

基于粒子群算法的路由优化与流量均衡研究

摘要

随着网络在诸多领域的应用，网络业务呈现快速增长，由此而对互联网提供的服务质量（Quality of Service, QoS）提出更高的要求。已经证明带有性能服务要求的 QoS 路由和流量优化是组合规划中的 NP-Hard 问题。诸多学者引入诸如粒子群算法、蚁群算法、遗传算法等智能算法用以此类问题，智能算法在网络问题中的应用已成为一个研究热点，同时粒子群算法的应用也成为其一个研究的重要方面。

粒子群优化（Particle Swarm Optimization, PSO）算法是一种群体智能算法和启发式全局优化技术，整个种群在算法规定的简单行为规则下能够表现出复杂的特性。PSO 与其他进化计算方法相比，具有可设置参数少、计算速度快和简单容易实现等优点，这些使其成为一种简单有效的随机算法，在处理约束条件问题时比传统的搜索算法要表现灵活的多。目前越来越多的网络应用需要 QoS 保证，路由算法的目标由传统的寻找一条最短路径转变为寻找多约束下更优的路径。由于基于最小跳数或最小时延的简单路由算法已经不能满足网络中具有质量要求和突发性的流量的需求以及不同类型的应用需求，由此必须通过路由优化寻求满足约束条件的路径将分组推至目的节点，进而可实现网络中的性能需求、负载平衡等要求。

本文在对粒子群算法的相关情况和基于粒子群算法的路由算法的综述基础上，提出一种关系矩阵来作为粒子群算法的编码方式，并用来处理路由优化和流量均衡问题，也就是粒子的位置是一个含有整个网络的拓扑结

构信息的关系矩阵。仿真实验表明采用关系矩阵编码方法可以使粒子群算法能够较好的应用到路由优化和流量均衡问题，同时能够克服其他方法所带来的编码复杂、对粒子群算法改动较大、实现复杂等缺点。本文所提出的编码方法能够无须对粒子群算法做出较大改动，能够减少冗余空间的产生和冗余搜索。

关键字：粒子群算法，路由优化，流量均衡，关系矩阵

RESEARCH ON ROUTING OPTIMIZATION AND FLOW BALANCING BASED ON PSO

ABSTRACT

As the network in many fields of application, quality of service provided by network which presents the fast growth is put forward higher request. QoS routing and Flow balance has been proved a NP complete problems, therefore, many scholars apply such as particle swarm algorithm, the ant colony algorithm and genetic algorithm of intelligent algorithm in such problems to seek the optimum solution of the problem. Intelligent algorithm in network applications has become a hotspot, and particle swarm algorithm of application is also a study of important aspects.

PSO is a kind of swarm intelligence algorithm and heuristic global optimization technique, whose individual will flock with no quality and no volume, is a potential solution to solve the problem, and rules stipulated algorithm can show complex characteristics in the simple behavior. PSO has fewer set parameters and computing speedier and easier to realize, etc. These make it become a kind of simple and effective in the treatment of random algorithm, constraint condition problem than traditional algorithm to more flexible. At present more and more network application needs to ensure the quality of service, the target by routing algorithm of traditional find a shortest path for more change more optimal path constraint. Based on the minimal hop

due to delay or simple routing algorithm in network cannot have satisfied with the constant change of the quality requirements and different types of traffic demand, the application must be sought by routing optimization path will meet the constraints of grouping nodes, which aim to push the performance requirements can realize network load balance, etc.

Before the related information of PSO and the routing algorithm based on PSO are proposed, relationship matrix as a kind of encoding method is put forward to deal with routing optimization and flow optimization by PSO. Therefore the position of a particle must be relationship matrix in order that PSO could performance well while dealing with the problems. The kind of encoding method can solve the problem of routing optimization and load balancing in the application of PSO , that is , it can reduce the redundant space generating and redundant searching with making little change of using that coding method.

Keywords: PSO,Routing optimization,Flow balancing, Relationship matrix

第一章 引言

1.1 课题背景

互联网网络业务的迅猛发展对互联网的服务质量 (QoS) 提出了更高的要求。目前随着通信设备及其技术的不断完善改进, 传输链路和传输节点已经不再是限制网络发展的主要因素, 而作为网络业务交换节点的交换路由设备已成为制约网络性能的主要“瓶颈”。由于网络动态性和实时性的存在, 传输数据路径的实际状态不仅与路径本身的条件有关, 更受当前网络路径上负载的影响, 此时如果网络节点对全局网络服务质量的状态了解不够精确, 这就使得路径状态信息的概率模型难以确定, 预计算也不够准确, 更新路由不实时, 路由算法的计算复杂度和时间复杂度过高而不能应用在实际的网络。由于可以通过网络所分担的网络负载来充分反映互连网络复杂的动态特性, 而网络负载又是网络动态行为的主导因素, 因此, 在保证公平性、满足约束、优化性能、减少阻塞为主要因素条件下, 在当前的网络环境中进行路由优化以寻找出最优路径。另外, 通过对网络负载进行合理的负载分担规划也是提升网络性能和保证服务质量的重要途径。

生命科学与工程科学的相互交叉、相互渗透和相互促进已经成为近代科学技术发展的特点之一。粒子群算法的出现及发展体现了科学交叉发展的这种特征和趋势, 近年来, 将粒子群算法应用到网络优化问题引起了很多专家学者的注意; 粒子群算法作为一种新的全局优化搜索算法, 以其简单通用、实现容易、设置参数少和鲁棒性强等优点和适用于并行处理以及应用范围广等显著特点, 被成功应用到许多网络组合优化问题中, QoS(Quality of Service)路由选择便是其中之一。

为了有效地求解约束优化问题, 人们逐渐将目光转向随机搜索算法, 其中仿生随机算法以其较强的求解力、通用性日益受到广大学者的关注, 并逐渐成为求解约束优化问题的重要工具。与传统的优化算法相比, 仿生随机算法具有许多不可比拟的优越性, 其中最主要的一点是求解过程不依赖目标函数的解析性质, 同时能通过对问题解

空间的多点并行搜索，以较大概率收敛于全局最优解。另外仿生随机算法在处理约束条件时比传统的搜索算法要灵活得多，不仅可借助进化操作对传统的罚函数法进行改进使之更加有效的处理约束条件，也可以通过特定的编码保证个体落在可行点集内，或者在每一演化代通过特定的修正算子对后代个体进行修正以满足约束条件，而不需要借助于问题的梯度信息。

粒子群算法是一种简单有效的随机算法，与其它进化计算方法比较起来，它的求解过程更加简单易行，所付出的计算代价更小，因此也被视为求解 CO 问题的可行方法。其同样对于路由优化和流量均衡问题也是有效的。

1.2 路由算法本身面临的主要问题

路由选择包含路径确定和通过确定的路径传输信息。路径的确定即让路由器寻找一条数据包从发送端通过诸多不同网络到达目的地的可行路由的过程。路由优化的目的是提高路由选择协议选择路由的能力，使路由选择算法根据度量标准（如带宽、跳数和延时等）和度量标准所指定的权值选择最优路径以传输数据分组。

由于基于最小跳数或最小时延的路由算法已经不能满足当前网络中带有服务质量要求、具有突发性的流量以及不同类型服务应用的要求，有必要通过路由优化使路由算法选择满足约束条件的可行路径将数据分组传递至目的节点，进而实现网络中的管理策略、性能需求、负载平衡和可量测性等要求。当前的路由优化基本上是实现基于多约束条件下对分组传递路径的智能选择。

目前路由优化算法的特征和性能大多都缺少路由模型和理论上的支持，因此进行路由优化的理论研究比较困难，评价标准也不全面；基于状态信息概率分布的 QoS 路由算法必须依赖于链路状态信息的概率模型，而实际的链路状态不仅与链路本身的条件有关，而且还受当前网络流量的影响，使得链路状态信息的概率模型难以确定；大部分路由算法都只是针对 QoS 路由问题中的某些特殊情况进行的设计，缺少多个算法的纵向的比较与分析。当前的路由算法仍停留在算法研究阶段，它必须被写入通信协议才能够被实际应用。

1.3 负载均衡当前的问题与研究的意义

提高网络的运行效率、网络运行可靠性、网络资源的使用效率和流量均衡性能成为当前流量研究的主要目的。负载均衡和流量优化的核心任务就是任务调度，可以把多个请求任务相对均衡地分担到若干个控制节点，然后由控制节点决策路由路径，这样就能有效的利用各个控制节点，并能提高系统的运行效率和吞吐能力，保障整个网络系统的实时高效运行。目前，开放最短路径优先(Open Shortest Path First, OSPF)是 Internet 上应用最为广泛的内部网关协议，它采用最短路径优先(Shortest Path First, SPF)算法进行路径的选择。假设网络中的每条路径都与一个可管理的权值相关，SPF 总是选择链路权值总和最小的路径，但它的缺点是常因此导致网络上的流量不能均衡分担到各条路径，使得某些链路因为过载而产生拥塞，同时另一些链路分配较少的流量而处于闲置状态。因此，网络流量优化体系的主要目的就是优化网络资源利用率，提高网络性能，能够提供有保证的网络负载服务。

1.4 论文的主要内容

本文主要针对粒子算法在网络路由优化和流量负载均衡两个方面进行研究，提出采用关系矩阵编码的粒子群算法，这种算法立足解决目前粒子群算法在路由优化和负载均衡方面研究的不足和缺点。

本论文共分为五部分，主要内容章节安排如下：

第一章为引言，在提出课题研究的背景和意义后，介绍了当前路由优化和负载均衡研究所面临的问题。

第二章为相关研究综述：首先介绍最优优化问题的概念；本文对粒子群算法的基本概念、基本原理和它的改进算法做了较为系统的阐述；对路由优化的相关概念进行了介绍，并且在此基础上介绍了粒子群算法在该方面的研究进展；论文最后指出了当前研究存在的问题并作了进一步研究方向的展望。

第三章主要研究了采用关系矩阵作为编码方法的粒子群算法在负载均衡方面的研究：首先介绍负载均衡模型，在此基础上对优化问题进行分析并进而提出优化的目标函数；最后，对粒子群算法在负载均衡问题上的应用作了试验仿真研究。

第四章对基于关系矩阵的粒子群算法作了应用研究：在对 QoS 路由模型进行分析

和提出路由优化目标函数之后，本文对如何将关系矩阵映射为路由进行了详细的介绍；本文最后对所提出的算法进行了仿真试验研究，并与遗传算法进行了对比试验。

第五章进行了总结，并针对粒子群算法在负载均衡和路由优化上的进一步应用提出一些展望。

第二章 相关研究综述

2.1 引言

粒子群优化(Particle Swarm Optimization, PSO)算法是由James Kennedy 和 Russell Eberhart博士于1995年提出的一种基于群智能的随机全局优化技术,其源于鸟群扑食行为的研究^[1]。Kennedy又在1997年提出二进制粒子群算法^[2],解决了粒子群在离散问题上的应用。Shi为了提高算法的收敛性在1998年提出了带有惯性权重的粒子群算法^[3],成为现在的标准PSO算法。其后,有诸多学者从算法的参数设置、种群拓扑结构等方面提出的改进算法,例如混合PSO、邻域PSO、协同PSO、离散PSO等;并且PSO在诸多领域得到应用,最早是由Kennedy应用于分类XOR问题神经网络的训练,PSO已经被学者们应用在函数优化、约束及多目标优化、组合规划问题、模糊系统控制等诸多工程或计算领域,并成为一种重要的优化工具。

PSO是一种群体智能算法和启发式全局优化技术,将鸟群中的个体抽象为无质量无体积的粒子,每个粒子都是所求解问题的一个潜在解,整个种群在算法规定的简单行为规则下能够表现出复杂的特性。PSO与其他进化计算方法相比,具有可设置参数少、计算速度快和简单易实现等优点;这些使其成为一种简单有效的随机算法,在处理约束条件问题时比传统的搜索算法要灵活的多。

目前越来越多的网络应用需要服务质量保证,路由算法的目标由传统的寻找一条最短路径转变为寻找多约束下更优的路径。由于基于最小跳数或最小时延的简单路由算法已经不能满足网络中带有质量要求的不断变化的流量以及不同类型的应用需求的需求,必须通过路由优化寻求满足约束条件的路径将分组推至目的节点,进而可实现网络中的性能需求、负载平衡等要求。

