

DOI: 10.19783/j.cnki.pspc.190336

基于 APSO-GSA 和相关向量机的短期风电功率预测

田璧源¹, 刘琪¹, 张新燕², 王昱洁¹, 张怡帆¹, 郭红艳¹, 常喜强¹

(1. 国网乌鲁木齐供电公司, 新疆 乌鲁木齐 830011; 2. 新疆大学电气工程学院, 新疆 乌鲁木齐 830049)

摘要: 精确的短期风电功率预测建模对于提升新能源电力系统经济稳定运行十分重要。针对传统预测方法在小样本学习、精细化建模、概率性预测等方面的不足和易陷入局部最优的影响, 首先以相关向量机(RVM)理论为核心, 建立了基于 RVM 的风电功率预测模型。然后, 针对万有引力搜索算法(GSA)缺少跳出局部最优机制和群体记忆功能, 提出了一种结合自适应粒子群算法(APSO)的 APSO-GSA 混合优化算法, 利用该算法对 RVM 模型参数进行优化。最后, 以中国西北某风电场运行数据为例进行验证。结果表明, 所提方法具有更高的建模精度和更快的收敛速度, 实现了利用少量样本和简单模型对未来时刻风电功率的精确预测。

关键词: 风电功率预测; 相关向量机; 万有引力搜索算法; 自适应粒子群算法

Short-term wind power prediction based on APSO-GSA and correlation vector machine

TIAN Biyuan¹, LIU Qi¹, ZHANG Xinyan², WANG Yujie¹, ZHANG Yifan¹, GUO Hongyan¹, CHANG Xiqiang¹

(1. State Grid Urumqi Power Supply Company, Urumqi 830011, China;

2. College of Electrical Engineering, Xinjiang University, Urumqi 830049, China)

Abstract: Accurate short-term wind power forecasting modeling is very important to improve the economic and stable operation of new energy power systems. In view of the shortcomings of traditional forecasting methods in small sample learning, fine modeling, probability prediction and the influence of easily falling into local optimum, this paper firstly establishes the wind power forecasting model of Relevant Vector Machine (RVM) based on the theory of RVM. Then, aiming at the lack of local optimum mechanism and group memory function in Gravitational Search Algorithm (GSA), an APSO-GSA hybrid optimization algorithm is proposed to optimize the parameters of RVM model. Finally, a wind farm operation data in Northwest China is taken as an example to verify the effectiveness of the proposed method. The results show that the proposed method has higher modeling accuracy and faster convergence speed, and achieves accurate prediction of wind power at future time using a small number of samples and simple models.

This work is supported by National Natural Science Foundation of China (No. 51667018 and No. 51367015).

Key words: wind power prediction; relevant vector machine; GSA; APSO

0 引言

风能是可再生清洁能源, 风力发电已经成为世界上增长最快的可再生能源发电技术^[1]。然而, 风电本身具有间歇性与波动性, 大规模的风电并网给电力系统运行调度工作提出了严峻考验^[2]。准确可靠的风电功率预测是缓解上述不利影响的有效途径之一, 可以协助调度员及时调整日前调度计划及风电机组控制方案, 进而减少系统备用容量, 降低系统运行成本, 对提高电力系统运行稳定性及风险

评估能力都具有十分重要的意义^[3]。根据时间尺度预测, 风电功率预测可分为中长期、短期和超短期^[4]。中长期预测多用于机组检修计划、年度发电计划等, 而准确可靠的短期预测对减少弃风、优化发电计划与备用等十分必要^[5]。

目前, 现有风电预测数学模型主要分为两大类: 物理统计法和时间序列法。物理方法^[6]主要通过风电场物理气象信息, 对风电进行预测, 受物理环境影响较大, 预测精度较差, 仅适用于风电场的中长期预测和选址; 时间序列法^[7]则是利用历史及现时的数据去进行系统辨识和预测, 智能计算已逐渐成为该领域的研究热点。此类方法主要包括支持

基金项目: 国家自然科学基金项目资助(51667018, 51367015)

向量机法^[8]、ARMA 模型法^[9]、GARCH 模型法^[10]、混沌理论法^[11]、神经网络法^[12]等, 此类方法在短时风电预测中得到了广泛的应用。神经网络具有学习能力, 广泛应用于风电预测。然而, 人工神经网络对训练数据的要求很高, 为了克服这一问题, 提出了支持向量机(SVM)方法^[13]。支持向量机的基本思想是通过非线性映射将输入数据映射到高维空间中, 然后进行回归, 在解决非线性和高维模式识别等方面具有诸多优势, 可以克服神经网络的过度配置, 是一种性能优良的回归模型。但其核函数局限于连续对称函数, 且支持向量的数目随着训练样本数的增加而线性增长, 增加了后处理过程的计算复杂度。相关向量机(Relevance Vector Machine, RVM)是基于总体贝叶斯框架下稀疏概率模型的一种智能机器学习算法^[14], 使得 RVM 方法具有灵活的核函数选取及参数优化功能, 因此比 SVM 方法具有更为出色的预测和泛化能力, 有效改善了传统人工智能方法在计算概率信息方面的不足。因核参数宽度值决定了核函数具体形态, 直接影响预测精度, 因此需对相关向量机的核参数进行优化, 已有学者提出采用粒子群算法(PSO)和遗传算法(GA)等优化算法优化模型参数^[15], 但都存在过早收敛及精度较差的问题。GSA 算法^[16]相较于其他智能优化算法具有结构简单、参数较少、全局寻优能力强等特点。现有研究表明, GSA 算法的收敛速度要明显优于粒子群算法和遗传算法。但是 GSA 也存在着易陷入早熟收敛和局部最优、搜索精度不足以及搜索能力弱等缺点。

