



슈퍼픽셀 DBSCAN 군집 알고리즘을 이용한 용융아연도금 강판의 부식이미지 분석

김범수^a, 김연원^b, 이경황^c, 양정현^{a*}

^a경상국립대학교 기계시스템공학과, ^b목포해양대학교 메카트로닉스공학부, ^c포스코 철강솔루션연구소

Corrosion image analysis on galvanized steel by using superpixel DBSCAN clustering algorithm

Beonsoo Kim^a, Yeonwon Kim^b, Kyunghwang Lee^c, Jeonghyeon Yang^{a*}

^aDepartment of Mechanical System Engineering, Gyeongsang National University, Tongyeong, 53064, Korea

^bDivision of Mechatronics Engineering, Mokpo National Maritime University, Mokpo, 58628, Korea

^cSteel Solution R&D Center, POSCO, Inchen, 21985, Korea

(Received 15 June, 2022 ; revised 20 June, 2022 ; accepted 24 June, 2022)

Abstract

Hot-dip galvanized steel(GI) is widely used throughout the industry as a corrosion resistance material. Corrosion of steel is a common phenomenon that results in the gradual degradation under various environmental conditions. Corrosion monitoring is to track the degradation progress for a long time. Corrosion on steel plate appears as discoloration and any irregularities on the surface. This study developed a quantitative evaluation method of the rust formed on GI steel plate using a superpixel-based DBSCAN clustering method and k-means clustering from the corroded area in a given image. The superpixel-based DBSCAN clustering method decrease computational costs, reaching automatic segmentation. The image color of the rusty surface was analyzed quantitatively based on HSV(Hue, Saturation, Value) color space. In addition, two segmentation methods are compared for the particular spatial region using their histograms.

Keywords : Corrosion; Superpixel; DBSCAN; k-means clustering; HSV color space.

1. 서 론

용융아연도금강판(Hot-dip Galvanized steel, GI)은 우수한 내식 특성으로 인하여 다양한 분야에 널리 사용되고 있다[1,2]. 이러한 아연도금강판은 소재의 수명 유지 및 연장을 위하여 부식 진행 상태를 모니터링 및 추적 관찰할 필요가 있으며, 가장 간단하게 진행할 수 있는 모니터링 법으로써

육안관찰 방법이 있다. 그러나 육안관찰 방법은 검사자의 눈에 의한 평가방법으로 검사자의 상태에 따라 평가 결과가 달라질 수 있으며, 또한 검사자의 주관적인 관점이 개입될 수 있어 정량적 평가를 기대하기는 힘든 실정이다[3].

이러한 문제점으로 인해 영상처리기술을 이용한 부식 이미지 평가가 많은 관심을 받고 있다[3-6]. 이전 연구에서는 GI 강판 이미지로부터 배경과 샘플을 분리하는 grab-cut[3,7] 방법과 k-means 클러스터링(clustering)[6,8]을 이용해서 영상 이미지로부터 사용자가 지정한 k개만큼 영역을 분할

*Corresponding Author: Jeonghyeon Yang
Department of Mechanical System Engineering,
Gyeongsang National University
Tel: +82-55-772-9107; Fax : +82-55-772-9109
E-mail: jh.yagi@gnu.ac.kr

하였으며, Red, Green, Blue (RGB)로 표현된 색상 영역을 HSV(Hue, Saturation, Value)로 변환 후에 색상 채널인 Hue에 대한 히스토그램으로 나타난 연구결과를 발표하였다.

그러나 k-means 알고리즘의 경우, 적정 k 값을 결정하기가 어려운 단점이 있다. 이로 인해 Elbow Method, Silhouette Score와 같은 다양한 방법을 이용하여 최적의 k 를 구할 필요가 있다[9].

본 연구에서는 GI 강판의 부식 특성을 효율적으로 분석하기 위해서 슈퍼픽셀 기반 DBSCAN(Density Based Spatial Clustering of Application with Noise) 클러스터링과 k-means 클러스터링 기법을 적용하여 부식 이미지를 비교 분석하였다. 일반적으로 강판에서의 부식 형태는 불규칙하며 다양한 계통의 색상이 혼재되어 있는 것이 특징이다. 본 연구에 사용된 영상 이미지는 POSCO에서 서산 한국건설 생활 시험연구원 옥외 폭로 시험장(위도 : $36^{\circ} 55'N$, 경도 : $126^{\circ} 21'E$)에서 6년 동안 노출 시킨 두께 1.6mm, 도금량 $180g/m^2$ 의 GI 강판의 절단면(cut-edge section) 영역을 이용하였으며 1 ~ 6년간 절단면에서의 부식 진행 과정을 분석하였다. 옥외 폭로 시험장의 경우, 연 평균 온·습도 $11.8^{\circ}C$, 75.4%RH, 연 강수량·일사량 1,232mm, $2.749MU/m^2$, 해안으로부터의 거리 200m, 기후 분류는 해양 및 공업기후, 해발 6.5m에 위치하고 있다.

