

一种量子磷虾群融合算法及其应用

冯增喜^{1,2}, 赵锦彤¹, 李诗妍¹, 杨亚龙^{2*}, 陈海越¹, 张聪¹

(1. 西安建筑科技大学 建筑设备科学与工程学院, 陕西 西安 710055;

2. 安徽建筑大学 智能建筑与建筑节能安徽省重点实验室, 安徽 合肥 230022)

摘要: 针对磷虾群算法和量子进化算法的缺陷, 提出了一种量子磷虾群融合算法(*quantum krill herd fusion algorithm, QKH*)。该算法通过采用双链实数编码量子磷虾位置, 加快收敛速度, 避免量子观测的随机性和复杂性; 通过利用动态调整的量子磷虾群旋转门更新磷虾位置, 提升收敛精度, 提高量子旋转相位的确定效率; 通过改进的量子全干扰交叉策略, 避免算法陷入局部最优, 提升优化效率。通过经典测试函数验证了所提算法的优势。建立了 QKH-BPNN 空调负荷预测模型, 仿真结果表明: 该模型具有更好的准确性和稳定性。

关键词: 量子磷虾群融合算法; 双链实数编码; 量子磷虾群旋转相位; 改进的量子全干扰交叉; QKH-BPNN 预测

中图分类号: TP183

文献标志码: A

文章编号: 1004-731X(2022)10-2142-10

DOI: 10.16182/j.issn1004731x.joss.21-0534

A Quantum Krill Herd Fusion Algorithm and Its Application

Feng Zengxi^{1,2}, Zhao Jintong¹, Li Shiyan¹, Yang Yalong^{2*}, Chen Haiyue¹, Zhang Cong¹

(1. School of Building Services Science and Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China;

2. Anhui Key Laboratory of Intelligent Building and Building Energy Conservation, Anhui Jianzhu University, Hefei 230022, China)

Abstract: Aiming at the defects of krill herd algorithm and quantum evolutionary algorithm, a *quantum krill herd fusion algorithm (QKH)* is proposed. The algorithm uses double-chain real numbers to encode the krill position, which can speed up the convergence speed, and avoids the randomness and complexity of quantum observations. The dynamically adjusted quantum krill herd rotation phase update strategy improves the convergence accuracy, and the efficiency of determining the quantum rotation phase. The introduction of an improved quantum full interference crossover strategy can prevent the fusion algorithm from falling into a local optimum, and can improve the optimization efficiency. The advantages of the quantum krill herd fusion optimization algorithm are verified by the classic test functions. A QKH-BPNN prediction model is established for air conditioning load forecasting, and the results show that the model has better accuracy and higher stability.

Keywords: quantum krill herd fusion algorithm; double-chain real numbers encoding; quantum krill herd rotation phase; improved quantum full interference crossover; QKH-BPNN prediction

引言

磷虾群算法 (krill herd algorithm, KH)^[1] 是

Gandomi 和 Alavi 基于南极磷虾群生存环境和生活规律而提出的一种群智能优化算法。由于其编程

收稿日期: 2021-06-08 修回日期: 2021-09-11

基金项目: 国家重点研发计划(2017YFC0704104-03); 陕西省科技厅专项(2017JM6106); 安徽建筑大学智能建筑与建筑节能安徽省重点实验室 2018 年度开放课题(IBES2018KF08)

第一作者: 冯增喜(1979-), 男, 博士, 副教授, 研究方向为建筑节能、智能建筑、智慧城市。E-mail: fengzengxi2000@163.com

通讯作者: 杨亚龙(1980-), 男, 博士, 教授, 研究方向为建筑物联网、建筑节能技术、智慧城市。E-mail: yalong_yang2020@163.com

简单、易于实现, 已被应用于电力系统、神经网络训练、优化调度和聚类分析等领域^[2-6]。然而, 磷虾群算法在应用中也存在诸如收敛速度慢、精度低、易陷入局部最优等问题, 这在一定程度上限制其更广泛的应用^[7]。

量子进化算法(quantum evolutionary algorithm, QEA)^[8]是 Han 等基于量子计算提出的一种概率进化算法, 该算法具有种群多样性好、收敛速度快等优点。基于此, 文献[9]提出了一种量子衍生蜂群算法(quantum-inspired bee algorithm, QIBC), 利用量子比特在 Bloch 球面上的绕转旋转实现人工蜂群的进化搜索, 提高了人工蜂群算法的优化能力; 文献[10]提出了求解连续空间优化问题的量子蚁群算法(continuous quantum ant colony algorithm, CQACA), 利用量子旋转门实现了携带一组量子比特的蚂蚁移动, 加倍了搜索空间, 并通过量子非门进行蚂蚁的变异操作, 增加了蚂蚁位置的多样性; 文献[11]提出了一种混合量子行为的麻雀优化算法(quantum sparrow search algorithm, QSSA), 利用量子策略对基本麻雀搜索算法迭代后的劣势群体进行变异, 加强了算法的空间搜索能力, 并对优势群体引入莱维随机游走策略, 增加了种群多样性。虽然量子进化算法与这些群智能算法的融合都取得了较好的效果, 但这些融合算法大多是利用量子进化算法的优点来改善目标算法的不足, 而对于目标算法的优点能否改善量子进化算法中存在的诸如量子观测的随机性、解码编码的复杂性, 以及量子旋转相位的大小和方向难以确定的问题, 并没有进行深入的研究。

为改善 QEA 和 KH 2 种算法的不足, 实现优势互补, 本文提出了一种量子磷虾群融合算法(quantum krill herd fusion algorithm, QKH)。QKH 采用双链实数编码量子磷虾的位置, 利用磷虾的运动分量和比例收缩因子 k 动态调整了量子磷虾群旋转相位, 并利用调整的旋转相位构建了量子旋转门, 实现了量子磷虾的位置更新, 还通过改

