

## 정적 변형률 데이터 기반 머신러닝에 의한 무도상 철도 판형교의 손상 탐지

문태욱<sup>1</sup>, 신수봉<sup>2\*</sup>

### Damage Detection of Non-Ballasted Plate-Girder Railroad Bridge through Machine Learning Based on Static Strain Data

Taeuk Moon<sup>1</sup>, Soobong Shin<sup>2\*</sup>

**Abstract** : As the number of aging railway bridges in Korea increases, maintenance costs due to aging are increasing and continuous management is becoming more important. However, while the number of old facilities to be managed increases, there is a shortage of professional personnel capable of inspecting and diagnosing these old facilities. To solve these problems, this study presents an improved model that can detect Local damage to structures using machine learning techniques of AI technology. To construct a damage detection machine learning model, an analysis model of the bridge was set by referring to the design drawing of a non-ballasted plate-girder railroad bridge. Static strain data according to the damage scenario was extracted with the analysis model, and the Local damage index based on the reliability of the bridge was presented using statistical techniques. Damage was performed in a three-step process of identifying the damage existence, the damage location, and the damage severity. In the estimation of the damage severity, a linear regression model was additionally considered to detect random damage. Finally, the random damage location was estimated and verified using a machine learning-based damage detection classification learning model and a regression model.

**Keywords:** Non-ballasted railway bridge, Machine Learning, Damage detection, static strain, Local damage index

## 1. 서 론

공용년수 50년 이상인 국내 무도상 철도교량의 비율이 80%이상으로 노후화로 인한 유지관리비가 점점 증가하고 지속적인 관리가 보다 중요해지고 있다. 이를 해결하기 위해 최근 무도상 교량의 유도상화가 점진적으로 진행되고 있다. 하지만 유도상화를 위한 우회로 설치, 가교 설치 등이 어려울 뿐만 아니라 경제적 타당성이 낮아 무도상 교량의 유도상화 실적이 저조하다.(Moon T, 2020) 또한 관리해야 하는 SOC 노후 시설물은 증가하고 있지만, 점점 진단할 수 있는 전문인력은 부족하다.(Kim D, 2018) 이러한 전문인력 부족 문제를 해결하기 위해 최근 AI 기술을 접목한 교량의 지속적인 모니터링 기술 개발의 필요가 부각되고 있다. 이를 바탕으로 국토교통부는 4차산업혁명 대응전략에서 노후 인프라

에 IoT 기법을 적용해 안전하고 효율적인 유지관리를 하는 것을 중점 추진과제로 선정함으로써 구조물 건전도 평가 기법과 손상탐지기법들을 AI기술과 융합하는 연구를 추진하도록 하고 있다.(MOLIT, 2017)

하지만 아직 딥러닝 기술을 연구단계를 넘어 실생활에 적용하는 것에 대해선 비판과 한계가 있다. 그리고 SOC 디지털화를 위해 신호계측 센서 기반 또는 영상기반의 실시간 모니터링을 함에 있어 아래와 같은 3가지 문제를 고려하여야 한다.(Gary Marcus, 2018;2019)

- ① 고품질 학습데이터의 부재
- ② 소량 데이터만으로 학습 가능 여부
- ③ 문제에 최적화된 학습 알고리즘 여부

공용중인 SOC 구조물의 효과적인 손상탐지를 위해선 실제 구조물의 손상 데이터 획득이 극히 어렵기 때문에 소량의 손상 데이터만으로도 학습이 가능한 알고리즘을 개발해야 한다. 또한 구조물의 손상 위치가 육안으로 관찰하기 어려운 위치에 있거나 콘크리트 내부에 있는 경우에는 고품질 학습데

<sup>1</sup>정회원, 인하대학교 토목공학과 석사

<sup>2</sup>정회원, 인하대학교 사회인프라공학과 정교수, 교신저자

\*Corresponding author: sbshin@inha.ac.kr

Civil Engineering, Inha University, Incheon, 22212, Korea

•본 논문에 대한 토의를 2021년 1월 31일까지 학회로 보내주시면 2021년 2월 호에 토론결과를 게재하겠습니다.

이터의 빅데이터화가 불가능하다. 따라서 한정적인 손상예 대한 대상 구조물의 손상탐지 학습모델을 개발해야 하는 한계가 있다. 그리고 머신러닝 및 딥러닝 학습 데이터는 특징을 정의하는 피처엔지니어링 (feature engineering)의 과정이 필요하며, 계측 데이터를 사용할 경우 계측 데이터의 데이터 전처리 및 분석을 위한 전문 도메인 지식이 필요하기 때문에 문제에 최적화된 학습 알고리즘을 구성하기가 어렵다.

본 연구에서는 철도차량을 무도상 판형교에 정적재하 하였을 때 교량 거더에서 계측한 정적 변형률 데이터를 사용하여 손상탐지 모델에 효과적인 피처엔지니어링 과정을 제안하여 소량의 데이터만으로 손상을 탐지할 수 있는 손상탐지 학습 알고리즘을 제안하고 검증하였다. Fig. 1은 이런 손상탐지 절차를 도시한 것이다.

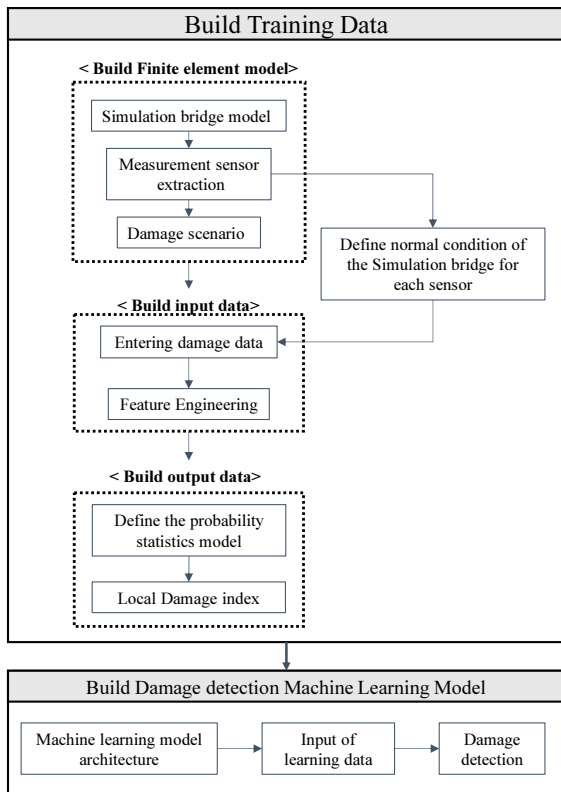


Fig. 1 Flow of the proposed detection process

## 2. 정적 변형률 데이터 기반 손상시나리오 설계

### 2.1 무도상 판형교 수치예제 모델

무도상 판형교 손상 모니터링 체계의 시뮬레이션 검증을 위해 본 연구는 정적 변형률 센서의 위치와 부재의 손상 특징을 정의할 수 있는 전산구조해석 시뮬레이션 모델을 상용프로그램 Midas Civil(2019)를 사용하여 구현하였다.