针对上述问题, 本文提出了一种结合自适应粒子群算法(APSO)的 APSO-GSA 混合优化算法, 通过引入惯性质量自适应修正、粒子学习及全局记忆机制以及更新保留策略, 改善了 GSA 算法收敛速度较慢及粒子对自身经验和群体经验学习不足的缺点。同时以 RVM 理论为核心, 建立了 RVM 模型与 APSO-GSA 算法相结合的短期风电功率预测模型, 利用提出的 APSO-GSA 算法全局寻优的特性对 RVM 参数进行优化以提高预测准确性。通过不同模型间的对比, 包括 BP、RVM、RVM-PSO 和 RVM-GSA 验证了本文所提模型具有适应效果好、泛化能力强、运算效率高等优点。

1 基于 RVM 的风电功率预测模型

RVM 是 Tipping 基于贝叶斯概率学习理论提出的一种与 SVM 相似的稀疏概率模型^[17], 与 SVM 相比, RVM 在先验参数的结构基础上采用主动相关决策模型移除不相关点, 使得相关向量的数目远远小于 SVM, 具有高度稀疏性。具体过程实现如下:

若给定的训练样本输入向量 x_n 和与之对应的目标 t_n , 则 RVM 回归模型可定义为

$$t_n = \sum_{i=1}^N w_i K(x, x_i) + w_0 + \xi_n \quad (1)$$

式中: N 为样本数量; t 为标量输出; w_i 为第 i 个输出对应的权值; ξ_n 为独立分布的零均值高斯噪声; $K(x, x_i)$ 为核函数。

较高的稀疏性决定了 RVM 核函数的运算量将大大减少, 因此, 灵活地选择核函数类型对预测结果至关重要。本文中使用时高斯核函数作为 RVM 的核函数。高斯核函数为

$$K(x, x_i) = \exp(-\|x - x_i\|^2 / 2\sigma^2) \quad (2)$$

假定 t_n 为相互独立分布的目标值, 则整个训练数据的似然函数为

$$\text{prob}(t|w, \sigma^2) = (2\pi\sigma^2)^{-\frac{N}{2}} \exp\left(-\frac{1}{2\sigma^2} \|t - \phi w\|^2\right) \quad (3)$$

式中: ϕ 为 $N \times (N+1)$ 的矩阵, 且 $\phi(x_n) = (1, K(x_n, x_1), K(x_n, x_2), \dots, K(x_n, x_n))^T$ 。

采用稀疏贝叶斯原理对 w 赋予零均值高斯先验分布得

$$\text{prob}(w|\alpha) = \prod_{i=0}^N N(w_i | 0, \alpha_i^{-1}) \quad (4)$$

式中, α 为 $N+1$ 维超参数向量。

定义先验分布后, 根据贝叶斯原理, 所有未知参数的后验分布为

$$\text{prob}(w|t, \alpha, \sigma^2) = (2\pi)^{-\frac{N+1}{2}} |\Sigma|^{-\frac{1}{2}} \times \exp\left\{-\frac{1}{2}(w - \mu)^T \Sigma^{-1}(w - \mu)\right\} \quad (5)$$

其中, 后验协方差矩阵为

$$\begin{cases} \mu = \sigma^{-2} \Sigma \phi^T t \\ \Sigma = (\sigma^{-2} \Sigma \phi^T \phi + A)^{-1} \\ A = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_n) \end{cases} \quad (6)$$

RVM 学习过程就是计算超参数后验模型的过程, 就是寻找使得式(5)取得最大值时的超参数 α 和方差 σ^2 , α 和 σ^2 的计算公式为

$$\begin{aligned} \alpha_{i, \text{new}} &= \frac{1 - \alpha_i \Sigma_{ii}}{\mu_i^2} \\ \sigma_{\text{new}}^2 &= \frac{\|t - \phi \mu\|^2}{N - \sum_i (1 - \alpha_i \Sigma_{ii})} \end{aligned} \quad (7)$$

式中: Σ_{ii} 为后验权重值方差矩阵的对角线元; μ_i 为第 i 个后验分布的权重值。

在超参数估计过程中, 不断调整最大化的 α_{max} 和 σ_{max}^2 对新数据 x_{new} 进行预测。式(8)、式(9)分别为

RVM 单点预测结果和预测结果的系统方差。

$$\begin{cases} \text{prob}(t_{\text{new}} | t, \alpha_{\text{max}}, \sigma_{\text{max}}^2) = N(t_{\text{new}} | y_{\text{new}}, \sigma_{\text{new}}^2) \\ y_{\text{new}} = \mu^T \phi(x_{\text{new}}) \end{cases} \quad (8)$$

$$\sigma_{\text{new}}^2 = \sigma_{\text{max}}^2 + \phi(x_{\text{new}})^T \Sigma \phi(x_{\text{new}}) \quad (9)$$

2 基于 GAS 和 APSO 的混合优化算法

由于 RVM 核参数选择是影响其预测性能的主要因素, 为进一步改善 RVM 模型的预测效果, 需对模型参数进行优化, 以降低数据复杂度, 提高预测精度^[18]。因此, 优化算法的收敛性对本文预测算法的精度会有直接影响, 鉴于 GAS 快速收敛性及 APSO 的适应度函数修正、全局记忆及信息交换能力, 本文采用混合优化算法对 RVM 模型进行参数优化。

