



# 머신 러닝을 이용한 레이저 용접의 용입깊이 모델링 및 공정변수 맵

고범수\* · 유현정\*\* · 방희선\*† · 김철희\*\*,\*†,††

\*조선대학교 용접·접합과학공학과

\*\*한국생산기술연구원 용접접합그룹

\*\*\*포틀랜드주립대학교 기계재료공학과

## Penetration Depth Modeling and Process Parameter Maps for Laser Welds Using Machine Learning

Bum-su Go\*, Hyeonjeong You\*\*, Hee-seon Bang\*†, and Cheolhee Kim\*\*,\*†,††

\*Department of Welding and Joining Science Engineering, Chosun University, Gwangju, 61452, Korea

\*\*Joining R&D Group, KITECH, Incheon, 21999, Korea

\*\*\*Department of Mechanical and Materials Engineering, Portland State University, OR 97229, USA

†Corresponding author: †banghs@chosun.ac.kr, ††chkim@kitech.re.kr

(Received March 8, 2021; Revised June 1, 2021; Accepted June 30, 2021)

### Abstract

Penetration control is an important factor in determining the weld quality in keyhole mode laser welding, which enables deep penetration. In this study, machine learning models and neural network models were developed by using 380 published welding data which were constructed for steel base metals under the following welding conditions: a laser power of 0.3-16.7 kW, a welding speed of 0.3-20.0 m/min, and a bead diameter of 0.05-0.78 mm.

A machine learning model SVM (supported vector machine) could accurately predict the penetration depth with a coefficient of determination,  $R^2$  of 0.95. A shallow neural network model with five nodes in only one hidden layer was developed with a slightly improved accuracy with  $R^2$  of 0.98. It was confirmed that neither model was over-fitted, and process parameters (welding speed and beam diameter) maps with penetration depth contours were provided for a laser power of 2-8 kW.

Key Words: Laser welding, Deep penetration, Prediction, Machine learning, Deep learning, Contour map

### 1. 서 론

레이저를 용접의 열원으로 사용할 경우 아크용접 열원에 비해 작은 빔 직경에 집중된 열을 인가하여 키홀 모드 용접에서는 키홀 내 다중반사를 통한 레이저 흡수가 가능하여 적은 입열로 깊은 용입의 달성이 가능하다. 최근 자동차 차체용 초고도강/비철금속이나 이차전지용 비철금속의 경우 용접부 및 열영향부의 연화 현상이 발생하므로 입열을 줄여 연화를 방지하기 위한 레이저 용접연구가 활발하게 진행되고 있다. 또한 레이저

발전기술의 발전으로 인해 용접용 레이저 발전기가 기존의 CO<sub>2</sub> 레이저와 Nd:YAG 레이저에서 디스크, 파이버, 다이오드 레이저로 진화하여 더 작은 빔 직경과 더 큰 발전 출력이 용접공정에 활용되고 있다.

레이저 빔의 집중성을 활용하여 기존의 연구에서는 1.8 GPa까지의 강도를 가지는 초고강도 강의 용접에서 저입열 레이저 용접 특성 및 강도 확보방안이 검토되었다<sup>1-6)</sup>. Al 합금<sup>7,8)</sup>과 Mg 합금<sup>9)</sup>, Ti 합금<sup>10)</sup> 등 다양한 비철금속에 대해서도 용접성에 대한 검토가 이루어졌으며, 특히 최근에는 이차전지용 비철 소재인 Cu 박판 및 Cu/Al 이종재료의 레이저 용접<sup>11,12)</sup>에 대한

관심 높아지고 있다. 레이저 용접의 또 하나의 트렌드로 레이저 빔은 출력 및 경로 제어가 용이하므로 공간적 모듈레이션<sup>13-16)</sup>, 시간적 모듈레이션<sup>17)</sup>, 듀얼 빔 배치<sup>18)</sup>를 이용하여 비철금속의 용접균열 및 결함을 제어하고 강도를 향상시키는 연구가 활발하게 수행되고 있다. 레이저 빔의 집중성으로 인해 부재의 겹에 대한 대응력이 부족하거나 아연도금강판 적용 용접에서 결함의 우려가 있어 다양한 아크용접 공정과의 복합화를 통해 단점을 보완하고 있다<sup>19-22)</sup>. 후판의 레이저 용접에서는 10 kW 이상의 대출력 레이저를 이용한 용접연구가 보편화되고 있고<sup>23)</sup>, 저진공 분위기하에서 레이저 용접을 적용하여 용입을 극대화하거나 100 kW급의 레이저를 활용하여 기존에 다른 방법으로 얻지 못하던 용입을 확보하려는 연구가 지속되고 있다<sup>24,25)</sup>.

키홀모드 레이저 용접에서 에너지의 흡수 깊이와 에너지 흡수율은 키홀의 형상 및 다중반사와 관련이 있어 본질적으로 예측이 쉽지 않다. 기존 연구에서 해석적 방법과 수치적 방법을 이용하여 키홀의 형상, 흡수율, 용접부 형상을 모델링하였으나 현재까지 제안된 방법들의 수렴성이나 적용성은 상당히 제한적이다<sup>26-28)</sup>. 그래서 실험적 모델을 통해 용접 깊이를 예측하려는 연구가 지속되었고, 레이저 용접 용입과 관련된 다양한 지표가 제안되었다. 레이저 용접 현상을 설명하는 대표적 지표로는 레이저 에너지밀도(energy density), 상호작용시간(interaction time)이 있으며, 다양한 연구자들이 레이저 출력과 빔 직경의 비<sup>29,30)</sup>, 레이저 출력과 상호작용시간의 곱<sup>31-33)</sup>, 키홀 내 다중반사강도<sup>34)</sup> 등 추가 지표를 활용하여 용접부 형상을 스케일링하려고 하였다. 그러나 키홀을 통한 에너지 흡수과정의 비선형성으로 인해 개발된 지표들로는 일반화가 여전히 어렵다.

