

Wavelet frame 변환을 이용한 냉연 시각검사 알고리즘

Visual Inspection Algorithm of Cold Rolled Strips by Wavelet Frame Transform

이 창 수, 최 종 호
(Chang Su Lee and Chong-Ho Choi)

Abstract : This paper deals with the detection, feature extraction and classification of surface defects in cold rolled strips. Inspection systems are one of the most important fields in factory automation. Defects such as slipmark and dullmark can be effectively detected with a Gaussian matched filter because their shapes are similar to Gaussian. It is justified that the proposed WF(Wavelet Frame) method could be regarded as multiscale Gaussian matched filter which can be applied to the inspection of cold rolled strip. After a wavelet frame transform, the entropies and moments are computed for each subband which pass through both local low pass filter and nonlinear operator. With these features as input, a MLP(Multi Layer Perceptron) is used as a classifier. The proposed inspection method was applied to the real images with defects, and hence showed good performance. The role of each extracted feature is analyzed by KLT(Karhunen-Loève Transform).

Keywords : wavelet frame, Markov process, feature extraction, inspection, classification

I. 서론

검사 시스템은 공장 자동화 분야에 있어서 중요한 역할을 수행한다. 이들의 응용 분야는 적용 대상에 따라 반도체 웨이퍼[1], 금속[2],[3], 유리[4]등 다양한 분야에서 유사한 목적을 가지고 연구되어 왔다. 철강산업에 있어서 표면 결함 검사(surface defect inspection) 시스템은 그 좋은 예이다[5]-[7]. 강판은 강괴를 로울러로 여러번 통과하는 과정에서 생성되나 강괴의 불량, 이물질, 로울러의 불량 등으로 인하여 강판의 표면에 여러 가지 결함이 생기게 된다. 품질의 고급화를 위해서는 강판의 표면에 결함이 없어야 한다. 냉연 강판(cold rolled strip)의 표면흠 검사의 경우 흠의 검출과 검출된 흠의 종류는 강판제품의 품질에 직접적인 영향을 주는 것 외에도 생산라인의 이상 유무와 이상 부위의 중요한 단서가 되므로 흠 검사는 필수적인 과정이 된다. 본 논문의 목적은 wavelet frame 변환에 의한 질감 분석 방법을 이용하여 흠영상에 대한 특징을 추출하고 분류하는 방법을 제시하는데 있다.

Haralick 등은 영상의 공간 영역 상에서 통계적인 질감 특징을 정의하고 분류에 사용하였다[8],[9]. Groß[10] 등은 여러 종류의 질감으로 구성된 영상을 wavelet 변환 후 계수를 특징으로 한 영역분할 방법을 제시하였다. Unser [11]는 N뱅크의 FIR 필터를 이용하여 국부 선형 변환에 의하여 질감 분석을 하고 분류 실험을 하였다. 이 방법은 동시 발생행렬 방법에 비하여 강인성을 가지며 적은 수의 특징을 가지고도 좋은 결과를 얻었다. 또

한 질감에 대한 영역분할 문제에 있어서 국부 선형 변환에 의한 다해상도 특징을 이용하였고[12], Unser는 12개의 Brodatz 질감 영상에 대한 분류 실험으로 wavelet frame 변환을 적용한 결과 좋은 성능을 보여 주었다[13],[14]. 이러한 결과들로 보아 다해상도 영상 분석이 단해상도 영상 분석에 비하여 좋은 성능을 얻을 수 있음을 알 수 있다.

흠의 검출에 있어서는 dullmark [19], slipmark(그림 4) 등의 기본흠의 형태가 주로 가우시언 형태를 띄고 있는 점을 감안하면 이의 검출은 매치 필터에 의하여 검출이 가능하다. 이를 구하기 위하여 냉연 강판의 배경 질감 영상의 자기상관(autocorrelation) 함수를 회전상의 대칭형인 비분리(nonseparable) 1차 Markov 프로세스로 간주하여 이의 파워 스펙트럼의 곡면정합에 의하여 모델링함으로써 최적의 파라미터를 구하였다. 이후 Markov 모델링된 파워 스펙트럼으로부터 백색화 과정을 거쳐서 매치 필터를 구하였다. 냉연 강판 배경 영상의 가우시언 물체 검출에 있어서도 LOG 형태의 wavelet을 이용하면 제안된 WF 기법이 다중 스케일 가우시언 매치필터의 기능을 수행할 수 있음을 실험적으로 확인하였다.

