

해석 가능한 전력사용량 예측 모델 연구

(A Study on an Interpretable Power Consumption Prediction Model)

양민호*, 최태종**

(Min Ho Yang, Tae Jong Choi)

요약

본 연구는 유전 프로그래밍(Genetic Programming, GP) 기반 기호 회귀(Symbolic Regression, SR)와 신경망 모델(RNN, LSTM, GRU)을 활용하여 전력 사용량 예측의 성능 및 해석 가능성을 비교하고, 해석 가능한 대안적 접근법을 제시하는 것을 목적으로 한다. 기존 신경망 모델은 높은 예측 성능을 보이나 블랙박스 특성으로 인해 변수 간 관계를 명확히 해석하기 어렵다. 반면, GP 기반 SR은 변수 간 관계를 설명하는 명확한 수식을 도출함으로써 모델의 해석 가능성을 크게 향상시킨다. 제조업 공장의 최대 수요 전력 예측 문제를 대상으로 동일한 데이터셋에서 신경망 모델과 SR을 학습한 결과, SR은 신경망 모델보다 우수한 예측 성능과 해석 가능한 수식을 도출하는 특징을 나타냈다. 실험 결과, SR이 예측 성능과 해석 가능성 측면에서 신경망 모델에 비해 유의미한 장점을 가진다는 점을 실증적으로 확인하였다.

■ 중심어 : 유전 프로그래밍 ; 기호 회귀 ; 해석 가능한 인공지능 ; 자원 최적화 ; 신경망

Abstract

This study presents an interpretable alternative approach to power usage prediction by comparing the performance and interpretability of Genetic Programming (GP)-based symbolic regression (SR) and various neural network models (RNN, LSTM, GRU). Although conventional neural network models deliver high prediction accuracy, their black-box nature makes it difficult to clearly interpret the relationships between variables. In contrast, GP-based SR enhances interpretability by generating explicit formulas that describe these relationships. When applied to the maximum demand power prediction problem in a manufacturing plant using the same dataset, SR not only achieved higher prediction performance compared to the neural network models but also provided interpretable formulas. The experimental results empirically confirm that SR offers significant advantages over neural networks in terms of both prediction performance and interpretability.

■ keywords : Genetic Programming ; Symbolic Regression ; Interpretable AI ; Resource Optimization ; Neural Network

I. 서 론

제조업에서 에너지 비용 절감은 기업의 경쟁력 강화와 지속 가능성 확보의 핵심 요소 중 하나이다[1]. 특히 전력 사용 최적화를 통해 생산 공정의 효율성을 향상시키고 에너지 비용 절감 효과를 극대화할 수 있으므로 그 중요성이 더욱 부각된다. 한국전력공사가 제조업체의 연간 전기 요금을 최대 수요 전력을 기준으로 산정하기 때문에[2], 효과적인 전력 관리가 이루

어지지 않으면 불필요한 비용 부담이 발생할 수 있다. 따라서 전력 소비 패턴을 분석하고 신뢰성 높은 예측 모델을 구축하는 것은 에너지 사용 효율화와 운영 비용 절감을 위해 필수적이다.

공장의 전력 소비는 기온, 습도, 생산량, 공장 가동 인원 등 다양한 내·외부 요인의 영향을 받으며, 이들 변수 간의 관계는 복잡한 비선형적 특성을 나타낸다. 전통적인 통계 모델(선형 회귀, ARIMA)은 이러한 복잡성을 반영하는 데 한계가 있어 더욱 정교한 데이터 분석 기법이 요구된다[3]. 최근 인공지능(AI) 기술의

* 정회원, 전남대학교 데이터사이언스대학원 석사과정

** 정회원, 전남대학교 데이터사이언스대학원 부교수

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(RS-2023-00242528).

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(RS-2023-00214326).

