

DNN 기법을 활용한 지하공동 데이터기반의 지반침하 위험 지도 작성

Verification of Ground Subsidence Risk Map Based on Underground Cavity Data Using DNN Technique

김한응¹ · 김창현² · 김태건³ · 박정준^{4*}Han Eung Kim¹, Chang Hun Kim², Tae Geon Kim³, Jeong Jun Park^{4*}¹CEO, Geotechnical Korea Engineering Co., Ltd., Anyang, Republic of Korea²Director, Research Institute, Geotechnical Korea Engineering Co., Ltd., Anyang, Republic of Korea³Senior Research Engineer, Research Institute, Geotechnical Korea Engineering Co., Ltd., Anyang, Republic of Korea⁴Research Professor, Incheon Disaster Prevention Research Center, Incheon National University, Incheon, Republic of Korea

*Corresponding author: Jeong Jun Park, smearjun@hanmail.net

ABSTRACT

Purpose: In this study, the cavity data found through ground cavity exploration was combined with underground facilities to derive a correlation, and the ground subsidence prediction map was verified based on the AI algorithm. **Method:** The study was conducted in three stages. The stage of data investigation and big data collection related to risk assessment. Data pre-processing steps for AI analysis. And it is the step of verifying the ground subsidence risk prediction map using the AI algorithm. **Result:** By analyzing the ground subsidence risk prediction map prepared, it was possible to confirm the distribution of risk grades in three stages of emergency, priority, and general for Busanjin-gu and Saha-gu. In addition, by arranging the predicted ground subsidence risk ratings for each section of the road route, it was confirmed that 3 out of 61 sections in Busanjin-gu and 7 out of 68 sections in Saha-gu included roads with emergency ratings. **Conclusion:** Based on the verified ground subsidence risk prediction map, it is possible to provide citizens with a safe road environment by setting the exploration section according to the risk level and conducting investigation.

Keywords: Deep Neural Network, Data Preprocessing, Underground Facilities, Cavity, Ground Subsidence Risk Map

요약

연구목적: 본 연구에서는 지하공동탐사로 발견된 공동자료를 지하시설물과의 원인별 상관관계로 분석하고, AI 알고리즘 기반으로 지반침하 예측지도를 검증하여 시민에게 안전한 도로 환경을 제공하고자 한다. **연구방법:** 위험도 평가 관련 데이터조사 및 빅데이터 수집, AI분석을 위한 데이터 전처리, 그리고 AI 알고리즘을 이용하여 지반침하 위험도 예측지도 검증 등 3가지 단계로 연구를 수행하였다. **연구결과:** 작성한 지반침하 위험 예측지도를 분석하여 부산시 부산진구와 사하구에 대해 긴급, 우선, 일반 3단계의 공동관리 위험등급 분포를 확인 할 수 있었다. 또한, 지반침하 위험 등급 예측 값을 도로노선의 구간별로 정리하여 긴급 등급이 포함된 도로가 부산진구는 총 61개구간 중 3개소, 사하구는 총 68개구간 중 7개소임을 확인하였으며 각 도로노선별 지반침하 위험 예측 순위를 파악하였다. **결론:** 도출된 지반침하 위험 예측지도를 바탕으로 효율적으로 탐사구간을 설정하여 우선 조사, 선제 조치함으로써 시민들의 불안을 해소하고 효율적인 도로유지관리 및 보수, 제도의 개선 등의 부수적인 효과를 얻을 수 있다.

핵심용어: 심층 신경망, 데이터 전처리, 지하시설물, 공동, 지반침하 위험 지도

Received | 4 May, 2023

Revised | 30 May, 2023

Accepted | 30 May, 2023

OPEN ACCESS



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 noncommercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

© Society of Disaster Information All rights reserved.

서론

싱크홀은 오늘날 도시 도로에서 가장 심각한 문제 중 하나이다. 갑작스러운 지반 함몰은 도로 폐쇄 및 경제적 손실뿐만 아니라 인명 피해로 이어지기 때문이다. 도심지 도로의 경우, 평균 수명 40년이 넘어 노후화로 진입하는 시대적 상황에 직면하였다. 도로포장 상부면 뿐만 아니라 도로 포장 하부에서도 노후화의 문제는 매우 심각하다. 특히 상하수도관, 도시가스, 통신관 등 도시기반시설의 노후화가 도로함몰의 주원인으로 작용하고 있다. 지반함몰은 지반 내부의 공동(Cavity)에 의해 생기는 지표면의 소규모 침하, 함몰현상이다. 지반함몰의 주요 원인은 공동, 즉 지반 속에 있는 빈 공간이다. 따라서 지반 속의 공동을 찾아 이를 복구하는 것만으로도 지반함몰 및 침하, 포트홀 현상 등의 예방에 큰 도움이 된다. 싱크홀은 예고없이 나타나기 때문에 도심지에서는 조기 발견을 위한 다양한 기술들이 개발되었다(Schoor, 2002; Chang et al., 2003). 최근 국내 지자체에서는 도로함몰 피해를 사전에 예방하기 위해서 지표투과레이더(Ground Penetrating Radar, 이하 GPR) 탐사를 실시하고 있다(Park et al., 2020; Kim et al., 2020; Chae, 2017).

