

Research Paper

건축물 안전등급 산출을 위한 외관 조사 상태 평가 데이터 기반 DNN 모델 구축 Development of a Building Safety Grade Calculation DNN Model based on Exterior Inspection Status Evaluation Data

이재민¹ · 김상용² · 김승호^{3*}

Lee, Jae-Min¹ · Kim, Sangyong² · Kim, Seungho^{3*}

¹Master's Course, Department of Architecture, Yeungnam University, 280 Daehak-ro, Gyeongsan-si, Gyeongsangbuk-do, 38541, Korea

²Professor, Department of Architecture, Yeungnam University, 280 Daehak-ro, Gyeongsan-si, Gyeongsangbuk-do, 38541, Korea

³Professor, Department of Architecture, Yeungnam University College, 170 Hyeonchung-ro, Nam-gu, Daegu, 42415, Korea

*Corresponding author

Kim, Seungho

Tel : 82-53-650-9487

E-mail : Kimseungho@ynu.ac.kr

Received : October 20, 2021

Revised : November 22, 2021

Accepted : November 22, 2021

ABSTRACT

As the number of deteriorated buildings increases, the importance of safety diagnosis and maintenance of buildings has been rising. Existing visual investigations and building safety diagnosis objectivity and reliability are poor due to their reliance on the subjective judgment of the examiner. Therefore, this study presented the limitations of the previously conducted appearance investigation and proposed 3D Point Cloud data to increase the accuracy of existing detailed inspection data. In addition, this study conducted a calculation of an objective building safety grade using a Deep-Neural Network(DNN) structure. The DNN structure is generated using the existing detailed inspection data and precise safety diagnosis data, and the safety grade is calculated after applying the state evaluation data obtained using a 3D Point Cloud model. This proposed process was applied to 10 deteriorated buildings through the case study, and achieved a time reduction of about 50% compared to a conventional manual safety diagnosis based on the same building area. Subsequently, in this study, the accuracy of the safety grade calculation process was verified by comparing the safety grade result value with the existing value, and a DNN with a high accuracy of about 90% was constructed. This is expected to improve economic feasibility in the future by increasing the reliability of calculated safety ratings of old buildings, saving money and time compared to existing technologies.

Keywords : safety grade, 3D point cloud, reverse engineering, deep-learning, deep-neural network

1. 서론

최근 노후 건축물 비율이 증가함에 따라 건축물 안전진단 및 유지보수 방안에 대한 중요성이 증가하고 있으며, 중장기적인 관리방안이 필요하다. 기존 상태평가 등급 산출을 위한 안전진단 프로세스는 육안조사를 기반으로 시행되며, 일반적으로 1인 또는 하나의 업체에 의해 다양한 검사가 수행되고 있다. 이는 점검자의 주관적인 판단이 개입되어 평가 결과가 상이하게 나타나는 문제가 발생하며, 정보의 신뢰성이 떨어질 우려가 있다[1]. 또한, Kwan and Ng[2]는 건물의 정기점검 및 상태 평가에 대한 문제점을 제시하였으며, 프로세스가 획일화되지 않아 재작업 시간이 많이 소요되어 결과적으로 비용적인 증가를 가져온다고 말하였다. Park and Kim[3]은 건축물 안전진단의 주체가 점점 공공주체에서 민간주체로의 넘어감에 따라 효율적이며 객관성을 가진 획일화된 안전진단의 연구가 필요하다고 언급하였다. 또한 민간업체 선정과정에 있어 최저가 입찰을 통해 진행되기 때문에 전문가 개개인의 수준 차이 및 관점의 차이에서 결과가 좌우되고 객관성이 떨어지는 문제가 발생



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

하기도 한다[1]. 따라서 작업 과정의 세분화를 통해 분석하고, 정형화된 방법 및 보고서 양식이 제시되어야 한다. 이처럼, 기존의 노후 건축물 상태 데이터 수집방법에는 객관성에 대한 한계를 지니고 있으며, 정형화된 프로세스가 제시되지 않고 있다는 것이 확인되었다[4].

노후 건축물 안전진단 프로세스의 문제점은 2가지로 구분할 수 있다. 첫 번째는 최저가 입찰을 통해 민간업체를 선정하며 1인 또는 하나의 업체가 건축물의 안전관리를 실시하는 것이다. 이는 수작업으로 정보를 수집하여 정략적인 표현이 어려우며, 개개인의 수준 및 관점에 따라 결과값이 다르게 도출될 수 있다. 결국 결과값의 신뢰성이 문제 될 우려가 있다. 두 번째는 외관 조사 및 안전진단 프로세스를 수행한 후 제출되는 보고서 양식이다. 외관 조사 및 안전진단 프로세스를 수행한 후 제출되는 보고서의 양식은 매번 다르다[4]. 이는 추후 수행 되어질 안전진단에서 기존의 데이터를 활용하지 못할 뿐더러 재작업 시간이 많이 소요된다. 또한 비용의 증가로 이어지며, 재 작업량이 많아짐에 따라 객관성이 떨어질 수 있다. 따라서 기존의 단점들을 해결하기 위해 객관성 및 정형화된 방안이 필요하다고 판단된다. 본 연구는 기존 외관 조사 방법 및 안전진단의 한계점을 해결하고자 고정밀 측정 기기를 사용한 외관 조사 데이터 수집 방법론을 제시하여 안전진단의 객관성 향상 방안을 도출하고자 한다. 또한 Deep-Learning을 사용하여 건축물의 안전성 및 상태평가등급을 종합적으로 분석하는 방법론을 통해 건축물의 안전등급 자동 산출 프로세스를 제시하고자 한다.

2. 기존 연구의 고찰

2.1 육안조사

육안조사를 통한 외관 조사는 전문가 또는 관찰자의 주관적인 성격이 포함될 수 있어 객관성을 가지고 있는 평가데이터가 되지 못할 우려가 있다[1]. Kwan and Ng[2]는 기존의 외관 조사 프로세스는 획일화 되지 않아 재작업 시간이 많이 소요되며, 데이터의 객관성이 떨어지고, 결과적으로 비용의 증가를 가져온다고 말하였다. 또한 Park et al.[5]는 전문가 개개인의 수준 차이 및 관점의 차이에서 외관 조사 결과가 좌우되어 객관성이 떨어진다고 말하였다. Liu et al.[6]은 기존의 안전진단이 매우 노동집약적이며, 시간이 많이 소요된다고 말하였다. Shi and Ergon[4]은 외관 조사 방법 및 관행을 작업 과정의 세분화를 통해 분석하고, 정형화된 외관 조사 방법 및 보고서 양식이 제시되어야 한다고 말하였다. 이처럼 기존의 외관조사 프로세스를 통해 취득된 데이터는 전문가의 지식수준의 차이, 관점의 차이에 따라 조사 결과가 좌우되어 객관성이 떨어진다. 이는 점검자의 주관적인 성격에 따라 외관조사 결과가 상이하게 나타나며 신뢰성이 떨어진다는 한계를 가지고 있다. 또한 전문가를 통한 외관조사는 매우 노동집약적이며, 정형화된 프로세스가 제시되지 않아 재작업량이 많아져 시간, 비용의 증가를 가져온다는 것을 확인하였다.

