

# 관측 강우와 심층신경망의 적용을 통한 도시홍수 분석

## Applying Observed Rainfall and Deep Neural Network for Urban Flood Analysis

김현일\* · 이재영\*\* · 한건연\*\*\* · 조재웅\*\*\*\*

Kim, Hyun Il\*, Lee, Jae Young\*\*, Han, Kun Yeun\*\*\*, and Cho, Jae Woong\*\*\*\*

### Abstract

Urban flooding primarily occurs due to flash floods in low-lying regions or insufficient capacity of drainage systems. Urban inundation has become more dangerous to residents because of an increase in impermeable areas, uncertainties in urban sewage planning, and the accumulation of sedimentation in drainage pipes. As an urban watershed with a drainage system and an urbanized river is complicated, a specific time interval is required for the preparation and processing of urban runoff analysis. To allow for rapid simulations of urban runoff estimation during heavy rainfall, a deep neural network model that imitates the conditions of a 6-h duration rainfall was developed in this study. Ten different statistical aspects for each rainfall event were considered as input data, and the total accumulated overflow from a manhole was calculated at intervals of 10 min using storm water management model (SWMM). To verify the accuracy of the results from SWMM, the results obtained from a two-dimensional hydraulic model and an inundation trace map were compared. The computational times for the deep neural network and rainfall data-based models proposed in this study were estimated to be within 1 s, whereas the simulation using SWMM required 14 min. The proposed deep learning model was tested using the total accumulated overflow for the rainfall event observed at Gangnam (400) automatic weather station on July 27, 2011. The simulated results agreed with the observed results in terms of the total accumulated discharge.

**Key words :** Urban Flood, Observed Rainfall, Deep Neural Network, Flood Prediction

### 요 지

도시유역의 홍수 발생은 주로 저지대의 유수 집중과 배수관거의 만관에 의해 발생하는데, 이는 높은 강우강도와 집중적인 양상을 가지는 강우 사상과 함께 나타난다. 도시유역에 대한 유출량 사전 분석을 위해서는 SWMM이 이용될 수 있지만, 대상 유역이 넓고 배수시스템이 복잡한 경우 1차원 도시유출해석에 적지않은 시간이 발생할 수 있다. 또한, 특정 도시 유역에 대하여 많지 않은 침수 사례와 침수 유발 관측강우의 부족은 홍수 대비에 대한 기초자료를 제공하는데 어려움이 있다. 홍수를 일으킬 위험 강우 발생 시 긴급하게 도시 유출량을 예측하기 위해서, 본 연구에서는 6시간 지속시간을 가지는 전국단위 관측 강우사상을 반영하여 심층신경망 모형을 구축하였다. 하나의 강우사상에서 10개의 통계적 특성을 입력 자료로서 고려하였으며, 예측하고자 하는 목표값은 SWMM을 통한 10분 단위 총 누가 월류량으로 하였다. SWMM의 결과의 적절성을 검증하기 위해 2차원 수리해석 모형과 침수흔적도를 연계한 검증을 실시하였다. 대상지역에 대한 SWMM의 모의 시간은 14분이 소요되었으며, 본 연구에서 제시된 심층신경망과 관측 강우 자료 기반 모형은 2~3초 내외에서 수행되었다. 예측은 강남(400) AWS에서 2011년 7월 27일에 관측된 강우사상에 대한 총 누가 월류량을 대상으로 하여 모형의 실용성을 검증하였다.

**핵심용어 :** 도시홍수, 실측 강우사상, 심층신경망, 홍수예측

\*정회원, 경북대학교 건설환경에너지공학부 박사과정(E-mail: hyunn228@gmail.com)

Member, School of Architectural, Civil, Environmental, and Energy Engineering, Kyungpook National University

\*\*교신저자, 정회원, 한국건설기술연구원 박사후연구원(Tel: +82-31-910-0586, Fax: +82-504-001-9933, E-mail: jaeyeonglee@kict.re.kr)

Corresponding Author, Member, Korea Institute of Civil Engineering and Building Technology

\*\*\*정회원, 경북대학교 토목공학과 교수(E-mail: kshanj@knu.ac.kr)

Member, Department of Civil Engineering, Kyungpook National University

\*\*\*\*국립재난안전연구원 시설연구사(E-mail: jwcho80@korea.kr)

Research Officer, National Disaster Management Research Institute

## 1. 서론

도시구역의 침수는 공간적으로 주거지역, 공업지역, 상업지역, 교통지역을 포함한 다양한 토지피복과 높은 불투수율로 인한 그 발생 가능성이 높아지고 있으며, 더욱이 기후변화의 영향으로 높은 강우강도를 가지는 국지성 호우로 인한 침수 발생이 나타나고 있다. 도시화가 상당히 진행됨에 따라 건물의 밀집도와 관거시스템의 복잡성으로 인해 도시 침수로 인한 흐름 특성 파악이 쉽지 않은 실정이다. 도시 구역에서 발생하는 홍수 사상은 막대한 재산상의 피해와 인명피해로 이어질 수 있기 때문에 침수 발생 가능성을 예측하고 이에 대한 홍수량을 사전에 파악하는 것은 매우 중요하다 할 수 있다. 침수를 일으키는 실제 호우 사상은 다양한 형태와 빈도로 나타날 수 있으며, 이에 대한 특징을 사전에 파악하는 것은 수해에 기준 결정에 중요한 사항이다. 현재 강우를 포함한 기상상태를 실시간으로 자동관측 할 수 있는 장비인 Automated Synoptic Observing System (ASOS)와 Automatic Weather System (AWS)를 이용하여 사전에 수치해석 기반 홍수해석을 실시하고 이에 대한 경향 파악과 침수 예측을 하는 것은 도시 계획 또는 홍수 대응에 필요하다. 다만 수치해석 기반 모형의 경우, 매개변수의 조정, 자료의 수집, 입출력 자료에 대한 전·후처리에 시간이 다소 소요될 수 있는 단점이 있다. 이에 인공지능을 이용한 강우, 하천 수위, 도시 홍수 예측이 이루어지고 있으며, 사전에 정립된 수문 사상 또는 유출 패턴을 이용하여 실시간으로 분석 예측을 수행할 수 있게 되었다.

도시 구역에 대한 홍수량 예측으로서 Granata et al. (2016)은 도시 구역에 대한 강우-유출 현상의 재현성의 비교를 EPA's Storm Water Management Model (EPA-SWMM) 모형과 Support Vector Regression (SVR) 기반 접근법 통해 수행하였다. 대상 지역의 총 유출량 예측을 하였는데 SVR 기반 모형은 침투 유량 보다 적은 값을 예측하였으며, EPA-SWMM의 경우 침투 유량을 상회하는 값을 예측하였다. 이에 SVR 기반 모형은 추후 검증과 개선을 통해 도시 수문 분석 및 예측에 잠재력을 가졌음을 나타내었지만, 정확한 침투유량값을 예측하지 못한 한계가 있다. Kim et al. (2018)은 세 가지 동적신경망인 입력지연 인공신경망, 시간지연 인공신경망, 비선형 자기회귀 신경망을 통하여, 맨홀 지점별 월류량을 예측하였다. 기본적인 동적신경망보다 피드백 기능을 통한 동적신경망을 통해 홍수량 예측하는 것이 더욱 좋은 결과를 나타냄을 1차원 해석 결과와 함께 검증하였으나, 지점 별 맨홀 월류량을 예측을 하여 총 누가 월류량에 대한 예측력은 다소 높지 않은 문제가 있었다. Li and Willens (2018)은 자료 및 실측이 부족한 도시구역에서 유용한 자료지향형 모델을 사용하기 위하여, 관거를 고려한 개념적인 모델과 로지스틱 회귀 기법을 조합하여 홍수 가능성을 예측하고자 하였다. 수치해석 기반 모형과 비교하였으며, 발전가능성이 있는 검증결과를

