



공구 온도 시계열 데이터와 설명가능 인공지능(XAI) 기반 마찰교반용접 모니터링 기법

조민구^{a,b}, 김재황^c, 이광진^d, Deva Prasaad Neelakandan^e,
이찬호^e, 정윤철^f, 강성욱^g, 김진수^{a,*}

Monitoring Method of Friction Stir Welding (FSW) based on Tool Temperature Time-Series Data and Explainable Artificial Intelligence (XAI)

Mingoo Cho^{a,b}, Jaehwang Kim^c, Kwang-Jin Lee^d, Deva Prasaad Neelakandan^e,
Chanho Lee^e, Yoon Chul Jung^f, Sungwook Kang^g, Jinsu Gim^{a,*}

^a Jinju Center, Dongnam Technology Application Division, Korea Institute of Industrial Technology (KITECH)

^b School of Mechanical Engineering, Pusan National University

^c Jeonbuk Technology Application Division, Korea Institute of Industrial Technology (KITECH)

^d USA Technology Cooperation Center, Korea Institute of Industrial Technology (KITECH)

^e Department of Mechanical Engineering, Auburn University

^f R&D Center, DnM Aerospace

^g Department of Smart Ocean Mobility Engineering, Changwon National University

ARTICLE INFO

Article history:

Received	4	June	2025
Revised	4	July	2025
Accepted	10	July	2025

Keywords:

Friction stir welding (FSW)
Explainable artificial intelligence (XAI)
AI-assisted monitoring
Autonomous monitoring setup
Tool temperature

ABSTRACT

Friction stir welding (FSW), a solid-state welding process, is widely used in industries such as automotive and aerospace. Weld quality in FSW is primarily influenced by the frictional heat generated during the process. To more accurately capture this heat, this study measured the temperature of the rotating welding tool. Since the tool rotates during welding, a wireless measurement device was developed for real-time data acquisition. Al6061-T6 was used as the base material, and key features extracted from the temperature profile were applied as input features to an artificial neural network (ANN) model to predict tensile strength. Using explainable AI (XAI), the influence of each feature on model prediction output was analyzed, and process monitoring windows were established. The proposed method successfully identified FSW conditions likely to produce tensile strength outside acceptable limits. This study offers a practical approach for real-time quality prediction and monitoring in FSW, supporting the development of intelligent, data-driven, and autonomous manufacturing systems.

1. 서론

마찰교반용접(friction stir welding, FSW)은 회전하는 비소모

성 공구가 모재와 접촉하며 발생하는 마찰열로 인해 연화된 모재가 강제로 교반되어 이루어지는 용접을 말한다^[1,2]. 1991년 영국 The Welding Institute(TWI)에서 처음 개발되었으며^[3,4], 기존 용

* Corresponding author. Tel.: +82-55-924-0134

E-mail address: jgim@kitech.re.kr (Jinsu Gim).

접 방식과 달리 소재가 용융되지 않아 용접 결함 및 균열이 거의 발생하지 않고 열 변형이 작기 때문에 기계적 강도가 우수하다^[5,6]. FSW는 금속 및 복합재료 뿐만 아니라 알루미늄 합금 박판 접합에도 적합하여, 항공우주산업 및 다양한 수송 산업 분야에 적용되고 있다^[7-9]. 이러한 산업 적용에 있어 용접 결함을 방지하고 안정적인 용접 품질 확보를 위해서 공정 최적화가 필수적이다^[10-12]. 용접부 품질은 솔더 직경 및 패턴, 프로프 직경과 같은 공구의 형상, 공구의 회전속도 및 이송속도, 하향력과 같은 다양한 공정변수에 의해 결정된다^[13-15].

이러한 공정변수들 가운데, 공정 중 발생하는 마찰열은 용접부의 품질과 결합에 직접적인 영향을 미친다^[16,17]. 기존의 여러 연구에서는 FSW에서의 최대 온도를 예측하는 것이 결합을 최소화하고 용접부 품질을 향상시키는 데 중요하다고 보고하였다. Filippis et al.은 열화상 카메라로 접합부 표면온도를 측정하였고, 인공신경망을 사용하여 공정변수가 접합부의 인장강도와 heat affected zone (HAZ)의 미세 경도에 미치는 영향을 분석하고 예측하였다^[18]. Nic et al.은 공정변수가 용접온도에 의한 잔류응력에 미치는 영향을 분석하기 위해 모재에서 온도를 측정하여 유한요소해석 모델과 비교하였고, 회귀 분석을 수행하였다^[19]. 또한, 모재에 열전대를 설치하여 FSW 공정 중 발생하는 온도를 측정하고 측정된 온도 프로파일을 이용하여 접합부의 인장강도를 예측한 연구도 수행된 바 있다^[20]. 이전 연구들은 대부분 모재의 온도를 측정하여 FSW 공정

을 분석하였다. 열화상 카메라는 측정 재료 표면에서 복사에 의한 열 방출 특성을 기반으로 온도를 측정하므로, 카메라의 위치, 각도, 측정 재료의 방사율 등에 따라 측정 결과가 달라질 수 있다^[21,22]. 용접물에 설치된 열전대는 접촉식 온도 측정 장치로, 교반 시 소재의 흐름으로 인해 용접부 근방의 온도를 측정하기 어렵고 설치된 열전대가 파괴될 수 있다는 한계점을 가진다^[23,24]. 이러한 한계를 보완하기 위해 용접물 대신 공구의 온도를 측정하는 방법이 제안되었고, 이를 활용하여 용접 품질을 예측하거나 공정변수와의 상관관계를 분석한 연구들이 수행되었다. Wang et al.은 용접 시 공구에 내장된 열전대를 이용하여 실시간 온도 신호를 측정하였다. 이후 웨블릿 패킷 방법을 사용하여 용접 품질과 관련된 특징을 추출하였고, least squares support vector machine(LSSVM)과 유전 알고리즘을 이용하여 용접 품질을 예측하였다^[25]. Hu et al.은 보빈 톨에 열전대를 설치하여, FSW 공정 중 공구와 용접물 사이의 접촉면 온도를 제어함으로써 용접 품질을 효과적으로 보장하고 향상시킬 수 있음을 보여주었다^[26]. Abboud et al.은 최적 공정변수를 판단하기 위해 공구에 내장된 열전대를 통해 온도를 측정하였고, 고품질의 용접부를 달성하기 위해서는 공구 온도가 재료의 최소 고상선 온도의 65%에 도달해야 한다고 제시하였다^[27]. 기존 연구에서는 공구 온도를 활용하여 용접 품질을 예측하거나 공정변수와의 상관관계를 분석하는 시도가 있었으나, 이를 직접적으로 FSW 공정의 모니터링에 활용하지는 않았다.

