

머신러닝을 이용한 레이저 용접부의 모델링

Part II: 고강도강 겹치기 레이저용접부의 형상 및 기계적 거동

유현정^{*,**} · 강민정^{***} · 이 성^{*} · 현승균^{**} · 김철희^{*,***,†}

^{*}포틀랜드주립대학 기계재료공학과

^{**}인하대 신소재공학과

^{***}한국생산기술연구원 용접집합그룹

Modeling of Laser Welds Using Machine Learning Algorithm

Part II: Geometry and Mechanical Behaviors of Laser Overlap Welded High Strength Steel Sheets

Hyeonjeong You^{*,**}, Minjung Kang^{***}, Sung Yi^{*}, Soongkeun Hyun^{**} and Cheolhee Kim^{*,***,†}

^{*}Department of Mechanical and Materials Engineering, Portland State University, OR 97229, USA

^{**}Department of Materials Science and Engineering, Inha University, Incheon, 22212, Korea

^{***}Joining R&D Group, KITECH, Incheon, 21999, Korea

[†]Corresponding author: chkim@kitech.re.kr

(Received December 25, 2020; Revised January 22, 2021; Accepted February 8, 2021)

Abstract

In accordance with the requirements of lightweight automobiles, the application of high-strength steel sheets to car bodies is continuously increasing. The strength of the laser overlap welds is determined by the strength distribution of weldments and the bead width at the faying surface. In the case of high-strength steel sheets, it is difficult to predict the fracture load and fracture mode during the tensile shear test of the weldment owing to the high strength of the base material, softening of the heat affected zone (HAZ), and small bead width. In this study, we investigated machine learning algorithms, including artificial neural networks, to develop a fracture mode classification model and regression models for joint strength and bead width. Machine learning algorithms have shown excellent performance in predicting mechanical behaviors during tensile shear tests. Among the machine learning regression algorithms, Gaussian process regression showed the best regression ability. The R² values for the bead width and fracture load models were 0.98 and 0.99, respectively. Several machine learning models, including shallow neural networks, have shown perfect estimates for fracture locations.

Key Words: Machine learning, Laser welding, High strength steel, Overlap welding, Joint strength, Fracture mode

1. 서 론

아자동차 경량화 추세에 따라 자동차 차체에는 고강도강과 경량 비철금속의 적용이 확대되고 있다. 이 중 고강도강의 경우 성형성이 우수한 TRIP (Transformation Induced Transformation)강과 마르텐사이트를 이용하여 강도를 향상시키는 DP (Dual Phase), CP (Complex Phase), MART (MARTensitic)강 등이 채택되어 자

동차에 적용되고 있으며, 비교적 최근에는 HPF (Hot Press Forming)강이 적용되면서 열간성형을 통해 부품 성형이 가능하게 되어 2.0 GPa급 강판 소재의 적용이 검토되고 있다¹⁻³⁾. 자동차용 차체에 사용되는 박판의 경우 하중을 지지하기 위한 주된 겹치기 용접기법으로 저항점용접이 적용되고 있는데⁴⁾, 편면 용접이 가능하고 좁은 플랜지 길이를 사용할 수 있는 레이저용접이 저항점용접을 대체할 수 있어 다양한 소재에 대한 레이저용접 연구를 수행하고 있다⁵⁻⁹⁾.

자동차용 박판의 겹치기 용접시험편에 인장전단 하중이 걸릴 경우 용접부가 파단되지 않고 모재나 열영향부가 파단되는 것이 용접부에 요구되는 특성이므로 저항점 용접의 경우 소재 두께의 제곱근의 4~5배의 용접 너깃을 만들어서 충분한 강도를 지지하도록 용접공정을 설계하고 있다. 레이저 용접의 경우 모재와 용접부의 강도가 균일할 경우 폰 미세스(von Mises)나 트레스카 기준에 따라 소재 두께의 1.7~2배의 용접계면길이를 확보하도록 설계된다. 예전 Nd:YAG 레이저나 CO₂ 레이저를 연강의 겹치기 용접부에 적용할 경우 용접부가 소재에 비해 3배 가량의 강도를 가지고, 상대적으로 큰 레이저 빔의 크기로 인해 좁은 비드 형성이 되지 않았으므로 대부분의 경우 계면 파단을 피할 수 있었다. 그러나 최근에는 아래 이유로 계면 파단이 발생하는 경우가 관찰되고 있다. 먼저 디스크레이저, 파이버레이저 등 고휘도 레이저가 적용되어 수십 마이크로미터 단위의 레이저 빔을 강판 용접에 적용할 수 있고 증횡비가 아주 큰 용접부의 형성이 가능하다. 또한 모재의 조직이 완전마르텐사이트일 경우 용접부가 가지는 최대 강도가 모재와 동일한 수준이므로 연강에 비해 더 넓은 계면에서의 용접비드폭이 요구되고 있다. 여기에 더하여 780 MPa 이상의 소재에서는 용접할 경우 열영향부의 연화가 발생하므로 파단 양상에 대한 예측이 복잡해지고 있다⁵⁾. 고강도강의 레이저겹치기 용접부에서의 파단 위치 및 파단 강도는 인장-전단시험에서의 하중의 어긋남에 따른 시험편의 변형¹⁰⁻¹³⁾, 레이저 입열에 따른 계면에서의 용접비드폭 및 용접부의 경도분포¹⁴⁾ 등에 의해 결정된다. 이중 용접부의 경도 분포는 모재의 화학적 조성 및 냉각 곡선에 따라 결정이 되므로 상대적으로 복잡한 모델들¹⁴⁻¹⁸⁾을 통해서 설명되고 있으나 아직 이를 설명할 수 있는 통일된 이론적 모델은 계속 연구 중에 있다.