최근 기계학습과 딥러닝에 대한 연구가 지속적으로 성과를 도출하고 있으며 점차 적용대상이 확대되고 있다. 다양한 기계학습 솔루션이 제공되고, 딥러닝에서 새로운 활성화함수, 합성곱 신경망 및 최적화 방법 등이 제안되어 대표적 비선형 문제인 용접현상의 예측에도 많이 활용되고 있다. Lee et al.은 합성곱 신경망을 용접 분야에 적용한 사례 및 모델 평가 방법을 소개하였다<sup>35,36)</sup>. Lee et al.은 다른 논문에서 Al/Cu 이중재료의 레이저 용접부의 용입깊이를 예측하기 위해 다양한 기계학습 모델을 평가하였으며 높은 차수의 비모수 모델을 이용할 경우 이중재료 레이저 용접부의 용입깊이를 정밀히 예측 가능함을 확인하였다<sup>12)</sup>. You et al.은 기계학습 및 신경망을 통해 고강도강의 레이저 용접부의 파단시험에서 파단강도 및 파단위치에 대한 회귀 및 분류모델을 개발하였다<sup>37)</sup>.

본 연구에서는 다수의 연구자에 의해 공개된 대출력 용접에 대한 논문으로부터 레이저 용접 공정변수에 따른 용입깊이 데이터를 수집하고 기계학습 및 신경망 모델로 용입깊이에 대한 예측 모델을 개발하였다. 이에 기반하여 공정변수에 따른 용입깊이 예측하거나 반대로 희망 용입깊이 달성을 위한 공정변수 제안이 가능한 공정변수 맵을 도출하고자 하였다.

## 2. 데이터 수집 및 모델링방법

### 2.1 데이터 수집

본 연구의 머신러닝 및 인공신경망 모델 학습에 사용된 데이터는 공개된 여러 종류의 연강과 스테인레스강의 레이저 용접부에 대한 데이터로부터 수집하였다<sup>29-31,38-40)</sup>. 레이저 발전기는 디스크(disk)와 파이버(fiber)이며, 레이저 출력 0.3-16.7 kW, 용접속도 0.3-20.0 m/min, 빔 직경 0.05-0.78 mm 사이의 용접조건을 가지는 총 380개의 조건에 대한 데이터를 수집하였다.

학습 모델 구축을 위해 사용된 입력 데이터는 레이저 출력, 용접속도, 빔 직경 총 3개의 파라미터이며, 출력 데이터는 용접부의 용입깊이로 설정하여 논문의 실험값을 수집하였다.

### 2.2 모델

본 연구에서는 레이저 용접의 용입깊이 예측 모델을 구축하기 위해 MATLAB® R2020a의 기계학습 모델 및 인공신경망 모델을 사용하였으며, 학습 모델에 따른 특성을 규명하여 최적의 학습조건을 도출하였다.

기계학습 모델은 선형 회귀, 서포트 벡터 머신(Support vector machine, SVM), 가우스 과정 회귀(Gaussian process regression, GPR) 총 3개의 모델로 학습을 수행하였다.

여기서, 선형 회귀 모델은 일차함수 커널을 사용하였으며, SVM 모델은 3차 함수 커널, 마지막으로 GPR 모델은 지수 함수 커널을 적용하였다.

학습 모델에 따른 출력값의 과적합 여부를 판단하기 위해서 총 380개 데이터 중 266개의 데이터를 무작위로 추출하여 훈련하였으며, 나머지 114개의 데이터로 테스트하여 결정계수(coefficient of determination,  $R^2$ )를 도출하고, 학습 모델 각각에 대한 정확도와 타당성을 비교 및 검토하였다.

인공신경망 모델은 크게 입력층, 은닉층 및 출력층으로 구성되며 각각의 층은 다수의 노드(node)로 이루어져 있다. 본 연구에서는 1개의 은닉층을 가진 얇은 신

경망(shallow neural network, SNN)을 사용하였으며, 수집된 입력 및 출력 데이터로부터 함수를 추론하는 지도학습을 수행하였다. 은닉층 노드 개수에 따른 과적합 정도를 평가하기 위해서 3, 5, 7개 각각에 대한 용입깊이 예측 모델을 비교 및 고찰하였으며, 모델 구축을 위한 훈련(training), 검증(validation), 테스트(test)를 위해 총 380개의 데이터를 각각 266, 57, 57개로 분배하여 학습을 수행하였다.

### 3. 머신러닝 모델

Table 1은 학습 모델에 따른 용입깊이 예측 정확도를 나타내며, GPR 모델에서 평균 제곱 오차(MSE, mean square error)는 0.05 mm<sup>2</sup>, 평균 제곱근 오차(RMSE, root mean square error) 크기는 0.22 mm로 다른 학습 모델에 비해 가장 높은 정확도를 갖고 있다. GPR은 테스트 결정계수가 훈련의 결정계수에 비해 다소 감소하였으며 모델의 높은 자유도로 인해서 과적합이 발생하였음을 알 수 있다.

선형 회귀 모델의 경우 MSE 2.44 mm<sup>2</sup>, RMSE 1.56 mm로 다른 학습 모델에 비해 가장 낮은 정확도를 나타내었으며, 이는 선형 회귀 모델의 낮은 차수로 인한 확장성 부족 문제로 용입깊이 예측에 한계가 있음을 의미한다.

**Table 1** Accuracy of machine learning models

	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	
			Training	Testing
Linear regression	2.44	1.56	0.71	0.74
SVM	0.42	0.65	0.95	0.96
GPR	0.05	0.22	0.99	0.96


SVM 모델은 선형 회귀 모델보다 차수가 높기 때문에 보다 높은 정확도를 갖게 되며, 적절한 확장성으로 테스트 조건에서 결정계수의 크기가 훈련에서의 결정계수와 거의 유사하다. 다른 두 모델에 비해 SVM 모델은 높은 결정계수를 보이면서도 과적합을 피할 수 있어 최적화된 학습 모델임을 확인하였다.

