

# 로직에 기반 한 트리 구조의 퍼지 뉴럴 네트워크를 이용한 복합 화력 발전소의 출력 예측

## Output Power Prediction of Combined Cycle Power Plant using Logic-based Tree Structured Fuzzy Neural Networks

한 창 옥\*, 이 돈 규\*

Chang-Wook Han\*, Don-Kyu Lee\*

### Abstract

Combined cycle power plants are often used to produce power. These days prediction of power plant output based on operating parameters is a major concern. This paper presents an approach to using computational intelligence technique to predict the output power of combined cycle power plant. Computational intelligence techniques have been developed and applied to many real world problems. In this paper, tree architectures of fuzzy neural networks are considered to predict the output power. Tree architectures of fuzzy neural networks have an advantage of reducing the number of rules by selecting fuzzy neurons as nodes and relevant inputs as leaves optimally. For the optimization of the networks, two-step optimization method is used. Genetic algorithms optimize the binary structure of the networks by selecting the nodes and leaves as binary, and followed by random signal-based learning further refines the optimized binary connections in the unit interval. To verify the effectiveness of the proposed method, combined cycle power plant dataset obtained from the UCI Machine Learning Repository Database is considered.

### 요 약

오늘날 복합 화력 발전소는 전력 생산을 위해 많이 사용되고 있고, 최근에는 운전 매개 변수를 기반으로 발전 출력을 예측하는 것이 주요 관심사이다. 본 논문에서는 복합 화력 발전소의 출력을 예측하기 위해 컴퓨터 지능 기법을 이용하는 방법을 제시한다. 컴퓨터 지능 기술은 지속적으로 발전되어 많은 실제 문제에 적용되어 왔다. 본 논문에서는 트리 구조의 퍼지 뉴럴 네트워크를 이용하여 발전 출력을 예측하고자 한다. 트리 구조의 퍼지 뉴럴 네트워크는 퍼지 뉴런을 노드로 선택하고 관련 입력을 최적으로 선택하여 규칙 수를 줄이는 장점이 있다. 네트워크의 최적화를 위해 2 단계 최적화 방법이 사용된다. 유전 알고리즘은 최적의 노드와 리프를 선택하여 네트워크의 이진 구조를 최적화 한 다음 랜덤 신호 기반 학습을 수행하여 최적화 된 이진 연결을 단위 구간에서 미세 학습한다. 제안 된 방법의 유용성을 검증하기 위해 UCI Machine Learning Repository Database에서 얻은 복합 화력 발전소 데이터를 사용한다.

*Key words* : fuzzy neural networks, combined cycle power plant, output power prediction

\* Dept. of Electrical Engineering, Dong-Eui University

★ Corresponding author

E-mail : donkyu@deu.ac.kr, Tel : +82-51-890-1666

※ Acknowledgment

This work was supported by Dong-Eui University Grant.(201802980001)

Manuscript received, Jun. 9, 2019; revised, Jun. 13, 2019; accepted, Jun. 17, 2019.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

## I. 서론

실제 세계의 문제를 모델링하는 것이 점점 더 복잡해짐에 따라 그 요구 사항을 충족시키기 위해 보다 강력한 모델링 기술이 필요하다. 이로 인해 컴퓨터 지능 기반 모델링 기술이 개발되어 많은 연구가 논의되고 실제 문제에 적용되어 왔다[1-3].

본 논문에서는 트리 구조의 퍼지 뉴럴 네트워크[4]를 복합 화력 발전소의 발전 출력 예측에 적용하였다. 데이터 세트는 복합 화력 발전소가 최대 부하에서 674일 동안 작동하도록 설정된 경우 수집된 9568 개의 데이터 포인트로 구성된다. 데이터 세트는 다양한 주변 조건에서 6년 동안 수집되었다.

