



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](#)

2022년 2월
석사학위 논문

딥러닝을 이용한 비정상 상태시 원자로 트립변수 예측

조선대학교 대학원

원자력공학과

조혜선

딥러닝을 이용한 비정상 상태시 원자로 트립변수 예측

Prediction of reactor trip variables in abnormal states
using deep learning

2022년 2월 25일

조선대학교 대학원

원자력공학과

조혜선

딥러닝을 이용한 비정상 상태시 원자로 트립변수 예측

지도교수 나 만 균

이 논문을 공학 석사학위신청 논문으로 제출함

2021년 10월

조선대학교 대학원

원자력공학과

조혜선

조혜선의 석사학위논문을 인준함

위원장 조선대학교 교수 김종현 (인)

위원 조선대학교 교수 김진원 (인)

위원 조선대학교 교수 나만균 (인)

2021년 12월

조선대학교 대학원

목차

표 목차	ii
그림 목차	iii
ABSTRACT	iv
제 1 장 서론	1
제 2 장 인공지능 방법론	3
제 1 절 PCA	3
제 2 절 LSTM	5
제 3 절 Attention mechanism	7
제 4 절 MIMO 전략	9
제 5 절 다단계 예측 절차 및 최적화	11
제 3 장 데이터 수집 및 전처리	14
제 1 절 데이터 수집	14
제 2 절 데이터 전처리	16
제 4 장 트립변수 예측 결과	18
제 5 장 결론	32
참고문헌	34

표 목차

표 1. 수집된 비정상 시나리오	15
표 2. LSTM with Attention mechanism을 이용한 예측 결과	19
표 3. LSTM with Attention mechanism과 기본 LSTM의 예측 결과 비교표	31

그림 목차

그림 1. 각 주성분에 따른 원시데이터의 분산 비율	5
그림 2. LSTM 구조	6
그림 3. LSTM 은닉층의 내부 구조	6
그림 4. Attention mechanism이 적용된 Encoder-Decoder 구조	8
그림 5. MIMO 전략 적용을 위한 데이터 도식화	11
그림 6. 학습 횟수에 대한 손실 함숫값	12
그림 7. 제안된 인공지능 모델의 다단계 예측 절차	13
그림 8. 데이터 전처리 세부 절차	17
그림 9. 예측 단계에 따른 RMS 오차	21
그림 10. 비정상 시나리오별 RMS 오차	21
그림 11. 예측 단계가 60 step일 때 예측 결과 (가압기 수위채널 고장 - 저)	23
그림 12. 예측 단계가 120 step일 때 예측 결과 (가압기 수위채널 고장 - 저)	24
그림 13. 예측 단계가 180 step일 때 예측 결과 (가압기 수위채널 고장 - 저)	25
그림 14. 예측 단계가 60 step일 때 예측 결과 (RCS에서 1차 기기냉각수 계통으로 누설)	27
그림 15. 예측 단계가 120 step일 때 예측 결과 (RCS에서 1차 기기냉각수 계통으로 누설)	28
그림 16. 예측 단계가 180 step일 때 예측 결과 (RCS에서 1차 기기냉각수 계통으로 누설)	29

ABSTRACT

Prediction of reactor trip variables in abnormal states using deep learning

Hye Seon Jo

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

Department of Nuclear Engineering,

Graduate School of Chosun University

When an abnormal state occurs in a nuclear power plant, the operator must be aware of the situation based on a lot of information, which can increase human error and miss the timing of the action. These can eventually cause a reactor trip. Therefore, in order to prevent unexpected reactor trip, the variables that cause the reactor trip were predicted using artificial intelligence. The variables that cause the reactor trip in a nuclear power plant include those related to pressurizer, steam generator, neutron flux, and so on. Among these variables, the pressurizer water level and pressure were predicted in this thesis.

Applied artificial intelligence methods to predict the trip variables are Long Short-Term Memory (LSTM) with attention mechanism. The performance of the developed prediction model was compared with the basic LSTM to which the attention mechanism was not applied. If information on the future behavior of the trip variables is provided to the operator through the developed prediction model, it is expected that it will be possible to reduce the human error of the operator and prevent the reactor trip in abnormal situations.

제 1 장 서 론

핵분열 물질을 다루는 원자력발전소 특성상 방사성 물질이 생성될 수 있다. 방사성 물질이 외부에 누출되면 인명 및 환경 오염을 발생시킬 수 있으므로 이를 방지하기 위해서 원자력발전소에는 다양한 안전설비 및 안전 개념이 적용되어 있다. 그러나, 안전성 확보를 기반으로 설계된 원자력발전소는 가동 시간이 증가함에 따라 기계, 전기, 계측 결함 등 다양한 고장 원인으로 인해 비정상 상태가 발생할 수 있다.

원자력발전소에서 비정상 상태가 발생했을 때, 운전원은 발전소를 정상 상태로 회복하기 위한 상황 인지 및 해당 상황에 적합한 비정상 절차서를 찾고 절차서를 기반으로 적절한 조치를 수행해야 한다. 만약 빠른 시간 내에 조치를 수행하지 못하거나, 잘못된(발생된 비정상 상태와 적합하지 않은) 비정상 절차서를 기반으로 조치를 수행할 시 원자력발전소의 상태가 더 악화되어 원자로 트립이 발생할 수 있다. 원자로 트립은 발전소의 안전을 위해 발생될 수 있지만, 예상치 못한 원자로 트립은 막대한 경제적 손실을 발생시킬 수 있다.

따라서, 본 논문에서는 인공지능을 활용한 진단 결과와 더불어 비정상 상태시 예상치 못한 원자로 트립을 방지할 수 있도록 원자로 트립을 유발하는 변수에 대한 정보를 운전원에게 제공해주기 위해서 수행되었다. 즉, 운전원에게 미리 원자로 트립 시점 및 트립변수의 추세를 제공할 수 있도록 인공지능을 이용하여 원자로 트립을 유발하는 변수의 추세를 정확하게 예측하는 것을 목표로 하였다.

현재, 운전원의 운전지원을 위해 다양한 인공지능 방법을 이용하여 비정상 상태 및 비정상 절차서 진단 연구[1-3]와 원자력발전소 내 기기의 유지 보수 계획 및 잔여 수명을 추정하기 위한 연구가 수행되고 있다. 관련 연구로는 Long Short-Term Memory(LSTM)를 이용한 원자로 냉각재 펌프의 밀봉수 유량 예측[4], 증기발생기 수위 예측[5] 연구와 역전파 신경망을 이용한 증기발생기 및 가압기 수위 예측[6] 연구가 있다.

본 논문에서는 트립 유발 변수의 추세를 예측하기 위해 Principal Component Analysis(PCA), 인공지능 방법의 LSTM, 그리고 Attention mechanism을 사용하였다. 원자로 트립 유발 변수에는 중성자 flux, 원자로 냉각재 유량, 가압기와 증기발생기의 수위 및 압력 등이 포함된다[7]. 가압기는 가압경수로형 원자력발전소에서 1차측 냉각

재가 끊지 않도록 압력을 조절해주는 주요 변수이기 때문에 트립 유발 변수 중에서 가압기 수위와 압력을 예측하였다. 가압기 수위와 압력 예측을 위해 적용된 데이터는 Westinghouse-993MWe를 참조로 하여 설계된 Compact Nuclear Simulator(CNS)[8]를 통해 취득하였다.

원자력발전소의 데이터는 비선형 시계열 데이터이므로 시계열 데이터 처리에 특화된 LSTM을 이용하여 가압기 수위와 압력을 예측하기 위한 인공지능 모델을 개발 및 평가하였다. 그리고 LSTM의 성능을 향상시키기 위해 LSTM에 입력데이터에서 예측 대상과 관련성이 높은 시간에 가중치를 부여하여 학습하는 Attention mechanism을 적용하였다. 또한, 다단계 예측 전략 중 하나인 Multi-Input Multi-Output(MIMO) 전략을 적용하여 다단계 예측을 수행하였다. 개발된 인공지능 모델은 다양한 평가지표를 기반으로 예측성능이 평가되었으며, Attention mechanism이 적용되지 않은 기본 LSTM의 예측 결과와 성능을 비교하였다.

개발된 인공지능 모델을 통해 비정상 상태 발생시 운전원에게 원자로 트립 유발 변수에 대한 추세를 제공해준다면, 운전원에게 사전 조치를 유도하여 예상치 못한 원자로 트립을 방지할 수 있을 것으로 기대된다.

제 2 장 인공지능 방법론

원자로 트립을 유발할 수 있는 변수를 예측하기 위해 PCA, LSTM, Attention mechanism, MIMO 전략을 사용하였다. 우선 인공지능의 학습 속도 및 효율성을 높이기 위해 PCA 방법을 적용하여 데이터의 차원을 축소시켰다. 그 후, 축소된 데이터를 기반으로 LSTM과 Attention mechanism을 이용하여 인공지능 모델 학습과 예측 변수의 추세 예측을 수행한다. 이때, 예측 변수의 추세를 예측하기 위해 MIMO 전략을 적용하였다. MIMO 전략은 다단계 예측 전략 중 하나로써 단일 모델을 통해 다중 입력 데이터를 기반으로 다중 출력을 내는 전략이다. 따라서, 본 논문에서는 PCA를 통해 차원이 축소된 입력데이터를 기반으로 LSTM과 Attention mechanism이 적용된 인공지능 모델을 통해 예측 대상 변수의 다단계 예측을 수행하였다. 본 장에서는 인공지능 모델 개발에 적용된 알고리즘 및 방법론과 개발된 예측 모델의 최적화에 대해 설명하고자 한다.

