

基于 TensorFlow 的 LSTM 算法在农业中的应用

勾志竟¹, 宫志宏^{2*}, 刘布春³

(1. 天津市气象信息中心, 天津 300074;

2. 天津市气候中心, 天津 300074;

3. 中国农业科学院农业环境与可持续发展研究所, 北京 100081)

摘要:针对如何反映水稻产量与生长周期气象要素的非线性关系,并提高产量预测准确度的问题,提出了在 TensorFlow 深度学习框架上构建长短时记忆网络算法(LSTM)的水稻产量预测方法。该方法避免了传统 BP 神经网络容易陷入局部最优和长期预测精度不高的问题,并以天津市宁河区 1989~2015 年地面气象观测资料与产量数据为基础,选取移栽-返青期、分蘖期、孕穗期、抽穗期、成熟期 5 个不同生长期的风速、日照、温度等 21 个变量作为预测因子,最后以水稻亩产量(kg)作为预测目标进行了实验。结果表明,BP 神经网络预测结果的均方根误差(root mean square error, RMSE)和平均绝对误差(mean absolute error, MAE)分别为 75.12 和 65.64, LSTM 的 RMSE 和 MAE 分别为 34.77 和 33.37,相比 BP 神经网络, LSTM 长短期记忆网络的预测精度更高,可以较好地预测水稻产量的长期发展趋势,为水稻生长期的精准管理和决策提供了新的思路和方法。

关键词:水稻产量;BP 神经网络;LSTM;TensorFlow;预测

中图分类号: TP39

文献标识码: A

文章编号: 1673-629X(2021)08-0215-06

doi: 10.3969/j.issn.1673-629X.2021.08.037

Application of LSTM in Rice Yield Prediction Based on TensorFlow

GOU Zhi-jing¹, GONG Zhi-hong^{2*}, LIU Bu-chun³

(1. Tianjin Meteorological Information Center, Tianjin 300074, China;

2. Tianjin Climate Center, Tianjin 300074, China;

3. Institute of Environment and Sustainable Development in Agriculture, Chinese Academy of Agricultural Sciences, Beijing 100081, China)

Abstract: To solve the problem of how to reflect the nonlinear relationship between rice yield and meteorological factors in the growth period and improve the accuracy of yield prediction, we propose a rice yield forecast method based on the LSTM on TensorFlow deep learning framework, which can avoid the problem of local optimization and low accuracy in long-term prediction in traditional BP algorithm. Then, the ground meteorological observation data and the rice statistical data of Ninghe district in Tianjin from the year 1989 to 2015 were used, and 21 factors were extracted such as wind speed, sunshine and temperature in 5 different growth stages including transplanting-returning green stage, tillering stage, booting stage, heading stages, maturing stage. Finally, the experiment is performed taking the rice yield per acre as the prediction target. It is showed that the root mean square error (RMSE) and mean absolute error (MAE) of BP neural network were 75.12 and 65.64, respectively, the RMSE and MAE of LSTM were 34.77 and 33.37. Compared with BP neural network, LSTM has higher prediction accuracy and can better predict the long-term development trend of rice yield, which can be used as a new method for the precise management and decision making in the growth period of rice.

Key words: rice yield; BP neural network; LSTM; TensorFlow; prediction

0 引言

水稻是中国最主要的粮食作物之一,其产量的预

测对于农业政策调整和保障粮食安全问题具有重要的意义^[1]。由于其受多种因素影响,水稻产量的准确预

收稿日期:2020-09-29

修回日期:2021-01-29

基金项目:天津市气象局重点项目(202019zdxm07);中国农业科学院科技创新工程协同创新任务“新时期国家粮食安全战略研究”(CAAS-ZDRW202012)

