



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](#)

2024년 2월  
석사학위 논문

딥러닝을 이용한 원자로냉각재계통  
소량 누설 정량화 연구

조선대학교 대학원

원자력공학과

이상현

딥러닝을 이용한 원자로냉각재계통  
소량 누설 정량화 연구

Study on Quantifying Small RCS Leaks Using Deep  
Learning

2024년 2월 23일

조선대학교 대학원

원자력공학과

이상현

딥러닝을 이용한 원자로냉각재계통  
소량 누설 정량화 연구

지도교수 나 만 균

이 논문을 공학 석사학위신청 논문으로 제출함

2023년 10월

조선대학교 대학원

원자력공학과

이 상 현

# 이상현의 석사학위논문을 인준함

위원장 김종현 (인)

위원 김진원 (인)

위원 나만균 (인)

2023년 12월

조선대학교 대학원

# 목차

표 목차 .....	ii
그림 목차 .....	iii
ABSTRACT .....	iv
제 1 장 서론 .....	1
제 2 장 누설탐지 방법 .....	4
제 1 절 음향누설감시계통 .....	4
제 2 절 불활성 방사성 기체를 이용한 누설탐지 .....	5
제 3 절 한국원자력연구원 개발 누설탐지 시스템 .....	6
제 3 장 인공지능 방법론 .....	7
제 1 절 LSTM .....	7
제 2 절 Bi-LSTM .....	8
제 3 절 GRU .....	9
제 4 절 Grid search .....	11
제 4 장 데이터 처리 .....	13
제 1 절 데이터 취득 .....	13
제 2 절 데이터 전처리 .....	20
제 5 장 초기 상대 습도 예측 결과 .....	22
제 6 장 결론 .....	35
참고문헌 .....	37

## 표 목차

표 1. 입력 데이터 조합 .....	18
표 2. 하이퍼파라미터 최적화 선정 변수 .....	23
표 3. LSTM의 Grid search 적용 예측 결과 .....	24
표 4. Bi-LSTM의 Grid search 적용 예측 결과 .....	25
표 5. GRU의 Grid search 적용 예측 결과 .....	26

## 그림 목차

그림 1. 음향누설감시계통의 측정 구조 .....	5
그림 2. LSTM의 구조 .....	8
그림 3. Bi-LSTM의 구조 .....	9
그림 4. GRU의 구조 .....	11
그림 5. Grid search 구조 .....	12
그림 6. CUPID 시뮬레이션 튜브 단면도 .....	14
그림 7. CUPID 시뮬레이션 튜브 구조 .....	15
그림 8. 특정 데이터 포인트에서 취득한 건도 데이터 결과 .....	17
그림 9. 특정 데이터 포인트에서 취득한 수증기압 데이터 결과 .....	17
그림 10. 특정 데이터 포인트에서 취득한 온도 데이터 결과 .....	17
그림 11. 특정 케이스에서의 상대 습도 분포 .....	19
그림 12. 모든 케이스에서의 상대 습도 분포 .....	19
그림 13. 예측모델 개발 절차 .....	21
그림 14. LSTM의 배치 사이즈에 따른 MAE .....	27
그림 15. Bi-LSTM의 배치 사이즈에 따른 MAE .....	27
그림 16. GRU의 배치 사이즈에 따른 MAE .....	28
그림 17. LSTM의 레이어 깊이에 따른 MAE .....	29
그림 18. Bi-LSTM의 레이어 깊이에 따른 MAE .....	29
그림 19. GRU의 레이어 깊이에 따른 MAE .....	30
그림 20. LSTM의 상위 하이퍼파라미터 조합 초기 상대 습도 예측 결과 .....	31
그림 21. Bi-LSTM의 상위 하이퍼파라미터 조합 초기 상대 습도 예측 결과 .....	32
그림 22. GRU의 상위 하이퍼파라미터 조합 초기 상대 습도 예측 결과 .....	32
그림 23. LSTM의 하위 하이퍼파라미터 조합 초기 상대 습도 예측 결과 .....	33
그림 24. Bi-LSTM의 하위 하이퍼파라미터 조합 초기 상대 습도 예측 결과 .....	33
그림 25. GRU의 하위 하이퍼파라미터 조합 초기 상대 습도 예측 결과 .....	34



# ABSTRACT

## Study on Quantifying Small RCS Leaks Using Deep Learning

Sang Hyun Lee

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

Department of Nuclear Engineering,

Graduate School of Chosun University

In nuclear power plants reactor coolant leakage can occur due to a variety of factors. Coolant leakages can lead to casualties and economic losses. To prevent this, early detection of leakages is crucial to ensuring the safety of nuclear power plants. Currently, a detection system is being developed in Korea Atomic Energy Research Institute to identify reactor coolant system (RCS) leakages of less than 0.5 gpm. Typically, RCS leakage is detected by monitoring the temperature, humidity, radiation, and sump water level in the containment. However, detecting small leakages proves difficult because the resulting changes in containment humidity and temperature and sump water level are small. To address these issues and enhance the speed of leak detection, it is necessary to quantify the leakages and develop an artificial intelligence-based leakage detection system. In this study, temperature, relative humidity of the measured area, and distance were used as input variables among the variables obtained using the CUPID code. And, long short-term memory, bidirectional long short-term memory, and gated recurrent unit, were employed to predict the relative humidity in the leakage area for leakage quantification. Additionally, an optimization technique was implemented to reduce

the learning time and improve the prediction performance. Through evaluation of the developed artificial intelligence model's prediction accuracy, the initial relative humidity of the leakage area was accurately predicted. And the amount of leakage was quantified, which is expected to be used in a future leakage detection system to detect small-scale coolant leakage by applying artificial intelligence even in the event of instrument failure or sensor failure. In addition, it is expected to secure time margin for operators to take actions and contribute to reducing secondary human errors.

# 제 1 장 서 론

원자력 발전소는 수많은 배관과 밸브로 구성되어 있으며, 원자로냉각재계통(RCS; Reactor Coolant System) 배관, 밸브 및 용접 부품의 열화, 장비 진동 및 피로 손상으로 인해 누설이 발생할 수 있다. 누설 사고가 발생하면 운전원은 적절한 절차에 따라 원자력 발전소를 안전한 상태로 유지하며 정지시킨다. 그러나 사고상황을 인지하지 못하거나 잘못된 조치를 취하면 누설 사고로 이어질 수 있다. 누설 사고는 방사능 누출과 직결되기 때문에 이를 예방하는 것은 발전소의 안전을 위해 매우 중요하다. 원자력 안전운영정보시스템[1]에 따르면 2017년부터 2022년까지 기계적 결함으로 인한 사고는 총 12건이 발생했다. 사례 중 하나로 2017년에는 고리원전 4호기 밸브 용접부의 진동 피로에 의한 균열로 인한 원자로 냉각재 누설이 확인되어 원자로가 정지되는 사고가 발생하였다[1, 2]. 이러한 사고가 악화된다면 인명 피해뿐만 아니라 막대한 경제적 손실을 초래할 수 있기 때문에 누설의 조기 탐지는 필수적이다.

현재 누설을 감지하는 방법은 공기 중 입자 방사능, 기체 방사능, 원자로 격납건물의 압력이나 대기 습도 및 온도, 냉각기로부터의 응축수 유량으로 탐지를 진행한다. 또한, 1차측의 특정 기기 또는 위치에서 누설을 모니터링하는 감지 계통인 음향 누설 계통이 있다. 음향 누설 감지 계통은 신호가 감지된 후 전치 증폭기를 통해 주제어실의 경보기에 전달되고, 신호 값이 설정치를 넘으면 경보를 발생하는 방식이다. 그리고, 베타 방사선 감지 시스템은 불활성 방사성 기체를 이용하여 누설을 감지한다[3]. 또한, 경수로형 원전의 누설 감지 계통에 대한 성능 기준은 규제지침(KINS/RG-N06.01)에 명시되어 있으며, 모든 누설 감지 계통은 1시간 이내에 1gpm의 누설을 감지할 수 있어야 한다고 규정하고 있다. 그러나 위의 언급된 방법은 소규모 누설 감지에 적합하지 않다는 단점이 존재한다.