2.2 고정밀 측정 장비를 활용한 안전진단

최근 고정밀 기기의 발달에 따른 정확도 향상과 데이터 마이닝 기법의 고도화로 인해 Unmanned Aerial Vehicle(UAV)를 활용하여 건축물의 외관 조사를 실시한 후 건축물의 상태를 분석하는 연구가 증가하고 있다. Choi and Kim[7]은 이미지 프로세싱 기술과 UAV기술을 융합하여 균열 및 상태를 평가하는 연구를 진행하였다. Falorca and Lanzinha[8]는 UAV을 활용하여 건축물의 외관 조사를 실시하여 데이터 취득 후 External Thermal Insulation Composite System(ETICS) 보존 상태를 분석해 건축물의 성능 수준을 파악하고 유지 보수 방안을 제시하였다.

Laser Scanner로 취득된 3D Point Cloud와 스테레오 이미지는 지난 10년 동안 균열 감지 및 측정에 대해 연구되었으며, 2mm 크기의 미세한 균열을 측정 할 수 있는 것으로 입증되었다[9,10]. Law et al.[11]는 연구를 통해 Laser Scanner 기술이 건물의 외관조사 및 표면 노후화에 대해 매우 객관적이고 정밀한 데이터를 제공한다는 것을 확인하였다. 이러한 연구들을

바탕으로 Turkan et al.[12]는 취득한 3D Point Cloud 데이터를 분석하여 터널의 손상 부위를 검출하였으며, 교량, 댐과 같은 대형 구조물의 손상부위의 균열을 파악하는 연구들도 수행되었다[13]. 하지만 UAV, Laser Scanner로 취득된 3D Point Cloud 데이터를 이용한 기존 연구는 외관 조사에서 취득되는 여러 항목 중 하나의 항목인 균열에 국한되어 있다. 또한 자동 이 아닌 수동으로 이루어지기 때문에 전문가의 주관적 의견이 데이터에 포함될 가능성이 있으며, 제시된 프로세스는 건축물의 상태를 수동적으로 평가하기 때문에 다수의 건축물의 상태를 평가하기에는 시간, 비용적인 측면에서 효율성이 떨어진다. 또한 외관 조사 데이터만을 이용하여 상태등급을 판별하였기 때문에 건축물의 내구성, 안전성에 대한 평가는 배제되어 종합적인 안전 등급 산정에 어려움이 따르며, 기존 연구는 교량, 댐과 같은 비교적 단순한 형상정보를 가진 대형 구조물의 상태평가에 관한 연구가 이루어지고 있어 복잡한 형상정보를 가진 건축물에 관한 연구가 필요하다.

2.3 Machine-Learning을 활용한 안전진단

초기 연구들은 Artificial Neural Network(ANN)과 같은 비교적 간단한 신경망을 통해 연구가 이루어졌다. Silva et al.[14]은 통계학적인 관점인 선형 회귀분석과 ANN을 통해 건물의 내구성을 측정하고, 수학적 모델을 만들어 외관의 등급을 산출하고자 하였다. Sousa et al.[15]는 Support Vector Machine(SVM)과 ANN을 통해 구조물 상태를 예측하고, 결과값을 비교분석함으로써 SVM과 ANN에 대해 평가하여 각각의 장점을 제시하였다. 또한 El-Abbasy et al.[16]은 ANN을 통한 파이프라인의 상태를 예측하고자 하였고, 간단한 신경망의 경우 Deep-Neural Network(DNN), Convolutional Neural Network(CNN)과 같은 복잡한 신경망에 비해 정확성이 떨어진다는 문제를 제기하였다.

최근 컴퓨터 하드웨어의 발달을 통해 Deep-Learning 알고리즘의 종류 중 하나인 CNN, DNN을 활용한 균열 감지 연구가 수행되었다. Cha et al.[17]은 취득한 이미지 데이터를 수치화시켜 얻은 Input 데이터로 학습된 알고리즘 모델을 통해 균열 위치, 크기 정보를 파악하여 98%정도의 정확도를 얻을 수 있다는 것을 확인하였다. 하지만 기존의 연구는 균열이라는 하나의 항목에만 국한된 알고리즘 모델이기 때문에 전체적인 건물의 외관조사 항목에 적용시키기에는 어려움이 따른다. Kang and Cha[18]는 초음파 비콘, CNN, Geo-Tagging 방법을 통해 새로운 검사 시스템을 제안했으며, Global Positioning System(GPS) 신호가 구조 감지 및 위치 파악을 위해 폐쇄된 환경에서도 수행할 수 있다는 장점을 확인하였다. 또한 Gopalakrishnan et al.[19]은 UAV과 이미지 데이터, Deep-Learning을 활용한 자동화된 결함을 찾는 아웃라인을 제시하였다. Perez et al.[20]는 CNN Layer를 활용하여 균열의 위치정보를 파악하고, 표면 노후화의 정보를 파악하였으며, 학습된 데이터를 통해 Confusion Matrix를 만들어 데이터를 시각화하였다. 이처럼 기존의 연구들은 ANN, DNN과 같은 여러 형태의 Deep-Learning 구조 학습을 통해 건물, 교량, MEP 구성요소의 외관 손상, 위치 정보를 확인하여 Confusion Matrix를 통해 시각화하는 단계에 머물렀다. 이는 건물의 내구성 및 안전성에 대한 구조적 평가는 이루어지지 않고 배제되어 종합 등급을 산출하기에는 어려움이 따른다. 이에 본 연구는 UAV, Laser Scanner를 사용하여 외관 조사를 실시한 후 취득된 객관적이고 신뢰성 높은 상태평가 데이터를 취득하고자 한다. 또한 Deep-Learning을 활용하여 시간 및 비용적 측면의 효율성이 향상된 노후 건축물 안전 등급 자동 산출 프로세스를 제시하고자 한다.

