

一种风电功率混沌时间序列概率区间 简易预测模型*

章国勇¹⁾²⁾ 伍永刚^{1)†} 张洋²⁾ 代贤良¹⁾

1)(华中科技大学水电与数字化工程学院, 武汉 430074)

2)(西澳大利亚大学电气电子及计算机学院, 澳大利亚 珀斯 6009)

(2014年1月3日收到; 2014年3月17日收到修改稿)

本文基于极限学习机构建了一种简易模型以直接输出风电功率概率区间. 同时, 为优化模型训练过程中输出区间的性能, 本文基于对数据集区间带偏差信息的分析构建了一种新的优化准则, 并采用量子细菌觅食优化算法以获取问题的最优解, 提高模型泛化能力. 对比分析两个风电场在不同置信水平和不同优化准则下的概率预测结果, 仿真表明本文模型具有更高的可靠性和更窄的区间带宽, 可为风电并网安全稳定运行提供决策支持.

关键词: 混沌时间序列, 概率区间预测, 极限学习机, 量子细菌觅食优化

PACS: 88.50.-k, 03.65.-w

DOI: 10.7498/aps.63.138801

1 引言

受风电输出功率强随机性和不确定性影响, 风电并网发电对电网安全稳定运行提出了新的要求. 将风电功率预测信息纳入电网决策是解决风电波动的主要技术之一. 准确的风电功率预测不仅可以减少系统备用容量和储能, 降低系统运行成本, 同时也有助于减轻风电接入对电网的冲击, 提高电网运行可靠性^[1].

为揭示风电功率序列内在的动态序列, 文献^[2]利用非线性方法对风电时间序列混沌特性进行识别, 为风电预测提供了基础. 现有混沌时间序列预测研究大多基于对未来时刻可能输出值进行预测^[3-5], 仿真表明这种单一点预测模型虽然能获得较高的预测精度, 但由于风电输出功率受自然风速、风轮机运行状态等不确定因素影响, 其点预测模型的误差仍无法避免, 且预测结果不能反映其可靠性. 这种单纯的将风电功率视为确定性变量将使得电力系统运行面临较大的风险^[6]. 作为点预测的

一个延伸, 概率区间预测通过给出满足一定置信概率下风电功率的可能波动范围, 一方面能有效地描述风电输出功率的不确定性, 评估电网潜在运行风险^[7]; 另一方面决策者可灵活选择不同置信概率下可能波动范围, 并依此进一步确定系统优化运行方式. 目前, 引入风电功率概率预测信息的系统优化运行已成为研究热点^[6-9], 这也使得风电概率区间预测变得更加迫切且有意义.

针对风电功率混沌时间序列概率预测的研究目前大多基于对风电点预测误差分布特性的分析^[10,11], 而实际中对于具体风电场而言难以寻求与假设一致的分布函数. 文献^[12-15]分别引入了分位点回归分析和核密度估计以获取不同分位点风电功率预测偏差信息, 并通过匹配不同分位点数值得到一组预测区间 (prediction intervals, PIs). 但上述预测模型大都需要复杂的数学计算, 如需计算预测误差相关系数矩阵、联合概率分布函数等, 难以适应电网实际运行中决策者的要求. Khosravi等^[16]基于神经网络结构提出了一种上下限评估

* 国家自然科学基金 (批准号: 51379081) 和湖北省自然科学基金 (批准号: 2011CDA032) 资助的课题.

† 通讯作者. E-mail: ygangwu@163.com

(lower upper bound estimation, LUBE)模型以获取风电功率时间序列预测区间. 该模型较常规概率区间模型更为简单可行, 但传统神经网络的一个重要弊端就是其训练时间过长, 且当训练样本较大时, 其时间代价是巨大的. 极限学习机 (extreme learning machine, ELM)^[17], 作为一种新型的单隐藏层前馈神经网络, 具有训练时间短, 抗干扰能力强等特点, 已在混沌时间序列的点预测模型中得到广泛应用^[18,19].

基于上述分析, 本文构建了一种基于ELM的风电功率概率区间简易预测模型, 利用模型的二维输出数值直接输出风电功率区间预测的上下限. 模型训练过程, 考虑到现有的基于宽度覆盖的区间优化准则 (coverage width-based criterion, CWC)^[16,20] 缺乏对实际数值与预测区间带偏差的合理描述, 难以准确评估当前PIs性能, 本文提出了一种综合考虑数据集区间带偏差信息的区间优化目标函数. 同时, 针对上述非线性优化问题的求解, 现有文献^[16, 21] 采用的模拟退火及粒子群优化算法已被证明在求解复杂优化问题时易陷入局部最优^[22]. 本文结合量子粒子群^[23] 优越的全局搜索能力和细菌觅食优化^[24], 构建一种量子细菌觅食算法以求解概率区间预测优化问题. 三种算法的实例仿真结果对比表明, 改进算法具有更好的全局寻优能力, 能有效提高模型训练过程中风电功率PIs性能. 此外, 两个风电场数据的仿真结果表明本文所述概率区间预测模型简单可行, 基于数据集偏差信息的目标函数较CWC具有更高的可靠性和更窄的区间带宽.

