

基于深度学习的LSTM模型在X荧光光谱中的应用

唐琳^{1,2,3,4} 李勇¹ 唐羽锋⁵ 刘泽¹ 柳炳琦⁵

1(成都大学电子信息与电气工程学院 成都 610106)

2(安徽大学农业生态大数据分析与应用国家工程研究中心 合肥 230039)

3(数学地质四川省重点实验室(成都理工大学) 成都 610059)

4(南洋理工大学电气与电子工程学院 新加坡 639798)

5(成都大学机械工程学院 成都 610106)

摘要 在X荧光光谱分析中,为了解决传统谱分析方法中存在的特征峰计数率损失以及影子峰的问题,本文拟采用一种基于深度学习的长短期记忆(Long and Short Term Memory,LSTM)神经网络模型,该模型对核脉冲幅度时间序列具有较好的适用性,通过对样本的学习能够对核脉冲信号的幅度进行准确估计。鉴于核脉冲信号样本较大,模型训练效率低,特引入卷积神经网络(Convolutional Neural Network,CNN),利用其特有的卷积核结构逐层提取样本特征,能够有效减少样本数量,降低模型训练复杂度。使用粉末铁矿样品测量得到的一系列离线核脉冲序列产生模型训练所需的数据集,该数据集的64 000个条目中,44 800个用作训练集,12 800个用作验证集,余下6 400个用作测试集。实验结果表明:训练好的CNN-LSTM模型能够极大地节省训练时间,克服传统方法局部收敛的缺陷,也能够对不同程度畸变的输入脉冲进行准确的参数估计,在训练集和验证集上得到的准确率都高于99%。进一步分析计数修复结果,得到三个影子峰校正比例的平均值为91.52%,表明训练的CNN-LSTM模型对畸变脉冲产生的计数损失的校正比例约为91.52%。该模型能够有效校正因畸变脉冲幅度损失造成的影子峰,改善X射线荧光光谱中特征峰计数率精度,在X射线荧光光谱领域具有较高的应用价值。

关键词 深度学习, 长短期记忆, X荧光光谱, 卷积神经网络

中图分类号 O657.34

DOI: [10.11889/j.0253-3219.2023.hjs.46.070502](https://doi.org/10.11889/j.0253-3219.2023.hjs.46.070502)

Application of an LSTM model based on deep learning through X-ray fluorescence spectroscopy

TANG Lin^{1,2,3,4} LI Yong¹ TANG Yufeng⁵ LIU Ze¹ LIU Bingqi⁵

1(School of Electronic Information and Electrical Engineering, Chengdu University, Chengdu 610106, China)

国家自然科学基金(No.42104174)、四川省自然科学青年基金项目(No.2023NSFSC1366)、安徽大学农业生态大数据分析与应用国家工程研究中心开放研究基金(No.AE202209)、广西多源信息挖掘与安全重点实验室研究基金(No.MIMS22-04)、中国留学基金委(No.202110640002)资助

第一作者: 唐琳, 女, 1988年出生, 2019年于成都理工大学获博士学位, 副教授, 新加坡南洋理工大学访问学者, 研究领域为核辐射探测与电子学

通信作者: 刘泽, E-mail: liuze@cdu.edu.cn

收稿日期: 2023-02-15, 修回日期: 2023-03-13

Supported by National Natural Science Foundation of China (No.42104174), the Sichuan Natural Science Youth Fund Project (No.2023NSFSC1366), the Open Research Fund of National Engineering Research Center for Agro-Ecological Big Data Analysis & Application, Anhui University (No. AE202209), the Research Fund of Guangxi Key Lab of Multi-source Information Mining & Security (No.MIMS22-04), China Scholarship Council (No.202110640002)

First author: TANG Lin, female, born in 1988, graduated from Chengdu University of Technology with a doctoral degree in 2019, associate professor, visiting scholar of Nanyang Technological University, Singapore, focusing on nuclear radiation detection and electronics

Corresponding author: LIU Ze, E-mail: liuze@cdu.edu.cn

Received date: 2023-02-15, revised date: 2023-03-13

2(National Engineering Research Center for Agro-Ecological Big Data Analysis & Application, Anhui University, Hefei 230039, China)

3(Geomathematics Key Laboratory of Sichuan Province (Chengdu University of Technology), Chengdu 610059, China)

