arXiv:2601.00146v1 [astro-ph.IM] 1 Jan 2026

使用低秩适配组合真实值不同的数据集，以泛化基于图像的卷积神经网络模型，用于光度红移预测

Vikram Seenivasan[1]
vikrams25@ucla.edu

Srinath Saikrishnan[2]
srinathsai22@ucla.edu

Andrew Lizarraga[3]
andrewlizarraga@ucla.edu

Jonathan Soriano[1]jsoriano@天体物理学.加州大学洛杉矶分校.edu

Bernie Boscoe[4]
boscoeb@sou.edu

Tuan Do[1]tdo@天体物理学.加州大学洛杉矶分校.edu

[1] 加州大学洛杉矶分校物理与天文学系，洛杉矶，加利福尼亚州 90095[2] 加州大学洛杉矶分校计算机科学系，洛杉矶，加利福尼亚州 90095[3] 加州大学洛杉矶分校统计学与数据科学系，洛杉矶，加利福尼亚州 90095[4] 南俄勒冈大学计算机科学系，阿什兰，俄勒冈州 97520

摘要

在本研究中，我们展示了如何使用低秩适配（LoRA）组合不同的星系成像数据集，从而改进用于宇宙学的卷积神经网络模型的红移估计。LoRA 是一种成熟的大语言模型技术，它通过添加适配器网络来调整模型权重和偏置，从而在无需重新训练的情况下高效微调大型基础模型。我们使用一个光度红移真实值数据集训练基础模型，该数据集涵盖广泛的星系类型，但准确性较低。随后，我们在一个光谱红移真实值数据集上使用 LoRA 进行微调。这些红移更准确，但仅限于明亮星系，且获取所需的时间长出几个数量级，因此在大型巡天中较难获得。理想情况下，组合这两个数据集能够得到泛化能力强、准确性更高的模型。与传统迁移学习方法相比，LoRA 模型的表现更好，$\sim 2.5\times$ 偏差更小，$\sim 2\times$ 散布更小。使用组合数据集重新训练模型，得到的模型泛化能力优于 LoRA，但代价是需要更多计算时间。我们的研究表明，LoRA 有助于天体物理学中的回归模型微调，在完全重新训练与不重新训练之间提供了一种折中方案。LoRA 展现出利用现有预训练天体物理模型的潜力，尤其适用于数据稀疏任务。

1 引言

天文学正处于大数据时代，LSST[13] 和欧几里得 [17] 等正在开展或即将开展的多项巡天将对数十亿个星系成像，以约束支配宇宙起源与演化的宇宙学模型。星系红移用于确定星系的距离，使我们能够绘制宇宙在宇宙时间中的结构，并确定支配宇宙加速膨胀的暗能量和暗物质的性质。天体物理学家越来越多地采用机器学习技术，从大型数据集 [26, 20]中高效地进行测量，例如测定星系红移。此类测量通常需要利用不同来源的真实值。在本文中，我们探讨如何通过整合具有不同真实值来源的数据集，采用低秩适配（LoRA）[12] 和传统迁移学习，对星系红移预测模型进行微调。

机器学习与物理科学研讨会，NeurIPS 2025。

1.1 相关工作

红移估计：传统上，红移通过光谱学获得。此类红移的精度很高，但仅适用于具有强发射线的明亮星系；由于成本高昂，这种方法无法应用于即将开展的大规模巡天 [20]。光度红移是根据星系在不同波段的测光（亮度）推导得出的，这些波段可用于采样其光谱特性。此类红移的精度较低 [2]，但能够分析规模大得多的数据集。近年来，人们提出了许多用于估计光度红移的机器学习模型 [8, 6, 4, 2, 25, 14, 15, 26, 27]。例如，卷积神经网络（CNN）直接利用星系图像，能够获得最精确的红移估计结果之一[21, 27, 9, 16] 。这些方法通常依赖光谱红移作为训练集的真实值。 [5, 29] 近期的研究探索了如何将来自多波段光度测量的光度红移作为另一种真实值来源加以利用。然而，这些方法仅使用测光进行训练，因此未能充分利用图像中丰富的信息 [18]。

LoRA 与微调：LoRA 是一种成熟的大语言模型微调技术，它通过向预训练模型添加秩更低的权重矩阵构成的适配器网络来实现微调。这样可以高效地微调大型基础模型，且只需更新极少一部分参数[12]。低秩适配已用于天体物理学领域，将其他领域的预训练模型微调用于天体物理学任务。例如，基于词元的红移估计大语言模型 [23]、射电天文学基础模型 [24], 以及用于星系图像生成的扩散模型 [3]。其在天体物理学中用于基于回归的任务的效用尚未得到充分探索。

1.2 贡献

我们探索使用 LoRA 和迁移学习，为一个以 5 波段星系图像为输入的红移回归卷积神经网络整合不同来源的真实值。我们将近期开发的 LoRA 实现 [19] 适配到用于天体物理数据的卷积神经网络。就我们所知，这是 LoRA 首次应用于天体物理学中的基于回归的任务。以往天体物理学领域的研究使用的是来自其他领域的预训练模型；而本研究首次使用在天文数据上训练的基线模型。这些都是大规模巡天的重要关键考量，因为此类巡天将利用以往积累的天体物理学知识。