이와 상대적으로 다양한 머신러닝 기술의 발전에 따라 이론적 모델에 따른 용접현상의 모델링이 아닌 데이터에 기반한 용접부의 모델링 기술은 점차 적용이 확대되고 있다. 1990년대부터 신경회로망¹⁹⁻²¹⁾, 유전알고리즘²²⁾ 및 표면반응모델²³⁾ 등 머신러닝 기술을 이용한 연

구가 용접분야에 소개되었으며 최근의 딥러닝 기술의 발전으로 인해 최근 연구가 폭발적으로 증가하고 있다^{24,25)}. 또한 레이저 용접의 강도 및 비드폭을 예측하기 위해 SVR (Support Vector Regression), 가우스 프로세스 (Gaussian Process), 신경회로망을 이용한 논문이 최근 소개되었으나 단 하나의 소재에 실시한 제한된 실험데이터로 각 머신러닝 알고리즘이 적용가능하다고 소개하는 수준에 불과하였다²⁶⁾. 본 연구의 1편²⁷⁾에서는 머신러닝을 이용하여 Cu/Al의 이종재료의 조합에서 레이저용접현상의 모델링이 가능한지 검토하였으며, 본 논문에는 590 MPa에서 1500 MPa급 강도 소재에 대해 다양한 동종 및 이종소재의 겹치기 용접부에 다양한 용접조건으로 레이저용접을 수행한 데이터¹⁴⁾를 이용하여, 파단 위치의 분류, 계면 비드폭과 파단 강도의 회귀에 다양한 머신러닝 알고리즘을 적용하여 수학적 모델 없이 데이터에 기반한 모델로 고강도강 용접현상의 예측이 가능한지 확인하고자 하였다.

2. 데이터 수집 및 모델링방법

2.1 데이터의 수집

본 연구에서 기계학습 모델에 사용한 학습 데이터는 Kang의 논문¹⁴⁾에 공개된 다양한 고강도강의 동종·이종 강판 겹치기용접부에 대한 데이터를 이용하였다. 실험에 사용된 재료는 590 MPa부터 1500 MPa까지의 인장강도를 갖는 고강도강으로, 대상 강종의 화학 조성은 Table 1과 같다. 1500 HPF 강은 두께 1.1 mm를, 그 외에 다른 강은 모두 두께가 1.2 mm인 것을 사용하였다. 코팅층의 화학적인 영향을 제거하고자 HPF 1500 강은 표면의 코팅을 가공하여 제거했으며, 실험에 사용된 강은 모두 코팅되지 않은 강판을 사용했다. 이중 접합의 경우 저강도 강판을 위에 놓고 용접을 수행하였다. 1180 CP강을 제외한 다른 강은 모두 탄소 함량을 높여 강도를 증가시켰으며, 다양한 탄소 당량 조건을 얻기 위해 총 15개의 조합을 만들었다.

레이저 용접을 적용하여 동종 접합과 이종 접합을 수행했으며, 계면에서의 비드폭과 인장-전단 시험을 통해

Table 1 Chemical compositions of base materials (wt. %)

Base materials (thickness)	C	Si	Mn	P	S	Cr	B
590 DP (1.2 mm)	0.078	0.363	1.808	0.011	0.001	-	-
780 DP (1.2 mm)	0.070	0.977	2.264	0.010	0.015	-	-
980 DP (1.2 mm)	0.170	1.340	2.000	0.016	0.001	-	-
1180 CP (1.2 mm)	0.110	0.110	2.790	0.019	0.004	1.040	-
1500 HPF (1.1 mm)	0.216	0.240	1.255	0.002	0.002	0.001	0.003

파단 강도와 파단 위치를 측정했다. 계면 비드폭은 레이저 출력, 용접 속도 및 초점 위치와 같은 매개 변수의 영향을 받기 때문에 레이저 출력은 3.5 kW로 고정시키고, 초점 위치는 5 mm 간격으로 0~25 mm까지 설정되었다. 레이저빔은 시험편의 접침면의 중심에 수직으로 조사되었다. 용접 속도는 주어진 초점 위치에서 용접 시 완전히 용입된 비드를 얻을 수 있는 16~72 mm/s 범위 내에서 지정되었다. 동일 조건에서 5개의 시험편에 대해 평가를 수행하고 평가결과의 평균값을 데이터로 활용하였다.

기계학습 모델을 구축하기 위해 입력 데이터는 Table 2와 같이 상판의 화학 조성, 하판의 화학 조성, 용접 속도 및 초점 위치로 총 16개의 파라미터로 구성하였다. 그에 따른 출력 데이터는 계면에서의 비드폭, 파단 강도 및 파단 위치로, 논문의 데이터를 기반으로 총 90개의 조건에 대한 출력 데이터를 수집하였다.

2.2 머신러닝 모델

준비된 데이터 세트를 MATLAB® R2020a 버전을 활용하여 기계학습 모델을 구현하고 성능을 검증하였다.