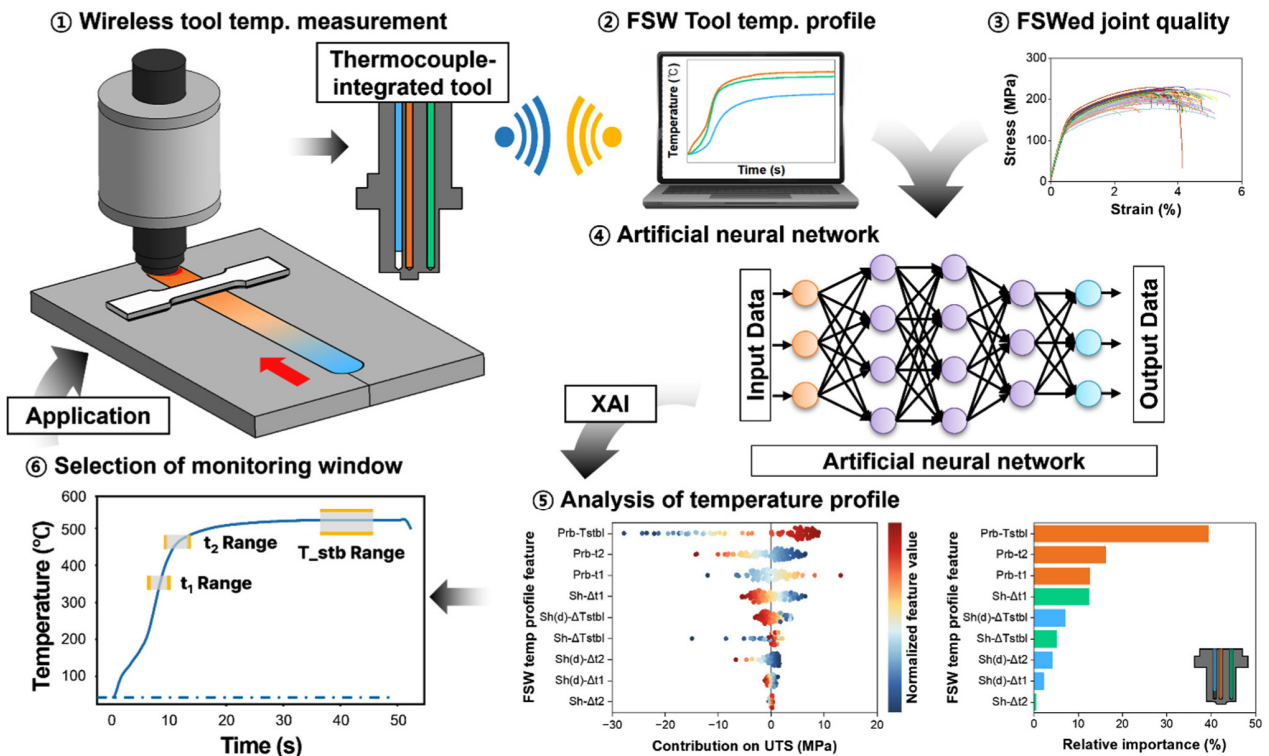


Fig. 1 Schematic of this research

본 연구에서는 FSW 공정의 모니터링을 위한 방법론을 제안한다. 실시간 무선 온도 측정 장치를 통하여 측정된 공구 온도를 기반으로, 용접부의 인장강도를 예측하는 인공지능 모델을 학습시켰다. 인공지능 모델이 온도 프로파일 데이터로부터 학습한 물리적 연관 관계를 설명가능 인공지능(XAI)을 이용하여 분석하여, 공구 온도 모니터링을 위한 모니터링 윈도우를 선정하여 적용하였다. Fig. 1은 본 연구의 전체적인 흐름을 나타낸다.

2. 마찰교반용접 실험

2.1 온도 측정 장치 제작

FSW 공정에서의 공구 온도를 측정하기 위해 무선 온도 측정 장치를 제작하여, 공정 중 실시간 공구 온도를 측정하였다. FSW 공정 중 공구는 회전하기 때문에 온도 측정을 위해서는 무선으로 온도를 측정하고 데이터를 송수신할 수 있는 장치가 필요하다. 본 연구에서 사용한 무선 온도 측정 장치는 이전 연구^[28,29]에서 사용된 무선 온도 측정 장치를 사용하였다. 무선 온도 측정 장치는 크게 다음과 같이 구성된다. 1) 열전대가 내장된 FSW 공구, 2) 측정 데이터를 무선으로 송신하기 위한 송신부, 3) 데이터를 수집하기 위한 수신기와 측정 제어 및 저장을 위한 PC로 구성된다. Fig. 2는 열전대가 내장된 FSW 공구를 나타낸다.

공구의 온도를 측정하기 위하여 열전대가 설치된 FSW 공구를 제작하였다. FSW에서 발생하는 마찰열은 프로브(probe)와 솔더(shoulder) 바닥에서 집중적으로 발생하고, 프로브가 먼저 용접물과 닿기 때문에 마찰열이 공구의 축 방향에서 반경 방향으로 전달되는 것으로 가정하였다. Fig. 2(a)는 열전대가 공구에 삽입된 위치를 나타낸다. 열전대가 솔더면에 노출되어 설치될 경우 용접 시 열전대가 파손될 위험이 있고, 3개의 열전대를 같은 높이에서 측정할 경우 측정 온도의 차이가 미미할 것으로 판단하여 각 열전대를 서로 다른 깊이와 반경 위치에 설치하였다. 열전대를 고정하고 온도 측정 시 전기적 노이즈를 방지하기 위해 산화 알루미늄(Al_2O_3) 기반의 절연 접착제를 사용하였고 Fig. 2(c)와 같이 제작하였다. Fig. 3은 사용된 무선 측정 장치 구성을 나타낸다.

온도 측정을 위한 열전대 앰프 3개와 데이터 송신을 위한 모듈이 장착되어 있으며, 전원 공급을 위한 배터리가 장착되어 있다.

2.2 공정 조건

인공지능 모델의 용접부 품질 예측 성능을 향상시키기 위하여, 공구 온도 안정화 구간 형성을 고려하고, Hammersley sequence sampling(HSS) 기반의 실험계획법을 적용하여 공정 조건을 샘플링 하였다. FSW에서 일반적으로 통용되는 공정변수는 공구의 회전속도와 이송속도이다. 공구의 회전속도는 500~2,500 rpm 범위




Fig. 2 Thermocouple-integrated FSW tool: (a) thermocouple insertion positions and FSW tool design, (b) a fabricated FSW tool before thermocouple insertion, (c) thermocouple-integrated FSW tool




Fig. 3 Configuration of the devised wireless temperature measurement device




Fig. 4 Sampled FSW conditions using HSS

로 설정하였다. 이송속도가 너무 빠르면 공구 온도가 안정화된 구간이 형성되기 전에 용접이 끝나므로 충분히 공구 온도가 안정화된 구간이 확보되는 100~500 mm/min 범위에서 90 case를 메인 실험 조건으로 설정하였다. 추가적으로 안정화된 온도 구간이 모호할 것으로 생각하는 500~1,000 mm/min 범위에서 10 case를 추가 실험 조건으로 설정하였다. 예측 성능이 뛰어난 인공지능 모델의 구축을 위해서는 중복되지 않는 조건의 최대한 많은 데이터를 학습시키는 것이 중요하다. HSS는 Quasi-Monte Carlo 방식에 기반한 실험계획법으로, 기존의 무작위 샘플링 방식인 Monte

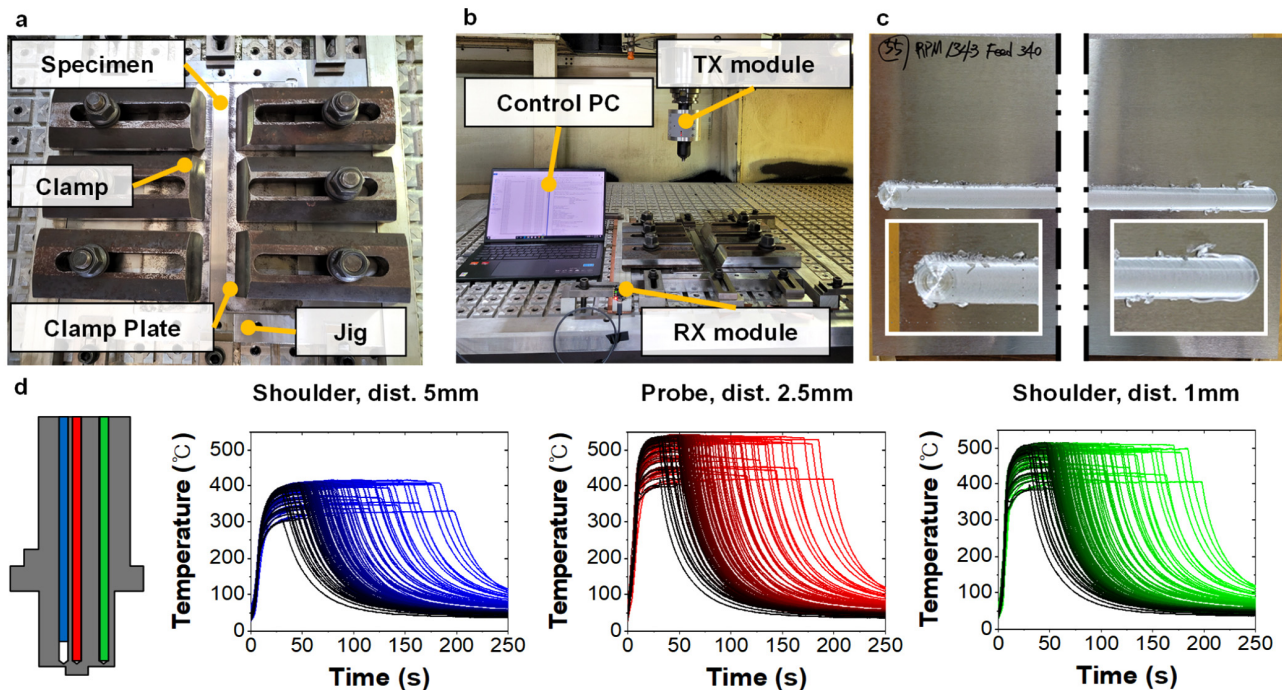


Fig. 5 Experimental procedure and results: (a) workpiece setup, (b) data acquisition setup using a wireless temperature measurement device, (c) an example result of FSW process, (d) temperature profiles at different measurement locations under various FSW conditions

Carlo 방법보다 입력 공간에 샘플을 보다 더 균등하게 분포시킬 수 있는 방법이다. HSS를 기반으로 실험 조건의 중복을 방지하였으며, 각 실험 조건의 분포는 Fig. 4와 같다. FSW 실험은 머시닝 센터(Hartford HEP-3150, She Hong Industrial Co., Ltd., Taiwan)를 사용하여 진행하였다. FSW 실험에는 가로 100 mm, 세로 300 mm, 두께 2 mm의 Al6061-T6 소재를 사용하였다.

