

알루미늄 합금의 레이저 가공에서 인장 강도 예측을 위한 회귀 모델 및 신경망 모델의 개발

박영환*, 이세현#

Development of Statistical Model and Neural Network Model for Tensile Strength Estimation in Laser Material Processing of Aluminum Alloy

Young Whan Park* and Sehun Rhee#

ABSTRACT

Aluminum alloy which is one of the light materials has been tried to apply to light weight vehicle body. In order to do that, welding technology is very important. In case of the aluminum laser welding, the strength of welded part is reduced due to porosity, underfill, and magnesium loss. To overcome these problems, laser welding of aluminum with filler wire was suggested. In this study, experiment about laser welding of AA5182 aluminum alloy with AA5356 filler wire was performed according to process parameters such as laser power, welding speed and wire feed rate. The tensile strength was measured to find the weldability of laser welding with filler wire. The models to estimate tensile strength were suggested using three regression models and one neural network model. For regression models, one was the multiple linear regression model, another was the second order polynomial regression model, and the other was the multiple nonlinear regression model. Neural network model with 2 hidden layers which had 5 and 3 nodes respectively was investigated to find the most suitable model for the system. Estimation performance was evaluated for each model using the average error rate. Among the three regression models, the second order polynomial regression model had the best estimation performance. For all models, neural network model has the best estimation performance.

Key Words : Laser Welding (레이저 용접), Filler Wire (용가와이어), Tensile Strength (인장 강도), Regression Model (회귀 모델), Neural Network Model (신경망 모델), Average Error Rate (평균 오차율)

1. 서론

알루미늄은 경량 재료로서 제품의 경량화에 많이 사용되고 있다. 특히 자동차 산업에 있어서는 차량 경량화에 있어서 매우 중요한 재료로 각광을

받고 있다. 알루미늄이 차체에 적용되는 경우, 용접과 같은 결합의 방법이 요구된다. 그러나 알루미늄 합금의 용접에 있어서 알루미늄의 물리적 특성, 즉 높은 열 전도도(thermal conductivity)와 낮은 용융점(melting point) 그리고 용융금속의 낮은

접수일: 2006년 7월 26일, 게재승인일: 2007년 2월 21일

* 한양대학교 BK21 혁신 설계 기계인력 양성사업단

교신저자: 한양대학교 기계공학부

E-mail: srhee@hanyang.ac.kr Tel. (02) 2220-0438

표면장력(surface tension)에 의해 용접이 매우 어렵다. 그러므로 고밀도 에너지 열원이 필요하다. 이에 따라 박판의 알루미늄 합금의 용접에 있어서 레이저(laser)의 사용이 크게 늘고 있다.¹

알루미늄의 5000 계열 합금은 마그네슘이 주요 합금이며, 구조용 용도로 많이 사용되고 성형성과 내식성이 좋기 때문에 자동차 차체의 적용에 매우 유리하다. 그러나 5182 합금의 레이저 용접에 있어서는 용접 후 강도 저하 현상이 발생된다. Debroy²는 기공(porosity), 용착 부족(underfill) 그리고 마그네슘 손실(magnesium loss)이 이러한 강도 저하 현상의 원인임을 규명하였다. 이러한 현상을 극복하기 위하여 용가와이어(filler wire)를 이용한 레이저 용접이 제안되었다.^{3,4}

일반적인 레이저 가공의 모델링은 용접부의 형상(geometry)을 해석적으로 예측하여 모델을 얻는 연구가 많이 수행되었다.^{5,6} 이러한 용접부의 형상은 용접부의 강도를 정하는데 매우 중요한 역할을 하지만, 용접부 강도는 해석적 모델을 이용하여 구하는 것은 쉽지 않다. 그러므로 본 논문에서는 용접 공정변수를 이용한 예측모델을 실험적 모델로 제안하고자 한다. 용접된 시편의 인장 강도를 통계적 회귀 모델과 인공지능 알고리즘인 신경망 모델을 이용하여 예측하였다.

