Deep Learning을 활용한 산사태 결정론 방법의 활용성 고찰

Application of Deterministic Method for Landslide Susceptibility with Deep Learning

민대홍* · 윤형구**

Min, Dae-Hong*, and Yoon, Hyung-Koo**

Abstract

A method for estimating landslide susceptibility based on the analytic hierarchy process (AHP) was developed in 2017 as a deterministic method. The objective of this study is to verify the reliability of the proposed method by applying deep learning to improve the applicability of the method. The AHP-based deterministic method comprises eight factors: fines content, soil thickness, porosity, elastic modulus, shear strength, hydraulic conductivity, saturation, and water content. After dividing the testing area into 1 m square grids, eight factors were derived through field and laboratory experiments. The factor of safety was calculated based on the Mohr-Coulomb failure theory. Finally, the input and output values of deep learning were obtained. Bayesian regularization was applied among gradient descents to improve the learning efficiency when applying machine learning. The actual and predicted factors of safety were compared, and they showed excellent reliability in both the training and test phases. This study demonstrates that the AHP-based deterministic method with deep learning is valuable for determining landslide risk areas.

Key words : Bayesian Regularization, Deep Learning, Deterministic Method, Landslide, Susceptibility

요 지

산사태 위험지역을 결정론적인 방법으로 도출할 수 있는 Analytic Hierarchy Process (AHP) 기반의 선행 연구가 2017년도에 제안되었다. 해당 연구의 목적은 기존에 제안된 결정론적인 방법의 활용성을 향상시키고자 deep learning 기법을 적용하여 해당 방법의 신뢰성을 검증하는 것이다. AHP 기반의 결정론적인 방법은 8개 인자인 세립분 함량, 표토층 두께, 간극비, 탄성계수, 전단강도, 투수계수, 포화도 그리고 함수비로 구성되며 이를 통해 안전율을 도출할 수 있다. 대상 지역을 1 m 정사각형의 격자로 구성한 후 현장 및 실내 실험을 통해 8개의 인자를 도출하였다. 안전율은 Mohr-Coulomb의 파괴 이론을 통해 계산하여 deep learning의 출력 값으로 활용하였다. Deep learning 기법 적용 시 입력 값과 출력 값의 학습 능력을 향상시키기 위하여 경사하강법 중 Bayesian regularization을 적용하였으며, 학습 결과 실제 안전율과 deep learning 기법으로 예측된 안전율이 train과 test 단계 모두에서 우수한 신뢰성을 보여준다. 해당 연구에서 활용한 deep learning 기법이 산사태 위험지역 선정에 결정론적 방법으로 유용하게 이용될 것으로 사료된다.

핵심용어 : 결정론적 방법, 산사태, 위험성, Bayesian Regularization, Deep Learning

1. 서 론

산사태 위험지역을 결정하기 위해서는 대표적으로 확률론적(Probabilistic) 및 결정론적(Deterministic) 방법이 활용되고 있으며, 확률론적인 방법은 역사적인 기록 데이터를

통해 기준 값을 설정하고 기준 보다 초과 여부를 통해 산사태 발생 여부를 예측하는 방법이다(Wang et al., 2014). 해당 방법은 기준 값을 설정하기 위한 강우량 등 다수의 데이터가 필요하며 해당 지역의 지형학적 특성도 신뢰성에 중요한 영향을 미친다. 반면 결정론적인 방법은 GIS 기반의 격자를

*정회원, 대전대학교 건설안전공학과 박사과정(E-mail: mdh3689@naver.com)

Member, Ph.D. Candidate, Department of Construction Safety Engineering, DaeJeon University

**교신저자, 정회원, 대전대학교 건설안전공학과 교수(Tel: +82-42-280-2578, Fax: +82-42-280-2576, E-mail: hyungkoo@dju.ac.kr)

Corresponding Author, Member, Associate Professor, Department of Construction Safety Engineering, DaeJeon University

