

영상처리와 SVM을 이용한 Billet의 스크래치 결함 분류

Classifying Scratch Defects on Billets Using Image Processing and SVM

이 상 준, 김 상 우*
(Sang Jun Lee¹ and Sang Woo Kim¹)
¹POSTECH

Abstract: In the steel manufacturing area, researches for defect inspection receive a big attention for quality control. This paper proposes an algorithm to detect a scratch defect on steel billets. This algorithm takes ROIs (Regions of Interest), and extracts 11 features which represent properties of defect on a ROI. SVM (Support Vector Machine) is used to classify defect and normal ROIs. The algorithm classifies a frame image of a Billet as a defect image if there is one or more defect ROIs. In the experiments, the proposed algorithm had reliable classifying accuracy.

Keywords: steel, defect detection, automation, inspection system, image analysis

I. 서론

최근 반도체 및 디스플레이 제조 공정 분야를 비롯하여 여러 분야에서 품질제어를 위한 결함탐상과 시스템의 고장을 진단하기 위한 연구가 활발히 이루어지고 있다[1-4]. 철강 산업분야 또한 결함탐상의 자동화를 위한 연구가 주목 받고 있으며 영상처리를 이용하여 철강제품의 표면 결함을 찾는 연구가 진행된 바 있다. 다른 분야와 달리 철강분야는 철강제품 자체가 가지는 특징인 scale이라는 결함과 유사한 모양의 산화 물질이나 표면의 불균등성 때문에 결함탐상에 어려움이 있다. 또한, 철강제품의 종류마다 제조공정이 달라 철강표면의 특징 및 발생하는 결함이 다르다. 기존 연구로서 필터 설계를 통하여 BIC (Bar in Coil) 표면의 crack 등의 결함을 검출 하였으며[5], 최적화와 Gabor filter를 이용하여 Billet 표면의 결함을 검출하는 알고리즘이 제안된 바 있다[6]. 또한 Billet 표면 결함을 탐상하기 위해 wavelet transform과 수직투영 프로파일을 이용한 문턱치 기법이 제안되었다.

기존의 결함탐상 관련 연구는 결함의 특징을 분석하여 필터를 설계하거나 적절한 문턱치를 설정하여 이진화 하는 방법에 대해 주로 다루어져 왔다. 본 논문에서는 결함의 특성을 수치화 하고 이를 학습시켜 스크래치 결함을 탐상하는 방법에 대해 소개한다.

먼저 II 장에서는 Billet의 제조과정 중 영상을 얻는 시스템에 대한 설명과 이로부터 얻은 영상 및 찾고자 하는 결함에 대해 설명하고, III 장에서 Billet의 스크래치 결함을

찾기 위한 알고리즘을 제안 할 것이다. IV 장에서는 실험 결과를, V 장에서는 본 논문의 결론에 대해 논한다.

II. Billet 영상 분석

Billet은 길이가 약 10m이고, 단면은 160×160mm의 모서리가 둥근 사각형인 철강제품이다. 제조과정 중 2m/s의 속력으로 이동하며 압연되는데, 이 과정에서 스크래치 결함이 빈번하게 발생한다. 이러한 Billet을 네 방향에서 라인카메라를 이용하여 표면영상을 얻었다. 공정에서 사용된 라인카메라의 스펙은 0.5mm/line이며, 하나의 라인에 1024 픽셀씩




그림 1. Billet의 표면영상 촬영 시스템.

Fig. 1. Camera system for Billet surface images.




그림 2. Billet의 표면 영상.

Fig. 2. Surface image of Billets.

* 책임저자(Corresponding Author)

논문접수: 2012. 12. 4., 수정: 2013. 1. 30., 채택확정: 2013. 2. 5.

이상준: POSTECH, 전자전기공학과(lsj4u0208@postech.ac.kr)

김상우: POSTECH, 창의IT융합공학과, 전자전기공학과

(swkim@postech.ac.kr)

※ This research was supported by the MKE (The Ministry of Knowledge Economy), Korea, under the "IT Consilience Creative Program" support program supervised by the NIPA (National IT Industry Promotion Agency) (C1515-1121-0003).