GPR은 현재 비접촉 특성, 빠른 스캐닝 속도 및 3차원 이미징 기능 덕분에 구조 상태 모니터링 분야에서 인기를 얻고 있다(Endres et al., 2000; Cassidy et al., 2011; Kang et al., 2013). GPR은 고주파 전자파를 지면으로 방출하고 지하 물체에서 반사된 반환 전자파를 수신한다. 매질의 상대유전율이나 지하 조성 등 전자기적 특성에 변화가 있을 경우 수신 신호 분석을 통해 이러한 이상 현상의 경계를 파악할 수 있다. GPR은 지하 목적물을 매핑하는데 사용되는 고고학 및 지질학적 맥락에서 주로 적용되었으며 최근에는 지하 공동 및 잠재적인 싱크홀 탐지로 그 사용이 확장되었다. 지하의 정보를 얻기 위하여 도로를 주행하는 다른 차량과 비슷한 속도로 진행하면서 노면 하부에 중심 주파수 400~650MHz의 24채널 전파를 발생시키고 이를 다시 안테나로 측정하여 탐사깊이 1.5m 정도 깊이 이내의 공동 및 지하매설물을 탐지한다(Park et al., 2019). 그러나 미가공된 GPR 신호는 일반적으로 포장 도로와 같은 상위 계층에서 반사의 역할을 지배하기 때문에 분석하기가 매우 어렵다. 즉, 공동으로 인해 만들어지는 신호의 이미지와 배수관, 큰 돌 등 기타 지장물에 의해 생기는 신호와 모양이 흡사하여 이를 구별하는 데는 많은 경험과 노력이 필요하다. 따라서, 현재는 해당 문제를 해결하기 위하여 전문가의 경험에 의존할 수밖에 없는데 그마저도 정확한 판단을 내리는 것이 쉽지 않다. 또한, GPR 장비를 다루는 연구자들은 주로 전자파가 반사된 정보를 방정식으로 이해하여 그 방정식의 해를 푸는 방법으로 전자파의 정보를 해석하는 방식으로 본 문제를 다루어 왔다(Batayneh et al., 2002; Rodriguez et al., 2014).

이에 본 연구에서는 AI를 활용하여 지반함몰 위험 예측 지도를 제작해 GPR 탐사로 얻은 공동의 데이터와 지하시설물 및 지하철 노선도와와의 원인별 상관관계를 분석하고 AI 알고리즘을 이용하여 지반침하 예측 가능성을 검증하였다.

데이터 전처리 및 심층 신경망 이론

데이터 전처리

주어진 원래의 데이터를 그대로 사용하기보다 원하는 형태로 변형하여 분석에 적합하게 데이터를 가공하는 작업을 데이터 전처리라고 한다. 데이터 전처리 방법에는 결측값 처리, 이상값 처리, 데이터 샘플링 등의 방법이 있다. 결측값이 있는 상태로 모델을 만들게 될 경우 변수간의 관계가 왜곡될 수 있기 때문에 모델의 정확성이 떨어지게 된다. 이러한 결측값은 결측값이 발생한 모든 관측치를 삭제하거나 다른 관측치의 평균, 최빈값, 중앙값 등으로 대체하거나 결측값을 예측하는 모델을

만들어서 예측값을 삽입하여 처리하는 방법이 사용된다(Benedetto et al., 2017; Park et al., 2018; Tzani, 2015). 이상값은 데이터 또는 샘플과 거리가 먼 관측치로 모델을 왜곡할 가능성이 있는 관측치를 말하며 변수의 분포를 시각적으로 확인하거나 변수 간의 회귀 모형에서 잔차 등의 값을 확인하여 찾는 방법이 있다. 이상값이 오류라면 단순 삭제나 다른 값으로 대체하는 방법으로 처리한다. 그러나 이상값이 오류가 아닌 자연 발생한 경우에 삭제나 대체하는 방법을 사용하면 모델 현상을 잘 설명할 수 없다. 이러한 경우에는 이상값을 변수화 하거나 분리해서 모델을 만드는 방법 등으로 처리할 수 있다.