4종류의 흠을 분류하기 위하여 특징 추출하고 분류하는 구조를 택하였다. 즉, 흠영상에 대하여, WF 변환후 각 부대역마다 국소 저역 필터 및 비선형 연산기를 통과 후 계산량이 적은 엔트로피 및 모멘트 정보를 특징으로 추출하고 다층인식자로 분류하는 새로운 구조를 제시하였다.

마지막으로 실제 냉연흠 영상에 대하여, 제시된 검사 기법을 이용하여 흠의 검출 및 분류 실험을 하였고 그 결과 좋은 분류 성능을 보임을 확인하고 추출된 특징들을 분석하였다.

접수일자 : 1997. 5. 8., 수정완료 : 1998. 2. 28.

이창수 : 수원대학교 전기전자정보통신공학부

최종호 : 서울대학교 전기공학부, 자동화시스템공동연구소

※ 본 논문은 (주)포항제철에서 지원하여 연구하였습니다.

II. Wavelet frame 변환

Wavelet 이론은 Grossmann과 Morlet [15] 등에 의하여 발표되었으며 다음의 기저함수로 표현된다.

$$\psi_{p,q}(x) = \frac{1}{\sqrt{p}} \psi\left(\frac{x-q}{p}\right), p \in R \quad (1)$$

$\psi(x)$ 는 기저함수이며 bandpass 필터이다. Wavelet 들은 $\psi(x)$ 라고 하는 mother wavelet 의 팽창과 수축 연산을 통하여 구해진다. 위의 (1)에서 p 는 scale 파라미터이고 q 는 이동연산자이고 $1/\sqrt{p}$ 은 에너지 정규화를 위한 인자이다. p 가 크면($p \gg 1$) 기저함수는 길이가 길어지게 되어 분석하고자 하는 신호의 긴 시간거리에 해당하는 경향을 알 수 있고 p 가 작으면($0 < p < 1$) 기저함수의 길이가 짧아지게 되어 신호의 좁은 시간영역에 해당하는 경향을 분석할 수 있게 된다. Wavelet frame 변환의 계산 방법은 decimator가 필요 없기 때문에 wavelet 변환에 비하여 간단하다. 그림 1에 quadtree 구조의 분리가능한 다중 해상도의 J 레벨 2-D WF 변환을 나타내었다. 여기서 $\tilde{H}(\omega)$ 는 임펄스 응답 $\tilde{h}(n)$ 의 Fourier 변환이다. WF 변환에 있어서 $\tilde{H}(2\omega)$ 는 $\tilde{h}(n)$ 의 각 계수들 사이에 0을 첨가함으로써 간단히 얻을 수 있다. 이는 wavelet 변환에 있어서 $\tilde{H}(\omega)$ 와의 필터링 후 subsampling을 수행하는 기본 연산이 $\tilde{H}(2\omega)$ 와의 필터링과 동등하기 때문이다. 말단 노드로부터 생성된 부대역은 $\{A_{2^i}, (D_{2^i}^j)_{1 \leq j \leq 1 \leq i \leq 3}\}$ 와 같다.

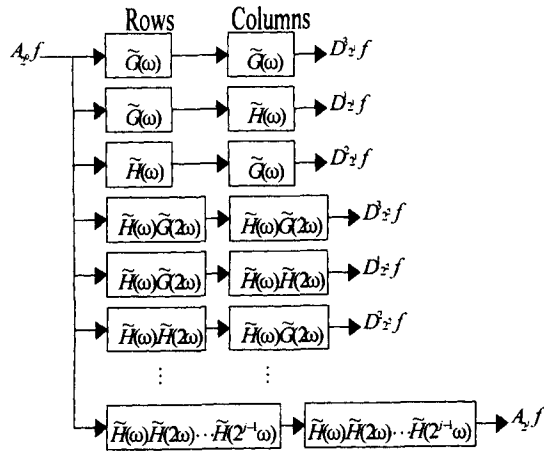


그림 1. 분리가능한 다중해상도의 2-D WF 변환.
Fig. 1. Separable multiresolution 2-D WF transform.

