



## 基于卷积神经网络的放射性源项活度反演

胡湘 宋英明 夏月 张戈马 袁微微

### Activity Inversion of Radioactive Source Term Based on Convolutional Neural Network

HU Xiang, SONG Yingming, XIA Yue, ZHANG Gema, YUAN Weiwei

在线阅读 View online: <https://doi.org/10.11804/NuclPhysRev.40.2022104>

#### 引用格式:

胡湘, 宋英明, 夏月, 张戈马, 袁微微. 基于卷积神经网络的放射性源项活度反演[J]. *原子核物理评论*, 2023, 40(3):401–409. doi: 10.11804/NuclPhysRev.40.2022104

HU Xiang, SONG Yingming, XIA Yue, ZHANG Gema, YUAN Weiwei. Activity Inversion of Radioactive Source Term Based on Convolutional Neural Network[J]. *Nuclear Physics Review*, 2023, 40(3):401–409. doi: 10.11804/NuclPhysRev.40.2022104

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 基于Bayesian神经网络评价核裂变产额分布

Evaluation of Fission Yields with Bayesian Neural Networks

原子核物理评论. 2020, 37(4): 918–923 <https://doi.org/10.11804/NuclPhysRev.37.2020027>

#### 利用深度学习研究方法研究核物质状态方程

Using Deep Learning to Study the Equation of State of Nuclear Matter

原子核物理评论. 2020, 37(4): 825–832 <https://doi.org/10.11804/NuclPhysRev.37.2020017>

#### 基于粒子滤波和人工势场法的放射源搜寻方法

Search Method of Radioactive Source Based on Particle Filter and Artificial Potential Field

原子核物理评论. 2020, 37(4): 867–874 <https://doi.org/10.11804/NuclPhysRev.37.2020030>

#### HIAF高能辐照终端感生放射性

Induced Radioactivity at High-energy Irradiation Terminal of HIAF

原子核物理评论. 2018, 35(2): 165–171 <https://doi.org/10.11804/NuclPhysRev.35.02.165>

#### CiADS中LBE散裂靶的放射性核素研究

Radionuclides Study of Lead–bismuth Eutectic Spallation Target in CiADS

原子核物理评论. 2021, 38(3): 345–354 <https://doi.org/10.11804/NuclPhysRev.38.2021009>

#### 卵石材料在中子场下的次级放射性分析

Analysis of Induced Radioactivity in Pebbles Caused by High Energy Neutrons

原子核物理评论. 2018, 35(1): 53–60 <https://doi.org/10.11804/NuclPhysRev.35.01.053>

文章编号: 1007-4627(2023)03-0401-09

## 基于卷积神经网络的放射性源项活度反演

胡湘<sup>1</sup>, 宋英明<sup>1,2,†</sup>, 夏月<sup>1</sup>, 张戈马<sup>1</sup>, 袁微微<sup>2</sup>

(1. 南华大学核科学技术学院, 湖南 衡阳 421001;

2. 南华大学氡湖南省重点实验室, 湖南 衡阳 421001)

**摘要:** 放射性源项往往分布于探测目标内部, 难以直接定位和测量。为监测废物处理和核设施退役过程中放射性源项的剂量水平, 本工作提出了一种基于卷积神经网络(CNN)的源项活度反演方法, 建立了辐射场通量与源项活度的相关性。该方法对废物钢桶、内置过滤器滤芯的混凝土桶、内置空气过滤器的废物方箱及退役反应堆一回路管道建立源项计算模型, 并基于CNN对样本进行学习, 达到反演源项活度的目的。将活度反演结果与模拟实测值进行对比, 平均误差能控制在10%左右, 验证了该方法的有效性。这种方法能快速反演活度, 在预测精度和预测性能的稳定性上优于其他活度反演方法, 证明了CNN与源项活度反演的结合研究在废物处理和核设施退役等领域具有较高应用价值。

**关键词:** 活度反演; 放射性源项; 卷积神经网络

**中图分类号:** TL77

**文献标志码:** A

**DOI:** 10.11804/NuclPhysRev.40.2022104

### 0 引言

核设施经过长期运行, 无论是运行过程中产生的中低放射性固体废物, 还是退役过程中待拆除的各部件, 都存在不同程度的放射性核素污染, 而放射性源项计算分析能为废物管理与核设施退役提供参考依据<sup>[1]</sup>。放射性源项核素成分复杂, 经长时间才能衰减至可接受的放射性水平, 需选取适当方法对源项进行有效预测使便于处理。在实际辐射场景中, 精准获取源项活度等特征信息受测量手段的限制, 一般采用分析计算的方式得到源项数据, 可基于外部监测数据的优化反演获得放射性源项活度。

目前国内外用于源项活度反演的方法仍存在预测精度低、预测稳定性差等问题, 还未形成一种通用、快速准确的方案<sup>[2-4]</sup>。采用具有自学习、快速收敛特性的列文伯格-马夸特算法(LM)建立反演目标函数<sup>[5]</sup>, 求解目标函数的极小值得到点源活度, 并通过MCNP模拟探测器扫描多点源探测过程验证求解过程。由于准直屏蔽的作用, 反解点源活度时发现: 对于低活度点源反演的相对误差为高活度点源的5倍<sup>[6-7]</sup>, 探测结果差别较大。Li<sup>[8]</sup>提出通过探测器测量特征能量获取核素种类, 由辐射场剂量率实测值计算源项活度这一过程可转化为求解线性方程组问题迭代计算。研究结果的准确率高于简单