3. Deep-Neural Network 기반 안전등급 예측 모델 구축 프로세스

3.1 Reverse Engineering 3D 모델을 통한 상태평가 데이터 취득

Reverse Engineering은 장치, 객체, 구조 등을 시스템적인 분석을 통해 기본적인 원리 기능 및 운영체계를 발견하는 프로세스이다[21]. 건축물의 3D Point Cloud가 가지고 있는 형상정보를 통한 외관조사 및 상태평가 등급 산출은 Reverse Engineering 기술이 필수적이다.

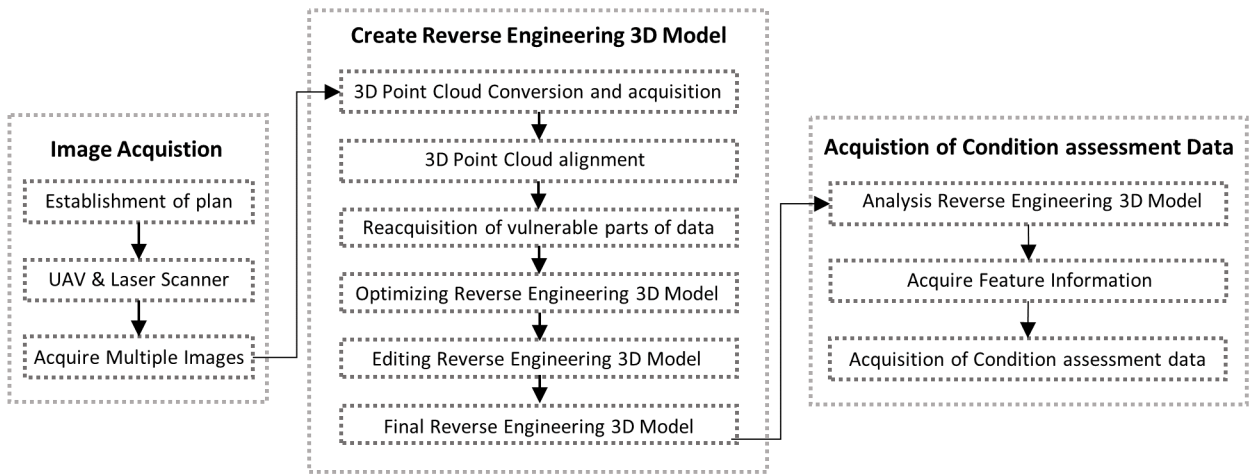


Figure 1. Obtaining Condition Assessment Data with Reverse Engineering 3D Model

Figure 1은 UAV, Laserscanner를 사용한 상태평가 데이터 취득 프로세스를 도식화 하고있다. 규모가 큰 건물의 경우 UAV의 촬영구간을 분할하여 중첩되는 부분을 가지도록 설정하여 정확성을 높일 필요가 있다. 또한 Laser Scanner의 경우 방사형으로 주사되기 때문에 외곽의 정보를 모두 스캔하기 위해서는 적어도 두 곳 이상의 지점에서 스캔하여야한다. 이후, 취득된 3D Point Cloud데이터는 Alignment 정합 프로세스, Optimizing, Editing과정을 통하여 최적화된 Reverse Engineering 3D Model을 생성하고자 한다. 결과적으로, 최적화 작업이 완료된 Reverse Engineering 3D Model을 통해 신뢰성 높은 상태 평가 데이터를 취득하고자한다. 하지만 Reverse Engineering 3D Model은 형상정보만을 포함하고 있어 물리적인 요소(강도, 중성화)의 데이터 취득이 어렵다. 따라서 본 연구에서는 물리적 요소가 포함되지 않은 7가지 항목(균열, 박리, 박락 및 층분리, 누수 및 백태, 철근노출, 기울기, 변위변형)의 데이터만을 취득하여 사용하고자 한다.

3.2 기존 상태평가 데이터 재배치 및 수정

기존의 외관 조사 데이터의 결과값은 부재, 층수에 대한 상태평가 값으로 이루어져 있어 외관 조사를 통한 평가항목별 데이터에 대한 상태평가 값을 알 수 없다. 이는 전체적인 건물의 상태만을 알 수 있으며, 어떠한 항목이 가장 심하게 노후화가 진행되는지, 우선적으로 진행되어야 할 보수·보강 순서를 알 수 없다. 따라서 본 연구에서는 앞서 제시한 9가지의 항목 중 형상정보를 통해 취득 가능한 7가지 항목으로 분류하여 데이터를 가공하고자 한다. 이때 평가항목 및 평가기준은 대한민국 시설안전공단[22]에서 제공하는 안전점검 및 정밀안전진단 세부지침 해설서를 활용하였다(Table 1).

Figure 2는 7가지 항목으로 분류하여 텍스트 데이터로 가공한 노후 건축물 안전진단 데이터이다. 가공된 등급별 데이터는 개수 차이에 의한 데이터 불균형이 발생할 우려가 있다. 또한, E등급의 건축물의 경우 구조적인 문제 때문에 사용이 불가하여 E등급에 대한 건축물의 데이터는 취득하기에 어려움이 따른다. 데이터의 불균형이 발생할 시 취득된 데이터 중 무작위로 선택되는 Training, Test, Validation 데이터에 따라 DNN 신경망의 학습 과정에서의 정확도가 떨어질 우려가 있으며, 결과값이 매번 상이하게 나올 수 있는 문제점이 있다. 따라서 본 연구에서는 제시된 문제점을 해결하고자 데이터 Over-Sampling 실시하였다. 본 연구의 데이터 Over-Sampling은 R 프로그램에서 지원하는 SMOTE 함수를 사용하여 실시하였다. 이는 각 데이터의 최근접 이웃을 이용하여 새로운 데이터를 생성하기 때문에 오차가 상대적으로 낮게 나타난다. 이와 같은 과정을 통해 A, B, C, D등급의 데이터를 각각 250개, 총 1000개의 데이터를 생성하였다.

