

doi: 10.3969/j.issn.1000-8349.2025.02.XX

基于光谱的恒星大气参数测量综述

张译心^{1,2}, 葛健¹

(1. 中国科学院 上海天文台, 上海 200030; 2. 中国科学院大学 天文与空间科学学院, 北京 100049)

摘要:

恒星大气参数, 如有效温度、表面重力和金属丰度, 是研究恒星性质与演化的基础。随着天文进入大数据时代, 如何从海量光谱中高效提取这些参数成为重要问题。近年来, 相关研究在数据规模和分析方法推动下取得显著进展, 主要形成了光谱特征分析、模板匹配、机器学习、深度学习及物理约束的数据驱动混合方法等技术路线。相关方法在参数测量精度、处理效率和适用范围等方面各具优势, 也面临参数空间覆盖、物理可解释性等挑战。

关键词: 恒星大气参数, 大规模光谱巡天, 深度学习

中图分类号: P145.2 **文献标识码:** A

1 引言

1.1 恒星大气参数的科学意义

恒星是宇宙的基本组成, 而测量恒星的大气参数是我们了解恒星的重要途径。恒星大气参数决定了其物理状态、演化路径和最终命运, 对理解恒星本身的性质具有重要意义。从更大尺度上来说, 恒星大气参数是研究星族合成、银河系的动力学与化学演化以及系外行星形成的基础^[1-3]。恒星大气主要由有效温度、表面重力和金属丰度共同刻画了恒星的大气性质, 并直接影响其光谱的形态。恒星光谱由连续谱和叠加其上的吸收线(或发射线)构成。连续谱主要由恒星表面的黑体辐射决定, 而吸收线的强度和形态与大气的温度、密度以及元素丰度紧密相关。针对恒星光谱的研究已有悠久的历史。自十九世纪以来, 天文学家首先通过对恒星光谱的记录与分类揭示了恒星的基本性质, 例如哈佛光谱分类体系的建立为理解恒星类型和演化奠定了框架。随着量子力学的发展, 人们逐渐能够从物理原理解释光谱线的形成机制, 从而实现对恒星温度、压力和化学组成的定量刻画。

恒星大气参数的测量方法经历了由传统到现代的持续发展。早期工作主要依赖谱线强度与经验关系, 通过分析巴尔末线、金属线等光谱特征推导恒星的有效温度、表面重力和

收稿日期: YYYY-MM-DD; 修回日期: YYYY-MM-DD

资助项目: 太空探源专项 GJ11030405

通讯作者: 葛健, jge@shao.ac.cn

金属丰度。随后,随着恒星大气模型与合成光谱库的完善,模板匹配方法得到广泛应用,它通过将观测光谱与经验或理论光谱库进行比较来反演大气参数。在大规模巡天时代,基于理论模型的传统方法在效率和精度上的局限逐渐显现。研究方向转向机器学习方法,实现了在海量光谱中的快速、自动化参数提取。近年来,伴随深度学习与人工智能的快速发展,基于深度神经网络的方法在恒星光谱分析中展现出强大的特征提取与非线性拟合能力。因此迅速地成为了处理大样本数据的重要工具。这些方法的演进不仅提升了参数推导的精度与效率,也为未来多波段、多信使数据的综合分析奠定了基础。

1.2 恒星大气参数测量的核心科学问题

高分辨率光谱仪的发展使恒星大气参数的精确测定成为可能,而光纤多目标光谱仪的广泛应用则进一步推动了恒星光谱观测由小样本研究转向大规模巡天。过去二十年间,SDSS/SEGUE、APOGEE 和 LAMOST 等项目在不同波段和分辨率条件下积累了海量恒星光谱数据^[4,5],为恒星参数测量提供了前所未有的数据基础,也对参数提取方法的自动化、稳健性和适用范围提出了更高要求。

在这一背景下,如何从实测光谱中快速、准确地提取恒星大气参数,已成为现代恒星物理中的关键技术问题。当前研究面临的核心挑战主要体现在三个方面。首先,参数提取精度强烈依赖于数据质量,不同巡天在分辨率、波段覆盖和信噪比方面差异显著,尤其在低分辨率或低信噪比条件下,弱谱线信息容易受损,因此如何在有限数据质量下可靠恢复参数仍是重要问题。其次,不同方法的精度指标往往建立在不同的数据条件、样本范围和评价方式之上,因此其结果通常缺乏直接可比性,如何合理评估不同方法的性能并依据观测条件选择合适策略,是综述中必须讨论的问题。再次,大规模巡天覆盖了从 OBA 型热星到 M 型冷星、从富金属到极端贫金属恒星的广阔参数空间,不同类型恒星的主导谱线特征和建模难点并不相同,因此方法的适用范围、泛化能力以及物理可解释性同样值得关注。

基于上述背景,本文对基于光谱的恒星大气参数测量方法进行系统综述,重点讨论不同方法在大规模光谱巡天中的适用条件、精度特征与局限性。全文结构如下:第 2 节介绍主要恒星光谱巡天及其数据特征;第 3 节综述恒星大气参数测量的主要方法与基本原理;第 4 节讨论这些方法在主要巡天中的应用及其表现;第 5 节总结当前进展,并展望未来的发展方向。

2 相关光谱巡天及其对参数测量方法发展的推动

大规模恒星光谱巡天为恒星大气参数测量提供了重要的数据基础,也推动了相关方法的发展。不同巡天在波段覆盖、光谱分辨率、目标样本和样本规模等方面存在显著差异,因此其参数测量任务和技术路线并不相同。一般而言,低分辨率大样本巡天更强调自动化、稳健性和处理效率,高分辨率巡天则更适合精细参数和多元素丰度测量。

2.1 Sloan Digital Sky Survey

2.1.1 SEGUE

斯隆银河系理解与探索扩展计划 (Sloan Extension for Galactic Understanding and Exploration, SEGUE) 是 SDSS 中的重要恒星光谱巡天项目^[4]。该项目获取了数十万颗银河系恒星的光学光谱, 分辨率约为 $R \sim 2000$, 波长范围覆盖 3900–9000 Å, 样本涵盖多种主序星和演化星。此类中低分辨率、大样本数据适合开展面向基本大气参数的自动化测量。SDSS DR9 基于 SEGUE Stellar Parameter Pipeline (SSPP) 统一发布了有效温度、表面重力和金属丰度等参数产品^[6]。因此, SEGUE 代表了低分辨率恒星巡天中自动化参数管线的典型实践。

2.1.2 APOGEE

阿帕奇点天文台银河演化实验 (Apache Point Observatory Galactic Evolution Experiment, APOGEE) 是 SDSS 中的核心恒星光谱巡天之一^[5]。该巡天在近红外 H 波段 (约 1.51–1.70 μm) 开展大规模高分辨率观测, 光谱分辨率约为 $R \sim 22500$ 。相较于低分辨率巡天, 其光谱能够分辨更多谱线细节, 因此不仅可测量基本大气参数, 还可进一步测量多种元素丰度。其自动化处理主要依赖 ASPCAP (APOGEE Stellar Parameters and Chemical Abundances Pipeline), 该管线通过将观测光谱与预先计算并经经验校准的综合光谱库进行比较, 推导视向速度、 T_{eff} 、 $\log g$ 、整体金属丰度以及二十余种元素丰度^[7–9]。因此, APOGEE 体现了高分辨率巡天中基于光谱合成与系统光谱库比较的自动化参数测量路线。

2.2 GALAH

GALAH (Galactic Archaeology with HERMES) 是一项面向银河系考古学研究的大型光谱巡天^[10]。该巡天使用 HERMES 光谱仪在四个不连续的光学波段开展观测, 分辨率约为 $R \sim 28000$ ^[10]。其较高分辨率和多波段覆盖使其不仅能够测量基本大气参数, 还能分析多种元素丰度。更重要的是, GALAH 展示了较为典型的方法学演进: DR1 和 DR2 采用基于 The Cannon 的数据驱动管线^[11], DR3 转向光谱合成方法, DR4 则进一步采用由物理建模生成训练集并结合神经网络快速插值的混合策略。因而, GALAH 清楚体现了高分辨率多元素丰度测量背景下, 参数测量方法从数据驱动到物理建模再到混合方案的发展过程。

