

미시추 구간의 지반 층상정보 예측을 위한 정규 크리깅 및 인공신경망 기법의 비교

Comparison of Ordinary Kriging and Artificial Neural Network for Estimation of Ground Profile Information in Unboring Region

전 찬 준¹⁾ · 최 창 호²⁾ · 조 진 우[†]

Chanjun Chun · Changho Choi · Jinwoo Cho

Received: November 13th, 2018; Revised: November 16th, 2018; Accepted: February 18th, 2019

ABSTRACT : A large amount of site investigation data is essential to obtain reliable design value. However, site investigations are generally insufficient due to economic problems. It is important to estimate the ground profile information in unboring region for accurate earthwork-volume prediction, and such ground profile information can be estimated by using the geo-statistical approach. Furthermore, the ground profile information in unboring region can be estimated by training a model via machine learning technique such as artificial neural network. In this paper, artificial neural network-based model estimated the ground profile information in unboring region, and this results were compared with that of ordinary kriging technique, which is referred to the geo-statistical approach. Accordingly, a total of 84 ground profile information in an actual bridge environment was split into 75 training and 9 test databases. The observed ground profile information of the test database was compared with those of the ordinary kriging technique and artificial neural network.

Keywords : Site investigation, Ground profile, Earthwork-volume, Ordinary kriging, Artificial neural network

요 지 : 정확한 토공량 설계를 위해서는 충분한 량의 지반조사 자료가 필요하나 비용적인 문제로 인하여 제한적인 지반조사가 수행되고 있다. 정확한 토공량 예측을 위해서 지반의 층상정보를 추정하는 것은 중요한 사항이며, 이러한 제한적인 지반조사 데이터로부터 정확한 토공량 예측을 위해서는 지구통계학적(geo-statistical) 분석방법으로 지반 층상정보를 예측할 수 있다. 또한, 기시추된 지반 층상정보를 활용하여 기계학습을 통하여 모델을 학습하여 미시추된 지반 층상정보를 예측할 수도 있는데, 본 논문에서는 인공신경망을 통하여 미시추된 지반 층상정보를 예측하고 기존의 정규 크리깅 기법과 성능을 비교한다. 이를 위하여, 84공의 지반 층상정보를 활용한다. 84공의 지반 층상정보의 데이터셋 중에서 75공을 학습 데이터셋으로 활용하였고, 나머지 9공을 검증 데이터셋으로 활용하였다. 검증 데이터셋의 실측된 지반 층상정보와 정규 크리깅 기법과 인공신경망으로 예측된 지반 층상정보를 비교 분석한다.

주요어 : 지반조사, 지반층상, 토공량, 정규크리깅, 인공신경망

1. 서 론

정확한 토공량 예측을 위해서는 3차원 지형정보 내 지질 주상도, 지반 특성 등의 속성정보 입력이 중요하나 충분한 데이터 확보가 어려운 실정이다. 불확실성 및 변동성이 큰 지반에서 선 단위의 시추정보로부터 공간단위의 연속적인 지반속성의 구분은 어려운 일이며, 설계자의 공학적 판단에 의한 지반속성의 결정방법은 경험적·통계적 방법에 의한 예측방법으로서 실제 현장의 조건과 많은 오차가 발생하며, 이로 인하여 공사물량이 대폭 증감하여 재설계가 필요한 사례가 빈번하게 발생하고 있다. 이렇듯 정확한 토공량 예측

을 위해서 지반의 층상정보를 추정하는 것은 중요한 사항이며, 이러한 지반 층상정보를 예측하기 위해서는 면적 혹은 거리에 대비하여 보간(interpolation)하는 방법과 지구통계학적(geo-statistical) 분석방법으로 지반 층상정보를 예측할 수 있다. 보간방법에 있어서는 역거리가중치법(Inverse Distance Weighting, IDW)이 널리 활용되고 있으며, 지구통계학적인 방법에 있어서 대표적인 것은 크리깅(kriging) 기법이다(Isaaks & Srivastava, 1989). 두 가지 방법 모두 시추된 구간의 층상정보를 통하여 미시추된 구간의 지반 층상정보 예측이 가능하다.