구분 한 후 파괴 이론에 기초하여 정량적인 안전율을 산정하는 것으로 대상 지역의 다양한 지질, 지반 및 식생 특성이 결과의 신뢰를 좌우한다(Ba et al., 2018; Chen et al., 2020). 결정론적 방법은 다양한 입력 인자를 결정해야 하는 한계가 있어 이를 개선하고자 Jun et al. (2017)은 실험기반으로 도출할 수 있도록 지반공학 물성치에 국한하여 산사태 위험성 평가에 주요 영향을 미치는 인자를 전문가 의견 조사 후 AHP 분석으로 제안하였다. 지반공학 물성치 중 산사태 전문가들이 산사태 발생에 가장 중요하다고 판단하는 인자는 세립분 함량, 표토층 두께, 간극비, 탄성계수, 전단강도, 투수계수, 포화도 그리고 함수비로 나타났으며, Jun et al. (2017)은 중요도 분석을 통해 각 인자들의 가중치 값을 결정하였다. 즉, 8개 독립 변수를 결정 후 가중치 값을 통해 종속 변수인 안전율 값을 산출할 수 있도록 Eq.을 제안하였다. 하지만, 각 독립 변수가 고유하게 가지고 있는 값의 범위가 상이하고 단위도 차이가 있어 결정된 가중치를 통해 일률적으로 종속 변수를 계산하기에는 한계가 있다. 따라서 해당 연구에서는 회귀에 탁월한 성능이 있는 Deep learning 기법을 활용하여 독립 변수와 종속 변수의 관계를 고찰하고자 하였다. 토사재해가 발생하는 강우강도를 수리모형실험을 통해 검증하거나 저감시설의 성능에 대해 검토하였다.

해당 연구는 AHP 기반으로 구축된 결정론적인 방법인 Jun et al. (2017)의 연구결과를 이론적 배경에 설명하였으며, 해당 연구에서 중점적으로 활용한 Deep learning 방법에 대해서도 서술하였다. 일반적으로 활용하고 있는 경사하강법을 개선하고 우수한 성능이 나타날 수 있도록 해당 연구에서 활용한 Bayesian regularization 방법에 대해서도 추가적으로 설명하였다. 최종적으로 격자로 구성된 대상현장에서 획득한 입력 인자에 대해 묘사한 후 Deep learning 기법으로 예측된 안전율과 파괴 이론으로 계산된 안전율 간의 관계를 비교 후 고찰하였다.

2. 배경이론

2.1 AHP 기반의 결정론 방법

Jun et al. (2017)은 결정론적 방법의 한계를 극복하고자 AHP 기법을 통해 토석류 발생과 밀접한 연관이 있는 인자를 결정하였다. 토석류 발생에 가장 민감한 영향을 보이는 지반공학 물성치 범주를 1) Soil structure & particle distribution, 2) Stress & strain of soil 그리고 3) Soil & Water로 구분한 후 각 범주에 해당되는 다양한 물성치 중 전문가 자문그룹을 통해 주요 물성치를 선정하였다. 선정된 주요 물성치는 총 8개로 세립분 함량, 표토층 두께, 간극비, 탄성계수, 전단강도, 투수계수, 포화도 그리고 함수비이다. 결정된 항목의 신뢰성은 Consistency ratio (CR)를 이용하였으며, 그 값은 0.0022로 나타났다. 일반적으로 CR 값은 0.1 미만이면 우수한 응답률이라고 판단한다(Dweiri et al., 2016). 또한 각

물성치들의 중요도를 고려하여 각 인자들의 가중치 값을 결정하였으며 이를 통해 위험도를 평가할 수 있도록 하였다. 각 물성치들의 단위가 상이하여 각각 값의 범위로 Scored index도 제안하였지만, 여전히 가중치에 대한 한계가 있어 활용성이 부족한 실정이다. 따라서 본 연구에서는 선택된 8개의 위험인자는 입력 인자로 활용하고 최종 값은 안전율로 설정하여 Deep learning을 진행하고자 하였다. 안전율은 참 값을 도출해야 하므로 일반적으로 활용성이 높은 Mohr-Coulomb의 파괴이론을 기반으로 무한 사면의 안정성 평가에 이용되는 Eq. (1)을 이용하였다(Hammond et al., 1992).