而Wang Z等^[4]证明多QoS参数约束的组播路由问题一个非线性的组合优化问题,当它至少含有两个不相关可加度量的约束条件时是一个NP-C问题,而传统的路由算法很难解决NP-C问题,通常需要采用启发式算法或智能算法解决。当前提出的启发式算法要么太复杂而难于求解,要么太费时而不能实际应用。于是人们开始转向研究智能优化算法来求解该问题,而粒子群算法是一种具有深刻群智能的演化计算方法,其个

体之间通过相互协作在多点并行搜索最优解；另外，它可以不对特定问题建模或不依赖目标函数的解析性质而直接依据经过变换的输入信息在问题解空间多点并行搜索而得出问题解。这些特点使它特别适用于解决路由优化问题。

一些学者已经进行了粒子群算法在路由优化上的应用研究，并且取得了一定的成果，他们的仿真实验结果显示粒子群算法在路由优化的应用是可行的，在一定情况下表现要优于其他的智能算算法。

2.2 最优化问题

优化已经成为一个广泛使用的术语，表示从一个问题的可行解中找到最好解或次优解的概念。因此，可以将优化的目标定义为寻找满足约束条件的一组数或向量使得优化目标函数能够取得最大值或者最小值。另外，将一组满足所有约束条件的解定义为优化目标的一组可行解。因此，最优解也可以定义为在所有的可行解中能够使得目标函数取得最优值的解。

所谓最优化问题，就是在满足一定的约束条件下，寻找一组参数值，以使某些最优性度量得到满足，也就是使系统的某些性能指标达到最大或最小。优化问题包括最大化问题和最小化问题。可以使任何一个最大化问题通过把目标函数取负转化为最小化问题。同理，最小化问题也能转化为最大化问题。最优化问题的应用可以说涉及到工业、社会、经济、管理等各个领域，具有着一定的重要性。在本文中所讨论的优化问题为最小化问题。

为了后面讨论的方便性和不失一般性，设所讨论的最小优化问题为：

$$\begin{aligned} & \min f(x) \\ & s.t \\ & x \in s = \{x | g_i(x) \leq 0 \quad i \in R^+\} \end{aligned} \quad (2-1)$$

其中， $f(x)$ 为优化目标函数， $g_i(x)$ 为约束条件函数， s 为约束域， x 为 n 维优化变量。一般情况下可以很容易将最大化问题 ($f(x)$) 转换为最小化问题 ($-f(x)$)，对于 $g_i(x) \geq 0$ 的约束也可以转换为 $-g_i(x) \leq 0$ ，因此对于式 (2-1) 所描述的最小优化问题不失一般性。

当 $f(x)$ 为线性函数，且 $x \geq 0$ 时，上述最优化问题即为线性规划问题，其求解方法

有成熟的单纯形法和 Karmarc 方法；当 $g_i(x) \leq 0$ ($i \in R^+$) 所限制的约束空间为 n 维欧氏空间，即 R^n 时，上述最优化问题为无约束优化问题，即：

$$\begin{aligned} & \min\{f(x)\} \\ & \text{s.t.} \\ & x \in S \subset R^+ \end{aligned} \tag{2-2}$$

当 $f(x)$ 、 $g_i(x)$ 中至少有一个函数为非线性函数时，最下优化问题即为非线性规划问题。已证明了非线性规划问题的复杂性，只到目前还没有适应所有问题的有效方法；当优化变量 x 仅取整数值时，上述问题就成为整数规划问题，特别是当 x 仅能取 0 或 1 时，上述问题即演变为 0-1 整数规划问题。由于其计算量随变量维数的增长而呈指数级增长，因此存在着“维数灾难”问题。

非线性规划问题（包括无约束优化问题和约束优化问题），由于函数的非线性，使得问题的求解变得十分困难，特别是当目标函数在约束域内存在多峰值时。常见的求解非线性问题的优化方法，其求解结果与初值的选择关系很大，也就是说，一般的约束或无约束非线性优化方法均是求目标函数在约束域内的近似极值点，而非真正的最小点。

2.2.1 局部优化算法

定义 2-1 若 $\exists X_B^* \in B$ ，使得对 $\forall X \in B$ 有 $f(X_B^*) \leq f(X)$ ， $X \in B$ 成立，其中 $B \subset S \subset R^n$ ， S 为为由约束函数限定的搜索空间，则称 X_B^* 为 $f(x)$ 在 B 内的局部极小点， $f(X_B^*)$ 为局部极小值。

常见的优化方法大多为局部优化方法，都是依据一定的方法从一个给定的初始点 $x_0 \in S$ 开始，寻找下一个使得目标函数得到改善的更好解，直至满足某种停止准则。成熟的局部优化方法很多，如 Newton-Raphson 法、Fletcher-Reeves 法、Polar-Ribiere 法、共轭梯度法、Broyden-Fletcher-Goldfarb-Shann(BFGS)方法、Davidon-Fletcher-Power(DFP)法等等。这些优化算法的局限性在于他们都是针对无约束优化问题而提出的，并且对目标函数均有一定的解析性质要求。

将约束问题通过罚函数法转换为无约束优化问题是求解约束非线性优化问题最常

用的方法，然后再用无约束优化方法进行求解。

2.2.2 全局优化算法

定义 2-2 若 $\exists X^* \in S$ ，使得 $\forall X \in S$ ，有 $f(X^*) \leq f(X)$, $X \in S$ 成立，其中 $S \subseteq R^n$ 为约束条件限定的搜索空间，则称 X^* 为 $f(X)$ 在 S 内的全局极小点， $f(X^*)$ 为全局极小值。

目前为止，全局优化问题也已存在了许多算法，如填充函数法等，但比起局部优化问题的众多成熟方法，其间还有很大差距。另外，解析性优化方法对目标函数及约束域均有较强的解析性要求，对于诸如目标函数不连续、约束域不连通、目标函数难以用解析函数表达或者难以精确估计等问题时，解析确定性优化方法就难以适应。

为了可靠解决全局优化问题，人们试图放弃解析确定型的优化算法研究，转而探讨对函数解析性质要求较低甚至不作要求的随机型优化方法。最早的随机优化方法是基于Monte-Carlo方法的思想，针对具体问题性质的特点，构造以概率1收敛于全局最小点的随机搜索算法。真正有效且具有普遍适应性的随机全局优化方法，是模拟自然界的一些自然现象而发展起来的一系列仿生型智能优化算法，如模拟退火方法、进化类算法、群体智能算法等算法。

2.2.3 进化算法

近十余年来，遗传算法(Genetic Algorithm, GA)、进化策略(Evolutionary Strategy, ES)、进化规划(Evolutionary Programming, EP)等进化类算法在理论和应用两方面发展迅速、效果显著，并逐渐走向了融合，形成了一种新颖的模拟进化的计算理论，统称为进化计算(Evolutionary Computation, EC)，进化计算的具体实现方法与形式称为进化算法(Evolutionary Algorithm, EA)。进化算法是一种受生物进化论和遗传学等理论启发而形成的求解优化问题的随机算法。

1. 遗传算法

遗传算法最早是由美国 Michigan 大学的 J.Holland 博士提出的。1975 年，依他的开创性的著作“Adaptive in Natural and Artificial Systems”标志着遗传算法的正式诞生。遗传算法的操作对象是一组二进制串，即种群(Population)。每一个二进制串称为染色体，每个染色体或个体都对应于问题的一个解。从初始种群出发，采用基于适应值比例的选择策略在当前种群中选择个体，并使用交叉和变异来产生下一代种群，如此一

代一代进化下去，直至满足期望的终止条件。

遗传算法是一中可用于复杂系统优化的具有鲁棒性的搜索算法，与传统的优化算法相比，主要有以下特点：

(1) 遗传算法以决策变量的编码作为运算对象。传统的优化算法往往直接决策变量的实际植本身，而遗传算法处理决策变量的某种编码形式，使得我们可以借鉴生物学中的染色体和基因的概念，可以模仿自然界生物的遗传和进化机理，也使得我们能够方便的应用遗传操作算子。

(2) 遗传算法直接以适应度作为搜索信息，无需导数等其它辅助信息。

(3) 遗传算法使用多个点的搜索信息，具有隐含并行性。

(4) 遗传算法使用概率搜索技术，而非确定性规则。

(5) 搜索过程不直接作用在变量上，而是在参数集进行了编码的个体。此编码操作，使得遗传算法可以直接对结构对象进行操作。

(6) 搜索过程是一组迭代到另一组解，采用同事处理群体中多个个体的方法，具有本质的并行性。

(7) 遗传算法利用概率转移规则，可以在一个具有不确定性的空间上寻优。与一般的随机型优化方法相比，遗传算法不是从一点出发沿一条线寻优，而是在整个解空间同事开始寻优搜索，因此可以有效地比卖弄陷入局部极小点，具备全局最优搜索性。

(8) 对搜索空间没有任何特殊要求，只以决策变量的编码作为运算对象。在优化过程中借鉴生物学中染色体和基因等概念，模拟自然界中生物的遗传和进化等原理，应用遗传操作，不需要导数等其他辅助信息，可用于求解无数值概念或很难有数值概念的优化问题，适应范围更广。

(9) 遗传算法有极强的容错能力。遗传算法的初始串集本身就带有大量的与最优解甚远的信息，通过选择，交叉，变异操作能迅速排除与最优解相差极大的串。这是一个强烈的滤波过程。并且是一个并行滤波机制。因而遗传算法具有很高的容错能力。

(10) 遗传算法的选择，交叉和变异都是随机操作，而不是确定的精确规则。这说明遗传算法是采用随机方法进行最优解搜索，选择体现了向最优解的迫近，交叉体现了最优解的产生，变异体现了全局最优解的覆盖。

2.进化策略

进化策略是由德国柏林工业大学的 I.Rechenberg 和 H.P.Schwefel 等提出的。早期的

演化策略，其种群只包含一个个体且只使用变异操作。具体在每一操作代中，变异后的个体与其父代个体进行比较，从中择优选取作为新一代个体，这就是所谓的(1+1)策略。它所使用的变异算子主要是基于正态分布的变异操作。

进化策略与遗传算法相比，其主要不同之处在于：遗传算法是将原问题的解空间映射到位串空间上，然后再进行遗传操作，它强调的是个体基因结构的变化对其适应度的影响，而进化策略则是直接在解空间上进行遗传操作，它强调的是父代到子代行为的自适应性和多样性。

3.进化规划

进化规划(Evolutionary Programming, EP)方法最初是由美国科学家 Lawrence J.Fogel 等人在 20 世纪 60 年代提出的。它在求解连续参数优化问题时与 ES 的区别很小。进化规划仅使用变异与选择算子，而绝对不使用任何重组算子。其变异算子与进化策略的变异相类似，也是对父代个体采用基于正态分布的变异操作进行变异，生成相同数量的子代个体。即 μ 个父代个体总共产生 μ 个子代个体。EP 采用一种随机一竞争选择方法，从父代和子代的并集中选择出 μ 个个体构成下一代群体。其选择过程如下：对于由父代个体和子代个体组成的大小为 2μ 的临时群体中的每一个个体，从其它 $2\mu - 1$ 个个体中随机等概率地选取出 q 个个体与其进行比较。在每次比较中，若该个体的适应值不小于与之比较的个体的适应值，则称该个体获得一次胜利。从 2μ 个个体中选择出获胜次数最多的 μ 个个体作为下一代群体。

4.模拟退火算法

模拟退火算法来源于固体退火原理，将固体加温至充分高，再让其徐徐冷却，加温时，固体内部粒子随温升变为无序状，内能增大，而徐徐冷却时粒子渐趋有序，在每个温度都达到平衡态，最后在常温时达到基态，内能减为最小。根据 Metropolis 准则，粒子在温度 T 时趋于平衡的概率为 $e^{-\Delta E/(kT)}$ ，其中 E 为温度 T 时的内能， ΔE 为其改变量， k 为 Boltzmann 常数。用固体退火模拟组合优化问题，将内能 E 模拟为目标函数值 f ，温度 T 演化成控制参数 t ，即得到解组合优化问题的模拟退火算法：由初始解 i 和控制参数初值 t 开始，对当前解重复“产生新解 计算目标函数差 接受或舍弃”的迭代，并逐步衰减 t 值，算法终止时的当前解即为所得近似最优解，这是基于蒙特卡罗迭代求解法的一种启发式随机搜索过程。退火过程由冷却进度表(Cooling Schedule)控制，包括控制参数的初值 t 及其衰减因子 Δt 、每个 t 值时的迭代次数 L 和停止条件 S 。

