



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

2022년 8월  
석사학위 논문

머신러닝 기반 고강도  
아연도금강판 CMT 용접부의  
품질기준 예측을 위한 공정변수  
최적화

조선대학교 대학원

용접 · 접합과학공학과

조 윤 희

머신러닝 기반 고강도  
아연도금강판 CMT 용접부의  
품질기준 예측을 위한 공정변수  
최적화

Optimization of the Process Parameter for the  
Quality Standard Prediction of the High Strength GA  
Steel CMT Welded Joint based on Machine Learning

2022년 8월 26일

조선대학교 대학원

용접 · 접합과학공학과

조 윤 희

머신러닝 기반 고강도 아연도금강판  
CMT 용접부의 품질기준 예측을 위한  
공정변수 최적화

지도교수                      방 희 선

이 논문을 공학 석사학위신청 논문으로 제출함

2022년 4월

조선대학교 대학원

용접 · 접합과학공학과

조 윤 희

## 조윤희의 석사학위논문을 인준함

위원장 조선대학교 교 수 손윤철 (인)  
위 원 조선대학교 교 수 방희선 (인)  
위 원 조선대학교 교 수 박철호 (인)

2022년 5월

조선대학교 대학원

## 목차

List of Figures .....	III
List of Tables .....	IV
Abstract .....	V
제1장 서론 .....	1
1.1 연구 배경 및 목적 .....	1
1.2 국내외 기술 동향 .....	2
제2장 이론적 배경 .....	6
2.1 아연도금강 아크용접부 결함 .....	6
2.2 CMT(Cold Metal Transfer) 용접 공정 .....	9
제3장 연구 방법 .....	11
3.1 용접 조건 및 실험 .....	11
3.2 CMT 용접부 품질 특성 평가 .....	14
3.2.1. 현장관리규격(MS181-13)과 연구 용접 품질 지표 ...	14
3.2.2. 현장관리규격을 활용한 용접부 품질평가 .....	15

3.3 머신러닝을 이용한 모델링 .....	16
제4장 연구결과 .....	18
4.1 용접 공정 변수에 따른 용접부 특성 .....	18
4.2 용접 품질 지표에 따른 실측 값 비교 .....	21
4.3 머신러닝 기반 회귀 학습 모델 예측 결과 .....	24
4.4 타당성 검증을 위한 SNN 분석 .....	31
제5장 결론 .....	37
참고문헌 .....	39

## List of Figures

Fig. 1.1	Porosity Formation Behaviour as Function of Heat Input	3
Fig. 1.2	X-ray RT and Bead Cross-section Images of Welds	4
Fig. 1.3	Comparison of Number of Blowholes	5
Fig. 2.1	Mechanism of the Porosity by the Heat Input	8
Fig. 2.2	Schematic of CMT Welding Process	9
Fig. 2.3	Welding Waveform and High Speed Images in CMT Process	11
Fig. 3.1	Schematic Illustration	13
Fig. 3.2	Research Quality Indicators	14
Fig. 4.1	Welding Speed 56cm/min; Bead Surface and Bead Cross-section	18
Fig. 4.2	Welding Speed 66cm/min; Bead Surface and Bead Cross-section	19
Fig. 4.3	Welding Speed 76cm/min; Bead Surface and Bead Cross-section	20
Fig. 4.4	Bead Cross-section by the Heat Input	21
Fig. 4.5	Comparison of the Real Measurements	24
Fig. 4.6	Residual Plots of the Bead Width	25
Fig. 4.7	Residual Plots of the Slide Length	26
Fig. 4.8	Residual Plots of the Throat Thickness	27
Fig. 4.9	Residual Plots of the Leg Length	28
Fig. 4.10	Residual Plots of the Penetration Depth	29
Fig. 4.11	Residual Plots of the Reinforcement Height	30
Fig. 4.12	Residual Plots of the Toe Angle	31
Fig. 4.13	Shallow Neural Network Result	32
Fig. 4.14	Comparison of the Training and Test of Bead Width SNN	33
Fig. 4.15	Comparison of the Training and Test of Penetration Depth SNN	34
Fig. 4.16	Comparison of the Training and Test of Leg Length SNN	34
Fig. 4.17	Shallow Neural Network Result	35,36



## List of Table

Table. 1.1 Chemical Compositions of Test Wires .....	5
Table. 3.1 Chemical Composition of DP 590, KC-25 Wire .....	12
Table. 3.2 Mechanical Properties of DP 590, KC-25 Wire .....	12
Table. 3.3 Welding Conditions .....	13
Table. 3.4 Comparison of the Indicators .....	15
Table. 3.5 Welding Quality Standard .....	15
Table. 3.6 Input and Output Parameter for Machine Learning .....	17
Table. 4.1 Welding Quality Standard by MS181-13 .....	21
Table. 4.2 Regression Model Analysis Result of Bead Width .....	25
Table. 4.3 Regression Model Analysis Result of Side Length .....	26
Table. 4.4 Regression Model Analysis Result of Throat Thickness .....	27
Table. 4.5 Regression Model Analysis Result of Leg Length .....	28
Table. 4.6 Regression Model Analysis Result of Penetration Depth .....	29
Table. 4.7 Regression Model Analysis Result of Reinforcement Height .....	30
Table. 4.8 Regression Model Analysis Result of Toe Angle .....	31
Table. 4.9 Comparison of the Results .....	37

## ABSTRACT

# Optimization of the Process Parameter for the Quality Standard Prediction of the High Strength GA Steel CMT Welded Joint based on Machine Learning

Jo Yun Hee

Advisor : Prof. Bang, Hee-Seon, Ph.D.

Department of Welding and Joining Science Engineering,

Graduate School of Chosun University

Recently, the adaption of the GA steel which has high corrosion resistance is increasing to the automobile. But, in case of th GA steel, the differences between melting point of the steel and boiling point of the zinc leads to defect such as the porosity. It causes not only the decreasing the strength of the joint, also decreasing the productivity. Thus, it must be solved to improve the productivity.

This study is to investigate the effect of process parameters on possibility to effectively reduce porosity in welded joints under different heat inputs ranging from 155 to 458J /mm by CMT process. Cold metal transfer welding that is automated GMAW process related to short circuit transfer has been

used to join galvanized steel sheets in a lap joint without a gap. Moreover, machine learning has been performed to predict the quality factor and this result is compared with that of shallow neural network.

Therefore, this study involves an investigation of the optimization of process parameters based on machine learning for predicting quality factor in high strength GA steel welded joints by CMT.

# 제 1 장. 서 론

## 1.1 연구 배경 및 목적

최근 전세계적으로 환경 문제들이 대두됨에 따라 자동차 산업 역시 이산화탄소 배출에 대한 규제가 엄격해지고 있는 실정이다. 자동차 제조업들은 이산화탄소 배출 저감과 연비 효율을 위하여 차량 경량화를 선택하였고, 박판의 고강도강을 적용함으로써 차체 경량화에 성공하였으나, 자동차의 샤시 부품은 부식되기 좋은 환경에 노출되어있으므로 부식 문제에 대한 해결이 요구되었다. 산화된 강판은 차량의 내구성 뿐만 아니라 안정성 저하의 원인이 되므로 부식 저항성이 필수적으로 요구되므로, 자동차 제조사들은 부식 저항성과 가격 대비 효율이 뛰어난 아연 도장을 자동차 샤시 부품에 적용하였다.[1]

샤시 부품의 용접은 주로 GMAW(Gas Metal Arc Welding, 가스 메탈 아크 용접)이 적용되고 있지만 아연의 기화점은 906℃, 강판이 녹기 시작하는 온도는 1300℃로, 용접 시 발생하는 아크 열로 인한 아연의 기화가 강판의 용융보다 빠르므로 기화된 아연이 용접부 내에 잔류함으로써 용접부의 기공결함으로 이어진다. 또한, 아연 증기의 반력으로 스파터와 같은 결함으로 이어질 수 있는 문제가 발생한다. 이는 불안정한 아크로 인한 용접성 저하나 용접 이음부의 강도 저하로 인한 후처리 공정이 불가피하므로 자동차 제조사들의 생산성을 크게 저하 시키는 주요 요인 중 하나이며 반드시 해결 되어야 하는 부분이다.[2,12]

