

基于不同优化准则的风电功率预测

张 露, 卢继平, 梅亦蕾, 朱三立

(重庆大学 输配电装备及系统安全与新技术国家重点实验室, 重庆 400044)

摘要: 为了获得较好的风电功率预测综合评价指标和提高风电功率预测精度, 提出基于不同优化准则的风电功率预测模型。首先, 通过基于贴近度的单项预测模型的择优方法得到较高精度的单项预测模型, 然后利用选择出的单项预测模型分别以平均相对误差最小、平均绝对误差最小和均方根误差最小为优化准则建立不同的组合预测模型, 最后利用灰色关联度分析方法确定每种组合预测模型在优化模型中的权系数, 进而得到优化模型。以风电场的实际数据进行验证, 结果表明: 与各单项预测模型、不同优化准则的组合预测模型及其他组合模型相比, 所提优化模型的整体误差指标较小, 有效地提高了预测精度, 证明了所提模型的有效性和实用性。

关键词: 风电; 贴近度; 单项预测模型; 优化准则; 组合预测模型; 灰色关联度分析; 优化; 模型

中图分类号: TM 614

文献标识码: A

DOI: 10.16081/j.issn.1006-6047.2015.05.022

0 引言

随着风力发电技术的不断发展, 风电在电力需求中所占比例越来越大^[1]。风电场穿透功率的不断加大, 威胁着电力系统安全、稳定、经济、可靠运行^[2]。对风电功率进行准确预测可以减少电力系统运行成本和旋转备用, 提高风电穿透功率极限, 有利于调度部门及时调整计划, 从而减轻风电对电网的影响^[3]。

风电功率预测根据预测模型的不同分为物理方法、统计方法和学习方法。物理方法是基于数值天气预报的方法, 该方法不需要大量历史数据, 但需要准确的数值天气预报数据和风电场周围详细的物理信息^[4]; 统计方法主要有时间序列法 (ARIMA)^[5]、卡尔曼滤波法^[6]、灰色预测 (GM) 法^[7]、空间相关法^[8]等; 学习方法^[9-14]能更准确拟合非线性关系, 用于风电功率预测的学习方法主要有神经网络法^[9]、小波分析^[10]、支持向量机 (SVM)^[11]等。

以上每种方法都各有优劣和不同的适用场合, 不可能在任何情况下都有较好的预测精度。因此采用组合预测方法对风电功率进行预测, 可以充分利用各种单一模型的信息, 有利于提高风电功率预测精度^[15]。

组合预测方法的关键是确定各单项预测模型的权系数。有大量文献在求取权系数时, 根据某一优化准则来构建组合模型, 进而求得组合预测权系

数, 例如文献^[16]和文献^[17]根据最小方差确定组合模型权系数; 文献^[18]依据误差平方和最小的原则得到权系数; 文献^[19]通过平均绝对误差最小准则计算各单项模型的权系数。不同的优化准则对应不同的权系数, 它并不能改进其他评价准则^[20], 因此有必要综合考虑不同优化准则的权系数。故本文将不同优化准则的组合模型进行组合, 进而建立新的优化模型。

本文提出了风电功率预测的优化模型。首先计算常用的 6 种单项预测方法的贴近度, 选择贴近度大于 0 的单项预测方法构建组合模型; 然后利用择优的单项预测模型以平均相对误差 MRE (Mean Relative Error) 最小、平均绝对误差 MAE (Mean Absolute Error) 最小以及均方根误差 RMSE (Root Mean Squared Error) 最小为优化准则分别建立组合模型; 最后将 3 种组合模型进行优化组合, 利用灰色关联度分析方法得到每种组合模型的权系数, 进而得到优化模型。

1 单项预测模型的选择

风电功率预测的方法较多, 每种预测方法都有其特点, 组合预测方法能结合各单项预测方法的优点, 从而提高预测精度。但并不是所有的组合方法都能提高风电功率预测精度, 当单项预测方法本身预测误差较大, 由它构成的组合方法的预测精度可能比构成该组合方法的其他单项预测方法低, 预测效果未得到改善, 因此选择合适的单项预测模型至关重要。针对上面的问题, 本文提出了一种基于贴近度的单项预测模型的选择方法。

1.1 最大-最小贴近度的基本概念^[21]

设 $\{a(t), t=1, 2, \dots, n\}$ 和 $\{b(t), t=1, 2, \dots, n\}$

收稿日期: 2014-03-31; 修回日期: 2015-01-07

基金项目: 输配电装备及系统安全与新技术国家重点实验室自主研究项目 (2007DA10512712205)

Project supported by Research Project of State Key Laboratory of Power Transmission Equipment & System Security and New Technology (2007DA10512712205)

是 2 个实数序列,则最大-最小贴近度定义为:

$$\Gamma(a, b) = 1 - \frac{2 \sum_{t=1}^n |a(t) - b(t)|}{\sum_{t=1}^n (a(t) + b(t) + |a(t) - b(t)|)} \quad (1)$$

最大-最小贴近度能反映 2 个序列的相近程度,当 2 个实数序列越相近,其最大-最小贴近度越大,其中 2 个实数序列完全相同时,即 $a(t) = b(t)$ ($t = 1, 2, \dots, n$) 时,最大-最小贴近度达到最大值 1。

