

基于时序气温特征增强的苹果始花期 Bi-LSTM 预测方法

刘恩奇^{1,2}, 刘 淼¹, 王 拓^{1,2}, 朱耀辉³, 陈日强², 徐 波², 高美玲¹,
张 静¹, 杨 耘¹, 杨贵军^{1,2*}

(1. 长安大学地质工程与测绘学院, 陕西西安 710054, 中国; 2. 农业农村部农业遥感机理与定量遥感重点实验室/北京市农林科学院信息技术研究中心, 北京 100097, 中国; 3. 江苏大学农业工程学院, 江苏镇江 212013, 中国)

摘要: [目的/意义] 苹果始花期是果园物候管理的核心节点, 其精准预测对于安排疏花疏果、病虫害防治及规避花期冻害至关重要。传统始花期预测模型特征输入所用气温特征类型单一, 且对深层语义信息挖掘不足, 难以表征内在物候变化规律; 物理驱动模型需预设物候变化函数, 依赖人工分区标定阈值, 难以实现大范围自适应花期预测。为克服这些局限并进一步提升预测精度, 构建了一种数据驱动的深度学习预测框架。[方法] 以陕西省洛川县为研究区域, 选取 2019—2021 年苹果采摘后至次年开花期前的逐日最高/平均/最低近地表气温数据, 引入局部依赖头、全局依赖头和累积特征头 3 种多头注意力机制, 联合表征多维气温特征, 增强模型对气温局部波动、全局趋势及累积变化等时变规律的识别能力, 并将地理因子(高程经纬度)作为静态特征与递归神经网络融合, 构建区域自适应的双向长短期记忆网络, 实现面向空间差异的苹果始花期预测。以洛川县 2022 年实际调查的始花期数据对模型进行了精度验证。[结果和讨论] 模型在测试集上的均方根误差为 1.34 d, 平均绝对误差为 1.13 d, 预测误差主要集中在 0~2 d, 相关系数达到 0.84。进一步分析表明, 引入地理因子有助于降低预测误差并增强模型的空间适应性。经验证, 该方法在研究区内可实现提前 15~20 d 的稳定预测。[结论] 研究结果为实现苹果始花期更高精度的预测提供了新路径, 为果园花期管理及灾害防控提供了技术支撑。

关键词: 近地表气温; 多头注意力机制; 地理因子; 双向长短期记忆网络; 苹果始花期

中图分类号: S127

文献标识码: A

文章编号: SA202510026

引用格式: 刘恩奇, 刘淼, 王拓, 朱耀辉, 陈日强, 徐波, 高美玲, 张静, 杨耘, 杨贵军. 基于时序气温特征增强的苹果始花期 Bi-LSTM 预测方法[J]. 智慧农业(中英文), 2026, 8(2): 86-97. DOI: 10.12133/j.smartag.SA202510026

LIU Enqi, LIU Miao, WANG Tuo, ZHU Yaohui, CHEN Riqiang, XU Bo, GAO Meiling, ZHANG Jing, YANG Yun, YANG Guijun. A Bi-LSTM Prediction Method for Apple First Flowering Date Based on Enhanced Time-Series Temperature Features[J]. Smart Agriculture, 2026, 8(2): 86-97. DOI: 10.12133/j.smartag.SA202510026 (in Chinese with English abstract)

0 引言

中国是世界上较大的苹果种植国之一, 种植面积达 222 万 hm^2 、年产量 4 139 万 t, 占世界总量的 40% 以上^[1,2]。苹果树的生长发育高度依赖于气候条件, 其中始花期作为果树全年生长周期的重要物候节点, 对授粉效率、果实坐果率和最终产量具有决定性作用。影响始花期的主要气候因子包括温度、降水量和光照条件, 其中温度起到主导作用。

近年来, 全球气候变化导致春季低温事件呈现

出频率增加、强度增强且时空分布更不确定的趋势^[3]。苹果树在春季的生长发育正处于嫩芽一开花的关键窗口, 若在此阶段发生低温冻害事件, 极易导致授粉受阻和坐果率骤降, 影响苹果正常生产^[4]。因此, 准确预测始花期能够为防范和减轻春季低温冻害提供科学决策依据。在这一背景下, 开展苹果始花期预测研究受到广泛关注。现有始花期的预测方法主要分为两类^[5]: 基于果树生长发育的机理模型和基于观测调查数据的统计经验模型。果

收稿日期: 2025-10-30

基金项目: 国家自然科学基金项目(42171303)

作者简介: 刘恩奇, 硕士研究生, 研究方向为农业遥感应用。E-mail: enqiliu0504@163.com

*通信作者: 杨贵军, 博士, 研究员, 研究方向为农业定量遥感机理模型及应用。E-mail: guijun.yang@163.com

copyright©2026 by the authors

(登录 www.smartag.net.cn 免费获取电子版全文)

树在进入冬季时保持休眠状态，在春季温度升高时适当条件下解除休眠恢复生长^[6]，故机理模型以作物生理机制为基础，模拟苹果树从休眠解除到盛花期的全过程^[7]，如果在一定时期内满足苹果树冷量要求，就进入热累积阶段，在满足热量需求之后果树进入萌芽阶段^[8-10]。机理模型主要有序列模型和冷重叠模型^[5]。序列模型认为果树在冬季进行冷量积累（寒冷期），在春季进行热量积累（强迫期），并且这两段积累是先后独立进行的。但随后的研究认为序列模型忽视了果树所具备的生物学特性，比如果树已积累的冷量对后续热量积累的动态影响，因此相关学者认为序列模型可能不具有普遍适用性^[9]。LUEDELING 等^[11]基于冷量累积模型和热量累积模型，提出了一个可动态响应温度的温带果树春季物候预测模型 PhenoFlex，该模型能够更好地反映果树的生物学特性。机理模型能揭示物候与温度间的生理联系，但其参数通常需针对不同区域分别进行校准。与机理模型相比，统计模型通常通过分析物候期与气象因子间的定量关系来建立回归模型^[12]，在预测时灵活且计算简单。柏秦凤等^[13]基于有效积温因子与观测花期的相关性，构建了多元线性回归的始花期预测模型，用于模拟中国富士系苹果主产区的苹果花期分布，但此类模型易受到气象变量多重共线性的影响。为解决这一问题，张艳艳等^[14]在预测苹果始花期时采用偏最小二乘回归法，结果显示其方法优于传统回归模型。郭连云和赵年武^[15]通过敏感性分析筛选关键变量，并结合逐步回归建立了梨树始花期预测模型，所建立的预测模型能准确预测贵德县梨树始花期。刘森等^[16]提出了一种半机理半统计模型，该方法以机理模型为基础，通过网格化方式为苹果主产区匹配冷量和热量需求参数，再结合每日温度构建随机森林（Random Forest, RF）模型对冷/热积温进行分区估算，并通过热量累加判定物候节点，但仍需分区域标定阈值。通过上述方法建立的始花期预测模型，预测精度仍有待提升。