$$Factor\ of\ safety = \frac{C_{root} + C_{soil} + \cos^2\theta[\rho_{soil} \times g(D - D_{water}) + (\rho_{soil} \times g - \rho_{water} \times g)D_{water}]}{\tan\Phi / [D \times \rho_{soil} \times g \times \sin\theta \times \cos\theta]} \quad (1)$$

Eq. (1)에서 C [N/m²]는 점착력을 의미하며 θ [°]와 Φ [°]는 사면 경사각과 마찰각을 보여준다. ρ [kg/m³]는 단위중량이며, D [m]는 표토층의 두께이다. g는 중력가속도인 9.81 [m/s²]를 의미하며 밑첨자 root, soil, water는 식생 뿌리, 토양 그리고 지하수를 의미한다.

2.2 Deep learning

본 연구에서는 입력 값과 출력 값 간의 관계를 규명하기 위하여 비선형 함수 기반의 회귀분석에 용이한 Deep learning 기법을 이용하였으며, 반복 연산을 통해 최적의 해를 구하고자 하였다. 기본 구조는 Eq. (2)와 같으며 출력 값(Output)은 최적 상태의 가중치(Weight)와 편향(Bias)로 결정된다.

$$Output(x) = weight \times x + bias \quad (2)$$

여기서, x는 입력 값을 의미한다.

인공신경망(Neural network)는 Deep learning 기법의 일환으로 여러 개의 함수로 구성된 Network의 분류 및 회귀 문제를 해결하는데 이용되며(Rosenblatt, 1958), 역전파(Back propagation)를 통한 반복 학습으로 최적의 출력 값을 도출할 수 있다. 역전파는 Feedforward를 통해 도출된 출력 값의 오차를 역방향으로 전파시켜 각 층의 가중치를 업데이트하는 방법이며, 최소 오차에 도달할 때까지 반복 학습을 수행한다(Chauvin and Rumelhart, 1995). 이때 반복학습을 수행하는 함수를 활성화 함수(activation function)로 정의하며 사용자의 목적에 따라 다양한 비선형 함수가 적용된다(Jung et al., 2018; Ryu and Kwak, 2020). 인공신경망은 Fig. 1과 같이 입력층과 출력층으로 구성되며 두개의 층 사이에 단계적으로 심층 연산을 수행 할 수 있는 은닉층이 포함되어 최적의 해를 도출할 수 있다.

비용 함수는 예측 값과 실제 값의 차이를 통해 Deep learning 결과를 정량적으로 표현하기 위해 사용하며, Eq.

(3)과 같이 출력값(Output)과 실제 데이터 값(Real value)의 차이에 제곱으로 계산된다. 이 값은 2차 포물선 형태의 분포를 보이며, 편미분을 통해 기울기 값이 최소가 되는 지점은 경사하강법(Gradient descent)이 활용된다.

$$Cost\ Function(w,b) = \frac{1}{m} \sum_{i=1}^m (output(x_i) - real\ value_i)^2 \quad (3)$$

해당 연구에서는 MacKay (1992)에 의해 제안된 Bayesian regularization 기법을 활용하였으며, 이는 가중치와 편향이 Random variable을 따라 결정될 수 있도록 Hessian matrix와 Bayesian 이론을 기반으로 한다(Sariev and Germano, 2020).

따라서 입력 데이터를 기반으로 신뢰성 있는 가중치를 결정할 수 있도록 Eq. (4)와 같이 확률밀도함수 기반의 우도함수 (Likelihood function)가 이용된다.

$$P(weight|Data, \alpha, \beta, NM) = \frac{P(Data|Weight, \beta, NM) P(weight|\alpha, NM)}{P(Data|\alpha, \beta, NM)} \quad (4)$$

여기서 Weight는 가중치, Data는 입력 데이터 그리고 α 와 β 는 상수 값을 의미한다. NM은 Deep learning에 활용된 Network model을 보여준다.

