심층 신경망을 이용한 산사태 민감도 분석

Analysis of Landslide Susceptibility Using Deep Neural Network

송창호* · 이지성** · 김윤태***

Song, Chang-Ho*, Lee, Ji-Sung**, and Kim, Yun-Tae***

Abstract

Landslides in Korea are caused by various factors, such as topographic characteristics, geology, and climate change, and they cause significant damage to property and human life. It is necessary to analyze landslide susceptibility to identify the location of landslide occurrence precisely and respond to the risk of landslides. In this study, the probability of landslide occurrence was calculated through a landslide sensitivity analysis using a deep neural network based on eight conditioning factors and 26 landslide data. In addition, verification was performed using the ROC method. The landslide susceptibility obtained using a deep neural network showed a success rate of 70% and a prediction rate of 81.7%, indicating that the prediction rate was 11.7% higher than the success rate. In addition, a landslide susceptibility map for estimating the probability of landslide occurrence was plotted using the geometric spacing method. The chi-square test results indicated that the landslide susceptibility map obtained in this study was statistically significant. The location of landslides can be identified more accurately using the proposed method.

Key words : Deep Neural Network, Multi-collinearity, ROC Method, Landslide Susceptibility

요 지

국내에서 발생하는 산사태는 지형적인 특성, 지질, 기후변화 등 여러 가지 요인들이 복합적으로 작용하여 발생하며 많은 재산 및 인명 피해를 유발한다. 산사태 위험에 대응하기 위해서는 산사태 발생에 영향을 미치는 주요 인자들을 분석하여 산사태 발생 위치를 정확히 식별하는 민감도 분석이 필요하다. 본 연구에서는 8개 인자와 26개 산사태 자료를 바탕으로 심층 신경망을 활용한 산사태 민감도 분석을 수행하여 산사태 발생 확률을 산정하였다. 그리고 ROC 기법을 통해 검증을 수행하였다. 성공률은 70%, 예측률은 81.7%로서 예측률이 성공률보다 11.7% 높은 것을 보여주었다. 또한 심층 신경망을 통해 평가된 산사태 발생 확률을 기하학적 간격 방법을 사용하여 산사태 민감도 지도를 제작하였고, 카이제곱 테스트를 수행한 결과 통계적으로 유의한 것을 입증하였다. 이와 같은 연구를 통해 산사태의 발생 위치를 보다 정확히 식별할 수 있을 것으로 기대된다.

핵심용어 : 심층 신경망, 다중공선성, ROC 기법, 산사태 민감도

1. 서 론

국내의 경우 산지 비율이 높고 산지 경계부를 따라 인구가 밀집된 지역이 많다. 최근에 주택난 및 교통난 해소를 위해 산지를 중심으로 많은 개발이 진행되었고, 또한 급격한 기후 변화로 인해 산사태 피해가 증가하여 인명과 시설물에 큰

영향을 주고 있다. 특히 2011년 국내 우면산과 춘천에서 발생한 산사태로 인해 산사태 발생 위치와 내적 요인에 관한 연구들이 꾸준히 수행되고 있다. 산사태를 유발하는 내적 요인으로는 지형학적 특성, 지반·지질 특성, 임상 등 여러 가지 요인들이 있다. 산사태는 일반적으로 내적 요인과 외적 요인(집중호우, 태풍, 지진 등)이 복합적으로

*정회원, 부경대학교 해양공학과 박사과정(E-mail: chsong913@naver.com)

Member, Ph.D. Student, Dept. of Ocean Engineering, Pukyong National University

**정회원, 부경대학교 스마트인프라기술연구소 전임연구원(E-mail: js3497@naver.com)

Member, Associate Researcher, Smart Infra-Structure Technology Institute, Dept. of Ocean Engineering, Pukyong National University

***교신저자, 정회원, 부경대학교 해양공학과 교수(Tel: +82-51-629-6587, Fax: +82-51-629-6590, E-mail: yuntkim@pknu.ac.kr)

Corresponding Author, Member, Professor, Dept. of Ocean Engineering, Pukyong National University

작용하여 발생한다. 따라서 산사태로 인한 피해를 줄이고 예방하기 위해서는 산사태 발생지역과 산사태 발생에 영향을 미치는 요인들을 분석하여 산사태 발생 가능성을 사전에 평가하는 연구가 필요하다.

일반적으로 산사태 발생 위치를 식별하기 위해서 민감도 평가가 이루어진다. 민감도 평가는 과거 발생된 산사태 자료와 영향 인자 간의 공간적 분석을 통해 추후 발생할 산사태를 등급 및 확률로 나타내는 방법이다.

