

강우유출수 침투필터의 폐색 예측을 위한 딥러닝 모델 개발

이병식
공주대학교 사회환경공학과

Development of Deep Learning Model to Estimate Clogging of Stormwater Infiltration Filter

Byung-Sik Lee
Department of Civil & Environmental Engineering, Kongju National University

요 약 필터폐색은 강우유출수 침투시설 기능저하의 주된 요인이다. 침투시설의 수명예측과 효율적인 유지관리를 위해서는 폐색도의 명확한 예측이 필수적으로 요구된다. 폐색현상을 조사하기 위한 시험연구들이 꾸준히 수행되어 왔다. 시험연구 결과에 근거하여 폐색예측을 위한 시험모델들이 제안되어 왔다. 시험모델 개발에는 적지 않은 시간과 비용이 소요된다. 따라서 시험모델을 보완하기 위해 다양한 이론모델의 적용이 시도되었다. 하지만 제안된 이론모델을 적용함에 있어서 문제점이 상존한다. 일반적으로 결정하기 힘든 많은 수의 자료 입력이 요구된다. 또한 많은 경우에 얻은 결과의 신뢰도도 낮다. 최근에는 여러 분야에서 기존 이론모델을 대체하는 데이터 기반 모델 개발을 위해 딥러닝 기법을 적용하고 있다. 개발된 딥러닝 모델들은 기존 이론모델의 단점을 보완할 수 있을 것으로 기대된다. 이 논문에서는 장단기기억순환신경망(LSTM-RNN : Long Short Term Memory - Recurrent Neural Network)을 이용하여 강우유출수 침투시설의 폐색을 추정하는 모델을 개발하였다. 침투시험 결과에 대한 훈련 및 검증을 통해 개발된 모델의 실용 가능성을 실증하였다. 결과에 근거하여 폐색 데이터 축적과 적용성이 기대되는 딥러닝 기법을 필터폐색 모델에 적용하기 위한 지속적인 연구를 제안할 수 있었다.

Abstract Filter clogging is a major problem resulting in the failure of a stormwater infiltration system. Definite knowledge about the degree of clogging is essential to plan effective maintenance and estimate the lifespan of the facility. Experimental studies have been conducted continuously to investigate clogging phenomena. Based on experiment results, experimental models to estimate clogging have been suggested. A relatively long period and high cost are required to develop experimental models. Thus, the applications of various theoretical models have been attempted to supplement experimental models. On the other hand, problems have limited the applications of the suggested theoretical models. A large number of difficult-to-determine inputs are usually required. Therefore, the obtained results are not confident. Deep learning techniques have recently been applied to develop new data-driven models replacing conventional models in various fields. The developed deep learning models are expected to exclude the shortcomings of theoretical models. The LSTM-RNN (Long Short Term Memory-Recurrent Neural Network) model was developed to estimate the clogging of stormwater infiltration systems. The applicability of the model was validated by implementing the model train and evaluation by the experimental infiltration test results. As a result, ongoing studies could be suggested to accumulate clogging data and apply promising deep learning algorithms to clogging models.

Keywords : Deep Learning, Filter, Clogging, Stormwater, Infiltration

*Corresponding Author : Byung-Sik Lee(Kongju National Univ.)

email: blee@kongju.ac.kr

Received May 31, 2021

Accepted September 3, 2021

Revised June 25, 2021

Published September 30, 2021

1. 서론

비점오염관리 및 도시 물 순환 체계 개선을 위한 강우유출수 침투시설 필터에는 다공성 매질의 여과재가 자주 사용된다. 다공성 여과재의 간극은 유출수 침투량이 증가함에 따라 오염물질로 폐색된다. 필터가 폐색되면 침투시설의 운영 장애를 초래할 수 있다. 따라서 폐색현상은 침투시설의 설계 및 운영관리에서 중요하게 고려되어야 한다.

여과재의 침투능, 오염물질 제거 능력, 침투조건 변화 등 필터 내 폐색현상을 조사하기 위한 많은 시험연구가 수행되어 왔다[1-10]. 이들 연구에서는 강우유출수량과 필터 폐색도 간의 상관관계를 조사했다. 여재 종류, 수리 조건, 오염물 종류 및 농도 등 다양한 침투 조건 변화에 따른 조사가 수행되었다. 이들 결과는 필터 설계 및 운영 시 반영되었다. 또한, 시간에 따른 폐색도의 변화를 구하기 위한 모델들이 제안되었다[3-5,11,12]. 이들 폐색모델은 개발과 적용에 소요된 비용과 노력에 비해 실제 문제에 대해서는 적용성과 신뢰도가 낮은 것으로 평가되었다[12]. 따라서 이러한 문제점을 배제할 수 있는 폐색추정모델의 개발이 요구되고 있다.