作者简介:勾志竟(1989-),男,硕士,工程师,研究方向为大数据、气象数据挖掘;通讯作者:宫志宏(1985-),男,硕士,高工,研究方向为农业气象信息化。

测较为困难。常规的产量预测主要包括基于统计回归原理预测、灰色理论生长模拟^[2]、卫星遥感预测^[3]等方法,这些方法简便易行,可以预测产量。然而,水稻产量与多种因素之间存在着复杂的非线性关系,传统的方法预测精度往往不高,随着基于人工智能方法的不断研究和优化^[4-5],BP 神经网络因其适用于分析产量与影响产量的众多因素之间的复杂非线性关系,在产量预测方面得到较为广泛的应用^[6]。

张成才等^[7]采用播种面积、农田有效灌溉面积、农用机械总动力、化肥施用量、农药施用量等指标建立了 BP 神经网络粮食产量预测模型;姜新等^[8]基于作物参数和农机水平建立了神经网络产量预测模型;郭亚菲等^[9]提出了基于主成分分析和粒子群优化神经网络的粮食产量预测模型。但是这些模型对水稻产量的长期变化趋势预测能力偏弱,同时未能充分考虑生长长期的气象要素对产量的影响。

而长短期记忆网络(long-short term memory, LSTM)作为一种改进的时间循环神经网络,在长时间序列预测问题处理中有独特的优势,在机器翻译、语音识别等方面已经有很多应用^[10-11],但目前鲜有在水稻产量预测中的应用。因此,该文拟基于 TensorFlow 深度学习框架,构建 LSTM 水稻产量预测方法,以水稻不同生长长期的气象要素作为预测因子对水稻产量进行预测,并将预测结果与 BP 神经网络预测模型进行比较,由此探讨 LSTM 在水稻产量长期趋势预测中的优越性,以期可为水稻产量长期趋势预测提供一种新方法。

1 资料与方法

1.1 研究区域概况

天津市宁河区位于 39°21'N, 117°49', 属于大陆性季风气候, 暖温带半干旱半湿润风带, 年均降水量为 500 mm ~ 700 mm, 降水量 70% 集中在 6-8 月份, 地貌属于海积、冲积平原, 土壤含盐分较高^[12]。天津宁河区“小站稻”既有食味特性, 又有良好的耐盐碱特性^[13], 一般在 4 月上旬播种, 5 月底至 6 月上旬移栽, 6 月中下旬进入返青期, 8 月上旬进入孕穗期, 9 月上旬进入乳熟期, 9 月下旬至 10 月中旬成熟。

1.2 数据来源

水稻产量数据和生育期地面气象观测资料来自天津市气象信息中心, 水稻产量数据为宁河区单位面积(每亩)水稻产量(kg), 生育期包括移栽-返青期(周期 1)、分蘖期(周期 2)、孕穗期(周期 3)、抽穗期(周期 4)、成熟期(周期 5)。

地面气象观测资料来自天津市宁河区气象观测站, 包括 1989-2015 年逐日平均风速、最大风速、日照时数、最高温、最低温、平均相对湿度、最小相对湿度及降水量。

1.3 研究方法

LSTM 神经网络最早是由 Hochreiter 等^[14]提出, 是一种改进的 RNN 算法, 增加了忘记门, 可以学习时间序列长短依赖信息, 能够克服梯度消失的问题, 主要由忘记门、输入门、候选门和输出门组成, 其基本结构如图 1 所示。

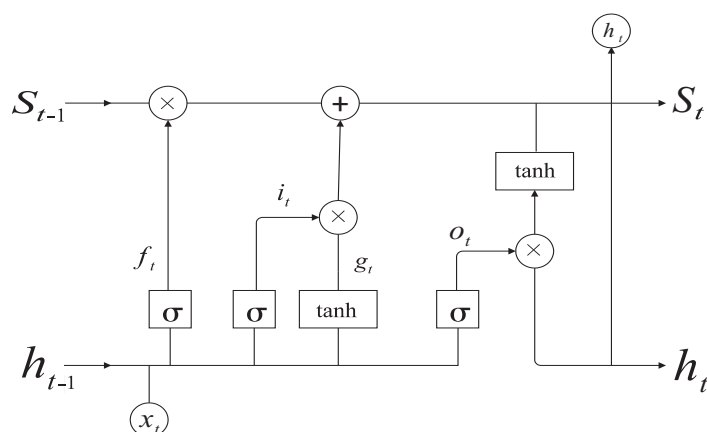


图 1 LSTM 内部结构

忘记门(forget gate layer)控制着应该忘记哪些信息,其计算公式如下所示:

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

其中, W_f 为忘记门权重, h_{t-1} 为上一个单元的输, x_t 为当前单元的输入, b_f 为偏置, σ 为 sigmoid 函数。

输入门(input gate layer)通过激活函数决定着当

前时刻的输入信息 x_t , 有多少信息被加到信息流里面,其计算公式如下所示:

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

$$g_t = \sigma(W_g[h_{t-1}, x_t] + b_g) \quad (3)$$

其中, W_i 、 W_g 为权重, b_i 、 b_g 为偏置。

候选门(candidate layer)用来计算当前的输入和过去的记忆所具有的信息的总和,其计算公式如下

所示:

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (4)$$

$$h_t = o_t * \tanh(S_t) \quad (5)$$

输出门(output gate layer)控制着有多少记忆信息被用于下一阶段的更新中,其计算公式如下所示:

$$S_t = f_t * S_{t-1} + g_t * i_t \quad (6)$$

本研究采用 LSTM 算法实现水稻产量预测模型,模型输入为天津市宁河区水稻 5 个生长周期的气象要素观测数据,即移栽-返青期平均风速、移栽-返青期最大风速、移栽-返青期平均风速日照时数、移栽-返青期最高温等,模型输出为天津市宁河区单位面积的水稻产量。

1.4 模型评价指标

本研究采用均方根误差和平均绝对误差来评价预测模型的优劣程度。

(1)均方根误差(root mean square error, RMSE)。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (7)$$

(2)平均绝对误差(mean absolute error, MAE)。

$$MAE = \frac{1}{n} \sum_{i=1}^n (|Y_i - \hat{Y}_i|) \quad (8)$$

其中, \hat{Y}_i 和 Y_i 分别表示单位面积水稻产量的预测值和实际值, n 为测试样本的个数。

2 结果与分析

2.1 1989-2015 年水稻单位面积产量趋势

宁河区 1989-2015 年的水稻单产趋势如图 2 所示,可以看出宁河区 1993 年水稻单产明显低于往年(按缺测处理),2010 年之前整体波动不大,2012 年水稻单产最高,2014 年和 2015 年相比也出现了较大程度的减产。




图2 宁河区 1989-2015 年水稻单产变化趋势

2.2 1989-2015 年水稻各生长期气象要素变化特征

为了消除原始气象要素数据量纲不同所带来的不利,通常的做法是归一化处理,将各气象要素数据转换到[0,1]之间归一化公式如下:

$$x_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (9)$$

其中, x_i 为输入数据, i 为数据序号, x_{\max} 、 x_{\min} 为 x 中的最大值和最小值。

本研究主要考虑天津市宁河区水稻 5 个生长周期的气象要素对水稻产量的影响,通过对 1989-2015 年宁河区气象要素观测数据进行统计分析,得到如下结论:

经分析,1989-2015 年宁河区水稻移栽-返青期平均风速、最大风速、平均气温、最高气温几乎无变化,日照总时数减少,最低气温降低,最小相对湿度和平均相对湿度变小,降雨量减少。

