中国科学: 地球科学 2024 年 第 54 卷 第 8 期: 2496 ~ 2514
SCIENTIA SINICA Terrae earthcn.scichina.com
《中国科学》杂志社 SCIENCE CHINA PRESS
论 文

# 太阳活动预测: 太阳黑子数和太阳综合磁图

卓睿[1], 何建森[1*], 段叠[2], 林荣[1,3], 吴子祺[1], 闫丽梅[4,5], 魏勇[4,5]

1. 北京大学地球与空间科学学院, 北京 100091;
2. 国防科技大学前沿交叉学科学院, 长沙 410073;
3. Centre for Mathematical Plasma Astrophysics, Department of Mathematics, KU Leuven, Leuven 3001, Belgium;
4. 中国科学院地质与地球物理研究所地球与行星物理重点实验室, 北京100029;
5. 中国科学院大学地球与行星科学学院, 北京100049
* 通讯作者, E-mail: jshept@pku.edu.cn

收稿日期: 2023-12-15; 收修改稿日期: 2024-04-13; 接受日期: 2024-05-30; 网络版发表日期: 2024-07-17
国家自然科学基金项目(42241118、42174194、42150105、42204166、42241106、42074207)、国家重点研发计划项目(2021YFA0718600、2022YFF0503800)、民用航天技术预研项目(D050106)和中国科学院青年创新促进会项目(2021064)资助

**摘要** 太阳磁场的演化对于了解和预测太阳活动至关重要, 而目前对于太阳磁场的认识很大程度依赖于光球磁场. 本文基于威尔科克斯天文台观测的光球磁场及其球谐展开形式, 对光球磁场球谐系数的时间序列进行了分析, 并对第25太阳活动周的太阳黑子数和综合磁图进行了预测. 结果发现, 光球磁场在太阳高年存在着复杂的短周期扰动. 此外, 光球磁场球谐系数$g_7^0$与太阳黑子数的时间序列接近同相位, 这可能与太阳的子午环流有关. 利用长短时记忆网络(LSTM), 本文预测第25活动周的太阳黑子数峰值可能出现在2024年6月前后8个月内, 峰值黑子数预计为166.9±22.6, 下一个黑子数最低值可能出现在2031年1月左右. 结合经验模态分解方法, 进一步预测了截断到5阶的太阳综合磁图, 并验证了预测结果具有一定的可靠性. 此次预测不仅弥补了太阳磁场全球分布预测的空白, 而且对未来的太阳观测计划具有潜在的参考价值.

**关键词** 太阳活动预测, 太阳磁场, 球谐展开, 长短时记忆(LSTM), 经验模态分解(EMD)

## 1 引言

太阳黑子数(Sunspot Number, SSN)作为太阳活动的重要指标, 很早就有了持续的记录. 1843年, Schwabe总结了25年的太阳观测, 发现太阳黑子数具有约10年的周期性. 为了更系统地记录太阳黑子数, R. Wolf于1848年提出了相对太阳黑子数的概念, 被称为Wolf太阳黑子数(Wolf Sunspot Number, WSN). WSN的时间序列揭示了11年的太阳活动周(Solar Cycle, SC), 分为上升相和下降相. 此外, 太阳极区磁场在峰年发生反转, 形成22年的太阳磁场周期. Babcock (1961)提出了太阳活动周的经验模型, 其中极向场和环形场在不同的活动周相位中相互转换. 这一假说与观测结果十分吻合, 并被广泛接受.

为了深入研究太阳磁场演化的细节, 研究者们通过球谐展开(网络版附录A, http://earthcn.scichina.com)

中文引用格式: 卓睿, 何建森, 段叠, 林荣, 吴子祺, 闫丽梅, 魏勇. 2024. 太阳活动预测: 太阳黑子数和太阳综合磁图. 中国科学: 地球科学, 54(8): 2496–2514, doi: 10.1360/N072023-0305
英文引用格式: Zhuo R, He J, Duan D, Lin R, Wu Z, Yan L, Wei Y. 2024. Prediction of solar activities: Sunspot numbers and solar magnetic synoptic maps. Science China Earth Sciences, 67(8): 2460–2477, https://doi.org/10.1007/s11430-023-1354-4

© 2024 《中国科学》杂志社 

对太阳磁多极矩的演化特征展开研究. Stenflo和Vogel (1986)以及Stenflo和Güdel(1988)根据Mt. Wilson和Kitt Peak提供的综合磁图, 对球谐系数的时间序列进行傅里叶变换, 发现轴向反对称球谐函数(例如轴向偶极子和轴向八极子)具有显著的22年周期性, 轴向对称球谐函数则不具备22年周期性, 而是表现为一系列的谐振信号. Knaack和Stenflo(2005)对Stenflo的工作进行了延伸, 使用小波变换分析时间序列, 并提出了周期分别为2.1~2.5、1.5~1.8和1.2~1.4年的三种间歇性振荡. 2.1~2.5年的振荡在与非线性发电机波动相关的系数中最为明显(Stix, 1972), 可能代表非线性发电机模型中某些尚未解释的方面. 1.5~1.8年的周期性在奇数活动周(SC 21和23)中更为明显, 而1.2~1.4年的周期性在偶数活动周(SC 22和24)中更为明显.

此外, 人们对预测太阳活动也越来越感兴趣, 特别是即将到来的太阳活动周的太阳黑子数(SSN). 一般来说, SSN的预测方法可分为三类: 前兆法、基于模型法和外推法(Petrovay, 2020).

(1) 前兆法旨在识别SSN的预兆, 通常采用极场和地磁指数作为前兆. 极场前兆法基于当前活动周的太阳黑子数峰值与前一个谷年中的太阳极区磁场之间的相关性. 磁力线的缠绕可以将极向场转变为环形场, 因此谷年的太阳极场可以被视为峰年磁场的种子, 从而与未来活动周的太阳黑子数联系起来. 地磁前兆法源自Ohl的想法, 即谷年的地磁aa指数与下一个峰年的黑子数峰值正相关(Ohl, 1966). aa指数反映了太阳极场, 实际代表了行星际空间中开放的磁通量(Jiang等, 2007, 2013). 对于SC 24, 极性前兆法的预测结果与实际SSN峰值之间的误差小于10%, 而基于地磁aa前兆的预测通常低于观测值(Obridko和Shelting, 2008; Wang和Sheeley, 2009; Bhatt等, 2009).

(2) 模型法利用太阳发电机的理论模型进行预测, 理论上可以反映太阳黑子的本质. 尽管这种方法具有坚实的物理基础, 但高度依赖于我们对太阳发电机的理解, 同时还包含大量的假设和待定参数, 因此也具有相当大的任意性. 一个不错的实例是Choudhuri等(2007)采用的磁通量传输发电机模型, 该模型预测第24活动周的太阳黑子数峰值将比第23活动周低30%~35%(实际低了40%).

(3) 外推法则试图从数学的角度解决问题, 将太阳黑子数序列视为一个普通的序列. 这种泛化方法使之便于与不断发展的计算机算法相结合, 并且能够捕捉理论和观测中尚未认识到的潜在规律. 近几十年来, 该领域的发展势头十分迅猛. 最简单的模型是线性模型, 如自回归移动平均(Auto-Regressive Moving Average, ARMA), 及其非稳态变体(自回归积分移动平均, Auto-Regressive Integrated Moving Average, ARIMA)和周期性变体(季节性自回归积分移动平均, Seasonal Auto-Regressive Integrated Moving Average, SARIMA). 但由于其效果不佳, 研究者们转而考虑非线性模型, 如循环神经网络(Recurrent Neural Network, RNN). Calvo等(1995)首次尝试的RNN预测与观测相比存在较大的偏差, 但随着计算机技术的进步, 更稳健的模型训练使得偏差逐渐减小(Maris和Oncica, 2006; Uwamahoro等, 2009). 长短时记忆(Long-Short Term Memory, LSTM)是一种特殊的RNN, 自诞生以来迅速发展, 并已应用于预测第25活动周的太阳黑子数(Lee, 2020; Hasoon和Al-Hashimi, 2022; Prasad等, 2022). Lundstedt等(2005)认为, 非线性神经网络对于太阳活动的预测是值得认可的, 因为太阳活动本身就是一个高度非线性的混沌动力系统.

一方面我们注意到, 尽管Stenflo和Vogel(1986)、Stenflo和Güdel(1988)以及Knaack和Stenflo(2005)对光球磁场的球谐系数进行了相对细致的讨论, 但仍遗漏了一部分间歇性的周期信号, 而持续性的周期信号也未必能持续贯穿所有活动周. 此外, 这些研究中并没有深入探讨各个系数之间, 以及这些系数与太阳黑子数(SSN)之间的可能存在的相位关系.

另一方面, 目前已有大量研究对太阳黑子数进行了预测, 也有部分研究关注了其他方面, 例如耀斑发生的可能性和强度(Qahwaji和Colak, 2006)、太阳表面的大尺度磁场(Jiang和Cao, 2018)以及宇宙放射性同位素的丰度(Lockwood, 2010; Lockwood等, 2011). 然而, 需要强调的是, 这些研究通常侧重于特定位置或总体概览的太阳活动, 对未来太阳磁活动全球分布的了解仍然存在空白.

我们的工作包括两个主要部分. 首先, 采用小波变换分析光球磁场球谐系数的时间序列, 揭示了太阳峰年存在着间歇性的短周期振荡. 借助李萨如图, 进一步发现, 尽管$l$为奇数且$m$为零的球谐系数与SSN都有22年的周期性, 但不同系数与SSN之间的相位关系存在明显的差异. 有趣的是, 系数$g_7^0$几乎与SSN同相位,

我们猜测这可能与太阳的子午环流(Meridional Circulation, MC)有关. 之后, 我们利用长短时记忆网络并与经验模态分解相结合, 预测了未来12年的太阳黑子数和综合磁图. 本次模型预测第25太阳活动周的SSN峰值将出现在2024年6月前后8个月内, 峰值强度估计为166.9±22.6. 值得一提的是, 本工作首次预测了光球磁场的全球分布. 通过综合分析和比较, 验证了我们预测的综合磁图在一定范围内具有一定的可靠性.

## 2 数据来源: 太阳综合磁图及其球谐展开系数

由于WSN仅仅基于"首席观测者"的观测(Waldmeier, 1961), 其不确定性可高达25%(Vitinsky等, 1986). 因此在1986年, 比利时皇家天文台提供的国际太阳黑子数(International Sunspot Number, ISN)取代了WSN(Clette等, 2007). ISN是来自全球30多个观测者观测结果的加权平均值, 大大提高了最终结果的可靠性. 2015年, 比利时皇家天文台将ISN更新为2.0版本, 该版本采用A.Wolfer而非R.Wolf进行校准, 与1.0版本相比引入了0.6的比例因子(Clette等, 2014). 本文使用的SSN数据是13个月平滑的月度ISN v2.0, 时间跨度从1749年7月到2022年11月. 目前太阳正处于第25活动周的上升相.

作为太阳磁场全球分布的反映, 综合磁图被视为研究太阳物理的重要工具. 世界各地的观测台站和组织已经积累了多年的综合磁图观测数据, 包括威尔科克斯太阳天文台(Wilcox Solar Observatory, Stanford/WSO)、全球日震网络组(Global Oscillation Network Group, NSO/GONG)和太阳动力学天文台(Solar Dynamics Observatory, SDO)上的日震和磁成像仪(Helioseismic and Magnetic Imager, SDO/HMI). WSO利用Babcock型磁像仪获取光球磁场的视线分量, 并自1975年以来无间断地记录综合磁图(Scherrer等, 1977). WSO综合磁图覆盖经度0°~360°, 纬度75°S~75°N, 网格精度为73×30. 截至本文完成时, WSO提供了从1976年4月30日到2023年10月1日(CR1641至CR2276)的综合磁图数据.

除了综合磁图之外, 一些观测台站还提供了光球磁场的球谐展开系数. 对于每一个卡林顿周(Carrington Rotation, 1CR=27.2753天), WSO提供了截断到9阶的球谐系数. 根据这些系数, 我们可以使用附录A中的方程(4)计算每个纬度和经度处的径向磁场, 并重构低阶综合磁图. 图1a~1c分别展示了对于CR2239, WSO的截断到5阶和截断到9阶的重构磁图以及直接观测磁图. 尽管低阶磁图与观测磁图在磁场强度和细节分布上存在差异, 但在一定程度上可以反映光球磁场的整体分布, 包括强磁场区域的位置和范围, 以及极区磁场的延伸情况.