模拟退火算法与初始值无关，算法求得的解与初始解状态 S (是算法迭代的起点) 无关；模拟退火算法具有渐近收敛性，已在理论上被证明是一种以概率 1 收敛于全局最优解的全局优化算法；模拟退火算法具有并行性。模拟退火法的实验性能具有质量高，初始鲁棒性能强，通用易实现的特点。但同时通过上面的分析可以看出，模拟退火法也存在一下不足：

(1) 尽管理论上只要计算时间足够长，模拟退火法就可以保证以概率 1 收敛于全局最优点。但是在实际算法的实现过程中，由于计算速度和时间的限制，在优化效果和计算时间二者之间存在矛盾，因而难以保证计算结果为全局最优点，优化效果不甚明显。

(2) 在每一温度下很难判断是否达到了平衡状态，即马尔科夫链的长度不易控制，反映到算法上，就是 Metropolis 过程的次数不易控制。

(3) 模拟退火算法的两种退火方式， T 始终按照优化前给定的规律变化而没有修正，这是不科学的。

2.2.4 群体智能算法

1. 蚁群算法

蚁群算法(Ant Colony Algorithm)也称蚂蚁算法，是在 20 世纪 90 年代初由意大利学者 M.Dorigo 提出的，它是根据蚂蚁觅食原理而设计的一种群体智能算法。据研究，当蚂蚁找到食物并将它搬回来时，就会在它经过的路上留下一一种“外激素”；其它蚂蚁闻到这种激素的“味道”；就沿该路线去觅食，而且还会沿着最短的路径奔向食物。它具有以下特点：

(1) 蚁群优化算法是一种结合了分布式计算，正反馈机制和贪婪式搜索的算法，具有很强的搜索较优解的能力。正反馈能够快速地发现较优解，分布式计算避免了早熟收敛，而贪婪式搜索有助于在搜索过程中早期找出可接受的解决方案，缩短了搜索时间。

(2) 蚁群算法具有很强的并行性。

(3) 可以不通过个体之间直接通信而是通过信息素进行合作，这样的系统具有更好的可扩展性。由于随着系统中个体增加而增加的系统通信开销在这里将非常小。

但是，蚁群算法具有以上所述的优点，同时它也有以下两个方面的缺点。

(1) 该算法一般需要较长的搜索时间。蚁群中各个个体的运动是随机的，虽然通

过信息交换能够向着最优路径进化，但是当群体规模较大时，很难在较短的时间内从大量杂论无章的路径中找到一条较好的路径。这是因为在进化的处级阶段，各个路径上信息量相差不明显。通过的信息正反馈，使得较好路径上的信息量逐渐增大，经过较长时间，才能使得较好路径上的信息量明显高于其他路径上的信息量，随着这一过程的进行，差别越来越明显，从而最终收敛于较好的路径。这一过程一般需要较长的时间。

(2) 该算法容易出现停止现象，即搜索进行到一定程度后，所有个体所发现的解完全一致，不能对解空间进一步进行搜索，不利于发现更好的解。

2. 粒子群算法

粒子群算法(Particle Swarm Optimization, PSO)是在 1995 年由美国社会心理学家 James Kennedy 和电气工程师 Russell Eberhart 共同提出的，其基本思想是受他们早期对鸟类群体行为研究结果的启发，并利用了生物学家 Frank Heppner 的生物群体模型。有关粒子群算法的详细介绍是本文后续各章节的内容，在这里就不作阐述。

2.3 粒子群算法

自然界中各种生物体均具有一定的群体行为，而人工生命的主要研究领域之一就是探索自然界生物的群体行为从而在计算机上构建其群体模型。通常，群体行为可以由几条简单的规则进行建模，如鱼群、鸟群等。虽然每一个个体具有非常简单的行为规则，但群体的行为却非常复杂。

粒子群算法最早是在 1995 年由美国社会心理学家 James Kennedy 和电气工程师 Russell Eberhart 共同提出的，其基本思想是受他们早期对许多鸟类的群体行为进行建模与仿真研究结果的启发。

由于鸟类使用简单的规则确定自己的飞行方向与飞行速度（实质上，每一只鸟都试图停在鸟群中而又不相互碰撞），当一只鸟飞离鸟群而飞向栖息地时，将导致它周围的其它鸟也飞向栖息地。这些鸟一旦发现栖息地，将降落在此，驱使更多的鸟落在栖息地，直到整个鸟群都落在栖息地。

由于 James Kennedy 和 Russell Eberhart 所具有的专业背景，就能很容易理解他们为什么会对 Hepper 的鸟类模型感兴趣。鸟类寻找栖息地与对一个特定问题寻找解很类似，已经找到栖息地的鸟引导它周围的鸟飞向栖息地的方式，增加了整个鸟群都找到

栖息地的可能性，也符合信念的社会认知观点。

Eberhart 和 Kennedy 对以往的模型进行了修正，以使粒子个体能够飞向解空间并在最好解处降落。其关键在于如何保证微粒降落在最好解处而不降落在其它解处，这就是信念的社会性及智能性所在。信念具有社会性的实质在于个体向它周围的成功者学习。个体与周围的其它同类比较，并模仿其优秀者的行为。将这种思想用算法实现将导致一种新的最优化算法。要解决上述问题，关键在于在探索（寻找一个好解）和开发（利用一个好解）之间寻找一个好的平衡。太小的探索导致算法收敛于早期所遇到的好解处，而太小的开发会使算法不收敛。另一方面，需要在个性与社会性之间寻求平衡，也就是说，既希望个体具有个性化，像鸟类模型中的鸟不互相碰撞，又希望其知道其它个体已经找到的好解并向它们学习，即社会性。

2.3.1 基本的粒子群算法原理

粒子群算法与其它进化类算法相类似，也采用“群体”与“进化”的概念，同样也是依据个体（粒子）的适应值大小进行操作。所不同的是，粒子群算法不像其它进化算法那样对于个体使用进化算子，而是将每个个体看作是在 n 维搜索空间中的一个没有重量和体积的粒子，并在搜索空间中以一定的速度飞行。该飞行速度由个体的飞行经验和群体的飞行经验进行动态调整。

假设有 M 个粒子组成的粒子群体在 D 维空间中依一定的速度飞行搜索。粒子群算法先随机初始化各粒子位置，使得粒子具有在解空间的全局探索能力，然后通过迭代找到最优解；每次迭代，粒子通过跟踪两个“极值”个体与邻域极值来改变自己的飞行速度，使其从这些较优解获得信息，趋向于对相应邻近区域的局部搜索。

设：

$x_i = (x_{i1}, x_{i2}, \dots, x_{in})$ 为粒子 i 的当前位置；

$v_i = (v_{i1}, v_{i2}, \dots, v_{in})$ 为粒子 i 的当前飞行速度；

$P_i = (P_{i1}, P_{i2}, \dots, P_{in})$ 为粒子 i 所经历的最好位置，也就是粒子 i 所经历过的具有最好适应值的位置，称为个体最好位置。对于最小化问题，目标函数值越小，对应的适应值越好。

由于本文以后章节讨论的都是最小化问题和讨论方便，设 $f(X)$ 为最小化的目标函数，则粒子 i 的当前最好位置由下式（2-3）确定：

$$P_i(t+1) = \begin{cases} P_i(t) & \text{if}(f(x_i(t+1)) \geq f(P_i(t))) \\ x_i(t+1) & \text{if}(f(x_i(t+1)) \leq f(P_i(t))) \end{cases} \quad (2-3)$$

设群体中的粒子数为M，群体中所有粒子所经历过的最好位置为 P_g ，称为全局最好位置。则有：

$$P_g(t) \in \{P_1(t), P_2(t), \dots, P_M(t) \mid f(P_g(t)) = \min\{f(P_1(t)), f(P_2(t)), \dots, f(P_M(t))\}\} \quad (2-4)$$

为了简单起见，只列出粒子i位置和速度的第d 维分量更新公式：

$$v_{id}(t+1) = v_{id}(t) + c_1 r_1 (p_{id} - x_{id}(t)) + c_2 r_2 (p_{gd} - x_{id}(t)) \quad (2-5)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (2-6)$$

其中，通常为了防止 V_{id} 过大，使得粒子搜索域超出搜索空间，使其满足： $|V_{id}| \leq V_{max}$ 。

在式（2-5）中第一部分 $V_{id}(t)$ 表示粒子的当前飞行速度，它使粒子具有一定全局的搜索能力；第二部分是粒子的“认知部分”，表示对自身经验的学习过程；第三部分为社会认知，表示粒子学习其他粒子经验的过程，表现了微粒间信息的共享与社会协作。 c_1, c_2 代表粒子从个体极值和全局极值的信息继承度，反映了对继承信息的程度。简而言之，粒子在“认知模型”和“社会模型”的作用下，分别从其个体极值和全局极值继承部分信息，并利用粒子的速度进行随机搜索。

虽然已经证明粒子群算法在解决非线性、不可微、多模态等复杂优化问题时具有收敛度快、强壮性好等特点，并已成为的一种有效方法。但它在进化后期也存在容易陷入局部最优解，因此其也存在收敛精度不高、易发散等缺点，为此，许多学者针对这些问题提出了多种改进方法，以期提高算法的全局搜索能力和精度。

2.3.2 改进的粒子群算法

1. 带有惯性权重的PSO算法

Y. Shi和R.C.Eberhart在首次引入惯性权重 w ^[3]，即将(1)式变为下式(2-7)：

$$v_{id}(t+1) = w v_{id}(t) + c_1 r_1 (p_{id}(t) - x_{id}(t)) + c_2 r_2 (p_g(t) - x_{id}(t)) \quad (2-7)$$

在大多文献中将带有惯性权重 w 的PSO算法称为标准PSO算法。惯性权重 w 表明微粒原先的速度能在多大程度上得到保留。通常采用 w 线性减小的方法来达到开始阶段具有较强的全局搜索能力，而在后期以较小的 w 能够收敛到最优解。但是对于某些特殊的问题此方法并不凑效，有的学者就此提出了只对 w 的改进PSO算法。比如，Shi Y等提出

了一种用模糊规则动态调整 ω 的方法^[5]，通过对当前最好性能评价(CBPE)和当前惯性权重制定相应的隶属度函数和模糊推理规则，确定惯性权重 ω 的增量；胡建秀等给出了典型的线性递减、线性微分递减、非线性微分变化和步长较小的线性递减等四种惯性权重调整策略^[6]。

2.带有收缩因子的PSO算法

Clerc M 等人对PSO算法的收敛性进行了研究，证明采用收敛因子能够确保算法的收敛^[7,8]。基于收敛因子的算法速度公式为：

$$v_{id}(t+1) = \mathbf{a}((v_{id}(t) + c_1 r_1 (p_{id}(t) - x_{id}(t)) + c_2 r_2 (p_{gd}(t) - x_{id}(t))) \quad (2-8)$$

其中，收敛因子满足： $\mathbf{a} = \frac{2}{|2 - \mathbf{e} - \sqrt{\mathbf{e}^2 - 4\mathbf{e}}|}$ 且 $\mathbf{e} = c_1 + c_2 > 4$ 。

其相关的实验结果表明，与使用惯性权重的粒子群优化算法相比，使用收敛因子的粒子群优化算法有更快的收敛速度。在使用收缩因子时首先对算法进行限定，这样几乎可以改进算法对所有测试函数的求解性能。

3.混合粒子群算法

利用选择的方法:文献^[9]将选择算子引进PSO算法中作为锦标赛选择算子，将每个个体的适应度与种群中的其他个体的适应度逐一进行比较，如果当前个体的适应度优于某个个体的适应度，则每次授予该个体一分。根据个体所得的分数对种群中的个体进行由大到小的排列。选择种群中顶部的一半个体，并对他们进行复制，取代种群底部的一半个体，在此过程中最佳个体的适应度并未改变。

借鉴杂交的方法:Angeline^[10]提出了杂交粒子群算法，在每次迭代中，依据指定的杂交概率选取指定数量的粒子放入一个池中。池中的粒子随机两两杂交，产生相同数量的后代，并用后代代替父代。杂交算法并不改变粒子位置量的大小，而只是改变其方向。

