

Preof canopy leaf area in hydroponic lettuce based on bidirectional TCN-BiLSTM

Fei Hu Liangcheng Xiao Ling Luo Xiubo Gong Ying Zhang

Chongqing Chongqing Institute of International Business and Economics, Chongqing, 401520, China

Abstract

In view of the problem of real-time monitoring of nutrient solution concentration, this study proposed a hybrid architecture of two-way temporal convolution network (BiTCN)) and bidirectional long-way short-term memory network (BiLSTM) (Temporal Convolutional Network-Bidirectional Long Short-Term Memory). Among them, BiTCN uses void convolution to expand the receptive field, alleviates the gradient disappearance through residual connection (Residual block), and the BiLSTM layer analyzes the local temporal dynamic features. The output of the two types of modules is weighted and integrated by the attention mechanism. The genetic algorithm is introduced to optimize the hyperparameters, and the projection area of the canopy is predicted combined with the temporal data of illumination intensity. With the Stanley plant hydroponic special nutrient solution, the lettuce growth parameters were obtained by setting the gradient concentration test, and the growth environment data and growth index data set were constructed. The test shows that the model determination coefficient (R^2) reaches 0.91 and the improved TCN-BiLSTM model improves by 0.19 compared with the conventional LSTM model.

Keywords

home hydroponic lettuce; canopy projection area; TCN-BiLSTM model

基于双向 TCN-BiLSTM 的水培生菜冠层叶面积预测研究

胡飞 肖良成 罗玲 龚秀波 张英

重庆对外经贸学院, 中国 · 重庆 401520

摘 要

针对家庭水培生菜营养液浓度实时监测依赖人工经验的问题,本研究通过建立叶面积-营养液浓度耦合关系,本研究提出双向时间卷积网络 (BiTCN) 与双向长短期记忆网络 (BiLSTM) 的混合架构 (Temporal Convolutional Network-Bidirectional Long Short-Term Memory)。其中, BiTCN采用空洞卷积扩展感受野,通过残差连接 (Residual block) 缓解梯度消失, BiLSTM层则解析局部时间动态特征。两类模块的输出经注意力机制加权融合后输入全连接层,引入遗传算法优化超参数,结合光照强度时序数据预测冠层投影面积。以史丹利植物水培专用营养液为对象,通过设置梯度浓度试验获取生菜生长参数,构建生长环境数据和生长指标数据集。试验表明,模型决定系数 (R^2) 达0.91改进后的TCN-BiLSTM模型较传统LSTM模型提升0.19。

关键词

家庭水培生菜; 冠层投影面积; TCN-BiLSTM模型

1 引言

在资源日益紧张、土壤退化的背景下,传统土质栽培方式显现出弊端^[1]。农业技术飞速发展,从蔬菜大棚到营养液水培的植物工厂,栽培系统逐渐向微型化、立体化发展,而家庭室内和阳台水培正适应这一发展趋势。这种方式不仅能满足人们观赏需求,还可提升城市的生态环境、净化空气,

并满足自给绿色蔬菜等需求。近年来,关于家庭水培食用和药用植物以及家庭菜园设计等研究不断涌现。通过采用营养液水培方式取代传统土质栽培,不仅有效应对化学农药引发的污染问题,提升作物的安全性,还更有利于实现自动化管理、提高果蔬品质和观赏作物效率。因此,研究简化家庭水培种植方式,提高生产质量,使非专业人员也能轻松进行水培栽培,是非常有必要的。

营养液的用量是影响生菜生长的关键因素,适量的营养液对维持生菜叶片健康至关重要。低浓度的营养液会抑制植物生长,而高浓度则可能损害叶片和根系,并增加环境问题和生产成本。因此,对营养液的最佳用量进行深入研究显得尤为重要。家庭水培系统是在家庭环境中利用补光灯与自然光进行水培,控制作物生长微环境,实现蔬菜高效培育的