2 数据

在本研究中，我们使用三个数据集：一个用于基础模型，一个用于迁移学习，另一个用于 com-
两者的数据集组合。用于训练基础模型的数据集源自 TransferZ[29]，并加入了来自 Hyper Suprime-Cam Subaru Strategic Program (HSC-SSP) 第二次公开数据发布 [1] 的五波段图像，以及 [10]中所述的额外质量筛选。

由此得到的数据集称为 TransferZ-Images [1]，包含100,442个星系及其五波段g、r、i、z、y 图像。我们使用GalaxiesML[10] [2]数据集进行微调。这些数据集已用于宇宙学领域的红移估计，且均已做好机器学习应用准备；它们覆盖了不同的星系颜色类型和红移范围，因而相互补充。

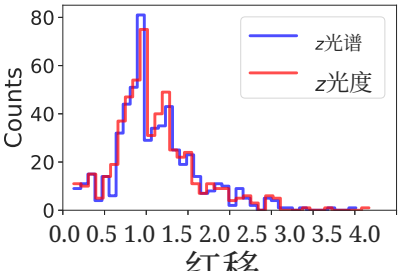

图 1：557个共同星系的红移数量分布，分别采用 GalaxiesML 的光谱真实值（蓝色）和 TranferZ-Images 的测光真值（红色）。

TransferZ-Images数据集的红移真实值来自光度红移估计，而GalaxiesML的真实值来自光谱学。TransferZ-Images的光度红移不如GalaxiesML准确，但包含更暗、更丰富多样的星系类型。理想情况下，它是用于训练基础模型的良好数据集。我们的目标是在GalaxiesML上进行微调，以利用更准确的红移改进基础模型。原则上，这种组合应能生成一个更准确且更具泛化能力的模型。此外，我们通过组合TransferZ-Images和GalaxiesML创建了Combo数据集，得到

[1]TransferZ-Images 可在此处通过 Zenodo 获取。[2] GalaxiesML 可在此处通过 Zenodo 获取。

一个包含386,286个星系的数据集。对于两个数据集共有的557个星系，我们使用GalaxiesML的光谱红移作为真实值。此外，通过比较这些重叠星系的光谱红移真实值和光度红移真实值，我们发现两个红移分布中均不存在系统偏差（见图1）。本研究所使用的数据汇总于表 1。三个数据集分别划分为80%的训练集、10%的验证集和10%的测试集。

表 1：数据摘要。

数据集	真实值 真值 z	数量 源	z 第 90 百分位数	中位数 z 不确定性	i 波段星等 第 90 百分位数	No. 滤波器
TransferZ-Images	z_{phot}	100,442	1.8	0.03	25	5
GalaxiesML	z_{spec}	286,401	1.2	0.0002	22	5
组合	z_{phot} & z_{spec}	386,286	1.4	0.0006	24	5

3 方法与指标

本研究训练了四种模型，以比较 LoRA 在泛化红移估算模型方面的有效性：(1) 在 TransferZ 上训练的基础模型（CNN-Base）；(2) 通过在 GalaxiesML 上微调 CNN-Base 构建的传统迁移学习模型（CNN-TL）；(3) 使用 LoRA 在 GalaxiesML 上微调 CNN-Base 构建的 LoRA 模型（CNN-LoRA）；以及 (4) 在组合数据集上训练的完整重新训练模型（CNN-Combo）。这些模型采用相同的 ResNet18 架构[11]，，并经过修改以接受五张图像作为输入，同时连接一个回归网络，以输出单个红移值。我们对学习率、批量大小和回归器架构进行了超参数调优。学习率是最敏感的参数。回归器由两个线性层组成，分别包含 512 个和 256 个神经元；两层之间设有丢弃层（采用标准丢弃率 0.5）和 SiLU激活函数，以促进模型稳定训练。

为了训练这些模型，我们使用 ReduceLROnPlateau 调度器，其参数与 [11]，Adam优化器中的参数相同，并采用自定义损失函数 $L(\Delta z) = 1 - \frac{1}{1+(\Delta z/0.15)^2}$，来源于 [30]。该损失函数涵盖了光度红移精度指标，例如离群值率、偏差和散布，这些是宇宙学中最重要的指标 [16]（见下文）。我们使用验证损失的指数移动平均（EMA）来确定何时停止训练。模型最多训练 500 轮，并采用提前停止：如果模型的 EMA 验证损失在 20 轮后仍未改善，则结束训练。我们使用一台 AMD