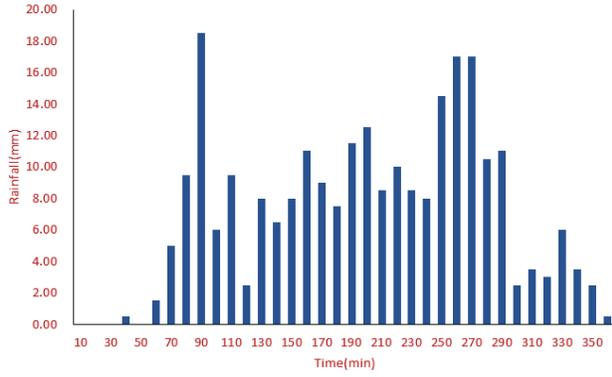
나타내었다. 하천 유량에 대한 예측은 Zhou et al. (2018)에 의해 수행되었는데, Radial Basis Function Network (RBFN), Extreme Learning Machine (ELM), Elman Network의 앙상블 기법을 이용하였다. 데이터 전처리 기법으로 Empirical Wavelet Transform (EWT)을 사용하였으며, 연구 대상 하천에서의 평균 월 유량을 예측하였다. 수문자료에 대한 예측력의 향상과 더 많은 사상을 모형에 포함시키기 위하여 딥러닝 기법이 수자원 분야에 적용되기 시작했다. Hu et al. (2018)은 강우-유출 시뮬레이션을 위해 Long Short-Term Memory (LSTM) 신경망을 사용하였으며, 86개의 강우-유출 패턴 자료를 이용하였다. 이에 대한 결과를 일반적인 ANN 모델과 비교하여 LSTM 신경망의 우수성을 검증하였다. Shen (2018)에 따르면, 수자원 및 수문분야에 대한 딥러닝 기법의 적용은 점차 증가하고 있으며 대부분 과학 분야에서와 마찬가지로 수자원 분야에서도 우수한 예측 및 분석결과를 도출해낼 것으로 보인다.

다양한 기계학습 및 딥러닝 기법이 도시 및 하천에 대한 수문자료 예측에 이용되고 있으나, 딥러닝을 이용한 도시 배수분구 단위 홍수량을 예측하고자 하는 연구는 부족한 것으로 보인다. 도시 구역의 내수 침수는 하천과 같이 연속적인 시계열 형태의 유량 및 홍수량 분석이 어려우며, 단일 도시 구역에 대한 실제 월류량 자료와 이를 유발한 관측 강우자료도 부족한 실정이다. 아직까지 침수 이력이 있는 도시 지역에 대한 지표 침수심을 측정할 수 있는 기기가 부족하며, 배수관망 내에 흐름을 통해 월류되는 홍수량을 기록할 수 있는 시스템이 구축되어 있지 않아 도시구역에 대한 강우-유출 양상 파악에 더욱 어려움을 주고 있다. 이에 본 연구에서는 서울시 지역을 포함한 전국단위로 침수를 발생시킨 사상과 발생 시키지 않은 다양한 관측강우 사상을 조사하여 1차원 도시유출해석을 위한 입력 자료로서 사용하였다. 이는 침수를 일으키는 실제 강우자료에 대한 부족함을 보완해주고, 다양한 자료 패턴을 필요로 하는 딥러닝기법을 적용할 수 있는 기반을 구축할 수 있을 것으로 보인다. 1차원 도시유출해석 결과와 실제호우 사상에 대한 통계특성치를 이용하여 심층 신경망의 입력 자료로서 사용하였으며, 실시간으로 총 누가 월류량을 빠르고 정확하게 예측 할 수 있는 기법을 제시하고자 한다.

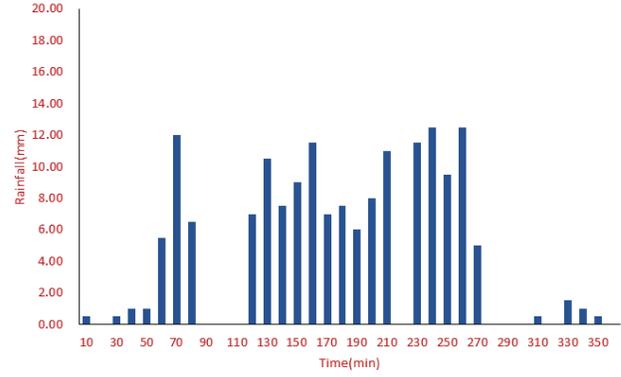
## 2. 연구 방법

### 2.1 실제 호우 자료의 수집

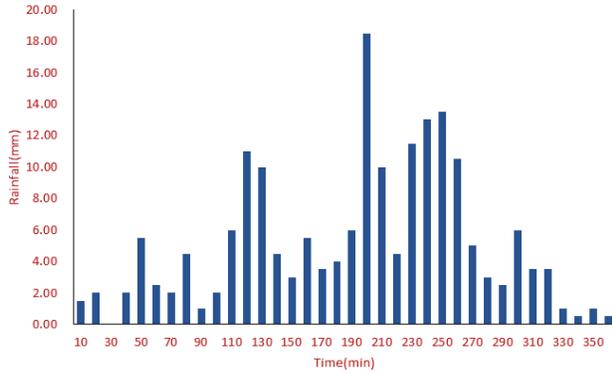
홍수량 산정을 목적으로 하는 확률강우량이 아닌 실제 호우를 사용하였으며, 최근에 큰 침수피해를 야기한 서울시를 포함한 전국단위(인천, 천안, 충주, 부산, 울산, 창원)로 하는 지속시간 6시간 강우를 조사하였다. 2009~2017년도에 걸친 실제 호우를 조사하였으며, 총 70여개의 강우 자료를 수집하였다. 총 강우량(mm)은 최소 7.5 mm에서 최대 284.4 mm까지