【基金项目】自然科学基金项目: 基于营养液浓度差异的家庭水培生菜分级模型构建与应用研究 (项目编号: KYZK2024048)。

【作者简介】胡飞 (1999-), 男, 中国四川渠县人, 硕士, 软件设计师, 从事农业信息化研究。

小型设施。此系统多用于栽培叶菜，兼具家庭蔬菜生产和调节心情的功能。其中，光照、温度和营养液的浓度是影响蔬菜品质的关键因素。当作物受到不利条件的影响，其正常生长便会受阻。因此，通过深入研究生菜的最佳营养液浓度需求，制定科学的营养管理计划，对提高作物产量至关重要^[2]。

2 相关研究

时间序列分析与预测在多个领域具有不可或缺的研究价值，如智能农业、金融预测、异常预测、医学成像以及空气污染预测等^[3]。随着人工智能的迅猛发展，深度学习技术已被广泛应用于社会的各行各业。相较传统的分析模型，其具备精准预测未来数据的显著优势，特别是在农业领域发挥着重要作用。由于植物系统高度复杂且动态多变，植物生长动态建模面临诸多的挑战，尤其是数据变化巨大，涉及生长规模、描述水平及环境参数等多个方面。当前农业研究的焦点在于如何通过往年农作物产量数据预测今年产量，通过生长环境预测作物未来生长情况，以及借助作物图像数据预测未来生长状况，从而实现提前控制影响作物生长的因素，优化作物生长条件。在这一领域，深度学习（DL）模型在作物管理和植物生长分析等农业任务中取得显著进展。

在农业科研领域，特别是生菜的营养液调配及生长预测的研究仍然较为稀缺。为此，本研究拓宽了视野，深入探讨了叶菜类蔬菜在此领域的应用潜力，并吸取了其他植物研究的经验教训。与室外农作物研究不同，温室作物生长预测对于神经网络的应用显得尤为关键。通过实时监测并调整温室内的环境参数，可以精确地操控作物生长^[4]。利用人工智能技术，可以实现对茎长、叶数、植株重量等生理指标的精准测量，进而实现作物生长的科学管理^[5]。温室的环境与作物的生长息息相关，Rizkiana A 等人^[6]认为植物生长是独特的，受到环境条件和营养供应等内外部因素的影响。在生产周期中，考虑环境条件和初始植物高度来估计植物生长对于植物管理是必要的。为了应对这一挑战，提出通过应用弹性

反向传播神经网络方法，预测受控环境下生菜的株高增长，揭示了营养液电导率为影响生菜生长的关键因素。但该研究所采用的单一评价标准限制了模型预测效果的全面评估。在另一方面，作物生长预测研究大多依赖高质量的图像数据，但是在复杂环境条件下，图像数据获取困难。因此，Zhu Hua ji^[7]在幼苗移栽时间预测研究里，建立了基于 DCNN-LSTM 的高精度作物生长预测模型，采用 RMSE、MAPE、SMAP 评价指标对模型进行评价，展现了深度学习技术在精准农业中的应用前景。但是现有研究往往局限于单一环境条件下的生长预测，缺乏对不同生长环境的广泛验证。现有的温室无土培养中，营养液是由溶液的 EC（电导率）值控制的。营养液的 EC 受生长环境和作物生长的双重影响，因此 Moon Taewon 等人使用 LSTM 网络模型对封闭的无土培养的营养液的 EC 值进行预测，希望通过该模型实现营养液的计划调控，减少资源浪费^[8]。

本研究结合了双向 TCN 结构和 BiLSTM 模型，能够充分提取时间序列数据的特征，并有效处理长期数据依赖问题。通过引入遗传算法优化超参数，模型的预测精度得到了显著提升。该模型能够根据当前的营养液浓度和光照参数，预测对应生菜的冠层投影面积。

3 材料和方法

3.1 数据采集

在 2023 年 3 月至 11 月期间，于大理大学工科楼实验室通过水培生菜最佳浓度栽培试验，采集了共 16 个有效样本，每个样本包含了移栽后 1 到 20 天营养液浓度参数、光照参数和生菜冠层投影面积及其他生长指标，累计收集 320 条数据记录。选用营养液浓度及光照作为生长预测模型的输入特征，这 6 个关键因素分别为：营养液的 PH（酸碱度）、TDS（溶解性总固体）、EC（电导率）、水温、光照强度、色温。表 3.1 和 3.2 分别展示了一个样本的生菜生长指标、冠层投影面积和营养液浓度及光照参数部分信息。

表 3.1 生长指标和冠层投影面积数据示例表

时间（天）	平均株高（mm）	平均最大叶宽（mm）	平均最大叶长（mm）	平均冠层投影面积（cm ² ）
1	49.72	14.89	49.22	5.11
2	49.22	17.29	51.22	6.15
3	48.22	19.74	47.47	7.62
4	43.77	25.83	52.97	10.13
5	51.42	23.35	53.77	10.87
6	56.17	24.12	61.47	12.11

表 3.2 营养液及光照参数示例表

时间（天）	光照强度（lx）	色温（K）	pH 值（pH）	TDS 值（ppm）	EC 值（us/cm）	水温（℃）
1	1950.7	5912	9.1	378	189	13.9
2	4163.6	5929	9.2	376	188	15.7
3	2670	6083	9.3	380	190	15.5
4	2834.4	5992	9.3	386	193	14.8
5	2696	6008	9.4	382	191	16.3
6	3638.6	5086	9.7	370	185	18.4

为了提高模型的泛化能力，本文实验中进行了如下两个步骤的预处理：第一，通过滑动窗口技术对数据集进行了增强，这一方法不仅增加了训练数据量，而且通过引入更丰富的上下文信息，进一步提高了模型的性能。数据集随机划分为训练集和测试集，其中 75% 的数据用于训练，剩余 25% 用于测试，训练集在增强后总共包含 4420 条数据。第二，为了加速网络的收敛并消除数据特征间的量纲差异，本研究采用最大最小标准化方法对所有输入输出数据进行归一化处理，将数值范围统一调整至 [0,1] 之间。采用了如下函数来实现这一转换：

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (3.1)$$

其中， x 代表原始数据值， $\min(x)$ 和 $\max(x)$ 分别代表数据中的最小值和最大值，而 x' 是归一化后的结果。这一步骤通过对数据进行标准化或归一化，确保所有特征都在相同的尺度上，从而使模型训练时有一个均衡的数值基础。

3.2 模型设计

传统的特征预测算法往往依赖于单一的模型或方法，而在处理复杂、多变的数据时，其效果往往不尽如人意。为了精准预测生菜冠层投影面积，本章设计了一种针对生菜冠层投影面积预测中输入营养液浓度以及光照相关因素的作物生长模型，该模型融合了双向时序卷积网络（TCN）和双向长短期记忆网络（BiLSTM），命名为双向 TCN-BiLSTM，结构详见图 3.1。此网络能够更好地捕捉数据中的时序信息和特征依赖关系，提高预测的准确性和稳定性。此外，针对作物生长预测模型中超参数选择的难题，本研究采用了遗传优化算法进行细致探索，以确定最佳参数组合，进一步优化了预测性能。




图 3.1 双向 TCN-BiLSTM 网络结构示意图

双向 TCN-BiLSTM 模型主要由 TCN 网络、BiLSTM 网络以及部分全连接神经网络组成。其中，双向 TCN 部分主要负责营养液参数和光照因素的关键信息提取，该部分的输出作为后续 BiLSTM 网络的输入，最后得到对应时间下的冠层投影面积。

4 物生长预测模型结果分析

4.1 实验设置

4.1.1 模型配置

在双向 TCN-BiLSTM 模型中两次的自循环使计算更为复杂，参数量也更多。在此基础上，需要用遗传算法确定的超参数中膨胀卷积的扩展率、卷积和 BiLSTM 的神经元以及最后全连接层的神经元。遗传算法需要遍历整个解空间，计算量较大，因此，设置算法迭代次数为 50 次，最后得到模型参数配置如表 4.1 所示。在优化策略方面，本文采用了 Adam 优化器方法对模型参数进行更新。这些优化策略有助于加快模型的训练速度，并提高模型的收敛性能。

表 4.1 模型参数配置

层名称	激活函数	参数	输出维度
输入			(20, 6)
双向 TCN	relu	filters(100) kernel_size(5 × 5) dilation_rate([1, 3, 9, 18, 27])	(20, 64)
BiLSTM	tanh	hidden_size(100)	(20, 120)
全连接层	linear	units(32)	(20, 32)
		units(1)	(20, 1)

4.1.2 评价指标

为了评估模型的预测性能，本文采用了均方根误差（RMSE）作为损失函数。通过最小化 RMSE，模型能够学习到数据中的真实分布，从而提高预测的准确性。时间序列预测模型本质上是构建一个从输入到输出的映射关系，可以利用回归模型的指标来评估模型的性能表现。设模型的预测值为 y' ，观测值为 y 。均方根误差（RMSE）用于评价误差的绝对值大小，能直观地反映模型的预测精度，其定义如下：

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y'_i - y_i)^2}{N}} \quad (4.1)$$

决定系数 R^2 用于评估拟合模型对于实际观测值的解释程度，同时也可用于描述模型与实际观测值之间的相关性。其定义如下：

$$R^2 = 1 - \frac{\sum_{i=1}^N (y'_i - y_i)^2 / N}{\sum_{i=1}^N (y_i - \bar{y})^2 / N} \quad (4.2)$$

平均绝对误差（MAE）用于衡量模型的预测值与实际观测值之间的平均绝对差异。其计算方式是对预测误差取绝对值，然后求取这些绝对值的平均值。MAE 的定义如下：

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (4.3)$$

其中， n 是观测值的数量， y_i 是第 i 个观测值， y'_i 是对应的模型预测值。MAE 越小，表示模型的预测与实际观测值之间的平均差异越小，即模型的性能越好。

4.2 生长预测模型精度验证

为了评估生菜生长预测模型的准确性，本研究根据表

4.1 所述的结构对数据集进行了训练，数据集划分遵循了之前数据集构建的结果。模型训练的误差曲线显示在图 4.1 中。其中，RMSE 值衡量了误差的归一化程度。模型在每个训练周期结束时分别对训练集与验证集进行评估。结果显示训练误差在 10 轮训练后基本保持稳定，验证集误差同样保持低水平且模型的验证误差均小于训练误差。该结果的原因可能是训练集数据与测试集数据的特征基本一致，表明模型对未见数据具有良好的预测性能。

图 4.2 展示了双向 TCN-BiLSTM 模型对选定四个样本的预测能力，尤其是在移栽后的 1 至 8 天内，模型预测的冠层投影面积与真实值高度吻合。尽管偶尔出现一些峰值误差，但模型成功捕捉了整体趋势，显示了较高的预测精度。在图 4.3 与表 4.2 中将本模型与其他几种模型在测试集上的表现进行了比较，揭示了通过将每日环境参数（如 pH、TDS、EC、水温、光照强度和色温）作为输入的本模型能够精确预测生菜的冠层投影面积。在本研究中，模型的均方根误差(RMSE)为 5.96cm^2 ，平均绝对误差(MAE)为 3.92cm^2 。实验结果表明本模型的预测效果显著优于其他模型。

尤其值得注意的是，双向 TCN-BiLSTM 模型在追踪生菜生长曲线，特别是对前三个样本的预测中展现出了其出色的预测能力。然而，面对数据中的关键转折点，其他模型的预测表现存在显著差异，特别是在预测显著变动时期。例如如图 4.3 所示的移栽后 15 至 20 天内，多数模型均展现出了滞后现象。相比之下，尽管本模型在某些特定情况下也未能完美预测样本的具体转折趋势，但它在整体上仍能较为准确地反映出数据变化的趋势，这体现了其在处理时间序列数据方面的强大潜力。

本文所建立的模型在预测冠层投影面积时展现出了较

高的预测精度。这一精度的提升主要得益于充分考虑了营养液浓度和光照因素对水生菜生长的影响。将这些环境因素纳入模型考虑范围，使得预测结果更为准确。同时，模型采用了双向 TCN 网络作为特征提取结构，这使得模型能够提取更多有用的信息，并且还能保留这些信息之间的时序关系，从而进一步提高了预测精度。




