

산불 방재용 무선 센서 네트워크에서 딥 러닝 기반의 온도 센서 데이터 추정 및 산불 전파 예측

윤완규*, 송유진*, 문지선*, 장성진*, 유상조^o

Deep Learning Based Temperature Sensor Data and Wildfire Propagation Prediction in Duty Cycled Wireless Sensor Network

Wan-Kyu Yun*, Yoo-Jin Song*, Ji-Sun Moon*, Sung-Jeen Jang*, Sang-Jo Yoo^o

요약

산불 방재용 무선 센서 네트워크는 온도 센서들을 통해 수집한 실시간 온도 데이터를 사용하여 화재를 감지할 수 있다. 재난지역 감시를 위한 무선 네트워크에서 센서는 에너지 소모를 최소화하기 위해 일정한 간격으로 수면 상태에 들어가게 되는데 이는 전체 네트워크의 정보량이 적어지게 되는 문제가 발생한다. 이러한 문제를 해결하기 위해 본 논문에서는 딥 러닝 기술을 이용하여 수면 상태에 들어간 센서들의 데이터를 추정하고, 추정된 데이터를 이용하여 미래의 센서 데이터를 예측하는 것을 제안한다. 산불의 데이터를 얻기 위해 무선 센서 네트워크가 배치된 산을 형성하고 3차원 지형 환경과 산불의 확산 속도, 주변의 상황 등을 고려한 산불 전파 모델을 시뮬레이터를 통해 구현하였다. 시뮬레이터를 통해 얻은 데이터를 이용하여 심층 신경망 모델을 학습하여 비활성 센서 데이터를 추정하여 현재 산불의 진행 상황을 확인할 수 있다. 또한, 추정된 데이터와 얻은 데이터를 이용하여 순환 신경망을 통해 미래의 센서 데이터를 예측하여 미래의 산불 전파경로를 예측함으로써 산불 진압에 대한 대비와 대피 계획을 세울 수 있다. 마지막으로 성능평가를 통해 제안된 모델이 비활성 센서들의 온도를 높은 정확도로 추정하고, 산불 전파경로를 예측할 수 있음을 보였다.

Key Words : Wireless Sensor Network, duty cycle, wildfire prediction, Deep Neural Network, Recurrent Neural Network

ABSTRACT

Wireless Sensor Networks can detect wildfire using real-time temperature data collected by temperature sensors. In wireless sensor networks for monitoring disaster areas, sensors can enter into sleep mode at regular interval in order to minimize energy consumption, resulting in limited sensing information in the entire networks. In this paper, to solve this problem, we propose a deep learning based method that can estimate inactive sensor's data, and predict sensor data in any desired time. To obtain data from wildfire, we implemented a GUI-based simulator that can generate any 3-D geographical map, deploy sensors and make any desired wildfire conditions

* 이 논문은 2017년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(2017R1A2B4003512)

• First Author : Inha University Department of Information and Communication Engineering, zipell135@gmail.com, 학생회원

° Corresponding Author : Inha University Department of Information and Communication Engineering, sjyoo@inha.ac.kr, 중신회원

* Inha University Department of Information and Communication Engineering, 12151574@inha.edu; 12151552@inha.edu, 학생회원; sungjeen_jang@ inha.edu, 학생회원

논문번호 : 201903-482-B-RN, Received March 2, 2019; Revised April 12, 2019; Accepted April 15, 2019

by defining wildfire modeling including spreading speed of wildfire and surrounding environment parameters. By using obtained data from simulator, we can train a deep neural network model and obtain the wildfire situation at the entire sensor field with inactive sensor data estimation. In addition, by using estimated and obtained data, we also train a recurrent neural network model to predict future wildfire propagation so that we are able to prepare for wildfire suppression and evacuation plan. Finally, through the performance evaluation the suggested methods can calculate inactive sensor's data and predict wildfire propagation with high accuracy.

I. 서 론

급속히 발전하는 기술에 의해 세계의 이상기후 발생은 늘어나고 있고, 그로 인해 자연재해도 자주 발생하고 있다¹⁾. 산이 많이 있는 우리나라의 경우 가장 가까운 자연재해는 산불이라고 할 수 있다. 이러한 산불은 초기에 발견이 어려워 대형 산불로 번지는 경우가 많고, 이러한 대형 산불의 경우 대비를 하지 못해 크나큰 인명피해와 재산피해가 발생한다. 이러한 피해를 줄이기 위해서는 피해 범위를 인지하고, 앞으로의 피해 범위를 예측하여 대비함으로써 줄일 수 있다. 하지만 많은 예방 기술들이 적용됨에도 불구하고 아직까지 많은 피해가 발생하고 있다²⁾.

기존의 산불 예측 방법으로는 지형과 기상의 정보, 영상인식 등을 이용하여 산불의 확산 모델을 만들고 이를 예측하였다. 하지만 넓은 범위의 예측을 할 때 비용이 많이 발생하는 등의 문제가 발생한다^{3,4)}. 본 논문에서는 이러한 넓은 지역에 대해서 현재 교통, 군사, 환경, 의료와 같이 넓은 분야에서 사용되고 있는 무선 센서 네트워크를 이용하여 산불의 발생을 감지하고 산불의 전파경로를 예측하여 미리 진화계획을 수립하고 대비할 수 있도록 한다⁵⁾.

무선 센서 네트워크(WSN: Wireless Sensor Network)는 무선통신이 가능한 센서 노드들이 에드혹 네트워크(ad-hoc network) 형태로 연결되어 있어 각 노드가 수집한 데이터를 싱크 노드(sink node)로 전송하고 싱크 노드에서 수집된 데이터들을 처리한다⁶⁾. 이러한 무선 센서 네트워크의 수명을 늘리기 위해 각 센서는 듀티 사이클(duty cycle)에 의한 활성화 시간에만 데이터를 수집한다. 그러나 낮은 듀티 사이클을 사용하면 데이터를 수집 및 송신하는 시간이 줄어들게 되어 정확한 실시간 데이터를 제공하지 못하게 되는 문제가 발생한다. 현재 낮은 듀티 사이클을 사용하여 센서의 수명을 늘리면서 정확한 데이터를 얻기 위한 방법이 제시되었지만 다양한 모양의 지형에서 발생할 수 있는 산불의 모양에 대해 수학적으로는 계산하기 어려운 부분이 있었다⁷⁾. 따라서 본 논문에서는 다양한 지형과

기상 환경 등 산불에 영향을 미치는 요소들이 존재하는 환경 속에서 인공 신경망(ANN: Artificial Neural Network) 기술 중 하나인 심층 신경망(DNN: Deep Neural Network)을 이용하여 비활성 센서의 데이터를 계산해 산불의 모양을 추정한다. 더 나아가 순환 신경망(RNN: Recurrent Neural Network)을 이용하여 미래의 산불 전파경로를 예측한다.