역거리가중치법은 단순한 거리 요소만을 적용하는 방법

1) Research Specialist, Construction Automation Research Center, Korea Institute of Civil Engineering and Building Technology

2) Research Fellow, Construction Automation Research Center, Korea Institute of Civil Engineering and Building Technology

† Senior Researcher, Construction Automation Research Center, Korea Institute of Civil Engineering and Building Technology

(Corresponding Author : jinucho@kict.re.kr)

으로 공간정보 변동의 통계적인 특성을 적절하게 반영하지는 못한다. 지구통계학적인 접근 방법인 크리깅은 주위에 알려진 값들의 선형조합(linear combination)을 통하여 미지 값을 예측하는데, 먼저 크리깅을 수행하기 위해서는 공간정보의 상관관계를 분석하는 과정이 필요하다. 이러한 공간정보의 상관관계를 분석하는 방법은 베리오그램(variogram) 모델링을 통하여 얻을 수 있다. 베리오그램의 특성은 문턱값(sill), 상관거리(range), 너깃(nugget)에 의해서 결정되어지며, 여기에서 가우시안(gaussian)의 형태를 따르는지, 지수(exponential) 형태를 따르는지, 구(spherical) 형태를 따르는지 결정함으로써 베리오그램 모델링이 가능하다(Isaaks & Srivastava, 1989). 구체적인 크리깅 방법에 대한 내용은 다음 2장에서 자세히 기술하도록 한다.

최근 인공지능망(Artificial Neural Network, ANN) 기반으로 이루어진 기술들이 여러 분야에서 높은 성능을 보이며 널리 활용되고 있다(Goodfellow et al., 2016). 인공지능망이란 인간의 뉴런 구조를 본떠 만든 기계학습의 하나의 방법론으로 몇 개의 신경망 층을 만들고, 각각의 신경망 안에 있는 뉴런에 들어온 신호를 가중치와 곱해서 더한 다음에 다음 뉴런으로 전송하는 형태를 지닌다. 여기서, 입력 신호에 대하여 선형 조합만을 수행하기 때문에 비선형 함수를 취하기 위하여 활성화 함수(activation function)를 선형 조합 다음에 취하는 것이 일반적이다. 인공지능망은 지도 학습(supervised learning)과 비지도 학습(unsupervised learning)으로 모두 활용될 수 있으며, 두 분야 모두에서 탁월한 성능을 보이고 있는 추세이다. 지도 학습이란 주어진 입력 데이터와 레이블 된(labeled) 데이터를 쌍으로 가지고 있고, 이를 통하여 신경망 모델을 학습한 뒤, 일반적인 회귀분석(regression) 혹은 분류(classification) 문제를 풀 수 있는 학습 방법을 가리킨다(Goodfellow et al., 2016). 특정 현장에서 미시추된 지반 층상정보를 예측하는 것은 이미 알고 있는 시추된 지점의 위치정보와 층상정보를 쌍으로 활용하여 인공지능망을 통하여 지도 학습 방법으로 모델 생성이 가능하다.

인공지능을 활용한 지반정보 예측에 관한 연구사례로는 토층 심도(Min & Yoon, 2018), 표준관입시험 N값(Samui & Sitharam, 2010), 유기물 함량(Dai et al., 2014), 세굴 심도(Rahman et al., 2010), 지하수위(Tapoglou et al., 2014), 강우량(Seo et al., 2015) 예측에 관한 연구들이 보고되고 있다. 전술한 연구사례들을 분석해 보면 지반이 가지는 공간적 변동성 및 분석에 사용된 데이터가 포함하고 있는 이상치 등으로 인하여 기대만큼의 정확한 예측 성능을 보이지 못할 수 있으며, 이러한 문제의 극복을 위하여 지구통계학적 기법과 인공지능을 결합한 방법을 제시하고 있다.

