

基于近红外光谱与双重门控高分辨率网络的煤种智能分类方法

陆成伟¹, 赵义杰^{1*}, 张子豪², 韩祎陟³

(1. 中国矿业大学 信息与控制工程学院, 江苏 徐州 221116; 2. 广州海关技术中心, 广东 广州 510423;
3. 呼和浩特海关技术中心, 内蒙古 呼和浩特 010020)

摘要: 针对近红外光谱在煤种分类中存在谱峰严重混叠和非线性耦合, 导致传统模型难以有效提取判别特征、分类精度受限的问题, 该文提出了一种基于双重门控高分辨率网络(DG-HRNet)的智能分类方法。该方法首先结合正则化马氏距离与标准正态变换, 对异常样本进行剔除并提升光谱数据质量; 随后以Unet为骨干网络, 引入双重门控高分辨率融合机制, 以缓解深层网络中微弱细节特征丢失的问题; 进一步结合改进的空洞空间卷积池化金字塔和压缩-激励注意力机制, 实现对光谱长距离依赖信息的有效建模与关键特征的自适应筛选。实验结果表明, DG-HRNet在煤种四分类任务中的准确率、精确率、召回率和F1分数分别达到0.961 0、0.964 7、0.958 6和0.961 4, 分类性能显著优于传统机器学习模型和主流深度学习模型。该研究为煤炭贸易和海关监管中的煤种快速、精准无损识别提供了新的技术路径。

关键词: 煤种分类; 近红外光谱; 深度学习; 高分辨率融合; 注意力机制

中图分类号: O657.3 **文献标识码:** A **文章编号:** 1004-4957(2026)09-0001-10

Intelligent Coal Classification Method Based on Near-infrared Spectroscopy and Dual-gated High-resolution Network

LU Cheng-wei¹, ZHAO Yi-jie^{1*}, ZHANG Zi-hao², HAN Yi-zhi³

(1. School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, China; 2. Technical Center of Guangzhou Customs, Guangzhou 510423, China;
3. Technical Center of Hohhot Customs, Hohhot 010020, China)

Abstract: To address the problem that severe peak overlap and nonlinear coupling in near-infrared spectra make it difficult for traditional models to effectively extract discriminative features and thus limit classification accuracy in coal classification, this study proposes an intelligent classification method based on a dual-gated high-resolution network (DG-HRNet). First, regularized Mahalanobis distance and standard normal variate transformation are combined to remove abnormal samples and improve spectral data quality. Then, Unet is employed as the backbone network, and a dual-gated high-resolution fusion mechanism is introduced to alleviate the loss of weak detailed features in deep networks. Furthermore, an improved atrous spatial pyramid pooling module and a squeeze-and-excitation attention mechanism are incorporated to enable effective modeling of long-range spectral dependencies and adaptive selection of key features. Experimental results show that, in the four-class coal classification task, DG-HRNet achieves an accuracy, precision, recall, and F1-score of 0.961 0, 0.964 7, 0.958 6, and 0.961 4, respectively, significantly outperforming traditional machine learning models and mainstream deep learning models. This study provides a new technical route for rapid, accurate, and non-destructive coal identification in coal trade and customs supervision.

Key words: coal type classification; near-infrared spectroscopy; deep learning; high-resolution fusion; attention mechanism

煤炭作为重要基础能源与工业原料, 广泛应用于电力生产^[1]、化工^[2]、钢铁冶炼及建材制造^[3]等领域, 在保障国家能源安全与维持经济社会稳定发展中发挥着压舱石的关键作用^[4-5]。随着“双碳”目标

持续推进,我国对煤炭分质利用、清洁高效利用及精细化监管的要求不断提高。与此同时,煤炭进口规模持续扩大^[6-7],煤炭流通环节呈现来源国多样、矿点复杂、混配频繁等特点,给煤种识别与监管带来了更大挑战。特别是在国家调整进口煤关税的背景下,不同煤种之间往往存在显著的关税与价格差异^[8]。因此,实现对无烟煤、炼焦煤、其他烟煤和褐煤的快速、准确分类,对于海关监管、贸易结算等具有重要的战略意义与经济价值。

目前,煤种检测主要依赖湿法化学分析方法,尽管这些传统方法结果准确,但普遍存在制样繁琐、检测周期长且成本较高等问题^[9],难以满足海关及港口对大宗煤炭贸易快速、全量监管的迫切需求。近年来,多种现代分析技术被引入检测领域,例如激光诱导击穿光谱^[10]、X射线荧光光谱^[11]和中子活化分析技术^[12]。这些技术在一定程度上提高了检测效率,但往往存在设备成本高昂、前处理复杂、安全防护要求严苛等局限,现场适应性受限。相比之下,近红外光谱技术(NIRS)凭借其快速、无损和前处理简单等优势,近年来在制药、食品^[13]、石化^[14]等领域取得了显著进展。不同煤种在分子组成和微观结构上的差异能够在近红外光谱吸收特征中得到反映,这为基于近红外光谱的煤种智能分类提供了理论基础。此外,尽管经验丰富的技术工人能通过外观特征对部分典型煤种进行初步鉴别,但此类方式因主观经验的局限性而难以形成统一、可复现的判定标准,无法满足大宗煤炭规模化、标准化的离线检测需求。特别是对于炼焦煤与其他烟煤等同属煤种,由于其外观特征极度相似且光谱信息高度耦合,仅凭人工视觉经验极易造成误判。因此,引入近红外光谱结合深度学习算法构建自动化分类模型,是突破相似煤种鉴别盲区、实现客观精准分类的必要技术手段。

