

신경회로망을 이용한 고주파 전기 저항 용접 파이프의 비드 형상 분류

고 국 원,* 김 종 형,* 조 형 석,* 공 원 일**

A Bead Shape Classification Method using Neural Network in High Frequency Electric Resistance Welding

Kuk Won Ko,* Jong Hyung Kim,* Hyung Suck Cho,* Won Il Kong**

ABSTRACT

Bead shape in high frequency electric resistance (HER) pipe welding gives useful information on judging current welding condition. In most welding process, heat input is controlled by skilled operators observing color and shape of bead. In this paper, a visual monitoring system is designed to observe bead shape in HERW pipe welding process by using structured light beam and a C.I.D(Charge injection device) camera. To avoid some difficulties arising in extracting stable features of stripe pattern and classifying the extracted features, Kohonen neural network is used to classify such bead shapes. The experimental results show accurate classification performance of the proposed method.

Key words : 고주파 전기 저항 용접(High Frequency Resistance Welding), 비드 형상 분류(Bead shape classification), 코호넨 신경회로망(Kohonen neural network)

1. 서 론

고주파 전기 저항 용접은 강관의 생산에 주로 사용되는 용접법으로써, Fig. 1과 같이 둥글게 성형 된 대강(skelp)에 전극을 접촉시키고, 이 접촉 팁(contact tip)을 통하여 고주파를 흘려 보내서 재료의 양단면을 국부적으로 가열하여 용융 시킨 후, 용융된 선단부를 가압롤로 압축시켜서 접합하는 방법이다. 고주파 전기

저항 용접법은 10~20 m/min 정도의 빠른 용접 속도로 인하여 생산성이 높아 용접 강관의 생산에 큰 비중을 차지하고 있다. 그러나, 고주파 전자 저항 용접은 아직도 대부분의 용접 공정이 숙련된 작업자의 경험에 의하여 용융부의 화색이나 용융 비드의 형상을 육안으로 관찰하여 용접 변수들을 수동으로 조절하고 있으므로 신뢰성 있는 용접부의 품질을 얻기가 힘들며, 생산 품목이 바뀌거나, 작업자들이 바뀔 경우 적절한 용접

* 한국과학기술원 기계공학과

** 부산파이프 주식회사

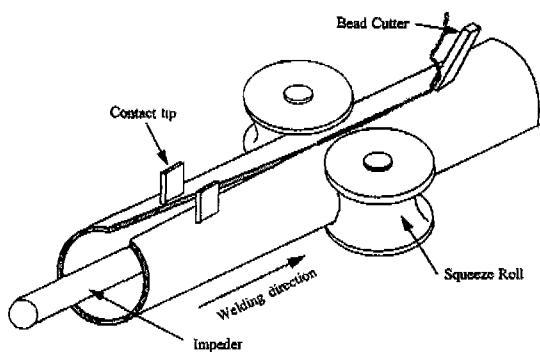


Fig. 1 High frequency electric resistance welding process

변수를 찾기 위해 많은 시행 착오를 겪어야 하는 문제점을 안고 있다. 이러한 문제점을 극복하기 위해서는 먼저 고주파 전기 저항 용접 현상을 이해하고, 이 결과를 바탕으로 각 용접 변수들의 조절이 이루어져야 한다. 그러나, 고주파 전기 저항 용접법에 대한 연구가 주로 강관의 생산에만 사용됨으로 인하여 관심 있는 전문가들에게만 국한되어 있어 많은 연구가 필요한 실정이다.

현대까지의 고주파 전기 저항 용접법에 대한 대부분의 연구는 주로 일본의 강관 생산 회사들을 중심으로 이루어졌다. 먼저 각 용접 변수들이 고주파 전기 저항 용접에 미치는 영향에 대한 연구를 시작으로 용접부의 품질을 나타내는 변수를 가려내기 위한 연구가 진행되었다. 기초 연구의 결과를 바탕으로 용접 중의 용접 변수 또는 용접질을 대변하는 성능 변수들을 측정하여 용접 공정 중 발생하는 외란을 위한 영향을 파악하고 이를 보상하여 최적의 용접 조건에서 용접이 이루어 질 수 있도록 자동으로 용접 조건을 조절하는 제어 장치의 개발이 이루어졌다. 이때 사용된 용접 상태를 나타내는 변수는 단접점(V-convergency point)의 위치 변화, 용접 전류 및 전압, 용접부의 온도 분포 패턴, 용접 비드의 형상 등 이었다.^{[6][11]} 그러나, 고주파 전기 저항 용접의 특성상 발생하는 강한 고주파 노이즈나 냉각수, 수증기의 영향으로 인하여 변수들의 측정에 어려움이 있었다. 이러한 문제를 해결하기 위한 연구가 현재 진행중이다.