4(School of Electrical and Electronic Engineering, Nanyang Technological University, Singapore 639798, Singapore)

5(School of Mechanical Engineering, Chengdu University, Chengdu 610106, China)

Abstract [Background] Traditional X-ray fluorescence spectrum analysis has the limitations of poor accuracy of the characteristic peak counting rate and shadow peak. [Purpose] This study aims to propose a long and short term memory (LSTM) neural network model based on deep learning for the loss correction of the characteristic peak count rate and shadow peak. [Methods] Firstly, a LSTM neural network model based on deep learning was proposed to estimate accurately the amplitudes of nuclear pulse signals by learning samples. Then, a convolutional neural network (CNN) with unique convolutional kernel structure was introduced to deal with the challenges of large sample size of the nuclear pulse signal and the low training efficiency of the model by extracting the sample features layer by layer, thereby effectively reducing the number of samples and the complexity of model training. Finally, a series of offline nuclear pulse sequences of powdered iron ore samples were used to generate the dataset required for model training. Among the 64 000 entries in this dataset, 44 800 were used as training sets, 12 800 were used as validation sets, and the remaining 6 400 were used as testing sets. [Results] The trained CNN-LSTM model saves considerable training time, overcomes the defects of local convergence of traditional methods, and accurately estimates the parameters of input pulse under different degrees of distortion. Results show that the accuracy rate of the training and verification sets is greater than 99%. An analysis of the count repair results reveals that the average value of the correction ratio of the three shadow peaks, that is, the correction ratio of the depth learning model trained in this study to the count loss derived from the distorted pulses, is 91.52%. [Conclusions] The CNN-LSTM model can effectively correct the shadow peaks derived from the amplitude loss of distorted pulses and improve the accuracy of the characteristic peak count rate in X-ray fluorescence spectra. The model is shown to have high application value for the field of X-ray fluorescence spectroscopy.

Key words Deep learning, Long and short term memory, X-ray fluorescence spectroscopy, Convolutional neural network

X射线荧光是指当样品被X射线照射时，样品中的原子会吸收X射线的能量，然后发出特定波长的荧光X射线。这些荧光X射线可以被探测器探测到，从而分析样品中的元素，它包含了被分析样品化学组成的信息，通过对X射线荧光的分析确定被测样品中元素含量的仪器就是X射线荧光分析仪。X射线荧光分析仪主要有波长色散型^[1]和能量色散型^[2]，后者因其较高的性价比已成为X射线荧光主要的分析方式。在能量色散型X射线荧光光谱分析(Energy Dispersive X-ray Fluorescence, EDXRF)中，计数率和能量分辨率都是非常重要的指标，直接决定了被测样品中各元素含量分析的准确性^[3]，尤其是对微弱元素的检测，谱峰漂移和计数率损失将会对辐射光谱产生扭曲，进而对光谱学分析造成不可估量的影响^[4]。造成谱峰漂移和计数率损失的主要原因则是测量系统本身带来的脉冲畸变、脉冲堆积等。在X射线荧光光谱获取过程中，探头输出的脉冲信号经前端电路、数字脉冲处理单元处理后在控制器中形成多道X荧光光谱图。脉冲畸变造成三角成形结果幅度受损导致了当前X荧光光谱的一些

局限性，包括谱峰漂移、计数率不可靠以及元素含量分析不准确等。

在X荧光光谱分析领域中已经公布了大量关于优化数字脉冲处理效果的研究成果。其中，Zhong等^[5]提出的算法解决了 γ 射线光谱系统中脉冲堆积和温度波动导致的能量谱分辨率差的问题；Regadio等^[6]利用遗传算法来确定光谱时域最佳成形方式；Zhou等^[7]提出了一种基于梯形成形的堆积脉冲识别方法，能够有效识别无严重堆积的脉冲；Kafaei等^[8]提出了基于双极性尖顶成形的基线恢复和堆积校正算法；Usman等^[9]对脉冲堆积提出了测量和补偿技术；作者在前期研究中针对畸变脉冲提出了脉冲剔除法^[10]和脉冲修复法^[11]，两种方法都在一定程度上改善了谱分析精度。上述研究方法作为传统的脉冲处理方式，在脉冲堆积或者脉冲畸变不是特别严重的应用中对X荧光光谱分析有较为明显的优化效果，但是当脉冲严重堆积或者脉冲畸变难以甄别时，传统的脉冲处理方法则受到了极大的限制，这也是谱处理领域中的一个研究热点和难点问题。