산사태 민감도에 관한 연구로는 경험적 방법(Van Westen, 2000; Abella and Van Westen, 2007), 물리 기반 모델(Jibson, 2011; Nguyen et al., 2020; Nguyen and Kim, 2021), 통계적 방법(Bai et al., 2010; Lee et al., 2018) 등 다양한 방법을 사용하여 산사태 민감도 평가를 수행하였다. 최근에 빅데이터를 활용하는 연구가 증가함에 따라 산사태 민감도 분석에도 머신러닝 기법을 적용하는 사례가 증가하고 있다. 독립 변수의 선형 결합을 이용하여 값을 예측하는 로지스틱 회귀(Bai et al., 2014; Akgun, 2012; Das et al., 2012; Tsangaratos and Ilia, 2016), 자료 분석을 위한 모델인 서포트 벡터 머신(Yilmaz, 2010; Xu et al., 2012; Pradhan, 2013; Peng et al., 2014; Lee et al., 2017), 다수의 결정 트리로부터 결과값을 예측하는 랜덤 포레스트(Pradhan, 2013; Alkhasawneh et al., 2014; Catani et al., 2013) 등 여러 가지 머신러닝 기법을 적용하여 산사태 민감도 분석을 수행하고 있다. 그러나 이러한 방법들의 단점은 모델 구축을 위한 시간 증가, 데이터 증가에 따른 메모리 사용량 증가 및 계산속도 저하, 계층 수 증가로 인한 계산변화 방향 상실, 가중치 해석의 어려움 등이다.

최근 들어 기존의 머신러닝 기법들의 단점을 보완하여 데이터 분류나 회귀분석에 사용되는 기술인 딥러닝이 산사태 민감도 연구에 활용되고 있으며(Yang et al., 2019; Nguyen and Kim, 2021), 일반적으로 인공신경망(Artificial Neural Network)을 통한 연구가 주로 수행되었다(Ermini et al., 2005; Bui, Ho et al., 2016; Bui, Tuan et al., 2016; Chen, Pourghasemi,

Komejady et al., 2017; Chen, Pourghasemi, and Zhao (2017); Lee et al., 2018; Yang et al., 2019; Tian et al., 2019; Lee and Oh, 2019). 하지만 인공신경망은 모델 내 최적값을 찾기 어려워 학습데이터에 따른 과적합 문제가 발생한다. 또한, 은닉층이 증가 될수록 연산량이 급격히 증가하여 학습 시간이 상대적으로 오래 걸리는 단점이 있다. 이와 같은 인공신경망 모델의 단점을 보완한 모델이 심층 신경망(deep neural network)이다. 심층 신경망은 복잡하고 비선형적 관계의 데이터를 이용해 학습하고 분석하는 방법이다. 그러나 국내에서 심층 신경망을 이용해 산사태 발생 확률을 평가하는 연구는 현재 전무한 상황이다.

따라서 본 연구에서는 심층 신경망을 이용해서 산사태 발생 확률을 평가하였고, ROC 곡선을 통해 검증하였다. 또한, 기하학적 간격 방법(geometrical interval method)을 사용하여 매우 낮음, 낮음, 보통, 높음 및 매우 높음의 다섯 가지 그룹으로 분류되는 산사태 민감도 지도를 제작하였다. 본 연구 결과에서 도출된 산사태 민감도 지도는 도심지 지반재해 민감도 평가의 기초자료로 활용될 수 있다.

2. 연구 지역

본 연구에서는 과거부터 현재까지 수차례 산사태가 발생하고 있는 부산 황령산을 대상으로 연구를 수행하였고, 연구 대상 지역은 Fig. 1과 같다. 황령산은 부산의 중심에 있어 인구가 밀집되어 있을 뿐만 아니라, 주변부를 따라 주요시설물들이 위치하고 있다. 또한, 등산로와 임도가 많이 개설되어 있으며 수많은 산사태 취약 요소들이 존재하고 있다. 특히, 1999년 9월 10일 황령산 터널 방면 우측의 도로 절취 사면에서 발생한 산사태로 인해 발생한 토사 유출은 수평거리 최대 17 m 이동하여 황령산 터널 입구 4차선 도로의 끝까지 발생하였고, 토사매몰로 인해 사망자 1명 부상자 3명이 발생하였다(Choi and Paik, 2002). 2020년 7, 8월 집중호우로 인해 약 70건의 산사태가 발생하였으며 그 중 황령산 일대에

Fig. 1. Study Area

5건의 산사태가 집계되었다. 그리고 집중강우 시기에 얇은 사면파괴 및 토사 유출이 지속적으로 발생하고 있어 잠재적 위험성이 가중되고 있다. 따라서 산사태 피해에 선제적으로 대응하기 위해서는 산사태 민감도 분석을 통해 위험지역을 식별하는 연구가 필요하다.

