JOURNAL OF RADIATION INDUSTRY

Original article

17(1) : 19-32 (2023)
https://doi.org/10.23042/radin.2023.17.1.19

방사성폐기물 핵종분석 검증용 이상 탐지를 위한 인공지능 기반 알고리즘 개발

장승수[1], 이장희[1], 김영수[2], 김지석[3], 권진형[3], 김송현[4,*]

[1]포항공과대학교 첨단원자력공학부, [2]한국원자력연구원 해체기술연구부,
[3]한국원자력연구원 하나로이용부, [4]한국전력 국제원자력대학원대학교 에너지정책학과

Development of an Anomaly Detection Algorithm for Verification of Radionuclide Analysis Based on Artificial Intelligence in Radioactive Wastes

Seungsoo Jang[1], Jang Hee Lee[1], Young-su Kim[2], Jiseok Kim[3], Jeen-hyeng Kwon[3] and Song Hyun Kim[4,*]

[1]Division of Advanced Nuclear Engineering, Pohang University of Science and Technology, 77 Cheongam-ro, Nam-gu, Pohang, Gyeongbuk 37673, Republic of Korea
[2]Decommissioning Technology Research Division / Korea Atomic Energy Research Institute, 111, Daedeok-daero, 989beon-gil, Yuseong-gu, Daejeon 34057, Republic of Korea
[3]HANARO Utilization Division / Korea Atomic Energy Research Institute, 111, Daedeok-daero, 989beon-gil, Yuseong-gu, Daejeon 34057, Republic of Korea
[4]Department of Energy Policy & Engineering, KEPCO International Nuclear Graduate School, 658-91 Haemaji-ro, Seosaeng-myeon, Ulju-gun, Ulsan 45014, Republic of Korea

Abstract The amount of radioactive waste is expected to dramatically increase with decommissioning of nuclear power plants such as Kori-1, the first nuclear power plant in South Korea. Accurate nuclide analysis is necessary to manage the radioactive wastes safely, but research on verification of radionuclide analysis has yet to be well established. This study aimed to develop the technology that can verify the results of radionuclide analysis based on artificial intelligence. In this study, we propose an anomaly detection algorithm for inspecting the analysis error of radionuclide. We used the data from 'Updated Scaling Factors in Low-Level Radwaste' (NP-5077) published by EPRI (Electric Power Research Institute), and resampling was performed using SMOTE (Synthetic Minority Oversampling Technique) algorithm to augment data. 149,676 augmented data with SMOTE algorithm was used to train the artificial neural networks (classification and anomaly detection networks). 324 NP-5077 report data verified the performance of networks. The anomaly detection algorithm of radionuclide analysis was divided into two modules that detect a case where radioactive waste was incorrectly classified or discriminate an abnormal data such as loss of data or incorrectly written data. The classification network was constructed using the fully connected layer, and the anomaly detection network was composed of the encoder and decoder. The latter was operated by loading the latent vector from the end layer of the classification network. This study conducted exploratory data analysis (i.e., statistics, histogram,

http://www.ksri.kr/

Copyright © 2023 by
Korean Society of Radiation Industry

***Corresponding author.** Song Hyun Kim
Tel. +82-52-712-7367 Fax. +82-52-712-7154 E-mail. kimsh@kings.ac.kr
Received 4 November 2022 **Revised** 5 January 2023 **Accepted** 27 March 2023

correlation, covariance, PCA, k-mean clustering, DBSCAN). As a result of analyzing the data, it is complicated to distinguish the type of radioactive waste because data distribution overlapped each other. In spite of these complexities, our algorithm based on deep learning can distinguish abnormal data from normal data. Radionuclide analysis was verified using our anomaly detection algorithm, and meaningful results were obtained.

Key words: Radionuclide analysis, Radioactive wastes, Anomaly detection, Artificial neural network, Clustering

1. 서 론

방사성폐기물은 원자력발전소, 산업현장, 의료시설 등 다양한 분야에서 발생하고 있으며 우리나라 최초의 원자력 발전소인 고리 1호기 원전 해체를 시작으로 방사성폐기물 발생량은 급격히 증가할 것으로 예상된다[1]. 방사성폐기물은 구성 물질 및 이력에 따라 다양한 오염 특성을 가지며 '방사선 안전 관리 등의 기술기준에 관한 규칙'을 준수하여 관리하고 있다[2]. 이를 효율적으로 처리하기 위해서 각 핵종에 대해 농도를 분석하고 폐기물에 포함되어 있는 핵종을 규명하여 주요 핵종의 농도를 정확하게 평가하는 것이 중요하다. 하지만 2019년도에 한국원자력연구원이 경주 방폐장으로 보낸 방사성폐기물에 대하여 측정값을 잘못 기입하거나 아직 검증되지 않은 자체개발 프로그램을 사용하여 핵종분석 오류가 발생하였고 방사성폐기물 처분업무에 막대한 지장이 발생한 사례가 있다[3].

방사성폐기물을 안전하게 관리하기 위해서는 정확한 핵종분석이 필수적이며 이러한 핵종분석 오류를 줄이기 위해서 프랑스의 경우 방사성폐기물 관리 전담기관인 방사성폐기물 관리청이 자체 검증을 실시하고 있으며, 미국의 경우 대학 등의 검증 능력을 갖춘 기관을 제3자로 들여 교차 검증을 수행하고 있다. 국내의 경우 한국원자력연구원 및 한국 수력원자력 주식회사만이 관련 분석기술을 보유하고 있어 당장 검증 능력을 보유한 제3의 기관을 통해 독립적인 검증을 수행하는 것은 우리나라 현실상 어려움이 있다[4]. 따라서 분석기관에서 자체적인 검증 시스템을 확보하는 것이 대안이 될 수 있다.

최근 인공지능을 이용한 핵종분석은 여러 연구진에서 다양한 연구가 진행되고 있다. 청두 공과대학교에서 인공지능 기술 중 합성곱 인공신경망(Convolutional Neural Network)을 사용하여 감마 스펙트럼을 반정량적(Semi-quantitative)으로 분석하였고 합성곱 인공신경망으로 감마 스펙트럼을 분석하는 가능성 연구를 실시하였다[5]. 일리노이대학 소속의 Mark Kamuda의 연구팀은 핵종의 스펙트럼을 1-D 합성곱 인공신경망(1-Dimensional Convolutional Neural Network)과 순방향 신경망(Feedforward Neural Network)을 이용하여 핵종 혼합 계수(Mixing Coefficient)을 예측하고 두 신경망의 성능을 비교하였다[6]. 또한 로스앨러모스 국립 연구소 Eric Shumaker의 연구진은 두 개의 인공신경망(Twin Neural Network) 구조를 이용하여 신속하게 핵종을 분류할 수 있는 가능성을 제시[7]하였고 오리건주립대 소속 Mario Gomez-Fernandez의 연구진은 핵종의 에너지 스펙트럼을 해석할 때, 1-D 합성곱 인공신경망과 순방향 신경망을 이용하여 핵종 분류를 시도하고 성능을 평가하였다[8].

본 연구에서는 자체적인 검증 시스템을 확보하기 위해 인공지능 기반의 핵종분석 검증 자동화 시스템을 구축하고자 한다. 오류의 세부내용은 드럼 시료 데이터의 망실, 시료 측정 후 다른 값 기재, 방폐물 발생 정보가 유사하지 않은 드럼 그룹핑, 척도 인자 적용 대상이 아닌 방폐물에 대한 오적용 등이 있다. 이러한 다양한 오류들을 여러 가지 필터 알고리즘을 사용해서 해석하게 되면 상황에 따른 변수에 대하여 대응이 불가능하므로 현장에서 사용할 수 있을 정도의 정확도를 얻기 힘들다. 하지만 인공지능 기술을 이용하게 되면 단순 알고리즘을 이용해서 풀지 못하는 문제를 풀 수 있으며 분석 시간도 확연하게 줄여줄 수 있는 장점이 있다. 다양한 핵종이 들어간 샘플을 분석하기 위해서 인공지능 기술 중 딥러닝(Deep Learning) 기반의 인공신경망을 제작하였다. 딥러닝 이상 탐지(Anomaly Detection) 기술[9,10]을 이용하여 효율적인 핵종 분석 알고리즘을 구축하고 분석 결과의 신뢰성을 확보하는 것이 목표이다.

향후 증가할 것으로 예상되는 방사성폐기물의 안정적인 처리를 위해 본 연구진은 인공지능 기반 방사성폐기물 핵종분석을 할 수 있는 교차 검증 기술 개발을 하여 기존

의 분석방법을 검증하고 향후 대량 해체 폐기물에 대해서도 신속 정확한 핵종 분석이 가능한 활용체계를 구축하고자 한다.

2. 재료 및 방법

2.1. 핵종분석 검증 기술 개발 현황

한국원자력안전기술원에서는 원자력 시설 해체 및 방사성폐기물 처분 전 관리 규제 기술, 선진핵연료주기 및 사용후 핵연료 장기저장 규제 기술, 방사성폐기물 처분 안전성 검증 규제 기술을 개발하는 연구를 수행하였다[11]. 또한 방사성폐기물 관리와 안전성 확인을 위하여 규제 요건 및 현황을 검토하였고 처분 전, 해체 및 사용후 핵연료와 관련된 평가 기준을 마련하는 연구를 수행하였다. 한국원자력연구원에서는 규제 대상 방사성 핵종 화학 분리 및 정량 요소 기술 개발, 원자력 시설 현장 시료 특성평가, 해체 방사성폐기물 유형별 방사화학 분석기술을 검토하였다. 핵종 재고량 분석, 저준위 핵종분석, 난분석 등과 같은 상세 기술 개발은 다수 이루어졌으나, 인공지능 기반 핵종분석이나 핵종분석 검증 기술 개발 등에 관한 연구는 이루어지지 않고 있다[12].