관련 연구로써 Alsheikh는 무선 센서 네트워크에서 사용할 수 있는 기계 학습 기술에 대해 설명하였다⁸⁾. Doolin은 무선 센서 네트워크를 통해 산에서 산불이 일어난 것을 감지할 수 있는 것을 확인하였다⁹⁾. Sohn은 산에서 무선 센서 네트워크를 사용하였을 때 산에서 장애물 여부에 따른 시스템의 신뢰성과 안전성을 분석하여 산불 방재용 무선 센서 네트워크를 사용할 수 있음을 보였다¹⁰⁾. Isakkson은 인공 신경망 중 하나인 합성곱 신경망을 이용해 기존의 기존 예측모델보다 낮은 에러율로 예측하는 모델을 만들었으므로 온도 데이터 예측에 인공 신경망을 사용할 수 있음을 보였다¹¹⁾. 현재 산불 감지 시스템에서는 지리 정보 시스템(GIS: Geographic Information System)과 영상인식을 이용한 산불 예방 시스템을 사용하고 있다. 그러나 이러한 영상인식 시스템의 경우 넓은 지역에서 사용하기에 비용이 많이 들고, 초기 산불 발생에 대해 감지해 내기 힘들었다^{12,13)}. 본 논문에서는 지리 정보 시스템 대신 무선 센서 네트워크를 사용함으로써 보다 넓은 지역에서 산불을 감지해 초기 대응이 가능하게 만들어 주고, 또한 미래의 산불 전파경로를 예측해 산불 진화와 대피를 해 산불 재해의 피해를 줄일 수 있는 모델을 제안한다.

본 논문의 구성은 다음과 같다. 2장에서는 산불이 전파하는 환경을 만들기 위해 지형 생성 및 산불의 전파하는 방법에 대해 설명한다. 3장에서는 제안된 환경에서 데이터를 수집 및 처리하고, 딥 러닝(deep learning)을 이용하여 산불의 온도 데이터 추정 및 산불 전파를 예측하는 방법에 대해 설명한다. 4장에서는 시뮬레이션 결과 및 제안된 모델의 성능을 분석하고 5장에서 결론을 내린다.

II. 산불 전파 환경 모델링

2.1 산불 전파 요인 및 지형 생성

산불이 발생하였을 때의 무선 센서 네트워크의 데이터를 얻어내기 위해 산불 상황을 시뮬레이션한다. 그림 1과 같이 산불 전파의 요인 중 지형과 바람에 의해 전파 속도가 변화하는 것을 고려한다^[14].

산의 지형의 모양은 산에 따라 다를 뿐만 아니라, 특정 범위에서는 같은 산이라고 할지라도 지형의 모양이 다를 수 있다. 지형의 모양이 다르면 그림 1(a)와 같이 산불의 전파 속도 또한 달라질 수 있다. 불은 경사가 증가하는 곳에서 닿는 면적의 크기가 커지기 때문에 더 빠른 속도로, 반대의 경우에는 느린 속도로 확산한다. 따라서 지형의 모양은 산불의 전파 속도와 모양에 영향을 미친다. 또한, 바람의 속도에 의해서 불의 전파 속도는 변화한다. 그림 1(b)와 같이 바람이 부는 방향으로 불이 더 빠르게 번지며, 바람의 속도에 의해서도 불의 전파 속도가 결정된다. 다른 형태의 지형과 시시각각 변하는 바람의 방향, 속도에 의해 산불의 전파 모양은 산불이 발생했을 때마다 달라진다.

딥 러닝 모델의 학습을 위한 다양한 산불의 데이터를 얻기 위해 3차원 공간상에 임의의 위치에 점을 발생시키고 보간법을 사용해 다양한 형태의 지형을 생성한다. 그림 2(a)와 같이 임의의 점들에 대해 x, y, z축에 대한 보간법을 이용하여 그림 2(b)와 같은 N_p 개의 봉우리와 골짜기를 갖는 지형을 형성한다. 형성된 지형에 평균 온도(t_a)와 높이에 따라 감소하는 온도(t_d)를 이용하여 그림 2(c)와 같이 지점마다 높이에 따른 초기 온도를 입력한다.

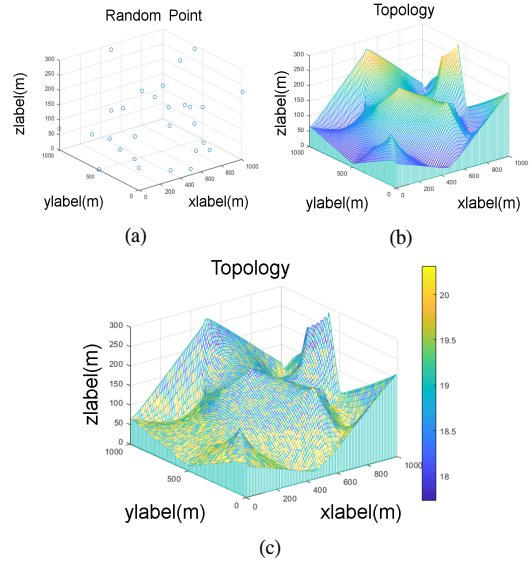


그림 2. 보간법을 이용한 지형 생성, (a) 임의의 점 생성, (b) 지형생성, (c) 지형의 초기 온도 설정
Fig. 2. Creating Topology using Interpolation, (1) random point

2.2 산불 전파 모델링

본 논문에서는 산불이 초기의 한 점 ($P_f = \{x_f, y_f, z_f\}$)에서 발생한다고 가정한다. 한 점에서 온도가 발화점(t_p) 이상이 되면 불이 발생한 것으로 간주한다. 따라서 초기의 점의 온도는 발화점이 되고 주기마다 해당 지역이 연소하는 것을 고려하여 수식 (1)과 같이 만큼 온도가 t_u 만큼 선형적으로 증가한다. 나무가 연소할 때의 최고 온도(t_l) 이상이 되면 불이 발생한 점의 온도는 더 이상 증가하지 않는다.

$$temp(P) = temp(P) + t_u \quad (1)$$

여기서 $temp(P)$ 는 점 P 에서의 온도이다.

수식 (2)와 같이 불이 발생한 점은 최고 온도 이상이 되고 일정 시간(d_p) 지나면 더 이상 연소할 것이 없어 불이 점차 줄어드는 것과 같이 불의 온도가 d_t 의 비율로 감소한다.

$$temp(P) = \frac{temp(P)}{d_t} \quad (2)$$

불의 확산은 수식 (3)과 같이 표현한다. 불이 발생한 점 주변에 불이 발생하지 않은 점이 존재할 때, 불의 확산 속도는 그림 1에서 설명한 것과 같이 바람의 방향과 두 점의 경사에 의해 결정된다. 그림 3과 같이 바




그림 1. 지형과 바람에 따른 산불 전파 속도, (a) 지형에 따른 전파 속도, (b) 바람에 따른 전파 속도
Fig. 1. Wildfire propagation speed according to topology and wind, (a) propagation speed according to topology, (b) propagation speed according to wind




그림 3. 바람의 방향에 영향을 받는 위치
Fig. 3. Location affected by wind direction

람의 방향에 영향을 받는 점일 때 더 빠르게 확산이 되며, 두 점 사이의 각도(θ)에 의해서도 결정이 된다.

$$temp(P) = temp(P) + \alpha \times \{ [temp(P_f) - temp(P)] \times \beta \times \{ 1 + (\frac{\theta}{90}) \} \} \quad (3)$$

여기서 P_f 는 불이 발생한 점의 위치이며 P 는 불이 발생하지 않은 점의 위치이다. α 는 경사가 증가할 때 큰 값을 가지며, 감소할 때에는 작은 값을 갖는다. θ 와는 다른 경사에 대한 가중치 값이 된다. β 는 그림 3과 같이 바람의 방향에 의해 영향을 더 많이 받는 셀의 경우 큰 값을, 아닌 경우에는 작은 값을 갖는 가중치이다.