3. 현장 실험 및 시료 채취

해당 연구에서는 약 5년전에 이미 토석류가 발생한 세종시 인근의 OO산을 대상 사면으로 결정하였으며, Fig. 2와 같이 수치표고모델(DEM) 결과 대상지역의 표고는 약 82~114 m로 분포하는 것으로 나타났다. AHP 기반의 결정론 Eq.의 입력 상수를 얻고자 현장 실험(전기비저항 탐사, 탄성과 탐사, 동적 콘관입시험 그리고 TDR)과 실내 실험(체분석 및 함수비)을 수행하였다. 탄성과 탐사와 전기비저항 탐사는 Fig. 2와 같이 계곡부 전체를 포함할 수 있도록 4개의 측선(Line 1~4)을 설정하였다. 탄성과 탐사의 지오폰 간격은 2 m로 설정하였으며, 가진원은 일반적으로 활용하는 Drop hammer를 이용하였다. 전기비저항은 수직 탐사에 분해능이 좋은 Wenner

Fig. 1. Architecture of Deep Learning

Fig. 2. Site Description of this Study. The Line 1, 2, 3 and 4 Show the Profiles Performed by Elastic and Electrical Resistivity Survey. The L1A, L1B, L1C, L1D, L1E, L1F, L1G, L1H, L1I, L1J, L2A, L2B, L3A, L3B, L4A, L4B Denote the Positions for Dynamic Cone Penetration, TDR and Extracted Soil

배열 방법으로 탐사를 진행하였다. 동적 콘관입시험과 TDR 은 탄성과 전기비저항 실험이 진행된 동일한 축선에서 약 10 m 간격으로 진행되었으며 각각 총 16개(L1A~J, L2A, L2B, L3A, L3B, L4A, L4B)의 원위치 실험이 수행되었다. 또한 시료채취는 원위치 탐사와 동일한 지역에서 수행 후 실내에서 체분석 및 함수비 측정 실험을 진행하였다.

4. 실험 결과

현장에서 수행한 전기비저항 탐사, 탄성과 탐사, 동적 콘관입시험 그리고 TDR 결과와 시료 채취로 도출한 세립분 함량 및 함수비 결과는 Fig. 3에 도시하였다. 실험 결과는 AHP 기반 결정론 Eq.의 독립 변수에 활용하였으며, 참 값인 안전율도 도출할 수 있도록 Eq. (1)의 입력 상수로도 이용하였다.

전기비저항과 탄성과 측정 결과 중 L1에 해당하는 결과를 Figs. 3(a)와 3(b)에 도시하였다. 전기비저항 결과는 심도 약 3 m까지 1,000 $\Omega \cdot m$ 이상의 고비저항대를 보이며, 심도가

깊어 갈수록 500 $\Omega \cdot m$ 이하의 저비저항대가 나타났다. 거리 0~45 m의 심도 10 m 이하는 100 $\Omega \cdot m$ 대의 저비저항대가 나왔으며, 대상 부분이 사면의 하부에 해당되어 지하수가 집수되는 지점으로 인해 낮은 값이 나타난 것으로 판단된다. 전기비저항 결과는 AHP 기반 결정론 Eq. 중 간극율과 투수 계수 환산에 활용하였다. 간극율은 Archie's law를 이용하였으며 이때 포화도는 TDR로 도출된 값을 이용하였다(Archie, 1942; Byun et al., 2014). 또한 투수계수는 간극률과 투수계수의 관계인 Kozeny-carman Eq.을 이용하였으며, 이때 간극률은 측정된 전기비저항으로 환산하였다. 또한 Kozeny-carman Eq.의 타 입력 값은 Lee and Yoon (2020)에서 활용한 값을 이용하였다. 최종적으로 도출된 간극율과 투수계수는 각각 0.4~0.9 그리고 $2 \times 10^{-6} \sim 2 \times 10^{-4}$ cm/s로 나타났다. 탄성과 탐사 결과는 문헌 값을 통해 심도 약 3 m 및 그 이후를 봉적층과 연암층으로 구분하여 도시하였으며(Whiteley and Greenhalgh, 1979) 봉적층의 깊이를 통해 표토층 두께를 도출하였다. 해당 사면의 표토층 두께는 0.2~1.2 m의 두께로 분포하는 것으로 나타났으며, 이 값은 AHP Eq.과 안전율 계산 Eq.의

