

## 基于 U-Net 的 $\gamma$ 测厚方法研究

吕亮亮<sup>1,2</sup>, 高旭东<sup>1,2</sup>, 魏雯静<sup>1,2</sup>, 李 畅<sup>1,2</sup>, 孙淑义<sup>1,2</sup>, 雷胤琦<sup>1,2</sup>, 潘小东<sup>1,2</sup>, 李公平<sup>1,2,\*</sup>

(1. 兰州大学 核科学与技术学院, 甘肃兰州 730000;  
2. 兰州大学 特殊功能材料与结构设计教育部重点实验室, 甘肃兰州 730000)

**摘要:** 噪声环境或复杂放射性本底环境下采用  $\gamma$  吸收法测厚时, 由于噪声和其他同位素特征峰会对测厚结果产生不利影响,  $\gamma$  吸收法测厚方法的稳定性和抗干扰能力有待进一步提升。因此, 基于深度学习建立一种新颖的  $\gamma$  能谱测厚方法, 并利用<sup>241</sup>Am 放射源和碲锌镉探测器搭建了一套  $\gamma$  测厚装置, 对测厚方法进行训练和验证。首先, 利用搭建的测厚装置对不锈钢、陶瓷和塑料等不同材质、不同厚度的样品进行测量。随后, 利用采集到的能谱数据建立数据集对测厚方法进行训练, 在原始能谱数据中添加高斯噪声和高斯峰模拟不同程度的噪声和放射性环境, 研究了  $\gamma$  测厚方法在不同噪声和放射性环境下测厚稳定性, 并与传统方法进行对比。结果表明, 在相同噪声环境下, 建立的  $\gamma$  测厚方法引起的最大峰面积变化率仅 0.049%, 优于传统方法的 0.85%; 在有其他高斯峰干扰的情况下, 建立的  $\gamma$  测厚方法能有效扣除其他高斯峰, 最大峰面积变化率仅 7.58%, 优于传统方法的 33.29%, 抗干扰能力优于传统方法。因此, 基于深度学习建立的测厚方法为  $\gamma$  射线测厚的数据处理提供了新思路, 提高了  $\gamma$  测厚方法的抗噪能力和抗干扰能力, 有助于将  $\gamma$  测厚方法应用于复杂放射性环境, 进一步拓宽  $\gamma$  测厚方法的应用领域。

**关键词:** 无损测量; 深度学习;  $\gamma$  吸收测厚; 基线扣除

中图分类号: TL81; TP18

文献标志码: A

文章编号: 1000-6931(2024)08-1777-12

doi: [10.7538/yzk.2023.youxian.0746](https://doi.org/10.7538/yzk.2023.youxian.0746)

## Research on Gamma-thickness Measurement Method Based on U-Net

LYU Liangliang<sup>1,2</sup>, GAO Xudong<sup>1,2</sup>, WEI Wenjing<sup>1,2</sup>, LI Chang<sup>1,2</sup>, SUN Shuyi<sup>1,2</sup>,  
LEI Yinqi<sup>1,2</sup>, PAN Xiaodong<sup>1,2</sup>, LI Gongping<sup>1,2,\*</sup>

(1. School of Nuclear Science and Technology, Lanzhou University, Lanzhou 730000, China;  
2. Key Laboratory of Special Functional Materials and Structural Design,  
Ministry of Education, Lanzhou University, Lanzhou 730000, China)

**Abstract:** The presence of noise and other isotope characteristics in the background environment can significantly impact the accuracy of thickness measurements when using the  $\gamma$ -absorption method in a noisy or complex radioactive environment. Therefore, it is essential to conduct research on a gamma absorption method with strong anti-noise capabilities and good stability. Aiming at the problems of energy spectrum background elimination and peak area calculation in gamma thickness measurement, a gamma thickness measurement method was established based on U-Net deep learning network to improve the measurement efficiency, stability and anti-interference ability of gamma thickness measurement method. Firstly, a gamma absorption thickness measuring device was built based on

<sup>241</sup>Am radioactive source and cadmium zinc telluride detector to measure samples of different thickness and obtain sufficient energy spectrum data. The corresponding baseline elimination spectra were obtained by traditional methods and manual methods, and the training dataset was established. The gamma spectrum baseline elimination network was built based on U-Net, and the network was trained using the established dataset. Using the PPS40 thickness measurement results as an example, Gaussian noise and a Gaussian peak were added to the original energy spectrum data to simulate various levels of noise and radioactive environment. The stability of the thickness measurement method under various noise and radioactive environment was studied, and it was compared with the conventional method. The findings reveal that the established gamma thickness measurement method yields a maximum peak area change rate of only 0.049% under the same noise environment, outperforming the conventional approach's 0.85%. In the presence of interference from other Gaussian peaks, the proposed gamma thickness measuring method can effectively subtract the Gaussian peaks unrelated to thickness measurement, with a maximum peak area change rate of only 7.58%, outperforming the traditional method which has a peak area change rate of 33.29%. This demonstrates a superior anti-interference capacity compared to the conventional method. As a result, the gamma thickness measurement method based on deep learning offers a novel approach to the data processing of gamma ray thickness measurement. It enhances the gamma thickness measurement method's anti-noise and anti-interference capability, enabling its application in complex radiation environments and expanding its potential application fields.

**Key words:** nondestructive measurement; deep learning;  $\gamma$  absorption method; baseline elimination

$\gamma$  射线测厚法采用  $\gamma$  放射性同位素, 通过测量透过样品的射线强度得到样品的厚度信息, 具有无损测量、测量精度高、经济效益好和使用寿命长等优点, 在工业领域已得到广泛应用, Bessinger 等<sup>[1]</sup> 利用煤炭附近的页岩层中存在的天然  $\gamma$  辐射, 实现预留煤层厚度测量; 韩揽月等<sup>[2]</sup> 利用 <sup>241</sup>Am 放射源和 NaI(Tl) 闪烁体探测器, 通过测量反散射  $\gamma$  射线强度, 实现坩埚厚度测量; 王飞等<sup>[3]</sup> 研究了三点式  $\gamma$  射线测厚仪在钢板厚度测量的应用及测量精度影响因素; Weng 等<sup>[4]</sup> 利用<sup>137</sup>Cs 和 NaI(Tl) 闪烁体探测器研究  $\gamma$  射线厚度测量的检测方法和最佳的测量状态, Chuong 等<sup>[5]</sup> 利用蒙特卡罗方法拟合校准曲线和伽马射线背散射法实现铝板的厚度测量, 同时该课题组又利用蒙特卡罗方法模拟<sup>137</sup>Cs 放射源释放的  $\gamma$  射线穿透不同材料板的能谱, 获取校准曲线, 实现厚度测量<sup>[6]</sup>。

目前, 对于  $\gamma$  射线测厚的研究主要集中在方法设计和测量装置结构优化等方面, 而对于  $\gamma$  能谱数据后处理的相关研究则较为匮乏。 $\gamma$  能谱数据后处理包括能谱基线扣除和峰面积计算等, 能谱中基线的存在影响测量系统的能量分辨率和稳

