기계학습을 이용한 동상방지층의 온도예측에 관한 연구

Temperature Prediction of Anti-frost Layer using Machine Learning Techniques

손재호* · 서용원** · 박영목*** · 조규태****

Son, Jaeho*, Seo, Youngwon**, Park, Youngmog***, and Cho, Gyutae****

Abstract

In Korea, the temperature falls below 0 °C in winter and rises above 0 °C in spring. This change in temperature between the two seasons results in the ground alternatively freezing and thawing, which leads to road surfaces being damaged. Predicting the ground temperature becomes very important in identifying and responding to potential infrastructure damage due to the ground freezing and thawing. A simulation was conducted through numerical analysis using the Crank–Nicholson differential method to predict the temperature of each layer of a road. Moreover, the data gathered from measuring the temperature at each layer of a road over a period of 42 days in “Evaluation of Validity for Anti-frost Layer and Development of its Construction Criteria,” organized by the Ministry of Land, Transport and Maritime Affairs (2012), were used for the simulation. The training for temperature prediction of the anti-frost layer was performed using deep learning machine learning techniques with 650 days of measurement data by changing the number of hidden layers and nodes. With two hidden layers, 40 nodes, and 100 nodes, the reliability of the training result was close to 1. The reliability of the predictive model, a by-product of the training, was approximately 0.87.

Key words : Anti-frost Layer, Machine Learning, Deep Learning

요 지

우리나라는 겨울철이 되면 기온이 0 °C 이하로 내려가고 지반이 동결되고 팽창되어 도로구조물에 피해를 끼친다. 지반동결로 인한 피해를 사전에 파악하고 대처하기 위해서는 지중온도의 예측은 매우 중요하다. 도로의 각 층의 온도를 예측하기 위하여 크랭크-니콜슨 차분법에 의한 수치해석을 수행하였으며 지중온도를 예측하기 위하여 장기간 도로포장구조물의 온도를 측정한 국토해양부(MLTM, 2012)에서 주관한 “도로 동상방지층의 효용성 검증 및 설치기준 연구”의 포장층별 온도자료를 이용해 인공지능의 한 분야인 기계학습에 의한 수치해석을 통하여 온도예측을 실시하였다. 약 650일의 온도자료를 인공지능의 한분야인 기계학습 중 심층신경망학습을 이용하여 동상방지층의 온도예측을 수행하였고, 히든레이어 수와 노드 수를 변경시켜가며 트레이닝과정을 거쳤다. 히든레이어가 두 개이고 노드의 수가 40, 100 개인 경우 1에 가까운 적합도를 나타냈으며, 트레이닝결과를 이용하여 예측모델을 만들었고 적합도가 0.87인 결과를 나타내었다.

핵심용어 : 동상방지층, 기계학습, 심층신경망학습

*정회원, (주)동명기술공단종합건축사사무소 사원(E-mail: thswogh1992@naver.com)

Member, Staff, Dong Myeong Engineering Consultants & Architecture Co., Ltd.

**영남대학교 건설시스템공학과 교수(E-mail: yseo@ynu.ac.kr)

Professor, Department of Civil Engineering, Yeungnam University

***정회원, 영남대학교 건설시스템공학과 교수(E-mail: ympark@ynu.ac.kr)

Member, Professor, Department of Civil Engineering, Yeungnam University

****교신저자, 정회원, 영남대학교 건설시스템공학과 교수(Tel: +82-53-810-2414, Fax: +82-53-810-4622, E-mail: gtcho@ynu.ac.kr)

Corresponding Author, Member, Professor, Department of Civil Engineering, Yeungnam University

1. 서 론

우리나라는 겨울철의 기온이 0℃이하로 내려간다. 이는 지반을 동결시키는 역할을 하고 동결된 지반은 팽창하여 도로나 구조물과 같은 시설물에 영향을 끼쳐 파손시키거나 수명을 단축시킨다. 또한 기온이 영상으로 바뀌는 봄철이 되면 동결되었던 지반이 녹기 시작한다. 이때 팽창되었던 지반이 다시 수축하면서 지반침하가 생기고 이 또한 시설물에 파손을 야기한다. 이와 같이 지반동결로 인한 피해를 사전에 파악하고 대처하기 위해 정확한 지중온도의 예측은 매우 중요하다.

