

머신 러닝 알고리즘을 이용한 역방향 깃발의 에너지 하베스팅 효율 예측

임세환* · 박성군†

Prediction of Energy Harvesting Efficiency of an Inverted Flag Using Machine Learning Algorithms

Sehwan Lim* and Sung Goon Park†

Abstract The energy harvesting system using an inverted flag is analyzed by using an immersed boundary method to consider the fluid and solid interaction. The inverted flag flutters at a lower critical velocity than a conventional flag. A fluttering motion is classified into straight, symmetric, asymmetric, biased, and over flapping modes. The optimal energy harvesting efficiency is observed at the biased flapping mode. Using the three different machine learning algorithms, i.e., artificial neural network, random forest, support vector regression, the energy harvesting efficiency is predicted by taking bending rigidity, inclination angle, and flapping frequency as input variables. The R^2 value of the artificial neural network and random forest algorithms is observed to be more than 0.9.

Key Words : Machine learning(기계 학습), Inverted flag(역방향 깃발), Energy harvesting(에너지 하베스팅)

1. 서론

에너지 하베스팅은 외부 에너지 소스로부터 사용할 수 있는 에너지의 형태로 저장 혹은 변환하는 과정으로 연성체가 유동 내에서 자발적으로 필력임을 지속하는 현상을 이용하여 시스템을 구축할 수 있다. 연성체를 이용한 에너지 하베스팅 시

스템은 유체의 운동에너지를 연성체의 변형에너지로 변환하고 최종적으로 연성체에 부착된 압전 소자를 이용하여 전기 에너지로 변환시키는 역할을 수행한다. 따라서 연성체의 변형이 클수록 더 많은 전기에너지 생산을 기대할 수 있다.^[1,2] 앞부분이 고정되고, 뒷부분이 자유롭게 필력하는 형태의 연성체에 대해 기존 많은 연구들이 수행되었으나 이 경우 상대적으로 다른 형태에 비해 연성체의 변형이 크지 않아 에너지 하베스팅 시스템에 도입되기에는 한계점이 존재한다. 이러한 한계점을 극복하기 위해 연성체 상류 영역에 고정된 물체를 추가하여 연성체 운동의 불안정성을 증가시켜 변형을 크게 하기 위한 연구도 수행되었다.^[3-5] Kim et al.^[6]은 연성체의 선행 부분이 필력이고, 후

† Department of Mechanical and Automotive Engineering, Seoul National University of Science and Technology, Seoul, 01811, Korea, Assistant professor
E-mail: psg@seoultech.ac.kr

* Department of Mechanical Engineering, Seoul National University of Science and Technology, Seoul, 01811, Korea, MS Student

행 부분이 고정된 형태의 역방향 깃발을 제시하여 낮은 유체 속도에서 연성체의 큰 변형을 유발할 수 있는 형태를 고안하였다. Ryu et al.^[7]은 2차원 수치 계산을 통해 굽힘 강성과 레이놀즈 수에 따른 역방향 깃발의 에너지 하베스팅 효율을 비교하였다. Shoole and Mittal^[8]은 역방향 깃발의 기울어진 각도가 0°부터 30°까지 변화시켰을 때 역방향 깃발의 운동을 수치 계산을 이용하여 분석하였다.

수치 해석을 통해 역방향 깃발의 운동과 에너지 하베스팅 효율을 예측하고 분석하는 방법에 대해 많은 연구가 진행되어 왔지만 복잡한 연산을 위해 많은 계산 시간이 요구된다. 최근, 기계 학습 알고리즘을 이용하여 수치 해석 결과를 이용하여 모델을 학습시키고 이를 활용하여 다른 조건에서의 결과를 예측하는 연구가 활발하게 진행되고 있다.^[9-10]

본 연구에서는 기울어진 역방향 깃발의 각도와 굽힘 강성에 깃발의 움직임과 에너지 하베스팅 효율에 대해 2차원 수치 해석을 진행하였다. 유체 운동 에너지와 깃발 변형 에너지의 변환 과정에서 에너지 효율을 정의하였으며, 인공 신경망(Artificial Neural Network), 랜덤 포레스트(Random Forest), 서포트 벡터 머신(Support Vector Machine) 알고리즘을 이용하여 모델을 학습시켜 에너지 하베스팅 효율을 예측하고자 한다.