샘플링이란 데이터를 일부 정리하여 최적의 입력 데이터로 만들어 주는 작업으로서 특히 오버 샘플링(Over sampling)은 적은 레이블을 가진 데이터 세트를 많은 레이블을 가진 데이터 세트 수준으로 증식하여 학습에 충분한 데이터를 확보하는 기법이다. 소수 범주의 집합에서 무작위로 데이터를 추출하여 또 다른 집합을 만들고 이를 기존 집합에 더하는 과정으로 이뤄진다. 이러한 과정을 거쳐 기존 데이터 개수는 무작위로 데이터를 추출하여 만든 집합만큼 증가하게 되고 기존 집합의 범주 분포는 그에 따라 조절이 된다. 데이터를 단순 복제하는 대신 지능적으로 오버 샘플링을 사용한 대표적 방법으로 SMOTE (Synthetic Minority Oversampling Technique)가 있다. SMOTE는 기존에 있는 데이터를 복제하는 대신 소수 범주의 데이터들을 서로 보간하여 새로운 인공적인 데이터를 합성하는 방법이다. 이 기법은 먼저 k 근접 이웃(k nearest neighbor) 알고리즘을 사용해 소수 범주의 데이터들과 가장 가까운 데이터들을 찾은 뒤 새로 합성된 데이터가 그 성향을 반영하여 추가된다.

모델을 평가하는 요소로 모델이 내놓은 답과 실제 정답 사이의 관계로 식(1)과 같이 정의할 수 있다. 정밀도(Precision)은 Positive 정답률로서 모델이 True라고 분류한 것 중에서 실제 True인 것의 비율이다. 재현율(Recall)은 실제 True인 것 중에서 모델이 True라고 예측한 것의 비율이며, Precision과 Recall은 상호보완적으로 사용할 수 있으며, 두 지표가 모두 높을수록 좋은 모델이라고 할 수 있다. F-score는 Precision과 Recall의 조화평균으로 데이터 레벨이 불균형 구조일 때, 모델의 성능을 정확하게 평가할 수 있다.

$$Precision = \frac{true\ positive}{true\ positive + false\ positive}$$

$$Recall = \frac{true\ positive}{true\ positive + false\ negative}$$

$$F - score = \frac{2 \times (Precision \times Recall)}{Precision + Recall}$$

(1)

심층 신경망

심층 신경망(DNN: Deep Neural Network)은 인간 두뇌의 설계 방식을 기반으로 계층적 네트워크에서 수많은 레이어에 데이터를 훈련함으로써 분류가 수행되는 인공지능의 기술로서, 다양한 비선형 변환 기법을 결합하여 추상화하려는 기계학습의 한 유형이다(Fig. 1). 심층 신경망은 입력 레이어, 출력 레이어 및 입력 레이어와 출력 레이어 사이에 있는 은닉 레이어로 구성되며, 이를 통하여 추출은 자동으로 수행, 학습 데이터의 양이 많을수록 성능이 향상되고, 예측력은 다른 기계 학습 기술보다 뛰어나다. 또한 분류나 군집화를 원하는 경우 데이터 위에 몇 개의 층을 포개어 작업을 하는 것으로, 각 층에서 라벨링이 되어 있지 않은 데이터를 비교해 가면서 유사도를 획득하고, 라벨링된 데이터를 사용하여 분류기를 학습하며, 데이터를 자동으로 분류할 수 있다. 심층 신경망은 오차 역전파법(Back propagation)으로 학습할 수 있다. 기계 학습에서 사용되는 학습 구조로 일반적인 다층 퍼셉트론의 형태는 입력층 - 은닉층 - ... - 은닉층 - 출력층으로 구성되며, 각 층은 서로 교차되는 가중치

값으로 연결되어 있다. 출력층에서 제시한 값이 실제 원하는 값에 가까워지도록 학습하기 위해 통계적 방법에 의한 오차역전파법을 사용한다. 오차역전파법은 동일 입력층에 대해 원하는 값이 출력되도록 개개의 가중치를 조정하는 방법으로 사용되며, 속도는 느리지만 안정적인 결과를 얻을 수 있는 장점이 있어 기계 학습에 널리 사용되고 있다(Kim et al., 2019; Kang et al., 2019; Kizhevsky et al., 2012).