对于地球上的预报业务, 更直接的影响因素是太阳源表面上($2.5R_S$)的磁场分布, 这可以通过势场源表面(Potential Field Source Surface, PFSS)模型得到. 图1d~1f显示了基于WSO和GONG对于CR2239的观测,

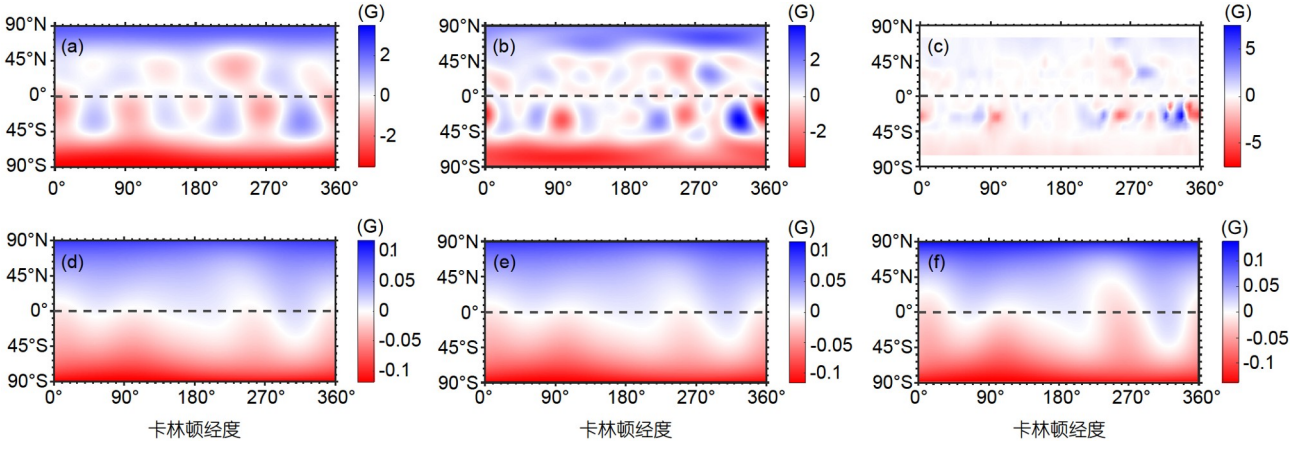


**图 1 基于WSO和GONG的观测得到的CR2239的综合磁图及其在源表面上的PFSS结果**

(a) 截断到5阶的重构磁图; (b) 截断到9阶的重构磁图; (c) 直接观测的WSO磁图; (d) 5阶重构磁图在源表面上的PFSS结果; (e) 9阶重构磁图在源表面上的PFSS结果; (f) 直接观测的GONG磁图在源表面上的PFSS结果. 水平虚线表示太阳的赤道

由低阶重构磁图得到的PFSS结果. 在源表面, 5阶重构磁图在源表面的磁场分布与观测磁图之间的相关系数达到0.990705, 而9阶重构磁图与观测磁图之间的相关系数为0.990708. 因此, 对预报业务而言, 截断到5阶的球谐系数就足以较好地代表全球的磁场分布.

本文采用WSO磁图及其相应的球谐系数作为原始数据, 在分析时阶数限制在9阶以内, 而在预测时阶数限制在5阶以内. 这种选择是出于对数据规模的考虑, 因为WSO提供的长期和稳定的观测最有利于使用机器学习进行预测. 与截断到9阶相比, 如果我们将系数截断到5阶进行预测, 就可以节省三分之二的计算资源. 另外, 低阶重构磁图已经足以捕捉到大尺度分布, 而更细节的磁场结构有可能在长期内不具备可预测性.

## 3　时间序列分析

为了研究太阳磁活动的规律, 我们首先分析光球磁场球谐系数的时间序列. 图2呈现了ISN的时间序列, 图3和图4呈现了球谐系数的时间序列. 值得注意的是, 对于关键系数$g_1^0$, 我们观察到其在太阳活动峰年到来后不久出现了极性反转, 而在太阳活动谷年时达到了极值. 此外, 所有$l$为奇数且$m$为零的系数都表现出显著的22年周期性, 而它们之间的相位差异很大. 接下来, 我们将对这些系数各自的周期和相位进行详细分析.

### 3.1　谐系数的周期性

我们采用小波变换分析1~9阶的球谐系数, 并关注周期小于30年的周期性特征. 图5和图6展示了相应的小波频谱, 可以看到其中存在着不同周期和不同时段的频谱模式. 我们将这些模式分为两种类型: 一种是持续型(C型), 持续几个太阳活动周; 另一种是间歇型(I型), 持续时间不足一个太阳活动周, 但在不同活动周中反复出现. 关于频谱模式的周期总结见附表S1 (http://earthcn.scichina.com).