제 1 절 PCA

일반적으로 인공지능 모델에 적용할 데이터의 특징이 많아질수록 인공지능 모델의 학습 시간 증가 및 과적합이 쉽게 발생할 수 있다. 따라서 이를 방지하기 위하여 본 논문에서는 차원 축소 알고리즘 중 하나인 PCA를 이용하여 데이터의 차원 축소를 수행하였다. PCA의 기본 원리는 고차원의 데이터에 대한 정보손실은 최소화하면서 저차원의 데이터로 차원을 축소 시키는 방법이다[9]. 즉, PCA를 통해 차원이 축소된 데이터는 기존 데이터의 분포를 최대한 보존한 데이터를 나타낸다. PCA를 통한 차원 축소 절차는 1) 입력데이터에 대한 공분산 행렬 생성, 2) 고유벡터, 고유값, 기여율 계산, 3) 누적 기여율에 따른 주성분 개수 결정, 4) 입력데이터 변환 순서로 진행된다.

PCA를 통한 차원 축소의 첫 번째 절차인 입력데이터에 대한 공분산 행렬은 식 (1)을 통해 생성된다.

$$A = \frac{1}{N-1} \mathbf{X}\mathbf{X}^T \quad (1)$$

여기서 N 은 데이터의 개수이며 \mathbf{X} 는 입력데이터를 표준화시킨 행렬이다.

이후, 생성된 공분산 행렬은 고윳값 분해를 통해 고유벡터와 고윳값으로 분해된다. 분해된 고윳값은 값이 큰 순서대로 배열되며, 이에 따라 해당하는 고유벡터가 계산된다. 계산된 고유벡터는 각각 서로 직교하며, 주성분으로 정의된다. 주성분의 총 개수는 입력데이터의 총 특징 수와 동일하다. 여기서 최종적으로 축소될 입력데이터의 차원 수, 즉, 주성분의 개수를 결정하기 위해서 각 고유벡터의 기여율을 계산해야 한다. 기여율은 해당 주성분이 전체 입력데이터 중에서 어느 정도의 비율을 설명할 수 있는지를 나타내며, 각 고유벡터의 기여율은 식 (2)를 통해 계산된다.

$$\alpha_j = \frac{\lambda_j}{\sum_{j=1}^m \lambda_j} \times 100\% \quad (2)$$

여기서 λ 는 고윳값이고, m 은 고윳값의 총 개수로 입력데이터의 차원 수와 동일하다.

각 고유벡터의 기여율을 식 (2)를 통해 계산했다면, 누적 기여율을 통해 주성분 개수를 결정한다. 본 논문에서는 누적 기여율이 95%일 때까지 포함된 주성분의 개수를 최종 주성분 수로 결정하였다. 그림 1은 각각 주성분에 대한 기여율을 도표로 나타내었으며, 파란색 선은 주성분에 따른 누적 기여율을 나타낸다. 최종적으로, 입력데이터의 차원을 최종 주성분 수로 축소시키는 데이터 변환이 수행된다.

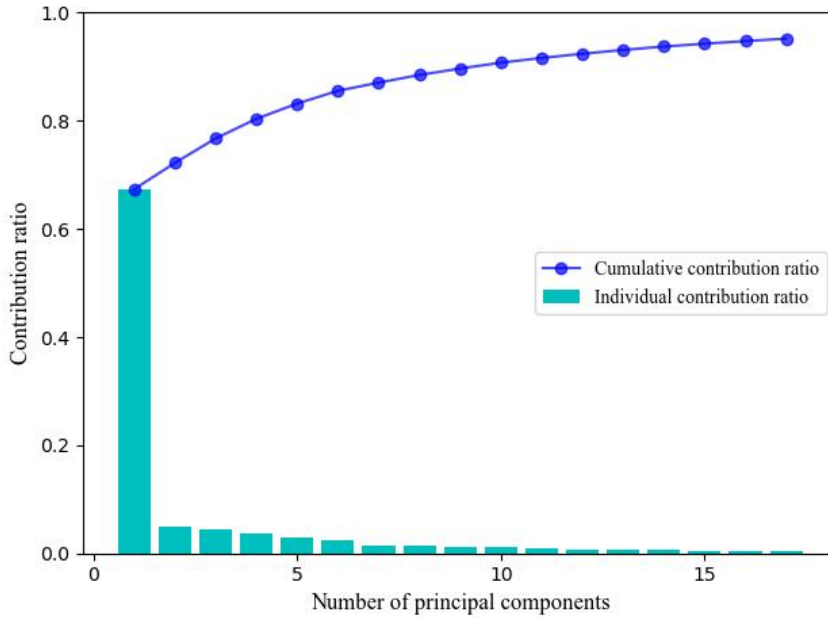


그림 1. 각 주성분에 따른 원시데이터의 분산 비율

제 2 절 LSTM

기존 순환신경망(RNN; Recurrent Neural Network)은 짧은 시계열에 대해서는 음성 인식, 번역, 주가 예측 등 다양한 분야에서 뛰어난 성능을 보였다. 하지만, 기존 RNN 방법은 긴 시계열에 대해 학습할 때 성능이 저하되는 장기 의존성 문제에 직면했다. 이러한 문제를 해결하기 위해서 LSTM이 도입되었다[10]. LSTM은 기존 RNN의 은닉층에 셀 상태를 추가하여 불필요한 정보를 삭제하고 필요한 정보를 기억하는 방법이다. 셀 상태는 망각, 입력, 출력 게이트를 통해서 업데이트되거나 유지된다. 다시 말해, LSTM은 추가된 게이트들을 통해 정보를 제어하기 때문에 기존 RNN보다 장기간 데이터 처리를 수행할 수 있다. LSTM의 기본 구조와 세부적인 은닉층은 그림 2와 3에 나타내었다.




그림 2. LSTM 구조

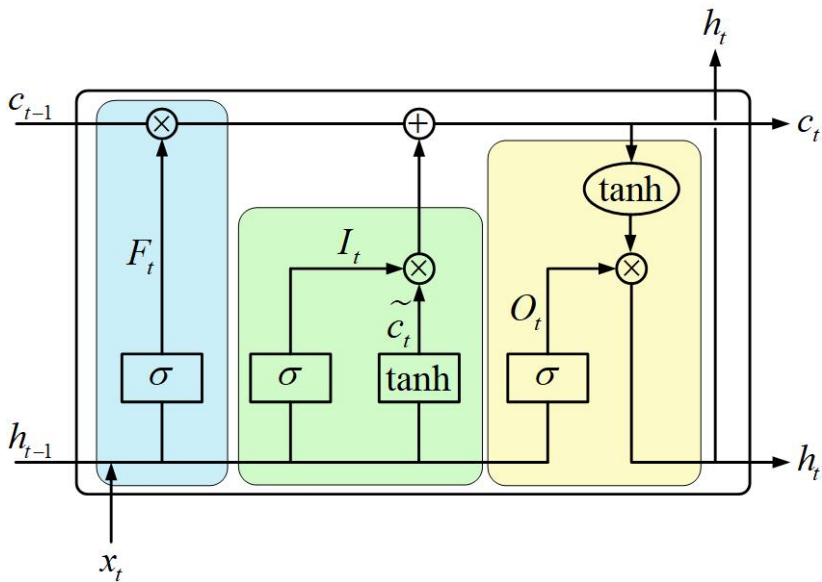


그림 3. LSTM 은닉층의 내부 구조

구체적으로 망각, 입력, 출력 게이트들은 각각 식 (3)~(5)를 통해 벡터 형태로 계산되고 계산된 값을 이용해 셀 상태 c_t 를 업데이트시킨다. 이전 은닉층의 은닉 상태 h_{t-1} 와 입력데이터 x_t 는 시그모이드 함수를 통해서 0과 1 사이의 값으로 계산되는데, 도출된 값은 정보 전달량의 척도를 나타낸다. 즉, 0에 가까울수록 입력된 정보를 거의 사용하지 않고, 1에 가까울수록 입력된 정보를 온전히 사용한다는 것을 의미한다.

그림 3의 파란색 부분인 망각 게이트는 이러한 특성을 통해 이전 정보를 기억할 것

인지 잊어버릴 것인지를 판별한다. 그림 3의 초록색 부분인 입력 게이트도 마찬가지로 시그모이드 함수를 통해 셀 상태에 업데이트할 입력데이터 값을 결정한다. 그리고, 식 (6)을 이용하여 현재 정보의 반영 정도를 결정하는 새로운 후보군을 생성하고, 입력 게이트 값과 합쳐져 셀 상태를 업데이트시킨다. 셀 상태는 식 (7)과 같이 망각 게이트와 입력 게이트를 통해서 업데이트된다. 마지막으로 그림 3의 노란색 부분인 출력 게이트는 업데이트된 셀 상태 중 은닉 상태로 출력시킬 값을 결정하기 위해서 입력데이터의 값을 결정한다. 출력 게이트의 결과값은 업데이트된 셀 상태와 결합하여 최종적으로 현재 시점의 은닉 상태를 도출한다. 은닉 상태를 결정짓는 식은 식 (8)과 같다.

$$F_t = \sigma(W_F \cdot [h_{t-1}, x_t] + b_F) \quad (3)$$

$$I_t = \sigma(W_I \cdot [h_{t-1}, x_t] + b_I) \quad (4)$$

$$O_t = \sigma(W_O \cdot [h_{t-1}, x_t] + b_O) \quad (5)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

$$c_t = F_t \circ c_{t-1} + I_t \circ \tilde{c}_t \quad (7)$$

$$h_t = O_t \circ \tanh(c_t) \quad (8)$$

여기서 W 와 b 는 학습 가능한 매개변수이며, 각각 가중치와 바이어스를 의미한다. 그리고 \cdot 는 일반적인 행렬 곱셈을 의미하며, \circ 는 각 요소별 곱셈을 의미한다.

