

# 냉연강판의 표면결합 분류를 위한 신경망 분류기 개발

문창인\*, 최세호\*\*, 주원종#, 김기범\*\*, 김철호\*\*\*

## Development of a Neural Network Classifier for the Classification of Surface Defects of Cold Rolled Strips

Chang In Moon\*, Se Ho Choi\*\*, Won Jong Joo#, Gi Bum Kim\*\* and Cheol Ho Kim\*\*\*

### ABSTRACT

A new neural network classifier is proposed for the automatic real-time surface inspection of high-speed cold steel strips having 11 different types of defects. 46 geometrical and gray-level features are extracted for the defect classification. 3241 samples of Posco's Kwangyang steel factory are used for training and testing the neural network classifier. The developed classifier produces plausible 15% error rate which is much better than 20-30% error rate of human vision inspection adopted in most of domestic steel factories.

**Key Words** : Neural Networks(신경망), Surface Inspection(표면 검사), Steel Strip Defects(강코일 결함), Feature Extraction(특징 추출), Data Normalization(데이터 정규화)

### 1. 서론

최근 산업 발전에 따라 철강제품의 수요 증가와 함께 품질의 고급화에 대한 요구도 점차 증가하고 있다. 특히 가전제품, 자동차 등 최종 소비재의 외장재로 사용되는 냉연강판의 경우 사소한 표면결합이라 할지라도 하자 소송을 초래할 수 있다.

강 코일(steel strip)은 표면의 품질에 따라 5등급(A to E)으로 나누어지는데 통상 가격차는 25~50%까지 이른다. 따라서 결함(defect)의 원인을 미리 찾아서 결함을 줄일 수만 있다면 상당한 손실을 막을 수 있다.

보통 냉연강판의 표면결합검사는 생산라인의 맨 끝단에서 실시하고 있는데, 우리나라 대부분의 철강업체에서는 Fig. 1 과 같이 검사자가 빠른 속도(약 150~800m/min)로 지나가는 인라인(in-line)코일을 상하면을 비추는 거울 앞에 서서 검사한 후 검사자의 감(feeling)에 의해 등급을 결정하는 시스템으로 되어 있다. 이와 같은 시각에 의한 검사방법은 사람마다 동일 결함에 대한 분석이 다를 수 있기 때문에 부정확할 뿐 아니라 결함에 대한 아무런 정보 데이터를 남겨놓지 않아 품질향상을 위한 피드백(feed-back) 자료로 사용할 수 없으며 판매를 위한 품질 보증자료로도 너무 부족하다. 즉

접수일: 2006년 8월 17일; 게재승인일: 2007년 2월 9일

\* 서울산업대학교 산업대학원 메카트로닉스공학과

# 교신저자: 서울산업대학교 기계설계·자동화공학부

E-mail joo@snut.ac.kr Tel. (02) 970-6340

\*\* POSCO 기술연구소 계속연구그룹, 서울산업대학교 기계설계·자동화공학부

\*\*\* 서울산업대학교 산업대학원 메카트로닉스공학과

구입처로부터의 손해 보상청구(claim) 소송이 걸렸을 때 제출할 수 있는 적절한 대응자료(back-up document)를 만들 수가 없다.