해석모델은 현재 운영되지 않는 판형교의 설계도면을 참고하여 단면을 설정하였으며, 이를 Fig. 2 및 Table 1에 표시하였다.(Moon T, 2020) 받침의 경우 대상 판형교의 선받침 방향을 고려하여 고정단과 이동단으로 단순 모델링 하였다. 레일 단면은 KR60의 단면을 적용하였으며 Fig. 3과 같이 해석 모델 단순화를 위해 곡선부를 제거하여 단순화된 레일 단면을 사용 하였다.(Park S, 2019)

Table 1 Dimension of the test bridge

Classification	Dimension (mm)	Material
Span length	26000	-
web	1810×17	SM490
flange	313×29	SM490
bracing	150×12	SM490
Sleeper	230×230×3000	Wood

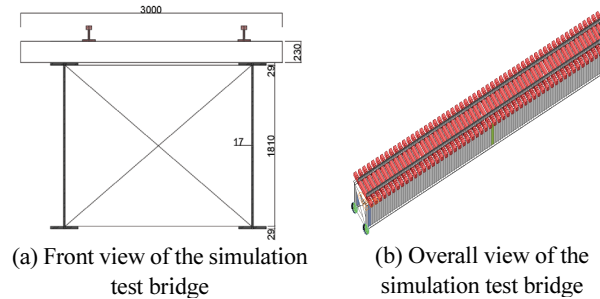


Fig. 2 Simulation test bridge detail diagram




Fig. 3 Simulation model - rail section detail

### 2.2 손상시나리오 설계

무도상 판형교의 손상은 일반적으로 주거더 좌굴에 의한 손상과 강성에 영향을 줄 수 있는 리벳 탈락, 볼트 풀림 등이 해당된다. 본 연구는 구조물의 손상 발생 시 강성의 변화를 시뮬레이션 구조해석 모델에 반영하기 위해 Table 2와 같이 탄성계수의 값을 수정하여 손상을 정의하였으며, 변형률 센서 바로 위에 위치한 거더 복부의 탄성계수를 인위적으로 감소




Fig. 7 Strain gauge layout for the test bridge

Table 2 Define Damage by reducing Elastic Modulus

Level. 0 : Non-damage	$E_{nd} = 205000 (N/mm^2)$
Level. 1 : Damage 5%	$E_{d1} = 194750 (N/mm^2)$
Level. 2 : Damage 10%	$E_{d2} = 184500 (N/mm^2)$




Fig. 5 Test train loading diagram

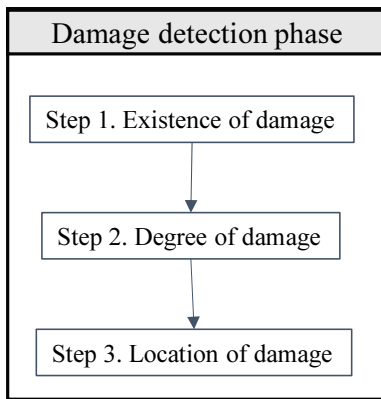


Fig. 4 Damage detection verification phase




Fig. 6 Sample static load case

시켰다. 변형률 센서의 위치는 거더 플랜지 하부에 부착하는 것으로 가정하였으며 Fig. 7은 손상위치와 변형률 데이터 위치를 나타내고 있다.

손상시나리오에서 추출된 손상 변형률 데이터에 대해 손상 유무, 크기 및 위치를 파악하기 위해 Fig. 4와 같이 3가지 단계를 차례로 수행했다. 손상은 위험 단면 중 1개의 단면에 손상이 발생한 단일 부재 손상으로 무손상을 포함한 총 57개의 손상케이스를 정의하였다.

### 2.3 정적재하시험

정적재하시험을 모사하기 위해 1량 시험 열차 차량을 대상 교량의 침목 중심 간격으로 하중을 위치 시켰으며, 시험 열차가 교량을 진입하여 나갈 때까지의 총 92가지 정적하중 case를 만들었다. 따라서 본 연구의 정적재하를 통한 손상시나리오는 손상케이스(57개)×차량케이스(92개) = 5244개의 데이터로 구성하였다. Fig. 5와 Fig. 6은 시험 열차 하중선도와 하중재하를 도시하였다.

## 3. 피처 엔지니어링(Feature Engineering)

머신러닝을 위한 데이터는 많은 행과 열로 구성되어 있으며 행은 케이스, 열은 피처라고 불린다. 피처 엔지니어링은 머신러닝 알고리즘을 작동하기 위해 데이터에 대한 도메인 지식을 활용하여 특징(feature)을 만들어내는 과정이며, 적용 모델의 결과를 향상시키기 위해 피처 엔지니어링의 많은 시행착오를 필요로 한다. (Andrew Ng, 2013)

본 연구에서는 부재의 미소 손상에 따른 변형률 데이터의 이상치 특징 추출을 위한 방법을 제안하고자 한다. 구조해석 교량 모델의 정적 변형률 데이터에 대해 손상 전후의 표준 잔차를 계산한 후 이상탐지에 효과적인 마할라노비스 거리를 적용해 데이터의 특징을 누적하였다. 누적된 데이터로 부터 경험적 누적 확률 분포를 사용하여 통계적인 방법으로 신뢰도 기반 Local 손상지수의 입력데이터를 구성하였다. Fig. 8은 Local 손상지수를 정의하기 위한 프로세스이다. Fig. 8에서  $ND_{nm}$ 와  $D_{nm}$ 은 무손상과 손상케이스를 의미하며,  $n$ 은 교량의 변형률 각 센서의 번호이며,  $m$ 은 손상시나리오에서 정의한 하중 케이스,  $i$ 는 Local 손상지수를 정의하기 위해 몬테카를로 시뮬레이션(Monte Carlo Simulation)을 적용하여 시뮬레이션의 추정치들이 신뢰적인 통계적 의미를 가질 때까지의