分蘖期平均风速变大,最大风速减小,日照总时数增多,平均气温、最低气温、降雨量几乎无变化,最高气温升高,最小相对湿度、平均相对湿度变小。

孕穗期平均风速、最大风速变大,日照总时数减少,平均气温、最高气温、最低气温升高,最小相对湿度几乎无变化,平均相对湿度变小。

抽穗期平均风速变大,最大风速几乎无变化,日照总时数减少,平均气温、最高气温、最低气温降低,最小相对湿度、平均相对湿度变小,降雨量减少。

成熟期平均风速、最大风速变大,日照总时数减少,平均气温、最高气温、最低气温升高,最小相对湿度、平均相对湿度变小,降雨量几乎无变化。

2.3 预测因子的选择

预测因子的选择很大程度上影响了预测的结果,该文利用 Pearson 相关系数法^[15]来考察各气象要素对水稻产量的影响力,公式如下:

$$r = r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (10)$$

其中, x 与 y 分别为 2 个变量的观测值。

若 $r > 0$,表示 2 个变量是正相关的;若 $r < 0$,则表

示 2 个变量是负相关的, n 为样本数量(文中为 26)。

各生长周期各要素与水稻产量相关性系数如表 1 所示,其中, X_1 、 X_2 、 X_3 、 X_4 、 X_5 、 X_6 、 X_7 、 X_8 、 X_9 分别表

表 1 各生长周期各要素与水稻产量相关性系数

| 变量 | 移栽-返青期 | 分蘖期 | 孕穗期 | 抽穗期 | 成熟期 |
|-------|--------|--------|--------|--------|--------|
| X_1 | -0.139 | -0.109 | -0.338 | -0.341 | -0.439 |
| X_2 | -0.239 | -0.266 | -0.191 | -0.388 | -0.496 |
| X_3 | 0.104 | 0.094 | 0.034 | -0.113 | 0.29 |
| X_4 | -0.237 | -0.069 | 0.278 | 0.092 | 0.103 |
| X_5 | -0.046 | -0.117 | 0.241 | 0.038 | 0.052 |
| X_6 | -0.272 | 0.132 | 0.35 | 0.116 | 0.148 |
| X_7 | -0.097 | 0.205 | 0.32 | 0.061 | 0.087 |
| X_8 | -0.225 | 0.263 | 0.223 | 0.018 | 0.032 |
| X_9 | -0.246 | 0.444 | 0.187 | 0.044 | 0.241 |

$$t = \frac{|r_{xy}|}{\sqrt{(1 - r_{xy}^2)/(n - 2)}} \quad (11)$$

最后经过显著性检验,如公式(11)所示,并结合农业气象专家的建议,选取移栽-返青期最大风速、移栽-返青期平均温度、移栽-返青期最低温、移栽-返青期最小相对湿度、移栽-返青期总降水量、分蘖期最大风速、分蘖期平均相对湿度、分蘖期最小相对湿度、分蘖期总降水量、孕穗期平均风速、孕穗期平均温度、孕穗期最高温、孕穗期最低温、孕穗期平均相对湿度、孕穗期最小相对湿度、抽穗期平均风速、抽穗期最大风速、成熟期平均风速、成熟期最大风速、成熟期日照总时数、成熟期总降水量这 21 个要素作为水稻产量的预测因子。

2.4 TensorFlow 框架

TensorFlow 是谷歌的开源机器学习算法框架^[16],其应用场景非常广泛,包括语音识别、自然语言处理、计算机视觉、数据分析及预测等^[17],它支持 Python、C++ 等多种编程语言,计算模型采用有向图(directed graph),其中每个运算操作(operation)作为一个节点(node),节点间的连接为边(edge)。

本研究采用 Anaconda 在 Windows 操作系统下安装 CPU 版本的 TensorFlow,Anaconda 提供了 Python 的包管理和环境管理功能。

TensorFlow 的具体安装步骤如下:

(1)到 Anaconda 官网下载电脑系统对应版本的 Anaconda 并安装。

(2)创建运行环境,安装 Python3.6.10,命令如下:

```
conda create --name tensorflow python=3.6.10
```