Park 과 Rhee⁷은 CO₂ 레이저 용접에 있어서 비드의 폭과 용입깊이를 다중 회귀 분석과 신경회로망 알고리즘을 이용하여 모델링하였다. 이러한 회귀 모델은 용접 뿐만 아니라 마킹과 같은 다양한 레이저 가공에도 예측 모델로 적용되었으며, 두 연구에서 얻어진 회귀 모델의 예측 성능은 우수하였다.⁸

인공 신경망 이론을 사용한 레이저 용접 공정의 모델링에 있어서 Jeng 등⁹은 레이저 맞대기 용접에서 신경회로망의 역전파(back propagation) 알고리즘과 학습 벡터 정량 네트워크(learning vector quantization network)를 이용하여 용접 파라미터를 예측하는 연구를 수행하였다. Chan 등¹⁰은 가스 메탈 아크(gas metal arc) 용접에서 인공 신경망 알고리즘을 이용하여 용접부 형상을 예측하는 모델을 얻었다.

본 논문에서는 용가와이어를 이용한 알루미늄 레이저 가공공정에서 레이저 출력, 용접속도, 그리고 와이어 송급속도를 입력변수로 하고 출력변수는 용접성을 나타낼 수 있는 인장 강도로 하여 이

두 변수간의 관계를 모델링 하였다. 모델링 방법으로는 통계적 회귀 모델과 인공지능 알고리즘의 하나인 신경회로망 모델을 이용하였다. 회귀 모델의 경우 변수의 차수(order)와 비선형 모델등 다양하게 구성할 수 있으므로 3 가지 모델을 제안하였다. 그리고 각 모델의 예측성능을 평균오차율을 이용하여 정량적으로 비교하였다.

2. 실험

2.1 실험장치

용가와이어(filler wire)를 이용한 알루미늄 레이저 용접 실험을 수행하였다. 실험에 사용된 시스템은 Fig. 1 과 같다. 실험 시스템 중에서 레이저는 최대 출력 4.4 kW 의 Nd:YAG 레이저를 사용하였다. 레이저 시스템의 세부 사항은 Table 1 과 같다. 레이저는 직각으로부터 18° 를 기울였다. 그 이유는 레이저가 알루미늄에 조사될 때, 알루미늄 표면에서 역 반사(back reflection)되는 레이저로부터 광학계와 같은 부품을 보호하기 위함이다. 용가와이어 송급장치는 Fig. 1 에서 보는 바와 같이 용접 방향의 앞쪽에서 와이어를 공급하는 방법을 이용하였다. 와이어의 송급각도는 레이저와 45° 의 각도를, 모재와는 27° 를 이루고 있다. 보호가스(shielding gas) 공급장치는 모재의 위쪽에서 용가와이어의 송급방향과 같은 축으로 공급되며, 판재 아래에는 가스 채널(channel)을 이용하여 공급하는 방법을 이용하였다.




Fig. 1 Experimental Setup

Table 1 Laser specifications used in experiment

Wavelength (nm)	1064
TEM mode	00
Focal length (mm)	250
Beam spot size (mm)	0.4
Beam propagation parameter (mm x mrad)	25

실험에 사용된 알루미늄 합금 판재는 AA5182 로 두께는 1.4 mm 였고, 용가와이어(filler wire)는 직경 1.2 mm 의 AA5356 용접봉이었다. 알루미늄 판재의 화학적 조성은 Table 2 과 같으며, AA5356 용가와이어(filler wire)의 조성은 Table 3 과 같다. 두 재료 모두 5000 계열 합금으로 주요 합금원소는 마그네슘 (Mg)이다.

Table 2 Chemical compositions of AA5182 (wt%)

Si	Fe	Cu	Mn	Mg
0.06	0.19	0.02	0.24	4.46
Cr	Zn	Ti	other	Al
0.03	0.03	0.01	0.02	Val.

Table 3 Chemical compositions of AA5356 (wt%)

Mg	Mn	Cr	Ti	Al
5.00	0.35	0.10	0.15	Val.