계면에서의 비드폭과 파단 강도를 예측하기 위해 사용한 회귀 학습 모델은 선형 회귀 (Linear Regression), 의사결정 트리(Decision Tree), 서포트 벡터 머신(Support Vector Machine, SVM) 및 가우스 프로세스 회귀(Gaussian Process Regression, GPR) 모델을 사용했다. 선형 회귀는 상호 작용 항을 사용한 모델을 적용했으며, 의사결정 트리는 과적합이 일어나기 쉬운 단점을 보완하기 위해 여러 개의 독립적인 회귀 트리를 이용해 순차적으로 학습한 후 결과에 따라 가중치를 부여하고, 다음 모델의 결과 예측에 영향을 주는 방법을 사용하였다. 서포트 벡터 머신은 커널 함수가 3차로 이루어진 비선형 SVM 모델을 적용했으며, 가우스 프로세스 회귀모델은 지수 커널 함수를 사용하였다.

파단 위치를 예측하기 위해 사용한 분류 학습 모델은 의사결정 트리(Decision tree), 나이브 베이즈(Naive bayes), 서포트 벡터 머신(SVM), 최근접 이웃 분류(K-Nearest neighbors, KNN) 모델을 사용했다. 의사결정 트리는 분기된 잎노드에 연결된 데이터의 개수가 36개 이하인

분류 트리 모델을 적용했으며, 나이브 베이즈 모델은 연속적인 값을 지닌 데이터 처리를 위해 가우스 분포를 통해 고차원 데이터 세트에 이용되는 모델을 사용했다. 서포트 벡터 머신은 가우스 커널 함수를 사용하여 비선형 분류기를 생성하여 사용했으며, 최근접 이웃 분류 모델은 새로운 데이터를 입력했을 때 K 번째까지의 거리에 있는 기존에 분류한 데이터들과 유사도를 측정하고 가장 비슷한 카테고리로 입력 데이터를 분류하는 방법을 사용하였다. 자세한 알고리즘에 대한 설명은 본 연구의 1편에 소개하였다²⁷⁾.

마지막으로, 모든 출력값에 대해 각각 인공신경망을 이용해 기계학습 모델을 구성하였다. 인공신경망 모델은 입력층, 은닉층, 출력층이 다수의 노드로 구성되며, 입력값과 출력값을 미리 알고 있는 지도학습을 통해 수행되었다. 1개의 은닉층을 가진 얇은 신경망(Shallow Neural Network, SNN)을 사용하여 모델을 구성하였고, SNN의 입력층과 출력층의 노드 수는 입력 노드 수는 입력 파라미터 수와 같은 16이며, 은닉층의 노드 수는 30개로 선정하였다. 출력 노드는 출력 파라미터 수와 같이 회귀모델의 경우 2개, 분류모델의 경우는 1개이다. 학습(Training), 검증(Validation), 테스트(Testing) 데이터는 각각 62, 14, 14개로 나누어 데이터 정확도를 분석하였다.

3. 결과 및 토론

3.1 회귀모델 분석 결과

레이저 용접 비드폭과 인장-전단 시험을 통해 얻을 수 있는 파단 강도를 예측하기 위해 Table 2에 나타난 것과 같이 총 16개의 파라미터를 사용하여 각각 회귀 분석을 실시하였다. 회귀모델의 정확도를 확인하기 위해 오차와 결정계수를 나타내었다. 오차는 박스 플롯(box plot)을 이용하여 나타냈으며, 박스 플롯 위에서부터 최대값, 3사분위수, 중앙값, 1사분위수, 최소값으로 이루어져 있다. 또한 회귀모델의 적합성을 판단하기 위해서 잔차분석을 실시하였다. 잔차분석은 실제 측정치와 그에 따른 잔차의 산점도를 그려서 나오는 패턴을 통해 설명변수의 유의성을 검정할 수 있다.

Table 2 Input and output parameters to construct machine learning models

No.	1~7	8~14	15	16
Input parameter	Chemical composition of the upper sheet	Chemical composition of the lower sheet	Welding speed	Focal position
	Regression model		Classification model	
Output parameter	Bead width at the faying surface	Fracture load	Fracture location	

3.1.1 비드폭 회귀모델 분석 결과

Fig. 1은 계면에서 실제 측정된 비드폭과 회귀모델을 통해 예측한 비드폭에 대한 오차를 박스 플롯으로 나타내었다. 모든 회귀모델의 오차는 -0.3~0.3 mm 내에 위치하며, 편향되지 않고 비교적 고르게 분포한다. 평균 오차는 선형 회귀가 0.08 mm, 회귀 트리 0.09 mm, SVM이 0.06 mm, GPR이 0.04 mm로 GPR이 가장 작은 평균 오차를 가지는 것을 확인할 수 있었다. 전체적으로 표준 편차는 0.09~0.10 mm으로 비슷하고, GPR은 0.06 mm로 가장 작은 값을 가진다.

Table 3은 회귀모델로 예측한 비드폭의 결정계수를 보여준다. 모든 모델은 0.9 이상의 결정계수를 가지며, GPR의 경우 0.98로 가장 높은 결정계수 값을 가진다. GPR이 다른 회귀모델에 비해 작은 오차와 높은 결정계수를 가지는 것을 확인할 수 있다. GPR이 모델의 확장성이 높기 때문에 0.98의 우수한 결정계수 값을 가지는 것으로 판단된다.

