



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

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

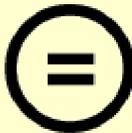
다음과 같은 조건을 따라야 합니다:



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](#)

2017년 2월
석사학위 논문

Cascaded Fuzzy Neural Networks
모델을 이용한 중대사고시 격납용기
압력 예측

조선대학교 대학원

원자력공학과

최 건 필

Cascaded Fuzzy Neural Networks 모델을 이용한 중대사고시 격납용기 압력 예측

Prediction of the containment pressure under severe
accidents using a cascaded fuzzy neural networks
model

2017년 2월 24일

조선대학교 대학원

원자력공학과

최 건 필

Cascaded Fuzzy Neural Networks
모델을 이용한 중대사고시 격납용기
압력 예측

지도교수 나 만 균

이 논문을 공학석사학위 신청 논문으로 제출함

2016년 10월

조선대학교 대학원

원자력공학과

최 건 필

최건필의 석사학위논문을 인준함

위원장 조선대학교 교수 송 종 순 (인)

위 원 조선대학교 교수 나 만 균 (인)

위 원 조선대학교 교수 김 진 원 (인)

2016년 11월

조선대학교 대학원

목 차

표 목차	ii
그림 목차	iii
Abstract	v
제 1 장 서론	1
제 2 장 Cascaded Fuzzy Neural Networks 모델	
제 1 절 CFNN 방법론	3
제 2 절 CFNN 모델 최적화	9
제 3 장 CFNN 모델을 사용한 격납용기 압력 예측	
제 1 절 CFNN 모델에 사용한 데이터	14
제 2 절 실험결과	16
제 4 장 결론	40
【참고문헌】	41

표 목차

표 1. 고온관에서 소형파단인 경우 CFNN 모델의 수행결과	16
표 2. 고온관에서 대형파단인 경우 CFNN 모델의 수행결과	20
표 3. 저온관에서 소형파단인 경우 CFNN 모델의 수행결과	24
표 4. 저온관에서 대형파단인 경우 CFNN 모델의 수행결과	28
표 5. 증기발생기 튜브에서 소형파단인 경우 CFNN 모델의 수행결과	32
표 6. 증기발생기 튜브에서 대형파단인 경우 CFNN 모델의 수행결과	36

그림 목차

그림 1. FNN 모듈의 퍼지추론계통(FIS)	6
그림 2. CFNN 모델 최적화 과정	11
그림 3. CFNN 모델의 모듈 수 증가에 따른 $F(k)$ 의 경향	13
그림 4. 데이터의 구조	15
그림 5. 고온관에서 소형파단인 경우 CFNN 모델의 RMS 오차	17
그림 6. 고온관에서 소형파단인 경우 CFNN 모델의 최대 오차	18
그림 7. 고온관에서 소형파단인 경우 CFNN 모델의 격납용기 압력 예측	19
그림 8. 고온관에서 대형파단인 경우 CFNN 모델의 RMS 오차	21
그림 9. 고온관에서 대형파단인 경우 CFNN 모델의 최대 오차	22
그림 10. 고온관에서 대형파단인 경우 CFNN 모델의 격납용기 압력 예측	23
그림 11. 저온관에서 소형파단인 경우 CFNN 모델의 RMS 오차	25
그림 12. 저온관에서 소형파단인 경우 CFNN 모델의 최대 오차	26
그림 13. 저온관에서 소형파단인 경우 CFNN 모델의 격납용기 압력 예측	27

그림 14. 저온관에서 대형파단인 경우 CFNN 모델의 RMS 오차	29
그림 15. 저온관에서 대형파단인 경우 CFNN 모델의 최대 오차	30
그림 16. 저온관에서 대형파단인 경우 CFNN 모델의 격납용기 압력 예측	31
그림 17. 증기발생기 튜브에서 소형파단인 경우 CFNN 모델의 RMS 오차	33
그림 18. 증기발생기 튜브에서 소형파단인 경우 CFNN 모델의 최대 오차	34
그림 19. 증기발생기 튜브에서 소형파단인 경우 CFNN 모델의 격납용기 압력 예측	35
그림 20. 증기발생기 튜브에서 대형파단인 경우 CFNN 모델의 RMS 오차	37
그림 21. 증기발생기 튜브에서 대형파단인 경우 CFNN 모델의 최대 오차	36
그림 22. 증기발생기 튜브에서 대형파단인 경우 CFNN 모델의 격납용기 압력 예측	39

ABSTRACT

Prediction of the containment pressure under severe accidents using a cascaded fuzzy neural networks model

Geon Pil Choi

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

Department of Nuclear Engineering

Graduate School of Chosun University

Because of continuously increasing energy demands, many nuclear power plants(NPPs) are in operation globally. The NPPs in long-term operation may be slightly more vulnerable to accidents, such as loss-of-coolant accidents(LOCAs), because the pipes in these plants can be weak. The NPPs automatically operate emergency core cooling systems(ECCSs), such as safety injection system (SIS), when a LOCA occurs. If the SIS is not operating under the severe accident, the core uncover may occur. When the core uncover occurs under the accidents such as LOCAs, the containment is difficult to maintain a integrity by the direct heating or hydrogen combustion.

The containment surrounding nuclear steam supply system(NSSS) is one of the facilities that have an important role on nuclear safety in NPPs. The containment is the facility to prevent or minimize leakage of radioactive materials in normal operation or in severe accidents including LOCAs. Therefore, it is important to keep containment integrity. The purpose of this study is to keep the containment integrity by estimating the containment pressure in the event that the SIS is not operating under the severe accident.

The cascaded fuzzy neural networks(CFNN) model is used to predict containment pressure. The CFNN model consists of more than two FNN

modules, of which each stage corresponds with a single-stage FNN module. The FNN model is a combination of a fuzzy inference system(FIS) and neuronal training. The CFNN model is developed through the process of repeatedly adding FNN modules. The training of the CFNN model is accomplished by a hybrid method combined with a genetic algorithm and a least squares method.

The CFNN model based on artificial intelligence requires data for its development and verification. Because a variety of real LOCA accident data cannot be obtained from actual NPP accidents, the data used herein were obtained by numerically simulating severe accident scenarios of an optimized power reactor(OPR1000) using MAAP code.

To estimate the containment pressure using the CFNN model, the LOCA break size is used as input data. The LOCA break size cannot be measured, but it was known through previously developed methods. The LOCA break size can be predicted using the trend data for a short time after reactor trip.

It was confirmed that the containment pressure would be exactly predicted by the proposed CFNN model.

제 1 장 서론

세계적으로 에너지 수요가 급증함에 따라 많은 원자력발전소들이 가동되고 있다. 가동되고 있는 원자력발전소들 중 노후화 된 발전소는 배관이 약해지므로 파손, 단절 등으로 인해 냉각재상실사고(LOCA)와 같은 중대사고가 발생할 확률이 높다. 냉각재상실사고(LOCA)가 발생한 경우 노심의 온도가 올라가는 것을 방지하기 위하여 원자력발전소는 자동적으로 비상노심냉각장치(ECCS)와 같은 안전주입장치(SIS)가 작동한다. 그러나 소형냉각재상실사고(SBLOCA)의 경우 대형냉각재상실사고(LBLOCA)와는 달리 천천히 진행되므로 배관 내에 높은 압력이 유지되므로 비상노심냉각장치(ECCS)가 정상적으로 작동하지 못할 수도 있다.

1979년에 일어난 미국 스리마일 섬 원자력발전소 사고의 경우에는 비상노심냉각장치(ECCS)가 사고 발생 후에 작동되었으나, 운전원이 계량을 오판하여 잠시 비상냉각장치(ECCS)의 작동을 멈추는 등의 실수가 겹쳐 냉각불능에 의해 노심노출이 발생하였다. 노심노출이 발생되면 핵연료 피복재의 산화 반응에 의해 수소가 생성되고 고온의 용융 물질이 원자로용기 하부헤드에 남아있는 냉각수와 접촉할 때 원자로용기 내부 증기 폭발이 일어난다. 또한, 원자로 공동에서의 냉각수와 노심용융물과 접촉하면 원자로용기 외부 증기 폭발이 일어난다. 수소 연소만 일어났을 때에는 원자력발전소에 미치는 영향이 크지 않지만, 격납용기 직접 가열 현상이나 증기폭발과 함께 수소연소가 일어나면 격납용기 건전성을 유지하기 어렵다.

원자력발전소에서 주증기계통을 둘러싸고 있는 격납용기는 발전소 안전에 중요한 역할을 하는 시설중 하나이다. 다중 방벽의 4,5번째로서 격납용기는 정상운전 또는 냉각재상실사고(LOCA)를 포함하는 중대사고가 발생했을 때 방사성 물질의 누출 방지 및 최소화 목적을 가진 시설이다. 그러므로 격납용기의 압력을 증가시켜 기능에 해가 되는 주요 위해 요소인 온도와 수소농도를 측정하고 적시에 안전설비를 작동하여 격납용기의 건전성을 지키는 것이 중요하다.

본 연구에서는 중대사고가 발생하였을 때 원자력발전소 내부의 모든 계측설비가 작동하지 않는 상황을 가정하였고, 격납용기 압력 상승의 주 원인인 온도와 수소농도를 정확하게 계측할 수 없는 극한의 상황에서 격납용기 압력의 조기 계

측을 통하여 격납용기의 건전성을 효율적으로 유지하는 것이 본 연구의 목적이다.

격납용기 압력을 예측하기 위하여 인공 지능 기법인 CFNN(Cascaded Fuzzy Neural Networks) 모델을 사용하였다. 인공지능 기법은 원자력산업 내에서 신호 검증[1-3], 발전소 진단[4-7], 스마트 센싱[8-10]과 같이 성공적으로 적용되어졌다. CFNN 모델은 FNN(Fuzzy Neural Networks) 모듈을 연속적으로 수행함으로써 격납용기 압력을 예측한다. 즉, CFNN은 FNN의 확장된 개념이다.

CFNN 모델은 격납용기 압력을 예측하기 위하여, 파단위치는 고온관(Hot-leg), 저온관(Cold-leg), 증기발생기 튜브 (SGT)로 구분하였고, 입력 값으로 냉각재상실사고(LOCA) 파단크기를 사용하였다. 냉각재상실사고(LOCA) 파단크기는 이전에 개발된 방법에 의해 중대사고시 원자로 정지 후 짧은 시간 동안 측정된 데이터를 사용하여 정확하게 예측할 수 있으므로[11,12], 격납용기 압력을 예측하기 위한 입력 데이터로서 사용할 수 있다.

CFNN 모델은 개발과 검증을 위한 데이터를 필요로 하는 데이터 기반의 방법이다. 실제 중대사고 데이터는 원자력발전소로부터 얻을 수 없기 때문에 연구를 위해 쓰인 데이터는 MAAP 코드를 사용하여 OPR1000의 중대사고 시나리오를 시뮬레이션 하여 얻어졌다[13].