2 风电功率概率区间简易预测模型

2.1 极限学习机

设有 N 个训练样本 $\{(\mathbf{x}_i, \mathbf{t}_i)\}_{i=1}^N$, 其中 $\mathbf{x}_i \in \mathbf{R}^n$, 目标值 $\mathbf{t}_i \in \mathbf{R}^m$, 基于 K 个隐藏节点的网络模型可表示为

$$\sum_{i=1}^K \beta_i g_i(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) = \mathbf{y}_j, \quad j = 1, \dots, N, \quad (1)$$

其中 \mathbf{w}_i 为连接输入节点和隐藏层节点的输入权值, b_i 为隐藏层偏置, β_i 为连接隐藏层与输出层的输出权值. 具有 K 个隐藏节点的单隐藏层神经网络模型以激活函数 $g(\cdot)$ 能够零误差的逼近任意 N 个样

本, 即 $\sum_{j=1}^N \|\mathbf{y}_j - \mathbf{t}_j\| = 0$, 可以表示为

$$\sum_{i=1}^K \beta_i g_i(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) = \mathbf{t}_j, \quad j = 1, \dots, N. \quad (2)$$

上述 N 个方程的矩阵形式可以简写为

$$\mathbf{H}\beta = \mathbf{T}, \quad (3)$$

$$\mathbf{H} = \begin{bmatrix} g_1(\mathbf{w}_1 \cdot \mathbf{x}_1 + b_1) & \dots & g_1(\mathbf{w}_K \cdot \mathbf{x}_1 + b_K) \\ \vdots & \dots & \vdots \\ g_1(\mathbf{w}_1 \cdot \mathbf{x}_N + b_1) & \dots & g_1(\mathbf{w}_K \cdot \mathbf{x}_N + b_K) \end{bmatrix}_{N \times K}, \quad (4)$$

其中 \mathbf{H} 为极端学习机的隐含层输出矩阵, \mathbf{T} 为期望输出向量. ELM 训练过程等价于求取线性系统 $\mathbf{H}\beta = \mathbf{T}$ 的最小二乘解:

$$\|H(\omega_1, \dots, \omega_K, b_1, \dots, b_K)\beta^* - T\|$$

$$= \min_{\beta} \|H(\omega_1, \dots, \omega_K, b_1, \dots, b_K)\beta - T\|. \quad (5)$$

上式等同于寻找最优的权值 β^* 使如下目标函数值最小:

$$C = \sum_{j=1}^K \left[\sum_{i=1}^K \beta_i g_i(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) - t_j \right]^2. \quad (6)$$

ELM 训练过程中, 在 \mathbf{w}_i 和 b_i 随机赋值并保持不变情况下, 仅需确定输出权值 β 以逼近任意训练样本. 根据文献^[17] 证明可知, 所形成的隐含层输出矩阵 \mathbf{H} 是可逆, 并具惟一性, 因此存在精确解使得 $C(\mathbf{w}_i, b, \beta_i) = 0$. 相比于传统的基于梯度下降的BP神经网络模型, ELM 训练过程中输入权和隐藏层偏差随机赋值, 只需求取线性系统 $\mathbf{H}\beta = \mathbf{T}$ 的最小二乘解, 具有结构简单、学习速度快以及良好的泛化性能等优点.

2.2 基于ELM的概率区间上下限评估模型

传统概率区间预测大多基于对风电数据或预测误差的概率分布进行假设, 计算过程复杂, 本文构建一种基于ELM的概率区间上下限评估简易评估模型. 采用双输出神经网络直接输出风电概率区间预测上下限, 模型结构如下图1所示.

上述基于ELM的概率区间预测模型避免了传统LUBE中对神经网络结构参数的选取, 大大降低了模型训练的复杂度. 通过随机产生输入权值和隐藏层偏置信息, 得到确定的隐含层输出矩阵 \mathbf{H} ,

模型的训练过程仅需优化选取不同的输出权值 β 以获取模型的最优输出区间. 因此, 在置信水平 $100(1 - \alpha)\%$ 下风电功率预测区间优化问题可描述: 通过优化风电功率区间预测模型参数, 使其输出区间带宽 $[L^\alpha(x_i), U^\alpha(x_i)]$ 尽可能窄的同时满足

$$P(t_i \in [L^\alpha(x_i), U^\alpha(x_i)]) \geq 100(1 - \alpha)\%. \quad (7)$$

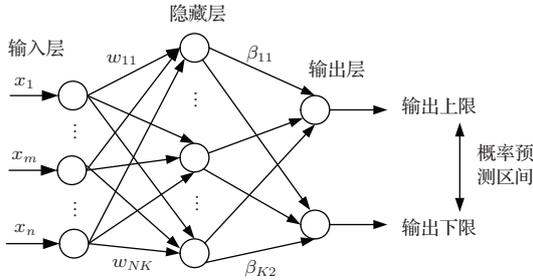


图1 基于 ELM 的概率区间预测模型

3 区间预测优化准则构造

为提高模型训练过程中 PIs 性能, 需首先构建合适的优化目标准则以获取模型最优参数. 评价输出区间的准确性应从两个方面考虑 [25]: 1) 预测结果的可靠性需满足决策者需求; 2) 预测区间带宽尽可能小.