2.2 실험조건

본 연구에서는 많은 용접 변수 중 용접속도 (welding speed : WS) 와 레이저 출력(laser power : LP) 그리고 와이어 송급속도(wire feed rate : WFR) 를 제어인자로 사용하여 실험 하였다. 각 제어 인자의 영향력을 나타낼 수 있도록 삼원 배치법(3-way factorial design)을 이용하였다. 실험영역은 기초적인 실험을 통하여 그 범위를 설정하였고, 제어인자의 수준(level)은 3 단계로 나누었다. 각 제어 인자의 실험 영역과 수준의 변화는 Table 4 와 같다. 그러므로 총 용접 조건은 27 개였고, 반복 회수는 3 회로 전체 실험회수는 81 회였다.

고정 인자로서 초점 위치는 모재의 표면에 집광되도록 설정하였다. 보호 가스는 아르곤 (Ar) 을 이용하였으며 보호 가스의 유량은 상부에서 20 l/min, 하부에서 10 l/min 이었다. 용접길이는 280

mm 이었다. 용접 방법은 I 형 맞대기 용접으로, 용접 그루브면은 밀링 가공하여 일정하게 유지하였다.

용접성을 나타낼 수 있는 인자로 본 논문에서는 인장 강도를 선택하였다. 인장 강도는 각 실험에서 2 개씩 채취하여 실험을 수행하였다. 그러므로 각 조건당 6 개의 인장시편을 얻을 수 있었고, 이를 평균하여 실험 결과로 이용하였다.

Table 4 Welding conditions of experiment


Variables	Welding conditions		
Wire feed rate (m/min)	2	3	4
Laser power (kW)	3	3.5	4
Welding speed (m/min)	6	7.5	9

3. 실험 결과 및 고찰


용가와이어(filler wire)를 이용한 레이저 용접의 인장 시험 결과는 Fig. 2 와 같다. 알루미늄 5182 합금의 모재의 인장 강도는 277 N/mm² 이고, 알루미늄 5182 합금에게 요구되는 인장 강도는 255 N/mm² 이다. 모재의 인장 강도 보다 높은 경우는 모재부에서 파단이 발생하며, 그렇지 않은 경우, 용접부에서 파단이 발생한다.

Fig. 2 에서 보는 바와 같이 레이저 출력이 커짐에 따라 인장 강도가 커지고 있다. 그리고 용접속도와 와이어 송급속도가 커짐에 따라 인장 강도가 작아지고 있다. 다시 말하면 인장 강도에 대하여 레이저 출력은 양의 비례관계를 가지고 있으며, 용접속도와 와이어 송급속도는 음의 비례관계를 가지고 있다.


Fig. 2 에서 와이어 송급속도가 2 m/min 인 경우, 277 N/mm² 보다 높은 용접조건은 4 가지, 255 N/mm² 와 277 N/mm² 사이의 인장 강도를 갖는 조건은 2 가지이다. 와이어 송급속도가 3 m/min 인 경우는 각각 2 조건, 4 조건 이었으며, 4 m/min 인 경우는 2 조건, 2 조건 이었다. 이처럼 용가와이어 (filler wire)의 양이 늘어 날수록 적정 용접의 범위가 줄어들고 있다. 이것은 용가와이어(filler wire)가 공급되면 레이저 출력과 용접속도에 의해 입력되는 에너지가 모재와 더불어 용가와이어(filler wire)를 녹이는데 동시에 소모되기 때문이다. 그러므로



(a) Wire feed rate : 2m/min



(b) Wire feed rate : 3m/min



(c) Wire feed rate : 4m/min

Fig. 2 Results of tensile strength

모재의 용입 깊이가 작아지며, 완전 용입이 이루어 지지 않게 된다.