부식된 GI 강판으로부터 부식 영역 분리에는 grab-cut을 이용하였다. 또한 영상 이미지로부터 k-means 클러스터링을 이용해서 k 개만큼 영역을 분할 하였으며, Hue에 대해 히스토그램으로 특정 영역의 색상 분포와 영역 비율을 계산하였다.

영상의 픽셀 수는 영상 크기에 따라 증가하므로 픽셀간의 거리 계산 등, 영상 처리에 소요되는 시간을 단축할 필요가 있다. 슈퍼픽셀은 특징이 비슷한 픽셀들로 구성된 작은 영역을 슈퍼픽셀의 기본 단위로 하면 영상 처리 속도를 매우 빠르게 할 수 있는 장점을 가지고 있다[10]. 분리된 시험편 영상에서 슈퍼픽셀을 구하고 이를 바탕으로 비지도 학습(Unsupervised Learning)기법 중 하나인 DBSCAN을 통해 색상 분포에 따른 분할된 영역을 구하였다.

K-means 방법은 주어진 영상을 몇 개의 영역으로 분할 해야하는 k 값 설정이 매우 중요한 변수이다. 그러나 DBSCAN은 주어진 반경과 클러스

터를 구성할 최소한의 픽셀 개수를 지정하면 거리 함수를 계산하여 유사성을 갖는 클러스터를 유연하게 구축할 수 장점을 가지고 있다. 이러한 특징들을 이용하여, 부식 이미지로부터 k-means와 DBSCAN으로 구한 특정 공간 영역에서 각각의 히스토그램을 비교하였다.

2. 영상 분할

2.1. Grab-cut을 이용한 영상 분할

영상 이미지에서 시험편의 전체 픽셀 수, 색상 등 시험편 특성을 영상처리 기법으로 분석하기 위해서는 주어진 이미지에서 시험편을 분리하는 작업이 선행되어야 한다. 추출하고자 하는 객체(전경, foreground)만을 배경으로부터 분리하는 방법은 객체와 배경을 분리 지정해야 한다[6,7],

Grab-cut은 가우시안 혼합 모델(Gaussian Mixture Model)을 이용하여 사용자 또는 프로그램에서 지정한 배경 영역의 픽셀과 객체가 포함된 영역의 픽셀, 그리고 픽셀이 어느 영역에 속하는지를 나타내는 상태 값 등을 파라미터로 갖는 에너지 함수를 정의한 후에 이 에너지 함수를 최소로 하는 픽셀의 상태 값으로부터 전경을 추출한다. 본 연구에서는 주어진 영상이미지로부터 시험편을 분리하기 위해 영상 최외곽으로부터 일정 간격이 떨어진 직사각형을 프로그램을 적용하여 자동으로 시험편을 추출하였다.

2.2. 최대 내접 사각 영역

주어진 영상에서 grab-cut으로 분리해 낸 영역은 시험편 색상과 배경의 색상의 일부 유사성과 영상 확대 과정에서 경계의 선명도 저하 때문에 볼록(convex)과 오목(concave)한 것이 혼합된 다각형 형태로 검출될 수 있어, grab-cut 된 영역은 시험편의 일부가 잘려 나가거나, 시험편에 접한 배경 일부가 포함될 수 있다. 시험편의 색상 분석은 시험편 전체의 픽셀 수를 기준으로 가능한 배경 부분을 제거하기 위해 grab-cut 된 영역에 내접한 최대 직사각형(the largest inscribed rectangle)을 구하였다[11]. 그리고 최대 내접 사각 영역을 원 영상에서 잘라낸(crop) 영상을 대상으로 분석하였다.