2.1 万有引力搜索算法原理

GSA 是模拟物理学上万有引力定律和牛顿第二定律而产生的一种智能种群优化算法^[19], 即中立和质量相互作用的算法。在 GSA 中, 将一组在空间运行的粒子视为多目标问题的潜在解, 在迭代进化过程中, 将每个粒子视为遵循牛顿第二定律, 因此, 受万有引力的相互作用影响, 各粒子之间存在着相对运动且运动的方向是朝着质量大的粒子的方向, 也就是优化问题的最优解方向。基本万有引力算法表述如下:

假设一个引力系统中由粒子 X_i 构成的规模为 N 的种群, 并定义粒子 i 的位置 $X_i = (X_i^1, X_i^2, X_i^3, \dots, X_i^n)$, ($i=1, 2, \dots, N$), 由牛顿万有引力定律可知, d 维空间中, 在第 t 次迭代进化时, 粒子 i 、 j 间的引力可以表示为

$$F_{ij}^d(t) = G(t) \frac{M_i(t)M_j(t)}{R_{ij}(t) + \varepsilon} (x_j^d(t) - x_i^d(t)) \quad (10)$$

式中: M_i 与 M_j 分别表示为粒子 i 、 j 间的惯性质量; $G(t)$ 为第 t 代的万有引力系数; $R_{ij}(t)$ 表示为粒子 i 、 j 间的欧氏距离。计算公式分别为

$$G(t) = G_0 \times e^{(-\alpha \frac{t}{T})} \quad (11)$$

$$R_{ij}(t) = \|X_i(t), X_j(t)\| \quad (12)$$

式中: G_0 为初始引力常量; α 为引力系数变化系数。

粒子 i 的惯性质量 $M_i(t)$ 根据适应度函数定义为

$$\begin{cases} m_i(t) = \frac{fit_i(t) - \min(fit_i(t))}{\max(fit_i(t)) - \min(fit_i(t))} \\ M_i(t) = \frac{m_i(t)}{\sum_{j=1}^N m_j(t)} \end{cases} \quad (13)$$

式中: $fit_i(t)$ 表示引力算法进化至第 t 代时, 粒子 i 的适应度函数值; $\max fit_i(t)$ 、 $\min fit_i(t)$ 分别表示第 t 代粒子 i 的最大、最小适应度函数值。

为了使算法具有随机性, 作用在 d 维上粒子 i 所受合力可以表示为

$$F_i^d(t) = \sum_{j=1, j \neq i}^{K_{\text{best}}} \text{rand}_j \times F_{ij}^d(t) \quad (14)$$

式中: K_{best} 初始值为 $K_0=N$, 随着时间推移逐渐减小; rand_j 为区间[0,1]的随机数。

引力算法进化至第 t 代时, 第 d 维上粒子 i 的加速度可以表示为

$$a_i^d(t) = \frac{F_i^d(t)}{M_i(t)} \quad (15)$$

根据万有引力搜索算法原理, 在进化过程中, 不断地根据迭代计算得到的加速度来更新粒子 i 的速度与位置, 直到全局最优解达到预设精度或最大迭代次数, 更新公式如式(16)所示。

$$\begin{cases} v_i^d(t+1) = \text{rand}_j v_i^d(t) + a_i^d(t) \\ x_i^d(t+1) = x_i^d(t) + v_i^d(t+1) \end{cases} \quad (16)$$

式中: $v_i^d(t)$ 、 $x_i^d(t)$ 、 $a_i^d(t)$ 分别为粒子 i 第 t 代时第 d 维空间的速度、位置及加速度。

根据分析上述万有引力搜索算法原理可知:

1) 算法在迭代进化过程中仅利用当前粒子位置信息引导算法搜索最优解, 缺少群体记忆功能与群体信息共享机制。

2) 随着算法迭代次数增加, 可能丢失部分具有良好进化趋势但质量较小的粒子, 导致种群的多样性降低, 易造成算法早熟收敛或陷入局部最优。

因此, 针对万有引力搜索算法缺少跳出局部最优机制和群体记忆功能等缺陷, 对其进行改进以提高其搜索寻优精度, 进而应用于 VVRVM 模型的关键参数寻优, 实现更加精确的短期风电功率预测。

2.2 APSO-GSA 算法

利用 GSA 算法的快速收敛能力, 结合自适应粒子群算法在粒子的适应度函数修正、社会信息交换能力及加强全局寻优等特点, 分别从粒子惯性质量、全局搜索及信息交互能力方面对万有引力搜索算法做相应改进。

(1) 惯性质量的自适应修正

由式(15)可知, 万有引力搜索算法中粒子的惯性质量由其所在位置所求得的适应值决定, 因此惯性质量越大, 所代表的优化问题的解越接近搜索空间中的最优解, 而粒子的惯性质量与适应度呈正相关性, 同理适应度越大, 表示粒子越优秀。针对算法迭代过程中可能丢失部分具有良好进化趋势但质

量较小的粒子以及最优值振荡的缺陷, 考虑同一代粒子间的差异性, 提出根据粒子的进化状态对权重系数 $\omega_i(t)$ 进行自适应调整, 使 $\omega_i(t)$ 值较大的粒子具有更好的局部搜索能力, 而 $\omega_i(t)$ 值较小但具有良好进化趋势的粒子拥有较好的全局搜索能力。