최근 머신러닝, 딥러닝 기법 등의 인공지능기법을 폐색추정모델 개발에 적용하는 연구가 다공성 필터, 정수 시스템, 대수층 투수, 비점오염 침투 등과 관련한 다양한 분야에서 수행되고 있다[13-17]. 인공지능기법에서는 데이터를 기반으로 몇 가지 특성(feature)들에 대한 기준값(label) 간의 알려진 관계를 학습을 통해 습득한 모델을 만든다. 특성변화에 대한 예측값(prediction)은 학습된 모델을 사용하여 추정한다. 인공지능기법에서는 고전적 이론모델에서 요구되는 복잡한 입력변수의 결정을 배제할 수 있다는 장점이 있다. 하지만 모델 적용의 성공여부는 신뢰성 있는 데이터 수집에 영향을 받을 수 있다.

이 논문에서는 침투시설에서 침투량 증가에 따른 필터 폐색도의 변화를 추정하기 위한 딥러닝모델을 개발하였다. 침투량과 폐색도는 시간에 따라 변화하므로 이들 관계는 시계열데이터로 구분된다. 따라서 시계열 자료분석에 유용한 것으로 알려진 RNN 기법을 적용하였다. 결과를 바탕으로 강우유출수 침투시설 필터의 폐색모델에 대한 딥러닝기법의 적용성을 평가하였다.

2. 데이터

2.1 침투시험 데이터

폐색모델을 개발하기 위해 Segismundo et al.(2017)이 수행한 침투시험 결과를 사용하였다[9]. 순수한 모래 필터와 모래-저회 혼합 필터에 대해 혼합율을 변화시킨 세 가지 조건을 포함하여 총 4종의 침투시험 결과를 사용하였다. 필터조건과 사용한 여재의 상세한 특성은 Segismundo et al.(2017)에서 참조할 수 있다[9]. 각 필터 조건의 공시체에 대해서 수행한 변수위 및 정수위 침투시험 중 침투유량 많아 상대적으로 긴 시간구간에 대한 폐색변화를 볼 수 있는 정수위침투시험 결과를 사용하였다. 시험결과로부터 침투시간에 따른 필터의 폐색도 변화를 알 수 있으며 결과는 Fig. 1에 보인 바와 같다. 그림에서 수평축은 물높이로 나타낸 침투유량(Q)으로 침투시간에 따라 증가한다. 수직축은 임의의 시간에 토출되는 침투유량을 초기침투유량에 대해 정규화한 값으로 침투율(IR)로 정의하였다. 이 값은 시간에 따른 침투유량의 증가에 따라 폐색도가 증가하면서 감소한다.

이 논문에서는 임의의 침투 특성조건에서 침투에 따른 폐색도 증가 시 감소하는 침투율과 이에 대응하는 침투유량의 상관관계를 추정할 수 있는 딥러닝 모델을 개발하였다.




Fig. 1. Experimental results representing the reduction of IR with increasing Q [9]

2.2 모델 학습을 위한 데이터 가공

2.2.1 특성(feature)과 기준(label)

딥러닝모델 학습 및 검증 데이터셋트는 침투율(IR), 침투율 증분(ΔIR), 침투유량(Q), 모래함유율(P_S), 저회함유율(P_A) 등 5개 특성에 대한 시간 데이터로 구성하였다. 이들 특성 중 기준값은 Q 로 정해 IR 변화에 따른 Q 를 추정하는 회귀(regression) 모델을 개발하였다.

Fig. 1에 보인 4가지 침투조건은 모래와 저회의 함유율 P_S 와 P_A 를 적용하여 구분하였다. 같은 목적으로 원-

핫 인코딩(One-Hot Encoding) 방법의 적용도 고려하였지만 이 논문에서 다룬 데이터에 대해서는 뚜렷한 장점이 없어 적용하지 않았다.