그림 3. 스크래치 결함의 예시.

Fig. 3. Example of scratch defects.

저장하여 1600개의 라인을 프레임 영상으로 저장하였다.

카메라 시스템으로부터 얻은 Billet의 표면영상은 8-bit 흑백의 1024×1600 픽셀로 이루어져 있으며, 배경을 제외한 실제 Billet은 약 540 픽셀의 너비를 가진다. 그림 2의 왼쪽 영상에서 보이는 얼룩은 scale이라는 산화물질로, 제품의 후처리 과정에서 제거되어 결함으로 분류되지 않는다. 또한 오른쪽 영상에 보이는 색깔의 경계는 Billet의 모서리가 둥근 특징으로 인한 밝기 차이 때문이다. 이렇게 Billet 표면의 결함을 찾는 데에는 다른 분야가 가지는 결함탐상의 어려움 외에도 scale이라는 결함과 유사한 특징을 갖는 물질이나 밝기의 불균등성 때문에 시스템의 정확도가 떨어지곤 한다.

본 논문에서 탐상하고자 하는 스크래치 결함은 세로방향으로 150 픽셀(약 7.5cm) 이상의 길이로 나타나 직진성이 강하며, 그 너비가 8~13 픽셀정도로 다양하다는 특징을 가진다. 또한 하나의 영상에 여러 개의 스크래치가 나타날 수 있으므로 이 점을 고려하여야 한다. 영상에 나타나는 결함은 보통 주변부분보다 밝기가 어둡기 때문에, 결함이 있는 부분은 밝기의 이중경계가 나타난다. 위 그림은 결함이 있는 프레임 영상이다.

III. PROPOSED ALGORITHM

앞서 설명한 Billet영상에 나타나는 불균등한 밝기나 scale에 의한 영향을 줄이기 위해 원본 영상이 아닌 작은 영역에 대하여 결함의 특성을 수치로 표현하고 분류기를 적용하였다. 먼저 원본영상에서 Billet부분을 segmentation한 뒤 이 segmentation 된 영상들을 sub-image들로 나누었다. sub-image 중 결함이 있을 것이라 예상되는 부분을 관심영역으로 선정하고 미리 결함과 비결함으로 분류한 관심영역들을 이용하여 SVM (Support Vector Machine)을 학습시켰다. 실제 공정에서는 입력 영상에서 관심영역들을 찾은 뒤, 이를 offline으로 학습시킨 SVM을 이용하여 결함과 비결함으로 분류하였다. 입력영상에 결함 관심영역이 존재할 경우 이를 결함 영상으로 결정하였다. 이 과정에 대한 자세한 내용은 아래와 같다.

1. Segmentation

1.1 영상의 위·아래 segmentation

다음 그림과 같이 Billet의 끝에 해당하는 영상에는 위




그림 4. Billet 영상의 위·아래 배경 segmentation.

Fig. 4. Segmentation of top/bottom background images.

혹은 아래 부분에 배경이 찍히는데, 먼저 이 부분을 고려해 주고자 한다.


이를 위해 가로 방향으로 픽셀값의 합을 구해 실험적인 문턱값으로 영상의 위·아래에 있는 배경을 찾았다. 스크래치의 경우 Billet의 끝 부분에는 거의 나타나지 않고, Billet 끝 부분의 영상이 흐리거나 휘어진 경우가 많다. 이에 200 픽셀(약 10cm)의 영상을 잘라 segmentation 하였다.

1.2 가이드로 인한 흰색 띠 제거

영상에는 Billet의 좌우에 제조공정 중 Billet의 이동을 돕는 가이드로 인한 흰색의 띠가 발생하곤 하는데, 이 띠가 영상에 나타나는 Billet의 경계를 찾는 데에 어려움을 주는 요인이 된다. 이를 고려하기 위해 앞에서 위·아래 부분을 잘라낸 영상의 수직투영 프로파일을 thresholding하여 그룹화해주고, Billet이 영상 가운데에 위치한다는 정보를 이용하여 Billet이 위치한 인덱스들을 찾았다.

