

광 강도차와 MLP 신경망을 이용한 냉연강판 표면결함 인식

장성열*, 공성곤
숭실대학교 전기공학과

Surface Flaw Inspection of Cold Rolled Strips by Intensity Gradient and MLP Neural Network

Sung-Yeoul Jang*, Seong-Gon Kong
Department of Electrical Engineering, Soongsil University

Abstract - 본 연구에서는 영상처리 기법을 이용하여 조각으로 나누어진 강판의 표면정보를 계산하여 표면홈을 검사하는 새로운 검사 기법을 제안한다. 이는 냉연 표면의 입력영상으로부터 wavelets 변환기법을 이용하여 영상을 정량화하고, 이 영상으로 co-occurrence 행렬을 이용하여 대이터들 간의 주된 특징들을 추출하여, 표면 정보를 인식 후 홈을 분류하기 위한 분류기로서 신경망을 이용하여 분류하는 과정을 거치게 된다. 제시하는 알고리즘은 기존의 벡터양자화 기법과 비교하여 우수한 성능을 보임을 실증을 통해 입증하였으며, 실시간 구현에 효과적으로 적용될 수 있음을 보였다.

1. 서 론

현대 산업사회에 있어서 텍스쳐(texture)의 정확한 분석으로 오류를 검출하는 과정은 빠른속도와 안정성과 함께 매우 중요한 부분으로 요구되고 있다. 일반적으로 오류검출 제어 시스템은 폭 1.6~2.0m, 그리고 8~20 m/min 의 속도로서 인간의 제어에 의존하고 있는 실정이다. [1][4]

본 논문의 목적은 이러한 이유를 통해 냉연 표면 홈의 특성을 이해하여 자동검사 기법에 이용하는데 기여하고자 한다. 여기서 말하는 표면검사의 부분은 철강 산업에서 매우 중요한 역할을 하는데, 이는 철강의 작업 수행에 표면에 다수의 결함이 생길 수 있기 때문이다. 특히 냉연 표면 강판(cold rolled strip)의 표면홈 검사의 경우 홈의 종류 판별은 강판제품의 품질에 직접적인 영향을 주는 것 외에도 생산 라인의 이상 유무와 이상부위를 점검하는 중요한 단서가 되므로 홈검사는 필수적인 과정이다.[3]

따라서 이 논문에서는 확률 분포 행렬을 가지는 몇 가지의 파라미터들과 신경망 기법을 통하여 냉연 표면 강판의 홈의 종류를 검사하는 기법을 제안하고자 한다. 2절에서는 입력영상의 크기를 재구성 하기 위해 정보의 순서를 최대한 줄이면서, 저주파의 특징분분만을 추출하기 위해 웨이브렛 변환 방법을 이용하여 영상을 재구성하였다.

3절에서는 재구성한 영상에 대하여 광 강도차를 이용하여 생성한 행렬을 통하여 특징을 추출하는 방법을 보이며. 4절에서는 텍스쳐 정보에 영향을 가지는 몇 가지 파라미터를 알아보고, 구성하고자 하는 신경망의 학습을 위한 데이터를 추출하게 된다. 5절에서는 홈을 분류하기 위한 신경망으로서 MLP(Multi Layer Perceptron)를 이용하여 네트워크를 구성하였다.[2][5]

추출된 특징 데이터로서 6장에서는 몇 가지 냉연표면 강판의 분류 실험을 수행하여 결과를 산출하였고, 7장에서는 주요한 개념을 정리하고, 앞으로의 수행방향에 대해서 논하였다.

2. 본 론

2.1 웨이브렛 변환을 이용한 특징 영상 재구성
영상처리를 위한 데이터는 CCD 카메라를 사용하였다.
CCD 카메라와 프레임 그레이스케일 이미지는 512 x 512 크기의 영상으로 한 그레이스케일의 이미지는 512 x 512 크기의 영상으로

서, 계산상의 공정을 줄이기 위해 32 x 32 크기의 영상으로서 재구성(recomposition)하였다. 재구성으로 사용한 방법은 STFT(Short Time Fourier Transform)에서의 시간, 주파수 해상도의 한계를 극복하기 위해 고주파에서는 시간 해상도가, 저주파에서는 주파수 해상도가 좋았도록 하여 신호처리에서 시간과 주파수를 동시에 처리가 가능하도록 하는 웨이브렛 변환을 사용하였다.

