

# 신경회로망을 이용한 CO<sub>2</sub> 레이저 가공 모니터링 및 비드 예측에 관한 연구

## Estimation of CO<sub>2</sub> laser weld bead by using neural network

한양대학교 정밀기계공학과 박현성, 이세현  
㈜대우자동차 정경훈, 박인수, 노재홍, 고광무, 유종우, 이삼주

### I. 서론

레이저를 이용하여 고속, 대량으로 용접을 하는 경우에는 용접 품질을 확보하는 것이 중요하며, 레이저 용접 품질 검사 방법이 계속적으로 연구되고 있다. 특히 자동차용 테일러드 블랭크(tailored blank)와 같이 CO<sub>2</sub> 레이저를 사용하여 고속으로 용접을 하는 경우, 판재로 사용되는 박판의 상태, 레이저 출력, 보조가스의 유량, 용접속도등 용접변수들의 변화에 의해 용접비드의 형상과 크기가 변화할 수 있으며, 이것이 용접 결함으로 작용하게 된다. 또한 대량생산 체제로 돌입하게 되면, 약간의 용접변수 변화는 불연속적인 비드 형상을 발생시키게 되고, 그로 말미암아 용접부의 강도가 변하게 되지만 이를 육안으로 관측하기는 매우 어렵다. 따라서 레이저 용접을 하면서 발생하는 용접부의 비드 형상을 실시간으로 검출해 내어야만 계속되는 불연속 비드의 발생을 막을 수 있으며, 재료의 손실을 줄이고, 우수한 품질을 얻을 수 있다. 그러므로 비드의 형상을 실시간으로 검출해낼 수 있는 용접 비드 예측 시스템 요구되고 있다.

용접부 예측의 경우, Kovacevic 등<sup>1)</sup>은 고속 카메라(high speed camera)를 사용하여 용융지의 형상(geometrical appearance)를 측정, 신경회로망을 사용하여 이면 비드의 폭을 예측하였으며, Farson 등<sup>2)</sup>은 음향방사(acoustic emission)를 신호를 사용하여 신경회로망으로 완전용입, 부분용입, 미접착(no-coupling)을 구분할 수 있는 연구를 수행하였다. 또한 Lankalapalli 등<sup>3)</sup>은 레이저 용접부의 온도와 용융지 폭을 측정하여 용입깊이를 예측하는 수학적 모델을 개발하였다. 그러나 레이저 용접의 경우, 현재까지 용접 비드의 크기를 정확히 예측하는 연구가 부족하여, 품질을 모니터링 하는데 많은 어려움이 있다. 따라서 본 논문에서는 자동차용 아연도금 강판의 용접시 포토다이오드를 사용하여 용접속도, 레이저 출력 등의 용접변수 변화에 따른 플라즈마와 스패터를 측정, 그 신호들을 체계적으로 분석하며, 이를 회귀분석(regression analysis)과 인공신경회로망(artificial neural network)을 사용하여 용접 비드 형상을 정량적으로 예측하는 시스템을 구현하였으며, 두 예측기법을 비교, 분석하였다.

### II. 실험방법 및 예측기법

본 연구에서 사용한 포토 다이오드는 자외선 영역과 적외선 영역의 두 가지 종류이다. 용접 시편은 두께 1.5mm의 자동차용 아연도금강판을 사용하여 용접길이 약 500mm의 상판(bead on plate)용접을 수행하였다. 용접변수는 용접속도(travel speed), 레이저 출력(laser power)을 주어, 용접 변수의 변화에 따른 신호를 획득하였다.

레이저 용접의 플라즈마와 스패터 신호는 용접부가 완전용입과 부분용입으로 나뉘므로 인하여 신호가 변하게 되고, 그에 따른 용입깊이와 비드폭도 변하게 된다. 이로 말미암아 신호들과 용입깊이, 비드폭 사이에는 복잡한 비선형 함수관계를 갖게 되고, 이들 사이의 함수관계

를 정확하게 사상(mapping)할 수 있는 기법이 요구된다. 따라서 이 신호를 이용하여 용입깊이와 비드폭을 예측하기 위해서 통계적인 방법인 다중회귀분석(multiple regression analysis)을 통하여 체계적으로 분석하여 회귀 모델을 만들었다. 또한 최근에 예측 알고리즘으로 많이 사용되고 있는 인공신경회로망(artificial neural network)중에서 오류 역전파 알고리즘(error backpropagation algorithm)을 사용하여 용입깊이와 비드폭을 구하였다.

