

2D 평면 트러스 구조물의 예측 성능 향상을 위한 하이퍼파라미터 최적화 연구

노승현*, 이경석*, 이돈우*, 이승재*
*한국기술교육대학교 디자인·건축공학부
e-mail: lov1004ely@koreatech.ac.kr

A Study on the Hyper-parameters Optimization for Improving the Prediction Performance of 2D Plane Truss Structures

Don-Woo Lee*, Seung-Hyun Noh*, Kyung-Seok Lee*, Seung-Jae Lee*
*School of Industrial Design & Architecture Engineering,
Korea University of Technology & Education

요약

건축구조 분야에서 머신러닝의 활용은 많은 연구자의 관심사이며, 특히 하중이 가해지는 상태에서 제약조건을 만족하는 트러스 구조물의 단면을 예측하는 연구가 꾸준히 수행되고 있다. 하지만 대부분의 연구에서는 하이퍼파라미터의 중요성에 언급하지 않고 있으며, 단순히 연구자가 임의로 설정한 값을 사용하여 결과를 도출한다. 하지만 트러스 구조물의 단면 데이터는 비선형성이 강하기 때문에 하이퍼파라미터 값에 따라 머신러닝의 수렴성능이 크게 좌우된다. 따라서 본 논문에서는 트러스 구조물의 예측에 있어 최적의 하이퍼파라미터를 도출할 수 있는 새로운 알고리즘을 제안하고, 기존의 방법들과 비교하여 수렴 성능을 비교 및 분석한다.

1. 서론

트러스 구조물은 경량으로 설계가 가능하여 경제적이고 효율적인 설계가 가능하며, 넓은 공간을 창출할 수 있기 때문에 경기장, 전시장 등의 대형 건축물의 지붕 구조물로 많이 적용되고 있다. 트러스 구조물의 경량 설계를 위해 메타휴리스틱스(meta-heuristics) 알고리즘을 이용하여 최적의 단면적을 찾는 연구가 주로 진행되어 왔으며[1], 최근에는 머신러닝을 활용하여 트러스 구조물의 최적 단면적을 예측하는 연구가 많은 연구자에게 관심을 받고 있다.

단순히 머신러닝을 트러스 구조물의 단면 예측에 활용하는 연구가 주로 수행되고 있으며, 더 나아가 다양한 방법으로 개선된 머신러닝 알고리즘을 이용하여 수렴 성능을 개선하고 있다. 하지만 대부분 하이퍼파라미터의 중요성에 대해 언급되지 않거나 하이퍼파라미터의 최적화를 수행하지 않고 임의의 값을 이용하여 수행한다. 또한, 트러스 구조물의 문제에서 가장 영향이 큰 하이퍼파라미터에 대한 연구가 부족하다.

하이퍼파라미터는 머신러닝 훈련 모델을 구현하기 위해 설정하는 변수들을 의미하며, 모델의 종류에 따라 다양한 파라미터가 존재한다. 하이퍼파라미터는 머신러닝 훈련 모델이 학습하는 방식을 결정하기 때문에 성능 및 학습 과정에 큰 영향을 끼친다. 하이퍼파라미터 최적화를 위해 일반적으로 그리드 서치(Grid search), 랜덤 서치(Random search), 베이시

안 최적화(Bayesian optimization)가 일반적으로 많이 사용된다. 하지만 그리드 서치와 랜덤 서치는 국부 최적화가 많은 문제에서 최적의 결과를 도출하기 어려운 문제를 가지고 있다. 이러한 문제를 해결하기 위해 보완하기 위해 2012년 Snoek et al에 의해 베이시안 최적화라는 개념이 머신러닝에 적용되기 시작하였다[2]. 베이시안 최적화는 앞선 두 방법에 탐색과 개척의 균형 조정으로 인해 최적값에 도달할 가능성을 키우지만, 초기 단계에 따라 성능의 영향이 크고 많은 시간이 소요되기 때문에 새로운 방법이 요구된다.

따라서 본 연구에서는 까마귀 탐색 알고리즘을 하이퍼파라미터 최적화에 적용하고 트러스 구조물의 단면 예측에 있어 더 우수한 성능을 보이는 것을 확인하고자 한다.

2. 하이퍼파라미터 최적화 알고리즘에 따른

2D 평면 트러스 구조물의 예측 성능

2.1 까마귀 탐색 알고리즘을 이용한 최적화 방법

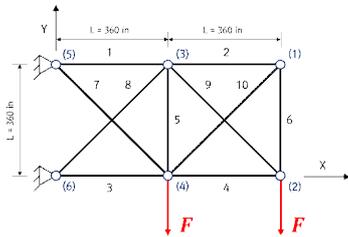
군집(swarm) 기반의 까마귀 탐색 알고리즘은 2016년 Askarzadeh에 의해 제안되었으며, 까마귀의 높은 지능을 이용한 먹이활동을 모티브로 제안된 최적화 알고리즘이다[3]. 까마귀 탐색 알고리즘은 공학 문제에 적용이 쉽고 파라미터의 개수가 적으며, 수렴 성능이 우수하여 다양한 공학 문제의 최적화에 적용되고 있다.

