

## Spectrum Analysis of a Portable Radiation Detector Based on a CZT Sensor Using Artificial Intelligence

Duck-Gun Park\* and Sung-Jin Han

AIPIT Inc., Daejeon 34057, Korea

(Received 26 November 2025, Received in final form 22 December 2025, Accepted 22 December 2025)

Portable radiation detectors capable of radionuclide analysis in radiation environments have broad applications in nuclear power plants, radiation safety management, defense, and security. Their utility is expected to grow further with the commercialization of small modular reactors (SMRs). However, on-site radionuclide analysis using portable detectors faces challenges such as low dose rates, limited measurement times, background radiation, and electronic noise. These factors reduce the accuracy of spectral peak detection and may lead to errors in radionuclide identification. In this study, we developed a portable radiation detector employing a CdZnTe (CZT) sensor to enable field-based radionuclide analysis. Artificial intelligence techniques were integrated into the system to mitigate identification errors and enhance the reliability of radionuclide analysis under practical conditions.

**Keywords :** radiation detector, CZT sensor, artificial intelligence, CNN, spectrum, nuclide analysis

## 인공지능을 이용한 CZT 센서기반 휴대용 방사선 계측기의 스펙트럼 분석

박덕근\* · 한성진

(주)아이피트, 대전광역시 대덕대로989번길 111, 34057

(2025년 11월 26일 받음, 2025년 12월 22일 최종수정본 받음, 2025년 12월 22일 게재확정)

방사선 환경에서 핵종을 분석할 수 있는 휴대용 방사선 계측기는 원자력 발전소, 방사선 안전 관리, 국방 및 보안 분야 등 다양한 현장에서 적용될 수 있으며, 특히 중소형원자로(SMR)이 실용화되면 활용가능성이 높을 것으로 보인다. 휴대용 방사선 계측기로 핵종을 분석할 경우에는 낮은 방사선 선량, 측정 시간의 제약, 배경 방사선 및 전자적 노이즈가 있으며, 이러한 요인들은 방사선 핵종 피크 검출에서 정확도를 저하시켜 핵종 식별 과정에서 오류를 발생시킬 수 있다. 본 연구에서는 CZT(CdZnTe) 센서를 이용하여 현장에서 방사능 핵종을 분석할 수 있는 휴대용 방사능 계측기를 제작하여 인공지능을 이용하여 핵종분석의 오류를 감소시켰다.

**주제어 :** 방사선탐지기, CZT 센서, 인공지능, 합성곱신경망, 스펙트럼, 핵종분석

### I. 서 론

일반적으로 방사능의 핵종을 분석할 경우에는 고순도 게르마늄센서를 사용한 HPGe 계측기가 사용된다. 그러나 고순도 게르마늄 반도체 검출기의 경우는 방사선의 에너지흡수에 의해서 뿐만 아니라 상온에서도 열적 여기에 의해 항상 미량의 전류가 흐르기 때문에 사용 시에는 반드시 액체질소로 냉각 시켜 주어야 하는 단점을 가지고 있다[1]. 이에 따라 최근에는 고순도 게르마늄 반도체 검출기와 같이 감마선( $\gamma$ )을 측정할

수 있고 상온에서도 사용할 수 있는 카드뮴(Cd), 아연(Zn), 텔루륨(Te) 물질을 이용한 CZT 반도체 검출기가 많이 사용되고 있으며 관련 연구 및 개발이 활발히 진행되고 있다[2]. CZT 검출기는 Cadmium Zinc Telluride(CdZnTe)로 구성된 반도체 검출기로 다른 방사선 검출기에 비하여 비교적 최근에 개발된 반도체 검출기에 속한다[3,4]. CdZnTe는 고원자번호(Z)와 높은 밀도를 가져 감마선 흡수 효율이 뛰어나며, 각 핵종은 고유한 감마선 에너지 피크를 가지므로 핵종에서 방출되는 감마선의 에너지 스펙트럼을 고해상도로 분석 가능하