的插值和外推法, 但迭代计算时易导致不收敛, 人为选取迭代算法也对预测效果产生影响。

随着深度学习理论的提出和数值计算的改进, 卷积神经网络(CNN)在各领域得到飞速发展。Lecun<sup>[9]</sup>和Syafeeza等<sup>[10]</sup>基于LeNet-5模型提出复杂度较低的新CNN模型, 对人脸和手指静脉生物特征进行识别, 改进其他算法加快了收敛速度, 识别精度高达99.38%。在辐射防护领域, CNN也表现出强大潜能。Koo等<sup>[11]</sup>提出一种应用CNN的RPM放射性核素识别算法, 以能量加权谱的谱分布作为CNN模型的训练特征, 准确识别多数放射性核素, 证明了CNN在特征识别方面的可行性。

为解决现有源项反演方法中存在的预测精度低等问题, 本文提出基于CNN的源项活度反演方法, 利用CNN擅于特征分类这一特性改进源项反演方法。本研究针对三维辐射场内未知源项活度的核设施, 通过搭建合适的CNN来构造源项反演算法, 在无需解耦输入输出之间复杂物理关系的情况下, 提取空间辐射场数据作为神经网络的训练特征, 得到不依赖于具体物理模型的泛化神经网络。在现场测量手段受限的条件下, 测量设施所在空间辐射场通量反演获取指定位置的源项活度。

收稿日期: 2022-10-07; 修改日期: 2022-12-26

作者简介: 胡湘(1998-), 女, 湖南常德人, 硕士研究生, 从事辐射防护研究; E-mail: [hxiang77@foxmail.com](mailto:hxiang77@foxmail.com)

† 通信作者: 宋英明, E-mail: [songyingming@tsinghua.org.cn](mailto:songyingming@tsinghua.org.cn)

# 1 原理及研究流程

## 1.1 基于 CNN 的源项反演原理

CNN 是一种多层特征学习网络，最先用于解决视觉学习过程中的问题<sup>[12]</sup>，其主要原理是通过卷积核提取特征并转化。CNN 结构如图 1 所示。CNN 包括输入层、特征提取部分、全连接层和输出层，特征提取这一核心部分则由卷积层和池化层构成。




图 1 卷积神经网络结构示意图 (在线彩图)

卷积层利用神经元之间的参数共享减少网络参数数量，降低过拟合风险。卷积核将输入数据通过不同的卷积操作转化为多个具备不同特征的新数据，实现不同类型特征的提取。池化层能压缩数据，降低特征维数和计算复杂度，改善模型的旋转不变性<sup>[13-15]</sup>。在 CNN 中，设输入为  $I$ ，卷积核为  $K$ ，特征映射为  $F$ ，卷积核宽为  $M$ ，卷积核高为  $N$ ，多维卷积运算可表示为

$$F(i, j) = \sum_{m=0}^M \sum_{n=0}^N I(m, n)K(i - m, j - n). \quad (1)$$

若在反演时已知源项几何形状及位置分布，可将内部源项标记为若干几何体并表示为  $S=[S_1, S_2, \dots, S_n]$ ，对任意集合体存在与之对应的活度  $A=[A_1, A_2, \dots, A_n]$  空间中剂量率可表示为

$$D = F(A, S, L), \quad (2)$$

其中： $F$ 为计算剂量的因子； $L=[L_1, L_2, \dots, L_m]$ 为包含空间中  $m$  个测量点位置的矩阵； $D=[D_1, D_2, \dots, D_m]$ 为对应位置的剂量。

结合 CNN 的输出  $O$ 、反演因子  $k$  及反演误差  $e$ ，可将源项反演过程描述为

$$A = k(L, D, S) + e, \quad (3)$$

相比传统数值估算方法，将 CNN 应用于源项活度反演工作，误差更小，效率更高，可调整超参数使 CNN 模型适应多种预测对象。同时避免了物理量间的线性，具备较强的灵活性和通用性。

## 1.2 研究流程

基于 CNN 的放射性源项活度反演方法流程如图 2 所示。蒙特卡罗计算模块<sup>[16]</sup>采用粒子输运程序 MCNP5 中的网格计数卡模拟 NaI(Tl) 闪烁晶体探测器探测  $\gamma$  光子通量过程。在  $8\text{ m} \times 8\text{ m} \times 8\text{ m}$  辐射场空间内放置

