

DOI: 10.11830/ISSN.1000-5013.201911024



模糊信息粒化和 GWO-SVM 算法 结合的短期风速范围预测

黄文聪, 张宇, 杨远程, 李子修, 陈润, 常雨芳

(湖北工业大学 太阳能高效利用及储能运行控制湖北省重点实验室, 湖北 武汉 430068)

摘要: 为了实现对风速范围区间的准确预测, 提出一种基于模糊信息粒化和灰狼优化-支持向量机(GWO-SVM)算法的风速预测模型. 该模型首先利用模糊信息粒子, 从一段连续时间的风速值提取出最大值、最小值及大致的平均水平值; 然后, 采用时间序列风速输入模型, 构建输入支持向量机模型的标签向量与特征矩阵; 最后, 通过灰狼算法进行支持向量机预测模型的参数寻优, 实现对风速范围区间的准确预测. 在实例验证阶段, 将风速历史数据进行模糊粒化, 采取 4 种不同的参数寻优方式对支持向量机预测模型进行参数寻优. 结果表明: GWO-SVM 算法可以有效地提高风速范围预测的精确度.

关键词: 风速预测; 时间序列; 模糊信息粒化; 灰狼算法; 支持向量机

中图分类号: TM 614; TP 301.6 **文献标志码:** A **文章编号:** 1000-5013(2020)05-0674-09

Short-Term Wind Speed Range Prediction Based on Fuzzy Information Granulation and GWO-SVM Algorithm

HUANG Wencong, ZHANG Yu, YANG Yuancheng,
LI Zixiu, CHEN Run, CHANG Yufang

(Hubei Key Laboratory for High-Efficiency Utilization of Solar Energy and Operation Control of
Energy Storage System, Hubei University of Technology, Wuhan 430068, China)

Abstract: In order to achieve accurate prediction of wind speed range interval, this paper proposes a wind speed prediction model based on fuzzy information granulation and grey wolf optimizer-support vector machine (GWO-SVM) algorithm. Firstly, the fuzzy information granules are used to extract the maximum, minimum and general average values of wind speed for a continuous period of time. Then the label vector and feature matrix are constructed as input of the SVM model by the time series wind speed prediction model, and finally the parameters of the SVM prediction model are optimized by the gray wolf algorithm to realize the accurate prediction of the wind speed range interval. On the example verified stage, the fuzzy information granulation of historical wind speed data is carried out, and the parameters of the SVM prediction model are optimized by four different parameter optimization methods. The results show that the GWO-SVM algorithm can improve the accuracy of wind speed range interval prediction more effectively.

收稿日期: 2019-11-06
通信作者: 黄文聪(1977-), 男, 副教授, 博士, 主要从事能源系统优化与控制、电力系统规划的研究. E-mail: hwc@hbut.edu.cn.
基金项目: 国家自然科学基金资助项目(61903129, 51977061); 湖北工业大学绿色工业引领计划资助项目(CPYF2017003); 湖北工业大学大学生创新创业训练计划资助项目(201710500002, S201810500045, S201910500058)

Keywords: wind speed prediction; time series; fuzzy information granulation; grey wolf optimizer; support vector machine

随着能源危机的到来,大力发展绿色可再生能源已成为全社会的共识.风能作为一种取之不尽用之不竭的绿色可再生能源,得到了广泛的关注和有力的开发利用.根据《2017 年全球风电发展报告》,截止到 2017 年 12 月底,全球风力发电装机容量达 539.1 GW^[1].由于风电的波动性和间歇性,当大规模的风电接入电网时,可能会对电网的稳定性产生影响,甚至会扰乱电力系统的正常运行.风速是影响风力发电最直接的因素,若能对风速范围进行准确的预测,则可以提供高精度的风力发电功率预测.这将有利于电网及时调整电力调度计划,提高风能资源的高效利用,降低电网运行成本,降低风电接入电网时对电网产生的影响,对风力发电的发展具有积极重要的意义.

目前,国内外的学者对风速预测做了大量的研究.李大中等^[2]提出基于卷积循环神经网络深度学习的预测模型;陈金富等^[3]提出用时空相关性的多位置多步风速预测模型,构造了一个利用时空相关性的风速预测模型——深层时空网络;Zhang 等^[4]提出基于小波分解和布谷鸟搜索算法的小波神经网络风速预测;赵征等^[5]提出一种基于变分模态分解和改进差分自回归滑动平均模型的风速预测模型.上述研究建立的预测模型在一定程度上提高了风速的预测精度,其平均百分比误差在 1%~10% 的范围内.

通过对已发表文献的分析,目前对风速的预测主要采用物理方法与统计方法相结合的方法^[6-11],这些方法各具特点,在预测精度上存在一些差异.灰狼优化算法(grey wolf optimizer,GWO)是由 Mirjalili 等提出的一种模拟灰狼捕食行为的群智能优化算法^[12-14],因其原理简单、收敛速度快且全局性能好等优点,广泛应用于故障诊断、无人机航迹规划、客流预测、滑坡位移预测等领域^[15-18].廖小平等^[19]利用灰狼优化的支持向量机得到刀具磨损的分类等级,能准确地反映刀具的磨损状态,且具有较高的泛化能力;朱敬旭辉等^[20]基于灰狼算法优化的比例积分微分(PID)控制,采用灰狼优化算法对 PID 控制参数进行自整定以提高控制系统的动态性能,该控制算法能够有效稳定地控制移动机器人完成路径跟踪任务.