바람의 방향과 속도는 정수 값을 이용하고 변화의 정도는 중심 극한 정리에 의거해 수식 (4)와 같은 정규 분포(normal distribution) 난수 발생 식을 이용하여 변화한다.

$$W_{i+1} = \left[\sigma_w \times \frac{\sqrt{-2 \cdot \ln(rv_1)}}{\cos(2 \cdot \pi \cdot rv_2)} + W_i \right] \quad (4)$$

여기서 두 변수 (rv_1, rv_2)는 0과 1 사이의 균등분포(uniform distribution)를 갖는 난수이고, W_i 는 이전 시간의 바람의 방향($W_{D,i}$)과 속도($W_{S,i}$)의 조합이며, σ_w 는 방향과 속도 난수의 분산(σ_{wd}, σ_{ws})의 조합이다. 바람의 방향과 속도는 정수로 표시되기 때문에, 다음 바람의 방향, 속도 값(W_{i+1})은 계산된 값에 반올림($[\cdot]$)을 적용한 값이 된다.

III. 딥 러닝 기반 산불 온도 데이터 추정 및 전파 예측

3.1 산불 전파 예측 모델 구조

본 장에서는 본 논문에서 제안하는 시뮬레이션을 통한 데이터 수집 및 처리, 심층 신경망을 이용해 비활성

센서 데이터를 추정하고 순환 신경망을 이용해 특정 시간마다 활성화된 센서의 데이터를 수집해 센서 집합 지도를 만든다. 미래의 센서 데이터를 예측하는 시스템의 전체적인 구조에 관해 설명한다. 그림 4는 전체 시스템 구조는 간략하게 나타내고 있으며, 첫 번째 단계는 2장에서 소개한 3차원 환경 산불 시뮬레이션이 일어나는 환경에 듀티 사이클이 적용된 무선 센서 네트워크를 배치하고, 두 번째 단계는 수집된 센서 지도를 모델에 알맞게 처리한 데이터를 이용하여 비활성 센서 데이터를 심층 신경망을 통해 추정하는 단계로 이를 3.3.1장에서 자세히 설명한다. 마지막으로 세 번째 단계는 심층 신경망으로 추정된 센서 데이터들을 이용하여 미래의 센서 데이터를 순환 신경망을 통한 예측 단계로 3.3.2장에서 자세히 설명한다.

3.2 센서 배치, 데이터 수집 및 딥 러닝 모델을 위한 데이터 처리

본 논문에서 제시하는 시뮬레이션 환경 모델에서 효율적인 산불 데이터 수집을 위해 일정 거리만큼 떨어진 무선 센서 네트워크를 배치한다^[15]. 산불 시뮬레이션이 진행됨에 따라 각 센서는 듀티 사이클로 인해 활성 또는 비활성 상태가 되는데 싱크 노드가 특정 간격마다 해당 간격 사이에 활성화된 센서들의 데이터를 수집해 센서 지도를 만든다고 가정한다. 수집한 센서 지도를 이용하여 예측모델이 센서 지도를 이용하여 결과를 출력할 때 보다 정확하고 효율적인 작동을 할 수 있도록 데이터 처리를 진행한다.

산불의 데이터를 보다 효과적으로 수집하는 센서 배치를 위해 형성된 지형의 x, y 축을 그림 5(a)와 같이

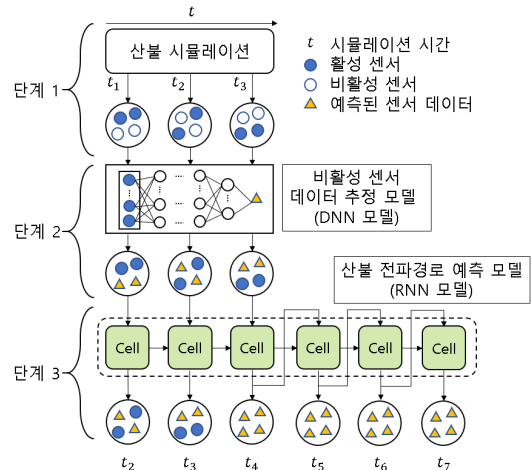


그림 4. 전체 시스템 구조
Fig. 4. System Architecture

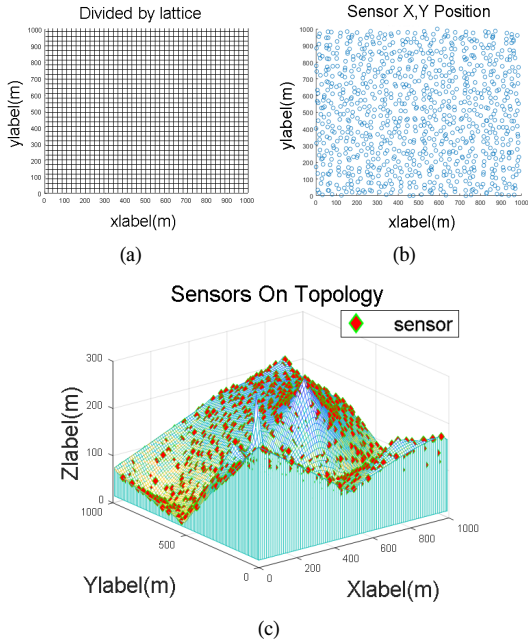


그림 5. 센서 배치 과정, (a) 일정한 간격으로 범위 나누기, (b) 격자 안 센서 발생, (c) 지형에 센서 배치
 Fig. 5. Sensor deployment Process, (a) Divide range with constant interval, (b) Creating Sensors in each lattice, (c) deploy Sensor on topology

N_x, N_y 개의 격자로 나누고, 나눠진 격자 안에 그림 5(b)와 같이 임의의 위치에 센서 1개를 생성한다. 생성된 센서의 x, y 위치와 2.1장에서 생성한 지형 데이터를 이용하여 그림 5(c)와 같이 무선 센서 네트워크가 배치된 지형을 형성한다.

듀티 사이클이 적용된 센서는 활성화 시간에 데이터를 수집 및 전송하며 비활성화 시간에는 에너지 효율을 위해 수면(sleep) 상태에 들어간다. 듀티 사이클은 수식 (5)와 같이 한 주기 시간(T_I)에서 활성화 시간(T_a) 만큼만 활성화가 되는 것으로 한 주기 내에서 차지하는 비율로 나타낼 수 있다.

$$D = \frac{T_a}{T_I} \times 100(\%) \quad (5)$$

듀티 사이클이 적용된 무선 센서 네트워크에서 싱크 노드가 센서의 데이터를 수집하는 모습은 그림 6과 같이 나타낼 수 있다. 본 논문에서는 센서 노드가 활성화 되었을 때 싱크 노드가 활성화 센서 노드의 데이터를 일정 시간 간격으로 받고 그 간격은 적절히 정해져 시간마다 수집된 활성화 센서의 개수는 전체 센서에 듀티 사이클을 곱한 만큼 수집된다고 가정한다. 또한, 수집된

활성화 센서의 데이터는 위치와 데이터를 포함하는 지도 형식으로 수집된다고 가정한다. 그림 6과 같이 일정 시간 내에서 활성화된 센서의 데이터를 수집하면 듀티 사이클로 인해 시간 t_k 마다 다른 모양의 센서 데이터 집합이 생성된다.