본 연구에서는 고주파 전기 저항 용접기의 자동 제어 장치 개발에 앞서 필요한 용접 상태를 나타내는 변수 중의 하나인 비드의 형상 변화를 측정하여 분류할 수

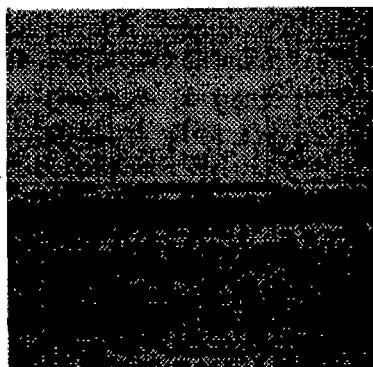
있는 시스템을 개발하였다. 비드 형상 측정의 종전 연구는 레이저광을 이용하여 구성된 직선광을 비드의 표면에 주사하고 비드의 형상에 따라 변형된 레이저 빔의 영상으로부터 비드의 높이, 폭등의 기하학적 특징치를 추출하여 비드 형상을 추출하여 분류하는 것이다. 일반적으로 기하학적 특징치 추출 방법에 의한 비드의 형상 분류는 공정상 생기는 스패터, 냉각수, 수증기 등에 의하여 비드의 영상이 오염될 경우에 신뢰성 있는 특징치의 추출이 어렵다는 문제점이 있으며, 분류 규칙을 정하기 위해 많은 실험이 필요하여 빠른 현장 적용이 어렵다.

본 연구는 이러한 문제점을 해결하고자 입력 데이터 분류(input data clustering) 기능을 가진 코호넨 신경회로망을 사용하여 비드 형상을 분류하였다. 신경회로망은 영상처리과정을 통하여 얻은 세선화된 비드 형상으로 비드 형상을 분류하므로, 기하학적 특징치를 사용한 분류 방법에 비해 노이즈 환경에 강건하게 대응하고, 다양한 비드의 형상을 많은 실험과 복잡한 규칙이 없이 쉽게 분류할 수 있다. 또한, 빠른 학습 속도와 뛰어난 수렴성을 가지므로, 실제 현장에서도 빠르게 적용할 수 있다는 장점을 가지고 있다.

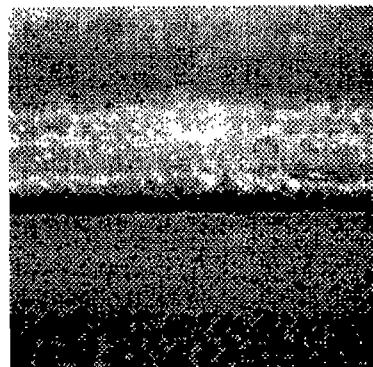
2. 고주파 전기 저항 용접과 비드 형상

Fig. 2는 고주파 전기 저항 용접부의 비드 형상을 나타내었다. 일반적으로 용접부 성능은 용접부의 비드의 형상과 관련이 있으며,^{[1][5]} 비드의 폭, 높이, 중앙 높이, 면적 등 여러 가지 기하학적 형상으로 구분할 수 있다. 비드 형상은 다음과 같은 용접 변수들, 용접 속도, 업셋팅(upsetting) 압력, 업셋팅 양, 업셋팅으로 인한 대강의 각도 변화, 접촉 티의 위치, 입열량의 영향을 받는다.^[9] 이들 변수들 중 입열량을 제외한 나머지 변수들은 생산량과 밀접한 관계가 있으므로 용접전에 결정되는 수동변수들이다. 입열량에 따라 용접부의 형상변화와 용접 결함을 살펴보면 Fig. 3과 같다.

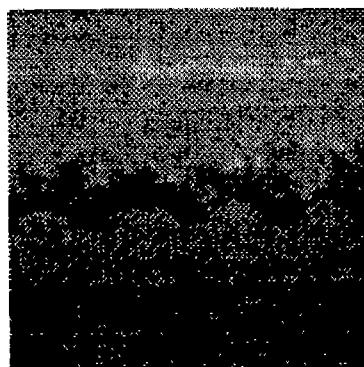
입열량이 부족할 때는 충분히 녹지 않은 대강의 양다면이 가압률에 의하여 압착되므로 양다면의 모서리 부분이 가압력에 의하여 변형이 일어나 접합부를 중심으로 벌어지며 용융 금속을 바깥으로 배출되어 냉却 결함이 생긴다. 이때 비드 형상의 특징은 다음과 같다. 적은 용융부위로 인하여 크기는 작고, 접합부의 변형으로



(a) Small welding power (160.3kW)



(b) Optimal welding power (174.7kW)



(c) Large welding power (203.1kW)

Fig 2. Bead shapes of HERW pipe

	Crosssection of Welding Joint	Crosssection of bead
Small	Molten metal Skelp Direc. of squeeze	Cold weld
Optimal		
Large		Penetration

Fig. 3 Relationships between bead shape and input power

인한 비드의 중앙부에 오목한 형상이 생기고, 폭은 좁고, 경사면의 기울기는 급하다.