2.3 GAIA

盖亚任务 (GAIA) 是由欧洲航天局主导的空间任务^[12, 13]。对于恒星参数测量而言, 其相关信息主要来自 BP/RP 低分辨率测光光谱和 RVS 光谱数据, 其中 RVS 的分辨率约为 11500, 波段范围为 847–874 nm。由于数据规模极大且信息来源多样, GAIA 的参数测量依赖高度自动化的参数化框架。RVS 光谱的参数测量主要通过 GSP-Spec 完成, 该框架结合了 FERRE、MATISSE^[14, 15] 和神经网络等算法, 对光谱进行自动化处理, 并推导 T_{eff} 、 $\log g$ 、总金属丰度 $[M/H]$ 、 $[\alpha/\text{Fe}]$ 、径向速度及若干元素丰度^[16]。因此, GAIA 展示了多算法联合、面向超大样本数据的自动化参数化思路。

2.4 GAIA-ESO

GAIA-ESO 是一项基于甚大望远镜 FLAMES 光纤多目标光谱仪的公共巡天^[17]。该巡天同时使用 GIRAFFE 和 UVES 两种分辨率不同的光谱仪获取银河系恒星光谱^[18]。其中,

GIRAFFE 更适合视向速度、基本大气参数和部分元素测量, UVES 则更适合高精度参数和稀有元素研究。由于同一巡天内部同时包含中高分辨率和高分辨率数据, GAIA-ESO 为比较不同分辨率条件下参数测量能力及方法选择提供了较好的观测基础。

2.5 LAMOST

郭守敬望远镜 (Large Sky Area Multi-Object Fiber Spectroscopic Telescope, LAMOST) 是中国主导的大型地面光学巡天项目。其低分辨率标准模式可在 3700–9100 Å 波段获得分辨率约为 $R \sim 1800$ 的光谱, 中分辨率模式分辨率约为 7500, 并具备单次曝光获取 4000 条光谱的能力^[19]。这一观测模式使其成为典型的大样本恒星光谱巡天平台。对于恒星参数测量而言, LAMOST 的海量低分辨率数据对参数提取的自动化、效率和稳健性提出了很高要求, 而中分辨率数据则进一步提升了谱线分辨能力和元素丰度测量能力。依托其大样本数据, LAMOST 已成为推动低分辨率恒星参数自动化测量方法持续发展的代表性巡天之一^[20–24]。

总体而言, 不同巡天在分辨率、波段覆盖、样本规模和目标样本类型等方面的差异, 直接影响了恒星参数测量任务及其技术路线。低分辨率大样本巡天推动了自动化模板匹配和数据驱动方法的发展, 高分辨率巡天则更依赖光谱合成和物理建模方法。因而, 在综述恒星大气参数测量方法时, 有必要结合主要巡天的数据特征理解相关方法的形成与演进背景。

3 恒星大气参数测量原理

3.1 物理模型驱动法

3.1.1 常用的谱线特征

恒星光谱记录了恒星大气中的辐射转移信息, 是约束恒星物理性质与化学组成的关键观测数据。不同的大气条件会在光谱中留下可诊断的特征, 因此可据此反演有效温度 (T_{eff})、表面重力 ($\log g$) 与金属丰度 ($[\text{Fe}/\text{H}]$)。

在恒星光谱中, 连续谱和吸收线都可用于参数测量。Balmer 断裂 ($\lambda \approx 3646 \text{ Å}$) 是较显著的诊断特征, 对 T_{eff} 和 $\log g$ 均敏感: 在较高温度下, 该特征主要随 T_{eff} 变化; 在较低温度下, 则对 $\log g$ 更为敏感。对于吸收线, 氢 Balmer 线在晚型星中可作为温度指针, 在早型星中还对 $\log g$ 表现出一定敏感性。金属线方面, 一些对温度敏感而受压力和金属丰度影响较小的谱线可用于估计 T_{eff} ; 强金属线的翼部形状受压力展宽影响明显, 可作为 $\log g$ 指标; 在 T_{eff} 和 $\log g$ 确定后, 金属吸收线强度则可进一步用于约束 $[\text{Fe}/\text{H}]$ 。

基于谱线特征测量恒星大气参数的优点在于高效且易于批量处理。实践中, 通常选取若干对参数敏感的特征量, 如等值宽度、线深比和氢线翼部宽度, 并利用标准星样本建立“特征—参数”标定关系, 再推广至更大样本。其主要局限在于参数耦合以及系统误差的影响, 例如湍流、旋转展宽、仪器分辨率和谱线混叠等因素都可能影响测量结果。

3.1.2 恒星模板匹配

相较于仅依赖少数谱线特征的方法, 模板匹配通过在整个观测波长范围内将目标光谱与一组已知参数的模板光谱进行比较, 从而推断恒星的大气参数。该方法能够综合利用整




图 1 恒星大气有效温度和巴尔默线等值宽度的关系 (以 $H\gamma$ 为例)^[25]。三条曲线分别对应不同表面重力条件 ($\log g = 4, 3$ 和 2)。 $H\gamma$ 线随温度升高先增强后减弱, 并在低温端主要依赖于 T_{eff} 。图片来源于 [25]。

谱信息, 因此通常具有更好的稳定性和精度。

模板匹配的关键在于模板谱库。按来源不同, 模板一般分为经验模板和理论模板两类。经验模板来自实际观测, 通常能较好反映真实谱线特征, 但参数空间覆盖可能有限; 常用谱库包括 MILES^[26]、ELODIE^[27] 和 XSL^[28]。理论模板则基于恒星大气模型和辐射转移计算生成, 能够在更广泛的参数空间内提供均匀覆盖, 但其精度依赖于模型物理假设以及原子、分子数据的完备性; 常用谱库包括 PHOENIX^[29] 和 MARCS^[30]。

在给定模板库之后, 需要采用统计方法确定最优参数。早期研究多采用最小 χ^2 拟合, 其定义为:

$$\chi^2 = \sum_{\lambda} \left(\frac{F_{\text{obs}}(\lambda) - F_{\text{model}}(\lambda)}{\sigma(\lambda)} \right)^2 \quad (1)$$

其中 F_{obs} 为观测流量, F_{model} 为模型流量, σ 为观测误差。通常以参数网格中使 χ^2 最小的解作为测量结果。随着光谱质量和数据规模的提升, 研究者进一步引入贝叶斯推断框架, 并利用马尔可夫链蒙特卡洛 (MarkovChainMonteCarlo, MCMC) 等采样方法在后验分布中探索参数空间, 以更好地表征参数相关性与不确定性, 并引入先验信息提升拟合的鲁棒性。

模板匹配是恒星大气参数测量中最常用的方法之一, 具有物理解释性强的优点, 但其计算效率通常低于机器学习方法, 且结果在一定程度上依赖于模板谱库和模型假设。

3.2 数据驱动机器学习法

随着光谱巡天规模和天文数据量的迅速增长, 基于数据驱动的机器学习与深度学习方法已逐渐成为提取恒星大气参数的重要手段。这类方法的核心思想是利用已知参数样本构建训练集, 自动学习光谱与恒星大气参数之间的映射关系, 并将其推广到未知样本, 从而实现高效的参数测量。

3.2.1 机器学习

传统机器学习是数据驱动建模的重要基础,在中小规模数据场景中通常具有计算效率高、实现相对简单和可解释性较强等优点。在恒星光谱分析中,常用方法包括线性回归、支持向量机 (Support Vector Machine, SVM)^[31]、决策树^[32]与随机森林^[33]、主成分分析 (Principal Component Analysis, PCA)^[34]以及 K 近邻算法 (K-Nearest Neighbours, KNN)^[35]等。

其中,一部分方法主要用于特征提取与降维。最典型的是 PCA,它通过线性变换将高维光谱压缩为少数几个主成分,在降低数据维度的同时保留主要信息。PCA 已被广泛应用于 SDSS/SEGUE 光谱分析,尤其在 SEGUE 恒星参数管线 (SSPP) 中发挥了重要作用^[36],也被用于基于 LAMOST 光谱的 T_{eff} 、 $\log g$ 和 $[\text{Fe}/\text{H}]$ 估计^[37]。

另一类方法则直接建立光谱与参数之间的映射关系。线性回归适用于较简单的近似关系;支持向量机可用于非线性参数回归,并已被用于从高维恒星光谱中提取有效温度、表面重力和金属丰度^[38];决策树及其集成形式,如随机森林和梯度提升方法,能够刻画更复杂的非线性关系,并在 LAMOST 等巡天数据中表现出较好的精度与鲁棒性^[39];K 近邻方法则基于样本相似性进行预测,在样本规模适中且数据质量较高时通常能够取得较好效果^[40]。总体而言,传统机器学习方法在数据量有限或需要较明确模型解释时仍具有重要价值。

