

물리와 데이터 분석 모델을 결합한 해안선 변화 모델링 기법

김용민¹ · 윤현수¹ · 민수홍² · 임창빈³ · 이정렬^{3,4} · 강지훈^{5*}

¹연세대학교 산업공학과 / ²한국공학대학교 스마트팩토리융합학과 / ³성균관대학교 건설환경시스템공학과 /
⁴성균관대학교 수자원전문대학원 / ⁵한국공학대학교 경영학부

A Shoreline Change Prediction Technique Combining Physics and Data-driven Model

Yongmin Kim¹ · Hyunsoo Yoon¹ · Su Hong Min² · Changbin Lim³ · Jung-Lyul Lee^{3,4} · Jihoon Kang⁵

¹Department of Industrial Engineering, Yonsei University

²Department of Smart Factory Convergence, Tech University of Korea

³School of Civil, Architecture and Environmental System Engineering, Sungkyunkwan University

⁴Graduate School of Water Resources, Sungkyunkwan University

⁵Department of Business, Tech University of Korea

In modern engineering, Artificial Intelligence (AI) and several data analysis techniques are frequently used and developed in various fields. These quantitative approaches, however, are somewhat focused on the assumption that sensor data properly expresses the physical phenomenon. Besides they still have limitations such as nonlinearity, different environmental condition and complexity of response. Another issue is that the data can be obtained through experiments, but due to the constraints of time and cost of experiments, obtaining a large amount of data that may be able to fully explain diverse natural occurrences is impossible. To deal with the aforementioned issues, we propose shoreline prediction techniques using a combination of physics and data analysis models. The physical coefficients of the existing differential equation are optimized through a genetic algorithm and approximate solution is obtained through the Euler method. This was used as prior knowledge and combined with a data analysis model to predict the shoreline position. As a result of the experiment, when there was enough training data, the performance of data analysis model was better than that of the proposed method, but the performance of the proposed method was better in situations where the training data was insufficient.

Keywords: Shoreline Prediction, Ordinary Differential Equations, Genetic Algorithm, Physics Informed Machine Learning

1. 서론

최근 전 세계적으로 기후변화에 따른 해수면 상승 및 파랑 환경 변화 등과 함께 해안 및 항구의 무분별한 개발로 인한 심각한 연안침식 문제가 대두되고 있다. 따라서 가속화되는 연안침식을 대

비하여 해안선을 예측하고 모니터링하는 것이 매우 중요한 상황이다. 국내 해양수산부에서는 2003년도부터 매년 대부분의 해안에 대하여 모니터링을 실시하고 있으며 4개의 침식등급(즉, A: 양호, B: 보통, C: 우려, D: 심각)으로 평가하고 있다. 하지만 해안선은 파고, 조수, 조류와 같은 파도 관련 변수에 영향을 받으며 시간

본 연구는 2023년도 과학기술정보통신부의 지원[2020R1F1A107494713]과 정보통신산업진흥원의 지원[S0317-21-1002]에 의한 연구임.

* 연락저자 : 강지훈 교수, 15073 경기도 시흥시 산기대학로 237 공학관 G-311, Tel : 031-8041-0687, Fax : 031-8041-0689,

E-mail : jhkang82@kpu.ac.kr

2023년 7월 17일 접수; 2023년 8월 8일 게재 확정.

이 지남에 따라 비선형적으로 변하기 때문에 예측하기 매우 어려운 것으로 알려져 있다(Chang and Lai, 2014).

해안선의 변화를 설명하고 예측하기 위해서, 과거부터 경험적 및 물리적 모델에 기반을 둔 해안선 변화 모델이 많이 연구되었다(Larson and Kraus, 1989; Miller and Dean, 2004; Caldwell and Edmonds, 2014; Lim *et al.*, 2022). 경험적 모델은 해안선의 변화에 대한 자연적인 현상이 경험적으로 유도되었다는 특징이 있다. 그러나 그 현상에 대한 물리적인 설명이 부족하다는 한계가 있다. 이와 달리 물리적 모델은 자연 현상이 물리적인 특성을 기반으로 유도되었기 때문에 물리적 일관성과 설명력을 가진다.

최근 Kim *et al.*(2021)이 물리적 모델로 파랑 특성에 따른 해안선의 변화를 모의하였다. 해당 모형에 포함하고 있는 물리계수인 해변 반응 계수(beach response factor)와 해변 회복 계수(beach recovery factor)는 해안선의 변화를 모의하는데 상당한 역할을 한다. Kim and Lee(2018)는 Dean(1977)의 평형해빈 단면 식으로부터 해변 반응 계수를 모래 입경에 대한 함수로 표현하였다. Lim *et al.*(2022)은 대한민국 동해안에서의 관측 자료를 활용하여 주요 해변 회복 계수를 모래 입경에 대하여 분석을 실시하였다. 그러나 Lim *et al.*(2022)의 연구는 대한민국 동해안에서는 유효할 수 있으나 대부분의 해변에 적용 가능 여부에 대하여 추가적인 연구가 필요하다. 또한, 앞서 말한 모형들은 관련 계수 추정에 대한 불확실성, 일반화된 가정으로 인한 낮은 예측력 등의 한계를 가지고 있다(Fang and Ron, 2013; Montano *et al.*, 2020).

