

基于LSTM的作物需水量预测模型研究

孙博瑞, 蒋 敏, 薛 山

塔里木大学, 新疆 阿拉尔

收稿日期: 2021年12月22日; 录用日期: 2022年1月19日; 发布日期: 2022年1月26日

摘要

为了提高作物需水量的预测精度, 提出基于LSTM (长短时记忆网络)的作物需水量预测模型。模型以空气温湿度、风速、日照时数为特征输入值, 作物需水量为标签输出值, 以枣树为试验对象, 进行了相关预测试验, 并将预测结果与RNN模型, FCNN模型的准确性进行了对比分析, 结果表明LSTM预测模型的精确程度更高, 该方法在节水灌溉领域具有一定的研究意义。

关键词

预测精度, 作物需水量, LSTM预测模型, 节水灌溉

Research on Forecast Model of Crop Water Demand Based on LSTM

Borui Sun, Min Jiang, Shan Xue

University of Tarim, Alar Xinjiang

Received: Dec. 22nd, 2021; accepted: Jan. 19th, 2022; published: Jan. 26th, 2022

Abstract

In order to improve the prediction accuracy of crop water demand, a crop water demand prediction model based on LSTM (Long Short-term Memory Network) is proposed. The model uses air temperature and humidity, wind speed, and sunshine hours as the characteristic input values, and the crop water demand is the label output value. Jujube tree is the test object, related prediction experiments are carried out, and the prediction results are compared with the accuracy of the RNN model and FCNN model. The results show that the accuracy of the LSTM time series model is higher. This method has advantages in the field of water-saving irrigation.

Keywords

Prediction Accuracy, Crop Water Demand, LSTM Prediction Model, Water-Saving Irrigation

Copyright © 2022 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

水是农业、国民经济乃至人类生活的命脉，我国是一个水资源严重不足的国家，人均水资源占有量仅相当于世界水平的 1/4，是世界上人均水资源最匮乏的 13 个国家之一。而农业用水量大约占全国用水量的 70%，但有效利用率仅为 40% 左右[1]。因此准确预测作物的需水量，根据预测结果对作物进行指导灌溉在农业节水工作中具有重要的意义。

作物需水量即蒸发蒸腾量是农业水资源开发利用中必不可少的基本资料，作物需水量的预测是灌溉预报的关键[2]。当前作物的需水量主要应用 Penman-Monteith 公式来计算，但因其计算过程较为复杂需要用到的气象数据过多，所以国内外学者利用先进的计算机技术对作物需水量的预测进行了一系列的研究。其中李志新[3]等利用基于遗传算法优化的 Elman 神经网络构建了作物需水量预测模型，并验证了模型的可行性。孟玮[4]等构建了基于人工蜂群径向基神经网络的预测模型。其余还有灰色神经网络、贝叶斯模型、BP 神经网络[5][6][7]等不同模型对作物的需水量进行了预测。目前作物需水量的预测在农业节水方面有着重大的意义。因此本文构建了基于 LSTM 时间序列的作物需水量预测模型，并与其他模型进行了准确性对比分析。

2. LSTM 模型算法

LSTM 指的是长短期记忆神经网络，是循环神经网络 RNN (recurrent neural network) 算法的改进。RNN 相较于传统的前馈型神经网络区别在于其在隐含层上增加了一个反馈连接，能够通过循环反馈连接看到前面所有时刻的信息，并将之前信息的记忆保留在中间的隐藏节点中，从而影响网络的输出[8]。

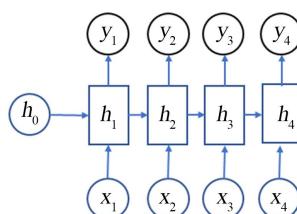


Figure 1. RNN structure diagram
图 1. RNN 结构图

如图 1 所示为序列长度 4 的 RNN 模型经典结构， x 为序列的输入， h 为隐含状态其作用是对序列数据进行特征提取接着再转化为输出 y ，每一个箭头都代表一次 h 到 y 的转换。由于在 RNN 模型中输入和输出序列必须是等长的，这就限制了 RNN 的适用范围，其在训练过程中，如果需要参考的信息距离当前预测任务过远，超过 8~10 个步长后，RNN 可能就会出现梯度消失问题，因此其保存的信息通常为短期信息无法体现其长期的记忆效果。为了解决这一问题，LSTM 长短时记忆网络模型被提出。

