

从CSST低分辨率光谱中精确估计恒星红化值^{*}

肖尧¹ 陈丙秋^{2†} 李静¹

(1 西华师范大学物理与天文学院 南充 637001)

(2 云南大学中国西南天文研究所 昆明 650500)

摘要 在天体物理研究中, 准确扣除星际消光与红化的影响对于光学和近红外观测至关重要. 恒星的星际红化信息是揭示其内秉性质的关键. 中国空间站望远镜(Chinese Space Station Telescope, CSST)的光学巡天项目将为科学家提供海量的恒星无缝光谱数据, 而基于这些数据测量恒星的红化信息, 对于进一步测定恒星参数和理解银河系的性质具有重要意义. 提出了一种基于随机森林回归的机器学习方法, 该方法以光谱的归一化流量为输入参数来训练恒星的内秉颜色, 旨在精确估计CSST低分辨率光谱中的恒星红化值. 利用下一代恒星光谱库(Next Generation Stellar Spectral Library, NGSL)模拟CSST低分辨率光谱, 并预测了所提方法的精度, 同时探讨了不同波段和有效温度对结果精度的影响. 基于CSST不同波段的无缝光谱所得到的恒星红化值 $E(g-i)$ (g 、 i 分别为 g 、 i 波段星等)与真实值的比较结果显示, 在光谱信噪比为100时, GU波段的平均误差为0.0005 mag, 标准差为0.0272 mag; GV波段的平均误差为0.0008 mag, 标准差为0.0286 mag; GI波段的平均误差为0.0008 mag, 标准差为0.0271 mag; 全波段的平均误差为0.0003 mag, 标准差为0.0252 mag. 此方法作为CSST科学预研究的一部分, 未来可直接应用于CSST数据, 为CSST的科学研究提供基础支持.

关键词 恒星: 基本参数, 方法: 数据分析, 技术: 光谱学

中图分类号: P144; 文献标识码: A

1 引言

测量恒星的消光与红化信息不仅是获取恒星内秉性质的关键, 也是研究银河系星际尘埃分布与性质的基础. 目前, 基于恒星光谱数据测量恒星消光与红化值的方法大多依赖于恒星大气参数. 例如蓝边缘法^[1-3]被用来确定恒星的内禀颜色. 该方法假设对于给定有效温度和金属丰度的恒星, 在颜色图上绘制时, 其最蓝的恒星没有受到星际消光, 观测颜色与光谱型的内禀颜色一致. 该方法的可行性依赖于样本中包含未经消光的天体, 其观测颜色应为同类型恒星中最蓝的, 并将其观测

颜色视为该类型恒星的内禀颜色. 然而, 蓝边缘法的适用范围有限, 仅适用于特定的恒星有效温度、表面重力和金属丰度范围, 并非所有恒星均适用. 此外, 恒星配对方法^[4-6]通过比较两颗大气参数相同, 但由于消光影响而颜色不同的恒星, 可测量恒星的红化值. 这些方法的准确性依赖于恒星大气参数的精确性. 基于郭守敬望远镜(Large Sky Area Multi-Object Fiber Spectroscopy Telescope, LAMOST)^[7] Data Release 8 M矮星样本和Gaia Early Data Release 3数据, Shen等^[8]通过随机森林回归的机器学习方法训练M矮星的谱指数与内禀

2024-12-02收到原稿, 2025-01-21收到修改稿

^{*}国家自然科学基金项目(12273027)、CSST科学研究课题(CMS-CSST-2021-A08、CMS-CSST-2021-A09)资助

[†]bchen@ynu.edu.cn

颜色的关系, 最终得到了66万颗恒星的精确红化值. 这种方法的优势在于不依赖恒星大气参数, 在没有精确的恒星大气参数的情况下, 也能精确测定恒星的内秉颜色.

中国空间站望远镜(Chinese Space Station Telescope, CSST)是一个2 m级的空间望远镜, 其大视场约为 1.1 deg^2 ^[9–11]. CSST光学巡天将覆盖 17500 deg^2 的天区, 在近十年的巡天时间内, 同时进行多波段测光和无缝光谱巡天的工作. 它包含7个测光波段(NUV、u、g、r、i、z和y), 覆盖波长范围从255到1000 nm. 3个无缝光谱波段分别为GU (255–420 nm)、GV (400–650 nm)和GI (620–1000 nm). CSST无缝光谱巡天将为数亿恒星和星系提供分辨率 R 约为200的高质量光谱.