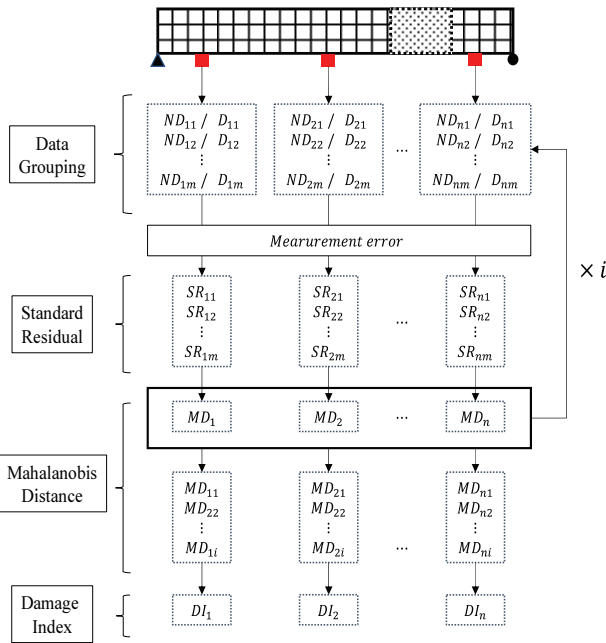


Fig. 8 Process of defining Local damage index

반복한 횟수이다.

### 3.1 계측 오차

손상 시나리오로부터 추출된 각 센서 별 정적 변형률 데이터의 신뢰를 높이기 위해 실제 변형률 센서가 갖는 계측오차를 반영하였다. Micro-Measurement(2007)에서 제시한 3% 계측오차를 발생시키기 위해 평균이 1, 표준편차가 0.015인 가우시안 확률 분포도를 사용했으며 Fig. 9와 같이 오차 3%가 넘는 데이터는 경계 값으로 절삭하여 노이즈 데이터를 생성하였다.(Lee K, 2018)

시뮬레이션 교량의 표준상태(normal condition)를 정의하기 위해 3% 계측오차를 적용한 무손상 평균 데이터를 구성하였다. Fig. 10과 같이 500번의 반복수행을 통한 몬테카를로 시뮬레이션을 적용하였다. 계측오차를 적용하기 전후의 무손상 데이터로부터 잔차의 평균을 계산하여 몬테카를로 시뮬레이션 횟수를 결정하였으며, 본 연구는 평균값이 일정해지는 100번의 반복 수행을 통해 계산된 무손상의 평균 데이터를 해석 교량의 표준상태라 정의하였다.

### 3.2 특징 추출

#### 3.2.1 표준 잔차(Standard residual)

머신러닝 입력 숫자의 스케일이 크게 차이가 나면 모델 알고리즘 학습과정에서 0으로 수렴하거나 무한으로 발산해버려 학습의 정확도가 낮아질 수 있다. 변형률 데이터의 경우 미소 손상에 대해 손상 전후의 미소 차이를 보이며, 원 데이터를




Fig. 9 Cut-type Standard probability distribution of 3% Noise




Fig. 10 Variation of the mean value of residuals by Monte Carlo simulation repetition

사용할 경우 학습 모델의 효과적인 결과를 도출하기가 어렵다. 또한 손상 전후의 잔차(residual)를 적용해 특징을 추출할 경우 각 센서 별 손상 데이터의 값 차이가 정규화가 되지 않는 문제점이 있다. 따라서 잔차의 분산을 정규화 시켜 손상 전후의 데이터를 비교분석 해야 한다. Fig. 8.의  $i$  번째 잔차에 대한 표본 분산(Standard error)과 표준 잔차(Standard residual)식은 다음과 같다.

$$\text{Var}(Y_i - \hat{Y}_i) = \sigma^2(1 - h_{ii}), \quad h_{ii} = \frac{1}{n} + \frac{(X_i - \bar{X})^2}{\sum (X_i - \bar{X})^2} \quad (1)$$

$$Z_i = \frac{e_i}{\sigma \sqrt{1 - h_{ii}}} \quad (e_i = Y_i - \hat{Y}_i) \quad (2)$$

위 식에서  $X_i$ 은 손상 케이스의 변형률 데이터,  $\bar{X}$ 은 무손상 평균 변형률 데이터이다. 이때, 무손상 평균 데이터의 모집단을 정의하기 위해서 시뮬레이션 구조 해석 모델로부터 무손상 데이터에 대한 몬테카를로 기법(Monte Carlo Method)을 적용하였다.

Fig. 11은 단부 센서1(이하  $s_1$ )에 손상을 가했을 시 손상 전후 변형률 데이터의 하중 케이스별 표준 잔차 데이터를 도시하였다. 변형률 데이터는 차량의 하중에 의존적으로 반응하

기 때문에 Fig. 9와 같이 열차가 들어오고 나가는 양 끝단의 데이터는 무손상과 손상과의 차이가 크게 구별되지 않음을 알 수 있다. 따라서 본 연구는 표준 잔차를 적용한 후 92개 하중 케이스에 대한 마할라노비스 거리를 적용해 2차 데이터 특징을 추출하였다.

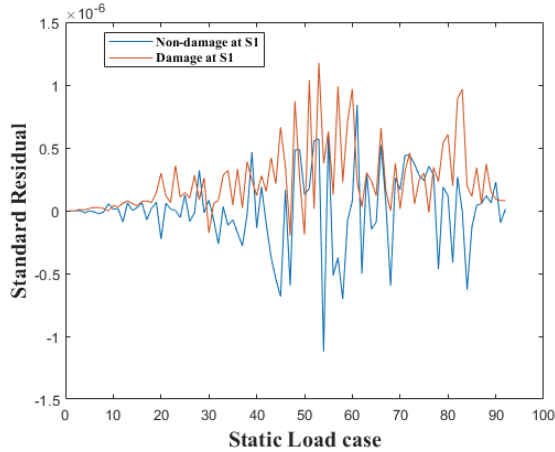


Fig. 11 Comparison of standard residuals at S1

### 3.2.2 마할라노비스 거리(Mahalanobis Distance)

마할라노비스 거리는 이상탐지(anomaly detection) 방법 중 하나로 식 (3)과 같이 데이터 간의 거리를 구하는 대표적인 방법인 유클리디안 거리(Euclidean distance)와 달리 마할라노비스 거리는 공분산( $\Sigma$ ) 개념을 사용해 데이터 두 특징간의 데이터의 상관관계에 따라 거리를 나타내게 된다.(Kim Y, 2017)