다. CZT 검출기는 감마선의 에너지와 세기를 측정하며, 감마선( $\gamma$ )이 CZT 검출기로 입사되면 광전효과(Photoelectric effect), 컴프턴산란(Compton scattering) 또는 전자쌍생성(Pair production) 과정을 통해서 전자(Electron)와 정공(Hole) 쌍이 생성된다. 검출기는 이러한 전자를 필스 또는 전류신호 형태로 수집하여 감마선의 에너지와 세기를 측정하며, 감마선 방출선원은 핵종별로 고유에너지의 감마선을 방출하므로 CZT 검출기로 측정된 에너지를 확인하면 핵종 판별이 가능하다[5]. 휴대용 방사선 계측기로 핵종을 분석할 경우에는 낮은 방사선 선량, 측정 시간의 제약, 배경 방사선 및 전자적 노이즈가 있으며, 이러한 요인들은 피크 검출의 정확도를 저하시켜 핵종 식별 과정에서 오류를 발생시킬 수 있다[1]. CZT 검출기는 방사성 물질의 검출과 식별을 수행하는 핵심 장치이다. 이러한 계측기는 감마선 및 기타 방사선 신호를 수집하여 스펙트럼 형태로 출력하며, 이를 기반으로 특정 핵종의 존재 여부를 판단한다. 전통적인 핵종 식별 방법은 계측된 스펙트럼에서 특정 에너지 피크를 탐지하고, 기존 데이터베이스와 비교하는 방식으로 이루어진다. 특히 휴대용 계측기는 현장에서 실시간으로 사용되므로, 피크가 미약하거나 간헐적으로 나타나는 상황에서도 정확하게 핵종을 판별할 수 있는 안정적인 알고리즘이 요구된다. 기존의 규칙 기반(rule-based) 피크 검출 알고리즘은 이러한 조건에서 취약점을 가지며, 노이즈가 많은 데이터에서는 잘못된 피크를 검출하거나 실제 존재하는 피크를 놓치는 문제가 발생한다[4]. 이러한 한계는 방사선 안전 관리, 환경 모니터링, 긴급 대응 등 실제 응용 상황에서 심각한 위험으로 작용할 수 있다. 본 연구에서는 휴대용 방사선 검출기의 이러한 한계를 인공지능을 이용하여 극복하려고 시도하였다. CZT를 이용한 핵종분석 스펙트럼은 시계열 신호로서 잡음에 민감한 특징이, 자기센서의 데이터와 유사하다. 본 연구에서 사용된 특징벡터 추출 및 패턴인식 기술은, 자기센서 데이터에서 비정상적인 패턴을 AI가 학습해 고장 예측이나 이상 상황 탐지하는데 적용이 가능하며, 자기센서가 측정한 저해상도 데이터를 AI가 보간·재구성해 정밀한 자기장 맵 생성하는데도 적용 가능하다[5]. 최근 인공지능(AI) 기술은 이미지 처리, 음성 인식, 의료 데이터 분석 등 다양한 분야에서 기존 알고리즘의 한계를 극복하며 높은 성능을 보여주고 있다. 특히 합성곱 신경망(CNN)은 시계열 데이터나 1차원 신호에서 패턴을 추출하는 데 효과적이며, 노이즈가 존재하는 환경에서도 특징을 안정적으로 학습할 수 있다[6]. 이러한 특성은 방사선 스펙트럼 데이터를 분석하여 핵종을 식별하는 문제에도 적용 가능하며, AI 기반 접근 방식이 기존 규칙 기반 방법을 대체하거나 보완할 수 있는 잠재력을 가진다. 본 연구로 개발한 휴대용 방사선 계측기로부터 수집된 감마선 스펙트럼 데이터를 기반으로, 인공지능 기법을 활용하여

핵종을 자동으로 구분할 수 있는 모델을 설계하고 그 성능을 검증하는 데 있다. 기존 피크 검출 기반 알고리즘이 가진 노이즈 민감성과 저선량 환경에서의 한계를 극복하고, 데이터 내 숨겨진 패턴을 학습하여 보다 안정적이고 정확한 핵종 식별을 수행하는 것을 목표로 한다. 본 연구에서는 수집된 스펙트럼 데이터를 정규화 및 이동평균 필터 등의 전처리 과정을 통해 학습에 적합한 입력으로 변환하고, 1차원 CNN 구조를 적용하여 핵종 식별 모델을 설계한다. 또한 학습된 모델의 성능을 기존 피크 검출 기반 방법과 비교하고, 실제 데이터에 적용하여 모델의 실용적 타당성을 평가한다[7,8]. 본 연구의 주요 기여는 다음과 같이 요약할 수 있다. 첫째, 실제 계측 데이터를 활용하여 AI 기반 핵종 식별 모델을 구축함으로써 실용적 타당성을 확보하였다. 둘째, 저선량 및 고잡음 환경에서도 안정적인 핵종 식별 성능을 입증함으로써 기존 규칙 기반 피크 검출 알고리즘의 한계를 보완하였다. 셋째, AI 기반 접근의 유효성을 기존 방법과 비교 분석하여, 향후 휴대용 계측기의 핵종 식별 정확도 향상 및 신속 대응 시스템 구축에 기여할 수 있음을 제시하였다.