(3)激活 TensorFlow 环境,命令如下:

```
activate tensorflow
```

示平均风速、最大风速、日照总时数、平均温度、最高温、最低温、平均相对湿度、最小相对湿度及总降水量。

(4)安装 TensorFlow,命令如下:

```
pip install tensorflow
```

(5)启动 Anaconda,并安装 Spyder。

2.5 基于 TensorFlow 的 LSTM 预测模型

实验采用 Python 语言和 TensorFlow 库实现 LSTM 预测模型,如图 3 所示。

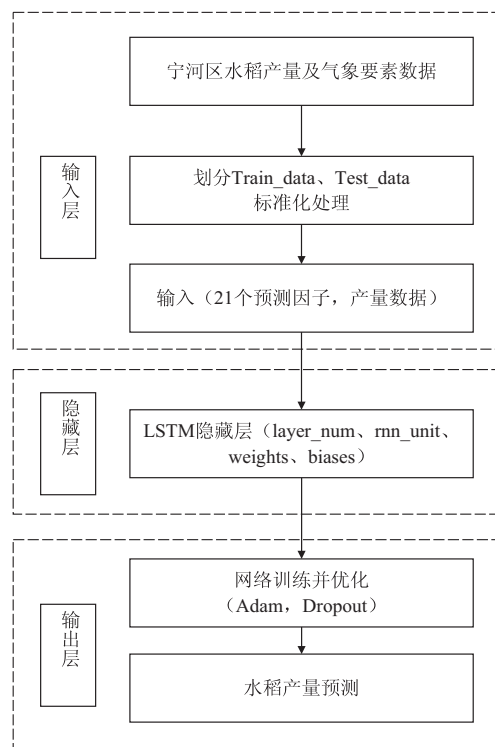


图 3 LSTM 水稻产量预测模型

(1)输入层:以天津市宁河区水稻生长周期的 21 个气象要素作为训练数据,水稻单产数据作为目标数据,对原始气象要素和水稻产量数据进行预处理,得到逐年的时间序列数据集,并将数据集划分为训练集 Tran_data 和测试集 Test_data,采用公式(9)对训练集和测试集进行标准化处理。

训练数据和目标数据实现如下:

```
X = tf.placeholder(tf.float32, [None, time_step, input_size])
Y = tf.placeholder(tf.float32, [None, time_step, output_size])
```

其中, X 为训练数据, Y 为目标数据。

(2) 隐藏层: 将输入层处理后的数据传入隐藏层, 计算相对损失, 对 LSTM 算法隐藏层参数 $layer_num$ 、 rnn_unit 、 $weights$ 、 $biases$ 进行优化, 将最终结果输出。

其中, $layer_num$ 为隐藏层数量, rnn_unit 为隐藏层单元数。输入层和输出层的权重为 $weights$, 偏置为 $biases$ 。

输入层和输出层权重、偏置及误差实现如下:

```
weights = {'in': tf.Variable(tf.random.normal([input_size, rnn_unit])), 'out': tf.Variable(tf.random.normal([rnn_unit, 1])}
biases = {'in': tf.Variable(tf.constant(0.1, shape=[rnn_unit,])), 'out': tf.Variable(tf.constant(0.1, shape=[1,]))}
loss = tf.reduce_mean(tf.square(tf.reshape(pred, [-1]) - tf.reshape(Y, [-1])))
```

(3) 输出层: 通过隐藏层的输出计算得到均方根误差和平均绝对误差, 本研究网络单元采用 $tf.nn.rnn_cell.BasicLSTMCell$, 默认激活函数为 \tanh 。

(4) 优化: 神经网络最常用的优化方法多为基于梯度的, 本研究针对传统神经网络梯度下降问题采用自适应距估计优化器 (Adam), 该算法将 Momentum 和 RMSprop 融合在一起, 能够根据参数调节相应的学习率, 并且内存占用较少。同时, 本研究采用 Dropout 方法防止网络在训练过程中出现过拟合问题。