Fig. 3. Experiment Results Performed by Field and Laboratory

입력 인자로 활용하였다. Fig. 3(c)는 동적 콘관입시험 결과이며, 타격당 관입 깊이를 나타내는 DCPI [mm/blow]로 도시하였다. 해당 결과는 사면의 상부와 하부를 단면으로 구성하는 L1 축선의 결과이며 상부, 중부, 하부로 구분하여 나타내었다. 상부는 약 800 mm에서 최종타격 되었으며, 중부와 하부는 약 500 mm 및 1,050 m까지 타격을 수행하였다. 동적 콘관입시험 결과의 최종 타격 심도는 탄성과 결과로 도출한 표토층 두께와 유사한 범위의 값을 보여주는 것으로 나타났다. 측정된 DPCI는 Tsuchida et al. (2011)이 제안한 경험식을 통하여 전단강도와 탄성계수로 환산하였으며, 각각의 범위는 2.4~3.5 kPa와 93.9~160.3 kPa로 계산되었다. 또한 TDR로 측정된 결과는 거리계수 기반의 유전상수를 유추한 후 Topp et al. (1980)이 제안한 방법으로 포화도를 계산하여 Fig. 3(d)에 도시하였으며, 환산된 값은 L1축선에서 21.5~63.5%의 범위로 나타났다.

L1 지역에서 시료 채취 후 수행한 함수비 측정 실험의 결과는 Fig. 3(d)에서 확인할 수 있으며 11.6~37.8% 값을 보여준다. 또한 체분석 결과 대상 사면의 세립분 함량은 시료 채취 위치마다 다소 상이한 범위를 보여주며 L1 축선에서 도출된 값의 범위는 2.0~10.0%이며 Fig. 3(e)에 도시하였다.

5. 데이터 구성

Deep learning을 수행하기 위해서는 Fig. 1과 같이 입력값과 출력값이 필요하며, 해당 연구에서 입력값은 AHP 기반의 결정론 Eq.을 구성하는 8개 인자이며 출력 값은 Eq. (1)로 계산된 안전율이다. 안전율 계산시 필요한 점착력, 사면 각사각 및 마찰각 등은 기존에 동일지역에서 수행된 Choo et al. (2019)의 선행 연구결과를 참고하여 결정하였다. 해당 사면은 공간적인 분포를 고려한 상세한 거동을 이해하고자 1 m 간격으로 격자를 나누어 총 1,800개의 그리드로 구성하였다. 하지만 현장 실험과 실내 실험이 수행된 지역이 23개소이므로 데이터 구성에 한계가 있어 데이터 증폭을 위해 지구통계학 기법을 적용하였다. 따라서 지구통계학 기법을 통해 나머지 격자의 데이터를 유추하였으며, 이를 위해 각 물성치에 적합한 확률 기반의 베리오그램(Variogram)을 도출하였다. 각각의 베리오그램은 물성치마다 상이한 Nugget, Sill 그리고 Range를 가지고 있으며, Fig. 4와 같이 물성치 자체의 값이 큰 전단 강도가 Nugget과 Sill 값이 높게 나타났다. Nugget은 탄성계수와 전단강도가 각각 0.0001 (최소)과 30,000 (최대)으로 추정되었으며 나머지 인자는 모두 0으로 절편 값이 없는 것으로 나타났다. Sill은 5.5×10^{-9} ~120,000 범위로 큰 편차를 보이며, Range 값은 약 9.6~132 범위로 함수비가 가장 큰 영향범위를 보였다. 표토층 두께와 간극률은 상대적으로 낮은 영향범위를 보이는 것으로 나타났다. 또한 8개 인자 모두 Spherical 함수를 통해 데이터의 분포 경향을 유추하였다. 이를 통해 지구통계학의 Kriging 기법을

