

## 基于双通道卷积神经网络的煤灰分太赫兹预测

任姣姣<sup>1,2,3\*</sup>, 焦铁鑫<sup>1,2,3</sup>, 顾健<sup>1,2,3</sup>, 陈奇<sup>3</sup>, 李丽娟<sup>1,2,3</sup>, 张霁旸<sup>3</sup><sup>1</sup>长春理工大学光电测控与光信息传输技术教育部重点实验室, 吉林 长春 130022;<sup>2</sup>长春理工大学光电工程学院, 吉林 长春 130022;<sup>3</sup>长春理工大学中山研究院, 广东 中山 528400

**摘要** 利用太赫兹时域光谱技术对不同煤灰含量的光谱进行分析,发现在 0.5~3 THz 频段内,随着煤灰含量的增加,其折射率会逐步提高,吸收效应也会逐步增强;考虑到煤样品厚度对光谱的影响,提出一种基于厚度校正的吸收系数特征提取方法,提高了低灰分煤样品吸收曲线的数据区分度;利用双通道卷积神经网络提取折射率和吸收系数特征,建立了煤灰分预测模型。实验结果显示,训练集的拟合度为  $R^2=98.21\%$ ,预测精度  $E_{\text{RMS}}=0.1442$ ,而预测集的  $R^2=93.56\%$ , $E_{\text{RMS}}=0.2037$ ,均优于传统 PLSR、BP 和 LSSVM 等方法。可见,所提方法在解决选煤厂煤灰分检测问题上具有较好的表现,为选煤厂提供了一种新的技术路径。

**关键词** 光谱学; 太赫兹时域光谱技术; 煤灰分; 折射率; 吸收系数; 卷积神经网络; 预测

中图分类号 TQ533.6

文献标志码 A

DOI: 10.3788/AOS231086

## 1 引言

煤炭在中国的经济和能源战略中扮演着至关重要的角色,是主要的能源来源之一,也是能源安全的重要组成部分<sup>[1]</sup>。在煤炭生产过程中,灰分含量一直是选煤厂控制产品质量的难题。通过收集和分析灰分检测数据,保持煤炭灰分稳定,能够保证煤炭洗选产品的质量,提高能源利用率,降低碳排放,有助于环境保护<sup>[2-4]</sup>。中国主要使用快速或缓慢灰化法来检测灰分含量。该过程需要 2~3 h 才能从采制煤样中得到检测结果,检测周期长、效率低、检测结果严重滞后;近些年,灰分含量在线检测技术取得了突破和进展,如射线吸收法在线检测技术的测量精密度和准确度比较高,但对检测煤种的适应性不佳,在管理和安全生产中存在不便<sup>[5-6]</sup>。工业生产中需要一种快速准确、安全、可用于实时监测的煤灰分含量检测方法。

太赫兹 (THz) 光谱技术是一种新兴的光谱技术,弥补了微波光谱和红外光谱之间的差距,该频段包含物质的物理、结构和化学信息,可满足煤炭工业的实际技术要求<sup>[7]</sup>。Tanno 等<sup>[8]</sup>利用水分在 THz 波段有着强烈的吸收,通过对煤炭 THz 波段进行测试,发现煤炭 THz 波段的折射率随着水分含量的增大呈下降趋势,证明了 THz 波段用于煤炭中水分含量的预测是可行

的;王昕等<sup>[9]</sup>对我国 7 种不同类型的烟煤进行光谱测量,得到其吸收光谱、折射光谱等光谱数据,分析了不同烟煤中灰分、挥发分含量及其变质程度等因素对 THz 光谱特性的影响;贾成艳等<sup>[10]</sup>研究了 75~750 GHz 频率范围内的煤层衰减特性,在较高的频段或含有较多水分的情况下对电磁波的衰减较大;Zhan 等<sup>[11]</sup>通过 THz 时域光谱技术结合主要成分分析法,对煤样中的部分关键参数进行表征,这对煤田的参数监测和元素控制意义重大;Yu 等<sup>[12]</sup>利用 BP 神经网络和最小二乘支持向量机 (LSSVM) 建立了煤岩混合物与 THz 信号之间的定量模型,该方法能准确估计采煤机滚筒齿轮嵌入岩层的深度,即利用太赫兹时域光谱系统 (THz-TDs) 在线表征煤岩界面,并能及时调整滚筒高度;郜亚松等<sup>[13]</sup>采用改进的轻型深度辨识网络模式辨识煤矸石,对煤炭与矸石的辨识准确度可达 97.7%,较原模式提高了 2.3%,且召回率提高了 2%,达到 97.8%,该研究为煤矸石开采自动化控制提供了新思路、新方法。上述研究主要涉及煤炭样品的一些关键参数表征、煤和矸石的定性分析和煤岩定性分析,没有对灰分进行定量分析。

