

이차전지 건식 전극 롤투롤 캘린더 공정 다중 출력 회귀를 이용한 롤 간극(GAP) 예측 연구

문장현¹ · 유홍석² · 장재석^{2*}

¹경운대학교 산업공정AI융합학과 / ²경운대학교 소프트웨어학부

Research of a Multi-Output Regression Model for Roll Gap Prediction in Roll-to-Roll Calendering of Dry Battery Electrodes

Janghyun Mun¹ · Hongseok Yoo² · Jaeseok Jang²

¹Department of Industrial Process AI Convergence, Kyungwoon University

²School of Software, Kyungwoon University

This study develops a multi-output regression model to predict multi-stage roll gaps in a roll-to-roll calendering process for dry lithium-ion battery electrodes. We collected 2,912 samples from process logs measured across Calender 1-6 and used 33 variables (line speed, roll temperature, roll pressure, and web tension) as inputs. Ten OS/DS gaps of Calender 2-6 were predicted simultaneously using a MultiOutputRegressor, and MLR, RandomForest, and XGBoost were compared with 5-fold cross-validation. Tree-based nonlinear models outperformed the linear baseline, and XGBoost achieved the best accuracy with stable generalization. Gap-wise evaluation and feature-importance analysis identified difficult sections and highlighted line speed, roll pressure, and roll temperature as dominant factors. The proposed model can act as a virtual sensor to fill measurement gaps and estimate the full gap profile in real time, supporting monitoring, gap-control strategy design, and operating-condition optimization.

Keywords: Roll-to-roll Calendering, Dry Electrode, Roll Gap Prediction, Multi-Output Regression, XGBoost, Secondary Battery Electrode Manufacturing

1. 서론

롤투롤 캘린더 압연 공정은 연속적으로 이송되는 시트(필름, 전극, 박판 등)에 일정 압력을 가하여 목표 두께와 밀도를 형성하는 핵심 제조 공정이다. 이때 롤 간극(GAP)은 최종 제품의 두께, 밀도, 공극률 및 두께 편차에 직접적인 영향을 미치며, 미세한 간극 변화가 품질 불량으로 이어질 수 있다. 따라서 간극 제어의 정밀도와 안정성 확보는 고품질 생산을 위한 필수 요소이다. 롤투롤 캘린더링 공정에서 전극 시트가 두 롤 사이

를 통과하며 압연되고, 이때 형성되는 롤 간극이 품질 특성에 영향을 미치는 기본 구조를 아래 <Figure 1>에 나타내었다.

그러나 실제 제조 현장에서는 Calender(롤로 구성된 압연 설비) 2~6 구간의 간극이 온도, 실린더 압력, 라인 속도, 장력 등 다수의 공정 변수와 비선형적으로 상호작용하며 변화한다. 여기에 롤 마모, 롤 정렬 오차, 재료 편차 등 외생 요인까지 포함되어 간극 변동 원인을 단순한 경험식으로 설명하기 어렵다. 더불어 일부 구간은 센서 미부착 또는 설치 위치의 한계로 인해 실시간 간극 측정 자체가 어렵거나 불연속적이다. 이로 인

본 연구는 산업통상자원부와 한국산업기술진흥원의“중견기업-지역 혁신 얼라이언스 지원(R&D, RS-2024-00421022)”사업의 지원을 받아 수행된 연구결과임. 본 과제(결과물)은 교육부 및 경상북도의 재원으로 경북rise센터의 지원을 받아 수행된 지역혁신중심 대학지원체계(rise)의 결과임이다.(2025-rise-15-102).

* 연락처 : 장재석 교수, 39160, 경상북도 구미시 산동읍 강동로 730 2호관 508호, Tel : 054-479-1252, E-mail : jaeseok.jang@ikw.ac.kr
2026년 1월 26일 접수; 2026년 2월 13일; 2026년 3월 5일 수정본 접수; 2026년 3월 10일 게재 확정.

해 현장에서는 작업자의 경험과 노하우에 기반한 수동 조정이 이루어지며, 이는 예기치 못한 간극 변동과 품질 불량을 초래하는 원인이 된다(Perera *et al.*, 2023).




Figure 1. Roll Calendering.

최근 제조 분야에서는 공정 데이터 기반의 머신러닝 및 딥러닝 기법을 활용해 품질 예측, 이상 탐지, 공정 최적화 등을 수행하는 연구가 활발히 진행되고 있다(Haghi *et al.*, 2023). 특히 트리 기반 앙상블 모델과 부스팅 기반 모델은 비선형 관계와 변수 간 상호작용을 효과적으로 학습할 수 있어 복잡한 공정 데이터 분석에 적합한 것으로 알려져 있다. 본 연구는 이러한 흐름 속에서 톨투를 캘린더 공정의 간극 예측에 특화된 다중 출력 회귀 모델을 구축하고, 이를 바탕으로 가상 간극 센서 구현 가능성과 공정 인사이트 도출을 목표로 한다.

본 논문의 구성은 다음과 같다. 제2장에서는 이차전지 건식 전극 공정과 캘린더링 공정의 특성을 정리하고, 톨 간극 및 공정 데이터 기반 품질 예측과 관련된 선행 연구를 검토하여 본 연구의 차별성을 제시한다. 제3장에서는 연구 대상 톨투를 캘린더 공정과 데이터셋 구성을 설명하고, 다중 출력 회귀 프레임워크, 비교 모델 및 성능 평가 방법을 기술한다. 제4장에서는 구축된 모델의 5-fold 교차검증 결과를 제시하고, GAP별 예

측 성능과 공정 변수 중요도를 분석한다. 마지막으로 제5장에서는 연구 결과를 요약하고, 현장 적용 관점에서의 시사점과 향후 연구 방향을 논의한다.

2. 관련 연구

2.1 이차전지 전극 제조 공정과 건식 전극 기술

리튬이온전지 전극 제조 공정은 전통적으로 슬러리 기반의 습식 공정(wet electrode process)에 의존해 왔다. 활물질, 도전재, 바인더를 N-methyl-2-pyrrolidone(NMP) 등의 유기용매에 분산시켜 슬러리를 제조한 뒤, 집전체(동박, 알루미늄박)에 코팅하고 건조 및 용매 회수, 캘린더링 공정을 거쳐 최종 전극을 완성하는 방식이다. NMP는 바인더 분산과 코팅 안정성 측면에서는 유리하지만, 독성을 가진 고가 용매로 분류되어 건조 후 회수 및 정제가 필수이며, 전극 코팅·건조·용매 회수 단계가 전체 전극 제조 비용과 에너지 소비에서 상당한 비중을 차지한다는 연구 결과가 보고되고 있다(Zhang *et al.*, 2022; Yu *et al.*, 2025).

이러한 습식 공정의 비효율성과 환경 규제 강화에 대응하기 위해, 최근에는 건식 전극(dry electrode) 공정이 차세대 전극 제조 기술로 주목받고 있다. 건식 전극 공정은 용매를 사용하지 않고 활물질, 도전재, 건식용 바인더를 분말 상태에서 혼합한 뒤, 압축, 라미네이션, 캘린더링 등을 통해 집전체에 직접 부착하는 방식으로 전극을 제조한다. 이 방식은 슬러리 제조, 건조 및 용매 회수 공정을 생략할 수 있어 공장 면적 감소, 에너지 사용량 절감, 설비 투자비 및 운영비 절감 등의 제조 공정상의 장점이 기대된다(Jin *et al.*, 2024). 건식 공정은 용매를 전혀 사용하지 않고 건조 단계를 생략하기 때문에 습식 기반 공정보다 짧다. 이러한 습식 전극 공정과 건식 전극 공정의 주요 공정 흐름 및 차이는 <Figure 2>에 비교하여 나타내었다.




