

doi: 10.7690/bgzdh.2025.01.013

基于卷积神经网络的放射性核素识别算法

朱岳武¹, 梁杰², 董喆¹, 刘尔聃¹, 李林珊², 姜麟泉³

(1. 中国中原对外工程有限公司, 北京 100044;
 2. 中国兵器装备集团自动化研究所有限公司智能测控事业部, 四川 绵阳 621000;
 3. 北京联合大学, 北京 100044)

摘要: 为实现对低计数、多种类的复杂放射性核素的准确识别, 引入卷积神经网络(convolutional neural network, CNN)搭建针对低计数、多种类放射性核素识别模型。利用蒙特卡罗仿真创建由²⁴¹Am、¹³³Ba、⁵⁷Co、⁶⁰Co、¹³⁷Cs、¹⁵²Eu以及⁴⁰K组成的单源、两源以及三源共63种不同种类放射性核素能谱数据库。利用仿真训练集和仿真验证集样本完成CNN训练及超参数优化, 利用测试集样本验证模型性能。结果表明, 该模型对低计数、多种类放射性核素具有良好的识别性能。

关键词: 放射性核素识别; 卷积神经网络; 蒙特卡罗仿真

中图分类号: R14 文献标志码: A

Radionuclide Identification Algorithm Based on Convolutional Neural Network

Zhu Yuewu¹, Liang Jie², Dong Zhe¹, Liu Erdan¹, Li Linshan², Jiang Linquan³

(1. China National Nuclear Corporation Overseas Co., Ltd., Beijing 100044, China;
 2. Department of Intelligent Measurement and Control, Automation Research Institute Co., Ltd. of
 China South Industries Group Corporation, Mianyang 621000, China;
 3. Beijing Union University, Beijing 100044, China)

Abstract: To realize the accurate identification of low count and multi-class complex radionuclides, the convolutional neural network is introduced to build a recognition model for low count and multi-class complex radionuclides. The radionuclide energy spectrum database consisting of ²⁴¹Am, ¹³³Ba, ⁵⁷Co, ⁶⁰Co, ¹³⁷Cs, ¹⁵²Eu, and ⁴⁰K was established by the Monte Carlo simulation, which contained a total of 63 different radioactive nuclide sources. The simulation training set and simulation verification set samples were used to complete the training and hyperparameter optimization of convolutional neural networks. The test set samples were used to verify the model performance. The results demonstrate that the convolutional neural networks has good recognition performance in the identification of low count and multi-class complex radionuclides.

Keywords: radionuclide recognition; convolutional neural network; Monte Carlo simulation

0 引言

针对低计数、多种类复杂放射性核素的准确识别是辐射监测领域亟待解决的问题之一。传统的核素识别方法包括简单比较法、高斯乘积函数找峰法^[1]、导数法^[2]和对称零面积寻峰法^[3]等, 这些方法在高计数且单一源的情况下, 核素识别准确率尚可, 但是针对低计数、多种类的放射性核素识别效果并不理想。随着高性能机器学习算法在分类识别领域的快速发展, 卷积神经网络(CNN)由于其独有的局部感知、参数共享以及多层卷积等能力^[4]被一些研究学者引入放射性核素识别领域探索其可行性, 如Liang等^[5]利用CNN搭建用于识别⁶⁰Co、¹³⁷Cs、²³⁸Pu

和¹³¹I放射性核素识别模型, 实验结果显示CNN模型具有较高的识别精度; Li等^[6]开展了针对¹³³Ba、¹³⁷Cs、⁵⁷Co、²⁴¹Am、²²Na、^{99m}Tc、⁶⁰Co和²³⁵U这8种放射性核素数据CNN模型的识别能力研究, 结果表明, CNN模型对¹³³Ba、¹³⁷Cs、⁵⁷Co、²⁴¹Am、²²Na、^{99m}Tc、⁶⁰Co和²³⁵U识别准确率高于97%。