3.2.2 深度学习

深度学习以人工神经网络 (Artificial Neural Network, ANN) 为基础,能够通过多层非线性变换直接从原始光谱中学习高维特征表示,从而避免人工特征构造,并已在大规模巡天数据中成功用于恒星大气参数和多元素丰度建模^[41]。

在 ANN 基础上,卷积神经网络 (Convolutional Neural Network, CNN)^[42]能够自动提取局部谱线特征,已被广泛应用于恒星大气参数回归与光谱分类任务^[43, 44]。循环神经网络 (Recurrent Neural Network, RNN) 及其改进形式长短期记忆网络 (LSTM)^[45]和门控循环单元 (GRU)^[46]更适合处理具有序列结构的光谱数据,并已用于 LAMOST 光谱中的参数建模^[47, 48]。近年来,生成对抗网络 (Generative Adversarial Networks, GANs)^[49]被用于光谱数据增强与模拟^[50],而 Transformer 模型^[51]则利用自注意力机制建模不同波长点之间的全局依赖关系,并在恒星光谱分析中展现出较好的效率与鲁棒性^[52]。

总体而言,深度学习方法显著提升了恒星大气参数测量的自动化程度和拟合能力。CNN、RNN 等基础结构能够直接建模光谱与参数之间的复杂非线性关系,适合大规模巡天数据的批处理需求;GAN 和 Transformer 等模型则为光谱增强和复杂模式识别提供了新的技术路径。这些方法已在多个光谱巡天中得到应用,如 LAMOST^[48, 52, 53]、SDSS^[54, 55]和 Gaia-RVS^[56, 57]。




图2 基于BCD方法得到的 T_{eff} 与文献中其他方法结果的比较，左图为矮星与巨星，右图为超巨星^[62]。整体上，BCD标定结果与其他独立温标保持一致。图片来源于[62]。

4 恒星大气参数测量的进展

4.1 物理模型驱动的恒星大气参数提取

4.1.1 基于光谱特征的方法

截至目前，基于光谱特征测量恒星大气参数的方法已得到广泛研究。需要指出的是，不同光谱型恒星对应的大气物理条件差异显著，因此相关诊断方法具有明显的参数空间依赖性。对于FGK型恒星，连续谱形状、巴尔末线以及大量金属吸收线通常能够为 T_{eff} 、 $\log g$ 和 $[\text{Fe}/\text{H}]$ 提供较稳定的约束；而对于更高温的O、B、A型热星，参数提取则更依赖于巴尔默断裂、巴尔末线轮廓、He线及不同电离态金属线的联合诊断^[58-60]。

在恒星光谱中，巴尔默断裂是一个重要诊断特征。基于这一特征，Barbier、Chalonge和Divan提出了Barbier–Chalonge–Divan (BCD) 光谱测光系统^[58, 59]。该方法以断裂强度和断裂位置等观测量刻画巴尔默断裂，对数据质量和模型假设的要求相对较低，因此在OBA型热星有效温度标定中得到了持续应用^[61-63]。例如，Zorec、Cidale和Arias等人基于217颗早期型星建立了统一的 $T_{\text{eff}}(\lambda_1, D)$ 标定，并量化了金属丰度对断裂强度的系统影响，使BCD作为 T_{eff} 指针的精度达到约5%^[63]。除直接测量巴尔默断裂外，跨断裂颜色指数也可作为温度和重力的指示量。例如，在Strömgren $uvby-\beta$ 系统中， c_1 联合 $\text{H}\beta$ 线强可在早期型星样本中较好实现 T_{eff} 和 $\log g$ 的解耦^[64]；类似思想也被用于现代巡天的滤光系统设计中^[65]。对于更高温的O/B型星，后续研究进一步发展出基于NLTE模型大气的定量光谱分析框架，例如将FASTWIND与遗传算法结合，对氢线和氦线轮廓进行自动化联合拟合，从而推动热星参数测量由人工分析向自动化发展^[60]。

巴尔末吸收线也是测量恒星 T_{eff} 的重要指针，特别适用于F、G、K型星^[66-68]。与连续谱特征相比，这一指针受星际消光影响较小，并且通常对温度变化更为敏感，而对 $\log g$ 的依赖较弱。随着高精度角直径测量和总辐射通量估计的发展，已有研究将 $\text{H}\alpha$ 推导的温度与直接测量结果进行比较，结果表明两者整体高度相关，但仍存在一定系统偏差，典型差异约为数十K^[69]。

然而，在利用巴尔末线进行温度诊断时，仍存在两类主要不确定性：一是宽线轮廓归

一化较为复杂，二是理论模型本身仍存在系统误差。Ludwig、Behara、Steffen 等人比较了一维与三维恒星大气模型，指出三维模型预测的巴尔末线形状无法被任何一维模型完全再现，对应的 T_{eff} 差异可达约 300 K^[70]。进一步考虑非 LTE 效应后，三维非 LTE 模型与传统 1D LTE 模型在巴尔末线翼部上的差异仍可能导致百 K 量级的温度偏差^[71]。

除温度外，巴尔末线在部分参数空间中还可用于表面重力诊断。在 $T_{\text{eff}} \lesssim 9000$ K 的恒星中，其对 $\log g$ 的敏感性迅速减弱；但在更热的 A、B 型星以及白矮星中，巴尔末线翼部随 $\log g$ 的变化明显，因此被广泛用于重力测量。相较于简单的等值宽度指标，直接拟合谱线轮廓，尤其是远翼部分，通常能够提供更可靠的结果^[72, 73]。

金属线在恒星光谱分析中同样提供了重要的诊断信息。早期研究表明，弱金属线因位于增长曲线的线性区，对微湍流的依赖较小，可作为有效的大气参数诊断工具^[74-76]。其中，温度敏感与温度相对不敏感谱线的线深比是常用的温度指针；近年来，该方法已被系统应用于高分辨率红外光谱中的 T_{eff} 测量^[77]。结合不同元素及不同电离态的谱线信息，还可在同一光谱中同时约束 T_{eff} 、 $\log g$ 和 $[\text{Fe}/\text{H}]$ ^[78]。此外，金属线在短波段的整体吸收更强，这使得某些颜色指数也对金属丰度和温度敏感，并被广泛用于测光参数诊断^[79-81]。总体而言，金属线不仅是化学丰度的直接示踪，也有助于打破参数之间的退化并提高多参数联合测量的稳定性。

4.1.2 基于模版匹配的方法

在大规模光谱巡天中，恒星参数处理管线通常以模板匹配为核心。该方法通过将观测光谱与预先构建的合成光谱库或经验模板进行比较，并最小化两者之间的差异，从而同时推导恒星大气参数。由于能够综合利用整谱信息并适用于海量样本的自动化处理，模板匹配已成为现代巡天中最常用的参数提取手段之一。下面主要介绍几项典型巡天中基于模板匹配的恒星参数管线及其代表性结果。

SDSS/SEGUE 所使用的恒星参数管线 SSPP^[36] 结合了多种方法推导恒星参数，数据来源包括 SDSS/SEGUE 光谱和 SDSS 的 *ugriz* 测光。其特点是并行运行多种算法，并通过比较不同方法的结果经验性评估参数不确定性。在模板匹配实现中，SSPP 采用了两套光谱模型库：一套是包含宽带色指数信息的 k24 网格^[82, 83]，另一套是不依赖光度信息、仅包含归一化光谱的 ki13 网格。前者能够利用光度增强温度约束，后者则可降低星际消光和光度误差的影响。对于 $S/N > 10$ 且 $4500 \text{ K} \lesssim T_{\text{eff}} \lesssim 7500 \text{ K}$ 的样本，SSPP 的典型内部误差约为 $\sigma(T_{\text{eff}}) \lesssim 75 \text{ K}$ 、 $\sigma(\log g) \lesssim 0.2 \text{ dex}$ 、 $\sigma([\text{Fe}/\text{H}]) \lesssim 0.1 \text{ dex}$ ；与高分辨率光谱比较时，其外部精度约为 $\sigma(T_{\text{eff}}) \lesssim 117 \text{ K}$ 、 $\sigma(\log g) \lesssim 0.26 \text{ dex}$ 、 $\sigma([\text{Fe}/\text{H}]) \lesssim 0.22 \text{ dex}$ ^[36]。在极贫金属区，SSPP 对 $[\text{Fe}/\text{H}] < -2.0$ 的恒星存在约 0.15 dex 的系统高估，说明模板库在参数空间边缘的完备性对测量精度具有重要影响^[36]。