접수일자 : 2025년 02월 14일

수정일자 : 2025년 02월 26일

개재확정일 : 2025년 03월 11일

교신저자 : 최태종 e-mail : ctj17@jnu.ac.kr

발전과 함께 딥러닝 기반 시계열 예측 모델이 활발히 연구되었으며, 높은 예측 성능을 보인다[4-6].

RNN, LSTM, GRU 모델은 시계열 데이터의 장기 의존성을 학습하는 데 효과적이며, 다양한 외부 요인을 반영할 수 있어 전력 소비 예측에 널리 활용된다[7-9]. 이들 모델은 주로 기존 통계 모델보다 우수한 성능을 보이며 시계열 분석의 강력한 도구로 자리매김하고 있다. 그러나 신경망 모델은 복잡한 내부 구조로 인해 변수 간 관계를 명확하게 해석하기 어려운 블랙박스(Black-box) 문제를 내포하고 있다[10].

제조업 환경에서는 높은 예측 정확도뿐만 아니라 전력 소비 패턴을 명확히 설명하고, 이를 바탕으로 최적의 운영 전략을 수립할 수 있는 해석 가능성이 요구된다. 비록 신경망 모델이 변수 간 관계를 학습하는 데 뛰어난 능력을 보이지만, 특정 변수가 전력 소비에 미치는 영향을 수식으로 표현하기 어려워 산업 현장에서의 활용에 한계가 있다.

기호 회귀(Symbolic Regression, SR)는 유전 프로그래밍(Genetic Programming, GP) 기반 최적화 기법을 활용하여 독립 변수와 종속 변수 간의 수식을 자동으로 학습하는 방법으로, 블랙박스 모델의 해석 불가능성을 극복할 수 있는 대안이다. 학습된 수식은 직관적으로 해석 가능하며 변수 간 관계를 명확히 설명하는 특징을 가진다.

본 연구에서는 딥러닝 기반 신경망 모델(RNN, LSTM, GRU)과 기호 회귀(SR) 모델을 동일한 데이터셋에서 학습시켜 성능 및 해석 가능성을 비교하였다. 또한, SR 모델이 생성한 수식을 분석하여 신경망 모델이 제공하지 못하는 변수 간 관계를 평가하였다. 실험 결과, SR 모델은 신경망 모델보다 높은 예측 성능을 보였으며, 주요 변수를 자동으로 선택하는 동시에 해석 가능한 수식을 도출하는 특성을 나타냈다. 이러한 분석을 통해 SR이 제조업 공장의 에너지 최적화 및 데이터 기반 의사결정에 신뢰할 수 있는 대안이 될 가능성이 있음을 확인하였다.

II. 이론적 배경

1. 기호 회귀(Symbolic Regression, SR)

기호 회귀는 사전 정의된 함수 형태 없이 데이터를 기반으로 최적의 수식을 탐색하는 기법이다[10]. 기존 회귀 모델과 달리, 데이터에서 함수적 관계를 직접 학습하여 해석 가능한 수식을 생성한다. 즉, 모델 구조가 미리 고정되지 않고, 다양한 연산자(+, -, ×, ÷ 등)와 변수 조합을 활용해 최적의 표현식을 탐색하는 방식이다. 이러한 특징 덕분에 SR은 복잡한 비선형 관계를 포착하면서도 도출된 수식이 직관적이며 해석 가능하다는 장점을 가진다.

2. 유전 프로그래밍 기반 기호 회귀

유전 프로그래밍(GP)은 기호 회귀에 활용되는 대표적인 방법의 하나이다. [11]에 따르면, 기호 회귀 문제 해결에 뛰어난 성능을 보이는 대부분의 모델은 GP를 기반으로 한다. GP는 자연 선택(Natural Selection) 원리를 모방한 최적화 기법으로, 수식을 유전자로 표현하고 진화 과정을 거쳐 최적의 수식을 도출하는 방식으로 작동한다[12].