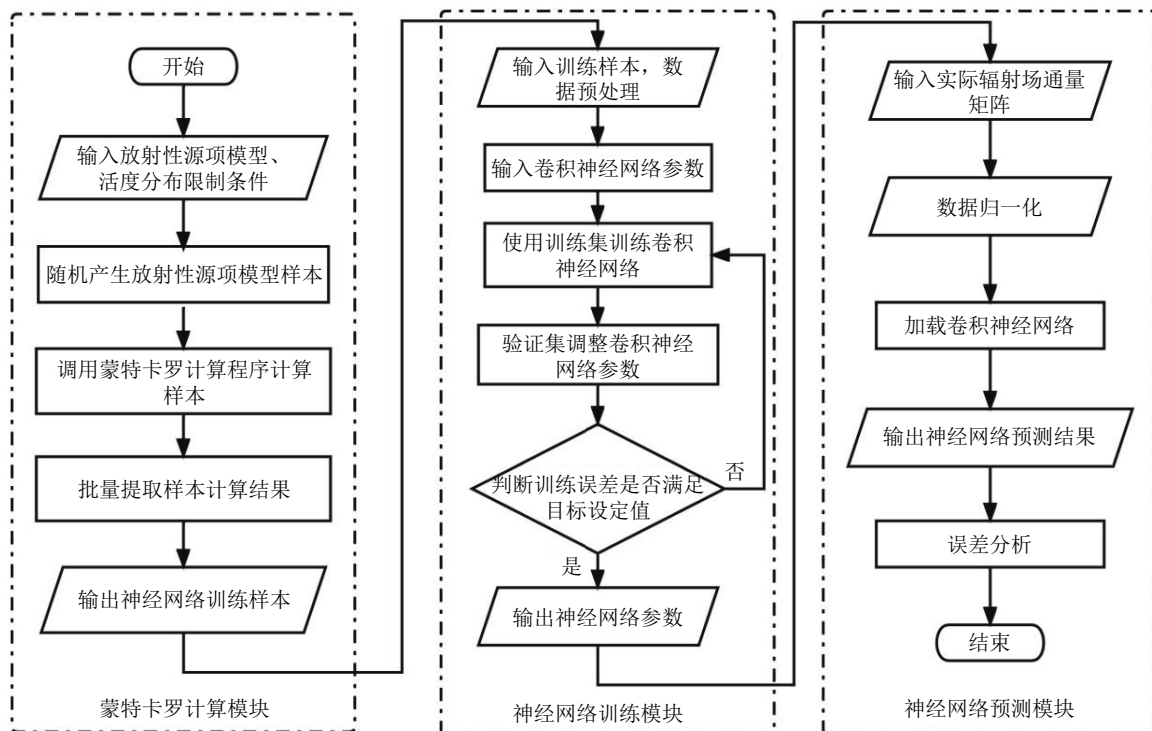


图 2 卷积神经网络结构示意图

NaI(Tl) 闪烁晶体和计算模型，晶体大小为 7.6 cm×7.6 cm，反射层厚为 0.05 cm，侧面与前部铝壳厚分别为 0.20, 0.25 cm，SiO<sub>2</sub> 层厚为 0.2 cm<sup>[17]</sup>，探测器放置在距计算模型 *x* 正轴方向 3 cm 处。放射性源项共列 6 种核素：47.14% <sup>58</sup>Co、10.49% <sup>60</sup>Co、14.97% <sup>137</sup>Cs、14.14% <sup>51</sup>Cr、9.78% <sup>54</sup>Mn 及 3.48% <sup>63</sup>Ni。在模拟计算时一般以核素  $\gamma$  射线能量作为源项进行模拟，但当放射性源项所处环境的屏蔽较厚时（例如混凝土桶）易导致统计涨落较大。为保证精度，本研究采用单一能量 2 MeV 进行模拟，对最终结果加权求和得到各核素通量。模型内部包含多个热点，在放射性活性区域各处均有分布，模拟不同活度分布的放射性源项，神经网络预测结果中给出了部分位置的活度。

神经网络训练模块对放射性源项模型样本进行训练，直到训练误差满足目标设定值，保存 CNN 参数。神经网络预测模块输入模拟的实际通量矩阵，利用已训练完成的神经网络预测活度，计算预测值与模拟实测值的相对误差，验证方法的可行性。

## 2 网络模型构建及参数分析

### 2.1 CNN 各参数影响分析

神经网络搭建成功的关键在于其泛化效果，其结构的合理性在于对样本以外的其他输入也能进行较好反演。CNN 属于回归模型<sup>[18]</sup>，常采用均方误差(MSE)函数作为损失函数<sup>[19]</sup>判断神经网络的收敛精度及泛化效果，均方误差值越小，网络泛化效果越好。其函数表达式为

$$L_{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2, \quad (4)$$

式中：分母 *n* 为样本数据个数；分子为预测值与真值误差平方的集合。

在神经元中，引入激活函数能增加神经网络模型的非线性。ReLU 函数在输入负值时会导致神经元死亡和梯度消失<sup>[20]</sup>，常选取 ReLU 的变体函数弥补其缺陷。ELU 函数的梯度对于所有负值均为非零，避免了神经元死亡，在缩短训练时间和提高准确度方面优于其他变体函数。其函数表达式如下：

$$ELU(x) = \begin{cases} x, & x > 0 \\ \alpha(e^x - 1), & x \leq 0 \end{cases}, \quad (5)$$

其中  $\alpha$  为根据模型实时变化的适宜常数。

#### 2.1.1 隐含层神经元数影响分析

在给定初始权值前提下，采用双隐含层对样本数据进行训练，当神经元数量分别为 20, 40, 60, ..., 200 时，

记录迭代训练 80 次后的均方误差值。

收敛精度的均方误差值如图 3 所示，随着神经元数量的增加，均方误差值有降低趋势，神经元数低于 140 时，曲线降低幅度较大，均方误差最大值为 45.90%，最小值为 18.88%，说明神经元数量对收敛精度影响较大。若神经元太少，则网络无法转换正确输出；而神经元太多，则增加神经网络工作量。




图 3 神经元个数对收敛精度的影响曲线

#### 2.1.2 样本数影响分析

在实际建模过程中发现：实验数据一定时，神经网络学习样本数量对泛化效果也存在影响。当数量取 500~4 500 时，检验样本数取 500 时，由图 4 曲线所示。训练样本过少，网络训练不充分不足以反映实际数据的特征；训练样本过多，在达到几乎相同的泛化效果条件下增加了神经网络训练负担。因此选取合适样本数能减少神经网络训练耗时。




图 4 样本数对收敛精度的影响曲线

## 2.2 CNN 模型结构

结合 3.1 中的分析结果，选取如表 1 所列参数构建 CNN 模型，损失函数为均方误差函数 (MSE)，激活函数为 ELU 函数，批处理大小设为 64，交叉验证集比例为 9:1，使用 Adam 优化器 (学习率为  $1 \times 10^{-5}$ ，超参数  $\beta$



为 0.5) 进行训练, 最大迭代次数为 180 次。网络性能目标误差设定为 10%, 当神经网络的训练误差低于目标设定值时, 认为神经网络已达到下一步预测源项活度的基本条件, 中止训练。