基于以上分析,本文提出一种基于模糊信息粒化和灰狼优化-支持向量机(GWO-SVM)算法的风速预测模型,实现对风速范围区间的准确预测.

1 时间序列风速输入模型

假设第 i 次测得的风速为 x_i ,其中,数据长度为 m 的第 n 组的连续时间风速数据 $\mathbf{Y}(n,m)$ 为

$$\mathbf{Y}(n,m)=\{x_n,x_{n+1},x_{n+2},\cdots,x_{n+m-1}\}.\tag{1}$$

式(1)中:数据以 x_n 开头,数据长度为 m ,顺序与原始风速数据相同.数据长度为 N 的原始的风速数据 $\mathbf{Y}(0,N)$ 可表示为

$$\mathbf{Y}(0,N)=\{x_1,x_2,x_3,\cdots,x_N\}.\tag{2}$$

第 1 组到第 $n-1$ 组连续时间风速数据所构成的风速数据时间序列矩阵 $\mathbf{X}(n-1,m)$ 为

$$\mathbf{X}(n-1,m)=\mathbf{Y}(1:n-1,m)=\begin{bmatrix} x_{n-1} & x_n & \cdots & x_{n+m-2} \\ \vdots & \vdots & & \vdots \\ x_3 & x_4 & \cdots & x_{2+m} \\ x_2 & x_3 & \cdots & x_{1+m} \\ x_1 & x_2 & \cdots & x_m \end{bmatrix}.\tag{3}$$

通过该风速数据为时间序列数据的特点,可以推导出第 n 次测得的风速 x_n 与第 1 次测得的风速 x_1 到第 $n-1$ 次测得的风速 x_{n-1} 之间存在模糊函数关系,即

$$x_n=f(x_1,x_2,x_3,\cdots,x_{n-1}).\tag{4}$$

数据长度为 m 的第 n 组的连续时间风速数据 $\mathbf{Y}(n,m)$ 与第 1 组到第 $n-1$ 组连续时间风速数据所构成的风速数据时间序列矩阵 $\mathbf{X}(n,m)$ 也存在模糊函数关系,即

$$\mathbf{Y}(n,m)=F(\mathbf{X}(n-1,m)).\tag{5}$$

通过这一层模糊函数关系,可以实现对风速数据的预测.

2 模糊信息粒化模型

信息粒化是根据一定的划分规则,将一个信息整体分解为多个部分,每个部分即为一个信息粒.非模糊的信息粒化有区间信息粒化、相空间信息粒化等具体粒化方法,在一些技术领域中有重要的作用.然而,在实际情况中,粒子都是模糊的,非模糊粒化具有一定的局限性.因此,采用模糊信息粒化(fuzzy information granulation,FIG)对数据进行处理.利用FIG可以对庞大的样本数据进行特征提取,将提取出的特征作为输入,代入预测模型.

对数据进行FIG处理主要划分为两个步骤:1)窗口划分,即对时间序列进行分割,划分为多个窗口;2)模糊信息化,即分别对每个窗口进行模糊化处理,生成数个模糊信息粒.模糊化是FIG的关键步骤,通过在窗口上建立一个合理的模糊集,也就是从数据中提取出关键的特征信息代替原来的数据.

针对单窗口模糊化问题,对于确定的风速时间序列 $\mathbf{X}=(x_1,x_2,\cdots,x_n)$,将整个 \mathbf{X} 作为一个单窗口进行模糊化得到模糊粒子 P ,提取出来的模糊粒子 P 能够合理描述以 \mathbf{X} 为论域的模糊概念 G .模糊化的本质是建立一个函数 M 的过程,函数 M 是模糊概念 G 的隶属函数,即 $M=\mu_G$,其中, μ_G 为 G 的隶属关系.模糊化的过程也就是先确定模糊概念的基本形式,然后,再确定模糊概念 G 的隶属函数 M .

要得到隶属函数 M ,先要确定好模糊概念的对应形式,其主要形式有三角型、梯型、高斯型和抛物型.文中采用的是三角型的模糊概念,函数关系为

$$M(x,s,m,h)=\begin{cases} 0, & x<s, \\ \frac{x-s}{m-s}, & s\leq x\leq m, \\ \frac{h-x}{h-m}, & m< x\leq h, \\ 0, & x>h. \end{cases} \tag{6}$$

式(6)中: s 和 h 为分别对应模糊概念 G 的下界值、上界值; m 是模糊概念 G 的隶属度为1时的取值.经过对一段连续时间的风速值进行模糊信息处理可以提取出3个参数UP,LOW和 R .其中:UP表示风速范围预测的最大值;LOW表示风速范围预测的最小值; R 表示风速范围预测的平均水平.

