

기계학습 기반 연속전지 Spot 용접 품질 예측 모델

(Machine Learning-based Method on Spot Welding Quality Prediction for Lead-Acid Batteries)

박재현*, 고창완**, 박진*, 정영선***

(Jai Hyun Park, Changwan Ko, Jin Park, Young-Seon Jeong)

요약

본 연구는 연속전지 생산 공정 중 중요한 단계인 Spot 용접에서 발생할 수 있는 품질 문제를 사전에 예측하기 위해 예측 모델을 구축하고, 다양한 기계학습 알고리즘의 성능을 비교하는 데 목적이 있다. 실제 제조 환경에서 확보한 전류, 사이클, 압력과 같은 공정 변수와 검사 결과를 변수로 사용하였으며, 파단 강도와 단면 상태를 품질 기준으로 설정하였다. 실험 결과, 공정 변수만을 활용한 모델보다 검사 데이터를 포함한 모델이 더 높은 예측 정확도를 보였으며, 이는 기존 검사 체계에서 발생할 수 있는 판정 신뢰도 저하 문제를 보완할 수 있는 가능성을 확인할 수 있었다. 본 연구는 배터리 제조 공정에서 확보한 실제 데이터 기반 예측 모델의 적용 가능성을 제시하였으며, 향후 Spot 용접 품질 관리의 고도화와 품질 안정화에 기여할 수 있는 방향을 제안한다.

■ 중심어 : 연속전지 ; Spot 용접 ; 기계학습 ; 품질 예측 ; 예측 모델링

Abstract

This paper develops a predictive model to identify potential quality issues in the spot welding process, a key stage in lead-acid battery manufacturing, and compares the performance of several machine learning algorithms. Actual production data—including current, cycle count, pressure, and inspection results—were used as input features, while fracture strength and weld cross-sectional condition served as quality indicators. Models that included inspection data achieved higher prediction accuracy than those using only process variables, indicating improved reliability in addressing misclassification issues. The findings highlight the applicability of real battery manufacturing data for machine learning-based quality prediction and provide direction for improving spot welding quality control and process stability.

■ keywords : Lead-Acid Battery ; Spot Welding ; Machine Learning ; Quality Prediction ; Predictive Modeling

I. 서론

최근 들어 리튬이온 전지의 높은 에너지 밀도와 출력, 긴 수명과 같은 이점으로 인해 배터리 산업의 중심으로 자리잡고 있다[1]. 그러나 현실적으로는 연속전지가 가지는 단순한 구조, 낮은 제조 비용, 안정적인 출력 등의 강점으로 인해 여전히 전 세계적으로 생산 및 사용되고 있으며,

수요 또한 유지되고 있다. 연속전지는 UPS, 산업용 전원, 차량 시동용 배터리(SLI), ESS 등 다양한 응용 분야에서 널리 사용되고 있다[2]. 그중에서도 자동차 분야는 최대 활용 영역으로, 연속전지는 시동 기능과 전장 시스템 구동을 담당하는 핵심 전원으로 사용되고 있다[3].

그러나 최근 기후 변화로 인해 고온 환경에서 배터리 운영 조건이 더욱 가혹해지면서, 연속전지의 열화와 고장 발생 가능성이 증가하고 있다.

* 준회원, 전남대학교 산업공학과 석사과정

** 정회원, 전남대학교 산업공학과 박사과정

*** 정회원, 전남대학교 산업공학과 및 아트&디자인 테크놀로지 협동과정 교수

이 연구는 교육부와 한국연구재단이 지원하는 BK21 FOUR 재원으로 전남대학교 대학원의 지역사회 연계 혁신연구 지원사업(G-ROOT)으로부터 지원을 받아 수행된 연구임.

접수일자 : 2025년 12월 23일

수정일자 : 2026년 02월 09일

게재확정일 : 2026년 02월 18일

교신저자 : 정영선 e-mail : young.jeong@jnu.ac.kr

특히 내부 전기 연결을 수행하는 Spot 용접부의 불량은 내부저항 증가, 발열, 심한 경우 팽창 및 파열까지 이어질 수 있는 치명적 요인으로 작용한다. Spot 용접 시 사용하는 팁, 사용되는 재료의 경우 동일한 환경 조건 하에서 이루어지기 때문에 편차가 작지만, 공정 특성상 미세한 공정 변수의 경우 작은 변화에 용접 품질 편차가 발생할 수 있어, 기존 단순 검사 방식만으로는 품질 문제를 완전히 차단하기 어렵다. 특히 고온 환경에서는 Spot 용접 열화 속도가 가속화되기 때문에, 사전 품질 예측과 이상 감지 체계 구축이 더욱 중요해지고 있다.

이에 본 연구는 실제 연속전지 제조공정 중 Spot 용접 공정에서 수집되는 수치형 공정 데이터를 기반으로 기계학습 기반 예측 기법을 활용하여 이상 발생 가능성을 사전에 탐지하는 방법을 제안한다. 이를 위해 공정 변수 및 검사 데이터를 분석하고, 기계학습 기반 이상 탐지 모델을 적용하여 품질 저하 및 불량 발생을 조기에 식별할 수 있는 가능성을 검증한다. 본 연구는 공정 편차와 품질 변동성을 실시간으로 감지함으로써, 제조공정의 신뢰도를 높이고 고온 환경에서도 연속전지 품질을 안정적으로 유지하는데 기여하고자 한다.

