

用于求解多约束 QoS 路由优化问题的改进伊藤算法^①

余世明^② 周凯杰^③ 何德峰

(浙江工业大学信息工程学院 杭州 310023)

摘要 针对伊藤算法(ITO)在大规模网络中求解多约束服务质量(QoS)路由优化时,存在收敛速度过慢、易陷入局部最优解从而导致算法成功率不高等问题,提出基于多策略协同优化的改进伊藤算法。该算法通过改进漂移与波动过程的结合方式,提出了一种新的协同更新策略,并引入双重认知策略和多精英引导学习策略,设计了一种新的路径权重更新规则。该规则使算法中漂移粒子和波动粒子强度根据个体适应度灵活变化,具有自适应性。仿真结果表明,该算法在保证系统稳定性的基础上,降低了QoS 路由的迭代次数与费用,并且在较大规模网络中有理想的表现。

关键词 路由优化;服务质量(QoS);伊藤算法(ITO);双重认知;协同更新;精英学习

0 引言

互联网+的提出与 Internet 的飞速发展,使得路由优化成为人们关注的焦点。路由优化是指在特定网络和路由需求的情况下,通过优化算法寻找一条满足约束条件的最优路径解,从而提高整体网络的路由质量,并对网络资源进行有效分配和管理。根据现有文献,对路由算法的研究有基于资源聚类的启发式路由算法^[1],网络结构重整的盒覆盖路由算法^[2],采用主动和被动路由协议相结合的路由协议^[3]等。上述算法都只选择路由延迟或链路费用作为优化目标,较少考虑其他路由因素。但是随着互联网业务的不断发展,仅仅考虑单一网络性能作为优化目标已经不能满足日益增加的互联网业务对网络性能指标的要求。因此,在路由优化算法基础上,研究多约束服务质量(quality of service, QoS)路由算法已经成为一个重要的课题。文献[4]证明 QoS 路由问题在多约束情况下是一个 NP 完全问题 (non-deterministic polynomial complete, NPC),通常采用启发式算法来解决。因此,许多启发式算法被

用来解决 QoS 路由问题,根据现有文献,遗传算法和蚁群算法在解决此问题上表现较好。其中,遗传算法^[5]通过引入混沌序列来增加种群多样性,改善了算法易早熟、易陷入局部最优的问题。而蚁群算法^[6-7]同样引入不同的优化策略来改善数据传递率、端到端延迟和路由费用等 QoS 指标。文献[8]的蚁群算法在一次搜索蚁群算法的基础上,加入二次搜索机制,极大程度地降低了算法陷入局部最优的概率。除此之外,文献[9]通过改进信息素初始化策略,将端到端延迟和带宽等信息加入启发式函数,改善了蚁群算法的收敛性。上述算法在端到端延迟、网络能耗和丢包率等指标上已经有很大的改进,但在实时通信环境下求解具有动态拓扑结构和多约束 QoS 要求的大规模网络优化问题时仍存在算法稳定性差和求解速度慢等缺点,因此改进现有算法或开发新型算法对研究多约束 QoS 问题是很必要的。

伊藤算法(ITO algorithm, ITO)是 Dong 等人^[10-13]在研究各类启发式算法的基础上,提出的一种通过观察微观粒子运动规律并加以抽象定义的新算法,

① 国家自然科学基金(61773345)和浙江省自然科学基金(LR17F030004)资助项目。

② 男,1962 年生,博士,教授;研究方向:模型预测控制与智能优化,智能装备与工业互联网;E-mail: ysm@zjut.edu.cn

③ 通信作者,E-mail: 779846517@qq.com

(收稿日期:2019-11-12)

相比于其他启发式算法,该算法具有较强的鲁棒性、求解时间短和易收敛等优点。文献[14]在理论上证明了伊藤算法收敛性和期望收敛速度,并进一步讨论了算法获得最佳解的平均期望时间、波动和漂移算子设计及参数设置等问题。现已有研究将伊藤算法用于多目标动态车辆路径的问题上,通过融入蚁群算法中信息素设计方法和混沌算法中混沌扰动,重构粒子状态转移策略,取得了较好的仿真结果^[15-16]。在此基础上,文献[17,18]将伊藤算法用于求解带软时间窗的车辆路径问题(vehicle routing problem, VRP),通过漂移和波动相结合,引入了协同扩散系数,克服了算法在求解离散组合优化问题时效率低下的缺点。根据现有文献,伊藤算法也开始应用于大规模社交网络^[19]和路由优化问题^[20]的研究。相比于其他启发式算法,伊藤算法通过设计漂移算子和波动算子,并结合路径转移策略能够快速跟踪优化目标的变化,在较小规模网络中求解 QoS 路由优化问题已有较好的表现,但应用于大规模网络时,存在收敛速度过慢、易陷入局部最优值从而导致算法成功率不高等问题。

针对上述问题,本文在基本伊藤算法的基础上,通过引入了路径权重协同更新策略,将粒子的漂移和波动过程协同进行,并结合双重认知策略,设计了一种新的路径权重更新规则。通过仿真实验,证明了改进伊藤算法在大规模网络中求解 QoS 路由优化问题的有效性和可行性。

本文的其余部分安排如下。第 1 节建立了基于无向带权连通图的网络模型和基于多约束的目标函数。第 2 节在基本伊藤算法的基础上,将协同更新策略、双重认知策略和多精英引导学习策略相结合,提出了一种基于多策略协同优化的改进伊藤算法。第 3 节对改进伊藤算法进行稳定性仿真及其在大规模网络中与其他启发式算法的求解成功率比较。第 4 节讨论了改进伊藤算法的优劣,并给出下一步研究方向。