트리 구조의 퍼지 뉴럴 네트워크는 퍼지 뉴런을 노드로 선택하고 관련 입력을 최적으로 선택하여 규칙 수를 줄이는 장점이 있다. 네트워크의 최적화를 위해 2단계 최적화 방법이 사용되었다. 유전 알고리즘(Genetic Algorithm, GA)[5]은 최적의 노드와 리프를 선택하고 랜덤 신호 기반 학습(Random Signal-based Learning, RSL)[6]은 GA를 이용해 최적화된 네트워크의 이진 구조를 기반으로 연결 강도를 단위 구간 내에서 더욱 미세 학습한다. 제안된 방법의 적용 가능성을 보이기 위해 UCI Machine Learning Repository Database 에서 얻은 복합 화력 발전소 데이터 세트가 사용된다.

## II. 본론

### 1. 트리 구조의 퍼지 뉴럴 네트워크

본 논문은 [4]에서 저자가 제안한 트리 구조의 퍼지 뉴럴 네트워크를 복합 화력 발전소의 출력 전력 예측에 적용하였다. 따라서 본 논문에서는 [4]의 트리 구조 퍼지 뉴럴 네트워크와 최적화 방법을 동일하게 사용 하였으며, 이러한 이유로 본 절의 모든 부분은 [4]를 직접 참조하였다(트리 구조의 퍼지 뉴럴 네트워크에 대한 자세한 내용은 [4]를 참조하기 바람).

트리 구조 퍼지 뉴럴 네트워크의 상세한 구조와 전체 네트워크에 대해 학습을 진행하기 전에 [4]에서 소개된 바와 같이 로직 기반 뉴런의 두 가지 기본 유형을 간략히 설명하고자 한다.

AND 뉴런은 먼저 입력 신호(멤버십 값)  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_n]$ 와 조정 가능한 연결(가중치)  $\mathbf{w} =$

$[w_1 \ w_2 \ \dots \ w_n] \in [0, 1]^n$  을 개별적으로 결합한 다음, 이 결과를 전역 적으로 식 (1)과 같이 AND 연산한다[4].

$$y = AND(x;w) = T_i^n(w_i s_i x_i) \quad (1)$$

여기서  $w$ 는 조정 가능한 연결 (가중치)의 n 차원 벡터를 나타낸다. “s”는 s-norm을 나타내고 “t”는 t-norm을 나타낸다. 개별 입력  $x$ 는 s-norm을 이용하여 해당 가중치와 or 결합되며, 이렇게 개별적으로 생성된 결과들은 t-norm을 이용하여 and 결합된다.

AND 뉴런에서 t-norm과 s-norm의 순서를 바꾸면 OR 뉴런을 식 (2)와 같이 나타낼 수 있다.

$$y = OR(x;w) = S_i^n(w_i t_i x_i) \quad (2)$$

AND 및 OR 뉴런은 멤버십 값에 대해 순수한 로직 연산을 구현한다.

퍼지 뉴런에 대한 몇 가지 분명한 점은 아래와 같다.

- 이진 입력 및 연결의 경우, 뉴런은 표준 AND 및 OR 게이트로 변환된다.
- 0 (1)에 가까운 연결은 AND (OR) 뉴런으로의 관련 입력의 영향을 향상시킨다.
- 파라미터(연결 강도)의 유연성은 네트워크 설계에 이용되는 중요한 특징이다.

본 논문의 모든 실험에서 퍼지 뉴런 연산을 위해 곱 연산( $a \ t \ b = ab$ )과 확률적 합( $a \ s \ b = a + b - ab$ )을 각각 사용한다.




Fig. 1. Basic structure of tree structured fuzzy neural networks.  
그림 1. 트리 구조의 퍼지 뉴럴 네트워크 기본 구조

그림 1은 로직 기반 트리 구조 퍼지 뉴럴 네트워크의 구조를 보여준다. 여기서 노드의 “\*”는 AND 뉴런을 “+”는 OR 뉴런을 나타낸다. 이 구조에서 각

노드는 AND 또는 OR 퍼지 뉴런을 선택하고, 리프 (Leaves)는 입력을 선택한다. 그림 1에서 보는바와 같이 트리 구조 퍼지 뉴럴 네트워크는 불필요한 연결을 제거하고, 적절한 "Level"을 선택함으로써 원하는 로직을 표현할 수 있는 유연한 구조를 갖는다.