3. 방법론

심층 신경망을 이용하여 산사태 발생 확률을 평가하기 위한 연구 흐름은 Fig. 2와 같다. 먼저 연구대상 지역의 산사태 영향 인자(DEM, Aspect, Slope, Curvature, Drainage proximity, STI, Soil depth, Soil type)들과 산사태 발생자료 26개를 구축하였다(Fig. 3). 구축된 영향 인자들로부터 다중공선성 분석(multi-collinearity)과 변수 중요도 분석(permutation

importance)을 수행하였다. 그리고 활성화 함수와 은닉층의 노드 수를 결정한 후 심층 신경망을 수행하였다. 구축된 산사태 발생자료 26개 중 70%는 훈련 데이터, 30%는 검증 데이터로 활용하여 ROC 기법을 통해 성공률 곡선과 예측률 곡선을 산정하여 검증하였다. 마지막으로 기하학적 간격 방법을 통해 산사태 민감도 지도를 등급화하였고, 제작된 민감도 지도가 통계적으로 유의함을 검증하기 위해 카이제곱 테스트(Chi-square test)를 수행하였다.

3.1 영향 인자 구축

연구 지역의 산사태 민감도 분석을 위해 Fig. 4와 같이 8개의 산사태 영향 인자들을 ArcGIS를 이용하여 레스터 형태로 구축하였다. 국토지리 정보원(National Geographic Information Institute, NGII)에서 얻은 1:5,000의 수치지도로

Fig. 2. The Framework of DNN-based Landslide Prediction Model Used in This Study

Fig. 3. Landslide Inventory

부터 10 × 10 m 격자의 DEM을 제작하였다(Fig. 4(a)). 제작된 DEM을 통해 지형학적 인자인 Aspect, Slope, Curvature를 도출하였다(Figs. 4(b), (c), (d)). 그리고 DEM, Slope, 상부기 여면적을 활용하여 수문학적 인자인 Drainage proximity, STI를 제작하였다(Figs. 4(e), (f)). 마지막으로 국립농업과학원(National Institute of Agriculture Sciences, NIAS)의 흙토 람에서 제공받은 1:25,000의 토양도 자료를 바탕으로 토양인 자인 Soil depth, Soil type을 제작하였다(Figs. 4(g), (h)). 그리고 구축된 영향 인자들의 범위는 다음과 같다. DEM은 65~424.65 m, Aspect는 (1) Flat, (2) North, (3) Northeast, (4) Southeast, (5) South, (6) Southwest, (7) West, (8) Northwest, (9) North 총 9개의 등급, Slope은 0.02°~47.11°, Curvature은 -12.35~10.99, Drainage proximity는 0~420.476, STI는 0~2467.49, Soil depth는 (1) NA, (2) <20 cm, (3) 20~50 cm, (4) 50~100 cm, (5) >100 cm 총 5개의 등급, Soil type는 (1) NA, (2) Silty clay, (3) Silt loam, (4) Sandy loam, (5) Clay loam, (6) Loamy sand 총 6개의 등급으로 분석되었다.

이와 같이 구축된 영향 인자들 간의 중복성을 평가하기 위해 다중공선성(multi-collinearity) 분석과 변수 중요도(permutation importance) 분석을 수행하였다. 먼저 다중공선 성 분석은 영향 인자 간의 상관성 및 유의성이 낮은 인자를 최소화하는 작업이다(Bui et al., 2011). 다중공선성 분석에는 허용오차(tolerance, TOL)와 분산팽창계수(Variance Inflation Factors, VIF)가 분석 지표로 사용되며(Kavzoglu et al., 2014; Pradhan and Kim, 2017), 분산팽창요인(VIF)> 10 또는 허용 오차(TOL)<0.1이면 영향 인자간 상관성이 높은 것으로 판단

하여 제거한다. 그리고 변수 중요도는 영향 인자들을 섞은 후 모델의 예측 오차를 계산하여 영향 인자의 중요도를 측정하여 불필요한 영향 인자를 제거한다.