이러한 문제점들을 해결하기 위해서는 추가 열원을 복합한 하이브리드 공정(TIG-MIG/GTA-GMA 하이브리드 용접)을 적용하거나, AC Pulse 용접, 동기화 펄스 와이어 송급, CMT 용접 공정과 같은 활성가스를 활용한 용접 공정 또는, 아연도금 강판 용접 시 갭(gap)을 두고 용접을 수행하여 아연증기의 방출을 유도하는 방법과 약 5%의 산소를 혼합한 가스를 사용하여 기화 및 아연 증기의 폭발을 지연시키

는 방법들이 제안되었다. 또한, 재료적인 측면으로 보았을 때, 저 Si-Mn계 용접 재료를 사용하여 용융풀의 점도를 조절하여 아연증기의 방출을 용이하게 하는 방법 등이 제안되었다. 갭을 두는 경우, 갭은 아연 증기가 빠져나가는 통로로 작용하므로 기공 저감에 효과적이며, 스파터의 발생을 피하기 위해서는 비산 현상 저감에 효과적인 상대적으로 높은 전류에서 고속으로 용접을 수행하는 방법이 효과적이므로, 기공 저감에 효과적이다.[3-10]

본 논문에서는 저 Si-Mn계 와이어를 적용한 CMT 용접 공정변수 다변화를 통해 비드 특성 변화를 고찰하여 기공 저감 조건을 도출하고자 하였다. 또한, 본 연구의 대상 부품은 자동차 샤시 부품으로, 용접실험 수행 이후 완성차 기업인 현대기아차에서 제시한 공급 규격에 만족할 수 있는 공정변수로 머신러닝을 이용한 기준치 예측을 통해 품질기준을 역 예측하고자 한다.

## 1.2 국내외 기술 동향

앞서 언급했던 것처럼 다양한 문헌에서 아연도금강판의 용접부에서 발생하는 기공 결함의 제어를 위한 많은 방법들이 제안되었다.

Md.R.U.Ahsan et al은 저입열 공정인 CMT 용접 공정을 적용하여 용접 공정변수 다변화를 통한 넓은 범위의 입열량(160~350J/mm)을 통해 기공 형성 거동의 경향성을 파악하고, 입열량에 따른 기공 저감 조건을 제안하였다.[2]

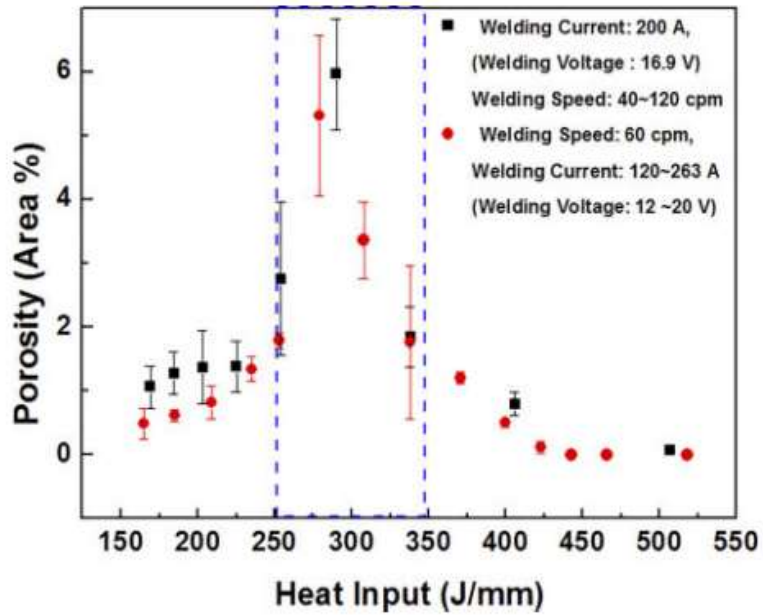


Figure. 1.2.1 Porosity formation behaviour as function of heat input[2]

연구 결과, Fig.1.2.1에 나타난 것처럼 저입열(< 250J/mm) 조건에서는 루트부에서 블로우홀 형태로 기공이 발생하는 것을 확인할 수 있었고, 중입열(250~350 J/mm)의 조건에서 열린 기공의 형태인 피트가 발생하는 것으로 나타났다. 또한, 고입열(350J/mm <) 조건에서는 발생하지 않는 것을 확인할 수 있었다.[2]




Figure. 1.2.2 X-ray RT and bead cross-section images of welds at different heat input conditions[2]

또한, 아연도금강판 용접부의 기공을 줄이기 위해서는 용접 재료의 성분 중 Si와 Mn의 함량을 줄이는 방법을 수행하였다. 용접 재료 중 규소와 망간의 함량을 줄일 경우, 용융된 금속의 점성이 감소하여 증기된 아연이 용융지 밖으로의 배출

이 용이하다는 특징이 있다.[10]

S.Izutani et al은 용접 재료 내의 규소 함량을 다양화하여 용융지의 표면장력을 증가시키므로써 용융풀의 선형을 방지시켜 용접부의 루트로부터 아연증기배출이 용이하다는 것을 연구를 통해 제안하였다.Table. 1.2.1과 Fig.1.2.3에 나타난 그래프를 통해 Si와 Mn의 함량이 적어짐에 따라 기공의 형성이 줄어드는 것을 확인할 수 있다.[11]

Table. 1.2.1 Chemical compositions of test wires[11]

	(mass%)				
	C	Si	Mn	P	S
<b>Wire 1</b>	0.03	0.92	1.36	0.008	0.057
<b>Wire 2</b>	0.05	0.56	1.12	0.003	0.014
<b>Wire 3</b>	0.05	0.76	1.25	0.008	0.004
<b>Wire 4</b>	0.05	0.72	0.60	0.009	0.005




Figure. 1.2.3 Comparison of number of blowholes[11]



뿐만 아니라, H. Matsui et al은 연구를 통해 피크 전류가 높고 피크 시간이 짧은 펄스용접을 적용하고, 용접 토치각을 기울이는 방법을 제안했다. 또한, 진동을 통해 용융풀의 잔류하고 있는 아연증기를 방출하는 방안을 제안하였다. 물리적인 진동을 줌으로써 용융풀 내의 아연 증기를 밖으로 내보내는 과정을 통해 기공 저감을 효과적으로 수행할 수 있음을 확인할 수 있다.[8,9]

본 연구는 현재 생산되고 있는 실제 완성차에 적용 중인 샤시 부품에 대한 연구로, 현장에서의 적용이 가능한 조건을 고려해야 하므로 본 연구에서는 저입열공정인 CMT 용접 공정과 저 Si 및 Mn계의 용접 재료를 적용하여 기공 저감 조건을 도출하고 머신러닝을 활용하여 품질 기준을 예측하고자 하였다.

## 제 2 장. 이론적 배경

### 2.1 아연도금강 아크용접부 결함

아연도금강판은 강재에 비하여 낮은 용점으로 도장이 편리하다는 장점과 부식 저항성이 높다는 장점이 있으나, 소재 특성상 도장된 아연과 강판의 비등점 차이로 인해 아크열로 증발한 아연이 증기 형태를 띄게 되며 기공 결함으로 이어지는 치명적인 단점이 있다. 기공 결함은 용접 이음부의 강도를 저하 시키므로 후처리 공정이 꼭 필요하다.[12]

결함이 발생하는 매커니즘에 대해 설명하자면, 먼저 용접 시 발생하는 아크의 열로 인해 용점이 더 낮은 아연이 기화하게 된다. 기화한 아연은 용융된 강판의 결정립계 사이로 침투하게 되고, 아연 증기가 결정립계 내에서 잔류하게 되면서 나타나는 양상이 바로 기공 결함이다. 기공 결함은 블로우홀(Blow hole)과 피트(Pit)의 형태로 나뉘어져 있으며, 블로우홀은 기공이 용접부 내에서 빠져나가지 못한 채로 굳어진 것을 일컫으며, 피트는 증기가 빠져나가는 도중 굳어져 열린 기

공의 형태를 띠는 것을 말한다.[7-10]