Fig. 1 Coil strip line of Union steel

이와 같은 사정에도 불구하고 철강 표면 검사 장비의 자동화가 이루어 지지 않은 이유는 다음과 같다. 첫째는 고속으로 지나가는 철강의 표면을 검사할 때 거의 실시간(real-time)으로 이루어져야 하는데 이를 위한 영상처리 기법의 개발이 용이하지 못했다. 둘째는 대부분의 결함들이 아주 낮은 영상대비(contrast)를 가지고 있기 때문에 결함들만을 배경으로부터 따로 분류하는 알고리즘의 개발이 어려우며, 셋째로는 결함의 종류도 많고 같은 결함이라 할지라도 코일의 상태에 따라 형태와 명암도가 다르기 때문에 특징 추출에 어려움이 발생하며 분류의 정확도가 매우 낮았다.<sup>1,2,3</sup> 또한 실제 개발을 하였다 하더라도 장기간에 걸쳐 현장 친숙화 작업(customizing)이 필요하며 하드웨어와 소프트웨어 모두 지속적인 유지보수와 투자가 필요하다.<sup>1,3</sup> 또한, 현재 세계 철강 검사장비 업체 중 점유율 1 위 회사인 파시텍(Parsytec)사의 장비도 결함검출은 90%정도의 성능을 발휘하지만, 분류능력은 75 ~ 85% 정도에 머무르며 계속적으로 발생하는 새로운 결함을 분류하기 위해서는 수정에 민감한 분류 소프트웨어를 수정하여야 하고 고액의 기술자를 초빙해야 하는 사실도 철강업계에서 선불리 개발을 하지 못하는 이유이기도 하다. 그러나 인건비 절감, 비 인간적인 작업환경 탈퇴, 품질 향상, 고객용 데이터 수립 등 많은 부분을 만족시키기 위해서는 이러한 검사장비의 개발이 매우 요구되는 실정이다.<sup>1,3,4</sup>

본 논문에서는 실시간 결함 검출 및 분류 시스템 구축을 위한 기반 요소기술 확보에 중점을 두고 최적의 결함 데이터를 분류기에 제공하기 위하

여 하드웨어적으로는 최적 조명, 비전기술 및 동기화(synchronization) 등을 연구하였으며 소프트웨어는 고속 전처리 알고리즘에 대해 연구를 하였다. 또한 각 결함의 형태와 색상, 명암도 등을 분석하여 많은 종류의 특징 값을 추출하였으며 특히 본 논문에서 다룰 신경망(neural networks) 분류기<sup>4,6,7,8</sup>를 이용하여 최적의 특징값을 선정하고 분류 성능을 평가하였다.

## 2. 영상획득 및 전처리

현장에서의 강 코일 고속이송 장치를 실험실 상황에 맞게 구성하기 위하여 고속 회전 테이블 장비로 대체하여 제작하였다. 검사장비는 기구부, 제어부, 광학부, 해석 및 소프트웨어로 구성되어 있으며 주요기능은 고속 이송 중인 강 코일의 표면을 실시간으로 결함 이미지를 획득하고 고속 이미지 프로세싱 기법을 사용, 노이즈 제거(filtering), 영역 분할(area segmentation), 이진화(binazation), 특징 추출(feature extraction)을 수행,<sup>3,11,13</sup> 분류를 위해 가장 적합한 특징값들을 추출한 후 신경망 결함 분류기에 의해 결함 종류를 판별을 하는 것이다.<sup>6,7,8</sup>

### 2.1 영상획득

실제 현장에서 철강은 매우 고속으로 이송한다. 고속 이송 물체를 카메라를 이용하여 이미지를 획득을 하게 되면 퍼짐(blurring)현상이 생기게 된다. 이러한 현상은 결함의 여러 정보를 정확하게 분석할 수 없게 한다. 본 논문의 실험장치에서는 이러한 현상을 없애고 깨끗한 이미지 획득을 위하여 Fig. 2 와 같이 파장이 일반 조명보다 긴 적외선(infrared LED)조명과 스트로브스코프(stroboscope)를 사용하였다.<sup>1,3,5</sup>




Fig. 2 Image acquisition system

이 시스템을 이용하여 높은 대비를 가진 영상을 획득하기 위해서는 카메라 노출시간(exposure time) 동안에 스트로브스코프를 사용하여 조명을 터뜨려 영상을 획득해야 한다. 이렇게 수  $\mu s$  의 짧은 노출 시간에 조명신호를 정확하게 일치시키는 과정인 동기화 작업이 필요하다. Fig. 3 은 실험을 통해 결정된 최적의 이미지를 획득하기 위한 소프트웨어와 하드웨어 출력 신호들 사이의 동기화 타이밍 차트(timing chart)이다.