본 논문에서는 인공지능망 기반으로 지반 층상정보 예측

하는 알고리즘을 제안하며, 이를 정규(ordinary) 크리깅 기법과 비교한다. 이를 위하여, 84공의 지반조사 데이터를 활용하였다. 84공의 지반 층상정보의 데이터셋 중에서 75공을 학습 데이터셋으로 활용하였고, 나머지 9공을 검증 데이터셋으로 활용하였다. 검증 데이터셋의 실측된 지반 층상정보와 정규 크리깅 기법과 인공지능망으로 예측된 지반 층상정보를 비교 분석한다.

2. 지구통계학 기반의 지반 층상정보 예측

공간정보에 있어서 주어진 거리 및 방향에 따라서 데이터 사이의 유사성 혹은 비유사성을 정량화하는 방법 중의 하나를 베리오그램이라고 할 수 있다. 다시 말하자면, 다른 공간위치에서 측정된 데이터 사이의 비유사성을 측정하는 것으로 Eq. (1)과 같이 표현이 가능하다.

$$e(\mathbf{h}) = \frac{1}{2} [z(\mathbf{u}_a) - z(\mathbf{u}_a + \mathbf{h})]^2 \quad (1)$$

여기서, \mathbf{u}_a 와 \mathbf{h} 는 특정 공간위치와 특정 위치로부터 떨어진 지연거리(lag distance)를 각각 가리킨다. 보통 Eq. (1)을 바로 활용하지 않고, 샘플 형태로 바뀌어서 표현하는 것이 일반적이며, 수식은 Eq. (2)와 같다.

$$2\gamma(\mathbf{h}) = \frac{1}{N(\mathbf{h})} \sum_{a=1}^{N(\mathbf{h})} [z(\mathbf{u}_a) - z(\mathbf{u}_a + \mathbf{h})]^2 \quad (2)$$

여기서, $2\gamma(\mathbf{h})$ 를 베리오그램(variogram), $\gamma(\mathbf{h})$ 를 반베리오그램(semi-variogram)이라고 각각 가리킨다. 또한, $N(\mathbf{h})$ 를 시추된 지반 층상정보의 개수라고 볼 수 있다. 샘플 형태로 표시된 베리오그램의 경우 Fig. 1과 같은 모형을 일반적으로 얻을 수 있다.

Fig. 1에서 볼 수 있듯이, 실험적인 베리오그램 데이터를




Fig. 1. Overview of variogram modeling

통해서 실선으로 표시된 베리오그램 형태를 찾는 과정을 베리오그램 모델링이라고 할 수 있으며, 이러한 베리오그램 형태는 문턱값(sill), 상관거리(range), 너깃(nugget)에 의하여 특성이 결정된다고 볼 수가 있다. 문턱값이란 일정거리 이상이면 데이터들의 상관관계가 없다고 보는 베리오그램의 한계를 나타내는 지표이며, 특정 분산값으로 수렴하게 되는데 이를 문턱값이라고 부른다. 상관거리는 데이터들의 상관관계를 보이는 최대거리를 가리키고, 너깃이란 원점에서의 베리오그램 값을 나타낸다. 이론적으로 원점에서는 거리가 0인 경우이므로 주어진 데이터에서도 0으로 수렴하는 것이 맞으나, 불충분한 데이터들 사이에서 상관관계를 도출하는데 한계가 존재하고, 이에 따라 발생할 수 있는 것이 너깃효과(nugget effect)이다. 추가적으로 문턱값에서 너깃값을 뺀 지표를 부분 문턱값(partial sill)이라고 부른다. 베리오그램이 어떠한 분포를 가지는지도 결정을 해주어야 하는데, 이는 가우시안(gaussian), 지수(exponential), 구(spherical) 형태가 일반적이다. 가우시안의 경우에는 Eq. (3)과 같이 표현할 수 있으며,

$$\gamma(h) = p \left[1 - \exp \left(- \frac{h^2}{\left(\frac{4}{7} r \right)^2} \right) \right] + n \quad (3)$$

여기서 p , r , n 을 부분 문턱값, 상관거리, 너깃을 각각 가리킨다. 또한, h 는 지연거리를 의미한다. 지수와 구 형태로 표현할 경우에는 Eq. (4)와 (5)와 같이 표현이 가능하다.