深度学习技术是一种基于人工神经网络的机器

学习方法,通过多层次的神经网络模型对数据进行学习和分析,从而实现对数据的自动化处理和预测。目前该技术已经被广泛应用于医疗^[12]、工业^[13]、控制^[14]等领域,在谱分析领域中也有相关的成果公布。王江玮等^[15-16]将神经网络应用于能谱校正并取得了较好的应用效果;文献[17]将残差网络应用于脉冲形状甄别,有效改进了谱分析精度;文献[18]显示了卷积神经网络(Convolutive Neural Network,CNN)在脉冲高度分析方面的良好性能。相比于在其他领域的应用,深度学习技术在谱分析领域中的应用目前尚处于探索阶段,将这项新技术引入X射线荧光光谱分析已变得非常紧迫。

1 原理及方法

1.1 谱线精细化原理

X荧光光谱多采用多道分析器(Multichannel Analyzer,MCA)进行分析,文献[19-20]详细陈述了多道谱的成谱原理。每一个脉冲幅度都对应着相应道址上的一次计数,当测量系统输出的脉冲因发生畸变而产生了幅度损失时,该脉冲对应的计数道址就会向左发生漂移。当这类脉冲的数量足够多时,就会在生成的全能谱中以特征峰的影子峰形式存在。本文提出CNN-LSTM模型,该模型将卷积神经网络(Convolutive Neural Network,CNN)与长短期记忆(Long and Short Term Memory,LSTM)模型^[21]相结合,通过对脉冲参数的准确估计将影子峰区域中的计数校正到特征峰中,既可以消除影子峰,也能够达到修复特征峰计数率的目的。

从理论上分析,当畸变脉冲的幅度得到准确估计时,被消除掉的影子峰应该是被校正到它原本的道址区间,而不是凭空消失。影子峰的校正原理如图1所示,以1 000个幅度恒定为1 000 mV的脉冲序列为为例,设脉冲畸变比例为10%,在未校正畸变脉冲之前得到的全能谱中特征峰区域的总计数为900,而在特征峰左侧第920道址附近则出现了一个由畸变脉冲形成的影子峰,该区域的计数率之和为100,如图1蓝色曲线所示;当100个畸变脉冲的幅度被有效校正时,1 000个脉冲得到的特征峰直方图则如图1红色曲线所示,总计数为1 000,既保证了特征峰区域的计数不受损失,也消除了因脉冲畸变造成影子峰。

1.2 数据集制作

在X射线荧光光谱峰校正的应用中,CNN-LSTM模型的数据集取自于离线保存的实测脉冲数据,在测量过程中激发源采用的是上海科颐维

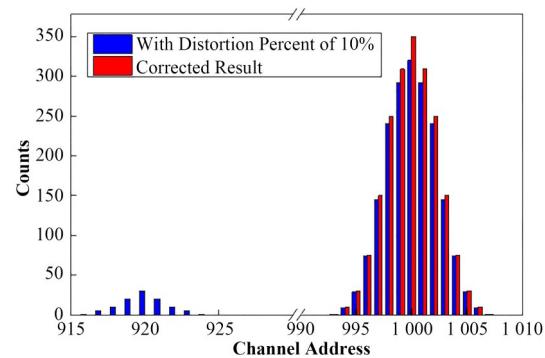


图1 峰位校正原理示意图(彩图见网络版)
Fig.1 Principle diagram of peak correction (color online)

2000A型X光管(额定管压50 kV、额定管流为0~1 mA),样品使用的是粉末铁矿样品(主要元素成为铁、锶、锡等),测量采用的探测器为AMPEK公司的高性能硅漂移探测器(FAST-SDD(Silicon Drift Detector)),其有效探测面积为25 mm²,探测器厚度为500 μm。