까마귀 탐색 알고리즘은 식(1)과 같이 까마귀의 위치를 초기화하며, AP(awareness probability)에 의해 탐색과 개척이 효율적으로 수행한다. 만약, 무작위 수(r)가 AP보다 크거나 같으면 식(2)에 의해 까마귀 위치는 미세 조정되며, AP보다 작으면 문제의 범위 내에서 무작위 이동을 수행한다. 여기서, x 는 설계 변수, d 는 문제의 차원, N 은 까마귀 군집 수, t 는 현재 세대수, fl 은 비행 거리, m^t 은 현재 세대수에서의 임의 설계변수를 의미한다.

$$Crows = \begin{bmatrix} x_1^1 & \dots & x_d^1 \\ \vdots & \ddots & \vdots \\ x_1^N & \dots & x_d^N \end{bmatrix} \quad (1)$$

$$x^{t+1} = x^t + r \times fl \times (m^t - x^t) \quad (2)$$

2.2 2D 평면 트러스 구조물의 하이퍼파라미터 최적화



[그림 1] 10-bar 트러스 구조물

본 논문에서는 [그림 1]과 같은 2D 평면 트러스 구조물을 대상으로 하였다. 최적 설계를 위한 목적 함수는 식(3)과 같으며, 제약조건에 만족하지 않으면 10^4 의 페널티가 부과된다. 머신러닝을 이용한 역설계가 가능한 데이터 세트 구성을 위해 구조물에 작용하는 하중, 부재의 최대 응력, 절점의 최대 변위를 [표 1]과 같이 다양하게 설정한다.

$$F(x) = \rho \sum_{i=1}^{10} B_i A_i L_i \times f_{penalty} \quad (3)$$

[표 1] 10-bar 트러스 구조물의 데이터 세트 범위

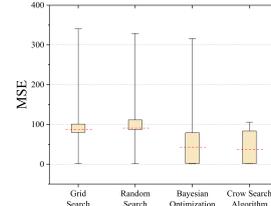
Index	Data range
Load (kips)	10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160
Maximum stress (ksi)	19, 21, 23, 25, 27, 29, 31
Maximum Displacement (mm)	0.5, 10, 1.5, 2.0, 2.5, 3.0, 3.5

위에서 도출된 10-bar 트러스 구조물의 데이터 세트를 이용하여 그리드 서치, 랜덤 서치, 베이지안 최적화, 메타휴리스틱스 알고리즘을 이용하여 하이퍼파라미터 최적화를 수행한다. 각 방법은 회귀 문제에서 가장 많이 사용되는 MSE의 평균값을 이용하여 성능을 비교하며, MSE는 식(4)와 같이 계산할 수 있다. 여기서, m 은 데이터 세트의 수, t_i 는 테스트 값,

p_i 는 예측값을 의미한다. 기본적으로 MSE는 테스트 값과 예측 값의 차이를 이용하기 때문에 0으로 수렴할수록 예측 결과가 우수하다는 것을 의미한다.

$$MSE = \frac{1}{m} \sum_{j=1}^m (t_i - p_i)^2 \quad (3)$$

하이퍼파라미터 최적화를 위해 레이어 수, 뉴런 수, 학습률, L2 정규화 계수, 에포크 수, 활성화함수를 선정한다. 해석을 위해 Matlab R2023a의 Deep learning toolbox, statistics and machine learning toolbox를 이용한다.



[그림 2] 하이퍼파라미터 최적화 결과

결과적으로 메타휴리스틱스 알고리즘을 활용하여 하이퍼파라미터 최적화를 수행하였을 때 가장 평균 MSE가 가장 적게 나왔으며, 최저값과 표준편차 또한 가장 적게 도출되었다.

4. 결론

감사의 글

이 논문은 2023년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. RS-2023-00244008). 또한, 2024년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구사업임(No. RS-2024-00352968).

참고문헌

- [1] Lee, D., Kim, J., Shon, S., & Lee, S., "An Advanced Crow Search Algorithm for Solving Global Optimization Problem", Applied Sciences, Vol.13 No.11, 6628, 2023.
- [2] Snoek, J., Larochelle, H., & Adams, R. P., "Practical bayesian optimization of machine learning algorithms", Advances in neural information processing systems, 25, 2012.
- [3] Askarzadeh, A. "A novel metaheuristic method for solving constrained engineering optimization problems: crow search algorithm", Computers & structures, 169, pp. 1-12, 2016.