

머신러닝을 이용한 침수 깊이와 위치예측 모델 개발

강지욱* · 박종혁* · 한수희* · 김경준**

Development of Machine Learning based Flood Depth and Location Prediction Model

Ji-Wook Kang* · Jong-Hyeok Park* · Soo-Hee Han* · Kyung-Jun Kim**

요약

최근 국지성 폭우로 인한 침수 피해가 빈번하게 발생함에 따라 침수 피해를 사전 예방하기 위한 침수 예측 연구가 진행되고 있다. 본 논문에서는 머신 러닝 기반으로 강우 데이터를 이용해 침수 깊이와 침수 위치를 예측하는 모델을 개발하는 방법을 연구한다. 실시간 강우량을 입력으로 사용하여 다양한 강우 분포 패턴에 강건하게 구성하고 적은 메모리로 모델을 학습시킬 수 있는 2가지 데이터 셋(set) 구성 방법을 제시하였다. 침수에 유의미한 영향을 미치는 valid total 데이터는 침수 위치는 잘 예측했지만, 특정 강우 패턴에 대해 값이 다르게 나타나는 경향을 띠었다. 부분적이지만 침수에 영향을 미치는 영역을 valid local이라 한다. Valid local은 고정 점 방법에 대해서는 잘 학습되었지만, 임의점 방법에 대해서는 침수 위치를 정확하게 나타내지 못했다. 본 연구를 통해 실시간으로 침수 깊이와 위치를 예측할 수 있게 되어 큰 피해를 예방할 수 있을 것으로 예상된다.

ABSTRACT

With the increasing flood damage by frequently localized heavy rains, flood prediction research are being conducted to prevent flooding damage in advance. In this paper, we present a machine-learning scheme for developing a flooding depth and location prediction model using real-time rainfall data. This scheme proposes a dataset configuration method using the data as input, which can robustly configure various rainfall distribution patterns and train the model with less memory. These data are composed of two: valid total data and valid local. The one data that has a significant effect on flooding predicted the flooding location well but tended to have different values for predicting specific rainfall patterns. The other data that means the flood area partially affects flooding refers to valid local data. The valid local data was well learned for the fixed point method, but the flooding location was not accurately indicated for the arbitrary point method. Through this study, it is expected that a lot of damage can be prevented by predicting the depth and location of flooding in a real-time manner.

키워드

Machine Learning, Flood Prediction, Random Forest, KNN, Dataset Construction

머신 러닝, 침수 예측, 랜덤 포레스트, K-최근접 이웃, 데이터셋 구축

* 포항공과대학교 IT융합공학과
(jwgangsheep@postech.ac.kr, jhpark.cocel@postech.ac.kr,
soohee.han@postech.ac.kr)

** 교신저자 : 포항공과대학교 IT융합공학과

• 접수일 : 2022. 12. 21
• 수정완료일 : 2023. 01. 16
• 게재확정일 : 2023. 02. 17

• Received : Dec. 11, 2022, Revised : Jan. 16, 2023, Accepted : Feb. 17, 2023

• Corresponding Author : Kyung-Jun Kim

Dept. of IT Convergence Engineering,, Pohang University of Science and Engineering
Email : kimkj0408@postech.ac.kr

I. 서론

최근 지구온난화가 진행됨에 따라 태풍, 폭우, 국지성 호우 등 이전과 다른 피해가 빈번하게 발생하고 있다[1, 2]. 특히 2022년에는 강남침수('22.8.9), 헌남노의 영향에 의한 포항 침수('22.9.6) 등 국지성 호우에 따른 홍수와 침수 피해가 발생했으며, 이에 따라 다수의 인명 피해와 산업시설 등 적지 않은 재산 피해가 발생하였다.