Wavelet frame 변환의 단점은 기저 함수가 수직인 성질을 잃어버린다는 점이다. 또한 정보 이론의 관점에서 볼 때 oversampling된 redundant한 변환을 얻음으로써 정보량의 과다 생성이라는 비효율적인 측면을 들 수 있다. 그러나 질감 분석에 의한 영상의 특징추출에 있어서는 다음에 열거하는 세 가지 이유에 의하여 wavelet frame 변환의 의미를 부여할 수 있다. 첫째, HVS(Human Visual System)의 입장에서 볼 때 각 부대역이 충분한 해상도의 크기일 때 영상으로부터의 특징을 잘 관찰할 수 있

다. 둘째, 여러 가지 대역별 화소의 비교 관찰을 위해서는 같은 크기의 영상을 가지고 다루어야 편리하다. 또한 wavelet frame 변환의 경우 영상이 이동불변인 성질을 그대로 유지하므로 각 대역별 특징이 잘 부각되어 나타날 수 있다.

III. 흠의 검출(detection)

흠의 검출에 있어서는 slipmark, dullmark 등의 기본 흠의 형태가 주로 가우시언 형태를 띄고 있는 점을 감안하면 이의 검출은 매치 필터에 의하여 검출이 가능하다. 이를 구하기 위하여 신호를 가우시언 물체로 가정하면 잡음에 해당하는 냉연 강판의 배경 질감 영상의 파워 스펙트럼을 구할 필요가 있다.

1. 배경 영상에 대한 모델링

영상은 보통 1차 Markov 프로세스로 모델링된다[16]. 자연영상의 경우 자기상관(autocorrelation) 함수를 회전상의 대칭형인 비분리(nonseparable) Markov 프로세스로 모델링할 수 있는 경우가 많고, 인공적인 영상의 경우 영상의 가로 세로 방향의 상관도가 매우 큰 경우가 많은데 이 경우 분리가능한(separable) Markov 프로세스로의 모델링이 가능하다. 2-D 비분리(nonseparable) Markov 프로세스의 자기상관 함수는

$$R_{ns}(j, k) = \sigma_v^2 e^{-\sqrt{a_x^2 j^2 + a_y^2 k^2}} \quad (2)$$

로 주어진다 [16]. 이 식에서 σ_v^2 은 잡음의 에너지를 결정한다. 이 프로세스에 대한 파워 스펙트럼은 2-D Fourier 변환에 의하여 다음과 같이 주어진다.

$$S_{ns}(\omega_x, \omega_y) = \frac{1}{a_x a_y} \frac{2\pi \sigma_v^2}{1 + \omega_x^2/a_x^2 + \omega_y^2/a_y^2} \quad (3)$$

이를 간단화하기 위하여 분리가능한 형태로 표현하기도 하는데 이에 대한 자기상관 함수는

$$R_s(j, k) = \sigma_v^2 e^{-a_x |j| - a_y |k|} \quad (4)$$


로 주어진다. 이에 대한 파워 스펙트럼은 다음과 같다.

$$S_s(\omega_x, \omega_y) = \frac{4\sigma_v^2 a_x a_y}{(a_x^2 + \omega_x^2)(a_y^2 + \omega_y^2)} \quad (5)$$

40여개의 채취된 강판의 흠영상 집합으로부터 흠을 제외한 배경 흠영상의 질감 특성을 주파수 영역에서 알아보기 위하여 이에 대한 파워 스펙트럼을 추정하여 보았다. 그림 2(a)는 배경 원영상의 파워 스펙트럼을 나타낸 것이다. 이를 자세히 살펴보면 앞서 언급한 특유의 줄무늬성의 질감이 주파수 영역상의 x축의 저주파 영역에 나타나 있음을 확인할 수 있다. 이 주파수 대역의 영상이 강판 특유의 질감을 나타내는 것으로 보인다.

그림 2(b)는 주파수 영역 상에서 (a)에 근사화시킨 2-D 비분리 Markov 프로세스의 파워 스펙트럼을 나타낸다. Markov 프로세스의 파라미터 a_x, a_y 와 σ_v 에 대한 최적의 해를 로그 영역에서 MSE(Mean Square Error)를 최소로 하는 곡면정합(curve fitting) 추정 방법에 의하여 구하였다 ($a_x = 4.0e-7, a_y = 1.16e-7, \sigma_v = e^3$). 그림 2(a)


를 보면 스트립의 진행방향의 수직방향에 대한 주파수 성분이 x축의 저주파 영역에서 크게 관찰됨을 알 수 있으며 그림 2의 (a)와 (b)는 주파수 영역 특성이 유사함을 보여주고 있다.



(a) 강판의 배경영상들 중 40개 샘플의 파워 스펙트럼의 추정치
(b) 비분리 Markov 파워 스펙트럼으로의 모델링

그림 2. 강판 배경 영상 모델링.
Fig. 2. Background image modeling for steel strip.