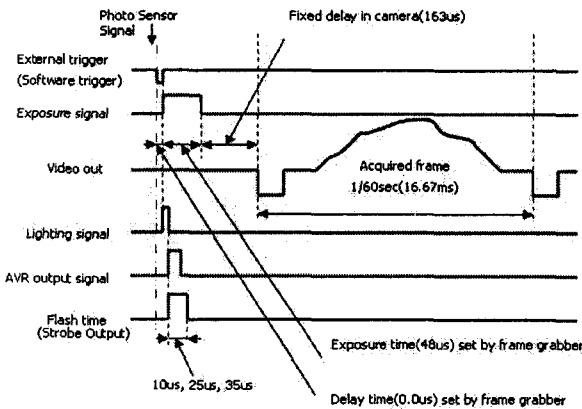


Fig. 3 Synchronization timing chart

강 코일 표면 결함의 종류는 다양해서 카메라의 위치에 따라 잘 검출되는 결함들의 종류가 다르므로 이를 위하여 Fig. 4 와 같이 카메라 두 대를 사용하여 암시야(dark field)와 명시야(bright field) 카메라 위치 모두에서 결함 영상을 획득하였다.




Fig. 4 Cameras of each field

2.2 이미지 전처리

카메라와 조명을 사용하여 철판 표면의 영상을 획득하면 영상은 각종 잡음과 조명의 영향을 포함하게 된다. Fig. 5(a)는 획득된 영상이고 Fig. 5(b)는 이진화된 영상인데 각종 노이즈나 조명영향으로

결함을 추출하기가 매우 어렵게 되어 있다.



Fig. 5 Image with illumination and its binary image

이러한 잡음과 조명의 영향이 존재하는 영상으로부터 결함영역을 추출하기 위해서는 조명과 잡음을 제거하고 흠을 배경과 더욱 명확하게 분리하여 이미지를 향상시키는 이미지 전처리(image preprocessing) 과정이 필요하다.<sup>1, 3, 11, 13</sup>

획득한 영상으로부터 일반적으로 조명의 영향을 제거하기 위해 영상의 백그라운드 노이즈를 복잡한 수식과 방법을 사용하여 정확한 조명의 프로파일을 생성하고 원영상과 차연산을 하지만 이 방법은 시간이 오래 걸리는 단점이 있다.

본 논문에서는 실시간 처리를 위해 결함이 없는 철판이미지를 기준이미지로 하여 획득한 영상과의 차연산을 통하여 조명이 제거된 영상을 얻도록 하였다. 단순히 두 이미지간에 차연산만 하는 것이므로 처리속도가 매우 빠르다. 조명은 시간이 지남에 따라 조금씩 변화하므로 아래의 (1)식에 의해 실시간으로 보정된 평균이미지를 기준이미지로 사용하였다.

$$R_{n+1} = t(R_n + A_{nl} - A_{ns}), \quad R_1 = A_0 \quad (1)$$

$$R_n = \frac{1}{r} \sum_i A_{fi}$$

$R_n$  = n 번째 기준 이미지(n<sup>th</sup> reference image)

$A_n$  = 획득된 이미지(acquired image)

$A_f$  = 무결점 이미지(defect free image)

$A_{nl}$  = 마지막 무결점 이미지

(last defect free image)

$A_{ns}$  = 최초의 무결점 이미지

(oldest defect free image)

$r$  = 이미지의 수(number of images)

$t$  = 조정계수

Fig. 6(a)의 결함이 없는 기준 이미지와 Fig. 5(a)의 원영상을 (2)의 식으로 차연산을 하여 조명이 제거된 Fig. 6(b) 이미지를 얻는다.

$$I(x, y) = |I_{ref}(x, y) - I_{orig}(x, y)| \times \alpha \quad (2)$$




Fig. 6 Reference image without defects and difference image

위의 조명이 제거된 이미지를 가지고 결함영역과 배경을 이치화 시키는 이진화를 한 후 이진화된 결함들을 영역별로 분리(labeling)하여 다음 단계인 특징값을 추출할 수 있도록 준비하였다.

