

레이저 용접공정의 자동화를 위한 신경망 모델과 목적함수를 이용한 최적화 기법 개발

박영환*

(논문접수일 2006. 8. 25, 심사완료일 2006. 9. 25)

Development of Optimization Methodology for Laser Welding Process
Automation Using Neural Network Model and Objective Function

Young Whan Park*

Abstract

In manufacturing, process automation and parameter optimization are required in order to improve productivity. Especially in welding process, productivity and weldability should be considered to determine the process parameter. In this paper, optimization methodology was proposed to determine the welding conditions using the objective function in terms of productivity and weldability. In order to conduct this, welding experiments were carried out. Tensile test was performed to evaluate the weldability. Neural network model to estimate tensile strength using the laser power, welding speed, and wire feed rate was developed. Objective function was defined using the normalized tensile strength which represented the weldablilty and welding speed and wire feed rate which represented the productivity. The optimal welding parameters which maximized the objective function were determined.

Key Words : Process automation(공정 자동화), Process modeling(공정모델링), Neural network model(신경망 모델), Objective function(목적함수), Parameter optimization(변수 최적화)

1. 서 론

자동차 산업을 비롯한 제조업에서 제품의 생산성과 원가 절감은 매우 중요하다. 이를 위하여 생산시스템의 자동화를 통

한 생산성의 극대화를 이루기 위하여 각 제조 업체는 많은 노력과 연구를 수행하고 있다. 자동차 산업에 있어서 알루미늄의 적용은 차체의 경량화에 있어서 매우 중요한 이슈다. 알루미늄의 차체에 적용하고, 이것을 대량 생산하기 위해서

* 한양대학교 BK21 혁신설계 기계인력 양성사업단 (honeydew@hanyang.ac.kr)
주소: 133-791 서울시 성동구 행당동 17

는 용접 공정 또한 자동화하여야 한다. 그러므로 다양한 방법으로 생산성을 극대화 할 수 있는 최적의 용접 조건을 도출하고자 노력하고 있다. 용접 공정에 있어서는 생산성과 더불어 용접성도 같이 고려하여 최적화를 수행하여야 한다.

알루미늄의 용접공정에 있어서 다양한 용접 공정변수가 존재한다. Leong⁽¹⁾은 AA5182 판재의 레이저 용접에 있어서 레이저 출력, 용접 속도, 보호 가스 등에 따른 용접 품질의 영향력을 판단하였다. 이러한 레이저 용접에 있어서는 용접 후에 강도 저하 현상이 발생한다. Debroy⁽²⁾는 용접중에 발생하는 기공과 용착 부족(underfill), 그리고 마그네슘의 손실에 의하여 발생한다고 보았고, 이를 보완하기 위하여 용가 와이어(filler wire)를 이용한 알루미늄 합금의 용접이 요구되고 있다^(3,4). 이와 같이 용가와이어에 의한 레이저 용접에 있어서는 위의 레이저 용접의 공정변수 이외에 용가와이어의 종류, 와이어 송급의 방향과 위치도 매우 중요한 인자이다⁽⁵⁾.

용접성과 생산성에 대하여 용접 공정변수는 서로 매우 복잡하게 연성되어 있으므로 최적의 용접 조건을 얻는다는 것은 매우 어렵다. 그러나 용접공정은 이 두 가지 조건을 만족시키는 최적화의 용접조건의 설정이 반드시 필요하다. 이를 위하여 용접성과 각 파라미터 간의 상관관계를 위한 해석이나 공정 모델링이 필요하다.

본 논문에서는 인공 신경망 이론을 이용하여 용접 공정을 모델링 하였다. 용접공정의 모델링에 있어서 Park⁽⁶⁾은 CO₂ 레이저 용접에 있어서 비드의 폭과 용입 깊이를 다중 회귀 분석과 신경회로망 알고리즘을 이용하여 모델링을 하였고, 두 모델 중에서 신경회로망 모델의 예측 성능이 더 우수함을 밝혔다. 또한 Jeng⁽⁷⁾은 레이저 맞대기 용접에서 신경 회로망의 역전파(back propagation) 알고리즘과 learning vector quantization network을 이용하여 용접 파라미터를 예측하는 연구를 수행하였다. Chan⁽⁸⁾은 가스 메탈 아크 용접(gas metal arc welding)에서 인공 신경망 알고리즘을 이용하여 용접부 형상을 예측하는 모델을 얻었다.