表 1 CNN 模型各层参数配置

网络层名称	网络输入	参数说明
Conv1	Input_detectors	卷积核数量: 32 卷积核大小: (5, 5, 5)
Conv2	Conv1	卷积核数量: 32 卷积核大小: (5, 5, 5)
Maxpool1	Conv2	步长: 1 掩膜大小: (2, 2, 2)
Conv3	Maxpool1	卷积核数量: 16 卷积核大小: (3, 3, 3)
Conv4	Conv3	卷积核数量: 16 卷积核大小: (3, 3, 3)
Maxpool2	Conv4	步长: 1 掩膜大小: (2, 2, 2)
Conv5	Maxpool2	卷积核数量: 8 卷积核大小: (2, 2, 2)
Conv6	Conv5	卷积核数量: 8 卷积核大小: (2, 2, 2)
Cout	Conv6	向量参数一维化
Dense1	Cout	神经元数目: 120
Dense2	Dense1	神经元数目: 80
Output	Dense2	

表 1 中 Input\_detectors 层为三维剂量分布矩阵的输入层; Conv1~Conv6 为卷积层; Maxpool1~Maxpool2 为池化层; Dense1~Dense2 为全连接层; Output 为输出层。在 CNN 模型中通过卷积、池化的方法逐层提取通量和源项的分布特征, 再通过全连接层映射到各源项活度输出。

### 2.3 CNN 模型训练时效对比

为研究 CNN 对于反演算法的预测效果, 表 2 实验结果对比了 CNN 与三类源项反演典型耦合优化算法<sup>[21]</sup>反演 3 000 次的平均耗时情况。整体来看, CNN 的平均反演耗时与 GA-NM 算法、PSO-NM 算法接近, 明显快于 GA-PSO 算法。在源项反演的时效性上, CNN 用时较短, 效率较高。

表 2 各算法实验结果对比

实验方法	平均反演耗时/s
遗传与粒子群算法耦合(GA-PSO)	12.46
粒子群与单纯形算法耦合(PSO-NM)	1.65
遗传与粒子群耦合算法(GA-NM)	1.57
卷积神经网络(CNN)	1.55

## 3 反演结果分析

### 3.1 废物钢桶模型预测结果分析

目前核电厂主要将产生的中低放射性固体废物压缩后置于钢桶中, 图 5 展示了废物钢桶模型剖面视图。废物钢桶<sup>[22]</sup>内部半径为 56.0 cm, 高 89.0 cm, 壁厚 0.2

cm, 桶内覆盖物材料主要为废个人防护用具<sup>[23]</sup>, 桶外为空气。建立如图 5 所示源项计算模型, 使用蒙特卡罗批量产生程序、批量计算程序和结果批量提取程序, 整合网格计数卡统计的通量值及各分区的比活度, 归一化处理后作为 CNN 的特征学习样本。




图 5 废物钢桶及内置源项模型剖面图(在线彩图)

选用均方差函数评估模型训练效果。图 6(a) 展示了以训练迭代次数为横轴的算法误差值曲线波动, 虚线和实线分别表示训练集、验证集误差曲线。从图中可以看出, 训练初始阶段误差较大, 废物钢桶模型误差值下降偏慢, 迭代近 150 次后趋于稳定。训练完成后输入模拟实际通量矩阵, 图 6(b) 为活度预测值与模拟实测值拟合结果, 拟合优度为 0.961 8, 理论上拟合优度大于 0.9 时即认为数据相关性较高<sup>[24]</sup>。

由表 3 预测数据计算得到活度预测平均相对误差为 9.45%, 最大相对误差为 17.68%, 证实了该活度反演方法预测精度较高, 具有优异的数据学习能力和准确的活度预测能力。该方法预测误差波动范围较小, 预测性能较稳定。多点源活度反演算法对低活度点源的反演误差远高于高活度点源, 预测性能不够稳定<sup>[5]</sup>, 而迭代计算辐射场剂量率实测值和源项活度的线性方程组时, 点源活度的预测性能较稳定, 但误差均大于 10%, 精度上仍需提高<sup>[8]</sup>。相较于这两种方法, 基于 CNN 的源项活度反演方法在预测的准确性和预测性能的稳定性上都取得了更优越的效果。

### 3.2 内置过滤器滤芯的混凝土桶模型

混凝土桶也常用于存放中低放射性固体废物, 其中 C4 桶用于存放废过滤器芯子<sup>[25-26]</sup>。构建如图 7 所示的内置过滤器滤芯的 C4 型混凝土桶简化模型。模型桶

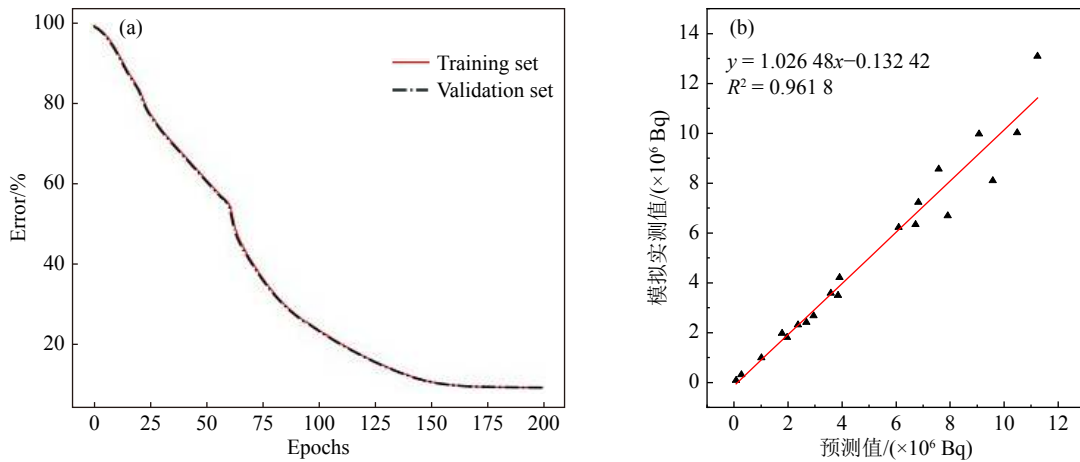


图 6 废物钢桶模型预测情况(在线彩图)