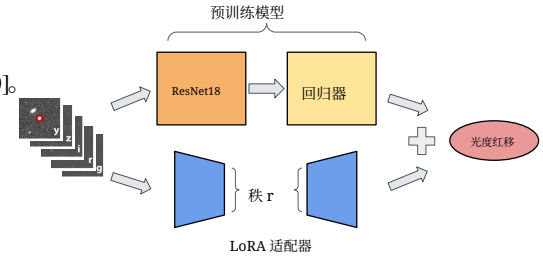

图 2：基于图 1，展示在 ResNet + 回归模型上实现 LoRA 的示意图，见[12]。

Ryzen Threadripper PRO 3955WX（16 核）和 NVIDIA RTX A6000 来训练模型。对于 CNN-Base，我们使用 1e-3 的学习率，训练 56 轮后停止，耗时 26.7 分钟，最终学习率为 1e-8。CNN-TL 和 CNN-LoRA 均以此模型为基础进行训练。为创建 CNN-TL，我们冻结 CNN-Base 中除输入层和回归器层以外的所有模型权重，并使用 CNN-Base 训练得到的最终学习率 1e-8 在 GalaxiesML 上进行训练。该模型训练满 500 轮，耗时 4.4 小时。为创建 CNN-LoRA，我们使用 peft 库（参数高效微调） [31]。我们创建了一个 LoRA 适配器，覆盖模型中的所有线性层和卷积层（图 2）。该适配器的秩为 4，alpha参数为 16，丢弃率为 0.1，这些设置由超参数调优确定。LoRA 适配器在 GalaxiesML 上训练，121 轮后停止，耗时 1.4 小时。最后，CNN-Combo 使用组合数据集以 1e-3 的学习率训练 121 轮，且不采用提前停止，耗时 2.4 小时。我们为 CNN-Combo 选择与 CNN-LoRA 相同的训练轮数，以量化计算效率的提升。所有模型均使用 Pytorch [22]实现。代码可通过此处的 Github 获取。

为了评估这些模型，我们使用偏差、散布和灾难性离群率指标 [30]。偏差指标是偏差分布的中位数，其定义为 $b = (z_{pred} - z_{truth})/(1 + z_{truth})$，其中 z_{pred}

和 z_{truth} 分别表示预测红移和真实红移。散布定义为偏差分布的绝对中位差乘以 1.4826。灾难性离群率是满足 $|z_{photo} - z_{truth}| > 1.0$ [28] 的天体所占的比例。我们在红移范围 $0.3 < z < 1.5$ 内计算这些指标。这些指标对大多数宇宙学科学应用都很重要；尤其是 LSST 要求光度红移估计的偏差 $< |0.003|$ 且散布 < 0.02 [7]。我们根据模型在所有测试集上的表现，对其“泛化能力”进行定性评估。

4 结果与讨论

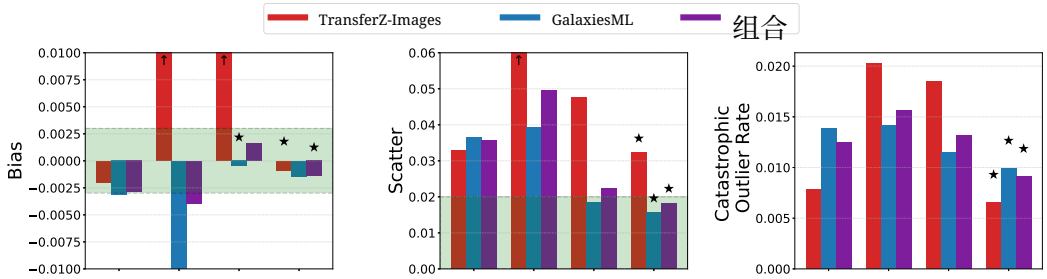

图3：所有四种模型的偏差（左）、散布（中）和灾难性离群率（右）性能指标。这些指标是在全部三个数据集上评估的（TransferZ-Images（红色）、GalaxiesML（蓝色）、组合（紫色））。偏差和散布图中的绿色带表示 LSST 科学要求。黑色星号表示每个数据集上表现最佳（指标最低）的结果。向上的黑色箭头表示柱形超出了绘图范围。低秩适配（CNN-LoRA）的表现优于传统迁移学习（CNN-TL），但不如在整个数据集上重新训练（CNN-Combo）。

我们发现，低秩适配（CNN-LoRA）得到的模型比传统迁移学习（CNN-TL）具有更好的泛化能力，但表现不如基于组合真实值重新训练的模型（CNN-Combo）。我们通过在以下测试集上测试四种模型来评估其性能：TransferZ-Images 中的 10,027 个星系、GalaxiesML 中的 40,914 个星系，以及组合数据集中的 50,871 个星系（预测值与真实值的散点图见附录A）。模型性能指标见图3（具体数值见表2）。与 CNN-TL 相比，CNN-LoRA 在组合数据集上的偏差低 $\sim$2.5$\times$，散布低 $\sim$2.2$\times$。与 CNN-Combo 相比，CNN-LoRA 在组合测试集上的偏差相近（高 $\sim$1.1$\times$），散布也相近（高 $\sim$1.2$\times$），但略高。具体来看 GalaxiesML 微调数据集，CNN-LoRA 的偏差比 CNN-Combo 低 $\sim$3$\times$，散布则高 $\sim$1.2$\times$。然而，CNN-LoRA 在基准数据 TransferZ-Images 上的表现较差，偏差高 $\sim$20$\times$，散布高 $\sim$1.5$\times$。这表明 CNN-LoRA 模型遗忘了在 TransferZ-Images 基准训练中学到的信息。混合真实值的方法需要在性能要求和可用计算资源之间权衡。因此，如果使用组合数据重新训练模型的计算开销过大，且在基准数据集上的性能下降不会妨碍科学目标，那么 LoRA 可能是一个不错的选择。