이러한 생산 공정의 모델링과 최적화는 용접공정에서 중요한 이슘이다. Tsai⁽⁹⁾은 TIG(tungsten inert gas) 용접공정을 신경회로망을 이용하여 모델링하였고, 이를 시뮬레이티드 어닐링(simulated annealing) 알고리즘을 이용하여 전역적 최적점을 찾는 연구를 수행하였다. Chung⁽¹⁰⁾과 Settle⁽¹¹⁾은 고속 확관기의 확산속도와 직물 제조 공정(spinning production process)에서 공정 변수를 신경망 알고리즘을 이용하여 모델링 하고 이를 유전 알고리즘을 이용하여 최적화하는 연구를 수행하였다.

본 논문에서는 레이저 알루미늄 용접공정에서 생산성과

용접성을 고려한 용접 공정변수의 최적화 기법을 제안하고자 한다. 이를 위하여 레이저 출력, 용접 속도, 용가 와이어 송급속도(wire feed rate)를 입력변수로 하여 실험을 하였고, 인장강도를 이용하여 용접성을 판단하였다. 그리고 용접 입력 변수를 신경 회로망 알고리즘을 이용하여 인장 강도를 예측할 수 있는 모델을 제시하였다. 용접성을 나타내는 인자로 인장강도 예측 모델을 그리고 생산성을 나타낼 수 있는 인자로 용접 속도와 와이어 송급속도를 정하였다. 인장강도, 용접속도, 와이어 송급속도를 표준화(normalizing)하고 표준화된 각 인자에 가중치를 주어 목적함수를 정의 하였다. 그리고 목적함수의 값을 최대화 하는 공정변수를 선택함으로써 용접 공정의 최적화를 수행하였다.

2. 실험 및 결과

2.1 실험 방법 및 실험 조건

본 실험에서 사용된 레이저는 Rofin 사의 4.4kW 급 Nd:YAG 레이저이다. 레이저는 연속파(continuous wave) 발진으로 출력되며, 레이저 빔의 단면 출력은 TEM00 모드이다. 레이저의 파장은 1064nm 이고, 초점거리는 250mm, 초점 위치에서 빔의 크기는 0.4mm이다. 레이저는 직각으로부터 18°를 기울였다. 레이저가 알루미늄에 조사될 때, 알루미늄 표면에서 역 반사(back reflection)되는 빛에 의해 레이저 발진 시스템이 영향을 받는 것을 방지하기 위하여 각도를 주어 실험을 수행하였다. 레이저와 와이어 공급 장치와는 45°의 각도를 가지고 있다. 보호가스는 용접부 상부와 하부의 2 방향에서 공급하였다. 상부에서 공급하는 장치는 와이어 공급

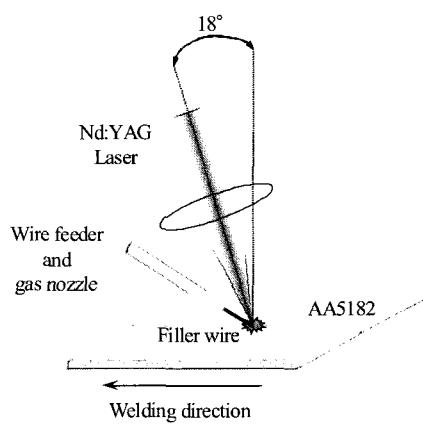


Fig. 1 Schematic illustration of experimental setup

장치와 같은 축에 있는 노즐을 이용하였고, 하부에서는 보호 가스 채널(channel)을 이용하여 보호ガス를 공급하였다. 실험 장비의 개략도는 Fig. 1과 같다.

실험에 사용된 판재는 AA5182로 두께는 1.4mm, 용접 길이는 280mm 였고, 용가 와이어(filler wire)는 직경 1.2mm 의 AA5356 용접봉이었다. AA5182 알루미늄 합금의 화학적 조성은 Table 1과 같으며, AA5356 용가 와이어(filler wire)의 조성은 Table 2와 같다.

