Regular paper

Journal of the KIECS. pp. 841-852, vol. 18, no. 5, Oct. 31. 2023, t. 121, pISSN 1975-8170 | eISSN 2288-2189
http://dx.doi.org/10.13067/JKIECS.2023.18.5.841

심층신경망 기법을 이용한 재열 가스터빈 입구온도 예측모델에 관한 연구

한영복* · 김성호** · 김변곤***

Study on the Prediction Model of Reheat Gas Turbine Inlet Temperature using Deep Neural Network Technique

Young-Bok Han* · Sung-Ho Kim** · Byon-Gon Kim***

요 약

국내 전력계통의 주파수 조정용 발전기로 사용되고 있는 가스터빈은 탄소중립 정책과 더불어 신속한 기동·정지 및 높은 열효율 등으로 인해 이용률이 증가하고 있다. 가스터빈은 고온의 화염을 이용하여 터빈을 회전시키기 때문에 터빈 입구온도가 기기의 성능과 수명을 좌우하는 핵심요소로 작용하고 있다. 하지만 입구온도는 직접적인 측정이 불가능함에 따라 제작사가 산출한 온도를 이용하거나, 현장 경험을 토대로 하여 예측된 온도를 적용하고 있어서 가스터빈의 안정적인 운전 및 유지관리에 많은 어려움을 겪고 있다. 이에 본 연구에서는 인공신경망에서 많이 사용되고 있는 DNN(: Deep Neural Network) 기반으로 하는 재열 가스터빈의 입구온도를 예측할 수 있는 모델을 제시하고 실측 데이터를 기반으로 제안된 DNN의 성능을 검증하고자 한다.

ABSTRACT

Gas turbines, which are used as generators for frequency regulation of the domestic power system, are increasing in use due to the carbon-neutral policy, quick startup and shutdown, and high thermal efficiency. Since the gas turbine rotates the turbine using high-temperature flame, the turbine inlet temperature is acting as a key factor determining the performance and lifespan of the device. However, since the inlet temperature cannot be directly measured, the temperature calculated by the manufacturer is used or the temperature predicted based on field experience is applied, which makes it difficult to operate and maintain the gas turbine in a stable manner. In this study, we present a model that can predict the inlet temperature of a reheat gas turbine based on Deep Neural Network (DNN), which is widely used in artificial neural networks, and verify the performance of the proposed DNN based on actual data.

키워드

Artificial Neural Network, Reheat Cycle Gas Turbine, Inlet Temperature, Deep Neural Network, Combustion Chamber
인공 신경망, 재열 가스터빈, 입구 온도, 심층 신경망, 연소실

* 한국중부발전 보령본부(hanyb67@komipo.co.kr)
** 교신저자 : 군산대학교 전자정보공학부
*** 군산대학교 전자공학과(bgkim@kunsan.ac.kr)
· 접 수 일 : 2023. 08. 18
· 수정완료일 : 2023. 09. 14
· 게재확정일 : 2023. 10. 17
· Received : Aug. 18, 2023, Revised : Sep. 14, 2023, Accepted : Oct. 17, 2023
** Corresponding author : Sung-Hoo Kim
School of IT Information & Control Engineering, Kunsan National University,
Email : shkim@kunsan.ac.kr

Ⅰ. 서 론

국내 전력계통망에 연계된 가스터빈 발전기는 150기 이상 운용되고 있으며, 기동 후 30분 이내에 계통 병입이 가능하기 때문에 전력망에서 첨두부하를 담당하거나 발전출력의 응동성이 뛰어나 주파수 조정용으로 사용되고 있다[1]. 가스터빈은 증기터빈과 조합되어 1차적으로 가스터빈에서 전기를 생산한 후 배열을 이용하여 생산된 증기를 이용하여 2차로 전기를 생산하는 복합발전 방식을 운용하고 있다.

발전용 가스터빈은 GE, SIEMENS, MHPS 등 3대 기업이 글로벌 시장의 80% 이상을 과점해 오고 있으며 사용수명은 30~35년 정도이다. 가스터빈은 성능과 수명유지를 위해 주요부품을 주기적으로 교체하고 있지만, 제작사간의 호환이 안되기 때문에 독점이며 유지관리 비용이 많이 들고 있다. 또한 제작사의 기술유출방지 정책으로 인해 설계·생산에 대한 원천기술 확보도 어렵고, 유지관리에 대한 전문적인 기술도 공유하지 않고 있어서 연소튜닝 기술도 제작사에 의존하는 경향이 높은 설비이기도 하다. 연소튜닝에서 가장 중요한 가스터빈 입구온도 산출과 관련된 연구로는 경험을 토대로 하여 공연비를 이용하여 입구온도를 계산하거나. 데이터 필터링 기법인 칼만필터를 이용한 단순 사이클 방식의 가스터빈의 입구온도를 산정하는 방법 등이 제안되었다[2].

이에 본 연구에서는 제작사에 의존하고 있는 가스터빈 입구온도 예측 방식에 대해 인공신경망의 한 종류인 심층신경망 기법을 이용하여 재열 가스터빈의 입구온도를 예측할 수 있는 심층신경망 모델을 개발하고자 한다. 이를 위해 심층신경망 모델을 설계하고 학습과정과 분석을 통해 모델별 특징을 살펴보고 예측모델에 대한 검증시험과 실증시험을 수행하고자 한다. 이러한 과정을 거쳐 최적화된 예측모델을 개발하여 산업현장에서 전문가가 아니더라도 간편하게 사용할 수 있는 인공신경망 모델을 제시하여 자체적으로 연소튜닝을 수행하는데 도움이 되고자 한다.

Ⅱ. 재열 가스터빈

2.1 재열 가스터빈

재열 가스터빈은 하나의 축에 연소실과 터빈이 고압·저압으로 분리되어 운전되는 2단 연소방식이라는 특징을 제외하면 단순 사이클 방식의 가스터빈과 동일하다고 볼 수 있다. 재열 가스터빈은 압축기, 연소기, 터빈으로 구성되어 있으며 브레이튼 사이클의 등압 연소 사이클이다. 가스터빈은 압축기로 공기를 압축한 후 연소기로 보내지며 연소기에서 연료와 함께 생성된 고온·고압의 연소가스가 팽창하면서 터빈의 회전날개에 충동·반동력을 주어 기계적인 에너지로 변환한다. 이 에너지는 터빈 축과 연결된 압축기와 발전기 로터를 구동하며 발전기의 회전력으로 전기가 생산된다. 재열 가스터빈은 고압 연소실에서 생성된 화염으로 고압터빈을 회전시키며, 고압터빈에서 배출된 열 가스는 저압 연소실에 유입되며 저압 연소실에 공급된 연료와 함께 한번 더 연소되어 저압터빈을 회전시키는 방식이다.