Fig. 1은 학습 모델에 따른 용입깊이 실측 및 예측 그래프이며, Table 1에서 살펴본 바와 같이 GPR, SVM, 선형 회귀 순으로 오차의 크기가 낮게 나타남을 알 수 있다.

선형 회귀 모델의 경우 다른 학습 모델에 비해 모든 구간에서 높은 크기의 오차가 나타나며, 실측값의 용입깊이가 증가할수록 오차가 증가하는 편향적인 경향이 발생하였다 (Fig. 1a). SVM 모델은 선형 회귀 모델보다 전체적으로 오차의 크기가 감소했으며, 용입깊이가 큰 구간에서 발생하는 편향적인 경향도 감소한 것을 알 수 있다 (Fig. 1b). GPR 모델은 다른 학습 모델에 비해 전체적으로 오차의 크기가 감소하여 나타났으며, 모든 용입깊이 구간에서 높은 정확도를 갖는다 (Fig. 1c).

학습 모델의 예측 결과를 자세히 살펴보기 위해 Fig. 2에 도시한 바와 같이 학습모델에 따른 잔차를 분석하였다. 이상적인 학습 모델에서 발생하는 잔차의 경우 오차의 크기는 낮게 나타나며, 특정 범위에 치우치지 않고, 전 범위에 걸쳐서 랜덤하게 분포하는 경향이 나타나야 한다.

선형 회귀 모델의 잔차 분석결과 잔차는 용입깊이 초기 0.3-4.0 mm 구간에 집중된 것으로 나타나며, 용입깊이 6.0 mm 부터 깊이가 증가할수록 잔차의 크기가 점차 증가하는 우상향의 경향이 발생함을 확인하였다 (Fig. 2a). SVM 모델은 용입깊이 6.0 mm 이후



**Fig. 1** Comparison of predicted and measured penetration according to the learning models

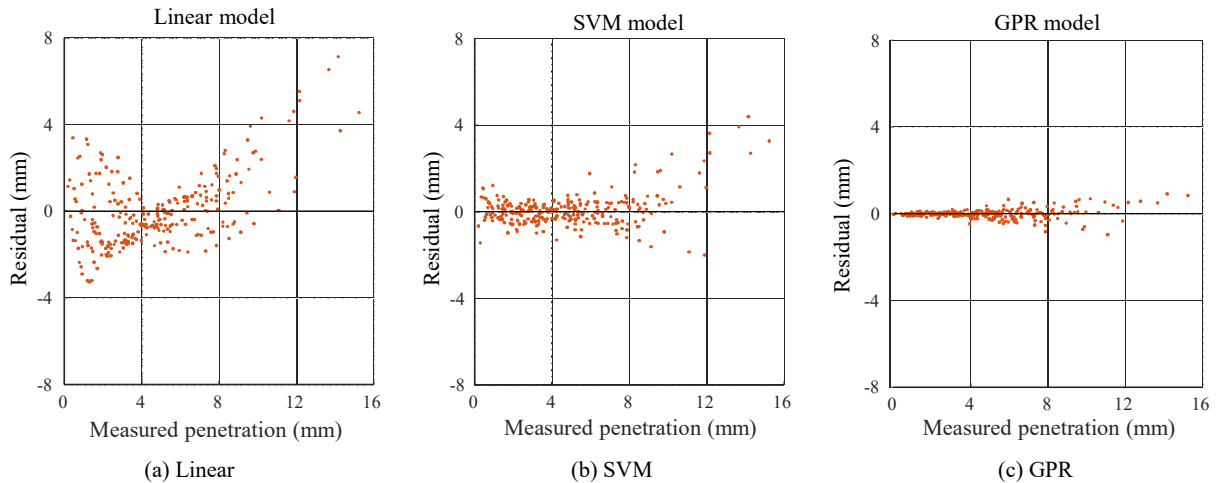


Fig. 2 Comparison of residual plots according to the learning models




Fig. 3 Comparison of contour plots for 4 kW laser power

용입깊이가 증가함에 따라 일부 데이터에서 우상향의 경향성이 나타났다. 선형 회귀 모델에 비해 잔차의 경향성이 감소하는 현상을 확인할 수 있었으며, 그 외에 구간에서는 균등하고, 등분산적인 건전한 잔차 분포 특성이 나타남을 알 수 있었다 (Fig. 2b). GPR 모델은 모든 구간에서 잔차나 다른 학습 모델에서 발생하는 우상향의 경향이 사라짐을 확인하였다 (Fig. 2c). 이는 GPR 모델의 특성상 무한대로 차수를 확장할 수 있기 때문이며, 이러한 이유로 비선형적인 회귀 모델을 학습하는 데 효과적이다. 하지만 과적합 현상이 발생할 수 있기 때문에 과적합에 대한 검증을 수행하였다.

Fig. 3은 수립된 모델에 따라 일반적으로 산업에서 적용되는 용접조건을 고려하여 레이저 출력이 4 kW일 때 용접속도와 빔 직경에 따른 용입깊이 등고선을 예시로 나타내었으며, 용접조건에 따른 등고선의 형태를 통해 과적합 발생 여부를 확인하고자 하였다.

선형 회귀 모델 등고선의 기울기는 학습 모델의 1차 함수적인 특성 때문에 선형적으로 나타났으나 실제 현

상과는 차이가 있다(Fig. 3a). SVM 모델은 선형 회귀 모델에 비해 차수가 높기 때문에 등고선이 완만한 곡선 형태로 나타났으며, 용접속도와 빔 직경 조건에 따른 영향이 충분히 반영되고 있음을 알 수 있다(Fig. 3b). GPR 모델의 경우 빔 직경 0.1~0.3 mm 구간의 용입깊이 등고선 기울기를 살펴보았을 때, 빔 직경이 감소할수록 용접속도가 감소하여 나타났으며, 실제 레이저 용입 현상에 부합하지 않는 과적합이 발생하고 있음을 확인하였다 (Fig. 3c). 현재 SVM 모델은 10 mm 이상의 용입깊이를 가질 경우 예측 성능이 떨어지는데 (Fig. 1b and 2b) 현재 수집한 데이터에서 용입깊이가 10 mm 이상일 경우는 상당히 저속에서 데이터 수집이 되어 공정변수와 용입과의 상관관계가 일반적인 용접속도에서의 그 상관관계와는 다른 특성을 가진다<sup>41)</sup>.