我们通过使用 GalaxiesML 的不同数据比例训练模型，进一步测试 CNN-LoRA。仅使用 10% 的 GalaxiesML 进行训练时，模型在 GalaxiesML 上的散布显著改善，并持续改善至数据比例约为 40%–50%（图 4）。超过这一比例后，模型性能不再有显著提升。此外，即使数据比例达到 100%，在两个模型训练轮次相同的情况下，CNN-LoRA 的训练耗时仍比 CNN-Combo 少 $\sim$1.5$\times$。数据比例越小，训练耗时也越短。因此，LoRA 提供了一种使用较小数据比例微调模型的方法，仍能在微调数据集上达到最佳模型性能，同时节省计算资源；不过，其表现仍不如基于组合真实值重新训练。

尤其是在考察迁移学习时，先前的研究表明，神经元会在模型层之间协同适应，而后面的模型层可能会高度专用于基准数据 [32]。CNN-LoRA 能够利用其训练得到的适配器调整整个模型的权重和偏置，从而

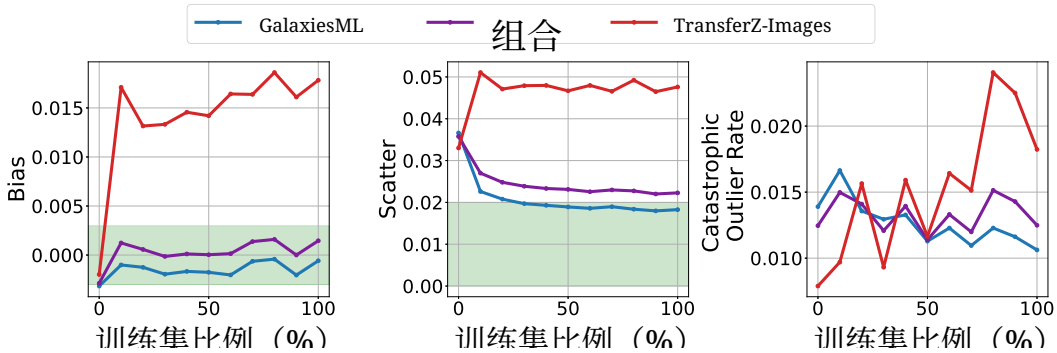

图4：偏差（左）、散布（中）和灾难性离群率（右）随使用 GalaxiesML 数据集比例进行微调（采用 CNN-LoRA）的变化。偏差和散布的绿色带表示 LSST科学要求。仅使用 10% 的数据时，模型在 GalaxiesML 上的散布有所改善，在 TransferZ 上则大幅降低。当使用 40%–50% 的 GalaxiesML 进行训练时，CNN-LoRA 的性能趋于饱和；要实现最佳微调效果，只需使用数据集的一部分。

表现优于 CNN-TL；后者仅训练输入层和回归器层。因此，LoRA 为模型上的迁移学习提供了一种标准化方法，无需像传统迁移学习那样，为确定要解冻的层进行大量优化。

表2：模型指标汇总

		Bias	散布	灾难性离群值率
CNN-Base	TransferZ-Images	-0.00198	0.0330	0.00789
	GalaxiesML	-0.00316	0.0366	0.0139
	组合	-0.00287	0.0358	0.0125
CNN-TL	TransferZ-Images	0.0502	0.121	0.0203
	GalaxiesML	-0.00995	0.0391	0.0141
	组合	-0.00396	0.0496	0.0157
CNN-LoRA	TransferZ-Images	0.0176	0.0476	0.0185
	GalaxiesML	-0.000481	0.0184	0.0115
	组合	0.0016	0.0223	0.0132
CNN-Combo	TransferZ-Images	-0.000868	0.0323	0.00660
	GalaxiesML	-0.00146	0.0156	0.00996
	组合	-0.00141	0.0183	0.00915
LSST 要求		$< \|0.03\|$	< 0.02	

未来的工作中，调优 LoRA 参数可以进一步优化其性能，并有望以更低的计算成本达到与 CNN- Combo 相当的性能。通过冻结和解冻不同层来构建不同 CNN-TL 模型的消融研究，也有助于进一步刻画传统迁移学习的性能，并与 LoRA 微调进行比较。未来还可以探索使用提前停止以及不同比例的数据来训练 CNN-Combo，从而全面量化其性能，并更稳健地与 LoRA 微调进行比较。随着我们逐步应对当前及未来的宇宙学巡天，LoRA 和其他微调方法最终将发挥关键作用。LoRA 展现出潜力，可利用种类繁多的现有预训练天体物理模型处理数据稀疏任务；尤其是在重新训练模型的计算成本过高时，它能够将现有模型适配到多个新数据集，为开展新的精密宇宙学研究开辟一条正在发展的途径。

致谢与经费披露

本研究获得了阿尔弗雷德·P·斯隆基金会和 NSF DGE2034835 的部分资助。本研究通过高级网络基础设施协调生态系统：服务与支持（ACCESS）计划获得了印第安纳大学 Jetstream2 的计算资源，分配编号为 # PHY230092。该计划由美国国家科学基金会提供资助，资助编号为 # 2138259、#2138286、#2138307、#2137603 和 #2138296。