Adam 优化器和 Dropout 方法实现如下:

```
train_op = tf.AdamOptimizer(lr).minimize(loss)
cell = tf.nn.rnn_cell.DropoutWrapper(cell, output_keep_prob = keep_prob)
```

(5) 预测: 通过 $saver.restore(sess, module_file)$ 将保存的训练好的最优模型参数恢复, 输入新的预测因子, 即可预测水稻产量。

2.6 实验结果

文中基于 TensorFlow 构建了 LSTM 长短时记忆网络, 并通过与传统的 BP 神经网络进行对比实验, 验证基于 TensorFlow 构建的深度学习模型的优越性。网络参数及调优方法参考文献 [18-19], 通过多次实验对模型进行调优得到 BP 神经网络和 LSTM 长短时记忆网络的参数, 如表 2 所示。

表 2 BP 神经网络和 LSTM 参数

| 参数 | 神经网络 | 长短时记忆网络 |
|---------|-------|---------|
| 输入层节点数目 | 21 | 21 |
| 隐藏层数目 | 43 | 100 |
| 输出层节点数目 | 1 | 1 |
| 学习率 | 0.005 | 0.000 6 |
| 迭代次数 | 1 000 | 300 |

从表 2 可以看出, BP 神经网络的网络结构为 $21-q-l$, 其中 21 为输入层的节点数目, q 为隐含层数目, 采用经验公式 $q = 2 * d + 1$, d 为输入层节点数目, l 为输出层节点数目, 即水稻单位面积产量, 学习率设为 0.005, 迭代次数设为 1 000, 误差精度设为 0.005 1。LSTM 长短期记忆网络的输入层节点数为 21, 输出层节点数为 1, 隐藏层数设为 3、隐藏层节点数为 100, 学习率为 0.000 6, 迭代次数为 300。

实验结果如图 4 所示。可以看出, 2014 年相比 2013 年产量有减小的趋势, BP 神经网络没有拟合出来。相比 BP 神经网络, LSTM 长短期记忆网络通过门单元 (gate) 可以更好地学习到长时间序列数据的细节, 进而更好地预测出未来的单位面积水稻产量的发展趋势。

两种方法的预测结果如表 3 所示。

表 3 BP 神经网络和 LSTM 产量预测结果

| 年份 | 真实值 | 预测值 Forecast value | |
|------|--------------|--------------------|--------|
| Year | Actual value | BP 神经网络 | LSTM |
| 2010 | 509.5 | 476.87 | 533.57 |
| 2011 | 604.2 | 509 | 555.43 |
| 2012 | 606.4 | 506.14 | 568.36 |
| 2013 | 600 | 490.17 | 559.67 |
| 2014 | 523.35 | 500.73 | 495.68 |
| 2015 | 430 | 463.29 | 451.35 |

从表 3 可以看出, 除了 2014 年, LSTM 长短时记忆网络对 2010-2015 年的宁河区小站稻亩产量预测精




图 4 BP 神经网络与 LSTM 预测结果对比

度都比 BP 神经网络要高。

其中,BP 神经网络预测结果的 RMSE 为 75.12, MAE 为 65.64。LSTM 长短期记忆网络预测结果的 RMSE 为 34.77, MAE 为 33.37, 相比 BP 神经网络 RMSE 和 MAE 都有明显的下降, RMSE 降低了 53.7%, MAE 降低了 49.2%, 预测精度更高。

3 结束语

该文利用水稻产量的时间序列数据进行预测, 基于 TensorFlow 深度学习框架构建了 LSTM 水稻产量预测方法, 采用 1989–2015 年天津市宁河区地面气象观测资料与产量数据, 选取水稻不同生长期的气象要素作为预测因子, 对水稻单产进行预测。结果表明, BP 神经网络由于过拟合问题, 预测效果不佳, LSTM 长短期记忆网络的预测精度较高, 可以更好地预测未来的粮食产量的长期发展趋势, 可为水稻产量预测提供新的参考思路。水稻产量受经济和自然条件等多种因素影响, 准确的预测往往十分困难, 文中的方法仅考虑了气象要素对产量的影响, 未来可以综合考虑社会经济因素及生产投入、品种等因素做进一步的产量预测研究。