定性<sup>[7]</sup>, 进而影响全能峰峰位的确立, 而峰面积计算方法的选取则直接影响峰面积的计算精度和厚度分辨率。因此, 精准的能谱基线扣除和峰面积计算是实现厚度精准测量的必要条件。传统基线扣除方法包括傅里叶变换、数字滤波法、迭代谱线剥离和统计敏感的非线性迭代剥峰算法<sup>[8]</sup>(statistics-sensitive nonlinear iterative peak-clipping algorithm, SNIP) 等, 其中, SNIP 方法是一种有效的能谱背景评估方法, 在能谱基线扣除中有广泛应用<sup>[9-11]</sup>。但 SNIP 方法的滤波窗宽度需通过实验测试和人工选择, 缺乏自适应性。神经网络和深度学习具有自主学习数据内在特征的能力, 已在语音识别、图像处理、目标识别和分割等领域得到广泛应用<sup>[12-13]</sup>。近年, 利用神经网络或深度学习方法开展  $\gamma$  能谱分析的研究逐渐增多。杜晓闯等<sup>[14]</sup> 利用 RBF 神经网络对不同核素的  $\gamma$  能谱进行模拟, 表明神经网络在建立核素库实现核素识别等方面有良好的应用前景; 申慧等<sup>[15]</sup> 利用 BP 神经网络算法对  $\gamma$  射线能谱进行分析, 实现了对核素的分类; 胡浩行等<sup>[16]</sup> 将  $\gamma$  能谱转为灰度图, 利用卷积神经网络实现了多核素分类。这些研究主要集

中于 $\gamma$ 能谱在核素分类方面的应用,而将神经网络及深度学习方法用于 $\gamma$ 能谱的基线扣除和 $\gamma$ 测厚方面的研究则较少。

传统的能谱基线扣除方法需人工选择参数,无法实现自适应调整,且对噪声较敏感,在能谱中存在弱峰、重峰和高本底等情况时,误差较大<sup>[17]</sup>,从而导致全能峰测量有误,无法进行有效刻度,实现精确厚度测量。而深度学习方法可自主学习到数据更高级的特征,有助于提高 $\gamma$ 测厚方法的稳定性和抗干扰能力。本研究基于深度学习方法开展 $\gamma$ 能谱测厚方法研究,优化能谱基线扣除方法,利用<sup>241</sup>Am 和碲锌镉(CZT)探测器搭建一套 $\gamma$ 测厚装置,对测厚方法进行训练和验证,实现厚度测量,提高 $\gamma$ 测厚方法的稳定性和抗干扰能力。此外,由于 Ronneberger 等<sup>[18-20]</sup>提出的 U-Net 网络采用 Concatenate 结构将编码网络(encoder network, EN)每层特征信息传递给解码网络(decoder network, DN)对应输出层,保留图像中更多细节信息,有助于实现精确预测,本文基于 U-Net 搭建能谱分析网络(spectrum analysis network, SpeNet)实现 $\gamma$ 能谱分析和厚度测量。区别于一般能谱分析网络的输入和输出数据类型,首先将一维的能谱数据转化为二维灰度图,作为 SpeNet 网络的输入和输出,SpeNet 网络通过 EN 和 DN 之间的信息传递,学习每个地址的特征信息的同时,也将有助于提取相邻地址间的关联信息,提高网络的学习能力和准确性。

## 1 测量原理与方法

### 1.1 $\gamma$ 厚度测量原理

本研究所搭建的系统厚度测量采用 $\gamma$ 吸收

法,放射源释放一定能量和强度的 $\gamma$ 射线,探测器测量透过度测物体的射线强度,反推出物体厚度,如式(1)所示,一定强度的 $\gamma$ 射线与待测物体发生相互作用(主要是光电效应和康普顿散射)使得 $\gamma$ 射线的强度衰减,通过探测透射射线的强度可得到样品的厚度等信息。

$$I = I_0 e^{-\mu_m \rho d} \quad (1)$$

其中: $I$ 为射线通过待测物体后的强度,即射线透射强度, $\text{cm}^{-2} \cdot \text{s}^{-1}$ ;  $I_0$ 为入射射线强度, $\text{cm}^{-2} \cdot \text{s}^{-1}$ ;  $\mu_m$ 、 $\rho$ 和 $d$ 分别为待测样品的质量衰减系数、密度和厚度,单位分别为 $\text{cm}^2/\text{g}$ 、 $\text{g}/\text{cm}^3$ 和 $\text{mm}$ 。当样品 $\rho$ 保持不变,样品 $d$ 与 $I$ 呈指数关系,当厚度变化范围较小时,可使用多项式代替指数关系拟合,得到合适的刻度曲线,实现厚度测量,实际测量中通过计算能谱中全能峰面积作为不同厚度的 $I$ ,与对应的 $d$ 建立刻度曲线,从而通过透射能谱全能峰面积预测样品厚度。

### 1.2 基于 U-Net 的 $\gamma$ 测厚方法

传统的 $\gamma$ 厚度测量方法一般可分为能谱测量、能谱分析和曲线标定等3个过程,曲线标定完成后就可用于样品厚度测量。本文建立的 $\gamma$ 测厚方法创新能谱分析过程,采用深度学习方法替代传统的基线扣除方法,得到基线扣除能谱后进行峰面积计算,得到的峰面积用于曲线标定和厚度测量,本文建立的 $\gamma$ 测厚方法流程如图1所示。首先利用搭建的 $\gamma$ 测厚装置得到不同厚度样品的能谱数据 $X$ ,通过传统方法和人工方法对能谱数据进行基线扣除,得到扣除本底的能谱数据 $Y$ , $X$ 和 $Y$ 一一对应,并将其转化为二维灰度图,建立数据集。而后基于 U-Net 网络建立适用于 $\gamma$ 能谱分析的 SpeNet 网络,利用已建立的数据集对

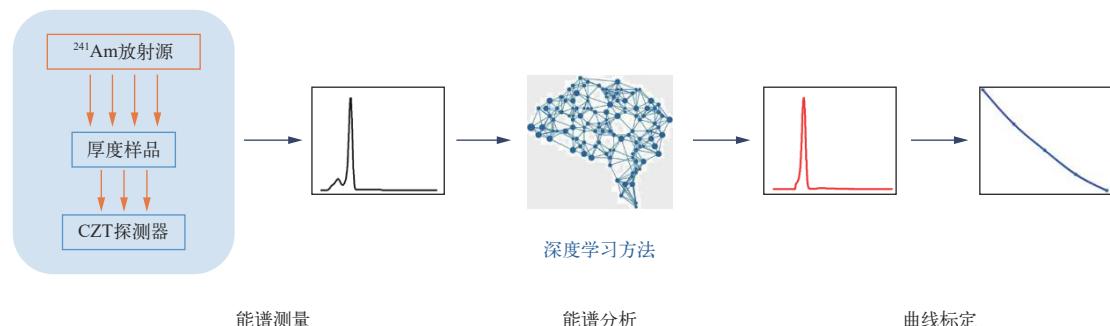


图1 基于深度学习的 $\gamma$ 测厚方法流程

Fig. 1 Flow chart of gamma thickness measurement method based on deep learning

SpeNet 网络进行训练和验证。网络训练完成后, 替代传统的能谱分析方法, 对 $\gamma$ 测厚装置得到的能谱数据进行基线扣除和峰面积计算, 得到峰面积与样品厚度的关系式, 重新完成装置测厚曲线的标定, 实现对未知样品的厚度测量。