최근 원자력 분야에서 인공지능을 활용한 연구가 활발하게 진행되고 있다. Park 등[4]은 과도현상의 초기 단계를 감지하여 운전원의 제어가 없는 경우 원자로 트립까지 남은 시간에 대한 예측 정보를 운전원에게 개발하는 연구를 Principal Component Analysis 기법을 통해 연구하였다. 그리고, Koo 등[5]은 이상 상태 완화를 위해 사고 감시 변수 중 하나인 원자로 용기 수위를 예측하여 운전원이 이상 상태를 효과적으로 완화할 수 있는 보조 정보를 제공하는 연구를 진행하였다. Park 등[6]은 임계열유속을

입력변수로 하는 SPACE 코드를 활용하여 외벽 온도를 예측하는 기계학습 모델을 개발하였다. 기존의 SPACE 코드가 계산 횟수가 많아 계산 시간이 오래 걸린다는 단점을 머신러닝 기법을 이용하여 극복하였다. 연구를 통해 계산 시간을 약 86%의 시간을 단축하였으며, 우수한 예측 성능까지 보이는 연구를 진행하였다. Jo 등[7]은 냉각재 상실사고(LOCA; Loss of Coolant Accident)시 안전주입계통 운전이 복구될 수 있는 잔여 시간인 Golden time을 예측하는 것을 목표로 연구를 진행하였다. Kim 등[8]은 원자력 발전소 사고상황에서 운전원의 상황 인식의 중요성을 인식하고 원자력 발전소의 불확실성 정보를 제공하기 위한 알고리즘을 개발하는 연구를 진행하였다. 연구는 높은 정확도의 예측 결과를 보이며 운전원 지원 시스템에 적용 가능한 불확실성 정보를 제공하였다. Yoo 등[9]은 진단뿐만 아니라 예측까지 하여 중대사고 시 운전원 의사결정 시스템을 개발하였다. 연구는 중대사고 상황에서 종합적인 예측을 통해 운전원에게 유의미한 정보를 제공하여 원자력 발전소의 안전성 향상에 기여하였다. She 등[10]은 LOCA 상황에서 진단 및 예측을 위해 인공지능 모델을 결합한 하이브리드 방법을 사용하여 신속한 사고 진단 및 비상 대응을 위한 의사결정 시스템을 제안하였다. 진단과 예측을 통합하여 원자력 발전소의 안전성 향상을 증진 시키는 연구를 진행하였다. 따라서, 본 연구에서는 기존의 원자력 발전소에서 채택하고 있는 누설탐지 방법으로 포착되지 않는 미확인 소량 누설 사고 시에도 신속하게 탐지할 수 있도록 인공지능 모델을 활용하여 누설부의 초기 상대 습도를 예측하여 누설량을 정량화하는 방법을 제안한다.

인공지능 방법론은 Long Short-term memory (LSTM)[11]과 Bidirectional LSTM (Bi-LSTM)[12], Gated Recurrent Unit (GRU)[13]이 사용되었다. 이러한 인공지능 방법론은 시계열 데이터 예측에 특화되어 있어 다양한 분야의 예측 연구에 광범위하게 활용되고 있다. 인공지능 모델의 예측 성능은 하이퍼파라미터에 의해 영향을 받는 경우가 많기 때문에 우수한 모델 성능을 얻기 위해서는 최적화가 필수적이다. 따라서 Grid search 방법론을 사용하여 본 논문의 모든 인공지능 모델에 적용하였다[14]. 인공지능 학습에 사용된 데이터는 한국원자력연구원에서 개발한 고정밀 열유체 해석 코드인 CUPID (Component Unstructured Program for Interfacial Dynamics) 코드에서 취득하였다[15]. CUPID 코드는 과도, 2 유체, 3 유동장 (Transient, 2-fluid, 3-field) 모델을 채택하여 2상 유동을 해석하며, 세 개의 유동장은 연속 액체, 액적 및 증기를 나타

낸다. 현재 개발 중인 누설 감지 시스템을 위해 누설부의 습한 공기를 흡입하여 측정부로 운반하고 센서 튜브의 종점에 상대 습도 및 온도 센서를 포함하는 센서 튜브를 시뮬레이션하는데 CUPID 코드가 사용되었다. 센서 튜브에 대한 시뮬레이션 데이터는 인공지능 모델 학습에 사용되었다. 누설부의 초기 상대 습도 예측 성능평가를 통해 인공지능 모델과 하이퍼파라미터 최적화 알고리즘의 적용 가능성을 확인했으며, 초기 상대 습도 예측을 하여 누설량 정량화를 통해 향후 미세한 누설을 신속하게 탐지하여 운전원이 조치에 필요한 여유시간을 확보하거나 이차적인 인적오류 저감에 기여할 수 있을 것으로 보인다.

## 제 2 장 누설탐지 방법

본 논문에서 누설량을 정량화하는 연구를 진행함에 따라 원자력 발전소에서 누설탐지를 진행하는 방법에 대해 조사하였다. 누설탐지는 안전성 확보 측면에서 중요하기 때문에 규제지침(KINS/RG-N06.01)에 1gpm 이하의 누설을 1시간 이내에 탐지하는 능력을 요구한다. 누설탐지에는 집수조 수위, 방사능 준위, 습도 및 압력을 측정하여 진행하는데 위 방법들은 탐지 시간이 약 10분 이상으로 실시간 탐지가 불가능하다는 단점이 존재한다. 본 장에서는 인공지능 모델 전 기존 발전소에 적용 중인 음향누설감시계통, 불활성 기체 활용 누설탐지 방법 및 한국원자력연구원에서 개발중인 누설탐지 시스템에 관해 설명하였다.

### 제 1 절 음향누설감시계통

음향누설감시계통은 원자로냉각계통의 압력경계에 설치된 센서들로부터 누설여부 및 균열상태를 탐지하는 설비이며 전치증폭기, 감지기, 경보기, 분석 컴퓨터 등으로 구성되어 있다[16]. 그리고, 압전형 가속도계를 이용하여 가압기 밸브의 개폐를 탐지하는 안전밸브 보조계통과 원자로냉각재압력경계의 누설 및 배관의 균열 상태를 탐지하는 비 안전밸브 보조계통으로 이루어져 있다. 동작은 감지기에서 탐지된 신호가 전치증폭기를 통하여 경보기에 전달되어 신호처리가 된 후, 신호값이 경보 설정치를 넘게 되면 경보를 발생시켜 누설을 탐지하는 방법이다. 그림 1은 음향누설감시계통의 기본적인 측정 구성을 나타내었다.

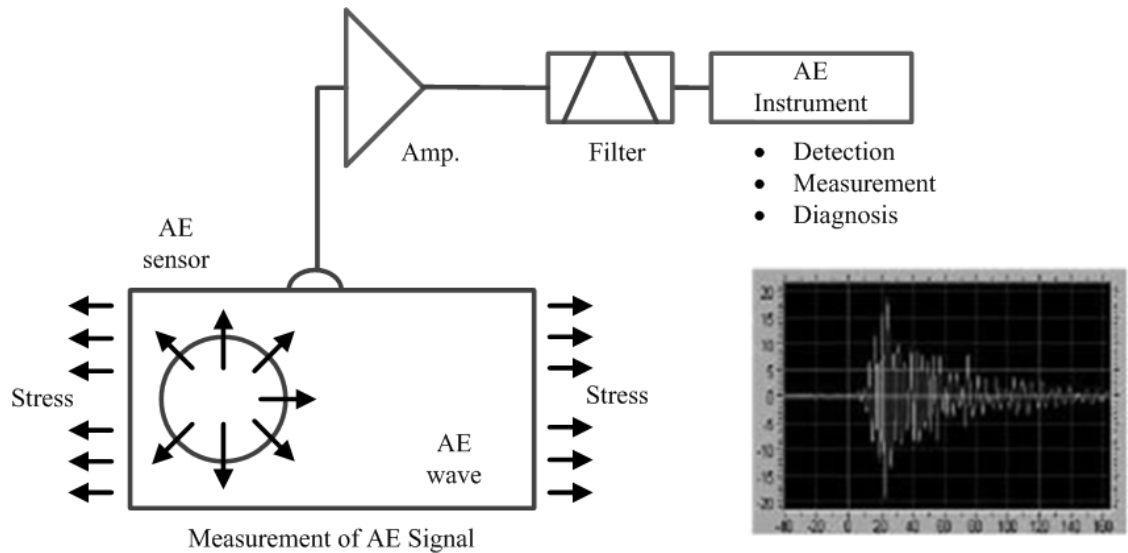


그림 1. 음향누설감시계통의 측정 구조[16]

## 제 2 절 불활성 방사선 기체를 이용한 누설탐지

방사선 기체를 이용한 누설탐지는 외부나 배관으로 유출되는 방사성 생성물에 의한 방사선을 측정하여 누설 여부를 감지하는 방법이다. 일반적으로 방사선 측정법을 이용하면 1gpm 정도의 누설을 감지하기 위해 약 10분에서 70분 정도의 시간이 소요되며, 감도가 낮아 누설 위치를 특정하기 힘들다. 또한, 유지비용이 많이 들게 된다는 단점이 존재한다.

불활성 방사성 기체를 이용한 누설탐지 방법은 1차측 기원 핵종인 불활성 기체 (Ar-41, Kr-85m, Kr-88, Xe-133, Xe-135, Xe-138)를 이용한다. 위의 핵종들은 모두 베타선과 감마선을 방출하면서 붕괴하게 된다. 불활성 방사성 기체를 이용한 누설탐지 방법은 원자력 발전소 내에 베타 방사선 감지기를 설치하고 방사선 측정을 통해 누설률을 계산하게 된다. 불활성 기체의 반감기는 N-16에 비해 길기 때문에 원자로 출력 20% 이하에서도 탐지가 가능하다는 장점이 있다[17].

불활성 방사성 기체를 이용한 누설탐지 방법에도 단점이 존재하는데 측정 대상인 Ar-41을 제외하면 모두 핵분열성 생성물이라는 단점이 있다. 불활성 기체의 원자로 냉각계통 내 농도는 핵연료를 둘러싸고 있는 cladding의 결함에 의해 결정되므로 누설률

감도의 정확도가 저하된다. 또한, 정상운전 시에는 핵연료 손상률이 거의 0에 가깝기 때문에 소규모 누설탐지와 실시간 누설탐지가 어렵다는 단점이 있다.