재열 가스터빈은 단순 사이클 방식과 비교했을 때 HRSG(: Heat Recovery Steam Generator)로 유입되는 배기가스 온도가 높아 종합 열효율은 약간 높으며, 대기로 배출되는 NOx의 농도는 2~3배 낮은 특징을 가지고 있다. 또한 단순 사이클에 비하여 동일한 열량을 가할 경우, 연소실의 최고온도를 조금 낮게 할 수 있어서 가스터빈 날개의 열 부하를 경감하여 기기의 수명 및 효율을 높일 수 있는 장점이 있다[3]. 그러나 2단연소 방식의 구성에 따라 연소기의 구조 및 연료 공급의 유로, 공기 냉각방식 등이 매우 복잡하다. 또한 연소방식의 구조적인 특성으로 인해 기동·정지 과정에서 화염의 불안정 가능성이 매우 높고 연소튜닝이 어려워 튜닝기간이 길어지는 단점이 있다.

2.2 재열 가스터빈 연소방식

단순 사이클 방식의 가스터빈과 2단 연소방식의 재열 사이클 가스터빈의 H-S(엔탈피-엔트로피) 선도를 비교해 보면 그림 1과 같다.

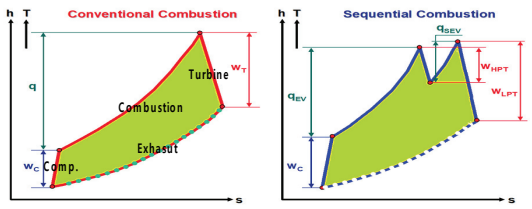

그림 1. 단순 사이클 및 재열 사이클 가스터빈 H-S선도
Fig. 1 Simple cycle & reheat cycle gas turbine H-S diagram

재열 사이클방식의 가스터빈은 고압연소기인 EV(: EnVironmental) 연소기로부터 열량 Q_{EV}를 가하면 1단계 연소된 가스가 고압 가스터빈에서 일 W_{HPT}를 한다. 고압터빈에서 팽창되어 온도가 낮아진 연소가스에 저압연소기인 SEV(: Sequential EnVironmental)에서 다시 Q_{SEV}의 열량을 가하여 2단계 연소가 이루어져 저압터빈에서 일 W_{LPT}을 한번 더 하는 방식이다. 즉 고압 연소기에서 점화 후 Pilot 연소가 시작되어 계통 병입이 이루어진다. 출력이 증발되면 희박연소 방식의 EV 연소가 이루어지며 Pilot 연소는 소화가 이루어지는 방식이다. EV로 연소전환이 이루어지면 저압터빈의 SEV 연소가 이루어지고 질소산화물 배출량 감소 위주의 예혼합 연소로 방식으로 운전되는 방식이다.

가스터빈 압축기의 압축공기의 후단온도는 530℃~540℃로서 높기 때문에 압축기에서 추기한 냉각용 공기를 직접 사용하지 못하고 열교환기를 통해 340~360℃까지 냉각하여 가스터빈의 블레이드 및 베인 등에 공급한다. 압축공기의 냉각을 위해 사용 되어진 물은 열교환기를 거치면서 포화증기로 변환되어 HRSG를 거치면서 과열증기가 되어 증기터빈을 회전시키는 동력원이 된다[4].

2.3 재열 가스터빈 연소제어

가스터빈은 배기온도 및 압축기 출구압력이 높을수록 압축기 출구온도 및 대기압이 낮을수록 연소기준 온도가 상승한다. 또한 높은 연소온도의 화염이 터빈에 직접 접촉되기 때문에 높은 안전등급으로 관리되고 있다. 연소제어가 불량할 경우 화염 불안정에 의한 고온부품이 손상되거나 연소진동이 발생되기 때문에 연소온도의 과도한 상승이나 연소실 내의 연소온도 분포 불균형은 보호회로로 제한하고 있다. 그러나 연소온도 제어기가 고장이 나거나 보호회로값 설정이 부적절하여 실제값이 연소기준 온도보다 높거나, 낮게 될 경우 발전기가 정지되어 전력품질을 저하시키지만 심한 경우에는 가스터빈의 블레이드가 손상되거나 용융되어 장기간동안 발전정지를 초래하기도 한다.

재열 사이클방식의 가스터빈은 고·저압으로 분리되어 연소가 이루어지다 보니 제어회로도 복잡하고 계측기기도 많으며 입출력에 대한 제어변수도 다양하다. 가스터빈의 연소온도에 대한 제어개념은 발전기 출력의 요구량이 변화되면 그에 따른 연소기준 온도가 정해지고 공기량과 고·저압 터빈에 필요한 연료량이 계산된다. 여기에서 연소온도는 고·저압 터빈 입구온도(TIT : Turbine Inlet Temperature) 1, 2와 고·저압 터빈 후단온도(TAT: Turbine After Temperature) 1, 2값과 기준 온도값과 비교하여 터빈에 필요한 연료량을 가감하는 방식으로 제어가 이루어진다.

가스터빈 발전기의 연소온도 제어목적은 연소실 내에 구성품인 각각의 고온부품들이 열응력의 한계 이하에서 최적의 운전상태를 유지하며 안정적이고 지속적인 전력생산을 위해 연소제어가 이루어진다. 가스터빈 연소온도 제어인자는 연소 기준온도, 대기온도, 대기압, 압축기 출구온도와 압력 등이 있으며 항상 실측을 통해 구해진 변수값을 통해 자동제어가 이루어진다. 여기서 연소 기준온도로 중에서 중간부하 이후부터 기준온도로 사용되는 TIT_1, TIT_2는 온도를 직접 측정할 수가 없어서 TAT_1, TAT_2를 측정한 값에 각종 상수값 등을 통해 계산되어 도출된 값을 기준으로 하여 제어를 한다. 가스터빈 연소제어에서 TIT_1은 주로 중간부하 이후부터 연소온도 기준 제어값으로 사용되며, TIT_2는 최대부하 구간에서 연소온도 제어 기준값으로 사용된다.

III. 심층신경망

3.1 심층신경망 개념

인공신경망은 뇌의 실제 신경계의 원리를 기초로 하여 수학적 형태의 모델로서 소프트웨어적으로 인간의 뉴런 구조를 본떠 만든 기계학습 모델로 인공지능을 구현하기 위한 기술 중 한 형태이다. 심층신경망(Deep Neural Network)이란 입력층과 출력층 사이에 여러 개의 은닉층으로 이루어진 인공신경망(Artificial Neural Network)의 한가지 종류이다. 심층신경망은 비지도학습(Unsupervised learning)을 기반을 두고 있으며 신경망 계층인 은닉층(Hidden layer) 간에는 가중치를 통해 연결되어 있지만, 계층 내의 노드(Node) 간에는 연결이 없는 딥러닝 알고리즘의 초기방식이라고 할 수 있다.