Fig. 2.1.1에 나타낸 자료에 따르면, 입열량에 따른 야연증기의 형성부터 용융지의 응고까지의 매커니즘을 모식도를 통해 확인할 수 있다. 저입열 구간의 경우, 야연 증기가 형성되었으나 용융지를 빠져나가지 못하고 굳어져 블로우홀 형태로 남아있는 것을 확인할 수 있다. 중입열의 경우, 증기가 빠져나가던 중 굳어진, 열린 기공의 형태인 피트 결함으로 나타나는 것을 확인할 수 있다. 또한, 고입열의 경우, 용융지가 굳어지는데에 충분한 시간이 소요되므로 기공이 전부 용융지 밖으로 빠져나왔기 때문에 기공은 발생하지 않는 것으로 나타났다. [2]




Figure. 2.1.1 Mechanism of the porosity by the heat input[2]

## 2.2 CMT(Cold Metal Transfer) 용접 공정

CMT(Cold Metal Transfer) 용접 공정은 2004년 미국의 Fronius 사에서 최초 개발한 용접 공정으로, 기존의 아크 용접과는 완전히 다른, 새로운 방식으로 용적이행이 제어되고, MIG나 MAG 용접 공정에 비하여 낮은 온도에서 금속이행이 이루어진다. 기존의 MIG 용접에서는 단락단계에서 전류가 증가하지만, CMT 용접 공정에서는 단락단계에서 와이어가 후진하며 전류가 낮게 유지된다. 이러한 용적이행은 용적의 표면장력 증가로 낮은 전류에서도 안정적이게 아크를 유지시키고, 스패터 저감에 효과적이다. Fig. 2.2.1에 나타난 것처럼 CMT 용접 공정에서는 와이어 송급의 제어를 통하여 강제적으로 단락을 이행시킨다. [14, 15]




Fig. 2.2.1 Schematic of CMT welding process

CMT 용접 공정은 전류의 파형 제어와 와이어의 기계적 송급 제어를 통한 진동 제어를 동시에 수행한다. 아크 열로 와이어의 선단과 모재가 용융되어 용융지가 형성되면 와이어가 용융지 방향으로 전진 송급된다.[8]

CMT 용접 공정의 매커니즘은 단락을 끊어지게 하기 위하여 전류를 0으로 하고, 단락 직전의 전류는 0A로, 단락이 이루어지는 순간 아크의 반발력에 의해서 순간적으로 단락의 발생이 억제되고 0A의 전류에서 단락이행이 이루어질 수 있도록 한

다. 또한, 와이어의 후진으로 강제적인 단락 해소를 수행함으로써 낮은 전류에서 아크가 재생되게 함으로 아크의 폭발력을 최소화한다.[16]

CMT 용접 공정은 와이어의 송급을 제어하여 아크 지속 시간과 단락 시간을 통제함으로써 적은 입열량을 유지할 수 있다. 다시 말하자면, 아크가 유지되는 동안 와이어를 송급하며 와이어 선단을 가열하고 가열된 와이어의 선단이 모재와 접촉을 일으키면서 단락이 발생하게 된다. 단락이 발생하며 아크가 끊어짐과 동시에 용접 전류를 낮춘다. 그 다음, 와이어가 후퇴하며 다시 아크를 발생시키는 공정을 반복 수행함으로써 입열량을 비롯하여 희석률과 용입깊이를 낮게 유지할 수 있다.[17,18]

CMT 용접 공정은 기존 GMAW에 비하여 낮은 입열량을 갖는 것이 특징으로, 이를 통하여 용접 시 입열로 인한 변형을 최소화할 수 있다. CMT 용접 공정의 경우, 알루미늄 용융용접에 있어서 TIG 용접은 생산성이 낮고, 레이저 용접은 장비가 고가이고, 갭 관리가 까다로운 반면에 CMT 용접 공정은 갭이 있는 경우 쉽게 접합이 가능하다.[19,20]

CMT 용접은 로봇을 활용한 자동화 작업으로, 금속 와이어와 아크를 이용한 적층 공정에 CMT를 적용하여 일반적인 적층 공정에 비해 빠른 생산속도를 낼 수 있다. 또한, 곡선 용접 시, 발생하는 크랙이나 변형과 같은 결함을 저감 시키는 효과를 낼 수 있다.[21,22]

CMT 용접 공정의 주기는 평균적으로 63Hz이고, 최대 70Hz이며, 주기는 용접 조건에 따라 다르게 제어된다. CMT 용접 공정에 의한 용접 파형과 실제 용접 수행을 촬영한 고속영상을 Figure. 2.2.1에 나타내었다.[23]




Figure. 2.2.1 Welding waveform and high speed images in CMT process[23]

## 제 3 장 . 연구방법

### 3.1 용접 조건 및 실험

용접 실험에서는 용접 공정변수 다변화에 따른 비드 특성을 관찰하여 기공 결함 발생에 대한 경향성을 파악하고 기공 저감 조건을 도출하고자 하였다. 또한, 용접 실험 수행 결과를 가지고 H사에서 공급하는 용접품질규격인 MS181-13에 대한 용접

품질 평가 지표 4가지 항목 뿐만 아니라 세 항목을 더 추가한 7개의 연구 품질 지표를 통해 용접 품질 평가를 수행하였다.

본 논문에서 사용된 강재는 자동차 부품으로 다양하게 활용되고 있는 고강도강인 DP 590 GA 강으로, 실험에 사용된 강재와 와이어의 화학적 조성과 기계적 물성은 Table. 3.1.1, Table. 3.1.2와 같다.

Table. 3.1.1 Chemical composition of DP 590, KC-25 wire

Composition (%) Material	C	Mn	Si	P	S
	<b>DP 590</b>	0.0666	1.989	0.193	0.015
<b>KS-25M</b>	0.07	1.2	0.67	0.015	0.011

Talbe. 3.1.2 Mechanical properties of DP 590, KC-25 wire

Material	Mechanical Properties		
	Tensile Strength (MPa)	Elongation (%)	Yield Strength (MPa)
<b>DP 590</b>	595	30	369
<b>KS-25M</b>	520	33	430

용접 실험은 233mm(L) X 100mm(W) X 2.3mm(T)의 크기의 시편을 20mm로 겹친 겹치기 용접을 수행하였으며 용접 실험의 모식도는 Fig. 3.1.1에 나타내었다. 와이

어는 저 Si-Mn계 와이어인 KS-25M으로 1.2Φ 두께의 와이어를 사용하였다. 가스 유량은 20~25L/min, 용접 토치 팁과 모재 간극은 15mm의 조건으로 수행되었다. 공정변수 다변화에 따른 30개의 조건으로 용접수행을 하였으며, 공정변수 다변화의 자세한 조건은 Table. 3.1.3에 나타냈다.




Fig. 3.1.1 Schematic illustration

Table. 3.1.3 Welding conditions

용접공정변수	용접 속도 : 56cm/min, 66cm/min, 76cm/min									
전류 (A)	230	236	231	225	219	209	188	166	156	147
전압 (V)	17.9	17.1	17.1	16.8	16.6	16.1	15.1	14.3	13.8	13.4
와이어 송급속도 (m/min)	8.8	8.3	7.8	7.3	6.8	6.3	5.8	5.3	4.8	4.3



### 3.2 CMT 용접부 품질 특성 평가

#### 3.2.1 현장관리규격(MS181-13)과 연구 용접품질지표

본 논문은 실제 완성차에 적용되는 프론트 바디 마운팅 부품에 대한 연구로, 용접 실험 수행 이후, 용접성 평가를 위해 현대기아차에서 공급하는 품질 규격인 MS181-13 중 용접 품질 평가 기준 4가지 항목을 비롯해 3가지 항목을 추가하여 총 7개의 항목의 연구 품질 지표를 선정하였으며, 7대 연구 품질 지표에 대한 사항은 Fig. 3.2.1.1에, 연구 품질 지표와 현장 품질 지표 비교에 대한 자세한 내용은 Table. 3.2.1.1에 나타내었다. L1부터 L3는 기존의 현장 품질 지표에 해당하지 않는 항목들로, 보다 더 자세한 기계학습을 위하여 본 연구에서는 연구 품질 지표로 추가 선정하여 품질 평가를 진행하였다.