실제 배경 홈영상과 위에서 구한 파라미터를 가지고 2-D 비분리 Markov 프로세스를 통해 모델링된 영상을 서로 비교하여 보았다. 그림 3(a)는 강판 질감의 일부분에 대한 고주파 필터링 후의 영상을 보인 것이고, 그림 3(b)는 고주파 필터링 후의 2-D 비분리 Markov 프로세스를 나타낸다. Markov 모델 영상은 세로 방향의 줄무늬가 강조되어 강판의 특성을 나타내고 있음을 볼 수 있다. 따라서 강판의 배경영상은 위에서 구한 최적의 파라미터를 가진 비분리 Markov 프로세스로 모델링하여도 크게 다르지 않음을 알 수 있다.



(a) 강판의 고주파 필터링 후의 배경영상
(b) 고주파 필터링 후의 비분리 Markov 잡음영상

그림 3. 강판 배경 영상 모델링.
Fig. 3. Background image modeling for steel strip.

2. 검출 실험

강판 배경 영상의 가우시언 물체 검출에 있어서 LOG 형태의 wavelet을 이용하면 WF변환이 다중 스케일 가우시언 매치필터와 동등한 역할을 수행함을 알 수 있다 [17]. 따라서 WF방법은 multiscale 가우시언 물체의 검출방법이라고 할 수 있다. 홈영상에 있어서 선 형태의 홈에 대한 검출 문제는 점 형태의 검출문제의 확장으로 볼 수 있다. 즉, 점들이 모여 선을 이루는 것으로 볼 수 있다. 홈의 검출방법은 각 레벨별로 에지성분을 검출하는 구조를 택하였다. 각 레벨마다 HL + LH를 구하면 이

는 각 레벨별 세부 영상을 나타낸다. 이들 세부 영상은 에지 성분을 포함하기 때문에 적당한 문턱치 설정에 의해 중요한 특징들을 추출할 수 있다. 문턱치 설정방법으로는 레벨 1 세부영상의 히스토그램을 구하고 이 표준편차의 3배 만큼에 해당하는 값으로 정하였다. 각 레벨마다 각 픽셀이 이 문턱치 보다 큰 값을 가질 경우 이를 홈영역의 일부에 해당하는 픽셀로 간주하였다. 각 레벨마다 검출된 이진 영상은 논리합 연산을 통하여 전체적인 이진영상을 구하였다. 검출하고자하는 홈의 크기에 따라 wavelet 분해 레벨의 깊이를 결정할 수 있다. 즉, 분해 레벨의 크기가 커짐에 따라 보다 큰 크기의 홈을 검출할 수 있다.

그림 4는 가우시언 모양을 가지는 slipmark중의 한 영상 p에 대하여 제시된 검출방법에 의한 결과를 나타낸다. 그림 4의 (1,2)-(3,1)에서 좌상에서 우하로 가면서 WF 변환후의 HL+LH의 세부영상 ($D_{2^j}^1 p + D_{2^j}^2 p$, $j=1,2,3$)들을 나타낸 것이다. 그림 4의 (2,2)는 이들 각 scale별 영상으로부터 문턱치 설정을 통하여 이진 영상을 구한 것이다. 문턱치는 레벨 1 세부영상의 히스토그램을 구하여 이들의 편차가 상위 0.3% 이상 되는 값으로 하였다.




그림 4. (1,1) slipmark 원영상, (1,2) 레벨 1 세부영상, (1,3) 레벨 2 세부영상, (2,1) 레벨 3 세부영상, (2,2) thresholding 후의 이진영상.
Fig. 4. Level 1, 2, 3, detail images for slipmark.

가우시언 형태가 아닌 홈에 대해서는 Mallat [18]와 같이 LOG형태의 WF변환 후 영점 통과(zero crossing) 부분의 근처에 존재하는 특이점(singularity), 즉 에지 성분의 검출로 생각할 수도 있다. WF 변환에 의한 방법의 경우 문턱치의 설정 기준을 레벨 1 HL+LH 부대역의 표준 편차에 비례하도록 가변적으로 정함으로써 여러 종류의 홈에 대해서도 적용 가능하다.

IV. 특징 추출

특징 추출부는 그림 5와 같이 WF 변환 및 국소 저역 필터(MA: moving average) [19]를 통과한 후 비선형 연산을 거쳐 각 부대역으로부터 특징들을 추출하는 구조로 되어 있다. MA 및 비선형 연산에 대한 자세한 방법은 [19]에 자세히 나와 있다.