LAMOST 针对不同目标星类型和不同分辨率数据构建了多套模板匹配管线，包括面向低分辨率 AFGK 型恒星的 LASP^[84]、面向 M 型星的 LASPM^[85]、面向中分辨率 A 型星的 LAMA^[86]，以及北京大学团队开发的 LSP3^[87]。

其中，LAMOST 恒星参数管线 LASP 主要面向低分辨率 AFGK 型恒星^[84]。其核心采用




图3 LSP3 有效温度测量精度随信噪比的变化关系。精度通过重复观测结果比较估算，样本进一步按有效温度、金属丰度以及表面重力进行划分。图片来源于^[87]。

相关函数插值法 (CFI) 和 ULYSS^[88, 89] 两种算法：CFI 先快速给出粗略参数，ULYSS 再基于 χ^2 最小化进行精细拟合。其模板分别基于 Kurucz/ATLAS9 合成光谱库^[90] 和 ELODIE 经验光谱库^[27, 91]。通过与 PASTEL 星表中共有恒星比较，LASP 的参数精度约为 $\sigma(T_{\text{eff}}) \approx 110 \text{ K}$ 、 $\sigma(\log g) \approx 0.19 \text{ dex}$ 和 $\sigma([Fe/H]) \approx 0.11 \text{ dex}$ ^[84, 92]。

LSP3 (LAMOST Stellar Parameter Pipeline at Peking University) 是一条基于模板匹配的恒星参数管线，用于从 LAMOST 光谱中测定径向速度和恒星大气参数^[87]。在径向速度测量中，LSP3 利用 ELODIE 模板进行交叉相关；在大气参数测量中，则采用与 LAMOST 分辨率相近且具有较好光度定标的 MILES 光谱库作为模板^[26, 27, 91, 93]。参数推导采用加权平均与 χ^2 最小化两种方法，其中当前版本以加权平均结果为主。对 FGK 型恒星的测试表明，对于 FGK 矮星和大多数 G/K 巨星，其典型精度分别可达 $\sigma(T_{\text{eff}}) \lesssim 150 \text{ K}$ 、 $\sigma(\log g) \lesssim 0.25 \text{ dex}$ 和 $\sigma([Fe/H]) \lesssim 0.15 \text{ dex}$ ^[87]。在部分次巨星中， $\log g$ 可能因边界效应而偏高约 0.4 dex，而在超太阳丰度区间， $[Fe/H]$ 也可能存在 0.05–0.1 dex 的低估（见图 3）。

针对 M 型星，LAMOST 团队开发了专门的 LASPM 管线^[85]。由于 M 型星光谱受分子带主导，常规 AFGK 管线难以直接适用，因此 LASPM 采用基于 PHOENIX 框架发展的 BT-Settl 理论模型光谱库^[94]，先寻找最佳匹配模板，再以多个最佳模板的线性组合作为初始条件，通过最小 χ^2 方法获得最终参数。基于重复观测的检验表明，其典型精度约为 $\sigma(T_{\text{eff}}) \lesssim 118 \text{ K}$ 、 $\sigma(\log g) \lesssim 0.20 \text{ dex}$ 、 $\sigma([Fe/H]) \lesssim 0.29 \text{ dex}$ ^[85]。针对中分辨率 A 型星，LAMOST 还开发了 LAMA 管线^[86]，其同样采用最小 χ^2 方法，并利用基于 Kurucz/ATLAS9 模型构建的合成模板光谱进行拟合^[90]。

Gaia DR3 除天体测量和测光外，还大规模提供了 BP/RP 棱镜光谱和 RVS 光谱，为恒星

参数推导提供了新的数据基础^[95]。在 Gaia 数据分析管线中, General Stellar Parametrizer from Photometry (GSP_Phot) 模块基于 BP/RP 光谱采用模板匹配方法推导恒星参数。为覆盖 Gaia 的参数空间, 该模块使用了 MARCS、PHOENIX、A 型星和 OB 型星四套模板光谱库^[30, 96–98], 并在 MCMC 框架下搜索与观测谱最一致的参数解。验证结果表明, 该方法在 FGK 星的有效温度测量上具有较高精度, 典型为 $T_{\text{eff}} \sim 120 \text{ K}$; 但在低金属丰度和低信噪比条件下, $[\text{Fe}/\text{H}]$ 的估计容易出现系统偏差。当源亮度为 $G < 16$ 等时, 其金属丰度中位绝对偏差约为 0.2 dex , 而对于更暗的恒星, GSP_Phot 给出的 $[\text{Fe}/\text{H}]$ 可能出现约 0.6 dex 的系统性低估, 离散度可达 0.5 dex ^[95]。

除面向 AFGKM 型恒星的大规模巡天管线外, 针对更高温的 O 型星, 近年来也发展出较成熟的半自动化分析工具。例如, Holgado、Simón-Díaz、Barbá 等人基于 IACOB-BROAD 和 IACOB-GBAT/FASTWIND, 对 128 颗现代 O 型标准星开展了均一化光谱分析, 系统给出了 O 型星的光谱参数, 并更新了光谱型与 T_{eff} 、 $\log g$ 之间的标定关系^[99]。这表明热星参数测量已逐步从个例研究走向更大样本的系统分析。

4.2 数据驱动的恒星大气参数提取

随着恒星光谱数据规模的快速增长, 数据驱动方法逐渐成为大规模巡天中重要的参数提取手段。相较于传统模板匹配和全谱拟合方法, 这类方法能够直接从大样本观测数据中学习光谱与恒星参数之间的映射关系, 并在模型训练完成后实现高效推理, 因此在 LAMOST 等海量低分辨率和中分辨率光谱数据处理中具有明显优势。

4.2.1 基于机器学习的方法

传统机器学习方法已较早应用于天文数据分析, 并被广泛用于特征提取、降维和回归建模^[100, 101]。在恒星大气参数测量中, 主成分分析 (PCA)、支持向量机和随机森林等方法具有较强代表性。

较早的研究已将 PCA 与神经网络结合用于恒星光谱分类^[102]。PCA 的主要作用是压缩高维光谱信息、提取主要变化模式并降低噪声影响, 因此常被作为参数估计前的特征提取步骤。例如, McGurk、Kimball 和 Ivezić 将 PCA 应用于约 10 万条 SDSS 恒星光谱, 发现仅前四个主成分即可在观测噪声范围内重建光谱, 并揭示了本征系数与金属丰度、表面重力之间的相关性^[103]。在测光数据中, PCA 也常与其他回归模型结合使用。例如, Liang 等人提出 PCA + LightGBM 方法, 将多波段测光数据降维后用于恒星参数回归, 在有效温度、表面重力和金属丰度上的误差分别约为 90 K 、 0.40 dex 和 0.20 dex ^[104]。Qu、Luo、Wang 等人基于 Gaia DR3 的实验进一步验证了 LightGBM 在此类任务中的有效性^[105]。

对于监督学习方法, 支持向量回归和随机森林等也已有应用。例如, 基于 J-PLUS 十二波段测光数据的研究利用支持向量回归建立恒星参数回归模型, 并结合 LAMOST、APOGEE 和 SEGUE 的交叉匹配样本构建训练集, 对约 249 万颗恒星的有效温度、表面重力和金属丰度分别得到约 160 K 、 0.35 dex 和 0.25 dex 的均方根误差^[106]。在光谱数据中, 也有研究结合 Kernel PCA 与 SVM 对 LAMOST 光谱进行建模, 并利用 APOGEE 高精度参数进行训练, 从而实现对恒星大气参数的高效提取^[107]。此外, 在 S-PLUS 测光巡天中, 随机森林和神经网络

络也被用于恒星大气参数和丰度回归，其中神经网络整体表现更优，而随机森林表现出较好的鲁棒性^[108]。

4.2.2 基于深度学习的方法

随着计算能力提升和大规模训练数据的积累，深度学习逐渐成为恒星大气参数提取的重要方向。与传统机器学习相比，深度神经网络能够直接从原始光谱中学习高维特征表示，在处理大样本数据和复杂非线性映射时具有明显优势，因此卷积神经网络、循环神经网络以及 Transformer 等模型已被广泛引入恒星光谱分析中。

Fabbro、Venn、O’ Briain 等人提出的 StarNet 是较早应用于恒星参数测量的卷积神经网络模型之一^[55]。该模型由一维卷积层和全连接层组成，可基于合成光谱估计恒星参数，其结果与传统模板匹配方法相当。作者同时指出，StarNet 的性能仍受训练样本规模、参数覆盖范围和信噪比条件影响，尤其在低信噪比条件下表现较弱。