1 网络模型及 QoS 优化指标

考虑具有链路带宽、延时、延时抖动和丢包率约

束的 QoS 路由问题,网络模型可以用无向带权连通图 $G = (V, E)$ 表示,其中 V 表示节点集, E 表示连接节点的链路集。设相邻两节点之间最多仅有一条可通信链路,假设网络 G 中,节点 $u, v \in V$ 连通,且 u, v 间无其他节点,则 $(u, v) \in E$ 称为 u, v 边的链路, $C(u, v)$ 表示链路 (u, v) 的费用。节点序列 $path(u_1, u_2, \dots, u_{m-1}, u_m)$ 为一条长 m 的路径,其中 $\forall u_l \in V, 1 \leq l \leq m$ 且 $\forall (u_{l-1}, u_l) \in E, 2 \leq l \leq m$ 。

本文研究 QoS 路由的目的是在同时满足延时、延时抖动、丢包率和带宽的约束限制下,找到一条由源节点到目的节点最小费用路径 $path(S, \dots, D)$,其中 S 为源节点, D 为目的节点。在网络业务中, QoS 即为网络的传输分组能力,其优劣可用如下可量化的性能指标来评估。

假设从源节点 S 到目的节点 D 的路径 $p(S, \dots, D)$,长度为 n ,则该路径的指标如下:

$$C(p) = \sum_{k=1}^n C(u_k) + \sum_{j=2}^n C(u_{j-1}, u_j) \quad (1)$$

$$De(p) = \sum_{k=1}^n De(u_k) + \sum_{j=2}^n De(u_{j-1}, u_j) \quad (2)$$

$$DJ(p) = \sum_{k=1}^n DJ(u_k) + \sum_{j=2}^n DJ(u_{j-1}, u_j) \quad (3)$$

$$PL(p) = 1 - \prod_{j=1}^n (1 - PL(u_j)) \quad (4)$$

$$B(p) = \min[B(u_{j-1}, u_j)], (j = 2, 3, \dots, n) \quad (5)$$

QoS 路由就是要找到一条路径,同时满足约束条件为

$$\begin{cases} \min C(p) \\ De(p) \leq De_{\max} \\ DJ(p) \leq DJ_{\max} \\ B(p) \geq B_{\min} \\ PL(p) \leq PL_{\max} \end{cases} \quad (6)$$

式中, C, De, DJ, B, PL 分别表示网络传输中设定的优化指标常数,即费用、延时、延时抖动、带宽、丢包率。由于是寻找最小费用路径,目标函数可定义为求解 $C(p)$ 的最小值,即求 $\frac{1}{C(p)}$ 的最大值。因此,目标函数定义如下:

$$F = \frac{1}{C(p)}(A \times f_{De} + B \times f_{DJ} + C \times f_{PL}) \quad (7)$$

$$f_{De} = \Phi_{De}(De_{\max} - De(p))$$

$$\Phi_{De}(x) = \begin{cases} 1 & x \leq 0 \\ r_{de} & x > 0 \end{cases} \quad (8)$$

$$f_{DJ} = \Phi_{DJ}(DJ_{\max} - DJ(p))$$

$$\Phi_{DJ}(x) = \begin{cases} 1 & x \leq 0 \\ r_{dj} & x > 0 \end{cases} \quad (9)$$

$$f_{PL} = \Phi_{PL}(PL_{\max} - PL(p))$$

$$\Phi_{PL}(x) = \begin{cases} 1 & x \leq 0 \\ r_{pl} & x > 0 \end{cases} \quad (10)$$

式中, A 、 B 、 C 分别为 f_{De} 、 f_{DJ} 、 f_{PL} 的权重系数, 其值根据具体问题设定。 $\Phi_{\Delta}(x)$ 是延时、延时抖动、丢包率的惩罚函数, 当该路径满足约束限制时, 其值为 1, 否则为 r_{Δ} , $0 < r_{\Delta} < 1$, 其大小决定惩罚的程度, 一般实验中取 $r_{\Delta} = 0.5$ 。

2 改进伊藤算法

2.1 粒子半径初始化

伊藤算法中将半径的设计与布朗运动中运动规律结合起来, 按照爱因斯坦和郎之万的理论, 半径越小粒子运动越剧烈, 则映射到算法中的漂移和波动算子的值也就越大, 这样粒子就会大范围地运动, 以达到快速搜索的目的, 更有利于大范围搜索全局最优解。而粒子半径也会随着当前目标函数值进行动态变化, 从而影响漂移和波动的强度。本文采用排序方法, 对种群中的 M 个粒子, 按照目标函数值由小到大进行排序, 求取粒子半径公式为

$$r_{L_i} = r_{\max} - \frac{r_{\max} - r_{\min}}{M - 1} \times (L_i - 1) \quad (11)$$

式中, M 表示粒子个数, L_i 表示粒子排列号, 通常情况取 $r_{\max} = 1, r_{\min} = 0$ 。

2.2 算子强度初始化

伊藤算法的漂移和波动剧烈程度由环境因素和粒子半径共同决定。波动算子主要完成粒子在自己邻域内的局部扰动, 漂移算子主要实现粒子朝着吸引元的方向移动。假定链路不受外部干扰, 按式(12) 初始化漂移算子和波动算子强度。

$$\rho = \mu = \omega_{\min} + f_1(r) \times f_2(T) \times (\omega_{\max} - \omega_{\min}) \quad (12)$$