2. 연구 방법

2.1. 역방향 깃발 수치 해석 지배방정식

Fig. 1은 기울어진 역방향 깃발의 계략도와 좌표 시스템을 보여준다. 기울어진 역방향 깃발은 선형이 자유롭게 움직이고, 후행이 고정된 형태이며 운동의 불안정성을 증가시키기 위해 선형 부분의 경사각(θ) 조건을 부여하였다. 유체의 움직임은 고정된 Eulerian 격자 시스템에서 정의를 하였으며, 역방향 깃발의 움직임은 움직이는 Lagrangian 격자 시스템에서 정의하였다. 가상 경계 기법(Immersed Boundary Method, IBM)을 사용하여 유체와 역방향 깃발 사이의 상호작용을 고려하였다.

유체의 움직임은 비압축성 Navier-Stokes 방정식에 의해 지배되며 식은 아래와 같다.

$$\frac{\partial \mathbf{u}}{\partial t} + \mathbf{u} \cdot \nabla \mathbf{u} = -\nabla p + \frac{1}{\text{Re}} \nabla^2 \mathbf{u} + \mathbf{f}, \quad (1)$$

$$\nabla \cdot \mathbf{u} = 0, \quad (1)$$

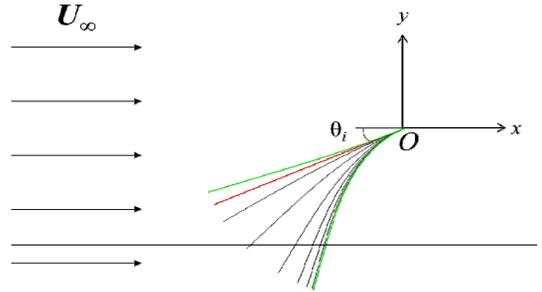


Fig. 1. Schematic diagram of an inclined inverted flag. The red line indicates the initial position of the flag. The two green lines indicate the position when the flag reaches the maximum and minimum y -position, respectively.

\mathbf{u} 는 속도 벡터, p 는 압력, \mathbf{f} 는 깃발 주변에서 점착 조건을 만족하는 운동량 힘을 나타낸다. 레이놀즈 수는 $\text{Re} = \rho_0 U_\infty L / \mu$ 로 정의하며 본 논문에서는 200으로 고정하였다. 레이놀즈 수가 높아지는 경우 깃발의 z 방향으로 3차원 효과가 발생하여 2차원 가정하에 계산된 값들이 실제 값과 다를 수 있다. μ 는 점성 계수, ρ_0 는 유체의 밀도, U_∞ 는 입구 유체 속도, L 은 역방향 깃발의 길이를 나타낸다. 역방향 깃발의 움직임을 나타내는 식은 다음과 같다.

$$\frac{\partial^2 \mathbf{X}}{\partial t^2} = \frac{\partial}{\partial s} \left(T \frac{\partial \mathbf{X}}{\partial s} \right) - \frac{\partial^2}{\partial s^2} \left(\gamma \frac{\partial^2 \mathbf{X}}{\partial s^2} \right) - \mathbf{F} \quad (3)$$

$\mathbf{X}(s, t)$ 는 깃발의 위치, s 는 곡선의 길이, T 는 곡선을 따라 작용하는 장력, γ 는 굽힘 강성, \mathbf{F} 는 깃발 주변 유체에 의해 작용하는 Lagrangian 운동량 힘을 나타낸다. 식 (1)-(3)은 특정 매개 변수에 의해 무차원화 된 형태이다. ρ_1 는 깃발의 밀도, L/U_∞ 는 시간, $\rho_0 U_\infty^2$ 은 압력, $\rho_0 U_\infty^2 / L$ 은 유체에 작용하는 운동량 힘 f , $\rho_1 U_\infty^2 / L$ 은 Lagrangian 힘 F , $\rho_1 U_\infty^2$ 은 장력, $\rho_1 U_\infty^2 L^2$ 은 굽힘 강성 γ 를 무차원화 하였다. 고정된 후행 부분($s = 0$)의 경계조건은

$$\mathbf{X} = \mathbf{X}_0, \quad \frac{\partial \mathbf{X}}{\partial s} = (-\cos \theta_i, -\sin \theta_i). \quad (4)$$