$$\gamma(h) = p \left[1 - \exp \left(- \frac{h}{r/3} \right) \right] + n \quad (4)$$

$$\gamma(h) = \begin{cases} p \left(\frac{3d}{2r} - \frac{d^3}{2r^3} \right) + n, & d \leq r \\ p + n, & d > r \end{cases} \quad (5)$$




Fig. 2. Examples of variogram modeling depending on distribution types

Fig. 2의 경우는 문턱값이 15, 상관거리가 50, 너깃이 5일 경우에 각각의 형태로 베리오그램 모델링을 했을 경우를 보여주며, 실험적으로 얻은 베리오그램 데이터와 가장 유사한 형태의 베리오그램 모델링을 수행한다. 가장 유사한 것을 모델링하는 과정에서 일반적으로 베리오그램을 설계하는 사람의 경험적이고, 주관적인 요소가 반영된다.

이렇게 얻어진 베리오그램 모델 기반으로 크리깅을 수행할 수 있다. 크리깅이란 주위에 알려진 데이터를 활용하여 선형조합을 통하여 미지의 값을 추정하는 방법을 가리킨다. 값을 예측하기 위해서는 가중치를 결정하여야 하며, 가중치를 결정하는 방법에는 여러 가지가 있다(Isaaks & Srivastava, 1989). 단순 크리깅(simple kriging), 정규 크리깅(ordinary kriging), 또한 일반 크리깅(universal kriging) 등이 존재하는데, 본 논문에서는 범용적으로 쓰이고 있는 정규 크리깅을 활용하여 미시추된 지반 층상정보를 예측하였다. 일반적으로 정규 크리깅이 단순 크리깅 기법에 비하여 예측된 결과의 기대치가 높다(Deutsch, 1996). 정규 크리깅에 대한 수식은 Eq. (6)과 같이 표현할 수 있다.

$$z^*(u) - m(u) = \sum_{\alpha=1}^{n(u)} \lambda_{\alpha}(u) [z(u_{\alpha}) - m(u_{\alpha})] \quad (6)$$

여기서, $z^*(u)$ 는 거리에 따른 예측되는 지반 층상정보를 가리키며, $\lambda_{\alpha}(u)$ 는 크리깅 수행하기 위하여 결정되어야 하는 가중치를 나타내며, 아래의 두 수식을 만족하여야 한다.

$$E[z^*(u) - z(u)] = 0 \quad (7)$$

$$\sigma^2(u) = Var[z^*(u) - z(u)] \quad (8)$$

3. 인공지능망 기반의 지반 층상정보 예측

최근 인공지능망(Artificial Neural Network, ANN) 기반으로 이루어진 기술들이 여러 분야에서 높은 성능을 보이며 널리 활용되고 있다(Goodfellow et al., 2016). 인공지능망이란 인간의 뉴런 구조를 본떠 만든 기계학습의 하나의 방법론으로 몇 개의 신경망 층을 만들고, 각각의 신경망 안에 있는 뉴런에 들어온 신호를 가중치와 곱해서 더한 다음에 다음 뉴런으로 전송하는 형태를 지닌다. Fig. 3은 인공신경망의 일반적인 구조를 나타낸다. 총 3개의 층으로 구성되는데, 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)으로 구성된다. 여기서, 은닉층은 여러 층으로 구성될 수도 있으며, 굉장히 많은 층으로 구성되었을 경우에는 신




Fig. 3. Overview of artificial neural network

경망이 깊다고 표현하며, 심층신경망(Deep Neural Network, DNN)이라 표현할 수 있다.