式中, $f_1(r) = \frac{e^{-\lambda r}}{e^{-\lambda r_{\min}} - e^{-\lambda r_{\max}}}$ 和 $f_2(T) = e^{-\frac{1}{T}}$ 分别表示粒子半径和环境温度对漂移和波动算子强度的影响, μ 和 ρ 分别表示漂移算子和波动算子强度, 其中 λ 为常数, r 为粒子半径, T 表示环境温度。 ω_{\max} 和 ω_{\min} 分别表示最大和最小波动(漂移)强度, 一般情况取 $\omega_{\max} = 1 - \omega_{\min}$, 本文取 $\omega_{\max} = 1, \omega_{\min} = 0$ 。

2.3 多策略协同优化

基本伊藤算法在求解多约束 QoS 问题时, 存在随着网络规模增大, 温度调节函数无法根据网络规模的变化而动态变化, 从而导致基本伊藤算法在大规模网络中求解多约束 QoS 路由优化时, 存在收敛速度过慢、易陷入局部最优解和算法成功率不高等问题。针对上述问题, 在基本伊藤算法的基础上引入路径权重协同更新策略, 将粒子的漂移和波动过程协同进行, 并结合双重认知策略和多精英引导学习策略, 设计了一种新的路径权重更新规则。新的路径权重规则不再使用基本伊藤算法的温度调节函数进行控制, 而是结合上一代波动和漂移算子强度信息采用双重认知策略进行协同更新, 相比于温度调节函数控制, 新规则可以有效避免温度调节函数存在的随着迭代次数的增加易陷入局部最优解的问题。其次, 相比于基本伊藤算法的漂移和波动过程分开进行, 协同更新策略也更符合实际粒子的运动规律, 能更好地模拟粒子在运动过程中波动和漂移相互影响的过程。最后, 在基本伊藤算法的基础上加入多精英引导策略, 可以有效避免双重认知策略中存在的信息共享机制为单向的问题, 即所有粒子只与全局最优粒子交换信息。这种情况可能导致算法后期会向局部最优解靠拢, 而多精英引导策略将引入多个适应度好的粒子作为引导粒子, 避免了单一粒子可能导致的易陷入局部最优解问题, 使波动和漂移算子强度趋向于全局最优值, 而不再是趋向于最小值。通过多种策略的结合使用, 使得改进伊藤算法在大规模网络中求解 QoS 路由优化问题时收敛速度快、成功率高。

2.3.1 双重认知策略

基本伊藤算法的温度函数类似于模拟退火算法中 Metropolis 准则设计,温度函数相关参数都是预先设置,并不会随着算法的进行而动态变化,无法根据网络规模变化进行动态调整,从而在大规模网络中求解 QoS 路由优化问题时,存在收敛速度过慢和易陷入局部最优值的问题。针对上述问题,本文引入了双重认知策略,将自我认知和社会认知相结合对算子强度更新公式进行改进,使得算法本身能够根据网络环境动态变化做出相应的调整,通过功能各不相同的三部分组成,平衡了全局搜索与局部搜索能力,使粒子在寻优过程中具有自适应性。改进后第 i 个粒子的波动算子强度和漂移算子强度可以根据上一代信息进行更新。算法的迭代更新过程为

$$\begin{aligned}\rho_i(t+1) = & \rho_i(t) + c_1 r_1 (\rho_{best_i}(t) - \rho_i(t)) \\ & + c_2 r_2 (\rho_{gbest}(t) - \rho_i(t))\end{aligned}\quad (13)$$

$$\begin{aligned}\mu_i(t+1) = & \mu_i(t) + c_1 r_1 (\mu_{best_i}(t) - \mu_i(t)) \\ & + c_2 r_2 (\mu_{gbest}(t) - \mu_i(t))\end{aligned}\quad (14)$$

式中, $t(t=1, 2, \dots, T)$ 表示算法迭代的次数, $i(i=1, 2, \dots, M)$ 表示第 i 个粒子个体, M 表示当前粒子群体的规模大小, c_1 和 c_2 表示影响因子。如果影响因子较小,那么会导致粒子在相同路径上重复搜索,而较高的影响因子则会导致粒子略过部分路径,因此影响因子的取值对算法的性能影响较大。本文取 c_1 和 c_2 的值为 1, r_1 和 r_2 为数值在 0 和 1 范围且符合均匀分布的随机小数,即 $c_1 r_1, c_2 r_2 \in [0, 1]$ 。公式共包含三部分内容,第 1 部分 $\rho_i(t)$ 和 $\mu_i(t)$ 分别表示粒子上一次迭代中波动算子和漂移

$$\tau_{u,v}(t+1) = \begin{cases} N(d\alpha_i(t+1), d\beta_i(t+1)) & e(u, v) \in \sigma' \cap \beta_i(t+1) \neq 0 \\ \frac{1 - N(d\alpha_i(t+1), d\beta_i(t+1))}{n} & e(u, v) \notin \sigma' \cap \beta_i(t+1) \neq 0 \\ 1 & e(u, v) \in \sigma' \cap \beta_i(t+1) = 0 \\ 0 & e(u, v) \notin \sigma' \cap \beta_i(t+1) = 0 \end{cases}$$

式中, σ' 表示当前最优路径, $N(\cdot)$ 表示正态分布,正态分布的均值为 $\alpha_i(t+1) = |\rho_i(t+1) - \rho_{gbest}(t)|$, 标准方差为 $\beta_i(t+1) = |\mu_i(t+1) - \mu_{gbest}(t)|$, μ_i 和 ρ_i 分别表示漂移算子和波动算子强度, $e(i, j)$ 表示两节点 i 和 j 之间的链路, d 为放大因子,可以通过 d 值大小的变化来改变正态分布的均值与标准方差,从而改进粒子的搜索能力。