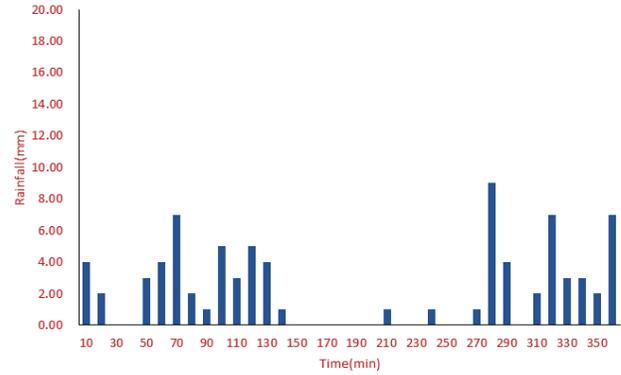
(a) Gangnam (400) 20100921



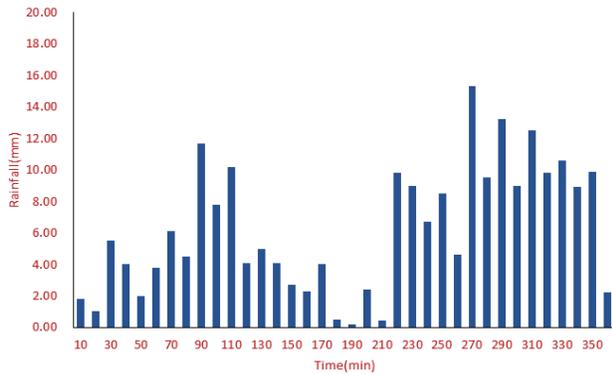
(b) Dobong (406) 20100921



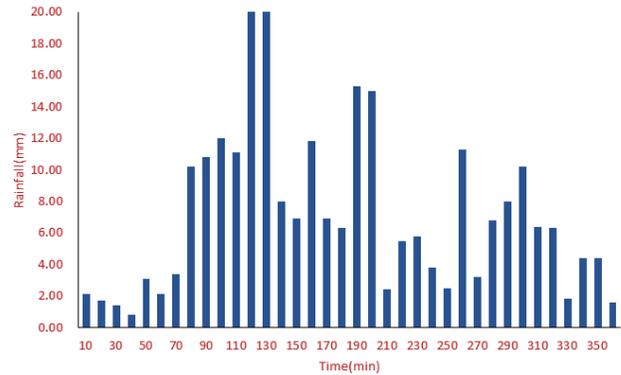
(c) Gangnam (400) 20110727



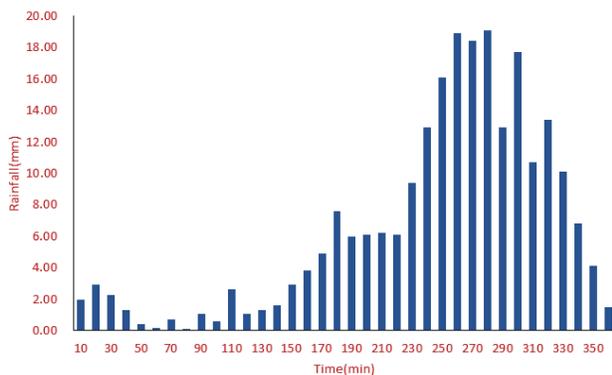
(d) Gangbuk (424) 20110727



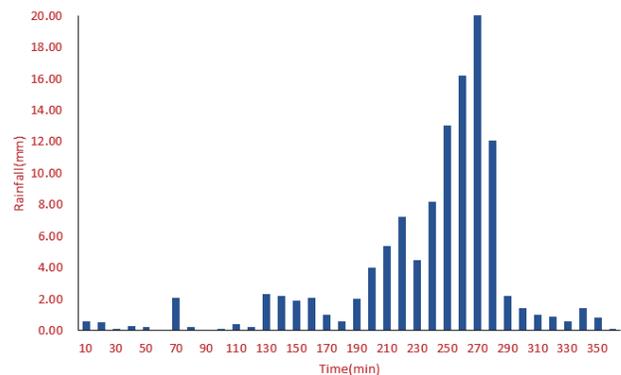
(e) Cheonan (232) 20170716



(f) Busan (159) 20170911



(g) Ulsan (152) 20161005



(h) Changwon (155) 20161005

Fig. 1. Survey of Observed Rainfall

나타났으며, 침수를 일으키지 않은 강우사상 또한 포함하여 월류가 발생하지 않은 사상까지 추후에 분석할 수 있도록 예측 모형을 구축하고자 하였다. 본 연구에서는 강우 사상 자체를 입력 자료로서 사용하기보다는 강우 자료의 통계적 특성치를 입력 자료로서 사용하였다. 침수를 유발한 과거 관측 강우를 다수 수집함으로써 대상 지역 내에 부족한 침수 사상을 보완할 수 있을 것으로 보인다. 본 연구에서 1차원 도시유출해석 모의와 심층신경망의 입력 자료 구축을 위해 수집한 강우사상들을 Fig. 1에 나타냈는데, 서울시 지역 관측 자료와 서울 외 전국단위 관측 자료를 나타내었다. Figs. 1(a), (b), (c)의 경우 2010, 2011년 수도권에 내린 관측강우 중 강우량과 강우강도가 큰 대표적인 3개의 사상을 보여주고자 하였으며, Fig. 1(d)와 같이 강우량이 크지않으며 무강우 시간이 길게 나타나는 강우 사상 역시 이용하여 다양한 강우-유출 패턴을 반영하고자 하였다. Figs. 1(e), (f), (g), (h)와 같이 전국 단위 강우 중 강우강도와 강우 분포의 침도가 높은 사상이 본 연구에 적용되었다.

## 2.2 도시유출해석

본 연구에서 대상 유역의 1차원 도시 유출량을 계산한 SWMM 모형은 도시유역이나 인위적인 배수계통을 갖는 유역에서 강우사상으로 인해 발생하는 지표면 및 지표하 흐름, 배수관망에 대한 유출량 추적 등 강우-유출 및 하도 추적 모두 가능한 도시유출 모형이다(Huber and Dickson, 1988). 각 배수분구에 대한 침수 범위의 분석에 앞서 강우에 따른 유출량을 EPA-SWMM(5.1버전)을 통하여 산출하였으며, 외수의 영향은 서울특별시 풍수해저감종합계획(Seoul Metropolitan City, 2015)을 참조하여 적용하였다. SWMM 모형의 실행블록 중 Runoff와 Extran을 활용하였으며, Runoff 블록은 강우사상 기반의 초기연산이 수행되는 블록으로써 배수유역 내의 유출현상, 수질모의, 각 맨홀에 대한 유입수문 곡선을 계산한다. Extran블록의 경우 Runoff 블록의 출력자료를 활용하여 배수관망 시스템의 유량과 수심을 구하기 위해 사용되며, 계산 시간별 배수관망 내의 유량 및 수위를 통해 관내의 역류현상, 월류량 해석이 가능하다(Park et al., 2019). 연구 대상지역에서 다양한 강우 사상에 따른 월류량 해석을 위하여 Eqs. (1), (2)에 나타난 Saint-Venant의 연속방정식과 운동량 방정식을 활용하였다.

$$Q = W \times \frac{1}{n} (d - d_p)^{\frac{5}{3}} S^{\frac{1}{2}} \quad (1)$$

$$\frac{\partial Q}{\partial t} + gAS_f - 2V \frac{\partial A}{\partial t} - V^2 \frac{\partial A}{\partial x} + gA \frac{\partial H}{\partial x} = 0 \quad (2)$$

여기서  $Q$ 는 유출량( $m^3$ ),  $W$ 는 소유역의 폭( $m$ ),  $n$ 은 Manning의 조도계수,  $d$ 는 수심( $m$ ),  $d_p$ 는 지면저류 손실수심

( $m$ ),  $S$ 는 소유역 경사를 의미하며,  $A$ 는 소유역의 지표흐름 단면적( $m^2$ ),  $V$ 는 지표흐름 속도( $m/sec$ )를 나타낸다.

## 2.3 K-fold 검증

K-fold 교차 검증은 모형의 검증을 위해 가장 널리 사용되는 서브 샘플링 기술이며, 유효성 확인의 경우 전체 입력 자료가 K개의 동일한 부분으로 분할되고 특정 한 부분이 테스트 자료 집합으로 사용되고 나머지는 학습 데이터 세트로 사용된다. 테스트 데이터 집합으로 결정된 데이터를 제외한 나머지 다른 부분은 두 번째 실험에서 테스트 데이터로 사용되며, 이 절차는 K회 반복되며 각 시나리오에서 오류가 산정되게 된다(Remesan and Mathew, 2015). 최종 오차는 각 실험에서 각각의 오차를 평균함으로써 K 시험 데이터의 예측으로부터 추정될 수 있으며, K-fold 교차 유효성 확인은 Fig. 2와 같이 나타낼 수 있다. 모델링에 많은 폴드를 사용하면 실제 오류를 추정기의 편차는 작지만 실제 오류를 추정자의 편차는 커지며, 적은 수의 폴드를 사용하면 실험 횟수와 계산 시간이 줄어드는 현상을 보인다. K-fold 유효성 확인 절차에서 K의 값은 보통 10을 사용하며, 본 연구에서도 입력 강우특성 자료에 대한 10분 단위 총 누가 월류량 자료를 이용하여 교차 검증을 실시하였다.

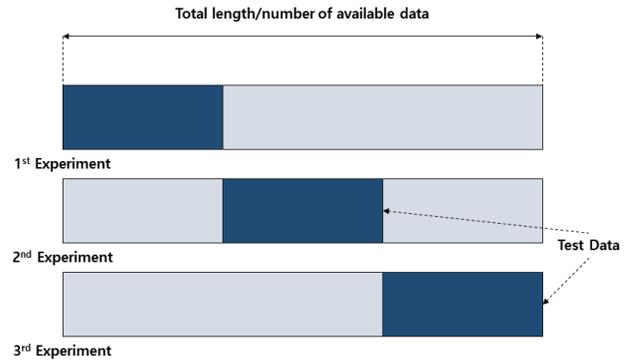


Fig. 2. K-fold Validation

## 2.4 심층신경망

심층신경망(Deep Neural Network, DNN)은 일반적인 인공신경망(Artificial Neural Network, ANN)에서 은닉층을 2개이상 사용하여 더욱 깊은 학습이 가능도록 구성된 가장 기본적인 딥 러닝 기법이다. 신경망 층을 깊게 하였을 때에 기본적으로 높은 수준의 표현력을 가질 수 있으며, 정교한 학습 및 표현의 효율성 측면에서 강점을 가진다. 심층신경망을 이용하기 위해서는 대량의 데이터가 필요할 수 있으며, 고성능 컴퓨팅 기술과 자료 저장 기능이 뒷받침 되어야 한다. 심층신경망 역시 입력층, 은닉층, 출력층으로 구성되어 있는데, 입력 자료가 출력층 까지 온전히 기억되기 위해 활성화 함수는 Fig. 3(b)과 같이 Relu함수가 사용된다.

