

doi: 10.3969/j.issn.1000-8349.2020.01.03

SAGE 巡天介绍 II —— 恒星大气参数估计

赵景昆¹, 赵 刚^{1,2}, 范 舟¹, 谈克峰¹,
宋轶晗¹, 王奇勋^{1,2}, 王 炜^{1,3}

(1. 中国科学院 国家天文台 光学天文重点实验室, 北京 100012; 2. 中国科学院大学 天文与空间科学学院, 北京 100049; 3. 中国科学院南美天文中心, 中智联合天文中心, 圣地亚哥 7550000, 智利)

摘要: 主要介绍 SAGE 巡天的恒星大气参数计算方法。首先回顾了前人利用恒星颜色确定恒星大气参数的工作; 然后介绍了确定参数的多项式拟合和深度学习两种方法, 并对每一种方法的原理、误差和特点进行了详细描述; 最后对利用 SAGE 巡天恒星大气参数的前景进行展望。

关键词: 测光系统; 恒星大气; 深度学习

中图分类号: P145.2 **文献标识码:** A

1 引 言

星系是宇宙的基本结构单元。阐释星系的集成历史, 理解星系形态、结构和性质的规律性和多样性, 是 21 世纪天体物理学的重大问题。在当下主流的暗能量与冷暗物质 (Λ CDM) 主导的宇宙学框架下, 宇宙大尺度结构 (包括星系自身) 通过并合及吸积较小尺度结构, 然后自下而上逐级增长形成。虽然这一理论获得了一系列观测及理论结果的支持, 但人们对宇宙结构形成过程所包含许多异常复杂的物理及天体物理过程^[1] 仍知之甚少。通过对近邻可解析星系进行精细研究, 以及对大样本遥远星系进行粗略的统计分析, 揭示星系集成历史及相关物理、天体物理过程和规律, 对进一步研究星系形成和演化过程具有重要的意义。作为一个典型的盘星系, 银河系有大约数千亿颗恒星, 是唯一可以将其星族组成解析为单体, 并对其在包括三维空间、三维速度以及化学元素丰度的多维相空间里进行细致研究的旋涡星系。恒星的大气参数为理解银河系的形成、结构和化学演化提供最基本的参量, 包括有效温度 T_{eff} 、表面重力 $\lg g$ 和金属丰度 $[\text{Fe}/\text{H}]$ 。如计算恒星的距离、化学丰度、年龄等都需要首先计算出恒星大气参数。恒星大气参数的估算主要有 2 种方法: 分光方法和测光方法。分光方

收稿日期: 2019-05-16; 修回日期: 2019-07-22

资助项目: 国家自然科学基金 (11988101, 11890694, 11973048, 11927804, 11390371, 11373003, 11673030); 国家自然科学基金联合基金 (U1631102)