움직이는 선행 부분($s = L$)에서

$$\mathbf{T} = \mathbf{0}, \quad \frac{\partial^2 \mathbf{X}}{\partial s^2} = (0, 0), \quad \frac{\partial^3 \mathbf{X}}{\partial s^3} = (0, 0). \quad (5)$$

유체와 역방향 깃발 사이 상호작용에 의한 Lagrangian 힘은 아래와 같이 계산된다.

$$\mathbf{F} = \alpha \int_0^t (\mathbf{U}_{ib} - \mathbf{U}) dt + \beta (\mathbf{U}_{ib} - \mathbf{U}), \quad (6)$$

상수 α 는 -6.25×10^6 , β 는 -1.56×10^2 로 설정하였고, 역방향 깃발의 속도는 $U = dX/dt$ 로 계산할 수 있다 (위의 상수 값은 안정된 영역 내에 존재하는 경우 계산 결과 값에 영향을 미치지 않는다). U_{ib} 는 가상 경계에서의 속도를 의미하며 델타 함수 $\delta()$ 를 이용하여 계산된다.

$$U_{ib}(s, t) = \int_{\Omega} u(x, t) \delta(\mathbf{X}(s, t) - x) dx \quad (7)$$

Lagrangian 힘은 아래와 같이 델타 함수를 이용하여 유체 격자에 전달된다.

$$f(x, t) = \rho \int_{\Gamma} \mathbf{F}(s, t) \delta(x - \mathbf{X}(s, t)) ds, \quad (8)$$

2.2. 기계 학습 알고리즘

인공 신경망은 입력층, 출력층과 은닉층으로 구성되어 입력과 출력사이의 관계를 찾는 알고리즘이다. Fig. 2는 단일 인공신경망 모델을 묘사한 모델이며, 다음과 같은 식을 통해 출력 결과를 얻는다.

$$y = h(\sum w_i x_i + b) \quad (9)$$

w 는 가중치, b 는 편향치, h 는 활성화 함수를 나타낸다. 본 연구에서는 가중치를 조정하기 위해 역전파를 사용한 다층 신경망을 사용했다. 순전파 과

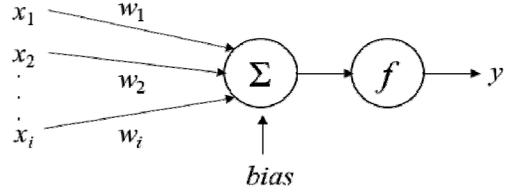


Fig. 2. Schematic diagram of perceptron model

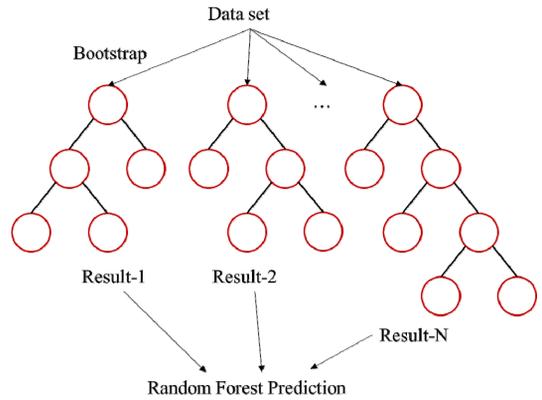


Fig. 3. Schematic diagram of the random forest algorithm.

정 이후 출력 결과에 대해 오차를 계산하고, 각 가중치 값으로 편미분한 값을 경사 하강법을 이용해 새로운 가중치를 얻는 과정이다.^[11]

랜덤 포레스트 알고리즘의 개략도는 Fig. 3에 나타났다. 랜덤 포레스트 알고리즘은 결정 트리를 기반으로 심화된 기계학습 알고리즘이며^[12] 입력

데이터를 부트스트랩과정을 통해 추출한 부트스트랩 샘플을 각각의 결정 트리 모델을 학습시켜 결과값을 얻어낸다. 각 결정 트리 최종 값의 평균을 통해 최종적인 예측 값을 얻는 앙상블(ensemble) 기법을 사용한다. 여러 개의 결정 트리 최종 값의 평균을 통해 최종적인 예측 값을 얻는 앙상블(ensemble) 기법을 사용한다. 여러 개의 결정 트리를 이용함으로써 과대적합을 방지할 수 있다. 랜덤 포레스트를 이용한 예측 결과는 다음과 같은 식을 통해 계산할 수 있다.