2.3 공구 온도 측정

FSW 공정 중 공구 온도는 무선 온도 측정 장치를 통해 실시간으로 측정되었다. Fig. 5는 FSW 공정 실행 과정과 결과를 나타낸다. Fig. 5(a)와 같이 Al6061-T6 시편을 지그에 고정하였으며, 시편은 클램프에 의해 고정된다. 이후 Fig. 5(b)와 같이 무선 온도 측정 및 무선 송신 장치(TX module)와 결합된 공구에 의해 용접이 되고, 공정 중 실시간으로 측정된 온도 데이터는 데이터 수신 장치(RX module)에 의해 취득된다. 수신된 온도 시계열 데이터는 Control PC에서 Python 기반 프로그램을 통해 실시간으로 표시되고 공정이 종료되면 저장된다. 이러한 과정들로 100 case의 실험 조건에서 실험이 수행되었다. Fig. 5(c)는 FSW 용접부의 형상을 나타낸다. 온도 측정 결과는 Fig. 5(d)와 같다. 예상대로 툴의 중앙인 프로브 위치에서 측정된 온도가 가장 높았고, 숄더에서 5 mm 지점의 열전대에서 측정된 온도가 가장 낮았다.

2.4 인장 시험

인공지능 모델의 예측값으로 용접부의 인장강도를 사용하기 위해 인장시험을 진행하였다. 용접부의 인장강도를 측정하기 위해 인장시험편을 공구 온도가 안정화된 구간에서 추출하여 제작하였다. Fig. 5(d)의 온도 측정 결과를 보면, 공구 온도 프로파일은 FSW 공정 상황을 다음과 같이 나타낸다. 용접 공정에서 공구가 회전하면서 모재에 접촉하기까지 공구의 온도는 상온과 비슷하고, 공구가 모재에 삽입되고 예열을 위해 머무르면 온도가 급격히 상승한다. 용접을 위해 공구가 이송되면 온도가 완만히 상승하다가 일정 지점부터는 온도가 안정화된다. Fig. 6(a)는 이와 같은 FSW 공정 상황 별 온도 프로파일의 변화와 온도 안정화 구간을 나타낸다. 따라서, FSW 공정변수에 따른 용접부 인장강도를 안정적으로 얻기 위해서는 온도 안정화 구간에서 인장 시험편을 채취할 필요성이 있다. 또한, 용접부에서 전체적으로 균일한 인장강도를 얻기 위해서는 공정조건뿐만 아니라 예열을 위한 dwell time도 중요한 것으로 생각된다.

인장시험편의 형상은 ASTM E8-13a의 소형 시험편 형상을 선택하였다. 시험 장비로는 Fig. 6(b), (c)에 나타난 인장시험기(Criterion Model 45, MTS Systems Corp., USA)를 사용하였다. 인장시험을 통해 측정된 인장강도는 인공지능 모델의 예측값으로 사용되었다.

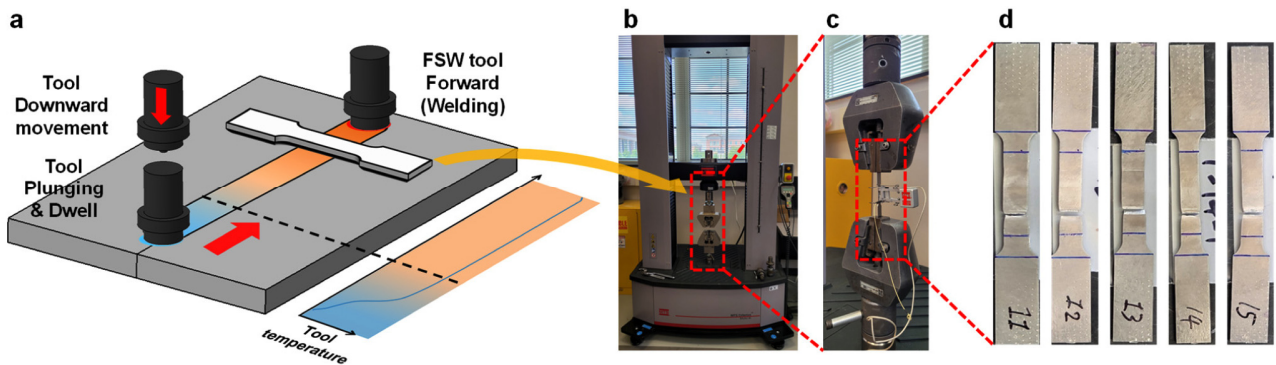


Fig. 6 Tensile test: (a) location of tensile specimen extraction and tool temperature stabilized region, (b) the used tensile testing machine, (c) tensile specimen setup, (d) fractured tensile specimens

3. 인공지능 모델

3.1 온도 프로파일 특징(input feature)

공구 온도 데이터를 인공지능 모델의 학습데이터로 활용하기 위하여, 공구 온도 시계열 프로파일에서 물리적 의미를 내포하고 있는 특징(feature)을 추출하였다. 공구 온도 프로파일은 시계열 데이터이며, 시간에 따른 온도 데이터의 양이 많다. 이를 그대로 인공지능 모델의 입력 데이터로 사용할 경우 입력층(input layer)의 폭이 매우 커지고 계산 비용이 증가하는 문제가 발생한다. 따라서, 계산 비용을 절감하고 학습 효율을 높이기 위해, 온도 프로파일상의 물리적으로 의미 있는 주요 feature를 추출하여 인공지능 모델의 입력 특징으로 반영하였다.

공구 온도 프로파일의 특징으로 온도 안정화 추이를 나타내는 특징을 추출하였다. FSW 공정에서 공구 온도 프로파일의 가장 두드러진 특징은, 공정 초반에 공구 온도가 상온에서 급격히 상승하여 특정 온도로 안정화된다는 점이다. Fig. 7은 이러한 특징을 활용하여 추출된 feature를 나타낸다. Stabilized T(T_{stbl})는 온도 안정화 영역의 마지막에서 공구 후퇴시의 dwell time으로 인한 온도 상승이 있는 데이터를 구간을 제거하고 남은 영역의 마지막 2초의 온도 값을 평균으로 하여 정의하였다. 공구 온도가 상승하기 시작하여 안정화에 도달하는 구간의 특성을 나타내는 feature를 추출하기 위해, 과도 열전달 과정에서 온도 안정화 특성을 나타내는 시계열 상수의 정의를 참조하였다. 먼저 안정화 영역에서 추출된 온도와 초기 온도 차이를 ΔT 로 정의하고 ΔT 의 63.2% ($1-e^{-1}$)와 86.5% ($1-e^{-2}$)에 도달하는 시간을 각각 t_1 , t_2 로 정의하였다. 각 온도 채널에 대한 feature를 3개씩 추출하였다. 공구의 중심에 위치하며, 가장 온도 상승 반응이 빠른 프로브에서의 온도 프로파일을 기준으로, 각 feature의 편차(ΔT_{stbl} , Δt_1 , Δt_2)를 타 위치에서의 온도 프로파일의 feature로 사용하였다. 따라서 Fig. 8과 같이 시험 1 case당 3채널에 대한 온도를 측정하였으므로, 최종적으로 시험




Fig. 7 Definitions of the FSW tool temperature profile features

1 case당 9개의 feature를 인공지능 모델 학습에 사용하였다.

3.2 하이퍼파라미터 최적화

인공지능 모델의 인장강도 예측 성능을 향상시키기 위하여 하이퍼파라미터 최적화(hyperparameter optimization, HPO)를 수행하였다. 용접부 품질인 인장강도를 예측하기 위한 인공지능 모델로, 인공신경망(artificial neural network, ANN)을 사용하였다. ANN 모델은 입력층, 은닉층, 출력층으로 구성되며, 각 층은 여러 개의 노드로 구성된다. 입력층에서 input feature가 입력되면 은닉층을 거쳐 주어진 가중치와 활성화 함수가 적용된다. 은닉층에서 계산된 출력 값은 다시 가중치와 활성화 함수를 거쳐 출력층으로 전달되고 최종 결과를 생성한다.

