

基于深度学习的LAMOST恒星形成星系气体金属丰度估算*

冯佳宝^{1,2} 王丽丽^{2†} 李萍^{1,2}

(1 吉林化工大学信息与控制工程学院 吉林 132022)

(2 德州学院计算机与信息学院 德州 253023)

摘要 气体金属丰度是衡量恒星形成星系化学演化程度的重要物理量, 其估算对于深入理解星系的形成与演化过程至关重要. 传统测量气体金属丰度方法依赖特定发射线的强度比, 数据处理复杂, 难以适应大规模巡天数据的自动化需求. 为此, 提出一种基于卷积神经网络(Convolutional Neural Network, CNN)的深度学习模型, 以LAMOST (Large Sky Area Multi-Object Fiber Spectroscopic Telescope)观测的全谱为输入, 在无需退红移和谱线测量的前提下, 实现恒星形成星系气体金属丰度的自动估算. 该模型由8个一维卷积层、4个最大池化层和1个全连接层构成, 通过回归方式学习光谱与金属丰度之间的非线性映射关系. 实验结果表明, 与传统方法基本一致, 误差为0.0829 dex. 此外, CNN模型在不同信噪比和红移范围内均表现出良好的稳健性, 并且模型预测的金属丰度建立的质量-金属丰度关系(Mass-Metallicity Relation, MZR)与经验MZR基本一致. 最后, 将训练好的模型应用于LAMOST第10次数据发布(Data Release 10, DR10)低分辨率巡天(Low-Resolution Survey, LRS), 构建了一份包含约20000个恒星形成星系的气体金属丰度星表. 该星表可通过中国科学院科学数据银行(<https://www.scidb.cn/s/UVBRzm>)获取.

关键词 星系; 气体金属丰度, 方法: 数据分析, 方法: 统计, 方法: 深度学习

中图分类号: P157; **文献标识码**: A

1 引言

恒星形成星系是宇宙中最活跃的星系类型之一, 其形成与演化过程与恒星形成活动及气体物理特性密切相关^[1]. 气体金属丰度作为衡量星系内部气体中金属元素含量的关键参数, 不仅影响恒星形成率、气体冷却过程等物理机制, 还能反映星系的化学演化历程^[2]. 因此, 精确测定恒星形成星系的气体金属丰度对理解星系化学演化具有重要意义.

气体金属丰度通常以氧丰度表示, 较高的金属丰度通常意味着星系经历了多次恒星形成和超新星爆炸, 从而富集了更多重元素^[3]. 传统上, 气体金属丰度的估算方法主要包括直接法(即电子温度法, 记作 T_e -method)^[4-6]和强线法(strong-line method)^[7-10]. 直接法通过测量特定发射线(如 $[\text{OIII}]\lambda 4363$ 、 $[\text{NII}]\lambda 5755$ 和 $[\text{SII}]\lambda 6312$, 其中 $[\]$ 表示禁线, λ 表示波长)的强度比值来计算电子温度, 进而推导气体金属丰度. 强线法则基于强发射线建立经验关系来估算金属丰度(例如, R23 ^[7]、 O3N2 ^[8]、

2025-04-03收到原稿, 2025-06-04收到修改稿

*国家自然科学基金项目(12273075、11903008、U1931106)资助

†jsjxwll@126.com

N2O2^[11]和N2^[12]). 不同方法的适用范围各异, Pagel等^[7]提出的R23方法适用于低至中等金属丰度的估算; Alloin等^[8]提出的O3N2和N2方法更适用于中等金属丰度测定; 而Kewley等^[11]提出的N2O2方法在高金属丰度下表现更稳定. 此外, Tremonti等^[13]采用贝叶斯光谱拟合方法, 对53000个SDSS (Sloan Digital Sky Survey)星系光谱进行分析, 利用Charlot和Longhetti于2001年提出的模型^[14], 该模型结合了星族合成和光电离计算, 通过拟合多条强发射线来估算气体金属丰度, 并建立了质量-金属丰度关系.