흠들 중 특히 dirt의 경우 불균일(nonuniformity), 비정형(irregularity)이고 기하학적인 형상을 띠고 있지 못하기 때문에 앞서 언급한 검출 방법을 사용하여 특징 추출을 하기에는 제한적인 요인이 된다. Dirt는 이와 같은 흠의 특성상 고주파 성분을 강하게 가지고 있으므로 HH 세부영상 정보도 특징 추출에 중요한 역할을 한다. 따라서 분류를 위한 특징 추출 문제에 있어서는 흠의 종류에 관계없이 HH도 고려하였다. 흠의 검출은 scale 별로 HL, LH, HH 영상의 합에 대하여 가우시언 모양을 가지는 흠을 찾아내는 WF 매치필터를 언급하였다.

이 방법에 의한 흠의 검출 결과는 slipmark, dullmark와 같은 점 성분의 흠에 대하여는 우수한 검출 능력을 발휘함을 알 수 있었다. 또한 web의 진행 방향에 평행한 선 성분을 가진 scratch와 같은 흠에 대하여는 세부영상 HL+LH+HH 영역을 조사하더라도 HL의 에너지가 많기 때문에 검출 가능하다. 그러나 같은 scratch라도 희미한(blurred) 원영상에 대해서는 주로 HL 영역에 미세하게 나타나므로 HL 영역에서의 1-D 검출이 더욱 효과적이다. 이때는 WF 변환의 HL 부대역이 1-D 가우시언 매치필터의 역할로서 간주될 수 있다. 방향성 흠에 대해서는 HL, LH, HH의 각 부대역을 조사하는 것이 더 나은 결과를 얻을 수 있다. 따라서 특징추출은 WF 변환후 각 부대역마다 정의된 특징들을 계산하였다.

본 WF 방법에서의 특징들은 기존에 많이 사용되는 엔트로피 특징 및 모양정보를 이용하였다. 엔트로피 특징들은 [19]에 제시된 행 엔트로피, 열 엔트로피, 총 엔트로피의 특징들이다. 흠영상의 특성상 모양정보에 기초한 둘레, 면적, 모멘트와 같은 기하학적인 특징들 또한 분류에 유용한 정보를 제공한다. Wavelet 영역 상에서는 원영상의 모양정보가 유지되지 않는다는. 여기서는 mother wavelet이 LOG 형태로써 이것과 입력 영상과의 convolution을 취하므로 wavelet 변환 영역에서는 원영상에 비하여 모양이 왜곡된다. 그러나 국부 convolution에 의한 변환이기 때문에 흠의 모양에 큰 영향을 미치지 않는다. 실제 사용한 모양 특징들로서는 면적(a), 길쭉함의 정도(e), 퍼짐 정도(s)를 나타내는 세 가지 특징들을 사용하였다 [20].

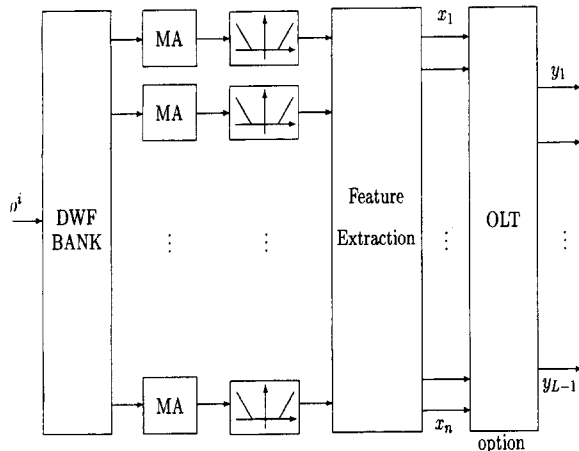


그림 5. WF 변환을 이용한 특징추출 과정.
Fig. 5. Feature extraction procedure using WF.

V. 특징수 저감을 위한 기법

1. KLT

KLT(Karhunen-Loève Transform)[21]는 특징수 저감(reduction)을 위한 기본적인 방법으로 1차, 2차 모멘트 정보를 이용한다. 이는 혼합 비산행렬(mixed scatter matrix)의 고유 벡터들에 의하여 변환이 정의된다. 또한 특징들 상호간의 연관성을 없애 줌으로써 MSE(Mean Square Error)를 최소화하는 선형 변환이다. 이는 전체 특징에 대한 사상뿐만 아니라 각 클래스의 특징의 분포를 정규화 시킴으로써 클래스간 분포의 편차를 서로 비슷하게 사상시키는 과정을 거침으로써 분류를 위한 최적의 선형 변환(Optimum Linear Transform, 이하 OLT)을 구할 수 있다[22].

