

基于改进鲸鱼优化策略的贝叶斯网络结构学习算法

刘浩然* 张力悦 范瑞星 王海羽 张春兰

(燕山大学信息科学与工程学院 秦皇岛 066004)

(燕山大学河北省特种光纤与光纤传感重点实验室 秦皇岛 066004)

摘要: 针对当前贝叶斯网络结构学习算法易陷入局部最优和寻优效率低的问题, 该文提出一种基于改进鲸鱼优化策略的贝叶斯网络结构学习算法。该算法首先提出一种新的方法建立较优的初始种群, 然后利用不产生非法结构的交叉变异算子构建适用于贝叶斯网络结构学习的改进捕食行为, 同时采用动态调节参数增强算法个体寻优的能力, 通过适应度排序更新种群, 最终获得最优的贝叶斯网络结构。仿真结果表明, 该算法具有全局收敛性, 寻优效率高, 精确率高于其它同类优化算法。

关键词: 贝叶斯网络结构学习; 改进鲸鱼优化算法; 改进捕食行为; 动态调节参数

中图分类号: TP18

文献标识码: A

文章编号: 1009-5896(2019)06-1434-08

DOI: 10.11999/JEIT180653

Bayesian Network Structure Learning Based on Improved Whale Optimization Strategy

LIU Haoran ZHANG Liyue FAN Ruixing WANG Haiyu ZHANG Chunlan

(School of Information Science and Engineering, Yanshan University, Qinhuangdao 066004, China)

(The Key Laboratory for Special Fiber and Fiber Sensor of Hebei Province,

Yanshan University, Qinhuangdao 066004, China)

Abstract: A Bayesian network structure learning algorithm based on improved whale optimization strategy is proposed to solve the problem that the current Bayesian network structure learning algorithm is easily trapped in local optimal and is of low optimization efficiency. The improved algorithm proposes first a new method to establish a better initial population, and then it uses the cross mutation operator that does not produce the illegal structure to construct an improved predation behavior suitable for Bayesian network structure learning. At the same time, it adopts the dynamic parameter tuning strategy to enhance the individual search ability. The population is updated followed by the fitness order so that the optimal Bayesian network structure is obtained. Simulation results demonstrate that the algorithm has global convergence, high efficiency and higher accuracy than other similar optimization algorithms.

Key words: Bayesian network structure learning; Improved whale optimization algorithm; Improved hunt behavior; Dynamic adjustment parameter

1 引言

贝叶斯网络(Bayesian Network, BN)是用来表示不确定性关系以及推理的一种方法^[1]。从二十多年的发展来看, 贝叶斯网络已经成为近几年研究的热点之一, 被广泛应用于人工智能、机器学习、故障诊断、医疗诊断、战场决策等领域^[2,3]。

结构学习是贝叶斯网络学习的重要内容之一, 从数据中学习贝叶斯网络结构是一个NP问题^[4], 在过去的20年中被广泛深入地研究。学习贝叶斯网络结构的方法主要包含3种: 基于评分搜索法^[5]、基于约束法^[6]、混合法^[7]。近些年, 结构学习通常使用混合法, 利用约束条件构建一个初始结构, 对初始结构使用合理的搜索策略与评分函数获得一个较优的贝叶斯网络结构^[7]。文献[8]提出了混合法MM-HC(Max-Min Hill-Climbing)算法, 通过条件独立性构建初始结构并结合爬山法, 学习贝叶斯网络结构, 但算法在大网络中耗时过长, 容易陷入局部最优。使用较优的启发式搜索策略能够避免算法陷入

收稿日期: 2018-07-03; 改回日期: 2019-01-15; 网络出版: 2019-01-26

*通信作者: 刘浩然 liu.haoran@ysu.edu.cn

基金项目: 国家自然科学基金(51641609)

Foundation Item: The National Natural Science Foundation of China (51641609)

局部最优, 因此, 许多学者把元启发式搜索策略应用到贝叶斯结构学习中, 找到最优的贝叶斯网络结构。文献[9]提出MAK(MWST-ACO-K2)算法, 利用蚁群算法寻找节点序, 将得到的节点序代入K2算法得到贝叶斯网络结构, 该算法运行时间短, 但由于蚁群算法稳定性差, 最终得到的贝叶斯网络结构不佳。文献[10]提出了节点序寻优的NOK2(Node Ordering searching for K2)算法, 算法通过交叉变异产生新的节点序以及对节点序有效的评分, 能够在小网络中学习到较优贝叶斯网络结构, 但该算法在大网络中学习的贝叶斯网络结构较差。文献[1]提出了AESL-GA(Adaptive Elite-based Structure Learner using GA)算法, 通过约束函数建立初始种群, 使用精英策略改进遗传和对参数的调整, 能够学习到较优的网络结构, 但算法缺少处理贝叶斯网络非法结构的操作, 无法保证生成结构的合法性。针对当前一些基于元启发式搜索的贝叶斯结构学习法存在上述问题, 如何寻找更好的搜索策略成为许多学者的研究方向。近几年, 鲸鱼算法已经成功应用到许多研究和领域中, 通过螺旋捕食(Spiral Hunt, SH)、包围捕食(Encircling Hunt, EH)、随机捕食(Random Hunt, RH)和种群迭代, 最终找到适应度最高的鲸鱼个体为全局最优解^[11]。然而经典的鲸鱼算法只能解决连续域的问题, 无法用在贝叶斯结构学习中。

