

基于长短期记忆网络的冬小麦连续时序叶面积指数预测

龙泽昊¹, 秦其明^{1, 2, 3*}, 张添源¹, 许伟¹

1. 北京大学地球与空间科学学院遥感与地理信息系统研究所, 北京 100871

2. 地理信息基础软件与应用工程技术研究中心, 北京 100871

3. 空间信息集成与3S工程应用北京市重点实验室, 北京 100871

摘要 连续时序的叶面积指数(LAI)可反映冬小麦长势的变化情况, 预测冬小麦未来时段的 LAI 对指导田间管理决策具有重要作用。以 WOFOST(World Food Studies)为代表的作物生长模型可通过模拟冬小麦的生长发育过程对未来 LAI 曲线进行预测, 但其预测过程依赖于未来的气象数据等难以获取的输入参数。由于冬小麦的 LAI 时序变化具有连续性和规律性的特点, 可通过深度学习的方法仅以历史 LAI 为输入参数对未来 LAI 进行预测, 但深度学习的方法需要大量样本参与训练, 训练样本的稀缺性限制了其在 LAI 预测方面的实际应用。针对上述问题, 通过数据同化方法将遥感数据与 WOFOST 模型相结合, 采用 SCE(Shuffled Complex Evolution)算法最小化校正后的 MODIS LAI 产品与模型模拟 LAI 之间差值来优化作物模型初始参数, 从而构建出京津冀地区 15 年的逐日冬小麦 LAI 数据集。在该数据集基础上, 利用长短期记忆网络(LSTM)分别建立了不同输入历史 LAI 天数的多个冬小麦预测模型, 探究了不同预测模型表达冬小麦生育期中 LAI 变化规律的能力。结果表明: 基于 LSTM 网络的预测模型都能较好地进行冬小麦 LAI 未来曲线变化的预测, 其中当模型输入 LAI 长度为 20 时, 预测冬小麦从返青到成熟阶段的 LAI 精度最高, 其决定系数(R^2)、均方根误差(RMSE)值分别为 0.986 5 和 0.183 6。对于冬小麦生长各个阶段, 预测模型对于返青至开花期的预测精度高, 开花至成熟期的预测精度稍有降低。总体而言, 构建训练数据集的方法对于深度学习的方法在相似问题中的应用具有借鉴意义, 建立的预测模型验证了 LSTM 网络对于冬小麦时序 LAI 曲线具有较好的预测能力, 为预测作物未来时序 LAI 提供了一种有效的方法。

关键词 叶面积指数; 长短期记忆网络; WOFOST 模型; 数据同化; MODIS LAI 遥感影像

中图分类号: TP79 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2020)03-0898-07

引言

叶面积指数(leaf area index, LAI)是描述植被形态结构的重要参数, 其定义为单位地表面上单面叶片的总面积^[1]。由于 LAI 与植被的光合作用、生物量积累等生理过程密切相关, 因而在农业生产中常被用于评价作物长势与估算作物产量^[2-4]。预测作物未来 LAI 曲线变化情况, 可以掌握作物未来的生长趋势, 对于估计作物未来的长势状况、制定田间管理决策具有重要意义。

时序 LAI 数据可通过作物生长模型模拟以及遥感反演等方法获得。WOFOST 是以日为步长来动态模拟作物生长

过程的作物模型, 通过输入气象、作物等参数可获得作物逐日时序 LAI 数据以及其他生长参数。利用 WOFOST 可以对作物未来的 LAI 曲线进行预测, 但需要以未来气象数据作为支撑^[5], 而模型繁多的输入参数且依赖于未来气象数据等问题限制了其应用。此外, 利用现有遥感 LAI 产品也可对时序 LAI 数据进行建模, 但传统建模方法可能会受到 LAI 数据时间或空间不连续性问题而削弱了应用的鲁棒性, 因此部分研究利用神经网络方法来对时序 LAI 建模, 有研究将季节自回归积分滑动平均(SARIMA)方法与 BP 神经网络进行结合对时序 MODIS LAI 进行预测, 结果显示该组合方法的预测准确性高于传统的 SARIMA 方法; Xiao 等^[6]利用广义回归神经网络(GRNN)来估算全球时序 LAI, 其建模精度优于