本文的目的是构建一个全新的软件包, 从CSST低分辨率光谱中精确测量恒星红化值. 我们将直接从恒星光谱中推导出恒星的内禀颜色, 其优点在于独立于恒星模型, 避免了恒星大气参数的测量误差.

2 数据

本研究选用下一代恒星光谱库¹(NGSL)^[12–14]以模拟CSST的无缝光谱. NGSL是基于哈勃空间望远镜(Hubble Space Telescope, HST)上的太空望远镜成像光谱仪(Space Telescope Imaging Spectrograph, STIS)观测数据构建的. 该光谱库包含了使用3种不同光栅(G230LB、G430L和G750L)对恒星进行观测所得到的光谱数据.

NGSL是一个高精度的经验恒星光谱库, 收录了378颗恒星的高分辨率光谱, 分辨率 R 约为1000. 其显著优势在于覆盖的金属丰度、有效温度和表面重力加速度范围广, 这使得NGSL能够代表多种恒星类型和演化阶段. 此外, NGSL的波长覆盖范围也广(从紫外到近红外)、信噪比高, 流量定标精度达3%. 这些特性为本研究提供了可靠的数据支持.

3 方法

3.1 CSST无缝光谱模拟

本研究首先基于NGSL进行CSST无缝光谱的

模拟. 考虑到NGSL与CSST无缝光谱具有不同的分辨率, 我们首先采用高斯卷积方法将NGSL光谱的分辨率降低至250, 以消除分辨率差异造成的影响. 高斯卷积是一种广泛应用于信号处理和图像处理中的滤波技术, 其基于高斯函数的数学性质, 用于模糊、平滑图像或信号. 通过将原始高分辨率光谱与高斯函数进行卷积, 我们可以得到分辨率较低的光谱. 运用这种方法, 我们得到了降低分辨率后的378颗NGSL恒星的光谱. 图1展示了不同光谱类型的恒星在原始低分辨率($R \sim 1000$)和降低分辨率($R = 250$)下的光谱对比.

为了获得恒星的内秉光谱, 我们使用从文献中获得的消光值^[15], 结合Fitzpatrick消光曲线^[16], 从降低分辨率后的光谱($R = 250$)上去除消光, 图2展示了去除消光前后的光谱对比. 可以清晰地看到, 去除消光后光谱发生了显著的变化, 验证了方法的可靠性. 为了保证后期工作中机器学习的质量, 需要模拟真实的CSST观测, 并获取更多的样本. 我们将378颗恒星的干净光谱中每一条恒星光谱随机添加了100个红化值, 考虑到CSST巡天区域主要为中高银纬地区, 这些区域通常不存在高消光区, 因此我们选择 $E(B - V)$ 的范围为0.001–1 mag, 其中 B 和 V 分别为B波段与V波段星等. 添加消光时使用了一致的消光曲线, 以此生成了37800颗恒星的光谱用于后续分析. 在实际观测中, 噪声是不可避免的, 由于目前对CSST无缝光谱观测的信噪比分布尚无明确估计, 我们在本文中采用了信噪比 $\text{SNR} = 100$ 作为观测误差的模拟参数, 以生成模拟光谱数据. 最终, 我们得到了37800条随机加入消光值的模拟光谱, 并给定了观测误差. 将Gong等^[11]提供的CSST响应曲线与光谱进行卷积得到g波段与i波段星等, 假设测光误差为0.008 mag, 我们进一步得到了这些模拟恒星的CSST颜色($g - i$), 其中 g 和 i 分别为g波段和i波段星等. 至此, 我们建立了一个包含37800条CSST模拟光谱和模拟颜色($g - i$)的样本. 为了进行机器学习训练, 我们随机抽取了4000颗恒星, 假定这些恒星是已有的光谱巡天(如LAMOST)中已经知道了其内秉颜色的. 这些恒星被用作我们的训练样本.

