributions of AI-based coagulant dosing concentration prediction models by coagulant type: (a) PACS and (b) PACI.



타낸 것은 아니며, 일부 시간대에서는 Ridge, ANN, DNN 및 LSTM-RNN이 최적 모델로 선택되었다. 이는 단일 RF 또는 ANN 모델을 고정적으로 적용할 경우 시간별 원수 수질 및 운전 조건 변화에 따른 최적 예측 성능을 충분히 반영하기 어려울 수 있음을 의미한다.

Model Bank 운영 중 모델 전환은 시간별 최저 RMSE 모델을 기준으로 1시간 단위 제어 설정값 산정 단계에서 이루어졌다. 즉, 모델 전환은 초단위 실시간 제어 신호를 빈번하게 변경하는 방식이 아니라, 매 시간 예측 결과를 기반으로 다음 제어 설정값을 갱신하는 과정으로 작동하였다. 선택된 모델의 예측값은 응집제 주입농도(mg/L)로 산정된 후 실시간 유입 유량을 반영하여 응집제 주입유량(mL/min)으로 변환되었으며, SCADA-HMI-PLC 기반 제어 시스템을 통해 펌프 제어에 적용되었다. 따라서 모델 전환은 펌프의 순간적인 제어 불안정을 유발하기보다는 시간별 운전 조건 변화에 대응하기 위한 setpoint 갱신 과정으로 해석할 수 있다. 실제 운영 결과에서도 모델 전환에 따른 별도의 제어 불안정 현상은 확인되지 않았으며, PACS 및 PACI 조건 모두에서 침전지 처리수 탁도 1 NTU 이하 기준을 100% 만족하였다.

종합적으로 ANN 및 DNN은 낮은 RMSE와 비교적 작은 변동성을 보여 예측 오차의 안정성 측면에서 장점을 나타냈다. 반면 RF 모델은 일부 구간에서 상대적으로 큰 예측 오차를 보였으나, PACS 및 PACI 조건 모두에서 가장 높은 선택 빈도를 나타내어 모델뱅크 내 운전 조건 적응성 측면에서 장점을 보였다. 따라서 ANN 및 DNN은 예측 오차의 안정성 측면에서, RF는 모델 선택 빈도 및 다양한 운전 조건에 대한 적용성 측면에서 각각 장점을 가지는 것으로 해석된다. 또한 응집제 종류에 따라 모델별 RMSE 분포 특성이 일부 상이하게 나타나, 응집제 특성 및 운전 조건 변화가 AI 기반 주입농도 예측 성능에 영향을 미치는 것으로 판단된다. 이러한 결과는 AI 기반 응집제 주입농도 예측에서 단일 모델보다 복수 모델 기반의 선택 전략이 유효할 수 있음을 보여준다. 특히 Model Bank 전략은 특정 단일 모델의 평균 성능에 의존하기보다, 시간별 원수 수질 및 운전 조건 변화에 따라 상대적으로 낮은 예측 오차를 나타내는 모델을 선택할 수 있다는 점에서 실제 정수처리 공정의 변동 조건에 대한 대응성을 높일 수 있다. 다만 본 연구에서는 단일 모델 고정 운전과 Model Bank 운전을 동일 조건에서

병렬 비교한 것은 아니므로, Model Bank의 우수성은 동일 운전자료 내에서의 시간별 RMSE, 모델 선택 횟수 및 실제 운영 안정성 결과를 기반으로 제한적으로 해석하였다.

3.3 PACS 주입시기 운전 결과 비교

PACS 주입 기간 동안 사후 대응 방식(reactive dosing)과 사전 예측 기반 방식(AI-based predictive dosing)의 운전 결과를 비교한 결과는 그림 3과 같다. 그림 3은 시간에 따른 유입수 및 침전지 처리수 탁도 변화와 함께 각 제어 방식에 따른 응집제 주입량 변화를 나타낸 결과이다.