제 2 장 Cascaded Fuzzy Neural Networks 모델

제 1 절 CFNN 방법론

CFNN 모델은 두 개 이상의 FNN 모듈로 구성된다. FNN 모델은 학습기능이 결합된 퍼지추론계통(FIS)이다. 퍼지추론계통(FIS)은 조건 및 결론부의 쌍으로 구성되며, *if/then*으로 묘사되는 조건부 규칙이 일반적으로 이용된다. 퍼지추론계통(FIS)의 입력변수는 실수 값을 갖는 변수이기 때문에 fuzzifier를 추가해야 한다. 퍼지추론계통(FIS)은 입력변수를 퍼지 집합으로 맵핑하며, 멤버십 함수는 0 과 1사이의 연속적인 값을 각각의 요소에 맵핑한다. 본 연구에서는 Mamdani-type FIS를 대신하여[14], defuzzifier 없이 실수 값을 출력하는 Takagi-sugeno-type FIS를 이용하였다[15]. 임의의 i -번째 규칙의 Takagi-sugeno-type FIS는 식 (1)과 같이 표현될 수 있다.

$$\text{If } s_1(t) \text{ is } A_{i1} \text{ AND } \dots \text{ AND } s_m(t) \text{ is } A_{im}, \text{ then } \tilde{y}_i = f_i(s_1(t), \dots, s_m(t)) \quad (1)$$

FNN 모델을 사용하는 대부분의 연구에서는 단일단계의 퍼지추론계통(FIS)을 제안해왔다. 단일단계의 퍼지추론계통(FIS)은 다양한 인간의 추론 메커니즘 중 가장 간단하다. 본 연구에서 사용한 삼단논법의 퍼지추론계통(FIS)은 이전 추론 단계의 결과 값이 현재 단계의 사실로 적용되어 높은 수준의 많은 데이터를 효과적으로 축적 시킨다[16]. 삼단논법의 기반인 CFNN 모델은 간단한 FNN 모델 보다 우수한 성능을 제공할 것이다. 식 (2)는 CFNN 모델의 Takagi sugeno-type FIS를 나타낸다.

$$\begin{aligned}
 & \text{Stage 1 } \left[\begin{array}{l} \text{If } s_1(t) \text{ is } A_{i1}^1(t) \text{ AND } \cdots s_m(t) \text{ is } A_{im}^1(t), \\ \text{then } \tilde{y}_i^1(t) = f_i^1(s_1(t) \cdots s_m(t)) \end{array} \right] \\
 & \text{Stage 2 } \left[\begin{array}{l} \text{If } s_1(t) \text{ is } A_{i1}^2(t) \text{ AND } \cdots s_m(t) \text{ is } A_{im}^2(t), \\ \text{AND } \tilde{y}^1(t) \text{ is } A_{i(m+1)}^2(t) \\ \text{then } \tilde{y}_i^2(t) = f_i^2(s_1(t), \cdots, s_m(t), \tilde{y}^1(t)) \end{array} \right] \\
 & \quad \vdots \\
 & \text{Stage } l \left[\begin{array}{l} \text{If } s_1(t) \text{ is } A_{i1}^l(t) \text{ AND } \cdots \text{ AND } s_m(t) \text{ is } A_{im}^l(t), \\ \text{AND } \tilde{y}^1(t) \text{ is } A_{i(m+1)}^l(t) \text{ AND } \cdots \text{ AND } \tilde{y}^{l-1}(t) \text{ is } A_{i(m+l-1)}^l(t), \\ \text{then } \tilde{y}_i^l(t) = f_i^l(s_1(t), \cdots, s_m(t), \tilde{y}^1(t), \cdots, \tilde{y}^{l-1}(t)) \end{array} \right] \quad (2) \\
 & \quad \frac{\text{Fact : } s_1(t) \text{ is } A_{i1}^1(t) \text{ AND } \cdots \text{ AND } s_m(t) \text{ is } A_{im}^1(t)}{\text{Consequent : } \tilde{y}_i^l(t) = f_i^l(s_1(t), \cdots, s_m(t), \tilde{y}^1(t), \cdots, \tilde{y}^{l-1}(t))}
 \end{aligned}$$

여기서

$s_j(t)$: 퍼지추론계통(FIS)의 입력변수 ($j = 1, 2, \dots, m$)

$A_{ij}^k(t)$: k -번째 단계에서 i -번째 퍼지 규칙, j -번째 입력 값의 퍼지 집합
 ($k = 1, 2, \dots, l$), ($i = 1, 2, \dots, n$)

$\tilde{y}_i^k(t)$: k -번째 단계에서 i -번째 퍼지 규칙의 출력

$\tilde{y}^k(t)$: CFNN 모델 출력 값

l : FNN 모듈의 수

m : 입력 데이터의 수

n : 퍼지 규칙 수

식 (3)의 퍼지 모델에서 T 개의 입/출력 학습용 데이터가 이용 가능하다면, 각 데이터의 관계를 재구성하여 데이터들이 효율적으로 입력하기 위해 정규화 되어져 있다고 가정한다.

$$C^T(t) = (\mathbf{s}^T(t), \tilde{y}(t)) \quad (3)$$

여기서

$$\mathbf{s}^T(t) = (s_1(t), s_2(t), \dots, s_m(t)), t = 1, 2, \dots, T$$

식 (4)는 1차 Takagi-sugeno-type 퍼지추론계통(FIS)이다. $f_i(\mathbf{s}(t))$ 는 입력변수들의 1차 다항식 형태로 표현되며, 각각의 퍼지 규칙의 출력은 다음과 같이 표현된다.

$$f_i(\mathbf{s}(t)) = \sum_{j=1}^m q_{ij} s_j(t) + o_i \quad (4)$$

여기서

q_{ij} : i -번째 퍼지 규칙과 j -번째 입력 값의 가중치

o_i : i -번째 퍼지 규칙의 바이어스

CFNN 모델의 구조는 FNN모듈이 연속적으로 연결되어 구성된다. 그러므로 첫 번째 FNN 모듈에 대해서만 자세하게 설명한다. 그림 1은 첫 번째 FNN 모듈의 계산방법을 설명한 것이다. 각각의 FNN 모듈 안에는 Input, Membership, Multiplication, Normalization, Weighting, 그리고 Output 레이어 총 6개로 구성된다.

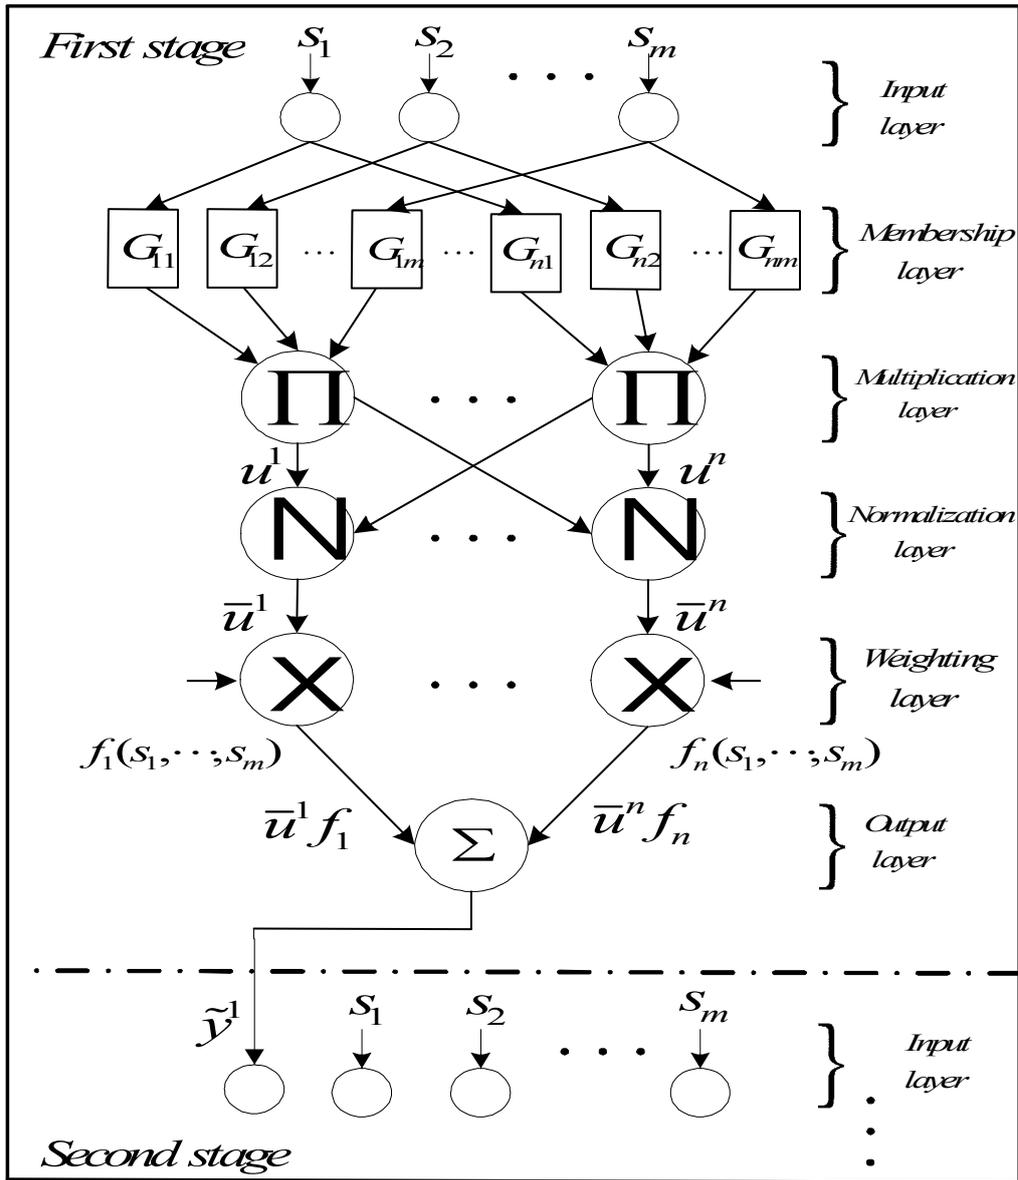


그림 1. FNN 모듈의 퍼지추론계통(FIS)

Input 레이어는 Membership 레이어로 전달하는 입력 노드로 구성된다. Input 레이어로부터 나온 각 출력 값들은 해당 멤버쉽 함수로 전달되어진다. Membership 레이어는 식 (5)에 주어진 가우시안 멤버쉽 함수를 이용하여 멤버쉽 값을 계산한다. 퍼지 집합 $A_{ij}(t)$ 의 멤버쉽 함수는 $G_{ij}(s_j(t))$ 를 의미한다. 최적화 된 매개변수들을 줄이기 위하여 대칭 가우시안 멤버쉽 함수를 사용하였다.

$$G_{ij}(s_j(t)) = e^{-\frac{(s_j(t) - x_{ij})^2}{2\sigma_{ij}^2}} \quad (5)$$

여기서

x_{ij} : peak의 중심점

σ_{ij} : bell shape의 폭

Multiplication 레이어는 식 (6)에 의하여 입력되는 모든 입력신호 값을 곱하는 기능을 수행한다. Normalization 레이어는 식 (7)에 의하여 정규화를 수행한다.

$$u^i(\mathbf{s}(t)) = \prod_{j=1}^m G_{ij}(s_j(t)) \quad (6)$$

$$u^i(t) = \frac{u^i(\mathbf{s}(t))}{\sum_{i=1}^n u^i(\mathbf{s}(t))} \quad (7)$$

Weighting 레이어는 정규화 된 가중치와 각 퍼지 규칙의 출력 값을 곱하는 기능을 수행한다. 마지막으로, Output 레이어는 Weighting 레이어에서 계산된 모든 값을 입력으로 받아 합산하는 기능을 수행한다. 출력 $\tilde{y}(t)$ 는 식 (8)과 같이 표현된다.

$$\tilde{y}(t) = \sum_{i=1}^n \bar{u}^i(t) y_i(t) = \sum_{i=1}^n \bar{u}^i(t) f_i(\mathbf{s}(t)) = \mathbf{u}^T(t) \mathbf{q} \quad (8)$$

여기서

$$\mathbf{u}(t) = [\bar{u}^1(t) s_1(t) \cdots \bar{u}^n(t) s_1(t) \cdots \bar{u}^1(t) s_m(t) \cdots \bar{u}^n(t) s_m(t) \bar{u}^1(t) \cdots \bar{u}^n(t)]^T$$

$$\mathbf{q} = [q_{11} \cdots q_{n1} \cdots q_{1m} \cdots q_{nm}]^T$$

벡터 \mathbf{q} 는 $(m+1) \times n$ 차원의 결론부 파라메타 벡터로 나타내고, 행렬 $\mathbf{u}(t)$ 는 입력데이터와 멤버쉽 함수 값으로 구성된다. 즉, 식 (8)에서 T 개의 입/출력 학습용 데이터의 예측된 출력 값은 식 (9)와 같이 표현된다.

$$\tilde{\mathbf{y}}_t = \mathbf{U}_t \mathbf{q} \quad (9)$$

여기서

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

$$\mathbf{U}_t = [\mathbf{u}(1) \mathbf{u}(2) \cdots \mathbf{u}(T)]^T$$

행렬 \mathbf{U}_t 는 $((m+1) \times n) \times T$ 의 차원을 가지고 있다. 두 번째 FNN 모듈은 초기 입력 데이터와 첫 번째 FNN 모듈의 출력 값을 입력데이터로서 사용한다. 이 과정은 출력 값이 최적화 될 때까지 i -번 반복하여 수행한다.