DNN은 적은 수의 노드로 구성된 방식으로도 복잡한 데이터를 간단하게 모델링 할 수 있으며, 입력변수들 간의 비선형 변수 조합의 관계식도 간단하게 모델링 할 수 있다. 또한 다른 종류의 신경망에 비해 학습

할 수 있는 데이터의 양이 많아질수록 정확성이 높아지고 데이터의 특징추출(Feature extraction)을 자동으로 수행할 수 있어 입력변수의 형태인 연속형, 범주형 등을 구분하지 않고 모두 분석이 가능함에 따라 변수 선택의 번거로움을 줄여줄 수 있다[5]. DNN 알고리즘은 컴퓨터가 스스로 분류레이블을 만들어 내고 공간을 왜곡하며 최적화를 수행하고 데이터를 구분 짓는 과정을 반복하면서 최적의 결과를 도출해 내는 방식으로서, 활성화 함수를 이용한 사전학습과 오류 역전파 기법이 널리 사용되고 있다. 이러한 기법은 현재 CNN, RNN, LSTM 등 최신의 알고리즘에 응용되어 이용되고 있기도 하다.

DNN 모델의 정확성을 높이기 위해서는 많은 데이터와 반복된 학습이 필요하지만 지나치게 많은 학습을 할 경우 실제 데이터에 대해 오차가 증가하는 과적합이나 높은 시간 복잡도 등의 문제가 발생할 수 있다. 또한 설계된 모델이 복잡하면 학습결과를 도출하는데 시간이 오래 걸리며, 높은 수준의 그래픽 처리 장치와 대용량의 메모리가 장착된 컴퓨터가 필요하다.

3.2 심층신경망 구조

DNN의 구성은 입력층과 출력층이라는 2개의 층으로 구성된 단순한 구조의 단층 퍼셉트론이 발전된 형태로서 입력층과 은닉층, 출력층 순서로 구성된 다층 퍼셉트론으로서 그림 2과 같이 복잡한 비선형 문제의 해결을 위해서 한 개의 층에 여러 개의 노드와 은닉층을 3개 이상으로 쌓은 구조를 말한다[6].

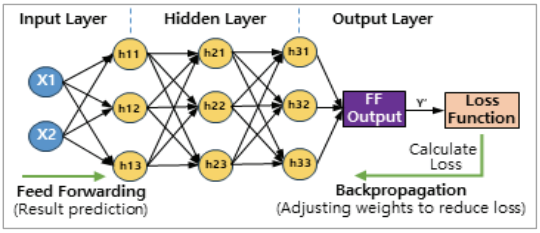

그림 2. 심층신경망의 구조 및 흐름도
Fig. 2 Structure and flow diagram of deep neural network

DNN은 작동방법에 따라 FFN(Feed Forward Network), 역전파(Back propagation), RNN(Recurrent Neural Network) 등이 있으며, 입력(input)과 출력(output) 활성화함수(Activation function) 가중치(Weight)와 편향(Bias) 등으로 조합된 구조로 이루어져 있다.

DNN 구성에서 입력정보는 벡터기반으로 입력되어서 'One hot encoding'의 형태로 입력되며, 보통 학습 매개변수의 수가 계층 크기의 제곱에 비례하는 방식으로 설계한다. 또한 모든 가중치는 신경망의 학습과정에서 계속 조금씩 변하며 가중치의 변수들을 일정한 순서나 방식으로 넣는 것이 아니기 때문에 결과가 일정하지 않을 수 있다. 즉 각각의 노드에 어떠한 입력값을 중요하게 여기는지가 반영이 되어서 가중치가 업데이트되는 방식으로서 학습결과 해석이 어려운 구조라고 볼 수 있다. 일반적으로 DNN 모델은 주로 사물의 분류나 수치예측을 목적으로 하는 분야에 사용되고 있으며 이미지 트레이닝이나 문자인식 같은 분야에서도 유용하게 쓰이고 있다.

3.3 심층신경망 학습방법

신경망 학습은 순전파와 역전파 알고리즘이 가장 많이 사용된다. 순전파는 입력층에서 은닉층 방향으로 순방향 이동하면서 각각의 입력에 해당하는 가중치가 곱해지고 편향값이 더해져 가중치 합으로 계산된 후, 은닉층의 활성화 함수를 거쳐 마지막의 은닉층의 변수값에 최종 편향값이 더해져 결과값을 출력하게 된다[7]. 이후 순전파를 통해 얻어진 출력값과 실제값의 오차를 확인하고 역전파 알고리즘을 통해 최종 출력값과 실제값의 오차가 최소화되도록 가중치와 편향을 업데이트해 나가며 학습이 진행된다.

신경망 알고리즘의 학습단계는 5가지의 단계로 구분할 수 있다. 즉 ①네트워크 가중치의 초기화 → ②순전파 활성화함수 가중치 적용 → ③실제값/예측값 오차평가 → ④오차를 반대로 전파, 오차계산 → ⑤가중치와 편향 조정 순으로 진행되며, 신경망 학습 흐름도는 그림 3과 같이 표현할 수 있다.

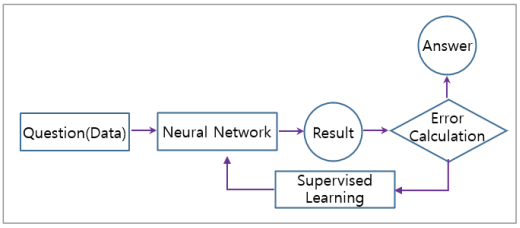

그림 3 인공지능 학습 흐름도
Fig. 3 Deep neural network training flow chart

손실함수는 신경망의 출력층에서 나오는 많은 가중치와 편향을 통해 산출된 결과값과 실제값의 차이를 수학적으로 구현한 함수로서, 계산방법으로는 MSE(Mean Square Error), RMSE(Root Mean Squared Error), MAE(Mean Absolute Error) 등이 있으나, 일반적으로 평균제곱오차(MSE) 방식을 많이 사용한다[8].

MSE는 오차를 제곱한 값의 평균으로서 수식은 식 (1)과 같이 표현할 수 있으며, 여기서 Y_0, Y_1은 순전파에서 계산된 결과 값이고 y_0, y_1는 실제의 값이다.

$$Error = \frac{1}{2}((Y_0 - y_0)^2 + (Y_1 - y_1)^2) \quad \cdots (1)$$

신경망 모델에서 원하는 연산결과를 만들도록 비중을 조절하는 매개변수인 가중치는 초기값을 수동으로 지정해주거나 컴퓨터가 무작위로 가중치의 초기값을 지정하는 방법이 있다. 일반적으로 가중치의 초기값이 최적값과 차이가 클수록 학습시간이 오래 걸리며, 학습을 오래할 경우 과적합의 가능성이 있으므로 초기의 가중치를 설정하여 빠르게 학습하는 것이 매우 중요하다. 가중치 감소(Weight Decay)기법은 과적합을 해결하기 위해 많이 사용하는 방법 중의 하나로서 가중치 값을 작아지도록 학습하는 방법이다[9].

