doi:10.6041/j.issn.1000-1298.2020.10.032

基于 WT - CNN - LSTM 的溶解氧含量预测模型

陈英义[1,2]　方晓敏[1,3]　梅思远[1,3]　于辉辉[4]　杨　玲[1,3]

(1. 中国农业大学信息与电气工程学院, 北京 100083; 2. 农业农村部农业信息获取重点实验室, 北京 100083;
3. 国家数字渔业创新中心, 北京 100083; 4. 北京林业大学信息学院, 北京 100083)

摘要: 溶解氧(Dissolved oxygen, DO)含量是影响水产养殖产量的重要因素之一,具有时序性、不稳定性和非线性等特点,且其影响因子过多、存在复杂的耦合关系,难以实现精准预测。针对传统长短时记忆神经网络(Long short-term memory, LSTM)预测模型易引入冗余数据,且在训练过长序列时会出现梯度消失现象,从而不能捕捉因子间长期的依赖性问题,提出了基于小波变换(Wavelet transform, WT)、卷积神经网络(Convolutional neural network, CNN)和 LSTM 的溶解氧含量预测模型。首先,使用 WT 降低数据噪声;然后,使用 CNN 深度挖掘各变量之间的潜在关系;最后,利用 LSTM 的时序性预测 2 h 后的水产养殖溶解氧含量。结果表明,本文提出的 WT - CNN - LSTM 模型预测效果良好,其平均绝对误差、均方根误差和决定系数分别为 0.138、0.229 和 0.954,比传统 LSTM 模型分别优化了 28.87%、21.03% 和 4.61%。

关键词: 溶解氧; 预测模型; 小波变换; 卷积神经网络; 长短时记忆神经网络

中图分类号: TP391　　**文献标识码**: A　　**文章编号**: 1000-1298(2020)10-0284-08　　**OSID**:

Dissolved Oxygen Prediction Model Based on WT - CNN - LSTM

CHEN Yingyi[1,2]　FANG Xiaomin[1,3]　MEI Siyuan[1,3]　YU Huihui[4]　YANG Ling[1,3]

(1. *College of Information and Electrical Engineering*, *China Agricultural University*, *Beijing* 100083, *China*
2. *Key Laboratory of Agricultural Information Acquisition Technology*, *Ministry of Agriculture and Rural Affairs*, *Beijing* 100083, *China*
3. *National Digital Fishery Innovation Center*, *Beijing* 100083, *China*
4. *College of Information*, *Beijing Forestry University*, *Beijing* 100083, *China*)

Abstract: Dissolved oxygen (DO) plays an important role in aquaculture. It has the characteristics of changing with time, instability and nonlinearity, and it has too many influence factors with complex coupling relationship, and it is difficult to be predicted accurately. The traditional long short-time memory neural network (LSTM) is easy to introduce redundant data. And when it deals with long sequences, the gradient disappears so that it cannot capture very long term dependencies. To solve the problems above, the WT - CNN - LSTM prediction model was proposed. In view of the timing and nonlinearity of dissolved oxygen in aquaculture, the LSTM, which was widely used in time series prediction and had excellent performance, was selected to predict the dissolved oxygen value in two hours later. Aiming at the noise generated by environmental factors, human factors and system factors in the process of data collection, the hybrid wavelet transform (WT) was proposed to reduce noise in the data set so as to provide reliable support for the establishment of accurate prediction model. Moreover, due to the complex aquaculture environment, the dissolved oxygen content was affected by a variety of water quality factors and environmental factors. Therefore, the convolutional neural network (CNN) was used to mine and store the potential information between variables and DO in aquaculture. The result showed that WT - CNN - LSTM had good predictive performance. Its mean absolute error, root mean squared error and determination coefficient were 0.138, 0.229 and 0.954, respectively, which were optimized by 28.87%, 21.03% and 4.61% compared with those of the LSTM model.

Key words: dissolved oxygen; prediction model; wavelet transform; convolutional neural networks; long short-term memory neural networks

收稿日期: 2020-01-07　修回日期: 2020-04-01

基金项目: 国家重点研发计划项目(2017YFE0122100)和山东省重点研发计划项目(2017CXGC0201)

作者简介: 陈英义(1980—),男,教授,博士,主要从事农业模型和信息处理技术研究,E-mail: chenyingyi@cau.edu.cn

0　引言

溶解氧含量是决定水产养殖产量的重要因素，它影响着水生物的生长速度和养殖的饲料比，是决定养殖成功与否的重要指标之一[1-2]，过低或过高的溶解氧含量都会导致养殖生物死亡。由于它具有时序性、不稳定性和非线性等特点，且受多种因素影响，各因素之间存在复杂的耦合关系[3]，所以难以建立具有普适性的模型，实现精准预测。以多层感知机（Multi-layer perceptron，MLP）、支持向量机（Support vector machine，SVM）和误差反向传播神经网络（Back propagation neural network，BPNN）为代表的浅层机器学习方法具有极大的局限性[4-5]，易引入冗余数据，且针对复杂问题的泛化能力受到一定的制约，尤其是在大数据的处理方面鲁棒性差，不能完全学习到数据的本质特征[6]，无法满足溶解氧预测的要求。