2.1.2 입력 데이터셋 가공

특성항목 중 IR , Q 와 ΔIR 은 시간축에 대해서 현시값(current state units)을 갖는다. 반면에 P_s 와 P_A 는 고정값(plan units)을 갖는다. 현시값을 가지는 특성항목에 대한 데이터를 추출하기 위해 IR 범위를 1.00~0.17로 정했다. 이 범위는 Fig. 1에 보인 모든 침투조건에 대한 시험결과를 포함한다. 이 범위에서 ΔIR 을 단계마다 0.0005씩 점차로 증가시키면서 58개로 나눈 점들에 대해 IR 값을 추출하였다. ΔIR 을 단계적으로 증가시키는 경우에 비교적 적은 훈련데이터로도 양호한 훈련결과를 얻을 수 있었다[18]. 또한, $IR-Q$ 곡선의 초기 구간 곡선부의 변화양상을 잘 반영할 수 있었다. 이렇게 정한 58개의 IR 에 대해 침투시험 결과를 기반으로 Q 를 정해 $IR-Q$ 관계를 나타내는 합성곡선을 가공했다. 4가지 침투조건에 대해 가공한 합성곡선을 Curve0, Curve1, Curve2, Curve3로 칭하기로 하였다. 각 합성곡선 데이터셋트에 적용한 특성과 각 특성값의 범위를 Table 1에 정리하였다.

Table 1. Summary of synthetic $IR-Q$ curves

Symbol	Infiltration Ratio (IR)	Flow Quantity (Q , m)	Sand Ratio	Ash Ratio	ΔIR
Curve0	1.00~0.17	1~100	1.00	1.00	0.0005~0.0285
Curve1	1.00~0.17	1~100	0.75	0.25	0.0005~0.0285
Curve2	1.00~0.17	1~100	0.50	0.50	0.0005~0.0285
Curve3	1.00~0.17	1~100	0.25	0.75	0.0005~0.0285

딥러닝 모델 훈련 및 최적화에서 정규화된 데이터의 사용하는 경우에 훈련 중 파라미터의 결정과정에서 가중치 편향을 배제할 수 있어 권장되었다[19]. 이 논문에서도 Table 1에 보인 합성곡선의 데이터셋트를 각 특성항목에서 최소값 0과 최대값 1을 갖도록 정규화하였다. 데이터셋트는 pandas Data Frame 형식으로 만들었고, 각 특성에 대한 분포를 나타내면 Fig. 2와 같다. Table 1의 합성곡선을 정규화한 데이터셋트에 대한 $IR-Q$ 곡선은 Fig. 3과 같다.




Fig. 2. Characteristics of the normalized synthetic data




Fig. 3. Synthetic $IR-Q$ curves

3. 모델

3.1 장단기 기억 순환신경망

침투유량과 침투량 간의 관계를 딥러닝으로 모델링하기 위해 시계열 자료분석에 적용성이 높은 모델로 알려진 장단기 기억(LSTM: Long Short-Term Memory) 층(layer)을 내포한 순환신경망(RNN: Recurrent Neural Network)인 LSTM-RNN 모델을 적용하였다. LSTM-RNN 모델은 다층퍼셉트론 구조를 가지며 시계열에서 단계 간 내부 상태(internal state)를 유지하면서 역방향 전달 알고리즘으로 최적화된다. 이 모델은 LSTM을 적용하지 않은 RNN과 비교하여 임의 단계 간 거리가 멀 경우 역전파 시 그라디언트가 점차 줄어 학습능력이 크게 저하되는 문제(vanishing gradient)를 배제할 수 있다[20]. 모델 형성 및 최적화는 머신러닝 플랫폼 tensorflow의 파이썬 API 인 Keras를 이용하여 개발하였다[21].

3.2 모델 구축

순환신경망모델은 각 1 층의 입력층, 은닉층과 출력층으로 만들었다. 입력층의 노드 수는 8 개이고 이는 데이터 입력장의 폭과 같다. 은닉층은 16개의 LSTM 셀로 설

계하였다. 셀의 개수는 하이퍼파라메트릭 최적화가 필요한 항목이다. 출력층은 1 개 노드를 가지며 이는 Q 로 구해지는 예측값에 해당한다. 모델의 층 구조를 개괄적으로 나타내면 Fig. 4와 같다.




Fig. 4. Architecture of developed model[22]

이 모델은 단일시간단계(single-time-step), 단일출력(single-output) 형식의 시계열모델로 구분할 수 있다. 모델은 임의의 시간단계에서 입력창으로 입력된 여러 개의 단일시간단계(single-time-step) 입력값에 대한 기준값을 각각 단일 출력(single-output)으로 추정한다. Keras RNN 층 생성 시 return-sequence 옵션을 True로 하여 각 입력값에 대해 출력값을 반환토록 하였으므로 모델은 여러 시간단계에서 동시에 훈련할 수 있다. 입력값, 모델, 예측값과 라벨 간의 데이터 흐름의 개략도를 나타내면 Fig. 5와 같다.

