



베이지안 딥러닝 기법을 이용한 확률적 적설심 예측 모델 개발

Development of a Stochastic Snow Depth Prediction Model Using a Bayesian Deep Learning Method

정영준^a · 이상익^b · 이종혁^c · 서병훈^d · 김동수^d · 서예진^d · 최원^e†

Jeong, Youngjoon · Lee, Sang-ik · Lee, Jonghyuk · Seo, Byunghun · Kim, Dongsu · Seo, Yejin · Choi, Won

ABSTRACT

Heavy snow damage can be prevented in advance with an appropriate security system. To develop the security system, we developed a model that predicts snow depth after a few hours when the snow depth is observed, and utilized it to calculate a failure probability with various types of greenhouses and observed snow depth data. We compared the Markov chain model and Bayesian long short-term memory models with varying input data. Markov chain model showed the worst performance, and the models that used only past snow depth data outperformed the models that used other weather data with snow depth (temperature, humidity, wind speed). Also, the models that utilized 1-hour past data outperformed the models that utilized 3-hour data and 6-hour data. Finally, the Bayesian LSTM model that uses 1-hour snow depth data was selected to predict snow depth. We compared the selected model and the shifting method, which uses present data as future data without prediction, and the model outperformed the shifting method when predicting data after 11-24 hours.

Keywords: Snow depth prediction; long short-term memory; Bayesian model; deep learning; time-series modeling

1. 서론

최근 급격한 기후변화 때문에 세계 각지에서 폭설, 이상고온, 집중호우, 가뭄 등 이상기후가 과거에 비해 더 자주, 그리고 더 강하게 발생하고 있으며 (Lu et al., 2020; Perera et al., 2020), 1958-1970년의 국내 자연재해 피해액은 연 평균 1,590억 원 (2020년 환산금액)이었으나 2000-2020년에는 연 평균 1조 281억 원으로 급격하게 증가하였다 (MOIS, 2021). 이에 따라 자연재해에 의한 농업시설물의 피해가 급증하고 있으며,

2020년 한 해에만 사유시설 재해의 피해액 중 비닐온실이 차지하는 비율은 약 32.2%에 달한다 (MOIS, 2021). 현재 한국의 폭설 경보 시스템은 특정 시각의 적설심을 기준으로 한 단순 경보로서 실제 폭설에 대처가 어렵다는 한계점이 있다. 또한 현존 시스템은 온실의 종류와 지역에 상관 없이 동일한 경보를 적용하는 것으로 알려져 있다 (Lee et al., 2020).

재난으로 인하여 피해를 입을 확률이 높은 지역, 즉 지역별 재난취약성을 산정하고 이를 통해 재난에 의한 피해액, 복구액을 줄이고자 하는 다양한 연구들이 수행된 바 있다. 기상자료, 지리 자료 등 입력 자료를 사용하여 다중 회귀 모델, 혹은 머신러닝 등의 방법으로 지진, 강풍, 폭우 등 다양한 유형의 재난에 의한 피해 여부를 계산하거나 (Choi et al., 2018; Hart et al., 2019; Rössli et al., 2021), 재난의 강도를 직접 예측하여 그로부터 피해 여부를 부차적으로 계산하는 연구들이 수행되었다 (Hajikhodaverdikhan et al. 2018; Liang et al., 2019). 특히 폭설에 한하여 살펴보면, 최심신적설량, 기온, 상대습도 등의 기상자료와 시군구 면적, 비닐온실 면적, 농가인구 등을 설명변수로, 과거 피해액을 종속변수로 하는 회귀 모델이나 머신러닝 모델을 사용하는 다양한 연구가 수행된 바 있는데 (Kwon and Chung, 2016; Oh and Chung, 2017; Lee and Chung, 2019), 이러한 접근법은 오차가 굉장히 크다는 단점이 존재하였다. 한편 Kim et al. (2021)은 현재 적설심이 주어졌을 때 특정 시간 후의 미래 적설심을 예측하기 위하

^a Ph.D. Student, Department of Rural Systems Engineering, Seoul National University

^b Researcher, Department of Rural Systems Engineering, Research Institute of Agriculture and Life Sciences, Seoul National University

^c Ph.D. Student, Department of Rural Systems Engineering, Global Smart Farm Convergence Major, Seoul National University