粒子 x_i 第 t 次寻优完成的历史适应度均值 $\overline{fit}(t)$ 可以表示为

$$\overline{fit}(t) = \frac{1}{N} \sum_{i=1}^N fit_i(t) \quad (17)$$

适应度优于 $\overline{fit}(t)$ 的粒子数为 N_1' , 均值为 $\overline{fit}^1(t)$; 非优于 $\overline{fit}(t)$ 的粒子数为 N_2' , 均值为 $\overline{fit}^2(t)$ 。

$$\begin{cases} \overline{fit}^1(t) = \frac{1}{N_1'} \sum_{i=1}^{N_1'} fit_i(t), & (fit_i(t) < \overline{fit}(t)) \\ \overline{fit}^2(t) = \frac{1}{N_2'} \sum_{i=1}^{N_2'} fit_i(t), & (fit_i(t) \geq \overline{fit}(t)) \end{cases} \quad (18)$$

本文采用权重系数在 $[0.5, 1.5]$ 范围内随着适应度值动态变化的方式进行自适应调整, 其公式为

$$\omega_i(t) = \begin{cases} 1.5, & (fit_i(t) \geq \overline{fit}^1(t)) \\ \exp\left(\frac{fit_i(t) - \overline{fit}(t)}{\overline{fit}(t)}\right), & (\overline{fit}^2(t) \leq fit_i(t) < \overline{fit}^1(t)) \\ 0.5, & (fit_i(t) \leq \overline{fit}^2(t)) \end{cases} \quad (19)$$

式中, $\omega_i(t)$ 表示粒子 x_i 在第 t 次寻优时对应的惯性权重。

改进后的每个粒子的惯性质量计算公式为

$$M_i(t) = \omega_i(t) \times M_i(t) \quad (20)$$

惯性质量的自适应修正具有以下优点: 使得同一代粒子中, 根据粒子的自身特点, 使惯性质量大的粒子在算法的下一代迭代过程中拥有更大的惯性质量, 增强局部寻优能力, 而惯性质量小的粒子在下一代迭代过程中其惯性质量变小, 使得该粒子能够有较快的全局搜索能力, 促进算法在全局搜索与局部搜索之间的协调性, 提高算法的搜索效率和收敛精度。

(2) 粒子的学习及全局记忆能力

在自适应粒子群算法中, 考虑了粒子间的信息交互功能, 利用学习因子 (c_1 、 c_2) 对粒子的自身经验及群体经验进行学习, 通过动态调整认知系数 c_1 及社会系数 c_2 , 既能保证个体快速寻优, 又能够保持群体的多样性。

由于万有引力搜索算法不具备记忆能力, 无法

根据当前位置结合自身特性进行位置更新, 因此本文引入自适应粒子群算法的信息交互能力及全局记忆能力来改进引力搜索算法多样性不足及最优值振荡的缺陷。混合优化算法 APSO-GSA 既遵循引力搜索算法的万有引力定律, 又具备了自适应粒子群算法的自身经验学习和群体记忆交流功能。根据 Eberhart 的结论, 只要学习因子在收敛域内沿着某一曲线运行, 且 c_1 随着进化时间递减, c_2 随着进化时间递增, 即可保证算法收敛^[20]。为控制 APSO 的记忆能力对 GSA 的影响程度, 本文采用学习因子 $c_1^i(t)$ 、 $c_2^i(t)$ 在 $[0.5, 2.5]$ 范围内随着适应度值动态变化的方式进行自适应调整, 以平衡引力和群体记忆对混合优化算法的影响。其公式为

$$\begin{cases} c_1^i(t) = \frac{1}{0.2 + 0.2e^{2.2fit_i(t)}} \\ c_2^i(t) = \frac{1}{0.1 + 0.2e^{-1.85fit_i(t)}} \end{cases} \quad (21)$$

当 $c_1^i(t)$ 与 $c_2^i(t)$ 的和大于 4 时, 需要对其进行标准化, 即

$$c_k^i(t) = 4c_k^i(t) / \sum_{k=1}^2 c_k^i(t) \quad (22)$$

改进后的 APSO-GSA 混合优化算法粒子运动方程可以表示为

$$\begin{cases} v_i^d(t+1) = \omega_i(t)v_i^d(t) + c_1^i(t)rand_{i1}(P_{ibest}^d - a_i^d(t)) + c_2^i(t)rand_{i2}(G_{best}^d - x_i^d(t)) + a_i^d(t) \\ x_i^d(t+1) = v_i^d(t+1) + x_i^d(t) \end{cases} \quad (23)$$

(3) 粒子的更新保留策略

万有引力搜索算法迭代过程中可能存在某些粒子适应度不满足约束条件, 若进一步用于计算将导致算法效率降低。为使优化算法的搜索和求解达到平衡, 逐步减少迭代过程中式(14)中粒子的数目, 提高算法的求解速度, 本文提出一种粒子更新策略。在粒子更新过程中, 将种群中适应度及惯性质量满足约束条件的粒子记录在安全粒子集中, 同时在此更新粒子, 将具有良好进化趋势但惯性质量相对较小的粒子放入非安全粒子集中。粒子更新策略如图 1 所示。

