

신경회로망을 이용한 필릿 이음부의 가스매달 아크
용접변수 선정에 관한 연구

*
문형순(한국과학기술원 정밀공학과)
이중영(한국과학기술원 정밀공학과)
나석주(한국과학기술원 정밀공학과)

I. 서론

실제 용접시 적절한 용접품질을 얻기위해 선정해야할 용접변수들은 서로 연관되어 있다. 용접품질에 대한 이들 변수들의 영향력을 수학적으로 모델링 하는데는 여러가지 어려운 점이 있는데 이들 변수사이의 관계가 정확하게 정의되지 않으면 용접품질에 대한 용접변수의 제어가 용의하지 않다. 용접품질에 대한 용접변수를 제어하기 위한 방법으로 와이어 공급속도와 루트 간격(root gap)사이의 관계를 실험적으로 구하거나[1] 용접속도와 비드(bead)형상에 대한 정보를 이용하여 용접부를 제어하는 방법[2]등이 발표되었으나 이들 방법들은 용접변수 전체를 고려하지 않고 용접변수 각각에 대한 용접부의 특성을 실험적으로 구하여 용접부를 제어하고자 하였다. 따라서 용접부의 형상을 결정하는데 있어 서로 연관된 특성을 가지는 용접변수들에 대해서는 전반적으로 고려되지 않았다.

원하는 용접품질에 대한 적절한 용접변수를 얻기위해서 열전달에 대한식을 유도하고[3] 이 식을 이용하여 주어진 용접변수에 대해서 용접품질을 예측할 수 있으나[4], 프로그램 수행시간이 오래 걸리고 채택된 물성치에 의해서 그 정확도가 변하는 단점이 있다.

본 연구에서는 신경회로망을 이용해 원하는 필릿 이음부의 용접품질에 대한 용접변수를 보다 쉽게 얻을 수 있는 시스템을 구성하고자 하며 신경회로망에 의한 모델링과 실제 실험한 데이터를 이용하여 학습된 신경회로망에 대한 신뢰성을 시험하였다.

II. 신경회로망을 이용한 용접변수 결정

용접공정에서 나타나는 여러가지 용접변수들은 각각 서로 상관관계를 가지며 용접공정의 물리적인 개념으로 이들 변수에 대한 용접품질의 관계를 정량화 시키는 데는 많은 문제점을 가지고 있다.

원하는 용접품질에 대해 선정할 용접변수들을 시행착오를 많이 거치지 않고 정확히 예측하기 위하여 신경회로망을 이용하여 위의 복잡한 문제점을 해결하고자 한다. 이를 위한 신경회로망 구성도를 Fig. 1에 나타내었다.

용접방법은 필릿용접이고 실험횟수는 각 모재 두께당 12번의 실험을 하였으며 모재 두께는 4.5mm, 6mm, 7mm의 연강을 대상으로 하였다. 여기서 구한 각각의 실험데이터를 학습데이터로 사용하기 위해서는 신경회로망의 시그모이드 함수의 특성에 의해 입력데이터를 0 ~ 1 사이의 값을 갖도록 해줘야 하며[5] 이를 위해서 본 연구에서는 각각의 값들을 (1)식과 같이 0.1 ~ 0.9 사이의 정규화된 값이 되도록 변경시켜 주었다.

$$[(0.9 - 0.1)/(Value(max) - Value(min))] \cdot (Value - Value(min)) + 0.1 \quad (1)$$

여기서 Value(max)는 사용하고자 하는 값의 최대값을 의미하며 Value(min)은 최소값, 그리고 Value는 실제값을 의미한다[6]. 값들을 0.1 ~ 0.9사이로 변경시킨 이유는 시그모이드(sigmoid) 함수의 특성에 의해 0과 1의 값으로 수렴하기가 매우 어려우며 이 때문에 과도한 학습이 일어날 수 있기 때문이다. 수렴속도 향상을 위해 연결강도 조절시 모멘텀(momentum)항을 추가로 사용했으며 반복학습 범위를 주기 위하여 학습시 에러(error)범위를 0.01로 하였다.