모델은 Adam 알고리즘[20]으로 최적화하였다. 손실(loss)은 Mean Squared Error(MSE)를 적용하고, 훈련과 검증과정에서 평가할 메트릭(metric)은 Mean Absolute Error(MAE)를 선택하였다. 모델 컴파일 시 이들 각 입력항목(argument)에 대한 선택값은 기본값[20]을 적용하였다.




Fig. 5. LSTM model of single-time-step, single-output predictions[20]

3.3 데이터셋

모델훈련을 위해 데이터프레임 형태인 Table 1의 데이터셋을 tf.data.Dataset로 변환해야 한다. 데이터프레임에서 데이터셋은 [시간, 특성]의 2차원 배열이다. 이를 변환한 tf.data.Dataset는 데이터프레임 자료를 각 배치(batch)에서 Fig. 5에 보인 바와 같이 시계열에서 입력창과 출력창이 8 시간단계 폭인 슬라이딩창을 적용하여 시간전이(offset) 1 시간간격으로 매핑한 데이터로서 [배치, 시간, 특성]의 3차원 텐서이다. 매핑 시 배치크기는 16으로 하고 시계열 의존성 데이터를 다루므로 shuffle을 False로 지정했다. 따라서 전시계열 구간에서 슬라이딩창을 통해 순차적으로 매핑한 16 세트의 데이터가 1 배치로 누적되었다. 데이터셋트가 모델에 입력되면 은닉층과 출력층의 텐서는 노드 수로 나타낸 특성에 따라 [배치, 시간, 특성]의 차원을 갖는다. 구축한 모델의 층 및 데이터 구조는 Fig. 6과 같고, 매개변수 수는 LSTM 층 1408개와 출력층 17개의 총 1,425개 매개변수를 포함하고 있다.




Fig. 6. Summary of the LSTM-RNN model

3.4 훈련 및 검증계획

교차검증을 통해서 딥러닝 모델훈련의 효율을 향상시킬 수 있다. 시계열 데이터의 교차검증에서는 시간의존성과 테스트셋 선택의 임의성(테스트셋 간의 독립성)을 고려한 nested cross-validation 방법 (Fig. 7)을 적용할 수 있다[23, 24]. 하지만 이 논문에서 다룬 데이터는 시간의존성과 데이터셋 간 독립성을 가진다는 점에서 문헌의 데이터와 유사하지만 1일 반복특성을 가지지 않는다는 점에서는 상이하여 직접 적용할 수 없었다[23].

Lin(2018), Shahin(2014), Shahin(2014) 등은 전체의 독립적 데이터셋 중 80~90%를 훈련셋으로 나머지는 테스트셋으로 구분하는 방법을 적용하였다[17, 18, 25]. 하지만 이 방법에서는 별도의 검증데이터셋트가 설

정되지 않았다는 문제점이 있었다. 하이퍼파라미터 최적화와 모델 과대적합(over fitting)을 방지하기 위해서는 검증셋트의 설정이 필요하다. 훈련셋트만으로 하이퍼파라미터를 튜닝하게 되면 과대적합(over fitting)이 일어날 가능성이 높은 것으로 알려져 있다[21].




Fig. 7. NCS(Nested Cross Validation) for a time series[23]

결과적으로 이 논문에서는 위의 방법들을 변형한 훈련 및 검증과정을 다음과 같이 고안하여 적용하였다.

- 1) 전체 데이터셋(총 4종) 중 훈련데이터셋 3종(75%)과 테스트데이터셋 1종(25%)을 선택
- 2) 선택한 훈련데이터셋 3종을 각각 단순 홀드아웃(hold-out validation)[21] 방법을 적용하여 훈련 데이터 80%와 검증 데이터 20%로 분리
- 3) 훈련데이터셋 3종의 훈련데이터에 대해 순차적으로 모델 훈련
- 4) 3)의 과정에서 각각 검증데이터를 사용하여 하이퍼파라미터 최적화를 시도
- 5) 4)의 과정에서 구한 최적모델에 대해 각각 훈련 및 검증데이터를 포함한 전체데이터에 대한 훈련
- 6) 테스트셋트 1종에 대한 모델 검증

이 방법을 적용하기 위해 Fig. 3의 $IR-Q$ 곡선의 데이터셋 중 Curve0, Curve1, Curve3을 훈련 및 검증셋트로 Curve2를 테스트셋트로 선택하였다. 각 데이터셋트의 목적에 따라 데이터를 훈련, 검증, 테스트 데이터로 분리하였으며 그 결과를 Fig. 8에 나타냈다. 목적 별 데이터셋트의 선택과 훈련순서 적용 방법이 결과에 영향을 미칠 수 있을 것으로 예상되었다. 또한 모델 층 수, 배치크기, epoch(반복훈련 횟수), fit 옵션인 patient, callback, early stopping 등의 하이퍼파라미터 최적화가 필요한 것으로 판단되었다. 이들 인자 중 데이터셋트의 훈련순서와 epoch의 영향에 관한 검토를 중점으로 수행하였다.