본 연구의 구성은 다음과 같이 구성되었다. 제 2장에서는 국내외에서 진행된 선행 연구에 대해 알아본다. 제 3장은 연속전지 Spot 용접 및 용접 품질과 관련된 개념을 설명하고, 제 4장에서는 공정 데이터 수집을 위한 과정과 Spot 용접 품질 예측을 위해 사용되는 기계학습 알고리즘을 설명하고, 품질 평가의 정량적인 기준을 제안한다. 제 5장에서는 기계학습 알고리즘에 따른 Spot 용접 품질 성능을 비교 분석한다. 마지막으로 제 6장에서는 결론 및 향후 연구 방향을 제시한다.

II. 선행연구 고찰

최근 제조 산업에서는 용접 품질을 정량적으로 평가하고 예측 정확도를 높이기 위해 기계학습

(Machine learning) 및 딥러닝(Deep learning) 기반 기술이 활발히 도입되고 있다. 특히 Spot 용접(저항 점 용접, Resistance Spot Welding; RSW)은 공정 조건과 품질 간의 비선형성이 크기 때문에, 데이터 기반 접근법이 전통적인 시험 중심 평가 방식의 대안으로 주목받고 있다.

선행 연구에서는 전류, 용접 시간, 전극 압력, 소재 두께, 도금 유무 등 다양한 공정 변수와 재료 물성을 입력값으로 활용하여, 너깃 크기, 피크 하중, 에너지 흡수량, expulsion 여부 등 주요 품질 지표를 예측하는 모델들이 다수 제안되었다[4]. 딥러닝 기반 예측 구조는 다양한 실험 조건에서도 강도 예측의 정확도를 높였고, 제한된 실험 데이터 환경에서도 일반화 가능한 프레임워크로 확장될 수 있음을 보여주었다.

또한, 용접 공정 중 센서로 수집되는 전류나 저항의 시계열 데이터를 활용하여 용접 상태를 정상, 오픈 회로, 과도한 발열 등으로 자동 분류하는 접근도 제시되었다. 이 경우에는 평균, 표준편차, FFT 계수 등 통계 기반 피처를 추출하여 인공신경망에 학습시키는 방식이 활용되었으며, 실시간 진단 시스템의 기초 기술로 활용 가능성이 확인되었다[5].

이와 함께 공정 설정값과 검사기 측정값을 통합하여 합격/불합격을 예측하는 분류 모델을 적용한 사례도 있으며, 의사결정트리 및 랜덤 포레스트와 같은 기법을 통해 변수 영향도 분석과 함께 설명 가능한 예측 모델 구조가 도입되었다[6].

기존의 선행 연구는 품질 예측의 기초적 기반을 마련하였지만, 검사기 저항값이나 너깃 크기, expulsion 등 중간 특성치를 품질 판단 지표로 활용하였으며, 실제 구조 강도나 단면 상태와의 직접적인 연계는 부족하다. 또한, 검사기 합격 판정과 실제 파단 강도 간 불일치 문제는 거의 다뤄지지 않았으며 오판을 교정할 수 있는 모델 설계가 미흡하다. 그 이외에도 전류나 시간 등 일부 공정 변수 반영하여 모델을 학습하고 있어 실제 현장 핵심 변수인 전류, 싸이클, 압력을 통합

반영한 연구나 다양한 알고리즘의 성능을 비교 분석하여 실제 현장 적용에 적합한 모델을 도출하는 사례도 많지 않다.

이에 본 연구에서는 다양한 예측 기계학습 알고리즘을 이용하여 연속전지 제조공정에서 수집되는 전류, 싸이클, 압력, 검사기 저항값을 입력 변수로 활용하고, 과단강도 시험 및 검사기와 Spot 단면의 판정 여부를 고려한 성능을 비교 분석하고자 한다. 이를 통해, 기존 연구들이 다루지 못했던 검사기 오판 가능성과 공정 내 품질 기준의 이중성을 중심으로, 보다 신뢰도 높은 용접 품질 예측 모델을 제안함으로써, 연속전지 제조현장의 품질관리 효율성과 판단 정확도를 동시에 향상시킬 수 있을 것으로 기대된다.

III. 이론적 배경

1. 연속전지 Spot 용접

Spot 용접은 두 금속을 전극으로 압착한 상태에서 전류를 흘려 발생하는 저항열로 접합하는 방식이며, 연속전지 제조에서 셀 간 스트랩(Strap)을 연결하기 위해 사용되는 핵심 공정이다. 발생하는 열량은 전류, 싸이클, 압력에 의해 결정되며 그 관계식은 다음과 같다.

$$Q = I^2 \times R \times t \quad (1)$$

- I : 용접 전류
- R : 접촉 저항(가압시 스트랩의 접촉 면적)
- t : 통전 시간(싸이클)

여기에서 전류는 열 생성에 가장 큰 영향을 미치며, 접촉 저항, 통전 시간과 함께 용융부(Nugget) 형상과 강도를 결정하는 주요 제어 변수로 작용한다[7]. 해당 변수의 경우 용접 품질에 직접적으로 영향을 주는 변수로서, 하나의 변수가 관리 범위를 벗어나 품질의 영향을 주기보다 여러 조건들이 특정한 조건을 만족했을 때, Spot 용접 품질에 큰 영향력을 미치게 된다.