近年来,研究人员尝试将支持向量机(SVM)^[15]、随机森林(RF)^[16]和极限学习机(ELM)^[17]等机器学习方法与近红外光谱技术相结合,以实现复杂光谱数据的快速建模与分类。Ding等^[18]的研究表明,结合特定的光谱预处理与优化的SVM算法,能实现黄山毛峰的快速准确分类。Wang等^[19]将RF与变量筛选方法结合,实现了裂纹种子的无损鉴别,分类准确率达到84%。在煤炭检测领域,相关探索也已逐步展开,Wang等^[20]利用近红外反射光谱结合改进的粒子群优化极限学习机,在特定煤种的分类中取得了较好的效果。Zou等^[21]则基于改进的宽度学习构建了近红外光谱分析模型,实现了煤炭与矸石的高效无损鉴别。然而,煤炭作为复杂的有机混合体系,其近红外光谱不仅具有高维、高相关的特征,而且普遍存在严重的谱峰混叠现象。对于煤种分类任务而言,类别间差异往往较小,而类内波动又受到产地、组成和结构差异等多因素影响。而传统机器学习方法本质上属于浅层模型,难以充分刻画光谱变量与煤种类别之间复杂的非线性映射关系,因此在面对相近煤种分类任务时,往往难以兼顾分类精度与模型泛化能力。

得益于较强的非线性表征能力,深度学习方法近年来在光谱分析领域得到了广泛应用^[22]。Li等^[23]利用一维卷积网络实现了脐橙产地的无损溯源(准确度97.92%);Zhou等^[24]通过轻量化模型实现了玉米种子的快速识别;Yang等^[25]则融合自注意力机制实现了西洋参产地的高精度溯源。针对煤炭这种高维复杂数据,深度学习也展现出巨大潜力。Liu等^[26]利用一维卷积神经网络结合近红外光谱技术,成功构建了多工况下的煤炭特征识别模型;Wang等^[27]引入深度残差网络,通过深层网络结构的优势有效挖掘了煤矸石的潜在光谱特征,实现了高准确率智能识别;Zou等^[28]则进一步提出了一种多输出注意力U-Net架构,实现了对煤炭多项工业分析指标的同步精准预测。尽管深度学习在上述预测与识别任务中进展显著,但在相近煤种理化性质非常接近、光谱耦合严重的复杂检测场景中,现有方法仍面临挑战。一方面,常规网络中的下采样操作容易导致浅层微弱光谱细节信息的丢失;另一方面,受限于局部感受野,模型难以充分捕获跨波段的长距离依赖关系。因此,在严重谱峰混叠背景下,如何实现高维光谱信号的有效解耦,并稳定保留煤种之间的微弱差异特征,仍是煤种智能分类面临的关键问题。

针对近红外光谱在煤种分类中存在的采样噪声干扰、谱峰严重混叠与微弱特征难以提取等关键难题,本文提出了一种基于双重门控高分辨率网络的高精度煤种智能分类方法。为改善建模数据质量,引入正则化马氏距离剔除异常样本,并结合标准正态变换(SNV)预处理策略,较好地抑制了基线漂移与散射干扰,改善了建模数据质量。在核心架构设计上,以U-Net为骨干网络,设计了双重门控高分辨率融合机制来弥合深浅层特征的语义差异,进一步缓解多次下采样带来的光谱细节信息丢失。为进一步强化网络对复杂特征的表征,模型结合了改进的空洞空间卷积池化金字塔(ASPP)与压缩-激励

(SE)通道注意力机制,增强了对跨波段长距离依赖关系的捕获能力及关键光谱特征的表征精度。基于多煤种近红外光谱数据集的系统性实验表明, DG-HRNet能够有效提取相近煤种间的微弱光谱差异,整体分类性能优于机器学习与深度学习基线模型,为煤炭的精细化、智能化检测提供了一种可行的技术支撑。