Table 1. Status Assessment criteria

	Rating	Score	Criteria		
			Maximum crack width : cw	Area Ratio : 20% or less	Area Ratio : 20% or more
Cracks	a	1	$cw < 0.1$	a	a
	b	3	$0.1 \leq cw < 0.2$	b	c
	c	5	$0.2 \leq cw < 0.3$	c	d
	d	7	$0.3 \leq cw < 0.5$	d	e
	e	9	$0.5 \leq cw$	e	e
.....					
	Rating	Score	Criteria		
			Scaling depth : sc	Area Ratio : 10% or less	Area Ratio : 10% or more
Scaling	a	1	$sc = 0$	a	a
	b	3	$0 < sc < 0.5$	b	b
	c	5	$0.5 \leq sc < 1.0$	c	c
	d	7	$1.0 \leq sc < 25$	d	d
	e	9	$25 \leq sc$	e	e
.....					
	Rating	Score	Criteria		
			Spalling and delamination depth : sd	Area Ratio : 20% or less	Area Ratio : 20% or more
Spalling & Delamination	a	1	$sd = 0$	a	a
	b	3	$0 < sd < 15$	b	c
	c	5	$15 \leq sd < 20$	c	d
	d	7	$20 \leq sd < 25$	d	e
	e	9	$25 \leq sd$	e	e
.....					
	Rating	Score	Criteria		
			No water leak and efflorescence		
Water leak & Efflorescence	a	1	No water leak and efflorescence		
	b	3	If there is a trace of minor leakage in a dry state, or the area rate of whitening occurs is less than 5%		
	c	5	Significant signs of water leakage in wet conditions or less than 5% to 10% of white coating occurrence area		
	d	7	The progress of the leak is observable, or the area rate of whitening is less than 10-20%		
	e	9	The progress of leakage is evident, or the area rate of whitening occurs at least 20%		
.....					
	Rating	Score	Criteria		
			$ra = 0$		
Rebar exposure	a	1	$ra = 0$		
	b	3	$0 < ra < 1.0\%$		
	c	5	$1.0 \leq ra < 3.0$		
	d	7	$3.0 \leq ra < 5.0$		
	e	9	$5.0 \leq ra$		
.....					
	Rating	Score	Criteria		
			L(span length) / 480 or less		
Displacement & Deformation	a	1	L(span length) / 480 or less		
	b	3	L / 480 or less		
	c	5	L / 240 or less		
	d	7	L / 150 or less		
	e	9	L / 150 or more		
.....					
	Rating	Score	Criteria		
			Slope	Evaluation contents	
Slope	a	1	1/750 or less	Risk subsidence limits on sensitive mechanical foundations.	
	b	3	1/500 or less	Construction Crack Occurrence Limits	
	c	5	1/250 or less	Detect the slope of a structure	
	d	7	1/150 or less	Limits to which structural damage is expected	
	e	9	1/150 or more	To the extent that the structure is dangerous	

3.3 Deep-Neural Network 데이터 분석

기존 대다수의 상태평가 데이터는 Excel, PDF 형식의 텍스트 데이터 형식으로 저장되어 있다. 따라서 본 연구에서는 이미지를 기반으로 하는 CNN이 아닌 텍스트 데이터를 기반으로 하는 DNN 신경망을 사용하여 데이터를 학습하고자 한다. DNN은 Matlab에서 제공하는 nntool이라는 Deep Learning toolbox를 사용하여 생성하였다. 이를 통해 생성된 DNN을 학습

