가속도계 설치 개수 및 위치에 따른 딥러닝 기반 교량 손상 추정 영향 분석

Impact Assessment of Bridge Damage Detection Based on Deep Learning According to Number and Location of Accelerometer Installations

이강혁* · 심성한** · 신도형***

Lee, Kanghyeok*, Sim, Sung-Han**, and Shin, Do Hyoung***

Abstract

In recent times, there has been an increase in the occurrence of disasters caused by a rapid increase in the aging of infrastructure. A structural health monitoring system can be utilized to detect severe damages in infrastructure and prevent accidents. In a previous study, the authors developed a method for damage detection in bridges using monitoring systems. However, the operational cost of the proposed method was high due to the requirement of multiple expensive accelerometers. The aim of this study is to reduce the number of accelerometers used in the aforementioned method by determining the optimal installation locations of the accelerometers. As a result of this study, optimal accelerometer installation locations for bridge damage detection, have been proposed.

Key words : Bridge Damage Detection, Deep Learning, Optimal Sensor Locations, Disaster Prevention for Infrastructure

요 지

최근 노후화 시설물의 급증과 함께 노후시설물로 인한 재난이 자주 발생하고 있다. 노후시설물로 인한 재난의 방재대책으로 모니터링 시스템을 기반한 시설물 유지관리가 활용될 수 있다. 본 연구진은 선행연구를 통해 모니터링 시스템에서 활용할 수 있는 딥러닝 기반의 교량 손상 추정 기술 기반 유지관리 기술을 제안하였다. 하지만, 선행 연구를 통해 제안된 기술은 기술의 사용에 있어 고가의 가속도계가 다수 필요하므로 높은 비용이 든다는 문제가 존재하였다. 이를 해결하기 위해, 본 연구에서는 손상 추정에 있어 가속도계의 위치 및 개수를 줄여 교량 손상 추정의 활용성을 높이기 위한 연구를 수행하였다. 그 결과, 기존 교량 손상 추정의 효과적인 위한 최적의 가속도계 설치 위치를 제시할 수 있었다.

핵심용어 : 교량 손상 추정, 딥러닝, 최적 센서 위치, 시설물 방재

1. 서 론

노후화된 기반 시설물은 사용연수가 30년 이상된 시설물을 말한다(Lee, 2016). 국토교통부가 관리하는 시설물 통합 정보관리 시스템(Facility Management System, FMS)의 2019

년 기준 정보를 토대로 할 때, 20년이 지난 2039년에는 국내 모든 시설물 중 74%의 시설물이 건령 30년 이상의 노후시설물이 될 것으로 파악된다(MOLIT, 2019).

노후시설물의 증가로 인해 최근에는 2016년 정릉천 고가 텐던 파단사고, 2018년 온수배관 파열 사고 등과 같은 시설물

*정회원, 인하대학교 건설환경시스템연구소 책임연구원(E-mail: kanghyeok0117@gmail.com)

Member, Senior Research Engineer, The Research Institute of Construction & Environmental System, Inha University

**성균관대학교 건설환경공학부 부교수(E-mail: ssim@skku.com)

Associate Professor, School of Civil, Architectural Engineering and Landscape Architecture, Sungkyunkwan University

***교신저자, 평생회원, 인하대학교 사회인프라공학과 교수(Tel: +82-32-860-7576, Fax: +82-32-873-7560, E-mail: dshin@inha.ac.kr)

Corresponding Author, Member, Professor, Department of Civil Engineering, Inha University

의 안전사고가 사회적 문제로 대두되고 있다. 특히 이러한 시설물은 그 규모가 크고, 여러 사용자들 수시로 사용한다는 특성을 가지고 있다. 노후화로 발생한 시설물 안전사고가 발생된다면 막대한 사회적, 경제적 피해를 입히는 재난이 수반될 가능성이 농후하다. 따라서, 시설물의 노후화로 발생할 수 있는 재난을 방지 및 조기에 재난을 예방할 수 있도록 적절히 유지관리 할 수 있는 방재 기술을 적극적으로 개발하고 활용할 필요가 있다.

