

딥러닝 활용 원전 중대사고 진단⁺

(Nuclear Power Plant Severe Accident Diagnosis Using Deep Learning Approach)

김성엽^{1)*}, 최윤영²⁾, 박수용³⁾, 권오규⁴⁾, 신형기⁵⁾

(Sung-yeop Kim, Yun Young Choi, Soo-Yong Park, Okyu Kwon, and Hyeong Ki Shin)

요약 원자력발전소의 중대사고 발생 시 신속하고 정확하게 사고 상황을 파악해야 하며, 이러한 사고진단 정보를 획득했을 때 적절한 사고관리 및 대응을 수행할 수 있다. 본 연구에서는 국가 원자력 재난관리 시스템인 AtomCARE (Computerized technical Advisory system for a Radiological Emergency)로 전송되는 주요 발전소 정보로부터 중대사고 상황을 진단하는데 있어 딥러닝 기술의 접목을 고려하였다. 이를 위하여 주요 시나리오를 선정하고 사고 진행에 따른 상세 시나리오에 대하여 중대사고 해석 코드인 MAAP5 다량 계산을 통한 학습 DB를 구축하였다. 그리고 이 DB의 학습을 통하여 주요 발전소 정보로부터 중대사고 상세 시나리오를 분류할 수 있는, 즉 중대사고 상황을 진단할 수 있는 기술을 개발하였다. 또한 블라인드 테스트와 주성분분석을 통한 검증 을 수행하였다. 본 연구에서 개발한 기술은 향후 전체 중대사고 시나리오로 확장 및 적용 가능할 것으로 판단되며 신속하고 정확한 사고진단의 기반기술로 활용 가치가 높을 것으로 기대된다.

핵심주제어: 중대사고, 사고진단, 사고관리, 딥러닝, 주성분분석

Abstract Quick and accurate understanding of the situation in a severe accident is essential for conducting the appropriate accident management and response using the accident diagnosis information. This study employed deep learning technology to diagnose severe accidents through the major safety parameters transferred from a nuclear power plant (NPP) to AtomCARE. After selecting the major accident scenarios to consider, a learning database was established for particular scenarios affiliated with major scenarios by performing a large number of severe accident analyses using MAAP5 code. The severe accident diagnosis technology, which classifies detailed accident scenarios using the major safety parameters from NPPs, was developed by training it with the established database. Verification and validation were conducted by blind test and principal component analysis. The technology developed in this study is expected to be extended and applied to all severe accident scenarios and be utilized as a base technology for quick and accurate severe accident diagnosis.

Keywords: Severe accident, Accident diagnosis, Accident management, Deep learning, Principal component analysis

* Corresponding Author: sungyeop@kaeri.re.kr

+ 본 연구는 원자력안전위원회에서 주관하는 원자력안전연구사업의 일환으로 수행되었음 (No.1805018). 또한 과학기술정보통신부에서 주관하는 가동원전 안전성 향상 핵심기술 개발사업의 지원을 일부 받았음 (RS-2022-00144405).

Manuscript received November 30, 2022 / revised

December 23, 2022 / accepted December 25, 2022

1) 한국원자력연구원, 제1저자 및 교신저자
2) 국가수리과학연구소, 제2저자
3) 한국원자력연구원, 제3저자
4) 국가수리과학연구소, 제4저자
5) 한국원자력안전기술원, 제5저자

1. 서론

원자력발전소는 에너지를 생산하는 과정에서 방사성물질이 생성되기 때문에 원전 외부로 방사성물질이 방출되는 것을 방지하기 위하여 다중방벽(multiple barriers)을 갖추고 있다. 다중방벽은 내부에서부터 핵연료 펠렛(fuel pellet), 핵연료 펠렛을 감싸고 있는 피복관(fuel cladding), 원자로 용기(reactor vessel), 원자로 건물(reactor building) 내벽 및 외벽 등으로 구성된다.

원전의 중대사고(severe accident)란 원자로용기 안에 있는 핵연료가 대량 손상되는 사고로서, 원자력안전법 제1장 제2조 25 (2022)에는 설계기준을 초과하여 노심(reactor core)의 현저한 손상을 초래하는 사고로 정의되어 있다. 중대사고는 그 가능성은 매우 낮지만 방사성물질의 외부 유출을 방지하는 물리적방벽의 건전성을 손상하여 노심과 격납건물 외부로 방사성물질의 방출을 야기할 수 있다. 대표적인 중대사고로 1979년 미국의 스리마일섬(TMI: Three Mile Island) 원전 사고, 1986년 구소련의 체르노빌 원전 사고, 그리고 2011년 일본의 후쿠시마 원전 사고의 예를 들 수 있다.