수집한 산물 시뮬레이션 데이터를 비활성 센서 데이터 추정 모델에 사용하기 위해 그림 7과 같은 데이터 처리를 진행한다. 비활성 센서 데이터를 추정하기 위해 비활성 센서 주변 활성화 센서들의 데이터를 비활성 센서 기준으로 상대적인 위치로 변환한다. 이러한 데이터 처리를 통해 학습된 모델은 비활성 센서의 위치뿐만이 아닌 다른 위치에서의 데이터 또한 추정해 낼 수 있고, 전체 센서 지도를 통한 모델 훈련이 아닌 한 개의 비활성 센서에 대해서 결과를 출력해 주기 때문에 모델 훈련 시에 전체 센서 지도를 통한 학습보다 빠른 속도로 학습을 진행할 수 있게된다. 또한, 각 센서의 위치를 상대적으로 바꿔줌으로써 비활성 센서 데이터 추정 시

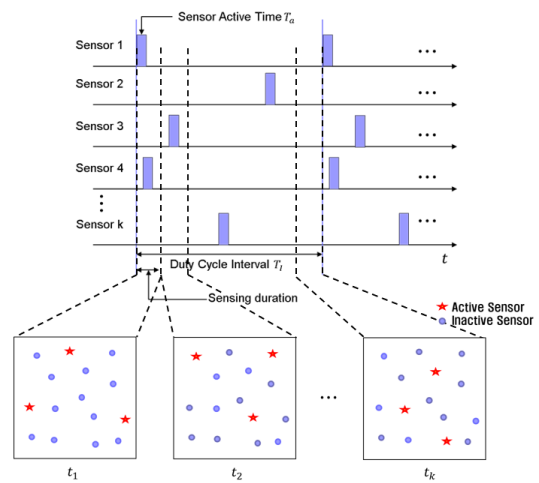


그림 6. 듀티 사이클이 적용된 무선 센서 네트워크에서의 데이터 수집
 Fig. 6. Data Collection from duty-cycled Wireless Sensor Network




그림 7. 비활성 센서와 활성화 센서의 위치, (a) 센서의 절대적인 위치, (b) 센서의 상대적인 위치
 Fig. 7. Positions of active and inactive sensors, (a) Absolute positions of sensors, (b) Relative positions of sensors

위치에 대한 추가적인 연산이 없어 더 간단한 모델을 이용하더라도 예측할 수 있게 된다. 데이터 처리는 그림 7(a)와 같이 센서 지도에서 각 비활성 센서 기준으로 가장 가까운 활성 센서 N 개를 수집해 그림 7(b)와 같이 비활성 센서 기준으로 활성 센서의 위치 데이터를 변환해준다.

그림 7의 (a)에서 (b)로 바꾸기 위해 비활성 센서의 상대적인 위치는 수식 (6)과 같이 기준점으로 변환한다.

$$(x_m, y_m, z_m, t_m) \rightarrow (0, 0, 0, t_m) \quad (6)$$

여기서 (x_m, y_m, z_m, t_m) 는 비활성 센서의 실제 위치와 온도이다.

따라서 활성 센서의 상대적인 위치는 수식 (7)과 같이 변환된다.

$$(x_i - x_m, y_i - y_m, z_i - z_m, t_i) \text{ for } i = 1, 2, \dots, N \quad (7)$$

여기서 (x_i, y_i, z_i, t_i) 는 비활성 센서와 i 번째로 가까운 활성 센서의 위치와 온도이다. 수식 (6), 수식 (7)을 이용한 변환된 위치를 이용하여 심층 신경망 모델을 학습을 진행하면 모델의 입력 차원을 낮춰 모델의 복잡도를 줄일 수 있고, 위치는 출력하지 않고 데이터만 출력하기 때문에 더 높은 정확도를 갖는다.

비활성 센서 데이터 추정 모델에서 추정된 전체 센서 데이터 지도를 이용하여 산불 전파경로 예측모델에 사용한다. 추정된 센서 데이터 지도를 산불 전파경로 예측모델에 사용하기 위해 그림 8과 같은 데이터 처리를 진행한다. 센서의 위치는 본 장에서 소개한 것과 같이 효율적인 무선 센서 네트워크가 배치되었다는 가정하에 일정한 격자로 나눈 구역에서 무작위의 위치에 배치한 것을 고려해 각 센서의 x, y 좌표를 격자의 중앙에 위치하도록 변환한다. 변환된 x, y축의 데이터는 입력으로 사용하지 않고, 산불의 확산의 요인인 지형의 모양과 관련된 z축 데이터와 온도 데이터를 이용하여 모델을 학습한다. 이러한 데이터 처리를 통해 모델의 입력 차원(dimension)이 낮아져 모델 학습이 더 빠르게 진행되고 하드웨어적 이득을 볼 수 있어 더 복잡한 형태의 모델을 구성해 더 정확한 데이터 출력을 낼 수 있게 된다. 그림 8(a)와 같이 센서의 위치를 그림 8(b)와 같이 고정 변환해 주는 방식으로 데이터 처리를 진행한다.

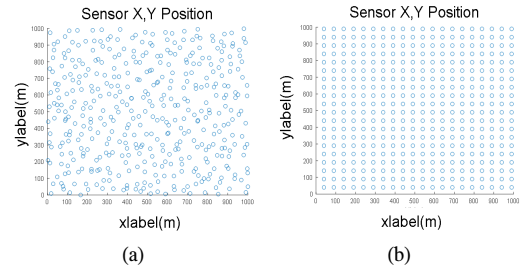


그림 8. 센서의 실제 위치와 고정 위치, (a) 센서의 실제 위치, (b) 고정 변환된 센서 위치
Fig. 8. Real and fixed positions of sensors, (a) Real positions of sensors, (b) Fixed position of sensors

3.3 비활성 센서 추정 및 산불 전파경로 예측을 위한 딥 러닝 모델

딥 러닝은 주어진 정보의 특징을 찾아내 입력에 대한 출력을 이용해 학습을 진행하여 올바른 출력을 내주는 모델을 형성하기 위해 사용한다. 모델 속 노드들이 가지고 있는 가중치와 바이어스를 조정하는 학습을 진행해 가며 주어진 입력에 대해서 올바른 출력을 낼 수 있는 모델을 형성해간다. 또한, 딥 러닝은 수학식을 세우기 힘든 정보들에 대해서 수학식을 사용하지 않고도 원하는 결과를 내주는 모델을 형성할 수 있다. 본 논문에서는 3차원 공간상에서 산불 확산에 대한 수학식을 세우기 힘들고, 보간법을 이용한 예측의 경우 정확도가 매우 낮은 점을 고려해 데이터 추정과 확산 예측에 대해 딥 러닝을 사용하는 모델을 제안한다.