국내 지중온도 예측에 대한 연구는 다음과 같이 실험적, 이론적 방법 혹은 수리해석에 의한 방법으로 제시되어 왔다. Jeong (2004)은 구미지역에 지중온도를 측정하여 회귀식을 이용한 보정계수를 수정하여 예측값을 제시하였고, Shin et al. (2012)은 경상대학교 교내에 온도센서를 설치하여 지중온도를 측정 후 2차원 비정상 열전도방정식, 수치계산법으로 계산하여 해석하였고, Cho and Ihm (2014)은 창원지역에 실험식(Buggs식)을 사용하여 기상청에서 제공된 지중온도와 비교 분석하여 지중온도를 예측하였으며, Jeong et al. (2015)은 충남 예산지역의 산림토양에 대해 지중온도를 관측하고, FEFLOW모델을 사용하여 지중온도 변화를 모사하였으며, Hwang (2017)은 Newton-Raphson반복계산법을 이용하여 초기지표면 온도로부터 근사해를 구하는 방법을 사용하여 수치 해석적 방법을 제시하고 있다.

그러나 동상방지층을 포함한 지중온도 예측에 대한 연구는 다소 미비한 실정이다. Kim and Hong (2005)은 1991년~2005년까지의 동결심도 측정자료를 이용하여 전국최대 동결심도 분포도를 작성하고 동결심도와 동결지수를 분석하여 동결심도 추정모델을 산정하였고, Hong et al. (2010)은 외국기준의 동상방지층설계값이가 적용되어 국내도로에서는 달라지므로 동결깊이 산정식을 도출하여 동결깊이 모델을 제안하였다. 그러나 이러한 연구는 다양한 조건에 대한 평가가 제시되어 있지 않은 실정이다. 따라서 이에 관련된 추가적인 연구가 요망되는 상황이다.

본 연구에서는 MLTM (2012)의 강원도 원주시의 국도 19호선 천은사 부근의 구축된 현장계측시스템 관측자료를 기초로 하여 Crank-Nicholson 차분법을 이용하여 열확산계수를 추정 및 검증하고 이를 통하여 도로포장층에 나타나는 열확산계수를 제시하였고, 열확산계수를 통하여 포장층의 온도를 예측하였다. 실험데이터와 수치해석 모델을 비교 검증하고 정밀도를 검증하는 데에 목적이 있다.

2. 이론적 배경

2.1 기계학습 및 심층신경망학습

머신러닝, 즉 기계학습은 인공지능의 한 분야로써 컴퓨터

가 학습할 수 있게 하는 알고리즘과 기술을 개발하는 분야이다. 딥러닝, 심층학습의 정의로 여러 비선형 변환기법의 조합을 이용해 보다 높은 수준의 추상화(abstractions)를 시도하는 기계학습(machine learning) 알고리즘의 집합이다. 추상화란 매우 복잡한 자료나 무수히 많은 양의 데이터들 속에서 핵심적인 내용 또는 기능을 요약하는 작업을 말한다. 넓게 보면 컴퓨터에게 사람의 인식, 사고하는 방식을 컴퓨터에 입력하는 기계학습의 한 분야라고 말할 수 있다.

딥러닝으로 대표되는 인공신경망(Artificial neural network)은 머신러닝을 구현하는 기술 중의 하나로 사람의 뇌의 동작 방식에서 착안하여 개발한 학습방법이다. 인공신경망은 뉴런의 동작원리에서 기초한다. Fig. 1은 실제 뉴런과 인공 뉴런을 설명하고 있다.

Fig. 1. Actual Neurons and Artificial Neurons (Kim, 2017)

가지돌기에서 신호를 받고, 축삭돌기를 통해 축삭말단으로 전달되는 뉴런의 기본동작과 같이 입력값인 X에 가중치 W를 곱하고 편향 b를 합하여 활성화 함수(ReLU 등)를 거쳐 결과값(y)를 만들어 내는 것이 인공뉴런의 기본이며 Eq. (1)과 같다. 원하는 학습값 y를 찾기 위해 W와 b를 변경해가면서 최적값을 찾는 최적화과정을 거친다. 이러한 과정을 학습(learning) 또는 훈련(Training)이라고 부른다.

$$y = ReLU(X \times W + b) \quad (1)$$

여기서 y는 출력값, ReLU는 활성화함수, X는 입력값, W는 가중치, b는 편향이다.