따라서 본 연구는 각 하중 케이스에 따라 달라지는 표준편차 데이터를 보완하기 위해 식(4)와 같이 마할라노비스 거리를 적용하여 차량하중 위치와 상관없이 센서 별로 특징을 추출하였다.

$$\bullet \text{ Mahalanobis Distance} = ((x-\mu)^T \Sigma^{-1} (x-\mu))^{0.5} \quad (3)$$

$$\bullet \text{ Euclidean Distance} = ((x-\mu)^T (x-\mu))^{0.5}$$

$$SR_n = (ND_n \text{ or } D_n) - \mu_n \quad (4)$$

$$MD_{ni} = ([SR_n]^T \quad \Sigma^{-1} \quad [SR_n])^{0.5}$$

$$[1 \times 1] \quad [1 \times 92] \quad [92 \times 92] \quad [92 \times 1]$$

식 (4)의  $\mu_n$ 은  $n$ 번째 센서 위치에서 전체 하중케이스 92개의 무손상의 평균 데이터를 의미하며 공분산행렬은 측정 변형률 데이터( $ND_{nm}$  or  $D_{nm}$ )의 공분산이다. 따라서 열차가 교량을 한번 지나갈 때 추출된 92개의 데이터는 1개의 마할라노비스 거리( $MD_{ni}$ ) 데이터로 계산되고  $i$ 번의 반복 실험을 수행했다고 가정했을 때,  $i$ 개의 데이터가 축적된다. 따라서 본 연구는 축적된 데이터의 표본 집단의 신뢰도를 갖기 위해 몬테

카를로 시뮬레이션을 적용하였다. 이를 손상 크기별로 Fig. 12~14에 도시하였다.

Fig. 12~14에서 손상 정도가 커질수록  $MD_{ni}$ 의 크기가 1에서 점점 낮아짐을 알 수 있다. Fig. 12~14에서의 (a)는 Table 2에서 정의한 단부의 손상 크기에 따라 달라지는  $MD_{ni}$ 의 분포를 나타내며 (b)는 몬테카를로 시뮬레이션의  $i$ 번 반복 횟수에 따른  $MD_{ni}$  값이 수렴하는 범위를 나타냈다. 1000회 이상으로 수렴함을 알 수 있어 본 연구는 정적재하 시뮬레이션 데이터의 반복 횟수를 1000회로 선정 하였다. Fig. 12~14에서의 (c)는  $i$ 개의  $MD_{ni}$  분포에 대한 히스토그램을 도시했으며, 무손상의 경우 1~0.9에 데이터가 집중된 지수분포를 가지지만 손상의 크기가 커질수록 정규 분포의 형태를 가져 특정한 확률분포를 적용하기가 어려움을 알 수 있다. 따라서 본 연구는 경험적 누적 분포 함수(Empirical cumulative distribution function, ECDF)를 이용하여 신뢰도 기반의 Local 손상지수를 정의했다.

### 3.2.3 확률적 통계에 따른 신뢰도 기반 Local 손상지수

Local 손상지수란 손상의 유무, 크기, 위치를 탐지하기 위해 각 센서 별로 손상의 특징을 통계적 방법을 이용해 측정 데이터의 손상지수를 나타낸 것을 말한다. Local 손상지수를 정의하기 위해 경험적 누적분포함수(ECDF)의 신뢰 하한구간 95%를 적용하였으며, Fig. 12~14의 (d)에 이를 도시하였다.

무손상 데이터는 정규 분포도의 형태를 갖지 않는다. 따라서 무손상 데이터와 손상 데이터 공통적으로 통계적 추정을 할 수 있는 ECDF를 적용해야한다.


누적분포  $F(x)$ 로부터 구한 랜덤포본의 순서 통계량을  $X_{(1)}, X_{(2)}, \dots, X_{(n)}$  이라고 했을 때, ECDF  $F_n(x)$ 는 식 (5)로 정의할 수 있다.

$$F_n(x) = \begin{cases} 0 & x < X_{(1)} \\ i/n & X_{(i)} \leq x \leq X_{(i+1)} \quad (i=1,2,\dots,n-1) \\ 1 & X_{(n)} \leq x \end{cases} \quad (5)$$


1000회 반복해 축적된  $[MD_{n1}, MD_{n2}, \dots, MD_{n1000}]$ 에 대해 각 센서 별 손상 정도에 따라 달라지는 Local 손상 지수를 Table 3.에 정리하였다. Table 3.의 데이터 분석 결과는 (1) 손상 정도가 커질 수록 약 0.3 간격으로 낮아지며, (2) 각 센서 별 손상 지수가 차이가 나며 특히 힌지 단부와 롤러 단부, 그 외에 센서들로 손상 지수를 구분할 수 있다. 따라서 본 연구는 교량 전체의 손상학습 모델이 아닌 각 센서 별 손상 학습 모델을 각각 모델링하였다.

**Table 3** Local damage index according to damage level and sensor locations


	Level 0	Level 1	Level 2
End of girder sensors at hinge		0.39 ~ 0.45	0.20 ~ 0.22
End of girder sensors at roller	0.882 ~ 0.904	0.50 ~ 0.55	0.24 ~ 0.26
Other sensors		0.61 ~ 0.66	0.37 ~ 0.42



**Fig. 12** Process of Local damage index of damage level 0



**Fig. 13** Process of Local damage index of damage level 1




**Fig. 14** Process of Local damage index of damage level 2

## 4. 정적 변형을 기반 머신러닝 모델 개발

### 4.1 손상 탐지를 위한 머신러닝 구조 설계

은닉층을 갖는 신경망의 기본 단위는 다층 퍼셉트론으로 입력 값과 활성화 함수를 사용해 출력 값을 계산하여 의미 있는 값인지 아닌지 결정하는 신경망 단위를 뜻한다. Fig. 16은 다층 퍼셉트론의 도식을 나타낸 것이다.



**Fig. 15** Multi layer Perceptron Structure model

Fig. 15의 가운데 은닉층의  $n_1, n_2$ 를 노드(node)라 하며  $n_1, n_2$ 의 값은 각각 단일 퍼셉트론으로 다음과 같이 표현할 수 있다.

$$n_1 = \sigma(x_1 w_{11} + x_2 w_{12} + b_1) \quad (6)$$

$$n_2 = \sigma(x_1 w_{21} + x_2 w_{22} + b_2) \quad (7)$$

위 식에서  $w$  = 가중치,  $b$  = 편심 그리고 이들의 합을 ‘가중합’,  $\sigma$  = 활성화 함수이다.

이들의 매개변수를 사용해 효과적인 머신러닝 모델을 구성하기 위해선 최적화가 필요하다. 이때 최적화를 위한 변수 및 여러 기법들을 hyperparameter라 한다. Hyperparameter에는 경사하강법, 활성화 함수, 손실 함수 등이 있으며, 본 논문에서는 학습 모델 최적화를 위한 hyperparameter를 선정하기 위해 Fig. 16과 같이 머신러닝 손상 탐지 모델을 분류 모델과 회귀 모델 나눠 진행했다.

먼저 분류 모델에서 단일 손상과 다중 손상을 탐지함으로써 hyperparameter의 매개변수들을 선정하였다. 이후 최적화된 분류 학습 모델의 활성화 함수와 출력층을 수정하여 회귀 모델로 전환함으로써 랜덤한 손상 데이터를 예측하는 학습 모델을 구성하였다. 머신러닝 손상 탐지 모델에서 사용한 hyperparameter는 Fig. 16에 도시하였다.

분류 모델의 활성화 함수와 손실함수의 경우 단일 손상과 다중 손상 각각 효과적인 Sigmoid, Softmax 활성화 함수와 Cross\_entropy 손실함수를 사용했으며, 회귀 모델의 경우 선형 회귀 분석을 수행하여 Linear 활성화 함수와 평균제곱오차 (Mean Square Error, MSE) 손실함수를 적용하여 예측 값을 도출하였다.

또한 학습 모델의 에포크(Epoch)와 배치사이즈(Batch size)

를 결정함으로써 적절한 실행 횟수를 통해 효율적인 학습 모델을 설계할 수 있다. 1 epoch는 전체 데이터를 한 번 학습 완료한 상태를 의미한다. 따라서 에포크가 증가함에 따라 신경망 알고리즘의 최적화가 진행되고 본 연구는 초기 값으로 에포크를 100으로 설계하여 학습모델의 정확도 검증을 수행하면서 과적합(overfitting) 현상이 발생하는지 평가하였다.

배치사이즈는 한 번의 에포크에 대해 전체 데이터를 몇 번을 나눠 데이터를 학습할지 결정하는 매개변수이다. 배치 사이즈에 따라 최적해를 찾을 가능성과 시간이 반비례하여 적절한 배치 사이즈의 선택이 필수적이다. 본 연구는 전체 데이터에 대해 10%의 크기로 분할하여 초기 학습 모델을 결정하였다.

#### 4.2 무도상 판형교 손상 탐지 학습 모델 결과

머신러닝 한계점 중 소량의 데이터로 학습이 가능함을 제시하기 위해 본 연구는 각 손상 크기(0%, 5%, 10%) 마다 100회 반복 수행함으로써 총 300개의 전체 데이터를 구성한 후 손상 탐지 단계별로 학습 결과를 정리하였다.

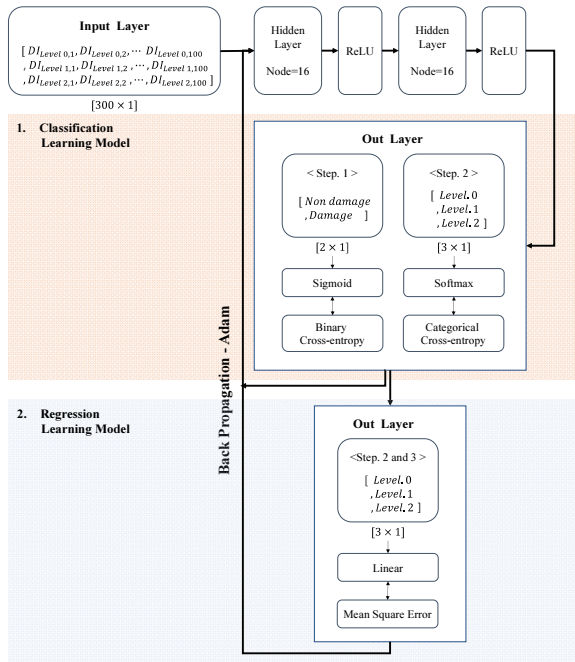


Fig. 16 Machine learning train model architecture

Table 4 Classification of Learning data by model

Damage level	Training Data		Test Data	Total Data
	Training set	Validation set	Test set	
Level 0	56	24	20	100
Level 1	56	24	20	100
Level 2	56	24	20	100

전체 데이터는 8:2의 비율로 학습 데이터(Training Data)와 시험 데이터(Test Data)로 나눠 각각 학습데이터 240개, 시험 데이터 60개로 구분하였다. 학습 데이터는 다시 training set과 validation set을 7:3으로 나눠 1 에포크의 정확도를 검증하였다. Table 4는 학습 모델을 위한 데이터 크기이다. 또한 Local 손상지수가 센서 위치마다 서로 다름을 반영하기 위해 센서 개수 56개의 학습 모델을 각각 만들어 결과를 분석했다.

#### 4.2.1 Step. 1: Existence of damage

손상 유무 탐지 단계 Step 1은 무손상(Level 0)과 손상(Level 1~2)을 구별하는 단계이다. Fig. 16과 같이 무손상 데이터 100개, 손상 데이터 200개에 대해 Table 4와 같이 나눠 학습을 진행했으며, Fig. 17은 본 연구의 센서 1에서의 손상탐지 분류 학습 모델 결과이다.

본 모델의 경우 에포크가 증가함에 따라 학습데이터의 정확도가 100%로 수렴하고 validation\_loss 값이 0으로 수렴한다. 즉 학습 모델의 과적합이 발생하지 않음을 확인할 수 있다. 이를 통해 Step 1의 정적해석 손상유무 분류모델의 성공적인 학습이 되었음을 알 수 있다.

따라서 최적화된 손상 유무 모델에 대하여 시험데이터 60개를 적용한 결과는 Fig. 18에 도시하였다. Fig. 18은 정확도를 평가할 수 있는 혼동행렬(confusion matrix)이다. 혼동행렬의 행은 시험 데이터의 실제 손상을 의미하며 열은 시험 데이터

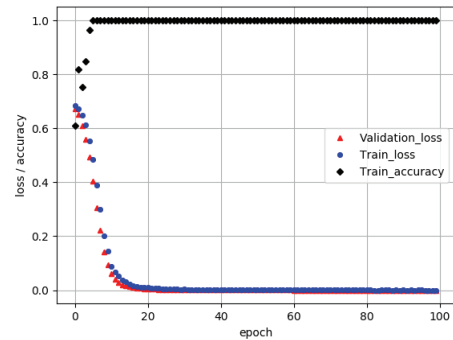


Fig. 17 Convergence of Step 1 model - history of the loss function for the training and validation set

		Predict	
		Level 0	Level 1~2
Actual	Level 0	TP = 20	FN = 0
	Level 1~2	FP = 0	TN = 40

Test Accuracy = 100%

Fig. 18 Confusion matrix for test data of Step 1 model

의 학습 모델이 예측한 손상이다. 따라서 Fig. 18에서 대각 셀은 예측건수에서 정답을 맞힌 건수이며 이를 정확도라 한다. 본 모델은 무손상 데이터 20개, 손상 데이터 40개로 데이터의 비대칭으로 인한 정확도 역설 (accuracy paradox)이 발생할 수 있다. 따라서 정확도가 아닌 F1 score를 추가로 성능 평가할 수 있다. 하지만 손상 유무 학습 모델에 대해 시험 데이터의 결과는 무손상이지만 손상이라 예측한 경우(False Negative, FN)와 실제로 손상이지만 무손상이라 예측한 경우(False Positive, FP) 모두 0개로 우수한 시험 결과를 보여준다. 따라서 정확도만으로 모델 성능 평가하였으며, test accuracy는 100%로 학습 모델이 우수함을 판단할 수 있다.

#### 4.2.2 Step 2: Degree of damage

손상 크기 탐지 단계 Step 2는 무손상(Level 0)과 손상 1(Level 1), 손상2(Level 2)로 구분하여 손상 크기를 탐지하는 단계이다. Step 1과 동일한 학습데이터와 시험데이터 크기를 적용했으며, Fig. 19는 Step 2의 다중 분류 학습 모델 결과이다. 다중 분류 학습 모델 역시 에포크가 증가함에 따라 정확도는 100%로 수렴하며 validation\_loss값이 0으로 수렴해 과적합이 발생하지 않음을 확인하였다. 이를 통해 손상 크기를 분류하는 모델 역시 성공적으로 학습되었음을 판단하였으며, 시험 데이터 60개를 적용한 결과를 Fig. 20에 도시하였다. 다중 분류 모델의 시험 데이터의 경우 무손상과 각 손상 데이터의 크기가 모두 20개로 동일함으로 정확도 역설이 발생하지 않아 정확도만으로 모델 성능 평가하는 것이 타당하다. Fig. 20과 같이 각 손상별 시험데이터 20개가 모두 정확하게 탐지됨을 알 수 있다.

본 연구는 손상 시나리오에서 정의한 손상이 아닌 임의의 손상 크기를 예측하는 모델을 구축하기 위해 분류 모델이 아닌 회귀모형을 구성하였다. 회귀모형 예측 값의 정확도를 검증하기 위해 먼저 거더 중앙부  $S_{14}$ 의 분류모델에서 사용한 validation set의 실제 값과 예측 값을 Fig. 21에 도시하였으며, 예측 손상범위는  $\pm 5\%$ 임을 알 수 있다. 또한  $S_{14}$ 의 손상 3%와 7% 손상케이스를 추가로 테스트하여 Local 손상지수에 대한 회귀 예측 값을 Table 5에 도시하였다. 손상 3%와 7% 모두 오차 5% 이내의 손상 크기 예측 값을 도출했으며 초기 hyperparameter를 사용한 회귀 모델이 타당함을 확인하였다. 따라서 이 모델을 손상 위치 추정을 위한 최종 회귀 모델로 선정하였다.

#### 4.2.3 Step 3: Location of damage

손상위치 추정 단계 Step 3은 Step 2에서 검증한 분류모델과 회귀모형을 이용하여 랜덤한 복수 손상 위치의 학습모델 결과를 분석하였다. 따라서 기존 손상시나리오에서 정의한 손상 데이터가 아닌 Fig. 22와 같이 손상 데이터를 단부 센서

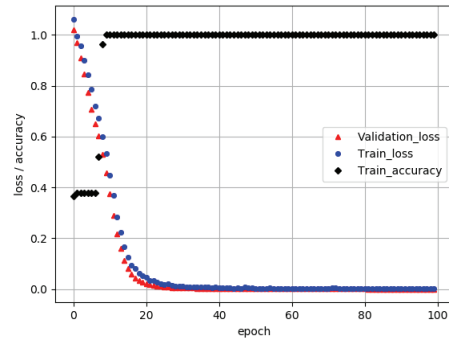


Fig. 19 Convergence of Step 2 model - history of the loss function for the training and validation set

		Predict		
		Level 0	Level 1	Level 2
Actual	Test size=60			
	Level 0	20	0	0
	Level 1	0	20	0
Level 2	0	0	20	

Test Accuracy = 100%

Fig. 20 Confusion matrix for test data of Step 2 model

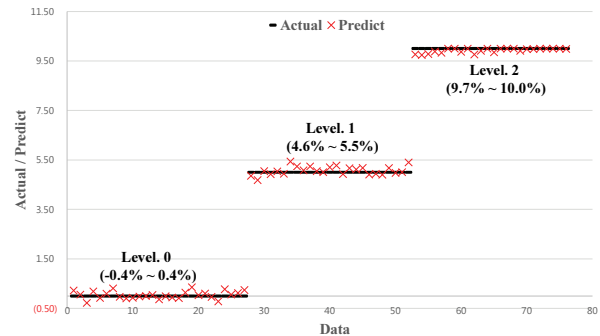


Fig. 21 Comparison of the real value with the predict value of the regression model at S14

( $S_1, S_{58}$ )와 중앙부 센서( $S_{13}, S_{43}$ ) 위치에서 한 칸씩(230mm) 이동하며 복수 손상 시험 데이터를 새롭게 구축하였다. 또한 손상 크기를 Level 1과 Level 2 두 개로 나눠 손상 크기가 달라짐에 따라 손상 위치 탐지 결과가 달라지는지 확인하였다.

각각 손상 Level 1과 2일 때, Test A~C에 대한 분류 모델의 손상 탐지 결과와 회귀모델의 손상 예측 값을 Table 6~8에 도시하였다. Test 손상 근처의 센서( $S_1, S_2, S_{13}, S_{14}, S_{42}, S_{43}, S_{55}, S_{56}$ )를 선택하였다.

(1) 분류(Classification) 모델의 경우 임의의 손상 위치에 대해 손상을 탐지 못하는 것으로 판단된다. 분류 학습 모델은 학습 시키지 않은 데이터에 대해 정확한 정답을 도출하지 못한




다. 즉, 앞에서 검증한 Step 1과 2의 경우 손상 시나리오에 국한되어 결과를 도출하는 한계를 가진다. 따라서 분류 모델로 손상위치를 파악하기 위해선 본 연구에서 정의한 5%와 10% 손상 케이스보다 더 다양한 손상에 대해 학습 데이터를 구축해야 함을 알 수 있다.

(2) 회귀(Regression) 모델의 경우 임의의 손상 크기와 위치에 대해 의미 있는 결과를 도출할 수 있다고 판단된다. Test A~C의 Local 손상지수는 동일한 손상 크기를 비교했을 때, Table 3에서 정리한 손상 Level 1과 2의 Local 손상지수 범위보다 큰 값을 가진다. 따라서 회귀모델을 이용해 정확한 손상 크기를 예측하지는 못했지만 예측 값에 대해 아래 2가지 결론을 도출하였다.


- ① 예측 값이 오차 범위 5% 이내의 실제 손상 크기를 정확

**Table 5** Predicted values of regression model for damage case 3% and 7%


	Damage 3% at S14	Damage 7% at S14
Local Damage Index	0.748	0.517
Regression Predict value	2.85%	7.34%



**Fig. 22** Designing random multiple damage cases for Test data



**Fig. 23** Comparison of damage predicts by S1 and S2



**Fig. 24** Comparison of damage predicts by S13 and S14

하게 탐지한 경우

- ② 예측 값이 계측 센서로부터 일정 거리가 떨어진 곳의 손상을 탐지한 경우

결론 ①은 Step 2의 임의의 손상 크기를 탐지함으로써 성능을 검증하였으며 결론 ②는 Fig. 23~24의 손상 위치를 이동함에 바뀌는 손상 예측값을 인근 센서 두 개를 비교하여 성능을 검증하였다.

계측 센서는 오른쪽 단부 센서( $S_1, S_2$ )와 중앙부 센서( $S_{13}, S_{14}$ )를 비교하였으며, x축을 Test A, B, C로 하여 손상이 왼쪽

**Table 6** Classification and Regression model results of Test A for each sensor

Sensor	Local Damage index		Classification		Regression	
	Level 1	Level 2	Level 1	Level 2	Level 1	Level 2
S1	0.894	0.891	0	0	-0.08%	-0.02%
S2	0.853	0.800	0	0	0.69%	1.69%
S13	0.728	0.537	1	1	3.37%	7.08%
S14	0.868	0.823	0	0	0.79%	1.62%
S42	0.896	0.829	0	0	0.61%	1.43%
S43	0.712	0.499	1	2	3.43%	7.45%
S55	0.891	0.872	0	0	0.65%	0.65%
S56	0.827	0.744	0	0	0.91%	2.18%

**Table 7** Classification and Regression model results of Test B for each sensor

Sensor	Local Damage index		Classification		Regression	
	Level 1	Level 2	Level 1	Level 2	Level 1	Level 2
S1	0.872	0.815	0	0	0.19%	0.87%
S2	0.856	0.765	0	0	0.64%	2.35%
S13	0.881	0.811	0	0	0.67%	1.75%
S14	0.867	0.826	0	0	0.81%	1.57%
S42	0.870	0.830	0	0	0.68%	1.42%
S43	0.869	0.819	0	0	0.59%	1.42%
S55	0.873	0.838	0	0	0.65%	1.13%
S56	0.810	0.703	0	0	1.17%	2.81%

**Table 8** Classification and Regression model results of Test C for each sensor

Sensor	Local Damage index		Classification		Regression	
	Level 1	Level 2	Level 1	Level 2	Level 1	Level 2
S1	0.889	0.877	0	0	-0.01%	0.13%
S2	0.683	0.444	1	2	3.89%	8.39%
S13	0.869	0.820	0	0	0.67%	1.57%
S14	0.745	0.528	0	1	3.05%	7.04%
S42	0.727	0.501	1	2	3.32%	7.50%
S43	0.886	0.824	0	0	0.59%	1.32%
S55	0.745	0.503	1	2	2.92%	7.57%
S56	0.870	0.863	0	0	0.26%	0.36%

에서 오른쪽으로 이동함을 표현하였다. Fig. 23에서  $s_1$ (검정)의 회귀모델은 예측 값이 Test B를 제외하고 모두 0.4% 미만으로 손상을 감지하지 못함을 확인하였다.  $s_2$ (빨강)의 회귀 모델은 계측 센서에서 가장 먼 곳의 손상을 0.69%로 예측함으로써 실제로 계측센서 위치에서 손상이 0.69%인 경우와, 계측 센서에서 가장 먼 곳의 손상이 있음을 판단할 수 있다. 또한 Test A에서 C로 손상이  $s_2$ 에 가까워질수록 손상예측 값이 증가하기 때문에  $s_2$ 에서 얼마나 떨어진 곳에 손상이 있는지 위치를 추정할 수 있다. Fig. 24는 중앙부 인근센서  $s_{13}$ (검정),  $s_{14}$ (빨강) 회귀모델의 예측 값을 비교한 것으로  $s_{13}$ 와  $s_{14}$  모두 Fig. 24의  $s_2$ 와 동일한 결론을 도출할 수 있다.

## 5. 결 론

이 연구에서는 단경간 무도상 철도 관형교를 대상으로 교량 모델을 구축한 후 손상 시나리오 설계 및 손상 데이터의 피쳐엔지니어링 과정을 통해 정적재하의 변형률 데이터 기반의 손상탐지 머신러닝 학습 모델 알고리즘을 제안 및 검증하였다. 손상 탐지는 손상 유무, 손상 정도, 손상 위치 탐지의 3단계로 나뉘어 학습 모델을 평가하였으며, 학습 결과에 대한 연구 결과를 정리하면 다음과 같다.