1.2 单项预测模型的择优原理

设 $\{y(t), t = 1, 2, \dots, n\}$ 为风电功率实际值序列, $\{\hat{x}_i(t), t = 1, 2, \dots, n\}$ ($i = 1, 2, \dots, s$) 为第 i 个单项预测模型的预测值序列,则定义第 i 个单项预测模型的预测精度向量为:

$$\mathbf{a}_i = [a_i(1), a_i(2), \dots, a_i(n)] \quad i = 1, 2, \dots, s \quad (2)$$

其中, $a_i(t) = |y(t) - \hat{x}_i(t)|$ ($t = 1, 2, \dots, n$)。这样每个单项预测模型对应一个预测精度向量。显然, $a_i(t)$ 越小说明第 i 个单项预测模型在 t 时刻的预测精度越高。从而得到最优点精度向量 $\bar{\mathbf{a}}$ 和最劣点精度向量 $\underline{\mathbf{a}}$, 记:

$$\begin{aligned} \bar{\mathbf{a}} &= [\bar{a}(1), \bar{a}(2), \dots, \bar{a}(n)] \\ \underline{\mathbf{a}} &= [\underline{a}(1), \underline{a}(2), \dots, \underline{a}(n)] \end{aligned} \quad (3)$$

$\bar{\mathbf{a}}$ 和 $\underline{\mathbf{a}}$ 满足: $\bar{a}(t) = \min \{a_1(t), a_2(t), \dots, a_s(t)\}$, $\underline{a}(t) = \max \{a_1(t), a_2(t), \dots, a_s(t)\}$ ($t = 1, 2, \dots, n$)。

为了判断各单项预测模型的预测精度,需要考虑各单项预测模型的预测精度向量与最优点精度向量和最劣点精度向量的接近程度^[22],故引入最大-最小贴近度来表示两向量的相近程度。根据第 1.1 节的最大-最小贴近度可得到各单项预测模型与最优点精度向量的最大-最小贴近度 $\Gamma(\bar{\mathbf{a}}, \mathbf{a}_i)$ 和与最劣点精度向量的最大-最小贴近度 $\Gamma(\underline{\mathbf{a}}, \mathbf{a}_i)$ 的表达式如下:

$$\Gamma(\bar{\mathbf{a}}, \mathbf{a}_i) = 1 - \frac{2 \sum_{t=1}^n |\bar{a}(t) - a_i(t)|}{\sum_{t=1}^n (\bar{a}(t) + a_i(t) + |\bar{a}(t) - a_i(t)|)} \quad (4)$$

$$\Gamma(\underline{\mathbf{a}}, \mathbf{a}_i) = 1 - \frac{2 \sum_{t=1}^n |\underline{a}(t) - a_i(t)|}{\sum_{t=1}^n (\underline{a}(t) + a_i(t) + |\underline{a}(t) - a_i(t)|)} \quad (5)$$

比较 $\Gamma(\bar{\mathbf{a}}, \mathbf{a}_i)$ 的大小,单项模型对应的 $\Gamma(\bar{\mathbf{a}}, \mathbf{a}_i)$ 越大,表明该单项模型的预测精度向量越接近最优点精度向量,从而该单项模型的预测精度越高,对单项模型,自然希望 $\Gamma(\bar{\mathbf{a}}, \mathbf{a}_i)$ 越大越好;比较 $\Gamma(\underline{\mathbf{a}}, \mathbf{a}_i)$ 的大小,单项模型对应的 $\Gamma(\underline{\mathbf{a}}, \mathbf{a}_i)$ 越大,表明该单项模型的预测精度向量越接近最劣点精度向量,从而该单项模型的预测精度越低,对单项模型,自然希

望 $\Gamma(\underline{\mathbf{a}}, \mathbf{a}_i)$ 越小越好^[22]。因此为了同时兼顾最优点和最劣点精度向量,计算 $\Gamma(\bar{\mathbf{a}}, \mathbf{a}_i)$ 和 $\Gamma(\underline{\mathbf{a}}, \mathbf{a}_i)$ 的差值,即 $T_i = \Gamma(\bar{\mathbf{a}}, \mathbf{a}_i) - \Gamma(\underline{\mathbf{a}}, \mathbf{a}_i)$,将 T_i 称为单项模型 i 的贴近度。 T_i 为正时,说明单项预测模型与最优点精度向量更相近,表明单项预测模型的预测精度较高; T_i 为负时,说明单项预测模型与最劣点精度向量更相近,表明单项预测模型预测精度较低。因此将贴近度大于 0 作为单项模型选择的依据。

1.3 单项预测模型的选择

单项预测方法的择优之前,需要确定用于预测精度比较的单项预测方法。本文选择目前常用的 6 种风电功率单项预测方法,即 GM 法^[23]、ARIMA^[15]、BP 神经网络法、RBF 神经网络法、SVM 方法^[24]、广义回归神经网络(GRNN)法^[25]。

