



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

2020년 2월
석사학위 논문

심층피지신경망을 이용한
임계유동 예측

조선대학교 대학원

원자력공학과

안예지

심층퍼지신경망을 이용한 임계유동 예측

Critical Flow Estimation Using Deep Fuzzy Neural
Networks

2020년 2월 25일

조선대학교 대학원

원자력공학과

안 예 지

심층퍼지신경망을 이용한
임계유동 예측

지도교수 나 만 균

이 논문을 공학 석사학위신청 논문으로 제출함

2019년 10월

조선대학교 대학원

원 자 력 공 학 과

안 예 지

안예지의 석사학위논문을 인준함

위원장 조선대학교 교수 김종현 (인)

위원 조선대학교 교수 김진원 (인)

위원 조선대학교 교수 나만균 (인)

2019년 11월

조선대학교 대학원

목차

표 목차	ii
그림 목차	iii
ABSTRACT	iv
제 1 장 서론	1
제 2 장 Deep Fuzzy Neural Network(DFNN) 모델	3
제 1 절 DFNN 방법론	3
제 2 절 DFNN 모델 최적화	10
제 3 장 DFNN 모델을 사용한 임계유동 예측	15
제 4 장 결론	34
참고문헌	35

표 목차

표 1. 테스트 데이터가 고정 간격인 경우 SCFNN을 이용한 임계질량속 예측 결과	16
표 2. 테스트 데이터가 5 MPa 경우 SCFNN을 이용한 임계질량속 예측 결과	16
표 3. 테스트 데이터가 고정 간격인 경우 SCFNN을 이용한 임계압력 예측 결과	21
표 4. 테스트 데이터가 5 MPa 경우 SCFNN을 이용한 임계압력 예측 결과	21
표 5. FNN, SVR 및 DFNN을 이용한 임계질량속 예측 결과	30
표 6. SCFNN과 CFNN 모델의 예측 성능 비교	32

그림 목차

그림 1. g -번째 FNN 모듈	5
그림 2. SCFNN 모델	8
그림 3. CFNN 모델	8
그림 4. DFNN 모델 최적화 과정	12
그림 5. 복잡도에 따른 오버피팅 경향	14
그림 6. $F(g)$ 에 의한 최적의 FNN 모듈 수 계산	14
그림 7. 테스트 데이터가 고정 간격일 경우 입력 값에 대한 임계질량속 예측 ...	17
그림 8. 테스트 데이터가 5 MPa 경우 입력 값에 대한 임계질량속 예측	19
그림 9. 테스트 데이터가 고정 간격일 경우 입력 값에 대한 임계압력 예측	22
그림 10. 테스트 데이터가 5 MPa 경우 입력 값에 대한 임계압력 예측	24
그림 11. case 1, 2에 대해 예측 된 임계질량속의 히스토그램	27
그림 12. SCFNN 단계에 따른 RMS 오차의 경향	31
그림 13. CFNN 단계에 따른 RMS 오차의 경향	31

ABSTRACT

Critical Flow Estimation Using Deep Fuzzy Neural Networks

Ye Ji An

Advisor : Prof. Man Gyun Na, Ph.D.

Department of Nuclear Engineering

Graduate School of Chosun University

In order to understand and quantify reactor coolant leakage in nuclear power plants, it is important to identify and simulate the leak phenomena of the fluid. When reactor coolant leaks from a high pressure and temperature reactor coolant system, two-phase mixture or vapor is ejected by the flashing phenomenon and has critical flow features. Therefore, critical flow analysis is needed to identify and quantify the leakage phenomena.

In this study, deep fuzzy neural networks (DFNNs) based on the artificial intelligence methods are developed to predict the critical flow. The total acquired data used for predicting critical flow consist of 5116 input and output data pairs.

The DFNNs refer to a methodology that includes the previously developed cascaded fuzzy neural networks (CFNNs) and the simplified cascade fuzzy neural networks (SCFNNs). The proposed DFNN model uses the data obtained from the Henry - Fauske model to understand the fluid properties and predict the critical flow. This model performed very well when compared to existing the machine learning methods.

It is expected that effective information will be provided to quantify the reactor

coolant leak from the DFNN model. Also, the developed DFNN model can be used as a universal standalone program to predict critical flow, which runs faster without iterative calculations, and without a need for steam tables.

제 1 장 서 론

임계유동은 노즐 또는 오리피스 유출을 통해 묘사될 수 있는데, 이를 통한 기체유동의 경우 출구압력과 배압, 임계압력이 동일할 때 최대유량인 상태를 말한다[1]. 이 상태의 압력을 임계압력이라고 하며, 배압을 이 압력 이하로 계속해서 낮추어도 노즐 내의 기체유동은 초크된 상태를 유지하게 된다. 유량이 더 이상 증가하지 않고 노즐 및 오리피스 내의 압력 분포 또한 변화하지 않으며, 압력분포는 출구압력 및 임계압력이 같고 배압은 이들보다 낮은 상태를 갖게 된다. 출구를 벗어난 후에 유동은 적용된 배압까지 낮게 조정된다[2]. 즉, 유동은 하류의 조건과 관계없이 상류측 조건에 의해 결정되며, 배관 내부에서 유체의 유량은 주어진 상류측 조건하에서 최댓값인 임계유량을 초과할 수 없다[3].

임계유동은 원자로 냉각재상실사고(LOCA; Loss of Coolant Accident) 또는 증기발생기전열관파단사고(SGTR; Steam Generator Tube Rupture)시에 파단부위를 통한 냉각재 방출유량을 결정한다. 또한, 원전의 안전한 정지를 시키기 위해서 설치되는 감압계통의 방출유량도 임계조건에 의해 결정된다. 이 때 방출유량은 원자력발전소의 냉각계통의 냉각재 재고량을 결정짓는 데 고려되며, 이는 곧 노심 냉각능력과 직결된다. 따라서 임계유동에 대한 정확한 지식이 요구되며, 이를 예측하는 것은 안전성 분석 및 안전계통 최적설계 관점에서 매우 중요하다. 유체의 상태에 따른 적절한 임계유동 예측은 누설현상을 이해하고 누설량을 정량화하기 위한 과정으로 원전의 안전성 및 건전성을 유지하는 데 필수적이다.

이전의 연구[4]에서 제안된 임계유동 맵은 증기와 물이 혼합된 임계 유속과 압력에 대해서 확장된 Henry-Fauske 모델[5]을 사용했다. 다른 연구[1]에서는 0.5~20MPa의 상류 정체 압력에 대해서 two-phase 과냉각수 및 포화된 물에 대한 10% 오차 범위 내에서 임계 유량을 예측했다. 본 논문에서는 인공지능 방법론을 사용하여 원자력발전소 내에서 임계유동을 정확하게 예측하고자 한다.

본 연구 외에도 최근 원자력발전소에 인공지능을 적용한 연구가 활발히 진행되고 있다. Guimaraes et al.[6]는 Westinghouse AP1000 원자로에서 LOCA에 적용되는 퍼지 불확실성 모델링 접근법을 제시했고, Tian et al.[7]은 원자력발전소의 LOCA 탐지를 위해 신경망 구조를 최적화하기 위한 제약 기반 유전자 알고리즘을 제시했다. 이외에

도 Yang and Kim[8]은 Long Short-term Memory(LSTM) 신경망을 이용한 사고 진단 알고리즘을 제안했고, Yoo et al.[9]는 원자력 발전소의 중대사고 진단을 위한 스마트 지원 시스템을 개발하였으며, Koo et al.[10]은 Deep Neural Networks(DNNs)를 사용한 중대사고 상황 시 원자로 용기 수위 예측 방법을 제안했다.

본 논문에서는 LOCA의 상황에서 임계유동을 예측하기 위해 심층퍼지신경망(DFNN; Deep Fuzzy Neural Network) 방법이 사용되었다. 기존에 제안되었던 Simplified Cascade Fuzzy Neural Network(SCFNN)과 Cascaded Fuzzy Neural Network(CFNN) 방법론을 DFNN 이라고 정의하였으며, SCFNN 모델은 CFNN의 복잡한 구조를 단순화 시킨 모델이다. DFNN 모델은 Fuzzy Neural Network(FNN) 모듈이 직렬로 연결된 형태이다. 기존의 연구에서 CFNN 방법론은 Duan and Chung[11], Kim et al.[12]에 의해 각각 다른 형태의 CFNN 모델이 제안되었다. CFNN 방법론은 이전에 원자력 분야에서 핵비등율[12], 원자로용기 수위[13], 수소농도[14] 등을 예측하는 데 사용되어졌다.