利用变异的方法:李宁提出的基于带变异算子的粒子群算法^[11]中，在子群的历史最优粒子位置 P_i 连续无变化或变化极小时，若粒子群出现较严重聚集情况，则保留历史最优粒子位置 P_i ，将粒子中少部分维重新随机初始化，这样同时能够保持算法的收敛速度和搜索精度。文献^[12]引入克隆选择使群体最佳微粒实现遗传微变、局部增值，具有变异确定性,同时又设计一个考虑粒子分布和迭代次数的函数,自适应调整粒子的“社会认知”能力，提高种群的多样性；利用Logistic序列指导最佳粒子随机漂移，进一步增强逃

离局部极值能力。

利用模拟退火算法作为收敛判据：文献[13]提出了一种基于粒子群算法与模拟退火算法的混合方法，以模拟退火算法作为粒子群算法的收敛判据并为不收敛的群体置换新的粒子，从而使群体向全局最优解方向飞行：即当基本粒子群算法收敛到某一解 P_g 时，用 P_g 作为模拟退火算法的初始点进行搜索，如果得到一个比 P_g 较优的新解 y ，然后用 y 来随机取代粒子群中的一个粒子，用基本粒子群算法继续进化。如果不存在这样一个解 y 则说明 P_g 就是全局最优解。仿真试验证明，这种混合方法能够有效地改进PSO算法的早熟现象。

引进免疫机制的改进算法：文献[14]结合粒子群优化算法具有的全局寻优能力和免疫系统的免疫信息处理机制而引入免疫机制的概念，以此来增强粒子群优化算法摆脱局部极值点的能力，提高了算法收敛速度和精度。

4.基于邻域思想的改进算法

P. N. Suganthan在1999年提出一种基于邻域结构的粒子群算法^[15]：每个粒子领域随着迭代从自身扩大至整个粒子群。J. Kennedy研究了不同拓扑结构对粒子群算法的影响^[16]，并且最终提出了几种基本粒子群拓扑结构^[17]。随后出现了诸多的基于邻域的改进算法，比如邢万波提出的自适应改变邻域结构粒子群算法^[18]。

5.多子群协同优化算法

多种群协同优化算法是将粒子群划分成多个子群，子群之间依特定方式相互联系、交互信息，共同对问题协同优化。Bask S 提出的多种群协同优化粒子位置的不同维的协同粒子群算法^[19]，Parsopoulos K.E 提出的将子群依据多目标函数划分子群的用于优化多目标问题的 VEPSO^[20]。

6.保证种群多样性的粒子群算法

J. Riget 提出了一种保证种群多样性的粒子群算法^[21]。该算法引入“吸引”和“扩散”两个算子，动态地调整“勘探”与“开发”比例，从而能更好的提高算法效率。在介婧等提出的基于群体多样性负反馈控制的自组织粒子群算法^[22]中，将粒子群体视为自组织系统，引入负反馈机制：用多样性参考输入 D_i 和当前的群体多样性 D_c 差值的正负来动态调整惯性权重或加速度系数，通过不同的特性参数实现粒子的集聚或分散，使群体维持适当的多样性水平以利于全局搜索。

7.保证全局收敛的随机粒子群算

“一种保证全局收敛的随机 PSO 算法”^[23]其基本思想是利用停止进化的粒子来改善全局搜索能力。在基本 PSO 算法中，当 $w=0$ 时，使得全局搜索能力减弱，而局部搜

索能力加强，但这样也使得在进化的某一代均至少有一个粒子由于处于粒子群的历史最好位置而停止进化，然后在搜索空间中重新随机产生新的微粒以代替停止粒子的进一步进化，这样就大大增强了全局搜索能力。

2.3.3 离散粒子群算法

为了用PSO算法求解离散组合优化问题，主要有两种离散粒子群算法形式^[24]：基于连续空间的DPSO和基于离散空间的DPSO。前者是以经典的连续粒子群算法为基础，针对特定问题，将离散问题空间映射到连续粒子运动空间，并适当修改PSO算法来求解，在计算上仍保留经典粒子群算法速度-位置更新中的在连续运算规则，比如二进制PSO算法(BPSO)^[2]和用于求解整数规划的PSO算法^[25]；后者是针对离散优化问题，在保持经典PSO算法信息更新机制、基本思想、算法框架下，重新定义特有的粒子群离散表示方式与操作算子来求解，比如Clerc^[26]和Kang-Ping Wang^[27]针对旅行商问题提出的TSP-DPSO算法。

关于粒子群算法的改进，大部分都是围绕粒子群收敛性和多样性而提出的，但是他们在改善算法的同时也增加了算法的复杂性。不同的学者根据不同的情况提出了不同的改进方法，或应用到了不同的领域，现把具有代表性的方法列表如表2-1：

表 2-1 具有代表性的改进粒子群算法
Table 2-1 Representative improved PSO

作者	解决问题	改进的算法或方法	年代
Kennedy J ^[2]	PSO 应用于离散问题	BPSO 算法	1997
Y. Shi ^[3]	局部极值	添加惯性系数 \dot{u}	1998
Angeline ^{[10][9]}	复杂的适应值函数	锦标赛选择算子、基于杂交概率的杂交操作	1998
Clerc M ^[7]	局部极值	速度收缩因子 \acute{a}	1999
Shi Y ^[5]	w 值线性减小的局限性	模糊规则动态修改 w 值	2001
J.Riget ^[21] 、介婧 ^[22]	种群多样性	种群多样性控制机制	2002、 2008
Kang-Ping Wang ^[27] 、 Clerc ^[26]	粒子群算法的离散化(可用于路由优化)	TSP-DPSO算法	2003 2004

曾建潮 ^[25]	整数规划问题(可用于路由优化)	将粒子位置和速度限定为整数	2004
王丽芳 ^[13]	收敛性	模拟退火算法作为收敛判据	2006
吕艳萍 ^[12]	遗传微变、种群多样性、局部极值	克隆选择、自适应调整函数、Logistic 序列	2007
Bask, S ^[19]	早熟	协同 PSO(CONPSO)	2004
邢万波 ^[18]	“Frankenstein's PSO”启发	自适应调整拓扑结构	2008
高鹰 ^[14]	收敛性、局部极值	引入免疫机制	2004

2.3.4 粒子群算法的收敛性

关于基本粒子群算法的收敛性问题，在理论上已经证明，基本微粒群算法并不能保证收敛于最优解，甚至是局部最优解^[28]。但是，文献^[29, 30]在假定 P_i 和 P_g 不变的情况下，分析了标准粒子群算法的运行轨迹和收敛性，证明了保证收敛的参数设置。尽管证明存在缺陷，但是具有重要意义。诸多的改进算法都是针对防止算法陷于局部最优或是提高算法收敛性而提出的。

2.4 路由优化

2.4.1 路由寻优

路由包含确定路径和通过网络传输信息。确定路径即让路由器找到一条到达目的地的可行路由，并沿该路径通过许多不同的网络发送数据包的过程。路由优化就提高路由选择协议选择路由的能力，使其根据度量标准(如跳数、延时等)以及度量标准所占的权值选择链路以转发数据包。

由于基于最小跳数或最小时延选择向前推进路径至目的节点的简单路由算法已经不能满足网络中带有质量要求的不断变化的流量以及不同类型的应用需求的需求，必须通过路由优化以处理网络服务提供商和用户之间的服务关系，通过路由优化，使路由算法选择满足约束条件路径将分组推至目的节点，进而可实现网络中的管理策略，性能需求，负载平衡，可量测性等要求。在尽力发送的网络体系结构种路由优化的目的是寻求一条综合性能最佳的路径来保证用户的服务质量。

1. 路由算法的决策因素

当前的路由优化主要是实现基于多约束条件对路径的智能选择，根据约束条件强调的不同因素，大致可以分为策略路由，QoS 路由，基于分组内容转发的路由等。

服务质量是网络在传输与特定QoS相关的从源到目的地的分组时，数据流对网络服务的需求的集合。QoS约束是应用数据对网络传输服务提出的一组可度量的要求，主要包括带宽、端到端延迟、分组丢失率、花费等。网络在传输相应的数据业务时，必须满足这组要求。QoS需求以通过一个约束集来描述，包括链路约束、路径约束和树约束^[31]。链路约束定义了从源到目的地的每一条链路的约束，如带宽约束；路径约束定义了从源到目的地的一条路径上端到端QoS需求，如延迟。

QoS路由就是将传统的最短路径变为一条更好的路径，其主要目标包括以下两点^[32]：

- (1)为每一个接纳的QoS业务连接请求，找到满足其QoS要求的可行路径(组播树)；
- (2)优化全局资源利用率，平衡网络负载，从而最大化网络接受其他QoS请求的能力。

QoSR 具有面向连接的特性。因为为了提供 QoS 保证，数据传输前通常需要沿着计算好的路径，从源到目的地传播一个消息，用来通知路径上的所有节点为这个 QoS 业务保留相应的资源(如带宽、缓存等)，而后续的数据传输则沿着这条已经预留了资源的路径。

优化设计 QoS 路由算法的目的就是要尽可能综合考虑多种链路度量值的约束条件，减少算法复杂度，定义准确合理的花费函数。

下面讨论路由算法的决策因素：

(1) 复杂度

路由算法应被设计成尽可能地简单，即必须以最少的开销和使用费用获得高效的功能。当路由算法由软件实现、并在物理资源受限、网络规模复杂的环境中运行，算法复杂度性能就显得尤为重要。

由于QoS路由问题要找到一条满足多个QoS条件下的最优路径问题已被证明是NP问题，就需要简化约束条件，或在多目标Pareto解集中博弈找到的全局优化解。如果将除了一类之外的所有QoS度量都限定在一个有限集上，则QoSR问题是多项式可解的^[33,44]。

(2) 花费函数

为了降低QoS路由算法的复杂度并提供更好的QoS支持，可行的方式是通过研究花费函数，从而保证所计算的最小花费路径能够满足QoS需求。例如，通过将链路花费与利用率结合，能够降低连接阻塞概率，抑制路由抖动^[35]。

(3) QoS 度量

QoS 要求需要通过可测量的 QoS 度量来实现。常用的几种 QoS 度量主要包括可用带宽、端到端延迟、分组丢失率、抖动和花费，不同的度量具有不同的性质。按照这些性质，QoS 度量可以分为可加性度量、可乘性度量和最小性度量三类。

QoS 要求需要通过可测量的 QoS 度量来实现。常用的 QoS 度量主要包括可用带宽、端到端延迟、分组丢失率、抖动和花费等，不同的度量具有不同的性质。按照这些性质，QoS 度量可以分为可加性度量、可乘性度量和最小性度量三类。对于图 G 中的路径 $P=(v_1, v_2, \dots, v_s)$ ，若 $e_{i,i+1} \in P$ (其中 $i=1, 2, \dots, s-1$)，将 $e_{i,i+1}$ 的第 j 个属性记为 $w_{i,i+1}^j$ 或 $w^j(e_{i,i+1})$ ，整个路径 P 的第 j 个属性记为 w_p^j ，则以上三类度量的定义如下^[36]：

定义 2-3 可加性度量：若 $w_p^j = \sum_{i=1}^{s-1} w_{i,i+1}^j$ ，则称路径 P 的第 j 个属性为可加性度量。

可加性度量包括延迟、抖动、花费、转发跳数等。例如，一条路径 P 的延迟为从源到目的地的所有链路延迟的总和。

定义 2-4 可乘性度量：若 $w_p^j = \prod_{i=1}^{s-1} w_{i,i+1}^j$ ，则称路径 P 的第 j 个属性为可乘性度量。

例如，分组丢失率为可加乘度量，其中链路丢失率 $0 \leq w_{i,i+1}^j \leq 1$ 。

定义 2-5 最小性度量：若 $w_p^j = \min_{i=1,2,\dots,s-1} \{w_{i,i+1}^j\}$ ，则称路径 P 的第 j 个属性为最小性度量。

例如：带宽为最小性度量，即路径带宽为路径上瓶颈链路的带宽。对于求解 $w_p^j = \max_{i=1,2,\dots,s-1} \{w_{i,i+1}^j\}$ 的问题可转化为 $-w_p^j = \min_{i=1,2,\dots,s-1} \{-w_{i,i+1}^j\}$ 问题。对于不同类型的 QoS 度量以及多个 QoS 度量的组合，其计算的代价是不同的。例如，求解多重最小性度量的组合可以在多项式时间内完成，而多重可加性度量的组合通常不能在多项式时间内完成。

