

AI 기반 홍수 예·경보 시스템의 정보 전달력 향상을 위한 모형 개선

유문무* · 백선욱** · 김동현*** · 이승민** · 김수준**†

*한국스마트워터그리드학회

**인하대학교

***KB손해사정

Improvement of models to enhance the information delivery capability of AI-based flood early warning systems

Mun Mu Yoo* · Seon Uk Baek** · Dong Hyun Kim*** · Seung Min Lee** · Soo Jun Kim**†

*The Society of Korean Smart Water Grid

**Inha University

***KB Claims Survey & Adjusting

(Received : 18 August 2025, Revised : 15 September 2025, Accepted : 15 September 2025)

요약

2023년은 세계적으로 기록적인 고온과 강수량을 나타낸 해로, 필리핀과 같은 열대성 저기압 영향권 국가에서는 태풍과 집중호우로 인한 홍수 및 산사태 위험이 크게 증가하였다. 특히 필리핀 동비사야스 지역은 기존 홍수 경보 시스템의 한계로 인해 실질적인 대응 능력이 부족한 상황이었다. 본 연구는 이러한 문제를 해결하기 위해 AI 기반 홍수 위험 예측 및 실시간 수위 예측 모형을 개발하였다. 머신러닝 기법 중 랜덤포레스트(RF)와 의사결정나무(Tree)를 활용한 홍수 위험 등급 분류에서는 RF 모형이 전체 F1-Score 0.83으로 우수한 성능을 나타냈으며, Tree 모형은 F1-Score 0.66으로 상대적으로 낮은 성능을 보였다. 실시간 수위 예측에는 딥러닝 기반 트랜스포머(Transformer) 모형을 적용하여 CC 0.92, NRMSE 0.09로 강우량과 수위 시계열 데이터를 기반으로 전체 수위 패턴과 첨두 수위를 정밀하게 예측하였다. 연구 결과, AI 기반 모형은 기존 관측 장비와 전문가 판단에 의존한 홍수 관리 방식의 한계를 보완하며, 체계적이고 신뢰 가능한 홍수 예측 및 경보 제공을 가능하게 한다. 향후 연구에서는 다양한 수문 데이터를 추가하고 모형을 지속적으로 개선함으로써 지역 사회의 재난 대응 역량 강화에 기여할 수 있을 것으로 기대된다.

핵심어 : 시간 수위 예측, 재난 대응, 집중호우, 트랜스포머 모형

Abstract

The year 2023 recorded historically high temperatures and increased precipitation globally, with the Philippines particularly affected due to its vulnerability to tropical cyclones and typhoons. In the Eastern Visayas region, including Biliran Island, frequent floods and landslides have highlighted the limitations of existing flood warning systems, which rely primarily on observational equipment and expert judgment and often lack systematic coverage. This study develops an AI-based flood hazard classification and real-time water level prediction framework to enhance disaster preparedness and response. For flood hazard classification, machine learning models—Random Forest (RF) and Decision Tree (Tree)—were employed. The RF model demonstrated superior performance with an overall F1-Score of 0.83 across all hazard classes, whereas the Tree model achieved an F1-Score of 0.66, indicating relatively lower predictive accuracy. For real-time water level prediction, a deep learning Transformer model was applied, utilizing rainfall and water level time-series data to accurately forecast overall patterns and peak water levels. Results show

†To whom correspondence should be addressed.

Inha University, Incheon, Korea

E-mail : sk325@inha.ac.kr

- Mun Mu Yoo The Society of Korean Smart Water Grid/Ph.D.(yoomunmu@gmail.com)
- Seon Uk Baek Inha University/Ph.D. candidate(tjsdnr9597@naver.com)
- Dong Hyun Kim KB Claims Survey & Adjusting/Ph.D. (yedsdktpdi@naver.com)
- Seung Min Lee Inha University/Ph.D. candidate(wooz1187@gmail.com)
- Soo Jun Kim Inha University/Ph.D.(sk325@inha.ac.kr)



This is an open-access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

that integrating machine learning and deep learning models can overcome the limitations of conventional flood management approaches, providing reliable hazard predictions and actionable information for early warning systems. The proposed AI framework enhances the timeliness and accuracy of flood alerts, supporting more effective disaster response. Future research should incorporate additional hydrological data and continuously refine the models to further improve predictive accuracy and strengthen local community resilience against floods.