국내에서는 시설물의 적절한 유지관리 수행을 위하여 “시설물 안전 및 유지관리에 관한 특별법(이하 시설물안전법)”을 제정하여 시행중이며, 시설물 안전법에서 규정하고 있는 1, 2, 3종 시설물에 대한 성능평가를 수행하도록 규정하고 있다(MOLIT, 2018). 하지만, 시설물안전법의 종합성능평가를 수행하기 위한 정밀안전진단의 경우, 4~6년의 긴 주기를 갖는다는 단점이 존재하므로, 시설물에 문제가 존재하더라도 이를 즉각적으로 조치하기는 쉽지 않다. 이러한 단점을 극복할 수 있는 방안으로 모니터링 기반의 시설물 유지관리 기술인 구조물 건전도 모니터링(Structural Health Monitoring, SHM)이 활용될 수 있다.

SHM 시스템은 시설물 거동을 실시간 계측 및 분석하여 시설물의 건전도를 파악하는 시스템을 말한다(Farrar and Worden, 2010). SHM 시스템을 활용하게 되면 안전진단 주기에 관계없이 시설물의 상태를 파악할 수 있으며, 시설물의 손상 추정에도 활용 가능하다(Lee et al., 2020). 이러한 시설물 손상 추정을 위한 다수의 연구들은 주로 교량을 손상 추정의 목적 시설물로 적용하여 수행되어 왔다(Casas and Moughty, 2017; Avci et al., 2021). 최근에는 딥러닝을 활용한 효율적이고 효과적인 교량 손상 추정 기술들이 개발되었으며, 본 연구진은 선행 연구(Lee et al., 2021)를 통하여 비지도학습 딥러닝 기반 교량 손상 추정 방법을 제시하였다.

한편, 선행 연구를 통해 개발된 손상 추정 기법을 활용하기 위해서는 교량 거동을 계측할 수 있는 다수의 가속도계의 설치가 필수적이다. 하지만, 교량의 손상 추정에 자주 사용되는 가속도계의 경우 가격이 비싸다는 단점이 있으므로, 개발 기술의 실용성이 떨어진다. 따라서, 선행연구를 통해 개발된 기술의 실용성을 높이기 위하여, 본 연구에서는 적은 수의 가속도계를 활용하여 높은 손상 추정 정확도를 낼 수 있는 가속도계의 설치 개수 및 위치를 찾고자 하였다.

2. 선행연구조사

교량의 손상 추정은 교량이 비손상상태, 손상상태 일 때 각각의 교량 상태의 거동에서 나타나는 차이를 분석하여 수행된다. 하지만 텐던의 파단과 같이 교량 안전에 비교적 큰 영향을 줄 수 있는 손상이 존재하더라도 그 손상으로 인한 교량 거동 변화는 계측데이터에 크게 나타나지 않는다는 한계가 있다(Lee et al., 2019). 따라서, 일반적으로 교량

손상 추정에서는 교량 거동 데이터 자체로는 잘 파악되지 않는 교량의 상태 변화를 간접적으로 보여줄 수 있는 Damage Sensitive Feature (DSF)를 이용하게 된다(Catbas et al., 2008). DSF의 도출에 있어서는 통계분석기법 및 신호처리기법 등이 자주 활용되었다(Lee et al., 2021).

자주 활용되는 기술들로는, 통계분석을 통해 얻은 마할라노비스 거리(Mahalanobis Squared Distance)를 활용한 방법(Worden et al., 2000; Sohn et al., 2001)이 존재하며, 주성분 분석의 주성분(Principal Component)를 활용한 방법(Manson, 2002; Wah et al., 2017) 등이 존재하며, 신호처리 기술을 통해 얻을 수 있는 웨이블릿 변환(Wavelet Transform)을 통해 얻은 웨이블릿 계수를 활용한 방법(Hou et al., 2000; Khatam et al., 2007) 등이 존재한다.

특히, Casas and Moughty (2017)에 따르면, 어떤 DSF를 사용하는지에 따라 손상 추정의 성능은 큰 영향을 받을 수 있다. 최근에는 딥러닝을 통해 얻은 DSF를 사용할 때 좋은 성능을 보임을 확인할 수 있었다(Avci et al., 2021). 대표적인 딥러닝 기반의 손상 추정 연구들의 연구 결과에 따르면, 딥러닝 네트워크 중 하나인 Convolution Neural Network (CNN)을 이용해 얻은 DSF를 활용할 때 좋은 손상 추정 성능을 나타냄을 확인할 수 있었다(Abdeljaber et al., 2017; Lin et al., 2017; Lee et al., 2020).