1.3 좌·우 segmentation

Billet은 영상위에 휘어진 모양으로 나타날 수 있기 때문에, 프로파일 정보로 구한 인덱스는 조금씩 오차가 있다. 이에 위에서 찾은 Billet의 경계점을 local 영역으로 잡고 그 부분에서 각 라인의 실제 Billet의 경계를 dynamic path algorithm을 이용하여 찾았다. Dynamic path algorithm은 weighted graph의 shortest path를 찾기 위한 그래프 분석 방법이다. 1.2에서 찾은 Billet의 경계 부근에서 각 라인에 차



(a) Guide for moving Billet.

(b) The result of segmentation.

그림 5. Billet 이동을 돕는 가이드와 segmentation 최종 결과.

Fig. 5. Guide for moving Billet and the result of segmentation.

분필터를 적용하면 Billet의 경계점에서 그 값이 커진다. local area에서 찾은 Billet 경계에서 차분필터의 결과 값이 큰 점을 따라 아래로 내려가며 인덱스를 저장함으로써 각 라인에서의 Billet 경계점을 찾을 수 있다.

1.4 Line merging

스크래치의 경우 Billet의 좌우 경계에서는 거의 발생하지 않고, 각 라인에서 앞서 구한 Billet 부분의 길이가 다를 수 있다. 이에 프레임 영상에서 앞서 구한 각 라인의 Billet 부분 길이의 평균을 구하고, 이 평균에서 좌우 10 픽셀씩 제외한 부분에 대해 각 라인의 Billet영역을 merging 하였다.

2. 관심영역 선정

Billet의 스크래치 결함은 직진성이 강해 보통 150 픽셀 (약 4cm) 이상으로 나타난다. 이에 앞에서 segmentation 한 영상을 세로 350 픽셀의 간격으로 100 픽셀씩 오버랩 하여 sub-image를 만들었다. 각 sub-image에서 결함의 특성을 이용하여 관심영역을 찾았다.

스크래치 결함은 주변부분과 밝기차이가 커서 이중경계가 발생하고 결함의 너비가 보통 8~13 픽셀 정도로 나타나는 특징을 보인다. 하나의 sub-image에서 이러한 결함 특성을 노이즈 영향을 덜 받으며 관찰하기 위해 수직투영 프로파일을 분석하였다.

먼저 표준편차가 3이고 크기가 35 픽셀인 가우시안 필터로 수직투영 프로파일을 스무딩 하였다. 그림 7은 sub-image의 수직투영 프로파일(blue)과 이를 스무딩한 결과(red)의 예시를 보여준다.

결함 특성을 관찰하기위해 수직투영 프로파일과 그 스무딩 결과의 차이를 구하였다. 이렇게 수직투영 프로파일과 그 가우시안 스무딩 결과의 차이를 이용하는 것은 일종의

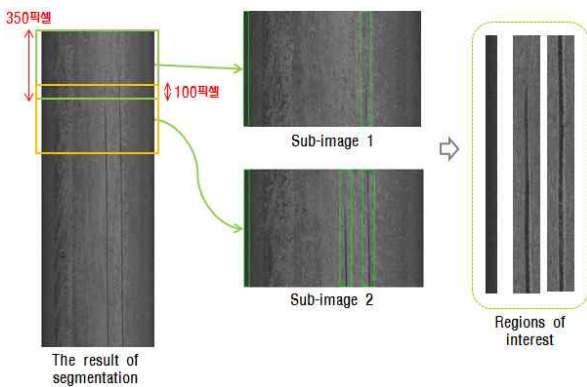


그림 6. 관심영역 선정 과정.

Fig. 6. Procedure for selecting regions of interest.




그림 7. 수직투영 프로파일(blue) 및 그 스무딩 결과(red).

Fig. 7. Vertical projection profile and its smoothing version.





