

基于风速局部爬坡误差校正的风电功率优化预测

肖逸^{1,2}, 李程煌³, 刘若平^{1,2}, 左剑⁴, 李银红^{1,2}

(1. 华中科技大学 电气与电子工程学院 强电磁工程与新技术国家重点实验室, 湖北 武汉 430074;

2. 华中科技大学 电气与电子工程学院 电力安全与高效湖北省重点实验室, 湖北 武汉 430074;

3. 长江勘测规划设计研究有限责任公司, 湖北 武汉 430010;

4. 广东电网有限责任公司电力调度控制中心, 广东 广州 510600)

摘要: 准确的风电功率预测对于电力系统安全稳定运行具有重要意义, 滞后性是产生风电功率预测误差的主要原因, 尤其是风速变化较快时, 滞后性引起的预测误差较大。考虑到风速波动与风电功率的变化息息相关, 提出一种基于风速局部爬坡(LR)误差校正的方法来改善预测风速的滞后性, 并将校正后的预测风速及历史功率数据作为输入进行风电功率预测。提出利用灰狼优化(GWO)算法对最小二乘支持向量机(LSSVM)的参数进行优化, 以提高风电功率预测的准确性。算例结果表明, 所提方法能够有效提高风电功率预测精度。

关键词: 风电功率预测; 预测风速; 滞后性; 局部爬坡误差校正; 最小二乘支持向量机; 灰狼优化

中图分类号: TM 761

文献标识码: A

DOI: 10.16081/j.issn.1006-6047.2019.03.029

0 引言

近年来, 以风电为代表的新能源发电得到了大力发展。由于风电出力具有间歇性和波动性^[1], 风电功率难以准确预测。随着大规模风电机组并网, 超短期风电功率预测在电力系统安全可靠运行和经济调度等方面具有愈加重要的影响。

超短期风电功率预测方法可分为2类, 即物理法和基于历史数据外推法的方法^[1]。物理法中, 在计算得到预测风速、风向等信息后, 需利用风速功率曲线得到预测功率。文献[2]表明, 基于历史数据外推方法的精度要高于物理法。常见基于历史数据外推法的方法主要有时间序列法^[3]、人工神经网络ANN(Artificial Neural Network)^[2]、支持向量机SVM(Support Vector Machine)^[4]及混合预测算法^[5]等, 其中ANN和SVM应用最为广泛。最小二乘支持向量机LSSVM(Least Square Support Vector Machine)是改进常规SVM后的预测算法, 其用等式约束取代传统SVM的不等式约束, 将二次规划问题转变为线性方程组求解的问题^[6], 进一步简化了计算。

目前已有较多文献针对预测算法进行改进以提高预测精度^[7]。然而, 仅对预测算法进行改进无法改善预测固有的滞后性问题。因此, 国内外学者采用组合预测的方法以期得到满意的效果。文献[8]提出采用小波神经网络的方法进行分层预测, 但其并不能保证ANN每次训练均能达到最优, 且叠加后的预测误差大小存在偶然性; 文献[9]提出利用相似数据来提高SVM的预测精度, 但风速波动具有随机性, 利用相似数据所能提升的精度有限。考虑到风电场的风电功率与风速存在很强的关联性, 已有

文献在采用历史数据外推方法时, 将精确的风速作为风电功率预测的输入, 并取得了较好的预测效果^[10]。因此, 若能改善预测风速的滞后性, 提高预测风速精度, 则能改善功率预测的滞后性。

此外, 对于LSSVM算法精度问题, 尚有改进空间。LSSVM核参数及正则化参数的选取, 对训练和预测结果有较大影响, 且两参数具有关联性^[6]。因此, 本文考虑引入具有较强寻优能力的灰狼优化GWO(Grey Wolf Optimization)算法来优化其参数。文献[11]通过多个算例验证了GWO算法的准确性。目前, GWO已被应用于ANN权值优化^[12]、电力系统稳定控制参数调整^[13]和经济调度^[14]等方面, 均取得了良好的效果。因此, 本文提出利用GWO优化LSSVM(GWO_LSSVM)方法来提高风电功率的预测精度。

基于此, 本文以历史数据外推方法为基础, 结合物理法, 提出一种基于风速局部爬坡LR(Local Ramp)误差校正的风电功率优化预测模型。首先利用局部爬坡误差校正方法判别并改善发生局部爬坡时预测风速的滞后性, 接着将校正后的风速作为风电功率预测输入的一部分, 再利用具有较强寻优能力的GWO_LSSVM方法实现对风电功率的预测。算例结果表明, 将局部爬坡误差校正与GWO优化预测方法相结合的风电功率预测效果最优。

1 局部爬坡误差校正

若风速在短时间内持续上升或下降, 则预测会表现出明显的滞后性。为充分校正风速预测误差, 提出了一种风速局部爬坡误差校正方法。

1.1 历史数据外推预测的滞后性

采用历史数据外推法对风电场风速序列进行预

测,预测结果如图1所示。图中采样点间时间间隔为5 min(后文未特别说明均与此相同)。

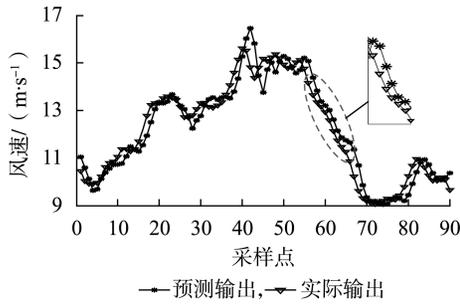


图1 风速预测实例

Fig.1 Example of wind speed prediction

由图1可以看出,预测输出曲线可近似看作实际输出向后平移了一个单位,这种预测结果在时间尺度上的延迟称为滞后性。由图1放大部分可以看出,当风速变化较快时,预测误差较大。

1.2 局部爬坡的定义

在图1中,预测时段可分为3个阶段,包括平稳波动阶段、非平稳波动阶段和爬坡阶段。平稳波动阶段风速波动趋势不定、变化幅度小,如采样点71—80;非平稳波动阶段风速波动趋势不定、变化幅度大,如采样点40—55;爬坡阶段风速波动趋势明确、变化幅度大,如采样点56—70。

常见的爬坡定义如式(1)—(3)所示^[15]。

$$|V(t_0+T) - V(t_0)| > V_{val} \quad (1)$$

$$\max(V(t)) - \min(V(t)) > V_{val} \quad t \in [t_0, t_0+T] \quad (2)$$

$$\frac{|V(t_0+T) - V(t_0)|}{T} > V_{val} \quad (3)$$

其中, $V(t_0)$ 为 t_0 时刻的风速值; V_{val} 为风速爬坡的门槛值; $\max(V(t))$ 为 $t \in [t_0, t_0+T]$ 内风速的最大值, $\min(V(t))$ 为 $t \in [t_0, t_0+T]$ 内风速的最小值。

由式(1)—(3)可知,判断风速爬坡事件发生与否与时间间隔 T 的选取有关。若 T 选取较长,则会忽略时间间隔小于 T 的小爬坡事件。为充分捕捉小爬坡事件,将式(1)—(3)中 T 取为2个采样间隔,称此时的爬坡事件为局部爬坡,其定义可表示为:

$$k_{up}(t-1) - k_{up}(t) \leq k_{val_up} \quad (4)$$

$$k_{down}(t) - k_{down}(t-1) \leq k_{val_down} \quad (5)$$

其中, $k_{up}(t)$ 为风速增大阶段 t 时刻风速实际值与 $t-1$ 时刻风速实际值连线的斜率, $k_{up}(t) > 0$; $k_{down}(t)$ 为风速下降阶段 t 时刻风速实际值与 $t-1$ 时刻风速实际值连线的斜率, $k_{down}(t) < 0$; k_{val_up} 为风速增大阶段局部爬坡门槛值; k_{val_down} 为风速下降阶段局部爬坡门槛值。

由图1不难看出,平稳波动阶段风速波动较小,不包含局部爬坡过程;非平稳波动阶段风速波动较大,包含部分局部爬坡过程;而爬坡阶段包含大量局部

爬坡过程。局部爬坡与各阶段之间的关系如图2所示。

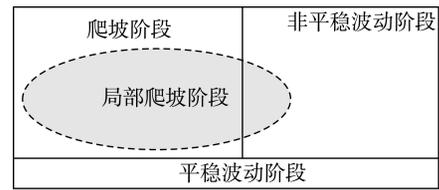


图2 风速预测各阶段包含关系

Fig.2 Relation among each stage of wind speed prediction

1.3 局部爬坡误差校正方法

本文提出的局部爬坡误差校正可用如下参数寻优问题描述。

a. 当风速处于局部爬坡过程,即满足式(4)、式(5),此时进行风速预测,预测滞后性明显,预测曲线与实际曲线近似平行,如图3所示。在这种情况下,可以通过叠加前一时间刻预测误差进行校正,以减小当前时刻预测风速的误差,即:

$$\tilde{V}(t+1) = \tilde{V}_{pre}(t+1) + e(t) \quad (6)$$

其中, $\tilde{V}_{pre}(t+1)$ 为 $t+1$ 时刻校正前的风速预测值; $\tilde{V}(t+1)$ 为 $t+1$ 时刻校正后的风速预测值; $e(t)$ 为 t 时刻的预测误差。

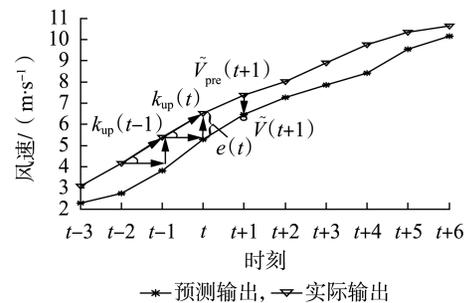


图3 局部爬坡误差校正示意图

Fig.3 Schematic diagram of local ramp error correction

b. 当风速爬坡变化率绝对值减小,如图4中的采样点5,有:

$$k_{up}(t-1) - k_{up}(t) > k_{val_up} \quad (7)$$

$$k_{down}(t) - k_{down}(t-1) > k_{val_down} \quad (8)$$

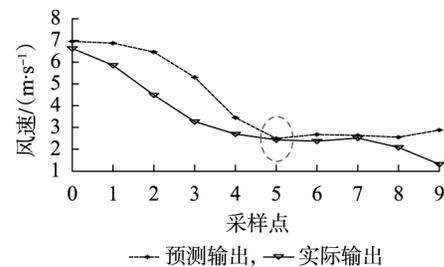


图4 局部爬坡速率减小示意图

Fig.4 Schematic diagram of local ramp speed decrease

此时预测值与真实值间的误差较小,若仍采用式(6)进行校正,则会导致风速预测误差增大。因此,在这种情况下不进行误差校正,即:

$$\tilde{V}(t+1) = \tilde{V}_{\text{pre}}(t+1) \quad (9)$$

c. 当风速处于平稳波动阶段时, 满足:

$$|k(t-1)| < k_{\text{val}} \quad (10)$$

$$|k(t)| < k_{\text{val}} \quad (11)$$

其中, $k(t)$ 为 t 时刻实际值与 $t-1$ 时刻实际值连线的斜率; k_{val} 为非局部爬坡校正门限值。

此时风速预测结果滞后性不明显, 若采用式(6)进行校正, 也可能导致预测误差增大。因此, 在这种情况下也不进行误差校正。

在对风速预测值进行校正, 改善风速预测的滞后性后, 进一步即可利用优化算法改进 LSSVM 以进一步提高风电功率预测精度。

2 含风速的 LSSVM 风电功率预测方法

LSSVM 是对 SVM 的一种改进, 提高了求解问题的速度和收敛精度^[6]。利用 LSSVM 进行风电功率预测的基本思想为: 先通过对 LSSVM 网络进行训练, 得出 LSSVM 网络的回归方程表达式; 再基于历史数据进行外推, 利用所得回归方程得到预测时刻的风电功率值。

2.1 预测模式

考虑到风速与风电功率之间较强的关联性, 将校正后的预测风速值作为已知量输入网络中以获得更加准确的结果, 具体流程如图 5 所示。



图 5 含风速的风电功率预测

Fig.5 Wind power prediction with wind speed

2.2 LSSVM 基本原理

LSSVM 中的优化目标采用了平方项, 将不等式约束转化为等式约束, 将较复杂的二次规划问题转化为较简单的线性方程组求解问题, 可引入拉格朗日函数求解。

3 GWO 算法寻优理论

LSSVM 核参数与正则化参数的选取对训练和预测结果有较大影响, 且两参数具有关联性, 故考虑引入寻优能力较强的 GWO 算法来优化其参数。

3.1 社会等级

整个种群按等级高低分为 α 、 β 、 δ 、 ω 这 4 种寻优种群。 α 的位置为最优解, β 的位置为次优解, δ 的位置为次次优解, ω 为搜索种群。

3.2 环绕猎物

在寻优过程中, 寻优种群通过环绕猎物来寻找狩猎的最佳路线。高等级种群命令向量 D 和寻优个体下一步移动向量 $X(n+1)$ 可分别由式(12)、式(13)确定。

$$D = |CX_p(n) - X(n)| \quad (12)$$

$$X(n+1) = X_p(n) - AD \quad (13)$$

其中, n 为当前迭代次数; A 和 C 为系数向量; $X_p(n)$ 为高等级种群的方向向量; $X(n)$ 为搜索种群 ω 的当前位置向量。

由式(12)和式(13)可以看出, 命令向量由高等级种群相对于搜索种群 ω 的方位 $X_p(n)$ 以及搜索种群 ω 自身的位置 $X(n)$ 共同确定, 而搜索种群 ω 的下一步移动方向则由高等级种群相对于搜索种群 ω 的方位 $X_p(n)$ 及命令向量 D 共同确定。系数向量 A 和 C 可分别由式(14)、式(15)表示。

$$A = 2ar_1 - a \quad (14)$$

$$C = 2r_2 \quad (15)$$

其中, a 为系数向量, 其模值随迭代次数的增加由 2 线性减小到 0; r_1 和 r_2 的模为 $[0, 1]$ 之间的随机数。

由式(14)、式(15)可以看出, 最优解周围点的位置均可通过调整 A 和 C 这 2 个系数向量的值搜索到。此外, 由于 $|r_1|$ 和 $|r_2|$ 均是区间 $[0, 1]$ 内的随机数, 寻优种群可遍历查找进攻目标的路径。

3.3 进攻

在进攻阶段, 种群 ω 根据种群 α 、 β 和 δ 所给出的信息进行下一步移动, 即靠近目标或远离目标。进攻过程可由式(16)~(18)表示。

$$\begin{cases} D_\alpha = |C_1 X_\alpha - X(n)| \\ D_\beta = |C_2 X_\beta - X(n)| \\ D_\delta = |C_3 X_\delta - X(n)| \end{cases} \quad (16)$$

$$\begin{cases} X_1 = X_\alpha - A_1 D_\alpha \\ X_2 = X_\beta - A_2 D_\beta \\ X_3 = X_\delta - A_3 D_\delta \end{cases} \quad (17)$$

$$X(n+1) = \frac{X_1 + X_2 + X_3}{3} \quad (18)$$

其中, D_α 、 D_β 、 D_δ 分别为种群 α 、 β 、 δ 与种群 ω 间的方向向量; C_1 、 C_2 、 C_3 与 A_1 、 A_2 、 A_3 分别为种群 α 、 β 、 δ 的系数向量; X_α 、 X_β 、 X_δ 分别为种群 α 、 β 、 δ 所在位置与目标的方向向量; X_1 、 X_2 、 X_3 分别为种群 α 、 β 、 δ 命令种群 ω 下一步移动的方向向量。

式(16)、式(17)分别为式(12)、式(13)的具体形式, 表示种群 α 、 β 、 δ 分别对种群 ω 下达命令的过程, 而种群 ω 最终会利用式(18)来权衡三者的命令向量, 以确定自身的进攻方向。完成进攻后, 再进行下一轮进攻。由此可见, 3.2 节中的环绕过程即为每次进攻过程的总和。

4 基于风速局部爬坡误差校正的风电功率优化预测方法

本文提出的风电功率预测方法首先需要利用局

部爬坡误差校正得到改善滞后性的预测风速及风向,然后结合历史风速风向数据,利用 GWO_LSSVM 对风电功率进行预测。

4.1 风速预测拐点校正处理方法

图 6 为风速拐点示意图,如图中所示的 2 个拐点时刻,风速时间序列在一个采样周期内出现了较大转折,这种情况在采样频率较低时容易出现。受预测滞后性影响,拐点处风速预测误差较小,此时进行误差校正可能导致风速预测误差增大,故在风速发生较大转折时,不进行校正。因此,需要对拐点进行识别。

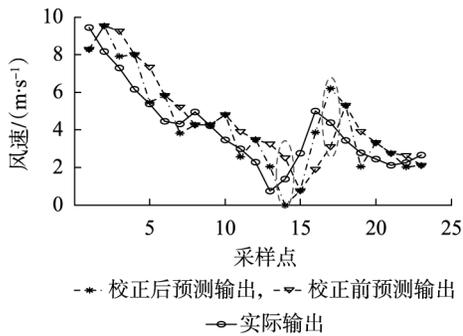


图 6 风速拐点示意图

Fig.6 Schematic diagram of wind speed turning point

受风速的物理特性和地形影响,空间相关点之间的风速时间序列具有很强的关联性和延时性^[16],因此,可以利用地理位置相近的风电场特性来推断目标风电场特性。风电场之间的相关关系需借助相关系数来判断。Kendall 系数表示随机变量间的变化趋势一致相关性^[17],因此,本文选取 Kendall 系数为判断依据,以此确定目标风速序列与已知风速序列的最佳时延。其表达式为:

$$\tau = P[(x_i - x_j)(y_i - y_j) > 0] - P[(x_i - x_j)(y_i - y_j) < 0] \quad (19)$$

其中, x_i, x_j 分别为图 6 中某 2 个采样点 i, j 对应数据的横坐标之差; y_i, y_j 分别为采样点 i, j 对应数据的纵坐标之差; $P[\cdot]$ 表示求概率。

4.2 局部爬坡误差校正阈值求解方法

阈值的选取对于局部爬坡误差校正结果具有重要影响,本文对阈值的选取方法采用参数寻优的方式,局部爬坡校正过程分为如下 3 步。

a. 利用 LSSVM 及历史风速数据进行风速预测,并记录各时刻的真实值、预测值及预测误差。

b. 将阈值 k_{val_up}, k_{val_down} 及 k_{val} 设为自变量,利用式(4)~(11)对风速预测值进行局部爬坡识别与校正。以局部爬坡校正后预测误差的平均绝对百分比误差 MAPE (Mean Absolute Percentage Error) 最小为目标函数,利用优化算法(本文采用 GWO 算法)进行求解,可得各阈值。

c. 利用步骤 b 得到的各阈值对后续风速预测

值进行局部爬坡误差校正。

4.3 含风速局部爬坡误差校正的风电功率优化预测流程

结合前面提到的各个问题,基于局部爬坡误差校正的风速预测及 GWO_LSSVM 方法的步骤可概括为训练和预测 2 个过程。图 7 为基于风速局部爬坡误差校正的风电功率优化预测的完整流程。其中,风向预测与风速预测类似,仅将输入变量由风速改为风向。图 7 中, γ 与 σ 分别为 LSSVM 的正则化参数及核参数,其具体含义详见文献[6], F_1, F_2 均以 MAPE 最小为目标。

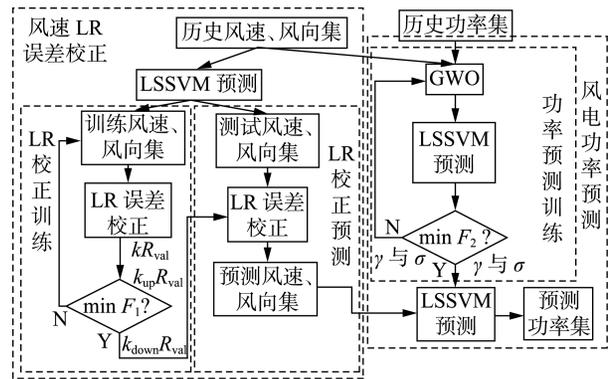


图 7 含风速局部爬坡误差校正的风电功率优化预测流程

Fig.7 Flowchart of optimal wind power prediction with local ramp error correction

5 算例分析

5.1 算例说明

选取美国加利福尼亚州某地区地理位置相近的多座风电场的风速及风电功率数据。该风电场群额定功率为 16 MW,各风电场的历史风速序列如图 8 所示。

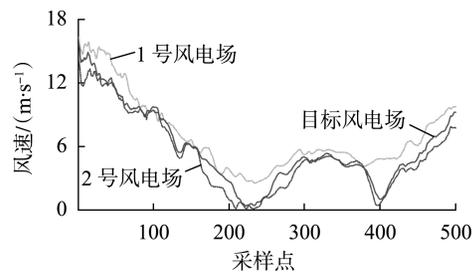


图 8 相邻风电场风速变化曲线

Fig.8 Wind speed variation of adjacent wind farms

5.2 评价指标

本文采用 MAPE 和均方根误差 RMSE (Root Mean Squared Error) 作为评价指标,表达式分别为:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|p_i - p'_i|}{p'_i} \quad (21)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (p_i - p'_i)^2}{N}} \quad (22)$$

其中, N 为预测样本数; p_i 为预测值; p_i' 为真实值。

5.3 风速预测结果

首先,需确定预测时段的相似风速段,即确定相邻风电场提前该风电场的最优时延。图 9 为目标风电场与各地理位置相近的风电场风速序列 Kendall 系数曲线,延迟步长选为 0—50,步长间间隔 5 min,样本为预测时刻前 100 个采样点。由图 9 可以看出,在延迟步长为 15 步时,Kendall 相关系数达到最大,表明此时目标风电场风速段与该风电场此段风速相关性最高。因此在该预测时段应取 1 号风电场为参考风电场,最优延迟步长取 15 步,即时间间隔为 75 min。

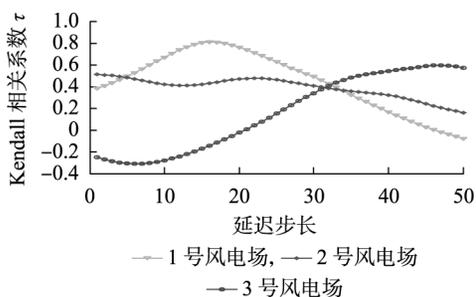


图 9 确定最优步长

Fig.9 Best step determination

接着,需对风速局部爬坡误差校正的各门槛值进行求解。采用 4.2 节所介绍的方法,本算例所选取的历史风速数据、预测值及预测误差样本容量为 1 000,分别对提前 5 min、10 min、15 min 及 30 min 的预测风速进行局部爬坡识别与误差校正,寻优所得参数值如表 1 所示,各预测尺度下的风速预测结果如表 2 所示。

表 1 风速局部爬坡误差校正参数

Table 1 Parameters of local ramp error correction for wind speed

预测尺度/ min	$k_{val_up}/$ ($m \cdot min^{-2}$)	$k_{val_down}/$ ($m \cdot min^{-2}$)	$k_{val}/$ ($m \cdot min^{-2}$)
5	0.052	0.045	0.012
10	0.044	0.042	0.002
15	0.071	0.115	0.005
30	0.110	0.201	0.005

表 2 风速预测结果

Table 2 Results of wind speed prediction

预测尺度/ min	预测方法	MAPE/%	RMSE/($m \cdot s^{-1}$)
5	LSSVM	5.322	0.844 3
	LR 误差校正法	3.423	0.618 7
10	LSSVM	7.431	0.593 8
	LR 误差校正法	3.902	0.328 3
15	LSSVM	8.989	0.422 5
	LR 误差校正法	7.484	0.330 8
30	LSSVM	26.09	0.780 2
	LR 误差校正法	16.56	0.615 5

提前 10 min 的预测局部爬坡校正结果如图 10

所示。为显示清晰,截取预测时段中 30 个采样点的结果。

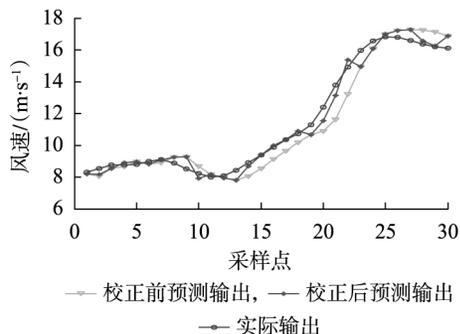


图 10 提前 10min 风速预测

Fig.10 Wind speed prediction with 10 min in advance

与预测风速类似,分别对预测风向进行局部爬坡识别与校正,预测结果详见附录。在求得最优步长后,便可对相邻风电场预测风速拐点进行识别与校正,如图 11 所示,图中给出了时间尺度为 30 min 时的校正结果。可以看出,在风速发生转折时,采用相邻风电场风速辅助判断可减少部分拐点的预测误差。

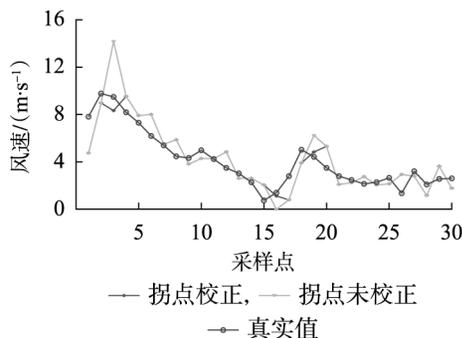


图 11 拐点校正结果

Fig.11 Results of turning point correction

5.4 风电功率预测结果

得到校正后的风速与风向预测结果后,可利用预测时刻的风速、风向以及历史功率数据对预测时刻的风电功率进行预测。其中历史功率数据均选取预测时刻前 9 个时刻的数据,算例考虑以下 5 种情形。

情形 1:利用未进行局部爬坡误差校正的风速及风向序列进行 ANN 风电功率预测。

情形 2:利用未进行局部爬坡误差校正的风速及风向序列进行 LSSVM 风电功率预测。

情形 3:利用局部爬坡校正后的风速及风向序列进行 LSSVM 风电功率预测。

情形 4:利用未进行局部爬坡误差校正的风速、风向序列及 GWO_LSSVM 进行风电功率预测。

情形 5:利用本文方法,即局部爬坡校正后的风速、风向序列及 GWO_LSSVM 进行风电功率预测。

各预测尺度下的风电功率预测结果如表 3 及表

4所示。其中提前10 min功率预测结果如图12所示。

表3 提前10 min风电功率预测结果

Table 3 Results of wind power prediction with 10 min in advance

情形	MAPE/%	RMSE/MW
1	16.970	1.246
2	15.990	1.294
3	7.882	0.697
4	15.670	1.314
5	5.103	0.428

表4 提前30 min风电功率预测结果

Table 4 Results of wind power prediction with 30 min in advance

情形	MAPE/%	RMSE/MW
1	21.870	1.990
2	23.200	2.117
3	10.740	0.840
4	22.840	2.095
5	7.930	0.680

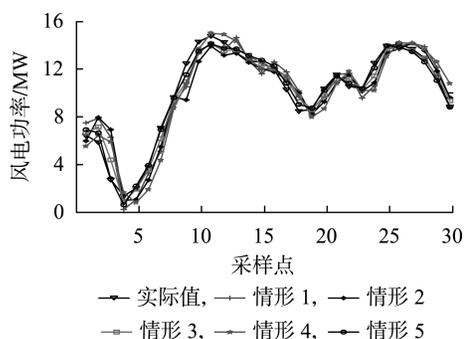


图12 提前10 min风电功率预测

Fig.12 Wind power prediction with 10 min in advance

由此可以得出以下结论。

a. 本文所提将局部爬坡误差校正与GWO_LSSVM相结合的方法所得风电功率预测误差最小,且局部爬坡误差校正对预测精度提升效果明显。

b. 情形2和情形4均未进行滞后性校正,预测误差均较大,造成这种结果的原因并非是优化算法的寻优能力较差,而是在预测存在滞后性时,随着预测时段或情况的改变,寻优算法无法确定何时才达到最优解,且发生风速或功率的巨大波动时,由于GWO算法无法从已训练的样本中得到下一时刻的信息,输入输出值关联性较小,所得到的解未必是最优解,因此可能会产生较大误差。因此,在进行风电功率预测时,应在优化之前对输入变量进行处理,改善训练及预测时的滞后性,才能发挥GWO算法较强的寻优能力,以得到更精确的结果。

c. ANN与LSSVM均为风电功率预测的有效途径,但从算例结果可以看出,两者均存在明显的滞后性,这是基于历史数据外推方法普遍存在的问题。表3、表4表明本文所提方法具有优越性,且算例耗

时在100 s之内,能较好地满足实时性要求。

6 结论

本文基于历史数据外推法,提出了风速局部爬坡误差校正方法,并建立了GWO_LSSVM风电功率预测模型。通过算例分析得出以下结论。

a. 针对基于历史数据外推的风速及功率预测普遍存在的滞后性问题,本文提出了一种局部爬坡误差校正模型。经算例验证,该方法在发生风速局部爬坡时能够显著提高预测风速的精度,且局部爬坡误差校正方法不受预测算法的限制,可在利用各种预测手段得到的结果上进行校正,具有普适性。

b. 实验结果表明,在利用局部爬坡误差校正改善了风速预测滞后性问题之后,GWO_LSSVM方法能够有效提高风电功率预测精度。

c. 在预测时间尺度大、采样频率低的情况下,在风速或功率拐点处的信息可能遗失,因此在极少数点可能造成局部爬坡误差校正的提升效果不显著。该方法预测精度还有待进一步提高,研究工作还需进一步开展。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 薛禹胜,郁琛,赵俊华,等. 关于短期及超短期风电功率预测的评述[J]. 电力系统自动化,2015,39(6):141-151.
XUE Yusheng, YU Chen, ZHAO Junhua, et al. A review on short-term and ultra-short-term wind power prediction [J]. Automation of Electric Power Systems, 2015, 39(6): 141-151.
- [2] 肖迁,李文华,李志刚,等. 基于改进的小波-BP神经网络的风速和风电功率预测[J]. 电力系统保护与控制,2014,42(15):80-86.
XIAO Qian, LI Wenhua, LI Zhigang, et al. Wind speed and power prediction based on improved wavelet-BP neural network [J]. Power System Protection and Control, 2014, 42(15): 80-86.
- [3] 冬雷,王丽婕,高爽,等. 基于混沌时间序列的大型风电场发电功率预测建模与研究[J]. 电工技术学报,2008,23(12):125-129.
DONG Lei, WANG Lijie, GAO Shuang, et al. Modeling and analysis of prediction of wind power generation in the large wind farm based on chaotic time series [J]. Transactions of China Electrotechnical Society, 2008, 23(12): 125-129.
- [4] YANG Renfu, LIN Wheimin, TSAI Mingtang, et al. Particle swarm optimisation aided least-square support vector machine for load forecast with spikes [J]. IET Generation, Transmission & Distribution, 2016, 10(5): 1145-1153.
- [5] 欧阳庭辉,查晓明,秦亮,等. 含核函数切换的风电功率短期预测新方法[J]. 电力自动化设备,2016,36(9):80-86.
OUYANG Tinghui, ZHA Xiaoming, QIN Liang, et al. Short-term wind power prediction based on kernel function switching [J]. Electric Power Automation Equipment, 2016, 36(9): 80-86.
- [6] 程启明,陈路,程尹曼,等. 基于EEMD和LS-SVM模型的风电功率短期预测方法[J]. 电力自动化设备,2018,38(5):27-35.
CHENG Qiming, XU Lu, CHENG Yiman, et al. Short-term wind power

- forecasting method based on EEMD and LS-SVM model[J]. Electric Power Automation Equipment, 2018, 38(5): 27-35.
- [7] 茆美琴, 周松林, 苏建徽. 基于脊波神经网络的短期风电功率预测[J]. 电力系统自动化, 2011, 35(7): 70-74.
MAO Meiqin, ZHOU Songlin, SU Jianhui. Short-term wind power forecast based on ridgelet neural network[J]. Automation of Electric Power Systems, 2011, 35(7): 70-74.
- [8] 王丽婕, 冬雷, 廖晓钟, 等. 基于小波分析的风电场短期发电功率预测[J]. 中国电机工程学报, 2008, 28(29): 30-33.
WANG Lijie, DONG Lei, LIAO Xiaozhong, et al. Short-term power prediction of a wind farm based on wavelet analysis[J]. Proceedings of the CSEE, 2008, 28(29): 30-33.
- [9] 杨锡运, 孙宝君, 张新房, 等. 基于相似数据的支持向量机短期风速预测仿真研究[J]. 中国电机工程学报, 2012, 32(4): 35-41.
YANG Xiyun, SUN Baojun, ZHANG Xinfang, et al. Short-term wind speed forecasting based on support vector machine with similar data[J]. Proceedings of the CSEE, 2012, 32(4): 35-41.
- [10] 茆美琴, 曹雨, 周松林. 基于误差叠加修正的改进短期风电功率预测方法[J]. 电力系统自动化, 2013, 37(23): 34-38.
MAO Meiqin, CAO Yu, ZHOU Songlin. Improved short-term wind power forecasting method based on accumulative error correction[J]. Automation of Electric Power Systems, 2013, 37(23): 34-38.
- [11] MIRJALILI S, MIRJALILI S, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [12] TURABIEH M. A hybrid ANN-GWO algorithm for prediction of heart disease[J]. American Journal of Operations Research, 2016, 6(2): 136-146.
- [13] GUHA D, ROY P, BANERJEE S. Load frequency control of interconnected power system using grey wolf optimization[J]. Swarm and Evolutionary Computation, 2016, 27: 97-115.
- [14] BHATTACHARJEE S, BHATTACHARYA A, SHARMA S. Grey wolf optimisation for optimal sizing of battery energy storage device to minimise operation cost of microgrid[J]. IET Generation, Transmission & Distribution, 2016, 10(3): 625-637.
- [15] 熊一, 查晓明, 秦亮, 等. 风电功率爬坡气象场景分类模型及阈值整定研究[J]. 电工技术学报, 2016, 31(19): 155-162.
XIONG Yi, ZHA Xiaoming, QIN Liang, et al. Study on wind power ramping weather scenario classification model and threshold setting[J]. Transactions of China Electrotechnical Society, 2016, 31(19): 155-162.
- [16] 雷若冰, 徐箭, 孙辉, 等. 基于相关性分析的风电场群风速分布预测方法[J]. 电力自动化设备, 2016, 36(5): 134-140.
LEI Ruobing, XU Jian, SUN Hui, et al. Wind speed distribution forecasting based on correlation analysis for wind farm group[J]. Electric Power Automation Equipment, 2016, 36(5): 134-140.
- [17] 黎静华, 文劲宇, 程时杰, 等. 考虑多风电场出力 Copula 相关关系的场景生成方法[J]. 中国电机工程学报, 2013, 33(16): 30-36.
LI Jinghua, WEN Jingyu, CHENG Shijie, et al. A scene generation method considering copula correlation relationship of multi-wind farms power[J]. Proceedings of the CSEE, 2013, 33(16): 30-36.

作者简介:



肖逸

肖逸(1992—),男,湖北武汉人,硕士研究生,主要研究方向为新能源发电预测及并网(**E-mail**: XiaoY_hust@163.com);

李程煌(1979—),男,湖北武汉人,高级工程师,硕士,主要研究方向为水电能源优化调度、电力系统优化调度等(**E-mail**: lichenghuang@163.com);

刘若平(1995—),女,山东潍坊人,硕士研究生,研究方向为直流输电系统保护与控制以及可再生能源(**E-mail**: liuruoping1995@163.com);

左剑(1986—),男,湖南衡阳人,博士,研究方向为电力系统动态安全稳定控制、广域阻尼控制以及可再生能源(**E-mail**: zuojian@hust.edu.cn);

李银红(1976—),女,湖北荆门人,副教授,博士,主要研究方向为电力系统继电保护整定计算理论、电力系统直流保护整定计算及可再生能源等(**E-mail**: liyinhong@hust.edu.cn)。

Optimal wind power prediction based on local ramp error correction of wind speed

XIAO Yi^{1,2}, LI Chenghuang³, LIU Ruoping^{1,2}, ZUO Jian⁴, LI Yinhong^{1,2}

- (1. State Key Laboratory of Advanced Electromagnetic Engineering and Technology, School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China; 2. Hubei Electric Power Security and High Efficiency Key Laboratory, School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China; 3. Changjiang Institute of Survey, Planning, Design and Research, Wuhan 430010, China; 4. Guangdong Electric Power Dispatch Center, Guangzhou 510600, China)

Abstract: Accurate wind power prediction is significant for secure and stable operation of power system, and the lag is the main reason of wind power prediction error, especially when wind speed changes rapidly, the lag will result in big error. Considering strong relationship between wind speed and wind power, an error correction method based on LR(Local Ramp) of wind speed is proposed to improve the lag, and the predicted wind speed after correction and historical wind power are taken as input for wind power prediction. The parameters of LSSVM(Least Square Support Vector Machine) are optimized by using GWO(Grey Wolf Optimization) algorithm to improve the accuracy of wind power prediction. Case results show that the proposed method can effectively improve the accuracy of wind power prediction.

Key words: wind power prediction; predicted wind speed; lagging quality; local ramp error correction; least square support vector machine; grey wolf optimization

附录:

1. 风向预测结果

表 A1 风向预测结果

Table A1 Results of wind direction prediction

预测尺度	预测方法	MAPE/%	RMSE/(°)
5min	LSSVM	9.612e-2	0.4559
	LR 误差校正法	5.499e-2	0.2707
10min	LSSVM	7.252e-2	0.3632
	LR 误差校正法	5.636e-2	0.2728
15min	LSSVM	7.950e-2	0.4093
	LR 误差校正法	4.985e-2	0.3023
30min	LSSVM	0.2535	0.9593
	LR 误差校正法	0.1428	0.6237

2. 提前 30min 预测风速

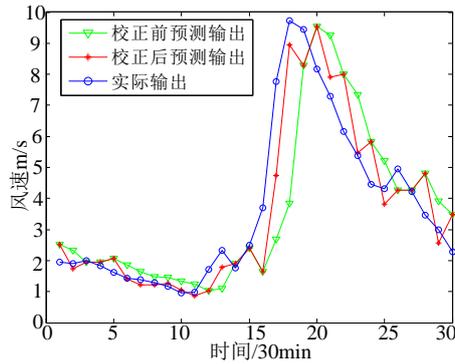


图 A1 提前 30min 风速预测

Fig.A1 Wind speed prediction with 30 min in advance

3. 提前 30min 功率预测

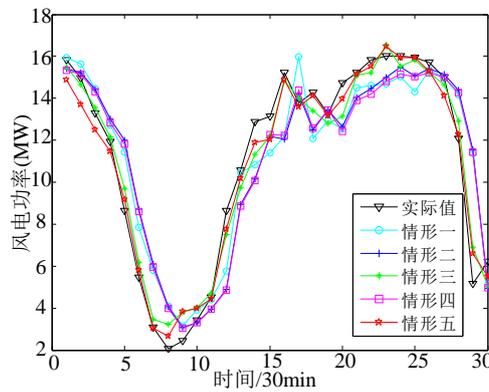


图 A2 提前 30min 功率预测

Fig.A2 Power prediction with 30 min in advance