通讯作者: 赵刚, gzhao@bao.ac.cn

法需要恒星光谱, 因而测光方法的使用相对更广泛。

在 3 个恒星基本参数中, 相对较容易估算的是有效温度 T_{eff} , 其次是金属丰度 $[\text{Fe}/\text{H}]$, 比较困难的是表面重力 $\lg g$ 。利用恒星颜色来估算有效温度的方法应用非常广泛。1987 年, Magain^[2] 利用红外流量方法建立了 $B-V$, $b-y$ 和 $V-K$ 与有效温度 T_{eff} 的关系, 这个关系可以用于矮星和亚巨星的温度估算。1996 年, Alonso 等人^[3] 建立了一个有精确 T_{eff} 的矮星和亚矮星样本, 这个样本的 T_{eff} 是通过红外流量方法计算得到的。他们利用这个样本, 通过多项式拟合建立了 $B-V$, $R-I$, $V-R$, $V-I$, $V-K$, $J-H$, $J-K$ 和 $u-b-v-y-\beta$ 颜色系统, 以及金属丰度 $[\text{Fe}/\text{H}]$ 与恒星有效温度 T_{eff} 的经验关系 $\theta_{\text{eff}} = P(\text{颜色}, [\text{Fe}/\text{H}])$, 其拟合精度从 $V-K$ 的 30 K 到 $J-H$ 的 154 K。1999 年, Alonso 等人^[4] 建立了巨星的 T_{eff} 与颜色以及金属丰度的关系, 其精度从 $V-K$ 的 40 K 到 $J-H$ 的 170 K。Holmberg 等人^[5] 建立了新的 $b-y$ 与有效温度的关系, 这个关系可用分段函数表示, 针对不同的 $b-y$ 范围, 函数略有不同, 精度大约为 60 K。Casagrande 等人^[6] 利用太阳孪生星对样本有效温度的零点进行了校正, 建立了一个 $[\text{Fe}/\text{H}]$ 范围非常宽 (-5.0 至 $+0.4$) 的颜色- T_{eff} 的关系, 但是用这个关系所计算出的 T_{eff} 比 Alonso 等人的结果要高约 200 K。2015 年, Huang 等人^[7] 从文献中收集了大约 200 颗近邻恒星样本, 其 T_{eff} 的相对误差仅为 2.5%。他们利用这些样本建立了 T_{eff} 与恒星颜色以及金属丰度 $[\text{Fe}/\text{H}]$ 的关系。对于矮星, 若有效温度从 3 100 K 到 10 000 K, 则光谱型从 M5 到 A0; 对于巨星, 若有效温度从 3 100 K 到 5 700 K, 则光谱型从 K5 到 G5。这个校正关系主要应用于盘星 ($[\text{Fe}/\text{H}] \geq -1.0$)。

由于光谱的获取相对困难, 对于较暗的恒星, 测光信息也经常用来计算恒星的金属丰度。最早人们利用 Strömrgren β 测光系统^[8] 初步建立了金属丰度与 m_1 的关系。随后, 1981 年 Olsen^[9] 建立了 $u-v-b-y$ 测光与有效温度、表面重力以及金属丰度的定标关系, 这个定标关系适用于 GK 矮星。对于 $\lg g$ 和 $[\text{Fe}/\text{H}]$, 精度分别为 0.009 dex 和 0.17 dex。由于用这种方法确定的 $\lg g$ 精度不高, 所以表面重力的精度还需要提高。1981 年, Nissen^[10] 建立了 $u-v-b-y-\beta$ 测光与金属丰度的关系, 这个关系主要适用于 F0—G2 恒星。Holmberg 等人^[5] 对以前的金属丰度与 $u-v-b-y$ 测光的关系进行了修正, 得到了一个较复杂的 $[\text{Fe}/\text{H}]$ 与 $b-y$, m_1 , c_1 的关系, 精度为 0.12 dex。2008 年, Ivezić 等人^[11] 利用 SDSS^[12] 光谱中 6 000 多颗 FG 恒星基于多项式模型拟合了 T_{eff} 与 $g-r$ 以及 $u-g$, $g-r$ 与 $[\text{Fe}/\text{H}]$ 的关系, 其精度与用光谱估计的相当。他们利用这个关系估算了 0.5 ~ 8 kpc 之间一个完备样本的无偏差的金属丰度分布, 并根据数密度能得到 2 个成分, 分别对应盘和晕。

SAGE 巡天的高精度测光完备星等深度 ($S/N = 100\sigma$; $V \approx 15 \text{ mag}$)^[13-16] 比 GCS 和 HM 巡天深约 7 ~ 8 mag: $u_{\text{SC}} \approx 11.0 \sim 17.5 \text{ mag}$, $v_{\text{SAGE}} \approx 10.0 \sim 16.5 \text{ mag}$, $gri \approx 9.0 \sim 15.5 \text{ mag}$, 这比之前 GCS 的结果 (约 40 pc) 在距离上扩展了约 25 倍, 相当于类太阳恒星的完备距离约为 1 kpc。5 σ 探测极限 $u_{\text{SC}} \approx 21.5 \text{ mag}$, $v_{\text{SAGE}} \approx 21 \text{ mag}$, $gri \approx 19.5 \text{ mag}$, 在距离上扩展了近 160 倍, 到太阳邻域 6.4 kpc 的距离。我们计划在 4 ~ 5 a 内完成测光巡天观测以及流量定标、天测定标, 得到一个均匀的北天 8 波段的包含 5×10^9 颗恒星的测光星表, 并利用该星表开展一系列以银河系为主的科学研究。本文详细介绍了利用 SAGE 巡天的高精度测光来计算恒星大气参数的三种方法。