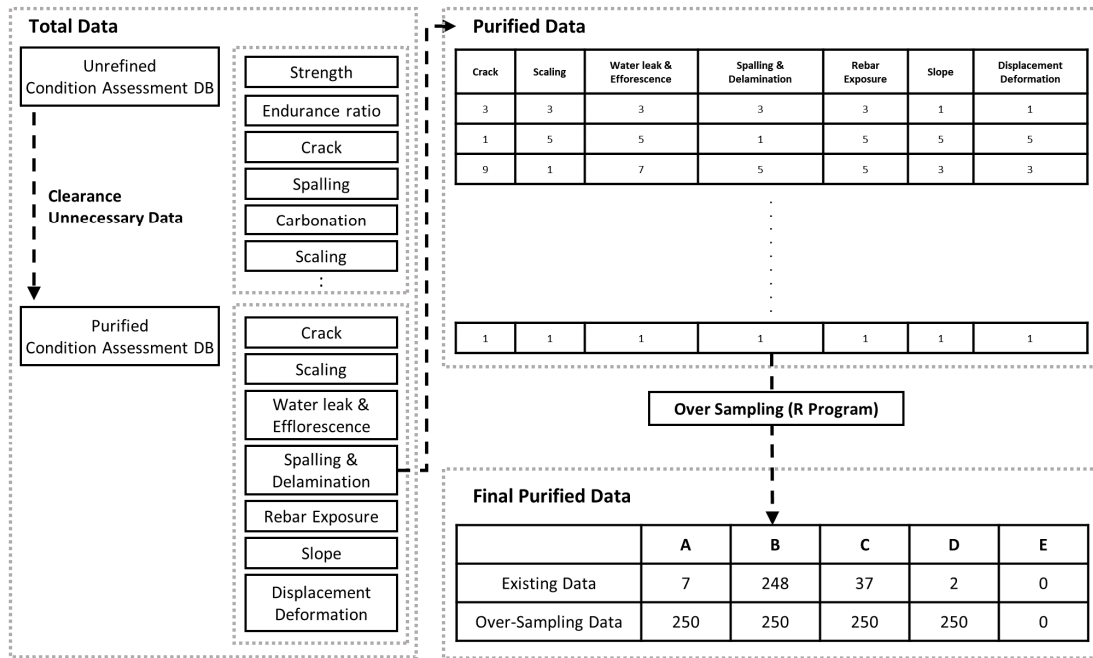


Figure 2. Classified Condition Assessment Results

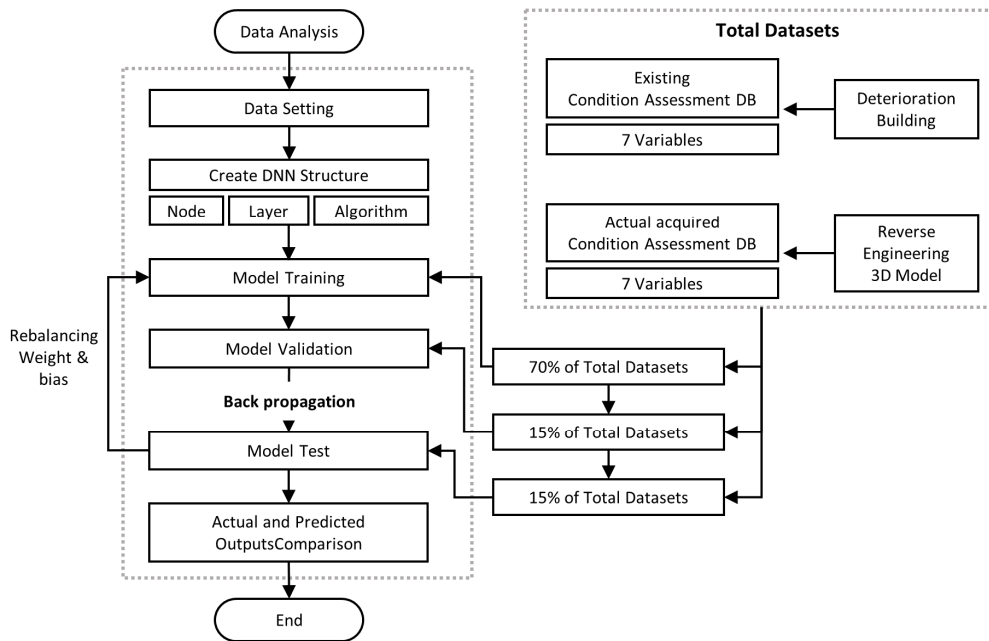


Figure 3. DNN Data analysis process

시킨 후 그에 따른 결과값은 Output Data 공간에 생성하여 최종적인 결과값을 도출할 수 있다. 본 연구의 Deep-Learning 데이터 분석의 순서는 다음과 같다(Figure 3).

Matlab에서 데이터를 사용하기 위해서는 Input Layer와 Target Layer에 사용 되어질 변수값을 생성 하여야한다. Input Layer에 사용될 변수는 입력값인 Input data, Output data, 학습된 모델을 검증하기 위한 Target data가 있다. 각각의 변수는 데이터를 가지고 있어야 하며 이러한 데이터를 입력하는 과정을 데이터 Setting이라고 한다. Setting이 완료된 Input data,

Output data, Target data 변수를 nntool의 Neural Network/Data Manager를 통해 데이터를 적절한 Layer로 Import 해주어야 한다. Import가 완료된 데이터는 필요한 Network Type, Hidden Layer의 개수, 각각의 Layer에 대한 node의 개수, 학습을 수행하기 위한 알고리즘을 학습하고자 하는 데이터 값에 따라 선택하고, 필요한 DNN 구조를 생성한다. 각각의 Hidden Layer는 학습에 필요로 하는 노드를 첫 Layer에 설정해놓은 노드의 수에 따라 자동적으로 산출이 된다. DNN 신경망은 가중치인 Weight(w) 값과 편향치인 Bias(b)의 값을 통해서 학습이 되며 Feed-Forward 알고리즘을 통해 초기 데이터 학습을 실시한다. 이후 Back Propagation 알고리즘을 통해 검증한 후 w의 값을 재조정하여 정확도가 높은 학습을 수행할 수 있는 DNN을 생성하게 된다. 학습은 Training data, Validation data, Test data가 70:15:15의 비율로 나누어져 들어가 자동적으로 학습, 검증 과정을 거친 후 테스트를 함으로써 데이터의 정확도를 판별한다. 최적화 학습이 완료된 DNN 구조는 Simulate 기능을 통해 Target data의 결과값을 도출하고자 하며, 도출된 데이터의 결과값을 실제값과 비교하여 본 연구에서 제시하고 있는 DNN의 정확도 및 신뢰도를 검증하고자 한다.

4. CaseStudy

4.1 노후건축물 선정 및 상태평가 데이터 취득

본 연구의 Case Study 대상 건축물은 30년 이상 된 노후 건축물 10개를 대상으로 수행되었다. 각각의 건축물의 데이터 취득 방식은 3.1절에서 언급한 방법을 토대로 진행되었으며, 하나의 건축물에 대한 상태평가 데이터 취득 방법에 대하여 나타내었다(Figure 4). 대상 건축물은 지상 3층으로 구성된 노후 건축물로 Laser Scanner를 통해 외부 및 내부의 데이터, UAV를 이용하여 고층부의 데이터를 취득하였다. 총 촬영 횟수는 Laser Scanner 50회, UAV 231회이며, 총 촬영 시간은 2시간 50분이 소요되었다. 3D Point Cloud 정합 시간은 2시간 10분, Reverse Engineering 3D Modeling은 1시간이 소요되었다. 또한 이를 토대로 상태평가 데이터 취득에 소요된 시간은 3시간 10분으로 대상 건축물에 대하여 본 연구에서 제시한 프로세스는 총 9시간이 소요되었다. 최종적으로 동일 면적 건축물 안전진단 시간 대비 50%가 감소하여 시간 및 비용적 측면에서 생산성이 높은 것으로 확인되었다. 본 연구에서 제안하는 프로세스를 통해 취득한 데이터는 다음과 같다.

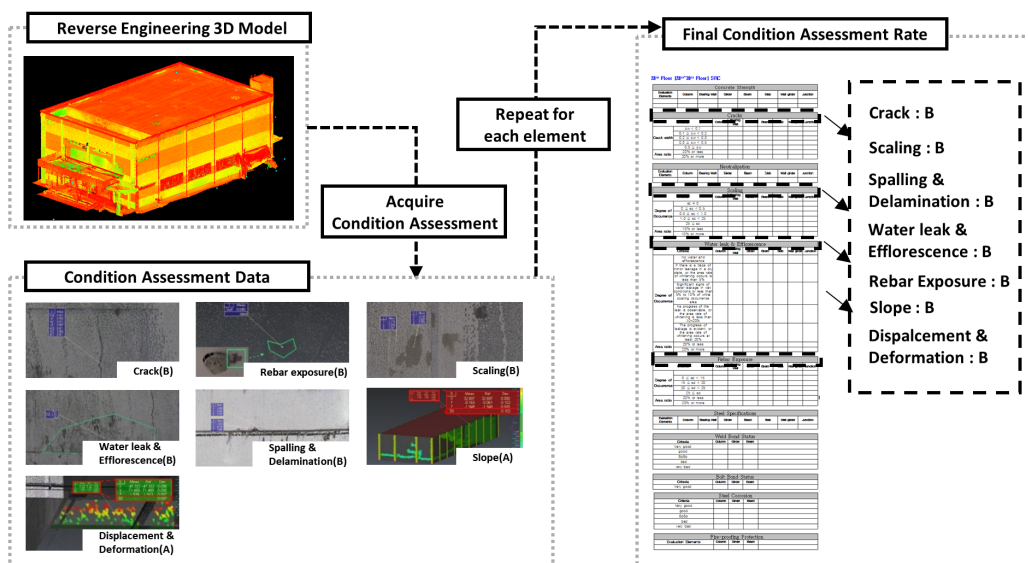


Figure 4. Reverse Engineering 3D Model-based Condition Assessment Data acquisition process

4.1.1 균열

Reverse Engineering 3D Model에서 발견되는 균열 중 하나에 대한 측정값으로 균열 폭에 대한 두 점 사이의 간격이 측정되어 평가 기준에 대입 후 결과값이 도출된다. 균열의 평균 균열 값은 0.101mm로 B등급 평가 기준인 $0.1\text{mm} \leq X < 0.2\text{mm}$ 에 속해있다. 따라서 해당 건물의 발생한 모든 균열 등급을 종합적으로 평가한 결과 균열에 대한 상태 등급은 B등급으로 확인되었다.

