



심층 신경망 기법을 통한 부유사 이동 모델링

Modeling of Suspended Sediment Transport Using Deep Neural Networks

봉태호* · 손영환**,† · 김규선*** · 김동근****

Bong, Tae-Ho · Son, Young-Hwan · Kim, Kyu-Sun · Kim, Dong-Geun

Abstract

Land reclamation, coastal construction, coastline extension and port construction, all of which involve dredging, are increasingly required to meet the growing economic and societal demands in the coastal zone. During the land reclamation, a portion of landfills are lost from the desired location due to a variety of causes, and therefore prediction of sediment transport is very important for economical and efficient land reclamation management. In this study, laboratory disposal tests were performed using an open channel, and suspended sediment transport was analyzed according to flow velocity and grain size. The relationships between the average and standard deviation of the deposition distance and the flow velocity were almost linear, and the relationships between the average and standard deviation of deposition distance and the grain size were found to have high non-linearity in the form of power law. The deposition distribution of sediments was demonstrated to have log-normal distributions regardless of the flow velocity. Based on the experimental results, modeling of suspended sediment transport was performed using deep neural network, one of deep learning techniques, and the deposition distribution was reproduced through log-normal distribution.

Keywords: Suspended sediment; grain size; flow velocity; open-channel; deep neural network

1. 서 론

급속한 산업의 발달 및 인구의 증가로 산업 및 주거용지, 공항, 항만 등의 수요가 늘어남에 따라 한정된 국토의 효율적인 활용과 부족한 용지의 확보를 위한 매립공사가 활발하게 이루어지고 있으며, 개방수역 (Open-water)에서 퇴적물 투기 (disposal)는 세계적으로 해안지역과 관련된 많은 분야에서 다양한 목적으로 사용되고 있다 (Gensheimer et al., 2013). 매립토는 직접적으로 파이프라인을 통한 방출 (pipeline discharge) 이나 기계적 배치 (mechanical placement) 또는 바지선 (barge) 이나 호퍼 (hopper)를 통한 투기 등을 통하여 이루어지며, 이러한 작업은 적절한 관리 또는 통제를 필요로 한다 (USACE and USEPA, 2004). 해안지역에서 부지 조성을 위한 매립은 많은 양의 매립토를 필요로 하며 효율적인 매립을 위해서는 매립토

를 목표한 위치에 정합한 수량을 매립할 수 있어야 한다. 하지만 준설 매립을 실시할 때 투기된 토사 중 일부는 목적인 장소에 퇴적되지 않고 다양한 원인으로 인하여 유실된다. 또한, 준설이나 매립작업에 따른 부유사의 거동은 환경영향평가를 위해서도 중요한 요소이며 이에 대한 많은 연구들이 수행되어왔다 (Bolam et al., 2006; Fredette and French, 2004; Okada et al., 2009). 따라서 효율적이고 경제적인 매립계획 및 관리를 위하여 매립토의 수중거동을 예측하는 것은 매우 중요하다. 매립토의 수중 투기 시 토립자들은 입자구름 (particle cloud)을 형성하며 이에 대한 확산 및 관련된 동역학적 거동에 대한 많은 연구들이 수행되었다. U.S. Army Corps of Engineers (USACE)에 의하여 수행된 준설물질 연구프로그램 (dredged material research program, DMRP)에서 Koh and Chang (1973)는 바지선이나 호퍼를 통하여 순간적으로 투기되는 준설토에 대한 단기 거동을 예측하기 위한 수치모델을 개발하였다. 이 모델은 이후 US Army Engineer waterways Experiment station (WES)에 의하여 몇 년의 기간 동안 수정되었으며 투기 작업에 따른 환경영향평가에 활용되었다. (Bokuniewicz et al., 1978; Johnson and Holliday, 1978; Trawle and Johnson, 1986). 또한, 유속이 없는 정체된 물에서 토립자의 침강 시 입자구름의 혼합과정을 예측하기 위하여 다양한 실험적 연구들이 수행되었으며 (Bühler and Papantoniou, 1999; Bush et al., 2003; Noh, 2000; Gu and Huang, 2008), Bhuiyan et al. (2010)은 유속이

* Post-doctoral Scholar, Oregon State University, 101 Kearney Hall, Corvallis, OR, 97331

** Department of Rural Systems Engineering and Research Institute for Agriculture and Life Sciences, Seoul National University