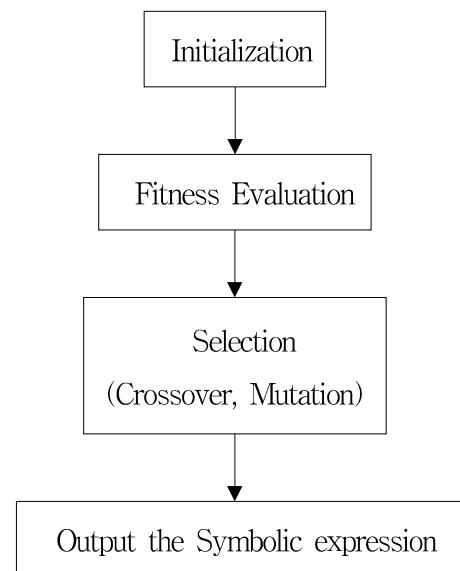


그림 1. GP의 기호 회귀 수행 과정

GP의 기호 회귀 수행 과정은 그림 1과 같이 진행된다. 초기화(Initialization) 단계에서는 사전에 정의된 연산자(+, -, ×, ÷, sin, cos, log 등)와 변수들을 조합하여 초기 후보 수식을 무작위로 생성한다. 이

후 적합도 평가(Fitness Evaluation) 단계에서 각 후보 수식에 대해 데이터셋을 적용하여 예측값과 실제값 간의 차이를 측정하고, 평균 절대 오차(MAE)나 평균 제곱 오차(MSE) 등의 지표를 활용해 성능을 평가한다. 평가 결과를 바탕으로 성능이 우수한 개체를 선택(Selection)하여 새로운 수식을 생성하며, 이 과정에서 교차(Crossover)와 돌연변이(Mutation) 연산이 적용된다. 이러한 과정을 반복하면서 세대를 거듭할수록 최적화된 수식이 도출된다.

GP 기반 SR은 데이터의 특성을 반영한 최적의 수식을 생성할 뿐 아니라, 불필요한 변수를 자동으로 제거하는 기능(Feature Selection)도 수행할 수 있다[13]. 이는 변수 간 관계를 직관적으로 해석할 수 있게 하며, 설명 가능한 AI(Explainable AI) 기법으로서의 강점을 제공한다.

III. 실험 방법

1. 데이터셋 전처리

본 연구에서는 제조업 공장의 최대 수요 전력 예측을 위한 신경망 모델(RNN, LSTM, GRU)과 기호 회귀의 성능 및 해석 가능성을 비교하기 위해 실험을 설계하였다. 실험에 사용된 데이터는 KAIST에서 제공하는 인공지능 제조 플랫폼(KAMP)의 자원 최적화 AI 데이터셋을 사용하였다[14]. 전처리 과정에서 다중 공선성을 줄이기 위해 데이터셋 전체에 걸쳐 유사한 패턴을 보이는 변수(15분, 30분, 45분, 60분 단위 측정 값)은 제거하였으며, 시간당 평균 최대수요전력으로 타겟 변수를 생성하였다. 또한 주말에는 공장 가동이 최소화되므로 주말 데이터를 제거하여 학습 데이터의 품질을 높였다. 독립 변수로는 생산량, 기온, 풍속, 습도, 강수량, 전기요금, 공장 가동 인원, 인건비를 선택하였다. 모든 변수는 MinMaxScalar를 이용하여 0과 1 사이로 정규화하였으며, 데이터는 70:15:15 비율로 훈련, 검증, 테스트 세트로 분할하였다.

2. 신경망 모델 설계

시계열 데이터를 학습할 수 있는 대표적인 신경망 모델인 RNN, LSTM, GRU, 각 모델은 동일한 하이퍼파라미터를 설정하여 공정한 비교를 수행하였다. 신경망 모델의 하이퍼파라미터 설정은 입력층의 차원은 독립 변수의 개수와 동일한 8개로 설정하였으며, 은닉 층은 128개의 뉴런을 갖는 2개의 층으로 구성하였다. 최적화 기법으로는 Adam Optimizer를 사용하였으며, 학습률은 0.001로 설정하였다. 손실 함수로는 MSE를 적용하였다. 배치 크기는 64, 학습 횟수(epoch)는 200으로 설정하여, 신경망 모델이 충분히 데이터를 학습 할 수 있도록 하였다.