### 3. 결함과 특징 값

#### 3.1 결함 선정

본 논문에서는 냉연공정에서 발생하는 결함들을 분류하고자 냉연제품의 등급에 치명적인 영향을 미치는 11 개의 결함을 선정하였고, 그 결함들의 종류와 발생원인은 아래와 같으며 대표적인 샘플 이미지는 Fig. 7 에 보여진다.

- (a) Hole: Slab 의 심한 내부 크랙, 이물질 부착
- (b) Scab: Slab 손질 불완전 및 Slab 핸들링 불량
- (c) Scale: 산화물질인 규소(si)가 제거되지 않고 냉각수와 응결되어 산화됨으로 생성.
- (d) D-Line: 공정 라인이나 Roll 에 작은 금속 조각이 나 끈적거리는 이물질이 이입 되었을 때 발생
- (e) P-patch: Pickling 공정에서 산화물 조합의 불량이 있을 때 발생
- (f) O-drop: 오일이 표면에 남아 있거나 새는 부분이 있을 때 발생.
- (g) Dirty: Rolling mills 에 작은 결함이나 먼지에 의해 발생
- (h) P-tree: Roll 의 불안정한 속도, 압력에 의해 발생.
- (i) B-hole: 표면 가까이 있는 기포의 미압착 및 대형 개재물에 기인

(j) L-scale: Pickling 과정에서 Scale 을 완전히 제거하지 못하였을 때 발생

(k) P-oil: Pickling 과정에서 주로 발생

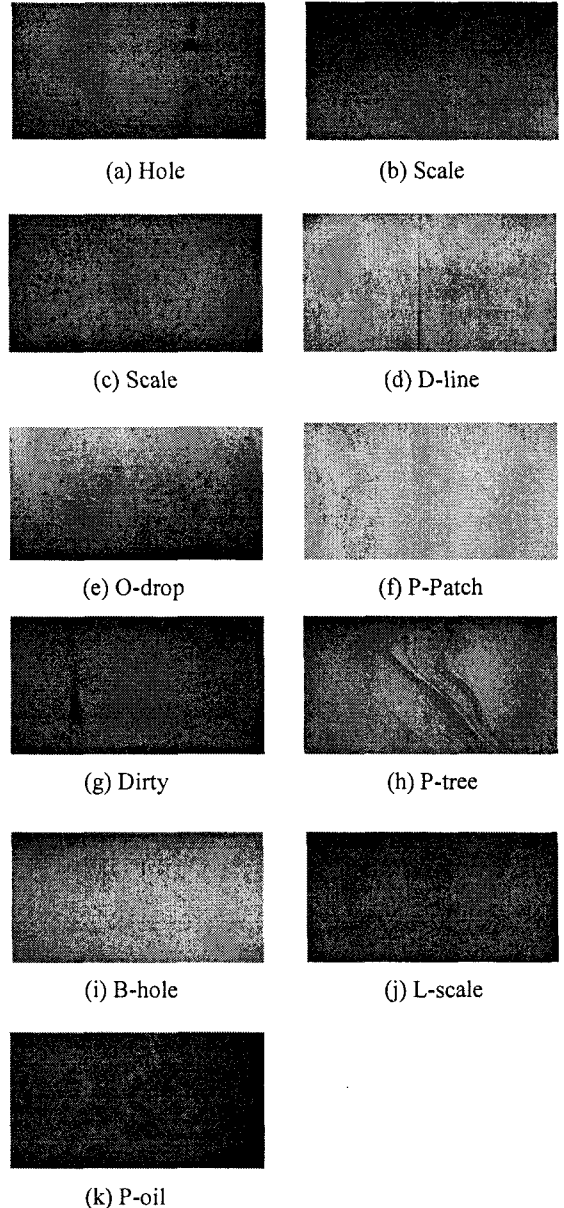


Fig. 7 Eleven defect types on surface of steel strip

#### 3.2 특징값 추출

특징값은 결함의 정보를 정량적으로 나타낼

수 있는 값이다. 전처리와 이진화를 통하여 구분된 결합영역으로부터 일반적으로 아래와 같이 크게 두 가지로 구분된 특징값들의 정보를 추출할 수 있다.