2.3. K-means 클러스터링

K-means 클러스터링은 사용자가 지정한 군집 개수 k 가 지정되면 중심점(centroid) k 개를 임의로 설정한 후 입력 데이터의 각 원소에 대해 유사성을 바탕으로 그 원소가 속한 군집의 중심점까지 평균 거리를 최소화시키는 과정을 일정 오차 범위 내로 수렴할 때까지 반복한다. K-means 클러스터링 과정을 유사코드(pseudo code)로 나타내면 다음과 같다[6,12].

step 0. 입력 데이터 및 군집수 설정

데이터 set : $\{x^{(1)}, x^{(2)}, \dots, x^{(m)}\}, x^{(i)} \in R^n$
 목표 군집 수 : k

step 1. 초기화

: k 개의 중심점(centroid)을 임의로 선정

$$\mu_1, \mu_2, \dots, \mu_k \in R^n \quad (1)$$

step 2. 수렴할 때 까지 반복

for $i = 1$ to m

$$c^{(i)} := \arg_j \min \|x^{(i)} - \mu_j\|^2 \quad (2)$$

for $j = 1$ to k

$$\mu_j := \frac{\sum_{i=1}^m r_{ij} x^{(i)}}{\sum_{i=1}^m r_{ij}} \quad (3)$$

여기서 $\|x^{(i)} - \mu_j\|$ 는 데이터 포인트 $x^{(i)}$ 와 클러스터 중심점 μ_j 간의 유클리드 거리이고, $c^{(i)}$ 는 $x^{(i)}$ 에 가장 가까운 클러스터 중심점의 인덱스, 그리고 μ_k 는 클러스터 k 의 중심점이다. 그리고

$$r_{ij} = \begin{cases} 1 & \text{if } j = \arg \|x^{(i)} - \mu_j\| \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

와 같이 정의할 수 있다.

2.4. 슈퍼픽셀(Superpixel) 방법

영상은 픽셀 격자(pixel grid) 구조로 구성되어 있어, 영상의 크기가 커짐에 따라 전체 픽셀 수는 급격히 증가하여 분할과 같은 영상처리에 있어서

많은 계산 시간이 필요하다. 영상에서 지각적으로 특징이 비슷한 픽셀들로 구성된 작은 영역을 하나의 슈퍼픽셀로 대체하고, 이 슈퍼픽셀을 기본 단위로 영상 처리함으로써 처리 속도를 매우 빠르게 할 수 있다[13,14].

그래프를 이용한 방법, 기울기(gradient) 기반 방법, 학습 기반 방법과 클러스터링 기반 방법 등 슈퍼픽셀을 구하는 많은 방법이 개발되었다[14]. 클러스터링에 기반한 SLIC (Simple Linear Iterative Clustering) 기법은 입력 영상을 공간좌표(x, y)와 Lab 칼라 공간으로 구성된 5차원 공간으로 변환한 후, 영상의 모든 클러스터를 이용하지 않고 정해진 일정 영역 내의 클러스터 정보를 이용하여 슈퍼픽셀을 구하는 방법으로 계산 효율성이 매우 높은 것으로 알려져 있다[13]. SLIC는 주어진 영상을 사용자가 지정한 슈퍼픽셀 개수 k 개로 클러스터링한다. 즉, 영상을 격자 간격이 S 인 k 개 격자로 나누고, 각 클러스터를 $C_k = [L_k, a_k, b_k, x_k, y_k]^T$ 로 초기화 한 후에 가로, 세로 크기가 각각 $2S$ 인 제한된 영역 내에서 다음 알고리즘 1과 같이 슈퍼픽셀을 결정한다.

알고리즘 1 [13]

초기화

- Cluster center : $C_k = [L_k, a_k, b_k, x_k, y_k]^T$
- Label: $l(i) = -1$ for each pixel
- Distance: $d(i) = \infty$ for each pixel

반복 과정

repeat

for each cluster center C_k do

for each pixel i in a $2S \times 2S$ region around C_k do

Compute the distance D between C_k and i

if $D < d(i)$ then

$d(i) = D$

$l(i) = k$

end

end

end

Update: (1) Compute new cluster centers

(2) Compute residual error E

until $E \leq threshold$

알고리즘 1에서 픽셀 i 와 클러스터 센터 C_k 와의 거리는 식 (5)로 주어진다.

$$D = \sqrt{d_c^2 + \left(\frac{d_s}{S}\right)^2 m^2} \quad (5)$$

식 (5)에서 m 은 가중치이고, d_c 와 d_s 는 각각 $2S$ 영역 내에 있는 클러스터 센터 C_k 와 픽셀 간의 Lab 색상 거리(식 (6))와 공간적 거리(식 (7))이다.

$$d_c = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \quad (6)$$

$$d_s = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2} \quad (7)$$

그리고 클러스터 간격 S 는 입력 영상의 총 픽셀 수 N 에 대해서 $S = \sqrt{N/k}$ 로 정해진다.