对模糊信息粒化得到的三个参数UP,LOW和 R 进行归一化处理,利用原始数据线性化将信息转换到 $[0,1]$ 的范围.归一化公式为

$$p=\frac{x_i-x_{\min}}{x_{\max}-x_{\min}}. \tag{7}$$

式(7)中: p 为归一化后的数据; x_i 为原始数据; x_{\max},x_{\min} 分别为原始数据集的最大值和最小值.该方法实现对原始数据的等比例缩放,归一化之后将数据UP,LOW和 R 代入时间序列风速输入模型,得到输入预测模型的标签向量和对应的特征矩阵.

3 建立 GWO-SVM 模型

3.1 SVM 理论

支持向量机(SVM)是一种基于统计理论的VC(Vapnik-Chervonenkis)维理论和结果风险最小化理论的统计机器学习算法.其在解决小样本、非线性,以及高维模式识别上有较好的应用,且在预测的应用上有较好效果.通过预测模型构造出损失函数,再基于结构风险最小化原则得到支持向量机算法.它要解决一个原始最优化问题,其形式为

$$\left. \begin{aligned} \min_{\mathbf{w},b,\xi^2} \quad & \frac{1}{2} \|\mathbf{w}\|^2 + c \sum_{i=1}^l (\xi_i + \xi_i^*), \\ \text{s. t.} \quad & \begin{cases} y_i - \mathbf{w}^* \varphi(x_i) - b \leq \epsilon + \xi_i, & \xi_i \geq 0, \quad \xi_i^* \geq 0, \quad i = 1,2,\cdots,l, \\ \mathbf{w}^* \varphi(x_i) + b - y_i \leq \epsilon + \xi_i^*, & \xi_i \geq 0, \quad \xi_i^* \geq 0, \quad i = 1,2,\cdots,l. \end{cases} \end{aligned} \right\} \tag{8}$$

式(8)中: \mathbf{w} 为权值向量; \mathbf{w}^* 为 \mathbf{w} 的伴随矩阵; c 为惩罚参数; ξ_i,ξ_i^* 为松弛变量; $\varphi(x_i)$ 为映射函数; x_i 为输入变量; y_i 为输出变量; l 为样本个数; b 为偏值; ϵ 为误差上限.

通过代入拉格朗日乘子 a_i 和 a_i^* , 将式(8)转化为拉格朗日多项式, 用 E 表示, 即

$$\left. \begin{aligned} \min_{a_i, a_i^*} E &= \frac{1}{2} \sum_{i,j=1}^l (a_i^* - a_i)(a_j^* - a_j)k(x_i, x_j) - \sum_{i=1}^l y_i(a_i - a_i^*), \\ \text{s. t. } \sum_{i=1}^l a_i &= \sum_{i=1}^l a_i^*, \quad 0 \leq a_i, \quad a_i^* \leq C, \quad i = 1, 2, \dots, l. \end{aligned} \right\} \quad (9)$$

式(9)中: $k(x_i, x_j)$ 为核函数; x_i, x_j 为输入变量; l 为样本个数.

由式(9)求解, 可得到支持向量机的预测函数为

$$f(x) = \sum_{i=1}^l (a_i - a_i^*)k(x_i, x_j) + b. \quad (10)$$

基于 Mercer 条件, 且将高斯 RBF 作为核函数, g 为核函数的内部参数, 则有

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) = \exp(-g \|x_i - x_j\|^2), \quad g > 0. \quad (11)$$

式(8)中的惩罚参数 c 和式(11)中的核函数的内部参数 g 决定了 SVM 的预测精确度. 因此, 为了构建高精度的预测模型, 需要对 SVM 内部的参数(c, g)进行优化以确定最优参数.

3.2 灰狼优化算法

采用灰狼优化(GWO)算法对 SVM 内部的参数 c, g 进行参数寻优, 有如下 3 个主要步骤.

步骤 1 包围猎物. 灰狼与猎物之间的距离 D 为

$$D = |C \cdot X_p(t) - X(t)|, \quad X(t+1) = X_p(t) - AD. \quad (12)$$

式(12)中: t 为迭代次数; $X_p(t)$ 为当前猎物的位置; $X(t)$ 为当前灰狼位置; $X(t+1)$ 下次迭代后灰狼的位置; A, C 为系数向量. A, C 的更新方式分别为 $A = 2a \cdot r_1 - a, C = 2 \cdot r_2$, 其中, r_1 与 r_2 为 $[0, 1]$ 之间的随机数, a 为收敛因子, 初始值为 2, 随着迭代次数的增加递减至 0.

