



〈Review Article〉

ISSN 2288-8403(Online)

한국표면공학회지

J. Surf. Sci. Eng.

Vol.56, No.6, 2023.

<https://doi.org/10.5695/JSSE.2023.56.6.353>

부식 검출과 분석에 적용한 영상 처리 기술 동향

김범수, 권재성, 양정현*

경상국립대학교 기계시스템공학과

Trends in image processing techniques applied to corrosion detection and analysis

Beomsoo Kim, Jaesung Kwon, Jeonghyeon Yang*

Department of Mechanical System Engineering, Gyeongsang National University, Tongyeong, Gyeongnam, 53064, Korea

(Received 13 November, 2023 ; revised 30 November, 2023 ; accepted 01 December, 2023)

Abstract

Corrosion detection and analysis is a very important topic in reducing costs and preventing disasters. Recently, image processing techniques have been widely applied to corrosion identification and analysis. In this work, we briefly introduces traditional image processing techniques and machine learning algorithms applied to detect or analyze corrosion in various fields. Recently, machine learning, especially CNN-based algorithms, have been widely applied to corrosion detection. Additionally, research on applying machine learning to region segmentation is very actively underway. The corrosion is reddish and brown in color and has a very irregular shape, so a combination of techniques that consider color and texture, various mathematical techniques, and machine learning algorithms are used to detect and analyze corrosion. We present examples of the application of traditional image processing techniques and machine learning to corrosion detection and analysis.

Keywords : Corrosion; Color Models; Image Segmentation; Machine Learning

1. 서 론

부식은 화학적 또는 전기화학적 반응, 마찰 등 여러 원인으로 발생 되어 점진적으로 진행되면서 변색 및 부식생성물 같은 이상 현상으로 소재를 열화시킨다. 부식은 금속 제품 사용 효율성을 떨어뜨리고, 경제적 손실을 발생시킨다. 따라서 효율적인 방법으로 부식을 검출하고 분석하는 것은 금속 제품의 안정성을 증가시키고 유지 관리 비용을 감소시킬 수 있다[1~4].

부식 검사는 무게, 부피, 전기화학, 자기측정 등 정량적 검사[5~8]와 육안 검사 그리고 광학 현미경, 공초점 현미경, 레이저 스캐닝 현미경, 주사 반사 측정법 등 정성적 검사가 있다[9]. 일부 정량적 검사는 시간이 많이 소요되고, 실험실 외부에서 검사하기가 힘들다[9]. 육안 검사는 검사자의 숙련과 경험이 중요하고 정량 분석이 어렵다. 또한 검사자가 접근하기 어렵거나 위험한 곳에서는 육안 검사가 힘들다[10~12].

최근에는 부식 검출과 분석에 영상 처리 기법을 많이 적용하고 있다. 영상 처리 기법은 카메라, UVA[11], 그리고 능동형 적외선 열화상 촬영[9] 등에서 취득된 영상을 다양한 알고리즘으로 처리

*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

비파괴 검사 방법으로 검사 및 분석이 빠르고, 부식에 관한 기하학적 정보 및 통계 데이터를 쉽게 구할 수 있다[13, 14].

부식 부위는 대개 표면 질감이 거칠고(rough texture), 주로 붉은색과 갈색을 띠며, 매우 불규칙한 기하학적 형태다. 이러한 부식 특징을 반영해서 영상에 부식이 있는지를 판별하거나 부식을 분석하기 위해 다양한 영상 처리 기법들이 사용되고 있다[10, 15~20].

부식 판별은 색상 공간 정보를 이용하거나, 머신 러닝을 이용하여 부식이 있는지 없는지에 대한 이진 분류(binary classification)와 부식이 어느 정도인지를 판별하는 다중(multiclass) 판별이 있다[15, 16, 20~27]. 부식 부위에 대한 기하학적 정보나 특정 부식 영역의 색상 통계 데이터를 구하기 위해서는 영상에 부식 부위를 경계 짓기 위해 경계선 검출(edge detection)이나 영역 분할(image segmentation) 등이 선행되어야 한다. 부식 분석에는 색상 정보를 이용하거나 [28~30] 고전적인 Canny 경계선 검출 방법부터 머신 러닝을 이용한 경계선 검출 기법 등 다양한 방법들이 사용된다[31]. 부식 부위 영역 분할에는 Grabcut[32], 유역 분할(Watershed)[33, 34], 그리고 최근에 활발히 연구되고 있는 머신 러닝을 이용한 기법들이 사용되고 있다[35, 36].

머신 러닝 알고리즘은 명시적으로 각 영상 데이터에 참값(label)을 부여한 후에 훈련(train)과 테스트를 거쳐 학습시킨 모델에 새로운 영상 데이터를 입력하여 출력을 얻는 지도 학습(supervised learning)과, 레이블 없이 입력된 영상으로만 의미 있는 결과를 구하는 비지도 학습(unsupervised learning)으로 구분된다. 비지도 학습에는 비슷한 특징을 갖는 것끼리 묶어 구별하는 군집화(clustering), 입력 데이터의 차원을 축소하는(dimensionality reduction) 것이 있다. 군집화 방법인 K-means 군집화[37, 38], 밀도 기반 군집화(DBSCAN, Density-based spatial clustering of applications with noise)[39, 40], 퍼지 C-평균(Fuzzy C-means) 군집화[41]가 부식 영역 분할에 사용되었다.

벡터의 Norm과 내적을 기반으로 개발된 SVM(Support Vector Machine)[42]은 지도 학습 이진 분류(binary classification) 알고리즘으로 주어진 영상 데이터에 부식이 있는지 여부를 판별하는데 적용되었다[43]. 또한 신경망

(Neural network) 구조를 갖는 심층 신경망(deep learning) 모델들도 부식 판별과 분석에 많이 적용되고 있다[2, 26, 44, 45].

본 연구는 부식 검출과 분석에 적용된 영상 처리 기술과 적용 사례를 살펴보고 몇 개의 기법을 적용한 예를 보인다. 2 장에서는 색상 공간을 설명하고, 3 장에서는 Grabcut, 유역 분할, 그리고 비지도 학습 머신 러닝 알고리즘을 이용한 영역 분할 방법과 적용 사례를 소개한다. 4 장에서는 지도 학습인 SVM, 콘볼루션 신경망(CNN, Convolutional Neural Network), Holistically-Nested Edge, Faster R-CNN 방법을 간략히 살펴 보고 그 응용 사례를 소개한다. 5 장에서는 SVM 을 적용해서 시편의 부식 여부를 판정하는 문제를 예를 들어 보이고, 시편의 부식 영역 분할을 K-means, 퍼지 C-평균, DBSCAN, HED 을 적용한 예를 보인다. 그리고 시간에 따른 시편 단면 부식 진행 상태를 색상 공간 정보를 이용해서 통계 처리할 수 있음을 보인다.

2. 컬러 모델

디지털 영상 처리(digital image processing)는 카메라나 스캐너 같은 영상 취득 장치로 실세계 아날로그 영상을 부호화한 디지털 영상에서 의미 있는 정보를 얻거나, 영상을 개선, 변형하는 것이다. 영상 분류, 특징 추출, 패턴 인식 등에서 영상 처리 기법이 광범위하게 사용되고 있다. 일반적으로 영상에서 정보를 식별하거나 인식할 때 중요한 요소는 색상이다. 따라서 컬러 영상을 분석하거나 디스플레이 장치에 사용할 때 목적에 맞는 컬러 모델을 사용한다[46, 47].

2.1 RGB 모델

RGB 모델은 빛의 3원색인 빨강(Red), 녹색(Green), 파랑(Blue)을 기본 채널로서 색을 표현하고, 각 컬러 채널은 일반적으로 8 bit로 이산화한다. 따라서 각 채널은 0 부터 255 까지 수치화할 수 있다. 가장 널리 사용되는 RGB 모델은 색을 혼합하면 명도가 올라가는 가산 혼합 방식으로 비디오 디스플레이에 적합하고, 영상을 표현하는데 변환(transform)이 필요 없다. 그러나 RGB 모델이 비선형 불연속 공간이므로 색상(hue)의 변화를 따라가기 어렵고, 색조는 조명(illumination)

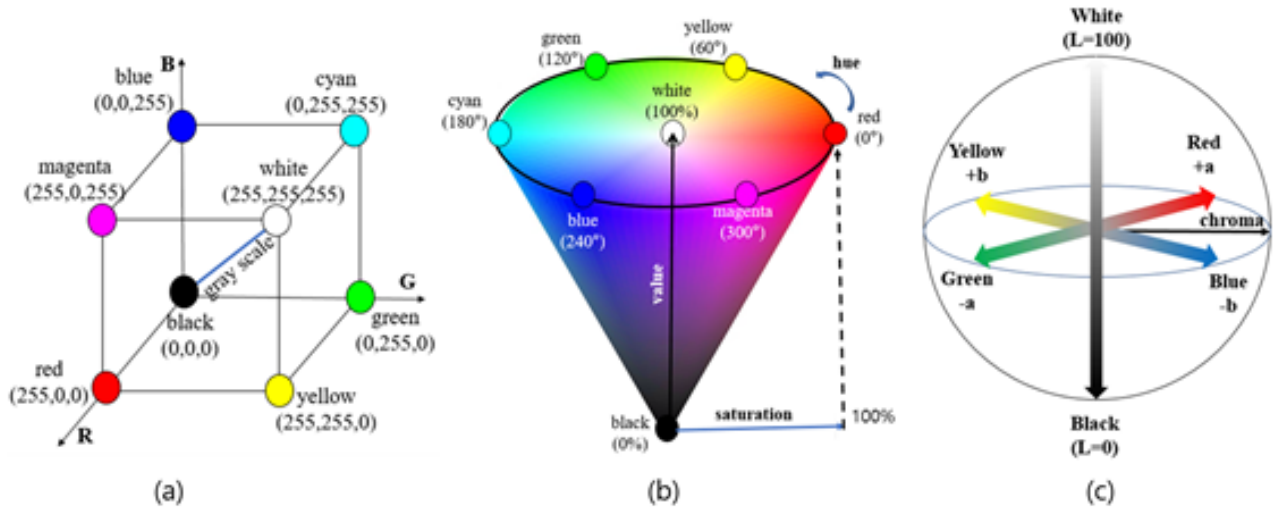


Fig. 1. Color models (a) RGB model (b) HSV model (c) CIE Lab model

영향을 많이 받는다[47].