*** Samsung C&T Engineering & Construction Group, Senior Researcher

**** Department of Rural Systems Engineering, Seoul National University

† **Corresponding author**

Tel.: +82-2-880-4585 Fax: +82-2-873-2087

E-mail: syh86@snu.ac.kr

Received: April 12, 2018

Revised: June 12, 2018

Accepted: June 12, 2018

있는 물에서 조립토의 연속적인 투기에 따른 퇴적물 더미의 형성을 조사하였다. Zhao et al. (2014)는 Rahimpour and Wilkinson (1992)에 의해 정의된 입자구름의 수와 입자의 질량과 크기에 따른 형성과정의 관계를 체계적으로 조사하였다. 그러나 대부분의 기존 연구는 정체된 물에서 퇴적물의 거동에 초점이 맞춰져 있으며 유속은 토립자의 거동에 큰 영향을 미침에도 불구하고 이에 대한 영향은 체계적으로 고려되지 못하였다. 또한, 수치 모델의 일반적인 결함은 모델의 수정 및 검증을 위한 실험 데이터가 부족하다는 점이며 (Johnson et al., 1992), 정확한 추정을 얻기 위해서는 많은 입력변수가 요구된다는 점이다. Bong et al. (2016)은 준설토의 매립 시 부유사 (suspended sediment)의 수중거동을 분석하고자 대형수로실험을 실시하였으며, 체가름을 통한 4가지 입경과 4가지 유속 (0.1, 0.3, 0.5, 0.67 m/s)에 따른 이동 특성을 파악하고 유속 및 입자의 크기에 따른 상관관계를 규명한 바 있다.

본 연구에서는 Bong et al. (2016)에 의하여 수행된 결과를 바탕으로 부유사의 이동거리를 예측하고자 딥러닝 (deep learning) 기법 중 하나인 심층 신경망 (deep neural networks)을 적용하여 부유사 이동에 대한 예측 모델링을 수행하였다. 또한, 토립자의 퇴적분포를 정량적으로 고려하기 위하여 분포형상을 분석하고 대수정규분포 (log-normal distribution)를 활용한 모델링을 수행하였으며, 제안된 예측모델을 통한 부유사의 퇴적분포를 다양한 입경 및 유속에 대한 수로시험 결과와 비교·분석하였다.

II. 재료 및 방법

1. 재료

시료의 입경에 따른 수중거동 특성을 분석하기 위하여 화강풍화토의 체분석을 통한 입경별 분류를 수행하였다. 초기 시료는 체눈 사이즈가 9.5 mm인 체를 이용하여 최대 입경을 조절하였으며, 이후 입자들 간의 분리가 명확하도록 수세법을 이용한 체가름 시험을 수행하였다. 사용된 체의 종류 및 이에 따른 평균 입경은 Table 1과 같으며, 비중시험 (KS F 2308)을 통하여 각 체별 잔류시료의 비중을 확인하였다.

Table 1 Grain size range according to the sieve and specific gravity

Sieves No.	Grain size range (mm)	Average grain size (mm)	Specific gravity
4	4.75~9.5	7.125	2.60
10	2~4.75	3.375	2.60
20	0.85~2	1.425	2.60
40	0.425~0.85	0.638	2.61

입자의 이동은 입경뿐만 아니라 입자의 형상에도 영향을 받는다. 따라서 입자 형상에 대한 특성을 파악하고자 디지털 이미지 프로세싱 (digital image processing)을 수행하였으며 흙입자의 원마도 (roundness)와 종횡비 (aspect ratio)를 측정하였다. 원마도는 $4\pi A/P^2$ 에 의하여 산정할 수 있으며, 여기서 A는 입자의 면적, P는 그 둘레이다. 종횡비는 최대 Feret 직경과 최소 Feret 직경의 비율이다. 이에 따른 평균 원마도는 0.7로 상대적으로 둥글며, 입자의 형상은 종횡비 2.1로 타원형으로 나타났다.

2. 시험장비

본 연구에 사용된 모형수로로는 철제 프레임으로 제작되었으며, 수로의 측면은 유리로 제작하여 외부에서 수로 내 거동을 쉽게 관찰할 수 있도록 하였다. 전체적인 수로의 제원은 길이 960 cm, 너비 30 cm, 높이 45 cm이다. 수로 내 물은 펌프를 통하여 공급되며 유속은 펌프의 용량 및 월류부의 높이 조절을 통하여 이루어진다. 본 연구에서는 두 개의 펌프를 통하여 총 3.7 m³/min의 유량을 조절할 수 있도록 하였다. 수로 내 물의 흐름 생성은 월류뿐만 아니라 월류부 바닥부에 펌프와 연결된 관을 통해 물을 강제적으로 흡입하여 물의 흐름을 재현하도록 함으로써 수심이 깊은 곳에서도 물의 흐름이 원활하게 이루어질 수 있도록 하고 물의 흐름이 월류벽에 부딪혀 형성되는 난류의 영향도 최소화하여 안정적인 등류를 생성할 수 있도록 하였다. 수로 내 물순환 모식도는 Fig. 1과 같다.




Fig. 1 Water circulation in open-channel (Bong et al., 2016)

수로 내 유속은 초음파 유속계 (OTT MF pro)를 설치하여 측정하였으며, 유속 측정은 실험구간 시작부에서 약 100 cm 정도 떨어진 위치에서 실시하였다. 시험장비의 제원에 대한 보다 자세한 설명 및 시험방법은 Bong et al. (2016)에 서술되어 있다.