Figure 2. Comparison of Dry and Wet Processes for Secondary Battery Electrode Manufacturing.

최근 리뷰 논문들에서는 전극 전극 공정을 기존 습식 공정과 비교하여, 용매 제거에 따른 환경 및 안전성 개선, 공정 라인 단축, 고면적 밀도 전극 구현 가능성 등 기술적 장점과 함께 분말 혼합 균일성, 바인더 네트워크 형성, 캘린더링 후 미세구조 제어의 어려움 등 해결해야 할 과제를 종합적으로 정리하고 있다(Zhang *et al.*, 2022; Lu *et al.*, 2022; Yu *et al.*, 2025; Schumm *et al.*, 2025). 그러나 대부분의 연구는 소재 조성, 바인더 시스템, 전극 미세구조 및 전기화학 성능에 초점을 두고 있으며, 전극 전극 공정 내 압연/캘린더링 조건과 간극(GAP) 제어를 공정 데이터 기반으로 정량 분석 및 예측한 사례는 상대적으로 드물다(Gyulai *et al.*, 2023).

2.2 캘린더링 공정 및 간극 관련 모델링 연구

캘린더링(calendering)은 두 롤 사이에 전극을 통과시키며 압력을 가해 두께와 밀도, 공극률을 조절하는 공정으로, 전극 및 습식 전극 모두에서 핵심 단위 공정으로 알려져 있다. 기존 연구에서는 전극 두께, 공극률, 기계적 특성 및 전기화학적 성능이 캘린더링 압력, 롤 간극, 롤 온도 등에 따라 어떻게 변화하는지 실험 및 시뮬레이션 기반으로 분석해 왔다(Yu *et al.*, 2025; Gyulai *et al.*, 2023; Schreiner *et al.*, 2020). 예를 들어 Schreiner 등은 NMC-622 전극을 대상으로, 캘린더링 전에 측정된 전극 두께와 설정 롤 간극을 바탕으로 목표 공극률에 필요한 롤 간극을 예측하는 이산요소법(DEM) 기반 시뮬레이션 모델을 제안하였다(Schreiner *et al.*, 2020; Schreiner *et al.*, 2023). 또한 Duquesnoy 등은 실험적 특성 분석, 전극 메조구조의 in-silico 생성, 머신러닝 알고리즘을 결합하여 캘린더링 조건과 전극 미세구조, 전기화학 성능 간의 관계를 모델링하는 데이터 기반 접근법을 제시하였다(Duquesnoy *et al.*, 2020). 최근에는 캘린더링 압력, 롤 온도, 간극, 직류 저항, 임피던스, 용량 감소 등의 상관관계를 분석하여 캘린더링 조건을 최적화하는 연구도 보고되고 있다(Schreiner *et al.*, 2020; Schreiner *et al.*, 2023; Duquesnoy *et al.*, 2020).

이러한 연구들은 전극 두께, 공극률, 전기화학 성능을 중심으로 캘린더링 조건의 영향을 모델링하고 있지만, 대부분이 설정된 롤 간극과 압력을 입력으로 사용하는 구조이며, 라인 전체에서 다수의 공정 변수(속도, 온도, 장력 등)로부터 각 스탠드의 실질적인 롤 간극을 역으로 예측하는 방향의 연구는 드문 편이다. 특히 다단 캘린더(Calender 2~6)의 각 스탠드별 OS/DS(정면/후면) 간극을 동시에 다중 출력으로 모델링하는 사례는 드물다.

2.3 공정 데이터 기반 품질 예측 및 다중 회귀

제조 분야에서는 센서 데이터와 공정 로그를 활용하여 품질 특성을 예측하거나 다단 공정의 품질을 동시에 추정하는 데이터 기반 품질 예측 연구가 활발히 진행되고 있다. 금속 압출, 사출, 캘린더링, 제련 등 다양한 공정에서 회귀 분석, 앙상블

러닝, 심층 신경망 등을 활용해 치수 정밀도, 표면 거칠기, 에너지 소비량 등을 예측하는 사례가 보고된다(Haghi *et al.*, 2023; Shardt *et al.*, 2018).

최근에는 여러 품질 지표를 동시에 예측하거나, 공정 단계별 품질을 한 번에 모델링하기 위한 다중 출력 회귀(multi-output regression), 다중 태스크 학습(multi-task learning) 접근이 주목받고 있다(Yan *et al.*, 2021; Wang *et al.*, 2023; Xu *et al.*, 2019). 예를 들어 Wang *et al.* (2023)은 다단 제조 공정의 품질을 동시에 예측하기 위해 멀티태스크 합동 딥러닝 프레임워크를 제안하였고, Yan *et al.* (2021)은 deep multistage multi-task learning 구조를 통해 공정 단계 간 상관관계를 활용할 때 단일 태스크 대비 예측 성능이 향상됨을 보였다. 또한 OLED, 제련 공정, 레이저 가공 등 다양한 제조 사례에서 다중 출력 SVM 및 다중 출력 딥러닝 모델을 적용하여 여러 품질 특성을 동시에 예측 및 최적화하는 기법이 제시되고 있다(Haghi *et al.*, 2023; Shardt *et al.*, 2018; Borchani *et al.*, 2015; Xu *et al.*, 2019; Schmid *et al.*, 2023; Spyromitros-Xioufis *et al.*, 2016).

배터리 분야에서도 전극 건조, 캘린더링, 전해액 함침 등 세부 공정에서 머신러닝 및 딥러닝을 활용해 전극 미세구조나 성능을 예측하는 연구가 증가하고 있다(Duquesnoy *et al.*, 2020; Shodiev *et al.*, 2021; Haghi *et al.*, 2023; Shardt *et al.*, 2018). 최근 리뷰에서는 공정 조건과 전극 구조 및 성능 간 매핑을 위한 데이터 기반 모델링의 중요성을 강조하며, 양산 공정에서 실시간 품질 예측과 공정 제어로 확장될 수 있는 잠재력을 제시하고 있다(Haghi *et al.*, 2023). 그러나 대부분의 연구는 품질 지표(두께, 공극률, 용량 등)를 타겟으로 하며, 롤 간극 자체를 여러 스탠드에 걸친 다중 출력 타겟으로 정의하고 공정 로그만을 입력으로 예측하는 프레임워크는 상대적으로 부족하다(Borchani *et al.*, 2015; Schmid *et al.*, 2023).