### 제 3 절 한국원자력연구원 개발 누설탐지 시스템

현재 한국원자력연구원에서 가압경수로의 0.5gpm 이하의 미확인 소량 누설탐지시스템을 개발하고 있다[18]. 원자력 발전소는 고방사선 구역으로 이루어져 있기 때문에 냉각재 누설이 자주 발생하는 취약 계통에 감시 센서를 배치하여 누설을 탐지하는 개념이다. 계측기기 등 전자 기기를 운영하기에는 방사선이 높은 구역에서는 어려우므로 방사선이 낮은 구역에서 격납건물과 원자로 사이의 환형공간이나 격리된 격실에 설치하여 운영한다. 따라서, 지름이 좁고 긴 길이를 가진 누설탐지 포집 튜브 시스템을 원자로 근처에 설치하여 환형 공간으로 인출하는 시스템을 고려하고 있다. 포집 튜브 시스템에는 온도센서, 습도센서 및 방사선센서 등을 채택하고 있으며, 미확인 소량누설 시 소량의 변화에도 탐지 가능한 센서를 개발하였다. 본 논문에서는 누설탐지 시스템에 추가적으로 누설량 정량화와 빠른 누설탐지에 기여할 수 있는 인공지능 모델을 만들어 활용할 계획이다.



## 제 3 장 인공지능 방법론

본 논문에서 누설부의 초기 상대 습도를 예측하는 데 사용된 인공지능 방법론은 LSTM, Bi-LSTM, GRU, Grid search이며, 먼저 시계열 예측을 위해 LSTM과 Bi-LSTM, GRU 방법론을 적용하여 초기 상대 습도를 예측하였다. 그리고, 예측 성능을 높이기 위해 grid search를 적용하여 하이퍼파라미터 최적화를 진행하였다. 따라서, 본 논문에서는 각 인공지능 모델을 적용하여 예측하고, 하이퍼파라미터 최적화를 통해 초기 상대 습도를 예측하는 연구를 진행하였다. 본 장에서는 인공지능 모델 개발 및 최적화 방법론에 관해 설명하였다.

### 제 1 절 LSTM

LSTM은 시계열 데이터를 예측하는 데 장점을 제공하는 순환 신경망(RNN; Recurrent Neural Network) 기반 방법론이다. 기존의 RNN은 역전파 학습 중에 기울기가 1보다 작은 값으로 반복적으로 곱해지기 때문에 기울기 소실 문제가 발생하여 훈련이 어렵다는 단점이 존재한다. LSTM은 기존의 RNN의 단점을 해결하기 위해 셀 상태와 세 개의 특성 게이트를 추가하여 정보를 제어한다.

망각, 입력, 출력, 세 개의 특성 게이트는 은닉층의 정보를 조절한다[11]. 망각 게이트에서 입력 데이터(셀 상태,  $C$ )가 컨베이어 벨트를 통과할 때, 망각 게이트는 이전 정보를 얼마나 유지할지 결정한다. 각 특성 게이트의 계산은 식 (1)~(3)으로 표현된다.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3)$$

식 (1), (2), (3)에서,  $\sigma$ 는 시그모이드 활성화 함수이고,  $x$ 와  $h$ 는 입력 데이터와 은닉층을 나타내며,  $W$ 는 가중치이고,  $b$ 는 bias이다. LSTM 모델의 입력 게이트 단계에서

는 셀 상태에 입력 데이터를 업데이트한다.  $\sigma$ 는 입력 게이트에서 업데이트할 새 정보의 일부를 결정하고,  $\tanh$  함수는 셀 상태에 추가할 후보 값을 생성한다. 이전 망각 게이트와 입력 게이트는 각각 어떤 정보를 잊고 기억할지 결정했기 때문에 출력 게이트에서 이전 셀 상태가 업데이트된다. 특성 게이트를 활용하면 LSTM의 역전파가 셀 상태를 통해 수행되므로 인공지능 모델에서 학습을 방해하는 경사 소실 문제에 탄력적으로 대응할 수 있다. LSTM 구조는 기존 RNN의 장기 종속성 문제를 완화할 수 있는 장점이 있다. 따라서 LSTM은 다양한 장기 종속성을 효과적으로 활용할 수 있어 장기 기억 및 순차적 데이터 처리와 관련된 작업에 적합하다. LSTM의 은닉층과 기본적인 구조는 그림 2에 나타내었다.

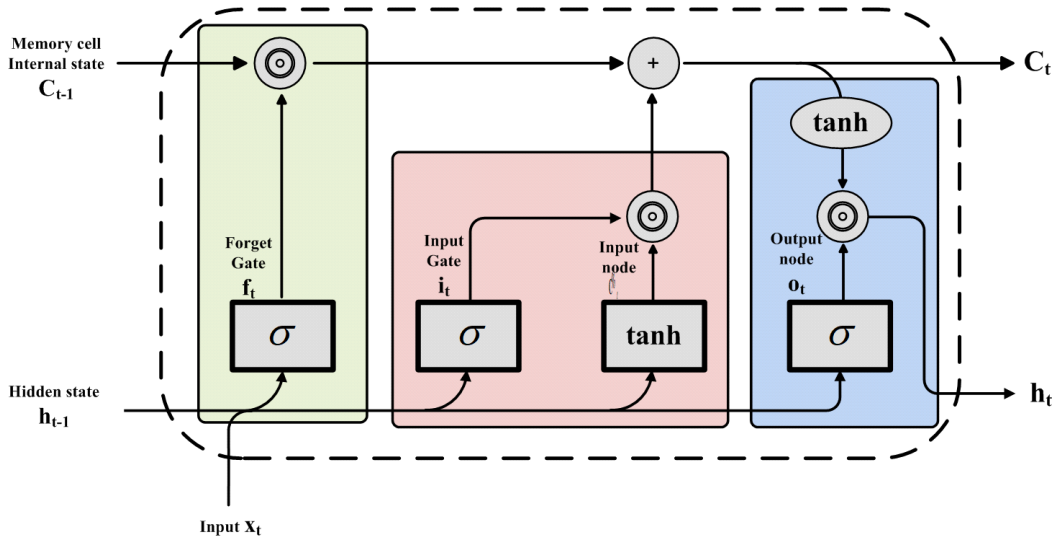


그림 2. LSTM의 구조

## 제 2 절 Bi-LSTM

하지만, LSTM은 순차적으로 데이터가 입력되기 때문에 이전 입력에 대한 출력 편향이 발생한다는 단점이 있다. 이러한 한계를 극복하기 위해 Bi-LSTM이 개발되었다 [12]. 기존의 LSTM과 달리 Bi-LSTM은 순방향으로 학습하는 상태와 역방향으로 학습하는 상태인 두 개의 은닉층을 도입하여 편향성 문제를 해결한다. 이를 통해 Bi-LSTM은 학습 과정에서 각 시간 단계에서 미래와 과거 시점의 정보를 모두 저장

하고 유지할 수 있다. 이로써, 양방향의 정보를 모두 고려할 수 있기 때문에 Bi-LSTM은 정보의 손실을 최소화하고 데이터의 입력 순서에 영향을 적게 받는 쪽으로 예측을 하는 것으로 목표로 한다.

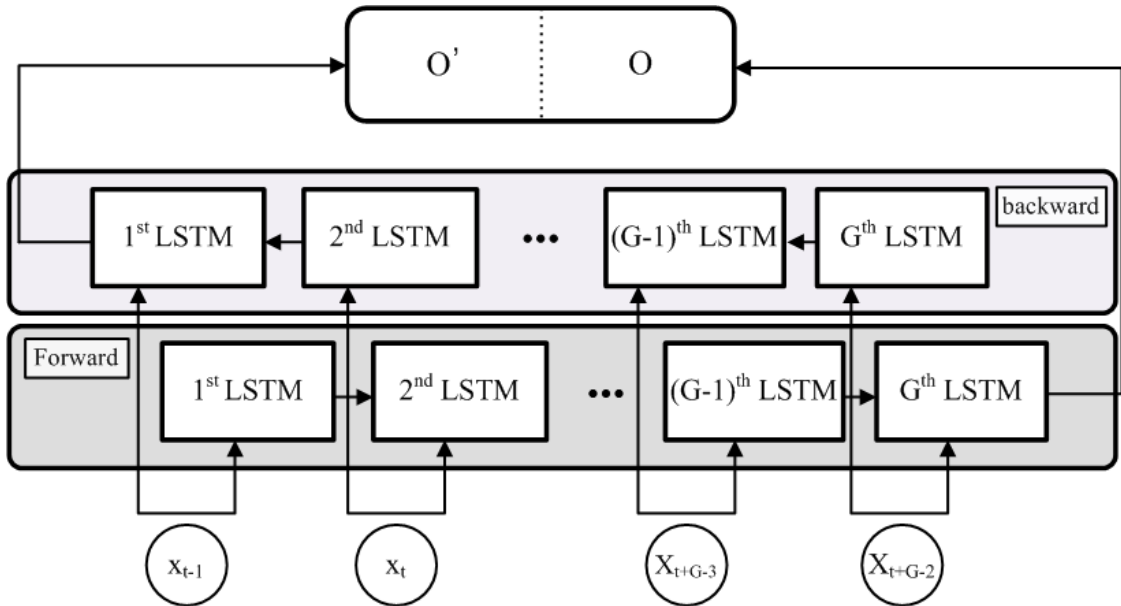


그림 3. Bi-LSTM의 구조

그림 3은 Bi-LSTM의 구조를 나타내었다. 각 시점에서 학습 방향은 각각 순방향 및 역방향 은닉층에 해당하는  $O$ 와  $O'$ 로 표시되는 출력을 생성한다. 그런 다음, 은닉층을 벡터 계산을 사용하여 결합하여 최종 결과를 생성한다. 출력은 인공지능 모델에 따라 평균 또는 단순 덧셈 등의 방법으로 적용할 수 있다.