为了得到每种预测方法的预测精度向量,需要利用每种预测方法进行建模和预测。GM 方法适用于处理小样本预测,即所需建模数据较少,而其他 5 种方法需要的建模数据较多。为了避免建模数据量带来的影响,对于 ARIMA、BP、RBF、GRNN 和 SVM 方法,选择相同的数据进行模型的建立,其中在构建神经网络模型(BP、RBF 和 GRNN)和 SVM 模型的训练样本时,采用相空间重构的方法^[26-27],一方面能得到用于建模的训练样本,另一方面也能得到模型的输入个数,从而解决了输入个数的确定问题;GM 方法的建模数据个数取为与神经网络模型和 SVM 模型的输入个数相同。

利用建立的 6 种模型,得到各模型的风电功率预测值序列,结合实际风电功率值,可得到每种预测模型的预测精度向量。根据第 1.2 节介绍的内容,进而得到每种模型的贴近度,选择贴近度大于 0 的模型进行组合预测模型的构建。

2 不同优化准则的组合预测模型

目前用于评价风电功率预测效果的常用误差指标为 MRE、MAE 和 RMSE^[28]。本文利用它们作为优化准则确定组合模型权系数,进而得到不同优化准则的组合预测模型。

设第 1 节单项预测模型的择优得到了 m 个算术平均贴近度大于 0 的单项预测模型,利用这 m 个单项预测模型分别构建 MRE 最小、MAE 最小和 RMSE 最小的组合预测模型。

设 $\{y(t), t = 1, 2, \dots, n\}$ 为风电功率实际值序列, $\{x_i(t), t = 1, 2, \dots, n\}$ ($i = 1, 2, \dots, m$) 为第 i 个单项预测模型的预测值序列, $\{\hat{y}(t), t = 1, 2, \dots, n\}$ 为组合预测模型得到的风电功率预测值序列,则组合预测模型的形式为:

$$\hat{y}(t) = \sum_{i=1}^m w_i x_i(t) \quad t=1, 2, \dots, n \quad (6)$$

其中, w_1, w_2, \dots, w_m 为组合预测模型的权系数, 且满足 $\sum_{i=1}^m w_i = 1$ 和 $w_i \geq 0 (i=1, 2, \dots, m)$ 。确定权系数的不同优化准则^[20]如下。

a. MRE 最小, 即确定 w_1, w_2, \dots, w_m 使式(7)最小。

$$Q_1 = \frac{1}{n} \sum_{t=1}^n \left| \frac{y(t) - \sum_{i=1}^m w_i x_i(t)}{y(t)} \right| \quad (7)$$

b. MAE 最小, 即确定 w_1, w_2, \dots, w_m 使式(8)最小。

$$Q_2 = \frac{1}{n} \sum_{t=1}^n \left| y(t) - \sum_{i=1}^m w_i x_i(t) \right| \quad (8)$$

c. RMSE 最小, 即确定 w_1, w_2, \dots, w_m 使式(9)最小。

$$Q_3 = \sqrt{\frac{1}{n} \sum_{t=1}^n \left(y(t) - \sum_{i=1}^m w_i x_i(t) \right)^2} \quad (9)$$

3 优化模型的权系数确定方法

第 2 节确定了 3 种组合预测模型, 它们相应的预测评价指标最小, 比如以优化准则 MAE 最小构建的组合模型对应的 MAE 最小, 但它们并不能改进其他预测评价指标。因此, 为了获得各项预测误差指标都较小的预测模型, 需要将不同优化准则的组合模型(以下简称组合模型)进行组合得到优化模型。在计算优化模型中各组合模型的权系数时, 本文采用灰色关联度分析方法, 它充分考虑了各组合模型的常用预测评价指标, 通过每个组合模型的误差评价指标(MRE、MAE 和 RMSE)与相关性指标(Theil 不等系数和相关系数), 构成的序列计算各组合模型的灰色关联度。当灰色关联度越大, 说明该组合模型的综合评价指标越好, 故该组合模型在优化模型中的比重应越大。

3.1 不同优化准则的组合预测模型的灰色关联度

为了计算每个组合模型综合评价的灰色关联度, 需要得到各组合模型的多个评价指标。设 $P_{i1} - P_{i5} (i=1, 2, 3)$ 分别表示第 i 个组合模型的 MRE、MAE、RMSE、Theil 不等系数和相关系数指标, 其中 $P_{i5} = 1 - R_i$, R_i 为第 i 个组合模型的相关系数, 这里对相关系数指标进行了修正, 使它与其他指标的变化类似, 即指标值越小, 模型预测精度越高, 为了叙述方便, 仍然称 P_{i5} 为相关系数指标。以下具体介绍计算组合模型灰色关联度的步骤^[29]。

a. 计算 3 个组合模型的评价指标, 它们构成了一个指标评价矩阵。

$$P = \begin{bmatrix} P_{11} & P_{12} & P_{13} & P_{14} & P_{15} \\ P_{21} & P_{22} & P_{23} & P_{24} & P_{25} \\ P_{31} & P_{32} & P_{33} & P_{34} & P_{35} \end{bmatrix}$$