1) 형상 정보 특징(geometry features)

대상체(object)의 윤곽선과 그를 둘러싸는 영역을 기초로 한 물체의 특징들이다. 이진화된 이미지에서 추출할 수 있는 특징데이터들이며 종류는 결합의 면적(area), 면적 중심(center of area), 결합과 전체 영역과의 면적비(area ratio), 최장축의 각도(orientation), 영역의 중심과 질량중심과의 거리(center distance)등의 정보들이 이에 속한다.<sup>3, 11, 13</sup>

2) 명암도 특징(gray features)

대상체와 배경의 명암 값을 기초로 하는 특징값들이며, 관심영역(Region of Interest: ROI)영역의 명암 값과 히스토그램을 사용하여 추출할 수 있는 특징 데이터들이다. 종류는 평균(mean), 표준편차(standard deviation), 휨(skew), 엔트로피(entropy), 대비(contras) 등이 있다.<sup>3, 11, 13</sup>

위의 방법으로 추출된 결합의 특징 정보를 이용하여 결합의 분류를 하게된다. 이때 결합 분류기를 설계하는 데 있어 유한한 샘플을 사용하는 홈 분류기를 설계할 경우 초기에는 특징값의 개수가 증가함에 따라서 분류기의 오분류가 감소하다가 어느 점에서 정점에 이르고 이후 특징 데이터 개수가 더 증가할수록 오분류가 다시 증가한다(peaking 현상).<sup>12, 15</sup> 또한 특징 데이터 수가 증가함에 따라 요구되는 결합의 샘플 숫자가 기하급수적으로 증가하기 때문에 적절한 특징 데이터 개수의 선택이 매우 중요하다.

본 논문에서는 포스코의 냉연공정에서 발생하는 결합들에서 추출한 340 개의 특징값을 통계적인 기법을 이용, 이들간의 상관관계(correlation)을 분석하여 각각의 특징 값들이 다른 특징 값과 가지는 상관관계수가 높은 값들은 제외하는 방법으로 총 46 개의 특징값, 형상 정보 특징값 33 개, 명암 정보 특징값 13 개를 추출하였다. 추출된 46 개의 특징값들은 Table 1 과 같다.

Table 1 List of extracted 46 features

Geometry features		Gray features
A	I min	Maxgv
W_sbox	I rat	Mingv
H_sbox	E_rat	Gvr

R_sbox	E A	Meagv
A_sbox	Im1	Medgv
A_r	Im2	Var
CD	Im3	Curt
O	Im4	Skew
R_max	Im5	Entr
R_min	Im6	Mgvgb
R_rat	Im7	Mgvdif
D_yx	A1 A	MEAN GV
D_y	A1 Ar	DEV GUV
D_xy	A2 A	
D_max	A2 Ar	
D_min	A3 A	
D_rat		

4. 신경망 분류기

다양한 형태와 명암도를 가지고 있는 강 코일 표면 결합의 종류를 컴퓨터에서 분류, 인식하기 위하여 패턴인식에 많이 쓰이는 신경망을 적용하였다. 신경망은 입력 데이터와 출력 데이터가 정해지면 엔지니어가 중간 계산 과정을 모르더라도 학습에 의해 연결 가중치(weighting factor)가 자동으로 조정되기 때문에 비전문가라도 현장에서 쉽게 접근하여 유지보수를 할 수 있다. 신경망이 다른 분류기법중 하나인 룰 베이스의 기법(expert system)보다 우수한 장점은 튜닝(tuning)이 자동적으로 이루어지는데 있다. 철강 표면 결합은 종류가 다양하고 같은 종류의 결합이라도 크기와 명암도가 다양하여 계속적인 튜닝 작업이 필요하므로 손쉽게 특징값을 추가하거나 제거할 수 있어야 하며, 가중치의 값이 학습을 통해서 자동으로 조절되는 신경망 분류기가 적합하다.<sup>2, 7, 10, 12</sup>