Fig. 2 Shallow and deep forward neural networks

3. Deep Neural Network

인공신경망 (artificial neural network, ANN)이란 인간의 뇌 신경망을 모델링하여 구성된 시스템으로 뇌를 구성하고 있는 뉴런과 그들 상호간의 연결 관계를 모사하여 뇌의 정보처리 방식과 유사한 네트워크 형태로 정보를 처리하는 기법이다. Rosenblatt (1958)는 인공뉴런의 개념을 기반으로 퍼셉트론 (perceptron)이라고 불리는 뉴런의 입력 값에 곱해지는 가중치를 학습하는 인공신경망 모델을 처음 제안하였다. 초기 모형은 학습 대상이 선형적인 모형으로 구분되는 경우에만 학습이 가능하며 주어진 신경망의 크기에 따라 요구되는 계산량이 급격하게 증가한다는 단점이 존재하였다. 하지만 이러한 단점은 Werbos (1974)에 의하여 개발된 오차역전파 (back propagation) 알고리즘과 비선형 활성화 함수를 활용한 다층 신경망을 통해서 해결할 수 있었다. Fig. 2는 은닉층 수에 따른 인공신경망의 분류 및 구조를 나타낸다. 일반적으로 입력층 (input layer)과 출력층 (output layer) 사이에 하나의 은닉층 (hidden layer)이 존재하는 얇은 (shallow)신경망이라 하며, 2개 이상의 은닉층을 가진 경우를 심층 (깊은)신경망 (deep neural network, DNN)이라한다.

기존 다층 신경망과 심층 신경망의 구조는 동일하며 심층 신경망에서는 기존 다층 신경망이 갖는 단점들을 보완하기 위한 다양한 최적화 방법이 사용되었다. 기존 다층 신경망의

한계점으로는 신경망의 깊이가 깊어지고 모형이 복잡해질수록 과적합 (overfitting)의 문제가 발생한다는 점이다. 과적합은 학습 데이터에 대한 예측은 정확하지만 학습 과정에 포함되지 않은 새로운 데이터에 대한 예측의 정확도는 낮게 나타나는 것으로 학습 데이터에 대해서만 과도하게 최적화되는 문제이다. Hinton et al. (2006)은 가중치의 초기값 설정방법인 제약볼츠만머신 (restricted boltzman machine, RBM)을 통하여 적절한 초기화를 수행할 경우, 과적합과 오차역전파의 오동작을 감소시킬 수 있음을 밝혔으며 이에 따라 심층 구조를 가진 경우도 적절한 학습이 가능한 것으로 나타났다. 또한, Glorot and Bengio (2010)은 RBM 보다 성능이 뛰어나면서도 간단한 초기값 설정 방법을 제안하였다. 기존 오차역전파 알고리즘의 또 다른 한계는 각 계층 사이에 활성화 함수가 반복적으로 사용됨에 따라 가중치를 수정하기 위한 경사도 계산이 누적되는 학습과정에서 경사도가 소실 (vanishing gradient) 되는 문제가 발생한다는 점이다. Fig. 3은 인공신경망에 있어서 일반적으로 사용되는 활성화 함수 (activation function)의 종류를 나타낸다.

기존 인공신경망에서 사용되는 활성화함수는 시그모이드 (sigmoid)함수로 미분값이 1보다 작으므로 층을 거칠수록 경사도 소실문제가 발생하게 되며 가중치의 수정이 어려워져 최적화 성능이 나빠질 수 있다 (Hochreiter et al. 2001). 이를




Fig. 3 Activation functions in neural networks

보완하기 위해 시그모이드 함수의 범위를 -1에서 1로 확장한 하이퍼볼릭 탄젠트 (tanh)가 제안되었지만 여전히 경사도 소실문제가 존재하였다. 이를 개선하기 위하여 Nair and Hinton (2010)은 ReLU (rectified linear units) 함수를 제안하였으며 이는 x 가 0보다 작을 때는 모든 값을 0으로 처리하고, 0보다 큰 값은 x 를 그대로 사용하는 방법으로 기존 시그모이드가 갖는 단점을 보완할 수 있으며 과적합 문제를 완화시키는 데에도 효과가 있음이 알려져 있어 현재 가장 일반적으로 사용되는 활성화 함수이다. 이에 따라 본 연구에서는 Glorot 초기화 방법과 ReLU 함수를 활성화 함수로 적용하였으며 손실함수로는 평균절대값오차 (mean absolute error, MAE)를 사용하여 학습을 수행하였다.

III. 결과 및 고찰

1. 퇴적분포

각 체의 잔류시료는 균질하다고 가정하였으나 시료의 분리 에 사용된 체크기의 간격에 따라 다양한 크기의 입경이 혼합

되어 있으며 입자의 형상 또한 퇴적거리에 영향을 미치게 된다. 이에 따라 입경 및 유속에 따른 퇴적은 일정한 분포 형태를 나타내었다. 퇴적분포는 종모양의 형태를 갖는 분포로 나타났다으며 입경에 관계없이 유속이 증가함에 따라 더 넓은 분포를 갖는 것으로 나타났다. 또한, 입경이 작을수록 퇴적분포가 더 넓게 형성되는 것으로 나타났으며 퇴적분포의 형태는 좌우대칭이 아닌 오른쪽이 좀 더 긴 형태로 나타남에 따라 대수정규분포의 형태와 유사함을 확인할 수 있었다. 대수정규분포는 연속확률분포이지만 실험결과는 포집상자를 통하여 퇴적량이 산출되는 이산형 자료이다. 이에 따라 대수정규분포를 통하여 퇴적거리에 대한 구간별 단위누적중량을 산정하였으며 이를 Fig. 4에 나타내었다.