2.4 본 연구의 차별성

정리하면, 기존 연구는 (1) 전극 전극 공정의 개념, 장점, 소재 및 전기화학 특성을 폭넓게 다루거나(Zhang *et al.*, 2022; Lu *et al.*, 2022; Yu *et al.*, 2025; Schumm *et al.*, 2025; Gyulai *et al.*, 2023), (2) 캘린더링 조건(압력, 롤 간극, 롤 온도 등)과 전극 두께, 공극률, 성능 간 관계를 실험/시뮬레이션 기반으로 모델링하거나(Gyulai *et al.*, 2023; Schreiner *et al.*, 2020; Schreiner *et al.*, 2023; Duquesnoy *et al.*, 2020), (3) 공정 데이터 기반으로 품질 지표를 예측하는 다중 출력/다중 태스크 학습 프레임워크를 제시하는 데 초점이 맞추어져 있다(Shodiev *et al.*, 2021; Haghi *et al.*, 2023; Yan *et al.*, 2021; Wang *et al.*, 2023).


반면, 본 연구는 이차전지 전극 전극 공정의 핵심 단위 공정인 물투를 캘린더 압연 공정을 대상으로, 실제 현장에서 수집된 다중 공정 데이터(속도, 온도, 압력, 장력 등)를 입력으로 사용하여 Calender 2~6 구간의 OS/DS GAP 10개를 동시에 예측하는 다중 출력 회귀 모델을 구축한다는 점에서 차별성을 가

진다. 나아가 단일 GAP이 아니라 라인 전체의 간극 프로파일을 통합적으로 예측하고, XGBoost 기반 변수 중요도 분석을 통해 각 GAP에 영향을 미치는 핵심 공정 인자를 정량적으로 도출함으로써, 향후 건식 전극 공정 라인에서 가상 간극 센서 구현 및 데이터 기반 간극 제어 전략 수립을 위한 구체적인 프레임워크를 제시한다는 점에서 기존 연구와 구분된다.

3. 연구 방법

3.1 롤투롤 캘린더 공정 및 데이터 구성

본 연구에 사용된 공정 데이터는 (주)피엔티에서 개발 및 운용 중인 건식 전극 롤투롤 캘린더 장비에서 수집하였다. 해당 장비의 전체 구조를 <Figure 3>에 나타내었다.



Source: PNT (People and Technology Inc.)

Figure 3. Dry Electrode roll-to-roll Calender Machine

장비는 건식 코팅부, 다단 캘린더부, 언와인더(unwinder), 리와인더(rewinder)로 구성되며, 각 캘린더 스탠드에서 속도, 온도, 압력, 간극 등 공정 변수를 계측할 수 있다. 본 연구에서 사용한 Calender 1~6 구간의 OS/DS GAP 및 공정 주요 변수 정의는 아래 <Figure 4>에 상세히 정리하였다.




Figure 4. Key Variables in dry-electrode roll-to-roll Calender Rolling Process.

Calender 1~6 구간의 운전 조건과 Calender 2~6 DS/OS 간극 센서 데이터를 포함하는 공정 로그가 분석에 사용되었다. 수집된 데이터는 CSV 형식이며, 약 2,912개 샘플로 구성되어 있다. 입력 변수는 총 33개 공정 파라미터, 출력 변수는 Calender 2~6의 OS/DS 간극 센서 값 10개로 구성된다.




Figure 5. calender 1~6 rolling process

입력 변수 X에는 Calender 1~6의 라인 속도(SPD), 온도(TEMP, center/edge), 압력(Pressure, OS/DS), Unwinder/Rewinder 속도 (SPD) 및 장력(Tension)이 포함된다. 출력 변수 y는 Calender 2~6의 OS/DS GAP 10개로 정의하였다. 이는 간극 예측을 통해 일부 센서 미부착 구간을 보완하고, 라인 전체 간극 프로파일을 동시에 파악하기 위함이다.

3.2 전처리 및 타깃 정의

데이터 전처리 과정은 다음과 같다. 첫째, 전체 컬럼을 수치 형으로 변환하여 모델 입력에 적합한 형태로 정리하였다. 둘째, 출력 변수(GAP) 컬럼에 결측값이 포함된 행은 제거하여 타깃 데이터의 신뢰성을 확보하고자 하였으나, 본 데이터셋에서는 타깃 결측으로 제거된 샘플이 없었다(N drop=0). 셋째, 입력 변수의 결측값은 변수별 중앙값(median)으로 대체하도록 전처리 파이프라인을 구성하였으며, 실제 데이터에서 입력 변수의 결측률은 0%로 확인되었다. 넷째, 학습 안정성과 모델 간 공정한 비교를 위해 모든 입력 변수에 대해 표준화(z-score) 기반 스케일 정규화를 수행하였다. 본 연구에서는 별도의 이상치 제거 규칙을 적용하지 않았으며, 대신 5-fold 교차검증을 통해 분할에 따른 성능 변동과 일반화 성능을 검증하였다. 또한, 본 데이터는 설비 로그가 동일 시점 기준의 레코드 형태로 정리되어 제공되어, 별도의 센서 동기화 또는 리샘플링 과정 없이 동일 시점의 공정 변수 벡터로 구성하였다. 최종적으로 입력 행렬 $X \in \mathbb{R}^{2912 \times 33}$, 출력 행렬 $Y \in \mathbb{R}^{2912 \times 10}$ 을 구성하였고, 단일 입력 벡터로부터 Calender 2-6의 OS/DS GAP 10개를 동시에 예측하는 다중 출력 회귀 문제로 설정하였다. 또한 타깃(GAP)은 스탠드별로 평균 수준과 분산 규모가 상이하여 후속 모델 비교에서는 이러한 타깃 스케일 차이를 고려하여 평가를 수행하였다.

Table 1. Dataset and preprocessing summary (Unit of GAP: μm)

Category	Item	Value
Dataset	Raw samples (N raw)	2,912
	Dropped due to target missing (N drop)	0
	Final samples (N final)	2,912
	# Input features (X) Calender1~6 SPD [m/min], Calender1~6 Center Temp [°C], Calender1~6 Edge Temp [°C], Calender1~6 OS Cyl. Pressure [kN], Calender1~6 DS Cyl. Pressure [kN], Unwinder SPD [m/min], Rewinder SPD [m/min], Unwinder Tension [N/m]	33
	# Target features (Y) Calender2~6 OS GAP Sensor [μm], Calender2~6 DS GAP Sensor [μm]	10
Missing values & scaling	X missing rate (overall / max across 33 features)	0.0% / 0.0%
	X handling	Median imputation (if missing; observed 0%)
	X scaling	Standardization (z-score)
	Outlier removal	Not applied
Target distribution	GAP mean range (across 10 targets)	151.9 - 260.0
	GAP std range (across 10 targets)	0.31 - 4.80
	GAP min-max (across 10 targets)	148.2 - 261.1
	P01-P99 range across targets (min of P01, max of P99)	149.7 - 260.6
Validation	Evaluation protocol	5-fold cross-validation

3.3 다중 출력 회귀 프레임워크

본 연구에서는 공정 로그로부터 추출한 33개 입력 변수(속도, 온도, 압력, 장력 등)를 이용하여 Calender 2~6 구간의 OS/DS GAP 10개를 동시에 예측하는 다중 출력 회귀(multi-output regression) 문제로 정의하였다. 이는 Calender 2~6의 OS/DS 간극이 동일 라인의 운전 조건과 소재 상태의 영향을 함께 받는다는 점과, 현장에서 간극을 개별 값이 아니라 라인 전체 간극 프로파일(profile)로 관리한다는 점을 반영한 설정이다.