위와 같은 결과로 머신러닝을 통한 대용입 레이저 용입 모델의 가능성과 타당성을 검토하였으며, 앞서 살펴본 3가지 학습 모델 중 SVM 모델에서 정확도와 적합성을 확인하였다.

### 4. 신경회로망 모델


Table 2는 은닉층 노드 개수에 따른 신경회로망 모델의 정확도를 나타내며, 노드의 개수가 증가할수록 정확도와 결정계수가 높아지는 경향성을 보인다.

3개의 은닉층 노드로 구성된 신경회로망 모델의 경우 다른 모델에 비해 차수가 가장 낮기 때문에 상대적으로 높은 크기의 오차를 갖게 되지만 테스트에서도 훈련이나 검증과 유사한 결정계수를 가져 과적합에 빠지지 않는다. 5개의 은닉층 노드로 구성된 신경회로망 모델은 이전 모델에 비해 차수가 높아짐으로써 상대적으로 우수한 정확도와 결정계수를 갖는다. 또한 학습, 검증, 테스트의 결정계수가 모두 동일하면서도 0.98로 높게 나와 과적합 되지 않은 건전한 예측 모델임을 알 수 있다. 7개의 은닉층 노드로 구성된 신경회로망 모델은 가장 높은 차수와 자유도로 인해 훈련과 검증에서 매우 높은 정확도 및 결정계수를 가지고 있으나 테스트에서의 오차 크기가 증가하고, 결정계수가 감소한 것을 확인하였다. 즉, 머신러닝의 GPR 모델과 유사하게 신경망모델에서는 은닉층 노드 수가 7개인 경우 과적합이 발생함을 확인하였다.

Fig. 4는 노드 개수에 따른 신경회로망 모델의 실측과 예측 그래프이며, 노드의 개수가 증가함에 따라 정확도가 향상됨을 알 수 있다. 3개의 노드로 구성된 모델의 예측 및 실측 그래프는 다른 모델에 비해 전반적으로 높은 크기의 오차가 발생하였으며, 용입깊이 6 mm를 기준으로 용입깊이가 증가할수록 오차의 크기가 점차 증가하는 경향이 나타남을 확인하였다 (Fig. 4a). 5개의 노드로 구성된 모델은 오차의 크기가 전체적으로 감소하였으나 용입깊이 10 mm 이상의 일부 데이터에서 다른 구간에 비해 상대적으로 큰 오차가 발생함

**Table 2** Accuracy of neural network models

		MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>
SNN (3 Node)	Training	0.53	0.73	0.93
	Validation	0.75	0.87	0.92
	Testing	0.57	0.75	0.94
SNN (5 Node)	Training	0.18	0.42	0.98
	Validation	0.18	0.42	0.98
	Testing	0.18	0.42	0.98
SNN (7 Node)	Training	0.13	0.36	0.99
	Validation	0.10	0.32	0.99
	Testing	0.25	0.50	0.97



**Fig. 4** Comparison of predicted and measured graphs according to the number of nodes



을 확인하였다 (Fig. 4b). 7개의 노드로 구성된 모델은 용입깊이 12 mm 이상의 소수 데이터를 제외한 대부분의 구간에서 거의 완벽한 예측이 가능함을 알 수 있었으며, 다른 모델에 비해 가장 높은 정확도가 나타났다 (Fig. 4c).

Fig. 5는 수립된 신경망 모델에 따라 레이저 출력이 4 kW일 때 용접속도와 빔 직경에 따른 용입깊이 등고선을 제시하였다. 3개의 노드로 구성된 모델의 경우 용입깊이 등고선은 거의 일정한 기울기를 갖는 선형적인 경향이 강하게 나타났으며, 용입깊이 2 mm에서 3.5 mm 와 같은 일부 영역에서 약간의 비선형적인 기울기를 나타냈으나, 빔 직경 조건에 따른 레이저 용입 현상을 예측하기에는 한계가 있음을 확인하였다 (Fig. 5a). 5개의 노드로 구성된 모델의 용입깊이 등고선은 아치형태의 등고선 기울기를 나타내며, 용접속도 1 m/min 부터 2 m/min 구간과 빔 직경 0.5 mm 부터 0.7 mm 구간의 경우 국부적으로 미약하게 왜곡 현상이 나타났지만, 전반적으로 용접속도와 빔 직경의 영향을 잘 묘사하고 있음을 확인하였다 (Fig. 5b). 7개의 노드로 구성된 모델의 용입깊이 등고선은 빔 직경 0.4 mm 를 기준으로 기준점 이하의 영역에서는 등고선 왜곡 현상이 발생하였으며, 기준점 이상의 영역에서는 선형적인 등고선 기울기가 나타남을 확인하였다 (Fig. 5c). 이는 Table 2에서 살펴보았듯 과도한 차원으로 인해 과적합이 발생함을 의미한다.

위와 같은 결과로 신경회로망을 통한 대용입 레이저 용입 모델의 가능성과 타당성을 검토하였으며, 노드 개수에 따라 용입깊이 등고선에 미치는 영향을 고찰하였을 때 5개의 노드로 구성된 모델에서 용접조건에 따른 용입깊이 현상이 잘 반영되고 있음을 확인하였다.

### 5. 공정변수 맵

4절에서 선정한 기계학습(SVM 모델)과 신경회로망(은닉노드 5개) 모델을 이용하여 디스크 및 파이버 레이저 출력인 2-8 kW에 대해 공정에 따른 용입깊이 맵을 Fig. 6과 7에 비교하여 나타내었다.