인공지능 모델 구조와 학습 조건을 정의하는 하이퍼파라미터(hyperparameter)는 모델의 예측 성능에 큰 영향을 미치므로, 모델의 성능을 향상시키는데 필수적이다. 본 연구에서는 모델의 예측 성능 평가 지표로 R-square(R^2), mean absolute percentage error(MAPE)를 사용하였다. HPO에 베이지안 최적화 기법 중 하나인 Tree-structured Parzen Estimator(TPE)를 적용하였다. TPE는 목적함수와 하이퍼파라미터 공간을 확률적으로 모델링하는 방식으로 최적화를 수행한다. 또한, 학습 과정에서 비효율적인




Fig. 8 AI model architecture, input and output features (Note: σ_{UTS} = ultimate tensile strength)

Table 1 Hyperparameter optimization (HPO) range

Hyperparameter	Range
Number of hidden layers	1, 2, 3
Number of neurons for each hidden layer	8, 16, 32
Weight initializer	Glorot normal, Glorot uniform He normal, He uniform LeCun normal, LeCun uniform
Optimizer	ReLU, GELU, ELU, SELU softplus, swish
Initial learning rate	0.001, 0.01, 0.1

하이퍼파라미터 조합을 조기에 제거하여 학습 속도를 향상시키기 위한 가지치기 기법인 Successive Halving과 Hyperband를 적용하였다. 과적합(overfitting)을 방지하기 위해 early stopping을 적용하였으며, 검증 성능이 가장 우수했던 시점의 가중치를 복원하여 최종 모델에 적용하였다. Table 1은 HPO를 수행하기 위한 각 하이퍼파라미터의 범위이다.

3.3 설명가능 인공지능

인공신경망을 포함하는 대부분의 인공지능 모델은 모델의 예측 결과에 대한 이유를 알 수 없는 “블랙박스(black box)” 또는 “불투명(opaque)” 특성을 가진다^[30]. 이는 인공지능 모델을 구성하는 가중치와 같은 파라미터의 수가 매우 많기 때문에, 인공지능 모델의 입력과 예측(출력)의 수학적 관계를 해석적으로 이해하기 어렵기 때문이다. Explainable artificial intelligence(XAI)는 인공지능 모델의 예측 결과에 대한 타당한 설명을 제공함으로써, 사람이 인공지능 모델의 예측을 이해할 수 있도록 한다. 또한, 인공지능 모델의 설명결과를 통하여 모델이 데이터에서 학습한 입력 및 출력 특징의 연관관계에 대한 통찰을 제공할 수 있다.

공구 온도 프로파일을 이용하여 용접부 품질을 예측하는 인공지

Table 2 HPO results

Hyperparameter	Result
Number of hidden layers	1
Number of neurons for each hidden layer	32
Weight initializer	LeCun normal
Optimizer	SELU
Initial learning rate	0.01




Fig. 9 Training and validation loss according to epochs

능 모델을 SHapley Additive exPlanation(SHAP)을 이용하여 분석하였다. 이는 Gim이 제시한 공정 데이터 프로파일의 품질에 대한 영향도를 XAI를 활용하여 분석하는 방법에 기반한다^[31,32]. XAI 기법 중 SHAP은 게임 이론의 Shapley value를 기반으로 하여 각 feature가 모델 예측에 기여하는 중요도를 계산하는 방법이다^[33]. 또한, 모델 구조에 대한 제약이 없으며(model agnostic), 각 예측에 대한 설명(local explanation)뿐만 아니라 전반적인 예측 결과에 대한 설명(global explanation)을 제공하기에, 본 연구에 적용하는데 적절하다 판단하였다. 즉, 온도 프로파일의 feature가 용접부 품질에 미치는 영향을 정량적으로 도출하고 평가하였다. 인공지능 또는 머신러닝 모델 분석에 input feature 조합을 모두

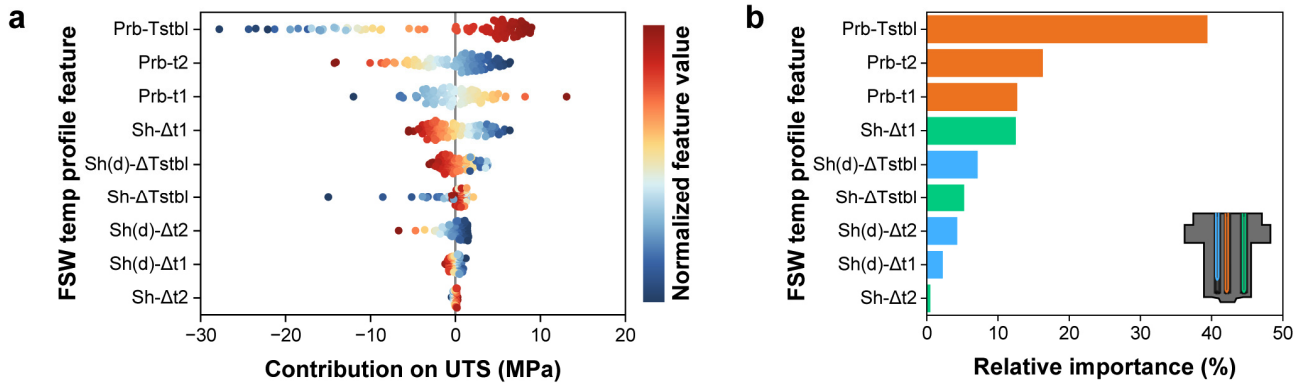


Fig. 10 XAI results: (a) contribution distribution of FSW temperature profile features on UTS, (b) overall feature importance for UTS prediction




Fig. 11 Relationship between process variables and features: (a) stabilized temperature, (b) t_1 , (c) t_2 according to process parameters

사용하여, 분석 결과가 결정론적으로(deterministic) 도출되도록, SHAP의 exact explainer를 사용하였다.

4. 설명가능 인공지능 기반 FSW 공정 분석

4.1 용접부 품질 예측 성능

학습된 인공신경망 모델의 예측 성능은 실제 FSW 공정에 대한 물리적인 설명을 XAI를 이용한 모델 분석 결과에서 얻기에 적절하다고 판단되었다. 인공신경망 모델의 예측성능을 향상시키기 위한 HPO 결과는 Table 2와 같다. Fig. 9는 인공신경망 모델의 학습 추이를 나타낸다. Train loss와 validation loss는 초반에 빠르게 감소한 뒤 일정 값으로 수렴하였다. 학습 결과 과적합은 발생하지 않았다.

해당 모델의 XAI 분석 결과는 실제 FSW 공정에 대한 분석 결과로 판단하기에 충분하다고 판단하였다. 학습된 인공신경망 모델의 용접부 품질 예측 성능은 $R^2 = 0.916$ 이며, $MAPE = 1.49\%$ 였다. R^2 가 0.95 미만으로 예측성능이 test data의 범위 내에서 우수하지는 않아 보이나, 전반적인 예측값의 절대상대오차의 크기는 1.5% 미만으로 준수하였다. 따라서, 구축된 인공지능 모델의 예측은 실제 FSW 공정을 예측 오차 약 1.5% 수준에서 적절히 반영한다고 판단하였다.

4.2 설명가능 인공지능 결과

구축된 인공지능 모델에 대한 SHAP을 적용한 결과인 Fig. 10은 FSW 공정의 공구 온도 프로파일의 특성을 나타내는 입력 변수들이 용접부 품질에 미치는 전반적인 영향도의 정량적인 비교를 나타낸다. Fig. 10에서 “Sh”, “Sh(d)”, “Prb”는 각각 솔더에 가까운 위치, 솔더에서 깊은 위치, 프로브 위치를 나타낸다. “s”는 프로브에서의 온도 프로파일 feature와의 편차임을 의미한다.

각 feature의 상대적인 변화(high=red, low=blue)에 따라서 각 feature의 용접부 인장강도에 대한 기여도의 변화를 나타내는 Fig. 10(a)를 통하여, 각 feature의 증감에 따른 용접부 인장강도의 변동 방향을 분석할 수 있다. 예를 들어, 프로브 위치에서 측정된 온도 프로파일의 안정화 온도(Prb- T_{stbl})의 경우, 값이 양의 방향으로 증가할수록 인장강도에 대한 기여도가 음수에서 양수로 변화한다. 이와 달리 프로브 위치에서 측정된 온도 프로파일 안정화 속도를 나타내는 두번째 시상수(Prb- t_2)의 경우, 해당 값이 증가할수록 용접부 인장강도에 대한 기여도가 양수에서 음수로 변화한다. 따라서, 용접부 인장강도를 증가시키기 위해서는 프로브 위치에서의 안정화 온도는 가급적 높아야하며, 온도 안정화 시점은 가급적 빨라야 함을 의미한다.

XAI 결과 FSW 용접부 인장강도는 프로브 위치에서의 안정화 온도와 안정화 속도가 매우 중요하다고 판단된다. 각 feature의 값

차이에 의한 용접부 인장강도의 기여도 변화가 클수록 해당 feature의 공정 전반에 대한 영향 또는 중요도가 크다고 판단할 수 있다. 이를 나타낸 결과가 Fig. 10(b)이다. 특히, 프로브 위치에서의 안정화 온도가 용접부 인장강도에 가장 큰 영향을 나타내었으며, 해당 온도 프로파일의 안정화 속도를 나타내는 feature의 영향도가 두번째 및 세번째로 큰 영향을 보였다.