오차역전파법과 경사 하강법은 구현의 용이함과 국지적 최적화에 잘 도달한다는 특성으로 많이 적용하는 방법들이다. 그러나 이 방법들은 심층 신경망을 학습 시킬 때 시간 복잡도가 매우 높다. 심층 신경망을 학습시킬 때에는 크기(계층의 수와 계층 당 유닛 수), 학습률, 초기 가중치 등 많은 매개변수들이 고려되어야 한다. 시간 복잡도를 해결하기 위해, 여러 학습 예제들의 경사를 동시에 계산하는 미니 배치(mini batch), 그리고 드롭아웃(drop out)과 같은 다양한 방법들이 등장하였다. 또한, 행렬 및 벡터 계산에 특화된 GPU는 많은 처리량을 바탕으로 두드러지는 학습 속도향상을 보여주고 있다(Al-Nuaimy et al., 2000; Gamba, 2000; Zhang et al., 2016).

데이터 전처리 결과

본 연구에서는 부산광역시 중 부산진구와 사하구의 공동, 지하 매설물, 지하철 노선도가 분석 대상이다. 공동(cavity) 자료는 위치 데이터(X좌표, Y좌표)와 등급, 면적 정보로 이루어져 있다. 지하 매설물의 종류는 상수도관, 하수도관, 통신(KT), 부산도시가스, 전기설비(관로), 전기설비(배전설비), 전기설비(전력구)가 있으며, 매설물과 지하철 노선도는 위치 데이터(X좌표, Y좌표)로 구성되어 있다.

지반침하 위험 예측지도를 얻기 위해서 지도에 색깔별로 지반침하 위험도를 나타내는 방법을 적용하기 위해서 지하 매설물과 지하철 노선도의 x, y 좌표의 최소값, 최대값을 범위로 지정하여 Table 1과 같이 일정 단위(grid)로 지도를 분할하였다.

Table 1. Grid-divided map coordinates

	x	y	x-1	x+1	y-1	y+1
0	200000	281000	199975.0	200025.0	280975.0	281025.0
1	200000	281050	199975.0	200025.0	281025.0	281075.0
2	200000	281100	199975.0	200025.0	281075.0	281125.0
3	200000	281150	199975.0	200025.0	281125.0	281175.0

Fig. 2에 나타난 바와 같이 지도를 바둑판의 형태로 나눈 후, 각 칸의 중심점에서 원본 자료의 좌표가 얼마나 떨어져 있는지를 식(2)와 같이 유클리드 거리 계산법을 통해 계산하였다. Table 2와 같이 거리가 가장 가까운 지하매설물 및 지하철 노선도와 공동 좌표만을 저장하여, 각 칸에 연결시키면 각 칸에서 공동과의 거리를 확인할 수 있다.

$$d_E(x, y) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (2)$$

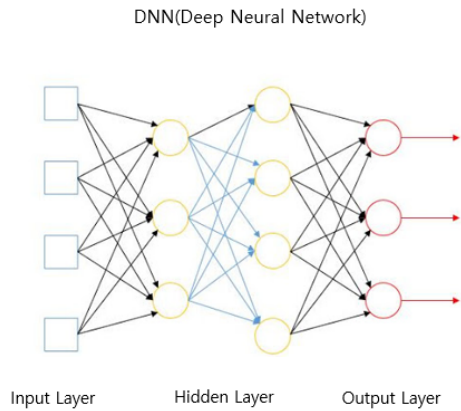


Fig. 1. Structure of deep neural network




Fig. 2. Euclidean distance

Table 2. Distance between cavity and underground facilities and subway lines

	Cavity	Water pipe	Sewer pipe	Communication pipe(KT)	Busan city gas	Pipeline	Distribution facility	Power grid	Subway lines
0	3034.86	2939.32	3893.72	3312.68	3313.90	3261.99	3315.98	3316.52	3342.48
1	2987.58	2896.21	3851.08	3268.58	3269.68	3217.57	3274.29	3274.82	3328.38
2	2940.38	2853.33	3808.61	3224.66	3225.63	3173.33	3232.84	3233.35	3295.53
3	2893.28	2810.68	3766.32	3180.91	3181.76	3129.25	3191.64	3192.13	3281.79

얻어진 자료 간의 상관관계를 통해 Fig. 3에 나타낸 바와 같이 공동은 상수도관과 가장 높은 상관관계를 가지며, 하수도관, 전기설비(배전설비), 전기설비(전력구), 전기설비(관로), 통신(KT) 순으로 높은 상관관계를 갖으며, 특히 공동 주변에 상수도관이 존재할 확률은 91%, 하수도관이 존재할 확률은 85%이다.