모든 출력조건에서 Fig. 6 SVM 모델의 용입깊이가 가장 깊은 영역인 그래프의 좌하단 구간과 Fig. 7 SNN 모델의 용입깊이가 가장 얇은 영역인 그래프의 우상단 구간의 등고선 기울기가 선형적으로 나타남을 알 수 있다.

등고선의 기울기가 선형적으로 나타나는 구간은 해당 조건에서의 공정변수가 용입깊이에 미치는 영향을 잘 반영하지 못하고 있음을 의미하며, 이는 좌하단과 우하단에 속한 데이터의 개수가 중앙부에 비해 상대적으로

부족하여 나타나는 현상이므로 추가적인 데이터 수집을 통해 충분한 학습이 이루어지면 완화시킬 수 있을 것으로 사료된다.

전 출력범위에서 기계학습 모델과 신경망 모델이 유사한 형식의 등고선이 출력되었고 양쪽 모두 용입깊이 예측 모델이 잘 구축되었음을 확인할 수 있었다.




Fig. 5 Comparison of contour plots according to the number of the hidden layer nodes

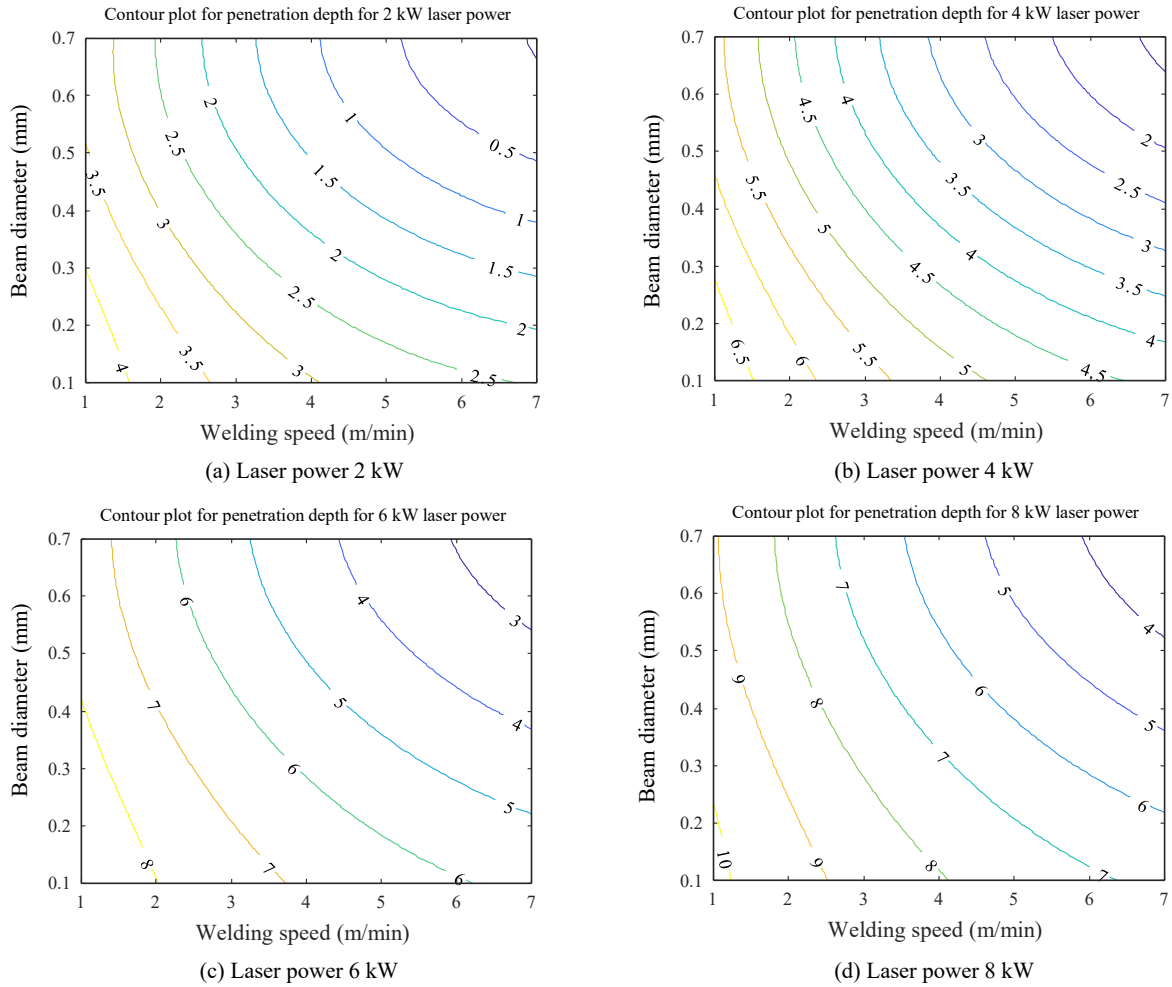


Fig. 6 Contour map using the SVM model

용입깊이 맵을 활용하기 위한 하나의 예시로 Fig. 8 과 같이 SVM 모델의 레이저 출력 6 kW 조건에서 용입깊이 5 mm 에 대한 등고선을 예시로 선정하여 용접 속도와 빔 직경에 따른 그래프로 도식화하였다. 학습 모델을 통해 출력된 그래프의 기울기는 실제 레이저 용접부의 용입깊이 현상과 매우 유사하게 나타났으며, 용접 실적용에서 희망하는 용접속도에 대응하기 위한 용접 빔의 직경을 그래프에서 바로 확인할 수 있다.

중형비가 큰 레이저 용접의 특성상 제품 생산에 있어서 용입깊이는 핵심적인 요소로 작용하며, 앞서 다룬 일련의 절차들을 통해 데이터를 통한 학습 모델을 실제 어플리케이션으로 활용할 수 있을 것으로 판단된다.