2.2 HSV 모델

HSV(hue, saturation, value) 모델은 직관적으로 컬러를 다루기 위한 색상 공간이다. Hue는 색상 자체이며, 채도(saturation)는 색의 맑고 탁한 정도를 나타내고, 명도(value, intensity)는 색의 밝고 어두운 정도를 나타낸다. HSV 모델을 사용하면 영상에 반영된 조명 영향을 낮출 수 있다 [48]. H, V, S 값은 식(1), (2), (3)과 같이 RGB 값에서 구한다[46].

$$H = \begin{cases} 60 \times \left(\frac{G-B}{C} \right) \bmod 6 & \text{if } M = R \\ 60 \times \left(\frac{B-R}{C} + 2 \right) & \text{if } M = G \\ 60 \times \left(\frac{R-G}{C} + 4 \right) & \text{if } M = B \\ \text{undefined} & \end{cases} \quad (1)$$

$$V = \max(R, G, B) \quad (2)$$

$$S = \begin{cases} 0, & \text{if } V = 0 \\ \frac{C}{V}, & \text{otherwise} \end{cases} \quad (3)$$

여기서 $M = \max(R, G, B)$, $m = \min(R, G, B)$, $C = M - m$ 이다.

HSV 모델은 색상을 원의 각도로 나타내고 있는 Hue 값으로 색상 정보를 직관적으로 구할 수 있지만 부식의 특징인 붉은색이 0° 를 기준으로 양 방향으로 분포하고 있어 붉은 계열 색상은 0° 에서 숫자 불연속성이 발생하므로 Hue 값을 이용

한 통계 처리가 쉽지 않다. Hue 모델을 이용해서 부식을 판별할 때 각도의 불연속을 고려하여 (0° -22°), (350°-359°) 두 범위를 사용한 연구도 있다[48].

2.3 CIE Lab 모델

국제 조명 위원회(CIE, Commission internationale de l'éclairage)가 제안한 CIE Lab 공간은 인간이 동일하다고 인식하는 색 차이가 CIE Lab 공간의 동일한 유클리드 거리에 해당되게 하여 지각적 균일성을 보장한 국제표준이다. 색상 모델은 CIE Lab 이지만 좌표는 L^* , a^* , b^* 로 표시한다. CIE Lab 모델은 1931 CIE 색상 일치 함수에서 파생된 XYZ 삼색 자극값(Tristimulus value)으로 정의한다[49, 50].

$$\bar{Y} = \frac{L^* + 16}{116} \quad (4)$$

$$X = X_n \left(\frac{a^*}{500} + \bar{Y} \right)^3 \quad (5)$$

$$Y = Y_n \bar{Y}^3 \quad (6)$$

$$Z = Z_n \left(-\frac{b^*}{200} + \bar{Y} \right)^3 \quad (7)$$

여기서 X_n, Y_n 그리고 Z_n 은 인간 눈이 백색(white)에 해당되는 광원(illuminant)에 반응하는 삼색 자극 값이다. 따라서 L^* , a^* , b^* 는 다음과 같이 구해진다 [50](이하 L^* , a^* , b^* 를 L, a, b 로 표기한다).

$$L = \begin{cases} 116\left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} - 16 & \text{if } \frac{Y}{Y_n} > 0.008856 \\ 903.3\left(\frac{Y}{Y_n}\right) & \text{if } \frac{Y}{Y_n} \leq 0.008856 \end{cases} \quad (8)$$

$$a = 500\left[\left(\frac{X}{X_n}\right)^{\frac{1}{3}} - \left(\frac{Y}{Y_n}\right)^{\frac{1}{3}}\right] \quad (9)$$

$$b = 200\left[\left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} - \left(\frac{Z}{Z_n}\right)^{\frac{1}{3}}\right] \quad (10)$$

Lab 칼라 모델에서 색상은 3D 공간 위치에 따라 결정된다. 그림 1-(c) 에서와 같이 색상 밝기 L은 0 이면 검정색을, 100 은 백색이고, 채도(chroma) a 에서 양수 값은 빨간색을 나타내고 음수 값은 녹색을 나타낸다. 색상 b 가 양수 값이면 노란색을 나타내고 음수 값은 파란색을 나타낸다.

RGB 모델은 컴퓨터 그래픽, 영상처리, 영상 분석, 저장할 때 주로 사용된다. 특히 RGB 모델은 디스플레이 화면에 정보를 표시하는 데 변환이 필요 없어 다양한 응용 프로그램의 기본 색 공간으로 이용된다. HSV 모델은 사람이 시각적으로 색상 정보를 직관적으로 인식할 수 있어, 컴퓨터 그래픽, 영상 분석 등에 많이 사용되지만, Hue 가 원[0°~360°] 각도에 따라 분포되어 0° 에서 숫자의 불연속성이 존재한다. Lab 모델에서 색상은 3D 공간 위치 정보로 구할 수 있으므로 유클리드 거리 공간 개념을 쉽게 적용할 수 있다. 따라서 색상 차이 평가, 색상 매칭 시스템, 그래픽 아트 등에 널리 사용된다[46, 47].

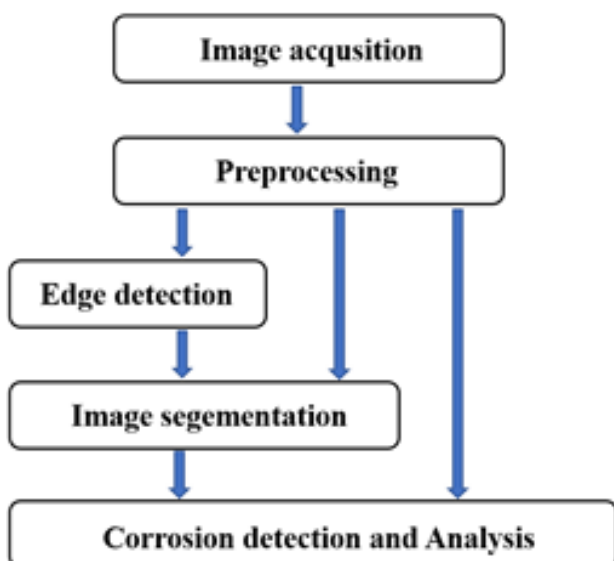


Fig. 2. Corrosion detection and analysis process using image processing.

3. 영상처리 기법

일반적으로 영상을 이용한 부식 검출이나 분석은 그림 2 와 같이 영상을 취득한 후, 전처리, 경계선 검출, 영역 분할 과정을 거친다.

3.1 영상 취득과 전처리

전처리(preprocessing)는 취득된 이미지에서 노이즈를 제거하거나 이미지 화질을 개선하는 작업이다. 노이즈 제거에는 Mean 필터, 가우시안(Gaussian) 필터, Wiener 필터, 마스크(mask) 필터 등이 많이 사용되고 있다[51]. 이미지 화소(pixel)들이 너무 어두운 값이나 밝은 값 쪽으로 몰려 있을 때 이미지를 회색조(grayscale)로 변환한 후에 회색조 값들의 누적분포함수를 바탕으로 회색조 값의 빈도수를 균일하게 분포시켜 밝기 값을 균등화하면 이미지의 손실된 대비(contrast)가 복구되어 화질을 향상 시킬 수 있다[51].

3.2 경계선 검출

컴퓨터는 영상을 포함한 모든 객체를 내부적으로는 숫자로 처리한다. 영상에서 경계선은 이웃 픽셀 간의 숫자 변화폭이 큰 지점이다. 따라서 영상의 밝기 변화는 구배(gradient)를 사용하거나 가우시안 미분을 사용해서 검출한다. 일차 미분인 구배를 사용한 경계선 검출 방법으로는 Robert 방법, Sobel 방법, Prewitt 방법 등이 있고[52], 2차 미분인 가우시안을 사용한 방법으로는 Canny 방법[53], LOG(Laplacian of Gaussian) 방법[54], DOG(difference of Gaussian) 방법[55] 등이 있다.

Canny 경계선 검출은 이미지를 가우시안 필터로 노이즈를 제거하고, 회색조 변환, 구배 계산, 최댓값이 아닌 픽셀값 억제, 그리고 사용자가 설정한 최대, 최소 임계값(threshold value)을 기준으로 구해진 경계선을 구한다[53].

[56]에서는 Canny 경계선 검출과 모폴로지(morphology) 연산을 사용하여 금속 영상에서 부식 부위를 검출했다.

3.3 영역 분할(Image segmentation)

부식 면적 계산이나, 부식 색상 등을 분석하기 위

해서는 영상에서 부식 영역을 추출하는 것이 필요하다. 영역 분할은 이미지에서 개체(object)나 관심 있는 영역을 추출하기 위해 픽셀들을 구분하는 것이다. 영상에서 개체를 추출하는 방법으로는 사용자와의 상호 작업(interactive)이 필요한 것과 자동으로 하는 것으로 나누어 볼 수 있다. Intelligent Scissors, Magic Wand, Bayes Mate, Grabcut 등은 사용자의 상호 작업을 통해서 영상에서 배경(background)과 전경(foreground)을 분할 한다.