입열량이 과다할 때는 대강의 모서리에 녹는 양이 많아지므로 용융된 금속이 용융부 밖으로 넘쳐 나온다. 비드 형상은 크기가 크며, 높이는 낮고, 폭은 넓다. 이 때 용접부는 열영향부의 증가로 용접부의 강도가 약해진다.

여기서 입열량을 더욱 증가시키면 과다한 입열량으로 인하여 용융부가 불안정해진다. 강한 전자기 압력으로 인하여 용융부의 용융 금속이 대강의 양단면 밖으로 급속히 배출되어 대강의 양단면 사이의 거리가 커진다. 그러면, 대강의 양단면에 흐르는 전류의 접중도가 멀어져 주울 열의 발생도가 적어져 녹은 양이 적어져 대강의 사이가 작아지면 다시 열원의 접중도가 커지며 이러한 과정을 반복하므로 비드의 형상은 불규칙적이다. 용접부의 특징은 열원의 접중도가 떨어질 때 배출된 용융금속과 함께 불순물이 용융부로 유입되어 결함이 생긴다.

이와 같이 비드 형상은 입열량 및 용접부의 불량과 밀접한 관련이 있으므로, 용접 공정중의 비드 형상을 측정하여 현재의 용접 상태를 판별한 후 입열량을 재조정하면 원하는 외관에 의해 용접 조건이 변하더라도 일정한 용접부의 품질을 얻을 수 있다.⁽³⁾

3. 비드 형상 측정장치

3. 1 측정원리

본 연구에서 고주파 전기 저항 용접부의 비드 형상

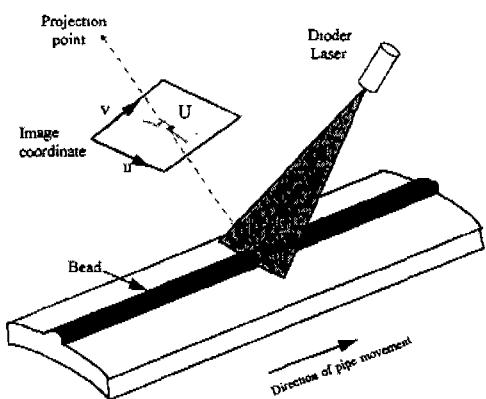


Fig. 4 Principle of bead shape monitoring

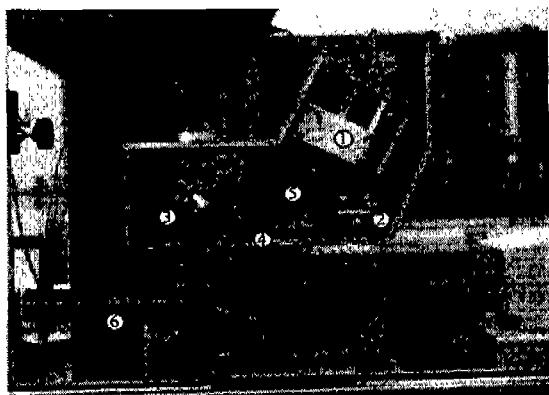


Fig. 5 Visual monitoring system

측정은 일반적인 시각 센서로는 비드 형상의 특징이 잘 나타나지 않으므로 레이저를 사용한 삼각 측량법에 의해 비드의 단면 형상을 구한다.⁽¹²⁻¹³⁾ Fig. 4와 같이 레이저 띠를 비드의 표면에 비추고 비드의 단면 형상에 따라 변형된 레이저 띠를 카메라로 관측한 후 2차원 영상 좌표로부터 비드의 단면 형상을 구한다.

3.2 측정 장치의 구성

시각 측정 장치에서는 양질의 영상을 얻음으로써 알고리즘으로 영상 정보를 처리하는 수고를 줄여서 처리 시간을 단축 시킬 수 있으며 정확도를 높일 수 있다. 고주파 전기 저항 용접 공정은 시각 측정면에서 어려운 점이 많으므로 측정 장치의 설계에 다음과 같은 점들을 고려해야 한다.

첫째, 파이프의 진동으로 측정 부위가 흔들리고 카메라의 초점이 잘 맞지 않을 수 있다.

둘째, 냉각수, 수증기, 분진 등의 이 물질이 측정 부위를 가릴 수 있으며, 측정 장치에 고착이 된다.