(a) 训练集、验证集误差随迭代次数变化情况; (b) 活度预测拟合结果。

表 3 废物钢桶模型内活度预测结果

源项位置/cm	模拟值/Bq	预测值/Bq	相对误差/%	源项位置/cm	模拟值/Bq	预测值/Bq	相对误差/%
(12, 12, 30)	$5.47 \times 10^6$	$4.93 \times 10^6$	-9.84	(-4, -17, -3)	$8.94 \times 10^6$	$1.02 \times 10^7$	14.24
(-13, -13, 34)	$8.06 \times 10^6$	$9.16 \times 10^6$	13.74	(28, -13, -7)	$4.52 \times 10^6$	$3.96 \times 10^6$	-12.36
(-17, 17, 38)	$7.94 \times 10^6$	$6.66 \times 10^6$	-16.01	(11, 22, -30)	$3.60 \times 10^6$	$3.25 \times 10^6$	-9.77
(20, -20, 42)	$2.77 \times 10^6$	$3.01 \times 10^6$	8.78	(-25, 3, -34)	$1.14 \times 10^6$	$1.15 \times 10^6$	1.49
(23, 9, 11)	$4.62 \times 10^5$	$4.45 \times 10^5$	-3.67	(-21, -25, -38)	$7.15 \times 10^6$	$7.93 \times 10^6$	10.87
(-7, 21, 14)	$2.99 \times 10^6$	$2.54 \times 10^6$	-15.06	(25, -9, -42)	$8.87 \times 10^5$	$9.81 \times 10^5$	10.58
(-27, -8, 17)	$8.80 \times 10^6$	$8.58 \times 10^6$	-2.53	(27, 15, -11)	$7.21 \times 10^6$	$6.22 \times 10^6$	-13.79
(6, -23, 25)	$7.39 \times 10^5$	$6.08 \times 10^5$	-17.68	(-10, 10, -14)	$4.79 \times 10^6$	$4.78 \times 10^6$	-0.19
(25, 16, 7)	$3.99 \times 10^6$	$4.18 \times 10^6$	4.66	(-26, -19, -17)	$6.86 \times 10^6$	$6.40 \times 10^6$	-6.73
(-23, 21, 3)	$8.27 \times 10^6$	$9.39 \times 10^6$	13.56	(21, 25, -25)	$5.41 \times 10^6$	$5.60 \times 10^6$	3.49




图 7 内置过滤器滤芯的混凝土桶模型剖面图(在线彩图)

体材料为C20混凝土,桶外高130.0 cm,侧面壁厚15.0 cm,内置过滤器滤芯高95.6 cm,过滤层依次设外衬纸层、

滤材层、海绵层和活性炭层等。

分析图8和表4可知,该类模型的训练误差可降至9.4%,其预测的平均误差为8.28%,与废物钢桶模型的误差相比略低,数据误差在合理范围内,说明基于CNN的源项活度反演方法同样适用于该类模型,预测精度未因模型更换而降低,证明了该CNN模型具有较强适应性。

### 3.3 内置空气过滤器的废物方箱模型

标准箱也常作为放射性废物处理容器。如图9所示构建不同放射性活度分布的废物方箱模型,内置空气过滤器尺寸为61.0 cm×61.0 cm×29.2 cm,外部为铁金属框架,内部为折叠空气过滤器滤纸,将空气过滤器置于100 cm×80 cm×80 cm的金属方箱内。

对该模型进行相同迭代训练,误差随迭代次数变化情况如图10(a)所示,模型误差值下降速度较快,迭代80次后误差曲线趋于平稳,训练集误差降至8.9%。图10(b)为模型活度预测拟合结果,拟合优度为0.96331。