미국, 프랑스, 스페인과 같은 선진국은 이미 핵종분석이 가능한 기관이 추가로 참여하는 교차 검증 시스템을 갖추고 방사성폐기물 관리 안전성을 평가하고 있다. 국내의 경우 한국원자력연구원 및 한국수력원자력 주식회사만이 관련 분석기술을 보유하고 있어 당장 검증 능력을 보유한 제3의 기관을 통해 교차 검증을 수행하는 것은 어려운 실정이다.

2.2. 핵종결정 및 농도 분석 시 발생 가능 오류 분석

방사성폐기물 핵종결정 및 농도 분석 시 발생 가능한 오류를 분석하기 위해, 기존에 원자력안전위원회 주관으로 방사성폐기물 핵종 농도 분석 오류에 대한 조사 결과 자료를 참고하였다. 오류의 유형으로는 시료 측정 후 다른 값을 기재하거나, 시료 데이터의 망실, 계산 수식 적용의 오류, 핵종분석 데이터 관리 시스템의 오류 등이 있었다. 원자력연구원이 2015년 이후 경주 방폐장으로 인도한 방폐물 2,600드럼 중 2,111드럼에 기재한 일부 핵종 농도 정보에 오류가 있었으며, 한수원이 의뢰한 원전 방폐물 분석 과정에서 3,465개의 분석 대상 데이터 중 167개 데이터에 오류가 있음을 확인하였다. 세부 오류 내용은 Table 1과 같다.

Table 1. Specific error list of radionuclide analysis

Error type	KAERI Radioactive wastes (number of drums with errors)	Nuclear plant Radioactive wastes (number of data with errors)
① Loss of radionuclide analysis data - Invalid concentration value in results of nuclide analysis - Nuclide analysis data does not exist	64	-
② Incorrect values are fed into database - Applied as one of unsuitable values (median, minimum, maximum)	609	64
③ Grouping with dissimilar radioactive wastes - Grouping with irrelevant data instead of similar data on date or area	124	-
④ Misapply scale factor to radioactive wastes - Calculated radionuclide concentration from incorrect scale factor	4	-
⑤ Error in applying calculation formula / input data - In case of incorrectly calculated concentration in radionuclide analysis	900	79
⑥ Error in management system of radionuclide analysis - Deduce incorrectly calculated concentration because of system malfunction occurring	1,559	24
Total number of errors	3,260 (2,111)	167

Pressurized Water Reactors

DATE	PLT	LAB	SAMPLE	H-3	C-14	Fe-55	Co-60	Ni-63	Sr-90	Tc-99	I-129	Cs-137	Ce-144	Pu-238	Pu-239	Pu-241	Am-241	Cm-242	Cm-244
830725	17	SAI	RESIN	2.9E-03	5.8E-03	6.1E-01	1.1E+00	1.3E+00	2.4E-02	-1.1E-03	-6.1E-05	1.3E+01	5.7E-03	7.9E-05	4.1E-05	4.9E-03	2.9E-05	4.1E-05	2.8E-05
831103	17	SAI	RESIN	1.1E-03	3.0E-03	2.6E-02	1.6E-01	2.3E-02	-1.6E-04	-3.3E-04	-2.8E-05	2.9E-01	4.3E-03	1.2E-04	1.0E-04	6.0E-03	1.1E-04	1.7E-05	5.8E-06
840301	17	SAI	DAW	5.1E-04	9.3E-05	5.3E-03	2.6E-04	6.6E-04	3.7E-05	-1.1E-04	-3.6E-05	2.9E-04	-1.0E-05	2.2E-06	1.6E-06	1.2E-03	1.2E-06	2.3E-06	-2.7E-07
840301	17	SAI	FILTER	2.7E-04	1.5E-03	5.8E-01	4.0E-01	3.6E-01	4.5E-04	-2.2E-04	-2.5E-05	8.2E-01	-1.6E-03	5.0E-05	4.2E-05	4.3E-03	2.6E-05	3.3E-05	2.2E-05
840906	17	SAI	RESIN	1.5E-02	3.5E-02	2.4E-01	1.8E-01	3.3E-01	6.3E-03	-2.8E-06	-3.4E-06	1.2E+00	1.5E-03	1.7E-05	1.9E-05	1.8E-03	6.0E-06	2.7E-06	3.1E-06
841126	17	SAI	FILTER	-4.9E-04	3.1E-03	1.3E+00	2.3E+00	1.9E+00	1.6E-03	-3.1E-05	-4.0E-05	7.6E-01	2.2E-01	1.1E-04	9.2E-05	7.2E-03	1.9E-03	2.1E-03	1.4E-03
841126	17	SAI	DAW	-2.5E-04	-4.3E-05	1.8E-02	8.0E-04	5.3E-03	-4.8E-05	-2.9E-05	-3.8E-05	1.6E-03	-1.5E-04	1.3E-06	-2.0E-06	-7.0E-04	-2.0E-06	-4.0E-07	-5.0E-07
841127	17	SAI	WSTE OIL	-2.4E-05	-8.2E-07	-7.4E-06	3.8E-06	2.0E-04	-1.1E-06	-7.0E-07	-1.1E-06	-3.7E-07	-4.9E-06	4.8E-08	-4.3E-08	-6.9E-06	-2.6E-08	-1.3E-08	-2.0E-08
830804	18	SAI	RESIN	4.3E-02	1.0E-02	1.8E-01	1.7E+01	3.5E+00	1.3E-02	-3.2E-06	-1.7E-06	1.3E+00	1.1E-02	4.8E-05	2.5E-05	2.4E-03	9.5E-06	1.8E-04	1.1E-05
830804	18	SAI	RESIN	6.0E-03	3.9E-04	2.7E-01	6.2E-01	1.4E-01	9.6E-04	-2.7E-06	-1.1E-06	7.9E-02	-4.5E-05	6.6E-07	4.4E-07	1.1E-04	2.1E-07	-1.0E-06	-7.7E-08
830804	18	SAI	RESIN	1.2E-02	6.4E-02	4.4E-01	8.5E+00	1.5E+00	1.3E-02	-7.4E-07	-1.5E-06	2.7E+00	6.9E-03	8.4E-05	4.5E-05	4.9E-03	2.0E-05	1.9E-04	2.0E-05
840326	18	SAI	CHARCOAL	2.9E-04	8.6E-06	-4.0E-05	-9.9E-07	6.4E-05	-1.5E-06	-9.7E-07	-6.4E-07	-7.3E-07	-4.1E-07	3.6E-08	5.6E-09	1.7E-05	-2.3E-08	-2.1E-09	2.0E-08
840418	18	SAI	RESIN	1.4E-02	3.4E-05	1.0E-01	8.3E-02	3.6E-02	1.1E-05	-4.5E-06	-1.1E-06	4.9E-04	1.2E-04	4.5E-06	1.9E-06	2.0E-04	5.9E-07	3.1E-06	8.7E-07
840423	18	SAI	DAW	1.2E-03	6.9E-05	5.1E-02	3.2E-02	4.7E-02	2.3E-04	-4.7E-05	-8.1E-05	5.1E-02	-2.3E-04	3.9E-06	3.6E-06	7.1E-04	2.7E-06	3.0E-06	1.0E-06
840612	18	SAI	RESIN	1.2E-02	4.6E-04	3.7E-02	6.4E-01	4.8E-01	4.7E-04	-2.4E-06	-2.3E-06	-5.9E-04	2.8E-03	1.0E-05	3.4E-06	4.1E-04	2.2E-06	5.3E-05	1.2E-05
840612	18	SAI	EVAP BOTT	6.8E-03	8.8E-05	5.0E-03	1.4E-02	1.2E-02	2.7E-05	-2.6E-06	-1.5E-06	1.4E-02	5.1E-05	7.9E-08	4.9E-08	6.5E-06	5.9E-08	7.4E-07	2.0E-07
840806	18	SAI	RESIN	5.3E-03	3.0E-05	4.4E-03	1.9E-02	2.1E-03	1.4E-05	-5.5E-07	-6.4E-07	1.3E-02	-8.3E-06	9.0E-08	1.3E-07	2.6E-05	1.1E-07	3.2E-07	1.5E-07
840806	18	SAI	CHARCOAL	2.0E-04	9.7E-05	1.2E-02	2.3E-02	3.6E-03	8.0E-06	-5.1E-07	-7.7E-07	9.8E-04	1.1E-08	5.2E-07	2.3E-07	2.3E-05	8.6E-07	2.3E-06	1.0E-06
840806	18	SAI	FILTER	6.6E-04	2.1E-03	1.4E+00	3.8E+00	5.3E-01	5.2E-04	-8.4E-06	-1.3E-05	3.8E-02	6.1E-04	1.3E-04	9.0E-05	7.7E-03	4.2E-06	1.5E-05	5.7E-06
840808	18	SAI	RESIN	9.4E-03	9.1E-03	3.2E-02	5.2E-01	7.2E-01	2.0E-03	-3.7E-05	-8.8E-06	5.1E+00	2.8E-03	1.0E-05	3.2E-06	5.5E-04	3.0E-06	4.3E-05	1.3E-05
840815	18	SAI	RESIN	6.3E-02	1.7E-02	4.4E+00	1.0E+01	4.4E+00	8.6E-03	1.2E-05	-3.1E-06	1.9E-01	2.6E-02	2.8E-04	1.3E-04	1.6E-02	5.5E-05	2.0E-04	4.4E-04
840816	18	SAI	RESIN	5.1E-02	1.9E-01	4.1E+01	5.1E+01	5.7E+00	3.0E-01	-3.1E-04	-2.5E-05	2.4E+00	1.1E-01	4.1E-04	2.6E-04	7.3E-02	6.4E-05	2.6E-03	2.3E-04
840927	18	SAI	DAW	3.8E-04	1.6E-02	9.8E-01	2.3E-01	2.2E-01	1.1E-04	-5.3E-05	-3.5E-05	1.1E-02	4.3E-04	2.2E-05	1.0E-05	1.5E-03	3.9E-06	1.0E-05	4.1E-06
841114	18	SAI	RESIN	1.2E-02	2.3E-02	7.2E+01	2.9E+02	6.5E+01	2.3E-02	-9.4E-05	-1.6E-05	1.3E+02	-4.3E-02	1.7E-03	7.0E-04	3.4E-01	4.4E-04	4.0E-04	-1.7E-04
841229	18	SAI	EVAP BOTT	1.8E-02	9.6E-05	8.7E-03	3.1E-02	2.5E-02	5.3E-05	-5.6E-07	-5.2E-07	1.5E-02	3.8E-05	2.4E-07	1.5E-07	1.9E-05	8.4E-08	4.4E-07	6.5E-08
850225	18	SAI	RESIN	1.7E-02	2.3E-04	1.5E-02	2.8E-01	2.3E-02	5.2E-04	-5.4E-06	-9.6E-06	4.9E-02	-3.8E-04	2.2E-06	1.2E-06	2.4E-04	1.2E-06	2.2E-06	7.2E-07
850225	18	SAI	FILTER	1.3E-03	3.0E-04	3.7E-01	5.9E-01	7.1E-02	-6.9E-05	5.5E-02	-2.6E-05	-4.9E-04	-6.6E-04	1.9E-05	1.2E-05	2.9E-03	9.4E-06	4.3E-05	1.2E-05
850226	18	SAI	DAW	2.7E-03	3.0E-04	3.8E-02	2.6E-02	3.4E-03	-7.5E-05	2.6E-05	-8.6E-05	3.4E-03	8.3E-05	7.9E-06	5.4E-06	3.0E-03	3.8E-06	1.9E-06	1.5E-06
850307	18	SAI	RESIN	1.3E-02	2.5E-02	2.9E-01	6.6E+00	3.0E+00	4.6E-03	-1.5E-05	-4.8E-05	5.6E+00	-2.7E-04	1.9E-05	1.3E-05	2.3E-03	3.2E-06	4.8E-06	2.3E-06
850322	18	SAI	FILTER	1.6E-03	9.1E-03	1.2E+01	7.2E+00	8.7E-01	1.1E-03	-2.9E-04	-7.1E-05	1.1E-02	3.6E-02	2.8E-04	3.4E-04	2.8E-02	7.6E-05	1.3E-03	1.3E-04
850408	18	SAI	FILTER	1.9E-01	1.1E-02	7.0E+00	5.2E+00	7.2E-01	2.3E-03	-4.0E-05	-1.6E-05	-5.8E-03	4.3E-02	2.9E-04	7.6E-04	5.5E-02	1.5E-04	1.1E-03	1.4E-04
850417	18	SAI	FILTER	1.0E-03	1.4E-03	4.5E+00	6.3E+00	4.0E-01	-1.2E-04	-1.5E-04	-1.6E-05	-8.4E-03	2.2E-03	1.2E-05	4.2E-06	2.7E-03	2.9E-05	6.0E-05	2.4E-05
850605	18	SAI	RESIN	3.1E-02	6.0E-04	8.9E-02	3.1E+00	2.1E+00	5.8E-03	-6.5E-05	-3.7E-06	1.9E-01	3.4E-03	5.3E-05	3.5E-05	2.8E-03	5.1E-06	4.6E-05	1.2E-05
850701	19	SAI	RCS	1.2E-02	-6.3E-06	6.3E-04	8.3E-03	1.1E-03	-1.7E-06	-2.3E-06	-4.8E-06	-3.1E-05	-1.3E-05	4.8E-07	2.2E-07	1.8E-05	5.0E-07	2.1E-07	-1.1E-07
850701	19	SAI	RCS	-3.1E-04	-2.4E-05	2.8E-03	2.3E-03	-8.0E-04	-4.7E-05	-4.7E-05	-3.4E-05	-1.1E-05	-5.5E-03	4.1E-06	1.4E-06	-1.7E-04	9.3E-07	-1.8E-07	-2.0E-07
850701	19	SAI	WASTE WTR	-3.7E-06	-6.2E-08	-8.2E-08	-4.4E-08	-2.6E-07	-1.6E-08	-1.8E-08	-4.7E-08	-3.3E-08	-1.2E-07	5.1E-09	-1.6E-09	-4.2E-07	-1.3E-09	-6.3E-10	-2.7E-10
850701	19	SAI	WASTE WTR	-4.0E-04	-2.2E-05	2.9E-04	-3.4E-06	9.0E-04	-4.0E-05	-5.5E-05	-4.4E-05	1.3E-05	-6.1E-03	3.1E-06	3.3E-06	-1.8E-04	-4.8E-07	-1.6E-07	-2.5E-07