本文提出用动态参数调节的改进鲸鱼策略的贝叶斯结构学习算法IWOA(Improved Whale Optimization Algorithm), 将鲸鱼寻找最优食物看作贝叶斯网络结构寻优, 提出生成较优初始种群的方法, 同时提出利用不产生非法结构的交叉和变异因子改进鲸鱼的3种捕食行为, 经过种群迭代, 最终学习到最优的贝叶斯网络结构。利用全局收敛性准则证明算法的全局收敛性。仿真结果表明, 在3个标准网络中, IWOA算法在寻优效率及算法精度方面优于其它几种同类优化算法。

2 IWOA算法构建

IWOA算法使用最大最小父子节点法^[8](Max-Min Parents and Children, MMPC)结合爬山法生成初始种群, 利用不产生非法结构的交叉和变异策略改进鲸鱼的捕食行为得到: 改进的螺旋位置捕食行为(Improved Spiral Hunt, ISH)、改进的包围捕食行为(Improved Encircling Hunt, IEH)、改进的随机捕食行为(Improved Random Hunt, IRH), 提出了动态调节参数调节全局与局部的关系, 通过鲸鱼种群迭代更新找到最优的贝叶斯网络结构。

2.1 IWOA算法初始种群的生成

IWOA算法首先采用MMPC生成父子节点集合, 然后利用互信息^[12]处理孤立节点, 再利用子结构评分定向, 最后利用爬山法生成初始种群。

IWOA算法利用式(1)计算目标节点 $T(T \in X_i, i=1, 2, \dots, n)$ 与其它节点的最小强度关联值, 将与目标节点 T 构成最大值的点加入候选父子节点(Candidate Parents and Children, CPC)。将CPC中的目标变量 T 代入式(2), 使用条件独立性测试检验去除CPC中假父子节点, 得到每个节点的CPC, 构建无定向的初始网络 $\mathbf{W}$ 。

$$\min_{S \subseteq D} \text{ASSOC}(X : T|D) = \min_{S \subseteq D} \text{ASSOC}(X : T|D) \quad (1)$$

$$\left. \begin{array}{l} X \in \text{CPC}, \text{Ind}(X; T|S) = 0 \\ X \notin \text{CPC}, \text{其它} \end{array} \right\} \quad (2)$$

式中, D 为数据集, $X_i, i=1, 2, \dots, n$ 为节点集。

将 $\mathbf{W}$ 代入式(3), 判断 $\mathbf{W}$ 中节点 X_i 是否为孤立节点 X_{IN} , 若是, 则将 X_i 代入式(4), 得到 X_i 与其它所有节点的互信息, 并找到与 X_i 互信息最大的点 X_m , 为 X_i 和 X_m 添加一条边。根据式(3)、式(4)将 $\mathbf{W}$ 中所有 X_{IN} 转化为非孤立节点 X_{NIN} 。

$$X_i = \begin{cases} X_{\text{IN}}, & \mathbf{W}(X_i, :) = 0 \\ X_{\text{NIN}}, & \text{其它} \end{cases} \quad (3)$$

$$I(X_j, X_i) = \sum_{X_j, X_i} P(X_j, X_i) \lg \frac{P(X_j, X_i)}{P(X_j)P(X_i)} \quad (4)$$

通过子结构评分对 $\mathbf{W}$ 定向。 $\mathbf{W}$ 中任意节点 X_u 的潜在父节点集合为 $\text{Pa}(X_u)$, 建立 X_u 和 $\text{Pa}(X_u)$ 的子结构 $\{X_u, \text{Pa}(X_u)\}(u=1, 2, \dots, n)$, 为 X_u 逐一添加父节点 $X_m, X_m \in \text{Pa}(X_u)$, 利用式(5)计算子结构评分 S 。直到 S 不再增加, 得到每个节点的父节点集合, 即得到了定向的 $\mathbf{W}$ 。

$$S = \sum_{u=1}^n \sum_{v=1}^{q_u} \sum_{k=1}^{r_u} m_{uvk} \lg \left(m_{uvk} / \sum_{k=1}^{r_u} m_{uvk} \right) \quad (5)$$