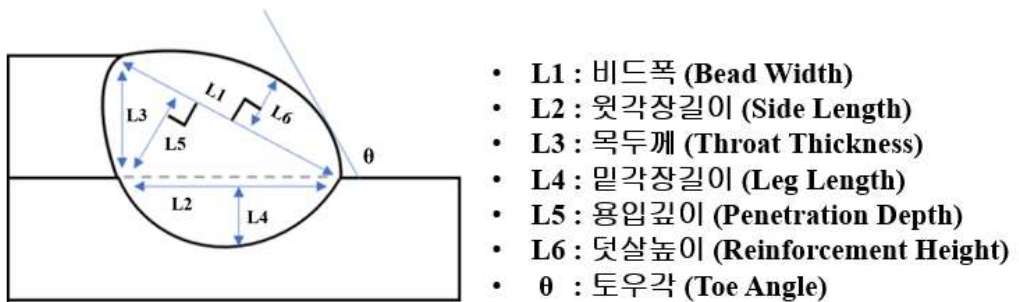


Figure. 3.2.1 Research quality indicators

Table. 3.2.1 Comparison of the indicators

용접 품질관련 현장관리규격(MS18-13)	연구 품질 지표
용입깊이	비드폭
밀각장길이	윗각장길이
덧살높이	목두께
토우각	-

### 3.2.2 현장관리규격을 활용한 용접부 품질평가

본 연구에서는 현장관리규격의 4개 항목을 포함한 총 7개의 품질지표를 선정하여 용접실험 수행 이후, 시편에 대한 용접성 품질평가를 수행하였다. 용접성 평가는 4대 항목인 용입깊이와 밀각장길이, 덧살높이, 토우각에 대하여 MS181-13이 제시하는 기준에 따라 실시하였으며, 상세한 기준치는 Table. 3.2.2.1에 나타났다.

Table. 3.2.1 Welding quality standard

용접 품질관련 현장관리규격(MS181-13)		
용입깊이	0.1mm X T ≤	0.23mm
밀각장길이	1.0mm X T ≤	2.3mm
덧살높이	≥0.5mm X L	최소 1.25mm
토우각	110° ≤	110°

### 3.3 머신러닝을 이용한 모델링

많은 연구들이 외부 열원을 이용한 용융용접의 용접 품질을 예측하기 위해 머신러닝을 활용한 온도분포에 대한 모델링들을 적용하고 있다. 외부 열원을 이용한 아크용접이나 레이저 용접과 같은 경우, 외부 열원으로 용융이 되므로 외부열원과 용접부의 상호작용을 모델링 하는 것이 온도분포해석에 있어서 가장 중요하다. 용접부의 크기와 비드의 폭, 깊이를 예측하기 위해서는 용접부의 온도분포를 먼저 구해야 하는데, 이는 열전도 지배 방정식을 풀이를 위한 로젠탈 식을 적용하는 해석 모델과 유한요소와 유한체적/차분을 이용한 수치 모델을 이용하여 구할 수 있다. [24,25]

지배방정식과 물리적 법칙을 기반이었던 전과는 다르게 최근 데이터를 기반으로 하는 머신러닝에 대한 연구가 활발하다. 머신러닝은 물리적 인덱스에 기반하는 것이 아니라 입력된 데이터를 기반으로 하여 스스로 학습하여 법칙을 도출하는 방법으로 신경회로망이 가장 대표적이며, 비신경회로망에는 서포트 벡터머신(Support Vector Machine), GBT(Gradient Boosted Trees), 랜덤포레스트(Random Forest) 등이 있다.[26]

머신러닝 모델을 구축하기 위해 입력값에는 앞서 제시된 CMT 용접 공정의 공정 변수인 용접 속도, 전류, 전압, 와이어 송금 속도가, 출력값으로는 7대 연구 품질 지표가 사용되었다. 자세한 내용은 Table. 3.3.1에 나타내었으며, 논문 데이터를 기반으로 총 30개의 조건에 대한 데이터를 수집하였다.

Table. 3.3.1 Input and output parameter for machine learning

No	1	2	3	4
<b>Input Parameter</b>	Welding Speed	Voltage	Current	Wire feeding Speed

Model	Regression Model						
<b>Output Parameter</b>	Bead Width	Leg Length	Side Length	Penetration depth	Throat Thickness	Reinforcement Height	Toe Angle

본 연구에서는 CMT 용접 공정을 적용한 고강도 아연도금강판의 기공 결함 해결에 대해 고찰하였으며, 7대 연구 품질 지표의 품질 예측을 위한 모델 구축을 위하여 MATLAB® R2020a의 머신러닝 모델 및 인공신경망 모델을 사용하였다. 출력값에 사용된 데이터인 비드폭, 밑각장길이, 윗각장길이, 용입깊이, 목두께, 덧살높이, 토우각의 예측을 위하여 회귀 학습을 진행하였으며, 회귀 학습 모델은 총 19개의 모델을 사용하였다. 회귀 학습의 결과 값 중 상위 3개의 모델인 선형 회귀(Linear Regression), SVM(서포트 벡터 머신, Support Vector Machine), GPR(가우스 프로세스 회귀, Gaussian Process Regression)를 선정하였다. 선형 회귀는 상호 작용 모델을 사용했으며, 서포트 벡터 머신은 커널 함수가 3차로 이루어진 비선형 모델을, 가우스 프로세스 회귀 모델은 지수 커널 함수를 적용하였다.[27]

회귀 학습 이후 모든 출력값에 대하여 인공신경망을 통해 머신러닝 모델을 구성하고, 용접 품질에 대해 예측하였다. 인공신경망은 입력층, 은닉층, 출력층으로 구성된 모델로, 각 층은 노드(node)들로 이루어져있다. 인공신경망 모델은 입력값과 출력값이 주어졌을 때, 스스로 학습하는 지도학습을 통해 수행된다. 본 연구에서 사용된 인공신경망은 1개의 은닉층으로 구성된 얇은 신경망(Shallow Neural Network, SNN)으로, 은닉층의 노드 수는 노드 수 다변화를 통한 경향성 파악 후

30개로 수행하였다. 얇은 신경망 분석은 훈련(Training), 검증(Validation), 테스트(Testing) 데이터를 각각 70%, 15%, 15%로 나눠 정확도를 검증하였다.[28]

## 제 4 장 . 연구결과

### 4.1 용접공정변수에 따른 용접부 특성

용접 실험 결과, 용접 공정변수에 따른 용접부의 특성에 대해 고찰해보았다. 먼저, 용융풀 제어를 통한 비드 특성에 대하여 관찰해보았는데, Fig.4.1.1에 나타난 비드 표면과 단면 비드의 형상에서 확인할 수 있듯이, 56cm/min 조건에서는 비드 표면에서 피트(Pit)가 발견되지 않았으나 입열량 45.4J/cm 이하의 조건인 Type 2 와 3에서는 블로우홀(Blowhole)이 관찰되었다. 또한, 입열량이 감소함에 따라 용입깊이가 감소하는 특성을 확인할 수 있었으며, 특히 저입열 조건 중에서도 가장 입열량이 적었던 Type 3의 경우, 거의 용융이 되지 않았음을 확인할 수 있었다.




Figure. 4.1.1 Welding speed 56cm/min; bead surface and bead cross-section

용접속도 66cm/min 조건 관찰 결과, Fig.4.1.2에 나타난 것처럼 45.4J/cm과

24.6J/cm의 입열량에서 피트와 블로우홀이 발생한 것을 확인할 수 있었다. 또한, 53.4J/cm에서는 결함이 없는 가장 건전한 용접부를 확인할 수 있었으며, 입열량 감소로 인해 Type 1에 비해 Type 3에서 용입깊이가 현저히 줄어든 것을 관찰할 수 있었다.


Type	Bead Surface	Bead Cross-section
Type 1 (53.4J/cm)		
Type 2 (45.4J/cm)		
Type 3 (24.6J/cm)		

Figure. 4.1.2 Welding speed 66cm/min; bead surface and bead cross-section

용접속도 76cm/min 조건의 경우, Fig.4.1.3에 제시된 것처럼 입열량 27.8J/cm 이하의 조건의 모든 표면에서 피트가 관찰되었다. 이는 상대적으로 빠른 용접속도에 의해 아연증기의 배출이 용이하지 못해 발생한 것으로 사료된다.

