

# 광 강도차를 이용한 냉연강판 표면결함 검출

## Surface Flaw Detection of Cold-Rolled Steel Strips using Intensity Gradient

장성열 · 공성곤

Sung-Yeoul Jang and Seong-Gon Kong

승실대학교 전기공학과

### 요 약

이 논문에서는 영상처리 기법과 신경회로망 분류기를 이용하여 냉연강판의 표면에 나타나는 결함을 검출하는 기법을 제안한다. 냉연강판 표면의 입력영상을 웨이블렛 변환하여 영상신호 데이터량을 감소시키고, 영상신호의 저주파수 영역에 해당하는 부분영상으로부터 구한 co-occurrence 행렬을 이용하여 주된 특징들을 추출한 후 신경회로망 분류기를 이용하여 표면결함을 분류하는 과정을 밟는다. 현장에서 직접 입수한 실제 냉연강판 표면결함 영상에 대하여 결함의 검출 및 분류기법을 제시하고, 실험을 통해 기존의 벡터양자화 기법과 비교하여 우수한 성능을 보임을 입증하였다.

### ABSTRACT

This paper presents a method of detecting surface flaw of cold-rolled steel plate using image processing technique and a neural network classifier. The amount of steel plate surface image data is reduced by the wavelet transform. Features are extracted from the co-occurrence matrix of the partial image corresponding to the low-frequency region, and a MLP neural network classifies into predetermined surface flaw categories. Simulations show the neural network classifier outperforms conventional vector quantization method.

### 1. 서 론

생산제품의 텍스쳐(texture) 분석으로 표면에 발생하는 결함을 검출하는 과정은 품질검사 과정에 있어서 매우 중요한 부분으로 요구된다. 일반적으로 오류검출 제어 시스템은 폭 1.6~2.0 m, 그리고 8~20 m/min의 속도로서 숙련된 기술자의 경험에 의존하는 실정이다. 이러한 방법은 제품에 측정 흔적이 남는다든지 온라인 감시에 적용이 어렵다는 문제점을 가지고 있으므로 새로운 방법에 의한 실시간 구현 방법들이 절실히 요구되고 있다[1,2]. 컴퓨터 비전을 이용한 검사방법은 여러 분야에서 시도되었으며, 많은 성과를 가져왔다[3-5]. 특히 비전 시스템을 이용한 냉연강판 표면에 대한 관찰은 주변환경에 대한 민감한 반응과 관찰 영역이 좁아진다는 단점으로 인해 실시간 계측에 많은 어려움이 따른다[6]. 강판의 표면결함 검사[7-10]는 철강 산업에서 매우 중요한 역할을 하는데, 특히 고급 외장재료로 널리 사용되는 냉연강판(cold-rolled steel strip)의 표면결함 유무의 검출 및 결함종류 판별은 강판제품의 품질에 직접적인 영향을 줄뿐만 아니라 생산라인의 이상 유무와 이상부위를 점검하는 중요한 단서가 되므로 필수적인 과정이다.

본 연구에서는 영상처리기술을 이용하여 냉연강판 표면 결함의 특징을 추출하고 신경회로망 분류기로 효과적으로 분류하여 냉연강판 표면결함 자동검사 시스템을 구축하고자 한다. 제안하는 알고리즘은 표면결함에 대한 텍스쳐 정보를 추출하고, 이를 변화에 따른 경향을 분석하여 온라인 측정에 적용할 수 있는 시스템을 구축하고자 한다. 추출된 텍스쳐 정보는 신경회로망 분류기를 이용하여 폐단 인식과정을 거친다 [11,12]. 그림 1은 광 강도차에 의한 냉연강판 표면결함 검출 알고리즘의 구성도를 나타낸다.

신경회로망을 이용한 냉연강판 표면결함의 전체 블록선도로서 CCD 카메라를 이용하여 받아들인 입력 영상에 대하여 전처리 과정과 특징 추출과정을 거친

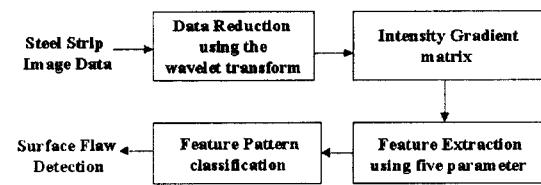


그림 1. 강판 표면결함 검출 알고리즘  
Fig. 1. Steel strip surface flaw inspection algorithm

후, 추출된 최적의 특징들을 패턴분류에 좋은 성능을 나타내는 신경회로망을 이용한 적응분류기를 거치게 된다. 이 분류기를 통하여 최종적인 결과로서 결합의 유/무를 구분하고 발견된 결합에 대하여 그 결합의 종류까지도 판별함으로써 세분화된 결과를 얻을 수 있다. 이를 통하여 궁극적으로 고속으로 생산되는 냉연강판의 표면결함 패턴의 유/무와 종류까지도 판별할 수 있는 분류기를 구현하는 것을 연구목표로 한다.