셋째, 비드 표면의 강한 열의 파장은 가시 영역에서 적외선 (infrared) 영역까지 포함하고 있으므로 일반적인 카메라와 레이저를 사용할 때 심한 잡음이 된다.

넷째, 강력한 고주파 유도 자장으로 인하여 전기 장비에 강한 유도 전류가 발생하여 측정되는 전기적 신호에 많은 잡음이 섞이게 된다.

다섯번째, 파이프 표면의 경면 반사로 인하여 예상하지 못한 외부 광원이나, 레이저에서 나온 파이프 표면에 반사되고, 이것이 측정장치의 벽면에 다시 산란되어 카메라에 들어오므로 영상상의 잡음이 된다.

본 연구에서 사용된 측정 장치는 Fig. 5와 같이 고주파 노이즈에 강한 C.I.D. (C.I.D 2710 CIDTEC Corp) 카메라, 수동 초점 렌즈 ($f=50\text{mm}$), 카메라의 위치를 조정하는 미세 조정 장치, 원통형 렌즈 및 다이오드 레이저 (30mW), 레이저의 파장 영역만 통과시키는 대역 통과 필터 (Narrow bandpass filter), 비드 표면의 경면 반사의 산란에 의한 잡음 성분을 줄이기 위한 편광 필터, 용접 중 발생하는 열로부터 필터와 렌즈를 보호하기 위한 열 방지용 필터 (Heat reflection filter)로 구성되어 있다. 또한 수증기, 냉각수, 분진 등으로 측정 장치를 보호하기 위하여 측정 장치 내외면에 압축공기를 사용한다.

3.3 영상처리

비들의 단면 형상을 구하기 위해 카메라로 받은 레이저 띠의 영상에는 측정 장치의 필터로 완전히 제거되지 않은 강한 스파터와 영상 획득 중 생긴 고주파 노이즈 성분들이 포함되어 있다. 이러한 노이즈 성분을 제거하기 위하여 영상 처리 시스템 (DT2867)의 특성을 고려하여 평균 필터 (mean filter)^(15,16)와 이진화 (binary) 처리로 노이즈 성분을 제거하였다. 이진화 처리에 필요한 경

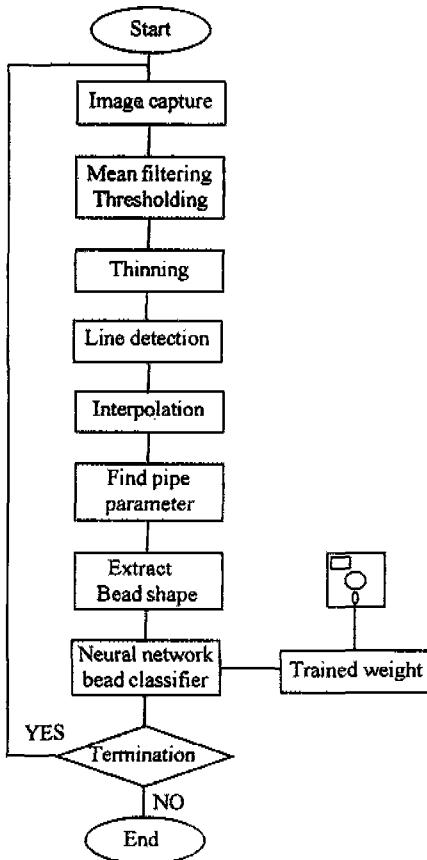


Fig. 6 Schematic diagram for bead shape classification

계값은 여러 차례의 실험을 통하여 경험적으로 구한다.

이진화된 영상으로부터 레이저 띠를 추출하여 비드의 단면 형상을 구하기 위한 세선화(thinning) 작업⁽¹⁷⁾은 이진화된 영역의 중심을 찾아 레이저 띠의 중심점을 구하였다.

레이저 띠는 영상의 가로 방향으로 놓여져 있으므로 세로 방향으로 탐색을 하고, 레이저 띠의 탐색 중 이진화된 영역이 미리 알고 있는 레이저 띠의 위치에 있고 두께가 적정하면 그 중심을 레이저 띠의 중심으로 생각하고 그렇지 않을 경우 노이즈로 간주한다. 이러한 방법은 세선화 작업과 노이즈 처리를 동시에 할 수 있는 장점이 있다.

비드 단면의 급한 형상 변화와 외란의 영향으로 인하여 레이저 띠의 영상 정보를 얻을 수 없는 부분은 선형 보간법(linear interpolation)을 사용하여 추정하였다.

4. 신경회로망을 이용한 비드 형상 분류

고주파 전기 저항 용접의 비드 형상 분류에 대한 전체 흐름도는 Fig. 6과 같이 먼저 영상 처리 과정을 통하여 구한 비드의 단면 형상으로 신경회로망을 학습 시킨후, 형상을 분류한다.