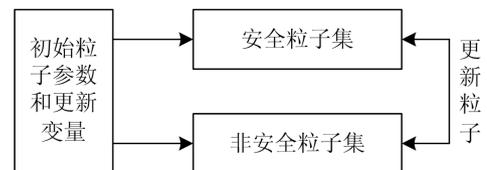


图 1 粒子更新策略

Fig. 1 Particle update strategy

通过引入权重系数的自适应修正、粒子的学习和全局记忆机制以及粒子的更新保留策略, 克服基本万有引力算法收敛速度较慢及粒子对自身经验和群体经验学习不足的缺点。

2.3 APSO-GAS 算法步骤

具体步骤描述如下:

Step1 设定种群初始化参数, 包括: 算法迭代次数、惯性权值及其上下限、学习因子范围, 同时初始化种群的速度、位置。

Step2 计算粒子的适应度值, 分别记录粒子个体和群体的最大惯性质量及最佳适应度值。

Step3 更新变量, 计算粒子所受万有引力合力、速度与加速度。

Step4 根据式(19)的惯性权重修正更新粒子惯性质量; 根据式(21)的群体记忆能力更新粒子的速度。

Step5 更新粒子, 采用粒子更新策略避免非安全粒子的重复出现。

Step6 更新安全粒子集中的个体及群体的最优位置及最佳适应度值。

Step7 判断计算结果是否满足终止条件, 若满足则终止计算, 输出算法最优解。若不满足则重复 Step3 至 Step6 步, 直到达到最大迭代次数或满足终止条件为止。

APSO-GSA 优化算法流程图如图 2 所示。

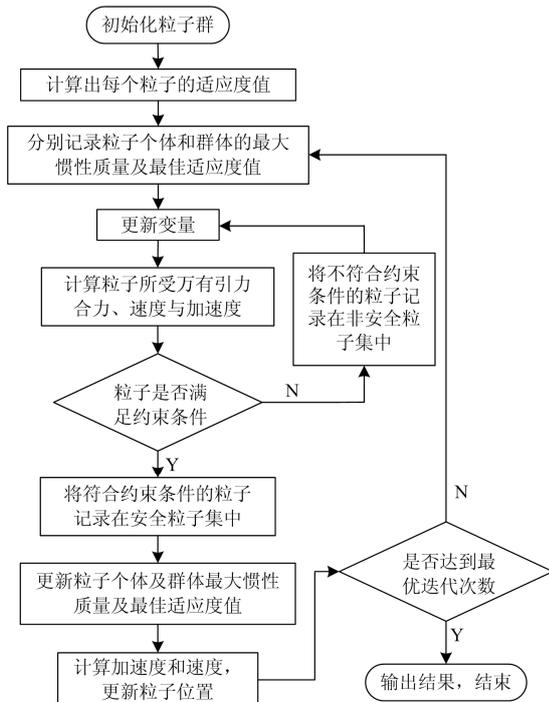


图 2 APSO-GSA 算法流程图

Fig. 2 APSO-GSA algorithm flow chart

3 基于 APSO-GSA 和相关向量机的短期风电功率预测模型

3.1 用 APSO-GSA 优化 RVM 参数

用 APSO-GSA 算法优化得到的粒子赋值给 RVM 待优化参数, 将 Matlab/Simulink 模型与 APSO-GSA 算法相结合, 通过粒子对应的性能指标相联系, 再将性能指标作为粒子适应度值, 最后通过判断是否满足结束条件来判断是否结束寻优。寻优的过程如图 3 所示。

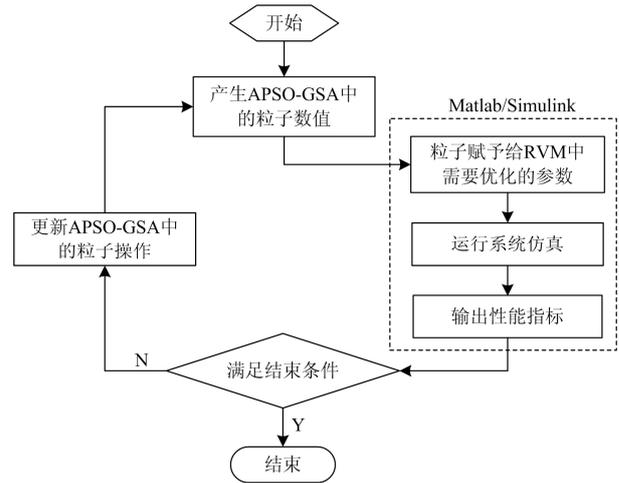


图 3 APSO-GSA 优化 RVM 参数过程示意图

Fig. 3 Schematic diagram of APSO-GSA for optimizing RVM parameters

3.2 预测误差评价指标

准确度评价是预测过程的重要组成部分, 本文采用三种主要的误差指标来评估短期风电功率单点预测精度, 分别为均方根误差^[21](RMSE)、平均绝对误差(MAE)及相关系数 ρ 。RMSE 可评估一段时期内的整体误差, 而 MAE 偏重代表系统实时偏差。相关系数 ρ 用于进行相关分析, 如果 ρ 的值接近 1, 则两者之间的相关性更强。以上指标定义如下。

1) 均方根误差 E_{RMSE}

$$E_{\text{RMSE}} = \frac{1}{P_{\text{cap}}} \sqrt{\frac{1}{N} \sum_{t=1}^N (P_t^{\text{act}} - P_t^{\text{pred}})^2} \quad (24)$$