2.2. 텍스쳐 이해를 위한 확률 분포 행렬

제안하고자 하는 분석적 방법은 확률 통계적(statistics probability)인 방법이다. 이 기법은 특징을 추출하고자 하는 텍스쳐의 성질이 가지는 고유한 정도를 이용하는 것으로, 서로 이웃한 픽셀들의 광 강도차(intensity gradient)의 빈도수를 조사함으로서 정량화 하는 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 역모멘트와 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. 인접한 픽셀과의 광 강도차를 나타내는 연산자로서 다음의 특성 연산자 C 를 사용한다.

$C = \text{한 픽셀에 대하여 } 45\text{도 각도와 } 90\text{도 각도, 그리고 } 135\text{도 각도에 위치한 레벨정도의 유사성 확인}$

특성 연산자 C 를 이용하여 광 강도차이를 나타내는 광 강도 차이 행렬 D 의 식(1)를 이끌어 낼 수 있다.

$$D = \begin{bmatrix} d_{00} & d_{01} & \cdots & d_{0(n-1)} \\ d_{10} & d_{11} & \cdots & d_{1(n-1)} \\ \vdots & \vdots & \ddots & \vdots \\ d_{(n-1)0} & \cdot & \cdots & d_{(n-1)(n-1)} \end{bmatrix} \quad (1)$$

여기서 구한 광 강도차이 매트릭스 D 를 이용하여 확률적 특징을 가지는 변수조합을 계산하고, 특징 연산자 C 를 이용해 광 강도차이를 나타내는 확률 매트릭스 P 를 구한다.

$$P = \begin{bmatrix} p_{00} & p_{01} & \cdots & p_{0(n-1)} \\ p_{10} & p_{11} & \cdots & p_{1(n-1)} \\ \vdots & \vdots & \ddots & \vdots \\ p_{(n-1)0} & \cdot & \cdots & p_{(n-1)(n-1)} \end{bmatrix} \quad (2)$$

확률 요소 p_{ij} 는 각 픽셀쌍의 비교횟수가 발생할 수 있는 총합을 표준화한 것으로서 즉, D 행렬에 속하는 각각의

발생 요소들을 전체 발생횟수로 나눈 것이다.
다음의 식(5),(6)은 파라미터 적용을 위한 텍스쳐 정보를 구하기 위한 확률 분포를 구하기 위한 식이다.

$$p_{ij} = \frac{d_{ij}}{N} \quad (3)$$

$$N = \sum_{i=1}^n \sum_{j=1}^n D_{ij} \quad (4)$$

따라서, 이러한 통계적 변수 행렬 p_{ij} 를 이용하여 특징 추출함으로서 텍스쳐 정보를 구할 수 있게된다.

2.3. 텍스쳐 정보를 얻기 위한 파라미터

2.3.1 자기 상관 관계(Auto-correlation)

자기 상관 관계는 식(2) 와 같이 각각의 픽셀 i 와 j 간의 그레이-레벨 변화에 따른 평균과 분산에 의한 연산으로 표현된다. m_i 와 m_j 는 각 픽셀 i 와 j 의 평균을 나타내며, σ_i 와 σ_j 는 분산을 나타낸다.

$$m_i = \sum_{i=1}^n \sum_{j=1}^n i p_{ij} \quad (5)$$

$$m_j = \sum_{i=1}^n \sum_{j=1}^n j p_{ij} \quad (6)$$

$$\sigma_i = \sqrt{\sum_{i=1}^n \sum_{j=1}^n i^2 p_{ij} - m_i^2} \quad (7)$$

$$\sigma_j = \sqrt{\sum_{i=1}^n \sum_{j=1}^n j^2 p_{ij} - m_j^2} \quad (8)$$

$$P_{auto} = \frac{\left\{ \sum_{i=1}^n \sum_{j=1}^n (ij p_{ij}) - m_i m_j \right\}}{\sigma_i \sigma_j} \quad (9)$$

P_{auto} 는 각 그레이레벨간의 종속적인 관계를 나타내며, 규칙적인 패턴이나 적은 노이즈를 가지는 영상에서 큰 값을 가진다.

