

群智能算法优化 SVR 预测模型的应用与分析

朱 林, 陆春伟

(内蒙古科技大学 信息工程学院, 内蒙古 包头 014010)

摘要: 群体智能是基于生物群体行为规律的智能计算技术, 常用以解决参数寻优等问题; 作为群体智能的两种典型算法, 蚁群算法和粒子群算法应用极为广泛; 文章分析了标准蚁群算法和粒子群算法的不足, 分别采用改进的蚁群算法和粒子群算法对支持向量机回归模型参数进行优化, 并以钎铁硼吸氢阶段合金氢含量预测为例, 通过 MATLAB 对改进后的预测模型进行了仿真实验, 最终给出了两种方法优化后, 模型的预测效果及性能对比; 仿真结果表明, 改进的群体智能算法对工艺优化控制有着重要的意义。

关键词: 改进蚁群算法; 改进粒子群算法; 支持向量机回归模型; 参数寻优; 收敛速度; 相对误差

Application and Analysis about Optimization of SVR Forecasting Model by Swarm Intelligence Algorithm

Zhu Lin, Lu Chunwei

(Information Engineering College, Inner Mongolia University of science and technology, Baotou 014000, China)

Abstract: As a intelligent computing technology based on biological laws of group behavior, Swarm intelligence is widely used to solve the problems of parameter optimization. Ant colony algorithm and particle swarm optimization are widely used as two typical algorithms of swarm intelligence. In this paper we did analyze the insignificance of the standard ant colony algorithm and particle swarm optimization, then the improved ant colony algorithm and particle swarm optimization were respectively used to optimize the parameters of the regression model of support vector machine, and the hydrogen content of NdFeB alloy in the hydrogen absorption stage is taken as an example to simulates and verifies the improved model by MATLAB. The contrast of prediction performance of the regression model between two algorithms was given at last. The results of simulation indicate that the improved swarm intelligence algorithm has important significance on optimizing the process control.

Keywords: improved ant colony algorithm; improved particle swarm optimization; regress model of support vector machine; parameter optimization; convergent rate; relative error

0 引言

由简单个体组成的族群与环境以及个体之间的互动行为称为群体智能 (swarm intelligence)。作为新兴的智能算法, 群体智能可在工业数据无法在线测量或问题无法用准确的数学模型描述的情况下, 寻求复杂问题的解决方案^[1]。目前, 群体智能研究领域主要有以下两种算法: 蚁群算法和粒子群算法, 前者主要模拟蚁群寻径时的群体行为, 后者主要模拟的则是鸟群觅食的群体行为^[2-3]。文中对上述两种算法的原理、建模方法及应用等方面进行了分析, 并对优化过程中出现的局部聚集、收敛缓慢等缺陷进行了针对性改进。与原有算法相比, 改进蚁群算法和粒子群算法的寻优性能、收敛速度均有提高。

由于支持向量机回归模型的性能过于依赖学习机的参数, 回归模型参数的选取与操作人员的经验息息相关, 难以保证参数的优选, 因此文中采用改进无约束连续蚁群算法和惯性权重正弦调整的粒子群算法对支持向量机回归模型参数进行优化。文中以钎铁硼吸氢工艺过程中基于支持向量机建立的氢含量预测模型的优化为例, 验证了上述改进群体智能算法的相关性能。

1 蚁群算法及其改进

作为群体智能进化算法, 蚁群算法具备较强的鲁棒性及良好的扩展性、优化过程中无需依赖相关问题的数学特性, 简化了数据的计算及处理^[4]。此外, 蚁群算法还具备群体协同搜索能力, 通过群体之间的信息交流, 可提高上述算法的收敛速度。但是标准蚁群算法亦存在局部搜索能力差、搜索精度不高等问题, 为改善上述不足, 笔者在标准蚁群算法的迭代过程中, 加入遗传、交叉及变异等操作。经过迭代及交叉变异等操作, 可打破标准蚁群局部聚集及过早收敛的情况, 从而加快蚁群系统的收敛速度, 提高求解效率。

改进蚁群算法寻优流程如下:

(1) 设蚁群数量为 N , 蚂蚁编号为 i ($i=1, 2, \dots, N$), 每只蚂蚁 x 都定义为一个由 M 个元素组成的一维数组, 其中存储用来确定第 x 只蚂蚁所经路径的决策变量;

(2) 数组清零, 设定迭代次数 K (进化次数) 以及初始时刻各个节点的信息素 τ (初始时刻各个节点的 $\tau=1$)。令 $\tau=0$, 此时蚁群都处于蚁巢 (初始位置);

(3) 令变量 $i=1$; 通过循环确定每只蚂蚁将要选取的路径 (同一时刻每只蚂蚁对应的决策变量值);