进的量子全干扰交叉策略, 提高了全局开发和局部探索的优化能力。通过经典测试函数验证了 QKH 在收敛速度、精度及稳定性方面的优势, 并将其应用于后向传播神经网络(back propagation neural network, BPNN)预测, 建立了 QKH-BPNN 空调负荷预测模型, 该模型提高了预测的精度和稳定性。

1 磷虾群算法和量子进化算法

1.1 磷虾群算法

在磷虾群算法中, 如果设在 D 维解空间中, 有 N 只磷虾, 那么可初始化磷虾位置为: $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{iD})$, $i = 1, 2, \dots, N$ 。磷虾 i 的位置变化速率用拉格朗日模型更新为

$$\frac{d\mathbf{X}_i}{dt} = N_i + F_i + D_i \quad (1)$$

$$\begin{cases} N_i = N^{\max} (\alpha_i^{\text{local}} + \alpha_i^{\text{target}}) + \omega_n N_i^{\text{old}} \\ F_i = v_f (\beta_i^{\text{food}} + \beta_i^{\text{best}}) + \omega_f F_i^{\text{old}} \\ D_i = D^{\max} (1 - t/t_{\max}) \delta \end{cases} \quad (2)$$

式中: $\frac{d\mathbf{X}_i}{dt}$ 为磷虾 i 的位置变化速率; N_i 、 F_i 、 D_i 分别为磷虾诱导运动、觅食过程和随机移动的 3 个运动分量; N^{\max} 、 v_f 、 D^{\max} 分别为最大诱导速度、最大觅食速度和最大扩散速度; N^{old} 、 F^{old} 分别为先前诱导运动和先前觅食运动; ω_n 、 ω_f 分别为诱导惯性权重和觅食惯性权重, 取值范围都为 $[0, 1]$; α_i^{local} 、 α_i^{target} 分别为磷虾 i 受“邻居”和全局最优个体的诱导方向; β_i^{food} 、 β_i^{best} 分别为磷虾 i 受“食物”和个体历史最优的诱导方向; δ 为随即扩散方向; t 、 t_{\max} 分别为当前迭代次数和最大迭代次数。

磷虾的位置更新为

$$\begin{cases} \mathbf{X}_i(t + \Delta t) = \mathbf{X}_i(t) + \Delta t \frac{d\mathbf{X}_i}{dt} \\ \Delta t = Ct \sum_{j=1}^D (UB_j - LB_j) \end{cases} \quad (3)$$

式中: $\mathbf{X}_i(t)$ 、 $\mathbf{X}_i(t + \Delta t)$ 分别为磷虾 i 更新前后的位置; Δt 为时间变化步长; $Ct \in [0, 2]$ 为步长缩放因

子; D 为决策变量的数量; UB_j 、 LB_j 分别为变量 j 的上界和下界。

为增大种群多样性, KH 算法的原作者在算法后还加入了遗传的交叉和变异操作, 并对加入的不同遗传操作的效果进行了对比, 文献[1]已证明了仅执行交叉操作对算法更有效, 因此本文将该方法作为标准磷虾群, 磷虾 i 的变量 j 的交叉方式为

$$x_{ij} = \begin{cases} x_{ij}, & a_{ir} < C_r \\ x_{ij}, & \text{else} \end{cases} \quad (4)$$

式中: C_r 为交叉算子; a_{ir} 为 $[0, 1]$ 上均匀分布的随机数。

1.2 量子进化算法

在 QEA 中, 一个量子比特的状态可以表示为 $|\varphi\rangle = \alpha|0\rangle + \beta|1\rangle$, α 、 β 是量子比特概率幅, 满足归一化条件 $|\alpha|^2 + |\beta|^2 = 1$ 。所以量子比特也可以表示为 $[\cos \theta \ \sin \theta]^T$, 其中 θ 为量子比特的相位。

QEA 中的量子观测和量子门是其较为重要的 2 部分内容。量子观测是求解代表优化问题适应度的二进制解的方法, 观测方式可参考文献[12]; 量子门是一个幺正矩阵, 量子比特的更新通过该幺正矩阵实现, 其中常用的量子门有量子旋转门和量子非门。

量子比特的进化是通过量子旋转门实现, 其表示方式为

$$\begin{bmatrix} \cos \Delta\theta & -\sin \Delta\theta \\ \sin \Delta\theta & \cos \Delta\theta \end{bmatrix} \quad (5)$$

式中: $\Delta\theta$ 是量子旋转门相位, 它是一个矢量, 是决定量子进化算法性能的核心参数, 范围大小一般在 $[0.005\pi, 0.01\pi]$, 具体方向和大小根据文献[12]的查表法所得。

其变异操作通过量子非门实现, 它表示交换一组量子比特概率幅, 实现如式(6)所示:

$$\begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} \alpha \\ \beta \end{bmatrix} = \begin{bmatrix} \beta \\ \alpha \end{bmatrix} \quad (6)$$

2 量子磷虾群融合算法

2.1 QKH 的初始化

针对 KH 的收敛速度慢和 QEA 中量子观测的随机性和解码编码的复杂性的问题。QKH 的初始化采用双链实数编码量子磷虾的位置。该初始化方式同时保留了 KH 的实数编码和 QEA 双链编码的优点。通过将量子态的概率幅直接映射为十进制解, 从而避免了量子染色体观测为二进制解时的随机性和二进制与十进制之间频繁编码解码的复杂性; 此外, 将映射态的 2 个十进制解都作为可能解, 并选择较优解作为优化问题最终解, 使磷虾数在相同的情况下, 磷虾的搜索空间扩展为原来的 2 倍, 从而加快搜索进程。