하지만 CNN 아키텍처를 통해 설계된 딥러닝 모델의 학습은 지도학습을 기반해 수행된다. 지도학습을 활용한다면, 교량의 거동데이터 뿐 아니라, 교량의 손상을 의미하는 라벨 데이터를 필수적으로 확보해야만 한다. 하지만, 이러한 라벨 데이터를 얻어내는 것은 사실상 불가능하여 지도학습 딥러닝 기반 교량 손상 추정 기법은 실제 현장에서 사용성이 크게 떨어진다는 한계가 있다. 본 연구진은 이러한 한계점을 개선하기 위하여 선행연구(Lee et al., 2019; Lee et al., 2021)를 통해 비지도학습을 이용하여 계측데이터로만 교량의 손상을 추정할 수 있는 기술을 개발하였으며, 시뮬레이션 교량 및 실제 교량의 적용을 통해 비지도학습 딥러닝 기반 교량 손상 추정이 가능함을 보였다.

한편, 본 연구진의 선행 연구에서는 교량의 동적 거동을 얻어내기 위해서, 9개의 가속도계를 이용하였다. 하지만 교량의 가속도를 측정하기 위한 가속도계는 그 가격이 상당히 하므로 수많은 노후교량에 적용하기에는 실용성이 떨어질 수 있다는 한계가 존재한다. 따라서, 효율적인 비지도학습 기반 교량 손상 추정을 위해 활용되는 가속도계의 숫자를 줄일 수 있는 방안을 찾아낼 필요가 있다. 본 연구에서는 가속도계를 줄일 수 있는 방안을 찾는 것을 본 연구의 목적으로 설정하였다.

3. 비지도학습 딥러닝 기반 교량 손상 추정

본 연구는 본 연구진의 선행연구인 Lee et al. (2021)에서

사용된 데이터 및 개발된 손상 추정 기술을 기반한다. 선행연구를 통하여 개발한 손상 추정 기술은 Fig. 1에 나타난 흐름도를 따라 수행되었다. 먼저 교량에 계측기를 설치하고, 비손상상태의 교량에서 데이터를 수집한다. 수집된 데이터는 딥러닝 모델의 학습에 적절한 형태로 전처리(Preprocessing)된다. 전처리가 된 데이터는 비지도학습 딥러닝 네트워크인 Convolutional Autoencoder (CAE) 모델 학습에 활용된다. 학습된 CAE 모델에 학습 시 활용되지 않았던 손상상태의 데이터가 출현하면 CAE 모델은 이를 감지해내며, 손상상태로 추정한다.

이러한 프레임워크 중 가장 중요한 요소는 CAE 모델의 학습이다. Fig. 2에서 볼 수 있듯이, 일반적으로 CAE 모델은 입력데이터를 정확하게 복원하는 형태로 학습되게 된다. 이 때 학습이 잘 되었는지는 입력데이터가 잘 복원되었는지를 통해 확인할 수 있으며, 복원 상태는 딥러닝 모델의 손실값(Loss)을 통해 판단할 수 있다. 선행연구에서는 Mean Squared Error를 손실값으로 활용하였으며, 0에 가까울수록 복원이 잘 되었다고 판정된다.

즉, 학습된 CAE 모델의 입력데이터로 학습에 활용되지 않았던 형태의 데이터(손상상태에 계측된 데이터)가 출현하

게 되면 데이터 복원에 어려움을 겪게 되며, 이는 손실값의 증대로 나타난다. 따라서, 이를 통해 교량의 손상과 비손상을 추정해낼 수 있다.

기존 선행연구에서는, 실제 교량의 손상을 추정하는 것을 목적으로 하였다. 이를 위해, 실증 교량의 손상을 인위적으로 발생시켰다. 손상을 발생시키기 위해서, 기존 교량 슬래브에 보강되어있던 길이 15 m, 폭 1 m, 두께 약 1 cm를 가지는 FRP판 2곳을 제거하였다. 실증 교량의 손상상태 및 비손상상태에 각각 데이터를 계측하였으며, 해당 데이터를 바탕으로 수행된 선행 연구의 결과, 최대 97.5%의 손상 추정 정확도를 보였으며 실제 교량의 손상을 추정하는 것이 가능함을 확인할 수 있었다.