검은 점선은 실험결과에 따른 토립자 이동거리에 대한 평균과 표준편차를 갖는 대수정규분포를 나타내며, 각 입경 및 유속에 따른 퇴적분포와 매우 잘 일치하는 것으로 나타났다. 따라서 토립자의 퇴적분포는 대수정규분포를 통하여 효과적으로 표현할 수 있을 것으로 판단되며, 이는 기존 Li and Shen (1975)과 Cuthbertson and Ervine (2007)에 의해 규명된 난류에서의 퇴적물 분포와도 일치하는 것으로 나타났다.

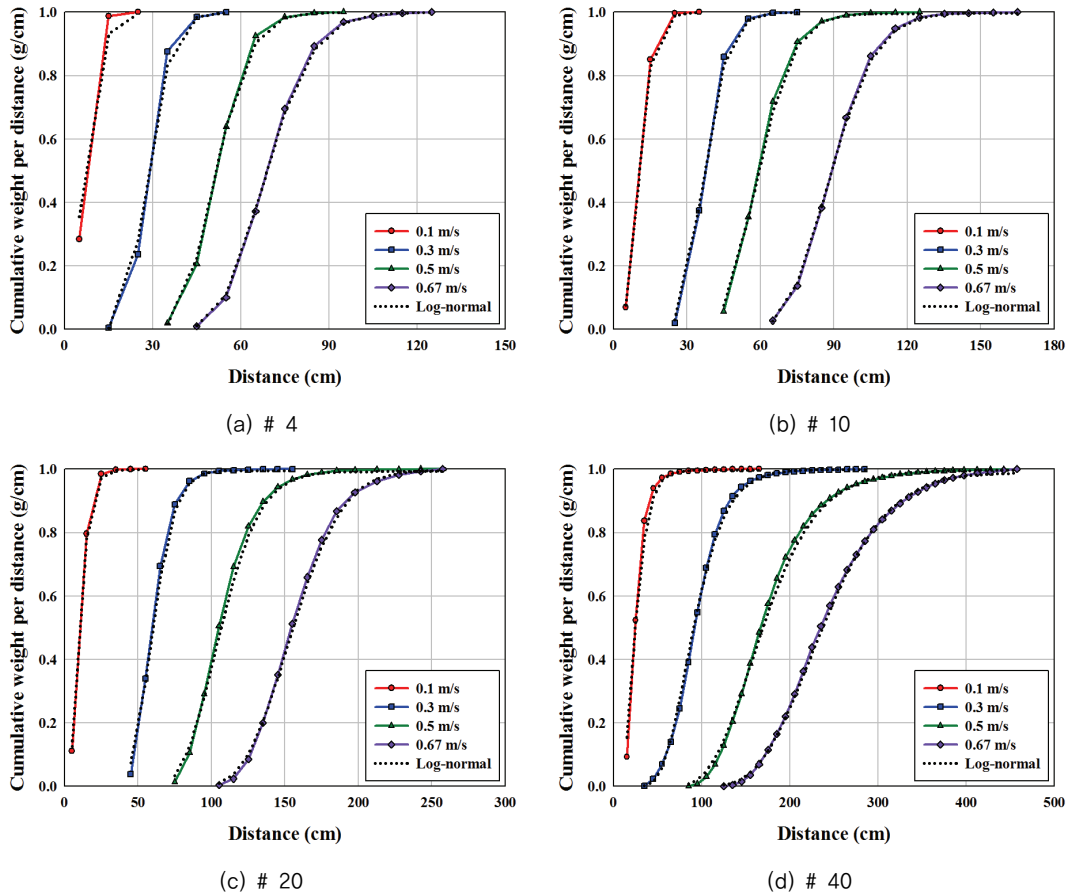


Fig. 4 Cumulative distribution of weight per distance

2. 퇴적거리의 통계적 특성

각 체의 잔류시료에 대한 퇴적거리는 대수정규분포의 형태를 가짐에 따라서 퇴적거리의 평균 (d_{Avg}) 및 표준편차 (d_{STD})는 다음 식과 같이 퇴적거리별 중량을 고려한 가중평균을 통하여 산정하였다.


$$d_{Avg} = \frac{\sum_{i=1}^n x_i \times w_i}{\sum_{i=1}^n w_i} \quad (1a)$$

$$d_{STD} = \sqrt{\frac{\sum_{i=1}^n (x_i - d_{Avg})^2 \times w_i}{\sum_{i=1}^n w_i}} \quad (1b)$$


여기서, x_i 와 w_i 는 각각 i 번째 포집상자에 대한 퇴적거리 (cm)와 퇴적중량 (g)을 나타낸다. 실험결과에 의한 입경 및 유속에 따른 퇴적거리의 평균 및 표준편차는 Table 2에 정리하였으며, 유속에 따른 퇴적거리의 평균 및 표준편차의 변화는 Fig. 5와 같다.