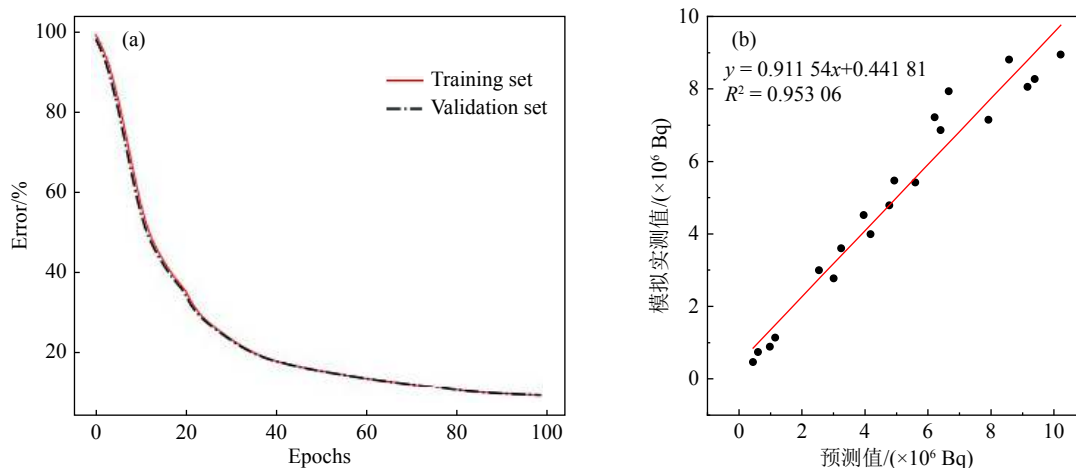


图 8 内置过滤器滤芯的混凝土桶模型预测情况(在线彩图)  
(a) 训练集、验证集误差随迭代次数变化情况; (b) 活度预测拟合结果。

表 4 内置过滤器滤芯的混凝土桶模型内活度预测结果

源项位置/cm	模拟值/Bq	预测值/Bq	平均误差/%	源项位置/cm	模拟值/Bq	预测值/Bq	平均误差/%
(28, 35, 30)	$3.58 \times 10^6$	$3.56 \times 10^6$	-0.56%	(-13, -57, -3)	$1.96 \times 10^6$	$1.79 \times 10^6$	-8.67%
(-37, 39, 34)	$7.56 \times 10^6$	$8.51 \times 10^6$	12.57%	(57, -12, -7)	$2.68 \times 10^6$	$2.40 \times 10^6$	-10.45%
(-52, 42, 38)	$9.56 \times 10^6$	$8.05 \times 10^6$	-15.79%	(19, -42, -30)	$3.91 \times 10^6$	$4.30 \times 10^6$	9.97%
(45, 47, 42)	$2.73 \times 10^5$	$3.11 \times 10^5$	13.92%	(-75, -33, -34)	$3.07 \times 10^5$	$2.89 \times 10^5$	-5.86%
(51, 45, 11)	$6.09 \times 10^6$	$6.18 \times 10^6$	1.48%	(-65, -37, -38)	$1.77 \times 10^6$	$1.95 \times 10^6$	10.17%
(-21, 36, 14)	$1.12 \times 10^7$	$1.30 \times 10^7$	16.07%	(71, -46, -42)	$1.05 \times 10^7$	$9.97 \times 10^6$	-5.05%
(-77, 30, 17)	$1.01 \times 10^6$	$1.07 \times 10^6$	5.94%	(72, -7, -11)	$3.84 \times 10^6$	$3.49 \times 10^6$	-9.11%
(6, 22, 25)	$9.05 \times 10^5$	$9.91 \times 10^5$	9.50%	(-44, -64, -14)	$2.94 \times 10^6$	$2.87 \times 10^6$	-2.38%
(63, 7, 7)	$7.90 \times 10^6$	$6.65 \times 10^6$	-15.82%	(-66, -30, -17)	$6.71 \times 10^6$	$6.30 \times 10^6$	-6.11%
(-71, 17, 3)	$2.36 \times 10^6$	$2.30 \times 10^6$	-2.54%	(37, -39, -25)	$6.81 \times 10^6$	$7.08 \times 10^6$	3.96%




图 9 内置空气过滤器的废物方箱模型剖面图(在线彩图)

由表 5 实验结果分析, 对于内置空气过滤器废物的方箱模型, 源项活度预测的最大误差为 15.69%, 平均误差为 9.18%。

该方法对多种放射性源项模型均能实现活度反演目标且预测精度较高, 模型的通用性也得以验证。综合分析以上三种模型的预测情况, 部分源项预测值误差相对偏高的可能原因如下: 1) 源项模型简化时引起误差; 2) 使用蒙特卡罗方法计算源项时引入误差; 3) 神经网络

训练过程中参数设置导致的误差。可通过优化辐射场数据分析方法、调整参数等来减小误差, 实现更高精度的预测。

### 3.4 退役反应堆一回路管道模型

以上模型实现了对容器内的放射性源项活度反演, 而在核设施退役过程中, 同样可对空间内待拆除部件进行源项活度的反演。如图 11 构建退役反应堆一回路部分管道模型, 管道材料为碳钢。对图中除入口管道外其他 10 根管道进行活度预测。源项位于管道中心, 管道内活度均匀分布, 管道中心活度代表该管道的平均活度。

反演数据如表 6 所列, 反应堆一回路部分管道模型内活度预测的最大误差为 24.95%, 平均误差为 13.88%, 预测效果在可接受范围内。说明该方法能实现对空间内管道活度的模拟预测, 再次证明该方法对高精度的源项反演预测的通用性。

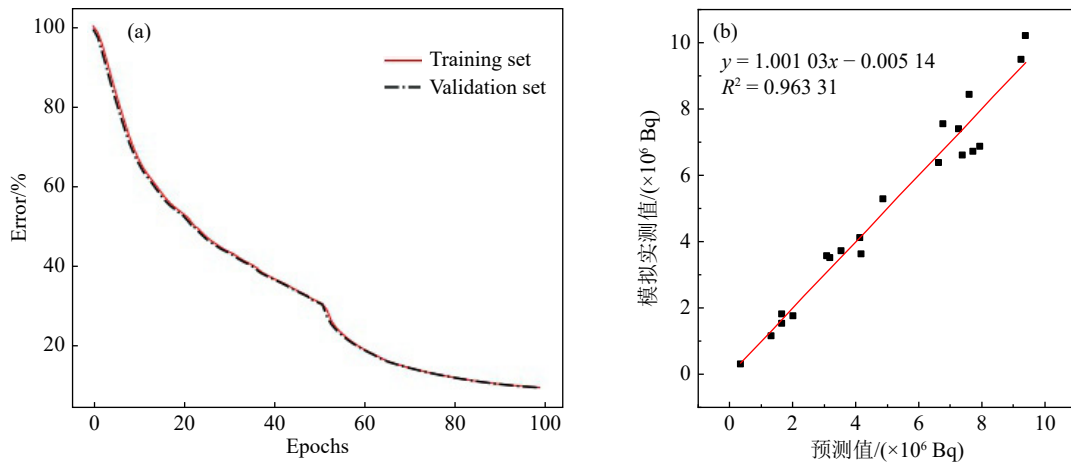


图 10 内置空气过滤器的废物方箱模型预测情况(在线彩图)