특징수 저감은 n차원의 특징을 여러 다른 클래스 분포간의 중복을 줄이면서 $m(<n)$ 차원의 특징 공간에로의 사상시키는 문제이다. n차의 특징 벡터 X로부터 클래스내 비산행렬(within class scatter matrix, S_W),

$$S_W = \sum_{i=1}^L p_i E\{(X - m_i)(X - m_i)^T\} \omega_i \quad (6)$$

과, 클래스간(between class) 비산행렬(S_B),

$$S_B = \sum_{i=1}^L p_i E\{(m_i - m_0)(m_i - m_0)^T\} \quad (7)$$

의 정의가 필요하다. 여기서 m_i 는 각 클래스별 평균 기대치 벡터를 나타내고 m_0 는 전체 분포의 기대치 벡터로서 $m_0 = \sum p_i m_i$ 과 같다. L은 총 클래스 수이고, p_i 는 클래스 i에 속할 확률을 나타낸다. 혼합 비산행렬, S_T 는

$$S_T = E\{(X - m_0)(X - m_0)^T\} = S_W + S_B \quad (8)$$

인 관계를 만족한다.

분류성능을 판단하는 척도로서 $J = tr(S_W^{-1} S_B)$ 를 정의하면 J가 최대값을 가지게 될 경우 클래스내 비산행렬의 분산은 작아지고 클래스간 비산행렬의 분포는 2차 모멘트가 큰 값을 가지게 되어 분산이 커지게 된다. 이때 특징들은 이상적인 분포 형태를 갖게 되는 것이다.

최적의 특징 도출을 위한 선형 변환을 구하면 특징벡터 X에 대하여 $Q\Phi^{-1/2}\Phi$ 와 같이 주어진다. 여기서 Φ 와 Φ 는 $S_W\Phi = \Phi\Theta$, $\Phi^T\Phi = I$ 인 관계를 만족한다.

n개의 특징에 대한 최적의 선형변환에 의한 특징 수는 항상 $r=L-1$ 개로 줄어들게 된다. 지금까지의 방법은 각 클래스의 분포가 가우시언 형태를 띠고 각 클래스별 클러스터링의 수가 한 개만 존재할 경우에 최적의 변환된 특징들을 구할 수 있다.

VI. 분류 실험

본 논문에서는 scratch, dullmark, dirt, slipmark의 4가지의 흠 영상 데이터 집합에 대하여 특징을 추출하고 분류 성능을 평가하였다. 고속의 냉면 라인에서 취득한 256 gray의 128x128 CCD 카메라 흠영상으로부터 서로 다른 107개의 훈련집합과 133개의 테스트집합을 구성하였다. 전체적인 분류과정은 다음과 같다. 우선 훈련영상 집합에 대하여 그림 5의 특징추출을 거쳐 생성된 특징들

을 신경회로망 분류기로 학습을 시킨 후 각각의 테스트 영상에 대하여 흠의 종류를 판정하는 구조이다 [19]. 그림 5에서 각각의 흠 영상을 3 레벨 WF 변환후의 생성된 부대역의 개수는 10개이다. 각 부대역별로 면적, 길쭉함의 정도, 퍼짐 정도의 3가지 특징과 3가지 엔트로피 특징을 계산하였다. 따라서 전 부대역에 대하여 추출된 특징들의 총 개수는 60개로 이를 신경회로망의 입력으로 사용하였다.

표 1. WF 방법을 이용한 4개 클래스로 구성된 (a)훈련, (b) 테스트 집합에 대한 MLP 분류 결과.

Table 1. MLP classification results for (a) training, (b) test set using WF method.

class	assigned class				classification rate	defect name
	0	1	2	3		
0						unknown
1		46			100%	scratch
2			16		100%	dullmark
3				27	100%	dirt
4					100%	slipmark
total rate					100%	

(a)

class	assigned class				classification rate	defect name	
	0	1	2	3			4
0						unknown	
1	2	67	3	1	3	88.2%	scratch
2			12	1	1	85.7%	dullmark
3	2	2	2	16	2	66.7%	dirt
4	1	0	3	1	14	73.7%	slipmark
total rate					82.0%		

(b)