在 LAMOST 的大规模低分辨率光谱上，深度学习方法得到了系统应用。Zhang、Zhao、Yang 等人将 StarNet 应用于 LAMOST DR5，并基于 APOGEE 与 LAMOST 的交叉匹配样本进行训练^[53]。该工作面向巨星样本，在 $S/N_g > 10$ 条件下对有效温度、表面重力和金属丰度给出了较稳定的结果，并通过外部高精度样本和星震表面重力进行了检验。Li、Zhao、Chen 等人则基于深度卷积神经网络构建了从 LAMOST 低分辨率光谱到 APOGEE 标签的 label transfer 框架，在巨星与次巨星样本上实现了较高精度的参数预测，并可进一步给出 $[\alpha/M]$ 及多种元素丰度^[109]。后续比较研究表明，该方法在 LAMOST DR8 巨星样本上的散布与其他基于 CNN 的结果处于相近水平^[110]。

除卷积网络外，循环神经网络也被用于 LAMOST 参数提取。Li 和 Lin 提出的 StarGRUNet 基于双向 GRU、自注意力机制和集成学习框架，在 LAMOST 低分辨率光谱上实现了对 T_{eff} 和 $\log g$ 的估计^[48]。针对中分辨率光谱，Xiong、Li、Liao 提出了 RRNet，并基于 LAMOST 中分辨率光谱实现了恒星大气参数和元素丰度测量^[47]，表明在分辨率提高后，深度学习模型可以进一步利用谱线结构信息扩展到丰度反演任务。

近年来，基于 Transformer 的模型也开始进入恒星参数推断领域。Leung 和 Bovy 基于多巡天数据和多种观测量构建了一个 Transformer 模型，并以自监督方式完成多种推理任务^[111]。在由 Gaia XP 光谱推导恒星参数的任务中，该模型在 T_{eff} 、 $\log g$ 和 $[\text{Fe}/\text{H}]$ 上取得了较好结果，显示出跨巡天训练和统一建模的潜力。尽管这类方法尚未广泛应用于 LAMOST，但其结果表明，基于大规模观测数据训练的基础模型有望成为未来大型巡天参数提取的重要方向。

4.3 混合方法

4.3.1 物理模型约束的数据驱动方法

物理模型驱动方法具有明确的物理含义，并在理论模型覆盖的参数空间内具有一定外推能力，因此在高分辨率光谱分析中长期占据重要地位。然而这类方法通常依赖合成光谱的前向建模与非线性拟合，计算成本较高且结果对大气模型假设敏感。

纯数据驱动方法则在训练完成后具有很高的推理效率，适合 APOGEE、LAMOST 等大

规模巡天数据的快速处理。这类方法能够直接从观测数据中学习光谱与标签之间的非线性映射关系，但其适用范围受限于训练集覆盖，且模型性能高度依赖训练标签的准确性与一致性。

基于上述两类方法的互补性，近年来发展出一类将物理模型与数据驱动思想结合的混合方法，即物理模型约束的数据驱动方法。这类方法一方面利用物理模型提供谱线响应和参数空间约束，另一方面保留数据驱动方法在高维标签空间中的高效拟合能力，因此在大规模巡天的恒星参数和元素丰度测量中显示出较强潜力。需要指出的是，不同文献给出的精度通常对应不同的数据质量、样本范围和评估方式，因此数值不宜简单作横向比较；更合理的比较应结合分辨率条件、标签定义和适用参数空间进行理解。各种方法类别在建模思想、典型应用工具及适用参数空间上的差异与互补性总结于表 1 中。

Ting、Conroy 和 Rix 等人提出的 The Payne^[41] 是此类方法的代表。该方法利用神经网络在高维恒星标签空间中对合成光谱进行连续、可微的快速插值，并在参数反演阶段仍采用前向建模与 χ^2 最小化拟合。与完全基于观测数据训练的纯数据驱动方法不同，The Payne 的训练集来自第一性原理计算的合成光谱，因此其预测始终受到恒星大气结构和辐射转移理论的约束。相比传统低阶多项式插值，The Payne 使用的神经网络具有更强的非线性表达能力，能够更灵活地描述谱线对标签变化的复杂响应，并在较宽参数范围内保持很高的插值精度，如图 4 所示。Ting 等人将 The Payne 用于 APOGEE 光谱分析，并利用疏散星团成员星的化学同质性检验丰度测量精度。结果表明，在无需外部经验标定的情况下，该方法对多个元素达到了约 0.03 dex 的测量精度，优于同期 APOGEE 官方管线 ASPCAP，并在若干元素上接近给定信噪比条件下的 Cramér–Rao 极限^[41]。这说明，物理约束与高效插值相结合的混合策略能够在保持物理自洽性的同时，更充分地提取高分辨率光谱中的化学信息。

在低分辨率巡天数据中，LAMOST 提供了检验混合方法的重要场景。由于 $R \sim 1800$ 的光谱中谱线混叠严重，模型若完全依赖数据驱动学习，容易更多利用标签之间的经验相关性，而不是真实的谱线物理响应。针对这一问题，Xiang、Ting、Rix 等人提出了 Data-Driven Payne (DD-Payne) 方法^[112]。该方法直接在实测光谱上训练模型，利用 LAMOST 与高分辨率巡天的共同观测源作为训练样本，并以高分辨率分析结果作为参考标签，从而将高分辨率标签信息迁移到低分辨率光谱参数测量中。其关键改进是在损失函数中引入理论梯度光谱作为物理正则化项，即约束模型学习到的梯度 $\partial f / \partial \ell$ 与第一性原理大气模型给出的理论梯度保持一致。这样，模型更倾向于利用真实谱线响应，而非标签间的经验相关性。DD-Payne 与 Kurucz 模型给出的梯度光谱在多数元素上具有较高一致性，表明其参数测量逻辑具有较好的物理合理性。

基于该方法，研究团队从约 600 万条 LAMOST 低分辨率光谱中测量了 16 种元素丰度；在 $S/N > 50$ 条件下，多数元素的内部精度达到 0.03–0.1 dex^[112]。这表明，即使在低分辨率条件下，只要引入合适的物理约束，数据驱动模型仍能够从大样本巡天光谱中提取具有天体物理意义的化学信息。

总体而言，The Payne 通过学习物理光谱库在高维标签空间中的快速插值，实现了对 *ab initio* 光谱模型的高效调用；DD-Payne 则进一步把物理先验显式注入观测数据驱动模型，使

表 1 恒星大气参数测量方法论全景表。本表总结了各方法类别的核心思想、典型数据/工具、适用分辨率以及主要优势与局限。

核心思想	典型应用/工具	适用分辨率	优势	局限
物理驱动：光谱特征分析				
测量对参数敏感的特定谱学指标（如巴尔末断裂、等效宽度、线深比、分子带指数等），并通过经验标定或半经验关系反推恒星参数。	BCD 系统 LDR 方法 谱线指数/等效宽度测量 标准星标定	高/中 (需较高 S/N)	物理可解释性强； 可针对特定参数设计敏感探针； 在高 S/N、高分辨率下精度可达很高水平。	对信噪比与分辨率敏感；连续谱归一化与流量定标误差可引入系统偏差；参数存在耦合与退化（如 $T_{\text{eff}}-\log g$ ）。
物理驱动：模版匹配				
在合成或经验光谱库中寻找与观测光谱差异最小的模版（常用 χ^2 最小化），或进行全谱拟合以同时约束多个恒星标签参数。	SSPP LASP LSP3 SME / iSpec FERRE GSP-Phot（测光/低分辨率）	低/中/高 (取决于模版库)	结果稳定、物理一致性较强；可同时拟合多参数；适用范围广。	计算成本较高（尤其是高维标签与全谱拟合）；依赖模版库覆盖与物理模型假设（如 LTE、1D）；模型不完备会引入系统误差。
数据驱动：机器学习				
利用统计学习模型（如 PCA+ 回归、SVR、随机森林、梯度提升树等）学习光谱或特征与恒星参数之间的非线性映射关系。	PCA+LightGBM SVR 随机森林 KNN The Cannon	低/中 或多波段测光	训练完成后推理速度快，适合海量巡天数据；在低 S/N 条件下表现稳定。	强依赖训练集标签质量与覆盖范围；对未见类型或参数边界泛化能力有限；可解释性相对较弱。
数据驱动：深度学习				
利用神经网络（CNN、RNN、Transformer 等）自动提取高维光谱表征，并以端到端方式回归恒星大气参数。	StarNet RRNet Transformer 自编码器 + 回归头	低/中 (对 S/N 较鲁棒)	特征提取能力强；对噪声与谱线缺失具有一定鲁棒性；适合大样本应用。	需要大规模高质量训练集；跨仪器/分辨率/波段迁移困难；系统误差控制更具挑战。
混合方法：物理约束的数据驱动				
在数据驱动模型中显式引入物理先验或物理约束，例如利用神经网络实现合成光谱的可微插值（The Payne），或通过理论梯度/响应函数正则化数据驱动模型（DD-Payne）。	The Payne DD-Payne	低至高 (依实现与约束)	兼顾数据驱动的高效率与物理模型的自治性与可解释性；在低分辨率条件下优势明显。	可能同时继承训练标签系统差与底层物理模型偏差；方法复杂度较高，验证与误差传播要求更严格。