第2章介绍样本的基本情况；第3章介绍通过多项式拟合计算恒星参数的方法；第4章介绍了通过深度学习估算恒星参数的方法；第5章对全文进行小结与展望。

2 样本

为了得到可靠的恒星大气参数 (有效温度 T_{eff} 、表面重力 $\lg g$ 和金属丰度 $[\text{Fe}/\text{H}]$) 与 SAGE 巡天测光系统各颜色之间的关系, 我们需要一个包含至少上百颗恒星的样本, 并且这些样本恒星要满足以下条件: (1) 有可靠的大气参数, 并且大气参数的覆盖范围尽可能宽; (2) 有精确的 SAGE 系统测光星等 ($u_{\text{SC}}-v_{\text{SAGE}}-g-r-i$)。基于上述要求, 我们决定利用 MILES 光谱库来建立恒星大气参数与颜色之间的关系。MILES 光谱库^[17]包含九百多颗恒星光谱。这些恒星都有基于高分辨率光谱得到的恒星大气参数, 并且 Cenarro 等人对来自不同工作的大气参数做了一致性改正和检验^[18]。这些恒星的大气参数覆盖范围很宽, 有效温度为 2748 ~ 36000 K, 表面重力为 0 ~ 5.5 dex, 金属丰度为 -2.93 ~ 1.65 dex。MILES 光谱由口径为 2.5 m 的 Isaac Newton 望远镜观测得到, 波长覆盖范围为 3525 ~ 7500 Å, 分辨率约为 2.3 Å (FWHM)。虽然 MILES 光谱的波长范围在红蓝两端都不能完全覆盖 SAGE 巡天测光系统的波长范围, 但是 Kerzendorf 利用理论模型对其进行了拟合并将蓝端和红端光谱分别向外扩展到了 2500 Å 和 10500 Å。MILES 光谱本身只有相对流量定标, Bessell 和 Murphy 在依巴谷星表中找到了 MILES 光谱库中 836 颗恒星的 H_p 星等, 他们通过让 MILES 光谱和响应曲线卷积得到的 H_p 星等与观测相符合的方法, 对这 836 颗恒星的 MILES 光谱做了绝对流量定标^[19]。我们将上述经过外插和绝对流量定标的 MILES 光谱与 SAGE 测光系统各波段的响应曲线卷积得到 $u-v-g-r-i$ 。

MILES 光谱库里的恒星都比较亮, 大部分恒星的 V 星等都亮于 10 mag, 极短的曝光时间也会使图像饱和, 这使得我们很难在观测上得到这些恒星的 $u-v-g-r-i$ 星等, 这也是我们利用光谱卷积得到它们星等的原因。我们做过如下测试: 从 CALSPEC^[20] 光谱库中找到了 13 颗 SDSS^[12] 标准星的有绝对流量定标的光谱, 用程序卷积得到了这些恒星的 $g-r-i$ 星等, 并和它们的观测星等进行了比较, 结果是这 13 颗恒星的卷积星等和观测星等的差的平均值为 0.01 mag, 标准差不超过 0.02 mag。我们在后面的多项式拟合和深度学习中使用的都是通过卷积所得到的星等。

3 多项式拟合

我们采用与 Alonso 等人^[3]类似的方法对有效温度与颜色的关系进行多项式拟合。因为主要研究对象是 FGK 型恒星, 所以我们将拟合范围限定在有效温度为 4000 ~ 7000 K 之间 (以下对表面重力和金属丰度的拟合也限定在这一温度范围内)。在第一次拟合之后, 我们将拟合值与观测值偏离大于 3σ 的样本剔除, 然后进行第二次拟合, 得到的结果如下:

$$T_{\text{eff}} = -3\,159.10(g-i) + 1\,006.43(g-i)^2 + 290.35(g-i)c_1 - 573.40(g-i)m_1 + 777.03m_1 - 411.77m_1^2 + 7\,050.06, \quad (1)$$