步骤 2 追捕猎物. 计算每个灰狼个体的适应度值 f_i , 将适应度值排列前三的灰狼个体的位置分别记为 $X_\alpha, X_\beta, X_\delta$, 并将适应度值最好的 X_α 记为最优解; 然后, 计算剩余灰狼个体 ω 与排列前三的灰狼个体位置 $X_\alpha, X_\beta, X_\delta$ 的距离, 即

$$D_\alpha = |C_1 X_\alpha(t) - X(t)|, \quad D_\beta = |C_2 X_\beta(t) - X(t)|, \quad D_\delta = |C_3 X_\delta(t) - X(t)|. \quad (13)$$

最后, 更新灰狼 α, β, δ 和猎物的位置, 即

$$X_1 = X_\alpha(t) - A_1 D_\alpha, \quad X_2 = X_\beta(t) - A_2 D_\beta, \quad X_3 = X_\delta(t) - A_3 D_\delta, \quad (14)$$

$$X_P(t+1) = (X_1 + X_2 + X_3) / 3. \quad (15)$$

步骤 3 狼群对猎物进行攻击并捕获猎物以获得最优解. 如果灰狼算法的迭代次数达到最大迭代次数 t_{\max} , 那么, 算法结束并输出最优解 X_α ; 否则, 返回步骤 2 继续进行寻优.

3.3 基于模糊信息粒化和 GWO-SVM 的风速预测模型

由上述建立的模糊信息粒化模型和 GWO-SVM 模型, 构建文中提出的风速范围组合预测模型, 实现对风速范围的准确预测. 风速预测有如下 4 个主要步骤.

步骤 1 将历史数据进行模糊粒化处理, 得到新的时间窗口的粒化数据; 然后, 将模糊粒化后的数据进行归一化操作, 可得到 LOW, R, UP 的归一化数据; 最后, 将归一化数据划分为训练集数据和测试集数据.

步骤 2 构建时间序列风速输入模型, 分别对 LOW, R, UP 三组时间序列进行归一化, 并将训练集数据分别代入时间序列风速输入模型, 即可得到三组 GWO-SVM 的训练集标签向量 $Y(n, m)$ 与训练集特征矩阵 $X(n, m)$ 数据.

步骤 3 将上述三组数据分别作为输入代入模型 GWO-SVM 模型, 初始化狼群数为 n , 最大迭代次数为 t_{\max} , 将惩罚参数 c 和核函数参数 g 代入 SVM 进行预测. 如果灰狼算法的迭代次数达到最大迭代次数 t_{\max} , 那么, 算法结束并输出最优解 c, g ; 否则, 继续进行 GWO 参数寻优.

步骤 4 将最优参数 c, g 代入 SVM 进行预测, 预测时间段 t 上最大值、最小值和大体平均水平值, 可得到时间段 t 风速范围区间; 然后, 用同样的预测方法继续预测 $t + \Delta t$ 时间段风速范围, 将风速预测值与风速实际值对比, 并进行误差检验.

基于模糊信息粒化模型和 GWO-SVM 模型的算法流程图,如图 1 所示. 本算法的目的是对未来风速值进行范围预测,预测结果为(LOW,R,UP).

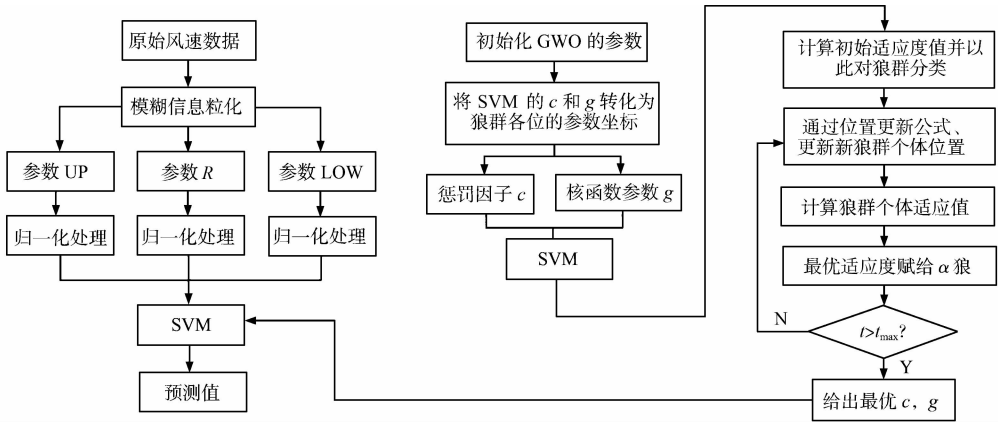


图 1 风速预测模型的算法流程图
Fig. 1 Algorithm flow chart of wind speed prediction model

4 实例仿真与分析

4.1 试验数据的处理

样本数据来自于某风力发电机在 2019 年 7 月 6 日至 2019 年 7 月 15 日连续 10 d 的风速数据,采样时间间隔为 5 min. 利用 MATLAB 编程实现对上述预测方式的验证,用前 6 天的历史风速数据对后 4 天的风速数据进行范围预测,其中,风速数据的总样本量为 3 000,训练数据样本量为 1 850,预测数据样本量为 1 150. 历史风速数据样本,如图 2 所示. 图 2 中: $N_{5\min}$ 表示每 5 min 为采样点的数; v 为风速.