然而, 随着天文观测数据的迅速增长, 传统方法在处理大规模数据集时面临计算复杂度高的问题. 在此背景下, 机器学习和深度学习技术因其高效处理海量数据和自动提取复杂特征的优势, 在天文研究领域得到广泛应用. Hoyle等^[15]训练机器学习模型对SDSS星系光谱进行红移估计, 提高了精度和鲁棒性. Wang等^[16]采用卷积神经网络(Convolutional Neural Network, CNN)对SDSS低红移的星系光谱进行训练, 以预测星系的年龄、金属丰度、消光和速度弥散. 在气体金属丰度估算方面, Ho等^[17]训练了一种基于多层感知机(Multilayer Perceptron, MLP)的模型, 利用950个HII区的发射线强度比值精准预测氧丰度, 并重建金属丰度梯度. Teimoorinia等^[18]提出了一种基于随机森林回归模型的方法, 利用SDSS光谱数据中的强发射线特征, 重新评估了不同强发射线金属丰度标定方法之间的转换关系. 这些方法依赖于单独测量特定发射线的强度, 并通过经验关系或机器学习模型建立金属丰度与发射线之间的映射. 这些研究表明, 机器学习和深度学习技术在预测红移、金属丰度以及星族参数等多个天文领域的任务中展现出了强大的能力.

大天区多目标光纤光谱天文望远镜(Large Sky Area Multi-Object Fiber Spectroscopic Telescope, LAMOST)是我国自主研制的大视场、多目标光谱巡天设备, 具备高效率的大规模光谱获取能力, 自2011年开始运行以来, 已经积累了海量的光谱数据^[19-20]. 其第10次数据发布(Data Release 10, DR10)于2024年正式向国际天文界开

放, 包括低分辨率(Low-Resolution Survey, LRS)和中分辨率(Medium-Resolution Survey, MRS)两类光谱数据. LRS数据包含11441011条光谱, 其中包括261381条星系光谱, 覆盖3700–9000 Å, 分辨率约为1800. 本研究提出了一种基于卷积神经网络的方法, 对LAMOST DR10 LRS的恒星形成星系计算气体金属丰度. 相较于传统方法, 该方法直接以全谱作为输入, 无需进行退红移处理, 并避免了单独计算特定发射线强度, 从而降低了数据预处理过程中的不确定性.

2 数据

本研究使用了LAMOST DR10观测的261381条星系光谱, 并使用以下标准进行了筛选. 为确保关键的发射线(如H β 、[OIII]、[NII]和H α)处于观测范围内, 限制红移范围为 $0.002 \leq z \leq 0.3$ 的星系. 同时, 为了保证数据质量, 要求r波段信噪比(S/N_r)不低于3, 筛选出242500条符合标准的星系光谱.

马克斯·普朗克天体物理研究所-约翰斯·霍普金斯大学(Max Planck Institute for Astrophysics-Johns Hopkins University, MPA-JHU)基于SDSS提供了星系的气体金属丰度等关键参数, 我们选择其中的中位气体金属丰度(oh_p50)^[13]作为回归模型的目标变量. 为了获取回归模型的标签, 我们按照赤经(ra)和赤纬(dec)对LAMOST与SDSS MPA-JHU DR8星表进行交叉匹配, 匹配半径设为1". 在242500条LAMOST星系光谱中, 共有约151000条(占比62.28%)成功匹配到MPA-JHU目录, 而剩余约91400条(占比37.72%)未能找到对应的参数信息. 在匹配成功的数据中, 进一步筛选出恒星形成星系(bptclass=1), 并剔除异常值(oh_p50 = -9999), 最终获得约38500条具有金属丰度的LAMOST恒星形成星系光谱. 图1显示了所选数据的红移、r波段信噪比(S/N_r)以及r波段Petrosian星等(petroMag_r)的分布情况. 可以看出, 红移主要集中在[0.02, 0.15]之间, S/N_r主要分布在[3, 30]之间, 而petroMag_r主要介于[16, 18]之间.

在模型训练前, 对所选数据进行预处理. 首先

通过线性插值将所有光谱统一到3800 Å至8000 Å的波长范围, 插值步长设为1 Å, 从而保证每条光谱都具有4201个数据点. 随后使用最小-最大归一

化方法对光谱流量标准化至[0, 1]区间, 以确保模型输入数据之间的可比性, 为后续的模型训练提供了可靠的数据基础.