式中, n 表示节点数量, q_u 表示 X_u 的父节点取值个数, r_u 表示 X_u 的取值个数, m_{uvk} 表示数 X_u 的父节点组合取值为 v 且 $X_u=k$ 的样本数。

在定向过程中, 对结构中出现的双向边转化为单向边并根据子结构评分定向。将定向完的 $\mathbf{W}$ 作为初始鲸鱼个体并代入式(6)得到初始种群 $\mathbf{G}$ 作为第1代种群。

$$\mathbf{G} = \{ \mathbf{W} * \text{op}^n \} \quad (6)$$

式中, op^n 表示加边、减边、转变操作。

2.2 IWOA算法新个体产生与种群更新

利用动态参数与交叉变异算子构建ISH, 平衡

全局搜索与局部寻优；根据p-g参数与最优交叉策略构建IEH，增强局部寻优能力；利用随机交叉策略构建IRH，增强全局搜索能力。种群中个体 $\mathbf{X}_{old}^t$ 通过ISH, IEH, IRH产生新个体 $\mathbf{X}_{new}^t$ 。种群中所有 $\mathbf{X}_{old}^t, \mathbf{X}_{new}^t$ 根据适应度排序更新种群。

鲸鱼个体进行包围捕食或随机捕食的同时也沿着螺旋状路径捕食，为了对这种同时行为构建模型，在捕食过程中，设定鲸鱼个体以50%概率选择包围捕食或随机捕食，以50%概率选择螺旋捕食^[11]。故第 t 代种群 $\mathbf{G}_{old}(t)$ 中个体 $\mathbf{X}_{old}^t$ 根据式(7)以0.5的概率选ISH，以0.5的概率选择IEH和IRH。

$$\mathbf{X}_{old}^t = \begin{cases} \text{ISH}, & q \leq 0.5 \\ \text{IEH+IRH}, & \text{其它} \end{cases} \quad (7)$$

鲸鱼捕食过程中，通过不断减小平衡参数 a 的值，使全局参数 A 的波动范围不断下降， A 在区间 $[-a, a]$ 值随 a 不断减小，当 A 的值在 $(-1, 1)$ ，即 $|A| < 1$ 时，鲸鱼个体将向食物靠近，显示出算法具有局部搜索的能力；当 A 的值小于等于-1或大于等于1时，鲸鱼个体将远离食物进行搜索，找到更合适的食物源，显示出算法具有全局搜索的能力^[11]。当鲸鱼个体 $\mathbf{X}_{old}^t$ 选择了IEH和IRH， $\mathbf{X}_{old}^t$ 根据式(8)计算出 A 。若 $|A| < 1$ 成立，则 $\mathbf{X}_{old}^t$ 选择IEH，否则选择IRH。

$$\left. \begin{aligned} A &= 2 \times \text{rand} \times a - a \\ a &= 2 - 2(t/t_{\max}) \wedge (1 - t/t_{\max}) \end{aligned} \right\} \quad (8)$$

式中，rand表示0到1随机数， t 表示当前种群迭代次数， $t_{\max}$ 表示最大种群迭代次数， a 表示平衡参数。

当个体 $\mathbf{X}_{old}^t$ 选择了ISH时，利用式(9)计算螺旋位置动态参数 b ，并根据式(10)计算 b 中适应度 F 的值^[13]。

$$b = ((F_{\max} - F) / (F_{\max} - F_{\min})) \wedge (1 - t/t_{\max}) \quad (9)$$

$$F = \lg(D/\theta^{\text{MV}}, \mathbf{X}_{old}^t) - \frac{1}{2} \text{Dim}(\mathbf{X}_{old}^t) \lg(N) \quad (10)$$

式中， $F_{\max}$ 表示种群中最优个体适应度， $F_{\min}$ 表示种群中最差个体适应度， θ^{MV} 表示参数最大似然估计， $\text{Dim}(\mathbf{X}_{old}^t)$ 表示 $\mathbf{X}_{old}^t$ 维数。

根据式(11)， $\mathbf{X}_{old}^t$ 利用变异或交叉操作产生新个体 $\mathbf{X}_{new}^t$ 。

$$\mathbf{X}_{new}^t = \begin{cases} \text{M}(\mathbf{X}_{old}^t), & b \leq p \\ \text{C}(\mathbf{X}_{old}^t, \mathbf{X}_{best}), & \text{其它} \end{cases} \quad (11)$$

式中，M表示不产生非法结构的两点变异操作，C表示不产生非法结构的单点交叉操作， p 为0到1之间的随机数。

进行M操作时， $\mathbf{X}_{old}^t$ 代入式(12)、式(13)输出合法的变异个体 $\mathbf{X}_{new}^t$ 。

$$\mathbf{X}_{old}^t(i, j) = \begin{cases} 0, & \mathbf{X}_{old}^t(i, j) = 1 \\ 1, & \text{其它} \end{cases} \quad (12)$$

$$\mathbf{X}_{new}^t = \begin{cases} \mathbf{X}_{old}^t, & \text{dig}(\mathbf{X}_{old}^t)^+ = 0 \\ \mathbf{X}_{old}^{t'}, & \text{其它} \end{cases} \quad (13)$$