Table 2 Average and standard deviation of deposition distance according to the grain size and the flow velocity

Grain size (mm)	Flow velocity (m/s)	Deposition distance (cm)	
		Average	Standard deviation
7.125	0.1	12.30	4.72
	0.3	33.99	6.38
	0.5	57.31	9.41
	0.67	74.76	12.68
3.375	0.1	15.83	4.70
	0.3	42.69	7.70
	0.5	67.08	11.56
	0.67	94.99	14.64
1.425	0.1	16.11	5.98
	0.3	66.03	12.22
	0.5	113.09	21.50
	0.67	162.57	27.04
0.638	0.1	31.76	12.71
	0.3	99.96	30.53
	0.5	180.81	51.45
	0.67	248.77	61.34




(a) average




(b) standard deviation

Fig. 5 Average and standard deviation of deposition distance for the flow velocity



(a) average



(b) standard deviation

Fig. 6 Average and standard deviation of deposition distance for the grain size

퇴적거리의 평균 및 표준편차는 유속이 증가함에 따라 0.67 m/s까지 거의 선형적으로 증가하는 것으로 나타났으며 2차 회귀식을 사용할 경우 결정계수 (R^2)는 거의 1.0으로 정확하게 예측 가능한 것으로 나타났다. Fig. 6은 입경에 따른 퇴적거리의 평균 및 표준편차의 변화를 나타낸다.

입경에 따른 퇴적거리의 평균과 표준편차는 입경이 증가함에 따라 급격하게 감소하였으며 거둬제곱의 형태로 감소함을 알 수 있다. 하지만 입경에 대한 퇴적거리의 평균과 표준편차의 관계는 비선형성이 높게 나타남에 따라 거둬제곱 회귀식을 사용할 경우 결정계수는 약 0.94로 약간의 오차가 발생할 수 있는 것으로 나타났다.

3. DNN 기반 예측 모델링

유속에 따른 퇴적거리의 평균과 표준편차는 거의 선형적으로 나타났지만 입경에 따른 영향은 비선형성이 매우 큰 것으로 나타났다. 이에 따라 비선형성을 고려한 효율적인 예측 모델링을 수행하기 위하여 딥러닝 기법 중 하나인 심층 신경망을 적용하였다. 부유사의 퇴적거리는 입경 및 유속뿐만 아니라 흙의 비중이나 물의 온도 등 다양한 조건에 영향을 받는다. 하지만 토립자 이동에 대한 물의 점성계수 영향은 수온이 5°C~30°C 범위일 때에는 매우 작으며 (Gibbs et al., 1971), 모래나 실트, 점토와 같은 일반적인 흙의 비중은 그 값이 큰 차이를 나타내지 않으며 비중보다는 입경의 크기에 따른 중량에 의한 영향이 지배적으로 작용하므로 이에 대한 영향은 무시하였다. 따라서 본 연구에서는 효율적이고 간편한 모델링을 위하여 입경과 유속만을 고려하여 모델링을 수행하였으며 다음 사항을 가정하였다. (a) 유속이 0 m/s인 경우 퇴적거리의 평균 및 표준편차는 0 cm이다. (b) 물의 흐름은 층류로 모든 깊이에 대한 유속은 동일하다. (c) 시료의 침강속도는 중단속도에 도달하여 일정한 것으로 간주한다. 이에 따라 총 20개의 자료를 활용한 학습 (training)을 수행하였으며 최적의 은닉층수와 노드수를 결정하기 위하여 은닉층의 개수는 2개부터 4개까지 설정하였으며 은닉층의 노드수를 5개씩 증가시켜가며 학습을 수행하고 예측결과에 대한 MAE를 최소화하는 조합을 최종적인 학습모델의 조건으로 선정하였다. 학습결과, 최소 MAE는 은닉층이 3개인 경우 은닉층이 4개인 경우와 큰 차이를 나타내지 않았으며, 노드수는 50개 이상일 경우 학습세대 (epochs)에 따른 예측성능이 비교적 안정적으로 나타났다. Fig. 7은 퇴적거리의 평균과 표준편차에 대한 실험결과와 예측모델에 의한 결과의 비교를 나타낸다.