收稿日期: 2019-01-06, 修订日期: 2019-04-21

基金项目: 高分辨率对地观测系统重大专项(11-Y20A16-9001-17/18), 国家自然科学基金项目(41771371), 国家自然科学基金国际合作项目(61661136006)资助

作者简介: 龙泽昊, 1994 年生, 北京大学遥感与地理信息系统研究所硕士研究生 e-mail: longzehao@pku.edu.cn

* 通讯联系人 e-mail: qmqinpk@163.com

MODIS 和 CYCLOPES LAI 产品; Chen 等^[7] 建立了一个基于循环神经网络(RNN)的非线性自回归模型来预测橡胶种植林 LAI, 结果表明 RNN 在反演时序 LAI 上具有可行性。与普通神经网络相比, RNN 通过在每层神经元之间建立连接, 从而能够有效地挖掘时序数据中所包含的规律, 而其变体长短期记忆网络(long short-term memory, LSTM)通过添加门控机制进一步提高了时序数据预测精度^[8-9], 但目前还未见研究利用 LSTM 对时序 LAI 建模。由于在冬小麦生长过程中 LAI 曲线变化具有规律性, 因此 LSTM 具有对冬小麦未来 LAI 曲线进行预测的潜力, 但此方法需要大量样本作为基础, 而样本的难获取性也限制了其在作物 LAI 时序预测方面的应用。

通过结合校正后的 MODIS LAI 产品与 WOFOST 模型, 构建了京津冀地区 15 年的历史逐日冬小麦 LAI 数据集, 并利用 LSTM 建立了冬小麦 LAI 预测模型, 探讨了其在农作物 LAI 曲线预测的潜力。

1 实验部分

1.1 研究区及数据介绍

研究区为京津冀地区, 位于 $36^{\circ}21' - 42^{\circ}37'N$, $113^{\circ}27' - 119^{\circ}51'E$, 该区域农作物以冬小麦和玉米为主, 其中冬小麦种植区域除河北省张家口和承德地区外均有种植。如图 1 所示, 研究区内共有 17 个气象站点, 本文下载了 2003 年 9 月至 2017 年 7 月共 15 年的逐日气象数据, 数据来源于国家气象信息中心的地面气候资料日值数据集。实测数据为河北衡水市 2017 年 3 月 30 日(DOY: 89)和 2017 年 5 月 5 日前后(DOY: 125)两个时期实测 LAI。遥感数据使用 4 天周期、500 m 分辨率的 MODIS LAI(MCD15A3H)数据, 时间范围为 2003 年—2017 年的 1 月—6 月, 每年有 45 张时序影像(DOY: 1~177)。