Fig. 4. Distributions of Variogram

적용하여 1,800개의 데이터 분포를 등고선 형태로 Fig. 5에 도시하였다. 도출된 2D 주상도는 각 물성치의 최대 및 최소 값과 베리오그램에 따라 상부, 중부 그리고 하부에서 다소 상이한 경향을 보였으며, 이는 각 물성치의 공간적 분포 상관성에 차이로 판단된다. 하지만 각 주상도는 대체적으로 상부에서 하부로 갈수록 입력 값이 낮은 범위로 분포하는 것을 알 수 있으며 이미 토석류가 발생한 지역이므로 상부의 토양이 하부로 퇴적되어 느슨한 상태의 값을 보이는 것으로 보인다. 이와 같이 1,800개의 격자에서 도출된 물성치를 AHP 기반의 결정론 Eq.의 독립변수로 활용하여 Deep learning 기법을 적용하였다.

6. 결 과

Deep learning은 Fig. 6과 같은 순서를 통해 진행하였으며, 입력 값에서 출력 값을 도출하기 위해서는 데이터 분할, 활성 함수, 은닉 층 그리고 최적화 방법이 필요하다. 데이터 분할은 일반적으로 활용하고 있는 holdout 방법을 선택하였으며, Training, Validation 그리고 Test 비율을 각각 70%,

Fig. 5. Kriging Results of Input Variables

15% 그리고 15%로 결정하였다. 활성 함수와 노드 수는 하이퍼파라미터 튜닝(Hyperparameter tuning)을 통해 비선형 거동에 적합한 Sigmoid와 100을 선정하였다. 도출된 출력값은 낮은 비용 함수 값이 도출될 수 있도록 반복 학습에 용이한 역전파 방법이 활용되었으며, 해당 논문은 역전파의 효율을 높이기 위해 확률밀도함수 기반의 우도함수로 표현되는 Bayesian regularization 방법을 활용하였다. 이와 같은 과정을 통해 도출된 출력값인 안전율 분포를 Fig. 7에 도시하였으며, 비교를 위하여 Eq. (1)로 계산된 안전율 값도 함께 도시하였다. 안전율을 결정하기 위하여 활용한 방법에 차이가 있어 등고선의 분포는 다소 차이가 있지만 전체적으로 도출된 안전율의 분포는 유사한 범위의 색을 보여준다. 두개의 분포도 모두 상부와 하부는 낮은 안전율 분포(약 1~1.5)를

보이며 중부는 상대적으로 높은 범위인 약 1.8~2.0의 안전율 범위로 나타났다. 정량적인 비교를 수행하기 위하여 1,800개 격자에서 계산된 안전율 값을 기반으로 RMSE 값을 도출하였으며, 이를 Fig. 8에 도시하였다. RMSE 값은 0.001~0.099의 범위를 보이며 평균은 0.001로 계산되었다. 해당 논문에서 사용한 결정론 Eq.에 Deep learning 기법을 연계한 방법론은 타 지역에 적용을 통해 신뢰성을 검증해야 하나 데이터를 추가적으로 측정해야 하는 한계가 있어, 해당 논문에서는 타 연구에서 수행한 Deep learning 기반의 위험도를 평가한 논문의 결과를 활용하여 비교하였다. 따라서 해당 연구와 동일한 방법론을 활용한 Van Dao et al. (2020), Ghasemian et al. (2020) 그리고 Nhu et al. (2020)에서 도출된 RMSE를 이용하였다. Van Dao et al. (2020)는 풍화도, 경사각 및 종횡비