Hyper Suprime-Cam（HSC）合作组由日本和中国台湾的天文学界以及普林斯顿大学组成。HSC仪器及软件由日本国立天文台（NAOJ）、卡夫利宇宙物理与数学研究所（Kavli IPMU）、东京大学、高能加速器研究机构（KEK）、中国台湾的中央研究院天文及天体物理研究所（ASIAA）以及普林斯顿大学开发。经费由日本内阁府的FIRST计划、文部科学省（MEXT）、日本学术振兴会（JSPS）、日本科学技术振兴机构（JST）、东丽科学振兴基金会、NAOJ、Kavli IPMU、KEK、ASIAA及普林斯顿大学提供。

本文使用了为大型综合巡天望远镜开发的软件。我们感谢LSST项目将其代码作为免费软件发布于 http://dm.lsst.org

本文部分基于 [在] 昴星团望远镜采集的数据，以及从HSC数据档案系统检索的数据。该系统由昴星团望远镜和日本国立天文台天文数据中心（ADC）运营。数据分析部分是在日本国立天文台计算天体物理中心（CfCA）的协助下完成的。昴星团望远镜对有机会从莫纳克亚山观测宇宙深感荣幸并心怀感激；莫纳克亚山在夏威夷具有重要的文化、历史和自然意义。

本研究基于欧洲南方天文台在ESO项目ID 179.A-2005下采集的观测数据，以及CALET和剑桥天文巡天组代表UltraVISTA联盟制作的数据产品。

参考文献

[1] Hiroaki Aihara 等：《Hyper Suprime-Cam Subaru Strategic Program 第二次数据发布》。载于《日本天文学会刊》71.6（2019年12月），第114页。ISSN：0004-6264。DOI：10.1093/pasj/psz103。（访问日期：2025年8月28日）。[2] Róbert Beck 等：《SDSS数据发布第12版的光度红移》。载于皇家天文学会月刊460.2（2016年8月），第1371–1381页。ISSN：0035-8711。DOI：10.1093/mnras/stw1009。（访问日期：2025年8月28日）。[3] Hardik Bishnoi 和 Tala Talaei Khoei：《使用低秩适配器快速模拟星系图像》。载于*2025*年*IEEE*第*15*届年度计算与通信研讨会（*CCWC*）。2025年1月，第00171–00177页。DOI：10.1109/CCWC62904.2025.10903751。（访问日期：2025年8月27日）。[4] Christopher Bonnett：《使用神经网络估计红移分布：在CFHTLenS中的应用》。载于皇家天文学会月刊449.1（2015年5月），第1043–1056页。ISSN：0035-8711。DOI：10.1093/mnras/stv230。（访问日期：2024年8月22日）。[5] L. Cabayol 等：《PAU巡天与欧几里得： 通过多任务学习改进宽带光度红移》。载于《天文学与天体物理学》671（2023年3月），A153。ISSN：0004-6361, 1432-0746。DOI：10.1051/0004-6361/202245027。（访问日期：2025年4月13日）。[6] Matias Carrasco Kind 和 Robert J. Brunner：《TPZ：利用预测树和随机森林获取光度红移概率密度函数及辅助信息》。载于皇家天文学会月刊432.2（2013年6月），第1483–1501页。ISSN：0003-8711，1365-2966。DOI：10.1093/mnras/stt574。（访问日期：2025年4月13日）。[7] LSST科学合作组等。*LSST*科学手册，第*2.0*版。2009年12月。DOI：10. 48550/arXiv.0912.0201。arXiv：0912.0201 [天体物理学]。（访问日期：2025年4月13日）。[8] Adrian A. Collister 和 Ofer Lahav：《ANNz：使用人工神经网络估计光度红移》。载于《太平洋天文学会刊》116（2004年4月），第345–351页。ISSN：0004-6280。DOI：10.1086/383254。（访问日期：2025年4月12日）。

