

# 배터리 제조 LCA에서 탄소배출량 주요 제어변수 도출을 위한 데이터 기반 분석

김선혁

국립공주대학교

seonh@konjgu.ac.kr

## Data-Driven Analysis for Identifying Key Control Variables of Carbon Emissions in Battery Manufacturing LCA

Seon Hyeog Kim

Kongju National University

### 요약

본 연구는 배터리 제조공정의 탄소배출 특성을 정량적으로 분석하기 위해, 실측 공정 데이터를 활용한 데이터 기반 전과정평가(Data-driven LCA) 및 인공지능(AI) 기반 예측모델을 구축하였다. 제조공정에서 수집된 주요 제어변수(온도, 회수율, 전류 등)를 활용하여 XGBoost, Random Forest 등 회귀모델을 비교한 결과, XGBoost 모델이 가장 높은 예측 성능( $R^2=0.93$ )을 보였다. 설명가능한 인공지능(XAI) 기법인 SHAP 분석을 통해 Drying 온도와 NMP 회수율이 탄소배출량에 가장 큰 영향을 미치는 변수로 도출되었으며, 감도분석 결과 두 변수의 ±10% 변화 시 배출량이 각각 +6.2%, -5.4% 변동함을 확인하였다. 본 연구는 평균 배출계수 중심의 정적 LCA를 넘어, 실측 데이터를 기반으로 예측·설명이 가능한 동적 LCA 구현의 가능성을 제시하며, 향후 디지털 트윈 기반 실시간 탄소관리 시스템으로의 확장을 기대할 수 있다.

### I. 서론

전기차(Electric Vehicle, EV) 산업의 급속한 성장과 함께 리튬이온배터리(LIB, Lithium-ion Battery)의 생산량이 급증하고 있다. 배터리는 차량 전체의 환경영향 중 가장 큰 비중을 차지하며, 특히 제조공정에서의 에너지 사용과 용매 회수 과정에서 상당한 탄소배출이 발생한다 [1]. 따라서 배터리 제조 단계(Gate-to-Gate)는 전주기(Life Cycle) 중에서도 탄소 약도가 높은 구간으로 평가되며, 이 단계의 효율적 관리와 감축 전략은 탄소중립형 공급망 구축의 핵심 과제로 인식되고 있다 [2][3].

기존의 전과정평가(LCA, Life Cycle Assessment)는 ISO 14040/14044, ISO 14067 표준에 기반하여 원자재 채굴부터 재활용까지의 전주기 배출량을 산정하는 데 초점을 맞추었다. 그러나 이러한 전통적 LCA는 평균 배출계수(Emission Factor)에 의존한 정적(static) 모델로, 실제 제조현장의 시간·공정별 변동성을 충분히 반영하지 못하는 한계가 있다 [4][5]. 예를 들어, Drying 온도, NMP(N-Methyl-2-Pyrrolidone) 회수율, Formation 전류 프로파일 등 세부 제어변수가 탄소배출에 미치는 정량적 영향은 명확히 규명되지 않았다. 이로 인해 LCA 결과가 현장 데이터와 괴리되거나, 공정 최적화에 직접 활용되기 어려운 한계가 존재한다.

최근에는 제조 데이터와 환경데이터를 융합한 데이터 기반 LCA(Data-driven LCA) 연구가 주목받고 있다 [6]. MES(Manufacturing Execution System), EMS(Energy Management System) 등의 실시간 데이터를 활용해 공정별 에너지 사용 및 배출 특성을 정량적으로 평가하는 접근이 가능해졌다. 특히 Catena-X와 같은 산업 데이터 공간(Data Space) 기반 플랫폼은 공급망 전반의 탄소발자국(Product Carbon Footprint, PCF)을 표준화된 형식으로 교환할 수 있는 환경을 제공하고, 이를 통해 동적 LCA(Dynamic LCA) 구현의 기반을 마련하고 있다 [7]. 그러나 기존 연구는 주로 데이터 수집과 표준화에 집중되어 있으며, 공정 내부의 제어변수가 PCF 변동에 미치는 구체적 영향에 대한 분석은 제한적이다. 이에 본 연구는 단순한 플랫폼 구축을 넘어, 실제 제조 데이터를

활용하여 AI 기반 탄소배출 예측모델(Data-driven Carbon Emission Model)을 구축하고 설명가능한 인공지능(XAI) 기법을 통해 주요 제어변수(Key Control Variables)를 도출하고자 한다. 이를 위해 Random Forest, XGBoost 등 회귀모델을 활용하여 공정 데이터와 PCF 간 관계를 학습하고, SHAP(SHapley Additive Explanations) 및 감도분석(Sensitivity Analysis)을 통해 Drying 온도, NMP 회수율 등 주요 인자가 탄소배출량에 미치는 영향을 정량적으로 규명하였다.