연속전지 Spot 용접은 <그림 1>과 같은 단계

로 진행되며, 전류가 지나치게 크거나 시간이 길면 과용착 또는 Spit-out이 발생할 수 있고, 반대로 부족하면 접합 불량이나 나타날 수 있다. 따라서 안정적인 용접 품질 확보를 위해 세 변수는 단일 제어가 아닌 상호 균형된 조건에서 설정되어야 한다[8].




그림 1. 연속전지 Spot 용접 절차

2. 용접 품질 검사기 원리

연속전지 제조공정에서 Spot 용접부의 접촉 저항은 전체 내부저항과 성능에 직접적인 영향을 미치기 때문에, 이를 정량적으로 측정하는 용접 품질 검사 장비가 사용된다. 검사기는 옴의 법칙($R = V/I$)에 기반하여 용접부에 일정한 전류를 인가하고, 발생한 전압강하를 측정해 저항값을 계산한다. 저항값이 높게 나타날수록 용접 상태가 불완전하거나 용융이 부족했을 가능성이 있으며, 설정된 기준값에 따라 합격 또는 불합격 판정이 이루어진다[9].

IV. 실험 설계

1. Spot 시편 제작

Spot 용접 시편은 실제 연속전지 제조라인에서 사용되는 COS(Cast of Strap)공정과 산업용 Spot 용접 설비(AMADA CY-210)를 활용하여 제작하였다. 스트랩과 전조는 실제 12V 배터리와 동일한 구조로 제작하였으며, 간벽 중앙에 Ø12 펀칭구를 형성하여 Spot 용접이 이루어지도록 하였다.

용접 공정은 전류(8.0~11.0kA), 싸이클(8, 10, 12N), 압력(4.0~4.4kgf/cm²)을 주요 변수로 설정하고, 교차 설계(full factorial) 방식으로 실험 조건을 구성하였다. 이때, N은 싸이클의 횟수를 의미하며, 가압시간(Squeeze)과 유지시간(Hold)은 각각 50N으로 고정하였다.

실제 제조 환경에서 다양한 공정 인자 변화가 용접 품질에 미치는 영향을 평가하기 위해 다양한 조건 조합을 바탕으로 총 974개의 Spot 용접 시편을 제작했으며, 이를 이용하여 Spot 용접 품질 평가 예측을 수행하였다.



그림 2. Spot 강도 측정 절차

2. Spot 품질 평가

가. 용접 품질 검사 데이터

모든 시편은 용접 직후 용접 품질 검사기를 통해 저항값을 측정하였으며, 제조 현장에서 사용 중인 관리 기준($\leq 8.0m\Omega$)에 따라 합격(OK)과 불합격(NG)으로 분류하였다. 해당 데이터는 공정에서 직접 발생하는 운영 데이터로서, 이후 기계학습 모델 분석에서 독립 변수의 하나로 활용하였다.

나. Spot 강도

<그림 2>는 Spot 용접 부위의 기계적 강도를 측정하기 위해 수행된 절차를 보여준다. 각 시편의 Spot 부위를 토크 시험용 형상으로 가공한 후, 디지털 토크렌치를 이용하여 파단 시 최대 토크 값을 측정하였다. 측정된 Spot 강도는 실제 제조 현장에서 적용되고 있는 기준값($\geq 12N \cdot m$)에 따라 OK/NG를 판정하였으며, 이는 용접부의 구조적 신뢰성을 평가하는 핵심 지표로 사용되었다.

다. 용접 단면 상태

용접 단면 상태에 따른 부적합 유형별 감점 기준을 점수화하기 위해, 실제 제조 현장에서 사용하고 있는 관리 기준과 전문가들의 도메인 지식을 기반으로 정량화하였다. <표 1>은 부적합 평가에 사용되는 상태와 감점에 대한 정량적인 수치를 포함하였으며, 최종 점수 기준(≥ 80 점)에 따라 OK/NG로 분류하였다.

표 1. Spot 용접 단면 상태 평가 기준표

단면상태	구분	Level1	Level2	Level3
V-Shape	상태			-
	기준	자국 1개	자국 2개	-
	감점	-5	-10	-
NET	상태			
	기준	수지 3줄 ↓	수지 6줄 ↓	수지 6줄 ↑
	감점	-5	-10	-15
Hole	상태			
	기준	Ø1 이하	Ø3 이하	Ø3 초과
	감점	-5	-10	-20
Shoulder	상태			
	기준	용접면 90% ↑	용접면 80% ↑	용접면 80% ↓
	감점	-10	-30	-50
Cold Welding	상태			
	기준	Ø3 이하	Ø6 이하	Ø6 초과
	감점	-30	-60	-100
Spit Out	상태	-	-	
	기준	-	-	납땜 발생
	감점	-	-	-100

3. 변수 선정 및 예측 모델

본 연구에서는 Spot 용접 품질 예측을 위해 독립 변수 구성에 따라 두 가지 그룹으로 나누어 연구를 수행하였다. A그룹은 공정 설정값(전류, 싸이클, 압력)만을 독립 변수로 사용하였고, B그룹은 동일 변수에 용접 품질 검사 변수를 추가하여, 독립 변수 확장이 예측 성능에 미치는 영향을 비교하였다. 종속 변수는 Spot 강도와 단면 상태 평가를 통합한 최종 품질 판정으로 구성하였다. 이때, 두 지표 중 하나라도 NG이면 최종 품질을 NG로 분류하였다. 연구에 사용한 두 가지 독립 변수 그룹과 종속 변수에 대한 내용은 <표 2>에 나타내었다.