사후 대응 방식에서는 자 테스트 결과를 기반으로 일정한 응집제 주입량이 유지되는 경향을 나타냈다. 운영기간 동안 응집제 주입량은 약 5.0-9.5 mL/min 범위로 유지되었으며, 유입 탁도 변화와 관계없이 비교적 일정한 주입 패턴을 보였다. 이는 1일 2회의 자 테스트 결과를 기반으로 응집제 주입량을 결정하는 기존 운영 방식의 특성이 반영된 결과로 판단된다.

반면 사전 예측 기반 방식에서는 유입수 수질 변화에 따라 응집제 주입량이 시간별로 변동하는 특성을 나타냈다. 사전 예측 기반 방식에서는 응집제 주입량이 시간별로 변동하였으나, 주입유량이 동일 시점의 유입 탁도 변화와 단순히 비례하여 증가하는 형태로 나타나지는 않았다. 이는 본 제어 방식이 매일 00시에 수행된 예측 결과를 기반으로 시간별 setpoint를 적용하는 구조이며, 동일 시점의 유입 탁도뿐만 아니라 과거 수질 및 운영자료를 함께 반영하기 때문으로 판단된다. 다만 현재 제어 방식은 매일 00시에 수행된 예측 결과를 기반으로 하루 동안의 주입량을 설정하는 구조이므로, 동일 시점의 유입 탁도 변화와 응집제 주입유량이 항상 직접적으로 일치하지는 않았다. 따라서 PACS 조건의 사전 예측 기반 주입 특성은 단순 동시점 탁도 변화보다는 과거 수질 및 운영자료를 반영한 시간별 setpoint 적용 결과로 해석할 필요가 있다.

처리수 수질 측면에서는 두 방식 모두 침전지 처리수 탁도를 대부분 1 NTU 이하 수준으로 유지하여 안정적인 처리 특성을 나타냈다. 특히 사전 예측 기반 방식에서는 상대적으로 낮은 응집제 주입량 조건에서도 처리수 탁도가 안정적으로 유지되는 경향이 확인되었다. 또한 유입 탁도가 급격하게 증가하는 구간에

pp. 487-500

pp. 501-509

pp. 511-527

pp. 529-539

pp. 541-551

pp. 553-564

pp. 565-582

pp. 583-596

서도 처리수 탁도는 비교적 안정적으로 유지되어, 사전 예측 기반 제어 방식이 원수 수질 변동에 효과적으로 대응할 수 있음을 확인하였다.

또한 사전 예측 기반 방식에서는 응집제 주입량의 변동폭이 상대적으로 크게 나타났는데, 이는 고정된 주입 조건을 유지하는 기존 사후 대응 방식과 달리 시간별 예측 결과를 반영하여 주입량을 조절하였기 때문으로 판단된다. 이러한 운전 특성은 유입수 수질 변화에 대응하여 응집제 주입량을 선제적으로 조절하는 예측 기반 운영 특성을 보여주는 결과로 판단된다.

PACS 조건에서 유입수 탁도와 응집제 주입유량 간 상관분석을 수행한 결과, 사후 대응 방식에서는 Pearson 상관계수 $r = 0.261(p < 0.001)$ 로 약한 양의 상관성이 나타났으나, Spearman 상관계수는 $\rho = 0.038(p = 0.473)$ 로 유의하지 않았다. 이는 자 테스트 기반 사후 대응 방식이 일정 시간 동안 동일한 주입량을 유지하는 특성을 가지므로, 유입수 탁도의 시간별 변화가 주입유량에 즉각적으로 반영되지 않았기 때문으로 판단된다.

사전 예측 기반 방식에서는 유입수 탁도와 응집제 주입유량 간 Pearson 상관계수가 $r = -0.214(p < 0.001)$, Spearman 상관계수가 $\rho = -0.345(p < 0.001)$ 로 나타났다. 이는 사전 예측 기반 방식의 주입유량이 동일 시점의 유입 탁도만으로 결정되는 것이 아니라, 과거 수질 및 운영자료를 기반으로 사전에 산정된 시간별 setpoint에 따라 적용되었기 때문으로 판단된다. 따라

서 단순 동시점 상관계수만으로 예측 기반 제어의 적절성을 평가하기보다는, 응집제 사용량 감소와 침전지 처리수 탁도 기준 만족 여부를 함께 고려하여 해석할 필요가 있다.