3.2 심층 신경망(Deep Neural Network)

심층 신경망은 은닉층을 2개 이상 지닌 학습 방법으로, 컴퓨터가 스스로 분류레이블을 만들어 내고, 데이터를 구분 짓는 과정을 수없이 반복하여 최적의 결과값을 도출해낸다(LeCun et al., 2015). 특히 회귀분석과 데이터 분석에서 널리 사용되어 산사태 발생 확률 예측 수행에 적합한 모델이다(Haykin, 2009; Brownlee, 2016; Bui et al., 2020; Dao et al., 2020). 심층 신경망의 구조는 Fig. 2와 같이 입력층, 은닉층, 출력층으로 나누어진다. 먼저 입력층을 통해 은닉층으로 전달이 되면 은닉층의 생성으로 많은 시행착오를 반복 하며 활성화 함수를 통해 출력층을 도출한다. 또한 신경망 모델들은 선형분류의 한계가 있어 이를 보완하기 위해 마지막에 활성화 함수를 통해 결과값을 출력한다. 이와 같은 활성화 함수에는 Sigmoid, ReLu, Softmax 등 다양한 활성화 함수가 사용되고 있지만, 결과물의 정확도를 향상시키기 위해서는 적절한 활성화 함수를 사용해야 한다(Nwankpa et al., 2018; Mehta et al., 2020; Yingying et al., 2006; Wang et al., 2020). 따라서 심층 신경망의 구조에서 은닉층의 노드 수와 활성화 함수를 선택하는 작업을 수행하였다. 마지막으로 출력층은 산사태가 발생할 확률과 발생하지 않을 확률을 추론하는 두 개의 출력층으로 구성되었다.

Fig. 4. Conditioning Factors

3.3 ROC method

일반적으로 산사태 민감도 지도를 검증할 때 ROC (Receiver Operating Characteristics) 기법을 활용한다(Gariano et al., 2015; Lee and Kim, 2017). ROC 기법은 모델의 결과와 산사태 발생자료를 통해 모델의 정확도를 평가하는 방법이고 Fig. 5와 같이 산정한다. 1에 가까울수록 성능이 우수함을 나타낸다. Probability of Detection (POD)는 Eq. (1)과 같이 True Positive (TP)를 True Positive (TP)와 False Negative (FN)을 더 한 값으로 나누어서 구하며, 예측의 정확성을 보여준다. Probability of False Detection (POFD)는 Eq. (2)와 같이 False Positive (FP)를 False Positive (FP)와 True Negative (TN)을 더한 값으로 나누어서 구하며, 예측의 오류를 보여준다.

$$POD = \frac{TP}{TP + FN} \quad (1)$$

$$POFD = \frac{FP}{FP + TN} \quad (2)$$

여기서 True Positive (TP)는 모델의 결과에서 산사태가 발생 예측한 곳에 실제 산사태가 발생한 경우, False Negative (FN)은 산사태가 발생하지 않는다고 예측하였는데 실제 산사태가 발생한 경우이다. False Positive (FP)는 산사태가 발생한다고 예측하였는데 실제 산사태가 발생하지 않은 경우, True Negative (TN)은 산사태가 발생하지 않는다고 예측하였는데 실제 산사태가 발생하지 않은 경우이다.

또한 AUC (area under the curve)는 ROC 곡선의 아래 면적을 산정한 값으로, 예측값의 정확성을 정량적으로 평가하기 위한 방법이다. 훈련 데이터 70%의 산사태 자료를 통해 성공률(Success rate)을 구하고, 검증 데이터 30%의 산사태 자료를 통해 예측률(Prediction rate)을 계산하고 성공률 곡선의 AUC보다 예측률 곡선의 AUC 값이 높게 산정되면

Fig. 5. Analysis of ROC (Lee and Kim, 2017)

모델이 합리적임을 의미한다.

4. 연구 결과 및 토론

먼저 다중공선성 분석을 Table 1과 같이 수행하였다. VIF (허용오차) 값의 범위는 1.026~1.523이고, TOL (분산팽창요인) 값은 0.656~0.975로 분석되었다. 이와 같은 결과는 임계값들 $VIF > 10$ 또는 $TOL < 0.1$ 을 충족하며 8개의 산사태 영향 인자간에 다중공선성이 없음을 보여주었다. 그리고 8개의 산사태 영향 인자들에 대한 상관성 분석을 위해 변수 중요도 분석을 Fig. 6과 같이 수행하였다. 영향 인자 모두 중요한 인자로 분석되었고, 특히 Drainage proximity와 Soil depth에 비해 DEM, Aspect, Slope, Curvature, STI, Soil type 이 더 중요한 영향 인자임을 알 수 있었다.