표 2. 독립 변수 그룹과 종속 변수

독립 변수		종속 변수
A그룹	B그룹	
전류(Current), 싸이클(Cycle), 압력(Pressure)	전류(Current), 싸이클(Cycle), 압력(Pressure), 용접 품질 검사(Inspection)	최종 품질 판단 결과 (FinalResult)

본 실험에는 다양한 분야에서 사용되는 대표적인 기계학습 기법인 로지스틱 회귀 분석 (Logistic Regression; LR), 의사결정 나무 (Decision Tree; DT) [10], 랜덤 포레스트 (Random Forest; RF) [11], 익스트림 그래디언트 부스팅(eXtreme Gradient Boosting; XGB) [12], 다중 퍼셉트론(Multi Layer Perceptron; MLP) [13], K-최근접 이웃(K-Nearest Neighbor; KNN) [14], 서포트 벡터 머신 (Support Vector Machine; SVM) [15]을 이용해 모델 간 성능을 비교 분석하였다. 해당 모델은 다양한 분야에서 사용되는 대표적인 분류 모델로, <표 3>에 제시된 모델별 특징을 바탕으로 Spot 용접 품질 예측을 위해 사용하였다.

표 3. 모델 별 특징 설명

모델	모델 특징
LR	선형 관계 가정 하의 베이스라인 모델, 입력 변수가 종속 변수에 미치는 영향 파악 용이 [16]
DT	비선형·상호작용 효과를 직관적으로 파악 및 간단한 규칙 기반 의사결정 구조 확인 가능 [17]
RF	앙상블 모델로 과적합 완화 및 변수 중요도 제공을 통해 주요 공정 변수의 영향을 정량화 [18]
XGB	용접 강도 예측 및 구조 분야에서 높은 정확도를 보임 [18]
MLP	비선형 관계를 반영하고 우수한 성능
KNN	거리 기반 비모수 모델로 단순하고 효율적이기 때문에 결과에 대한 해석이 용이 [16]
SVM	소표본·고차원 데이터에서 일반화 성능이 우수하고, 커널 함수를 통해 비선형 결정 경계 학습 가능 [17]

4. 성능 평가 지표

Spot 용접 품질 예측 모델의 성능은 예측값과 실제값의 조합을 통해 평가가 가능한 혼동행렬 (Confusion Matrix)을 이용하였다. 품질 성능에 대한 OK/NG 판정은 <표 4>을 통해 수행하였다. 이때, NG를 Positive class로 정의하여 성능을 계산하였다.

표 4. 혼동행렬 개념

		True Conditon	
		NG	OK
Predicted Condition	NG	True Positive (TP)	False Positive (FP)
	OK	False Negative (FN)	True Negative (TN)

혼동행렬을 바탕으로 본 연구에서는 정확도 (Accuracy), 정밀도(Precision), 민감도(Recall), F1-Score, AUC-ROC의 다섯 가지 지표를 활용하여 모델 성능을 비교하였다. 정확도는 전체 예측 중 정답 비율을 의미하며 식 (2)를 통해 계산된다[19]. 식 (3)과 (4)는 각각 정밀도와 민감도를 나타내며, NG로 예측된 항목의 정확성과 실제 NG를 얼마나 잘 검출하는지를 보여주는 지표로서 활용된다. F1-Score는 정밀도와 민감도의 균형을 평가하는 지표이며, AUC-ROC는 NG와 OK를 구분하는 모델의 판별력을 평가하기 위해 사용하였다[20].

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \tag{2}$$

$$Precision = \frac{TP}{(TP + FP)} \tag{3}$$

$$Recall = \frac{TP}{(TP+FN)} \tag{4}$$

$$F1-Score = \frac{(Precision \times Recall)}{(Precision + Recall)} \tag{5}$$

$$AUC = \int_0^1 TPR(FPR)d(FPR) \tag{6}$$

V. 실험 결과 및 분석

1. 탐색적 데이터 분석

탐색적 데이터 분석 결과는 <그림 3>의 상관 계수 히트맵을 통해 확인할 수 있다. Spot 용접 공정의 독립 변수(전류, 싸이클, 압력)는 서로 간 뚜렷한 상관성이 나타나지 않아, 단일 변수 기반 접근으로는 최종 품질을 설명하기 어렵다는 점이 드러났다. 반면, 용접 품질 검사값은 Spot 강도($r=-0.82$) 및 단면 상태 점수($r=-0.64$)와 강한 음의 상관관계를 보여, 검사기가 일정 수준의 실제 품질 특성을 반영하고 있음을 확인하였다.




그림 3. 변수 간의 상관계수 시각화(히트맵)

그러나 <그림 4>의 변수 간 일치도 분석에서 확인되듯, 검사 결과가 OK임에도 실제 Spot 강도 또는 단면 상태가 NG로 나타나는 경우가 적지 않았다. 종합 품질 기준으로는 전체 시편의 약 36.6%에서 검사 결과와 실제 품질 사이의 불

일치가 발생하였다. 이는 현장 검사 데이터만으로는 품질 오판 가능성이 존재하며, 복합적 공정 변수와 품질 정보를 함께 고려하는 고도화된 예측 모델의 필요성을 시사한다.