指标评价矩阵的每行对应该组合模型的指标

序列。

b. 确定参考序列。

利用灰色关联度分析方法进行各组合模型的综合评价时, 选择各指标的最优值作为评价的参考标准, 即参考序列为 $(P_{01}, P_{02}, P_{03}, P_{04}, P_{05})$, 其中 $P_{0j} = \min \{P_{1j}, P_{2j}, P_{3j}\} (j=1, 2, 3, 4, 5)$ 。

c. 指标值的归一化处理。

由于各评价指标值的量纲和数量级不尽相同, 为了进行比较, 需要各评价指标按下式进行归一化处理。

$$z = \begin{bmatrix} z_{11} & z_{12} & z_{13} & z_{14} & z_{15} \\ z_{21} & z_{22} & z_{23} & z_{24} & z_{25} \\ z_{31} & z_{32} & z_{33} & z_{34} & z_{35} \\ z_{01} & z_{02} & z_{03} & z_{04} & z_{05} \end{bmatrix}$$

其中, $z_{ij} = (P_{ij} - \min_j) / (P_{ij} - \max_j) (i=0, 1, 2, 3; j=1, 2, 3, 4, 5)$, $z_{0j} = 0$, $\min_j = P_{0j}$, $\max_j = \max \{P_{0j}, P_{1j}, P_{2j}, P_{3j}\}$ 。

d. 计算各组合模型的归一化指标序列与参考序列之差的极大值 M 和极小值 L , 并得到各组合模型的灰色关联度。

$$L = \min_{1 \leq i \leq 3} \min_{1 \leq j \leq 5} |z_{0j} - z_{ij}| = \min_{1 \leq i \leq 3} \min_{1 \leq j \leq 5} |z_{ij}| \quad (10)$$

$$M = \max_{1 \leq i \leq 3} \max_{1 \leq j \leq 5} |z_{0j} - z_{ij}| = \max_{1 \leq i \leq 3} \max_{1 \leq j \leq 5} |z_{ij}| \quad (11)$$

$$r_{ij} = \frac{L + \rho M}{z_{ij} + \rho M} \quad i=1, 2, 3; j=1, 2, 3, 4, 5 \quad (12)$$

$$r_i = \frac{1}{5} \sum_{j=1}^5 r_{ij} \quad i=1, 2, 3 \quad (13)$$

其中, ρ 为分辨系数, 它是 M 的系数或称权重, 反映了系统的各个因子对关联度的间接影响程度, ρ 越大, 各因子对关联度的影响越大, 反之, 各因子对关联度的影响越小, $\rho \in (0, 1)$, 通常可取 $\rho = 0.5$; r_{ij} 为第 i 个组合模型第 j 个指标与参考序列对应元素的关联系数; r_i 为第 i 个组合模型的灰色关联度。

3.2 权系数优化新方法

组合模型的灰色关联度越大, 则说明该模型的综合评价指标越好, 在优化模型中的比重越大, 根据此原则来确定优化模型中组合模型的权系数。设 $\{\hat{y}_i(t), t=1, 2, \dots, n\} (i=1, 2, 3)$ 为第 i 个组合预测模型得到的风电功率预测值序列, 则优化模型可表示如下:

$$f(t) = \lambda_1 \hat{y}_1(t) + \lambda_2 \hat{y}_2(t) + \lambda_3 \hat{y}_3(t) \quad t=1, 2, \dots, n \quad (14)$$

$\lambda_1, \lambda_2, \lambda_3$ 根据组合模型灰色关联度可得:

$$\lambda_i = r_i / \sum_{i=1}^3 r_i \quad i=1, 2, 3 \quad (15)$$

4 实例分析

本文的仿真分析是基于 MATLAB 软件实现的, 以云南某风电场(风电场 1)2012 年 2 月 1 日至 2 月 12 日共 12 d 的风电功率数据为实验数据, 数据的时

间间隔为 15 min,即每 15 min 采样一个数据点,原始数据如图 1 所示。

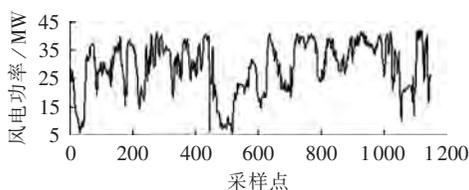


图 1 原始风电功率数据

Fig.1 Original wind power data

4.1 单项预测模型的选择

针对 ARIMA、BP、RBF、GRNN 和 SVM 模型,选择 2012 年 2 月 1 日至 2 月 10 的 960 个风电功率数据作为训练数据,2 月 11 日和 12 日的 192 个风电功率数据作为测试数据。相空间重构的 C-C 方法可得原始数据的嵌入维数为 5 和延迟时间为 21 个采样点,故 BP、RBF、GRNN 和 SVM 模型的输入为 $X(i)=[x(i),x(i+21),x(i+42),x(i+63),x(i+84)]$,输出为 $Y(i)=x(i+85)$, i 取值 1 至 875 对应训练样本, i 取值 876 至 1067 对应测试样本。GM 模型的建模数据个数与嵌入维数相等,即利用 956 至 960 点的实际值预测 961 点的功率,然后用 957 至 961 点的实际值预测 962 点的功率,依此类推。各单项模型的结构或参数设置如下:时间序列法的模型为 ARIMA(5,1,10),即差分阶数为 1,自回归阶数为 5 和滑动平均阶数为 10;灰色预测模型为 GM(1,1),即一阶一元灰色预测模型,建模数据为预测点前的 5 个数据;BP 神经网络的结构为 5-12-1,即输入层单元数为 5,隐含层单元数设置为 12,输出层单元数为 1,其中隐含层为双曲正切函数(tansig),输出层为线性函数(purelin),采用的训练算法为 L-M 算法(trainlm);RBF 神经网络的隐含层个数根据设置的期望目标值 0.001 自适应确定,其中径向基函数的扩展常数取为 10;GRNN 可根据试验法得到最佳平滑参数 σ 为 0.1;SVM 的核函数选为高斯径向基函数,不敏感系数 ε 设为 0.01,通过交叉意义下的网格搜索法可得到最佳惩罚因子 $c=45.2548$ 和核函数参数 $\gamma=1/\sigma^2=0.0220971$ 。