본 논문에서 LSTM은 입력데이터의 시간 종속성을 학습하여 다단계 예측을 수행하기 위해 적용되었다. 그리고 LSTM의 출력 벡터를 의미하는 LSTM unit을 32, 64, 128, 256 등으로 변경해가며 성능을 평가하였으며, 경험적으로 LSTM unit이 64일 때를 최적의 LSTM unit으로 결정하였다.

제 3 절 Attention mechanism

기계 번역에서 주로 사용되는 Sequence to Sequence 모델은 Encoder-Decoder 모델으로도 불리며, 입력 및 출력 시퀀스의 길이에 제약받지 않고 Encoder 부분에서 입력 시퀀스를 하나의 Context 벡터로 압축시켜준 뒤 이를 이용하여 Decoder 부분에서 출

력 시퀀스를 도출하는 방법이다[11]. Encoder-Decoder 방법은 Encoder에서 하나의 Context 벡터로 모든 입력 시퀀스에 대한 정보를 압축시킨 후 Decoder를 통해 예측을 수행하기 때문에 정보손실이 발생할 수 있다. 따라서 이를 방지하기 위해서 Attention mechanism[12]이 등장하였다.

Attention mechanism은 RNN 계열의 방법론이 학습될 때 시간 단계(Time step)만큼 쌓인 입력데이터에서 예측해야 할 대상과 관련된 특정 시간에 더 가중치를 높여 혼련시키는 방법이다. 즉, 기존 Encoder-Decoder에서 입력데이터에 대한 정보를 하나의 벡터로 압축시키는 대신에, Decoder를 통해 예측하는 매 시점마다 입력데이터에 대한 정보를 모든 시퀀스에서 동일한 비중이 아닌 예측 대상과 관련된 시퀀스마다 비중을 다르게하여 예측을 수행하는 방법이다. 본 논문에서는 LSTM의 예측성능을 향상시키기 위해서 Attention mechanism을 적용하였다.

Attention mechanism의 절차는 Attention score, Attention weight, Attention value, Attention vector 계산 순서로 진행된다. 그림 4는 Attention mechanism이 적용된 Encoder-Decoder의 구조를 나타낸 그림이다.

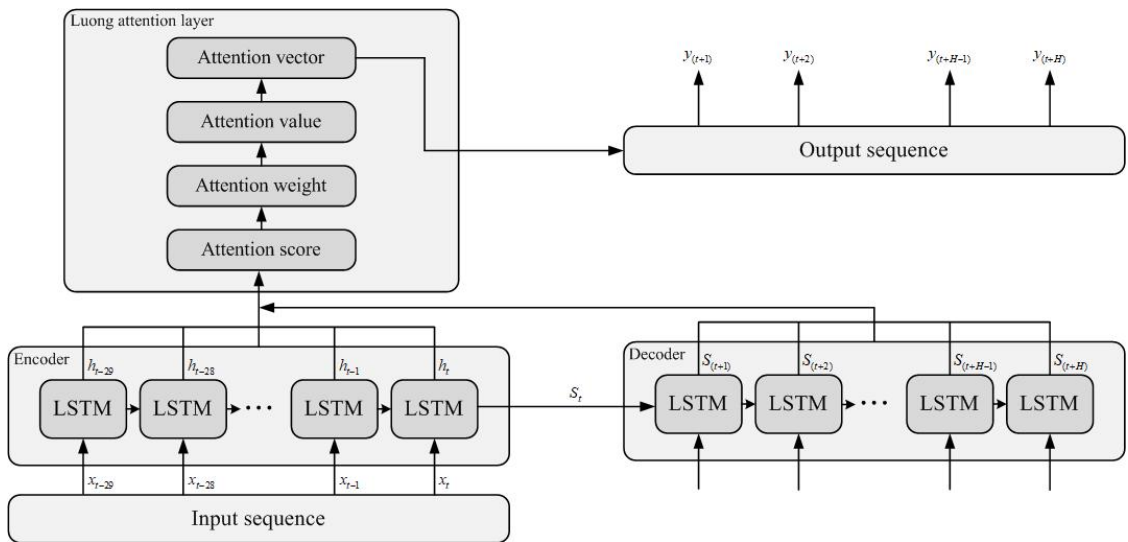


그림 4. Attention mechanism이 적용된 Encoder-Decoder 구조

그림 4에 나타난 Attention mechanism 절차를 구체적으로 설명하자면, 우선 Luong의 dot product Attention[13]을 사용하여 입력데이터의 시간 단계별로 Attention score를 계산한다. Luong의 dot product를 이용한 Attention score는 식 (9)를 통해서 계산된다.

$$score(S_{(t+1)}, h_i) = S_{(t+1)}^T \cdot h_i, (i = 1, 2, 3, \dots, t) \quad (9)$$

여기서 $S_{(t+1)}$ 과 h_i 는 각각 예측 대상의 특정 시간에 대한 은닉 상태와 입력데이터에 대한 은닉 상태를 나타낸다.

그 후, 식 (9)를 통해 계산된 Attention score를 기반으로 소프트맥스(softmax) 함수를 이용하여 시간 단계별 Attention weight를 계산한다. Attention weight는 i 번째 은닉 상태(h_i)가 예측하고자 하는 대상과 얼마나 연관성이 있는지를 0과 1사이의 값으로 나타낸 정규화된 값이며, Attention weight의 총합은 1이 된다. 이후, Attention weight와 은닉 상태 h_i 를 가중 합하여 Attention value를 도출한다. 식 (10)과 식 (11)은 Attention weight와 Attention value의 계산 식을 나타낸다.

$$\alpha_{(t+1),i} = softmax(score(S_{(t+1)}, h_i)) = \frac{\exp(score(S_{(t+1)}, h_i))}{\sum_{i=1}^t \exp(score(S_{(t+1)}, h_i))} \quad (10)$$

$$z_{(t+1)} = \sum_{i=1}^t \alpha_{(t+1),i} \cdot h_i \quad (11)$$

최종적으로, Attention value와 예측하고자 하는 대상에 대한 은닉 상태($S_{(t+1)}$)를 합하여 계산된 Attention vector를 통해 최종 출력인 가압기 수위 및 압력의 다단계 예측이 수행된다.

제 4 절 MIMO 전략

여러 시간 단계에 대한 입력데이터를 기반으로 특정 지표(H)까지 예측을 수행하는

다단계 예측은 재귀, 직접, MIMO 전략 등 다양한 전략 방법이 있다[14]. 간략하게, 재귀 전략은 한 단계 앞선 예측을 목적으로, 단일 모델이 훈련되고 다단계 예측을 수행할 때 예측된 값이 다음 단계 예측 시 입력으로 누적되어 적용되는 방법이다. 그리고 직접 전략은 재귀 전략과 동일하게 단일 단계 예측을 수행하지만, 동일한 입력데이터를 기반으로 예측하고자 하는 특정 지표 개수만큼 예측 모델을 구축하는 방법이다. 또한, 본 논문에서 적용한 MIMO 전략은 앞서 설명한 전략들과 다르게 단일 모델을 이용하여 다단계 예측을 수행하는 방법이다. 즉, MIMO 전략은 단일 단계를 예측하는 재귀와 직접 전략과 달리 다단계 예측을 통해서 예측값 간의 시계열 종속성을 보존할 수 있으며, 재귀 전략의 단점인 예측 오류의 누적 문제를 해결할 수 있고 여러 모델을 개발해야 하는 직접 전략의 문제를 해결할 수 있다.

MIMO 전략은 식 (12)로 표현되고, 입력 및 출력 데이터의 시간 단계는 사용자가 직접 설정해야 하는 변수로써 그림 5에서 각각 초록색과 노란색 바를 나타낸다. 그림 5는 30 step 데이터를 기반으로 이후 특정 시간(H)까지를 예측하는 것을 보여준다. 본 논문에서는 비정상 상태에서 운전원이 적시에 상황 인지 및 조치를 취할 수 있도록 운전원에게 빠르고 정확하게 정보를 전달해야 하므로 입력데이터의 시간을 30 step으로 설정하였다. 그리고 특정 시간에 해당하는 예측 단계를 60, 120, 180 step으로 설정하여 예측을 수행하였다.

$$\{y_{t+1}, y_{t+2}, \dots, y_{t+H}\} = f_{MIMO}(x_{t-29}, x_{t-28}, \dots, x_t) \quad (12)$$

여기서 x_t 는 시간이 t 일 때의 입력데이터이고, $\{y_{t+1}, y_{t+2}, \dots, y_{t+H}\}$ 는 MIMO 전략을 통해 나온 예측 결과이다.

