

레이저 변위 센서를 활용한 배관 표면 상태분류

천강민*, 신백천*, 신건호*, 고정일*, 이준혁*, 허장욱*,#

*금오공과대학교 기계공학과(항공기계전자융합공학전공)

Classification of the Rusting State of Pipe Using a Laser Displacement Sensor

Kang-Min Cheon*, Baek-Cheon Shin*, Geon-Ho Shin*, Jeong-Il Go*, Jun-Hyeok Lee*, Jang-Wook Hur*#

*Department of Mechanical Engineering (Department of Aeronautics, Mechanical and Electronic Convergence Engineering of Mechanical Engineering), Kumoh National Institute of Technology

(Received 13 March 2022; received in revised form 31 March 2022; accepted 11 April 2022)

ABSTRACT

Although pipe performs various functions in industrial sites and residential spaces, if it is damaged due to corrosion caused by the external environment, it may cause equipment failure or a major accident. For this reason, various studies for safety management are being conducted, but studies on detecting corrosion or cracks on the pipe surface using a laser displacement sensor have hardly been conducted. Therefore, in this study, the corrosion degree of the pipe surface was compared and classified into 4 corrosion conditions, and inspection equipment using a laser scanner was manufactured. The corrosion height was calculated from the four surface data obtained from the measuring equipment and applied to various CNN algorithms, and 91% accuracy was obtained during training using the Modified VGGNet16 code with reduced number of parameters.

Keywords : Pipe(배관), Laser Displacement Sensor(레이저 변위 센서), Convolution Neural Network(합성곱신경망), VGGNet(VGGNet), State Classification(상태분류)

1. 서 론

배관은 산업 현장의 지상 구조물, 해양 및 지하에 매립되어 석유, 가스 등 연료를 수송하는 설비로 사용되거나, 주거공간에 생활수를 공급하는 기능 등을 수행한다^[1]. 금속 재질의 배관은 시간이 지남에 따라 온도, 수분 및 산성 등 외부 환경에

의해 발생하는 부식 현상으로 불순물이 연료와 함께 장비에 공급되어 고장을 유발할 수 있고, 표면 부식으로 인해 연료가 외부로 유출될 수 있으며, 특히, 해수와 발전소에서 오랜 기간 동안 사용된 배관은 반복적인 고온, 고압 등의 극한 환경으로 파손되어 큰 사고를 야기할 수 있다^[2,3].

이로 인해 침투식 센서를 이용한 배관 내부 검사, 음향 및 진동 신호를 이용한 분석 등 국내외에서 안전성 관리를 위한 다양한 연구가 이루어지고 있다^[4-6]. 그러나, 배관 표면보다 내부 검사를

Corresponding Author : hhjw88@kumoh.ac.kr

Tel: +82-54-478-7399

위한 연구가 활발하게 진행되고 있으며, 레이저 변위 센서 등을 사용하여 배관의 표면 스캔으로 부식 또는 크랙을 탐지하는 연구는 거의 이루어지지 않고 있다. 이러한 레이저 변위 센서는 측정 대상과 비접촉하여 배관 표면 상태를 스캔할 수 있으며, 원격으로 표면을 검사할 수 있어 위험한 작업 현장으로 작업자를 투입하지 않고 검사할 수 있는 특징이 있다. 또한, 레이저 변위 센서는 작업자들이 육안으로 파악하기 어려운 미세한 크랙 등을 사전에 파악할 수 있으며, 배관 표면의 상태를 확인함으로써 교체 시기를 결정할 수 있다.

따라서, 본 연구에서는 육안으로 식별이 곤란한 배관의 표면 정보를 얻기 위해 레이저 변위 센서를 이용하여 제작한 측정장비로 배관의 표면을 스캔하였으며, 측정된 부식 높이를 파라미터로 하여 배관의 상태를 분류하였다. 또한, 배관의 표면 데이터를 이용하여 상태를 분류하는 인공지능 방법론 적용을 위해 CNN 알고리즘 기법 중 최적의 상태 분류 알고리즘을 제시하였다.