딥 러닝 모델 중 기본단위인 신경(neuron)을 여러 겹 쌓은 심층 신경망을 이용하여 비활성 센서 데이터 추정 모델을 만든다. 또한, 시계열(sequential) 데이터의 처리에 많이 사용되는 순환 신경망 모델을 이용하여 산불 전파경로 예측모델을 만든다^{16)[17]}. 딥 러닝은 수식 (8)과 같은 기본적인 인공 신경(artificial neuron) 구조인 선형 모델(linear model)은 여러개의 층을 쌓더라도 선형적인 계산에 의해서 1개의 층을 쌓는 것과 같은 효과를 얻게 된다. 따라서, 각 층 사이에 비선형 활성 함수(nonlinear activation function, $f(\cdot)$)를 적용하여 층마다 다른 계산을 진행할 수 있도록 한다.

$$Y = f(W \times X + B) \quad (8)$$

입력이 들어가는 처음의 층을 입력층(input layer), 출력이 나오는 마지막 층을 출력층(output layer), 입력 층과 출력층 사이에 보이지 않는 층을 은닉층(hidden layer)이라 하고 은닉층에서는 이전 층의 출력이 입력으로 들어가게 된다. 이렇게 형성된 모델에 입력층에

X , 출력층에 Y 를 입력해 주고 역전파(back propagation) 알고리즘을 이용하여 각 층에서의 가중치 (W)와 바이어스(B)의 값을 조정한다. 가중치와 바이어스는 비용 함수(cost function)를 기준으로 최적화(optimization) 알고리즘을 사용하여 훈련마다 값이 조정된다. 또한, 훈련 시에 가중치와 바이어스가 특정 훈련 데이터에만 정확한 답을 내놓는 과적합(overfitting)을 줄이기 위해 몇 개의 노드를 사용하지 않고 훈련하는 드랍아웃(dropout) 기법을 적용해 훈련을 진행한다. 훈련 데이터(train data)를 이용하여 가중치와 바이어스의 값을 조정하고, 검증 데이터(validation data)를 이용하여 가중치와 바이어스가 제대로 훈련이 되었는지 검증한다^[18]. 실제 실험 시에는 입력 데이터를 훈련된 모델에 입력하여 출력값을 얻는다.

3.3.1 비활성 센서 데이터 추정을 위한 심층 신경망 모델

본 논문에서는 비활성 센서의 데이터를 추정하기 위해 주변 활성화 센서의 데이터를 처리하여 입력으로 사용하는 심층 신경망 모델을 제안한다. 그림 9는 3.2장에서 소개한 데이터 처리 방식 중 상대적 위치 변환 방식을 이용하여 비활성 센서 데이터를 추정하는 방식을 나타낸 것이다. 그림 9(a)는 듀티 사이클이 적용된 무선 센서 네트워크의 특정 시간 t_k 의 센서 데이터를

싱크 노드가 수집한 모습을 나타낸 것이다. 듀티 사이클이 적용되었기 때문에 활성 센서의 데이터만을 출력하고 비활성 센서의 데이터는 출력되지 않은 모습을 볼 수 있다. 그림 9(b)는 비활성 센서 데이터 추정 모델을 통해 추정된 비활성 센서의 데이터까지 포함된 지도이다. 그림 9(c)는 그림 9(a)와 같이 수집된 활성 센서 지도에서 수집되지 않은 비활성 센서 데이터 주변 활성 센서를 모델에 입력해 출력으로 비활성 센서의 데이터를 추정해 비활성 센서에 입력하는 것을 나타낸 그림이다. 그림 9(c)와 같은 동작을 통해 그림 9(a)와 같은 무선 센서 네트워크를 그림 9(c)와 같이 비활성 센서가 추정된 무선 센서 네트워크로 언어낼 수 있다. 언어낸 센서 지도를 이용하여 현재의 산불 모양을 추측할 수 있다. 그림 9(b)와 같은 모델에서 입력층과 출력층의 신경 노드(neuron node)의 개수는 입력, 출력의 크기와 같고 각 은닉층의 총 신경 노드의 개수는 다르다. $Z_{i,j}$ 는 i 번째 은닉층의 j 번째 노드이며 이전 층의 노드에 가중치를 곱하고 바이어스를 더한 뒤 활성화 함수를 통과시켜 만든다.

3.3.2 산불 전파경로 예측을 위한 순환 신경망 모델

산불 전파경로 예측모델은 현재의 산불이 미래엔 어떻게 확산할 지에 대한 산불의 특성을 알아야 한다. 산불 확산에 대한 특성은 산불 확산 요인에 따라 다르며, 확산 요인에 대한 정보는 현재의 센서 데이터를 이용하여 추측하기 어려우므로 특성을 파악하기 위해서는 과거의 센서 데이터가 필요하다. 본 논문에서는 과거와 현재의 정보를 이용해 산불의 특징을 알아내어 미래의 센서 데이터를 예측하는 산불 전파경로 예측모델로 순환 신경망 모델을 사용하였다.

순환 신경망은 딥 러닝 모델의 은닉층에 해당하는 셀(Cell)에 의해 현재 출력에 대해 과거와 현재의 입력이 영향을 주게 된다. 셀은 그림 10(a)와 같이 상태

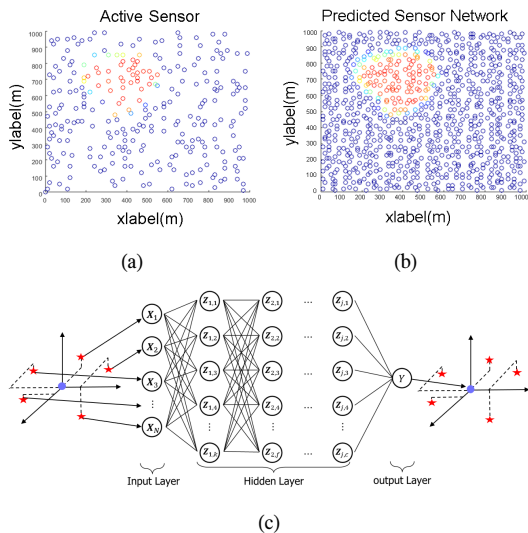


그림 9. 심층 신경망을 이용한 비활성 센서 데이터 추정 모델, (a) 수집된 활성 센서, (b) 추정된 센서 지도, (c) 심층 신경망을 통한 비활성 센서 데이터 추정 모델

Fig. 9. Inactive sensor data estimation model using Deep Neural Network, (a) Collected active sensor data, (b) Estimated overall sensor data, (c) Inactive sensor data estimation model using Deep Neural Network

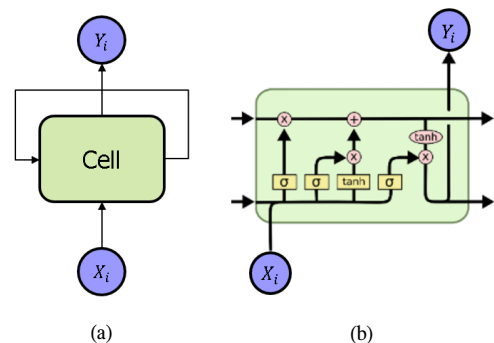


그림 10. RNN 구조와 LSTM 셀^[19]
Fig. 10. RNN architecture and LSTM cell

(state)와 입력을 받아 상태와 출력을 낸다. 상태는 다음 셀에 입력으로 들어가 이전 입력에 대한 가중치를 넘겨주게 되어 현재 출력에 대해 이전의 입력이 영향을 미치게 된다. 산불 전파경로 예측모델의 경우 그림 10(b)와 같은 망각 게이트(forget gate), 입력 게이트(input gate), 출력 게이트(output gate)라는 3가지 게이트로 구성된 셀을 사용하여 먼 과거의 입력까지 기억하게 해주는 LSTM(Long Short Term Memory) 셀을 사용한다¹⁹⁾.