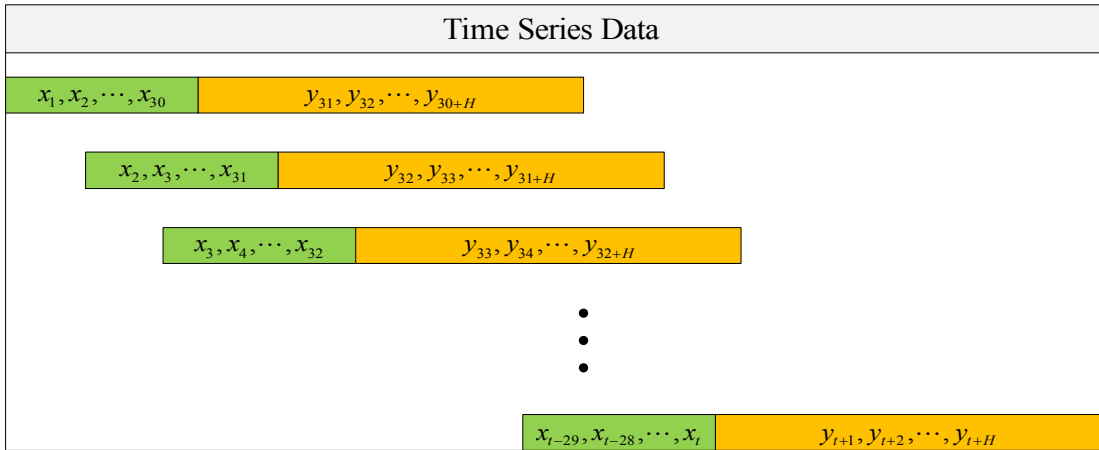


그림 5. MIMO 전략 적용을 위한 데이터 도식화

제 5 절 다단계 예측 절차 및 최적화

본 절에서는 제안된 인공지능 모델의 데이터 처리 및 전체 구조에 관해 설명하고자 한다. 우선 인공지능 모델 적용을 위해 데이터 수집을 수행해야 한다. 수집된 데이터는 수많은 변수 및 변수별로 각기 다른 척도를 지니기 때문에, 데이터 전처리를 통해 인공지능 모델 학습에 적합한 데이터로 변환된다. 이후, LSTM과 Attention mechanism을 통해 다단계 예측이 수행된다. 제안된 인공지능 모델의 최적화는 hyper-parameter를 최적화하기 위해서 adam optimizer를 사용하였고, 평균제곱오차(MSE; Mean Squared Error)를 손실 함수(비용 함수)로 사용하였다. 그리고 학습 중 과적합을 방지하면서 최적의 모델을 선정하기 위하여 조기 종료(early stopping) 기능을 적용하였다. 조기 종료 기능은 모델 훈련 중 검증 데이터에 대한 손실 함숫값이 사용자가 지정한 특정 횟수 이상 최적값보다 낮아지지 않으면 훈련이 종료되는 기능이다.

그림 6은 학습 횟수에 따른 훈련과 검증 데이터에 대한 손실 함숫값을 나타낸 그래프로, 조기 종료 기능이 적용되어 훈련 횟수가 약 320번일 때 훈련이 종료된 것을 나타낸다. 본 논문에서는 전체 훈련 횟수를 500으로 설정하고 검증 데이터에 대한 손실 함숫값이 최적값에서 50번 이상 낮아지지 않을 때 학습이 종료되도록 설정하여 학습을 진행하였다. 즉, 그림 6에서는 훈련 횟수가 약 270번일 때 검증 데이터에 대한 손실 함숫값이 최소이고 이후 50번의 학습이 진행되는 동안 손실 함숫값이 증가하지 않아서

모델 학습이 종료된 것을 나타낸다.

최종적으로 조기 종료 기능을 통해 결정된 최적 모델을 이용하여 예측 결과를 도출하였다. 그림 7은 본 논문에서 제안한 인공지능 모델 적용을 위한 데이터 전처리 및 인공지능 모델의 다단계 예측 절차를 나타낸 그림이다. 데이터 전처리에는 표준화, PCA를 통한 차원 축소, LSTM의 입력데이터 형태인 3차원 형태로의 데이터 변환 과정이 포함된다. 데이터 전처리 과정 후, 변환된 3차원 데이터를 기반으로 LSTM과 Attention mechanism을 통해 다단계 예측을 수행하게 된다.




그림 6. 학습 횟수에 따른 손실 함숫값

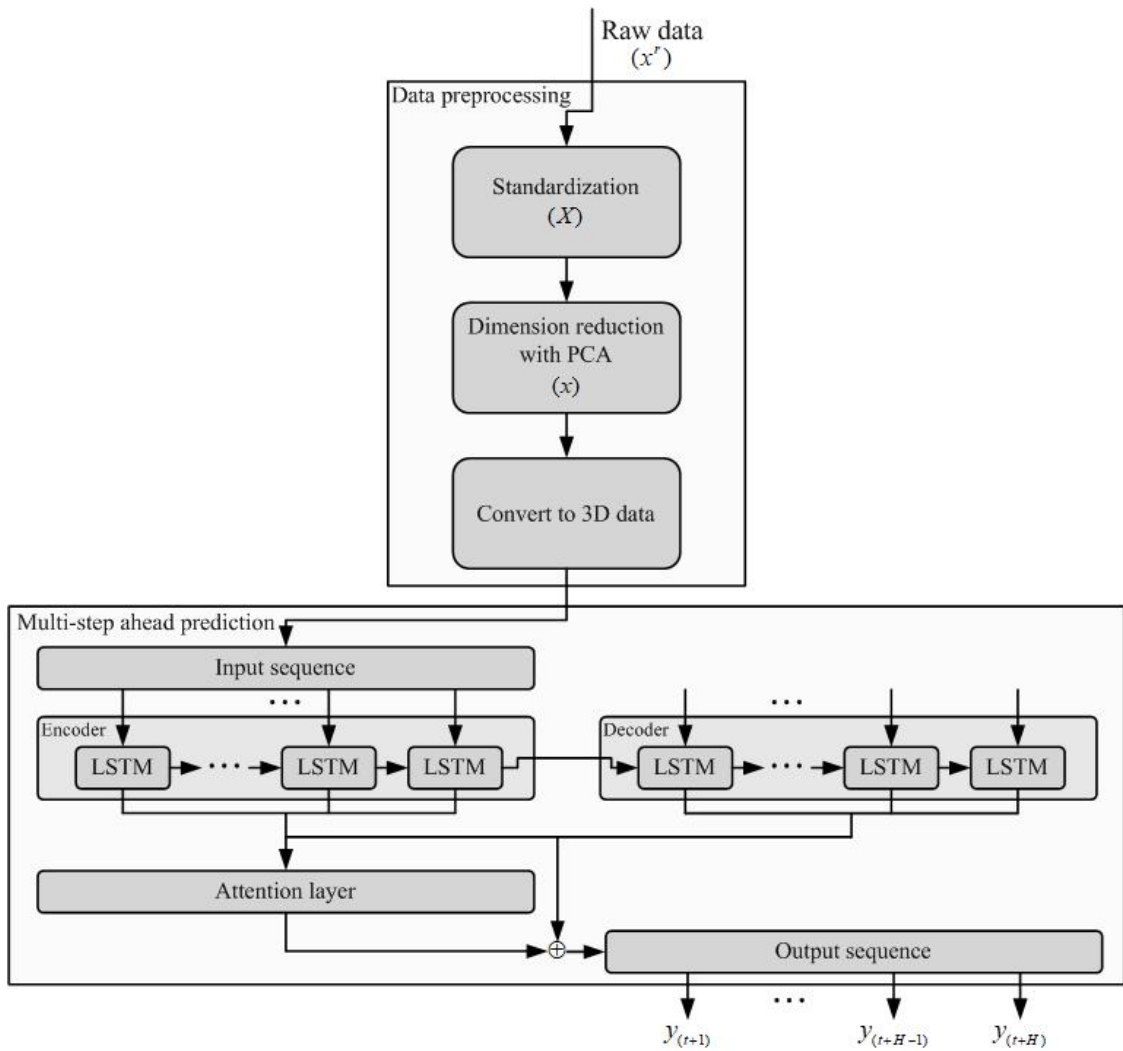


그림 7. 제안된 인공지능 모델의 다단계 예측 절차

제 3 장 데이터 수집 및 전처리

앞서 2장에서 설명한 알고리즘 및 인공지능 방법론을 적용하여 원자로 트립변수를 예측하는 모델을 개발하기 위해서 우선 비정상 시나리오 선정, 데이터 수집, 데이터 전처리를 수행해야 한다. 따라서 해당 장에서는 데이터 수집 및 전처리에 대해 설명하고자 한다.

제 1 절 데이터 수집

현재 원자력발전소의 가동 시간이 증가함에 따라 기기 노후화에 의해 비정상 상태 발생빈도가 증가하고 있다. 따라서 본 논문에서는 주로 비정상 상태 발생을 유발하는 원인인 계측기 고장, 기기 상태 이상, 배관 파단으로 인한 누설으로 카테고리를 분류하고, 카테고리 내에서 가압기 수위 및 압력과 관련성이 높은 비정상 시나리오 위주로 시나리오를 선정하였다.

선정된 비정상 시나리오에 대한 데이터는 3-loop의 Westinghouse-993MWe를 참조로 설계된 CNS[8]를 통해서 수집하였다. CNS를 통해 데이터를 수집할 때 원자로 트립이 발생하지 않는 시나리오는 30분까지 데이터를 취득하였으며, 30분 이전에 원자로 트립이 발생한 시나리오는 트립 발생 이후 10분까지의 데이터를 취득하였다. 또한, 데이터는 매초 단위로 수집되었다. CNS를 통해 수집된 비정상 시나리오 및 데이터 개수는 표 1에 나타내었다. 전체 데이터에서 인공지능 모델의 학습, 최적 모델 선정, 평가를 위해서 데이터를 훈련, 검증, 테스트 데이터로 구분하였다. 검증 데이터와 테스트 데이터의 개수는 각각 전체 데이터 중에서 무작위로 10%를 추출하였으며 나머지 데이터를 훈련 데이터로 사용하였다.

표 1. 수집된 비정상 시나리오

No.	시나리오 명	훈련 데이터 개수	검증 데이터 개수	테스트 데이터 개수	총 개수
1	가압기 압력채널 고장 - 고	11	2	2	15
2	가압기 수위채널 고장 - 고	12	2	2	16
3	가압기 수위채널 고장 - 저	11	2	2	15
4	제어봉의 지속적인 삽입	6	1	1	8
5	가압기 *PORV 열림	41	5	5	51
6	가압기 안전밸브 고장	36	5	5	46
7	가압기 살수밸브 고장 - 열림	56	7	7	70
8	재생열교환기 진단부위 파열	40	5	5	50
9	*CVCS에서 1차 기기냉각수 계통으로 누설	40	5	5	50
10	충진수 유량조절밸브 후단 누설	34	4	4	42
11	*RCS에서 1차 기기냉각수 계통으로 누설	7	1	1	9
12	증기발생기 전열관 누설	7	1	1	9

*PORV: Power-Operated Relief Valve

*CVCS: Chemical and Volume Control System

*RCS: Reactor Coolant System

제 2 절 데이터 전처리

가압기 수위와 압력의 다단계 예측을 위해서 수행한 데이터 전처리는 그림 7에 대략적으로 나타내었지만, 더 세부적인 데이터 전처리 절차를 그림 8에 나타내었다. 우선 수집된 데이터를 기반으로 입력변수를 선정한다. 본 논문에서 CNS를 통해 수집된 데이터는 총 2,257개 변수를 지닌 시계열 데이터이며, 해당 변수들 중에서 피어슨 상관관계수[15] 방법을 적용하여 가압기 수위와 압력과 관련된 변수들을 입력변수로 선정하였다.