[9] Biprateep Dey 等：《使用可解释深度胶囊网络从斯隆数字巡天图像估计光度红移》。载于皇家天文学会月刊515.4（2022年8月），第5285–5305页。ISSN：0035-8711，1365-2966。DOI：10 . 1093 / mnras / stac2105。arXiv：2112.03939 [天体物理学]。（访问日期：2025年4月12日）。[10] Tuan Do 等。GalaxiesML：用于机器学习的星系图像、测光、红移和结构参数数据集。2024年9月。DOI：10.48550/arXiv.2410.00271。arXiv：2410.00271 [天体物理学]。（访问日期：2025年8月28日）。[11] 何恺明等。用于图像识别的深度残差学习。2015年12月。DOI：10.48550/ arXiv.1512.03385。arXiv：1512.03385 [cs]。（访问日期：2025年8月27日）。[12] Edward J. Hu 等。LoRA：大语言模型的低秩适配。2021年10月。DOI：10.48550/arXiv.2106.09685。arXiv：2106.09685 [cs]。（访问日期：2025年8月27日）。[13] Željko Ivezi´c 等：《LSST：从科学驱动因素到参考设计及预期数据产品》。载于《天体物理学杂志》873.2（2019年3月），第111页。ISSN：0004-637X。DOI：10.3847/1538-4357/ab042c。（访问日期：2025年8月28日）。[14] E. Jones 和 J. Singal：《用于光度红移估计的定制支持向量机分析及星系形状信息的纳入》。载于《天文学与天体物理学》600（2017年4月），A113。ISSN：0004-6361，1432-0746。DOI：10.1051/0004-6361/201629558。（访问日期：2025年4月13日）。[15] Evan Jones 等：《利用贝叶斯神经网络改进LSST宇宙学光度红移估计》。载于《天体物理学杂志》964.2（2024年4月），第130页。ISSN：0004-637X，1538-4357。DOI：10.3847/1538-4357/ad2070。（访问日期：2025年4月12日）。[16] Evan Jones 等：《使用带有保形预测的贝叶斯卷积神经网络，通过图像进行宇宙学红移预测》。载于《天体物理学杂志》974.2（2024年10月），第159页。ISSN：0004-637X，1538-4357。DOI：10.3847/1538-4357/ad6d5a。（访问日期：2025年4月12日）。[17] R. Laureijs 等。欧几里得定义研究报告。2011年10月。DOI：10.48550/arXiv.1110. 3193。（访问日期：2025年8月28日）。[18] Andrew Lizarraga 等。通过红移条件扩散模型研究星系形态随宇宙时间的演化。2024年11月。DOI：10.48550/arXiv.2411.18440。（访问日期：2025年8月28日）。[19] Sourab Mangrulkar 等。PEFT：先进的参数高效微调方法。https://github.com/huggingface/peft。2022年。[20] Jeffrey A. Newman 和 Daniel Gruen：《下一代巡天的光度红移》。载于《天文学与天体物理学年度评论》60.第60卷，2022年（2022年9月），第363–414页。ISSN：0066-4146，1545-4282。DOI：10 . 1146 / annurev - astro - 032122 - 014611。（访问日期：2025年8月28日）。[21] Johanna Pasquet 等：《使用卷积神经网络从斯隆数字巡天图像估计光度红移》。载于《天文学与天体物理学》621（2019年1月），A26。ISSN：0004-6361，1432-0746。DOI：10. 1051 / 0004- 6361 / 201833617。arXiv：1806 . 06607 [天体物理学]。（访问日期：2025年4月12日）。[22] Adam Paszke 等。PyTorch：一种命令式风格的高性能深度学习库。2019年12月。DOI：10.48550/arXiv.1912.01703。arXiv：1912.01703 [cs]。（访问日期：2025年8月27日）。[23] Nesar Ramachandra 等。教大语言模型使用光谱学语言交流。2025年8月。DOI：10.48550/ arXiv.2508.10075。arXiv：2508.10075 [天体物理学]。（访问日期：2025年8月27日）。[24] S. Riggi 等。Radio-Llava：推进用于射电天文源分析的视觉语言模型。2025年8月。DOI：10.48550/arXiv.2503.23859。arXiv：2503.23859[天体物理学]。（访问日期：2025年8月28日）。[25] Iftach Sadeh、Filipe B. Abdalla 和 Ofer Lahav：《ANNz2——使用机器学习进行光度红移和概率分布函数估计》。载于《太平洋天文学会刊》128.968（2016年10月），第104502页。ISSN：0004-6280，1538-3873。DOI：10.1088/1538-3873/128/968/104502。arXiv：1507.00490 [天体物理学]。（访问日期：2025年4月13日）。[26] Mara Salvato、Olivier Ilbert 和 Ben Hoyle：《光度红移的多种面貌》。载于《自然·天文学》3（2019年6月），第212–222页。ISSN：2397-3366。DOI：10.1038/s41550-018-0478-0。（访问日期：2025年4月13日）。

[27] S. Schuldt 等：《使用卷积神经网络进行光度红移估计：NetZ》。发表于《天文学与天体物理学》651（2021年7月），A55。ISSN：0004-6361、1432-0746。DOI：10.1051/0004-6361/202039945。（访问日期：2025年7月25日）。[28] J. Singal 等：《通过机器学习分类识别光度红移估计中的灾难性离群值》。发表于《天体物理学杂志》928.1（2022年3月），第6页。ISSN：0004-637X。DOI：10.3847/1538-4357/ac53b5。（访问日期：2025年4月13日）。[29] Jonathan Soriano 等。利用不同的真实值来源和迁移学习提升光度红移估计的泛化能力。2024年11月。DOI：10.48550/ arXiv.2411.18054。（访问日期：2025年4月12日）。[30] Masayuki Tanaka 等：《Hyper Suprime-Cam Subaru战略计划数据发布第1版的光度红移》。发表于《日本天文学会刊》70.SP1（2018年1月），S9。ISSN：0004-6264、2053-051X。DOI：10.1093/pasj/psx077。（访问日期：2025年4月13日）。[31] Lingling Xu 等。预训练语言模型的参数高效微调方法：批判性综述与评估。2023年12月。DOI：10.48550/arXiv.2312.12148。arXiv：2312.12148 [cs]。（访问日期：2025年8月29日）。[32] Jason Yosinski 等。深度神经网络中的特征有多可迁移？2014年11月。DOI：10.48550/arXiv.1411.1792。arXiv：1411.1792 [cs]。（访问日期：2025年8月29日）。