제 2 절 CFNN 모델 최적화

격납용기 압력을 예측하기 위해 개발된 CFNN 모델은 특정 훈련 데이터의 결합 방법으로 최적화시킨다. 입력 매개변수들은 유전자 알고리즘을 통하여 최적화된다. 결론부 매개변수들은 최소자승법에 의하여 최적화 된다 [17]. 유전자 알고리즘에서 각 개체는 최적화하고자 하는 매개변수 값들을 코딩하여 포함하며 이들 개체의 우수성을 정량화하기 위하여 적합도 함수가 필요하다. 즉, 오차와 외란의 영향을 최소화하는 목표를 포함하게 된다. 식 (10)에서는 유전자 알고리즘 안에서 적합도함수를 통해 최대 오차와 Root-Mean-Square(RMS) 오차를 최소화하는 것을 나타낸다.

$$F = \exp(-\lambda_1 E_1 - \lambda_2 E_2) \quad (10)$$

여기서

$$E_1 = \sqrt{\frac{1}{T} \sum_{t=1}^T (y(t) - \tilde{y}(t))^2}$$

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

λ_1 : RMS 오차의 가중치

λ_2 : 최대 오차의 가중치

T : 학습용 데이터의 수

$y(t)$: 목표 출력 값

$\tilde{y}(t)$: CFNN 모델의 예측 값

입력 매개변수들이 선택, 교배, 돌연변이와 같은 유전자 함수에 의해 결정되면, 결론부 매개변수들은 일차 결합하여 식 (9)와 같이 표현된다. 결론부 매개변수 \mathbf{q} 는 최소자승법에 의해 최적화되고 목표 값 ($y(t)$)과 예측 값 ($\tilde{y}(t)$)사이의 제곱 오차로 표시되는 목적함수를 최소화하도록 계산된다.

$$\begin{aligned}
 J &= \sum_{t=1}^T (y(t) - \tilde{y}(t))^2 = \sum_{t=1}^T (y(t) - \mathbf{u}^t(t)\mathbf{q})^2 \\
 &= \frac{1}{2} (\mathbf{y}_t - \tilde{\mathbf{y}}_t)^2
 \end{aligned}
 \tag{11}$$

여기서

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

식 (11)안에서 목적함수를 최소화하기 위한 해결은 다음 방정식처럼 계산된다.

$$\mathbf{y}_t = \mathbf{U}_t \mathbf{q}
 \tag{12}$$

여기서

$$\mathbf{U}_t = [\mathbf{u}(1) \ \mathbf{u}(2) \ \cdots \ \mathbf{u}(T)]^T$$

식 (12)의 \mathbf{q} 는 pseudo-inverse에 의해 계산된다.

$$\mathbf{q} = (\mathbf{U}_t^T \mathbf{U}_t)^{-1} \mathbf{U}_t^T \mathbf{y}_t
 \tag{13}$$

여기서, 행렬 \mathbf{U}_t 는 입력데이터와 멤버쉽 함수 값으로 구성되고, \mathbf{y}_t 는 출력데이터로 구성된다.

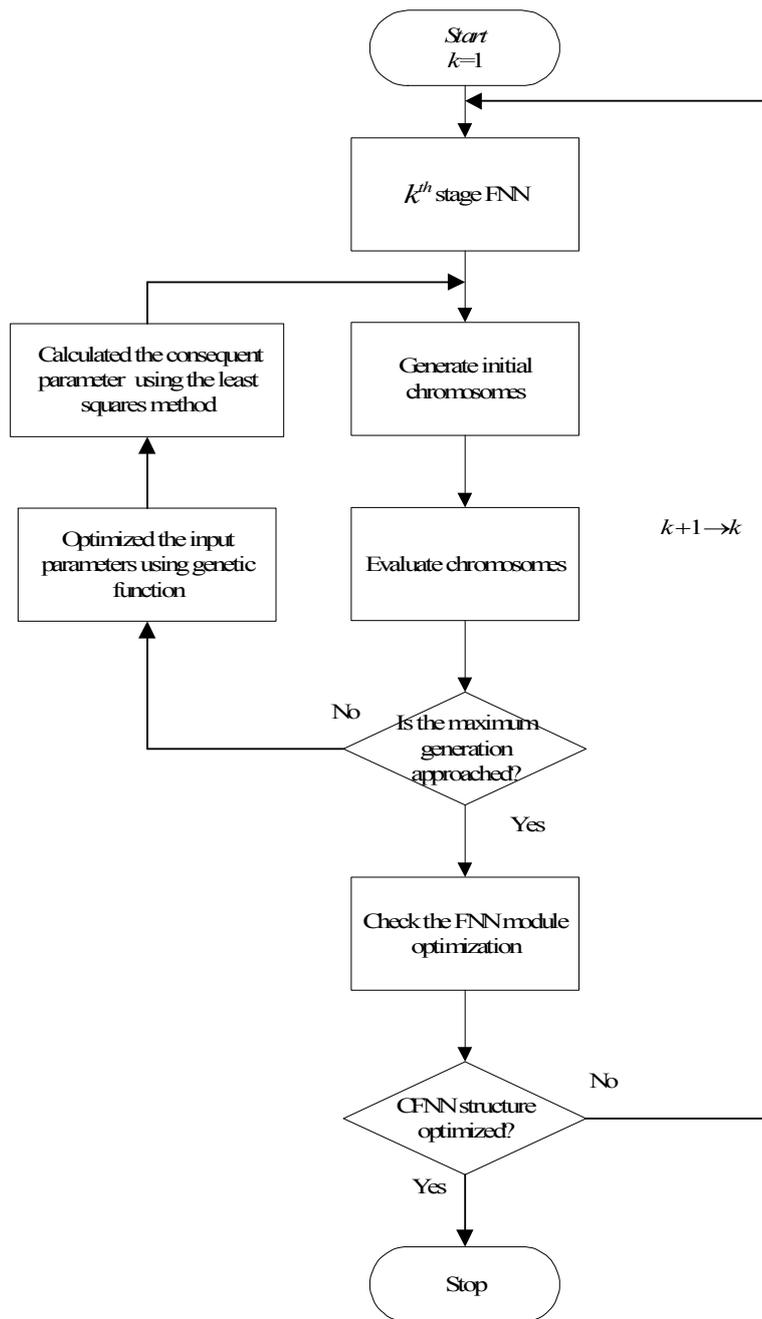


그림 2. CFNN 모델 최적화 과정

그림 2는 CFNN 모델의 최적화 과정을 나타낸다. 유전자 알고리즘의 처음 단계는 각 개체를 임의로 설정한다. 즉, 최적화할 매개변수를 구간 내에서 임의로 설정하여 각 개체내로 코딩하여 입력한다. 적합도 함수를 이용하여 각 개체의 우수성을 판단한다. 유전자 함수인 선택, 교배, 돌연변이를 통하여 입력 매개변수를 결정하게 된다. 결론부 매개변수들은 입력 매개변수와 1차 결합으로 이루어지며 최소자승법에 의해 결정된다. FNN 모듈이 최적화가 되면 CFNN 모델이 최적화되었는지 확인한 후에 최적화가 되지 않았으면, 다음 FNN 모듈을 수행하게 된다. 이 과정을 모델이 최적화가 될 때까지 반복하여 수행한다.

CFNN 모델의 복잡도(Complexity)는 q 의 요소의 수에 비례한다. 그러므로 복잡도(Complexity)는 CFNN 모델에서 모든 FNN 모듈의 q 의 요소의 수에 따라 정의되어진다. 식 (14)는 복잡도(Complexity)를 구하는 식이다.

$$Complexity = \frac{l(l+2m+1)n}{2} \quad (14)$$

여기서

l : FNN 모듈의 수

m : 입력데이터의 수

n : 퍼지 규칙 수

CFNN의 복잡도(complexity)는 퍼지 규칙 수(n)에 따라서 선형적으로 증가하고 FNN 모듈의 수(l)에 따라 증가한다. 모듈 수에 비례하는 복잡도(complexity)는 식 (13)에서의 pseudo-inverse와 관련된 잠재적인 ill-posed 문제를 예방하기 위해 학습데이터의 수보다 작아야한다.

CFNN 모델은 overfitting의 문제가 발생할 수 있다. Overfitting 문제가 발생할 때, 수행 중이던 FNN 모듈이 멈추게 된다. Overfitting 문제는 그림 4에서의 데이터의 구조를 사용해 cross-checking을 통하여 해결할 수 있다[17]. Overfitting의 문제가 k 단계에서 일어났는지 확인하기 위해서 식 (15)와 같은 검증데이터

(verification data)의 오차의 합을 이용한다.

$$F(k) = \sum_{t=T+1}^V (y(t) - \tilde{y}^k(t))^2 \quad (15)$$

그림 3은 CFNN 모델의 모듈 수 증가에 따른 $F(k)$ 의 경향을 나타낸다.

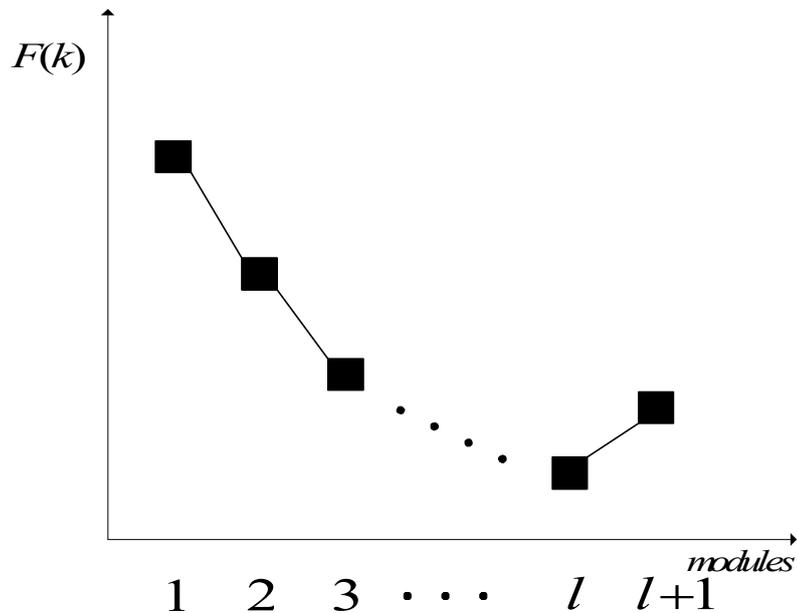


그림 3. CFNN 모델의 모듈 수 증가에 따른 $F(k)$ 의 경향

그림 3과 같이 $F(k+1) > F(k)$ 면, CFNN 모델의 학습과 검증과정을 멈추게 된다. 이때, FNN 모듈이 연속적으로 수행되고 있다면, CFNN 모델은 overfitting 문제가 발생한다. 반대의 경우 FNN 모듈은 다음 모듈로 연속해서 수행한다.

제 3 장 격납용기 압력 예측

제 1 절 CFNN 모델에 사용한 데이터

CFNN 모델을 사용하여 격납용기 압력을 예측하기 위해서 중대사고의 시뮬레이션 데이터가 필요하기 때문에, OPR1000의 냉각재상실사고(LOCA) 시나리오를 사용하였다[13].

본 연구를 위해 MAAP 코드를 사용한 시뮬레이션은 중대사고시 안전주입계통(SIS)이 정상적으로 작동하지 않는 상황에서 수행되어졌다. 그러므로 냉각재상실사고(LOCA)의 파단 위치와 크기는 알 수 없다. 하지만 파단크기는 격납용기 압력에 영향을 줄 것으로 예상되므로, 파단위치와 크기는 규명되고 예측해야 한다. 이전 연구[11-12]에서 냉각재상실사고(LOCA)의 파단위치는 정확하게 규명되었고, 파단크기는 0.4% 이내의 RMS 오차가 발생하므로 정확하게 예측이 가능하였다. 중대사고시 원자력발전소 내의 계측기들은 정상적으로 작동하지 않으므로 신뢰하기 어렵다. 이전 연구에서 중대사고시 냉각재상실사고(LOCA)의 파단크기는 정확하게 예측이 가능하므로, 격납용기 압력을 예측하기 위한 입력데이터로 사용하였다.