融合算法的初始化编码方案以及量子态到映射态的演化关系为

$$\begin{cases} \begin{bmatrix} \cos \theta_{i1} & \cos \theta_{i2} & \cdots & \cos \theta_{iD} \\ \sin \theta_{i1} & \sin \theta_{i2} & \cdots & \sin \theta_{iD} \end{bmatrix} \\ x_{ij}^1 = \frac{1}{2} (UB_j(1 + \cos \theta_{ij}) + LB_j(1 - \cos \theta_{ij})) \\ x_{ij}^2 = \frac{1}{2} (UB_j(1 + \sin \theta_{ij}) + LB_j(1 - \sin \theta_{ij})) \end{cases} \quad (7)$$

式中: $\theta_{ij} = 2\pi \times rand$, $i = 1, 2, \dots, N$, $j = 1, 2, \dots, D$; N 为磷虾数; D 为解空间的维度; $\cos \theta_{ij}$ 、 $\sin \theta_{ij}$ 为量子磷虾 i 的决策变量 j 的量子比特概率幅; x_{ij}^1 、 x_{ij}^2 为量子磷虾 i 的决策变量 j 所对应优化问题的 2 个可能解。

2.2 QKH 的更新策略

为提升 KH 的收敛精度, 并提高 QEA 中量子旋转门相位的确定效率。QKH 的更新策略是利用磷虾的 3 个运动分量和比例收缩因子 k 动态调整量子磷虾群的旋转相位, 其中 3 个运动分量计算量子旋转相位的大小和方向, 提高了 QEA 中确定量子旋转相位的效率; 随迭代次数线性递减的比例收缩因子 k 调整量子旋转相位, 提高了算法的收敛精度; 最后利用调整后的旋转相位构建量子旋转门更新磷虾的量子态, 从而实现每组量子磷虾

位置的同时移动。

对于 QKH 中的量子磷虾 i , 其位置变化速率的拉格朗日模型和 3 个量子比特相位表示的运动分量可重新表示为式(8)~(9), 其中量子磷虾群 3 个运动分量构成的位置变化速率的拉格朗日模型用量子比特概率幅表示的, 它被用来确定量子磷虾的旋转门相位的转角变化速率的依据。

$$\frac{d\theta_i}{dt} = N_{i,\theta} + F_{i,\theta} + D_{i,\theta} \quad (8)$$

$$\begin{cases} N_{i,\theta} = N^{\max} (\alpha_{i,\theta}^{\text{local}} + \alpha_{i,\theta}^{\text{target}}) + \omega_n N_{i,\theta}^{\text{old}} \\ F_{i,\theta} = v_f (\beta_{i,\theta}^{\text{food}} + \beta_{i,\theta}^{\text{best}}) + \omega_f F_{i,\theta}^{\text{old}} \\ D_{i,\theta} = D^{\max} (1 - \frac{t}{t_{\max}}) \delta \end{cases} \quad (9)$$

式中: $\theta_i = (\theta_{i1}, \theta_{i2}, \dots, \theta_{iD})$ 为磷虾 i 的量子比特相位; $\frac{d\theta_i}{dt}$ 为量子磷虾 i 的转角变化速率; $N_{i,\theta}$ 、 $F_{i,\theta}$ 、 $D_{i,\theta}$ 分别为磷虾诱导运动、觅食过程和随机移动的 3 个量子比特相位运动分量; $\alpha_{i,\theta}^{\text{local}}$ 、 $\alpha_{i,\theta}^{\text{target}}$ 分别为量子磷虾 i 受“邻居”和全局最优个体的诱导方向; $\beta_{i,\theta}^{\text{food}}$ 、 $\beta_{i,\theta}^{\text{best}}$ 分别为量子磷虾 i 受“食物”和个体历史最优的诱导方向。其余参数与磷虾群参数含义相同。

在计算 $\alpha_{i,\theta}^{\text{local}}$ 、 $\alpha_{i,\theta}^{\text{target}}$ 、 $\beta_{i,\theta}^{\text{food}}$ 和 $\beta_{i,\theta}^{\text{best}}$ 时, 要将当前量子磷虾位置到自身历史最优位置、邻居磷虾位置、当前食物位置以及全局最优位置的距离限制在 $[-\pi, \pi]$ 之间, 若该距离为 s , 则 s 的限幅操作为

$$s = \begin{cases} s - 2\pi, & s > \pi \\ s + 2\pi, & s < -\pi \end{cases} \quad (10)$$

量子磷虾 i 通过量子旋转门实现量子磷虾位置移动, 可根据式(11)~(12)更新, 利用式(11)中的时间变化步长、比例收缩因子和式(8)的量子磷虾的转角变化速率计算并调整量子磷虾的量子旋转门相位, 进而利用式(12)实现量子磷虾的位置更新。

$$\begin{cases} \Delta t_{ij} = Ct \sum_{j=1}^D (ub_j - lb_j) \\ k = k_{\min} + k_{\max} \cdot (1 - t/t_{\max}) \\ \Delta \theta_{ij} = k \cdot \frac{d\theta_{ij}}{dt} \cdot \Delta t_{ij} \end{cases} \quad (11)$$

$$\begin{bmatrix} \cos \theta_{ij}(t+1) \\ \sin \theta_{ij}(t+1) \end{bmatrix} = \begin{bmatrix} \cos \Delta \theta_{ij} & -\sin \Delta \theta_{ij} \\ \sin \Delta \theta_{ij} & \cos \Delta \theta_{ij} \end{bmatrix} \begin{bmatrix} \cos \theta_{ij}(t) \\ \sin \theta_{ij}(t) \end{bmatrix} \quad (12)$$