맞대기 레이저 용접에 있어서 제어 인자로 레이저의 출력, 용접속도, 보호ガス의 유량 및 방향, 판재의 갭 등이 있으며 용가 와이어를 이용하는 경우는 용가 와이어의 종류와 송급 속도 또한 주요 변수이다. 본 연구에서는 많은 용접 변수 중 레이저 출력, 용접속도 그리고 와이어 송급속도를 제어인자로 사용하여 실험하였다. 실험의 조건은 Table 3과 같다. 각 변수의 수준은 3개의 수준으로 나누었고 실험 영역의 설정을 위하여 기초 실험을 수행하였다. 기초실험을 통해 용접 속도가 9m/min 보다 크면 레이저 출력이 4kW가 되어도 두 모재가 용접되지 않았다. 또한 와이어 송급속도가 5m/min 이상이 되는 경우, 두 모재의 용접이 형성되지 않았고 그리고 1m/min 이하의 경우 와이어 송급에 의한 영향력을 거의 찾을 수 없었다. 그러므로 용접실험의 조건의 범위를 Table 3과 같이 설정하였다. 실험의 진행은 실험 계획법에 의하여 진행하였고, 실험의 방법은 3³ 요인 배치법(3³ factorial design)을 이용하였다. 그러므로 총 용접조건은 27개이며, 각 실험은 3회

Table 1 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 2 Chemical compositions of AA5356 (wt%)

Si	Fe	Cu	Mn	Mg
0.06	0.19	0.02	0.24	4.46

Table 3 Welding conditions and levels

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

반복실험을 수행하였다. 총 용접 실험의 수는 81회였으며, 각 실험의 순서는 무작위로 수행하였다.

실험에 있어서 고정 인자로서 초점 위치는 시편의 표면에 일치시켰다. 보호 가스는 아르곤(Ar)을 이용하였으며 보호 가스의 유량은 상부에서 20 l/min, 하부에서 10 l/min 이었다. 두 모재간의 갭(gap)은 0mm로 하였다. 용접 방법은 I 형 맞대기 용접으로, 용접 그루브면은 밀링 가공하여 일정하게 유지하였다. 용접 직전에 아세톤을 이용하여 모재를 닦아 알루미늄의 산화막 제거와 청결을 유지하였다.

실험의 결과로는 용접부의 전전성과 용접성을 나타낼 수 있는 인자인 인장강도를 선택하였다. 인장시험에 사용된 기기로는 Zwick사의 Z100 만능시험기를 이용하였다. 인장강도는 각 실험에서 2개씩 채취하여 실험을 수행하였다. 그러므로 각 조건 당 6개의 인장시편을 얻을 수 있었고, 이를 평균하여 실험 결과로 하였다.

2.2 실험 결과 및 고찰

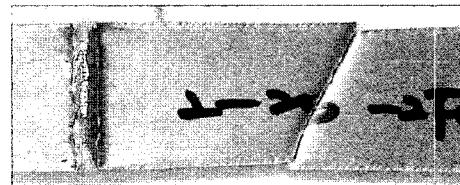
용가 와이어를 이용한 알루미늄 레이저 용접의 인장 시험의 결과와 용입깊이를 Table 4에 나타내었다. 알루미늄 5182 합금의 모재의 인장강도는 277N/mm²이고, ISO의 규정에서 정한 알루미늄 5182 합금의 최소 인장강도는 255N/mm²이다. Table 4에서 보는 바와 같이 와이어의 송급속도가 2m/min 인 경우 모재의 인장강도보다 높은 인장강도를 갖는 용접조건은 4가지 조건이었다. 와이어 송급 속도가 3과 4m/min 인 경우는 277 N/mm² 보다 높은 인장강도를 갖는 경우는 각각 2조건이었다. 그리고 인장강도의 범위가 255N/mm²와 277N/mm² 사이에 있는 경우는 와이어 송급속도가 2m/min 인 경우 2개, 3m/min 인 경우 4개, 4m/min 인 경우 1개이다. 와이어의 송급 속도가 빨라짐에 따라 적정의 용접 구간이 줄어들고 있다. 이것은 같은 입열인 경우 용가 와이어의 공급이 증가함으로 인하여 입열이 용가 와이어를 녹이는데 많이 분산되므로 모재를 녹이는데 필요한 열량이 줄어들기 때문으로 사료된다. 또한 모재의 강도는 용입 깊이와 비례적인 관계를 가지고 있다. Table 4에서 보는 바와 같이 레이저 출력이 커질수록 용입 깊이가 커지고 용접부의 강도가 커지고 있음을 알 수 있다. 그리고 용접속도와 용가와이어의 송급속도는 용입깊이를 줄어들게 하며, 이에 따라 용접부의 강도도 약화시키는 요인으로 작용하고 있음을 알 수 있다. 다시 말하면 레이저 출력은 용접부 강도에 대하여 비례적인 관계를 갖지만 용접속도와 용가와이어의 송급속도는 반비례적인 관계가 있다.