随着人工智能的发展，深度学习已逐渐成为物候预测的重要方法，特别是在处理物候时序数据方面展现出独特优势。相较于传统统计模型，深度学习能够在无需显式假设物候变化函数形式的情况下，自动学习气象因子与物候响应之间的非线性关系，从而为复杂物候过程的建模提供新的技术路径。现有研究中，长短期记忆（Long Short-term Memory, LSTM）网络因其在捕捉时间序列长期依

赖特征方面的优势，被广泛应用于物候过程建模。REDDY 和 PRASAD^[17]利用中分辨率成像光谱仪（Moderate Resolution Imaging Spectroradiometer, MODIS）得到的归一化植被指数（Normalized Difference Vegetation Index, NDVI）时间序列数据与 LSTM，成功构建了植被动态预测模型，用以模拟 NDVI 的季节性变化过程。LIU 等^[18]将 LSTM 网络与多变量气象记忆效应机制相结合，开发了一个深度学习框架，实现了对冠层绿度全季节动态轨迹的高精度模拟。这类研究表明，基于递归神经网络的模型能够有效表征物候演变过程中蕴含的时间依赖性。在此基础上，部分研究开始引入更复杂的时序建模结构以提升对物候事件的刻画能力。TRAN 等^[19]将基于自注意力机制的神经网络（Transformer）架构应用于物候学研究，通过注意力机制处理时间序列数据，实现了多个关键物候事件发生时间的预测。ALHNAITY 等^[20]将 LSTM 与注意力机制相结合来构建模型，用于植物茎直径变化的多步预测，结果表明，注意力机制有助于模型在复杂时序中聚焦关键信息，从而提升预测精度。

尽管上述研究在物候预测中取得了一定进展，但总体来看，现有深度学习方法多侧重于整体时间序列建模，对气温变化过程中不同时间尺度信息的区分与利用仍较为有限。尤其是在花前关键阶段，气温的短期波动、长期趋势及累积效应可能对始花期产生不同影响，而现有模型往往难以对这些时变规律进行有针对性的表征。此外，多数模型对空间差异的处理仍依赖分区建模或经验参数设定，区域适应性有待进一步提升。

针对上述问题，本研究从气温时变规律挖掘与区域自适应建模两个层面提出改进思路：在时间维度上，引入多头注意力机制以增强模型对气温序列中关键时段信息的关注能力，从而更精细地刻画局部波动、整体趋势及累积变化等时变特征；在空间维度上，将地理因子与递归神经网络结构相结合，构建区域自适应的预测框架，以表征不同地理位置下苹果始花期的响应差异。在此基础上，本研究构建了苹果始花期预测模型，并利用实地观测数据对其预测性能进行验证。


1 材料与方法

1.1 研究区概况

陕西省洛川县（图1）是中国苹果种植的主产区，主要种植品种是富士系（Fuji）。洛川县位于中国陕西

省北部、洛河中游 (35°26′~36°04′N, 109°13′~109°45′E), 地处黄土高原沟壑区, 地势由东北向西南倾斜, 如图 1 中数字高程模型 (Digital Elevation Model, DEM) 所示, 海拔约 604~1 522 m, 属

暖温带半湿润大陆性季风气候, 年平均气温 9.2 ℃, 年平均降水量为 502 mm, 素有“苹果之乡”的誉称。



注:该图基于自然资源部标准地图服务网站下载的审图号为GS(2024)0650号标准地图制作,底图无修改。

图 1 洛川县苹果始花期预测研究区示意图

Fig. 1 Schematic map of the study area for apple first flowering date prediction in Luochuan county

1.2 数据获取及预处理

1.2.1 气象数据

本研究使用的近地表气温 (Near-Surface Air Temperature, NSAT) 来源于 GAO 等^[21] 生成的近地表气温产品。该产品主要采用 RF 机器学习模型, 利用多个数据源, 包括 ERA5-Land、全球陆地数据同化 (Global Land Data Assimilation)、遥感数据, 以及若干辅助因素在 Google Earth Engine 云平台上实现。经年/月分层抽样训练后, 生成了 1981—2020 年黄河流域 1 km 日尺度最大、平均、最小近地面气温 (NSAT) 栅格。文章中通过十折交叉验证表明各类日温的均方根误差 (Root Mean Square Error, RMSE) 均低于 1.93 K、 R^2 不低于 0.968。本研究中使用该产品方法生成的 1 km 尺度日最高/平均/最低 NSAT 用于后续分析, 并且参考果树生理物候和区域花期调查信息, 所使用近地表气温时间范围为 10 月 1 日—次年 3 月 30 日 (苹果采收后至次年始花期前)。表 1 展示了样点 1 在 2019 年 10 月 1 日—10 月 5 日的逐日近地表气温数据。

1.2.2 花期调查数据

在 2020、2021、2022 年的 3—4 月, 在洛川县进行了苹果始花期调查, 记录了各调查样点实际的始花期数据。花期物候的判定依据是各调查样点苹果园的平均开花比例, 始花期限定为每个样本点单株苹果树开花量不能超过 25%。同时, 通过千寻差

表 1 洛川县逐日时序 NSAT 数据示例

Table 1 Example of daily time-series NSAT data in Luochuan county

日期	日最高气温/℃	日平均气温/℃	日最低气温/℃
2019-10-01	17.6	15.3	13.3
2019-10-02	21.9	15.5	13.5
2019-10-03	17.0	14.1	13.9
2019-10-04	14.8	12.5	11.9
2019-10-05	9.2	7.9	7.1