4.3 공정 조건과 온도 프로파일 feature 간 연관성

Fig. 11은 각 공정 조건에 따른 입력 feature들의 분포를 나타낸다. Fig. 11(a)에서는 회전속도가 증가함에 따라 온도가 급격히 상승하였고, 약 1,000 rpm 이후부터 완만히 상승하는 경향을 보였다. 반면, 이송속도의 변화에 따른 안정화 온도의 변화는 크지 않았다. Fig. 11(b), (c)에서는 이송속도가 낮을수록, 공구 온도 안정화에 소요되는 시간이 증가하는 경향이 나타났으며, 이러한 경향은 Fig. 11(c)에서 더욱 뚜렷하게 관찰되었다.

4.4 공구 온도와 용접부 인장강도 간 연관성

Fig. 12는 회전속도 및 이송속도와 입력 feature에 따른 인장강도 변화를 나타낸다. Fig. 12(a), (b), (c)는 회전속도와 각 feature에 따른 인장강도 변화를 나타내며, Fig. 12(d), (e), (f)는 이송속도와 각 feature에 따른 인장강도 변화를 보여준다.

공구 회전속도가 증가할수록 인장강도는 뚜렷하게 증가하였다 (Fig. 12(a), (b), (c)). Fig. 12(a), (d)에서는 공구 온도가 상승할수

록 인장강도도 함께 증가하는 경향이 관찰되었다. 앞서 Fig. 11에서 안정화 온도는 이송속도 보다 공구의 회전속도에 주된 영향을 받는 것으로 나타났으므로, Fig. 12(a), (b), (c)의 공구 안정화 온도에 의한 인장강도 상승은 이송속도보다 회전속도에 의한 영향으로 판단할 수 있다.

Fig. 12(b), (c)에서는 대부분의 t_1 이 7-9 s 구간에, Fig. 12(c), (f)에서는 대부분의 t_2 가 10-15 s 구간에 주로 분포되어 있다. 특히 t_2 는 이송속도 400 mm/min 이하 구간에서 이송속도가 증가함에 따라 급격히 감소하였고, 400 mm/min 이상 구간에서는 t_2 도달 시간이 9-10 s 사이에 집중적으로 분포하는 경향을 보였다. t_2 는 공구 온도가 안정화되기까지의 시간을 의미하므로, 이는 이송속도 증가에 따라 공구 온도의 안정화에 소요되는 시간이 점차 짧아진다는 것을 의미한다.

이러한 현상은 공정 중 발생하는 마찰열이 이송속도보다 회전속도의 영향을 더 크게 받는다는 것을 의미한다. Fig. 12(b), (c), (e), (f)에 나타난 이러한 공구 온도 안정화 소요 시간은 Fig. 12(a), (d)에 나타난 공구의 안정화 온도보다 인장강도에 대한 영향이 뚜렷하게 관찰되지는 않는다. 따라서, 이송속도보다 회전속도가 인장강도에 주된 영향을 미치는 공구의 (안정화) 온도에 주된 영향을 미치며, 이는 Aziz et al.의 연구 결과와 일치한다^[34]. 또한 해당 결과는 온도 프로파일 feature의 인장강도에 대한 영향도를 XAI를 이용한 분석결과와 일치한다. Fig. 10(b)의 XAI 결과를 보면, 프로브 위치에서의 안정화 온도가 인장강도에 대해 약 39%의 영

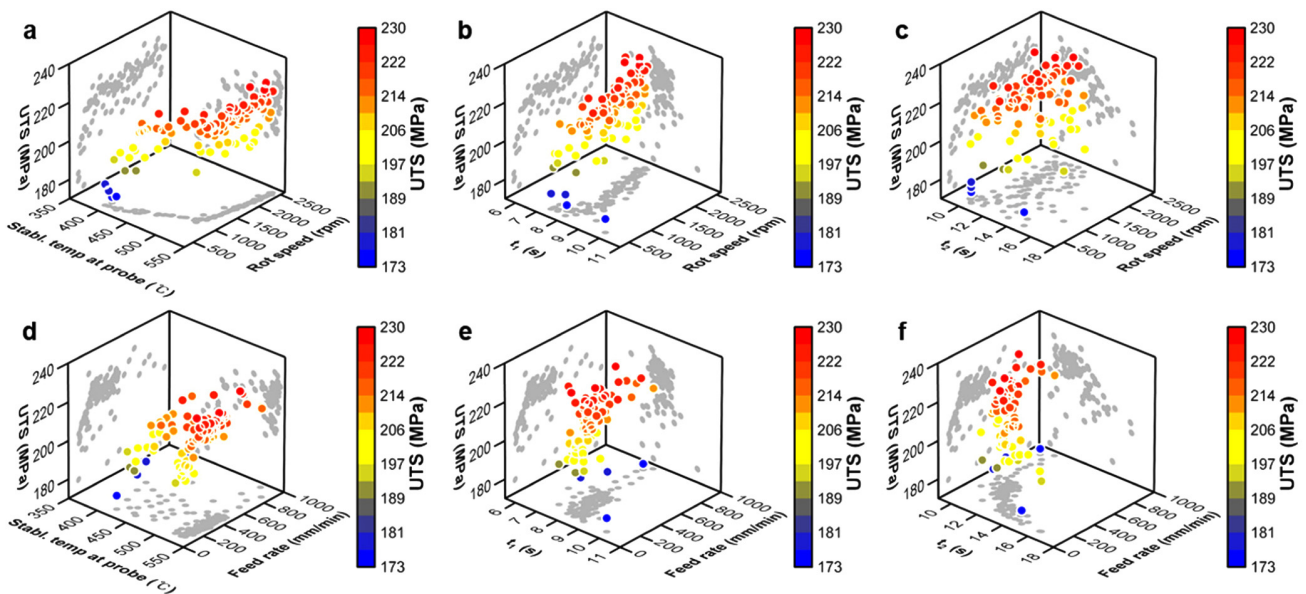


Fig. 12 Relationship between tool temperature profile features and ultimate tensile strength (UTS): (a) effect of rotation speed and stabilized temperature on UTS, (b) effect of rotation speed and t_1 on UTS, (c) effect of rotation speed and t_2 on UTS, (d) effect of feed rate and temperature on UTS, (e) effect of feed rate and t_1 on UTS, and f effect of feed rate and t_2 on UTS

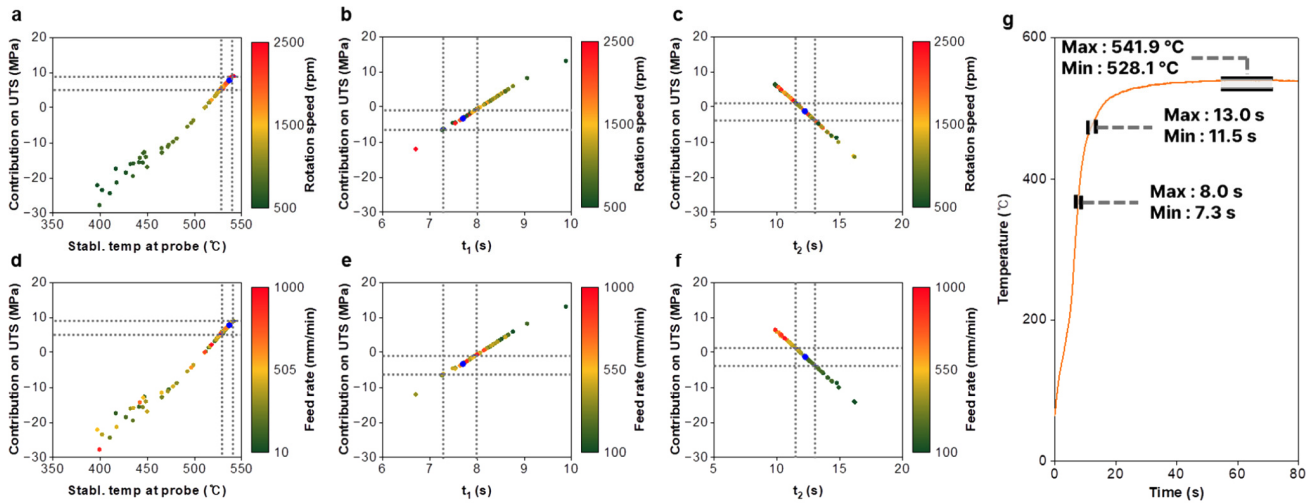


Fig. 13 Proposed monitoring windows: (a) contributions of stabilized temperature, (b) contribution of t_1 , (c) contribution of t_2 to UTS with rotation speed; (d) contribution of stabilized temperature, (e) contribution of t_1 , (f) contribution of t_2 to UTS with feed rate, and (g) proposed process monitoring window overlapped on reference temperature profile

향으로 가장 높은 것으로 나타났다. 이어서 probe의 t_2 가 약 16%, t_1 이 약 13%로, probe에서의 온도 영향이 가장 높은 것으로 나타났다.