为解决煤灰分含量预测精度低的问题,本文利用 THz 光谱仪对 46 个样本进行检测,对煤样品的吸收光谱和折射光谱进行提取,并对不同灰分含量的样品在

收稿日期: 2023-06-02; 修回日期: 2023-07-08; 录用日期: 2023-08-03; 网络首发日期: 2023-08-15

基金项目: 吉林省科技发展计划项目 (20220508032RC)、中山市第九批创新科研团队 (GXTD2022010)、中山市第二批社会公益和基础研究项目 (2022B2012)

通信作者: \*zimengrenjiao@163.com

THz 频段的吸收特征和折射特性进行研究。为排除样本厚度对吸收系数的影响,提出一种基于厚度模型校正的吸收系数特征提取方法;为提高预测精度、获取不同的特征信息,通过建立双通道卷积神经网络<sup>[14-15]</sup>提取折射特征和吸收特征并进行煤灰分预测,为煤矿智能化检测提供理论依据与技术支撑。

## 2 样品制备与 THz 光谱检测

### 2.1 样品制备

实验中用于样品制作的煤粉均来自某选煤厂,灰分的质量分数在 16.45%~81.49% 范围内,包含 5 个煤种,共制备 46 个样品。首先,把煤粉样品放置在高温干燥箱以去除样品煤粉中的水分;然后,利用高精度的电子天平对煤粉进行称量,每次称取 350 mg,并放入直径为 19.1 mm 的模具中,使用压片机在 20 MPa 的压强下保持 10 min,得到光滑、无裂纹的圆盘状板材;最后,利用螺旋测微器测量每个样品的厚度,虽然各样品的质量相同,但由于煤种密度不同,压片厚度并不相等。图 1 为灰分质量分数及厚度的变化散点图,可以看到,随着灰分质量分数的增大,煤样品厚度变薄。




图 1 样品灰分质量分数及厚度  
Fig. 1 Sample ash mass fraction and thickness

### 2.2 检测装置

本研究使用的实验设备是由日本 Advantest 公司生产的 TAS7500SU 透射式光谱仪,系统分辨率为 7.6 GHz,其工作频率范围为 0.5~7 THz;扫描速度小于 8 ms/scan,峰值动态范围大于 70 dB,如图 2 所示。本实验在常温(24 °C)下进行,样品室内充入干燥气体,以克服外界温度、湿度等因素对测定的干扰。连续三次测定煤样品的位置,并将其平均值作为样本的时域频谱信号。

## 3 光学参数提取和分析

### 3.1 煤样品光学参数提取

折射率和吸收系数的计算方法以透射式 THz 时域光谱系统为例,将空气的 THz 波形作为参考波形  $E_{ref}(t)$ ,样品的 THz 信号作为样品波形  $E_{sam}(t)$ 。使用

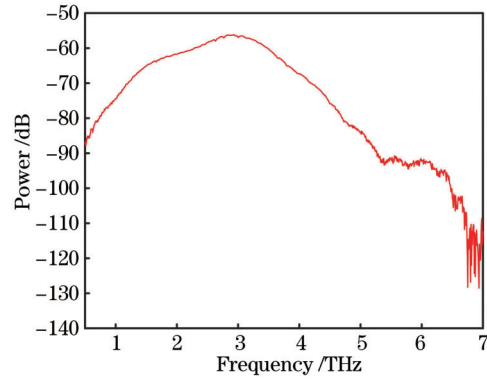


图 2 THz 光谱仪的频谱图  
Fig. 2 Spectrogram of THz spectrometer

傅里叶变换实现光谱从时域到频域的转换,分别用  $E_{ref}(\omega)$  和  $E_{sam}(\omega)$  表示,根据菲涅耳系数得到煤样品的传递函数为  $H(\omega) = \frac{E_{sam}(\omega)}{E_{ref}(\omega)} = \rho(\omega) \exp[-j\varphi(\omega)]$ ,样品的折射率  $n(\omega)$  和吸收系数  $\alpha(\omega)$  为

$$n(\omega) = \frac{\varphi(\omega)c}{\omega d} + 1, \quad (1)$$

$$\alpha(\omega) = \frac{2}{d} \ln \left\{ \frac{4n(\omega)}{\rho(\omega) [1 + n(\omega)]^2} \right\}, \quad (2)$$