제안된 DFNN 모델은 개발 및 검증을 위해 데이터가 요구되는 데이터 기반 모델로 균질 비평형 Henry-Fauske 모델에서 생성된 시뮬레이션 데이터에 의해 학습되고 검증되었다.

제 2 장 Deep Fuzzy Neural Network(DFNN) 모델

본 논문에서 임계유동을 예측하는 데 사용된 인공지능 방법론은 인공신경망 구조를 기반으로 한 FNN, DFNN(CFNN, SCFNN) 알고리즘을 사용하였으며 머신러닝의 대표적인 기법으로 분류 및 회귀 분석에서 좋은 성능으로 알려진 SVR(Support Vector Machine) 모델을 이용하여 예측한 결과와 비교하였다. 해당 방법의 대표적인 특징으로는 인공신경망을 기반으로 한 방법들과 비교했을 때 상대적으로 오버피팅이 발생 확률이 적다는 장점을 갖고 있지만, 훈련시간이 오래 걸리는 단점을 갖고 있다. 다양한 분야에서 사용되는 알고리즘이다.

본 논문에서는 SCFNN 모델과 기존에 개발된 CFNN 모델을 DFNN이라고 정의하였다. 임계유동을 예측하기 위해서 DFNN 모델을 사용하였고, 이 모델을 다방면으로 비교하였다. DFNN 모델의 기반인 FNN 모델은 퍼지 추론 계통(FIS; Fuzzy Inference System)과 인공신경망 구조가 합성된 형태의 알고리즘으로, 퍼지 추론 과정을 레이아웃 시키고 성능에 직접적인 관련이 있는 퍼지화 레이어(if-then 규칙)를 보다 더 간단히 조절할 수 있게 한 모델이다. 따라서 FNN 모델에서는 if-then 규칙을 대량으로 늘려 더욱 복잡한 계산을 수행할 수 있지만, 동시에 구조의 대형화로 인해 다소 많은 시간 비용이 요구될 수 있는 특징을 가지고 있다.

제 1 절 DFNN 방법론

DFNN 모델은 퍼지 추론 계통을 인공신경망에 구현한 것으로, 퍼지 추론 계통은 조건부 및 결론부의 쌍으로 구성되어 if-then과 같은 조건부 규칙이 이용된다. FNN 모델을 기반으로 하는 방법으로 두 개 이상의 FNN 모듈을 추가하여 변수를 정확하고 효과적으로 예측하는데 사용된다. 또한, 이 모델은 오버피팅이 발생할 경우에 FNN 모듈 추가를 중지하도록 구현되어 있으며, 각 모듈은 퍼지화, 퍼지 추론 및 학습단위가 포함되어 있다. 기존의 FNN 모델은 단일단계의 퍼지 추론 계통을 구현하기 위해 제안되었으나, 본 연구에서는 삼단 논법 퍼지 추론을 사용하였다. 사용된 삼단 논법의 퍼지 추론 계통은 이전 추론단계의 결과가 다음 단계의 사실로 적용되는 과정으로 많은 데이터를 높은 수준으로 축적시키는 방법으로 대규모 시스템을 구축하는데 효과적인 방

법이다[11].

본 논문에서는 결론부 퍼지명제와 조건부 퍼지명제의 함수관계로부터 추론 및 최적화를 시키는 Takagi-Sugeno-type 퍼지 추론 계통이 사용되었으며, 주된 특징은 명확한 출력 값을 계산하기 때문에 출력 터미널에 비퍼지화를 위한 레이어가 없고 이에 따라 해당 과정을 계산하기 위한 시간 소요가 적다는 특징을 지니고 있다[15, 16]. 임의의 i 번째 규칙에서 퍼지 추론 계통 식은 (1)과 같이 나타낼 수 있다.

$$\begin{aligned} & \text{If } x_1(k) \text{ is } P_{i1} \text{ AND } \cdots \text{ AND } x_m(k) \text{ is } P_{im}, \\ & \text{then } \hat{y}^i(k) \text{ is } f^i(x_1(k), \cdots, x_m(k)) \end{aligned} \quad (1)$$

$x_j(k)$ 은 FNN 모듈의 입력변수를 나타내고 ($j=1,2, \cdots, m$), P_{ij} 는 i -번째 퍼지 규칙, j -번째 입력변수의 membership 함수를 나타낸다. $f^i(x_1(k), \cdots, x_m(k))$ 는 i -번째 퍼지 규칙의 출력 값을 나타내며, 입력변수들의 1차 다항식 형태로 식 (2)와 같이 나타낼 수 있다.

$$f^i(\mathbf{x}(k)) = \sum_{j=1}^m w_{ij}x_j(k) + r_i \quad (2)$$

여기서

w_{ij} : i -번째 퍼지 규칙과 j -번째 입력변수의 가중치

r_i : i -번째 퍼지 규칙의 바이어스




그림 1. g -번째 FNN 모듈

그림 1은 g -번째 퍼지 신경망 모듈의 퍼지 추론 계통 계산 방법을 나타낸 것이다. 신경망 모듈은 Input, Membership, Multiplication, Normalization, Weighting, 그리고 Output으로 총 6개의 레이어로 구성되어 있다. 첫 번째 레이어인 Input 레이어는 입력 값을 다음 레이어로 직접 전달하는 층으로 각각의 출력 값은 membership 함수의 입력 값으로 전달되어진다. 두 번째 레이어는 Membership 레이어로 최적화 된 매개변수들을 줄이기 위해서 Gaussian membership 함수를 이용하여 membership 값을 계산하며 식 (3)과 같이 나타낼 수 있다.

$$P_{ij}(x_j(k)) = \exp\left(-\frac{(x_j(k) - c_{ij})^2}{2\sigma_{ij}^2}\right) \quad (3)$$

Gaussian 함수는 종 모양으로 식 (3)에서 매개변수 i 는 퍼지 규칙 수, j 는 입력 변수의 수, c_{ij} 는 peak의 중심점, σ_{ij} 는 종 모양의 폭을 결정하는 변수를 나타낸다. 이 변수들은 선행 매개변수이며, Gaussian membership 함수의 주요 매개변수이다.

세 번째 레이어인 Multiplication 레이어는 식 (4)에 의해서 membership 함수에 의한 값들을 곱하는 기능을 수행한다.

$$\omega^i(k) = \prod_{j=1}^m P_{ij}(x_j(k)) \quad (4)$$

네 번째 레이어는 Normalization 레이어로 식 (5)에 의하여 정규화를 수행한다.

$$\bar{\omega}^i(k) = \frac{\omega^i(k)}{\sum_{i=1}^n \omega^i(k)} \quad (5)$$

다섯 번째로 Weighting 레이어는 정규화 된 가중치와 각 퍼지의 규칙의 출력 값이 곱해진다. 마지막으로, Output 레이어는 다섯 번째 레이어로부터 계산된 값을 입력 값으로 받아 식 (6)과 같이 합해진다.

$$\hat{y}(k) = \sum_{i=1}^n \bar{\omega}^i(k) \hat{y}_i(k) = \sum_{i=1}^n \bar{\omega}^i(k) f^i(\mathbf{x}(k)) = \mathbf{w}^T(k) \boldsymbol{\theta} \quad (6)$$

여기서

$$\mathbf{w}(k) = [\bar{\omega}^1(k)x_1(k) \cdots \bar{\omega}^n(k)x_1(k) \cdots \bar{\omega}^1(k)x_m(k), \cdots \bar{\omega}^n(k)x_m(k)\bar{\omega}^1(k) \cdots \bar{\omega}^n(k)]^T$$

$$\theta = [\theta_{11} \cdots \theta_{n1} \cdots \theta_{1m} \cdots \theta_{nm} \cdots r_1 \cdots r_n]^T.$$

벡터 θ 는 $(m+1) \times n$ 차원의 결과 파라미터 벡터이며, $\mathbf{w}(k)$ 는 입력데이터와 membership 함수 값을 사용하여 계산된다. 따라서 예측한 출력 값은 식 (7)과 같이 정의될 수 있다.

$$\hat{y}_t = \mathbf{W}_t \theta \tag{7}$$

여기서 행렬 \mathbf{W}_t 는 $(m+1)n \times N_t$ 의 차원을 가지고 있다.

$$\hat{y}_t = [\hat{y}(1) \hat{y}(2) \cdots \hat{y}(N_t)]^T$$

$$\mathbf{W}_t = [\mathbf{w}(1) \mathbf{w}(2) \cdots \mathbf{w}(N_t)]^T$$

DFNN이라고 정의한 SCFNN 모델과 CFNN 모델은 삼단 논법 퍼지 추론을 기반으로 하는 모델이다. SCFNN 모델은 기존에 개발된 CFNN 모델[12]에서 구조를 단순화시킨 모델로써, CFNN 모델은 이전의 모든 FNN 모듈의 출력이 다음 모듈로 전달되는 복잡한 구조로 이루어져 있어 많은 시간이 소요된다. 그림 2는 SCFNN, 그림 3은 CFNN의 개략도를 나타낸다. 기존 모델인 CFNN은 모든 단계의 출력변수를 입력변수로 사용하였지만, SCFNN 모델은 바로 직전 단계에서 최적화 되어진 출력변수만 입력변수로 사용한다. 이 과정을 G 번 반복하여 수행한다. SCFNN의 각 단계에서 임의의 i -번째 규칙은 식 (8), CFNN의 각 단계에서 임의의 i -번째 규칙은 식 (9)와 같이 나타낼 수 있다.