그림 4. 품질 지표 변수 간 일치도

2. 기본 모델 학습

변수 간 스케일(scale) 차이에 따른 성능의 저하를 방지하기 위해 데이터 정규화를 통해 전처리를 수행하고, 학습용 데이터와 평가용 데이터를 7대 3의 비율로 분할하여 모델을 학습하고 예측 성능을 평가하였다. 모든 알고리즘의 파라미터는 기본값(default)으로 설정하고, 독립 변수 구성에 따라 A그룹과 B그룹으로 나누어 각 <표 5>와 <표 6>를 통해 성능을 비교 분석하였다.

표 5. 변수 A그룹 기본 모델 성능 평가

모델	정확도	정밀도	민감도	F1-Score	AUC-ROC
LR	0.485	0.485	1.000	0.653	0.500
DT	0.756	0.757	0.730	0.744	0.773
RF	0.787	0.832	0.702	0.762	0.837
XGB	0.735	0.725	0.730	0.728	0.827
MLP	0.732	0.730	0.709	0.719	0.838
KNN	0.770	0.753	0.780	0.767	0.842
SVM	0.756	0.773	0.702	0.736	0.847

A그룹에서는 LR이 가장 낮은 성능을 보여주었다. 이는 선형 결정 경계를 학습하는 LR의 특성상 OK와 NG의 확률 분포가 충분히 분리되지 않고, 클래스 불균형 환경에서 다수 샘플의 예측 확률이 분포의 임계값 근처에 집중되는 경향을 보여주었다. 따라서, Spot 품질이 선형적으로 설명되기 어려움을 확인하였다. 반면 RF는 정확도(0.787), 정밀도(0.832), KNN은 민감도(0.780), SVM은 AUC-ROC(0.847)에서 가장 높은 값을 기록해 데이터가 비선형적 특성을 가진다는 점

이 나타났다.

B그룹에서는 용접 품질 검사값 추가 시 KNN은 정확도(0.811), F1-Score(0.791), AUC-ROC(0.880)에서 가장 높은 값을 기록하였다. SVM 또한 정밀도(0.864)와 AUC-ROC(0.872)에서 높은 수치를 보였다. 반면 RF와 XGB는 A그룹에서도 일정 수준의 성능을 보였기 때문에, 검사기 변수 추가에 따른 개선 폭은 상대적으로 작았다.

표 6. 변수 B그룹 기본 모델 성능 평가

모델	정확도	정밀도	민감도	F1-Score	AUC-ROC
LR	0.485	0.485	1.000	0.653	0.500
DT	0.773	0.838	0.660	0.738	0.811
RF	0.773	0.795	0.716	0.754	0.859
XGB	0.732	0.748	0.674	0.709	0.835
MLP	0.756	0.837	0.617	0.710	0.843
KNN	0.811	0.852	0.738	0.791	0.880
SVM	0.790	0.864	0.674	0.757	0.872

3. 하이퍼 파라미터 튜닝

기본 모델 결과를 토대로, 알고리즘의 성능 향상을 위하여 Grid Search 기반 5-Fold 교차검증 방식으로 하이퍼 파라미터 튜닝을 진행하였다. 하이퍼 파라미터 튜닝 범위는 사전 실험을 통해 성능 변화가 유의미하게 나타나는 구간으로 설정하였으며, 부적합 검출 성능을 우선적으로 고려하기 위해 AUC-ROC를 평가 기준으로 선택하고 진행하였다. 독립 변수 구성은 A그룹과 B그룹으로 동일하게 적용하였으며, 모델별 최적 파라미터 조합은 <표 7>에 정리하였다.

표 7. 최적 하이퍼 파라미터 튜닝 결과

모델	하이퍼 파라미터	최적 하이퍼 파라미터	
		A그룹	B그룹
LR	alpha, lambda	$\alpha=0.9, \lambda=0.034$	$\alpha=0.9, \lambda=0.001$
DT	cp	0.008	0.010
RF	mtry	2	2
XGB	eta, max_depth, gamma, nrounds, colsample_bytree, min_child_weight, subsample	eta=0.5, depth=2, $\gamma=2$, rounds=50, colsample=1, weight=1, subsample=1	eta=0.1, depth=4, $\gamma=0$, rounds=50, colsample=1, weight=1, subsample=0.7
MLP	size, decay	size=4, decay=0.0001	size=10, decay=0.05
KNN	k, kernel	k=15, triangular	k=10, optimal
SVM	sigma, C	$\sigma=2.976, C=1.6$	$\sigma=5.456, C=0.6$

최적 하이퍼 파라미터를 이용한 모델의 성능은 각 그룹에 대해 <표 8>과 <표 9>에 제시되어 있다. A그룹에 대한 모델의 성능을 보면 SVM이 가장 높은 정확도(0.763)를 기록하여 비선형 데이터 구조를 비교적 잘 반영한 것으로 나타났다. XGB는 정밀도(0.767)에서 최솟값, KNN은 AUC-ROC(0.865)에서 최솟값을 기록하며 지표별 강점을 보였으나, RF는 오히려 정확도(0.735)가 감소하였다. 이는 기본 모델 단계에서 A그룹 특성에 가까웠으나, 튜닝 과정에서 분할 기준이 재조정됨으로써 오히려 일반화 성능이 소폭 저하되어 튜닝 효과가 제한적인 것으로 파악됐다.