해안선의 변화를 모의하기 위해 물리 및 수학기반의 수치 분석을 하는 경험적 및 물리적 모델과는 달리, 데이터 분석 모델은 많은 데이터를 통해 자연 현상을 모델링하고 예측을 하는 특징이 있다. 최근에는 센서 및 위성기술의 발달로 인해 데이터를 통해 해안선을 예측하고자 하는 연구가 진행되고 있다. Yan *et al.*(2021)은 중국 옌청시(Yancheng)의 1983년부터 2020년까지 획득한 해안선 위치 데이터를 DSAS(Digital Shoreline Analysis System)을 활용하여 해안선의 변화를 분석하였다. DSAS 소프트웨어의 대표적인 해안선 분석 방법은 가장 최근 해안선과 가장 오래된 해안선 위치의 차이를 경과시간으로 나눈 EPR(End Point Rate)과 시간에 따른 해안선의 위치를 선형 회귀 모델로 분석하는 LPR(Linear Regression Rate)이다. Kumar *et al.*(2020)은 인도 동부에 위치한 오디샤주(Odisha) 해안선의 1985년 1월부터 2015년 12월까지 월 단위의 위성 이미지에서 케니 에지 검출을 통해 해안선의 위치 데이터를 수집하였다. 이후 인공 신경망, 서포트벡터머신, KNN(K-Nearest Neighbors)으로 모델링하고 예측 성능을 비교하였으며, 머신러닝 기법이 해안선 변화 예측을 하는데 효과적임을 제시하였다. Zeinail *et al.*(2021)은 호주 나라빈(Narrabeen)의 해안선 예측을 위해 NARNET(Nonlinear Autoregressive Neural Network)을 활용하였다. NARNET은 시계열 변화 패턴과 비선형적 특성을 다루기 위해 과거 값들을 이용하여 미래 값을 예측하는 자기 회귀 기반의 인공신경망 모델로, 약

35년간의 월별 데이터를 통해 우수한 성능을 검증하였다. 앞서 소개한 데이터 분석 모델은 데이터 품질에 상당히 의존적인 특성이 가지기 때문에 데이터 품질이 좋지 않을 때 낮은 예측 정확도를 가진다. 또한, 학습 과정에서 변수 간 물리적 특성을 고려하지 않아 물리적 일관성을 가지기 어려워 모델에 대한 일반화가 어렵다는 한계를 가진다. 이외에도 자연현상을 온전히 반영하기 위해서는 충분한 학습데이터가 필요하지만 현실적으로 충분한 양의 데이터를 수집하기 어렵다는 문제가 있다(Karimpouli and Tahmasebi., 2020; Zeinail *et al.*, 2021).

본 논문에서는 앞서 말한 각 모델이 가지는 단점을 상쇄시키기 위해 Kim *et al.*(2021)이 제안한 물리적 모델을 기반으로 데이터 분석 모델과 결합하였다. 본 논문에서 제안하는 해안선 예측 모델의 학습 및 예측 과정은 다음과 같다. 먼저 해안선을 예측하기 위한 물리 모델에서 주요 물리 계수인 해변 회복 계수를 유전알고리즘(Genetic Algorithm)을 활용하여 추정하고 오일러방법을 통해 해안선 위치를 근사적으로 구한다. 이후, 근사적으로 구한 해안선 위치와 데이터 분석 모델로 예측한 해안선 위치를 결합하는 방법으로 moving window를 통해 시간 진행에 순차적으로 학습 및 예측을 진행한다.

본 논문의 순서는 다음과 같다. 제2장에서는 해안선 데이터와 해안선 변화를 설명하는 물리적 모델, 유전알고리즘을 이용한 물리계수 최적화를 소개한다. 제3장은 제안방법을 제시하고 제4장에서 실험결과를 나타낸다. 마지막으로 제5장에서 본 연구의 결론 및 향후 계획을 서술한다.

2. 해안선 변화 모델

2.1 해안선 데이터

본 연구에서는 제안 모델의 검증을 위한 데이터로 뉴질랜드의 tairua beach에서 수집된 shoreline evolution data(Montano *et al.*, 2020)를 활용하였다. 해안선 데이터는 선형 보간법을 통해 일일 데이터로 변환하였다. <Figure 1>은 1991년 1월 2일부터 2013년 12월 31일까지 일별 해안선의 평균 위치이며, <Figure 2>는 파도 관련 변수 유의파고(H_s), 침두주기(T_p), 파향(Dir) 데이터를 나타낸 것이다.