图 1 数据集中红移、r波段信噪比(S/N_r)及r波段Petrosian星等(petroMag_r)的分布

Fig. 1 Distributions of redshift, signal-to-noise ratio in the r-band (S/N_r), and Petrosian magnitude in the r-band (petroMag_r) in the dataset

3 方法

本章介绍用于预测气体金属丰度的CNN模型的设计与训练. 该模型旨在自动提取光谱数据中的深度特征, 并通过回归映射这些特征至目标变量.

3.1 网络架构

本研究构建的CNN模型架构如图2所示, 包括输入层、多个卷积与池化层以及最终的输出层. 整个网络通过层级特征提取机制, 实现从原始光谱到金属丰度的非线性映射. 具体描述如下:

1. **输入层:** 模型的输入为预处理后的光谱数据, 每条光谱包含4201个数据点. 标签数据为其对应的气体金属丰度(oh_p50).

2. **网络层:** 由于光谱数据为一维数据, 我们采用一维卷积层(Conv1D)和最大池化层(Max-Pooling1D). CNN模型由8个卷积层、4个最大池化层、1个展平层(Flatten)以及1个全连接层组成. 图2显示了网络结构, 其中每个卷积层标记为Conv1Dxx, xx表示该层的通道数. 以池化层作为分界, CNN模型可划分为4个模块, 每个模块内的卷积层通道数相同, 并依次增大为16、32、64和128, 以便在网络加深的过程中提取更复杂的特征. 所有卷积层的卷积核大小均设为3, 步长为1; 最大池化层的池化窗口大小为3, 步长为3. 各层的输出

尺寸以 $d \times 1$ 形式表示.

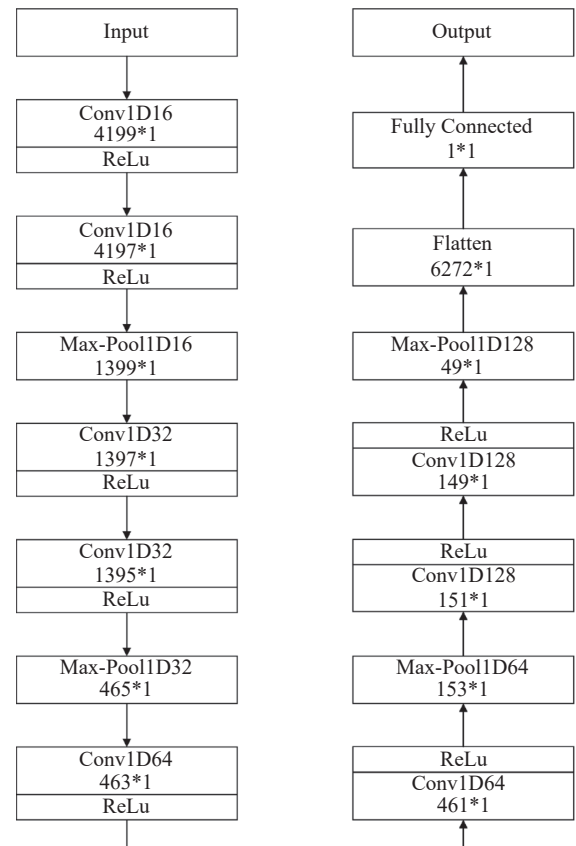


图 2 卷积神经网络结构图

Fig. 2 Architecture of the convolutional neural network

3. **激活函数:** 所有卷积层均使用修正线性单元(Rectified Linear Unit, ReLU)作为激活函数, 以引入非线性, 提高模型对复杂关系的拟合能力.

4. **输出层:** 经过展平操作后, 数据输入到全连接层, 最终输出预测的气体金属丰度.

5. **损失函数:** 采用均方误差(Mean Squared Error, MSE)作为损失函数, 用于计算预测值(Z_{pred})与真实值(Z_{true})之间的平均平方误差. 训练过程中的目标是 minimized 损失函数, 以提升预测精度. MSE计算公式如下:

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (Z_{\text{pred},i} - Z_{\text{true},i})^2, \quad (1)$$

其中, N 表示样本数量; $Z_{\text{pred},i}$ 为第 i 个样本的预测值; $Z_{\text{true},i}$ 是第 i 个样本的真实值.