인장 시험 후 시편의 파단 형태는 Fig. 2와 같다. 모재의

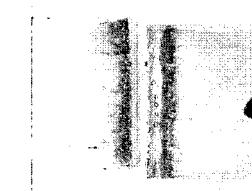
Table 4 Results of experiments

Wire feed rate (m/min)	Laser power (kW)	Welding speed (m/min)	Tensile strength (N/mm ²)	Penetration depth (mm)
2	4	6	282.13	1.48
2	4	7.5	280.04	1.53
2	4	9	275.48	1.39
2	3.5	6	277.16	1.51
2	3.5	7.5	273.55	1.35
2	3.5	9	227.46	1.33
2	3	6	283.15	1.49
2	3	7.5	211.05	1.08
2	3	9	166.68	0.91
3	4	6	284.93	1.54
3	4	7.5	281.62	1.53
3	4	9	257.93	1.40
3	3.5	6	270.84	1.50
3	3.5	7.5	256.10	1.43
3	3.5	9	242.60	1.00
3	3	6	267.28	1.20
3	3	7.5	205.99	1.11
3	3	9	177.63	0.86
4	4	6	282.14	1.53
4	4	7.5	278.11	1.41
4	4	9	252.12	1.28
4	3.5	6	261.37	1.30
4	3.5	7.5	204.04	1.25
4	3.5	9	187.09	0.93
4	3	6	192.02	0.85
4	3	7.5	159.09	0.75
4	3	9	111.06	0.63

인장강도인 277N/mm²보다 높은 경우는 Fig. 2의 (a)와 같이 모재부에서 파단이 발생하며, 그렇지 않은 경우, (b)와 같이 용접부나 열영향부 (heat affected zone: HAZ)에서 파단이 발생하였다. 기존의 연구 결과⁽²⁾에 의하면 레이저만을 이용하여 용접하는 경우, 강도 저하현상이 발생하여 대부분 모재보다 낮은 인장강도를 갖는다. 그러나 용가와이어를 이용



(a) Fracture at base metal



(b) Fracture at weld or HAZ

Fig. 2 Fracture type after tensile test

하여 알루미늄 레이저 용접을 하는 경우는 Fig. 2에서 보는 바와 같이 적정의 용접조건에서는 모재에서 파단이 형성됨을 알 수 있다. 그러므로 용접조건에 따라 인장강도의 변화가 매우 큼을 알 수 있다.

3. 신경망 모델을 이용한 인장강도 예측모델

용가 와이어를 이용한 알루미늄 레이저 용접에서 용접부의 인장강도를 예측하기 위한 프로세스 모델링을 위해 인공지능형 알고리즘의 하나인 신경회로망을 이용하였다. 앞 장의 실험 결과에서 보듯이 용가 와이어를 이용한 레이저 용접은 그 결과가 매우 비선형적이다. 그러므로 학습의 능력을 갖춘 신경회로망 모델을 이용하여 인장강도를 예측하는 모델을 구성하였다. 구성된 모델은 Fig. 3과 같다. Fig. 3에서 보는 바와 같이 1개의 입력층(input layer)과 2개의 은닉층(hidden layer) 그리고 출력층(output layer)으로 구성되어 있으며 각각의 층에는 3개, 5개, 3개, 1개의 노드를 가지고 있다. 각 입력층과 은닉층에는 바이어스(bias) 노드를 가지고 있다.