2.5. 밀도 기반 클러스터링(DBSCAN)

K-means는 주어진 입력 영상을 사용자가 지정한 클러스터 개수 k 개로 영역을 분할하는 기법으로 최적의 클러스터 수 k 값을 선정하는 것이 매우 중요한 문제이다. 반면에 k-means 처럼 비지도 머신 러닝 알고리즘 하나인 밀도 기반 클러스터링(DBSCAN)[15,16]은 반경 ϵ 과 클러스터를 구성할 최소 픽셀 수 $MinPts$ 를 사전에 지정하면 일정 반경 안에 있는 픽셀들로 클러스터를 형성하게 한다. 즉, 클러스터는 주어진 반경 안에 픽셀이 $MinPts$ 이상으로 존재할 때 정의되며, 이때 이웃한 밀도는 반경보다 커야 한다. 따라서 DBSCAN에서는 주어진 반경과 최소 픽셀 수에 따라서 클

러스터들로 분할된다. 주어진 영상 데이터 D 에서 각 픽셀은 다음과 같이 분류된다.

임의의 픽셀 p 의 ϵ -이웃 픽셀은 p 와의 거리가 ϵ 보다 작은 픽셀이다.

$$N_\epsilon = \{q \in D \mid dist(p,q) < \epsilon\} \quad (8)$$

여기서 $dist(p,q)$ 는 두 픽셀 p, q 간의 거리 함수이고 일반적으로 유클리드 거리 함수를 이용한다. 식 (9)와 같이 p 의 이웃 픽셀 수가 $MinPts$ 보다 크면 p 를 핵심(core) 픽셀이라 한다.

$$N_\epsilon(p) > MinPts \quad (9)$$

핵심 픽셀은 아니지만, 어떤 핵심 픽셀의 ϵ -이웃 픽셀을 외곽 픽셀이라 한다. 그리고 핵심 픽셀도 아니고 이웃 픽셀에도 속하지 않는 것을 노이즈 픽셀이라 한다. 반경 ϵ 과 최소 픽셀 수 $MinPts$ 가 주어지면, 임의의 핵심 픽셀 p 의 ϵ -이웃 픽셀은 p 로부터 직접 밀도 기반 도달 가능한 관계(direct density reachable)라고 한다. 여기서 p 의 ϵ -이웃 픽셀 q 가 또 다른 핵심 픽셀이면 q 의 ϵ -이웃 픽셀들은 픽셀 p 로부터 밀도 기반 도달 가능(density reachable)하다. 따라서 픽셀 p, q 가 임의의 픽셀 r 로부터 밀도 기반 도달 가능하면 픽셀 p, q 는 주어진 ϵ 과 $MinPts$ 조건 아래에서 밀도 기반 연결(density connected) 관계에 있다.

그림 1에서 화살표는 직접 밀도 기반 도달 가능한 관계를 나타낸다. X 에서 밀도 기반 도달 가능한 픽셀 Y_1, Y_2 는 서로 밀도 기반 도달하다,




Fig. 1. Illustration of the DBSCAN cluster model[16].

DBSCAN 알고리즘은 다음과 같다.

알고리즘 2.[15]

1. 입력

영상 데이터

ϵ : 반경

$MinPts$: 최소 픽셀 수

2. 군집화 과정

step 1. 데이터로부터 핵심 픽셀 조건을 만족하는 임의의 픽셀을 선택한다.

step 2. 밀도 도달 가능한 픽셀들을 구하고, 이 픽셀들을 코어 픽셀과 외곽 픽셀을 구분하고, 여기에 속하지 않은 픽셀을 노이즈 픽셀로 지정한다.

step 3. ϵ 반경 안에 있는 핵심 픽셀을 연결한다.

step 4. 연결된 핵심 픽셀들로 하나의 군집을 만든다.

step 5. 모든 외곽 픽셀들을 처음 속한 군집에 할당한다.

3. 분석 방법

컬러 영상은 RGB 채널의 혼합으로 표현되는데 영상 분석에서 RGB 영상을 각 채널별로 처리할 때 색상의 왜곡 및 인간의 색상에 대한 직관성과 다소 차이가 있다. 그러나 HSV의 컬러 공간은 색상, 채도, 밝기로 구성되어 있어 Hue 값으로 직관적인 색상 정보를 구할 수 있다. HSV 컬러 공간에서 색상은 생상각(hue angle)으로 표현하며, 범위는 $0^\circ \sim 360^\circ$ 이다. 채도는 $0 \sim 255$ 값으로 표현되며, 숫자가 클수록 색이 선명하다. 밝기 구간은 $0 \sim 255$ 이고, 0은 완전히 어둡고, 255는 가장 밝은 상태이다. 본 연구에서는 분할된 영역을 HSV 공간으로 변환한 후에 Hue값을 기준으로 통계 분석하였다.