6. **优化器与学习率调度:** 采用Adam优化器, 该方法结合了自适应学习率与动量机制, 可有效提升模型的收敛速度与稳定性. 初始学习率设为0.001, 并使用ReduceLROnPlateau¹学习率调度器. 当验证集损失在连续10个训练周期内无改善时, 学习率自动降低10倍, 以提高模型的稳定性并增强全局最优搜索能力.

3.2 网络训练

为了训练和评估模型, 我们将约38500个样本按照7:1:2的比例划分为训练集、验证集和测试集. 训练集用于优化模型参数, 使预测值与真实值尽可能接近; 验证集用于实时评估模型性能并调整超参数; 测试集用于最终评估模型的泛化能力. 图3展示了训练集、验证集和测试集中真实金属丰度的分布情况, 三者的分布较为一致, 为模型训练与评估提供了可靠的基础.

在训练过程中, 每批次(batch)输入128条光谱数据及其对应标签. 模型采用反向传播算法(backpropagation)更新参数, 以最小化损失函数. 训练共进行100轮(epoch), 通过监测验证集损失选择最优模型, 并保存最优模型用于最终测试.

4 模型评估

本章评估所构建的CNN模型在测试集上的预

测性能. 具体评估内容包括以下几个方面: 第4.1节分析CNN模型的 Z_{pred} 与 Z_{true} 之间的差异; 第4.2节比较CNN与常用模型(随机森林与多层感知机)的预测性能; 第4.3节和第4.4节分别分析信噪比和红移对模型性能的影响; 第4.5节探讨模型对质量-金属丰度关系的再现能力.

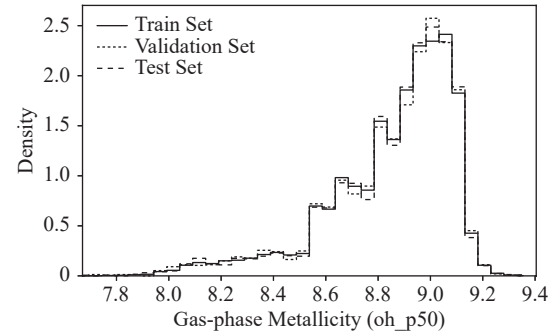


图3 训练集、验证集和测试集中气体金属丰度的真实值分布

Fig. 3 Distribution of true values of gas-phase metallicity for training, validation, and test sets

4.1 CNN模型预测结果分析

本节分析CNN模型预测的气体金属丰度与真实值之间的差异. 图4直观展示了CNN模型的预测值与真实值的对比情况. 图中, 红色中位线与黑色的1:1理想线基本吻合, 测试集上的均值(μ) -0.0002 和标准差(σ) 0.0829 表明模型整体预测精度较高. 值得注意的是, 在低金属丰度(< 8.5)和高金属丰度(> 9.2)的区间, 预测误差相对较大, 可能是由于这些区间内的样本数量较少(见图3所示). 总体而言, CNN模型在气体金属丰度的回归任务中表现出较高的准确性和稳定性.

4.2 不同模型性能对比

本节将CNN模型的预测性能与两种经典模型—随机森林回归(Random Forest, RF)和多层感知机(MLP)进行对比.

RF是一种集成学习方法, 通过构建多个决策树并对其预测结果进行平均, 以提高鲁棒性并减少过拟合. 每棵树在一个随机子集上训练, 最终预测结果由所有树的输出平均得到. 本研究中, RF

¹<https://pytorch.org/docs/stable/generated/torch.optim.lr.scheduler.ReduceLROnPlateau.html>

模型包含100棵决策树($n_{tree}=100$), 在计算效率与预测性能之间取得平衡. MLP是一种前馈人工神经网络, 由输入层、多个隐藏层和输出层组成. 每个神经元均与下一层所有神经元完全连接, 从而能够学习复杂的非线性关系. 本研究中, MLP结构包括输入层、输出层和3层隐藏层, 每个隐藏层包含1024个神经元, 以提取光谱的特征.