Type	Bead Surface	Bead Cross-section
Type 1 (39.4J/cm)		
Type 2 (33.4J/cm)		
Type 3 (18.1J/cm)		

Figure. 4.1.3 Welding speed 76cm/min; bead surface and bead cross-section

앞서 용접 공정변수 조건별 용접부 특성을 살펴보고, 모든 조건의 입열량을 계산하여 고입열, 중입열, 저입열 조건 구간으로 나누어 관찰해보았다. Fig 4.1.4 에 나타난 것처럼 고입열 조건(41.9J/cm~53.4J/cm)에서는 기공이 형성되었으나 모두 방출되어 기공 결함 없이 깨끗한 단면을 확인할 수 있었다. 또한, 입열량 45.3J/cm의 조건인 66cm/min, 239A, 17.9V, 8.8m/min 조건에서 가장 건전한 용접부를 확인할 수 있었다. 이는 기공 저감에 가장 적절한 조건으로 나타났다. 중입열 조건(32.1J/cm~40.7J/cm)에서는 형성된 아연 증기가 잔류하여 블로우홀의 형태의 결함이 발견되었다. 저입열 조건(18.1J/cm~30.9J/cm)의 조건에서는 기화된 아연이 분출되는 과정에서 굳어져 열린 기공의 형태인 피트 결함으로 발생된 것을 확인할 수 있었다. Fig 4.1.4 (c)에 나타난 사진은 용접속도 76cm/min 조건으로, 낮은 입열량에 비해 용접 속도가 빨라 증기가 빠져나가기에 시간이 부족하여 발생한 것으로 사료된다.




Figure. 4.1.4 Bead cross-section by the heat inputs

## 4.2 용접 품질 지표에 따른 실측 값 비교

CMT 용접 공정을 적용한 아연도금강판의 용접 실험 이후, 비드 단면의 육안검사와 단면 시험을 실시하였다. 육안 검사의 경우, 기공의 유무를 주안점으로 확인하였다.

본 논문의 연구 대상은 실제 완성차에 적용되고 있는 프론트 바디 마운팅 부품으로, 단면 시험은 H사에서 공급하는 규격에 의거하여 실시하였다. 규격에 해당하는 용접 품질 기준은 Table 4.2.1에 나타내었다.




Table. 4.2.1 Welding quality standard by MS181-13


항목	규격
용입깊이	0.23mm 이상
밑각장길이	2.3mm 이상
덧살높이	최소 1.15m
토우각	110°

용접 품질 평가는 단면 시험을 통해 이루어졌으며, 시편의 용접선에 수직 방향으로 절단하여 연마 후 Nital 4% 용액에 3초간 3번씩 노출시켜 부식 시킨 후 전자현미경을 사용하여 앞서 제시된 7대 연구 품질 지표인 비드폭, 윗각장길이, 목두께, 밑각장길이, 용입깊이, 덧살높이, 토우각 등을 측정하였다.


Fig. 4.2.1에 나타난 그래프 중간의 붉은 선은 용접 지표에 따른 실측값의 원활한 비교를 위하여 용접 품질 지표의 규격을 표시한 것이다. 각 용접 속도별로 나타난 세 개의 값은 가독성을 위하여 용접 속도에 따라 입열량 순으로 나열을 했을 때, 최저입열 조건과 중입열, 최고입열 조건의 값을 선정하였다.




**(a) Penetration Depth**



**(b) Leg Length**



**(c) Reinforcement Height**



(d) Toe Angle

Figure. 4.2.1 Comparison of the real measurement results with MS181-13 standard; (a) Penetration Depth, (b) Leg Length, (c) Reinforcement Height, (d) Toe Angle

용접 지표에 따른 실측값 비교 결과, 용접 기술 표준 측정 방법에 해당하는 4개 항목인 용입깊이와 밀각장길이, 덧살높이, 토우각에 대한 실측값은 MS181-13 규격에서 제시하는 기술 표준에 만족하는 것으로 나타났다.

또한, 용접 속도가 느려지고 입열량이 커질수록 지표들의 수치가 커지는 경향성을 보였으나, 토우각에서는 감소했던 측정값이 상승하는 양상을 보였는데, 이는 66cm/min 조건의 실험 당시 스패터의 간섭으로 갭이 발생하였기 때문에 실측값이 상승한 것으로 사료된다.

### 4.3 머신러닝 기반 회귀 학습 모델 예측 결과

다음은 Table 4.3.1은 Matlab을 활용한 비드폭의 회귀 모델에 따른 예측 정확도를 확인한 것이다. 총 19개의 회귀 학습 모델 중 평균적으로 결정계수의 값이 가장 높은 상위 3개의 모델인 상호작용 선형 회귀 모델과 3차 서포트 벡터 머신

모델, 지수 GPR 모델을 선정하였다. 비드폭에 대한 회귀 모델 분석 결과는 전체적으로 높은 결과값을 보였는데, 이는 높은 예측도를 의미한다. 또한, 예측도의 높고 낮음의 척도는 결정계수 값 0.90을 기준으로 임의로 선정하였다.

GPR 모델에서의 MSE(Mean Square Error, 평균 제곱 오차)는  $9.02e^{-08} \text{ mm}^2$ , RSME(Root Mean Square Error, 평균 제곱근 오차)는 0.0003 mm, 결정계수는 1.00으로 나타났다. 이는 다른 학습 모델에 비해 높은 정확도를 갖고 있으나, GPR은 2차원의 학습모델로, 자유도가 높은 모델이므로 과적합이 발생한 것으로 사료된다. 또한, 4.3.1에 나타낸 잔차 그래프가 산발적으로 보이는 경향이 있으나, 이는 적은 양의 데이터를 나타낸 것이기 때문으로 사료된다.

Table. 4.3.1 Regression model analysis result of bead width

Model	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>
Linear Regression	0.05183	0.22767	0.95
SVM	0.01987	0.14097	0.98
GPR	9.02e-08	0.00030	1.00





Figure. 4.3.1. Residual plots of the bead width

다음은 윗각장길이의 회귀 학습 모델에 대한 결과와 잔차 그래프를 Table. 4.3.2와 Figure 4.3.2에 나타내었다. 윗각장길이의 GPR 모델의 평균 제곱 오차와 평균 제곱근 오차는 각각  $5.5e^{-10} \text{ mm}^2$ ,  $2.366e^{-05} \text{ mm}$ 로 나타났다. GPR 모델의 결정계수는 1.00으로 정확한 윗각장길이의 예측이 가능한 것으로 나타났으나, 선형 회귀 모델과 SVM 모델의 결정계수가 각각 0.56, 0.35로 나타난 것으로 보아 GPR 모델의 결과값의 신뢰도가 낮은 것으로 추론된다.

Table. 4.3.2 Regression model analysis result of side length

Model	MSE ( $\text{mm}^2$ )	RMSE (mm)	$R^2$
Linear Regression	0.01196	0.10938	0.56
SVM	0.01759	0.13266	0.35
GPR	$5.5e-10$	$2.36e-05$	1.00



(a) Linear Model

(b) SVM Model

(c) GPR Model


Figure. 4.3.2. Residual plots of the side length

다음은 목두께에 대한 예측 정확도와 상위 세 모델에 대한 잔차 그래프를 Table 4.3.3과 Figure 4.3.3에 나타내었다. 세 모델 중 GPR 모델이 0.65로 결정계수의 값이 가장 높았으나, 이는 0.90에 한참 못 미치는 낮은 예측도를 보였고, GPR 모델 뿐만 아니라 전체적으로 결정계수 값이 낮았기 때문에 정확한 예측이라고 정의하기엔 어렵다.

목두께에 대한 학습 모델들의 잔차 그래프 분석 결과, 세 모델 모두 1.2~1.7 mm 사이의 구간에 집중된 것으로 나타났다.

Table. 4.3.3. Regression model analysis result of throat thickness

Model	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>
Linear Regression	0.01136	0.10659	0.47
SVM	0.01307	0.11433	0.39
GPR	0.00757	0.08705	0.65



(a) Linear Model

(b) SVM Model

(c) GPR Model


Figure. 4.3.3. Residual plots of the throat thickness

다음은 밑각장길이에 대한 회귀 학습 모델의 예측 결과를 Table 4.3.4와 Figure 4.3.4에 나타내었다. 세 모델 모두 0.95 이상의 결정계수로 높은 예측도를 보였다. 특히 GPR 모델이 1.00의 결정계수 값을 보였으므로, 예측 값의 유사도가 실측 값과 거의 일치하는 것으로 볼 수 있다.