上述研究验证了CNN模型对单一放射性核素具有良好的识别能力, 但是CNN模型对于复杂放射性核素识别能力鲜少研究。基于此, 笔者开展了基于CNN模型的放射性核素识别方法研究, 将聚焦于CNN模型对低计数、多种类的复杂放射性核素识别能力进行研究。

收稿日期: 2024-07-04; 修回日期: 2024-08-05

基金项目: 四川省科技成果转化示范项目(2023ZHCG0026)

第一作者: 朱岳武(1988—), 男, 湖南人。

1 材料与方法

经典的 CNN 模型结构包括输入层、卷积层、池化层、展平层、全连接层以及输出层。卷积层是卷积神经网络的核心组成部分，其主要包括卷积核和激活函数。在卷积层中，输入数据和卷积核进行卷积操作，假设 f 代表输入数据(离散值)， g 代表卷积核(离散值)，则 f 和 g 按照式(1)进行卷积操作。

$$(f * g)(n) = \sum_{\tau=-\infty}^{\infty} f(\tau)g(n-\tau)。 \quad (1)$$

激活函数将作用于输入数据与卷积核的卷积结果，其作用是增加网络结构的非线性，减少过拟合问题。

2 数据准备

考虑到实验室放射源类型有限，且出于安全性考虑，笔者采用的数据均为仿真数据。利用蒙特卡罗 n 粒子运输代码(Monte Carlo n particle transport code, MCNP)仿真由 ^{241}Am 、 ^{133}Ba 、 ^{57}Co 、 ^{60}Co 、 ^{137}Cs 、 ^{152}Eu 以及 ^{40}K 构成的单源放射性核素，以及其两两组合、三三组合构成的两源及三源放射性核素能谱数据集。此数据集中包括由 ^{241}Am 、 ^{133}Ba 、 ^{57}Co 、 ^{60}Co 、 ^{137}Cs 、 ^{152}Eu 以及 ^{40}K 7 种单源核素，两两组合构成的 21 种两源核素以及三三组成构成的 35 种三源核素。在针对每种放射性核素进行仿真时，设置光子数的变化范围为 $1 \times 10^4 \sim 6 \times 10^5 \text{ cm}$ ，变化步长为 10^3 cm ；设置距离(源与探测器)的变化范围为 $2 \sim 20 \text{ cm}$ ，变化步长为 2 cm 。MCNP 仿真 63 种不同放射性核素能谱，每种放射性核素仿真 150 组数据，共仿真 9 450 组放射性核素能谱数据。

3 结果与讨论

3.1 CNN 建模

CNN 建模数据被划分为训练集、验证集以及测试集 3 个数据集。9 450 组合成能谱数据按 6:2:2 的比例划分为训练集、验证集和测试集，则参与 CNN 建模的数据集组成如表 1 所示。

表 1 CNN 建模数据集组成

数据集	训练集	验证集	测试集
样本数量	5 670	1 890	1 890

笔者所建立的 CNN 模型架构包括 3 个卷积层、3 个池化层、1 个展开层、2 个全连接层、1 个 Dropout 层以及 1 个输出层。CNN 模型架构如图 1 所示。

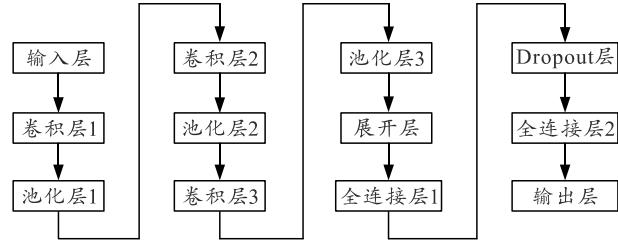


图 1 CNN 模型结构

利用训练集及验证集样本对上图所示模型进行训练及超参数优化，模型的超参数如表 2 所示。

表 2 CNN 模型超参数

序号	名称	卷积核大小	卷积核数量	神经元个数	删除比率
1	卷积层 1	16	3	/	/
2	池化层 1	/	3	/	/
3	卷积层 2	32	3	/	/
4	池化层 2	/	3	/	/
5	卷积层 3	32	3	/	/
6	池化层 3	/	3	/	/
7	全连接层 1	/	/	1 000	/
8	Dropout 层	/	/	/	0.1
9	全连接层 2	/	/	200	/