算子的强度;第 2 部分为粒子个体的自我认知部分,代表了粒子自身的经验与思考,即自我反思与学习能力;第 3 部分表示粒子的社会认知部分,代表对社会经验的思考与学习,即粒子向整个群体学习的能力。

假设改进伊藤算法中第 i 个粒子在第 t 次迭代时,粒子的波动算子强度表示为 $\rho_i(t) = [\rho_1(t), \rho_2(t), \dots, \rho_n(t)]$, 漂移算子强度可以表示为 $\mu_i(t) = [\mu_1(t), \mu_2(t), \dots, \mu_n(t)]$ 。截止到第 t 代,粒子搜索到满足目标函数的最优路径时,将波动算子和漂移算子强度记为 $\rho_{best_i}(t)$ 和 $\mu_{best_i}(t)$; 在所有粒子中得到目标函数最优解时的波动算子和漂移算子强度分别记为 $\rho_{gbest}(t)$ 和 $\mu_{gbest}(t)$ 。

2.3.2 协同更新策略

伊藤算法模拟花粉的布朗运动,然而基本的伊藤算法中漂移过程和波动过程相互独立,这并不符合实际布朗运动规律。实际布朗运动中,粒子的漂移过程和波动过程是同步进行的,文献[21]在求解 VRP 问题时,提出结合漂移和波动过程来更新路径权重的方法。在此基础上,本文根据维纳过程具有在任何有限时间上的变化服从正态分布这一特点,结合漂移算子强度和波动算子强度自适应改变的特性,提出一种新的路径权重协同更新策略,通过引入正态分布函数将漂移和波动算子进行结合,根据正态分布的均值和标准方差调整路径权重,体现了粒子在探索路径过程中,波动和漂移过程对路径权重的动态影响,改进后更新函数如式(15)所示。

$$\begin{aligned}e(u, v) \in \sigma' \cap \beta_i(t+1) \neq 0 \\ e(u, v) \notin \sigma' \cap \beta_i(t+1) \neq 0 \\ e(u, v) \in \sigma' \cap \beta_i(t+1) = 0 \\ e(u, v) \notin \sigma' \cap \beta_i(t+1) = 0\end{aligned}\quad (15)$$

2.3.3 多精英引导学习策略

针对基本伊藤算法存在随着网络规模扩大易陷入局部最优解和缺乏自适应能力的问题,本文提出了多精英引导学习策略,通过引入多个适应度好的粒子作为引导粒子,避免了单一粒子可能导致的易陷入局部最优解问题。由式(13)和(14)可见,粒子间的信息共享机制是单向的,并非是建立在全体粒

子之上,粒子除了自身的历史信息之外,只有全局最优粒子可以与其他粒子共享信息。当全局最优粒子的探索路径并非求解函数的全局最优解时,其他粒子容易受全局最优粒子信息影响朝着该位置迅速靠拢,从而导致陷入局部极值的问题。因此算法引入适应度较好的多个精英粒子,将其波动算子和漂移算子强度的平均值引入迭代公式,从而使所有粒子更易向全局最优解探索。在多精英粒子协同引导学习策略中,当算法迭代一定次数后,粒子的波动算子和漂移算子强度迭代公式更新如下:

$$\begin{aligned}\rho_i(t+1) &= \rho_i(t) + c \times r(\rho_{avg}(t) - \rho_i(t)) \\ \mu_i(t+1) &= \mu_i(t) + c \times r(\mu_{avg}(t) - \mu_i(t)) \\ \rho_{avg}(t) &= \frac{1}{n} \times \sum_{l=1}^n \rho_{best_l}(t) \\ \mu_{avg}(t) &= \frac{1}{n} \times \sum_{l=1}^n \mu_{best_l}(t)\end{aligned}\quad (16)$$

式中, c 为精英学习控制因子, r 为数值在 0 和 1 范围且符合均匀分布的随机小数, $\rho_{avg}(t)$ 和 $\mu_{avg}(t)$ 分别表示群体中适应度较好的 L 个粒子搜寻到历史最优路径时波动算子强度和漂移算子强度的平均值。在算法迭代过程中,每个粒子都有机会成为精英粒子,将其信息传播给其他粒子,从而加快迭代过程,加速算法的收敛。

2.3.4 路径转移策略

QoS 路由以提高用户的服务质量为目的,因此在选择路径节点时,带宽越宽的链路,造成网络拥堵的概率越小。综合考虑带宽、延迟和链路费用之间的关系后,设计启发因子为

$$\eta(u, v) = \exp\left(\frac{B(u, v)}{r_3(C(u, v) + C(v)) + r_4(De(u, v) + De(v))}\right)\quad (17)$$

式中, $B(u, v)$ 、 $C(v)$ 、 $C(u, v)$ 、 $De(v)$ 和 $De(u, v)$ 分别表示优化指标,即带宽、费用和延时, r_3 和 r_4 为数值在 0 和 1 范围内的小数且 $r_3 + r_4 = 1$, 其作用是用来平衡费用与延迟之间的关系,这里取 $r_3 = 0.7$, $r_4 = 0.3$ 。启发因子将优先选择链路带宽与待选节点链路费、延迟比较大的节点,且随着比值的增大启发因子将会呈非线性快速增加。通过式(18)求

得向每个可选节点的转移概率,再采用轮盘赌策略完成选择。

$$p^m(u, v) = \begin{cases} \frac{[\tau(u, v)]^a [\eta(u, v)]^b}{\sum_{l \notin tabu_m} [\tau(u, l)]^a [\eta(v, l)]^b} & u \in tabu_m, v \notin tabu_m \\ 0 & \text{其他} \end{cases}\quad (18)$$