其中, c_1 和 m_1 的定义为:

$$c_1 = (u-v) - (v-g), \quad (2)$$

$$m_1 = (v-g) - (g-i). \quad (3)$$

式 (1) 的适用范围为: $0.09 \leq g-i \leq 2.16$ mag, $-1.01 \leq c_1 \leq 1.20$ mag, $-0.31 \leq m_1 \leq 0.54$ mag。图 1 显示了拟合得到的有效温度与光谱确定值的比较以及残差的分布, 最终用于拟合的样本恒星的数量为 517 颗, 标准差为 103 K。

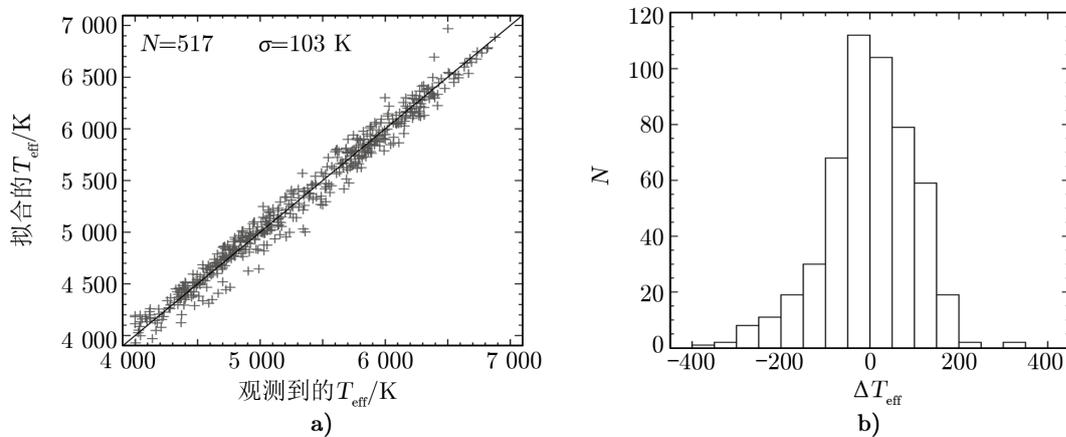


图 1 a) 拟合得到的有效温度与光谱确定值的比较; b) 残差的分布情况

我们采用与 Árnadóttir 等人^[21]类似的方式对表面重力与颜色的关系进行多项式拟合。经过一次迭代, 得到的结果如下:

$$\begin{aligned} \lg g = & -7.43(g-i) + 0.0046m_1 - 4.42c_1 + 1.64(g-i)^2 - 7.73m_1^2 + 1.77c_1^2 - \\ & 2.64(g-i)m_1 - 7.49m_1c_1 + 0.030(g-i)^3 + 1.32(g-i)^2m_1 + \\ & 0.34(g-i)^2c_1 + 4.32m_1^2(g-i) - 1.13c_1^2(g-i) + 5.53(g-i)m_1c_1 + 7.54. \quad (4) \end{aligned}$$

式 (4) 的适用范围为: $-0.39 \leq g-i \leq 2.19$ mag, $-1.38 \leq c_1 \leq 1.66$ mag, $-0.45 \leq m_1 \leq 0.54$ mag。图 2 显示了拟合得到的表面重力与光谱确定值的比较以及残差的分布, 最终用于拟合的样本恒星的数量为 454 颗, 标准差为 0.29 dex。

我们采用与 Holmberg 等人^[5]类似的方式对金属丰度和颜色的关系进行多项式拟合。经过一次迭代, 得到的结果如下:

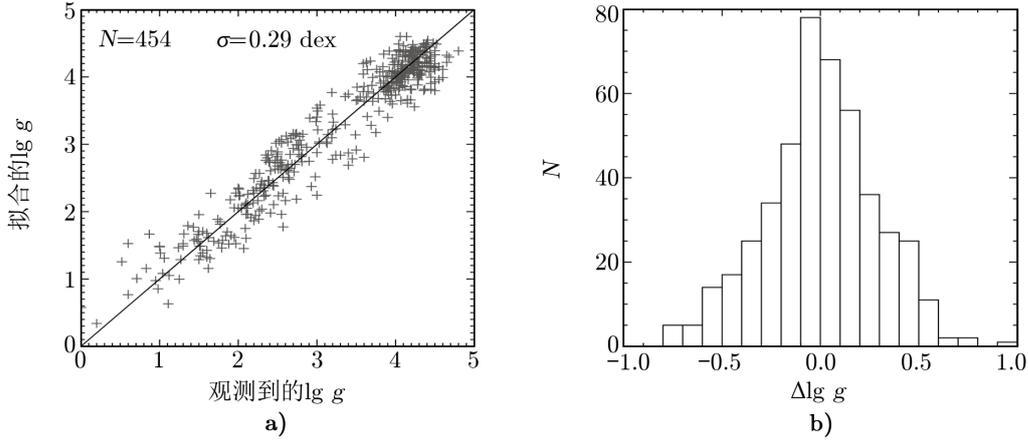


图 2 a) 拟合得到的表面重力与光谱确定值的比较; b) 残差的分布情况

$$\begin{aligned}
 [\text{Fe}/\text{H}] = & -6.93(g-i) + 9.06m_1 - 8.43c_1 + 9.80(g-i)^2 - 7.85m_1^2 + 7.62c_1^2 - \\
 & 1.14(g-i)m_1 + 21.70(g-i)c_1 + 5.33m_1c_1 - 3.68(g-i)^3 - 8.34m_1^3 - \\
 & 2.78c_1^3 - 2.12(g-i)^2m_1 - 11.77(g-i)^2c_1 + 5.38m_1^2(g-i) - \\
 & 7.12m_1^2c_1 - 9.77c_1^2(g-i) + 4.33c_1^2m_1 - 1.46(g-i)m_1c_1 + 0.14 \quad . \quad (5)
 \end{aligned}$$

式 (5) 的适用范围为: $-0.39 \leq g-i \leq 2.48$ mag, $-1.71 \leq c_1 \leq 1.66$ mag, $-0.32 \leq m_1 \leq 0.52$ mag。图 3 显示了拟合得到的金属丰度与光谱确定值的比较以及残差的分布, 最终用于拟合的样本恒星的数量为 471 颗, 标准差为 0.15 dex。从图中可看出 3 个大气参数的拟合误差和光谱得到的相当, 可以满足巡天的需求。在进行消光改正后, 我们可以把 SAGE 巡天星表的数据代入, 求得恒星大气参数。

4 深度学习

4.1 背景

深度学习^[22]作为近些年比较热门的机器学习方法, 被应用到了各个领域。2012 年, AlexNet^[23]利用深度网络在 ImageNet^[24] 崭露头角, 获得了第一名, 大幅提升了分类的准确率。随后的几年里, ZF Net^[25], VGG Net^[26], Google Net^[27] 和 Res Net^[28] 等都在网络的深度和结构上进行了扩展, 得到了更高的准确率。其中 Res Net 的图片分类错误率为 3.57%, 已经低于人类的错误率 5.1%。之后又有更多的网络结构被设计出来并被用到不同的领域中。

在天文学领域, 越来越多的课题引入了深度学习算法。Fabbro 等人^[29]设计了 StarNet 深度网络, 通过输入整条恒星光谱来确定恒星的大气参数 (T_{eff} , $\lg g$, $[\text{Fe}/\text{H}]$ 等)。在使用 SDSS-III APROGEE DR13 光谱进行训练后, 其准确性与 APOGEE 的 pipeline 近似。在使