¹<https://archive.stsci.edu/prepds/stisngsl/search.php?action=Search>




图 1 NGSL中不同光谱类型恒星的光谱. 灰线和蓝线分别代表原始光谱和降低分辨率后的光谱, 红线为降低分辨率后光谱的连续谱(流量单位任意). 图中标出了光谱的ID与恒星参数: 有效温度 T_{eff} 、金属丰度 $[\text{Fe}/\text{H}]$ 与表面重力加速度无量纲对数值 $\lg [g/(\text{cm} \cdot \text{s}^{-2})]$.

Fig. 1 Spectra of stars with different spectral types in the NGSL. The gray line and the blue line represent the original spectra and the degraded spectra, respectively, and the red line is the continuum of the degraded spectra (the flux unit is arbitrary). The ID of the spectra and stellar parameters: effective temperature T_{eff} , metal abundance $[\text{Fe}/\text{H}]$ and dimensionless logarithmic value of surface gravity acceleration $\lg [g/(\text{cm} \cdot \text{s}^{-2})]$ are also marked in the figure.




图 2 NGSL中不同光谱类型恒星光谱去除消光前后对比图. 灰线和蓝线分别代表原始光谱和降低分辨率后的光谱, 红线为去除消光后的光谱 (流量单位任意). 图中标出了光谱的ID和V波段消光值 A_V .

Fig. 2 The comparison of spectra of stars with different spectral types before and after removing extinction in NGSL. The gray line and the blue line represent the original spectrum and the degraded spectra, respectively, and the red line is the spectrum after removing the extinction (the flux unit is arbitrary). The ID of the spectrum and the extinction value A_V of the V band are also marked in the figure.

3.2 随机森林回归模型建立

随机森林回归模型^[17]是解决回归问题的有效机器学习算法之一. 随机森林由多个决策树预测器组成, 每棵树的构建依赖于随机选择的特征子集, 从而增加了模型的多样性并减少了过拟合的风险. 通过对数据集的多个子样本拟合多棵决策树, 并采用这些树的平均预测值, 随机森林能够有效提高预测的准确性.

本研究中, 我们从37800条恒星光谱样本中随机选取了4000颗恒星作为训练样本, 其中70%用于训练, 30%用于测试, 以验证模型的可靠性. 图3展示了训练样本在恒星大气参数空间中的分布, 训练样本完全覆盖了总样本的参数分布空间. 这在实际情况中是合理的, 因为我们采用的训练样本通常来源于大规模光谱巡天, 例如LAMOST等, 其结果能够较全面地覆盖恒星大气参数空间. 考虑到不同波段对机器学习的影响, 我们将GU、

GV、GI 3个波段分开进行了学习, 同时还测试了将3个波段光谱合并(GU+GV+GI)学习的结果. 本文采用高斯平滑(Gaussian Smoothing)方法来计算连续谱, 将光谱流量除以连续谱流量后得到归一化流量. 然而, 这种连续谱的测定方法在处理特别深或特别宽的谱线区域时表现不佳. 这是因为在计算连续谱时未屏蔽谱线, 导致部分连续谱测量与实际连续谱存在偏离. 不过, 由于这种偏离对同一光谱型的恒星是一致的, 因此不会显著影响模型训练的结果. 图4展示了我们如何从光谱和连续光谱中获得归一化流量, 这里给出了两条光谱的例子. 我们将归一化流量转化为二维矩阵作为输入参数. 测试了不同的随机森林回归模型的参数, 最终确定采用 $n_estimators = 500$ 和 $criterion = 'friedman_mse'$. 对恒星内禀颜色 $(g-i)_0$ 进行训练完成后, 我们将模型应用于全部37800个恒星样本, 得到所有样本的内禀颜色, 从而得到了它们的红化值.




图 3 不同参数空间中训练样本与总样本的分布情况. 子图(a)表示所选取的训练样本与总样本在恒星红化值 $E(B-V)$ 与内禀颜色 $(g-i)_0$ 参数空间中的分布. 蓝点为所有的37800个样本, 红点代表随机抽取的4000个样本. 子图(b)-(d)分别表示训练样本在不同恒星大气参数空间中的分布.

Fig. 3 The distribution of training samples and total samples in different parameter spaces. (a) represents the distribution of the selected training sample and the total sample in the parameter space of stellar redness $E(B-V)$ and intrinsic color $(g-i)_0$. The blue dots are all 37800 samples, and the red dots represent 4000 samples randomly selected. (b)-(d) represent the distribution of training sample in different stellar atmospheric parameter spaces.