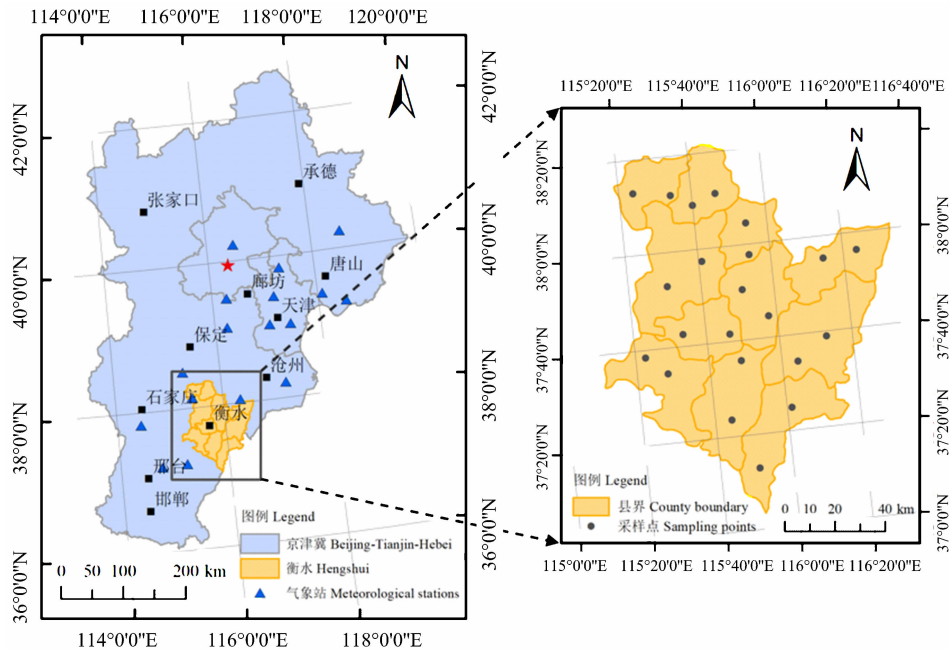


图 1 研究区以及气象站点和采样点分布

Fig. 1 Study area and locations of meteorological stations and sampling points

1.2 冬小麦 LAI 数据集构建

1.2.1 遥感数据预处理

MODIS LAI 空间分辨率较低, 像元中一般会混杂除冬小麦外的其他地物, 造成 LAI 值偏低问题, 因此需进行校正。如图 2 所示, 首先对于各气象站点和采样点, 在点周围 100 km 内的 MODIS LAI 时序影像中进行由里向外 LAI 曲线的提取, 并依据 LAI 曲线特征形态以及对应点的 Google Earth 影像来目视解译是否为冬小麦像元, 最终提取出 2003 年—2017 年共 247 条符合要求的气象站点 LAI 曲线和 2017 年采样点 LAI 曲线。然后, 利用 Savitzky-Golay 滤波对所有曲线进行平滑处理, 并对平滑后采样点 LAI 曲线提取出 DOY 为 88、124 的 LAI, 并根据文献^[10]方法与实测 LAI 建

立校正模型。最终, 从 247 条气象站点 LAI 曲线中提取 DOY 为 120、140 和 160 的 MODIS LAI 值, 并用校正模型对其进行校正。

1.2.2 遥感-WOFOST 同化

WOFOST 通过给定对应作物和环境参数可对不同作物进行生长模拟, 利用京津冀地区冬小麦作物参数, 在潜在生产水平下进行冬小麦 LAI 模拟, 并采用同化算法进行参数优化, 从而生成该地区 15 年的冬小麦 LAI 数据集。

在优化参数的选择中, TSUM1 和 TSUM2 参数代表有效积温, 需要依据气温数据动态计算获得, 由于获取往年各个气象站点附近冬小麦出苗、开花、成熟三个阶段的准确时间较困难, 所以需要进行优化。此外, 根据文献^[11]建议,

TDWI 和 SPAN 是 WOFOST 模型中重要的两个参数, 也将将其加入优化(如表 1)。

确定好优化参数后, 采用 SCE 优化算法实现模拟 LAI 与遥感观测 LAI 最小化, 从而得到比未优化之前更准确的连续时序 LAI 数据。优化算法的损失函数如式(1)所示。

$$Q = (x_{120} - y_{120})^2 + (x_{140} - y_{140})^2 + (x_{160} - y_{160})^2 \quad (1)$$

其中: x_{120} , x_{140} 和 x_{160} 为利用 WOFOST 模拟的 LAI 曲线中 DOY 为 120, 140 和 160 的 LAI 值, y_{120} , y_{140} 和 y_{160} 为校正

后的 MODIS LAI 中 DOY 为 120, 140 和 160 的 LAI 值。

通过所提取的 247 组校正后的 MODIS LAI 加入 WOFOST 进行同化, 并以每组所对应的当年站点气象数据来驱动模型, 从而得到优化后的 LAI 曲线数据。如图 3(a) 所示, 未同化生成的 LAI 曲线中 LAI 最高值达到 8, 最低值仅为 2, 部分曲线不符合冬小麦生长规律特征。如图 3(b) 所示, 同化后生成的 LAI 曲线中的均值线最大值为 5 且在轮廓线内分布较均匀, 更符合冬小麦 LAI 曲线变化规律。