2.3.2 엔트로피(Entropy)

엔트로피는 그레이레벨 이미지 분포의 랜덤한 변화를 나타내며 0에서 $\log_2 n$ 사이의 범위를 가진다. 이 수치는 확률 분포 매트릭스 p_{ij} 에서 영상이 가지는 그레이레벨의 차이가 동일한 경우 가장 큰 값을 갖는다.

$$P_e = \sum_{i=1}^n \sum_{j=1}^n D_{ij} \log_2 D_{ij} \quad (10)$$

2.3.3 역모멘트(Inverse difference moment)

이 값은 확률 분포 매트릭스 각 요소들의 분산 정도 즉, 명암의 차이를 나타낸다. 곧, 영상의 픽셀에서 가장 큰 명암의 차이를 나타내는 곳에서 가장 작은 값을 갖는다.

$$P_{im} = \sum_{i=1}^n \sum_{j=1}^n \frac{D_{ij}}{(i-j)^2} \quad (11)$$

2.4. 뉴럴 네트워크 분류기 구성

위에서 제안한 파라미터들을 사용해 구성한 뉴럴 네트워크 분류기는 3개의 입력과 7개의 중간층 그리고, 6개의 출력을 갖도록 구성하였다. 사용한 뉴럴 네트워크는 백프로퍼제이션 알고리즘을 사용하였고, 학습은 20000 epoch를 수행하였으나 그 이전에 만족할 만한 최소 오차(MSE)

:0.001)가 출력되면 학습을 중지하였고, 중간층과 출력층의 활성함수로는 로그-시그모이드 함수를 사용했고, 분류된 결과는 10번 실험 결과의 평균치를 사용하였다.

2.5. 시뮬레이션 및 결과

실험에 사용한 데이터는 Slip mark, Black line mark, Roll mark, Hole mark, scale mark, Fork mark의 6가지 흠으로서 사용한 총 데이터 수는 352개로서, 학습으로 204개, 테스트로 148개의 데이터를 사용하였다. 사용한 흠 데이터의 대표적 모양은 다음과 같다.

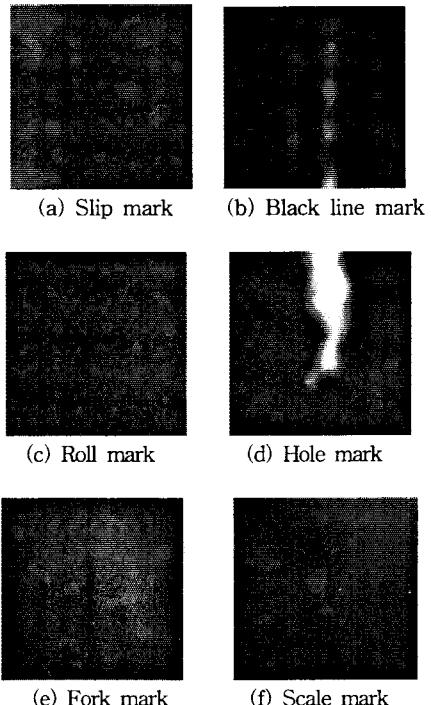
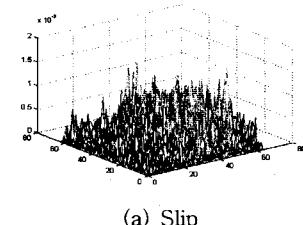
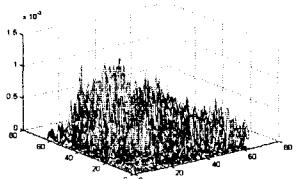


그림 1. 6가지 종류의 냉연 표면 흠 데이터

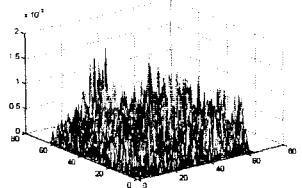
흡 데이터의 특성은 불균일(nonuniformity),비정형(irregularity) 적이고 동일 종류의 흠이라 하여도, 때때로 변화가 심하다. 또한 특정 조건에서는 조명의 영향으로 인하여 영상의 가운데 부분이 밝게 보이고, 주변부가 어둡게 보이는 현상이 발생한다. 이러한 특성은 특징 추출에 영향을 줄 수 있으므로, 전처리 과정을 통해 배경상의 잡음을 제거하여 조명의 영향으로부터 조건을 고르게 하는 과정을 거쳤다.
전처리 과정을 수행 후 특징을 추출하기 위한 확률 분포 행렬을 계산하여 나타내면 다음과 같은 모양으로 표면 정보들이 집중되어 있음을 알 수 있다.