### 1.3 能谱数据转化

本研究将一维的能谱数据转化为二维灰度图, 转化结果如图 2 所示, 转化过程中一方面要适应 SpeNet 网络的输入和输出数据格式, 另一方面使得网络实现对每个道址的特征信息提取的同时, 又提取附近道址的关联特征, 充分利用 $\gamma$ 能谱的信息, 提升网络的预测性能。深度学习网络的输入和输出普遍采用归一化的数据, 从而方便网络的训练和防止梯度扩散或消失。因此, 首先根据式(2)将每一道址的计数归一化。

$$N_{\text{norm}} = \frac{N - N_{\min}}{N_{\max} - N_{\min}} \quad (2)$$

其中:  $N$  为每道址的计数;  $N_{\min}$  为能谱中道址的最小计数;  $N_{\max}$  则为道址的最大计数;  $N_{\text{norm}}$  为归一化后的每道址的计数。根据能谱数据中的道数  $n^2$  将一维数据转化为  $n \times n$  的二维矩阵, 即二维的灰度图, 如图 2 所示, 将 144 道的能谱数据转化为  $12 \times 12$  的灰度图, 作为网络的输入和输出。灰度图的长和宽一致, 防止 SpeNet 网络在 EN 下采样和 DN 上采样过程中由于特征图不一致导致模型无法训练。

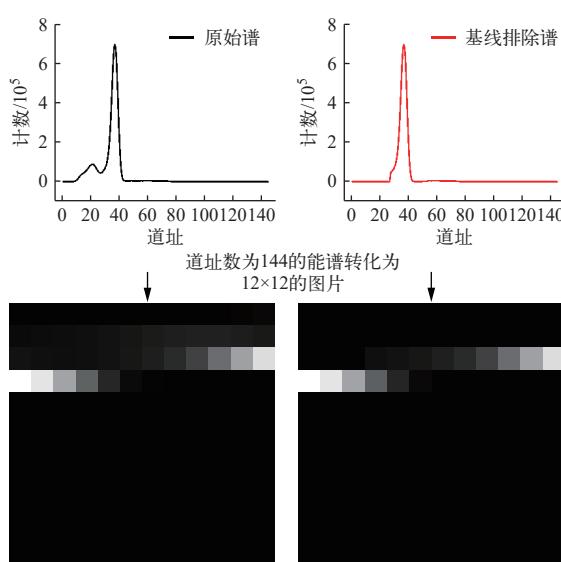


图 2 能谱数据转化示意图

Fig. 2 Schematic diagram of energy spectrum data transformation

### 1.4 SpeNet 网络

本文建立的 SpeNet 网络如图 3 所示, 网络的通道数  $n$  为 64, 网络深度为 2, 网络的输入和输出为能谱数据转化的二维灰度图, 本文搭建的厚度测量装置测得的能谱数据主要集中在 1~150 道范围内, 为保证能谱转化成的灰度图长和宽一致, 因此选取了 1~144 道的能谱数据, 即将能谱转化为  $12 \times 12 \times 1$ (1 为输入通道数)的灰度图。因为输入为原始能谱转化的灰度图, 输出为基线扣除能谱转化的灰度图, 因此两者的尺寸和通道数保持一致, 均为  $12 \times 12 \times 1$ 。SpeNet 网络可分为 EN 和 DN 结构。其中, EN 包括卷积(Conv)、批量归一化(batch normalization)、激活函数(activation)和池化(pooling)等操作, 通过卷积操作获取图像特征信息, 不同的通道获取不同的特征信息。批量归一化使得特征值保持在 0~1 的范围, 防止梯度扩散而无法进行权值更新, 保证网络正常学习。激活函数实现不同的非线性操作, 使得整个深度学习网络近似为一个非线性的通用函数逼近器<sup>[21]</sup>, 有助于解决复杂问题。池化操作保留关键信息的同时减小中间数据空间大小, 提高运算速度, 为继续增加网络深度提供便利, 一般采用最大池化(max pooling)。DN 中通过卷积转置(Conv2d transpose)操作将特征信息进行整合并增加图像尺寸, 最终使得输入与输出图像尺寸一致。不同层级提取不同特征信息, 层级越深, 提取的信息越高阶。相对应的每一层之间通过 Concatenate 连接实现特征信息传递, 保留图像的更多细节信息, 该连接方式有利于提高预测图的准确度, 因此本文也采用此种连接方式, 有利于网络预测出更加精准的基线扣除谱。

### 1.5 $\gamma$ 测厚装置

CZT 探测器具有可在室温条件下工作、能量分辨率高、快速响应、工作稳定等优点, CZT 晶体对 $\gamma$ 射线有很强的吸收本领, 但由于其厚度有限, 对于中高能 X 射线或 $\gamma$ 射线探测效率较低, 因此 CZT 探测器被广泛用于低能 X 射线和 $\gamma$ 射线的测量<sup>[22]</sup>。本文选取的<sup>241</sup>Am 放射源强度为  $1.39 \times 10^9$  Bq, 特征射线能量为 59.6 keV, 能量较低, 因此选取 CZT 探测器搭配<sup>241</sup>Am 放射源建立一套 $\gamma$ 测厚装置, 如图 4 所示, 测厚装置主要包括: 放射源及放置架、样品架、CZT 探测器、三轴位移台、能谱软

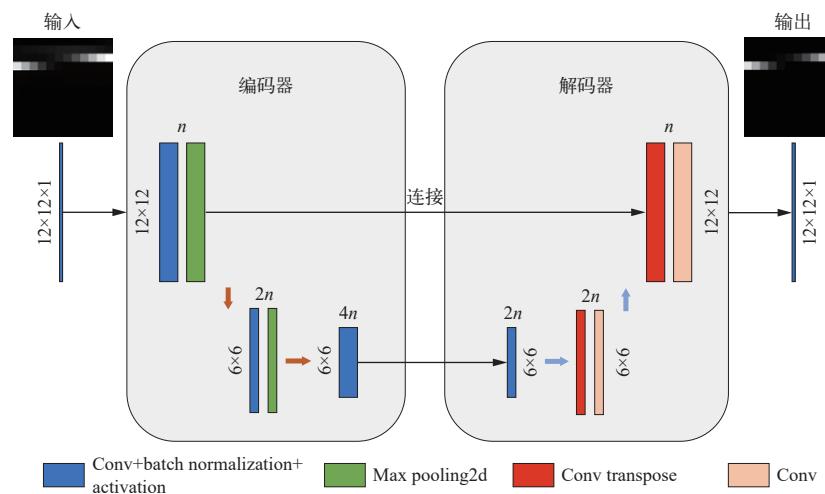


图3 SpeNet 网络结构

Fig. 3 Network structure of SpeNet

图4  $\gamma$  测厚装置图

Fig. 4 Gamma thickness measurement device

件和直流电源等。CZT 探测器将准直器、探测晶体、电荷灵敏前置放大器和高压模块集成化, 对<sup>241</sup>Am 的 59.6 keV 特征峰的能量分辨率优于 10%, 本征探测效率优于 99%。采用费思(Faith)直流电源 FTL8020P 为探测器提供 5 V 的稳压电源, 电压噪声小于 50 mV。利用此装置进行厚度测量, 为 SpeNet 的网络训练和测厚方法验证提供能谱数据集。