式中:  $\varphi(\omega)$  表示  $E_{sam}(\omega)$  与  $E_{ref}(\omega)$  的相位差;  $\rho(\omega)$  表示  $E_{sam}(\omega)$  与  $E_{ref}(\omega)$  的幅度比;  $c$  为光速,单位为  $m \cdot s^{-1}$ ;  $\omega$  为角频率,单位为  $rad \cdot s^{-1}$ ;  $d$  为样品厚度,单位为  $m$ 。

### 3.2 煤样品光学参数分析

图 3(a) 为由式(1)计算得到的折射率。可以看到:当处于 0.5~3 THz 的频率范围时,10 个样品的折射率波动幅度处于 1.76~2.02,但这种波动幅度相差不大;当灰分质量分数增大时,折射率也会相应地增大,说明灰分的含量对煤样品的折射率有着重要的影响。

图 3(b) 为由式(2)计算得到 10 个不同灰分质量分数样品的吸收系数,可以看到,10 个样品的吸收系数全部呈单调递增趋势且大小各不相同。随着灰分质量分数的增加,吸收系数的增长趋势更加显著,但不同灰分质量分数样品之间吸收效应差异并不明显,在 0.5~3 THz 的有效频段范围内并没有出现明显的吸收峰。实验结果表明,煤灰分含量是样品吸收效应的影响因素之一,灰分主要包括无机盐和氧化物,这些成分可能会影响煤样品的吸收效果。

### 3.3 基于厚度模型校正的吸收系数特征提取

式(2)中样品厚度与样品吸收系数呈负相关,为消除煤样品厚度对光谱数据的影响,方便样品灰分含量预测,提出一种基于厚度校正的吸收系数特征提取方法。首先,利用指数函数对煤样品吸收光谱数据进行拟合回归;然后,将非线性模型转化为线性模式,表示为  $\ln y = \ln a + bx$ ,在此采用最小二乘法进行线性拟

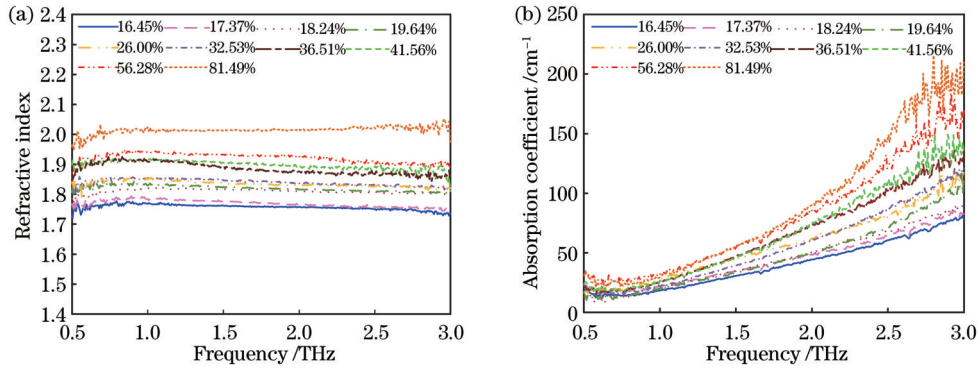


图 3 10 个不同灰分质量分数样品的折射率和吸收系数。(a) 折射率; (b) 吸收系数

Fig. 3 Refractive index and absorption coefficient of 10 samples with different ash mass fraction. (a) Refractive index; (b) absorption coefficient

合。假设拟合直线为  $p(y) = c + ex$ , 其中  $c = \ln a$ ,  $e = b$ , 均方误差为

$$Q(c, d) = \sum_{i=0}^{n-1} [p(y_i) - \ln y_i]^2 = \sum_{i=0}^{n-1} (c + ex_i - \ln y_i)^2 \quad (3)$$