역전파 알고리즘은 각 노드가 가지고 있는 가중치와 편향값을 조금씩 조정하고 갱신하여 오차를 최적화하는 알고리즘으로서 신경망에서 가장 핵심적인 부분이라고 할 수 있다. 역전파 알고리즘은 주로 전체에 대한 편미분을 곧바로 구하지 않고 마지막에 위치한 출력층에서 발생한 오차를 입력값 방향으로 전파해 나가면서 각각의 가중치와 편향을 수정해 나가며 각각의 가중치는 식 (2)를 이용하여 구해진다.

$$\triangle w_{ij}(t+1) = \triangle w_{ij}(t) + \eta(\frac{\partial C}{\partial w_{ij}}) \quad \cdots (2)$$

η는 학습률(Learning rate)을 의미하며, C는 비용함수(Cost function)를 의미하며, 비용함수의 선택은 지도 학습이나 비지도 학습, 강화학습 등과 같이 학습형태와 활성화 함수와 같은 요인들에 의해서 결정된다[10]. 또한 오차함수를 최소화하는 모델의 매개변수를 찾는데 많이 사용되고 있는 경사하강법(Gradient Descent)은 단계적으로 오차함수를 조금씩 줄여가며 반복적으로 가중치를 개선해 나가는 방식이다. 경사하강법에서 최적의 가중치를 찾아가는 가중치와 편향을 구하는 방법은 식 3과 같이 표현할 수 있다.

$$\mathrm{cost}(w,b) = \frac{1}{2m}\sum_{i}^{m}(H(x^i) - y^i)^2 \quad \cdots (3)$$

여기서 m은 학습할 데이터의 개수, i는 학습데이터의 Index를 의미하며 Cost 값이 클수록 예측결과가 좋지 않다는 것을 나타낸다[11].

Ⅳ. DNN 모델 설계 및 실험

4.1 데이터 및 실험방법

본 논문에서 제안하는 재열 가스터빈의 입구온도 예측모델은 인공신경망의 심층 신경망 기법을 활용하였다. 온도예측 모형학습에 필요한 데이터는 F급 재열 가스터빈에서 취득장비를 통해 직접 취득하였다. 가스터빈 연소온도 모델링 학습과 관련된 61개 계측기의 신호값을 추출하여 고압터빈 입구온도(TIT_1) 와 관련된 입력 매개변수 30개를 선정하였으며, 저압터빈 입구온도(TIT_2)와 관련된 입력 매개변수 35개를 선정하였으며 입력신호 항목은 표 1과 같다.

표 1. 가스터빈 고·저압 입구온도 예측모델 신호항목
Table 1. Gas turbine high and low pressure inlet temperature prediction model signal items

Equipment	Control elements related to temp. control
TIT_1 elements (HP TBN)	TAT_1, Comb. vib., Inner casing temp. Inlet temp., TBN air temp. Cooling air temp., Comb. 1, 2, 3P Metal temp., Heat exh. Cooling flow, Heat exh. aft STM temp., Heater STM pr. STM pr., Cooling air flow, HP NG flow
TIT_2 elements (LP TBN)	TBN inlet pr., TBN aft. pr. LP aft. pr., TBN aft. temp., TBN band comb. vib.(3Point), TBN1, 2 cooling temp., Comb. pr., Comb. Delta pr., Cooling air to feed flow, Heater before temp., Heater aft. temp., NG flow, Cooling air flow, TBN total NG flow, NG supply pr.
Common elements (TIT_1, TIT_2)	Amb. temp., Amb. pr., Humidity, Comp. filter temp., VGV 1, 2, 3 position, Comp. atf. pr., Comp. aft. temp, Cooling air to feed temp., Cooling air feed pr., Total NG, Heater STM flow, Heater STM pr., NOx ppm, Exh. gas O_2 flow, Exh. gas flow.

가스터빈 연소온도와 관련된 매개변수를 이용하여 인공신경망으로 예측이 가능한 알고리즘을 구현할 수 있는지 가능성을 판단하기 위해 Matlab의 심층신경망 디자이너 툴을 이용하여 가스터빈 입구온도를 예측할 수 있는 모형학습 모델을 구성하였다.

신경망 학습은 비선형적인 데이터 예측에 정확도가 높고 최적의 예측값을 도출하는데 많이 사용되고 있는 함수최적화기법(Levenberg-Marquardt)을 사용하였다. 또한 가중치와 편향 등은 자동 계산 방식으로 하였으며, 회귀모델 성능 지표는 MSE를 사용하였고 학습 횟수의 epoch는 1,000으로 설정하였다. 모형학습에 사용된 입력 데이터는 가스터빈에서 실측한 데이터 96,000개를 사용하였으며 입력 데이터의 활용성을 높이기 위해 데이터 분할은 신경망 훈련에 70%, 유효성 검사 및 테스트는 15%의 비율로 실험을 수행하였다.

4.2 TIT_1 신경망 모형 설계

고압터빈 입구온도인 TIT_1 예측에 적합한 모형모델을 설계하기 위해 노드의 개수와 은닉층의 개수를 변경해 가며 특성을 파악하였다. 모델이 이용된 입력 신호는 TIT_1과 관련 있는 신호 30개를 변수로 활용하여 노드의 개수를 변경하는 방식과 은닉층의 개수를 변경하는 방식 등으로 신경망 구조별로 8가지의 모델을 설계한 후 학습을 수행하였다.

첫 번째 학습은 설계 모델별로 실제값과 예측값의 차이를 분석하고 출력값에 대한 경향을 확인하기 위해 은닉층은 1개로 고정상태에서 노드의 개수를 증가하는 방식으로 신경망 모형모델을 학습을 수행하였다.

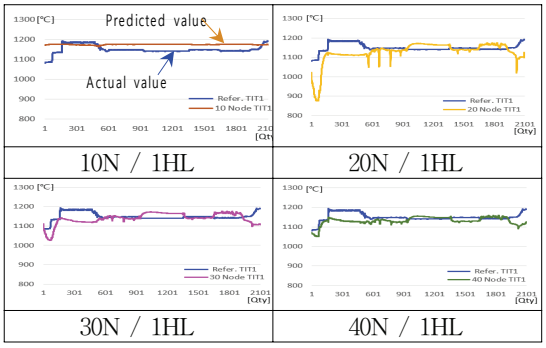

그림 4. 노드 개수 증가 신경망 모형모델 시험
Fig. 4 Node number increase method neural network model test

학습이 완료된 각각의 신경망에 새롭게 취득한 데이터를 입력한 후 특성시험을 수행한 결과, 그림 4와 같이 노드가 10개일 때는 입력값이 변동되더라도 출력값은 크게 변하지 않고 거의 일정한 값을 출력되었다. 그러나 노드 수가 증가할수록 실제값보다 오차가 크게 변동되는 특성을 보였으며, 예측값이 실제값을 추종하는 경향을 보였지만 입력값이 변할 때마다 편차가 발생하고 불규칙적인 패턴을 보였다.

두 번째 학습은 노드 개수는 10개로 고정한 상태에서 은닉층 개수만 증가하는 방식으로 신경망 모형모델의 학습을 수행하였다. 학습이 완료된 은닉층 증가 방식의 모형모델에 대한 특성을 파악하기 위해 실제값과 비교시험 결과 그림 5와 같은 특성을 보였다.