3.2 CNN 预测结果

利用建立的 CNN 模型对测试集中的单源核素数据进行预测，预测结果显示对 ^{241}Am 、 ^{133}Ba 、 ^{57}Co 、 ^{60}Co 、 ^{137}Cs 、 ^{152}Eu 以及 ^{40}K 7 种单源核素数据均正确认别，预测结果混淆如图 2 所示。

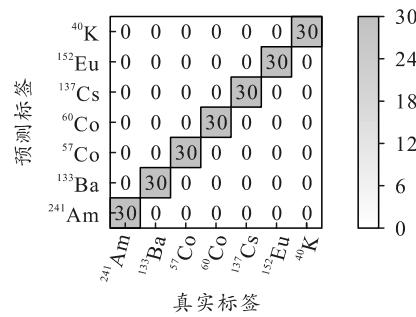


图 2 测试集单源核素预测混淆

利用建立的 CNN 模型对测试集中的两源核素数据进行预测，预测结果混淆如图 3 所示。预测结果显示来自 $^{133}\text{Ba}+^{152}\text{Eu}$ 一个样本被误识别为 $^{133}\text{Ba}+^{57}\text{Co}$ ；来自 $^{133}\text{Ba}+^{57}\text{Co}$ 一个样本被误识别为 $^{133}\text{Ba}+^{152}\text{Eu}$ 。

利用建立的 CNN 模型对测试集中的三源核素数据进行预测，预测结果混淆如图 4 所示。预测结果显示来自 $^{40}\text{K}+^{57}\text{Co}+^{133}\text{Ba}$ 一个样本被误识别为 $^{40}\text{K}+^{57}\text{Co}+^{152}\text{Eu}$ ；来自 $^{40}\text{K}+^{57}\text{Co}+^{152}\text{Eu}$ 2 个样本被误识别为 $^{40}\text{K}+^{57}\text{Co}+^{133}\text{Ba}$ ；来自 $^{40}\text{K}+^{60}\text{Co}+^{133}\text{Ba}$ 3 个样本被误识别为 $^{40}\text{K}+^{60}\text{Co}+^{152}\text{Eu}$ ；来自 $^{40}\text{K}+^{60}\text{Co}+^{152}\text{Eu}$ 2 个样本被误识别为 $^{40}\text{K}+^{60}\text{Co}+^{133}\text{Ba}$ 。