## 2 网络训练与方法验证

### 2.1 $\gamma$ 装置测厚

利用建立的 $\gamma$ 测厚装置分别对A4纸、锡纸、

不锈钢标准厚度块、陶瓷标准厚度块和塑料样品等进行测量, 部分样品如图5所示。根据样品种类、样品与源和探测器的位置、单次测量时间等实验条件设置多组测量状态, 每种测量状态下进行多次测量, 得到不同样品和相同样品不同强度的多种 $\gamma$ 能谱数据, 保证 $\gamma$ 能谱数据量的同时增加数据集的多样性, 从而提升 SpeNet 网络的泛化能力。

### 2.2 数据集及网络训练

对 $\gamma$ 测厚装置测得的能谱进行分析, 采用传统的 SNIP 方法, 通过调试选取合适的滤波窗宽度, 对能谱数据进行基线扣除, 得到与原始能谱  $X$  相对应的基线扣除能谱  $Y$ 。将  $X$  和  $Y$  转化为灰度图, 建立用于 SpeNet 网络训练的数据集, 数据集可分为训练集和验证集, 其中训练集有 1440 组, 验证集有 360 组, 共 1800 组, 部分训练集如图 6 所示。

SpeNet 网络搭建和训练采用 Tensorflow2.0 深度学习模型框架, 相应的数据分析程序基于 Python 语言编写。训练过程中, 卷积部分的激活函数使用 Relu 激活函数<sup>[23]</sup>, 权值初始化采用与 Relu 相匹配的 He 初始值<sup>[24]</sup>, 梯度优化算法采用 Adam 函数<sup>[25]</sup>, 网络训练次数取为 100 次。SpeNet 网络需对每道址的计数实现精准预测, 属于回归问题。因此, SpeNet 网络输出层采用 sigmoid 函数, 损失函数采用均方误差(mean squared error, MSE), 不再采用用于分类的交叉熵损失函数。网络训练完成后, 应用于本文建立的 $\gamma$ 测厚方法。

### 2.3 测厚方法验证

以实验中测量的 PPS40 样品为例, 对本文建立的测厚方法进行验证。PPS40 样品的厚度为 13、14、15、16、17 mm, 除厚度不同外, 其他条件保持一致, 如图 5c 所示。采用本文搭建的  $\gamma$  测厚装置进行厚度测量, 每种厚度样品单次测量时间为 300 s, 测量 5 次。分别采用 SNIP 方法和 SpeNet 方法对测得的能谱数据进行基线扣除和峰面积计算并对比分析, 用于验证 SpeNet 网络基线扣除效果和本文建立的测厚方法的可行性。对不同厚度 PPS40 样品测得的能谱添加强度为 100、300 和 500 等不同程度的高斯噪声, 并利用 SNIP 方法和 SpeNet 方法进行对比, 验证不同高斯噪声环境下的测厚性能。进一步对不同厚度 PPS40 样品测得的能谱随机添加高斯峰, 模拟放射性环境下其他核素特征峰的干扰, 验证 SpeNet 方法的抗干扰能力。

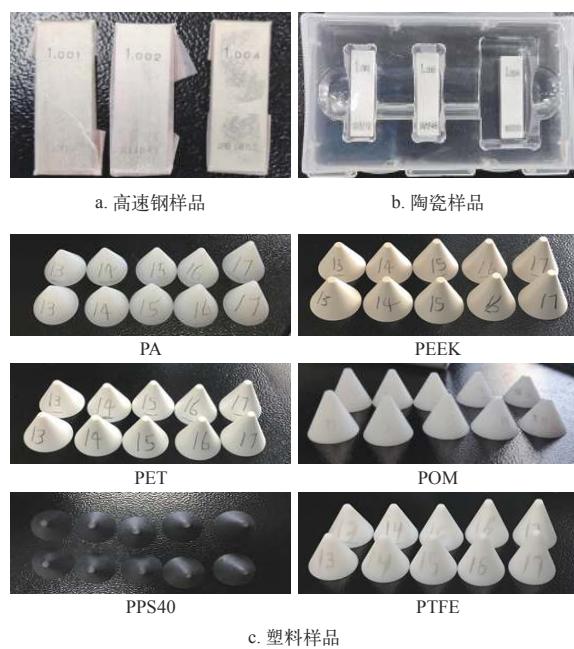


图 5 厚度样品

Fig. 5 Some thickness samples

## 3 结果与讨论

### 3.1 能谱拟合性能与测厚性能

对完成训练的 SpeNet 网络进行测试, 部分预测结果如图 7 所示, 图 7a 中将能谱灰度图转化为彩色图, 方便对比不同能谱图间的差异, 图 7b、c、d 分别表示原始能谱图、真值图和 SpeNet 预测的基线扣除能谱图。图 7b 展示的能谱图中第 2~4 行可被明显识别出, 与转化前的原始能谱对比可知, 第 2 行主要展示的是 $^{241}\text{Am}$  全能峰前的散射峰, 第 3~4 行展示的是 $^{241}\text{Am}$  的全能峰, 其中峰位计数最多, 则以红色显示。图 7c 则可看出, 经传统方法得到的标准基线扣除的能谱转化为的彩色图中第 2 行变为背景色, 说明 $^{241}\text{Am}$  的  $\gamma$  能谱中散射峰已被有效扣除; 图 7d 为 SpeNet 预测的基线扣除能谱, 可看到, 与图 7c 差别不大, 说明通过该网络可实现能谱基线扣除。

以 PPS40 样品测量结果为例, SNIP 和 SpeNet 方法的对比结果如图 8 所示, 图 8 展示两种方法基线扣除能谱对比和两种方法得到的归一化峰面积对比。图 8a 以 PPS40 厚度 13 mm 样品的  $\gamma$  能谱为例, 展示两种方法的基线扣除能力, 可看到 SpeNet 得到的基线扣除能谱与传统 SNIP 方法得到的基线扣除能谱几乎重合, 散射峰和本底基本被扣除, 与图 7c 展示的结果一致。图 8b 展示两种方法得到的基线扣除能谱进行峰面积计算后归一化, 得到的相对峰面积与厚度关系图, 可看到两种方法计算得到的峰面积与样品厚度均呈现出指数衰减关系, 且不同厚度对应的峰面积几乎一致, 证明了本文基于 SpeNet 建立的厚度测量方法可行, 可替代传统方法用于  $\gamma$  厚度测量。