본 연구에서 신경망의 모형은 $Y = WX + b$ 의 단순한 형태를 가지고 있다. 여기서 Y는 설명하고자 하는 종속변수 벡터를 나타내고, X는 Y를 설명하기 위한 종속변수를 나타낸다. b는 오차(bias)를 나타내는 매개변수이다. 히든레이어가 하나 추가되면 위 모형은 중첩되어 $Y = W_1(W_0X + b_0) + b_1$ 로 나타낼 수 있다. 히든레이어가 추가되며 선형 회귀로 설명할 수 없는 비선형 현상에 대한 설명이 가능해지며, 히든레이어의 개수가 두 개 이상인 경우의 모형을 심층신경망(deep layer neural network)이라 하며 이 경우 기계학습 즉, 머신러닝을 딥러닝(deep learning)이라 부른다. Fig. 2는 인공뉴런들

Fig. 2. Artificial Neural Network and Deep Neural Network (Kim, 2017)

을 연결해 구성한 인공신경망과 히든레이어가 2개 이상인 심층신경망의 모형을 나타내고 있다.

본 연구에서는 머신러닝을 위한 인공신경망을 3단계로 개발하였다. 히든레이어가 한 개인 경우, 히든레이어가 두 개인 경우, 히든레이어가 세 개인 경우로 3단계이다. 각 단계별로 히든레이어의 노드수와 트레이닝횟수를 적절히 조절하며 모형을 적용하였다.

3. 도로 동상방지층 현장계측

3.1 계측기설치

본 연구에서 적용된 Data는 MLTM (2012)에서 얻은 자료이다. 현장계측시스템은 Fig. 3과 같으며 국도19호선 천은사 부근에 구축되어 있다. 강원도 원주시 국도19호선 현장계측시스템은 절토부, 절성경계부 및 저성토부로 구성되어 있고, 설치 단면은 Fig. 5와 같다.

Fig. 3. Gangwon-Wonju Road site (Gwiraе-Madge) Location Map

Fig. 4는 Fig. 3의 A-A' 단면을 나타낸 것이다. 또한 절토부와 절성경계부, 저성토부의 계측기 설치는 본선 구간내에 모두 위치하고 있다.

Fig. 4. Gangwon-Wonju Road site (Gwiraе-Madge) Measurement System Location

Table 1은 절토부, 절성경계부, 저성토부의 단면에 대한 계측 센서별 매설 깊이를 나타낸 것이다. 강원도 원주시 현장계측시스템은 계측 센서, 수집장치(컨트롤 박스), 태양열 전원장치로 구성되어 있으며, 각 층 별 계측센서 배치는 Fig. 5와 같다.

Table 1. Gangwon - Wonju Road site Cutting area, Boundary Area of Cutting and Baking, Low Banking Measurement Sensor Embedded Position

Category	Depth	Measuring Instrument	
		Moisture	Temp
Concrete	15.0 cm	-	2
Lean concrete	7.5 cm	-	2
Subbase layer	15.0 cm	3	2
Anti-frost layer	20.0 cm	3	2
Road	15.0 cm	3	2
Total number		9	10

Fig. 5의 센서설치 단면은 콘크리트 포장 단면인 린 콘크리트 층과 보조기층 중앙부에 온도센서를 매설하였고, 도로 하부 층에 매설된 함수센서는 각층에 매설된 센서 간 간섭작용을 최소화하기 위해 지그재그 형태로 매설하였다.

Fig. 5. Sensor Installation Section (Function, Temperature sensor)

MLTM (2012)에서 강원도 원주시 국토19호선 현장계측 시스템은 2009년 1월 6일 절토부 단면을 시작으로 현장계측 자료를 지속적으로 수집하고 있으며, 2012년 6월 30일까지 수행된 약 42개월간의 현장계측 데이터를 수집하였다.