1) 可靠性准则

根据 PIs 定义, 预测目标值 t_i 落入预测区间的概率应满足 $100(1 - \alpha)\%$, 为此引入预测区间可信度 (PI coverage probability, PICP) 来评价其可靠性

$$\text{PICP} = \frac{1}{N_t} \sum_{i=1}^{N_t} \xi_i, \quad (8)$$

其中 N_t 为校验样本数, 如果预测目标值 t_i 包含于区间预测的上下限, 则 $\zeta = 1$, 否则 $\zeta = 0$.

2) 预测区间带宽

如果单纯追求可靠性, 得到的预测区间将失去实用价值, 因为其上下包络线将接近极值, 对决策者毫无意义. 为此, 引入预测区间平均带宽 (PI normalized average width, PINAW) 指标

$$\text{PINAW} = \frac{1}{N_t R} \sum_{i=1}^{N_t} (U_i - L_i), \quad (9)$$

其中 R 为目标值变化范围, 用于对平均带宽进行归一化处理.

3) 目标函数

作为系统决策者, 高可靠性和尽可能小的区间带宽都是风电功率概率预测所追求的, 而实际优化过程中两者是相互矛盾的, PIs 多目标优化模型可表示为

$$\begin{aligned} &\text{Maximize : PICP}(\beta), \\ &\text{Minimize : PINAW}(\beta), \end{aligned} \quad (10)$$

其中应满足 $\text{PINAW}(\beta) > 0; 0 \leq \text{PICP}(\beta) \leq 100\%$. 针对多目标的求解复杂性, 文献 [16, 20] 提出一种基于区间带宽的评价准则将上述多目标转换为单目标

$$\begin{aligned} &\text{CWC} \\ &= \text{PINAW} \cdot (1 + \gamma(\text{PICP}) e^{-\eta(\text{PICP} - \mu)}), \end{aligned} \quad (11)$$

$$\gamma(\text{PICP}) = \begin{cases} 0, & \text{PICP} \geq \mu, \\ 1, & \text{PICP} < \mu, \end{cases} \quad (12)$$

其中 μ 表示置信概率 $100(1 - \alpha)\%$, η 用于 $\text{PICP} < \mu$ 时施加一个惩罚量. 为避免对惩罚参数的选择, 文献 [21] 将 $\text{PICP} \geq \mu$ 作为一个约束条件, 以保证优化结果能够满足决策者需求, 具体描述为

$$\begin{aligned} &\text{Minimize : PINAW}(\beta), \\ &\mu \leq \text{PICP} \leq 100\%. \end{aligned} \quad (13)$$

但该方法实质是将 η 设为一个无穷大数, 对初始化要求较高, 易陷入局部最优. 基于对上述 CWC 描述可知, 当出现 $\text{PICP} < \mu$ 时, CWC 采用惩罚系数 η 来保证系统可靠性要求以获得更好的优化目标. 但此目标函数存在缺陷:

1) 惩罚系数难以决定. CWC 准则中单纯依靠对 PICP 的惩罚来保证系统可靠性, 惩罚系数过大易陷入局部最优出现过训练情形, 过小则可能无法保证系统的可靠性要求.

2) CWC 值不能有效的反映出当前 PIs 的真实情况. 现假设有两种情形, 其各自 PICP 值相等且均小于 μ , 但其偏差实测值程度不同, 而由于惩罚系数的作用, 基于 CWC 准则得到的目标函数值将几乎相同, 无法准区分其优势信息.

风电功率概率区间预测的目标是希望 PIs 带宽较窄的同时尽可能将实测功率包含于区间带内, 训练过程中为保证系统可靠性要求应尽量修正偏离区间带的时间点数据, 基于此思路, 本文通过计算数据集偏差信息提出一种新的概率区间预测优化准则 (PI evaluation criterion, PIC)

$$\text{Minimize : } f(\beta)$$

$$= \text{PINAW} + \gamma(\text{PICP}) \cdot \text{pun}, \quad (14)$$

$$\text{pun} = \sigma_1 \sum_{i=1}^{N_L} (L_i - t_i) + \sigma_2 \sum_{i=1}^{N_U} (t_i - U_i), \quad (15)$$

其中 σ_1 和 σ_2 分别为针对预测目标值小于 L_i 和大于 U_i 的惩罚系数. 相较于 CWC 中仅采用系数 η 对 PICP 偏差施以惩罚, PIC 中数值 pun 更能反映当前 PIs 的性能. 当出现 $\text{PICP} < \mu$ 时, 通过计算当前数据集中目标值偏离区间上下限的程度以确定系统惩罚量, 使得个体趋向于更优位置; 当 $\text{PICP} \geq \mu$ 时, 系统优化目标转化为获取最小的区间带宽.