### III. 실험결과 및 고찰

용접조건에 대해서 각 신호들과 용입깊이, 비드폭의 공상관관계를 구하여 전용접조건, 부분용입시, 완전용입시의 신호에 대한 회귀 모델을 구해보면 다음과 같다.

전용접조건

$$P = 0.363 \cdot U_2^{1.076} \cdot I^{-1.153} \quad (1)$$

$$W = 0.549 \cdot U_1^{-0.159} \cdot U_2^{0.396} \cdot I^{-0.292} \cdot U_{2S}^{0.11} \quad (2)$$

부분용입시

$$P = 1.132 \cdot U_1^{-0.794} \cdot I^{1.063} \cdot U_{IS}^{0.322} \quad (3)$$

$$W = 1.096 + 0.269U_2 - 0.351I \quad (4)$$

완전용입시

$$P = 0.787 \cdot U_2^{0.509} \cdot I^{-1.29} \quad (5)$$

$$W = 0.932 \cdot U_1^{-0.145} \quad (6)$$

다중회귀분석 부분용입과 완전용입만을 구분하여 사용할 경우에는 대체적으로 부분용입시 용입깊이를 제외하고는 모두 5%내외의 오차를 가지므로 어느 정도 타당성이 있다고 생각되어진다. 따라서 퍼지기법등과 같은 판단 알고리즘을 이용하여 부분용입과 완전용입을 구분한 후 이 모델에 적용시킬 경우에는 비교적 정확한 용입형상 예측시스템으로 사용할 수 있을 것이다.

한편, 비드 형상 예측 시스템이 부분용입과 완전용입의 정도까지도 구분해 내야하는 것까지 요구된다면, 이 모델의 사용이 곤란함을 알 수 있다. 신경회로망을 이용한 비드 형상 예측은 학습 데이터 뿐 만 아니라 생산단계의 새로운 데이터도 모두 5%내외의 오차를 갖게 된다. 이와 같은 신경회로망의 5%내외 오차는 비드 형상 예측의 타당성 범위 내에 존재하게 되므로, 정확한 레이저 비드 예측시스템으로 사용할 수 있을 것으로 생각된다. 또한 이 형상 예측 시스템을 레이저 결합 검출 시스템과 결합하여 생산현장에 함께 사용한다면, 완벽한 레이저 용접 모니터링 시스템을 구현할 수 있을 것이다.

### IV. 결론

다중회귀분석을 사용하여 부분용입과 완전용입에서 타당한 회귀 모델을 구현할 수 있었으며, 신경회로망을 사용하여 상당히 정확한 비드 예측 시스템을 만들 수 있었다.

## V. 참고문헌

1. R. Kovacevic, Y. M. Zhang, and L. Li, "Monitoring of Weld Joint Penetration Based on Weld Pool Geometrical Appearance", *Welding Journal*, Vol. 75, No. 10, pp. 317s-329s, (1996)
2. F. D. Farson, K. S. Fang, and J. Kern, "Intelligent Laser Welding Control", *ICALEO '92*, pp. 104-112
3. K. Lankalapalli, and J. F. Tu, "Penetration Depth Estimation for Monitoring CO<sub>2</sub> Laser Welding Process", *Laser process monitoring and control*, Laser institute of america, pp.107-116

Table 6 Model summary and estimation errors

|                   |                                | Total regression | Partial penetration regression | Full penetration regression | Neural network |
|-------------------|--------------------------------|------------------|--------------------------------|-----------------------------|----------------|
| Penetration depth | Adjusted R <sup>2</sup>        | 0.493            | 0.929                          | 0.773                       |                |
|                   | Standard error of the estimate | 0.4597           | 0.1373                         | 0.0213                      |                |
|                   | Error for training(%)          | 36.8             | 10.3                           | 1.5                         | 5.2            |
|                   | Error for production(%)        | 38.6             | 8.0                            | 4.4                         | 4.2            |
| Bead width        | Adjusted R <sup>2</sup>        | 0.715            | 0.914                          | 0.526                       |                |
|                   | Standard error of the estimate | 0.1316           | 0.1235                         | 0.0541                      |                |
|                   | Error for training(%)          | 9.8              | 5.8                            | 4.2                         | 3.5            |
|                   | Error for production(%)        | 10.3             | 5.0                            | 4.8                         | 5.2            |




Fig. 1 Estimated penetration depth(regression)




Fig. 2 Estimated bead width(regression)




Fig. 3 Estimated penetration depth(neural network)




Fig. 4 Estimated bead width(neural network)