본 연구에서 파단위치는 고온관(Hot-leg), 저온관(Cold-leg), 증기발생기 튜브(SGTR)로 구분하였다. 고온관과 저온관의 파단크기는 최소 절단크기의 1/400부터 최대 절단크기의 1/2까지, 증기발생기 튜브 파단의 크기는 11부터 210까지 범위로 설정하였다. 600개의 시뮬레이션 데이터는 고온관, 저온관, 증기발생기 튜브에서 각각 200개의 시뮬레이션 데이터로 구성되었다. 고온관과 저온관은 200개의 데이터를 소형 파단크기 데이터를 30개, 대형 파단크기 데이터를 170개, 증기발생기 튜브는 소형, 대형 파단크기를 각각 100개의 데이터로 구분하였다.

output	inputs					
$y(1)$	$s_1(1)$	$s_2(1)$...	$s_m(1)$	}	training data set
$y(2)$	$s_1(2)$	$s_2(2)$...	$s_m(2)$		
\vdots	\vdots	\vdots	\vdots	\vdots		
$y(T)$	$s_1(T)$	$s_2(T)$...	$s_m(T)$	}	development data set
$y(T+1)$	$s_1(T+1)$	$s_2(T+1)$...	$s_m(T+1)$		
$y(T+2)$	$s_1(T+2)$	$s_2(T+2)$...	$s_m(T+2)$		
\vdots	\vdots	\vdots	\vdots	\vdots	}	verification data set
$y(T+V)$	$s_1(T+V)$	$s_2(T+V)$...	$s_m(T+V)$		
$y(T+V+1)$	$s_1(T+V+1)$	$s_2(T+V+1)$...	$s_m(T+V+1)$		
$y(T+V+2)$	$s_1(T+V+2)$	$s_2(T+V+2)$...	$s_m(T+V+2)$	}	test data set
\vdots	\vdots	\vdots	\vdots	\vdots		
$y(N)$	$s_1(N)$	$s_2(N)$...	$s_m(N)$		

그림 4. 데이터의 구조

그림 4는 CFNN 모델을 개발하기 위하여 사용한 데이터의 구조이다. T 는 학습 데이터(training data)의 수, V 는 검증데이터(verification data)의 수, N 은 전체 데이터의 수이다. 시험데이터(test data)는 각 200개의 데이터로 구성된 파단위치에서 고정된 간격의 데이터를 선택한다. 학습데이터(training data)는 시험데이터를 제외한 나머지 데이터에서 고정된 간격을 가지고 선택된다. 시험데이터(test data)와 학습데이터(training data)를 제외한 데이터는 검증데이터(verification data)이다. CFNN 모델을 형성하기 위해 개발데이터(development data)를 사용하였고, 모델을 검증하기 위하여 시험데이터(test data)를 사용한다. CFNN 모델은 개발데이터(development data)를 사용하여 유전자 알고리즘과 최소자승법에 의해 최적화되고, 제안된 모델의 매개변수를 결정하기 위하여 학습데이터(training data)를 사용한다. 유전자 알고리즘과 관련된 매개변수 값들의 개체군은 20군이고, 교배 가능성은 100%, 돌연변이 가능성은 5%이다.

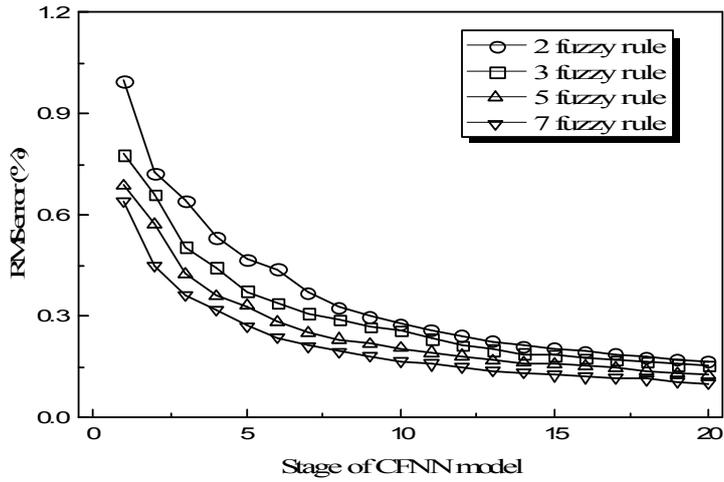
제 2 절 실험결과

표 1은 고온관에서 소형과단인 경우 CFNN 모델의 수행결과이다. 퍼지 규칙 수는 2,3,5,7을 사용한다. 최소 RMS 오차 값은 개발데이터(development data) 0.1%, 시험데이터(test data) 0.13%이다. RMS 오차가 퍼지 규칙 수에 따라 모두 다르지만 0.2% 이하이다.

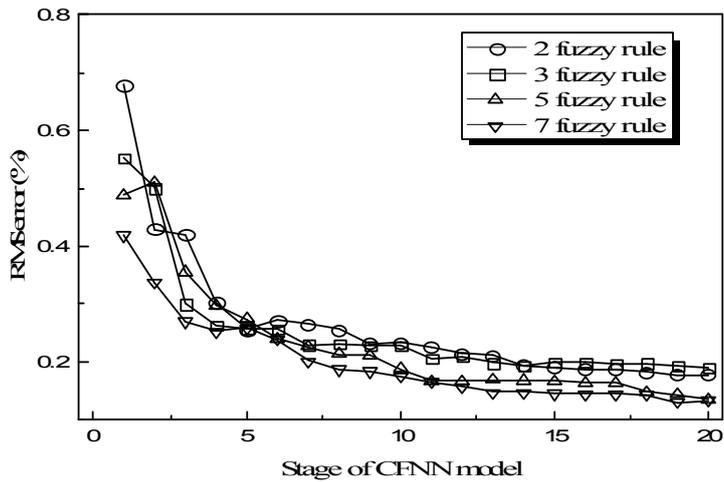
그림 5는 고온관에서 소형과단인 경우 CFNN 모델의 RMS 오차 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. FNN 모듈은 모두 20번째까지 수행되고, 각각의 퍼지 규칙에서의 RMS 오차 값은 모듈 수가 증가함에 따라 작아진다. 그림 6은 고온관에서 소형과단인 경우 CFNN 모델의 최대 오차 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. 그림 7은 CFNN 모델을 통해 예측된 값(predicted value)과 MAAP 코드를 시뮬레이션 하여 얻은 목표 값(target value)에 대한 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. CFNN 모델을 통하여 예측된 값(predicted value)이 개발데이터(development data)와 시험데이터(test data) 모두 정확하게 예측된 것을 볼 수 있다. 그러므로 CFNN 모델은 고온관에서 소형과단인 경우 격납용기 압력을 정확하게 예측할 수 있다.

표 1. 고온관에서 소형과단인 경우 CFNN 모델의 수행결과

No. of fuzzy rules	No. of FNN modules	CFNN 모델의 complexity	Development data		Test data	
			RMS 오차 (%)	최대 오차 (%)	RMS 오차 (%)	최대 오차 (%)
2	20	500	0.17	1.10	0.18	0.84
3	20	750	0.15	0.96	0.19	0.10
5	20	1250	0.13	0.83	0.13	0.82
7	20	1750	0.10	0.73	0.13	0.73

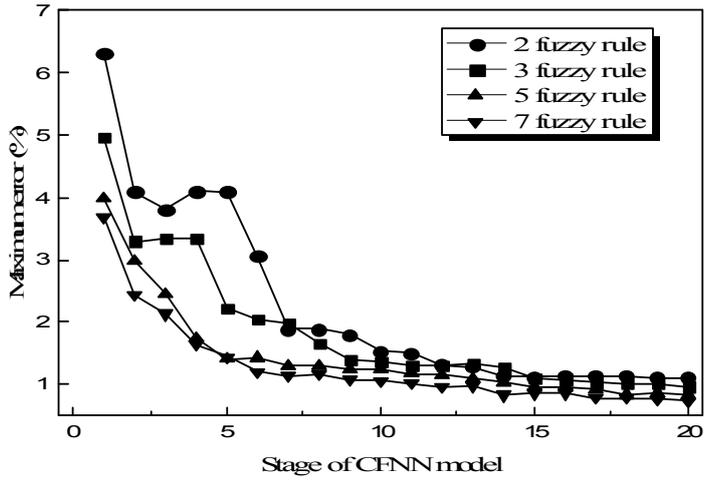


(a) 개발데이터(development data)의 RMS 오차

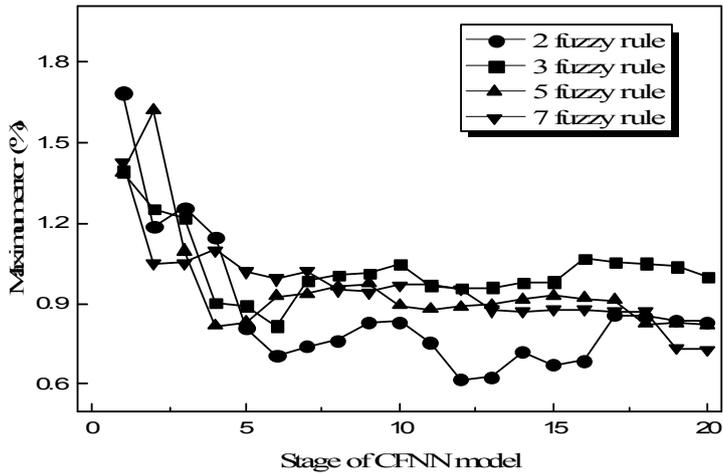


(b) 시험데이터(test data)의 RMS 오차

그림 5. 고온관에서 소형파단인 경우 CFNN 모델의 RMS 오차

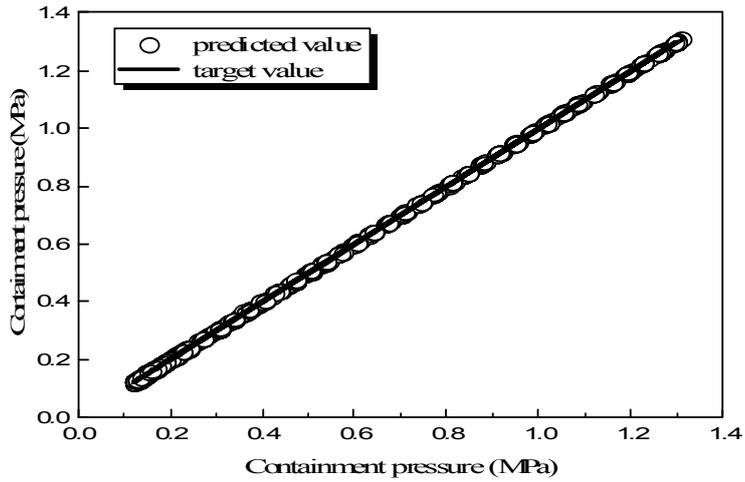


(a) 개발데이터(development data)의 최대 오차

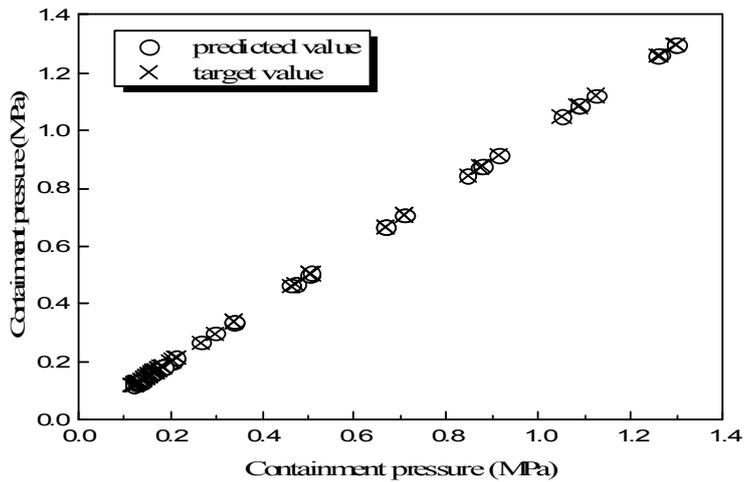


(b) 시험데이터(test data)의 최대 오차

그림 6 고온관에서 소형파단인 경우 CFNN 모델의 최대 오차



(a) 개발데이터(development data)의 격납용기 압력 예측



(b) 시험데이터(test data)의 격납용기 압력 예측

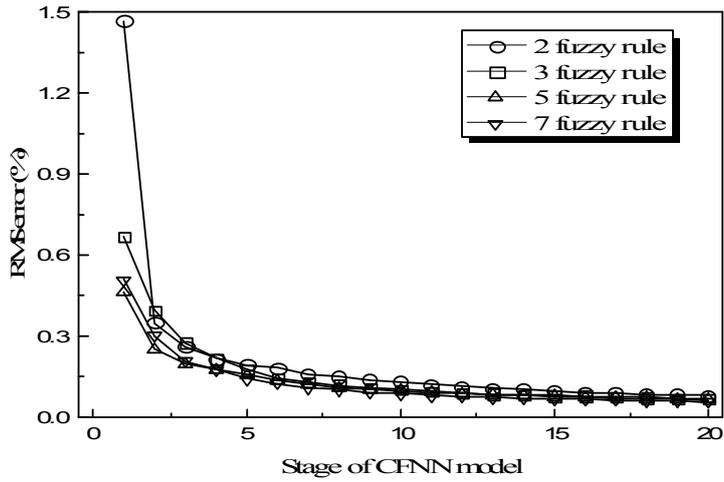
그림 7. 고온관에서 소형과단인 경우 CFNN 모델의 격납용기 압력 예측

표 2는 고온관에서 대형과단인 경우 CFNN 모델의 수행결과이다. 퍼지 규칙 수는 2,3,5,7을 사용한다. 최소 RMS 오차 값은 개발데이터(development data) 0.06%, 시험데이터(test data) 0.06%이다. RMS 오차가 퍼지 규칙 수에 따라 모두 다르지만 0.09% 이하이다.