현장계측시스템으로부터 얻어진 현장계측 데이터는 온도와 함수비로 분류가 되며, 온도계측 데이터는 포장층별 온도분포 특성 분석 및 동결깊이를 분석하는데 이용되며, 함수비분포 데이터(Volumetric Moisture Content, VMC)는 겨울철 노상도 동결특성을 분석하는데 이용된다. 강원도 원주시 현장계측분석에 이용된 강수량데이터는 기상청의 원주 기상대 자료를 활용하였다.

3.2 계측센서

현장 계측시스템에 적용된 계측센서는 Table 2와 같으며, 함수센서는 포장층하부의 함수비를 측정한다. 현장계측에서 적용된 T3 Probe와 CS616은 유전율의 비저항을 사용하는 Time domain reflectometry (TDR) 방식의 함수계측 센서이다. TDR 방식은 다른 방식보다 정밀도가 매우 우수하며, 오랜 시간동안 자동 계측과 수동 계측이 가능하다.

현장 계측시스템에 사용된 온도센서는 도로포장체의 내부 온도를 계측하며, 표층과 기층, 보조기층, 동상방지층 그리고 노상에 설치하였다. 현장계측시스템에 사용된 온도센서는 thermocouple K-type이며, 측정범위가 -100 °C에서 400 °C이고, 온도계측에 많이 사용되고 있는 모델이다.

Table 2. Measurement Sensor Type

Category	Model	Sensor Photo	Sensor Description	Manufacture
Moisture Sensor	CS616		TDR system Manual and Automatic measurement	Campbell (U.S.A)
	T3 Probe		TDR system Manual measurement	IMKO (Germany)
Temperature Sensor	Thermocouple		The Atmosphere and Packaging layer Temperature Measurement Sensor	YAMARI (Japan)

4. 기계학습 모델

수치해석은 이전 층의 온도를 경계값으로 사용하였고 k 값을 변경하여 가장 높은 신뢰도를 가지는 k 값에 대한 온도를 그림으로 나타내었다. 각 그림에 대한 설명은 다음과 같다.

본 연구에서는 K값을 구하기 위하여 Crank-Nicholson 차분법을 이용하여 수치해석을 하였다.

Fig. 6은 각 구간별 표층의 대기온도, 측정온도, 계산온도를 나타낸 그래프이다. 저성토부 k는 $1 \times 10^{-2.0} \text{ cm}^2/\text{s}$, 절성경계부 k는 $1 \times 10^{-1.9} \text{ cm}^2/\text{s}$, 절토부 k는 $1 \times 10^{-2.9} \text{ cm}^2/\text{s}$ 이다.

표층 세 구간에서 실제온도와 계산온도의 최저기온은 6일차에 동시에 나타났고 또한 경계값인 기온의 영향을 크게 받는 것으로 판단된다.

Fig. 7은 각 구간별 기층의 표층온도, 측정온도, 계산온도를 나타낸 그래프이다. 저성토부 k는 $1 \times 10^{-2.8} \text{ cm}^2/\text{s}$, 절성경계부 k는 $1 \times 10^{-3.0} \text{ cm}^2/\text{s}$, 절토부 k는 $1 \times 10^{-3.0} \text{ cm}^2/\text{s}$ 이다. 기층에서도 이전층인 표층의 온도의 영향을 크게 받는 것으로 판단된다. 최저점은 계산온도와 실제온도는 표층보다 1일 차이가 나는데 온도전달속도 차이로 판단된다.

Fig. 8은 각 구간별 보조기층의 기층온도, 측정온도, 계산온도를 나타낸 그래프이다. 저성토부 k는 $1 \times 10^{-2.1} \text{ cm}^2/\text{s}$, 절성경계부 k는 $1 \times 10^{-2.1} \text{ cm}^2/\text{s}$, 절토부 k는 $1 \times 10^{-2.1} \text{ cm}^2/\text{s}$ 이다. 보조기층에서는 이전층인 기층의 영향을 받음을 보이고 추가로 온도변화폭이 기층보다 보조기층에서 더 적은 것으로 판단된다.