1 实验部分

1.1 煤样采集

本研究共收集514个煤炭样本,其中部分样本来源于山西等国内主要煤炭产区,另一部分样本来源于海关技术机构提供的进口煤样,涵盖无烟煤、炼焦煤、其他烟煤和褐煤等类别。所有煤样均严格按照国家标准《煤样的制备方法》(GB/T 474-2 008)进行处理,依次经过初步破碎、二级破碎、研磨和筛分等步骤,制备成粒径小于0.2 mm的粉末样本,并置于密封袋保存。实验过程中,采用VIAVI公司开发的MicroNIR Pro手持式近红外光谱仪获取光谱数据。具体采集参数设定为:扫描模式选取漫反射,扫描波长范围为908.1~1 676.2 nm,采样间隔6.2 nm,共包含125个波长点,积分时间设置为自动优化模式。为降低颗粒分布不均、环境波动及仪器噪声等因素对测量结果的影响,采集时将光谱仪探头与煤样表面保持5 mm的固定距离,并在每个样品表面选取5个不同位置进行扫描,取其平均光谱作为该样本的最终光谱数据。

鉴于原始数据集中无烟煤、炼焦煤和褐煤的样本量相对较少,存在类别不平衡问题,同时非接触式光谱测量容易受到外部环境干扰,本文针对样本量不足的煤种类别采用了基于物理采样的数据增强策略。具体而言,通过在不同外部杂散光条件下对样本进行重新装填并重复采集光谱,引入颗粒散射变化和環境光噪声,从而构建包含复杂工况特征的增强数据集。最终,光谱数据总量扩充至1 450条,各类别具体分布见表1。考虑到数据增强会使单一物理煤样衍生出多条高度相关的光谱数据,若直接采用全局随机划分方式,容易造成同源样本同时进入训练集和测试集,从而引发数据泄露并高估模型性能。为此,本文在数据集构建和五折交叉验证过程中,以每个物理煤样作为基本划分单元,将同一煤样的所有原始光谱及其增强光谱统一划分到同一数据子集中,从而保证测试集的独立性,并更客观地评估模型的泛化性能。

表1 采集的近红外光谱数据汇总

Table 1 Summary of collected near-infrared spectral data

Particle size/mm	Coal category	Number of spectra	Total spectra
0.2	无烟煤	246	1 450
	炼焦煤	160	
	其他烟煤	384	
	褐煤	660	

1.2 数据预处理

在光谱采集与数据增强过程中,受环境光波动、样本颗粒堆积状态差异等因素影响,少量样本可能偏离整体数据分布,形成异常光谱。异常样本会增加数据分布的离散性,影响模型对典型光谱特征的学习。考虑到近红外光谱具有高维且波段间相关性强的特点,本文采用基于马氏距离的统计方法对异常样本进行筛选,以提高数据质量。

具体而言,设原始光谱数据集为矩阵 $\mathbf{X}_{n \times m} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]^T$,其中 n 为样本数量, m 为每个光谱的波长特征维度。首先,计算样本集的均值向量 $\boldsymbol{\mu}$ 与协方差矩阵 $\mathbf{C}$:

$$\boldsymbol{\mu} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \quad (1)$$

$$\mathbf{C} = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^T + \lambda \mathbf{I} \quad (2)$$

式(2)中,为缓解波段相关性对协方差矩阵逆运算稳定性的影响,本文在计算时引入了微小的正则化项 $\lambda \mathbf{I}$ ($\lambda = 10^{-6}$, $\mathbf{I}$ 为单位矩阵)。

基于上述统计量,可进一步计算每个光谱样本 $\mathbf{x}_i$ 的马氏距离 $D_M(\mathbf{x}_i)$:

$$D_M(\mathbf{x}_i) = \sqrt{(\mathbf{x}_i - \boldsymbol{\mu})^T \mathbf{C}^{-1} (\mathbf{x}_i - \boldsymbol{\mu})} \quad (3)$$

为确定异常样本的判定边界, 本文首先计算了所有样本马氏距离的均值 μ_d 与标准差 σ_d :

$$\mu_d = \frac{1}{n} \sum_{i=1}^n D_M(\mathbf{x}_i) \quad (4)$$

$$\sigma_d = \sqrt{\frac{1}{n} \sum_{i=1}^n (D_M(\mathbf{x}_i) - \mu_d)^2} \quad (5)$$

在此基础上, 结合统计学中的拉依达准则, 构建异常值判定的动态阈值 T :

$$T = \mu_d + 3\sigma_d \quad (6)$$

当样本马氏距离超过阈值时, 将其判定为异常样本并予以剔除。本文采用单轮筛选策略, 以避免过度清洗对增强样本合理波动信息的破坏。

异常样本剔除后, 为减弱非接触式采集条件下样本堆积状态差异及外部光照变化引起的基线漂移和散射干扰, 进一步采用标准正态变量变换(SNV)对光谱数据进行预处理。SNV 通过对单条光谱进行中心化和标准化处理, 可有效削弱散射效应和尺度差异的影响, 提升不同样本间光谱特征的一致性, 为后续建模提供稳定的数据基础。如图 1A 所示, 受上述物理因素及煤种差异的共同影响, 原始光谱存在明显的基线漂移现象。经 SNV 预处理后, 光谱的平移误差得到有效校正(图 1B), 吸收峰特征更加凸显。预处理虽然有效提升了数据质量, 但不同煤种的光谱局部特征仍存在一定程度的重叠。为了进一步增强特征的区分度并提升对复杂样本的判别能力, 本研究引入多尺度高分辨率网络(DG-HRNet)来提取更深层的鉴别特征。