구성한 신경회로망 모델의 입력 노드는 레이저의 출력, 용접속도, 그리고 용가 와이어의 송급속도로 하였다. 출력 노드는 레이저 용접 시편의 예측된 인장강도로 설정하였다. 학습에 사용된 데이터는 Table 3에 주어진 실험 결과를 사용하였다. 그러므로 총 학습에 사용된 데이터의 수는 27개였다. 각 노드의 연결 강도를 학습시키기 위한 방법은 오류 역

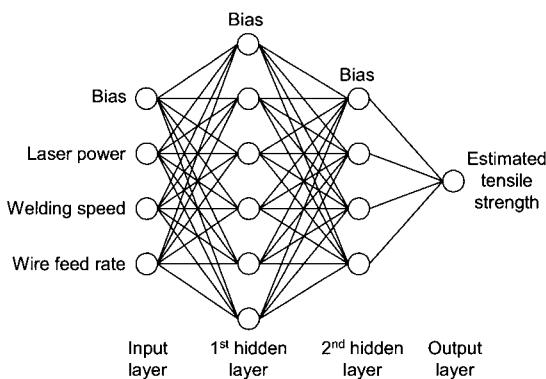


Fig. 3 Neural network model for tensile strength estimation

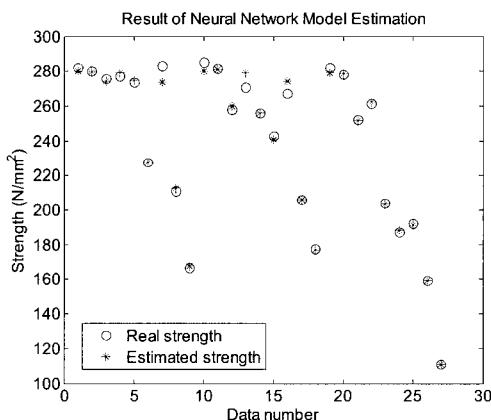


Fig. 4 Result of neural network estimation model

전파(error backpropagation) 알고리즘을 사용하였다. 신경 회로망 모델의 설정 값으로 학습률(learning rate)은 0.1, 모멘텀 계수(momentum parameter)는 0.9, 최소 학습오차는 10이하로 하였고 최대 학습수는 10,000회로 하였다. 학습은 총 250회를 수행하였고, 250회의 결과 중에 가장 예측 결과가 좋은 식을 이용하여 모델을 구하였다.

각 레이어를 연결하는 전달 함수로서 입력층과 1차 은닉층 간에는 로그 시그모이드(log-sigmoid) 전달 함수를 이용하였고, 1차 은닉층과 2차 은닉층 사이와 2차 은닉층과 출력층 간의 전달 함수는 1차 선형(linear) 함수를 사용하였다. 수렴 속도의 향상을 위해 수렴 속도나 성능에 있어서 우수한 레벤버그 마퀴드 알고리즘(Levenberg-Marquardt algorithm)을 이용하였다⁽¹²⁾.

Fig. 4는 신경 회로망 모델을 이용하여 얻은 결과를 보여

주고 있다. Fig. 4에서 ‘o’는 실제 인장강도로 Table 4의 실험결과와 같다. ‘*’는 신경망 모델에 의하여 예측된 인장강도이다. 각 데이터 번호에서 ‘o’와 ‘*’의 차이가 예측 오차가 된다. 그림에서 보는 바와 같이 전체적으로 예측성능이 우수함을 알 수 있었다.

일반적으로 예측 모델의 정도(precision)는 결정계수를 이용하여 판단할 수 있다. 또한 정량적 평가를 위해 평균 오차율(Average error rate: AER)을 이용하여 예측모델의 성능을 평가하여 보았다. 결정계수와 평균 오차율에 대한 식은 식 (1)과 (2)와 같다.

$$R^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2} \quad (1)$$

$$AER = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (2)$$

여기서 R^2 은 결정계수이고, i 는 데이터 번호이다. n 은 데이터의 총 수로 본 논문에서는 27이다. y 는 실제 측정된 인장 강도 값이고, \bar{y} 는 y 의 평균값이다. 그리고 \hat{y} 는 신경망 모델에 의하여 예측된 값이고, $\bar{\hat{y}}$ 는 \hat{y} 의 평균값이다.