4.1.2 박리

박리된 부분과 정상적인 콘크리트의 점을 각각 지정하여 x, y, z축에 대한 값을 도출하여 값을 비교함으로써 박리에 대한 깊이 값이 도출되며, 면적률에 의해 최종적인 등급이 판별된다. 박리의 평균값은 0.22mm로 B등급 평가기준인 $0\text{mm} < sc < 0.5\text{mm}$ 에 해당된다. 또한 면적률 10%이하에 해당하게 되므로 최종적인 상태평가 등급은 B등급으로 확인되었다.

4.1.3 박락 및 층분리

콘크리트 벽체에서 박락된 부분의 Z축과, 정상적인 콘크리트 Z축을 비교함으로써 박락 깊이 값이 도출된다. 박락에 대한 평균 깊이는 5.3mm로 B등급 평가기준인 $0\text{mm} < sd < 15\text{mm}$ 에 해당된다. 또한 면적률 20%이하에 포함되므로 최종적인 상태평가등급은 B등급으로 확인되었다.

4.1.4 누수 및 백태

누수 및 백태는 건축물의 면적에 따라 상태등급이 판별된다. 면적 산정은 Polyline을 통해 면적의 경계선을 만들고 Mesh화하여 면적을 산정하며, 산정된 면적의 넓이가 누수 및 백태의 결과값이 된다. 누수 및 백태의 평균 면적은 0.824m^2 가 산출되었다. 따라서 B등급 평가 기준인 백태발생 면적률이 5% 미만에 포함되므로 최종적으로 B등급으로 확인되었다.

4.1.5 철근 노출

철근 노출은 건축물의 면적에 따라 상태등급이 판별되며 평균 철근 노출 면적은 0.0089m^2 이다. 이는 B등급 평가기준인 $0\% < ra < 1.0\%$ 에 해당하므로 최종적으로 B등급으로 확인되었다.

4.1.6 기울기

건축물의 기울기는 실제 2D 도면을 통한 BIM Model과 Reverse Engineering 기술로 만들어진 실제 건물의 3D Model의 비교를 통해 가장 많이 기울어진 부분의 각 변위를 통해 판별된다. 기울기는 0.0007587로 A등급 평가기준인 1/750미만의 범위에 포함되어 A등급으로 확인되었다.

4.1.7 변위 변형

2D 도면 기반 BIM Model과 Reverse Engineering 3D Model을 중첩시켜 보, 슬래브 각각의 구조물에 대한 변위 변형을 확인할 수 있다. 변위, 변형 값은 0.006mm이므로 A등급 평가기준인 $L(\text{경간 길이})/480$ 이하이다. 따라서 A등급으로 판별되며, 시각적으로 확인할 수 있어 직관적인 데이터의 분석이 가능하다.

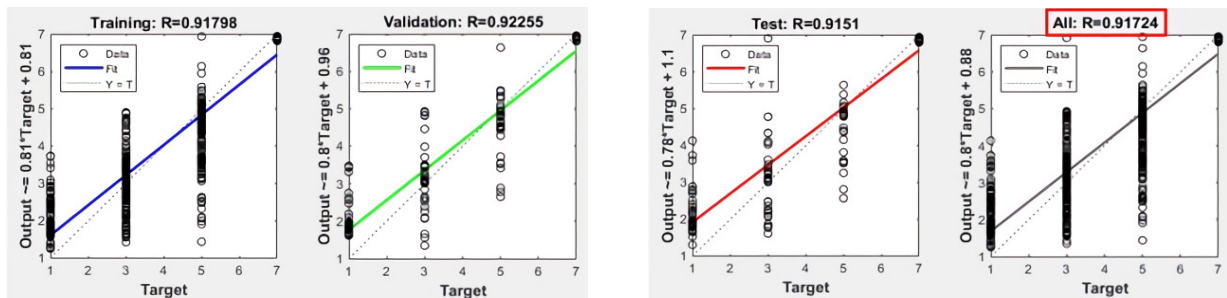
위와 동일한 프로세스를 통해 취득한 결과 대상 건축물 10개의 상태평가 데이터 값은 다음과 같다(Table 2).

Table 2. Acquired Condition Assessment Data

Building	No. 1	No. 2	No. 3	No. 4	No. 5	No. 6	No. 7	No. 8	No. 9	No. 10
Crack	5	3	3	5	9	3	5	7	9	9
Scaling	1	3	3	3	1	1	5	7	5	1
Spalling & Delamination	3	1	3	3	1	1	5	7	9	9
Water leak & Efflorescence	1	1	3	1	3	3	5	5	3	9
Rebar Exposure	3	1	3	3	3	1	5	7	3	9
Displacement Deformation	1	1	1	1	1	1	1	3	1	3
Slope	1	1	1	1	1	1	1	3	3	5

4.2 Deep-Neural Network 기반 데이터 학습

본 연구에서 제안하는 DNN 신경망은 Input Layer와 Output Layer, 그리고 3개의 Hidden Layer로 이루어져 있으며, 각 Layer의 노드의 개수는 변수의 개수보다 많이 생성될 경우 학습된 DNN 신경망에 Over-fitting을 유발할 수 있다. 따라서 3개의 Hidden Layer 중 첫 번째 Hidden Layer는 3개, 두 번째 Hidden Layer는 6개, 그리고 세 번째 Hidden Layer는 5개의 노드를 각각 가지고 있다. 생성된 DNN 신경망은 Training Data, Validation Data, Test Data는 랜덤으로 추출되어 총 1000번의 학습이 수행되어졌으며, 59번의 검증을 통해 최적화가 이루어져 학습이 수행되었다. 학습이 완료된 DNN 신경망의 선형 회귀 분석 그래프를 통해 Training Data, Validation Data, Test Data 그리고 종합적인 Data에 대한 정확도를 나타내고 있으며, 그래프를 통해 나타난 DNN 신경망의 정확도는 91.7% 정도로 나타내고 있다(Figure 5).