4. 딥러닝 기반 교량 손상 추정을 위한 가속도 센서 설치 최적 위치 및 개수 도출

본 연구진의 선행연구(Lee et al., 2021)에서는 Fig. 3(a)과 같이 9개 가속도계를 설치하고 데이터를 얻어내었다. 한편, 고가의 가속도계를 다수 이용하는 것은 손상 추정 기술의

Fig. 1. CAE-based Damage Detection Process

Fig. 2. CAE Architecture for Damage Detection Designed by Previous Study (Lee et al., 2020)

Fig. 3. Accelerometers Installation Location Candidates

실제적 활용도를 떨어뜨릴 우려가 있다. 따라서, 본 연구에서는 CAE 기반 손상 추정 기술의 보편적 활용을 위한 최적의 가속도계 설치 위치 및 최소 필요 가속도계 설치 개수를 찾아내고자 하였다.

4.1 센서 설치 위치 및 개수 후보군 선정

교량의 가속도 거동 계측을 위하여 교량에 설치가능한 모든 위치를 설치해보고 이를 검증하는 것이 가장 최적의 센서 설치 위치 및 개수를 결정하는 방법이다. 하지만, 교량에 설치될 수 있는 가속도계의 위치는 무한대에 가까우므로, 이를 모두 테스트 하는 데는 한계가 존재한다. 따라서, 본 연구진의 선행연구에서는 일반적으로 PSC-I 교량의 동적 거동을 계측하기 위해 설치되는 Fig. 3(a)의 가속도계 설치 위치(후보군 A)에 설치하여 활용하였다. 본 연구에서는 이러한 후보군 A를 기준으로 가속도계 설치 위치 및 개수를 최적화하고자 하였다.

교량에서 가속도 데이터를 계측하는 가장 큰 이유는 교량의 동적특성을 파악하기 위함이다. 교량의 동적특성을 잘 파악하기 위해선, 교량 거동이 나타내는 질량 참여율을 활용할 수 있다. 일반적으로, 교량의 다양한 동적거동 중 가장 큰 질량참여율을 가지는 동적거동은 교량의 휨 거동이며, 이를 계측하기 위해 Fig. 3(b)와 같은 중방향 계측데이터의 확보를 수행한다. 본 연구에서는 이러한 계측위치를 후보군 B로 지정하였다.

또한, 다수의 교량 해석 데이터를 기반 할 때, 비틀림 거동이 큰 질량참여율을 보이는 경우도 다수 존재한다. 따라서, Fig. 3(c)에서 보는 것과 같이, 교량의 비틀림 거동을 확인하기 위해 6곳의 센서 설치 및 계측 데이터 확보가 필요하다. 본 연구에서는 이와 같은 가속도계 설치 위치를 후보군 C로 지정하였다.

KISTEC (2012)의 안전점검 및 정밀안전진단 세부지침에 따르면, 교량의 상태평가 항목 중 하나로, 교량의 동적특성을

파악하는 것이 명시되어 있다. 이에 따라, 성능평가를 위해 사용되는 가속도계의 설치 위치 및 개수를 파악하고자 기존 PSC교량에 대한 정밀안전진단 보고서 12건을 조사하였다. 그 결과, 상태평가를 위해서는 Figs. 3(d)부터 3(f)까지에서 보는바와 같이 일반적으로 1-2개 가속도계를 중앙부 근처에 설치하는 것을 확인할 수 있었다. 따라서, 본 연구에서는 Figs. 3(d)부터 3(f)까지의 위치를 각각 후보군 D, E, F로 선정하였다. 이렇게 선정된 6개의 설치위치 후보군에 대하여 딥러닝 학습 및 검증 프로세스를 거쳐 손상 추정 성능 평가를 수행하였다.

4.2 후보군 별 CAE 모델 개발 및 학습

딥러닝 모델의 학습에서 가장 큰 단점은 Input layer에 입력되는 데이터의 형태가 미리 정해져 있어 다양한 형태의 입력데이터를 정해진 형태로 만들어 사용해야만 한다는 점이다. 따라서, 딥러닝에 활용하고자 하는 입력데이터의 형태 및 크기가 변화된다면, Input Layer의 노드 개수를 포함한 전반적인 CAE 아키텍처의 수정 및 보완이 필요하다.

앞서 선정된 가속도계 위치의 6개 후보군은 각 후보군별로 활용되는 가속도계의 위치 및 개수가 각기 다르므로 선행연구에서 사용되었던 손상 추정을 위한 CAE 아키텍처의 적절한 수정이 필수적이다. 따라서 본 연구에서는 9개 센서를 활용(후보군 A) 시, 사용되었던 선행연구의 CAE 아키텍처를 기본으로 하고 나머지 후보군의 가속도계 위치 및 개수의 특성에 맞게 CAE 아키텍처를 수정하여 5개의 새로운 CAE 아키텍처를 개발하였다. 개발된 아키텍처는 Table 1에 나타난 바와 같다.