Fig. 1. Radionuclide analysis data of the NP-5077 report for pressurized water reactor.

2.3. 데이터 수집방법

본 연구에서 사용되는 데이터는 발전소 시설에서 발생하는 방사성폐기물에 대한 데이터를 활용하는 것이 가장 이상적이나, 현실적으로 이를 직접 사용하는 데에 어려움이 따른다. 이에 본 연구개발에서는 EPRI (Electric Power Research Institute)에서 발간한 Updated Scaling Factors in Low Level Radwaste (NP-5077) [13]를 토대로 하여 데이터베이스를 확보하고 이를 바탕으로 리샘플링을 통해 가상 데이터를 마련하여 학습을 수행하는 방식을 택하였다. 본 데이터는 14개의 비등경수로와 31개의 가압경수로로부터 발생한 방사성폐기물로부터 샘플링하여 미연방정부법(10CFR61)에 준하는 분석을 수행한 데이터이다. Fig. 1은 해당 보고서 Appendix A에 제시된 가압경수로 방사성폐기물 분석 결과의 일부를 발췌한 것이다.

NP-5077 보고서에 수록된 가압경수로 방사성폐기물 분석 결과 데이터는 총 481개의 샘플에 대해 분석한 결과를 담고 있으며, 각 분석 결과마다 분석 일시, 발전소 번호, 분석을 수행한 실험실, 시료 분류, 16개의 핵종 재고량을 제시하고 있다. 해당 자료로부터 시료 분류 정보와 16가지 핵종별 재고량 정보를 추출하여 데이터베이스화하였다. 해당 데이터베이스에서 시료 분류 그룹별로 데이터의 개수를 살펴본 결과, 수지 (RESIN) 139개, 건식 방사성폐기물 (DAW) 96개, 필터 (FILTER)가 89개로 나타났고, 이외의 분류 그룹은 해당 데이터 개수가 너무 적어 인공지능 모델에 사용하기 부족하여 제외하였다. 이 데이터베이스도 분류 그룹당 데이터 수가 100개 남짓으로, 인공지능 모델에 바로 사용하기에는 부족[14]하여 머신러닝 기반의 데이터 오버샘플링 방법론 중 하나인 SMOTE (Synthetic Minority Oversampling Technique) 알고리즘을 활용하였다[15]. 이는 데이터 간의 상관성을 유지시키며 데이터를 리샘플링 (resampling)하는 방법으로 방사성폐기물의 핵종 농도와 같이 각 핵종별 재고량 간 강한 상관성을 지니는 데이터에 대해서도 그 성질을 유지하며 데이터의 양을 증식시킬 수 있어 적합하다 할 수 있다. 데이터를 증식시킬 때, 기존 데이터 중 이상치를 제거해 주는 과정을 거쳤다. 기준치보다 에러 값이 높으면 해당 데이터를 지우고 기준치보다 낮으면 데이터 생성을 멈추게 된다. 본 과제에서는 SMOTE 기법을 이용하여 인공신경망 학습을 위

```
Classes = [ 'DAW' , 'FILTER' , 'RESIN' ]
for class in Classes :
  while True :
    class smote data = SMOTE(data = class original data)
    train(epoch = 5000, data = class smote data)
    MSE = test(data = class original data)
    index = MSE.argmax()
    class original data.drop(index)
    if # of over values < 4:  (apply over value threshold)
      break
```

Fig. 2. Pseudo code for data augmentation with SMOTE algorithm.

한 각 폐기물 종류별 데이터의 수를 잡고체 49,904개, 필터 49,911개, 수지 49,861개로 생산하였다. SMOTE 기법을 이용한 데이터 증식 의사 코드(Pseudo Code)는 Fig. 2와 같다. 생성된 데이터는 인공신경망 교육에 사용되었고 NP-5077 보고서 데이터는 데이터 검증에 사용되었다.

2.4. 핵종분석 검증용 이상치 탐지 알고리즘

본 연구에서는 핵종분석 결과를 검증할 수 있는 이상치 탐지 알고리즘을 개발하였다. 알고리즘은 폐기물의 종류가 정확하게 분류되었는지 판별하고 판별이 완료된 데이터에 대하여 다양한 원인에 의해 입력 데이터가 잘못 기입된 경우를 검출해 낸다. 알고리즘을 도식화하면 Fig. 3과 같다.