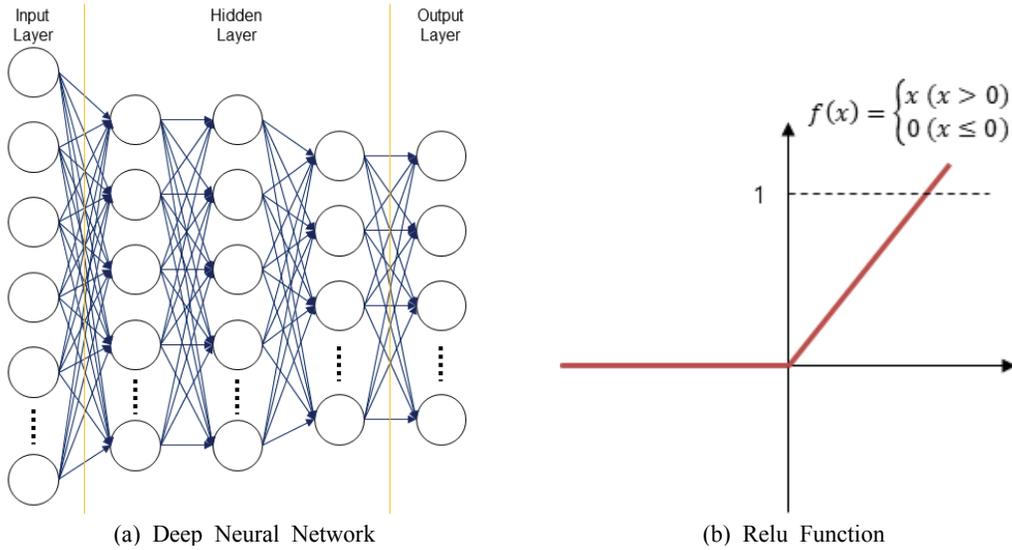


Fig. 3. Deep Neural Network and Activation Function

Relu 함수는 입력 자료  $x$ 가 0보다 작을 때는 모든 값을 0으로 처리하고, 0보다 큰 값은  $x$ 를 그대로 사용하는 방법이다. 이를 통해  $x$ 가 0보다 크기만 하면 미분 값이 1이 되어 여러 은닉층을 거치며 곱해지더라도 맨 처음 층 까지 사라지지 않고 자료의 특성이 남아 있을 수 있다. 심층신경망의 학습을 위한 경사 하강법은 Adam을 사용하였으며, 이는 이상치를 포함한 비선형적인 문제를 다루는데 효과적이다 (Kingma and Ba, 2015). 본 연구에서는 이 기법을 통해 정확도와 학습 보폭 크기를 개선할 수 있었다. 오차함수는 Eq. (3)과 같이 평균 절대 오차(Mean Average Error, MAE)를 사용하여 학습을 위한 기준을 지정하였으며, K-fold 검증 시에도 평균 절대 오차를 사용하였다. 여기서  $n$ 은 목표값 자료의 수이며, 본 연구에서는 예측하고자 하는 총 누가 월류량의 수를 나타낸다.  $y$ 는 SWMM을 통해 산정된 총 누가 월류량,  $\hat{y}$ 는 예측된 총 누가 월류량을 나타낸다.

$$MAE = \frac{1}{n} \sum |\hat{y} - y| \quad (3)$$

### 3. 모형의 적용

#### 3.1 대상유역

본 연구의 대상지역으로서 삼성1, 삼성2 배수분구를 포함하는 삼성동 일대로 선정하였으며, Fig. 4에 배수분구 경계와 배수관망과 맨홀지점이 나타나 있다. 나타난 배수관망과 맨홀 정보는 EPA-SWMM 기반 1차원 도시유출해석을 실시하는데 사용되었다. 도시 지표에 내린 우수는 관망을 통해 최종적으로 탄천으로 우수가 배수되는 연결 구조로 구성되어 있다. 연구 대상지역은 2001년, 2010년 9월 21일 그리고 2011년 7월 27일에 집중호우에 따른 극심한 침수피해가

발생한 사례가 있다. 상대적으로 저지대이며, 복잡한 배수체계 그리고 관내 흐름 한도를 초과하는 우수유입을 통하여 내수침수가 발생된 것으로 보인다. 서울시 풍수해저감종합계획(Seoul Metropolitan City, 2015)에 따르면, 삼성동에 대한 내수침수위험 지구는 Fig. 5(a)와 같이 삼성역-선릉역(테헤란로 일대)과 Fig. 5(b)와 같이 봉은사-삼성역(영동대로) 구간에 대해 나타났다. 하수관거의 설계빈도를 초과하는 집중호우가 발생한다면, 두 구간에 대해서 내수침수가 발생할 것으로 보이며, 실제로 2010년과 2011년 침수흔적도에 따르면 삼성역에서 선릉역 구간의 도로에 따라 내수침수가 발생한 것으로 나타난다.