Fig. 2는 비드폭에 대한 회귀모델의 잔차분석 그래프를 나타내었다. 선형 회귀모델과 회귀 트리 모델은 다른 모델에 비해 잔차가 무작위로 분포하지 않고 측정된 비드폭이 1.6 mm 이상인 부분에서 우상향으로 경향성이 나타나는 것을 확인할 수 있다. SVM 회귀모델과 GPR 모델은 잔차가 무작위로 분포되어 있으며, 잔차




Fig. 1 Box plot of regression models for bead width prediction error

Table 3 R-squared of regression models for bead width

	Linear regression	Regression tree	SVM	GPR
R ²	0.91	0.92	0.93	0.98

의 경향성과 크기가 감소하였다. GPR의 경우 앞서 분석한 우수한 결정계수 값과 잔차분석 그래프를 통해 모델 예측이 잘 이루어진 것을 확인할 수 있다.

잔차분석 그래프에서 다른 데이터와 비교했을 때, 특히 큰 잔차를 갖는 데이터의 원인을 분석하기 위해 가장 우수한 성능으로 예측한 GPR 회귀모델을 예측 결

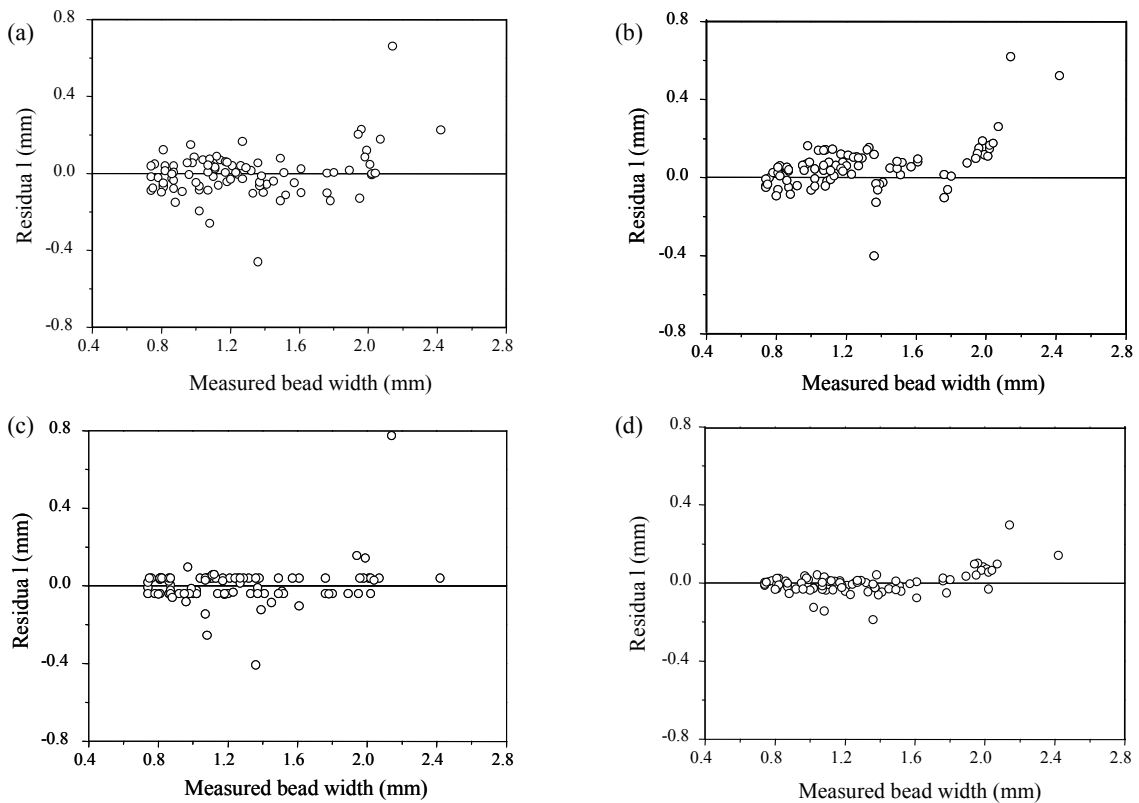


Fig. 2 Residual plots for regression models for bead width: (a) Linear regression; (b) Regression tree; (c) SVM; (d) GPR

과를 분석하였다. 잔차가 큰 조건을 선정한 다음 초점 위치와 용접 속도가 동일한 소재 조합에서 측정된 비드 폭과 GPR 회귀모델의 잔차를 Fig. 3과 4에 나타내었다. 각 소재 조합에서 유사한 비드폭을 가지고 있지만 Fig. 3의 DP780/DP980, CP1180/HPF1500과 Fig. 4의 DP780/DP980의 경우 다른 소재 조합에서의 비드폭과 상대적으로 큰 차이가 가지고 있어 잔차에서도 다른 데이터셋 보다 큰 값을 확인할 수 있었다. 그러나 동일한 소재 조합에서 다른 공정변수 조합에서는 이러한 경향성이 확인되지 않아 시편 제작 과정 혹은 단면 측정에서 파악되지 않은 오차가 발생했을 것으로 추정된다.