## II. 대상 및 방법

### 1. 연구 범위 및 기여

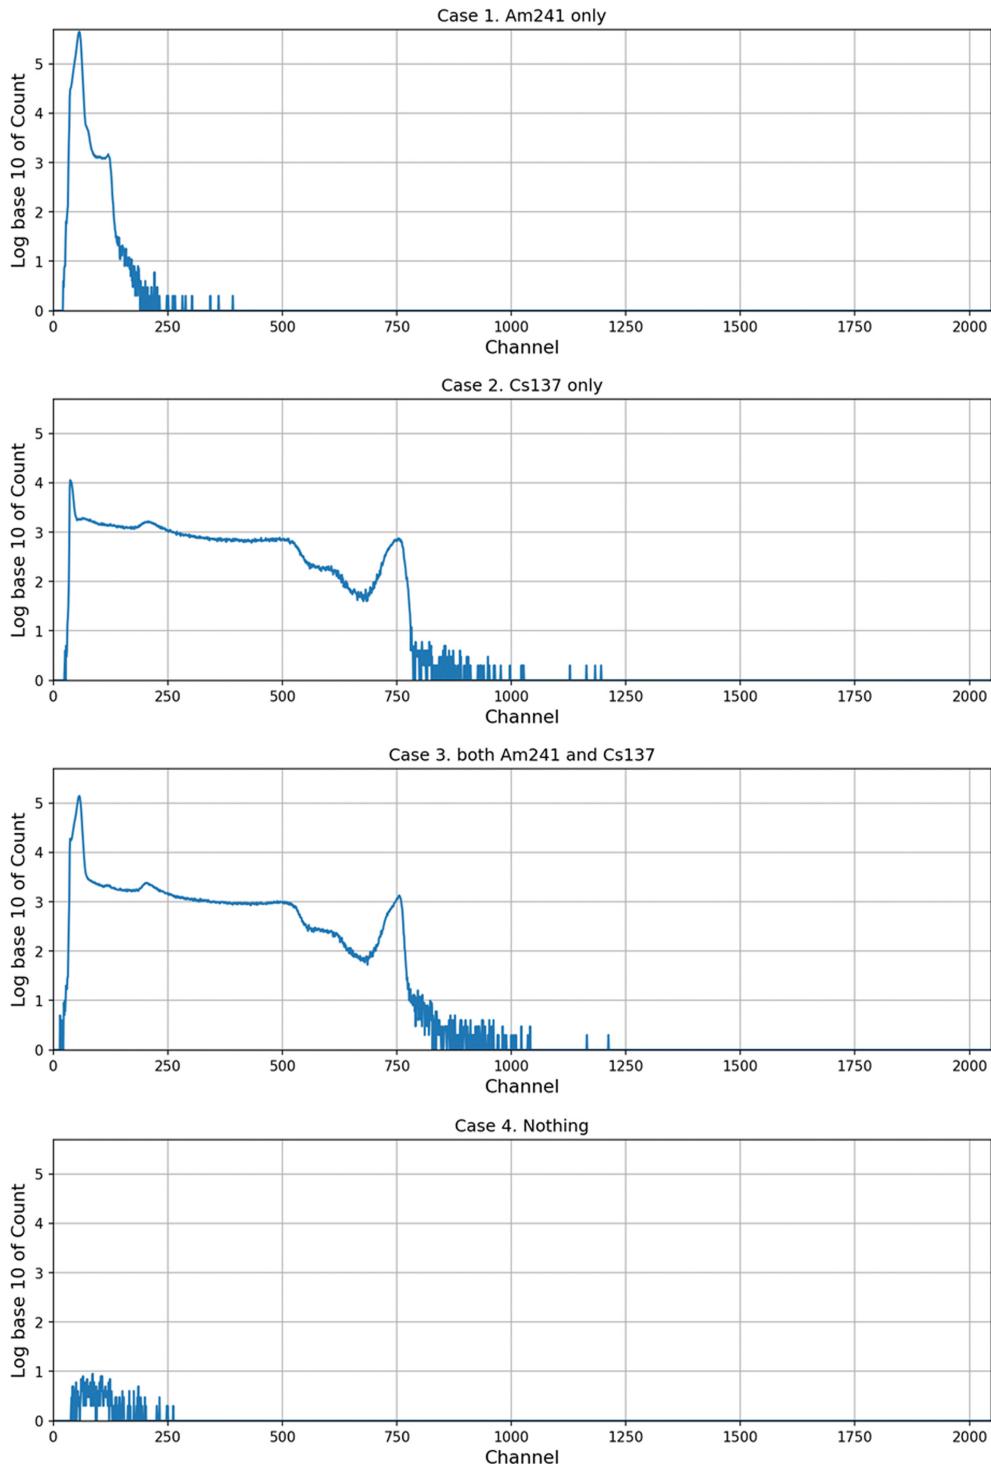
본 연구의 범위는 실제 현장에서 측정된 휴대용 방사선 계측기 스펙트럼 데이터에 한정하며, 주요 핵종으로는 Am-241, Cs-137 등 대표적인 감마선 방출 핵종을 대상으로 한다. 데이터 전처리 과정에서는 이동평균 필터를 적용하고, 0 값 처리 및 구간 자르기를 수행하여 모델 학습에 적합한 형태로 변환하였다. 모델 설계 측면에서는 1차원 CNN을 적용하여 시계열 신호 내 피크 패턴을 효과적으로 추출하고, 완전 연결 계층을 통해 핵종 존재 여부를 예측한다[7].