分定位系统获取调查样点的经纬度等地理位置信息。3 年共采集 145 个调查样点始花期数据, 具体调查样点分布如图 1 所示。为更全面展示始花期数据的分布情况, 图 2 通过箱线图展示了 3 年洛川县始花期数据的 4 分位数。本研究中的日期采用年积日表示, 即一年中的第几天 (Day of Year, DOY)。图 2 显示, 洛川县 3 年始花期出现在 3 月 30 日—4 月 14 日。其中, 2020 年始花期时间相对较早, 2021 年和 2022 年相对较晚。

1.2.3 数据预处理

在模型的构建过程中, 超参数选择对预测性能有一定影响。本研究通过贝叶斯优化方法, 针对隐含层数、隐含层神经元数、学习率、L2 正则化参数和优化器等超参数进行了调优。经优化后得到最优超参数配置如下: 学习率稳定在 0.01, 网络结构收敛为两层隐藏层、每层约 230 个神经元, 优




图2 洛川县3年调查样点实际始花期统计结果

Fig. 2 Statistical results of actual first flowering date of three-year survey sample points in Luochuan county

化器选用 Adam。在此配置下，验证集目标损失降至-0.01。

在模型训练过程中，需要将完整数据集划分为训练集、验证集与测试集3部分。训练集和验证集作为建模集，主要用于模型训练和超参数优化，测试集作为未知数据不参与模型训练，仅用于检验模型泛化能力。本研究根据已有调查样点数量，将2020年和2021年花期数据、2019年10月1日—2020年2月29日及2020年10月1日—2021年3月30日的逐日最高/平均/最低 NSAT 数据、各样点高程和经纬度数据按照 9 : 1 的比例划分并做十折交叉验证（表2），用作模型训练，并用 RMSE、平均绝对误差（Mean Absolute Error, MAE）和相关系数（Pearson's R, R ）来表征训练结果，以避免训练集样本或验证集样本出现不平衡问题，影响模型的训练效果。最后利用2022年花期数据、2021年10月1日—2022年3月30日逐日最高/平均/最低 NSAT 数据及高程和经纬度数据作为模型独立测试集。由于模型输入变量在量纲和物理意义上存在差异，其数值存在数量级不一致的情况，为避免量纲差异带来的影响，对数据进行了归一化处理。

1.3 研究方法

本研究以双向长短期记忆网络（Bidirectional Long Short-Term Memory, Bi-LSTM）为核心时序建模框架，在时间特征方面，引入局部依赖头、全局依赖头和累积特征头3种多头注意力机制（Multi-Head Attention, MhA），用于对多维近地表气温序列中的关键时序信息进行加权建模，从而提升模型对

表2 十折交叉验证模型训练结果

Table 2 Results of 10-fold cross-validation for model training

折数	MAE/d	RMSE/d	R
1	1.13	1.46	0.95
2	1.80	2.12	0.87
3	1.71	2.14	0.87
4	1.79	2.58	0.83
5	1.58	2.32	0.82
6	1.37	1.67	0.79
7	1.60	2.30	0.84
8	0.87	1.10	0.95
9	1.88	2.24	0.78
10	1.13	1.29	0.96

不同时间尺度气温变化特征的识别能力；在空间特征方面，将地理因子（经纬度与高程）作为静态特征与递归神经网络结构相融合，以增强模型对不同地理位置下物候响应差异的适应能力。为便于表述，本研究将在 Bi-LSTM 框架中引入多头注意力机制后的预测模型简称为基于多头注意力机制的双向长短期记忆网络（BiLSTM-MhA）。模型的整体技术流程与预测框架如图3所示。首先，基于 NSAT 估算产品，计算得到研究区各样点 2019—2022 年逐日的最大、平均和最小 NSAT 数据。其次，基于获取的各样点最大/平均/最小 NSAT 逐日数据、经纬度高程数据和实测始花期数据，分别构建 LSTM、Bi-LSTM 和 BiLSTM-MhA 3 类预测模型。为保证模型性能的可比性，对 LSTM 和 Bi-LSTM 模型均采用贝叶斯优化算法进行超参数寻优，从而获得较优的网络结构与训练参数；并在 Bi-LSTM 的基础上引入多头注意力机制得到 BiLSTM-MhA 模型，用于进一步增强模型对气温时变特征的建模能力。接着，将研究区 2021 年 10 月 1 日—2022 年 3 月 30 日逐日的最大、平均和最小 NSAT 栅格数据与 DEM、经纬度叠置，对每个有效像元直接调用已训练且固定的 BiLSTM-MhA 模型进行逐像元预测，得到研究区苹果始花期预测空间分布图。最后，对比已有苹果花期预测模型，分析讨论本方法在苹果始花期预测精度上的优势。

1.3.1 双向长短时记忆网络 (Bi-LSTM)

LSTM 是在循环神经网络（Recurrent Neural Network, RNN）的基础上，引入记忆单元和门控机制实现序列信息的有效传递的一种改进模型。LSTM 共有 3 个门：遗忘门、输入门（更新门）和





图3 Bi-LSTM和多头注意力机制融合的苹果始花期预测技术流程图

Fig. 3 Technical flowchart for predicting apple initial bloom using an integrated Bi-LSTM and multi-head attention mechanism

输出门^[22]。这些门通过控制信息的流动,决定哪些信息被遗忘、哪些信息被更新,并在每个时间步生成新的输出。这种机制使得LSTM能够保留长期依赖信息,并有效地处理较长的时间序列。故该模型在处理较长的时间序列信息时,可以有效解决普通的循环神经网络存在的记忆丢失和梯度消失问题^[23]。LSTM包含1个隐藏向量 h 和1个记忆向量 C ,二者在复杂的门控机制作用下协同工作,在每个时间步动态更新状态,如图4所示。



注: x_t 为输入数据集不同的输入信息; h_{t-1} 为上一时刻的隐藏状态; c_{t-1} 为上一时刻的记忆状态; h_t 为当前时刻的输出。

图4 LSTM模型原理图

Fig. 4 Schematic diagram of the LSTM model

为了使模型能够更好地学习各调查样点逐日最高/平均/最低 NSAT 和经纬度高程与其始花期之间的关系,本研究使用了Bi-LSTM模型,该模型由两

个LSTM单元组成,1个前向LSTM和1个后向LSTM,前向LSTM单元处理正向输入,即从时间序列起始到当前时间步的输入数据;另1个单元处理反向输入,即从当前时间步到序列结束的输入数据^[24]。通过这种双向的设计,Bi-LSTM能够同时捕捉过去和未来的依赖关系,从而为每个时间步提供更丰富的上下文信息。具体地,图5为该模型原理图,输入数据分别被送入两个LSTM单元进行处理,在每个时间步生成对应的双向特征。最终,模型将双向特征进行拼接,并且经由激活函数处理映射到输出层特征,得到预测结果^[25]。




