

<http://dx.doi.org/10.17703/JCCT.2024.10.2.505>

JCCT 2024-3-59

딥러닝 기반의 레일표면손상 평가

Deep Learning-based Rail Surface Damage Evaluation

최정열*, 한재민**, 김정호***

Jung-Youl Choi*, Jae-Min Han**, Jung-Ho Kim***

요약 철도 레일은 차륜과 레일의 접촉면인 레일 표면에서 구름 접촉 피로 균열이 상시 발생할 수 있는 조건이기 때문에 균열의 상태를 철저히 점검하고 절손을 방지하기 위한 정밀한 점검 및 진단이 필요하다. 최근 궤도 시설의 성능 평가에 대한 세부 지침에서는 궤도 성능평가를 위한 방법과 절차에 관한 필요사항을 제시하고 있다. 그러나 레일 표면 손상을 진단하고 등급을 산정하는 것은 주로 외관 조사(육안 조사)에 의존하며, 이는 점검자의 주관적인 판단에 따른 정성적인 평가에 의존할 수밖에 없는 실정이다. 따라서 본 연구에서는 Fast R-CNN을 사용하여 레일 표면 결함 검출에 대한 딥러닝 모델 연구를 수행하였다. 레일 표면 결함 이미지의 데이터 세트를 구축한 후, 모델을 테스트하였다. 딥러닝 모델의 성능평가 결과에서 mAP가 94.9%로 나타났다. Fast R-CNN의 균열 검출 효과가 높기 때문에 이 모델을 사용하면 레일 표면 결함을 효율적으로 식별할 수 있을 것으로 판단된다.

주요어 : 레일표면결함, 진단시스템, 딥러닝, Fast R-CNN, 애플리케이션

Abstract Since rolling contact fatigue cracks can always occur on the rail surface, which is the contact surface between wheels and rails, railway rails require thorough inspection and diagnosis to thoroughly inspect the condition of the cracks and prevent breakage. Recent detailed guidelines on the performance evaluation of track facilities present the requirements for methods and procedures for track performance evaluation. However, diagnosing and grading rail surface damage mainly relies on external inspection (visual inspection), which inevitably relies on qualitative evaluation based on the subjective judgment of the inspector. Therefore, in this study, we conducted a deep learning model study for rail surface defect detection using Fast R-CNN. After building a dataset of rail surface defect images, the model was tested. The performance evaluation results of the deep learning model showed that mAP was 94.9%. Because Fast R-CNN has a high crack detection effect, it is believed that using this model can efficiently identify rail surface defects.

Key words : Rail surface defects, Diagnostic system, Deep learning, Fast R-CNN, Application

1. 서론

최근 제정된 궤도시설의 성능평가에 관한 세부지침에서 궤도성능평가의 실시방법과 절차 등에 관한 필요사항을 제시하고 있다. 그러나 레일표면손상을 진단하고 등

급을 산정하는 것은 외관조사(육안조사)에 의해 결정된다[1,2]. 철도 레일은 차륜과 레일의 접촉면인 레일 표면에서 구름 접촉 피로 균열이 상시 발생할 수 있는 조건이기 때문에 균열의 상태를 철저히 점검하고 절손을 방지하기 위한 정밀한 점검 및 진단이 필요하다.

*정회원, 동양대학교 건설공학과 교수 (제1저자)

**정회원, 동양대학교 건설공학과 박사과정 (교신저자)

***정회원, 한국건설기술연구원 선임연구위원 (참여저자)

접수일: 2024년 1월 3일, 수정완료일: 2024년 2월 22일

게재확정일: 2024년 2월 25일

Received: January 3, 2024 / Revised: February 22, 2024

Accepted: February 25, 2024

**Corresponding Author: woals255@dyu.ac.kr

Dept. of Construction Engineering, Dongyang University, Korea

본 연구에서는 실제 진단 업무에 수행 가능한 레일표면손상 딥러닝 모델을 개발하고자 대한민국 궤도시설의 성능평가에 관한 세부지침의 레일표면손상의 기준을 활용하여 훈련데이터 셋을 분류하여 적용하였으며, 딥러닝 알고리즘을 통해 레일표면손상을 평가기준과 수렴하는 시점을 학습시키고자 하였다.

레일표면손상 이미지 데이터를 딥러닝이 적용된 분석 기법을 사용 시 종래의 육안조사가 아닌 인적오류를 최소화하며 관리자 및 점검자에게 레일표면손상을 진단할 때 신뢰성 높은 유의미한 데이터를 제공할 수 있으며, 분석이 정확성이 높은 분석이 가능할 것으로 판단된다.