4.1 신경회로망의 구조

본 연구에서 비드 형상의 분류를 위해 사용된 코호넨 신경회로망의 구조는 Fig. 7과 같이 두개의 층으로 이루어져 있다. 첫째 층은 입력층(input layer)이고 둘째 층은 경쟁층(competitive layer)이며 1차원 배열로 구성되어 있다. 입력층에서 경쟁층으로 연결된 웨이트(weight)는 입력 패턴과의 유사도를 판별하여 경쟁 학습(competitive learning)으로 입력 패턴과 출력 노우드와 연결된 웨이트들의 상호 유사성을 판별하여 제일 유사도가 큰 노우드가 반응을 하게 되어 입력 패턴을 분류하게 된다.^[18, 20]

신경회로망의 학습 과정은 다음과 같다. 입력 패턴이 가해지면 각 출력 노우드에 연결된 웨이트와 유사성을 판별하고 가장 유사성이 큰 출력 노우드를 학습시킨다. 이때 입력 패턴 X 와 출력 노우드에 연결된 웨이트 w_{ij} 와 유사성을 판별하기 위해 유clidean 거리를 사용한다. 입력 노우드를 j , 출력 노우드를 i 라는 침자를 사용하여

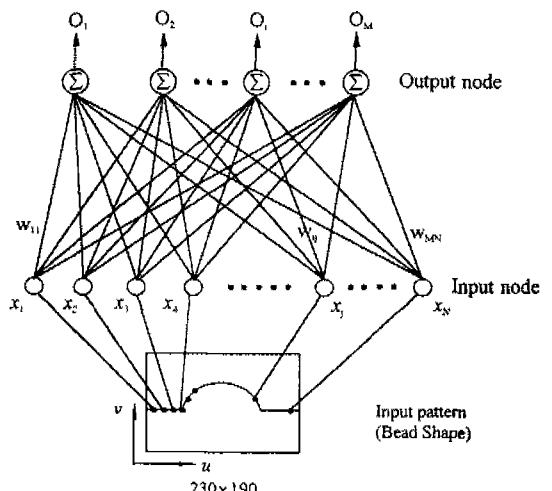


Fig. 7 Neural network architecture for bead shape classification

나타내면 i 번째 출력 노우드의 출력은 식(7)와 같다.

$$O_i = \sum_j |\omega_j - x_j| = \|W_i - X\| \quad (7)$$

이때 유사도가 가장 큰 노우드를 i^* 라 하면 모든 출력 노우드 κ 에 대해선 식(8)이 성립된다.

$$\|W_{i^*} - X\| \leq \|W_\kappa - X\| \quad (8)$$

이때 학습은 유사도가 가장 큰 노우드와 인접한 이웃 노우드(neighborhood output node)에 허용되며 다음의 학습 법칙에 의해 연결 강도는 수정되어진다.

$$\Delta w_{ij} = \eta(t) \cdot \Lambda(i, i^*) \cdot (x_j - \omega_{ij}) \quad (9)$$

여기서 t 는 학습을 위한 반복 횟수를 나타낸다. $\eta(t)$ 는 동 학습 계수(dynamic learning rate)로 t 가 증가할 수록 그 값은 감소한다. $\Lambda(i, i^*)$ 는 이웃 노우드의 학습의 정도를 결정하는 연결 가중치(connection weight)이며 멕시칸 모자의 형태를 가진다.

4.2 클래스의 개수 결정법

출력 노우드의 수는 입력 패턴을 분류하고자 하는 클래스 수와 관계가 있다. 출력 노우드의 수를 너무 많이 할 경우 처리 시간이 많이 걸리며 노이즈나 영상 처리 오차에 의한 미소한 변화까지 다른 클래스로 분류하게 된다. 반면에 출력 노우드의 수가 작을 경우 처리 시간은 짧아지나 분류의 정확도는 떨어진다. 따라서 분류 성능이 보장되는 범위에서 출력 노우드의 수를 줄이는 것이 효율적이다. 이를 위해 출력 노우드의 수를 변해가면서 학습한 후 분류된 클래스의 분포를 분석하여 전체 입력 데이터 개수 중 3%미만이 선택된 클래스를 dead output 노우드로 정의하고, dead output 노우드가 발생되지 않는 최대의 출력 노우드의 수를 최대 분류 성능을 가진 최적의 노우드 수로 생각하였다. 이때 dead output 노우드의 수를 결정하는 값은 전문가의 경험으로 정의하였다.