III. 결과 및 고찰

일반적으로 생각하면 학습데이터가 많을 수록 구성된 신경회로망의 예측 능력이 좋을 것으로 판단되나 실제로는 은닉층의 처리단위에 따라서 학습의 정확도가 달라질 수 있다. 따라서 예측성능이 좋은 적절한 신경회로망 구조를 얻기위해서는 다양한 구조에 대하여 실제 실험치와 신경회로망을 통하여 예측된 값들을 비교하여 가장 오차가 적은 구조를 시행착오법으로 찾아내야만 한다. 예측능력을 검증하기 위해 모재의 두께, 각장, 용입깊이를 하나의 입력 패턴으로 하고 전압, 전류, 용접속도를 출력 패턴으로 전체적으로 입, 출력 패턴이 15개인 경우에 대한 실험치와 검증데이터를 Table 1에 나타내었으며 30개인 경우를 Table 2에 나타내었다. Fig. 2에는 학습데이터가 각각 15, 30개에 대하여 실제 실험한 데이터와 입력수가 3개, 첫번째 은닉층의 노드(node)수가 7개, 두번째 은닉층의 노드수가 7개 그리고 출력수가 3개의 구조를 가지는 3-7-7-3의 신경회로망을 통해서 예측된 값들 사이의 오차율을 도식적으로 나타내었다. Fig. 2에서 보면 검증된 데이터가 학습데이터 갯수가 15개인 경우가 30개인 경우보다 더 큰 오차율을 나타내고

있음을 알 수 있으며 신경회로망 구성시 같은 구조인 경우 학습데이터가 많을 수록 예측된 용접변수들이 실제값과 비슷하며 오차가 적음을 알 수 있다.

또한 학습데이터가 같을 경우에도 은닉층의 노드 수에 따라 신경회로망의 특징이 조금씩 달라질 수 있으므로 한 패턴당 입력갯수가 3개 -모재의 두께, 각장, 용입깊이 -, 출력갯수가 3개 -아크전압, 용접전류, 용접속도 -인 구조에 대해 은닉층의 처리단위를 다양하게 바꿔가며 실험하였으며 Fig. 3에 이들 각각의 구조에 대하여 예측된 값과 실제 실험치와의 오차율을 도식적으로 나타내었다. 여기서 보면 3-7-7-3의 구조가 오차율이 가장 작고 따라서 구성된 신경회로망중 가장 예측능력이 우수함을 알 수 있다. Fig. 4에는 신경회로망을 이용하여 예측한 값과 실제값 사이의 오차율에 대한 표준편차를 나타내었으며 3-7-7-3의 구조가 표준편차값이 가장 작음을 알 수 있고 또한 오차율이 가장 작으므로 각각의 용접변수를 예측하는데 있어 실제 실험값과 비교해서 큰 오차를 가지지 않는 가장 안정된 신경회로망 구조임을 알 수 있다. 그러나 3-7-7-3의 구조가 위에서 제시된 여러가지 신경회로망의 구조에 비하여 용접품질에 대한 용접변수를 선정하는 가장 적절한 구조임에는 틀림없으나 다른 다양한 은닉층의 처리단위를 갖는 신경회로망에 대하여 실험을 해보면 더욱 적절한 구조의 신경회로망을 얻을 수도 있으리라 생각된다.

모재의 두께, 전류, 전압, 용접속도를 입력 패턴으로 하고 각장, 용입깊이를 출력 패턴으로 하는 구조에 대하여 예측특성을 알아보기 위해서 전체 학습 패턴이 30개인 경우에 대한 신경회로망을 구성하여 여러가지 다양한 은닉층의 처리단위를 갖는 구조에 대하여 실험 하였다. 예측값에 대한 실제값과의 오차율에 대한 표준편차를 4-8-4-2, 4-9-3-2, 4-10-4-2, 4-7-7-2, 4-8-8-2, 4-9-9-2의 구조에 대해서 Fig. 5에 나타내었다. 여기서 4-8-4-2의 구조가 오차율에 대한 표준편차에서 가장 작음을 알 수 있고 따라서 다른 신경회로망보다 각장과 용입깊이를 예측하는데 있어 가장 안정된 구조임을 알 수 있다.

IV. 결론

본 연구에서는 용접공정에 있어 용접변수 선정을 위한 신경회로망의 적용에 관하여 고찰하였다. 용접공정은 수학적인 모델링이 어려울 뿐만 아니라 공정에 관련되는 각 변수들을 독립적으로 형성시키기 어려우므로 경험에 의한 데이터들을 이용하여 예측능력의 특성을 가진 신경회로망 모델을 구성시켜 이러한 난점을 해결할 수 있으리라 생각된다. 이러한 개념을 이용하여 용접공정에 있어 용접변수 선정시 해석적인 방법에 의하지 않고 신경회로망 모델을 이용하여 변수값들을 예측하고 이 값들을 실제 실험치와 비교하여 가장 적절한 신경회로망 구조를 선택하였다. 신경회로망에 대하여 모의실험한 결과 용접품질에 대한 용접변수를 예측하는 모델로서 실제 실험치에 대한 예측 값들이 큰 오차없이 나타남을 알 수 있었다.