Fig. 9는 각 구간별 동상방지층의 보조기층온도, 측정온도, 계산온도를 나타낸 그래프이다. 저성토부 k는 $1 \times 10^{-2.3} \text{ cm}^2/\text{s}$, 절성경계부 k는 $1 \times 10^{-2.4} \text{ cm}^2/\text{s}$, 절토부 k는 $1 \times 10^{-2.4} \text{ cm}^2/\text{s}$ 이다. 동상방지층에서는 이전층인 보조기층의 온도의 영향을 다른 층보다 적게 받음을 보이는데, 이는 함수비, 잠열 등에 의한 것으로 판단되며 영향을 알아보는 추가 연구가 필요하다. 결정된 온도확산계수를 이용하여 겨울기간(2011년11월-2012년2월)의 예상동결일수를 구할 수 있었다. Fig. 10은 겨울철 기온을 이용하여 연쇄계산을 통한 동상방지층의 온도를 예측한 그래프이다. 비슷한 모양을 띄고 있으나

LOW BANK

CUT-BANK

CUT

Fig. 6. Measured Temperature and Calculated Temperature of the Surface Layer

Fig. 7. Measured Temperature and Calculated Temperature of the Base Layer

LOW BANK

CUT-BANK

CUT

Fig. 8. Measured Temperature and Calculated Temperature of the Sub-base Layer

Fig. 9. Measured Temperature and Calculated Temperature of the Anti-frost Layer

초기값에서 차이가 나서 실제 측정온도보다 0 ℃ 아래로 내려가는 온도가 많이 예측되었다. 이렇게 측정되는 이유로 표층에서 공기와 지표사이의 온도전파가 다르기 때문에 표층에서 열확산계수가 다소 작게 측정되었고 동상방지층에서는 대기온도의 영향이 다른 층들에 비해 적게 받는 영향 때문인 것으로 분석된다.

Fig. 10. Estimation of Temperature in Anti-frost Layer Using Thermal Diffusivity

5. 기계학습

5.1 히든레이어가 한 개인 경우

Fig. 11은 트레이닝회수에 따른 동상방지층의 측정온도와 계산온도의 결정계수를 나타낸 그래프이다. 노드수를 변경하여 트레이닝 시킨 결과 노드 수 200개 에서 트레이닝 횟수 5 만 번의 경우 가장 높은 신뢰도를 나타내었다.

히든레이어가 한 개 일 경우, 노드 수가 200개일 때가 신뢰도가 가장 높게 나타났고, 노드 수가 200개일 경우 트레이닝 횟수를 1,000회 하였을 때 신뢰도는 0.94, 5만회 하였을 때 신뢰도는 0.97, 50만회 하였을 때 신뢰도는 0.97로 나타났다.

5.2 히든레이어가 두 개인 경우

Fig. 12는 트레이닝회수에 따른 동상방지층의 측정온도와 계산온도의 결정계수를 나타낸 그래프이다. 노드수를 변경하여 트레이닝 시킨 결과 노드수 40개, 100개 에서 트레이닝 횟수 50만번의 경우 가장 높은 신뢰도를 나타내었다.

Fig. 11. The Result of Machine Learning Based Prediction Model with One Hidden Layer

Fig. 12. The Result of Machine Learning Based Prediction Model with Two Hidden Layers

히든레이어가 두 개 일 경우, 노드 수가 40개, 100개일 때가 신뢰도가 가장 높게 나타났고, 노드 수가 40개, 100개일 경우 트레이닝 횟수를 1,000회 하였을 때 신뢰도는 0.95, 5만회 하였을 때 신뢰도는 0.99, 50만회 하였을 때 신뢰도는 1.00에 가까이 나타났다. 히든레이어가 두 개인 경우가 한 개, 세 개의 경우보다 신뢰도가 높았다.

5.3 히든레이어가 세 개인 경우

Fig. 13은 트레이닝횟수에 따른 동상방지층의 측정온도와 계산온도의 결정계수를 나타낸 그래프이다. 노드수를 변경하여 트레이닝 시킨 결과 노드수 40개, 100개, 40개에서 트레이닝 횟수 50만번의 경우 가장 높은 신뢰도를 나타내었다.