심층 신경망에서 최적의 은닉층 노드 수를 결정하기 위해 Fig. 7과 같이 은닉층의 노드 수에 따른 성능을 비교하였다. 훈련 데이터에서 은닉층 1개에 대한 AUC는 39.5%, 은닉층 2개는 70%, 은닉층 3개는 40%로 산정되었다. 그리고 검증 데이터에서 은닉층 1개에 대한 AUC는 77.5%, 은닉층 2개는 81.7%, 은닉층 3개는 78.4%로 평가되어 훈련 데이터와 검증 데이터 모두 은닉층 2개에서 높은 성능을 보였다.

또한 ReLu, Sigmoid, Softmax의 세 가지 활성화 함수를

Table 1. Multicollinearity Test Result

Conditioning factors	VIF	TOL
Elevation	1.523	0.656
Aspect	1.026	0.975
Slope	1.382	0.724
Curvature	1.269	0.788
Drain proximity	1.431	0.699
STI	1.308	0.765
Soil depth	1.456	0.687
Soil type	1.075	0.930

Fig. 6. The Importance of Conditioning Factors

Fig. 7. AUC Values at Different Number of Hidden Layer

Fig. 8. AUC Values at Different Activation Functions

Fig. 9. Landslide Spatial Probability Obtained from DNN Model

사용하여 심층 신경망의 성능을 Fig. 8과 같이 비교평가를 하였다. 비교한 결과 훈련 데이터에서 ReLu는 70%, Sigmoid는 58.4%, Softmax는 45.7%의 AUC가 산정되었다. 그리고 검증 데이터에서 ReLu는 81.7%, Sigmoid는 75.4%, Softmax는 53.1%의 AUC를 나타내었다. 따라서 ReLu 활성화 함수가 훈련 데이터와 검증 데이터 모두 높은 AUC 값을 보여주었다. 이와 같은 분석결과는 Wang et al. (2020)과 Nguyen and Kim (2021)의 연구 결과와 일치하며, ReLu 활성화 함수를 사용하는 것이 효율적임을 알 수 있다. 따라서 본 연구에서는 8개의 입력층, 2개의 은닉층, ReLu 활성화 함수, 2개의 출력층 구조를 사용하여 심층 신경망을 수행하였다.

Fig. 9는 본 연구에서 제안된 심층 신경망을 통해 평가된 산사태 발생 확률지도이다. 산사태 발생 확률 범위는 0에서 1까지로, 1에 가까울수록 산사태 발생 확률이 높음을 의미한다. 이와 같은 결과를 훈련 데이터와 검증 데이터를 기반으로 심층 신경망의 성능을 ROC 기법을 통해 Fig. 10과 같이 분석하였다. Fig. 10(a)는 훈련 데이터의 성공률 곡선, Fig. 10(b)는 검증 데이터의 예측률 곡선으로 성공률의 AUC는 70%, 예측률의 AUC는 81.7%로 분석되었다. 따라서 예측률

곡선이 성공률 곡선보다 11.7% 높게 계산되어 심층 신경망이 합리적임을 보여주었다.

다음으로 심층 신경망을 통해 평가된 산사태 발생 확률지도를 산사태 발생 위험 등급으로 분류하기 위해 산사태 민감도 지수로 분류한 후 기하학적 간격 기법을 사용하여 Fig. 11(a)와 같이 산사태 민감도 지도로 제작하였다. 산사태 민감도 지도는 매우 낮음(VL), 낮음(L), 보통(M), 높음(H), 매우 높음(VH)과 같이 총 5단계의 산사태 위험 등급으로 나타내었다. 각 민감도 등급의 분포는 Fig. 11(b)와 같다. 매우 낮음(VL)은 28.3%, 낮음(L)은 23.2%, 보통(M)은 22%, 높음(H)은 20.3%, 매우 높음(VH)은 6.2%로 분석되었다.

또한 민감도 지도의 통계적 유의성을 평가하기 위해 Table 2와 같이 카이제곱 테스트를 수행하였다. 카이제곱 검정은 산사태 민감도 등급의 면적이 유의한 수준인 5%에서 완전히 무작위라고 가정하였고, 결과는 카이제곱값이 26.94으로 3.84을 초과하고 모든 p 값이 0.05보다 낮음을 보여주었다. 따라서 제작된 산사태 민감도 지도가 통계적으로 유의한 것으로 판단된다. 따라서 심층 신경망을 이용한 산사태 민감도 분석은 합리적임을 확인하였다. 추후 연구대상 지역 이외

(a) Success-rate curve of training data

(b) Predicted-rate curve of validation data

Fig. 10. Analysis of ROC

(a) Classified landslide susceptibility map

(b) Percent of area of each susceptibility class

Fig. 11. Landslide susceptibility map

Table 2. The Chi-Square Test Result

Model	Chi-square value	p value	Significant level
DNN	26.94	0.000	Yes

에도 적용하여 검증된다면 산사태 민감도 지도를 제작하는데 중요한 기법으로 활용될 것으로 기대된다.