### 제 3 절 GRU

GRU는 리셋 게이트와 업데이트 게이트로 이루어진 순환 신경망 기반 방법론이다. LSTM의 네트워크 문제를 개선하기 위한 방법론으로 기존 LSTM이 가지고 있던 세 개의 게이트에서 두 개의 특성 게이트로 줄어든 것이 큰 특징이다[13]. 이를 통해 LSTM에 비해 빠른 학습 시간을 가지고 있다는 장점이 있다. GRU의 리셋 게이트는

LSTM의 망각 게이트와 입력 게이트의 역할과 비슷하게 현재 상태에서 이전 상태의 정보를 얼마나 유지할지 결정하는 단계이다. 업데이트 게이트는 리셋 게이트를 통해 출력된 이전 상태의 정보와 새롭게 입력된 데이터 사이에서 결합하는 단계이다. 그림 4는 GRU에 대한 그림이며 간단한 구조를 보여준다.

$$r_t = \sigma(W_{xr}x_t + W_{hr}h_{t-1}) \quad (4)$$

$$u_t = \sigma(W_{xu}x_t + W_{hu}h_{t-1}) \quad (5)$$

$$g_t = \tanh(W_{hg}(r_t \otimes h_{t-1}) + W_{xg}x_t) \quad (6)$$

$$h_t = (1 - z_t) \otimes g_t + z_t \otimes h_{t-1} \quad (7)$$

식 (4)는 리셋 게이트에 관한 식이며, 시그모이드 함수를 출력으로 0과 1 사이의 값을 이전 은닉층에 곱한다. 그렇게 되면 직전 시점의 은닉층 값과 현시점의 정보에 가중치를 곱하여 리셋 게이트의 값을 얻을 수 있다.

식 (5)는 업데이트 게이트에 관한 식이며, 마찬가지로 시그모이드 함수로 출력된 결과는 현시점의 정보의 양을 유지하는 정도를 정하며, 은닉층의 정보에 곱해주는 역할을 한다.

식 (6)은 과거 은닉층의 정보를 리셋 게이트의 결과를 곱해주어 출력으로 내보낼 정보를 결정하는 값이다.

마지막으로 식 (7)은 식 (4)~(6)에서 얻은 값을 토대로 결합하여 값을 얻게 되는데, 시그모이드 함수를 통해 현시점의 정보와 과거 시점의 정보의 양을 결합하여 출력한다.

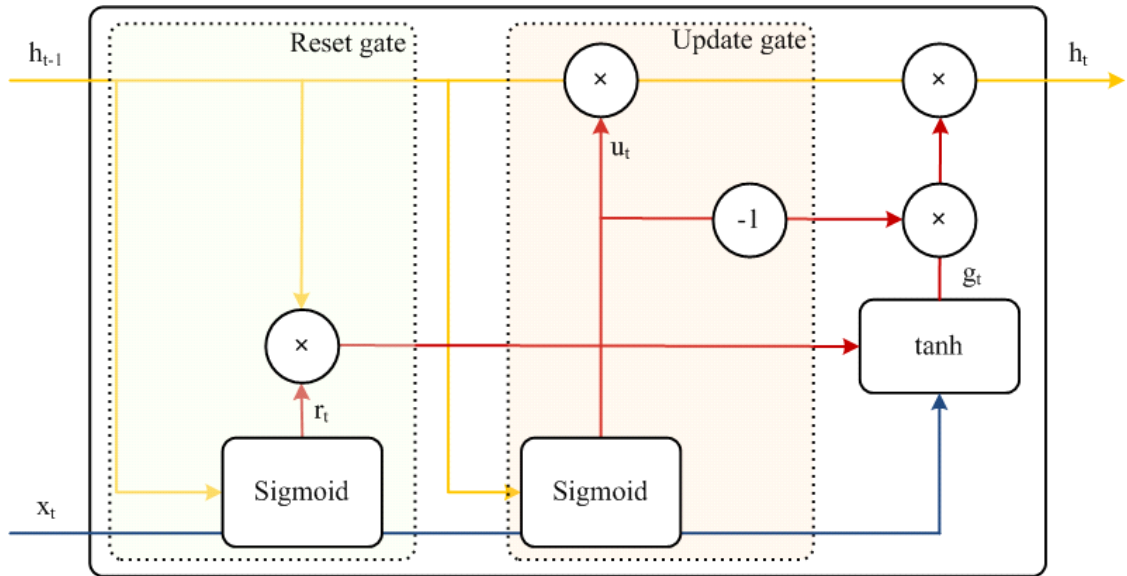


그림 4. GRU의 구조

## 제 4 절 Grid search

하이퍼파라미터는 인공지능 모델의 학습 과정을 제어하는 데 중요한 역할을 하며, 모델 내부에서 학습되는 매개변수와는 다른 의미를 가진다. 하이퍼파라미터는 인공지능 모델을 구축하는 모델 사용자가 설정한다. 하이퍼파라미터는 인공지능 모델의 성능과 학습 시간에 큰 영향을 미칠 수 있으므로 적절한 하이퍼파라미터를 선택하는 것이 중요하다.

인공지능 모델 구축 시 고려해야 할 하이퍼파라미터의 유형이 다양하기 때문에 의사결정 과정이 복잡해진다. 하이퍼파라미터 최적화란 활용하는 데이터와 인공지능 모델을 기반으로 최적의 하이퍼파라미터 조합을 검색하는 작업이다.

Grid search는 하이퍼파라미터 최적화에 사용되는 탐색적 방법 중 하나이다. 이를 통해 모델 사용자는 각 하이퍼파라미터에 대한 후보 값을 정의하고 후보 값의 각 조합에 대해 모델의 성능을 체계적으로 평가할 수 있다. 즉, 다양한 하이퍼파라미터 조합을 반복적으로 적용하여 해당 결과를 출력하는 방식이다. Grid search의 구조는 그림 5에 나타내었다[14].

Grid search는 가능한 모든 하이퍼파라미터 조합을 비교하여 모든 조합을 비교해 볼

수 있다는 장점을 제공한다. 하지만 grid search의 단점은 많은 수의 하이퍼파라미터 또는 광범위한 후보 값을 처리할 때 시간이 많이 소요될 수 있다는 것이다. 최적화 과정에서 각 조합을 순차적으로 학습하고 평가하는 과정이 포함되므로 최종 출력을 얻는데 시간이 더 오래 걸릴 수 있다.




그림 5. Grid search의 구조

## 제 4 장 데이터 처리

### 제 1 절 데이터 취득

다양한 조건에서 유체의 거동을 시뮬레이션하는 열유체 해석 코드를 사용하여 원자력 발전소에서 발생하는 다양한 사고를 모사 및 분석할 수 있다. 그러나 일반적인 열유체 해석 코드는 일반적인 물리 모델이나 수치 기법을 사용하여 1차원의 다차원 흐름을 시뮬레이션하는 데 한계가 있다[15]. 이러한 한계를 극복하기 위해 본 연구에서는 고정밀 열유체 해석 코드인 CUPID 코드를 활용하여 센서 튜브를 시뮬레이션했다. 그림 6는 센서 튜브의 단면을 나타내었다.

CUPID 코드는 증기발생기, 원자로 압력용기, 격납용기 등 다양한 원자력 발전소 설비의 다차원 2상 유동 현상을 분석하기 위해 고안된 열유체 해석 코드이다. 단상 및 2상 유동 문제뿐만 아니라 상 변화 및 공기-물 유동 현상까지 정확하고 안정적으로 해결할 수 있다는 장점이 있다. 현재, 한국원자력연구원에서는 배관 누설 발생 시 센서 튜브 하류의 온도 및 습도 측정값을 기반으로 유입되는 고습도 공기의 상대 습도를 예측하여 누설량을 정량화할 수 있는 시스템 연구를 진행하고 있다[18].

센서 튜브는 누설부의 고습도 공기를 빨아들여 측정부로 전달하며, 현재 개발 중인 누설 감지 시스템을 위해 센서 튜브의 종점에 상대 습도 및 온도 센서를 장착하였다. 또한, 누설 감지 시스템은 센서 튜브에 유체를 전달하기 위해 flushing, vacuuming, recovery pressure, discharge의 네 가지 동작을 반복하여 진행한다. 첫째, flushing은 센서 튜브에 상대 습도 10%의 건조한 공기를 채워 안정된 상태로 만들어주는 역할을 한다. 둘째, vacuuming은 부압을 형성하여 센서 튜브의 증기를 흡입한다. 셋째, recovery pressure는 증기가 센서 튜브에 들어갈 때까지 기다린 다음 공기를 순환시킨다. 마지막으로 discharge는 건조한 공기를 이동시켜 고습도 공기를 측정부로 운반한다. CUPID 코드를 사용하여 센서 튜브 내부의 이송 거리에 따른 상대 습도 변화에 대한 데이터를 취득하였다.