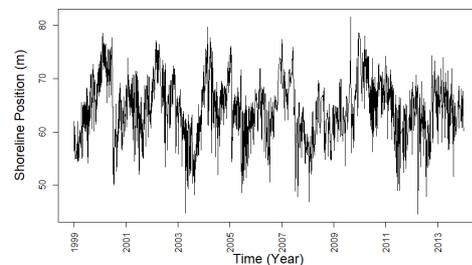


Figure 1. Temporal Series of Shoreline Change on Tairua Beach, New Zealand

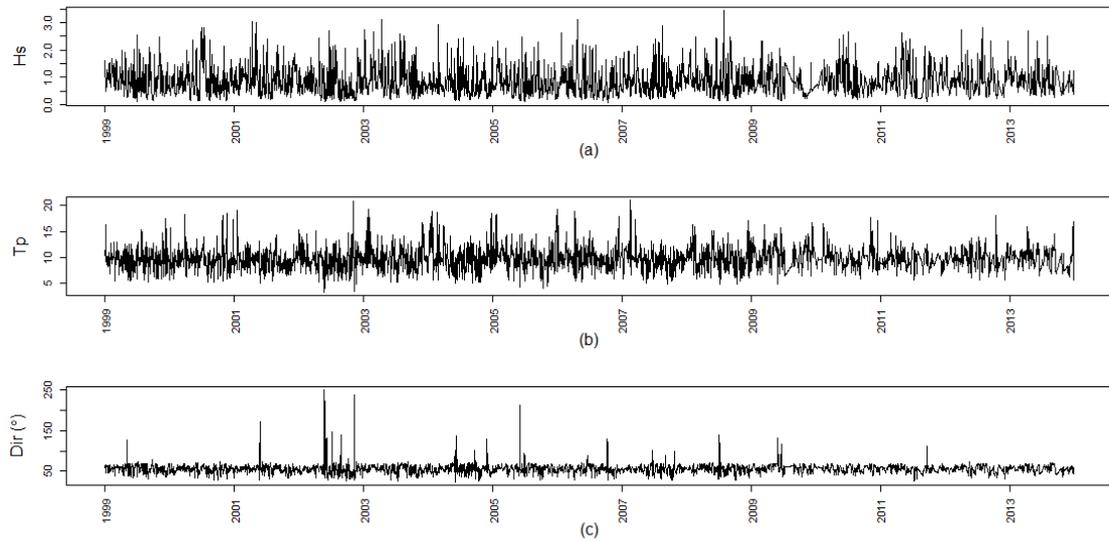


Figure 2. Temporal Series of Wave Data: (a) Significant Wave Height H_s (m); (b) Peak Wave Period T_p (s); (c) Wave Direction Computed at Peak Frequency of Total Wave Spectrum Dir (°)

2.2 물리 모델

Kim *et al.*(2021)은 해안선의 시간적인 변화를 모의하는 상미분방정식을 제안하였다. 또한 Lim *et al.*(2022)은 앞서 소개한 뉴질랜드의 tairua beach에서 관측된 자료들을 활용하여 Kim *et al.*(2021)이 제안한 해안선 변화 모형의 사용성을 검증하였다. Kim *et al.*(2021)이 제안한 해안선 변화 모형은 식 (1)과 같다.

$$\frac{dy}{dt} = f(t, y) = k_r \left(\frac{E'_b}{a_r} - y \right) \quad (1)$$

여기서 t 와 y 는 모형에서 해안선이 반응하는 시점에서의 시간과 위치를 의미하며, 각각 [day]와 [m]의 단위를 갖는다. 주요 물리 계수인 k_r 과 a_r 은 해변 회복 계수와 해변 반응 계수를 의미한다. 해변 회복 계수 k_r 은 day^{-1} 의 단위로 해안의 모래가 부유한 후 원래 위치로 돌아오는 회복 속도와 관련이 있는 물리 계수이다. 반면에 해변 반응 계수 a_r 은 [m]의 단위로 일정한 파고가 유입하는 경우에 평형에 도달하는 침식폭에 영향을 미치는 물리 계수이다. 그리고 E'_b 는 변환된 쇄파지점에서의 파랑에너지이며, 일반적인 파랑에너지와는 달리 E'_b 는 [m^2]의 단위로 Yates *et al.*(2009)이 제안한 방법을 적용하여 식 (2)와 같이 표현된다.

$$E'_b = \frac{H_b^2}{16} \quad (2)$$

여기서 H_b 는 쇄파지점에서의 파고를 의미한다.

Kim and Lee(2018)는 Dean(1977)의 평형해빈단면 식을 이용하여 근사적인 해변 반응 계수 a_r 을 제안하였다. 그리고 Lim *et*

al.(2022)은 Kim and Lee(2018)의 연구를 활용하여 a_r 을 간단한 모래 입경에 대한 함수로 식 (3)과 같이 제안하였다.

$$a_r = 0.115A^{3/2} \quad (3)$$

여기서 A 는 해변 축척 계수(beach scale factor)로 Dean(1977)의 평형해빈단면 식에 포함하는 계수이다. Dean(1977)이 제안하는 해변 축척 계수 A 는 모래 입경에 따라 결정되므로 해변 회복 계수 a_r 은 모래 입경에 따라 비례하여 결정된다. Montano *et al.*(2020)에 의하면 tairua beach의 모래 입경은 대략 0.427 mm이며, 이에 따른 해변 회복 계수 a_r 은 대략 0.006 m의 값을 얻는다.

위에서 소개한 상미분방정식의 근사해를 구하기 위한 수치 해석 방법으로는 오일러방법이 대표적이다(Hu and Tang, 2003). 오일러방법의 핵심은 식 (4)의 형태로 표현할 수 있다.

$$y_{i+1} = y_i + (t_{i+1} - t_i)f(t_i, y_i) \quad (4)$$

여기서 y_i 와 t_i 는 해당 격자에서의 해안선 위치와 시간을 의미한다. 그리고 $t_{i+1} - t_i$ 는 시간 간격 dt 에 따른 step size를 의미하며, 본 연구에서는 해당 시간 간격을 1 day로 설정하였다. 본 연구에서는 Lim *et al.*(2022)이 뉴질랜드의 tairua beach에 본 모형을 적용한 바와 같이 최적의 물리 계수 a_r , k_r 을 0.006, 0.012로 설정하였다. 그리고 오일러방법을 통해 식 (1)의 근사해를 구한 결과는 <Figure 3>과 같다. 방정식을 통한 예측 결과, 실제 해안선의 전진/후퇴 패턴에 대해 전반적인 패턴을 잘 추적하는 것으로 확인되나, 단기적으로 변화의 크기 및 peak 등 시계열 세부 패턴에 대해서는 보수적인 형태로 근사하는 것을 확인할 수 있다.