웨이블렛 변환을 이용하여 영상정보의 손실을 최대한 줄이면서 입력영상의 저주파수 특징성분만을 추출하였고, 광 강도차를 이용하여 생성한 co-occurrence 행렬을 통하여 특징을 추출하였다. 텍스쳐 정보에 영향을 가지는 몇 가지 특징을 알아보고, 구성하고자 하는 신경회로망의 학습을 위한 특징 벡터를 추출하게 된다. 결합을 분류하는 분류기로는 MLP(Multilayer Perceptron) 신경회로망을 이용하였다. 몇 가지 냉연강판 표면결함 데이터를 이용하여 분류실험을 수행하고 결과를 벡터양자화 알고리즘과 비교하였다.

## 2. 웨이블렛 변환을 이용한 특징 영상 재구성

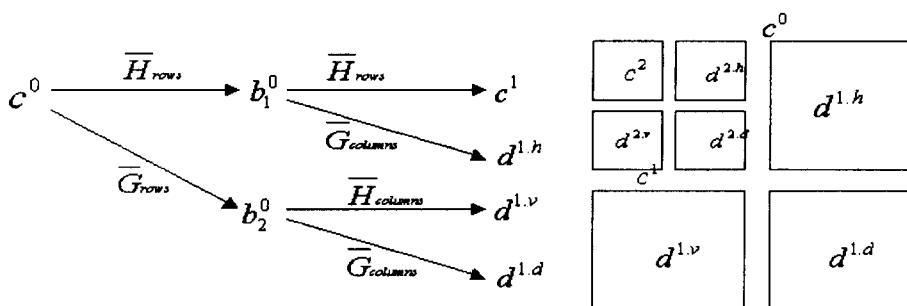
결합 영상은 CCD 행렬 카메라와 영상데이터 수집 장치(frame grabber)를 통하여  $512 \times 512$  해상도의 256 gray-scale로 영상화 한 것이다. 이들 영상을 가지고 결합분류를 위한 데이터 집합을 구성하였는데  $512 \times 512$  영상으로부터  $64 \times 64$  영상을 기본단위로 하여 결합 집합을 재구성하였다. 영상의 크기를 이와 같이 잡은 이유는 결합의 종류에 따라 넓은 면적과 작은 면적의 결합의 분포에 대해 최소한의 크기로서 영상데이터 처리시간을 줄이기 위하여 재구성한 것이다. 재구성 방법으로 사용한 웨이블렛 변환은 시간

에 따라 통계적인 성격이 변하지 않는 정상신호에 대한 분석은 Fourier변환을 이용하면 쉽게 주파수 성분을 얻을 수 있으나, 전체 신호 영역에 대한 적분이 행해지므로 국부적인 특성을 만족할 수 없다. 따라서, 시각에 따라 통계적인 성질이 변화하는 비정상(non-stationary) 신호의 경우 Fourier변환을 사용하면 주파수 성분이 전체적으로 퍼져 정확한 결과를 얻을 수 없게 되므로, 비정상 신호의 경우에는 그 신호가 시변스펙트럼을 갖기 때문에, 짧은 시간동안을 일정한 크기의 window로 제한, 정상적인 신호로 가정하여 분석하는 Short-time Fourier Transform(STFT)이 행하였다. 그러나, 이 변환은 시간 해상도와 주파수 해상도가 항상 일정해 신호 해석상 시간 해상도와 주파수 해상도를 동시에 개선시킬 수 없다는 단점을 지닌다. 이러한 STFT에서의 시간, 주파수 해상도의 한계를 극복하기 위해 고주파수 영역에서는 시간 해상도가, 그리고 저주파수 영역에서는 주파수 해상도가 좋아지도록 하여 신호처리에서 시간과 주파수를 동시에 처리가 가능하도록 하는 웨이블렛 변환을 사용하였다.

$$DWT_x(m, n) = \sum_k x(k) \psi_{m,n}(k) \quad (1)$$

$$\psi_{m,n}(k) = a_0^{-\frac{m}{2}} \psi\left(\frac{k - nb_0 a_0^m}{a_0^m}\right) \quad (2)$$

식 (1)은 이산시간 신호  $x(n)$ 에 대한 이산 웨이블렛 변환을 나타내는 일반식이다. 식 (2)에서  $\psi(k)$ 는 원형 웨이블렛이며 scale과 translation을 나타내는  $m$ 과  $n$ 은  $a_0$ 와  $b_0$ 에 따라 팽창과 이동하는 특징이 있다. 여기서는 주어진  $800 \times 600$  크기의 영상에 대하여 다중 분해기법으로서  $64 \times 64$ 의 크기를 가지는 저주파의 성분들로서 재구성하여 이 결과로서 특징추출을 위한 입력으로 사용하였다.