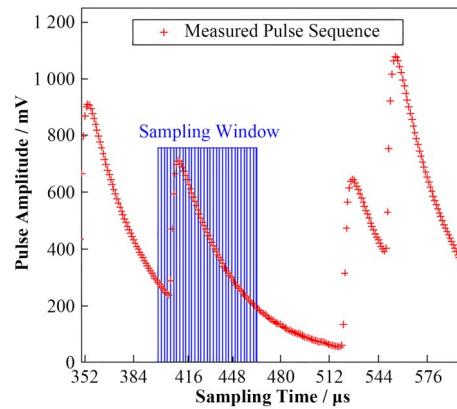


图2 数据集生成原理示意图
Fig.2 Principle diagram of dataset generation

制作数据集时,首先调用Scipy库中的峰值查找函数找到峰值位置,然后将峰值之前的10个采样点到峰值之后的53个采样点所在区域定义为采样窗口(Sampling window),如图2所示,从而获取到该峰值所在脉冲的64个采样点的值,形成一个包含64个采样点的单脉冲数据集。在训练中,可以通过参考峰值信号来匹配脉冲的真实脉冲幅度。对于实测脉冲生成的数据集,将脉冲幅度集与真实脉冲幅度一起作为输入,期望得到最接近真实脉冲幅度的输出。图2展示了对任意脉冲进行采样点分割的示意图。以1 000个脉冲为例进行数据集构造,经采样点分割得到包含64 000个幅度样本的数据集,生成的数据集如式(1)所示。

$$\begin{bmatrix} [V_o(T_{clk})]_1 & [V_o(2 \times T_{clk})]_1 & \cdots & [V_o(64 \times T_{clk})]_1 \\ [V_o(T_{clk})]_2 & [V_o(2 \times T_{clk})]_2 & \cdots & [V_o(64 \times T_{clk})]_2 \\ \vdots & \vdots & \cdots & \vdots \\ [V_o(T_{clk})]_{1000} & [V_o(2 \times T_{clk})]_{1000} & \cdots & [V_o(64 \times T_{clk})]_{1000} \end{bmatrix} \quad (1)$$

1.3 模型结构分析

本文拟采用的模型其处理对象是一系列核信号脉冲幅度序列, LSTM作为一种特殊的递归神经网络(Recursive Neural Network, RNN), 与RNN的本质区别在于遗忘门的引入, 通过控制参数来决定什么样的信息会被保留, 什么样的信息会被遗忘, 因此, LSTM能够解决长时间序列样本在训练过程中的梯度消失和梯度爆炸问题。软件平台使用Python和TensorFlow 2.3, 考虑到该模型用于快速光谱学, 本文尽可能将模型的架构简化, 以减少训练时间。模型由2个卷积层、2个池化层、4个LSTM层组成, 卷积层采用 3×3 的滤波器内核, 步长固定为1, 在每个卷积层之后还配置了一个最大池化层, 以减少要输入到下一层中的卷积特征的维数。模型结构图如图3所示, 输入为一个 1000×64 的脉冲幅度采样值矩阵, 经卷积层和LSTM层后输出为一个 1000×1 的矩阵, 代表1 000个脉冲的幅度估计值。

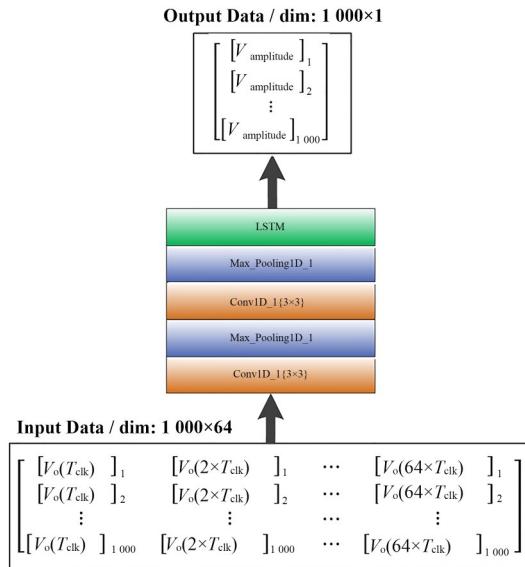


图3 网络模型结构图

Fig.3 Structure diagram of network model

2 仿真与实验

2.1 仿真结果

使用生成的数据集训练模型, 在该数据集中的

64 000个条目中, 44 800个用作训练集, 12 800个用作验证集, 余下6 400个用作测试集。为了评估期望输出和预测输出之间的差异, 均方误差(Mean-Square Error, MSE)被用作损失函数。使用Adam优化器对模型进行100个epoch的训练, 学习率为0.000 1。图4显示了该模型的训练曲线。随着训练时间的递增, 训练集与验证集上的损失值都是在第35个epoch之后就几乎趋近于零, 在训练集和验证集上得到的准确率接近100%。