본 연구의 부식 분석 방법을 그림 2에 나타냈다.

1. 히스토그램 평활화(Histogram Equalization)를 통해 입력 영상의 명암 대비를 개선한다.

2. Grab-cut을 통해 영상에서 시험편을 분할한다.

3. 최대 내부 인접 직사각형을 구한다.

4. k-means 방법

4-1. k-means를 이용하여 영역을 분할한다.

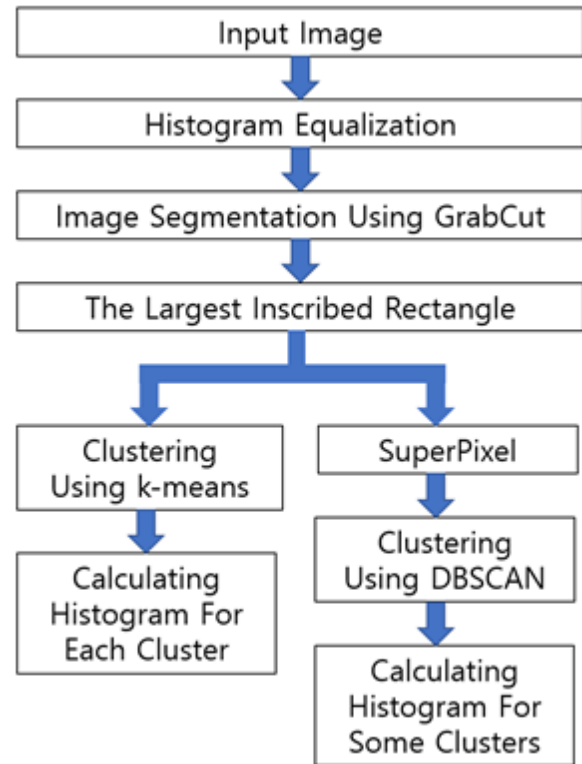


Fig. 2. Flowchart for rust analysis using the k-means and the superpixel DBSCAN methods.

4-2. 각 클러스터링에 대해 HSV 색공간 기준으로 histogram을 구한다.

5. 슈퍼픽셀 DBSCAN 방법

5-1. 슈퍼픽셀을 구한다.

5-2. DBSCAN을 이용하여 영역을 분할한다.

5-3. 분할된 영역 중 일부에 대해 HSV 색공간 기준으로 histogram을 구한다.

4. 실험 및 분석

1, 2, 3, 5, 6년간 옥외 폭로한 GI 강판의 단면 부식을 k-means와 슈퍼픽셀 DBSCAN 방법 통해 비교 분석하였다.

그림 3은 1년간 노출한 시험편의 영상분할 이미지로써, 그림 3 (a)는 프로그램을 통해 자동으로 이미지 영역을 추출하기 위해 시험편을 둘러싼 관심 영역(ROI, region of interest)을 영상의 가장 자리에서 상하좌우 간격이 5픽셀인 녹색 사각형으로 표시하였다. 녹색 사각형 밖은 배경(Background area)으로 설정하였으며, 사각형 내부에는 객체(Detection area)와 객체가 아닌 미지정 픽셀(Undetected area)이 혼재하는 것을 확인할 수 있었다. (b)는 grab-cut으로 분리된 이미지를 나타내었다. 분리된 이미지의 가장자리에 불규칙한 검은색 부분은 1.6 mm 두께를 가진 단




Fig. 3. GI 1 year exposure. (a) ROI is marked by a green rectangle, where offset is 5 pixels, (b) Segmented image using the grab-cut.

면 이미지 경계에서의 선명도 저하로 시험편 일부가 잘려 나가거나, 시험편에 접한 배경 일부가 포함된 것을 확인할 수 있다.

그림 4 (a)의 빨간색 직사각형은 그림 3의 (b) 영역에 내접한 최대 직사각형 영역을 나타낸다. 그림 4 (b)는 최대 내접 직사각형에 해당하는 부분을 나타내고 있다.