3.1.2 파단 강도 회귀모델 분석 결과

Fig. 5는 인장-전단 시험을 통해 실제 측정된 파단 강도와 회귀모델을 통해 예측한 파단 강도에 대한 오차를 박스 플롯으로 나타내었다. 모든 회귀모델의 오차 분포는 -3~3 kN 내에 위치하며, 박스 플롯의 형태를

Table 4 R-squared of regression models for fracture load

	Linear regression	Regression tree	SVM	GPR
R ²	0.94	0.94	0.97	0.99

통해 전체적으로 데이터가 한쪽으로 편향되지 않고 고르게 분포한 것을 알 수 있다. 평균 오차는 선형 회귀가 0.74 kN, 회귀 트리가 1.09 kN, SVM이 0.52 kN, GPR이 0.21 kN으로 GPR이 가장 작은 평균 오차를 가진다. 표준 편차는 선형 회귀가 0.66 kN, 회귀 트리가 0.79 kN, SVM이 0.39 kN, GPR이 0.26 kN으로 GPR이 가장 작은 오차 범위를 가지는 것을 확인할 수 있었다. Table 4는 회귀모델로 예측한 파단 강도의 결정계수를 보여준다. 모든 모델은 0.94 이상의 결정계수를 가지며, GPR의 경우 0.99로 가장 높은 결정계수 값을 가진다. 즉, GPR이 다른 회귀모델에 비해 작은 평균 오차와 높은 결정계수를 가지는 것을 확인할

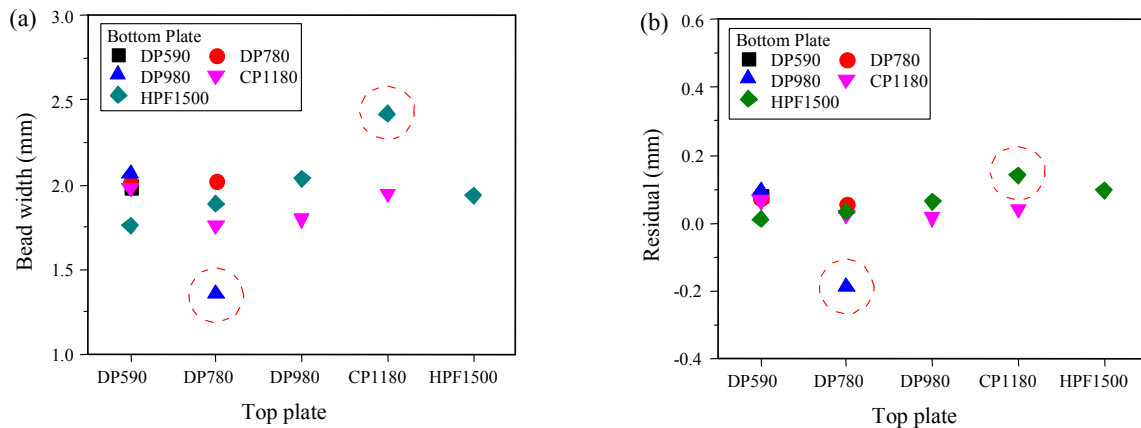


Fig. 3 Measured bead width and residual plots for GPR model (-20 mm focal position and 24 mm/s welding speed): (a) bead width; (b) residual

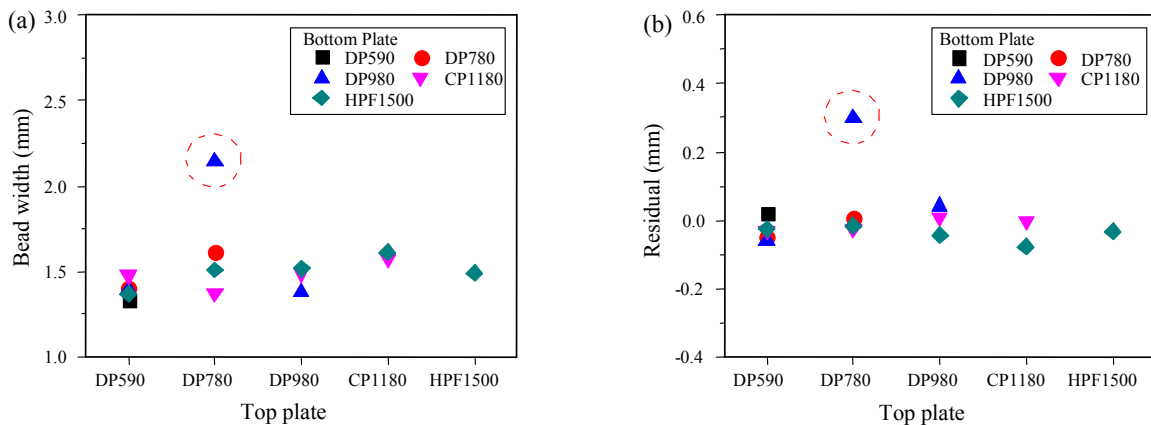


Fig. 4 Measured bead width and residual plots for GPR model (-15 mm focal position and 32 mm/s welding speed): (a) bead width; (b) residual

수 있다. 이는 GPR이 모델의 확장성이 높기 때문에 결정계수 0.99로 거의 완벽한 예측이 가능하였다.

Fig. 6는 파단 강도에 대한 회귀모델의 잔차분석 그래프를 나타내었다. 선형 회귀모델과 회귀 트리 모델은 다른 모델과 달리 잔차가 무작위로 분포하지 않고 측정된 파단 강도가 20 kN 이상인 부분에서 우상향으로 경향성이 나타나는 것을 확인할 수 있다. SVM 회귀모델과 GPR 모델은 잔차가 무작위로 분포되어 있으며, 잔차의 경향성과 크기가 감소하였다. GPR의 경우 앞서 분석한 우수한 결정계수 값과 잔차분석 그래프를 통해 모델 예측이 잘 이루어진 것을 확인할 수 있다.