$$F(x) = \sum_{i=1}^T F_i(x) / T. \quad (10)$$

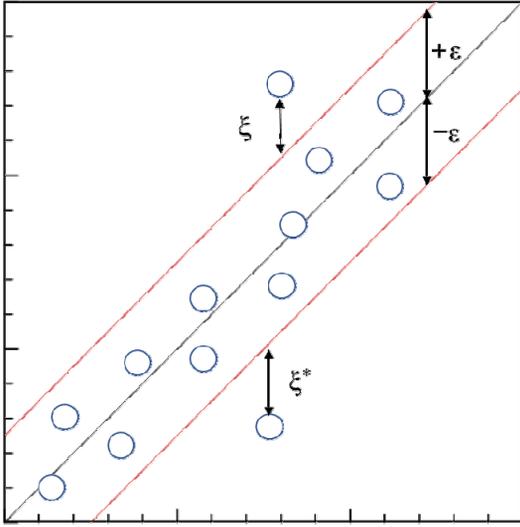


Fig. 4. Schematic diagram of the support vector regression algorithm.

$F(x)$ 는 각 결정 트리의 결과값, T 는 결정 트리의 개수를 나타낸다.

서포트 벡터 머신은 입력 데이터에 대해 점, 선 혹은 초평면들의 집합을 구성하고, 분류의 경우 마진이 최대가 되는 초평면을 선택한다¹³⁾. 서포트 벡터 머신을 이용한 회귀를 서포트 벡터 회귀(Support Vector Regression)이라 한다. SVR을 이용한 회귀식을 얻기 위해 다음과 같은 ε -insensitive loss function을 사용했다.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*), \text{subject to} \quad (11)$$

$$\begin{aligned} (w^T x_i + b) - y_i &\leq \varepsilon + \xi_i \\ y_i - (w^T x_i + b) &\leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* &\geq 0 \end{aligned}$$

ξ_i 는 여유 변수(slack variable), ε 은 허용가능한 오차를 나타낸다. Fig. 4는 식(11)을 이용하여 회귀 함수를 얻는 과정을 나타낸다. 위의 세 가지 기계 학습 알고리즘을 구현하기 위해 TensorFlow 2.3.1을 사용하였다.

3. 결과 및 고찰

3.1 역방향 깃발에 대한 수치 계산 결과

기울어진 각도는 깃발의 움직임을 결정하는 중요한 변수 중 하나이다. Fig. 5는 굽힘 강성이 0.8일 때 역방향 깃발의 세 가지 펄럭임 모드(straight, biased, over flapping mode)를 나타낸다. Fig. 5(a)는 각도가 0° 인 경우를 보여주며 초기에 빨간색 선으로 표시된 위치에서 펄럭임 운동을 시작하지만, 과도 구간을 거쳐 다시 빨간색 위치로 돌아오며 그 후에는 움직이지 않는 straight mode를 보인다. 각도가 증가함에 따라 깃발이 펄럭임 운동을 지속하였으며, Fig. 5(b), (c)에서 깃발의 최대위치는 시작 위치를 넘지 못하는 모습을 확인할 수 있다. 이를 biased flapping mode라고 정의한다. Fig. 5(d)는 역방향 깃발의 기울어진 각도가 매우 큰 값을 갖는데, 이 때 깃발 선단이 y 축을 넘으며 움직이는 over flapping mode가 나타난다.

굽힘 강성이 비교적 작은 0.6일 때 깃발은 굽힘 강성이 높은 0.8인 깃발보다 낮은 각도에서도 펄럭

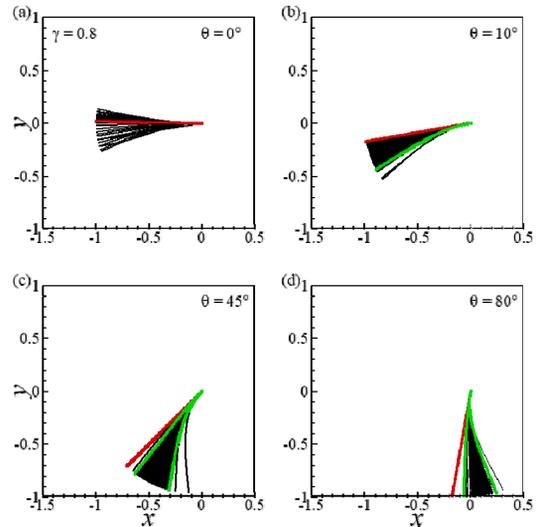


Fig. 5. Superimposed inverted flag at the bending rigidity of 0.8. The red line indicates the initial position of the inverted flag. The green line indicates the limit of the flutter motion in the converging state. (a) straight, (b) biased, (c) biased, (d) over flapping mode.