분류 인공신경망은 16개의 핵종별 개수 정보를 인공신경망에 넣어 폐기물의 종류를 예측하며, 실제 데이터에 기입되어 있는 폐기물의 종류를 비교하여 폐기물 종류의 오류를 탐지하는 알고리즘이다. 인공신경망은 Fully Connected Layer를 이용하여 신경망을 구성하였다. 반복적인 민감도 분석을 통해 Node는 16 (input) - 12 - 12 - 8 - 8 - 4 - 4 - 3 (ouput)으로 설계하였다. 설계된 분류 인공신경망은 SMOTE 데이터로 증식시킨 데이터를 이용하여 기계학습을 수행하고, 학습에 활용되지 않은 원본 데이터를 이용하여 인공신경망의 성능을 검증하였다. 본 인공신경망 학습에 사용된 하이퍼 파라미터는 Table 2와 같다.

폐기물의 종류 판별이 끝난 데이터를 이상 탐지 인공신경망을 통해 입력에 오류가 있는 데이터를 검출하였다. 해당 이상 탐지 인공신경망은 교육된 분류 인공신경망의 마지막 앞단까지 파라미터를 불러오고 4차원 잠재공

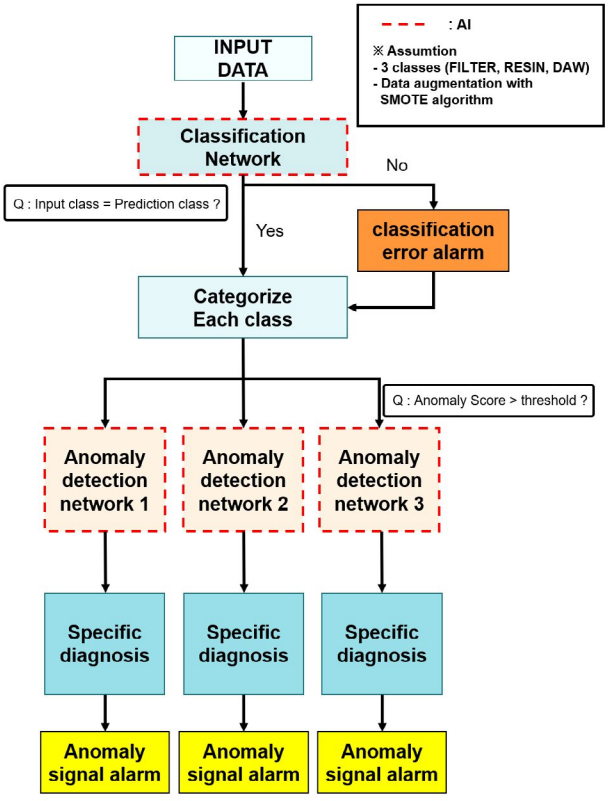

Fig. 3. Architecture of anomaly detection algorithm for verification of radionuclide analysis.

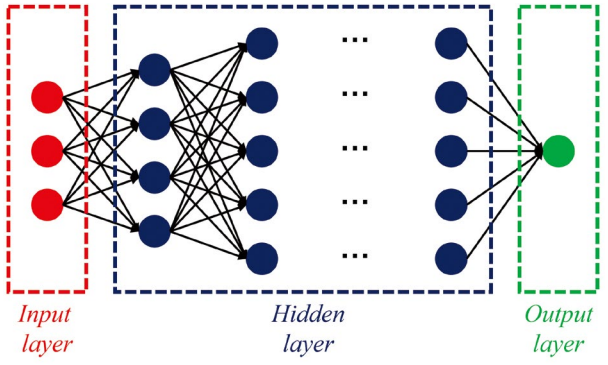

Fig. 4. Artificial neural network for classification of radioactive waste.

간(Latent Space)에서 군집화된 벡터를 이용해 이상 탐지를 수행하는 것이 특징이다. 이를 도식화하면 Fig. 5와 같다. 이상 탐지 인공신경망은 크게 인코더(Encoder), 디코더(Decoder), 잠재 벡터(Latent vector) 3가지 구간으로 나눌 수 있다. 인코더 구간에서 입력 데이터의 정보를 잠재벡터로 압축하는 역할을 수행한다. 이때, 인공신경망 교

육 시 다수의 데이터를 통해 중요한 정보를 추출하여 압축한다. 디코더 구간에서 압축된 잠재 벡터에서 원본 데이터로 복원하도록 인공신경망의 교육을 수행하였다. 복원된 데이터와 입력 데이터 간의 차이를 손실 함수(loss function)를 통해 계산하고 계산된 손실 값을 역전파(back propagation)를 이용하여 인공신경망을 교육하였다.

교육이 완료된 인공신경망은 정상 데이터가 입력으로 들어올 경우, 잠재 공간의 벡터로 정상 데이터가 압축되고 디코더를 통해 원활하게 데이터를 복원하여 이상치가 낮게 나타난다. 반면, 비정상 데이터가 입력으로 들어올 경우, 디코더를 통해 데이터 복원 시 정상적으로 복원이 이루어지지 않아 이상치 값이 높게 나오게 되어 이상치를 탐지하게 된다. 전체적인 인공신경망은 Fully connected layer를 이용하여 신경망을 구성하였으며, 각 Node는 4 (latent vector) - 4 - 2 - 4 - 4 (output)로 설계하였다. 이상치 탐지 인공신경망 교육에 사용된 하이퍼 파라미터는 Table 3과 같다.

Table 2. Hyper parameters for classification network training

Hyper parameter	Value
Optimizer	Adam
Loss	Cross Entropy
Learning rate	1e-3
Epoch	2,000
Batch size	1,024
Data Shuffle	True

3. 결 과

3.1. 데이터 분포 및 특성 분석

본 연구에 사용된 NP-5077 보고서 데이터를 효율적으로 다루기 위해 탐색적 자료 분석(Exploratory data analysis)을 실시하였다. 데이터의 분포를 정량적으로 분석하기 위해 상자 그림(Box plot), 히스토그램(Histogram)을 제작하였다. 상자 그림은 제1사분위수(Q1), 제2사분

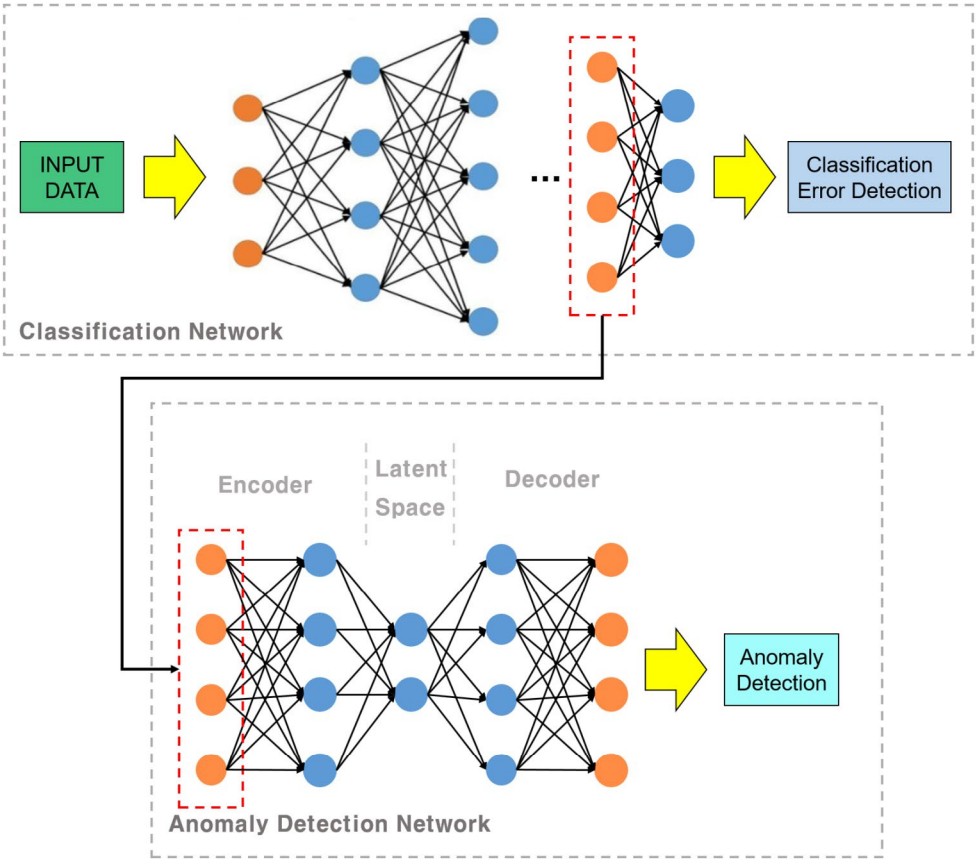

Fig. 5. Architecture of anomaly detection network for detecting abnormal data.

위수(Q2), 제3사분위수(Q3), 사분위 범위 수(IQR), 이상치(outlier)를 이용하여 데이터 분포의 특징을 나타낼 수 있다. 각 핵종에 대하여 분석의 용이성을 위해 로그 스케일로 변환하였다. 실제 핵종의 양이 0인 경우 값을 1로 치환한 후 로그 스케일로 변환하여 수지(RESIN), 잡고체(DAW), 필터(FILTER)에 대해 통계적으로 분포를 분석하였다. 각 핵종 및 폐기물 종류에 대하여 상자 그림을 그린 결과는 Fig. 6과 같다.

Table 3. Hyper parameters for anomaly detection network training

Hyper parameter	Value
Optimizer	Adam
Loss	Cross Entropy
Learning rate	5e-3
Epoch	2,000
Batch size	1,024

또한 데이터에 로그 스케일로 변환 후 가우시안 혼합 모델(Gaussian Mixure Model)로 곡선을 피팅(fitting)하였고 curve의 하부 면적이 1이 되도록 정규화를 거친 후 핵종별 히스토그램으로 정리한 그림은 Fig. 7과 같다.