C型模式通常对应于较长的周期. 最明显的例子是$l$为奇数且$m$为零的系数具有的22年周期性. 这些系

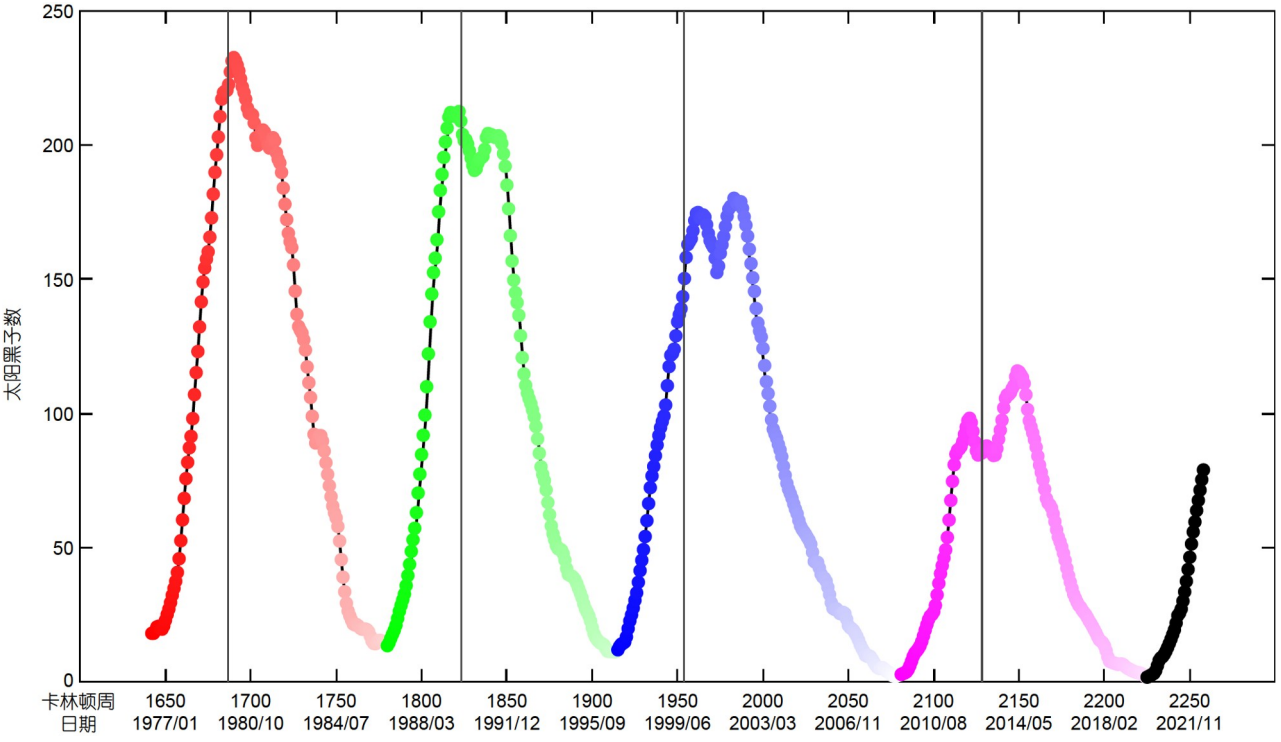


**图 2　1976-04-30至2022-05-28期间的ISN时间序列**

数据为13个月平滑. 不同的颜色代表不同的太阳活动周, 在一个周期内颜色逐渐从深到浅. 黑色竖线表示太阳磁场极性反转的时刻

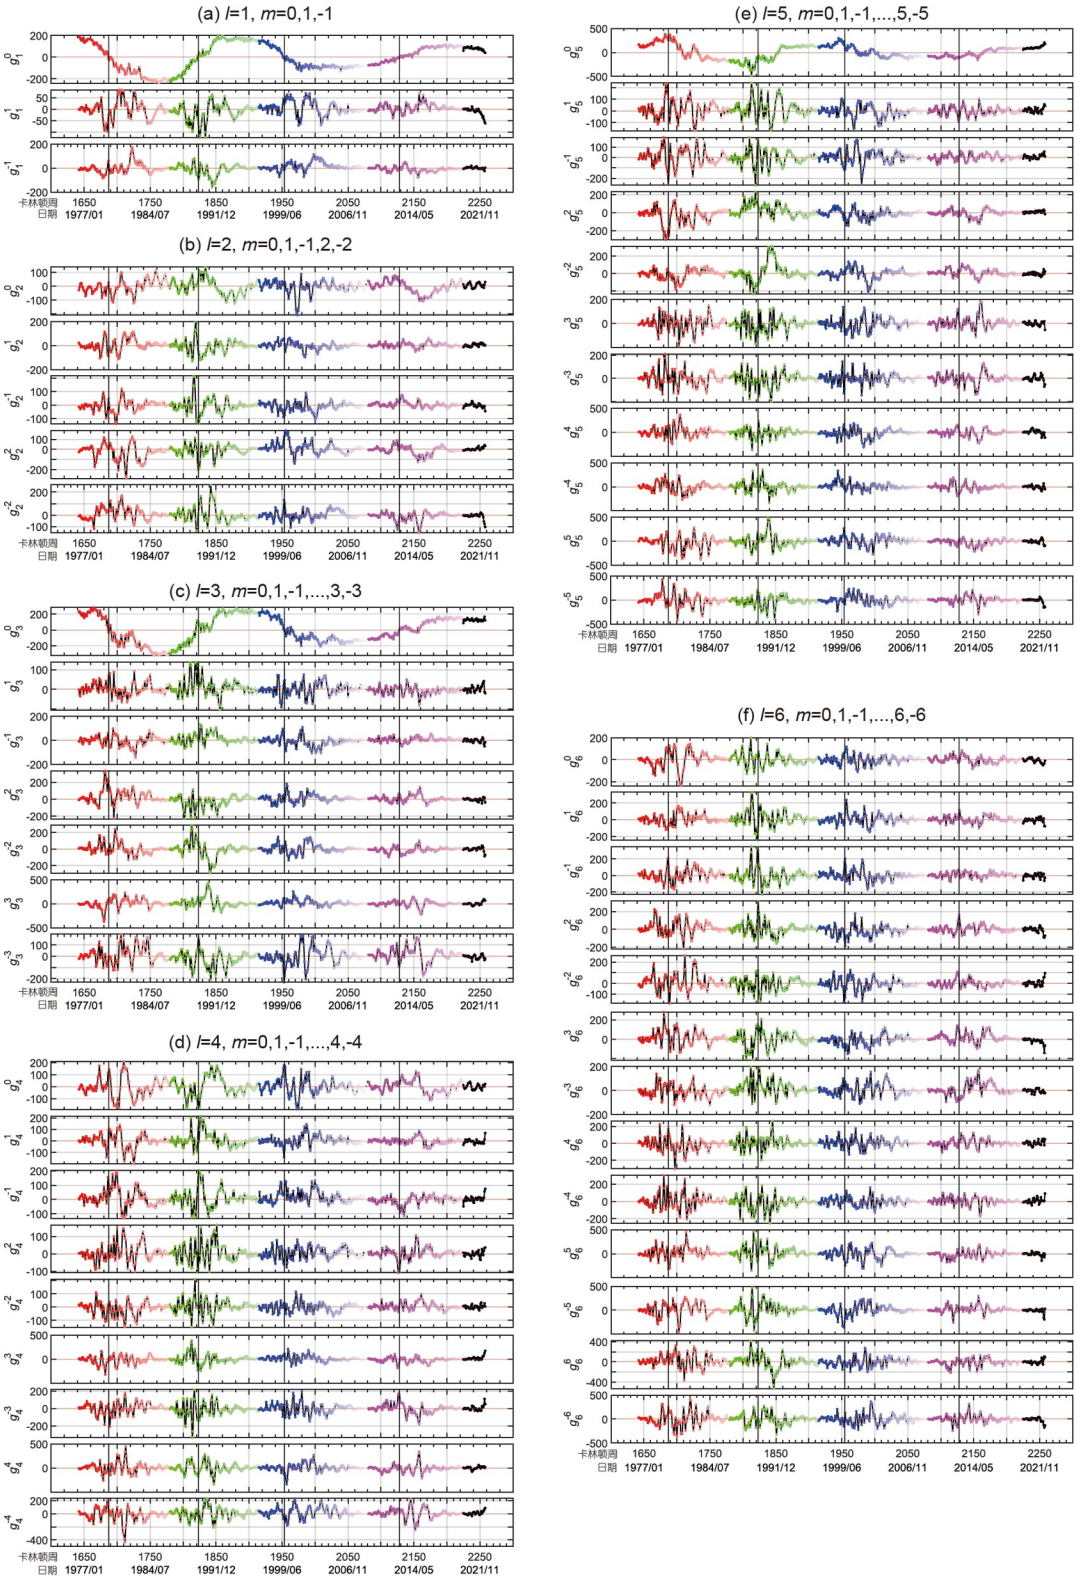


**图 3　1976-04-30至2022-05-28期间1~6阶球谐系数的时间序列**

颜色和竖线的含义与图2相同

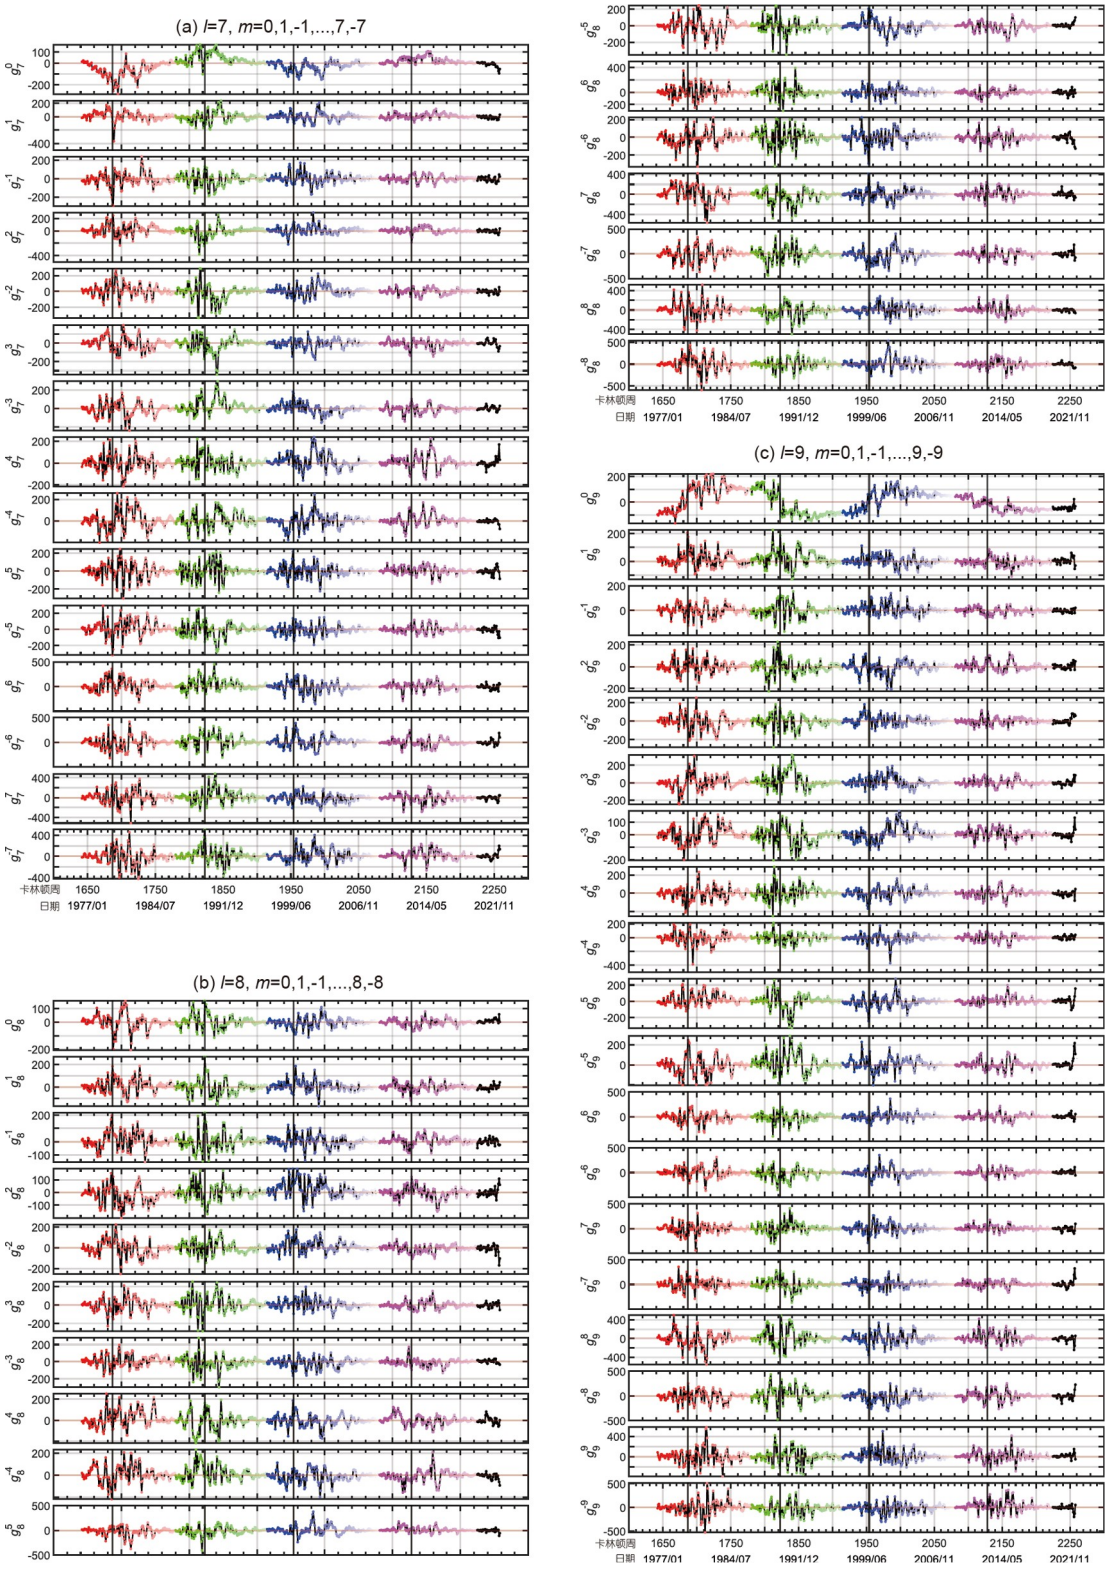


**图 4　1976-04-30至2022-05-28期间7~9阶球谐系数的时间序列**

颜色和竖线的含义与图2相同

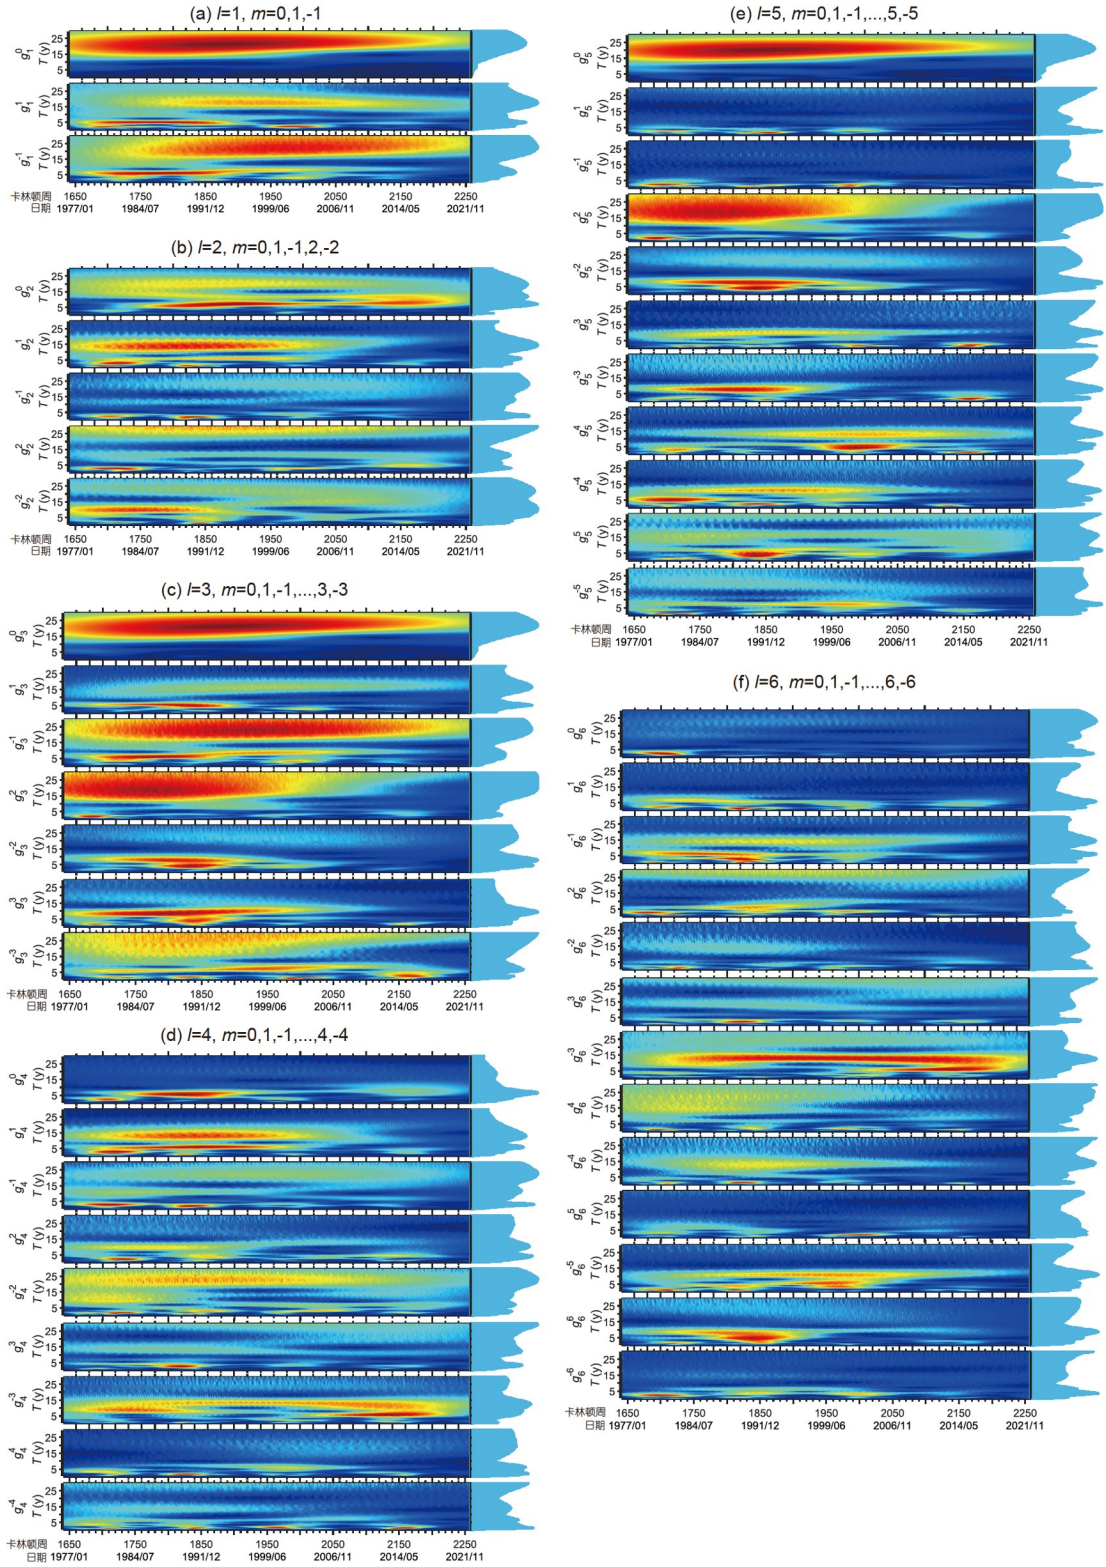


**图 5　1~6阶球谐系数的小波频谱及其时间平均值**

平均值显示在每个图版右侧. 相同阶数*l*的系数按照其度数*m*的顺序排列. 黑色竖线表示太阳磁场极性反转的时刻

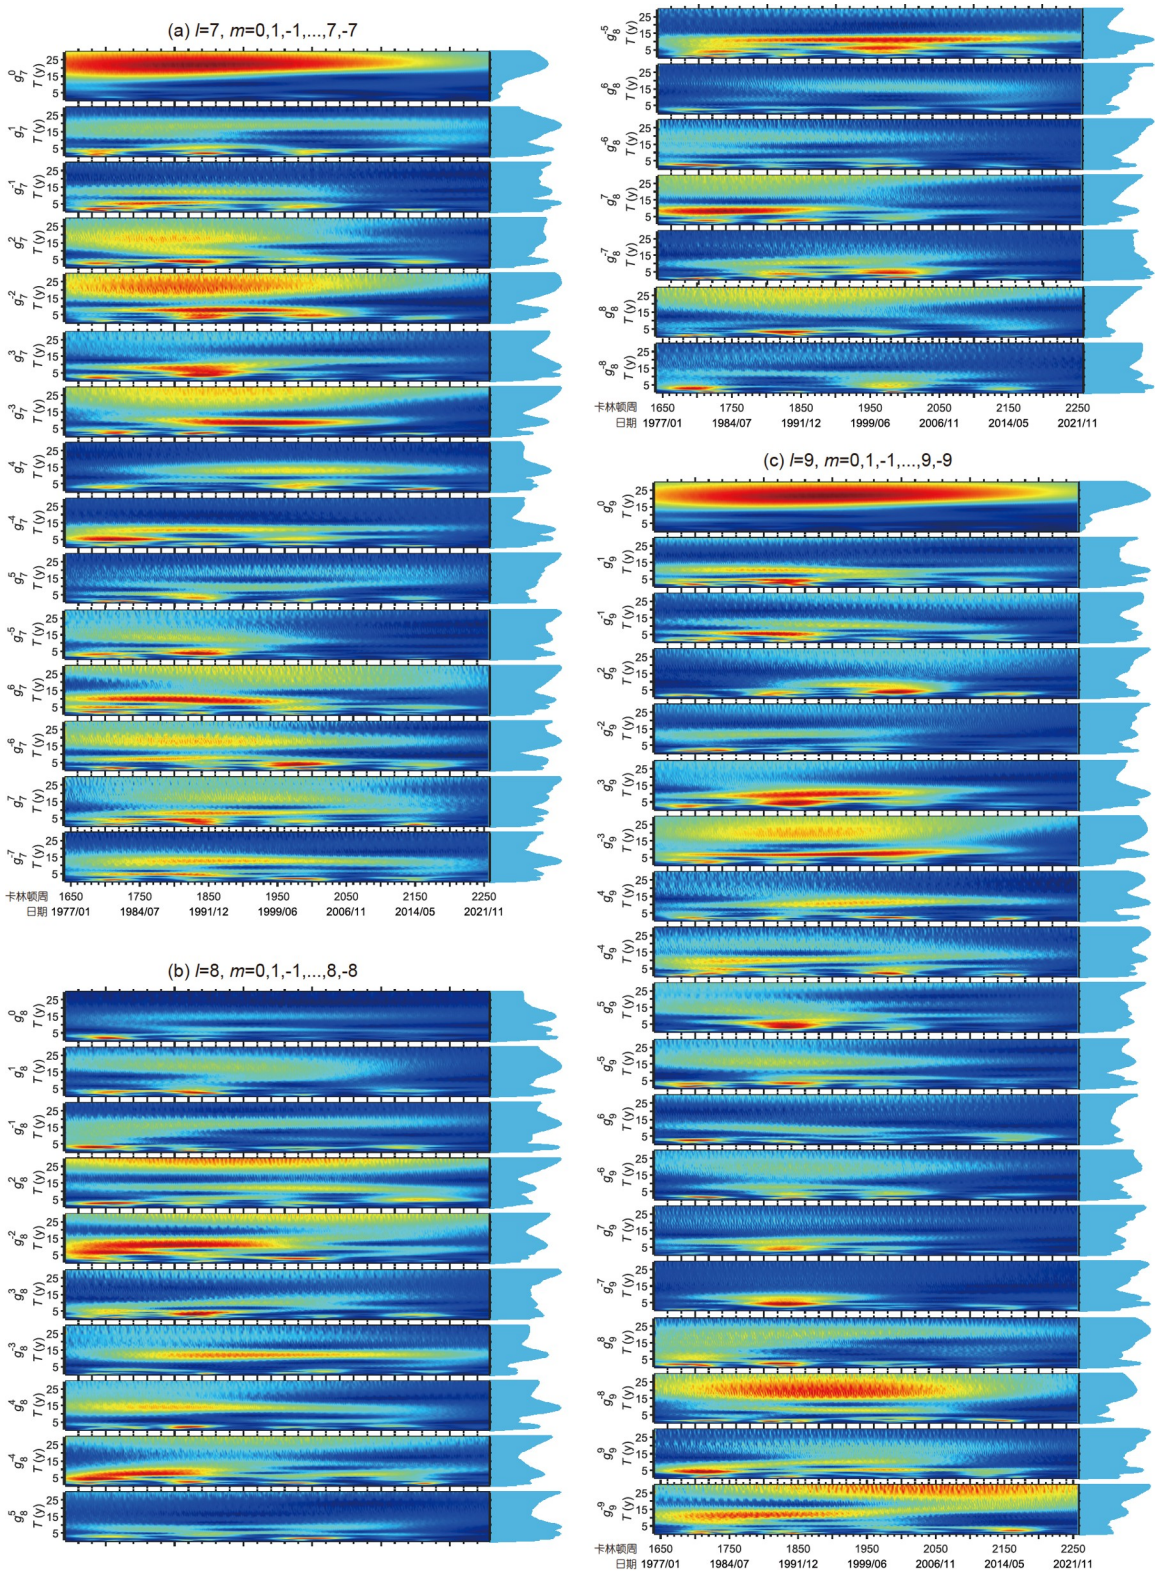


**图 6　7~9阶球谐系数的小波频谱及其时间平均值**

平均值显示在每个图版右侧. 相同阶数$l$的系数按照其度数$m$的顺序排列. 黑色竖线表示太阳磁场极性反转的时刻

数对应于轴向反对称的磁多极矩, 因此与太阳磁周期共有22年的周期性. 我们发现, 在最近的两个太阳活动周中, 这些系数的幅度有所下降, 这些22年周期模式的强度也逐渐减弱. 同时, 太阳黑子数在最近的两个活动周中也有所减少. 因此, 我们认为这些对应轴向反对称磁多极矩的系数和太阳黑子数都能反映太阳磁活动的活跃水平. 除此以外, 我们还注意到许多C型模式在2000年左右发生了显著的变化. 例如, 系数$g_3^{-2}$在2000年前具有非常明显的周期为8年左右的频谱模式, 但该模式此后迅速减弱; 类似的情况也发生在系数$g_3^3$、$g_4^1$、$g_5^{-2}$、$g_5^{-3}$、$g_6^6$、$g_7^6$和$g_8^7$中. 现有研究尚未能对此提供令人信服的解释.

I型模式通常对应于短周期, 并广泛存在于大多数系数中. 对于不同的系数, 其周期范围从1年到3年不等. 值得注意的是, I型模式一般出现在极性反转(黑色实线)后不久, 与活动峰年的时间一致(图2). 实际上, 在时间序列(图3和图4)中也可以看出, 在太阳活动峰年, 许多系数的短周期扰动都显著增强. 这表明在太阳活动峰年, 太阳磁场会呈现出更复杂的短周期扰动. 短周期的周期性特征(例如, 年变化, 1.3~1.7年、准两年和4~5年的振荡)也在极区光斑的分析中被揭示出来, 并显示出南北半球的不对称性(Deng等, 2014, 2020).

### 3.2 $g_l^0$和太阳黑子数之间的相位差

如上所述, $l$为奇数且$m$为零的系数与太阳磁周期共有22年的周期性. 在图7中, 我们展示了ISN与$m$为零的系数的李萨如图, 其中散点的颜色表示时间顺序. 从图7中可以看出, 这些系数与SSN之间具有不同的相位差. 对于$g_1^0$和$g_3^0$而言, 在第21活动周(红色)和第23活动周(蓝色)中, 该系数从正转变为负, 且SSN峰值出现在横轴下方; 而在第22活动周(绿色)和第24活动周(洋红色)中则相反. 这意味着这些系数的反转早于SSN峰值. 因此, $g_1^0$和$g_3^0$的绝对值比SSN超前的相位略大于$\pi$(5.5年). 而对于系数$g_5^0$和$g_9^0$, 它们的反转晚于SSN的峰值, 所以其绝对值比SSN超前的相位略小于$\pi$(5.5年).