그림 5의 왼쪽 열은 GI의 1년차 노출 단면 사진(그림 4의 (b)에 해당되는 부분)을 $k=5$ 로 설정하였으며, k -means를 수행하였을 때의 클러스터 값을 나타낸다. 오른쪽 열은 좌측 분할 영역을 RGB

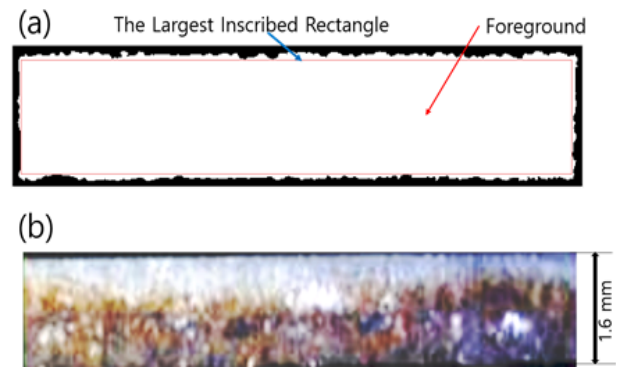


Fig. 4. (a) The largest inscribed rectangle, (b) Cropped image.

에서 HSV로 변환한 Hue에 대한 히스토그램이다. 그림 5 (a)는 $k=1$ 의 영역으로 그림 3에서 붉은색 계통을 나타내고 있으며, Hue 히스토그램(그림 5 (b))에서도 Hue값이 0 ~ 50의 붉은색 계통에 집중적으로 나타내는 것을 확인할 수 있었으며, 21.62%로 가장 넓은 영역을 나타내고 있다. 그림 5 (c)는 흰색 계통의 도금층 영역을 나타내고 있다. 그림 5 (d)의 Hue 값이 190 ~ 260 영역으로 푸른색 계통의 값을 나타내고 있는 것을 확인할 수 있었으며, 그 비율은 20.84%를 나타낸다. 그림 5 (e), (g), (i)의 영역도 그림 5 (a), (c)의 영역과 마찬가지로 Hue값이 붉은색과 푸른색 계통의 영역에 걸쳐 넓게 분포하는 것을 확인할 수 있었다.

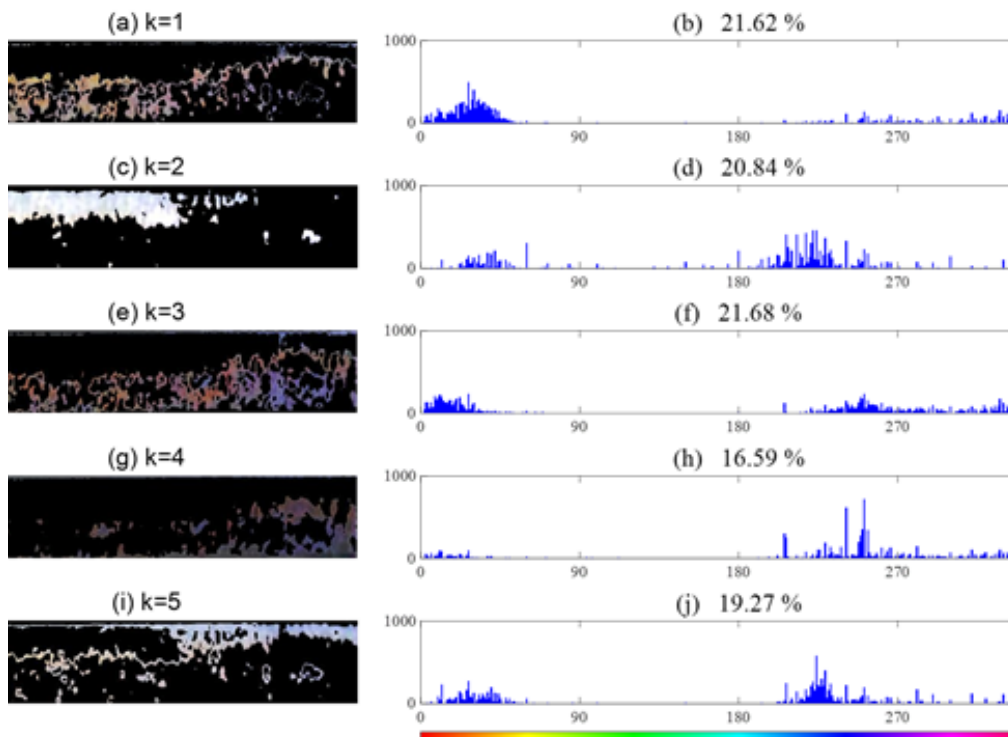


Fig. 5. GI 1 year exposure, k -means method. The left column shows the clustering and the right column displays their corresponding histograms.