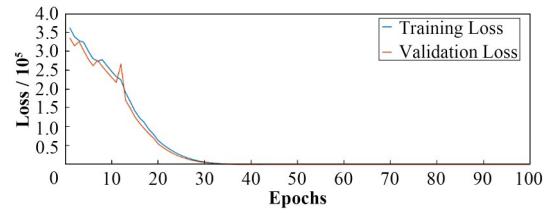


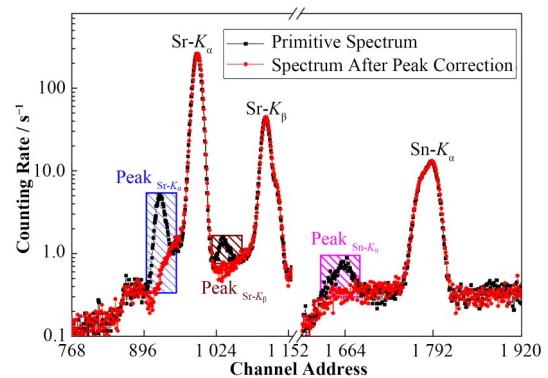
图4 模型训练过程中在训练集和验证集上的损失值与准确率迭代图

Fig.4 Iterative graph of loss and accuracy on training and validation sets during model training

2.2 实验验证

2.2.1 峰位校正结果分析

为了进一步验证模型对幅度参数的估计效果, 以及调用该模型对X射线荧光光谱分析产生的优化效果, 在实验验证环节中选择的被测样品以及测试条件都与数据集制作过程中采用的离线测量结果的实验条件保持一致。采用传统的MCA分析得到的结果如图5中的黑色谱线所示, 图中每个计数率较高的元素特征峰前面都存在一个像影子一样的弱峰, 如锶元素的 K_a 峰和 K_b 峰以及锡元素的 K_a 峰。根据前文的谱线精细化原理, 初步判断这样的弱峰就是计数率较高的特征峰由于计数率漂移形成的影子峰, 而计数率漂移其本质原因就是畸变的负指数脉冲三角成形结果的幅度严重受损。

图5 影子峰校正效果对照图(彩图见网络版)
Fig.5 Comparison of shadow peak correction effects with the primitive peaks (color online)

通过在对数坐标系中放大影子峰区域局部特征可以看出,图5中黑色谱线所示的锶元素的两个特征峰前面各有一个弱峰,在图中以Peak_{Sr-K_a}和Peak_{Sr-K_b}分别表示锶元素Sr-K_a峰和Sr-K_b峰的影子峰,而锡元素仅Sn-K_a峰存在明显的影子峰Peak_{Sn-K_a},Sn-K_b峰由于本身计数率较低,产生的影子峰并不明显,因此未在图5中进行标注。通过模型对畸变脉冲进行参数估计后有效地校正了峰位的左移,消除了影子峰。将模型估计的畸变脉冲的幅度值替换掉原始脉冲幅度,最终得到校正后的谱线如图5中的红色谱线所示,影子峰校正前后的对照图表明本文训练的深度学习模型能够有效地校正因脉冲畸变造成的影子峰,优化X射线荧光光谱分析结果。

2.2.2 计数修复结果分析

如前文所述,畸变脉冲幅度受损导致了特征峰计数受损,其本质就是特征峰区域损失掉的计数转移到了影子峰区域,在特征峰的左侧形成了影子峰,这里用峰面积来表示特定道址区间的计数率之和,因此计数修复结果的分析也就转换成了峰面积校正比例的分析。可以推测,影子峰的峰面积应近似等于调用模型进行参数估计后特征峰被校正的峰面积,其计算公式如式(2)~(4)所示:

$$\text{Area}_{\text{shadow}} = \text{Area}_{\text{shadow - original}} - \text{Area}_{\text{shadow - corrected}} \quad (2)$$

$$\text{Area}_{\text{TP - repair}} = \text{Area}_{\text{TP - corrected}} - \text{Area}_{\text{TP - original}} \quad (3)$$

$$\text{Area}_{\text{shadow}} \approx \text{Area}_{\text{TP - repair}} \quad (4)$$