图 1 煤样近红外光谱对比图
Fig. 1 Comparison of near-infrared spectra of coal samples
A. raw spectra; B. spectra after SNV preprocessing

1.3 DG-HRnet

针对煤炭近红外光谱高维冗余、谱峰重叠严重及波段间长距离依赖等问题, 本文以 Unet 为骨干, 提出双重门控高分辨率网络(DG-HRNet)。如图 2 所示, 该模型在编码-解码结构基础上, 引入双重门控高分辨率融合模块(DG-HRFusion)、改进空洞空间卷积池化金字塔(ASPP)和 SE 通道注意力机制, 以增强多层特征融合、多尺度信息提取和关键通道筛选能力。

具体而言, 输入光谱首先经过 DoubleConv 进行浅层特征提取; 编码阶段由 4 个包含 DoubleConv 和 SE 的特征提取模块组成, 通过逐层下采样实现局部特征到深层语义特征的递进表征。为增强多尺度建模能力, 在编码器末端引入改进 ASPP 结构, 以提取光谱的全局趋势和局部变化信息。同时, 设计 DG-HRFusion 模块对编码器各层特征进行跨层融合, 并通过双重门控机制自适应筛选有效信息, 生成高分辨率融合特征。在解码阶段, 通过 4 级上采样逐步恢复特征分辨率, 并与对应的编码端特征进行融合, 再经 DoubleConv 和 SE 模块进一步提取与筛选。最终, 重构特征输入分类头, 输出无烟煤、炼焦煤、其他烟煤和褐煤的分类结果。通过多层特征协同建模, DG-HRNet 提高了复杂煤炭近红外光谱分类任务的准确性与泛化能力。

1.3.1 双重门控高分辨率融合模块 为解决传统 Unet 跳跃连接中深浅层特征直接拼接易引发的语义鸿沟与噪声冗余问题, 本文设计了双重门控高分辨率融合模块。如图 3 所示, 该模块的核心处理流程

主要由特征对齐、双重门控信息筛选与特征深度融合3个阶段衔接而成。




图2 DG-HRNet网络结构示意图

Fig. 2 Schematic diagram of DG-HRNet structure




图3 DG-HRFusion模块示意图

Fig. 3 Schematic diagram of DG-HRFusion module

具体而言，该模块首先接收来自编码器的4个不同层级的特征(F_1 至 F_4)，利用 1×1 卷积将其统一投影至相同的通道维度，再通过插值操作严格对齐空间分辨率，并在通道维度上进行拼接，生成初始的融合特征 $F_5 \in \mathbb{R}^{C_{total} \times L_{target}}$ 。

为从高维冗余的融合特征 F_5 中提炼最具判别力的关键信息，模块引入了串联的“通道-波段”双重门控机制。通道信息筛选阶段，旨在评估并重标定不同特征通道对分类任务的贡献度。首先对 F_5 分别进行全局平均池化与全局最大池化，将维度压缩为 $\mathbb{R}^{C_{total} \times 1}$ ，随后送入共享的多层感知机(Shared MLP)提取通道间的依赖关系。两路输出相加后通过Sigmoid激活函数生成通道权重，对 F_5 重新进行加权标定，得到特征 F_6 。波段信息筛选则专注于定位光谱中蕴含关键化学信息的谱峰区域并抑制局部背景噪声。模块在通道维度上对 F_6 进行平均池化与最大池化，拼接后利用卷积核大小为7的卷积捕获局部波段间的关联，最后经Sigmoid生成波段的权重，得到筛选后的特征 F_7 。

最终, 经过双重门控筛选的特征 F_7 被送入融合层。通过两组连续的卷积操作, 模块进一步深层次整合跨层级的上下文信息并平滑局部特征, 输出最终的高分辨率融合特征 F_{out} 。该机制不仅确保了多层级光谱信息的有效互补, 还显著抑制了复杂背景噪声的干扰, 为后续高精度的煤种分类提供了高质量的特征表示。

1.3.2 改进的 ASPP 为兼顾煤炭光谱中宽波段宏观基线走势与尖锐局部吸收峰的协同提取, 打破常规连续卷积局部感受野受限的瓶颈, 本文在编码器末端引入了改进的 ASPP 模块。