Key words : Real-time water level prediction, Disaster response, Heavy rainfall, Transformer model

1. 서론

세계기상기구(World Meteorological Organization, WMO)에 따르면, 2023년은 역사상 가장 높은 기온을 기록한 해로 평가되었다. 산업화 이전(1850~1900년) 수준 대비 $1.45 \pm 0.12^\circ\text{C}$ 높은 기온을 나타냈으며, 특히 6월부터 12월까지 매월 월간 최고기온을 경신하였다. 7월과 8월은 역대 최고치를 기록하며 극값을 갱신하였다. 이로 인해 2023년 연평균 기온은 13.7°C 로 평년(12.5°C)보다 1.2°C 높았으며, 이는 기상청 관측이 시작된 1973년 이후 가장 높은 수치이다. 또한, 연간 강수량은 $1,476.0\text{mm}$ 로 평년 대비 31.8% 증가하여 역대 3위에 해당하였다(Han et al., 2025; Kim et al., 2018; Kim et al., 2019; Kwak et al., 2016).

필리핀은 열대성 저기압과 태풍의 영향을 강하게 받는 국가로, 이러한 기후 변화는 특히 사회·경제적 취약성이 높은 지역에서 큰 영향을 미친다. 2023년에도 필리핀 전역은 태풍과 집중호우로 인해 평년 대비 높은 기온과 강수량을 경험했으며, 동부 지역과 도서 지역에서는 홍수 및 산사태 위험이 크게 증가하였다. 연간 강수량의 급증과 극한 기온 현상은 농업 생산성과 지역 사회 인프라에 직·간접적인 피해를 유발하며, 기존 재난 관리 및 홍수 경보 시스템의 한계 또한 부각시키고 있다(Kim et al., 2022a; 2022b).

이러한 기후 현상은 태평양 해수면 온도의 상승과 밀접한 관련이 있으며, 해수면 온도가 평년보다 높아짐에 따라 대기로 유입되는 수증기 양이 증가하였다. 그 결과 대기 내 지속적인 상승기류가 형성되어 국지적 강수와 집중호우를 유발하고, 홍수 발생 가능성을 높이는 환경을 조성하였다(Ministry of the Interior and Safety, 2023). 이는 전 지구 평균기온 상승과 지구온난화에 따른 이상기후 발생 빈도의 증가와 맞물려, 매년 인명과 재산 피해 규모가 확대되고 있음을 뒷받침한다.

최근 홍수의 특징은 좁은 공간에서 짧은 시간 동안 집중 호우가 발생하여 상류에서 하류까지 유량이 급격히 증가하는 양상을 보인다. 현재 홍수통제소의 홍수 예보 선행 시간은 약 3시간으로 추산되지만, 예보의 정확성과 신속성을 높이기 위해 선행 시간을 확대하려는 노력이 지속적으로 이루어지고 있다(Granata et al., 2016; Ghumman et al., 2011; Shoaib et al., 2004; Yang et al., 2024).

특히 도시와 산지 지역에서는 홍수 도달 시간이 짧아 선행 시간을 확보하기 위해 데이터 기반 모형의 활용이 중요하다. 데이터 기반 모형은 물리적 메커니즘을 직접적으로 구현하지 않고, 과거 데이터와 물리적 기반 수문 모형에서 고려되는

과정 간의 상관관계를 학습하여 물리적 현상을 해석한다. 최근 데이터 시스템과 컴퓨터 하드웨어의 급속한 발전으로 데이터 기반 모형의 적용 범위가 확대되었으며, 지난 10년간 수문 분야에서의 활용도가 크게 증가하였다(Abrahant et al., 2004; Kim et al., 2020; Mosavi et al., 2018; Yan et al., 2018).

현재 홍수 예·경보는 기존 관측 장비로 수집된 데이터를 각 장치에서 센터로 전송하고, 실무자의 경험과 판단에 기반하여 발령되고 있다. 이러한 방식은 선행 시간 확보와 예보 일관성 측면에서 한계를 가지며, 보다 신속하고 정확한 대응이 어려운 문제점을 안고 있다. 따라서 데이터 기반 홍수 예측 모형의 개발 필요성이 대두되고 있으며, 이를 통해 산출된 예측 정보를 홍수 예·경보 시스템에 활용함으로써 신속하고 정확한 대응을 구현할 수 있다(Han et al., 2021; 2024; Kim et al., 2022a; 2022c).