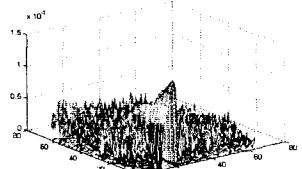
(a) Slip



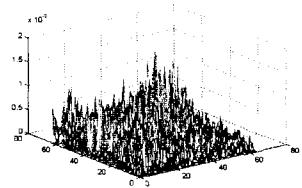
(b) Black line



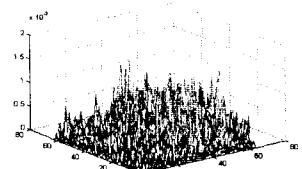
(c) Roll



(d) Hole



(e) Fork



(f) Scale

그림 2. 6가지 샘플의 특징 분포

실험결과에 대한 분류율은 다음의 식으로서 산출하였다. 여기서 분류율(classification rate) C_r 은 실험에 사용된 전체 데이터 개수 N 과 정인식된 개수를 C , 그리고 오인식된 개수를 E 로 정의하여 다음의 식(12)을 사용하였다.

$$C_r(\%) = \frac{N-E}{N} = \frac{C}{N} \quad (12)$$

표1. 기존 알고리즘과의 분류 결과 비교

	기존 알고리즘	제안한 알고리즘
학습 집합	93.3%	96.45%
테스트 집합	84.7%	90.23%

표2. 분류 결과(학습집합)

클래스	assigned class						분류율	홈명칭
	1	2	3	4	5	6		
1	53	1		1			96.36%	Slip mark
2		28	1				93.1%	Black line
3		1	35				97.2%	Roll mark
4	1			35			97.2%	Hole mark
5				1	19		95%	Scale mark
6					1	27	96.4%	Fork mark
total rate							96.45%	

표3. 분류 결과(테스트집합)

클래스	assigned class						분류율	홈명칭
	1	2	3	4	5	6		
1	27	1		2			90%	Slip mark
2	1	20	1				90.91%	Black line
3		1	22	2			88%	Roll mark
4	1	1		23			92%	Hole mark
5		1		1	18		90%	Scale mark
6				1	1	19	90.48%	Fork mark
total rate							90.23%	

3. 결 론

본 연구에서는 광강도차와 신경망을 이용하여 흠을 검출 및 판별할 수 있는 알고리즘을 제시하였고, 그에 따르는 고속 냉연 흠 검사 장치에 적용할 수 있는 가능성을 제시하였다. 고전적인 방법에서의 불완전한 분류결과에 비해 흠의 내용까지 제시해줌으로서 표면검사의 새로운 방향을 실증으로서 검증된 결과와 같이 제안한 방법의 우수함을 확인하였다. 향후 수행해야 할 과제로는 좀 더 세밀하고 많은 데이터에 대하여 고속 처리시 문제가 될 수 있는 환경에서의 성능향상을 위한 연구라 하겠다.

[참 고 문 헌]

- [1] T. S. Newman and A. K. Jain, "A survey of automated visual inspection," *Computer Vision and Image Understanding*, Vol. 61, no. 2, pp. 231-262, Mar. 1995
- [2] C. Wang, D. J. Cannon, S. R. T. Kumara, and G. Li, "A skeleton and neural network based approach for identifying cosmetic surface flaws," *IEEE Trans. on Neural Networks*, vol. 6, no. 5, pp. 1201-1211, 1995
- [3] A. Ercil, "Automated visual inspection of painted metallic surfaces," *Internat. Conf. on Automation, Robotics and Computer Vision*, pp. 1950-1954, 1994
- [4] F. Treiber, "On-line automatic defect detection and surface roughness measurement of steel strip," *Iron and Steel Engineer*, pp. 26-33, 1989
- [5] D. C. Heand, L. Wang, "Unsupervised textual classification of image using the texture spectrum," *Pattern Recognition*, vol. 25, no. 3, pp. 247-255, 1992