长短时记忆网络(Long Short Term Memory Network)通过三个不同的门控制之前信息对当前信息的影响即遗忘门(forget gate); 输入门(input gate); 输出门(output gate) [9]。遗忘门决定上一时刻单元状态, 输入门决定了当前的网络输入, 输出门控制单元的状态, 在每一个时间步 t 中可描述为[10]

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \quad (2)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, X_t] + b_o) \quad (3)$$

式中:

f_t ——遗忘门; i_t ——输入门; o_t ——输出门

σ ——门状态函数

W_f ——遗忘门权重系数; W_i ——输入门权重系数; W_o ——输出门权重系数

h_{t-1} ——LSTM 当前输出值

X_t ——LSTM 当前输入值

b_f ——遗忘门偏置项; b_i ——输入门偏置项; b_o ——输出门偏置项

这些门节点决定了 LSTM 的记忆功能, 当模型需要前面的训练结果影响当前计算的时候, 门节点就会被打开, 反之则将门节点关闭。因此通过调节阀门的开关就可以实现早期序列对最终结果的影响[11], 其结构如图 2 所示。

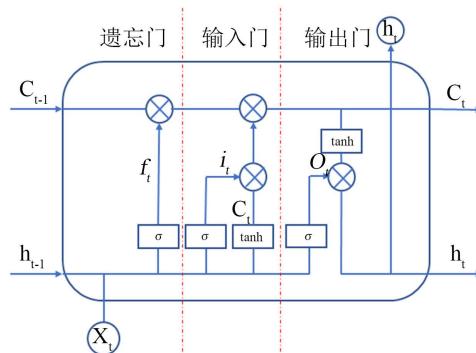


Figure 2. LSTM structure diagram
图 2. LSTM 结构图

LSTM 中, 决定当前时刻网络输出的不仅是这一时刻的输入, 还有上一时刻网络的隐状态和输出状态, 依次循环传递。在这种传递下历史输入的重要信息就会得以保留, 从而达到长期记忆的效果。

3. 模型的构建与结果分析

3.1. 数据来源与预处理

数据采用全国温室系统新疆自治区阿拉尔站点 2014~2017 年的日气象数据, 包括平均气温、平均风速、相对湿度、日照时数和参照蒸发量。其中 2014~2016 年的气象数据作为模型的训练数据, 2017 年的数据作为模型的验证数据。首先根据气象数据由公式(4) [12] 计算出作物的需水量。

$$E_t = K_C \cdot E_{t_0} \quad (4)$$

式中: E_t ——需水量; K_C ——作物系数; E_{t_0} ——参照蒸发量。

试验选取干旱区枣树全年需水量为研究对象，所以萌芽展叶期取 K_C 为 0.86；开花坐果期取 1.36；果实膨大期取 1.22；果实成熟期取 0.83 分别计算出各时期枣树的需水量[13]。将计算得出的需水量分为验证集和训练集两部分，并作为模型的输出值。将空气温度、空气相对湿度、日照时数、风速作为模型的特征值输入。将整理好的数据保存为 csv 格式或 xlsx 格式，部分数据如表 1 所示。

Table 1. Experimental data
表 1. 试验部分数据表

年份	月份	日	平均气温 (°C)	平均风速 (m/s)	相对湿度 (%)	日照时数 (h)	需水量 (mm)
2014	4	1	12.3	1.2	47	11.7	6.7
2014	4	2	14.6	1.5	35	11.5	6.4
2014	4	3	13.6	2.5	38	8.3	6.5
.....
2015	5	8	22	1.1	41	12.3	8.9
2015	5	9	23.2	0.9	41	11.6	8.6
2015	5	10	22.5	3.7	34	3	10.6
.....
2016	6	1	22.2	1.5	50	12.5	4.2
2016	6	2	23.7	1.8	41	11	5.6
2016	6	3	23.6	2	49	11.4	6.5
.....
2017	7	10	30	1.4	46	11.9	6.5
2017	7	11	29.3	3	39	7.3	10.7
2017	7	12	27.9	1.5	36	10.7	6.4

模型在训练前要将试验数据进行预处理操作，读取训练集 2014~2016 三年气象数据的 csv 格式或 xlsx 格式的原始数据文件，得到原始数据集，经过一系列处理，如提取表头、获取特征数据、获取标签数据、获取特征数据最值、归约化特征数据、归约化标签数据、获取标签数据最值、保存预处理数据等操作后得到模型训练使用的数据集。数据预处理运行结果如图 3 所示。

```
D:\Anaconda\python.exe C:/Users/孙博瑞/
npy_minmax saved.
npy saved.
avg_temp shape: (1096, 1)
avg_v shape: (1096, 1)
avg_hum shape: (1096, 1)
sunshine_t shape: (1096, 1)
water shape: (1096, 1)

Process finished with exit code 0
```

Figure 3. Screenshot of the results of the data preprocessing operation
图 3. 数据预处理运行结果截图

以上执行结果表示的含义是各特征和标签的矩阵规模(shape)，数据集的输入特征是合并四个特征后的四维特征，标签是 water 属性，所以 shape 为：(1096, 4)、(1096, 1)，即 2014~2016 三年共 1096 行数据记录，每个数据记录都是 4 维的输入特征和 1 维的需水量标签。预处理后的数据集会自动保存在 npy 文件中，以供模型加载训练。

3.2. 模型的参数设置

由于模型在训练好后需要移植到硬件中运用，而 MATLAB 软件的可移植性较差，所以本模型的构建使用 Python3.7 语言，在 TensorFlow 开发环境下进行。损失函数采用均方差损失函数(Mean Square Error)，其优点为曲线光滑、连续、处处可导，便于使用梯度下降算法。其梯度会随着误差的减小而下降，有利于收敛，用固定的学习速率，也能较快的收敛到最小值。计算公式如公式(5) [14]。

$$\text{MSE} = \frac{\sum_{i=1}^n (f(x_i) - y_i)^2}{n} \quad (5)$$

式中： $f(x)$ ——预测值； y ——目标值； n ——样本个数。

根据本实验的气象数据特点与模型的框架结构，将模型的具体参数值设置如表 2。

Table 2. Parameter settings of the prediction model

表 2. 预测模型的参数设置

模型参数	参数名称	参数取值
epoch	迭代次数	100
Batch_size	每批训练样本容量	128
validation_spli	训练验证集	0.2
Lr	学习率	0.001

3.3. 结果与分析

模型的性能评价指标选择均方误差 MSE，均方误差是指参数的估计值与真实值之差平方的期望值。在模型训练未出现过拟合的情况下，MSE 的值越小，说明预测模型对试验数据的精确度描述越高，模型的性能越优。

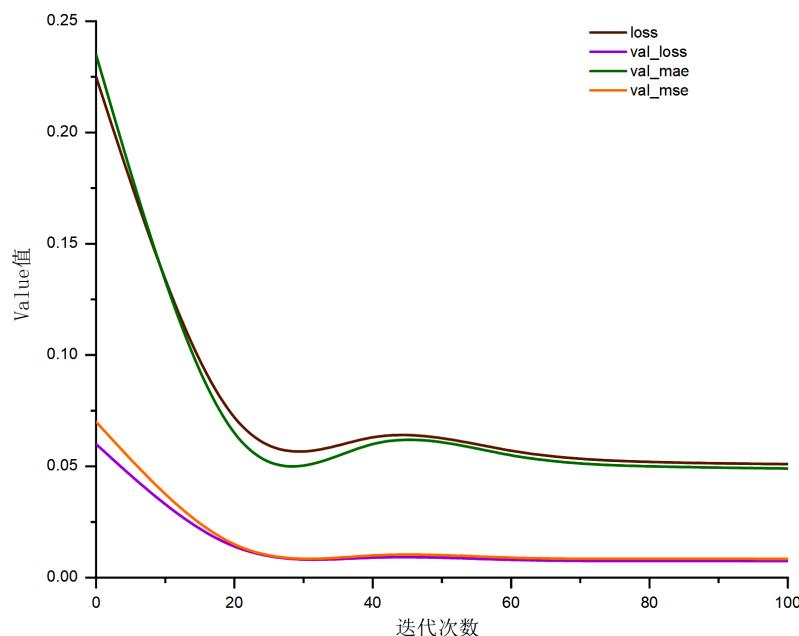


Figure 4. LSTM training index curve

图 4. LSTM 训练指标曲线图

如图 4 所示模型在迭代过程中每个指标曲线整体下降且开始下降快，后来稳定几乎不变说明网络逐步收敛，训练的模型效果较好；Val_ 的损失值保持在和训练集同等的水平且没有曲线上翘说明模型性能较优。

Table 3. Model MSE value**表 3.** 模型 MSE 值

模型	MSE 值
LSTM	0.0032
RNN	0.0044
FCNN	0.0065

在模型未出现过拟合的情况下，由表 3 可知 LSTM 模型的 MSE 值与 RNN 与 FCNN 模型对比最低，所以 LSTM 模型的训练效果较 RNN 与 FCNN 要好，其对试验数据描述的精确度更高。

模型训练好后会生成 h5 文件，为了方便模型的实际应用，编写一个 infer.py 的脚本，运行时可以对训练好的模型直接进行调用。如图 5 模型运行的结果 0.44 即为对应[-6.8, 0.8, 79, 7.4]四个气象数据预测的作物当前需水量，在后期模型投入实际应用后可以利用 sys.argv 代码将传感器采集的气象数据替换成矩阵中，供模型预测当前作物需水量使用。

The screenshot shows the PyCharm IDE interface. On the left is the project tree with files like 'actual.npy', 'avg_hum.npy', 'avg_temp_minmax.npy', 'fcnn.h5', 'infer.py', 'lstm.h5', 'lstmTrainingCurve.png', 'lstmTrainingCurveTotal.png', 'P.npy', 'preprocess.py', 'relative_hum.npy', 'rnn.h5', 'sunshine_t.npy', 'sunshine_t_minmax.npy', 'train.py', 'water.npy', and 'water_minmax.npy'. The main window displays the code for 'infer.py':

```

1 import numpy as np
2 from tensorflow.keras.models import load_model
3 model_name = 'LSTM'
4 validation_split = 0.2
5 val_num = 50
6 # The mode in practical applications should be a given record and the result is not a quantity given record.
7 # 'single' or 'batch'
8 test_mode = 'single' # Default single record mode
9 single_input = [-6.8, 0.8, 79, 7.4] # Corresponding four feature this is the single record to be tested.
10
11 # Loading the most value
12 avg_temp_minmax = np.load("avg_temp_minmax.npy", )
13 avg_v_minmax = np.load("avg_v_minmax.npy", )
14 avg_hum_minmax = np.load("avg_hum_minmax.npy", )
15 sunshine_t_minmax = np.load("sunshine_t_minmax.npy", )
16 water_minmax = np.load("water_minmax.npy", )
17 names = ['avg_temp', 'avg_v', 'avg_hum', 'sunshine_t', 'water']
18 minmax = [avg_temp_minmax, avg_v_minmax, avg_hum_minmax, sunshine_t_minmax, water_minmax]
19
20 load data()

```

The 'Run' tab at the bottom shows the command line output:

```

2021-10-08 21:33:56.99849: I tensorflow/stream_executor/cuda/cuda_diagnostics.cc:169] retrieving LUMA diagnostic information for host: LAPTOP-KJTEP34F
2021-10-08 21:33:56.999018: I tensorflow/stream_executor/cuda/cuda_diagnostics.cc:176] hostname: LAPTOP-KJTEP34F
2021-10-08 21:33:57.000733: I tensorflow/core/platform/cpu_feature_guard.cc:142] This TensorFlow binary is optimized with oneAPI Deep Neural Network Library (oneDNN) to use the following CPU instructions in performance-critical operations: AVX2
To enable them in other operations, rebuild TensorFlow with the appropriate compiler flags.
2021-10-08 21:33:57.002374: I tensorflow/compiler/jit/xla_gpu_device.cc:99] Not creating XLA devices, tf_xla_enable_xla_devices not set
2021-10-08 21:33:58.218418: I tensorflow/compiler/mlir/mlir_graph_optimization_pass.cc:116] None of the MLIR optimization passes are enabled (registered 2)
[0.44320947]

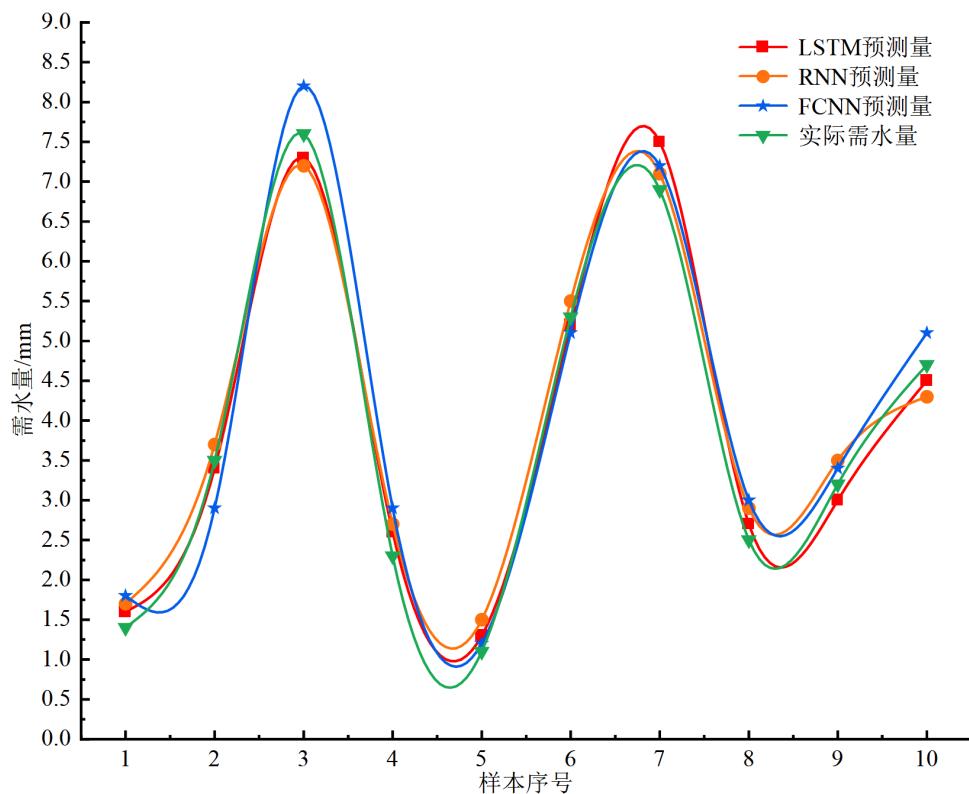
Process finished with exit code 0

```

Figure 5. Model running result graph**图 5.** 模型运行结果图

为了清晰的比较处预测模型的准确性，从验证集 2017 年的数据中随机选取 10 组数据作为预测数据验证。对三种模型的验证结果进行相对误差比较。

由图 6 与表 4 可以看出 LSTM 预测模型的预测结果无论是每一组的相对误差还是平均相对误差相较于其他两种模型都较低，其预测的准确性更高。而且 LSTM 预测模型的误差幅度变化比较小，与 RNN 与 FCNN 比较更适合用于需水量的预测。

**Figure 6.** Comparison of model prediction results**图 6. 模型预测结果对比图****Table 4.** Comparison and analysis table of model predicted values
表 4. 模型预测值对比分析表

样本序号	实际值/MM	预测值/MM			相对误差/%		
		LSTM	RNN	FCNN	LSTM	RNN	FCNN
1	1.4	1.5	1.7	1.8	7.1	21	28
2	3.5	3.4	3.7	2.9	2.8	5.7	17
3	7.6	7.3	7.2	8.2	3.9	5.2	7.8
4	2.3	2.6	2.7	2.9	11	17	26
5	1.1	1.2	1.3	1.2	9	18	9
6	5.3	5.2	5.5	5.1	1.8	3.7	3.7
7	6.9	7.5	7.1	7.2	8.6	2.8	4.3
8	2.5	2.7	2.9	3	8	16	20
9	3.2	3	3.5	3.4	6.2	9.3	6.2
10	4.7	4.5	4.3	5.1	4.2	8.5	8.5
平均相对误差/%					6.26	10.7	13.05