선형 회귀 모델과 SVM 모델의 잔차 그래프가 GPR 모델의 잔차 그래프에 비해 산발적으로 보이는 경향이 있으나, 이는 적은 양의 데이터로 인한 것으로 결정계수는 모두 1에 가까운 것으로 나타났다.

Table. 4.3.4. Regression model analysis result of leg length

Model	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>
Linear Regression	0.0474	0.2179	0.95
SVM	0.0254	0.1595	0.97
GPR	1.19e-07	0.0003	1.00



(a) Linear Model

(b) SVM Model

(c) GPR Model


Figure. 4.3.4. Residual plots of the leg length

다음은 용입깊이에 대한 회귀 학습 모델 예측 결과와 잔차 그래프를 Table 4.3.5, Figure 4.3.5에 나타내었다. 용입깊이에 대한 결정계수는 세 모델 모두 0.90 이상의 값으로, 과적합 없이 유사도가 실측 값과 거의 유사한 것으로 나타났다.

또한, 세 모델의 잔차 그래프는 서로 비슷한 양상을 띠고 있으며, 앞서 언급한 밀각장길이의 잔차 그래프들처럼 산발적인 모습을 하고 있으나, 이것 역시 잔차가 크게 차이가 나는 것이 아니라 적은 수의 데이터로 인해 산발적으로 보이는 경향이 있다.

Table. 4.3.5. Regression model analysis result of penetration depth

Model	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>
Linear Regression	0.00630	0.07937	0.91
SVM	0.00718	0.08474	0.90
GPR	0.00294	0.05422	0.96



(a) Linear Model

(b) SVM Model

(c) GPR Model

Figure. 4.3.5. Residual plots of the penetration depth



다음은 덧살높이에 대한 예측 결과값과 잔차 그래프를 Table 4.3.6과 Figure 4.3.6에 나타낸 것이다. 세 모델 중 GPR 모델이 0.82로 가장 높은 결정계수를 나타내었지만 전체적으로 낮은 유사도를 확인할 수 있었다. 덧살높이에 대한 예측 역시 낮은 유사도를 보였으며, 이는 적은 데이터 수가 원인인 것으로 사료된다.

Table. 4.3.6. Regression model analysis result of reinforcement height

Model	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>
Linear Regression	0.01252	0.11193	0.68
SVM	0.01360	0.11665	0.65
GPR	0.00719	0.08484	0.82

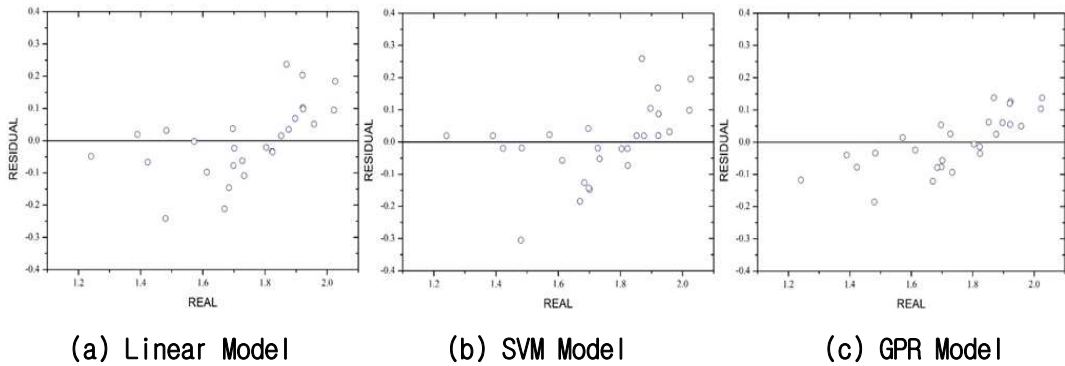


Figure. 4.3.6. Residual plots of the reinforcement height

다음은 토우각에 대한 회귀 학습 모델 예측 결과와 잔차 그래프를 Table 4.3.7과 Figure 4.3.7에 나타내었다. 학습 모델 예측 결과, GPR 모델에서 1.00의 결정계수를 보였으나 다른 모델들에서는 현저히 낮은 값을 확인할 수 있었다. 다른 모델의 결과 값을 미루어 보아, GPR 모델의 결정계수가 1.00이었지만 유사도가 낮은 것으로 사료된다.

Table. 4.3.7. Regression model analysis result of toe angle

Model	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>
Linear Regression	3.3573	1.8323	0.45
SVM	3.7762	1.9432	0.39
GPR	7.33e-08	0.0002	1.00




Figure. 4.3.7. Residual plots of the toe angle

머신러닝을 활용한 회귀 학습 모델 예측 결과, 비드폭과 밀각장길이, 용입깊이는 전체적으로 높은 유사도를 보였다. 다만, GPR 모델을 제외한 다른 모델에서 낮은 유사도가 나타난 윗각장길이와 토우각에 대해서는 데이터가 부족하여 일어난 현상으로 추론된다.

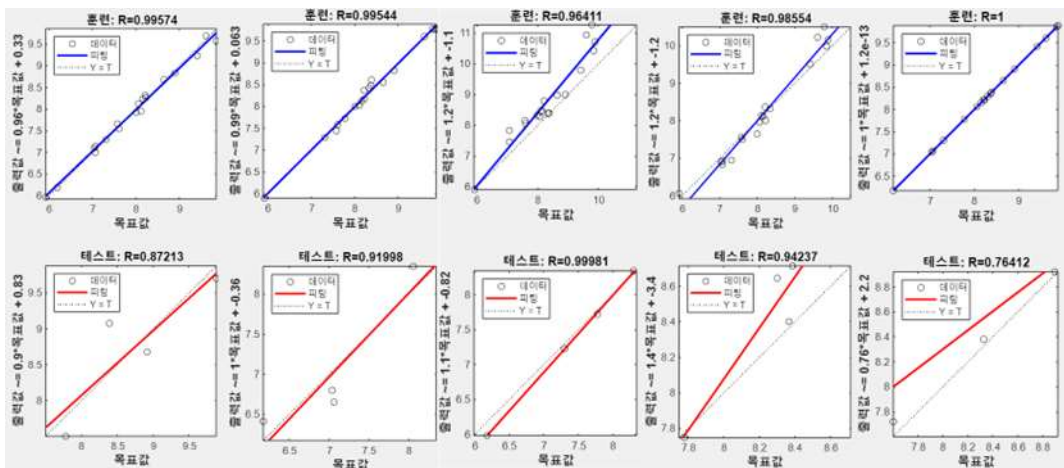
#### 4.4 타당성 검증을 위한 SNN 분석

회귀 학습 모델 예측 결과의 타당성 검증을 위하여 높은 유사도를 보였던 비드폭, 밀각장길이, 용입깊이에 대한 SNN(Shallow Neural Network, 얇은 신경망) 분

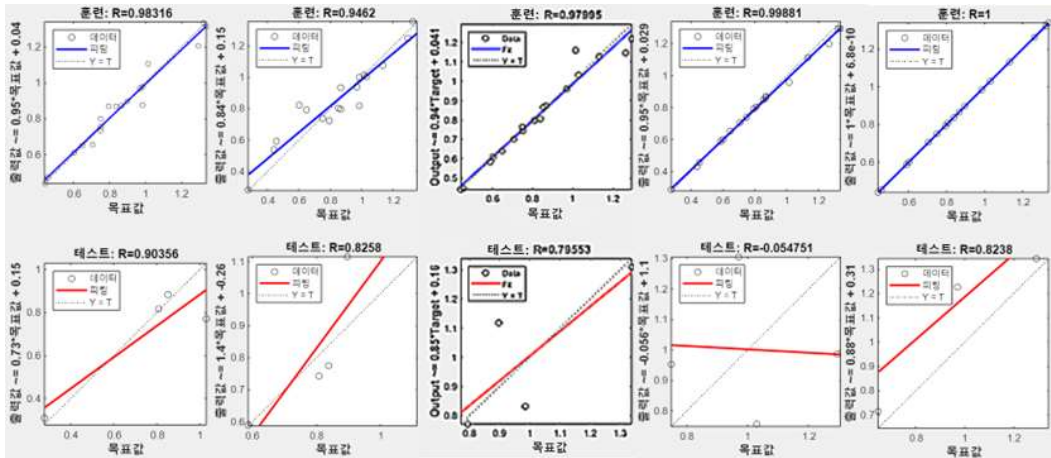
석을 하였다. Fig. 4.4.1은 유사도 상위 세 모델의 얇은 신경망 분석 결과를 나타낸 것이다.