자동으로 영상을 분할하는 알고리즘들은 영상 픽셀의 불연속성을 이용한 영역(region) 기반 분할과 픽셀의 유사성을 이용한 경계선(edge) 기반 방법으로 나누어 볼 수 있다. 이 방법들은 영상 픽셀의 색상 정보, 경계선 같은 특징을 이용한다.

3.3.1 Grabcut[32]

그림 3-(a)와 같이 사용자가 객체(전경, foreground) 외곽에 사각형을 그려주면 사각형 바깥의 모든 픽셀은 배경 픽셀 집합(background, TB)이고, 사각형 내부는 객체 픽셀 집합(TF)과 미분류된(unknown) 픽셀 집합(TU)이 섞여 있는 영역으로 분할된다. 입력 영상 배열을 z 로 정의하고, 각 픽셀은 분할 배열 a 에 매핑시켜 전경과 배경을 분리한다. 여기서 N 은 전체 픽셀수이며, n 번째 픽셀의 컬러 값이고, a_n 는 n 번째 픽셀의 분할 정보로서 0이면 배경이고, 1이면 전경에 해당된다.

그림 3-(b)와 같이 입력 영상에서 각 픽셀이 객체에 속하는지 배경에 속하는지를 구하기 위해 배경과 객체에 대한 가우시안 혼합 분포(GMM, Gaussian Mixture Model)를 식 11과 같이 정의한다.

$$\theta = \{\pi(a, k), \mu(a, k), \Sigma(a, k)\} \quad (11)$$

여기서 π 는 가중치(weight), μ 는 평균, $k_i \in \{1, 2, \dots, K\}$, 그리고 Σ 는 공분산이다. 분할을 위해 전경과 배경의 두 연결 링크를 에너지 함수인 식 12로 정의한다.

$$E(a, k, \theta, z) = U(a, k, \theta, z) + V(a, z) \quad (12)$$

여기서 $V(a, z)$ 는 경계선 특성이고, $U(a, k, \theta, z) = \sum_{n=1}^N D(a_n, k_n, \theta, z_n)$ 이며, $D(\cdot) =$

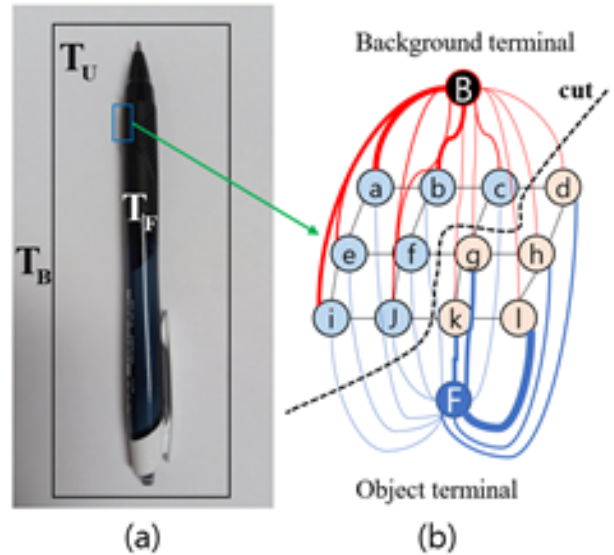


Fig. 3. Grabcut algorithm (a) Input image, (b) Grabcut segmentation process

$-\log p(z_n | a_n, k_n, \theta) - \log \pi(a_n, k_n)$, $p(\cdot)$ 은 가우시안 분포 확률 함수, $\pi(\cdot)$ 는 혼합 가중 계수이다. 따라서 식 12에 정의된 에너지 함수를 최소화하는 a^* 를 찾는 것은 다음과 같이 전역 최솟값을 찾는 문제로 귀결된다.

$$a^* = \arg \min_a E(a, k, \theta, z) \quad (13)$$

Grabcut 알고리즘은 다음과 같다.

step 1. TU 영역의 모든 화소 n 에 대해서 $k_n = \arg \min_{k_n} D_n(a_n, k_n, \theta, z_n)$ 을 구한다.

step 2. 영상 데이터 z 로 부터 GMM 파라미터를 갱신한다.

step 3. 식 (13)으로 부터 영상 분할 a^* 를 구한다.

step 4. 에너지 함수가 수렴할 때 까지 step 1~3 단계를 반복한다.

[57]에서는 시험편의 부식 영역 비율을 계산하기 위해 영상에서 시험편을 Grabcut으로 추출하여 강판의 부식 비율을 계산하였다. [58]에서는 철판 표면의 부식 영역을 Grabcut을 이용해서 분리하였고, 부식이 있는 영상 샘플에서 등간격으로 영역을 추출하기 위해 Grabcut을 사용했다. [59]에서는 UAV로 자연 환경에 놓인 철판 영상을 취득한 후에 영상에서 배경을 제거하고 철판만을 분리하기 위해 Grabcut을 사용하였고, 철판의 부식 영역을 R-CNN 모델을 사용하여 녹 발생률, 녹 신뢰도, 녹 히트맵을 분석하였다.

4. 머신 러닝 기법

비지도 학습 머신 러닝은 정답(label)을 주지 않고 데이터의 특성을 추론하는 것으로 K-means 군집화[37], DBSCAN 군집화[39], Fuzzy C-means 군집화[41] 등이 있다. 지도 학습 머신 러닝은 데이터 $\{x^{(i)}\}, i=1, \dots, N$ 와 함께 정답 $\{y_{target}^{(i)}\}, i=1, \dots, N$ 을 네트워크 모델 $F(\cdot, \theta)$ 에 입력하면 모델이 $y^{(i)} = F(x^{(i)}, \theta) \simeq y_{target}^{(i)}$ 로 예측하게끔 네트워크의 파라미터 θ 를 학습시키는 것이다[71]. 지도 학습 머신 러닝에는 Support vector machine, 선형 회귀(Linear regression), Logistic regression, Naive Bayes, 선형 판별 분석(Linear discriminant analysis), 결정 트리(Decision trees), K-최근접 이웃(K-nearest neighbor), 인공 신경망(Artificial neural networks), 콘볼루션 뉴럴 네트워크(Convolution neural networks) 등이 있다[18, 26, 33].

4.1 K-means 군집화

K-means 클러스터링은 주어진 입력 데이터를 유사한 특성을 갖는 픽셀을 하나의 군집으로 묶고, 이러한 군집 K 개를 생성한다. K 개 군집을 만들기 위해서 중심점(centroid) K 개를 임의로 설정한 후 각 픽셀로부터 유사성을 바탕으로 이 픽셀값과 픽셀이 속한 군집의 중심점 간의 평균 거리를 최소화하는 과정을 일정 오차 범위로 수렴할 때까지 반복한다[72].

[3]에서는 영상을 HSV와 CIE Lab로 각각 색상 변환한 후에 색상 변환된 각 영상에 K-means를 적용하여 부식 영역을 분리해 내는 방법을 제시하였다. [38]에서는 강판 영상을 히스토그램 평활화하고, K-means 로 몇 개의 클러스터로 분할하고 분할된 각 영역의 색상을 HSV 컬러 공간으로 변환하여 각 영역의 색상 분포 및 Hue 범위를 구하는 방법을 제시했다. [73] 그림자나 조명이 일정하지 않은 영상을 HSV 변환한 후에 Hue 채널 영상에 K-means 를 적용하여 부식을 검출하는 방법을 제안했다.

4.2 밀도 기반 군집화

반경 ϵ 과 클러스터를 구성할 최소 픽셀 수

MinPts 가 주어지면 밀도 기반 군집화 (Density-based spatial clustering of applications with noise, DBSCAN)는 주어진 반경 안에 픽셀이 MinPts 이상으로 존재하는 픽셀들로 클러스터를 생성한다. 입력 영상 데이터 D 에서 임의의 픽셀 p 의 ϵ -이웃 픽셀은 p 와의 거리가 ϵ 보다 작은 픽셀이다. p 의 이웃 픽셀 수가 MinPts 보다 크면 p 를 핵심(core) 픽셀이라 하고, 핵심 픽셀의 ϵ -이웃 픽셀을 외곽 픽셀 그리고 핵심 픽셀도 아니고 이웃 픽셀에도 속하지 않는 픽셀을 노이즈 픽셀이라 한다. 임의의 핵심 픽셀 p 의 ϵ -이웃 픽셀은 p 로 부터 직접 밀도 기반 도달가능한 관계(direct density reachable)라고 한다. 픽셀 p 의 ϵ -이웃 픽셀 q 가 또 다른 핵심 픽셀이면 q 의 ϵ -이웃 픽셀들은 픽셀 p 로 부터 밀도 기반 도달 가능(density reachable)하다. 따라서 픽셀 p, q 가 임의의 픽셀 r 로 부터 밀도 기반 도달 가능하면 픽셀 p, q 는 주어진 ϵ 과 MinPts 조건하에서 밀도 기반 연결(density connected) 관계이다[74].

DBSCAN 알고리즘은 다음과 같다.

1. 입력 : 영상 데이터, 반경 ϵ , 최소 픽셀 수 MinPts
2. 군집화 과정
 - step 1. 데이터로 부터 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. 반경 안에 있는 핵심 픽셀을 연결한다.
 - step 4. 연결된 핵심 픽셀들로 하나의 군집을 만든다.
 - step 5. 모든 외곽 픽셀들을 처음 속한 군집에 할당한다.