이러한 제어 인자들이 인장강도에 미치는 영향력을 판단하기 위하여 분산분석을 수행하였다. Table 5 는 인장강도에 대한 각 인자들의 분산분석표이다. Table 5 에서 DOF 는 자유도 (degree of freedom) 의 약자이고, SS 는 제곱합 (sum of square), MS 는 평균 제곱 (mean square) 의 약자이고, WFR 은 와이어 송급속도를, LP 는 레이저 출력을, 그리고 WS 는 용접속도를 의미한다. 그리고 분산분석에서 '×' 는 인자 수준의 조합에서 일어나는 효과를 의미하는 교호 작용을 나타낸다. F_0 는 평균 제곱의 비로서 에러의 평균 제곱에 대한 인자의 평균 제곱의 비로서 나타내고, 이 값이 클수록 인장강도에 대하여 인자의 영향력이 크다는 것을 의미한다. 분산 분석표에서 F_0 의 값을 보면, 레이저의 출력이 인장강도에 가장 큰 영향을 미치고 있음을 알 수 있다. 또한 레이저 출력과 와이어 송급속도, 그리고 레이저 출력과 용접속도는 서로 입열의 측면에 있어서 반비례 관계를 가지고 있으므로 분산 분석에서 보는 바와 같이 각 인자간에 교호작용이 있다는 것을 알 수 있다. 그러나 그 교호작용의 크기는 와이어 송급속도, 레이저 출력, 용접속도의 단일 인자에 비하여 상대적으로 작다는 것을 알 수 있다. 그러므로 본 논문에서는 와이어 송급속도, 레이저 출력, 용접속도를 회귀 모델과 신경망 모델의 입력인자로 사용하여 인장 강도를 예측 할 수 있는 모델을 제안하였다.

Table 5 ANOVA (Analysis of Variance) table for tensile strength

Factor	SS	DOF	MS	F_0
WFR	38868.6	2	19434.3	60.5
LP	161253.4	2	80626.7	251.1
WS	83573.2	2	41786.6	130.2
WFR × LP	18530.2	4	4632.6	14.4
WFR × WS	905.9	4	226.5	0.71
LP × WS	28051.7	4	7012.9	21.8
WFR × LP × WS	5742.4	8	717.8	2.2
Error	40775.39	127	321.1	
Total	9208421.7	154		

4. 인장 강도 예측 모델의 개발

4.1 회귀 모델

본 논문에서는 입력인자로 공정변수인 용가와 이어의 송급속도, 레이저 출력, 그리고 용접속도를 이용하여 용접부의 인장 강도를 예측하기 위하여 회귀 모델(regression model)을 공정 모델링의 한 방법으로 제안하고자 한다.

회귀 모델은 변수의 차수(order)와 비선형(nonlinear) 방법에 따라 다양하게 구성될 수 있다.⁸ 그러므로 본 논문에서는 인장 강도를 예측할 수 있는 3 가지 모델을 정의하였다. 첫번째 모델은 Model I 으로 다중 선형 회귀 모델(multiple linear regression model) 이다. 구성된 모델의 식은 식 (1) 과 같다. Model II 는 2 차 다항 회귀 모델(second order polynomial regression model) 로 식 (2)와 같다. Model III 는 다중 비선형 회귀 모델(multiple nonlinear regression model) 이며 그 식은 식 (3)과 같다.

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 \quad (1)$$

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_1 x_2 + \beta_5 x_1 x_3 + \beta_6 x_2 x_3 + \beta_7 x_1^2 + \beta_8 x_2^2 + \beta_9 x_3^2 \quad (2)$$

$$\hat{y} = \beta_0 + \beta_1 \ln x_1 + \beta_2 \ln x_2 + \beta_3 \ln x_3 \quad (3)$$