2. 부식 높이 측정

2.1 측정센서

배관의 부식 높이 측정을 위한 센서는 레이저 변위 측정용 스캐너를 이용하였으며, 센서는 물리적인 접촉 없이 대상 물체의 표면 정보를 획득할 수 있는 장치로 Riftek사의 RF627 모델을 사용하였다. 센서는 레이저를 방사하여 연속적인 라인 스캔을 통해 2차원 평면 데이터 획득이 가능하며, 측정 정밀도는 $1\mu\text{m}$ 수준이다. 센서의 형상과 측정 범위를 Fig. 1에 나타내었으며, 광학 삼각 측량의 원리를 기반으로 하고 있다. 레이저의 방사는 렌즈에 의해 직선으로 형성되어 물체에 투영되고, 물체로부터 산란된 방사선은 렌즈에 의해 수집되며, 2차원 CMOS(Complementary Metal Oxide Semiconductor) 이미지 센서로 전달된다. 이렇게 형성된 물체 윤곽선의 이미지는 FPGA(Field Programmable Gate Array)와 신호 프로세서를 통해 분석되며, 물체(x 좌표)의 레이저 라인에 따른 세트의 각 점을 이용하여 물체까지의 거리(z 좌표)를 계산한다^[7].




Fig. 1 The sensor shape and measurement range.




Fig. 2 Measuring equipment

2.2 측정장비

측정센서가 높은 정밀도로 인해 주변의 빛과 진동 등에 매우 민감하기 때문에 배관은 고정하고, 센서의 진동을 최소화하는 측정장비를 Fig. 2와 같이 설계하여 제작하였다. 배관을 올려놓는 롤러는 배관의 다른 면을 스캔하기 위해 이동없이 회전으로 측정이 가능하게 하였으며, 기준 가이드로 동일한 위치에서 측정할 수 있도록 하였다. 배관의 표면을 길이 방향으로 측정하기 위해 볼 스크류를 사용하여 센서를 이동토록 하였으며, 리니어 가이드를 치구 양쪽에 부착하여 진동을 최소화시켰다. 전원공급 및 제어장치는 센서 측정거리와 이동속도의 조절이 가능토록 하였으며, 실시간 측정되는 형상을 확인하고, 데이터를 저장하기 위해 컴퓨터와 연결하였다.

배관의 측정 조건으로 축 방향은 150mm, 폭은 센서의 측정범위인 21mm로 데이터를 획득하였다.

데이터 용량과 스캔 속도를 고려하여 센서 이송속도는 30mm/s, 프레임 수는 284frame/s로 스캔하였다.

2.3 측정 대상

산업에서 사용하는 배관 중 고압 가스에 사용되는 강관을 측정하였으며, 배관 표면의 부식 정도에 따라 4가지 상태로 분류하였다. 배관 표면이 깨끗한 상태를 A, 경미한 스크래치 또는 부식이 아주 희미하게 나타나는 상태를 B, 표면의 절반이 부식된 상태를 C, 표면 전체가 부식을 나타내는 상태를 D로 분류하였다. 각 상태에 해당하는 배관을 Fig. 3에 나타내었으며, 총 228개의 표면을 스캔하여 표면 데이터를 확보하였다.

3. 상태분류 알고리즘

3.1 CNN

합성곱 신경망(CNN, Convolutional Neural Network)은 1998년 Lecun 등이 수기로 작성한 우편번호를

효율적으로 인식하기 위해 만든 Lenet-5를 소개하면서 등장하였다^[8]. CNN은 컨볼루션 계층(Convolution Layer)과 풀링 계층(Pooling Layer)을 반복하여 수행함으로써 입력 데이터로부터 대상의 특징을 추출하며, 분류 계층(Classification Layer)에서 이미지를 구분한다^[9]. 컨볼루션 계층은 입력 데이터에 필터를 적용하여 컨볼루션 연산을 반복 수행함으로써 특징 맵(Feature Map)을 추출한다. 풀링 계층은 컨볼루션 계층에서 획득한 특징 맵 크기를 줄이고, 특징 추출의 견고성을 높이는 역할을 담당한다^[10]. CNN의 특징은 저차원 정보를 고차원으로 확장하여 분류하며, 이미지의 어떤 위치에서 특정 패턴을 학습할 시 다른 위치에서 학습한 패턴을 인식하는 알고리즘이다.