以长短时记忆神经网络（LSTM）为代表的深度学习方法因具备挖掘长距离时序数据信息的能力而被广泛应用于各个领域[7]。宋刚等[8]利用 LSTM 对不同类型的股票股价进行预测，证明该模型能够很好地处理具有长期依赖关系、复杂的非线性问题。满春涛等[9]将 3 种影响因子的不同组合作为 LSTM 的输入，研究其对交通流量预测精度的影响。若影响因子过多，该试验方法将过于繁杂，并且输入越长，数据间包含的信息量就越大，传统的 LSTM 模型在训练过程中会表现出明显的不稳定性，出现梯度消失的现象。因此，传统的 LSTM 模型无法捕捉数据间长期的相互依赖性。针对以上问题，陆继翔等[10]利用卷积神经网络（CNN）有效提取负荷、气象、峰谷电价等之间的潜在关系，形成特征向量[11]，以此向量构造时序序列，输入至 LSTM 中进行短期负荷预测，综合 CNN 和 LSTM 的优点，提高了短期负荷的预测精度。SUN 等[12]利用 CNN－LSTM 预测了受到各种气候数据和环境数据影响的市县级季中和季末大豆产量，均取得了较好的效果。CNN－LSTM 模型在处理具有多种影响因素的非线性时序序列预测问题时表现良好。目前，CNN－LSTM 模型已广泛应用于语音识别和文本分类领域[13-16]，但在水产养殖领域的应用较少。

本文提出混合 WT－CNN－LSTM 溶解氧预测模型，并将预测结果同门控神经网络（Gated recurrent unit，GRU）、LSTM、WT－GRU、WT－LSTM 和 WT－CNN－GRU 5 种模型进行对比，探索具有较高准确度、适应性和泛化性能的水产养殖溶解氧预测模型，解决传统溶解氧预测模型易引入冗余数据、无法完全学习到数据的本质特征、鲁棒性差的问题，以进一步提高溶解氧长期预测精度。

1　数据获取

试验于浙江省湖州市吴兴区八里店现代农业综合开发区内的浙江省淡水水产养殖研究所综合试验基地进行。所选池塘长为 30 m、宽为 30 m、水深约 1.2 m，养殖品种为杂交鲌鱼，池塘中央安装了一个叶轮式增氧机。结合已有设备和池塘情况，将 4 个溶解氧在线监测传感器分别置于水深 0.6 m 处。为了避开位于池塘中间的增氧机，4 个传感器分别放置于图 1 所示的位置。传感器上传的变量包括溶解氧含量和水温。气象站放置于池塘东北角，上传的有效变量包括风速、风向和太阳辐射，共 3 种气象参数。试验时间为 2017 年 7 月 15 日—8 月 2 日，由于夏季天气多变，试验期间包含了晴天、大风、阴雨、雷电、多云等多种复杂天气情况。

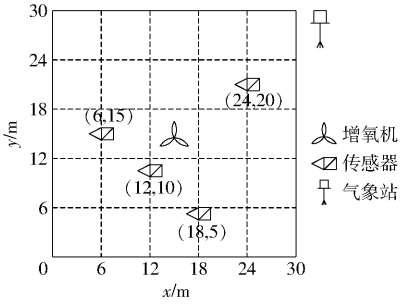

图 1　池塘传感器分布图

Fig. 1　Distribution map of sensors in pond

2　模型构建

2.1　小波变换

数据的真实性和可靠性是模型预测性能的决定性因素，而水产养殖生物的排泄物、饲料残余、藻类等因素都会导致水体污浊[17]，试验所使用的传感器在水体中放置时间过长会被污染物附着，从而导致采集的数据略有偏差，虽然定时清洗，但也无法避免少量噪声数据。另外，一些难以控制的系统误差、随机误差与人为误差等也会导致水质数据和气象数据存在噪声污染。因此，在训练模型前，对数据进行清洗降噪是必不可少的步骤。

本文采用具有自适应性的小波变换[18]对数据进行预处理，以实现在保留有效信息的前提下减少噪声[19]，尽可能维持溶解氧含量数据的时序性、连续性和可靠性。小波变换能够通过不同分辨率对时间序列进行分解，将原始信号分解成不同频率的子信号，使得原始信号的时序概况和细节部

分尽可能多地被发现,因此成为当前分析时间序列的有效工具[20]。其流程如图 2 所示。

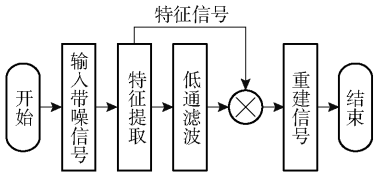

图 2 小波变换流程图

Fig. 2 Process of wavelet transform

具体步骤为:

(1)小波分解:根据不同变量的数据特征选择最佳小波函数对含噪信号进行分解,本文使用了常见的 haar、coif、sym、db 4 种小波。

(2)阈值量化:为分解后每一层的高频系数选择合适的阈值,本文采用的是全局阈值。

(3)小波重构:根据第 1 层至第 N 层的高频系数和第 N 层的低频系数进行小波重构,最终实现降噪。

(4)降噪效果评价:一般来说,信号的信噪比(Signal to noise ratio, SNR)与估计信号同原始信号的均方根误差(Root mean squared error, RMSE)是评价降噪效果的标准,SNR 越大,RMSE 越小,降噪效果越好。

2.2 CNN-LSTM 模型

2.2.1 卷积神经网络

针对溶解氧影响因素多,且影响因子间存在复杂的耦合关系这一特点,本文使用 CNN 来挖掘输入变量间的潜在信息。它采用局部连接和共享权值的方式,通过卷积层和池化层交替使用来获取原始数据的有效表征,自动提取原始数据的有用特征形成特征向量[21-22]。构建卷积层和池化层的具体步骤为:

(1)确定输入样本尺寸,初始化卷积层和池化层中的卷积核尺寸和数量。

(2)将降噪后的数据输入 CNN 模型。

(3)通过改变池化层中卷积核的尺寸,对比最终结果,选择池化层中卷积核的最佳尺寸。

2.2.2 长短时记忆神经网络

LSTM 网络是循环神经网络(Recurrent neural network, RNN)的改进版本。标准的 RNN 结构中只有一个神经元、一个 tanh 层进行重复学习,而 LSTM 引入了“门”的结构来去除或者增加信息到细胞状态的能力[23-24],具体架构如图 3 所示。

σ 层输出 0~1 之间的数值,描述每个部分可以通过的量。LSTM 拥有 3 个门,即输入门、输出门和遗忘门,来保护和控制细胞状态。遗忘门决定从“细胞”中丢弃的信息,输入门决定将要更新的值,

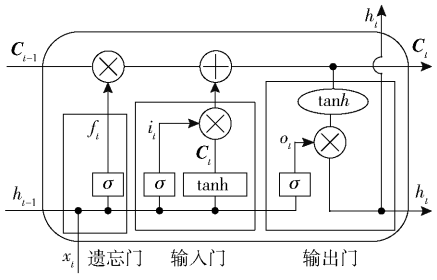

图 3 LSTM 结构图

Fig. 3 Structure diagram of LSTM

输入门和遗忘门协同更新细胞的信息编码。LSTM 模型相应计算公式为

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

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

$$\boldsymbol{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \tag{3}$$

$$\boldsymbol{C}'_t = f_t \boldsymbol{C}'_{t-1} + i_t \boldsymbol{C}_t \tag{4}$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \tag{5}$$

$$h_t = o_t \tanh(\boldsymbol{C}'_t) \tag{6}$$

式中 i_t、f_t、o_t——输入门、遗忘门、输出门

x_t——t 时刻的输入

$\sigma(\cdot)$——sigmoid 激活函数

$\tanh(\cdot)$——双曲正切激活函数

W_i、W_f、W_o——输入门、遗忘门、输出门权重

W_C——候选向量权重

b_i、b_f、b_o——输入门、遗忘门、输出门偏置

b_C——候选向量偏置

$\boldsymbol{C}_t$——t 时刻的候选向量

$\boldsymbol{C}'_t$——t 时刻的候选向量更新值

h_t、h_{t-1}——t、$t-1$ 时间点模型的所有输出

2.2.3 CNN-LSTM 模型构建

CNN 多用于特征工程,而 LSTM 在时序序列上作用效果显著。本文结合两类模型的各自特性,在 LSTM 网络的隐藏层之前加入卷积层和池化层,如图 4 所示。将溶解氧和另外 4 个影响因子串联成向量表示,形成了一个全新的时序序列输入模型,在卷积层和池化层进行特征提取形成特征向量之后进入 LSTM 模型。由于本文所使用的数据集时间间隔为 5 min,则预测 2 h 后的溶解氧含量的步长即为 24,具体步骤为:

(1)首先将训练集输入原始的 LSTM 模型进行训练,找出最适宜的隐藏层节点数。

(2)根据输入样本尺寸,在 LSTM 的隐藏层之前加入卷积层和池化层,初始化卷积层和池化层中的卷积核尺寸和数量。

(3)通过改变池化层中卷积核的尺寸,对比最终结果,选择池化层中卷积核的最佳尺寸,从而完成模型构建。

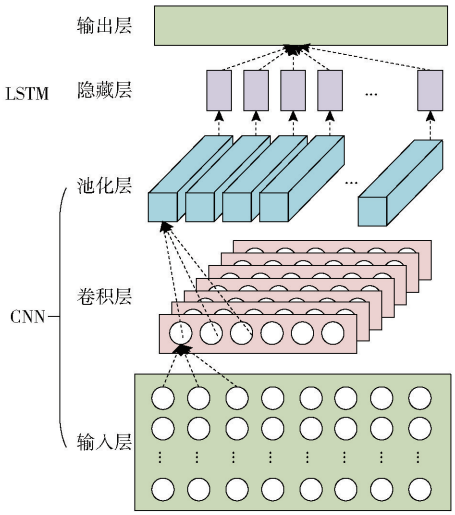

图 4　CNN－LSTM 结构图

Fig. 4　Structure diagram of CNN－LSTM

2.3　WT－CNN－LSTM 模型

水产养殖溶解氧含量受多种因素影响且随时间呈非线性变化，为了捕捉因素间的长期依懒性，提高预测精度，结合以上算法，本文提出了基于 WT－CNN－LSTM 的水产养殖溶解氧预测模型，具体预测流程如图 5 所示。

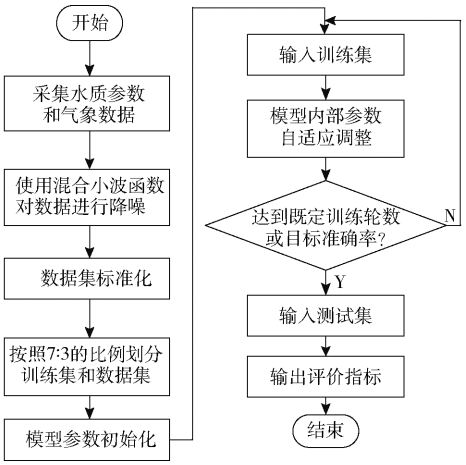

图 5　WT－CNN－LSTM 流程图

Fig. 5　Flowchart of WT－CNN－LSTM

使用该模型进行水产养殖溶解氧预测的步骤为：

(1)设计试验方案，采集溶解氧含量、水温以及风速、风向、太阳辐射 3 种气象因子，总计 5 种参数作为数据集。

(2)依据该数据集中不同参数的特性选择合适的小波函数进行降噪处理。

(3)对数据集进行标准化，初步按照 7∶3的比例分配训练集和测试集。

(4)初始化模型参数，将训练集输入至 CNN－LSTM 模型中，模型自身不断进行特征提取和参数优化，直至损失函数最小模型准确率最高或达到既定训练轮数时停止。

(5)输入测试集测试模型的性能，通过模型的评价指标，与其他模型进行对比，得出最优的水产养殖溶解氧预测模型。

2.4　对比模型

为了克服 RNN 无法对信息进行精细化处理的问题[25]，HOCHREATER 和 SCHMIDHUBER 在 1997 年提出了 RNN 的变体 LSTM，而 GRU[26]则是 LSTM 的一个变体。LSTM 的重复网络模块的结构很复杂，它实现了 3 个门计算，即遗忘门、输入门和输出门，而 GRU 模型只包含 2 个门，如图 6 所示，分别为更新门(z_t)和重置门(r_t)，结构更加简单。

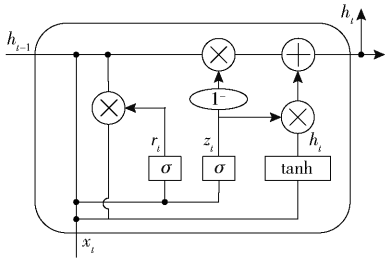

图 6　GRU 结构图

Fig. 6　Structure diagram of GRU

更新门用于控制前一时刻的状态信息被带入到当前状态中的程度，更新门的值越大说明前一时刻的状态信息带入越多。重置门用于控制忽略前一时刻的状态信息的程度，重置门的值越小说明忽略得越多。GRU 与 LSTM 十分相似，理论上来说，GRU 比 LSTM 少一个门，这样就少几个矩阵乘法，在训练数据很大的情况下 GRU 能节省很多时间，但二者效果需要依不同应用场景而定。因此，本文将 CNN－GRU、GRU、LSTM 作为 CNN－LSTM 的对比模型，对模型的预测效果进行比较，最终得出最佳水产养殖溶解氧预测模型。

3　结果与分析

3.1　小波降噪

为了使每个变量的降噪效果达到最好，使用 haar、coif、sym10 和 db5 4 种小波函数分别对 5 种变量进行降噪处理，通过对比评价指标 SNR 和 RMSE，寻找每个变量的最佳降噪小波函数，结果如表 1 所示。试验中，使用 ddencmp 函数获取序列在降噪过程中的默认阈值，此阈值为全局软阈值。

遵循 SNR 越高，RMSE 越小，小波降噪效果越好的原则，依据表 1 得出的结果，最终确定的小波函数组合为：风向使用 haar，风速和太阳辐射使用 coif，溶解氧含量使用 sym10，水温使用 db5，降噪后的结果如图 7 所示。降噪后得到一个大小为 9 681×5 的数据集。

表 1 5 种变量的降噪效果对比

Tab. 1 Comparison of noise reduction effects of five variables

参数	评价指标	小波函数			
		haar	coif	sym10	db5
风速	SNR/dB	13.258 9	13.544 8	13.518 3	13.515 5
	RMSE/(m·s^{-1})	0.535 5	0.518 1	0.519 7	0.519 9
风向	SNR/dB	22.262 6	22.051 5	21.768 8	21.716 0
	RMSE/(°)	12.915 3	13.233	13.670 7	13.754 1
太阳辐射	SNR/dB	27.695 7	29.231 2	29.139 0	29.104 2
	RMSE/(W·m^{-2})	15.357 1	12.868 8	13.006	13.058 3
水温	SNR/dB	57.175 7	60.295 7	60.347 6	60.636 0
	RMSE/℃	0.043 7	0.030 5	0.030 4	0.030 6
溶解氧含量	SNR/dB	25.554 5	26.523 2	26.574 3	26.329 2
	RMSE/(mg·L^{-1})	0.245 9	0.220 0	0.218 7	0.224 9

3.2 试验结果分析

降噪后的数据集按照 7∶3 的比例分为训练集和测试集后,将训练集输入传统的 LSTM 模型中,设置不同的隐藏层节点数对比模型结果,如表 2 所示。模型的评价指标选择了平均绝对误差(Mean absolute error, MAE)、均方根误差(RMSE)和决定系数(R^2)。R^2 越接近 1,表明模型对数据拟合的效果越好。

从表 2 可以看出,当隐藏层节点数为 1 000 时,传统 LSTM 模型性能最好。然后,将卷积层和池化层添加至模型中,输入训练集,设置每次迭代时输入的样本数量为 20,即 batch_size 为 20;由于采集数据的时间间隔为 5 min,需要预测的是 2 h 后水产养殖

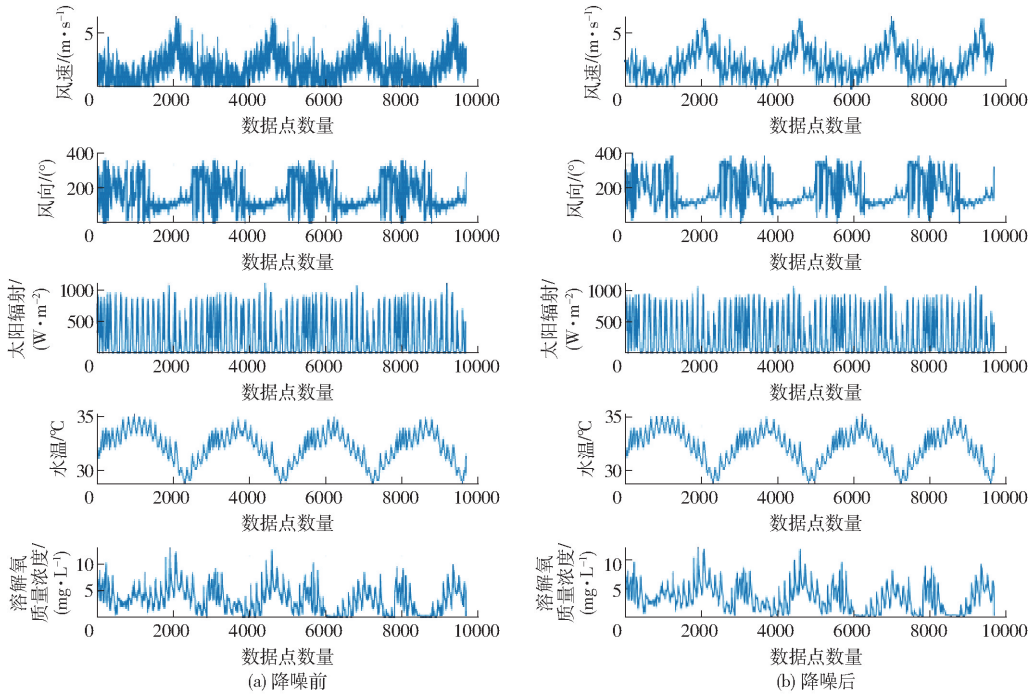

图 7 基于组合小波函数的 5 种变量降噪的结果

Fig. 7 Results of noise reduction of five variables by combined wavelet function

表 2 隐藏层节点数对比

Tab. 2 Comparison of number of nodes in hidden layer

隐藏层节点数	MAE	RMSE	R^2
5	0.167	0.287	0.913
10	0.184	0.298	0.900
20	0.177	0.288	0.914
40	0.200	0.321	0.891
100	0.198	0.295	0.899
200	0.165	0.283	0.915
400	0.177	0.287	0.908
1 000	0.164	0.275	0.916
1 500	0.174	0.284	0.908

溶解氧,因此本文设置每个输入样本的大小为 24 × 5,即 time_step 为 24;卷积核个数设置为 64 个,即 filters 为 64,且卷积核的大小都为 5 × 1。对于每个输入样本,经过 64 个卷积核卷积之后样本从 24 × 5 变为 24 × 1 × 64。本文选择的池化方式为最大池化,池化层尺寸对比结果如表 3 所示。

表 3 池化层参数对比

Tab. 3 Comparison of parameters of pooling layer

池化层尺寸	MAE	RMSE	R^2
1	0.129	0.248	0.935
2	0.132	0.250	0.930
3	0.127	0.246	0.936
4	0.131	0.250	0.929
5	0.146	0.271	0.863
8	0.131	0.252	0.925
10	0.146	0.270	0.862

从表 3 可以得出,当池化层尺寸为 3 时,模型拟

合效果最好，因此，CNN－LSTM 整个模型网络的结构如图 8 所示。

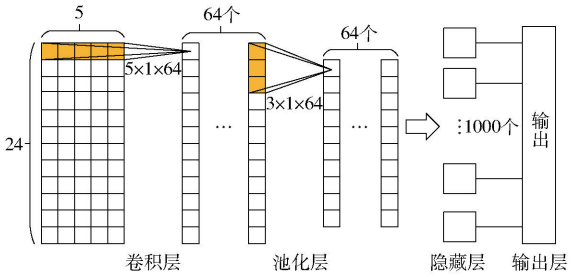

图 8　CNN－LSTM 模型网络结构图

Fig. 8　Structure diagram of CNN－LSTM network

模型构建完成后，为了研究训练集的尺寸对模型性能的影响，使用不同尺寸的训练集对模型进行如表 4 所示的试验。从表中可以看出，当训练集尺寸为 8 500 时，模型的性能最好。

表 4　训练集尺寸对比

Tab. 4　Comparison of size of training set

训练集尺寸	MAE	RMSE	R^2
4 000	0. 283	0. 408	0. 807
4 500	0. 195	0. 304	0. 895
5 000	0. 221	0. 321	0. 895
5 500	0. 226	0. 316	0. 886
6 000	0. 190	0. 265	0. 914
6 500	0. 187	0. 294	0. 903
7 000	0. 164	0. 281	0. 919
7 500	0. 156	0. 273	0. 928
8 000	0. 170	0. 292	0. 924
8 500	0. 138	0. 229	0. 954
9 000	0. 166	0. 265	0. 889

建立的 WT－CNN－LSTM 预测模型以及 5 个对比模型（WT－CNN－GRU、WT－LSTM、WT－GRU、LSTM、GRU）的性能对比如表 5 所示，6 个模型的预测结果如图 9 所示，图中纵坐标表示的是将溶解氧含量标准化处理后的数值。可以看出，对 LSTM 模型来说，经过 WT 进行数据降噪后，模型的 MAE 和 RMSE 降低了 11. 86% 和 14. 14%，R^2 提高了 2. 52%；再经过 CNN 对数据进行特征提取后，模型的 MAE 和 RMSE 降低了 19. 30% 和 8. 03%，R^2 提高了 2. 03%，提高了模型的预测准确率。对 GRU 模型来说，WT 使得模型的 MAE 和 RMSE 降低了 14. 42% 和 17. 68%，R^2 提高了 4. 15%；然后加入 CNN 使得模型的 MAE 和 RMSE 降低了 20. 11% 和 16. 41%，R^2 提高了 1. 94%。结果表明，6 种模型中，WT－CNN－LSTM 的性能最优，其 MAE、RMSE 和 R^2 分别为 0. 138、0. 229（比传统 LSTM 模型分别优化了 28. 87%、21. 03%）和 0. 954，对数据的拟合效果（R^2）依次比其他 5 种模型高 0. 85%、2. 03%、2. 80%、4. 61% 和 7. 07%。因此，本文提出的 WT－CNN－LSTM 模型能够很好地避免噪声影响，充分挖

表 5　模型性能对比

Tab. 5　Comparison of model performance

模型	MAE	RMSE	R^2
WT－CNN－LSTM	0. 138	0. 229	0. 954
WT－CNN－GRU	0. 147	0. 214	0. 946
WT－LSTM	0. 171	0. 249	0. 935
WT－GRU	0. 184	0. 256	0. 928
LSTM	0. 194	0. 290	0. 912
GRU	0. 215	0. 311	0. 891

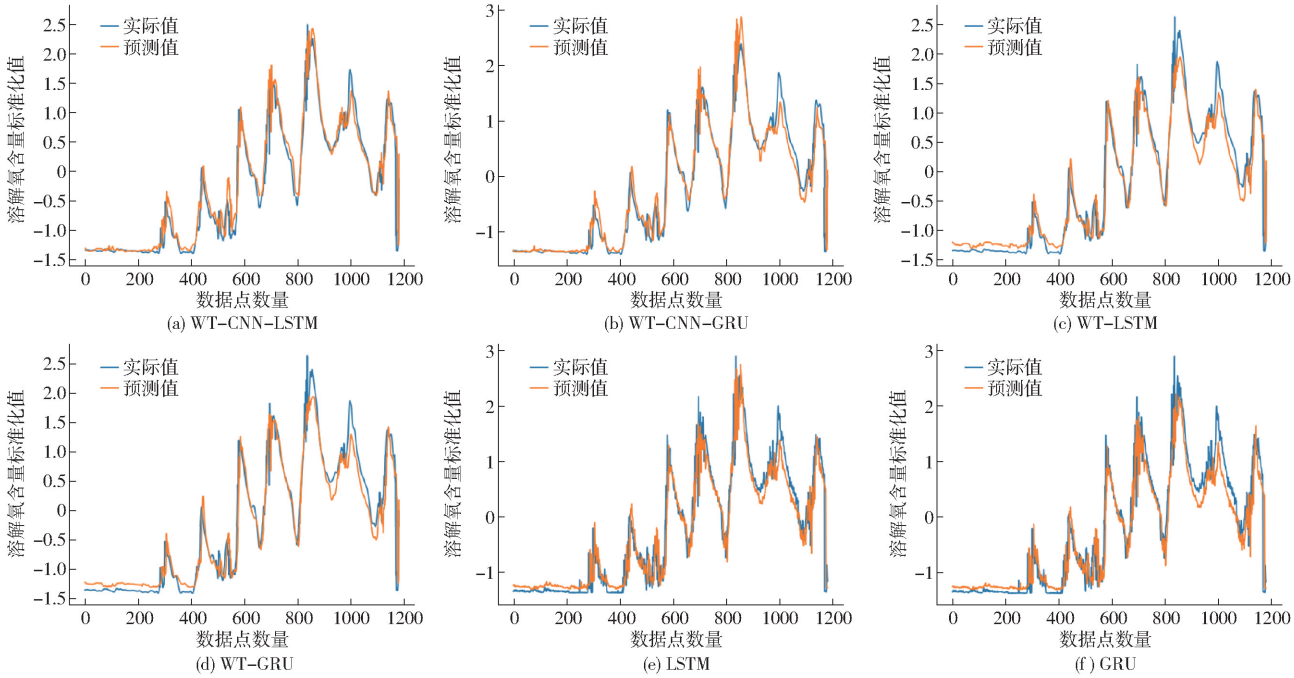

图 9　6 个模型的预测结果

Fig. 9　Prediction results of six models

掘数据间的隐藏信息,较理想地预测 2 h 后的水产养殖溶解氧含量,为水产养殖溶解氧含量的预测预警提供了可靠的决策依据。

3.3 讨论

以上结果表明,本文提出的 WT - CNN - LSTM 表现出良好的预测性能。在未来的研究中,可以从以下 3 方面入手,进一步改进水产养殖溶解氧预测模型:①由于溶解氧含量受气象因素的影响较大,本次试验时间较短,难以保证气候情况的多样性,因此,下一步还需要设计长期或具有周期性的试验方案,构建更完善的数据集,增强模型的泛化能力。②由于溶解氧在不同季节的变化趋势不同,对预测模型的准确率也有一定影响[27],因此,采集数据时可分季节采集。同时,可为每个传感器配备专用的自动清洗装备,从根源处减少冗余数据。③与 CNN 和 LSTM 同属于第三代人工智能神经网络的脉冲神经网络(Spiking neural network, SNN)[28]被认为是能接近仿生机制的神经网络模型,其模型基础和运算方式与哺乳动物脑更为接近。SNN 在特征工程上也被广泛应用,并取得了较理想的效果[29-31]。未来可探索 SNN 在水产养殖溶解氧预测中的可行性。

4 结束语

为了解决溶解氧影响因子过多、预测困难的问题,提出了 WT - CNN - LSTM 预测模型,进一步挖掘因子间的长期依赖性,提高预测精度。针对水产养殖溶解氧的时序性和非线性,选择广泛应用于时间序列预测、且性能优越的长短时记忆神经网络(LSTM),预测 2 h 后的溶解氧含量;针对数据采集过程中存在的由环境因素、人为因素和系统因素产生的噪声数据,提出了基于不同小波函数组合的小波变换(WT)方法,尽可能减少数据集中的噪声,为建立精准预测模型提供可靠数据支持。结果表明,降噪后,模型对数据的拟合精度(R^2)提高了 2.52%;使用卷积神经网络(CNN)挖掘并保存各变量与水产养殖溶解氧之间的潜在信息,将模型的拟合精度提高了 2.03%,WT - CNN - LSTM 模型预测效果良好,其 MAE、RMSE 和 R^2 分别为 0.138、0.229 和 0.954,比传统 LSTM 模型分别优化了 28.87%、21.03% 和 4.61%。

参 考 文 献

[1] 陈俊. 养殖中水体溶解氧的重要性[J]. 植物医生, 2016, 29(11): 46 - 47.

[2] 吴静,李振波,朱玲,等. 融合 ARIMA 模型和 GAWNN 的溶解氧含量预测方法[J/OL]. 农业机械学报, 2017, 48(增刊): 205 - 210.
WU Jing, LI Zhenbo, ZHU Ling, et al. Hybrid model of ARIMA model and GAWNN for dissolved oxygen content prediction[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 205 - 210. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 2017s033&journal_id = jcsam. DOI: 10.6041/j.issn.1000-1298.2017.S0.033. (in Chinese)

[3] 陈英义,程倩倩,方晓敏,等. 主成分分析和长短时记忆神经网络预测水产养殖水体溶解氧[J]. 农业工程学报, 2018, 34(17): 183 - 191.
CHEN Yingyi, CHENG Qianqian, FANG Xiaomin, et al. Principal component analysis and long short-term memory neural network for predicting dissolved oxygen in water for aquaculture[J]. Transactions of the CSAE, 2018, 34(17): 183 - 191. (in Chinese)

[4] LI C, LI Z, WU J, et al. A hybrid model for dissolved oxygen prediction in aquaculture based on multi-scale features[J]. Information Processing in Agriculture, 2018, 5(1): 11 - 20.

[5] ADENIRAN K A, ADELODUN B, OGUNSHINA M. Artificial neural network modelling of biochemical oxygen demand and dissolved oxygen of rivers: case study of Asa River[J]. Environmental Research, Engineering and Management, 2017, 72(3): 59 - 74.

[6] BENUWA B B, YONG Z Z, GHANSAH B, et al. A review of deep machine learning[J]. International Journal of Engineering Research in Africa, 2016, 24: 124 - 136.

[7] LIU Y, GONG C, YANG L, et al. DSTP - RNN: a dual-stage two-phase attention-based recurrent neural networks for long-term and multivariate time series prediction[J]. arXiv Preprint arXiv:1904.07464, 2019.

[8] 宋刚,张云峰,包芳勋,等. 基于粒子群优化 LSTM 的股票预测模型[J]. 北京航空航天大学学报, 2019, 45(12): 1 - 11.
SONG Gang, ZHANG Yunfeng, BAO Fangxun, et al. Stock prediction model based on particle swarm optimization LSTM[J]. Journal of Beijing University of Aeronautics and Astronautics, 2019, 45(12): 1 - 11. (in Chinese)

[9] 满春涛,康丹青. 考虑上下游的 LSTM 短时交通流量预测[J]. 哈尔滨理工大学学报, 2019, 24(5): 101 - 107.
MAN Chuntao, KANG Danqing. Using upstream and downstream traffic information for short-term traffic flow prediction based on LSTM recurrent neural network[J]. Journal of Harbin University of Science and Technology, 2019, 24(5): 101 - 107. (in Chinese)