采用消元法或克莱姆法解出  $c$  和  $e$ , 即为  $\ln a$  和  $b$ 。

厚度校正主要是对指数拟合的斜率参数进行校正, 计算公式为

$$c_d = \frac{c_i}{\bar{d}}, \quad i = 1, 2, \dots, 46, \quad (4)$$

式中:  $c_i$  为指数拟合吸收光谱的斜率;  $\bar{d}$  为样品厚度的

平均值;  $c_d$  为经厚度校正的指数拟合函数斜率。根据校正后的斜率  $c_d$  对吸收光谱曲线进行斜率  $c_i$  位置的平移校正。

图 4(a) 所示为原始吸收曲线, 可以看出, 9 个灰分质量分数相近的煤样品吸收曲线差异较小, 不易区分; 图 4(b) 所示为基于厚度模型校正的吸收系数, 未改变原始吸收曲线的变化趋势, 对不同灰分质量分数样品的吸收效应具有不同程度的增强, 在样品厚度保持一致的情况下, 可以更有效地区分不同样品吸收光谱之间的差异, 吸收曲线的分离程度更高, 进而提高后续模型的预测结果。




图 4 9 个样品的吸收光谱。(a) 原始吸收光谱; (b) 厚度校正增强后的吸收光谱

Fig. 4 Absorption spectra of nine samples. (a) Original absorption spectra; (b) absorption spectra after thickness corrected enhancement

## 4 灰分预测

### 4.1 双通道卷积神经网络模型的构建

为了实现对不同灰分含量样品特征向量的学习和预测, 本实验拟搭建双通道卷积神经网络, 用于煤样品特征向量的提取、加权融合及预测。双通道卷积神经网络能够提取煤样品折射率和吸收系数的特征, 克服了单一通道对特征提取不完全的缺点, 提高了预测精度, 减小了误差。对现有的样品数据进行多次实验, 完善和调整网络结构, 以煤样品光谱信息的最佳回归效果为导向, 建立起煤样品的双通道卷积预测模型结构,

具体网络结构如图 5 所示。

通道 1 对煤样品折射率光谱数据进行卷积操作, 以获取折射光谱的特征; 通道 2 负责从吸收光谱中提取特征。在卷积层和池化层中, 滤波器的 stride 都设置为 3, 并选取 ReLU 函数作为卷积层和全连接层的激活函数。

利用权重融合的方法构建了一个特征融合网络, 通过权重系数  $\alpha$  将煤样品吸收数据特性和折射率特性进行权重相加, 从而得到两个特性双通道特征:

$$f = \alpha \cdot f_1 + (1 - \alpha) f_2, \quad (5)$$

式中:  $f$  为融合后得到的特征;  $f_1$  为提取的煤样品折射



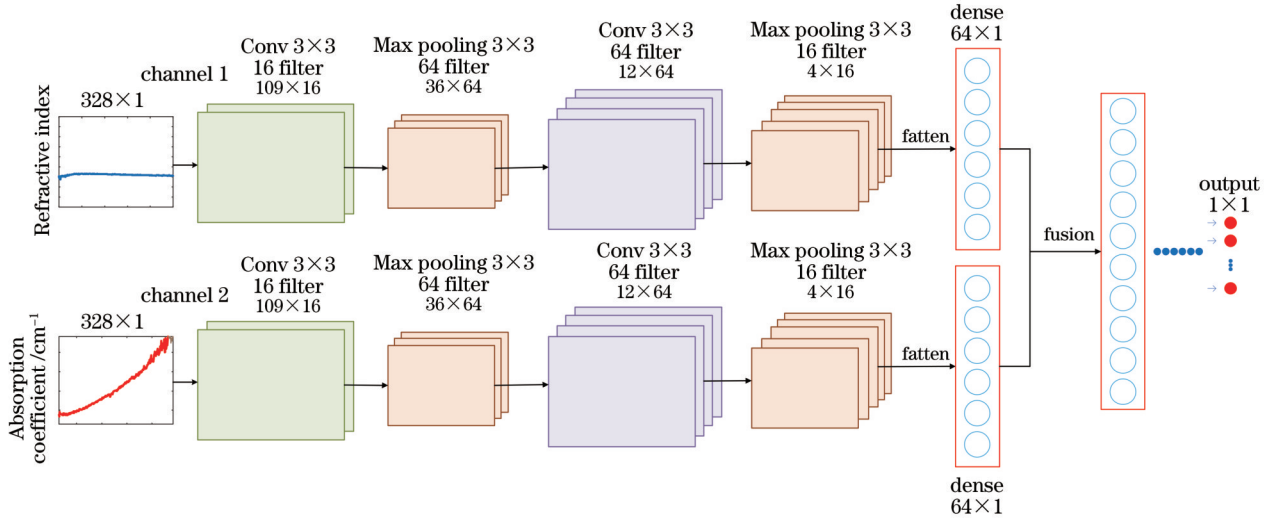


图 5 双通道卷积神经网络结构

Fig. 5 Structure of dual-channel convolutional neural network

率谱线的数据特征;  $f_2$  为煤样品吸收光谱特征。采用实验方法对  $\alpha$  的取值进行检验, 特征融合经全连接层后进行预测。

#### 4.2 模型评价方法

使用拟合度  $R^2$  和预测精度  $E_{RMS}$  来评估所提模型的表现。  $R^2$  表示模型之间的相似程度,  $E_{RMS}$  值则表示定量分析模型的准确率<sup>[16]</sup>, 计算公式为