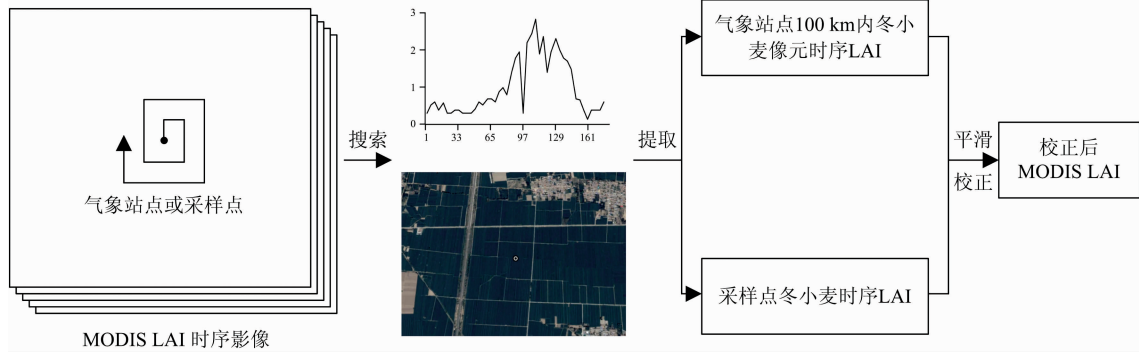


图 2 遥感数据预处理流程图

Fig. 2 Flow chart of remote sensing data preprocessing method

表 1 需优化参数的定义与校准值范围

Table 1 Description and range of parameters to be optimized

参数名称	定义	校准值范围	来源
TSUM1	出苗至开花有效积温/($^{\circ}\text{C} \cdot \text{d}$)	$0.9 * \text{TSUM1} \sim 1.1 * \text{TSUM1}$	计算
TSUM2	开花至成熟有效积温/($^{\circ}\text{C} \cdot \text{d}$)	$0.9 * \text{TSUM2} \sim 1.1 * \text{TSUM2}$	计算
SPAN	叶片衰老系数/d	17~50	调整
TDWI	初始生物量/($\text{kg} \cdot \text{hm}^{-2}$)	50~300	调整




图 3 未同化(a)与同化(b) WOFOST 模型生成的 247 条 LAI 曲线

Fig. 3 247 LAI curves generated by WOFOST model with assimilation (b) and without assimilation (a)

1.3 LAI 预测模型

以生成的冬小麦 LAI 数据集为基础, 采用 LSTM 网络对冬小麦 LAI 时序曲线变化规律进行学习, 实现对未来 LAI 曲线的预测。如图 4 所示, LSTM 通过添加门结构使得信息有选择性地影响模型中每个时刻的状态, 主要由输入门、输出门、遗忘门组成^[8]。

如式(2)一式(6)所示为 t 时刻的 LSTM 的计算公式

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (2)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (3)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (4)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (5)$$

$$h_t = o_t \circ \tanh(c_t) \quad (6)$$

其中: \circ 为点乘运算, σ 和 \tanh 为激活函数, $x_t \in R^d$ 为 t 时刻输入向量, $f_t, i_t, o_t \in R^h$ 分别为遗忘门、输入门、输出门激

活向量, $h_t \in R^h$ 为记忆单元输出向量, $c_t \in R^h$ 为记忆单元状态向量, $W \in R^{h \times d}$, $U \in R^{h \times h}$ 和 $b \in R^h$ 为权重矩阵和偏置向量。

对冬小麦 LAI 进行短时间预测并不能有效反映出其生长状态, 若对冬小麦进行较长时间预测, 会由于输入信息的不足而造成预测精度下降, 因此本研究建立的 LAI 预测模型选取了相对适宜的预测天数, 即通过前 N 天的 LAI 数据来预测未来 $N+1 \sim N+15$ 共 15 d 的 LAI。此外, 因不同气象条件下冬小麦物候会有差别, 所以将 t 时刻的 LAI 所对应的 DOY _{t} 也作为输入特征, 同时为保证输入特征具有一致性, 将特征进行归一化缩放至 0~1 之间。如图 5 所示, 建立的预测模型采用多层 LSTM 结构, LSTM 层数设置为 3 层, 每层隐藏神经元个数 h 设置为 32 个, 时间步长设定为 N , 时刻为 t 的输入参数为二元组 (LAI_t, DOY_t) , 该模型的最终输出为 $y' = \{LAI'_{N+1}, LAI'_{N+2}, \dots, LAI'_{N+15}\} \in R^{15}$ 。