2) 平均绝对误差 E_{MAE}

$$E_{\text{MAE}} = \frac{1}{NP_{\text{cap}}} \sum_{t=1}^N |P_t^{\text{act}} - P_t^{\text{pred}}| \quad (25)$$

3) 相关系数 ρ

$$\rho = \frac{\text{Cov}(P_t^{\text{pred}}, P_t^{\text{act}})}{\sqrt{\text{Var}[P_t^{\text{pred}}] \text{Var}[P_t^{\text{act}}]}} \quad (26)$$

式中: P_t^{pred} 、 P_t^{act} 分别表示在 t 的风电场或单台机

组输出功率的预测值、实际值； P_{cap} 为预测对象的装机容量； N 为样本数量； Cov 表示协方差； Var 表示方差。

4 实例仿真与分析

4.1 数据选择与模型参数初始化

(1) 风电样本数据的选取

为验证提出的 RVM-APSO-GSA 模型对短期风电功率的建模能力，选取中国西北某风电场 2018 年 5 月 1 日至 2018 年 5 月 31 日间的风机实际运行数据及该地区数值天气数据为例进行研究，该风电场的额定功率为 25 MW，总观测值为 744 h，数据样本的间隔时间为 1 h，风电场功率曲线如图 4 所示。将选取的风电场实际运行数据分为以下三个连续的部分：① 前 50%的 372 h 观测数据用于训练；② 剩下 44%的 324 h 观测数据用于验证；③ 最后 6%总涵盖 48 h 的观测数据用于测试。模型输入变量为数值天气风速、风向正弦值和余弦值，学习目标为实测功率。

(2) RVM-APSO-GSA 模型参数初始化

RVM-APSO-GSA 模型中相关参数的初始值设置为：粒子数 50，最大迭代次数 $T=300$ ，重力常数 $G_0=100$ ，衰减率 $\alpha=20$ ，迭代终止判据为最优个体连续 30 代保持不变或达到最大迭代次数 300 次。

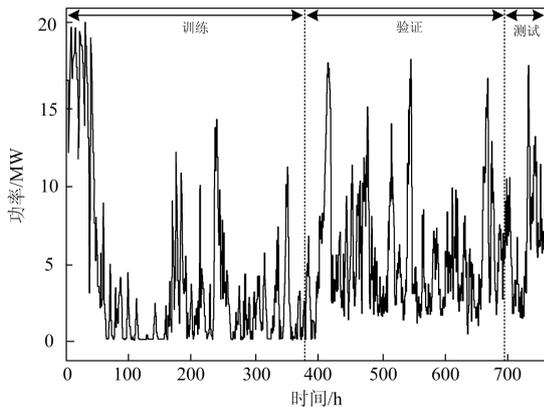


图 4 风电场实测功率曲线

Fig. 4 Measured power curve of wind farm

4.2 算法性能对比分析

本文仿真实验在 Intel®Core™i5-7400 CPU@3.00 GHz，内存 8.00 G，64 位 Windows10 操作系统和 Matlab 2015b 环境下对本文所提 APSO-GSA 混合算法进行仿真实验，并与 BP 神经网络、RVM 模型、基于 PSO 优化的 RVM 模型以及基于 GSA 优化的 RVM 模型 4 种建模方法进行对比。设置最大允许误差为 $\varepsilon=10^{-4}$ ，通过 372 h 观测数据及数值天气数据

训练，由 5 个预测模型分别得到 324 个验证数据点的性能指标如表 1 所示。

表 1 各预测方法的评价指标

Table 1 Evaluation indexes of each prediction method

模型	BP	RVM	RVM-PSO	RVM-GSA	RVM-APSO-GSA
$R_{RMSE} / \%$	4.998 7	4.830 6	4.679 3	4.678 2	4.547 8
$M_{MAE} / \%$	3.846 6	3.761 9	3.617 7	3.612 5	3.403 1
ρ	0.925 7	0.928 8	0.931 8	0.932 4	0.947 6

从表 1 可以看出，RVM-APSO-GSA 模型的所有预测性能指标均优于其余 4 种模型(BP、RVM、RVM-PSO、RVM-GSA)。

为验证模型的运算效率，对 5 种预测模型的计算时间(训练时间、测试时间)和向量维度进行统计，以检验模型的计算效率和泛化能力，并以 20 次运行时间的平均值列于表 2。

表 2 不同预测模型计算效率检验结果

Table 2 Efficiency test results of different prediction models

	训练时间/s	测试时间/s	向量个数
BP	360.69	5.78	
RVM	22.63	1.37	110.14
RVM-PSO	14.88	0.86	94.28
RVM-GSA	13.94	0.78	88.62
本文模型	10.02	0.60	80.46

由表 2 可知：本文所提 RVM-APSO-GSA 模型计算成本低、参与运算的向量少、模型结构更为简单，提高了模型实时计算的能力。

4.3 不同模型对风电功率预测效果的比较

为验证 RVM-APSO-GSA 的风电功率预测的效果，取风电场实际运行数据中的 48 个测试数据对 5 个模型(BP、RVM、RVM-PSO、RVM-GSA、RVM-APSO-GSA)的预测性能进行验证，得出的风电功率预测结果与实际值数据比较如图 5 所示。

直观判断预测模型建立的是否合理主要观察其跟踪实际曲线变化的趋势，由图 5、图 6 可以明显看出，RVM-APSO-GSA 模型的性能指标优于其余 4 种模型的性能指标。通过图 6 的预测误差对比曲线可以计算出 5 种预测模型预测误差分别小于 3%、5%、10%、15%的点数及其在预测点中的相应百分比，统计结果如表 3 所示。