4.1 신경망 분류기의 구조

본 논문에서 사용된 신경망의 구조는 일반적으로 널리 쓰이는 Fig. 8 의 다층(multi-layer) 신경망의 구조로 하였으며, 오류역전파(error back-propagation) 알고리즘을 사용하여 신경망을 학습시켰다. 입력층(input layer) 노드(node)의 입력값은 선정된 46 개의 특징값을 사용하였고, 출력층(output layer)의 출력값은 11 개의 결합의 종류가 선별되도록 하였다. 신경망의 성능에 가장 큰 영향을 미치는 은닉층(hidden layer)의 노드 개수는 여러 번의 실험을 통하여 분류율의 성능에 가장 적합한 개수를 찾아내었다.




Fig. 8 Structure of neural networks

### 5. 실험 및 결과

신경망 분류기의 학습과 분류율 실험을 위해서는 많은 양의 결함 데이터 이미지가 필요하다. 본 논문에 사용된 실험 장치에서는 다양한 결함 이미지 데이터를 얻을 수 없는 관계로 포스코 광양공장의 냉연공정에서 발생하는 대표적인 결함 11 가지를 얻어서 신경망의 학습과 분류율 실험에 사용하였다. 그 종류와 개수는 Hole(148), Scab(584), Scale(12), D-line(102), P-patch(199), Oil drop(52), Dirty(253), P-tree(285), B-hole(57), L-scale(11), P-oil(1538) 이다. 총 3241 개에 대한 실제 결함들의 특징 데이터를 가지고 신경망 분류기의 학습과 분류 성능을 실험하였다.

#### 5.1 결함 샘플 데이터의 재구성

현장에서 발생하는 결함의 빈도수는 결함별로 매우 차이가 많다. 예를 들면 Scale 이 12 번 발생할 때 Scab 는 584 번 발생하였다. 신경망을 학습시킬 때 신경망의 특성상 빈도수 및 각각의 값의 크기가 아주 큰 영향을 미친다. 즉, 많은 샘플 데이터가 학습에 사용되거나 하나의 값이 특별하게 크거나 작다면 신경망의 가중치의 값이 특정 값들에 큰 영향을 받게 된다. 이러한 현상을 없애기 위하여 각 샘플의 수를 통계적인 기법을 사용하여 결함 샘플 데이터의 개수를 적절하게 조절하고, 특징값들을 정규화(normalizing) 하였다.

각 결함당 기준 샘플수는 400 개로 설정하였으며 기준보다 샘플수가 적은 결함의 샘플은 원 샘플 데이터에 노이즈를 첨가하여 증가시켰고, 많은 결함의 샘플은 랜덤하게 선택하여 적정개수로 재구성하였다. 데이터의 개수를 재구성한 후의 결과는 Table 2 와 같다.

Table 2 Regulated sample data

Defect name	Samples Num.	Regulated
Hole	148	400
Scab	584	400
Scale	12	396
D-line	102	408
P-patch	199	398
O-drop	52	400
Dirty	253	400
P-tree	285	400
B-hole	57	399
L-scale	11	400
P-oil	1538	400
Total	3241	4401

#### 5.2 샘플 데이터의 정규화

샘플 결함들은 타입별로 특징값들의 크기가 큰 차이를 보인다. 특징값들의 차이가 너무 크면 큰 특징값들이 분류기에 큰 영향을 미쳐서 분류기의 성능이 떨어지게 된다. 이런 특성을 방지하기 위하여 특징값의 분포는 그대로 유지하면서 일정 범위 안으로 특징값의 크기를 조정하여야 한다. 즉 데이터를 정규화하는 과정이 필요하다. 본 논문에서는 각 특징별 표준편차(standard deviation)를 이용하여 특징값들을 정규화하였다. 임의의 특징값에 대한 표준편차 S 는 (3)의 식으로 구한다.

$$s = \sqrt{\frac{1}{N} \sum_{i=1}^n (m - f_i)^2} \quad (3)$$

$m$  은 특징 데이터들의 평균값이고  $f_i$  은 원 특징 데이터( $f_1 \sim f_n$ ),  $N$  은 특징값의 전체 개수이다. (3)의 식으로 구한 표준편차값을 이용하여 각 특징데이터들을 (4)식을 이용, 정규화하였다.

$$f_i' = (m - f_i) / s \quad (4)$$

여기서  $f_i' \sim f_n'$ 은 정규화된 특징 데이터들이다.

