

基于 Adaboost 算法的海上风速预测研究

张润锋^{1,2}, 王晓菲^{1,2}, 薛冬阳³, 吴以宁^{1,2}

(1. 天津理工大学 天津市先进机电系统设计与智能控制重点实验室, 天津 300384;

2. 天津理工大学 机电工程国家级实验教学示范中心, 天津 300384;

3. 天津商业大学 机械学院, 天津 300134)

摘要:复杂气象海况条件直接影响船舶的航海安全,海上风速作为气象海况中的主要因素,其预测的精准性对航行安全以及航迹规划等具有重要意义。为有效提高海上风速预测的精准度,克服单一预测模型的局限性,对连云港站点海上风场数据进行实例研究,采用 Adaboost 集成算法融合多模型优势构建海上风速组合预测模型。分别采用 BP 神经网络 (Back Propagation Neural Network, BPNN)、遗传算法 (Genetic Algorithm, GA)-BPNN、长短期记忆网络 (Long Short-Term Memory, LSTM) 和鲸鱼优化算法 (Whale Optimization Algorithm, WOA)-支持向量回归 (Support Vector Regression, SVR) 等 4 种时间序列预测模型进行风速预测。考虑单一模型预测效果,应用 Adaboost 算法对 GA-BPNN 模型和 WOA-SVR 模型进行集成,进而构建海上风速组合预测模型,并与 Bagging 算法集成精度进行比较。分析结果表明:Adaboost 集成算法的组合预测模型均方根误差相较单一模型均方根误差降低了约 13%, 平均绝对误差降低了约 16%, 试验结果有效地验证了组合预测模型在海上风速数据预测方面的优越性,对提高航海安全性与航迹优化设计具有重要的指导意义。

关键词:航海安全;风速预测;集成算法;组合预测

中图分类号:U692.31

文献标志码:A

DOI:10.3969/j.issn.1000-4653.2025.01.003

Research on offshore wind speed prediction based on Adaboost algorithm

ZHANG Runfeng^{1,2}, WANG Xiaofei^{1,2}, XUE Dongyang³, WU Yining^{1,2}

(1. Tianjin Key Laboratory for Advanced Mechatronic System Design and Intelligent Control, Tianjin University of Technology, Tianjin 300384, China; 2. National Demonstration Center for Experimental Mechanical and Electrical Engineering Education, Tianjin University of Technology, Tianjin 300384, China; 3. School of Mechanical Engineering, Tianjin University of Commerce, Tianjin 300134, China)

Abstract: Complex meteorological sea conditions directly affect the safety of ship navigation, and the accuracy of the prediction of offshore wind speed, as a major factor in meteorological sea conditions, is of great significance to the navigation safety and trajectory planning. In order to effectively improve the accuracy of offshore wind speed prediction and overcome the limitations of a single prediction model, the offshore wind form data of Lianyungang station is used as an example study, and the Adaboost algorithm is used to integrate the advantages of multi-models to construct a combined prediction model of offshore wind speed. Four time series prediction models, including BP neural network, GA BPNN, long and short-term memory network and WOA-SVR, are used for wind speed prediction. Considering the prediction effect of a single model, Adaboost algorithm is applied to integrate the GA-BPNN model and WOA-SVR model to construct the combined offshore wind speed prediction model, and the integration accuracy is compared with that of Bagging algorithm.

收稿日期:2023-10-17

基金项目:天津市自然科学基金项目(19JCQNJC03700)

作者简介:张润锋(1993—),男,讲师,博士,研究方向为海洋飞行器安全与环境感知。E-mail: zhangrunfeng@tju.edu.cn

通信作者:王晓菲(1984—),女,副教授,博士,研究方向为机器人系统设计与智能控制。E-mail: wangxiaofeitjut@163.com

引用格式:张润锋,王晓菲,薛冬阳,等.基于 Adaboost 算法的海上风速预测研究[J].中国航海,2025,48(1):18-25.

ZHANG R F, WANG X F, XUE D Y, et al. Research on offshore wind speed prediction based on Adaboost algorithm[J]. Navigation of China, 2025, 48(1): 18-25. (in Chinese)

The results show that the root mean square error of the combined prediction model with the Adaboost algorithm is reduced by about 13% and the mean absolute error is reduced by about 16% compared with the single model, which effectively verifies the superiority of the combined prediction model in the prediction of offshore wind speed data, and it is of great significance for the enhancement of navigational safety and the optimization of the trajectory design.