임 운동을 지속한다. 0°에서 굽힘 강성 0.8인 깃발이 보여주었던 **straight mode** 대신 0.6인 경우 깃발이 x 축에 대해 대칭적으로 움직이는 **symmetric flapping mode**가 나타난다. 기울어진 각도가 10°로 증가함에 따라 대칭적인 펄럭임 운동은 비대칭적 펄럭임 운동으로 전환된다. 이후 굽힘 강성이 0.8인 경우와 비슷하게 **biased flapping mode** 및 **over flapping mode**로 차례로 전환된다.

기존 기울어진 각도가 없는 역방향 깃발의 에너지 하베스팅 연구⁷⁾에서는 한 주기 동안 깃발의 y 방향 펄럭임 진폭을 통해 변형을 확인했다. 하지만 기울어진 각도가 존재하는 역방향 깃발의 경우, 각도가 증가하며 y 방향의 움직임이 감소하고 x 방향의 움직임이 증가한다. y 방향의 진폭으로는 기울어진 역방향 깃발의 변형을 표현할 수 없기 때문에 역방향 깃발 선단의 처음 위치와 한 주기 동안 선단의 평균 위치의 거리를 계산하여 변형을 예측할 수 있다.

한 주기 동안 역방향 깃발의 평균 변형 에너지는 E_s 로 나타내며 다음과 같은 식으로 계산한다.

$$E_s = \frac{1}{T} \int_0^T \int_0^L \frac{1}{2} \gamma \left(\frac{\partial^2 X}{\partial s^2} \right)^2 ds dt \quad (12)$$

각 굽힘 강성에서 평균 변형 에너지는 각도가 증가하며 점차 증가하는 경향을 보이며, 펄럭임 움직임이 **over flapping mode**로 전환된 순간부터 감소하는 모습을 보인다. 굽힘 강성이 0.6인 역방향 깃발이 높은 굽힘 강성을 가진 역방향 깃발보다 쉽게 변형하기 때문에 많은 변형 에너지를 얻을 수 있다. **straight mode**는 변형이 없는 상태이기 때문에 변형 에너지는 0에 가까운 값을 얻는다. 공통적으로 **biased flapping mode**에서 가장 높은 변형 에너지를 얻을 수 있다. 역전된 깃발의 펄럭임 운동은 굽힘 강성과 각도에 큰 영향을 받으며 본 연구에서는 각각 0.6-0.8, 0°-80° 범위에서 계산을 수행하였다.

역방향 깃발을 이용한 에너지 하베스팅 시스템에서 한 주기 동안 유체의 평균 운동 에너지를 입력 에너지로 사용하며 아래와 같이 계산할 수 있다.^[6,7]

$$E_k = \frac{1}{2} \rho_l U_\infty^3 L_{eff} \quad (12)$$

L_{eff} 는 유체가 깃발에 닿는 유효 길이로, 깃발의 수직방향 최대 사영 길이를 나타낸다. 깃발이 x 축을 넘으며 펄럭일 때 L_{eff} 는 y 방향 진폭과 동일하다. L_{eff} 가 각도에 따라 증가하기 때문에, 평균 운동 에너지는 각도가 커짐에 따라 함께 증가하는 경향을 보인다. **over flapping mode**로 전환되면 굽힘 강성과 관계없이 깃발의 선단이 y 축을 넘게 되어 L_{eff} 와 평균 운동 에너지는 굽힘 강성에 따른 차이를 보이지 않는다.

Fig. 6은 역방향 깃발의 펄럭임 주파수를 나타낸다. **Straight mode**에서는 깃발의 움직임이 없기 때문에 주파수 또한 0으로 나타난다. **Symmetric, over flapping mode**보다 **biased flapping mode**가 나타나

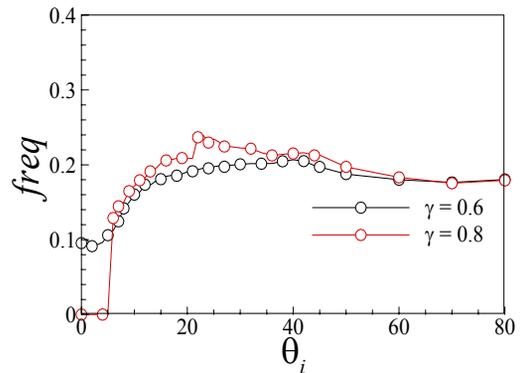


Fig. 6. The flapping frequency depending on the bending rigidity and inclination angle.