最有趣的结果是系数$g_7^0$和SSN几乎同时达到极值(图7g), 它们之间的相位差很小. 我们注意到球谐函数$S_{70}(\theta, \varphi)$将一个半球按极性划分为四个纬度带(图8). 而对太阳子午环流的模拟表明, 在陀螺泵效应的作用下, 在光球层下方的对流层顶部, 一个半球的纬度范围内存在着两个逆时针方向的子午环流单元, 如图9所示(Featherstone和Miesch, 2015; Karak等, 2014). 这里所说的逆时针方向, 指的是沿着太阳自转方向看去, 观察到的子午面内的流动方向. 从太阳的赤道到北极, 光球层底部子午环流的径向分量依次经历了上升、下降、再上升、再下降的运动顺序. 这四次连续交替的上升和下降运动在一个半球的纬度范围内按照径向运动划分出四个纬度带, 这与$S_{70}(\theta, \varphi)$的分布模式极为相似. 此外, 子午环流在维持太阳全球动力学和调节大规模太阳磁场方面起着至关重要的作用(Hanasoge, 2022). 因此, 我们认为$g_7^0$和SSN之间如此小的相位差可能与太阳子午环流密切相关, 而子午环流又与磁流管浮现产生的太阳黑子有关.

## 4 预测太阳黑子数

考虑到SSN具有超过200年的连续记录, RNN对于SSN建模和预测是有效的. 作为RNN的一种特殊类型, LSTM解决了训练过程中梯度消失和梯度爆炸的问题, 因此在处理长序列时表现更好. 关于LSTM的更详细介绍请参见附录B. 在本文中, 构建了一个针对ISN序列的LSTM模型, 并在训练完成后对未来12年的ISN进行了预测.

我们使用PyTorch包搭建模型, 并构建一个映射, 将长度为*look_back*的时间序列(输入)映射到时间序列上的下一个值(输出). 在对原始数据进行归一化后, 从时间序列中提取出“输入-输出”对, 并将它们分为训练集、验证集和测试集. 在训练过程中, 我们设计了一个早停策略, 即当以下三个条件同时满足时停止训练: (1) 验证集损失在给定的*patient*轮训练中连续增加; (2) 验证集损失低于给定的*val_loss_thres*; (3) 训练集损失低于给定的*train_loss_thres*. 训练停止后选择具有最小验证集损失的模型作为最佳模型. 之后, 我们在测试集上对最佳模型进行评估: 除了考虑三个数据集上的损失之外, 还关注模型输出是否能够重现已知的SSN观测规律. 这些步骤都完成后, 我们将整个时间序列末尾的长度为*look_back*的数据段作为输入, 通过最佳模型进行第一个未来预测. 之后, 将第一个预测值添加到原输入数据段的末尾, 同时删除原数据段的第一个数据, 以保持其长度始终为*look_back*. 由此得到

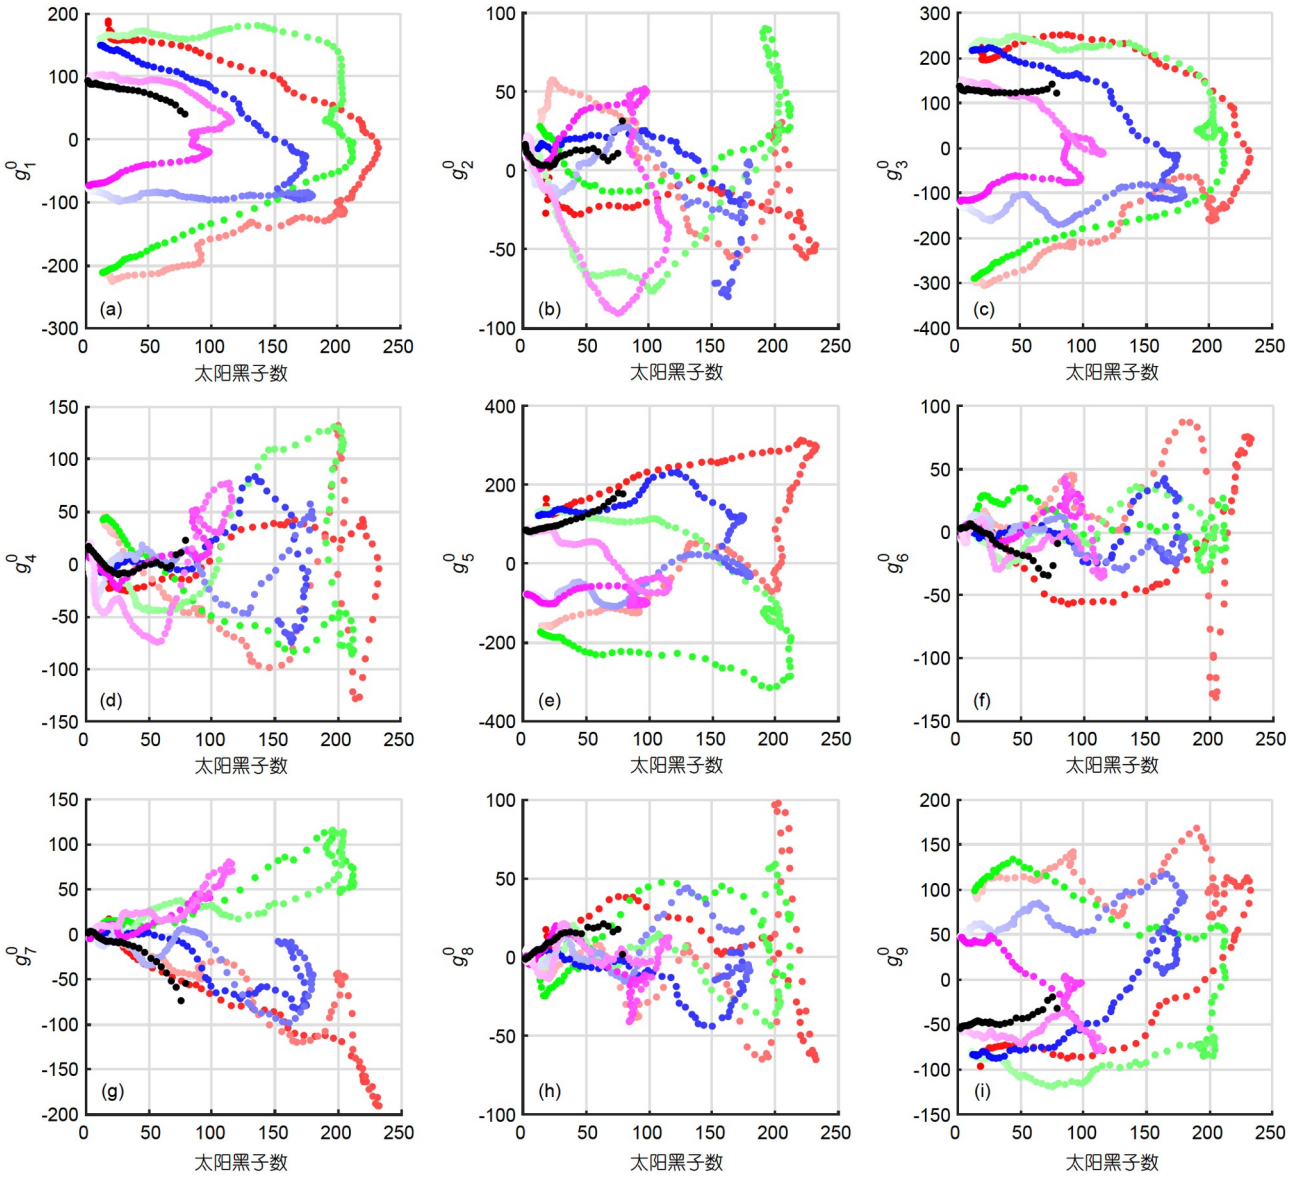


**图 7　ISN与*m*为零的球谐系数的李萨如图**

用于绘图的球谐系数时间序列已预先通过13个月的移动窗口进行平滑处理. 图中颜色的含义与图2相同

的新数据段被输入到最佳模型中进行第二次预测, 再然后进行第三次预测, 以此类推. 最后, 我们将预测序列反归一化, 获得未来的ISN序列. 在图10中, 我们通过可视化的方式展示了上述过程.