다중 출력 회귀 구현을 위해 scikit-learn의 MultiOutputRegressor를 적용하였다(Pedregosa *et al.*, 2011). MultiOutputRegressor는 하나의 모델이 여러 타깃을 공동 학습하는 구조가 아니라, 각 GAP 타깃에 대해 독립적인 회귀 모델을 각각 학습한 뒤 예측 결과를 하나의 출력 벡터로 결합하는 래퍼(wrapper) 방식이다(Borchani *et al.*, 2015; Xu *et al.*, 2019; Spyromitros-Xioufis *et al.*, 2016; Schmid *et al.*, 2023). 따라서 본 연구의 다중 출력 프레임워크는 타깃 간 상관관계를 명시적으로 공유하는 공동학습(joint) 다변량 모델이라기보다, 동일한 전처리 및 검증 절차 하에서 라인 전체 GAP을 일관되게 산출하고 평가하기 위한 통합 예측 구조에 해당한다.

또한 MultiOutputRegressor는 타깃별 독립 학습으로 구성되므로, 동일한 전처리와 교차검증 분할(동일한 난수 설정이 적용되는 경우) 조건에서는 단일 타깃 개별 학습(ST)과 MultiOutputRegressor 기반 다중 출력 래퍼(MO)의 성능이 이론적으로 동일하게 나타난다. 이를 확인하기 위해 XGBoost (Chen and Guestrin, 2016)를 대상으로 ST와 MO를 동일 조건에

Table 2. ST vs MO equivalence check (XGBoost, 5-fold CV)

Target	ΔR^2 (MO-ST)	ΔRMSE (MO-ST)	ΔMAE (MO-ST)
Calender2 DS GAP	0.00	0.00	0.00
Calender2 OS GAP	0.00	0.00	0.00
Calender3 DS GAP	0.00	0.00	0.00
Calender3 OS GAP	0.00	0.00	0.00
Calender4 DS GAP	0.00	0.00	0.00
Calender4 OS GAP	0.00	0.00	0.00
Calender5 DS GAP	0.00	0.00	0.00
Calender5 OS GAP	0.00	0.00	0.00
Calender6 DS GAP	0.00	0.00	0.00
Calender6 OS GAP	0.00	0.00	0.00

*Single-target individual learning (ST) and multi-output wrapper (MO).

서 비교한 결과, 모든 GAP 타겟에서 R^2 , RMSE, MAE 차이가 0으로 확인되었다(<Table 2>). 이 결과는 이후 비교 실험을 다중 출력 프레임워크로 통일하더라도 성능 왜곡 없이 모델 간 비교가 가능함을 뒷받침한다. 따라서 본 연구에서의 “다중 출력”은 타겟 간 공동학습을 의미하기보다, 동일한 전처리와 교차검증 분할 조건에서 10개 GAP을 일괄적으로 산출하고 평가하기 위한 운영상의 통합 출력 구조를 의미한다. 또한 본 프레임워크는 추후 현장 적용 시 라인 전체 GAP 프로파일을 한 번에 모니터링하는 가상 센서 출력 형식과도 일치한다.

3.4 비교 모델 구성

데이터의 특성과 표본 수를 고려하여 예측 비교 모델을 MLR, RandomForestRegressor, XGBoostRegressor, MLPRegressor 4가지로 구성하였다. 모델은 기본적으로 단일 타겟 회귀 모델이므로, 본 연구에서는 MultiOutputRegressor를 적용하여 Calender 2-6의 OS/DS GAP 10개를 동시에 예측하는 다중 출력 회귀 문제로 확장하였다(Borchani *et al.*, 2015; Xu *et al.*, 2019; Schmid *et al.*, 2023; Spyromitros-Xioufis *et al.*, 2016). 모델 구현 및 학습은 scikit-learn을 사용하였다(Pedregosa *et al.*, 2011). 각 모델의 주요 하이퍼파라미터는 사전 실험 및 제한적 탐색을 통해 결정하였으며, 비교의 공정성을 위해 동일한 교차검증 분할 조건에서 평가하였다. 모델별 최종 하이퍼파라미터 설정 값은 <Table 3>에 정리하였다.

<Table 3>은 모델 비교에 사용된 주요 하이퍼파라미터 설정을 요약한 것이다. RandomForest와 XGBoost는 비선형 관계 학습을 위해 트리 앙상블 기반 설정을 사용하였으며, MLP는 타겟(GAP)별 스케일 차이를 고려하여 교차검증 과정에서 타겟 표준화(Y-scaling)를 추가로 적용한 설정과 튜닝 설정을 함께 비교하였다. 표에 명시하지 않은 나머지 파라미터는 라이브러리 기본값을 사용하였다.

(1) Multiple Linear Regression

MLR은 공정 변수와 GAP 간의 관계를 선형으로 가정하고,

각 GAP을 입력 변수의 가중합으로 표현하는 기본 회귀 모델이다. 수식으로는, 각 시점 t 에서 $y_t = X_t\beta + \epsilon_t$ 형태로 나타낼 수 있으며, 회귀계수 β 는 최소제곱법(least squares)으로 추정한다. 해석이 직관적이고 계산 비용이 낮다는 장점이 있으나, 변수 간 상호작용과 비선형 효과를 충분히 반영하기 어렵다. 본 연구에서는 비선형 모델과의 성능 차이를 비교하기 위한 기준선(baseline) 모델로 사용하였다.

(2) RandomForestRegressor

<Figure 6>은 랜덤포레스트의 앙상블 예측 과정을 개념적으로 나타낸다. 서로 다른 부트스트랩(bootstrap) 표본과 무작위 피쳐 선택을 통해 학습된 다수의 결정트리(Decision Tree)가 각각 예측을 산출하고, 이를 결합하여 최종 출력을 생성한다(Breiman, 2001). 회귀 문제에서는 <Figure 6>의 결합 방식 averaging(평균)에 해당하며, 최종 예측은 트리 예측값의 평균으로 계산된다. 이러한 배깅(bagging) 기반 평균화는 분산을 감소시켜 과적합을 완화하고, 공정 변수들 사이의 비선형 관계와 상호작용을 안정적으로 포착하는 데 유리하다. 본 연구에서는 트리 개수와 최대 깊이 등 주요 하이퍼파라미터를 사전 실험을 통해 설정하였고, 강건한 기준 비선형 모델로 활용하였다.




Figure 6. Random Forest Ensemble Structure for Predicting 10 Multi-output Gaps with 33 Process Input Features.