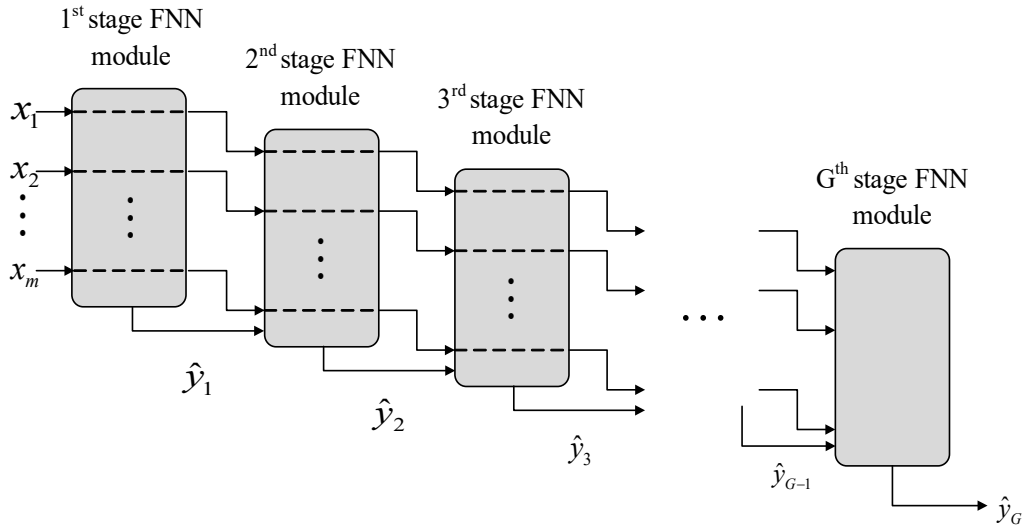


그림 2. SCFNN 모델

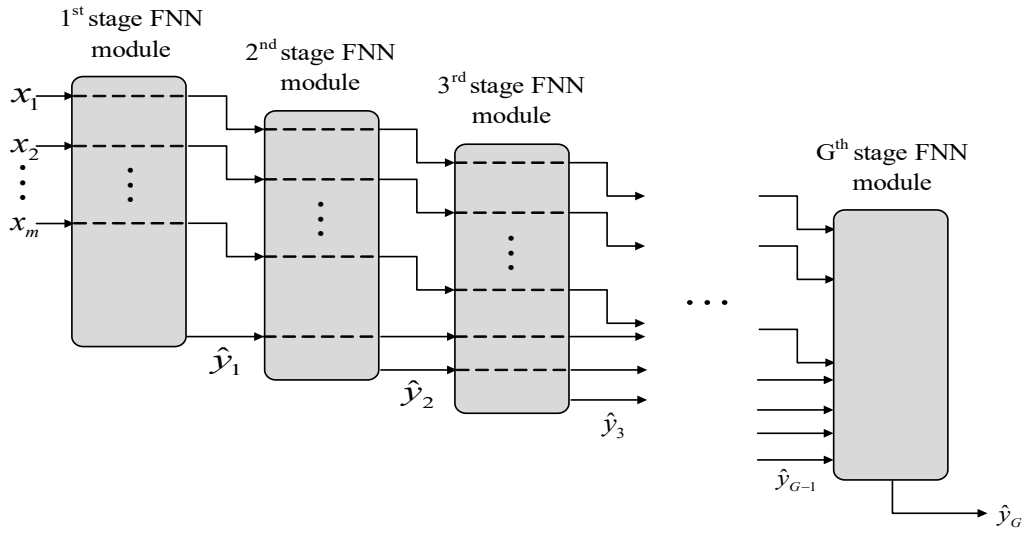


그림 3. CFNN 모델

$$\begin{aligned}
 & \text{Stage 1} \left[\begin{array}{l} \text{If } x_1(k) \text{ is } P_{i1}^1(k) \text{ AND } \cdots \text{ AND } x_m(k) \text{ is } P_{im}^1(k), \\ \text{then } \hat{y}_1^i(k) \text{ is } f_1^i(x_1(k), \cdots, x_m(k)) \end{array} \right] \\
 & \text{Stage 2} \left[\begin{array}{l} \text{If } x_1(k) \text{ is } P_{i1}^2(k) \text{ AND } \cdots \text{ AND } x_m(k) \text{ is } P_{im}^2(k), \\ \text{AND } \hat{y}_1(k) \text{ is } P_{i(m+1)}^2(k) \\ \text{then } \hat{y}_2^i(k) \text{ is } f_2^i(x_1(k), \cdots, x_m(k), \hat{y}_1(k)) \end{array} \right] \\
 & \quad \vdots \\
 & \text{Stage } g \left[\begin{array}{l} \text{If } x_1(k) \text{ is } P_{i1}^g(k) \text{ AND } \cdots \text{ AND } x_m(k) \text{ is } P_{im}^g(k), \\ \text{AND } \hat{y}_{g-1}(k) \text{ is } P_{i(m+1)}^g(k), \\ \text{then } \hat{y}_g^i(k) \text{ is } f_g^i(x_1(k), \cdots, x_m(k), \hat{y}_{g-1}(k)) \end{array} \right] \quad (8) \\
 & \quad \vdots \\
 & \text{Stage } G \left[\begin{array}{l} \text{If } x_1(k) \text{ is } P_{i1}^G(k) \text{ AND } \cdots \text{ AND } x_m(k) \text{ is } P_{im}^G(k), \\ \text{AND } \hat{y}_{G-1}(k) \text{ is } P_{i(m+1)}^G(k), \\ \text{then } \hat{y}_G^i(k) \text{ is } f_G^i(x_1(k), \cdots, x_m(k), \hat{y}_{G-1}(k)) \end{array} \right] \\
 & \quad \vdots \\
 & \text{Stage 1} \left[\begin{array}{l} \text{If } x_1(k) \text{ is } P_{i1}^1(k) \text{ AND } \cdots \text{ AND } x_m(k) \text{ is } P_{im}^1(k), \\ \text{then } \hat{y}_1^i(k) \text{ is } f_1^i(x_1(k), \cdots, x_m(k)) \end{array} \right] \\
 & \text{Stage 2} \left[\begin{array}{l} \text{If } x_1(k) \text{ is } P_{i1}^2(k) \text{ AND } \cdots \text{ AND } x_m(k) \text{ is } P_{im}^2(k), \\ \text{AND } \hat{y}_1(k) \text{ is } P_{i(m+1)}^2(k) \\ \text{then } \hat{y}_2^i(k) \text{ is } f_2^i(x_1(k), \cdots, x_m(k), \hat{y}_1(k)) \end{array} \right] \\
 & \quad \vdots \\
 & \text{Stage } G \left[\begin{array}{l} \text{If } x_1(k) \text{ is } P_{i1}^G(k) \text{ AND } \cdots \text{ AND } x_m(k) \text{ is } P_{im}^G(k), \\ \text{AND } \hat{y}_1(k) \text{ is } P_{i(m+1)}^G(k) \text{ AND } \cdots \text{ AND } \hat{y}_{G-1}(k) \text{ is } P_{i(m+G-1)}^G(k), \\ \text{then } \hat{y}_G^i(k) \text{ is } f_G^i(x_1(k), \cdots, x_m(k), \hat{y}_1(k), \cdots, \hat{y}_{G-1}(k)) \end{array} \right] \quad (9)
 \end{aligned}$$

여기서 G 는 총 단계의 수를 나타내며, $P_{ij}^g(k)$ 는 g -번째 단계에서 i -번째 퍼지규칙, j -번째 입력 값의 membership 함수를 나머지 변수들은 식 (1)에서 설명했던 값과 동일하다.