式中: $\cos \theta_{ij}(t)$ 、 $\sin \theta_{ij}(t)$ 、 $\cos(\theta_{ij}(t+1))$ 和 $\sin(\theta_{ij}(t+1))$ 分别为量子磷虾 i 的 j 变量在第 t 代和第 $t+1$ 代的一组量子比特位置; Δt_{ij} 为量子磷虾的时间变化步长; ub_j 、 lb_j 为量子比特相位的上界和下界, 分别等于 2π 和 0; k 为线性调整量子旋转相位比例收缩因子, k_{\max} 、 k_{\min} 分别为比例收缩因子的最大值和最小值; $\Delta \theta_{ij}$ 为量子磷虾的转角步长。

2.3 改进的量子全干扰交叉策略

交叉操作是进化策略中为增强种群多样性, 跳出局部最优的手段之一, 标准磷虾群中的交叉方式是单点交叉, 这种两个个体之间交叉对种群多样性的提升效果不佳。而在 QEA 中, 文献[13]利用量子的相干特性构造了一种量子全干扰交叉, 这种交叉使得所有染色体均参与交叉, 将种群按对角线重新排列组合, 能够很好地保证种群的多样性, 能解决 KH 中单点交叉方式的不足。但量子全干扰交叉又具有较大的随机性和盲目性, 可能使新解退化, 丢失适应度较好的解。

基于以上不足, 本文在量子全干扰交叉的基础上进行改进, 加入了精英保留策略和随迭代次数变化的交叉概率。精英保留策略是将每代种群中适应度最优的个体保存为精英个体, 不对其进行交叉操作, 而是直接作为下一次迭代中的种群个体之一, 以避免新解退化。随迭代次数变化的交叉概率是让 QKH 算法中每代种群按照式(13)计算的概率进行量子全干扰交叉, 使 QKH 算法前期以较大概率交叉, 产生较多的新解, 加快收敛速度; 后期以较小概率交叉, 避免产生无竞争性的解。因此, 改进的量子全干扰交叉策略既能避免 QKH 算法陷入局部最优, 又能提升优化效率。

$$C_t = C_{\min} + C_{\max} (1 - t/t_{\max}) \quad (13)$$

式中: C_t 为第 t 代交叉概率; C_{\max} 、 C_{\min} 分别为最

大交叉概率和最小交叉概率； t 和 t_{\max} 分别为当前迭代次数和最大迭代次数。

2.4 QKH 算法步骤及流程图

QKH 算法流程图如图 1 所示。

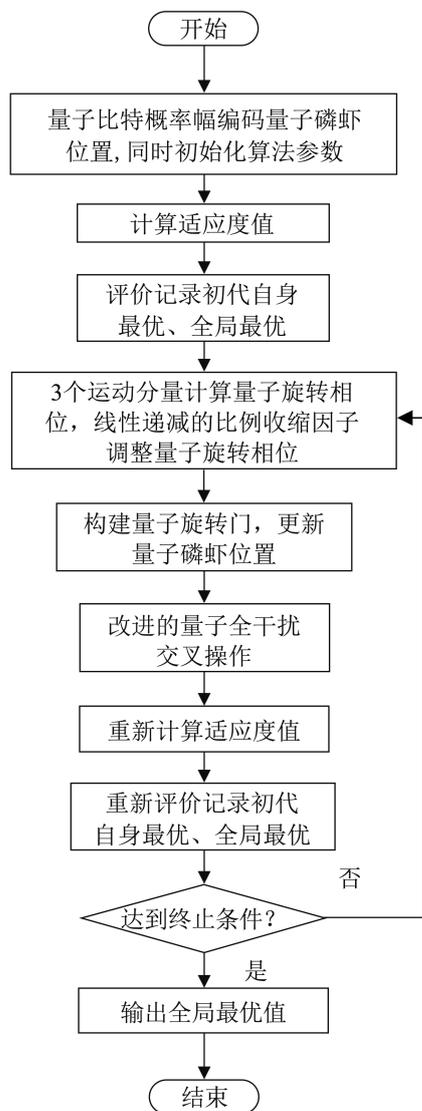


图 1 QKH 算法流程图

Fig. 1 Flow chart of QKH algorithm

其具体的计算步骤如下：

step 1: 设置算法参数，利用式(7)初始化量子磷虾群；

step 2: 计算适应度值，评价每个量子磷虾的适应度，记录全局最优量子磷虾位置和自身历史最优位置；

step 3: 利用式(8)~(11)计算量子旋转相位的大小和方向，同时用线性递减的比例收缩因子调整量子旋转相位；

step 4: 通过式(12)构建量子旋转门，实现量子磷虾的位置移动；

step 5: 利用改进的量子全干扰交叉策略对量子磷虾执行交叉操作；

step 6: 重新计算量子磷虾的适应度，更新并记录全局最优量子磷虾位置和自身历史最优位置；

step 7: 判断算法是否满足终止条件，如果满足，输出全局最优解，否则，返回 step 3 继续迭代搜索。

3 实验与结果分析

为验证 QKH 算法的优越性，本文采取了 2 部分实验：①利用 4 个基准测试函数验证 QKH 相比于 QEA、PSO 和 KH 的有效性；②建立 QKH-BPNN 神经网络来预测空调负荷，并与 BPNN、QEA-BPNN (quantum evolutionary algorithm-BPNN)、PSO-BPNN (particle swarm optimization-BPNN) 和 KH-BPNN (krill herd algorithm-BPNN) 预测结果进行对比，证明了 QKH-BPNN 进行空调负荷预测的优势。为保证对比的公平性，本文实验中所有代码均采用 Matlab R2014a 软件编写，都在统一 PC 机上运行。PC 机参数如下：Inter Code i7-8750H 处理器、GTX1050Ti 独立显卡、8 GB 内存和 64 位 Windows 10 操作系统。