그림 8. 스무딩 한 차분가우시안 결과에 문턱치기법 적용.

Fig. 8. Thresholding the smooth version of DoG.



(a) Non-defect ROIs.

(b) Defect ROIs.

그림 9. 결함 및 비결함 관심영역들의 예시.

Fig. 9. Defect and non-defect ROIs (Regions of Interest).

차분가우시안필터(DoG: Difference of Gaussian)를 적용하는 것과 동일하며, 경계를 가지는 결함영역에서 그 값이 커짐을 볼 수 있다. 노이즈 영향을 줄이기 위해 3.3의 가우시안 필터로 차분가우시안 필터의 결과를 스무딩하고 실험적인 수치로 문턱치 기법을 적용하여 결함 후보군(관심영역)을 선정하였다.

이와 같은 방법으로 sub-image에서 결함의 위치를 찾아낸 후 그 주변에 적당한 마진을 주어 선정한 관심영역들의 예시는 아래와 같다.

3. 결함특성수치 추출

이번 단계는 SVM을 이용하여 입력영상에서 선정한 관심영역들을 학습 및 분류하기 위해 결함특성들을 수치로 추출해 내는 과정이다. 각 관심영역에서 11가지 결함특성 수치를 추출 하였다.

본격적으로 결함특성 수치를 위한 식에 대해 설명하기 전에, 결함의 경계특성을 수치화 하는데에 사용한 엣지 검출 필터를 소개하고자 한다. 엣지를 검출하는 데에는 라플라시안이나 소벨필터 등이 많이 사용된다. 하지만 Billet의 경우 노이즈 성분이 많아 결함수치를 추출할 때에도 수직투영 프로파일에 대한 분석이 많이 행해지므로, 아래와 같은 1차원 엣지검출 필터를 정의하여 사용하였다.

$$H = [-1 -3 0 3 1] \tag{1}$$

소벨필터와 모양이 비슷한 이 필터는 소벨필터와 같이 경계의 오른쪽이 밝은지 어두운지 부호로 판별할 수 있다는 동시에 1차원 데이터에 적용 가능하다.

다음으로 수식에 쓰인 기호들에 대해 설명한다. 수식에서 F 는 입력 영상 위 하나의 관심영역을, H 는 위에서 설명한 엣지 검출필터를, $G_1 \cdot G_2 \cdot G_3$ 은 표준편차 1.82-3.3의 가우시안 필터를 의미한다. 또한 수식에 쓰이는 “*” 기호는

표 1. 관심영역의 결함특성 수치.

Table 1. Measures for detecting defects in a ROI.

| 수치 | 수식 | 비고 |
|-------|--|-----------------|
| 수치 1 | $\max(F^*H^*G_1)$ | 엣지 검출 반응도 |
| 수치 2 | $\min(F^*H^*G_1)$ | |
| 수치 3 | $abs(\text{수치1}) - abs(\text{수치2})$ | |
| 수치 4 | $\max(F^*H^*G_2)$ | |
| 수치 5 | $\max(F^*H^*G_3)$ | |
| 수치 6 | $\frac{1}{N(D)} \sum_{p \in D} p$ $\frac{1}{N(B)} \sum_{p \in B} p$ | 결함과 배경 부분의 밝기 비 |
| 수치 7 | $m = \sum_{i=0}^{L-1} i P(i)$ | 평균 밝기의 척도 |
| 수치 8 | $\sigma = \sqrt{\frac{1}{N} \sum_{i=0}^{L-1} (i-m)^2}$ | 평균 대비의 척도 |
| 수치 9 | $R = 1 - \frac{1}{1 + \sigma^2}$ | 평탄도 |
| 수치 10 | $U = \sum_{i=0}^{L-1} P(i)^2$ | 균일도 |
| 수치 11 | $e = - \sum_{i=0}^{L-1} P(i) \log_2 P(i)$ | 엔트로피 |




그림 10. 결함특성수치 1,2 계산 과정.