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y})^2}, \quad (6)$$

$$E_{RMS} = \sqrt{\frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{m}}, \quad (7)$$

式中:  $m$  表示样品的个数;  $y_i$  表示参考值;  $\hat{y}_i$  表示预测值;  $\bar{y}$  表示  $m$  个样品的平均值。  $R^2$  越接近 1 和  $E_{RMS}$  越接近 0, 均可以证明预测效果越好。

### 5 结果与讨论

#### 5.1 网络参数设置及收敛性

使用深度学习框架 Keras 来建立预测模型, 并且以 Python 3.9 为软件平台。基于所构建的双通道卷积神经网络, 网络中 learning rate 设置为 0.0001, batch-size 设置为 64, epoch 设置为 200。图 6 所示为网络训练过程中的损失函数值。总体上, 损失函数值随着迭代次数的增加而逐渐递减, 未出现过拟合现象。重复多次训练, 最后使用训练误差最小的网络模型。

采用 10-折交叉验证来评估特征融合网络的准确性。在实验中, 将步长设置为 0.1, 根据式(5), 令  $\alpha = 0.4$ , 该算法的预测准确率达到最大值(图 7)。

#### 5.2 模型预测结果及分析

数据划分规则对于机器学习的模型训练非常重




图 6 模型训练过程中的损失函数值

Fig. 6 Loss function value in the process of model training




图 7 融合权重对算法精度的影响

Fig. 7 Influence of fusion weight on the accuracy of the algorithm

要, 其目的是评估模型的预测性能。为了获得更准确的预测结果, 以及确保数据划分的合理性, 将数据划分为 32 个训练集和 14 个测试集, 训练集样本数量占样本总量的比例设置为 0.7, 以确保它们具有相似的统计特征, 从而使模型的预测能力达到最佳水平。通过训练和测试, 可以建立和评估模型的预测能力。经过 5

次训练和测试,所有预测点都位于参考线附近。这表明所提模型能够准确地预测未知数据,并且模型的预测结果与实际观测数据非常接近。训练集的  $R^2$  为 98.21%,  $E_{RMS}$  为 0.1442; 预测集的  $R^2$  为 93.56%,  $E_{RMS}$  为 0.2037。预测集结果如图 8 所示。

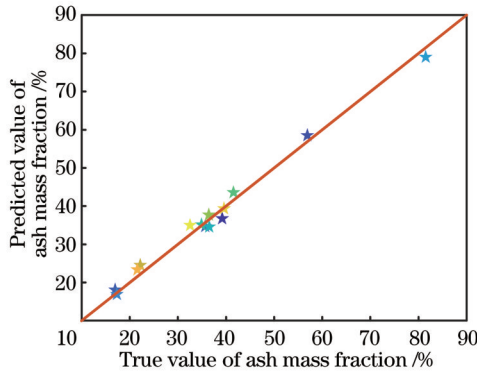


图 8 测试集预测结果

Fig. 8 Test set prediction results

### 5.3 模型比较

为了验证本文算法的预测性能,基于所采用的数据,选择传统卷积神经网络(CNN)<sup>[8]</sup>、偏最小二乘回归(PLSR)<sup>[17]</sup>、BP神经网络<sup>[18]</sup>和LSSVM<sup>[19]</sup>4种方法,对上述4种方法展开对比实验。传统CNN模型如图5通道1所示。BP神经网络选用单隐层模型进行搭建,PLSR模型采用全因子回归方式,LSSVM模型将采用线性核函数进行设置,其中BP神经网络和LSSVM模型的输入是样本的吸收系数。不同模型对灰分质量分数的预测结果如表1所示。