표 8. 변수 A그룹 하이퍼 파라미터 튜닝 성능 평가

모델	정확도	정밀도	민감도	F1-Score	AUC-ROC
LR	0.619	0.667	0.426	0.519	0.605
DT	0.756	0.757	0.730	0.744	0.773
RF	0.735	0.719	0.745	0.732	0.841
XGB	0.753	0.767	0.702	0.733	0.809
MLP	0.746	0.760	0.695	0.726	0.842
KNN	0.753	0.745	0.745	0.745	0.865
SVM	0.763	0.765	0.738	0.751	0.842

<표 9>에 제시된 B그룹에 대한 모델 성능을 비교해보면, MLP가 정확도(0.801)와 정밀도(0.861) 그리고 F1-Score(0.773)에서 최고 성능을 보였다. KNN(0.884)과 SVM(0.871)은 AUC-ROC 기준에서 높은 구분력을 유지하였다. 반면 RF와 XGB는 정확도는 증가했으나 나머지 지표는 감소하는 양상을 보였다.

표 9. 변수 B그룹 하이퍼 파라미터 튜닝 성능 평가

모델	정확도	정밀도	민감도	F1-Score	AUC-ROC
LR	0.663	0.731	0.482	0.581	0.718
DT	0.773	0.838	0.660	0.738	0.811
RF	0.784	0.805	0.730	0.766	0.860
XGB	0.777	0.839	0.667	0.743	0.858
MLP	0.801	0.861	0.702	0.773	0.876
KNN	0.780	0.847	0.667	0.746	0.884
SVM	0.780	0.853	0.660	0.744	0.871

하이퍼 파라미터 튜닝 결과 B그룹이 전반적인 성능 향상과 높은 성능을 보였으며, 특히 MLP가 가장 우수한 성능을 기록하였다. 다만 단일 시행의 결과만으로 모델 적용 가능성을 판단하기에

는 한계가 있어, 다음 단계에서는 반복 학습 기반 안정성 평가를 수행하였다.

4. 안정성 평가

최적 하이퍼 파라미터를 설정하고 얻어진 단일 성능 값만으로는 실제 제조 환경 적용 타당성을 판단하기 어렵다. 모델의 재현성과 Spot 용접 시편에 따른 변동성을 고려하기 위해, 최적 하이퍼 파라미터를 고정하고 무작위 표집을 통한 학습용 데이터를 다르게 하여 100회 반복 실험을 수행하였다.

표 10. 변수 A그룹 안정성 평가

모델	정확도	정밀도	민감도	F1-Score	AUC-ROC
LR	0.621 (0.024)	0.648 (0.042)	0.483 (0.054)	0.551 (0.037)	0.399 (0.031)
DT	0.745 (0.025)	0.748 (0.032)	0.716 (0.057)	0.730 (0.032)	0.776 (0.029)
RF	0.749 (0.020)	0.748 (0.026)	0.730 (0.034)	0.738 (0.021)	0.835 (0.019)
XGB	0.749 (0.026)	0.779 (0.036)	0.674 (0.058)	0.721 (0.037)	0.806 (0.029)
MLP	0.757 (0.024)	0.778 (0.037)	0.703 (0.046)	0.737 (0.025)	0.821 (0.024)
KNN	0.768 (0.021)	0.765 (0.026)	0.754 (0.038)	0.758 (0.023)	0.856 (0.021)
SVM	0.777 (0.019)	0.780 (0.024)	0.754 (0.035)	0.766 (0.022)	0.837 (0.022)

<표 10>은 A그룹에 대한 모델별 성능을 보여 주며, 표 내부의 상단에 제시된 값은 100회 반복 수행을 통해 나온 성능의 평균값, 하단에 제시된 괄호 안의 값은 표준편차를 의미한다. 여러 모델 중 SVM은 최고 정확도(0.777)와 최저 표준편차(0.019)를 기록하여 가장 안정적인 모델로 확인되었다. 또한 KNN은 AUC-ROC(0.856)에서 가장 높은 값을 보여 구분 능력 측면에서 우수한 성능을 나타냈다.

B그룹에 대한 안정성 평가 결과는 <표 11>에 제시되어 있으며, 그중 RF는 네 개 지표인 정확도(0.787), 정밀도(0.799), F1-Score(0.773), AUC-ROC(0.869)에서 가장 높은 성능을 기록하였다. 또한 KNN은 민감도(0.764)에서 가장 높은 값을 나타내어 불량 검출 측면에서 강점을 보였다.