Fig. 8. Data sets for training and evaluation of the model

4. 결과 및 분석

4.1 모델 훈련 및 검증

3.2에서 구축한 LSTM-RNN 모델을 3.4에서 설명한 훈련과정에 의거하여 Fig. 3의 합성곡선 Curve1로부터 시작하여 Curve0, Curve3의 순서로 훈련 및 검증하고 Curve2로 테스트하여 최종모델로 제안코자 하였다.

이 과정에서 검토한 결과의 한 예로서 훈련 시 epoch에 따른 손실 변화와 수렴 조건 만족 시 얻은 $IR-Q$ 곡선의 변화를 합성곡선 Curve1과 Curve0에 대해서 각각 Fig. 9 (a)와 (b)에 보였다. 그림의 결과에서 각 곡선에 대한 훈련 및 검증 시 손실은 충분히 수렴하였음을 알 수 있다. 또한 훈련 및 검증손실 값에 큰 차이가 없어 과대적합의 문제는 발생하지 않은 것으로 판단되었다.

Fig. 9 (a)에 보인 $IR-Q$ 곡선에서는 Curve1에 대해서만 훈련한 모델의 적합성을 검토할 수 있다. 이 단계에서 모델은 Curve0, Curve3에 대해서는 아직 훈련되지 않았으므로 Curve1을 제외하고는 기준값과 예측값이 일치하지 않는 결과를 보이는 것이 당연하다. 같은 그림에 보인 Curve2에 대한 결과는 최종 적합모델에 대한 테스트가 아니므로 아직은 의미가 없다.

Fig. 9 (b)는 Curve1에 대한 훈련한 모델을 Curve0에 대해 추가로 훈련한 모델을 적용한 결과이다. Curve0에 대한 $IR-Q$ 곡선은 기준값과 예측값이 잘 일치하였다. 모델을 Curve1에 대해 이미 훈련했지만 현 단계에서 모델은 Curve0에 대해서 적합한 상태로 Curve1을 포함하여 다른 곡선들에 대해서는 일치하지 않았다. 따라서 모든 곡선의 데이터셋트에 대해서 기준값과 예측값이 일치하는 $IR-Q$ 곡선을 추정할 수 있는 적합모델을 얻기 위해서는 Curve3을 포함한 데이터에 대한 훈련 및 검증 단계를 반복하여야 함을 알 수 있었다.

모든 데이터셋트에 대해서 훈련 및 검증손실이 수렴하는 조건을 만족하는 모델을 찾을 수 있었다. 이 모델을 최종 적합모델로 결정하였다. 총 15 단계의 훈련 및 검증 과정을 거쳤으며, 이 과정에서 모든 단계에 대한 손실이 Fig. 10에 나타났다. Fig. 10에서 나타난 바와 같이 초기 훈련단계에서 모델은 훈련대상 입력 데이터셋트에 가장 잘 수렴한다. 이후 다른 데이터셋트에 대한 훈련과정을 경험하면서 입력 데이터셋트에 의한 영향이 감소되었다. 12번째 훈련단계를 지나면서는 임의의 입력 데이터에 대해 훈련할지라도 다른 모든 데이터셋트에도 적합한 모델로 수렴하는 것을 볼 수 있었다. Fig. 10의 결과에는 Curve2에 대한 테스트 결과도 함께 나타냈고 최종 단계에서 적절한 수준으로 수렴함을 확인하였다. Fig. 10에 보인 수렴과정은 수동으로 진행되었지만 모델링 대상 특성 변화에 따른 합성곡선의 수가 매우 많아지는 경우에는 무작위로 선택한 훈련대상 입력데이터에 의한 자동수렴 방법을 고안하여 적용해야 할 것으로 판단되었다.