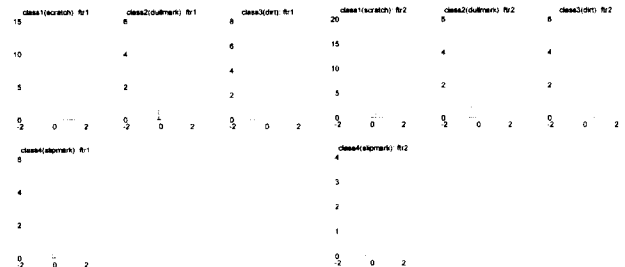
그림 5에서 OLT 블럭은 특징 수 저감을 통하여 특징의 히스토그램을 분석하기 위한 기법으로 이용하였기 때문에 실제 신경회로망의 입력으로는 OLT 이전 단계인 특징 데이터를 그대로 이용하였다.

표 1에 4개 클래스의 데이터 집합에 대하여 분류실험을 한 결과를 나타내었다. MLP의 구조는 60-5-4이고 5911 epoch에서 RMSE가 설정치인 0.01 이하로 줄었으며 훈련집합에 대해서 100%, 테스트 집합에 대해서는 82.0%로써 좋은 분류율을 얻었다.

그림 6은 추출된 60(즉, n=60) 개의 특징 집합을 가지고 V절에서 제시된 특징 수 저감 과정을 거쳐 도출된 특징들의 분포를 히스토그램으로 나타낸 것이다. 즉, X로부터 S_W, S_B 를 구하고 $S_W^{-1}S_B$ 중에 OLT 변환 행렬 $Q\Theta^{-1/2}\Phi$ 을 찾으면 가장 큰 고유치에 해당하는 특징인 $Q\Theta^{-1/2}\Phi X_k$ 의 3차원 특징 벡터를 구할 수 있다. 이때 V절에 설명되었듯이 총 클래스의 개수가 L=4이므로 특징 수 저감과정을 거친 후의 특징수는 r=3 이다. 따라서 특징 벡터 $X_k, (X_k = [x_{1k}, x_{2k}, x_{3k}]^T, k=1, \dots, m, \text{ 샘플의 개수 } m=269)$ 의 각 특징들에 대한 히스토그램을 도시한 것이다. 여기서 x축은 특징값을 y축은 개수를 나타낸다. 실선은 훈련집합을 나타내고 점선은 테스트 집합을 나타낸 것이다.


그림 6(a)에서 볼 수 있듯이 첫 번째 특징은 scratch와 같은 라인성분의 흠과 dullmark나 slipmark와 같은

점성분의 흠에 대하여 잘 구분하여 주는 것을 알 수 있다. Dirt의 경우 점성분과 면적성분을 동시에 지니고 있기 때문에 첫 번째 특징으로는 잘 구분이 되지 않으나 6(b)를 보면 다른 클래스들과 잘 구분이 됨을 알 수 있다. Dullmark와 slipmark와의 구분은 6(c)의 세 번째 특징에서 아주 다르게 나타난다는 것을 알 수 있다. 각 클래스내의 히스토그램의 분포는 표준편차에 있어서 큰 차이를 보이지 않음을 볼 수 있다. 이는 특징수 저감과정에서 고유치에 의하여 각 특징을 정규화 해주는 백색화 과정으로 인한 결과이다.



(a)

(b)



(c)

그림 6. 4 종류의 흠에 대한 특징수 저감 후 특징별 히스토그램. (a) x_{1k} , (b) x_{2k} , (c) x_{3k} .

Fig. 6. Histogram for 4 classes of defects after feature reduction.

VI. 결론

본 논문에서는 CCD 카메라를 이용하여 입수한 scratch, dullmark, dirt, slipmark의 4가지의 흠 영상 데이터 집합에 대하여 특징을 추출하고 분류 성능을 평가하였다. 우선 흠의 검출을 위하여 배경 흠 영상에 대한 수학적인 모델링을 하였다. 보통 자연 영상의 경우 Markov 프로세스로 모델링하는 점을 고려하여 비분리 Markov 프로세스로 모델링하고 이를 주파수 영역과 공간 영역 상에서 유사성을 비교하였다. 이는 파라미터 α_x 와 α_y 의 비례관계로써 표현 가능하였다.

한편 LOG 형태의 wavelet을 이용하여 WF 변환을 수행하면 이는 곧 가우시언 물체를 검출하는 매치 필터의 역할과 유사함을 보이고 실험을 통하여 확인하였다.