은닉층으로 몇 층으로 구성할지와 뉴런의 유닛수를 결정하여야 하는데, Fig. 3에서는 입력층의 유닛수는 6개, 은닉층은 4개, 출력층은 2개로 구성되어 있다. 입력층과 출력층은 어떠한 데이터를 입력받아서 어떤 정보를 예측하는지에 따라서 유닛수가 결정되어지며, 은닉층의 층수와 유닛수는 가변적으로 가져올 수 있으며, 여러 차례 학습을 통하여 실험적으로 도출할 수 있다. 신경망 안에 있는 유닛들의 관계 수식은 Eq. (9)와 같다.

$$z_j^{n+1} = f\left(\sum_i w_{ji}^n z_i^n\right) \quad (9)$$

여기서, i 와 j 는 각층 유닛수의 인덱스를 가리키며, n 은 층(layer)에 대한 인덱스를 의미한다. w 의 선형 조합을 취한 다음에 활성화 함수(activation function)인 $f(x)$ 를 통하여 다음 층에 있는 뉴런으로 연결되어진다. 여기서, 활성화 함수는 인공신경망 구조가 선형 조합만을 수행하기 때문에 비선형 함수를 취하기 위하여 선형 조합 다음에 취하는 것으로 본 논문에서는 $f(x) = \max(x, 0)$ 의 형태를 가지는 Rectified Linear Unit(ReLU) 함수를 활용하였다(Nair & Hinton, 2010).

신경망 모델은 일반적으로 크게 회귀분석(regression)과 분류(classification) 문제로 나눌 수가 있는데, 본 논문에서 수행하는 지반 층상정보 예측은 연속적인 지반 층상정보를 예측하는 문제이기 때문에 회귀분석에 속한다. 이러한 회귀분석은 비용 함수(loss function)를 최소평균제곱오차(Minimum-Mean-Squared-Error, MMSE) 형태로 구성할 수 있으며, Eq. (10)과 같다(Han et al., 2016).

$$L(\mathbf{w}, \mathbf{b}) = \min\left(\frac{1}{N} \sum_{i=0}^N \|y_i - \hat{y}_i\|_p\right) \quad (10)$$

$$= \min\left(\frac{1}{N} \sum_{i=0}^N \|y_i - f(\mathbf{w}, \mathbf{b}|\mathbf{x})\|_p\right)$$

여기서, y_i 와 \hat{y}_i 는 지반층상 정보의 실측과 예측된 정보를 나타내며, \mathbf{w} 와 \mathbf{b} 는 인공신경망의 가중치와 바이어스, \mathbf{x} 는 입력 데이터를 각각 가리킨다. 또한, p 는 norm의 차수를 나타내며, $p=2$ 일 경우에 l2-norm이라고도 불리는 MMSE 형태로 비용 함수가 결정된다.

Eq. (10)의 비용 함수가 최소화되는 방향으로 가중치와 바이어스를 결정하는 과정을 학습이라고 표현할 수 있다. 가중치를 업데이트하는 방법은 여러 가지 기법이 존재하지만, 본 논문에서는 adaptive moment estimation(ADAM) 기법을 활용하였다(Kingma & Ba, 2015). 어파인(affine) 층과 활성화 함수 사이에 배치 정규화(batch normalization) 레이어를 추가하여 학습의 수렴속도를 가속화시킬 수 있다(Ioffe & Szegedy, 2015). 배치 정규화를 통해서 초기값의 의존도가 떨어지며, 드롭아웃(dropout)이나 정규화(regularization) 작업을 하지 않아도 과적합(overfitting) 되는 현상을 억제하는 효과도 있다. 본 논문에서도 배치 정규화를 수행하였으며, 어파인 층과에 활성화 함수가 나오기 전에 배치 정규화를 수행하였다.

4. 지반 층상정보 예측 결과의 비교

정규 크리깅 기법과 인공신경망 기반으로 지반 층상정보 예측한 결과를 비교하기 위하여 84공의 실측 지반조사 데이터를 활용하였다. 본 예측에서는 지표면에서 풍화암까지의 토층심도를 예측하고자 하였으며, 토층의 평균 깊이는 17.76m, 표준편차 9.07로 변동성이 심한 지형적 특성을 나타내고 있다. 84공의 지반조사 현황도는 Fig. 4와 같다. 그