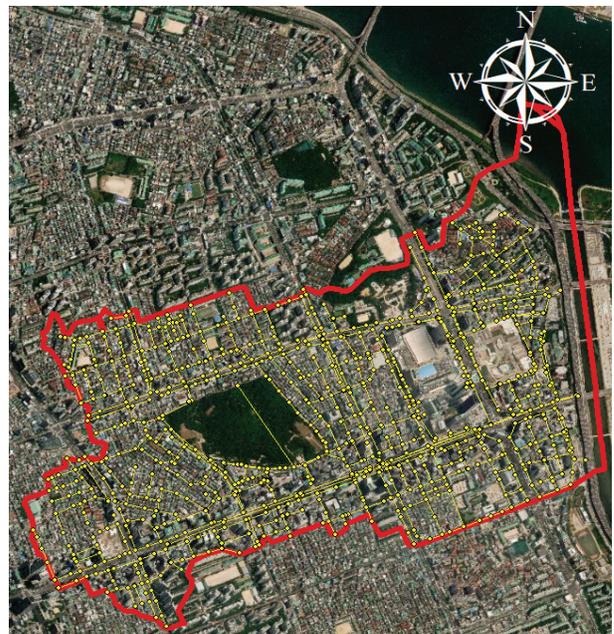


Fig. 4. Drainage System of Study Area

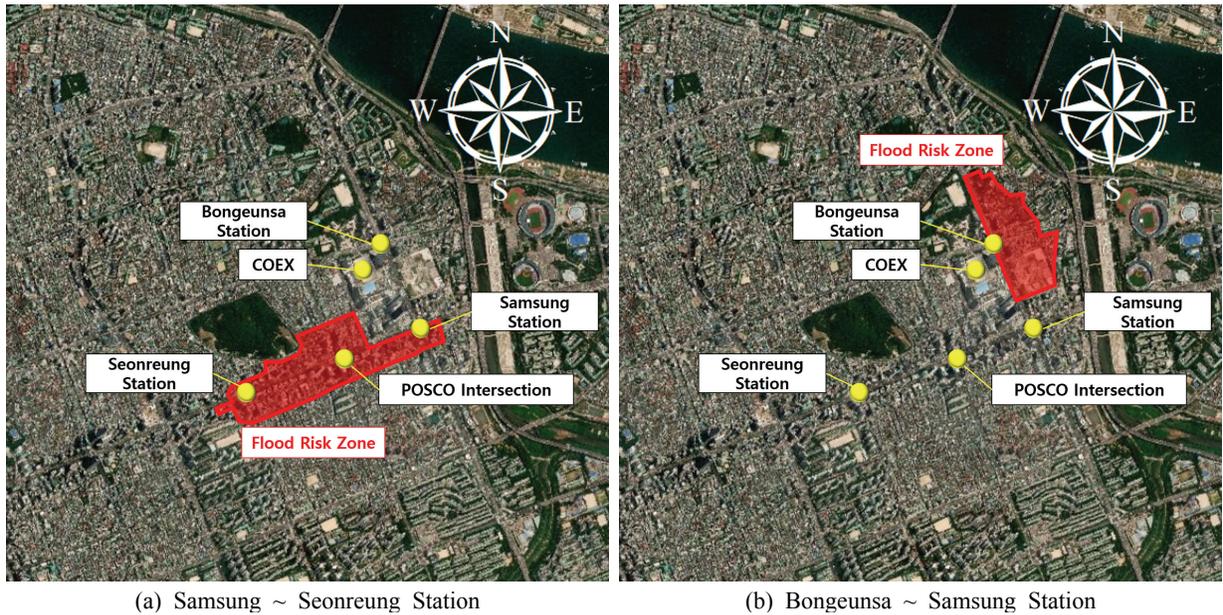


Fig. 5. Flood Risk Zone in Samsung-dong

### 3.2 1차원 도시유출해석의 검증

EPA-SWMM 기반 1차원 도시유출해석 결과의 적절성을 판단하기 위하여, 맨홀 지점 별 월류량을 이용한 2차원 침수 해석을 실시하고 이를 내수침수위험지구, 침수흔적도와 비교하고자 하였다. 이는 가장 최근 삼성동에 광범위한 침수가 발생한 것은 2010년, 2011년인데, 수치해석 기반 모형을 검증하기 위해서는 해당 년도의 관거 내 수위/유량 실측 자료가 부재하기 때문이다. SWMM모형 결과의 적절성 검증을 위한 2차원 모형은 유한차분기법을 기반으로 하는 수리해석 상용프로그램 FLO-2D를 이용하였다. FLO-2D 모형은 Federal Emergency Management Agency (FEMA, 미국 연방 재난관리청)가 승인한 하천흐름과 홍수해석을 위한 수리모형으로 유한차분법을 이용한다(Lim and Kim, 2019). 연구 대상구역에 대한 계산범위를 침수예상도 및 침수이력자료 등을 통해 파악하고, GIS 프로그램을 이용한 격자망을 구성하여 연속방정식과 운동량 방정식을 통한 홍수와 해석을 실시하였다.

2차원 수리학적 침수해석의 결과를 이용하여 각 강우조건에 따른 침수 지도를 생성하였으며, 침수예상도로 사용하기 위한 자료 상세 분석을 실시하였다. 모의시간에 대한 충분한 여유를 두어 홍수파가 건물 사이 및 도로에 최대한 전달 되도록 하였다. 홍수와 흐름에 대한 건물 및 도로의 영향을 적절히 반영하기 위하여 5 m 정방형 격자에 대한 2차원 수리학적 침수해석을 실시하였으며, Eqs. (4)~(5)을 이용하여 합성 조도계수를 0.025로 산정 및 적용하였다.

$$n^2 = n_0^2 + 0.02 \times \frac{\theta}{100 - \theta} \times h^{4/3} \quad (4)$$

$$n_0^2 = \frac{n_1^2 A_1 + n_2^2 A_2 + n_3^2 A_3}{A_1 + A_2 + A_3} \quad (5)$$

여기서,  $n$ 은 합성조도계수,  $n_0$ 는 저면조도계수,  $\theta$ 은 건폐율(%),  $n_1$ 은 0.06(농지),  $n_2$ 는 0.047(도로),  $n_3$ 는 0.05(기타),  $A_1$ 은 농지면적,  $A_2$ 는 도로면적,  $A_3$ 는 기타토지 이용면적,  $h$ 는 수심이다(Son et al., 2015).

Fig. 6과 같이 2010년 침수흔적도와 2010년 9월 21일의 관측 강우 기반 2차원 홍수해석 결과를 비교하였을 때, 선릉역 및 테헤란로 일대의 침수양상이 대부분 유사하게 나타났다. 침수흔적도 내에 발생한 격자 중, 침수가 발생한 격자의 비율은 75.82%로 나타났다. 또한 삼성역에서 선릉역까지의 전체 침수심에서 침수흔적도 내에 발생한 침수격자 개수의 비율은 67%로 나타났다. 침수흔적도가 0.3m 이상일 경우 작성하는 것과, Fig. 6(b)은 건물과 도로를 반영하여 지표흐름 해석 결과를 통한 침수심을 나타내는 것임을 고려하면 2차원 홍수해석 과정은 타당한 것으로 판단된다. 2차원 홍수해석과 침수흔적도를 이용하여 검증된 SWMM 기반 1차원 해석 결과는 총 누적 월류량을 예측하는 심층신경망의 비교대상이 되며, 신경망 학습을 위한 데이터베이스를 구축하기 위해 사용된다.

### 3.3 입력자료의 구축

실제 호우는 그 형상과 침도가 다양하게 나타나며, 예측하기 어려운 특징이 있다. 도시 구역에 대한 유출 양상은 강우의 분포 특성에 영향을 받는 것으로 보이며, 이에 대한 강우-유출 패턴은 도시 홍수의 크기를 예측하는데에 어려움을 주고 있다. 이에 본 연구에서는 사전에 조사한 70여개의 관측강우를 바탕으로 각 강우 사상에 대한 총 강우량(mm), 1시간

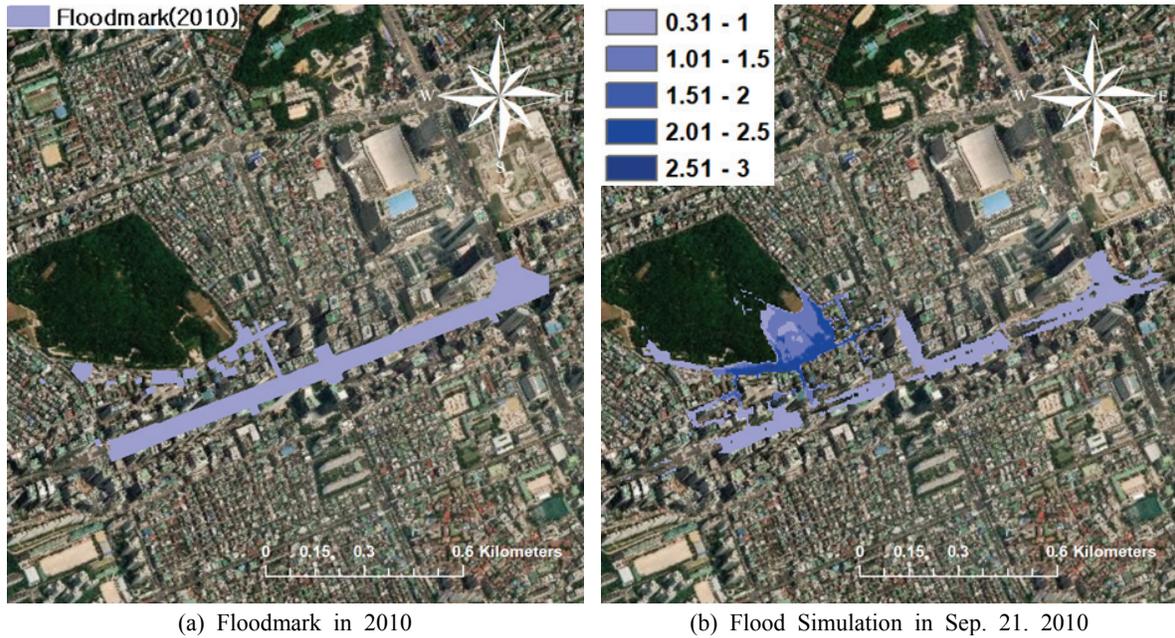


Fig. 6. Validation of 1D/2D Hydraulic Analysis

최대강우량(mm), 2시간 최대강우량(mm), 3시간 최대강우량(mm), 강우강도(mm/hr), 침투강우의 위치(%), 표준편차(mm), 왜곡도, 무강우시간(분), 침도를 조사하였으며, 이에 대한 인자들을 심층신경망의 입력 자료로서 사용하여 강우의 공간적 특성을 학습한 총 누가 월류량 예측 모형을 만들고자 하였다. 1~3시간 최대강우량은, 강우 사상 내에서 1시간, 2시간, 3시간 지속시간을 가지는 종거의 최대값을 나타내었고, 강우강도는 총 강우량에서 지속시간 6시간을 나누어 산정하였다. 침투강우의 위치는 침투 강우가 나타나는 시간이 총 지속시간에서 어느정도에 나타나는지 백분율로 나타낸 값이며, 무강우시간은 강우 사상 내에서 강우 0을 나타내는 시간을 분으로 산정한 결과이다. 수집 강우