式中， $\mathbf{X}_{old}^t(i, j)$ 表示 $\mathbf{X}_{old}^t$ 的邻接矩阵中随机位置元素， $\text{dig}(\cdot)^+$ 表示 $\cdot$ 的传递闭包矩阵对角线元素之和， $\mathbf{X}_{old}^{t'}$ 表示利用式(12)、式(13)产生的无环变异个体。

进行C操作时， $\mathbf{X}_{old}^t$ 利用式(14)、式(15)得到合法交叉个体 $\mathbf{X}_{new}^t$ 。

$$\left. \begin{aligned} \mathbf{X}_{old}^t(:, p) &= \mathbf{X}_{best}(:, p) \\ \mathbf{X}_{old, C}^{t'} &= \mathbf{X}_{old}^t \end{aligned} \right\} \quad (14)$$

$$\mathbf{X}_{new}^t = \begin{cases} \mathbf{X}_{old, C}^{t'}, & \text{dig}(\mathbf{X}_{old}^{t'})^+ = 0 \\ \mathbf{X}_{old, C}^{t''}, & \text{其它} \end{cases} \quad (15)$$

式中， p 表示 $\mathbf{X}_{old}^t$ 的随机列号， $\mathbf{X}_{old, C}^{t'}$ 表示将 $\mathbf{X}_{old, C}^{t'}$ 交叉列清零后，逐一添加交叉元素产生的插入位置最多的合法个体。

根据式(16)计算出p-g参数 c ，以概率 c 选择种群最优 $\mathbf{X}_{gbest}$ 作为 $\mathbf{X}_{best}$ ，以概率 $1 - c$ 选择个体历史最优 $\mathbf{X}_{pbest}$ 作为 $\mathbf{X}_{best}$ ，将得到的 $\mathbf{X}_{best}$ 作为 $\mathbf{X}_{old}^t$ 的交叉对象。

$$c = (t/t_{\max}) \wedge (1 - t/t_{\max}) \quad (16)$$

当 $\mathbf{X}_{old}^t$ 选择IEH时，将 $\mathbf{X}_{old}^t$ 代入式(17)，经过M操作产生合法变异个体，再经过C操作与 $\mathbf{X}_{best}$ 进行单点交叉(最优交叉)生成新个体 $\mathbf{X}_{new}^t$ 。当 $\mathbf{X}_{old}^t$ 选择IRH时，将 $\mathbf{X}_{old}^t$ 代入式(18)，经过M操作产生合法变异个体，再经过C操作与 $\mathbf{X}_{rand}$ 进行单点交叉(随机交叉)生成新个体 $\mathbf{X}_{new}^t$ 。

$$\mathbf{X}_{new}^t = \text{C}(\text{M}(\mathbf{X}_{old}^t), \mathbf{X}_{best}) \quad (17)$$

$$\mathbf{X}_{new}^t = \text{C}(\text{M}(\mathbf{X}_{old}^t), \mathbf{X}_{rand}) \quad (18)$$

式中， $\mathbf{X}_{rand}$ 是种群中的随机个体。

通过ISH, IEH, IRH得到更新种群 $\mathbf{G}_{new}(t)$ ，并利用式(10)计算个体的 F 值。将 $\mathbf{G}_{new}(t)$ 与 $\mathbf{G}_{old}(t)$ 中所有个体根据 F 从大到小排序，取前 z (种群规模)个生成下一代种群 $\mathbf{G}_{old}(t+1)$ 。当满足 $t < t_{\max}$ 时， $t=t+1$ ，种群继续迭代；否则算法结束迭代，输出 $\mathbf{G}_{old}(t+1)$ 中适应度最大的个体，即为最优贝叶斯网络结构。

2.3 IWOA算法步骤

步骤1 利用MMPC、互信息、子结构评分和爬山法生成初始种群 $\mathbf{G}$ ； $t=1$ ；

步骤2 种群 $G_{old}(t)$ 中随机个体 X_{old}^t , 以0.5概率跳转步骤3; 以0.5概率跳转步骤6;

步骤3 根据式(9)计算 b ; 当满足 $b \leq p$ 时, 算法跳转步骤4; 否则跳转步骤5;

步骤4 将 X_{old}^t 代入式(12)、式(13)进行M操作生成子代个体 X_{new}^t ;

步骤5 将 X_{old}^t 代入式(14)、式(15)进行C操作生成子代个体 X_{new}^t ;

步骤6 根据式(8)计算出 A , 若满足 $|A| < 1$, 则算法跳转步骤7; 否则跳转步骤8;

步骤7 将 X_{old}^t 代入式(17)进行包围捕食生成子代个体 X_{new}^t ;

步骤8 将 X_{old}^t 代入式(18)进行随机捕食生成子代个体 X_{new}^t ;

步骤9 将 $G_{old}(t)$, $G_{new}(t)$ 适应度排序, 生成 $G_{old}(t+1)$;

步骤10 若满足 $t < t_{max}$, 则 $t=t+1$, 算法跳转步骤2; 否则输出 $G_{old}(t+1)$ 中适应度最大的个体, 即为最优贝叶斯网络结构。

2.4 IWOA算法收敛性分析

IWOA算法全局收敛证明如下:

引理1 IWOA算法的最优解空间 S_{gbest} 测度大于0, 即 $L[S_{gbest}] > 0$ 。

证明 假设IWOA算法中鲸鱼的搜索域为 H , 显然它的Lebesgue^[14]总是大于0, 即 $L[H] > 0$ 。其中鲸鱼算法的最优解空间 S_{gbest} 属于Borel^[14]的一个子集, 由鲸鱼算法的最优解定义可得 $L[S_{gbest}] > 0$ 。
证毕

引理2 IWOA算法中, 当满足 $L[S_{gbest}] > 0$ 时, 式(19)成立。

$$\prod_{n=1}^{\infty} [1 - \mu_n(S_{gbest})] = 0 \quad (19)$$

式中, $\mu_n(*)$ 为第 n 次迭代结果的概率测度。

证明 根据F.SOLIS证明的搜索算法收敛准则^[15], IWOA满足式(20)。

$$\lim_{n \rightarrow \infty} P[x^n \in S_{gbest}] = 1 \quad (20)$$

式(20)说明第 n 步的结果 x^n 属于 S_{gbest} 的概率值为1。表明算法经过有限次迭代后, 改进的鲸鱼优化算法中一定有鲸鱼个体游进最佳区域 S_{gbest} 中, 因为在鲸鱼种群中存储了鲸鱼的最佳位置, 且最佳鲸鱼所在位置 $x_{best(n)}$ 同时属于最优解空间 S_{gbest} , 即式(19)成立。
证毕

由IWOA算法迭代性原则, 在以后的所有迭代中, 种群中各个鲸鱼都游向最佳区域并且逐渐靠拢, 最优个体收敛于最佳区域内, 满足全局收敛性准则^[16]即IWOA算法全局收敛。

3 实验结果与分析

3.1 实验环境以及参考量设置

为验证IWOA算法的寻优效率、精确性、全局收敛性, 本文选取了AESL-GA算法^[1]、MMHC算法^[8]、MAK算法^[9]、NOK2算法^[10]在ASIA网络(8个节点8条边)、ALARM网络(37个节点46条边)进行对比。本文使用贝叶斯网络的标准评价量^[17]如表1所示。

在不同数据量下各取10组并且在同一数据量下运行10次, 即对每个算法在不同数据量下独立运行100次求取平均值为最后的统计结果。实验环境: 处理器Pentium(R) Dual-Core, CPU E6500, 主频2.93 GHz, 内存为4G, Windows7 64 bit操作系统。

3.2 算法措施贡献度分析

本文在ALARM网络5000数据量下对IWOA算法提出的生成较优初始种群方法、改进平衡动态参数 a 、螺旋位置动态参数 b , p - g 参数 c 进行贡献度实验分析。

图例中none表示算法只使用较优初始种群的情况; a 表示算法使用较优初始种群和改进参数 a 的情况; b 表示算法使用较优初始种群和参数 b 的情况; c 表示算法使用较优初始种群和参数 c 的情

表1 贝叶斯网络的标准评价量

评价量	物理意义
TP (True Positive, 真正例)	得到的网络结构与标准网络结构相同的边的数量
TN (True Negative, 真负例)	得到的网络结构与标准结构相同无边情况的数量
FP (False Positive, 假正例)	得到的网络结构与标准结构相比增加的边的数量
FN (False Negative, 假负例)	得到的网络结构与标准结构相比丢失的边的数量
Pre (Precision, 精确率)	真正类别占正类别的比例
Sen (Sensitivity, 敏感度)	真正类别占有所有类别的比例
Score	网络结构的BIC得分
t	网络结构的执行时间

况; abc表示算法同时使用较优初始种群、改进参数 a 、参数 b 、参数 c 的情况; rabc表示算法同时使用随机初始种群、改进参数 a 、参数 b 、参数 c 的情况。

由图1可知, 状态abc时, 算法的精确率最高。在数据量较小时, 状态 c 得到的精确率高于状态 a 、状态 b 、状态none、状态rabc的精确率。这是由于算法使用了参数 c 使种群更新朝向更优, 在数据量较小时使种群选择优势个体的效率优于种群使用改进参数 a 的寻优效率, 更佳优于种群使用参数 b 的效率。在数据量较大时, IWOA算法在状态 c 得到的精确率低于状态 a 的精确率, 但高于其它未完全改进的情况。这是由于随着数据增大改进参数 a 能保证算法在前期具有较快的收敛速度, 算法后期保证算法收敛速度的同时提升算法的寻优值, 相比之下参数 c 通过控制最优值来提升算法精确率的能力略显不足。