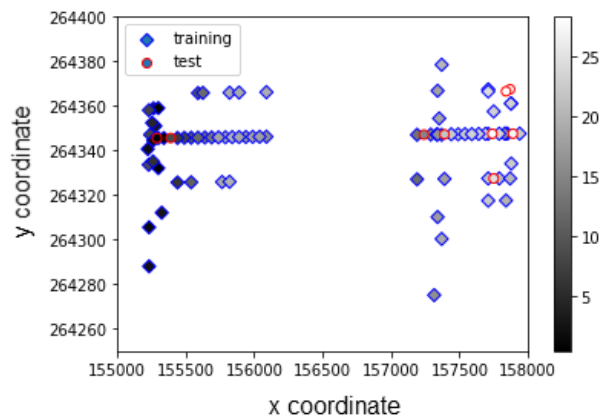


Fig. 4. Ground profile information in boring region

림에서 파란색으로 표시된 75공의 지반 층상정보가 학습 데이터셋으로 활용되었고, 빨간색으로 표시된 9공의 지반 층상정보가 검증 데이터셋으로 활용되었다. 여기서, 9공의 지반 층상정보는 84공의 지반 층상정보 중에 난수 발생을 통하여 임의적으로 선택한 지점이다.

Fig. 5는 정규 크리깅 기법을 위하여 모델링된 베리오그램 결과를 보여준다. 구(spherical) 형태의 베리오그램 분포를 활용하였으며, 여기서의 문턱값, 상관거리, 너짓은 각각 43, 511, 0이다. 베리오그램의 분포 모형과 파라메타의 결정은 가장 높은 정확도를 갖는 모형과 값을 갖도록 반복적으로 수행하면서 도출하였다. 가장 실험적으로 구한 베리오그램 데이터의 문턱값이 계속해서 증가하는 추세가 두 번 반복적으로 나타나고 있는데, 이는 예측에 사용된 데이터가 교량 건설을 위한 지반조사 데이터로 시추위치가 Fig. 4에서 나타나듯이 강을 기준으로 양쪽 교량의 출입구 근방에 밀집되어 있는 형태로 분포되어 있기 때문이다.

Fig. 6은 지반 층상정보를 예측하기 위한 인공신경망의 구조를 나타낸다. 정규 크리깅에서는 2D 크리깅을 활용하느냐, 3D 크리깅을 활용하느냐에 따라서 알고리즘의 복잡도가 크게 달라지며, 추가적인 인자를 쓰는 것은 교차 베리오그램까지 고려해 주어야 하지만, 인공신경망의 경우에는 입력층의 유닛수를 하나만 더 추가해주는 형태로 손쉽게 가




Fig. 5. Result of variogram modeling

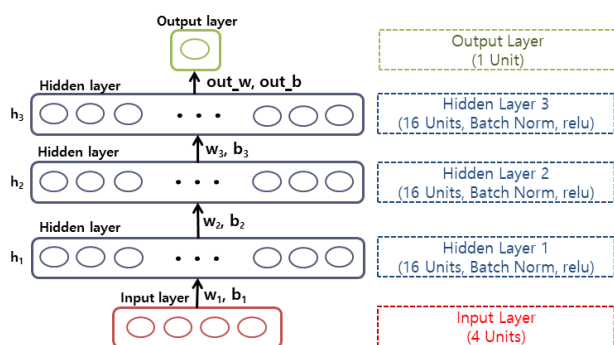


Fig. 6. Architecture of artificial neural network

능하다. Fig. 6에서 볼 수 있듯이 총 입력 유닛수는 4개로 공간정보의 x, y 좌표와 표고라고 할 수 있는 z 좌표, 그리고 지하수위(Ground Water Level, GWL)까지 활용하였다. 은닉층은 총 3층으로 구성하였으며, 총 16개의 은닉 유닛수를 가지도록 구성하였다. 출력층은 예측하고자 하는 지반의 층상정보로 토사층(매립토, 퇴적토, 풍화토)의 두께로 구성하였으며, 하나만 출력하면 되므로 유닛수는 한 개로 구성되어 있다.