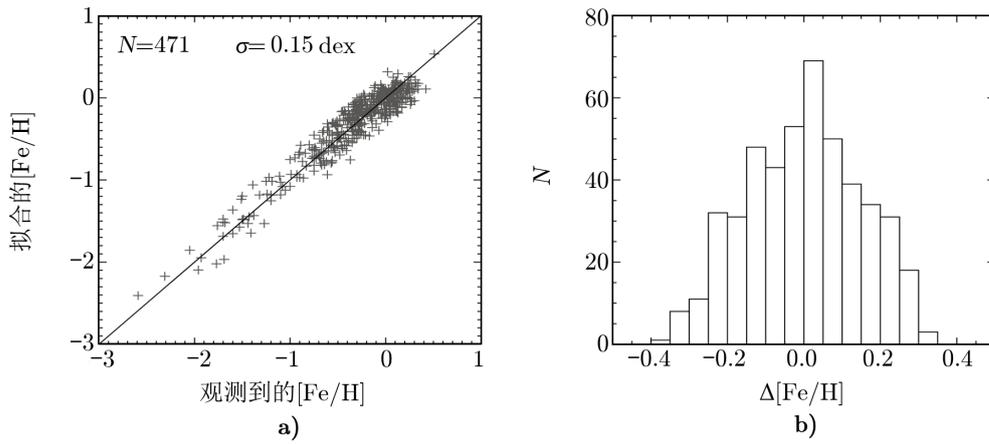


图 3 a) 拟合得到的金属丰度与光谱确定值的比较; b) 残差的分布情况

用相同的训练数据时, 把 StarNet 与 Cannon 2^[30] 进行了对比, StarNet 的结果更好一些。

4.2 参数测量

4.2.1 数据准备

我们采用的数据样本和前面多项式拟合方法相同, 选取温度为 4000 ~ 7000 K 的恒星测光数据, 一共 598 条数据。

4.2.2 网络结构

参数测量采用深度学习卷积神经网络的方法, 输入量为 MILES 光谱数据卷积 SAGE 滤光片响应曲线 6 个星等数据 ($u_{SC}, v_{SAGE}, g, r, i, V$)。同时输出 3 个参数: $T_{\text{eff}}, \lg g, [\text{Fe}/\text{H}]$ 。之所以要 3 个参数同时输出, 是考虑到参数之间存在简并问题。只有计算的 3 个参数在同一个模型中均逼近已知参数时, 模型才有意义。具体的卷积神经网络模型结构如图 4 所示。



图 4 网络结构

4.2.3 数据预处理

在使用深度网络模型进行训练之前, 为了得到比较理想的结果, 需要对数据进行归一化。本论文的归一化方法为对输入、输出数据的每个维度进行单独归一化处理。这样做的好处是可以更加平衡各个参量权重, 消除不同统计量之间的尺度差异。如由于零点不同导致的星等差异, 恒星的有效温度 T_{eff} 、金属丰度 $[\text{Fe}/\text{H}]$ 与表面重力 $\lg g$ 量纲不同导致数值尺度不同的差异等。

本方法使用的归一化方法为把每一个维度的数值都调整到 0 ~ 1 范围内。比如 u_{SC} 星等的调整用如下公式:

$$u_{SC1} = \frac{u_{SC} - u_{\min}}{u_{\max}}, \quad (6)$$

其中, u_{SC1} 为 u_{SC} 归一化后的值, u_{min} 和 u_{max} 分别为 u_{SC} 星等的最小和最大值。

经过测试, 数据集中在 598 条数据里面, 94 条数据的误差比较大。误差大可能由于观测和参数的不准确, 或者来自于模型的映射函数。被删除的这 94 条数据, 是在做模型学习后, 估计值与输入值在 2σ 之外的点。这些数据为均匀分布, 与温度的相关性不大。因为并不能确定输入的观测值与恒星参数误差到底多大, 在最后拟合的时候, 这些误差比较大的点被剔除掉, 最后还剩 505 条数据。

4.2.4 结果

经过深度学习 (见图 4) 的学习后, 得到的参数对比如图 5 所示。图中横坐标均为输入参数值, 纵坐标为算法通过输入预测的结果。每个绿色的点代表一条观测数据, 红色的线为“1:1”线。预测的参数值与输入的参数值的方差如下: 有效温度 T_{eff} 为 73.5 K, 金属丰度 $[Fe/H]$ 为 0.14 dex, 表面重力 $\lg g$ 为 0.24。