II. 레일 표면 및 내부 학습데이터

1. 실내시험 개요

본 연구에서는 레일표면손상 수준을 정량화하여 표면결함 점검 및 평가 방안에 대해 검토하고자 실내시험을 수행하였다[1].

본 연구에서는 각 시료에 대해 수행한 단면부 관찰 방법은 적절한 방향으로 절단하여 단면을 마운팅 하였으며, 마운팅 후 1 μm의 Diamond Suspension으로 Polishing을 실시하였다. 이후 주사전자현미경(JEOL JSM-IT500 with OXFORD ULTIM MAX)으로 관찰하여 균열길이 및 깊이를 각각 측정하였다. 전자주사현미경을 이용한 레일 조직검사 시험전경 및 시험결과 예시는 그림 1과 같다[1].



(a) 전자주사현미경 시험전경 (b) SEM 시험 결과 예시
 그림 1. 실내시험 전경
 Figure 1. Laboratory test overview

레일 표면 하부균열은 비파괴 검사 측정의 어려움이 있다. 레일표면손상 수준을 정량화하여 표면결함 점검 및 평가 방안을 검토하고자 한다. 손상된 레일 관찰은 그림 1(a)와 같은 주사전자현미경(SEM) 장비를 이용하여 그림 1(b)와 같은 시험결과를 이미지 형태로 도출한다.


또한 도출된 SEM 시험 결과는 균열 길이, 균열 깊이, 균열 각도(균열성장률)를 측정하였다.

2. 훈련데이터 세트

본 연구에서는 그림 2와 같이 공용중인 도시철도 레일 표면손상 구간에서 레일표면 이미지와 레일내부 손상이 미지를 매칭하여 약 1300개의 훈련 데이터셋을 확보하였으며, 훈련데이터를 머신러닝 알고리즘의 학습데이터로 적용하였다[1].



(a) Headcheck(surface)



(b) Headcheck(SEM)


그림 2. 레일표면 및 내부데이터 예시 (계속)
 Figure 2. Example of Rail surface and internal data

학습데이터의 구분은 그림 2와 같이 레일표면손상의 대표적 RCF 손상인 Headcheck, Spalling으로 구분하였다. Headcheck는 그림 2(a)와 같이 육안으로 쉽게 발견되지만 균열의 깊이나 손상 정도를 평가하는 것은 매우 어렵다. 미세균열은 비교적 큰 곡선반경 1,500~2,000m 구간에서 주로 발생하고 차륜과 곡선부 외측레일의 구름 접촉에 의해 발생하는 종방향 힘과 미끄러짐(Slip)에 의

해 외측레일 게이지코너에 형성된다. 미세균열은 2~7mm의 가느다란 실선모양으로 30~60°각도로 발생한다.



(c) Spalling(surface)



(d) Spalling(SEM)

그림 2. 레일표면 및 내부데이터 예시
 Figure 2. Example of Rail surface and internal data

Spalling의 경우 그림 2(c)와 같이 일반적으로 반복적인 하중과 관련된 높은 접촉응력으로 인해 레일두부에서 모재가 국부적으로 박리되는 것을 의미한다. 스포링은 표면에서 시작된 균열이 레일두부에서 얇은 깊이의 다른 유사한 균열에 의해 서로 연결되었을 경우 레일표면의 얇은 금속 조각이 떨어져 나간 현상이다. 따라서 레일내부손상 0~0.5mm의 균열깊이를 가진 레일표면손상 이미지를 분류하여 Headcheck_A로 구분하였다. 또한 0.5~0.75mm 이상의 균열깊이를 가진 Headcheck_B로 정량화하여 구분하였다. 레일내부손상 0~0.5mm의 균열깊이를 가진 레일표면손상 이미지를 분류하여 Spalling_A로 구분하였다. 또한 0.5~0.75mm 이상의 균열깊이를 가진 Spalling_B로 정량화하여 구분하여 학습데이터 셋으로 분류하였다.




그림 3. 학습데이터 예시
 Figure 3. Example of training data

본 연구에서는 그림 3과 같이 공용중인 도시철도 레일 표면손상 구간에서 레일표면 이미지와 레일내부 손상이 이미지를 매칭하여 약 1300개의 학습 데이터셋을 확보하였으며, 훈련데이터를 머신러닝 알고리즘의 학습데이터로 적용하였다. 레일표면에서부터 기인된 레일내부균열의 상태를 비파괴 검사를 이용하여 조사하기는 어려운 실정이다. 본 연구를 통해 학습데이터를 활용하여 레일표면 이미지만으로 레일내부 균열의 상태를 보다 정량적인 지표로 나타내고 점검자에게 조사하기 어려운 레일내부 결함을 도출하고자 딥러닝 모델의 개발을 수행하였다.