3.2 분류모델 분석 결과

Fig. 7은 실제 파단 위치와 분류모델을 통해 예측된 파단 위치에 대한 오차율과 정확도를 나타내었다. 모델의 정확도는 100%에서 평균 오차율을 제외한 값으로 계산되었다. 분류 트리는 98.89%, 나이브 베이즈는 94.44%, SVM은 91.11%, KNN은 100%의 정확도를 가지는 것을 확인할 수 있다. 모든 분류모델에서 90% 이상의 우수한 정확도를 나타내었으며, 그 중 KNN이 100%로 완벽하게 예측이 가능한 것을 볼 수 있다.




Fig. 5 Box plot of regression models for fracture load prediction error

3.3 얇은 신경망 분석 결과

Fig. 8은 실제 측정된 값과 SNN을 통해 예측된 값의 분포를 나타내는 그래프로 비드폭과 파단 강도에 대해 분석하였다. 앞서 분석한 회귀모델에서 가장 높은 결정계수를 가진 GPR 모델은 비드폭과 파단 강도 예측에서 각각 0.98, 0.99 값을 가지는 반면, SNN 모델의 경우 0.96과 0.95의 상대적으로 낮은 결정계수를 갖는 것을 확인할 수 있다. 이러한 결정계수 값의 차이

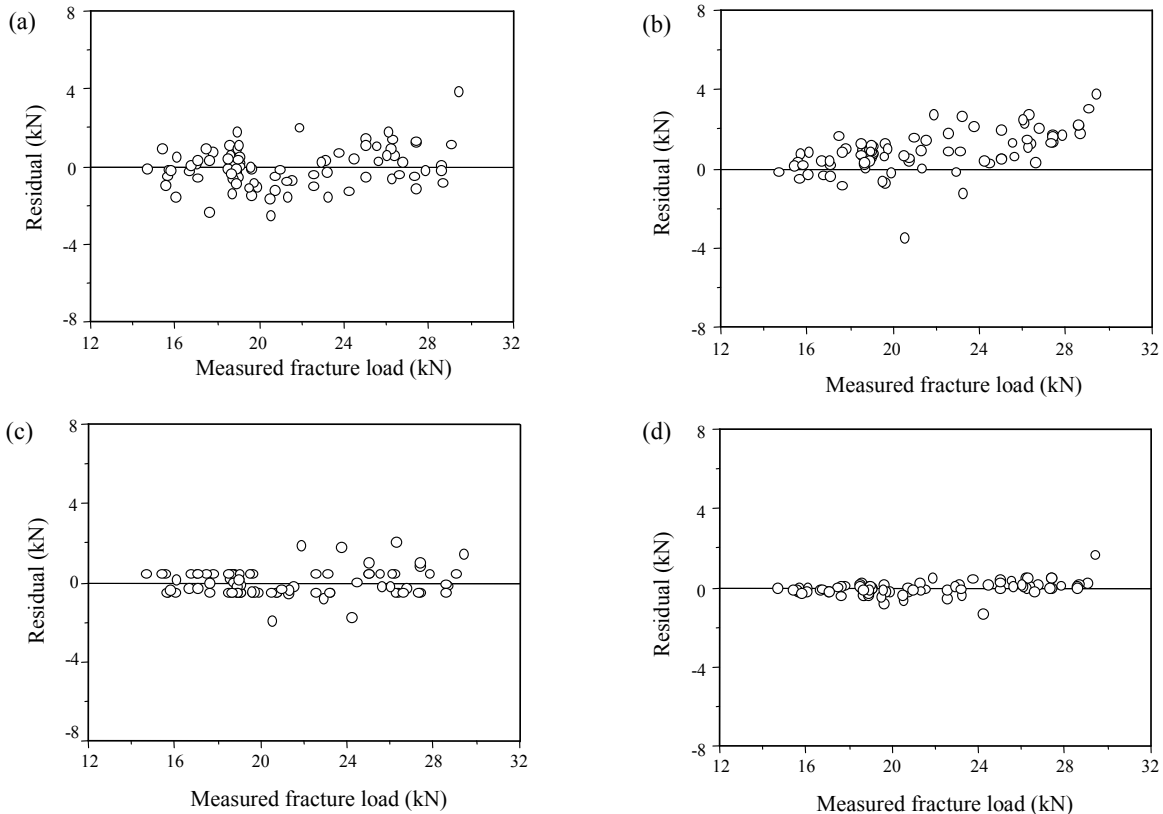


Fig. 6 Residual plots for regression models for fracture load: (a) Linear regression; (b) Regression tree; (c) SVM; (d) GPR




Fig. 7 Error rate and accuracy for classification models

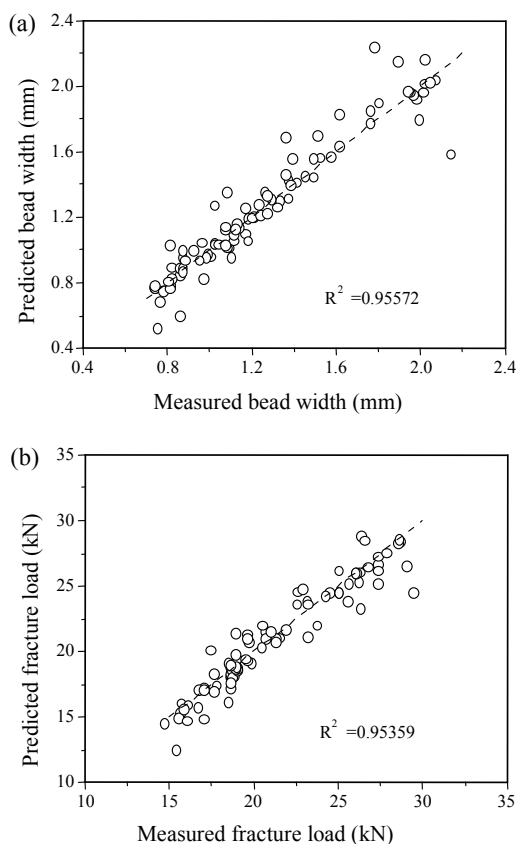


Fig. 8 Correlation between predicted and measured values of (a) bead width and (b) fracture load