空洞卷积通过引入扩张率(d)参数, 可在不增加计算参数量的前提下有效扩大模型的感受野。根据空洞卷积理论, 对于尺寸为 k 的卷积核, 其等效感受野 K 的计算公式为:

$$K = k + (k - 1)(d - 1) \quad (7)$$

如图 4 所示, 以卷积核 $k=3$ 为例, 当扩张率 d 分别为 1、2、3、4 时, 其感受野分别扩展至 3、5、7、9 个光谱点。这种机制使得网络能够灵活调节窗口, 从更广阔的维度获取特征信息。

结合煤炭光谱的实际特征分布规律, 本文构建了包含 4 个并行分支的改进 ASPP 模块, 如图 5 所示。该模块包含一个 1×1 卷积分支以严格保留原始分辨率的局部特征细节; 以及 3 个卷积核大小均为 3、扩张率分别设定为 6、12 和 18 的空洞卷积分支。在具体物理含义上, 这种多尺度并行分支精准模拟了不同维度的光谱感受野, 能够分别捕获短距离、中距离与长距离的光谱上下文依赖。这种设计不仅能够有效提取表征煤种精细差异的吸收峰信息, 也能兼顾捕获反映光谱整体背景的宏观变化趋势, 从而实现对高维光谱特征从微观到宏观的全面覆盖。




图 4 不同扩张率的感受野示意图
Fig. 4 Schematic diagram of receptive fields with different dilation rates




图 5 改进的 ASPP 模块示意图
Fig. 5 Schematic diagram of Improved ASPP module

然而, 多尺度特征在通道维度直接拼接后, 往往因感受野尺度的不一致而引入大量无关的冗余信息。针对此问题, 本文在多尺度特征融合层之后级联了 SE 通道注意力模块。该模块能够自适应学习并重标定不同尺度分支的特征权重, 显著增强包含关键吸收峰的有效特征, 并有效抑制噪声特征。通过 ASPP 模块在感受野上的多尺度信息聚合, 与 SE 模块在通道深度上的精准特征筛选协同工作, 网络最终生成了兼具全局视野且有效去除了冗余背景信息的深层语义特征 F_4 , 为后续的高精度解码重建奠定了坚实基础。

1.4 评价指标

为全面评价模型在煤种四分类任务中的分类性能, 本文采用混淆矩阵直观展示各类别的预测结果

及误判情况。对于四分类任务，混淆矩阵记为 $M \in \mathbb{R}^{4 \times 4}$ 。其中，矩阵中的元素 $M_{i,j}$ 表示真实类别为 i 但被模型预测为类别 j 的煤样数量。矩阵的主对角线元素 $M_{i,i}$ 表示被正确分类的样本数，非对角线元素则反映类别间的误判情况。在此基础上，选取准确率(Accuracy)、精确率(Precision)、召回率(Recall)和 F1 分数(F1-Score)作为模型性能的评价指标。

2 结果与讨论

本文模型基于 PyTorch 深度学习框架构建。在网络训练阶段，选用 Adam 优化器进行参数迭代，全局超参数分别设置为：批量大小 32，最大迭代轮次 50，初始学习率 0.000 25。为保障模型在复杂光谱特征下的稳定收敛，本文引入了 ReduceLROnPlateau 策略，通过实时监测验证集损失动态衰减学习率。在数据集划分与模型评估方面，本文严格执行了以实体物理煤样为独立单元的分组五折交叉验证。在每轮交叉验证中，抽取 1 折数据作为完全独立的测试集(外部检验集)，剩余 4 折数据则按 7:1 的比例进一步划分为训练集(校正集)与验证集。文中的各项分类评价指标均基于测试集的预测结果，以确保评价的客观性与鲁棒性。

2.1 数据优化验证

为评估不同异常样本剔除方法的有效性，本文比较了无处理、欧氏距离和正则化马氏距离 3 种策略对分类性能的影响，结果如表 2 所示。相比无处理数据，正则化马氏距离剔除法取得了更优结果，准确率和 F1 分数分别提升至 0.878 8 和 0.897 3。相比之下，欧氏距离方法的效果相对较弱。这表明，考虑波段相关性的马氏距离更适用于近红外光谱异常样本剔除。

表2 不同异常样本剔除策略的性能比较

Table 2 Performance comparison of different outlier removal strategies

Model	Outlier removal	Accuracy	Precision	Recall	F1-Score
Unet	无	0.864 4	0.865 3	0.834 0	0.842 3
	欧氏距离	0.859 3	0.863 9	0.885 3	0.872 9
	正则化马氏距离	0.878 8	0.889 2	0.914 5	0.897 3

尽管所有样本均筛分至 0.2 mm 以下，但不同煤种在颗粒形态和堆积状态上仍存在一定差异，且叠加采集过程中的光照波动，易引起散射效应和基线漂移。为减弱上述因素的影响，本文进一步比较了归一化、一阶差分、二阶差分、Savitzky-Golay(SG)平滑和标准正态变量变换(SNV)5 种预处理方法，结果如表 3 所示：不同预处理方法均在一定程度上改善了模型性能，其中 SNV 效果最佳。经 SNV 预处理后，模型准确率由 0.878 8 提升至 0.940 1，F1 分数达到 0.937 9。说明 SNV 能够较有效削弱散射干扰和基线漂移对光谱特征表达的影响，提升煤种分类性能。