망각 게이트를 통해 과거의 입력과 상태를 얼마나 더 기억할지 결정한다. 입력 게이트를 통해 현재 입력과 상태의 출력에 대한 가중치를 결정하고 출력 게이트를 통해 출력한다. 제안하는 시스템에서는 듀티 사이클로 인해 활성화된 센서의 데이터만을 입력하는 것이 아닌 비활성 센서 데이터 추정 모델을 이용하여 추정된 전체 센서 데이터 지도를 입력해 준다. 현재 산불 확산에 대해 활성 센서의 데이터만을 이용하는 방식보다 전체 센서 데이터를 입력하는 것이 특징을 찾기 쉬우므로 추정된 센서 지도를 입력으로 사용한다. 그림 11은 3.3.1장에서 소개한 비활성 센서 데이터 추정 모델을 통해 얻어낸 전체 센서 데이터 지도를 3.2장에서 소개한 데이터 처리 방식 중 센서 고정 위치 변환 방식을 사용하여 순환 신경망 모델인 산불 전파경로 예측모델

에 입력하는 것을 보여준다. 그림 11(a)와 같이 전체 센서 데이터 지도를 각 센서가 위치한 격자의 중앙으로 위치를 변환해 준다. 시간 t 마다 얻어낸 고정 변환된 전체 센서 데이터 지도를 그림 11(b)와 같이 산불 전파경로 예측모델인 순환 신경망 모델에 입력한다. 본 논문에서는 현재 시간에 대한 다음 시간에 대한 센서 데이터뿐만 아니라 더 미래의 데이터까지 출력해 주기 위해 인코더/디코더 (encoder/decoder) 모델을 사용한다²⁰⁾. 인코더/디코더 모델은 입력단인 인코더 부분에서는 기존의 순환 신경망과 다르지 않지만, 출력단인 디코더에서는 현재의 출력이 다음의 입력으로 들어가게 되는 구조로 형성되어있다. 이러한 디코더 구조를 통해 예측된 데이터의 특징을 이용해 좀 더 먼 미래의 데이터까지 예측할 수 있게 된다.

IV. 모의 실험 및 성능 평가

4.1 시뮬레이터 구현

산불 시뮬레이션의 데이터를 구하기 위해 산불 시뮬레이터를 구현하였다. 시뮬레이터는 센서의 데이터에 영향을 미칠 수 있는 파라미터들을 이용하여 표 1의 값을 사용해 구현하였다. 시뮬레이터는 매트랩(matlab)을 이용하여 구현하였으며, 그래픽 유저 인터페이스(GUI)를 이용하여 동작을 확인할 수 있도록 시각화하였다.

그림 12는 시뮬레이터 구현을 위한 파라미터 입력 창과 그 입력으로 인해 나타난 지형 환경, 무선 센서 네트워크를 나타낸 것이다. 지형 환경은 파라미터 입력 창에서 입력한 x, y 범위만큼 형성되며 굴곡의 개수만큼 봉우리와 골짜기가 형성된다. 무선 센서 네트워크 또한 파라미터 중 x, y 를 나눈 격자 수 만큼 형성된다.

그림 13은 시뮬레이터를 통해 생성된 지형 환경에서 산불의 전파와 듀티 사이클이 적용된 무선 센서 네




그림 11. 인코더/디코더 모델을 사용한 산불 전파경로 예측 모델, (a) 추정된 센서 네트워크 위치 고정 변환, (b) 인코더/디코더 모델
Fig. 11. Wildfire Propagation Model using Encoder/Decoder RNN Model, (a) Converting Estimated Sensor Network to fixed position, (c) Encoder/Decoder model

표 1. 시뮬레이션 파라미터
Table 1. Simulation Parameter

Parameter	Values	Parameter	Values
x, y range	1000(m)	N	10
Range Interval	10(m)	Time Iteration	60
Number of peak	20	$[\alpha_1, \alpha_2]$	[0.42 0.25]
Number of Sensor	900	$[\beta_1, \beta_2]$	[1, 0.5]
Duty Cycle	20(%)	$[\sigma_s, \sigma_d]$	[0.42 0.2]

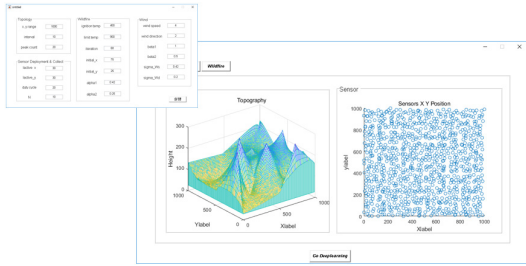


그림 12. 파라미터를 이용한 시뮬레이션 환경 생성
Fig. 12. Create simulation environment using Parameters

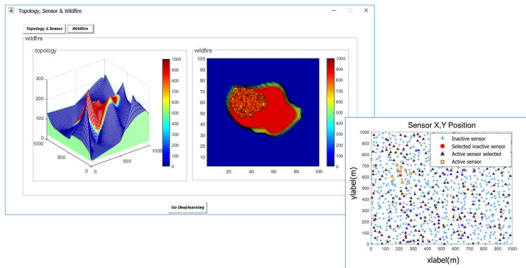


그림 13. 산불 확산 시뮬레이션과 데이터 수집 및 처리
Fig. 13. Wildfire propagation simulation and data collection, processing

트위크를 통해 수집된 데이터를 처리하는 것을 나타낸다. 생성된 지형에서 무선 센서 네트워크를 통해 산불 데이터를 수집하기 위해 산불을 발생시키고 시간마다 산불의 데이터를 무선 센서 네트워크를 통해 수집한다. 시간마다 무선 센서 네트워크 데이터는 듀티 사이클로 인해 활성화 센서와 비활성 센서로 나뉘어 수집된다.

수집된 무선 센서 네트워크의 데이터를 그림 13과 같이 비활성 센서 데이터 추정 모델에 맞도록 데이터 처리를 진행한다.

4.2 비활성 센서 데이터 추정 및 산불 전파경로 예측 모델 구현

비활성 센서 데이터 추정 모델과 산불 전파예측 모델은 표 2와 같은 구조를 이용하여 구현하였다. 모델 작성에는 파이썬(python)을 이용하였으며, 딥 러닝 라이브러리(deep learning library)로는 텐서플로우(tensorflow)를 사용하였다. 비활성 센서 데이터 추정 모델은 5개의 은닉층과 1개의 출력층으로 구성이 되어 있다. 비활성 센서 데이터 추정 모델에서 은닉층의 활성화 함수로는 Leaky ReLU(Leaky Recurrent Linear Unit) 를 사용하였다. 산불 전파경로 예측모델에서 은닉층에서의 활성화 함수로는 하이퍼 볼릭 탄젠트(tanh)를 사용하고 두 모델 모두 출력층에서는 활성화 함수로 시그모이드(sigmoid)를 사용하였다. 학습 시에는 표 2의 비용 함수(cost function)를 이용하여 아담(Adam) 최적화 알고리즘을 사용하였으며 성능 측정에는 오차율 함수(Error rate function)를 사용하였다.