Table 3. Hyperparameter Settings Used in Model Comparison (others: default)

Model	Key hyperparameters
MLR	fit_intercept = True
RandomForest	n_estimators = 300, max_depth = None, min_samples_leaf = 3, max_features = 1.0, bootstrap = True, random_state = 42
XGBoost	n_estimators = 500, max_depth = 6, learning_rate = 0.05, subsample = 0.9, colsample_bytree = 0.8, objective = reg:squarederror
MLP (baseline)	hidden_layer_sizes = (128, 64), activation = relu, alpha = 1e-4, learning_rate_init = 1e-3, max_iter = 800, early_stopping = True
MLP (Y-scaled, tuned)	hidden_layer_sizes = (128, 64), activation = tanh, solver = adam, alpha = 7.59e-4, learning_rate_init = 7.71e-4, batch_size = 128, max_iter = 1200, early_stopping = False, n_iter_no_change = 20, validation_fraction = 0.1, tol = 1e-4, y_standardize_in_cv = True

(3) XGBoostRegressor

XGBoostRegressor는 그라디언트 부스팅(gradient boosting) 기 반 트리 앙상블 모델로, 이전 단계의 예측 오차(residual)를 줄이는 방향으로 얇은 결정트리를 순차적으로 추가하여 오차를 점진적으로 개선한다(Chen and Guestrin, 2016). 즉, 앞 단계에서 남은 오차(residual)를 다음 단계 트리가 보정하도록 학습하며, 여러 단계의 보정이 누적되면서 최종 예측이 만들어진다. 이 과정에서 학습률(learning rate)과 트리 깊이/가지치기 같은 모델 복잡도 조절, L1/L2 정규화 등을 통해 과적합을 제어한다. 또한 컬럼 샘플링과 결측값 처리 기능을 제공하여 공정 로그와 같은 고차원 수치 데이터에서도 안정적으로 학습할 수 있다. 아래 <Figure 7>은 잔차를 보정하는 트리를 순차적으로 더해 최종 예측을 형성하는 XGBoost의 학습 과정을 개념적으로 나타낸다. 본 연구에서는 사전 실험을 통해 수렴 안정성과 예측 성능이 양호한 하이퍼파라미터 조합을 선택하였으며, 예측 성능과 피쳐 중요도 제공 측면에서 최종 후보 모델로 활용하였다.




Figure 7. Schematic Architecture of the XGBoost Model.

(4) MLPRegressor

MLPRegressor는 다층 퍼셉트론(multilayer perceptron) 기반의 신경망 회귀 모델로, 비선형 활성화 함수를 통해 입력 변수와 타겟 사이의 복잡한 관계를 근사한다. 다만 MLP는 트리 기반 모델에 비해 데이터 스케일과 분포에 민감하며, 표본 수가 제한적이거나 잡음이 큰 공정 데이터에서는 하이퍼파라미터 설정에 따라 성능 변동이 커질 수 있다. 이에 본 연구에서는 입력 변수(X)를 표준화(z-score)하여 학습 안정성을 확보하였고, 다중 출력 회귀 설정에서 타겟(GAP)별 스케일 차이로 인해 학습이 불안정해질 수 있음을 고려하여 타겟(Y) 표준화(Y-scaling)를 추가로 적용하였다. 또한 제한적 범위의 하이퍼파라미터 탐색(Optuna)을 통해 은닉층 구조, 학습률, 정규화 계수 등의 조합을 조정된 MLP(Y-Scaled, Tuned)를 비교 모델에 포함함으로써, 공정 로그 기반 간극 예측에서 딥러닝 모델의 경쟁력을 동일한 평가 조건에서 검증하고자 하였다.

3.5 K-Fold 교차검증

모델 성능 평가는 K-Fold 교차검증을 통해 수행하였다. 데

이터셋을 5개 fold로 분할한 후, 4개 fold를 학습, 1개 fold를 검증에 사용하는 과정을 5회 반복하여 평균 성능과 표준편차를 산출하였다. 이를 통해 데이터 분할에 대한 민감도와 일반화 성능을 동시에 확인하였다. 각 모델의 성능 평가 지표는 다음과 같다.

(1) R² score(결정계수)

모델이 타겟 변동성을 얼마나 설명하는지 나타내며, 값이 1에 가까울수록 설명력이 높다.

(2) RMSE(Root Mean Squared Error)

예측값과 실제값의 차이를 제곱해 평균 낸 뒤 제곱근을 취한 값으로, 예측 오차의 크기를 나타낸다.

(3) MAE(Mean Absolute Error)

예측값과 실제값의 절대 오차 평균으로, 이상치에 덜 민감한 오차 척도이다.

본 연구는 공정 로그의 각 시점을 독립 표본으로 간주하여 회귀 모델을 학습하였다. 따라서 시간 지연(lag) 효과, 스탠드 간 동적 상호작용, 롤 마모/정렬 변화와 같은 장기 드리프트를 명시적으로 모델링하지 못한다는 한계가 있다. 이에 본 연구의 예측 결과는 동일 시점 공정 상태에서의 GAP 추정(가상 센서) 관점에서 해석해야 하며, 향후에는 시계열 특징(이동평균/지연항) 추가, 시간 블록 기반 분할(Time-series split) 또는 sequence 모델을 통해 연속성 정보를 반영하는 확장이 가능하다.

4. 실험 결과

4.1 모델별 k-fold 교차검증 결과

<Table 4>는 5-fold 교차검증 기반의 모델별 성능을 요약한 결과이다. 선형 기준선인 MLR 대비 트리 기반 비선형 모델(RandomForest, XGBoost)이 전반적으로 더 높은 R²와 더 낮은 오차(RMSE, MAE)를 보였다. 또한 MLP는 입력 표준화만 적용한 경우 타겟 스케일 차이의 영향으로 성능이 불안정할 수 있어, 본 연구에서는 타겟 표준화를 적용한 MLP(Y-Scaled, Tuned)를 추가로 비교하였다. 그럼에도 본 데이터셋(2,912 샘플)에서는 트리 기반 모델이 더 안정적인 일반화 성능을 보였으며, 최종적으로 XGBoost를 후속 GAP별 분석 및 변수 중요도 분석의 기준 모델로 선정하였다.

MLP는 연속형 변수 중심의 탭형(tabular) 데이터에서 데이터 규모가 충분하지 않거나(본 연구는 2,912 샘플), 변수 간 비선형 상호작용의 형태가 트리 분할 구조에 더 잘 맞는 경우 성능이 제한될 수 있다. 또한 본 문제는 GAP 타겟별 평균과 분산 규모가 상이하여 타겟 스케일 정규화가 없으면 학습이 특정 타겟에 치우치거나 최적화가 불안정해질 수 있다. 반면 트리

Table 4. Summary of k-fold cv Results By Model

model	R ² (mean±std)	RMSE (mean±std)	MAE (mean±std)
MLR	0.926 (±0.006)	0.593 (±0.024)	0.306 (±0.008)
RandomForest	0.971 (±0.002)	0.193 (±0.026)	0.089 (±0.004)
XGBoost	0.993 (±0.001)	0.169 (±0.019)	0.083 (±0.002)
MLP (baseline)	0.551 (±0.160)	2.715 (±0.106)	2.061 (±0.123)
MLP (Y-scaled, tuned)	0.852 (±0.012)	0.207 (±0.026)	0.129 (±0.049)

*Representation of the third decimal place.

기반 앙상블은 비선형성과 상호작용을 분할 규칙으로 직접 포착하고, 제한된 표본에서도 비교적 강건하며, 변수 중요도 기반 해석을 제공한다는 장점이 있어 공정 로그 기반 예측 및 원인 인자 도출 목적에 적합하다.

아래 <Table 5>는 머신러닝 기반 모델의 교차검증별 (Fold 1-5) 성능 결과이다. R²(결정계수)와 오차 지표 기준, XGBoost 모델이 가장 좋은 성능을 보인다.