Fig. 10. The 1st & 2nd defect characteristic measures.

convolution을 의미하는 기호로서 필터링을 의미한다. 수식에서 i 는 그레이 레벨을 의미하며, L 은 8bit 흑백영상을 다루므로 256의 숫자가 된다.

먼저 1~5번의 결함특성 수치는 결함으로 인한 이중경계를 찾기 위하여 엣지 검출 필터 H 를 이용하여 수치화 한 것이다. 1,2번 수치의 경우 아래그림과 같이 관심영역의 수직투영 프로파일을 H 로 필터링하고 G_1 으로 스무딩하여 최댓값과 최솟값을 구한 것이다.

일반적인 결함의 경우 결함의 좌우 경계의 뚜렷한 정도가 비슷하며, 그 경계가 뚜렷할수록 1번과 2번 결함특성수치의 크기가 커진다. 3번수치는 1번과 2번수치 절댓값들의 차이를 구하였으며, 결함과 같이 이중경계가 있는 부분에서는 그 값이 0에 가까워지고 경계가 있더라도 그 경계가 하나인 경우 수치가 커진다. 4번과 5번 결함특성수치에서는 배경성분 대비 결함 경계의 뚜렷한 정도를 파악하기 위해 여러 표준편차의 가우시안 필터를 사용하였다.

6번 수치는 관심영역을 선정할 때 구한 결함 인덱스를 이용하였다. 본 수식에서 D 와 B 는 각각 관심영역 위에서

결함과 배경 부분의 픽셀값들의 집합을 의미하며, $N(A)$ 는 집합 A 의 원소 개수이다. 결함부분에 해당하는 평균 그레이레벨과 관심영역을 선정할 때 함께 저장한 마진(결함주변의 Billet표면) 부분의 평균 그레이 레벨의 비를 이용하여 구하였다. 관심영역 내에서 결함의 밝기가 주변에 비해 어두울수록, 6번 수치의 비가 커지게 된다.

7~11번 수치는 히스토그램에 기반한 결함의 특성을 수치화 한 것이다. 7과 8번은 관심영역 그레이레벨의 평균 및 표준편차를 의미하고, 9번은 평탄도로 관심영역 밝기의 부드러운 정도를 나타낸다. 9번 수치는 그레이레벨의 표준편차가 커짐에 따라 0에서 1에 가까워지며, 균일도를 나타내는 10번 수치는 모든 그레이레벨이 동일할 때 최대가 된다. 11번은 엔트로피를 의미하며 그레이레벨의 무작위성을 나타낸다.

4. Support Vector Machine 학습

SVM (Support Vector Machine)은 구조적 리스크를 최소화(structural risk minimization)하여 두 그룹간의 최적 마진(maximal margin)을 갖는 분류기를 찾는다. 통계적 학습 기법을 이용한 SVM은 기존의 뉴럴 네트워크 등의 분류기와 달리 에리(generalization error)의 상한값(upper bound)를 최소화(minimize)한다. 따라서 샘플 개수가 적은 환경에서 뉴럴 네트워크 등과 같이 empirical 리스크를 최소화하는 분류기보다 우수한 성능을 보인다고 알려져 있다[8]. 철강영상의 경우 비결함 영상의 샘플은 쉽게 구할 수 있지만 결함 영상의 경우 구할 수 있는 샘플의 수가 상대적으로 적어 일반적으로 분류기를 학습하는 데에 어려움이 있다. 이러한 어려움을 극복하고자 적은 샘플수의 환경에서 상대적으로 좋은 성능을 보이는 SVM을 적용하고자 한다. 먼저 기본적인 SVM 분류기는 아래와 같은 최적화 문제로 구성된다[9].

$$\begin{aligned} & \text{minimize}_{\mathbf{w},b} \quad \frac{1}{2} \|\mathbf{w}\|^2 \\ & \text{subject to} \quad y_i(\mathbf{w}^\top \mathbf{x}_i + b) \geq 1, \quad \forall i \end{aligned} \quad (2)$$