원전 중대사고 발생 시 사고가 어떻게 진행되고 있는지 신속하고 정확하게 파악하는 일은 사고관리 및 비상대응에 있어 매우 중요하다. 현재 국내에서 원전 중대사고 시 사고관리를 위한 주요 도구로 활용될 수 있는 국가 원자력 재난관리 시스템(AtomCARE: Computerized technical Advisory system for a Radiological Emergency) (Jeong et al., 2013)이나 중대사고 관리지침서(SAMG: Severe Accident Analysis Management Guideline) (Cho et al., 2022)는 많은 장점에도 불구하고 사고진단 및 사고진행 예측 등에 대한 정보 제공과 관련하여 지속적인 기술 개선이 요구된다. 후쿠시마 사고 시 일본에서는 SPEEDI (System for Prediction of Environmental Emergency Dose Information)라는 시스템을 갖추고 있었으나 중대사고 진단 및 방사성물질 방출 정보를 획득할 수 없어 주민보호조치 의사결정에 활용할 수 없었다 (NRA, 2014).

성공적인 사고관리 지원시스템의 요건으로서 (1) 매우 다양한 원전 중대사고 시나리오를 체계적이고 효율적으로 도출해야 하고, (2) 사고진단 및 사고진행 예측을 위한 빅데이터 생산 시 내재되는 현상학적 불확실성을 고려할 필요가 있으며, (3) 사고예방 및 완화를 위한 기술지원 요원들이 신속 정확하게 의사결정을 할 수 있는 시스템을 갖추어야 한다.

2. 중대사고 진단 딥러닝 모델 개발

서론에서 언급한 성공적인 사고관리 지원시스템의 요건을 충족시키기 위하여 본 논문에서는 크게 세 가지 방법론을 제안하고자 한다.

첫째, 다양한 원전 중대사고 시나리오 도출을 위해 확률론적 안전성 평가(PSA: Probabilistic Safety Assessment) 기법을 활용하였다. PSA는 원전뿐 아니라 다양한 산업설비로 인한 리스크를 평가하는 방법이며, 리스크는 수학적으로 어떤 사고로 인한 영향(consequence)과 사고의 발생 가능성(probability or frequency)의 곱이다. 원전 PSA는 다음의 3단계로 구성되어 있다.

- Level 1 PSA: 원전의 노심이 손상되는 시나리오들의 빈도(CDF: core damage frequency)를 평가
- Level 2 PSA: 원전 격납건물 파손 빈도와 방사성물질 누출량(사고 선원항, accident source term)을 평가
- Level 3 PSA: 외부로 방출된 방사성물질의 확산과 침적으로 인한 주변 주민과 환경의 영향을 평가

PSA 방법은 원전에서의 중대사고 발생 가능성이 있는 시나리오를 가장 체계적으로 분석하고 있으며, 본 논문에서는 Level 2 PSA의 발전소 손상상태 사건수목(PDS ET: Plant Damage State Event Tree) 기법을 활용하여 대표 중대사고 시나리오를 분류/도출하였다. PDS ET는 Level 1 PSA에서 고려하지 않은 안전계통을 추가적으로 모델링하기에 안전계통 작동 여부에 따른 중대사고 진행 시나리오를 상세히 분류할 수 있다 (Lee et al., 2021). 평가를 위한 대상

발전소로는 국내 가압경수로 원전의 표준형으로 일컬어지는 OPR-1000 원전을 선정하였다.

둘째, 사고진행과 관련된 열수력/중대사고 현상학적 분석과 불확실성 분석을 위해 MAAP5 (EPRI, 2019) 중대사고 종합해석코드를 이용하였다. MAAP5 코드는 현재 세계적으로 가장 활발하게 원전 중대사고 현상 해석에 활용되고 있으며 현상학적 불확실변수와 그 범위가 잘 정의되어 있다. 본 논문에서는 불확실변수의 범위 및 분포를 가정하고 샘플링 및 표본입력을 이용한 코드 계산을 수행하였다. 샘플링 방식으로는 무작위 추출법(random sampling)을 사용하였고 각 중대사고 시나리오별로 수백개의 샘플을 추출하여 분석을 수행하였다.

셋째, 신속 정확한 의사결정을 위해 딥러닝 기법을 적용하였다. PSA 방법론 중 PDS ET에 의한 시나리오 선정과 중대사고해석코드 MAAP5를 이용한 사고해석 데이터베이스(DB: Data Base)를 구축하였으며, 이를 활용하여 최적의 딥러닝 모델을 개발하고자 하였다.