4 基于量子细菌觅食优化的 PIs 预测框架

为获取上述目标函数 (14) 式的全局最优解, 引入优化算法以评估不同参数下训练数据集的 PIs 性能, 最终输出模型最优参数集. 本文结合量子粒子群优化和细菌觅食优化 (bacterial foraging optimization, BFO) 中个体寻优特点, 提出一种量子细菌觅食优化 (quantum bacterial foraging optimization, QBFO) 算法. 由 BFO 的基本原理可知, 细菌个体通过趋化操作实现自身较强的局部搜索能力, 细菌的繁殖算子相当于进化算法的选择操作, 通过淘汰觅食能力差的个体最终实现算法的收敛. 但传统 BFO 中由于采用个体直接复制的繁殖操作将导致种群多样性的缺乏, 算法也容易因此陷入局部最小区域. 量子细菌觅食算法的设计思想是: 在 BFO 繁殖阶段将细菌个体移至量子空间中描述, 通过利用细菌群共享信息建立量子空间下细菌个体的概率密度函数, 由蒙特卡洛随机采样完成各细菌个体位置的更新, 进而实现种群的繁殖操作, 避免因直接复制导致的种群多样性丢失.

在量子空间中, 细菌个体的状态和位置是不确定的, 由波函数 $\psi(Y, t)$ 来确定, $|\psi|^2$ 是个体位置的概率密度函数. 由文献 [26] 对量子系统中个体的收敛分析可知, 通过对细菌群体构建一个量子化的势阱以使得群体具有聚集态, 而处于量子束缚态的个体能以一定的概率密度出现在空间任意点. 根据文献 [23] 对空间个体运行轨迹分析表明, 要保证算法收敛, 个体 i 第 d 维变量的收敛过程是以 P_d 为局部吸引子, 并满足以下条件:

$$P_d = \frac{\phi_{1d}P_{id} + \phi_{2d}P_{gd}}{\phi_{1d} + \phi_{2d}}, \quad (16)$$

其中, P_{id} 为个体 i 自身第 d 维变量的最优位置, P_{gd} 为第 d 维变量的最优位置. 在吸引子 P_d 的每一维上建立一个基于 Delta 势阱模型的吸引势, 其势能函数为

$$V(Y) = -\gamma\delta(Y), \quad (17)$$

其中 $Y = x - P_d$, 表示个体所处位置 x 与吸引子的距离. 将其代入量子力学中 Schrodinger 方程, 可得个体每一维的波函数 $\psi(Y, t)$ 和概率密度函数 $Q(Y)$:

$$\begin{aligned} j\hbar \frac{\partial}{\partial t} \psi(Y, t) &= \left(-\frac{\hbar^2}{2m} \nabla^2 + V(Y) \right) \psi(Y, t), \quad (18) \\ Q(Y) &= |\psi(Y)|^2 = |\psi(x - p)|^2 \\ &= \frac{1}{L} e^{-2|x-p|/L}, \quad (19) \end{aligned}$$

其中 $L = \hbar^2/m\gamma$ 为 Delta 势阱特征长度, 它决定了粒子搜索范围. 在势场中细菌个体的运动位置服从上述概率密度函数, 取 $(0, 1)$ 内的随机数 u , 令 $u = e^{-2|x-p|/L}$, 采用蒙特卡洛进行随机模拟得到细菌个体位置更新方程如下:

$$x_{id} = P_d \pm \frac{L}{2} \ln(1/u), u \sim U(0, 1), \quad (20)$$

$$L = 2\delta \cdot |\text{mbest} - x_{id}(t)|, \quad (21)$$

其中参数 δ 为收缩扩张系数, 通常采用随着进化代数 t 从 δ_1 线性改变至 δ_2 的方式, 如下式:

$$\delta = \frac{(\delta_1 - \delta_2) \times (\text{MAXIER} - t)}{\text{MAXIER}} + \delta_2, \quad (22)$$

mbest 为种群最好位置向量的平均值, 如下式所示:

$$\begin{aligned} \text{mbest} &= \sum_{i=1}^M \frac{P_i}{M} \\ &= \left[\sum_{i=1}^M \frac{P_{i1}}{M}, \sum_{i=1}^M \frac{P_{i2}}{M}, \dots, \sum_{i=1}^M \frac{P_{iD}}{M} \right]^T, \quad (23) \end{aligned}$$

其中 MAXIER 为最大进化代数, M 为种群个体数. 结合 BFO 算法自身执行步骤, 并将上述量子空间下个体进化过程引入到其繁殖算子中, 同时针对细菌趋化步长一致的缺陷, 引入一种逐层缩进控制策略使得在保证算法收敛速度的同时保持种群多样性. 风电功率概率区间预测模型优化的具体步骤如下:

步骤 1 基础工作. 将训练数据集和测试数据集归一化到 $[-1, 1]$, 随机产生 ELM 模型的输入权值和偏置系数.

步骤 2 参数初始化. 包括细菌个体数 s , 迁移次数 N_{ed} , 繁殖次数 N_{re} , 趋化次数 N_c , 游动次数

N_s , 迁移概率 p_{ed} . 在解空间中随机生成 s 个独立的细菌个体向量 x_i .

步骤 3 构造基于 ELM 的区间预测模型, 并用细菌个体向量所对应的模型参数对样本进行区间预测, 根据 (8), (9), (14), (15) 式计算各粒子适应度值.