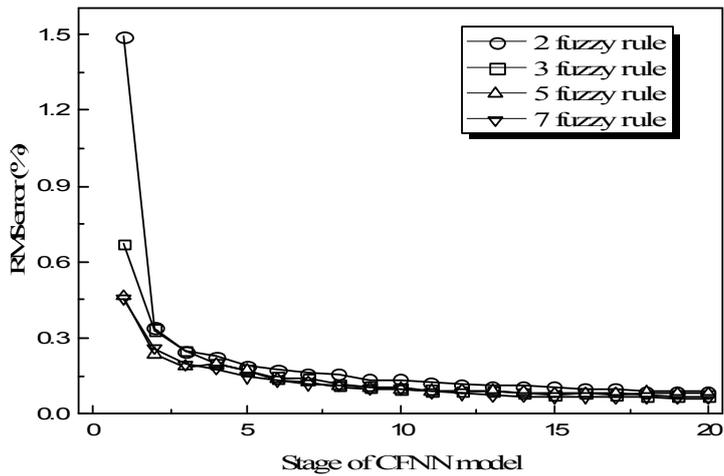
그림 8은 고온관에서 대형과단인 경우 CFNN 모델의 RMS 오차 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. FNN 모듈은 모두 20번째까지 수행되고, 각각의 퍼지 규칙 수에서의 RMS 오차 값은 모듈 수가 증가함에 따라 작아진다. 그림 9는 고온관에서 대형과단인 경우 CFNN 모델의 최대 오차 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. 그림 10은 CFNN 모델을 통해 예측된 값(predicted value)과 MAAP 코드를 시뮬레이션 하여 얻은 목표 값(target value)에 대한 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. CFNN 모델을 통하여 예측된 값(predicted value)이 개발데이터(development data)와 시험데이터(test data) 모두 정확하게 예측된 것을 볼 수 있다. 그러므로 CFNN 모델은 고온관에서 대형과단인 경우 격납용기 압력을 정확하게 예측할 수 있다.

표 2. 고온관에서 대형과단인 경우 CFNN 모델의 수행결과

No. of fuzzy rules	No. of FNN modules	CFNN 모델의 complexity	Development data		Test data	
			RMS 오차 (%)	최대 오차 (%)	RMS 오차 (%)	최대 오차 (%)
2	20	500	0.08	0.80	0.09	0.58
3	20	750	0.07	0.81	0.07	0.57
5	20	1250	0.07	0.74	0.08	0.67
7	20	1750	0.06	0.82	0.06	0.52

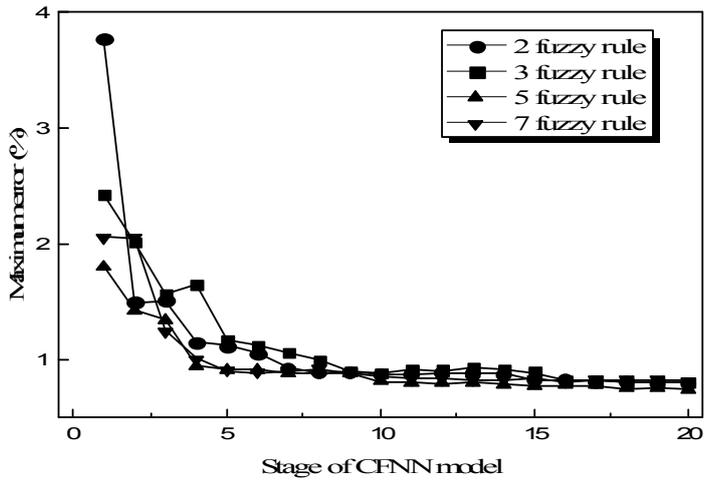


(a) 개발데이터(development data)의 RMS 오차

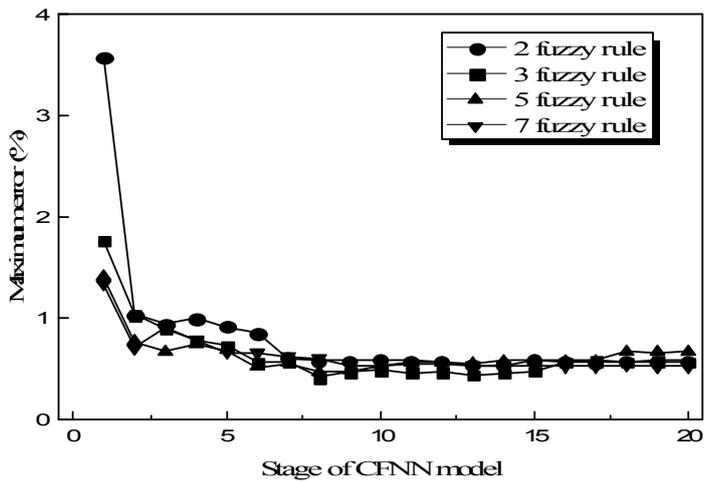


(b) 시험데이터(test data)의 RMS 오차

그림 8. 고온관에서 대형파단인 경우 CFNN 모델의 RMS 오차

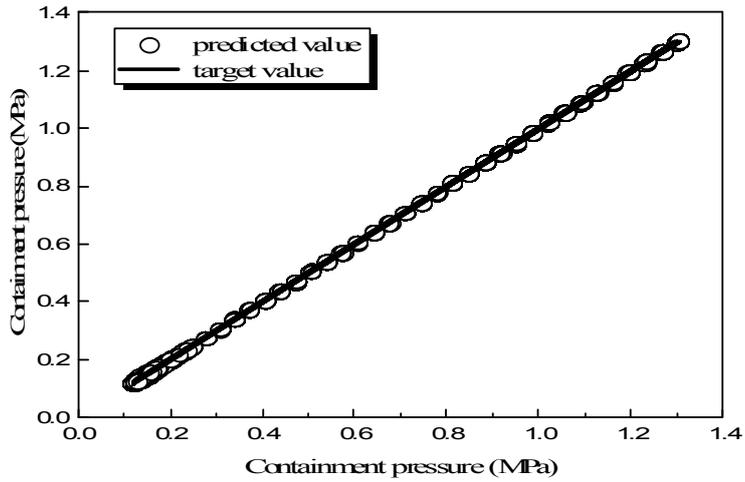


(a) 개발데이터(development data)의 최대 오차

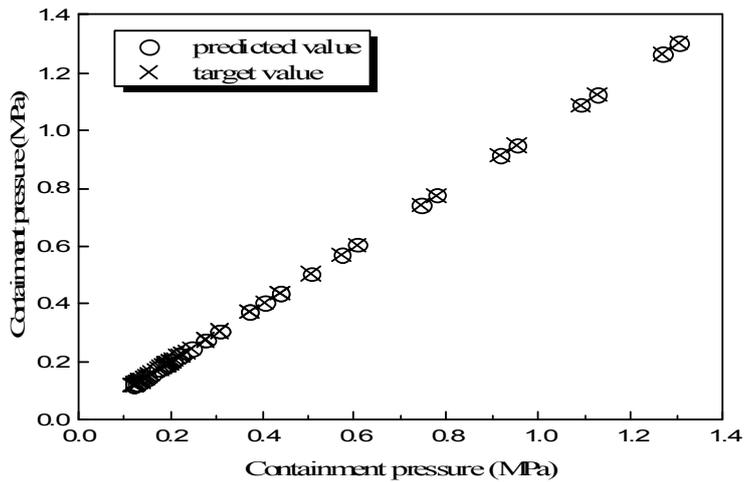


(b) 시험데이터(test data)의 최대 오차

그림 9. 고운관에서 대형파단인 경우 CFNN 모델의 최대 오차



(a) 개발데이터(development data)의 격납용기 압력 예측



(b) 시험데이터(test data)의 격납용기 압력 예측

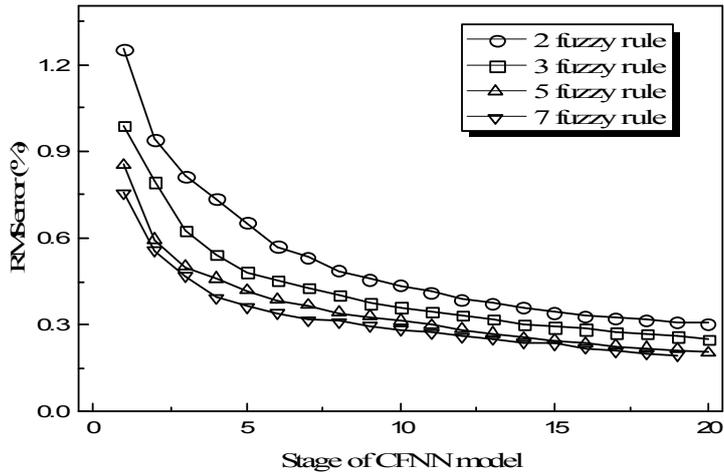
그림 10. 고온관에서 대형과단인 경우 CFNN 모델의 격납용기 압력 예측

표 3은 저온관에서 소형과단인 경우 CFNN 모델의 수행결과이다. 퍼지 규칙 수는 2,3,5,7을 사용한다. 최소 RMS 오차 값은 개발데이터(development data) 0.19%, 시험데이터(test data) 0.24%이다. RMS 오차가 퍼지 규칙 수에 따라 모두 다르지만 0.34% 이하이다.

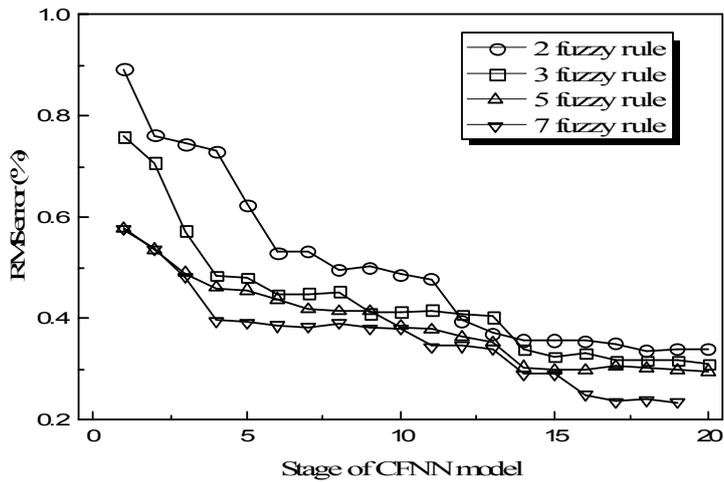
그림 11은 저온관에서 소형과단인 경우 CFNN 모델의 RMS 오차 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. FNN 모듈은 퍼지 규칙 수 2,3,5는 20번째, 7은 19번째까지 수행되고, RMS 오차 값은 모듈 수가 증가함에 따라 작아진다. 그림 12는 저온관에서 소형과단인 경우 CFNN 모델의 최대 오차 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. 그림 13은 CFNN 모델을 통해 예측된 값(predicted value)과 MAAP 코드를 시뮬레이션 하여 얻은 목표 값(target value)에 대한 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. CFNN 모델을 통하여 예측된 값(predicted value)이 개발데이터(development data)와 시험데이터(test data) 모두 정확하게 예측된 것을 볼 수 있다. 그러므로 CFNN 모델은 저온관에서 소형과단인 경우 격납용기 압력을 정확하게 예측할 수 있다.