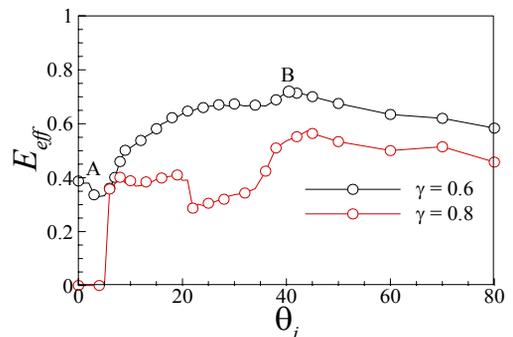


Fig. 7. The energy harvesting efficiency depending on the bending rigidity and inclination angle.

는 기울어진 각도가 10°-45°인 구간에서 역방향 깃발이 높은 주파수로 빠르게 펄럭이는 것을 확인할 수 있다.

에너지 하베스팅 효율은 E_{eff} 로 나타내며 변형 에너지와 유체 운동에너지의 비로 계산할 수 있다.^[6,7] 각 굽힘 강성에서 기울어진 각도에 따른 에너지 하베스팅 효율을 Fig.7에 도식화 하였다. 굽힘 강성 0.6 및 0.8인 경우 기울어진 각도가 각각 40° 와 44° 일 때 최적의 에너지 하베스팅 효율을 얻을 수 있다.

굽힘 강성 0.6인 역방향 깃발의 기울어진 각도가 0° (Fig.7 A)일 때 0.3877의 효율을 갖지만 40° (Fig.7 B)의 각도가 부여된 경우 0.7165의 에너지 하베스팅 효율을 보이며 효율이 84.85% 증가하는 결과를 보였다. Straight mode에서는 깃발의 펄럭임 운동이 없기 때문에 에너지 수확이 불가능하지만 선행 각도를 증가시킴에 따라 역으로 반전된 깃발 운동의 불안정성이 증가하여 펄럭임 운동을 지속하고 그에 따라 에너지 하베스팅을 지속할 수 있다.

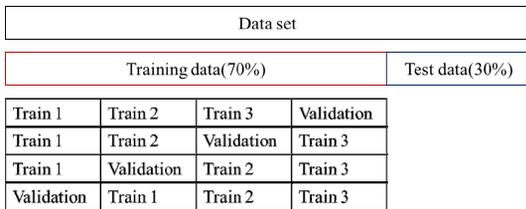


Fig. 8. Schematic diagram of K-fold cross validation method.

3.2 에너지 하베스팅 효율 예측

본 연구에서는 입력 값으로 역방향 깃발의 굽힘 강성, 기울어진 각도, 펄럭임 주파수를 설정하여 에너지 하베스팅 효율을 예측하였다. 수치 계산 결과 데이터를 트레이닝, 테스트 데이터로 나누어 세 가지 기계 학습 알고리즘을 이용해 예측 모델 학습을 시행하였다. 기계 학습의 높은 정확도를 위한 충분한 데이터를 확보하기 위해 굽힘 강성 0.7 및 0.9 일 때의 데이터를 추가로 활용하였다.

각 알고리즘에서 과대 적합 문제를 방지하기 위해 K-fold Cross Validation 방법을 사용했다. Fig. 8는 K-fold Cross Validation의 개략도를 나타낸다. 전체 데이터 세트를 트레이닝, 테스트 데이터 세트로 나눈 뒤 트레이닝 데이터 세트만을 이용하여 모델 훈련과 검증과정을 진행한다. 총 162개의 데이터를 사용했고 70% (114개)를 트레이닝, 30% (48개)를 테스트 데이터 세트로 나누었다. 114개의 트레이닝 데이터를 4분할한 뒤 3개의 데이터 그룹을 통해 모델 학습을 진행한다. 이후 남은 하나의 그룹을 이용해 모델 검증을 수행한다. 모든 데이터 그룹이 한 번씩 검증 데이터로 쓰이도록 위 과정을 반복 수행한다. 본 연구에서는 모델 훈련과 검증 과정을 총 4번 수행하여 모델 학습을 수행하였다.