이송 과정에서 유입되는 고습도 공기의 습도는 저습도 공기와의 혼합 및 확산으로 인해 점차 감소한다. 본 연구에서는 누설량을 정량화하기 위해 센서 튜브의 이송 과정

을 CUPID 코드로 시뮬레이션하여 이송 거리에 따른 상대 습도 변화 데이터를 취득하였다. 본 연구의 센서 튜브는 누설부에서 공기를 흡입하여 측정 위치로 이송하도록 설계되었다. 파이프 직경은 6mm이다. 센서 튜브의 첫 1m 구간은 공기 흡입에 사용되며 유속은 11m/s로 설정하였다. 고습도 공기는 센서 튜브로 빨려 들어간다.




그림 6. CUPID 시뮬레이션 튜브 단면도



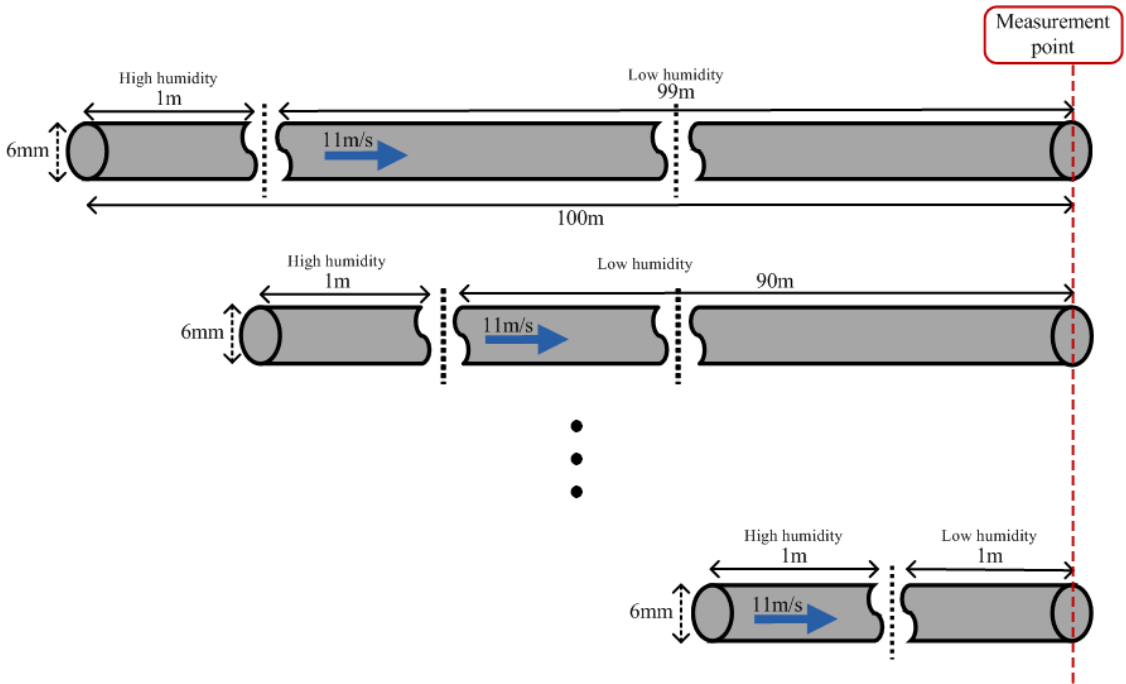


그림 7. CUPID 시뮬레이션 튜브 구조

그림 7은 측정부는 고정되어 있고 고습도 공기 부분은 누설부에 해당한다. 따라서 고습도 공기의 이동 거리는 RCS의 누설부의 위치에 따라 달라진다.

CUPID 코드 시뮬레이션을 통한 인공지능 모델의 입력 데이터를 취득하기 위해 온도, 압력, 건도, 이송 속도, 상대 습도가 입력변수로 선정되었다. 입력변수는 딥러닝 학습에 적합한 형태로 변환하기 위해 전처리 과정을 거친다. 일반적으로 상대 습도는 수증기압과 부피를 기준으로 계산한다. 본 연구에서는 식 (8)과 같이 수증기압을 기준으로 상대 습도 값을 계산된다.

$$\text{상대습도}(\%) = \frac{P_w}{P_{ws}} \times 100\% \quad (8)$$

$$P_{ws} = P_c e^{\frac{T_0}{T} (C_1\theta + C_2\theta^{1.5} + C_3\theta^3 + C_4\theta^{3.5} + C_5\theta^4 + C_6\theta^{7.5})} \quad (9)$$

여기서,

$$\theta = 1 - \frac{T}{T_c}$$

식 (8)에서  $P_w$ 는 수증기압이고  $P_{ws}$  포화 수증기압을 뜻한다. 식 (9)은 포화 증기압을 계산하기 위한 식이다. 식 (9)에서  $P_c$ 는 임계 압력 220,640 hPa,  $T$ 는 절대 온도,  $T_c$ 는 임계 온도 647.096 K이며, 각 값은 상수이다 ( $C_1=-7.85951783$ ,  $C_2=1.84408259$ ,  $C_3=-11.7866497$ ,  $C_4=22.6807411$ ,  $C_5=-15.9618719$ ,  $C_6=1.80122502$ )[19]. CUPID 코드 시뮬레이션은 이송 시간에 따른 온도, 건도 및 수증기압의 변화에 대한 정보를 제공한다.

그림 8~10은 CUPID 코드를 활용하여 취득한 데이터의 특정 지점의 그림을 나타내었다. 시뮬레이션 된 센서 튜브의 초기 조건은 상대 습도 10%와 50℃로 설정했으며, 누설부의 상대 습도와 유입되는 고습도 공기의 온도를 각각 2%와 2℃씩 변경하여 데이터를 취득하였다. 그 결과, 총 336개의 데이터 케이스가 생성되었다.




그림 8. 특정 데이터 포인트에서 취득한 건도 데이터 결과




그림 9. 특정 데이터 포인트에서 취득한 수증기압 데이터 결과




그림 10. 특정 데이터 포인트에서 취득한 온도 데이터 결과

표 1. 입력 데이터 조합

Temperature(°C)	Input relative humidity(%)	Distance from measurement point(m)	Total data length
60, 62, 64	60, 62, 64	1.1, 2.2, 3.3, 4.4	26,880
⋮	⋮	⋮	
96, 98, 100	86, 88, 90	96.6, 97.7, 98.8, 99.9	

표 1은 CUPID 코드 시뮬레이션을 위한 입력 데이터 조합을 보여준다. 여기에는 개발 중인 누설 감지 시스템의 측정 단위로 측정할 수 있는 0.1초의 time step, 온도 및 상대 습도가 포함되고, 데이터 세트는 세 가지 변수의 조합을 나타내는 총 26,880개의 데이터 길이로 구성된다. 본 논문에서 사용되는 인공지능 모델에는 모두 10개의 time step을 가지고 학습을 진행하였다.

그림 11은 하나의 데이터 케이스의 상대 습도 분포를 나타낸 것이고, 그림 12는 60°C에서의 모든 데이터 케이스에 대한 피크점을 연결하여 상대 습도 변화를 나타내었다. 그림을 통해 각 케이스에 대해 시간이 지남에 따라 상대 습도가 점진적으로 감소하는 것을 보여준다. 이 두 그림은 시뮬레이션 된 센서 튜브 내의 상대 습도 거동과 다양한 누설 시나리오가 상대 습도 변화를 보여줌으로써 데이터에 대한 신뢰성을 제공한다.




그림 11. 특정 케이스에서의 상대 습도 분포




그림 12. 모든 케이스에서의 상대 습도 분포

## 제 2 절 데이터 전처리

CUPID 코드를 통해 수집된 데이터는 인공지능 모델에 적용하기 위한 전처리 과정을 거쳤다. 전처리 단계에는 변수 선정, 정규화, 시계열 처리가 포함되었다.

변수 선정에서는 누설부의 초기 상대 습도를 예측하기 위한 인공지능 모델 개발에 필요한 입력변수를 선정하였다. CUPID 코드에서 취득된 변수와 센서 튜브에서 측정할 변수 중 누설부에서 측정부까지의 이송 거리, 측정부 온도와 상대 습도로 세 가지의 변수를 선정하였다. 선정 이유는 불필요한 변수나 향후 실적용을 고려하였을 때 실시간으로 탐지를 진행해야 하므로 실적용 시 활용하기 어려운 변수는 제외하였다.

다음으로, 선정된 변수를 정규화하여 데이터의 높은 변화로 인한 영향을 줄였다. 데이터 정규화는 특정 데이터가 인공지능 모델의 예측에 부정적인 영향을 미치는 것을 방지하고 학습 속도를 향상시키는 데 도움이 되는 전처리 방법이다. 본 논문에서는 데이터를 0과 1 사이의 범위로 스케일링하는 Mix-Max 정규화를 적용하였다.

마지막으로 sliding window 기법을 사용하여 시계열 데이터로의 변환 과정을 수행했다[20]. sliding window 기법은 CUPID 코드에서 얻은 이송 거리에 따른 상대 습도 데이터를 0.1초 단위의 시계열 구조로 변환하는 과정으로, sliding window 기법을 사용하면 데이터를 순차적으로 나누어 시계열 기반 방법론의 적용뿐만 아니라 시간 종속성을 포착할 수 있다.

인공지능 모델의 입력변수는 센서 튜브의 측정부의 상대 습도 및 온도와 누설부에서 측정부까지의 거리로 선정되었다. 다음 그림 13은 데이터 전처리부터 인공지능 적용까지의 절차를 간단하게 보여준다.