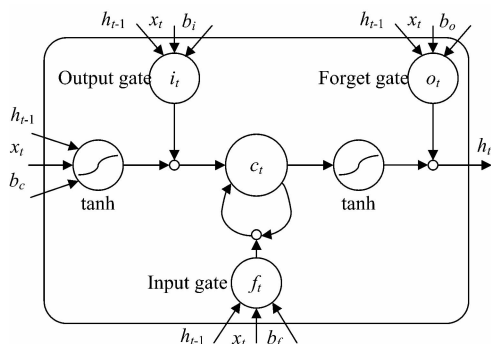


图 4 LSTM 单元结构
Fig. 4 LSTM cell structure




图 5 基于 LSTM 的 LAI 预测模型
Fig. 5 LSTM architecture of LAI prediction model

在最后时刻 N 时, 通过 3 层 LSTM 结构的输出为 $h_N \in R^{32}$, 之后通过连接一个全连接层即可到预测结果 y' , 其计算公式如式(7)所示。

$$y' = W_y h_N + b_y \quad (7)$$

其中 $W_y \in R^{15 \times 32}$ 为权重矩阵, $b_y \in R^{15}$ 偏置向量。

在模型训练过程中, 优化算法采用 Adam, 损失函数采用平方损失函数 L , 如式(8)所示。

$$L = \sum_{t=N+1}^{N+15} (LAI'_t - LAI_t)^2 \quad (8)$$

其中 LAI'_t 和 LAI_t 分别为 t 时刻预测模型对 LAI 的预测值

以及对应标签值。

2 结果与讨论

2.1 LAI 预测模型精度分析

冬小麦在出苗到返青阶段其 LAI 较低, 直到返青后 LAI 才开始明显变化。研究区域冬小麦大约三月份开始返青, 故采用 2003 年—2016 年冬小麦数据集中从 3 月 1 日到成熟阶段共 232 条 LAI 曲线作为训练数据, 并利用 2017 年 15 条 LAI 数据进行验证, 通过取 $N=5, 10, 15, 20, 25$ 和 30 共训练了 6 个 LAI 预测模型, 并对不同的模型结果进行对比分析。

如图 6 所示, 将验证数据切割为 35 d 的 LAI 曲线集合, 其中前 20 d 作为输入数据, 后 15 d 作为标签数据, 利用 $N=20$ 的 LAI 预测模型进行预测。结果显示, 模型预测 $LAI < 2.5$ 以及 $LAI > 5.5$ 的精度较高, 预测值与标签值均在 1:1 线附近。当 $2.5 \leq LAI \leq 5.5$ 时, 相比前两种情况预测精度稍低, 可能是因为不同生长条件下冬小麦返青和开花时间不同, 其对应 LAI 上升和下降阶段中 LAI 变化具有较大的差异。




图 6 $N=20$ 的 LAI 预测模型预测结果

Fig. 6 Results of LAI prediction model with input $N=20$

如表 2 所示, 对 6 个 LAI 预测模型的预测结果综合进行对比, 其中 $N=20$ 的预测模型的 R^2 (0.986 5) 最高、RMSE (0.183 6) 最低, 精度优于其他预测模型, 而 $N=5$ 的预测模型精度最差。当模型 LAI 输入长度从 5 增加到 20 时, 其 R^2 呈上升趋势, RMSE 呈下降趋势, 这是由于更多 LAI 信息输

表 2 6 个 LAI 预测模型预测结果精度对比

Table 2 Comparison of experiment results from LAI prediction models

	LAI 输入长度(N)					
	5	10	15	20	25	30
R^2	0.982 7	0.982 9	0.983 6	0.986 5	0.984 8	0.985 4
RMSE	0.205 2	0.204 4	0.202 0	0.183 6	0.190 7	0.189 3

入使得 LAI 预测精度提高。当模型 LAI 输入长度继续增长时,精度开始下降,可能是因为离预测日期太远的 LAI 对于预测 LAI 贡献作用小,反而有可能引起数据干扰的效果。

2.2 不同生育期冬小麦 LAI 预测精度对比

在冬小麦生长过程中,不同生育期的冬小麦 LAI 的变化存在区别,因此 LAI 预测模型对于处于不同生育期的冬小麦预测精度存在差异。通过将冬小麦生长大致分为返青至拔节(3月1日—4月15日)、拔节至抽穗(4月16日—5月10日)、抽穗至成熟(5月11日—结束)三个阶段,利用训练好的 6 个

预测模型对这三个阶段进行精度分析。

如表 3 所示,在返青到拔节期, $N=30$ 的预测模型精度最高;在拔节至抽穗期, $N=25$ 的预测模型精度最高;在抽穗至成熟期, $N=20$ 的预测模型精度最高。由此可见,不同 LAI 输入长度的预测模型对于不同生育阶段的预测精度并不一致。在返青到拔节期,随着 N 值的增大, LAI 预测模型的精度不断提高,在后两个阶段中,随着 N 值增大,预测精度先提高后下降。

表 3 不同生育阶段中 6 个 LAI 预测模型预测结果精度对比

Table 3 Comparison of experiment results from LAI prediction models in different stages

不同生育阶段		LAI 输入长度(N)					
		5	10	15	20	25	30
返青至拔节	R^2	0.988 1	0.987 2	0.990 6	0.990 5	0.991 7	0.992 3
	RMSE	0.126 4	0.118 2	0.104 3	0.106 1	0.099 7	0.092 1
拔节至抽穗	R^2	0.990 2	0.990 9	0.990 4	0.991 6	0.992 7	0.992 4
	RMSE	0.161 3	0.153 3	0.168 7	0.156 5	0.137 2	0.150 3
抽穗至成熟	R^2	0.934 4	0.936 3	0.938 5	0.950 4	0.939 5	0.943 7
	RMSE	0.230 6	0.233 0	0.223 2	0.201 0	0.219 9	0.212 8

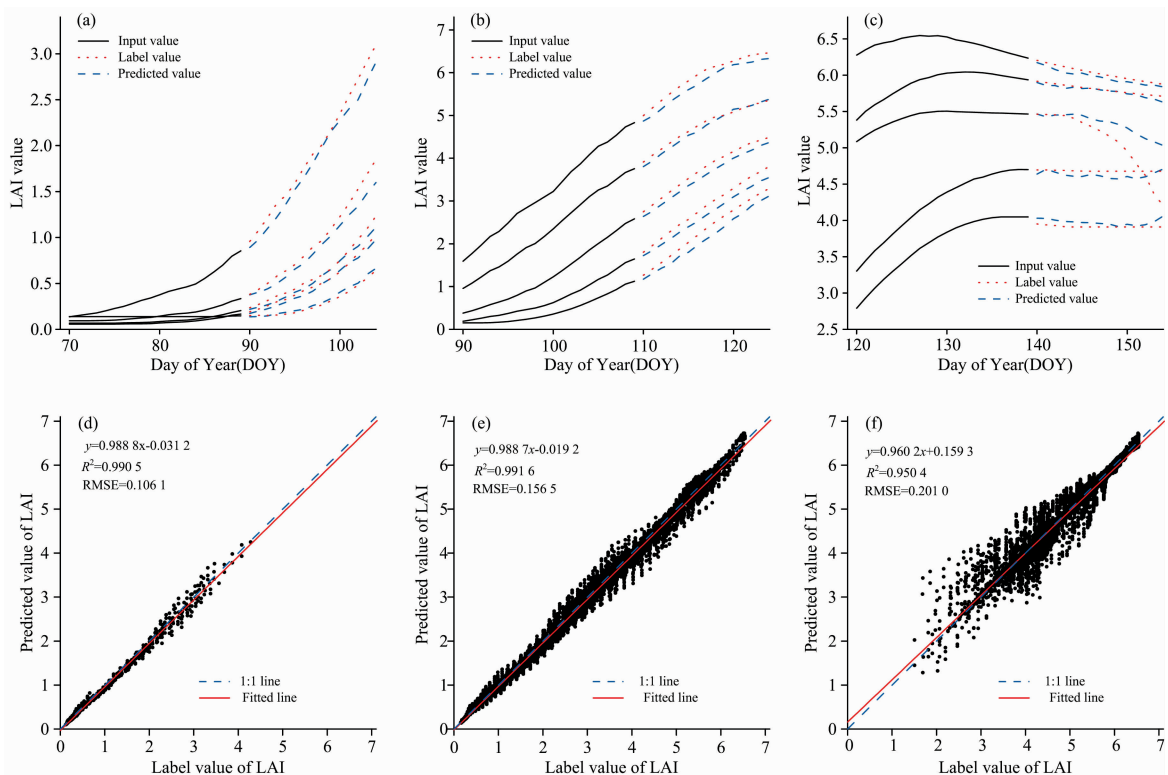


图 7 不同生育期中 $N=20$ 的 LAI 预测模型预测结果

(a): 返青至拔节期的标签与预测 LAI 曲线; (b): 拔节至抽穗期的标签与预测 LAI 曲线; (c): 抽穗至成熟期标签与预测 LAI 曲线; (d): 返青至拔节期标签与预测 LAI 值对比; (e): 拔节至抽穗期的标签与预测的 LAI 值对比; (f): 抽穗至成熟期标签与预测 LAI 值对比

Fig. 7 Results of LAI prediction model with input $N=20$ in different stages

(a): Label and predicted LAI curves from returning green to jointing; (b): Label and predicted LAI curves from jointing to heading; (c): Label and predicted LAI curves from heading TO maturity; (d): Comparison of Lable and predicted LAI value from returning green to jointing; (e): Comparison of lable and predicted LAI value from jointing to heading; (f): Comparison of lable and predicted LAI value from heading to maturity

如图 7(a), (b)和(c)所示, 在三个阶段分别抽取 5 条差异较大的 LAI 曲线, 截取 DOY 分别为 70~89, 90~109 和 120~139 的 LAI 曲线作为模型输入得到预测结果, 可见模型预测结果与标签值吻合且趋势一致。如图 7(d)所示, 在返青至拔节期, 低值 LAI 比高值 LAI 预测准确度高, 可能是由于刚返青时 LAI 的增长速率低, 而返青后 LAI 增长速率变快, 模型对其 LAI 快速变化的捕捉能力不足。如图 7(e)所示, 在拔节至抽穗期, 由于该阶段冬小麦 LAI 变化较为平缓, 预测结果基本处于 1:1 线附近, 模型对其模拟的精度高。如图 7(f)所示, 在抽穗至成熟期, 高值 LAI 比低值 LAI 预测准确度高, 可能是由于在抽穗至开花阶段冬小麦 LAI 处于高值且变化平缓, 在开花期后 LAI 迅速下降, 而模型捕捉冬小麦开花时间节点的能力并不理想, 预测精度出现下降。因此, LAI 预测模型对于返青至开花阶段预测精度较高, 前期 LAI 曲线预测的高精度性对于冬小麦前期田间管理和生产具有重要作用。

3 结 论

采用的冬小麦 LAI 数据集是利用潜在生产力水平下的

WOFOST 模型模拟得到的, 以该数据集为基础构建的预测模型对潜在生产力水平下的冬小麦具有较好的预测效果。然而, 冬小麦的生长发育是一个多环境因子作用的复杂过程, 干旱、病虫害、养分胁迫等因素均会对冬小麦的生长发育造成影响。下一步研究需要结合冬小麦生长发育的影响因素, 对训练数据集进行扩充, 从而提高预测模型的普适性。

本研究利用了数据同化、作物模型与遥感等手段, 构建了京津冀地区近 15 年冬小麦 LAI 曲线数据集, 为解决训练数据难以获取这一难题提供了新的思路, 对深度学习方法在类似问题中的实际应用具有借鉴意义。此外, 还验证了 LSTM 在预测农作物 LAI 时序曲线应用潜力, 对于利用现有热门的深度学习方法解决冬小麦未来长势预测、指导田间管理决策等传统问题具有重要价值。