(4) 对选取不同路径的蚂蚁进行适应度比较 (通过比较均方误差实现), 确定最差适应度所代表的蚂蚁爬行路径, 并剔除最差路径, 开始随机探路的过程, 路径 (节点) 的选择遵循轮盘策略。设 q 为选择某一路径的概率, q_0 为状态转移概率,

收稿日期:2014-05-29; 修回日期:2014-06-30。

基金项目:国家自然科学基金(61064001)。

作者简介:朱 林(1957-),女,河北承德人,教授,硕士研究生导师,主要从事智能控制、工业远程控制方向的研究。

一般取值 0.8。若 qq_0 , 则选择分量 i 中信息素最大的区间; 若 $q > q_0$, 则选择当前路径, 此外亦可使用动态概率 $1 - \frac{1}{\sqrt{k}}$ 。与定值 q_0 相比, 动态概率增加了蚁群的多样性, 可提高蚁群的搜索能力;

(5) 探路过程中, 对蚂蚁进行高斯变异, 打破蚁群严重聚集的情况 (局部极值), 以便探索新的路径, 并将新的路径与原有路径进行比较, 选出最优蚂蚁。高斯变异公式如下:

$$q = \text{normrnd}\left(\frac{lb_i + ub_i}{2}, \sqrt{\frac{ub_i - lb_i}{6}}\right)$$

上式主要是为了产生均值为 $\frac{lb_i + ub_i}{2}$, 均方误差为

$\sqrt{\frac{ub_i - lb_i}{6}}$ 的随机数, 以便打破局部聚集的情况。其中, ub_i 、 lb_i 为分别为每只蚂蚁决策变量的上界和下界;

(6) 向信息素最大的路径移动;

(7) 按照 $\tau_{ij}(t+1) = (1 - \rho) \cdot \tau_{ij}(t) + \rho \cdot \Delta\tau_{ij}(t)$ 更新信息素并对其进行自适应调整, 其中 τ_{ij} 为 t 时刻第 i 分量第 j 个子区间上的信息素, $\Delta\tau_{ij} = \sum QF_x$, Q 为常数, F_x 为第 x 只蚂蚁所走路径的适应度;

(8) 记录当前最优蚂蚁的爬行路径, 并存储对应的决策变量;

(9) 进入下一次迭代 (进化) 过程;

(10) 若迭代 k 次, 所有蚂蚁都集中到同一路径, 此时 $k < K$, 则迭代结束, 找出当前最优路径, 并存储到最优决策变量, 否则将蚁群置于蚁巢并转到步骤 3。

2 粒子群算法及其改进

粒子群优化算法中, 优化问题的解可看作是搜寻食物的鸟儿 (即粒子), 每一个粒子都有自己的速度、位置和各自对应的适应值 (由目标函数确定)。粒子经过的最好历史位置称为个体极值, 整个族群中粒子发现的最好位置则称为全局极值^[5]。种群数量为 m 的粒子组成粒子群中, 可作如下设定: 第 i 个粒子在第 d 维的位置为 X_{id} , 其飞行速度为 V_{id} , 该粒子当前搜索到的最优位置为 P_{id} , 整个粒子群当前的最优位置为 G_{id} 。其位置和速度更新公式为:

$$v_{id+1} = \omega \times v_{id} + C_1 \times r_1 \times (P_{id} - X_{id}) + C_2 \times r_2 \times (G_{id} - X_{id})$$

$$x_{id+1} = x_{id} + v_{id+1} \quad (1)$$

式中, ω 为惯性权重, 用来控制前面速度对当前速度的影响; C_1 和 C_2 为学习因子; r_1 和 r_2 为 $[0, 1]$ 范围内变化的随机数。

与标准粒子群算法相比, 改进粒子群算法可对粒子位置和速度进行自适应非线性调整, 使算法前期具备较快的收敛速度, 后期具备较强的局部搜索能力, 减少微粒陷入局部极值的机会, 最终收敛于全局最优解。惯性权重的计算公式为:

$$\omega = 0.4 + 0.5 \sin\left(\frac{\pi t}{t_{\max}}\right) \quad (2)$$

其中: t_{\max} 为最大迭代次数, t 为当前迭代次数。

改进粒子群算法寻优步骤如下:

- (1) 初始化粒子群各项参数, 即粒子数量 sizepop、最大进化次数 maxgen、学习因子 C_1 、 C_2 ;
- (2) 计算每个粒子的适应度, 和历史最优值以及全局最优值进行比较;

(3) 更新粒子的速度和位置, 并对其速度和位置进行自适应非线性调整, 计算此时粒子的适应度, 更新历史最优值和全局最优值;