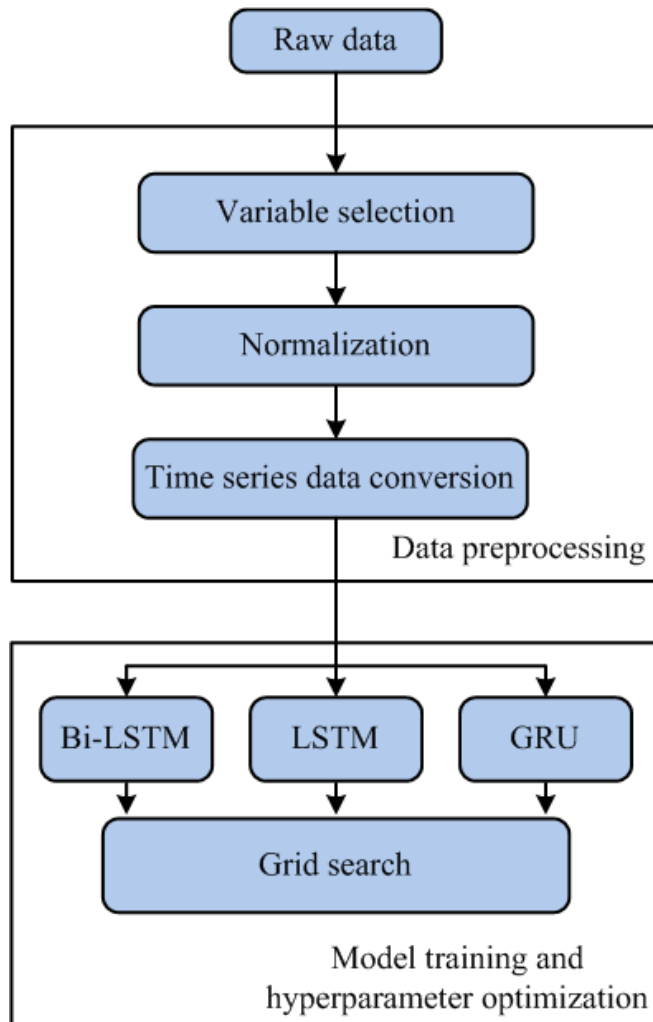


그림 13. 예측모델 개발 절차

## 제 5 장 초기 상대 습도 예측 결과

본 연구에서는 하이퍼파라미터 값이 예측 성능에 큰 영향을 미치기 때문에 grid search 방법론을 사용하여 인공지능 예측 모델에 대한 최적의 하이퍼파라미터 조합을 찾는 연구를 진행하였다. 하이퍼파라미터 조합에 사용된 하이퍼파라미터는 배치 사이즈(batch size), 레이어 깊이(layer depth), 최적화 함수(optimization function)를 사용하였고, 인공지능 모델의 과적합을 방지하기 위해 조기 종료(early stopping)를 적용하였다.

배치 사이즈는 인공지능 모델 학습이 진행될 때, 파라미터를 업데이트하는 데 사용되는 데이터의 길이이다. 배치 사이즈가 달라짐에 따라 학습 시간과 예측 성능에 영향을 주게 되는데, 본 연구에서는 8, 16, 32, 64, 128, 256의 배치 사이즈를 사용하였다. 인공지능 모델의 레이어 깊이는 인공지능 모델의 네트워크 깊이를 나타내며 가중치의 수와 학습을 위한 계산능력에 영향을 미친다. 본 연구에서는 레이어 깊이를 3, 4, 5, 6으로 결정하였다. 마지막으로 최적화 함수를 최적화하였는데, 방법으로는 RMSProp[21]과 Adam[22]을 사용하였고 각 최적화 함수에 해당하는 수식은 식 (10),(11)에 나타내었다. 식 (10)에서  $g_t$ 는 t번째 time step까지의 기울기이고,  $\gamma$ 는 지수 이동 평균의 업데이트 계수이다.  $\epsilon$ 은 약  $10^{-6}$ 에 해당하는 값으로 분모가 0이 되는 것을 방지 해주며,  $\eta$ 는 학습률을 의미한다. 식 (11)에서  $\beta_1$ ,  $\beta_2$ 는 Momentum과 RMSProp의 지수이동 평균을 뜻하고,  $\hat{m}$ 과  $\hat{g}$ 는 RMSProp에서  $\epsilon$ 의 역할을 하는 변수로 0이 되지 않게 해주는 보정값이다. 이를 통해 RMSProp은 경사도에 따라 학습률을 조정하여 최적의 출력값에서 멀어질 때 학습률을 높이고 가까워질 때 학습률을 낮추는 방법론이다. 반면에 Adam은 RMSProp과 Momentum 방법을 결합한 방법으로, 국부 최솟값에 대한 편향을 피하면서 학습률을 조절한다. 하지만, Adam의 단점은 초기 가중치 업데이트가 다른 방법론에 비해 상대적으로 느리다는 것이다.

$$g_t = \gamma g_{t-1} + (1-\gamma)(\nabla f(x_{t-1}))^2 \quad (10)$$

$$x_t = x_{t-1} - \frac{\eta}{\sqrt{g_t + \epsilon}} \cdot \nabla f(x_{t-1})$$



$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \nabla f(x_{t-1}) \quad (11)$$

$$g_t = \beta_2 g_{t-1} + (1 - \beta_2) (\nabla f(x_{t-1}))^2$$

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \hat{g}_t = \frac{g_t}{1 - \beta_2^t}$$

$$x_t = x_{t-1} - \frac{\eta}{\sqrt{\hat{g}_t + \epsilon}} \cdot \hat{m}_t$$

표 2는 grid search에 적용할 하이퍼파라미터 변수 종류를 보여준다. 최적의 하이퍼파라미터 조합은 평균 절대 오차(MAE; Mean Absolute Error)를 최소화할 수 있도록 선택되었다.

표 2. 하이퍼파라미터 최적화 선정 변수

Values	Hyperparameter		
	Batch size	Layer depth	Optimization function
8	3	Adam	
16			
32	4	RMSProp	
64	5		
128	6		
256			

표 3. LSTM의 grid search 적용 예측 결과

No.	Batch size	Layer depth	Optimization function	MAE	No.	Batch size	Layer depth	Optimization function	MAE
1	8	3	Adam	0.1742	25	64	3	Adam	0.2183
2	8	3	RMSProp	0.2003	26	64	3	RMSProp	0.2795
3	8	4	Adam	0.1067	27	64	4	Adam	0.1296
4	8	4	RMSProp	0.1474	28	64	4	RMSProp	0.4667
5	8	5	Adam	0.1036	29	64	5	Adam	0.1552
6	8	5	RMSProp	0.1091	30	64	5	RMSProp	0.2376
7	8	6	Adam	0.0876	31	64	6	Adam	0.1693
8	8	6	RMSProp	0.1761	32	64	6	RMSProp	0.2264
9	16	3	Adam	0.1543	33	128	3	Adam	0.1753
10	16	3	RMSProp	0.1551	34	128	3	RMSProp	0.3844
11	16	4	Adam	0.1294	35	128	4	Adam	0.1644
12	16	4	RMSProp	0.1530	36	128	4	RMSProp	0.5338
13	16	5	Adam	0.1180	37	128	5	Adam	0.1953
14	16	5	RMSProp	0.1354	38	128	5	RMSProp	0.7679
15	16	6	Adam	0.1214	39	128	6	Adam	0.3836
16	16	6	RMSProp	0.2309	40	128	6	RMSProp	0.5667
17	32	3	Adam	0.1589	41	256	3	Adam	0.2171
18	32	3	RMSProp	0.2414	42	256	3	RMSProp	0.8444
19	32	4	Adam	0.1421	43	256	4	Adam	0.2698
20	32	4	RMSProp	0.2188	44	256	4	RMSProp	0.7863
21	32	5	Adam	0.1556	45	256	5	Adam	0.3083
22	32	5	RMSProp	0.2378	46	256	5	RMSProp	0.6916
23	32	6	Adam	0.1527	47	256	6	Adam	0.1752
24	32	6	RMSProp	0.2600	48	256	6	RMSProp	0.7320

표 4. Bi-LSTM의 grid search 적용 예측 결과

No.	Batch size	Layer depth	Optimization function	MAE	No.	Batch size	Layer depth	Optimization function	MAE
1	8	3	Adam	0.0871	25	64	3	Adam	0.1313
2	8	3	RMSProp	0.0982	26	64	3	RMSProp	0.4238
3	8	4	Adam	0.0285	27	64	4	Adam	0.1943
4	8	4	RMSProp	0.1345	28	64	4	RMSProp	0.2242
5	8	5	Adam	0.0887	29	64	5	Adam	0.1577
6	8	5	RMSProp	0.4668	30	64	5	RMSProp	0.3752
7	8	6	Adam	0.0108	31	64	6	Adam	0.1261
8	8	6	RMSProp	0.0320	32	64	6	RMSProp	0.4828
9	16	3	Adam	0.0998	33	128	3	Adam	0.2408
10	16	3	RMSProp	0.1423	34	128	3	RMSProp	0.3361
11	16	4	Adam	0.0647	35	128	4	Adam	0.0882
12	16	4	RMSProp	0.2665	36	128	4	RMSProp	0.3757
13	16	5	Adam	0.0214	37	128	5	Adam	0.2868
14	16	5	RMSProp	0.0735	38	128	5	RMSProp	0.7949
15	16	6	Adam	0.0228	39	128	6	Adam	0.2388
16	16	6	RMSProp	0.1006	40	128	6	RMSProp	0.4238
17	32	3	Adam	0.1375	41	256	3	Adam	0.2238
18	32	3	RMSProp	0.1781	42	256	3	RMSProp	0.7299
19	32	4	Adam	0.1944	43	256	4	Adam	0.1920
20	32	4	RMSProp	0.2523	44	256	4	RMSProp	0.6259
21	32	5	Adam	0.1169	45	256	5	Adam	0.2310
22	32	5	RMSProp	0.1480	46	256	5	RMSProp	1.1889
23	32	6	Adam	0.0494	47	256	6	Adam	0.2013
24	32	6	RMSProp	0.2741	48	256	6	RMSProp	1.2427