얇은 신경망 같은 경우, 앞서 언급한 것처럼 은닉층 노드의 개수는 노드 수 다변화를 통해 경향성을 파악한 뒤, 선정하여 수행하였다. 그래프의 45도의 직선은 실측 값을 나타내며, 완벽한 피팅이 되려면 피팅 결과가 45도 직선에 위치해야 한다. 또한, Training 결과가 좋으나 Test 결과 값이 나쁠 경우, 이것은 모델의 과적합을 의미할 수 있으며, 노드 수를 줄임으로써 과적합을 방지할 수 있다.

Fig. 4.4.1, Fig. 4.4.2, Fig. 4.4.3은 노드 수 다변화에 따른 비드폭 얇은 신경망 분석 결과를 나타낸 것이다. 경향성을 살펴보면, 50개의 노드 수로 갈수록 Training 값은 실측 값과 유사하나 Test 값은 크게 하락하는 것으로 나타났다. 뿐만 아니라, 50개로 갈수록 피팅 결과가 45도에서 크게 벗어나는 것으로 보아 유사도가 떨어지는 것으로 사료된다.

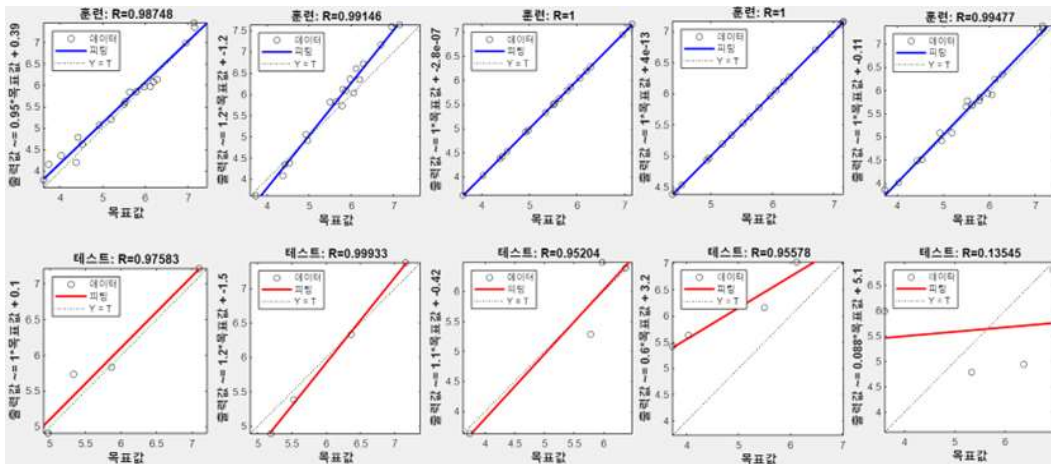


(a) Node 10    (b) Node 20    (c) Node 30    (d) Node 40    (e) Node 50  
Figure. 4.4.1. Comparison of the training and test graph of bead width SNN result by nodes



(a) Node 10 (b) Node 20 (c) Node 30 (d) Node 40 (e) Node 50

Figure. 4.4.2. Comparison of the training and test graph of penetration depth SNN result by nodes

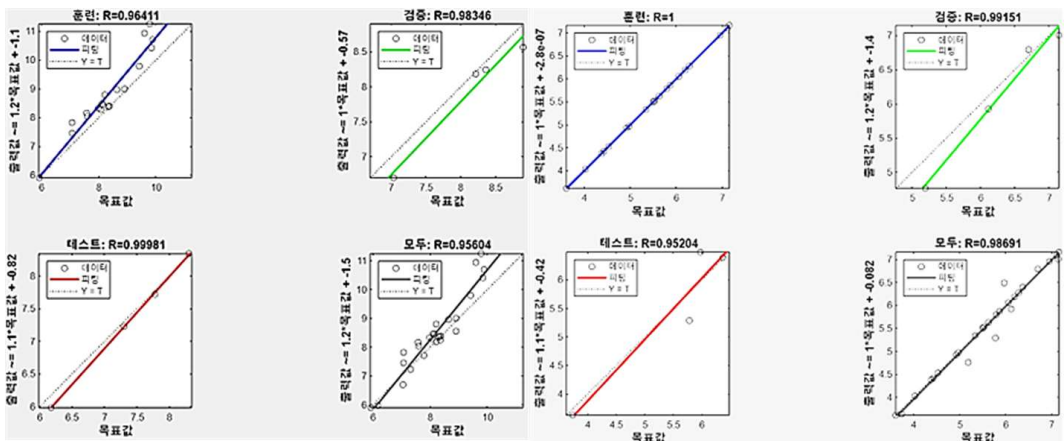


(a) Node 10 (b) Node 20 (c) Node 30 (d) Node 40 (e) Node 50

Figure. 4.4.3. Comparison of the training and test graph of leg length SNN result by nodes


따라서, 회귀 모델 분석 결과의 타당성 검증을 위한 얇은 신경망 분석에는 노드 수의 개수를 Test 값이 가장 높았던 30개로 지정했다. SNN 분석 결과, 높은 차수와 자유도로 Test와 Validation에서 높은 결정계수로 높은 정확도를 보였으나, 오차의 크기 역시 크다. 이는 머신러닝에서의 GPR 모델과 유사하게 과적합이 발생하는 양상을 보인다.[28]

비드 폭, 밑각장길이, 용입깊이에 대한 얇은 신경망 분석 결과, 결정계수가 각각 0.90(R=0.95), 0.98(R=0.99), 0.90(R=0.95)로 확인되었다. 세 항목 모두에서 0.90이 넘는 높은 결정계수를 보였으므로 유사도의 정확도 역시 높다고 판단된다.



(a) Bead Width

(b) Leg Length



(c) Penetration Depth

Figure. 4.4.4. Shallow neural network result

Table. 4.4.1은 회귀 학습 모델 분석 결과와 얇은 신경망 분석 결과를 비교한 것을 표로 나타내었다. 비교 결과, 회귀 모델의 결정계수에 비하여 약간 낮기는 하나 얇은 신경망 분석 결과 모두에서 0.90 이상의 값을 보였으므로 머신러닝 결과의 신뢰도가 높다고 판단할 수 있다. 회귀 학습 모델 분석 결과에 비해 낮은 결정계수 값을 보이는 것은 적은 양의 데이터를 Training, Validation, Test로 나누어 분석을 하였기 때문인 것으로 추론된다.

Table. 4.4.1. Comparison of the results; regression model and SNN analysis

모델	회귀모델( $R^2$ )	SNN( $R^2$ )
용입깊이(GPR)	0.96	0.90
비드폭(GPR)	1.00	0.98
밀각장길이(GPR)	1.00	0.90

## 제 5 장. 결 론

본 연구에서는 고강도 아연도금강판 CMT 용접공정 접합부의 품질 계수 예측을 위한 머신러닝 기반 공정변수 최적화에 관한 연구를 수행하였다. 연구 결과, 기공 저감 조건에 적절한 조건을 도출하였고, 머신러닝을 활용한 품질 지표에 대한 예측의 유사도가 높게 나타나는 것을 확인하였다.

1) 용접 실험 수행 결과, 용접 속도 66cm/min, 전류 239A, 전압 17.9V, 와이어 송급 속도 8.8m/min의 조건에서 가장 건전한 용접부를 보이며 최적의 조건으로 나타났다.