5. 설명가능 인공지능 기반 FSW 공정 모니터링

5.1 각 feature의 기여도 기반 모니터링 범위 산정

마찰교반용접에서 용접부의 품질은 공정 중 발생하는 마찰열에 의한 온도로 결정되므로, 해당 온도를 실시간으로 측정하고 모니터링하여 제어한다면 균일한 용접부 품질 확보가 가능하다. 특히, 용접물의 두께가 일정하지 않거나, 곡면/곡선 형상인 경우 용접물의 열전달 조건이 달라지기 때문에 마찰열을 일정하게 유지한다고 하더라도 용접부의 온도의 변동이 생겨 용접부 품질의 변동이 발생할 수 있다. 이에 본 연구에서는 실시간 공구 온도 기반의 마찰교반용접 공정 모니터링 방안을 제안한다^[36].

Fig. 13은 XAI로 분석된 공구의 프로브에서 측정된 온도 프로파일의 feature가 인장강도에 기여하는 정도를 나타낸다. Fig. 13(a)-(c)는 각 feature의 기여도를 회전속도에 따라 표현한 결과이며, Fig. 13(d)-(f)는 이송속도에 따른 분포로 시각화한 결과이다. 각 feature의 인장강도에 대한 기여도를 나타내는 결과를 토대로 온도 모니터링 윈도우를 산정하는 방법은 다음과 같다. 먼저, 1) 해당 분포에서 목표 인장강도를 보이는 조건에 해당하는 feature를 각 feature의 기준(reference)로 선정한다. 2) 인장강도의 관리 범위(기준 인장강도의 -범위, +범위)를 기준 feature의 기여도에 적용하여 상한 및 하한 범위를 산정한다. 3) 기준 feature의 상한 및 하한 범위에 따른 각 feature의 관리 범위를 도출한다.

먼저, 공정 모니터링을 위한 기준 인장강도를 설정하기 위해 선행 연구를 참조하였다. Gomathisankar et al.의 연구^[35]에 따르면, 최적화된 마찰교반용접 조건에서 Al6061-T6의 용접부 인장강도는 228.43 MPa로 보고되었으며, 이를 기준으로 공정 모니터링 및 온도 제어 범위를 설정하였다. 또한 인장강도의 관리 범위는 해당 기준 인장강도의 ± 2.5 MPa로 산정하였다.

인공지능 모델이 인장강도 228.43 MPa를 예측한 경우, 각 feature의 인장강도 예측에 대한 기여도는 안정화 온도의 경우 +7.76 MPa, t_1 은 -6.16 MPa, t_2 는 -1.26 MPa로 나타났다. Fig. 13의 파란색과 심볼은 각 feature의 값과 기여도에 따른 기준 feature를 나타낸다. 각 기준 feature에 인장강도의 관리 범위를 적용하면, 각각의 feature가 유지되어야 할 제어 범위는 다음과 같이 정의된다. 안정화 온도는 Fig. 13(a), (d)에서 528~542°C, t_1 은 Fig. 13(b), (e)에서 7.3~8.0 s, t_2 는 Fig. 13(c), (f)에서 11.5~13.0 s 범위이다. Fig. 13(g)은 각 feature의 관리 범위를 기준 feature에 해당하는 온도 프로파일에 겹쳐 표현한 것이다. 이와 같이 실시간 모니터링 시스템에서 온도 프로파일을 해당 범위 내로 제어한다면 일정한 목표 인장강도(228.43 MPa)를 안정적으로 유지할 수 있을 것으로 판단된다.

5.2 모니터링 방법 검증 분석

앞서 제안한 모니터링 방법의 타당성을 검증하기 위해, 각 feature 기반 모니터링 방법에 대해 confusion matrix 분석을 수행하였다. Confusion matrix는 인공지능 모델의 예측 결과를 기준으로 이진 분류(pass/fail 또는 within/outside)로 판단한 뒤, 판정 오류 유형과 그 빈도를 분석함으로써 모델의 성능을 정량적으로 평가

Table 3 Confusion matrix analysis - Stabilized T

		Actual UTS		Measures
		Pass	Fail	
Monitoring window	Within window	2 (TP)	2 (FP)	Recall 0.5
	Outside window	0 (FN)	6 (TN)	Specificity 1.0
Measures		PPV 1.0	NPV 0.75	Accuracy 0.8

Table 4 Confusion matrix analysis - t_1

		Actual UTS		Measures
		Pass	Fail	
Monitoring window	Within window	1 (TP)	4 (FP)	Recall 0.2
	Outside window	1 (FN)	4 (TN)	Specificity 0.8
Measures		PPV 0.5	NPV 0.5	Accuracy 0.5

Table 5 Confusion matrix analysis - t_2

		Actual UTS		Measures
		Pass	Fail	
Monitoring window	Within window	1 (TP)	3 (FP)	Recall 0.25
	Outside window	1 (FN)	5 (TN)	Specificity 0.83
Measures		PPV 0.5	NPV 0.625	Accuracy 0.6

한다. 이에 기반하여 대표적인 평가지표인 정확도(accuracy), 양성 예측도(positive predictive value, PPV, =정밀도, precision), 음성 예측도(negative predictive value, NPV), 재현율(recall), 특이도(specificity)를 기준으로 제안 방법론을 평가하였다. 참고로, 정확도는 전체 판정 중 정답의 비율을 의미한다. 양성 예측도는 모델이 positive로 예측한 샘플 중 실제로도 positive인 비율을 나타내며, 음성 예측도는 모델이 negative로 예측한 샘플 중 실제로도 negative인 비율을 나타낸다. 재현율은 실제 positive 샘플 중 모델이 positive로 정확히 예측한 비율이며, 특이도는 실제로 negative인 샘플 중 모델이 negative로 예측한 비율을 나타낸다.

Table 3~5는 각 feature에 대한 confusion matrix 분석 결과이다. 분석 대상은 안정화 온도, t_1 , t_2 이다. Pass 및 fail 판정 기준은 실제 인장강도가 관리범위 내에 있는지 또는 외에 있는지이다. Within/outside 판정 기준은 제시된 모니터링 윈도우 내에 있는지 또는 외에 있는지이다. 판정에는 인공지능 모델 학습에 사용되지 않은 test 데이터를 사용하였다.

Table 3의 Stabilize T는 모든 판정 기준에서 가장 우수한 판정

성능을 보였다. 이를테면 제안 모니터링 방법에 따른 용접부 인장강도의 pass/fail의 정확도는 80% 이었다. 안정화 온도가 제안된 모니터링 윈도우 내에 위치하는 경우(within window) 중에서 실제 인장강도가 관리범위 내에 위치하는 비율은(양성 예측도, PPV) 100% 였다. 그리고 제안된 모니터링 윈도우 밖에 안정화 온도가 위치(outside window)하여 인장강도가 관리범위 밖에 위치할 것이라는 예측(음성 예측도, NPV)의 적중 비율은 75% 였다. 실제 인장강도가 관리범위 내에 있는 경우(pass) 중 모니터링 윈도우가 적중한 비율(재현율, recall)는 50%, 관리범위 밖에 있는 경우(fail) 중 모니터링 윈도우가 적중한 비율(특이도, specificity)은 100% 였다.

종합하자면, 제안된 모니터링 윈도우 방법론으로 용접부의 인장강도를 판정하는 경우, 안정화 온도가 모니터링 범위 내에 위치하더라도 인장강도가 관리범위 밖에 위치하여 fail인 경우(pass를 잘못 판단)는 50%이지만, 안정화 온도가 모니터링 범위 밖에 위치하는 경우는 모두 인장강도가 관리범위 밖에 위치(fail을 옳게 판단)하였다. 따라서, 제안된 모니터링 윈도우 방법은 마찰교반용접의 불량률 검출하는데 유용할 것으로 판단한다.