III. 레일표면손상 딥러닝 모델 개발

1. 데이터 증강

데이터 증강 기법은 딥러닝 학습을 위해서 데이터 수집만큼 중요하다. 딥러닝의 능력은 훈련데이터의 수량과 다양성에 밀접한 관련이 있다[2]. 하지만, 실험에서 사용하는 데이터의 수는 제한적이기 때문에 가상의 데이터를 데이터 증강 기법을 이용해 훈련셋에 추가했다. 특히, 균열 데이터는 사람이나 동물과 같은 일반적인 객체보다 불규칙한 패턴을 가지고 있기 때문에 이를 신경망 모델에서 효율적인 학습데이터를 사용하기 위해서는 데이터 증강기법이 필수적이다. 데이터 증강을 위해 텐서플로 3.0에서는 이미지 뒤집기(flip), 그레이스케일(grayscale), 채도 변화(saturation), 밝기 변화(brightness), 자르기(crop), 회전(rotation)등과 같은 기능을 제공하고 있다.

표 1. 데이터 증강

Table 1. Data augmentation

| Parameter | Function |
|--------------------|------------------------------------------------------------|
| Rescale | Image resizing |
| Rotation_range | Rotate image within specified angle range |
| Width_shift_range | Move image within specified horizontal movement range |
| Height_shift_range | Move image within specified vertical movement range |
| Shear_range | Image transformation within the range of pushing intensity |
| Zoom_range | Zoom in/out images within a specified zoom range |
| Horizontal_flip | Flip image horizontally |
| Vertical_flip | Flip image vertically |

2. Fast R-CNN 모델 학습 및 예측

본 연구에서는 Fast R-CNN 모델 학습 방법을 그림 4 및 그림 5와 같이 설명하였으며, 단계별로 구분하여 모델 학습 및 예측을 수행하였다[3-7].




그림 4. Fast R-CNN 학습 개요도
Figure 4. Fast R-CNN training schematic

학습용 데이터 셋에서 1개의 이미지가 입력되었을 경우, Fast R-CNN에서 모델을 학습하는 방법은 아래와 같다. Step 1에서는 region proposals를 추출하기 위한 알고리즘으로, 1개의 이미지에서 2000 region proposals를 추출한다. Step 2에서는 VGG16 모델을 이용하여 224x224x3크기의 이미지를 입력하여 14x14크기의 feature map 512개 추출한다. Step 3에서는 추출한 feature map에 대하여 ROI projection을 진행하고, Max pooling 방식의 ROI pooling을 수행하여 7x7크기의 feature map 512개 추출한다.




그림 5. Fast R-CNN 학습 개요도(결과)
Figure 5. Fast R-CNN training schematic

Step 4에서는 추출한 7x7x512 feature map에 대하여 flatten하고, fc layer를 통해 4096크기의 feature vector 생성한다. Step 5에서는 생성한 4,096크기의 feature vector를 4개의 클래스와 배경을 포함하여 5개의 output unit을 가진 fc layer에 입력한다. 또한 1개의 이미지에서 1개의 region proposal에 대한 클래스 예측값을 구한다. Step 6에서는 Step 5와 병렬로 4,096크기의 feature vector를 클래스별로 bounding box의 좌표를 예측하도록 5x4개의 output unit을 가진 fc layer에 입력한다. 또한 1개의 이미지에서 1개의 region proposal에 대한 클래스별로 조정된 bounding box 좌표값을 구한다. Step 7에서는 1개의 region proposal에 대한 Bounding box regressor와 Classifier의 loss를 반환하고, 이후 Backpropagation을 통해 두 모델(Bounding box regressor, Classifier)을 한번에 학습한다.

IV. 딥러닝 모델 적정성

1. 실험환경

실험은 Intel(R) Core(TM) i5-13600K CPU @ 3.5GHz, 128G DDR5 memory, NVIDIA Geforce GTX 4060ti, Python 3.7 환경에서 진행되었다.