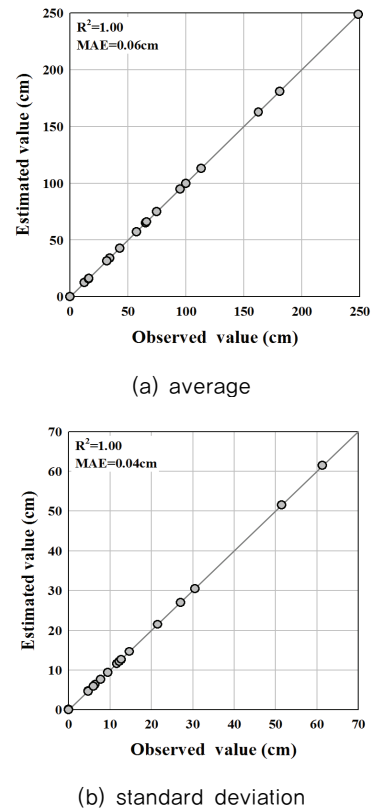


Fig. 7 Comparison of observed and estimated results for training data

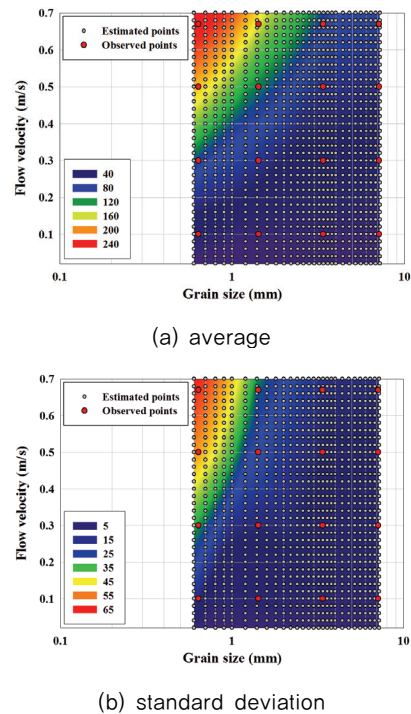


Fig. 8 Contour maps for the average and standard deviation of deposition distance

심층 신경망 기반 모델링에 의한 예측결과와 MAE는 퇴적거리에 대한 평균과 표준편차에 대하여 각각 0.06 cm와 0.04 cm로 매우 정확한 예측이 가능한 것으로 나타났다. 비록 학습 데이터에 대한 예측모델의 오차는 매우 작게 나타날 수 있지만 모형의 복잡도가 큰 경우에는 과적합에 의한 모형왜곡 (bias)이 발생할 수 있다. 이에 따라 과적합의 발생 여부 및 유속과 입경에 따른 영향을 파악하기 위하여 유속과 입경에 대한 조밀한 범위의 입력값을 생성한 뒤 학습된 모델을 통하여 유속 및 입경에 따른 퇴적거리의 평균과 표준편차를 산정하였으며 이에 대한 등고선을 Fig. 8에 나타내었다.

등고선 위의 회색원은 예측을 위해 임의로 생성된 입력값의 위치를 나타내며 빨간원은 학습에 사용된 입력값의 위치이다. 등고선은 Fig. 5와 6에서 확인되었던 입경과 유속에 대한 비선형성이 적절하게 고려되었음을 확인할 수 있었으며, 과적합에 의한 특이점은 발생하지 않는 것으로 나타났다.

본 연구에서는 토립자의 퇴적분포는 대수정규분포를 갖는 것으로 모델링 되었다. 앞에서 언급한 바와 같이 대수정규분포는 연속확률분포이므로 구간 [a, b]에 대한 퇴적율은 다음 식과 같이 대수정규분포의 확률밀도함수의 구간별 적분을 통하여 산정할 수 있다.

$$\int_a^b f(x)dx = \int_a^b \frac{1}{x \sqrt{2\pi} \sigma_{\ln x}} \exp\left[-\frac{(\ln x - \mu_{\ln x})^2}{2\sigma_{\ln x}^2}\right] dx \quad (2)$$

여기서 x 는 퇴적거리이며, $\mu_{\ln x}$ 와 $\sigma_{\ln x}$ 는 다음 식을 통하여 산정되는 $\ln(x)$ 의 평균과 표준편차이다.

$$\mu_{\ln x} = \ln(\mu_x) - \frac{\sigma_{\ln x}^2}{2} \quad (3a)$$

$$\sigma_{\ln x} = \sqrt{\ln\left[\left(\frac{\sigma_x}{\mu_x}\right)^2 + 1\right]} \quad (3b)$$

확률밀도함수에 대한 구간별 적분값은 대수정규분포의 누적확률함수 (F)를 통하여 다음과 같이 간편하게 산정할 수 있다.

$$\int_a^b f(x)dx = F(b) - F(a) \quad (4)$$

최종적으로 심층 신경망을 통하여 퇴적거리의 평균과 표준편차를 예측한 뒤, 식 (2)~(4)을 통한 대수정규분포를 따르는 퇴적분포를 고려하여 부유사의 이동을 예측할 수 있다. 본 연구에서 제안된 모델을 통한 예측결과와 실험을 통한 입경 및 유속별 퇴적결과와의 비교는 Fig. 9와 같다.

예측모델을 통한 토립자의 퇴적분포는 수로시험을 통한 다양한 입경 및 유속에 대한 퇴적분포와 매우 잘 일치하는 것으로 나타났다. 이에 따라 제안된 예측모델을 통하여 효과적으로 부유사 이동예측이 가능할 것으로 판단된다.