5. 결 론

본 연구는 부산 황령산을 대상으로 구축된 산사태 영향 인자 DB를 기반으로 딥러닝 알고리즘 중 하나인 심층 신경망(Deep Neural Network)을 사용하여 산사태 발생 확률을 평가하였고 다음과 같은 결론을 얻었다.

- 1) 8개의 영향 인자들에 대한 상관성 분석을 위해 다중공선성 분석과 변수 중요도 분석을 수행하였다. 다중공선성 분석 결과 VIF (허용오차) 값의 범위는 1.026~1.523, TOL (분산팽창요인) 값은 0.656~0.975로 VIF > 10 또는 TOL < 0.1을 충족하며 영향 인자간에 다중공선성이 없음을 보여주었다. 그리고 변수 중요도분석 결과 8개의 영향 인자 모두 중요한 인자로 분석되었고, 특히 Drainage proximity와 Soil depth에 비해 DEM, Aspect, Slope, Curvature, STI, Soil type이 더 중요한 영향 인자임을 알 수 있었다.
- 2) 심층 신경망의 최적 은닉층 수와 활성화 함수를 선택하기 위해 은닉층의 노드수와 활성화 함수에 대한 성능 비교평가를 수행하였다. 2개의 은닉층, ReLu 활성화 함수를 사용할 때 훈련 데이터 및 검증 데이터의 AUC가 높게 산정되었다. 따라서 심층 신경망의 구조는 8개

영향 인자의 입력층, 2개의 은닉층, ReLu 활성화 함수를 사용하여 산사태가 발생할 확률과 발생하지 않을 확률을 추론하는 2개의 출력층으로 구성되었다.

- 3) 심층 신경망을 통해 평가된 산사태 발생 확률은 훈련 데이터와 검증 데이터를 기반으로 ROC 기법을 통해 성능 분석을 하였다. 성공률의 AUC는 70%, 예측률의 AUC는 81.7%로 성공률 보다 11.7% 높게 분석되어 심층 신경망의 성능이 합리적임을 보여주었다. 그리고 산사태 발생 확률 지도는 기하학적 간격 기법을 사용해서 5가지{매우 낮음(VL), 낮음(L), 보통(M), 높음(H), 매우 높음(VH)} 등급으로 분류하여 산사태 민감도 지도를 제작하였다. 각 민감도 등급의 분포는 매우 낮음(VL)은 28.3%, 낮음(L)은 23.2%, 보통(M)은 22%, 높음(H)은 20.3%, 매우 높음(VH)은 6.2%로 분석되었다. 또한, 카이제곱 테스트를 통해 통계적으로 유의함을 알 수 있었다.

감사의 글

본 연구는 국토교통부/국토교통과학기술진흥원의 지원으로 수행되었고(21TSRD-B151228-03), 또한 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원(No. 20201510100020)으로 수행되었으며, 이에 깊은 감사를 드립니다.