### 3.2 噪声环境下的测厚性能

本文建立的  $\gamma$  测厚装置采用的放射源特征峰单一且射线源强度较强, 得到的能谱的噪声较低, 为研究本文建立的测厚方法抗噪能力, 给能谱添

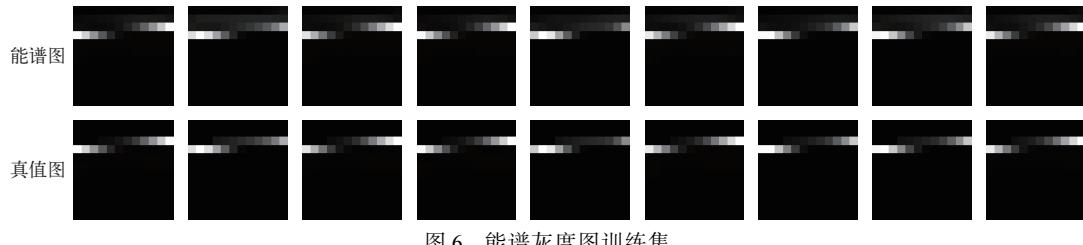


图 6 能谱灰度图训练集

Fig. 6 Some training datasets composed of energy spectrum gray-scale images

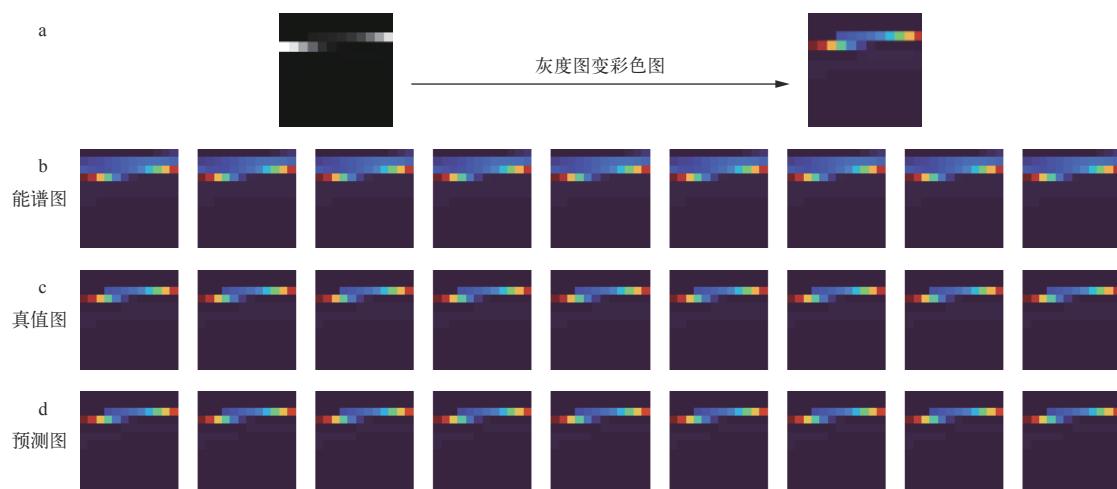


图 7 SpeNet 网络预测结果图  
Fig. 7 Prediction results of SpeNet network

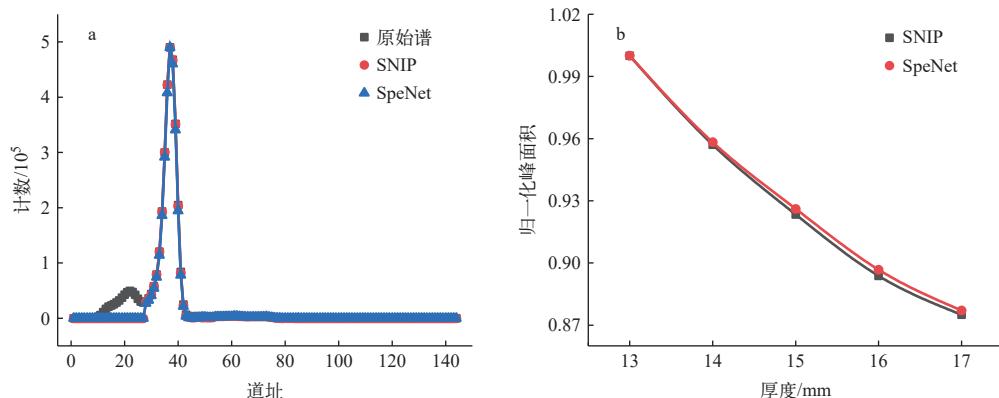


图 8 SNIP 和 SpeNet 方法厚度测量结果对比  
Fig. 8 Comparison of thickness measurement results by SNIP and SpeNet method

加不同程度的高斯噪声, 模拟不同噪声条件, 对比 SpeNet 和 SNIP 两种方法的厚度测量结果, 如图 9 所示。图 9 表示不同噪声条件下 SNIP 和 SpeNet 方法扣除基线后计算峰面积得到的相对峰面积与

样品厚度的关系。从图 9a 可看出, 随着噪声强度的增加, PPS40 每种厚度对应的峰面积逐渐减小且变化明显。这是因为 SNIP 方法在迭代过程中通过对比某道的计数值与附近道址的计数值更新

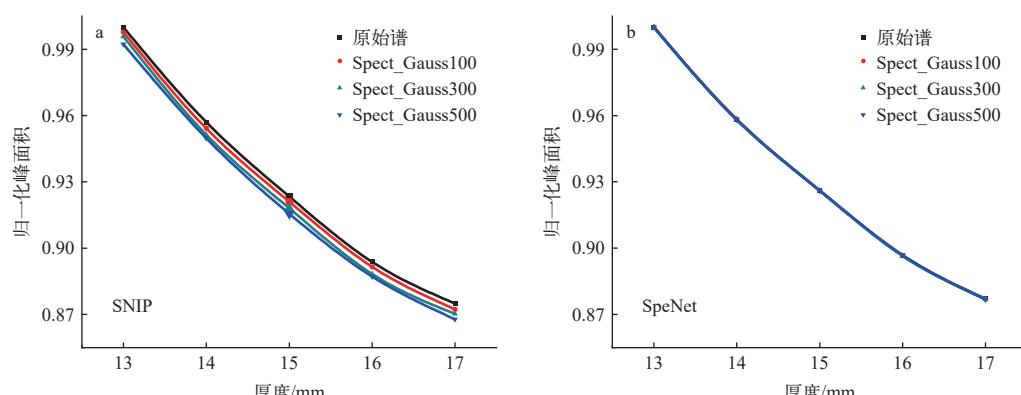


图 9 噪声条件下不同方法厚度测量结果对比  
Fig. 9 Comparison of thickness measurement results using different methods under noise conditions

该道址的计数值,不可避免地会受到噪声影响,噪声强度增加,使得SNIP计算得到的本底基线增加,从而使得扣除基线后全能峰内道址的计数变小,峰面积逐渐减小。图9b为SpeNet方法在不同噪声背景下得到的相对峰面积与样品厚度关系,可看到不同噪声强度下的曲线几乎重合,噪声的增加对于峰面积的影响较小,体现出以SpeNet网络建立的 $\gamma$ 测厚方法有着良好的抗噪性能。

在不同噪声强度下,根据SNIP得到的基线扣除能谱,计算PPS40不同厚度样品的峰面积,并与未添加噪声的峰面积进行对比,计算峰面积变化率,结果列于表1,负值表示相比于未添加噪声的

峰面积,添加噪声后所得峰面积减小,因此引起的变化率为负值,可看到噪声强度越强,引起的峰面面积变化率越大,最大达0.85%。同理,计算不同噪声强度下SpeNet方法得到的峰面积变化率,结果列于表2,可看到,相同噪声强度下每种厚度的峰面积变化率有正有负,且不同噪声强度下相同厚度的峰面积变化率也存在有正有负的情况,即峰面积增加或减小,说明峰面积的变化与噪声强度几乎无关,并且不同噪声强度下,引起的噪声变化率相比于SNIP来说明显减弱,最大仅0.049%,体现出基于深度学习建立的 $\gamma$ 测厚方法有着优异的抗噪能力,明显优于传统测厚方法。