图 4 CNN模型预测的气体金属丰度与真实值的对比

Fig. 4 Comparison of the predicted gas-phase metallicity values using our CNN model with the true values

我们对CNN、RF和MLP模型在相同的数据集上进行了训练, 并在测试集上评估其性能. 表1总结了3种模型的关键指标. 可以看出CNN模型的均值($\mu = -0.0002$)和标准差($\sigma = 0.0829$)均为最小, 表明CNN相较于其他两个模型具有较大的优势.

表 1 CNN、RF和MLP模型的性能对比

Table 1 Comparison of the performance of CNN, RF, and MLP models

Model	Mean (μ)	Standard Deviation (σ)
CNN	-0.0002	0.0829
RF	-0.0053	0.1824
MLP	0.0099	0.1758

4.3 不同信噪比下的模型评估

信噪比对CNN模型的预测精度可能会存在影响. 为了分析模型在不同信噪比下的表现, 我们按照r波段信噪比(S/N_r)将数据划分为不同区间: [3, 5)、[5, 7)、[7, 10)、[10, 15)、[15, 25)和[25, $+\infty$), 并计算各区间内 $Z_{pred} - Z_{true}$ 的标准差(见图5 (a)). 结果表明, 当 S/N_r 低于5时, 预测误差最大, 标准差接近0.11 dex. 随着 S/N_r 增加, 预测误差逐渐减小, 并在 $S/N_r \geq 25$ 时降至约0.05 dex. 结果表明, 随着输入数据质量的提升, CNN模型的预测准确度相应提高.




图 5 不同信噪比(a)和红移(b)区间下的模型预测误差

Fig. 5 Model performance across different intervals: signal-to-noise ratio (a) and redshift (b)

4.4 不同红移下的模型评估

红移是天文观测中的重要参数. 由于我们的数据并没有退红移, 因此模型的泛化能力可能受红移影响. 为探讨该影响, 我们将数据按红移划分为不同区间: $[0.0, 0.03)$ 、 $[0.03, 0.05)$ 、 $[0.05, 0.07)$ 、 $[0.07, 0.10)$ 、 $[0.10, 0.15)$ 和 $[0.15, 0.30)$, 并计算各区间内的预测误差(见图5 (b)). 结果显示, 在红移范围 $[0.05, 0.15]$ 内, 预测误差保持较低且稳定(约0.07 dex), 但在高红移和低红移端, 误差均有所增加, 最高达0.1 dex. 这可能有两个原因: 第一, 在红移 < 0.02 时, $[OII]$ 发射线不在我们采样的波长范围, 而在红移 > 0.21 时, $H\alpha$ 和 $[NII]$ 发射线也会超出采样范围; 第二, 样本量有限, 例如红移 > 0.15 的样本仅占6.12%, 导致预测不确定性增加.

4.5 基于CNN模型预测的质量-金属丰度关系

质量-金属丰度关系 (Mass-Metallicity Relation, MZR) 作为星系化学演化的关键诊断工具, 其准确测定对理解星系形成历史具有重要意义. 本研究利用CNN模型预测的气体金属丰度值, 结合MPA-JHU星表中的恒星质量数据来分析这一关系, 并与Tremonti等^[13]的经典研究进行了对比. 工作中Tremonti提出的MZR关系:

$$12 + \lg(O/H) = -1.492 + 1.847 \times \lg(M_*/M_\odot) - 0.08026 \times [\lg(M_*/M_\odot)]^2, \quad (2)$$

其中, $12 + \lg(O/H)$ 表示气体金属丰度, 而 $\lg(M_*/M_\odot)$ 是恒星质量 M_* 相对于太阳质量 M_\odot 的对数值. MZR关系适用的恒星质量范围为 $8.5 < \lg(M_*/M_\odot) < 11.5$, 为本研究提供了重要参照基准.

在本研究中, 我们使用测试集数据来分析这一关系, 气体金属丰度由CNN模型预测, 恒星质量数据来自MPA-JHU星表中的 $\lg m_fib_p50$ 值. 我们对测试集限制恒星质量范围在 $8.5 < \lg(M_*/M_\odot) < 11.5$ 之间, 绘制了 Z_{pred} 与 $\lg(M_*/M_\odot)$ 之间的关系, 如图6所示. 红色实线表示拟合得到的关系, 如公式(3)所示:

$$12 + \lg(O/H) = -1.412 + 1.986 \times \lg(M_*/M_\odot) - 0.094 \times [\lg(M_*/M_\odot)]^2. \quad (3)$$

在图6中, 红线表示CNN预测的气体金属丰度

的中位数, 而红虚线表示 $\pm 1\sigma$ 的离散程度, 大约为 ± 0.1 dex. 黑线和虚线表示Tremonti等^[13]提出的中位数经验MZR及其 $\pm 1\sigma$ 范围. 结果表明, CNN预测的MZR在大部分范围内与经验MZR一致. 这进一步验证了我们模型的准确性和可靠性.