图 3 续

Fig. 3 Continued




图 4 归一化流量获取方法. 上图显示了样本光谱(蓝线表示)及其连续光谱(红线表示). 下图表示从样本光谱中扣除连续谱后得到的归一化流量.

Fig. 4 Normalized flux acquisition method. The upper panels show the sample spectrum (blue line) and its continuum spectrum (red line). The lower panels show the normalized flux obtained by subtracting the continuum spectrum from the sample spectrum.

4 结果与讨论

通过前述方法, 我们对GU、GV、GI和全波段分别进行了随机森林回归模型训练, 并计算了随机森林模型的 R^2 分数(保留小数点后3位). R^2 分数是衡量回归模型性能的常用指标, 它反映了模型对数据拟合程度和解释能力. R^2 分数的取值范

围为0至1, 通常以百分比形式表示. 分数越接近1, 表明模型拟合数据的能力越强, 能更好地解释目标变量的变异性; 分数越接近0, 则表明模型的拟合能力越弱. 图5展示了训练得到的随机森林回归模型预测的内禀颜色与测试集内禀颜色的比较, 图中标注了不同波段的名称.




图 5 随机森林模型预测的内禀颜色与测试集内禀颜色的比较. 横轴为测试样本的内禀颜色, 纵轴为随机森林模型预测的内禀颜色. 红线表示1:1线. 图上都标注了随机森林回归模型的 R^2 分数和对应的波段.

Fig. 5 Comparison of the intrinsic color predicted by the random forest model and the intrinsic color of the test set. The transverse axis is the intrinsic color of the test sample, and the longitudinal axis is the intrinsic color predicted by the random forest model. The red line indicates the 1:1 line. The R^2 scores of the random forest regression models and the corresponding bands are labeled on each panel.

从图5可以看出, 所得到的结果 R^2 分数很高, GU、GV、GI波段以及全波段分别为0.992、0.994、0.995和0.995, 这表明目标变量在训练数据上拟合得很好. 在GU、GV和GI波段, 对于温度较高的热星, 即内禀颜色值 $(g-i)_0 < 0$ 时, 随机森林

预测的内禀颜色值与测试样本的内禀颜色值有所偏差, 尤其在更热的恒星中效果不如更冷的恒星. 其中的原因一部分可能是由于NGSL光谱库中热星的光谱数量较少, 导致训练样本数量有限. 当训练样本数量较少时, 模型更容易记住训练数据中

冷星的具体特征和噪声,这也导致了热星的效果不如冷星.对于全波段来说,整体效果不错,这体现在较高的 R^2 分数上,说明模型与数据匹配度很好,训练样本与预测所得内禀颜色差异不大.

将训练好的机器学习模型应用于所有样本中,我们获得了各个波段下37800颗恒星的内禀颜色,并计算得到了它们的红化值.为了更直观地观察预测值与真实值的差异,我们绘制了4个随机森林模型预测的红化值与真实红化值差值分布直方图如图6所示,并分析了4个波段的真实红化值与机器学习得到的预测红化值的差值分布.从4个训练

模型的结果直方图中可以看出,4个模型得到的红化值与真实值之间差值的平均误差和标准差分别为:GU波段的平均误差为0.0005 mag,标准差为0.0272 mag;GV波段的平均误差为0.0008 mag,标准差为0.0286 mag;GI波段的平均误差为0.0008 mag,标准差为0.0271 mag;全波段的平均误差为0.0003 mag,标准差为0.0252 mag.4个模型预测结果与真实值之间差值的平均值几乎为0,所以没有系统差.预测结果与真实值之间差值的弥散体现了我们方法的精度,GV波段弥散最大为0.0286,全波段的弥散最小为0.0252.




图 6 4个随机森林模型预测的红化值与真实红化值差值 $\Delta E(g-i)$ 分布直方图.蓝色直方图表示分布直方图,红线表示高斯曲线.每张图都标有均值(μ)和标准差(σ)以及波段名称.每张图的横轴代表真实红化值与预测红化值之间的差值,纵轴代表数量.