3. 기호 회귀 모델 설계

기호 회귀 모델은 유전 프로그래밍을 기반으로 최적의 수식을 탐색하는 방식으로 구현되었다. 연산자는 덧셈, 뺄셈, 곱셈, 나눗셈뿐만 아니라, 제곱근(sqrt), 로그(log), 삼각함수(sin, cos, tan), 절댓값(abs) 등을 포함하여 다양한 비선형 관계를 학습할 수 있도록 구성하였다. 유전 알고리즘의 세대 수(generation)는 30, 개체 수(population size)는 12,000으로 설정하였으며, 교차(crossover), 돌연변이(mutation) 등의 확률은 각각 0.7, 0.3으로 적용하였다. 손실 함수의 경우, 신경망 모델은 MSE를 사용하여 학습하는 것이 일반적이지만, SR은 간결한 수식을 도출하기 위해 MAE를 사용하기 때문에[15], 모델의 적합도 평가는 MAE를 기반으로 수행하였다. 모델이 생성하는 수식의 복잡성을 제어하는 파라미터인 parsimony coefficient는 0.05로 설정하였다[16].

IV. 실험 결과

실험은 신경망 모델과 기호 회귀 모델 모두 10번 독립적으로 반복 수행함으로써 각 모델 성능의 신뢰성을 확보하였다. SR의 경우, random state를 42로 설정하면 실험마다 동일한 수식이 도출되기 때문에, 초

표 1. 신경망 모델과 기호 회귀 모델 성능 비교 () : 10회 실험의 표준편차

Models	R^2	MSE	MAE	RMSE	MAPE
RNN	0.70(0.03)	575.33(59.83)	15.88(1.73)	23.96(1.22)	29.18(3.52)
LSTM	0.79(0.03)	405.94(49.38)	12.34(1.02)	20.12(1.18)	25.64(2.99)
GRU	0.80(0.02)	380.97(40.62)	11.45(1.39)	19.50(1.01)	23.67(3.07)
SR	0.85(0.05)	290.16(94.33)	8.06(3.87)	16.85(2.61)	12.58(5.07)

기예만 적용하였고, 이후 9회의 실험에서는 None 값을 적용하여, 다양한 초기 조건에서 수식을 탐색하도록 하였다. 각 모델에서 10번의 실험을 수행한 후, 도출된 결정계수(R^2), MSE, MAE, 평균 제곱근 오차(RMSE), 평균 절대비율 오차(MAPE)의 평균값을 토대로 성능을 비교하였다.

모델 간 예측 성능 차이가 통계적으로 유의미한지를 검정하기 위해 Diebold-Mariano (DM) 검정을 수행하였다[17]. DM 검정은 두 개의 예측 모델이 통계적으로 유의미한 차이를 보이는지를 평가하는 통계적 방법으로, 본 연구에서는 RNN, LSTM, GRU, SR 모델 간 성능 비교를 위해 활용하였다. 각 실험에서 얻은 10회의 예측 오차(Residuals)를 비교하여 모델 간 성능 차이를 검정하였으며, $p\text{-value} < 0.05$ 인 경우 성능 차이가 유의미하다고 판단하였다. 비교 대상은 RNN vs LSTM, RNN vs GRU, RNN vs SR, LSTM vs GRU, LSTM vs SR, GRU vs SR로 설정하였다.

표 1은 RNN, LSTM, GRU, SR 모델의 평균 성능을 비교한 결과를 나타낸다. 결정계수를 기준으로 평가하

였을 때, 신경망 모델 중에서는 GRU가 0.80으로 가장 높은 설명력을 보였으며, LSTM이 0.79, RNN이 0.70의 값을 기록하였다. 반면, SR은 0.85의 결정계수를 보여 신경망 모델 대비 더 높은 설명력을 가짐을 확인할 수 있다. 또한 MSE와 MAE를 비롯한 모든 평가 지표에서 SR이 신경망 모델보다 낮은 값을 기록하며, 더 정확한 예측 성능을 보였다. 특히 MAPE 지표에서는 SR이 12.58%로, 신경망 모델보다 매우 낮아 실제 값 대비 오차율이 가장 낮은 모델임을 확인할 수 있다.