추가적으로 핵종별 상관관계(Correlation)를 분석하였다. 각 핵종별 상관관계를 행렬 형태로 나타낸 그림을 Fig. 8에 정리하였다. 몇 가지 핵종과 서로 강한 상관관계를 갖는 사실과 폐기물 종류에 따라 행렬의 형태가 다소 다름을 확인하였다.

16개의 핵종 간의 상관관계를 이용하여 인공신경망의 효율적인 교육을 위해 주성분 분석(Principal Component Analysis)을 수행하였다. 주성분 분석을 통해 서로 종속적인 핵종 간의 관계를 이용하여 새로운 기저(basis)를 생성함으로써 차원을 축소할 수 있다. 16개 핵종의 공분산 행렬을 이용하여 설명된 분산(explained variance)을 구

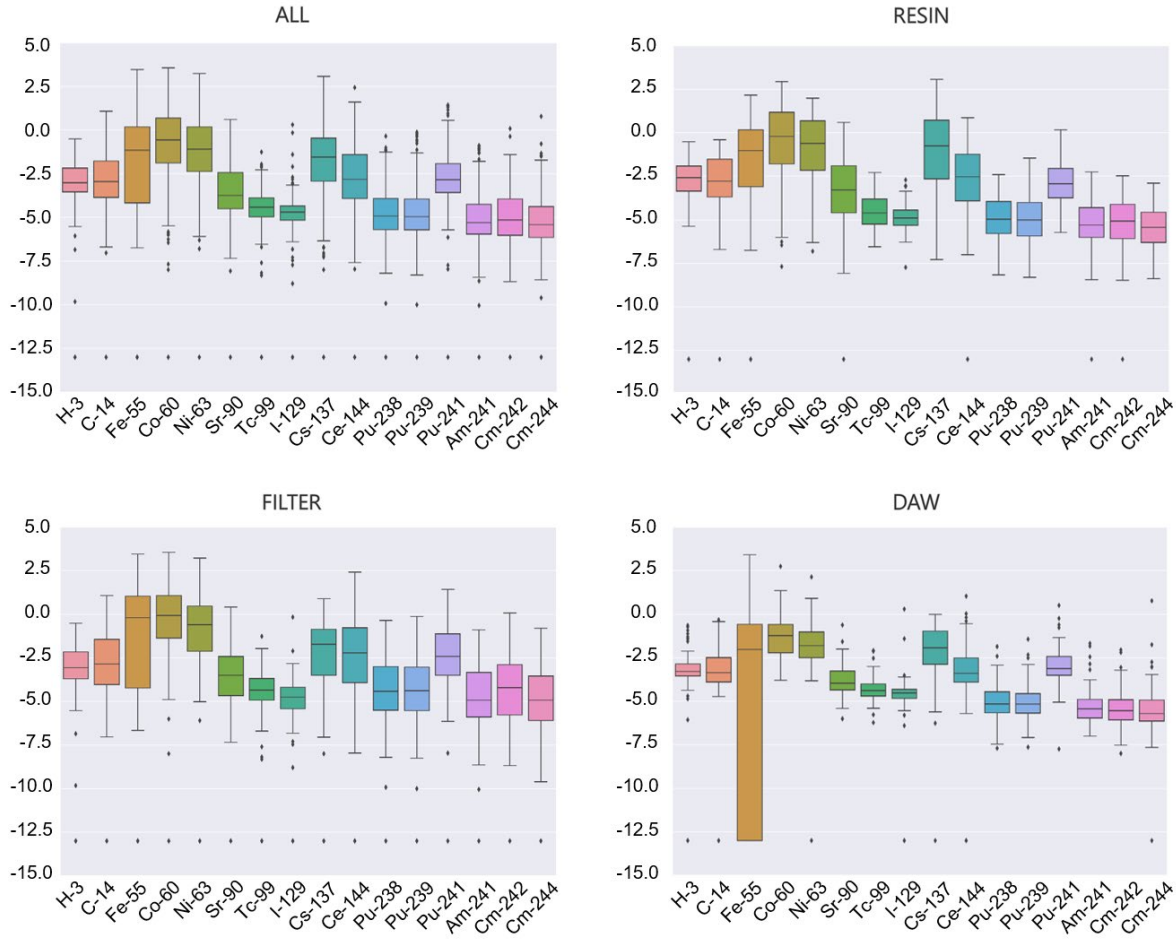

Fig. 6. Data distribution of each radioactive waste class with logarithm scale.

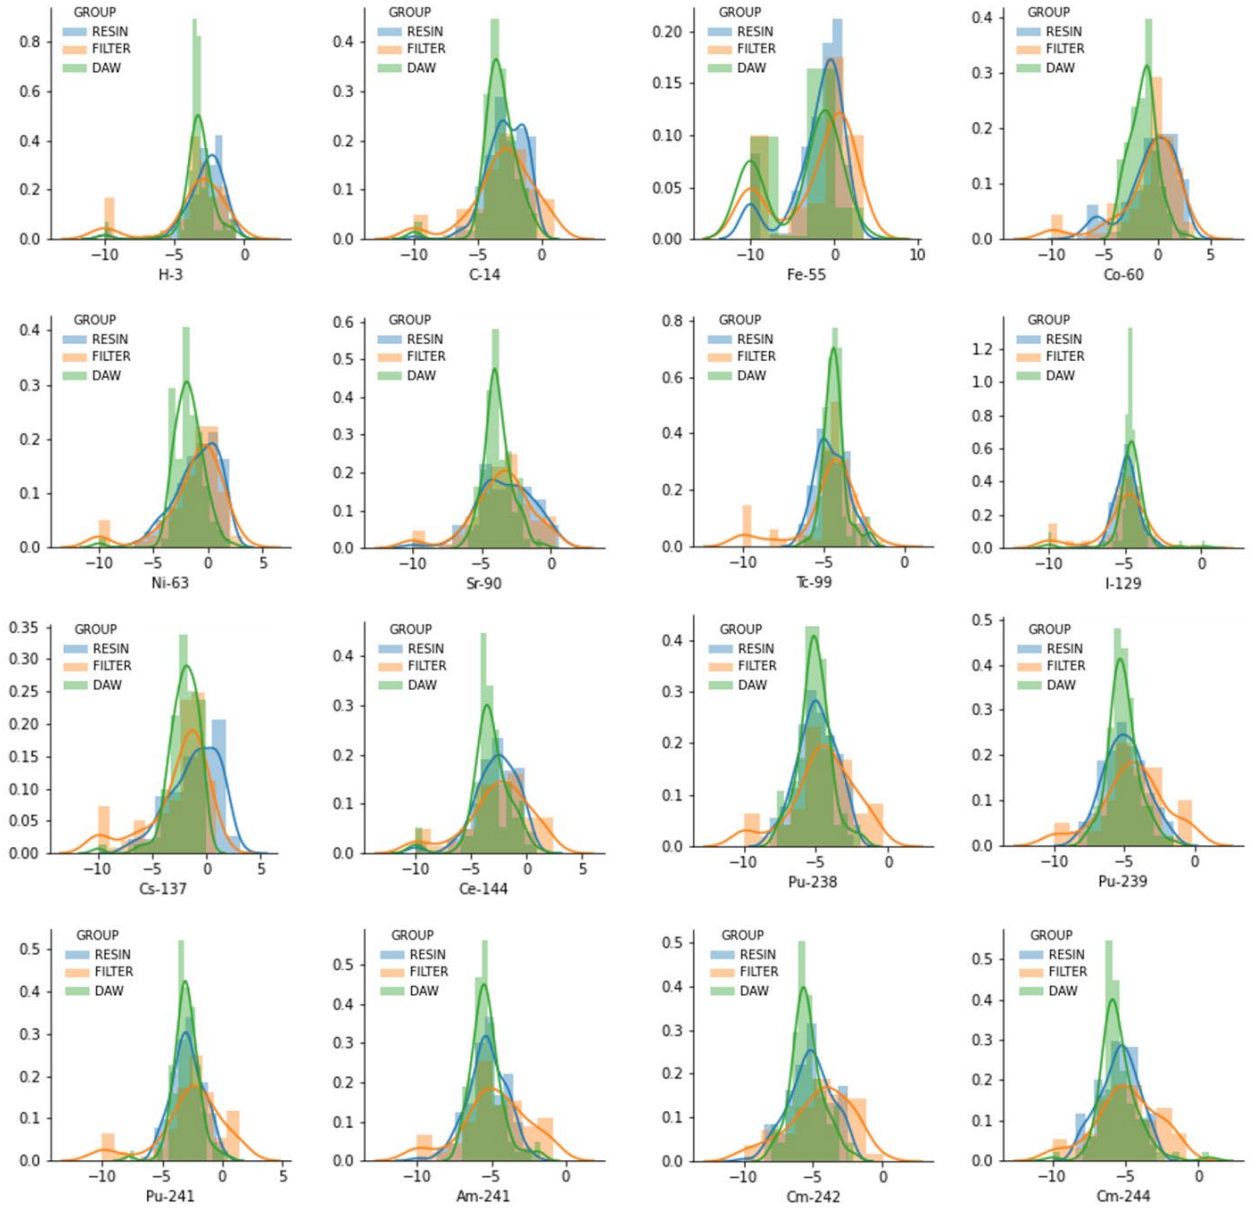

Fig. 7. Histogram of each radioactive waste class with logarithm scale.

하고 각 성분의 설명력 비율을 구한다. 차원 축소 시 8차원으로 축소를 하였을 경우 8번째 성분까지의 누적 설명력 비율이 90%가 넘어가므로 8차원으로 축소하였다. 주성분 분석으로 축소된 각 차원에 대하여 설명 분산 비율(Explained variance ratio)을 구하면 Table 4와 같다.