표 3. 저온관에서 소형과단인 경우 CFNN 모델의 수행결과

No. of fuzzy rules	No. of FNN modules	CFNN 모델의 complexity	Development data		Test data	
			RMS 오차 (%)	최대 오차 (%)	RMS 오차 (%)	최대 오차 (%)
2	20	500	0.31	1.82	0.34	1.10
3	20	750	0.25	1.40	0.31	1.28
5	20	1250	0.21	1.12	0.30	0.97
7	19	1596	0.19	1.65	0.24	0.77

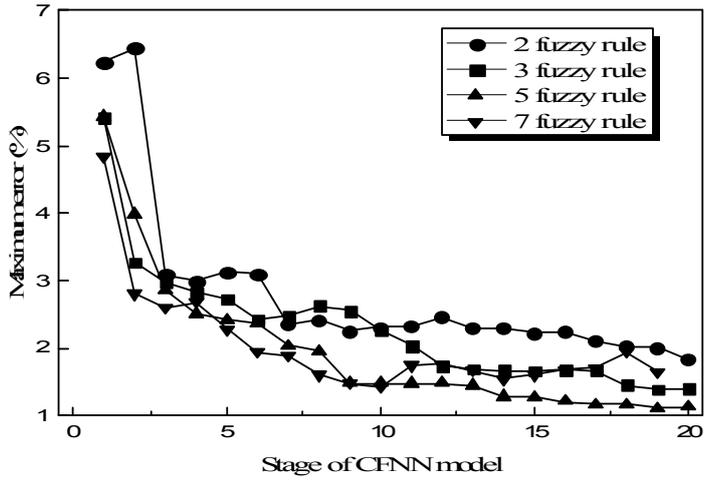


(a) 개발데이터(development data)의 RMS 오차

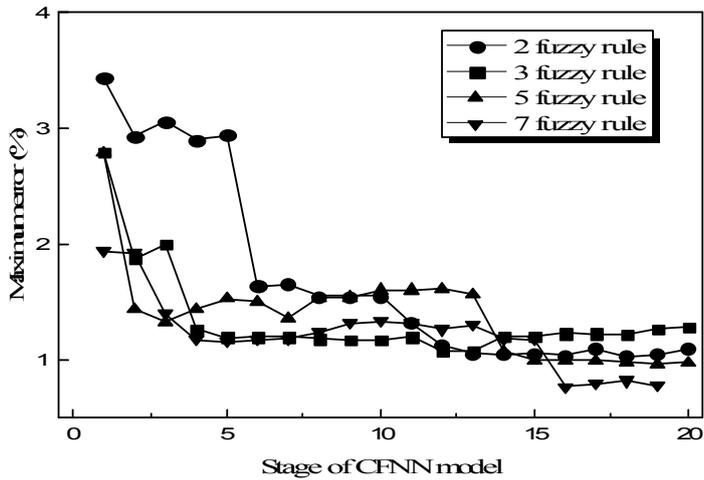


(b) 시험데이터(test data)의 RMS 오차

그림 11. 저온관에서 소형파단인 경우 CFNN 모델의 RMS 오차

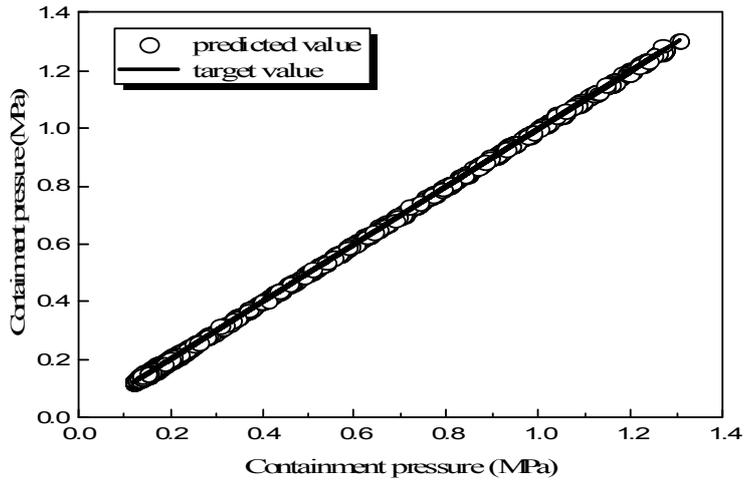


(a) 개발데이터(development data)의 최대 오차

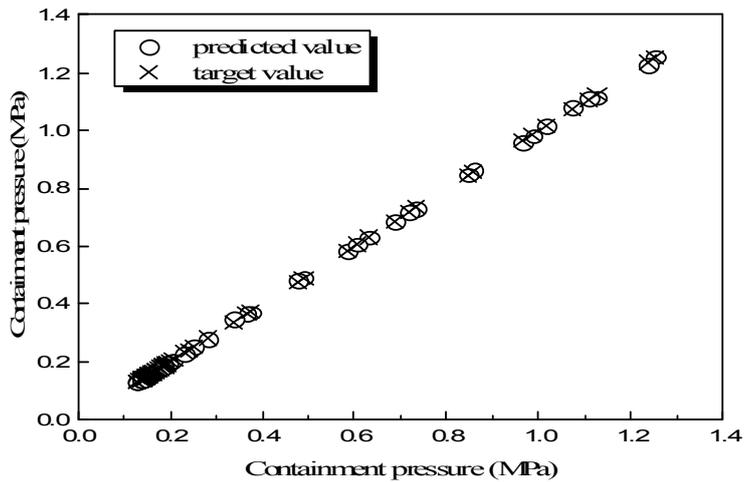


(b) 시험데이터(development data)의 최대 오차

그림 12. 저온판에서 소형파단인 경우 CFNN 모델의 최대 오차



(a) 개발데이터(development data)의 격납용기 압력 예측



(b) 시험데이터(test data)의 격납용기 압력 예측

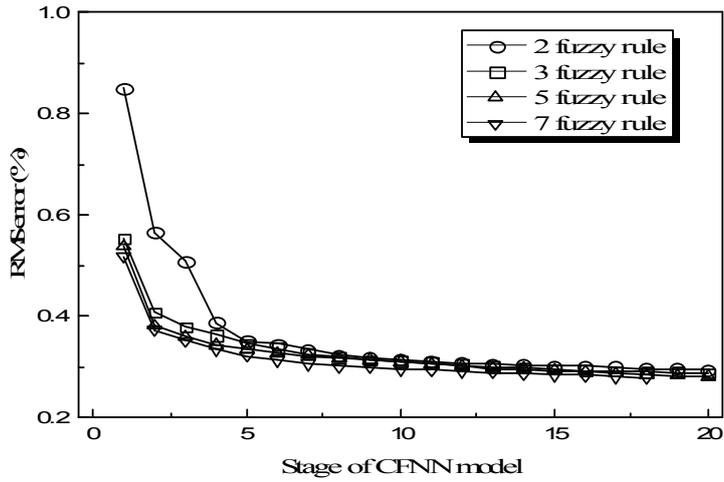
그림 13. 저온관에서 소형과단인 경우 CFNN 모델의 격납용기 압력 예측

표 4는 저온관에서 대형과단인 경우 CFNN 모델의 수행결과이다. 퍼지 규칙 수는 2,3,5,7을 사용한다. 최소 RMS 오차 값은 개발데이터(development data) 0.28%, 시험데이터(test data) 0.26%이다. RMS 오차가 퍼지 규칙 수에 따라 모두 다르지만 0.29% 이하이다.

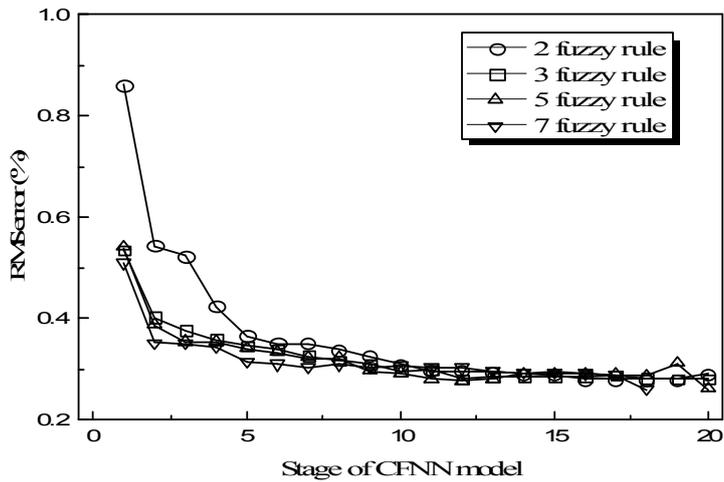
그림 14는 저온관에서 대형과단인 경우 CFNN 모델의 RMS 오차 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. FNN 모듈은 퍼지 규칙 수 2,3,5에서는 20번째, 7에서는 18번째까지 수행되고, RMS 오차 값은 모듈 수가 증가함에 따라 작아진다. 그림 15는 저온관에서 대형과단인 경우 CFNN 모델의 최대 오차 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. 그림 16은 CFNN 모델을 통해 예측된 값(predicted value)과 MAAP 코드를 시뮬레이션 하여 얻은 목표 값(target value)에 대한 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. CFNN 모델을 통하여 예측된 값(predicted value)이 개발데이터(development data)와 시험데이터(test data) 모두 정확하게 예측된 것을 볼 수 있다. 그러므로 CFNN 모델은 저온관에서 대형과단인 경우 격납용기 압력을 정확하게 예측할 수 있다.

표 4. 저온관에서 대형과단인 경우 CFNN 모델의 수행결과

No. of fuzzy rules	No. of FNN modules	CFNN 모델의 complexity	Development data		Test data	
			RMS 오차 (%)	최대 오차 (%)	RMS 오차 (%)	최대 오차 (%)
2	20	500	0.29	1.74	0.29	1.09
3	20	750	0.29	1.94	0.28	1.15
5	20	1250	0.28	1.92	0.26	0.89
7	18	1449	0.28	2.00	0.26	0.83