표 2는 신경망 모델과 SR 모델 간 DM 검정을 수행한 결과를 나타낸다. 실험 총 60개의 비교 중 신경망과 SR을 비교한 30개 실험의 경우, 25개의 실험에서 $p\text{-value}$ 가 0.05 미만을 기록하였다. LSTM과 SR을 비교한 경우, 10개의 실험 모두 통계적으로 유의미한 성능 차이가 확인되었다. 이는 SR이 신경망 모델과 비교하였을 때 단순히 동등한 수준의 성능을 보이는 것 아니라, 대부분의 경우에서 유의미한 성능 향상을 제공함을 시사한다.

표 2 DM 검정 결과 * $P\text{-value} > 0.05$ 로 통계적 유의성이 검증되지 않은 비교

DM Test	RNN,LSTM	RNN,GRU	RNN,SR	LSTM,GRU	LSTM,SR	GRU,SR
1	0.0282	0.0000	0.0000	0.0000	0.0000	0.0102
2	0.0000	0.0000	0.0350	0.0000	0.0033	0.0168
3	0.0000	0.0000	0.4648*	0.7729*	0.0000	0.0000
4	0.0000	0.6834*	0.0000	0.0000	0.0000	0.0000
5	0.0134	0.0000	0.0000	0.0000	0.0000	0.5994*
6	0.0000	0.0000	0.0032	0.0054	0.0083	0.0443
7	0.0000	0.0000	0.0014	0.0001	0.0008	0.1268*
8	0.0209	0.0000	0.0000	0.0000	0.0000	0.1345*
9	0.0017	0.0000	0.3774*	0.0000	0.0073	0.0000
10	0.0000	0.0000	0.0009	0.1195*	0.0000	0.0000

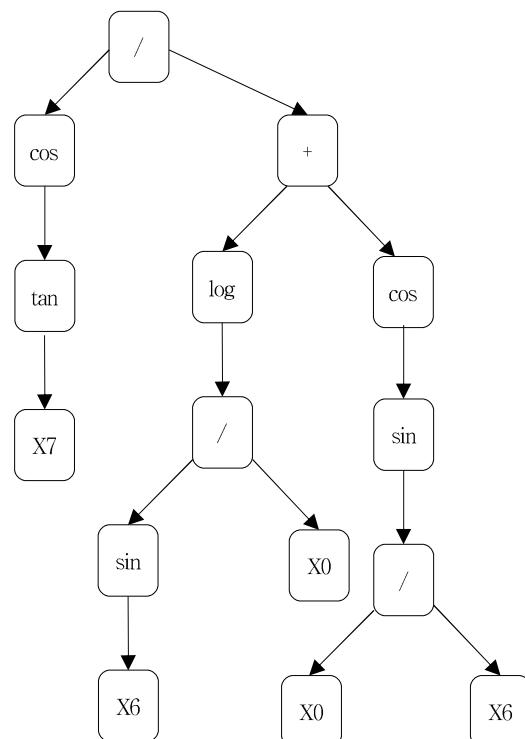


그림 2. 트리 구조로 표현된 수식,
부록의 표1에서 발췌

그림 2에서 SR 모델을 10회 학습한 결과 생성된 수식(부록의 표1 참고) 중 가장 해석가능성이 높은 수식

$$\left(\frac{\log\left(\frac{X0}{\sin(X6)}\right) + \cos(\sin(\frac{X0}{X6}))}{\cos(\tan(X7))} \right)$$