(a) 训练集、验证集误差随迭代次数变化情况; (b) 活度预测拟合结果。

表 5 内置空气过滤器的废物方箱模型内活度预测结果

源项位置/cm	模拟值/Bq	预测值/Bq	相对误差/%	源项位置/cm	模拟值/Bq	预测值/Bq	相对误差/%
(-27, 27, -4)	$4.18 \times 10^6$	$3.63 \times 10^6$	-13.17	(-27, 27, 12)	$7.94 \times 10^6$	$6.86 \times 10^6$	-13.58
(-22, -22, -12)	$3.18 \times 10^6$	$3.51 \times 10^6$	10.46	(-22, -22, 2)	$3.54 \times 10^6$	$3.73 \times 10^6$	5.32
(-18, 18, -4)	$3.08 \times 10^6$	$3.56 \times 10^6$	15.69	(-18, 18, 12)	$4.14 \times 10^6$	$4.11 \times 10^6$	-0.65
(-12, -12, -12)	$4.87 \times 10^6$	$5.28 \times 10^6$	8.35	(-12, -12, 2)	$3.47 \times 10^5$	$3.09 \times 10^5$	-10.89
(-6, 6, -4)	$6.64 \times 10^6$	$6.37 \times 10^6$	-4.01	(-6, 6, 12)	$1.65 \times 10^6$	$1.81 \times 10^6$	9.29
(2, -2, -12)	$7.73 \times 10^6$	$6.71 \times 10^6$	-13.19	(2, -2, 2)	$7.27 \times 10^6$	$7.39 \times 10^6$	1.72
(6, 6, -4)	$1.33 \times 10^6$	$1.16 \times 10^6$	-12.60	(6, 6, 12)	$9.39 \times 10^6$	$1.02 \times 10^7$	8.66
(13, -13, -12)	$7.62 \times 10^6$	$8.43 \times 10^6$	10.65	(13, -13, 2)	$7.39 \times 10^6$	$6.60 \times 10^6$	-10.67
(18, 18, -4)	$2.02 \times 10^6$	$1.76 \times 10^6$	-12.97	(18, 18, 12)	$6.77 \times 10^6$	$7.55 \times 10^6$	11.51
(23, -23, -12)	$9.26 \times 10^6$	$9.49 \times 10^6$	2.50	(23, -23, 2)	$1.66 \times 10^6$	$1.53 \times 10^6$	-7.64

表 6 反应堆一回路部分管道模型内活度预测结果

源项位置/cm	模拟值/Bq	预测值/Bq	相对误差/%	源项位置/cm	模拟值/Bq	预测值/Bq	相对误差/%
(710, 10, 90)	$1.22 \times 10^7$	$1.06 \times 10^7$	-13.43%	(260, 145, -140)	$1.15 \times 10^7$	$1.25 \times 10^7$	9.46%
(740, 240, 20)	$1.49 \times 10^7$	$1.37 \times 10^7$	-8.01%	(630, 10, 185)	$7.70 \times 10^6$	$7.35 \times 10^6$	-4.60%
(470, 240, -140)	$1.83 \times 10^7$	$1.54 \times 10^7$	-15.60%	(800, 10, 65)	$8.46 \times 10^6$	$8.09 \times 10^6$	-4.35%
(540, 50, -320)	$6.88 \times 10^6$	$5.59 \times 10^6$	-18.75%	(680, 240, -80)	$6.61 \times 10^6$	$8.00 \times 10^6$	21.02%
(800, 125, -20)	$7.81 \times 10^5$	$9.76 \times 10^5$	24.95%	(260, 50, -230)	$1.35 \times 10^7$	$1.60 \times 10^7$	18.63%




图 11 反应堆一回路管道模型示意图(在线彩图)

## 4 结论

本文提出了一种基于 CNN 的放射性源项活度反演方法，为探测未知源项活度的放射性源项提供了技术支持。建立四类放射性源项计算模型，利用蒙特卡罗方法构建物理模型进行模拟计算，以辐射场通量和不同分布的源项活度作为神经网络训练的输入输出，通过 CNN 反演放射源活度。对活度预测数据与模拟实测数据的拟合结果表明，该源项反演方法具有可行性，且经四类放射性源项模型验证了该方法的准确性。相较其他反演方法，基于 CNN 的源项反演耗时较少，在精度上能将平均误差降至 10% 以下，同时保证数据预测的稳定性，对于废物处理及核设施退役过程中放射性源项活度的监