Fig. 6. Flowchart of Deep Learning in this Study

Fig. 7. Distributions of Safety Factor

등 대상 현장에서 도출한 총 9개의 인자에 Deep learning을 적용하여 위험도를 계산하였으며 Ghasemian et al. (2020)은 각 격자에서 sediment transport index (STI)와 topographic wetness index (TWI)를 도출한 후 CART 및 RepTree의 Machine learning 모델을 통해 위험성을 예측하였다. 또한 Nhu et al. (2020)은 경사각, 고도, 차도와의 거리 등 17개의 인자로 구성된 입력값에 AdaBoost 및 Alternating decision tree 기법으로 위험도를 예측하였다. Van Dao et al. (2020),

Fig. 8. Comparison of RMSE Based on this Study and Previously Performed Studies

Ghasemian et al. (2020) 그리고 Nhu et al. (2020) 연구결과에서 도출된 RMSE의 평균값은 Fig. 8과 같이 각각 0.387, 0.192 그리고 0.321로 나타났으며, 비교 결과 해당 연구에서 수행한 RMSE 값(0.001)이 상대적으로 낮게 나온 것을 알 수 있다. 또한 선행 연구에서 수행된 RMSE 범위는 0.331~0.450, 0.117~0.235 그리고 0.212~0.443로 오차 범위도 해당 연구의 결과(0.001~0.099)가 작게 나타났다. 이와 같은 결과는 AHP 기반의 결정론 Eq.에 deep learning 적용 시 신뢰성 높은 위험도 평가를 정량적으로 제공할 수 있음을 보여준다.

7. 결론

해당 연구는 AHP를 통해 선정된 산사태 위험인자에 Deep learning 기법을 이용하여 대상 지역의 안전율 분포를 예측하

였으며, 세분화된 결론은 다음과 같다.

- AHP의 8개 인자(세립분 함량, 표층 두께, 간극률, 탄성 계수, 전단강도, 투수계수, 포화도 그리고 함수비)를 구축하기 위해 현장 및 실내 실험을 수행하였으며, 공간적 분포를 기반한 kriging을 통해 딥러닝 예측 성능 향상에 적합한 Data set 구축 방안을 제시하였다.
- Deep learning 기법의 정확성을 높이기 위해 최적화 기법 중 Bayesian regularization 알고리즘을 사용하였으며 이를 통해 1,800개의 격자로 구성된 해당 지역의 신뢰성 높은 안전율 예측 결과를 도출하였다.
- 해당 연구와 유사한 방법으로 수행된 선행 연구와 오차를 값을 비교하여 신뢰성을 검증하였으며, 해당 연구는 상대적으로 작은 RMSE 값을 보여 제안된 기법으로 산사태 위험성을 정량적으로 도출할 수 있는 가능성을 보여준다.

감사의 글

본 연구는 국토교통부/국토교통과학기술진흥원의 지원으로 수행되었으며, 이에 감사드립니다(과제번호: 21CTAP-C164152-01).