[75]에서는 저장탱크 표면의 영상 밝기 변화로 인해 발생하는 분할 문제를 해결하기 위해 영상을 슈퍼픽셀로 분할하고 각 슈퍼픽셀의 특징을 바탕으로 DBSCAN 으로 전체 영상을 분할하는 방법을 제안했다. [40]에서는 용융아연도금 강판 부식 영상에 DBSCAN 과 K-means 를 적용하여 각 색상의 유사성을 기준으로 클러스터를 구했다. K-means 는 사용자가 지정한 K 만큼 영역을 분할하고 DBSCAN은 반경과 클러스터를 구성할 최소 픽셀 수만 주면 이에 맞추어 클러스터를 생성

하게 된다. 따라서 유사한 특성을 갖는 픽셀들이 K-means 에서는 지정된 K 때문에 분할될 수 있지만 DBSCAN에서는 하나의 영역으로 나올 수 있다. 그리고 생성된 각 클러스터의 색상 분포와 전체 강판 영상에서 차지하는 면적 비율을 쉽게 계산할 수 있음을 보였다.

4.3 퍼지 C-평균 군집화

퍼지 C-평균[76]은 K-means 와 유사하게 픽셀 p_i 를 사용자가 설정한 군집에 퍼지 멤버십을 이용해서 할당한다. 영상 픽셀 개수가 N 개이고, 군집 개수가 M 개일 때, 식 15 로 정의된 목적 함수를 최소화하는 반복 최적화 방법이다.

$$J = \sum_{i=1}^N \sum_{j=1}^M u_{ij}^m \|p_i - c_j\|^2, 1 \leq m < \infty \quad (15)$$

Fuzzy C-means 군집화 알고리즘은 다음과 같다.

step 1. 군집 개수 K 와 수렴 조건 $\epsilon \in [0, 1]$ 를 정하고, 각 픽셀 p_i 가 특정 군집에 속할 멤버십 행렬 U 를 무작위로 초기화한다.

$$k = 0, U^{(0)} = |u_{ij}| \quad (16)$$

step 2. 각 군집의 중심점 $C^{(k)} = |c_j|$ 과 픽셀이 특정 군집에 속할 멤버십 u_{ij} 계산한다.

$$C_j = \frac{\sum_{i=1}^N u_{ij}^m p_i}{\sum_{i=1}^N u_{ij}^m}, u_{ij} = \frac{1}{\sum_{k=1}^M \left(\frac{\|p_i - c_j\|}{\|p_i - c_k\|} \right)^{\frac{2}{m-1}}} \quad (17)$$

$$k = k + 1 \\ U^{(k)} = |u_{ij}|$$

step 3. if $\|U^{(k)} - U^{(k-1)}\| < \epsilon$ stop, else repeat step 2.

식 (10) 에서 볼 수 있듯이, 픽셀 p_i 가 중심점 c_j 에 가까우면 비용함수 는 최소화 된다.

[41] 에서는 약 1년에 걸친 부식 시간 동안 실험된 강철 영상 156 개에서 특징을 추출한 후에 주 성분분석(PCA)으로 차원을 축소한 것에 퍼지 C-

평균을 적용하여 시간에 따른 철강 표면을 분류하는 방법을 제안했다. [77] 에서는 영상을 이용한 불량/정상 샘플 분류 방법을 각 샘플에서 특징 벡터를 뽑아내기 위해 PCA를 사용하였고 퍼지 C-평균을 이용해서 불량 여부를 판별하는 알고리즘을 제안했다.

4.4 Support vector machine(SVM)

1990년대 Vapnik이 발표한 SVM[78] 은 지도 학습 머신 러닝 알고리즘으로 훈련 데이터를 기반으로 비확률적 이진 선형모델을 만들어 새로운 입력 데이터가 어느 클래스에 속하는지를 판별한다. 식 18 과 같이 n 개의 훈련 데이터가 있을 때

$$D = \{(x_i, y_i) \mid x_i \in R^p, y_i \in \{-1, 1\}\} \quad (18) \\ i = 1, \dots, n$$

여기서 x_i 는 입력 벡터이고, 클래스 2 개를 $\{1, -1\}$ 라 표현하고, (x_i, y_i) 는 x_i 가 클래스 y_i 에 속해 있음을 나타낸다. SVM 은 훈련 데이터들을 y_i 에 따라 선형적으로 분리할 초평면(hyperplane)을 구하는 알고리즘이다. 이 초평면은 식 19 로 부터 구한다.

$$w \cdot x + b = 0 \quad (19)$$

$w \in R^b$ 는 초평면에 수직한 벡터이고 $b \in R$ 이다. 그림 4-(a) 와 같이 n 개의 입력 데이터와 이 데이터를 선형적으로 분리하는 많은 초평면 중에서, 입력 데이터들과 거리가 가장 먼 초평면은 벡터 내적과 norm을 이용하면 식 20 과 같이 최적화 문제로 귀결된다.

$$\min \langle w, w \rangle \quad (20) \\ s.t. y_i (\langle x_i, w \rangle + b) - 1 \geq 0$$

식 20 은 primal Lagrangian 를 이용해서 와를 구할 수 있다. 그림 4-(b) 에서 점선으로 표현된 초평면 간의 거리 d 를 마진(margin) 이라 하고, 이 두 개의 초평면에 있는 데이터를 support vectors 라 한다. 그림 4-(c) 와 같이 새로운 입력 데이터는 구해진 초평면을 이용하여 어느 클래스에 속하는지를 판별된다.

사회 기반 시설물에 발생한 소공 부식(pitting

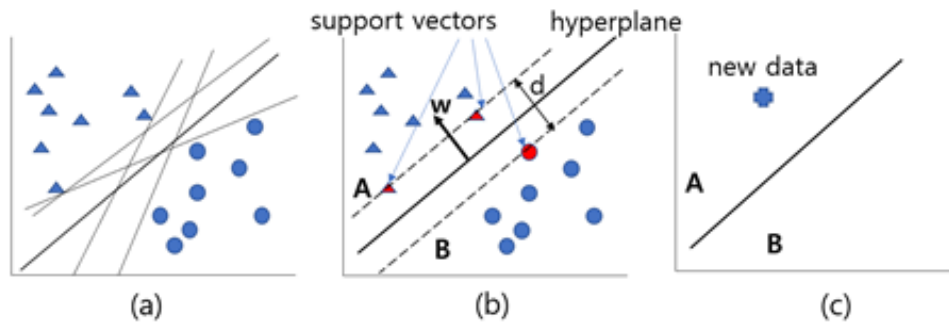


Fig. 4. support vector machine (a) input data and hyperplanes, (b) support vectors lie on the marginal hyperplane, (c) new input data and classification

corrosion) 위치를 정확히 찾기 위해 선형 모집단 크기 감소(Linear Population Size Reduction) 메타휴리스틱스(Metaheuristics) 알고리즘과 SVM으로 훈련된 모델에 새로운 입력 영상이 입력 되면 소공 부식이 있을 것 같은 관심 영역(Region of Interest)을 추출하는 알고리즘이 연구되었다 [79]. 산, 염기, 염분 등 다양한 환경에서 여러 유형의 스테인레스 강의 부식 거동 예측을 의사결정 트리(DT), SVM, 랜덤 포레스트(Random forest), 배깅 분류기의 예측 성능을 비교한 연구가 발표되었다[80]. [45]에서는 입력 영상을 BOW(Bag of Words) 기반으로 추출된 특징을 SVM 으로 훈련한 모델로 부식을 분류하는 방법을 제시했다. [43]에서는 입력 영상을 여러 컬러 공간으로 변환하고, 변환된 각각 영상에 Fourier 변환으로 노이즈가 제거된 영상에서 추출된 특징을 SVM 으로 훈련한 모델로 부식을 분류하는 방법을 제시했다. [33]에서는 배관 부식을 판별하기 위해 영상에서 GLCM 으로 추출된 특징을 SVM 으로 훈련하는 방법을 제시했다.

4.5 인공 신경망과 합성곱 신경망

지도 학습 머신 러닝은 정답이 있는 데이터 세트로 모델을 학습시키는 것으로 일반적으로 그림 5와 같이 기능을 나누어 볼 수 있다. 입력 데이터

를 훈련용과 테스트용으로 무작위 분류한 후에 훈련 데이터를 모델에 입력해서 출력과 정답을 비교해서 오차가 발생하면 모델의 파라미터나 하이퍼 파라미터를 갱신한다. 훈련이 끝난 모델은 테스트 데이터로 모델을 평가한다.

4.5.1 인공 신경망 (ANN, Artificial Neural Network)

그림 6에 표현된 인공 신경망은 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)으로 구성된다. 입력층에 입력 벡터를 인가하면, 은닉층의 각 뉴런(neuron)은 모든 입력 뉴런 값에 가중치(weight)를 곱한 값들의 합이 전달된다. ANN에서 입력이 2D 영상일 때 2차원 배열은 1차원 벡터로 변환되어 입력층에 인가된다. 그림 7의 은닉층의 뉴런 $a_i^{(1)}$ 는 식 21과 같이 앞에 있는 레이어의 모든 뉴런 출력값과 가중치의 선형결합 형태로 구한다.

$$a_i^{(1)} = \sigma \left(\sum_{i=1}^n w_{i,i} a_i^{(0)} + b_i^{(1)} \right) \tag{21}$$

여기서 $a_i^{(0)}, (i = 1, \dots, n)$ 는 앞에 있는 레이어의 뉴런 값, $w_{i,i}$ 는 가중치, $b_i^{(1)}$ 는 편향값(bias)이고, $\sigma(\cdot)$ 는 활성화 함수(activation function)이다.