을 트리 구조로 나타내었다. 해당 수식은 시간당 평균 최대수요전력이 $X0$ (생산량), $X6$ (공장 가동 인원), $X7$ (인건비)의 비선형적 결합을 통해 결정됨을 보여준다. 특히, 생산량($X0$)이 $\sin(X6)$ 으로 나누어진 형태는 공장 가동 인원($X6$)이 생산량의 효과를 조정하는 역할을 의미한다. 즉, 동일한 생산량이라도 공장 가동 인원의 변화에 따라 전력 소비량이 달라질 수 있음을 시사한다. 또한, 인건비($X7$)는 분모의 $\cos(\tan(X7))$ 항을 통해 전력 수요에 영향을 미친다. \tan 함수는 특정 주기에서 급격한 변화를 보이는 특성을 가진다. 따라서 인건비가 일정 수준을 초과할 경우, 전력 소비의 변동성이 증가할 가능성이 크다. 이에 따라 공장 운영자는 인건비 변화에 따른 전력 소비 패턴을 면밀히 모니터링하고, 적절한 인력 배치 전략을 고려할 필요가 있다. 한편, SR 모델은 해석 가능성을 높이기 위해 중요한 변수만을 포함하여 최적의 수식을 탐색하는 역할을 수행한다. 도출된

수식에서 생산량, 공장 가동 인원, 인건비가 선택된 것은 데이터가 내재한 비선형 관계를 반영하기 위한 탐색 결과로 해석할 수 있다.

V. 결론

본 연구는 제조업 공장의 전력 수요 예측 문제를 해결하기 위해 신경망 기반 시계열 예측 모델(RNN, LSTM, GRU)과 유전 프로그래밍 기반 기호 회귀 기법(SR)을 비교 분석하였다. 기존 신경망 모델은 높은 예측 성능을 보이나 해석 가능성성이 작아 변수 간 관계를 직관적으로 파악하기 어렵다는 한계를 지닌다. 반면, SR은 유전 프로그래밍을 활용하여 변수 간 관계를 명확한 수식으로 표현함으로써, 모델이 제공하는 인사이트를 산업적 의사결정에 효과적으로 활용할 수 있다.

실험 결과, 유전 프로그래밍은 신경망 모델보다 높은 예측 성능을 보였으며, 주요 변수를 자동으로 선택하고 불필요한 변수를 제거하는 특성을 지닌 것으로 확인되었다. 특히, 유전 프로그래밍이 도출한 수식을 분석한 결과, 생산량, 공장 가동 인원, 인건비 등의 변수가 전력 소비와 밀접한 관계를 맺으며, 비선형적 관계를 포함한 최적의 수식을 도출할 수 있음을 확인하였다. 이러한 결과는 유전 프로그래밍이 신경망 모델보다 예측 성능만 아니라 해석 가능성 측면에서도 유의미한 이점을 제공함을 시사한다.

본 연구에서는 신경망 모델과 유전 프로그래밍을 비교하였지만, 트리 기반 모델(Random Forest, XGBoost, LightGBM 등)도 높은 예측 성능과 부분적인 해석 가능성을 제공하는 기법이므로, 유전 프로그래밍과의 추가적인 비교 연구가 필요하다 [18,19]. 향후 연구에서는 표면처리, 소성가공 등 자원 최적화와 관련된 다양한 데이터셋을 추가하여 모델의 일반성을 강화할 예정이다. 또한, 트리 기반 모델과 SR의 예측 성능 및 해석 가능성을 비교 분석함으로써, 제조업 공장에서 실용적으로 활용할 수 있는 최적의 예측 모델을 탐색할 계획이다.