데이터 기반 모형은 과거 관측 데이터를 활용하여 입력 변수, 내부 변수, 출력 간의 관계를 분석하고, 이를 바탕으로 미래를 예측한다. 머신러닝 기법은 분류(classification)에 특화되어 있어, 모형 예측 결과를 기반으로 홍수 예·경보 의사결정을 지원하며, 딥러닝 기술은 예측된 홍수 정보를 정밀하게 산출하고 전달하는 데 활용된다.

이에 본 연구에서는 머신러닝 모형을 활용하여 과거 및 실시간 데이터를 학습시키고, 일정 시간 후 유출 지점에서 홍수가 발생할 가능성을 판단하여 정보를 제공하고자 한다. 더불어 예측된 수위 및 홍수 정보를 정확하게 제시하기 위해 딥러닝 모형을 병행 활용한다. 이러한 접근은 모형별 장단점을 극대화하여 홍수 예·경보 시스템의 정보 전달력과 대응 효율성을 향상시키는 데 기여할 수 있다.

2. 방법론

2.1 의사결정나무

의사결정나무(decision tree, Tree)는 데이터 규칙을 기반으로 자료를 나무 형태(graph)로 표현하여 유사한 데이터를 세분화하고 항목별로 분류할 수 있는 모형이다(Breiman et al., 1984). 이 모형은 동적 계획법(dynamic programming)에 기반한 하향식 귀납법(top-down inductive approach)을 사용하며, 상위 노드에서 분리된 자료는 기준에 따라 유사한 집단으로 반복적으로 세분화되어 최종적으로 항목별 분류가 완전히 이루어진다(Kamiński et al., 2018).

Tree는 뿌리 노드(root node), 내부 노드(internal node), 끝 노드(leaf node), 가지(branch)로 구성된다. 끝 노드를

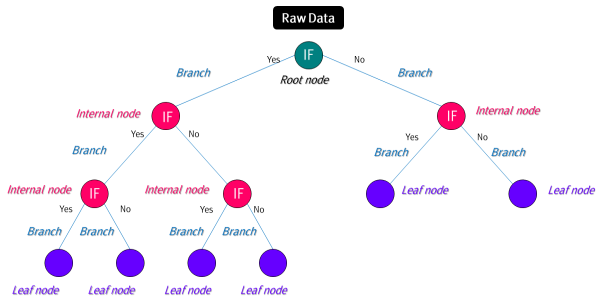


Fig. 1. Conceptual diagram of decision tree model

제외한 모든 노드에서는 분류 기준에 따라 조건문(conditional)을 학습하고 이를 바탕으로 예측 결과를 도출한다. 또한, 학습 과정에서 가지치기(pruning)를 통해 모델의 복잡성을 조절하고 예측 정확도를 향상시킬 수 있다. 가지치기 과정에서는 매개 변수별 정확도를 평가하여 최적의 매개 변수를 선택함으로써 보다 정확한 예측 결과를 얻는다(Fig. 1).

2.2 랜덤포레스트

랜덤포레스트(random forest, RF)는 앙상블(ensemble) 기반 모형으로, 여러 개의 의사결정나무를 학습시키고 이를 집계(aggregation)하여 최종 예측을 수행하는 배깅(bootstrap aggregation, bagging) 기법에 임의성(randomness)을 결합한 분류 모형이다. RF는 의사결정나무보다 일반적으로 높은 정확도를 나타내는 것으로 알려져 있다(Amit et al., 1997; Breiman, 2001).

RF는 학습 자료를 무작위로 추출하여 독립적인 tree를 총 n-tree개 생성하며, 통상 약 500개의 tree를 사용한다. 생성된 각 tree의 예측 결과는 투표(voting)를 통해 최종 결과를 결정한다. 또한, 각 노드에서 분할 기준에 사용할 변수의 개수를 무작위로 선택하며, 이를 분류기의 개수(mtry)라고 정의한다. 학습 과정에서는 최적의 매개 변수를 반복 학습을 통해 선정하여, 가장 우수한 성능의 예측 결과를 도출하도록 한다(Fig. 2).