제 2 절 DFNN 모델 최적화

유체의 성질에 따른 임계유동을 예측하기 위해서 개발된 각각의 FNN 모듈은 유전자 알고리즘과 훈련데이터의 최소자승법에 의하여 훈련되고 최적화된다.

유전자 알고리즘의 경우, 최대 오차와 Root Mean Square(RMS) 오차를 최소화하기 위해서 식(10), (11)과 같은 적합성 함수를 나타낸다.

$$F_1 = \exp(-\lambda_1 E_{\max 1} - \lambda_2 E_{\max 1}), \quad (10)$$

$$F_2 = \exp(-\lambda_1 E_{\max 2} - \lambda_2 E_{\max 2}), \quad (11)$$

여기서

$$E_{\max 1} = \sqrt{\frac{1}{N_t} \sum_{k=1}^{N_t} [y(k) - \hat{y}(k)]^2}$$

$$E_{\max 1} = \max |y(k) - \hat{y}(k)|, k = 1, 2, \dots, N_t$$

$$E_{\max 2} = \sqrt{\frac{1}{N_t + N_o} \sum_{k=1}^{N_t + N_o} [y(k) - \hat{y}(k)]^2}$$

$$E_{\max 2} = \max |y(k) - \hat{y}(k)|, k = 1, 2, \dots, N_t + N_o$$

$$E_2 = \max (y(k) - \tilde{y}(k))^2$$

λ_1, λ_2 : RMS 오차 및 최대 오차의 가중치 값

N_t : 학습용 데이터의 수

N_o : 검증용 데이터의 수

$y(k)$: 실제 값

$\hat{y}(k)$: FNN 모듈을 사용하여 예측된 출력 값

선택, 교배, 돌연변이와 같은 유전자 함수에 의해 입력 매개변수들이 결정되면, 벡터

θ 는 식 (7)처럼 최소자승법을 이용하여 계산된다. 즉, θ 는 목적함수를 최소화하기 위해서 선택된다. 목적함수는 식 (12)과 같이 실제 값과 예측 값 사이의 제곱오차로 표현된다.

$$\begin{aligned}
 J &= \sum_{k=1}^N [y(k) - \hat{y}(k)]^2 = \sum_{k=1}^N [y(k) - \mathbf{w}^T(k)\theta]^2 \\
 &= \frac{1}{2} (\mathbf{y}_t - \hat{\mathbf{y}}_t)^2
 \end{aligned} \tag{12}$$

여기서

$$\mathbf{y}_t = [y(1) \ y(2) \ \dots \ y(N_t)]^T$$

위의 식 (12)에서 목적 함수를 최소화하는 방법은 식 (13)과 같다.

$$\mathbf{y}_t = \mathbf{W}_t \theta \tag{13}$$

여기서 θ 는 pseudo-inverse에 의해 아래와 같이 계산된다.

$$\theta = (\mathbf{W}_t^T \mathbf{W}_t)^{-1} \mathbf{W}_t^T \mathbf{y}_t$$

즉, 여기서 θ 는 입력데이터와 출력데이터 쌍으로부터 계산된다.

그림 4는 DFNN 모델을 최적화하는 절차를 나타낸다. 유전자 알고리즘의 첫 단계는 각 개체를 설정한 후 적합도 함수를 이용하여 각 개체를 평가한다. 유전자 함수를 통해 입력 매개변수를 결정하면 결론부 매개변수들이 입력 매개변수와 1차적으로 결합하며 최소자승법에 의해 결정된다. FNN 모듈이 최적화되면 DFNN 모델이 최적화되었는지 확인하고 최적화가 되지 않았으면, 다음 FNN 모듈을 수행하게 된다. 모델이 최적화될 때까지 이 과정을 반복하여 수행하게 된다.

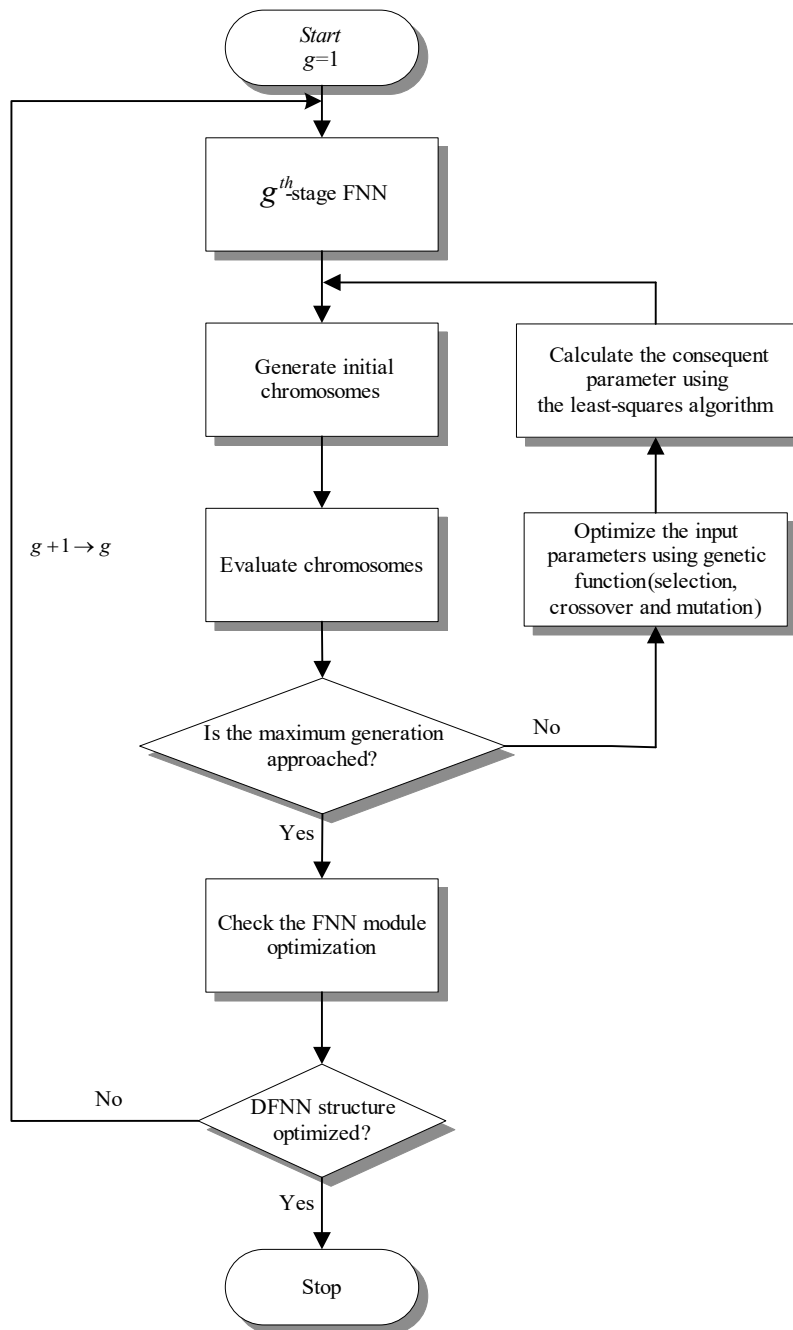


그림 4. DFNN 모델 최적화 과정

FNN 모듈에 레이어처럼 쌓인 형태인 DFNN 모델의 특징상 오버피팅의 문제가 발생할 수 있다. 모듈의 층이 쌓임에 따라서 복잡도는 증가하게 되며 오버피팅의 발생 확률 또한 증가하게 된다. 그림 5는 복잡도에 따라 발생하는 언더피팅 및 오버피팅의 그래프를 나타낸다. 복잡도가 낮은 모델에서는 훈련 오차와 테스트 오차 모두 높은 결과를 보이며, 일정 지점까지는 모델의 복잡도가 증가할수록 훈련 오차와 테스트 오차 모두 감소한다. 적절한 복잡도를 갖는 모델은 이 두 오차 값이 모두 낮아지는 지점을 말한다. 그러나 모델 복잡도가 일정 지점을 넘어가게 되면 훈련 오차는 지속적으로 감소하는 반면에, 테스트 오차는 증가하게 된다. 이러한 상태를 오버피팅이라고 정의할 수 있으며, 훈련 오차를 통해 어떠한 관계를 학습한 것이 아니고 데이터 자체를 암기해버린 것으로 판단할 수 있다. DFNN에서 오버피팅 방지를 위해서는 적절한 FNN 모듈 수를 정해야 하며, 이를 위해 식 (14)과 같은 검증데이터의 오차의 합을 이용한다. 그림 6은 $F(g)$ 계산에 의한 최적의 모듈 수의 계산 과정을 그림으로 표현한 것이며, 표시된 부분은 최적의 모듈 수를 나타낸다. 그림과 같이 오버피팅이 발생하면, 수행중이었던 FNN 모듈이 중지하게 되며, 최적화된 모듈 수를 구할 수 있게 된다.