피어슨 상관관계수란 데이터 간의 선형 관계를 측정하기 위해 일반적으로 사용되는 상관관계 분석 방법이다. 즉, 분석하고자 하는 변수와 다른 변수 간에 피어슨 상관관계수 값을 계산하여 서로 연관되어 있는지 상관관계를 분석한다. 피어슨 상관관계수 값은 -1과 1 사이의 값으로 계산되며, -1에 가까울수록 강한 음의 선형 상관관계에 해당하고 1에 가까울수록 강한 양의 선형 상관관계에 해당한다. 그리고 0은 두 데이터 간의 관계가 없음을 의미한다. 본 논문에서는 피어슨 상관관계수 값이 0인 변수와 알람 및 원자로 트립 변수를 제외한 변수들을 일차적인 입력변수로 선정하였다. 그리고 선정된 입력변수 내에서 변수를 변경해가며 인공지능 모델을 학습하고 모델의 성능 비교를 통해 최종적으로 235개의 변수가 입력변수로 선정되었다.

이후, 인공지능 모델을 효과적으로 학습시키기 위한 수단 중 하나인 데이터 정규화를 수행한다. 본 논문에서는 다양한 정규화 방법 중에서 표준화 방법을 사용하여 데이터를 변환하였다. 표준화는 평균이 0이고 분산이 1인 데이터로 변환시켜주는 방법이다. 표준화는 식 (13)을 통해 수행된다. 이때 평균과 표준편차는 훈련 및 검증 데이터를 기반으로 계산된다.

$$\mathbf{X} = \frac{x^r - \overline{x^r}}{\phi} \quad (13)$$

여기서 $\overline{x^r}$ 는 데이터의 특징별 평균값을 의미하고, ϕ 는 특징별 표준편차를 의미한다.

최종적으로 표준화를 통해 변환된 입력데이터는 PCA를 통한 차원 축소 후에 시계열 데이터 처리를 통해 3차원 형태로 변환된다. 즉, 인공지능 모델 학습을 위한 최종적

인 입력데이터 형태는 샘플 수, Time step, PCA 후 축소된 차원 수로 구성된 3차원 형태이다. 본 논문에서는 PCA를 통해서 235개의 특징수를 지닌 입력데이터를 17개의 특징을 지닌 데이터로 축소시켰으며, Time step을 30 step으로 설정하여 3차원 형태의 데이터로 변환시켰다.

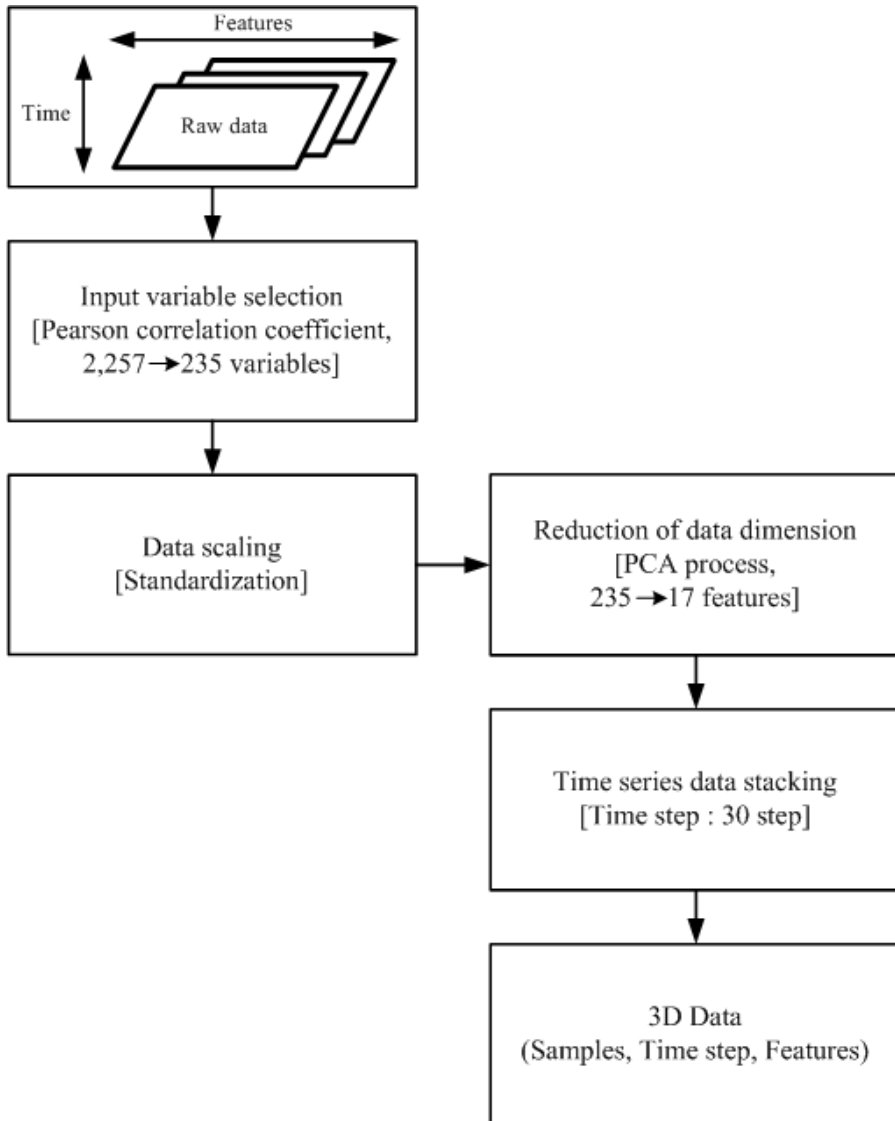


그림 8. 데이터 전처리 세부 절차

제 4 장 트립변수 예측 결과

본 논문에서 개발된 인공지능 모델은 일반적으로 회귀모델 평가에 많이 사용되는 평가지표인 평균제곱근오차(RMSE; Root Mean Squared Error), R Square (R^2), 그리고 최대오차를 통해 평가되었다. 각 평가지표는 식 (14)~(16)을 통해 계산된다. RMSE와 최대오차는 실제값과 예측값의 차이를 기반으로 계산되기 때문에 값이 작을수록 예측 모델의 예측성능이 좋은 것을 의미한다. 그리고 R^2 는 결정된 회귀식이 주어진 데이터를 얼마나 잘 표현하는지를 나타내는 지표로써, 실제값과 예측값의 분산을 기반으로 계산되기 때문에 0과 1 사이의 값을 가진다. 즉, R^2 의 값이 1에 가까운 값일수록 결정된 회귀식이 주어진 데이터를 정확하게 설명할 수 있다는 것을 의미하며, 예측 모델의 성능이 좋다는 것을 의미한다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N \left(\frac{y_k - \hat{y}_k}{y_{k,\max}} \times 100\% \right)^2} \quad (14)$$

$$R^2 = \frac{\text{예측값의 분산}}{\text{실제값의 분산}} = 1 - \frac{\sum_{k=1}^N (y_k - \hat{y}_k)^2}{\sum_{k=1}^N (y_k - \bar{y})^2} \quad (15)$$

$$E_{\max} = \max \left| \frac{y_k - \hat{y}_k}{y_{k,\max}} \times 100\% \right| \quad (16)$$

여기서 y_k 와 \hat{y}_k 는 각각 실제값과 예측값을 의미하며, $y_{k,\max}$ 는 실제값 중에서 가장 큰 값인 최댓값을 의미한다. 본 논문에서는 가압기 수위 및 압력의 최댓값을 100(%)와 17,000,000(Pa)으로 설정하였다. 그리고 \bar{y} 는 실제값에 대한 평균값을 의미한다.

표 2는 개발된 인공지능 모델의 훈련, 검증, 테스트 데이터에 대한 가압기 수위 및 압력 예측 결과를 보여준다. 원자로 트립을 유발하는 변수의 거동 예측은 정확하면서 긴 시간을 예측하는 것이 중요하다. 그러나, 특정 입력 시간을 기반으로 장기간의 예측

단계를 예측하는 것은 한계가 있기 때문에, 예측 단계를 점차 늘려가며 현재 입력 시간 단계에 대한 적절한 예측 단계를 탐색해 보았다. 이에 따라 일반적으로 예측 단계가 증가함에 따라서 예측 오차가 증가하는 현상을 확인하였다. 또한, 표 2의 예측 결과를 통해서 가압기 수위보다 압력을 예측할 때 예측 오차가 더 낮은 것을 확인할 수 있다. 이는 입력변수를 선정할 때 상관관계 분석을 수행한 결과, 가압기 수위보다 압력과 관련된 변수들이 훨씬 많은 것으로 인해 발생한 것으로 판단된다.