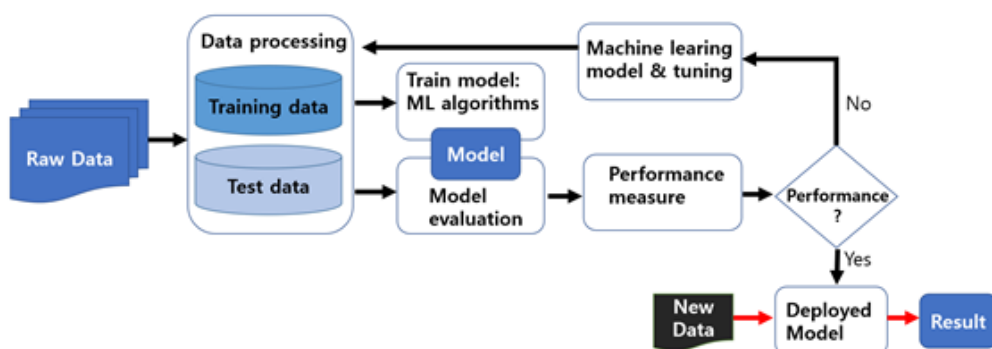


Fig. 5. Supervised machine learning process




Fig. 6. Neural network structure with two hidden layers




Fig. 7. ANN

ANN은 입력 데이터를 클래스로 분류하는 것과 입력 데이터를 토대로 다른 값을 예측하는 회귀(regression)로 나누어 볼 수 있다. 분류 ANN에서 출력값과 목표값 간에 오차(=목표값 - 출력값)가 있으면 이 오차를 줄이기 위해서 비용 함수를 정의하고 이 비용 함수가 최소가 되도록 경사 하강법(gradient descent)과 역전파(back propagation) 알고리즘을 사용해서 가중치 w_j 와 편향 b 를 갱신하는 과정을 반복한다[71].

입력: X : 훈련 데이터 세트, η : 학습률(learning rate), ϵ : 허용 오차, $C(X; \omega, b)$: 비용 함수
초기화: ω, b 를 임의의 값으로 초기화한다.

종료 조건 : 최대 반복 횟수 또는 $C(X; \omega, b) < \epsilon$
종료 조건이 만족될 때까지 다음 훈련을 반복한다.

step 1. 초기화: $\Delta \omega_i = 0$

step 2. 훈련 데이터 세트 각 데이터에 대해 다음 과정을 수행한다.

(2-1) 순방향 : 입력 데이터를 입력층에 인가하여 출력층에서 출력을 구한다.

(2-2) 오차를 구한다.

(2-3) 역방향: 가중치와 편향 값을 갱신한다.

$$\omega_j \leftarrow \omega_j - \eta \frac{\delta C}{\delta \omega_j}$$

$$b \leftarrow b - \eta \frac{\delta C}{\delta b}$$

step 3. 훈련이 종료되면 ω, b 로 신경망 모델을 구축한다.

4.5.2 합성곱 신경망(CNN, Convolution Neural Network)

CNN은 기본적으로 컨볼루션 계층(Convolution layer), 풀링 계층(Pooling layer), 완전 연결 계층(fully-connected layer)으로 구성된다. 컨볼루션 계층은 격자 모양의 2D 구조로 ANN의 벡터 형태인 1D 계층에 비해 영상과 같은 2D 데이터를 처리하기에 매우 효율적이다. 그림 8에서 입력 데이터는 그림 9와 같이 컨볼루션 계층에서 입력 데이터와 커널 필터로 컨볼루션 연산을 한 후에 활성화 함수로 결괏값을 구한다. 컨볼루션 계층은 입력 데이터의 특징(feature) 추출에 효율적이다. 또한 컨볼루션 계층은 슬라이딩 윈도우를 통해 동일한 컨볼루션 커널과 입력의 다른 위치에서 반복적으로 계산하므로, 매개변수가 공유되어 훈련 매개변수 크기가 너무 커지는 것을 효과적으로 방지한다[81].

풀링 계층은 컨볼루션 계층의 결괏값인 특징 맵(feature map)의 크기를 축소하는 역할을 하는 개념으로 컨볼루션 계층간의 연결 수를 줄여 계산 부담을 줄인다. 대표적인 풀링 방법으로는 예를




Fig. 8. A generic CNN Architecture




Fig. 9. Convolution process

들어 2x2 영역에 있는 요소 4 개 중 최댓값을 취하는 최대 풀링(max pooling) 또는 4개의 평균값으로 하는 평균(average pooling)이 있다. 이렇게 몇 개의 컨볼루션 계층과 풀링 계층이 반복 연결되어 컨볼루션과 풀링 연산을 한 후에 마지막에는 풀링 계층이 벡터 형태인 완전 연결 계층에 연결된다.

최근에는 CNN 의 다양한 변형 아키텍처가 연구 개발되고 있으며[81], 여러 아키텍처가 부식 판별이나 분석에 이용되고 있다[82, 83]. 열전 파이프(thermoelectric metallic) 벽 내부 표면의 다양한 부식 수준을 식별하는데 TCNN(texture CNN)을 이용한 연구가 보고되었다[22]. [84]에서는 U-Net 을 기반으로 부식 검출하는 방법을 제시했다. [26]에서는 철 구조체의 부식을 검출하기 위해 부식 질감과 색상 특징을 ANN 에 입력으로 하는 방법을 제시했다. [85]에서는 다양한 조명과 환경을 고려한 부식 검출 알고리즘을 개발하기 위해 실험실에서 만든 훈련 데이터 5000 개로 ANN 을 훈련시킨 후 강철 교량의 부식 검출에 적용했다. [86]에서는 의미론적 분할을 위해 수정된 고해상도 네트워크(HRNetV2, High-Resolution Network as modified for semantic segmentation)로 부식을 픽셀 수준으로 분할하는 방법을 제시했다. [2]에서는 CNN을 기반으로 하는 앙상블 딥 러닝 프레임워크로 구조물의 부식을 분류하는데 적용했다.

4.6 R-CNN 과 Faster R-CNN

영상에 포함된 각 객체를 구별해 내는 R-CNN(Regions with CNN features)[87] 은 입력 영상에서 객체가 있을 가능성이 있는 영역(region proposals, 그림 11에서 파란색 박스)을 선택적 검색(selective search)[88]로 약 2000 개 이내로 찾는다. 각 선택적 영역을 5개의 레이어

와 2개의 완전 연결 계층(fully connected layer)을 가진 CNN 에 입력하여 특징(feature)을 찾고, 이를 선형 SVM로 분류하고 선형 회귀(linear regressor)로 객체에 꼭 맞는 박스를 그린다.

R-CNN 아이디어를 바탕으로 많은 객체 탐지 모델들이 개발되고 있다. R-CNN[89]은 학습이 여러 단계로 진행되어 학습 시간과 검출 시간이 많이 소요된다. Fast R-CNN 은 입력 영상을 CNN 에 인가하여 특징 맵(feature map)을 구하고, 입력 영상에서 선택적 검색으로 영역 제안(region proposals)을 구한다. 영역 제안을 특징 맵에 투영하여 관심 영역(ROI, Region of Interest)을 구하고, ROI 풀링 계층(Pooling layer)은 ROI로부터 크기가 고정된 특징을 구하고, 이 특징들을 두 개의 완전 연결 계층에 각각 인가하여 한 계층에

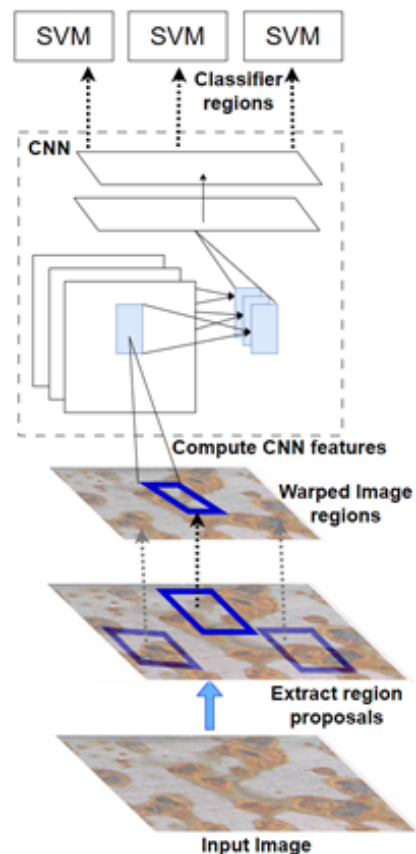


Fig. 10. R-CNN architecture




Fig. 11. Faster R-CNN structure [36]

서는 Softmax 를 이용해서 객체를 예측하고, 다른 계층에서는 객체 경계 박스(bounding box)를 구한다. Fast R-CNN 은 2000 개의 영역 제안이 CNN 에 매번 입력될 필요 없이 단 한 장의 입력 영상으로 특징 맵을 구하고 RoI 풀링 계층 출력인 고정 크기를 갖는 특징 벡터를 이용하여 R-CNN 보다 빠르게 객체를 판별할 수 있다.

Faster R-CNN[90]은 fast R-CNN 에서 이용된 선택적 검색 대신 RPN(Region Proposal Network) 이 CNN 으로 생성된 특징 맵에서 다양한 크기의 직사각형 경계 박스인 anchor 박스(그림 12 에서 붉은색 박스)를 생성한다. RPN 에서 구한 제안 영역은 RoI pooling 계층에 입력되고, Softmax 분류 계층과 경계 상자 회귀 분석기는 RoI pooling 계층 출력을 입력 받아 영상에서

분류된 객체의 정확한 위치를 표시해 준다.