图 4.1 模型训练曲线

表 4.2 所有模型在 3 个评价指标上的表现

模型	RMSE(cm^2)	MAE(cm^2)	R ²
双向 TCN-BiLSTM	5.96	3.92	0.91
TCN	10.03	6.27	0.74
Transformer	10.71	6.46	0.70
LSTM	10.26	6.60	0.72
RNN	10.63	6.71	0.70




图 4.2 测试集中四个样品冠层投影面积的预测结果




图 4.3 所有模型对冠层投影面积预测的结果




图 4.4 预测样本与最佳浓度组的冠层投影面积对比

4.3 模型作用

本研究旨在构建一个生长预测模型，该模型通过综合考虑多个参数（包括 pH 值、TDS 值、EC 值、水温、光照强度、色温和时间）来预测水培生菜的冠层投影面积。这种模型对于水培生菜的栽培至关重要，它使得非农业专业人员能够更深入地理解和精确控制生菜的生长过程。

鉴于双向 TCN-BiLSTM 模型在先前章节中展现的出色预测精度，相较于其他模型有着明显的优势，所以决定利用此模型进行实时预测。通过该模型可以在生菜移栽后根据实测环境参数即时预测生菜的冠层投影面积，并将这些预测值与试验中确定的最佳营养液浓度下的冠层投影面积进行比较。如图 4.5 所示，比较结果表明预测的样本并未处于最佳营养液浓度环境下，提示需要对营养液浓度进行及时调整。

通过这种方法，不仅能够优化生菜的生长条件，还能水培栽培技术的进步和精准农业实践给予坚实的支持和深厚的理论基础。

5 结论

本文首先介绍了双向 TCN-BiLSTM 生长预测模型的构建，接着阐述了双向 TCN 在特征提取方面的优势，并通过结合 BiLSTM 技术和遗传算法优化超参数，实现了对生菜冠层投影面积的有效预测。然后利用构建的包含营养液浓度、光照条件及冠层投影面积的数据集进行对比实验。实验结果显示，双向 TCN-BiLSTM 在生菜冠层投影面积预测问题上的表现出色。所以基于本模型的预测结果可以用于与栽培试验中确定的最佳浓度处理下的冠层投影面积进行对比分析，以准确评估当前营养液浓度是否合适。

参考文献

- [1] 计雪伟, 霍兴赢, 薛端, 等. 基于神经网络的农作物产量预测方法[J]. 南方农机, 2022, 53(02): 36-38.
- [2] Shabani E. Improving the growth, P uptake and quality characteristics of 'Lollo Rosso' lettuce in the nutrient solution by *Bacillus subtilis* in different phosphorus concentrations[J]. Journal of Plant Nutrition, 2023, 46(6): 971-983.
- [3] Li Q, Gao H, Zhang X, et al. Describing Lettuce Growth Using Morphological Features Combined with Nonlinear Models[J]. Agronomy, 2022, 12(4): 860.
- [4] 张向君, 陈优良, 肖钢. 基于机器学习的农作物产量预测研究综述[J]. 安徽农学通报, 2021, 27(03): 117-119+134.
- [5] 周瑞, 魏正英, 张育斌, 等. 基于LSTM递归神经网络的番茄目标产量时间序列预测[J]. 节水灌溉, 2018, (08): 66-70.
- [6] Rizkiana A, Nugroho A P, Salma N M, et al. Plant growth prediction model for lettuce (*Lactuca sativa*.) in plant factories using artificial neural network[C]//IOP Conference Series: Earth and Environmental Science. IOP Publishing, 2021, 733(1): 012027.
- [7] Zhu H, Liu C, Wu H. A prediction method of seedling transplanting time with DCNN-LSTM based on the attention mechanism[J]. Agronomy, 2022, 12(7): 1504.
- [8] Moon T, Ahn T I, Son J E. Forecasting root-zone electrical conductivity of nutrient solutions in closed-loop soilless cultures via a recurrent neural network using environmental and cultivation information[J]. Frontiers in Plant Science, 2018, 9: 328105.