## 6. 결 론

본 연구를 통해 강재에 대한 대출력 디스크 및 파이버 레이저의 용입데이터를 기반으로 기계학습 모델과 인공지능망 모델을 구축하였으며, 용입깊이 예측과 공

정변수 맵을 도출하여 다음과 같은 결론을 얻을 수 있었다.

1) 기계학습 모델인 GPR, SVM을 통해 대출력 레이저 용접에서 용입깊이의 예측이 성공적으로 수행되었으며 예측모델의 결정계수는 각각 0.99와 0.95이다. SVM 모델은 과적합 없이 정확한 용입예측이 가능함을 확인하였다.

2) 은닉층이 하나인 얇은 신경망모델에서도 성공적으로 용입깊이 예측이 가능하였으며, 은닉 노드 수가 5 개와 7개인 경우 각각 0.98과 0.99의 결정계수로 용입예측이 가능하였으며, 은닉 노드 5개 모델의 경우 과적합이 발생하지 않음을 확인하였다.

3) 개발된 모델을 이용하여 가장 많이 사용되는 출력 범위인 2-8 kW 레이저 출력에서 용접속도와 레이저 빔 직경에 따른 용입깊이 맵을 작성하였다. 데이터 수가 부족한 일부 영역을 제외한 현실적인 공정변수 범위에서 충분한 적용성을 가진 용입깊이 맵의 제공이 가능하였다.

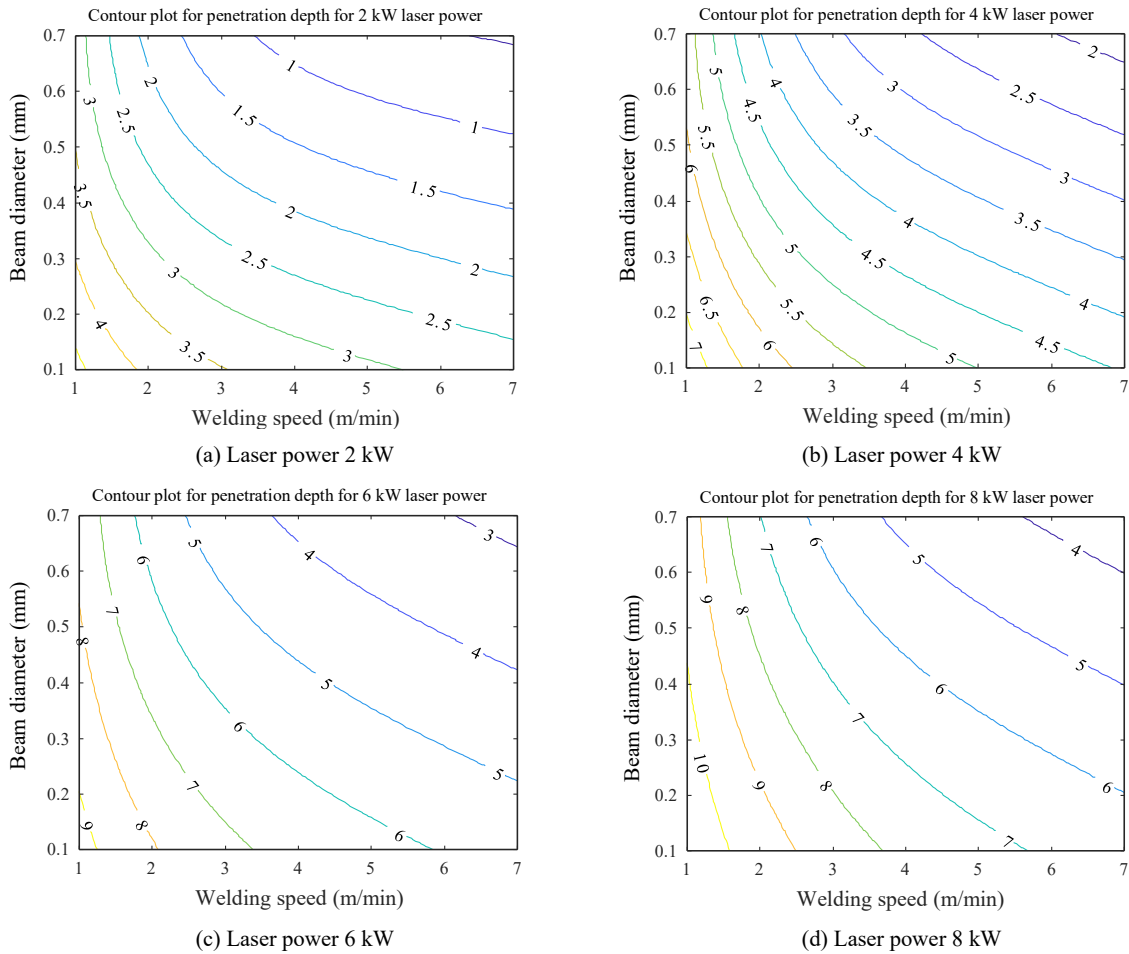


Fig. 7 Contour map using the SNN model

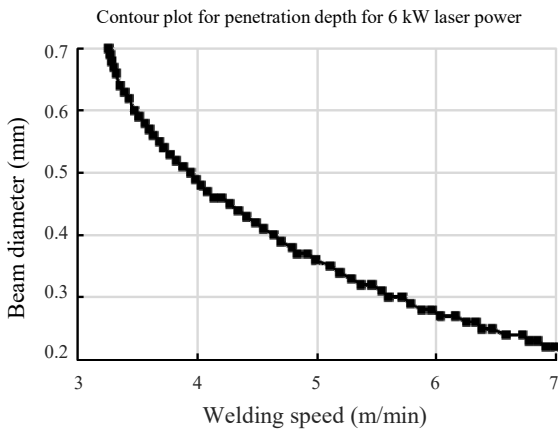


Fig. 8 Relationship between welding speed and beam diameter to obtain 5 mm penetration at 6 kW laser power

**Acknowledgements**

이 논문은 2021년도 정부(산업통상자원부)의 재원으로 한국산업기술진흥원의 지원을 받아 수행된 연구임 (N000P0008425, 2021년 산업혁신인재성장지원사업).