2.3 트랜스포머 모형

트랜스포머(Transformer) 모델은 순환 신경망(Recurrent Neural Network, RNN) 모델에서 발전되었다. 시계열 데이터

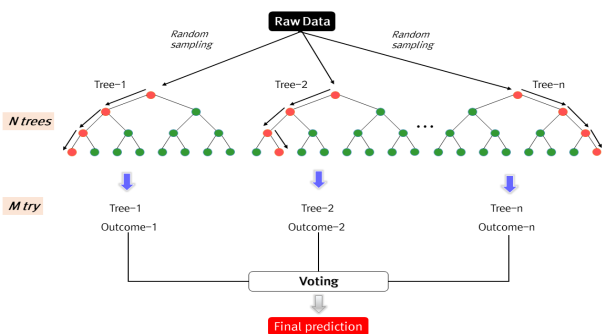


Fig. 2. Conceptual diagram of the random forest model

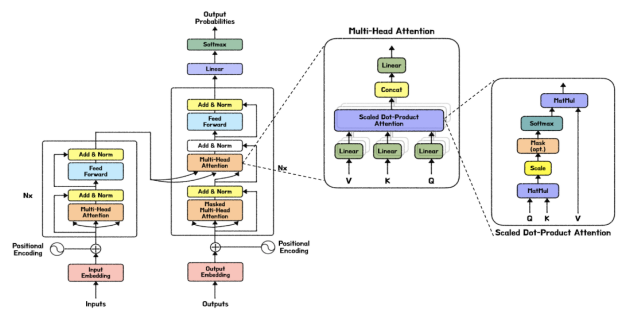


Fig. 3. Conceptual diagram of transformer

상에서 RNN 계열의 모델들은 입력 시퀀스 값을 학습하여 미래의 값을 예측하는데, 이러한 방식은 인코더-디코더(Encoder-Decoder) 구조 및 컨텍스트 벡터(context vector) 개념 도입을 통해 입력 시퀀스 기반 출력 시퀀스를 예측하는 시퀀스-투-시퀀스(Sequence-to-Sequence, Seq2Seq) 모델로 발전하였다(Sutskever et al., 2014).

2.4 모형의 정확도 평가

본 연구에서는 위험등급을 분류하고, 수위를 정밀하게 예측하는 모형을 각각 제시한다. 모형의 평가는 목적에 따라 적절한 지표를 통해 수행해야 한다. 따라서 위험등급 분류에는 F1-score를, 수위 예측에는 정규화 평균제곱근오차(Normalized Root Mean Squared Error, NRMSE)와 상관계수(Correlation Coefficient, CC)를 통해 모형을 평가하였다.

F1-score는 분류모형의 평가에 널리 활용되는 지표로, 결과물의 재현율(recall), 정밀도(precision)을 고려한다. 0~1의 범위를 가지며 값이 클수록 분류 정확도가 높다는 것을 의미한다.

NRMSE와 CC는 정확한 수치를 도출해야 하는 예측모형의 평가에 적절하다. NRMSE는 평균제곱근오차(Root Mean Squared, RMSE)를 0~1 범위로 정규화한 지표로, 표본의 범위 또는 크기에 따라 값의 범위가 달라 직관성이 떨어진다는 문제점을 가진 RMSE를 개선한 지표이다. 오차의 크기를 정규화하여 나타내기 때문에 NRMSE는 값이 작을수록 모형의 정확도가 높은 것으로 해석한다. CC는 비교하고자 하는 두 표본집단에서 값의 증가와 감소에 따른 상관관계를 표현한 지표이다. -1~1의 범위를 가지며, 절대값이 클수록 상관관계가 높다고 해석할 수 있다.

하지만, Seq2Seq 모델은 장기 의존성 문제(long-term dependency problem)에 의한 정보 손실이 있다는 문제점이 존재한다, 이를 해결하기 위해, 디코더에서 인코더의 입력 시퀀스를 다시 한 번 참고할 수 있도록 어텐션(attention) 개념을 도입하여 개선한 것이 Transformer 모델이다(Vaswani et al., 2017).

Transformer 모델의 인코더-디코더 아키텍처는 다음과 같이 구성된다. 인코더에서는 입력 시퀀스에 대해 임베딩(embedding)을 수행하고, 위치 정보를 추가(positional encoding)

한다. 그리고 입력 시퀀스에서 특징을 추출하기 위해 multi-head 어텐션을 사용한다. 인코더를 통해 획득한 입력 시퀀스 정보는 디코더의 multi-head 어텐션에 입력되어 디코더의 학습을 지원한다. Transformer 모델은 주로 자연어 처리 분야에서 사용되었는데, 최근에는 시계열 데이터 예측 분야에서도 연구가 활발하게 진행되고 있다.