^d MS Student, Department of Rural Systems Engineering, Global Smart Farm Convergence Major, Seoul National University

^e Associate Professor, Department of Rural Systems Engineering, Research Institute of Agriculture and Life Sciences, Global Smart Farm Convergence Major, Seoul National University

† Corresponding author

Tel.: +82-2-880-4715, Fax: +82-2-873-2087

E-mail: fembem@snu.ac.kr

Received: August 05, 2022

Revised: September 15, 2022

Accepted: September 20, 2022

여 마코프 체인 (Markov Chain)을 사용하였으며 이때 얻은 전이확률행렬 (Transition Probability Matrix)을 활용하여 특정 적설심이 관측되었을 때 n 시간 안에 온실이 파괴될 확률을 직접적으로 계산한 바 있다.

한편, 적설의 강도를 직접 예측하는 연구들도 수차례 수행된 바 있다. 기온, 강수량, 과거 적설량 등 기상자료를 이용하여 다중 회귀 모델 (Kim et al., 2013) 및 인공신경망 (Kim et al., 2013; Park et al., 2014; Kim et al., 2014)으로 적설량을 예측하는 접근 방법이 있었다. 또한, 기상자료 뿐 아니라 경위도, 고도 등의 지리자료까지 포함하여 Support Vector Regression (SVR), Random Forest (RF), 인공신경망 등의 머신러닝 기법을 통하여 적설량을 예측하는 접근법도 있었다 (Hamidi et al., 2018; Zhang et al., 2019; Hu et al., 2021; Song et al., 2022). 한편 앞에서 적설량을 예측했던 것과 다르게, Oh et al. (2020)은 기상자료를 사용하여 적설심 자체를 예측하기도 하였으며, Kim et al. (2021)은 마코프 체인을 이용하여 현재 적설심이 주어졌을 때 n 시간 후의 적설심을 예측하였다. 한편, Kim et al. (2021)이 시간별 적설 데이터를 예측한 것 외에는 주로 일별 (Kim et al., 2013; Kim et al., 2014; Park et al. 2014; Zhang et al., 2019; Oh et al., 2020; Hu et al., 2021; Song et al., 2022), 또는 월별 (Hamidi et al., 2018) 적설 데이터를 예측하였다.

폭설에 의한 피해를 저감하기 위하여 임시보강구조물을 설치하는 등 적시에 대응하기 위해서는 최소한 시간별 적설 데이터를 예측할 필요가 있는데, 대부분의 선행연구는 일별, 혹은 월별 적설 데이터를 예측하는데 그쳐 실시간 경보 시스템을 제공하는 데에는 한계가 있을 것으로 판단되었다. 따라서 본 연구에서는 마코프 체인 모델과, 시계열 데이터를 다루는 데 특화된 것으로 알려진 Long Short-Term Memory (LSTM) 모델을 사용하여 시간별 적설심을 예측하고, 이 중 더 성능이 나은 것으로 적설심 예측 모델을 선정하고자 하였다.

II. 재료 및 방법

1. 데이터 전처리

본 연구에서 개발하고자 한 지역별 적설심 예측 모델은, 1시간 간격으로 관측된 현재 적설심 (mm)을 입력 데이터로 받아, 그로부터 n 시간 후의 적설심 (n : 1-12)을 출력하는 모델이다. 사용한 데이터는 2002년부터 2021년까지 총 20년 간의 전국 기상대 적설심 데이터이다. 시계열 데이터의 교차 검증을 위하여 2002년부터 2005년까지를 학습한 뒤 2006년부터 2009년까지, 2002년부터 2009년까지를 학습한 뒤 2010년부터 2013년까지, 2002년부터 2013년까지를 학습한 뒤 2014년부터 2017년까지, 2002년부터 2017년까지를 학습한 뒤 2018년부터 2021년까지를 예측하는 총 4가지의 경우를 고려하였다. 이때, 원활한 학습을 위하여 총 데이터가 5000개보다 적은 기상대는 배제하고 사용하였으며, 최종적으로 사용된 기상대는 아래와 같다 (Table 1). 또한, 마코프 체인의 경우 1시간 뒤 데이터가 존재하는, 그리고 LSTM의 경우 n 시간 뒤 데이터가 존재하는 적설심 데이터만 학습 및 검증에 사용하였다.

2. 확률적 예측 모델

가. 마코프 체인

먼저 마코프 체인을 이용하여 확률적 적설심 예측 모델을 구축하였다. 마코프 체인은 이산 확률 과정의 일종으로서, 한 상태가 그 직전 상태에만 영향을 받는 것으로 가정한다 (Scherer and Glaogla, 1994). 전국 기상대에 대한 적설심 데이터를 먼저 군집 분석을 이용하여 20개의 상태로 나눈 뒤, 각 한 상태에서 1시간이 지났을 때 어떤 상태로 가는지 분석하여 상태 간의 전이확률행렬을 계산할 수 있다. 이 전이확률행렬은 1시간 후 적설심에 대한 자료이며, 이를 n 번 곱하면 n 시간 후 적설심을 예측하는 데 사용할 수 있다. 이때 전이확률행렬은 지역별로 다르게 계산되며, 이를 사용하여 지역별 현재 적설심이 주어졌을 때 n 시간 뒤의 적설심을 예측할 수 있다.

Table 1 Weather stations whose data were used in training models

No.	Name	No.	Name	No.	Name	No.	Name
90	Sokcho	108	Seoul	133	Daejeon	232	Cheonan
95	Cheorwon	112	Incheon	140	Gunsan	235	Boryeong
98	Dongducheon	114	Wonju	156	Gwangju	245	Jeongeup
100	Daegwallyeong	115	Ulleungdo	165	Mokpo	251	Gochanggun
101	Chuncheon	119	Suwon	172	Gochang		
102	Baeknyeongdo	129	Seosan	175	Jindo		
104	Bukgangneung	131	Cheongju	216	Taebaek		

마코프 체인은 Kim et al. (2021)에서 다룬 것을 그대로 구현하여 사용하였으며, 이를 이용하여 n시간 뒤 적설심에 해당하는 상태를 구한 뒤, 그 상태 내에서 균등분포를 따르도록 무작위로 값을 추출하여 최종적으로 적설심 값을 결정할 수 있다.

나. 베이지안 LSTM

다음으로, LSTM은 현재 적설심 데이터를 입력 데이터로, n시간 뒤 적설심 데이터를 목표 데이터로 두고 학습하였다. 기존 LSTM은 결정론적 방법으로 한 모델은 계속해서 같은 적설심을 예측하기 때문에 적설심에 의해 온실이 파괴될 확률을 구할 수 없다는 한계점이 있었다. 이를 해결하기 위하여 본 연구에서는 베이지안 개념을 도입한 베이지안 LSTM을 구현하였다. 베이지안 LSTM은 모델의 파라미터가 값이 아닌 분포로 나타나기 때문에, 최종적인 출력 데이터 또한 분포를 이루게 된다. 본 연구에서는 Bayes by backprop (Blundell et al., 2015)이라는 방법을 사용하였는데, 이 방법은 학습 시 미분 및 역전파를 통하여 파라미터의 값을 업데이트하는 기존 LSTM과 다르게, 미분 및 역전파를 통하여 파라미터의 분포 (평균, 표준편차)를 업데이트한다는 특징이 있다. 베이지안 LSTM을 학습시키기 위한 방법은 식 (1)과 같다. 이때 지점별, 시간별 모델을 각각 따로 훈련시켜, 25개 지점에 해당하는 1-12시간 모델, 즉 총 300개의 모델을 학습하였다.

$$\begin{aligned} \epsilon &\sim N(0,1) \\ \theta &= (\rho, \mu) \\ w &= \mu + \epsilon \log(1 + e^\rho) \\ \Delta_\mu &= \frac{\delta f(w, \theta)}{\delta w} + \frac{\delta f(w, \theta)}{\delta \mu} \\ \Delta_\rho &= \frac{\delta f(w, \theta)}{\delta w} \frac{\epsilon}{1 + e^\rho} + \frac{\delta f(w, \theta)}{\delta \rho} \end{aligned} \tag{1}$$

w는 신경망의 파라미터 (가중치)를 의미하고, ρ와 μ는 각각 w의 표준편차와 평균이다. f(w, θ)는 목적 함수 (손실 함수)이다. Δ_μ, Δ_ρ는 각각 w의 평균과 표준편차의 업데이트를 위한 기울기를 의미한다.

III. 결과 및 고찰

1. 지역별 적설심 예측 모델 개발

마코프 체인과 베이지안 LSTM의 성능을 평가하기 위하여 검정에 사용된 지역에 대하여 n시간 후의 적설심을 예측한 뒤 (n: 1-12) 적설심 오차를 비교하였다. 이때 베이지안 LSTM에 대하여 입력 자료로 적설심 자료만을 사용한 모델과 적설심 자료와 함께 풍속, 기온, 습도 데이터를 함께 사용한 모델을 따로 훈련시켜 성능을 비교하고자 하였다. 또한, 직전 1시간 데이터만을 사용한 경우와 직전 3시간, 6시간 데이터를 모두 입력 자료로 사용한 경우를 비교하였다. 확률적인 모델의




Fig. 1 RMSEs of snow depth after n hours of Markov chain and Bayesian LSTM models (n: 1–12); Weather 1 h, 3 h, 6 h indicate the Bayesian LSTM models that input 1-hour, 3-hour, and 6-hour past weather data (wind speed, temperature, humidity) with snow depth data respectively, and snow 1 h, 3 h, 6 h indicate the Bayesian LSTM models that input 1-hour, 3-hour, and 6-hour past snow depth data

비교를 위하여 각 지점에 대하여 100번씩 예측한 후 모든 지점의 평균 오차를 계산하였고, 교차 검증을 수행한 뒤 평균 오차로 성능을 비교하였다 (Fig. 1). 비교 결과, 직전 1시간의 적설 데이터만을 사용한 베이지안 LSTM 모델이 가장 성능이 좋은 것으로 드러났다. 마코프 체인은 1시간에서 6시간 사이의 적설심을 예측할 때는 RMSE가 최소 11.5 mm에서 최대 27.6 mm까지 나타나 성능이 다른 LSTM 모델과 비슷하거나 더 좋게 나타났으나, 그 이후로는 최소 32.2 mm에서 최대 64.2 mm까지 나타나 성능이 떨어지는 것으로 판단되었다. 1시간, 3시간, 6시간 적설심 데이터를 사용한 베이지안 LSTM은 각각 10.0-37.4 mm, 20.0-40.9 mm, 21.5-43.1 mm의 RMSE를 나타내어 더 많은 과거 데이터를 사용할수록 성능이 악화되는 것을 확인하였다. 1시간, 3시간, 6시간 기상 데이터를 사용한 베이지안 LSTM은 각각 15.5-40.0 mm, 26.8-43.3 mm, 39.8-56.3 mm로 적설심 데이터를 사용했을 때와 마찬가지로의 양상을 보였다. 한편 1시간의 적설심 데이터만을 사용한 LSTM과 다른 기상자료를 포함하여 사용한 LSTM을 비교한 결과 RMSE가 각각 10.0-37.4 mm와 15.5-40.0 mm로 나타나 과거 적설심 데이터만을 모델의 입력 자료로 사용하는 것이 더 좋다는 결론을 내릴 수 있었다. 따라서, 최종적으로 직전

1시간 적설심 자료를 사용한 베이지안 LSTM을 적설 예측 모델로 선정하였다. 한편 마코프 체인과 베이지안 LSTM (직전 1시간 적설심 사용)의 성능을 비교하기 위한 예시로 Fig. 2, 3에 두 모델로 각각 속초 기상대의 3시간 후 적설심을 예측한 결과와 대관령 기상대의 12시간 후 적설심을 예측한 결과를 도시하였다. 두 모델 모두 확률적인 결과를 출력하기에 10회 시행 후 평균과 95% 신뢰 구간을 함께 도시하였다. 해당 그림을 보면, 3시간 정도의 짧은 시간에는 마코프 체인도 비교적 정확한 예측을 하는 것을 확인할 수 있으나, 12시간 정도의 긴 시간에는 마코프 체인보다 베이지안 LSTM이 훨씬 정확한 예측을 하는 것을 확인하였다.

2. 모델의 시간별 예측 유효성 검증

한편 앞서 선정된 직전 시간의 적설심 데이터만을 예측에 활용하는 베이지안 LSTM 기반 예측 모델의 유효성을 검증하기 위하여, n시간 뒤의 데이터를 예측하는 대신 지금의 데이터를 그대로 사용하는 방법과 비교 검증을 수행하였다. 즉 실제 데이터를 그래프 상에서 그대로 n시간 shift하는 방식과의 비교를 수행하였다. 1시간부터 24시간 뒤까지의 데이터를 예측하는 24가지 경우에 대해 각각 비교를 실시하였다.

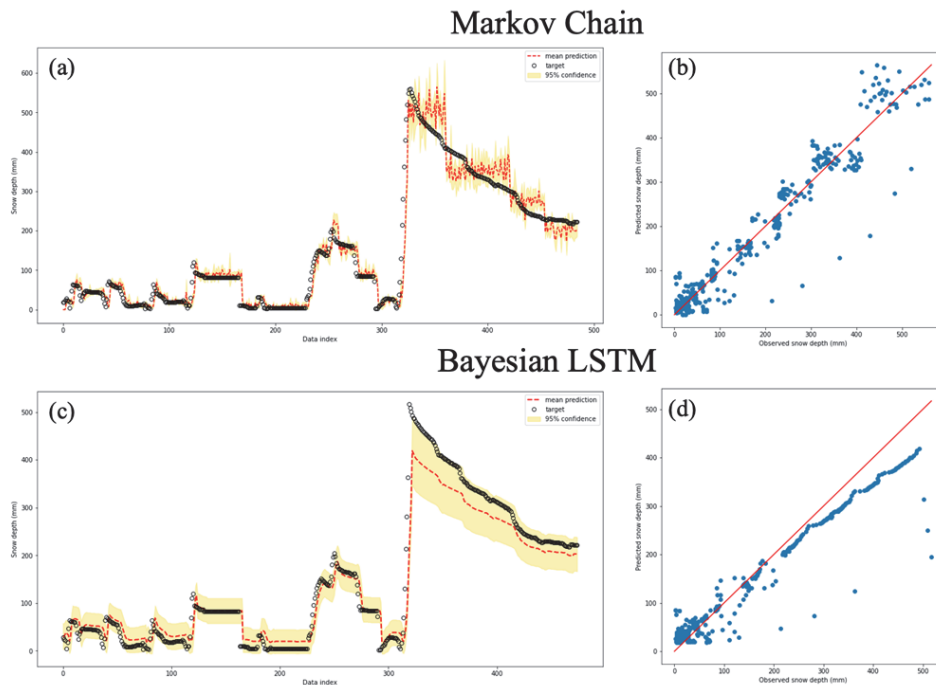


Fig. 2 Snow depth after 3 hours prediction with regard to test data in Sokcho station: (a), (c) is a plot of mean predicted snow depth by Markov chain and Bayesian LSTM, and observed snow depth, respectively. (b), (d) is a scatter plot of observed snow depth (x-axis) and mean predicted snow depth (y-axis) by Markov chain (R^2 : 0.94) and Bayesian LSTM (R^2 : 0.95), respectively

비교 결과 1시간에서 10시간 사이에는 베이지안 LSTM의 RMSE가 14.6-42.8 mm로 나타났으며 단순히 shift하는 방식에서는 RMSE가 7.7-42.8 mm로 나타나 단순히 shift하는 방식이 더 좋은 성능을 보여주었다. 반면, 11시간에서 24시간 사이에 베이지안 LSTM의 RMSE는 45.1-68.3 mm로 나타났고 단순히

shift하는 방식의 RMSE는 45.4-72.6 mm로 나타나 베이지안 LSTM이 더 좋은 성능을 보여주었다 (Fig. 4). 이를 통해 베이지안 LSTM을 사용하여 단기 데이터를 예측하는 것은 무리가 있으며, 11시간 이상의 긴 시간 뒤 데이터를 예측할 때 신뢰할 만한 결과를 얻을 수 있다는 결론을 내릴 수 있었다. 한편 온

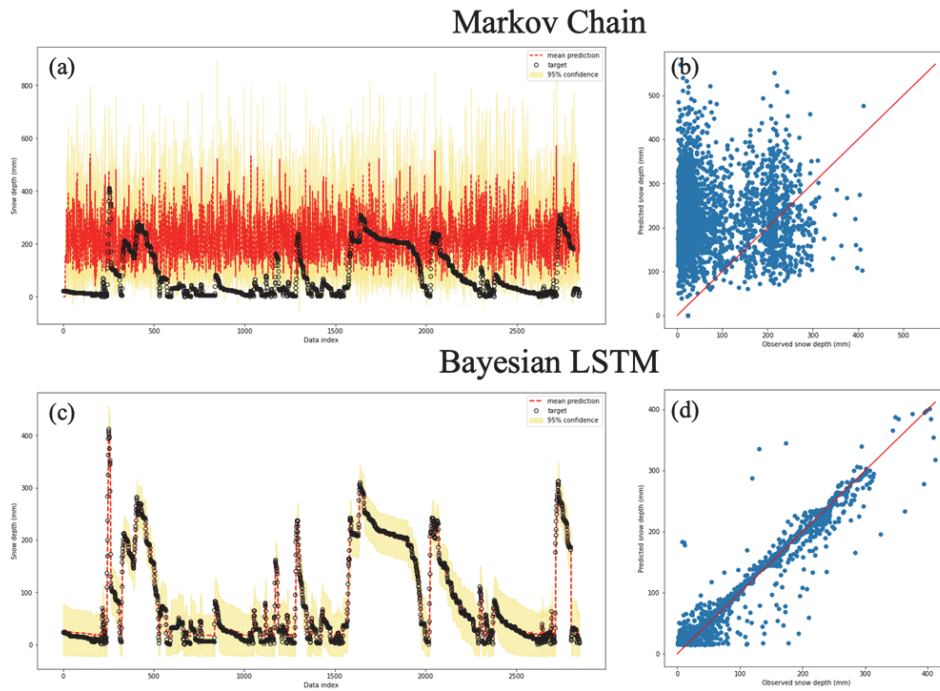


Fig. 3 Snow depth after 12 hours prediction with regard to test data in Daegwallyeong station: (a), (c) is a plot of mean predicted snow depth by Markov chain and Bayesian LSTM, and observed snow depth, respectively. (b), (d) is a scatter plot of observed snow depth (x-axis) and mean predicted snow depth (y-axis) by Markov chain (R^2 : 0.01) and Bayesian LSTM (R^2 : 0.94), respectively




Fig. 4 RMSEs of snow depth after n hours of Bayesian LSTM model and shifting (n: 1-24)

실의 폭설 피해를 방지하기 위해서는 임시보강구조물을 설치하는 등의 조치가 필요한데, 이러한 조치를 취하기 위해서는 충분히 긴 시간이 필요하므로 본 연구에서 제안한 베이지안 LSTM 모델을 통해 11-24시간 뒤의 적설심 데이터를 예측하는 것이 현실적으로 유효한 접근법이라고 판단하였다.

IV. 결론

본 연구에서는 폭설에 의해 농업 시설물이 입는 피해를 예방하기 위한 기초자료로서 확률적 적설 예측 모델을 개발하고자 하였다. 이를 기반으로 현재 적설심이 관측된 후 n시간 뒤 적설심을 예측하고자 하였다.

선행연구에서 제시된 마코프 체인 모델과 본 연구에서 제시한 베이지안 LSTM 모델을 비교한 결과 1-12시간 후 적설심을 예측할 때 대부분의 경우에서 베이지안 LSTM 모델이 우세한 것으로 드러났으며, 특히 긴 시간 후의 적설심을 예측할 때 성능 차이가 더 크게 나타나는 것을 확인하였다. 한편 입력 데이터의 종류에 따른 베이지안 LSTM의 예측 성능을 비교하였는데, 예측 시점 직전 1시간의 적설심 데이터만 사용했을 때 가장 성능이 좋게 나타났을 경우 적설심만을 사용했을 때보다 성능이 악화됨을 확인하였고, 직전 3시간, 6시간의 데이터를 입력함에 따라 직전 1시간의 평균 데이터를 사용했을 때보다 성능이 나빠짐을 보였다. 한편 모델의 유효성을 검증하기 위하여 n시간 뒤의 데이터를 예측하는 대신 지금의 데이터를 그대로 사용하는 방법인 shift 방법과 비교를 수행하였는데, 1-10시간 사이인 비교적 단기 예측에서는 shift 방법이 더 좋은 성능을 보여주었으나 11-24시간 사이에는 베이지안 LSTM이 더 우세한 성능을 보여, 해당 모델은 비교적 장기 예측에 활용되는 것이 적합하다고 판단되었다.

본 연구는 선행연구에서 현재 적설심이 관측되었을 때 n시간 뒤 적설심 예측에 사용되던 모델인 마코프 체인보다 성능이 개선된 베이지안 LSTM을 도입하여 적설심을 예측하였다. 또한 적설심 예측을 위한 LSTM 모델의 입력 데이터의 종류에 따라 성능이 어떻게 변화하는지 제시하였다. 그러나 예측 지점의 지형적 특성 등의 영향을 고려하지 않고 미래 데이터를 예측하였다는 한계점이 존재한다. 또한 지역별, 시간별로 전부 다른 모델을 사용하여 너무 많은 모델을 훈련시켜야 했으며, 향후 이를 모두 한 모델 안에서 다룰 수 있도록 큰 모델을 개발하는 방안을 고려해볼 필요가 있다. 마지막으로 11-24시간 뒤 데이터를 예측하는 데에는 유효했지만, 1-10시간 뒤 데이터를 예측할 때는 신뢰할 만한 결과를 얻지 못했기에, 향후에는 단기 예측에도 유효한 모델을 개발할 필요가 있다.

감사의 글

이 논문은 행정안전부 기후변화대응 AI기반 풍수해 위험도 예측기술개발사업의 지원을 받아 수행된 연구임 (2022-MOIS61-003).

REFERENCES

1. Blundell, C., J. Cornebise, K. Kavukcuoglu, and D. Wierstra, 2015. Weight Uncertainty in Neural Networks. *arXiv preprint arXiv:1505.05424*. doi:10.48550/arXiv.1505.05424.
2. Choi, C., J. Kim, J. Kim, D. Kim, Y. Bae, and H. S. Kim, 2018. Development of heavy rain damage prediction model using machine learning based on big data. *Advances in Meteorology*, 2018. doi:10.1155/2018/5024930.
3. Hajikhodaverdikhan, P., M. Nazari, M. Mohsenizadeh, S. Shamshirband, and K. W. Chau, 2018. Earthquake prediction with meteorological data by particle filter-based support vector regression. *Engineering Applications of Computational Fluid Mechanics*, 12(1): 679-688. doi:10.1080/19942060.2018.1512010.
4. Hamidi, O., L. Tapak, H. Abbasi, and Z. Maryanaji, 2018. Application of random forest time series, support vector regression and multivariate adaptive regression splines models in prediction of 365 snowfall (a case study of Alvand in the middle Zagros, Iran). *Theoretical and Applied Climatology*, 134(3-4): 769-776. doi:10.1007/s00704-017-2300-9.
5. Hart, E., K. Sim, K. Kamimura, C. Meredieu, D. Guyon, and B. Gardiner, 2019. Use of machine learning techniques to model wind damage to forests. *Agricultural and Forest Meteorology*, 265: 16-29. doi:10.1016/j.agrformet.2018.10.022.
6. Hu, Y., T. Che, L. Dai, and L. Xiao, 2021. Snow depth fusion based on machine learning methods for the Northern Hemisphere. *Remote Sensing*, 13(7): 1250. doi:10.3390/rs13071250.
7. Kim, D., Y. Jeong, S. I. Lee, J. Lee, K. Hwang, and W. Choi, 2021. Development of Snow Load Sensor and Analysis of Warning Criterion for Heavy Snow Disaster Prevention Alarm System in Plastic Greenhouse. *Journal of The Korean Society of Agricultural Engineers*, 63(2): 75-84. doi:10.5389/KSAE.2021.63.2.075. (in Korean).
8. Kim, Y., N. Kang, S. Kim, and H. Kim, 2013. Evaluation for Snowfall Depth Forecasting using Neural Network and Multiple Regression Models. *Korean Society of Hazard*