표 2. 실험환경

Table 2. Experiment environment

| | |
|-----|------------------------------------------|
| OS | Windows 11 Professional |
| CPU | Intel(R) Core(TM) i5-13600K CPU @ 3.5GHz |
| RAM | DDR5 32G(PC5-44800) * 4 = 128G |
| GPU | GeForce RTX 4060Ti |
| SSD | Gold P31 M.2 2TB |

1. Fast R-CNN 성능평가

검증 데이터를 분류한 결과로부터 True Positive(TP), True Negative(TN), False Positive(FP) 및 False Negative(FN)를 산출하였으며, 3가지 성능 지표를 적용하였다[8,9]. TP(정답)는 균열 이미지의 분류결과가 참일 때 모델이 참이라고 판단한 경우, FP(오답)는 균열 이미

지의 분류결과가 참일 때 모델이 거짓(잘못) 되었다고 판단한 경우, FN(오답)은 균열 이미지의 분류결과가 거짓(잘못)일 때, 모델이 참이라고 판단한 경우, TN(정답)은 균열 이미지의 분류결과가 거짓(잘못)일 때, 모델이 거짓(잘못) 되었다고 판단한 경우이다. 성능평가는 다음 3가지 항목으로 성능지표로 설정하였다. 재현율(Recall), 정밀도(Precision), 정확도(Accuracy)를 사용했다[8]. 또한, 성능지표에 대한 산출 방법을 테이블에 정리하였다.

표 3. 혼동행렬
 Table 3. confusion matrix

| | | Actual result | |
|-----------------------|-------|----------------|----------------|
| | | True | False |
| Classification result | True | True Positive | False Positive |
| | False | False Positive | True Positive |

레일표면손상을 탐지할 딥러닝 모델 성능을 mAP(mean Average Precision)로 평가하였다. mAP를 구하기 위하여 Precision-Recall 곡선 및 Average Precision(AP)를 이용하여 산출하였다. 표 3의 지표를 이용하여 표 4에 성능평가 항목을 정리하였다.

표 4. 성능평가
 Table 4. Performance Matrix

| | |
|-----------|--------------------------|
| Recall | $\frac{TP}{TP+FN}$ |
| Precision | $\frac{TP}{TP+FP}$ |
| Accuracy | $\frac{TP}{TP+FN+TN+FP}$ |

Recall은 재현율이며 실제로 옳은 값에서 모델이 옳다고 검출한 비율이다. 그러니까 실제 정답의 레일표면손상 중에서 모델이 균열이라고 예측한 비율이다.

본 연구에서는 그림 5와 같이 계산을 통해 Precision-Recall 곡선을 구한다. 세로 좌표는 정밀도를 나타내고 가로 좌표는 재현율을 나타낸다. 또한 학습 가 여러 개인 경우 각 클래스당 AP를 구한 다음 각 클래스를 모두 합하고 학습 클래스의 갯수로 나뉘므로 알고리즘의 성능을 평가하였다. 이것을 mAP(mean average precision)라고 한다. 그림 5와 같이 딥러닝 모델의 적정성을 평가하고자 한다. 또한 딥러닝 모델의 정밀도는 높

지만, 재현율이 낮다면, 객체가 옳다고 분류할 때 모델이 정확하지만 옳은 예측을 한 결과 중 일부만 분류할 수도 있다. 따라서 레일표면손상이라고 손상을 분류할 때 정확하지만 레일표면손상이 아니라 판단할 가능성이 있다. 딥러닝 모델의 재현율은 높지만, 정밀도가 낮다면 딥러닝 모델은 대부분의 옳은 예측을 한 손상을 잘 분류하지만 옳지 않은 객체를 옳다고 분류한다. 따라서 레일표면손상으로 설정된 데이터 세트를 mAP의 비율을 분석하였다.




그림 5. Fast R-CNN 성능평가 결과
 Figure 5. The precision and recall result.

Fast R-CNN모델을 이용한 분석결과, Headcheck_A와 Headcheck_B의 경우 각각 99.4% 및 86.8%로 나타나 높은 결과의 정확성을 나타냈으나 상대적으로 Headcheck_B의 경우는 86.8%로 실용화 단계에서는 좀 더 높은 정확성을 위해 학습데이터를 추가적으로 확보해야 할 것으로 판단된다.

Spalling_A와 Spalling_B의 경우 각각 95.3% 및 98.2%로 나타나 높은 정확성의 균열을 탐지할 수 있는 것으로 분석되었다. 또한 본 연구에서 수행한 딥러닝 모델로 전체클래스에 대한 레일표면손상 이미지 분석을 수행하였을 때 mAP의 값은 94.9%로 나타나 해당모델의 적정성은 충분히 확보할 수 있을 것으로 분석되었다.