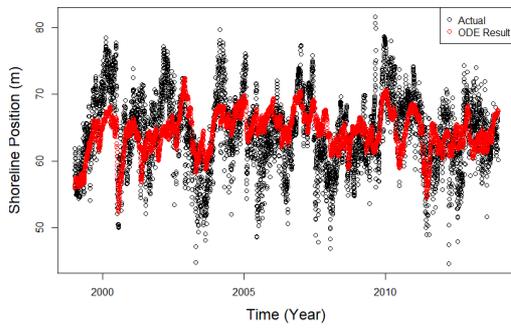


Figure 3. Prediction Results via ODE and Actual Values of Shoreline Position

해안선을 예측하는 관점에서 앞서 언급한 방법을 이용하여 대략적인 해빈 회복 계수 a_r 은 수학적으로 구할 수 있다. 하지만 해빈 회복 계수 k_r 은 해변의 특성 및 파랑 환경의 변화에 따라 바뀔 수 있기 때문에 확보한 학습데이터를 통해 최적화하는 과정이 필요하다.

2.3 유전알고리즘을 이용한 물리계수 최적화

유전알고리즘은 자연 진화 과정에서 영감을 얻어 최적 해를 구하는 최적화 알고리즘으로 함수의 미분 가능성을 필요로 하지 않기 때문에 복잡한 최적화 문제에서 많이 활용된다. 유전 알고리즘은 문제에 대한 가능한 해를 염색체(Chromosome)로 보며 이들의 집합을 개체군(Population)이라 한다. 하나의 염색체는 여러 개의 유전자(Gene)로 구성되며 이를 그림으로 표현하면 <Figure 4>와 같다.

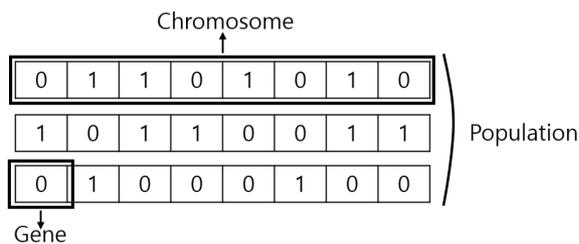


Figure 4. Chromosomes, Population and Genes in Genetic Algorithm

유전알고리즘은 선택(Selection), 교차(Crossover), 돌연변이(Mutation)라는 연산자를 통해 더 좋은 해를 가지는 개체를 찾아낸다. 교차 연산은 두 개의 염색체를 바탕으로 새로운 해를 만드는 연산을 말한다. 선택 연산은 교차 연산에서 두 개의 염색체를 선택하기 위한 단계이며, 해의 적합성을 수치화한 적합도 값을 통해 확률적으로 선택한다. 돌연변이 연산은 유전 알고리즘이 지역해에 빠지는 것을 방지하기 위해 임의로 개체값을 바꿔주어 해의 다양성을 만들어낸다. <Figure 5>는 유전 알고리즘의 순서도를 나타낸 것으로 초기 세대의 개체군은 랜

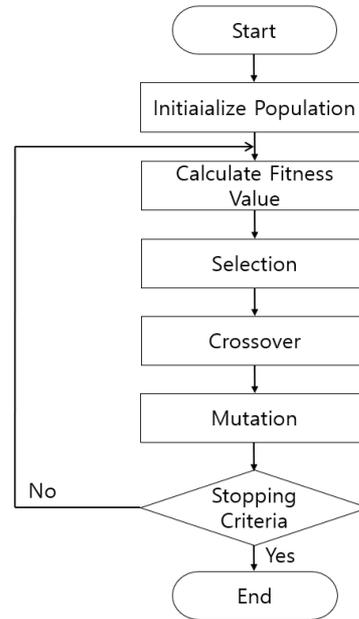


Figure 5. A Flow Chart of Optimization Process with Standard Genetic Algorithm

덤하게 생성되고, 선택, 교차, 돌연변이 연산을 통해 개체들이 진화한다. 이후, 종료 조건을 만족할 때까지 반복한다 (Tabassum and Mathew, 2014).

본 연구에서는 풀어야 하는 최적화 수식이 일반적인 기울기를 사용할 수 없는 상황이기 때문에 유전알고리즘을 활용하여 미분방정식의 근사해가 실제 해안선 위치와 가장 차이가 적게 나타나는 물리계수를 산출하였다. 기존 연구는 미분방정식의 근사해를 구할 때, 전체 해안선 데이터를 사용하여 k_r 을 최적화하였지만, 데이터 분석 관점에서는 학습(Training)데이터를 학습하고 검증(Test)데이터를 예측하는 것이 아닌 학습데이터를 예측한 것과 같이 때문에(즉, 학습과 검증데이터를 모두 포함한 형태에서의 모델 구축), 본 연구에서는 공정한 분석 결과 도출을 위해 물리계수를 구하는 과정에서 window size를 설정, 각 window size내에 포함되는 데이터에 한해서만 최적 k_r 을 구하였다. <Table 1>은 window size별 최적 k_r 을 나타낸 것으로 예를 들어 window size가 500이면, 전체 데이터에서 과거 500일의 데이터만을 활용하여 물리모델을 통해 모든 날짜의 해안선의 위치를 구한 것이다.