Table 5. K-fold cv results by model (MLR, RandomForest, XGBoost)

model Fold N	R ²	RMSE	MAE
MLR Fold 1	0.9291	0.5886	0.3039
MLR Fold 2	0.9210	0.6186	0.3105
MLR Fold 3	0.9282	0.5778	0.3090
MLR Fold 4	0.9355	0.5605	0.2925
MLR Fold 5	0.9174	0.6239	0.3166
RF Fold 1	0.9723	0.1936	0.0855
RF Fold 2	0.9692	0.2291	0.0950
RF Fold 3	0.9702	0.2131	0.0925
RF Fold 4	0.9753	0.1506	0.0830
RF Fold 5	0.9729	0.1830	0.0909
XGB Fold 1	0.9922	0.1955	0.0830
XGB Fold 2	0.9933	0.1796	0.0870
XGB Fold 3	0.9942	0.1639	0.0846
XGB Fold 4	0.9962	0.1359	0.0784
XGB Fold 5	0.9937	0.1728	0.0832


*Representation of the fourth decimal place.

4.2 간극별 예측 성능

XGBoost 모델에 대해 GAP 센서별 예측 성능 평가 지표를 산출한 결과를 <Table 6>과 <Figure 8>에 나타내었다. Calender2 DS, Calender4 DS, Calender6 DS/OS 등은 R²가 0.95 이상으로 매우 높은 예측력을 보인 반면, Calender3/4 OS, Calender5 DS/OS 구간은 상대적으로 낮은 R²(0.83~0.90)를 보였다. 이는 해당 구간에서 외란, 센서 노이즈, 미모델링된 기계적 요인의 영향이 상대적으로 크다는 가능성을 시사한다.

Table 6. XGBoost gap prediction performance

target	R ²	RMSE	MAE
Calender 2 DS GAP	0.9866	0.1039	0.0637
Calender 2 OS GAP	0.9424	0.0865	0.0582
Calender 3 DS GAP	0.9317	0.1182	0.0729
Calender 3 OS GAP	0.8265	0.1269	0.0876
Calender 4 DS GAP	0.9506	0.1224	0.0681
Calender 4 OS GAP	0.8497	0.1332	0.0873
Calender 5 DS GAP	0.8542	0.1897	0.0956
Calender 5 OS GAP	0.8970	0.1229	0.0706
Calender 6 DS GAP	0.9967	0.2693	0.1031
Calender 6 OS GAP	0.9964	0.2832	0.1247

**Figure 8.** XGBoost gap prediction performance graph (R²).

4.3 간극에 대한 공정 변수 중요도 분석

최종 선정된 XGBoost 기반 다중 출력 회귀 모델에 대해, 간극(GAP) 예측에 영향을 미치는 공정 변수의 상대적 중요도를 분석하였다. XGBoost는 각 입력 피처가 분할 시 손실 감소에 기여한 정도를 바탕으로 피처 중요도(feature importance)를 산출할 수 있으며, 본 연구에서는 학습이 완료된 모델에 대해 모든 트리와 노드 분할 정보를 집계하여 중요도를 계산하였다. 다중 출력 구조의 특성을 반영하기 위해, 각 GAP 타겟에 대해 개별적으로 산출된 중요도를 평균하여 전체 GAP에 대한 통합 중요도를 도출하였다.

단, 본 연구의 피처 중요도는 모델 예측에 대한 상대적 기여도를 나타내는 통계적 지표이며, 변수와 GAP 간 인과관계(causality)를 직접 의미하지는 않는다. 변수 중요도 결과는 공

정 이해를 위한 탐색적 인사이트로 해석된다.




Figure 9. Graph of Calculated Variable Importance Averages by Gap.

한편, 앞선 2절에서 상대적으로 예측 성능이 낮았던 Calender3/4 OS 및 Calender5 DS/OS GAP의 경우, 중요도 상위 변수 구성이 다른 GAP과 일부 상이하게 나타났다. 이는 해당 구간에 대해 모델이 충분히 설명하지 못하는 외란 요인이나 미측정 공정 변수의 영향이 존재할 가능성을 보여준다. 예를 들어 롤 정렬 오차, 롤 표면 상태, 소재 유입 조건 등의 기계적, 재료적 요인이 추가로 작용할 수 있으며, 이러한 요인을 계측하거나 모델에 반영할 경우 예측 성능 개선 여지가 있을 것으로 판단된다.

요약하면, 변수 중요도 분석을 통해 건식 전극 롤투를 캘린더 공정에서 간극 변동에 민감하게 작용하는 공정 인자를 정량적으로 도출할 수 있었으며, 이는 향후 간극 제어 로직 설계, 운전 조건 최적화, 센서 배치 전략 수립 등 공정 개선 활동에 기초 자료로 활용될 수 있다.

5. 결론 및 향후 연구

5.1 요약 및 결론

본 연구에서는 이차전지 건식 전극 롤투를 캘린더 공정을 대상으로, 다단 롤 간극(GAP)을 동시에 예측하기 위한 다중 출력 회귀 기반 예측 모델을 개발하였다. Calender 1~6 구간에서 계측된 속도(SPD), 롤 온도(TEMP), 롤 압력(Pressure), 장력(Tension) 등의 공정 로그로부터 총 2,912개 샘플을 수집하였으며, 33개의 공정 변수를 입력으로, Calender 2~6의 OS/DS GAP 센서 10개를 동시에 출력으로 예측하는 문제로 정식화하였다. 데이터 전처리 과정에서는 수치형 변환 및 스케일 정규화를 포함한 전처리 파이프라인을 구성하여 학습 안정성과 일반화 성능을 확보하였다.

모델링 측면에서는 다중 선형 회귀(MLR), 랜덤포레스트(RandomForestRegressor), XGBoostRegressor에 더해, 신경망 기반 회귀 모델인 MLPRegressor까지 포함하여 비교 실험을 수

행하였다. 모든 모델은 동일한 교차검증 분할 조건에서 MultiOutputRegressor 기반의 다중 출력 예측 구조로 확장하여 평가하였다. 5-fold 교차검증 결과, 선형 기반 MLR은 평균 R^2 약 0.92 수준으로 간극의 전반적인 추세를 설명하였으나, 공정 변수 간 비선형 상호작용을 충분히 반영하지 못해 RMSE와 MAE 측면에서 상대적으로 큰 오차를 보였다. 트리 기반 배경 앙상블인 RandomForest는 평균 R^2 약 0.97로 성능이 크게 향상되었고, 부스팅 기반 트리 앙상블인 XGBoost는 평균 R^2 약 0.994와 가장 낮은 RMSE 및 MAE를 기록하여 가장 우수한 예측 성능과 fold 간 편차가 작은 안정적인 일반화 성능을 나타냈다.

한편 MLPRegressor는 비선형 근사 능력을 갖는 딥러닝 기반 모델이지만, 공정 로그와 같이 스케일 차이가 존재하고 표본 수가 제한적인 환경에서는 학습 안정성이 저하되거나 하이퍼파라미터에 따른 성능 변동이 커질 수 있다. 이에 본 연구에서는 입력(X) 표준화에 더해, 타깃(GAP)별 스케일 차이를 완화하기 위한 타깃(Y) 표준화(Y-scaling)를 적용하고, 제한적 범위의 하이퍼파라미터 탐색(Optuna)을 통해 은닉층 구조, 학습률, 정규화 계수 등을 조정된 MLP(Y-Scaled, Tuned)도 함께 비교하였다. 그럼에도 불구하고 전반적인 성능은 트리 기반 앙상블 모델(RandomForest, XGBoost)에 미치지 못했으며, 특히 XGBoost가 본 데이터셋에서 가장 높은 예측 정확도와 안정성을 제공하는 최종 후보 모델임을 재확인하였다.