表1 相比于原始谱的峰面积变化率(SNIP方法)

Table 1 Rate of change of peak area compared to original spectrum (SNIP method)

厚度/mm	峰面积变化率/%		
	Spect_Gauss100	Spect_Gauss300	Spect_Gauss500
13	-0.231	-0.422	-0.765
14	-0.295	-0.605	-0.767
15	-0.251	-0.575	-0.851
16	-0.239	-0.606	-0.739
17	-0.298	-0.530	-0.825

表2 相比于原始谱的峰面积变化率(SpeNet方法)

Table 2 Rate of change of peak area compared to original spectrum (SpeNet method)

厚度/mm	峰面积变化率/%		
	Spect_Gauss100	Spect_Gauss300	Spect_Gauss500
13	0.006	-0.016	0.010
14	0.010	-0.010	-0.028
15	-0.016	-0.012	-0.010
16	0.002	-0.043	0.007
17	-0.009	-0.005	-0.049

### 3.3 复杂环境下的测厚性能

同样以PPS40不同厚度的样品为例,通过给 $\gamma$ 测厚装置得到的能谱全能峰附近添加新的高斯峰,模拟其他放射性核素特征峰对厚度测量的影响,验证本文 $\gamma$ 测厚方法的复杂核素抗干扰能力,并与传统方法对比。本研究随机设置3个不同高度、不同位置的高斯峰模拟放射性复杂环境中多种核素的特征峰,这些核素的特征峰强度不变,表示这些特征峰强度与样品厚度无关,作为放射性环境中固有的放射性存在,对测厚产生干扰,能谱中具体分布如图10a所示,峰①为原 $\gamma$ 能谱中的

散射峰,峰②为原 $\gamma$ 能谱中 $^{241}\text{Am}$ 特征峰,峰强度与样品厚度相关,峰③~⑤为增加的模拟放射性核素特征峰,对测厚形成干扰。图10b展示SpeNet和SNIP方法对能谱的基线扣除结果,可看到两种方法均可实现对散射峰①的扣除,但SNIP方法无法扣除峰③~⑤,SpeNet方法则可将这些与测厚无关的干扰峰有效扣除,有效降低干扰峰的影响,体现出基于SpeNet网络的 $\gamma$ 测厚方法应用于复杂放射性环境的优势。

图10a中随机添加的峰③~⑤与用于测厚的 $^{241}\text{Am}$ 全能峰无重叠,因此这些峰对于 $^{241}\text{Am}$ 的全

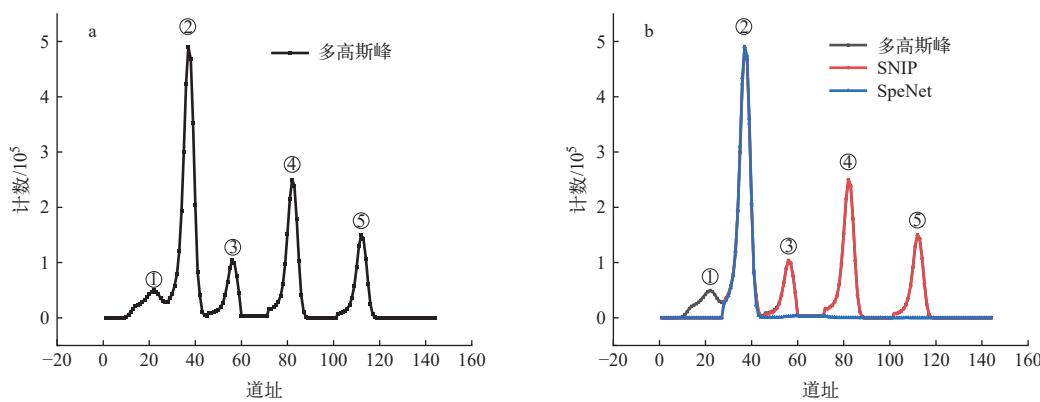


图 10 不同方法能谱基线扣除结果对比

Fig. 10 Comparison of spectral baseline elimination results by different methods

能峰面积计算影响较小, 可通过道址(阈值)选择过滤掉与厚度测量无关的高斯峰, 无法充分体现 SpeNet 扣除干扰峰的优势。因此, 进一步设计一与<sup>241</sup>Am 全能峰有重叠的高斯峰, 添加的高斯峰如图 11a 中的峰⑥, 该峰位于 40~45 道, 处于<sup>241</sup>Am 特征峰的区间内, 且峰强度为定值, 不随 PPS40 样品厚度而变化, 因此不可避免地对<sup>241</sup>Am 全能峰内的计数产生影响, 且难以通过阈值选择去除该峰的影响。SNIP 和 SpeNet 方法的对比结果如图 11 所示, 图 11a 所示为 SNIP 选择不同滤波窗大小的基线扣除结果, 图 11b 对比 SpeNet 与 SNIP 的基线扣除结果。图 11a 可看到, 改变 SNIP 方法中滤波窗的大小, 对<sup>241</sup>Am 全能峰之前的散射峰扣除影响明显, 当  $w=53$  时可有效去除散射峰①, 但对于添

加的高斯峰⑥却无法扣除, 表明传统方法对于其他核素特征峰的抗干扰能力较弱, 与此同时, 传统方法需进行人工试验才能确定合适的滤波窗用于基线扣除, 体现了传统方法的不足之处。图 11b 通过 SpeNet 与 SNIP 的对比, 可看到 SpeNet 除可扣除掉散射峰①外, 还可有效扣除在 40~45 道添加的高斯峰⑥, 体现出该方法对其他核素的抗干扰能力。从 SpeNet 的网络结构来看, 通过不同网络层级提取输入信息不同级别的特征信息, 网络层数越深, 提取信息越高级<sup>[26-27]</sup>, 从而在有噪声或有其他核素干扰的情况下, 仍能得到较好的基线扣除能谱, 突出深度学习方法在放射性环境下优异的抗干扰能力, 有利于复杂放射性环境下的 $\gamma$ 厚度测量。