Table 1. Optimal k_r values corresponding to the Several Window Sizes

Window Size	Optimal k_r
500	0.0056
1000	0.009
2000	0.015
3000	0.014
4000	0.012
5000	0.013

Lim *et al.*(2022)은 해안선을 모니터링하는 과정에서 조수나 파랑 등으로 인한 평균 수위에 대한 오차가 포함될 수 있음을 확인하였다. 또한 본 연구에서 활용한 해안선 변화 모형은 파랑에 의한 횡단표사 이동의 변화만을 고려한다. 그러나 실제 해안선은 표사수지 변화나 연안표사 이동 등과 같이 다양한 영향에 의하여 반응한다. 따라서 본 연구에서 추정한 미분방정식의 최적 해빈 회복 계수 k_r 은 다소 과대평가 혹은 과소평가 될 수 있다. 또한, 데이터 분석 모델은 소수의 샘플을 활용하여 훈련 시 참고할 수 없었던 해안선의 물리적 특성을 온전히 반영할 수 없기에, 물리 기반 모델과 결합하여 앞서 말한 문제들을 해결하고자 했다. 데이터 분석 모델은 가장 대표적이고 간단한 다중선형회귀모델을 사용하였으며, 데이터를 기반으로 하는 다른 모델들로 대체 가능하다는 장점이 있다. 마찬가지로 물리 기반 모델 또한 다른 미분방정식 모델을 사용할 수 있다.

3. 제안 방법

본 연구에서는 미분방정식의 근사해와 데이터 분석 모델의 예측값을 조합하여 새로운 예측값을 도출하는 방법으로 해안선 예측을 수행하였다. 제안 방법의 순서는 <Figure 6>과 같다. 우선 window size(N)과 예측 구간 및 이동 크기인 step size(T)를 설정한 후, 유전알고리즘을 통해 미분방정식의 물리 계수를 최적화한다. 이후 오일러 방법을 구한 근사해와 다중선형회귀 모델의 예측값을 조합하여 새로운 예측값을 만드는 방법으로 식 (5)와 같다.

$$\hat{y} = \alpha f_d + (1 - \alpha) f_p \tag{5}$$

여기서 f_d 는 데이터 분석 모델을 의미하며 f_p 는 물리 모델을 의미한다. <Figure 7>은 학습 구간인 window 내에서 α 에 따

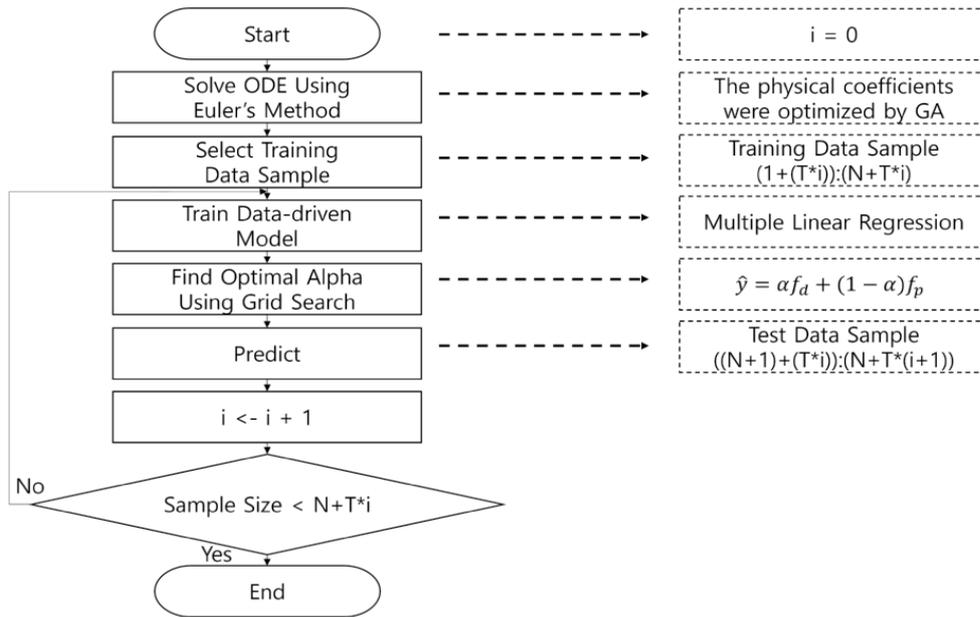


Figure 6. A Flow Chart of Modeling and Prediction Process Using Numerical Approximations for the ODE Solutions as Input Variables

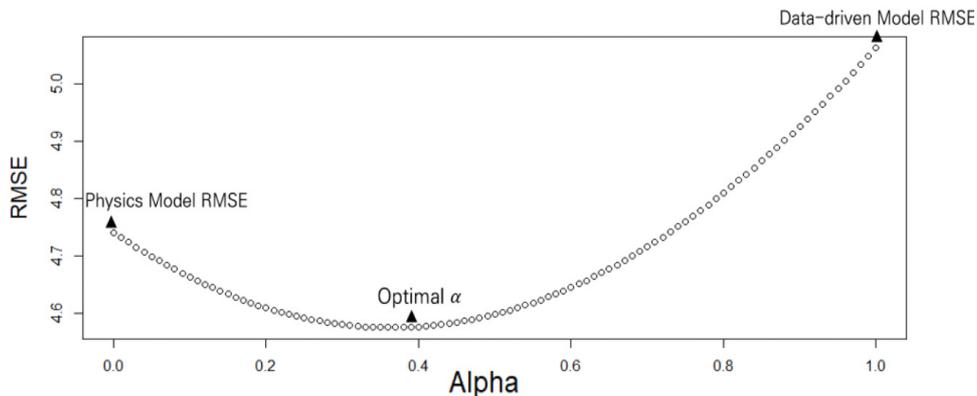


Figure 7. Change of RMSE according to the Setting Parameter(Alpha)