는 SNN 모델을 분석할 경우, 90개의 데이터를 학습, 검증, 테스트로 나눠서 분석하기 때문에 기계학습 회귀 모델에 비해 낮은 결정계수를 가지는 것으로 판단된다. 3.1절에서 사용한 기계학습 회귀모델의 경우 일반적인 선형 회귀에서처럼 90개의 데이터셋을 모두 이용하여 학습을 사용하고 별도의 테스트를 수행하지는 않은 경우이다. 현재 SNN에서 사용한 데이터의 개수가 상당히 작음에도 불구하고 결정계수는 상당히 높게 나타났다.

Fig. 9는 파단 위치 분류모델에 대해 분석한 결과로,



Fig. 9 Confusion matrices of fracture location

학습, 검증, 테스트 데이터 모두 예측 정확도 100%를 나타낸다. 앞서 분석한 분류모델 중 가장 우수한 정확도를 가진 KNN과 비교했을 때 동일한 값을 나타내는 것을 통해 SNN을 통한 파단 위치 분석을 위한 모델이 잘 구축된 것을 확인할 수 있었다.

4. 결 론

본 논문은 고강도강 동종-이종재료 겹치기 레이저용접부의 제시된 변수(상판의 화학조성, 하판의 화학조성, 용접 속도, 초점 위치)에 대한 비드폭, 파단 강도 및 파단 위치를 예측하기 위해 기계학습 모델을 구축하였으며 자세한 결과는 아래와 같다.

- 1) 비드폭과 파단 강도 예측을 위해 머신러닝 회귀 모델을 사용했으며, 그 중 가장 우수한 성능을 가진 가우스 프로세스 회귀의 결정계수는 비드폭이 0.98, 파단 강도가 0.99의 높은 결정계수로 예측이 가능하였다.
- 2) 회귀모델에 대해 잔차분석을 진행한 결과, 차수가 낮은 선형 회귀, 의사결정 트리에 비해 차수가 무한대로 확장 가능한 서포트 벡터 머신과 가우스 프로세스 회귀는 무작위 분포와 낮은 분산을 가졌다.
- 3) 파단 위치 예측을 위해 분류모델을 사용했으며, 최근접 이웃 분류모델이 정확도 100%로 가장 우수한 성능을 나타냈다.
- 4) 얇은 신경망을 통해 각 출력 데이터에 대해 모델을 학습시킨 결과 비드폭과 파단 강도는 각각 0.96과

0.95의 결정계수를, 파단 위치는 100%의 우수한 정확도를 갖는 모델을 구축할 수 있었다.