3. 연구 결과

3.1 연구 대상 지역

필리핀 동비사야스(Eastern Visayas of the Philippines) 지역에 위치한 빌리란 섬(Biliran Island)은 태풍과 집중호우로 인한 홍수 피해에 상시적으로 노출되어 있는 지역이다(Kim et al., 2023d). 2022년 4월 발생한 열대성 태풍 메기(MEGI)의 사례에서 알 수 있듯이, 홍수와 산사태로 인해 170명의 인명 피해가 발생하였으며, 농작물 손실과 주택 파손을 비롯한 대규모 재산 피해가 지역 사회 전반에 걸쳐 나타났다. 필리핀 지역은 매년 열대성 저기압과 태풍으로 인한 집중호우로 심각한 홍수 피해를 겪고 있는 실정이다.

지형적으로 살펴보면 고지대와 저지대가 뚜렷하게 구분되며, 주요 산악지형으로 유속은 상류에서 하류까지 도달하는 시간이 매우 짧은 특징을 지니고 있다. 빌리란 섬에는 홍수 예보 및 정보를 담당하는 기관이 존재하지만, 운영 체계가 비체계적이고 전문 기술 인력이 부족하여 효율적인 대응이 이루어지지 못하고 있다. 또한 현재의 홍수 경보 시스템은 일부 지역에만 국한되어 있어 섬 전역에 대한 위험 대응 역량이 충분히 확보되지 못한 실정이다.

이러한 상황은 홍수 관리 능력의 부족과 예측 정보(데이터)의 한계로 인해 피해 규모가 점차 심화되는 원인이 되고 있다. 따라서 본 연구에서 제안하는 인공지능(AI) 기반 모형은 빌리란 섬의 재난관리 역량을 강화하고, 보다 체계적이고 예측 가능한 홍수 대응 체계를 구축하는 데 기여하고자 한다.

3.2 홍수위 위험등급 분류

본 연구에서는 머신러닝 모형(의사결정나무, 랜덤포레스트)을 활용하여 과거 및 실시간 자료를 학습시킴으로써 일정 시간이

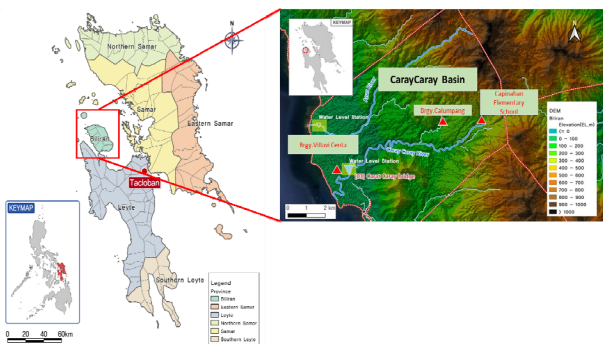


Fig. 4. Study area. Biliran Island, located in the Eastern Visayas of the Philippines.

지난 후 유출 지점에서 홍수 발생 여부를 사전에 판단하고, 이를 정보로 제공하고자 하였다. 종속변수로는 빌리란에 위치한 카라이카라이(CarayCaray) 수위관측소의 시간별 수위 자료를 사용하였으며, 독립변수로는 인근 지역인 칼룸팡(Brgy. Calumpang), 카피나한 초등학교(Capinahan Elementary School), 빌라비 센타(Brgy. Villavi Centa) 관측소의 시간별 강우량 자료를 활용하였다. 연구 기간은 2016년 4월부터 2021년 12월까지를 학습 구간으로, 2022년 1월부터 2023년 10월까지를 평가 구간으로 설정하였다. 모든 자료를 사용하기엔 저위값의 부정확한 예측 결과가 나올 수 있기 때문에, 1m 이상의 수위 값만 사용하였다. 모형의 예측 성능 평가는 F1-score를 활용하였다.