- 1) 기존의 교량 손상탐지 모델의 경우 손상 데이터의 부재로 인해 한정적인 손상 학습 결과에 대한 한계를 피할 수 없다. 따라서 손상 전후 데이터의 뚜렷한 특징을 추출하기 위해 통계적 기법을 이용하여 신뢰도 기반의 Local 손상지수를 산정하였다.
- 2) Step 1, 2단계에서 손상의 유무, 손상의 크기를 분류할 수 있는 모델을 검증하였다. 손상 유무 탐지 모델은 무손상과 손상을 탐지하는 이중분류 학습 모델이며, 손상 크기 탐지 모델은 3가지 손상 케이스로 분류하여 다중분류에 효과적인 학습 모델이다. 두 모델 모두 시험 데이터의 정확도가 100%로 우수한 결과를 도출하였다. 이는 Local 손상지수가 각 손상별로 뚜렷이 구별되는 특징을 가지고 있기 때문이다. 또한 임의의 손상 크기 추정하기 위해 회귀 모델의 예측 값을 실제 값과 비교 분석하였으며, 손상 시나리오에서 정의하지 않은 손상을 오차율 5% 이내로 예측하여 더 다양한 손상에 대해 탐지할 수 있음을 판단된다.
- 3) 최종적으로 손상 탐지 분류 모델과 회귀 모델을 비교 분석하여 임의의 손상위치를 추정하였다. 분류 모델의 경우 시험 데이터의 Local 손상지수가 학습 데이터의 범위 안에 있는 경우만 손상을 정의할 수 있어 랜덤한 상황의

손상을 탐지하기 위해선 다양한 손상시나리오를 학습해야 함을 판단할 수 있다. 회귀 모델의 경우 계측 센서에서 거리가 떨어질 수록 예측 값의 크기가 작아짐을 확인하였고, 인근 센서의 예측 값을 분석함으로써, 정적변형률 데이터 기반 머신러닝 회귀모델이 효과적으로 랜덤한 손상 위치를 추정할 수 있는 모델임을 검증하였다.

- 4) 본 연구에서 정적 변형률 데이터 기반 머신러닝을 이용한 손상 탐지 모델을 검증하였다. 회귀모델을 통해 임의의 손상 크기와 위치를 추정할 수 있으나, 공용중인 철도교량에 적용 시 차량통제를 통한 정적 데이터의 축적이 어려울 것으로 판단된다. 따라서 추후 실시간 모니터링을 위한 동적 열차 하중의 손상 탐지 머신러닝 학습 모델을 검증하는 연구가 필요하다고 판단된다. 또한 시뮬레이션 교량이 아닌 공용중인 무도상 철도 관형교의 정적, 동적 변형률 데이터를 계측함으로써 손상 탐지 알고리즘을 검증하는 추후 연구가 필요하다.

## 감사의 글

본 연구는 국토교통부 국토교통기술촉진연구사업 (과제번호 20RTRP-B137949-04)에 의해 수행되었습니다.

## References

1. Moon, T. U. (2020). Safety Evaluation of the Superstructure of Railway Non-ballasted Plate Girder Bridge in the Application of CWR, International Journal of Railway, 23(1), pp. 10-20.
2. Ministry of Land Infrastructure and Transport (2017). Strategies to respond to the 4th industrial revolution, April, 21, 2017, pp. 1-16.
3. Kim, D. G. (2018). Performance evaluation of SOC Structure using Deep Learning technology, Seoul: Korea Institute of Construction Technology, pp. 164-172.
4. Gary Marcus. (2019). DeepMind's Losses and the Future of Artificial Intelligence, WIRED, Retrieved from <https://www.wired.com/story/deepminds-losses-future-artificial-intelligence>, Aug. 14. 2019.
5. Gary Marcus. (2018). Deep Learning: A Critical Appraisal, arXiv:1801.00631 [cs], Jan. 2. 2018.
6. Park, S. J. (2019). Reinforce Effect of Lower Bracing on Dynamic Behavior Characteristic in Railway Plate Girder Bridges, Master Thesis, Inha University, pp. 17-18.
7. Ng, Andrew. (2013). Machine Learning and AI via Brain simulation, Stanford University, Retrieved from <http://ai.stanford.edu/~ang/slides/DeepLearning-Mar2013>, Mar. 2013.
8. Micro-Measurements, V. (2007). Strain gage selection: criteria, procedures, recommendations, Tech Note TN-505-6, pp. 4-6

9. Lee, G. H. (2018). Damage Detection for RC Rahmen Bridge Based on Convolutional Neural Network, Master Thesis, Inha University, pp. 55-56.
10. Kim, Y. H. (2017). Development and Application of Reliability-based Structural Health Monitoring Algorithm for Existing Bridges, Doctor Thesis, Inha University, pp. 58-59.

Received : 11/10/2020

Revised : 11/23/2020

Accepted : 12/15/2020

---

**요 지 :** 국내의 노후 철도교량이 증가함에 따라 노후화로 인한 유지관리비가 점점 증가하고 있으며, 지속적인 관리가 더욱 더 중요해지고 있다. 하지만 관리해야하는 노후 시설물은 증가하지만, 노후 시설물을 점검 및 진단을 할 수 있는 전문 인력은 부족해지고 있다. 이러한 문제를 해결하기 위해 본 연구는 정적 변형률 응답 데이터를 적용하여 AI 기술의 머신러닝 기법으로 구조물의 국부적인 손상을 탐지하는 개선된 학습 모델을 제시하고자 한다. 손상탐지 머신러닝 학습 모델을 구성하기 위해 우선 무도상 철도 관형교의 설계도면을 참고하여 교량의 해석모델을 설정하였으며, 설정된 해석모델로 손상시나리오에 따른 정적변형률 데이터를 추출하여 통계적 기법을 이용해 교량의 신뢰도 기반의 Local 손상 지수를 제시하였다. 손상 탐지는 손상 유무 탐지, 크기 탐지, 위치 탐지 3단계의 과정을 수행하여 손상 크기 탐지에서 선형 회귀 모델을 추가로 고려해 임의의 손상을 탐지하였으며, 최종적으로 손상 탐지 머신러닝 분류 학습 모델과 회귀 모델을 이용한 임의의 손상 위치를 추정 및 검증하였다.

**핵심용어 :** 무도상 철도 관형교, 머신러닝, 손상 탐지, 정적 변형률, Local 손상지수

---