2) 또한, 용접 실험 수행 결과, 입열량에 비하여 용접 속도가 빠른 경우의 조건인 76cm/min에서 열린 기공의 형태인 피트(Pit)가, 입열량에 비하여 용접 속도가 느린 경우의 조건인 56cm/min에서는 용융지 내에서 웜홀(Worm hole)의 형태로 나타나는 블로우홀(Blowhole)이 나타나는 경향성을 확인하였다.

3) 용접 지표에 따른 실측 값 비교 결과, MS 자동차 용접 기술 표준에 해당하는 네 가지 항목(용입깊이, 밀각장길이, 덧살높이, 토우각)은 MS 규격이 제시하는 품질 기준에 모두 만족하는 것을 확인하였다.

4) 용접 실험 데이터를 기반으로 한 회귀 학습 결과, 머신러닝 모델인 지수 GPR 모델에서 용입깊이와 비드폭, 밀각장길이에 대한 결과값의 유사도가 결정계수 0.90 이상의 값인 0.96, 1.00, 1.00으로 나타났으므로 정확한 예측이 가능함을 확인하였다.

5) 회귀 학습 분석 결과에 대한 타당성 검증을 위해 수행된 얇은 신경망 분석에서의 은닉층 노드 개수는 노드 수 30에서의 결과 값에서 과적합 없이 Training과 Test 결과가 거의 완벽한 피팅을 보였으며, 높은 결정계수 값을 확인하였다.

6) 회귀 학습 결과에 대한 유사도 검증을 위하여 진행된 얇은 신경망 분석 결과,



회귀 학습 결과 값에 비하여 조금 낮은 결정계수가 나타나긴 했으나 결정계수 값이 각각 0.90, 0.98, 0.90으로, 세 항목 모두에서 0.90 이상으로 나타났기 때문에 정확한 예측이 가능하였으며, 세 항목 모두 과적합이 발생하지 않은 것을 확인하였다.

## 참고문헌

- [1] J. Yu, D. Kim, Effect of Welding Current and Torch Position Parameters on Minimizing the Weld Porosity of Zinc-Coated Steel, The International Journal of Advanced Manufacturing Technology, 95(1), 2017
- [2] Md. R. U. Ahsan, Y. R. Kim, C. H. Kim, J. W. Kim, R. Ashiri, Y. D. Park, Porosity formation mechanisms in cold metal transfer (CMT) gas metal arc welding (GMAW) of zinc coated steels, Science and Technology of Welding and Joining, 21:3, 2016, pp209-215
- [3] Kanemaru. S, Sasaki T. Sato. T, Mishima. H, Tashiro. S, Tanaka. M, Study for TIG-MIG Hybrid Welding Process, Welding in the World, Vol.58, 2014
- [4] 안영남, 김철희, GTA-GMA 하이브리드공정에 따른 자동차용 아연도금강판의 용접부 기공감소 (1) - 선행 GTA의 영향, Journal of Welding and Joining, Vol. 34, 2016, pp48-54
- [5] 조상명, 김기정, 이병우, 아연도금강판에 대한 중첩펄스 MIG 용접에서의 파형제어와 기공 발생 특성, Journal of KWJS, Vol.23 No.1, 2005
- [6] Md. R. U. Ahsan, Kim. Y. R, Ashiri. R, Cho. Y, Jeong. C. Y, Park. Y. D, Cold Metal Transfer (CMT) GMAW of Zinc-coated Steel, Welding Journal, Vol.95 No.4, 2016
- [7] H. Matsui, H. Suzuki and M. Yamada, Reduction of blowholes in high-speed arc welding of hot-dip galvanised steel sheets, Welding International, 12(6), 1998, pp432-439
- [8] H. Matsui and M. Yamada, Fundamental study of an arc welding procedure for hot-dip zinc-coated steel sheet, Welding International, 12(7), 1998, pp529-538
- [9] H. Matsui and S. Shionoya, Reduction of blowholes by vibration of the molten pool in arc welding of galvanised carbon steel sheet, Welding

- International, 12(12), 1998, 959-965
- [10] M. Uchinara, T. Taka, H. Miyazaki, Effect of Welding Conditions and Shielding Gas on Weldability of Zinc-Plated Steel, Journal Welding Society, 2, 1995, pp105-109
- [11] S. Kodama, Y. Ishida, S. Furusako, M. Saito, Y. Miyazaki and T. Nose, Arc Welding Technology for Automotive Steel Sheets, Nippon Steel Technical Report, 103, 2013, pp83-90
- [12] S. Izutani, K. Yamazaki, R. Suzuki, New Welding Process, "J-Solution™ Zn", Suitable for Galvanized Steel in the Automotive Industry, Kobelco, KOBELCO TECHNOLOGY REVIEW NO. 32, 2013
- [13] S. Yang, J. Wang, B. E. Carlson and J. Zhang, Vacuum-assisted laser welding of zinc-coated steel in a gap-free lap joint configuration, Weld. J, 92, (7), 2013, pp197-204
- [14] 최보성, 이덕영, 김목유, 임창용, 해석을 통한 CMT 용접 열원 구현 및 변형 예측, 한국정밀공학회 학술대회 논문집, 2012, pp369-370
- [15] Fronius International GmbH, Welding wire storage device, Journal of PCT Appl, 2005, No. AT2005000019
- [16] 나용근, 자동차 브라켓 프레스 이형복합공법 및 CMT 용접 적용에 따른 품질 평가, 조선대학교 대학원, 2019
- [17] 김재성, 이영기, 안주선, 이보영. Al 5052 합금의 저입열 Pulse MIG 최적 현장 용접조건 산정에 관한 실험적 연구. 대한용접·접합학회지 제 29권, 제 1호, 2010, pp80-84
- [18] Japan Welding Society, Advanced Welding & Joining Technology (New edition), Japanese book, 2008, pp49
- [19] C.G. Pickin, S.W. Williams, M. Lunt, Characterisation of the cold metal transfer (CMT) process and its application for low dilution cladding, Journal of Materials Processing Technology, Vol 221, 2010, pp496-502
- [20] Md. R. U. Ahsan, T. H. Kim, D. B. Kim, C. W. Ji, Y. D. Park, A Study on the

- Effect of Wire Composition on Welding with Gap and Offset in Cold Metal Transfer (CMT) GMAW. Journal of The Korean Welding & Joining Society, Vol. 36, No 5, 2018, pp12-18
- [21] 송상은, 정윤교, 이창제, 이은진, 조영태, CMT용융 방식을 이용한 적층 공정에서 비드 형상에 관한 연구, 한국기계가공학회 춘추계학술대회 논문집, 2017, pp1-1
- [22] 송현수, 최보성, 윤준도, 박승태. 도금 강판 CMT 용접부위의 재료특성평가. 한국정밀공학학회지 제 35권 제 10호, 2015, pp891-896
- [23] 김영삼, 유희수, 김희진, 오성철. 단락이행에서 스파터 저감을 위한 전류 파형 제어 및 기계적 제어 기술 리뷰. 대한용접·접합학회지 제 25권 제5호, pp4-14.
- [24] Welding and Joining Handbook, 1: Ferrous and Non-ferrous Alloys, Korean Welding and Joining Society, 2008, pp287-288
- [25] 강민정, 안영남, 김철희, Porosity Reduction during Gas Tungsten Arc-Gas Metal Arc Hybrid Welding of Zinc Coated Steel Sheets (I) - Effect of Preceding Gas Tungsten Arc, Journal of Welding and Joining. The Korean Welding and Joining Society, Vol. 34, 2016, pp40-7
- [26] 이기동, 강상훈, 강민정, 이성, 현승균, 김철희, 머신러닝을 이용한 레이저 용접부의 모델링 Part I: Al/Cu 이종재료 겹치기 레이저용접부의 용입깊이, J. Weld. Join. 39(1), 2021, pp27-35
- [27] 유현정, 강민정, 이성, 현승균, 김철희, 머신러닝을 이용한 레이저 용접부의 모델링 Part II: 고강도강 겹치기 레이저용접부의 형상 및 기계적 거동, Journal of Welding and Joining ; 39(1), 2021, pp36-44
- [28] 고범수, 유현정, 방희선, 김철희, 머신 러닝을 이용한 레이저 용접의 용입깊이 모델링 및 공정변수 맵, 대한용접접합학회지 39, no.4, 2021, pp392-401