(4) QoS 约束条件

对于 QoS 的研究最初主要是对不同约束的 QoS 或多个约束的 QoS 的路由选择问题，近来，研究主要转向实际中问题的优化。比如在时延最小的路径中选择带宽最大

的路径可以在网络链路上提供基本的负载均衡机制，也可以在带宽最大的路径中选择跳数最小的路径即最宽最短路径。

在实时网络中，对于时间上的任意一点，很多信道建立的条件是活动的，其目标在于找到一条从各自的源到目的节点的符合要求的路径。路由发现中的路径选择属于典型的最短路径优化问题。优化的目标是一些参数，诸如时延、带宽、代价、跳数等其他与被选路径上链路的某些参数数值之和的度量标准。QoS 路由问题就是找到一条满足一个或多个 QoS 条件下的路径。研究表明，寻找一条路径，使之满足两个或者多个加法和乘法组合的约束条件属于 NP 完全问题。

2.主要QoS度量的分析：

时延：实际链路上的时延包含了分组在节点及链路上的排队、发送和传播三部分时延。其中发送和传播时延一般依赖于路由器或交换机的性能，排队时延主要受网络拥塞状况影响，跟链路的带宽使用有关。所以需要分轻载、重载情况考虑。

带宽利用率：带宽是网络传输中最重要的资源之一，所以带宽利用率的指标就是衡量路由算法好坏的重要标准，也是提高整个网络传输性能的关键所在。网络的路由目标是最大化资源效用。

跳数：跳数是路由算法中考虑的重要因素。在其他网络属性相同条件下，选择跳数少的路由显然可以减少交换机的传送时延，提高带宽利用率，尤其在网络负载严重的情况下，能尽量减少路径所经过的交换机数量会很好的减轻网络负载压力。保证整个网络良好的收敛性，减少网络带宽的消耗

3.QoS 路由算法

QoS 路由算法是基于数据流的 QoS 需求和网络资源的可用性进行路由选择，在优化资源利用的同时，选取可用路径满足 QoS 需求。在路由过程中确定路径即选择路径是最关键的，如图 2-1 所示

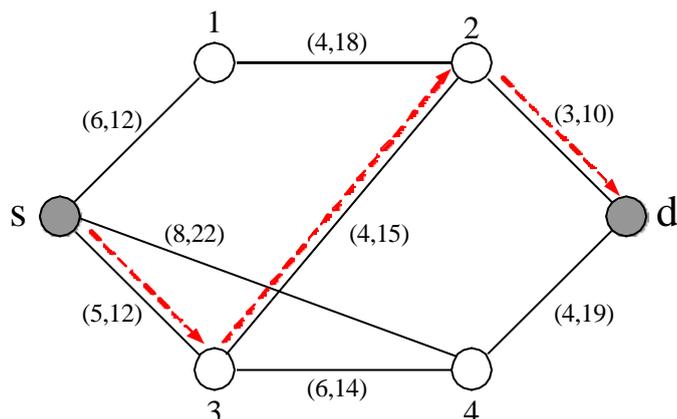


图 2-1 基于网络资源的可用性进行 QoS 路由选择

Figure 2-1 The QoS-based routing based on the serviceability of network resource

链路上的标注表示每条联路的代价与时延。例如 QoS 的目标是代价最小、时延小于等于 40，即 $C = (\text{时延} \leq 40 \text{ Cost}_{\min})$ ，由 $s \rightarrow d$ 选择路径为 $S \rightarrow 3 \rightarrow 2 \rightarrow d$ (时延=12 Cost=12)；如果代价需求改变为 $\text{Cost} \leq 13$ ，另一条路径 $S \rightarrow 1 \rightarrow 2 \rightarrow d$ 也为一条有效选择。所以在满足多个约束的 QoS 需求中，确定路径的顺序是很重要的^[37]。假设两个优化的目标分别为跳数和可用带宽，QoS 路由算法可以优先选择跳数最小的路径，也可以优先选择带宽最大的路径。

2.4.2 粒子群算法的路由优化研究进展

1. 粒子群算法的适应度函数

粒子群优化算法利用种群中每个个体的适应值在解空间中寻找最优解，因此，适应度函数作为对粒子的绩效评价，直接影响到 PSO 算法的收敛速度以及能否找到最优解。在路由优化问题中，一般把路由的花费或是代价设计成适应度函数（目标函数），但是当涉及到 QoS 约束的时候，在现有的文献中是将约束项通过罚函数转化为粒子群适应度函数的一部分。

2. 粒子群算法的编码

编码问题是将 PSO 算法成功应用到路由优化中的关键问题之一。编码问题也就是如何在解空间和粒子表示之间建立合适的映射，在路由优化中，即如何将 QoS 路由的一个路径序列编码为搜索空间中的一个解。编码的好坏直接关系到优化算法的性能和效率。在作者所能查找的文献中，大多都是采用整数编码方案，将一条链路序列映射整数空间，即用整数为所有已发现的链路进行编码，由此而确定 PSO 的搜索空间为整数空间；或者用粒子表示一条链路序列或是一棵组播树。

3. 粒子群算法的路由优化的研究进展

在现有文献中，对链路的处理情况可以分为两类：第一类，不直接对链路进行处理而是对链路的编号进行搜索，比如文献[38, 39, 40, 41]。此编码方案要求将粒子群改进成能搜索整数空间，比如文献[25]提出的应用于处理整数规划的PSO算法；第二类也就是对PSO的加减乘运算重新定义，粒子初始化为链路序列或是，以此直接对链路序列或组播树进行操作，例如文献[42, 43, 44]。下面将分别对其作简要介绍：

链路整数编码情况：在J.Liu等的文献^[38]中所提出的方法可以看作是最为基本方法，其他方法基本上都是在此基础上加以改进而成。文献[39]引进一个参数 P_L ，当 P_L 稳定下来且趋于0时，认为当前为局部最优，对粒子群重新初始化，防止算法陷于局部最优；文献[41]引进了基于粒子群位置更新阶段的概率收敛机制，粒子位置在更新之后依据一定的概率被其他值取代。

直接对链路序列或组播树处理的情况：文献[42]所提出的广播代理的方法不仅在粒子初始化阶段广播代理，并且在每代中重复执行广播代理，这样就是比增加算法的计算量；文献[43, 44]设计了特殊的操作算子对粒子群算法加以改进，使之可以对粒子位置的各维所表示的联络序列直接进行操作，使得较差路径向较优路径学习。但是，这种方法也存在缺点，即它会产生冗余搜索空间和冗余搜索，影响到算法的搜索精度和速度。

虽然一些学者将粒子群算法应用到多QoS约束路由优化中取得一定成功，显示了粒子群算法这方面应用的优越性，但是这方面的研究还是较少，往往他们都是对整数编码下的粒子引进一些特殊操作，形式较为单一以及增加了算法实现的复杂度和计算量。如何将其他改进的算法或是针对路由优化而作的改进算法较好的应用到路由优化中，以实现流量负载平衡、拥塞控制，将是未来的研究热点问题。

表 2-2 在路由优化中的粒子群算法的研究与应用

Table 2-2 The research and application of PSO in the routing optimization

作者	应用领域	采用的方法	解决问题	年代
Jing Liu ^[38]	路由优化	整数编码的基本粒子群算法	PSO 在路由优化中的应用	2006
王楷 ^[39]	Ad Hoc 路由优化	变异策略	局部最优	2006
Jun Sun ^[40]	路由优化	量子粒子群算法	将新的粒子群应用到路	2006

			由优化中	
Xi-huang Zhang ^[42]	WSN路由优化	广播代理	确保路由满足QoS要求	2006
杨明 ^[43]	选播路由优化	特殊相加和随机扰动算子	较差路径学习和局部最优	2008
Xing Jin ^[41]	QoS组播路由优化	粒子排序规则、概率收敛机制、反拥挤控制策略	粒子群的多样、早熟问题	2008

2.5 本章小结

粒子群算法在提出之时是应用在连续问题，以及以后也是多用于求解连续优化问题。但是，粒子群在不同领域的应用研究并不是完全独立的，程现出相互促进的作用，因此，对粒子群算法无论基于哪种问题改进算法的研究，都对粒子群应用到路由优化上有着积极的启示意义。并且，现有的文献显示粒子群算法在路由优化上是可行的，一些情况下，仿真结果要优于同属于进化算法的遗传算法。粒子群算法在网络路由优化方面研究刚刚起步，在该领域的研究虽然已经取得了一定的成果，只是在简化条件下对算法进行了简单的应用，在一些方面还需要加以改进和完善。

QoS路由优化的粒子群算法以下几个方面应该是其主要研究方向：算法的改进、算法收敛性分析、适应度函数设计、编码方案等。

- (1) 目前的算法改进都是针对连续优化问题，即使一些用于处理离散问题的算法，在处理路由优化时很可能没有在它原来的领域内表现的那么优秀。由于离散空间的特殊性,连续空间中的向量计算不能很好的反映粒子对应离散状态的变化,因此,基于连续空间的PSO 算法解决离散组合优化问题时存在局限。因此，为了使PSO算法在路由优化上表现出优越性，需要针对路由优化的特点而设计出一种新的PSO算法。
- (2) 粒子群算法的数学基础还是比较薄弱，尽管有些学者做了初步的研究，但还没有给出具有普遍意义的收敛性和收敛速度估计等方面的数学分析。人们并不仅仅关心PSO在路由优化中的实际表现情况，还需要了解其内在的运行机理和行为轨迹，这样势必要求对粒子群的数学基础作进一步的研究，进行更深入的收敛性分析。

- (3) 适应度函数设计的好坏直接影响算法的收敛时间和是否能够找到最优解。为了降低QoS路由算法的复杂度并提供更好的QoS支持，可行的方式是通过研究，从而在保证所计算的最小花费路径能够满足QoS需求情况下，使所设计的适应度函数的复杂度尽可能小。因此，主要的焦点就是如何将QoS约束与目标函数结合问题，即将约束优化问题转化为没有约束的单目标优化问题，而又要保证适应度函数具有较小的复杂度，是将PSO应用到路由优化中主要考虑的问题之一。
- (4) 目前，编码方案基本就是整数编码，虽然其使得粒子群成功用到路由优化中，但是，在这种方案下，粒子的表示和路径序列之间联系的还是不那么紧密，粒子还不能够直接表示路径序列，因此设计一个高效而又能较好避免产生冗余搜索的编码方案也将是一个发展趋势。

第三章 基于粒子群算法的流量均衡研究

3.1 引言

流量负载均衡研究的目的是网络可用路径能够合理的分担网络流量,避免网络拥塞,提高网络的资源利用率、网络的运行效率和网络的服务质量(QoS),其一直是网络资源管理研究中的重要内容^[45]。将生物启发机制应用于网络研究已成为当前研究的一个热点^[46],其中就包括粒子群算法。粒子群优化算法(Particle Swarm Optimization, PSO)是由James Kennedy 和Russell Eberhart 博士于1995年提出的一种基于群智能的随机全局优化技术,其源于鸟群和鱼群扑食行为的研究。粒子群算法目前在诸多领域得到应用,具有需设置的参数较少、编码简单、容易实现等优点和具有深刻的智能背景的优势。粒子群算法采用“群体”和“进化”的概念,依据个体的适应度进行操作,通过个体间的协作搜寻最优解的一种群体智能算法。

有些学者已经将粒子群算法应用于路由选择与负载均衡等问题。Li Taoshen在将粒子群算法应用到路由优化中时设计了特殊相加算子,但是这种方法存在一个缺点,即当迭代时每个粒子个体在更新位置时都需要运用深度优先的方法寻找路径,这样就算法的时间花费就特别巨大。潘达儒在算法中引入了交换、插入、删除、增量等操作算子和操作算子序列等概念,这一方法的缺点就是操作算子会产生冗余搜索和增加算法实现复杂度。本文针对以上问题,提出了将关系矩阵作为粒子群算法的编码方式,本方法可以很好的克服以上算法的缺点,采用这种编码方式无需对粒子群算法的框架结构作任何改变,只要对搜索空间作一定的限制就可以避免冗余搜索。本文将采用了关系矩阵编码的粒子群算法应用到网络的流量优化和负载均衡问题,提出了基于粒子群算法的流量均衡算法,目标为使得整个网络中的流量均衡分布在各条链路上。每个个体在数据表示上就是一个矩阵变量,它代表着对应的网络状态信息,矩阵元素的大小表示对应链路上所分担的流量大小。在粒子群算法迭代过程中,个体始终追踪全体最优个体而搜索最优值,即一种最好的网络状态解。