Key words: navigational safety; wind speed prediction; integrated algorithm; combined prediction

随着我国“一带一路”战略的提出,商品进出口贸易量逐渐增大。海上船舶航行运输作为进出口贸易的重要手段,其运输的安全性极为重要,且海上台风情况多变,复杂的气象海况条件与船舶航行安全息息相关,气象预报的精准程度直接影响着船舶航线规划^[1]。海上风速作为气象海况中的主要因素,对其进行合理准确预测有助于避免恶劣海区,提高航海的安全性,对航海领域船舶路径规划与保障具有重要的科学意义。

大数据的发展推进了深度学习算法的应用进程,诸如长短期记忆网络(Long Short Term Memory, LSTM)、卷积神经网络等方法开始逐步应用于海上航行安全保障方面。王凤武等^[2]采用 LSTM 方法对海港集装箱吞吐量进行预测,并与整合移动平均自回归模型的预测结果进行比较,实现对港口集装箱吞吐量较为准确地预测,有效地拓展了深度学习方法的应用。在采用深度学习方法进行风速预测方面,目前已有较多学者在该领域进行研究。高阳等^[3]提出一种基于广义回归神经网络的短期风速预测模型,实现对风场数据的高效预测。颜宏文等^[4]将卷积神经网络运用于短期风速预测中,有效地借助了深度学习对大数据处理的优势,并通过风场数据对卷积神经网络的实际应用效果进行验证。英如发^[5]提出一种基于支持向量机方法的短期风速预测模型,对风场数据的预测精度进行多角度评价。此外,针对风速的时间序列特性,SAEED 等^[6]提出一种基于 LSTM 的短期风速预测方法,实现对短期风速的预测。王红刚等^[7]通过考虑临近风电场之间的风速时空相关性,进一步提出一种融合 LSTM 的风速预测模型,提高预测的精度。

目前,所采用的方法大多数采取单一模型进行预测,往往存在泛化能力较弱和抗噪声能力较弱的缺点,无法呈现出最理想的预测效果。此外,单一模型往往只在某些特定情况下表现较好,不具有普适性。因此,本文提出一种基于集成算法的短期风速预测模型,分别通过 Bagging 算法和 Adaboost 算法将表现较为出色的单一预测模型进行组合,通过优势互补思想将单个模型的优点自适应集成组合,实现单预测模型优势互补,从而可较好地提高海上风速的预测精度,且具有一定的普适性。

1 单一预测方法

1.1 GA-BPNN

1.1.1 反向传播神经网络

反向传播神经网络(Back Propagation Neural Network, BPNN)在智能算法领域应用最为广泛。BPNN 是一种按照误差逆向传播算法训练的多层前馈神经网络, BPNN 主要包含输入层、隐含层和输出层^[8]。训练 BPNN 的过程主要有两个阶段:

1) 信号的前向传播,信号从输入层经过隐含层,最后到达输出层,一般传递函数为正切 S 型函数;

2) 误差的反向传播,根据其输出值与期望输出值之间的偏差,从输出层到隐含层,最后到输入层,依次采用梯度下降算法调节隐含层到输出层的权重和偏置以及输入层到隐含层的权重和偏置。

1.1.2 遗传算法

遗传算法(Genetic Algorithm, GA)主要思想是模拟生物进化过程并以此来实现优化问题的求解。GA 最早的灵感来自达尔文进化理论中的自然选择以及遗传原理^[9]。GA 中包含选择、交叉和变异等 3 个重要的算子。此外,GA 中的个体适应度函数用来表示如今编码下个体的优化程度。GA 的具体过程为:首先将需要优化的参数编码以进行个体初始化,形成初代个体;然后进入“遗传和进化”的循环过程,根据个体的适应度大小选择适应度较高的个体,并借助于选择、交叉和变异等 3 个算子产生新的种群,直到进化算法终止。通过这个循环过程最终产生的末代种群中的最优体经过解码并以此得出所需参数的值作为问题近似最优解。

1.1.3 GA-BPNN

由于 BPNN 在反向传播时采用梯度下降算法调节隐含层到输出层的权重和偏置以及输入层到隐含层的权重和偏置,且 BPNN 的传输函数通常为非线性函数,导致梯度下降法很容易陷入局部最优解,从而造成 BPNN 的预测精度较差。为解决这一问题,本文引入 GA 算法训练神经网络以求得神经网络的初始权值和初始的偏置值,GA 算法具有较好的全局搜索能力,可降低陷入局部最优解的风险^[10]。

1.2 WOA-SVR

1.2.1 SVR

支持向量回归 (Support Vector Regression, SVR), 是支持向量机模型在回归领域的进一步应用^[11]。传统的线性回归通常利用预测值和真实值之间的差值来构造损失函数, 而 SVR 在构建损失函数时设立了宽度为 2ε 的容忍带, 落入该容忍带的点可认为预测正确, 只利用容忍带外的点代入损失函数。SVR 是通过核函数来实现空间变维的映射, 将线性与非线性问题互相转换, 在高维特征空间中求解最优超平面。假设目前的训练集可表示为