表1 不同模型下的灰分质量分数预测结果

Table 1 Prediction results of ash mass fraction under different models

| Model    | Training set<br>( $N_{sam}=32$ ) |           | Prediction set<br>( $N_{sam}=14$ ) |           |
|----------|----------------------------------|-----------|------------------------------------|-----------|
|          | $R^2 / \%$                       | $E_{RMS}$ | $R^2 / \%$                         | $E_{RMS}$ |
| Proposed | 98.21                            | 0.1442    | 93.56                              | 0.2037    |
| CNN      | 95.38                            | 0.1858    | 91.33                              | 0.3145    |
| PLSR     | 91.56                            | 0.2767    | 87.33                              | 0.4736    |
| BP       | 89.31                            | 0.4349    | 85.47                              | 0.5989    |
| LSSVM    | 90.78                            | 0.2734    | 86.68                              | 0.4595    |

由表1可知,对于相同样品数据的煤灰分的回归预测,所提出的双通道卷积灰分预测模型取得的效果优于传统CNN、PLSR、BP和LSSVM模型。其中:对于传统CNN模型,双通道方法可以兼顾煤样品的吸收和折射特征,从而提高特征提取的完整性和准确性;BP网络的训练模式和CNN类似,但是其真实的预测性能比理论模型要差得多,泛化性能也要差得多;PLSR和LSSVM模型的预测效果一般,这是因为这两种模型仅考虑单一的吸收光谱信息。测试结果证明,

卷积神经网络比传统预测模型更有优势。单通道和双通道卷积神经网络都能够对灰分含量进行准确预测,而且可获得更加准确的预测结果。相比之下,传统的预测方法需要更大的数据筛选工程,而卷积神经网络具有数据特征分析提取的能力。除准确性外,通过采用卷积神经网络模型,可以有效地抑制不相关数据的影响,显著提升模型的稳定性和实际泛化能力。

## 6 结 论

采用THz时域光谱技术对煤样品在0.5~3 THz频段内的光谱煤样进行THz波段的光谱分析。结果表明,随灰分含量的增多,煤样品的折射率和吸收系数呈上升趋势。考虑到0.5~3 THz频率范围内不同厚度煤样品吸收系数的差异,提出基于厚度校正的吸收系数特征提取方法,该方法能够对煤样品原始吸收光谱信号进行更好的数据分离和分散处理,从而有助于实现对不同灰分含量的准确预测。实验结果表明,与传统的CNN、PLSR、BP和LSSVM模型相比,所提出的双通道卷积神经网络回归模型在煤灰分含量预测方面具有明显的优势。相较于传统灰分含量检测方法,本文方法可以减少80%左右的时间,极大地提升了工作效率;同时可以对不同的煤种进行灰分含量检测,满足实际工作要求。根据洗煤厂的环境要求等,需要考虑整体装置结构安装,并且我国煤炭种类丰富,需要对不同种类的煤炭进行深入研究。建立一个基于THz光谱的煤样品数据库,可以实现对煤样品的分类和灰分含量预测,从而进一步提高选煤厂的智能化水平。

### 参 考 文 献

- [1] 陈浮,王思遥,于昊辰,等. 碳中和目标下煤炭变革的技术路径[J]. 煤炭学报, 2022, 47(4): 1452-1461.  
Chen F, Wang S Y, Yu H C, et al. Technological innovation paths of coal industry for achieving carbon neutralization[J]. Journal of China Coal Society, 2022, 47(4): 1452-1461.
- [2] 张守玉,徐梓航,黄东东,等. 氯化钠蒸气对高钠煤灰钠捕获性能及其烧结温度的影响[J]. 煤炭学报, 2023, 48(1): 452-459.  
Zhang S Y, Xu Z H, Huang D D, et al. Effect of sodium chloride vapor on sodium capture performance and sintering temperature of high sodium coal ash[J]. Journal of China Coal Society, 2023, 48(1): 452-459.
- [3] Howaniec N, Smoliński A. Influence of fuel blend ash components on steam co-gasification of coal and biomass-chemometric study[J]. Energy, 2014, 78: 814-825.
- [4] Chakravarty S, Mohanty A, Banerjee A, et al. Composition, mineral matter characteristics and ash fusion behavior of some Indian coals[J]. Fuel, 2015, 150: 96-101.
- [5] 赵忠辉. 基于无源的煤质在线检测技术发展与应用分析[J]. 煤炭技术, 2018, 37(1): 312-315.  
Zhao Z H. Development and application of coal quality on-line detection technology based on no radioactive source[J]. Coal Technology, 2018, 37(1): 312-315.
- [6] 程栋,温和,滕召胜,等. 基于双能 $\gamma$ 射线的煤灰分软测量技术研究[J]. 仪器仪表学报, 2014, 35(10): 2263-2270.  
Cheng D, Wen H, Teng Z S, et al. Study on soft-sensing of coal ash content based on dual-energy  $\gamma$ -ray[J]. Chinese Journal