다양한 환경을 조성해 비활성 센서 데이터 추정 모델의 성능을 측정하기 위해 데이터 추정과 관련된 요인인 주변 센서와의 거리와 굴곡의 개수, 듀티 사이클을 변화시키며 성능 측정을 진행하였다. 센서의 개수가 작을수록 주변의 데이터를 확보하지 못하기 때문에 데이터 추정이 힘들고, 굴곡의 개수에 따라 산불 확산 진행이 달라질 수 있으므로 해당 파라미터를 조절해 가

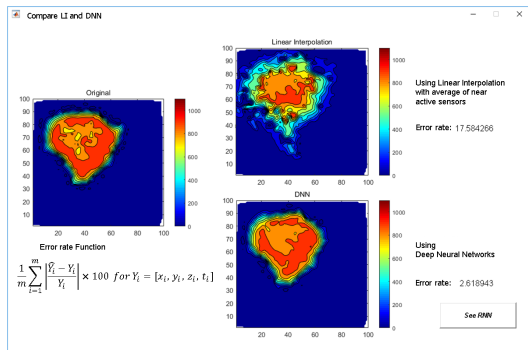
표 2. 비활성 센서 데이터 추정 및 산불 전파경로 예측 모델
Table 2. Inactive sensor data estimation and wildfire propagation prediction Model

DNN Model			RNN Model		
Layers	Neuron		Layers	Cell	
Hidden Layer	FC Layer	4096	Hidden Layer	Encoder	LSTM Cell
	FC Layer	4096			
	FC Layer	4096		Decoder	LSTM Cell
	FC Layer	4096			
	FC Layer	2048			
Output Layer	FC Layer	1024	Output Layer	FC Layer	Outputs
Optimizer	Cost Function		Error Rate Function		
Adam Optimizer	$\frac{1}{m} \sum_{i=1}^m (\hat{Y}_i - Y_i)^2$		$\frac{1}{m} \sum_{i=1}^m \left(\frac{\hat{Y}_i - Y_i}{Y_i} \right) \times 100(\%)$		

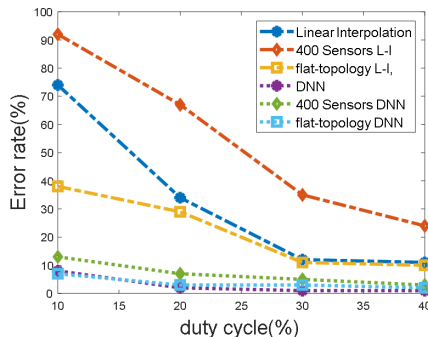
면 실험을 진행하였다. 또한, 듀티 사이클이 작을수록 주변 활성 센서와의 거리가 멀어지기 때문에 세 가지 요인을 변화시키며 성능 측정을 진행하였다. 보간법을 이용한 방식과 딥 러닝 모델 간의 성능을 비교하기 위해 주변 활성 센서의 평균으로 비활성 센서의 데이터를 추정하는 보간법의 성능 측정을 함께 진행하였다. 그림 14는 실제 센서 데이터와 보간법, 심층 신경망을 이용하여 추정된 비활성 센서 데이터의 2차원 지형 온도와 두 방법에 대한 다양한 환경 속에서 듀티 사이클에 따른 오차의 비교를 나타낸다. 센서가 900개이고 굴곡이 20개인 환경을 기준으로 실험을 진행하였으며, 기준 환경으로부터 센서의 개수와 굴곡의 개수를 바꿔가며 실험을 진행하였다. 또한, 10~40% 사이에서 듀티 사이클을 변화해가며 성능을 측정하였다. 그림 14(b)와 같이 제안된 모델에서는 센서의 개수가 적어 비활성 센서의 데이터를 추정하기 어려운 환경에서도 기준 환경에서의 실험 결과보다 큰 오차율을 보이지

않은 것을 볼 수 있다. 또한, 듀티 사이클이 10%인 환경에서는 제안된 모델이 보간법 모델보다 환경에 따라 오차율이 30~80% 정도 적은 것을 확인할 수 있다. 전반적으로 보간법이 추정하기 유리한 환경과 데이터 추정이 힘든 환경에서도 제안된 모델이 보간법보다 비활성 센서의 데이터를 20~50% 정도 더 정확히 추정하는 것을 확인할 수 있다.

다양한 환경을 조성해 산불 전파예측 모델의 성능을 측정하기 위해 바람의 변화율, 굴곡의 개수를 변화시켰다. 바람의 변화율이 높을수록 전파경로 예측이 어려워지고, 굴곡이 많을수록 지형에 대한 변수가 많아지므로

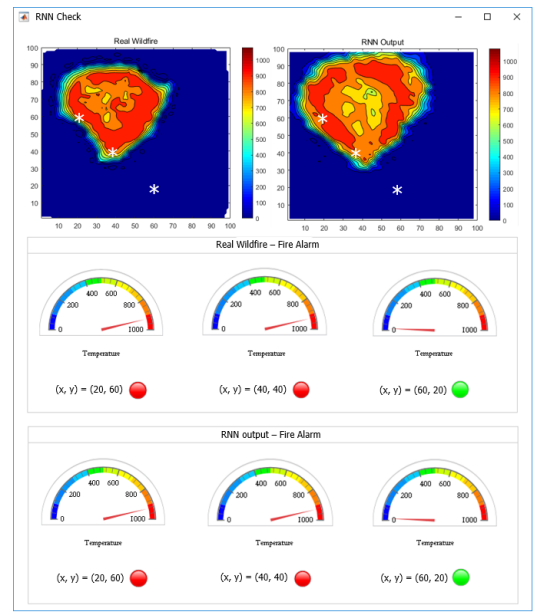


(a)




(b)

그림 14. 추정 모델 간의 성능 비교, (a) 선형 보간법과 제안된 추정 모델 간 성능 비교, (b) 다양한 환경에서의 오차율 그래프
Fig. 14. Performance comparison between estimation model, (a) Performance comparison between linear interpolation and proposed estimation model, (b) error rate graph in various environment



(a)



(b)

그림 15. 산불 전파경로 예측 모델의 성능 측정, (a) 실제 산불 데이터와 예측 모델 비교, (b) 다양한 환경에서의 오차율 그래프
Fig. 15. Performance evaluation of wildfire propagation prediction model, (a) error rate graph in various environment

두 가지 요인을 변화시키며 제안된 모델의 성능을 측정하였다. 실제 시뮬레이터를 이용한 산불 확산과 제안된 모델 간의 오차율 함수를 통한 비교를 통해 성능 측정을 진행하였다. 그림 15(a)는 시뮬레이션의 실제 센서 데이터와 산불 전파경로 예측 모델을 이용해 출력된 센서 데이터를 보간법을 이용하여 2차원 온도 데이터 지도로 나타낸 것이다. 실제 예측모델의 성능을 시각적으로 확인하기 위해 특정 지점에서 온도를 보여주고 일정 온도 이상이 되면 화재 경보가 일어나도록 만들었다. 그림 15(b)는 굴곡의 개수가 환경에서 바람의 변화율을 변화시키며 산불 전파경로 예측모델의 성능을 측정할 수 있다. 바람의 영향이 적을 때에는 지형의 모양과 관계없이 일정한 오차율로 예측을 하는 것을 볼 수 있다. 하지만 바람의 변화율이 높아질수록 지형의 모양에 따라 오차율이 증가하는 것을 볼 수 있다. 지형에 굴곡이 많은 경우에는 오차율이 70% 정도까지 나오는 것을 확인할 수 있다. 그러므로 전반적으로 굴곡이 적고 바람의 변화율이 낮을수록 정확하게 예측하는 것을 확인할 수 있다.