经过多次仔细的测试, 我们确定了模型的参数. 13个月平滑的月度ISN序列的长度为3281, 我们选取*look_back*为356(约30年), 并按照0.6:0.2:0.2的比例划分数据集. 我们的LSTM网络是一个3层结构, 隐藏层大小为*look_back*. 在训练过程中, 我们选取均方误差(mean-square error, MSE)作为损失函数, 并选取Adam优化器进行优化. 对于早停策略, 我们选取参数*patient*为10, *val_loss_thres*为0.007, *train_loss_thres*为0.003, 最大训练轮次为2000.

上述建模过程和参数设置确保了能够得到单步预测的最佳模型, 但仍需要对其在长期预测上的表现进行验证. 为了评估模型的适用性和进行ISN长期预测时的预测误差, 我们基于上述设置对SC 24进行了多步预测, 如图11a和11b所示. 预测始于2011年11月, 即

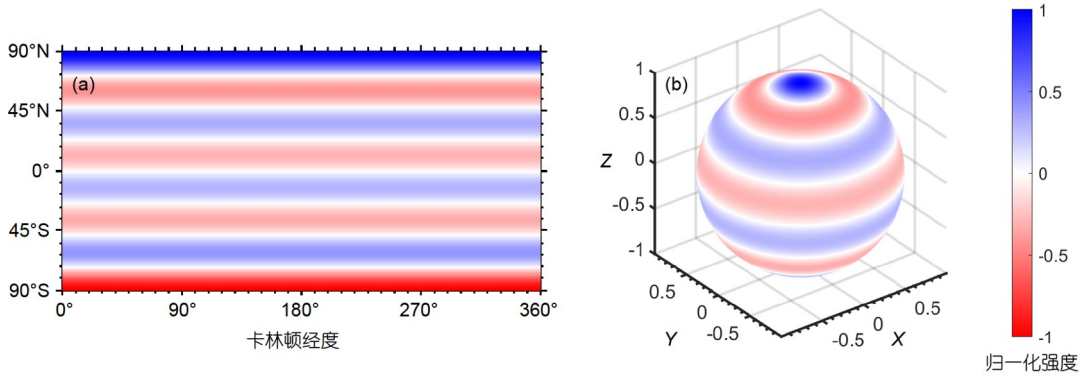


**图 8　球谐函数$S_{70}(\theta, \varphi)$对应的球面分布**

(a) $(\theta, \varphi)$平面内的二维视图; (b) 三维视图. 蓝色代表正极性, 红色代表负极性, 白色线条为中性线

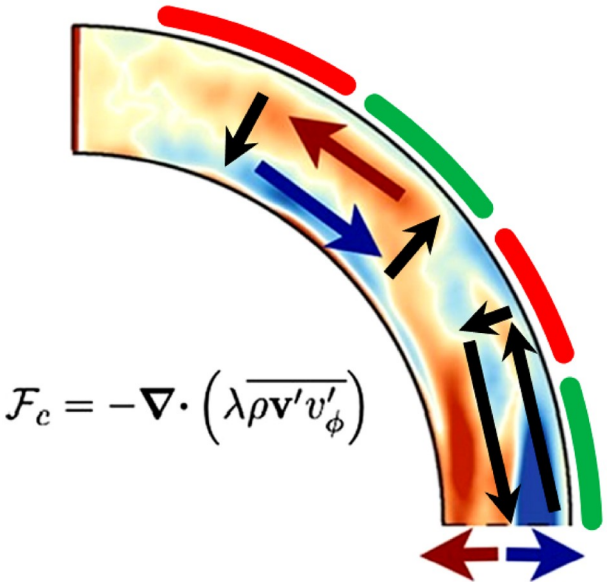


**图 9　使用非弹性球谐(Anelastic Spherical Harmonic, ASH)代码模拟的子午环流剖面**

据Karak等(2014)修改. 经过经度和时间平均的对流角动量通量的负散度, 构成净扭矩$\mathcal{F}_c$的对流分量. 蓝色表示收敛, 红色表示发散. 箭头表示感应子午流的方向, 红色(绿色)弧线表示光球下层子午流的上升(下沉)

ISN可用数据截止时间的11年前, 对应SC 24的上升阶段. 预测的SC 24黑子数峰值出现在2013年8月, 强度为100.9, 而观测到的SC 24黑子数峰值出现在2014年4月, 强度为116.4. 因此, 本文模型对ISN峰值强度的预测存在约13.3%的相对误差, 对ISN峰值到达时间的预测存在约8个月的绝对误差.

接下来, 我们利用模型对未来12年的ISN时间序列进行预测. 图11c和11d展示了模型在训练集(蓝色)、验证集(橙色)和测试集(绿色)上的单步输出, 以及多步预测的ISN时间序列(红色). 可以看到, 模型的单步输出与13个月平滑的月度ISN序列比较匹配, 其均方根误差(root-mean-square error, RMSE)分别为13.576、22.352和14.919.

我们还将本文模型与持续模型(persistent model)进行了比较. 持续模型假设当前$t$时刻的测量值在未来的$t+\delta t$时刻保持不变, 其中$\delta t$是前瞻时间, 在单步预测时取为1. 在相应的三个数据集上, 持续模型与ISN序列之间的RMSE分别为3.493、4.397和3.880. 对于单步预测而言, 持续模型的RMSE小于LSTM模型. 这是很正常的现象, 因为我们的LSTM模型旨在捕捉太阳活动周的长期趋势, 这要求我们不仅要考虑大量的历史数据, 还要避免可能的过拟合问题. 出于这个要求, 我们设计了早停策略, 以在训练集损失和验证集损失没有那么低时就停止训练. 这可能会导致RMSE稍高, 但更有利于长期预测. 相反, 如果目标序列的时间变化平缓且预测时间较短, 持续模型可以表现得相当不错, 然而对于我们最终希望实现的多步预测, 持续模型则无能为力.

本文模型预测, SC 25的ISN峰值将于2024年6月出现, 误差估计为8个月, 峰值强度可能会达到166.9±22.6, 而下一个黑子数最低值将出现在2031年1月左右. 考虑到SC 24的峰值强度为116.4, SC 23为180.3, 预计SC 25将比SC 24更强, 但略弱于SC 23. 我们将SC 25的长度定义为上一个谷年的ISN最小值出现时间(2019年11月)和下一个谷年的ISN最小值出现时间

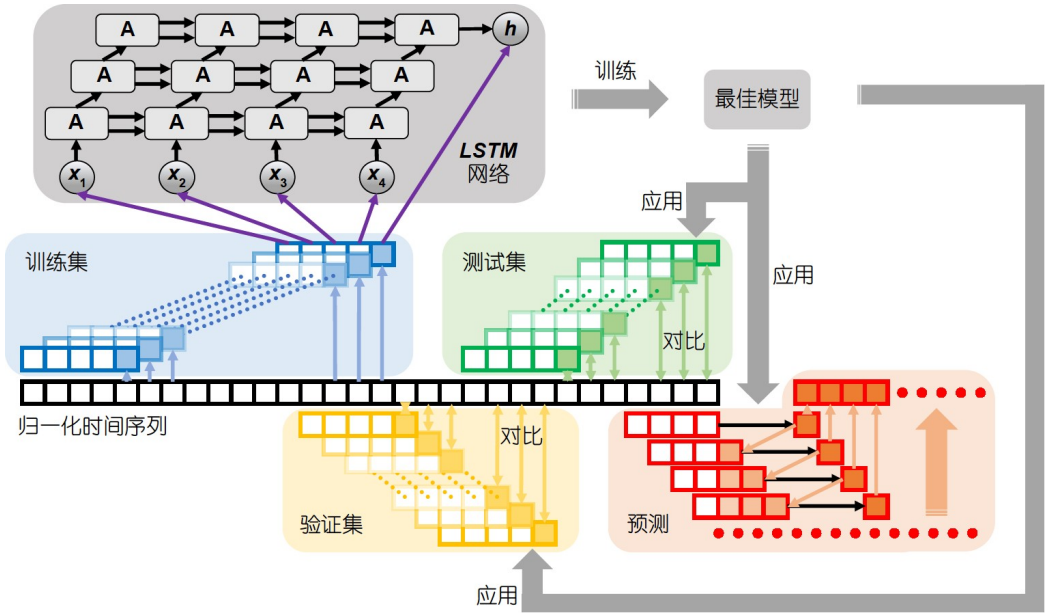


**图 10　基于LSTM网络进行ISN时间序列的建模、训练和预测过程的示意图**

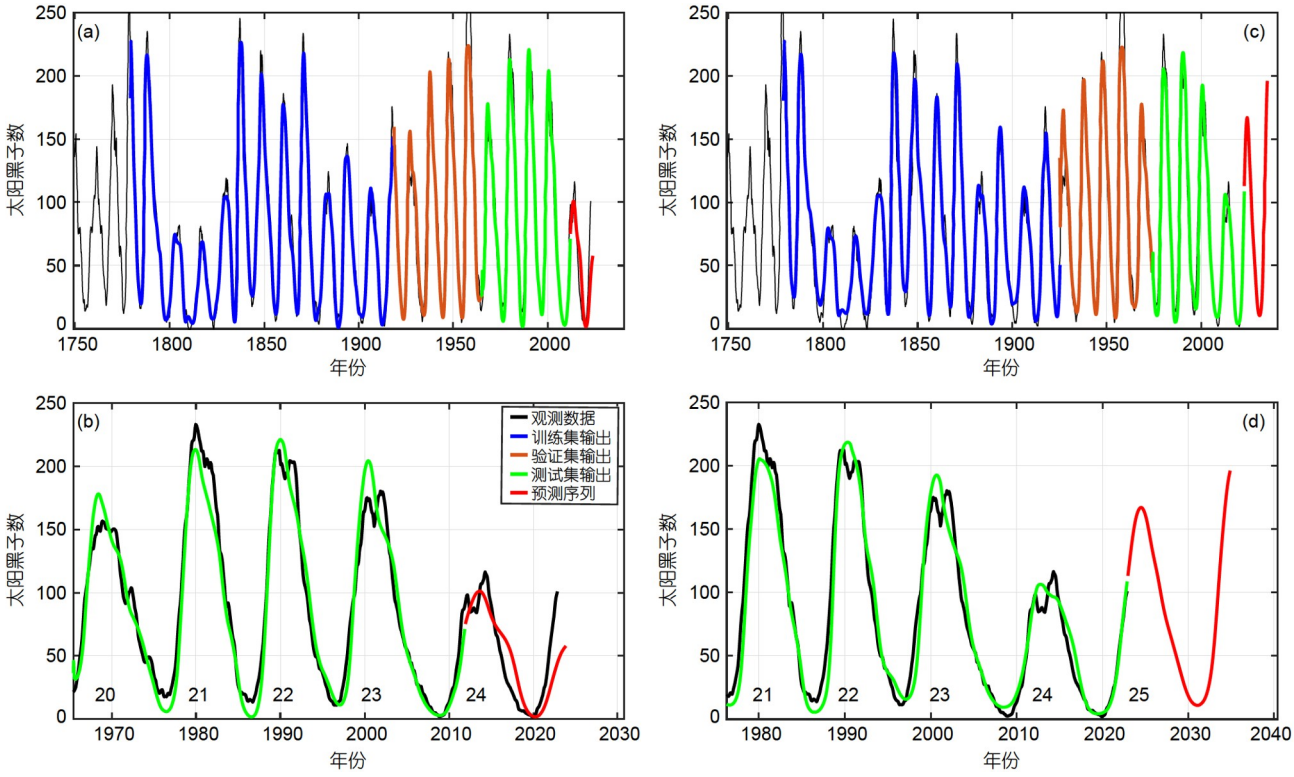


**图 11　基于LSTM模型的ISN预测**

(a)和(b)分别为从长期和最近几个活动周来看的SC 24的预测; (c)和(d)分别为从长期和最近几个活动周来看的SC 25的预测. 黑线表示13个月平滑的月度ISN系列, 红线表示未来12年的预测值, 蓝线表示训练集上的模型预测, 橙线表示验证集上的模型预测, 绿线表示测试集上的模型预测. (b)和(d)底部的数字表示太阳活动周的编号

(2031年1月)之间的时间间隔, 根据预测, SC 25的长度大约为11年零2个月.

## 5 预测综合磁图

如第3节所述, 光球磁场的球谐系数包含了跨越多时间尺度的复杂周期性. 为了使模型更容易捕捉到时变特征, 我们首先利用经验模态分解对每个系数的时间序列进行预处理, 以获得涵盖不同频段的若干个分量序列. 然后分别为每个分量序列构建LSTM模型进行预测, 并将它们相加以获得预测的系数序列. 最后, 我们根据截断到5阶的预测系数重构低阶综合磁图.

### 5.1 预测球谐系数

我们采用经验模态分解(Empirical Mode Decomposition, EMD)对每个系数序列进行预处理, 然后利用长短时记忆(LSTM)来预测每个系数各自的EMD分量. 更多关于EMD的详细信息可以参见附录C. 将EMD和LSTM结合进行预测的主要优势在于, 我们可以为不同频段的分量序列分别选择合适的建模参数, 以匹配它们各自的特征. 这种方法已经在多个领域取得了成功, 包括外汇汇率的预测(Zhang, 2018)、中国近海非稳态波浪的预测(Hao等, 2022)以及城市排水网络水质的预测(Zhang等, 2022).

通过EMD, 我们将每个系数序列分解为4个分量序列, 即IMF1、IMF2、IMF3和残差, 其对应频段的频率逐渐降低(如图12a中的黑色线所示). 然后, 我们按照与第4节中相同的步骤, 构建LSTM模型, 并对每个球谐系数的每个EMD分量进行预测. 考虑到球谐系数截断到5阶, 并且每个系数分解为四个分量, 因此总共进行了36×4次建模. 对于所有建模, 每次仅改变关键参数*look_back*, 而保持其他参数不变. *look_back*的选择详见附表S2, 除了*train_loss_thres*=0.005和*val_loss_thres*=0.003外, 其他固定参数的选择与第4节一致.

在图12中, 我们展示了结合EMD和LSTM的$g_1^0$预测结果. 对于所有四个分量, 我们的模型输出与观测比较一致, 有效捕捉到了整体扰动. 尽管在高频的IMF1中有时会出现比较明显的偏离, 但总体趋势得到了复现. 此外, IMF1的最大振幅仅为20左右, 对总振幅为100~200的$g_1^0$而言影响不大. 同时, 图12f中预测的$g_1^0$时间序列呈现出明显的22年周期性, 表明我们的预测相对可靠.

我们在图13中展示了从0阶到5阶的球谐系数的预测结果, 并在附表S3中列出了每次建模的RMSE. 通过比较可以看出, 模型表现出良好的性能, 证明其对预测目标而言是比较令人满意的.

### 5.2 重构综合磁图

获得了球谐系数的预测时间序列之后, 我们便可以根据附录A中方程(4)来重构预测的低阶综合磁图.

正如第4节中所述, 我们预测SC25的ISN峰值将在2024年6月(CR2284)前后到来, 届时太阳磁场极性会发生反转. 在图14中, 我们分别展示了CR2271、CR2278、CR2286和CR2361的预测结果, 并进行了比较粗糙的定性分析. 目前太阳处于SC 25的上升阶段, 太阳北极的磁场极性为正. 预测磁图在CR2271(图14a)仍然保持这种极性, 大致在从CR2278(图14b)到CR2286(图14c)的峰年期间发生了极性反转, 并保持反转后的极性直至下一个谷年的CR2361(图14d)以后. 此外, 太阳峰年的大尺度磁场形态比谷年更复杂, 这也意味着太阳的活跃程度更高. 因此, 我们的综合磁图预测与基本的极性规律相定性吻合, 并且在时间上也与太阳黑子数的预测结果一致, 表明预测是相当合理的.

正如第2节所述, WSO近期将综合磁图数据更新到了CR2276. 这使得我们可以借助预测与观测的对比进一步评估我们的预测. 图15显示了CR2259(第一个预测卡林顿周)和CR2261(第三个预测卡林顿周)中预测磁图与观测磁图之间的比较.

我们发现, 对于CR2259, 磁场的分布和强度都高度匹配, 并且大多数大尺度磁场的磁场极性和覆盖范围都能够得到正确的预测. 用预测磁图减去观测磁图, 得到残差磁图, 如图15c所示. 在全球范围内, 大多数区域的残差绝对值低于1.5G, 其中大部分区域内都低至0.5G以下. 此外, 从图15d可以看出, 观测磁场和预测磁场之间有很好的相关性, 相关系数达到0.92.

对于CR2261, 预测准确性有所降低, 如图15e~15h所示. 即使大尺度磁场区域的中心位置与观测结果大致相近, 并且相关系数达到了0.77, 但它们的覆盖范围或偏大或偏小. 图15g显示了CR2261的残差磁图, 提供了对预测结果的更详细评估. 总的来说, CR2261的预测磁图与观测磁图之间的残差大于CR2259的残差, 并

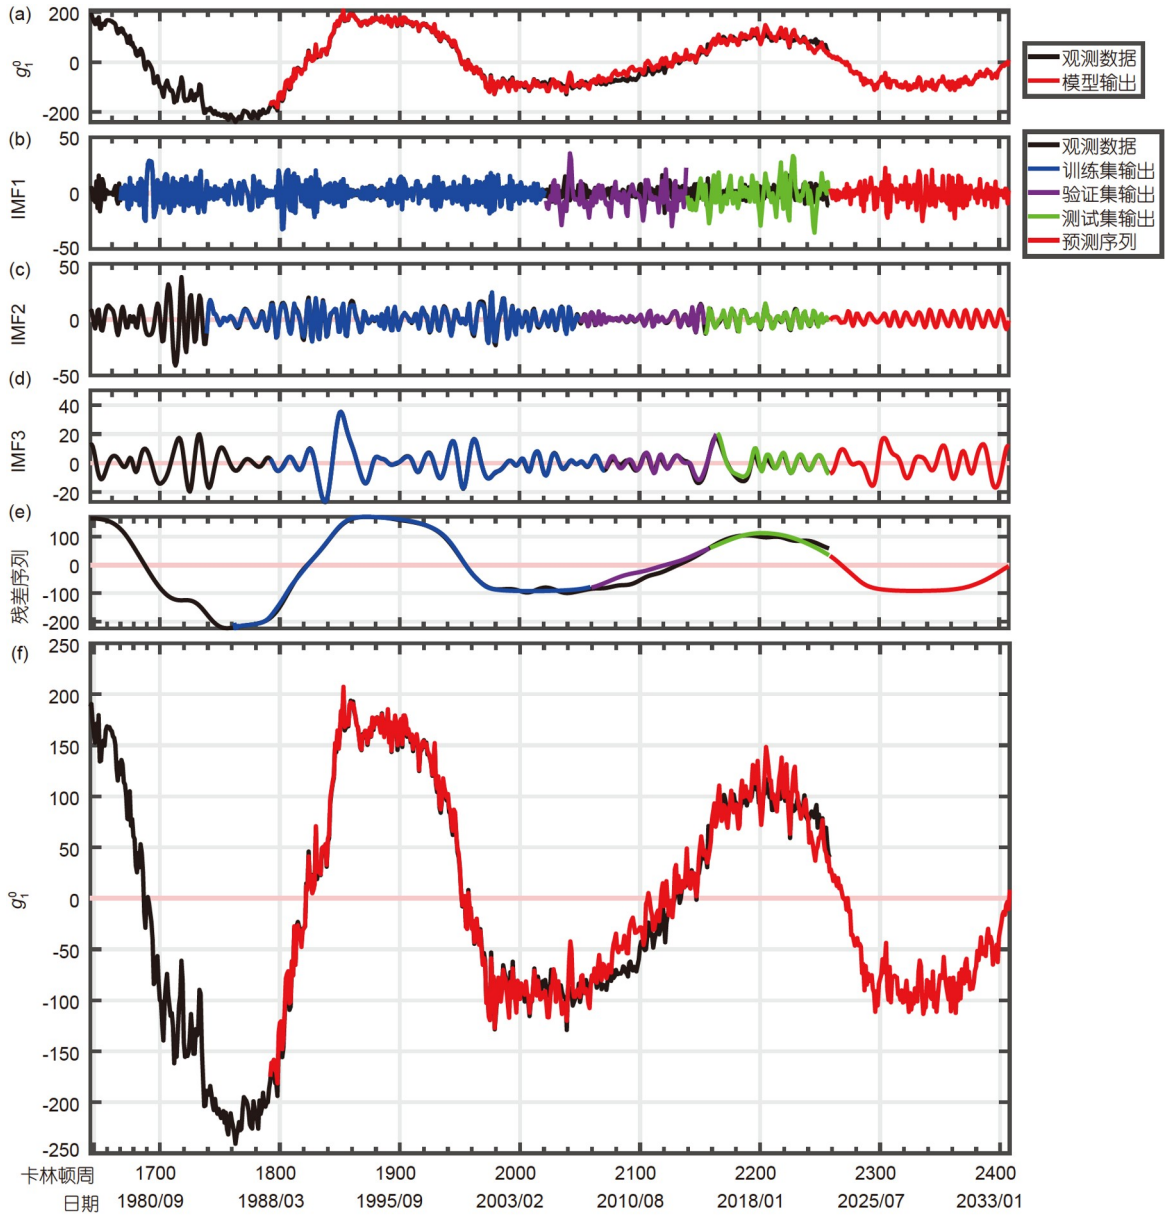


**图 12　结合EMD和LSTM的$g_1^0$预测结果**

(a) $g_1^0$的时间序列. 黑线代表观测序列, 红线代表所有四个分量序列上的模型输出之和. (b)~(e) 4个EMD分量的时间序列, 依次为IMF1、IMF2、IMF3和残差. 黑线代表观测序列, 蓝线代表训练集上的模型输出, 紫色线代表验证集上的模型输出, 绿线代表测试集上的模型输出, 红线代表预测序列. (f)是(a)的放大图, 水平的粉红色线表示零

且残差较大的区域主要集中在太阳南极附近以及卡林顿经度范围50°到250°之间的中低纬度区域. 考虑到这些区域中有很多与CR2259中的相似, 我们推断CR2261中呈现出的较大偏差可能来源于执行递归预测时误差的累积效应.

作为比较, CR2258的观测磁图与CR2259的观测磁图之间的相关系数为0.95, 而CR2258和CR2261之间的相关系数为0.75. 因此, 本文预测结果的相关系数略低于前瞻时间为1的持续模型, 但略高于前瞻时间为3的持续模型. 这意味着与持续模型相比, 我们的模型在临近预测方面没有优势, 但在未来的长期预测中表现更好.