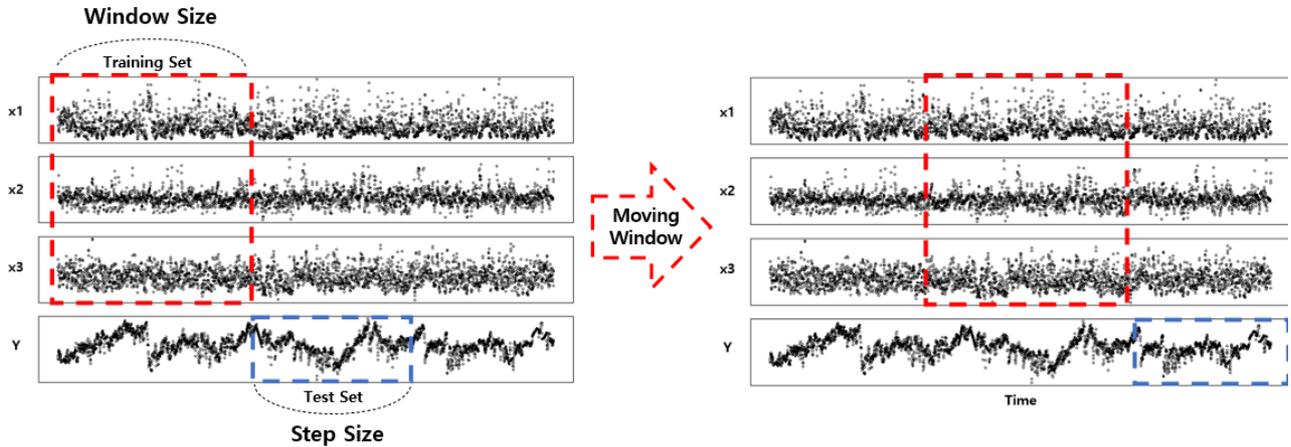


Figure 8. Updating and Evaluating Regression Models through Moving Window Scheme

라 변하는 각 모델의 RMSE를 나타낸 것으로 α 가 0일 때 물리 모델만을 이용하여 예측을 하고, α 가 1일 때, 데이터 분석 모델만을 이용하여 예측을 한다. 이때 최적의 α 를 구한다면 각 따라서 학습 과정에서 최적의 α 를 구하는 것이 중요하며, 본 연구에서는 α 의 범위를 0부터 0.01 간격으로 1까지 설정한 후 grid search를 통해 α 를 도출한 후 최적의 α 를 통해 step size만큼 예측을 진행한다. 예측이 끝나면 $i+1$ 을 통해 window를 이동시켜 순차적인 모델링과 예측값을 구할 수 있다. 만약 학습데이터의 크기(training data size)가 $N+T*i$ 보다 작으면 학습데이터에서 추출할 수 있는 데이터가 N 보다 작기 때문에 알고리즘이 종료된다. 위 과정은 moving window 기법을 적용한 것으로 시간에 따라 데이터 분포가 변화함을 고려하여 <Figure 8>과 같이 학습데이터의 범위를 순차적으로 이동시켜 예측을 진행한다.

4. 실험 결과

해안선 모델링 문제에서 상대적으로 적은 양에 대한 기준은 따로 제시되어 있지는 않기 때문에 본 연구에서는 약 1~2년 정도의 변화(500)일을 적은 양의 학습데이터, 10~15년 정도의 변화(5000)일을 충분한 양의 학습데이터로 임의로 설정하였다. window size를 [500, 1000, 2000, 3000, 4000, 5000]으로, step size는 60으로 설정하였으며 순차적 학습 및 예측이 진행되기 때문에 각 예측 성능인 RMSE의 평균을 나타내는 aRMSE(Average Root Mean Squared Error)를 성능지표로 사용하였다. 각 모델의 window size 별 예측 성능은 <Table 2>에 나타내었다. window size 5000을 제외하면 기존 데이터 분석 모델보다 제안 기법들이 더 낮은 aRMSE를 가지게 되었다. 이는 학습데이터가 충분히 많을 때, 데이터 분석 모델의 성능이 좋으며 학습데이터가 충분하지 않다면 물리 모델과의 결합이 더 우수할 수 있음을 보여준다. <Figure 9>는 <Table 2>를 그림으로 나타낸 것이다.

<Figure 10>은 인공지능망 모델(Data-driven), 미분방정식 모

델(ODE), 제안 모델(Physics-informed)을 통해 예측한 해안선 변동에 대해, 약 500일간의 파도의 에너지 관련 데이터를 학습 후, 그 다음 60일의 해안선 위치 예측 결과를 실제 변화와 비교하여 나타낸 것이다. 인공지능망 모델의 네트워크 구조는 히든레이어 8, 히든 노드 20으로 설정하였고 활성화함수는 ReLU, Optimizer는 Adam을 사용하였다. 훈련은 epochs 100, batch size 32, learning rate 0.001로 학습하였다. 인공지능망 모델 세부적인 변화를 잘 추적한다는 장점이 있지만 일정 기간

Table 2. The Performance Comparisons of Models(aRMSE) Corresponding to the Training Window Sizes(Step Size = 60)

Window Size	Data-driven Model	Physics-informed Model
500	4.886	4.498
1000	4.649	4.393
2000	4.389	4.130
3000	4.474	4.170
4000	3.917	3.669
5000	2.904	3.002