图 1 ALARM网络中IWOA算法不同措施的精确率对比

IWOA算法在状态 a 的精确率平均高出状态none的精确率的10.74%。IWOA算法在状态 b 的精确率平均高出状态none的精确率的6.65%。IWOA算法在状态 c 的精确率平均高出状态none的精确率的9.24%。IWOA算法在状态abc的精确率平均高出状态rabc的精确率的21.32%。由此可知随机生成初始种群在其它参数完全设置下算法的精确率明显低于使用较优初始种群算法的精确率, 算法在有一定改进措施下得到的精确率均高于无改进措施的精确率, 且均低于加入所有改进措施下的精确率。

3.3 与其它算法的对比

在数据量为500, 1000, 3000, 5000时, 各个算法在ASIA网络、ALARM网络下进行仿真对比。

由表2、表3数据可知, 在ASIA网络, IWOA算法的TP, TN在4种数据量下均大于MAK算法、MMHC算法、AESL-GA算法, IWOA算法的FP, FN也小于其它3种算法, 这是由于算法生成了较好的初始种群, 提高了算法的搜索效率。IWOA算法在小型网络中学习到的增加边和缺失边较少。这是由于改进的螺旋位置捕食行为的 b 协调了IWOA算法全局与局部的关系, 提高了IWOA算法寻优的精确率, 使算法收敛到全局最优解。

在ALARM网络中, IWOA算法在TP, TN, FP, FN等方面优于AESL-GA算法。与NOK2算法相比, TP平均增加了4.83, TN平均增加了5.20, FP平均减少了1.75, FN平均减少了3.83, 这是由于IWOA算法使用了改进的捕食行为, 增强了算法中

表 2 不同算法在ASIA网络中的对比

数据量	算法	TP	TN	FP	FN	$t(s)$	Score
500	IWOA	7.0	47.3	0.2	0.9	6.09	-1153.8 $\pm$ 2.13
	MAK	4.2	44.6	3.8	3.4	3.62	-1170.5 $\pm$ 4.46
	MMHC	6.7	47.2	1.1	1.2	3.54	-1157.1 $\pm$ 6.79
	AESL-GA	6.5	46.3	1.7	1.5	4.21	-1165.5 $\pm$ 9.12
1000	IWOA	7.2	47.6	0	0.8	6.28	-2314.8 $\pm$ 3.52
	MAK	4.6	45.0	3.4	3.2	3.70	-2317.5 $\pm$ 7.47
	MMHC	6.9	45.7	0.9	0.8	4.58	-2315.6 $\pm$ 6.45
	AESL-GA	6.4	46.4	1.5	1.6	6.02	-2317.2 $\pm$ 2.24
3000	IWOA	7.4	47.8	0	0.6	7.81	-6711.8 $\pm$ 5.77
	MAK	5.0	46.2	3.4	3.0	4.32	-6723.9 $\pm$ 5.84
	MMHC	7.0	46.9	0.7	0.6	6.27	-6713.3 $\pm$ 6.46
	AESL-GA	6.9	47.1	1.2	0.9	8.63	-6719.5 $\pm$ 7.31
5000	IWOA	7.6	47.9	0	0.4	9.00	-11201.0 $\pm$ 11.42
	MAK	5.0	46.6	3.4	3.0	5.31	-11212.9 $\pm$ 12.35
	MMHC	7.2	47.5	0.5	0.6	9.01	-11208.9 $\pm$ 15.57
	AESL-GA	7.1	47.7	1.0	0.8	9.56	-11210.4 $\pm$ 14.63