[20] 에서는 Faster R-CNN, SSD-Mobile net 및 SSD Inception V2를 포함한 심층 신경망 모델을 사용하고 앵커 박스 최적화로 최적화하여 선적 컨테이너 표면의 부식 결함을 자동으로 검사하는 방법을 제안했다. [91] 에서는 FCN(Fully Convolutional Networks), U-Net 및 Mask R-CNN으로 입력 영상에서 부식 영역을 분리하고 유역 분할 알고리즘으로 경계선을 구한 후 부식 영역을 분할 하는 방법을 제시했다.

4.7 전체적으로 중첩된 경계선 검출

심층 신경망 러닝(deep learning) 기반 경계선 검출 알고리즘에는 CDEN, RINDNet, COB, AMH-Net, DeepEdge, HED, RCF, RCN, VCF 와 많은 알고리즘이 있다[31]. 전체적으로 중첩된 경계선 검출(HED, Holistically-Nested Edge Detection) [92]은 그림 13 과 같이 콘볼루션 계층과 max pooling 을 갖는 VGGNet[93] 을 바탕으로 종단간 학습(end-to-end) 방식으로 경계선을 훈련하고 예측한다. 훈련 데이터 $S = \{(X_n, Y_n), n = 1, 2, \dots, N\}$ 에서 Y_n 은 입력 영상 에 X_n 대해 HED 가 예측해 주길 바라는(ground truth) 이진 영상 경계선 맵이다. 훈련 데이터로 학습된 HED 모델에서 새로운 영상을 입력하면 모델의 콘볼루션 계층 conv1_2, conv2_2, conv3_3, conv4_3, conv5_3 의 출력(side outputs)를 디콘볼루션(deconvolution) 하여 경계선을 구한다.




Fig. 12. HED architecture. side output from the conv1_2, conv2_2, conv3_3, conv4_3, conv5_3 layers




Fig. 13. (a) Sample specimen, rust with probability 1.0, (b) Apple(source: pixabay), no rust with probability 0.22, (c) Sunflower(source: pixabay), no rust with probability 0.42

5. 예 제

5.1 분류(classification) 문제

Scikit-learn[94-sklearn] 패키지 SVM 으로 영상에 부식이 있는지를 판별하기 위해 부식이 아닌 샘플(1, norust) 70 장, 부식 샘플(0, rust) 79 장[90]으로 모델을 훈련시켰다. 훈련 결과를 평가하기 위해 그림 13 에서와 같이 영상 3개를 테스트했다. 부식 분류는 부식 확률이 50 %를 넘으면 부식으로, 그렇지 않으면 부식 아닌 것으로 분류한다. 그림 13 의 (a)는 부식이 있는 시편으로 확률 1.0 으로 부식으로 분류하였고, (b) 는 사과로서 부식 확률 0.22 로 부식이 아님으로 판정하였다. SVM은 해바라기 영상 (그림13-(c))을 확률 0.56 로 부식으로 분류했다. 훈련에 사용된 이미지는[95] 주로 창문이나 현관과 같은 격자형 샘플과 빨간색 원형 물체를 부식이 아닌 샘플(norust)로 구성되었다. pixabay 에서 해바라기 사진 8장을 norust 샘플에 추가한 후 다시 훈련을 거친 다음 그림 13 의 (c) 영상을 테스트한 결과 부식 확률 0.43 으로 부식이 아닌 것으로

분류되었다. 따라서 지도학습 머신러닝은 용도에 맞게 잘 정의된 매우 많은 샘플로 훈련해야 성능이 향상됨을 보여준다[96].

5.2 Segmentation 문제

그림 14-(a) 시편으로 비지도학습 방법인 K-means, Fuzzy C-means, DBSCAN 그리고 지도학습 방법인 HED를 이용해서 영역 분할을 구한 예를 보인다. 그림 14-(b) 와 (c) 는 각각 5 개 영역(K=5) 로 했을 때 K-means와 Fuzzy C-means 결과이고, 그림 14-(d) 는 일때 DBSCAN 결과로서 하얀 실선으로 경계가 구분된 2303 개의 영역이 구해졌다. 이 예에서 같은 클러스터 개수에 대해 K-means와 Fuzzy C-means 는 거의 동일한 분할 결과를 보여줬다. K-means와 Fuzzy C-means는 사용자가 클러스터 개수를 일일이 지정해야 하지만 DBSCAN 은 반경 이 주어지면 클러스터를 자동 생성하는 장점이 있다. 그러나 이 방법들로 부식을 분석하기 위해서는 어느 클러스터가 부식에 해당되는지를 지정해야 한다.




fig.14. (a) Sample specimen (b) K-means with K=5 (c) Fuzzy C-means with k=5 (d) DBSCAN with $\epsilon=5$, (e) HED output(edge) (f) HED segment using blob(binary large object)

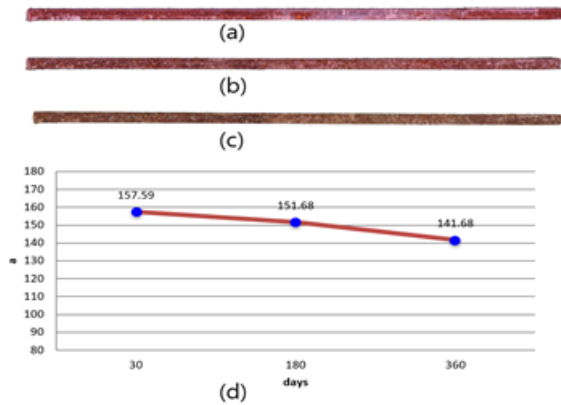


Fig. 15. Hot-dip Galvanized Iron(HGI) (a) 30 day, (b) 180 day, (c) 360 day, (d) trend of average 'a' values.




Fig. 16. 30 days HGI (a) a vs. b, (b) a vs. L, (c) 3D scatter plot




Fig. 17. 360 days HGI (a) a vs. b, (b) a vs. L, (c) 3D scatter plot

5.3 Pixel 칼라 분포 문제

그림 16과 17은 각각 열연용융아연도금강판 (HGI) 을 30일, 360일 동안 외부에 노출했을 때 샘플 단면의 부식 색상을 Lab 공간에서 분석한 결과다. 그림 16-(a)와 그림 17-(a)는 a 대 b의 점 분포도이다. 30일 노출한 그림 16-(a)에서 a의 평균은 157.59, 표준편차는 8.81 이고, 360일 노출한 그림 8-(a)에서 a의 평균은 141.68, 표준편차는 5.64 이다. 이 샘플은 노출 시간이 길수록 단면 색상이 그림 1의 (c)에 있는 Lab 공간에서 원점 방향으로 이동하고, 표준편차도 8.81에서 5.64로 작아진다는 것은 색상이 평균 색상으로 밀집하고 있음을 보여준다. 그림 16-(b)와 그림 17-(b)는 a 대 L의 점 분포도이다. 그림 16-(a),(b), 그림 17-(a),(b) 점 분포도의 가운데 검은 점선은 해당 변수의 평균을 양쪽 푸른색 점선은 표준편차선이고, 점 분포도의 위쪽과 우측 그래프는 점 분포도에 대한 커널밀도추정(kernel density estimate)이다. 30일 노출한 그림 16-(b)에서는 L이 상당히 넓게 분포하고 있으며 색상이 225 이상까지 분포되어 있어 상대적으로 밝은 색상이 존재함을 보여주고, 360일 노출한 그림 17-(b)에서는 a와 L 분포가 좁아지고 상단이 약 220으로 색상이 어두운 쪽으로 이동하는 것을 보여준다. 그림 16-(c)와 그림 17-(c)는 Lab 분포를 3차원 공간에 플롯한 것으로 그림 17-(c)는 그림 16-(c)에 비해 색상 분포가 밀집함을 잘 보여준다. 이와 같이 픽셀의 색상을 분석할때 Lab 모델은 유클리드 거리정보를 이용할 수 있으므로 평균과 표준편차를 사용하여 색상 분포 분석에 유용함을 보여준다.

6. 결론

본 논문에서는 부식 분석이나 판별에서 사용되는 다양한 영상 처리 기법을 소개하였고, 전통적인 영상 처리 기법과 머신 러닝을 적용한 예를 보였다. 부식은 색상이 붉은색 계통과 갈색 계통이 대부분이고 표면이 거칠고 매우 불규칙한 형태이고 조명 영향도 많이 받으므로 영상 처리 기법을 적용할 때 알맞은 색상 공간과 효과적인 기법을 고려할 필요가 있다. 부식 판별이나 분석을 하기 위해서는 부식 영역을 경계선으로 표시하거나 부식 영역 분할이 필요하다. 최근에는 SVM이나 CNN 기반 알고리즘 등 머신 러닝 알고리즘들이 부식 판별에 많이 적용되고 있다. 또한 영역 분할에도 머신 러닝을 적용한 연구가 매우 활발히 진행되고 있다. 그러나 지도 기반 머신 러닝 알고리즘을 부식 검출과 분석에 적용해 높은 정확도를 얻기 위해서는 많은 데이터가 필요하다.

REFERENCES

[1] M. Komary, S. Komarizadehasl, N. Tooic, I. Segura, J.A. Lozano-Galant, J. Turmo, Low-cost technologies used in corrosion monitoring, *Sensors*, 23 (2023) 1309.