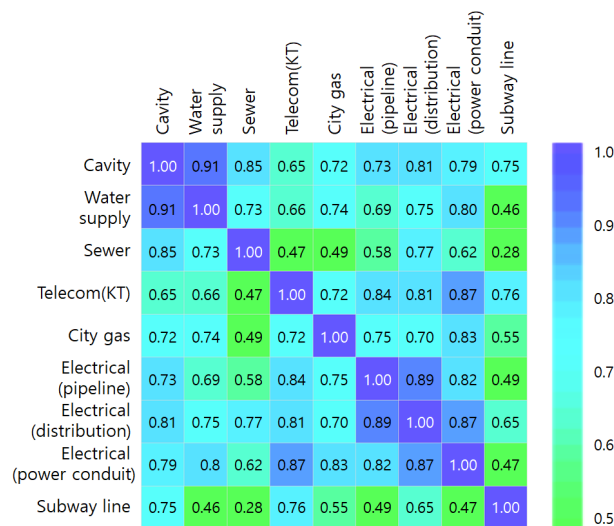


Fig. 3. Correlation between cavity, underground facilities and subway lines

공동의 거리는 실수로 표현되어 있는데, 이를 분석에 적합한 범주형 자료로 만들어주기 위하여 공동에 가장 가까운 칸을 0으로, 가장 먼 칸을 119로 범주화 하여 공동과 지하 시설물 및 지하철 노선도의 거리에 따라 0~119까지의 120등급으로 나누어 분류하였다. 각 지점에 해당하는 거리등급 분류를 적용하면 Table 3과 같은 데이터를 얻을 수 있다. 마지막으로 데이터의 개수가 적다는 단점을 보완하기 위하여 오버샘플링의 방법 중 하나인 SMOTE를 적용하여 데이터의 개수를 늘려주었다.

Table 3. Underground facilities and subway lines classified by grade

	Category	Water pipe	Sewer pipe	Communication pipe(KT)	Busan city gas	Pipeline	Distribution facility	Power grid	Subway lines
0	74	1731.08	2146.47	1914.64	1897.76	1793.63	2076.85	2069.44	2042.68
1	75	1756.73	2163.80	1944.38	1927.53	1803.32	2101.04	2093.66	2007.87
2	75	1483.41	2182.14	1974.94	1958.12	1814.38	2126.13	2118.77	1976.03
3	76	1811.08	2201.47	2006.28	1989.51	1826.66	2152.09	2144.76	2018.29

딥러닝 학습 결과

딥러닝 모델은 텐서플로우(tensorflow) 라이브러리를 활용하여 구성하였으며, Dense 레이어라는 fully connected 레이어를 구성하였다. 총 7개의 층으로 이루어져 있고, 각 층은 범주형 개수(120개)에 비례한 유닛을 설정하였으며 가장 마지막 레이어의 경우 범주형 자료의 확률을 나타내기 위해 120개로 설정하였다. 본 연구에서 사용된 모델의 총 파라미터 수는 26,276,272개라는 것을 확인 할 수 있었고(Table 4), Fig. 4는 모델 알고리즘의 구조를 간략하게 표현한 것이다.

위의 전처리된 데이터로 모델을 훈련 및 학습시켰다. 모델이 학습하는 과정에서 가중치가 조금씩 올바른 방향으로 조정되고 손실 점수가 감소하여 충분한 횟수만큼 반복하면 손실함수를 최소화하는 가중치 값을 산출해준다. Fig. 5는 모델이 학습하는 동안의 오차율을 나타낸 것이다. Loss는 손실 점수, Epoch는 전체 데이터 셋에 대해 한 번 학습을 완료한 상태를 나타내는 지표이며, Epoch 70 까지 학습을 진행하였다.

Table 4. Model algorithm structure

Model : "sequential"		
Layer(type)	Output Shape	Param #
dense(Dense)	(None, 4760)	71400
dense_1(Dense)	(None, 3570)	16996770
dense_2(Dense)	(None, 2380)	8498980
dense_3(Dense)	(None, 238)	566678
dense_4(Dense)	(None, 238)	56882
dense_5(Dense)	(None, 238)	56882
dense_6(Dense)	(None, 120)	28680

Total parameters: 26,276,272 / Trainable parameters: 26,276,272 / Non-trainable parameters: 0