将数据代入模糊信息粒化模型后进行 FIG 处理,使原来每 5 min 为采样点的数以 30 min(6 个采样点)作为新的窗口周期,数据模糊信息粒化的视图,如图 3 所示.




图 2 历史风速数据
Fig. 2 Historical wind speed data




图 3 粒化风速数据
Fig. 3 Granulated wind speed data

对风速数据进行新的窗口划分后(6 个时间点为一个窗口),提取出 LOW,R 和 UP 值分别进行预测,对应得到下一个时间窗口的 LOW,R 和 UP 值,即得到最小值、大体平均水平值及最大值. 主要步骤包括对粒化后的 LOW 值进行归一化处理,然后,使用 GWO-SVM 预测模型得到风速的 LOW 值. 同样选取风速模糊信息粒化后的 R 值和 UP 值进行归一化处理,再通过 GWO-SVM 预测模型进行预测,分别获取对应的预测值,最后,得到风速的预测范围.

GWO 的初始参数设置,如表 1 所示. 通过 GWO 得到的 SVM 模型的内部参数 c 和 g ,如表 2 所示. 最终的取值采用 GWO-SVM 预测模型预测的风速 LOW,R 和 UP 值,实际对比如图 4 所示. 图 4 中: $N_{30\min}$ 表示每 30 min 为采样点的数. 通过对比图 4 中预测变化曲线和实际变化曲线可以看出,GWO-SVM 预测模型对风速 LOW,R 和 UP 值的预测效果较好.

表 1 GWO 的初始参数设置
Tab.1 GWO initial parameter settings

主要参数	初始狼群数量	最大迭代	c		g	
			下界	上界	下界	上界
参数值	20	200	0.01	100	0.01	100

表 2 GWO-SVM 模型的参数最终值
Tab.2 Final value of parameters of GWO-SVM model

参数	UP	LOW	R
c	7.68	36.21	1.20
g	0.28	0.40	0.34




图 4 GWO-SVM 预测模型的预测值与实际值的对比

Fig. 4 Comparison of predicted and actual values of GWO-SVM prediction model

连续 30 min 内的实际风速值对应的风速范围的预测值,如表 3 所示. 表 3 中:实际风速值之间的时间间隔(Δt)为 5 min;风速范围区间可用[LOW,R,UP]表示.

表 3 连续 30 min 时间内风速范围的预测值

Tab.3 Prediction of wind speed range in 30 consecutive minutes

$v/\text{m} \cdot \text{s}^{-1}$						信息特征(LOW,R,UP)	
t_i	$t_i + \Delta t$	$t_i + 2\Delta t$	$t_i + 3\Delta t$	$t_i + 4\Delta t$	$t_i + 5\Delta t$	实际值	预测值
4.67	4.81	4.74	4.54	4.52	4.57	(4.52,4.65,4.81)	(4.40,4.77,4.83)
5.45	5.66	6.12	6.05	5.38	5.70	(5.38,5.73,6.12)	(5.27,5.80,6.20)
3.00	3.13	3.61	2.96	2.67	3.19	(2.67,3.07,3.61)	(2.51,3.11,3.62)

由表 3 可见:实际风速值都在预测范围区间之内,且实际风速范围与预测风速范围一致. 由此可知,采用模糊信息粒化和 GWO-SVM 的组合风速预测算法可以实现对风速范围的精准预测.

4.2 算法预测精度的分析

为了对算法预测精度进行分析,分别利用网格搜索(grid search,GS)法、遗传算法(genetic algorithm,GA)寻优法、粒子群算法(particle swarm optimization,PSO)寻优法进行参数寻优后,再进行风速预测,通过对误差大小的对比,研究 GWO-SVM 算法的预测精度.

通过计算预测值与实测值之间的平均百分比误差(mean absolute percent error,MAPE)和均方根误差(mean absolute error,MAE)对结果进行误差分析和评价,结果如表 4 所示. MAPE 和 MAE 计算公式分别为

$$E_{\text{MAP}} = \frac{1}{m} \sum_{i=1}^m \left| \frac{x_i - \hat{x}_i}{x_i} \right|, \quad \left. \vphantom{\sum} \right\} \quad (16)$$
$$E_{\text{MA}} = \frac{1}{m} \sum_{i=1}^m |x_i - \hat{x}_i|^2.$$

式(16)中: E_{MAP} 为平均百分比误差; E_{MA} 为均方根误差; x_i 表示第*i*个样本实际值; \hat{x}_i 表示第*i*个样本预测值; m 表示预测样本个数.

表 4 四种优化算法的误差对比

Tab.4 Comparison of errors in four optimization algorithms

预测模型	参数	LOW	R	UP
GWO-SVM	E_{MA}	0.118 8	0.145 5	0.128 6
	E_{MAP}	0.005 4	0.006 1	0.004 3
PSO-SVM	E_{MA}	0.140 5	0.184 5	0.144 5
	E_{MAP}	0.009 5	0.008 1	0.007 2
GA-SVM	E_{MA}	0.150 5	0.172 3	0.132 1
	E_{MAP}	0.007 7	0.007 1	0.006 9
GS-SVM	E_{MA}	0.218 8	0.233 7	0.194 8
	E_{MAP}	0.012 1	0.009 8	0.008 2

采用 MAPE 和 MAE 估算模型对不同数量级样例的拟合程度,其中,MAPE 和 MAE 的数值越小,表示拟合精度越高.通过表 4 可知:GWO-SVM 算法的预测精度最高,说明经过基于 GWO-SVM 算法的参数寻优效果优于其他参数寻优算法,即 GWO-SVM 算法提高了模型的预测精度和效果.