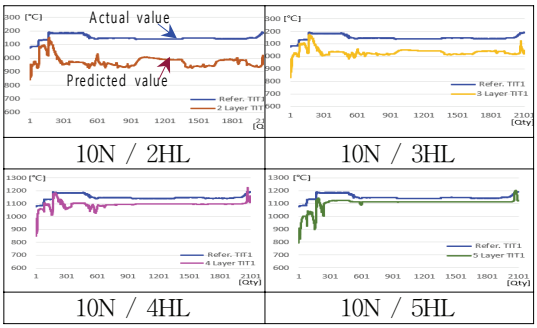

그림 5. 은닉층 개수 증가방식 신경망 모형모델 실험
Fig. 5 Method of increasing the number of hidden layers ANN model test

은닉층이 2개인 모델에서는 실제값보다 낮은 값으로 편차가 큰 상태로 예측하였으며, 예측은 유사한 패턴을 보였지만 입력값 대비 특정 신호가 증폭되는 경향을 보였다. 그러나 은닉층 개수가 증가할수록 실제값과 거의 동일한 패턴이었으며 온도 편차가 최소화되는 경향을 보였다.

4.3 TIT_2 신경망 모형 설계

저압터빈 입구온도인 TIT_2 온도를 예측할 수 있는 최적의 모델을 설계하기 위해 TIT_2 모형모델 시험도 TIT_1 모형모델 시험과 동일한 방법으로 수행하였다. 먼저 TIT_2와 관련된 취득신호 35개의 변수를 기준 입력값으로 하고 은닉층은 고정된 상태에서 노드의 개수를 증가했을 때의 모형모델의 특성을 파악하는 시험을 하였으며, 두 번째로는 노드의 개수는 고정된 상

태에서 은닉층을 증가시켜 가며 학습을 수행하였다. TIT_2의 온도예측 모형학습이 완료된 각각의 신경망에 가스터빈 기동부터 운전, 정지까지의 데이터를 취득하여 각각 4가지의 모형모델에 적용한 결과, 그림 6과 같이 실제값과 예측값의 온도가 거의 유사하게 산출되는 특성을 보였다.

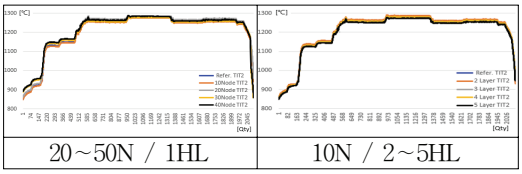

그림 6. 노드 및 은닉층 증가방식의 TIT_2 모형모델 시험
Fig. 6 Learning result of TIT_2 model test of increasing node and hidden layer

즉 노드 및 은닉층의 개수가 변동되어도 실측값과 모형학습을 통한 예측값과의 편차가 크게 발생하지 않았으며 기동·정지 구간에서만 오차가 발생하는 경향을 보였다. 좀더 자세한 특징을 파악하기 위해 그림 7과 같이 실제값을 "0"으로 기준으로 설정하고 예측값과 온도편차를 계산하여 그래프로 나타내 보았다.

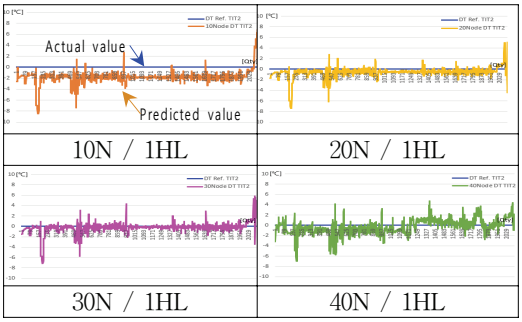

그림 7. 노드 증가방식의 TIT_2 모형모델 온도편차
Fig. 7 TIT_2 model of node increment method Model temp. deviation

TIT_2 신경망 모델별로 출력값을 비교 분석한 결과, 노드 개수가 10개일 때는 실제온도보다 액 1~3℃ 낮게 예측되었으나 노드의 개수가 증가할수록 오차가 줄어들었으며 30개일 때가 가장 안정적이고 오차도 최소화 되었다. 그러나 노드가 40개일 때에는 실제값과 유사한 경향을 보이다가 -5~4℃의 크기로 불규칙적인 패턴을 보였다.

두 번째는 노드의 개수는 고정된 상태에서 은닉층의 개수만 증가하는 방식의 예측모형에 대한 결과값을 토대로 하여 예측값과의 온도편차를 계산한 후 그림 8과 같이 그래프로 나타내 보았다.

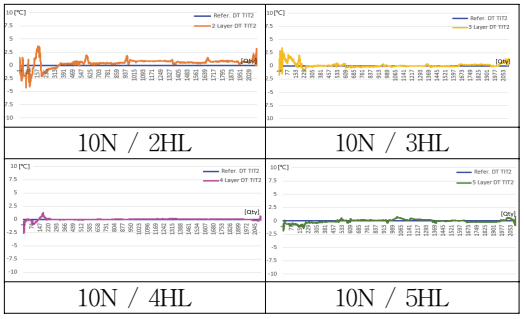

그림 8. 은닉층 증가방식의 TIT_2 모형모델 온도편차
Fig. 8 TIT_2 model of temp. deviation with increasing hidden layer method

은닉층의 변화를 주며 도출된 예측값을 분석한 결과 은닉층이 2개일 경우에만 1.5℃ 내외의 변동을 보였으며 은닉층이 4개 이상이 되면 매우 안정적이고 최적화된 결과값이 산출되는 경향을 보였으며, 은닉층이 5개일 경우에는 온도값이 소폭 움직일 때마다 실제값보다 증폭되는 경향을 보였다.

4.4 입구온도 예측모델 구축

TIT_1, TIT_2의 신경망 모형모델을 통해 매개변수와 신경망 구조별로 특성을 파악한 결과를 기반으로 하여 재열 가스터빈 입구온도 예측에 가장 최적화된 신경망 모델을 적용하기 위해 표 2와 같이 노드와 은닉층을 다르게 구성하여 각각의 예측 모델의 성능을 시험하는 연구를 수행하였다.

표 2. 고·저압 가스터빈 입구온도 예측모델 종류
Table 2. gas turbine inlet temperature prediction models

Inlet temp.	Nodes	Hidden layers
TIT_1	10	5
	20	6
	30	7
TIT_2	20	4
	30	5
	40	6

노드 크기와 층이 다른 신경망 예측모델에 사용된 데이터는 최근 3년간 재열 가스터빈의 기동·정지 및 최대부하 구간에서 취득한 데이터를 사용하였다.

그림 9. 신경망 학습 데이터 구성 및 학습결과 (예시)
Fig. 9 Neural network training data configuration and learning result (example)

학습에 사용된 데이터는 대기온도, 압축기 온도 등이었으며, 그림 9와 같이 TIT_1의 실험 데이터는 1,000,297 × 30개, TIT_2의 데이터는 1,000,297 × 35개를 추출하여 예측모델 학습 데이터로 이용되었다.

그림 10. 온도예측 학습 프로그래밍 코드(예시)
Fig. 10 Temp. prediction learning programming code (example)

입구온도 예측모델도 Matlab의 심층신경망 디자이너의 툴을 이용하였다. 스크립트 편집기를 이용하여 데이터 전처리부터 데이터 학습, 검증시험까지 간편하게 진행될 있도록 그림 10과 같이 프로그래밍 코드로 작성하여 학습을 수행하였다. 학습시간 및 성능은 은닉층의 개수와 에포크의 횟수에 따라서 학습시간이 변동되었으며, 그림 3과 같이 신경망 학습 성능 및 오차도 개수가 많을수록 높아지는 경향을 보였다. 또한 회귀분석에 의한 R값은 99.7% 수준을 유지하였으며 크게 변동하지 않았다.