Fig. 9은 세 가지 알고리즘을 이용한 에너지 하베스팅 효율 예측 결과와 수치 계산 결과를 비교한 그래프를 나타낸다. Fig. 9(a)는 인공 신경망 모델 결과를 보여준다. 인공 신경망 모델은 검증 결

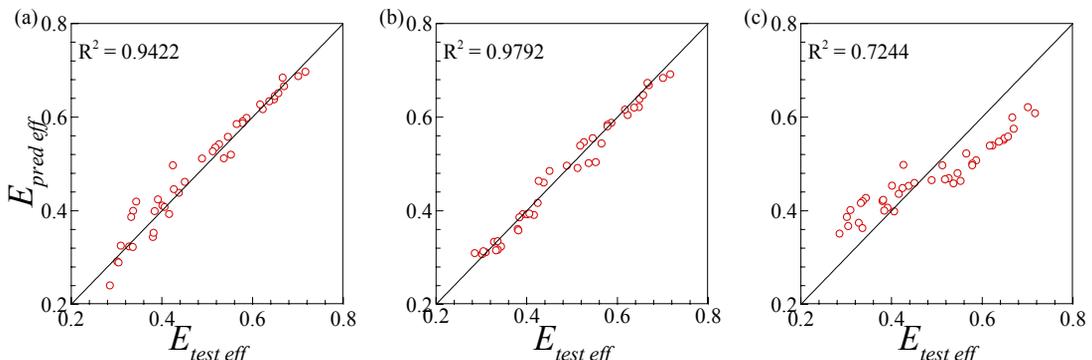


Fig. 9. The predicted result (y-axis) versus the numerical result (x-axis) for the three different machine learning algorithms;(a) artificial neural network, (b) random forest, (c) support vector regression.

과를 바탕으로 두개의 은닉층에 각각 128개의 노드를 사용했고, 활성화 함수는 회귀 문제에 사용하는 ReLU함수를 이용하였다. 랜덤 포레스트는 총 500개의 결정 트리에 대해 최대 리프 노드수를 20, 최대 깊이를 8로 모델 파라미터를 설정하였다. 랜덤 포레스트를 통한 예측 결과는 Fig. 9(b)에 나타났다. Fig. 9(c)는 서포트 벡터 회귀 모델 결과이며, 선형 모델에 대해 식 (11)의 ϵ 과 C 값을 조정하여 모델을 학습하였다. 모든 알고리즘 모델의 정확성은 평균 절대 오차(이하 MAE)와 평균 제곱 오차(이하 MSE)를 이용하여 평가하였다. Table. 1은 각 알고리즘 별 예측 정확도를 나타낸다. 랜덤 포레스트 알고리즘이 가장 정확했으며, 인공 신경망, 서포트 벡터 회귀 순으로 R^2 , MSE, MAE가 높은 결과를 보였다. 랜덤 포레스트의 R^2 는 0.9792로 정확도가 높은 결과를 보였다.

Table 1. Prediction accuracy according to each machine learning algorithm.

Algorithm	R^2	MSE	MAE
ANN	0.9422	0.0005	0.0176
RF	0.9792	0.0003	0.0156
SVR	0.7244	0.0045	0.0607

4. 결론

기울어진 역방향 깃발의 움직임과 에너지 하베스팅 시스템에 대해 수치 계산을 수행하고, 세 가지 기계 학습 알고리즘을 이용하여 효율 예측을 진행했다. 유체와 역방향 깃발간 상호작용을 고려하기 위해 가상경계기법을 사용하였다. 굽힘 강성과 기울어진 각도에 따른 에너지 하베스팅 효율을 연구하기 위해서 굽힘 강성 범위 0.6-0.8, 각도 범위 0° - 80° 범위에서 해석을 진행하였다. 각도가 증가하면서 역전된 깃발의 불안정성이 증가하였으며 symmetric mode, straight mode, biased mode 그리고 over flapping mode를 확인할 수 있었다. Straight mode에서는 깃발이 움직이지 않는 상태로 에너지 하베스팅이 불가능 하지만 각도가 커짐에 따라 깃발의 펄럭임을 유발하여 에너지 하베스팅이 가능한 상태로 전환시킬 수 있다. 에너지 하베스팅 효

율은 깃발의 변형 에너지와 유체의 운동에너지 비로 나타내며, 굽힘 강성 0.6에서 40° 인 경우 0° 일 때보다 에너지 하베스팅 효율이 약 85% 증가하는 경향을 확인할 수 있다.