위의 최적화 문제는 분류하고자 하는 두 데이터가 하이퍼플레인(hyperplane)으로 분류 될 때 사용할 수 있다. 관심영역에서 결함특성수치들을 추출하여 벡터로 구성된 뒤 살펴보면 보통의 경우 결함과 비결함 관심영역들의 결함특성수치들이 직선으로 분류되지 않는다. 또한 보통의 경우 비결함 관심영역보다 결함 관심영역의 수가 상대적으로 적으므로 아래와 같은 데이터의 중요도 및 개수를 고려한 CSVM을 사용하였다[10].

$$\begin{aligned} & \text{minimize}_{\mathbf{w},b,\epsilon} \quad \frac{1}{2} \|\mathbf{w}\|^2 + C_1 \sum_{i \in C_1} \epsilon_i + C_2 \sum_{i \in C_2} \epsilon_i \\ & \text{subject to} \quad y_i(\mathbf{w}^\top \mathbf{x}_i + b) \geq 1 - \epsilon_i, \quad \epsilon_i \geq 0, \quad \forall i \end{aligned} \quad (3)$$

본 논문에서 사용한 C_1 과 C_2 의 값은 아래와 같으며, N 은 총 training 데이터의 개수를, N_1 과 N_2 는 각각 결함 및 비결함 training 관심영역의 개수를 의미한다.

$$C_1 = \frac{N}{2N_1}, \quad C_2 = \frac{N}{2N_2} \quad (4)$$

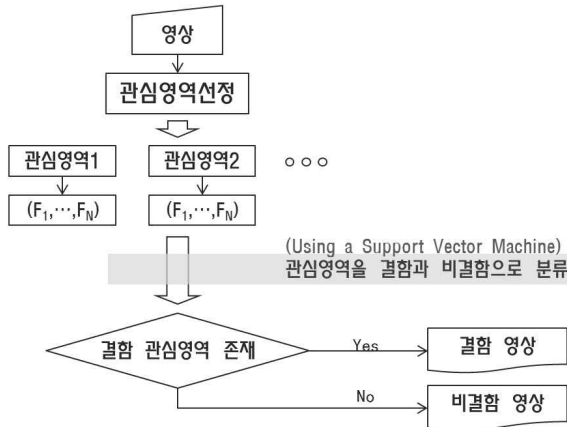


그림 11. 알고리즘 다이어그램.

Fig. 11. Diagram of the proposed algorithm.

학습을 통한 분류기를 구성할 때에는 일반적으로 학습(training)과 확인(validation) 과정을 반복하며 학습시킨다. 한번만 학습하여 최적 분류기를 구성할 경우, 분류기의 일반성(generalization performance)이 떨어져 학습시킨 데이터 외에 다른 데이터에 대한 성능이 떨어질 수 있기 때문이다. 본 논문에서는 139개의 결함이 있는 관심영역과 611개의 비결함 관심영역을 무작위로 50%씩 나눠 두 그룹으로 구성된 뒤 학습 및 확인을 반복하였다. 이에 대한 결과는 IV장에서 보인다.

5. 입력 영상 분류

새로운 입력영상에 대하여 앞장과 같이 segmentation 후 관심영역들을 선정하고, 이 관심영역에서 결함특성 수치를 계산하여 미리 학습시킨 SVM으로 분류한다. 입력영상위에 결함 관심영역이 있을 경우 결함 영상으로 분류하였다. 이 과정에 대한 다이어그램은 위와 같다.

IV. EXPERIMENTAL RESULTS

1. 알고리즘 평가 방법

알고리즘의 정확도는 sensitivity와 specificity를 이용하여 평가하였으며, 아래와 같이 정의된다.

$$sensitivity = \frac{TP}{TP + FN} \tag{5}$$

$$specificity = \frac{TN}{TN + FP} \tag{6}$$

$$accuracy = \frac{TP + TN}{TP + FP + FN + TN} \tag{7}$$

위 식에서 TP (True Positive)는 실제 결함영상을 결함이라고 분류한 개수를, FN (False Negative)는 실제 결함영상인데 비결함영상이라 분류한 개수를 의미한다. 마찬가지로 TN (True Negative)는 실제 비결함 영상을 비결함이라 분류한 개수를, FP (False Positive)는 실제 비결함 영상을 결함이라 분류한 개수이다.