종합적으로 PACS 적용 조건에서 사전 예측 기반 제어 방식은 기존 사후 대응 방식과 다른 응집제 주입 패턴을 나타냈으며, 원수 수질 변화에 따라 응집제 주입량이 유연하게 변화하는 특성을 확인할 수 있었다. 이는 하천형 원수와 같이 수질 변동성이 큰 조건에서 사전 예측 기반 제어 방식의 적용 가능성을 보여주는 결과로 판단된다.

3.4 PACI 주입시기 운전 결과 비교

PACI 주입 기간 동안 사후 대응 방식과 사전 예측 기반 방식의 운전 결과를 비교한 결과는 그림 4와 같다. 그림 4는 시간에 따른 유입수 및 침전지 처리수 탁도 변화와 함께 각 제어 방식에 따른 응집제 주입량 변화를 나타낸 결과이다.

사후 대응 방식에서는 1일 2회 수행되는 자 테스트 결과를 기반으로 응집제 주입량이 비교적 일정하게 유지되는 특성을 나타냈다. 특히 약 9.0-13.5 mL/min 범위의 고정된 주입 패턴이 반복적으로 유지되었으며, 이는 자 테스트 기반 운영 방식의 특성이 반영된 결과로 판단된다. 그러나 일부 고탁도 유입 구간에서는 유입수 탁도 변화 대비 응집제 주입량 변화가 제




Fig. 3. Temporal variations in coagulant dosing flow rate and sedimentation basin effluent turbidity under reactive and AI-based predictive control during PACS dosing.



한적으로 나타나, 급격한 원수 수질 변동에 대한 대응성이 상대적으로 낮은 경향을 보였다.

반면 사전 예측 기반 방식에서는 유입수 수질 변화에 따라 응집제 주입량이 시간별로 지속적으로 변화하는 특성을 나타냈다. 특히 유입 탁도가 증가하는 구간에서는 응집제 주입량 또한 증가하는 경향을 보였으며, 상대적으로 안정적인 원수 조건에서는 주입량이 감소하는 경향을 나타내었다. PACS 조건과 동일하게 현재 제어 방식은 매일 00시에 수행된 예측 결과를 기반으로 하루 동안의 주입량을 설정하는 구조이므로, 일부 구간에서는 실시간 유입 탁도 변화와 차이를 보이는 경향도 확인되었다. 그러나 전체적으로는 유입수 수질 변화 경향에 따라 응집제 주입량이 함께 변화하는 유연한 주입 제어 특성을 확인할 수 있었다.

PACI 적용 기간은 PACS 기간 대비 상대적으로 높은 유입 탁도 조건이 지속적으로 발생하였으며, 최대 약 156 NTU 수준의 고탁도 유입 이벤트도 확인되었다. 이러한 조건에서도 두 방식 모두 침전지 처리수 탁도를 대부분 1 NTU 이하 수준으로 유지하여 비교적 안정적인 처리 특성을 나타냈다. 특히 사전 예측 기반 방식에서는 고탁도 유입 구간에서도 처리수 탁도가 비교적 안정적으로 유지되는 경향을 나타내어, 원수 수질 변동에 대한 대응 가능성을 확인할 수 있었다.

또한 사전 예측 기반 방식에서는 응집제 주입량의 시간별 변동폭이 상대적으로 크게 나타났는데, 이는 고정된 주입 조건을 유지하는 기존 사후 대응 방식과 달리 시간별 예측 결과를 반영하여 응집제 주입량을 조절하였기 때문으로 판단된다. 이러한 특성은 원수 수질 변화에 따라 응집제 주입량을 유연하게 조절하는 예측 기반 운영 특성을 보여주는 결과로 판단된다.