表 3 不同算法在ALARM网络中的对比

数据量	算法	TP	TN	FP	FN	$t(s)$	Score
500	IWOA	37.2	1271.6	8.4	1.4	205.72	-5575.61±7.28
	NOK2	31.8	1269.5	10.1	5.6	35.91	-5374.76±18.05
	MAK	32.2	1261.4	20.5	7.2	314.16	-5580.04±10.02
	MMHC	27.6	1244.1	15.3	20.2	2647.78	-5598.67±20.33
	AESL-GA	33.3	1274.7	11.3	12.7	2647.78	-5472.37±15.35
1000	IWOA	37.6	1274.2	7.8	1.0	223.87	-10752.25±5.35
	NOK2	32.2	1270.3	9.8	5.4	37.64	-10538.84±20.20
	MAK	33.4	1265.2	19.8	5.8	356.10	-10771.08±12.36
	MMHC	30.2	1250.4	10.8	15.2	3637.85	-10824.35±15.89
	AESL-GA	35.4	1275.2	10.0	9.2	3637.85	-10964.18±8.23
3000	IWOA	39.5	1279.5	5.6	0.4	476.02	-28340.28±13.89
	NOK2	35.6	1271.9	7.2	4.0	57.35	-29043.43±14.74
	MAK	36.4	1283.4	14.2	4.4	505.57	-29308.01±14.20
	MMHC	32.6	1253.5	10.2	12.3	3963.62	-28939.91±17.12
	AESL-GA	37.0	1277.1	6.9	7.0	3963.62	-29248.78±19.30
5000	IWOA	40.8	1280.6	5.2	0.2	856.10	-47893.12±17.66
	NOK2	36.2	1273.4	6.5	3.3	69.67	-48126.57±19.58
	MAK	37.7	1270.9	10.7	3.7	948.41	-48259.15±20.45
	MMHC	35.1	1277.8	7.5	8.0	5613.55	-48677.04±19.52
	AESL-GA	38.3	1278.7	6.3	4.2	5613.55	-48148.56±24.79

种群个体间的相互交流以及有效信息的继承,提升了算法的寻优效率。IWOA算法的执行时间大于NOK2算法,这是由于IWOA算法使用的是整体的BIC评分评价结构,相比于节点序评价的NOK2算法的时间消耗小略长,但IWOA算法学习到的结构优于NOK2算法。在数据量为500, 1000时, IWOA算法的评分小于MAK算法,但所得结构好于MAK算法,这是由于MAK在评分过程中出现了过拟合现象。在数据增大到3000时, IWOA算法的得分超过其它4种算法,表明IWOA算法在数据量较大时,算法的得分更高。

由图2、图3得,在ASIA网络, IWOA算法的精

确率和敏感度在不同数据量下均高于其它3种算法。在ASIA网络中IWOA算法在5000数据量时精确率超过0.9, 而MAK算法、MMHC算法、AESL-GA算法的精确率均低于0.85。在ALARM网络中, IWOA算法的精确率随着数据量增大越来越接近0.9, 与NOK2算法、MMHC算法、AESL-GA算法相比, IWOA算法的精确率最高。在敏感度方面, IWOA算法高于其它4种算法,并且在数据量较大时达到0.8以上,而其它4种算法的敏感度低于0.7,这是由于算法使用了p-g参数 c 有效控制了寻优的方向,提高了算法的精确率和敏感度,增强了算法的全局收敛性。




图 2 不同网络中各算法精确率对比




图3 不同网络中各算法灵敏度对比

4 结束语

本文提出了基于改进鲸鱼算法的贝叶斯结构学习算法IWOA。算法通过MMPC构建初始网络大大缩减了算法的搜索空间,提出改进的捕食行为增强了种群的交流,增加了种群多样性,提升了全局的寻优能力,同时使用动态参数有效地控制了寻优的方向并提升了寻优效率,能够很好地平衡全局和局部的搜索,不产生非法结构的操作也为算法的运行提供了保证,解决了贝叶斯网络结构学习过程中产生非法结构的问题。本文使用全局收敛性准则证明了IWOA算法具有全局收敛性。经过仿真证明,IWOA在不依靠任何先验知识的情况下,通过鲸鱼算法的迭代更新找到最优的贝叶斯网络结构,与其它算法相比在算法的寻优效率、精确率、全局收敛性方面有明显的优势,而且在大网络中的时间消耗也少于改进爬山算法和其它基于元启发搜索策略的结构算法,在大数据量下能学习到与实际数据较吻合的结构。