根据 6 种模型的 192 个点的预测值和实际值,计算得到各种单项预测模型的贴近度,结果如表 1 所示。

表 1 各单项预测模型的贴近度
Table 1 Approach degree of single forecasting models

预测模型	贴近度	预测模型	贴近度
GM	-0.2316	RBF	-0.0147
ARIMA	0.1080	GRNN	0.0997
BP	-0.1994	SVM	0.1743

分析表 1 可知,贴近度为正的单项预测模型为 ARIMA、GRNN 和 SVM 模型,故选择它们构建组合模型,预测结果见图 2,预测误差见图 3。为更加清晰地看出单项预测模型的预测效果,将整体预测效果图 2 中 2 个采样时间段(1 至 20 点和 110 至 130 点)进行放大显示。

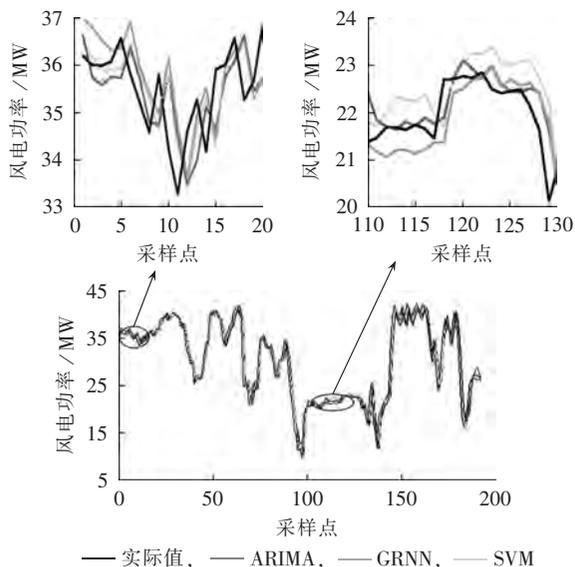


图 2 3 种单项预测模型的预测结果

Fig.2 Forecast results of three single forecasting models

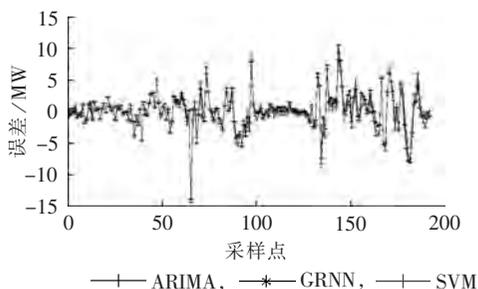


图 3 3 种单项预测模型的预测误差

Fig.3 Forecast errors of three single forecasting models

从图 2 可知,ARIMA、GRNN 和 SVM 都能跟踪实际风电功率的走势,但都存在一定的滞后性。利用 MRE、MAE 和 RMSE、Theil 不等系数 δ_{Theil} 和相关系数 δ_{CC} 分析它们的预测效果,评价指标见表 2。分析表 2 知,GRNN、ARIMA 和 SVM 的各项误差和 Theil 不等系数依次减小,相关系数依次增大,从而说明 SVM 的预测效果最好,ARIMA 次之,GRNN 的

表 2 3 种单项预测模型的预测结果分析
Table 2 Forecast result analysis for three single forecasting models

单项模型	MRE/%	MAE/MW	RMSE/MW	δ_{Theil}	δ_{CC}
ARIMA	7.42	2.0876	2.9846	0.0993	0.9309
GRNN	7.81	2.3930	3.1518	0.1080	0.9213
SVM	7.27	1.9906	2.8793	0.0922	0.9356

预测效果较差。尽管 SVM 的整体预测结果较好,但从图 3 可看出其在某些点仍然出现较大的误差。

4.2 3 种组合模型

以 MRE 最小、MAE 最小和 RMSE 最小为优化准则确定的组合模型分别记为组合模型 1、组合模型 2 和组合模型 3,它们的预测评价指标如表 3 所示。

表 3 各组合预测模型的预测结果分析
Table 3 Forecast result analysis for combination forecasting models

组合模型	MRE/%	MAE/MW	RMSE/MW	δ_{Theil}	δ_{CC}
1	6.45	1.8218	2.7548	0.0792	0.9509
2	6.84	1.7002	2.7254	0.0785	0.9512
3	6.97	1.8050	2.6020	0.0795	0.9516

从表 3 可知,3 种组合模型的各项误差和 Theil 不等系数都比单项模型小,相关系数都比单项模型大,说明了 3 种组合模型的预测精度都得到提高。把 3 种组合模型每种误差的最小值称为该指标的最优值,以某种优化准则建立的组合模型对应的误差指标最小。