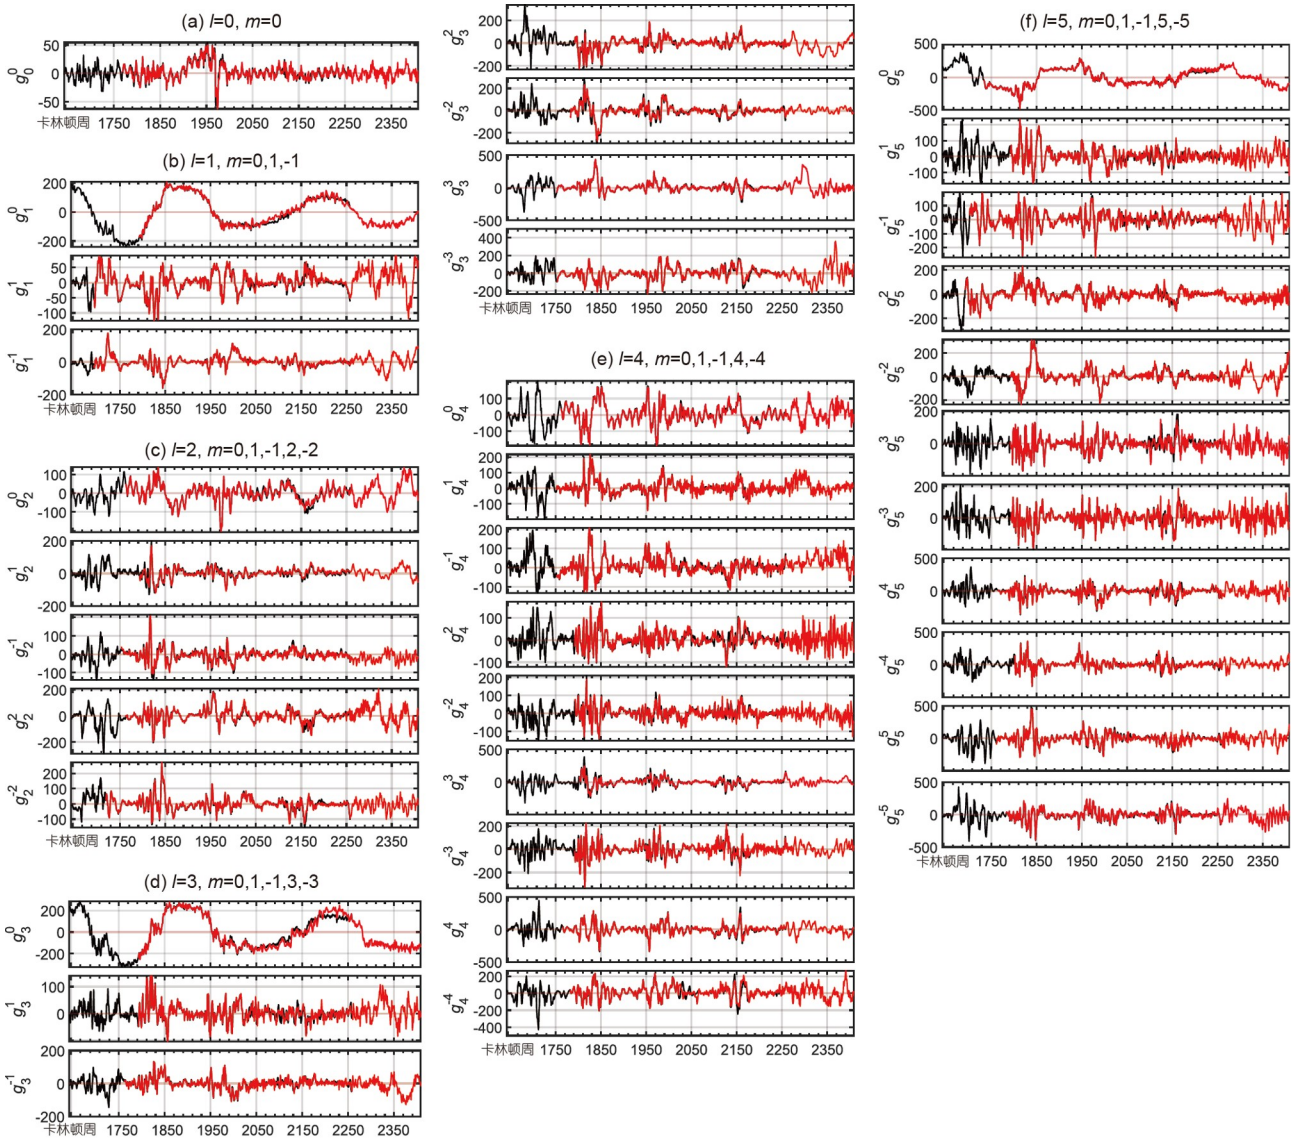


**图 13　0~5阶的球谐系数预测结果**

相同阶数$l$的系数按照其度数$m$的顺序排列. 黑线代表观测时间序列, 红线代表预测时间序列

总的来说，我们对WSO综合磁图的预测在部分方面与理论和观测是一致的，比如太阳的南北极性和一定时间范围内大尺度磁场的中心位置，并且在一定程度上是相对可靠的.

## 6　总结和讨论

本文分析了光球磁场的球谐展开系数的时变特性. 基于这些分析, 我们对第25太阳活动周的黑子数和综合磁图进行了预测.

我们提取了从1阶到9阶的球谐系数的周期性，并将它们的小波频谱分类为连续型(C型)和间歇型(I型)两种模式. C型模式中最明显的是具有22年周期性的$l$为奇数且$m$为零的系数，它们对应于轴向反对称磁多极矩，并与太阳的活动水平密切相关. 我们还发现系数$g_2^1$表现出13.53年的周期性(附表S1)，与Yan等(2023)的研究结果一致, 他们将蒙德极小期的8年太阳活动周期解释为22年的偶极模式和13~15年的四极模式相叠

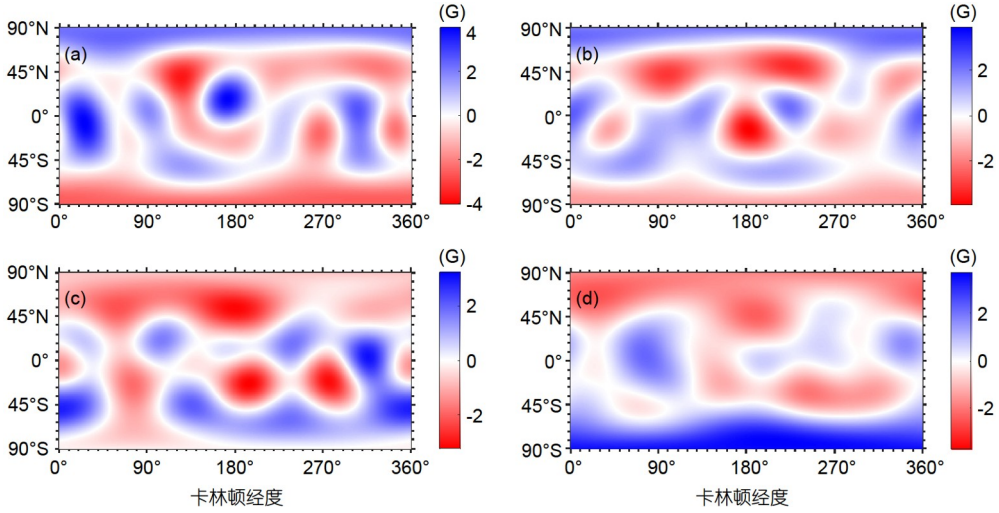


**图 14　截断到5阶的综合磁图预测结果**

(a) CR2271, 当前活动周的上升相; (b) CR2278, 临近下一次极性反转; (c) CR2286, 完成下一次极性反转; (d) CR2361, 下一个太阳活动谷年. 卡林顿周的选择基于我们对SC 25的ISN峰值的预测, 即峰值将于2024年6月前后到达(CR2284)

加的结果. 另一方面, I型模式广泛存在于大多数系数中, 并且在每个太阳活动峰年附近间歇性地出现, 表明太阳峰年具有周期为1到3年的复杂短周期扰动. 进一步研究球谐系数与太阳黑子数之间的相位关系, 发现$g_7^0$的绝对值与太阳黑子数几乎保持同相位. 考虑到球谐函数$S_{70}$的分布模式与近年揭示的太阳子午环流在对流层顶部的分布模式非常相似, 而后者可以调节太阳大尺度磁场, 我们推断$g_7^0$与太阳黑子数之间如此小的相位差可能与子午环流有关.

之后, 我们构建非线性模型来预测太阳黑子数和光球磁场的球谐系数, 并最终重构出低阶综合磁图. 预测显示, 第25个太阳活动周(SC 25)将在2024年6月达到峰值, 误差估计为8个月, 峰值太阳黑子数可能达到166.9±22.6, 并且SC 25将在2031年1月左右结束. 因此, SC 25会强于SC 24, 但略弱于SC 23, 持续时间约为11年2个月. 附表S4列出了过去五年不同研究者对于SC 25的预测结果. 此外, 我们对截断到5阶的球谐系数进行了预测, 获得了预测的综合磁图. 通过分析它们的极性并将预测结果与观测磁图进行比较, 我们认为本文预测结果可以在一定的时间范围内呈现正确的磁场极性和一些大尺度的磁场区域.

如第2节所述, 将球谐系数截断到5阶对于地球上的实际预测应用已经足够, 因为更高阶系数对于源表面磁场的贡献并不那么显著. 但值得注意的是, 更高阶系数仍然对光球磁场有相当大的贡献, 尤其是在磁场的总强度和梯度方面(图1), 对我们了解太阳的全球磁场具有重要意义. 更高阶系数的贡献在源表面上大幅衰减, 可能归因于光球到源表面的区域内的磁场拓扑连接性, 比如冕环的形成和极区磁场的延伸, 从而导致源表面上的磁场分布变得更弱、更均匀.

我们对光球磁场球谐系数时间序列的分析有助于理解太阳磁活动的规律性和不规律性. 球谐系数的频谱特征与太阳磁多极矩密切相关, 并且反映了磁多极矩演化产生的尚未解释的重要规律. 此外, 提出了系数$g_7^0$与太阳子午环流之间的潜在关系, 提供了一条从对流区到光球的合理路径.

我们首次进行了对综合磁图的预测, 为理解未来的太阳提供了一种新颖的视角. 我们的预测揭示了光球磁场的全球分布, 提供了大尺度磁场的整体轮廓. 这些信息对设计未来的太阳任务、部署太阳观测卫星以及探索太阳极区(邓元勇等, 2023; Wang等, 2023; Hassler等, 2023)都可能是有价值的参考. 然而, 需要注意的是, 尽管我们的预测在多个方面都具备一定准确性, 其与观测数据之间仍存在着不可忽视的偏差. 提高预测准确度需要更长期的观测支持和更先进的模型辅助, 这些都是未来将长期面临的挑战.

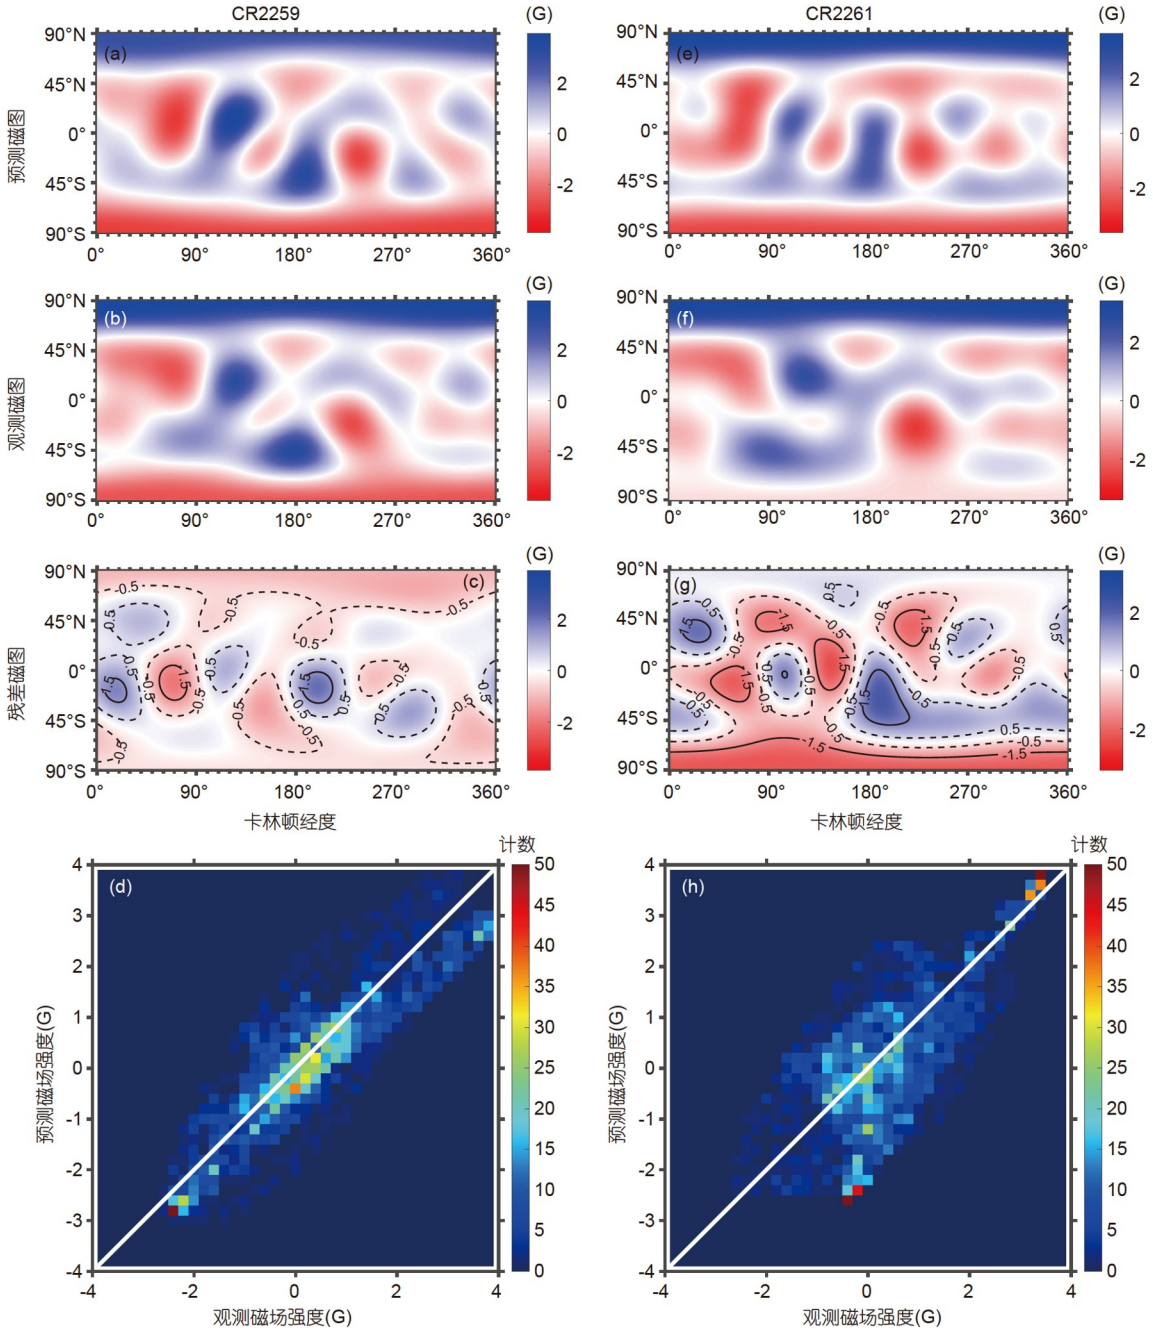


**图 15　CR2259(左列)和CR2261(右列)的预测磁图与观测磁图的比较**

(a)和(e)是预测磁图; (b)和(f)是观测的WSO磁图; (c)和(g)是用预测磁图减去观测磁图得到残差磁图, 其中实线标记了残差为±1.5G的等值线, 虚线标记了残差为±0.5G的等值线; (d)和(h)是观测磁场与预测磁场的散点分布, 对角线用白色标记. 对于CR2259和CR2261, 观测磁图与预测磁图之间的相关系数分别为0.92和0.77

**致谢**　比利时皇家天文台和威尔科克斯太阳天文台提供了原始数据, 国际太阳黑子数数据可在https://sidc.be/SILSO/datafiles上获取, WSO提供的综合磁图数据可在http://wso.stanford.edu/#Synoptic上获取; B. B. Karak提供图9的背景图; 汪景琇教授、姜杰教授和邓林华教授对本工作提供了有益讨论. 在此一并致谢.