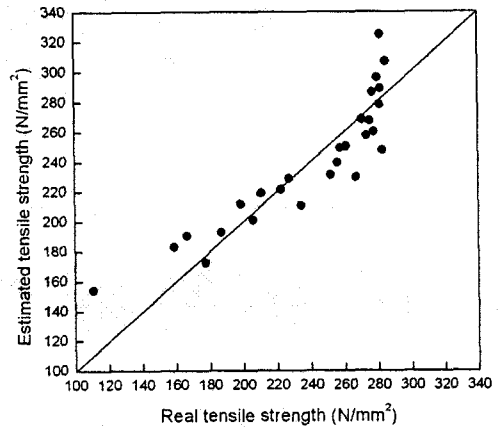
식 (1), (2), (3)에서 x_1, x_2, x_3 는 입력 인자로서 각각 와이어 송급속도, 레이저 출력, 용접속도를 나타낸다. \hat{y} 는 출력 인자로 각각의 모델에 의해 예측된 인장 강도의 값이다. 그리고 β_0 는 y 축의 절편이고, $\beta_1 \sim \beta_9$ 는 각각 입력 인자의 계수값이다. 각 계수 값은 최소제곱법(method of least square)으로 구한다.

Model I 에 해당하는 다중 선형 회귀 모델(multiple linear regression model) 의 계수 값은 Table 6 와 같다. 계수의 값을 이용하면 출력 인자 즉 회귀 모델에 의해 예측 되는 인자에 대하여 입력인자의 영향력을 판단할 수 있다.^{8,11} 식 (1) 과 Table 6 에서 보는 바와 같이 예측된 인장 강도에 대하여 레이저 출력은 양의 효과를 와이어 송급속도와 용접속도는 음의 효과를 준다. 이것은 실험에서 얻은 결과와 일치하고 있다. 그리고 실험영역 내에서 레이저 출력이 다른 입력인자에 비해 큰 영향력을


주고 있음을 알 수 있다.

Table 6 Coefficients for Model I (multiple linear regression model)

β_0	β_1	β_2	β_3
283.6	-49.3	269.1	-141.0



(a) Regression data



(b) Verification data

Fig. 3 Estimation results of model I (multiple linear regression model)

1 차 선형 회귀 모델을 이용하여 실제 인장 강도 값과 예측된 인장 강도를 비교하여 보았다. 회귀 모델을 만드는데 사용된 데이터를 회귀 데이터

(regression data)로 정의하였다. 회귀 데이터는 Fig. 2에 나타난 인장 강도의 실험값이다. 그리고 회귀 모델의 예측성능을 평가하기 위하여, 각 용접 조건에서 수행된 6 번의 인장시험 결과 중 각 조건당 임의로 1 개씩 데이터를 추출하여 검증 데이터(verification data)라고 정의 하였다.


Model I 에 대한 예측 성능을 Fig. 3 에서 보여 주고 있다. Fig. 3 에서 가로축은 실제 인장시험을 통해 얻어진 인장 강도 값이고, 세로축은 각 모델에 의하여 예측된 인장 강도의 값이다. 그리고 예측 모델의 성능을 Fig. 3 에서 (a)는 회귀 데이터와 비교하였고, (b)는 검증 데이터와 비교하였다. 그림에 있는 직선 라인에 가까울수록 예측 성능이 우수한 것이다. 그림에서 보는 바와 같이 전체적으로 오차가 큼을 알 수 있다. 강도가 260 이상이 되는 부분에 대해서는 오차가 매우 크다. 특히 검증 데이터도 전체적으로 오차의 값이 매우 큼을 알 수 있다.

Model II 에 해당하는 2 차 다항 회귀 모델(second order polynomial regression model)의 계수 값은 Table 7 과 같다. 식 (2)와 Table 7 에서 보는 바와 같이 예측된 인장 강도에 대하여 레이저 출력은 양의 효과를 와이어 송급속도와 용접속도는 음의 효과를 준다. 그러나 2 차 다항 회귀 모델은 2 차의 비선형 항이 있으므로 계수 값이 매우 복잡함을 알 수 있다.