표 11. 변수 B그룹 안정성 평가

모델	정확도	정밀도	민감도	F1-Score	AUC-ROC
LR	0.661 (0.024)	0.723 (0.040)	0.488 (0.039)	0.582 (0.034)	0.278 (0.027)
DT	0.747 (0.023)	0.769 (0.033)	0.686 (0.050)	0.723 (0.030)	0.779 (0.025)
RF	0.787 (0.021)	0.799 (0.031)	0.750 (0.036)	0.773 (0.023)	0.869 (0.018)
XGB	0.763 (0.022)	0.794 (0.032)	0.692 (0.039)	0.738 (0.026)	0.844 (0.020)
MLP	0.769 (0.022)	0.792 (0.030)	0.711 (0.037)	0.749 (0.025)	0.855 (0.021)
KNN	0.781 (0.022)	0.781 (0.030)	0.764 (0.035)	0.772 (0.023)	0.869 (0.036)
SVM	0.722 (0.020)	0.798 (0.027)	0.711 (0.041)	0.751 (0.026)	0.847 (0.021)

종합적으로, 모델 안정성 평가는 단일 실험 결과와 일부 순위 차이를 보였다. 이는 실제 공정에 적용할 때, 예측 안정성이 단일 수행에 의한 성능보다 더 중요한 기준으로 고려될 수 있음을 시사한다. 이에 따라, B그룹의 RF 모델은 높은 성능과 낮은 변동성을 동시에 확보하여 실제 품질 판정 시스템 적용 시 가장 적합한 후보 모델로 도출되었다.

5. 운영 적용 제안

안정성 평가 결과, 현장 적용 후보 모델로 B그룹 RF를 선정하였다. <그림 5>와 같이 혼동행렬 기반 성능 비교 결과 기존 검사기에서는 실제 불량률의 36.5%가 통과(FN) 되는 미검출 문제가 나타났으나, RF 모델 적용 시 FN이 12.1%로 감소하여 불량 검출 신뢰도가 크게 향상되었다. 다만 FP가 0%에서 9%로 증가하여 일부 양품이 NG로 판정될 수 있으나, 제조 환경에서는 불량 누락 방지 효과가 FP 증가보다 더 중요하게 평가된다.




그림 5. 검사기 및 RF 모델 혼동행렬 비교

따라서 Spot 용접 품질 관리는 기존 검사기 단일 방식보다 <그림 6>와 같이 검사기 및 기계학습 모델을 병합한 이중 판정 구조가 적합하며 이를 통해 검출 민감도 향상과 공정 학습을 기반으로 한 지속적 품질 관리 체계 구축이 가능함을 확인하였다.




그림 6. Spot 용접 공정 기계학습 기반 이중 품질 검사

VI. 결론

본 연구는 연속전지 Spot 용접 공정에서 발생하는 품질 이상을 보다 정확히 판단하고 기존 검사기 방식의 한계를 보완하기 위해 기계학습 기반의 예측 모델을 구축하고 성능을 비교 분석하였다. 공정 변수(전류, 사이클, 압력)와 검사기 계측값을 조합하여 두 가지 그룹(A그룹: 공정 변수만 적용, B그룹: 공정변수 및 검사기 검출값 적용)으로 나누어 독립 변수를 구성하고, 7개 모델을 대상으로 기본 학습, 하이퍼 파라미터 튜닝, 안정성 평가 순으로 분석하였다.

기본 학습 결과, 로지스틱 회귀는 가장 낮은 성능을 기록하여 Spot 품질이 단순 선형 관계로 설명되기 어렵다는 점을 확인하였다. A그룹에서는 랜덤 포레스트 모델이 정확도에서 가장 높은 값을 보였으며, K-최근접 이웃과 서포트 벡터 머신 모델은 각각 F1-Score와 AUC-ROC에서 강점을 나타냈다. 검사기 변수를 포함한 B그룹에서는 K-최근접 이웃과 서포트 벡터 머신의 성능이 개선되어 검사기 데이터가 예측력 향상에 기여하는 유효한 독립 변수임을 확인하였다.

최적 하이퍼 파라미터를 사용한 성능 평가 결과에서 B그룹의 다중 퍼셉트론 모델이 가장 높은 정확도를 기록하여 비선형 패턴 학습 능력이 반영된 것으로 나타났다. 반면 K-최근접 이웃과

서포트 벡터 머신 모델은 기본 학습 단계에서 이미 높은 성능을 보여 개선 폭이 크지 않았다.

모델의 성능 안정성 평가에서는 B그룹의 랜덤 포레스트 모델이 정확도, AUC-ROC, 표준편차 등 여러 지표 측면에서 가장 균형적인 결과를 보여 실제 품질 판정 적용 시 적합한 후보 모델로 확인되었다.

이에 따른 기존 검사기와 랜덤 포레스트 모델의 판정 결과를 비교하기 위해 혼동행렬 분석을 수행한 결과, 기존 검사기 방식에서 발생하던 False Negative(FN)는 랜덤 포레스트 모델 적용 시 크게 감소(36.5% → 12.1%)하며 검출 능력이 향상되었다. 반면 False Positive(FP)는 소폭 증가(0.0% → 9.0%)하였으나, 제조 환경에서 FN 감소 효과가 더 중요하다는 점을 고려하면 기존 검사기의 미검출 문제를 모델이 보완할 수 있음을 시사한다.

결과적으로 기계학습 기반 Spot 품질 예측은 검사기 단독 방식이 가진 한계를 보완하며, 검사기 1차 판정 및 기계학습 2차 검증 구조가 가장 효과적인 품질 운영 방식으로 판단된다. 향후 용접 팁 마모, 실시간 센서, 단면 이미지 등 추가 변수 확장이 이루어진다면, 기계학습 품질 예측 모델은 Spot 용접 공정의 품질 변동 최소화와 신뢰성 향상에 기여할 수 있을 것으로 기대된다.