## 参考文献


邓元勇, 周桂萍, 代树武, 王颖, 冯学尚, 何建森, 姜杰, 田晖, 杨尚斌, 侯俊峰, 颜毅华, 甘为群, 白先勇, 李乐平, 夏利东, 黎辉, 苏扬, 熊明, 张也驰, 朱成林, 林佳本, 章海鹰, 陈波, 何玲平, 封莉, 张红鑫, 孙明哲, 张爱兵, 陈林杰, 谭宝林, 张哲, 杨建峰, 杨孟飞, 汪景琇. 2023. 太阳极轨天文台. 科学通报, 68: 298–308

Babcock H W. 1961. The topology of the Sun's magnetic field and the 22-year cycle. Astrophys J, 133: 572

Bhatt N J, Jain R, Aggarwal M. 2009. Prediction of the maximum amplitude and timing of sunspot cycle 24. Sol Phys, 260: 225–232

Bhowmik P, Nandy D. 2018. Prediction of the strength and timing of sunspot cycle 25 reveal decadal-scale space environmental conditions. Nat Commun, 9: 5209

Calvo R A, Ceccato H A, Piacentini R D. 1995. Neural network prediction of solar activity. Astrophys J, 444: 916

Choudhuri A R, Chatterjee P, Jiang J. 2007. Predicting solar cycle 24 with a solar dynamo model. Phys Rev Lett, 98: 131103

Chowdhury P, Jain R, Ray P C, Burud D, Chakrabarti A. 2021. Prediction of amplitude and timing of solar cycle 25. Sol Phys, 296: 69

Clette F, Berghmans D, Vanlommel P, Van der Linden R A M, Koeckelenbergh A, Wauters L. 2007. From the Wolf number to the International Sunspot Index: 25 years of SIDC. Adv Space Res, 40: 919–928

Clette F, Svalgaard L, Vaquero J M, Cliver E W. 2014. Revisiting the Sunspot number: A 400-year perspective on the solar cycle. Space Sci Rev, 186: 35–103

Covas E, Peixinho N, Fernandes J. 2019. Neural network forecast of the sunspot butterfly diagram. Sol Phys, 294: 24

Dang Y, Chen Z, Li H, Shu H. 2022. A comparative study of non-deep learning, deep learning, and ensemble learning methods for sunspot number prediction. Appl Artif Intelligence, 36: 2074129

Dani T, Sulistiani S. 2019. Prediction of maximum amplitude of solar cycle 25 using machine learning. J Phys-Conf Ser, 1231: 012022

Deng L H, Li B, Xiang Y Y, Dun G T. 2014. On mid-term periodicities of high-latitude solar activity. Adv Space Res, 54: 125–131

Deng L H, Fei Y, Deng H, Mei Y, Wang F. 2020. Spatial distribution of quasi-biennial oscillations in high-latitude solar activity. Mon Not R Astron Soc, 494: 4930–4938

Featherstone N A, Miesch M S. 2015. Meridional circulation in solar and stellar convection zones. Astrophys J, 804: 67

Gonçalves Í G, Echer E, Frigo E. 2020. Sunspot cycle prediction using warped Gaussian process regression. Adv Space Res, 65: 677–683

Hanasoge S M. 2022. Surface and interior meridional circulation in the Sun. Living Rev Sol Phys, 19: 3

Hao W, Sun X, Wang C, Chen H, Huang L. 2022. A hybrid EMD-LSTM model for non-stationary wave prediction in offshore China. Ocean Eng, 246: 110566

Hasoon S O, Al-Hashimi M M. 2022. Hybrid deep neural network and long short term memory network for predicting of sunspot time series. Comput Sci, 17: 955–967

Hassler D M, Gibson S E, Newmark J S, Featherstone N A, Upton L, Viall N M, Hoeksema J T, Auchere F, Birch A, Braun D, Charbonneau P, Colannino R, DeForest C, Dikpati M, Downs C, Duncan N, Elliott H A, Fan Y H, Fineschi S, Gizon L, Gosain S, Harra L, Hindman B, Berghmans D, Lepri S T, Linker J, Moldwin M B, Munoz-Jaramillo A, Nandy D, Rivera Y, Schou J, Sokol S, Thompson B, Velli M, Woods T N, Zhao J. 2023. Solaris: A focused Solar polar discovery-class mission to achieve the highest priority heliophysics science now. arXiv preprint, doi: 10.48550/arXiv.2301.07647.

Hawkes G, Berger M A. 2018. Magnetic helicity as a predictor of the solar cycle. Sol Phys, 293: 1–25

Hazra G, Choudhuri A R. 2019. A new formula for predicting solar cycles. Astrophys J, 880: 113

Jiang J, Cao J. 2018. Predicting solar surface large-scale magnetic field of cycle 24. J Atmos Sol-Terr Phys, 176: 34–41

Jiang J, Chatterjee P, Choudhuri A R. 2007. Solar activity forecast with a dynamo model. Mon Not R Astron Soc, 381: 1527–1542

Jiang J, Cameron R H, Schmitt D, Işık E. 2013. Modeling solar cycles 15 to 21 using a flux transport dynamo. Astron Astrophys, 553: A128

Jiang J, Wang J X, Jiao Q R, Cao J B. 2018. Predictability of the solar cycle over one cycle. Astrophys J, 863: 159

Karak B B, Jiang J, Miesch M S, Charbonneau P, Choudhuri A R. 2014. Flux transport dynamos: From kinematics to dynamics. Space Sci Rev, 186: 561–602

Knaack R, Stenflo J O. 2005. Spherical harmonic decomposition of solar magnetic fields. Astron Astrophys, 438: 349–363

Labonville F, Charbonneau P, Lemerle A. 2019. A dynamo-based forecast of solar cycle 25. Sol Phys, 294: 82

Leamon R J, McIntosh S W, Chapman S C, Watkins N W. 2020. Timing terminators: Forecasting sunspot cycle 25 onset. Sol Phys, 295: 36

Lee T. 2020. EMD and LSTM hybrid deep learning model for predicting sunspot number time series with a cyclic pattern. Sol Phys, 295: 82

Lockwood M. 2010. Solar change and climate: An update in the light of the current exceptional solar minimum. Proc R Soc A, 466: 303–329

Lockwood M, Owens M J, Barnard L, Davis C J, Steinhilber F. 2011. The persistence of solar activity indicators and the descent of the

Sun into Maunder Minimum conditions. Geophys Res Lett, 38: L22105

Lundstedt H, Liszka L, Lundin R. 2005. Solar activity explored with new wavelet methods. Ann Geophys, 23: 1505–1511

Maris G, Oncica A. 2006. Solar cycle 24 forecasts. Sun Geosphere, 1: 8–11

Miao J, Wang X, Ren T L, Li Z T. 2020. Prediction verification of solar cycles 18–24 and a preliminary prediction of the maximum amplitude of solar cycle 25 based on the Precursor Method. Res Astron Astrophys, 20: 004

Obridko V N, Shelting B D. 2008. On prediction of the strength of the 11-year solar cycle No. 24. Sol Phys, 248: 191–202

Ohl A I. 1966. Wolf's number prediction for the maximum of the cycle 20. Soln Dannye, 12: 84

Okoh D I, Seemala G K, Rabiu A B, Uwamahoro J, Habarulema J B, Aggarwal M. 2018. A hybrid regression-neural network (HR-NN) method for forecasting the solar activity. Space Weather, 16: 1424–1436

Panigrahi S, Pattanayak R M, Sethy P K, Behera S K. 2021. Forecasting of sunspot time series using a hybridization of ARIMA, ETS and SVM methods. Sol Phys, 296: 6

Pesnell W D, Schatten K H. 2018. An early prediction of the amplitude of solar cycle 25. Sol Phys, 293: 112

Petrovay K. 2020. Solar cycle prediction. Living Rev Sol Phys, 17: 2

Petrovay K, Nagy M, Gerják T, Juhász L. 2018. Precursors of an upcoming solar cycle at high latitudes from coronal green line data. J Atmos Sol-Terr Phys, 176: 15–20

Prasad A, Roy S, Sarkar A, Panja S C, Patra S N. 2022. Prediction of solar cycle 25 using deep learning based long short-term memory forecasting technique. Adv Space Res, 69: 798–813

Qahwaji R, Colak T. 2006. Neural network-based prediction of solar activities. Orlando: Proceedings of CITSA2006. 4–7

Scherrer P H, Wilcox J M, Svalgaard L, Duvall T L, Dittmer P H, Gustafson E K. 1977. The mean magnetic field of the Sun: Observations at Stanford. Sol Phys, 54: 353–361

Stenflo J O, Vogel M. 1986. Global resonances in the evolution of solar magnetic fields. Nature, 319: 285–290

Stenflo J O, Güdel M. 1988. Evolution of solar magnetic fields-Modal structure. Astron Astrophys, 191: 137–148

Stix M. 1972. Non-linear dynamo waves. Astron Astrophys, 20: 9

Upton L A, Hathaway D H. 2018. An updated solar cycle 25 prediction with AFT: The modern minimum. Geophys Res Lett, 45: 8091–8095

Uwamahoro J, McKinnell L A, Cilliers P J. 2009. Forecasting solar cycle 24 using neural networks. J Atmos Sol-Terr Phys, 71: 569–574

Vitinsky Y I, Kopetsky M, Kuklin G V. 1986. Statistika Pyatnoo-brazovatel'noi Deyatel'nosti Solntsa (Sunspot Formation Statistics). Moscow: Nauka

Waldmeier M. 1961. The Sunspot-activity in the Years 1610–1960. Zurich: Schulthess

Wang Y M, Sheeley N R. 2009. Understanding the geomagnetic precursor of the solar cycle. Astrophys J, 694: L11–L15

Wang Y M, Bai X Y, Chen C Y, Chen L J, Cheng X, Deng L, Deng L H, Deng Y Y, Feng L, Gou T Y, Guo J N, Guo Y, Hao X J, He J S, Hou J F, Huang J J, Huang Z H, Ji H S, Jiang C W, Jiang J, Jin C L, Li X L, Li Y R, Liu J J, Liu K, Liu L, Liu R, Liu R, Qiu C B, Shen C L, Shen F, Shen Y D, Shi X J, Su J T, Su Y, Su Y N, Sun M Z, Tan B L, Tian H, Wang Y M, Xia L D, Xie J L, Xiong M, Xu M J, Yan X L, Yan Y H, Yang S B, Yang S H, Zhang S Y, Zhang Q H, Zhang Y H, Zhao J S, Zhou G P, Zou H. 2023. Solar ringmission: BuildingapanoramaoftheSunandinner-heliosphere. Adv Space Res, 71: 1146–1164

Yan L M, He F, Yue X N, Wei Y, Wang Y Q, Chen S, Fan K, Tian H, He J S, Zong Q G, Xia L D. 2023. The 8-year solar cycle during the Maunder Minimum. AGU Adv, 4: e2023AV000964

Zhang B. 2018. Foreign exchange rates forecasting with an EMD-LSTM neural networks model. J Phys-Conf Ser, 1053: 012005

Zhang Y, Li C, Jiang Y, Sun L, Zhao R, Yan K, Wang W. 2022. Accurate prediction of water quality in urban drainage network with integrated EMD-LSTM model. J Clean Prod, 354: 131724

(责任编委: 傅绥燕)