차원을 8차원으로 압축시킨 후 상자 그림을 그려서 통계적 분포를 분석하였다. Fig. 9는 잡고체, 필터, 수지 데이터를 8차원 데이터로 압축시킨 후 상자 그림을 그려서 분포를 분석한 도표이다. 3가지의 폐기물에 대해 첫 번째 주성분(pc1)에 대해서는 잡고체의 분포가 다소 다를 뿐 뚜렷하게 구분되는 특성을 보이지 않았다.

3.2. 데이터 군집화 알고리즘을 이용한 분석

앞서 분석한 내용과 같이 다른 폐기물 종류 간에 데이터 분포에는 큰 차이가 없어 데이터 입력 실수와 같은 인적오류가 발생하더라도 육안으로 판별하기 힘들다. 기존의 알려진 k-평균 군집화 알고리즘(k-means clustering algorithm) [16]을 이용하여 특성을 추출하고 군집화를 시도하였다. k-평균 군집화 알고리즘을 이용하여 모든 경우의 수에 대하여 군집화 성능을 확인하였다.

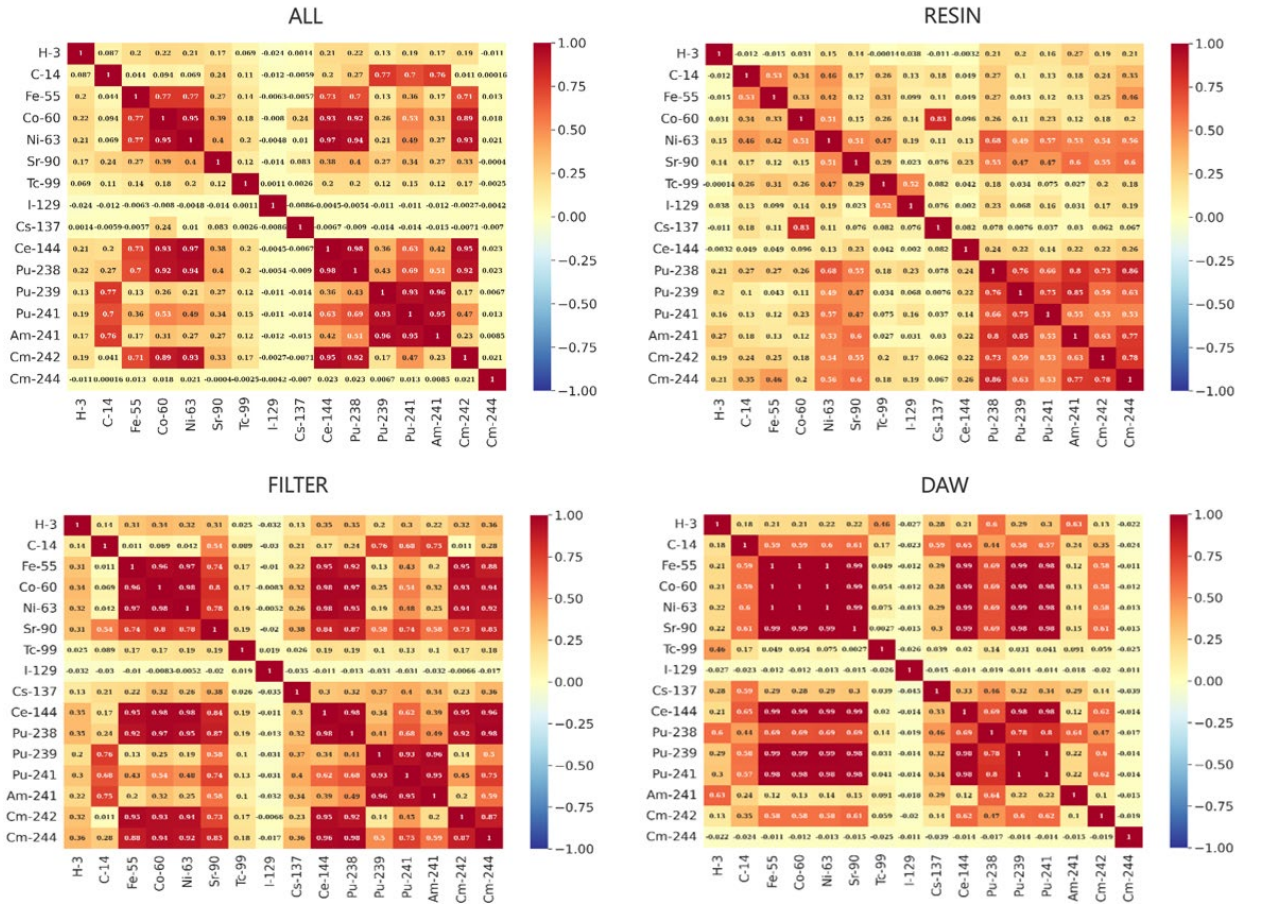

Fig. 8. Matrices of correlation for radioactive wastes.

Table 4. Explained variance ratio of principal components

Principal component number	Explained variance ratio
1	0.59869087
2	0.09734624
3	0.05939431
4	0.05441068
5	0.03382827
6	0.02952543
7	0.02644742
8	0.02396962

16개의 핵종중 n개의 핵종을 선택하여 나오는 경우의 수는 총 $\sum_{n=1}^{16}\binom{16}{n}=2^{16}-1=65{,}535$개이며, 자체적으로 제작한 군집화 지수를 이용하여 군집화 성능을 평가하였다.

k-평균 군집화 알고리즘은 데이터의 특징이 비슷한 값들을 모아 k개의 군집을 만들어 분류하고 본 데이터에 대해서는 3개의 군집을 만들었다. 분류된 군집들이 잡고체, 필터, 수지 중 어떤 폐기물에 해당하는지는 알 수 없으므로 군집 결과를 군집 1 (C1), 군집 2 (C2), 군집 3 (C3)으로 정의하고 다음과 같은 자체 개발한 k-평균 군집화 알고리즘 지수를 도입하였다.

$$\text{군집화 지수} = \sum_{n=1}^{3} score - Cn$$

$$= \sum_{n=1}^{3} 3\max(Cn) - CnRESIN - CnFILTER - CnDAW$$

score-Cn: n번째 군집에 해당하는 군집화 지수

max (Cn): n번째 군집으로 판별된 데이터 중 *CnRESIN*, *CnFILTER*, *CnDAW* 중에 가장 큰값

CnRESIN: n번째 군집 중 실제 라벨이 RESIN인 데이터의 수

CnFILTER: n번째 군집 중 실제 라벨이 FILTER인 데이터의 수

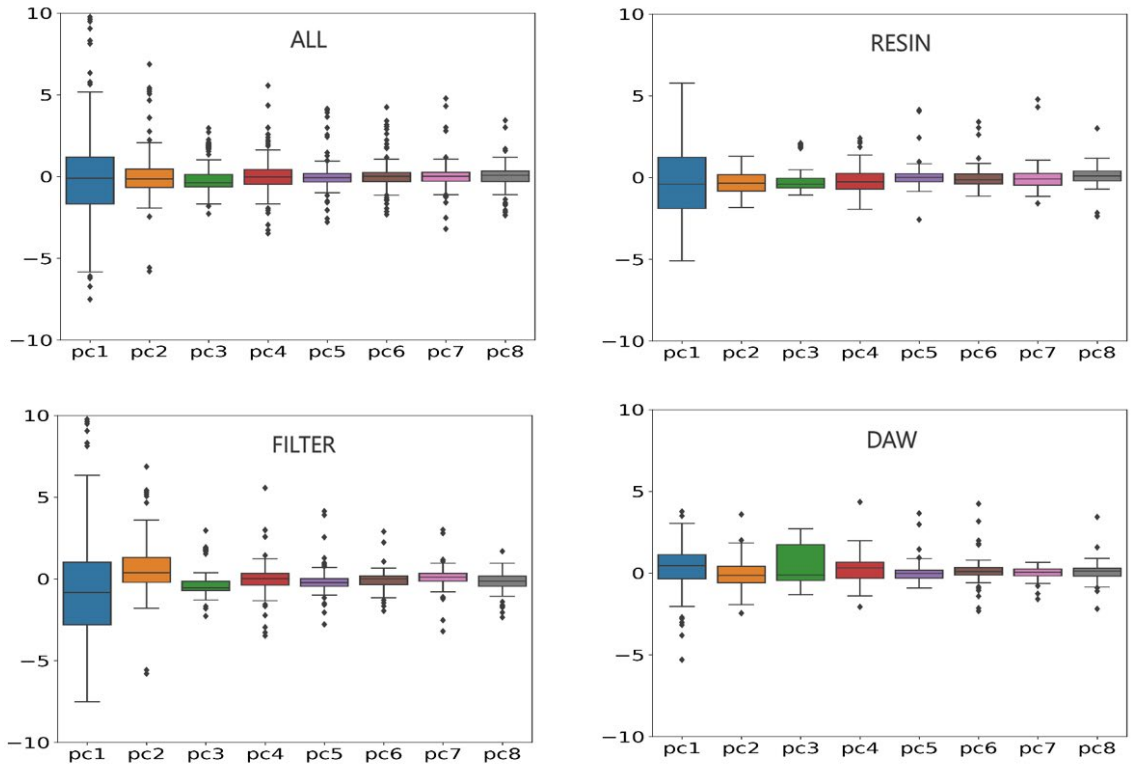

Fig. 9. Results of principal component analysis (PCA) with 8 dimensions.

CnDAW: n번째 군집 중 실제 라벨이 DAW인 데이터의 수

본 데이터에 대해 이상적으로 군집화가 잘 된 경우는 군집화 지수가 최대 648까지 계산된다. 하지만 65,535개의 군집화 경우의 수에 대해 군집화 지수를 계산한 결과 ^{14}C, ^{55}Fe, ^{63}Ni, ^{129}I, ^{137}Cs, ^{239}Pu, ^{242}Cm를 이용하여 군집화를 시도하였을 때, 최대 198로 나타났다. 이는 이상적인 군집화 지수와 큰 괴리가 있고 군집화가 적절하게 이루어지지 않았음을 알 수 있다.

추가적으로 DBSCAN (Density-based spatial clustering of applications with noise)을 이용하여 데이터 군집화를 시도하였다. DBSCAN 알고리즘은 k-평균 군집화 알고리즘이 이상치에 의해서 군집화 결과가 바뀔 수 있는 단점을 극복할 수 있는 알고리즘이다. DBSCAN 알고리즘은 군집화 직경과 그 직경 내의 최소 데이터의 수를 설정해 주어 데이터 공간상에 비슷한 위치에 있는 데이터끼리 군집화 시켜준다. 반지름의 값을 너무 작게 설정하거나 최소 데이터의 수를 적게 설정해 주면 대부분의 데이터를 잡음(noise)으로 해석하기 때문에 적절한 값을 찾기 위해 반지름의 값과 최소 데이터의 수를 바꿔가며 군집화를 시도하였다. DBSCAN을 이용하여 군집화를 시도한 결과는 Table 5와 같다.

반지름이 2인 경우 군집화 최소 데이터의 수를 증가시켰을 때, 잡음으로 판별하는 양이 늘어나는 경향이 있다. 반지름이 작은 경우 군집화 공간에서 반지름 내에 최소 데이터의 수를 충족하지 못하는 경우가 다수 발생하기 때문에 잡음으로 판별된다. 또한 반지름의 값이 3인 경우와 4인 경우, 대부분 한 가지 그룹에 군집화가 되는 것을 알 수 있다. 이는 수지(RESIN) 139개, 건식 방사성폐기물(DAW) 96개, 필터(FILTER)가 89개의 데이터 수를 고려하였을 때, 유의미한 군집화가 이루어지지 않았음을 나타낸다.

3.3. 인공신경망을 이용한 분석

분류 인공신경망을 이용하여 실제 데이터에 기입되어 있는 폐기물의 종류와 신경망이 예측하는 폐기물의 종류를 비교하여 성능을 검증하였다. 인공신경망 교육을 위해 SMOTE 기법으로 만들어진 폐기물 데이터 잡고체 49,904개, 필터 49,911개, 수지 49,861개를 이용하여 인공신경

Table 5. Results of clustering using DBSCAN algorithm

Radius (ϵ)	Min. Points = 2		Min. Points = 3		Min. Points = 4	
2	Group	Number	Group	Number	Group	Number
	−1	193	−1	257	−1	281
	1	2	1	40	1	16
	2	2	2	6	2	12
	3	2	3	5	3	5
	Others	125	Others	16	Others	10
3	Group	Number	Group	Number	Group	Number
	−1	60	−1	76	−1	76
	1	175	1	175	1	175
	2	46	2	46	2	39
	3	12	3	12	3	12
	Others	31	Others	15	Others	22
4	Group	Number	Group	Number	Group	Number
	−1	31	−1	39	−1	47
	1	214	1	214	1	214
	2	56	2	56	2	55
	3	8	3	8	3	8
	Others	15	Others	7	Others	0

−1: Noise; 1: Cluster Group 1; 2: Cluster Group 2; 3: Cluster Group 3

망을 교육하였고 잡고체 96개, 필터 89개, 수지 139개의 원본 데이터를 이용하여 성능을 평가하였다. 분류 인공신경망을 이용한 폐기물별 정확도는 잡고체 91.7%, 필터 100%, 수지 93.5%를 얻었고 전체적으로 94.8%에 달하는 정확도를 달성하였다. 도표를 이용하여 결과를 정리하면 Table 6과 같다.

데이터가 분류 인공신경망을 거쳐서 나온 결과와 거치지 않고 나온 결과를 비교하였다. 분류 인공신경망을 거쳐서 나온 이상 탐지 인공신경망은 Fully Connected Layer 형태로 4 (latent vector) - 4 - 2 - 4 - 4 (output) 형태의 층을 쌓았고, 분류 인공신경망을 거치지 않은 이상 탐지 인공신경망은 전자의 인공신경망보다 좀 더 많은 정보를 담을 수 있도록 노드(Node) 수를 증가시켜 16 (input) - 8 -2 - 8 - 16 (output) 형태로 층을 쌓았다. Fig. 10은 인코더를 지나 압축된 잠재 벡터 (v1, v2)에서의 군집화 정도를 보여준다. 군집화에 실패한 예시는 원본 데이터 중 이상값 (outlier)을 제거하지 않은 상태로 군집화를 진행하였고, 성공한 예시는 분류 인공신경망을 거쳐 나온 잠재 벡터 4개를 인코더를 통해 압축시켜 군집화를 시도하였다. 로그 스케일 변환 및 반복적인 민감도 분석 방식으로 인공신경망 교육 시 3개의 이상치를 제거하는 방식을 적용한 결과이다. 각 폐기물에 대한 데이터를 정상 데이터로 사용하여 이상 탐지 인공신경망을 교육하였다. 잘 교육된 인공신경망을 이용하여 인코더로 압축된 잠재 벡터 분포를 나타내면 Fig. 11과 같다. Fig. 11은 왼쪽부터 잡고체 폐기물을 정상으로 교육시켰을 때, 필터를 정상으로 교육시켰을 때, 수지를 정상으로 교육시켰을 때, 잠재 벡터의 분포이다.

Table 6. Accuracy of classification network for radioactive waste

Radioactive waste type	True positive ratio	Accuracy (%)
DAW	88 / 96	91.7
FILTER	89 / 89	100
RESIN	130 / 139	93.5
Total	307 / 324	94.8

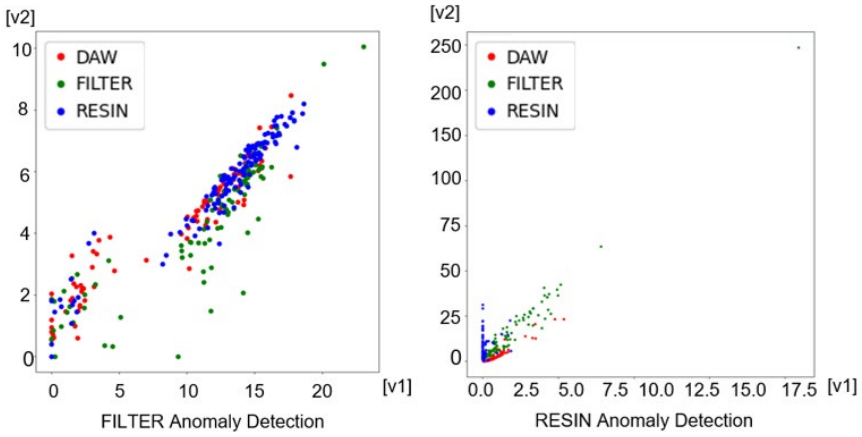

Fig. 10. Cluster with latent vectors (v1, v2), Failed (left), success (right) clustering.

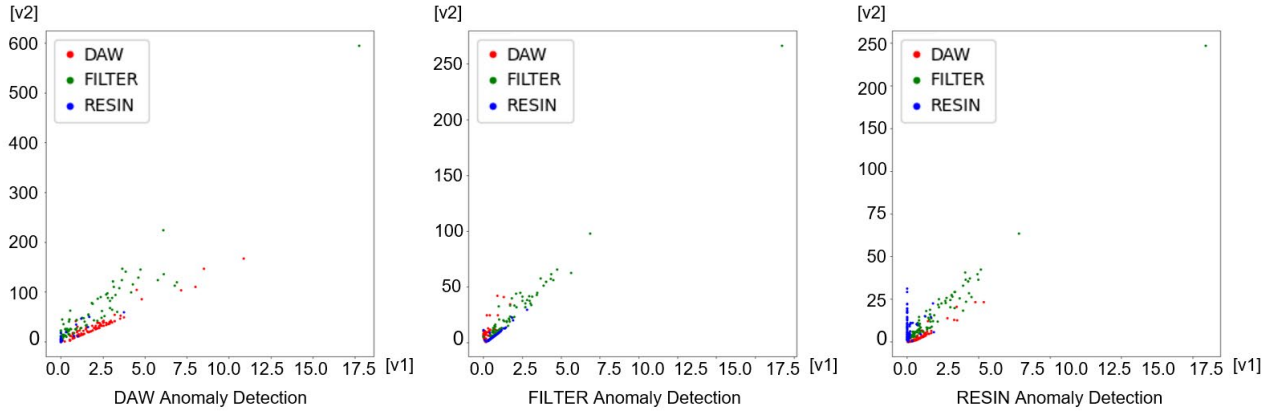

Fig. 11. Latent vector (v1, v2) distribution at anomaly detection.

테스트는 16개의 핵종 중 무작위로 1개의 데이터에 0 값을 넣어서 이상치 상황을 임의로 만들어 테스트를 진행하였다. 정상 잡고체, 필터, 수지 데이터에 대하여 이상치 탐지를 한 결과 정상적으로 탐지하는 비율이 각각 88.5, 93.3, 89.9%로 나타났고, 임의로 만든 이상치 데이터를 이용하여 이상치를 탐지한 결과 비정상으로 탐지하는 비율이 각각 70.8, 39.3, 75.5%로 나타났다. Table 7은 이상 탐지 알고리즘을 이용하여 정상 데이터와 이상치 데이터를 찾을 때의 정확도를 나타낸다.