$$F(g) = \sum_{k=N_i+1}^{N_i+N_o} [y(k) - \hat{y}(k)]^2 \tag{14}$$

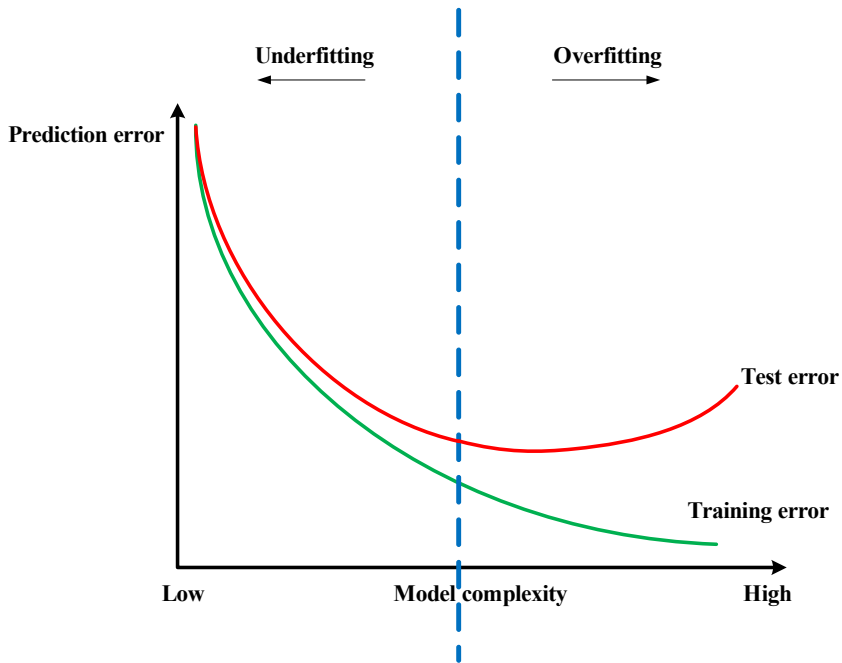


그림 5. 복잡도에 따른 오버피팅 경향

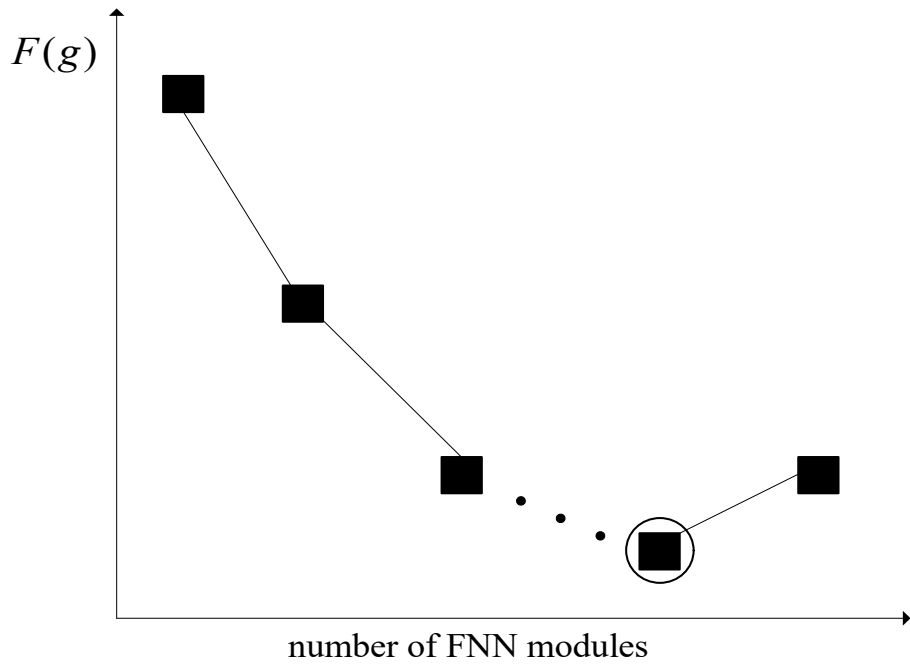


그림 6. $F(g)$ 에 의한 최적의 FNN 모듈 수 계산

제 3 장 DFNN 모델을 사용한 임계유동 예측

임계유동을 예측하기 위해서 본 논문에 사용된 데이터는 균질 비평형 Henry-Fauske 모델을 이용해 계산된 데이터로 과냉각수 및 포화증기의 경우 0.5~20 MPa의 압력 범위이다. DFNN 모델의 입력 변수는 배관이나 탱크 내부의 압력, 온도, 엔탈피 및 증기건도를 사용하였다[4].

본 연구에서 사용하기 위해 수집된 모든 데이터(5116개의 입·출력데이터)는 훈련데이터, 검증데이터 및 테스트 데이터로 분류된다. 훈련데이터는 각각의 FNN 모듈을 훈련시키기 위해서 사용되고 검증데이터는 최적화 된 FNN 모듈의 수를 결정 즉, 오버피팅 문제를 방지하여 DFNN의 구조를 결정하는 데 사용된다. 보통 훈련데이터와 검증데이터를 개발데이터로 부르며, 본 논문에서 검증데이터는 개발데이터의 10%가 사용되었다. 또한 테스트 데이터는 DFNN 모델을 훈련하는 데 사용되지 않고 개발된 DFNN 모델의 성능을 검증하는 데 사용되며, 성능은 RMS 오차, 최대오차를 통해 확인하였다. 본 연구에서는 개발된 DFNN 모델을 검증하기 위해 2가지 종류의 테스트 사례를 선정하였다. 하나는 획득된 데이터 중에서 고정된 간격으로 전체 데이터의 5%를 테스트 데이터로 선택하였고(사용된 데이터는 테스트 데이터 248개, 훈련데이터 4390개, 검증데이터 478개) 다른 하나의 경우는 5 MPa의 모든 데이터를 테스트 데이터로 선택하였다(사용된 데이터는 테스트 데이터 223개, 훈련데이터 4412개, 검증데이터 481개). 앞서 언급한대로 선택된 테스트 데이터는 DFNN 모델을 훈련시키는 데 사용하지 않았다.

표 1부터 4까지는 DFNN 모델을 사용하여 예측한 결과이다. 먼저, 본 논문에서 사용된 SCFNN 모델은 퍼지 규칙의 수를 5, 7, 9, 11, 13, 15로 임의로 정하여 임계유동을 예측하였다. 그림 7부터 10까지는 우수한 성능을 나타낸 퍼지 규칙 수인 13에 대한 예측 결과를 그래프로 나타낸 것이다. 그래프에서 G_c 는 임계질량속, P_c 는 임계압력, h_o 는 정체엔탈피를 나타낸다. 표 1과 2는 SCFNN 모델을 사용하여 예측한 임계질량속의 RMS 오차 및 최대 오차를 나타낸다. 표 1은 테스트 데이터가 일정한 간격일 경우의 결과를 나타내고, 표 2는 5 MPa의 모든 데이터가 테스트 데이터로 사용된 경우의 결과이다. 그림 7은 테스트 데이터가 일정한 간격일 경우 임계질량속에 대한 압력, 온도, 엔탈피, 증기건도의 예측 결과를 보여주는 그래프이다. 예측 값은 십자가 모양, 목

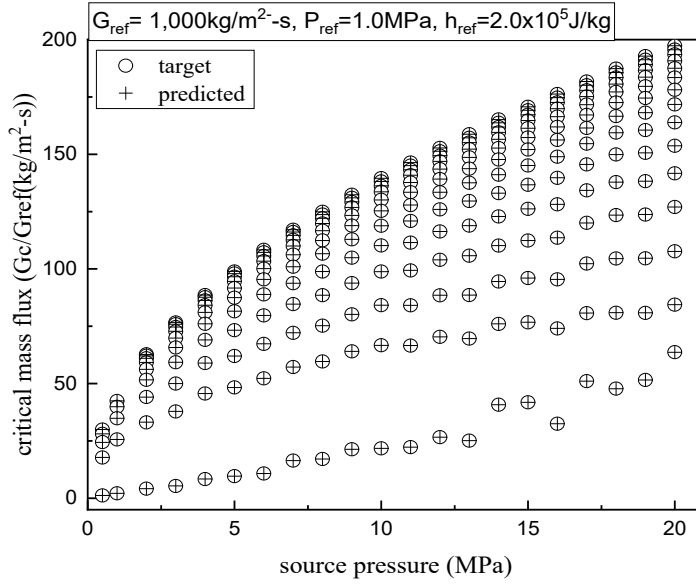
표 값은 원 모양으로 나타내었다. 그림 8은 테스트 데이터가 5 MPa 경우 임계질량속에 대한 압력, 온도, 엔탈피, 증기건도의 예측 결과를 보여주는 그래프이다. 예측 값은 십자가 모양, 목표 값은 원 모양으로 나타내었다.