References

- Abella, E.A.C., and Van Westen, C.J. (2007). *Generation of a landslide risk index map for cuba using spatial multi-criteria evaluation*. Landslides.
- Akgun, A. (2012). A comparison of landslide susceptibility maps produced by logistic regression, multi-criteria decision, and likelihood ratio methods: A case study at İzmir, Turkey. *Landslides*, Vol. 9, No. 1, pp. 93-106.
- Alkhasawneh, M.S., Ngah, U.K., Tay, L.T., Isa, M., Ashidi, N., and Al-Batah, M.S. (2014). Modeling and testing landslide hazard using decision tree. *Journal of Applied Mathematics*, Vol. 2014, Article ID. 929768.
- Bai, S.-B., Wang, J., Lü, G.-N., Zhou, P.-G., Hou, S.-S., and Xu, S.-N. (2010). GIS-based logistic regression for landslide susceptibility mapping of the Zhongxian segment in the Three Gorges area, China. *Geomorphology*, Vol. 115, No. 1-2, pp. 23-31.
- Bai, S., Wang, J., Thiebes, B., Cheng, C., and Yang, Y. (2014). Analysis of the relationship of landslide occurrence with rainfall: A case study of Wudu County, China. *Arabian Journal of Geosciences*, Vol. 7, No. 4, pp. 1277-1285. <https://doi.org/10.1007/s12517-013-0939-9>
- Brownlee, J. (2016). *Deep learning with python: Develop deep learning models on theano and tensorflow using keras*. Machine Learning Mastery.
- Bui, D.T., Lofman, O., Revhaug, I., and Dick, O. (2011). Landslide Susceptibility Analysis in the Hoa Binh Province of Vietnam Using Statistical Index and Logistic Regression. *Natural hazards*, Vol. 59, No. 3, p. 1413.
- Bui, D.T., Ho, T.-C., Pradhan, B., Pham, B.-T., Nhu, V.-H., and Revhaug, I. (2016). GIS-based modeling of rainfall-induced landslides using data mining-based functional trees classifier with AdaBoost, Bagging, and MultiBoost ensemble frameworks. *Environmental Earth Sciences*, Vol. 75, No. 14, p. 1101.
- Bui, D.T., Tuan, T.A., Klempe, H., Pradhan, B., and Revhaug, I. (2016). Spatial prediction models for shallow landslide hazards: a comparative assessment of the efficacy of support vector machines, artificial neural networks, kernel logistic regression, and logistic model tree. *Landslides*, Vol. 13, No. 2, pp. 361-378.
- Bui, D.T., Tsangaratos, P., Nguyen, V.T., Liem, N.V., and Trinh, P.T. (2020). Comparing the prediction performance of a Deep Learning Neural Network model with conventional machine learning models in landslide susceptibility assessment. *Catena*, Vol. 188, pp. 1004426.
- Catani, F., Lagomarsino, D., Segoni, S., and Tofani, V. (2013). Landslide susceptibility estimation by random forests technique: sensitivity and scaling issues. *Natural Hazards and Earth System Sciences*, Vol. 13, No. 11, pp. 2815-2831.
- Chen, W., Pourghasemi, H.R., and Zhao, Z. (2017). A GIS-based comparative study of Dempster-Shafer, logistic regression and artificial neural network models for landslide susceptibility mapping. *Geocarto International*, Vol. 32, No. 4, pp. 367-385.
- Chen, W., Pourghasemi, H.R., Kornejady, A.K., and Zhang, N. (2017). Landslide spatial modeling: Introducing new ensembles of ANN, MaxEnt, and SVM machine learning techniques. *Geoderma*, Vol. 305, pp. 314-327.
- Choi, J.C., and Paik, I.S. (2002). Study on Analysis for Factors Inducing the Whangryeong Mountain Landslide. *The Journal of Engineering Geology*, Vol. 12, No. 2, pp. 137-150.
- Dao, D.V., Jaafari, A.J., Jaafari, A., Bayat, M., Davood, M.G., Qi, C., et al. (2020). A spatially explicit deep