步骤 4 for $j = 1 : N_c$, 开始执行趋化操作循环. 针对趋化步长, 采用从初始搜索空间逐层缩进的策略, 对每个细菌个体 i 按如下步骤执行:

步骤 4.1 翻滚: 产生一个随机向量 $\Delta \in R^n$ 进行方向调整, 向量 Δ 的每一个元素为区间 $[-1, 1]$ 的随机数. 对个体变量 x_{id} 按下式更新细菌位置:

$$x_{id}(j+1, k, l) = x_{id}(j, k, l) + C(i, j)\varphi(i), \quad (24)$$

$$\varphi(i) = \frac{\Delta(i)}{\sqrt{\Delta^T(i)\Delta(i)}}, \quad (25)$$

$$C(i, 0) = x_max - x_min, \quad (26)$$

其中 $C(i, j)$ 表示个体向前游动的步长单位, $\varphi(i)$ 表示旋转后选择的随机前进方向.

步骤 4.2 游动: 评价 $x_i(j+1, k, l)$ 适应度, 若优于 $x_i(j, k, l)$, 则将 $x_i(j, k, l)$ 替换为 $x_i(j+1, k, l)$, 并按照此翻转方向进行游动直至适应度值不再改善或者达到最大游动次数.

步骤 4.3 $d = d + 1$, 若已达最大维数转步骤 4.4, 否则转步骤 4.1 继续对下一变量进行操作.

步骤 4.4 $j = j + 1$, 按下式逐层缩进策略改变细菌个体游动步长, 其中 A 为逐层缩进系数.

$$C(i, j+1) = A \cdot C(i, j). \quad (27)$$

步骤 5 for $k = 1 : N_{re}$, 开始执行基于量子行为的细菌繁殖操作. 首先更新当前群体的个体最好位置 p_{id} 和全局最优位置 p_g , 按 (23) 式计算种群的平均最好位置向量 $mbest$, 并按 (20), (21) 式更新群体位置.

步骤 6 for $l = 1 : N_{ed}$, 开始执行细菌迁徙. 将所有细菌按照能量进行排序, 对适应度较低的部分细菌 ($s \cdot P_{ed}$) 按照随机初始化的方法进行迁徙.

步骤 7 循环结束判断, 满足则输出最优权值变量, 并构建概率区间预测模型, 评估测试数据集的 PICP 和 PINAW 指标.

5 算例分析

为验证本文所述风电功率混沌时间序列概率区间预测模型的有效性, 以美国国家可再生能源实

验室中两个风电场在 2004 年实际采集到的风电功率时间序列进行测试. 取 1 月到 6 月的小时级风电功率数据作为训练数据, 取 7—9 月数据作为测试. 首先对数据进行归一化处理, 转化为 $[-1, 1]$ 之间, 建立基于 ELM 的简易预测模型以得到下一小时的风电功率概率区间.

5.1 量子细菌觅食参数优化性能对比分析

分别采用 QPSO, BFO 和 QBFO 算法对模型训练过程进行寻优. 基于文献 [2] 中对风电功率时间序列混沌特性描述, 借用混沌相空间理论确定风电功率时间序列的输入维数, 通过交叉校验确定 ELM 隐藏层节点数, 惩罚系数 σ_1 和 σ_2 取 10, 置信概率取 90%. 3 种算法的群体规模均为 100, QPSO 算法分别仿真计算 500 代, 算法其他参数设置如表 1 所示. 使用 Matlab 编写程序得到各算法训练过程中 PICP 和 PIC 值的变化曲线如图 2 所示.

从图 2 中可以看出: BFO 算法初期由于其出色的局部搜索能力能够较快速的达到一个较好的最优适应度值, 但由于后期种群多样性缺失使得算法过早陷入局部收敛, PIC 指标难以下降; QPSO 利用其量子概率模型使得种群能以一定概率出现在空间任意地方, 但由于其局部搜索能力较差, 后期全局最优解未能得到有效改善; QBFO 结合了两者的优点, 趋化算子中采用逐层递进搜索, 使得算法在初期能进行有效的局部搜索, 避免种群搜索的盲目性, 而量子空间下的细菌繁殖操作增强了种群多样性, 避免算法早熟收敛, 使得最终得到较理想的区间预测结果.

表 1 优化算法参数设置

参数	BFO					QPSO		QBFO
	P_{ed}	N_{ed}	N_{re}	N_c	N_s	δ_1	δ_2	A
值	0.25	2	10	25	5	1	0.5	0.6

表 2 3 种算法优化下的模型概率预测指标

仿真实例	BFO/%		QPSO/%		QBFO/%	
	PICP	PINAW	PICP	PINAW	PICP	PINAW
风电场 1	87.70	37.76	90.40	32.42	90.85	28.47
风电场 2	90.15	34.16	90.30	31.58	90.80	27.84

表 2 给出了 3 种优化算法寻优下的概率区间预测指标. 从中可以看出, 在保持 ELM 预测模型中随机初始化 w 和 b 不变时, 基于 BFO 得到的输出权值在测试数据集区间预测可靠性较低, 而基于

QPSO 和 QBFO 得到的 PIs 均能满足决策者需求. 针对 PINAW 指标, 基于 QBFO 算法的寻优结果较 QPSO 减少了 3.95%, 更加有利于决策者操作. 因

此, 基于上述实例分析可以看出, 采用 QBFO 对模型进行全局优化将更有助于提高模型训练精度, 改善输出的预测区间性能.