자료 중 일부에 대한 통계 분석 결과는 Tables 1~2와 같다. 심층신경망에는 강우 자료에 대한 통계적 특성이 입력되는데, 본 연구에서는 3가지 CASE의 입력 자료 조합을 선정하였다(Table 3). 통계적 특성 분석 대상이 되는 강우 시나리오는 동일하며, 각 입력자료 조합 별 이용되는 특성이 다르다. 각 통계 특성치의 총 누가 월류량( $m^3/s$ )에 대한 상관도 분석을 실시하였는데, 총 강우량 인자가 총 누가 월류량에 대한 양의 상관도가 가장 높게 나타났으며, 침투강우의 위치(%)의 경우 상관도가 0에 수렴하여 입력 자료 조합에 사용하지 않았다. 3시간 최대강우량과 강우강도 역시 높은 양의 상관관계를 나타내었다. 관측 강우에 대한 왜곡도, 침도, 무강우시간의 경우 음의 상관관계가 나타났다. 심층신경망

Table 1. Observed Rainfall and Statistical Features (4 Observations in Seoul)

Statistical Characteristics	Gangnam (400)	Gangnam (400)	Dobong (406)	Gangbuk (424)
Observation Date	2010-09-21	2011-07-27	2010-09-21	2011-07-27
Total Rainfall (mm)	253.50	184.50	166.50	81.00
Max. Rainfall in 1hr (mm)	71.00	71.00	57.00	25.00
Max. Rainfall in 2hr (mm)	128.50	105.00	106.00	38.00
Max. Rainfall in 3hr (mm)	190.00	143.00	136.00	41.00
Rainfall Intensity (mm/hr)	44.58	30.75	27.75	13.35
Peak Rainfall Location (%)	69.44	55.56	66.67	77.78
Standard Deviation (mm)	5.36	4.38	4.68	2.49
Skewness	-0.02	1.28	0.40	1.05
No Rain Time (min)	60	10	100	130
Kurtosis	-0.9904	1.2289	-1.4715	0.3522

**Table 2.** Observed Rainfall and Statistical Features (4 Observations in Other Area)

Statistical Characteristics	Busan (159)	Ulsan (152)	Changwon (155)	Cheonan (232)
Observation Date	2017-09-11	2016-10-05	2016-10-05	2017-07-16
Total Rainfall (mm)	254.10	233.80	116.70	223.60
Max. Rainfall in 1hr (mm)	84.90	103.10	74.90	69.30
Max. Rainfall in 2hr (mm)	144.90	166.40	97.10	118.50
Max. Rainfall in 3hr (mm)	176.20	203.30	107.20	142.50
Rainfall Intensity (mm/hr)	42.35	38.97	19.45	75.00
Peak Rainfall Location (%)	36.11	77.78	75.00	37.27
Standard Deviation (mm)	5.15	6.06	4.96	4.05
Skewness	1.05	0.89	2.25	0.33
No Rain Time (min)	0	0	20	0
Kurtosis	0.6922	-0.4508	4.7215	-0.8722

**Table 3.** Combination of Input Data

CASE1 (9 Inputs)	CASE2 (7 Inputs)	CASE3 (5 Inputs)	$R^2$ with Total Overflow
Total Rainfall	Total Rainfall	Total Rainfall	0.8144
Max. Rainfall in 1hr	Max. Rainfall in 1hr	Max. Rainfall in 1hr	0.5698
Max. Rainfall in 2hr	Max. Rainfall in 2hr	Max. Rainfall in 2hr	0.5114
Max. Rainfall in 3hr	Max. Rainfall in 3hr	Max. Rainfall in 3hr	0.3957
Rainfall Intensity	Rainfall Intensity	Rainfall Intensity	0.566
Standard Deviation	Standard Deviation	-	0.3623
Skewness	Skewness	-	-0.3778
Kurtosis	-	-	-0.2499
No Rain Time	-	-	-0.1087

을 위한 입력 자료에는 기본적으로 침투강우의 위치를 제외시켰으며, Fig. 8(e)와 같이 총 누가 월류량과 상관성이 거의 없는 것으로 나타났기 때문이다. CASE1의 경우 침투 강우 위치를 제외한 모든 통계 분석값을 이용한 값이며, CASE2는 음의 상관관계를 갖는 특성치 중 하위 2개를 제외시킨 입력자료 조합이다. 마지막으로 CASE3은 양의 상관도가 높은 5개의 자료를 이용한 경우이다. 입력 자료 조합에 상관없이 목표값은 총 누가 월류량으로 동일하다. 상관도 분석에 따른 산포도는 Figs. 7~8에 나타나있다.

### 3.4 모형의 구축 및 예측결과

심층신경망을 세 가지 자료 조합에 대해 각각 학습하였으며, 목표값은 특정 강우 사상에 대한 총 누가 월류량이다. 총 70여개 관측 강우 사상에서 69개를 신경망 학습에 사용하였으며, 강남(400) AWS 관측소에서 2011년 7월 27일에 관측된 강우사상에 대한 SWMM모형 결과(10분 단위 총 누가 월류량)를 심층신경망의 예측 대상으로 하였다. 신경망

은 1개의 입력층, 3개의 은닉층과, 1개의 출력층으로 구성하였으며, 3개의 은닉층은 각각 18, 12, 10개의 노드를 가지도록 설정하였다. 은닉층 개수와 각 은닉층의 노드의 수는 시행착오법을 통해 결정하였다. 은닉층의 활성화 함수는 Relu함수를 사용하였으며, 출력 함수의 경우 Linear함수를 사용하여 부동소숫점 단위 결과를 도출할 수 있도록 설정하였다. 심층신경망 학습 시 입력 자료의 70%를 training에 사용하였으며, 30%를 Testing에 적용하여 검증하였다. 입력 자료에서 임의 추출하여 할당하였으며, 학습하는데 시간은 1시간가량 소요되었다.

심층신경망의 학습 후 모형에 대한 검증을 위해 각 입력자료 조건 별로 K-fold 검증을 실시하였으며, 이에 대한 결과는 Table 4와 같이 나타나있다. 각 입력자료 조건 CASE1, CASE2, CASE3 별로 절대평균오차( $m^3/s$ )는 최대값 28.29, 16.18, 21.06으로 나타났으며, 평균값은 18.21, 11.27, 13.39로 각각 나타났다. 총 강우량, 1~3시간 최대강우량, 강우강도, 표준편차, 강우의 왜곡도를 사용하였을 때인 CASE2 입력자