3.2 粒子群算法在流量均衡中的应用

3.2.1 流量均衡模型

一般情况下，令有向图 $G(V, E)$ 表示计算机网络的拓扑结构， $V = \{1, 2, \dots, n\}$ 是网络中节点集合， $1, 2, \dots, n$ 分别是网络拓扑中 n 个节点的编号， $E = \{e_{ij} | i, j \in [1, n]\}$ 是网络的有向边集合，其中 e_{ij} 为节点 i 到节点 j 的有向边， n 是网络的节点数，链路 e_{ij} 上所能承担的最大流量为 L_{ij} 。假定流量自源节点 1 经过一定的网络流向目的节点 n 。本文研究的网络拓扑图采用图 3-1 所示的网络拓扑。

定义 3-1 l_{ij} 表示链路 e_{ij} 上所分担的网络流量，则整个网络的网络流量的平均值为：

$\bar{l} = \frac{1}{m} \sum_{i,j} I_{ij} l_{ij}$ ，其中， m 为网络链路的条数， $i, j = 1, 2, \dots, n$ ， I_{ij} 满足下式 (3-1)：

$$I_{ij} = \begin{cases} 1 & \text{若存在} \\ 0 & \text{若不存在} \end{cases} \quad (3-1)$$

将负载均衡问题的均化问题转化为异化问题，所以本文以网络的流量平均值与各个链路的流量差值的绝对值之和的最小值为目标，即为下式 (3-2)：

$$\min \left\{ \sum_{i,j} |I_{ij} l_{ij} - \bar{l}| \right\} \quad (3-2)$$

假定链路 e_{ij} 不存在即 $I_{ij} = 0$ ，其链路流量应满足：

$$l_{ij} = 0 \quad (3-3)$$

对于每条链路 e_{ij} 上分担的流量应满足：

$$0 < l_{ij} \leq L_{ij} \quad (3-4)$$

对于网络中的每一个节点（除源节点 1 和目的节点 n 外），当有流量流经时都应当满足流量守恒。因此，对于网络中的第 i 节点（ $i \neq 1$ and $i \neq n$ ），当与此节点相关联的每条链路上的流量流经此节点时应当满足流量守恒：

$$\sum_j I_{ij} l_{ij} = \sum_j I_{ji} l_{ji} \quad (3-5)$$

其中, i 满足 $i \neq 1, n$ 。

对于源节点 1 和目的节点 n , 流出节点 1 和流入节点 n 流量大小应该是一样的, 即他们应该满足下式 (3-6):

$$\sum_j I_j l_j = \sum_i I_{in} l_{in} \quad (3-6)$$

其中, $i \neq n, j \neq 0$ 。

对于每一个节点, 假定不存在从自己到自己的链路, 因此, 应该满足如下条件:

$$l_{ii} = 0 \quad (3-7)$$

其中, $i = 1, 2, \dots, n$ 。

通过以上分析, 优化目标函数为:

$$\min \left\{ \sum_{i,j} |l_{ij} - \frac{1}{2m} \sum_{i,j} I_{ij} l_{ij}| \right\} \quad (3-8)$$

s.t.

$$\begin{cases} \sum_j I_{ij} l_{ij} = \sum_j I_{ji} l_{ji} & (\text{其中, } i \neq 1 \text{ and } i \neq n) \\ \sum_j I_{1j} l_{1j} = \sum_i I_{in} l_{in} & (\text{其中, } i \neq n, j \neq 1) \\ l_{ii} = 0 & (i = 1, \dots, n) \\ l_{ij} = 0 & (I_{ij} = 0) \\ 0 < l_{ij} \leq L_{ij} & (i \neq j \text{ and } I_{ij} \neq 0) \end{cases} \quad (3-9)$$

3.2.3 粒子群算法在流量均衡中的应用

1. 编码及操作符重新定义

用网络的关系矩阵表示问题的解, 粒子的位置可以表示成式 (3-10):

$$x = \begin{bmatrix} x_{11} & \cdots & x_{1n} \\ \cdots & \cdots & \cdots \\ x_{n1} & \cdots & x_{nn} \end{bmatrix} \quad (3-10)$$

相应地，粒子的速度定义为：

$$v = \begin{bmatrix} v_{11} & \cdots & v_{1n} \\ \cdots & \cdots & \cdots \\ v_{n1} & \cdots & v_{nn} \end{bmatrix} \quad (3-11)$$

其中，元素 x_{ij} 的下标 i 表示链路的起点，下标 j 表示链路的终点，其大小表示从节点 i 到节点 j 的链路 e_{ij} 上分担的流量，即是满足如下映射关系式： $x_{ij} \leftrightarrow l_{ij}$ 。因此，可以利用后面给出的适应度函数 $f(x)$ 对相应的粒子所寻找到的位置计算其适应值，并进行优劣评价。粒子群算法采用了关系矩阵作为编码方法，其迭代公式中所涉及的加减乘运算也应重新定义^[47]，各个运算符所涉及的是矩阵，因此将迭代公式中运算符定义为满足矩阵运算规则的运算。以下将给出它们的定义。

粒子群算法有速度与速度的加法和速度与位置的加法两种加法运算，因此加法的重新定义为：

$$v = v1 \oplus v2 = \begin{bmatrix} v1_{11} & \cdots & v1_{1n} \\ \cdots & \cdots & \cdots \\ v1_{n1} & \cdots & v1_{nn} \end{bmatrix} + \begin{bmatrix} v2_{11} & \cdots & v2_{1n} \\ \cdots & \cdots & \cdots \\ v2_{n1} & \cdots & v2_{nn} \end{bmatrix} = \begin{bmatrix} v1_{11} + v2_{11} & \cdots & v1_{1n} + v2_{1n} \\ \cdots & \cdots & \cdots \\ v1_{n1} + v2_{n1} & \cdots & v1_{nn} + v2_{nn} \end{bmatrix} \quad (3-12)$$

$$x' = x \oplus v = \begin{bmatrix} x_{11} & \cdots & x_{1n} \\ \cdots & \cdots & \cdots \\ x_{n1} & \cdots & x_{nn} \end{bmatrix} + \begin{bmatrix} v_{11} & \cdots & v_{1n} \\ \cdots & \cdots & \cdots \\ v_{n1} & \cdots & v_{nn} \end{bmatrix} = \begin{bmatrix} x_{11} + v_{11} & \cdots & x_{1n} + v_{1n} \\ \cdots & \cdots & \cdots \\ x_{n1} + v_{n1} & \cdots & x_{nn} + v_{nn} \end{bmatrix} \quad (3-13)$$

在迭代公式中，减法运算为位置和位置的减法运算，其运算结果为速度，因此减法的重新定义为：

$$v = x1 \ominus x2 = \begin{bmatrix} x1_{11} & \cdots & x1_{1n} \\ \cdots & \cdots & \cdots \\ x1_{n1} & \cdots & x1_{nn} \end{bmatrix} - \begin{bmatrix} x2_{11} & \cdots & x2_{1n} \\ \cdots & \cdots & \cdots \\ x2_{n1} & \cdots & x2_{nn} \end{bmatrix} = \begin{bmatrix} v1_{11} + v2_{11} & \cdots & x1_{1n} + x2_{1n} \\ \cdots & \cdots & \cdots \\ v1_{n1} + v2_{n1} & \cdots & x1_{nn} + x2_{nn} \end{bmatrix} \quad (3-14)$$

乘法的运算主要为实数和位置或速度的乘法，因此，其重新定义为：

$$p' = a \otimes p = a \begin{bmatrix} p_{11} & \cdots & p_{1n} \\ \cdots & \cdots & \cdots \\ p_{n1} & \cdots & p_{nn} \end{bmatrix} = \begin{bmatrix} ap_{11} & \cdots & ap_{1n} \\ \cdots & \cdots & \cdots \\ ap_{n1} & \cdots & ap_{nn} \end{bmatrix}, \text{ 其中, } p' \text{ 和 } p \text{ 为位置 } x \text{ 或速度 } v, a$$

为实数。

因此，重新定义操作符后的 PSO 的迭代公式为：

$$V_i(t+1) = w \otimes V_i(t) \oplus c_1 r_1 \otimes (P_i \ominus X_i(t)) \oplus c_2 r_2 \otimes (P_g \ominus X_i(t)) \quad (3-15)$$

$$X_i(t+1) = X_i(t) \oplus V_i(t+1) \quad (3-16)$$

2. 适应度函数定义

本文采用惩罚函数法处理约束问题，将约束优化问题转化为无约束优化问题^[25]。对于约束 (3-4) 可以将其作为粒子群算法的搜索边界来处理，即 $0 < x_{ij} \leq L_{ij}$ ，其中， $i, j = 1, 2, \dots, n$ ；对于约束 (3-3) 和 (3-7) 的性质和采用关系矩阵的原因，可以在关系矩阵中设置对应的元素值为零而实现约束，即通过设置 $x_{ij} = 0$ 实现 $l_{ij} = 0$ 的约束。因此惩罚函数只需考虑约束 (3-5) 和 (3-6)。根据公式 (3-9) 所设计算法的适应度函数为：

$$f(x) = \sum_{i,j} |x_{ij} - \frac{1}{m} \sum_{i,j} x_{ij}| + \mathbf{a}\Psi(|\sum_j x_{ij} - \sum_j x_{ji}|) + \mathbf{b}\Psi(|\sum_j x_{1j} - \sum_i x_{im}|) \quad (3-17)$$

其中， \mathbf{a} ， \mathbf{b} 分别为两项约束在适应度函数中所占的权重。其中， $\Psi(z)$ 是惩罚函数，其满足：

$$\Psi(z) = \begin{cases} 0 & \text{if}(z = 0) \\ r & \text{if}(z > 0) \end{cases} \quad (3-18)$$

其中， r 为一个不为零的正实数， z 为一个大于等于零的实数。当约束项不为零时由 r 决定对约束的惩罚程度， z 越大惩罚程度就越大即 r 越大。

3. 算法实现

关系矩阵中的每个元素表示对应链路上所分担的流量大小，而链路 e_{ij} 承担的能力是有限的，因此，需要首先初始化网络链路能分担的最大流量 L_{ij} ，其作为粒子群算法的搜索边界条件。当个体搜索区域超出了边界条件时即个体位置满足： $x_{ij} > L_{ij}$ ，将个体的位置在搜索区域内重新初始化，即使其满足： $0 < x_{ij} \leq L_{ij}$ ；另外，将不存在的链路对应于关系矩阵中的元素值设置为零，即： $x_{ij} = 0$ ，本文这样处理是为了尽可能减少冗余空间的产生和冗余搜索。

一般情况下，粒子群算法在迭代早期具有较强的搜索能力，就要具有较大的惯性

权重 w ；而在搜索后期算法应当在较小的局部进行搜索，即具有较强的局部搜索能力，此时惯性权重 w 应是较小值。因此，把惯性权重 w 设计成一个随着迭代次数递减的线性函数，即：

$$w = w_{\max} - \frac{t}{t_{\max}}(w_{\max} - w_{\min}),$$

其中， t_{\max} 为设置的最大迭代次数， t 为当前

迭代次数， w_{\max} 为最大惯性权重， w_{\min} 为最小惯性权重。

对粒子群个体初始化以后，粒子群算法就依据已经设置的好的参数进行循环迭代，按照适应度函数 $f(x)$ 对个体进行优劣评价并更新个体极值和全体极值，在整个迭代搜索过程中，个体始终会追寻全体最优值和个体极值在搜索区域进行搜索。为了使算法获得较优的性能，每当全局最优适应值发生变化时，把当前的最优粒子位置随机赋值。一般在粒子群进化后期容易陷入局部最优解，本文采用在进化一定代数后将粒子群的全体粒子位置重新随机赋值。在迭代结束后，粒子群算法所搜寻到的最优解就是所求的最优解，解的各个元素值就代表着对应链路上应分担的流量大小。算法的实现步骤如下：