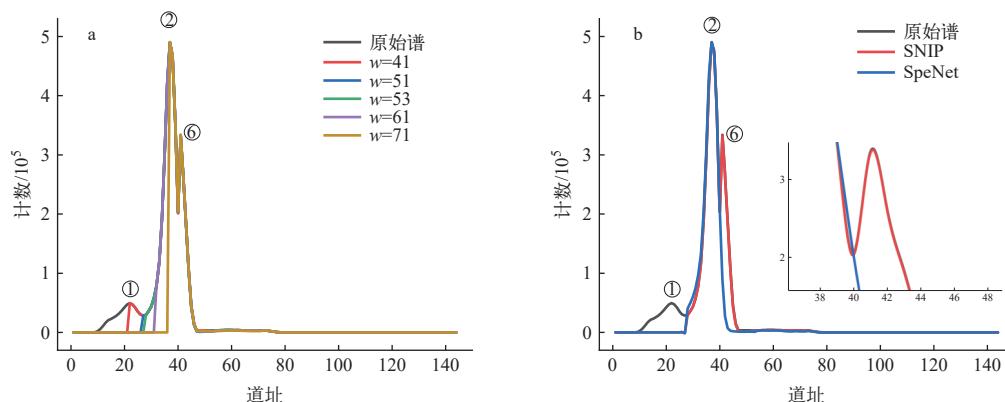


图 11 不同方法能谱基线扣除结果对比

Fig. 11 Comparison of spectral baseline elimination results by different methods

测量 PPS40 不同厚度的样品, 得到不同厚度样品对应的 $\gamma$ 能谱, 在能谱中添加干扰峰⑥, 采用 SNIP 和 SpeNet 两种方法进行基线扣除, 计算峰面积, 得到峰面积与样品厚度的关系如图 12 所示,

原始谱表示未添加干扰峰得到的峰面积与厚度关系曲线, SNIP 和 SpeNet 则分别表示两种方法得到的峰面积与厚度关系曲线。可直观看出, 相比于原始谱, 对于相同厚度的样品, 基于 SpeNet 的 $\gamma$ 测

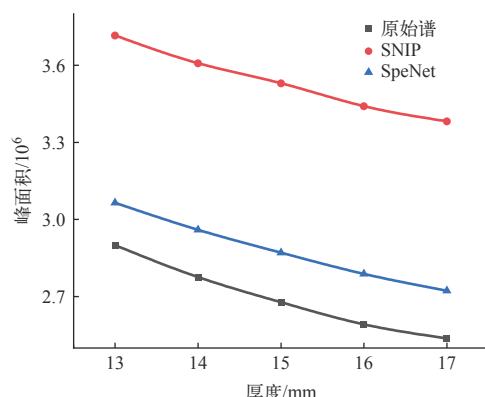


图 12 不同方法的峰面积与样品厚度关系图

Fig. 12 Relationship between peak area and sample thickness using different methods

厚方法和基于 SNIP 的  $\gamma$  测厚方法得到的峰面积均增加, SpeNet 的峰面积增加小于 SNIP 的结果, 是因为 SpeNet 有效扣除了新增的高斯峰。而由于高斯峰的存在导致  $^{241}\text{Am}$  的全能峰范围内每个

道址计数均相应增加, 因此, 即使有效扣除高斯峰, 仍会导致全能峰的面积增加, 从而高于原始的全能峰面积。两种方法得到的峰面积及峰面积变化率结果列于表 3, 可看到 SpeNet 方法计算得到的峰面积最大变化率为 7.58%, 优于 SNIP 的结果 33.29%。通过对同种方法不同厚度的峰面积变化率可知, SNIP 得到的峰面积变化率随着厚度增加逐渐增加且造成的峰面积变化明显, 峰面积变化率随着厚度逐渐增加, 会逐渐破坏峰面积与样品厚度的指数关系而无法用于厚度测量, 进一步会导致  $\gamma$  测厚方法失效。而 SpeNet 方法的不同厚度对应的峰面积变化率则变化较小, 峰面积变化率与厚度变化并未呈现正相关, 对峰面积与样品厚度的指数关系影响较小, 继续改进 SpeNet 网络, 有望进一步改善峰面积计算结果和提高测厚方法的稳定性。

表 3 不同方法峰面积计算结果对比

Table 3 Comparison of peak area results using different methods

厚度/mm	原始峰面积	峰面积		峰面积变化率/%	
		SNIP	SpeNet	SNIP	SpeNet
13	2900060	3716428	3065312	28.150	5.698
14	2775551	3608216	2959859	30.000	6.640
15	2677755	3530294	2870942	31.838	7.215
16	2591899	3441025	2788397	32.761	7.581
17	2537541	3382344	2723219	33.292	7.317

### 3.4 讨论

通过在原始能谱上添加不同程度的高斯噪声和高斯峰, 模拟不同的噪声环境和复杂放射环境下测得的能谱, 利用 SpeNet 和 SNIP 方法进行能谱基线扣除并计算峰面积, 结果均表明 SpeNet 方法表现出较好的抗噪能力和抗干扰能力, 不仅可将能谱本底去除, 还可将与测厚无关的高斯峰有效扣除, 这是传统方法无法做到的。原因在于深度学习方法在图像分割和图像降噪等领域表现突出, 通过不同深度的层级提取不同层次的特征, 实现较好的目标分割和图像降噪, 得到广泛应用<sup>[12,18-19,28-29]</sup>。本文将  $\gamma$  能谱转化为灰度图, 作为 SpeNet 网络的输入, 输出为基线扣除后的能谱灰度图。网络通过不断训练, 不断学习图片中存在的特征信息, 将能谱中的高斯噪声和其他与测厚

无关的高斯峰逐渐识别为图像中存在的噪声, 不断减弱这些噪声在输出灰度图中的灰度值, 而将与  $\gamma$  测厚相关的  $^{241}\text{Am}$  的全能峰识别为分割目标, 将其保存在输出的灰度图中, 实现较为精确地输出灰度图。随后将输出灰度图转化为  $\gamma$  能谱图, 从而得到精确的基线扣除谱。通过将能谱转化为灰度图, 可充分发挥深度学习在目标分割和图像降噪方面的优势, 实现了能谱基线和无关高斯峰的有效扣除, 进而增强了  $\gamma$  测厚方法在噪声环境和复杂放射性环境下的抗噪能力和抗干扰能力, 拓宽了  $\gamma$  测厚方法的应用领域。

### 4 结论

本文基于深度学习网络建立一种新颖的  $\gamma$  测厚方法, 利用搭建的伽马测厚装置进行训练和验

证,并与传统方法进行了对比分析。具体而言,通过搭建的 $\gamma$ 测厚装置对多种厚度样品进行测量,产生足够的能谱数据用于SpeNet网络的训练。以13~17 mm厚度的PPS40样品为例,测试基于SpeNet网络建立的 $\gamma$ 测厚方法。结果表明,该方法得到的峰面积与样品厚度关系与传统方法基本一致,证明了该方法的可行性。在不同厚度PPS40样品对应的 $\gamma$ 能谱上添加不同程度的高斯噪声,模拟噪声环境下的测量,发现本文建立的 $\gamma$ 测厚方法抗噪能力强,最大峰面积变化率仅为0.049%,优于传统SNIP方法得到的结果0.85%。在能谱上添加高斯峰模拟其他核素特征峰干扰的研究,证明了本文建立的 $\gamma$ 测厚方法可有效扣除添加的高斯峰,最大峰面积变化率仅7.58%,优于传统方法的33.29%,具有较强的抗干扰能力,体现出该方法应用于复杂放射环境下的潜力。综上所述,基于深度学习方法的基线扣除,避免了人工多次调参,直接得到基线扣除后的 $\gamma$ 能谱,提高了工作效率。同时对传统的测厚方法进行了优化,提高了 $\gamma$ 测厚方法的抗噪能力和抗干扰能力,为 $\gamma$ 测厚数据分析提供了新思路。