References

- Archie, G.E. (1942). The electrical resistivity log as an aid in determining some reservoir characteristics. *Transactions of the AIME*, Vol. 146, No. 1, pp. 54-62.
- Ba, Q., Chen, Y., Deng, S., Yang, J., and Li, H. (2018). A comparison of slope units and grid cells as mapping units for landslide susceptibility assessment. *Earth Science Informatics*, Vol. 11, No. 3, pp. 373-388.
- Byun, J.H., Park, C.H., Won, K.S., and Yoon, H.K. (2014). Estimation of Porosity Based on the Electrical Resistivity. *J. Korean Soc. Hazard Mitig.*, Vol. 14, No. 3, pp. 163-169.
- Chauvin, Y., and Rumelhart, D.E. (Eds.). (1995). *Backpropagation: theory, architectures, and applications*. Psychology press.
- Chen, L.K., Chang, C.H., Liu, C.H., and Ho, J.Y. (2020). Application of a three-dimensional deterministic model to assess potential landslides, a case study: Antong Hot Spring Area in Hualien, Taiwan. *Water*, Vol. 12, No. 2, pp. 480.
- Choo, H., Min, D.H., Sung, J.H., and Yoon, H.K. (2019). Sensitivities of input parameters for predicting stability of soil slope. *Bulletin of Engineering Geology and the Environment*, Vol. 78, No. 8, pp. 5671-5685.
- Dweiri, F., Kumar, S., Khan, S.A., and Jain, V. (2016). Designing an integrated AHP based decision support system for supplier selection in automotive industry. *Expert Systems with Applications*, Vol. 62, pp. 273-283.
- Ghasemian, B., Asl, D.T., Pham, B.T., Avand, M., Nguyen, H.D., and Janizadeh, S. (2020). Shallow landslide susceptibility mapping: A comparison between classification and regression tree and reduced error pruning tree algorithms. *Vietnam Journal of Earth Sciences*, Vol. 42, No. 3, pp. 208-227.
- Hammond, C.J., Prellwitz, R.W., and Miller, S.M. (1992, February). Landslide hazard assessment using Monte Carlo simulation. *Proceedings of 6th international symposium on landslides*, Christchurch, New Zealand, Balkema, Vol. 2, pp. 251-294.
- Jun, H., Min, D.H., and Yoon, H.K. (2017). Determination of monitoring systems and installation location to prevent debris flow through web-based database and AHP. *Marine Georesources & Geotechnology*, Vol. 35, No. 8, pp. 1049-1057.
- Jung, S.H., Lee, D., and Lee, K. (2018). Prediction of River Water Level Using Deep-Learning Open Library. *J. Korean Soc. Hazard Mitig.*, Vol. 18, No. 1, pp. 1-111.
- Lee, S.J., and Yoon, H.K. (2020). Hydraulic Conductivity of Saturated Soil Medium through Time-Domain Reflectometry. *Sensors*, Vol. 20, No. 23, pp. 1-17.
- MacKay, D.J. (1992). The evidence framework applied to classification networks. *Neural computation*, Vol. 4, No. 5, pp. 720-736.
- Nhu, V.H., Mohammadi, A., Shahabi, H., Ahmad, B.B., Al-Ansari, N., Shirzadi, A., et al. (2020). Landslide susceptibility mapping using machine learning algorithms and remote sensing data in a tropical environment. *International Journal of Environmental Research and Public Health*, Vol. 17, No. 14, pp. 4933.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, Vol. 65, No. 6, pp. 359-408.
- Ryu, J., and Kwak, D. (2020). A study on flame and smoke detection algorithm using convolutional neural network based on deep learning. *J. Korean Soc. Hazard Mitig.*, Vol. 20, No. 1, pp. 223-132.
- Sariev, E., and Germano, G. (2020). Bayesian regularized artificial neural networks for the estimation of the probability of default. *Quantitative Finance*, Vol. 20, No. 2, pp. 311-328.
- Topp, G.C., Davis, J.L., and Annan, A.P. (1980). Electromagnetic

- determination of soil water content: Measurements in coaxial transmission lines. *Water Resources Research*, Vol. 16, No. 3, pp. 574-582.
- Tsuchida, T., Athapaththu, A.M.R.G., Kano, S., and Suga, K. (2011). Estimation of in-situ shear strength parameters of weathered granitic (Masado) slopes using lightweight dynamic cone penetrometer. *Soils and Foundations*, Vol. 51, No. 3, pp. 497-512.
- Van Dao, D., Jaafari, A., Bayat, M., Mafi-Gholami, D., Qi, C., Moayedi, H., et al. (2020). A spatially explicit deep learning neural network model for the prediction of landslide susceptibility. *Catena*, Vol. 188, pp. 1-13.
- Wang, X., Frattini, P., Crosta, G.B., Zhang, L., Agliardi, F., Lari, S., and Yang, Z. (2014). Uncertainty assessment in quantitative rockfall risk assessment. *Landslides*, Vol. 11, No. 4, pp. 711-722.
- Whiteley, R.J., and Greenhalgh, S.A. (1979). Velocity inversion and the shallow seismic refraction method. *Geoexploration*, Vol. 17, No. 2, pp. 125-141.

Received	■	August 8, 2021
Revised	■	August 9, 2021
Accepted	■	August 17, 2021