式中, $tabu_m$ 是存储粒子 m 已访问过的节点的禁忌表, l 表示待访问的节点。 a 、 b 分别表示路径权重、启发因子对下一节点选择的影响因子,其大小可以根据两者的比重相互协调。

2.4 算法设计

本文在基本伊藤算法的基础上,改进漂移与波动过程的结合方式,提出了一种新的协同更新策略,并引入双重认知策略和多精英引导学习策略,设计了一种新的路径权重更新规则,并将改进伊藤算法应用于多约束 QoS 路由优化问题求解。改进伊藤算法求解多约束 QoS 路由优化问题实现步骤如图 1 所示。

3 仿真结果分析

3.1 参数设置

本文算法设置实验中粒子个数 $M = 50$, 算法预设迭代次数 $N = 150$, 算法最大迭代次数 $N_{max} = 200$, 路径权重影响因子 $a = 5$, 影响因子 $b = 3$, 初始路径权重 $\tau_{u, v}(t) = 1$, 环境温度 $T = 8000$, 权重系数 $A = B = C = 1$, 初始局部最优算子强度和全局最优算子强度分别为 $\rho_{best_i}(t) = \mu_{best_i}(t) = \rho_{gbest}(t) = \mu_{gbest}(t) = 0.5$, 其他参数经实验后取 $d = 10$, $c = 2$ 效果较好。

3.2 仿真分析

本节采用 Salam 网络拓扑随机生成算法生成网络节点数为 20 的网络拓扑结构,如图 2 所示。其中链路的费用、延时抖动、带宽取值范围分别设置为 $[1, 3]$ 、 $[0, 20]$ 、 $[30, 150]$, 节点的延时、费用、延时抖动、丢包率的取值范围分别设置为 $[2, 20]$ 、 $[3, 9]$ 、 $[0, 15]$ 、 $10^{-6} \times [0, 500]$, QoS 约束为 $De = 50$, $DJ = 100$, $B = 70$, $PL = 0.001$ 。

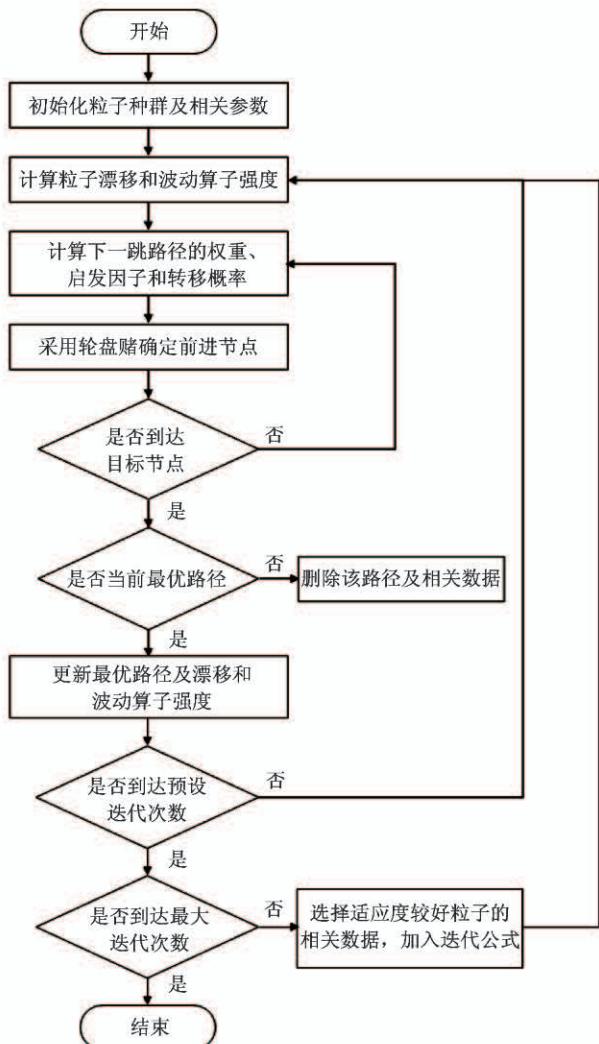


图 1 改进伊藤算法运行流程图

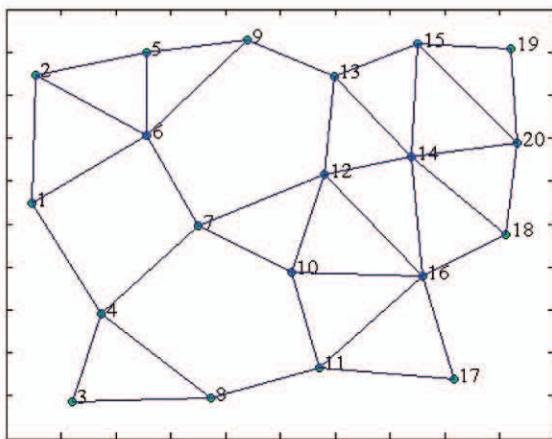


图 2 Salam 生成网络拓扑结构示意图

为验证算法受多精英引导学习策略的影响,能在迭代后期将多个适应度较好的粒子信息加入迭代更新,从而使得改进伊藤算法相比于基本伊藤算法

和文献[20]伊藤算法有着更好的收敛性,在上述网络拓扑结构中进行仿真,假设源节点为 $S = 1$,目的节点为 $D = 20$,仿真结果如图 3 所示。

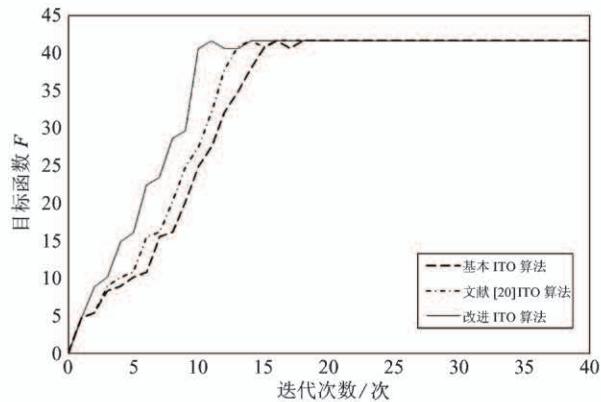


图 3 几种伊藤算法收敛性比较

从图 3 中可以看出,双重认知策略和多精英引导学习策略的结合使用使得改进伊藤算法在迭代过程中能够较快寻找到满足约束的最优路径,即当前目标函数 F 的最大值。相比于基本伊藤算法和文献[20]伊藤算法,改进算法收敛速度有明显的加快。