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (1)$$

式(1)中: x 为输入值; y 为输出值。

SVR 主要思想是搜寻高维空间的超平面 $f(x) = \mathbf{w}^T x + b$ 以实现回归预测, 其中 $\mathbf{w} = (w_1, w_2, \dots, w_d)$ 为法向量, 定义了超平面的方向; b 为截距项。SVR 在回归预测问题的本质便是寻找合适的 \mathbf{w} 和 b , 使损失函数达到最小。

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n l_i(f(x_i) - y_i) \quad (2)$$

式(2)中: C 为正则化常数; l_i 为不敏感损失函数, 有

$$l_i(z) = \begin{cases} 0, & |z| \leq \varepsilon \\ |z| - \varepsilon, & |z| > \varepsilon \end{cases} \quad (3)$$

1.2.2 WOA

鲸鱼优化算法 (Whale Optimization Algorithm, WOA), 其灵感来自座头鲸的一种名为气泡网觅食法的捕食方法。在 WOA 中, 每条鲸鱼代表 1 个可行解。WOA 数学模型包括随机搜索、包围收缩和螺旋式捕食等 3 个行为^[12]。这 3 种行为由 A 和 p 两个随机数决定, 其中: $A = 2ar - r$, a 为初始值为 2, 随着迭代次数线性递减至 0 的常数, $a = 2 - 2t/M$ (M 为最大迭代次数, r 为每一维在 $(0, 1)$ 内随机取值的随机向量); p 为一个取值范围为 $(0, 1)$ 的随机数。3 种行为的描述如下:

1) 随机搜索: 鲸鱼算法选择随机搜索捕食, 即随机地向 1 条鲸鱼移动。其移动公式可描述为

$$X_{t+1} = X_{\text{rand}} - A |CX_{\text{rand}} - X_t| \quad (4)$$

式(4)中: X_{rand} 为当前随机个体的位置; C 为在 $(0, 2)$ 内的随机数。

2) 包围收缩: 鲸鱼算法采用包围收缩。当鲸鱼选择包围猎物时, 每条鲸鱼开始选择向最优位置的鲸鱼移动, 其移动公式可描述为

$$X_{t+1} = X_t - A |CX_t^* - X_t| \quad (5)$$

式(5)中: X_t^* 为当前鲸鱼的最优位置。

3) 螺旋式捕食: 当鲸鱼在收缩包围的同时, 也

会进行螺旋式捕食。螺旋式捕食公式为

$$X_{t+1} = |X_t^* - X_t| e^{bl} \cos(2\pi l) + X_t^* \quad (6)$$

式(6)中: b 为定义的对数螺旋形状常数; l 为 $(-1, 1)$ 之间的随机数。

当 $p < 0.5$ 时, 鲸鱼个体将采取随机搜索或者包围收缩, 且根据 $|A|$ 的大小在随机搜索和包围收缩之间选择, 即 $|A| \leq 1$ 时采取包围收缩, $|A| > 1$ 时采取随机搜索。当 $p \geq 0.5$ 时, 鲸鱼个体采取螺旋式捕食。

1.2.3 WOA-SVR

由于 WOA 算法调节参数少、收敛速度快, 可采用 WOA 算法对 SVR 的两个最关键的参数惩罚因数 c 和核参数 g 进行优化处理, 以此来提升 SVR 预测的准确性^[13]。其中, WOA 算法需要优化的目标函数为

$$\min f(c, g) = \sqrt{\frac{1}{n} \sum_{i=1}^n (f(x_i) - x_i)^2} \quad (7)$$

式(7)中: $f(x_i)$ 为第 i 个值的预测值。

1.3 LSTM

长短期记忆神经网络 (Long Short-Term Memory, LSTM), 是一种特殊的循环神经网络^[14]。LSTM 很好地解决了时间间隔较长时的梯度消失和梯度爆炸问题, 相比于普通的循环神经网络, LSTM 在隐藏层原有的对短期信息敏感的状态 h 上增加一个对长期信息敏感的状态 c , 能在更长的序列中有更好的表现。在时刻 t , 输入值为 x_t , 上一时刻 LSTM 的输出值为 h_{t-1} , 上一时刻的单元状态为 c_{t-1} 。LSTM 的输出有当前时刻 LSTM 输出值 h_t 和当前时刻的单元状态 c_t 两个。