Fig. 6 The distribution histogram of the difference between the predicted reddening value and the real reddening value $\Delta E(g-i)$ of the four random forest models. The blue histogram indicates the distribution histogram and the red line indicates the Gaussian curve. The mean (μ), standard deviation (σ) and the name of the band are labeled in each panel. The transverse axis of each panel represents the difference between the true and predicted reddening values, and the longitudinal axis represents the number.

我们还考虑了温度和红化值精度之间的关系, 并绘制了图7来体现机器学习所得到的红化值与真实红化值之差与恒星大气参数的关系, 不同颜色的密度分布展示了不同参数区间的中值变化趋势, 图中MedAD为中位绝对偏差, RMSD为弥散大小. 相比于F、G和K型恒星, 我们的模型在低温星(如M型星)和高温星(如O型星)的机器学习效果相对较差. 纵观样本37800颗恒星, 有效温度的分布范围是3100–32902 K, 其中M型星占2.5%左右, O型星占3%左右, 导致在极高温和低温处误差较大. 在本研究中, 我们采用归一化光谱作为输入特征、

内禀色指数作为标签, 训练随机森林模型. 为了增强训练数据, 我们通过随机加入消光的方式扩充了样本量. 然而, 这种方法并未显著扩展恒星大气参数的覆盖范围. 由于我们使用的样本中绝大多数恒星的有效温度集中在5000–10000 K, 导致高温区域(热星)的样本显著不足, 从而限制了模型在高温恒星参数估计中的适用性和准确性. 在未来的工作中, 我们将致力于构建更大规模、覆盖更广参数空间的训练样本, 包括冷星和热星, 以进一步优化模型性能并降低最终结果的误差.




图 7 4个随机森林回归模型预测的红化值与真实红化值差值与恒星大气参数的关系. 每一横排表示不同波段训练的结果. 图中标注了波段.

Fig. 7 The relationship between the difference between the predicted reddening value and the real reddening value of the four random forest regression models and the stellar atmospheric parameters. Each horizontal row represents the training results of different bands. The bands are marked in the figure.

CSST无缝光谱观测在极限星等与光谱分辨率方面具有显著优势,相比之下, Gaia XP光谱^[18]蓝端波长范围为330–680 nm,分辨率约为20–60,红端波长范围为640–1050 nm,分辨率约为30–50,而CSST的光谱覆盖波长范围更广,分辨率更高,可以更精细地刻画光谱中的细节特征,从而提供更加丰富的物理信息并有效减少测量误差.此外,CSST无缝光谱的极限星等可达到21 mag^[11],相较于Gaia XP光谱的19 mag,能够探测到更暗的天体.这些特点使得未来基于CSST无缝光谱所建立的消光图在空间分辨率、精度和覆盖范围上具有明显的优势,有望显著提升消光测量的可靠性与精确性,同时为研究银河系的三维结构和恒星形成过程提供更加全面的数据支持.

5 总结

恒星参数的测量是恒星物理以及银河系性质研究的基石,而红化值作为与恒星性质密切相关的重要基本参数,对于天体物理研究具有重要意义. CSST光谱巡天项目为研究人员提供了数以亿计的恒星无缝光谱,这为恒星物理性质的研究提供了宝贵数据. 本研究利用NGSL中的光谱模拟CSST低分辨率光谱,并在单个光谱中随机添加噪声和消光值,以构建大的恒星样本库. 随后,通过随机森林回归进行机器学习,建立了归一化流量与内禀颜色之间的关系. 模型的拟合程度通过 R^2 分数进行评价,其中GU波段的 R^2 分数最低为0.992,全波段最高为0.995,表明目标变量在训练数据上拟合得很好. 尽管在热星部分存在一些小的偏差,主要原因可能是热星训练样本数量不足,同时也反映了恒星对不同波段响应曲线的敏感度存在差异.

我们的结果显示4个模型得到的红化值与真实值之间差值的平均误差和离散度分别为: GU波段的平均误差为0.0005 mag,标准差为0.0272 mag; GV波段的平均误差为0.0008 mag,标准差为0.0286 mag; GI波段的平均误差为0.0008 mag,标准差为0.0271 mag; 全波段的平均误差为0.0003

mag,标准差为0.0252 mag. 我们结果的系统差可以忽略不计,精度可达到0.02–0.03 mag,表明我们的方法取得了良好的效果,能够获得相对准确的恒星红化值. 本工作独立于恒星模型,避免了恒星参数的测量误差,提高了数据处理效率,同时保证了结果的精确度. 在未来的工作中,可以将这种方法应用到真实的CSST数据中,为CSST后续科学奠定基础.