(a) 2-D wavelet transform of tree structure    (b) Concept of 2-D wavelet transform

그림 2. 2-D 웨이블렛 변환의 구조  
Fig. 2. Structure of 2-D Wavelet transform

그림 2는 2차원 영상에 대해 방향성을 가진 연산을 취함으로서 2차원 정규 직교 웨이블렛을 변환하는 과정이다. High-Pass 필터  $\bar{G}$ 와 Low-Pass 필터  $\bar{H}$ 를 통과한 입력 영상신호는 decimation을 거쳐 웨이블렛 변환 전후의 sample 수를 같게 하는 과정을 거친다.  $\bar{G}$ 를 통과한 신호는 고주파 성분의 신호로 웨이블렛 계수가 되고,  $\bar{H}$ 를 통과한 신호는 저주파 신호 성분으로 다음 웨이블렛 변환 단위 구조의 입력으로 사용된다.

웨이블렛을 이용하여 원 영상을 그대로 특징 추출부에 적용했을 경우와 웨이블렛을 적용하여 특징을 추출한 결과를 비교한 결과 웨이블렛을 적용하여 영상의 크기를 재구성한 결과가 시간적으로 약 3배의 처리시간 감소를 나타냈으며, 이러한 효율적인 결과를 토대로 웨이블렛 변환법을 이용한 알고리즘을 구성하였다.

### 3. 흄 분류를 위한 특징추출

결합 분류를 위한 특징 추출은 일반적으로 패턴인식 분야의 요구조건을 만족해야 하지만, 결합 분류의 특성상 다음의 조건을 만족하는 특징을 추출하였다. 우선 추출된 특징은 이동불변(translation invariant) 해야 한다. 결합의 특성상 회전에 의해 결합의 종류에 영향을 받으므로 회전불변(rotation invariant)할 필요는 없다. 크기에 관한 특징의 경우 일반적인 검사 시스템에서는 결합의 크기 자체도 하나의 중요한 특징이 되므로 크기 불변(scale invariant)<sup>[1]</sup> 성질을 만족할 필요도 없다. 제안하는 분석적 방법은 확률 통계적(statistics probability)<sup>[2]</sup> 방법이다. 이 기법은 특징을 추출하고자하는 텍스쳐의 성질이 가지는 고유한 정도를 이용하는 것으로, 서로 이웃한 픽셀들의 광 강도차(intensity gradient)의 빈도수를 조사함으로서 정량화하는 과정이다.

이 통계적 방법은 일반적인 영상 신호와 잡음이 섞인 영상 신호 데이터에서 잡음이 섞인 영상신호들을 통계적으로 제거하고 원하고자 하는 신호의 특성을 파악하는 공정을 수행하기 위해 통계적인 특성을 찾는 것이다. 이러한 통계적인 정보를 이용하여 자기상관성, 엔트로피, 그리고 역 모멘트, 에너지, 2차 각 모멘트와 같은 파라미터를 이용할 수 있다. 예를 들어, 광 강도차가 많이 나타나는 부분에서는 대상과 주위와의 차이가 동일한 픽셀 쌍이 많을 것이고, 그렇지 않은 곳에서는 동일 픽셀 쌍이 적을 것이다. 기준 픽셀과의 광 강도차를 나타내는 연산자로서  $d_{mn}$ 은 한 픽셀에 대하여 주위 8방향에 위치한 같은 레벨을 가지는 픽셀

수의 정도를 나타낸다. 또한 이 특성연산자는 각 모서리에서 부분에서 연산의 형평성을 고려하기 위하여 symmetric이라고 가정한 후 연산을 하였다. 인접한 픽셀과의 광 강도차를 나타내는 연산자로서 한 픽셀에 대하여 0도, 45도, 90도, 그리고 135도 각도에 위치한 레벨정도의 유사성을 확인하여 각 픽셀의 광 강도차를 나타내는 광 강도차 행렬 D를 구한다.

$$D = \begin{bmatrix} d_{11} & d_{12} & \dots & d_{1N} \\ d_{21} & d_{22} & \dots & d_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ d_{N1} & \dots & \dots & d_{NN} \end{bmatrix} \quad (3)$$

각 요소  $d_{mn}$ 는 그레이 레벨(gray level)을 가지는 픽셀( $m, n$ )에서 위치연산자에 의해 거리  $P$ 만큼 떨어진 위치에서 동일한 레벨을 가지는 픽셀쌍의 빈도수를 나타내는  $N \times N$  행렬이다. 광 강도차 확률행렬 P는 다음과 같이 구한다. 확률 요소  $p_{ij}$ 는 각 픽셀 쌍의 비교횟수가 발생할 수 있는 총합으로 정규화한 것으로, 행렬에 속하는 각각의 발생 요소들을 전체 발생횟수로 나눈 것이다. 확률요소  $p_{mn}$ 를 이용하여 텍스쳐 특징을 추출할 수 있다.

$$P = \begin{bmatrix} p_{11} & p_{12} & \dots & p_{1N} \\ p_{21} & p_{22} & \dots & p_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ p_{N1} & \dots & \dots & p_{NN} \end{bmatrix} \quad (4)$$

$$p_{mn} = d_{mn} / \sum_{i=1}^N \sum_{j=1}^N d_{ij} \quad (5)$$

### 4. 텍스쳐 정보를 얻기 위한 파라미터

#### 4.1 엔트로피

엔트로피는 그레이레벨 영상분포의 랜덤한 변화를 나타내며 0에서  $\log_2 n$  사이의 범위를 가진다. 이 수치는 확률분포 행렬  $P_{mn}$ 에서 영상이 가지는 그레이레벨의 차이가 동일한 경우 가장 큰 값을 갖는다.

$$P_{ent} = - \sum_{m=1}^N \sum_{n=1}^N p_{mn} \log_2 p_{mn} \quad (6)$$

#### 4.2 역 모멘트(Inverse difference moment)

이 값은 확률분포 행렬 각 요소들의 분산 정도 즉, 명암의 차이를 나타낸다. 곧, 영상의 픽셀에서 가장

큰 명암의 차이를 나타내는 곳에서 가장 작은 값을 갖는다.

$$P_{inv} = \sum_{m=1}^N \sum_{n=1}^N \frac{p_{mn}}{1 + (m - n)^2} \quad (7)$$

#### 4.3 에너지

이 값은 행렬의 요소들이 분포되어 있는 정도를 나타내며, 영상의 명암도 대비를 측정하는데 이용할 수 있다. 그러므로 높은 명암대비를 갖는 영상에서는 큰 값을 나타내며, 행렬의  $p_{mn}$ 의 값이 가장 높은 값이 주 대각선 주위에 있을 때 가장 적게 관계한다.

$$P_{eng} = \sum_{m=1}^N \sum_{n=1}^N (m - n)^2 p_{mn} \quad (8)$$

#### 4.4 최대확률(Maximum probability)

이 값은 영상의 그레이 레벨 분포에 대한 응답성을 나타내며 확률분포 행렬에서 가장 큰 특징을 나타내는 곳에서 큰 값을 가진다.

$$P_{\max} = \max(p_{mn}) \quad (9)$$

### 5. 신경회로망 분류기 구성

위에서 제안한 파라미터들을 사용해 구성한 신경회로망 분류기는 4개의 입력과 10개의 중간층 그리고, 9개의 출력을 갖도록 구성하였다. MLP의 학습률은 0.01, 모멘텀은 0.85로 설정하였고, 4가지 특징(엔트로피, 역모멘트, 에너지, 최대확률)을 가지는 입력벡터로서 636개의 흄 데이터를 사용하였다. 사용한 신경회로망은 단일 중간층으로 구성된 전방향 다층 신경회로망을 사용하였으며, 오차역전파(backpropagation) 알고리즘으로 학습하였다. 최대 epoch는 10,000이나 허용오차(MSE=0.001)에 도달하면 학습을 중지하였고 분

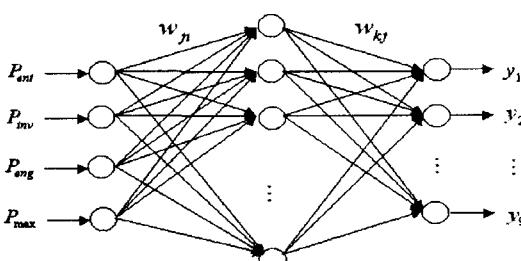


그림 3. MLP 신경망 분류기의 구조

Fig. 3. Structure of MLP neural network classifier

류결과는 10번 실험결과의 평균치를 사용하였다. 그림 3은 신경회로망 분류기의 구조를 나타낸다.