4.3 优化模型的预测效果分析

根据第 3.1 节计算 3 个组合模型的灰色关联度分别为 0.5604、0.6983 和 0.7333,所以优化模型中它们的权系数分别为 0.2813、0.3506 和 0.3681,进而得到优化模型的预测效果如图 4 所示。

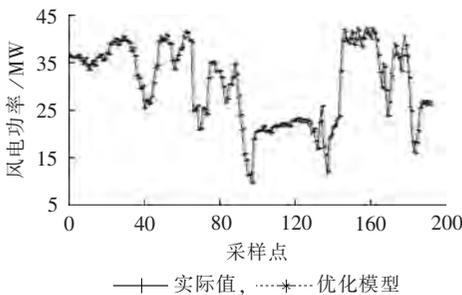


图 4 优化模型的预测结果

Fig.4 Forecast results of optimized model

为了更好地说明本文优化模型的有效性,分别采用等权重组合法、方差倒数法和熵值法对风电功率进行预测,并将各组合模型的评价指标列于表 4。

表 4 优化模型和其他组合模型的预测结果分析
Table 4 Forecast result analysis for optimized model and other combination models

预测模型	MRE/%	MAE/MW	RMSE/MW	δ_{Theil}	δ_{CC}
优化模型	6.53	1.7209	2.6326	0.0698	0.9610
等权重组合法	7.15	1.8863	2.8140	0.0901	0.9397
方差倒数法	7.01	1.8572	2.8001	0.0878	0.9432
熵值法	7.09	1.8745	2.8126	0.0885	0.9426

由表 4 得知:优化模型的各项指标都优于其他 3 种组合模型,预测精度得到提高。

分析表 3 和表 4 可知:

a. 优化模型的预测评价指标值 MRE 大于组合模型 1,MAE 大于组合模型 2, RMSE 大于组合模型 3,这是符合客观事实的,因为组合模型 1、组合模型 2 和组合模型 3 是分别建立在 MRE、MAE 和 RMSE 最小原则的基础上的;

b. 优化模型的各项误差仅大于 3 种组合模型的最优值,并且与最优值相差很小,这是因为优化模型是不同优化准则的组合模型的线性组合,它兼顾了组合模型 1 的 MRE 最小、组合模型 2 的 MAE 最小和组合模型 3 的 RMSE 最小的优点,使得各项误差评价指标都较好;

c. 优化模型与 3 种组合模型相比,Theil 不等系数减小和相关系数增大,说明了优化模型较 3 种组合模型,预测精度得到提高。

分析表 2 和表 4 可知:优化模型与各单项预测模型相比较,优化模型的各项误差和 Theil 不等系数减小,相关系数增大,由此可得出兼顾不同优化准则的风电功率预测模型能有效提高预测精度。

为检验本文优化模型的适用性,选择广州某风电场(风电场 2)2011 年 5 月 1 日至 5 月 12 日的数据进行建模和预测,该风电场的数据间隔也为 15 min,数据波动较大,其原始数据见图 5。

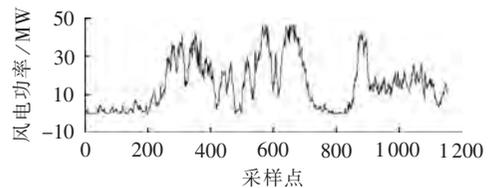


图 5 原始风电功率数据

Fig.5 Original wind power data

针对此风电场数据得到的贴近度为正的单项模型为 RBF、GRNN 和 SVM,它们的预测效果见图 6。

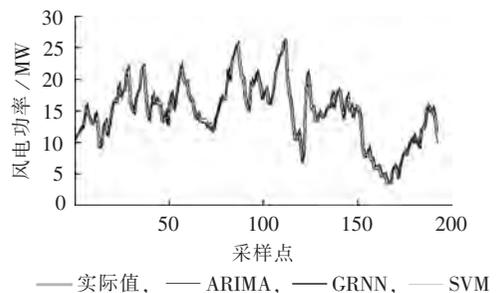


图 6 3 种单项预测模型的预测结果

Fig.6 Forecast results of three single forecasting models

限于篇幅,本文只列出了风电场 2 择优的各单项预测方法、等权重组合法、方差倒数法、熵值法和优化模型的预测评价,见表 5。

分析表 5 知,优化模型的各项指标依然优于择优的单项预测方法、等权重组合法、方差倒数法和

表 5 各预测模型的预测结果分析

Table 5 Forecast result analysis for different forecasting models

预测模型	MRE/%	MAE/MW	RMSE/MW	δ_{total}	δ_{CC}
RBF	11.44	1.8414	2.4884	0.1462	0.9121
GRNN	12.64	1.9642	2.6407	0.1534	0.9092
SVM	10.96	1.8706	2.5067	0.1445	0.9135
等权重组合法	9.37	1.7789	2.2987	0.1320	0.9237
方差倒数法	10.12	1.7028	2.1609	0.1356	0.9228
熵值法	9.73	1.7744	2.1878	0.1298	0.9278
优化模型	8.58	1.5450	1.8788	0.1009	0.9450