图 4 The Payne 的插值与丰度精度示例。(a) 不同标签变化下单个像素流量的响应。相比二次多项式模型（蓝色实线），The Payne（橙色实线）能够在更宽标签空间内更灵活地拟合非线性和非单调响应。(b) 基于疏散星团成员星的元素丰度精度评估，The Payne 在多个元素上达到了约 0.03 dex 的精度。图片来源于 [41]。

其在低分辨率光谱中更依赖真实谱线响应而非经验相关性。二者均代表了将传统模板匹配思想与现代数据驱动方法相结合的典型范例。

需要指出的是，数据驱动方法的早期应用大多集中于 FGK 型恒星，而对 OBA 型热星的系统研究相对滞后。近年来，这一局面开始改变。Xiang、Rix、Ting 等人提出 HOTPAYNE 方法，针对 LAMOST DR6 的低分辨率热星光谱同时拟合 T_{eff} 、 $\log g$ 、 $v \sin i$ 以及多种元素丰度，并为约 33 万颗 OBA 热星给出了参数结果，表明数据驱动框架也能够扩展到热星参数空间。不过，该工作也指出，热星低分辨率参数提取仍受到底层 LTE 模型的系统限制，尤其在更高温区间需要结合 NLTE 模型进一步改进^[113]。

为了更直观地展示近年来在 LAMOST 低分辨率光谱上发展的代表性数据驱动与混合

方法，表 2 汇总了若干相关研究工作。不同方法在输入数据、输出标签、评价指标和适用样本范围上存在差异，因此表中结果主要用于展示方法发展的总体特征，而不宜简单作数值上的一一对应比较。

表 2 LAMOST 光谱数据上数据驱动与混合方法的代表性工作

代表工作	LAMOST 数据	分辨率	核心算法	输入	输出参数	典型精度 (按原文定义)
StarNet ^[53] (Zhang, Zhao, Yang et al. 2019)	DR5 (巨星)	$R \sim 1800$	卷积神经网络 (CNN)	归一化光谱	$T_{\text{eff}}, \log g, [\text{Fe}/\text{H}]$	$\sigma \sim 100 \text{ K}, 0.10 \text{ dex}, \sim 0.12 \text{ dex}$ (外部参考)
StarGRUNet ^[48] (Li & Lin 2023)	LRS	$R \sim 1800$	Bi-GRU + 注意力机制	归一化光谱	$T_{\text{eff}}, \log g$	$\sigma \sim 94 \text{ K}, 0.16 \text{ dex}$ (随 S/N 变化)
RRNet ^[47] (Xiong, Li, Liao et al. 2022)	MRS	$R \sim 7500$	残差循环神经网络 (Res-RNN)	归一化光谱	$T_{\text{eff}}, \log g, [X/H]$	MAE $\sim 88 \text{ K}, 0.13 \text{ dex}, 0.05\text{--}0.10 \text{ dex}$
深度 CNN ^[109] (Li, Zhao, Chen et al. 2022)	LRS (巨星)	$R \sim 1800$	深度卷积神经网络	归一化光谱	$T_{\text{eff}}, \log g, [\text{Fe}/\text{H}]$	MAE $\sim 29 \text{ K}, 0.07 \text{ dex}, 0.03 \text{ dex}$
DD-Payne ^[112] (Xiang, Ting, Rix et al. 2019)	DR5	$R \sim 1800$	物理梯度约束 NN (混合方法)	局部归一化光谱	$T_{\text{eff}}, \log g, [\text{Fe}/\text{H}], 15 \text{ 种元素丰度}$	σ (S/N > 50): $\sim 60 \text{ K}, 0.10 \text{ dex}, 0.05\text{--}0.10 \text{ dex}$ (丰度)

5 总结与展望

5.1 主要进展总结

恒星大气参数的精确测量对于研究恒星物理、银河系结构与化学演化具有重要意义，同时也为系外行星巡天提供关键信息。随着大规模光谱巡天的开展，恒星参数测量已由小样本精细分析逐步转向海量数据的自动化处理。早期方法主要依赖光谱特征，具有较强的物理可解释性，但对信噪比和分辨率较为敏感；随后，模板匹配方法在 SDSS/SEGUE、APOGEE 和 LAMOST 等巡天中得到广泛应用，在稳定性、精度和自动化之间取得了较好平衡。近年来，机器学习和深度学习方法在大样本快速推断方面展现出明显优势，而以 The Payne 和 DD-Payne 为代表的混合方法则进一步表明，物理约束与数据驱动方法的结合能够在提高效率的同时增强结果的物理自洽性与可解释性。

5.2 不同方法精度比较的前提与局限

需要指出的是，文献中给出的恒星大气参数测量精度通常难以直接横向比较。不同研究在光谱分辨率、波段覆盖、信噪比、样本参数空间和误差评估方式上往往并不一致，因此其误差数值所对应的测量难度和物理含义并不完全相同。对于数据驱动方法而言，训练标签的质量、参数空间覆盖以及训练集与应用样本之间的一致性，还会进一步影响精度指标的解释。因此，在比较不同方法的性能时，不宜仅依据单一误差数值作简单排序，而应结合其数据条件、目标参数、适用样本范围、评价方式以及物理约束程度进行综合判断。表 2 所汇总的结果更适合用于展示方法发展的总体特征，而不宜作简单的一一对应比较。

5.3 未来发展方向

尽管近年来恒星大气参数测量方法取得了显著进展,该领域仍面临若干关键问题,包括不同方法在低分辨率、低信噪比和复杂样本条件下的精度极限尚缺乏统一评估,以及现有方法在特殊参数空间上的覆盖仍不均衡。与此同时,纯数据驱动方法虽然效率较高,但对训练标签质量和样本覆盖范围依赖较强,在物理可解释性和跨巡天泛化方面仍存在不足。

未来研究需要在数据、模型和方法三个层面协同推进:在数据层面建立更加统一的评估框架,在模型层面完善面向不同恒星类型的专门模型库,在方法层面推动物理模型与数据驱动方法的深度融合。基于这一思路,我们正在开展敏感吸收线窗口与深度学习结合的恒星大气参数提取研究,期望在保留物理指向性的同时兼顾大样本快速推断的需求。

总体来看,恒星大气参数测量未来的发展重点,不仅在于进一步提高测量精度,更在于增强方法对更广参数空间、更复杂观测条件和更大规模巡天数据的适应能力。随着 Gaia、LAMOST、APOGEE、GALAH 等巡天数据的持续积累,以及未来 CSST^[114]、MUST^[115]、JUST^[116] 等新一代巡天的开展,人工智能与天文光谱分析的结合将更加紧密,并在恒星参数测量中发挥更重要的作用。

参考文献:

- [1] Conroy C. ARA&A, 2013, 51: 393. DOI: 10.1146/annurev-astro-082812-141017
- [2] Andryushin A S, Popov S B. Astronomy Reports, 2021, 65: 246. DOI: 10.1134/S1063772921040016
- [3] Xiang M, Rix H W, Yang H, et al. Nature Astronomy, 2025, 9: 101. DOI: 10.1038/s41550-024-02382-w
- [4] Yanny B, Rockosi C, Newberg H J, et al. AJ, 2009, 137: 4377. DOI: 10.1088/0004-6256/137/5/4377
- [5] Majewski S R, Schiavon R P, Frinchaboy P M, et al. AJ, 2017, 154: 94. DOI: 10.3847/1538-3881/aa784d
- [6] Lee Y S. Dissertation, Michigan State University, 2008
- [7] Jönsson H, Holtzman J A, Allende Prieto C, et al. AJ, 2020, 160: 120. DOI: 10.3847/1538-3881/aba592
- [8] Holtzman J A, Hasselquist S, Shetrone M, et al. AJ, 2018, 156: 125. DOI: 10.3847/1538-3881/aad4f9
- [9] García Pérez A E, Allende Prieto C, Holtzman J A, et al. AJ, 2016, 151: 144. DOI: 10.3847/0004-6256/151/6/144
- [10] De Silva G M, Freeman K C, Bland-Hawthorn J, et al. MNRAS, 2015, 449: 2604. DOI: 10.1093/mnras/stv327
- [11] Ness M, Hogg D W, Rix H W, et al. ApJ, 2015, 808: 16. DOI: 10.1088/0004-637X/808/1/16
- [12] Perryman M A C, de Boer K S, Gilmore G, et al. A&A, 2001, 369: 339. DOI: 10.1051/0004-6361:20010085
- [13] Gaia Collaboration, Prusti T, de Bruijne J H J, et al. A&A, 2016, 595: A1. DOI: 10.1051/0004-6361/201629272
- [14] Recio-Blanco A, Bijaoui A, de Laverny P. MNRAS, 2006, 370: 141. DOI: 10.1111/j.1365-2966.2006.10455.x
- [15] García Pérez A E, Allende Prieto C, Holtzman J A, et al. AJ, 2016, 151: 144. DOI: 10.3847/0004-6256/151/6/144
- [16] Recio-Blanco A, de Laverny P, Allende Prieto C, et al. A&A, 2016, 585: A93. DOI: 10.1051/0004-6361/201425030
- [17] Gilmore G, Randich S, Asplund M, et al. The Messenger, 2012, 147: 25
- [18] Randich S, Gilmore G, Magrini L, et al. A&A, 2022, 666: A121. DOI: 10.1051/0004-6361/202243141
- [19] Zhao G, Zhao Y H, Chu Y Q, et al. Research in Astronomy and Astrophysics, 2012, 12: 723. DOI: 10.1088/1674-4527/12/7/002
- [20] Wu Y, Xiang M, Chen Y, et al. MNRAS, 2021, 501: 4917. DOI: 10.1093/mnras/staa3949
- [21] Xing Q F, Zhao G, Liu Z W, et al. Nature, 2023, 618: 712. DOI: 10.1038/s41586-023-06028-1
- [22] Zhang M, Xiang M, Zhang H W, et al. ApJ, 2021, 922: 145. DOI: 10.3847/1538-4357/ac22a5
- [23] Wang R, Luo A L, Chen J J, et al. ApJ, 2020, 891: 23. DOI: 10.3847/1538-4357/ab6dea
- [24] Xiang M, Rix H W. Nature, 2022, 603: 599. DOI: 10.1038/s41586-022-04496-5
- [25] Gray D F. The Observation and Analysis of Stellar Photospheres. 2008
- [26] Sánchez-Blázquez P, Peletier R F, Jiménez-Vicente J, et al. MNRAS, 2006, 371: 703. DOI: 10.1111/j.1365-2966.2006.10699.x
- [27] Prugniel P, Soubiran C. A&A, 2001, 369: 1048. DOI: 10.1051/0004-6361:20010163
- [28] Verro K, Trager S C, Peletier R F, et al. A&A, 2022, 661: A50. DOI: 10.1051/0004-6361/202142387
- [29] Husser T O, Wende-von Berg S, Dreizler S, et al. A&A, 2013, 553: A6. DOI: 10.1051/0004-6361/201219058
- [30] Gustafsson B, Edvardsson B, Eriksson K, et al. A&A, 2008, 486: 951. DOI: 10.1051/0004-6361:200809724
- [31] Cortes C, Vapnik V. Machine learning, 1995, 20: 273
- [32] Quinlan J R. Machine learning, 1986, 1: 81
- [33] Breiman L. Machine learning, 2001, 45: 5
- [34] Jolliffe I. International encyclopedia of statistical science. Springer, 2011: 1094
- [35] Cover T, Hart P. IEEE transactions on information theory, 1967, 13: 21
- [36] Lee Y S, Beers T C, Sivarani T, et al. AJ, 2008, 136: 2022. DOI: 10.1088/0004-6256/136/5/2022
- [37] Xiang M S, Liu X W, Shi J R, et al. Monthly Notices of the Royal Astronomical Society, 2017, 464: 3657
- [38] Lu Y, Li X. Monthly Notices of the Royal Astronomical Society, 2015, 452: 1394
- [39] Chen S X, Sun W M, He Y. Research in Astronomy and Astrophysics, 2022, 22: 025017. DOI: 10.1088/1674-4527/ac41c5
- [40] Ball N M, Brunner R J. International Journal of Modern Physics D, 2010, 19: 1049
- [41] Ting Y S, Conroy C, Rix H W, et al. The Astrophysical Journal, 2019, 879: 69
- [42] LeCun Y, Bottou L, Bengio Y, et al. Proceedings of the IEEE, 2002, 86: 2278
- [43] Sharma K, Kembhavi A, Kembhavi A, et al. Monthly Notices of the Royal Astronomical Society, 2020, 491: 2280
- [44] Zheng Z P, Qiu B, Luo A L, et al. Publications of the Astronomical Society of the Pacific, 2020, 132: 024504