[2] A. R. M. Forkan, Y. B. Kang, P. P. Jayaraman, K. Liao, R. Kaul, G. Morgan, S. Sinha, Corrdetector: A framework for structural corrosion detection from drone images using ensemble deep learning,

- Expert Systems with Applications, 193 (2022) 116461.
- [3] N. N. Almanza-Ortega, J. M. Flores-Vazquez, H. Martínez-Anorve, J. Perez-Ortega, J. C. Zavala-Diaz, A. Mexicano-Santoyo, J. C. Carmona-Fraustro, Corrosion analysis through an adaptive preprocessing strategy using the K-means algorithm, *Procedia Computer Science*, 219 (2023) 586-595.
- [4] M. A. Jayaram, M. A. Computer vision applications in construction material and structural health monitoring: A scoping review, *Materials Today: Proceedings* (2023).
- [5] M. S. B. Reddy, D. Ponnamma, K. K. Sadasivuni, S. Aich, S. Kailasa, H. Parangusan, R. Zarandah, Sensors in advancing the capabilities of corrosion detection: A review, *Sensors and Actuators A: Physical*, 332 (2021) 113086.
- [6] H. Zhu, H. Luo, D. Ai, C. Wang, Mechanical impedance-based technique for steel structural corrosion damage detection, *Measurement*, 88 (2016) 353-359.
- [7] S. Sharma, A. Mukherjee, Ultrasonic guided waves for monitoring corrosion in submerged plates, *Struct Control Health Monit*, 22 (2015) 19-35.
- [8] S. Doshvarpassand, C. Wu, X. Wang, X, An overview of corrosion defect characterization using active infrared thermography, *Infrared Physics and Technology*, 96 (2019) 366-389.
- [9] M. Enikeev, I. Gubaydullin, M. Maleeva, Analysis of corrosion process development on metals by means of computer vision, *Engineering Journal*, 21 (2017) 183-192.
- [10] H. S. Munawar, F. Ullah, D. Shahzad, A. Heravi, S. Qayyum, J. Akram, Civil infrastructure damage and corrosion detection: An application of machine learning, *Buildings*, 12 (2022) 156.
- [11] Q. Chen, X. Wen, S. Lu, D. Sun, Corrosion detection for large steel structure base on uav integrated with image processing system, *IOP Conference Series: Materials Science and Engineering*, 608 (2019) 012020.
- [12] M. Khayatazad, L. De Pue, W. De Waele, Detection of corrosion on steel structures using automated image processing, *Developments in the Built Environment*, 3 (2020) 100022.
- [13] X. Lv, F. Duan, J.J. Jiang, X. Fu, L. Gan, Deep metallic surface defect detection: The new benchmark and detection network, *Sensors*, 20 (2020) 1562.
- [14] S. Doshvarpassand, C. Wu, X. Wang, An overview of corrosion defect characterization using active infrared thermography, *Infrared Physics and Technology*, 96 (2019) 366-389.
- [15] S. K. Ahuja, M. K. Shukla, A survey of computer vision based corrosion detection approaches, *ICTIS*, 2 (2018) 55-63.
- [16] H. Jia, G. Qiao, P. Han, Machine learning algorithms in the environmental corrosion evaluation of reinforced concrete structures-A review, *Cement and Concrete Composites*, (2022) 104725.
- [17] M. M. H. Imran, S. Jamaludin, A. F. M. Ayob, A. A. I. Ali, S. Z. A. S. Ahmad, M. F. A. Akhbar, S. B. Mohamed, Application of artificial intelligence in marine corrosion prediction and detection, *Journal of Marine Science and Engineering*, 11 (2023) 256.
- [18] Z. Lin, W. Zhang, J. Li, J. Yang, B. Han, P. Xie, Application of artificial intelligence (AI) in the area of corrosion protection, *Anti-Corrosion Methods and Materials*, 70 (2023) 243-251.
- [19] P. H. Chen, L. M. Chang, Artificial intelligence application to bridge painting assessment, *Automation in Construction*, 12 (2003) 431-445.
- [20] Z. Bahrami, R. Zhang, R. Rayhana, T. Wang, Z. Liu, Optimized deep neural network architectures with anchor box optimization for shipping container corrosion inspection, *IEEE Symposium Series on Computational IntelligenceComput Intell*, (2020) 1328-

- 1333.
- [21] F. N. Medeiros, G. L. Ramalho, M. P. Bento, L. C. Medeiros, On the evaluation of texture and color features for nondestructive corrosion detection, *EURASIP Journal on Advances in Signal Processing*, (2010) 1–7.
- [22] D. Vriesman, A. B. Junior, A. Zimmer, A. L. Koerich, Texture CNN for thermoelectric metal pipe image classification, *International Conference on Tools for Artificial Intelligence*, (2019) 569–574.
- [23] D. Haitz, P. Hubner, M. Ulrich, S. Landgraf, B. Jutzi, Semantic segmentation with small training datasets: a case study for corrosion detection on the surface of industrial objects, *Image Processing Forum*, (2022) 73–85.
- [24] J. A. I. Diaz, M. I. Ligeralde, J. A. C. Jose, A. A. Bandala, Rust detection using image processing via Matlab, *TENCON 2017 - 2017 IEEE Region 10 Conference*, (2017) 1327–1331.
- [25] D. Haitz, P. Hubner, M. Ulrich, B. Jutzi, A comparison of learning-based approaches for the corrosion detection on barrels in industrial applications, *tm - Technisches Messen*, (2023).
- [26] M. Khayatazad, M. Honhon, W. De Waele, Detection of corrosion on steel structures using an artificial neural network, *Struct. Infrastruct. Eng.*, 19 (2023) 1860–1871.
- [27] W. A. Mustafa, M. M. M Abdul Kader, A review of histogram equalization techniques in image enhancement application, *Journal of Physics: Conference Series*, 1019 (2018) 012026.
- [28] A. K. Aijazi, L. Malaterre, M. L. Tazir, L. Trassoudaine, P. Checchin, Detecting and analyzing corrosion spots on the hull of large marine vessels using colored 3D lidar point clouds, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 3 (2016) 153–160.
- [29] H. K. Shen, P. H. Chen, L. M. Chang, Automated steel bridge coating rust defect recognition method based on color and texture feature, *Automation in Construction*, 31 (2013) 338–356.
- [30] V. Bondada, D. K. Pratihar, C. S. Kumar, Detection and quantitative assessment of corrosion on pipelines through image analysis, *Procedia Computer Science*, 133 (2018) 804–811.
- [31] R. Sun, T. Lei, Q. Chen, Z. Wang, X. Du, W. Zhao, A. K. Nandi, Survey of image edge detection, *Front Signal Process*, 2, (2022) 826967.
- [32] C. Rother, V. Kolmogorov, A. Blake, "GrabCut" interactive foreground extraction using iterated graph cuts, *ACM Transactions on Graphics*, 23 (2004) 309–314.
- [33] N. D. Hoang, V. D. Tran, Image processing-based detection of pipe corrosion using texture analysis and metaheuristic-optimized machine learning approach, *Computational Intelligence and Neuroscience*, 8097213 (2019) 1–13.
- [34] S. Beucher, F. Meyer, The morphological approach to segmentation: the watershed transformation, *Mathematical Morphology in Image Processing*, 34 (1993) 49.
- [35] M. M. H. Imran, S. Jamaludin, A. F. M. Ayob, A. A. I. M Ali, S. Z. A.S. Ahmad, M. F. A. Akhbar, S. B Mohamed, Application of artificial intelligence in marine corrosion prediction and detection, *Journal of Marine Science and Engineering*, 11 (2023) 256.
- [36] S. Minaee, Y. Boykov, F. Porikli, A. Plaza, N. Kehtarnavaz, D. Terzopoulos, Image segmentation using deep learning: A survey, *IEEE Trans Pattern Anal Mach Intell*, 44 (2021) 3523–3542.
- [37] K. P. Sinaga, M. S. Yang, Unsupervised K-means clustering algorithm, *IEEE access*, 8 (2020) 80716–80727.
- [38] B. Kim, J. Kwon, S. Choi, J. Noh, K. Lee, J. Yang. Corrosion Image Monitoring of steel plate by using k-means clustering,