2.1 대표 중대사고 시나리오 선정 및 학습 DB 구축

대표 시나리오로서 중대사고 진행 시 원자로 냉각재계통(RCS: Reactor Coolant System)이 저압으로 유지되는 냉각재상실사고(LOCA: Loss of Coolant Accident) 및 고압으로 유지되는 과도사건(transient)에 대하여 각 초기사건 1건씩을 선정하였다 (Kim et al., 2021). 이는 원자로 냉각재계통 압력 조건에 따라 중대사고 현상들이 현격히 다르게 전개되기 때문이다. 대상 원전의 노심손상빈도가 가장 높은 시나리오를 선정하였으며 냉각재상실사고로서는 중형 냉각재상실사고(MLOCA: Medium break Loss of Coolant Accident), 과도사건으로서는 1차측 기기냉각수 완전 상실사고(TLOCCW: Total Loss of Component Cooling Water)를 대표 시나리오로 선정하였다.

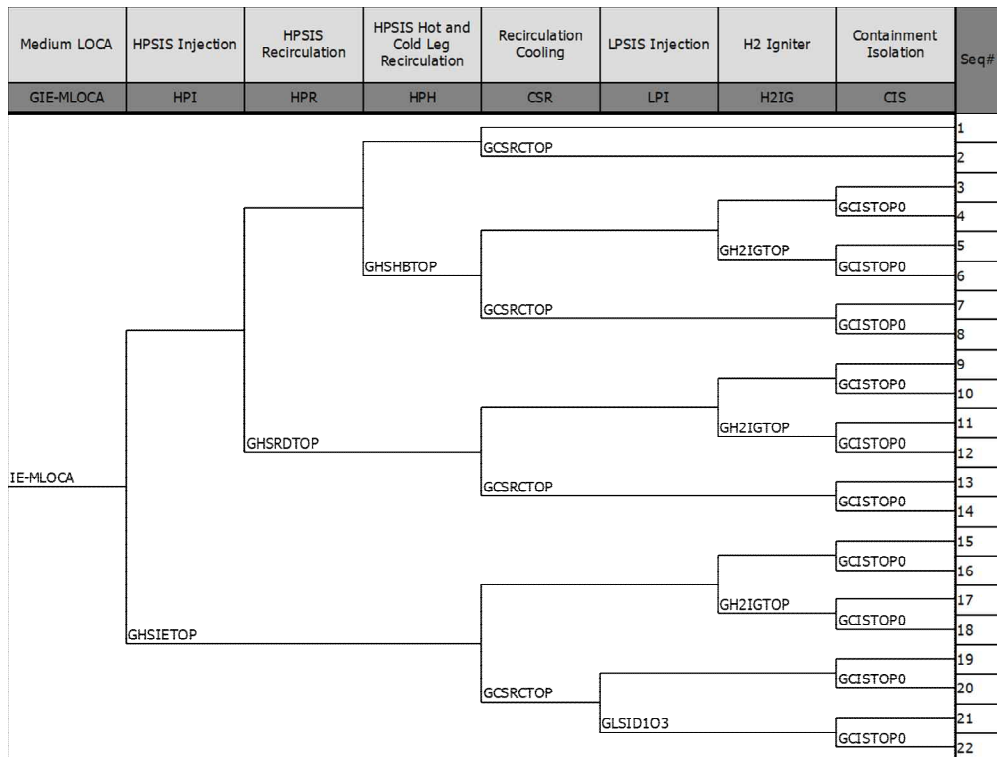


Fig. 1 PDS ET (Plant Damage State Event Tree) of the MLOCA (Medium break Loss of Coolant Accident) Scenario

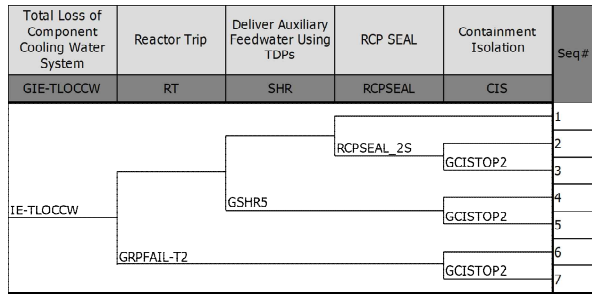


Fig. 2 PDS ET (Plant Damage State Event Tree) of the TLOCCW (Total Loss of Component Cooling Water) Scenario

원자력발전소는 원자로 노심에서 생성되는 열을 이용하여 증기를 생산하고 이를 통해 터빈을 돌려 전기를 생산한다. 냉각재상실사고는 원자로로부터 발생하는 열을 제거하여 증기발생기로 전달하는 냉각수가 원자로 냉각재계통 배관 파단 등에 의해 상실되어 원자로 노심 냉각기능이 손상되는 사고이며, 배관 파단 크기에 따라 소형, 중형, 대형 냉각재상실사고로 분류한다. 1차측 기기냉각수 완전 상실사고는 원자로의 여러 보조계통에 냉각수를 공급하여 열을 제거하는 기기냉각수가 상실되는 사고이다.