Fig. 6. GI, 1 year exposure. (a) superpixel with $k = 1000$, (b) superpixel based DBSCAN with $\epsilon=5$, $MinPts = 1$

그림 6의 (a)에서 검은색 다각형은 그림 4 (b)에 대해 수퍼픽셀 1000개를 나타낸 그림이다. 그림 4 (b)의 픽셀 수는 너비 546 픽셀, 높이 107 픽셀로 전체 픽셀 수는 58,422개를 나타내며, 그림 6의 (a)의 수퍼 픽셀은 1000개이므로 (a)를 DBSCAN 할 때 $MinPts$ 를 1로 지정하여도 DBSCAN을 이용할 때 더 빠르게 계산할 수 있다. (b)는 (a)의 수퍼픽셀을 하나의 화소로 보고 ϵ 은 5, $MinPts$ 는 1로 지정하여 DBSCAN 한 결과를 나타낸다. (b)의 분할 영역은 621개를 나타낸다.

그림 7은 2 ~ 6년간 노출한 시험편의 이미지를

DBSCAN 한 결과를 나타낸다. 좌측 열은 2년, 3년, 5년, 6년 노출된 단면 이미지이며, 우측 열은 수퍼픽셀 1000개로 DBSCAN 한 이미지를 나타내었으며 그 결과는 표 1에 나타내었다. 표 1은 연차별 DBSCAN 한 결과를 각 영역 개수 및 영역별 픽셀 비율을 나타내었다. 1년차 샘플에서 DBSCAN은 621개 영역으로 클러스터링 되었으며, 군집 중 가장 큰 영역을 나타낸 No. 1의 경우 16.3106%의 비율을 나타내었다. 그리고 픽셀 수가 가장 적은 n번째(621번) 영역은 0.0086%를 나타내는 것을 확인 할 수 있었다.




Fig. 7. The figures in the first column correspond to (a) 2, (b) 3, (c) 5 and (d) 6 years exposure. The figures in the second column are the result of superpixel based DBSCAN with $k = 1000$, $\epsilon=5$, $MinPts. = 1$.

Table 1. The numbers of regions for each exposure material and top and the upper and lower areas(% , percentage).

Year	Clustering No.	Area percentage (%)				
		Region No. 1	No. 2	No. 3	No. (n-1)	No. n
1	621	16.3106	1.7476	1.5354	0.0103	0.0086
2	552	11.1924	4.5138	3.5677	0.0108	0.0018
3	585	4.2828	2.9598	2.1664	0.0136	0.0114
5	513	13.4817	4.2562	3.5373	0.0258	0.0200
6	92	59.2676	8.1022	5.8331	0.0536	0.0482

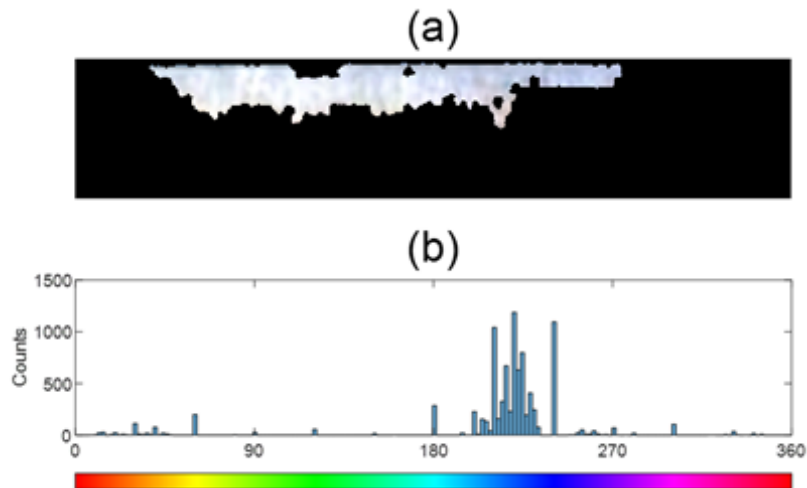


Fig. 8. (a) The nonblack part is the largest region of the Fig. 6. and (b) histogram.

그림 8의 (a)는 GI강판의 1년간 노출한 시험편(그림 6의 (a))에서 중 가장 큰 분할 영역만을 분리해 낸 것으로, 이 영역은 k-means에 의한 분할 영역(그림 5의 (c))과 공간적으로 상당 부분 겹치는 영역이다. 그림 5의 (d) 히스토그램에서 나타낸 것처럼 Hue 색상이 20 ~ 40과 200 ~ 260 영역에 걸쳐 분포되어 있는 것을 확인할 수 있지만, DBSCAN에 의한 그림 8의 (b)는 200 ~ 230 부분에 집중적으로 분포되어 있음을 확인할 수 있다. K-means는 지정된 수 만큼 분할 하기에 분할 영역은 색상 스펙트럼 분포가 넓게 나타나며, 상대적으로 DBSCAN은 주어진 반경과 최소 픽셀 수에 따라 영역을 분할 하므로 각 분할 영역의 스펙트럼은 집중되어 있는 것을 확인할 수 있었다.