인장강도 예측에 대한 영향도가 낮은 타 feature를 이용한 모니터링 윈도우(Table 4 및 Table 5)의 경우, 전반적인 판정의 정확도는 낮으나, 인장강도의 관리범위 불만족(fail)을 판정하는데 활용 가능성이 있다고 판단된다. Table 4, 5에서 t_1 , t_2 각각은 recall 및 precision(PPV) 모두 50% 이하의 성능을 보였다. 이는 해당 feature를 이용한 제안 모니터링 방법론을 활용하여 pass 판정을 하기에는 부족함을 의미한다. 하지만, 모니터링 윈도우 밖에 각 feature가 위치하여 인장강도가 관리범위 밖에 위치(fail) 할 것이라는 판정의 각각 80%, 83%의 성능을 보였다. 즉, 앞서 안정화 온도를 이용한 모니터링 판정과 유사하게, 타 feature를 이용한 제안 방법론의 모니터링 윈도우는 마찰교반용접의 불량(fail)을 검출하는데 유용할 것으로 판단한다.

6. 결론

본 연구에서는 마찰교반용접에서 정확한 인장강도 예측과 최적화를 위해 공정 중 마찰교반용접 공구에서 발생하는 온도를 측정하였다. 100종의 다양한 공정조건에 해당하는 용접부의 인장강도와 각 조건에서의 공구 온도 프로파일을 분석하였다. 측정된 공구 온도 프로파일에서 시계열 데이터의 feature를 추출하여 인장강도를 예측하기 위한 인공지능 모델의 입력으로 사용하였다. 인공지능 모델의 입력 feature가 예측 결과에 미치는 영향도, 즉 공구 온도 프로파일의 인장강도에 대한 영향도를 분석하기 위해 설명가능 인공지능(XAI)을 적용하였다. 이에 본 연구에서는 다음의 결론을

도출하였다.

1) 측정된 공구 온도 프로파일의 feature가 인장강도 예측에 미치는 영향도는 공구의 probe에서의 안정화 온도가 39%로 가장 크게 나타났고, 온도의 안정화 속도를 나타내는 feature인 t_2 와 t_1 이 각각 16%, 13% 이었다. 따라서, 마찰교반용접의 용접부 인장강도에는 공구의 안정화 온도가 지배적인 영향을 보인다.

2) 마찰교반용접 공정조건에 따른 온도 프로파일의 영향을 분석한 결과, 마찰교반용접 시 발생하는 열에 의한 공구의 안정화 온도는 이송속도 보다 회전속도의 영향이 더 지배적이다.

3) XAI로 분석된 각 feature의 인장강도에 대한 기여도 분포를 기반으로, 마찰교반용접부 인장강도 측면에서의 공구 온도 모니터링 윈도우를 선정할 수 있으며, 본 연구에서 적용된 공구와 용접물의 경우 공구의 온도는 528~542°C 범위 내로 제어되어야 한다.

4) 제안된 모니터링 방법의 신뢰성을 검증한 결과, 인장강도에 대한 영향도가 높은 feature를 이용한 모니터링 윈도우 산정이 적절하였다.

5) 선정된 모니터링 윈도우는 특히 인장강도가 선정된 관리범위 밖으로 벗어나 불량이 되는 공정 상황을 검출하는데 높은 성능을 나타내었다. 따라서, 제안 방법론은 마찰교반용접 공정의 불량을 사전에 검출하고 예방하는데 활용될 수 있다.

제안된 방법은 추후 실시간 공정 제어를 통해 산업현장에서 안정적인 용접 품질을 유지할 수 있고, 공구 온도의 실시간 모니터링을 통해 용접부의 품질을 예측하여 제품 생산성에 기여할 수 있다. 또한 해당 방법은 마찰교반용접 뿐만 아니라 여러 공정 프로세스의 안정성을 개선하고 자율 제조에 적용할 수 있을 것으로 기대된다.

후 기

이 연구는 2025년도 한국생산기술연구원의 기본사업 ‘설명가능 인공지능(XAI) 및 무선 툴 온도 모니터링 기반 Hemispherical 툴 FSW 공정 기술 개발’의 지원을 받아 수행되었음(KITECH JE25 0027).

References

- [1] Salish, O. S., Ou, H., Sun, W., McCartney, D. G., 2015, A Review of Friction Stir Welding of Aluminium Matrix Composites, *Materials and Design*, 86 67-71, <https://doi.org/10.1016/j.matdes.2015.07.071>.
- [2] Mandal, S., Rice, J., Elmustafa, A. A., 2008, Experimental and Numerical Investigation of the Plunge Stage in Friction Stir Welding, *J. Mater. Process. Technol.*, 203:1-3 411-419, <https://doi.org/10.1016/j.jmatprotec.2007.10.067>.
- [3] He, X., Gu, F., Ball, A., 2014, A Review of Numerical Analysis of Friction Stir Welding, *Prog. Mater. Sci.*, 65 1-66, <https://doi.org/10.1016/j.pmatsci.2014.03.003>.
- [4] Venkatesh K. M., Arivarsu, M., Manikandan, M., Arivazhagan, N., 2018, Review on Friction Stir Welding of Steels, *Materials Today: Proceedings*, 5:5:Part 2 13227-13235, <https://doi.org/10.1016/j.matpr.2018.02.313>.
- [5] Mishra, R. S., Ma, Z. Y., 2005, Friction Stir Welding and Processing, *Materials Science and Engineering: R: Reports*, 50:1-2 1-78, <https://doi.org/10.1016/j.mser.2005.07.001>.
- [6] Gibson, B. T., Lamlein, D. H., Prater, T. J., Longhurst, W. R., Cox, C. D., Ballun, M. C., Dharmaraj, K. J., Cook, G. E., Strauss, A. M., 2014, Friction Stir Welding: Process, Automation, and Control, *J. Manuf. Process.*, 16:1 56-73, <https://doi.org/10.1016/j.jmapro.2013.04.002>.
- [7] Liu, F. C., Hovanski, Y., Miles, M. P., Sorensen, C. D., Nelson, T. W., 2018, A Review of Friction Stir Welding of Steels: Tool, Material Flow, Microstructure, and Properties, *J. Mater. Sci. Technol.*, 34:1 39-57, <https://doi.org/10.1016/j.jmst.2017.10.024>.
- [8] Meng, X., Huang, Y., Cao, J., Shen, J., dos Santos, J. F., 2021, Recent Progress on Control Strategies for Inherent Issues in Friction Stir Welding, *Prog. Mater. Sci.*, 115 100706, <https://doi.org/10.1016/j.pmatsci.2020.100706>.
- [9] Song, M., Kovacevic, R., 2002, Thermal Modeling of Friction Stir Welding in a Moving Coordinate System and Its Validation, *Int. J. Mach. Tools Manuf.*, 43:6 605-615, [https://doi.org/10.1016/S0890-6955\(03\)00022-1](https://doi.org/10.1016/S0890-6955(03)00022-1).
- [10] Kumaraswamy, S., Malik, V., Devaraj, S., Jain, V. K., Avinash, L., 2021, A Study of Shear Friction Factor in Friction Stir Welding for Developing a Finite Element Model and Its Importance in the Context of Formation of Defect Free and Defective Weld, *Materials Today: Proceedings*, 45:Part 1 299-303, <https://doi.org/10.1016/j.matpr.2020.10.651>.
- [11] Asadi, P., Aliha, M. R. M., Akbari, M., Imani, D. M., Berto, F., 2022, Multivariate Optimization of Mechanical and Microstructural Properties of Welded Joints by FSW Method, *Eng. Fail. Anal.*, 140 106528, <https://doi.org/10.1016/j.engfailanal.2022.106528>.
- [12] Türkan, M., Karakaş, Ö., 2022, Numerical Modeling of Defect