PDS ET는 중대사고 시 안전계통 작동 여부에 따라 시나리오를 분류한다. Fig. 1에 나타난 바와 같이 안전계통 작동 여부에 따라 MLOCA 시나리오의 22개 세부 시나리오가 도출되었다. 그리고 발생빈도 기준으로 99.99%를 차지하는 12개 세부 시나리오(MLOCA-02, 03, 04, 05, 07, 09, 11, 13, 15, 17, 19, 21)만을 남기고 무시할 수 있는 저빈도의 시나리오들을 제외하였다. 안전계통 중 수소폭발을 방지하기 위해 연소를 통해 원자로건물 내 수소 농도를 제어하는 수소점화기(hydrogen igniter)의 경우 그 작동 시점이 중대사고 진행 후반에 위치한다. 수소점화기 작동 시점까지의 정보를 모두 활용한 딥러닝 모델의 개발은 예측의 의미를 퇴색시키므로 수소점화기 계통에 의해 분기되는 3개의 시나리오(MLOCA-05, 11, 17) 또한 제외하였다. 최종적으로 MLOCA에 대하여 9개의 세부 시나리오를 확정하였다.

TLOCCW 시나리오의 세부 시나리오는 Fig.

2처럼 PDS ET에 따라 7개 시나리오로 분류 후 발생빈도 99.99% 이상을 차지하는 3개 세부 시나리오(TLOCCW-02, 04, 06)를 선정하였다.

Fig. 1과 Fig. 2의 약어 해석은 다음과 같다.

- HPSIS (High Pressure Safety Injection System): 고압안전주입계통
 - LPSIS (Low Pressure Safety Injection System): 저압안전주입계통
 - TDPs (Turbine Driven Pumps): 터빈구동펌프
 - RCP (Reactor Coolant Pump): 원자로냉각재펌프
- 최종적으로 선정된 MLOCA 세부 시나리오 9개와 TLOCCW 세부 시나리오 3개에 대하여 중대사고 종합해석코드인 MAAP5 및 불확실성 분석코드인 MOSAIQUE (Lim et al., 2011)를 활용하여 다량 중대사고해석 입력 개발 및 분석을 수행하였고 학습 DB를 구축하였다. AtomCARE로 전송되는 주요 발전소 정보 중 중대사고 진단과 관련이 높을 것으로 생각되는 24개의 주요 변수를 전문가 검토를 통해 선정하였으며 MAAP5 코드와 연계하여 DB를 구축하였다 (Kim and Park, 2021; Kim et al., 2021). 선정된 24개 주요 변수는 다음과 같다.
- 가압기 광역 압력 [kg/cm²(a)]
 - 가압기 수위 [%]
 - 원자로 수위 [m]
 - 냉각재 계통 평균온도 [°C]
 - 저온관 질량유량 1 [kg/h]
 - 저온관 질량유량 2 [kg/h]
 - 저온관 질량유량 3 [kg/h]
 - 저온관 질량유량 4 [kg/h]
 - 증기발생기 1번 압력 [kg/cm²(a)]
 - 증기발생기 2번 압력 [kg/cm²(a)]
 - 증기발생기 1 광역수위 [%]
 - 증기발생기 2 광역수위 [%]
 - 노심출구 최대 온도 [°C]
 - 최대노심온도 채널 A [°C]
 - 안전주입탱크 협역 압력 [kg/cm²(g)]
 - 고압안전주입 펌프 유량 (저온관+고온관) [L/min]
 - 저압안전주입 펌프 배출 헤더유량 [L/min]
 - 격납건물 살수 유량 [L/min]
 - 재장전수탱크 수위 [%]

- 격납건물 협역압력 [cmH₂ O(g)]
- 격납건물 평균온도 [°C]
- 격납건물 수위 [%]
- 격납건물 집수조 수위 [%]
- 격납건물 수소농도 [%]

2.2 중대사고 상황파악 딥러닝 모델 개발 및 적용

중대사고 상황파악 모델의 경우, 전체 원전 주요 변수 데이터 중 초기 시점의 데이터를 바탕으로 시나리오의 분류가 가능해야 그 의미를 가질 수 있을 것이다. 또한 학습 데이터가 시간에 따라 변하는 24개의 발전소 정보를 포함하는 다차원 변수로 구성되어 있기에 전통적인 방법을 적용하기에는 한계가 존재한다.