ORCID: Hyeonjeong You: <https://orcid.org/0000-0002-0734-1743>

ORCID: Minjung Kang: <http://orcid.org/0000-0003-1894-4301>

ORCID: Soong Keun Hyun: <http://orcid.org/0000-0002-3434-8465>

ORCID: Cheolhee Kim: <http://orcid.org/0000-0003-4127-3171>

References

1. T. K. Han, K. Y. Lee and J. S. Kim, Recent Developments and Weldability of Advanced High Strength Steels for Automotive Applications, *J. Korean Weld. Join. Soc.* 27(2) (2009) 13-18.
<https://doi.org/10.5781/KWJS.2009.27.2.013>
2. K. Fahlström, K. A. Persson, J. K. Larsson and E. V. Ferrer, Evaluation of Laser Weldability of 1800 and 1900 MPa Boron Steels, *J. Laser Appl.* 28(2) (2016) 022426.
<https://doi.org/10.2351/1.4944102>
3. L. Lu, Z. Liang, J. Yang, Q. Sun, T. Zhu and X. Wang, Investigation on Laser Welding of a Novel Hot-Stamped Steel With 2000 MPa, *J. Mater. Res. Technol.* 9(6) (2020) 13147-13152.
<https://doi.org/10.1016/j.jmrt.2020.09.044>
4. M. Uchihara, Joining Technologies for Automotive Steel Sheets, *Weld. Int.* 25(4) (2011) 249-259.
<https://doi.org/10.1080/09507111003655341>
5. C. H. Kim, J. K. Choi, M. J. Kang and Y. D. Park, A Study on the CO₂ Laser Welding Characteristics of High Strength Steel up to 1500 MPa for Automotive Application, *J. Achiev. Mater. Manuf.* 39(1) (2010) 79-86.
6. C. Kim, M. Kang and Y. Park, Laser Welding of Al-Si Coated Hot Stamping Steel, *Procedia Eng.* 10 (2011) 2226-2231.
<https://doi.org/10.1016/j.proeng.2011.04.368>
7. M. Kang, C. Kim and J. Lee, Weld Strength of Laser-Welded Hot-Press-Forming Steel, *J. Laser Appl.* 24(2) (2012) 022004.
<https://doi.org/10.2351/1.3699080>
8. M. Kang, C. Kim and S. Bae, Laser Tailor-Welded Blanks for Hot-Press-Forming Steel with Arc Pretreatment, *Int. J. Automot. Technol.* 16(2) (2015) 279-283.
<https://doi.org/10.1007/s12239-015-0029-y>
9. M. Kang, Y.-M. Kim and C. Kim, Effect of Heating Parameters on Laser Welded Tailored Blanks of Hot Press Forming Steel, *J. Mater. Process. Technol.* 228 (2016) 137-144.
<https://doi.org/10.1016/j.jmatprotec.2015.06.028>
10. S. Furusako, Y. Miyazaki, K. Hashimoto and J. Kobayashi, Establishment of a Model Predicting Tensile Shear Strength and Fracture Portion of Laser-Welded Lap Joints, *Proceedings of International Congress on Laser Advanced Materials Processing (LAMP 2002)*, Osaka, Japan (2002) 197-202.
11. T. Terasaki and T. Kitamura, Prediction of Static Fracture Strength of Laser-Welded Lap Joints by Numerical Analysis, *Weld. Int.* 18(7) (2004) 524-530.
<https://doi.org/10.1533/wint.2004.3284>
12. J. Lee, K. Asim and J. Pan, Modeling of Failure Mode of Laser Welds in Lap-Shear Specimens of HSLA Steel Sheets, *Eng. Fract. Mech.* 78(2) (2011) 374-396.
<https://doi.org/10.1016/j.engfracmech.2010.10.011>
13. J. Ha and H. Huh, Failure Characterization of Laser Welds Under Combined Loading Conditions, *Int. J. Mech. Sci.* 69 (2013) 40-58.
<https://doi.org/10.1016/j.ijmecsci.2013.01.022>
14. M. Kang, I. H. Jeon, H. Han and C. Kim, Tensile-Shear Fracture Behavior Prediction of High-Strength Steel Laser Overlap Welds, *Met.* 8(5) (2018) 365.
<https://doi.org/10.3390/met8050365>
15. M. Ono, M. Kabasawa and M. Omura, Static and Fatigue Strength of Laser-Welded Lap Joints in Thin Steel Sheet, *Weld. Int.* 11(6) (1997) 462-467.
<https://doi.org/10.1080/09507119709451995>
16. T. K. Han, B. G. Park and C. Y. Kang, Hardening Characteristics of CO₂ Laser Welds in Advanced High Strength Steel, *Met. Mater. Int.* 18(3) (2012) 473-479.
<https://doi.org/10.1007/s12540-012-3014-2>
17. S. Vignier, E. Biro and M. Hervé, Predicting the Hardness Profile Across Resistance Spot Welds in Martensitic Steels, *Weld. World*, 58(3) (2014) 297-305.
<https://doi.org/10.1007/s40194-014-0116-0>
18. I. H. Jeon, C. Kim and J. D. Kim, Hardness Estimation of Laser Welded Boron Steel Welds with the Carbon Equivalent, *J. Weld. Join.* 34(5) (2016) 1-5.
<https://doi.org/10.5781/JWJ.2016.34.5.1>
19. K. Andersen, G. E. Cook, G. Karsai and K. Ramaswamy, Artificial Neural Networks Applied to Arc Welding Process Modeling and Control, *IEEE Trans. Ind. Appl.* 26(5) (1990) 824-830.
<https://doi.org/10.1109/28.60056>
20. G. E. Cook, R. J. Barnett, K. Andersen and A. M. Strauss, Weld Modeling and Control Using Artificial Neural Networks, *IEEE Trans. Ind. Appl.* 31(6) (1995) 1484-1491.
<https://doi.org/10.1109/28.475745>
21. H.-S. Moon and S.-J. Na, A Neuro-Fuzzy Approach to Select Welding Conditions for Welding Quality Improvement in Horizontal Fillet Welding, *J. Manuf. Syst.* 15(6) (1996) 392-403.
[https://doi.org/10.1016/S0278-6125\(97\)83053-1](https://doi.org/10.1016/S0278-6125(97)83053-1)
22. D. Kim and S. Rhee, Optimization of Arc Welding Process Parameters Using a Genetic Algorithm, *Weld. J.* 80(7) (2001) 184s-189s.
23. D. Kim and S. Rhee, Optimization of GMA Welding Process Using the Dual Response Approach, *Int. J. Prod. Res.* 41(18) (2010) 4505-4515.
<https://doi.org/10.1080/0020754031000595800>

24. K. Lee, S. Yi, S. Hyun and C. Kim, Review on the Recent Welding Research with Application of CNN-Based Deep Learning Part I: Models and applications, *J. Weld. Join.* 39(1) (2021).
<https://doi.org/10.5781/JWJ.2021.39.1.1>
25. K. Lee, S. Yi, S. Hyun and C. Kim, Review on the Recent Welding Research with Application of CNN-Based Deep Learning Part II: Model evaluation and visualizations, *J. Weld. Join.* 39(1) (2021).
<https://doi.org/10.5781/JWJ.2021.39.1.2>
26. D. Petković, Prediction of Laser Welding Quality by Computational Intelligence Approaches, *Optik*, 140 (2017) 597-600.
<https://doi.org/10.1016/j.ijleo.2017.04.088>
27. K. Lee, S. Kang, M. Kang, S. Yi, S. Hyun and C. Kim, Modeling of Laser Welds Using Machine Learning Algorithm Part I: Penetration Depth for Laser Overlap Al/Cu Dissimilar Metal Welds, *J. Weld. Join.* 39(1) (2021).
<https://doi.org/10.5781/JWJ.2021.39.1.3>