为验证当拓扑网络节点发生故障,即节点丢包率升高或网络数据过多导致带宽无法满足要求时,本文算法的适应能力,假设网络拓扑结构中的节点 6、节点 7、节点 12、节点 14 及其相关链路分别发生故障,即节点带宽或丢包率无法满足数据的正常传输时,QoS 各项指标的变化情况如图 4 所示。

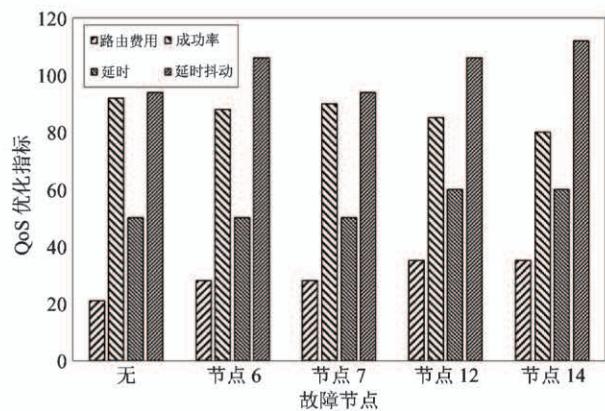


图 4 不同故障节点对 QoS 优化指标的影响

从图 4 仿真结果可见,当网络拓扑结构中最优路径上的节点发生故障时,改进伊藤算法会重新计

算当前网络的最优路径,从而用新的路由路径替代已经发生故障的路径,相比于最优路径,新路径在 QoS 指标上仍能满足约束,显然在节点及相关链路发生故障时,改进伊藤算法仍能正常运行。

随着网络的发展,网络拓扑将会不断发生变化,为验证在网络拓扑发生变化的情况下,本文改进算法本身的稳定性,设置 4 条路径,分别为源节点为 $S = 1$,目的节点为 $D = 16$;源节点为 $S = 2$,目的节点为 $D = 18$;源节点为 $S = 3$,目的节点为 $D = 20$;源节点为 $S = 4$,目的节点为 $D = 17$ 。将基础伊藤算法、文献[9]改进蚁群算法、文献[22]多路径路由算法以及本文算法分别在 4 种情况下运行 50 次,各算法在不同路径上的平均迭代次数如图 5 所示。

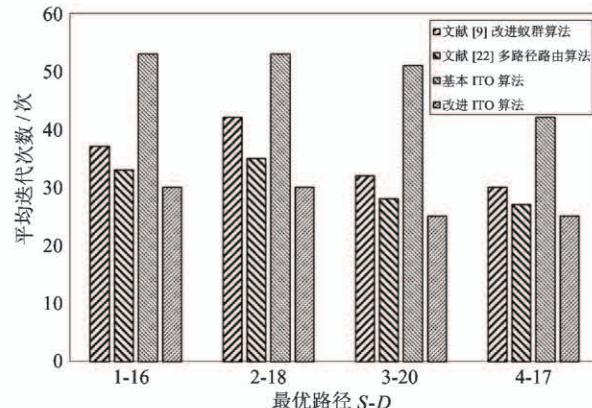


图 5 各算法在不同路径上的平均迭代次数

从图 5 中可以明显看出,在加入双重认知策略和路径权重协同更新策略后,改进伊藤算法在搜寻最优路径时,平均迭代次数明显少于其他算法,且随着最优路径发生变化仍能保持较少的迭代次数。显然,随着迭代次数的增加,算子强度受更新规则影响,更容易控制粒子向全局最优解靠近。

为进一步验证算法在不同迭代次数下的稳定性,仿真取源节点为 $S = 1$,目的节点为 $D = 20$ 作为实验最优路由路径,将基本伊藤算法、文献[20]伊藤算法、文献[22]多路径路由算法、文献[23]多目标路由算法和本文的改进伊藤算法在拓扑网络上进行仿真,设定迭代次数均为 60、其他条件均不变的情况下,得到的路由费用、延时、延时抖动与迭代次数之间的关系如图 6~图 8 所示。