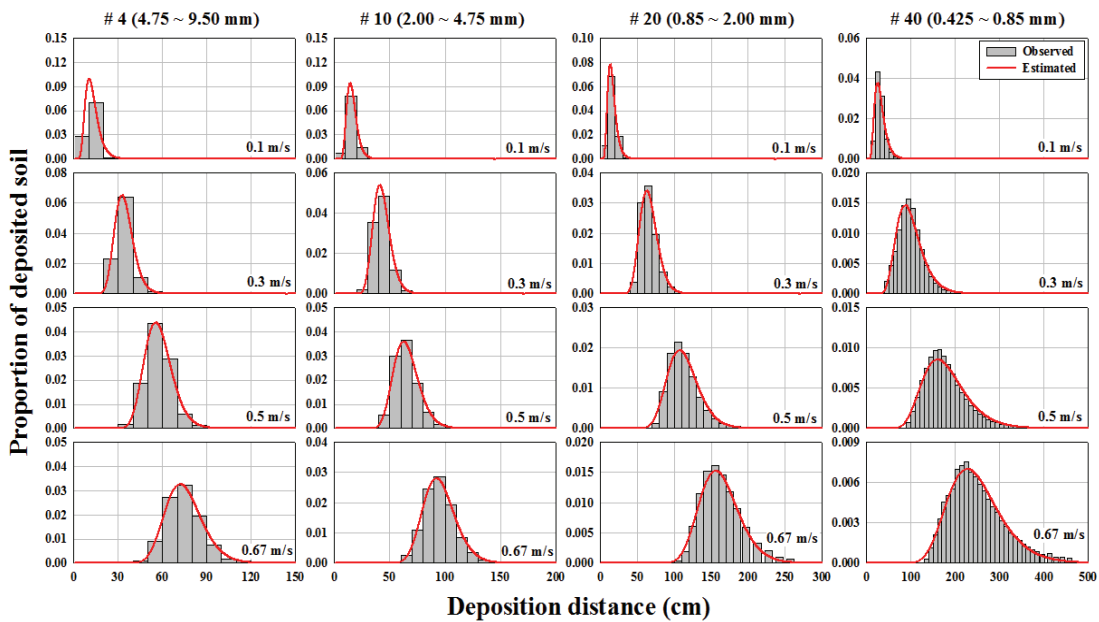


Fig. 9 Comparison of observed and estimated deposition distribution for each size of sieved particles

IV. 요약 및 결론

본 연구에서는 유속이 있는 수중에서 부유사의 거동특성을 분석하기 위하여 실내수로실험을 실시하였으며, 부유사의 이동에 대한 입경 및 유속의 영향을 규명하였다. 또한, 실험결과를 바탕으로 심층 신경망 기법을 적용하여 부유사의 거동을 예측하기 위한 모델링을 수행하였으며 이에 대한 결과를 요약하면 다음과 같다.

1. 각 체에 대한 잔류시료는 비교적 균일한 입경이라 하더라도 체 사이즈 간격에 따라 다양한 입경이 혼합되어 있으며 입자의 형상, 비중 등의 영향으로 대수정규분포 형태의 퇴적분포를 갖는 것으로 나타났다.
2. 퇴적거리의 평균과 표준편차에 대한 유속의 영향은 입경에 관계없이 거의 선형적인 것으로 나타났으며, 입경의 영향은 유속에 관계없이 거둬제공형태의 감소곡선을 나타내었다.
3. 부유사의 거동을 예측하기 위하여 유속이 0 m/s 경우를 포함한 총 20개의 실험데이터를 구축하고 심층 신경망 기법을 통한 학습을 수행하였다. 최적의 학습조건을 찾기 위하여 다양한 은닉층의 수 및 노드수를 고려하였으며 평균절대값오차가 가장 작은 조합을 학습조건으로 선정한 뒤 예측모델을 구축하였다.
4. 심층 신경망 기반 모델링에 의한 평균절대값오차는 퇴적 거리에 대한 평균과 표준편차에 대하여 각각 0.06 cm와 0.04 cm로 매우 정확한 예측이 가능한 것으로 나타났다. 또한, 학습에 활용된 입력값 범위에서 과적합은 발생하지 않았으며 입경과 유속에 따른 영향을 적절하게 반영할 수 있었다.
5. 예측모델을 통한 부유사의 퇴적분포는 다양한 입경 및 유속에 대한 수로시험결과와 매우 잘 일치하는 것으로 나타났으며, 이에 따라 제안된 예측모델은 토립자의 입경 및 유속을 고려하여 효과적으로 부유사 이동예측이 가능할 것으로 판단된다.

REFERENCES

1. Bhuiyan, F., N. Rajaratnam, and D. Z. Zhu, 2010. An experimental study of mounds formed by dumping coarse sediment in channel flow. *Journal of Hydraulic Research* 48(3): 283-291. doi:10.1080/00221681003726205.
2. Bokuniewicz, H. J., J. Gebert, R. B. Gordon, J. L. Higgins, P. Kaminsky, C. C. Pilbeam, M. Reed, and C. Tuttle, 1978.