3.2 VGGNet

VGGNet은 영국 옥스퍼드의 VGG(Visual Geometry Group)가 제안한 논문에 소개되었으며, 2014년 이미지넷 대회에서 우수한 성능을 검증받은 CNN 모델이다^[11]. VGGNet 모델은 기존의 딥러닝 모델들



(a) A state



(b) B state



(c) C state



(d) D state

Fig. 3 Pipe shape according to the degree of rust




Fig. 4 VGGNet16 structure

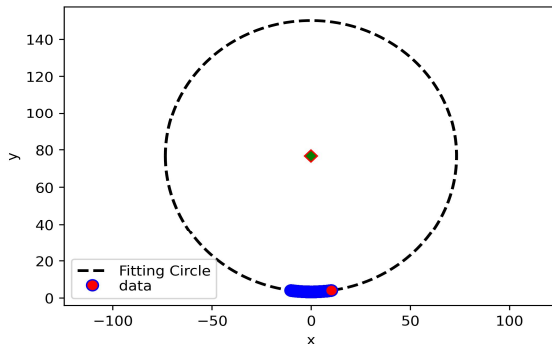



Fig. 5 Suitable circle from surface scan data

이 5x5, 7x7 커널을 사용하여 넓은 정보를 표현하는 반면, 컨볼루션 필터 사이즈를 3x3 커널로 설정하였다. 이로 인해 이미지 사이즈를 점차 줄였으며, 큰 사이즈의 커널을 적용하였을 때 보다 파라미터 수는 적어지고, 네트워크의 깊이가 증가하였다^[11]. 대표적인 VGGNet 구조는 16개의 Layer를 사용하는 VGGNet16과 19개의 Layer를 사용하는 VGGNet19가 있으나, 본 연구에서는 보다 단순한 구조인 VGGNet16을 사용하였으며, VGGNet16에 사용되는 Layer의 종류와 순서를 Fig. 4에 나타내었다^[12].


4. 배관의 상태분류

4.1 데이터 전처리


센서로부터 획득한 배관의 표면 데이터는 한번 스캔 시 원주 방향으로 645개의 x, y, z 데이터가 획득되며, 이때, x는 배관의 원주방향 변위, y는 스캔 횟수, z는 배관과 레이저 스캐너 사이의 높이를 의미한다. 배관의 표면 정보를 사용하기 위해




(a) A state surface



(b) B state surface



(c) C state surface



(d) D state surface

Fig. 6 Visualization of rust height according to the degree of rust

배관의 높이를 나타내는 z축 데이터만 추출하였으며, 위치에 따른 부식 정도를 비교하기 위해 데이터 개수를 일치시켰다. 또한, 표면에서 빛의 반사로 인해 발생한 결측치를 원주 방향으로 선형 보간법을 통해 보충하였다.

제작된 배관의 설계 오차로 인해 센서로부터 배관의 중심까지 발생한 편차를 보상하기 위해 측정 데이터로부터 원의 방정식을 사용하였으며, 배관의 원주를 적용하여 Fig. 5와 같이 표현하였다. A 상태에서 부식 정도가 가장 심한 D상태로 될수록 표면이 균일하지 않고, 부식이 심한 위치에서 데이터가 높게 나타나는 것을 확인할 수 있으며, 부식 정도가 다른 배관의 표면을 Fig. 6에 나타내었다.

4.2 상태분류 모델

이미지넷에서 우수한 성적을 거둔 VGGNet16, RESNet 및 AlexNet 등 다양한 알고리즘을 사용하여 부식 정도에 따른 상태분류를 진행하였지만, 불규칙한 부식 위치 등으로 인해 높은 정확도를 얻지 못하였다. 따라서, 3x3 커널을 연속적으로 사용하여 넓은 영역의 특징을 추출하고, 파라미터 개수를 줄이는 Modified VGGNet16을 배관 부식 상태를 분류하는 알고리즘으로 적용하였다.

배관의 스캔 데이터는 채널이 1이고, 1,420개의 행과 645개의 열을 가진 형태로 데이터 크기, 손실 및 계산 속도를 고려하여 Input_shape(1420, 645, 1)을 설정하였다. 컨볼루션 계층의 필터 개수는 입력 데이터 크기를 고려하여 32개, 64개, 128개, 256개로 늘려갔으며, 분류 계층은 총 4개의 Layer를 사용하였다. 그리고 마지막 Dense Layer의 활성화 함수는 모델이 예측한 결과값을 확률값으로 나타내는 Softmax를 이용하였다. 총 4개의 상태로 분류되는 출력 형태를 고려하였으며, 전체 코드는 Fig. 7에 나타내었다.