**Figure 5.** Learned DNN Learning Result

4.3 기존값과 결과값 비교 분석

기존의 육안조사 안전진단 프로세스를 통해 취득한 10개의 건축물의 안전등급 데이터와 본 연구에서 제안하고 있는 안전 등급 산출 프로세스와의 비교를 통해 정확성을 검증하고자 한다. 학습이 완료된 DNN 신경망 구조에 Case Study 대상 건축물의 상태평가 값인 Target Data를 적용시킨 후 종합평가 결과값을 도출하였다. 또한 결과값을 A, B, C, D등급으로 분류하여 기존값과의 비교분석을 통해 각 등급에 대한 정확도를 검증하였다(Table 3).

4.3.1 A등급

도출된 결과값과 기존값을 비교하게 되면 정확성이 떨어진 것처럼 보인다. 하지만 결과값을 A등급 기준에 따라 정수화시키게 되면 B, A등급이 나오므로써 50%정도의 결과값이 나오게 된다.

4.3.2 B등급

도출된 결과값을 B등급 기준에 따라 정수화 시키게 되면 B, B, B, B, B등급이 나오게 되며, 약 100%의 정확도를 가진다.

4.3.3 C등급

도출된 결과값을 C등급 기준에 따라 정수화 시키게 되면 C, C 등급이 나오게 되며, 100%의 정확도를 가진다.

4.3.4 D등급

결과값으로 도출된 값을 D등급 기준에 적용하여 등급값을 산출하게 되면 D, D등급이 도출된다. 따라서 100%의 정확도를 가지게 된다.

Table 3. Error in measurement Data and Actual Data

Building	No. 1	No. 2	No. 3	No. 4	No. 5	No. 6	No. 7	No. 8	No. 9	No. 10
Resulting Value	3.683	1.8241	2.6	2.1	4.6	2.6	4.16	4.47	6.89	6.94
Rating Value	B(3)	A(1)	B(3)	B(3)	C(5)	B(3)	C(5)	C(5)	D(7)	D(7)
Actual Value	A(1)	A(1)	B(3)	B(3)	B(3)	B(3)	C(5)	C(5)	D(7)	D(7)

위의 결과값을 종합적으로 보았을 때 약 90% 정도의 정확도를 가진 DNN 신경망이 생성되었다. A등급, B등급에서 오차가 발생한 이유는 DNN 신경망 구조가 보수적으로 학습되었으며, 기존값은 전문가의 개개인의 주관적인 판단을 통해 결과가 산출되었기 때문에 결과값에 대한 신뢰성이 떨어진다. 따라서 객관적인 데이터를 통해 산출된 결과값은 등급이 떨어지게 되며, 오차가 발생하였다고 볼 수 있다.

5. 결론

본 연구는 기존에 사용된 안전 진단 프로세스의 고찰을 통해 관찰자의 주관적 성격이 포함되어 객관성 및 신뢰성이 떨어진다는 한계를 확인하였으며, 외관조사만 데이터만을 사용한 안전진단은 건축물의 내구성, 안전성을 파악하기에 어려움이 있다. 따라서 본 연구에서는 고정밀 측정기기를 활용하여 객관적인 데이터를 취득하였으며, Reverse Engineering 3D Model을 통해 상태평가 데이터를 취득하였다. 이후 학습된 DNN 신경망에 Reverse Engineering 3D Model을 통해 취득한 상태 평가 데이터를 적용시킴으로써 종합평가를 도출하였으며, 도출된 결과값과 기존값의 비교를 통해 DNN 신경망의 정확성 검증을 수행하였다. 학습된 DNN 신경망의 정확성은 약 90%정도로 매우 높은 수준임을 알 수 있으며, 물리적인 데이터가 포함되지 않음에도 불구하고 본 연구에서 제안하는 노후 건축물 안전 등급 산출 프로세스를 통해 객관적이고 정확한 안전 등급을 산출이 가능하다는 것을 확인하였다.

하지만 본 연구에서 제안된 노후 건축물 안전 등급 산출 프로세스는 철근 콘크리트구조의 건물에 제한적으로 적용이 가능하다. 철골조, 조적조 건물에 적용하기 위해서는 새로운 변수를 생성하고 새로운 Deep-Learning 학습을 통해 적용 해야한다. 따라서 추후 연구에서는 철근 콘크리트구조, 철골조, 조적조와 같이 다양한 구조의 건축물의 평가를 일률적으로 할 수 있는 프로세스가 제시되어야한다. 또한 본 연구에서 제안된 노후 건축물 안전 등급 산출 프로세스는 Deep-Learning과 같은 일정부문에서만 자동화가 진행되었다. 이에 향후 자동화된 상태평가 데이터 산출과 같은 추가적인 요소들이 필요한 것으로 판단된다. 제시된 Deep-Learning과 3D Point Cloud 데이터의 연동을 통한 자동화된 건축물 종합 등급 산출 프로세스가 필요하다고 판단되며, 이는 신속한 상태평가 및 종합등급산출로 인해 객관성 향상과 비용, 시간을 절약할 것으로 예상된다.

요약

노후 건축물의 수가 증가함에 따라, 건물의 안전진단, 유지 보수에 대한 중요성이 증가하고 있다. 기존 외관 조사는 점검자의 주관적인 판단이 수반되어 평가 결과가 다르고 객관성과 신뢰성이 떨어진다. 따라서 본 연구는 기존 연구를 통해 기실시된 외관 조사 및 상태 평가 프로세스의 한계를 제시하였으며, UAV, Laser Scanner를 통해 3D Point Cloud 데이터를 수집하였다. 또한, Reverse Engineering 기술을 이용하여 3D 모델을 생성한 후 객관적인 상태평가 데이터를 취득하였다. 이후 기존의 정밀검사 데이터와 정밀 안전진단 데이터를 활용하여 DNN 구조를 생성하고, 고정밀도 측정 장치를 이용하여 얻은 상태평가 데이터를 적용하여 객관적인 건물안전등급을 산출하였다. 자동화된 프로세스는 20개의 노후된 건축물에 적용되며 동일 면적 건축물 기준 수작업으로 실시되는 안전진단의 시간에 비해 약 50% 감소하였다. 이후 본 연구에서는 안전등급 결과값과 기존값을 비교하여 안전등급 산출과정의 정확성을 검증하고 약 90%의 높은 정확도를 가진 DNN을 구축하였다. 이는 향후 노후 건물의 안전등급 산정의 신뢰성이 향상되고 비용과 시간을 절약해 경제성이 향상될 것으로 기대된다.