히든레이어가 세 개 일 경우, 노드 수가 40개, 100개, 40개일 때가 신뢰도가 가장 높게 나타났고, 노드 수가 40개, 100개, 40개일 경우 트레이닝 횟수를 1,000회 하였을 때 신뢰도는 0.94, 5만회 하였을 때 신뢰도는 0.99, 50만회 하였을 때 신뢰도는 0.99에 가까이 나타났다. 히든레이어가 세 개인 경우가 트레이닝 횟수가 적정량을 넘을 경우 발산하는

경향이 나타났다.

5.4 예측모델

텐서플로우의 라이브러리를 이용하여 다양한 히든레이어와 노드 수에 대해 강원도 원주시 19번국도 천은사 부근의 저성토부를 대상으로 적용하였다. 트레이닝 적용결과 심층신경망의 구성에 있어 트레이닝 결과 적합도는 심층신경망의 수와 비례하지 않는다는 것이 나타났다. 트레이닝 결과 세 개의 심층신경망보다 두 개의 심층신경망에서 더 높은 적합도가 나타났다. 또한 노드의 수가 많은 것이 높은 적합도로 이어지지 않는 것으로 나타났다.

본 연구에서는 트레이닝 결과를 이용하여 모델을 만들어 동상방지층의 온도를 예측하였다.

Fig. 14는 트레이닝으로 만들어진 모델을 사용하여 동상방지층의 온도를 예측한 그림이다. 히든레이어가 2개이고 노드수가 각각 40, 100의 모델을 사용하였고 적합도가 0.87로 나타났다. 트레이닝결과와 적합도보다 다소 낮은 적합도로 온도예측이 가능했다. 이러한 이유는 트레이닝의 데이터

Fig. 13. The Result of Machine Learning Based Prediction Model with Three Hidden Layers

Fig. 14. Anti-frost Layer Temperature Prediction, Goodness of Fit

로 약 650일의 데이터를 적용하였고 650일은 1년을 1주기로 보았을 때 다소 적은 양의 데이터이기 때문이다. 더 많은 측정데이터를 이용한다면 온도예측에서 더 나은 적합도로 이어질 거라 판단된다. 또한 심층신경망학습결과가 우수하게 나타나는 것으로 나타났으나, 신경망 구성에 있어 예측자료

가 많이 축적되어야만 신뢰성을 확보할 것으로 판단된다.

6. 결 론

본 연구는 MLTM (2012)에서 수행된 강원도 원주지역의

측정 데이터를 이용하였다. 기계학습은 텐서플로우(Tensor Flow TM)을 이용하여 히든레이어를 변경해가며 트레이닝을 하였고 이를 통해 예측모델을 만들어 동상방지층의 온도를 예측하였다. 본 연구에서 얻은 결론은 다음과 같다.

- (1) MLTM (2012)에서 수행된 동상방지층 온도Data를 활용하여 수치해석을 한 결과로 열확산계수(k)는 표층, 기층, 보조기층, 동상방지층에서 각각 $1 \times 10^{-1.6}$, $1 \times 10^{-2.8}$, $1 \times 10^{-2.1}$, $1 \times 10^{-2.3} \text{ cm}^2/\text{s}$ 으로 도출되었다.
- (2) Crank-Nicholson 차분법 수치해석기법을 통해 열확산계수(k)를 얻었으며, 이를 적용하여 동상방지층 온도 예측이 가능했다. 온도 예측은 기간은 11월~2월, 겨울에 대해 하였으며 실제온도보다 예측온도가 더 낮게 나타났다. 이는 함수부, 현장여건 등이 고려되지 않았기 때문이라고 판단된다.
- (3) 기존 연구된 열확산계수와 비교를 통하여 표층과 동상방지층에서 낮은 열확산계수를 얻었으며 이러한 결과는 함수비나 현장여건을 적용하는 데 어려움이 있었다. 본 연구에서는 동상방지층의 온도예측을 열확산계수로 하였으며 앞으로 함수비, 현장여건을 고려한 연구가 필요하다고 사료된다.
- (4) MLTM (2012)에서 수행된 동상방지층 온도Data 중 약 650일의 측정온도를 이용하여 기계학습을 수행하였고 이를 통하여 예측모델을 만들었다. 예측모델을 통하여 온도 예측을 하였고 적합도를 얻었다.
- (5) 히든레이어를 변경하고 트레이닝을 하였고 히든레이어가 2개이고 노드수가 각각 40, 100개의 모델을 트레이닝을 한 결과 1에 가까운 적합도를 도출하였다.
- (6) 온도예측모델을 수행한 결과 다소 낮은 적합도(0.87)을 나타내었다. 이러한 이유는 온도 예측모델을 만드는데 필요한 만큼의 계층자료의 양이 부족한 것으로 판단된다. 향후 계층자료가 많이 축적되면 예측모델에서 높은 신뢰도를 확보할 것으로 판단된다. 따라서 향후 더 많은 양의 데이터를 이용한 추가적인 연구가 필요하다고 사료된다.