通过设计启发因子平衡带宽、费用和延时之间

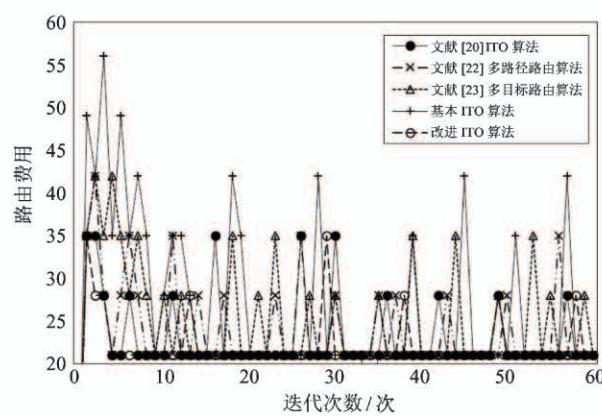


图 6 各算法的路由费用与迭代次数的关系

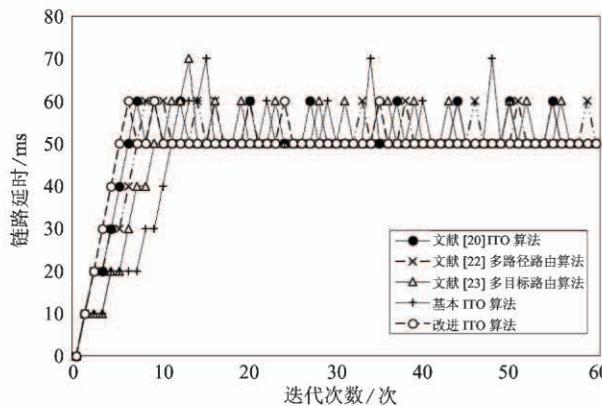


图 7 各算法的链路延时与迭代次数的关系

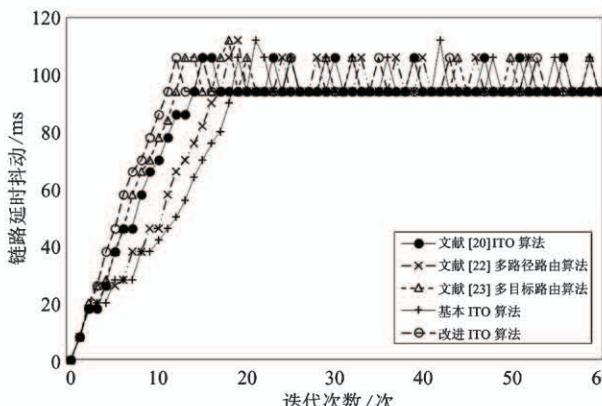


图 8 各算法的链路延时抖动与迭代次数的关系

的关系,使得算法运行过程中,粒子更容易选择带宽较大、费用和延迟较小的路径,从而易获得目标函数的最优解。从图 6~图 8 可见,改进伊藤算法的路由费用、延时、延时抖动曲线相比于其他算法,能够更早达到最优解,且随着迭代次数的增加趋于稳定,可见该算法在收敛性和稳定性上优势明显。

为验证本文改进算法在大规模网络中的适应能力,在上述实验的基础上,改变网络节点数,设计节点规模不同情况下的仿真实验,统计算法寻优的成功次数以及每次成功时的迭代次数,将搜索到最优路径的次数与实验次数的比值作为成功率,通过比较成功率来判断算法的稳定性。仿真中每增加一次网络节点数,则最大迭代次数 N_{\max} 、粒子数 M 和蚂蚁数均递增变化,仿真结果如图 9 和图 10 所示。

由图 9 可以看出,随着节点规模不断增加,网络中的链路数也随之增加,整体网络变得复杂时,本文改进伊藤算法在求解成功率上表现最好。由此可见,在大规模网络中,改进伊藤算法仍保持着良好的稳定性。从图 10 可以发现,随着节点数的不断增加本文改进算法在迭代次数上虽未能表现出优势,但是在多精英引导学习机制的作用下,即使节点规模不断增加,粒子仍能在精英粒子的引导下快速向最优解靠近,在保证平均迭代次数的情况下,较好地提高了算法成功率。

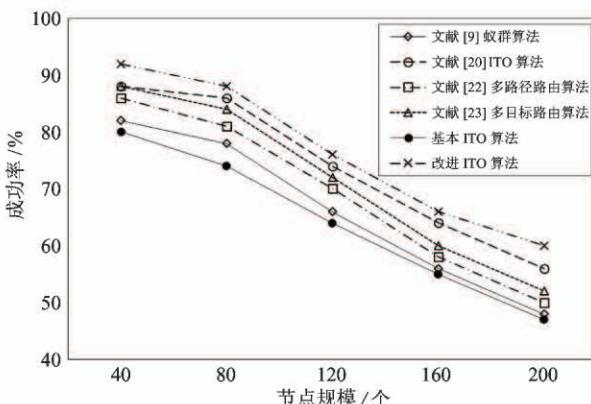


图 9 各算法的节点规模与算法成功率的关系

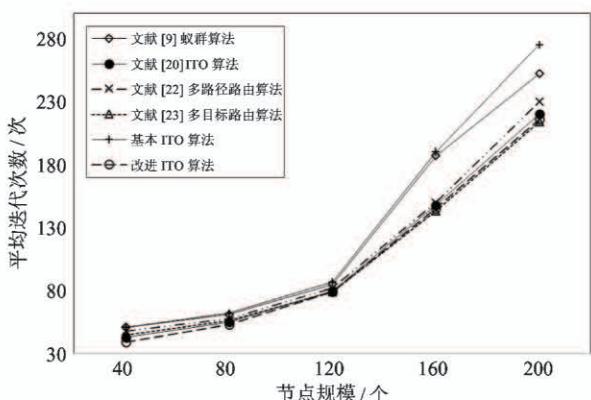


图 10 各算法的节点规模与平均迭代次数的关系

4 结 论

本文提出了一种基于多策略协同优化的改进伊藤算法,以解决网络中具有时延、带宽、费用等多约束条件的 QoS 路由优化问题。在该算法中设计了一种新的协同更新策略,并引入双重认知策略和多精英引导学习策略,提高了算法在大规模网络中的适应能力,相比于基本伊藤算法,改进伊藤算法在收敛性和稳定性上都有提升。但是,算法中有较多参数依赖于仿真实验结果。此外,随着网络规模的增大,改进伊藤算法的收敛性仍需要进一步研究与证明。