针对上述对测试集的预测结果，分别计算了查准率(P)、查全率(R)以及 F1 值 3 个评价指标，计算结果如表 3 所示。结果显示针对单源、两源以及三

源的 Macro P、Macro R 以及 F1 的计算结果均 > 0.99 ，表明针对测试集该 CNN 模型表现出较好的识别分类性能。

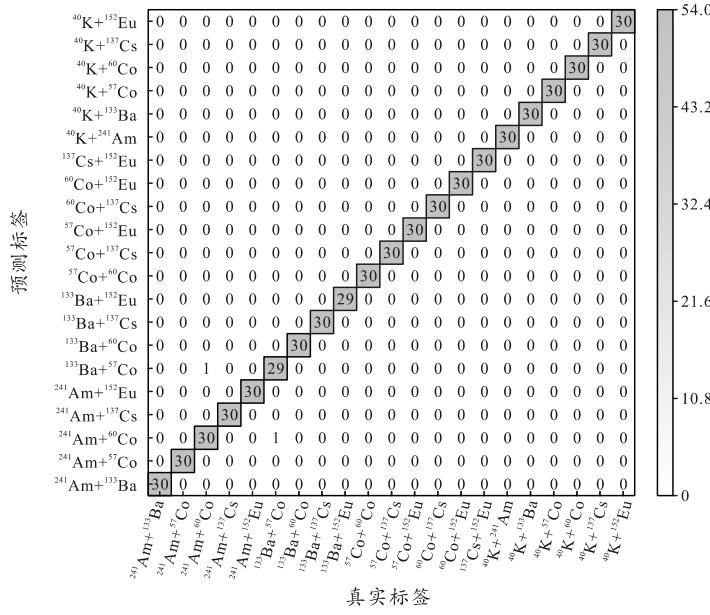


图 3 测试集中两源核素预测混淆

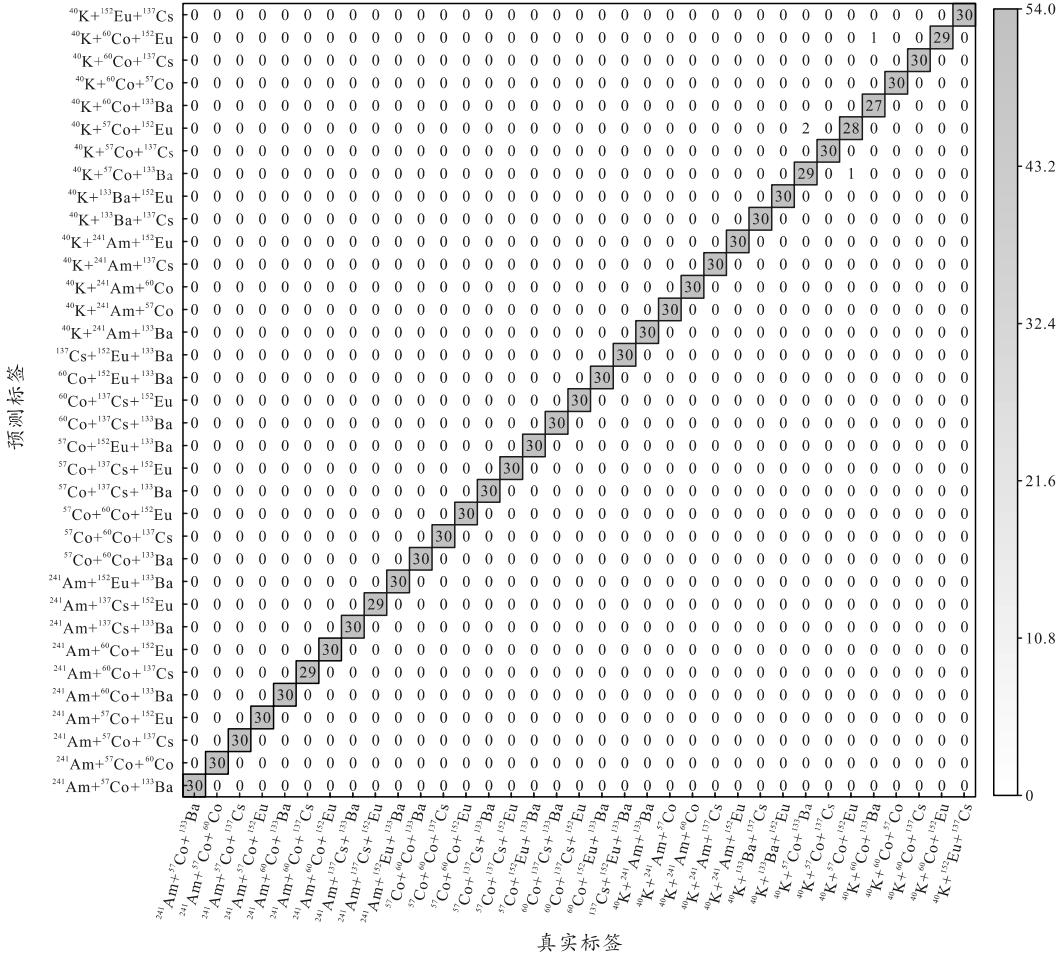


图 4 测试集中三源核素预测混淆