트레이닝과 모델의 적합도를 확인하였고 부족한 부분은 데이터의 부족이 큰 것으로 나타났다. 기계학습은 약 650일 측정온도 Data를 이용하여 트레이닝을 하였고 이를 통하여 모델을 만들었다. 모델을 통해 온도예측을 하고 적합도를 얻었다. 히든레이어가 2개이고 노드수가 각각 40, 100개의 모델은 트레이닝결과 높은 적합도(0.99)를 도출하였고 온도 예측모델에서는 다소 낮은 적합도(0.87)를 나타내었는데 모델을 만드는데 필요한 만큼의 계층자료의 양이 부족한 것으로 판단된다. 향후 계층자료가 많이 축적되면 예측모델에서 높은 신뢰도를 확보할 것으로 판단된다. 따라서 향후 더 많은 양의 데이터를 이용한 추가적인 연구가 필요하다고 판단된다.

감사의 글

본 연구는 MLTM (2012) 과제의 일환으로 이루어졌습니다. 이에 감사드립니다.

References

- Cho, S.W., and Ihm, P.C. (2014). The study on the prediction of underground temperature in Changwon district. *Korean Journal of Air-Conditioning and Refrigeration Engineering*, Vol. 26, No. 3, pp. 97-102.
- Hong, S.S., Kim, Y.S., and Kim, H.S. (2010). Development of prediction model of frost penetration depth on pavement in Korea. *Journal of Korean Geosynthetics Society*, Vol. 9, No. 3, pp. 47-56.
- Hwang, S.H. (2017). A study on prediction method for low-depth ground temperature by using surface energy balance equation. *Journal of Korean Institute of Architectural Sustainable Environment and Building Systems*, Vol. 11, No. 2, pp. 142-148.
- Jeong, J.H., Kim, G.B., Park, S.K., Kim, H.S., and Kim, T.H. (2015). Fluctuation features and numerical model for underground temperature in shallow subsurface soil. *Journal of the Korean Geo-Environmental Society*, Vol. 16, No. 5, pp. 35-42.
- Jeong, S.I. (2004). A study on the comparison of measurement and prediction of underground temperature in Gumi. *Journal of the Korean Housing Association*, Vol. 15, No. 4, pp. 99-105.
- Kim, J.J. (2017). *Golbin hacker's 3 minute deep run*. Seoul: Hanbitmedia (in Korean).
- Kim, Y.C., and Hong, S.S. (2005). A study for penetration depth in pavement in Korea. *Proceedings of 2005 Annual Conference*, Korean Geo-Environmental Society, pp. 271-278.
- Ministry of Land, Transport and Maritime Affairs (MLTM). (2012). *Evaluation of validity for frost protection layer and development of its construction criteria*.
- Shin, Y.H., Tanshen, M., Chung, H.C., and Jeong H.M. (2012). A study on the yearly measurement and numerical analysis of underground temperature. *Journal of the Korean Society for Power System Engineering*, Vol. 16, No. 2, pp. 30-35.

Received	October 24, 2019
Revised	November 4, 2019
Accepted	December 9, 2019