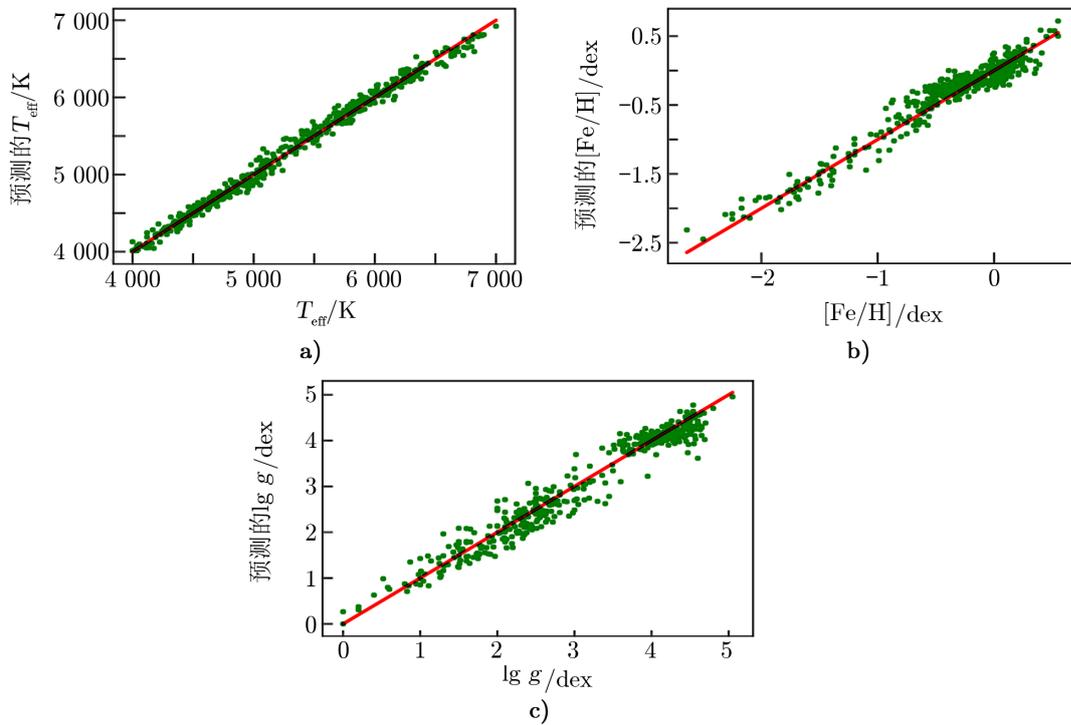


图 5 参数回归结果

4.2.5 讨论

由于目前训练数据只有 505 条, 而在深度网络中待训练的参数非常多, 这容易导致模型对训练数据的过拟合。为了避免太严重的过拟合情况, 在模型中设置了比较大的退出率值 (退出率为 0.5)。今后的工作中, 将加入扩展的 MILES 光谱库 LEMONY^[31], 扩大样本数量。相信随着巡天中数据的逐步积累, 我们可以得到更多的训练数据, 通过这些数据能够更

好地评价模型的好坏。数据在实际使用中, 参数的误差是非常重要的一个值。目前的算法不包括误差的估算。我们将进一步改进算法, 增加对恒星参数的误差估计。

5 总结与展望

对于 $0.1 < g - i < 1.7$ mag 的 FGK 恒星, SAGE 测光系统利用本文中的方法, 同时使用多项式和深度学习, 可提升精度和可靠性, 得到一个完备恒星样本的大气参数。利用这个样本, 可以发现极端贫金属星、白矮星等特殊恒星的候选体。结合 Gaia 的天测数据和 LAMOST 的视向速度数据, 还可以对银河系结构进行研究。通过建立不同银心距、银盘距离处的金属丰度分布函数, 可以得到白矮星的光度函数。随着 SAGE 巡天的开展, 人们将得到约 5×10^9 颗恒星的大气参数和消光, 必将加深人们对银河系的形成和演化的认识和理解。

参考文献:

- [1] Del Popolo A, Le Delliou M. 2016, arXiv:1606.07790
- [2] Magain P. *A&A*, 1987, 181: 323
- [3] Alonso A, Arribas S, Martines-Roger C. *A&A*, 1996, 313: 873
- [4] Alonso A, Arribas S, Martines-Roger C. *A&AS*, 1999, 140: 261
- [5] Holmberg J, Nordstrom B, Andersen J. *A&A*, 2007, 475: 519
- [6] Casagrande L, Ramírez I, Meléndez J, et al. *A&A*, 2010, 512: A54
- [7] Huang Y, Liu X W, Yuan H B, et al. *MNRAS*, 2015, 454: 2863
- [8] Strömgren B. *Astrophysica Norvegica*, 1964, 9: 333
- [9] Olsen E H. *A&AS*, 1981, 57: 443
- [10] Nissen P. *A&A*, 1981, 97: 145
- [11] Ivezić Z, Sesar B, Jurić M, et al. *ApJ*, 2008, 684: 287
- [12] York D G, Adelman J, Anderson J E, et al. *AJ*, 2000, 120: 1579
- [13] Zheng J, Zhao G, Wang W, et al. *RAA*, 2019, 19: 3
- [14] Zheng J, Zhao G, Wang W, et al. *RAA*, 2018, 18: 147
- [15] 郑捷, 赵刚, 王炜, 等. *天文研究与技术*, 2019, 16: 93
- [16] 范舟, 赵刚, 王炜, 等. *天文学进展*, 2018, 36: 2
- [17] Sánchez-Blázquez P, Peletier R F, Jiménez-Vicente J, et al. *MNRAS*, 2006, 371: 703
- [18] Cenarro A J, Peletier R F, Sánchez-Blázquez P, et al. *MNRAS*, 2007, 374: 664
- [19] Bessell M, Murphy S. *PASA*, 2012, 124: 140
- [20] Bohlin R C, Gordon K D, Tremblay P E. *PASP*, 2014, 126: 711
- [21] Árnadóttir A S, Feltzing S, Lundström I. *A&A*, 2010, 521: A40
- [22] 张荣, 李伟平, 莫同. 2018, arXiv:1804.01653
- [23] Krizhevsky A, Sutskever I, Hinton G E. *ImageNet Classification with Deep Convolutional Neural networks*[C]//Annual Conference on Neural Information Processing Systems. Cambridge: MIT Press, 2012: 1097
- [24] Deng J, Dong W, Socher R, et al. *ImageNet: A Large-scale Hierarchical Image Database*[C]//IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2009: 248

- [25] Zeiler M D, Fergus R. Visualizing and Understanding Convolutional Networks[C]//European Conference on Computer Vision. Cham, Switzerland: Springer International Publishing AG, 2014: 818
- [26] Simonyan K, Zisserman A. arxiv: 1409.1556
- [27] Szegedy C, Liu W, Jia Y, et al. Going Deeper with Convolutions[C]//IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2015: 1
- [28] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 770
- [29] Fabbro S, Venn K A, ÓBriain T, et al. MNRAS, 2018, 475: 2978
- [30] Andrew R C, David W H, Melissa N, et al. arXiv:1603.03040
- [31] Wang C, Liu X W, Huang Y, et al. MNRAS, 2018, 480: 4766

Introduction of SAGE Survey II —— The Determination of Stellar Atmospheric Parameters

ZHAO Jing-kun¹, ZHAO Gang^{1,2}, FAN Zhou¹, TAN Ke-feng¹,
SONG Yi-han¹, WANG Qi-xun^{1,2}, WANG Wei^{1,3}

(1. Key Laboratory for Optical Astronomy, National Astronomical Observatory, Chinese Academy of Sciences, Beijing 100012, China; 2. School of Astronomy and Space Science, University of Chinese Academy of Sciences, Beijing 100049, China; 3. Chinese Academy of Sciences South America Center for Astronomy, China-Chile Joint Center for Astronomy, Santiago 7550000, Chile)

Abstract: The photometric system and data reduction of SAGE survey has been introduced before. This paper mainly focuses on the stellar parameter determination of stars from the SAGE survey. First, the previous work on stellar parameter estimation from photometric color is reviewed. Then, we illustrated two methods to derive the stellar parameters: polynomial fitting and deep learning with MILES spectral library. For each method, the theory, accuracy and characteristic are presented in detail. Finally, the prospect of the stellar parameters of the SAGE survey are demonstrated.

Key words: photometric system; stellar atmosphere; deep learning