굽힘 강성과 기울어진 각도에 따른 에너지 하베스팅 효율을 얻기 위해 각각의 경우에 대해서 수치 계산을 수행해야 하며 높은 계산 비용을 요구한다. 하지만 수치 데이터를 바탕으로 기계 학습을 이용해 에너지 하베스팅 효율을 예측하는 모델을 만들 수 있으며 이를 활용하는 경우 적은 계산 비용으로도 에너지 하베스팅 효율을 예측할 수 있다. Straight mode를 제외한 162개의 데이터를 사용하였으며, 예측을 위해 깃발의 굽힘 강성, 기울어진 각도, 펄럭임 주파수를 입력 값으로 부여하였다. 인공 신경망, 랜덤 포레스트, 서포트 벡터 회귀 알고리즘 모델을 이용하여 학습을 진행하였다. 각 알고리즘에서 과대 적합 문제를 방지하기 위해 K-fold Cross Validation 방법을 사용하였고, 4개의 그룹으로 나누어 예측 모델 검증을 실시하였다. 예측 정확도는 R^2 , MSE, MAE로 평가하였으며, 예측 결과 랜덤 포레스트, 인공 신경망, 서포트 벡터 회귀 순으로 정확도가 높은 결과를 보였다. 기계 학습 알고리즘을 이용하여 굽힘 강성, 기울어진 각도, 펄럭임 주파수 값이 주어지는 경우 에너지 하베스팅 효율을 예측할 수 있는 가능성을 확인하였다.

후 기

본 연구는 한국연구재단의 지원을 받아 수행되었습니다. (NRF-2021R1C1C1008791)

REFERENCE

- 1) S. Michelin and O. Doaré, Energy harvesting efficiency of piezoelectric flags in axial flows., Journal of Fluid Mechanics 714, 489-504, 2013.
- 2) X.-F. He and J. Gao, Wind energy harvesting based on flow-induced-vibration and impact. Microelectronic Engineering 111, 82-86, 2013.
- 3) J. J. Allen and A. J. Smits, Energy harvesting eel., Journal of Fluids and Structures 15, 629-640, 2001.

- 4) G. W. Taylor, J. R. Burns, S. M. Kammann, W. B. Powers and T. R. Welsh, The Energy Harvesting Eel: a small subsurface ocean/river power generator., *IEEE Journal of Oceanic Engineering* 26(4), 539-547, 2001.
- 5) H. Kim, S. Kang and D. Kim, Dynamics of a flag behind a bluff body., *Journal of Fluids and Structures* 71, 1-14, 2017.
- 6) D. Kim, J. Cossé, C. H. Cerdeira, and M. Gharib, Flapping dynamics of an inverted flag., *Journal of Fluid Mechanics* 736, R1, 2013.
- 7) J. Ryu, S. G. Park, B. Kim and H. J. Sung, Flapping dynamics of an inverted flag in a uniform flow., *Journal of Fluids and Structures* 57, 159-169, 2015.
- 8) K. Shoele and R. Mittal, Energy harvesting by flow-induced flutter in a simple model of an inverted piezoelectric flag., *Journal of Fluid Mechanics* 790, 582-606, 2016.
- 9) Kwon, B., Ejaz, F., and Hwang, L. K., Machine Learning for Heat Transfer Correlations., *International Communications in Heat and Mass Transfer*, 116, 104694, 2020
- 10) M. Babanezhad, I. Behroyan, A. Taghvaie Nakhjiri, M. Rezakazemi, A. Marjani, S. Shirazian, Prediction of turbulence eddy dissipation of water flow in a heated metal foam tube., *Scientific Reports*, 10, 2020, Article 19280
- 11) M. Riedmiller, Advanced supervised learning in multi-layer perceptrons - From backpropagation to adaptive learning algorithms, *Computer Standards & Interfaces* 16, 265-278, 1994.
- 12) L. Breiman, Random forests., *Machine Learning* 45, 5-32, 2001.
- 13) W. S. Noble, What is a support vector machine?., *Nature biotechnology* 24, 1565-1567, 2006.