식 (1)과 (2)를 이용하여 구한 결과는 다음과 같다. 신경망 모델의 결정 계수는 0.9942이고, 평균 오차율은 0.0103이다. 결정계수는 1에 가까울수록 예측 성능이 우수하며 평균 오차율은 0에 가까울수록 우수한 것이다. 각 결정계수와 평균오차율에서 보는 바와 같이 신경망 모델이 정량적으로 예측 성능이 우수함을 알 수 있다.

4. 생산 자동화를 위한 변수 최적화

4.1 목적 함수

생산 자동화를 위하여 용접 공정을 최적화하기 위해서는 다양한 인자가 고려되어야 한다. 용접 공정에 있어서는 용접 성과 생산성이 동시에 고려되어야 한다. 실험결과에서 보는 바와 같이 모재 이상의 인장강도를 얻기 위해서는 레이저 출력이 높거나 용접속도가 느려야 한다. 그러나 레이저 출력을 높이는 데는 한계가 있고, 용접속도를 느리게 하면 생산성이 감소된다. 그러므로 이 상반된 결과로부터 생산성과 용접성을 동시에 만족시키기 위해서는 이에 맞는 성능평가 지수를 구성하여야 한다. 본 논문에서는 이러한 성능 평가 지수를 목적함수로 정의하였다. 목적함수에 있어서 용접성을 나타내는 인자로 인장강도를 선택하였다. 인장강도의 값은

앞에서 구한 신경망 모델을 이용하였다. 생산성을 나타내는 인자로는 용접속도와 와이어 송급속도를 선택하였다.

인장강도는 Table 3에서 보는 바와 같이 111에서 285의 값을 갖으며, 용접속도와 와이어 송급속도는 각각 6에서 9, 그리고 2에서 4까지의 값을 갖는다. 각각의 값이 서로 다른 차수(order)를 가지고 있기 때문에 직접적인 연산이 불가능하다. 그러므로 3개의 특징인자를 표준화(normalizing) 하였다. 표준화를 위한 식은 식 (3)에서 (5)와 같다.

$$TS_N = \begin{cases} 1.5 \times \frac{TS - 100}{277 - 100} & (TS \geq 277) \\ 1.0 \times \frac{TS - 100}{277 - 100} & (100 \leq TS < 277) \\ 0 & (TS < 100) \end{cases} \quad (3)$$

$$WS_N = \frac{WS - 9}{6 - 9} \quad (4)$$

$$WFR_N = \frac{WRF - 4}{2 - 4} \quad (5)$$

여기서 TS_N 은 신경망 모델을 통하여 예측된 인장강도의 표준화된 값이고, WS_N 과 WFR_N 은 용접속도와 와이어 송급속도의 표준화된 값이다. TS 는 신경망 모델에 의하여 예측된 인장강도 값이다. WS 와 WRF 은 각 용접조건에서 용접속도와 와이어 송급속도이다.

식 (3)은 Table 4에서 보는 바와 같이, 실험 결과의 최소값보다 적은 $100N/mm^2$ 과 모재의 인장 강도인 $277N/mm^2$ 을 기준으로 그 구간내의 값을 0에서 1로 할 수 있도록 목적함수를 정의하였다. 모재보다 높은 인장 강도로 예측되는 구간에 대해서는 1.5의 가중치를 줌으로서 그 중요도를 더하였다. 용접 속도는 빠를수록 생산성이 유리하므로, 용접 속도에 대한 표준화 함수의 값은 변수 영역내의 가장 빠른 속도인 $9m/min$ 은 1로, 가장 느린 속도인 $6m/min$ 은 0이 되도록 정의하였다. 와이어 송급속도에 대한 표준화 함수는 제품의 단가를 고려할 때, 와이어 송급 속도가 작을수록 유리하다. 그래서 변수 영역 내에서 가장 작은 값을 갖는 $2m/min$ 은 1로, 가장 큰 값을 갖는 $4m/min$ 은 0으로 되도록 하였다.