5. 실험 및 토의

5.1 비드 형상 측정

비드 형상 측정 실험 장치의 카메라와 레이저의 각도

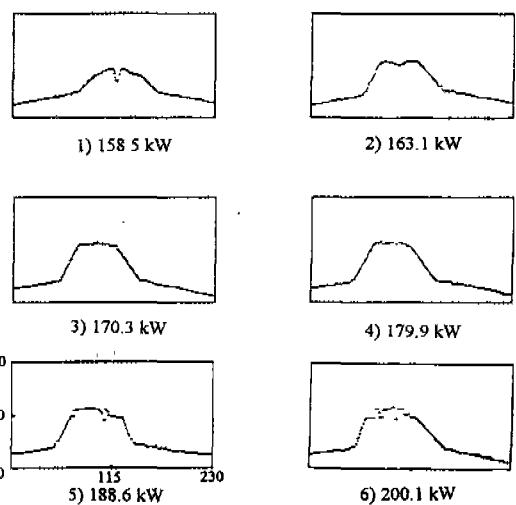


Fig 8 Stripe pattern image(230×100pixels)

는 레이저 빔의 두께와 카메라와 레이저의 각도 오차에 대하여 생길 수 있는 위치 정보의 부정확도를 최소화하기 위해서 수직으로 하였다.⁽¹⁴⁾ 카메라 고정은 용접 비드의 형상을 정확히 측정하기가 힘들어 크기를 알고 있는 물체를 이용하였다. 교정 후 카메라의 분해능은 1화소당 약 0.02mm이었으며, 성형중인 파이프의 형상을 측정한 결과 파이프 지름의 오차가 0.2mm이내에 들었다.

Fig. 8은 파이프 제조 공정 중 측정 장치를 사용하여 얻은 비드의 단면 형상이다. 영상에서 레이저 띠의 검색은 초기 레이저 띠의 위치를 기준으로 하여 비드의 크기와 파이프의 진동으로 인한 비드의 위치 변화를 고려하여 가로 230 화소, 세로 190화소의 창(window)을 사용하였다. 입열량이 많을 때 측정된 비드형상은 비드의 중앙 부분이 많이 오염되어 정확한 측정이 이루어지지 않았다. 이는 고열로부터 카메라 케이블을 보호하기 위하여 사용한 금속 튜브를 통하여 고주파 노이즈가 침투한 것이다.

5.2 비드 형상 분류

신경회로망의 비드 형상 분류 성능을 알아보기 위하여 파이프·제조 공정 중 입열량을 변화시켜 720개의 비드 영상 표본을 수집하였다. 입열량은 전문가의 경험을 바탕으로 파다, 정상, 부족의 3개 클래스(class)로 나누었으며, 수집된 720개의 영상 표본을 앞서 정한 입열량으로 나누었다. 이중 615개의 영상 표본은 신경회로

Table 1 Welding conditions for the experiment

Material	Carbon Steel	
Thickness	4.7 mm	
Size (outer dia.)	48.6 mm	
Welding Power	Small	155.1 kW ~ 169 kW
	Optimal	169 kW ~ 194 kW
	Large	194 kW ~ 214.5 kW

Table 2 Classification results with different number of output nodes

Output node	The number of output node		
node	11	12	13
1	42	36	41
2	58	38	56
3	51	35	53
4	52	67	47
5	33	28	31
6	63	49	**13
7	82	68	53
8	52	40	24
9	41	63	49
10	53	78	52
11	88	57	76
12		56	48
13			72

** : Dead output node

Table 3 Classification results of the training data

Welding Power (kW)	No. of samples	Classification Result												No. of confusion	
		Large				Optimal				Small					
		1	2	3	4	5	6	7	8	9	10	11	12		
Large (194~214)	175	36	38	35	60	5								5	
Optimal (169~194)	186				7	.23	49	68	40					7	
Small (155~169)	254									63	78	57	56	0	
Total success rate		$(1-12/615) \times 100 = 98.05\%$													

Table 4 Classification results of the test data

Welding Power (kW)	No. of samples	Classification Result												No. of confusion	
		Large				Optimal				Small					
		1	2	3	4	5	6	7	8	9	10	11	12		
Large (194~214)	35	2	14	7	9	3								3	
Optimal (169~194)	40				5	15	7	9	4					5	
Small (155~169)	30									8	7	3	12	0	
Total success rate		$(1-8/105) \times 100 = 92.38\%$													

방의 학습으로 사용하고 나머지 105개의 영상은 추후 검증용으로 사용하였다. Table 1은 실험에 사용된 용접 조건을 나타내었다.