## 2. 네트워크 최적화

### 가. 유전 알고리즘

유전 알고리즘(GA)은 자연 선택과 진화 유전학에 기반 한 탐색 알고리즘이다. 개체군의 개체라고 불리는 임의의 문자열에서 시작하여 유전 연산자를 통해 세대를 반복하게 된다.

기존의 GA에는 세 가지 기본 연산자가 있다. 즉, 선택, 교차 및 돌연변이이다. 선택 확률은 문자열의 적합도 값에 비례한다. 이를 위해 다음과 같은 적합도 함수를 사용하여 각 개체에 대한 적합도를 계산한다.

$$F = \frac{1}{1+Q} \quad (3)$$

여기서 Q는 성능 지수이다. 교차는 두 개체의 유전 정보를 교환함을 의미한다. 임의로 선택된 두 개체의 정보는 교차 위치에서 부분적으로 상호 교환된다. 교차는 부모세대에서 정보를 교환하여 자식세대에게 물려주기 위해 적용되며, 교차 확률에 따라 수행 빈도가 정해진다. 돌연변이는 연산자는 새로운 유전자 또는 유전 정보 다양성의 원천이 될 수 있다. 돌연변이는 검색 공간을 통해 무작위적으로 수행되기 때문에 아주 낮은 빈도로 사용되어야 한다.

### 나. 랜덤 신호 기반 학습

랜덤 신호 기반 학습 (RSL)은 다음과 같은 형태로 표현되는 강화 학습의 일종이다.

$$weight(t+1) = weight(t) + \eta r(t) f(n(t)) \quad (4)$$

여기서  $\eta$ 는 학습율,  $f()$ 는 식 (6)과 같은 활성화 함수,  $n(t)$ 는  $[-1, 1]$ 의 값을 갖는 이산 랜덤 함수,  $r(t)$ 는 다음과 같이 정의되는 강화 신호이다.

$$r(t) = \begin{cases} 1 & \text{if } \Delta Q < 0 \\ 0 & \text{if } \Delta Q \geq 0 \end{cases} \quad (5)$$

여기서  $\Delta Q$ 는 나중에 정의될 성능 지수의 변화

이다. 이 학습법에서 시냅스는 학습 후 성능 지수가 감소할 때만 학습한다( $r(t)=1$ ). 그렇지 않으면 학습이 거부된다( $r(t)=0$ ). 활성화 함수  $f()$ 는 양극성 시그모이드(sigmoid) 함수이며, 다음 식과 같다.

$$f(x) = \frac{2}{1+e^{-\lambda x}} - 1 \quad (6)$$

RSL의 주요 아이디어는 이산 랜덤 함수  $n(t)$ 가 최적의 상태를 찾기 위해 학습 속도 범위에서 랜덤하게 상태를 움직인다는 것이다. RSL은 최적 해가 매우 빠르게 성능 지수가 감소하는 방향으로 이동하기 때문에 지역 최적해를 찾는 데 매우 효과적이다.

### 다. 2단계 최적화

퍼지 규칙의 지수함수적 증가에 따른 문제를 해결하기 위해 GA는  $\{0, 1\}$ 을 포함한 입력을 리프로 선택하고, 트리 구조를 형성하는 퍼지 뉴런을 노드로 선택하여 트리 구조의 퍼지 뉴럴 네트워크의 이진 구조를 만든다. 이후 RSL에 의해 각 노드에 접속된 연결 강도는 미세 학습된다. RSL은 최적해가 성능 지수 감소 방향으로 매우 빨리 움직이기 때문에 지역 최적해를 찾는 데 매우 효과적인 강화 학습 알고리즘이다.