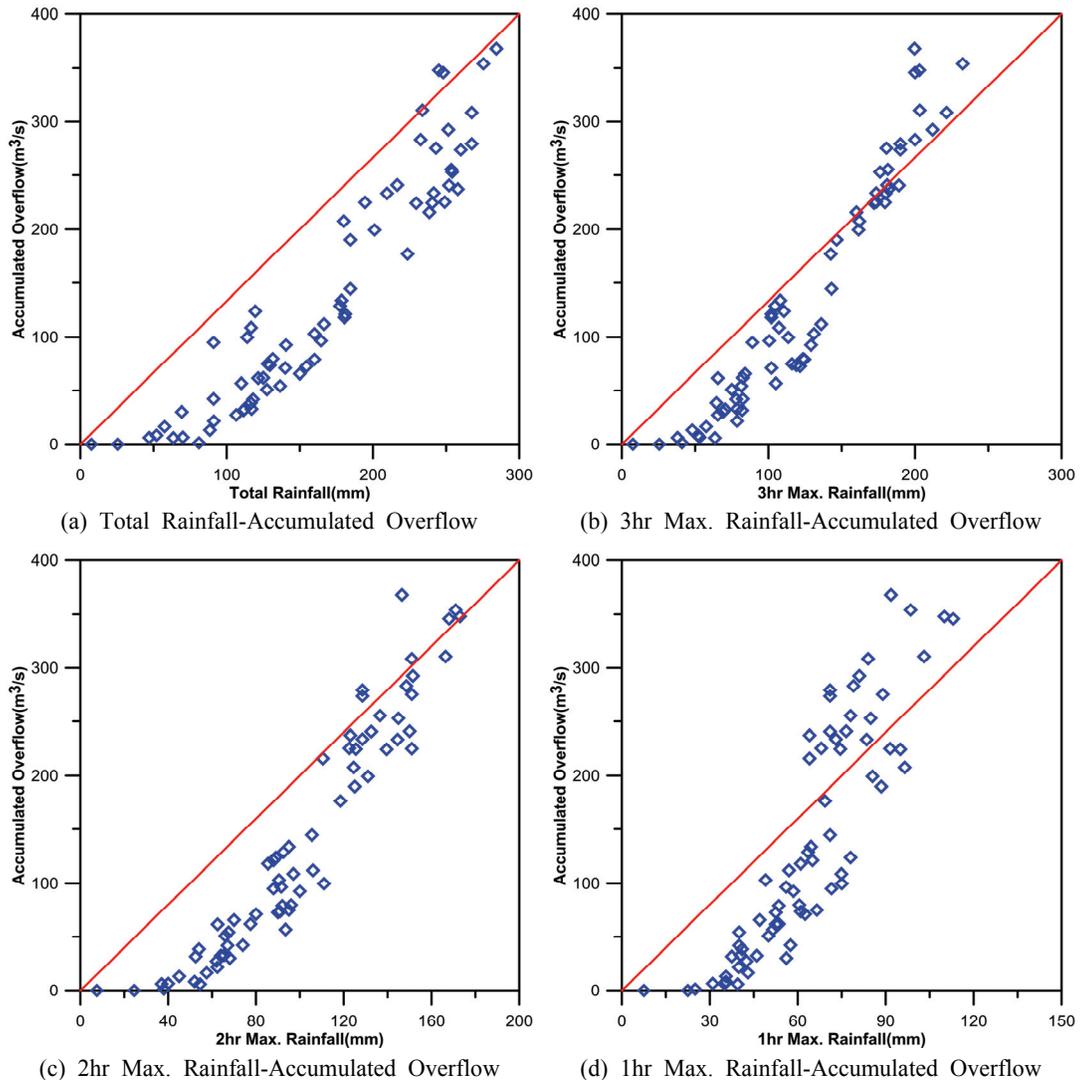


Fig. 7. Result of Correlation Analysis (1)

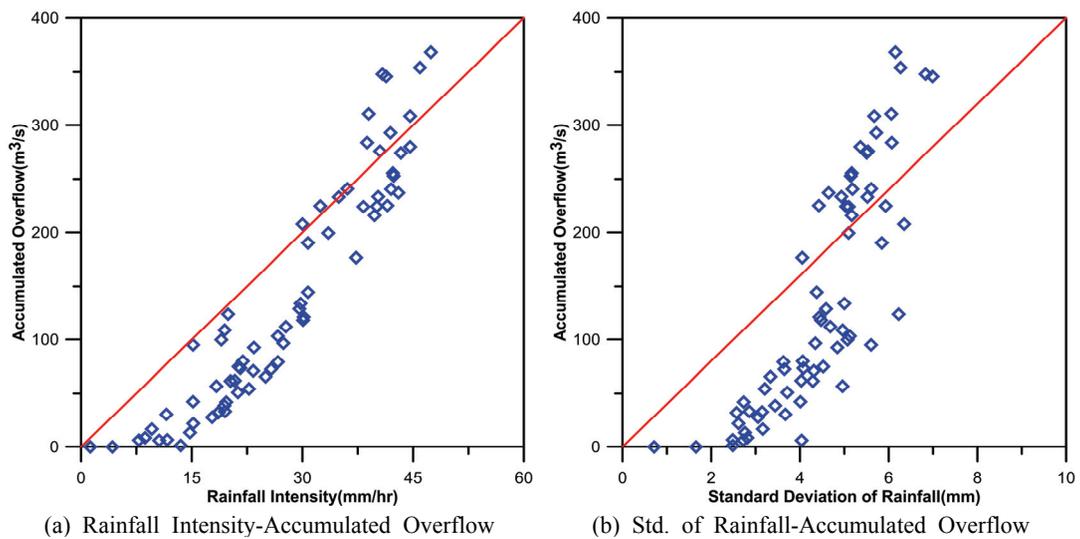


Fig. 8. Result of Correlation Analysis (2)

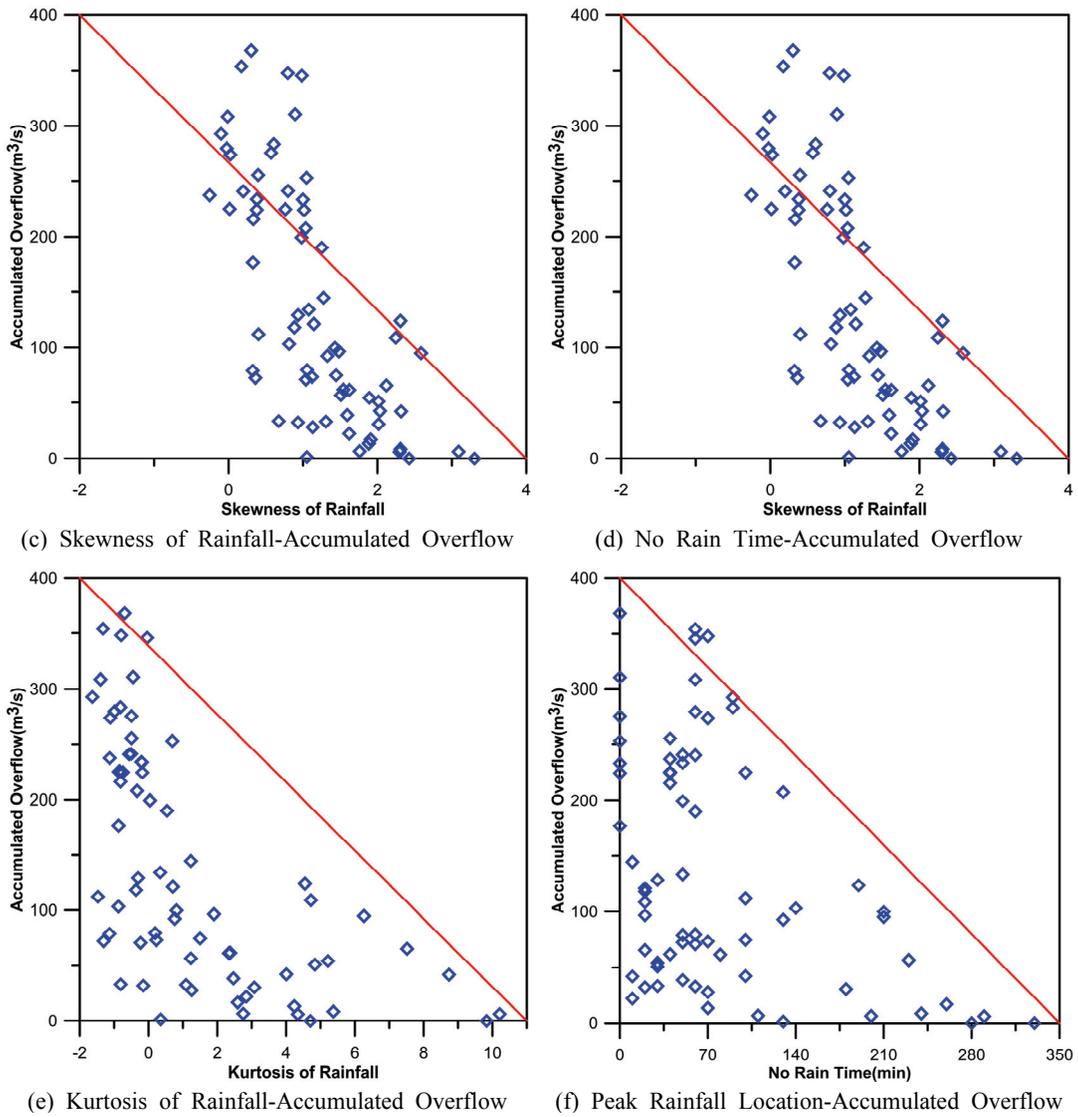


Fig. 8. (Continued)

Table 4. Result of K-fold (K=10, Mean Absolute Error,  $m^3/s$ )

No. of K	CASE1	CASE2	CASE3
1	14.06	6.60	10.62
2	12.41	9.94	14.16
3	19.52	16.86	19.14
4	14.81	14.83	11.80
5	10.14	5.58	8.47
6	16.72	7.50	11.64
7	22.92	14.24	11.13
8	28.29	10.66	15.52
9	27.56	16.18	21.06
10	15.65	10.36	10.37
Average	18.21	11.27	13.39

**Table 5.** Results of Simulation and Prediction

Total Acc. Overflow ( $m^3/s$ )	Input Criterion		
	CASE1	CASE2	CASE3
SWMM Simulation	144.7		
Prediction with DNN	168.66	129.16	155.69
Residual (SWMM-Predicted Result)	-23.96	15.54	-10.99

료 조합에서 가장 좋은 결과가 나타났으며, 목표값이 되는 총 누가 월류량 자료와 상관도가 높은 자료를 이용할수록 더 좋은 예측 모델이 구축되는 것이 증명된 것으로 판단된다.