학습을 위한 환경설정으로 가중치를 갱신하는 Optimizer(최적화 함수)는 Adam을 사용하였으며, 실제 값과 예측 값의 차이를 수치화하는 함수인 Loss(손실함수)는 다중 클래스 분류에 적합한 Categorical_crossentropy를 사용하였다. 평가지표를 나타내는 Metrics는 Accuracy를 사용하여 학습 과정을 모니터링하였다. 학습 횟수인 Epoch는 최대 300으로





Fig. 7 Modified VGGNet16 model

설정하였고, EarlyStopping 기법을 사용하여 학습 도중 Loss 값이 감소하지 않으면 조기 종료하여 학습시간을 단축하였다.


4.3 상태분류 결과

학습 과정의 Loss와 Accuracy를 Fig. 8에 나타내었으며, 초기에는 Loss 값은 크고, Accuracy도 낮게 나타나지만, Epoch가 증가할수록 점점 수렴하는 것을 나타내고 있다. 학습된 분류 모델의 혼동 행렬(Confusion Matrix)을 Fig. 9에 나타내었으며, 배관 표면 상태가 A와 F일 경우 25%로 정확하게 분류하였다. B상태의 경우에는 1개를 A상태로 분류하였으며, C상태의 경우에는 3개를 B상태, 1개를 F상태로 분류하였다. 이는 A상태의 표면은 매끄럽고, F상태의 표면은 모든 면이 부식되어 표면 특징이 분명하지만, B와 C 상태의 표면은 불특정한 위치에 부식 현상이 발생한 원인으로 보인다. 추후 각 상태에 대한 표면 데이터를 많이 수집하여 학습할 경우 정확도가 향상될 것으로 보인다.

또한, 본 연구에서 적용한 배관 표면 분류 Modified VGGNet16 모델과 대회에서 우수한 성적을 거둔 ResNet, AlexNet, VGGNet16 모델의 학습 결과를 비교하였으며, 위의 모델들은 파라미터 개수가 상당히 많기 때문에 출력층의 개수를 바꾸어 사용하였다. 각 모델들의 성능을 평가하기 위한 척도로 Accuracy, Precision, Recall, F1-score를 사용하였으며, Macro-Average 값으로 전체 클래스에 대한 일반적인 성능을 Table 1에 나타내었다^[13]. Modified



(a) Model accuracy



(b) Model loss

Fig. 8 Training model accuracy and loss graphs

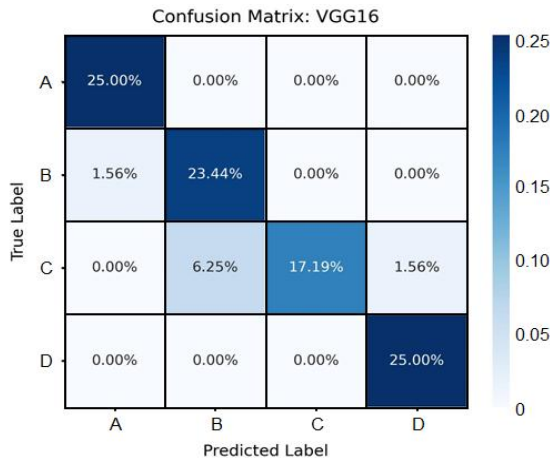


Fig. 9 Confusion Matrix

VGGNet16 모델이 모든 척도에서 다른 모델보다 높게 나타나는 것을 확인할 수 있으며, 이는 ResNet, AlexNet, VGGNet의 경우 출력층을 수정하여 대회에서 사용된 가중치를 전부 적용하지 못해 성능이 떨어지는 것으로 판단된다.

Table 1 Comparison of results of various models

	ResNet50	AlexNet	VGGNet16	Modified VGGNet16
Accuracy	0.55	0.88	0.81	0.91
Precision	0.48	0.89	0.83	0.92
Recall	0.55	0.88	0.81	0.91
F1-score	0.48	0.87	0.81	0.90

5. 결론

배관의 부식 정도에 따른 상태를 분류하기 위해 레이저 스캐너를 이용한 측정장비를 제작하였으며, 표면에서부터 부식 높이를 산출하였다. 각 상태의 표면 데이터를 다양한 CNN 알고리즘으로 학습하였으며, 얻어진 결과를 비교하여 최적의 알고리즘을 제시하였다. 본 연구 내용을 요약하면 다음과 같다.