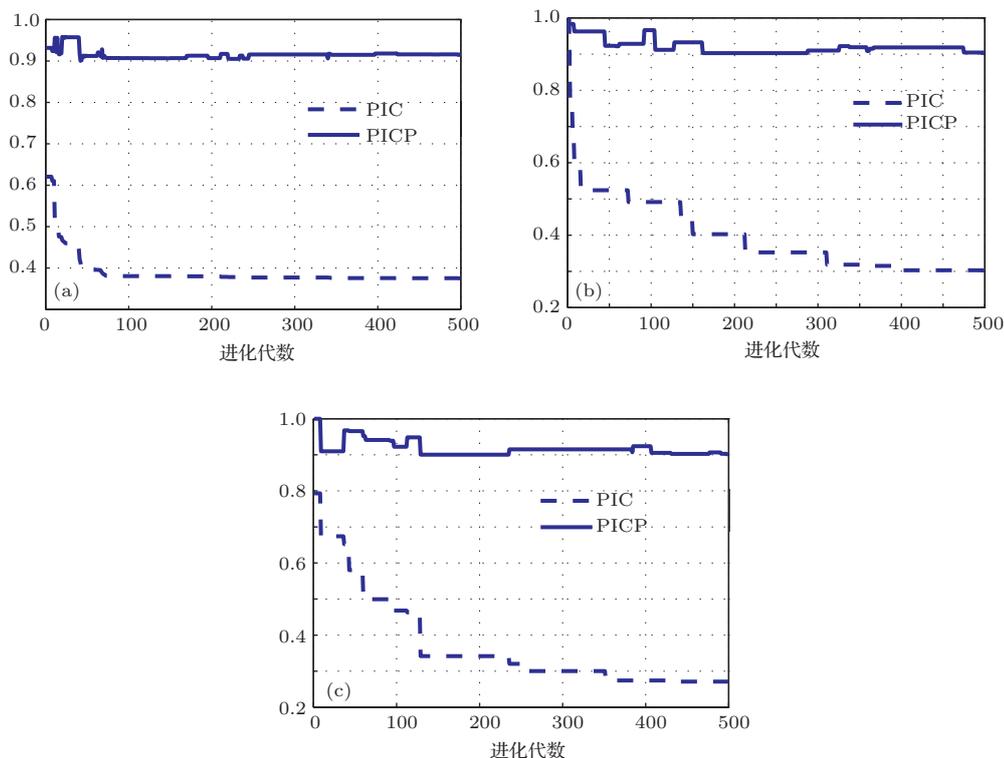


图2 3种算法寻优收敛曲线 (a) BFO算法收敛曲线; (b) QPSO算法收敛曲线; (c) QBFO算法收敛曲线

5.2 基于PIC准则的概率区间预测性能分析

基于上节对比分析, 采用 QBFO 算法对选取的两个风电场分别基于 CWC 和 PIC 准则进行参数寻优, 将优化得到的输出权值和随机产生的 w 和 b 应用于测试数据集, 计算两种情况下区间预测指标. 参照文献 [16, 20] 中关于 CWC 准则描述和取值, 惩罚系数 η 取 50. 表 2 给出了两个风电场在不同置信水平和不同优化准则下概率预测结果, 表中数据为 5 次计算结果的平均值. 从中可以看出, 对于两个风电场而言, 基于 PIC 准则得到的区间预测值均能满足决策者可靠性需求, 而基于 CWC 准则下的预测结果可靠性较低, 这主要是由于 CWC 准则中单纯依赖惩罚系数来突出可靠性约束易出现过训练情况, 导致模型的泛化能力下降. 对比分析 80% 置信水平下的 PINAW 数值可以看出, 基于 PIC 得到的预测区间相较 CWC 减少了 3.85% 和 3.44%. 因此, 采用 PIC 准则优化得到的预测区间相比已有的 CWC 具有更高的可靠性和更小的区间带宽, 对决

策者更具使用价值.

图 3 至图 6 给出了 PIC 优化准则下 2 个风电场在 90% 和 80% 置信概率下的区间预测结果, 为方便展示取 200 点数据. 从中可以看出, 本文所述的概率预测结果能较好的追踪风电功率混沌时间序列的变化, 预测区间能较好的包络风电功率实际值, 部分未被包络的点偏差也较小, 这符合 PIC 准则被提出的初衷. 另外, 随着置信概率越高, 区间预测范围相应变宽, 可为决策者提供选择依据.