Transformer 모델은 자연어 처리 (NLP: Natural Language Processing) 문제를 해결하기 위해 제안된 뉴럴 네트워크 구조이다 (Vaswani et al, 2017). Transformer 모델의 핵심은 멀티 헤드 어텐션(multi-head attention)으로 최근 시계열 예측부터 사진 분류까지 다양한 문제에서 성공적으로 도입되고 있는 방법이다 (Chen et al, 2021). 본 논문에서는 다차원 변수로 구성된 시계열 데이터를 입력으로, 멀티 레이블을 출력으로 하는 분류 문제를 해결하기 위하여 다음과 같은 형태로 기본 Transformer 모델의 인코더(encoder) 레이어를 변형하여 사용하였다: (1) 다변수 시계열 데이터에서 잠재 변수를 추출하기 위해 Transformer 모델의 인코더 영역을 사용하여 다변수 시계열 데이터에서 각 변수를 토큰으로 변형한다. 그리고 토큰들 간의 관계를 멀티 헤드 어텐션을 통해 형성하고 잠재 변수를 생성한다. (2) 멀티 레이블 분류 (multi-label classification)를 위해 인코더에서 생성된 잠재 변수를 출력부의 완전연결계층 (fully connected layer)에 통과시킨다. Fig. 3은 본 연구에서 개발한 딥러닝 모델의 구조를 보여 준다.

전처리로 각각의 변수들을 정규화 시킨 뒤, 모델 입력으로 주요 발전소 정보인 24개의 변수에 대한 초기 30,000초 데이터(50초 간격 600개

의 시계열 데이터)를 사용하였다. 출력으로는 12개의 중대사고 시나리오에 대한 분류를 설정하였다. Optimizer로는 Adam (Adaptive momentum estimation) (Kingma and Ba, 2017) 기법의 변형으로 학습률(learning rate)을 조절하여 학습의 편의성과 모델의 성능을 향상시킨 AdamP (Heo et al., 2020)를 사용하였다. 손실 함수(loss function)로는 기계학습의 멀티 레이블 분류 문제를 해결하기 위해 일반적으로 많이 사용되는 CrossEntropyLoss를 사용하였다. 전체 샘플 수는 12개의 각 세부 시나리오별로 200개씩 총 2,400개의 샘플을 사용하였으며 테스트 데이터는 학습 데이터의 20%로 지정하였다.




Fig. 3 Structure of the Deep Learning Model for Severe Accident Diagnosis

우선 MLOCA 9개 시나리오에 대해 분류 모델을 개발하고 그 결과를 도출하였다. 사고 시작 후 초기 30,000초의 발전소 정보를 획득했을 때 학습 데이터 및 테스트 데이터에 따른 분류 모델 정확도는 Fig. 4의 MLOCA의 X축의 30,000초 결과와 같다. 학습 데이터와 테스트 데이터 모두 각각 100%와 99.7% 정확도에 수렴한다는 것을 확인할 수 있었다.

최초에 30,000초 정도 데이터로 학습 및 테스트를 수행한 근거는 수소점화기 외의 대부분의 안전계통 작동 여부가 30,000초 정도는 되어야 결정이 될 것이라 판단하였기 때문이다. 또한 시나리오마다 다를 수 있으나 SAMG 진입조건도 이 정도의 시간이 경과해야 할 것으로 예상되므로 그 이전에 중대사고 진단 정보를 제공할 수 있다면 사고관리 전략을 수행하는 데 이를 활용할 수 있을 것으로 판단하였다. 물론 시나리오를 판별하는데 필요한 시간을 최소화할수록 신속한 사고관리 및 비상대응이 가능할 것이다. 따라서 중대사고 시나리오 판별을 위한 시계열 데이터의 길이에 따른 정확도 분석을 추가로 수행하였다. 시계열 데이터 길이는 최소 6,000초에서 36,000초까지로 설정하여 각각의 분류 정확도를 비교하였다. Fig. 4에 도식된 결과처럼 15,000초 이하에서는 정확도가 80% 이하로 감소하는 것을 확인할 수 있었다. 시나리오 분류 정확도를 95% 이상 확보하기 위해서는 적어도 20,000초까지의 데이터가 확보되어야 함을 확인할 수 있었다.