- 1) 레이저 변위 센서에 의한 표면 정보를 획득하여, 표면에서부터 부식 높이를 측정하였으며, 4 가지 부식 상태를 분류할 수 있다.
- 2) ResNet, AlexNet, VGGNet16, Modified VGGNet16를 적용하여 성능을 평가한 결과 Modified VGGNet16이 가장 우수한 결과를 보였으며, Modified VGGNet16은 Accuracy 91%, Precision 92%, Recall 91%, F1-score 90%를 획득하였다.
- 3) 차후에는 배관의 일부 표면만을 추출하여 측정하는 것이 아니라, 실제 설치된 배관의 모든 면을 검사할 수 있는 측정장비를 설계하여 배관 표면의 부식 상태를 분류할 수 있도록 할 예정이다.

후기

“이 논문은 2019년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. 2019R111A3A01063935)”

REFERENCES

1. Park, K. D. and Kim, D. W., “Environment Corrosion Effect Estimation Engineering Development of Pipe

- Material by Surface Treatment”, Conference of the Korean Society for Power System Engineering, pp. 246-251, 2005.
2. Park, C. S., Sung, K. Y. and Han, S. J., “Experimental Quality Characteristics for Water Removal in Inner Flushing Oil in Process Piping of Offshore Plant”, Journal of The Korean Society of Industry Convergence, Vol. 22, No. 6, pp. 797-805, 2019.
 3. Choi, S. W., Lee, J. H. and Cho, Y. H., “Application of Laser-based Ultrasonic Technique for Evaluation of Corrosion and Defects in Pipeline”, Journal of the Korean Society for Nondestructive Testing, Vol. 25, No. 2, pp. 95-102, 2005.
 4. Lu, H., Iseley, T., Behbahani, S. and Fu, L., “Leakage Detection Techniques for Oil and Gas Pipelines: State-of-the-art”, Tunnelling and Underground Space Technology, Vol. 98, Article 103249, 2020.
 5. Van Hieu, B., Choi, S., Kim, Y. U., Park, Y. and Jeong, T., 2011, “Wireless Transmission of Acoustic Emission Signals for Real-Time Monitoring of Leakage in Underground Pipes,” KSCE Journal of Civil Engineering, Vol. 15, No. 5, Article 805.
 6. Choi, H. S., Na, W. H., Kang, D. W., Kang, H. S., Jeon, J. G. and Kim, H. S., “Development of an In-Pipe Inspection and Cleaning Robot,” Journal of the Korean Society of Marine Engineering, Vol. 33, No. 5, pp. 662-671, 2009.
 7. Laser Scanners RF627 Series User's manual, RIFTEK, pp. 4-5
 8. Kim, H. Y., Cho, L. H. and Kim, K. S., “Rock Classification Prediction in Tunnel Excavation Using CNN,” Journal of the Korean Geotechnical Society, Vol. 35, No. 9, pp. 37-45, 2019.
 9. Jang, J. W., An, H. J., Lee, J. H. and Shin, S. B., “Construction of Faster R-CNN Deep Learning Model for Surface Damage Detection of Blade Systems,” Journal of the Korea Institute for Structural Maintenance and Inspection, Vol. 23, No. 7, pp. 80-86, 2019.
 10. Lee, Y. H. and Kim, Y. S., “Comparison of CNN and YOLO for Object Detection” Journal of the Semiconductor & Display Technology, Vol. 19, No. 1, pp. 85-92, 2020.
 11. Ko, S. J. and Kim, Y. H., “Object Classification and Detection Technology Using Deep Learning” The Magazine of the IEEE, Vol. 44, No. 11, pp. 26-33, 2017.
 12. Kim, B. M., “Trend of Image Classification Technology Based on Deep Learning” The Journal of The Korean Institute of Communication Sciences, Vol. 35, No. 12, pp. 8-14, 2018.
 13. Namgung, J. H., Son, S. W. and Moon, Y. S., “GRU-based Deep Learning Algorithm for DGA Classification” Conference of Korean Institute of Information Scientists and Engineers, pp. 937-939, 2020.