2. SVM 분류기 학습결과

다양한 결함이 포함된 56장의 결함 프레임 영상과 65장의 비결함 프레임 영상을 학습하기 위한 영상으로 선정하

표 2. 관심영역 학습 및 확인 결과.

Table 2. Training and validation result for ROIs.

| (개수) | 학습(training) | | 확인(validation) | | 합계 |
|------|--------------|----|----------------|----|-----|
| | 성공 | 실패 | 성공 | 실패 | |
| 결함 | 66 | 3 | 64 | 6 | 139 |
| 비결함 | 304 | 2 | 301 | 4 | 611 |

표 3. 관심영역 분류에 대한 평가.

Table 3. Evaluation for the classification of ROIs.

| (%) | 학습(training) | 확인(validation) |
|-------------|--------------|----------------|
| sensitivity | 95.65 | 91.43 |
| specificity | 99.35 | 98.69 |
| accuracy | 98.67 | 97.33 |

였다. 관심영역 선정 알고리즘을 적용하여 750개의 관심영역을 모았으며, 이를 결함과 비결함으로 분류하여 SVM 분류기를 학습시키는 데에 사용할 139개의 결함 관심영역과 611개의 비결함 관심영역을 얻을 수 있었다.

139개의 결함 관심영역과 611개의 비결함 관심영역에서 각각 50% 비율로 학습(training) 및 확인(validation)을 위한 집합을 구성하였다. 여러 번 SVM을 학습 및 확인 시키는 cross-validation 과정을 통하여, 학습 및 확인결과의 sensitivity 및 specificity가 모두 90% 이상이 될 때까지 무작위로 집합을 구성하여 위 과정을 반복하였다. 이와 같은 cross-validation 과정을 통해 얻은 학습 및 확인 결과 및 그 정확도는 아래와 같다.

3. 알고리즘 결과영상

그림 12는 제안하고자 하는 알고리즘의 입력 프레임 영상과 이에 대한 출력영상의 예시이다.

4. Billet 영상에 대한 정확도 분석

한 개의 Billet 제품은 여백을 포함하여 84개의 프레임 영상으로 표현된다. 40개의 Billet 제품으로부터 얻은 3360장의 프레임 영상을 이용하여 제안하고자 하는 알고리즘의 성능을 평가해 보았다. 앞서 cross-validation 과정을 통해 얻은 SVM 분류기를 이용하였으며, 그 결과는 다음 표와 같다.




그림 12. 알고리즘 결과 영상.

Fig. 12. Result image of the proposed algorithm.

표 4. Billet 영상에 대한 알고리즘 테스트 결과.

Table 4. Classification result for Billet images.

| (개수) | 성공 | 실패 | 합계 |
|------|------|----|------|
| 결함 | 2707 | 76 | 2783 |
| 비결함 | 548 | 29 | 577 |

표 5. Billet 영상에 대한 알고리즘 평가.

Table 5. Evaluation for classification of Billet images.

| | |
|-------------|---------|
| sensitivity | 97.27 % |
| specificity | 94.97 % |
| accuracy | 96.88 % |

V. 결론

본 논문에서는 철강제품 중 하나인 Billet 영상위의 스크래치 결함을 찾는 알고리즘을 제안한다. 본 논문의 가장 큰 특징은 결함이 있을 것이라 추측되는 후보군을 관심영역으로 선정하여, 이 관심영역에 대하여 분류기를 적용하는 것이다. 관심영역을 분류하기 위해 CSVM 알고리즘을 사용하였으며, 11가지의 결함의 특성을 표현하는 결함특성수치를 사용하였다. 실제로 공정에 적용할 때에는 offline에서 학습시킨 SVM분류기를 입력영상위의 관심영역들에 적용하여 결함 관심영역의 유무를 판별함으로써 Billet영상의 결함유무를 알 수 있다.