- 1) 设置参数。包括设置算法的惯性权重、学习因子和粒子群的规模，以及网络各条链路分担的流量的最大值；
 - 2) 初始化。对每个个体的随机位置和速度进行初始话；
 - 3) 计算粒子群的每个个体适应值；
 - 4) 更新每个个体的最好位置 p_i 。对于每个个体，将其适应值与其所经历过的最好位置的适应值进行比较，若较优，则更新最好位置；
 - 5) 更新全局最优位置 p_g 。对于每个个体，将其适应值与全局所经历的最好位置的适应值进行比较，若较好，则将其作为当前的全局最好位置。
 - 6) 根据式 (3-9) 和(3-10)对个体的速度和位置进行进化；
 - 7) 循环条件判断。若未达到足够好的适应值或达到预设最大代数 t_{\max} ，则返回 3)；
- 若算法找到较优的解或达到最大的迭代次数，则终止循环输出最优解。

3.3 仿真实验与结果分析

试验环境采用PC机 (Pentium IV 2GHz CPU, 1G内存)、Windows XP、VC++ 2008。

在仿真实验中采用的网络拓扑结构如图1所示，共有9个节点构成，对节点从0依次编号，圆圈内数字为节点编号。设置粒子群规模为60，学习因子 c_1, c_2 设置为1.8。为了使粒子群算法在早期具有较强的探索能力，在后期能快速收敛，将惯性系数设计成从最大值 $w_{max} = 2.0$ 线性递减到最小值 $w_{min} = 1.0$ ，并且增加了 $w = 1.0$ 和 $w = 2.0$ 的对比试验。

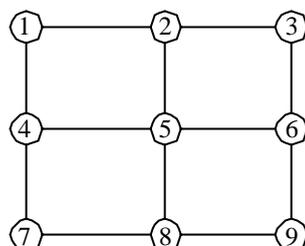


图 3-1 网络拓扑图

Figure 3-1 Network topology

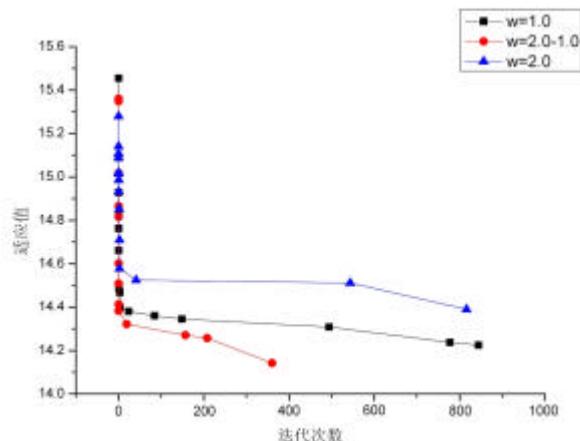


图 3-2 迭代次数-适应值

Figure 3-2 Iterations- Adaptive value

图 3-2 为迭代次数和适应值之间的关系图，从图 3-2 中可以看出，采用惯性系数递减的算法在 300 次和 400 次迭代次数之间就能够终止迭代，并且获得了较优的适应值，因此与采用常量的惯性系数相比，采用递减的惯性系数可以获得较好的实验结果：在较小的迭代次数内，获得较优的适应值。在图 3-3 中，节点连线上标注的数字表示此链路上分担的流量大小，显示了最终的链路流量分担结果，可以看出，各链路的流量分布能够取得相对均衡的状态，算法获得了较优的结果。本文另外通过 Transit-Stub 模型^[48]随机生成节点数分别为 10、100、200、...、1000 的网络拓扑结构，分别运行本文算法，图 3-4 显示了他们分别能够找到最优解所需要的迭代次数。可以从图 3-4 中看出在节点数小于 1000 时，迭代次数会随着网络拓扑的节点数增加而增加，但是这种变化

较为缓慢，即网络节点数小于 1000 时本文算法是有效的。从图 3-2 和图 3-4 可以看出，粒子群算法在处理负载均衡问题的时间花费较少。

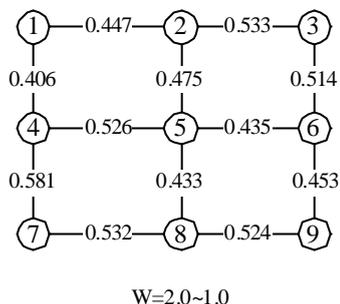


图 3-3 流量分担结果

Figure 3-3 Share results of Flow

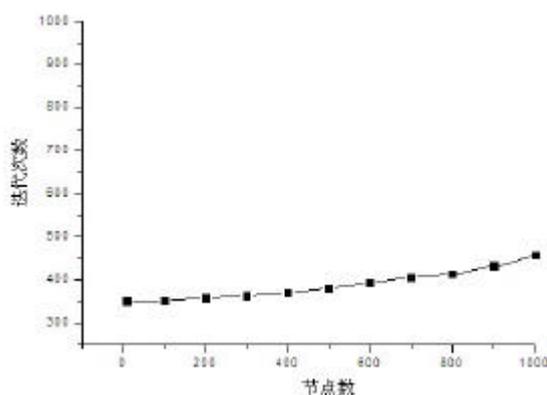


图 3-4 迭代次数-网络节点

Figure 3-4 iterations- Network nodes

3.4 结论

针对网络流量负载问题，本文采用关系矩阵作为粒子群算法的编码方式，并将基于这种编码方法的粒子群算法尝试性的应用到网络的流量优化中，以求网络流量在网络链路上的相对均衡分布。从仿真实验结果看，采用关系矩阵编码的粒子群算法取得了较好的链路流量负载分担效果，因此，这种方法为粒子群算法解决网络流量负载均衡问题提供了一种新思路，对于以后粒子群算法在负载均衡问题上更好的应用具有一定的启发意义。

第四章 基于粒子群算法的路由优化算法

4.1 引言

随着计算机网络应用的发展,人们对网络所提供的延迟带宽等能力的要求越来越高。现有的Internet路由基于目的IP地址逐跳寻路(hop by hop)是以时延为标准的最小时延路径。多约束路由选择是指在网络中寻找一条满足传输带宽、链路时延、时延抖动和信息丢失率等约束条件并使通信费用最小的路径。多约束路由选择是一个NP完全问题。

将采用关系矩阵编码的粒子群算法应用于QoS约束单播路由选择中,利用粒子间信息共享与相互协作来找寻网络中的最优路由,以路由的总花费作为度量标准,QoS作为约束条件,来对路由的选择进行控制。仿真结果显示该算法应用于QoS路由优化及选择时要优于遗传算法。

4.2 数学模型

本文仅讨论QoS约束单播路由问题并且是基于源点计算,其网络拓扑图可以描述为一个无向连通图 $G=(V)E$,其中, V 为网络中所有网络节点集合, E 为任意两相邻节点 i, j 之间的链路边 e_{ij} 集合, $i, j \in 1, \dots, n$, n 表示网络的节点数。QoS约束单播路由就是要在指定的源节点 s 和目的节点 t 之间寻找一条目标值最优的路径 P_{st} (s 和 t 分别是源节点和目的节点的编号),使路径的花费最小,同时满足以下QoS约束:

- (1) P_{st} 的可用带宽不小于带宽要求 B_w ;
- (2) P_{st} 的延迟不大于延迟要求 D 。

由此可得QoS约束的单播路由的数学模型:

$$\begin{aligned} & \min \sum_{e_{ij} \in P_{st}} c_{ij} \\ & s.t. \end{aligned} \quad (4-1)$$

$$\begin{cases} \min_{e_{ij} \in P_{st}}(B_{ij}) \geq B_w \\ \sum_{e_{ij} \in P_{st}} D_{ij} \leq D \end{cases}$$

其中， c_{ij} 表示链路 e_{ij} 上的花费。

本文通过定义一个罚函数^[25] $Q(P_{st})$ 将约束优化问题转化为无约束优化问题进行求解，这样应用起来比较方便。因此，本文所讨论的约束优化目标问题转化为无约束优化，即为下式 (4-2) 表示：

$$\min \left\{ \sum_{e_{ij} \in P_{st}} c_{ij} + Q(p_{st}) \right\} \quad (4-2)$$

其中，罚函数 $Q(P_{st})$ 表示为下式 (4-3)：

$$Q(p_{st}) = g \left\{ B_w - \min_{e_{ij} \in P_{st}}(B_{ij}) \right\}^2 + h \left\{ \sum_{e_{ij} \in P_{st}} D_{ij} - D_{req} \right\}^2 \quad (4-3)$$

需要说明的是，当满足某条 QoS 约束时，式 (4-3) 中罚函数对应的项为 0，此外，系数 g 和 h 的取值要合理，以使式 (4-3) 等号右边的各项在数值上处于同一数量级，并且总和应与式(4-2)及式 (4-3) 的目标处于同一数量级。

由优化目标函数本文可以直接定义算法的适应度函数，它可以表示成下式 (4-4)：

$$f(x) = \sum_{e_{ij} \in P_{st}} c_{ij} + Q(p_{st}) \quad (4-4)$$

4.3 基于粒子群算法的路由算法

4.3.1 编码

设网络中的节点数是 n ，在所构建的网络中的每个节点都有一个在 1 到 n 之间的对应的独立编号。由网络的节点数 n 可知，这个矩阵是一个 $n \times n$ 的方阵，用一个具有大于

或等于零的元素的二维关系矩阵 $x = \begin{pmatrix} x_{11} & \dots & x_{1n} \\ \dots & \dots & \dots \\ x_{n1} & \dots & x_{nn} \end{pmatrix}$ 来表示网络的拓扑结构信息，矩阵

中元素 x_{ij} 的值大小表示链路 e_{ij} 被选中的概率，其值越大表示链路被选中的概率越大，若为 0 则表示在网络中不存在此条链路，下标值 i 表示链路起始节点， j 表示链路的终止节点。

采用关系矩阵编码方式后应当与3.2.3一样，对粒子群算法操作符重定义，其迭代公式参考3.2.3如下：

$$V_i(t+1) = w \otimes V_i(t) \oplus c_1 r_1 \otimes (P_i \ominus X_i(t)) \oplus c_2 r_2 \otimes (P_g \ominus X_i(t)) \quad (4-5)$$

$$X_i(t+1) = X_i(t) \oplus V_i(t+1) \quad (4-6)$$

定义4-1 集合K称作一个路由 P_{st} 的节点序列，若 $K = \{s, K_1, \dots, K_k, t\}$ ，其中， k 为路由序列的节点数， K_i ($K_i \in \{1, 2, \dots, n-2\}, i \in \{1, 2, \dots, k\}$) 是路由节点序列的第 i 个节点。

由定义4-1我们知道，采用关系矩阵编码方法时必须将位置矩阵 x 映射为路由序列节点集合K，这样才能使用粒子群算法进行路由寻优。即为式 (4-7)：

$$\begin{pmatrix} x_{11} & \dots & x_{1n} \\ \dots & \dots & \dots \\ x_{n1} & \dots & x_{nn} \end{pmatrix} \rightarrow \{s, K_1, \dots, K_k, t\} \quad (4-7)$$

4.3.2 路由策略

在采用关系矩阵的编码方法中，矩阵中的列需要标记为是否已经被选择了，因此采用一个一维数组来标记矩阵中的列是否已经被选择了。另外，由定义4-1知道关系矩阵需要映射为路径节点序列，因此应使用一个数组来存储路径的节点序列。在将关系矩阵映射为路径节点序列时，首先将所有的列都标记为“未选择”，然后按照相应规则处理矩阵中的相应行，选择未被其他行选择过的并且具有最大值的那个元素，然后将这个元素所在的列标记为“选择”，并且该列的列号值被插入到路径数组中，表示在本行中选择序号为该列号的节点。这样就可以从路径数组中得到解路径以及解路径的费用值。

采用这种方法能够保证最终得到QoS路由的可行解。例如，首先将起始节点 s 加入路径，并将矩阵第 s 列标记为已选择。然后找到第 s 行中的最大且不为零的元素 x_{sj} ，因此应将列号值 j 加入路径并且将第 j 列标记为已选择，然后在第 j 行标记为未被选择的列中选择一个最大的元素 x_{jh} ，将 h 加入路径列表并且将第 h 列标记为已选择，依次

类推直至目的节点 t 而得到整个路由。当不能到达目的节点 n 时在更新粒子个体位置时其位置将不做更新处理。

定义4-2 位置矩阵的适应值就是由该位置矩阵映射为路由的费用。即本文按照式(4-4)来计算路由所得到的适应值大小就是该路由所对应的位置矩阵的适应值。

4.3.3 初始化

由4.3.1节知道，对于位置 $x = \begin{pmatrix} x_{11} & \dots & x_{1n} \\ \dots & \dots & \dots \\ x_{n1} & \dots & x_{nn} \end{pmatrix}$ 中的元素值表示所对应的链路被选择的