### 5.3 신경망 분류기 학습

신경망 학습을 위하여 조정된 샘플 데이터를 랜덤 함수를 사용하여 훈련용 샘플 데이터와 테스트용 샘플 데이터로 반반씩 나누었으며 그 결과는 Table 3 과 같다. 훈련용 샘플 데이터를 사용하여 신경망을 학습하였다.

Table 3 Separated sample data

Defect name	Train set	Test set
Hole	195	205
Scab	212	188
Scale	206	190
D-line	200	208
P-patch	202	196
O-drop	187	213
Dirty	195	205
P-tree	203	197
B-hole	210	189
L-scale	193	207
P-oil	197	203
Total	2200	2201

학습방법으로는 형상 인식 기법 중 널리 사용하는 오류 역전파 알고리즘을 이용하였다.<sup>6, 7, 8, 10, 12</sup> 신경망의 훈련횟수(iteration)를 오래 반복하는 것이 신경망의 성능을 높이는 것은 아니므로, 본 논문에서는 가장 분류 결과가 좋은 가중치값을 찾아 내기 위하여 신경망 훈련중에 분류 결과를 비교하여서 가장 분류 성능이 좋을 때의 연결 가중치값을 자동으로 저장하여 최종적으로 저장된 연결 가중치값을 사용하여 분류실험을 하였다.

### 5.4 분류 실험 결과

다층 신경망의 분류율 성능은 은닉층의 노드 개수에 따라 분류 결과의 차이가 아주 크다.<sup>6, 7, 8, 12</sup> 본 논문에서는 19 가지의 은닉층의 노드 개수를 실험하여 가장 분류 결과가 좋은 은닉층의 노드 개수를 찾아내었으며 그 결과는 Table 4 와 같다.

Table 4 Error rates based on number of hidden nodes

Hidden node	Error rate	Hidden node	Error rate
13	13.6756	23	38.8459
14	16.6288	24	90.6861
15	20.9905	25	90.6861
16	12.90323	26	90.6861
17	28.9868	27	90.6861
18	35.8473	28	90.6861
19	36.3471	29	90.6861
20	36.1199	30	90.6861
21	36.1199	31	90.6861
22	90.6860		

Table 4 에서 보면 16 개의 은닉 노드를 가지고 있는 신경망의 구조에서 분류 결과가 가장 좋을 것을 알 수 있다. 이 신경망을 이용하여 학습을 시킨 후 테스트용 샘플을 가지고 수행한 실제 테스트의 결과는 Table 5 와 같다.

Table 5 Result errors of neural network classifier

Defect	Sample No.	Fail No.	Error (%)
Hole	205	6	2.926829
Scab	188	29	15.42553
Scale	190	9	4.736842
D-line	208	9	4.326923
P-patch	196	12	6.122449
O-drop	213	35	16.43192
Dirty	205	79	38.53659
P-tree	197	24	12.18274
B-hole	189	44	23.28042
L-scale	207	21	10.14493
P-oil	203	67	33.00493
Total	2201	335	15.22035

Table 5 에서 전체 평균 결함 분류 에러율은 약 15%로 분류되었으며 이는 대부분의 철강업계에서 수행하는 인간 시각에 의한 결함검사 분류 에러율(20~30%) 보다 우수한 분류율을 보이고 있다. 결함 에러율이 높은 Dirty 와 P-oil 은 현재 선정된 특징값의 범위가 다른 결함의 범위와 많이 중첩 되는 결함으로 이들만이 가지고 있는 특별한 특징값들을 추가로 찾아낸다면 더 좋은 분류율을 기대할

수 있다.