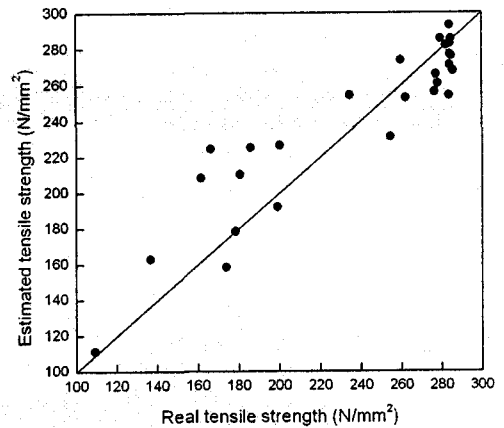
Table 7 Coefficients for Model II (second order polynomial regression model)

β_0	β_1	β_2	β_3	β_4
493.8	-25.8	60.9	-91.1	27.8
β_5	β_6	β_7	β_8	β_9
-1.1	25.6	-13.6	-37.0	-1.0

Model II 에 대한 예측 성능을 Fig. 4 에서 보여 주고 있다. Fig. 5 에서 보는 바와 같이 회귀 데이터에 대해서는 전체적으로 잘 예측하고 있음을 알 수 있다. 검증 데이터에 있어서는 가운데 부분에서 오차가 크지만 강도가 큰 부분에 대해서는 예측을 잘 하고 있다.



(a) Regression data



(b) Verification data


Fig. 4 Estimation results of model II (second order polynomial regression model)

Model III 에 해당하는 다중 비선형 회귀 모델(multiple nonlinear regression model)의 계수 값은 Table 8 과 같다. 식 (3) 과 Table 8 에서 보는 바와 같이 예측된 인장 강도에 대하여 레이저 출력의 자연 대수(logarithm)값은 양의 효과를 와이어 송급속도와 용접속도의 자연 대수(logarithm)값은 음의 효과를 준다. 실험영역 내에서 레이저 출력의 자연 대수값이 다른 입력인자에 비해 큰 영향력을 주고 있음을 알 수 있다.

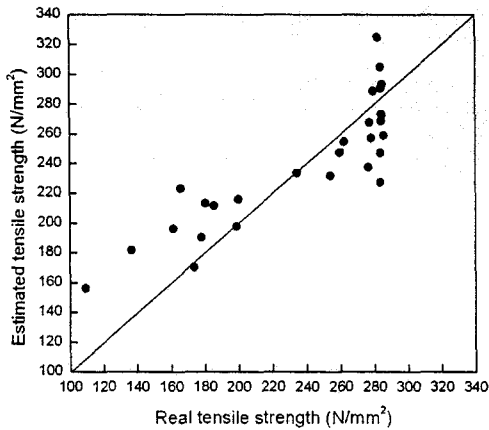
Table 8 Coefficients for Model III (multiple nonlinear regression model)

β_0	β_1	β_2	β_3
238.6	-4	269.1	-141.0

Model III 에 대한 예측 성능을 Fig. 5 에서 보여 주고 있다. Fig. 5 도 Fig. 3 과 같이 예측 영역 전체 적에 대하여 오차가 크을 알 수 있다. 회귀 데이터 나 검증 데이터 모두 모재에서 파단이 나는 277 이상의 강도에서는 오차가 매우 크을 알 수 있다.



(a) Regression data



(b) Verification data

Fig. 5 Estimation results of model III (multiple nonlinear regression model)

4.2 신경망 모델

용가와이어를 이용한 알루미늄 레이저 용접에서 용접부의 인장 강도예측 모델로 인공지능형 알고리즘의 하나인 신경회로망 이론을 이용하였다. 일반적으로 신경회로망 모델은 학습 능력을 가지고 있으므로 비선형 성질에 대하여 예측 성능이 우수하다.⁷ 구성된 모델은 Fig. 6 과 같이 1 개의 입력층(input layer)과 2 개의 은닉층(hidden layer), 그리고 출력층(output layer)으로 구성되어 있으며 각각의 층에는 3 개, 5 개, 3 개, 1 개의 노드를 가지고 있다.