由表 3 可知，RVM-APSO-GSA 模型的绝对误差小于 3%的预测点有 20 个，占总量的 41.67%；小于 5%的预测点有 33 个，占总量的 68.75%；小于 10%的预测点有 48 个，占总量的 100%。结果表明，RVM-APSO-GSA 模型的预测性能较好，预测精度较高。因此，本文提出的 RVM-APSO-GSA 模型适用于短期风电预测。

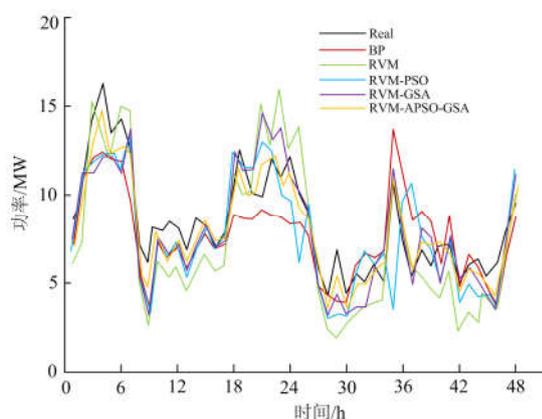


图 5 不同模型预测值与实际值比较

Fig. 5 Comparison of prediction values and real values for different models

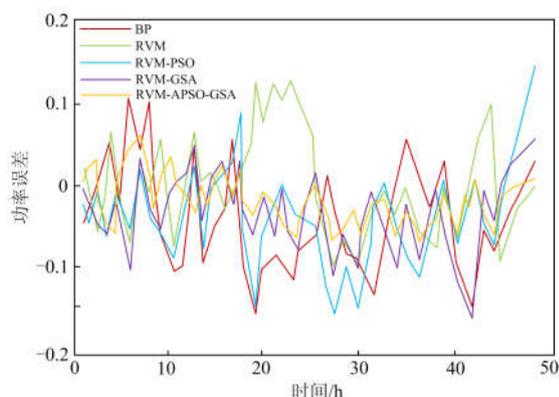


图 6 预测误差对比曲线

Fig. 6 Comparison curve of prediction error

表 3 测试集预测点的精度估计

Table 3 Accuracy estimation of prediction point for test set

模型		BP	RVM	RVM-PSO	RVM-GSA	RVM-APSO-GSA
<3%	数量	11	9	13	14	20
	占比	22.92	18.75	27.08	29.17	41.67
<5%	数量	21	18	22	24	33
	占比	43.75	39.58	45.83	50.00	68.75
<10%	数量	36	35	41	41	48
	占比	75.00	72.92	85.42	85.42	100

5 结论

针对现有预测方法在小样本学习、精细化建模、概率性预测等方面的缺陷, 本文建立了相关向量机(RVM)的风电功率预测模型, 并运用 APSO-GSA 混合优化算法对系统参数进行优化。通过仿真验证, 可以得到以下结论。

(1) RVM-APSO-GSA 模型的均方根误差、平均

绝对误差及相关系数指标均优于其余 4 种模型(BP、RVM、RVM-PSO、RVM-GSA)。

(2) 兼备 APSO 和 GSA 优点的 APSO-GSA 算法克服了 GSA 算法缺少群体记忆功能与群体信息共享机制以及容易陷入局部最优的缺陷, 并结合自适应粒子群算法(APSO)在粒子的适应度函数修正、社会信息交换能力及强全局寻优等特点收敛性能更强, 适应度值得以改善。

(3) 通过与 BP、RVM、RVM-PSO、RVM-GSA 模型的仿真结果相比, 所提方法可以利用少量相关样本精确模拟不同气象条件下的风力发电特性, 提高了单点预测的精度和可靠性。

精细化、动态化建模是未来风电功率预测不确定性分析的关键发展方向, 本文研究中所提相关性建模方法减少了计算规模和时间, 对未来的在线风电功率超短期预测起到了铺垫作用。但仍需进一步探索: 增加不同类型的验证案例进行分析, 探索不同单点预测模型对所提模型精度的影响, 优化索引参数提升模型精度。

参考文献

- [1] 叶林, 李智, 孙铂皓, 等. 基于随机预测控制理论和功率波动相关性的风电集群优化调度[J]. 中国电机工程学报, 2018, 38(11): 3172-3183.
YE Lin, LI Zhi, SUN Bohao, et al. Optimal dispatch of wind power cluster based on stochastic predictive control theory and power fluctuation correlation[J]. Proceedings of the CSEE, 2018, 38(11): 3172-3183.
- [2] 王静, 李维德. 基于 CEEMD 和 GWO 的超短期风速预测[J]. 电力系统保护与控制, 2018, 46(9): 76-81.
WANG Jing, LI Weide. Ultra-short-term wind speed prediction based on CEMD and GWO[J]. Power System Protection and Control, 2018, 46(9): 76-81.
- [3] 潘尔生, 李晖, 肖晋宇, 等. 考虑大范围多种类能源互补的中国西部清洁能源开发外送研究[J]. 中国电力, 2018, 51(8):162-168.
PAN Ersheng, LI Hui, XIAO Jinyu, et al. Study on clean energy development and outward delivery in western china considering large-scale and multi-type energy complementarity[J]. Electric Power, 2018, 51(8): 162-168.
- [4] 陈昊, 张建忠, 许超, 等. 基于多重离群点平滑转换自回归模型的短期风电功率预测[J]. 电力系统保护与控制, 2019, 47(1): 73-79.
CHEN Hao, ZHANG Jianzhong, XU Chao, et al. Short-term wind power prediction based on multiple outliers smoothing conversion autoregressive model[J]. Power