4.5 예측모델별 검증시험

심층신경망을 이용하여 가스터빈 입구온도 예측모델을 최종적으로 결정하기 위해 그림 11과 같이 예측모델별로 검증시험을 시행하였다.

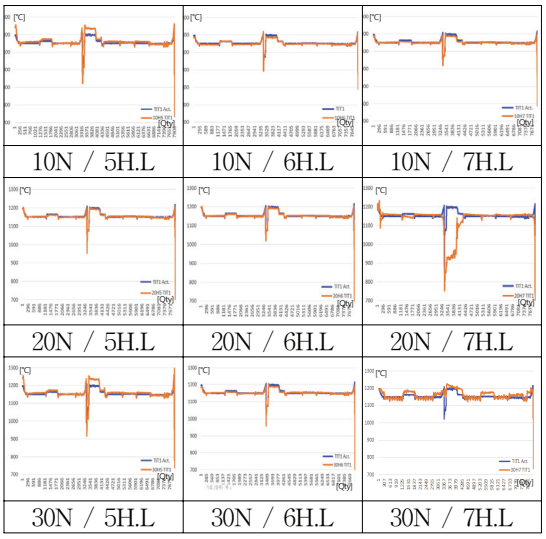

그림 11. TIT_1 신경망 모델별 검증시험 결과
Fig. 11 Verification test results for each TIT_1 DNN model

TIT_1 설계 모델별로 검증시험 결과, 노드가 20~30개이고 은닉층은 6개인 신경망 모델이 오차가 가장 적었으며 실제값과 가장 적합한 결과를 예측하는 것으로 나타났다. 이 결과를 토대로 하여 국내 발전소의 가스터빈 연소튜닝 공정 중에 입구온도 확인용으로 실증시험에 사용될 TIT_1의 신경망은 노드 20개, 은닉층 5개의 구조로 형성된 심층신경망을 적용하였다.

TIT_2도 설계 모델별로 검증시험 결과, 그림 12와 같이 노드의 수가 30~40개의 구조에서 은닉층이 5개로 구성된 신경망 모델이 가장 최적화된 결과를 보여주었다. 따라서 산업현장에서 연소튜닝 공정에 사용될 TIT_2의 신경망은 노드 40개와 은닉층 4개로 구성된 심층신경망을 적용하였다.

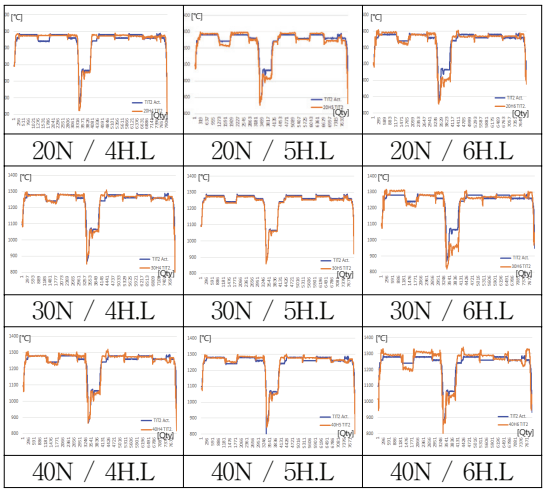

그림 12. TIT_2 신경망 모델별 검증시험 결과
Fig. 12 Verification test results for each TIT_2 DNN model

Ⅴ. 실증시험 및 결과분석

5.1 DNN 모델 실증시험

예측모델의 실증시험은 발전소 계획정비공사 후 시운전 과정에서 연소튜닝이 이루어지고 있는 가스터빈 발전기 2대를 대상으로 하여 검증시험이 완료된 모델을 적용하였다. TIT_1 예측에는 노드 20개이고 은닉층이 6개인 모델을 적용했으며, TIT_2에는 노드가 30개이고 은닉층이 5개인 모델을 적용하여 실제값과 예측모델의 차이를 확인하고 비교하는 시험을 수행하였다.

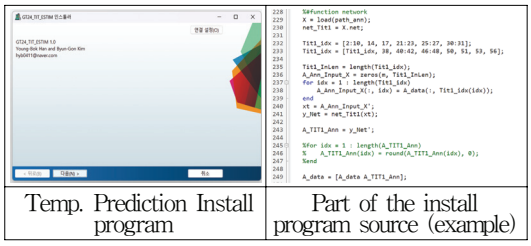

그림 13. 입구온도 예측모델 실행 프로그램
Fig. 13 Inlet temperature prediction model execution program

현장에서 실증시험을 빠르고 쉽게 수행하고 결과값을 비교하고 확인할 수 있도록 그림 13과 같이 온도예측 실행 프로그램을 개발하여 연소튜닝 장비에 설치하였다. 개발한 프로그램은 매트랩의 App Designer를 활용하여 독립적으로 실행할 수 있는 데스크탑 앱 프로그램을 개발하였다. 프로그램에는 비교 검증을 위해 DNN 모델뿐만 아니라 폴리트로픽 지수기반의 온도산출식 등을 코딩하여 동시에 실행될 수 있도록 프로그래밍 하였다. 또한 TIT_1 및, TIT_2 입구 온도값이 자동으로 산출되는 방식으로서 한개의 화면에서 입력신호값 및 결과값을 육안으로 확인할 수 있도록 사용자 입장을 고려하여 개발하였다.

가스터빈 발전기의 최대부하 구간에서 연소튜닝 후 입구온도 설정을 위해, 연소튜닝 장비에 설치된 프로그램을 실행한 결과 TIT_1, TIT_2 값은 그림 14와 같은 결과값이 도출되었다.

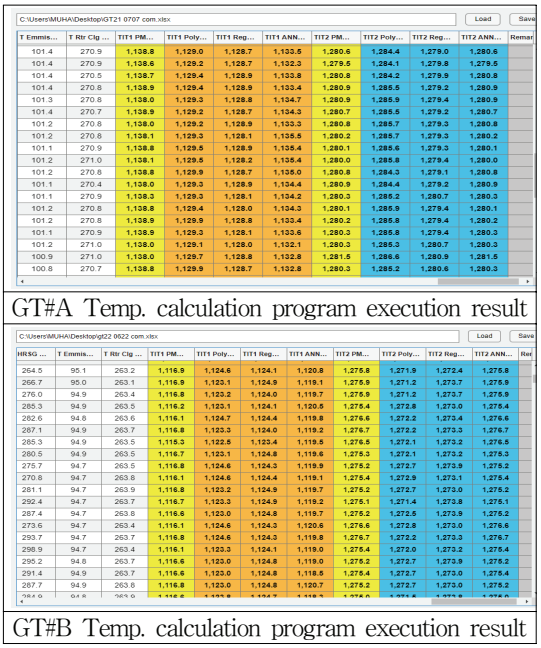

그림 14. 온도예측 프로그램 실행결과 화면
Fig. 14 TIT_1, TIT_2 Prediction program execution result screen

프로그램에서 실행 후 산출방식별로 예측한 값의 비교 결과는 표 3과 같은 결과가 나왔다. 가스터빈

#A 호기의 TIT_1은 폴리트로픽 지수값과 4.8℃의 편차가 있었으며, TIT_2는 1.6℃의 편차가 있었으나 가스터빈 연소제어 파라미터 값은 DNN으로 산출된 값을 제어로직에 입력하였다.