Fig. 6 Neural network model for tensile strength estimation

구성된 신경회로망 모델의 입력노드는 용가와이어의 송급속도, 레이저 출력, 그리고 용접속도로 하였다. 출력노드는 용접부의 인장 강도로 하였다. 학습에 사용된 데이터는 Fig. 2 의 인장 강도의 평균값을 이용하였다. 그러므로 총 학습에 사용된 데이터의 수는 27 개였다. 각 노드의 연결 강도를 학습시키기 위한 알고리즘으로 오류 역전파(error backpropagation) 알고리즘을 사용하였다. 신경회로망의 학습율(learning rate)은 0.1 로, 모멘텀 계수(momentum parameter)는 0.9 로 설정하였다


각 레이어를 연결하는 전달함수(transfer function)는 입력층과 1 차 은닉층 사이에는 로그 시그모이드(log-sigmoid) 전달함수를 이용하였고 1 차와 2 차 은닉층 간과 2 차 은닉층과 출력층 간의 전달함수는 1 차 선형(linear) 전달함수를 사용하였다. 수렴속도의 향상을 위해 신경망 모델의 최적화 방법은 레벤버그 마쿼드 알고리즘(Levenberg - Marquardt algorithm)을 이용하였다.

실제 인장 강도 값과 신경회로망 모델에 의해 예측된 인장 강도를 비교하여 보았다. 신경회로망의 학습에 사용된 데이터를 학습 데이터(training data)로 정의하였다. 회귀 모델에서 이용된 검증 데이터(verification data)를 이용하여 신경망 모델의 예측 성능을 평가하였다.

Fig. 7 는 신경회로망 모델을 이용하여 얻은 결과를 보여주고 있다. Fig. 7 의 (a)는 학습 데이터와 신경망 모델에 의하여 예측된 데이터를 비교한 그림이고, (b)는 검증 데이터와 예측값을 비교한 그림이다. 그림에서 보는 바와 같이 전체적으로 예측 성능이 우수한 것을 알 수 있다.



(a) Training data



(b) Verification data

Fig. 7 Estimation results of neural network model

4.3 회귀 모델과 신경망 모델의 성능평가

일반적으로 예측모델의 정도(precision)는 분산 분석에 의한 F 점검, 결정계수, 잔차평균제곱과 같은 것으로 사용되고 있다.¹¹ 본 연구에서 작성한 각 회귀 모델과 신경망 모델의 정량적인 평가를 위해 구성된 모델의 예측값의 평균 오차율(average error rate)을 이용하여 각 모델의 성능을 비교하였다.⁸ 이것은 식 (4)와 같이 구하여지며, 0 에 가까울수록 모델의 예측성능이 좋다.

$$AER (\%) = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \times 100 \quad (4)$$

여기서 *AER* 은 평균 오차율이고, *n* 은 실험의 수 혹은 검증 데이터의 수이다. *i* 는 데이터의 번호이다. *y* 는 측정 데이터 값이고 \hat{y} 는 각 모델에 의해 예측된 값이다.

Table 9 는 논문에서 제안된 3 개의 회귀 모델과 1 개의 신경망 모델에 대한 평균 오차율을 표시하였다. 각 모델에 대하여 회귀 데이터, 학습 데이터, 그리고 검증 데이터에 대하여 평균 오차율을 보여주고 있다. Table 9 에서 보는 바와 같이 3 개의 회귀 모델 중에서 Model II 에 해당하는 2 차 다항 회귀모델의 예측 성능이 가장 우수함을 알 수 있다. 회귀 데이터에 대한 평균 오차율은 3.3% 그리고 검증 데이터에 대한 평균 오차율은 8.4% 였다. 그리고 전체 4 개의 예측 모델 중에서는 신경망 모델이 가장 예측 성능이 우수 하였다. 학습 데이터와 검증 데이터에 대한 평균 오차율은 각각 1.2% 와 6.3% 였다. 이것은 신경회로망 모델이 학습 능력을 가지고 있으므로 비선형 성질에 대하여 예측 성능이 우수하므로 7 회귀모델보다 더 우수한 예측 성능을 갖는 것으로 사료된다.