Fig. 7은 실측된 지반 층상정보와 정규 크리깅 및 인공신경망을 통하여 예측된 지반 층상정보를 보여준다. 그림에서 볼 수 있듯이 정규 크리깅 및 인공신경망 모두 실측된 지반 층상정보와 유사한 패턴의 결과를 보여준 것을 확인할 가능하다. 이에 대하여 정량적인 수치로 측정하고자 평균제곱근편차(Root-Mean-Squared-Error, RMSE)를 측정하였다. RMSE의 수식은 Eq. (11)과 같다.

$$RMSE(\mathbf{y}, \hat{\mathbf{y}}) = 20 \log_{10} \sqrt{\frac{1}{N} \sum_{n=0}^{N-1} (y(n) - \hat{y}(n))^2} \quad (11)$$

여기서, $y(n)$ 과 $\hat{y}(n)$ 은 실측된 지반 층상정보와 예측된 지반 층상정보를 각각 가리킨다. N 은 예측된 지반 층상정보의 개수를 나타내며, 본 논문에서는 언급하였듯이 9공의 검증 데이터셋을 가지고 실험하였다.

Table 1은 RMSE 결과를 보여준다. 정규 크리깅 기법으로 예측된 지반 층상정보의 RMSE는 6.622dB이고, 인공신경망의 경우에는 14.607dB로 나타났다. 인공신경망의 결과

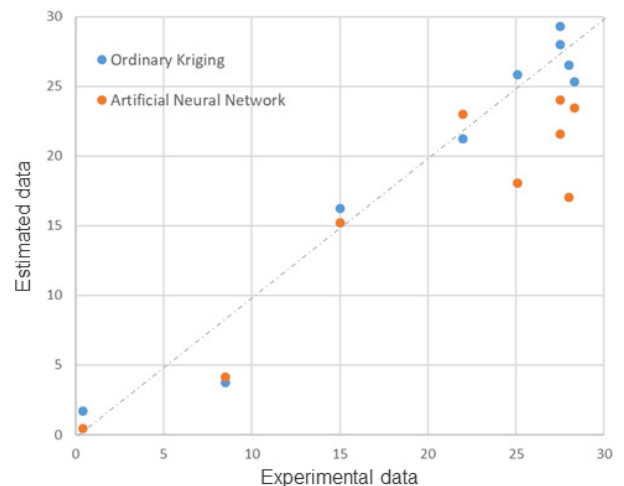


Fig. 7. Result of variogram modeling

Table 1. RMSE results of estimated data

(Unit: dB)	Ordinary kriging	Artificial neural network
RMSE	6.622	14.607

가 정규 크리깅 기법에 비하여 객관적으로 좋은 성능을 보이고 있지는 않지만, Fig. 7에서 나타나듯이 정규 크리깅 기법만큼이나 비슷한 분포 형태로 지반 층상정보를 예측한 것을 볼 수 있다. 지반 층상정보가 깊은 곳에서 인공신경망이 예측한 층상정보가 상대적으로 낮게 나타나는 것을 볼 수 있는데, 이는 신경망 모델이 학습하는 과정에서 베리오그램 모델과 달리 비용함수에서 나오는 비용수치(cost value)만을 쫓아서 나타나는 현상이며, 향후에 다양한 데이터를 활용할 시에 해결할 수 있는 사항으로 사료된다.