랜덤포레스트(RF) 모형의 혼동 행렬(confusion matrix)을 살펴보면, Class 1, Class 2, Class 3, Class 4 모두에서 높은 예측력을 나타냈다. 전체 클래스에 대한 예측 성능을 종합한 결과, F1-Score는 0.83로 매우 우수한 성능을 확인할 수

Table 1. Evaluation of flood risk classification prediction performance using XGBoost and F1-score.

Classification		Observed (Class)			
		1 (green)	2 (yellow)	3 (orange)	4 (red)
Predicted (Class)	1 (green)	7,556	113	0	0
	2 (yellow)	147	438	27	0
	3 (orange)	0	41	297	82
	4 (red)	0	0	73	679
precision		0.98	0.73	0.74	0.89
recall		0.98	0.71	0.70	0.90
F1-score		0.83			

Table 2. Evaluation of flood risk classification prediction performance using Tree and F1-score.

Classification		Observed (Class)			
		1 (green)	2 (yellow)	3 (orange)	4 (red)
Predicted (Class)	1 (green)	7,178	468	23	0
	2 (yellow)	213	335	64	0
	3 (orange)	0	134	210	76
	4 (red)	0	17	182	553
precision		0.97	0.35	0.43	0.87
recall		0.93	0.54	0.5	0.75
F1-score		0.66			

있었다(Table 1). 의사결정나무(Tree) 모형의 경우, Class 1과 Class 2는 높은 예측력을 보였으나, Class 3과 Class 4는 상대적으로 낮은 예측력을 나타냈다(Table 2). 전체 클래스에 대한 F1-Score는 0.66으로 평가되었다. 세부적으로 살펴보면, Class 1에서 RF 모형의 적절히 예측된 값은 7,669건으로, Tree 모형은 7,178건이었으며, 실제 데이터 수는 7,669건이었다. 이를 통해 RF 모형이 가장 높은 예측력을 가진 것을 확인할 수 있다. Class 2의 경우, RF 모형은 438건, Tree 모형은 335건을 적절히 예측하였고, 실제 데이터 수는 612건이었다. 이와 유사하게 Class 3과 Class 4에서도 RF 모형은 높은 예측력을 보여주었다. 이는 RF가 대량의 데이터를 효과적으로 처리하고 과적합(overfitting) 문제를 최소화하여 최종적으로 높은 모델 정확도를 달성할 수 있음을 의미한다.

3.3 실시간 홍수위 예측 모형

아울러 보다 정밀한 수위 예측을 위하여 딥러닝 기반의 트랜스포머(Transformer) 모형을 적용하여 실시간 홍수위 예측 모형을 개발하였다. 학습 및 평가 구간의 설정은 홍수위 위험등급 분류 모형과 동일하게 구성하였으며, 모형의 예측 성능 평가는 CC와 NRMSE를 활용하였다.

트랜스포머 모형은 입력 시계열 데이터의 시간적 상관관계를 효과적으로 학습할 수 있는 구조로, 셀프 어텐션(self-attention) 메커니즘을 기반으로 각 시점의 데이터가 전체 시계열 내에서 가지는 중요도를 자동으로 가중치화하여 학습한다. 본 모형에서는 강우량과 하천 수위 자료를 입력으로 사용하며, 인코더-디코더 구조를 통해 향후 일정 시간 후 수위 변화를 예측하도록 설계하였다.

인코더는 입력 시계열 데이터의 특성을 추출하고, 디코더는 이를 기반으로 향후 수위 패턴을 예측한다. 각 층(layer)에는 멀티헤드 어텐션(multi-head attention)과 피드포워드(feed-forward) 네트워크가 포함되어 있으며, 레이어 정규화(layer normalization)와 드롭아웃(dropout) 기법을 적용하여 학습 안정성과 과적합 방지를 도모하였다.

트랜스포머 모형은 강우량과 수위 데이터를 입력으로 활용했을 때 CC 0.92, NRMSE 0.09로 전체 수위 패턴과 침투 수위를 높은 정확도로 예측하였다. 트랜스포머는 다양한 독립 변수 입력에도 안정적인 예측력을 보여 홍수 예·경보 시스템에서 활용 가능성을 높였다. 특히 홍수 예측에서 중요한

침투 수위 예측에서 높은 정확도를 기록하여 실질적인 재난 대응 정보 제공에 기여할 수 있음을 확인하였다(Fig. 5).