图6 质量-金属丰度关系: 横轴为MPA-JHU星表中的恒星质量 ($\lg m_fib_p50$), 纵轴为CNN预测的气体金属丰度.

Fig. 6 Mass-metallicity relation: the x -axis represents stellar mass ($\lg m_fib_p50$) from the MPA-JHU catalog, and the y -axis represents the gas-phase metallicity predicted by the CNN model.

5 应用

本章基于训练好的模型, 预测LAMOST DR10观测但未包含在MPA-JHU星表中的恒星形成星系的气体金属丰度. 使用第2章中与MPA-JHU星表未成功匹配的约91400条光谱, 首先对这些数据进行恒星形成星系的识别(见第5.1节), 然后使用训练好的CNN回归模型预测其气体金属丰度(见第5.2节).

5.1 恒星形成星系的识别

由于LAMOST数据未直接提供恒星形成星系的分类信息, 本研究使用卷积神经网络构建了一个二分类模型, 以区分恒星形成星系与非恒星形成星系. 该模型的架构与第3.1节描述的回归模型类似(见图2), 但输出层由一个节点改为两个节点, 分别对应恒星形成星系和非恒星形成星系, 并采用Sigmoid激活函数.

该模型的训练标签来自SDSS MPA-JHU

DR8星表的bptclass参数^[21], 其中bptclass=1对应恒星形成星系. 为了训练该模型, 从第2章与MPA-JHU交叉匹配得到的约151000条光谱中, 随机抽取10000条恒星形成星系(bptclass=1)和10000条非恒星形成星系, 共计20000条样本. 这些光谱经过与第2章相同的光谱插值和标准化处理. 随后, 数据集按7:1:2的比例划分为训练集、验证集和测试集. 训练过程与第3.2节回归模型的训练方法类似, 使用二元交叉熵损失函数²(Binary Cross-Entropy Loss, BCELoss), 优化器采用Adam、学习率设为0.001、批次大小(batch size)为128, 共训练100轮(epoch).

表2总结了模型在测试集上的分类结果, 包括精确率(Precision)、召回率(Recall)和F1分数(F1-score). 从结果来看, 恒星形成星系和非恒星形成星系的精确率、召回率及F1分数均超过92%. 模型的总体分类准确率约为92.5%, 另外7.5%误分类的样本中约87%为Composite (复合型)星系. 该类星系的光谱特征介于恒星形成星系与活动星系核(Active Galactic Nucleus, AGN)之间, 其发射线特性与恒星形成星系相似, 因而在模型分类时容易被误判为恒星形成星系, 是造成分类混淆的主要来源. 整体而言, 该分类模型能够有效地区分恒星形成星系与其他类型星系, 为构建高质量的回归样本集奠定了可靠基础.

表 2 恒星形成星系与非恒星形成星系的分类结果
Table 2 Classification results of star-forming and non-star-forming galaxies

Galaxy Type	Precision	Recall	F1-Score
Star-Forming Galaxy	92.93%	92.09%	92.50%
Non-Star-Forming Galaxy	92.25%	93.07%	92.66%

我们将该分类模型应用于LAMOST观测的、不包含在MPA-JHU星表中的约91400条光谱. 同时, 为进一步提高后续回归样本的纯净度, 我们在推断阶段对分类置信度进行筛选, 仅保留置信度 ≥ 0.85 的光谱作为恒星形成星系. 最终, 模型识别得到约20000条高置信度的恒星形成星系光谱, 这些光谱数据成为后续气体金属丰度预测的基础.