XGBoost 모델을 중심으로 GAP별 예측 성능을 분석한 결과, Calender2 DS, Calender4 DS, Calender6 DS/OS 등 일부 구간은 R^2 가 0.95 이상으로 매우 높은 예측력을 보인 반면, Calender3/4 OS, Calender5 DS/OS 구간은 상대적으로 낮은 R^2 를 보이며 예측 난이도가 높은 구간으로 나타났다. 나아가 변수 중요도 분석을 통해 간극 변동에 크게 기여하는 핵심 공정 변수(라인 속도, 롤 압력, 롤 온도, 장력 등)를 정량적으로 도출함으로써, 간극 변화 특성을 데이터 기반으로 해석할 수 있음을 확인하였다.

요약하면, 본 연구는 건식 전극 롤투를 캘린더 공정에서 실제로 수집된 다중 공정 데이터에 기반하여 Calender 2~6 구간의 OS/DS GAP 10개를 고정밀로 예측하는 프레임워크를 제시하고, 머신러닝(MLR, RandomForest, XGBoost)과 신경망(MLP) 모델을 동일한 검증 조건에서 비교하여 XGBoost의 우수성과 안정성을 실증하였다. 또한 성능 비교와 변수 중요도 분석을 통해 공정 인사이트를 도출함으로써, 향후 가상 간극 센서 구현 및 데이터 기반 간극 제어 전략 수립에 활용 가능한 기반을 제공한다.

5.2 기대 효과

- (1) 공정 변수만으로 Calender 2~6 구간의 OS/DS 간극 10개를 동시에 고정밀($R^2 \approx 0.994$)로 예측함으로써, 센서 미부착 구간 또는 측정 공백을 모델로 보완하는 가상 GAP 센서(virtual GAP sensor)로 활용될 수 있다. 이를 통해 라

인 전체 간극 상태를 실시간으로 추정하고, 간극 이상 징후를 조기에 감지하는 공정 모니터링 체계 구축이 가능하다(Shardt *et al.*, 2018; Perera *et al.*, 2023).

- (2) 간극 편차는 최종 전극 두께, 밀도, 공극률 등 핵심 품질 지표에 직접적인 영향을 미치는 주요 원인이다. 제안 모델을 통해 간극 변동을 사전에 예측함으로써, 불량 발생 이전에 공정 조건을 선제적으로 조정하거나 경보를 발생시킬 수 있는 기반을 제공한다. 이는 결과적으로 두께 편차 및 불량을 감소, 품질 분포 안정화에 기여할 것으로 기대된다.
- (3) 기존에는 다수의 공정 변수가 비선형적으로 연계된 간극을 작업자의 경험과 감각에 의존하여 조정하는 한계가 존재하였다. 본 연구의 모델은 공정 변수 변화에 따른 간극 반응을 수치적으로 제시하므로, 작업자 개인 경험 의존도를 낮추고 표준화된 데이터 기반 공정 제어 체계로의 전환을 뒷받침할 수 있다.
- (4) GAP별 예측 성능 분석에서 Calender3/4 OS, Calender5 DS/OS 등 일부 구간의 예측 정확도가 상대적으로 낮게 나타나, 외란 및 노이즈 변수 영향이 큰 구간을 식별할 수 있었다. 이는 해당 구간을 우선적인 공정 개선 대상 또는 추가 센서 부착 후보 지점으로 설정하는 등 공정 개선 우선순위 도출에 직접적으로 활용될 수 있다.
- (5) XGBoost 기반 변수 중요도 분석을 통해 간극 변화에 크게 기여하는 핵심 공정 인자(라인 속도, 롤 압력, 롤 온도, 장력 등)를 정량적으로 도출함으로써, 간극 변화 메커니즘을 데이터 기반으로 해석할 수 있다. 이러한 결과는 향후 전식 전극 롤투를 캘린더 공정의 최적 운전 조건 탐색, 제어 변수 선정, 공정 설계 및 개선 전략 수립에 참고 지표로 활용될 수 있을 것이다.

5.3 향후 연구 방향

향후 연구에서는 먼저, 간극 변동에 대한 시간적 동특성 반영이 필요하다. 본 논문에서 사용한 공정 로그는 시간 순서대로 기록된 시계열 데이터이지만, 모델링 단계에서는 각 시점을 독립 샘플로 간주하여 정적 다중 출력 회귀 모델을 구성하였다. 다시 말해, 롤 간극이 이전 시점의 운전 조건과 하중 이력에 의해 영향을 받는 동적 특성은 모델 구조에 명시적으로 반영되지 않았다.

따라서 공정 데이터를 시계열 형태로 재구성하고, 일정 길이의 과거 구간 $[t-k, \dots, t]$ 을 입력으로 사용하는 LSTM, Temporal Convolution, 시계열용 Transformer 등 순차 모델을 적용함으로써, 이력 효과와 동적 거동을 함께 학습하는 방향으로 확장할 필요가 있다. 또한 현재 데이터셋에는 속도, 압력, 온도, 장력 등 주요 공정 변수 위주로만 포함되어 있으므로, 롤 정렬 상태, 롤 표면 조도, 소재 두께 및 물성, 환경 조건 등 추가적인 기계 및 재료, 환경 변수를 통합한다면, 특히 예측 난이도

가 높게 나타난 Calender3/4 OS 및 Calender5 DS/OS 구간에서 모델의 예측 성능과 설명력을 동시에 향상시킬 수 있을 것으로 기대된다.

다음으로, 본 연구에서 제안한 GAP 예측 모델을 실제 공정 제어 및 디지털 트윈 기반 연구 측면에서 고도화할 계획이다. 우선 학습된 모델을 실제 제어 시스템이나 엣지 컴퓨팅 장비(산업용 PC, 임베디드 GPU 모듈 등)와 연계하여, 온라인 간극 모니터링 및 간극 제어 보조 기능으로 구현 및 검증하는 실증 연구가 요구된다. 더 나아가 롤투를 캘린더 장비의 기계와 공정 특성을 반영한 디지털 트윈(digital twin)을 구축하고, 본 연구의 간극 예측 모델을 디지털 트윈 환경에 내장하여 다양한 운전 조건, 외란 시나리오, 제어 로직을 가상 실험하는 연구를 수행할 계획이다. 이를 통해 실제 공정에 부담을 주지 않고도 간극 제어 전략과 공정 최적화 방안을 사전에 검증할 수 있으며, 공정 전반에 걸친 데이터 기반 품질 예측 및 가상 센서 기술로 발전시키는 것이 향후 중요한 연구 방향이 될 것이다(Rasheed *et al.*, 2020; Manoharan *et al.*, 2025).