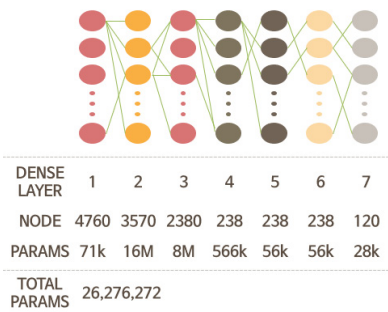


Fig. 4. Schematic of model algorithm structure




Fig. 5. Error rate graph

딥러닝 학습 모델을 통해 완성된 모델을 도출하여 부산진구, 사하구 자료에 각각 적용하였다. 공동과 지하매설물 및 지하철노선도의 좌표를 표시하고 모델에 거리 값을 넣어주면 범주형 자료를 출력해 주는데 이를 통해 나누어진 그리드, 즉 각 칸이 어느 범주에 속하는지 예측하여 색깔을 통해 위험 정도를 표현하였다. 최종적으로 도로노선과 공동, 지하매설물 및 지하철노선도, 공동 위험등급이 색칠된 지도를 위성사진과 합성하여 지반침하 위험 예측 지도를 생성하였다. Table 5는 학습이 완료된 모델을 적용했을 때의 분류 성능 평가 지표이다. 식(1)을 이용하여 정밀도(precision), 재현율(recall), F-score 등의 통계적 지표를 산출하여 지하공동자동탐지기법의 성능을 평가하였다. 여기서 ‘grid100’은 지하매설물의 좌표의 최소 단위가 100인 것, ‘grid50_b’는 좌표의 최소 단위가 50인 것, ‘grid50_s’는 좌표의 최소 단위가 50이고 파라미터의 개수를 줄인 모델로 평가를 해 본 지표이다. 종합 정확도(F-score)는 ‘grid100’일 때 부산진구가 0.94, 사하구가 0.95로 만족스러운 지표 결과를 얻을 수 있었다.

지반침하 위험 예측 3단계 등급 구분으로, 부산진구, 사하구에 해당하는 도로노선별 위험등급 거리 결과를 각각 Table 6과 Table 7에 정리하였다. 이를 공동과 지하매설물 및 지하철노선도의 좌표를 표시하고 모델에 거리 값을 넣어주면 범주형 자료를 출력해 주는데 이를 통해 나누어진 그리드, 즉 각 칸이 어느 범주에 속하는지 예측하여 색깔을 통해 위험 정도를 표현해 준다. 지도에 긴급, 우선, 일반 3개의 위험 예측 등급 중 긴급, 우선등급 2개의 위험 정도를 색깔별로 표현 후 도로노선이 그려진 위성사진과 합성하여 Fig. 6에 나타난 바와 같이 지반침하 위험 예측 지도를 생성하였다. 결과, 지반침하 위험 등급 예측 값을 도로노선의 구간별로 정리하여 긴급 등급이 포함된 도로가 부산진구 총 61개 구간(56.84km) 중 3개소(0.39km), 사하구 총 68개 구간(68.29km) 중 7개소(1.66km)임을 확인하였다. 즉, 부산진구와 사하구의 지반침하 위험 예측 지도를 바탕으로 지하시설물 밀집 정도를 보았을 때, 부산진구 위험 예측 구간보다 사하구의 위험 예측 구간에서 상·하수도관이 더 밀집된 것을 확인할 수 있었다.

Table 5. Performance evaluation index

Item	Busanjin-gu			Saha-gu		
	Precision	Recall	F-Score	Precision	Recall	F-Score
grid100	0.94	0.93	0.94	0.95	0.95	0.95
grid50_b	0.85	0.89	0.87	0.88	0.91	0.89
grid50_s	0.86	0.90	0.88	0.88	0.92	0.90

Table 6. Risk rating prediction results for each road route in Busanjin-gu

Item	Urgent(km)(%)	Priority(km)(%)	General(km)(%)	Total distance(km)
Baekamsan ro 53 gil	0.15(14%)	0.26(25%)	0.64(61%)	1.05
Dongpyeong-ro(22)	0.12(6%)	0.98(53%)	0.75(41%)	1.85
Dongpyeong-ro(30)	0.12(15%)	0.66(85%)	-	0.78

Table 7. Risk rating prediction results for each road route in Saha-gu

Item	Urgent(km)(%)	Priority(km)(%)	General(km)(%)	Total distance(km)
Dasan-ro	0.39(20%)	0.19(10%)	1.36(70%)	1.94
Eulsukdo daero	0.32(15%)	0.84(38%)	1.05(47%)	2.21
Jangnim ro	0.32(11%)	2.3(77%)	0.37(12%)	2.99