- Journal of the Korean Society of Surface Science and Engineering, 54 (2021) 278-284.
- [39] K. Khan, S. U. Rehman, K. Aziz, S. Fong, S. Sarasvady, DBSCAN: Past, present and future, The International Conference on The Applications of Digital Information and Web Technologies, (2014) 232-238.
- [40] B. Kim, Y. Kim, K. Lee, J. Yang, Corrosion image analysis on galvanized steel by using superpixel DBSCAN clustering algorithm, Journal of the Korean Society of Surface Science and Engineering, 55 (2022) 164-172.
- [41] M. Trujillo, M. Sadki, Fuzzy C-means classification for corrosion evolution of steel images, In Image Processing: Algorithms and Systems III, 5298, (2004) 318-327.
- [42] B. E. Boser, I. M. Guyon, V. N. Vapnik, A training algorithm for optimal margin classifiers, Proceedings of the fifth annual workshop on Computational learning theory, (1992) 144-152.
- [43] P. H. Chen, H. K. Shen, C. Y. Lei, L. M. Chang, Support-vector-machine-based method for automated steel bridge rust assessment, Automation in Construction, 23 (2012) 9-19.
- [44] L. B. Soares, P. J. Evald, E. A. D. Evangelista, P. L. J. Drews-Jr, S. S. D. C. Botelho, R. I. Machado, An autonomous inspection method for pitting detection using deep learning, 2023 INDIN - 21st IEEE International Conference on Industrial Informatics, (2023) 1-6.
- [45] G. Sanchez, W. Aperador, A. Cerón, Corrosion grade classification: a machine learning approach, Indian Institute of Chemical Engineers, 62 (2020) 277-286.
- [46] N. A. Ibraheem, M. M. Hasan, R. Z. Khan, P. K. Mishra, Understanding color models: a review, ARPN Journal of science and technology, 2 (2012) 265-275.
- [47] E. Chavolla, D. Zaldivar, E. Cuevas, M. A. Perez, Color spaces advantages and disadvantages in image color clustering segmentation, Advances in soft computing and machine learning in image processing, (2018) 3-22.
- [48] L. Petricca, T. Moss, G. Figueroa, S. Broen, Corrosion detection using AI: a comparison of standard computer vision techniques and deep learning model, International Conference on Computer Science, Engineering and Information Technology, (2016) 91-99.
- [49] M. W. Schwarz, W. B. Cowan, J. C. Beatty, An experimental comparison of RGB, YIQ, LAB, HSV, and opponent color models, ACM Transactions on Graphics, 6 (1987) 123-158.
- [50] K. Leon, D. Mery, F. Pedreschi, J. Leon, Color measurement in L*a*b* units from RGB digital images, Food Research International, 39 (2006) 1084-1091.
- [51] R. C. Gonzales, P. Wintz, Digital image processing, Addison-Wesley Longman Publishing Co., Inc., (1987).
- [52] G. N. Chaple, R. D. Daruwala, M. S. Gofane, Comparisons of Robert, Prewitt, Sobel operator based edge detection methods for real time uses on FPGA, ICTSD-2015, (2015) 1-4.
- [53] J. Canny, A computational approach to edge detection, IEEE Transactions on Pattern Analysis and Machine Intelligence, 6 (1986) 679-698.
- [54] S. R. Gunn, On the discrete representation of the Laplacian of Gaussian, Pattern Recognit, 32 (1999) 1463-1472.
- [55] V. Torre, T. A. Poggio, On edge detection, IEEE Transactions on Pattern Analysis and Machine Intelligence, 2 (1986) 147-163.
- [56] R. K. Ranjan, T. Gylati, Condition assessment of metallic objects using edge detection, International Journal of Advanced Research in Computer Science and Software Engineering, 4 (2014) 253-258.

- [57] B. Kim, Y. Kim, J. Yang, Detection of corrosion on steel plate by using Image Segmentation Method, *Journal of the Korean Society of Surface Science and Engineering*, 54 (2021) 84-89.
- [58] R. Vorobel, I. Ivasenko, O. Berehulyak, T. Mandzii, Segmentation of rust defects on painted steel surfaces by intelligent image analysis, *Automation in Construction*, 123, (2021) 103515.
- [59] B. Yin, N. Josselyn, T. Considine, J. Kelley, B. Rinderspacher, R. Jensen, W. Rundensteiner, Corrosion image data set for automating scientific assessment of materials, *BMVC*, (2021) 1-15.
- [60] D. A. Yeshanew, M. G. Jiru, G. M. S. Ahmed, I.A. Badruddin, M.E.M Soudagar, S. Kamangar, M. A. Tolcha, Corrosion characterization at surface and subsurface of iron-based buried water pipelines, *Materials*, 14 (2021) 5877.
- [61] A. Carlos, Mendiola-Santibanez, F. Paredes-Orta, D. Jorge, I.R. Terol-Villalobos, Method for grain size determination in carbon steels based on the ultimate opening, *Measurement*, 133 (2019) 193-207.
- [62] H. Gao, W. C. Siu, C. H. Hou, Improved techniques for automatic image segmentation, *IEEE Transactions on Circuits and Systems for Video Technology*, 11 (2001) 1273-1280.
- [63] X. J. XWang, X. J. Sun, C. Song, H. Chen, S. Tong, W. Han, F. Pan, Grain size-dependent mechanical properties of a high-manganese austenitic steel, *Acta Materialia*, 32 (2019) 746-754.
- [64] G. Ji, Y. Zhu, Y. Zhang, The corroded defect rating system of coating material based on computer vision, *Transactions on edutainment VIII*, (2012) 210-220.
- [65] F. N. Medeiros, G. L. Ramalho, M. P. Bento, L.C. Medeiros, On the evaluation of texture and color features for nondestructive corrosion detection, *EURASIP Journal on Advances in Signal Processing*, (2010) 1-7.
- [66] B. Ghogh, F. Karray, M. Crowley, Fisher and kernel Fisher discriminant analysis: Tutorial, *arXiv:1906.09436*, (2019).
- [67] P. S. Addison, *The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance*, CRC press, (2017).
- [68] T. A. Alkanhal, Image processing techniques applied for pitting corrosion analysis, *IJRET*, (2014) 385-391.
- [69] S. A. Idris, F. A. Jafar, Image enhancement based on software filter optimization for corrosion inspection, *International Conference on Advanced Intelligent Systems for Sustainable Development*, (2014) 345-350.
- [70] S. Ghanta, T. Karp, S. Lee, Wavelet domain detection of rust in steel bridge images, *ICASSP*, (2011) 1033-1036.
- [71] G. R. Yang, X. J. Wang, Artificial neural networks for neuroscientists: a primer, *Neuron*, 107 (2020) 1048-1070.
- [72] M. Ahmed, R. Seraj, S. M. S. Islam, The k-means algorithm: A comprehensive survey and performance evaluation, *Electronics*, 9 (2020) 1295.
- [73] K. S. Liao, Y. T. Lee, Detection of rust defects on steel bridge coatings via digital image recognition, *Automation in Construction*, 71 (2016) 294-306.
- [74] A. A. Bushra, G. Yi, Comparative analysis review of pioneering DBSCAN and successive density-based clustering algorithms, *IEEE Access*, 9 (2021) 87918-87935.
- [75] L. Sun, Y. Li, X. Li, C. Liu, Corrosion defect segmentation method based on superpixel feature cascade, *Ain Shams Eng.*, (2023) 102425. clustering algorithm, *IEEE Access*, 8 (2020) 80716-80727.
- [76] S. Ghosh, S. K. Dubey, Comparative analysis of k-means and fuzzy c-means algorithms, *International Journal of Advanced Computer Science and*

- Applications, 4 (2013)35–39.
- [77] V. Mosorov, L. Tomczak, Image texture defect detection method using fuzzy C-means clustering for visual inspection systems, *Arabian Journal for Science and Engineering*, 39, (2014) 3013–3022.
- [78] C. Cortes, V. Vapnik, Support-vector networks, *Machine learning*, 20 (1995) 273–297.
- [79] N. D. Hoang, Image processing-based pitting corrosion detection using metaheuristic optimized multilevel image thresholding and machine-learning approaches, *Mathematical Problems in Engineering*, (2020) 1–19.
- [80] S. Hakimian, S. Pourrahimi, A. H. Bouzid, L.A. Hof, Application of machine learning for the classification of corrosion behavior in different environments for material selection of stainless steels, *Computational Materials Science*, 228, (2023) 112352.
- [81] Z. Li, F. Liu, W. Yang, S. Peng, J. Zhou, A survey of convolutional neural networks: analysis, applications, and prospects, *IEEE Transactions on Neural Networks and Learning Systems*, (2021). 6999–7019.
- [82] W. Nash, T. Drummond, N. Birbilis, A review of deep learning in the study of materials degradation, *npj Materials Degradation*, 2 (2018) 37.
- [83] L. B. Coelho, D. Zhang, Y. Van Ingelgem, D. Steckelmacher, A. Nowe, H. Terryn, Reviewing machine learning of corrosion prediction in a data-oriented perspective, *npj Materials Degradation*, 6 (2022) 8.
- [84] A. Srivastava, G. Ji, R. K. Singh, Application of deep-learning architecture for image analysis based corrosion detection, In 2021 STCR (2021) 1–5.
- [85] D. L. Naik, H. U. Sajid, R. Kiran, G. Chen, Detection of corrosion-indicating oxidation product colors in steel bridges under varying illuminations, shadows, and wetting conditions, *Metals*, 10 (2020) 1439.
- [86] W. Nash, L. Zheng, N. Birbilis, Deep learning corrosion detection with confidence, *npj Materials Degradation*, 6(1), (2022) 26.
- [87] R. Girshick, J. Donahue, T. Darrell, J. Malik, Rich feature hierarchies for accurate object detection and semantic segmentation, *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, (2014) 580–587.
- [88] J. R. Uijlings, K. E. Van De Sande, T. Gevers, A.W. Smeulders, Selective search for object recognition, *International Journal of Computer Vision*, 104, (2013) 154–171.
- [89] R. Girshick, Fast r-cnn, *Proceedings of the IEEE International Conference on Computer Vision*, (2015) 1440–1448.
- [90] S. Ren, K. He, R. Girshick, J. Sun, J. Faster r-cnn: Towards real-time object detection with region proposal networks, *Advances in Neural Information Processing Systems*, 28 (2015) 1–9.
- [91] I. Katsamenis, E. Protopapadakis, A. Doulamis, N. Doulamis, A. Voulodimos, Pixel-level corrosion detection on metal constructions by fusion of deep learning semantic and contour segmentation, *Advances in Computer Vision and Pattern Recognition*, (2020) 160–169.
- [92] S. Xie, Z. Tu, Holistically-nested edge detection, *Proceedings of the IEEE International Conference on Computer Vision*, (2015) 1395–1403.
- [93] K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, *arXiv:1409.1556*, (2014).
- [94] "scikit-learn", scikit-learn, last modified Nov 27. 2023, accessed Nov 29. 2023, <http://scikit-learn.org>.
- [95] "github", github, last modified Dec 12. 2023, accessed Dec 13. 2023, <https://github.com/anirbankonar123>.
- [96] H. Huang, H. Zhou, X. Yang, L. Zhang, L. Qi, A. Y. Zang, Faster R-CNN for marine organisms detection and recognition using data augmentation, *Neurocomputing*, 337 (2019) 372–384.