### 2. 데이터 수집

개발된 휴대용 방사선 계측기를 이용하여 Table I과 같은 조건으로 감마선 스펙트럼 데이터를 수집하였다. Am-241과 Cs-137 원소에 대하여 핵종이 하나씩만 있는 경우, 같이 있는 경우, 아무것도 없는 경우 이렇게 네 가지 경우에 대하여 각각 10번씩 30분간 측정하였다. 측정 데이터는 CSV 형식이고 채널(Channel), 계수(Counts) 값이 포함되어 있으며, 본

**Table I.** Experimental conditions for nuclide measurements.

구분	Am-241 사용	Cs-137 사용	측정시간	측정회수	
1	○		×	30분	20회
2	×	○			
3	○	○			
4	×	×			



**Fig. 1.** (Color online) Examples of spectral signals under different experimental conditions.

연구에서는 1차원 시계열 신호로서 각 채널 별 계수 값을 이용하여 피크 검출 및 핵종 식별을 수행하였다. 이렇게 데이터를 구성함으로써 다양한 핵종 중 어떤 핵종이 포함되어 있는지를 AI 모델이 판단할 수 있도록 했다. 총 수집한 데이터의 개수는 80개며, 이 중 40개는 학습에 사용했고 나머지 40개

는 시험에 사용했다. Fig. 1은 개발된 계측기에서 나오는 스펙트럼 신호를 나타내었다. 방사성 핵종은 붕괴 과정에서 핵내부의 에너지 준위가 변하면서 감마선을 방출한다. 스펙트럼의 피크 위치(에너지 값)는 해당 핵종의 고유한 준위 전이에 대응한다. 따라서 그림에서 각 피크는 특정 핵종의 고유한 에

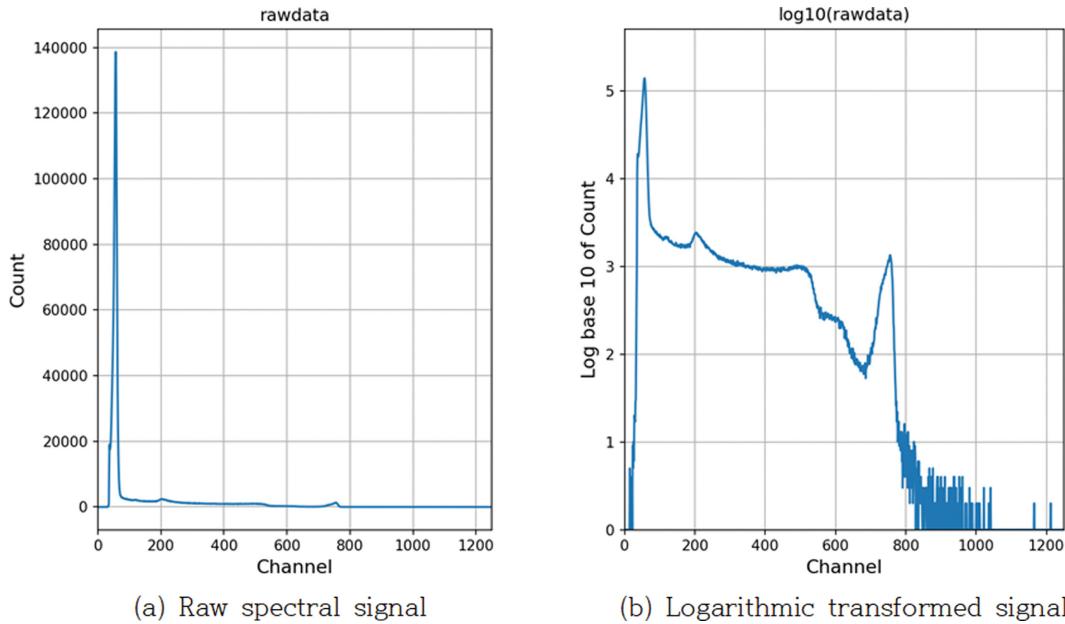
너지 준위 전이를 의미한다.

### 3. 데이터 전처리 및 입력 데이터 생성

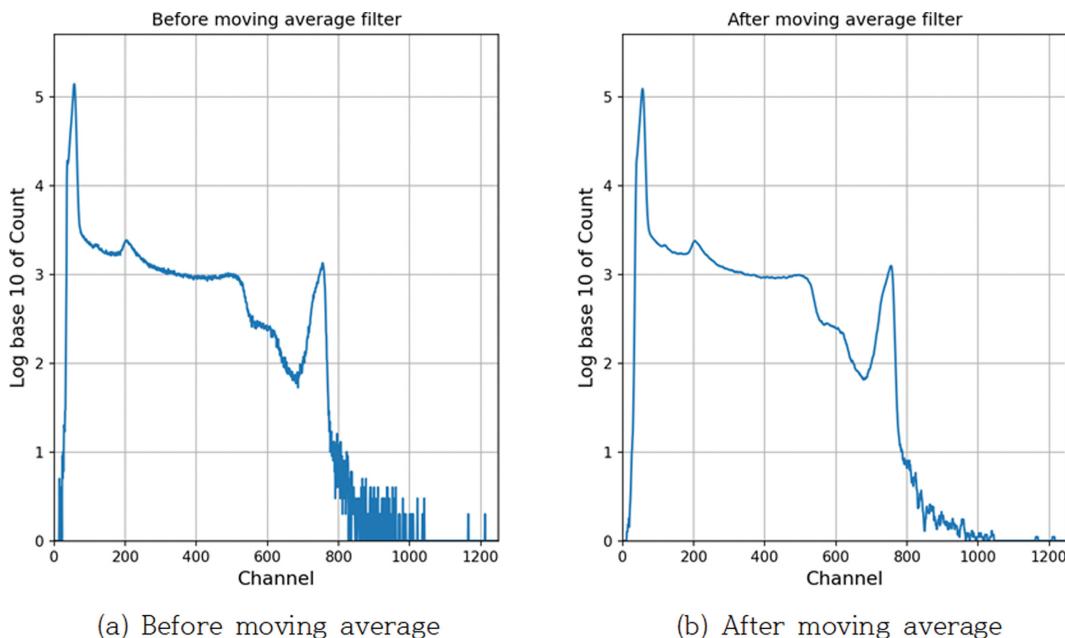
#### 3.1. 데이터 전처리

CSV로 파일로부터 불러온 원시 스펙트럼 데이터는 피크 검출과 AI 학습 성능 향상을 위해 여러 단계의 전처리 과정을 거쳤다. 데이터 길이를 줄이기 위하여 신호에서 의미없는 구간을 제거하여 학습 효율을 높였다. 또한 신호의 극단치에