선행연구에서 사용되었던 CAE 아키텍처는 가속도계의 설치 위치에 연관되어 설계되었다. 따라서, 새로 개발된 5개의 아키텍처 모두 공통된 순서로 공통된 숫자의 Layer들을 적용하였다. 각 아키텍처에서 나타나는 레이어별 노드의 크기 차이는 Table 2에서 나타난 바와 같다. 첫 번째 나타나는

Convolutional Layer #1 (Conv#1)는 행렬형태로 구성된 입력 데이터의 종방향으로 나타나는 데이터의 시간 길이를 1/10로 줄이며, 동시에 횡방향으로는 같은 거더 위치에서 계측된 데이터들을 합성시키도록 설계되었다. 이후, Conv#2, 3은 필터의 깊이를 늘리도록 설계되어 이전 레이어에서 생성된 특징값들을 더 많은 특징값으로 변화시키도록 한다. 두 개의 Pooling Layer #1, 2 (Pool#1, 2)는 순차적으로 이전 레이어에서 도출된 특징값을 횡방향 및 종방향으로 통합되도록 설계되었으며, Max Pooling을 활용하였다. 또한, 디코더의 복원 능력을 일정하게 통일시키기 위하여 잠재변수와 입력데이터 노드 수 비율을 20대 1로 유지되도록 인코더의 아키텍처를 설계하였다. 디코더 아키텍처의 Deconvolutional Layer 및 Unpooling Layer들은 인코더의 아키텍처와 정반대로 설계되도록 하였다. 학습에 사용된 하이퍼파라미터는 Lee et al. (2021)에서 사용한 것과 동일하다.

4.3 학습된 각 후보군별 CAE 모델 검증 결과

본 연구의 손상 추정 모델은 각각의 후보군 위치에서 얻어진 데이터를 고려해 Table 1에 나타난 것과 같은 6개의

아키텍처를 후보군별로 각각 구성하고 이용하고자 하였다. 한편, 비지도학습 딥러닝의 특성상, 실제 교량의 손상 추정에서는 가장 좋은 성능을 발휘할 수 있는 하이퍼파라미터의 조합을 찾아내는 Fine-Tuning 과정을 거칠 수 없다는 한계가 존재한다. 따라서 본 연구에서는 각 아키텍처 별로, 60개의 다양한 하이퍼파라미터 조합을 사용하는 60개의 딥러닝 모델을 각 후보군별로 학습 및 검증하였다. Table 2는 각 후보군별 60개 모델의 검증 결과의 평균값을 나타내고 있다.

본 연구진의 선행연구(Lee et al., 2021)에서 확인할 수 있듯이, 후보군 A의 정확도는 손상 추정에 있어 충분히 만족할 수 있는 수준으로 판단되었다. 따라서, 본 연구에서 선정된 각 후보군들에 따른 딥러닝 모델 정확도의 비교는 비교 기준인 후보군 A와 유사한 수준을 확보할 수 있는지도 하나의 중요한 척도로 활용되었다.

Table 2에서 볼 수 있듯이, 모든 결과에서 95% 이상의 결과를 보인 후보군은 B와 E임을 확인되었으므로 후보군 B, E의 위치가 CAE 기반 손상 추정에 있어 가장 효율적인 위치로 판단되었다.

이러한 결과는 Fig. 4를 통해 도식적으로 확인할 수 있다.

Table 1. Matrix Sizes ($H \times W \times C$) of CAE Architecture for Accelerometers Installation Location Candidates