熵值法,说明本文所提优化模型具有一定的实用性。

5 结论

本文通过单项预测模型的择优、不同优化准则的组合模型的建立以及优化模型权系数的确定,得到具有较好预测能力和较高预测精度的优化模型,并得到如下结论。

a. 通过计算每种单项预测模型的贴进度,选择高精度的单项预测模型,一方面可以解决构建组合模型的单项预测模型的选择问题,另一方面也能使组合模型的精度提高。

b. 以 MRE 最小、MAE 最小和 RMSE 最小为优化准则建立的 3 种组合模型的预测精度较择优的单项预测模型都有所提高。

c. 利用灰色关联度分析方法确定优化模型中 3 种组合模型的权系数,进而得到优化模型。该方法考虑了各种组合模型的综合预测评价指标,确定的权系数充分反映各组合模型预测的综合效果。优化模型同时兼顾了不同优化准则,各项预测评价指标都较好,具有较好的预测能力,能有效提高风电功率预测精度。本文的优化模型对于解决实际工程问题具有很好的应用价值。

参考文献:

- [1] 王丽婕,廖晓钟,高阳,等. 风电场发电功率的建模和预测研究综述[J]. 电力系统保护与控制,2009,37(13):118-121.
WANG Lijie, LIAO Xiaozhong, GAO Yang, et al. Summarization of modeling and prediction of wind power generation[J]. Power System Protection and Control, 2009, 37(13): 118-121.
- [2] 符金伟,马进,周榆晓,等. 风电功率预测研究方法综述[J]. 华东电力,2012,40(5):888-892.
FU Jinwei, MA Jin, ZHOU Yuxiao, et al. Review on wind power prediction methods[J]. East China Electric Power, 2012, 40(5): 888-892.
- [3] 王晓兰,王明伟. 基于小波分解和最小二乘支持向量机的短期风速预测[J]. 电网技术,2010,34(1):179-184.
WANG Xiaolan, WANG Mingwei. Short-term wind speed forecasting based on wavelet decomposition and least square support vector machine[J]. Power System Technology, 2010, 34(1): 179-184.
- [4] 冯双磊,王伟胜,刘纯,等. 风电场功率预测物理方法研究[J]. 中

国电机工程学报,2010,30(2):1-6.

- FENG Shuanglei, WANG Weisheng, LIU Chun, et al. Study on the physical approach to wind power prediction[J]. Proceedings of the CSEE, 2010, 30(2): 1-6.
- [5] TORRES J L, GARCIA A, de BLAS M, et al. Forecast of hourly averages wind speed with arma models in Navarre (Spain)[J]. Solar Energy, 2005, 79(1): 65-77.
- [6] 潘迪夫,刘辉,李燕飞. 风电场风速短期多步预测改进算法[J]. 中国电机工程学报,2008,28(26):87-91.
PAN Difu, LIU Hui, LI Yanfei. Optimization algorithm of short-term multi-step wind speed forecast[J]. Proceedings of the CSEE, 2008, 28(26): 87-91.
- [7] EL-FOULY T H M, EL-SAADANY E F, SALAMA M M A. Improved grey predictor rolling models for wind power prediction[J]. IEEE Proceedings on Generation, Transmission and Distribution, 2007, 1(6): 928-937.
- [8] BILLINTON R, CHEN H, GHAJAR R. A sequential simulation technique for adequacy evaluation of generating systems including wind energy[J]. IEEE Trans on Energy Conversion, 1996, 11(4): 728-734.
- [9] BARBOUNIS T G, THEOCHARIS J B, ALEZIADIS M C, et al. Long-term wind speed and power forecasting using local recurrent neural network models[J]. IEEE Trans on Energy Conversion, 2006, 21(1): 273-284.
- [10] MOHANDS M A, HALAWANI T O, REHMAN S, et al. Support vector machines for wind speed prediction[J]. Renewable Energy, 2004, 29(6): 939-947.
- [11] CAO Lei, LI Ran. Short-term wind speed forecasting model for wind farm based on wavelet decomposition[C] // The Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies. Nanjing, China: [s.n.], 2008: 2525-2529.
- [12] 李慧杰,刘亚南,卫志农,等. 基于相关向量机的短期风速预测模型[J]. 电力自动化设备,2013,33(10):28-32.
LI Huijie, LIU Yanan, WEI Zhinong, et al. Short-term wind speed forecasting model based on relevance vector machine[J]. Electric Power Automation Equipment, 2013, 33(10): 28-32.
- [13] 凌武能,杭乃善,李如琦. 基于云支持向量机模型的短期风电功率预测[J]. 电力自动化设备,2013,33(7):34-38.
LING Wuneng, HANG Naishan, LI Ruqi. Short-term wind power forecasting based on cloud SVM model[J]. Electric Power Automation Equipment, 2013, 33(7): 34-38.
- [14] 崔明建,孙元章,柯德平,等. 基于原子稀疏分解理论的短期风电功率滑动预测[J]. 电力自动化设备,2014,34(1):120-127.
CUI Mingjian, SUN Yuanzhang, KE Deping, et al. Short-term wind power forecasting based on atomic sparse decomposition theory[J]. Electric Power Automation Equipment, 2014, 34(1): 120-127.
- [15] 贺电. 大型风电场短期预测研究[D]. 北京:北京交通大学,2011.
HE Dian. Research on short-term forecast of wind power on a large scale wind farm[D]. Beijing: Beijing Jiaotong University, 2011.
- [16] 张国强,张伯明. 基于组合预测的风电场风速及风电功率预测[J]. 电力系统自动化,2009,33(18):92-95.
ZHANG Guoqiang, ZHANG Bomeng. Wind speed and wind turbine output forecast based on combination method[J]. Automation of Electric Power Systems, 2009, 33(18): 92-95.