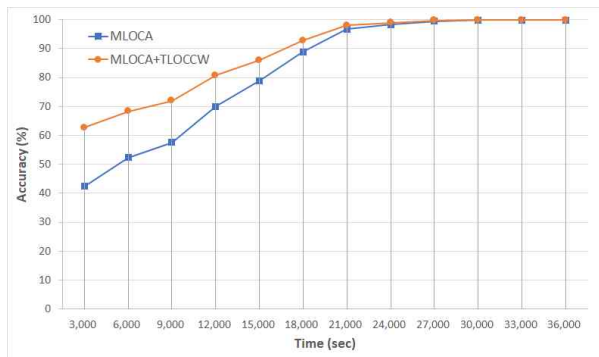


Fig. 4 Classification Accuracy by Input Data Length

MLOCA의 9개 세부시나리오에 대한 분류 결과를 확인한 뒤 TLOCCW의 세부 시나리오 3개를 추가하여 총 12개 세부 시나리오에 대한 개발 모델의 분류 결과를 검토하였다. Fig. 4에 나타난 바와 같이 MLOCA 시나리오와 차이가 극명한 TLOCCW 시나리오를 추가하여 분류하는 문제에 있어서는 정확도가 더욱 향상됨을 확인할 수 있었다. 이 결과를 통하여 개발 딥러닝

모델이 시나리오 하나에 대해서만이 아닌 다양한 시나리오에 대한 분류가 가능함을 확인하였으며 향후 전체 중대사고로의 확장 및 적용 연구를 수행하여 그 가능성을 가늠해 볼 수 있을 것이다.

3. 개발 모델 검증

3.1 주성분분석을 통한 검증

주성분분석(PCA: Principal Component Analysis)은 매우 널리 사용되는 차원 축소 기법 중 하나로 원 데이터의 분포를 최대한 보존하면서 고차원의 데이터를 저차원의 데이터로 변환하는 방법이다. 본 연구에서는 주성분분석 기법을 활용하여 MLOCA의 각 상세 시나리오들의 24개의 변수에 대한 데이터의 특징들이 2차원 상에서 어떻게 분포하는지 도식해 보았다. 95% 이상 분류 정확도 확보가 가능한 20,000초 데이터에서부터 220,000초까지 시간을 늘려가며 2차원으로 축소한 데이터의 특성 분포를 Fig. 5에 도식하였다.

주성분분석의 결과처럼 각 상세 시나리오의 경우 초반에는 1개의 시나리오 안에서도 그 특성이 나뉘는 경우도 있으나 시간이 지나며 점차 하나로 모이는 경향을 보임을 알 수 있었다. 이는 PSA 기법으로 PDS ET에 따라 중대사고 시나리오를 분류하는 것이 합리적인 접근법임을 보여주는 결과이다.

또한 일부 시나리오들은 시간이 지나며 서로 유사한 분포를 보여 분류가 어려워지는 경향을 파악할 수 있었는데 딥러닝 모델에 의한 분류는 20,000초 정도의 데이터만 확보되어도 95% 이상의 높은 정확도를 보여주고 Fig. 4에서 볼 수 있듯이 데이터의 시간이 길어질수록 그 정확도는 향상된다. 이는 본 연구에서 2차원으로 차원을 상당히 축소한 주성분분석 방법의 한계에 기인한 것일 수 있으며, 주성분분석을 통한 분류로는 부족한 점들을 딥러닝 기법의 적용을 통해 극복할 수 있음을 보인 반증이기도 하다.