V. 결 론

본 논문에서는 듀티 사이클이 적용된 산불 방재용 무선 센서 네트워크에서 비활성 센서의 데이터를 추정하고, 미래의 센서 데이터를 예측하여 산불 전파경로를 예측하는 딥 러닝 모델을 제안하였다. 학습 모델뿐만 아니라 산불 환경의 데이터를 얻기 위해 산불 시뮬레이션을 진행하였다. 결과적으로 비활성 센서 데이터 추정 모델은 주변 활성 센서의 평균을 내는 수학적식을 사용한 모델보다 좋은 결과를 얻을 수 있었다. 실제 데이터값과 비교해 보았을 때의 오차율을 계산하니 평균적인 오차율의 값이 선형 보간 모델보다 낮은 값을 갖는 것을 볼 수 있었다. 전파경로 예측모델의 경우 바람의 영향이 적을수록 정확도가 높아지는 것을 확인할 수 있었다. 듀티 사이클 기법이 적용된 산불 방재용 무선 센서 네트워크 환경에서 기계 학습 모델을 이용하여 비활성 센서 데이터를 높은 정확도로 추정하는 것이 가능하고 전파경로 예측을 하여 산불의 경로를 미리 알아내 산불 진압계획을 세우고 대비할 수 있음을 보였다. 그러나 실제 데이터 사용이 아닌 시뮬레이션을 이용한 예측 결과이기 때문에 추후 실제 산불 방재용 무선 센서 네트워크에서 취득한 데이터를 이용하여 연구할 필요가 있다.

References

- [1] A. Z. Shvidenko and D. G. Schepaschenko, "Climate change and wildfires in Russia," *Contemporary Problems of Ecology*, vol. 6, no. 7, pp. 683-692, Dec. 2013.
- [2] H. S. Lee and S. Y. Lee, "The analysis of distribution and characteristics of forest fires damage over 30ha in Korea," *Fire Sci. and Eng.*, vol. 25, no. 5, pp. 39-46, Oct. 2011.
- [3] L. Yu, N. Wang, and X. Meng, "Real-time forest fire detection with wireless sensor networks," in *Proc. 2005 Int. Conf. Wireless Commun., Netw. and Mob. Comput.*, Dec. 2005.
- [4] J. Lloret, M. Garcia, D. Bri, and S. Sendra, "A wireless sensor network deployment for rural and forest fire detection and verification," *Sensors*, vol. 9, no. 11, pp. 8722-8747, Oct. 2009.
- [5] F. Ali, S. M. R. Islam, D. H. Kwak, P. Khan, N. Ullah, S. J. Yoo, and K. S. Kwak, "Type-2 fuzzy ontology-aided recommendation systems for iot-based healthcare," *Comput. Commun.*, vol. 119, pp. 138-155, Apr. 2018.
- [6] J. H. Choi, J. K. Choi, and S. J. Yoo, "Positioning scheme based on iterative path-loss exponent estimation in WSNs," *J. KICS*, vol. 37, no. 10, pp. 889-900, Oct. 2012.
- [7] U. Raza, A. Camera, A. L. Murphy, T. Palpanas, and G. P. Picco, "Practical data prediction for real-world wireless sensor networks," *IEEE Trans. Knowledge and Data Eng.*, vol. 27, no. 8, pp. 2231-2243, Aug. 2015.
- [8] M. A. Alsheikh, S. Lin, D. Inyati, and H. Tan, "Machine learning in wireless sensor networks: Algorithms, strategies, and applications," *IEEE Commun. Surveys & Tuts.*, vol. 16, pp. 1996-2018, 4Q, 2014.
- [9] D. M. Doolin and N. Siter, "Wireless sensors for wildfire monitoring," *SPIE on Smart Structures & Materials*, pp. 477-484, 2005.
- [10] J. M. Sohn, C. H. Seok, W. J. Park, Y. S. Chang, and J. C. Kim, "Wireless sensor network for wildfire monitoring," *J. KIICE*,

vol. 11, no. 4, pp. 846-851, Apr. 2007.

- [11] R. Isaksson, "Reduction of temperature forecast errors with deep neural networks," *Department of Earth Sciences, Uppsala University (www.geo.uu.se)*, Uppsala, 2018.
- [12] S. C. Kang, S. Y. Lee, and B. d. Lee, "A Study on the Effectiveness Analysis of Forest Fire Surveillance Cameras - Case study on Samcheok City-," in *Proc. KIFSE. Conf. 2012*, pp. 468-471, Dae-gu, Korea, May 2012.
- [13] S. H. Yeom and D. S. Kang, "A simple adaptive forest fire detection system to a variety of changes in the external environment," *J. KIIT*, vol. 11, no. 12, pp. 21-27, Dec. 2013.
- [14] H. S. Song, W. J. Jeon, and S. H. Lee, "A simulation model for the study on the forest fire pattern," *J. Korea Soc. Simulation*, vol. 22, no. 2, pp. 101-107, Jun. 2013.
- [15] S. Abdollahzadeh and N. J. Navimipour, "Deployment strategies in the wireless sensor network: A comprehensive review," *Computer Commun.*, vol. 91-92, pp. 1-16, Oct. 2016.
- [16] S. C. Lee, H. D. Jung, S. T. Park, and S. H. Kim, "Deep learning," *J. KSNVE*, vol. 27, no. 3, pp. 19-25, May 2017.
- [17] S. M. Ahn, "Deep learning architectures and applications," *J. Intell. and Inf. Syst.*, vol. 22, no. 2, pp. 127-142, Jun. 2016.
- [18] S. M. Yang, W. J. Song, I. S. Choi, and S. J. Yoo, "Implementation of deep learning-based motion classification system for IoT device control in ultrasonic sound environments," *J. KICS*, vol. 42, no. 9, pp. 1796-1805, Sep. 2017.
- [19] *colah's blog, Understanding LSTM Networks* (2015), Retrieved Jan. 18, 2019, from <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [20] M. S. Kim, D. M. Singh, and M. H. Lee, "Summerization using RNN encoder-decoder," in *Proc. IEEK. Conf. 2016*, pp. 1890-1892, Jeju Island, Korea, Jun. 2016.

윤 완 규 (Wan-Kyu Yun)



2019년 2월 : 인하대학교 정보통신공학과 학사 졸업
2019년 2월~현재 : 인하대학교 정보통신공학과 석사
<관심분야> 이동통신, IoT, 무선 센서 네트워크, 머신러닝

송 유 진 (Yoo-Jin Song)



2019년 2월 : 인하대학교 정보통신공학과 학사 졸업
<관심분야> 이동통신, IoT, 무선 센서 네트워크

문 지 선 (Ji-Sun Moon)



2015년 2월~현재 : 인하대학교 정보통신공학과 학사
<관심분야> 통신, 네트워크

장 성 진 (Sung-Jeen Jang)



2007년 2월 : 인하대학교 전자공학(공학사)
2009년 2월 : 인하대학교 정보통신공학과(공학석사)
2009년 3월~현재 : 인하대학교 정보통신공학과 박사과정
<관심분야> Cognitive Radio Network, 무선센서네트워크

[ORCID:0000-0002-0087-9751]

유 상 조 (Sang-Jo Yoo)



1988년 2월 : 한양대학교 전자통신학과(공학사)

1990년 2월 : 한국과학기술원 전기및전자공학과(공학석사)

2000년 8월 : 한국과학기술원 전자전산학과(공학박사)

1990년 3월~2001년 2월 : KT 연구 개발 본부

1990년 3월~2000년 11월 : NIST(미국 표준기술연구원) 초빙연구원

2001년 3월~현재 : 인하대학교 정보통신공학과 교수
<관심분야> 무선 네트워킹 프로토콜, Cross-layer 프로토콜 설계, Cognitive Radio Network, 무선센서 네트워크, 미래인터넷

[ORCID:0000-0003-1533-0814]