本研究工作得到了兰州大学超算平台的支持,在此致以感谢。

## 参考文献:

- [1] BESSINGER S L, NELSON M G. Remnant roof coal thickness measurement with passive gamma ray instruments in coal mines[J]. *IEEE Transactions on Industry Applications*, 1993, 29(3): 562-565.
- [2] 韩揽月,袁平. $\gamma$ 射线反散射石英坩埚厚度仪样机的研制[J].*核电子学与探测技术*,2013,33(6): 705-707.  
HAN Lanyue, YUAN Ping. Prototype development of quartz crucible thickness meter with gamma backscatter[J]. *Nuclear Electronics & Detection Technology*, 2013, 33(6): 705-707(in Chinese).
- [3] 王飞,段方民.三点式 $\gamma$ 射线测厚仪的研究与应用[J].冶金自动化,2018,42(3): 63-67.  
WANG Fei, DUAN Fangmin. Research and application of a 3-head  $\gamma$ -ray thickness gauge[J]. Metallurgical Industry Automation, 2018, 42(3): 63-67(in Chinese).
- [4] WENG Q, MA Y. Gamma ray thickness measurement[J]. *IOP Conference Series: Earth and Environmental Science*, 2019, 237: 032072.
- [5] CHUONG H D, NGOC TRANG L T, TAM H D, et al. A new approach for determining the thickness of material plate using gamma backscattering method[J]. *NDT & E International*, 2020, 113: 102281.
- [6] CHUONG H D, NGOC TRANG L T, MINH L H, et al. Thickness determination of material plates by gamma-ray transmission technique using calibration curves constructed from Monte Carlo simulation[J]. *Radiation Physics and Chemistry*, 2022, 190: 109821.
- [7] 王海涛,汤彬,王仁波,等.数字化 $\gamma$ 能谱测量系统中的脉冲基线估计与扣除方法[J].*核技术*,2018,41(5): 45-50.  
WANG Haitao, TANG Bin, WANG Renbo, et al. Method of pulse baseline estimate and deduction for digital gamma energy spectrometer[J]. *Nuclear Techniques*, 2018, 41(5): 45-50(in Chinese).
- [8] RYAN C G, CLAYTON E, GRIFFIN W L, et al. SNIP: A statistics-sensitive background treatment for the quantitative analysis of PIXE spectra in geoscience applications[J]. *Nuclear Instruments and Methods in Physics Research B*, 1988, 34(3): 396-402.
- [9] MORHÁČ M. An algorithm for determination of peak regions and baseline elimination in spectroscopic data[J]. *Nuclear Instruments and Methods in Physics Research A*, 2009, 600(2): 478-487.
- [10] 王一鸣,魏义祥.用于 $\gamma$ 全谱基线扣除的改进SNIP算法研究[J].*核电子学与探测技术*,2012,32(12): 1356-1359, 1393.  
WANG Yiming, WEI Yixiang. Baseline elimination method for  $\gamma$ -ray spectra based on improved SNIP algorithm[J]. *Nuclear Electronics & Detection Technology*, 2012, 32(12): 1356-1359, 1393(in Chinese).
- [11] 任俊松.伽马能谱分析与核素识别方法研究[D].绵阳:西南科技大学,2017.
- [12] LE CUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [13] 张瑤,张云波,陈立.基于深度学习的光学表面杂质检测[J].*物理学报*,2021,70(16): 353-361.  
ZHANG Yao, ZHANG Yunbo, CHEN Li. Deep-learning-assisted micro impurity detection on an optical surface[J]. *Acta Physica Sinica*, 2021, 70(16): 353-361(in Chinese).
- [14] 杜晓闯,涂红兵,黎肯,等.基于径向基神经网络仿真 $\gamma$ 能谱模板库的核素识别方法[J].清华大学学报(自然科学版),2021,61(11): 1308-1315.  
DU Xiaochuang, TU Hongbing, LI Ke, et al. Radionuclide identification method based on a gamma-spectra template library simulated by radial basis function neural

- networks[J]. Journal of Tsinghua University (Science and Technology), 2021, 61(11): 1308-1315(in Chinese).
- [15] 申慧, 刘知贵, 刘素萍. 基于神经网络算法的 $\gamma$ 射线能谱分析[J]. *计算机工程与科学*, 2008, 30(8): 57-60.
- SHEN Hui, LIU Zhigui, LIU Suping. A research on the  $\gamma$  ray detection based on neural networks[J]. *Computer Engineering & Science*, 2008, 30(8): 57-60(in Chinese).
- [16] 胡浩行, 张江梅, 王坤朋, 等. 卷积神经网络在复杂核素识别中的应用[J]. *传感器与微系统*, 2019, 38(10): 154-156, 160.
- HU Haohang, ZHANG Jiangmei, WANG Kunpeng, et al. Application of convolutional neural networks in identification of complex nuclides[J]. *Transducer and Microsystem Technologies*, 2019, 38(10): 154-156, 160(in Chinese).
- [17] 赵日, 刘娜. 基于深度学习模型的伽马能谱解析方法[J]. *原子能科学技术*, 2023, 57(2): 379-388.
- ZHAO Ri, LIU Na. Deep learning model based gamma spectrum analysis method[J]. *Atomic Energy Science and Technology*, 2023, 57(2): 379-388(in Chinese).
- [18] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015: 234-241.
- [19] BLANC-DURAND P, van der GUCHT A, SCHAEFER N, et al. Automatic lesion detection and segmentation of 18F-FET PET in gliomas: A full 3D U-Net convolutional neural network study[J]. *PLoS One*, 2018, 13(4): e0195798.
- [20] DAIS D, BAL İ E, SMYROU E, et al. Automatic crack classification and segmentation on masonry surfaces using convolutional neural networks and transfer learning[J]. *Automation in Construction*, 2021, 125: 103606.
- [21] HORNIK K, STINCHCOMBE M, WHITE H. Multilayer feedforward networks are universal approximators[J]. *Neural Networks*, 1989, 2(5): 359-366.
- [22] ALAM M D, NASIM S S, HASAN S. Recent progress in CdZnTe based room temperature detectors for nuclear radiation monitoring[J]. *Progress in Nuclear Energy*, 2021, 140: 103918.
- [23] GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks[C]//Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics. [S. l.]: [s. n.], 2011: 315-323.
- [24] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification[C]//2015 IEEE International Conference on Computer Vision (ICCV). Santiago, Chile: IEEE, 2015: 1026-1034.
- [25] KINGMA D P, BA J. Adam: A method for stochastic optimization[C]//ICLR 2015. (2017-01-30). <http://arxiv.org/pdf/1412.6980.pdf>.
- [26] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks[C]//Computer Vision-ECCV. [S. l.]: [s. n.], 2014: 818-833.
- [27] MAHENDRAN A, VEDALDI A. Understanding deep image representations by inverting them[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). USA: IEEE, 2015: 5188-5196.
- [28] FENG P, LUO Y, ZHAO R, et al. Reduction of Compton background noise for X-ray fluorescence computed tomography with deep learning[J]. *Photonics*, 2022, 9(2): 108-112.
- [29] PRABHAKARAN S, ANNIE UTHRA R, PREETHA ROSELYN J. Deep learning-based model for defect detection and localization on photovoltaic panels[J]. *Computer Systems Science and Engineering*, 2023, 44(3): 2683-2700.