表3 不同光谱预处理方法对模型性能的影响

Table 3 Impact of different spectral preprocessing methods on model performance

Model	Preprocessing	Accuracy	Precision	Recall	F1-Score
Unet	无	0.878 8	0.889 2	0.914 5	0.897 3
	归一化	0.902 5	0.917 0	0.902 5	0.906 8
	一阶差分	0.915 0	0.913 7	0.925 0	0.918 7
	二阶差分	0.909 5	0.892 8	0.904 7	0.898 4
	SG	0.891 4	0.906 3	0.890 8	0.896 8
	SNV	0.940 1	0.945 3	0.932 8	0.937 9

2.2 机器学习模型性能对比

为验证 DG-HRNet 在煤种高维光谱分类任务中的有效性，本文将其与支持向量机(SVM)、随机森林(RF)、线性判别分析(LDA)、轻量级梯度提升机(LightGBM)和逻辑回归(LR)5 种传统机器学习模型进行了对比。所有模型均基于前文确定的最优预处理流程进行训练与测试，结果如表 4 所示：DG-HRNet 在各项评价指标上均取得了最佳结果，其中准确率达到 0.961 0，较表现最优的传统模型 LDA (0.894 1)提升约 7.5%；F1 分数则由 0.903 8 提升至 0.961 4，提升约 6.4%。结果表明，传统机器学习方法在处理煤炭近红外光谱中复杂非线性特征及类别间微弱差异时仍存在一定局限，而 DG-HRNet 能够更有效地挖掘光谱中的判别信息，从而获得更优的分类性能。

表4 传统机器学习模型与DG-HRNet性能对比

Table 4 Performance comparison between traditional machine learning models and DG-HRNet

Model	Accuracy	Precision	Recall	F1-Score
SVM	0.878 0	0.914 7	0.872 8	0.890 3
RF	0.883 6	0.917 3	0.877 2	0.894 3
LDA	0.894 1	0.908 1	0.905 3	0.903 8
Lightgbm	0.884 3	0.920 5	0.874 5	0.893 2
LR	0.850 2	0.886 0	0.854 2	0.868 3
DG-HRNet	0.961 0	0.964 7	0.958 6	0.961 4

2.3 深度学习模型性能对比

为进一步评估DG-HRNet在煤种复杂光谱分类任务中的性能, 本文将其与Unet、Unet++、Unet3+、DenseNet及MobileNet系列等7种典型深度学习模型进行了对比, 结果如表5所示: DG-HRNet在各项评价指标上均取得了最佳结果, 准确率、精确率、召回率和F1分数分别达到0.961 0、0.964 7、0.958 6和0.961 4。相比基础Unet, 准确率由0.940 1提升至0.961 0, 提升约2.22%。同时, DG-HRNet整体优于Unet++、Unet3+、DenseNet及MobileNet系列模型, 表明其在煤炭近红外光谱高维、强相关特征建模方面具有更好的适应性。

表5 深度学习模型与DG-HRNet性能对比

Table 5 Performance comparison of deep learning models and DG-HRNet

Model	Accuracy	Precision	Recall	F1-Score
Unet	0.940 1	0.945 3	0.935 3	0.937 9
Unet++	0.937 3	0.943 4	0.938 8	0.935 8
Unet3+	0.915 0	0.931 8	0.872 7	0.885 6
DenseNet	0.919 2	0.920 8	0.930 1	0.924 2
MobileNetv1	0.935 2	0.940 9	0.945 8	0.941 7
MobileNetv2	0.934 5	0.942 2	0.934 3	0.937 1
MobileNetv3	0.930 3	0.940 0	0.922 9	0.930 7
DG-HRNet	0.961 0	0.964 7	0.958 6	0.961 4

其中, Unet取得了较好的分类效果, 说明编码-解码结构对光谱特征提取具有一定优势; 而Unet++和Unet3+未表现出进一步提升, 说明在本任务中, 更复杂的跨层连接结构未必能够带来更优结果。MobileNet系列虽具有较好的轻量化特性, 但分类性能略低于DG-HRNet。综合来看, DG-HRNet通过双重门控高分辨率融合、多尺度特征提取和通道重标定, 能够更有效地挖掘煤种间的判别信息, 从而获得更优的分类性能。

2.4 消融实验

为验证DG-HRNet中各关键模块的作用, 本文以Unet为基线模型进行了消融实验, 结果如表6所示。在基线模型基础上分别引入DG-HRFusion、改进ASPP和SE模块后, 模型性能均有不同程度提升, 说明各模块对煤炭近红外光谱分类均具有积极作用。其中, 单独加入DG-HRFusion、改进ASPP和SE后, 准确率分别提升至0.951 3、0.944 3和0.948 5, 表明高分辨率特征融合、多尺度特征提取和通道重标定均有助于增强模型的判别能力。