式中:Area_{shadow}表示畸变脉冲产生的影子峰的峰面积,在数值上就等于谱峰校正前后影子峰所在道址区间的峰面积之差;Area_{TP - repair}表示调用模型进行参数估计实现谱峰校正后特征峰被修复的那部分计数,在数值上等于谱峰校正前后特征峰所在道址区间的峰面积之差,如式(3)所示。

根据前文的理论分析,影子峰的峰面积近似等于特征峰被校正的峰面积,本文选取的三个特征峰

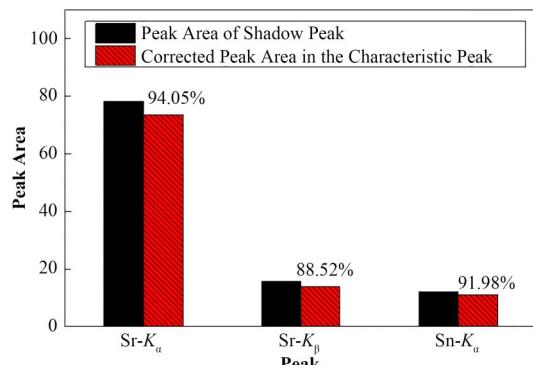


图6 峰面积修复比例(彩图见网络版)
Fig.6 Repair ratio of peak areas (color online)

及其相应的影子峰的峰面积定量分析结果如图6所示,其中黑色阴影区域表示影子峰的峰面积,红色阴影区域表示被校正到特征峰中的峰面积,可以看出三个特征峰相应的影子峰峰面积和被校正的峰面积是近似相等的,式(4)得到了实验结果的验证。由于放射性测量的随机性以及测量过程不可避免的统计涨落,不同影子峰的校正比例存在一定差距,其计算公式如式(5)所示,得出三个影子峰校正比例分别为94.05%、88.52%和91.98%,取三者的平均值为91.52%,从而得出本文训练的深度学习模型对畸变脉冲产生的计算损失的校正比例约为91.52%。

$$\text{Rate}_{\text{corrected}} = \frac{\text{Area}_{\text{TP - repair}}}{\text{Area}_{\text{shadow}}} \times 100\% \quad (5)$$

3 结语

本文训练了一种基于深度学习的CNN-LSTM模型用于X射线荧光光谱的谱峰校正,通过模拟和实验对模型进行了验证,模型由两个卷积层、两个池化层、4个LSTM层组成,其模型的处理对象是1 000个离线保存的实测脉冲采样得到的64 000个幅度样本,为了提高训练效率,该模型分为两个部分,先通过CNN对数据进行特征提取,然后再通过LSTM网络进行脉冲幅度的估计,验证集与测试集的结果表明:该模型对畸变脉冲幅度估计的准确率高于99%。在实验环节中,将采用MCA分析得到的原始谱与调用模型进行谱峰校正得到的校正谱进行对比,结果表明CNN-LSTM模型能够准确估计畸变脉冲幅度,达到消除影子峰,校正特征峰计数的目的。

在进一步的计数修复结果分析中,锶元素Sr-K_a峰的影子峰Peak_{Sr-K_a}的校正比例分别为94.05%;Sr-K_b峰的影子峰Peak_{Sr-K_b}的校正比例为88.52%;锡元素Sn-K_a峰的影子峰Peak_{Sn-K_a}的校正比例为91.98%。结果表明:对于计数值较高的特征峰,其影子峰校正比例也相对较高,而计数较低的影子峰则易受到测量过程中的各种干扰,造成统计涨落。取三个影子峰校正比例的平均值91.52%,从而得出本文训练的深度学习模型对畸变脉冲产生的计算损失的校正比例约为91.52%。

未来关于深度学习在谱分析领域的应用研究将旨在优化训练模型和数据集,同时也可考虑将参数估计模型应用在高纯锗探测器(HPGe)和溴化镧探测器(LaBr₃)中,以期将深度学习模型广泛应用于辐射测量领域。