표 2에서 예측 단계가 60과 120 step일 때 훈련 및 검증 데이터에 대한 RMS 오차와 최대오차가 각각 0.27%와 9.2% 내의 오차를 보여주었으나, 예측 단계가 180 step일 때는 RMS 오차와 최대오차가 0.32% 및 23%를 보여주었다. 즉, 180 step을 예측할 때 60 및 120 step보다 큰 예측 오차를 보여주었다. 테스트 데이터에 대한 예측 결과에서 최대오차는 앞서 언급한 예측 단계가 증가함에 따라 오차가 증가하는 경향을 보여주었으나, RMS 오차 측면에서 120 step이 다른 예측 단계보다 다소 큰 오차를 보여주었다. 따라서, 최종적으로 훈련, 검증, 테스트 데이터에 대한 예측 결과를 기반으로 인공지능 모델의 정밀도 및 정확도를 고려하였을 때 120 step이 가장 적절한 예측 단계로 판단된다.

표 2. LSTM with Attention mechanism을 이용한 예측 결과

예측 대상	예측 단계	훈련 데이터		검증 데이터		테스트 데이터	
		RMSE (%)	E_{max} (%)	RMSE (%)	E_{max} (%)	RMSE (%)	E_{max} (%)
가압기 수위	60 step	0.111	6.656	0.205	7.829	0.222	11.856
	120 step	0.159	8.767	0.268	8.436	0.255	12.683
	180 step	0.167	22.808	0.322	8.755	0.242	13.048
가압기 압력	60 step	0.087	6.533	0.183	7.038	0.172	8.239
	120 step	0.120	9.156	0.233	7.664	0.204	8.421
	180 step	0.125	12.493	0.273	7.119	0.192	8.680

그림 9는 가압기 수위 및 압력 거동 예측에서 테스트 데이터를 기반으로 예측 단계가 60 step일 때 예측 단계에 따른 RMS 오차를 나타낸 그림이다. 주황색 선은 가압기 수위를 예측할 때의 예측 단계에 따른 RMS 오차를 나타내며, 파란색 선은 가압기 압력을 예측할 때의 예측 단계에 따른 RMS 오차를 나타낸다. 해당 그림에서 가압기 수위 및 압력 거동 예측시 초반에는 RMS 오차가 다소 발생하였지만, 이후 예측 오차가 점차 증가하는 것을 확인할 수 있다. 즉, 그림 9를 통해서도 앞서 설명했던 예측 단계가 증가함에 따라 예측 오차가 증가하는 경향을 확인할 수 있다.

그림 10은 모든 예측 단계(60, 120, 180 step)에서의 가압기 수위 및 압력 거동 예측에 대한 비정상 시나리오별 RMS 오차를 나타낸 그림이다. 대부분의 비정상 시나리오에서는 RMS 오차가 0.5% 미만의 오차를 보이고 있으나, RCS에서 1차 기기냉각수 계통으로 누설 시나리오에서 RMS 오차가 1% 이상으로 다소 높게 발생한 것을 확인할 수 있다. 해당 시나리오는 수집할 수 있는 데이터 개수도 제한될 뿐만 아니라 비정상 발생 후 빠른 시간 이내에 원자로 트립이 발생하는 것으로 인해 데이터 길이가 상대적으로 다른 시나리오보다 짧기 때문으로 판단된다.

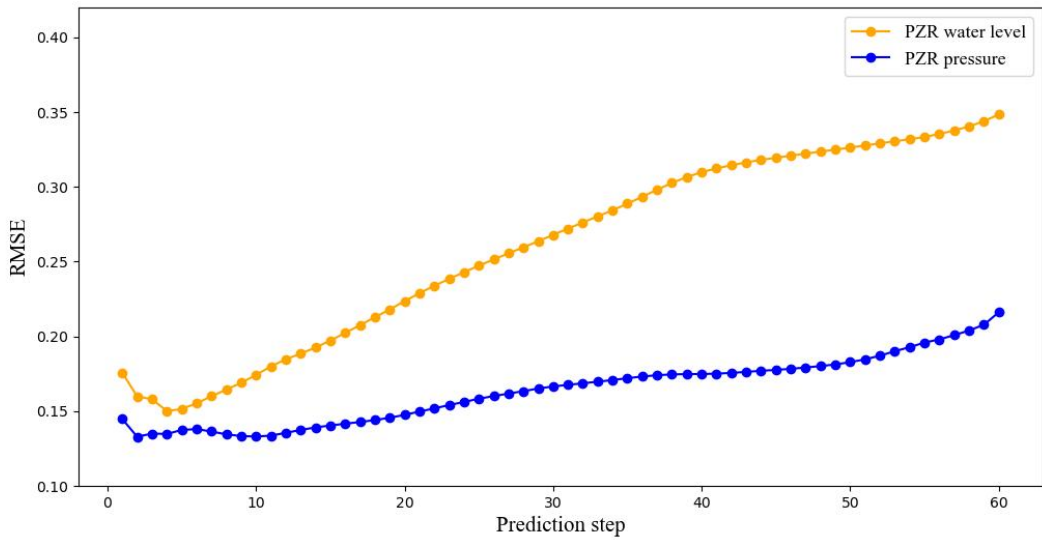


그림 9. 예측 단계에 따른 RMS 오차

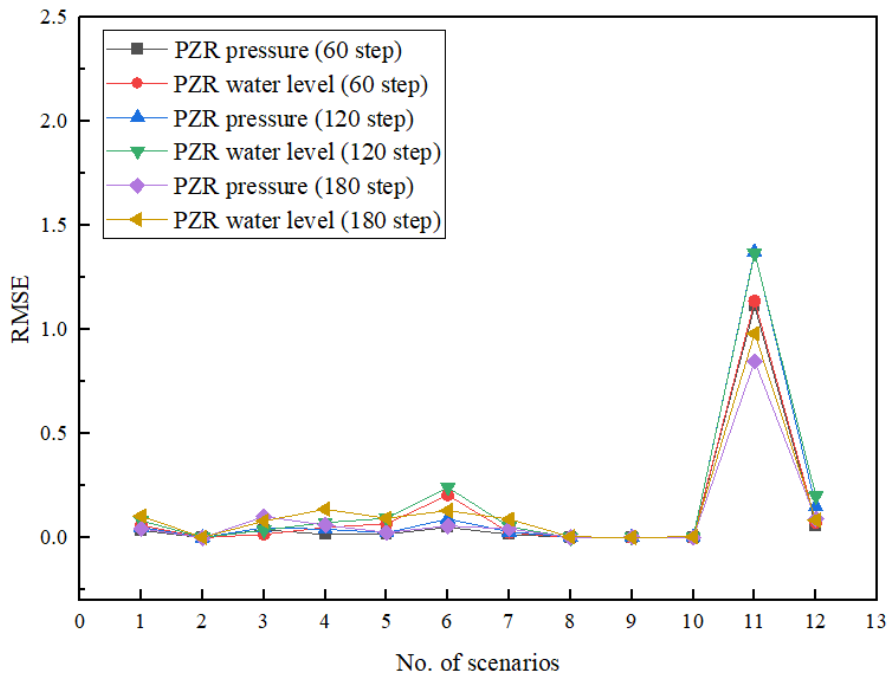
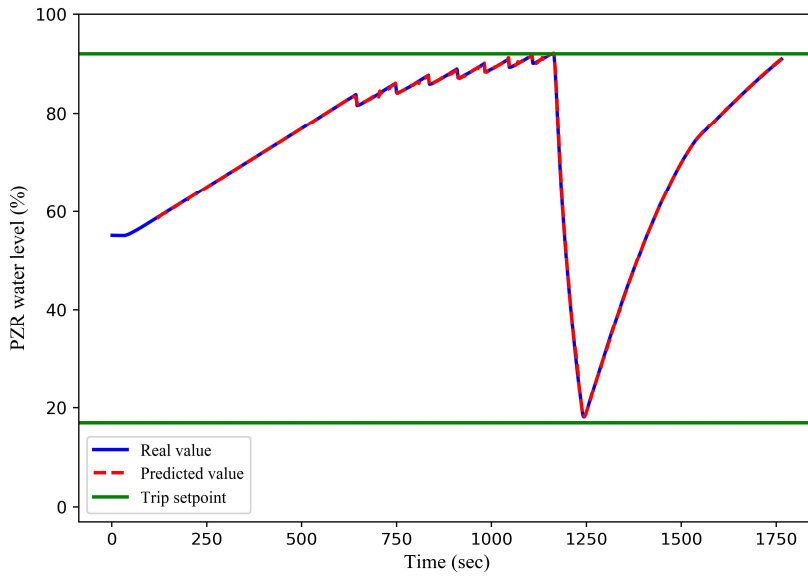


그림 10. 비정상 시나리오별 RMS 오차


다음은 표 1에 나타낸 비정상 시나리오 중 RMS 오차가 낮은 비정상 시나리오와 높은 시나리오에서 가압기 수위 및 압력 거동을 예측한 결과와 각 시나리오 발생시 증상, 자동 동작 사항 등에 대해 간략하게 설명하고자 한다. 우선 RMS 오차가 낮은 시나리오 중 하나인 “가압기 수위채널 고장 - 저” 시나리오에서 모든 예측 단계(60, 120, 180 step)에 대해 가압기 수위 및 압력 거동 예측 결과는 그림 11~13에 나타내었다.

“가압기 수위채널 고장 - 저” 시나리오는 가압기 수위채널에 이상이 발생하여 계측치가 실제 수위와 다르게 저수위로 고정되어 나타내는 시나리오이다. 해당 시나리오는 계측기 지시치가 저수위를 가리키므로 비정상 상태 발생 초반에는 RCS에 냉각재를 채워주기 위해 충전 유량이 증가하게 된다. 그러나, 실제 가압기 수위는 저수위가 아니라 정상 범위에 해당하므로 실제 수위는 지속적으로 증가하게 된다. 이후 가압기 수위의 지속적인 증가로 인해 가압기 수위가 원자로 트립 설정치에 도달하여 원자로 트립이 발생하게 된다. 가압기 수위로 인한 원자로 트립 설정치는 저수위일 때 17%이며, 고수위일 때 92%에 해당한다. 그리고 가압기 압력으로 인한 원자로 트립 설정치는 저압력에서 약 $13,400,000\text{Pa}(136\text{kg}/\text{cm}^2)$, 고압력에서 약 $16,700,000\text{Pa}(167\text{kg}/\text{cm}^2)$ 이다. 원자로 트립 발생 이후 안전주입작동 신호 발생 설정치까지 가압기 압력이 떨어지게 되면, 안전주입계통이 동작하게 되어 RCS에 고농도의 붕산수를 공급해줌으로써 가압기 수위 및 압력이 증가하게 된다.