参考文献

- [1] CONTALDI C, VAFAEE F, and NELSON P C. Bayesian network hybrid learning using an elite-guided genetic algorithm[J]. *Artificial Intelligence Review*, 2018. doi: 10.1007/s10462-018-9615-5.
- [2] 刘广怡, 李鸥, 宋涛, 等. 基于贝叶斯网络的无线传感网高效数据传输方法[J]. *电子与信息学报*, 2016, 38(6): 1362–1367. doi: 10.11999/JEIT151027.
- [3] 邓歆, 孟洛明. 基于贝叶斯网络的通信网告警相关性和故障诊断模型[J]. *电子与信息学报*, 2007, 29(5): 1182–1186. DENG Xin and MENG Luoming. Bayesian networks based alarm correlation and fault diagnosis in communication networks[J]. *Journal of Electronics & Information Technology*, 2007, 29(5): 1182–1186.
- [4] CHICKERING D M. Learning Bayesian Networks is NP-complete[M]. FISHER D and LENZ H J. Learning from Data. New York: Springer, 1996: 121–130. doi: 10.1007/978-1-4612-2404-4_12.
- [5] SCANAGATTA M, CORANI G, DE CAMPOS C P, et al. Approximate structure learning for large Bayesian networks[J]. *Machine Learning*, 2018, 107(8/10): 1209–1227. doi: 10.1007/s10994-018-5701-9.
- [6] DENNIS D M K, WILLIAMS M R, and SIGMAN M E. Investigative probabilistic inferences of smokeless powder manufacturers utilizing a Bayesian network[J]. *Forensic Chemistry*, 2017, 3: 41–51. doi: 10.1016/j.forc.2016.12.001.
- [7] LIU Hui, ZHOU Shuigeng, LAM W, et al. A new hybrid method for learning Bayesian networks: separation and reunion[J]. *Knowledge-Based Systems*, 2017, 121: 185–197. doi: 10.1016/j.knosys.2017.01.029.
- [8] TSAMARDINOS I, BROWN L E, and ALIFERIS C F. The max-min hill-climbing Bayesian network structure learning algorithm[J]. *Machine Learning*, 2006, 65(1): 31–78. doi: 10.1007/s10994-006-6889-7.
- [9] 刘浩然, 孙美婷, 李雷, 等. 基于蚁群节点寻优的贝叶斯网络结构算法研究[J]. *仪器仪表学报*, 2017, 38(1): 143–150. doi: 10.19650/j.cnki.cjsi.2017.01.019.
- [10] LIU Haoran, SUN Meiting, LI Lei, et al. Study on Bayesian network structure learning algorithm based on ant colony node order optimization[J]. *Chinese Journal of Scientific Instrument*, 2017, 38(1): 143–150. doi: 10.19650/j.cnki.cjsi.2017.01.019.
- [10] 刘彬, 王海羽, 孙美婷, 等. 一种通过节点序寻优进行贝叶斯网络结构学习的算法[J]. *电子与信息学报*, 2018, 40(5): 1234–1241. doi: 10.11999/JEIT170675.
- LIU Bin, WANG Haiyu, SUN Meiting, et al. Learning Bayesian network structure from node ordering searching

- optimal[J]. *Journal of Electronics & Information Technology*, 2018, 40(5): 1234–1241. doi: 10.11999/JEIT170675.
- [11] MIRJALILI S and LEWIS A. The whale optimization algorithm[J]. *Advances in Engineering Software*, 2016, 95: 51–67. doi: 10.1016/j.advengsoft.2016.01.008.
- [12] MENG Qingfei, CHEN Yuehui, WANG Dong, *et al.* Learning bayesian networks structure based part mutual information for reconstructing gene regulatory networks[C]. Proceedings of the 13th International Conference on Intelligent Computing, Liverpool, UK, 2017: 647–654. doi: 10.1007/978-3-319-63312-1_57.
- [13] DE CAMPOS C P, SCANAGATTA M, CORANI G, *et al.* Entropy-based pruning for learning bayesian networks using BIC[J]. *Artificial Intelligence*, 2018, 260: 42–50. doi: 10.1016/j.artint.2018.04.002.
- [14] ZAKHAROV V K and RODIONOV T V. Naturalness of the class of Lebesgue-Borel-Hausdorff measurable functions[J]. *Mathematical Notes*, 2014, 95(3/4): 500–508. doi: 10.1134/S0001434614030225.
- [15] FANG Wei, SUN Jun, CHEN Huanhuan, *et al.* A decentralized quantum-inspired particle swarm optimization algorithm with cellular structured population[J]. *Information Sciences*, 2016, 330: 19–48. doi: 10.1016/j.ins.2015.09.055.
- [16] 陈志敏, 田梦楚, 吴盘龙, 等. 基于蝙蝠算法的粒子滤波法研究[J]. *物理学报*, 2017, 66(5): 050502. doi: 10.7498/aps.66.050502.
- CHEN Zhimin, TIAN Mengchu, WU Panlong, *et al.* Intelligent particle filter based on bat algorithm[J]. *Acta Physica Sinica*, 2017, 66(5): 050502. doi: 10.7498/aps.66.050502.
- [17] ADABOR E S, ACQUAAH-MENSAH G K, and ODURO F T. SAGA: A hybrid search algorithm for Bayesian network structure learning of transcriptional regulatory networks[J]. *Journal of Biomedical Informatics*, 2015, 53: 27–35. doi: 10.1016/j.jbi.2014.08.010.
- 刘浩然: 男, 1980年生, 教授, 博士生导师, 研究方向为无线传感器网络、工业故障检测及预测.
- 张力悦: 男, 1994年生, 硕士生, 研究方向为贝叶斯网络、工业故障检测及预测.
- 范瑞星: 男, 1993年生, 硕士生, 研究方向为贝叶斯网络、工业故障检测及预测.
- 王海羽: 男, 1993年生, 硕士生, 研究方向为群智能算法、贝叶斯网络、工业故障检测及预测.
- 张春兰: 女, 1992年生, 硕士生, 研究方向为工业故障检测及预测.