- [45] Hochreiter S, Schmidhuber J. *Neural computation*, 1997, 9: 1735
- [46] Chung J, Gulcehre C, Cho K, et al. 1412.3555, 2014
- [47] Xiong S, Li X, Liao C. *The Astrophysical Journal Supplement Series*, 2022, 261: 36
- [48] Li X, Lin B. *MNRAS*, 2023, 521: 6354. DOI: 10.1093/mnras/stad831
- [49] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. *Advances in neural information processing systems*, 2014, 27
- [50] Rui W, Luo A L, Shuo Z, et al. *Publications of the Astronomical Society of the Pacific*, 2019, 131: 024505
- [51] Vaswani A, Shazeer N, Parmar N, et al. *Advances in neural information processing systems*, 2017, 30
- [52] Zhao X, Li X, Li H, et al. *The Astrophysical Journal Supplement Series*, 2025, 278: 41
- [53] Zhang X, Zhao G, Yang C Q, et al. *PASP*, 2019, 131: 094202. DOI: 10.1088/1538-3873/ab2687
- [54] Pan R y, Li X r. *Chinese Astronomy and Astrophysics*, 2017, 41: 318
- [55] Fabbro S, Venn K A, O'Briain T, et al. *MNRAS*, 2018, 475: 2978. DOI: 10.1093/mnras/stx3298
- [56] Dafonte C, Fustes D, Manteiga M, et al. *Astronomy & Astrophysics*, 2016, 594: A68
- [57] Guiglion G, Nepal S, Chiappini C, et al. *Astronomy & Astrophysics*, 2024, 682: A9
- [58] Barbier D, Chalonge D. *Annales d'Astrophysique*, 1941, 4: 30
- [59] Chalonge D, Divan L. *Annales d'Astrophysique*, 1952, 15: 201
- [60] Mokiem M R, de Koter A, Puls J, et al. *A&A*, 2005, 441: 711. DOI: 10.1051/0004-6361/20053522
- [61] Underhill A B, Divan L, Prevot-Burnichon M L, et al. *MNRAS*, 1979, 189: 601. DOI: 10.1093/mnras/189.3.601
- [62] Zorec J, Briot D. *A&A*, 1991, 245: 150
- [63] Zorec J, Cidale L, Arias M L, et al. *A&A*, 2009, 501: 297. DOI: 10.1051/0004-6361/200811147
- [64] Moon T T, Dworetzky M M. *MNRAS*, 1985, 217: 305. DOI: 10.1093/mnras/217.2.305
- [65] Wolf C, Onken C A, Luvaul L C, et al. *Publ. Astron. Soc. Aust.*, 2018, 35: e010. DOI: 10.1017/pasa.2018.5
- [66] Fuhrmann K, Axer M, Gehren T. *A&A*, 1993, 271: 451
- [67] Gehren T. *A&A*, 1981, 100: 97
- [68] Fuhrmann K, Pfeiffer M J, Bernkopf J. *A&A*, 1997, 326: 1081
- [69] Cayrel R, van't Veer-Menneret C, Allard N F, et al. *A&A*, 2011, 531: A83. DOI: 10.1051/0004-6361/201116911
- [70] Ludwig H G, Behara N T, Steffen M, et al. *A&A*, 2009, 502: L1. DOI: 10.1051/0004-6361/200911997
- [71] Amarsi A M, Nordlander T, Barklem P S, et al. *A&A*, 2018, 615: A139. DOI: 10.1051/0004-6361/201732546
- [72] Olson E C. *ApJS*, 1975, 29: 43. DOI: 10.1086/190331
- [73] Bell R A, Dreiling L A. *ApJ*, 1981, 248: 1031. DOI: 10.1086/159232
- [74] Cayrel de Strobel G. *Annales d'Astrophysique*, 1968, 31: 43
- [75] Peterson D M, Scholz M. *ApJ*, 1971, 163: 51. DOI: 10.1086/150746
- [76] Bell R A, Edvardsson B, Gustafsson B. *MNRAS*, 1985, 212: 497. DOI: 10.1093/mnras/212.3.497
- [77] Afşar M, Bozkurt Z, Topcu G B, et al. *ApJ*, 2023, 949: 86. DOI: 10.3847/1538-4357/acc946
- [78] Sitnova T M, Mashonkina L I, Ezzeddine R, et al. *MNRAS*, 2019, 485: 3527. DOI: 10.1093/mnras/stz626
- [79] Eggen O J, Sandage A R. *ApJ*, 1962, 136: 735. DOI: 10.1086/147432
- [80] Bond H E. *ApJS*, 1980, 44: 517. DOI: 10.1086/190703
- [81] Karaali S, Bilir S, Ak S, et al. *Publ. Astron. Soc. Aust.*, 2011, 28: 95. DOI: 10.1071/AS10026
- [82] Allende Prieto C, Beers T C, Wilhelm R, et al. *ApJ*, 2006, 636: 804. DOI: 10.1086/498131
- [83] Kurucz R L. *SYNTHES spectrum synthesis programs and line data*. 1993
- [84] Wu Y, Du B, Luo A, et al. *Heavens A, Starck J L, Krone-Martins A, eds. IAU Symposium: Vol. 306 Statistical Challenges in 21st Century Cosmology*. 2014: 340. DOI: 10.1017/S1743921314010825
- [85] Du B, Luo A L, Zhang S, et al. *Research in Astronomy and Astrophysics*, 2021, 21: 202. DOI: 10.1088/1674-4527/21/8/202
- [86] Li C q, Shi J r, Yan H l, et al. *ApJS*, 2024, 273: 18. DOI: 10.3847/1538-4365/ad5002
- [87] Xiang M S, Liu X W, Yuan H B, et al. *MNRAS*, 2015, 448: 822. DOI: 10.1093/mnras/stu2692
- [88] Koleva M, Prugniel P, Bouchard A, et al. *A&A*, 2009, 501: 1269. DOI: 10.1051/0004-6361/200811467
- [89] Wu Y, Luo A L, Li H N, et al. *Research in Astronomy and Astrophysics*, 2011, 11: 924. DOI: 10.1088/1674-4527/11/8/006
- [90] Castelli F, Kurucz R L, Piskunov N, Weiss W W, Gray D F, eds. *IAU Symposium: Vol. 210 Modelling of Stellar Atmospheres*. 2003: A20. DOI: 10.48550/arXiv.astro-ph/0405087
- [91] Prugniel P, Soubiran C, Koleva M, et al. *astro-ph/0703658*, 2007

-
- [92] Soubiran C, Le Campion J F, Cayrel de Strobel G, et al. *A&A*, 2010, 515: A111. DOI: 10.1051/0004-6361/201014247
- [93] Falcón-Barroso J, Sánchez-Blázquez P, Vazdekis A, et al. *A&A*, 2011, 532: A95. DOI: 10.1051/0004-6361/201116842
- [94] Allard F, Homeier D, Freytag B. *Philosophical Transactions of the Royal Society of London Series A*, 2012, 370: 2765. DOI: 10.1098/rsta.2011.0269
- [95] Fouesneau M, Frémat Y, Andrae R, et al. *A&A*, 2023, 674: A28. DOI: 10.1051/0004-6361/202243919
- [96] Brott I, Hauschildt P H, Taron C, O’Flaherty K S, Perryman M A C, eds. *ESA Special Publication: Vol. 576 The Three-Dimensional Universe with Gaia*. 2005: 565. DOI: 10.48550/arXiv.astro-ph/0503395
- [97] Shulyak D, Tsymbal V, Ryabchikova T, et al. *A&A*, 2004, 428: 993. DOI: 10.1051/0004-6361:20034169
- [98] Lanz T, Hubeny I. *ApJS*, 2003, 146: 417. DOI: 10.1086/374373
- [99] Holgado G, Simón-Díaz S, Barbá R H, et al. *A&A*, 2018, 613: A65. DOI: 10.1051/0004-6361/201731543
- [100] Huertas-Company M, Rouan D, Tasca L, et al. *A&A*, 2008, 478: 971. DOI: 10.1051/0004-6361:20078625
- [101] Foster G, Karastergiou A, Golpayegani G, et al. *MNRAS*, 2018, 474: 3847. DOI: 10.1093/mnras/stx3038
- [102] Singh H P, Gulati R K, Gupta R. *MNRAS*, 1998, 295: 312. DOI: 10.1046/j.1365-8711.1998.01255.x
- [103] McGurk R C, Kimball A E, Ivezić Ž. *AJ*, 2010, 139: 1261. DOI: 10.1088/0004-6256/139/3/1261
- [104] Liang J, Bu Y, Tan K, et al. *AJ*, 2022, 163: 153. DOI: 10.3847/1538-3881/ac4d97
- [105] Qu C X, Luo A L, Wang R, et al. *ApJS*, 2024, 270: 32. DOI: 10.3847/1538-4365/ad103c
- [106] Yuan H, Zhang Y, Lei Y, et al. *Griffin R E, ed. IAU Symposium: Vol. 339 Southern Horizons in Time-Domain Astronomy*. 2019: 345. DOI: 10.1017/S1743921318002983
- [107] Wang C, Bai Y, Yuan H, et al. *A&A*, 2022, 664: A38. DOI: 10.1051/0004-6361/202243130
- [108] Ferreira Lopes C E, Gutiérrez-Soto L A, Ferreira Alberice V S, et al. *A&A*, 2025, 693: A306. DOI: 10.1051/0004-6361/202451491
- [109] Li Z, Zhao G, Chen Y, et al. *Monthly Notices of the Royal Astronomical Society*, 2022, 517: 4875
- [110] Liu H, Du C, Deng M, et al. *MNRAS*, 2025, 541: 58. DOI: 10.1093/mnras/staf964
- [111] Leung H W, Bovy J. *MNRAS*, 2024, 527: 1494. DOI: 10.1093/mnras/stad3015
- [112] Xiang M, Ting Y S, Rix H W, et al. *The Astrophysical Journal Supplement Series*, 2019, 245: 34
- [113] Xiang M, Rix H W, Ting Y S, et al. *A&A*, 2022, 662: A66. DOI: 10.1051/0004-6361/202141570
- [114] Zhan H. *42nd COSPAR Scientific Assembly: Vol. 42*. 2018: E1.16
- [115] Cai Z, Huang S, Liu Y, et al. *Science China Physics, Mechanics, and Astronomy*, 2025, 68: 280403. DOI: 10.1007/s11433-025-2725-3
- [116] JUST Team, Liu C, Zu Y, et al. *Astronomical Techniques and Instruments*, 2024, 1: 16. DOI: 10.61977/ati2024008

Progress on Measuring Stellar Atmospherics Parameters

Yixin Zhang^{1,2}, Jian Ge¹

(1. Shanghai Astronomical Observatory, Chinese Academy of Sciences, Shanghai 200030, China; 2. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: Stellar atmospheric parameters, such as effective temperature, surface gravity, and metallicity, are fundamental to the study of stellar properties and evolution. As astronomy enters the era of big data, how to efficiently extract these parameters from massive spectroscopic datasets has become an important issue. In recent years, substantial progress has been made under the combined drive of increasing data volume and advancing analysis methods. The main technical approaches now include spectral feature analysis, template matching, machine learning, deep learning, and hybrid data-driven methods with physical constraints. While these methods offer distinct advantages in terms of measurement precision, processing efficiency, and applicability, they also face ongoing challenges such as parameter space coverage and physical interpretability.

Key words: Stellar Atmospheric Parameters, Large Scale Spectroscopic Surveys, Deep Learning