그림 11~13에서 가압기 수위 및 압력의 거동은 앞서 언급한 비정상 시나리오 발생 절차와 동일하게 수위 및 압력이 증가하다가 원자로 트립으로 인한 감소 후 다시 증가하는 경향을 확인할 수 있다. “가압기 수위채널 고장 - 저” 시나리오에 대한 가압기 수위 및 압력 거동 예측 결과는 모든 예측 단계에서 정확하게 예측하는 것을 확인할 수 있다.

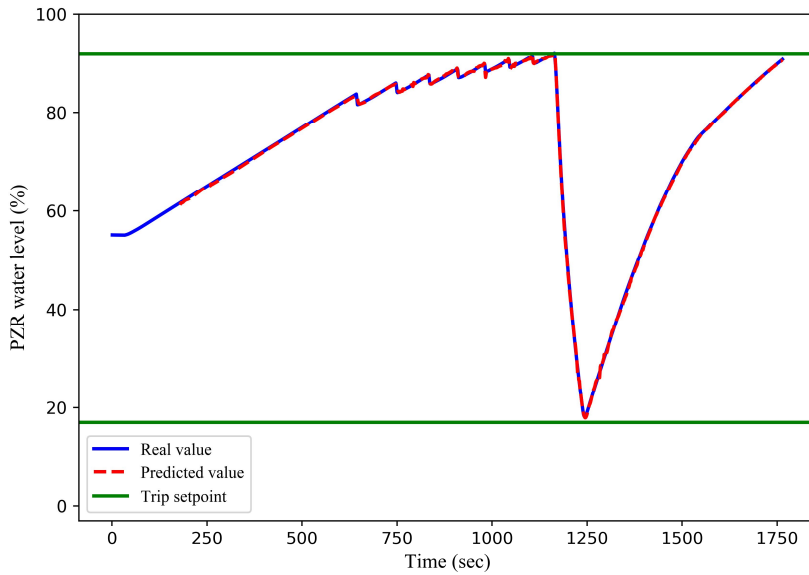


(a) 가압기 수위 예측 결과

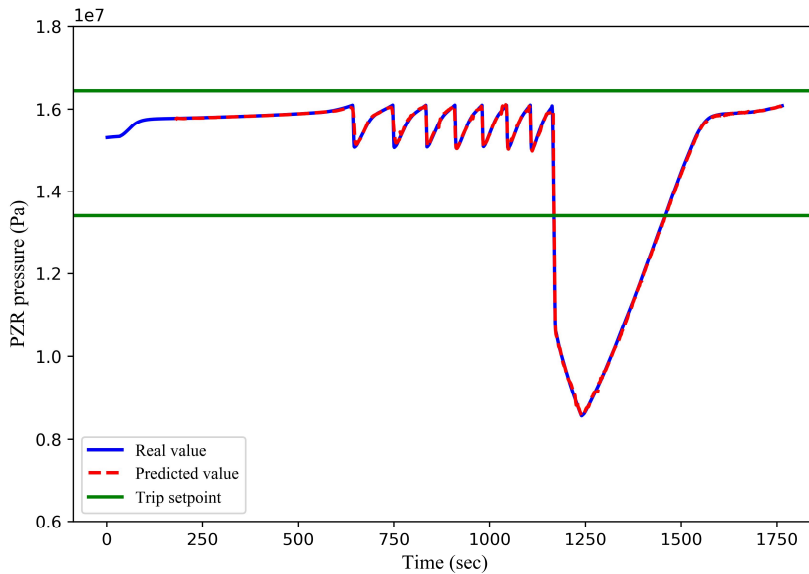


(b) 가압기 압력 예측 결과

그림 11. 예측 단계가 60 step일 때 예측 결과 (가압기 수위채널 고장 - 저)




(a) 가압기 수위 예측 결과




(b) 가압기 압력 예측 결과

그림 12. 예측 단계가 120 step일 때 예측 결과 (가압기 수위채널 고장 - 저)



(a) 가압기 수위 예측 결과




(b) 가압기 압력 예측 결과


그림 13. 예측 단계가 180 step일 때 예측 결과 (가압기 수위채널 고장 - 저)

그림 14~16은 “RCS에서 1차 기기냉각수 계통으로 누설” 시나리오에서 모든 예측 단계(60, 120, 180 step)에 대해 가압기 수위 및 압력 거동 예측 결과를 나타낸다. “RCS에서 1차 기기냉각수 계통으로 누설” 시나리오는 누설 시나리오이기 때문에 초반에 가압기 수위 및 압력이 감소하게 되고, 이와 더불어 체적제어탱크의 수위가 감소하게 된다. 이때, 운전원은 가압기 수위 감소를 방지하기 위하여 충전펌프를 기동시켜 충전 유량을 증가시켜야 한다. 또한, 가압기 압력 조절이 필요할 경우 보조 전열기를 수동으로 작동시켜야 한다. 본 논문에서는 운전원의 조치사항이 포함되지 않은 데이터를 기반으로 가압기 수위 및 압력 거동을 예측하였기 때문에 그림 14~16에서 해당 변수들은 지속적으로 감소하다가 원자로 트립 설정치에 도달하여 원자로 트립이 발생하는 것을 보여준다,

그림 14~16의 가압기 수위 및 압력의 거동은 꾸준히 감소하다가 원자로 트립 설정치에 도달하여 원자로 트립이 발생한 후, 마찬가지로 안전주입계통이 동작하여 가압기 수위 및 압력이 다시 증가하는 경향을 보인다. 그림 14의 예측 단계가 60 step일 때는 오차가 다소 발생하지만, 경향성은 잘 따라가는 것을 확인할 수 있다. 그림 15의 예측 단계가 120 step일 때는 전반적으로는 60 step을 예측할 때보다 정확도는 더 높지만, 특정 부분에서 진동이 발생하는 것을 확인할 수 있다. 그리고 마지막으로 그림 16의 예측 단계가 180 step일 때는 전반적으로 오차가 다소 발생하며 특정 부분에서 진동이 발생하는 것을 확인할 수 있다.




(a) 가압기 수위 예측 결과

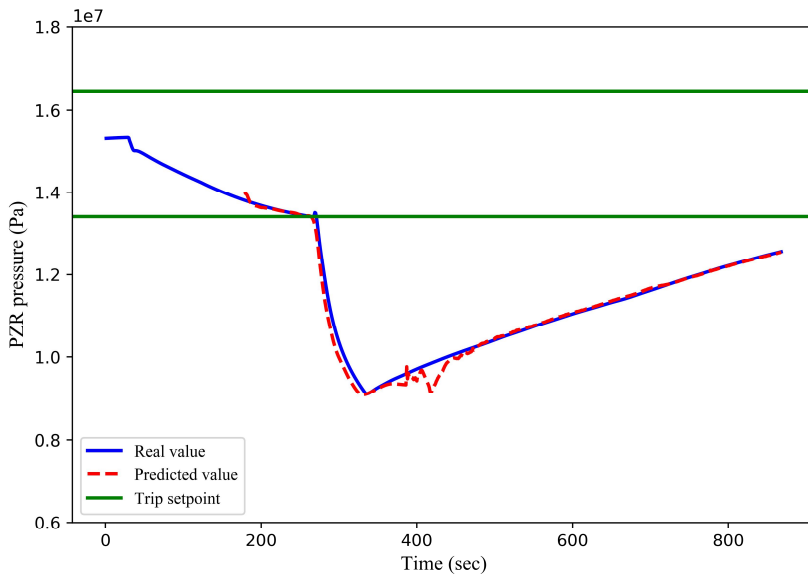


(b) 가압기 압력 예측 결과

그림 14. 예측 단계가 60 step일 때 예측 결과 (RCS에서 1차 기기냉각수 계통으로 누설)




(a) 가압기 수위 예측 결과

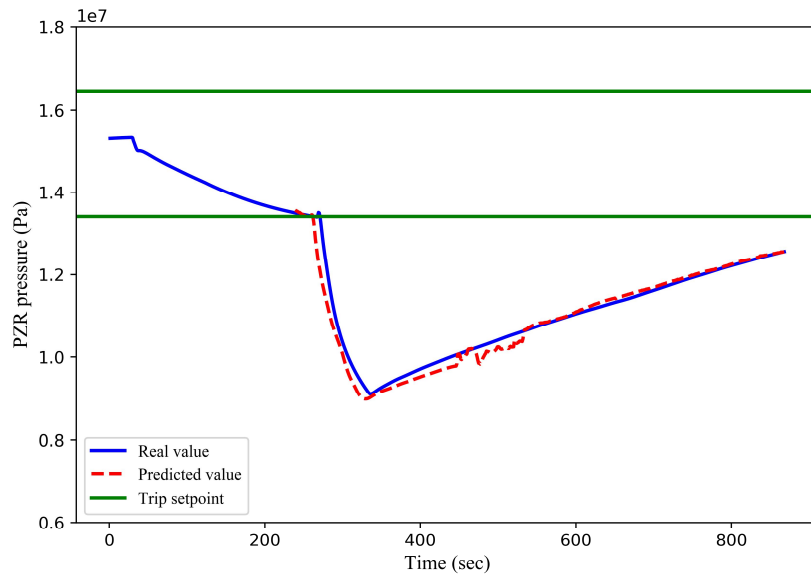


(b) 가압기 압력 예측 결과

그림 15. 예측 단계가 120 step일 때 예측 결과 (RCS에서 1차 기기냉각수 계통으로 누설)