REFERENCES

- [1] 류한일, 이상훈, 최덕재, 박혁로, "충전 특성과 어텐션 기반 LSTM을 활용한 개선된 리튬이온 배터리 SOH 예측 모델," *스마트미디어저널*, 제12권, 제11호, 103-112쪽, 2023년 12월
- [2] G.J. May, A. Davidson, and B. Monahov, "Lead batteries for utility energy storage: A review", *Journal of Energy Storage*, vol. 15, pp. 145-157, Nov. 2017.
- [3] F. Mohammadi and M. Saif, "A comprehensive overview of electric vehicle batteries market", *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, vol. 3, pp. 1-10, Feb. 2023.
- [4] Wei Zhang, D. Wang, J. Chen, H.

- Ghassemi-Arnaki, B. Carlson, and Z. Feng, "Enhance resistance spot welding quality control: A machine learning approach", *Oak Ridge National Laboratory and General Motors*, pp. 2-5, 2023.
- [5] 김상희, 박원우, 최한고, "신경회로망을 이용한 스폿용접의 용접상태검사 시스템의 개발," *전기학회 논문지*, 제46권, 제10호, 5-11쪽, 1997년 10월
- [6] 김재화, "머신러닝 기법을 활용한 용접 품질 판단," *동의대학교 대학원 조선해양공학과 석사학위논문*, 2020년 1월
- [7] 박성재, 김현성, 김용수, "델타스폿용접 프로세스를 이용한 이중소재의 웰드본딩 공정 조건 최적화," *대한용접·접합학회지*, 제39권, 제2호, 3-7쪽, 2021년 2월
- [8] AMADA, *CY-210E Operation Manual*, pp. 34-40, Jun. 2023.
- [9] TIMSS, *용접 품질 검사기 매뉴얼*, 3-4쪽, 2017년
- [10] J.R. Quinlan, "Induction of Decision Trees", *Machine Learning*, vol. 1, no. 1, pp. 87-89, Aug. 1985.
- [11] L. Breiman, "Random Forests", *Machine Learning*, vol. 45, no. 1, pp. 5-8, 24-26, Apr. 2001.
- [12] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System", *Proceeding. of the 22nd ACM SIGKDD Conference*, pp. 785-788, Aug. 2016.
- [13] M.-C. Popescu, V. Balas, L. Perescu-Popescu, and N. Mastorakis, "Multilayer Perceptron and Neural Networks", *WSEAS Transaction on Circuits and Systems*, pp. 579-583, Jul. 2009.
- [14] L. E. Peterson, "K-nearest neighbor", *Scholarpedia*, pp. 1-3, 2009.
- [15] C. Cortes and V. Vapnik, "Support-Vector Networks", *Machine Learning*, vol. 20, no. 3, pp. 273-297, Mar. 1995.
- [16] 고창완, 김현민, 정영선, 김재희, "차대차 교통사고에 대한 상해 심각도 예측 연구," *한국ITS학회논문지*, 제19권, 제4호, 22-28쪽, 2020년 8월
- [17] M. Akbari, "A comprehensive review on the integration of artificial intelligence in friction stir welding for monitoring, modelling, and process optimization", *Engineering Applications of Artificial Intelligence*, vol. 141, 107012, May 2025.
- [18] D. Suenaga, Y. Takase, T. Abe, G. Orita, and S. Ando, "Prediction accuracy of Random Forest, XGBoost, LightGBM, and artificial neural network for shear resistance of post-installed anchors", *Structures*, vol. 49, pp. 101139, Apr. 2023.
- [19] Taghiyev Ilkin, 이재홍, "머신 러닝 접근 방식을 통한 가짜 채용 탐지," *스마트미디어저널*, 제12권,

- 제2호, 36-41쪽, 2023년 3월
- [20] G. Shmueli, P.C. Bruce, and N.R. Patel, *비즈니스 애널리틱스를 위한 데이터마이닝 R Edition*, 한빛아카데미, 134-149쪽, 2018년 9월

 저 자 소 개

**박재현(준회원)**

2015년 전북대학교 산업정보시스템공학과 학사 졸업.
2023년~현재 전남대학교 산업공학과 석사과정.
<주관심분야 : HCI, 기계학습, 인공지능, 스마트팩토리>

**고창완(정회원)**

2019년 전남대학교 산업공학과 학사 졸업.
2021년 전남대학교 산업공학과 석사 졸업.
2022년~현재 전남대학교 산업공학과 박사과정.
<주관심분야 : 통계적 데이터마이닝, 불확실성 데이터 분석, 머신러닝>

**박진(준회원)**

2024년 전남대학교 산업공학과 학사 졸업.
2024년~현재 전남대학교 산업공학과 석사과정.
<주관심분야 : 통계적 데이터마이닝, 실시간 데이터, 연속 학습>

**정영선(정회원)**

1997년 전남대학교 산업공학과 학사 졸업.
2001년 고려대학교 산업공학과 석사 졸업.
2011년 뉴저지주립대학교 산업시스템공학과 박사 졸업.
2014년~현재 전남대학교 산업공학과 교수.
<주관심분야 : 통계적 데이터마이닝, 반도체 공정 자동화>