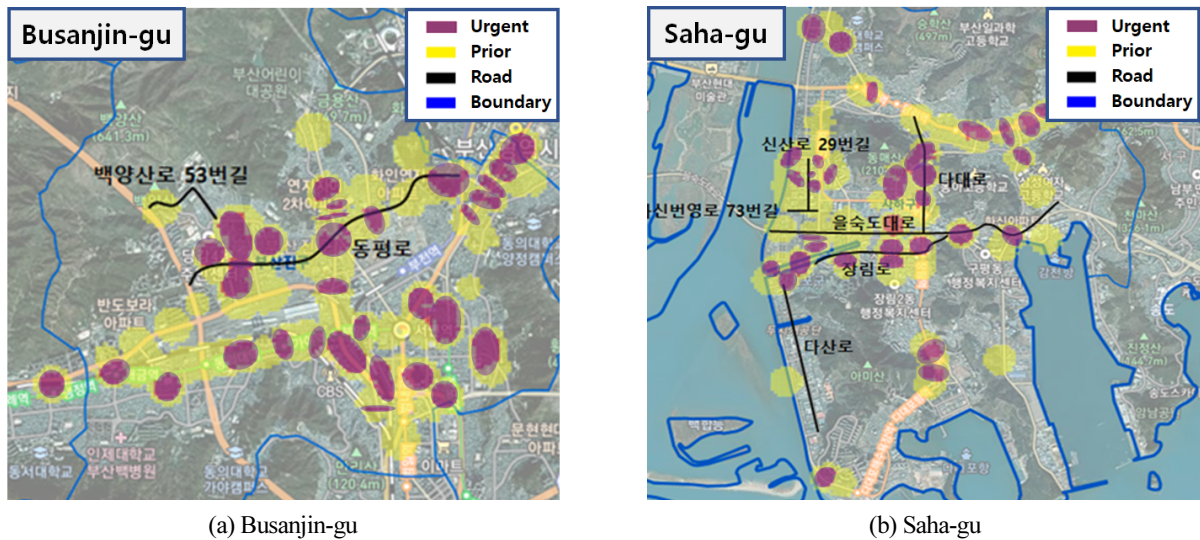


Fig. 6. Ground subsidence risk map

결론

본 연구에서는 지하공동자료와 지하시설물 등의 데이터를 이용, 심층신경망을 활용한 딥러닝 기법으로 지반침하 위험 예측지도를 만들고 도로노선별 위험등급 예측 값을 얻었으며 다음과 같은 결론을 도출하였다.

작성한 지반침하 위험 예측지도를 분석하여 부산시 2개구(부산진구, 사하구)에 대해 긴급, 우선, 일반 3단계의 위험등급 분포를 확인 할 수 있었다. 또한, 지반침하 위험 등급 예측 값을 도로노선의 구간별로 정리하여 긴급 등급이 포함된 도로가 부산진구 총 61개구간(56.84km) 중 3개소(0.39km), 사하구 총 68개구간(68.29km) 중 7개소(1.66km)임을 확인하였으며 각 도로노선별 지반침하 위험 예측 순위를 파악하였다. 즉, 부산진구와 사하구의 지반침하 위험예측지도를 바탕으로 지하시설물 밀집정도를 확인해 본 결과, 부산진구 위험예측 구간보다, 사하구의 위험예측 구간에서 상·하수도관이 더 밀집된 것을 확인할 수 있었다.

도출된 지반침하 위험 예측지도를 바탕으로 효율적으로 탐사구간을 설정하고 우선 조사, 선제 조치함으로써 시민들의 불안 해소하고 인적, 물적 손실 최소화 효과를 기대할 수 있으며, 기반공사 및 건축에도 지반침하 위험 예측지도를 참조하여 보강 및 계획에 반영함으로써 큰 사고나 피해를 예방할 수 있으며 효율적인 도로유지관리 및 보수, 제도의 개선 등의 부수적인 효과를 얻을 수 있다. 향후 공동 발생원인 인자를 추가 입력하여, 분석·학습 시킴으로써 보다 정밀하고 신뢰성 높은 지반침하 위험 예측이 가능하며 부산광역시 관리 프로그램과 연계하여 분석할 수 있을 것으로 판단된다.