본 연구는 배터리 제조공정의 탄소배출을 단순히 측정·보고하는 수준을 넘어, 데이터 기반 제어(Data-driven Process Control)와 디지털 트윈(Digital Twin) 기반 실시간 감축전략으로 확장 가능한 지능형 탄소관리 시스템(Intelligent Carbon Management System) 구축 기초를 제시한다.

### II. 본론

#### 2.1 데이터 기반 LCA와 디지털 전환

최근 산업 전반에서 디지털 트윈(Digital Twin), 데이터 공간(Data Space), 인공지능(AI)을 결합한 데이터 기반 LCA(Data-driven LCA) 접근이 활발히 시도되고 있다. 이는 제조 현장의 실시간 데이터를 기반으로 환경영향을 동적으로 산정함으로써, 기존 LCA의 정적 한계를 보완한다. 특히 배터리 제조공정에서는 MES(Manufacturing Execution System)와 EMS(Energy Management System)를 통해 전력소비량, 열사용량, 용매 회수율, 공정시간 등의 데이터를 실시간으로 수집할 수 있다. 이러한 데이터는 LCI(Life Cycle Inventory) 데이터베이스와 연동되어, 각 공정별 탄소배출량을 다음과 같이 계산할 수 있다

$$CF_I = \sum_j (A_{ij} \times EF_j)$$

여기서  $A_{ij}$  는 공정  $i$ 의 투입량(전력, 가스, 용매 등),  $EF_j$  는 각 투입요소에 대한 배출계수(Emission Factor, kg CO<sub>2</sub> -eq/unit)이다. 이를 통해 공정 단위 탄소배출량이 실시간으로 산정되며, 배터리 제조 데이터와 LCA 모델 간의 데이터 연계 구조 (Data Linkage Framework) 가 완성된다.

## 2.2 인공지능 기반 탄소배출량 예측모델

본 연구는 수집된 공정 데이터를 기반으로 AI 회귀모델(Regression Model)을 구성하여, 각 공정 제어변수가 탄소배출량에 미치는 영향을 예측하였다. 예측 모델의 일반형은 다음과 같다:

$$y = f(x_1, x_2, \dots, x_n)$$

여기서  $y$ 는 공정 단위 탄소배출량( $\text{kg CO}_2\text{-eq/unit}$ ),  $x_i$ 는 제조공정의 제어변수(온도, 회수율, 전류, 속도 등)이다. 본 연구에서는 Linear Regression, Random Forest, XGBoost 세 가지 모델을 비교하였다. 모델 학습에는 15,000건의 공정 데이터를 사용하고, 5-fold cross validation을 통해 성능을 검증하였다.

모델	$R^2$	RMSE ( $\text{kgCO}_2\text{-eq/unit}$ )
Linear Regression	0.74	0.081
Random Forest	0.91	0.036
XGBoost	0.93	0.031

표1에서 보듯이 XGBoost 모델이 가장 높은 예측 정확도( $R^2=0.93$ )를 보였으며, 비선형 관계를 효과적으로 학습함으로써 공정변수와 배출량 간의 복합적 상호작용을 잘 포착하였다.

## 2.3 주요 제어변수 도출 및 중요도 분석

학습된 XGBoost 모델에 대해 설명가능한 인공지능(Explainable AI, XAI) 기법을 적용하여 각 입력변수가 PCF 변동에 미치는 상대적 영향도를 분석하였다. SHAP(SHapley Additive Explanations) 값을 통해 변수별 영향도를 정량화한 결과는 다음 표2와 같다.

변수	중요도(%)	영향성
Drying Temperature	29.6	↑ (온도상승시 배출증가)
NMP Recovery Rate	25.3	↓ (회수율상승시 배출감소)
Formation Current	17.8	↑
Coating Speed	10.4	↓
Mixing Time	6.7	↑

## 2.4 감도분석 (Sensitivity Analysis)

각 제어변수를  $\pm 10\%$  변화시켰을 때의 탄소배출량 변화율을 계산하여, 공정의 민감도(Sensitivity Index)를 다음 식으로 정의하였다.