4. 结语

本文以全国温室系统，阿拉尔站点 2014~2017 年的日气象数据为基础，以枣树为研究对象建立了基于 LSTM 的作物需水量预测模型。并对预测结果与 RNN 模型、FCNN 模型进行误差对比分析。在输入

因子相同的情况下，得到 LSTM 预测值与实际值的平均相对误差为 6.26% 低于 RNN 与 FCNN 的 10.7% 和 13.05%，且在模型训练过程中三种模型的 MSE 值分别为 0.0032、0.0044、0.0065 可见 LSTM 模型的预测准确性与模型性能都有优于 RNN 与 FCNN 模型，说明其作为作物需水量的预测模型是可行的，为作物需水量的预测及实现高效节水灌溉提供一定参考。并且该模型在 PyCharm 环境下使用 python 编程语言进行构建相较于文献[5]可移植性高，实用性更好。后期可将训练好的模型移植到上位机硬件中运用，实际指导系统灌溉。在后续的开发试验中可以将实际测得的枣树灌水量替换掉模型中的理论需水量，重新对模型进行训练，以达到更加准确的预测效果。

参考文献

- [1] 孙景生, 康绍忠. 我国水资源利用现状与节水灌溉发展对策[J]. 农业工程学报, 2000(2): 1-5.
- [2] 房军, 方小宇, 吕东玉, 等. 丘陵半干旱区作物需水规律的研究进展[J]. 安徽农业科学, 2006(19): 4847-4849.
- [3] 李志新, 赖志琴, 龙云墨. 基于 GA-Elman 神经网络的参考作物需水量预测[J]. 节水灌溉, 2019(2): 117-120.
- [4] 孟玮, 孙西欢, 郭向红, 等. 基于人工蜂群径向基神经网络预测参考作物需水量[J]. 节水灌溉, 2020(1): 79-83.
- [5] 夏泽豪, 翁绍捷, 罗微, 等. 基于灰色神经网络的作物需水量预测模型研究[J]. 中国农机化学报, 2015, 36(2): 219-223.
- [6] 王景雷, 康绍忠, 孙景生, 等. 基于贝叶斯最大熵和多源数据的作物需水量空间预测[J]. 农业工程学报, 2017, 33(9): 99-106+315.
- [7] 尹京川, 马孝义, 孙永胜, 等. 基于 BP 神经网络与 GIS 可视化的作物需水量预测[J]. 中国农村水利水电, 2012(2): 13-15+18.
- [8] 赵淑芳, 董小雨. 基于改进的 LSTM 深度神经网络语音识别研究[J]. 郑州大学学报(工学版), 2018, 39(5): 63-67.
- [9] Herstinsky, A. (2020) Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network. *Physica D: Nonlinear Phenomena*, **404**, Article ID: 132306.
- [10] 和志强, 杨建, 罗长玲. 基于 BiLSTM 神经网络的特征融合短文本分类算法[J]. 智能计算机与应用, 2019, 9(2): 21-27.
- [11] 孙鹏, 白光伟, 沈航, 等. 基于长短期记忆的流媒体 QoE 预测模型[J]. 计算机工程与设计, 2020, 41(6): 1501-1508.
- [12] 李志磊, 周建平, 魏正英, 张育斌, 许燕. ET_0 预测的卡尔曼滤波修正 ANFIS 模型研究[J]. 干旱地区农业研究, 2017, 35(3): 114-119.
- [13] 王则玉, 谢香文, 刘国宏, 等. 干旱区绿洲滴灌成龄枣树耗水规律及作物系数[J]. 新疆农业科学, 2015, 52(4): 675-680.
- [14] 李昊, 杨国明, 辛靖, 等. 基于神经网络与遗传算法的常压塔顶油气系统腐蚀预测[J]. 石油化工腐蚀与防护, 2018, 35(2): 34-37.