致谢 感谢审稿人提出的宝贵建议,使得文章质量有了显著提高.

参考文献

- [1] Ducati J R, Bevilacqua C M, Rembold S B, et al. *ApJ*, 2001, 558: 309
- [2] Xue M Y, Jiang B W, Gao J, et al. *ApJS*, 2016, 224: 23
- [3] Deng D S, Sun Y, Jian M J, et al. *AJ*, 2020, 159: 208
- [4] Yuan H B, Liu X W, Xiang M S. *MNRAS*, 2013, 430: 2188
- [5] Zhang R Y, Yuan H B. *ApJL*, 2020, 905: 20
- [6] Zhang R Y, Yuan H B. *ApJS*, 2023, 264: 14
- [7] Deng L C, Newberg H J, Liu C, et al. *RAA*, 2012, 12: 735
- [8] Shen H, Chen B Q, Guo H L, et al. *MNRAS*, 2022, 514: 4398
- [9] Zhan H. *SSPMA*, 2011, 41: 1441
- [10] Cao Y, Gong Y, Meng X M, et al. *MNRAS*, 2018, 480: 2178
- [11] Gong Y, Liu X K, Cao Y, et al. *ApJ*, 2019, 883: 203
- [12] Gregg M D, Silva D, Rayner J, et al. *The 2005 HST Calibration Workshop: Hubble after the Transition to Two-Gyro Mode*. Baltimore: NASA, 2006: 209
- [13] Heap S R, Lindler D. *Revived STIS. II. Properties of Stars in the Next Generation Spectral Library*. American Astronomical Society Meeting Abstracts 215th, Washington DC, January 3-7, 2010
- [14] Heap S R, Lindler D. *Calibration and Standardization of Large Surveys and Missions*. San Francisco: ASPCS, 2012, 503: 211
- [15] Koleva M, Vazdekis A. *A&A*, 2012, 538: A143
- [16] Fitzpatrick E L. *PASP*, 1999, 111: 63
- [17] Breiman L. *Machine Learning*, 2001, 45: 5
- [18] Andrae R, Fouesneau M, Sordo R, et al. *A&A*, 2023, 674: A27

Estimating Stellar Reddening Values from CSST Low Resolution Spectra

XIAO Yao¹ CHEN Bing-qiu² LI Jing¹

(¹ School of Physics and Astronomy, China West Normal University, Nanchong 637001)

(² South-Western Institute for Astronomy Research, Yunnan University, Kunming 650500)

ABSTRACT In astrophysical research, accurately accounting for the effects of interstellar extinction and reddening is crucial for optical and near-infrared observations. Information on the interstellar reddening of stars is essential for uncovering their intrinsic properties. The optical survey project of the Chinese Space Station Telescope (CSST) will provide us with a vast amount of very low resolution spectral data for stars, and measuring the reddening information of stars based on this data is of great significance for further determining stellar parameters and understanding the nature of the Milky Way. This study proposes a machine learning method based on random forest regression, which uses the normalized flux of spectra as input parameters to train the intrinsic colors of stars, aiming to accurately estimate the reddening values of stars in very low resolution CSST spectra. This study simulated CSST spectra using the Next Generation Spectral Library (NGSL), predicted the accuracy of the proposed method, and also discussed the impact of different bands and effective temperatures on the accuracy of the results. The comparison between the reddening values $E(g-i)$ obtained from the seamless spectra of different CSST bands and the true values shows that at a spectral signal-to-noise ratio of 100, the average deviation for the GU band is 0.0005 mag with a standard deviation of 0.0272 mag; for the GV band, the average deviation is 0.0008 mag with a standard deviation of 0.0286 mag; for the GI band, the average deviation is 0.0008 mag with a standard deviation of 0.0271 mag; and for the full band, the average deviation is 0.0003 mag with a standard deviation of 0.0252 mag. This method, as part of the scientific pre-research for CSST, can be directly applied to CSST data in the future, providing basic support for scientific research on CSST.

Key words stars: fundamental parameters, methods: data analytical, techniques: spectroscopic