References

- [1] Al-Nuaimy, W., Huang, Y., Nakhkash, M., Fang, M.T.C., Nguyen, V.T., Eriksen, A. (2000). "Automatic detection of buried utilities and solid objects with GPR using neural networks and pattern recognition." *Journal of Applied Geophysics*, Vol. 43, pp. 157-165.
- [2] Batayneh, A., Abdelruhman, A., Moumani, K. (2002). "Use of ground-penetrating radar for assessment of potential sinkhole conditions: an example from Ghor al Haditha area." *Environmental Geology*, Vol. 41, pp. 977-983.
- [3] Benedetto, A., Tosti, F., Ciampoli, L., D'Amico, F. (2017). "An overview of ground-penetrating radar signal processing techniques for road inspections." *Signal Processing*, Vol. 132, pp. 201-209.
- [4] Cassidy, N.J., Eddies, R., Dods, S. (2011). "Void detection beneath reinforced concrete sections: The practical application of ground penetrating radar and ultrasonic techniques." *Journal of Applied Geophysics*, Vol. 74, pp. 263-276.
- [5] Chae, H.Y. (2017). "Study on Subsurface Collapse of Road Surface and Cavity Search in Urban Area." *Tunnel & Underground Space*, Vol. 27, No. 6, pp. 387-392.
- [6] Chang, P., Flatau, A., Liu, S. (2003). "Review paper: Health monitoring of civil infrastructure." *Structure Health Monitoring*, Vol. 2, pp. 257-267.
- [7] Endres, A.L., Clement, W.P., Rudolph, D.L. (2000). "Ground penetrating radar imaging of an aquifer during a pumping test." *Ground Water*, Vol. 38, pp. 566-576.
- [8] Gamba, P. (2000). "Neural detection of pipe signatures in ground penetrating radar images." *IEEE Trans Geoscience Remote Sensing*, Vol. 38, pp. 790-797.
- [9] Kang, M.S., Kim, N.G., Lee, J.J., An Y.K. (2019). "Deep learning-based automated underground cavity detection using three-dimensional ground penetrating radar." *Structure Health Monitoring*, Vol. 19, No. 1.
- [10] Kang, Y.V., Hsu, H.C. (2013). "Application of ground penetrating radar to identify shallow cavities in a coastal dyke." *Journal of Applied Science and Engineering*, Vol. 16, No. 1, pp. 23-28.
- [11] Kim, N.G., Kim, S., An, Y.K., Lee, J.J. (2019). "A novel 3D GPR image arrangement for deep learning-based underground object classification." *International Journal of Pavement Engineering*, Vol. 22, No. 6, pp. 740-751.
- [12] Kim, S.M., Choi, H., Yoon, J.S., Park, J.J. (2020). "A study on the change of cavity area through groundwater injection test under pavement cavity." *Journal of the Society of Disaster Information*, Vol. 16, No. 2, pp. 267-275.
- [13] Kizhevsky, A., Sutskever, I., Hilton, G. (2012). "ImageNet classification with deep convolutional neural networks." In *Proceedings of the NIPS'12, Lake Tahoe, NV, USA*, pp. 1-9.
- [14] Park, B., Kim, J., Lee, J., Kang, M.S., An, Y.K. (2018). "Underground object classification for urban roads using instantaneous phase analysis of ground-penetrating radar (GPR) data." *Remote Sensing*, Vol. 10, No. 9.
- [15] Park, J.J., Chung, Y., Hong, G. (2019). "A method for cavity scale estimation based on ground-penetration radar(GPR) explorations: An experimental study." *Advances in Civil Engineering*, Vol. 2019, 1365759.

- [16] Park, J.J., Kim, I.D. (2020). "Analysis of the under pavement cavity growth rate using multi-channel GPR equipment." *Journal of the Society of Disaster Information*, Vol. 16, No. 1, pp. 60-69.
- [17] Rodriguez, V., Gutierrez, F., Green, A., Carbonel, D., Horstmeyer, H., Schmelzbach, C. (2014). "Characterizing sagging and collapse sinkholes in a Mantled Karst by means of ground penetrating radar(GPR)." *Environmental & Engineering Geoscience*, Vol. 20, pp. 109-132.
- [18] Schoor, M. (2002). "Detection of sinkholes using 2D electrical resistivity imaging." *Journal of Applied Geophysics*, Vol. 50, pp. 393-399.
- [19] Tzanis, A. (2015). "The curvelet transform in the analysis of 2-D GPR data: signal enhancement and extraction of orientation and scale dependent information." *Journal of Applied Geophysics*, Vol. 115, pp. 145-170.
- [20] Zhang, Y., Huston, D., Xia, T. (2016). "Underground object characterization based on neural networks for ground penetrating radar data." *Proceedings of the SPIE, Nevada, US*, pp. 1-9.