表6 DG-HRNet关键模块消融实验结果

Table 6 Ablation experiment results of key modules of DG-HRNet

Model	Accuracy	Precision	Recall	F1-Score
Unet	0.940 1	0.945 3	0.935 3	0.937 9
DG-HRFusion	0.951 3	0.957 9	0.944 3	0.950 7
改进的ASPP	0.944 3	0.955 4	0.944 4	0.949 2
SE	0.948 5	0.952 3	0.949 1	0.950 4
DG-HRFusion+改进的ASPP	0.954 0	0.953 8	0.952 0	0.951 5
DG-HRFusion+SE	0.958 2	0.962 2	0.958 0	0.959 9
改进的ASPP+SE	0.952 6	0.954 9	0.946 2	0.949 7
DG-HRNet	0.961 0	0.964 7	0.958 6	0.961 4

进一步地, 不同模块组合后模型性能继续提升, 其中DG-HRFusion与SE联合时效果较优, 准确率达到0.958 2。综合3种模块后, DG-HRNet取得最佳结果, 准确率、精确率、召回率和F1分数分别

达到 0.961 0、0.964 7、0.958 6 和 0.961 4。相比基线 Unet, 准确率提升了 2.22%, 说明所提出的各模块具有良好的互补性, 能够共同提升模型对复杂煤炭光谱特征的代表能力。

2.5 可视化分析

为进一步分析 DG-HRNet 的分类效果, 本文从混淆矩阵和特征空间分布两个方面进行了可视化展示。图 6 给出了基于五折交叉验证结果汇总得到的混淆矩阵 ($N=1\,435$)。可以看出, 模型对无烟煤实现了准确识别; 对炼焦煤、其他烟煤和褐煤等特征相近类别也保持了较好的区分能力。其中, 炼焦煤与其他烟煤之间的错分样本分别为 15 个和 4 个, 其他烟煤与褐煤之间的错分样本分别为 17 个和 19 个, 说明 DG-HRNet 能够较好地提取不同煤种间的判别特征, 整体误判较少。

为进一步验证特征提取效果, 本文采用 t-SNE 对原始光谱、SNV 预处理后光谱及 DG-HRNet 提取特征进行可视化分析, 如图 7 所示。结果表明, 原始光谱分布较为混杂, 经 SNV 预处理后类别分离程度有所提升, 但仍存在一定重叠; 而 DG-HRNet 提取的深层特征具有更好的类内聚集性和类间分离性, 说明该模型能够有效增强煤种间的判别特征表达。




图 6 五折交叉验证的混淆矩阵

Fig. 6 Confusion matrix of five-fold cross-validation




图 7 原始光谱、预处理光谱与 DG-HRNet 深层特征的 t-SNE 可视化

Fig. 7 t-SNE visualization of raw spectra, preprocessed spectra, and deep features of DG-HRNet

3 结论

针对煤炭近红外光谱分类中存在的谱峰严重混叠、类别间差异细微、判别特征难以提取等问题, 本文提出了一种基于双重门控高分辨率网络的煤种智能分类方法 DG-HRNet。该方法首先采用正则化马氏距离进行异常样本剔除, 并结合标准正态变量变换对光谱进行预处理, 以提升数据质量并减弱散射干扰和基线漂移的影响; 在此基础上, 以 Unet 为骨干网络, 引入双重门控高分辨率融合模块、改进 ASPP 模块和 SE 注意力机制, 实现多层特征融合、多尺度信息提取及关键通道增强, 从而提高复杂光谱条件下的判别特征表征能力。实验结果表明, DG-HRNet 在煤种四分类任务中取得了较优性能, 准确率和 F1 分数分别达到 0.961 0 和 0.961 4, 整体优于传统机器学习方法及对比深度学习模型。消融实验和特征可视化结果进一步表明, 所引入的各模块能够有效增强模型对煤炭光谱特征的提取与表征能力。综上, 本方法在煤炭近红外光谱分类任务中表现出较好的准确性与稳定性, 可为煤炭快速识别与智能检测提供参考。后续工作将进一步扩大样本规模与煤种覆盖范围, 结合更多实际工况下的光谱数据开展模型验证, 并围绕模型轻量化、跨仪器适应性及现场在线应用能力开展深入研究。

参考文献:

- [1] Vardar S, Demirel B, Onay T T. *Environ. Sci. Pollut. Res.*, **2022**, 29(27): 40302–40318.
- [2] Midilli A, Kucuk H, Topal M E, Akbulut U, Dincer I. *Int. J. Hydrogen Energy*, **2021**, 46(50): 25385–25412.
- [3] Rafieizonooz M, Khankhaje E, Rezaei S. *J. Build. Eng.*, **2022**, 49: 104040.
- [4] Zhou H X, Bhattarai R, Li Y K, Si B C, Dong X X, Wang T F, Yao Z T. *Sci. Total Environ.*, **2022**, 804: 149985.