의한 학습 편향을 방지하고, 신호 대비 잡음비(SNR)를 개선하기 위하여 카운트 값이 1 이하인 경우 0으로 처리하고, 1을 초과하는 값은 로그 변환을 적용하여 동적 범위를 조정하였다(Fig. 2). 또한 시계열 신호에서 잡음을 줄이고 데이터의 추세를 부드럽게 하여 모델 학습과 예측의 정확성을 높이기 위해서 Fig. 3과 같이 이동평균필터(Moving Average Filter)를 적용하였다. 이동평균 필터는 시계열 데이터에서 신호 패턴을 보존하면서 노이즈를 줄이는 표준적인 방법이다[8]. 이



**Fig. 2.** (Color online) Spectral signal representation before (a) and after logarithmic transformation (b).



**Fig. 3.** (Color online) Comparison of the signal before and after moving average filter application.

동평균필터는 일정 구간의 평균을 취함으로써 고주파 잡음을 완화하고 데이터 평활화(Smoothing)를 통하여 급격한 변동을 줄여 장기적인 추세(trend)를 더 명확히 드러낸다. 이렇게 필터링된 데이터는 인공지능 모델에서 입력데이터의 변동성을 높이고 학습 안정성을 높여 과적합을 줄이는 역할을 한다. 이를 위하여 각 데이터 포인트를 중심으로 좌우 일정 범위 창크기(window size) 내 평균을 계산하여 작은 변동과 랜덤 노이즈를 제거하였다. 본 연구에서는 필터 창크기(filter window size)를 7로 설정하였다. Fig. 2는 로그값을 조정하기 전·후의 스펙트럼 모습을 보여준다.

### 3.2. 데이터 라벨링

이렇게 얻어진 신호를 인공지능을 처리하기 위하여는 데이터 라벨링이 필요하다. 이미지나 텍스트와 달리, 시계열 데이터는 ‘시간의 흐름’과 ‘문맥(Context)’이 중요하다. 시계열 신호의 데이터 라벨링은 시간에 따라 변화하는 데이터에 의미 있는 태그를 부여하는 과정으로, 인공지능 모델이 특정 패턴이나 이벤트를 학습하고 예측할 수 있도록 하는 과정이다. 따라서 신호에 대한 물리적 이해를 바탕으로 신호의 모양이나 구조에 따라서 라벨링 방식을 결정하여야 한다. 본 연구에서는 각 파일에서 Am-241 및 Cs-137 핵종의 피크 위치를 육안으로 판단하여 가장 값이 높은 위치(Channel)를 정답으로 설정하였으며, 전체 신호를 중심 포인트 기준으로 좌우 창크기 범위(여기서는 33샘플)로 슬라이딩하여 입력 데이터를 생성하였다. 여기서 피크로 라벨링 된 위치 기준으로 일정 거리 내의 인접 지점들은 학습에서 제외하여, 모델이 피크 주변에서 과도하게 반복 학습하지 않도록 처리하였다. Fig. 4에 보이는 바와 같이 피크 주변에서는 피크를 제외하고는 샘플링을 하지 않았다. 여기서, 파란색 점은 좌우로 16개씩(33

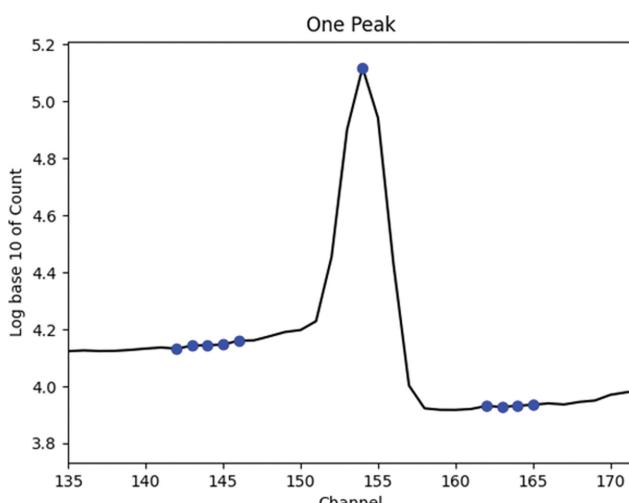


Fig. 4. (Color online) Window-based sliding sampling.