PACI 조건에서 유입수 탁도, 응집제 주입유량 및 침전지 처리수 탁도 간 관계를 정량적으로 검토하기 위하여 상관분석을 수행하였다. 사후 대응 방식에서 유입수 탁도와 응집제 주입유량 간 Pearson 상관계수는 $r = -0.066$ ($p = 0.343$)으로 유의하지 않았으나, Spearman 상관계수는 $\rho = 0.281$ ($p < 0.001$)로 약한 양의 상관성을 나타냈다. 이는 자 테스트 기반 사후 대응 방식에서 일부 탁도 변화가 주입량 조절에 반영되었으나, 1일 2회 자 테스트 결과에 따라 일정 시간 동일한 주입유량이 유지되는 운전 특성으로 인해 선형적 관계는 뚜렷하지 않았음을 의미한다.

사전 예측 기반 방식에서는 유입수 탁도와 응집제 주입유량 간 Pearson 상관계수 $r = 0.147$ ($p < 0.001$), Spearman 상관계수 $\rho = 0.301$ ($p < 0.001$)로 나타나, 유입수 탁도 변화에 따라 응집제 주입유량이 증가하는 경향이 확인되었다. 이는 사전 예측 기반 방식이 시간별 예측 setpoint를 통해 원수 수질 변화에 대응하여 주입유량을 조절하였음을 정량적으로 보여준다.

한편 사전 예측 기반 방식에서 유입수 탁도와 침전지 처리수 탁도 간 상관성은 Pearson $r = 0.214$ ($p < 0.001$), Spearman $\rho = 0.608$ ($p < 0.001$)로 나타났다. 이는 PACI 적용 기간에 최대 155.8 NTU 수준의 고탁도 유입 이벤트가 포함되어, 유입수 탁도 변동이 침전지 처리수 탁도에도 일부 영향을 미쳤기 때문으로 판단된다. 그러나 해당 조건에서도 침전지 처리수 탁도는 1 NTU 이하의 단위 공정 관리 기준을 모두 만족하였으므로, 처리수 탁도는 기준 범위 내에서 안정적으로 유지된 것으로 해석된다.

종합적으로 PACI 적용 조건에서도 사전 예측 기반 제어 방식은 기존 사후 대응 방식과 다른 응집제 주입 패턴을 나타냈으며, 원수 수질 변화에 따라 응집제 주입량이 유연하게 변화하는 특성을 확인할 수 있었다. 특히 PACS 조건 대비 상대적으로 높은 탁도 변동 환경에서도 안정적인 처리 특성을 유지하는 경향을 나타내어, 고변동성 원수 조건에서 사전 예측 기반 운영 방식의 적용 가능성을 확인할 수 있었다.

3.5 운영 결과

사후 대응 방식과 사전 예측 기반 방식의 운영 성능을 정량적으로 비교한 결과는 표 4와 같다. 운영 결과 비교는 PACS 및 PACI 적용 기간에 대하여 각각 수행하였으며, 응집제 사용량, 침전지 처리수 탁도 및 단위 공정 기준 만족 여부를 중심으로 평가하였다. 또한 두 제어 방식 간 차이의 통계적 유의성을 검토하기 위하여 시간별 운영자료를 이용한 Welch's t-test를 수행하였다.

PACS 적용 조건에서 사후 대응 방식의 평균 응집제 주입량은 6.804 ± 1.384 mL/min (5.0-9.5 mL/min)으로 나타났으며, 사전 예측 기반 방식에서는 4.097 ± 1.367 mL/min (0.6-10.6 mL/min)으로 감소하였다. 두 방식 간 응집제 주입유량 차이는 통계적으로 유의하게 나타났으며 ($p < 0.001$), 이에 따라 약 39.71%의 응집제

pp. 487-500

pp. 501-509

pp. 511-527

pp. 529-539

pp. 541-551

pp. 553-564

pp. 565-582

pp. 583-596




Fig. 4. Temporal variations in coagulant dosing flow rate and sedimentation basin effluent turbidity under reactive and AI-based predictive control during PACI dosing.

절감 효과가 확인되었다. 반면 침전지 처리수 탁도는 각각 0.794 ± 0.193 NTU(0.1-1.0 NTU) 및 0.807 ± 0.189 NTU(0.5-1.0 NTU)로 나타났으며, 두 방식 간 유의한 차이는 확인되지 않았다($p = 0.367$). 또한 두 방식 모두 침전지 처리수 탁도 1 NTU 이하 기준을 100% 만족하였다.