REFERENCES

- [1] Bensouda, Mehdi, Mimoun Benali, and Youssef Zizi. "Enhancing Corporate Sustainability and Competitiveness through Energy Efficiency: A Literature Review," *Procedia Computer Science*, vol. 241, pp. 266–271, 2024.
- [2] 한국전력공사, 전기요금 제도, 전기요금 제도 이해하기 (2 0 2 5) . https://home.kepco.co.kr/kepco/EB/A/htmlView/EBAAHP002_08.do?menuCd=FN430101 (accessed Feb., 11, 2025).
- [3] Liu, Zhenyu, et al. "Forecast methods for time series data: a survey," *Ieee Access*, vol. 9, pp. 91896–91912, 2021.
- [4] Pushpavalli, M., et al. "Enhancing Electrical Power Demand Prediction Using LSTM-Based Deep Learning Models for Local Energy Communities," *Electric Power Components and Systems*, pp. 1–18, 2024.
- [5] Ni, Zhongjun, et al. "A study of deep learning-based multi-horizon building energy forecasting," *Energy and Buildings*, 303: 113810, 2024.
- [6] Tang, Xin-Yuan, et al. "Deep learning performance prediction for solar-thermal-driven hydrogen production membrane reactor via bayesian optimized LSTM," *International Journal of Hydrogen Energy*, vol. 82, pp. 1402–1412, 2024.
- [7] Amalou, Ibtissam, Naoual Mouhni, and Abdelmounaim Abdali. "Multivariate time series prediction by RNN architectures for energy consumption forecasting," *Energy Reports*, vol. 8, pp. 1084–1091, 2022.
- [8] Eren, Yavuz, and İbrahim Küçükdemiral. "A comprehensive review on deep learning approaches for short-term load forecasting," *Renewable and Sustainable Energy Reviews*, vol. 189, 114031, 2024.
- [9] Chandrasekaran, Radhika, and Senthil Kumar Paramasivan. "Advances in deep learning techniques for short-term energy load forecasting applications: A review," *Archives of Computational Methods in Engineering*, pp. 1–30, 2024.
- [10] Angelis, Dimitrios, Filippos Sofos, and Theodoros E. Karakasidis. "Artificial intelligence in physical sciences: Symbolic regression trends and perspectives," *Archives of Computational Methods in Engineering*, vol. 30, no. 6, pp. 3845–3865, 2023.
- [11] de Franca, Fabricio O., et al. "SRBench++: Principled benchmarking of symbolic regression with domain-expert interpretation," *IEEE transactions on evolutionary computation*, 2024.
- [12] Alhijawi, Bushra, and Arafat Awajan. "Genetic algorithms: Theory, genetic operators, solutions, and applications," *Evolutionary Intelligence*, vol. 17, no. 3, pp. 1245–1256, 2024.
- [13] Zhang, Hengzhe, et al. "SR-Forest: a genetic programming based heterogeneous ensemble learning method," *IEEE Transactions on Evolutionary Computation*, 2023.
- [14] 중소벤처기업부, Korea AI Manufacturing Platform (KAMP), 자원 최적화 AI 데이터셋, KAIST(UNIST, 주유피시엔에스), (2021). <https://www.kamp-ai.kr> (accessed Jan., 10, 2025).
- [15] Aravanis, Theofanis, et al. "Predicting Fish-Mortality: Artificial Neural Networks vs Symbolic Regression," *2023 14th International Conference on Information, Intelligence, Systems & Applications (IISA)*. IEEE, 2023.
- [16] gplearn, API reference, Symbolic Regression (2 0 1 6) . <https://gplearn.readthedocs.io/en/stable/reference.html> (accessed Jan., 20, 2025).
- [17] Maiti, Reetun, Balagopal G. Menon, and Anand Abraham. "Ensemble empirical mode decomposition based deep learning models for forecasting river flow time series," *Expert Systems with Applications*, vol. 255, 124550, 2024.
- [18] Simaiya, Sarita, et al. "A transfer learning-based hybrid model with LightGBM for smart grid short-term energy load prediction," *Energy Exploration & Exploitation*, vol. 42, no. 5, 2024.
- [19] Hissou, Hasna, et al. "A lightweight time series method for prediction of solar radiation," *Energy Systems*, pp. 1–38, 2024.

저자소개

**양민호(정회원)**

2023년 전남대학교 농업경제학과 학
사 졸업.