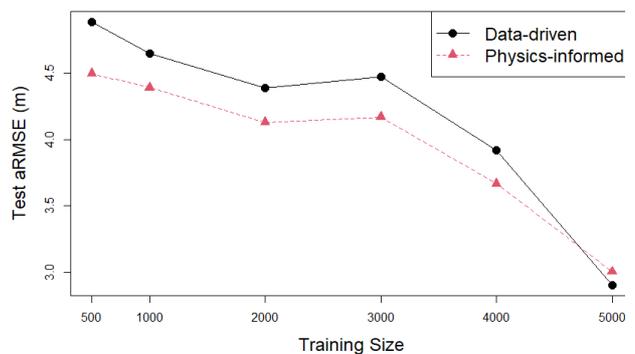


Figure 9. Performance Comparisons between Data-driven Model and Physics-informed Data-driven Model with the Different Training Sample Sizes

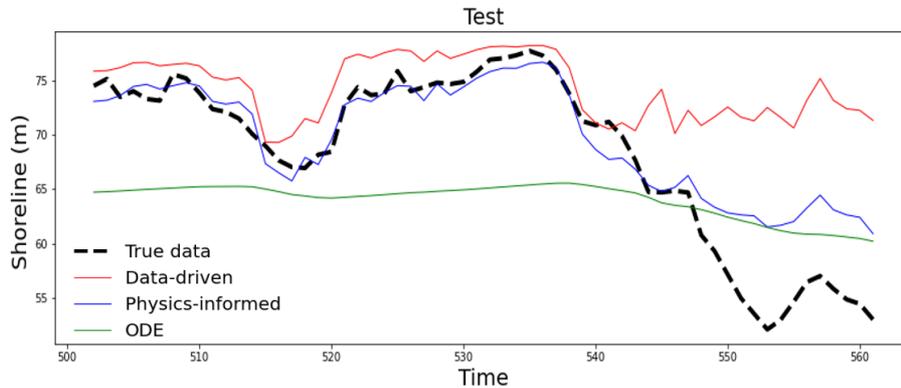


Figure 10. Comparison of Performance of Three Models(Data-driven Model, Physics-informed Model, and Ordinary Differential Equation(ODE) Model) for 60 Days of Future Data

을 지나면 해안선의 추세(특히, 540 시점 이후에 해안선이 급격히 후퇴하는 패턴 등)를 따라가지 못한다. 반면 ODE 모델의 경우, 540시점 이후의 후퇴 패턴에 대해 전체적인 트렌드가 잘 추적한다는 장점이 있지만, 세부적인 패턴을 반영하지 못하며 지나치게 일반화된 예측 성능을 보이고 있다. 반면 물리 결합 모델은 세부적인 패턴 변화를 잘 학습하면서도 동시에 미분방정식 모델의 일반화 강점을 동시에 확보할 수 있기에 관측 데이터의 분포에 제한되는 문제점을 극복, 데이터 분석 모델보다 외삽 측면에서 더 나은 예측 성능을 보여준다. 다시 말해서 제안 기법은 적은 양의 학습 데이터, 자연의 다양성 대비 상대적으로 희박한 데이터로 인해 훈련 범위를 벗어난 케이스를 예측하는 문제에 적합한 모델이라고 볼 수 있다.

5. 결론 및 향후 계획

본 논문에서는 최근 환경적으로 큰 이슈가 되고 있는 해안침식 문제에 대비하기 위해 해안선의 위치를 예측/시뮬레이션하는 물리 기반(Physics-informed) 데이터 분석 모델을 제안하였다. 기존의 완전히 데이터에 의존하는 머신러닝 모델과는 달리, 본 연구의 제안 방법은 해안선의 다양한 변화를 설명하는 미분방정식의 물리 계수를 최적화하고 오일러방법을 통해 산출한 근사해를 사전지식으로 활용, 모델링과 검증작업을 수행하였다. 예측 모델의 신뢰성을 위해 moving window 개념을 도입, 순차적인 모델링 과정과 예측, 검증을 진행하였다. 실험 결과, 충분히 많은 학습 데이터에서는 제안 방법보다 기존의 데이터 기반 방법의 평균 예측 성능 측면에서 더 높았지만, 부족한 관측을 기반으로 한 학습 데이터에서는 물리 결합형 머신러닝 방법의 외삽 능력이 더 우수하기 때문에 기존 방법보다 평균 예측 성능이 더 높았다. 따라서 해안 관련 데이터가 현실적으로 부족한 사례에서 제안하는 물리 결합 방법이 더 효율적으로 해안선을 예측할 수 있을 것으로 보인다.

본 연구에서는 60일이라는 짧은 기간을 기반으로 예측을 진행하였는데 이러한 방법은 단기적인 예측에는 좋은 성능을 보

일 수 있으나 아무래도 장기적인 변화를 추정하는데에는 무리가 있는 것이 현실이다. 향후에는 장기트렌드(Long-time trend) 및 주기성(Seasonality)을 동시에 반영하는 결합 모델링 연구 수행을 통해, 보다 다양한 예측상황에 강건한(Robust) 모델링 구축 기법 개발 등 다양한 추가적인 연구를 진행할 계획이다.