Table 9 Average error rate for each estimation model

	Regression Model			Neural Network Model
	Model I	Model II	Model III	
Regression / Training data	7.4%	3.3%	7.7%	1.2%
Verification data	11.4%	8.4%	11.3%	6.3%

5. 결론

본 논문에서는 레이저 가공공정에 대하여 모델링을 하였다. 모델링의 입력 인자는 와이어 송급속도, 레이저 출력, 그리고 용접속도로 하였고, 출력 인자는 인장 강도로 설정하였다. 예측모델로서는 회귀 모델과 신경회로망 모델을 이용하였다. 회귀 모델은 차수와 비선형성에 따라 다중 선형 회귀 모델, 2 차 다항 회귀 모델, 그리고 다중 비선형 회귀 모델의 3 가지 모델을 제안하였으며, 신경회로망 모델은 1 개의 입력 및 출력층 그리고 2 개의 은닉층을 갖는 모델을 제안하였다.

제안된 4 가지 모델의 예측 성능을 평균 오차율을 이용하여 정량적으로 비교하였다. 회귀 모델은 3 가지의 회귀 모델 중에서 2 차 다항 회귀 모델이 가장 예측성능이 좋았다. 그리고 본 논문에서 제안한 4 개의 예측모델 중에서 신경망 모델이 가장 우수한 예측성능을 가지고 있었다.

후기

이 논문은 2007 년도 2 단계 두뇌한국 21 사업에 의하여 수행되었습니다.

참고문헌

- Mather, G., "The Welding of Aluminium and its Alloy," Woodhead Publishing Ltd, pp. 1-9, 2002.
- Pastor, M., Zhao, H., Martukanitz, R. P. and Debroy, T., "Porosity, Underfill and Magnesium Loss during Continuous Wave Nd:YAG Laser welding of Thin Plates of Aluminum Alloys 5182 and 5754," Welding Journal, Vol. 78, No. 6, pp. 207s-216s, 1999.
- Naeem, M. and Jessett, R., "Aluminum Tailored Blank Welding With and Without Wire Feed, Using High Power Continuous Wave Nd:YAG Laser," SAE Conference Proceedings P, No. 334, pp. 247-256, 1998.
- Yoon, J. W., "Laser Welding of Aluminum Alloys," Journal of Korean Welding Society, Vol. 18, No. 2, pp. 147-153, 2000.
- Kar, A. and Mazumder, J., "Mathematical Modeling of Keyhole Laser Welding," Journal of Applied Physics, Vol. 78, No. 1, pp. 6353-6360, 1995.
- Modest, M. F., "Three-dimensional. Transient Model for Laser Machining of Ablating/Decomposition Materials," International Journal of Heat and Mass Transfer, Vol. 39, No. 2, pp. 221-234, 1996.
- Park, H. and Rhee, S., "Estimation of Weld Bead Size in CO₂ Laser Welding by Using Multiple Regression and Neural Network," Journal of Laser Applications, Vol. 11, No. 3, pp. 143-150, 1999.
- Park, Y. W. and Rhee, S., "Development of Statistical Model for Line Width Estimation in Laser Micro Material Processing Using Optical Sensor," Journal of the Korean Society for Precision Engineering, Vol. 22, No. 7, pp. 27-37, 2005.
- Jeng, J. Y., Mau, T. F. and Leu, S. M., "Prediction of Laser Butt Joint Welding Parameters Using Back Propagation and Learning Vector Quantization Networks," Journal of Materials Processing Technology, Vol. 99, No. 1-3, pp. 207-218, 2000.
- Chan, B., Pacey, J. and Bibby, M., "Modeling Gas Metal Arc Weld Geometry Using Artificial Neural Network Technology," Canadian Metallurgical Quarterly, Vol. 38, No. 1, pp. 43-51, 1999.
- Montgomery, D. C., "Design and Analysis of Experiments," 5th Edition, John Wiley & Sons, Inc., pp. 392-426, 2001.