개발된 모델로 예측한 결과는 아래 웹페이지에서도 확인할 수 있음. ([https://deepjoining.github.io/laser\\_penetration.html](https://deepjoining.github.io/laser_penetration.html))

ORCID: Bum-su Go: <https://orcid.org/0000-0002-7513-3321>  
 ORCID: Hyeonjeong You: <https://orcid.org/0000-0002-0734-1743>  
 ORCID: HeeSeon Bang: <https://orcid.org/0000-0003-4891-5712>  
 ORCID: Cheolhee Kim: <http://orcid.org/0000-0003-4127-3171>

**References**

1. C. H. Kim, J. K. Choi, M. J. Kang, and Y. D. Park, A Study on the CO<sub>2</sub> Laser Welding Characteristics of High Strength Steel up to 1500 MPa for Automotive Application, *J. Achiev. Mater. Manuf. Eng.* 39(1) (2010) 79-86.
2. 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>
3. 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>
4. 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>
  5. M. Kang and C. Kim, Influence of Surface Oxide on Mechanical Properties of Laser-Welded Hot-Press-Forming Steel with Strength of 1.8 GPa, *J. Laser Appl.* 30(3) (2018) 032415.  
<https://doi.org/10.2351/1.5040618>
  6. C. Kim, M. Kang, and Y. Park, Laser Welding of Al-Si Coated Hot Stamping Steel, *Proc. Eng.* 10 (2011) 2226-2231.  
<https://doi.org/10.1016/j.proeng.2011.04.368>
  7. J. Kim, H. Lim, J. Cho, and C. Kim, Bead-On-Plate Weldability of Al 5052 Alloy Using a Disk Laser, *J. Achiev. Mater. Manuf. Eng.* 28(2) (2008) 187-190.
  8. J. Kim, H. Lim, J. Cho, and C. Kim, Weldability During the Laser Lap Welding of Al 5052 Sheets, *Arch. Mater. Sci. Eng.* 31(2) (2008) 113-116.
  9. M. J. Kang and C. H. Kim, Effect of Cao Content on Yb:YAG Disk Laser Weldability of AZ31 Mg Alloy, *Mater. Sci. Forum* 804 (2014) 31-34.  
<https://doi.org/10.4028/www.scientific.net/MSF.804.31>
  10. Y. N. Ahn and C. H. Kim, Yb:Yag Laser and Electron Beam Welding of Ti-6Al-4V Alloy, *J. Korean Weld. Join. Soc.* 29(6) (2011) 4-8.  
<https://doi.org/10.5781/kwjs.2011.29.6.624>
  11. M. Kang, T. Park, C. Kim, and J. Kim, Laser Welding Characteristics of Aluminum and Copper Sheets for Lithium-Ion Batteries, *J. Korean Weld. Join. Soc.* 31(6) (2013) 58-64.  
<https://doi.org/10.5781/kwjs.2013.31.6.58>
  12. K. Lee, 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) 10-19.  
<https://doi.org/10.5781/JWJ.2021.39.1.3>
  13. K. D. Choi, Y. N. Ahn, and C. Kim, Weld Strength Improvement for Al Alloy by Using Laser Weaving Method, *J. Laser Appl.* 22(3) (2010) 116-119.  
<https://doi.org/10.2351/1.3499456>
  14. B. Kim, N. Kang, W. Oh, C. Kim, J. Kim, Y. Kim, and Y. Pari, Effects of Weaving Laser on Weld Microstructure and Crack for Al 6K21-T4 Alloy, *J. Mater. Sci. Technol.* 27(1) (2011) 93-96.  
[https://doi.org/10.1016/S1005-0302\(11\)60031-5](https://doi.org/10.1016/S1005-0302(11)60031-5)
  15. C. Kim, M. Kang, and N. Kang, Solidification Crack and Morphology for Laser Weave Welding of Al 5J32 Alloy, *Sci. Technol. Weld. Join.* 18(1) (2013) 57-61.  
<https://doi.org/10.1179/1362171812Y.0000000073>
  16. M. Kang, H. Han, and C. Kim, Microstructure and Solidification Crack Susceptibility of Al 6014 Molten Alloy Subjected to a Spatially Oscillated Laser Beam, *Mater.* 11(4) (2018) 648.  
<https://doi.org/10.3390/ma11040648>
  17. D. C. Ahn, C. Kim, and J. D. Kim, Prevention of Back Side Humping in Laser Welding of Al 5j32 Alloy by Using Laser Power Modulation, *J. Korean Weld. Join. Soc.* 29(4) (2011) 80-84.  
<https://doi.org/10.5781/KWJS.2011.29.4.442>
  18. M. Kang and C. Kim, Evaluation of Hot Cracking Susceptibility on Laser Welded Aluminum Alloy Using Coaxially Arranged Multiple-Beam Laser, *J. Laser Appl.* 32(2) (2020) 022072.  
<https://doi.org/10.2351/7.0000107>
  19. H. Chae, C. Kim, J. H. Kim, and S. Rhee, Improvement of Gap Bridging Ability in CO<sub>2</sub> Laser-GMA Hybrid Welding, *J. Korean Weld. Join. Soc.* 24(5) (2006) 49-56.
  20. H. Chae, C. Kim, J. Kim, and S. Rhee, The Effect of Shielding Gas Composition in CO<sub>2</sub> Laser-Gas Metal Arc Hybrid Welding, *Proc. Inst. Mech. Eng. B: Eng. Manuf.* 222(11) (2008) 1315-1324.  
<https://doi.org/10.1243/09544054JEM944>
  21. C. Kim, W. Choi, J. Kim, and S. Rhee, Relationship between the Weldability and the Process Parameters for Laser-TIG Hybrid Welding of Galvanized Steel Sheets, *Mater. Trans.* 49(1) (2008) 179-186.  
<https://doi.org/10.2320/matertrans.MER2007159>
  22. C. Kim, Y. Ahn, and J. Kim, CO<sub>2</sub> Laser-Micro Plasma Arc Hybrid Welding for Galvanized Steel Sheets, *Trans. Nonferr. Met. Soc. China*, 21 (2011) s47-s53.  
[https://doi.org/10.1016/S1003-6326\(11\)61059-5](https://doi.org/10.1016/S1003-6326(11)61059-5)
  23. Y. N. Ahn and C. Kim, The Effect of Shielding Gas Composition on High Power Laser Welding Characteristics, *J. Weld. Join.* 33(4) (2015) 17-23.  
<https://doi.org/10.5781/jwj.2015.33.4.17>
  24. Y. Lee, J. Cheon, B. K. Min, and C. Kim, Contamination of Coupling Glass and Performance Evaluation of Protective System in Vacuum Laser Beam Welding, *Appl. Sci.* 9(23) (2019) 5082.  
<https://doi.org/10.3390/app9235082>
  25. S. Katayama, M. Mizutani, Y. Kawahito, S. Ito, and D. Sumimori, Fundamental Research of 100 kW Fiber Laser Welding Technology, *Proceedings of the Lasers in Manufacturing Conference (LiM2015)*, Munich, Germany (2015) 342.
  26. A. Kaplan, A Model of Deep Penetration Laser Welding Based on Calculation of the Keyhole Profile, *J. Phys. D: Appl. Phys.* 27(9) (1994) 1805.  
<https://doi.org/10.1088/0022-3727/27/9/002>
  27. H. Zhao and T. Debroy, Macroporosity Free Aluminum Alloy Weldments through Numerical Simulation of Keyhole Mode Laser Welding, *J. Appl. Phys.* 93(12) (2003) 10089-10096.  
<https://doi.org/10.1063/1.1573732>
  28. J. H. Cho and S. J. Na, Implementation of Real-Time