Layer	Candidate A (Lee et al., 2021)	Candidate B	Candidate C	Candidate D	Candidate E	Candidate F
Input	$9 \times 2,400 \times 1$	$3 \times 2,400 \times 1$	$6 \times 2,400 \times 1$	$2 \times 2,400 \times 1$	$2 \times 2,400 \times 1$	$1 \times 2,400 \times 1$
Conv#1	$3 \times 240 \times 128$	$1 \times 240 \times 128$	$2 \times 240 \times 128$	$2 \times 240 \times 128$	$1 \times 240 \times 128$	$1 \times 240 \times 128$
Conv#2	$3 \times 240 \times 256$	$1 \times 240 \times 256$	$2 \times 240 \times 256$	$2 \times 240 \times 256$	$1 \times 240 \times 256$	$1 \times 240 \times 256$
Pool#1	$3 \times 48 \times 256$	$1 \times 48 \times 256$	$2 \times 48 \times 256$	$2 \times 48 \times 256$	$1 \times 48 \times 256$	$1 \times 48 \times 256$
Conv#3	$3 \times 48 \times 256$	$1 \times 48 \times 256$	$2 \times 48 \times 256$	$2 \times 48 \times 256$	$1 \times 48 \times 256$	$1 \times 48 \times 256$
Pool#2	$1 \times 24 \times 256$	$1 \times 24 \times 256$	$1 \times 24 \times 256$	$1 \times 24 \times 256$	$1 \times 24 \times 256$	$1 \times 24 \times 256$
FC#1	6,144	6,144	6,144	6,144	6,144	6,144
Latent Variable	1,080	360	720	240	240	120
FC#2	6,144	6,144	6,144	6,144	6,144	6,144
Unpool#1	$1 \times 24 \times 256$	$1 \times 24 \times 256$	$1 \times 24 \times 256$	$1 \times 24 \times 256$	$1 \times 24 \times 256$	$1 \times 24 \times 256$
Deconv#1	$3 \times 48 \times 256$	$1 \times 48 \times 256$	$2 \times 48 \times 256$	$2 \times 48 \times 256$	$1 \times 48 \times 256$	$1 \times 48 \times 256$
Unpool#2	$3 \times 48 \times 256$	$1 \times 48 \times 256$	$2 \times 48 \times 256$	$2 \times 48 \times 256$	$1 \times 48 \times 256$	$1 \times 48 \times 256$
Deconv#2	$3 \times 240 \times 256$	$1 \times 240 \times 256$	$2 \times 240 \times 256$	$2 \times 240 \times 256$	$1 \times 240 \times 256$	$1 \times 240 \times 256$
Deconv#3	$3 \times 240 \times 128$	$1 \times 240 \times 128$	$2 \times 240 \times 128$	$2 \times 240 \times 128$	$1 \times 240 \times 128$	$1 \times 240 \times 128$
Output	$9 \times 2,400 \times 1$	$3 \times 2,400 \times 1$	$6 \times 2,400 \times 1$	$2 \times 2,400 \times 1$	$2 \times 2,400 \times 1$	$1 \times 2,400 \times 1$

Table 2. Accuracies of CAE Models with 95th and 99th Percentile Threshold

Threshold	Average Accuracy of Each Candidate					
	A (Lee et al., 2021)	B	C	D	E	F
95th	97.50%	95.20%	96.00%	57.50%	97.50%	50.50%
99th	94.20%	96.40%	83.20%	53.10%	99.50%	49.70%

(a) Candidate A (Lee et al., 2021)

(d) Candidate D

(b) Candidate B

(e) Candidate E

(c) Candidate C

(f) Candidate F

Fig. 4. Histograms of CAE Losses for Accelerometers Installation Candidates

Fig. 4에서 파란색으로 표현된 히스토그램은 비손상상태의 CAE 손실값을 나타내며, 초록색 히스토그램은 손상상태의 CAE 손실값을 보이고 있다. 파란색 점선은 95th percentile 임계값, 붉은색 점선은 99th percentile 임계값을 나타낸다. Fig. 4에서 볼 수 있듯이, 후보군 B, E의 경우, 기준이 된 후보군 A와 동일하게 두 가지의 임계값이 모두 교량의 두 가지 상태(손상 및 비손상상태)를 명확하게 구분할 수 있음을 확인할 수 있다.

한편, 후보군 A, B, E의 정확도를 비교해보면, 가속도계의 개수가 적어지는 E로 갈수록 정확도가 오히려 높아진 것이 확인되었다. 하지만 이는 가속도계 위치 변화 인한 영향으로

해석되기 보단, 60개 하이퍼파라미터 조합 중, 제대로 모델을 학습시키지 못하는 몇몇 하이퍼파라미터 조합이 존재하기 때문인 것으로 확인되었다. 따라서, Table 2에서 나타낸 정확도 수치는 기준이 되는 후보군 A와 비교했을 때 비슷한 수준을 보이고 있는지를 가장 주목해서 확인할 필요가 있다.