2023년~현재 전남대학교 데이터사이
언스대학원 석사과정.

<주관심분야 : 인공지능, 자원 최적
화, 딥러닝, 기호 회귀>

**최태종(정회원)**

2017년 성균관대학교 전기전자컴퓨터
공학과 박사 졸업.

2020년~2022년 경일대학교 컴퓨터사
이언스학부 조교수.

2022년~현재 전남대학교 데이터사이
언스대학원 부교수.

<주관심분야 : 인공지능, 머신러닝,
딥러닝, 진화연산>

부록

표 1. SR 생성 수식

	SR 생성 수식
1	$((\frac{X0}{X6}) + \tan(X7) - (\frac{X6}{X0} + \sin(\sqrt{\log(\tan(\tan(X7)))})) + \cos(\tan(X7)) + (X1 + \tan(\tan(X7))))$
2	$(\sqrt{\tan(\log(\frac{X6}{X0}))} + \cos(\sqrt{\frac{X6}{X0}} + 0.573)) * (\tan(\tan(X7)) - \tan(\tan(\sin(\sqrt{\frac{X6}{X0}}))) - \tan(\log(\frac{X6}{X0})))$
3	$(\frac{\tan(X0)*\sin(-0.062)}{\tan(X0)*\log(\sin(-0.062))} + \tan(\tan(\cos(\frac{X6*\log(0.945)}{\cos(\frac{\log(0.094)}{\sin(-0.062)})})))) + \frac{\log(0.094)}{\sin(-0.062)}$
4	$\frac{\log(\frac{X0}{\sin(X6)}) + \cos(\sin(\frac{X0}{X6}))}{\cos(\tan(X7))}$
5	$\cos(\cos(\frac{-0.062*X0}{X6}))*\cos(\cos(\frac{0.853*X0}{X6}))*\frac{\tan(\tan(X7))}{\cos(\log(\sin(\frac{X6}{X0})))}$
6	$\frac{\sin(\tan(\tan(-0.868)))*\log(0.987)}{X0*X6}$
7	$\frac{\tan(\left \frac{X6}{X0} + \cos(\log(\tan(\log(X7 + X7 + \tan(\tan(X7))))))\right)}{\tan(\left \log(\frac{X6}{X0})\right) + \log(\tan(\log(\tan(\log(\frac{X6}{X0})))) + \tan(\tan(X7)) + \cos(\sqrt{\log(\tan(\frac{X6}{X0}))}))}$
8	$\frac{(\tan(\tan(X7)) + \log(\log(\frac{X0}{X6})*X0) + \frac{X0}{X6}) + \log(\log(\cos(\log(\frac{X0}{X6}))))}{\tan(\tan(\tan(X7)) + \log(\frac{X0}{X6})) + \cos(\sqrt{\log(\frac{X0}{X6})})}$
9	$\log(\sqrt{\log(\frac{X6}{X0})}) + \cos(\frac{X6}{X0} * \cos(\sqrt{\sqrt{\log(\frac{X6}{X0})}})) + \left \sqrt{\frac{\tan(\tan(X7))}{\cos(\log(\frac{X6}{X0}))}} + \left \cos(\frac{X6}{X0}) \right * \left \frac{\tan(\tan(X7))}{\cos(\sqrt{\log(\frac{X6}{X0})})} \right \right $
10	$\tan(\tan(X7)) * \left(\tan(\cos((\sqrt{\frac{X6}{X0}} + \sqrt{\frac{\sqrt{\sqrt{X0}}}{\sqrt{X0}}} + \sqrt{\sqrt{X0}}) + \sin(\sqrt{\sqrt{\tan(\cos((\sqrt{\sqrt{\sqrt{\cos(\tan(X4) + X7)} + X7}) * \frac{X6}{X0}))) * \frac{X6}{X0}}})) \right) + \tan(\cos((\sqrt{\sqrt{0.943}} + X7) * \frac{X6}{X0})) \right)$