표 1. 테스트 데이터가 고정 간격인 경우 SCFNN을 이용한 임계질량속 예측 결과


Fuzzy rule number	Optimized number of FNN modules	Development data		Test data	
		RMS error (%)	Maximum error (%)	RMS error (%)	Maximum error (%)
5	22	0.6227	9.0296	0.6342	7.3609
7	20	0.3655	4.2718	0.2689	2.8457
9	15	0.2286	2.8268	0.1674	1.2934
11	17	0.1716	2.2123	0.1108	1.2616
13	18	0.1299	1.6519	0.1319	1.3604
15	8	0.1509	1.9980	0.1564	1.5141

표 2. 테스트 데이터가 5 MPa 경우 SCFNN을 이용한 임계질량속 예측 결과

Fuzzy rule number	Optimized number of FNN modules	Development data		Test data	
		RMS error (%)	Maximum error (%)	RMS error (%)	Maximum error (%)
5	24	0.5760	6.1891	0.5791	4.4321
7	21	0.3686	4.0859	0.4146	2.8343
9	22	0.2647	3.4681	0.1519	3.4681
11	16	0.1650	2.0509	0.1227	1.3626
13	12	0.1310	1.8234	0.1269	1.3287
15	16	0.1088	1.5668	0.1249	1.2168




(a) 압력




(b) 온도

그림 7. 테스트 데이터가 고정 간격일 경우 입력 값에 대한 임계질량속 예측

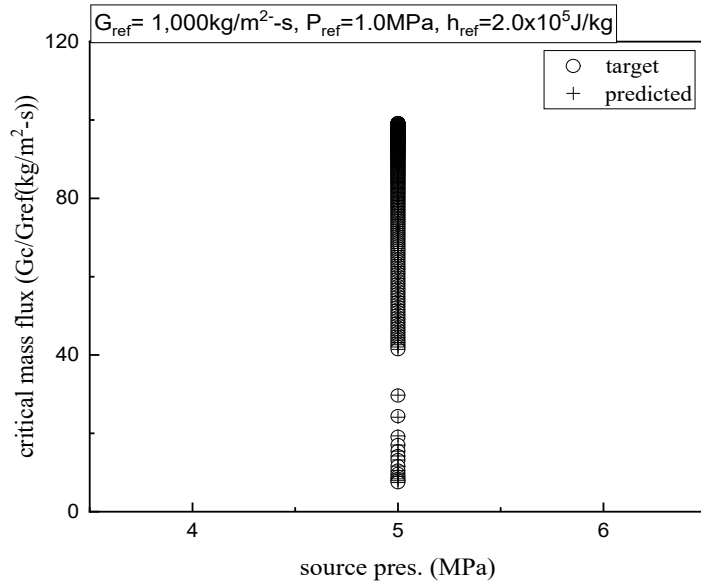


(c) 엔탈피




(d) 증기건도

그림 7. 테스트 데이터가 고정 간격일 경우 입력 값에 대한 임계질량속 예측 (계속)




(a) 압력




(b) 온도

그림 8. 테스트 데이터가 5 MPa 경우 입력 값에 대한 임계질량속 예측



(c) 엔탈피



(d) 증기건도

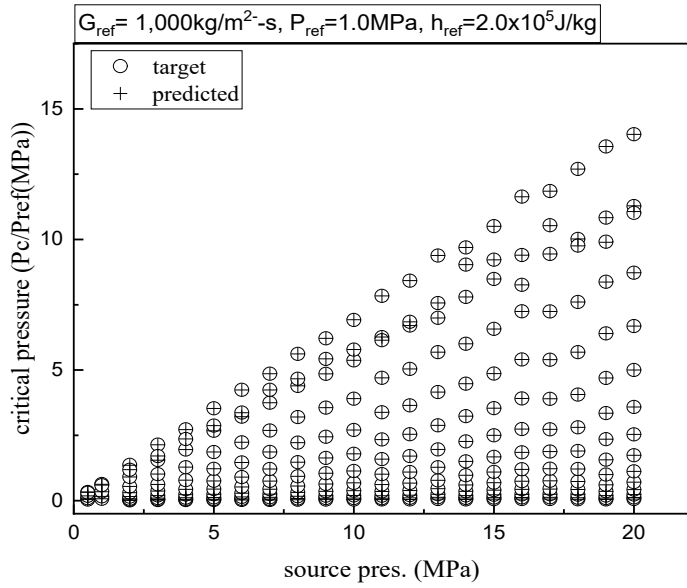
그림 8. 테스트 데이터가 5 MPa 경우 입력 값에 대한 임계질량속 예측 (계속)

표 3. 테스트 데이터가 고정 간격인 경우 SCFNN을 이용한 임계압력 예측 결과


Fuzzy rule number	Optimized number of FNN modules	Development data		Test data	
		RMS error (%)	Maximum error (%)	RMS error (%)	Maximum error (%)
5	37	0.6820	5.5024	0.5983	2.6596
7	20	0.7896	5.0704	0.8159	5.1574
9	10	0.9521	11.8873	0.9956	10.5326
11	7	0.8775	12.0899	0.6899	3.0934
13	22	0.4802	6.2584	0.6069	5.9953
15	17	0.4768	5.1160	0.5797	4.8251

표 4. 테스트 데이터가 5 MPa 경우 SCFNN을 이용한 임계압력 예측 결과

Fuzzy rule number	Optimized number of FNN modules	Development data		Test data	
		RMS error (%)	Maximum error (%)	RMS error (%)	Maximum error (%)
5	50	1.1204	9.6440	1.3340	4.9401
7	15	0.9472	7.5741	0.6394	2.9369
9	7	1.1429	11.5913	1.2131	4.0752
11	15	0.6851	7.7801	0.8145	1.8809
13	12	0.5110	5.3324	0.3659	1.3751
15	20	0.6338	7.5717	0.7027	2.4781

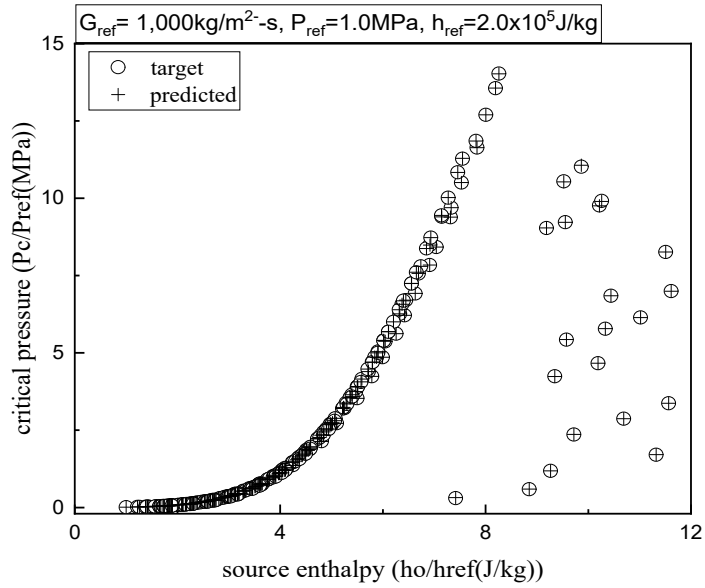


(a) 압력

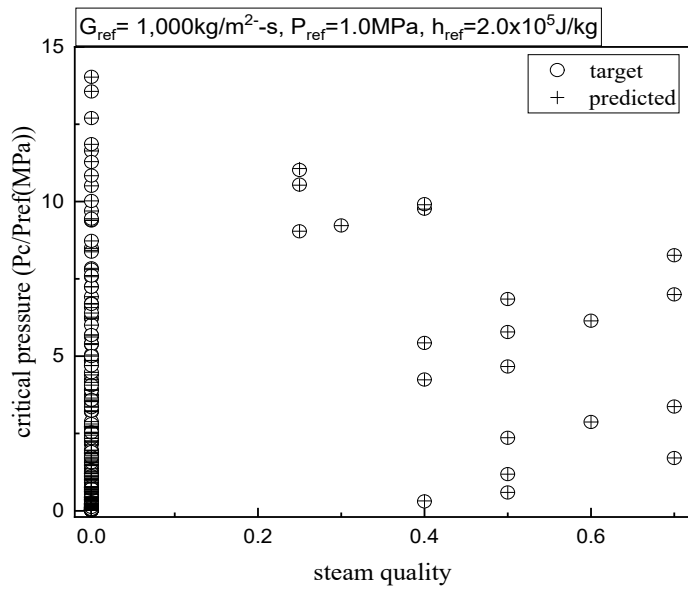


(b) 온도

그림 9. 테스트 데이터가 고정 간격일 경우 입력 값에 대한 임계압력 예측




(c) 엔탈피




(d) 증기건도

그림 9. 테스트 데이터가 고정 간격일 경우 입력 값에 대한 임계압력 예측 (계속)