참고 문헌

1. H. Nomura, Y. Sugitani, M. Murayama, "Development of Automatic Fillet Welding Process with High Speed Rotating Arc", Transaction of the Japan Welding Society, Vol. 18, No. 2, 1987, pp. 116-124.
2. H. Nomura, Y. Sugitani, Y. Suzuki, "Automation Real-Time Bead Height Control with Arc Sensor in TIG Welding", Transaction of the Japan Welding Society, Vol. 18, No. 2, 1987, pp. 125-132.
3. D. Rosenthal, "Mathematical Theory of Heat Distribution during Welding and Cutting", Welding Journal, Vol. 20, No. 5, 1941, pp. 220-234.
4. A. C. Nunes, "An Extended Rosenthal weld model", Welding Journal, Vol. 62, No. 6, 1983, pp. 165-170.
5. P. D. Wasserman, "Neural Computing Theory and Practice", Van Nostrand Reinhold International Company Ltd., New York, 1989, pp. 44-47.
6. K. Andersen, G. E. Cook, G. Karssai and K. Ramaswamy, "Artificial Neural Networks Applied to Arc Welding Process Modeling and Control", IEEE Transaction on Industry Application, Vol. 26, No. 5, 1990, pp. 824-830.

Table 1. Data sets used for Training(1-15) and Testing(16-24) of Neural Network

Test Number	Thickness of Plate (mm)	Leg Length (mm)	Penetration (mm)	Voltage (V)	Travel Speed (mm/s)	Current (A)
1	4.5	4.7	0.5	19	4	200
2	4.5	4.35	1.125	20	6	200
3	4.5	5.5	1.5	21	4	240
4	4.5	6.65	1.81	24	4	250
5	4.5	5.7	2.0	24	6	260
6	6.0	6.0	1.4	21	4	230
7	6.0	6.5	1.7	23	4	250
8	6.0	5.35	1.82	23	6	250
9	6.0	5.4	1.97	25	6	270
10	6.0	5.8	2.12	26	6	270
11	7.0	6.5	1.25	23	4	240
12	7.0	6.85	1.8	26	4	260
13	7.0	5.1	1.88	25	6	260
14	7.0	7.25	2.32	28	4	280
15	7.0	6.02	2.5	28	6	280
16	4.5	3.8	1.0	19	6	200
17	4.5	4.95	1.8	22	6	240
18	4.5	5.7	1.25	22	4	220
19	6.0	5.1	1.63	22	6	230
20	6.0	6.75	1.85	25	4	270
21	6.0	5.3	1.68	24	6	240
22	7.0	4.9	1.4	23	6	240
23	7.0	6.7	2.25	27	4	280
24	7.0	5.55	2.14	25	6	270

Table 2. Data sets used for Training(1-30) and Testing(31-39) of Neural Network

Test Number	Thickness of Plate (mm)	Leg Length (mm)	Penetration (mm)	Voltage (V)	Travel Speed (mm/s)	Current (A)
1	4.5	4.7	0.5	19	4	200
2	4.5	4.9	0.81	20	4	200
3	4.5	4.35	1.125	20	6	200
4	4.5	5.5	1.5	21	4	240
5	4.5	6.25	1.67	22	4	240
6	4.5	4.3	1.75	21	6	240
7	4.5	6.4	1.9	23	4	260
8	4.5	6.65	1.81	24	4	250
9	4.5	5.0	1.94	23	6	260
10	4.5	5.7	2.0	24	6	260
11	6.0	6.0	1.4	21	4	230
12	6.0	6.35	1.53	22	4	230
13	6.0	4.5	1.59	21	6	230
14	6.0	6.5	1.7	23	4	250
15	6.0	6.6	1.75	24	4	250
16	6.0	5.35	1.82	23	6	250
17	6.0	5.7	1.835	24	6	250
18	6.0	6.95	1.9	26	4	270
19	6.0	5.4	1.97	25	6	270
20	6.0	5.8	2.12	26	6	270
21	7.0	6.5	1.25	23	4	240
22	7.0	6.6	1.32	24	4	240
23	7.0	5.6	1.6	24	6	240
24	7.0	6.6	1.69	25	4	260
25	7.0	6.85	1.8	26	4	260
26	7.0	5.1	1.88	25	6	260
27	7.0	5.7	1.93	26	6	260
28	7.0	7.25	2.32	28	4	280
29	7.0	5.45	2.37	27	6	280
30	7.0	6.02	2.5	28	6	280
31	4.5	3.8	1.0	19	6	200
32	4.5	4.95	1.8	22	6	240
33	4.5	5.7	1.25	22	4	220
34	6.0	5.1	1.63	22	6	230
35	6.0	6.75	1.85	25	4	270
36	6.0	5.3	1.68	24	6	240
37	7.0	4.9	1.4	23	6	240
38	7.0	6.7	2.25	27	4	280
39	7.0	5.55	2.14	25	6	270




Fig.1. Neural Network for determining welding parameters




Fig.2. Error of neural network for two training data




Fig.3. Error of various nodes of hidden layer for 30 training data




Fig.4. Standard deviation of error(%) for various nodes of hidden layer




Fig.5. Standard deviation of error(%) for various nodes of hidden layer