作者贡献声明 唐琳参与论文研究,负责神经网络模拟搭建并撰写论文;李勇负责模型训练;唐羽锋负责实验结果分析;刘泽负责资料的搜集及整理;柳炳琦负责模型训练。

参考文献

- 1 Chowdhury P R, Mitra A, Patra S, *et al.* A study on material dispersion around zero material dispersion wavelength of different material composition based optical fiber[J]. Advanced Materials Research, 2021, **1166**: 25 – 31. DOI: [10.4028/www.scientific.net/amr.1166.25](https://doi.org/10.4028/www.scientific.net/amr.1166.25).
- 2 Marchewka M, Śliż P, Rogalska I. The engineering of Weyl nodes and Dirac-like energy dispersion for topological surface states in $Hg_{1-x}Mn$ Te under structure and interface inversion asymmetry[J]. Surface Science, 2020, **700**: 121653. DOI: [10.1016/j.susc.2020.121653](https://doi.org/10.1016/j.susc.2020.121653).
- 3 张浩宇, 吴文圣, 熊世涛. 造岩元素中子 γ 测井仪器结构优化研究[J]. 核技术, 2022, **45**(9): 090402. DOI: [10.11889/j.0253-3219.2022.hjs.45.090402](https://doi.org/10.11889/j.0253-3219.2022.hjs.45.090402).
ZHANG Haoyu, WU Wensheng, XIONG Shitao. Optimal design of neutron gamma logging tool for rock-forming elements[J]. Nuclear Techniques, 2022, **45**(9): 090402. DOI: [10.11889/j.0253-3219.2022.hjs.45.090402](https://doi.org/10.11889/j.0253-3219.2022.hjs.45.090402).
- 4 Lee D, Lim K, Park K, *et al.* An innovative method to reduce count loss from pulse pile-up in a photon-counting pixel for high flux X-ray applications[J]. Journal of Instrumentation, 2017, **12**(3): P03006. DOI: [10.1088/1748-0221/12/03/p03006](https://doi.org/10.1088/1748-0221/12/03/p03006).
- 5 Zhong X D, Chen L, Wang B C, *et al.* A spectrometer with baseline correction and fast pulse pile-up rejection for prompt gamma neutron activation analysis technology [J]. The Review of Scientific Instruments, 2018, **89**(12): 123504. DOI: [10.1063/1.5049517](https://doi.org/10.1063/1.5049517).
- 6 Regadío A, Sánchez-Prieto S, Tabero J, *et al.* Synthesis of optimal digital shapers with arbitrary noise using a genetic algorithm[J]. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 2015, **795**: 115 – 121. DOI: [10.1016/j.nima.2015.05.059](https://doi.org/10.1016/j.nima.2015.05.059).
- 7 Zhou J B, Liu Y, Hong X, *et al.* Trapezoidal pulse shaping for pile-up pulse identification in X-ray spectrometry[J]. Chinese Physics C, 2015, **39**(6): 068201. DOI: [10.1088/1674-1137/39/6/068201](https://doi.org/10.1088/1674-1137/39/6/068201).
- 8 Kafaee M, Moussavi-Zarandi A. Baseline restoration and pile-up correction based on bipolar cusp-like shaping for high-resolution radiation spectroscopy[J]. Journal of the Korean Physical Society, 2016, **68**(8): 960 – 964. DOI: [10.3938/jkps.68.960](https://doi.org/10.3938/jkps.68.960).
- 9 Usman S, Patil A. Radiation detector deadtime and pile up: a review of the status of science[J]. Nuclear Engineering and Technology, 2018, **50**(7): 1006 – 1016. DOI: [10.1016/j.net.2018.06.014](https://doi.org/10.1016/j.net.2018.06.014).
- 10 Tang L, Yu J, Zhou J B, *et al.* A new method for removing false peaks to obtain a precise X-ray spectrum[J]. Applied Radiation and Isotopes, 2018, **135**: 171 – 176. DOI: [10.1016/j.apradiso.2018.01.033](https://doi.org/10.1016/j.apradiso.2018.01.033).
- 11 Tang L, Zhou J B, Fang F, *et al.* Counting-loss correction for X-ray spectra using the pulse-repairing method[J]. Journal of Synchrotron Radiation, 2018, **25**(6): 1760 – 1767. DOI: [10.1107/s160057751801411x](https://doi.org/10.1107/s160057751801411x).
- 12 Cheng N T, Fu J, Chen D J, *et al.* An antibody-free liver cancer screening approach based on nanoplasmonics biosensing chips via spectrum-based deep learning[J]. NanoImpact, 2021, **21**: 100296. DOI: [10.1016/j.impact.2021.100296](https://doi.org/10.1016/j.impact.2021.100296).
- 13 Chen Y F, Han W. Harmonic Current control strategy of DC distribution network based on deep learning algorithm [J]. Energy Reports, 2022, **8**: 13066 – 13075. DOI: [10.1016/j.egyr.2022.09.071](https://doi.org/10.1016/j.egyr.2022.09.071).
- 14 Alwan N A S, Hussain Z M. Deep learning for robust adaptive inverse control of nonlinear dynamic systems: improved settling time with an autoencoder[J]. Sensors, 2022, **22**(16): 5935. DOI: [10.3390/s22165935](https://doi.org/10.3390/s22165935).
- 15 王江玮, 顾卫国, 杨桧, 等. 基于深度神经网络的放射性废物桶 γ 能谱解析方法[J]. 核技术, 2022, **45**(4): 040501. DOI: [10.11889/j.0253-3219.2022.hjs.45.040501](https://doi.org/10.11889/j.0253-3219.2022.hjs.45.040501).
WANG Jiangwei, GU Weiguo, YANG Hui, *et al.* Analytical method for γ energy spectrum of radioactive waste drum based on deep neural network[J]. Nuclear Techniques, 2022, **45**(4): 040501. DOI: [10.11889/j.0253-3219.2022.hjs.45.040501](https://doi.org/10.11889/j.0253-3219.2022.hjs.45.040501).
- 16 张松, 胡传皓, 李承洋, 等. 小波包软阈值降噪法在航空 γ 能谱中的应用[J]. 核技术, 2022, **45**(9): 090501. DOI: [10.11889/j.0253-3219.2022.hjs.45.090501](https://doi.org/10.11889/j.0253-3219.2022.hjs.45.090501).
ZHANG Song, HU Chuanhao, LI Chengyang, *et al.* Apply wavelet packet soft threshold noise reduction method to aviation gamma energy spectrum[J]. Nuclear Techniques, 2022, **45**(9): 090501. DOI: [10.11889/j.0253-3219.2022.hjs.45.090501](https://doi.org/10.11889/j.0253-3219.2022.hjs.45.090501).
- 17 Woldegiorgis S, Enqvist A, Baciak J. ResNet and CycleGAN for pulse shape discrimination of He-4