PACI 적용 조건에서 사후 대응 방식의 평균 응집제 주입유량은 10.043 ± 1.904 mL/min(9.0-13.5 mL/min)으로 나타난 반면, 사전 예측 기반 방식에서는 4.609 ± 1.568 mL/min(0.7-13.4 mL/min)으로 감소하였다. 두 방식 간 응집제 주입유량 차이는 통계적으로 유의하였으며($p < 0.001$), 약 54.08%의 응집제 절감 효과가 나타났다. 침전지 처리수 탁도는 각각 0.821 ± 0.146 NTU(0.5-1.0 NTU) 및 0.867 ± 0.170 NTU(0.4-1.0 NTU)로 나타났다. 두 방식 간 처리수 탁도 차이는 통계적으로 유의하였으나($p < 0.001$), 평균 차이는 0.046 NTU로 작았으며 두 방식 모두 1 NTU 이하의 단위 공정 관리 기준을 100% 만족하였다.

응집제 종류별 결과를 비교한 결과, 사전 예측 기반 방식은 PACS 및 PACI 조건 모두에서 기존 사후 대응 방식 대비 응집제 사용량 감소 효과를 확인하였다. 특히 PACI 조건에서는 PACS 대비 높은 응집제 절감률이 나타났으나, PACI 운전기간에는 PACS 운전기간보다 높은 유입 탁도 조건과 고탁도 이벤트가 포함되어 있었으므로, 이를 단순히 응집제 종류 또는 제어 방식

만의 효과로 해석하기에는 한계가 있다. 따라서 본 연구에서는 각 응집제 조건 내에서 사후 대응 방식 대비 사전 예측 기반 방식의 상대적 응집제 사용량 감소와 처리수 탁도 안정성 유지 여부를 중심으로 평가하였다.

고탁도 유입 조건에서의 처리수 탁도 안정성을 정량적으로 검토하기 위하여 유입수 탁도 20 NTU 이상인 구간을 고탁도 조건으로 구분하였다. 분석 결과, PACS 조건의 고탁도 구간은 총 39개 시간자료로 확인되었으며, 해당 구간의 유입수 탁도는 21.3-77.2 NTU 범위를 나타냈다. 이때 침전지 처리수 탁도는 평균 0.810 ± 0.198 NTU, 최대 1.0 NTU로 나타났으며, 1 NTU 이하 기준 준수율은 100.0%로 확인되었다. PACI 조건의 고탁도 구간은 총 31개 시간자료로 확인되었으며, 유입수 탁도는 20.0-155.8 NTU 범위를 나타냈다. 해당 구간의 침전지 처리수 탁도는 평균 0.832 ± 0.122 NTU, 최대 1.0 NTU로 나타났으며, 1 NTU 이하 기준 준수율은 100.0%로 확인되었다.

또한 사전 예측 기반 방식이 적용된 고탁도 구간만을 대상으로 분석한 결과, PACS 조건에서는 총 39개 시간자료에서 유입수 탁도 21.3-77.2 NTU가 관측되었으며, 침전지 처리수 탁도는 평균 0.810 ± 0.198 NTU, 최대 1.0 NTU, 1 NTU 이하 기준 준수율 100.0%로 나타났다. PACI 조건에서는 총 19개 시간자료에서 유입수 탁도 38.6-155.8 NTU가 관측되었으며, 침전지 처리

**Table 4.** Comparison of coagulant dosing performance between reactive and AI-based predictive control strategies

Category	Parameter	Unit	PACS Reactive	PACS Predictive	p-value	PACI Reactive	PACI Predictive	p-value
Operation	Operation Time	h	360	352	-	207	600	-
Coagulant dosing	Dosing Flow Rate	mL/min	6.804 ± 1.384 (5.0-9.5)	4.097 ± 1.367 (0.6-10.6)	<0.001	10.043 ± 1.904 (9.0-13.5)	4.609 ± 1.568 (0.7-13.4)	<0.001
Water quality	Effluent Turbidity	NTU	0.794 ± 0.193 (0.1-1.0)	0.807 ± 0.189 (0.5-1.0)	0.367	0.821 ± 0.146 (0.5-1.0)	0.867 ± 0.170 (0.4-1.0)	<0.001
Evaluation	Coagulant reduction rate	%	-	39.71	-	-	54.08	-
Evaluation	Effluent turbidity compliance rate(≤1 NTU)	%	100	100	-	100	100	-