키워드 : 안전 등급, 3D 점군 데이터, 역설계, 깊은 학습, 깊은 신경망


Funding

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government (MSIT)(No. 2020R1F1A1058136).

ORCID

Jae-min Lee,  <http://orcid.org/0000-0003-2391-4457>

Sangyong Kim,  <http://orcid.org/0000-0002-7363-3058>

Seungho Kim,  <http://orcid.org/0000-0001-9708-5343>

References

1. Park HJ, Lee SH, Kim EJ, Choo SY. A proposal for building safety diagnosis processes using bim-based reverse engineering technology. Proceeding of the 22nd International conference of the Association for Computer-Aided Architectural Design Research in Asia; 2017 Apr 5-8; Suzhou, China. Hongkong (China): Association for Computer-Aided Architectural Design Research in Aisa; 2017. p. 673-83.
2. Kwan AKH, Ng PL. Building diagnostic techniques and building diagnosis: The way forward. germany. Germany: Springer; 2015. p. 849-62.
3. Park J, Kim SG. Structural safety management for small-scale buildings. Korea: The Seoul Institute; 2020. p. 1-115.
4. Shi Z, Ergan S. Towards point cloud and model-based urban facade inspection: Challenges in the urban facade inspection process. Proceeding of the Construction Research Congress 2020; 2020 Mar 8-10; Tempe, AZ. Reston (VA): ASCE; 2020. p. 385-94. <http://dx.doi.org/10.1061/9780784482872.042>
5. Park HJ, Ryu JR, Woo SH, Choo SY. An improvement of the building safety inspection survey method using laser scanner and bim-based reverse engineering. Journal of the Architectural Institute of Korea Planning & Design. 2016 Dec,32(12):79-90. https://doi.org/10.5659/JAIK_PD.2016.32.12.79

6. Liu D, Chen J, Hu D, Zhang Z. Dynamic BIM-augmented UAV safety inspection for water diversion project. *Computers in Industry*. 2019 Mar;108:163-77. <https://doi.org/10.1016/j.compind.2019.03.004>
7. Choi SS, Kim EK. Design and implementation of vision-based structural safety inspection system using small unmanned aircraft. *Proceeding of the 2015 17th International Conference on Advanced Communication Technology*; 2015 Jul 1-3; PyeongChang, Korea. Piscataway (NJ): IEEE; 2015. p. 562-67.
8. Falorca JF, Lanzinha JCG. Facade inspections with drones – theoretical analysis and exploratory tests. *International Journal of Building Pathology and Adaptation*. 2021 Mar;39(2):235-58. <https://doi.org/10.1108/ijbpa-07-2019-0063>
9. Ani AIC, Johar S, Tawil NM, Abd Razak MZ, Hamzah N. Building information modeling (BIM)-based building condition assessment: A survey of water ponding defect on a flat roof. *Jurnal Teknologi*. 2015 Aug;75(9):25-31. <https://doi.org/10.11113/jt.v75.5222>
10. Sarker MM, Ali TA, Abdelfatah A, Yehia S, Elaksher A. A cost-effective method for crack detection and measurement on concrete surface. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2017 Nov;42:237-41. <https://doi.org/10.5194/isprs-archives-XLII-2-W8-237-2017>
11. Law DW, Holden L, Silcock D. The assessment of crack development in concrete using a terrestrial laser scanner (TLS). *Australian Journal of Civil Engineering*. 2016 Jan;13(1):22-31. <https://doi.org/10.1080/14488353.2015.1092635>
12. Turkan Y, Hong J, Laflamme S, Puri N. Adaptive wavelet neural network for terrestrial laser scanner-based crack detection. *Automation in construction*. 2018 Oct;94:191-202. <https://doi.org/10.1016/j.autcon.2018.06.017>
13. Mukupa W, Roberts GW, Hancock CM, Al-Manasir K. A review of the use of terrestrial laser scanning application for change detection and deformation monitoring of structures. *Survey Review*. 2016 Feb;49(353):99-116. <https://doi.org/10.1080/00396265.2015.1133039>
14. Silva A, Dias JL, Gaspar PL, de Brito J. Statistical models applied to service life prediction of rendered facades. *Automation in Construction*. 2013 Mar;30:151-60. <https://doi.org/10.1016/j.autcon.2012.11.028>
15. Sousa V, Matos JP, Matias N. Evaluation of artificial intelligence tool performance and uncertainty for predicting sewer structural condition. *Automation in Construction*. 2014 Aug;44:84-91. <https://doi.org/10.1016/j.autcon.2014.04.004>
16. El-Abbasy MS, Senouci A, Zayed T, Mirahadi F, Parvizedghy L. Artificial neural network models for predicting condition of offshore oil and gas pipelines. *Automation in Construction*. 2014 Sep;45:50-65. <https://doi.org/10.1016/j.autcon.2014.05.003>
17. Cha YJ, Choi W, Buyukozturk O. Deep learning-based crack damage detection using convolutional neural networks. *Computer-Aided Civil and Infrastructure Engineering*. 2017 Mar;32(5):361-78. <https://doi.org/10.1111/mice.12263>
18. Kang D, Cha YJ. Autonomous UAVs for structural health monitoring using deep learning and an ultrasonic beacon system with geo-tagging. *Computer-Aided Civil and Infrastructure Engineering*. 2018 May;33(10):885-902. <https://doi.org/10.1111/mice.12375>
19. Gopalakrishnan K, Gholami H, Vidyadharan A, Choudhary A, Agrawal A. Crack damage detection in unmanned aerial vehicle images of civil infrastructure using pre-trained deep learning model. *International Journal for Traffic and Transport Engineering*. 2018 Feb;8(1):1-14. [https://doi.org/10.7708/ijtte.2018.8\(1\).01](https://doi.org/10.7708/ijtte.2018.8(1).01)
20. Perez H, Tah JH, Mosavi A. Deep learning for detecting building defects using convolutional neural networks. *Sensors*. 2019 Aug;19(16):3556. <https://doi.org/10.20944/preprints201908.0068.v1>
21. Kim SH. 3D point cloud and 4D BIM-based construction project EV tracking process. [dissertation]. [Gyeongsan (Korea)]: Yeungnam University; 2019. 205 p.
22. Korea Authority of Land & Infrastructure Safety. Detailed guidelines for implementation of safety and maintenance of facilities (Safety inspection and diagnostics) instructions. Jinju (Korea): Korea Authority of Land & Infrastructure Safety; 2019 Nov. 161 p. Report No.: IM-19-E6-007.