5. 결 론

본 논문에서는 정규 크리깅 기법과 인공신경망을 통하여 지반 층상정보(토사층 두께)를 예측하고 이에 대한 성능을 비교하였다. 먼저, 정규 크리깅 기법과 인공신경망에 대하여 개략적인 예측 방법을 기술하였고, 실측된 지반 층상정보를 활용하여 성능을 비교하였다. 총 84공의 지반 층상정보를 75공의 학습 데이터셋과 9공의 검증 데이터셋으로 분리하였다. 정규 크리깅을 수행하기 위하여 베리오그램을 모델링하고 정규 크리깅에 대한 가중치를 도출하였으며, 인공신경망을 학습하기 위하여 신경망 모델을 구성하고 지반 3차원 위치정보와 지하수위 정보를 활용하여 신경망 모델을 학습하였다. 분석결과, 정규 크리깅 기법으로 예측된 지반 층상정보의 RMSE는 6.622dB이고, 인공신경망의 경우에는 14.607dB로 나타났다. 인공신경망의 결과가 정규 크리깅 기법에 비하여 객관적으로 좋은 성능을 보이고 있지는 않지만, 정규 크리깅 기법만큼이나 비슷한 분포 형태로 지반 층상정보를 예측하는 것을 확인할 수 있었으며, 지반 층상정보가 낮은 구간에서는 정규 크리깅 기법에 비하여 정확한 예측값을 나타내었다. 향후, 유의한 추가적인 정보들을 활용하거나, 빅데이터를 활용하여 인공신경망 모델을 고도화할 경우 보다 우수한 예측 성능을 보일 수 있을 것으로 기대한다.

감사의 글

본 논문은 한국건설기술연구원 임무형 주요사업(지능형 가상 지반데이터 및 다짐 관리 기술을 적용한 스마트 토공 플랫폼 개발)의 지원으로 수행되었습니다.

References

1. Dai, F., Zhou, Q., Lv, Z., Wang, X. and Liu, G. (2014), Spatial prediction of soil organic matter content integrating artificial neural network and ordinary kriging in Tibetan Plateau, *Ecological Indicators* 45, pp. 184~194.
2. Deutsch, C. V. (1996), Correcting for negative weights in ordinary kriging, *Computers & Geosciences*, 22(7), pp. 765~773.
3. Goodfellow, I., Bengio, Y. and Courville, A. (2016), *Deep Learning*, MIT Press, Cambridge, MA. pp. 161~263.
4. Han, W., Wu, C., Zhang, X., Sun, M. and Min, G. (2016), Speech enhancement based on improved deep neural networks with MMSE pretreatment features, in *Proc. IEEE 13th International Conference on Signal Processing (ICSP)*, Chengdu, China, DOI: 10.1109/ICSP.2016.7878006.
5. Ioffe, S. and Szegedy, C. (2015), Batch normalization: accelerating deep network training by reducing internal covariate shift, in *Proc. the 32nd International Conference on Machine Learning (ICML)*, Lille, France, pp. 448~456.
6. Isaaks, E. H. and Srivastava, R. M. (1989), *An Introduction to Applied Geostatistics*, Oxford University Press, New York, NY. pp. 278~322.
7. Kingma, D. P. and Ba, J. L. (2015), ADAM: a method for stochastic optimization, in *Proc. 3rd International Conference on Learning Representations (ICLR)*, San Diego, CA, pp. 1~15.
8. Min, D. H. and Yoon, H. K. (2018), Method for Establishment of High Reliable Soil Depth Modeling, *J. Korean Soc. Hazard Mitig.* 18(2), pp. 307~315.
9. Nair, V. and Hinton, G. E. (2010), Rectified linear units improve restricted boltzmann machines, in *Proc. the 27th International Conference on Machine Learning (ICML)*, Haifa, Israel, pp. 807~814.
10. Rahman, H. S., Alireza, K. and Reza, G. (2010), Application of Artificial Neural Network, Kriging, and Inverse Distance Weighting Models for Estimation of Scour Depth around Bridge Pier with Bed Sill, *J. Software Engineering & Application*, 3, pp. 944~964.
11. Samui, P. and Sitharam, T. G. (2010), Site Characterization Model Using Artificial Neural Network and Kriging, *Int. J. Geomech.* 10(5), pp. 171~180.
12. Seo, Y., Kim, S. and Singh, V. P. (2015), Estimating Spatial Precipitation Using Regression Kriging and Artificial Neural Network Residual Kriging (RKNNRK) Hybrid Approach, *Water Resour Manage.* 29, pp. 2189~2204.
13. Tapoglou, E., Karatzas, G. P., Trichakis, I. C. and Varouchakis, E. A. (2014), A spatio-temporal hybrid neural network-kriging model for groundwater level simulation, *Journal of Hydrology*, 519, pp. 3193~3203.