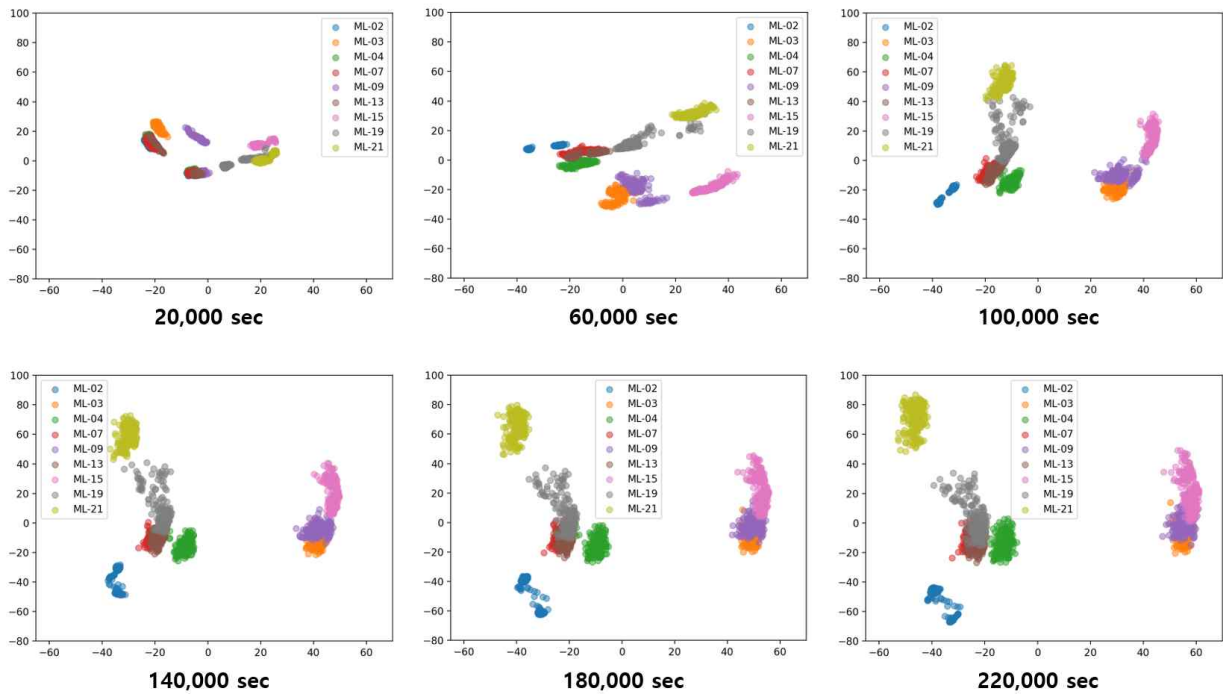


Fig. 5 PCA (Principal Component Analysis) Results by Time

3.2 블라인드 테스트를 통한 검증

블라인드 테스트를 위하여 MLOCA 및 TLOCCW 총 12개 세부 시나리오에 대하여 각 100개씩 총 1,200개의 별도의 검증용 DB를 새로운 MAAP5 분석을 통하여 구축하였다. 검증용 데이터 생산을 위한 샘플링에서는 학습용 데이터 생산 때와 달리 결과에 큰 편차를 야기하는 파이프 파단 크기, 운전원 조치 시간을 고정하고 분석 전산코드의 불확실성만 고려하였다.

1,200개의 샘플들에 대한 라벨링 정보를 제공하지 않고 개발한 모델을 통하여 시나리오를 분류하는 블라인드 테스트를 수행하였다. 30,000초까지의 데이터를 통해 12개 세부 시나리오를 분류해본 결과 100% 정확도로 분류에 성공함을 확인할 수 있었다.

4. 결론

본 연구에서는 국가 원자력 재난관리 시스템

인 AtomCARE로 전송되는 발전소 정보로부터 원전 중대사고 발생 시 중대사고를 진단할 수 있는 딥러닝 모델을 개발하였다. 이를 위해 중대사고 진단과 관련이 높은 24개 주요 원전 변수를 선별하였으며 대표 시나리오로 선정된 MLOCA와 TLOCCW에 대해 딥러닝 학습 및 테스트 DB를 구축하였다. MLOCA와 TLOCCW의 12개 세부 시나리오를 분류하는 문제에 대하여 24개로 선정된 주요 원전 변수 데이터를 중대사고 발생 후 약 20,000초 이상 확보하면 95% 이상의 정확도로 분류가 가능함을 확인할 수 있었다. 그리고 이러한 진단을 내리는 데 걸리는 시간이 단 1초도 소요되지 않음 또한 확인할 수 있었다. 불확실성을 많이 내재하고 신속성도 떨어지는 기존의 방식의 한계점을 첨단기술 융합을 통하여 극복할 수 있는 가능성을 보였다고 평가할 수 있을 것이다.

향후 연구로서 24개의 원전 변수 중 어떤 변수가 시나리오 분류, 즉 중대사고 상황과악에 주요한 변수인지 우선순위를 가늠하는 연구도 수행할 수 있을 것으로 보인다. 또한 본 연구에

서 선정된 저압 및 고압 대표 시나리오뿐만 아니라 기타 모든 중대사고 시나리오로 본 기술을 확장 및 적용 가능할 것으로 기대되며, 궁극적으로 신속하고 정확한 사고진단을 가능하게 할 기반기술로 그 활용 가치가 높을 것으로 판단된다. 그리고 신속하고 정확한 사고진단은 적절한 사고관리 및 대응으로 연계될 수 있기에 본 기술이 최종적으로는 원전 안정성 향상에 기여할 수 있는 가능성이 클 것으로 기대된다.

본 논문은 한국산업정보학회 2022년 춘계학술대회에서 발표한 “원전 중대사고 상황파악 딥러닝 모델 개발” 논문의 내용을 확장 및 개선하여 학술지에 투고함을 명시함. 저압 대표 시나리오(MLOCA 시나리오)에 국한되어 있던 딥러닝 모델을 고압 대표 시나리오(TLOCCW 시나리오)까지 확장하였으며, 검증을 위해 블라인드 테스트를 추가로 수행하여 개발 딥러닝 모델의 완성도를 향상시켰음.