3.1 测试函数验证实验

为验证 QKH 针对不同对象的优化性能，本文选取了 $f_1 \sim f_4$ 的 4 个多变量测试函数进行测试，如表 1 所示。其中 f_1 和 f_2 是单峰值， f_3 和 f_4 是多峰值，维度都取 30 维，全局最小值都为 0，分别采用 QEA、PSO、KH、QKH 进行实验并对比优化结果。QEA、PSO、KH、QKH 4 种算法的种群规模均设定为 50，最大迭代次数设定为 500。QEA 的量子旋转门策略采用文献[12]的策略，每个变量的二

进制位长度为 20, 变异概率为 0.1; PSO 的惯性权重为 0.75, 学习因子都为 2; KH 的 N^{\max} , v_f , D^{\max} 分别取值为 0.01、0.02、0.005, 步长缩放因子 Ct 取 0.5; QKH 中 k_{\max} 、 k_{\min} 分别取 0.8 和 0.1, 交叉概率最大值和最小值分别取 0.9 和 0.4, 其余参数与 KH 算法相同。

测试时, 利用 4 种算法对 4 个测试函数进行寻优实验, 分别独立运行 30 次。4 个测试函数的平均适应度迭代曲线如图 2 所示; 算法优化测试函数的最小值反映算法的最大收敛能力, 平均值反映算法的收敛精度, 标准差反映算法的稳定性, 记录 30 次测试函数实验结果如表 2 所示。

表 1 测试函数
Table 1 Test functions

函数	函数表达式	解空间范围
Sphere	$f_1(x) = \sum_{i=1}^D x_i^2$	$ x_i \leq 100$
Step	$f_2(x) = \sum_{i=1}^D (x_i + 0.5)^2$	$ x_i \leq 100$
Ackley	$f_3(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{D} \sum_{i=1}^D x_i^2}\right) - \exp\left[\frac{1}{D} \sqrt{\sum_{i=1}^D \cos(2\pi x_i)}\right] + 20 + e$	$ x_i \leq 32$
Griewank	$f_4(x) = \sum_{i=1}^D \frac{x_i^2}{4000} - \prod_{i=1}^D \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	$ x_i \leq 600$

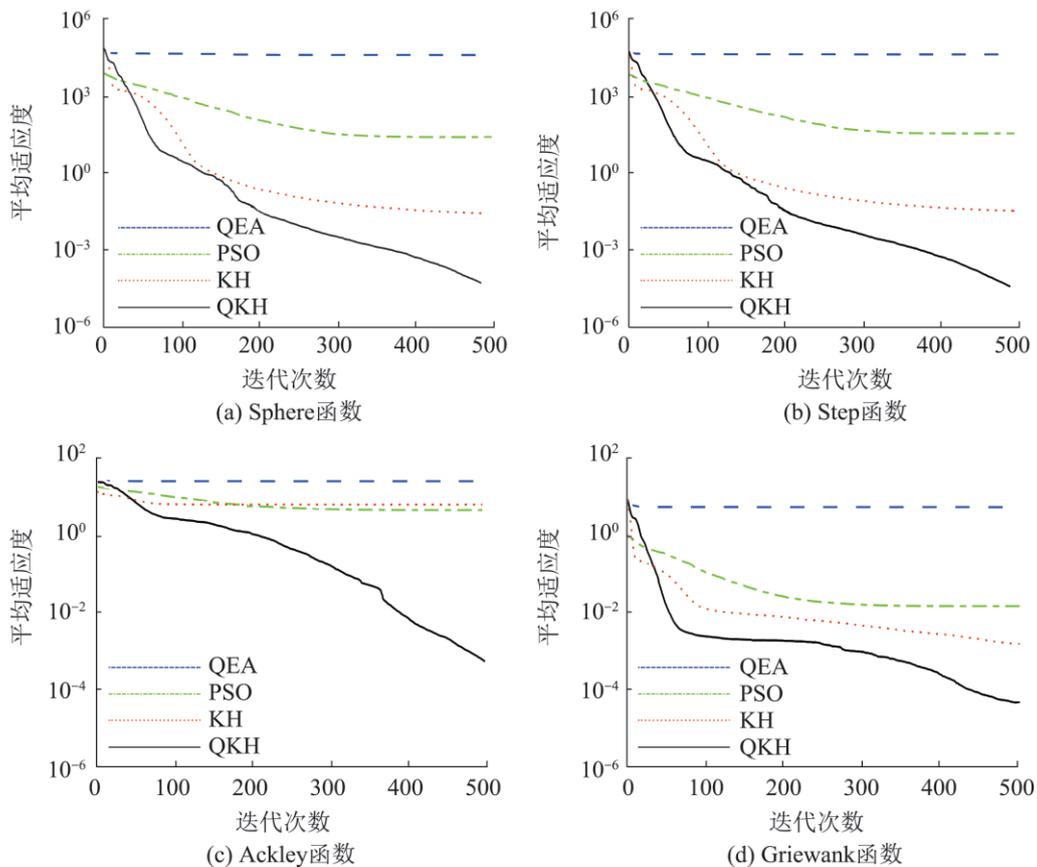


图 2 测试函数平均适应度迭代曲线
Fig. 2 Average fitness iterative curve of test functions

表 2 测试函数实验结果
Table 2 Result of test functions experiment

函数	算法	最小值	平均值	标准差
Sphere	QEA	3.76×10^4	4.34×10^4	3.43×10^3
	PSO	4.32×10^0	2.63×10^1	1.63×10^1
	KH	3.28×10^{-3}	2.66×10^{-2}	1.24×10^{-2}
	QKH	1.74×10^{-5}	3.52×10^{-5}	1.47×10^{-5}
Step	QEA	4.06×10^4	4.59×10^4	3.93×10^3
	PSO	6.09×10^0	3.66×10^1	2.96×10^1
	KH	1.45×10^{-2}	3.38×10^{-2}	1.65×10^{-2}
	QKH	1.29×10^{-5}	3.37×10^{-5}	2.06×10^{-5}
Ackley	QEA	1.93×10^1	1.99×10^1	2.94×10^{-1}
	PSO	1.01×10^0	3.68×10^0	8.09×10^{-1}
	KH	2.82×10^0	5.08×10^0	1.19×10^0
	QKH	1.43×10^{-4}	4.59×10^{-4}	2.70×10^{-4}
Griewank	QEA	3.75×10^2	4.36×10^2	2.95×10^1
	PSO	1.03×10^0	1.30×10^0	2.19×10^{-1}
	KH	5.57×10^{-2}	1.39×10^{-1}	3.52×10^{-2}
	QKH	1.31×10^{-3}	4.52×10^{-3}	2.06×10^{-3}

在独立运行的 30 次实验中，不论是单峰值还是多峰值的多变量测试函数，图 2 中 4 个测试函数的平均适应度迭代曲线和表 2 中 4 种算法的最小值、平均值和标准差结果均表明，QKH 对 4 个测试函数的寻优效果是最佳的，证明了 QKH 对于多变量全局优化这一类问题的适用性，其次 KH 的效果比 PSO 略好，QEA 的寻优效果最差。

在收敛速度方面，从图 2 可以得出，QEA 速度虽快，但收敛精度极差，原因是 QEA 二进制编码方案对求解高维度优化问题的不适用性，这一点与文献[14]得到同样的结论。QKH 算法前 50 代左右收敛速度略慢于 PSO 和 KH 算法，则是因为 QKH 前期较大的步长以更快寻找全局最优解为主要目标而导致的结果，但在此之后 QKH 的收敛速度是远快于 PSO 和 KH 算法的。所以 QKH 同时保留了 QEA 的收敛速度和 KH 的收敛精度方面的优点。

在收敛精度方面，QEA 受量子观测的随机性和解码编码的复杂性影响使收敛精度很差，PSO 和 KH 因为本身存在的易陷入局部最优的缺陷而导致收敛精度也不高。从表 2 的平均值指标可以

得出，QKH 收敛精度远远高于 QEA、PSO 和 KH，这是因为 QKH 动态调整了量子旋转相位和并引入了改进的量子全干扰交叉策略，同时解决了 QEA 和 KH 各自缺点造成收敛精度低的缺点。

在稳定性方面，QKH 利用 3 个运动分量与比例收缩因子确定量子旋转相位大小和方向、以及改进量子全干扰交叉策略的效果可通过 QKH 对测试函数优化的稳定性反映。表 2 中的标准差指标可以得出，QKH 的标准差远小于 QEA、PSO 和 KH 的标准差，说明 QKH 的稳定性最好，所以 QKH 在解决 KH 易陷入局部最优和 QEA 量子旋转相位难以确定的问题时效果良好。

3.2 基于 QKH-BP 神经网络的空调负荷预测实验

为证明 QKH 方法的有效性，针对 BPNN 预测中多个权值和阈值的优化问题，利用 QKH 对其优化，以改善预测效果。基于西安建筑科技大学变风量中央空调系统实验平台建立了 5 种空调负荷预测模型：传统 BP 神经网络空调负荷预测模型和通过 QEA、PSO、KH 和 QKH 分别优化 BPNN 初始权值和阈值建立的 QEA-BPNN、KH-BPNN 和 QKH-BPNN 空调负荷预测模型。

在 5 种 BPNN 模型中，网络的输入层节点为 t 时刻的室外空气温度、室外空气湿度、太阳辐射和 $t-1$ 时刻的室外空气温度、太阳辐射及空调负荷；输出层节点为预测空调负荷^[15-16]；隐含层节点数根据经验公式 $m=2n+1$ ，式中 $n=6$ 为网络输入节点数， m 为隐含层节点数。设定神经网络最大训练步数为 100，学习率为 0.01，目标误差为 0.000 01，网络基本结构如图 3 所示。

通过实验平台得到 55 天数据，其中前 50 天的 400 组数据被用于训练负荷预测模型，后 5 天的 40 组数据被用来验证预测效果。采用参考文献[17]中预测的评价指标，对夏季中连续 5 日的每天 8 个小时的空调负荷进行预测，得到空调负荷预测值、绝对误差和相对误差，分别如图 4~6 所示。利用

5 种预测模型预测最终所得平均绝对误差、平均相对误差和均方根误差如表 3 所示。

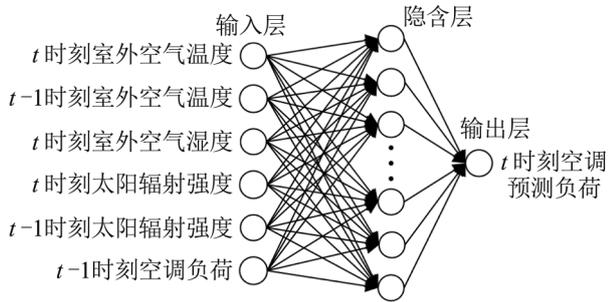


图 3 BPNN 空调负荷预测模型结构图

Fig. 3 BP neural network air conditioning load forecasting model structure diagram