图5 Bi-LSTM模型原理图

Fig. 5 Schematic diagram of the Bi-LSTM model

1.3.2 多头注意力机制

注意力机制最早用来模拟人脑在信息处理中的选择性关注特征。早期大部分实现均依赖于RNN架构,但是这种序列依赖结构限制了计算的并行

化。Transformer 框架在此基础上发展出多头注意力机制，通过运行多个自注意力层并融合其结果，增强了对输入序列在不同子空间中的信息捕捉能力，从而提升了模型的表达能力^[26]。尽管 Bi-LSTM 能够有效捕捉时序数据中的长期依赖性，但对于短期波动和多尺度特征的提取存在一定的局限性。因此，本研究在 Bi-LSTM 基础上引入了多头注意力机制，以增强模型的表达能力，并且设计了 3 种自定义注意力头：局部依赖头、全局依赖头和累积特征头。局部依赖头关注局部时间步的短期气候波动，如突如其来的气温升高或下降，这类短期波动对苹果的始花期有着直接的影响。该头通过对输入的最高/平均/最低气温序列的查询矩阵进行 softmax 操作，强化了对局部时间步变化的关注，使得模型能够在气候突变时及时调整对始花期的预测。全局依赖头则平均化捕捉全局的信息，聚焦于全局最高/平均/最低气温变化的长期变化。全局依赖头通过对输入的最高/平均/最低气温序列的查询矩阵做均值化处理，帮助模型识别局温的长期效应，避免短期波动的干扰，同时高程经纬度信息在该头中也被重点关注。累积特征头则关注气温变化的累积效应，特别是气温积累对始花期的影响。始花期通常受到气温长期变化的影响，比如低温的积累（冷量积累）和高温的积累（热量积累），这对于预测花期具有关键意义。该头通过对输入的最高/平均/最低温度序列查询矩阵进行累加（Cumsum）操作，学习了气温的逐步变化和积累，从而更好地捕捉到气温变化趋势对始花期的影响。图 6 为多头注意力机制的原理构图。




图 6 多头注意力机制原理图

Fig. 6 Schematic diagram of the multi-head attention

多头注意力机制的本质就是学习 3 个权重矩阵，它们用于构造分别用查询（Query）、键（Key）和值（Value）矩阵表示。通常随机定义 3 个权重矩

阵，将输入分别映射为 Q 、 K 、 V ，如公式（1）～公式（3）所示。

$$Q = XW_Q \quad (1)$$

$$K = XW_K \quad (2)$$

$$V = XW_V \quad (3)$$

式中： X 为输入序列； W_Q 、 W_K 、 W_V 为对应查询、键和值矩阵的可学习的线性变换矩阵，用于将输入投影到不同的子空间^[27]。

接着，将 Q 、 K 、 V 分为 3 个子矩阵；每个头独立计算注意力权重，对应图 3 的 $A1$ 、 $A2$ 、 $A3$ ，如公式（4）所示。

$$\text{Attention}(Q_i, K_i, V_i) = \text{softmax}\left(\frac{Q_i K_i^T}{\sqrt{d_k}}\right) V_i \quad (4)$$

式中： d_k 为每个头的维度。

最后，再将多个头的输出拼接并映射回原始的隐藏空间，如公式（5）所示。

$$\text{MultiHead}(X) =$$

$$\text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_i) W_O \quad (5)$$

式中： head_i 为第 i 个头的输出； W_O 为输出层的权重矩阵。

1.3.3 精度评价指标

RMSE 用于衡量预测值 y_i 与真实值 t_i 之间的偏差，是评估模型预测精度的常用指标。较小的 RMSE 值表明模型在整体上更贴近真实观测值，如公式（6）所示。

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2} \quad (6)$$

式中： N 表示样点总数； y_i 表示第 i 个样本的预测值； t_i 表示第 i 个样本的真实值。

MAE 是预测值与真实值之差的绝对值的平均值，能够更直观地刻画预测偏差的平均水平。MAE 值越低，说明模型在绝大多数样本上的预测更为精准，如公式（7）所示。

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N \sqrt{(y_i - t_i)^2} \quad (7)$$

R 用于衡量预测值与真实值之间的线性相关程度， R 越接近 1，表示模型预测与真实观测高度正相关，如公式（8）所示。

$$R = \sqrt{\frac{\text{SSR}}{\text{SST}}} \quad (8)$$

式中： SSR 为回归平方和； SST 为总平方和。

2 结果与讨论

2.1 模型跨年度建模验证结果

在本研究中,针对苹果始花期的预测任务,基于贝叶斯优化选定的超参数,分别构建了LSTM、Bi-LSTM,以及在Bi-LSTM框架中引入多头注意力机制的BiLSTM-MhA模型。采用前两年数据(2020年和2021年花期数据、2019年10月1日—2020年2月29日及2020年10月1日—2021年3月30日的逐日最高/平均/最低NSAT数据、各样点高程和经纬度数据)进行模型训练,并利用第3年的数据(2022年花期数据、2021年10月1日—2022年3月30日的逐日最高/平均/最低NSAT数据、各样点高程和经纬度数据)开展独立验证,旨在评估模型在不同年份数据上的预测性能和泛化能力。