- Multiple Reflection and Fresnel Absorption of Laser Beam in Keyhole, *J. Phys. D: Appl. Phys.* 39(24) (2006) 5372.  
<https://doi.org/10.1088/0022-3727/39/24/039>
29. F. Dausinger, P. Berger, and H. Hügel, Laser Welding of Aluminum Alloys: Problems, Approaches for Improvement and Applications, *Proceeding of the International Congress on Applications of Lasers & Electro-Optics (ICALEO 2002)*, Scottsdale, Arizona, USA (2002) 287255.  
<https://doi.org/10.2351/1.5065733>
  30. W. Suder and S. Williams, Investigation of the Effects of Basic Laser Material Interaction Parameters in Laser Welding, *J. Laser Appl.* 24(3) (2012) 032009.  
<https://doi.org/10.2351/1.4728136>
  31. W. J. Suder and S. Williams, Power Factor Model for Selection of Welding Parameters in CW Laser Welding, *Opt. Laser Technol.* 56 (2014) 223-229.  
<https://doi.org/10.1016/j.optlastec.2013.08.016>
  32. J. Coroado, S. Meco, S. Williams, S. Ganguly, W. Suder, L. Quintino, and E. Assunção, Fundamental Understanding of the Interaction of Continuous Wave Laser with Aluminium, *Int. J. Adv. Manuf. Technol.* 93(9-12) (2017) 3165-3174.  
<https://doi.org/10.1007/s00170-017-0702-6>
  33. M. Zavala-Arredondo, T. London, M. Allen, T. Maccio, S. Ward, D. Griffiths, A. Allison, P. Goodwin, and C. Hauser, Use of Power Factor and Specific Point Energy as Design Parameters in Laser Powder-Bed-Fusion (L-PBF) of AlSi10Mg Alloy, *Mater. Des.* 182 (2019) 108018.  
<https://doi.org/10.1016/j.matdes.2019.108018>
  34. J. Kim and H. Ki, Scaling Law for Penetration Depth in Laser Welding, *J. Mater. Process. Technol.* 214(12) (2014) 2908-2914.  
<https://doi.org/10.1016/j.jmatprotec.2014.06.025>
  35. 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) 20-26.  
<https://doi.org/10.5781/JWJ.2021.39.1.1>
  36. Lee, K., 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) 27-35.  
<https://doi.org/10.5781/JWJ.2021.39.1.2>
  37. H. You, S. Kang, M. Y. Kang, S., S. Hyun, and C. Kim, Modeling of Laser Welds Using Machine Learning Algorithm-Part II: Geometry and Mechanical Behaviors of Laser Overlap Welded High Strength Steel Sheets, *J. Weld. Join.* 39(1) (2021) 36-44.  
<https://doi.org/10.5781/JWJ.2021.39.1.4>
  38. G. Verhaeghe and P. Hilton, The Effect of Spot Size and Laser Beam Quality on Welding Performance When Using High-Power Continuous Wave Solid-State Lasers, *Proceeding of the International Congress on Applications of Lasers & Electro-Optics (ICALEO 2005)*, Miami, Florida, USA (2005) 507.  
<https://doi.org/10.2351/1.5060500>
  39. F. Vollertsen and C. Thomy, Welding with Fiber Lasers from 200 to 17000 W, *Proceeding of the International Congress on Applications of Lasers & Electro-Optics (ICALEO 2005)*, Miami, Florida, USA (2005) 506.  
<https://doi.org/10.2351/1.5060499>
  40. L. Quintino, A. Costa, R. Miranda, D. Yapp, V. Kumar, and C. J. Kong, Welding with High Power Fiber Lasers - a Preliminary Study, *Mater. Des.* 28(4) (2007) 1231-1237.  
<https://doi.org/10.1016/j.matdes.2006.01.009>
  41. Y. Kawahito, M. Mizutani, and S. Katayama, Elucidation of High-Power Fibre Laser Welding Phenomena of Stainless Steel and Effect of Factors on Weld Geometry, *J. Phys. D: Appl. Phys.* 40 (2007) 5854-5859.  
<https://doi.org/10.1088/0022-3727/40/19/009>