신경회로망의 학습에 사용된 영상 표본은 230X190 화소 크기의 영상으로부터 파이프의 중심을 구한 후, 중심을 기준으로 하여 비드의 크기를 고려하여 좌우 90 개의 화소의 높이 정보로 이루어져 있다. 이러한 표본 추출 방법은 비드의 수평 방향의 위치 변화로 인하여 신경회로망의 분류 성능이 달라지는 것을 방지하기 위한 것이다. 영상 표본의 각 화소점의 가로방향은 각 입력노우드와 대응된다.

Table 1은 실험 표본을 사용하여 출력 노우드의 수를 결정하기 위하여 노우드의 수를 변화시켜 학습한 후 각 클래스에 속하는 패턴의 수를 나타낸 것이다. 출력 노우드의 개수가 13개일 때 dead output 노우드가 발생하였으므로 계산량을 줄이며 최대의 분류 성능을 기대할 수 있는 노우드의 수는 12개이다.

Table 1은 학습에 사용한 표본을 분류한 결과이다. 이때 학습에 사용된 시간은 3분정도였다. 1에서 12까지의 클래스 번호는 신경회로망에 의해 분류된 비드의 클래스를 의미하며 각 클래스는 출력 노우드와 일치한다. 학습에 의해 분류된 비드 형상은 전문가의 경험을 토대로 다시 입열량의 기준에 따라 다시 분류할 수 있다. Fig. 9는 학습 후 분류된 클래스의 대표 비드 형상을 나타내고 있다.

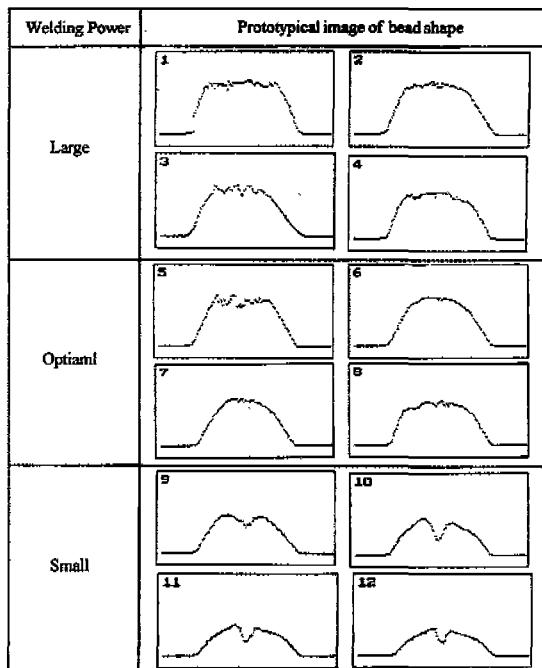


Fig. 9 Prototypical bead shape for classification

입열량이 적을 때의 비드 형상은 정확히 분류를 하였지만, 입열량이 아주 많을 경우 Fig. 2의 (C)와 같이 다양한 비드 형상이 얻어지고, 이중 일부 비드 형상이 입열량이 적정할 경우와 차이가 적어 2%의 분류 오차가 생겼다.

Table 4는 학습에 사용되지 않은 표본에 대한 분류 결과이다. 이때 사용된 영상 표본은 Fig. 8에서와 같이 고주파의 의해 오염된 영상을 포함하고 있다. 마찬가지로 입열량이 아주 많을 경우에 분류 오차가 있었지만, 전체적인 우수한 분류 성능을 보였으며, 고주파 노이즈에 의해 일부 왜곡된 형상에도 우수한 분류 결과를 보였다.

공학적인 측면에서 제안된 알고리즘은 기하학적 특징치를 추출하는 기존 연구와는 달리 비드 형상의 측정에서 학습 분류까지 시간면에서 우수한 결과를 보이며, 복잡한 알고리즘을 사용하지 않아 빠른 처리 속도를 가진다. 실제 비드를 측정하여 분류하는데 0.23초의 시간이 소요되어 실시간 적용이 가능하였다.

6. 결 론

본 연구에서는 고주파 전기 저항 용접기의 입열 자동 제어 장치 개발에 필요한 용접부 비드 형상을 측정하기 위하여 측정 장치를 구성하고, 신경회로망을 사용하여 측정된 비드 형상을 입열량에 따라 분류하는 방법을 제시하였다. 신경회로망을 이용한 비드 형상 분류 방법은 기존의 비드 단면 영상으로부터 기하학적 특징치를 추출한 후 이를 이용하여 분류하는 방법^(5,21)과 비교하면 다음과 같은 장점이 있다.

첫째, 추출된 특징치와 비드 형상과의 관계를 분석하기 위하여 많은 실험이 필요하지 않으므로 쉽고 빠르게 공정에 적용할 수 있다.

둘째, 간단한 구조로 인하여 빠른 처리 속도를 가져 실시간 처리가 가능하다.