후보군 C의 경우, 95th percentile 임계값을 활용할 때는 좋은 결과를 보였으나, 99th percentile 임계값을 활용할 때는 상대적으로 좋지 않은 결과를 보임을 확인할 수 있다. 따라서, 후보군 C의 위치에 계측기를 설치할 경우 이를 주의하여 활용할 필요가 있다. 한편, 후보군 D, F의 경우 50% 이하의 정확도를 보이고 있으므로, 후보군 D와 F의 위치에서는

CAE 기반의 손상 추정치가 불가할 것으로 판단된다. 이러한 결과는 Figs. 4(d)와 4(f)의 CAE 손실값 히스토그램을 통해 다시 한 번 확인할 수 있다.

한편, 실증실험에 사용되었던 PSC 교량들의 경우에도 가장 큰 거동을 차지하는 1차 휨거동이 지배적인 것으로 분석되었다. 이러한 분석결과와 일맥상통하게 후보군 B, E의 가속도계 위치는 공통적으로 교량의 휨 거동을 잘 예측할 수 있다. 이러한 결과를 종합할 때, 만약 문제가 없다면 9개 가속도계를 설치하고 데이터를 예측하여 후보군 A, B, E의 모델을 개발하여 여러 모델을 함께 활용하는 것이 손상 추정의 신뢰성을 높일 수 있는 가장 바람직한 방법으로 판단된다. 하지만, 그렇지 못한 경우에는 최소한 후보군 E의 위치에 가속도계를 설치하여 데이터를 예측하고, 이를 CAE 모델 학습에 활용해야 한다.

5. 결 론

본 연구에서는 본 연구진의 선행연구를 통해 개발된 딥러닝 기반 교량 손상 추정 기술을 개선하는데 목적을 두었다. 기존의 딥러닝 기반 교량 손상 추정 기술은 그 사용에 있어 많은 숫자의 가속도계를 필요로 하였다. 한편, 많은 수의 가속도계를 운영하는 것은 높은 비용을 수반하게 된다는 단점이 존재하였다. 따라서, 본 연구에서는 적은 수의 가속도계로도 교량 손상 추정이 가능케 하는 가장 최적의 가속도계 위치 및 개수를 제시하고자 하였다.

본 연구에서는 PSC-I교 형식을 가진 교량에 9개의 가속도 센서를 설치하였던 선행연구의 실험 결과를 기본 대상으로 선정하여 센서 개수 및 위치를 최적화할 수 있는 방안을 제시하였다. 선정된 후보군을 통해 얻어진 데이터들은 비지도학습 딥러닝 모델을 학습시키는데 이용되었으며, 각 설치 위치에 따른 딥러닝 모델의 손상 추정 정확도를 비교 분석하여 최적의 설치 위치를 도출하고자 하였다.

이를 위해, 선정된 가속도계의 설치 위치 후보군은 기존 9개의 위치를 포함, 교량의 휨 거동(후보군 B), 비틀림 거동(후보군 C), 기존 정밀안전진단의 활용 위치(후보군 D, E, F)로 6개의 비교 대상을 선정하였다. 이후, 선정된 6개의 후보군에 알맞게 활용할 수 있도록 선행연구에서 제시하였던 비지도학습 딥러닝 CAE 모델 아키텍처를 수정하여 모델 검증에 활용하였다. 6개의 모델을 학습하고 검증한 결과, 휨 거동을 잘 예측할 수 있는 위치인 후보군 B와 후보군 E의 위치가 9개의 가속도계(후보군 A)를 사용할 때만큼 좋은 성능을 발휘하고 있음을 확인할 수 있었다.

이러한 결과를 바탕으로 볼 때, 교량의 방재를 위한 모니터링 시스템을 구축한다면, 예측기의 위치를 교량의 휨 거동을 잘 예측할 수 있는 위치로 선정해 손상 추정 기술을 운용해야 할 것으로 판단된다. 한편, 본 연구의 결과는 하나의 교량에만 적용되어 나타난 결과이므로, 다른 형식, 경간 길이 등을

가진 여러 교량에도 적용시키는 향후 연구의 수행이 필요하다고 판단된다. 이러한 관점에서, 본 연구 및 선행연구에서 개발한 교량 손상 추정 기술이 기초 기술로써 활용될 수 있을 것이라 판단된다. 더 나아가, 모니터링 기술을 활용한 교량 시설물 재난의 방재를 위한 기술로써도 응용되어 널리 활용될 수 있기를 기대한다.