*Values are presented as mean ± standard deviation (min-max). Statistical differences between reactive and predictive operations were evaluated within each coagulant condition using Welch's t-test based on hourly operation data. p-values indicate the significance of differences between the two control strategies. The effluent turbidity compliance rate was calculated based on the criterion of ≤1 NTU.

수 탁도는 평균 0.868 ± 0.106 NTU, 최대 1.0 NTU, 1 NTU 이하 기준 준수율 100.0%로 나타났다. 따라서 본 연구의 제한된 실증 조건 내에서는 고탁도 유입 이벤트 발생 시에도 사전 예측 기반 제어 방식 적용 구간의 침전지 처리수 탁도가 단위 공정 관리 기준 내에서 유지된 것으로 판단된다.

상관분석 결과, PACS와 PACI 조건에서 제어 방식별 운전 특성이 다르게 나타났다. PACS 조건에서는 사전 예측 기반 방식의 유입수 탁도와 응집제 주입유량 간 상관성이 음의 방향으로 나타났으나, 이는 동일 시점의 유입 탁도만으로 주입유량이 결정되는 것이 아니라 과거 수질 및 운영자료를 기반으로 사전에 산정된 시간별 setpoint가 적용되었기 때문으로 판단된다. 반면 PACI 조건에서는 사전 예측 기반 방식에서 유입수 탁도와 응집제 주입유량 간 유의한 양의 상관성이 확인되어, 유입수 탁도 변화에 따라 주입유량이 증가하는 경향이 나타났다. 특히 PACI 운전기간에는 최대 155.8 NTU의 고탁도 유입 이벤트가 포함되어 유입수 탁도와 침전지 처리수 탁도 간 상관성이 상대적으로 높게 나타났으나, 침전지 처리수 탁도는 전 구간에서 1 NTU 이하 기준을 만족하였다. 따라서 사전 예측 기반 방식은 응집제 주입유량을 크게 절감하면서도 단위 공정 관리 기준 내에서 처리수 탁도 안정성을 유지한 것으로 해석된다.

종합적으로 AI 기반 사전 예측 제어 방식은 기존 자 테스트 기반 사후 대응 방식 대비 응집제 사용량

을 유의하게 절감하면서도 처리수 탁도 기준을 만족하여, 본 연구의 실증 조건 내에서 운영 적용 가능성을 나타냈다. 특히 사전 예측 기반 방식은 PACS 및 PACI 조건 모두에서 사후 대응 방식 대비 응집제 주입유량을 유의하게 감소시켰으며, 침전지 처리수 탁도는 두 방식 모두 단위 공정 관리 기준인 1 NTU 이하를 만족하였다. 다만 PACI 조건에서는 처리수 탁도 평균값의 통계적 차이가 확인되었으므로, 해당 결과는 평균 차이의 크기와 기준 준수 여부를 함께 고려하여 해석할 필요가 있다.

다만 본 연구의 실증 운전은 약 3개월간 수행되었으며, 여름~가을 시기의 원수 수질 및 수온 조건을 중심으로 검증되었다. 따라서 저수온기, 계절 전환기, 장기 고탁도 조건 및 조류 발생과 같은 극한 수질 변동 조건까지 본 연구 결과를 일반화하기에는 한계가 있다. 특히 저수온기에는 응집 반응 속도, 플록 형성 특성 및 침강성이 달라질 수 있으므로, 사전 예측 기반 제어 방식의 장기 운영 안정성을 추가로 검증할 필요가 있다. 향후 연구에서는 동절기 및 고탁도·조류 발생 이벤트를 포함한 장기 실증 운전을 통해 계절별 원수 수질 변화에 따른 모델 성능과 제어 안정성을 평가할 필요가 있다.