### 6. 시뮬레이션 및 결과

영상 데이터로부터 결함의 종류를 판별해 내는 것은 과정은 영상 취득부와 데이터 처리부로 구성되며, 데이터 처리부는 전처리, 중간처리, 상위처리로 나눌 수 있다. 전처리부는 필터링등을 이용하여 영상취득부에서 발생하는 잡음 등에 대해 보상을 해 주는 단계이다. 중간 처리부는 전처리부에서 얻은 데이터로부터 패턴인식에 필요한 각종 특징들을 추출하는 부분이다. 이 단계에서는 패턴을 인식하기 위해 주어진 결함 데이터의 어떤 부분이 실제의 결함 영역에 해당하는지를 판단하여 그 부분을 영역분할하고, 이로부터 결함의 분류에 필요한 각종 특징들을 추출해 내는 작업을 하게 된다. 여기에서 추출한 특징의 종류가 다음의 상위처리에서 얼마나 잘 분류해 낼 수 있는지에 큰 영향을 미치게 되므로, 어떤 특징을 추출해야 할지를 잘 선택해야 한다.

실험에 사용한 데이터는 Slip, Black line, Roll, Hole, Scale, Fork, Heat, Dirty, 그리고 Scratch의 9 가지 결함으로서 각각의 특징을 간단히 기술하면 다음과 같다. Slip mark는 Strip 사이의 마찰, 두 roll의 속도차로 인한 장력 불균일로 발생하며, Black line mark는 특수한 강에 나타나는 선상결함으로 압연 방향에 직선상으로 길게 나타난다. Roll mark는 부정형의 결함으로 roll에 이물이 부착되어 요철상으로 발생하는 점상 결함이다. Hole mark는 Scale, 이중판 등이 심한 경우 앞면에 의해 구멍이 뚫리거나 압연시 발생한다. Scale mark는 크게 선 형태의 것과 pit 형태의 군집에 의한 것이 존재한다. Fork mark는 강의 미세한 마찰에 의해 간헐적으로 길게 나타나는 결함이다. Heat mark는 열처리 과정에서 장력의 불균일 및 형상 불량과 두께의 불균일로 발생한다. Dirty mark는 기름, 먼지, 오물들이 부착될 때 더럽혀진 상태로 불규칙한 결함의 형태이다. 그리고 Scratch는 Roll, guide, 테이블과 strip과의 접촉, strip끼리의 접촉시 생긴다.

이들 결함 영상의 밝기 특성을 살펴보면 조명의 영향으로 인하여 영상의 가운데 부분이 밝게 보이고, 주변부가 어둡게 보이는 현상이 나타나는데, 이와 같은 영상들을 그대로 훈련 영상으로 사용하는데는 조명 조건이 다르므로 특징 추출 및 분류 결과에 영향을 미칠 수 있다. 따라서 결함을 검출하고 원하지 않는 배경상의 잡음을 제거하여 조명 조건을 고르게 해 주고

자 전처리 과정을 거쳤다. 사용한 총 데이터 수는 612개로서, 학습으로 320개, 테스트로 292개의 데이터를 사용하였다. 그림 4는 사용한 강판 표면결함 데이터 중에서 대표적인 모양 3가지를 나타낸다.

결함 데이터의 특성은 불균일(nonuniformity), 비정형(irregularity)적이고 동일 종류의 결함이라 하여도, 때때로 변화가 심하다. 또한 기하학적인 형상을 띠고 있지 못하기 때문에 결합 검사 시스템의 알고리즘으로 주로 쓰이는 구조적인(structural) 특징 추출에 있어

서 커다란 제한적인 요인이 된다. 특정 조건에서는 조명의 영향으로 인하여 영상의 가운데 부분이 밝게 보이고, 주변부가 어둡게 보이는 현상이 발생한다. 이러한 특성은 특정 추출에 영향을 줄 수 있으므로, 전처리 과정을 통해 배경상의 잡음을 제거하여 조명의 영향으로부터 조건을 고르게 하는 과정을 거쳤다. 전처리 과정을 거친 특징들에 대하여 웨이블렛 변환을 이용하여  $512 \times 512$ 의 입력영상( $C_0$ )를 분할하여  $64 \times 64(C_2)$ 의 크기로 재구성하였는데 그림 5는 웨이블렛

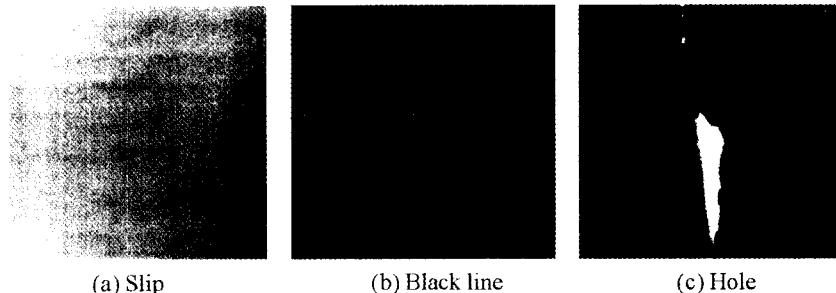


그림 4. 냉연강판 표면 결함 데이터  
Fig. 4. Examples of surface flaws of cold-rolled steel strips

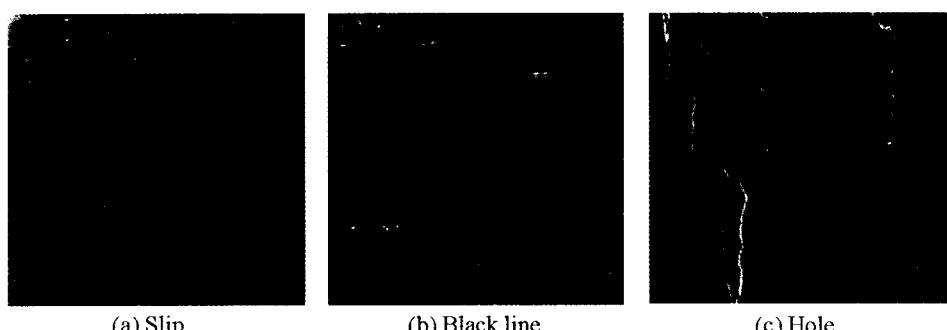


그림 5. 웨이블렛 변환후의 냉연강판 표면 결함 데이터  
Fig. 5. Wavelet transfor result of surface flaws

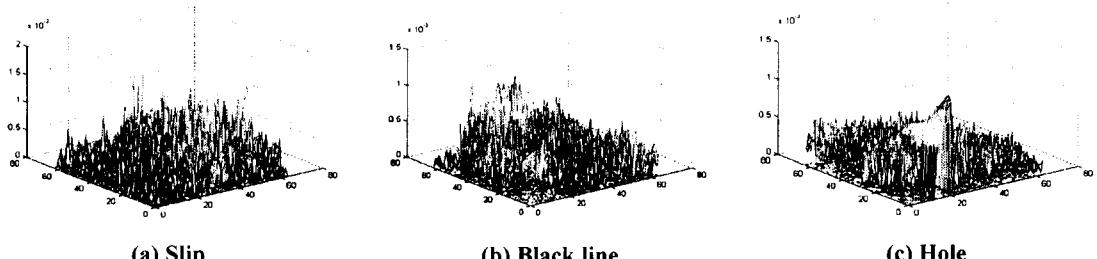


그림 6. 냉연강판 표면 결함 데이터의 특징 분포  
Fig. 6. Probability distribution of surface flaw data of cold-rolled steel strips

변환을 통한 각각의 결합 데이터들이 같이 저주파 지역을 국소적인 특징을 가지며 분포하는 모양을 나타낸다.

전처리 과정을 수행 후 특징을 추출하기 위한 확률 분포 행렬을 계산하여 나타내면 그림 6과 같은 모양으로 보면 정보들이 분포되어 있음을 알 수 있다.

신경회로망 분류기에 사용한 파라미터로서 학습률은 0.15, 모멘텀은 0.85로 설정하였고, 5가지 특징(자기상관관계, 엔트로피, 역모멘트, 에너지, 2차 각 모멘트)을 가지는 입력벡터로서 592개의 결합 데이터를 사용하였다. 신경회로망 분류기의 경우 중간층은 1개로 하여 실험을 하였고, 중간층의 노드수는 5개에서부터 시작하여 개수를 증가시켜 15개까지 실험을 수행하였으며, 개수를 증가시킬 때마다 각각 3번의 반복학습을 수행하였다. 중간층 노드수가 같다고 할지라도, 학습에는 다른 영향을 미칠 수 있으므로, 3번 반복 학습을 통한 평균 오차값을 구해서 인식률로 판단하였다. 그래서 평균 오차값이 목표치에 추종하지 못했을 경우에는 중간층 노드수의 개수를 한 개씩 증가시켜서 위의 단계를 반복하였다. 반복되어진 중간층 노드수의 개수는 15개 이후로부터 크게 향상되어지지 않으므로, 최적의 조건으로 성능을 보이는 10개의 노드수에 대한 학습결과를 실험의 결과치에 사용하였다.

실험결과에 대한 분류율은 다음의 식으로서 산출하였다. 여기서 분류율( $C_r$ )은 실험에 사용된 전체 데이터 개수  $N$ 과 오인식된 개수를  $E$ 로 정의하였다.

$$C_r = \frac{N - E}{N} \times 100(\%) \quad (10)$$

이렇게 사용한 특징을 다르게 하여 실험한 이유는 가장 적은 개수의 특징을 사용하여 최소한의 연산으로서 연산의 복잡도를 줄이고 간단하게 네트워크를 구성하기 위함인데, 결과적으로 분류율을 비교한 결과 4개의 특징을 사용하는 경우 최적의 분류성능을 가짐을 확인할 수 있었다. 그림 7은 4개의 특징을 사용했을 경우 MLP 신경회로망 분류기의 학습률을 나타낸다. epoch에 비례하여 동일하게 오차는 감소하여 적은 특징을 사용한 경우가 시간적으로는 효율적인 결

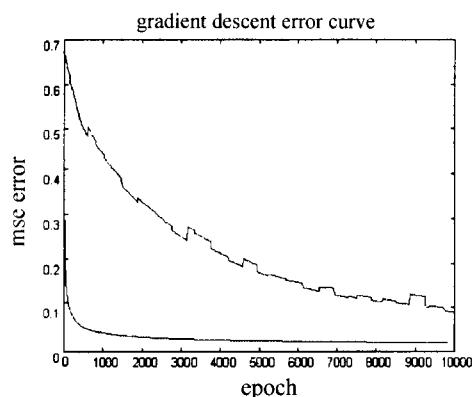


그림 7. MLP 신경회로망의 학습곡선  
Fig. 7. Learning curve of the MLP network

표 1. 분류 결과  
Table 1. Classification result

분류된 부류 \ 실제부류	0	1	2	3	4	5	6	7	8	9	분류율
1		44 38	1 0		0 1		0 2				97.7 92.6
2			33 29		1 0	1 1					97.0 90.3
3		1 1		31 27		0 1					96.8 93.1
4					42 37						100 100
5		1 1	0 1			38 32		0 1			97.4 91.4
6			0 1		1 1		30 25	0 1			96.7 89.2
7			1 0	0 1		0 1		21 18			95.2 90
8				0 1			1 2		34 30		97.1 90.9
9					0 1	0 1	1 0			39 35	97.5 92.1

과를 보였지만, 최종적인 결과를 비교하면 분류율을 산출한 결과 가능한 입력공간의 크기를 3차원 특징 벡터로서는 충분히 만족시키지 못하여 4개의 특징 벡터를 사용한 결과보다 좋지 못한 분류율을 확인 할 수 있었다. 결국 이러한 epoch에 따른 학습결과는 분류율에 크게 영향을 미치지는 못하였는데, 2개의 특징을 사용했을 경우와 4개의 특징을 사용했을 경우의 분류율은 전체의 2%정도의 차이를 보였으며, 나은 결과를 산출하기 위하여 사용하는 특징의 개수를 4로 하였다.

표 1은 5개의 특징을 사용하여 평균적으로 산출한 학습 집합과 테스트 집합의 분류결과이다. 각 칸에서 위의 숫자는 학습데이터, 아래의 숫자는 테스트데이터에 대해서 분류한 결과를 나타낸다. 결합패턴을 분류하지 못하는 경우 unknown 부류로 하여 인위적인 검사에 의존하게 하였으며, 나머지부분에 있어서는 자동적으로 검사가 가능하게 하는 환경에서 분류작업을 수행하였다. 각 부류는 각각 unknown(0), slip(1), black line(2), roll(3), hole(4), scale(5), fork(6), heat(7), dirty(8), scratch(9)로 정의하였다. 분류결과는 학습집합에서 hole과 같이 분명하게 나타나는 결함에 대해서는 완벽한 분류율을 보였지만, 그 이외의 결함 집합에 대해서는 입력공간에 있어서 동일한 특징이 미세하게 중첩되어 분포되어 있음으로서 완벽한 분류를 보이지는 못하였다. 학습데이터의 경우 97.1%, 테스트 데이터의 경우 92.2%의 분류율을 보여준다.

입수된 결함 영상들로부터 결함별로 뚜렷한 특징을 찾는 것이 분류 성능에 결정적인 영향을 준다. 전반적으로 결함 영상의 상태가 시편의 오염으로 인하여 결함 이외의 부분의 특징들에 의하여 분류 성능이 영향을 많이 받는다. 벡터양자화(vector quantization) 방법은 look-up 테이블에 근거한 코드북을 가지고 분류를 하는 대표적인 검사시스템의 표본이므로 이 실험에서 제안하는 알고리즘과 분류 결과의 성능을 비교하였다. 이 방법은 입력된 벡터를 거리 함수에 의해 그 값이 최소가 되는 코드벡터에 대응시켜 입력벡터를 근사화하는 것으로 코드벡터의 집합인 코드북을 이용해 분류에 적용하는 방법이다. 표 2는 광 강도차 행렬과 신경회로망에 의한 분류가 벡터양자화 알고리즘에 비

하여 결함 분류성능이 향상되었다는 것을 입증한다.