图7给出了LSTM模型、Bi-LSTM模型和BiLSTM-MhA模型的预测结果与真实值的回归分析及误差分布情况。图7a和图7b表明LSTM模型在预测过程中存在低估,无法有效地捕捉数据的变化趋势, R 为0.39,表明LSTM预测值与真实值之间的相关性较弱,说明该模型在时间序列数据建模过程中对数据变异性的解释能力较低,拟合效果较差。结合置信区间来看,LSTM预测值的离散程度较高,尤其是在数据较大或较小时,其偏差更大,导致整体预测精度受限。由于LSTM在建模过程中对不同时段的气温信息赋予了相同权重,难以有效区分开花前关键阶段与非关键阶段的影响,部分站点的RMSE误差超过3 d。相较之下,Bi-LSTM模型通过引入双向结构,在一定程度上增强了对气温序列前后依赖关系的利用。由图7c可见,其预测相关性提高至 $R=0.45$ 。然而,如图7d所示,由于Bi-LSTM仍主要依赖隐状态传递进行时间特征建模,缺乏对不同时序信息重要性的显式刻画,在部分样点上仍存在预测不稳定的情况。在Bi-LSTM框架中进一步引入多头注意力机制后,模型在始花期预测精度与稳定性方面均得到改善。如图7e和图7f所示,BiLSTM-MhA模型能够较好地拟合始花期的整体变化趋势,相较于传统LSTM和Bi-LSTM模型,其预测值与实测值之间的相关系数提升至 $R=0.84$ 。通过多头注意力机制对气温序列中不同时段信息进行加权建模,模型能够分别关注气温变化过程中的局部波动、长期趋势及累积效应,提高模型预测能力。结果表明,预测误差主要集中在0~2 d,其RMSE为1.34 d,MAE为1.13 d(表3),

较LSTM和Bi-LSTM模型,预测精度分别提升了39.37%和20.71%。表明模型在整体预测精度上具备综合优势。这说明在进行苹果始花期预测时,BiLSTM-MhA模型能够更好地捕捉数据的非线性特征,在进行跨年度验证时,也具有较好的可迁移预测能力。此外,图8c展示了BiLSTM-MhA模型得到的2022年洛川县尺度苹果始花期预测值的空间分布图。可以看到,始花期在90~120 d呈现海拔梯度特征,从空间维度印证了将高程、经纬度纳入模型的必要性。

2.2 不同输入时间窗口下的模型性能分析

为进一步验证模型的可提前预测能力,本研究以不同数据截止日期(3月5日—3月30日)为分界,对模型进行提取预测能力测试(表4)。结果显示,随着数据截断日期的提前,模型预测误差呈轻微上升趋势,但整体波动幅度较小。截至3月15日—3月20日的模型仍维持RMSE为1.3~1.5 d、MAE为1.1~1.2 d、相关系数 $R\approx 0.83$ 的水平,与3月30日全信息输入时的结果几乎一致;即便将输入数据提前至3月10日(提前约20 d),RMSE仅为1.41 d、MAE为1.18 d, R 仍保持0.82,说明模型在气象观测不完全的条件下仍具稳健性。

当输入数据进一步提前至3月5日(约提前25 d)时,误差开始增大(RMSE=2.21 d,MAE=1.99 d), R 下降至0.58,并且进一步减少输入数据的时间窗口会导致预测误差逐渐增大,这表明此时由于气温上升阶段尚未充分展开,模型预测的不确定性增大。总体而言,该结果表明所建模型在不依赖未来气象信息的情况下,仍可稳定地提前15~20 d预测苹果始花期,误差控制在 ± 2 天以内,满足生产应用对花期预测时效性和准确性的双重要求。

2.3 BiLSTM-MhA模型与机器学习对比

常见的传统的机器学习方法,如RF和支持向量机(Support Vector Machine, SVM),在许多回归任务中已表现出一定的有效性。在同一数据集与评估框架下,本研究进一步复现了RF与SVM两类经典算法,以量化其与本研究模型的性能差异。实验结果表明,在本研究的苹果始花期的预测中,这些方法存在适用性不足,预测精度较低的问题。

如表5所示,RF模型的RMSE为2.30 d、MAE为2.63 d, R 仅为0.25,显示预测值与真实值之间的相关性极弱;SVM模型的RMSE为2.63 d、MAE为3.03 d, R 虽略高(0.51),但仍处于较低水平。




图 7 LSTM、Bi-LSTM 与 BiLSTM-MhA 模型验证结果图

Fig.7 Verification result charts of LSTM, Bi-LSTM and BiLSTM-MhA

表 3 LSTM、Bi-LSTM 与 BiLSTM-MhA 模型验证结果

Table 3 Verification results of LSTM, Bi-LSTM and BiLSTM-MhA


模型	RMSE/ d	MAE/ d	R
LSTM	2.21	1.91	0.39
Bi-LSTM	1.69	1.30	0.45
BiLSTM-MhA	1.34	1.13	0.84

两种方法在预测过程中均存在低估,尤其是在数据分布两端(即始花期较早样点和较晚样点),预测偏差更大,导致整体预测精度受限。这说明,经典

的非时间序列机器学习模型(如 RF 和 SVM)在跨年度的情景下无法保持稳定的预测性能,而 BiLSTM-MhA 模型通过时间序列建模和多头自注意力机制,能够更好地应对数据的时序变化,从而在预测精度上具有优势。

2.4 BiLSTM-MhA 模型与机理模型对比

本研究基于温度时序数据和地理位置数据,利用深度学习的方法开展始花期预测研究。从模型预报试验结果可知,跨年度的验证方式下始花期预测 RMSE 为 1.34 d。为对比现有机理模型的研究成果,



注:该图基于自然资源部标准地图服务网站下载的审图号为GS(2024)0650号标准地图制作,底图无修改。

图 8 2022 年洛川县苹果始花期预测分布图

Fig. 8 The predicted distribution map of the first flowering date of apples in Luochuan county in 2022

表 4 输入数据不同截止日对苹果始花期预测模型精度的影响
Table 4 Impact of different input data cutoff dates on the prediction accuracy of the first flowering date of apples

截止日	RMSE/ d	MAE/ d	R
3月30日	1.34	1.13	0.84
3月25日	1.30	1.07	0.83
3月20日	1.32	1.10	0.84
3月15日	1.46	1.20	0.82
3月10日	1.41	1.18	0.82
3月5日	2.21	1.99	0.58
2月28日	2.54	2.10	0.51
2月23日	2.63	2.44	0.49

表 5 机器学习方法测试精度
Table 5 Machine learning method test accuracy

方法	RMSE/ d	MAE/ d	R
随机森林	2.30	2.63	0.25
支持向量机	2.63	3.03	0.51
BiLSTM-MhA	1.34	1.13	0.84

本研究引用了相关文献中的精度指标。以西欧地区为例, DREPPER 等^[28]在比利时的花期预测试验中, 预测平均误差分布于 4.15~6.36 d。国内相关研究方面, 邱美娟等^[29]在北方苹果主产区开展的预报工作中, 模型偏差为 3.4~6.6 d。刘森等^[16]的苹果始花期预测模型预测精度 RMSE 约为 3.44 d。而刘璐等^[6]针对全国主产区构建的模型结果显示始花期误差大致为 5 d。总体来看, 现有研究多数精度处于 3~6 d。值得注意的是, 由于数据来源、

模型构建和研究区域的不同, 这些结果更多是展示了本研究提出的 BiLSTM-MhA 模型与传统机理模型相对精度的差异, 但仍可发现, 本研究引入的 Bi-LSTM 与多头注意力结构能够有效地对长时间序列进行整体建模, 避免了分步计算过程中的结构性误差积累, 并在可比指标上展现出具有竞争力的预测精度。

2.5 静态因子(高程经纬度)消融实验

静态因子(高程经纬度)对始花期预测有一定的影响, 且在实际应用中常作为环境变量影响生长周期。为探讨经纬度和高程作为静态地理因子在苹果始花期预测中的贡献, 本研究设计了消融实验对模型的输入变量进行逐步删减, 以完整模型输入(动态温度序列+经纬度+高程)作为基准, 评估了去除静态因子对模型预测精度的影响。实验结果见表 6。

当分别去除高程和经纬度后, 模型性能均发生不同程度下降, 其中单独去除高程后 RMSE 略升至

表 6 静态地理因子消融对苹果始花期预测模型精度的影响
Table 6 Impact of static geographic factor ablation on the prediction accuracy of the first flowering date of apples

静态因子	RMSE/ d	MAE/ d	R
完整模型	1.34	1.13	0.84
去掉高程	1.45	1.11	0.64
去掉经纬度	2.54	2.05	0.50
去掉高程+经纬度	2.69	2.38	0.35

1.45 d, 而 R 则降至 0.64, 表明高程虽未增加绝对误差, 但对模型解释变异的能力有一定贡献; 而当单独去除经纬度后, RMSE 升高至 2.54 d, MAE 增至 2.05 d, R 亦降至 0.50, 表明经纬度在花期预测中的重要性超过高程。同时, 去除经纬度与高程, 仅保留动态温度变量时, 模型性能大幅下降 (RMSE=2.69 d, MAE=2.38 d, R =0.35), 预测误差较完整模型增大超过 1 倍, 说明经纬度与高程作为静态特征的加入提高了模型对区域花期时空差异的预测能力。

通过上述消融实验可知, 静态地理因子尤其是经纬度特征, 增强了模型对于空间尺度差异的敏感性, 从而有效捕捉到不同区域间苹果始花期的变化规律。这也充分验证了相较于传统机理模型, 本研究提出的基于深度学习的方法融入静态地理特征, 能够更为精准地描述区域尺度上的苹果始花期差异及变化趋势。

3 结论与展望

3.1 结论

本研究围绕苹果始花期预测中气温时序信息利用不足与区域适应性有限的问题, 构建了一种以 Bi-LSTM 为核心、融合多头注意力机制与地理因子的苹果始花期预测方法, 并在陕西省洛川县开展了跨年份验证分析, 主要结论如下。

1) 通过在 Bi-LSTM 框架中引入多头注意力机制, 增强了模型对气温序列中关键时段信息的关注能力, 有助于刻画花前气温变化过程中局部波动、整体趋势及累积效应等时变规律。在测试集上, 模型的始花期预测 RMSE 为 1.34 d, 相较于传统 LSTM 和 Bi-LSTM 模型, 本研究模型预测精度分别提升了 39.37% 和 20.71%。

2) 通过将地理因子 (高程经纬度) 作为静态特征与递归神经网络结构相融合, 提高了模型的区域自适应预测能力。此外, 模型能够提前 15~20 d 预测苹果始花期, 展示了其较强的适应性和预测潜力。

综上, 本研究提出的苹果树始花期预测模型在苹果始花期预测中提升了一定的精度, 具有较强的实际应用潜力。

3.2 展望

尽管本研究提出的 BiLSTM-MhA 模型在始花期预测中取得了精度提升, 但未来仍有进一步改进

空间。首先, 本研究主要依赖 1 km 分辨率的近地表气温数据, 未来研究可以探索如何融合更高分辨率气象数据以进一步提高预测精度。其次, 本研究仅限于洛川县, 未来可以考虑将该模型推广到其他地区, 以提高模型的普适性。

利益冲突声明: 本研究不存在研究者以及与公开研究成果有关的利益冲突。

参考文献:

- [1] ZHU Y H, YANG G J, YANG H, et al. Identification of apple orchard planting year based on spatiotemporally fused satellite images and clustering analysis of foliage phenophase[J]. *Remote Sensing*, 2020, 12(7): 1199.
- [2] 程存刚, 赵德英. 新形势下我国苹果产业的发展定位与趋势[J]. *中国果树*, 2019(1): 1-7.
CHENG C G, ZHAO D Y. Development orientation and trend of the apple industry under the new situation[J]. *China Fruits*, 2019 (1): 1-7.
- [3] 蔡敏, 樊娟, 闫雷玉, 等. 黄土高原晚霜气温变化及瑞雪苹果花抗冻性研究[J]. *落叶果树*, 2023, 55(5): 30-35.
CAI M, FAN J, YAN L Y, et al. Analysis of late frost temperature variation in Loess Plateau and a study on the frost resistance of Ruixue apple flowers[J]. *Deciduous Fruits*, 2023, 55(5): 30-35.
- [4] ZHU Y H, YANG G J, YANG H, et al. Estimation of apple flowering frost loss for fruit yield based on gridded meteorological and remote sensing data in Luochuan, Shaanxi province, China[J]. *Remote Sensing*, 2021, 13(9): 1630.
- [5] 邹定荣, 霍治国, 王培娟, 等. 陕西苹果花期机理性预报模型的适用性评价[J]. *应用气象学报*, 2019, 30(5): 555-564.
WU D R, HUO Z G, WANG P J, et al. The applicability of mechanism phenology models to simulating apple flowering date in Shaanxi province[J]. *Journal of Applied Meteorological Science*, 2019, 30(5): 555-564.
- [6] 刘璐, 王景红, 傅玮东, 等. 中国北方主产地苹果始花期与气候要素的关系[J]. *中国农业气象*, 2020, 41(1): 51-60.
LIU L, WANG J H, FU W D, et al. Relationship between apple's first flower and climate factors in the main producing areas of the northern China[J]. *Chinese Journal of Agrometeorology*, 2020, 41 (1): 51-60.
- [7] KWON J H, NAM E Y, YUN S K, et al. Chilling and heat requirement of peach cultivars and changes in chilling accumulation spectrums based on 100-year records in Republic of Korea[J]. *Agricultural and Forest Meteorology*, 2020, 288/289: 108009.
- [8] YANG Y, WU Z F, GUO L, et al. Effects of winter chilling vs. spring forcing on the spring phenology of trees in a cold region and a warmer reference region[J]. *Science of the Total Environment*, 2020, 725: 138323.
- [9] DARBYSHIRE R, POPE K, GOODWIN I. An evaluation of the chill overlap model to predict flowering time in apple tree[J]. *Scientia Horticulturae*, 2016, 198: 142-149.
- [10] YAACOUBI AEL, OUKABLI A, HAFIDI M, et al. Validated model for apple flowering prediction in the Mediterranean area in response to temperature variation[J]. *Scientia Horticulturae*, 2019, 249: 59-64.
- [11] LUEDELING E, SCHIFFERS K, FOHRMANN T, et al. PhenoFlex: An integrated model to predict spring phenology in temperate fruit trees[J]. *Agricultural and Forest Meteorology*, 2021, 307: 108491.
- [12] 戴君虎, 陶泽兴, 王焕炯, 等. 物候模型在气候定量重建中的应用[J]. *第四纪研究*, 2016, 36(3): 702-710.
DAI J H, TAO Z X, WANG H J, et al. Applications of phenological models in quantitative climate reconstruction[J]. *Quaternary Sciences*, 2016, 36(3): 702-710.
- [13] 柏秦凤, 霍治国, 王景红, 等. 中国富士系苹果主产区花期模拟