(4) 重复步骤 (3) 直至迭代结束。若此时粒子全部聚集, 则输出最优参数; 若没有全部聚集, 则跳转到步骤 (1) 开始执行。

3 群体智能算法应用案例分析

3.1 应用背景

钕铁硼氢粉碎工艺在高性能钕铁硼磁体的工业制备中应用极为广泛, 经过氢碎处理的磁粉具有易破碎, 抗氧化性强等特点。但是, 氢粉碎过程中钕铁硼合金粉碎状态不可知、反应过程非线性、耦合等特点, 无法用准确的数学模型去描述, 导致氢粉碎工艺优化控制过程还处于探索阶段^[6]。工艺研究发现, 钕铁硼氢粉碎过程中合金的吸氢量 (氢含量) 能间接反映合金的粉碎状态, 但目前能够在线测量氢碎过程中钕铁硼合金氢含量的传感器还没有问世。针对此类控制对象不可直接在线测量的问题^[7], 作者先后研究了支持向量机与改进粒子群算法联合建模、支持向量机与改进无约束连续蚁群算法联合建模等方法, 以此实现氢碎过程中钕铁硼合金粉碎状态的实时监测。

3.2 群体智能算法优化 SVR 预测模型参数

支持向量机回归模型 SVR 具备以任意可控精度逼近任意非线性函数的优点, 用于钕铁硼合金氢含量的实时预测, 效果较为理想。但是, SVR 的性能过于依赖学习机的参数, 相同的训练、测试数据, SVR 回归模型参数不同, 得到的回归性能也不尽相同。采用正弦调整的改进粒子群算法和改进无约束连续蚁群算法分别对钕铁硼合金吸氢量预测模型参数进行优化, 优化方法和预测结果对比如下。

选取 86 组钕铁硼氢粉碎工艺数据, 其中 70 组作为训练集, 16 组作为测试集。按照上述章节所述寻优过程分别对 SVR 氢含量预测模型参数进行优化, 并比较优化之后 SVR 回归模型的预测效果及相对误差。

改进蚁群算法优化的 SVR 模型氢含量预测效果见图 1; 改进粒子群算法优化的 SVR 模型氢含量预测效果见图 2。

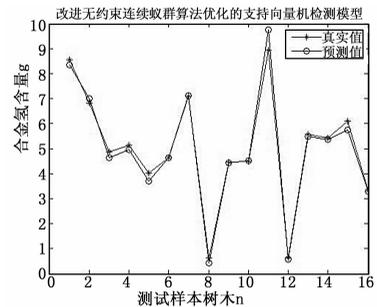


图 1 改进蚁群优化参数的 SVR 检测模型数据仿真

上述对比可以看出粒子群参数寻优能力略强于蚁群, 预测模型相对误差见图 3。

仿真结果表明, 改进粒子群算法优化的 SVR 模型具备更好的拟合能力, 检测精度更高。

需要指出的是, 蚁群算法和粒子群算法适用范围不尽相同。蚁群算法适用于离散组合优化问题 (路径寻优), 而粒子群则适用于连续组合优化问题 (参数寻优) 的求解, 两者优化能力亦存在少许差距。实际问题中, 可根据需要对上述算法进行改进, 优化系统结构, 解决相关问题。

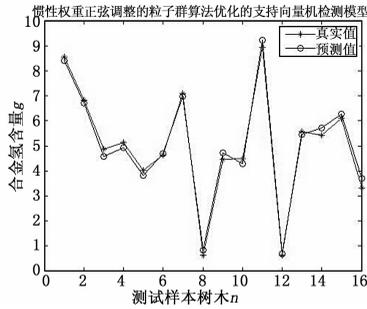


图 2 改进粒子群优化参数的 SVR 检测模型数据仿真

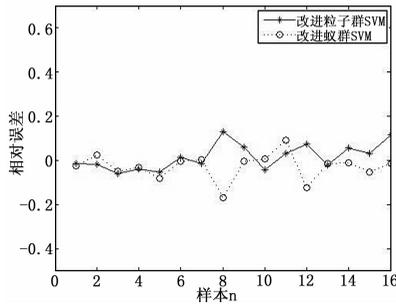


图 3 改进群体算法优化后预测模型的相对误差

4 结束语

文中提出的基于改进蚁群算法及改进粒子群算法优化 SVR 回归模型参数的方法, 可避免 SVR 回归模型参数选择时对经验的依赖性, 与原有智能算法相比, 改进蚁群算法及粒子群算法优化的 SVR 模型具备如下特点:

- (1) 改进群体收敛速度快, 迭代次数少, 在提高搜索速度的同时, 具备较强的局部搜索能力;
- (2) 局部搜索的同时, 可根据实际情况进行自适应调整控制, 可有效避免搜索偏向, 即二级欺骗等现象;
- (3) 具备大视域全局搜索和小步长局部搜索相互协作优化的能力, 可有效避免族群局部聚集的情况, 最终得到的则是全局最优解。