표 3. 예측 프로그램 실행 결과값 비교
Table 3. Comparison of prediction program execution results

Division	#A GT		#B GT	
	TIT_1	TIT_2	TIT_1	TIT_2
Regress. A.	1128.7	1279.0	1124.6	1120.8
Poly T Inx	1129.0	1284.4	1124.1	1271.9
DNN	1133.5	1280.6	1120.8	1275.8
R/D ΔT	3.5℃	3.8℃	3.8℃	-3.9℃
P/D ΔT	-4.8	-1.6	3.3	-3.9

#B호기 입구온도는 폴리트로픽 지수로 계산한 값과 DNN으로 산출한 온도편차가 3.3℃, 3.9℃로서 IEC 60584 Class 1 기준값에 근접하였다. 하지만 연소튜닝 전문가의 의견에 따라 폴리트로픽 지수함수를 이용하여 산출된 온도를 제어로직에 적용하였으며, TIT_2는 DNN으로 산출된 온도값이 신뢰성이 높은 것으로 판단됨에 따라 DNN에서 도출된 값을 연소제어 파라미터값으로 사용하였다.

5.2 온도예측 DNN 모델 성능

실증시험에 사용된 DNN 모델은 가스터빈 연소제어에서 가장 중요한 구간인 최대부하 구간에서의 입구온도를 허용범위 이내로 예측값을 도출하고 있으며 신뢰성이 높아 튜닝 전문가로부터 연소튜닝 온도 검증용으로 사용 가능함을 확인하였다.

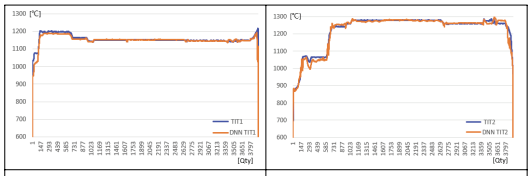

TIT_1 temp. comparison | TIT_2 temp. comparison

그림 15. #A호기 전 구간 온도예측 그래프
Fig. 15 Temp. prediction graph of all sections of #A

그러나 가스터빈 기동·정지 및 중간부하 이하에서는 온도편차가 발생함에 따라 DNN 모델의 성능과 특성을 파악하기 위해 연소튜닝이 완료된 가스터빈을 대상으로 하여 기동부터 정상운전, 정지구간까지 입구온도를 비교한 결과 그림 15와 같이 나타났다.

최대부하 구간에서는 TIT 온도편차가 ±3℃로서 허용범위 이내이었지만, 기동구간에서는 120℃까지 편차가 발생하였으며 예측값이 5~10sec 늦게 변동하는 경향을 보였다. 또한 정지구간에서는 90℃까지 편차가 발생하였으며 실제값보다 빠르게 하향곡선을 나타내는 경향을 보였다. 이러한 특성을 나타내는 원인을 분석하기 위해 예측모델의 초기 가중치는 컴퓨터가 무작위로 설정되도록 한 상태에서 TIT_1, TIT_2를 대상으로 하여 노드가 20개이고 은닉층이 5개 및 6개, 7개인 예측모델에 대한 입력 변수별 가중치와 편향 값을 확인하였다. TIT_1의 영향을 주는 변수 중에서 가중치가 높은 입력변수는 터빈 후단온도, 냉각공기 스팀 온도 및 연소기 케이싱 금속온도 등이었으며, TIT_2의 온도 예측에 영향을 주는 요소는 추기공기 온도 및 냉각공기 온도, 0-1kHz 구간의 연소진동 등이었다. 편향은 상하 반복하는 경향을 보였으며 은닉층이 많아질수록 편향값의 크기가 작아지는 경향을 보였으며 가중치와 편향의 추이 그래프는 그림 16과 같다.

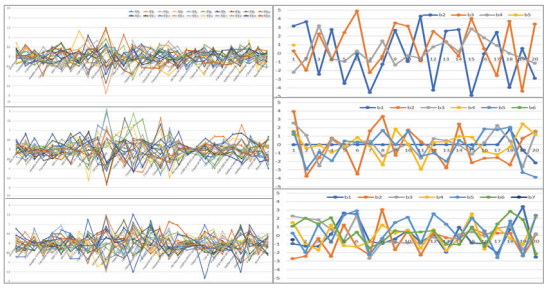

그림 16. TIT_1 은닉층 구성별 Weight 및 Bias 추이
Fig. 16 Weight and Bias Trend by TIT_1 Hidden Layers

5.3 기동·정지구간 예측온도 분석

가스터빈 기동·정지 구간에서 입구온도 예측값의 정확도가 낮은 원인을 파악하기 위해 DNN 모델에서 층간 노드의 연결강도를 조정하는 가중치와 민감도를 조절해 주는 역할을 하는 편향값을 조정해 보았다. 그 결과 조정 전보다 파라미터값을 올리거나 내렸을 때마

다 오차의 크기가 더 커졌으며, 최대부하 구간에서는 가중치 변화값이 더 크게 영향을 주었다. 이러한 특성은 DNN 예측모델의 구성이 부적합하거나 가중치를 미세하게 조정하여 학습시키는 방법이 필요한 것이 아니라, 재열 가스터빈 기동·정지시 연소 전환방식의 영향으로 인하여 오차가 커지는 것으로 추정된다.

즉 재열 가스터빈 기동 초기에는 화염안정을 위해 고압 연소기의 확산연소 방식의 Pilot 연소가 시작되어 연료공급이 이루어지다가 전기를 생산하기 시작하면 질소산화물 배출량 감소 위주의 예혼합 연소로 방식으로 연소전환이 이루어진다. Pilot 연소에서 Premix 연소로 전환하는 과정에는 화염불안정 현상이 발생하고 연소진동도 급격히 증가한다. 또한 연소실 냉각용 공기온도가 낮고 유량도 적어서 정상적인 냉각기능을 하지 못하고 있는 상태에서 TAT_1을 기준으로 하여 연소전환 제어가 이루어지 지기 때문에 일시적으로 TIT_1의 온도가 높게 지시되는 특성이 있다[12]. 이러한 과정은 계통병입 후 약 10~20분간 이루어지며 약 30% 부하 이전까지는 TAT_1의 연소온도 제어가 이루어진다. 점화구간부터 TIT_1 제어가 이루어지기 전까지는 연소실 화염이 불안정하고 각종 실측 데이터값도 차이가 크게 발생하기 때문에 경향을 파악하기에는 데이터의 신뢰성이 낮은 편이다. 이후 TIT_1으로 연소온도 제어를 수행하며 주로 중간부하 구간을 연소온도 제어를 담당하게 되며, 최대부하 구간에서는 TIT_2의 온도값이 연소온도의 제어인자로 사용되며 TIT_1의 기준값은 고정된 상태로 운전된다. 따라서 기동과 정지·구간에서는 TAT_1을 기준제어 값으로 연소제어가 이루어지며 TIT_1과 TIT_2가 온도제어 연소온도 제어요소로 작용하지 않기 때문에 DNN 모델에서 도출된 온도값의 정확도가 낮은 것으로 판단된다.