4.3 区间预测效果的评价

为验证模型的区间预测效果,在不同相对宽度(90%,70%)下实现短期风速区间预测.调整相对宽度的方式计算式为

$$\left. \begin{aligned} U(x_i)^{(1-\alpha)} &= R(x_i) + (U(x_i) - R(x_i)) \times (1-\alpha), \\ L(x_i)^{(1-\alpha)} &= R(x_i) + (L(x_i) - R(x_i)) \times (1-\alpha). \end{aligned} \right\} \tag{17}$$

式(17)中: $1-\alpha$ 为相对宽度; $U(x_i)$ 为第*i*个预测样本的原始上界; $L(x_i)$ 为第*i*个预测样本的原始下界; $U(x_i)^{(1-\alpha)}$ 为相对宽度 $1-\alpha$ 下第*i*个预测样本的上界; $L(x_i)^{(1-\alpha)}$ 为相对宽度 $1-\alpha$ 下第*i*个预测样本的下界.模型的区间预测效果及其对应方框框出的范围放大后的区间预测结果,如图 5 所示.图 5 中: $N_{5\min}$ 表示每 5 min 为采样点的数.

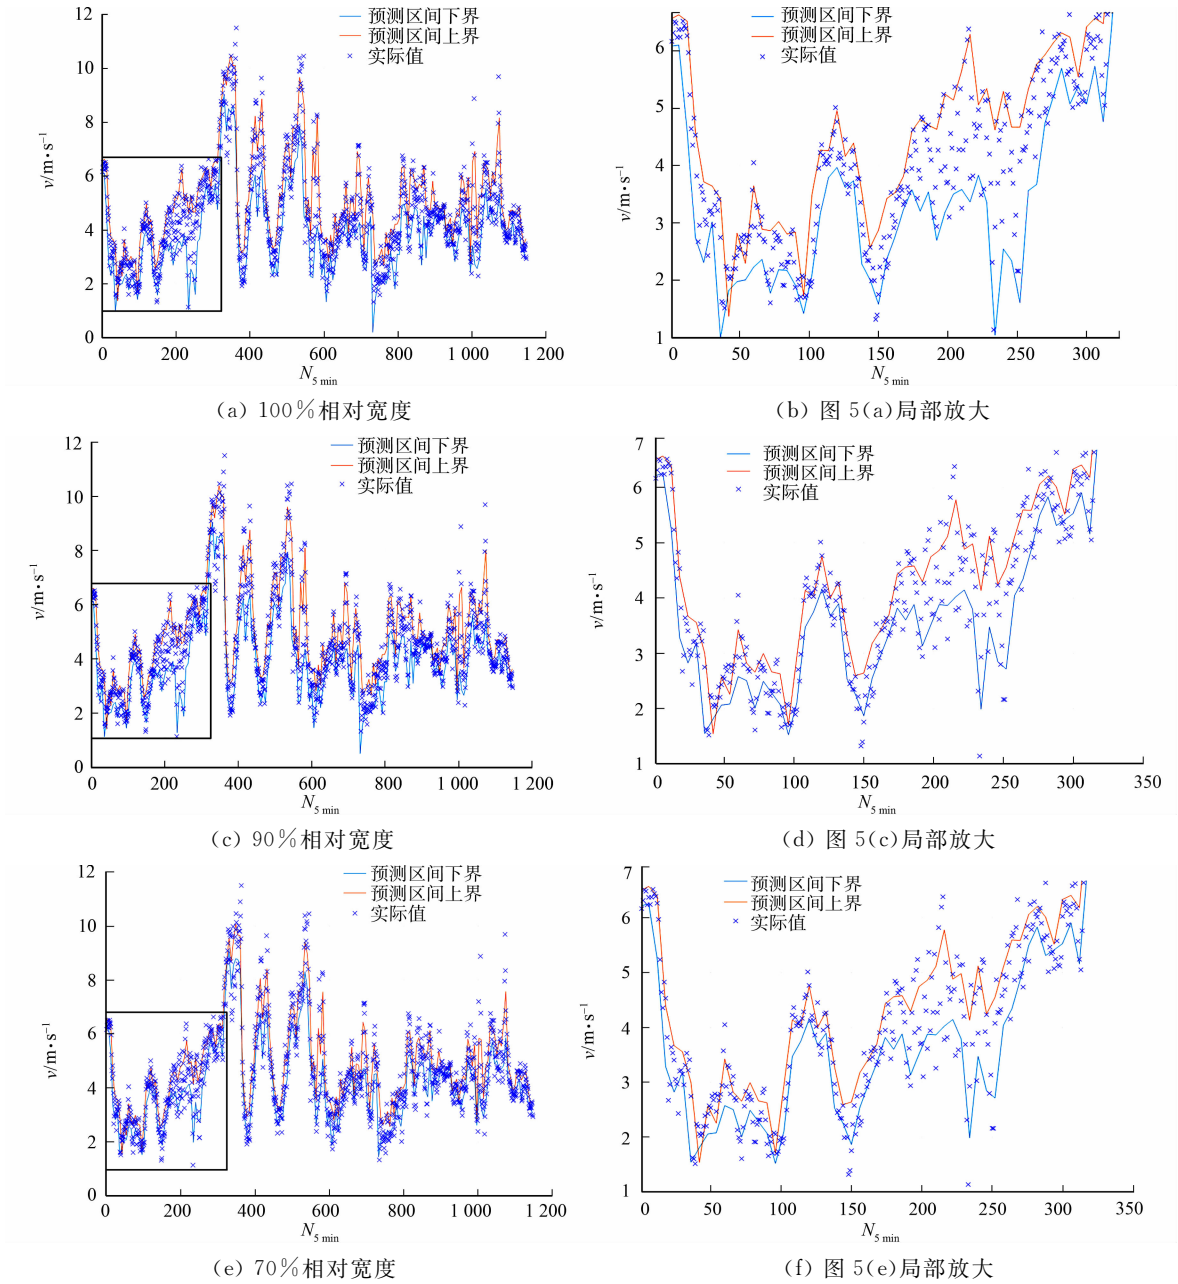


图 5 不同相对宽度下的风速区间预测结果

Fig. 5 Wind speed interval prediction results under different relative widths

采用如下几个指标对区间预测效果进行评价.

1) 区间覆盖率(forecasting interval coverage percentage,FICP). FICP 用于评价区间的可信程度, 其值越大,可信度就越高,其计算式为

$$p_{\text{FIC}}^{(1-\alpha)} = \frac{1}{m} \xi^{(1-\alpha)} \times 100\%.$$

(18)

式(18)中: $p_{\text{FIC}}^{(1-\alpha)}$ 为区间覆盖率; m 表示预测样本个数; $\xi^{(1-\alpha)}$ 为相对宽度 $1-\alpha$ 下实际值落在预测区间内的个数.

2) 区间平均宽度(forecasting interval average width,FIAW). FIAW 用于评价预测结果描述不确定信息的能力,其值越小,效果就越好,其计算式为