## 6. 결론

본 연구에서는 강 코일의 표면 결함 검사 자동화를 위한 하드웨어 제작기술 및 소프트웨어 알고리즘, 신경망 분류기에 대하여 연구하였다.

하드웨어적으로는 고속이송 장비에서 깨끗한 이미지를 얻기 위한 각 카메라와 조명의 동기화를 하드웨어 제어프로세서인 마이크로 컨트롤러와 컴퓨터의 인터페이스로 구현하였다.

소프트웨어 측면에서는 균일하지 않은 백그라운드 노이즈 제거, 이진화, 결함 검출 및 특징 추출 등의 알고리즘을 연구하였다. 분류기의 성능을 높이기 위한 특징 데이터의 선정과 특징 데이터의 개수를 결정 짓는 다양한 통계적인 방법들을 시도하였으며, 이를 제안된 신경망 분류기에 적용하기 위한 연구를 하였다. 선정된 특징 데이터를 제안된 신경망에 적용시켜 실제 분류 테스트를 수행하였으며 제안된 신경망 분류기는 실제 인간의 결함 분류율 75%보다 뛰어난 결함 분류율 85%를 보였다. 이를 실제 현장에 적용할 경우 아주 큰 효과를 가져다 줄 것으로 기대된다.

## 후 기

이 논문은 한국 산업 기술재단(KOTEF)의 지역 혁신 인력 양성 사업 연구비 지원에 의하여 연구되었습니다.

## 참고문헌

1. Song, S. J., Kim, H. J., Choi, S. H. and Lee, J. H., "Classification of Surface Defects on Cold Rolled Strips by Probabilistic Neural Networks," The Korean Society for Nondestructive Testing, Vol. 17, No. 3, pp. 162-173, 1997.
2. Kim, K. M., Park, G. T., Park, J. J., Lee, J. H., Jung, J. Y. and Lee, J. K., "Development of Surface Defect Inspection Algorithms for Cold Mill Strip," Journal of Control Automation and System Engineering, Vol. 3, No. 2, pp. 179-186, 1997.
3. Lee, S. W., Park, W. J., Joo, J. I., Jung, J. Y., Lee, J. H. and Park, C. H., "Development of Surface Inspection

- System for #1 PCM," Technical Research Lab. POSCO, 2000.
4. Treiber, F., "On-line Automatic Defect Detection and Surface Roughness Measurement of Steel Strip," Iron and Steel Engineer, pp. 26-33, 1989.
5. Kim, C. H., Choi, S. H., Joo, W. J. and Kim, G. B., "Classification of Surface Defect on Steel Strip by KNN Classifier," Journal of the Korean Society for Precision Engineering, Vol. 23, No. 8, pp. 80-88 2006.
6. Mehrotra, K., Mohan, C. K. and Ranka, S., "Elements of Artificial neural networks," A Brand Book, pp. 65-109, 1997.
7. Freeman, J. A. and Skapura, D. M., "Neural Networks Algorithms, Applications, and Programming Techniques," Addison-Wesley, pp. 1-545, 1992.
8. Bishop, C. M., "Neural Networks for Pattern Recognition," Oxford University Press, pp. 77-163, 1995.
9. Rao, V. and Rao, H., "C++ Neural Networks and Fuzzy Logic Second edition," MIS, pp. 1-540, 1995.
10. Haralick, R., Shaumugam, K. and Dinstein, I., "Textural Features for image Classification," IEEE Trans. Systems and Cybernetics, Vol. 3, No. 6, pp. 53-58, 1973.
11. Rumelhart, D. E., Hinton, G. E. and Williams, R. J., "Learning Internal Representations by Error Propagation," MIT Press Cambridge, Vol. 1, pp. 318-362, 1986.
12. Gonzalez, R. C. and Woods, R. E., "Digital Image Processing," Addison-Wesley, pp. 50-141, 1992.
13. Gose, E., Honsonbaugh, R. and Jost, S., "Pattern Recognition and Image Analysis," Prentice Hall, pp. 1-483, 1996.
14. Umbaugh, S. E., "Digital Image Analysis and Processing," CRC Press, pp. 130-150, 2005.