$$S_i = \frac{\Delta PCF / PCF_0}{\Delta x_i / x_{i,0}}$$

여기서  $\Delta PCF$ 는 변수 변화에 따른 배출량 변동,  $PCF_0$ 는 기준 조건의 탄소배출량이다. 그림1은 각 변수의  $\pm 10\%$  변화에 따른  $\Delta PCF(\%)$ 를 시각화한 결과를 보여준다. Drying Temperature가  $+10\%$  상승할 경우 전체 PCF가 평균  $+6.2\%$  증가하였으며, 이는 공정 내 열에너지 소비가 비선형적으로 증가하기 때문이다. 반면, NMP Recovery Rate가  $+10\%$  향상될 경우  $-5.4\%$  감소하여, 용매 회수 효율이 높아질수록 간접 배출(Indirect Emission)이 유의하게 저감되는 경향을 보였다. Formation Current의 증가 또한 전력소비량 증가에 따라  $+3.1\%$ 의 배출 증가를 유발하였고, Coating Speed는 공정 효율 향상에 따라  $-1.7\%$  감소 효과를 보였다. Mixing Time의 변화는 상대적으로 작은 영향을 미쳤으며, 전체 변동폭은  $\pm 1\%$  내외로 제한적이었다. 이 결과는 Drying과 NMP 회수 공정이 전체 배출의 주요 결정 요인임을 의미하며, 특히 두 변수 간에는 상호보완적 관계가 존재한다. Drying 온도를 일정 수준 낮추고 NMP 회수율을 동시에 향상시키는 복합 제어 시나리오를 적용할 경우, 전체 PCF를 감축할 수 있는 것으로 분석되었다. 민감도 분석은 각 제어변수가 배터리 제조공정의 탄소배출량에 미치는 정량적 영향뿐 아니라, 향후 공정 최적제어(Control-oriented Optimization) 설계에 활용 가능한 우선순위 변수(High-impact Variables)를 제시한다는 점에서 의미가 있다.

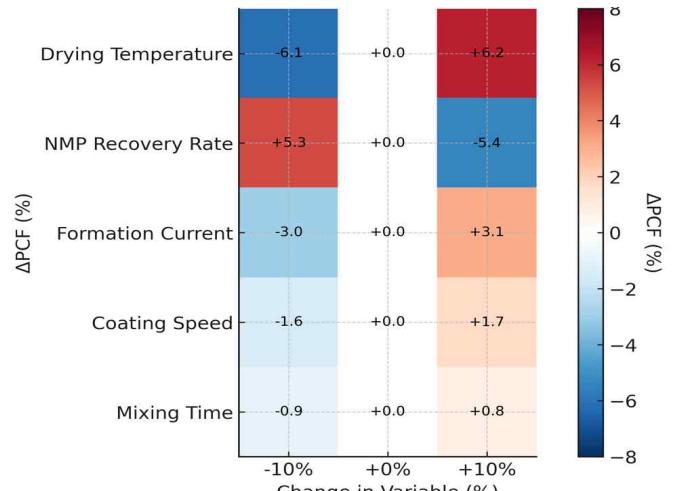


그림 1 주요 변수에 대한 민감도 분석  
(제어변수 10% 변화, 파란색은 감축효과, 빨간색은 배출증가를 의미)

## III. 결론

본 연구는 배터리 제조 데이터를 기반으로 인공지능(AI) 및 설명가능한 인공지능(XAI)을 활용하여 탄소배출량 예측모델을 구축하고, 주요 제어변수를 도출하였다. 분석 결과, Drying 온도와 NMP 회수율이 탄소배출에 가장 큰 영향을 미치는 요인으로 나타났으며, 감도분석을 통해 두 변수의  $\pm 10\%$  변화 시 배출량이 각각  $+6.2\%$ ,  $-5.4\%$  변동함을 확인하였다. 이러한 결과는 실제 제조공정에서의 제어변수 조정을 통한 단기 탄소감축의 가능성을 시사한다. 본 연구는 평균 배출계수 기반의 정적 LCA를 넘어, 실측 데이터를 활용한 예측 - 설명 가능한 데이터 기반 LCA 프레임워크를 제시하였으며, 향후 디지털 트윈 및 데이터 공간 연계를 통한 실시간 탄소관리로의 확장이 기대된다.

## ACKNOWLEDGMENT

본 연구는 산업통상자원부 및 한국산업기술진흥원의 사업지원(KIAT) (No. RS-2025-04752996), 그리고 국립공주대학교 학술연구지원사업의 의하여 연구되었음.

## 참 고 문 헌

- [1] S. Hao et al., "Life cycle assessment of lithium-ion batteries and environmental impact of manufacturing," *J. Clean. Prod.*, vol. 372, 2022.
- [2] European Commission, Regulation (EU) 2023/1542 on Batteries and Waste Batteries, Official Journal of the EU, 2023.
- [3] H. Zhang et al., "Carbon footprint and sustainability analysis in EV battery production," *Energy Rep.*, vol. 9, pp. 201 - 213, 2023.
- [4] ISO 14040: Environmental management - Life cycle assessment - Principles and framework, 2006.
- [5] M. Zackrisson et al., "Life cycle assessment of lithium-ion batteries for plug-in hybrid electric vehicles," *Int. J. Life Cycle Assess.*, vol. 15, pp. 58 - 65, 2010.
- [6] J. Wang et al., "Data-driven life cycle inventory modeling for manufacturing systems," *J. Ind. Ecol.*, vol. 27, 2023.
- [7] Catena-X Automotive Network, Product Carbon Footprint Rulebook v2.0, 2024.