4. 결론

본 연구에서는 정수 실증화 시설을 대상으로 기존

pp. 487-500

pp. 501-509

pp. 511-527

pp. 529-539

pp. 541-551

pp. 553-564

pp. 565-582

pp. 583-596

자 테스트 기반 사후 대응 방식과 AI 기반 사전 예측 방식의 응집제 주입 운영 성능을 비교·평가하였다. 이를 위해 PACS 및 PACI 조건에서 응집제 주입농도 예측 모델을 통해 산정된 제어값을 SCADA-HMI-PLC 기반 제어 시스템과 연계하여 실증 운전을 수행하였다.

운영 결과, 사전 예측 기반 방식은 기존 사후 대응 방식 대비 PACS 조건에서 39.71%, PACI 조건에서 54.08%의 응집제 절감 효과를 나타냈다. 반면 침전지 처리수 탁도는 두 응집제 조건 모두에서 1 NTU 이하 수준으로 안정적으로 유지되었으며, 단위 공정 탁도 기준 준수율은 100%로 나타났다. 이는 본 연구의 실증 운전 조건 내에서 사전 예측 기반 제어 방식이 응집제 사용량을 절감하면서도 처리수 수질 안정성을 유지할 수 있음을 의미한다.

또한 사전 예측 기반 방식은 기존 사후 대응 방식과 달리 유입수 수질 변화에 따라 응집제 주입량이 시간별로 변화하는 특성을 보였다. 특히 PACI 적용 기간과 같이 상대적으로 높은 탁도 변동 조건에서도 처리수 탁도는 1 NTU 이하 기준을 만족하였다. 따라서 본 연구 결과는 하천형 원수와 같은 변동성 수질 조건에서 AI 기반 사전 예측 제어 방식의 적용 가능성을 제한된 실증 조건 내에서 확인한 결과로 해석할 수 있다.

다만 PACS와 PACI 운전기간의 원수 수질 조건이 상이하였으므로, 응집제 종류 간 절감률 차이를 직접 비교하기보다는 각 운전기간 내에서의 상대적 절감 효과로 해석할 필요가 있다. 또한 본 연구는 약 3개월의 여름~가을 실증 운전자료를 기반으로 수행되었으므로, 저수온기, 계절 전환기, 장기 고탁도 조건 및 조류 발생과 같은 극한 수질 변동 조건까지 결과를 일반화하기에는 한계가 있다.

종합적으로 AI 기반 사전 예측 제어 방식은 기존 자 테스트 중심의 사후 대응 운영 한계를 보완하고, 응집제 사용량 절감과 처리수 수질 안정성을 동시에 확보할 수 있는 운영 전략으로 판단된다. 다만 본 연구에서 확인한 효과는 D시에 위치한 정수 실증화 시설, PACS 및 PACI 운전조건, 그리고 연구기간 동안의 원수 수질 조건에 한정된 결과이므로, 실제 정수장 전반에 대한 현장 적용성을 일반화하기 위해서는 다양한 계절, 원수 특성 및 시설 규모를 대상으로 한 추가 검증이 필요하다. 본 연구 결과는 향후 스마트 정수장 및 자율운영 기반 정수처리 공정 구현을 위한 기초

자료로 활용될 수 있을 것으로 기대된다.

본 연구는 실증화 시설에서 연속 취득 가능한 온라인 계측자료를 중심으로 입력 변수를 구성하였기 때문에, TOC, UV₂₅₄, 알칼리도 및 조류 관련 인자와 같이 응집제 주입량 결정에 영향을 줄 수 있는 일부 수질 인자를 충분히 반영하지 못한 한계가 있다. 향후 연구에서는 해당 수질 인자에 대한 온라인 계측자료를 추가로 확보하고, 변수 중요도 및 민감도 분석을 통해 입력 변수별 기여도와 모델 해석성을 보완할 필요가 있다. 또한 동절기 및 고탁도·조류 발생 이벤트를 포함한 장기 실증 운전을 통해 계절별 모델 성능, 제어 안정성 및 응집제 절감 효과의 재현성을 검증할 필요가 있다. 나아가 단일 AI 모델 고정 적용 방식과 Model Bank 기반 선택 전략을 동일 조건에서 비교함으로써, 복수 모델 기반 사전 예측 제어 방식의 실질적 운영 효과를 보다 정량적으로 평가할 필요가 있다.