4. 결 론

본 연구에서는 해안가에서 6년간 옥외 폭로시킨 GI강판의 절단면에서의 부식 이미지를 비지도 학습 방법인 k-means 클러스터링과 슈퍼픽셀 DBSCAN법을 이용하여 분석하였으며, 2가지 학습 방법에 따른 이미지 분할 결과를 비교 분석하였다. 특히, 2가지 방법에 따른 특징들로 인하여 특성 분석 목적에 따른 영상 분할 방법을 제시하는 것이 가능한 것을 확인할 수 있었다.

또한, 부식면의 픽셀단위의 색상 Hue값과 그 영역에서의 전자주사현미경, 에너지분산분광법, 전자탐침미세분석법 등을 접목하면 부식이미지의 색상으로 표면구조, 성분분석도 가능할 것으로 사료된다.

REFERENCES

- [1] M. H. Hong, D. G. Kang, D. J. Paik, H. S. Hwang, S. H. Park, Effect of added magneisum on the coating properties of galvanized steel sheets, *Korean J. Met. Mater.*, 54 (2016) 723-731.
- [2] S. J. Kwon, S. M. Lee, M. H. Lee, S. S. Park, Study on corrosion and structural performance in hot-dip galvanizing steel, *J. Korea Concr. Inst.*, 24 (2012) 613-621.
- [3] B. S. Kim, Y. W. Kim, J. H. Yang, Detection of corrosion on steel plate by using image segmentation method, *J. Korean Inst. Surf. Eng.*, 54 (2021) 84-89.
- [4] V. Bondada, D. K. Pratihari, C. S. Kumar, Detection and quantitative assessment of corrosion on pipelines through image analysis, *Procedia Comput. Sci.*, 133 (2018) 804-811.
- [5] K. W. Liao, Y. T. Lee, Detection of rust defects on steel bridge coatings via digital image recognition, *Autom. Constr.*, 71 (2016) 294-306.
- [6] B. S. Kim, J. S. Kwon, S. W. Choi, J. P. Noh, K. H. Lee, J. H. Yang, Corrosion image monitoring of steel plate by using k-means clustering, *J. Korean Inst. Surf. Eng.*, 54 (2021) 278-284.
- [7] C. Rother, V. Kolmogorov, A. Blake, "GrabCut": interactive foreground extraction using iterated graph cuts,

- ACM Trans. Graph., 23 (2004) 309-314.
- [8] K. P. Sinaga, M. S. Yang, Unsupervised k-means clustering algorithm, *IEEE Access*, 8 (2020) 80716-80727.
- [9] D. M. Saputra, D. Saputra, L.D. Oswari, Effect of distance metrics in determining k-value in k-means clustering using elbow and silhouette method, *Adv. Intell. Syst. Res.*, 172 (2019) 341-346.
- [10] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, S. Ssstrunk, SLIC superpixels compared to state-of-the-art superpixel methods, *IEEE Trans. Pattern Anal. Mach. Intell.*, 34, (2012) 2274-2282.
- [11] M. Marzeh, M. Tahmasbi, N. Mirehi, Algorithm for finding the largest inscribed rectangle in polygon, *J. Algorithm. Comput. Technol.*, 51 (2019) 29-41.
- [12] M. Ahmed, R. Seraj, S. M. S. Islam, The k-means algorithm: a comprehensive survey and performance evaluation, *Electronics*, 9 (2020) 1295.
- [13] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, S. Ssstrunk, SLIC superpixels compared to state-of-the-art superpixel methods, *IEEE Trans. Pattern Anal. Mach. Intell.*, 34 (2012) 2274-2282.
- [14] Y. Zhang, Q. Guo, Y. Zhang, C. Zhang, Fast and robust superpixel generation method, *IET Image Process.*, 14 (2020) 4543-4553.
- [15] M. Ester, H. P. Kriegel, J. Sander, X. Xu, A density-based algorithm for discovering clusters in large spatial databases with noise, *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (KDD 96)*. AAAI Press. (1996) 226-231.
- [16] E. Schubert, J. Sander, M. Ester, H. P. Kriegel, X. Xu, DBSCAN revisited, revisited: why and how you should (still) use DBSCAN, *ACM Trans. Database Syst. (TODS)*, 42 (2017) 1-21.