- System Protection and Control, 2019, 47(1): 73-79.
- [5] SANTHOSH M, VENKAIHAH C, KUMAR D M V. Ensemble empirical mode decomposition based adaptive wavelet neural network method for wind speed prediction[J]. Energy Conversion & Management, 2018, 168: 482-493.
- [6] HU J, WANG J. Short-term wind speed prediction using empirical wavelet transform and Gaussian process regression[J]. Energy, 2015, 93: 1456-1466.
- [7] SAFARI N, CHUNG C Y. A novel multi-step short-term wind power prediction framework based on chaotic time series analysis and singular spectrum analysis[J]. IEEE Transactions on Power Systems, 2018, 33(1): 590-601.
- [8] 阎洁, 李宁, 李莉, 等. 短期风电功率动态云模型不确定性预测方法[J]. 电力系统自动化, 2019, 43(3): 17-23.
YAN Jie, LI Ning, LI Li, et al. Uncertainty prediction method of dynamic cloud model for short-term wind power[J]. Automation of Electric Power Systems, 2019, 43(3): 17-23.
- [9] 田波, 朴在林, 郭丹, 等. 基于改进 EEMD-SE-ARMA 的超短期风功率组合预测模型[J]. 电力系统保护与控制, 2017, 45(1): 72-79.
TIAN Bo, PIAO Zailin, GUO Dan, et al. Wind power ultra short-term model based on improved EEMD-SE-ARMA[J]. Power System Protection and Control, 2017, 45(1): 72-79.
- [10] 郑婷婷. 基于混沌理论的短期风电功率预测方法研究[D]. 大连: 大连理工大学, 2013.
ZHENG Tingting. Research on short-term wind power prediction method based on chaos theory[D]. Dalian: Dalian University of Technology, 2013.
- [11] 徐龙博, 王伟, 张滔, 等. 基于神经网络平均影响值的超短期风电功率预测[J]. 电力系统自动化, 2017, 41(21): 46-51.
XU Longbo, WANG Wei, ZHANG Tao, et al. Ultra-short term wind power prediction based on mean impact value of neural network[D]. Automation of Electric Power Systems, 2017, 41(21): 46-51.
- [12] YANG J. A novel short-term multi-input-multi-output prediction model of wind speed and wind power with LSSVM based on improved ant colony algorithm optimization[J]. Cluster Computing, 2019, 22(S2): 3293-3300.
- [13] TORABI A, MOUSAVY S A K, DASHTI V, et al. A new prediction model based on cascade NN for wind power prediction[J]. Computational Economics, 2018(4): 1-25.
- [14] MORTAZAVI M, ALMASGANJ F. Optimal midcourse guidance of an air-to-air missile via SVM and RVM[J]. Soft Computing, 2019, 23(15): 6603-6616.
- [15] 范磊, 卫志农, 李慧杰, 等. 基于变分模态分解和蝙蝠算法-相关向量机的短期风速区间预测[J]. 电力自动化设备, 2017, 37(1): 93-100.
FAN Lei, WEI Zhilong, LI Huijie, et al. Short-term wind speed interval prediction based on VMD and BA-RVM algorithm[J]. Electric Power Automation Equipment, 2017, 37(1): 93-100.
- [16] MBUVHA R, BOULKAIBET I, MARWALA T, et al. A hybrid GA-PSO adaptive neuro-fuzzy inference system for short-term wind power prediction[C] // International Conference on Swarm Intelligence, 2018.
- [17] 阎洁. 风电功率预测不确定性及电力系统经济调度[D]. 北京: 华北电力大学, 2016.
YAN Jie. Uncertainty of wind power prediction and economic dispatch of power system[D]. Beijing: North China Electric Power University, 2016.
- [18] YUAN X, TAN Q, LEI X, et al. Wind power prediction using hybrid autoregressive fractionally integrated moving average and least square support vector machine[J]. Energy, 2017, 129: 122-137.
- [19] PURI V, CHAUHAN Y K, SINGH N. Optimization of design with estimation of performance parameters of inner rotor permanent magnet synchronous machine used in VAWT using GSA and GSA-PSO[J]. International Journal of Energy & Statistics, 2017, 5(2).
- [20] 宋雨妍, 王渝红, 刘天宇, 等. 基于多目标离散粒子群算法的电容隔直装置优化配置[J]. 电网技术, 2018, 42(12): 1-10.
SONG Yuyan, WANG Yuhong, LIU Tianyu, et al. Modeling and algorithm for dynamic economic dispatch of power systems with wind farms[J]. Power System Technology, 2018, 42(12): 1-10.
- [21] SANTAMARIA-BONFIL G, REYES-BALLESTEROS A, GERSHENSON C. Wind speed forecasting for wind farms: a method based on support vector regression[J]. Renewable Energy, 2016, 85: 790-809.

收稿日期: 2019-03-27; 修回日期: 2019-05-13

作者简介:

田璧源(1989—), 男, 通信作者, 硕士, 研究方向为风电功率预测、不确定性分析、新能源电力系统多能互补调度。

E-mail: 2528586070@qq.com

(编辑 张爱琴)