- of Scientific Instrument, 2014, 35(10): 2263-2270.
- [7] Liang J, Lu X X, Chang T Y, et al. Deep learning aided quantitative analysis of anti-tuberculosis fixed-dose combinatorial formulation by terahertz spectroscopy[J]. Spectrochimica Acta Part A, 2022, 269: 120746.
- [8] Tanno T, Oohashi T, Katsumata I, et al. Estimation of water content in coal using terahertz spectroscopy[J]. Fuel, 2013, 105: 769-770.
- [9] 王昕, 赵端, 胡克想, 等. 烟煤的太赫兹光谱特性研究[J]. 煤炭学报, 2018, 43(4): 1146-1154.  
Wang X, Zhao D, Hu K X, et al. Terahertz spectrum characteristics of bituminous coal[J]. Journal of China Coal Society, 2018, 43(4): 1146-1154.
- [10] 贾成艳, 常天英, 樊伟, 等. 太赫兹波穿透煤层的衰减特性[J]. 煤炭学报, 2015, 40(S1): 298-302.  
Jia C Y, Chang T Y, Fan W, et al. Attenuation characteristics of terahertz wave penetrating coals[J]. Journal of China Coal Society, 2015, 40(S1): 298-302.
- [11] Zhan H L, Zhao K, Xiao L Z. Spectral characterization of the key parameters and elements in coal using terahertz spectroscopy[J]. Energy, 2015, 93: 1140-1145.
- [12] Yu J, Wang X, Ding E J, et al. A novel method of on-line coal-rock interface characterization using THz-TDs[J]. IEEE Access, 2021, 9: 25898-25910.
- [13] 郜亚松, 张步勤, 郎利影. 基于深度学习的煤矸石识别技术与实现[J]. 煤炭科学技术, 2021, 49(12): 202-208.  
Gao Y S, Zhang B Q, Lang L Y. Coal and gangue recognition technology and implementation based on deep learning[J]. Coal Science and Technology, 2021, 49(12): 202-208.
- [14] Ma K, Tang C H, Zhang W J, et al. DC-CNN: dual-channel convolutional neural networks with attention-pooling for fake news detection[J]. Applied Intelligence, 2023, 53(7): 8354-8369.
- [15] Sun Y, Liang D, Wang X G, et al. DeepID3: face recognition with very deep neural networks[EB/OL]. (2015-02-03)[2023-03-02]. <https://arxiv.org/abs/1502.00873>.
- [16] Yang W Y, Xiong Y R, Xu Z Z, et al. Piecewise preprocessing of near-infrared spectra for improving prediction ability of a PLS model[J]. Infrared Physics & Technology, 2022, 126: 104359.
- [17] 王桂芬, 张银雪, 徐文龙, 等. 基于高光谱吸收的南海浮游植物色素浓度估算[J]. 光学学报, 2021, 41(6): 0601002.  
Wang G F, Zhang Y X, Xu W L, et al. Estimation of phytoplankton pigment concentration in the South China Sea from hyperspectral absorption data[J]. Acta Optica Sinica, 2021, 41(6): 0601002.
- [18] Mao S C, Zhou J P, Hao M, et al. BP neural network to predict shelf life of channel catfish fillets based on near infrared transmittance (NIT) spectroscopy[J]. Food Packaging and Shelf Life, 2023, 35: 101025.
- [19] Adnan R M, Liang Z M, Heddam S, et al. Least square support vector machine and multivariate adaptive regression splines for streamflow prediction in mountainous basin using hydro-meteorological data as inputs[J]. Journal of Hydrology, 2020, 586: 124371.