概率，因此，对于位置矩阵随机赋值并且每次迭代后都应当满足如下关系式(4-8)：

$$\begin{cases} \sum_{j=1}^n x_{ij} = 1, & i = 1, 2, \dots, n \\ x_{ij} = 0, \text{ 如果不存在} \\ x_{ij} \in (0, 1] \end{cases} \quad (4-8)$$

每经过一次迭代过程，每个粒子位置都有可能违反上面的位置约束条件，因此应该以下式(4-8)变换矩阵：

$$\begin{pmatrix} x_{11} & \dots & x_{1n} \\ \dots & \dots & \dots \\ x_{n1} & \dots & x_{nn} \end{pmatrix} \rightarrow \begin{pmatrix} x_{11} / \sum_{j=1}^n x_{1j} & \dots & x_{1n} / \sum_{j=1}^n x_{1j} \\ \dots & \dots & \dots \\ x_{n1} / \sum_{j=1}^n x_{nj} & \dots & x_{nn} / \sum_{j=1}^n x_{nj} \end{pmatrix} \quad (4-8)$$

对于速度 $v = \begin{bmatrix} v_{11} & \dots & v_{1n} \\ \dots & \dots & \dots \\ v_{n1} & \dots & v_{nn} \end{bmatrix}$ 中的元素值随机赋值并且每次迭代后都应当满足如下关

系(4-9)：

$$\sum_{j=1}^n v_{ij} = 0, i = 1, 2, \dots, n \quad (4-9)$$

对于速度 v 应当满足式(4-9)是由位置限制条件(4-7)和迭代公式(4-6)决定的，因为对于(4-6)的计算结果要求满足(4-7)此时必然要求速度 v 满足(4-9)。

4.3.4 算法描述

对于网络中节点的表示，本文所设计算法对每一个网络节点依次进行编码，即若有 n 个节点，则给每个节点分配一个在1到 n 之间不重复的编号，以此来对应于表示节点被路由选择情况的矩阵中的元素，这样克服编码操作所带来的负面影响。

假设有 M 个粒子的粒子群在搜索空间进行搜索，其最大的迭代次数为 t_{\max} ，网络节点数量为 n 。那么，将此算法应用于网络中的具体步骤如下：

步骤1：初始化。

步骤1.1：设定种群的规模 M 以及最大的迭代次数 t_{\max} 。

步骤1.2：采用上述的初始化过程，对每个粒子 i 得到一个随机的初始位置 X_i 以及一个随机的初始速度 V_i ，局部最好解 $P_i = X_i$ ，全局最好解 P_g 是所有 P_i 中最好的。

步骤2：对于粒子群所有个体，计算每个粒子个体的位置和速度。

步骤2.1：根据速度更新公式（4-5）计算下一代的速度。

步骤2.2：根据位置更新公式（4-6）计算下一代的位置。

步骤2.3：对新位置按照路由策略计算位置的适应值。如果新位置的适应值比当前局部最好解的适应值还要小，则用新的位置更新当前的局部最好解。

步骤3：假若有粒子的局部最优解优于当前的全局最优解和其他粒子的局部最优解，则用此局部最优解更新当前的全局最优解。

步骤3：如果当前迭代的次数等于最大迭代次数，转步骤4，否则转步骤2。

步骤4：输出求得的最好解路径。

4.4 仿真实验与结果分析

本文采用基于源路由的路由选择机制，即在仿真网络中的源节点需要维护全局网络拓扑结构及其状态参数，基于此网络拓扑及其状态参数，在源端进行计算并确定路由。边链路由三元组 $[C, B_w, D]$ 描述，其中 D, B_w, C 分别表示开销、带宽和延时。用于仿真实验的网络拓扑图如图4-1表示：

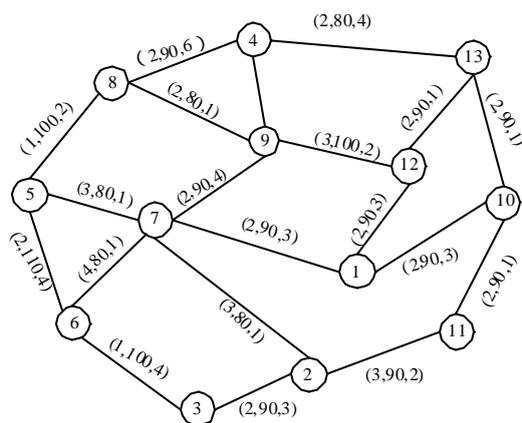


图 4-1 网络结构拓扑图

Figure 4-1 Network topology structure

对于此网络拓扑结构，节点个数 n 为13，因此粒子群个体编码为 13×13 的矩阵，在此，路由请求为 $R=[3,5,60,14,12]$ ，其中，其数据结构为 $R=[源节点, 目标节点, 请求带宽, 时延, 代价]$ 。在本仿真实验中试验环境采用PC机（Pentium IV 2GHz CPU，1G内存）、Windows XP、VC++ 2008。设置粒子群算法的参数为：惯性权重 w 从2.0随迭代次数递减到0.8，学习因子 c_1 和 c_2 统一设置为2.0，最大迭代次数 t_{max} 设置为200。容易知道适应值越小表示所找到的解越好，表4-1是本算法的路径寻优结果，从图4-1中可以很容易计算出最优路径应该是 $3 \rightarrow 6 \rightarrow 5$ ，而本算法的寻优结果也是 $3 \rightarrow 6 \rightarrow 5$ ，表明本算法能够寻找到最优解，即采用关系矩阵编码的粒子群算法能够应用到路由优化问题上，并能很好的解决路由问题。另外，我们从表中看到，最优解所对应的费用是最小值，而延迟不是最小值，这就表明QoS度量值之间不存在共同的最小点。

表 4-1 PSO 路径寻优结果

Table 4-1 The path optimization results of PSO

迭代结果	路径	费用	延迟	跳数	适应值
1	$3 \rightarrow 6 \rightarrow 7 \rightarrow 5$	8	9	4	1065.3
2	$3 \rightarrow 2 \rightarrow 7 \rightarrow 5$	8	8	4	1032.2
3	$3 \rightarrow 6 \rightarrow 5$	2	9	3	762.6

表 4-2 PSO 与 GA 算法的比较

Table 4-2 The performance comparison between PSO and GA

算法	成功率	平均迭代次数
PSO	86%	151
GA	73%	168

为了方便对比实验，我们将文献[49]中的适应度函数采用本论文所设计的函数，对于遗传算法（Genetic Algorithm, GA）的参数设置仍按照原文献中的参数进行设置，即：编码长度为 169，群体规模为100，交叉概率为0.95，变异概率为0.03，在相同的实验环境下分别对两种算法各重复运行100次。表4-2是本文算法与遗传算法的比较结果。表4-2中的成功率表示算法成功找到最优解的次数与算法重复运行的次数之间的比率。从表4-2可以看出，本文算法在搜索到最优解的成功率要比遗传算法要较高，在平均迭代次数上也要比GA若小。因此，表4-2表明本文算法要比遗传算法较为有效和具有比遗传算法较小的时间花费。

4.5 本章小结

本文提出的基于关系矩阵编码的粒子群算法应用到具有NP完全问题性质的QoS单播源路由问题，仿真实验显示能够成功找到问题的最优解，并且寻优结果上要优越于GA算法，仿真结果表明粒子群算法能够应用具有离散性质的路由优化问题上，并且是切实可行的，因此，本文为解决QoS单播路由问题提供了一种新的方法。

第五章 总结与展望

5.1 总结

粒子群算法作为一种解决优化问题的方法虽然研究的时间不长，但是由于其自身所具有的优点和特性，专家学者们在如何改进方面以克服粒子群算法自身缺点做了研究，并将粒子群算法应用到神经网络训练、参数优化、组合优化等具体的领域，得到了一定的研究成果。从事网络优化研究的学者们同时也将粒子群算法网络研究中，比如路由优化、网络流量优化、网络工作调度和旅行商问题等领域，并取得了一定成果。尽管如此，粒子群算法无论是在理论研究上还是在实际应用中还存在着一定的不足。

针对网络流量负载问题和具有 NP 完全问题性质的 QoS 单播源路由问题，本文采用关系矩阵作为粒子群算法的编码方式，并将采用这种编码方式的粒子群算法尝试性的应用到此类问题中。从实验结果显示看，采用关系矩阵编码的粒子群算法取得了较好的实验效果。本文为粒子群算法解决网络网络问题提供了一种新思路和新方式，并且具有一定的启发意义。

5.2 展望

5.2.1 粒子群算法

它是学者们受自然界中鱼群和鸟群的觅食行为的启发而得出的优化算法，虽然它比提出之初要完善了很多，但是还需要对粒子群的行为特性还有待进一步的研究，以发现粒子群更多的智能行为，学者们根对粒子群算法的改进只是在现有掌握的粒子群知识的基础上对算法的改进，并且这些改进都是针对某些具体的问题，所以这些改进不具有广泛性，只能解决一部分问题，所以如何提出一种更具广泛性的模型来解决所有的优化问题也同样是亟待解决的问题。

5.2.2 粒子群算法在路由优化中的进一步研究

由于网络的路由设备的路由性能直接影响着网络性能，所以服务质量路由（QoS Routing）是当今网络技术领域的一个研究热点问题。专家学者们把粒子群算法应用到

路由优化中寻找最优路径并通过仿真实验证明能够得到最优解。但是，由于不同的网络结构其约束条件不同，如何统一约束条件限制，如何规范约束条件标准以寻找最优路径是当前研究的一个热点。另外，粒子群算法虽然能够找到最优路径，但是，由于不同的拓扑结构和网络节点对粒子群算法寻找最优路径的时间影响很大，如何提高粒子群算法的寻优效率，缩短寻优时间，也是当前亟待解决的重要研究课题。

本文在如何将粒子群算法应用到路由优化和流量负载均衡上做了一些研究工作。在已有的工作基础上，进一步的研究工作包括一下几个方面：

1. 采用关系矩阵的粒子群算法应用到网络负载均衡问题上，快速分配网络上各条链路上所分担的流量大小，以使网络流量负载的均衡分担。
2. 采用关系矩阵的粒子群算法应用到路由优化中，并采取特殊映射方法，将关系矩阵映射为路由路径。

由于作者的水平有限，论文中存在一些不足之处，敬请各位专家和老师批评指正，提出宝贵意见。

参考文献

- [1] Kennedy J, Eberhart R C. Particle swarm optimization[A]. Proc IEEE International Conference on Neural Net-works, IV .Piscataway, NJ: IEEE Service Center, 1995: 1942-1948.
- [2] Kennedy J, Eberhart R C. A discrete binary version of the particle swarm algorithm[C]. Proc. the World Multiconference on Systemics, Cybernetics and Informatics, IEEE Press, 1997: 4104-4109.
- [3] Shi Y, Eberhart R C. A modified particle swarm optimizer [C]. IEEE World Congress on Computational Intelligence, 1998: 69-73.
- [4] Wang Z, Crowcroft J. Quality of service routing for supporting multimedia application. IEEE Journal on Selected Areas in Communication, 1996, 14(7): 1228-1234.
- [5] Shi Y, Eberhart R C. Fuzzy adaptive particle swarm optimization[C]. Proceedings of the IEEE Conference on Evolutionary Computationa, Seoul, Korea, 2001: 101-106.
- [6] 胡建秀, 曾建潮. 微粒群算法中惯性权重的调整策略[J], 计算机工程. 2007, 33(11): 193-195.
- [7] Clerc M. The swarm and the queen:Towards a deterministic and adaptive particle swarm optimization [C]. Proc. 1999 Congress on Evolutionary Computation, Washington, DC, 1999: 1951-1957.
- [8] Clerc M, Kennedy J. The particle swarm-explosion, stability, and convergence in a multidimensional complex space [J]. IEEE Transactions on Evolutionary Computation, 2002, 6(1): 58-73.
- [9] Angeline P. J. Using selection to improve particle swarm optimization[R]. 1998. Anchorage , Alaska , USA.IEEE International Conference on Evolutionary Computation. 1998: 84-89.
- [10] Angeline, Peter J. