

정적 변형률 데이터를 사용한 CNN 딥러닝 기반 PSC 교량 손상위치 추정

CNN deep learning based estimation of damage locations of a PSC bridge using static strain data

한만석¹⁾, 신수봉²⁾, 안효준³⁾

Han, Man-Seok¹⁾ · Shin, Soo-Bong²⁾ · An, Hyo-Joon³⁾

Received May 11, 2020; Received June 30, 2020 / Accepted June 30, 2020

ABSTRACT: As the number of aging bridges increases, more studies are being conducted on developing effective and reliable methods for the assessment and maintenance of bridges. With the advancement in new sensing systems and data learning techniques through AI technology, there is growing interests in how to evaluate bridges using these advanced techniques. This paper presents a CNN(Convolution Neural Network) deep learning based technique for evaluating the damage existence and for estimating the damage location in PSC bridges using static strain data. Simulation studies were conducted to investigate the proposed method with error analysis. Damage was simulated as the reduction in the stiffness of a finite element. A data learning model was constructed by applying the CNN technique as a type of deep learning. The damage status and its location were estimated using data set built through simulation. It was assumed that the strain gauges were installed in a regular interval under the PSC bridge girders. In order to increase the accuracy in evaluating damage, the squared error between the intact and measured strains are computed and applied for training the data model. Considering the damage occurring near the supports, the results of error analysis were compared according to whether strain data near the supports were included.

KEYWORDS: Damage location, PSC bridge, CNN, Deep learning, Static strain

키워드: 손상위치, PSC 교량, CNN, 딥러닝, 정적 변형률

1. 서론

노후화된 교량이 많아지면서 교량의 안전성 평가와 보수보강, 유지관리 부분에 대한 연구가 보다 활발히 진행되고 있다. 하지만 노후화된 교량에 대한 효과적인 안전성 평가법은 아직 개발되었다고 보기 어렵다. Figure 1은 한국시설안전공단에서 제시한 안전점검 및 정밀안전진단 세부지침(KISTEC, 2017)에서 제시한 안전관리 업무 흐름도이고, Table 1은 안전등급에 따른 정밀안전진단 횟수이다. 국내의 경우 교량 정밀안전진단 시 안전성 평가를 위해 현장재하시험을 진행하도록 하고 있다. 현장재하시험을 위해서는 차량통행을 제한해야 하므로, 일반적으로 차량통행이 적고 환경

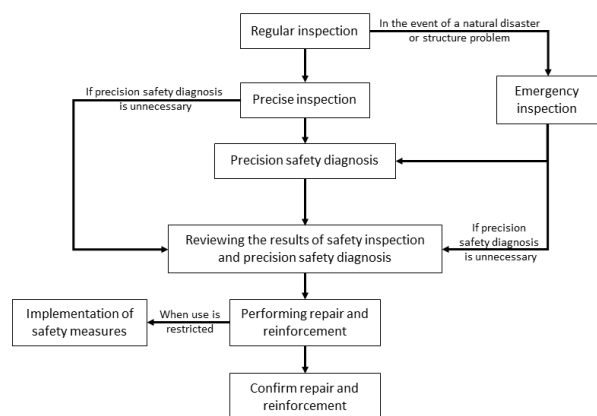


Figure 1. Process of safety management (KISTEC, 2017)

¹⁾학생회원, 인하대학교 토목공학과 석사과정 (hms115@hanmail.net)

²⁾정회원, 인하대학교 사회인프라공학과 교수 (sbshin@inha.ac.kr) (교신저자)

³⁾학생회원, 인하대학교 토목공학과 박사과정 (kiekil12@daum.net)

Table 1. Safety diagnosis period according to safety grade (KISTEC, 2017)

| Safety Grade | Safety Diagnosis Period |
|--------------|---------------------------------|
| Grade A | More than once every six years |
| Grade B, C | More than once every five years |
| Grade D, E | More than once every four years |




Figure 2. Damage detection based on machine learning of railroad bridges (Neves, 2018)




Figure 3. Machine learning-based damage detection using responses data (Malekjafarian, 2019)

변화의 요인이 작은 새벽 시간에 현장재하시험을 수행한다.

최근 계측값과 해석값을 단순 비교하거나 둘 사이의 오차를 최소화하여 설정한 해석모델로 교량의 성능을 평가하는 방법들과는 별도로, 실시간 계측데이터를 활용하여 효과적이면서도 지속적으로 교량의 상태를 파악하기 위해 머신러닝, AI(Artificial Intelligence)기법 등을 접목한 기술개발 연구가 국내외적으로 활발하게 이루어지고 있다(Neves, 2018; Malekjafarian, 2019).

첨단기법을 적용하여 교량의 성능 및 상태를 평가하고 손상을 진단하는 연구들은 다양하게 소개되고 있다. Figure 2와 Figure 3은 머신러닝 기법을 기반으로 교량의 손상을 진단하는 사례들이다(Neves, 2018; Malekjafarian, 2019). 그외 머신러닝 혹은 ELM(Extreme Learning Machine) 기반으로 교량의 손상 상태 및 위치를 추정하는 연구들이 소개되어 있다(Mangalathu, 2019; Djemana, 2017).

AutoEncoder 혹은 CAE(Convolutional Auto Encoder) 기법을 적용한 예로 교량 텐던의 손상을 탐지한 연구(Lee, 2019)와 구조 손상을 식별한 연구(Pathirage, 2018)를 들 수 있다. 또한 RSNB(Rough Set 이론과 Naive-Bayes 분류기) 방법으로 교량에서의 다중 손상 문제에 대한 진동기반 손상 감지 방법을 제시

한 연구(Sun, S, 2018), 철도교량의 실시간 피로손상 식별을 위해 POD-ANN(Proper Orthogonal Decomposition-Artificial Neural Network) 방법을 적용한 연구(Rageh, 2020), 구조물 손상 검출을 위해 실제 사례의 데이터를 SVM(Support Vector Machine) 기법에 적용하고 SVM기법을 적용한 연구(Gui, 2017)등 다양한 연구가 진행되고 있다. 그러나 이러한 다양한 연구에도 불구하고 아직 대부분 연구가 손상유무를 감지하는 수준에 머물고 있다.

손상진단 기술은 손상유무 감지, 손상위치 추정, 손상정도 평가의 3단계 수준으로 정의할 수 있다. 본 논문에서는 손상유무 감지뿐만이 아니라 손상위치를 추정하는 2단계 수준까지의 기술을 제안하고 PSC 교량에 대해 검증하였다. 우선 PSC 교량 수치모델을 설정하고 발생 가능한 손상을 수치모델에 모사한 후, 구조해석을 통해 정적 변형률을 계산하였다. 그리고 이 변형률 데이터를 딥러닝기법 중 하나인 CNN(Convolution Neural Network)을 통한 데이터 학습을 수행하여 손상을 감지하고 위치를 추정하는 기술을 제시하였다. PSC 교량의 손상은 지점부와 경간 중앙에 발생 가능한 것으로 모사하였으며, 지점 부근 손상 파악을 위해 지점부 변형률 데이터를 확보하는 경우와 확보하지 않는 경우의 손상진단 결과의 차이를 분석하였다.

2. CNN 딥러닝 기반 손상위치 추정 기본 원리

2.1 CNN 기법의 원리

일반적으로 CNN 기법은 2차원 이상의 배열 형태인 입력 데이터에 대해서 데이터 학습이 필요할 경우 주로 사용한다. 이는 CNN 기법에서 사용되는 convolution filter가 배열 형태의 데이터를 분석하는데 최적화되어있기 때문이다. Figure 4는 CNN 기반 데이터 학습 과정을 표현한 것으로 입력데이터가 convolution layer를 거치면서 데이터의 크기가 줄어드는 것을 보여준다.




Figure 4. Conceptual diagram of CNN data learning processing (Daphne, 2018)

Convolution filter란 빛이 편광필름을 통과하여 빛의 세기가 조절되는 것처럼, 배열 형태의 데이터를 필터링하여 특징을 더 정교하게 추출하고 크기를 축소시키는 역할을 한다. Convolution filter의 가중치로 인해 데이터의 특징 및 패턴을 더욱 증폭시키는




Figure 5. Digitization of image data (a) separation of 3 RGB components, (b) Numerical representation for each pixel (Brandon, 2019)

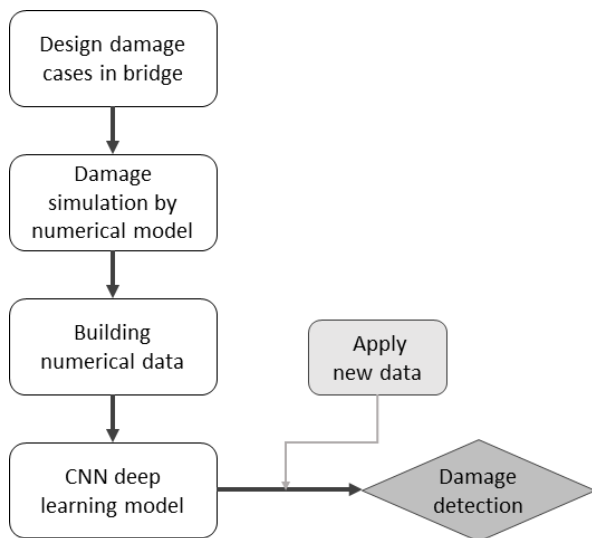


Figure 6. Damage localization algorithm using CNN

효과가 있으며, convolution filter를 통과한 데이터는 가중치를 통한 합성곱(convolution)방식으로 하나의 값으로 추출되어 데이터 크기가 줄어든다. 데이터의 크기가 줄어들면 학습을 진행하는 컴퓨팅 속도가 빨라지기 때문에 더 많은 양의 데이터를 학습하는데 유리하다(Taeho, 2019).

이러한 특성 때문에 CNN 기법은 주로 이미지 데이터를 학습하는 용도로 많이 사용된다. 이미지 데이터는 수많은 픽셀로 이루어져 있다. 각 픽셀은 숫자의 값을 가지고 있으며 RGB 3 원소의 3가지 값을 가진다. Figure 5는 이미지 데이터를 RGB로 나누고, 각 픽셀 별 수치를 표현한 것이다. 이미지 데이터의 경우는 모두 RGB와 배열 형태의 픽셀을 가지면서 Figure 5와 같이 3차원의 형태로 데이터를 표현할 수 있다. 이미지를 배열 형태로 표현하여 이미지 내에 특징을 학습하는 것을 모티브로 본 논문에서는 구조물을 2차원 평면으로 가정하고 손상위치 정보를 배열의 형태로 표현하여 CNN기법으로 손상위치를 추정하는 학습을 진행하였다.

2.2 CNN 기반 손상위치 추정 알고리즘

본 논문에서 제시하는 손상위치 추정 알고리즘은 Figure 6과 같다. 먼저 교량에서 발생할 수 있는 손상에 대한 학습을 진행하고, 해당 교량의 위치적 특성과 주변 환경요소 등을 고려한 시나리오를 구성하고, 이때 교량에서 발생할 수 있는 손상을 설계한다. 그 다음 해당 교량에 대해서 손상이 발생한 경우에 대한 시뮬레이션을 수행한다. 이를 위해 해당 교량에 적합한 수치모델을 설정하고 손상을 모사한다. 시뮬레이션을 통해 계산된 결과로 데이터를 구축하고 CNN을 적용한 학습모델에 입력하여 손상에 대한 학습을 진행한다. 입력 데이터에 대한 학습모델이 완전히 구축되면 해당 교량에 설치된 계측시스템을 통해 획득되는 데이터로 손상을 추정한다.

2.3 입력 데이터 패턴 분석

AI 기술 및 머신러닝 데이터 학습에서 가장 중요한 것은 학습 결과의 정확도(accuracy)이다. 정확도를 높이기 위해서는 입력 데이터의 특성에 맞는 학습모델을 구성하는 것도 중요하지만 입력 데이터가 가지고 있는 특성도 매우 중요하다. 학습모델을 매우 정교하게 구성하여도 입력 데이터에 특성이 존재하지 않거나 특성이 존재하나 노이즈가 있어 뚜렷하지 않을 경우 예측 정확도가 떨어질 수 있다. 따라서 학습을 위한 입력 데이터의 선정도 매우 중요하다. 교량에서 계측되는 변형률은 일반적으로 설치 오류로 인한 오차가 있을 수 있지만, 광섬유센서를 사용하는 경우 환경영향과 계측오차가 상대적으로 적고 안정적이므로 본 논문에서는 변형률을 학습 데이터로 사용하였다. 하지만 단경간 교량의 경우 변형률이 측정 위치마다 거의 비슷하게 나타난다는 점을 고려하여 다음 식(1)을 적용하여 변형률 데이터를 변환하였다.

$$(\Delta \epsilon_i)^2 = |(\epsilon_i)^2 - (\epsilon_0)^2| \quad (1)$$

여기서, ϵ_i 는 설계한 각각의 손상 시나리오에서 시뮬레이션을 통해 계산한 변형률이고, ϵ_0 는 손상이 없는 경우에 대한 변형률이다. 식(1)과 같이 제곱오차방식을 이용하게 되면, 손상을 적용하지 않았을 경우는 $(\Delta \epsilon_0)^2$ 값이 모두 0이 되어 손상 시나리오에 따른 데이터의 특성 및 패턴이 더욱 뚜렷하게 된다.

3. PSC 교량 수치모델에 대한 손상위치 추정

3.1 PSC 교량 수치모델 설계

본 논문에서는 현존하는 실제 PSC 교량을 참조하여 유한요소 모델로 설정하였다. 거더 4개와 가로보 3개에 거더 높이 2m, 바닥 높이 0.27m에 폭 12.6m, 경간장 30m로 설계하였다. Table




Figure 7. Strain sensor locations under the bridge girders




Figure 8. Simulated damage locations around the supports and in the mid-span of the PSC model bridge

Table 2. Material and sectional properties of PSC bridge numerical model

| Type | Properties |
|------------|---|
| girder | <ul style="list-style-type: none"> • Modulus of Elasticity: 30,867 MPa • Poisson's ratio: 0.18 • Structural Damping: 0.05 • Mass Density: 2.452 |
| slab | <ul style="list-style-type: none"> • Modulus of Elasticity: 27,782 MPa • Poisson's ratio: 0.18 • Structural Damping: 0.05 • Mass Density: 2.452 |
| cross beam | <ul style="list-style-type: none"> • Modulus of Elasticity: 28,554 MPa • Poisson's ratio: 0.18 • Structural Damping: 0.05 • Mass Density: 2.452 |

2는 수치모델에 대해서 각 구조요소 별로 재료 물성을 정리한 것이다.

Figure 7은 설계한 PSC 교량 수치모델에서 변형률 데이터를 계측할 위치를 표시한 것이다. 각 거더마다 일정한 간격으로 7개씩 계측지점을 선정하였다. 거더의 양쪽 끝부분 계측지점은 지점부 위치로 일반적으로는 지점부에서 변형률을 계측하지는 않지만,

교량받침을 포함한 지점 부근에서의 손상이 다수 보고되고 있으므로 이러한 손상도 추정하기 위하여 계측지점으로 선정하였다. 본 연구에서는 손상위치 추정 학습 데이터를 지점부 변형률을 포함한 것과 포함하지 않은 것으로 구성하여 정확도를 비교하였다.

3.2 손상 시나리오 설계

본 논문에서는 Figure 8에서와 같이 몇 가지 손상 시나리오를 가정하여 손상추정 학습을 진행하였다. Figure 8은 PSC 교량 수치모델에서 4개 거더만 표현한 것이다. 교량 거더의 양쪽 끝단 부분과 중앙부분 총 3가지 영역에 손상이 발생하는 것으로 정하여 총 12가지 손상위치를 설정하였다. 손상은 총 12곳 중에서 1곳만 발생한 것으로 가정하여 손상이 발생하지 않은 경우를 포함해 총 13가지의 손상 시나리오를 설계하였다. 손상 정도는 실제 교량에서 발생하는 경미한 손상을 반영하기 위해 손상 영역의 EI 값을 10% 감소시키는 것으로 가정하였고, 모든 손상 시나리오에 동일하게 적용하여 데이터를 구축하였다.

3.3 정적재하 시뮬레이션 실시 및 데이터 구축

본 논문에서는 데이터 구축을 위해 Han(2019)의 학위논문에서 사용된 방식을 적용하였다. 각 손상 시나리오에 대해서 정적재하 방식으로 시뮬레이션을 실시하였다. 시뮬레이션을 통해 Figure 8에서 설정한 계측위치에서의 변형률 데이터를 구축하였다. 데이터 학습을 위해서는 동일 손상 시나리오에 대한 다양한 데이터가 필요하므로, 본 논문에서는 다양한 하중재하 경우를 설정하여 데이터를 구축하였다. 시뮬레이션 하중으로 국토교통부 도로교설계 기준(MLIT, 2015)에서 제시하는 표준트럭하중(KL-510)을 적용하였다. 표준트럭하중(KL-510)의 제원은 Figure 9과 같다.




Figure 9. Standard truck load KL-510 (MLIT, 2015)

다양한 변형률 데이터를 구축하기 위해 수치모델의 다양한 위치에 Figure 9과 같은 제원의 하중을 입력하였다. Figure 10은 표준트럭하중이 이동하는 경로를 표현한 것으로, 표준트럭하중의 전륜과 후륜 간격을 고려하여 4개의 거더에 모두 작용될 수 있게 4가지 경로를 설정하였다.




Figure 10. Four loading paths in the PSC bridge model (Han, 2019)

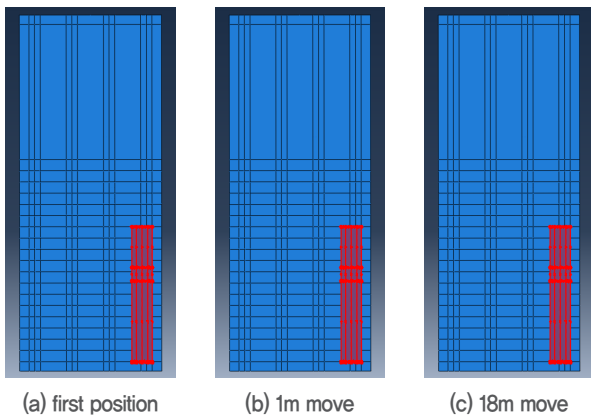


Figure 11. Static loading cases of the standard truck load on path_1 (Han, 2019)

Table 3. Sample of strain data(7X4)

| Location | girder1 | girder2 | girder3 | girder4 |
|----------|------------|------------|------------|------------|
| Support1 | -1.922E-05 | -5.124E-05 | -1.3E-05 | -3.369E-06 |
| Sensor1 | -2.701E-06 | -4.326E-06 | -2.805E-06 | -3.018E-06 |
| Sensor2 | -4.886E-06 | -7.071E-06 | -4.183E-06 | -3.064E-06 |
| Sensor3 | -6.638E-06 | -6.697E-06 | -5.254E-06 | -3.075E-06 |
| Sensor4 | -4.506E-06 | -5.079E-06 | -3.526E-06 | -2.101E-06 |
| Sensor5 | -2.267E-06 | -2.473E-06 | -1.783E-06 | -1.098E-06 |
| Support2 | -1.255E-05 | -1.672E-05 | -1.162E-05 | -8.057E-06 |

또한 각 경로마다 정적재하를 1m씩 이동하면서 진행하였다. Figure 11은 Figure 10의 (a)경로에 대해서 하중이 1m씩 이동하면서 정적재하가 진행된 모습을 보여준다. 경간장과 표준트럭하중

의 길이를 고려하여 각 경로마다 19번씩 하중재하를 실시하였다.

위 방식으로 표준트럭하중 정적재하를 실시하여 19번씩 4가지 경로를 다 합한 76가지 변형을 데이터를 출력하였다. 시뮬레이션을 통해 출력한 변형률 데이터의 예시는 Table 3과 같다. 각 거더의 위치적 요소를 데이터에 반영하기 위해 7x4의 배열 형태로 변형률 데이터를 구성하였다. 이러한 배열 형태의 데이터는 손상 위치의 특징을 잘 반영할 수 있을 것으로 판단하였고, 이러한 부분을 제대로 학습시키기 위해 CNN 기법을 도입하였다.

3.4 입력 데이터 설계

입력 데이터는 2가지로 구성하였다. 지점부 부근 손상 탐지를 위해 Table 3처럼 지점부를 포함한 7x4형태의 데이터와 지점부를 제외한 5x4형태의 데이터로 분류하였다. 2.3절에서 제안한 식(1)을 적용하여 데이터의 특징 및 패턴이 더 뚜렷해지게 변환하였다. 식(1)을 적용하면 손상이 없는 경우는 모두 0의 값을 가지게 된다. 이는 손상이 없는 경우를 기준으로 제곱오차를 계산하였기 때문이다. 따라서 식(1)을 적용하면 손상의 유무는 100% 탐지할 수가 있을 것으로 예상하였다.

3.2절에서 제시한 손상 시나리오 13가지와 3.3절에서 제시한 손상 시나리오별 정적재하 76가지를 모두 적용하여 총 988개의 데이터 셋을 구축하고, 이를 식(1)에 적용하여 변환하였다. 변환한 988개의 데이터를 가지고 CNN 기반 딥러닝을 적용시켜 손상 탐지 학습을 하였다.

3.5 CNN 학습모델 설계

Figure 12는 본 연구에서 설계한 CNN 기반의 딥러닝 알고리즘이다. Figure 12는 지점부를 포함하는 데이터를 사용하였을 때




Figure 12. CNN based deep learning algorithm

의 예시로 지점부를 포함하지 않은 데이터도 동일한 알고리즘으로 학습을 진행하였다. 알고리즘은 입력층과 convolution filter를 적용한 은닉층 2개, flatten 층, dropout, 출력층으로 구성하였다. 배열 형태의 데이터를 입력하여 거더별 손상위치 정보가 포함되게 하였고, convolution filter(1x1)을 2층 적용하여 처음은 16가지, 두 번째는 32가지 랜덤으로 작용하여 데이터의 특징이 더욱 뚜렷해지게 하였다. 그 다음 2차원 배열 형태 데이터를 1차원으로 변환해주는 flatten 층을 적용하고, 과적합을 방지하기 위한 dropout을 40% 적용한 다음, 손상 시나리오 13가지로 정답이 출력되게 출력층을 설계하였다. 학습에 사용된 train 데이터는 전체의 80%인 790개를 무작위로 선정하여 학습하였고, 학습이 완료된 이후 나머지 20% 데이터 198개를 Test 셋으로 적용하여 학습 모델을 검증하였다.

3.6 학습모델 정확도 분석

Train 데이터(790개)를 통해 학습이 완료된 모델에 Test 데이터(198개)를 적용하여 정확도를 출력하였다. 지점부를 포함한 데이터(7x4)와 지점부를 포함하지 않은 데이터(5x4) 모두 동일한 학습 알고리즘으로 정확도를 출력하였다. 우선 손상진단 기술 3단계에 있어서 1단계 손상유무에 대한 학습 정확도 결과를 출력하여 Figure 13과 Figure 14에서 분석하였다.

Figure 13은 지점부를 포함한 데이터에 대한 학습 결과이고, Figure 14는 지점부를 포함하지 않은 데이터에 대한 학습 결과이다. 무작위로 train 데이터를 선정하였기 때문에 2가지 데이터 셋의 개수는 서로 다르지만 모두 False Positive(FP)와 False Negative(FN)의 개수가 0개로 출력되면서 100% 정확도로 손상의 유무를 구별하였다. 이는 식 (1)을 적용하면서 손상 유무에 대한 매우 뚜렷한 특징이 나타났기 때문으로 판단된다. False Positive(FP)는 실제 손상이 없지만 예측 결과는 손상이 있다고 판단하는 것이고, False Negative(FN)는 실제 손상이 있지만 예측 결과 손상이 없다고 판단하는 것이다.

손상진단 기술 2단계 수준인 손상위치 추정에 대한 학습 결과에서는 지점부를 포함한 데이터와 지점부를 제외한 데이터가 서로 다르게 측정되었다. 총 198개의 Test 데이터에 대하여 Figure 13과 Figure 14에서 제시한 손상유무 판별 개수에 대한 위치 추정 결과를 분류하였다. Figure 15은 지점부를 포함한 데이터에 대하여 손상위치 추정 학습 결과이다. 손상위치까지 정확하게 찾는 개수가 167개, 손상이 있다고 판단했지만 위치를 다른 곳으로 인식한 경우 17개, 손상이 없어서 없다고 판단한 경우 14개로 나타났다. 결론적으로 총 198개 중 181개를 정확하게 맞추어 90.91%의 정확도가 출력되었다. 지점부를 제외한 데이터에 대해서는 Figure 16과 같이 손상이 있다고 판단하면서 정확한 위치를 파악한 경우가 162개, 손상이 있지만 다른 위치로 파악한 경

우 20개, 손상이 없다고 판단한 경우 16개로 나타나 총 198개 중 178개를 정확히 맞추면서 89.90%의 정확도를 출력하였다.

손상정도를 EI값 10% 감소로 하였을 때 CNN 기법을 통해 손상유무에 대해서는 정확도 100%, 손상위치 추정에 대해서는 정확도가 평균적으로 90%가 나타나는 것으로 분석되었다.

| | | ANSWER | |
|---------|-------|--|--|
| | | True | False |
| PREDICT | True | True Positive(TP) 184/184 (100%) | False Positive(FP) 0 |
| | False | False Negative(FN) 0 | True Negative(TN) 14/14 (probability = 100%) |

Figure 13. Error analysis of damage detection results with strain data from supports

| | | ANSWER | |
|---------|-------|--|--------------------------------------|
| | | True | False |
| PREDICT | True | True Positive(TP) 182/182 (100%) | False Positive(FP) 0 |
| | False | False Negative(FN) 0 | True Negative(TN) 16/16 (100%) |

Figure 14. Error analysis of damage detection results without strain data from supports

| Damage: O | | Damage: X |
|-----------------------------------|---------------------------------|-----------------|
| Location: O 167/184 (90.8%) | Location: X 17/184 (9.2%) | 14/14 (100%) |

Figure 15. Error analysis of damage localization results with strain data from supports

| Damage: O | | Damage: X |
|-----------------------------------|----------------------------------|-----------------|
| Location: O 162/182 (89.0%) | Location: X 20/182 (11.0%) | 16/16 (100%) |

Figure 16. Error analysis of damage localization results without strain data from supports

3.7 Test 데이터를 통한 학습모델 검증

실제 교량의 경우 손상정도를 파악하기는 어렵다. 따라서 손상이 발생하였을 때 손상위치를 정확히 파악하기 위해서는 손상

정도를 모르는 경우에 대해서도 손상위치를 추정할 수 있어야 한다. 따라서 본 논문에서는 PSC 교량 수치모델에 대해서 3.2절에서 제시한 손상위치를 무작위로 4곳을 선정하고 손상정도를 값 5%와 20%로 감소시킨 경우에 대한 무작위 데이터를 구축하였다. 손상 정도를 값 5%와 20%로 감소한 데이터로 선정한 이유는 손상 정도 값 10% 감소시킨 경우와 같이 경미한 손상에 대한 학습 정확도를 검증하기 위함이다. 총 8개의 데이터를 구축하고 지점부를 포함한 데이터와 지점부를 제외한 데이터를 식(1)에 적용하여 변환한 다음, 3.5절에서 제시한 CNN 기반 학습모델에 적용하고 정확도를 출력하였다.

Table 4. Damage localization results for the cases of 5% and 20% reduction of EI with strain data from supports

| Type | Case1 | Case2 | Case3 | Case4 | Case5 | Case6 | Case7 | Case8 |
|------------|-------|-------|-------|-------|-------|-------|-------|-------|
| Prediction | 10 | 2 | 6 | 7 | 3 | 5 | 9 | 10 |
| Answer | 12 | 2 | 6 | 7 | 3 | 5 | 9 | 10 |
| Result | False | True | True | True | True | True | True | True |

Table 5. Damage localization results for the cases of 5% and 20% reduction of EI without strain data from supports

| Type | Case1 | Case2 | Case3 | Case4 | Case5 | Case6 | Case7 | Case8 |
|------------|-------|-------|-------|-------|-------|-------|-------|-------|
| Prediction | 4 | 2 | 3 | 7 | 3 | 4 | 12 | 10 |
| Answer | 12 | 2 | 6 | 7 | 3 | 5 | 9 | 10 |
| Result | False | True | False | True | True | False | False | True |

Table 4와 Table 5는 8가지 무작위 변형률 데이터에 대한 예측 결과이다. 각 경우마다 손상 시나리오 번호를 출력하여 정답과 비교하였다. Table 4는 지점부를 포함한 데이터에 대한 예측 결과로 총 8가지 경우에 대해서 7개를 맞춰서 정확도가 87.5%로 출력되었다. Table 5는 지점부를 제외한 데이터를 사용하였을 때의 예측 결과이다. 총 8가지 경우에 대해 4개를 맞춰서 정확도가 50%로 출력되었다. 값 10% 감소 손상 정도로 학습모델을 검증한 결과는 지점부 변형률의 유무에 상관없이 대략 90%로 나타났다. EI값 5%와 20%의 손상 정도 데이터를 입력하였을 때는 손상 위치 추정에 대한 정확도가 서로 다르게 측정되었다. 이는 지점부 부근에서 손상이 발생하였을 경우에 대해 지점부 부근에서 측정된 변형률이 손상위치 추정에 비교적 영향이 있는 것으로 판단된다. 실제 교량의 경우 지점부 부근에서도 다양한 손상이 발생하기 때문에 지점부 손상을 파악하기 위해서는 지점부 부근의 변형률 계측이 필요할 것으로 판단된다.

4. 결론

본 논문은 AI 기반으로 교량의 손상을 진단하는 기술을 개발하기 위한 초기 연구로, 정적재하 방식의 변형률 데이터를 사용한 손상유무 및 손상위치를 추정할 수 있는 기술을 제시하였다. 실제 PSC 교량에 적합한 수치모델을 설정하고, 발생 가능한 손상위치를 선정하여 손상 시나리오를 설계한 다음, 정적재하 방식으로 변형률 데이터를 구축하였다. CNN 기반의 딥러닝 학습모델을 설계하여 변형률 데이터 셋을 입력하고 손상유무 및 손상위치 추정에 대한 학습을 진행한 다음, test 데이터 셋을 통해 학습모델을 검증하였다. 손상진단의 1단계(손상유무)와 2단계(손상위치) 추정에 대한 결과를 분류하여 오차분석을 통해 비교 검증하였으며 다음과 같은 결론을 도출하였다.

- (1) 손상유무 추정에 대해서는 학습모델 정확도가 거의 100%로 매우 높게 측정되었다. 이는 변형률 데이터를 변환하는데 사용한 변형률 제공오차 식(1)에 의해 손상이 없는 경우는 모든 데이터가 0으로 측정되어 손상이 있는 경우의 데이터를 확연하게 구분할 수 있었기 때문으로 판단된다. 이러한 데이터 변환 과정을 실제 교량에 적용한다면 교량의 현재 상태를 바탕으로 추후 계속되는 변형률 데이터로 손상유무를 판단할 수 있을 것이다. 실제 교량에 적용하기 위해서는 해당 교량에 대한 수치모델을 설정할 때 현재 교량의 상태를 반영하기 위한 모델 업데이트가 필요할 것이다.
- (2) 손상의 위치추정에 대해서는 학습모델의 정확도가 지점부를 포함한 데이터와 지점부를 제외한 데이터에 대해서 서로 다르게 나타났다. 손상 정도를 값 10% 감소한 데이터 셋으로 검증을 한 경우에 대해서는 평균적으로 90%의 정확도를 보이면서 비교적 위치 추정이 잘되는 것으로 판단된다. 그러나 10% 감소한 데이터로 학습한 모델을 적용하였을 때, 이와 다소 다른 손상 정도인 값 5%와 20%로 감소한 데이터 셋에 대한 검증 결과는 지점부 변형률을 포함한 여부에 따라 서로 다르게 결과가 나타났다. 즉 지점부 변형률을 포함한 데이터를 사용한 경우가 손상의 위치를 보다 정확하게 추정하는 결과를 보였다. 따라서 지점부 변형률이 손상위치를 구분하는데 어느 정도 영향을 미친 것으로 판단된다. 실제 현장재하시험에서도 지점부 부근 변형률을 계측하는 경우는 극히 드물지만 본 논문의 기술을 적용하기 위해서는 지점부 부근에서도 변형률을 계측하여 데이터 학습을 진행하는 것이 좋을 것으로 판단된다.

본 논문에서는 PSC 교량 수치모델을 사용한 시뮬레이션으로 구축한 변형률 데이터로 딥러닝 CNN 기반 학습모델을 설정하였다. 이를 활용하여 정적재하시험 시 계속되는 변형률로 손상유무 및 손상위치 추정이 가능하다는 것을 증명하였다. 본 연구에서 제

안한 방법을 확대 적용하면 향후 정적재하 방식이 아닌 동적재하 방식으로 손상위치 추정이 가능한 기술을 개발할 수 있을 것으로 기대하며, 이에 대한 추가 연구가 필요하다. 또한 본 논문은 실제 교량과 매우 흡사한 수치모델을 통해 방법론을 제시하였지만 실제 교량의 거동 및 손상 시나리오를 수치모델로 모두 표현하기에는 한계가 있다. 따라서 실제 교량의 계측 데이터를 접목하여 적용하는 연구가 필요하다. 또한 실제 교량의 거동을 표현하기 위한 가상 모델 구축을 위해 디지털트윈 기술에 대한 연구가 필요하다. 센싱시스템을 이용한 실제 교량의 디지털트윈 기술을 개발한다면 본 논문에서 제안한 방법을 적용할 수 있을 것이다.

감사의 글

본 연구는 국토교통부 건설기술연구개발사업의 연구비지원 (20SCIP-B128569-04)에 의해 수행되었습니다.

References

- Brandon, R. (2019). How to Convert an RGB Image to Grayscale. End-to-End Machine Learning Library, https://brohrer.github.io/convert_rgb_to_grayscale.html (Nov. 14, 2019)
- Daphne, C. (2018). An intuitive guide to Convolutional Neural Networks. freeCodeCamp, <https://medium.freecodecamp.org/an-intuitive-guide-to-convolutional-neural-networks-260c2de0a050> (Apr. 24, 2018)
- Djemana, M., Hrairi, M., Al Jeroudi, Y. (2017). Using electromechanical impedance and extreme learning machine to detect and locate damage in structures. *J. of Nondestructive Evaluation*, pp. 36–39.
- Gui, G., Pan, H., Lin, Z., Li, Y., Yuan, Z. (2017). Data-driven support vector machine with optimization techniques for structural health monitoring and damage detection. *KSCE J. of Civil Engineering*, 21(2), pp. 523–534.
- Han, M. (2019). Construction of Digital Twin for Bridges and Development of Damage Localization Process using CNN Deep Learning. Masters Thesis, Inha University.
- KISTEC. (2017). Specification for detailed violation of safety inspection and precision safety diagnosis (bridge).
- Lee, K., Jeong, S., Sim, S. H., Shin, D. H. (2019). A Novelty detection approach for tendons of prestressed concrete bridges based on a convolutional autoencoder and acceleration Data. *Sensors*, 19(7),1633, pp. 1–27.
- Malekjafarian, A., Golpayegani, F., Moloney, C., Clarke, S. (2019). A machine learning approach to bridge-damage detection using responses measured on a passing vehicle. *Sensors*, 19, 4035, pp. 1–19.
- Mangalathu, S., Hwang, S. H., Choi, E., Jeon, J. S. (2019). Rapid seismic damage evaluation of bridge portfolios using machine learning techniques. *Engineering Structures*, 201(2019), 109785, pp. 1–12.
- MLIT. (2015). the Limit-State based Bridge Design Specification. Korean Ministry of Land, Infrastructure and Transport.
- Neves, A. C., González, I., Leander, J., Karoumi, R. (2018). A new approach to damage detection in bridges using machine learning. *Lecture Notes in Civil Engineering*, 5, pp. 73–84.
- Pathirage, C. S. N., et al. (2018). Structural damage identification based on autoencoder neural networks and deep learning. *Engineering Structures*, 172, pp. 13–28.
- Rageh, A., Eftekhar, A. S., Linzell, D. G. (2020). Steel railway bridge fatigue damage detection using numerical models and machine learning: Mitigating influence of modeling uncertainty. *Int. J. of Fatigue*, 134, 105458, pp. 1–21.
- Sun, S., Liang, L., Li, M., Li, X. (2018). Vibration-based damage detection in bridges via machine learning. *KSCE J. of Civil Engineering*, 22(12), pp. 5123–5132.
- Taeho, J. (2019). Everyone's Deep Learning, 5th ed., Gilbut, pp. 221–233.