[10] 陆继翔,张琪培,杨志宏,等. 基于 CNN - LSTM 混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019,

43(8)：131－137.
LU Jixiang, ZHANG Qipei, YANG Zhihong, et al. Short-term load forecasting method based on CNN－LSTM hybrid neural network model[J]. Automation of Electric Power Systems, 2019, 43(8)：131－137. (in Chinese)
[11] TA X, WEI Y. Research on a dissolved oxygen prediction method for recirculating aquaculture systems based on a convolution neural network[J]. Computers and Electronics in Agriculture, 2018, 145：302－310.
[12] SUN J, DI L, SUN Z, et al. County-level soybean yield prediction using deep CNN－LSTM model[J]. Sensors, 2019, 19(20):4363.
[13] TAN M, SANTOS C D, XIANG B, et al. LSTM-based deep learning models for non-factoid answer selection[J]. arXiv Preprint arXiv:1511.04108, 2015.
[14] BARTZ C, HEROLD T, YANG H, et al. Language identification using deep convolutional recurrent neural networks[C]// International Conference on Neural Information Processing. Siem Reap, Cambodia：Springer, Cham, 2017.
[15] XIAO Y, CHO K. Efficient character-level document classification by combining convolution and recurrent layers[J]. arXiv Preprint arXiv:1602.00367, 2016.
[16] SEKHAR V C, DOCTOR A, MUKHERJEE P, et al. A Light weight and hybrid deep learning model based online signature verification[C]// International Workshop on Machine Learning. Sydney, Australia：IEEE, 2019.
[17] 饶伟,杨卫中,位耀光,等. 鱼菜共生水体溶解氧时空变化规律及其影响因素研究[J/OL]. 农业机械学报, 2017, 48(增刊):374－380.
RAO Wei, YANG Weizhong, WEI Yaoguang, et al. Temporal and spatial variability of water dissolved oxygen with influence factors in aquaponics system[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.)：374－380. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=2017s057&journal_id=jcsam. DOI：10.6041/j.issn.1000-1298.2017.S0.057. (in Chinese)
[18] MORLET J. Sampling theory and wave-propagation[J]. Geophysics, 1982, 47(4)：233－261.
[19] 李丽容. 小波分析的产生、发展及应用[J]. 中国水运(理论版), 2007, 5(3)：94－96.
[20] 蔡富,孙付平,戴海亮,等. 小波和傅里叶变换在坐标时间序列分析中的应用[J]. 全球定位系统, 2019, 44(4)：40－46.
CAI Fu, SUN Fuping, DAI Hailiang, et al. Application of wavelet and Fourier transform in time series analysis[J]. GNSS World of China, 2019, 44(4)：40－46. (in Chinese)
[21] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11)：2278－2324.
[22] 陈英义,龚川洋,刘烨琦,等. 基于 FTVGG16 卷积神经网络的鱼类识别方法[J/OL]. 农业机械学报, 2019, 50(5)：223－231.
CHEN Yingyi, GONG Chuanyang, LIU Yeqi, et al. Fish identification method based on FTVGG16 convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(5)：223－231. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20190526&journal_id=jcsam. DOI：10.6041/j.issn.1000-1298.2019.05.026. (in Chinese)
[23] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 8(9)：1735－1780.
[24] GRAVES A, MOHAMED A, HINTON G. Speech recognition with deep recurrent neural networks[C]// International Conference on Acoustics, Speech and Signal Processing. Vancouver, BC, Canada：IEEE, 2013.
[25] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult[J]. IEEE Transactions on Neural Networks, 1994, 5(2)：157－166.
[26] GERS F A, SCHMIDHUBER J, CUMMINS F. Learning to forget：continual prediction with LSTM[J]. Neural Computation, 2000, 12(10)：2451－2471.
[27] CSABRAGI A, MOLNAR S, TANOS P, et al. Application of artificial neural networks to the forecasting of dissolved oxygen content in the Hungarian section of the river Danube[J]. Ecological Engineering, 2017, 100：63－72.
[28] 曾毅,刘成林,谭铁牛. 类脑智能研究的回顾与展望[J]. 计算机学报, 2016, 39(1)：212－222.
ZENG Yi, LIU Chenlin, TAN Tieniu. Retrospect and outlook of brain-inspired intelligence research[J]. Chinese Journal of Computers, 2016, 39(1)：212－222. (in Chinese)
[29] 邓小云,刘金清,吴庆祥. 基于脉冲神经网络人脸特征提取[J]. 福建师范大学学报(自然科学版), 2014, 30(1)：45－51.
DENG Xiaoyun, LIU Jinqing, WU Qingxiang. Face features extraction base on spiking neural networks[J]. Journal of Fujian Normal University (Natural Science Edition), 2014, 30(1)：45－51. (in Chinese)
[30] 阮承妹. 基于 STDP 的脉冲神经网络学习算法的研究[D]. 福州：福建师范大学, 2013.
RUAN Chengmei. Research on learning algorithm of spiking neural network with spike timing[D]. Fuzhou：Fujian Normal University, 2013. (in Chinese)
[31] 胡志根. 脉冲神经网络学习算法的研究及其应用[D]. 成都：电子科技大学, 2017.
HU Zhigen. Research and application of spiking neural networks learning algorithm[D]. Chengdu：University of Electronic Science and Technology of China, 2017. (in Chinese)