GA 최적화 동안, 앞에서 언급한 것처럼 퍼지 뉴런의 특성 때문에 AND 및 OR 뉴런에 대한 연결은 각각 0과 1로 설정된다. RSL 미세 학습은 GA에서 최적화된 이진 연결을 단위 구간간의 연결 강도로 변환하는 것이다. RSL 미세 학습은 트리 연결만을 고려하고, 값이 0 또는 1인 리프에 의해 발생하는 제거된 연결은 고려하지 않는다. 이 미세 학습은 성능 지수의 값을 더욱 낮추는 것을 목표로 한다.

## 3. 실험 및 결과분석

본 실험에는 Irvine에 있는 University of California의 Machine Learning Repository 사이트에서 이용 가능한 복합 화력 발전소 데이터 세트를 사용하였다. 데이터 세트는 복합 화력 발전소가 최대 부하에서 674 일 동안 작동하도록 설정된 경우 수집된 9568 개의 instance와 4 개의 attribute로 구성된다. 데이터 세트는 다양한 주변 조건에서 6년 동안 수집되었으며, attribute에 대한 설명은 다음과 같다.

특징 벡터는 시간당 평균으로 구해짐.

- 1.81~37.11 °C 범위의 온도 (T)
- 992.89~1033.30 milibar 범위의 주변 압력 (AP)
- 25.56~100.16 % 범위의 상대 습도 (RH)
- 25.36~81.56 cmHg 범위의 배기 진공 (V)
- 420.26~495.76 MW 범위의 매시간 전기 에너지 출력 (EP)

트리 구조의 퍼지 뉴럴 네트워크를 실험하기 위해 5개의 Gaussian 멤버십 함수 (overlap : 0.5)를 사용하였다. 중복된 정보를 줄이기 위해 각 노드의 입력 수는 2로 고정되며(고차원의 문제에 대해 증가될 수 있음), 본 실험에서 적절한 레벨의 수 (Number of Level, NL)을 찾기 위해 NL의 수만 2에서 4까지 변화시켰다. 데이터의 70 %는 트레이닝으로 사용되었으며, 나머지 30 %는 테스트용으로 사용되었다. GA는 노드와 리프를 최적으로 선택하여 이진 구조를 만들고, RSL은 이진 연결을 단위 구간 내에서 더욱 미세학습하였다. 본 실험에 사용한 파라미터 값들은 [4]와 동일하다.

신뢰성 있는 결과를 얻기 위해 서로 다른 트레이닝 및 테스트 데이터 세트를 사용하여 20번의 독립적인 실험을 수행하였다. 표 1과 2는 20번의 독립적인 실험에서 트레이닝 데이터와 테스트 데이터에 대한 평균 오차(RMSE)를 각각 보여준다. 표 1, 2에서 보는 바와 같이 GA 최적화 후 RSL을 수행하여 평균 오차가 줄어들었으며, NL의 수가 증가할수록 평균 오차가 줄어들음을 알 수 있다. 또한 평균 규칙의 수는 NL의 수가 증가할수록 늘어남을 볼

Table 1. Average performance index(RMSE) and number of rule for training data.

표 1. 트레이닝 데이터에 대한 평균 오차 및 규칙의 수

	NL=2	NL=3	NL=4
After GA	0.097	0.092	0.085
After RSL	0.091	0.082	0.079
No. of rule	5.1	9.6	13.7

Table 2. Average performance index(RMSE) and number of rule for testing data.