이렇게 표준화된 인자를 이용하여 각 용접조건에 대한 성능평가 지수를 목적함수로 식 (6)과 같이 정의하였다.

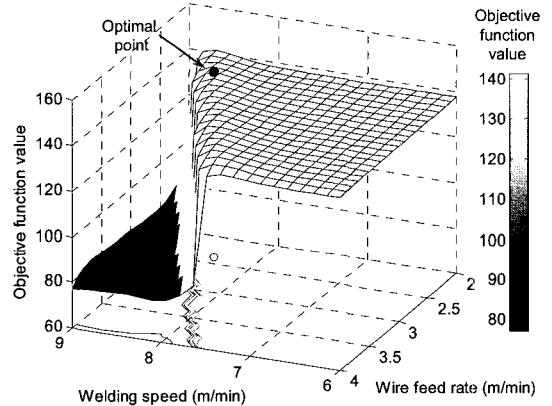
$$obj = w_{TS} \times TS_N + w_{WS} \times WS_N + w_{WFR} \times WFR_N \quad (6)$$

여기서 obj 는 목적함수의 값을 의미한다. TS_N , WS_N , 그리고 WFR_N 은 식 (3)에서 (5)에 정의된 각 인자의 표준화 된 값이다. w_{TS} , w_{WS} , 그리고 w_{WFR} 는 각 특징 인자의 표준화 된 값에 대한 가중치를 나타낸다. 본 연구에서는 인장 강도

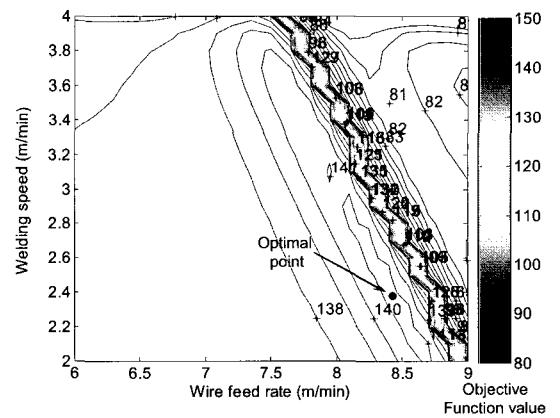
에는 80의 가중치를, 용접속도와 와이어 송급속도에는 각각 15와 5의 가중치를 두었다. 이것을 통해 용접성이 좋은 변수 범위 내에서 최대의 생산성을 얻을 수 있는 값을 찾고자 하였다.

4.2 변수 최적화 결과

Fig. 5는 4kW에서 용접속도와 와이어 송급속도에 따른 목적함수의 곡면과 목적함수의 등고선(contour)을 표시하였다. 그림에서 보는 바와 같이 목적함수의 값이 급격하게 상승하는 구간이 있다. 이것은 식 (3)에서 인장강도의 표준화 함수값에서 모재의 인장강도 보다 큰 영역에 1.5의 가중치를 두었기 때문이다. 그러므로 목적함수의 값이 급격히



(a) Surface of objective function value



(b) Contour of objective function

Fig. 5 Fitness function value at 4 kW of laser power

변하는 영역을 중심으로 목적함수 값이 큰 쪽은 인장강도가 모재의 인장강도보다 높은 영역이고 목적함수의 값이 적은 쪽은 예측된 인장강도가 모재의 인장강도보다 낮은 영역이다.

결과적으로 최적의 공정 변수는 레이저 출력은 4kW, 용접 속도는 8.5m/min, 그리고 와이어 송급속도는 2.4m/min 이었다. 이때의 적합도 함수의 값은 141.29 이고 예측되는 인장강도의 값은 284.2N/mm² 이다. 예측되는 인장강도가 277N/mm² 보다 높으므로 파단은 모재에서 발생될 것으로 예상된다. 그리고 와이어 송급속도가 느리면서도 용접 속도는 빠르므로 생산성 측면에서도 적정한 용접 조건으로 사료된다.