参考文献

- [1] Schütz G, Correia N, A. Martins J, et al. A bounded heuristic for collection-based routing in wireless sensor networks[J]. *IEEE Access*, 2018(6):9858-9864
- [2] Zhang L, Deng Q, Su Y, et al. A box-covering-based routing algorithm for large-scale SDNs[J]. *IEEE Access*, 2017(5):4048-4056
- [3] Brar B, Rani S, Chopra V, et al. Energy efficient direction based PDORP routing protocol for WSN[J]. *IEEE Access*, 2016(4):3182-3194
- [4] Wang Z, Crowcroft J. Quality of service routing for supporting multimedia applications[J]. *IEEE Journal on Selected Areas in Communications*, 1996, 14(7):1228-1234
- [5] 方仕勇,邹恩,辛建涛,等. 新型混沌遗传算法在多约束 QoS 路由的应用[J]. 计算机应用研究, 2012, 29(8):3078-3080
- [6] Liu X X. Routing protocols based on ant colony optimization in wireless sensor networks: a survey[J]. *IEEE Access*, 2017(5):26303-26317
- [7] Zhang H, Wang X, Memarmoshrefi P, et al. A survey of ant colony optimization based routing protocols for mobile Ad Hoc networks[J]. *IEEE Access*, 2017(5):24139-24161
- [8] 古明家,宣士斌,廉佩超,等. 基于自适应变异蚁群算法的 QoS 路由算法[J]. 计算机工程, 2009, 35(23):209-211
- [9] 王菁,刘三阳,李祖猛. 基于改进蚁群算法的 QoS 单播路由优化[J]. 系统仿真学报, 2009, 21(19):6081-6085
- [10] Dong W Y, Zhang D Y, Zhong W C, et al. The simula-

- tion optimization algorithm based on the ITO process [C] //The 3rd International Conference on Intelligent Computing, Advanced Intelligent Computing Theories and Applications, With Aspects of Contemporary Intelligent Computing Techniques, Qingdao, China, 2007:115-124
- [11] Dong W Y, Ming L, Yu R G. A new evolutionary algorithms for global numerical optimization based on ITO process [C] //The 5th International Symposium on Computational Intelligence and Intelligent Systems, Sydney, Australia, 2010:57-67
- [12] Dong W Y, Yu R G, Ming L. Merging the ranking and selection into ITO algorithm for simulation optimization [C] //The 5th International Symposium on Computational Intelligence and Intelligent Systems, Sydney, Australia, 2010:87-96
- [13] 吴德敏. 伊藤算法关键技术研究 [D]. 武汉:武汉大学计算机学院, 2013:13-22
- [14] 董文永, 张文生, 于瑞国. 求解组合优化问题伊藤算法的收敛性和期望收敛速度分析 [J]. 计算机学报, 2011, 34(4):636-646
- [15] Yi Y F, Cai Y L, Dong W Y, et al. Improved ITO algorithm for multi-objective real-time vehicle routing problem with customers' satisfaction [J]. *Acta Electronica Sinica*, 2015, 43(10):2053-2061
- [16] 华茂, 余世明. 一种改进的混沌伊藤算法求解车辆配送问题 [J]. 计算机科学, 2016, 43(3):266-270
- [17] Yi Y F, Dong W Y, Lin X D, et al. The improved ITO algorithm to solve the vehicle routing problem with soft time windows and its convergence analysis [J]. *Acta Electronica Sinica*, 2015, 43(4):658-664
- [18] 易云飞. 基于伊藤随机过程的粒子群优化算法及其应用研究 [D]. 武汉:武汉大学计算机学院, 2015:48-66
- [19] Wang Y F, Dong W Y, Dong X S. A novel ITO algorithm for influence maximization in the large-scale social networks [J]. *Future Generation Computer Systems*, 2018, 88:755-763
- [20] 满振祯, 余世明, 何德峰. 基于改进伊藤算法的最短路径网络路由优化算法 [J]. 计算机科学, 2017, 44(7): 215-220
- [21] 易云飞, 蔡永乐, 董文永, 等. 求解带容量约束的车辆路径问题的改进伊藤算法 [J]. 计算机科学, 2013, 40(5):213-216
- [22] Geng H J, Shi X G, Yin X, et al. Algebra and algorithms for multipath QoS routing in link state networks [J]. *Journal of Communications and Networks*, 2017, 19(2):189-200
- [23] Fernández F A, Cervelló P C, Ochoa A L. A multi-objective routing strategy for QoS and energy awareness in software-defined networks [J]. *IEEE Communications Letters*, 2017, 21(11):2416-2419

Improved ITO algorithm for solving multi-constrained QoS routing optimization problems

Yu Shiming, Zhou Kaijie, He Defeng

(College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023)

Abstract

The available ITO algorithms have the problems of slow convergence and easily falling into some local optimal solutions during solving a multi-constrained quality of service (QoS) routing optimization problem, which leads to the low success of the algorithms. Aiming at the problems, an improved ITO algorithm is proposed based on multi-strategy collaborative optimization in this work. By improving the combination mode of drift and wave process, a new collaborative update strategy is presented. Moreover, by introducing a dual cognitive strategy and multi-elite guided learning strategy, a new path weight update rule is designed to raise the strength of the drift particles and make wave particles in the algorithm be flexible and adaptable according to individual fitness. The simulation results show that the proposed algorithm can greatly reduce the iteration times and costs of QoS routing with guaranteed stability of the system, and it has an ideal performance in large-scale networks.

Key words: route optimization, quality of service (QoS), ITO algorithm (ITO), double cognition, collaborative update, elite learning