References

- [1] LIU Yang, LIU Rong-gao, CHEN Jing-ming, et al(刘 洋, 刘荣高, 陈镜明, 等). *Journal of Geo-Information Science(地球信息科学学报)*, 2013, 15(5): 734.
- [2] Campos-Taberner M, Garcia-Haro F J, Camps-Valls G, et al. *Remote Sensing of Environment*, 2016, 187: 102.
- [3] Rembold F, Atzberger C, Savin I, et al. *Remote Sensing*, 2013, 5(4): 1704.
- [4] Dong T, Liu J, Qian B, et al. *International Journal of Applied Earth Observation and Geoinformation*, 2016, 49: 63.
- [5] Marletto V, Ventura F, Fontana G, et al. *Agricultural and Forest Meteorology*, 2007, 147(1-2): 71.
- [6] Xiao Z, Liang S, Wang J, et al. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(1): 209.
- [7] Chen B, Wu Z, Wang J, et al. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, 102: 148.
- [8] Kim Y, Roh J H, Kim H Y. *Sustainability*, 2017, 10(1): 34.
- [9] Rußwurm M, Körner M. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2017, 42: 551.
- [10] Ma G, Huang J, Wu W, et al. *Mathematical and Computer Modelling*, 2013, 58(3-4): 634.
- [11] Huang J, Tian L, Liang S, et al. *Agricultural and Forest Meteorology*, 2015, 204: 106.

Prediction of Continuous Time Series Leaf Area Index Based on Long Short-Term Memory Network: a Case Study of Winter Wheat

LONG Ze-hao¹, QIN Qi-ming^{1, 2, 3*}, ZHANG Tian-yuan¹, XU Wei¹

1. Institute of Remote Sensing and Geographical Information System, School of Earth and Space Science, Peking University, Beijing 100871, China
2. Geographic Information Foundation Software and Application Engineering Technology Research Center, Beijing 100871, China
3. Beijing Key Lab of Spatial Information Integration and 3S Application, Beijing 100871, China

Abstract The continuous time series of Leaf Area Index (LAI) can reflect the growth of winter wheat, and the prediction of future LAI is important for guiding agricultural production. The crop growth models, such as the World Food Studies (WOFOST), can predict the future LAI by simulating the growth and development of winter wheat. But the simulation depends on numerous input parameters, such as future meteorological data, which is difficult to obtain. Due to the continuity and regularity of LAI variations of winter wheat, the future LAI can be predicted with historical LAI through deep learning methods. However, deep learning methods require a large number of samples with labels to build training dataset. The scarcity of training dataset limits the application of deep learning methods in practice. To solve the above problems, we used data assimilation framework to combine remote sensing data with WOFOST model and constructed 15-year time series dataset of winter wheat LAI in Hebei province. Shuffled Complex Evolution (SCE) algorithm was applied to minimize difference between corrected MODIS LAI and simulated LAI for optimizing initial parameters of WOFOST. Based on the dataset, multiple LAI prediction models with different input lengths of historical LAI were established by using the Long Short-Term Memory (LSTM). The abilities of different prediction models to delineate LAI variations of winter wheat were evaluated. Results showed that the LSTM-based models can predict the future LAI of winter wheat effectively. The prediction model with an input length of 20 days achieved the highest accuracy, and RMSE of the prediction model were 0.986 5 and 0.183 6 after winter wheat returned green. For different stages of winter wheat growth, the accuracy was higher before winter wheat bloomed and reduced slightly after winter wheat bloomed. Therefore, it could be concluded that the method of constructing training dataset proposed in this study could be a reference for the application of deep learning methods in similar problems. The prediction models built in this study also verified the effectiveness of the LSTM, which provided a helpful way for predicting the future LAI of crops.

Keywords Leaf area index; Long short-term memory; World food studies; Data assimilation; MODIS LAI remote sensing image

(Received Jan. 6, 2019; accepted Apr. 21, 2019)

* Corresponding author