본 논문에서는 관심영역 결함의 특징을 관찰하기 위해 11가지의 결함특성수치를 적용하였지만, 좀 더 많은 결함특성수치를 적용함으로써 알고리즘의 성능을 올릴 수 있을 것이다. 예를 들어 결함의 너비가 다양하기 때문에, 이를 고려하기 위해 다양한 표준편차의 차분가우시안필터를 적용할 수 있을 것이다. 이렇게 많은 수의 결함특성 수치를 사용한다면 SVM 분류기의 입력 데이터의 차원(dimension)이 커지겠지만, SVM은 입력 데이터의 내적 정보만을 이용하여 분류기를 결정하므로 학습하는 데에 걸리는 시간은 크게 늘어나지 않을 것이다.

실제 철강제조공정의 영상을 이용하여 테스트 해 본 결과, 제안하고자 하는 알고리즘이 Billet표면의 스크래치 결함을 탐상하는데 있어 믿을만한 성능을 보임을 확인할 수 있었다.

참고문헌

[1] Y. Zhang, J.-S. Lee, H. Joo, and J.-S. Kim, "Pattern partitioning and decision method in the semiconductor chip marking inspection," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 16, no. 9, pp. 913-917, 2010.

[2] D. Park, H. Joo, and K.-H. Rew, "Automatic extraction of size for low contrast defects of LCD polarizing film," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 14, no. 5, pp. 438-443, 2008.

[3] C.-J. Kim, K.-J. Yoo, H.-S. Kim, and J. Lyoo, "Fault detection method of laser inertial navigation system based on the overlapping model," *Journal of Institute of*

Control, Robotics and Systems (in Korean), vol. 17, no. 11, pp. 1106-1116, 2011.

[4] I. S. Lee, J. H. Cho, H. M. Seo, and Y. S. Nam, "A Study on a fault detection and isolation method of non-linear systems using SVM and neural network," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 18, no. 6, pp. 540-545, 2012.

[5] J. P. Yun, S. H. Choi, B. Seo, and S. W. Kim, "Real-time vision-based defect inspection for high-speed steel products," *Optical Engineering*, vol. 47, no. 7, pp. 077204-, July 2008.

[6] J. P. Yun, S. H. Choi, J.-W. Kim, and S. W. Kim, "Automatic detection of cracks in raw steel block using Gabor filter optimized by univariate dynamic encoding algorithm for searches (uDEAS)," *NDT & E International*, vol. 42, no. 5, pp. 389-397, July 2009.

[7] J. P. Yun, S. H. Choi, and S. W. Kim, "Vision-based defect detection of scale-covered steel billet surfaces," *Optical Engineering*, vol. 48, no. 9, pp. 037205-, March 2009.

[8] H. Byun and S.-W. Lee, "A survey on pattern recognition applications of support vector machines," *International Journal of Pattern Recognition*, vol. 17, no. 3, pp. 459-486, May 2003.

[9] V. Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273-279, Sep. 1995.

[10] K. Veropoulos, C. Campbell, and N. Cristianini, "Controlling the sensitivity of support vector machines," *Proceedings of the International Joint Conference on AI*, pp. 55-60, 1999.

이 상 준



2011년 포항공과대학교(POSTECH) 전자전기공학과(공학사). 2011년~현재 포항공과대학교(POSTECH) 전자전기공학과 석박사 통합과정 재학. 관심분야는 최적화, 기계학습, 패턴인식, 영상처리.

김 상 우



1983년 서울대학교 제어계측공학과(공학사). 1985년 동 대학원 제어계측공학과(공학석사). 1990년 동 대학원 제어계측공학과(공학박사). 1992년~ 2011년 포항공과대학교 전자전기공학과 교수. 2012년~현재 포항공과대학교 창의IT융합공학과/전자전기공학과 교수. 관심분야는 최적제어, 최적화 알고리즘, 지능제어, 공정자동화.