## Terahertz Coal Ash Prediction Method Based on Dual-Channel Convolutional Neural Network

Ren Jiaojiao<sup>1,2,3\*</sup>, Jiao Tiexin<sup>1,2,3</sup>, Gu Jian<sup>1,2,3</sup>, Chen Qi<sup>3</sup>, Li Lijuan<sup>1,2,3</sup>, Zhang Jiyang<sup>3</sup>

<sup>1</sup>Key Laboratory of Photoelectric Measurement and Optical Information Transmission Technology of Ministry of Education, Changchun University of Science and Technology, Changchun 130022, Jilin, China;

<sup>2</sup>College of Optoelectronic Engineering, Changchun University of Science and Technology, Changchun 130022, Jilin, China;

<sup>3</sup>Zhongshan Institute of Changchun University of Science and Technology, Zhongshan 528400, Guangdong, China

### Abstract

**Objective** Coal plays a crucial role in China's economy and energy strategy as one of the main sources of energy and an important component of energy security. The ash content has always been a challenging issue for coal preparation plants to control product quality during the coal production process. By collecting and analyzing ash content detection data and maintaining stable ash content, the quality of coal washing products can be ensured, energy utilization can be improved, carbon emissions can be reduced, and environmental protection can be promoted. In China, rapid or slow ash methods are mainly used to detect ash content. This process takes 2-3 h, resulting in long detection cycles, low efficiency, and significant delays in obtaining detection results from coal sampling to analysis. In recent years, breakthroughs and progress have been made in online ash content detection technology. Natural  $\gamma$ -ray measurement-based online detection technology has poor adaptability to different coal types, while X-ray absorption-based online detection technology offers high measurement precision and accuracy but is inconvenient for management and safety production. Therefore, there is a demand for a fast, accurate, safe, and real-time monitoring method for coal ash content in industrial production.

**Methods** Terahertz spectroscopy is an emerging spectral technique that bridges the gap between microwave and infrared spectroscopy. It encompasses the physical, structural, and chemical information of substances within its frequency range, thus meeting the practical technological requirements of the coal industry. In this study, to address the prediction of coal ash content, 46 samples were tested using a terahertz spectrometer to extract the absorption spectrum and refractive index

spectrum of the coal samples. The absorption characteristics and refractive properties of different ash content samples in the terahertz frequency range were investigated. To eliminate the influence of sample thickness on the absorption coefficient, a method based on thickness model correction was proposed for extracting the absorption coefficient features. To improve the prediction accuracy and obtain different feature information, a dual-channel convolutional neural network was established to extract refractive index features and absorption features for coal ash prediction. This research provides the theoretical basis and technical support for intelligent detection in the coal mining industry.

**Results and Discussions** First, we obtained the refractive index and absorption coefficient of coal samples and explored the correlation law between them and the increase in coal ash content in the frequency range of 0.5–3 THz (Fig. 3). By taking into account the influence of sample thickness on the spectrum, a method based on thickness model correction for extracting the absorption coefficient features was proposed, which improved the data distinguishability of low-ash coal sample absorption curves (Fig. 4). In order to learn and predict the feature vectors of coal ash content samples, a dual-channel convolutional neural network was constructed for feature extraction, weighted fusion, and prediction of coal ash content samples (Fig. 5). The loss function of the network training process gradually decreased with the increase in iteration times, and no overfitting occurred (Fig. 6). A 10-fold cross-validation was used to evaluate the accuracy of the feature fusion network, with  $\alpha=0.4$ , and the algorithm achieved the highest prediction accuracy (Fig. 7). The fitting degree and prediction accuracy of the model training process in the training set were  $R^2=98.21\%$  and  $E_{\text{RMS}}=0.1442$ , respectively, while in the prediction set,  $R^2=93.56\%$  and  $E_{\text{RMS}}=0.2037$  (Fig. 8), outperforming traditional methods such as PLSR, BP, and LSSVM (Tab. 1).

**Conclusions** In this article, the THz time-domain spectroscopy technique was used to analyze the spectral characteristics of coal samples in the frequency range of 0.5–3 THz. The results showed that the refractive index and absorption of the coal samples increased with the increase in ash content. By considering the differences in the absorption coefficient of coal samples with different thicknesses within the frequency range of 0.5–3 THz, we proposed a method for extracting absorption coefficient features based on thickness correction, which could better separate and disperse the original absorption spectra of coal samples, thereby facilitating accurate prediction of different ash content. The experimental results demonstrated significant advantages of the proposed dual-channel convolutional neural network regression model in predicting coal ash content compared with traditional CNN, PLSR, BP, and LSSVM models. Compared with traditional ash content detection methods, this method can reduce the detection time by approximately 80% and greatly improve work efficiency. Additionally, it can be applied to ash content detection of different coal types to meet practical demands.

**Key words** spectroscopy; terahertz time-domain spectroscopy; coal ash; refractive index; absorption coefficient; convolutional neural network; prediction