표 5. GRU의 grid search 적용 예측 결과

No.	Batch size	Layer depth	Optimization function	MAE	No.	Batch size	Layer depth	Optimization function	MAE
1	8	3	Adam	0.1749	25	64	3	Adam	0.2446
2	8	3	RMSProp	0.2497	26	64	3	RMSProp	0.5892
3	8	4	Adam	0.2151	27	64	4	Adam	0.2309
4	8	4	RMSProp	0.3299	28	64	4	RMSProp	0.4454
5	8	5	Adam	0.1166	29	64	5	Adam	0.2885
6	8	5	RMSProp	0.2041	30	64	5	RMSProp	0.3921
7	8	6	Adam	0.1254	31	64	6	Adam	0.1811
8	8	6	RMSProp	0.1402	32	64	6	RMSProp	0.1926
9	16	3	Adam	0.2491	33	128	3	Adam	0.3047
10	16	3	RMSProp	0.2819	34	128	3	RMSProp	0.4281
11	16	4	Adam	0.2051	35	128	4	Adam	0.3889
12	16	4	RMSProp	0.2615	36	128	4	RMSProp	0.4983
13	16	5	Adam	0.1627	37	128	5	Adam	0.3794
14	16	5	RMSProp	0.2841	38	128	5	RMSProp	0.5721
15	16	6	Adam	0.1605	39	128	6	Adam	0.2922
16	16	6	RMSProp	0.1615	40	128	6	RMSProp	0.5325
17	32	3	Adam	0.2243	41	256	3	Adam	0.3444
18	32	3	RMSProp	0.2667	42	256	3	RMSProp	0.9164
19	32	4	Adam	0.2404	43	256	4	Adam	0.3741
20	32	4	RMSProp	0.3057	44	256	4	RMSProp	0.7401
21	32	5	Adam	0.1467	45	256	5	Adam	0.3606
22	32	5	RMSProp	0.1664	46	256	5	RMSProp	0.6048
23	32	6	Adam	0.1549	47	256	6	Adam	0.2688
24	32	6	RMSProp	0.2142	48	256	6	RMSProp	0.5372

표 3, 4, 5는 각각 LSTM과 Bi-LSTM, GRU에 대해 48개의 하이퍼파라미터 조합의 MAE 결과를 보여준다. MAE가 제일 낮은 하이퍼파라미터를 최적의 하이퍼파라미터 조합으로 간주하였다. 일반적으로 배치 사이즈가 작고 레이어 깊이가 깊은 인공지능 모델이 학습 시간이 길고 높은 성능을 가진 인공지능 모델이 되었다. Grid search 결과를 바탕으로 하이퍼파라미터 변화에 따른 결과는 다음과 같은 특징을 가진다.




그림 14. LSTM의 배치 사이즈에 따른 MAE




그림 15. Bi-LSTM의 배치 사이즈에 따른 MAE




그림 16. GRU의 배치 사이즈에 따른 MAE

1) 배치 사이즈: 그림 14~16은 grid search를 적용했을 때 LSTM과 Bi-LSTM, GRU 모델의 오차를 통해 전반적인 성능 변화를 보여준다. 일반적으로 배치 사이즈를 줄이면 특정 배치 사이즈 값을 제외하고는 MAE가 감소하는 추세를 보인다. 배치 사이즈가 작을수록 일반적으로 예측 성능이 향상되지만, 학습에 걸리는 시간도 늘어나는 추세를 보인다. Grid search를 통해 배치 사이즈가 작을수록 예측 정확도 측면에서 더 나은 결과를 얻는 경향이 있음을 확인할 수 있었다.

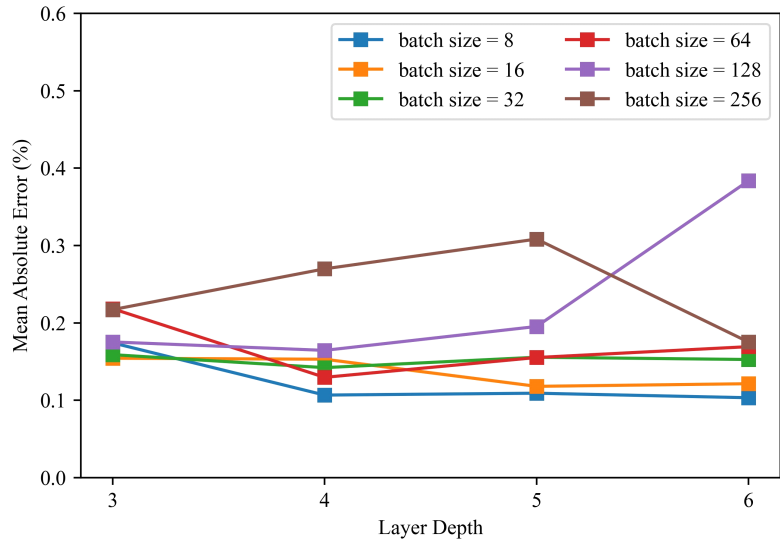


그림 17. LSTM의 레이어 깊이에 따른 MAE




그림 18. Bi-LSTM의 레이어 깊이에 따른 MAE

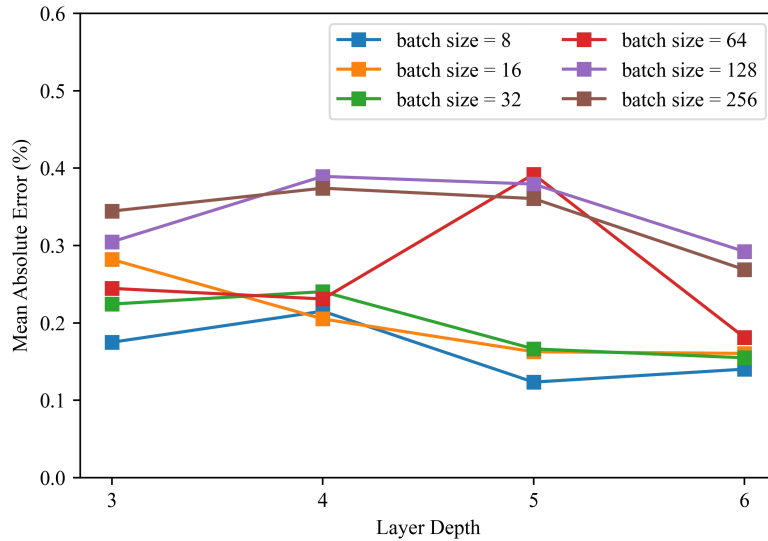


그림 19. GRU의 레이어 깊이에 따른 MAE

2) 레이어 깊이: 그림 17~19는 레이어 깊이에 따른 LSTM과 Bi-LSTM, GRU 모델의 예측 성능을 보여준다. 레이어 깊이가 깊을수록 작은 배치 사이즈에서는 예측 성능이 향상될 가능성이 있지만, 큰 배치 사이즈에서는 의미 있는 성능 개선이 이루어지지 않았다. 그러나 레이어 깊이가 깊을수록 더 많은 계산이 필요함에 따라 학습에 걸리는 시간이 늘어난다. 일반적으로 최적의 레이어 깊이는 인공지능에 입력되는 데이터와 모델의 특성에 따라 달라진다.

3) 최적화 함수: Adam은 적용된 모든 하이퍼 파라미터 조합에서 RMSProp보다 우수한 성능을 보였다. Adam은 RMSProp과 Momentum의 장점을 결합하여 더 나은 성능 결과를 제공한다.

취득된 데이터 중 90%는 학습 데이터로, 나머지 10%는 테스트 데이터로 사용되었다. 누설부의 초기 상대 습도 예측 성능은 MAE를 사용하여 평가되었다. 오차 평가 지표는 예측값과 실제 값 사이의 오차를 정량화한다. MAE는 예측값과 실제 값 간의 절댓값을 취해 오차를 측정한다. 식 (12)는 각 오차에 해당하는 식을 나타내었다. 이때,



$z_i$ 는 실제 상대 습도를 의미하고,  $\hat{z}_i$ 는 인공지능 모델이 예측한 값을 나타낸다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |z_i - \hat{z}_i| \quad (12)$$

MAE를 평가하여 누설부의 상대 습도를 예측하는 인공지능 모델의 성능을 평가할 수 있다. MAE에서 알 수 있듯이 Bi-LSTM 모델은 모든 케이스의 예측 정확도 측면에서 LSTM 모델보다 우수한 성능을 보였다. Bi-LSTM의 미래의 정보뿐만 아니라 과거의 정보까지 포착할 수 있는 특성이 우수한 예측 성능에 기여하였다.