²<https://pytorch.org/docs/stable/generated/torch.nn.BCELoss.html>

5.2 气体金属丰度的预测与星表构建

我们使用第3章训练的CNN回归模型, 对前述约20000个恒星形成星系的气体金属丰度进行预测, 并最终构建出该星表. 表3展示了星表的部分示例数据. 其中, 列(1) obsid为LAMOST光谱的唯一标识符; 列(2)和(3)分别给出目标的赤经(ra)与赤纬(dec); 列(4) S/N_r表示光谱在r波段的信噪比; 列(5) z 为光谱红移; 列(6) Z_{pred} 则记录了本文CNN回归模型预测得到的气体金属丰度. 图7显示了星表中气体金属丰度的分布情况, 峰值位于9.0 dex附近, 其中大部分样本的气体金属丰度分布在8.5–9.2 dex之间, 均值约为8.91 dex.

表 3 LAMOST DR10的恒星形成星系气体金属丰度星表
Table 3 The gas-phase metallicity catalog of star-forming galaxies in LAMOST DR10

obsid	ra	dec	S/N_r	z	Z_{pred}
(1)	(2)	(3)	(4)	(5)	(6)
101162	331.90851	-1.31349	3.65	0.148407	8.981
102052	331.50241	-1.30848	3.97	0.0960971	9.035
102075	331.56058	-1.47138	3.99	0.18395	9.108
104183	331.9577	0.08844	5.1	0.109185	9.081
107037	332.74158	-1.25447	3.36	0.128122	8.391

Note: The data in columns (1)-(5) are from the publicly available LAMOST catalog; column (6) lists the gas-phase metallicity predicted by the model.




图 7 星表中气体金属丰度的分布情况

Fig. 7 Distribution of gas-phase metallicity in our catalog

6 总结

本研究利用LAMOST星系光谱, 基于CNN模型预测恒星形成星系的气体金属丰度. 首先, 我们对LAMOST DR10 LRS星系光谱进行清洗和筛选, 并在此基础上应用CNN模型进行气体金属丰度预测. 实验结果表明, 该CNN模型能够精确预测气体金属丰度, 为传统光谱分析提供了一种高效且精准的替代方法, 显著提升了大数据环境下的处理能力与预测效率.

为评估模型的性能, 本研究从多个角度进行了分析:

1. 通过分析CNN预测值与真实值之间的偏差, 评估模型的精度. 结果表明, CNN模型预测的真实值和预测值之间的偏差仅为 -0.0002 dex, 标准差为 0.0829 dex, 表明该模型在大多数情况下能够准确估算气体金属丰度.

2. 将CNN与两种经典机器学习模型(随机森林和多层感知机)进行比较. 结果表明, CNN在偏差和标准差方面均优于随机森林和多层感知机模型, 其中CNN的标准差最小(0.0829 dex), 表明该方法在气体金属丰度预测任务中表现更好.

3. 分析信噪比对模型性能的影响. 尽管在低信噪比($S/N_r = 3$)条件下, 预测误差上升至约 0.11 dex, 但总体上该模型在不同信噪比范围内仍然表现出良好的预测能力.

4. 评估模型在不同红移范围内的预测表现. 在高红移和低红移区域, 预测误差最高增加至约 0.10 dex. 这可能与光谱数据的不均衡分布有关, 或某些发射线落在采样范围之外所致, 但整体误差处于合理范围.

5. 探讨模型再现星系质量-金属丰度关系方面的能力. 我们利用模型预测的气体金属丰度对数据进行多项式拟合, 得到了新的质量-金属丰度关系, 其与经验关系保持基本一致. 这表明该模型能够准确恢复星系的质量-金属丰度关系.

最后, 我们将训练好的CNN模型应用于LAMOST DR10 LRS星系光谱, 以构建恒星形成星系的气体金属丰度星表. 首先, 利用分类模型识别出恒星形成星系, 随后使用训练好的回归模型

预测其气体金属丰度. 最终, 我们获得了一份包含约20000个恒星形成星系气体金属丰度预测值的星表, 为LAMOST DR10 LRS数据提供了可靠的金属丰度测量结果, 为进一步的天文学研究提供了重要数据支持. 未来, 我们计划基于当前的金属丰度预测框架, 构建一个多输出或多任务学习的深度神经网络架构, 使模型在输入全谱信息的基础上, 能够同时预测多个星系物理参数(恒星质量和恒星形成率等), 为LAMOST等光谱巡天项目提供更全面的星系物理参数星表.