$$W_{\text{FIA}}^{(1-\alpha)} = \frac{1}{m} \sum_{i=1}^m \frac{U(x_i)^{(1-\alpha)} - L(x_i)^{(1-\alpha)}}{x_i}.$$

(19)

式(19)中: $W_{\text{FIA}}^{(1-\alpha)}$ 为相对宽度 $1-\alpha$ 下的区间平均宽度; $U(x_i)^{(1-\alpha)}$, $L(x_i)^{(1-\alpha)}$ 分别为相对宽度 $1-\alpha$ 下第 i 个预测样本的上界和下界; x_i 表示第 i 个样本实际值.

不同相对宽度(W)下区间预测效果指标,如表 5 所示.

由图 5 和表 5 的预测效果指标可以得出以下两点结论:

1) 文中所提模型的风速预测范围区间能够有效包含实际值,其上下浮动趋势与实际风速变化情况基本一致;2) 在进行区间相对宽度调节后,发现存在极少风速实际值落在相对宽度 100%下的预测区间之外,风速实际值大部分都落在相对宽度 90%下的预测区间之内,少部分落在相对宽度 70%下的预测区间之外,满足实际情况,体现了文中所提模型的有效性.

各预测模型的指标评价结果,如表 6 所示.由表 6 可知:总体上,文中所提出的模型的预测区间的区间平均宽度最窄,区间覆盖率最高,GWO-SVM 预测的区间预测效果较为理想.

综上所述,所提的基于模糊信息粒化和 GWO-SVM 算法的短期风速范围预测模型可实现短期风速的区间预测,且预测效果较好.

5 结论

基于时间序列预测法和模糊信息粒化方法,提出对风速范围区间预测的方法,并建立模糊信息粒化和 GWO-SVM 算法的风速范围预测模型.通过算例分析,得出以下 2 点主要结论.

1) 由于针对时间序列分布的风速预测具有偶然性,文中所提出的模糊信息粒化的风速范围预测模型,通过模糊信息粒化提取一定时间内风速的特征信息,对特征信息进行预测,从而实现对风速范围区间的预测.

2) 通过与其他算法的误差对比,证明利用灰狼算法进行参数寻优能有效地提高支持向量机对风速范围预测的精度.

基于模糊信息粒化和 GWO-SVM 算法的风速范围预测方法具有较高的预测精度,风速范围的准确预测对风力发电功率的准确预测具有重要的意义.因此,该预测方法具有良好的应用价值.