(a) 압력




(b) 온도

그림 10. 테스트 데이터가 5 MPa 경우 입력 값에 대한 임계압력 예측



(c) 엔탈피




(d) 증기건도


그림 10. 테스트 데이터가 5 MPa 경우 입력 값에 대한 임계압력 예측 (계속)

표 3과 4는 SCFNN을 이용하여 예측한 임계 압력의 RMS 오차 및 최대 오차를 보여준다. 표 3은 테스트 데이터가 고정 간격인 경우 SCFNN을 이용한 임계압력 예측 결과를 나타내며, 표 4는 테스트 데이터가 5 MPa인 경우 SCFNN을 이용하여 임계압력을 예측한 결과를 나타낸다. 개발데이터 및 테스트 데이터에 대한 예측된 임계질량속의 RMS 오차는 0.15% 이하이다. SCFNN을 이용하여 임계질량속과 임계압력을 예측한 결과, 표 3과 4를 통하여 임계압력 예측 결과가 임계질량속 예측 결과에 비해 상대적으로 낮은 것을 확인할 수 있다.

그림 9는 테스트 데이터가 일정한 간격일 경우 임계압력에 대한 압력, 온도, 엔탈피, 증기건도의 예측 결과를 보여주는 그래프이다. 예측 값은 십자가 모양, 목표 값은 원 모양으로 나타내었다. 그림 10은 테스트 데이터가 5 MPa 경우 임계압력에 대한 압력, 온도, 엔탈피, 증기건도의 예측 결과를 보여주는 그래프이다. 예측 값은 십자가 모양, 목표 값은 원 모양으로 나타내었다. 표1에서 4가지 SCFNN을 이용하여 각 변수들을 예측한 결과는 비교적 작은 오차로 목표 값을 잘 예측하는 것을 확인할 수 있으며, 퍼지 규칙의 수가 13일 때 우수한 성능을 보였음을 확인하였다. 특히 임계질량속을 예측하는 2가지 test 사례에서 높은 정확도를 확인 할 수 있다. 그림 11은 이 2가지 테스트 사례에서 예측된 임계질량속의 히스토그램을 보여준다. 그림 11은 case 1과 2로 나누어 나타내었다. case 1은 테스트 데이터가 고정된 간격일 경우를, case 2는 테스트 데이터가 5 MPa일 경우에 각각의 데이터에 대한 히스토그램을 나타내었다.




(a) case 1에 대한 개발데이터




(b) case 1에 대한 테스트 데이터

그림 11. case 1, 2에 대해 예측된 임계질량속의 히스토그램



(c) case 2에 대한 개발데이터



(d) case 2에 대한 테스트 데이터

그림 11. case 1, 2에 대해 예측된 임계질량속의 히스토그램 (계속)

본 연구에서는 다양한 방법론의 비교 및 정확한 예측을 위해 회귀 성능이 뛰어난 것으로 잘 알려진 머신러닝(machine learning)의 대표적인 모델인 SVR[17]과 FNN 모델 [18]을 임계질량속 예측에 사용하였다. FNN은 DFNN의 기반이 되는 방법으로 단일 모듈이며, DFNN과의 예측성능 비교를 위해서 사용하였으며, SVR은 머신러닝의 대표적인 기법으로 인공신경망과 어떠한 성능 차이를 보이는지 확인하기 위해서 사용하였다.

FNN 및 SVR 모델에 관련된 파라미터는 유전자 알고리즘에 의해 최적화되며, 표 5는 최적화 된 FNN 및 SVR 모델의 RMS 오차 및 최대 오차를 나타낸다. 사용된 CFNN 모델은 SCFNN 모델을 사용하여 예측한 결과값 중 가장 우수한 성능을 보인 퍼지 규칙 13을 적용하여 비교하였다. FNN 모델의 결과는 DFNN의 첫 번째 모듈과 유사한 오차 결과를 보여야하지만 유전자 알고리즘의 임의의 특징으로 인해 달라질 수 있다. 본 연구에서 모든 AI 기술(DFNN(SCFNN, CFNN), FNN 및 SVR)에 대해 동일한 훈련데이터가 사용되었다. 임계유동을 예측하는 데 사용된 총 데이터는 5116개의 입력 및 출력데이터로 구성되며, 훈련데이터는 전체 데이터의 85%, 검증데이터는 전체 데이터의 10%, 테스트 데이터는 전체데이터의 5% 입력 및 출력데이터로 구성되어 있다. 훈련데이터는 유전자 알고리즘에 의해 SVR 파라미터를 최적화하기 위한 많은 시간을 요구한다. 이에 따라 SVR 성능이 저하될 수 있지만, 최적화가 잘 진행되어도 오차가 10배 이상 줄어들지 않기 때문에 성능에 큰 영향을 미치지 않는다. 표 5를 통해 분석한 결과 SCFNN과 CFNN 즉, DFNN 모델이 잘 훈련되었다고 확인할 수 있으며, 이는 임계유동을 예측할 때 다른 AI 기술보다 최대 20배 이상의 임계질량속을 더 정확하게 예측할 수 있다.

표 5. FNN, SVR 및 DFNN을 이용한 임계질량속 예측 결과

AI techniques		Selection of test data	Development data		Test data	
			RMS error (%)	Maximum error (%)	RMS error (%)	Maximum error (%)
FNN		fixed interval	1.3733	35.8083	2.0936	27.6168
		5 MPa	1.6117	30.3342	0.8548	4.0240
SVR		fixed interval	3.1271	85.3852	20.9463	311.0489
		5 MPa	1.7941	38.3062	0.6243	3.0986
DFNN	SCFNN	fixed interval	0.1299	1.6519	0.1319	1.3604
		5 MPa	0.1310	1.8234	0.1269	1.3287
	CFNN	fixed interval	0.0979	1.4932	0.2570	3.2640
		5 MPa	0.1006	1.4386	0.1999	2.1674

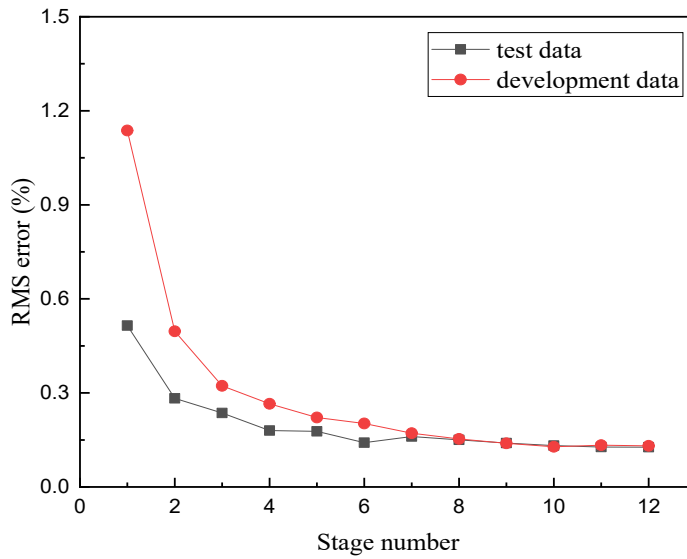


그림 12. SCFNN 단계에 따른 RMS error의 경향




그림 13. CFNN 단계에 따른 RMS error의 경향

그림 12는 SCFNN 단계에 따른 RMS 오차의 추세를 보여주는 그래프이며, 그림 13은 CFNN 단계에 따른 RMS 오차의 추세를 나타내는 그래프이다. 각각의 그래프는 stage 수가 증가함에 따라 RMS 오차가 감소하는 것을 확인할 수 있다.

표 6. SCFNN과 CFNN 모델의 예측 성능 비교

AI techniques	Test case	Development data		Test data		Optimized number of FNN modules	Training time (sec)
		RMS error (%)	Max error (%)	RMS error (%)	Max error (%)		
SCFNN	fixed interval	0.1299	1.6519	0.1319	1.3604	18	1.9952E+04
	5 MPa	0.1310	1.8234	0.1269	1.3287	12	1.6926E+04
CFNN	fixed interval	0.0979	1.4932	0.2570	3.2640	9	2.2267E+04
	5 MPa	0.1006	1.4386	0.1999	2.1674	8	1.6471E+04

마지막으로, 표 6은 SCFNN과 기존에 개발된 CFNN 모델의 예측 성능 비교를 나타낸다. CFNN에서 퍼지 규칙의 수는 SCFNN에서 우수한 성능을 보인 13으로 선택하여 예측 성능을 비교하였다. 테스트 데이터의 RMS 오차 및 최대 오차는 개발데이터의 두 배를 초과하는 것을 볼 수 있는데, 이 결과에서 CFNN 모델에 오버피팅이 발생한 것으로 예상되며. 이는 그림 13을 통해서도 확인할 수 있다. 이 결과는 CFNN 모델이 SCFNN 모델에 비해 더 많은 입력 값을 갖는 복잡한 구조를 가지고 있기 때문에 오버피팅이 발생한 것으로 예상된다. 제안된 SCFNN 모델에서 테스트 데이터의 RMS 오차 및 최대 오차는 개발데이터의 오차와 유사하다. 또한, SCFNN에 대한 RMS 오차 및 최대오차는 CFNN에 대한 오차보다 적은 것을 확인할 수 있다. 또한, 표 6에서 CFNN 모델이 SCFNN 모델에 비해서 최적의 값에 빨리 수렴함에 따라서 FNN 모듈 수가 적기 때문에 SCFNN과 CFNN 모델의 훈련 시간은 비슷한 수준을 갖는 것을 확인할 수 있다.

위와 같이 다양한 방법론의 비교를 통해 DFNN 방법론이 가장 우수한 성능을 보였음을 확인하였고, 더 세분화해서 DFNN 방법론에서 SCFNN 모델이 CFNN 모델에 비해 조금 더 우수한 성능을 보였고, 오버피팅 문제에 강함을 확인할 수 있었다.

임계유동을 예측하기 위해 개발된 DFNN 모델은 열수력 시설의 제작과 임계유동과 관련된 타 분야에서의 연구를 위해 개발되었다.

제 4 장 결론

원자력발전소에서 임계유동을 예측하는 것은 원자로의 건전성 및 안전성 측면에서 매우 중요하다. 본 논문에서는 임계질량속 및 임계압력을 Deep Fuzzy Neural Network(DFNN) 모델을 사용하여 예측하였다. 원자력발전소에서 Loss of Coolant Accidents 시에 원자로 냉각재의 누설현상을 이해하고 정량화하기 위해서는 정확한 임계유동의 분석이 필요하다. 제안된 DFNN 모델은 개발데이터와 독립적인 테스트 데이터를 이용하여 검증하였다. 제안된 DFNN 방법론 중 Simplified cascade fuzzy neural network(SCFNN) 모델은 기존 Cascade Fuzzy Neural Network(CFNN) 모델보다 구조가 간단하고 오버피팅 문제에 더 강하다는 장점을 가지고 있다. 또한, Root Mean Square(RMS) 오차는 DFNN 모델의 stage 수가 증가함에 따라 감소하는 경향을 보였다.

DFNN 모델을 통해 임계질량속, 임계압력을 예측한 결과 SCFNN과 CFNN 모델 모두 우수한 성능을 보였다. 특히 SCFNN 모델은 퍼지 규칙의 수가 13일 경우에 가장 우수한 성능을 보인 것을 확인하였으며, 임계질량속 예측 결과는 테스트 데이터의 RMS 오차 수준이 약 0.15% 이하임을 확인하였다. CFNN 모델을 이용한 예측결과는 오버피팅 문제가 발생하였지만, 충분히 정확한 예측 결과를 확인함으로써 제안된 모델은 적용된 인공지능 방법 중 머신러닝의 대표적인 방법인 Fuzzy Neural Network(FNN), Support Vector Regression에 비해 우수함을 검증하였다.

결과적으로 임계질량속 및 임계압력은 DFNN 방법을 이용하여 보다 정확하게 예측할 수 있으며, 이는 유체의 임계유동을 분석함으로써 원자로의 냉각재 누설현상을 이해하고 누설량을 정량화 하는 데 도움이 될 것으로 판단된다. 또한, 개발된 DFNN 모델은 반복적인 계산이나 증기표가 없어도 빠르게 예측하는 범용 독립형 프로그램으로도 사용할 수 있을 것으로 예상하며, 임계유동을 예측함으로써 원자로의 안전성 및 건전성을 보장할 수 있을 것으로 판단된다.

참고문헌

- [1] Y. S. Kim, A proposed correlation for critical flow rate of water flow, *Nucl. Eng. Technol.* 47 (2015) 135-138.
- [2] FOX, McDONALD, PRITCHARD, *Fluid mechanics*, WILEY, (2011)
- [3] H. D. Kim, J. H. Kim, K. A. Park, Study for the gas flow through a critical nozzle, *Proceedings of 4th ASME_JSME Joint Fluids Engineering Conference*, (2003) 532-537.
- [4] Y. S. Kim, Critical flow maps using an extended Henry-Fauske model, *Annals of Nuclear Energy.* 75 (2015) 516-520.
- [5] R. E. Henry, H. K. Fauske, The two-phase critical flow of one component mixtures in nozzles, orifices, and short tubes, *ASME Journal of Heat Transfer.* 93 (1971) 179-187.
- [6] A. C. F. Guimaraes, C. M. F. Lapa, F. F. L. S. Filho, D. C. Cabral, Fuzzy uncertainty modeling applied to AP1000 nuclear power plant LOCA. *Annals of Nuclear Energy* 38(8), (2011) 1775-1786.
- [7] D. Tian, J. Deng, G. Vinod, TV. Santhosh, H. Tawfik, A constraint-based genetic algorithm for optimizing neural network architectures for detection of loss of coolant accidents of nuclear power plants. *Neurocomputing* 322, (2018) 102-119.
- [8] J. M. Yang, J. H. Kim, An accident diagnosis algorithm using long short-term memory. *Nucl. Eng. Technol.* 50(4), (2018) 582-588.
- [9] K. H. Yoo, J. H. Back, M. G. Na, S. Hur, H. M. Kim, Smart support system for diagnosing severe accidents in nuclear power plants. *Nucl. Eng. Technol.* 50(4), (2018) 562-569.
- [10] Y. D. Koo, Y. J. An, C. H. Kim, M. G. Na, Nuclear reactor vessel water level prediction during severe accidents using deep neural networks. *Nucl. Eng. Technol.* 51(3), (2019) 723-730.
- [11] J. C. Duan and F. L. Chung, Cascaded fuzzy neural network model based on

- sylogistic fuzzy reasoning, IEEE Trans. Fuzzy Syst. 9 (2001) 293 - 306.
- [12] D. Y. Kim, K. H. Yoo, M. G. Na, Estimation of minimum DNBR using cascaded fuzzy neural networks, IEEE Trans. Nucl. Sci. 62 (2015) 1849-1856.
- [13] D. Y. Kim, K. H. Yoo, G. P. Choi, J. H. Back, M. G. Na, Reactor vessel water level estimation during severe accidents using cascaded fuzzy neural networks, Nucl. Eng. Technol. 48 (2016) 702-710.
- [14] G. P. Choi, D. Y. Kim, K. H. Yoo, M. G. Na, Prediction of hydrogen concentration in nuclear power plant containment under severe accidents using cascaded fuzzy neural networks, Nucl. Eng. Des. 300 (2016) 393-402.
- [15] M. Negnevitsky, Artificial intelligence: a guide to intelligent systems. Pearson education, 2005.
- [16] T. Takagi, M. Sugeno, Fuzzy identification of systems and its applications to modeling and control, IEEE Trans. Systems, Man, Cybern. SMC-1 (1985) 116-132.
- [17] D. S. Kim, S. W. Lee, M. G. Na, Prediction of axial DNBR distribution in a hot fuel rod using support vector regression models. IEEE Trans. Nucl. Sci. 58, (2011) 2084-2090.
- [18] M. G. Na, On-line Estimation of DNB Protection Limit via a Fuzzy Neural Network, Nucl. Eng. Technol. 30(3), (1998) 222-234.