参考文献

- [1] Nagamine K, Reddy N, Daddi E, et al. *SSRv*, 2016, 202: 79
- [2] Simons R C, Papovich C, Momcheva I, et al. *ApJ*, 2021, 923: 203
- [3] Maiolino R, Mannucci F. *A&ARv*, 2019, 27: 3
- [4] Garnett D R. *AJ*, 1992, 103: 1330
- [5] Pérez-Montero E. *MNRAS*, 2014, 441: 2663
- [6] Izotov Y I, Thuan T X. *ApJ*, 1999, 511: 639
- [7] Pagel B E J, Edmunds M G, Blackwell D E, et al. *MNRAS*, 1979, 189: 95
- [8] Alloin D, Collin-Souffrin S, Joly M, et al. *A&A*, 1979, 78: 200
- [9] Dopita M A, Kewley L J, Heisler C A, et al. *ApJ*, 2000, 542: 224
- [10] Pérez-Montero E, Contini T. *MNRAS*, 2009, 398: 949
- [11] Kewley L J, Dopita M A. *ApJS*, 2002, 142: 35
- [12] Denicoló G, Terlevich R, Terlevich E. *MNRAS*, 2002, 330: 69
- [13] Tremonti C A, Heckman T M, Kauffmann G, et al. *ApJ*, 2004, 613: 898
- [14] Charlot S, Longhetti M. *MNRAS*, 2001, 323: 887
- [15] Hoyle B, Rau M M, Bonnett C, et al. *MNRAS*, 2015, 450: 305
- [16] Wang L L, Yang G J, Zhang J L, et al. *MNRAS*, 2024, 527: 10557
- [17] Ho I T. *MNRAS*, 2019, 485: 3569
- [18] Teimoorinia H, Jalilkhany M, Scudder J M, et al. *MNRAS*, 2021, 503: 1082
- [19] Cui X Q, Zhao Y H, Chu Y Q, et al. *RAA*, 2012, 12: 1197
- [20] Zhao G, Zhao Y H, Chu Y Q, et al. *RAA*, 2012, 12: 723
- [21] Brinchmann J, Charlot S, White S D M, et al. *MNRAS*, 2004, 351: 1151

Estimating Gas-phase Metallicity of Star-forming Galaxies in the LAMOST Spectral Survey Using Deep Learning

FENG Jia-bao^{1,2} WANG Li-li² LI Ping^{1,2}

(1 School of Information and Control Engineering, Jilin University of Chemical Technology, Jilin 132022)

(2 School of Computer and Information, Dezhou University, Dezhou 253023)

ABSTRACT Gas-phase metallicity is a key parameter for measuring the chemical evolution of star-forming galaxies. Accurate estimation of gas-phase metallicity is crucial for a deeper understanding of galaxy formation and evolution processes. Traditional gas-phase metallicity estimation methods rely on emission line intensity calculations, which involve complex data processing and are difficult to scale to large spectroscopic surveys. In this study, we propose a deep learning model based on a convolutional neural network (CNN) that uses the full spectrum observed by the Large Sky Area Multi-Object Fiber Spectroscopic Telescope (LAMOST) as input. The model enables automatic estimation of gas-phase metallicity in star-forming galaxies without explicit redshift correction or emission line measurement. The CNN model consists of 8 1D convolutional layers, 4 max-pooling layers, and 1 fully connected layer, and is trained to learn the nonlinear mapping between spectral features and gas-phase metallicity values through a regression framework. Experimental results show that the model achieves a prediction error of 0.0829 dex, which is basically consistent with traditional methods. Further evaluation shows that the CNN model performs robustly across different signal-to-noise ratios and redshift ranges, and also effectively recovers the mass-metallicity relation. Finally, the trained model is applied to the LAMOST Data Release 10 Low-Resolution Survey, generating a catalog of predicted gas-phase metallicity for star-forming galaxies, which includes about 20000 galaxy spectra. The catalog is publicly available through the Science Data Bank (<https://www.scidb.cn/s/UVBRzm>).

Key words galaxies: gas-phase metallicity, methods: data analysis, methods: statistical, methods: deep learning