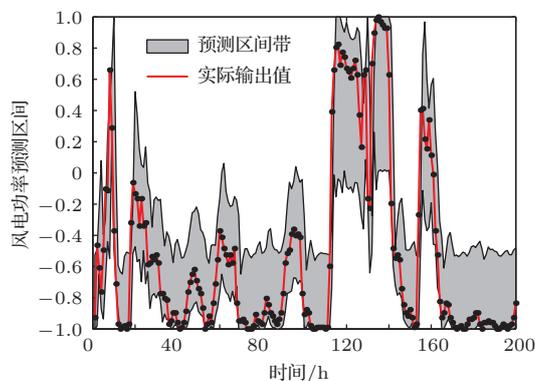


图3 (网刊彩色) 风电场 1 的 90% 预测区间仿真结果

表3 不同优化准则下风电功率概率预测结果

置信水平/%	仿真实例	PIC 准则		CWC 准则	
		PICP/%	PINAW/%	PICP/%	PINAW/%
90	风电场 1	90.15	30.14	87.97	33.23
	风电场 2	91.40	28.07	89.28	30.95
80	风电场 1	81.60	20.02	80.20	23.87
	风电场 2	83.10	18.21	82.70	21.65

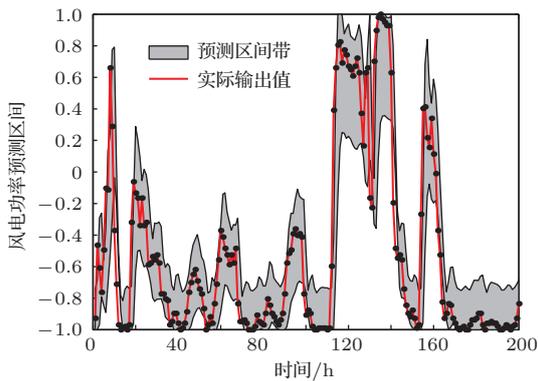


图4 (网刊彩色) 风电场 1 的 80% 预测区间仿真结果

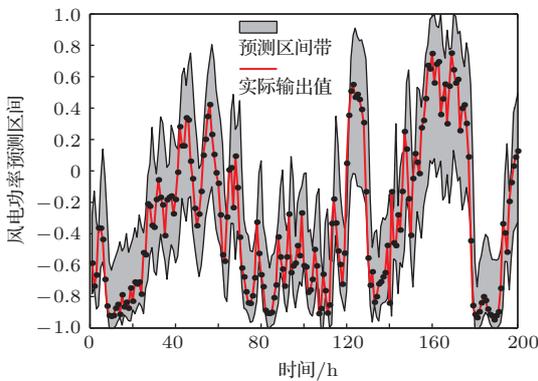


图5 (网刊彩色) 风电场 2 的 90% 预测区间仿真结果

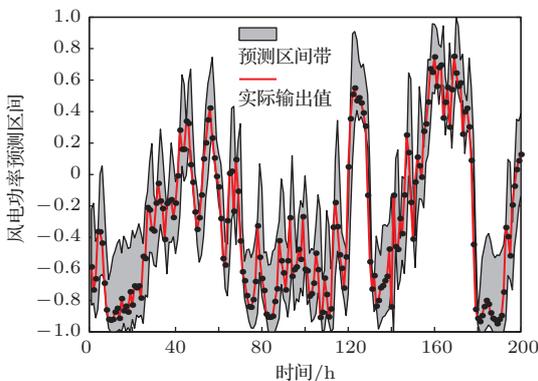


图6 (网刊彩色) 风电场 2 的 80% 预测区间仿真结果

6 结 论

概率区间预测不仅能描述未来风电功率可能波动范围,同时能有效评估预测区间的可靠性.针对目前风电功率概率区间预测中大都基于对点预测结果误差分布特性的研究,本文提出一种基于极限学习机的概率区间简易预测模型以直接输出一定置信概率下的风电功率上下限.相比传统的神经网络模型,ELM简化了模型训练过程中参数的选择,大大减少了模型的计算量.针对模型训练过程中预测区间优化准则问题,论文提出一种综合考虑数据集区间带偏差信息的目标函数,避免了传统CWC准则中因惩罚系数选择不当而导致的过训练和欠训练.基于量子细菌觅食优化算法的风电场实例仿真对比分析表明本文模型结构简单、计算速度快,新的优化准则较已有的CWC具有更好的PIs性能,为风电功率混沌时间序列概率区间预测提供了一种新的方法.

感谢 Kit Po Wong 教授对作者在西澳大利亚大学电气电子与计算机学院留学期间的指点,感谢香港理工大学电机工程系许昭教授及新加坡南洋理工大学电力及计算机工程学院权浩博士对本论文工作的讨论.

参考文献

- [1] Jung J, Broadwater R P 2014 *Renewable and Sustainable Energy Reviews* **31** 762
- [2] Zhang X Q, Liang J 2012 *Acta Phys. Sin.* **61** 190507 (in Chinese) [张学清, 梁军 2012 物理学报 **61** 190507]
- [3] Zhang Y 2013 *Chin. Phys. B* **22** 050502
- [4] Qu H, Ma W T, Zhao J H, Chen B D 2013 *Chin. Phys. Lett.* **30** 110505
- [5] Zhang X Q, Liang J 2013 *Acta Phys. Sin.* **62** 050505 (in Chinese) [张学清, 梁军 2013 物理学报 **62** 050505]