그림 20. LSTM의 상위 하이퍼파라미터 조합 예측 결과




그림 21. Bi-LSTM의 상위 하이퍼파라미터 조합 예측 결과




그림 22. GRU의 상위 하이퍼파라미터 조합 예측 결과




그림 23. LSTM의 하위 하이퍼파라미터 조합 예측 결과




그림 24. Bi-LSTM의 하위 하이퍼파라미터 조합 예측 결과




그림 25. GRU의 하위 하이퍼파라미터 조합 예측 결과

그림 20~22는 인공지능 모델의 상위 수준의 하이퍼파라미터 최적화 조합의 예측 결과를 그림을 통해 나타내었다. 그림에서 파란색 점은 누설부의 실제 초기 상대 습도 값을 나타내고, 빨간색 점은 인공지능 모델에서 학습 후 출력한 예측값을 나타낸다. LSTM과 GRU에서는 예측을 수행한 결과인 빨간색 점을 확인해 보았을 때, 눈에 띄는 오차가 보이는 반면, Bi-LSTM에서는 앞선 두 인공지능 모델에 비해 우수한 성능을 보이는 것을 확인할 수 있다.

하지만, 그림 23~25는 하위 수준의 하이퍼파라미터 최적화 조합을 나타낸 그림이다. 그림을 확인해 보았을 때, 모든 인공지능 모델에서 예측 지점에 도달하지 못하는 등 예측이 성공적으로 수행이 되지 않는 것을 볼 수 있다.

본 연구를 요약하면, grid search를 통해 동일한 인공지능 모델이라도 사용자가 조합한 하이퍼파라미터 조합에 따라 성능이 달라지고 성능 향상을 할 수 있는 것을 확인할 수 있었다. 세 가지 인공지능 모델 모두 작은 배치 사이즈와 Adam을 사용하여 학습한 인공지능 모델이 다른 하이퍼파라미터 조합보다 누설부의 초기 상대 습도를 예측하는데 있어 우수한 성능을 보여주었다.

## 제 6 장 결론

본 논문에서는 인공지능 모델인 LSTM과 Bi-LSTM, GRU를 활용하여 누설부의 상대 습도 예측을 수행하였다. 이 인공지능 모델들은 시계열 예측 작업에 적합한 방법론을 활용하였다. 인공지능 학습을 위한 데이터는 고정밀 열유체 해석 코드인 CUPID 코드를 시뮬레이션하여 취득하였다. 인공지능 학습을 위해 총 26,880개의 데이터 포인트가 취득되었다. 인공지능 모델 학습에 적합한 데이터를 만들기 위해 데이터 전처리를 통해 시계열 데이터로 변환하였다.

LSTM과 Bi-LSTM, GRU 모델의 학습에는 학습 성능 개선을 위한 최적의 하이퍼파라미터 조합을 찾기 위해 grid search를 사용하여 하이퍼파라미터를 최적화하는 작업이 포함되었다. 양방향 종속성을 학습할 수 있는 Bi-LSTM 모델이 상대 습도 예측에서 LSTM과 GRU 모델보다 우수한 성능을 보였다. 모든 인공지능 모델 학습에는 과적합을 방지하기 위해 학습 과정에서 조기 종료기가 사용되었다.

하이퍼파라미터 최적화 방법을 적용한 초기 상대 습도 예측 결과, Bi-LSTM 모델의 오차는 0.0108%, 학습 시간은 7시간 8분, LSTM 모델의 오차는 0.0876%, 학습 시간은 1시간 50초, GRU 모델의 오차는 0.1166%, 학습 시간은 1시간 12분으로 결과를 보였다. 이러한 결과는 양방향 종속성을 포착할 수 있다는 이점을 가진 Bi-LSTM 모델의 우수한 성능을 확인하는 결과를 보인다. 인공지능 모델의 실적용에서는 인공지능 적용 전 학습에 사용할 수 있는 시간에는 제한이 없으며, LSTM과 Bi-LSTM, GRU 모델 모두 거의 빠르게 탐지할 수 있기 때문에, Bi-LSTM이 학습에 더 많은 시간을 소비하더라도 성능을 개선하고 오차를 최소화하여 성능을 높이는 것이 더 중요하다고 생각한다.

본 연구는 원자력 발전소의 기기 열화, 진동, 배관 및 밸브 손상 등으로 인한 소규모 RCS 누설 사고를 탐지하고 안전성을 향상시킬 수 있는 잠재력을 가진 인공지능 모델을 개발하여 누설량을 정량화하는 것을 목표로 했다. 개발된 인공지능 모델은 누설부의 초기 상대 습도를 성공적으로 예측함으로써 원자력 발전소에서 누설 사고의 감지 및 관리를 개선하는 데 기여할 수 있을 것으로 기대된다.

전반적으로 본 연구는 누설량 정량화를 위한 인공지능 모델 활용에 대한 인사이트를

제공하며, 원자력 발전소의 안전성 향상에 기여할 수 있는 잠재력을 가진다. 향후 개발 중인 누설 감지 시스템에서 실험 데이터를 취득하거나 실제 발전소 누설 데이터를 확보하고 이를 인공지능 모델과 결합하여 결과를 낼 수 있다면 더 높은 신뢰도를 얻을 수 있을 것으로 기대된다.

## 참고문헌

- [1] “Operational Performance Information System for Nuclear Power Plant”, Nuclear accident and failure status, last modified Jan 05, 2023, accessed Jan 16, 2023, <http://opis.kins.re.kr/opis?act=KROBA3100R>.
- [2] Korea Institute of Nuclear Safety, Reports of Accident and Breakdown in the Nuclear Power Plant, Korea Institute of Nuclear Safety, 2009, 170327K4.
- [3] Y. S. Kim, D. J. Euh, W. S. Kim, T. S. Kwon, Investigation of Leakage Characteristics on Major Equipment/Component in Reactor System, The KSFJ Journal of Fluid Machinery 22 (2019) 30–35.
- [4] S. J. Park, J. K. Park, G. Y. Heo, Transient diagnosis and prognosis for secondary system in nuclear power plants, Nuclear Engineering and Technology 48 (2016) 1184–1191.
- [5] 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, Nuclear Engineering and Technology 51 (2019) 723–730.
- [6] H. M. Park, J. H. Lee, K. D. Kim, Wall temperature prediction at critical heat flux using a machine learning model, Annals of Nuclear Energy 141 (2020).
- [7] H. S. Jo, Y. D. Koo, J. H. Park, S. W. Oh, C. H. Kim, M. G. Na, Prediction of golden time for recovering SISs using deep fuzzy neural networks with rule-dropout, Nuclear Engineering and Technology, 53 (2021) 4014–4021
- [8] H. J. Kim, J. H. Kim, Long-term prediction of safety parameters with uncertainty estimation in emergency situations at nuclear power plants, Engineering and Technology. 55 (2023) 1630–1643.
- [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, Nuclear Engineering and Technology 50 (2018) 562–569.
- [10] J. She, T. Shi, S. Xue, Y. Zhu, S. Lu, P. Sun, H. Cao, Diagnosis and Prediction for Loss of Coolant Accidents in Nuclear Power Plants Using Deep Learning

- Methods, *Frontiers in Energy Research* 9 (2021) 1–9.
- [11] S. Hochreiter, J. Schmidhuber, Long Short-Term Memory, *Neural Computation* 9 (1997) 1735–1780.
- [12] M. Schuster, K. K. Paliwal, Bidirectional recurrent neural networks, *IEEE Trans. Signal Processing* 45 (1997) 2673 – 2681.
- [13] J. Y. Chung, C. Gulcehre, K. H. Cho, Y. Bengio., Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling, arXiv preprint arXiv:1312.3555, (2014).
- [14] J. Bergstra, Y. Bengio., Random Search for Hyper-Parameter Optimization, *Journal of Machine Learning Research* 13 (2012) 281–305.
- [15] J. J. Jung, H. Y. Yun, I. K. Park, H. G. Jo, The CUPID CODE Development and Assessment Strategy, *Nuclear Engineering and Technology* 42 (2010) 636–655.
- [16] 한국과학기술원, 음향신호를 이용한 누설 위치 추정 기술 개발 (No. KAERI/CM-1330/2009).
- [17] 한국전력공사, 원자력 발전소의 증기발생기의 누설 감지장치 및 방법, 10-2008-0046273, (2008).
- [18] T. S. Kwon, J. R. Kim, C. K. Choi, J. S. Park, C. R. Choi, Development of an Unidentified RCS Leakage Detection Sensor System Less than 0.5 gpm, *The KSFM Journal of Fluid Machinery* 24 (2021) 13–19.
- [19] Vaisala Oyj. Calculation Formulas for Humidity–Humidity Conversion Formulas; Vaisala: Helsinki, Finland, (2013).
- [20] C. K. Koc, Analysis of Sliding Window Techniques for Exponentiation, *Computers & Mathematics with Applications* 30 (1995) 17–24.
- [21] S. Ruder, An overview of gradient descent optimization algorithms, arXiv preprint arXiv:1609.04747, (2016).
- [22] D. P. Kingma, J. L. Ba, Adam: A method for stochastic optimization, arXiv preprint arXiv:1412.6980, (2014).