A 红移预测图

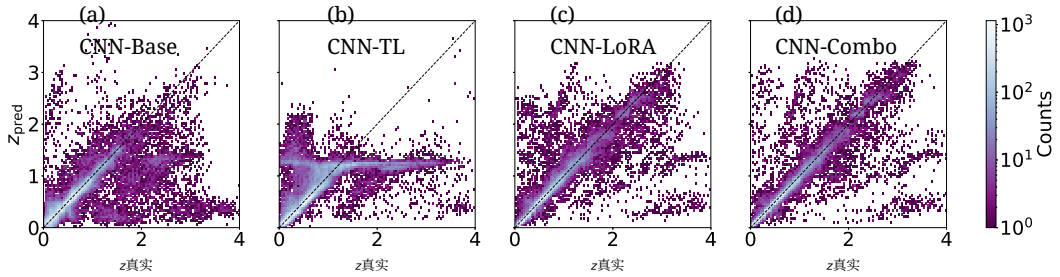

图 5：在 Combo数据集上评估的四种模型的真实红移与预测红移对比：(a) CNN-Base、(b) CNN-TL、(c) CNN-LoRA 和 (d) CNN-Combo。颜色条表示每个二维直方图分箱中星系数量的对数范数。恒等线（1:1 线）表示真实值与预测值完全一致。低秩适配（CNN-LoRA）的表现优于传统迁移学习（CNN-TL），但不及在整个数据集上重新训练（CNN-Combo）。

本节展示了四种模型——CNN-Base、CNN-TL、CNN-LoRA 和 CNN-Combo——在 Combo数据集上评估得到的真实红移与预测红移关系图（图5）。与 CNN-Base 相比，CNN-LoRA 的预测有所改善：其沿 1-1 线的离散度更低，且在 $z \sim 2$以上的预测更准确。CNN-LoRA 和 CNN-Combo 的图中呈现出相似的结构，但 CNN-LoRA 沿 1-1 线的离散度比 CNN-Combo 更大。CNN-TL 存在系统偏差，对大量星系的红移预测集中在 $\sim$1.2–1.4 附近，这表明模型在迁移学习过程中未能保留已有知识或进行有效学习。这可能是因为微调数据集 GalaxiesML 中缺少 $z \sim 1$ 以上的星系，也可能是因为需要进一步调整 CNN-TL 架构。此外，所有模型在 1-1 线之外都呈现出某些相似结构。进一步研究构成这些结构的源，有助于揭示数据中可能存在的系统偏差。

B “反向”方向的微调

为充分探索模型微调方法，我们还首先在 GalaxiesML 上进行训练（CNN-Base-Rev），随后使用 LoRA 或传统迁移学习，借助 TransferZ-Images 进行微调。CNN-Base-Rev 使用 GalaxiesML 进行训练，其架构和超参数与 CNN-Base 相同。模型在训练 147 个训练轮次后停止，耗时 1.3 小时。这比 CNN-Base 的训练时间更长，因为 GalaxiesML 是比 TransferZ-Images 更大的数据集。随后，我们使用 TransferZ-Images 对 CNN-Base-Rev 进行微调，创建了 CNN-LoRA-Rev，采用与 CNN-LoRA 相同的 LoRA

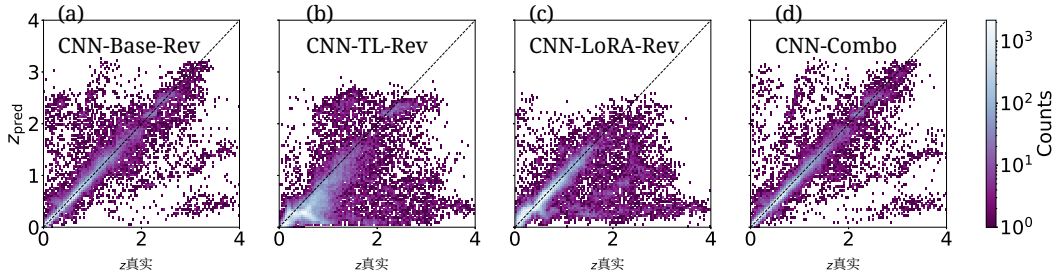

图 6：在 Combo 数据集上评估的四种模型的真实红移与预测红移：(a) CNN-Base-Rev、(b) CNN-TL-Rev、(c) CNN-LoRA-Rev 和 (d) CNN-Combo。颜色条表示每个二维直方图分箱中星系数量的对数范数。1:1 线表示真实值与预测值完全一致。低秩适配（CNN-LoRA-Rev）的表现优于传统迁移学习（CNN-TL-Rev），但不及在整个数据集上重新训练的模型（CNN-Combo），与正向方向的情况相同。