- 与分布[J]. 中国农业气象, 2020, 41(7): 423-435.
- BAI Q F, HUO Z G, WANG J H, et al. Simulation and distribution of flower stage in main production areas of fuji apple in China[J]. Chinese Journal of Agrometeorology, 2020, 41(7): 423-435.
- [14] 张艳艳, 赵玮, 高庆先, 等. 气候变化背景下陇东塬区“红富士”苹果始花期研究[J]. 果树学报, 2017, 34(4): 427-434.
- ZHANG Y Y, ZHAO W, GAO Q X, et al. The effect of climate change on the apple's initial flowering date in the eastern Gansu province[J]. Journal of Fruit Science, 2017, 34(4): 427-434.
- [15] 郭连云, 赵年武. 贵德县梨树始花期与气象因子的相关分析及预报模型[J]. 中国农学通报, 2016, 32(7): 147-151.
- GUO L Y, ZHAO N W. Correlation analysis and forecasting model of beginning of flowering period of pear tree and meteorological factors[J]. Chinese Agricultural Science Bulletin, 2016, 32(7): 147-151.
- [16] 刘森, 邱春霞, 杨贵军, 等. 基于日气温特征值与冷/热积量模型耦合的苹果始花期预报模型[J]. 中国农业气象, 2022, 43(4): 295-307.
- LIU M, QIU C X, YANG G J, et al. Forecast model of apple first flowering date based on the coupling of daily air temperature characteristic values and chill/heat accumulation model[J]. Chinese Journal of Agrometeorology, 2022, 43(4): 295-307.
- [17] REDDY D S, PRASAD P R C. Prediction of vegetation dynamics using NDVI time series data and LSTM[J]. Modeling Earth Systems and Environment, 2018, 4(1): 409-419.
- [18] LIU G H, MIGLIAVACCA M, REIMERS C, et al. DeepPhenoMem V_{1.0}: Deep learning modelling of canopy greenness dynamics accounting for multi-variate meteorological memory effects on vegetation phenology[J]. Geoscientific Model Development, 2024, 17(17): 6683-6701.
- [19] TRAN K H, ZHANG X Y, ZHANG H K, et al. A transformer-based model for detecting land surface phenology from the irregular harmonized Landsat and Sentinel-2 time series across the United States[J]. Remote Sensing of Environment, 2025, 320: 114656.
- [20] ALHNAITY B, KOLLIAS S, LEONTIDIS G, et al. An autoencoder wavelet based deep neural network with attention mechanism for multi-step prediction of plant growth[J]. Information Sciences, 2021, 560: 35-50.
- [21] GAO M L, XU H H, TAN Z Y, et al. A 40-year 1-km daily seamless near-surface air temperature product over Yellow River Basin of China[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 16: 7433-7446.
- [22] WAQAS M, HUMPHRIES U W. A critical review of RNN and LSTM variants in hydrological time series predictions[J]. MethodsX, 2024, 13: 102946.
- [23] 缪程远, 张博轩, 张赞, 等. 基于 BiLSTM 和卷积神经网络模型的辐射源个体识别研究[J]. 物联网技术, 2025, 15(1): 3-8.
- MIAO C Y, ZHANG B X, ZHANG Z, et al. Research on individual identification of radiation source based on BiLSTM and convolutional neural network model[J]. Internet of Things Technologies, 2025, 15(1): 3-8.
- [24] 赵瑜, 霍永华, 黄伟, 等. 基于双向 LSTM 模型的流量异常检测方法[J]. 无线电工程, 2023, 53(7): 1712-1718.
- ZHAO Y, HUO Y H, HUANG W, et al. Traffic anomaly detection method based on bidirectional LSTM models[J]. Radio Engineering, 2023, 53(7): 1712-1718.
- [25] 王茂发, 章赫, 黄鸿亮, 等. BiLSTM 与多头注意力机制结合的生成式中文自动文摘[J]. 山西大学学报(自然科学版), 2022, 45(4): 996-1003.
- WANG M F, ZHANG H, HUANG H L, et al. Automatic Chinese abstractive summarization based on BiLSTM and multi-head attention mechanism[J]. Journal of Shanxi University (Natural Science Edition), 2022, 45(4): 996-1003.
- [26] TAY Y, DEHGHANI M, BAHRI D, et al. Efficient transformers: A survey[J]. ACM Computing Surveys, 2023, 55(6): 1-28.
- [27] 黄泽民, 吴迎岗. 结合 BERT 和卷积双向简单循环网络的文本情感分析[J]. 计算机应用与软件, 2022, 39(12): 213-218.
- HUANG Z M, WU Y G. Text emotion analysis based on BERT and cnn-bisru[J]. Computer Applications and Software, 2022, 39(12): 213-218.
- [28] DREPPER B, GOBIN A, REMY S, et al. Comparing apple and pear phenology and model performance: What seven decades of observations reveal[J]. Agronomy, 2020, 10(1): 73.
- [29] 邱美娟, 刘布春, 刘园, 等. 中国北方主产地苹果始花期模拟及晚霜冻风险评估[J]. 农业工程学报, 2020, 36(21): 154-163.
- QIU M J, LIU B C, LIU Y, et al. Simulation of first flowering date for apple and risk assessment of late frost in main producing areas of northern China[J]. Transactions of the Chinese Society of Agricultural Engineering, 2020, 36(21): 154-163.