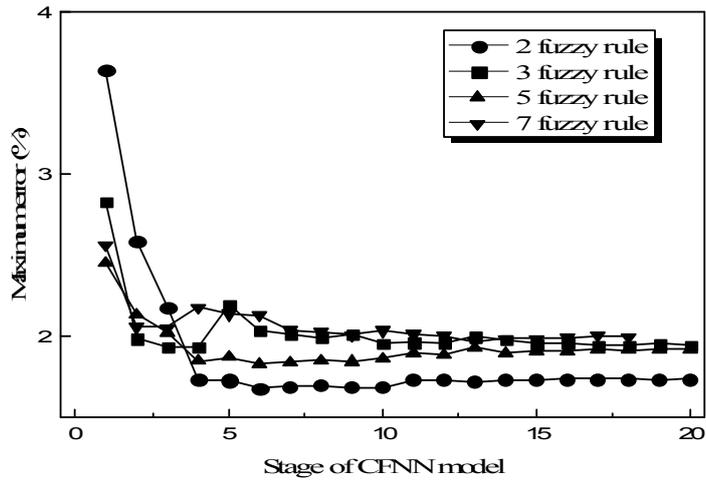


(a) 개발데이터(development data)의 RMS 오차

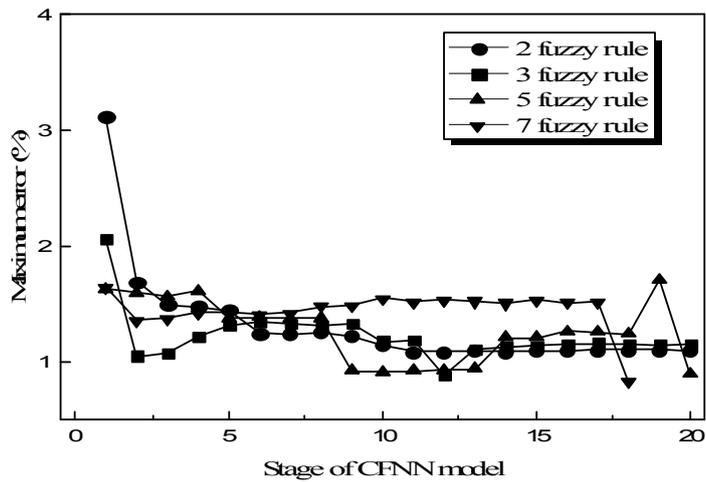


(b) 시험데이터(test data)의 RMS 오차

그림 14. 저온관에서 대형과단인 경우 CFNN 모델의 RMS 오차

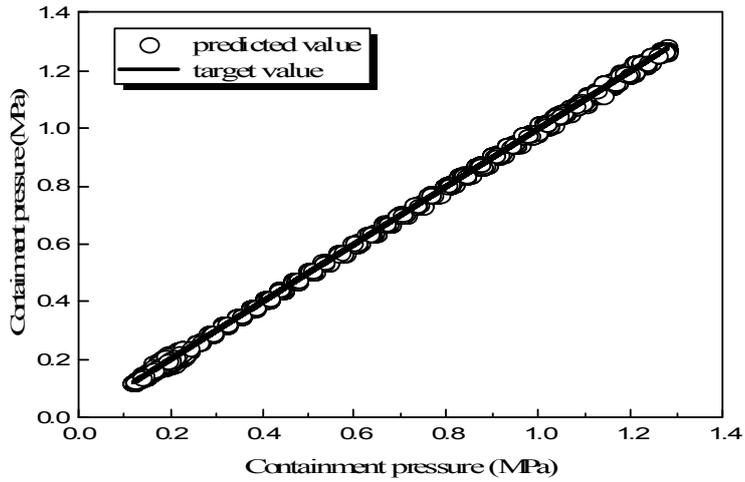


(a) 개발데이터(development data)의 최대 오차

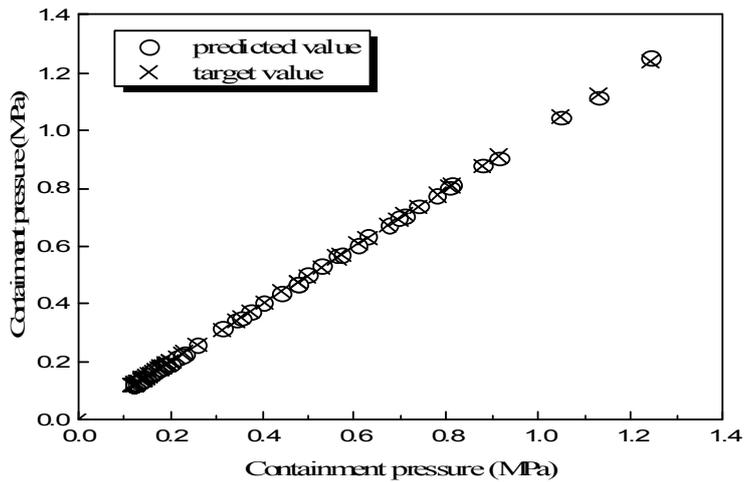


(b) 시험데이터(test data)의 최대 오차

그림 15. 저온판에서 대형과단인 경우 CFNN 모델의 최대 오차



(a) 개발데이터(development data)의 격납용기 압력 예측



(b) 시험데이터(test data)의 격납용기 압력 예측

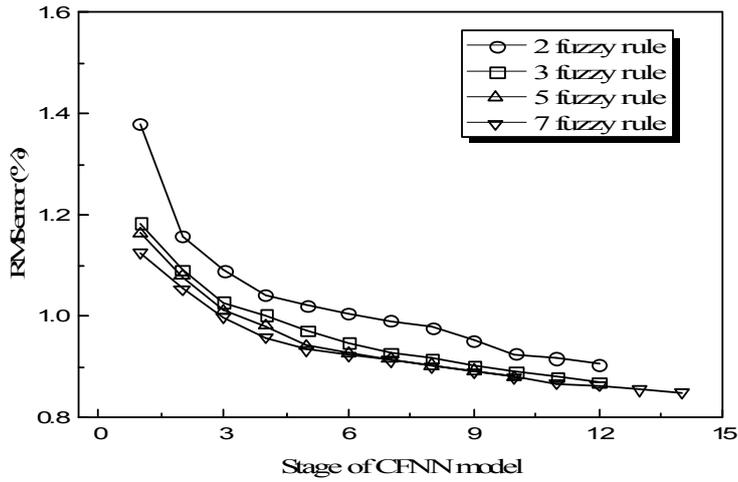
그림 16. 저온관에서 대형과단인 경우 CFNN 모델의 격납용기 압력 예측

표 5는 증기발생기 튜브에서 소형과단인 경우 CFNN 모델의 수행결과이다. 퍼지 규칙 수는 2,3,5,7을 사용한다. 최소 RMS 오차 값은 개발데이터(development data) 0.85%, 시험데이터(test data) 0.94%이다. RMS 오차가 퍼지 규칙 수에 따라 모두 다르지만 1.01% 이하이다.

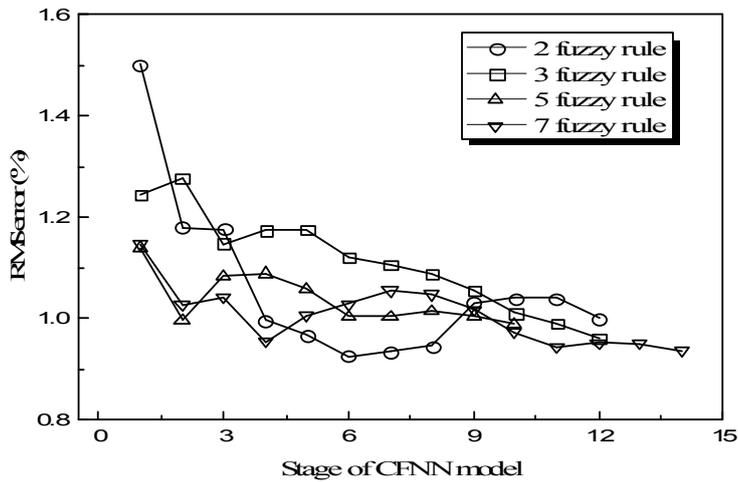
그림 17은 증기발생기 튜브에서 소형과단인 경우 CFNN 모델의 RMS 오차 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. FNN 모듈은 퍼지 규칙 수 2,3에서는 12번째, 5에서는 10번째, 7에서는 14번째까지 수행되고, RMS 오차 값은 모듈 수가 증가함에 따라 작아진다. 그림 18은 증기발생기 튜브에서 소형과단인 경우 CFNN 모델의 최대 오차 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. 그림 19는 CFNN 모델을 통해 예측된 값(predicted value)과 MAAP 코드를 시뮬레이션 하여 얻은 목표 값(target value)에 대한 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. CFNN 모델을 통하여 예측된 값(predicted value)이 개발데이터(development data)와 시험데이터(test data) 모두 정확하게 예측된 것을 볼 수 있다. 그러므로 CFNN 모델은 증기발생기 튜브에서 소형과단인 경우 격납용기 압력을 정확하게 예측할 수 있다.

표 5. 증기발생기 튜브에서 소형과단인 경우 CFNN 모델의 수행결과

No. of fuzzy rules	No. of FNN modules	CFNN 모델의 complexity	Development data		Test data	
			RMS 오차 (%)	최대 오차 (%)	RMS 오차 (%)	최대 오차 (%)
2	12	204	0.91	7.40	1.01	5.08
3	12	306	0.87	6.83	0.96	5.77
5	10	375	0.88	6.92	0.99	5.56
7	14	937	0.85	7.21	0.94	4.64

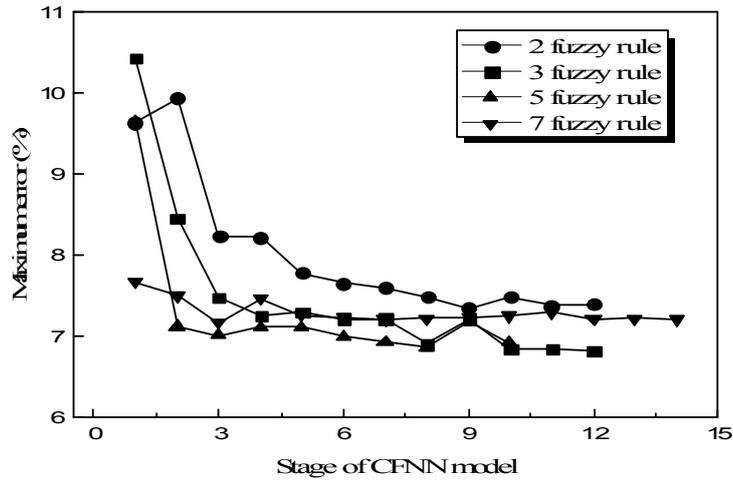


(a) 개발데이터(development data)의 RMS 오차

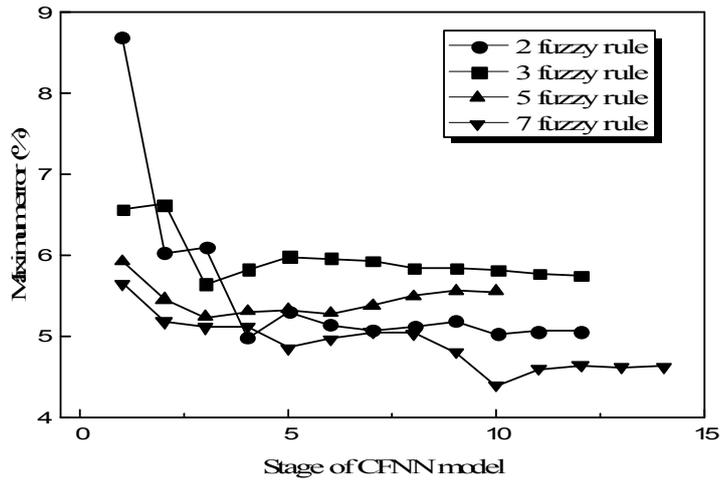


(b) 시험데이터(test data)의 RMS 오차

그림 17. 증기발생기 튜브에서 소형파단인 경우 CFNN 모델의 RMS 오차

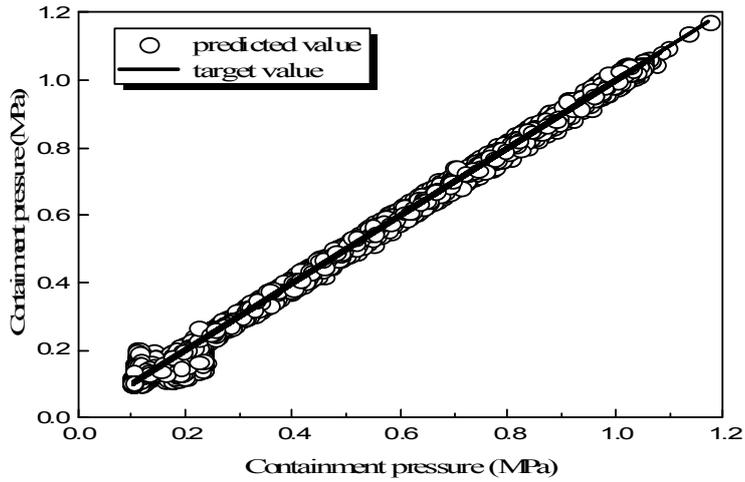


(a) 개발데이터(development data)의 최대 오차

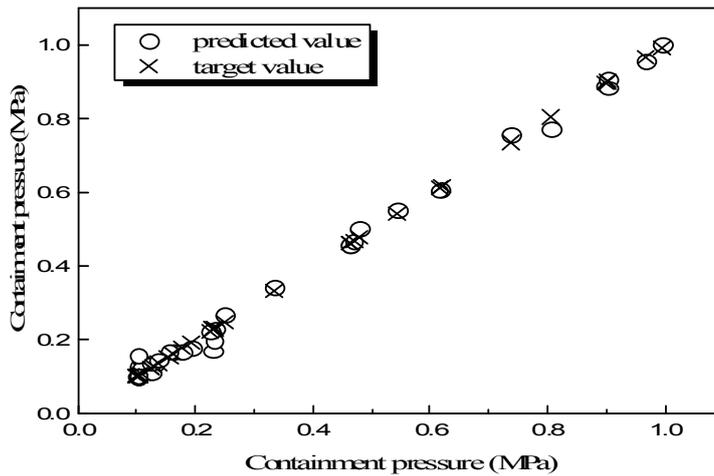


(b) 시험데이터(test data)의 최대 오차

그림 18. 증기발생기 튜브에서 소형과단인 경우 CFNN 모델의 최대 오차



(a) 개발데이터(development data)의 격납용기 압력 예측



(b) 시험데이터(test data)의 격납용기 압력 예측

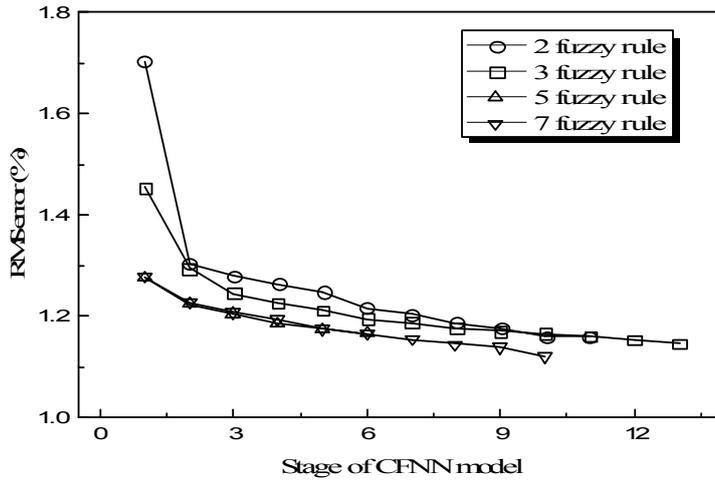
그림 19. 증기발생기 튜브에서 소형파단인 경우 CFNN 모델의 격납용기 압력 예측

표 6은 증기발생기 튜브에서 대형과단인 경우 CFNN 모델의 수행결과이다. 퍼지 규칙 수는 2,3,5,7을 사용한다. 최소 RMS 오차 값은 개발데이터(development data) 1.13%, 시험데이터(test data) 1.27%이다. RMS 오차가 퍼지 규칙 수에 따라 모두 다르지만 1.41% 이하이다.