- [6] Liu D W, Guo J B, Huang Y H, Wang W S 2013 *Proceeding of the CSEE* **33** 9 (in Chinese) [刘德伟, 郭剑波, 黄越辉, 王伟胜 2013 中国电机工程学报 **33** 9]
- [7] Wu X S, Zhang B H, Yuan X M, Li G W, Luo G, Zhou Y 2013 *Proceeding of the CSEE* **33** 45 (in Chinese) [吴小珊, 张步涵, 袁小明, 李高望, 罗钢, 周杨 2013 中国电机工程学报 **33** 45]
- [8] Zhang Z S, Sun Y Z, Gao D W, Lin J, Cheng L 2013 *IEEE Trans. on Power Systems* **28** 3114
- [9] Jiang R W, Wang J H, Zhang M H, Guan Y P 2013 *IEEE Trans. on Power Systems* **28** 2271
- [10] Lange M 2005 *J. Sol. Energy Eng.* **127** 177
- [11] Zhou S L, Mao M Q, Shu J H 2011 *Proceeding of the CSEE* **31** 10 (in Chinese) [周松林, 茆美琴, 苏建徽 2011 中国电机工程学报 **31** 10]
- [12] Li Z, Han X S, Yang M, Zhong S M 2011 *Automation of Electric Power Systems* **35** 83 (in Chinese) [李智, 韩学山, 杨明, 钟世民 2011 电力系统自动化 **35** 83]
- [13] Sideratos G, Hatziaargyriou N D 2012 *IEEE Trans. Power Syst.* **27** 1788
- [14] Jeon J, Taylor J W 2012 *J. Amer. Statist. Assoc.* **107** 66
- [15] Bessa R J, Miranda V, Botterud A, Zhou Z, Wang J 2012 *Renew. Energy* **40** 29
- [16] Khosravi A, Nahavandi S, Creighton D, Atiya A 2011 *IEEE Trans. Neural Networks* **22** 337
- [17] Huang G B, Zhu Q Y, Siew C K 2006 *Neurocomputing* **70** 489
- [18] Wang X Y, Han M 2012 *Acta Phys. Sin.* **61** 080507 (in Chinese) [王新迎, 韩敏 2012 物理学报 **61** 080507]
- [19] Gao G Y, Jiang G P 2012 *Acta Phys. Sin.* **61** 040506 (in Chinese) [高光勇, 梁国平 2012 物理学报 **61** 040506]
- [20] Khosravi A, Nahavandi S 2013 *IEEE Trans. Sustainable Energy* **4** 849
- [21] Quan H, Srinivasan D, Khosravi A 2014 *IEEE Trans. Neural Netw. Learn. Syst.* **25** 303
- [22] Van den Bergh F, Engelbrecht A P 2002 *Proceedings of the IEEE International Conf on Systems, Man and Cybernetics*, October 6–9, 2002 p94
- [23] Sun J, Feng B, Xu W B 2004 *Proceedings of the IEEE Congress on Evolutionary Computation*, Dec. 1–3, 2004 p325
- [24] Passino K M 2002 *IEEE Control Systems Magazine* **22** 52
- [25] Shrestha D L, Solomatine D P 2006 *Neural Netw.* **19** 225
- [26] Fang W, Sun J, Xie Z P, Xu W B 2010 *Acta Phys. Sin.* **59** 3686 (in Chinese) [方伟, 孙俊, 谢振平, 须文波 2010 物理学报 **59** 3686]

A simple model for probabilistic interval forecasts of wind power chaotic time series*

Zhang Guo-Yong¹⁾²⁾ Wu Yong-Gang^{1)†} Zhang Yang²⁾ Dai Xian-Liang¹⁾

1) (College of Hydroelectricity and Digitalization Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

2) (School of Electrical, electronic and computer engineering, University of Western Australia, WA 6009, Australia)

(Received 3 January 2014; revised manuscript received 17 March 2014)

Abstract

Integration of wind power into grids requires accurate forecasting, however, traditional wind power point forecast errors are unavoidable and they cannot be eliminated due to the highly volatile and uncertain in the chaotic time series of wind power. Unlike point prediction, which conveys no information about the prediction accuracy, probabilistic interval forecasts can provide a range, within which the target will lie with a certain probability, for estimating the potential impacts and risks facing the system operation. Most existing prediction interval (PI) construction methods are often placed after a deterministic forecasting model with or without prior assumptions, this paper propose a novel lower-upper bound estimation approach using extreme learning machine to directly construct PIs for wind power series. Based on the analysis of the interval forecasting error information in training dataset, a new problem formulation is developed in this method to get better PIs. In addition, in order to obtain the global optimal solution of the above model, a quantum bacterial foraging optimization algorithm is proposed by introducing the theory of quantum mechanics into bacteria foraging behavior. The testing results from two real wind farms with different confidence probability and optimization criterion demonstrate the excellent quality of PIs in terms of both reliability and sharpness, which provide a support for the steady operation of power system with wind power integration.

Keywords: chaotic time series, probabilistic interval forecasts, extreme learning machine, quantum bacterial foraging optimization

PACS: 88.50.-k, 03.65.-w

DOI: [10.7498/aps.63.138801](https://doi.org/10.7498/aps.63.138801)

* Project supported by the National Natural Science Foundation of China (Grant No. 51379081), and the Natural Science Foundation of Hubei Province, China (Grant Nos. 2011CDA032).

† Corresponding author. E-mail: ygangwu@163.com