- Mitigation*, 13(2): 269-280. doi:10.9798/KOSHAM.2013.13.2.269. (in Korean).
9. Kim, Y., S. Kim, N. Kang, T. Kim, and H. Kim, 2014. Estimation of Frequency Based Snowfall Depth Considering Climate Change Using Neural Network. *Journal of Korean Society of Hazard Mitigation*, 14(1): 93-107. doi:10.9798/KOSHAM.2014.14.1.93. (in Korean).
 10. Kwon, S. H., and G. Chung, 2017. Estimation of Snow Damages using Multiple Regression Model - The Case of Gangwon Province -. *KSCE Journal of Civil and Environmental Engineering Research*, 37(1): 61-72. doi: 10.12652/Ksce.2017.37.1.0061. (in Korean).
 11. Lee, H. J., and G. Chung, 2019. Categorical Prediction and Improvement Plan of Snow Damage Estimation using Random Forest. *Journal of Wetlands Research*, 21(2): 157-162. doi:10.17663/JWR.2019.21.2.157. (in Korean).
 12. Lee, S. I., Y. J. Jeong, J. H. Lee, G. Chung, and W. Choi, 2020. Development of a heavy snowfall alarm model using a Markov chain for disaster prevention to greenhouses. *Biosystems Engineering*, 200: 353-365. doi:10.1016/j.biosystemseng.2020.10.019.
 13. Liang, H., M. Zhang, and H. Wang, 2019. A neural network model for wildfire scale prediction using meteorological factors. *IEEE Access*, 7: 176746-176755. doi:10.1109/ACCESS.2019.2957837.
 14. Lu, H., M. Chen, and W. Kuang, 2020. The impacts of abnormal weather and natural disasters on transport and strategies for enhancing ability for disaster prevention and mitigation. *Transport Policy*, 98: 2-9. doi:10.1016/j.tranpol.2019.10.006.
 15. Ministry of the Interior and Safety (2021), *2020 Disaster Report*. pp. 276-352.
 16. Oh, Y., and G. Chung, 2017. Estimation of Snow Damage and Proposal of Snow Damage Threshold based on Historical Disaster Data. *KSCE Journal of Civil and Environmental Engineering Research*, 37(2): 325-331. doi: 10.12652/Ksce.2017.37.2.0325. (in Korean).
 17. Oh, Y., G. Lee, K. S. Jun, W. Sunwoo, S. Baek, and G. Chung, 2020. A Study on the Prediction of 390 Daily Snowmelt Depth using Multiple Linear Regression. *Journal of the Korean Society of Hazard Mitigation*, 20(6): 311-321. doi:10.9798/KOSHAM.2020.20.6.311. (in Korean).
 18. Park, H., S. Jeong, and G. Chung, 2014. Frequency Analysis of Future Fresh Snow Days and Maximum Fresh Snow Depth using Artificial Neural Network under Climate Change Scenarios. *Journal of Korean Society of Hazard Mitigation*, 14(6): 365-377. doi:10.9798/KOSHAM.2014.14.6.365. (in Korean).
 19. Perera, A. T. D., V. M. Nik, D. Chen, J. L. Scartezzini, and T. Hong, 2020. Quantifying the impacts of climate change and extreme climate events on energy systems. *Nature Energy*, 5(2): 150-159. doi:10.1038/s41560-020-0558-0.
 20. Rössli, T., C. Appenzeller, and D. N. Bresch, 2021. Towards operational impact forecasting of building damage from winter windstorms in Switzerland. *Meteorological Applications*, 28(6): e2035. doi:10.1002/met.2035.
 21. Scherer, W. T., and D. M. Glagola, 1994. Markovian models for bridge maintenance management. *Journal of Transportation Engineering*, 120(1): 37-51. doi:10.1061/(ASCE)0733-947X(1994)120:1(37).
 22. Song, M. S., H. S. Yun, J. J. Lee, D. M. S. G. Yum, 2022. A Comparative Analysis of Machine Learning Algorithms for Snowfall Prediction Models in South Korea, *Natural Hazards and Earth System Sciences*, preprint. doi:10.5194/nhess-2022-118.
 23. Zhang, X., X. Li, L. Li, S. Zhang, and Q. Qin, 2019. Environmental factors influencing snowfall and snowfall prediction in the Tianshan Mountains, Northwest China. *Journal of Arid Land*, 11(1): 15-28. doi:10.1007/s40333-018-0110-2.