K-fold 검증 후 각 2011년 7월 27일 강우 사상에 대한 총 누가 월류량(SWMM모형 모의결과)에 대한 심층신경망의 예측을 실시하였다. 예측은 입력 자료조합 CASE1~3에 따라 실시되었으며, 그 결과를 1차원 도시유출해석 결과의 총 누가 월류량과 비교하였다(Table 5). SWMM모형 결과와 잔차를 보았을 때에, CASE3에서 가장 그 차이가 적게 나타났지만 모의 된 결과값보다 높게 나타났다. CASE2에서는 그 다음으로 잔차가 적게 나타났으며, SWMM모형을 통해 모의 된 결과보다 낮게 나타난 것으로 보인다. CASE1의 경우 잔차가 가장 크게 나타나고, 모의 결과값도 현저히 높게 나타났는데 상관도가 낮은 입력 자료를 적용하여 나타난 것으로 판단된다. K-fold 검증 결과와 특정 강우 사상에 대한 예측 결과를 종합하여 보았을 때에, 양의 상관관계를 가지며, 총 누가 월류량 자료와 높은 상관도를 보이는 CASE3자료에 기반하여 학습된 심층신경망이 가장 적합한 것으로 판단된다.

#### 4. 결론

일반적으로 특정 도시지역에 대한 침수이력과 자료는 부족하며, 이에 실시간적인 도시 홍수 분석을 위한 기초자료가 부족한 상황이다. 도시 홍수량 또는 총 누가 월류량을 예측하기 위해 본 연구에서는 지속시간 6시간을 가지는 70개의 전국단위 관측강우를 조사하였으며, 이에 대한 10분 단위 총 누가 월류량을 산정하기 위해 SWMM모형을 이용하였다. 예측 모형을 위해 심층신경망을 사용하였으며, 입력 자료는 강우자료에 대한 통계적 특성을 이용하였다. 예측 모형에 대한 검증은 K-fold 기법을 통해 수행하였으며, 심층신경망의 학습 후 예측은 2011년 7월 27일 실측 호우사상에 대하여 실시하였다. 주요 연구 결과는 다음과 같다.

- (1) 침수를 발생시키는 6시간 강우에 대한 자료 수집을 하였으며, 이에 대한 강우 특성 분석을 통하여 도시유출 현상과 높은 상관도를 가지는 특성치를 파악할 수 있었다. 총 강우량과 강우강도에서 가장 높은 상관도를 보였지만, 6시간 강우 내에서 1~3시간 단위 최대

강우량 또한 높은 상관도를 나타냄을 알 수 있었다. 강우 사상 내에서 침투강우 위치의 경우 큰 영향을 주지 못함을 파악할 수 있었으며, 강우 사상에 대한 침도와 왜곡도는 유출 양상과 음의 상관관계를 가지는 것을 확인하였다.

- (2) K-fold 검증과 단일 사상에 대한 예측 결과를 검토하였을 때에, CASE3의 입력자료 조합 기반 예측 모형이 가장 적합한 것으로 판단되었다. 이는 총 강우량, 강우강도, 1~3시간 최대 강우량만을 이용한 모형인데, 도시유역에 대한 총 누가 월류량은 강우 사상의 형상과 침투의 위치보다 강우의 물리적인 양에 더욱 큰 영향을 받는 것으로 판단되었다. 총 누가월류량에 있어서 SWMM모형 결과보다  $10.99m^3/s$  정도 높게 예측되었지만, 추후 데이터베이스의 보완과 심층신경망의 보정으로 더욱 예측력이 높아질 수 있을 것으로 보인다.
- (3) 2011년 7월 27일 강우 사상에 대한 SWMM모형의 1차원 도시유출해석이 완료되는데 14분이 소요되었으나, 심층신경망을 통한 예측은 2~초 내외에 수행되어 실제 침수 유발 강우 발생 시, 도시 홍수량 산정에 많은 시간을 절약할 수 있을 것으로 보인다. 연구 대상지역 외 실제 강우 자료를 이용한 예측을 성공적으로 수행함으로써, 자료기반 해석 시 자료 보완 기법에 대한 기초 연구를 수행할 수 있었다. 제시된 실측 강우 기반 심층신경망 모형은 도시지역에서 실시간 홍수 대응을 위한 기초자료가 될 것으로 보이며, 삼성 배수분구 뿐만 아니라 서울시 전 배수분구에 대한 예측 모형을 구축한다면 서울시 전체 홍수 예·경보 체계에 실용적으로 이용 될 수 있을 것으로 판단된다.

#### 감사의 글

본 연구는 행정안전부 국립재난안전연구원의 지원(“딥러닝 기반 도시침수 예측 및 분석기술 개발”, “NDMI-주요-2019-09-01”)에 의해 수행되었습니다. 이에 감사드립니다.

#### References

Granata, F., Gargano, R., and Marinis, G. (2016). Support

- vector regression for rainfall-runoff modeling in urban drainage: A comparison with the EPA's storm water management model. *Water*, Vol. 8, No. 3, 69. doi:10.3390/w8030069.
- Hu, C., Wu, Q., Li, H., Jian, S., Li, N., and Lou, Z. (2018). Deep learning with a long short-term memory networks approach for rainfall-runoff simulation. *Water*, Vol. 10, No. 11, 1543. doi:10.3390/w10111543
- Huber, W.C., and Dickson, R.E. (1988). *Storm water management model, Version 4. Part A: User's manual*. EPA/600/3-88/001A, U.S. Environmental Protection Agency, Washington, D.C.
- Kim, H.I., Keum, H.J., and Han, K.Y. (2018). Application and comparison of dynamic artificial neural networks for urban inundation analysis. *Journal of the Korean Society of Civil Engineers*, Vol. 38, No. 5, pp. 671-683.
- Kingma, D.P., and Ba, J.L. (2015). ADAM : A method for stochastic optimization. *Proceedings of 3rd International Conference for Learning Representations (ICLR 2015)*, San Diego, CA, USA.
- Li, X., and Willems, P. (2018). A data-driven hybrid urban flood modeling approach. *HIC 2018, 13th International Conference on Hydroinformatics*, Vol. 3, pp. 1193-1200.
- Lim, J.T., and Kim, B.H. (2019). Modeling for debris flow behavior on expressway using FLO-2D. *Journal of the Korean Society of Civil Engineers*, Vol. 39, No. 2, pp. 263-272.
- Park, J.H., Kim, S.H., and Bae, D.H. (2019). Evaluating appropriateness of the design methodology for urban sewer system. *Journal of Korea Water Resource Association*, Vol. 52, No. 6, pp. 411-420.
- Remesan, R., and Mathew, J. (2015). *Hydrological data driven modeling*. Earth System Data and Models 1, Springer.
- Seoul Metropolitan City. (2015). *Comprehensive plan for storm and flood damage reduction*. Korea, Vol. 1, Chapter 3, pp. 374-375.
- Shen, C. (2018). A transdisciplinary review of deep learning research and its relevance for water resources scientists. *Water Resources Research*, Vol. 54, No. 11, pp. 8558-8593. doi:10.1029/2018WR022643
- Son, A.L., Kim, B.H., and Han, K.Y. (2015). A study on prediction of inundation area considering road network in urban area. *Journal of the Korean Society of Civil Engineers*, Vol. 35, No. 2, pp. 307-318.
- Zhou, J., Peng, T., Zhang, C., and Sun, N. (2018). Data pre-analysis and ensemble of various artificial neural networks for monthly streamflow forecasting. *Water*, Vol. 10, No. 5, 628. doi:10.3390/w10050628

---

<b>Received</b>	November 14, 2019
<b>Revised</b>	November 15, 2019
<b>Accepted</b>	November 27, 2019