(a) 가압기 수위 예측 결과



(b) 가압기 압력 예측 결과

그림 16. 예측 단계가 180 step일 때 예측 결과 (RCS에서 1차 기기냉각수 계통으로 누설)

표 3은 제안된 모델과 Attention mechanism이 적용되지 않은 기본 LSTM과의 예측 결과 비교를 나타낸 표이다. 표 3에 나타난 예측 결과는 테스트 데이터에 대한 결과만을 나타낸 것이며, Attention mechanism이 적용된 LSTM이 기본 LSTM을 이용한 단계 예측을 수행한 것보다 RMS 오차와 R^2 에서 훨씬 나은 성능을 보여주었다. 가압기 수위 예측의 경우 RMS 오차는 기본 LSTM과 비교했을 때 약 0.06% 정도의 차이를 보여주었으며, 최대오차는 12% 정도의 차이를 보여주었다. 가압기 압력 예측의 경우 RMS 오차는 두 인공지능 모델이 비슷한 수치를 보였지만, 최대오차의 경우 6% 정도의 오차를 보여주었다. 제안된 모델과 기본 LSTM 모델과의 예측성능 비교를 통해서 LSTM에 Attention mechanism의 적용이 시계열 데이터 예측을 수행할 시 예측성능을 더 향상시켜주는 것을 확인하였다.

표 3. LSTM with Attention mechanism과 기본 LSTM의 예측 결과 비교표

예측 대상	예측 단계	평가 척도	LSTM with Attention mechanism	기본 LSTM
가압기 수위	60 step	RMSE	0.222	0.254
		E_{\max}	11.856	13.588
		R^2	0.99988	0.99984
	120 step	RMSE	0.255	0.290
		E_{\max}	12.683	24.763
		R^2	0.99984	0.99980
	180 step	RMSE	0.242	0.309
		E_{\max}	13.048	13.024
		R^2	0.99986	0.99977
가압기 압력	60 step	RMSE	0.172	0.192
		E_{\max}	8.239	14.893
		R^2	0.99984	0.99980
	120 step	RMSE	0.204	0.209
		E_{\max}	8.421	10.686
		R^2	0.99978	0.99977
	180 step	RMSE	0.192	0.228
		E_{\max}	8.680	10.016
		R^2	0.99981	0.99973

제 5 장 결론

원자력발전소의 예상치 못한 트립은 발전소에 막대한 경제적 손실을 유발할 수 있기 때문에 예상치 못한 원자로 트립을 최소화해야 한다. 이에 따라 본 논문에서는 인공지능을 이용하여 비정상 상황에서 원자로 트립을 방지하기 위해 원자로 트립 유발 변수를 예측하였다. 원자로 트립을 유발시키는 변수에는 가압기, 증기발생기, 중성자속, 터빈 등 관련된 변수들이 포함되며 본 논문에서는 가압기 수위와 압력 변수를 예측하였다.

가압기 수위와 압력 변수를 예측하기 위해서 차원 축소 알고리즘 중 하나인 Principal Component Analysis(PCA), 인공지능 방법인 Long Short-Term Memory(LSTM), LSTM의 성능 향상을 위한 Attention mechanism을 사용하였으며, 트립변수의 거동을 예측하기 위해 다단계 예측 전략 중 Multi-Input Multi-Output(MIMO) 전략을 사용하였다. MIMO 전략을 기반으로 입력데이터의 시간 단계를 30 step, 예측 단계를 60, 120, 180 step으로 변경시켜가며 예측 모델 개발을 수행하였다.

인공지능기반 예측 모델을 구축하기 위해 Compact Nuclear Simulator(CNS)를 이용하여 비정상 데이터를 취득하였다. 그리고 취득한 비정상 데이터를 기반으로 피어슨 상관계수를 통해 가압기 수위 및 압력과 관련된 변수 위주로 입력변수를 선정하였다. 이를 통해 선정된 입력변수의 개수는 총 235개이며, PCA를 통해 입력데이터의 차원을 축소시켰다. 그 후, LSTM과 Attention mechanism을 이용하여 가압기 수위 및 압력 변수의 다단계 예측을 수행하였다.

개발된 예측 모델은 회귀모델의 평가지표인 평균제곱근오차(RMSE; Root Mean Squared Error), R Square (R^2), 최대오차를 통해 평가되었으며, Attention mechanism이 적용되지 않은 기본 LSTM 모델과 개발된 예측 모델의 예측성능 비교를 수행하였다. 개발된 예측 모델의 가압기 수위 및 압력 예측 결과는 60, 120step을 예측할 때 RMS 오차가 최대 0.27%, 최대오차가 약 13% 수준을 보여주었으며, 180 step을 예측할 때는 RMS 오차가 최대 0.32%, 최대오차 약 23% 수준을 보여주었다. 즉, 예측 단계가 증가함에 따라 RMS 오차 및 최대오차도 증가하는 경향을 보여주었다. 또한, 기본 LSTM 모델과의 비교를 통해 개발된 예측 모델의 예측성능이 모든 예측 단계에서

훨씬 낮은 RMS 오차 및 1에 가까운 R^2 값을 보여주었다. 그리고 최대오차는 기본 LSTM보다 최대 12% 감소한 것을 보여주었다. 개발된 예측 모델은 60 step과 120 step 예측시 RMS 오차 및 최대오차의 차이가 크지 않았지만 180 step을 예측할 때 상대적으로 큰 최대오차를 보였다. 이에 따라, 본 논문에서는 30 step을 기반으로 최대 120 step을 예측하는 것이 적절한 예측 단계로 판단하였다.

최종적으로, 본 논문은 원자력발전소에서 비정상 상태가 발생했을 때 운전원에게 원자로 트립변수의 거동을 미리 제시해 줌으로써 불필요한 원자로 트립 방지 및 사전조치를 유도하기 위한 목적으로 인공지능을 이용한 예측 모델을 개발하였다. 개발된 인공지능기반 예측 모델은 가압기 수위 및 압력을 비교적 정확하게 예측하는 것으로 판단되며, 비정상 진단 모델과 더불어 진단 결과와 함께 예측 결과를 운전원에게 제공해 준다면 운전원의 인적오류를 저감할 수 있을 것으로 기대된다.

그러나, 현재 많은 원자로 트립변수 중 가압기 수위와 압력에 대한 거동만 예측하였기 때문에, 향후 더 많은 원자로 트립변수를 예측하는 인공지능 모델을 개발한다면 원자로 트립 발생 시점과 원자로 트립변수 중 어떤 원자로 트립변수로 인해 원자로 트립이 발생할 것인지를 파악할 수 있을 것으로 기대된다.

참고문헌

- [1] H. J. Kim, A. M. Arigi, J. H. Kim, Development of a diagnostic algorithm for abnormal situations using long short-term memory and variational autoencoder, *Annals of Nuclear Energy*, Vol. 153, 108077, 2021.
- [2] G. M. Lee, S. J. Lee, C. Y. Lee, A convolutional neural network model for abnormality diagnosis in a nuclear power plant, *Applied Soft Computing*, Vol. 99, 106874, 2021.
- [3] M. D. Wang, T. H. Lin, K. C. Jhan, S. C. Wu, Abnormal event detection, identification and isolation in nuclear power plants using LSTM networks, *Progress in Nuclear Energy*, Vol. 140, 103928, 2021.
- [4] H. P. Nguyen, P. Baraldi, E. Zio, Ensemble empirical mode decomposition and long short-term memory neural network for multi-step predictions of time series signals in nuclear power plants, *Applied Energy*, Vol. 283, 116346, 2021.
- [5] H. P. Nguyen, J. Liu, E. Zio, A long-term prediction approach based on long short-term memory neural networks with automatic parameter optimization by Tree-structured Parzen Estimator and applied to time-series data of NPP steam generators, *Applied Soft Computing*, Vol. 89, 106116, 2020.
- [6] Y. K. Liu, F. Xie, C. L. Xie, M. J. Peng, G. H. Wu, H. Xia, Prediction of time series of NPP operating parameters using dynamic model based on BP neural network, *Annals of Nuclear Energy*, Vol. 85, pp. 566-575, 2015.
- [7] USNRC Technical Training Center, Westinghouse Technology Systems Manual. USNRC HRTD. Rev 12/08.
- [8] KAERI, 교육훈련용 Nuclear Simulator 개발, RR-734, 1988.
- [9] I. T. Jolliffe, *Principal Component Analysis*, Springer, 2002.
- [10] S. Hochreiter, J. Schmidhuber, Long Short-Term Memory, in *Neural Computation*, Vol. 9, No. 8, pp. 1735-1780, Nov. 1997.
- [11] I. Sutskever, O. Vinyals, Q. V. Le, Sequence to sequence learning with neural networks, In: *Advances in neural information processing systems*, pp. 3104-3112,

2014.

- [12] D. Bahdanau, K. Cho, Y. Bengio, Neural Machine Translation by Jointly Learning to Align and Translate, in International Conference on Learning Representations, 2015.
- [13] M. T. Luong, Neural Machine Translation, Stanford University, United States, 2016.
- [14] N. H. An and D. T. Anh, Comparison of Strategies for Multi-step-Ahead Prediction of Time Series Using Neural Network, International Conference on Advanced Computing and Applications (ACOMP), pp. 142-149, Nov. 23-25, 2015.
- [15] J. Benesty, J. Chen, Y. Huang, I. Cohen, Pearson Correlation Coefficient, Springer, 2009.