4. 결론

본 연구는 필리핀 동비사야스 지역의 빌리란 섬을 대상으로, 홍수 발생 위험을 사전에 예측하고 대응할 수 있는 AI 기반 홍수위 위험등급 분류 및 실시간 홍수위 예측 모형을 개발하였다. 빌리란 섬은 태풍과 집중호우로 인한 홍수 피해에 상시적으로 노출되어 있으며, 기존 홍수 경보 시스템은 일부 지역에만 국한되고 운영 체계가 비체계적이어서 실질적인 대응 역량이 부족한 상황이었다. 이러한 배경에서 본 연구의 목표는 체계적이고 예측 가능한 홍수 대응 체계를 구축함으로써 지역 재난관리 역량을 강화하는 것이었다.

홍수 위험 등급 분류에서는 머신러닝 기반의 랜덤포레스트(RF) 및 의사결정나무(Tree) 모형을 활용하였다. RF 모형은 Class 1부터 Class 4까지 모든 등급에서 우수한 예측력을 나타냈으며, 전체 F1-Score 0.83으로 매우 높은 성능을 확인할 수 있었다. 반면, Tree 모형은 Class 2와 Class 3에서 상대적으로 낮은 성능을 보여 전체 F1-Score 0.66으로 평가되었다. 특히, RF 모형은 대량 데이터를 효과적으로 처리하고 과적합 문제를 최소화하여 높은 정확도를 달성할 수 있음을 입증하였다.

실시간 홍수 수위 예측을 위해 딥러닝 기반 트랜스포머(Transformer) 모형을 적용하였다. 트랜스포머 모형은 강우량과 수위 시계열 데이터를 입력으로 활용하여 전체 수위 패턴과 침투 수위를 정밀하게 예측하였으며, 안정적인 성능을 보였다. 그러나, 본 연구에서 개발한 예측모형은 입력자료 분포 외 값에는 취약할 수 있으며, 하나의 유역을 대상으로 모형을 개발한 만큼 대상지역 외에서는 적용이 어렵다. 이러한 한계점은 향후 연구에서 추가자료 확보를 통해 타 유역으로 확장 적용하거나 유역별로 모형을 각각 개발할 필요성이 있음을 의미한다. 결과적으로, 침투 수위 예측에서의 높은 정확도는 홍수 예·경보 시스템에서 실질적인 재난 대응 정보로 활용될 수 있음을 시사한다.

본 연구를 통해, 머신러닝 및 딥러닝 기반 AI 모형이 기존 홍수 관리 방법의 한계를 보완하며, 체계적이고 신뢰할 수 있는 홍수 위험 예측과 정보 제공에 기여할 수 있음을 확인하였다. 또한, 같은 방법으로 타 유역의 입력자료를 활용함으로써 높은 정확도를 가지는 예·경보 시스템을 확장 적용하는 것이 가능하다. 이러한 예·경보 시스템은 지역에 거주하는 시민들이 재난 대응에 필요한 선행시간을 확보함으로써 지역사회 안전에 기여할 수 있다. 국내에 적용할 경우 등급 분류 기준과 예측 수위를 바탕으로 국내에서 운영하는 홍수 예·경보 시스템을 크게 개선할 수 있을 것으로 판단된다. 향후 연구에서는 다양한 수문 관련 데이터를 추가로 통합하고 모형을 지속적으로 개선함으로써 홍수 예측 정확도를 더욱 향상시키고, 지역 사회의 재난 대응 역량을 강화할 수 있을 것으로 기대된다.




Fig. 5. CarayCaray(water level), observed and predicted water level prediction model from Transformer model.

감사의 글

본 연구는 자연재난 정책연계형 기술개발사업의 연구비지원 (기후변화 대응 재해예방사업 표준화 기술개발)(과제번호: 2021-MOIS35-004)에 의해 수행되었습니다.