이러한 피해에 대비하기 위해 많은 강수 및 침수 지역 예측 연구가 진행되고 있다[3]. 기존의 연구는 수치해석적 접근이나 통계적 접근법을 사용하였다. 하지만 이 같은 접근 방식은 비선형 방정식을 푸는 등 예측에 많은 시간이 소요된다. 따라서, 국지성 호우 등 제한된 지역 및 시간에 발생할 수 있는 침수피해를 감안했을 때, 실시간으로 특정 지역의 강수량 혹은 침수 지역을 예측하는 데에 적합하지 않았다[4].

이런 문제점을 해결하기 위해 최근에는 비선형 예측에 좋은 성능을 보이는 머신러닝 방법[5, 6]을 이용해 강우 혹은 침수 지역을 예측하려는 연구가 새롭게 주목받고 있다. Lee와 Kim은 태풍 차바 강우량을 시뮬레이션으로 재현해 당시 큰 피해가 발생했던 대화강 인근의 침수 데이터를 로지스틱 회귀로 학습시켜 침수 지역을 예측하는 연구를 진행했다[2]. Hou et al.도 도시 침수예측 모델로 랜덤포레스트, K-최근접 이웃 알고리즘, 그 둘을 합친 모델 등을 사용하였다[3]. Motta et al.은 침수 및 기후 데이터 전처리 기법과 다양한 머신러닝 모델을 실험하고 이를 GIS 모델과 결합하여 리스본 부근의 침수 가능성이 높은 지역을 예측하는 연구를 수행하였다[4]. 하지만, 기존의 머신러닝을 이용한 방법은 강우 데이터를 주로 설계 강수량으로 사용하였는데 이에 따라 강우 실시간성을 반영하지 못하는 단점이 있다. 기존의 방법에서는 입력값인 강수량을 통계적으로 표현하여 재현 빈도, 강우 지속시간, Huff 4분할 분포 등으로 나타냈다[7].

본 논문에서는 실시간 강우량을 입력 데이터로 사용함으로써 기존 설계 강수량 사용 시 실시간성을 반영하지 못하는 단점을 대폭 개선했다. 따라서, 본 연구를 통해 일반적인 강우 특성 분석 외에 실시간 강우의 특성을 반영하였다. 이를 통해 다양한 강우 패턴에 대한 침수예측 방법을 제시하였다. 특히 도시지역

을 관통하는 강의 범람에 의해 발생하는 외수 침수에 대한 데이터의 특성을 분석하였다. 학습을 위한 전처리 기법을 제시하고, 학습에 적용하여 제안 데이터 전처리 기법의 성능을 분석하였다.

II. 데이터 학습방법

본 장에서는 학습을 위한 데이터를 분석하고 학습에 사용될 알고리즘을 소개한다[8, 9]. 학습 데이터는 임의의 강수량에 따라 경기도 남동쪽을 지나는 경안천 일대가 범람 데이터를 전처리하여 학습에 사용하였다.

2.1 학습 데이터 구성

학습 데이터의 구성은 침수예측 모델 학습을 위해 입력값과 목표가 되는 출력값으로 구성하였다. 학습 데이터를 얻기 위해, 우선 강수량을 입력, 침수 시뮬레이션을 수행하고, 목표로 하는 위치별로 침수 지역 데이터를 얻는다. 학습 데이터는 이상 강우와 Huff 분포로 표현되지 않는 일반적인 강우 패턴을 고려하여 시뮬레이션에 입력되는 강수량을 그대로 사용하였다. 강수량은 10분당 강수량으로 강우 지속시간은 1~6 시간 분포를 갖는다. 이다. 다양한 강우 지속시간을 표현하기 위해 전체 입력 길이를 최대 지속시간에 맞춰 36으로 고정하고 그보다 적은 지속시간에 대해서는 zero-padding을 적용하였다. 이런 데이터 처리는 비가 오지 않다가 비가 오기 시작하는 상황을 표현한 것으로도 볼 수 있다. 임의의 강우량에 대해 입력값은 Fig. 1과 같다.




그림 1. '0'으로 채워진 강우 데이터
Fig. 1. Zero-padded rainfall data

시물레이션 결과는 Fig. 2와 같이 나타난다. 경안천 인근을 3m × 3m 해상도로 수치 해석하여 전체 그림의 크기는 4,448 × 4,704픽셀이다. 이 중 경안천 인근을 제외한 지역은 수치해석에 사용되지 않았고 None으로 처리되어있다. 전체 영역 중 침수 데이터가 존재하는 지역은 약 20만 픽셀로 전체 데이터 중 약 1%이다. 최대 침수심은 1,725 × 3,679픽셀 부근에서 발생한 18m이다. 데이터 중에는 하천 영역도 포함되어 있어 해당 부분은 실제로 범람에 의해 침수된 것이 아니고 물이 흐르는 것이 평소 상태이기 때문에 데이터 후처리를 통해 침수 예측 영역에서 분리해야 한다.



그림 2. 경안천 침수 이미지(335개) 데이터
Fig. 2. No. 335 sample image of Gyeongangcheon flood

2.2 학습 데이터 생성을 위한 전처리 기법

침수심 예측 모델을 학습시킬 때 단순하게 전체 데이터를 사용하면 2-1절에서 설명한 것처럼 데이터의 대부분을 차지하는 None으로 처리된 데이터도 사용하기 때문에 불필요한 메모리까지 사용하게 되는 단점이 있다. 랜덤포레스트(Random Forest, RF)와 K-최근접 이웃(K-Nearest Neighbor, KNN) 모델은 연속 학습이 불가능해 학습시킬 데이터를 한 번에 처리해야 하므로 메모리 사용량을 최소화할 필요가 있다 [8, 9]. 메모리 사용량이 증가할 경우 학습할 수 있는 데이터의 의미 있는 양이 줄어들고 모델 자체의 표현력이 떨어지게 된다. 데이터 전처리는 아래 두 방법으로 실험하였다.

첫째는 None 처리된 부분을 제거하기 위해 한 번이라도 침수가 되었던 영역만 골라서 해당 부분만 학습에 사용하는 방법이다. 이 부분은 231,432픽셀로 전체 픽셀에 대해 약 1.1%로 학습에 필요한 데이터와

파라미터 수가 기하급수적으로 줄어든다. 이 데이터를 ‘valid total’라고 한다.

둘째는 전체 결과 중 침수에 유의미한 영향을 미치는 부분으로 일부만 포함해 사용하는 데이터를 valid local 데이터라 하며, 이때는 자른 위치에 따라 데이터를 구분하기 위해 입력값으로 자른 이미지 중앙의 좌표값을 추가해준다. 이 데이터를 ‘valid local’라고 한다. 이번 연구에선 잘린 이미지가 128×128픽셀이 되도록 설정하였다. 이때 나누어진 데이터가 전체 영역의 정보를 모두 담을 수 있도록 강수 데이터 당 최소 20개의 부분 데이터를 생성하였다. 생성된 모델이 전체 영역에 대한 정보를 표현할 수 있는지 확인하기 위해 고정된 영역을 생성하는 유형과 임의의 영역을 생성하는 유형을 나누어 비교하였다. 두 가지 전처리 방식을 통한 학습 개념을 Fig. 3에서 제시하였다.

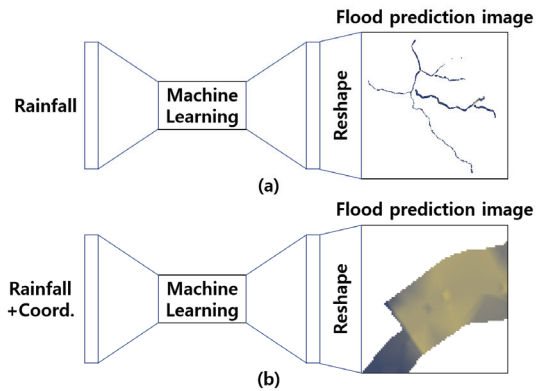


그림 3. 데이터 전처리 모델의 개념: (a) 전체 유효데이터, (b) 부분 유효데이터

Fig. 3. A schematic diagram of model for each pre-processed data (a) total valid, (b) local valid

2.3 알고리즘

침수심 예측 모델을 만들기 위해 머신 러닝에서 잘 알려진 랜덤포레스트(RF)와 K-최근접 이웃(KNN) 모델을 사용하였다. RF는 의사결정나무 구조의 앙상블 모델로 예측의 변동성이 현저히 감소하고 그로 인해 결측치에 강건하다[10, 11, 12, 13]. 본 논문에서 사용된 데이터의 축소한 것을 감안했을 때 결측치의 비율이 높아져도 비교적 정확도가 높게 나온다는 특징이 있다[7]. KNN은 입력 데이터 사이의 거리를 기반으

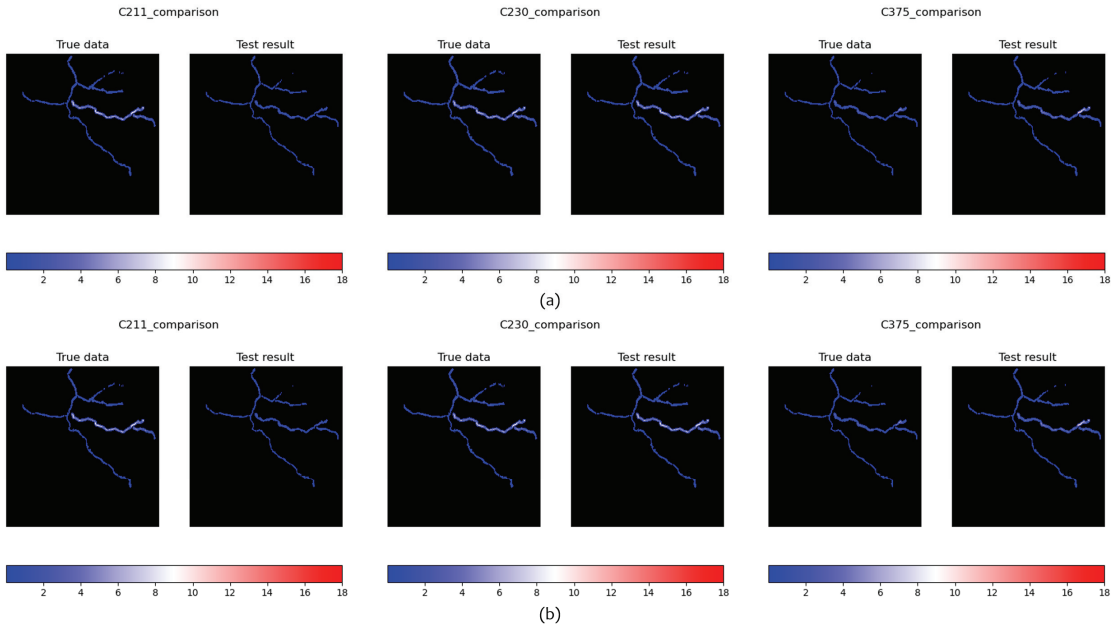


그림 4. 유효 데이터 셋에 대한 침수예측 결과 (a) KNN (b) Random Forest
 Fig. 4. Estimated flood for 'Valid total' dataset (a) KNN (b) Random Forest

로 가장 가까운 데이터들의 값을 사용하는 모델로 학습에 시간이 거의 들지 않는다는 특징이 있다[8]. 오류 데이터가 결과값에 크게 영향을 미치지 않는다는 장점이 있다. 두 알고리즘 모두 정형 데이터에 잘 적용되는 알고리즘이기 때문에 예측 모델에 적합할 것으로 판단되어 사용하였다. 두 알고리즘의 구현은 파이썬 라이브러리 중 하나인 'Sci-kit learn'에 내재한 함수를 사용하였다[14]. 사용된 파이썬과 Sci-kit 버전은 각각 3.7.11, 1.0.2이다.

III. 모델 학습 및 결과

본 장에서는 제안된 데이터 전처리 방법에 따라 딥러닝 기법의 성능을 비교하는 실험을 수행하였다.

3.1 전체유효 데이터셋 학습 및 결과

전체 690개의 데이터(Valid total) 중 95%를 학습에 사용하고 나머지 5%는 성능 확인에 사용하였다. 이 데이터셋에 대해 RF의 하이퍼파라미터로 $n_{estimator}=20$ 을 사용하였고 KNN의 하이퍼파라미터는 $K=10$ 을 사용

하였다. 모델을 학습한 결과는 Table. 1과 Fig. 4와 같다. Table. 1의 위쪽 4개 지표는 침수 깊이 예측, 아래쪽 5개 지표는 침수 위치 예측의 성능을 나타낸 것이다.

표 1. 전체 유효데이터 셋에 대한 모델 성능
 Table 1. Model performance for total dataset

Metric	Random Forest	KNN	Def.
RMSE	1.103	1.070	$\sum_{i=1}^n (\hat{y}_i - y_i) / n$
RMSE/Mean	0.657	0.638	
Max. - Min. error	9.94	9.85	
MRE	0.606	0.570	$\sum_{i=1}^n \frac{ \hat{y}_i - y_i }{ny_i}$
Sensitivity	0.929	0.923	TP/P
Precision	0.879	0.885	TP/(TP+FP)
F1	0.887	0.887	$\frac{2TP}{2TP+FP+FN}$
Accuracy	0.851	0.851	$(TP+TN)/(P+N)$
IoU	0.809	0.808	$\frac{ A \cap B }{ A \cup B }$

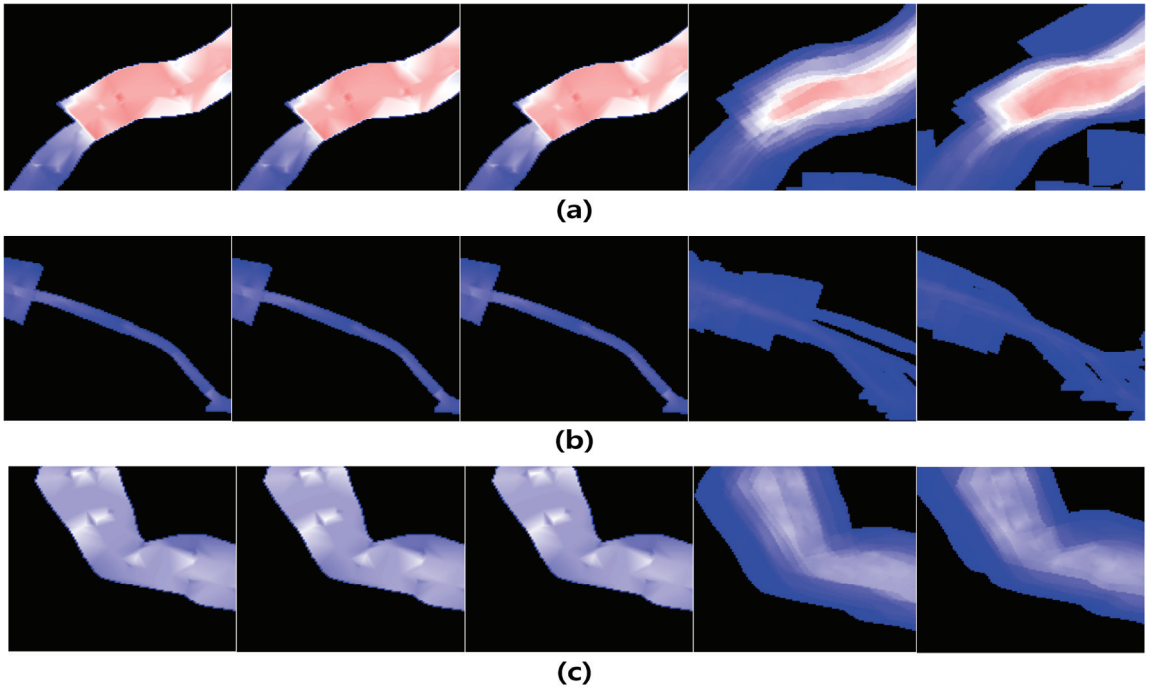


그림 5. 유효 지역 데이터셋에 대한 침수 평가: 왼쪽부터 시뮬레이션 결과, KNN-F20, RF-F20, KNN-R20, RF-R20, 강우량 패턴 번호 (a) 225번, (b) 550번, (c) 668번
 Fig. 5. Estimated flood for 'Valid local' dataset: from left, true simulation, KNN-F2, RF-F20, KNN-R20, RF-R20, for rainfall data (a) No. 225, (b) No. 550, (c) No. 668

침수 예측 결과 중 침수 깊이 예측 성능은 RF와 KNN 모두 RMSE가 평균에 비해 60%가 넘고 MRE 역시 각각 60.6%, 57.0%로 전체에 대해 균일하게 학습되었다고 보기 어렵다. 침수 위치 예측 성능은 대부분 지표에서 80%를 넘어 예측 성능을 갖춘 것으로 볼 수 있다. Fig. 4는 각 모델에 의해 생성된 예측 침수 모형을 보여준다. 211번 강우 데이터에 대해서는 RF와 KNN 모두 오른쪽 강줄기에 적은 침수 깊이를 예측하며 과소평가하는 양상을 보여준다.

3.2 지역 데이터셋 학습 및 결과

이 데이터셋(Valid local)은 한 강우 데이터에 대해 20개의 지역 이미지를 생성하였기 때문에 총 13,800개의 데이터로 구성되어 있고 95%를 학습에 사용하고 5%를 성능 검증에 사용하였다. 데이터 셋을 생성할 때 고정된 점들은 침수가 자주 발생하는 지역을 사전에 선정하여 생성하였고 임의의 점들은 전체 영역 중 침수가 발생한 곳 중에 임의로 위치를 선정하여 생성

하였다. 머신 러닝 알고리즘은 마찬가지로 RF와 KNN을 사용하였고 하이퍼파라미터 또한 3.1과 같이 설정하였다. 모델 학습 결과는 Table. 2와 Fig. 5와 같다. Table. 2에서 고정된 점 데이터는 F, 임의의 점 데이터는 R으로 표현되었다. 뒤의 숫자는 지역 이미지 개수이다. 예를 사용한 인공지능 모델은 랜덤포레스트 및 KNN모델이며, 이 모델의 학습을 위한 포인트를 다음과 같이 사용하였다. R20은 임의점(random point) 20개, F20은 고정점(fixed point) 20을 가정하고 학습한 것을 의미한다.

Fig. 5에서는 RF와 KNN 모두 고정된 점들에 대해서는 잘 학습되었지만 임의의 점들에 대해서는 결과를 제대로 생성하지 못하였다. 특히 임의의 점들에 대해서는 실제와 비슷한 침수 위치 형태를 띠지만 고정된 점들과 다르게 한 위치에 선명하게 나타나지 않고 여러 위치에 겹쳐서 나타났다.

이는 학습에 사용된 데이터가 위치 정보를 충분히 담고 있지 않은 것으로 생각할 수 있다. 데이터를 분

할했기 때문에 좌표 정보와 실제 침수 사이의 관계를 학습시킬 만큼 표현력이 갖춰지지 않은 것으로 볼 수 있다. 이를 확인하기 위해 임의의 점의 개수를 50개로 늘려서 표현력이 늘어나는지 추가 실험하였다. Table. 3에서 RMSE(root mean squared error), MRE(mean squared error), IoU(intersection over union)과 분류 모델 평가지표인 F1에 대해 평가하였다.

표 2. 부분 유효데이터 셋에 대한 모델 성능
Table 2. Model performance for local valid dataset

Metric	RF-R20	KNN-R20	RF-F20	KNN-F20
RMSE	0.944	1.167	0.031	0.023
RMSE/Mean	0.398	0.486	0.018	0.013
Max. - Min. error	6.351	6.351	0.107	0.082
MRE	0.365	0.363	0.032	0.019
Sensitivity	0.514	0.476	0.965	0.981
Precision	1.000	1.000	1.000	1.000
F1	0.661	0.630	0.980	0.990
Accuracy	0.998	0.997	1.000	1.000
IoU	0.512	0.473	0.964	0.980

표 3. 부분 유효데이터 셋의 데이터 개수에 의한 성능
Table 3. Performance for different data points

Metric	KNN-R20	KNN-R50
RMSE	1.167	1.024
RMSE/Mean	0.486	0.426
Max. - Min. error	6.351	6.350
MRE	0.363	0.292
Sensitivity	0.476	0.984
Precision	1.000	0.532
F1	0.630	0.680
Accuracy	0.997	0.842
IoU	0.473	0.530

위치 예측에서 정밀도와 정확도는 떨어졌지만 민감도는 높아졌고 F1과 IoU도 올랐다. 침수 깊이 예측에

서는 모든 지표에서 성능이 좋아져 데이터셋을 이루는 점의 개수가 많을수록 데이터의 손실이 적은 것을 확인할 수 있다.

IV. 결 론

본 논문에선 증가하고 있는 침수 사고에 실시간으로 대비하기 위해 머신러닝을 이용해 침수 지역과 깊이를 예측하는 방법을 연구하였다. 특히 용량이 큰 침수 데이터를 비교적 적은 메모리를 사용하여 다루는 데이터 셋 구성 방법을 제안하였다. 제안된 데이터 셋 구성에 따라 RF, KNN 등 알고리즘을 사용하여 성능을 비교하였다. ‘valid total’ 방식은 지역 예측엔 좋은 성능을 보여주었다. 반면, 침수 깊이 예측에선 입력 데이터에 따라 과대평가 혹은 과소평가하는 경향을 띠었다. ‘valid local’ 방식은 고정 점에서는 좋은 성능을 보여줬지만, 임의점 선정 방식에서는 침수 깊이와 지역 모두 제대로 예측하지 못했다. 이는 학습 데이터 개수의 한계 혹은 제한된 메모리에 의한 모델 파라미터 수의 불충분 등의 이유로 발생한 것으로 판단된다.

추후 역합성곱(Deconvolution) 층이나 생산적 적대 신경망(Generative adversarial network, GAN), 변분 오토인코더(Variational AutoEncoder, VAE) 등을 이용하면 학습에 필요한 메모리 자원 최소로 하면서 침수예측 모델을 구성할 수 있다. 또 제안 방법에서 특정 지역에 대해서만 모델을 학습하여 지역적 특성을 나타내는 정보를 입력값으로 사용하지 않았지만, 후속 연구에서는 수치표고모델(Digital Evaluation Models, DEM) 등을 활용하여 전 지역에 사용 가능한 모델을 개발할 예정이다.

감사의 글

본 논문은 2022년도 행정안전부 ‘기후변화대응 AI기반 풍수해위험도 예측기술개발 사업의 지원으로 수행되었음 (No. 2022MOIS61-002)

References

- [1] C. Lee, "Train Location and Control using Spread Spectrum Radio Communications," United States Patent, no. 5420883, May 30, 1995.
- [2] B. Kim, O. Kim, H. Kwon, and S. Yoon, "Climate change effect of rainfall frequency analysis using high resolution RCM data," in *Proceeding of the 30th Annual Korea Water Resources Association Conference*, Gyeongju, Korea, 2008, pp. 224-228.
- [3] J. Lee and B. Kim, "Scenario-based real-time flood prediction with logistic regression," *Water*, vol. 13, no. 9, Apr. 2021, pp. 1191.
- [4] J. Hou, N. Zhou, G. Chen, M. Huang, and B. Bai, "Rapid forecasting of urban flood inundation using multiple machine learning models," *Natural Hazards*, vol. 108, May. 2021, pp. 2335-2356.
- [5] J. Choi and H. Choi. "Prediction of Wind Power Generation using Deep Learning," *The Journal of The Korea Institute of Electronic Communication Sciences*, vol. 16, no. 2, 2021, pp. 329-338.
- [6] G. Bak and Y. Bae. "Groundwater Level Prediction Using ANFIS Algorithm." *The Journal of the Korea Institute of Electronic Communication Sciences*, vol. 14, no. 6, Dec. 2019, pp. 1235 - 1240
- [7] M. Motta, M. de Castro Neto, and P. Sarmiento, "A mixed approach for urban flood prediction using machine learning and GIS," *Natural International Journal of Disaster Risk Reduction*, vol. 56, Apr. 2021, pp. 102154
- [8] B. Leo, "Random forests," *Machine Learning*, vol. 45, 2001, pp. 5-32.
- [9] T. Cover and P. Hart, "Nearest neighbor pattern classification," *IEEE Transactions on Information Theory*, vol. 13, 1967, pp. 21-27.
- [10] A. B. Ranit and P. V. Durge, "Different Techniques of Flood Forecasting and Their Application," in *Proc. of 2018 International Conference on Research in Intelligent and Computing in Engineering (RICE)*, El Salvador, El Salvador, Aug. 2018.
- [11] S. Bande and V. V. Shete, "Smart Flood Disaster Prediction System using IoT & Neural Networks," in *Proc. of 2017 International Conference On Smart Technologies For Smart Nation (SmartTechCon)*, Bengaluru, India, 2017.
- [12] S. Kurnaz, S. Salahova, R. B. Rustamov, and M. Zeynalova, "River Inundation Impact Reduction Based on Space Technology Application," in *Proc. of 2009 4th International Conference on Recent Advances in Space Technologies*, Istanbul, Turkey, June 2009.
- [13] S. Park, "Adaptive Sea Level Prediction Method Using Mearured Data," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 12, no. 5, 2017, pp. 891-898.
- [14] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderpals, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchensay, "Scikit-learn: Machine learning in Python," *the Journal of Machine Learning Research*, vol. 12, 2011, pp.2825-2830.

저자 소개

강지욱(Ji-Wook Kang)



2018년 포항공과대학교 기계공학과 학사

2018년-2021년 국방과학연구소 파견연구원

2021년-현재 포항공과대학교 IT융합공학과 석사 과정

※ 관심분야 : 강화 학습, 드론 제어, 비행 역학



박종혁(Jong-Hyeok Park)

2016년 포항공과대학교 기계공학과
학사

2016년-현재 포항공과대학교 IT융
합공학과 통합 과정

※관심분야 : 최적화, 강화 학습, 로봇 제어

한수희(Soo-Hee Han)



1998년 서울대학교 전자공학과 학
사

2000년 서울대학교 전기정보공학부
석사

2003년 서울대학교 전기정보공학부
박사

2003년-2007년 서울대학교 제어계측신기술연구센터
연구원


2008년 로봇 소프트웨어 연구센터 연구원

2009년-2014년 건국대학교 전자공학과 교수

2014년-현재 포항공과대학교 IT융합공학과 교수

※관심분야 : 최적화, 강화 학습, 배터리 인포매틱스

김경준(Kyung-Jun Kim)



1996년 경일대학교 컴퓨터공학과
(학사)

1999년 경북대학교 대학원 전산공
학전공(석사)

2005년 경북대학교 대학원 정보통
신학과(박사)

2006년 호남대학교 전파이동통신공학과 교수

2009년 한국과학기술원 전산학과 연구부교수

2012년 대구디지털산업진흥원 책임연구원

2013년 ~현재 포항공과대학교 (전)인공지능연구원
연구부장/연구부교수, IT융합공학과 연구부교수

※ 관심분야 : 재난의사결정시스템, AIoT, 산업AI