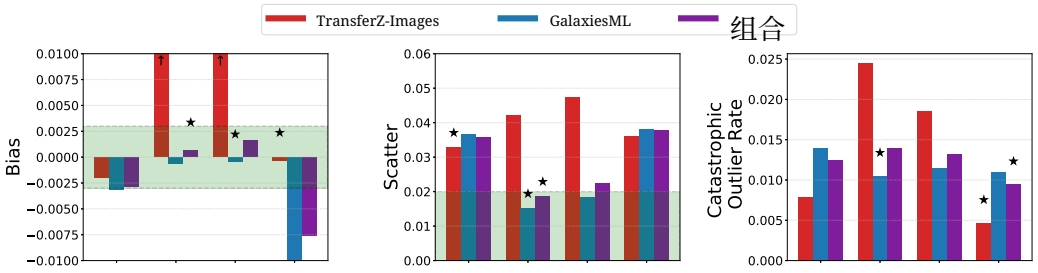

图7：CNN-Base、CNN-Base-Rev、CNN-LoRA 和 CNN-LoRA-Rev 的偏差（左）、散布（中）和灾难性离群率性能指标（右）。这些指标在全部三个数据集上进行评估（TransferZ-Images（红色）、GalaxiesML（蓝色）、组合（紫色））。偏差和散布图中的绿色带表示 LSST 科学要求。黑色星号表示各数据集上的最佳（最低）指标。向上的黑色箭头表示柱状条超出了绘图范围。
CNN-LoRA-Rev 在大多数数据集上的表现都不如 CNN-LoRA。CNN-Base-Rev 在所有数据集上的散布指标均优于 CNN-LoRA，在 GalaxiesML 和组合数据集上的偏差指标也优于 CNN-LoRA。

配置。该模型在训练 56 个训练轮次后停止，耗时 25.3 分钟。最后，我们使用 TransferZ-Images 对 CNN-Base-Rev 进行微调，创建了 CNN-TL-Rev，采用与 CNN-TL 相同的冻结层；该模型在训练 27 个训练轮次后停止，耗时 14.7 分钟。
图6展示了四种模型（CNN-Base-Rev、CNN-TL-Rev、CNN-LoRA-Rev 和 CNN-Combo）在组合数据集上的表现散点图。沿反向进行迁移学习会导致负迁移；与 CNN-Base-Rev 相比，CNN-TL-Rev 和 CNN-LoRA-Rev 的预测图离散度更大，离群值也更多。与附录A中讨论的 CNN-TL 不同，CNN-TL-Rev 并未执着于预测范围为 $\sim$ 1.2–1.4的红移，而是对大多数源的红移预测偏低，且离散度较大。
图7展示了四个模型（CNN-Base、CNN-Base- Rev、CNN-LoRA 和 CNN-LoRA-Rev）在所有测试集上评估得到的偏差、散布和灾难性离群率。表3列出了这些指标值，此外还包括 CNN-TL、CNN-TL-Rev 和 CNN-Combo 的指标。CNN-LoRA-Rev 在 TransferZ-Images 和组合数据集上的表现不如 CNN-LoRA。特别是在组合测试集上，CNN-LoRA-Rev 的偏差比 CNN-LoRA 高 $\sim$4.7×，散布高 $\sim$1.7× 。同样，CNN-TL-Rev 的表现也不如 CNN-TL。因此，在这些模型中整合真实值的方向很重要，即从光度红移真实值到光谱红移真实值，或反之。从相反方向进行迁移学习的效果较差，可能是因为 TransferZ-Images 中的光度红移真实值精度较低。

此外，仅使用 GalaxiesML 训练的卷积神经网络（CNN-Base-Rev）表现优于所有迁移学习模型。例如，在所有数据集上，就散布而言，CNN-Base-Rev 的表现都优于我们迁移学习模型中表现最好的 CNN-LoRA。具体来说，在组合测试集上，CNN-LoRA 的散布高出 $\sim 1.2\times$，偏差高出 $\sim 2.4\times$。事实上，在组合测试集上，就散布而言，CNN-Base-Rev 的表现与 CNN-Combo 相近（数值分别为 0.188 和 0.183）。因此，仅使用光谱红移真实值训练模型，也能使模型泛化到更广泛的星系类型。

表3：比较两个微调方向的模型指标汇总

		Bias	散布	灾难性 离群值率
CNN-Base	TransferZ-Images	-0.00198	0.0330	0.00789
	GalaxiesML	-0.00316	0.0366	0.0139
	组合	-0.00287	0.0358	0.0125
CNN-Base-Rev	TransferZ-Images	0.0114	0.0421	0.0244
	GalaxiesML	-0.000647	0.0153	0.0105
	组合	0.000672	0.0188	0.0139
CNN-LoRA	TransferZ-Images	0.0176	0.0476	0.0185
	GalaxiesML	-0.000481	0.0184	0.0115
	组合	0.0016	0.0223	0.0132
CNN-LoRA-Rev	TransferZ-Images	-0.000322	0.0362	0.00466
	GalaxiesML	-0.0101	0.0381	0.0110
	组合	-0.00759	0.0378	0.00944
CNN-TL	TransferZ-Images	0.0502	0.121	0.0203
	GalaxiesML	-0.00995	0.0391	0.0141
	组合	-0.00396	0.0496	0.0157
CNN-TL-Rev	TransferZ-Images	-0.0638	0.101	0.0259
	GalaxiesML	-0.147	0.0844	0.0149
	组合	-0.134	0.0973	0.0175
CNN-Combo	TransferZ-Images	-0.000868	0.0323	0.00660
	GalaxiesML	-0.00146	0.0156	0.00996
	组合	-0.00141	0.0183	0.00915
LSST 要求		$< \lvert 0.03 \rvert$	< 0.02	