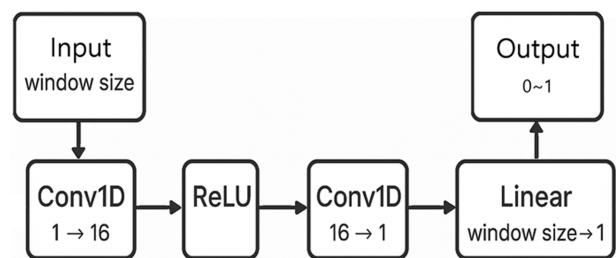


Fig. 5. Model Architecture used in this study.

개) 샘플링을 했다는 의미이다.

### 3.3. AI 모델 설계

본 연구에서는 1차원 감마선 스펙트럼 신호에서 피크를 검출하기 위해 CNN 기반 신경망을 설계하였다. 1차원 감마선 스펙트럼에서 피크를 검출하기 위해 CNN 기반 신경망을 설계할 때는 스펙트럼 데이터를 1차원 시계열 입력으로 처리하고, 잡음 속에서도 피크 특징을 추출할 수 있는 합성곱 계층을 설계하는 것이 중요하다. 설계된 CNN은 입력 신호의 지역적 패턴을 학습하도록 구성되었으며, Fig. 5에 처리과정과 주요 구성 요소를 정리하였으며, 각 과정에 대한 설명은 다음과 같다[9].

#### ① 1차원 합성곱층(Conv1D)

첫 번째 합성곱층은 입력 시퀀스에서 16개의 필터를 적용하며, 커널 크기는 5, 패딩은 2로 설정하여 입력 길이를 유지하였다. 이를 통해 신호의 국소적 특징을 효과적으로 추출할 수 있으며, 작은 피크도 포착할 수 있다.

#### ② 활성화 함수 (ReLU)

합성곱층 뒤에 ReLU(Rectified Linear Unit) 활성화 함수를 적용하여 비선형성을 부여하고, 신호의 음수 영역은 0으로 변환함으로써 학습 안정성을 높였다[2].

#### ③ 두 번째 합성곱층 및 완전 연결층

두 번째 합성곱층을 통해 추출된 특징을 다시 1개의 출력 채널로 변환하고, 이후 완전 연결층(Fully Connected

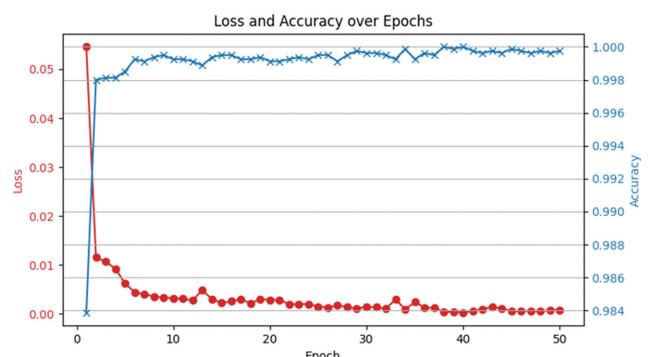


Fig. 6. (Color online) Loss and accuracy graph during training.

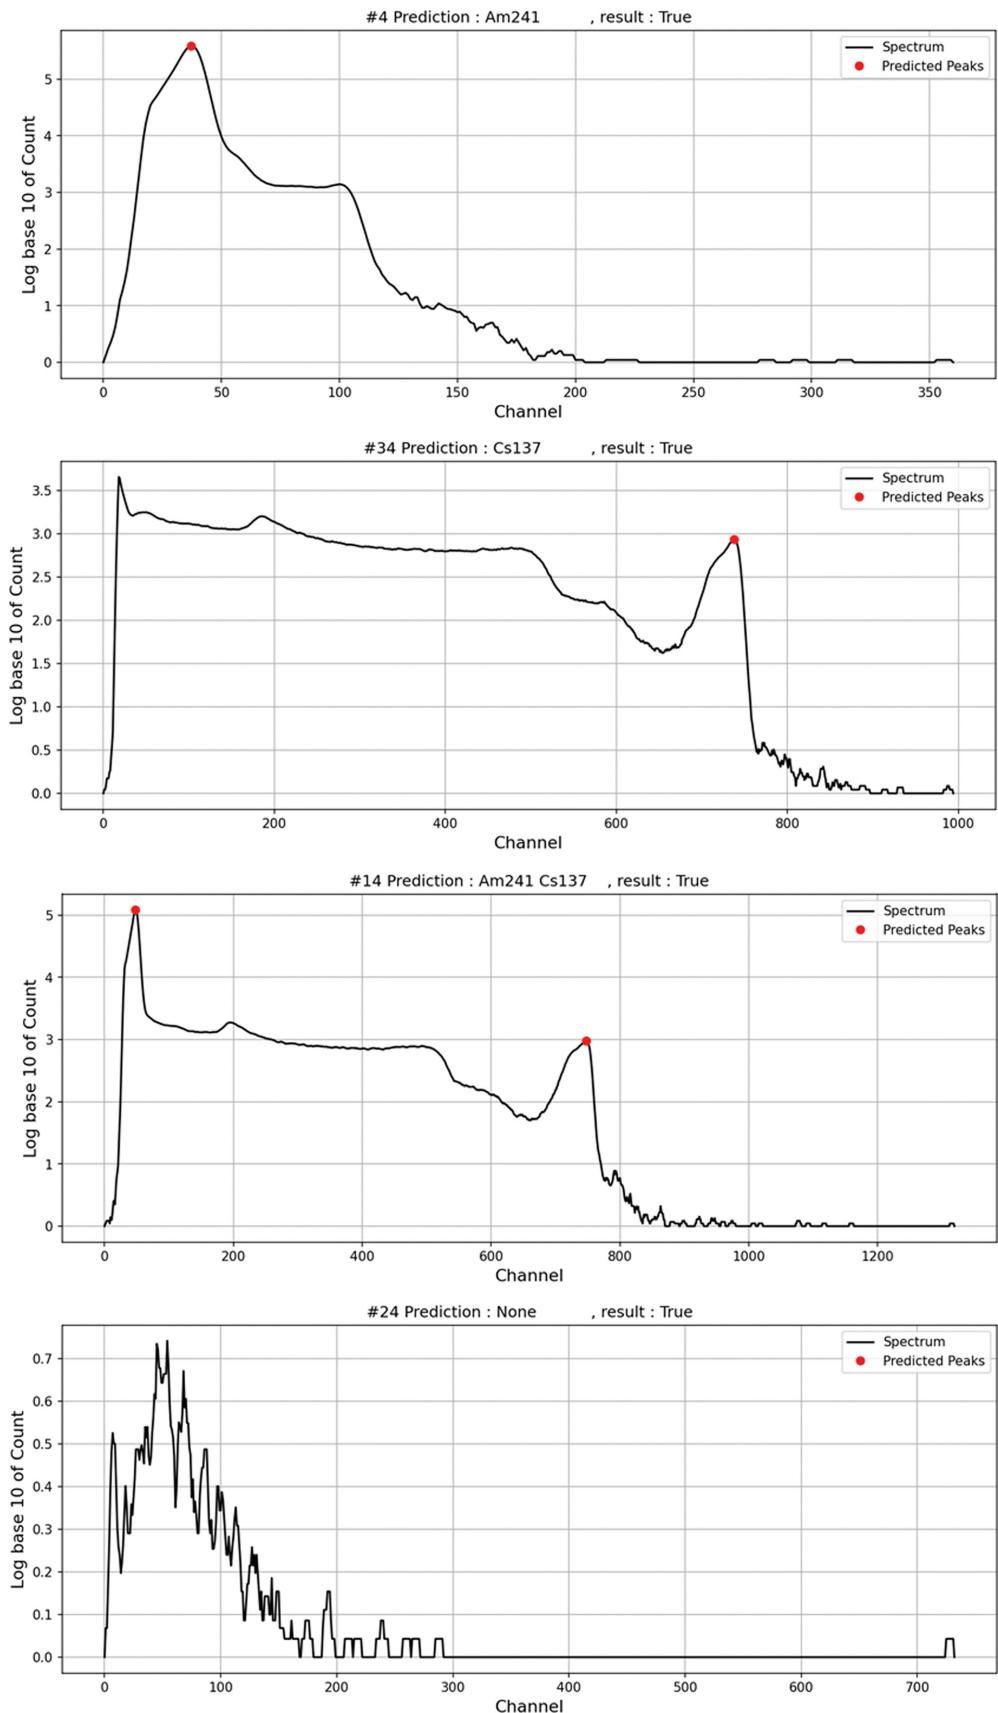


Fig. 7. (Color online) Graphical representation of individual spectral data.

Layer)을 통해 각 윈도우 샘플의 피크 존재 확률을 0~1 사이로 매핑하였다. 출력층에는 시그모이드 활성화 함수를 사용하여 이진 분류 문제에 적합하도록 설계하였다.

### 3.4. 모델 학습

모델 학습은 지도학습 방식으로 수행되었으며, 손실 함수로는 이진 교차 엔트로피(Binary Cross-Entropy)를 사용하였다. 최적화 알고리즘은 Adam을 적용하여 학습률 0.01로 50 epoch 동안 학습하였다[8].

학습 과정에서 손실과 정확도를 모니터링 하였다. 초기 epoch에서는 손실이 높고 정확도가 낮았으나, 학습이 진행됨에 따라 손실이 점진적으로 감소하고 정확도가 상승하는 경

```

result.txt - Windows 메모장
파일(F) 편집(E) 서식(O) 보기(V) 도움말(H)
Prediction : None      result : True
# 24 T Datafile : background(3)  result : True
# 25 T Datafile : background(4)  result : True
# 26 T Datafile : background(5)  result : True
# 27 T Datafile : background(6)  result : True
# 28 T Datafile : background(7)  result : True
# 29 T Datafile : background(8)  result : True
# 30 T Datafile : background(9)  result : True
# 31 T Datafile : Cs137(1)    result : True
# 32 T Datafile : Cs137(10)   result : True
# 33 T Datafile : Cs137(2)    result : True
# 34 T Datafile : Cs137(3)    result : True
# 35 T Datafile : Cs137(4)    result : True
# 36 T Datafile : Cs137(5)    result : True
# 37 T Datafile : Cs137(6)    result : True
# 38 T Datafile : Cs137(7)    result : True
# 39 T Datafile : Cs137(8)    result : True
# 40 T Datafile : Cs137(9)    result : True

** 예측 결과 **
1. 전체 데이터 수 : 40
2. 정답 수 : 40
3. 오답 수 : 0
4. 정확도 : 100.00 %

```

Fig. 8. (Color online) A section of the text file with complete results and summary.