참고문헌

- Borchani, H., Varando, G., Bielza, C., and Larrañaga, P. (2015), A Survey on Multi-output Regression, *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, **5**(5), 216-233.
- Breiman, L. (2001), Random Forests, *Machine Learning*, **45**(1), 5-32.
- Chen, T. and Guestrin, C. (2016), XGBoost: A Scalable Tree Boosting System, *Proceeding 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD)*, 785-794.
- Duquesnoy, M., Shodieva, A., Arcelus, O., Chouchane, M., Li, J., and Franco, A. A. (2020), Data-Driven Assessment of Electrode Calendering Process by Combining Experimental Results, In Silico Mesosstructures Generation and Machine Learning, *Journal of Power Sources*, **480**, 229103.
- Gyulai, A., Bauer, W., and Ehrenberg, H. (2023), Dry Electrode Manufacturing in a Calender: The Role of Powder Premixing for Electrode Quality and Electrochemical Performance, *ACS Applied Energy Materials*, **6**(10), 5122-5134.
- Haghi, S., Hidalgo, M. F. V., Niri, M. F., Daub, R., and Marco, J. (2023), Machine Learning in Lithium-Ion Battery Cell Production: A Comprehensive Mapping Study, *Batteries & Supercaps*, **6**(7), e202300046.
- Jin, W., Song, G., Yoo, J.-K., and Kim, J. (2024), Advancements in Dry Electrode Technologies: Towards Sustainable and Efficient Battery Manufacturing, *ChemElectroChem*, **11**(17), e202400288.
- Lu, Y., Zhao, C. Z., Yuan, H., Hu, J. K., Huang, J. Q., and Zhang, Q. (2022), Dry Electrode Technology, the Rising Star in Solid-State Battery Industrialization, *Matter*, **5**(3), 876-898.
- Manoharan, A., Chong, J. J., Choong, Z. J., Lambert, S., Gupta, R. K., Chandra, D., Jain, A., Rao, A., and Sharma, A. (2025), Optimizing Lithium-Ion Battery Manufacturing with Digitalization and AI-Driven Frameworks, *International Journal of Advanced Manufacturing Technology*, doi: 10.1007/s00170-025-17129-8.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V.,

- Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011), Scikit-learn: Machine Learning in Python, *Journal of Machine Learning Research*, 12(85), 2825-2830.
- Perera, Y. S., Ratnaweera, D. A. A. C., Dasanayaka, C. H., and Abeekoon, C. (2023), The Role of Artificial Intelligence-Driven Soft Sensors in Advanced Sustainable Process Industries: A Critical Review, *Engineering Applications of Artificial Intelligence*, **121**, 105988.
- Rasheed, A., San, O., and Kvamsdal, T. (2020), Digital Twin: Values, Challenges and Enablers from a Modeling Perspective, *IEEE Access*, **8**, 21980-22012.
- Schmid, L., Gerharz, A., Groll, A., and Pauly, M. (2023), Tree-based Ensembles for Multi-output Regression: Comparing Multivariate Approaches with Separate Univariate Ones, *Computational Statistics & Data Analysis*, **179**, 107628.
- Schreiner, D., Klinger, A., and Reinhart, G. (2020), Modeling of the Calendering Process for Lithium-Ion Batteries with DEM Simulation, *Procedia CIRP*, **93**, 149-155.
- Schreiner, D., Lindenblatt, J., Daub, R., and Reinhart, G. (2023), Simulation of the Calendering Process of NMC-622 Cathodes for Lithium-Ion Batteries, *Energy Technology*, **11**(5), 2200442.
- Schumm, B., Dupuy, A., Lux, M., Girsule, C., Dörfler, S., Schmidt, F., Fiedler, M., Rosner, M., Hippauf, F., and Kaskel, S. (2025), Dry Battery Electrode Technology: From Early Concepts to Industrial Applications, *Advanced Energy Materials*, 15(24), 2406011.
- Shardt, Y. A. W., Mehrkanon, S., Zhang, K., Yang, X., Suykens, J. A. K., Ding, S. X., and Peng, K. (2018), Modelling the Strip Thickness in Hot Steel Rolling Mills Using Least-Squares Support Vector Machines, *Canadian Journal of Chemical Engineering*, **96**(1), 171-178, doi: 10.1002/cjce.22956.
- Shodiev, A., Duquesnoy, M., Arcelus, O., Chouchane, M., Li, J., and Franco, A. A. (2021), Machine Learning 3D-Resolved Prediction of Electrolyte Infiltration in Battery Porous Electrodes, *Journal of Power Sources*, **511**, 230384.
- Spyromitros-Xioufis, E., Tsoumakas, G., Groves, W., and Vlahavas, I. (2016), Multi-target Regression via Input Space Expansion: Treating Targets as Inputs, *Machine Learning*, **104**(1), 55-98.
- Wang, P., Qu, H., Zhang, Q., Xu, X., and Yang, S. (2023), Production Quality Prediction of Multistage Manufacturing Systems Using Multi-Task Joint Deep Learning, *Journal of Manufacturing Systems*, **70**, 48-68.
- Xu, D., Shi, Y., Tsang, I. W., Ong, Y.-S., Gong, C., and Shen, X. (2019), A Survey on Multi-output Learning, *arXiv preprint*, arXiv:1901.00248.
- Yan, H., Sergin, N. D., Brenneman, W. A., Lange, S. J., and Ba, S. (2021), Deep Multistage Multi-Task Learning for Quality Prediction of Multistage Manufacturing Systems, *Journal of Quality Technology*, **53**(5), 526-544.
- Yu, J., Kim, B., and Yoo, Y. (2025), Dry Electrode Processing for Lithium-Ion Battery Cathodes and Anodes: Materials, Fabrication Strategies, and Future Outlook, *Advanced Materials Technologies*, **10**(22), e01420.
- Zhang, Y. S., Courtier, N. E., Zhang, Z., Liu, K., Bailey, J. J., Boyce, A. M., Richardson, G., Shearing, P. R., Kendrick, E., and Brett, D. J. L. (2022), A Review of Lithium-Ion Battery Electrode Drying: Mechanisms and Metrology, *Advanced Energy Materials*, 12(2), 2102233.

저자소개

문장현 : 경운대학교 소프트웨어학과에서 2024년 학사를 졸업하고, 2025년부터 경운대학교 산업공학AI융합학과 석사과정에 재학 중이다. 연구분야는 AI기반 산업 공정 최적화 및 제어이다.

유홍석 : 경북대학교 컴퓨터공학과에서 2005년 학사, 전자전기 컴퓨터학부에서 2007년 석사학위를 취득하고, 동 대학교에서 2014년에 컴퓨터공학 박사학위를 취득하였다. 현재, 경운대학교 소프트웨어학부 교수로 재직하고 있고 연구분야는 AI 기반 제어 최적화 및 공간 지능이다.

장재석 : 경북대학교 컴퓨터공학과에서 2007년 학사, 전자전기 컴퓨터학부에서 2009년 석사학위를 취득하고, 동 대학교에서 컴퓨터공학 박사학위를 취득하였다. 경북대학교 강의전담교수를 역임하였고, 2025년부터 경운대학교 소프트웨어학부 교수로 재직하고 있다. 연구분야는 센서융합 자율주행, VLM기반 자율형 감시, VLA기반 매니플레이터 제어이다.