## 7. 결 론

본 연구에서는 광 강도차와 MLP 신경회로망을 이용하여 냉연강판 표면결함의 유무를 검출하고 결함의 종류를 판별할 수 있는 알고리즘을 제시하였고, 고속 냉연강판 표면결함 검사장치에 적용할 수 있는 응용 가능성을 제시하였다. 표면결함의 특징 추출 기법이 핵심 요소이고 결함 영상에 대한 데이터로서 냉연강판 결함들에 대한 CCD카메라 영상 데이터를 사용하였으며, 이 데이터로서 웨이블렛 변환과 광 강도차, 그리고 신경회로망을 이용하여 분류하였다. 지금까지 수행된 연구 결과로 볼 때 제시된 질감 분석에 기초한 특징 추출 및 분류 기법들이 실제 냉연강판 결함 검사 장치에 적용 될 수 있을 것으로 판단된다.

## 참고문헌

- [1] A. Ercil, "Automated visual inspection of painted metallic surfaces," *Int. Conf. on Automation, Robotics and Computer Vision*, pp. 1950-1954, 1994.
- [2] F. Treiber, "On-line automatic defect detection and surface roughness measurement of steel strip," *Iron and Steel Engineer*, pp. 26-33, 1989.
- [3] H. Yoda, Y. Ohuchi, Y. Taniguchi, and M. Ejiri, "An automatic wafer inspection system using pipelined image processing technique," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 10, No. 1, pp. 4-16, 1988.
- [4] T. S. Newman, "A survey of automated visual inspection" *Computer Vision and Image Understanding*, Vol. 61, No. 2, pp. 231-262, 1995.
- [5] C. Fernandez, C. Platero, P. Campoy, and R. Aracil, "Visual system for on-line surface inspection in aluminum casting process," *Proc. Int. Conf. on Image Processing*, pp. 1854-1859, 1993.
- [6] A. Rosenfeld, "Image analysis and computer vision: 1993," *CVGIP: Image Understanding*, Vol. 59, No. 3, pp. 367-404, 1994.
- [7] D. C. Heand and L. Wang, "Unsupervised textual classification of image using the texture spectrum," *Pattern Recognition*, Vol. 25, No. 3, pp. 247-255, 1992.
- [8] N. Sarkar and B. B. Chaudhuri, "An efficient approach to estimate fractal dimensions of textural images," *Pattern Recognition*, Vol. 25, No. 9, pp. 1035-1041, 1992.
- [9] Y. Li, "Performing the theory of invariant moment for pattern recognition," *Pattern Recognition*, Vol. 25, No. 7, pp. 723-730, 1992.
- [10] D. Brzakovic and N. Vujovic, "Development environment for designing and testing inspection systems," *IAPR Int. Conf. on Pattern Recognition*,

표 2. 벡터양자화 알고리즘과의 분류 결과 비교

Table 2. Comparison of the VQ and the proposed algorithm

	VQ 알고리즘	제안한 알고리즘
학습 집합	93.3%	97.1%
테스트 집합	84.7%	92.2%

Vol. 3, 1994.

- [11] C. Wang, D. J. Cannon, S. R. T. Kumara, and G. Lu, "A skeleton and neural-network based approaches for identifying cosmetic surface flaws," *IEEE Trans. on Neural Networks*, Vol. 6, No. 5, pp. 1201-1211,

1995.

- [12] P. McKenzie and M. Alder, "Syntactic pattern recognition by quadratic neural nets, a case study: Rail flaw classification," *IEEE Int. Joint Conf. on Neural Networks*, pp. 2101-2104, 1993.

---

**장 성 열 (Sung-Yeoul Jang)**

1998년 : 송실대학교 전기공학과(공학사)

2000년 : 송실대학교 대학원 전기공학과(공학석사)

주관심분야 : 영상 신호처리, 패턴인식



**공 성 곤 (Seong-Gon Kong) (정회원)**

1982년 : 서울대학교 전기공학과(공학사)  
1987년 : 서울대학교 대학원 전기공학  
(공학석사)

1991년 : 미국 University of Southern California(공학박사)

1992년 3월~현재 : 송실대학교 전기공학  
과 부교수

---

주관심분야 : 지능시스템이론, 영상 및 신호처리, 로보틱스,  
진화연산, 인공생명

---