仿真结果表明, 采用改进粒子群算法优化 SVR 回归模型的参数, 参数寻优能力优于改进蚁群算法, 具有实际应用价值。

参考文献:

- [1] 王艳玲, 李龙澎, 胡哲. 群体智能优化算法 [J]. 计算机技术与发展, 2008, 18 (8): 114-117.
- [2] Dorigo M, Gambardella L M. Ant Colony System: A Cooperative Learning Approach to the Traveling Salesman Problem [J]. IEEE Transactions on Evolutionary Computations, 1997, 1 (1): 53-66.
- [3] Kennedy J, Eberhart R C. Particle swarm optimization [A]. Proceedings of IEEE International Conference on Neural Networks [C]. NJ: [s. n.], 1995: 1942-1948.
- [4] 付云朋, 王宏力, 侯青剑. 基于改进蚁群算法的故障树最优检测次序的研究 [J]. 战术导弹技术, 2009, 11. (6): 23-25.
- [5] 熊伟丽, 徐保国. 粒子群算法在支持向量机参数选择优化中的应用研究 [A]. 2007 中国控制与决策学术年会论文集 [C]. 2007: 447-452.
- [6] 罗阳. 展望 21 世纪的中国稀土磁体产业 [A]. 第九届中国稀土企业家联谊会会议论文集 [C]. 2002: 111-132.
- [7] 侯忠生, 许建新. 数据驱动控制理论及方法的回顾和展望 [J]. 自动化学报, 2009, 35 (6): 650-667.

(上接第 2869 页)

Sink 节点。Dijkstra 算法可改进蚁群算法中的缺陷, 可增强搜索过程的探寻, 加快最优道路的搜索速度, 减少路径寻优能耗, 使得路径的搜索离最优解保持在有限小的范围内。在仿真实验中, 通过与蚁群算法的死亡节点分布情况和死亡节点数目相对比可知: 在相同的已知条件下, 本文提出的改进 Dijkstra 算法能够在节点死亡速度上保持良好性能。综合动态分簇能量均衡管理模式, 可以克服在搜寻过程中由于过度使用某些节点而导致的网络能耗热点问题, 进而达到网络节点能耗均衡, 优化网络节点的最优路径并增强网络节点寿命, 提高网络鲁棒性。

参考文献:

- [1] Helio Mendes Salmon, Claudio M. de Farias, Paula Loureiro, Luci Pirmez. Intrusion Detection System for Wireless Sensor Networks Using Danger Theory Immune-Inspired Techniques [J]. International Journal of Systems Science, 2012: 1-28.
- [2] Li Q, Zhang B H, Cui L G, et al. Immunizations on small worlds of tree-based wireless sensor networks [J]. Chinese Phys. B, 2012, 21 (5): 1-9.
- [3] 王翥, 王祁. 多约束容错性 WSN 中继节点布局算法的研究 [J]. 电子学报, 2011, 39 (3): 115-120.
- [4] 陈丹, 郑增威, 李际军. 无线传感器网络研究综述 [J]. 计算机

- 测量与控制, 2004, 12 (8): 701-704.
- [5] Oh Hoon, Han Trung-Dinh. A demand-based slot assignment algorithm for energy-aware reliable data transmission in wireless sensor networks [J]. Wireless Networks, 2012, 18 (5): 523-534.
- [6] 肖伟, 徐明, 吕品, 等. 无线传感器网络事件簇的数据聚集容错机制 [J]. 通信学报, 2010, 31 (6): 112-118.
- [7] 李洪兵. 基于蚁群算法的无线传感器网络路由算法研究 [D]. 重庆: 重庆理工大学, 2011.
- [8] 李士勇. 蚁群优化算法及其应用研究进展 [J]. 计算机测量与控制, 2003, 11 (12): 911-917.
- [9] Lu X J, Ding Y S, Hao K R. Immune clonal selection algorithm for target coverage of wireless sensor networks [J]. Int. J. Modelling, Identification and Control, 2011, 12 (1): 119-124.
- [10] Heinzelman W B, Chandrakasan A P, Balakrishnan H. An Application-specific Protocol Architecture for Wireless Microsensor Networks [J]. IEEE Transactions on Wireless Communications, 2002, 1 (4): 660-670.
- [11] 冯跃喜, 金心宇, 蔡文郁. 基于改进型蚁群算法的无线传感路由协议 [J]. 传感技术学报, 2007, 20 (11): 2461-2464.
- [12] Lindsey S, Raghavendra C, Sivalingam K. Data Gathering Algorithms in Sensor Networks Using Energy Metrics [J]. IEEE Transactions on Parallel and Distributed Systems, 2002, 13 (9): 924-935.