- [5] Gou W, Zhang X K. *Distrib. Energy*(苟伟, 张勋奎. 分布式能源), **2025**, 10(5): 1–9.
- [6] National Bureau of Statistics of China. Statistical Communique of the People's Republic of China on the 2025 National Economic and Social Development(国家统计局. 中华人民共和国 2025 年国民经济和社会发展统计公报). [2026–04–09]. https://www.stats.gov.cn/sj/zxfbhjd/202602/t20260228_1962662.html.
- [7] Sun C K, Cao Q. *Fuel Chem. Processes*(孙春凯, 曹强. 燃料与化工), **2025**, 56(3): 1–5, 10.
- [8] Lü H W, Qiu M D, Chen P. *Inf. Syst. Eng.*(吕汉闻, 仇明达, 陈鹏. 信息系统工程), **2025**, (10): 73–75.
- [9] Wang H L, Guo X, Zhang Y F, Zhang J S. *Coal Sci. Technol.*(王洪磊, 郭鑫, 张亦凡, 张俊升. 煤炭科学技术), **2024**, 52(2): 219–237.
- [10] Du H, Ke S, Zhang W, Qi D F, Sun T F. *Anal. Sci.*, **2024**, 40(9): 1709–1722.
- [11] Tian Q, Ouyang Z, Qu Q, Guan S. *Metall. Anal.*(田琼, 欧阳政, 曲强, 管嵩. 冶金分析), **2024**, 44(10): 64–71.
- [12] Roy T, Shukla S, Kashyap Y, More M R, Shukla M, Singh P. *Radiat. Phys. Chem.*, **2024**, 222: 111830.
- [13] Ozturk S, Bowler A, Rady A, Watson N J. *J. Food Eng.*, **2023**, 341: 111339.
- [14] Xu Y P, Liu D, Chen P, Li J Y, Chu X L. *J. Instrum. Anal.*(许育鹏, 刘丹, 陈瀑, 李敬岩, 褚小立. 分析测试学报), **2025**, 44(10): 2026–2033.
- [15] Vasconcelos L, Dias L G, Leite A, Ferreira I, Pereira E, Silva S, Rodrigues S, Teixeira A. *Foods*, **2023**, 12(3): 470.
- [16] Ye W X, Yan T Y, Zhang C, Duan L, Chen W, Song H, Zhang Y F, Xu W, Gao P. *Foods*, **2022**, 11(11): 1609.
- [17] Bian X H, Li S J, Fan M R, Guo Y G, Chang N, Wang J J. *Anal. Methods*, **2016**, 8(23): 4674–4679.
- [18] Ding Y H, Yan Y L, Li J, Chen X, Jiang H. *Foods*, **2022**, 11(11): 1658.
- [19] Wang L S, Huang Z L, Wang R J. *Infrared Phys. Technol.*, **2021**, 115: 103731.
- [20] Wang Y Y, Li B Y, Li H Y, Xiao D. *ACS Omega*, **2024**, 9: 47756–47764.
- [21] Zou L, Yu X, Li M, Lei M, Yu H. *IEEE Trans. Instrum. Meas.*, **2020**, 69(10): 8043–8052.
- [22] Li S T, Liao F, Wu J Z, Zhang J, Xu M Y, Ding W, Li Y S, Li S B, He W M, Wang H, Bi Y M. *J. Instrum. Anal.*(李石头, 廖付, 吴继忠, 张军, 徐梦瑶, 丁伟, 李永生, 李淑彪, 何文苗, 王辉, 毕一鸣. 分析测试学报), **2025**, 44(3): 514–520.
- [23] Li Y, Ren Z, Zhao C Y, Liang G Q. *Foods*, **2025**, 14(3): 484.
- [24] Zhou H C, Guan H O, Ma X D, Wei B X, Zhang Y F, Lu Y X. *Microchem. J.*, **2024**, 206: 111542.
- [25] Yang Y, Wang S Q, Zhu Q B, Qin Y, Zhai D D, Lian F Y. *J. Food Compos. Anal.*, **2024**, 136: 106736.
- [26] Liu T, Li J L, Xia R, Wang X W, Li B. *Int. J. Coal Prep. Util.*, **2024**, 44(8): 1017–1038.
- [27] Wang Y D, Jia J W, Tan W J, Lei M. *J. Instrum. Anal.*(王亚栋, 贾俊伟, 谭韦君, 雷萌. 分析测试学报), **2024**, 43(4): 607–613.
- [28] Zou L, Qiao J H, Yu X H, Chen X, Lei M. *IEEE Trans. Artif. Intell.*, **2024**, 5(3): 1398–1410.

(责任编辑: 盛文彦)