제시된 WF 기법으로 4가지 흠 데이터에 대하여 분류 실험 결과 훈련집합에 대해서는 100%, 테스트 집합에 대해서는 82%의 좋은 분류율을 얻었다.

참고문헌

- [1] H. Yoda, Y. Ohuchi, Y. Taniguchi, and M. Ejiri, "An automatic wafer inspection system using pipelined image processing techniques," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 10, no. 1, pp. 4-16, 1988.
- [2] H. Boerner and H. Strecker, "Automated x-ray inspection of aluminum castings," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, pp. 79-91, 1988.
- [3] A. Ercil, "Automated visual inspection of painted metallic surfaces," *Internat. Conf. on Automation, Robotics and Computer Vision*, pp. 1950-1954, 1994.
- [4] H. Freeman, *Machine Vision for Inspection and Measurement*, Academic Press, 1988.
- [5] J. L. C. Guay, "A machine vision system for real time inspection of moving web," *IRCV*, vol. 1193, pp. 204-227, 1989.
- [6] L. J. Olsson and S. Gruber, "Web process inspection using neural classification of scattering light," *IEEE Trans. on Industrial Electronics*, vol. 40, no. 2, pp. 228-234, Apr., 1993.
- [7] C. Fernandez, C. Platero, P. Campoy and R. Aracil, "Vision system for on-line surface inspection in aluminum casting process," *Proc. Internat. Conf. on Industrial Electronics, Control, and Instrumentation (IECON)*, pp. 1854-1859, Nov., 1993.
- [8] R. Haralick, K. Shanmugam and I. Dinstein, "Textual features for image classification," *IEEE Trans. on System, Man and Cybernetics*, vol. 3, no. 6, pp. 610-621, Nov., 1973.
- [9] R. M. Haralick, "Statistical and structural approaches to textual," *Proceedings of the IEEE*, vol. 67, no. 5, pp. 786-804, 1979
- [10] M. H. Groß, R. Koch, L. Lippert and A. Dreger, "Multiscale image texture analysis in wavelet spaces," *Proc. Internat. Conf. on Image Processing*, vol. 3, pp. 412-416, 1994.
- [11] M. Unser, "Local Lineal transforms for texture measurements," *Signal Processing*, vol. 11, pp. 61-79, 1986.
- [12] M. Unser and M. Eden, "Multiresolution feature extraction and selection for texture segmentation," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, pp. 717-728, 1989.
- [13] M. Unser, "Texture discrimination using wavelets," *Proc. Computer Vision and pattern Recognition*, pp. 640-641, Jun., 1993.
- [14] M. Unser, "Texture classification and segmentation using wavelet frames," *IEEE Trans. on Image Processing*, vol. 4, no. 11, pp. 1549-1560, 1995.
- [15] A. Grossmann and J. Morlet, "Decomposition of hardy functions into square integrable wavelets of constant shape," *SIAM J. Math.* vol. 15, pp. 723-736, 1984.
- [16] W. K. Pratt, *Digital Image Processing*, John Wiley & Sons Inc., New York, Second edition, 1991.
- [17] R. N. Strickland and H. I. Hahn, "Wavelet transforms for detecting microcalcifications in mammograms," *IEEE Trans. on Medical Imaging*, vol. 15, no. 2, pp. 218-229, Apr., 1996.
- [18] S. Mallat, "Zero-crossings of a wavelet transform," : *IEEE Trans. on Information Theory*, vol. 37, no. 4, pp. 1019-1033, July, 1991.
- [19] C. S. Lee, C.-H. Choi, J. Y. Choi and S. H. Choi, "Surface defect inspection of cold rolled strips with features based on adaptive wavelet packets," *IEICE Trans. on Information and Systems*, vol. E80-D, no. 5, pp. 594-604, May, 1997.
- [20] I. Pitas, *Digital Image Processing Algorithms*, Prentice Hall, 1993.
- [21] R. C. Gonzalez and R. E. Wood, *Digital Image Processing*, Addison-Wesley, 1992.
- [22] K. Fukunaga, *Introduction to Statistical Pattern Recognition*, Academic Press, 1990.



이 창 수

1985년 서울대 제어계측공학과 졸업. 동대학원 석사(1987. 2.), 동대학원 전기공학부 박사(1997. 2.). 1997년 9월~현재 수원대학교 전기전자정보통신공학부 전임강사. 관심분야 wavelet 이론과 이의 영상처리 응용, 신경회로망.

최 종 호

제어·자동화·시스템공학회 논문지 제 4권 제 2호 참조.