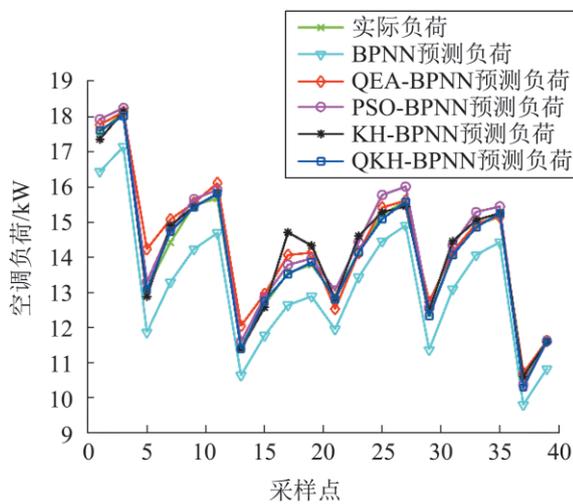


图 4 空调负荷预测值

Fig. 4 Air conditioning load forecast value

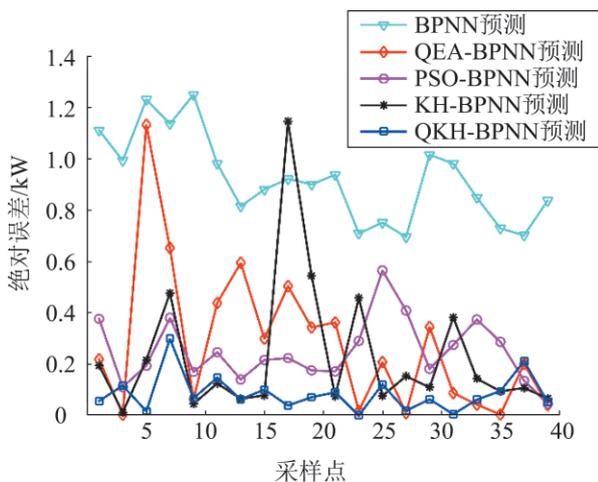


图 5 空调负荷预测的绝对误差

Fig. 5 Absolute error of air conditioning load forecast

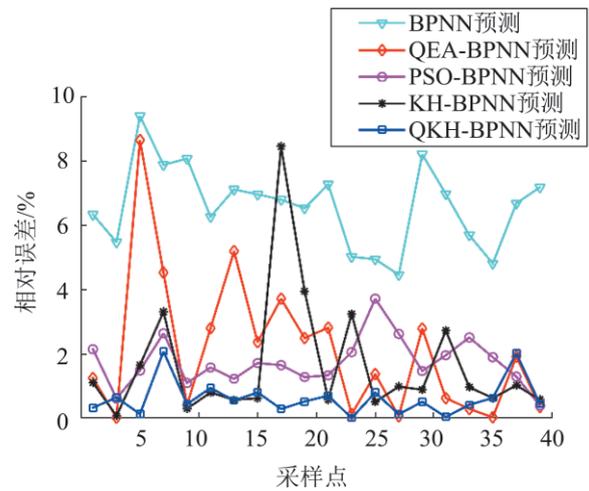


图 6 空调负荷预测的相对误差

Fig. 6 Relative error of air conditioning load forecast

表 3 不同方法的空调负荷预测结果

Table 3 Air conditioning load forecast results of different methods

参数	BPNN	QEA-BPNN	PSO-BPNN	KH-BPNN	QKH-BPNN
平均绝对误差/kW	0.89	0.28	0.26	0.22	0.09
平均相对误差/%	6.28	2.03	1.76	1.56	0.63
均方根误差	0.91	0.37	0.28	0.32	0.11

图 4~6 表明 4 种算法优化后的 BPNN 预测模型的精度较传统 BPNN 明显大幅提高, 其中 QKH-BPNN 进行空调负荷预测的精度最高。此外, 传统 BPNN 预测的绝对误差和相对误差的最大值分别为 1.25 kW 和 9.40%。而另外 4 种算法优化的 BPNN 预测的绝对误差和相对误差的最大值均变小, 其中 QKH-BPNN 预测的绝对误差和相对误差的最大值分别降低至 0.30 kW 和 2.07%, 且整体的预测误差稳定性也比另外 4 种预测模型明显提高。

表 3 中, QEA-BPNN、PSO-BPNN、KH-BPNN 和 QKH-BPNN 预测的平均绝对误差、平均相对误差、均方根误差均较传统 BP 神经网络预测降低, 其中 QKH-BPNN 预测的 3 个评价指标分别降低了 0.80 kW、5.65% 和 0.80。表明算法优化后的 BPNN 预测模型的稳定性优于传统 BPNN, 且 QKH-BPNN 的稳定性最好。

以上2个仿真实验结果表明: QKH具有收敛速度快、精度高和全局优化能力强的特点。且无论是对具有多变量、多个局部极值的测试函数优化还是对BPNN预测模型中多个权值和阈值的优化, QKH都表现出了很好的效果。因此, QKH可适用于多变量全局优化问题的求解。

4 结论

本文通过QEA和KH算法各自进化机制的融合, 提出了一种QKH算法, 实现了对QEA和KH算法相互之间的取长补短。通过测试函数验证了QKH在收敛速度、精度和稳定性方面的有效性。将融合算法应用于BPNN进行空调负荷预测, 结果表明QKH-BPNN神经网络预测结果的平均绝对误差、平均相对误差和均方根误差均优于另外4种神经网络预测模型, 其用于预测时精度更高且稳定性更强。两组实验结果表明: QKH对于多变量全局优化问题的求解具有较强的适用性。今后的研究工作一方面探索QKH在其他领域的应用, 另一方面研究该算法对于求解其他类优化问题的可行性。

参考文献:

[1] Gandomi A H, Alavi A H. Krill Herd: A New Bio-Inspired Optimization Algorithm[J]. Communications in Nonlinear Science and Numerical Simulation(S1007-5704), 2012, 17(12): 4831-4845.