- detector pulses: recovering pulses conventional algorithms fail to label unanimously[J]. Applied Radiation and Isotopes, 2021, **176**(10): 109819. DOI: [10.1016/j.apradiso.2021.109819](https://doi.org/10.1016/j.apradiso.2021.109819).
- 18 Regadío A, Esteban L, Sánchez-Prieto S. Unfolding using deep learning and its application on pulse height analysis and pile-up management[J]. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 2021, **1005**(6): 165403. DOI: [10.1016/j.nima.2021.165403](https://doi.org/10.1016/j.nima.2021.165403).
- 19 唐琳, 廖先莉, 刘星月, 等. X射线光谱中特征峰漂移校正算法的研究[J]. 光谱学与光谱分析, 2020, **40**(11): 3633 – 3638. DOI: [10.3964/j.issn.1000-0593\(2020\)11-00-06](https://doi.org/10.3964/j.issn.1000-0593(2020)11-00-06).
TANG Lin, LIAO Xianli, LIU Xingyue, et al. Study on correction algorithms of characteristic peak drift in X-ray spectrum[J]. Spectroscopy and Spectral Analysis, 2020, **40**(11): 3633 – 3638. DOI: [10.3964/j.issn.1000-0593\(2020\)11-00-06](https://doi.org/10.3964/j.issn.1000-0593(2020)11-00-06).
- 20 Liu Y L, Zhang Q X, Zhang J, et al. Quantitative energy-dispersive X-ray fluorescence analysis for unknown samples using full-spectrum least-squares regression[J]. Nuclear Science and Techniques, 2019, **30**(3): 52. DOI: [10.1007/s41365-019-0564-8](https://doi.org/10.1007/s41365-019-0564-8).
- 21 Wielgosz M, Skoczeń A, Mertik M. Using LSTM recurrent neural networks for monitoring the LHC superconducting magnets[J]. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 2017, **867**: 40 – 50. DOI: [10.1016/j.nima.2017.06.020](https://doi.org/10.1016/j.nima.2017.06.020).