5. 결 론

본 논문에서는 차량 경량화에 있어서 매우 중요한 알루미늄 합금의 레이저 용접에서 생산성과 용접성을 고려한 공정 변수의 최적화 기법을 제안하였다. 본 연구를 통하여 얻어진 결론은 다음과 같다.

- (1) AA5356 용가와이어를 이용한 AA5182 알루미늄 합금의 레이저 용접에서 용가와이어의 공급에 의해 인장강도의 향상이 되었고, 적정 용접 영역에서는 모재 파단이 발생하였다.
- (2) 신경망 모델을 이용하여 용접성을 나타낼 수 있는 인자인 인장강도 예측모델을 구성하였다. 예측 모델에 있어서 결정 계수는 0.9942이고, 평균 오차율은 0.0103로 그 예측성능이 우수함을 알 수 있었다.
- (3) 용접성과 생산성을 고려한 최적의 용접조건을 얻기 위하여 목적함수를 정의하였다. 용접성을 나타내는 인자로 인장강도 모델을 이용하였고, 생산성을 나타내는 인자로 용접속도와 와이어 송급속도를 이용하였다. 이들 값을 표준화하였고 각각의 표준화된 값에 가중치를 곱하여 목적함수를 정의하였다. 그리고 목적함수가 최대 값을 갖는 점을 최적의 공정변수로 설정하였다.
- (4) 최적의 용접조건은 레이저 출력은 4kW, 용접 속도는 8.5m/min, 그리고 와이어 송급속도는 2.4m/min 이었다. 이때의 적합도 함수의 값은 141.29이고 예측되는 인장강도의 값은 284.2N/mm² 이다.

참 고 문 헌

- (1) Leong, K. H., Sabo, K. R., Altshuller, B., Wilkinson, T. L. and Albright, C. E., 1999, "Laser Beam Welding of 5182 Aluminum Alloy Sheet," *Journal of Laser Applications*, Vol. 11, No. 3, pp. 109~118.
- (2) Pastor, M., Zhao, H., Martukanitz, R. P. and Debroy, T., 1999, "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.
- (3) Naeem, M. and Jessett, R., 1998, "Aluminium 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.
- (4) Yoon, J. W., Lee, Y. S., Lee, K. D. and Park, K. Y., 2003, "Effect of Filler Wire Composition on the Solidification Cracking of 6061 Aluminum Alloy Laser Welds," *Proceedings of the 2003 Fall Annual Meetings of Korean Welding Society*, Vol. 41, pp. 98~100.
- (5) Salminen, A. S. and Kujanp, V. P., 2003, "Effect of Wire Feed Position on Laser Welding with Filler Wire," *Journal of Laser Applications*, Vol. 15, No. 1, pp. 2~10.
- (6) Park, H. and Rhee, S., 1999, "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.
- (7) Jeng, J. Y., Mau, T. F. and Leu, S. M., 2000, "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.
- (8) Chan, B., Pacey, J. and Bibby, M., 1999, "Modeling Gas Metal Arc Weld Geometry Using Artificial Neural Network Technology," *Canadian Metallurgical Quarterly*, Vol. 38, No. 1, pp. 43~51.
- (9) Tarng, Y. S., Tsai, H. L. and Yeh, S. S., 1999, "Modeling, Optimization and Classification of Weld

- Quality in Tungsten Inert Gas Welding," *International Journal of Machine Tools & Manufacture*, Vol. 39, No. 9, pp. 1427~1438.
- (10) Jung, W. J., Kim, J. L., Kim, J. H., Hong D. S., Kang, H. S. and Kim, D. S., "Optimization of Expanding Velocity for a High-speed Tube Expander Using a Genetic Algorithm with a Neural Network," *Transactions of the Korean Society of Machine Tool Engineers*, Vol. 14, No. 2, pp. 27~32.
- (11) Sette, S., Boullart, L. and Van Langenhove, L., 1996, "Optimizing a Production Process by A Neural Network/Genetic Algorithm Approach," *Engineering Applications of Artificial Intelligence*, Vol. 9, No. 6, pp. 681~689.
- (12) Demuth, H. B. and Beale, M., 1998, *Neural network toolbox user's guide*, Version 3, The Math Works Inc, pp. 5~36.