References

- Abrahart, R., Kneale, P. E. See, L. M. (2004) Neural networks for hydrological modeling. CRC Press.
- Amit Y, Geman D, Wilder K (1997) Joint induction of shape features and tree classifiers. *IEEE transactions on pattern analysis and machine intelligence* 19(11):1300–1305.
- Breiman L (2001) Random forests. *Machine learning*, 45(1):5–32.
- Ghumman A R, Ghazaw Y M, Sohail A R, Watanabe K (2011) Runoff forecasting by artificial neural network and conventional model. *Alexandria Engineering Journal*, 50(4):345–350.
- Granata F, Gargano R, De Marinis G (2016) Support vector regression for rainfall–runoff modeling in urban drainage: A comparison with the EPA’s storm water management model. *Water*, 8(3):69.
- Han H, Choi C, Jung J, Kim H S (2021) Application of sequence to sequence learning based LSTM model (LSTM-s2s) for forecasting dam inflow. *Journal of Korea Water Resources Association*, 54(3):157–166.
- Han, H., & Park, H. (2024). Baseflow Separation for Improving Dam Inflow Prediction using Data-Driven Models.
- Kamiński B, Jakubczyk M, Szufel P (2018) A framework for sensitivity analysis of decision trees. *Central European journal of operations research*, 26(1):135–159.
- Kim D, Choi C, Kim J, Lee J, Bae Y, Kim H S (2018) Analysis of heavy rain damage considering regional characteristics. *Journal of the Korean Society of Hazard Mitigation*, 18(4):311–320.
- Kim D, Han H, Wang W, Kim H S (2022b) Improvement of Deep Learning Models for River Water Level Prediction Using Complex Network Method. *Water*, 14(3):466.
- Kim D, Kim J, Choi C, Wang W, You Y, Kim H S (2019) Estimations of hazard-triggering rainfall and breach discharge of aging reservoir. *Journal of the Korean Society of Hazard Mitigation*, 19(7):421–432.
- Kim D, Kim J, Kwak J, Necesito I V, Kim J, Kim H S (2020) Development of water level prediction models using deep neural network in mountain wetlands. *Journal of Wetlands Research*, 22(2):106–112.
- Kim D, Lee J, Kim J, Lee M, Wang W, Kim H S (2022a) Comparative Analysis of Long Short-Term Memory and Storage Function Model for Flood Water Level Forecasting of Bokha Stream in NamHan River, Korea. *Journal of Hydrology*, 127415.
- Kim D, Lee K, Hwang-Bo J, Kim H S, Kim S (2022c) Development of the Method for Flood Water Level Forecasting and Flood Damage Warning Using an AI-based Model. *Journal of the Korean Society of Hazard Mitigation*, 22(4):145–156.
- Kim J, Kim D, Wang W, Lee H, Lee M, Kim H S (2021) Comparative analysis of linear model and deep learning algorithm for water usage prediction. *Journal of Korea Water Resources Association*, 54(spc1):1083–1093.
- Kim, D., Kim, J., Kwak, J., Necesito, I. V., Kim, J., & Kim, H. S. (2020). Development of water level prediction models using deep neural network in mountain wetlands. *Journal of Wetlands Research*, 22(2), 106–112.
- Kim, D., Park, J., Han, H., Lee, H., Kim, H. S., & Kim, S. (2023d). Application of AI-based models for flood water level forecasting and flood risk classification. *KSCE Journal of Civil Engineering*, 27(7), 3163–3174.
- Kwak J, Kim S, Jung J, Singh V P, Lee D R, Kim H S (2016) Assessment of meteorological drought in Korea under climate change. *Advances in Meteorology*, 2016. MOIS (Ministry of the Interior and Safety), The 2023 Annual Natural Disaster Report, MOIS, Republic of Korea, 2024.
- Mosavi A, Ozturk P, Chau K W (2018) Flood prediction using machine learning models: Literature review. *Water*, 10(11):1536.
- Shoaib M, Shamseldin A Y, Melville B W, Khan M M (2016) A comparison between wavelet based static and dynamic neural network approaches for runoff prediction. *Journal of hydrology*, 535:211–225.
- Sutskever, Ilya, Oriol Vinyals and Quoc V. Le., “Sequence to sequence learning with neural networks,” *Advances in neural information processing systems*, 27, 2014.
- Vaswani, Ashish, et al., “Attention is all you need,” *Advances in neural information processing systems*, 30, 2017.
- Yan J, Jin J, Chen F, Yu G, Yin H, Wang W (2018) Urban flash flood forecast using support vector machine and numerical simulation. *Journal of Hydroinformatics*, 20(1):221–231.
- Yang, H., & Park, J. (2024). Comparing the Performance of a Deep Learning Model (TabPFN) for Predicting River Algal Blooms with Varying Data Composition. *Journal of Wetlands Research*, 26(3), 197–203.