참고문헌

- Caldwell, R.L. and Edmonds, D. A. (2014), Delft3D-Flow: Simulation of Multi-Dimensional Hydrodynamic Flows and Transport Phenomena, Including Sediments-User Manual, *Journal of Geophysical Research: Earth Surface*, **119**, 961-982.
- Chang, F. J. and Lai, H. C. (2014), Adaptive neuro-fuzzy inference system for the prediction of monthly shoreline changes in northeastern Taiwan, *Ocean Engineering*, **84**, 145-156.
- Dean, R. G. (1977), Equilibrium Beach Profiles: U.S. Atlantic and Gulf Coasts, Technical Report No. 12, *Department of Civil Engineering, University of Delaware*.
- Fang Y. and Ron J. C. (2013), Modelling Coastal Process for Long-term Shoreline Change, *Proceeding of Coast and Ports 2013 Conference*.
- Hu, J. W. and Tang, H. M. (2003), Numerical methods for differential equations, City University, Hong Kong.
- Karimpouli, S., and Tahmasebi, P. (2020), Physics informed machine learning: Seismic wave equation, *Geoscience Frontiers*, **11**(6), 1993-2001.
- Kim, T.-K. and Lee, J.-L. (2018), Analysis of Shoreline Response due to Wave Energy Incidence Using Equilibrium Beach Profile Concept, *Journal of Ocean Engineering and Technology*, **32**(2), 116-122.
- Kim, T.-K., Lim, C., and Lee, J.-L. (2021), Vulnerability Analysis of Episodic Beach Erosion by Applying Storm Wave Scenarios to a Shoreline Response Model, *Frontiers in Marine Science*, **8**, 759067.
- Kumar, L., Afzal, M. S., and Afzal, M. M. (2020), Mapping Shoreline Change Using Machine Learning: A Case Study from the Eastern Indian Coast, *Acta Geophysica*, **68** (4), 1127-1143.
- Larson, M. and Kraus, N. C. (1989), SBEACH: numerical model for simulating storm-induced beach change; report 1: empirical foundation and model development, *Technical Report - US Army Coastal Engineering Research Center* 89-9.
- Lim, C., Kim, T. -K., Kim, J. -B. and Lee, J. -L. (2022), A Study on the

- Influence of Sand Median Grain Size on the Short-Term Recovery Process of Shorelines, *Frontiers in Marine Science*, 9, 906209.
- Lim, C., Kim, T. -K., and Lee, J. -L. (2022), Evolution model of shoreline position on sandy, wave-dominated beaches, *Geomorphology*, 415(15), 108409.
- Miller, J. K., and Dean, R. G. (2004), A simple new shoreline change model, *Coastal Engineering*, 51(7), 531-556.
- Montaño, J., Coco, G., Antolínez, J. A., Beuzen, T., Bryan, K. R., Cagigal, L., ... and Vos, K. (2020), Blind testing of shoreline evolution models, *Scientific Reports*, 10(1), 1-10.
- Tabassum, M. and Mathew, K. (2014), A genetic algorithm analysis towards optimization solutions, *International Journal of Digital Information and Wireless Communications (IJDWC)*, 4(1), 124-142.
- Yan, D., Yao, X., Li, J., Qi, L., and Luan, Z. (2021), Shoreline change detection and forecast along the Yancheng coast using a digital shoreline analysis system, *Wetlands*, 41(4), 1-16.
- Yates, M. L., Guza, R. T., and O'reilly, W. C. (2009), Equilibrium shoreline response: Observations and modeling, *Journal of Geophysical Research: Oceans*, 114(C9).
- Zeinali, S., Dehghani, M., and Talebbeydokhti, N. (2021), Artificial neural network for the prediction of shoreline changes in Narrabeen, Australia, *Applied Ocean Research*, 107, 102362.

저자소개

김용민: 한국공학대학교 스마트팩토리융합학과에서 2022년 석사학위를 취득하고 현재는 연세대학교 산업공학과 박사과정에 재학 중이다. 연구분야는 지식융합 인공지능, 기계 결합진단 및 이상감지 등이 있다.

윤현수: 2018년 에리조나 주립대에서 산업공학 박사 학위를 취득하였으며, 현재 연세대학교 산업공학과 교수로 재직 중이다. 대표 연구 분야는 전이 학습, 도메인 적응, 비전 검사, 지식융합 인공지능 등이 있다. 이 외에도 반도체 수율 검사, 이상 탐지, 일반화 성능 향상을 위한 머신 러닝 이론 모형들을 개발하였다

민수홍: 2022년 한국공학대학교 산업경영학과에서 학사학위 취득 후, 한국공학대학교 스마트팩토리융합학과 석사과정에 재학 중이다. 연구분야는 데이터마이닝과 유전 프로그래밍이다.

임창빈: 2022년도에 성균관대학교 수공학 전공 박사학위를 취득하였으며, 현재 성균관대학교 건설환경연구소에서 박사후연구원으로 재직 중이다. 대표 연구분야는 연안에서의 침식 예측 및 재해 관리 등이 있다.

이정렬: 1993년도에 미국 플로리다 대학교 해안/해양공학 전공 박사 학위를 취득하였으며, 현재 성균관대학교 수자원전문대학원 교수로 재직 중이다. 대표 연구분야는 연안 침식 및 연안 재해 관리 등이 있다. 이 외에도 수치 해석 기법을 이용하여 다양한 연안 환경에 적용 가능한 모형들을 개발하였다.

강지훈: 2015년 고려대학교에서 박사학위를 취득하고 2019년까지 삼성 SDS 데이터분석그룹 Senior Engineer로 근무하였다. 현재는 한국공학대학교 경영학부 교수로 재직하고 있다. 대표 연구분야로는 물리모델과 머신러닝의 결합 기법, 최적화 및 최적제어, 품질 및 예지보전 등이 있다.