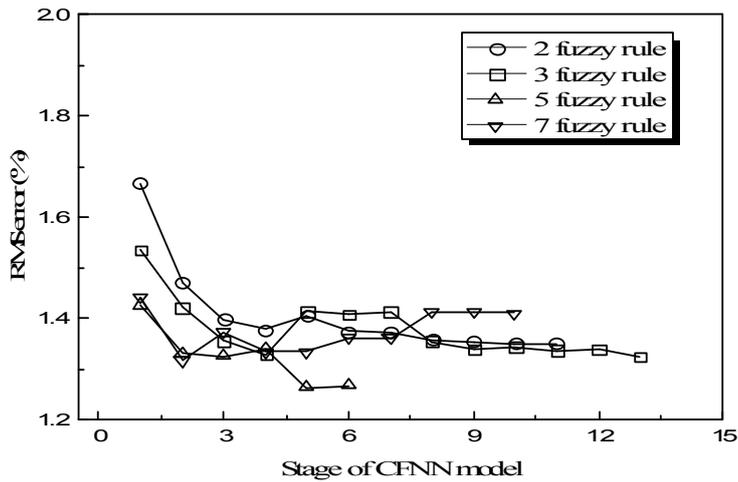
그림 20은 증기발생기 튜브에서 대형과단인 경우 CFNN 모델의 RMS 오차 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. FNN 모듈은 퍼지 규칙 수 2, 3, 5, 7은 11, 13, 6, 10번째까지 수행되고, RMS 오차 값은 모듈 수가 증가함에 따라 작아진다. 그림 21은 증기발생기 튜브에서 대형과단인 경우 CFNN 모델의 최대 오차 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. 그림 22는 CFNN 모델을 통해 예측된 값(predicted value)과 MAAP 코드를 시뮬레이션 하여 얻은 목표 값(target value)에 대한 그래프이다. (a)는 개발데이터(development data), (b)는 시험데이터(test data)의 그래프이다. CFNN 모델을 통하여 예측된 값(predicted value)이 개발데이터(development data)와 시험데이터(test data) 모두 정확하게 예측된 것을 볼 수 있다. 그러므로 CFNN 모델은 증기발생기 튜브에서 대형과단인 경우 격납용기 압력을 정확하게 예측할 수 있다.

표 6. 증기발생기 튜브에서 대형과단인 경우 CFNN 모델의 수행결과

No. of fuzzy rules	No. of FNN modules	CFNN 모델의 complexity	Development data		Test data	
			RMS 오차 (%)	최대 오차 (%)	RMS 오차 (%)	최대 오차 (%)
2	11	176	1.16	6.89	1.35	6.55
3	13	351	1.15	6.69	1.33	7.04
5	6	165	1.17	6.78	1.27	6.22
7	10	525	1.13	6.93	1.41	7.22

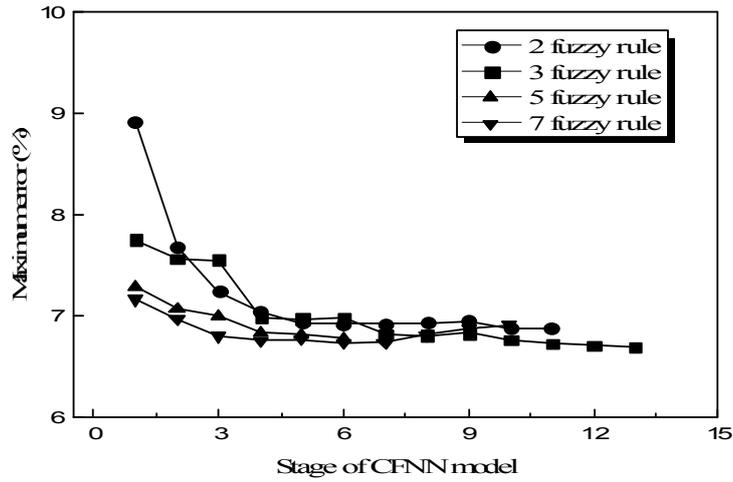


(a) 개발데이터(development data)의 RMS 오차

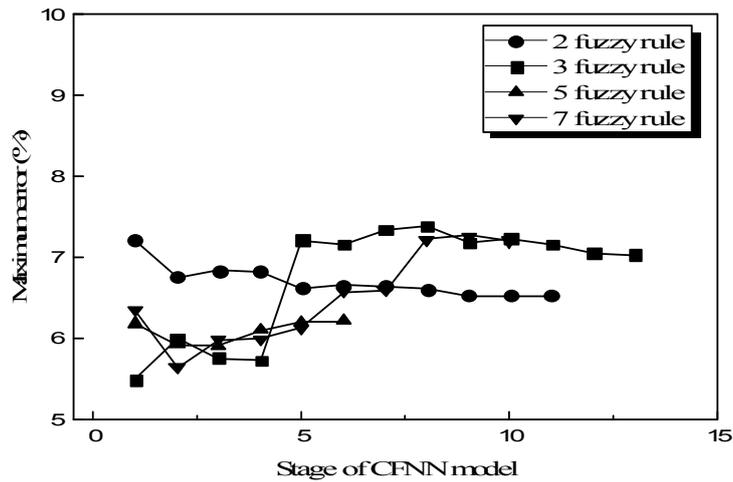


(b) 시험데이터(test data)의 RMS 오차

그림 20. 증기발생기 튜브에서 대형파단인 경우 CFNN 모델의 RMS 오차

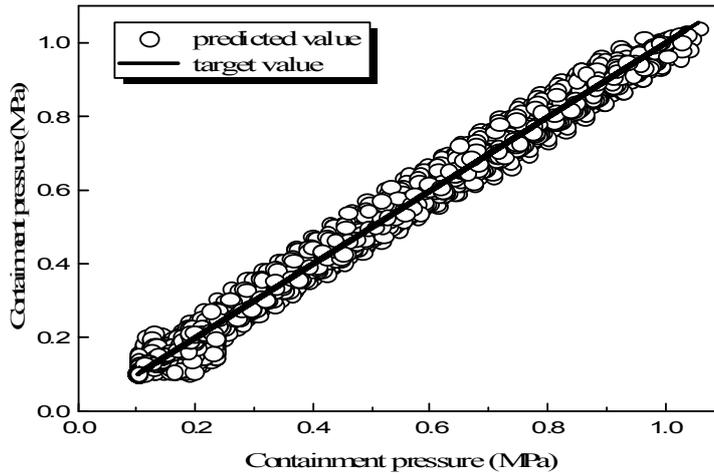


(a) 개발데이터(development data)의 최대 오차

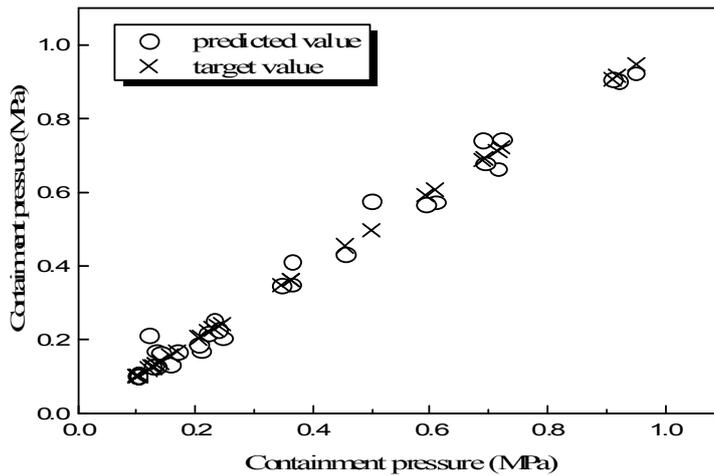


(b) 시험데이터(test data)의 최대 오차

그림 21. 증기발생기 튜브에서 대형과단인 경우 CFNN 모델의 최대 오차



(a) 개발데이터(development data)의 격납용기 압력 예측



(b) 시험데이터(test data)의 격납용기 압력 예측

그림 22. 증기발생기 튜브에서 대형파단인 경우 CFNN 모델의 격납용기 압력 예측

제 4 장 결론

원자력발전소에서 주증기계통을 둘러싸고 있는 격납용기는 발전소 안전에 중요한 역할을 하는 시설중 하나이다. 격납용기는 냉각재상실사고(LOCA)와 같은 중대사고가 발생하였을 때 방사성 물질의 누출 방지 및 최소화의 목적을 가진 시설이다. 그러므로 격납용기의 건전성을 유지하는 것은 중요하다.

본 연구에서는 CFNN 모델을 사용하여 냉각재상실사고(LOCA)시 안전주입계통이 작동하지 않는 상황에서 격납용기 압력을 예측하였다. 연구에 사용된 데이터는 MAAP 코드를 사용하여 OPR1000의 중대사고 시나리오를 시뮬레이션 하여 얻어졌다. CFNN 모델의 수행결과, RMS 오차는 고온관에서 소형과단인 경우 0.19%, 대형과단인 경우 0.09% 이하로 예측되었다. 저온관에서 소형과단인 경우 0.34%, 대형과단인 경우 0.3% 이하로 예측되었다. 증기발생기 튜브에서는 소형과단인 경우 1.0%, 대형과단인 경우 1.4% 이하로 예측되었다. RMS 오차가 과단의 위치에 따라 다르지만 1.4% 이하로 예측되었다.

또한, MAAP 코드를 통하여 얻어진 목표 값과 CFNN 모델을 통해 예측된 값의 그래프를 보았을 때, 고온관, 저온관, 증기발생기에서 모두 정확하게 예측하는 것을 볼 수 있다.

결과적으로, 원자력발전소에 냉각재상실사고(LOCA)시 안전주입계통이 작동하지 않는 상황에서 CFNN 모델은 격납용기 압력을 매우 정확하게 예측할 수 있다.

원자력발전소 운전원들이 중대사고시 CFNN 모델을 통해 격납용기 압력을 미리 예측한다면, 효율적인 사고 대응을 통하여 격납용기의 건전성을 유지할 수 있을 것입니다.

【참고문헌】

- [1] J. Garvey, D. Garvey, R. Seibert, J.W. Hines, Validation of on-line monitoring techniques to nuclear plant data, Nucl. Eng. Technol. 39 (2007) 149-158.
- [2] J.W. Hines, D.J. Wrest, R.E. Uhrig, Signal validation using an adaptive neural fuzzy inference system, Nucl. Technol. 119 (1997) 181-193.
- [3] M.G. Na, A neuro-fuzzy inference system for sensor failure detection using wavelet denoising, PCA and SPR, J. Korean Nucl. Soc. 33 (2001) 483-497.
- [4] E.B. Bartlett, R.E. Uhrig, Nuclear power plant diagnostics using an artificial neural network, Nucl. Technol. 97 (1992) 272-281.
- [5] A. Gofuku, H. Yoshikawa, S. Hayashi, K. Shimizu, J. Wakabayashi, Diagnostic techniques of a small-break loss-of-coolant accident at a pressurized water reactor plant, Nucl. Technol. 81 (1988) 313-332.
- [6] M. Marseguerra, E. Zio, Fault diagnosis via neural networks: The Boltzmann machine, Nucl. Sci. Eng. 117 (1994) 194-200.
- [7] Y.G. No, J.H. Kim, D.H. Lim, K.I. Ahn, Monitoring severe accidents using AI techniques, Nucl. Eng. Technol. 44 (2012) 393-404.
- [8] M.G. Na, H.Y. Yang, D.H. Lim, A soft-sensing model for feedwater flow rate using fuzzy support vector regression, Nucl. Eng. Technol. 40 (2008) 69-76.
- [9] S.H. Park, D.S. Kim, J.H. Kim, M.G. Na, Prediction of the reactor vessel water level using fuzzy neural networks in severe accident circumstances of NPPs, Nucl. Eng. Technol. 46 (2014) 373-380.
- [10] S.H. Park, J.H. Kim, K.H. Yoo, M.G. Na, Smart sensing of the RPV water level in NPP severe accidents using a GMDH algorithm. IEEE Trans, Nucl. Sci. 61 (2014) 931-938.

- [11] M.G. Na, S.H. Shin, D.W. Jung, S.P. Kim, J.H. Jeong, B.C. Lee, Estimation of break location and size for loss of coolant accidents using neural networks, Nucl. Eng. Des. 232 (2004) 289-300.
- [12] M.G. Na, W.S. Park, D.H. Lim, Detection and diagnostics of loss of coolant accidents using support vector machines, IEEE Trans. Nucl. Sci. 55 (2008) 628-636.
- [13] MAAP4 Modular Accident Analysis Program for LWR Power Plants User's Manual, prepared by Fauske & Associates, LLC for EPRI, Project RP3131-02, May 1994-June 2005.
- [14] E.H. Mamdani, S. Assilian, An experiment in linguistic synthesis with a fuzzy logic controller, Int. J. Man-Machine Studies 7 (1975) 1-13.
- [15] 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.
- [16] J.C. Duan, F.L. Chung, Cascaded fuzzy neural network model based on syllogistic fuzzy reasoning, IEEE Trans. Fuzzy Systems 9 (2001) 293-306.
- [17] 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.