A Bi-LSTM Prediction Method for Apple First Flowering Date Based on Enhanced Time-Series Temperature Features

LIU Enqi^{1,2}, LIU Miao¹, WANG Tuo^{1,2}, ZHU Yaohui³, CHEN Riqiang², XU Bo², GAO Meiling¹,
ZHANG Jing¹, YANG Yun¹, YANG Guijun^{1,2*}

(1. School of Geological Engineering and Surveying, Chang'an University, Xi'an 710054, China; 2. Key Laboratory of Agricultural Remote Sensing Mechanism and Quantitative Remote Sensing, Ministry of Agriculture and Rural Affairs/Information Technology Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China; 3. College of Agricultural Engineering, Jiangsu University, Zhenjiang 212013, China)

Abstract: [Objective] The first flowering date of apples is a key phenological stage in the annual growth cycle of fruit trees. Its occurrence timing is directly associated with pollination efficiency, fruit set rate, and subsequent fruit development, and it also serves as an important basis for orchard management practices, including flower and fruit thinning, pest and disease control, as well as early risk warning and emergency management for low-temperature frost events during the flowering period. Existing studies still have room for improvement in the fine-scale extraction of temperature time-series information and in the representation of model adaptability across different spatial locations. Therefore, the purpose of this research is to develop a prediction method for the first flowering date of ap-

ples that can effectively characterize time-varying temperature patterns and achieve regional adaptability, thereby providing more reliable technical support for refined orchard management and disaster prevention. **[Methods]** A deep learning-based forecasting framework for predicting the first flowering date of apples was developed based on observation sites in Luochuan county, Shaanxi province. First, daily near-surface air temperature (NSAT) data from 2019 to 2021 were collected for the period from apple harvest to the subsequent flowering season in the study area, including daily maximum, mean, and minimum temperatures. In addition, elevation, latitude, and longitude were introduced as static geographic factors, forming a combined input composed of dynamic temperature sequences and static spatial attributes. Second, in terms of the model design, a bidirectional long short-term memory network (Bi-LSTM) was employed as the temporal encoder to learn bidirectional dependencies within the temperature time series. On this basis, a customized multi-head attention (MHA) mechanism was integrated, consisting of a local dependency head, a global trend head, and a cumulative feature head, which were designed to represent short-term pre-flowering temperature fluctuations, overall temperature trends, and cumulative temperature effects, respectively. This configuration enhanced the extraction of time-varying information across multiple temporal scales. The attention outputs were then fused with the static geographic factors, and the predicted first flowering date was generated through a regression layer, enabling regionally adaptive prediction. To ensure comparability of results, LSTM and Bi-LSTM models were simultaneously constructed as baseline models using identical data preprocessing and training procedures. Third, Bayesian optimization was applied for automatic hyperparameter tuning, during which key parameters, including learning rate, number of network layers, number of hidden units, regularization terms, and optimizers, were systematically searched, and the optimal configuration was selected based on validation performance. Finally, a cross-year validation strategy was adopted to evaluate model generalization ability: Data from 2019 to 2021 were used as the modeling dataset (training and validation), while the observed first flowering date in 2022 served as an independent test dataset. The predictive performance of all models was evaluated using three widely recognized metrics: root mean square error (RMSE), mean absolute error (MAE), and correlation coefficient (R). **[Results and Discussions]** The proposed model achieved an RMSE of 1.34 d, a MAE of 1.13 d, and the R of 0.84 on the test dataset, with most prediction errors concentrated within a range of 0–2 d. Validation results indicated that the proposed approach was capable of providing stable predictions approximately 15–20 d in advance within the study area. Further comparative analysis demonstrated that the Bi-LSTM architecture more effectively exploited both forward and backward dependencies in the pre-flowering temperature time series, thereby offering a more stable temporal representation for regression-based prediction of the first flowering date. Building upon this structure, the introduction of three attention heads: the local dependency head, the global trend head, and the cumulative feature head, enabled the model to more explicitly distinguish and utilize short-term fluctuations, stage-wise trends, and cumulative temperature effects. This targeted extraction of multi-scale time-varying information contributed to reduced prediction errors and improved overall prediction accuracy. Ablation experiments involving static geographic factors further verified the necessity of the spatial adaptability component. When the elevation was removed, the RMSE increased from 1.34 d to 1.45 d. Removing latitude and longitude led to a larger increase in RMSE to 2.54 d, and when both elevation and geographic coordinates were excluded, the RMSE further rose to 2.69 d accompanied by a decrease in correlation. These results indicated that geographic factors provided effective spatial constraints, which supported the learning of location-specific phenological responses across different sampling sites. In addition, spatial prediction maps revealed that the first flowering date in the study area exhibited a gradient distribution with respect to elevation to a certain extent. This spatial pattern was consistent with the modeling rationale of incorporating geographic factors into a unified prediction framework. **[Conclusions]** This study proposes a deep learning-based prediction method for the first flowering date of apples that integrates multi-dimensional temperature features, a multi-head attention mechanism, and geographic factors. The proposed method achieves relatively high prediction accuracy in cross-year forecasting and enables spatially adaptive prediction of the first flowering date of apples. These findings provide a new data-driven technical pathway for refined prediction of apple flowering phenology and offer important technical support for orchard flowering management, frost damage prevention, and agricultural production decision-making.

Keywords: near-surface air temperature; multi-head attention; geographic factors; Bi-LSTM; the first flowering date of apples

Foundation items: National Natural Science Foundation of China (42171303)

First author: LIU Enqi, E-mail: enqiliu0504@163.com

***Corresponding author:** YANG Guijun, E-mail: guijun.yang@163.com