Fig. 9. Typical results of loss history and $IR-Q$ curve after training and validating




Fig. 10. Variation of training and validation loss

Curve0, Curve1, Curve3에 대한 반복 훈련 과정에서 훈련 및 검증을 위한 합성곡선의 선택 순서가 훈련결과에 주는 영향을 검토하였다. 그 결과 Curve0으로부터 시작하여 Curve3 혹은 Curve1의 순서로 훈련 및 검증하고 Curve2로 테스트한 결과도 유사한 최종모델로 수렴하는 것으로 확인되었다. 각 합성곡선이 독립시계열 데이터이므로 이와 같은 결과는 적절한 것으로 판단되었다.

4.2 모델 적합성

훈련 및 검증과 테스트를 마친 최종 적합모델을 이용해 훈련 데이터셋트인 Curve0과 테스트 데이터셋트인 Curve2의 전체 배치에 대한 입력값, 기준값, 예측값의 변화 양상을 Fig. 11에 보였다. 또한, Fig. 11의 결과 중 배치데이터 각 입력창의 마지막 기준값과 예측값을 수집하여 각 합성곡선에 대한 $IR-Q$ 곡선을 구해 Fig. 12에 보였다.

Fig. 11과 12의 결과에서 Curve0에 대해서는 기준값 구간의 상대적 차이로 인해 기준값과 예측값의 일치도가 다른 곡선에 비해서 상대적으로 낮았다. 하지만 전체 구간에서 폐색도 증가를 양호하게 추정할 수 있는 수준의 결과를 얻을 수 있었다. 다른 합성곡선에 대해서는 기준값과 예측값이 적절한 수준으로 일치하였다. Curve2에 대한 테스트 결과도 양호하였다. 전반적으로 모델은 침투유량 증가에 따른 폐색도 변화를 예측하기 위한 목적으로 적용할 수 있다고 판단되었다.

또한 모델의 신뢰도는 Fig. 13에 보인 상관관계를 이용해서도 검토할 수 있었다. Fig. 13의 결과는 Fig. 12에 보인 모든 합성곡선에 대해 구한 기준값과 예측값의 상관관계를 보인 것이다. 그림의 결과에서 상관관계수(r)는 0.9669로서 모델이 기준값을 적절한 수준으로 예측하고




Fig. 11. Comparison between inputs, labels, predictions for all batch data of Curve0 and Curve2

있음을 볼 수 있었다.

개발한 모델의 일반화 성능(적합성), 민감도, 오차를 평가하기 위한 검토를 수행하였다. 이를 위해 모래와 저회의 혼합율 90:10, 60:40, 40:60, 10:90 조건의 4가지 필터를 가정하고 폐색도를 추정해 보았다. 최초 검증단계에서 임의로 추정한 여러 셋트의 모델입력값에 대해 모델을 이용해 구한 예측값의 변화 추세를 검토하였다. 그 결과 어떤 값을 입력해도 Fig. 3의 합성곡선과 비교할 때 모래와 저회의 혼합율이 반영되는 예측값을 추정할 수 있는 것으로 확인되었다. 하지만 입력값의 변화에 따른 예측값의 변화는 매우 컸다. 신뢰성 있는 예측값을 얻기 위해서는 시험자료를 바탕으로 혼합율을 반영하여 실제와 유사할 것으로 추정되는 입력값을 가정하여 적용할 때 가장 좋은 결과를 얻을 수 있었다. Fig. 14에 이렇게 추정한 예측값을 입력값과 비교하였다. 같은 그림에 시험결과인 Fig. 3의 기준값을 함께 보였다.




Fig. 12. $IR-Q$ relation curve obtained from the final model




Fig. 13. Correlation between label and predict values




Fig. 14. Sensitivity analyses according to the mixing ratio of sand and ash

저회 대비 모래의 혼합율이 증가함에 따라 필터의 침투유량 증가에 따른 침투율 감소율이 증가하는 현상은 침투폐색시험[9]으로부터 확인된 물리적 현상이다. Fig. 14에 보인 결과에서 모델 예측값으로 추정한 폐색곡선이

이러한 현상을 반영하고 있음을 알 수 있었다. 따라서 일반적인 침투조건에 대한 침투필터 폐색 예측이 가능한 수준까지 개발 모델의 적용성을 확대할 수 있는 가능성을 확인하였다.

4. 결론 및 제언

도시강우유출수 침투시설 필터의 유출량 증가에 따른 폐색을 추정하기 위해 장단기역순환신경망 딥러닝 모델을 개발한 결과 다음의 결론 및 제언을 할 수 있었다.

- 1) 모든 데이터에 대해 모델을 사용하여 폐색을 예측한 결과 기준값과의 상관관계(r)가 0.9 이상으로 나타나 적합성을 검증할 수 있었다.
- 2) 임의의 혼합을 조건에 대해 모델의 적용성을 평가한 결과 입력데이터를 임의의 값으로 입력한 조건에서도 혼합율을 반영한 폐색곡선을 예측할 수 있었다.
- 3) 이러한 결과에 근거하여 개발모델의 신뢰도와 적용성 확대 가능성을 확인하였다. 또한, 기존 이론 및 시험 폐색모델들에 대한 보완 및 대체 기법으로 딥러닝 기법의 활용 가능성을 확인하였다.
- 4) 개발한 모델에서 반영한 폐색특성이 모래 저회 혼합물에 국한되었고, 하이퍼파라미터 검증 필요성, 부족한 훈련데이터 양과 같은 문제점들이 있었다. 이러한 문제점에도 불구하고 폐색 예측을 위한 딥러닝 모델의 활용 가능성이 매우 높은 것으로 검증 되었으므로 딥러닝 알고리즘을 이용한 모델개발과 적합성 검토에 관한 지속적인 연구수행을 제안할 수 있었다.

References

- [1] N. R. Siriwardene, A. Deletic and T. D. Fletcher, "Clogging of stormwater gravel infiltration systems and filters: Insights from a laboratory study", *Water Research*, Vol.41, No.7, pp.1433-1440, 2007.
DOI: <http://dx.doi.org/10.1016/j.watres.2006.12.040>
- [2] J.-H. Kim, J.-H. Yang and Y.-S. Lee, "A Study on Process Optimization for CSOs Application of Horizontal Flow Filtration Technology", *Journal of the Korea Academia-Industrial cooperation Society*, Vol.19, No.2, pp.56-63, 2018.
DOI: <https://doi.org/10.5762/KAIS.2018.19.2.56>
- [3] Y. Wang, J. Chen and F. Larachi, "Modelling and simulation of trickle-bed reactors using computational fluid dynamics: A state-of-the-art review", *The Canadian Journal of Chemical Engineering*, Vol.91, No.1, pp.136-180, 2013.
DOI: <https://doi.org/10.1002/cjce.20702>
- [4] G. F. Hua, L. Li, Y. Q. Zhao, W. Zhu and J. Q. Shen, "An integrated model of substrate clogging in vertical flow constructed wetlands", *Journal of Environmental Management*, Vol.119, pp.67-75, 2013.
DOI: <https://doi.org/10.1016/j.jenvman.2013.01.023>
- [5] X. Du, Z. Wang and X. Ye, "Potential Clogging and Dissolution Effects During Artificial Recharge of Groundwater Using Potable Water", *Water Resources Management*, Vol.27, No.10, pp.3573-3583, 2013.
DOI: <https://doi.org/10.1007/s11269-013-0365-5>
- [6] H. S. Kandra, A. Deletic and D. McCarthy, "Assessment of Impact of Filter Design Variables on Clogging in Stormwater Filters", *Water Resources Management*, Vol.28, No.7, pp.1873-1885, 2014.
DOI: <https://doi.org/10.1007/s11269-014-0573-7>
- [7] H. S. Kandra, D. McCarthy, T. D. Fletcher and A. Deletic, "Assessment of clogging phenomena in granular filter media used for stormwater treatment", *Journal of Hydrology*, Vol.512, pp.518-527, 2014.
DOI: <https://doi.org/10.1016/j.jhydrol.2014.03.009>
- [8] X. Du, Y. Fang, Z. Wang, J. Hou and X. Ye, "The Prediction Methods for Potential Suspended Solids Clogging Types during Managed Aquifer Recharge", *Water*, Vol.6, No.4, pp.961-975, 2014.
DOI: <https://doi.org/10.3390/w6040961>
- [9] E. Q. Segismundo, L.-H. Kim, S.-M. Jeong and B.-S. Lee, "A Laboratory Study on the Filtration and Clogging of the Sand-Bottom Ash Mixture for Stormwater Infiltration Filter Media", *Water*, Vol.9, No.1, 32, 2017.
DOI: <https://doi.org/10.3390/w9010032>
- [10] B. Lee, L. Kim and B. Goo, "Clogging characteristics of stormwater infiltration system according to filter media conditions", *Journal of the Korean Society of Hazard Mitigation*, Vol.18, No.3, pp.391-398, 2018.
DOI: <https://doi.org/10.9798/KOSHAM.2018.18.3.391>
- [11] R. Blazejewski and S. Murat-Blazejewska, "Soil clogging phenomena in constructed wetlands with subsurface flow", *Water Science and Technology*, Vol.35, No.5, pp.183-188, 1997.
DOI: <https://doi.org/10.2166/wst.1997.0193>
- [12] B. S. Lee, L. H. Kim, K. H. Lee, P. G. Jeon, and E. Segismundo, "Modeling of Suspended Solid Clogging of Porous Media in Urban Stormwater Infiltration Facility", *Journal of Korean Society of Hazard Mitigation*, Vol.14, No.6, pp.427-437, 2014.
DOI: <http://dx.doi.org/10.9798/kosham.2014.14.6.427>
- [13] H. Wu, W.-Z. Fang, Q. Kang, W.-Q. Tao and R. Qiao, "Predicting Effective Diffusivity of Porous Media from Images by Deep Learning", *Scientific Reports*, Vol.9, No.1, pp.20387, 2019.
DOI: <http://dx.doi.org/10.1038/s41598-019-56309-x>

- [14] B.-G. Hwang, "Evaluation of LSTM Model for Inflow Prediction of Lake Sapgye", *Journal of the Korea Academia-Industrial cooperation Society*, Vol.22, No.4, pp.287-294, 2021.
DOI: <https://doi.org/10.5762/kais.2021.22.4.287>
- [15] A. W. Z. Chew and A. W.-K. Law, "Feature engineering using homogenization theory with multiscale perturbation analysis for supervised model-based learning of physical clogging condition in seepage filters", *Journal of Computational Science*, Vol.32, pp.21-35, 2019.
DOI: <https://doi.org/10.1016/j.jocs.2019.02.003>
- [16] B. Meade, H. Khorshidi, H. Kandra and A. Barton, "Regression modelling for prediction of clogging in non-vegetated stormwater filters", In *10th International Conference on Water Sensitive Urban Design: Creating water sensitive communities* (WSUD 2018 & Hydropolis 2018), pp.233-240, January 2018.
https://www.researchgate.net/publication/323247339_REGRESSION_MODELING_FOR_PREDICTION_OF_CLOGGING_IN_NON-VEGETATED_STORMWATER_FILTERS
- [17] J. Lin, H. Kandra, T. A. Choudhury and A. Barton, "Prediction of Clogging in Stormwater Filters Using Artificial Neural Network", In *2018 IEEE 27th International Symposium on Industrial Electronics (ISIE)*, pp.771-776, June 2018.
DOI: <https://doi.org/10.1109/isie.2018.8433758>
- [18] M. A. Shahin, "Load-settlement modeling of axially loaded steel driven piles using CPT-based recurrent neural networks", *Soils and Foundations*, Vol.54, No.3, pp.515-522, 2014.
DOI: <https://doi.org/10.1016/j.sandf.2014.04.015>
- [19] F. Chollet, *Deep Learning with Python*, p. 384, Manning Publications, 2017.
- [20] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, et al., *TensorFlow: Large-scale machine learning on heterogeneous systems* Software available from tensorflow.org, 2015.
URL: <https://www.tensorflow.org/>
- [21] F. Chollet, et al., *Keras*, 2015.
URL: <https://keras.io>
- [22] A. LeNail, "NN-SVG: Publication-ready neural network architecture schematics", *Journal of Open Source Software*, No. 4 Vol. 33, 747, 2019.
DOI: <https://doi.org/10.21105/joss.00747>
- [23] C. Cochrane, Time Series Nested Cross-Validation [Internet]. In *Towards Data Science*, [cited 2021 May 20], Available From: https://medium.com/@ccochrane_17940 (accessed May 20, 2021)
- [24] S. Varma and R. Simon, "Bias in error estimation when using cross-validation for model selection", *BMC Bioinformatics*, Vol.7, No.1, 91, 2006.
DOI: <https://doi.org/10.1186/1471-2105-7-91>
- [25] M. A. Shahin, "Load-settlement modeling of axially loaded steel driven piles using CPT-based recurrent neural networks", *Soils and Foundations*, Vol.54, No.3, pp.515-522, 2014.
DOI: <https://doi.org/10.1016/j.sandf.2014.04.015>

이 병 식(Byung-Sik Lee)

[정회원]



- 1987년 8월 : 고려대학교 대학원 토목공학과 (공학석사)
- 1996년 5월 : 텍사스주립대학교 대학원 토목공학과 (공학박사)
- 1996년 8월 ~ 현재 : 공주대학교 사회환경공학과 교수

<관심분야>

지반공학, 지반환경, 인공지능