향을 보였다. 학습 종료 후, 역대 세대 중 최소 손실을 달성한 모델이 저장되었으며, 학습 데이터에 대한 정확도는 약 99% 이상으로 평가되었다. 학습 과정 중 손실과 정확도의 변화는 Fig. 6에 나타내었다.

### 3.5. 시험 결과

학습 과정에서 저장된 최소 손실 모델을 사용하여 시험을 진행하였다. 시험에 사용한 데이터는 학습에 사용한 40개를 제외한 나머지 40개를 사용하였다. 시험 결과는 개별 데이터에 대해 그림파일과 전체 결과 및 요약에 대해 텍스트파일로 저장하게 하였다. Fig. 7에 개별 스펙트럼 데이터에 대한 그림파일 일부를, Fig. 8은 전체 결과 및 요약을 저장한 텍스트 파일의 일부를 나타내었다. 보이는 바와 같이 정확도 100%를 달성하는 우수한 결과를 보였다. 40개라는 다소 적은 수의 학습 데이터량에도 불구하고 우수한 결과가 나온 것은 슬라이딩 윈도우 방식으로 샘플링하여 데이터 1개당 약 1000개 정도의 입력 데이터가 생성되었기 때문으로 예상된다 [10]. 슬라이딩 윈도우(Sliding Window)는 인공지능 기반 신호처리에서 시간·공간적으로 연속된 데이터 구간을 일정 크기의 윈도우로 잘라내어 분석하는 기법이다. 이를 통해 국소적 특징 추출, 짐음 제거, 패턴 인식이 가능하며, 특히 CNN 기반 영상·음성 처리, 이상 탐지, 실시간 데이터 분석에서 핵심적으로 활용된다.

## III. 맺음말

본 연구는 직접 개발한 휴대용 방사선 계측기의 스펙트럼 데이터를 기반으로 CNN 모델을 활용하여 1차원 신호에서 피크를 검출하고, AI 기반 핵종을 분류하는 방법을 제안하였다. 적은 수의 데이터에서 슬라이딩 윈도우 방식 샘플링을 사용하여 데이터의 부족함을 해결 했으며 CNN 모델 설계 및 학습을 통해 자동으로 핵종을 분류하는 모델을 완성하였고 정확도 100%를 달성하였다. 이에 기존 수치적 피크 검출 방법보다 높은 편리성과 정확도 및 안정성을 확보하였다고 볼 수 있다. 이러한 결과는 실환경에서 방사선 계측 데이터를 기반으로 핵종을 자동 식별하는 AI 시스템 개발에 기여할 수 있을 것으로 기대된다.

## 감사의 글

본 연구는 원자력안전위원회의 “중소형원자로 안전규제기반 기술 개발(RS-2025-02314096)” 및 “자기영상 기술을 이용한 원자로 제어봉 집합체 손상평가 장비개발(RS-2023-00225436)” 과제의 연구비 지원으로 수행되었습니다.

## References

- [1] L. S. Darken and C. E. Cox, *Semiconductors and Semimetals* **43**, 23 (1995).
- [2] D. J. Wagenaar, K. Parnham, B. Sundal, G. Maehlum, S. Chowdhury, D. Meierl, T. Vandehei, M. Szawlowski, and B. E. Patt, *International Society for Optics and Photonics* **6707**, 67070I (2007).
- [3] J. K. Kim, W. G. S. Y. Lee, C. H. Shin, K. O. Kim, J. M. Park, D. Y. Jang, and J. S. Kang, Simulation and performance test technology development for semiconductor radiation detection instrument fabrication, KAERI/CM-1319/2009 (2010).
- [4] K. Iniewski, *Journal of Instrumentation* **9**, C11001 (2014).
- [5] H.-G. Kim, Y.-H. Hong, Y.-S. Jung, J.-H. Kim, and S. Park, *Journal of Radiological Science and Technology* **43**, 481 (2020).
- [6] S. Kiranyaz, T. Ince, O. Abdeljaber, O. Avci, and M. Gabbouj, *Mechanical System and Signal Processing* **151**, 107398 (2021).
- [7] C. H. Lee, J. Son, T. H. Kim, S. Lee, and Y.-K. Kim, Measurement of Neutron Energy Spectrum Emitted by Cf-252 Source Using Time-of-Flight Method. *Transactions of the Korean Nuclear Society Autumn Meeting*, 1 (2016).
- [8] A. V. Oppenheim and R. W. Schafer, *Discrete-Time Signal Processing*, 3rd ed. Pearson, Upper Saddle River, NJ (2010) pp. 17.
- [9] A. Krizhevsky, I. Sutskever, and G. E. Hinton, *Computer Science* **60**, 84 (2012).
- [10] R. Snytsar, *International Journal on Cybernetics & Informatics (IJCI)* **12**, 5 (2023).