测有着重要意义。根据其他复杂模型的实际情况调整网络结构和优化各项参数,可进一步提高 CNN 源项反演的通用性。

#### 参考文献:

- [1] LIU Jiajia, CHEN Hao, DENG Lilin. *China Nuclear Power*, 2020, 13(2): 240. (in Chinese)  
(刘嘉嘉, 陈晔, 邓理邻. *中国核电*, 2020, 13(2): 240.)
- [2] BÜCHER L, KALTHOFF O, GOSTOMSKI C V, et al. *Physics Procedia*, 2017, 88: 64.
- [3] ASAHARA A, KAWASAKI D, YANAGIHARA S. *Nuclear Engineering and Design*, 2021, 374: 111066.
- [4] AN Hongzhen, XU Chunyan, BI Sheng. *China Nuclear Industry*, 2014(4): 38. (in Chinese)  
(安洪振, 徐春艳, 毕升. *中国核工业*, 2014(4): 38.)
- [5] YANG Hongwei, ZHANG Liang. *Annual Report of China Institute of Atomic Energy*, 2009(1): 444. (in Chinese)  
(杨宏伟, 张良. *中国原子能科学研究院年报*, 2009(1): 444.)
- [6] HONG Z, ZHOU R, LIN T. *Journal of Xi'an Jiaotong University*, 2002, 36(5): 523.
- [7] SANG Y P, FAN P Z, HAO L, et al. *Computer Applications*, 2004, 24(7): 108.
- [8] LI Hua. *Research and Preliminary Application of Fast Calculation of Gamma Radiation Field and Source Term Inversion Algorithm [D]*. Beijing: Tsinghua University, 2016: 86. (in Chinese)  
(李华.  $\gamma$ 辐射场快速计算与源项反演算法研究及初步应用[D]. 北京: 清华大学, 2016: 86.)
- [9] LECUN Y. LeNet-5, Convolutional Neural Networks[EB/OL]. [2022-09-15]. <http://yann.lecun.com/exdb/lenet>.
- [10] RADZI S A, HANI M K, BAKHTERI R. *Turkish Journal of Electrical Engineering and Computer Sciences*, 2016, 24(3): 1863.
- [11] KOO B T, LEE H C, BAE K, et al. *Radiation Physics and Chemistry*, 2021, 180: 109300.
- [12] FUKUSHIMA K. *Biological Cybernetics*, 1980, 36(4): 193.
- [13] SHU Hongqiao, HONG Ying, LIU Yan. *Network New Media Technology*, 2020, 9(1): 40. (in Chinese)  
(舒红乔, 洪缨, 刘岩. *网络新媒体技术*, 2020, 9(1): 40.)
- [14] LUO Songjiang, QIU Shuisheng. *Microcomputer Information*, 2009, 25(09): 161. (in Chinese)  
(罗松江, 丘水生. *微计算机信息*, 2009, 25(09): 161.)
- [15] LECUN Y, BOSER B, DENKER J S, et al. *Neural Computation*, 1989, 1(4): 541.
- [16] SIEGEL A R, SMITH K, ROMANO P K, et al. *The International Journal of High Performance Computing Applications*, 2014, 28(1): 87.
- [17] Fudan University. *Experimental Methods of Nuclear Physics[M]*. Beijing: Atomic Energy Press, 1997: 165. (in Chinese)  
(复旦大学. *原子核物理实验方法[M]*. 北京: 原子能出版社, 1997: 165.)
- [18] KORDZAKHIA N, MISHRA G D, REIERSØLMOEN L. *Journal of Statistical Planning and Inference*, 2001, 98(1-2): 211.
- [19] KÖKSOY O. *Applied Mathematics and Computation*, 2006, 175(2): 1716.
- [20] DUBEY S R, SINGH S K, CHAUDHURI B B. arXiv: 2109.14545.
- [21] SHEN Zeya, LANG Jianlei, CHENG Shuiyuan, et al. *China Environmental Science*, 2019, 39(08): 3207. (in Chinese)  
(沈泽亚, 郎建垒, 程水源, 等. *中国环境科学*, 2019, 39(08): 3207.)
- [22] SU Rongbo, YANG Linfeng, TUO Xianguo, et al. *Nuclear Electronics and Detection Technology*, 2012, 32(11): 1332. (in Chinese)  
(苏容波, 阳林峰, 庾先国, 等. *核电子学与探测技术*, 2012, 32(11): 1332.)
- [23] ZHANG Gen, XIONG Xiao, REN Lili, et al. *Journal of Nuclear Safety*, 2022, 21(1): 104. (in Chinese)  
(张根, 熊骁, 任丽丽, 等. *核安全*, 2022, 21(1): 104.)
- [24] WANG Lei, XU Yongqiang. *Zhejiang Water Conservancy Science and Technology*, 2022, 50(4): 18. (in Chinese)  
(王磊, 许永强. *浙江水利科技*, 2022, 50(4): 18.)
- [25] WEN Yinghui. *China Nuclear Science and Technology Report*, 1995(1): 955. (in Chinese)  
(温英惠. *中国核科技报告*, 1995(1): 955.)
- [26] XUE Dahai, YOU Zhijun, CUI Anxi. *Radiation Protection Communication*, 2008(2): 28. (in Chinese)  
(薛大海, 游志均, 崔安熙. *辐射防护通讯*, 2008(2): 28.)

# Activity Inversion of Radioactive Source Term Based on Convolutional Neural Network

HU Xiang<sup>1</sup>, SONG Yingming<sup>1,2,†</sup>, XIA Yue<sup>1</sup>, ZHANG Gema<sup>1</sup>, YUAN Weiwei<sup>2</sup>

(1. School of Nuclear Science and Technology, University of South China, Hengyang 421001, Hunan, China;

2. Radon Provincial Key Laboratory, University of South China, Hengyang 421001, Hunan, China)

**Abstract:** The radioactive source terms are often distributed inside the detection target, which are difficult to be located and measured directly. In order to monitor the dose level of radioactive source terms during the waste treatment and nuclear facilities decommissioning, in this research we propose an activity inversion method of radioactive source terms based on convolutional neural network(CNN), and establishes the correlation between the radiation field flux and the source term activity. In this method, source terms calculation models are established for waste steel barrel, concrete barrel with built-in filter, square box with built-in air filter and pipeline in primary circuit of reactor, and the samples are learned based on CNN for source term activity inversion. Compared the activity inversion results with the simulated measured values, the average error can be controlled at about 10%, which verifies the effectiveness of the proposed method. In addition, the accuracy of prediction and stability performance of this method are superior to other activity inversion methods. Which proves that the combination of CNN and source term activity inversion has high application value in the fields of waste disposal and nuclear facilities decommissioning.

**Key words:** activity inversion; radioactive source terms; convolutional neural network

---

Received date: 07 Oct. 2022; Revised date: 26 Dec. 2022

† Corresponding author: SONG Yingming, E-mail: [songyingming@tsinghua.org.cn](mailto:songyingming@tsinghua.org.cn)