Ⅵ. 결론

본 논문에서는 신경망의 심층신경망 기법을 이용하여 F급 재열 가스터빈의 입구온도를 쉽게 예측할 수 있는 예측모델을 제시하여 정비비용을 절감하고 연소튜닝 기술확보에 도움이 되고자 연구를 시작하였다.

가스터빈 입구온도에 대한 최적의 예측모델을 도출해 내기 위해 빅데이터를 통해 인공신경망의 하나인 심층신경망 기법을 활용하여 모형모델을 만들어 모델별로 특징을 분석 후, 가장 적합한 방식의 신경망 모델을 도출하였으며, 연소튜닝 중인 가스터빈 발전기 2대에 예측모델을 적용하여 실증시험을 하였다. 예측모델을 검증하기 위해 폴리트로픽 지수기반의 입구온도 산출식과 DNN 모델을 한 화면에서 실시간으로 예측할 수 있는 프로그램을 개발하여 데이터 분석장치에 설치 후 실시간으로 비교한 결과, 결과값이 오차범위 내에서 안정적으로 도출되고 있어 DNN 모델에서 도출값을 가스터빈 제어로직에 입력하여 3개월간 운영하고 있다.

하지만 가스터빈 기동·정지 및 저부하 구간에서 불규칙적인 패턴을 보이거나 정확도가 많이 낮아지는 경향을 보였다. 이러한 원인은 재열 가스터빈의 연소방식 및 온도제어 특성 등에 의한 영향이 크다고 판단된다. 따라서 연소전환 구간은 전이학습을 통해 정확도를 높이고, 각각의 입력 매개변수에 회귀분석의 상관관계 해석을 통해 입력변수의 개수를 최적화하여 데이터의 처리속도를 향상시키고, 복잡성을 줄여서 전 구간에서의 예측온도값의 신뢰도를 높일 수 있도록 신경망 모델을 업그레이드를 시행할 계획이다.

이번 연구는 최신기술의 활용도가 낮은 플랜트 산업 분야에 인공지능의 기술을 적용하여 가스터빈 연소 최적화 기술자립과 친환경 연소기술 확보에 기여할 수 있는 사례라고 본다.

최근 탄소중립 정책에 따라 발전산업 분야에서는 수소 혼소 또는 수소 발전에 대한 연구가 이루어지고 있다[13]. 수소 연소 특성상 안정적인 연소제어 기술이 핵심인 만큼 가스터빈 수소 혼소 발전기 연소시험에도 인공신경망 기술을 연구하고 적용해 나간다면 수소연소에 대한 핵심기술을 확보하고 전문기술을 축적하여 기술력 향상과 안정적인 전력공급에 기여할 수 있을 것으로 기대된다.

References

[1] H. Lee, “Power system operation performance in 2022,” *Report,* June 2023, pp. 1-24.

[2] J. Lee, T. Kim, D. Kang, and J. Sohn, “Estimation of turbine inlet temperature of heavy duty gas

turbine using Kalman filter," *2018 Korea Fluid Mechanics Society summer conference thesis,* Jeju, Korea, June 2018, pp. 04-07.

[3] S. Yun and S. Kim, "Analysis of Operation Conditions of a Reheat Cycle Gas Turbine for a Combined Cycle Power Plant," *The Korean Society Fluid Machinery*, vol. 9, no. 6, Sept. 2006, pp. 35-44.

[4] Y. Han and S. Kim, "Development of a Polytropic Index-Based Reheat Gas Turbine Inlet Temperature Calculation Algorithm," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 18, no. 3, June 2023, pp. 483-494.

[5] S. Chung and Y. Chung, "Comparison of Audio Event Detection Performance using DNN," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 13, no. 3, June 2018, pp. 571-578.

[6] H. Choi and J. Choi, "Prediction of Wind Power Generation using Deep Learning," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 16, no. 2, Apr. 2021, pp. 329-338.

[7] M. Cho, "A Study on the History, Classification and Development Direction of Artificial Intelligence," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 16, no. 2, Apr. 2023, pp. 115-126.

[8] S. Yeo and D. Park, "Design of DNN-Based Injection Molded Product Defect Prediction System," *The Journal of Korean Institute of Communications and Information Sciences*, vol. 46, no. 10, Aug. 2021, pp. 1771-1777.

[9] H. Lee, "Nonlinear Noise Attenuator by Adaptive Wiener Filter with Neural Network," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 18, no. 1, Feb. 2023, pp. 71-76.

[10] S. Cen and C. Lim, "Power Quality Disturbances Detection and Classification using Fast Fourier Transform and Deep Neural Network," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 18, no. 1, Feb. 2023, pp. 115-126.

[11] S. Ahn, "Deep learning model and application history," *J. of the Intell Inform Syst 2016*, vol. 22, no. 2, May 2016, pp. 127-142.

[12] D. Kim, "Performance Sensitivity Analysis for the Calculation of the Turbine Inlet Temperature of a Reheat Gas Turbine," Master's. Thesis, *Chunnam National University*, 2009.

[13] S. Kim, "Review on the Development Trend of Hydrogen Gas Turbine Combustion Technology," *J. of The Korean Society of Combustion,* vol. 24, no. 4, Dec. 2019, pp. 1-10.

저자 소개

한영복(Young-Bok Han)

1993년 원광대학교 전기공학 학사
1997년 전북대학교 전기시스템공학 석사
2023년 군산대학교 전자정보공학 박사수료

1993년~2002년 한국전력공사 복합발전 건설 및 제어설비 관리
2002년~현재 한국중부발전 발전소 건설 및 제어설비 관리
※ 관심분야 : 인공지능, 퍼지제어, 공장자동화, PID제어, 분산제어

김성호(Sung-Ho Kim)

1984년 고려대학교 공과대학 학사
1986년 고려대학교 공과대학 석사
1991년 고려대학교 공과대학 박사
1988년~1990년 고려대 생산기술 연구소 연구원
1995년~1996년 Japan Hiroshima Uni. Post Doc.

1991년~현재 군산대학교 전자정보공학부 교수
※ 관심분야 : 인공신경망, 퍼지 센서네트워크, 공장자동화 및 오류검출

김변곤(Byun-Gon Kim)

1990년 한국항공대학교 공과대학 학사
1997년 전북대학교 공과대학 석사
2001년 전북대학교 공과대학 박사
2001년~2002년 표준과학연구원 Post Doc.

2005년~현재 군산대학교 전자공학과 교수
※ 관심분야 : 인공신경망, 무선 센서네트워크, 퍼지 제어