감사의 글

본 연구는 국토교통부 건설기술연구개발사업의 연구비 지원(21SCIP-B128569-05)에 의해 수행되었습니다.

References

- Abdeljaber, O., Avci, O., Kiranyaz, S., Gabbouj, M., and Inman, D.J. (2017). Real-time vibration based structural damage detection using one-dimensional convolutional neural networks. *Journal of Sound and Vibration*, Vol. 388, pp. 154-170.
- Avci, O., Abdeljaber, O., Kiranyaz, S., Hussein, M., Gabbouj, M., and Inman, D.J. (2021). A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications. *Mechanical systems and signal processing*, Vol. 147, 107077.
- Casas, J.R., and Moughty, J.J. (2017). Bridge damage detection based on vibration data: Past and new developments. *Frontiers in Built Environment*, Vol. 3, 4.
- Catbas, F.N., Gul, M., and Burkett, J.L. (2008). Conceptual damage-sensitive features for structural health monitoring: Laboratory and field demonstrations. *Mechanical systems and signal processing*, Vol. 22, No. 7, pp. 1650-1669.
- Farrar, C.R., and Worden, K. (2010). *An introduction to structural health monitoring*. New Trends in Vibration Based Structural Health Monitoring, pp. 1-17.
- Hou, Z., Noori, M., and Amand, R.S. (2000). Wavelet-based approach for structural damage detection. *Journal of Engineering mechanics*, Vol. 126, No. 7, pp. 677-683.
- Khatam, H., Golareshani, A.A., Beheshti-Aval, S.B., and Noori, M. (2007). Harmonic class loading for damage identification in beams using wavelet analysis. *Structural Health Monitoring*, Vol. 6, No. 1, pp. 67-80.
- Korea Infrastructure Safety Corporation (KISTEC). (2012). *Guidelines for Safety Diagnosis*.
- Lee, K., Byun, N., and Shin, D. (2020). A damage localization

- approach for Rahmen bridge based on convolutional neural network. *KSCE Journal of Civil Engineering*, Vol. 24, No. 1, pp. 1-9.
- Lee, K., Jeong, S., Sim, S.H., and Shin, D. (2019). A novelty detection approach for tendons of prestressed concrete bridges based on a convolutional autoencoder and acceleration data. *Sensors*, Vol. 19, No. 7, pp. 1633.
- Lee, K., Jeong, S., Sim, S.H., and Shin, D. (2021). Field experiment on a PSC-I bridge for convolutional autoencoder-based damage detection. *Structural Health Monitoring*, Vol. 20, No. 4, pp. 1627-1643.
- Lee, S.K. (2016). The legislation for improvement and longevity of the aging urban infrastructure in Seoul. *Journal of the Korean Society of Civil Engineers*, Vol. 64, No. 11, pp. 11-21.
- Lin, Y.Z., Nie, Z.H., and Ma, H.W. (2017). Structural damage detection with automatic feature-extraction through deep learning. *Computer-Aided Civil and Infrastructure Engineering*, Vol. 32, No. 12, pp. 1025-1046.
- Manson, G. (2002). Identifying damage sensitive, environment insensitive features for damage detection. *Proceedings of the third international conference on identification in engineering systems*, pp. 187-197.
- Ministry of Land, Infrastructure and Transport (MOLIT). (2018). *Special Act on the Safety Control and Maintenance of Establishments*.
- Ministry of Land, Infrastructure and Transport (MOLIT). (2019). *Facility Management System*. Retrieved November 30, 2019, from <https://www.fms.or.kr/>
- Sohn, H., Farrar, C.R., Hunter, N.F., and Worden, K. (2001). Structural health monitoring using statistical pattern recognition techniques. *J. Dyn. Sys., Meas., Control*, Vol. 123, No. 4, pp. 706-711.
- Wah, W.S.L., Chen, Y.T., Roberts, G.W., and Elamin, A. (2017). Damage detection of structures subject to nonlinear effects of changing environmental conditions. *Procedia Engineering*, Vol. 188, pp. 248-255.
- Worden, K., Manson, G., and Fieller, N.R. (2000). Damage detection using outlier analysis. *Journal of sound and vibration*, Vol. 229, No. 3, pp. 647-667.

Received	■	August 25, 2021
Revised	■	August 26, 2021
Accepted	■	September 10, 2021