- Formation in Friction Stir Welding, *Mater. Today Commun.*, 31 103539, <https://doi.org/10.1016/j.mtcomm.2022.103539>.
- [13] Buffa, G., Hua, J., Shivpuri, R., Fratini, L., 2006, Design of the Friction Stir Welding Tool Using the Continuum Based FEM Model, *Mater. Sci. Eng. A*, 419:1-2 381-388, <https://doi.org/10.1016/j.msea.2005.09.041>.
- [14] Sharma, C., Dwivedi, D. K., Kumar, P., 2012, Effect of Welding Parameters on Microstructure and Mechanical Properties of Friction Stir Welded Joints of AA7039 Aluminum Alloy, *Materials & Design (1980-2015)*, 36 379-390, <https://doi.org/10.1016/j.matdes.2011.10.054>.
- [15] Balasubramanian, V., 2008, Relationship Between Base Metal Properties and Friction Stir Welding Process Parameters, *Mater. Sci. Eng. A*, 480:1-2 397-403, <https://doi.org/10.1016/j.msea.2007.07.048>.
- [16] Imam, M., Biswas, K., Racherla, V., 2013, On Use of Weld Zone Temperatures for Online Monitoring of Weld Quality in Friction Stir Welding of Naturally Aged Aluminum Alloys, *Materials & Design (1980-2015)*, 52 703-739, <https://doi.org/10.1016/j.matdes.2013.06.014>.
- [17] Abolusoro, O. P., Akinlabi, E. T., Kailas, S. V., 2020, Tool Rotational Speed Impact on Temperature Variations, Mechanical Properties and Microstructure of Friction Stir Welding of Dissimilar High-strength Aluminum Alloys, *J. Braz. Soc. Mech. Sci. Eng.*, 42 176, <https://doi.org/10.1007/s40430-020-2259-9>.
- [18] De Filippis, L. A. C., Serio, L. M., Facchini, F., Mummolo, G., Ludovico, A. D., 2016, Prediction of the Vickers Microhardness and Ultimate Tensile Strength of AA5754 H111 Friction Stir Welding Butt Joints Using Artificial Neural Network, *Materials*, 9:11 915, <https://doi.org/10.3390/ma9110915>.
- [19] Nie, L., Wu, Y. X., Gong, H., 2020, Prediction of Temperature and Residual Stress Distributions in Friction Stir Welding of Aluminum Alloy, *Int. J. Adv. Manuf. Technol.*, 106 3301-3310, <https://doi.org/10.1007/s00170-019-04826-4>.
- [20] Cho, M., Gim, J., Kim, J. H., Kang, S., 2024, Development of an Artificial Neural Network Model to Predict the Tensile Strength of Friction Stir Welding of Dissimilar Materials Using Cryogenic Processes, *Applied sciences*, 14:20 9309, <https://doi.org/10.3390/app14209309>.
- [21] Avdelidis, N. P., Moropoulou, A., 2003, Emissivity Considerations in Building Thermography, *Energy and Build.*, 35:7 663-667, [https://doi.org/10.1016/S0378-7788\(02\)00210-4](https://doi.org/10.1016/S0378-7788(02)00210-4).
- [22] Maio, L., Liberini, M., Campanella, D., Astarita, A., Esposito, S., Boccardi, S., Meola, C., 2017, Infrared Thermography for Monitoring Heat Generation in a Linear Friction Welding Process of Ti6Al4V Alloy, *Infrared Phys. Technol.*, 81 325-338, <https://doi.org/10.1016/j.infrared.2017.01.023>.
- [23] Hwang, Y.-M., Kang, Z.-W., Chiou, Y.-C., Hsu, H.-H., 2008, Experimental Study on Temperature Distributions Within the Workpiece During Friction Stir Welding of Aluminum Alloys, *Int. J. Mach. Tools Manuf.*, 48:7-8 778-787, <https://doi.org/10.1016/j.ijmactools.2007.12.003>.
- [24] Silva, A. C. F., De Backer, J., Bolmsjö, G., 2017, Temperature Measurements During Friction Stir Welding, *Int. J. Adv. Manuf. Technol.*, 88 2899-2908, <https://doi.org/10.1007/s00170-016-9007-4>.
- [25] Wang, H., He, D., Liao, M., Liu, P., Lai, R., 2021, Study on Quality Prediction of 2219 Aluminum Alloy Friction Stir Welding Based on Real-Time Temperature Signal, *Materials*, 14:13 3496, <https://doi.org/10.3390/ma14133496>.
- [26] Hu, Y., Wang, Y., Zhao, S., Ji, Y., 2023, Effect of Tool-workpiece Interface Temperature Control on the Weld Quality of a Bobbin-tool Friction-stir-welded Aluminum Alloy, *Int. J. Adv. Manuf. Technol.*, 128 4379-4396, <https://doi.org/10.1007/s00170-023-12077-7>.
- [27] Abboud, M., Dubourg, L., Racineux, G., Kerbrat, O., 2024, Experimental Methodology to Identify Optimal Friction Stir Welding Parameters Based on Temperature Measurement, *J. Manuf. Mater. Process.*, 8:4 137, <https://doi.org/10.3390/jmmp8040137>.
- [28] Cho, M., Gim, J., Kim, J., Park, M.-S., Lee, H.-H., Kang, S., 2025, Development of a Real-Time Wireless Tool Temperature Measurement System for Friction Stir Welding Monitoring, *J. Koeran Soc. Manuf. Technol. Eng.*, 34:2 96-103, <https://doi.org/10.7735/ksmte.2025.34.2.96>.
- [29] Gim, J., Cho, M., Kim, J., Lee, K.-J., Neelakandan, D. P., Lee, C., Jung, Y. C., Kang, S., 2025, Design and Application of Wireless Tool Temperature Measurement of Friction Stir Welding (FSW) for Process Monitoring and Control, *Measurement*, 252 117395, <https://doi.org/10.1016/j.measurement.2025.117395>.
- [30] Gim, J., Lin, C.-Y., Turng, L.-S., 2024, In-mold Condition-centered and Explainable Artificial Intelligence-

based (IMC-XAI) Process Optimization for Injection Molding, *J. Manuf. Syst.*, 72 196-213, <https://doi.org/10.1016/j.jmsy.2023.11.013>.


- [31] Gim, J., Turng, L.-S., 2023, Interpretation of the Effect of Transient Process Data on Part Quality of Injection Molding Based on Explainable Artificial Intelligence, *Int. J. Prod. Res.*, 61:23 8192-8212, <https://doi.org/10.1080/00207543.2023.2216310>.
- [32] Gim, J., Lin, C.-Y., Turng, L.-S., 2024, Analysis Methodology for Effect of In-Mold Condition (IMC) on Quality based on Explainable Artificial Intelligence (XAI) in Injection Molding, *J. Koeran Soc. Manuf. Technol. Eng.*, 33:5 251-261, <https://doi.org/10.7735/ksmte.2024.33.5.251>.
- [33] Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., Katz, R., Himmelfarb, J., Bansal, N., Lee, S.-I., 2020, From Local Explanations to Global Understanding With Explainable AI for Trees, *Nat. Mach. Intell.*, 2 56-67, <https://doi.org/10.1038/s42256-019-0138-9>.
- [34] Aziz, S. B., Dewan, M. W., Huggett, D. J., Wahab, M. A., Okeil, A. M., Liao, T. W., 2016, Impact of Friction Stir Welding (FSW) Process Parameters on Thermal Modeling and Heat Generation of Aluminum Alloy Joints, *Acta Metall. Sin. (Engl. Lett.)*, 29 869-883, <https://doi.org/10.1007/s40195-016-0466-2>.
- [35] Gomathisankar, M., Gangatharan, M., Pitchipoo, P., 2017, A Novel Optimization of Friction Stir Welding Process Parameters on Aluminum Alloy 6061-T6, *Materials Today: Proceedings*, 5:6:part2 14397-14404, <https://doi.org/10.1016/j.matpr.2018.03.025>.
- [36] Gim, J., Cho, M., Kim, W., 2025, Explainable Artificial Intelligence-Based Sensor Signal Monitoring Window Selection Method and Selection System Therefor, *KR Patent Application*: 10-2025-0091460.



Mingoo Cho

Researcher in Korea Institute of Industrial Technology (KITECH) & Ph. D. Candidate in School of Mechanical Engineering, Pusan National University. His research interests are Friction Stir Welding, Finite Element Analysis and Artificial Intelligence.

E-mail: cmg0142@pusan.ac.kr



Jaehwang Kim

Principal Researcher, Korea Institute of Industrial Technology (KITECH). His research interests are Light Metal and Artificial Intelligence.

E-mail: raykim@kitech.re.kr



Kwang-Jin Lee

Principal Researcher, Korea Institute of Industrial Technology (KITECH). His research interests are Light Metals and Its Application Process Technologies Using Artificial Intelligence.

E-mail: kjlee@kitech.re.kr



Deva Prasad Neelakandan

Graduate research assistant in the Department of Mechanical Engineering, Auburn University in U.S. His research interest is Identification of Mechanical Mechanisms in Refractory High Entropy Alloys.

E-mail: dzn0037@auburn.edu



Chanho Lee

Professor in the Department of Mechanical Engineering, Auburn University in U.S. His research interests are Designing New Alloys for Extreme Environmental Applications.

E-mail: czl0176@auburn.edu



Yoon Chul Jung

Senior Researcher, R&D Center of DnM Aerospace. His research interest is Friction Stir Welding Process and Tools.


E-mail: yoon3324@naver.com



Sungwook Kang

Associate Professor in Changwon National University (CWNU). His research interests are Friction Stir Welding, Finite Element Analysis, Thermal Elasto-Plastic Simulation and Topology Optimization.

E-mail: swkang@changwon.ac.kr



Jinsu Gim

Senior Researcher, Korea Institute of Industrial Technology (KITECH). His research interests are Autonomous Manufacturing Using In-Process Sensors and Artificial Intelligence, Polymer/Plastic/Composite Processing Including Molding and Forming, Rheology, and Mold Technology.

E-mail: jgim@kitech.re.kr