4. 고 찰

NP-5077 데이터로 작성한 상자 그림, 히스토그램의 분포를 살펴보면 수지 (RESIN), 잡고체 (DAW), 필터 (FILTER)가 유사한 분포를 가지며 거의 겹쳐져 분포하고 있어서 폐기물의 분류에 있어 오류가 발생하더라도 사람의 육안이나 특정한 기준만을 이용한 오류의 판단이 매우 어려운 실정이다.

본 연구에서 사용된 NP-5077 데이터는 16개의 핵종들은 서로 독립적이지 않고 종속적인 관계를 가지기 때문에 서로의 상관계수 행렬을 구하여 핵종들 사이에 어떠한 상관관계가 있는지 확인하였고 그 결과, 몇몇의 핵종들 간 강한 상관관계를 가졌다. 이러한 상관관계가 있는 핵종들의 정보를 누적 설명 분산 비율(cumulative explained variance ratio)이 90%가 넘는 차원의 수인 8차원으로 압축을 시켜 주성분 분석을 실시하였다. 주성분 분석 결과를 살펴보면 한 가지 성분이 약 60%의 설명 분산 비율을 가지며 각 성분들의 분포 또한 비슷하여 뚜렷한 특징을 얻지 못하였다.

Table 7. Accuracy of anomaly detection for results in radionuclide analysis

		Number of total data	Number of normal detection	number of abnormal detection	Accuracy (%)
DAW	DAW	96	85	11	88.5
	Anomaly DAW	96	28	68	70.8
FILTER	FILTER	89	83	6	93.3
	Anomaly FILTER	89	54	35	39.3
RESIN	RESIN	139	125	14	89.9
	Anomaly RESIN	139	34	105	75.5

기존에 널리 알려져 있는 군집화 알고리즘인 k-평균 군집화 알고리즘과 DBSCAN (Density-Based Spatial Clustering of Applications with Noise) 알고리즘을 이용하여 폐기물 종류에 따른 군집화를 시도하고 이를 통해 이상치 탐지를 시도하였으나, 유의미한 군집화 결과를 얻지 못하였다. 이렇게 복잡하게 얽혀 있는 데이터들을 해석하기 위해 딥러닝 기술을 이용하였다. 인공신경망을 이용하여 데이터의 분포가 밀집되어 분류가 힘든 데이터에 대해서도 약 95%에 달하는 분류 정확도를 달성하였고 인공신경망을 통해 데이터의 분포가 비슷하더라도 다차원 공간에서 특징을 잘 추출해 내어 데이터를 잘 분류할 수 있음을 확인하였다.

또한 이상 탐지 인공신경망에서도 데이터의 값을 일부 0으로 만드는 등 비정상 데이터를 인위적으로 만들어서 성능을 확인하였다. Table 7의 결과에서 잡고체 이상치 탐지 신경망에 잡고체 데이터가 아닌 다른 데이터를 넣었을 때, 상대적으로 이상치를 잘 구분하였다. 특히 인위적으로 만든 이상치 데이터인 이상치 잡고체 데이터에 대해서 이상치가 급격하게 증가한 것을 알 수 있다. Fig. 10의 분포에서 잡고체 군집화 영역이 다른 폐기물 영역과 비교적 명확하게 구분이 되어서 이상치 필터의 성능보다 높게 나왔다. 수지의 경우도 잡고체와 마찬가지로 이상치 수지 데이터에 대하여 이상치 데이터 수가 급격하게 증가하였다. 이 또한 잠재 벡터 속에서의 분포가 필터 이상치 탐지 신경망보다 비교적 더 명확하게 구분되어서 성능이 높은 것으로 분석된다. 필터 이상 탐지 신경망의 경우 다른 잡고체와 수지 인공신경망보다 정확도가 낮은 경향을 띠었다. 잠재 벡터 공간에서 각 폐기물들의 군집화 영역이 서로 겹치는 부분이 많아 디코더로 정보를 복원할 때, 정확도가 하락한 것으로 사료된다. 정상 데이터와 이상치 데이터를 분류하는 정확도는 약 77% 수준의 유의미한 결과를 얻었다. 향후 다양하고 양질의 데이터를 확보한다면 성능을 더 개선할 수 있을 것으로 기대된다.

5. 결 론

방사성폐기물 관리 시 실시되는 핵종분석의 결과를 검증할 수 있는 인공지능 기반 이상치 탐지 알고리즘을 개발하였다. 본 연구에 사용된 방사성폐기물 데이터는 폐기물 종류가 달라도 통계적으로 거의 겹쳐진 분포를 가지고 있어서 데이터 입력 오류와 같은 인적오류가 발생하더라도 육안으로 구분이 쉽지 않다. 기존에 널리 알려진 군집화 알고리즘인 k-평균 군집화 알고리즘과 DBSCAN 알고리즘을 이용하여 분류해 내지 못하는 데이터에 대해 인공신경망을 이용하여 유의미한 분류 결과를 얻었다. 이를 기반으로 인적오류나 시스템 오류로 인해 발생할 수 있는 핵종분석 사고에 대하여 분석 결과를 검증할 수 있는 알고리즘을 구축하였다.

본 연구에서 개발한 인공지능 기반 핵종분석 검증 기술은 핵종분석 자동화에도 활용이 될 수 있으며, 향후 데이터가 누적이 되고 최신 알고리즘을 적용하게 되면 간섭핵종에 대한 정량평가 시에도 활용이 가능할 것으로 예상된다. 또한 중·저준위 폐기물에 대한 이상 탐지, 분류, 분석 업무에 적극 활용함으로써 기존 분석체계와는 독립적으로 핵종분석 결과의 신뢰성을 검증할 수 있고 이에 따라 방사성폐기물 처분 적합성 확보 체계의 개선이 가능하다. 향후 고리 1호기 원전 해체를 시작으로 대량 해체 폐기물에 대해서도 신속하고 정확한 핵종분석을 하여 기존 방사성폐기물 관리 체제하에서 운영 기관 및 규제 기관이

부담해야 하는 시간, 인력, 비용을 획기적으로 절감할 수 있을 것으로 기대된다.

사 사

본 연구는 한국원자력연구원의 도전창의 집단기술연구사업 지원을 받았으며(NRF-2021M2D2A201844521 61082139290201), 한국수력원자력(주)의 지원(No. 2020-Tech-14), 한국에너지기술평가원의 에너지기술개발사업 지원(No. 20203210100390)으로 수행되었습니다.

참고문헌

1. Kim CL. 2016. Nuclear Decommissioning Waste Management Trends. Konetic Report 2016-138
2. Kim TW, Choi KS, Kang KD and Ha JH. 2008. Method for Determining Transportation Grade for HIC Containing Spent Resin Using Radioactivity Analysis. *J. Nucl. Fuel Cycle Waste Technol.* **6**(1): 11-15.
3. Nuclear Safety and Security Commission. 2019. Investigation Results on the Errors in Nuclide Analysis of Radioactive Waste at the Korea Atomic Energy Research Institute, 103rd Nuclear Safety and Security Commission, Report: 1.
4. Lee KM, Hong DS, Kim TG, Bae SM, Shon JS and Hong GP. 2004. Radioactive Wastes Assay Technique & Equipment. KAERI/TR-2879/2004.
5. Li F, Wang J, Ge L, Hu F, Cheng F and Sun K. 2019. Research on gamma spectrum semi-quantitative analysis based on convolutional neural network. *J. Phys.: Conf. Ser.* **1423**:012005.
6. Kamuda M, Zhao J and Huff K. 2020. A comparison of machine learning methods for automated gamma-ray spectroscopy. *Nucl. Instrum. Methods Phys. Res. A.* **954**:161385. https://doi.org/10.1016/j.nima.2018.10.063
7. Shumaker E, Stinnett J and Hero AO. 2020. Twin Artificial Neural Networks for Gamma Ray Spectra Comparison. 2020 ETI Annual Workshop.
8. Gomez-Fernandez M, Wong WK, Tokuhiro A, Welter K, Alhawsawi AM, Yang H and Higley K. 2021. Isotope identification using deep learning: An explanation. *Nucl Instrum Methods Phys. Res. A.* **988**:164925. https://doi.org/10.1016/j.nima.2020.164925
9. Chalapathy R and Chawla S. 2019. Deep Learning for Anomaly Detection: A Survey. arXiv:1901.03407v2.
10. Pang G, Shen C, Cao L and Hengel AV. 2020. Deep Learning for Anomaly Detection: A Review. arXiv:2007.02500v3.
11. Lee GJ, Paek MH, Park JG, Han BS, Cheong JH, Lee HC, Yang JY, Hong HK and Park JB. 1995. A Study on the Establishment of the Regulatory Guide to the Characteristics and Classi fication Cri teria of Low and Intermediate Level Radioactive Waste. KINS/HR-111.
12. Han SJ, Lee HY, Kim BG and An EM. 2021. Analysis and Consideration of the Establishment of a Multiplexed Channel for Domestic RI Waste Nuclide Analysis. *J. Radiol. Sci. Technol.* **44**(4): 351-358. https://doi.org/10.17946/JRST.2021.44.4.351
13. Best WT and Miller AD. 1987. Updated Scailing Factors in Low-Level Radwaste. EPRI NP-5077, Project 1557-6, Final Report.
14. Tyagi AK and Chahal P. 2019. Artificial Intelligence and Machine Learning Algorithms. pp. 188-219. In: Challenges and Applications for Implementing Machine Learning in Computer Vision (Kashyap R and Kumar AV), IGI Global, Hershey. PA.
15. Wang J, Xu M, Wang H and Zhang J. 2006. Classification of Imbalanced Data by Using the SMOTE Algorithm and Locally Linear Embedding. ICSP2006 Proceeding.
16. Teknomo K. 2006. K-means clustering tutorial. Available online at http://people.revoledu.com/kardi/tutorial/kMean/