References

- Chen, C., Fan, Q. and Panda, R. (2021). CrossViT: Cross-Attention Multi-Scale Vision Transformer for Image Classification, *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, pp. 357-366.
- Cho, J., Lee, S., Kim, J., and Park, S. (2022). Framework to Model Severe Accident Management Guidelines into Level 2 Probabilistic Safety Assessment of a Nuclear Power Plant, *Reliability Engineering and System Safety*, 217, 108076. <https://doi.org/10.1016/j.ress.2021.108076>.
- EPRI. (2019). *Modular Accident Analysis Program - MAAP5 v5.05 for Windows*, Electric Power Research Institute.
- Heo, B., Chun, S., Oh, S., Han, D., Yun, S., Kim, G., Uh, Y., and Ha, J. (2020). Adam: Slowing Down the Slowdown for Momentum Optimizers on Scale-invariant Weights, [arXiv:2006.08217](https://doi.org/10.48550/arXiv.2006.08217).
- Kim, S. and Park, S. (2021). Production of Deep Learning Data Base for Accident Source Term Estimation, *Transactions of the Korean Nuclear Society Autumn Meeting*, Oct. 21-22, Changwon, Korea.
- Kim, S., Park, S., Yoon, J., Song, K. and Jin, K. (2021). *Construction of Severe Accident Analysis DB for Deep Learning of Source Term Estimation*, Nuclear Safety Technology Analysis Report, NSTAR-21RS42-395, Korea Foundation of Nuclear Safety.
- Kingma, D. and Ba, J. (2017). Adam: A Method for Stochastic Optimization, [arXiv:1412.6980v9](https://doi.org/10.48550/arXiv.1412.6980), <https://doi.org/10.48550/arXiv.1412.6980>.
- Lee, S., Yang, J., Kim, M., Cho, J., Kim, S., Kim, J., Kim, J., Kim, D. and Kim, D. (2021). *Probabilistic Safety Assessment of Nuclear Power Plants*, Seoul, Korea eBook Publishing Company.
- Lim, H., Han, S. and Jeong, J. (2011). MOSAIQUE - A Network Based Software for Probabilistic Uncertainty Analysis of Computerized Simulation Models, *Nuclear Engineering and Design*, 241(5), 1776-1784. <https://doi.org/10.1016/j.nucengdes.2011.01.021>.
- Nuclear Safety Act. (2022). Chapter 1 (General Provisions), Article 2 (Definitions) 25, Act No. 18972, Republic of Korea.
- NRA. (2014). *About the Operation of SPEEDI in an Emergency Situation (緊急時迅速放射能影響予測ネットワークシステム(SPEEDI)の運用について)*, Japan Nuclear Regulation Authority.
- Jeong, S., Nam, K., Lee, Y., Lee, H., Woo, S., Kim, D., Park, S. and Bae, K. (2013). *Functionality Advancement of AtomCARE*, KINS/GR-509, Vol.2, Korea Institute of Nuclear Safety.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A, Kaiser, Ł. and Polosukhin, I. (2017). Attention is All You Need, *Advances in Neural Information Processing Systems* 30.



김 성 엽 (Sung-yeop Kim)

- 한양대학교 원자시스템공학과 학사
- KAIST 원자력및양자공학과 박사
- (현재) 한국원자력연구원 리스크평가연구실 선임연구원

• 관심분야: Level 3 PSA, 소외사고영향분석, 원전 사고 비상대응



신 형 기 (Hyeong Ki Shin)

- 서울대학교 원자핵공학과 학사
- 서울대학교 원자핵공학과 석사
- Univ. of Provence, France 원자로물리 박사
- (현재) 한국원자력안전기술원 방사선안전연구실 책임연구원

• 관심분야: 방사선방호, 방사능방재, 원자로 안전해석



최 윤 영 (Yun Young Choi)

- 연세대학교 대기과학/기계공학과 학사
- 연세대학교 계산과학공학과 박사
- (현재) 국가수리과학연구소 박사후연구원

• 관심분야: 그래프 뉴럴 네트워크, 다중 물리 모델링, 시계열 데이터 분석



박 수 용 (Soo-Yong Park)

- 서울대학교 원자핵공학과 학사
- KAIST 원자력및양자공학과 석사
- (현재) 한국원자력연구원 리스크평가연구실 책임연구원

• 관심분야: Level 2 PSA, 원전 중대사고 해석/사고관리



권 오 규 (Okyu Kwon)

- KAIST 물리학과 학사
- KAIST 물리학과 석사
- KAIST 물리학과 박사
- (현재) 국가수리과학연구소 공공데이터분석연구팀 팀장

• 관심분야: 교통 및 인간 이동 데이터 분석, 감염병 확산 모델링