参考文献:

[1] 向玲,邓泽奇,赵玥.基于 LPF-VMD 和 KELM 的风速多步预测模型[J].电网技术,2019,43(12):4461-4467. DOI: 10.13335/j.1000-3673.pst.2019.0176.

[2] 李大中,李颖宇,王超.基于卷积神经网络深度学习的短期风速预测[J].电力科学与工程,2019,35(8):1-6. DOI:10.3969/j. ISSN.1672-0792.2019.08.001.

[3] 陈金富,朱乔木,石东源,等.利用时空相关性的多位置多步风速预测模型[J].中国电机工程学报,2019,39(7):

2093-2106. DOI:10.13334/j.0258-8013.pcsee.180897.

[4] ZHANG Ye, YANG Shiping, GUO Zhenhai, *et al.* Wind speed forecasting based on wavelet decomposition and wavelet neural networks optimized by the Cuckoo search algorithm[J]. Atmospheric and Oceanic Science Letters, 2019, 12(2):107-115. DOI:10.1080/16742834.2019.1569455.

[5] 赵征, 汪向硕, 乔锦涛. 基于 VMD 和改进 ARIMA 模型的超短期风速预测[J]. 华北电力大学学报, 2019, 46(1):54-59. DOI:10.3969/j.issn.1007-2691.2019.01.08.

[6] 常雨芳, 张力, 谢昊, 等. 采用小波分析和神经网络的短期风速组合预测[J]. 华侨大学学报(自然科学版), 2019, 40(4):556-560. DOI:10.11830/ISSN.1000-5013.201806023.

[7] 张维, 高明明, 洪烽, 等. 基于 BP-SVM 模糊信息粒化掺烧煤泥循环流化床经济性建模[J]. 中国电机工程学报, 2018, 38(4):1093-1100, 1286. DOI:10.13334/j.0258-8013.pcsee.170432.

[8] 余鹏, 唐权, 张文涛, 等. 基于高斯模糊信息粒化和改进小波神经网络的短期负荷区间预测研究[J]. 机电工程, 2017, 34(2):167-172. DOI:10.3969/j.issn.1001-4551.2017.02.013.

[9] 徐继亚, 王艳, 严大虎, 等. 融合 KPCA 与信息粒化的滚动轴承性能退化 SVM 预测[J]. 系统仿真学报, 2018, 30(6):2345-2354. DOI:10.16182/j.issn1004731x.joss.201806043.

[10] 李建强, 张莹莹, 牛成林. 基于 PSO-LSSVM 模型的火电厂烟气含氧量预测[J]. 热能动力工程, 2018, 33(7):49-55. DOI:10.16146/j.cnki.rndlgc.2018.07.009.

[11] 徐晶, 迟福建, 葛磊蛟, 等. 基于 SARIMA-GRNN-SVM 的短期商业电力负荷组合预测方法[J]. 电力系统及其自动化学报, 2020, 32(2):85-91. DOI:10.19635/j.cnki.csu-epsa.000353.

[12] 鲍毅, 戴波, 汪志华, 等. 基于灰狼算法的多目标智能家居负荷控制算法[J]. 系统仿真学报, 2019, 31(6):1216-1222. DOI:10.16182/j.issn1004731x.joss.17-0188.

[13] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69(3):46-61. DOI:10.1016/j.advengsoft.2013.12.007.

[14] MIRJALILI S. How effective is the grey wolf optimizer in training multi-layer perceptrons[J]. Applied Intelligence, 2015, 43(1):150-161. DOI:10.1007/s10489-014-0645-7.

[15] 马小平, 李博华, 张旭, 等. 基于 GWO 优化的 CS-SVM 轴承故障诊断[J]. 煤矿机械, 2019, 40(5):171-173. DOI:10.13436/j.mkjx.201905056.

[16] 柳长安, 王晓鹏, 刘春阳, 等. 基于改进灰狼优化算法的无人机三维航迹规划[J]. 华中科技大学学报(自然科学版), 2017, 45(10):38-42. DOI:10.13245/j.hust.171007.

[17] 王盛, 杨信丰. 基于 EEMD-GWO-LSSVM 的公共交通短期客流预测[J]. 计算机工程与应用, 2019, 55(20):216-221, 239. DOI:10.3778/j.issn.1002-8331.1903-0262.

[18] 廖康, 吴益平, 李麟玮, 等. 基于时间序列与 GWO-ELM 模型的滑坡位移预测[J]. 中南大学学报(自然科学版), 2019, 50(3):619-626. DOI:10.11817/j.issn.1672-7207.2019.03.015.

[19] 廖小平, 黎宇嘉, 陈超逸, 等. 基于核主成分和灰狼算法的刀具磨损状态识别[J/OL]. 计算机集成制造系统, [2019-08-19]. <http://kns.cnki.net/kcms/detail/11.5946.TP.20190817.1232.002.html>.

[20] 朱敬旭辉, 赵景波, 薛秉鑫. 基于灰狼算法优化 PID 的机器人路径跟踪控制[J]. 电子技术与软件工程, 2019(21):69-71.

(责任编辑: 黄仲一 英文审校: 吴逢铁)