LSTM 的核心为遗忘门、输入门和输出门等 3 个门。其中: 遗忘门决定了上一时刻的单元状态对此时单元状态的影响; 输入门决定当前输入对当前状态的影响; 输出门决定单元状态对当前输出值的影响。LSTM 算法流程见图 1。




图 1 LSTM 算法流程

Fig. 1 The workflow of LSTM algorithm

2 组合预测方法

组合预测模型即是多种单一预测模型进行集

成,进一步优化模型预测的精度和可靠性。本文主要采取两种集成算法来实现组合预测。

2.1 Bagging 算法

Bagging 算法采用模型平均的思想将多种单一模型集成^[15],每次通过 Bootstrap 抽样方法从训练集里面抽出部分样本进行训练,进而得出不同的单一预测模型。最终通过不同的单一模型“投票”的形式来做出最终的预测,并以此来提高模型的泛化能力。由于不同的模型在同一测试集上不会产生完全一样的误差, Bagging 算法理论上可很好地降低误差。

假设训练集为 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, Bagging 算法集成的 k 个单一预测模型为 G_1, G_2, \dots, G_k 。 Bagging 算法的计算步骤如下:

2.1.1 步骤 1

For $i = 1, 2, \dots, k$

1) 使用 Bootstrap 抽样方法从训练集 D 中抽取部分样本 D_{bs} 。

2) 由 D_{bs} 训练单一预测模型 G_i 。

2.1.2 步骤 2

将新的数据集代入得到的 k 个单一预测模型,通过对每个单一预测模型的结果取平均,得到最终的预测结果。

Bagging 算法流程见图 2。

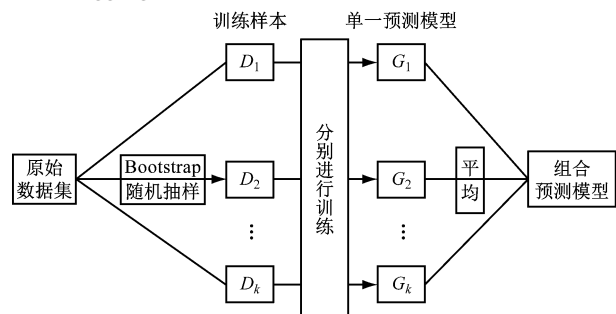


图 2 Bagging 算法流程

Fig. 2 The workflow of Bagging algorithm

2.2 Adaboost 算法

Adaboost 算法采用迭代的思想,每次迭代都用训练数据训练一个单一预测模型,并赋予其一个权重^[16]。初次迭代时,这些权重都是相等的,之后在每次迭代时都会依据预测的误差对数据集中样本的各个权重进行调整,误差较小的样本的权重降低,而误差较大的样本权重则上升,但这些权重的总和保持为 1。最后, Adaboost 算法会根据每次迭代训练好的单一预测模型的预测误差,分配不同的决定系数,形成最终的预测值。 Adaboost 算法可使用各种单一预测模型来构建集成算法且不易发生过拟合现象。

假设训练集为 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, Adaboost 算法集成的 k 个单一预测模型为 G_1, G_2, \dots, G_k 。定义 $k \times n$ 维权重矩阵 W , 其中,第一次迭代的初始化权重为 $w_{ij} = 1/n, j = 1, 2, \dots, n$, Adaboost 算法的计算步骤如下:

2.2.1 步骤 1

For $i = 1, 2, \dots, k$

1) 使用权重分布为 $\{w_{i1}, w_{i2}, \dots, w_{in}\}$ 的训练集训练单一预测模型 G_i 。

2) 计算单一预测模型 G_i 的误差。

$$E_i = \max_j |y_j - G_i(x_j)| \quad (8)$$

$$e_{ij} = \frac{|y_j - G_i(x_j)|}{E_i} \quad (9)$$

$$e_i = \sum_{j=1}^n w_{ij} e_{ij} \quad (10)$$

3) 计算单一预测模型 G_i 的决定系数 α_i 。

$$\alpha_i = \frac{1}{2} \ln \frac{1 - e_i}{e_i} \quad (11)$$

4) 更新训练集权重。

$$w_{i+1,j} = \frac{w_{i,j} \alpha_i^{1-e_i}}{z_i} \quad (12)$$

2.2.2 步骤 2

形成最终的集成算法为

$$f(x) = \sum_{i=1}^k \frac{\alpha_i}{\sum_{i=1}^k \alpha_i} G_i(x) \quad (13)$$

Adaboost 算法流程见图 3。

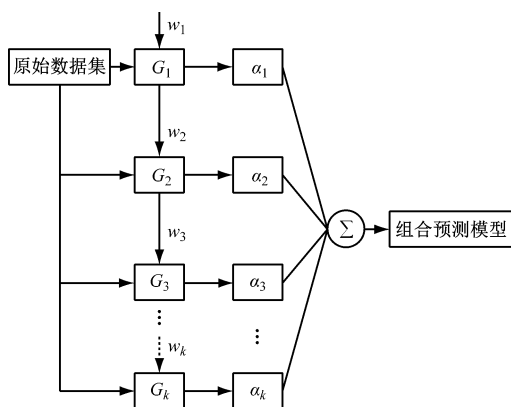


图 3 Adaboost 算法流程

Fig. 3 The workflow of Adaboost algorithm

3 试验数据

采用国家科技资源共享服务平台—国家海洋科学数据中心提供的沿海风场连云港站点数据进行实例分析,数据为 ASCII 格式,经过解码、格式检查、代码转换、标准化、自动质量控制、可视化检查和校准

等处理,形成标准化数据集,其中,自动质量控制包括范围检验、非法码检验,相关性检验、季节性检验、站代码检验和可视化图形检验等。该数据集包含了从1996—2020年的风速数据,涵盖经纬度方向风速和站点经纬度信息等。经度方向风速的前2000组数据见图4。在进行预测时,采用12个连续数据来预测下一组数据。考虑到连云港为季风区,本研究中试验数据集选取连云港站点从2019年7月1日0点—2020年6月30日0点的8760组数据,数据间隔为1h,根据经验,选取前7008组数据(80%)作为训练集,后1752组数据(20%)作为测试集,并随机选取46组数据作为验证集。




图4 经度方向风速情况

Fig. 4 The data of longitudinal wind speed

4 实例分析

4.1 评价指标

在本次实例分析中,为得到更好更全面的效果评价,采用了均方根误差(Root Mean Square Error, E_{RMS})、平均绝对误差(Mean Absolute Error, E_{MA})和 R^2 作为算法效果等3个指标^[17]。其中, E_{MA} 可更为直观、真实地反映预测值和真实值之间的差距,而 E_{RMS} 则对异常值更加敏感,他们的计算公式为

$$E_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (14)$$

$$E_{MA} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (15)$$

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

式(14)~式(16)中: n 为样本数量; x_i 为真实值; y_i 为预测值。

4.2 单一预测模型

4.2.1 BPNN 模型参数设置

BPNN 神经网络采用12-9-1的结构设置,即输入层节点数为12,隐含层节点数为9,输出层节点数

为1。最大迭代次数设置为1000,学习目标为0.001,学习率为0.010。输出层和隐含层的激励函数分别为purelin函数和tansig函数。

4.2.2 GA-BPNN 模型设置

1) 首先采用GA算法对BPNN的初始权值和初始偏置进行搜索,GA算法的最大迭代次数为100,种群规模为20,交叉概率设置为0.6,变异概率设置为0.2。

2) 将GA算法得出的初始权值和初始偏置赋予BPNN神经网络。

3) BPNN神经网络结构设置为12-10-1,即输入层节点数为12,隐含层节点数为10,输出层节点数为1。最大迭代次数设置为1000,学习目标为0.001,学习率为0.010。

4.2.3 WOA-SVR 模型设置

首先采用WOA算法对SVR模型中的惩罚因数 c 和核参数 g 的最佳取值进行搜索,在经度方向风速预测时得出最优的 $c = 448.7418$, $g = 0.0216$;在纬度方向风速预测时得出的最优的 $c = 0.001024$, $g = 0.0032$ 。将最优的 c 和 g 代入SVR模型中进行回归预测。其中,SVR模型采用RBF核函数,每次预测采用12个连续数据作为输入进行分析。

4.2.4 LSTM 模型

考虑到LSTM的时间记忆性质,在每次使用LSTM模型时,采用12组数据的后3个数据作为输入。LSTM模型输入层数目设置为3,隐含层的数目设置为18,输出层数目设置为1。网络中的偏置的初始值、短期信息敏感状态 h 、长期信息敏感状态 c 和隐藏层输出的权重均设置为(0,1)之间的随机数,网络其余权重的初始值均设置为(0,0.05)之间的随机数,误差的阈值设置为 10^{-6} ,迭代的最大次数为3000,每次迭代权重的最大调整比例为0.01。

对模型参数设置后,单一模型评价指标见表1。表1中:在预测经度和纬度方向风速时,GA-BPNN模型和WOA-SVR模型的预测精度在各个指标上都表现得较为出色;在 E_{RMS} 方面,GA-BPNN的预测精度为0.75 m/s和0.94 m/s,相较其他模型效果最优;在 E_{MA} 方面,WOA-SVR模型预测精度更高,为0.58 m/s和0.62 m/s,表明从预测值和真实值之间的差距的角度来说,WOA-SVR模型预测的整体效果更好。

4.3 组合预测模型

基于第4.2节的单一预测模型效果,综合选取GA-BPNN模型和WOA-SVR模型作为单一预测模型导入Bagging算法和Adaboost算法进行组合集

表 1 单一模型评价指标

Tab. 1 Evaluation indices of single model

预测模型	$E_{RMS}/(m/s)$		$E_{MA}/(m/s)$		R^2	
	x	y	x	y	x	y
BPNN	0.82	1.28	0.59	0.96	0.38	0.36
GA-BPNN	0.75	0.94	0.52	0.70	0.48	0.66
LSTM	0.91	1.13	0.78	0.87	0.22	0.50
WOA-SVR	0.76	1.13	0.58	0.62	0.46	0.50

成。在具体实施时,分别使用 Bagging 算法和 Adaboost 算法集成 GA-BPNN 模型和 WOA-SVR 模型。两种组合预测模型和 4 种单一预测模型的效果对比见图 5 ~ 图 8。

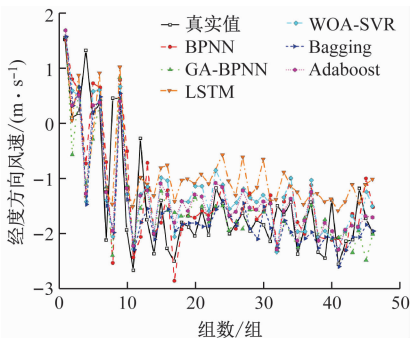


图 5 经度方向风速预测

Fig. 5 The prediction of longitudinal wind speed

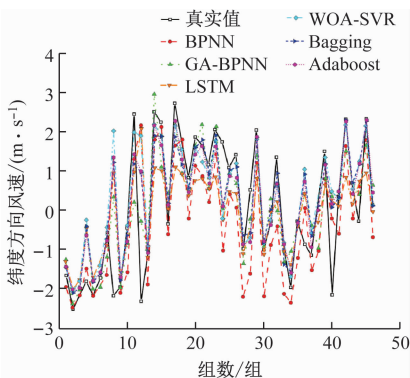


图 6 纬度方向风速预测

Fig. 6 The prediction of latitudinal wind speed

由图 5 和图 6 可知:采用组合预测模型所得出的预测值更加接近真实值,预测趋势更为平稳。由图 7 和图 8 可知:预测方法在经度方向的最大误差约为 3 m/s,在纬度方向最大误差约为 4 m/s。在每一组的预测中, Bagging 算法和 Adaboost 算法得出的预测值相对误差更小,体现了组合算法在预测过程中的优越性能。组合预测模型与单一模型对海上风速预测的综合模型评价指标见表 2。

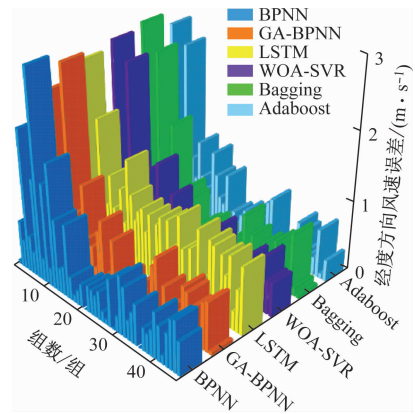


图 7 经度方向风速预测误差

Fig. 7 The prediction error of longitudinal wind speed

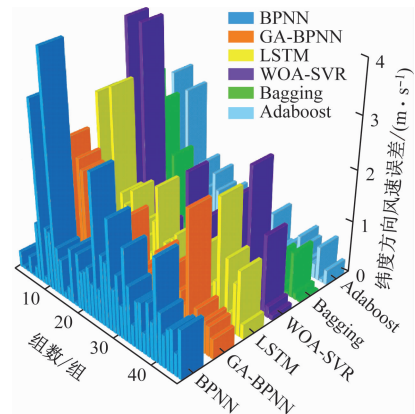


图 8 纬度方向风速预测误差

Fig. 8 The prediction error of latitudinal wind speed

表 2 模型评价指标

Tab. 2 Evaluation indices of single models and ensemble models

预测模型	$E_{RMS}/(m/s)$		$E_{MA}/(m/s)$		R^2	
	x	y	x	y	x	y
GA-BPNN	0.75	0.94	0.52	0.70	0.48	0.66
WOA-SVR	0.76	1.13	0.58	0.62	0.46	0.50
Bagging	0.67	0.88	0.49	0.60	0.59	0.63
Adaboost	0.65	0.87	0.42	0.60	0.55	0.63

由表 2 可知:在经度或纬度方向风速预测误差和预测不确定性方面进行分析, Bagging 算法和 Adaboost 算法的 E_{RMS} 和 E_{MA} 相较单一预测模型均有较大提升, E_{RMS} 预测精度提升约 13%, E_{MA} 预测精度提升约 16%; 针对指标 E_{MA} 而言, Bagging 算法和 Adaboost 算法很好地利用了 WOA-SVR 在解决高维回归问题上的优势, 预测精度超过了任一单一预测模型; 针对指标 E_{RMS} 和 R^2 而言, 两种集成算法很好

地利用了 GA-BPNN 的全局寻优特性,避免了 WOA-SVR 在预测时出现的异常预测值的问题,较好地实现了单模型的优势互补;具体针对两种集成算法的预测误差分析,Adaboost 算法具有较低的泛化误差,改善分类器的分类正确率,但对数据异常点较为敏感,而本文中的风速数据因为采集误差或者数据抖动极易出现异常点,虽已进行数据去噪处理,但也难免出现遗漏,导致预测出现误差,而 Bagging 算法使用均匀取样,根据错误率不断调整样例的权值,可有效消减预测异常点带来的误差。在不确定方面,风速时序数据随时间变化,预测周期越长,预测误差不确定性越大。

5 结束语

海上风速准确预报是船舶航行安全的重要保障要素。为合理准确地对海上风速进行预测,本文采用组合模型集成深度学习和机器学习方法对海上风速数据进行了预测。首先使用 4 种单一模型分别对两个方向的风速分量进行预测,然后根据输出结果的准确程度,选取 GA-BPNN 和 WOA-SVR 两种方法作为基础预测模型,并分别采用 Bagging 算法和 Adaboost 算法进行组合预测。

为验证本文提出方法的有效性,采用连云港站点观测数据进行实例分析,试验结果验证 Adaboost 算法集成模型沿经度和纬度方向的风速预测均方根误差为 0.65 m/s 和 0.87 m/s,均方根误差相较单一模型降低了约 13%,平均绝对误差降低了约 16%,其效果优于各单一预测模型;相较 Bagging 算法集成模型,均方根误差降低了约 0.3%,平均绝对误差降低了约 0.5%,也表现出了较好的预测效果,避免了单一预测模型的局限性,实现多模型优势融合互补,以达到最优预测结果。

今后,将会进一步采用多个海上站点风速数据对 Adaboost 算法集成模型进行验证,并开展高风速下的预测研究。同时,后续会考虑在不同量级数据条件下分析集成模型的预测效果,以贴合风速观测站点实际工作场景。此外,本文所提出的集成算法也可应用于其他的时间序列数据预测,如:大气温度预测、降雨量预测和海上波浪预测等相关领域,对时序数据的预测及海上航行安全保障具有重要科学意义。

参 考 文 献

[1] 冯珂,张本伟. 复杂气象海况条件下船舶航行安全辨识及航行优化方法[J]. 中国航海, 2022, 45(3):

1-6.

FENG K, ZHANG B W. Ship navigation safety identification and optimization under complex sea and weather conditions[J]. Navigation of China, 2022, 45(3):1-6. (in Chinese)

[2] 王凤武,张晓博,阎际驰,等. 基于 LSTM 的上海港集装箱吞吐量预测[J]. 中国航海, 2022, 45(2): 109-114.

WANG F W, ZHANG X B, YAN J C, et al. Prediction of container throughput of Shanghai Port with LSTM[J]. Navigation of China, 2022, 45(2): 109-114. (in Chinese)

[3] 高阳,钟宏宇,葛延峰,等. 基于 GRNN 全信息神经网络的超短期风速预测研究[J]. 测控技术, 2016, 35(4):149-152.

GAO Y, ZHONG H Y, GE Y F, et al. Research on ultra short-term wind speed prediction based on GRNN all information neural network[J]. Measurement and Control Technology, 2016, 35(4): 149-152. (in Chinese)

[4] 颜宏文,卢格宇. CEEMD-WT 和 CNN 在短期风速预测中的应用研究[J]. 计算机工程与应用, 2018, 54(9):224-230.

YAN H W, LU G Y. Application research on Complete Ensemble Empirical Mode Decomposition, Wavelet Transform and Convolutional Neural Networks in short-term wind speed forecasting[J]. Computer Engineering and Applications, 2018, 54(9): 224-230. (in Chinese)

[5] 莫如发. 基于相空间重构和 LSSVM 的短期风速预测[J]. 电工技术, 2022(18):54-58.

MO R F. Short term wind speed prediction based on phase space reconstruction and LSSVM [J]. Electric Engineering, 2022(18):54-58. (in Chinese)

[6] SAEED A, LI C S, DANISH M, et al. Hybrid bidirectional LSTM model for short-term wind speed interval prediction[J]. IEEE Access, 2020,8: 182283-182294.

[7] 王红刚,李彬. 基于融合长短时记忆网络的风电场超短期风速预测研究[J]. 可再生能源, 2020, 38(1):41-46.

WANG H G, LI B. Very-short-term wind speed prediction of multiple wind farms based on merged long-short term memory networks [J]. Renewable Energy Resources, 2020, 38(1):41-46. (in Chinese)

[8] ZHU D, CHENG C, ZHAI W, et al. Multiscale spatial polygonal object granularity factor matching method based on BPNN [J]. International Journal of Geo-Information, 2021, 10(2):75.

- [9] JAMALI A, AHMADI P, JAAFAR M M. Optimization of a novel carbon dioxide cogeneration system using artificial neural network and multi-objective genetic algorithm[J]. Applied Thermal Engineering, 2014, 64 (1-2):293-306.
- [10] WANG S X, ZHANG N, WU L, et al. Wind speed forecasting based on the hybrid ensemble empirical mode decomposition and GA-BP neural network method[J]. Renewable Energy, 2016, 94: 629-636.
- [11] GANDHI A B, JOSHI J B, JAYARAMAN V K, et al. Development of support vector regression (SVR)-based correlation for prediction of overall gas hold-up in bubble column reactors for various gas-liquid systems [J]. Chemical Engineering Science, 2007, 62 (24): 7078-7089.
- [12] SEYEDALI M, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95:51-67.
- [13] WANG X, GAO S, ZHOU S, et al. Prediction of house price index based on bagging integrated WOA-SVR model[J]. Mathematical Problems in Engineering, 2021 (45):1-15.
- [14] NAZARÉ G, CASTRO R, GABRIEL FILHO L R. Wind power forecast using neural networks; tuning with optimization techniques and error analysis [J]. Wind Energy, 2020, 23(3):810-824.
- [15] TASCIKARA OGLU A, UZUNOGLU M. A review of combined approaches for prediction of short-term wind speed and power[J]. Renewable and Sustainable Energy Reviews, 2014, 34:243-254.
- [16] WANG J, TANG S. Time series classification based on ARIMA and Adaboost [J]. MATEC Web of Conferences, 2020, 309: 1-7.
- [17] YAN J H, BAI X H, ZHANG W Y, et al. No-reference image quality assessment based on Adaboost-BP neural network in wavelet domain [J]. Journal of Systems Engineering and Electronics, 2019, 30(2): 223-237.

~~~~~

(上接第 17 页)

- LIU Y H, YANG X J, XIAO Y J. Simulation of Q-Max LNG carrier berthing Yangkou Port in Jiangsu [J]. Journal of Shanghai Maritime University, 2014, 35(3): 1-6. (in Chinese)
- [11] 黄明, 窦佩军, 王裕平, 等. 基于虚拟仿真和实船验证的恶劣天气下 LNG 船舶靠离泊操作分析[J]. 武汉理工大学学报(交通科学与工程版), 2022, 46(4): 743-748.
- HUANG M, DOU P J, WANG Y P, et al. Analysis of LNG ship berthing and unberthing operation in bad weather based on virtual simulation and real ship verification [J]. Journal of Wuhan University of Technology (Transportation science & engineering), 2022, 46(4): 743-748. (in Chinese)
- [12] 王超峰, 刘明俊, 张磊, 等. 鄱阳湖水利枢纽船舶失控漂移建模方法[J]. 中国航海, 2023, 46(2): 67-73.
- WANG C F, LIU M J, ZHANG L, et al. Modeling of ship out of control and drifting in area of Poyang Lake water control project [J]. Navigation of China, 2023, 46(2): 67-73. (in Chinese)
- [13] 罗立科, 于亮. 浅谈船舶在港内失控后的应急处置[J]. 航海技术, 2023(3): 10-13.
- LUO L K, YU L. Emergency handling of ship out of control in harbors [J]. Marine technology, 2023(3): 10-13. (in Chinese)
- [14] HE Y, JIN Y, HUANG L, et al. Quantitative analysis of COLREG rules and seamanship for autonomous collision avoidance at open sea[J]. Ocean Engineering, 2017, 140: 281-291.
- [15] 王雪刚, 苏林王, 林美鸿. 浅吃水半潜驳在浅水域运输沉管的运动响应分析[J]. 中国航海, 2022, 45(4): 94-99.
- WANG X G, SU L W, LIN M H. Motion response of shallow-water submerged barge transporting sinking tube in shallow water [J]. Navigation of China, 2022, 45(4): 94-99. (in Chinese)