V. 결론

본 연구는 레일표면결합이 발생한 구간에서 현장조사를 통한 레일 시료를 채취하였다. 또한 실내시험 (SEM Test)을 통한 레일내부손상특성을 분석하였다. 현장조사를 통한 레일표면결합 이미지와 SEM시험을 통해 레일내부손상 데이터를 바탕으로 학습데이터를 구축하였으며, Headcheck, Spalling으로 클래스를 구분하여 딥 러닝 알고리즘을 개발하였다. Fast R-CNN 알고리즘을 이용하여 레일표면손상 진단 딥러닝 모델을 자체 개발하였다.

(1) 본 연구에서 수행된 딥러닝 모델에 따르면 Fast R-CNN모델의 정확성이 좋다는 결론을 얻을 수 있다. 레일 표면 결함은 데이터 세트 작성, 모델 매개변수 설정 및 모델 학습을 통해 감지할 수 있다. 시험 결과를 분석함으로써 레일 표면 결함 검출이 가능하고 결함 유형을 효과적으로 식별할 수 있다는 결론을 도출하였다. 또한 철도 안전사고를 더욱 줄이는 데 큰 도움이 될 것으로 분석되었다.

(2) 레일표면손상을 바탕으로 절손 가능성을 사전에 파악함으로써 대형사고 예방에 따른 사회적 피해 최소화 가능하다. 본 연구결과를 바탕으로 레일손상상태 및 점검결과 이력을 빅데이터화함으로써 보다 과학적으로 궤도의 손상이력 추적이 가능할 뿐만 아니라 궤도진단 결과의 신뢰성을 증대시킬 수 있을 것으로 판단된다.

References

[1] J.Y. Choi, J.M. Han, Y.K. Kim, "Correlation Analysis of Rail Surface Defects and Rail Internal Cracks", The Journal of the Convergence on Culture Technology (JCCT), Vol. 10, No. 1, pp.585-591, 2024. <http://dx.doi.org/10.17703/JCCT.2024.10.1.585>

[2] J.Y. Choi, H.S. Kim, K.S. Han, C.J. Jang, J.S. Chung "Damage Evaluation of Track Components for Sleeper Floating Track System in Urban Transit", The Journal of the Convergence on Culture Technology (JCCT), Vol. 5, No. 4, pp.387-394, 2019. <https://doi.org/10.17703/JCCT.2021.7.3.517>

[3] L. Perez and J. Wang, "The effectiveness of data augmentation in image classification using deep learning," arXiv preprint arXiv:1712.04621,

2017.

- [4] S. Ren, K. He, G. Ross, and S. Jian, "Faster r-cnn: Towards real-time object detection with region proposal networks", Advances in Neural Information Processing Systems, Vol. 28, pp. 91-99, 2015.
- [5] G. M. Jog, C. Koch, M. Golparvar-Fard, and I. Brilakis, "Pothole properties measurement through visual 2D recognition and 3D reconstruction", International Conference on Computing in Civil Engineering, pp. 553-560, 2012.
- [6] E. Buza, S. Omanovic, and A. Huseinovic, "A pothole detection with image processing and spectral clustering", Proc. the 2nd International Conference on Information Technology and Computer Networks, Antalya, Turkey, pp. 48-53, 2013.
- [7] A. Mednis, G. Strazdins, R. Zviedris, G. Kanonirs, and L. Selavo, "Real time pothole detection using Android smartphones with accelerometers", Proc. IEEE International Conference on Distributed Computing in Sensor Systems and Workshops, Barcelona, Spain, 2011.
- [8] T.H. Kim, S.K. Ryu, "Review and analysis of pothole detection methods", Journal of Emerging Trends in Computing and Information Sciences, Vol. 5, No. 8, pp. 603-608, 2014.
- [9] M.K. Lee, K.S. Seo, "Comparison of Region-based CNN Methods for Defects Detection on Metal Surface", The Transactions of the Korean Institute of Electrical Engineers, Vol. 67, No. 7, PP.865 - 870, 2018
- [10] D.H. Seol, J.H. Oh, H.J. Kim, "Comparison of Deep Learning-based CNN Models for Crack Detection", Journal of the Architectural Institute of Korea Structure & Construction, Vol. 36, No.3, pp.113-120, 2020

※ 이 논문은 2023년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No. RS-2023-00233470, 인공지능경망 이미지 분석을 이용한 레일표면손상 진단시스템 개발)