셋째, 노이즈에 의한 일부 영상의 왜곡에도 훌륭한 분류 결과를 얻을 수 있다. 본 연구에서 개발된 비드 형상 측정 장치는 고주파 노이즈로 인하여 왜곡된 영상이 종종 얻어지므로 보완이 필요하며, 급한 경사면의 추가 정보를 얻기 위한 다중 레이저를 사용한 측정 장치 개발에 대한 연구가 계속되어야 할 것이다. 본 연구를 입열량의 제어에 적용하기 위해서는 비드의 형상과 용접부의 물리적 성질 및 입열량의 관계를 파악해야 한다. 현재 신경회로망의 학습에 있어 분류 성능을 높이기 위한 클래스의 수를 자동으로 분류하기 위한 기법의 개발이 진행되고 있다.

참고문헌

1. Hisashi Gondo, Hiroyo Haga, Kazuo Aoki and Takeshi Sato, "Welding Mechanisms in High-Frequency Electric Resistance Welding", Nippon Steel technical report No. 14, December 1979.
2. Hiroyo Haga and Nobuo Mizuhashi, "High-Frequency ERW Phenomena and Weld Defect Ratio under High-speed and Large V-convergence angle condition", Transation ISIJ., Vol. 25, 1986.
3. Hichio Saito, Atsushi Siga, Teiichi Enami, Motoaki Itatani and Hiroji Kasahara, "Relation between Current Voltage and

- Power in Oscillator and Load Circuit during HFERW" Transactions ISIJ, Vol. 24, 1984
4. Shigeyuki Sugimura and Hiroo Matsuda, "Welding Technology in Manufacture of Large-Diameter Line Pipe", Nippon Steel Technical report No.20, December 1982.
 5. H. Haga, K. Aoki and T. Sato, "Welding Phenomena and Welding Mechanisms in High Frequency Electric Resistance Welding-1st Report", Nipp steel Technical report, 1986.
 6. Narumi Andou, Hirotaka Chino, Chozaburo Hamamoto, Hiroyoshi Majima and Hiroyo Haga, "A new ERW-SAW Process for Spiral Manufacture", Nippon Steel Technical report, 1986.
 7. Nobuo Watanable, Masaaki Funaki, Sei-etu Sanmiya, Noriyuki Kosuge, Hiroyo Haga and Nobuo Mizuhashi, "An Automatic Power Input Control System in High Frequency Electric Resistance Welding", Nippon steel technical report, 1986.
 8. Norio Tanaka, Toshio Iwasaki, Norio Watanabe and Yasuo Tamura, "High Frequency Induction Welded High-strength Steel Pipe", Nippon Steel Technical report No. 30, July, 1986.
 9. Yutuka Mihara, "A New Automatic Heat Input Control for Production of Electric Resistance Welded Pipe", Transaction ISII Vol. 26, 1986.
 10. Tetsuo Kyogoku, Chiharu Takamadate, Kazuyuki Hotta, Masao Tatsuwaki and Shin Nemoto, "Automatic Welding Control System for Electric-resistance Weld Tube Mill", Sumitomo Technical report, 1983.
 11. Osamu Sugiyama, Chiharu Takamadate and Toshihiro Hikite, "Recent Progress in Automatic Welding Control System for ERW Tube Mill", The Sumitomo search No.49, April 1992
 12. Steven J GORDON, "Real-Time Part Position Sensing", IEEE Transactions on Pattern Analysis and Machine Intelligence Vol. 10. No. 3, May, 1988.
 13. J. Paul, "Active, Optical Range Image Sensors", Machine Vision Application Vol. II pp. 127-152, 1988.
 14. Katsushi Ikeuchi and Takeo Kanade, "Modeling Sensors:Toward Automatic Generation of Object Recognition Program", Computer vision, Graphincs, and Image Processing 48, pp. 65-67, 1989.
 15. Rafael C. Onzalez, Richard E. Woods, "Digital Image Processing", Addison Wesley Publishing Company, 1992.
 16. H. Shapiro, "Computer and Robot Vision", Vol. 1, Addison Wesley Publishing Company, 1992.
 17. D.H Ballard, and C.M. Brown, "Computr Vision", Prentice Hall, 1985.
 18. J. Hertz, A. Krogh, R.G Palmer, "Introduction to the Theory of Neural Computation", Addison-Wesley, 1991.
 19. Yoh-Han Pao, "Adaptive pattern recognition and neural networks", Addison-Wesley Publishing Company, 1989.
 20. Jacek M. Zurada, "Introduction to Artificial Neural Systems", West Publishing Company, 1992.
 21. 김종형, 고국원, 조형석, "강관의 용접 입열 자동 제어 기술 및 장치 개발에 관한 연구", 한국과학기술원, 1차년도 위탁 연구 중간 보고서, 1993.