[2] Mukherjee V, Mukherjee A. Chaos Embedded Krill Herd Algorithm for Optimal VAR Dispatch Problem of Power System[J]. International Journal of Electrical Power and Energy Systems(S0142-0615), 2016, 82(11): 37-48.

[3] 刘东, 李帅, 付强, 等. 基于KHA优化BP神经网络的地下水水质综合评价方法[J]. 农业机械学报, 2018, 49(9): 275-284.

Liu Dong, Li Shuai, Fu Qiang, et al. Comprehensive Evaluation Method of Groundwater Quality Based on BP Network Optimized by Krill Herd Algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(9): 275-284.

[4] Mandal B, Roy P K, Mandal S. Economic Load Dispatch Using Krill Herd Algorithm[J]. International Journal of Electrical Power and Energy Systems(S0142-0615),

2014, 57(5): 1-10.

[5] 庄存波, 熊辉, 刘检华, 等. 一种改进离散磷虾群的复杂产品装配调度算法[J]. 兵工学报, 2018, 39(8): 1590-1600.

Zhuang Cunbo, Xiong Hui, Liu Jianhua, et al. An Improved Discrete Krill Herd Algorithm for Complex Product Assembly Scheduling Problem[J]. Acta Armamentarii, 2018, 39(8): 1590-1600.

[6] 王秋萍, 丁成, 王晓峰. 一种基于改进KH与KHM聚类的混合数据聚类算法[J]. 控制与决策, 2020, 35(10): 2449-2458.

Wang Qiuping, Ding Cheng, Wang Xiaofeng. A Hybrid Data Clustering Algorithm Based on Improved Krill Herd Algorithm and KHM Clustering[J]. Control and Decision, 2020, 35(10): 2449-2458.

[7] 郭伟. 磷虾群优化算法的研究[D]. 银川: 北方民族大学, 2016.

Guo Wei. Research on Krill Herd Optimization Algorithm [D]. Yinchuan: North Minzu University, 2016.

[8] Han K H, Kim J H. Quantum-Inspired Evolutionary Algorithm for a Class of Combinatorial Optimization [J]. IEEE Transactions on Evolutionary Computation (S1089-778X), 2002, 6(6): 580-593.

[9] 杨淑云, 李盼池. 量子衍生蜂群算法的设计与实现[J]. 系统仿真学报, 2015, 27(7): 1480-1489.

Yang Shuyun, Li Panchi. Design and Implementation of Quantum-Inspired Bee Colony Algorithm[J]. Journal of System Simulation, 2015, 27(7): 1480-1489.

[10] 李盼池, 李士勇. 求解连续空间优化问题的量子蚁群算法[J]. 控制理论与应用, 2008, 25(2): 237-241.

Li Panchi, Li Shiyong. Quantum Ant Colony Algorithm for Continuous Space Optimization[J]. Control Theory & Applications, 2008, 25(2): 237-241.

[11] 何国松, 董泽, 孙明. 基于混合量子麻雀算法的过热汽温模型参数辨识[J/OL]. 华北电力大学学报(自然科学版), (2021-08-06)[2021-09-03]. <http://kns.cnki.net/kcms/detail/13.1212.TM.20210806.1032.002.html>.

He Guosong, Dong Ze, Sun Ming. Parameter Identification of Superheated Steam Temperature Model Based on Hybrid Quantum Sparrow Algorithm[J/OL]. Journal of North China Electric Power University (Natural Science Edition), (2021-08-06) [2021-09-03]. <http://kns.cnki.net/kcms/detail/13.1212.TM.20210806.1032.002.html>.

[12] Han K H, Park K H, Lee C H, et al. Parallel Quantum-Inspired Genetic Algorithm for Combinatorial Optimization Problem[C]//2001 Congress on Evolutionary Computation. Piscataway: IEEE Press, 2001: 1422-1429.

[13] 杨淑媛, 刘芳, 焦李成. 量子进化策略[J]. 电子学报, 2001, 29(增1): 1873-1877.

- Yang Shuyuan, Liu Fang, Jiao Licheng. The Quantum Evolutionary Strategies[J]. Acta Electronica Sinica, 2001, 29(S1): 1873-1877.
- [14] 蔡延光, 张敏捷, 蔡颢, 等. 混合混沌量子进化算法[J]. 系统工程理论与实践, 2012, 32(10): 2207-2214.
- Cai Yanguang, Zhang Minjie, Cai Hao, et al. Hybrid Chaotic Quantum Evolutionary Algorithm[J]. Systems Engineering-Theory & Practice, 2012, 32(10): 2207-2214.
- [15] Paudel S, Elmitri M, Couturier S, et al. A Relevant Data Selection Method for Energy Consumption Prediction of Low Energy Building Based on Support Vector Machine [J]. Energy and Buildings(S0378-7788), 2017, 138: 240-256.
- [16] 于军琪, 井文强, 赵安军, 等. 基于改进 PSO-BP 算法的冷负荷预测模型[J]. 系统仿真学报, 2021, 33(1): 54-61.
- Yu Junqi, Jing Wenqiang, Zhao Anjun, et al. Cold Load Prediction Model Based on Improved PSO-BP Algorithm [J]. Journal of System Simulation, 2021, 33(1): 54-61.
- [17] 冯增喜, 任庆昌. 基于动态组合残差修正的预测方法 [J]. 系统工程理论与实践, 2017, 37(7): 1884-1891.
- Feng Zengxi, Ren Qingchang. Forecasting Model with Dynamical Combined Residual Error Correction[J]. Systems Engineering-Theory & Practice, 2017, 37(7): 1884-1891.