사 사

본 결과물은 환경부의 재원으로 한국환경산업기술원의 상하수도 혁신 기술개발사업의 지원을 받아 연구되었습니다.(2020002700003)

References

- Bello, O., Hamam, Y., and Djouani, K. (2014). Coagulation process control in water treatment plants using multiple model predictive control, *Alexandria Eng. J.*, 53(4), 939-948.
- Breiman, L. (2001). *Random forests*, *Mach. Learn.*, 45, 5-32.
- Bressane, A., Goulart, A.P.G., Melo, C.P., Gomes, I.G., Loureiro, A.I.S., Negri, R.G., Moruzzi, R., Reis, A.G.d., Formiga, J.K.S., da Silva, G.H.R., and Thome, R.F. (2023). A non-hybrid data-driven fuzzy inference system for coagulant dosage in drinking water treatment plant: Machine-learning for accurate real-time prediction, *Water*, 15(6), 1126.
- Environmental Protection Agency. (2002). *Water treatment manuals: Coagulation, flocculation and clarification*, Environmental Protection Agency, 1-104.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory, *Neural Comput.*, 9(8), 1735-1780.
- Kim, J., Hua, C., Kim, K., Lin, S., Oh, G., Park, M.H., and



- Kang, S. (2024). Optimizing coagulant dosage using deep learning models with large-scale data, *Chemosphere*, 350, 140989.
- Kim, S. G., Son, H. J., Lee, J. K., Yeom, H. S., and Yoo, P. J. (2017). Evaluation of streaming current detector (SCD) and charge analyzing system (CAS) for automation of coagulant dosage determination, *J. Korean Soc. Environ. Eng.*, 39(4), 201-207.
- Lin, S., Kim, J., Hua, C., Park, M.H., and Kang, S. (2023). Coagulant dosage determination using deep learning-based graph attention multivariate time series forecasting model, *Water Res.*, 232, 119665.
- Liu, J., Deng, Y., Chen, R., Xu, Y., and Wu, J. (2024). Application of artificial intelligence in the management of coagulation treatment engineering system, *Processes*, 12(9), 1824.
- Nam, S.W., Jo, B.I., Kim, M.K., Kim, W.K., and Zoh, K.D. (2013). Streaming current titration for coagulation of high turbidity water, *Colloids Surf. A Physicochem. Eng. Asp.*, 419, 133-139.
- Narges, S., Ghorban, A., Hassan, K., and Mohammad, K. (2021). Prediction of the optimal dosage of coagulants in water treatment plants through developing models based on artificial neural network fuzzy inference system (ANFIS), *J. Environ. Health Sci. Eng.*, 19, 1543-1553.
- Tochio, E.L.L., do Nascimento, B.C., and Lautenschlager, S.R. (2023). Coagulant dosage prediction in the water treatment process, *Water Supply*, 23(9), 3515-3531.
- U.S. Environmental Protection Agency. (2020). Surface water treatment rule turbidity guidance manual, U.S. Environmental Protection Agency, 1-192.
- Wang, D., Chen, L., Li, T., Chang, X., Ma, K., You, W., and Tan, C. (2023). Successful prediction for coagulant dosage and effluent turbidity of a coagulation process in a drinking water treatment plant based on the Elman neural network and random forest models, *Environ. Sci.: Water Res. Technol.*, 9, 2263-2274.
- Yu, R.F., Kang, S.F., Liaw, S.L., and Chen, M.C. (2000). Application of artificial neural network to control the coagulant dosing in water treatment plant, *Water Sci. Technol.*, 42(3-4), 403-408.

pp. 487-500

pp. 501-509

pp. 511-527

pp. 529-539

pp. 541-551

pp. 553-564

pp. 565-582

pp. 583-596