参考文献:

- [1] 王桂芝, 胡 慧, 陈纪波, 等. 基于 BP 滤波的 Fourier 模型在粮食产量预测中的应用[J]. 中国农业气象, 2015(4): 472–478.
- [2] 向昌盛, 张林峰. 灰色理论和马尔可夫相融合的粮食产量预测模型[J]. 计算机科学, 2013, 40(2): 245–248.
- [3] 薛利红, 曹卫星, 罗卫红. 基于冠层反射光谱的水稻产量预测模型[J]. 遥感学报, 2005, 9(1): 100–105.
- [4] 汪小岳, 丁为民, 罗卫红, 等. 利用 BP 神经网络对江淮地区梅雨季节现代化温室小气候的模拟与分析[J]. 农业工程学报, 2004, 20(2): 235–238.
- [5] 任守纲, 刘 鑫, 顾兴健, 等. 基于 R-BP 神经网络的温室小气候多步滚动预测模型[J]. 中国农业气象, 2018, 39(5): 314–324.
- [6] 宗宸生, 郑焕霞, 王林山. 改进粒子群优化 BP 神经网络粮食产量预测模型[J]. 计算机系统应用, 2018, 27(12): 204–209.
- [7] 张成才, 陈少丹. BP 神经网络在河南省粮食产量预测中的应用[J]. 湖北农业科学, 2014(8): 1969–1971.
- [8] 姜 新. 河南省粮食产量影响因素和预测方法研究[J]. 中国农学通报, 2019, 35(1): 154–158.
- [9] 郭亚菲, 樊 超, 闫洪涛. 基于主成分分析和粒子群优化神经网络的粮食产量预测[J]. 江苏农业科学, 2019, 47(19): 241–245.
- [10] 汤鹏杰, 王瀚漓, 许恺晟. LSTM 逐层多目标优化及多层概率融合的图像描述[J]. 自动化学报, 2018, 44(7): 1237–1249.
- [11] 吴娟娟, 任 帅, 张卫钢, 等. 一种基于 LSTM 模型的日销售额预测方法[J]. 计算机技术与发展, 2020, 30(2): 133–137.
- [12] 詹华明, 康 慧, 宋小军, 等. 天津市宁河湿地资源动态变化及生态环境影响分析[J]. 地质调查与研究, 2007, 30(4): 307–314.
- [13] 邴静静, 高红梅. 基于 SWOT 分析的天津市优质稻米产业发展研究——以“小站稻”为例[J]. 浙江农业学报, 2019, 31(8): 1217–1223.
- [14] HOCHREITER S, SCHMIDHUBER J. LSTM can solve hard long time lag problems[C]//Advances in neural information processing systems. Canada: NIPS, 1996: 473–479.
- [15] 殷长春, 孙思源, 高秀鹤, 等. 基于局部相关性约束的三维大地电磁数据和重力数据的联合反演[J]. 地球物理学报, 2018, 61(1): 358–367.
- [16] ABADI M. TensorFlow: learning functions at scale[J]. ACM SIGPLAN Notices, 2016, 51(9): 1.
- [17] 费 宁, 张浩然. TensorFlow 架构与实现机制的研究[J]. 计算机技术与发展, 2019, 29(9): 31–34.
- [18] 徐 计, 王国胤, 于 洪. 基于粒计算的大数据处理[J]. 计算机学报, 2015(8): 1497–1517.
- [19] 刘承启, 林振荣, 黄文海. 基于 LSTM 的 WEB 服务响应时间大数据预测方法[J]. 四川大学学报: 自然科学版, 2019, 56(1): 71–77.