- Field study of the mechanics of the placement of dredged material at open-water sites. Rep. No. D-78-7, US Army Engineer Waterways Experiment Station, Vicksburg, MS.
3. Bolam, S. G., H. L. Rees, P. Somerfield, R. Smith, K. R. Clarke, R. M. Warwick, M. Atkins, and E. Garnacho, 2006. Ecological consequences of dredged material disposal in the marine environment: a holistic assessment of activities around the England and Wales coastline. *Marine Pollution Bulletin* 52(4): 415-426. doi:10.1016/j.marpolbul.2005.09.028.
4. Bong, T. H., Y. H. Son, K. S. Kim, J. S. Park, and D. G. Kim, 2016. Transport and deposition characteristics of coarse grained soil according to the flow velocity and grain size. *Journal of the Korean Society of Agricultural Engineers* 58(1): 11-17 (in Korean). doi:10.5389/KSAE.2016.58.1.011.
5. Bühler, J., and D. A. Papantoniou, 1999. Barge dumping of rubble in deep water, *Environmental hydraulics*, 193-198. Balkema, Rotterdam, Netherlands.
6. Bush, J. W. M., B. A. Thurber, and F. Blanchette, 2003. Particle clouds in homogeneous and stratified environments. *Journal of Fluid Mechanics* 489: 29-54. doi:10.1017/S0022112003005160.
7. Cuthbertson, A. J., and D. A. Ervine, 2007. Experimental study of fine sand particle settling in turbulent open channel flows over rough porous beds. *Journal of Hydraulic Engineering* 133(8): 905-916. doi:10.1061/(ASCE)0733-9429(2007)133:8(905).
8. Fredette, T. J., and G. T. French, 2004. Understanding the physical and environmental consequences of dredged material disposal: history in New England and current perspectives. *Marine Pollution Bulletin* 49(1-2): 93-102. doi:10.1016/j.marpolbul.2004.01.014.
9. Gensheimer, R. J., E. E. Adams, and A. W. K. Law, 2013. Dynamics of particle clouds in ambient currents with application to open water sediment disposal. *Journal of Hydraulic Engineering* 139(2): 114-123. doi:10.1061/(ASCE)HY.1943-7900.0000659.
10. Gibbs, R. J., M. D., Matthews, and D. A. Link, 1971. The Relationship between sphere size and settling velocity. *Journal of Sedimentary Research* 41(1): 7-18. doi:10.1306/74D721D0-2B21-11D7-8648000102C1865D.
11. Glorot, X., and Y. Bengio, 2010. Understanding the difficulty of training deep feedforward neural networks. *Proceedings of the 13th International Conference on Artificial Intelligence and Statistics*, 249-256. Sardinia, Italy.

12. Gu, J., J. Huang, and C. W. Li, 2008. Experimental Study on Instantaneous Discharge of Unsorted Particle Cloud in Cross-flow. *Journal of Hydrodynamics* 20(1): 10-16. doi: 10.1016/S1001-6058(08)60021-9.
13. Hinton, G. E., S. Osindero, and Y. W. Teh, 2006. A Fast learning algorithm for deep belief nets. *Neural Computation* 18(7): 1527-1554. doi:10.1162/neco.2006.18.7.1527.
14. Hochreiter S., Y. Bengio, P. Frasconi, and J. Schmidhuber, 2001. Gradient flow in recurrent nets: the difficulty of learning long-term dependencies. *Field Guide to Dynamical Recurrent Neural Networks*. IEEE Press. doi:10.1109/9780470544037.ch14.
15. Johnson, B. H., and B. W. Holliday, 1978. Evaluation and calibration of the Tetra Tech Dredged material disposal models based on field data. Rep. No. D-78-47, US Army Engineer Waterways Experiment Station, Vicksburg, MS.
16. Johnson, B. H., D. N. McComas, and D. C. Mcvanl, 1992. Modeling dredged material disposed in open water. *Proceedings of the Hydraulic Engineering sessions at Water Forum 92*, 1036-1041. Baltimore, Maryland.
17. Koh, R. C. Y., and Y. C. Chang, 1973. Mathematical model for barged ocean disposal of wastes. Environmental protection technology series WPA-660/2-73-029, US Environmental Protection Agency, Washington, DC.
18. Li, R. M., and H. W. Shen, 1975. Solid particle settlement in open-channel flow. *Journal of the Hydraulics Division* 101(7): 917-931.
19. Nair, V., and G. E. Hinton, 2010. Rectified linear units improve restricted boltzmann machines. *Proceedings of the 27th international conference on machine learning*, 807-814. Haifa, Israel.
20. Noh, Y., 2000. Sedimentation of a particle cloud across a density interface. *Fluid Dynamics Research* 27: 129-142. doi:10.1016/S0169-5983(99)00046-5.
21. Okada, T., P. Larcombe, and C. Mason, 2009. Estimating the spatial distribution of dredged material disposed of at sea using particle-size distributions and metal concentrations. *Marine Pollution Bulletin* 58(8): 1164-1177. doi:10.1016/j.marpolbul.2009.03.023.
22. Rahimpour, H., and D. Wilkinson, 1992. Dynamic behaviour of particle clouds. *11th Australasian Fluid Mechanics Conference*, 743-746. Hobart, Australia.
23. Rosenblatt, F., 1958. The Perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review* 65(6): 386-408. doi:10.1037/h0042519.
24. Trawle, M. J., and B. J. Johnson, 1986. Alcatraz Disposal site investigation. miscellaneous paper HL-86-1, US Army Engineer Waterways Experiment Station, Vicksburg, MS.
25. USACE (United States Army Corps of Engineers) and USEPA (United States Environmental Protection Agency), 2004. Evaluating environmental effects of dredged material management alternatives - A Technical Framework. Washington, DC.
26. Werbos, P., 1974. Beyond regression: New tools for prediction and analysis in the behavioral sciences. Ph.D. thesis, Harvard University.
27. Zhao, B., A. W. K. Law, E. E. Adams, and J. W. Er, 2014. Formation of particle clouds. *Journal of Fluid Mechanics* 746: 193-213. doi:10.1017/jfm.2014.121.