- [17] 牛晨光,游晓科,刘观起,等. 组合模型在风电场发电功率短期预测中的应用[J]. 电力科学与工程,2012,28(3):13-16.
NIU Chenguang, YOU Xiaoke, LIU Guanqi, et al. Application of combination model in the short-term prediction of wind farm generation power[J]. Electric Power Science and Engineering, 2012,28(3):13-16.
- [18] 方江晓. 短期风速和风电功率预测模型的研究[D]. 北京:北京交通大学,2011.
FANG Jiangxiao. Research on short-term prediction models of wind speed and wind power[D]. Beijing:Beijing Jiaotong University,2011.
- [19] 叶晨. 风电功率组合预测研究[D]. 保定:华北电力大学,2010.
YE Chen. The research of wind power combined prediction [D]. Baoding:North China Electric Power University,2010.
- [20] 王丰效. 不同优化准则统计组合预测权重系数优化[J]. 数学的实践与认识,2013,43(13):135-139.
WANG Fengxiao. Weight coefficient optimization of combination forecast by different criteria[J]. Mathematics in Practice and Theory,2013,43(13):135-139.
- [21] 金飞飞,陈华友,周礼刚. 基于最大-最小贴近度的IOWA算子最优组合预测模型[J]. 数学的实践与认识,2013,43(7):110-116.
JIN Feifei, CHEN Huayou, ZHOU Ligang. The optimal combination forecasting model based on the maximum-minimum approach degree and induced ordered weighted averaging operator[J]. Mathematics in Practice and Theory,2013,43(7):110-116.
- [22] 王丰效. 组合预测模型预测精度的贴近度评价法[J]. 统计与决策,2013(8):70-72.
WANG Fengxiao. Close degree evaluation method applied in forecast accuracy of combination models [J]. Statistics and Decision,2013(8):70-72.
- [23] 党耀国,刘思峰,王正新,等. 灰色预测与决策模型研究[M]. 北京:科学出版社,2009:39-42.
- [24] SIMON H. 神经网络原理[M]. 叶世伟,史忠值,译. 北京:机械工业出版社,2004:109-123,229-249.
- [25] 李聪. 基于GRNN网络的短期与超短期负荷预测[D]. 吉林:东北电力大学,2010.
LI Cong. Short-term and ultra-short-term load forecasting based on GRNN network[D]. Jilin:Northeast Dianli University,2010.
- [26] 吕金虎,陆君安,陈士华. 混沌时间序列分析及其应用[M]. 武汉:武汉大学出版社,2002:57-71.
- [27] 韩敏. 混沌时间序列预测理论与方法[M]. 北京:中国水利水电出版社,2007:79-92.
- [28] 徐曼,乔颖,鲁宗相. 短期风电功率预测误差综合评价方法[J]. 电力系统自动化,2011,35(12):20-26.
XU Man, QIAO Ying, LU Zongxiang. A comprehensive error evaluation method for short-term wind power prediction[J]. Automation of Electric Power Systems,2011,35(12):20-26.
- [29] 王丰效. 基于灰色关联分析统计组合预测精度评价[J]. 统计与决策,2013(4):15-16.
WANG Fengxiao. Accuracy evaluation of combination forecast based on grey relational analysis[J]. Statistics and Decision, 2013(4):15-16.

作者简介:



张露

张露(1990—),女,重庆人,硕士研究生,研究方向为风电功率预测(**E-mail**: zhanglu20084603@163.com);

卢继平(1960—),男,北京人,教授,博士研究生导师,主要从事电力系统运行与控制等方面的研究工作(**E-mail**: lujiiping@cqu.edu.cn)。

Wind power forecasting based on different optimization criterions

ZHANG Lu, LU Jiping, MEI Yilei, ZHU Sanli

(State Key Laboratory of Power Transmission Equipment & System Security and New Technology, Chongqing University, Chongqing 400044, China)

Abstract: In order to obtain better comprehensive evaluation index and improve the accuracy of wind power forecasting, a wind power forecasting model based on different optimization criteria is proposed. The approach degree is adopted to select the single forecasting models with higher accuracy, based on which, different combination forecasting models are built with the minimum average relative error, minimum mean absolute error or minimum root mean square error as the optimization criterion respectively. The grey correlation analysis method is applied to determine the weight coefficients of each combination model and then obtain the optimized model. The verification with the actual data of a wind farm show that, compared with single forecasting models, combination forecasting models based on different optimization criteria and other combination models, the proposed optimized model has smaller overall error and improves the forecasting accuracy effectively, which proves its effectiveness and practicability.

Key words: wind power; approach degree; single forecasting model; optimization criterion; combination forecasting model; grey correlation analysis; optimization; models