표 2. 테스트 데이터에 대한 평균 오차 및 규칙의 수

	NL=2	NL=3	NL=4
After GA	0.112	0.099	0.090
After RSL	0.096	0.091	0.083
No. of rule	5.1	9.6	13.7

수 있는데, 이는 고차의 복잡한 문제에서는 NL의 크기를 적절히 증가시켜야함을 알 수 있다. 표 1, 2의 결과에서 볼 수 있듯이 트리 구조의 퍼지 뉴럴 네트워크는 복합 화력 발전소의 발전 출력을 적절한 오차 내에서 예측함을 볼 수 있다.

$$Q = \sqrt{\frac{1}{N} \sum_{i=1}^N (F_i - O_i)^2}, \text{ (RMSE)} \quad (7)$$

$F_i$  : 예측모델에 의한 예측값     $O_i$  : 실제값

$N$  : 데이터의 수

### III. 결론

본 논문에서는 복합 화력 발전소의 출력을 예측하기 위해 트리 구조의 퍼지 뉴럴 네트워크를 사용하였다. 트리 구조의 퍼지 뉴럴 네트워크는 퍼지 뉴런을 노드로 선택하고 관련 입력을 최적으로 선택하여 퍼지 규칙의 수를 줄이는 이점이 있다. 네트워크의 최적화를 위해서는 2단계 최적화 방법이 사용되었다. 유전 알고리즘으로 최적의 노드와 리프를 선택하여 네트워크의 이진 구조를 최적화 한 다음 랜덤 신호 기반 학습을 수행하여 이전 단계에서 최적화된 이진 연결을 단위 구간 내에서 더욱 미세 학습하였다. 제안된 방법의 적용 가능성을 보이기 위해 UCI Machine Learning Repository Database에서 얻은 복합 화력 발전소 데이터 세트가 사용되었다. 실험 결과에서 볼 수 있듯이 트리 구조의 퍼지 뉴럴 네트워크는 복합 화력 발전소의 발전 출력을 적절한 오차 내에서 예측함을 볼 수 있다.

### References

- [1] P. Tufekci, "Prediction of full load electrical power output of a base load operated combined cycle power plant using machine learning methods," *Electrical Power and Energy Systems*, vol.60, pp.126-140, 2014.  
DOI: 10.1016/j.ijepes.2014.02.027
- [2] H. Kaya, P. Tufekci and F. Gurgen, "Local and Global Learning Methods for Predicting Power of a Combined Gas & Steam Turbine," in *Proc. of the Int. Conf. on Emerging Trends in*

*Computer and Electronics Engineering*, pp.13-18, 2012.

[3] M. Rashid, K. Kamal, T. Zafar, Z. Sheikh, A. Shah and S. Mathavan, "Energy Prediction of a Combined Cycle Power Plant using a Particle Swarm Optimization Trained Feed Forward Neural Network," in *Proc. of the Int. Conf. on Mechanical Engineering, Automation and Control Systems*, 2015. DOI: 10.1109/MEACS.2015.7414935

[4] C. W. Han, "Developing a Tree Structures of Fuzzy Controller," *Advanced Science and Technology Letters*, vol. 139, pp. 439-442, 2016.


[5] *D.E. Goldberg, Genetic algorithms in search, optimization and machine learning*, Reading, MA: Addison-Wesley, 1989.

[6] C. W. Han, J. I. Park, "A Study on Hybrid Random Signal-based Learning and Its Applications," *International Journal of Systems Science*, vol.35, no.4, pp.243-253, 2004.

DOI: 10.1080/00207720410001714149

## BIOGRAPHY

### Chang-Wook Han (Member)



1994 : BS degree in Electronic Engineering, Yeungnam University.  
 1996 : MS degree in Electronic Engineering, Yeungnam University.  
 2002 : PhD degree in Electronic Engineering, Yeungnam University.  
 2008 ~ : Professor in Electrical Engineering, Dong-Eui University.

### Don-Kyu Lee (Member)



2002 : BS degree in Electrical Engineering, Pusan National University.  
 2004 : MS degree in Electrical Engineering, Pusan National University.

2007 : PhD degree in Electrical Engineering, Pusan National University.

2008 ~ : Professor in Electrical Engineering, Dong-Eui University.