- learning neural network model for the prediction of landslide susceptibility. *CATENA*, Vol. 188, pp. 104451.
- Das, I., Stein, A., Kerle, N., and Dadhwal, V.K. (2012). Landslide susceptibility mapping along road corridors in the Indian Himalayas using Bayesian logistic regression models. *Geomorphology*, Vol. 179, pp. 116-125.
- Ermini, L., Catani, F., and Casagli, N. (2005). Artificial Neural Networks applied to landslide susceptibility assessment. *Geomorphology*, Vol. 66, No. 1-4 SPEC. ISS., pp. 327-343. <https://doi.org/10.1016/j.geomorph.2004.09.025>
- Gariano, S.L., Brunetti, M.T., Iovine, G., Melillo, M., Peruccacci, S., Terranova, O., et al. (2015). Calibration and Validation of Rainfall Thresholds for Shallow Landslide Forecasting in Sicily, Southern Italy. *Geomorphology*, Vol. 228, pp. 653-665.
- Haykin, S.S. (2009). *Neural networks and learning machines*. Simon Haykin.
- Jibson, R.W. (2011). Methods for assessing the stability of slopes during earthquakes—A retrospective. *Eng. Geol.*, Vol. 122, No. 1-2, pp. 43-50.
- Kavzoglu, T., Sahin, E.K., and Colkese, I. (2014) Landslide susceptibility mapping using GIS-based multi-criteria decision analysis, support vector machines, and logistic regression. *Landslides*, Vol. 11, pp. 425-439.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature*, Vol. 521, No. 7553, p. 436.
- Lee, J.S., and Kim, Y.T. (2017). Development of Optimum Rainfall Threshold to Predict of Rainfall-induced Landslides Occurrence. *Korean Society of Hazard Mitigation*, Vol. 17, No. 6, pp. 333-340.
- Lee, S., Hong, S.-M., and Jung, H.-S. (2017). A support vector machine for landslide susceptibility mapping in Gangwon Province. Korea. *Sustainability*, Vol. 9, No. 1, p. 48.
- Lee, S., Hong, S.-M., and Jung, H.-S. (2018). GIS-based groundwater potential mapping using artificial neural network and support vector machine models: The case of Boryeong city in Korea. *Geocarto International*, Vol. 33, No. 8, pp. 847-861.
- Lee, S.R., and Oh, H.J. (2019). Landslide Susceptibility Prediction using Evidential Belief Function, Weight of Evidence and Artificial Neural Network Models. *Korean Journal of Remote Sensing*, Vol. 35, No. 2, pp. 299-316.
- Mehta, D.B., Barot, P.A., and Langhnoja, S.G. (2020). Effect of Different Activation Functions on EEG Signal Classification based on Neural Networks. *2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC)*, pp. 132-135.
- Nguyen, B., Lee, S., and Kim, Y. (2020). Spatial probability assessment of landslide considering increases in pore-water pressure during rainfall and earthquakes: Case studies at Atsuma and Mt. Umyeon. *CATENA*, Vol. 187, pp. 104317.
- Nguyen, B.Q.V., and Kim, Y.T. (2021). *Regional-scale landslide risk assessment on Mt. Umyeon using risk index estimation*. Landslides. <https://doi.org/10.1007/s10346-021-01622-8>
- Nwankpa, C., Ijomah, W., Gachagan, A., and Marshall, S. (2018). Activation functions: Comparison of trends in practice and research for deep learning. *ArXiv Preprint ArXiv:1811.03378*.
- Peng, L., Niu, R., Huang, B., Wu, X., Zhao, Y., and Ye, R. (2014). Landslide susceptibility mapping based on rough set theory and support vector machines: A case of the Three Gorges area, China. *Geomorphology*, Vol. 204, pp. 287-301.
- Pradhan, A.M., and Kim, Y.T. (2017). Spatial data analysis and application of evidential belief functions to shallow landslide susceptibility mapping at Mt. Umyeon, Seoul, Korea. *Bulletin of Engineering Geology and the Environment*, Vol. 76, pp. 1263-1279.
- Pradhan, B. (2013). A comparative study on the predictive ability of the decision tree, support vector machine and neuro-fuzzy models in landslide susceptibility mapping using GIS. *Computers & Geosciences*, Vol. 51, pp. 350-365.
- Tian, Y., Xu, C., Hong, H., Zhou, Q., and Wang, D. (2019). Mapping earthquake-triggered landslide susceptibility by use artificial neural network (ANN) models: an example of the 2013 Minxian (China) Mw 5.9 event. *Geomatics, Natural Hazards and Risk*, Vol. 10, pp. 1-25.
- Tsangaratos, P., and Ilia, I. (2016). Comparison of a logistic regression and Naïve Bayes classifier in landslide susceptibility assessments: The influence of models complexity and training dataset size. *Catena*, Vol. 145, pp. 164-179.
- Van Westen, C.J. (2000). The Modelling Of Landslide Hazards Using Gis. *Surveys in Geophysics*, Vol. 21, pp. 241-255.

- Wang, Y., Li, Y., Song, Y., and Rong, X. (2020). The Influence of the Activation Function in a Convolution Neural Network Model of Facial Expression Recognition. *Applied Sciences*, Vol. 10, No. 5, p. 1897.
- Xu, C., Xu, X., Dai, F., and Saraf, A.K. (2012). Comparison of different models for susceptibility mapping of earthquake triggered landslides related with the 2008 Wenchuan earthquake in China. *Computers & Geosciences*, Vol. 46, pp. 317-329.
- Yang, B., Yin, K., Lacasse, S., and Liu, Z. (2019). Time series analysis and long short-term memory neural network to predict landslide displacement. *Landslides*, Vol. 16, No. 4, pp. 677-694.
- Yilmaz, I. (2010). Comparison of landslide susceptibility mapping methodologies for Koyulhisar, Turkey: conditional probability, logistic regression, artificial neural networks, and support vector machine. *Environmental Earth Sciences*, Vol. 61, No. 4, pp. 821-836.
- Yingying, L., Guodong, L., Qiang, G., and Yonghai, X. (2006). Radial Basis Function Neural Network Based Comprehensive Evaluation for Power Quaility. *International Conference on Power System Technology (ICPST)*, pp. 1-4.

Received	■	April 12, 2021
Revised	■	April 12, 2021
Accepted	■	April 21, 2021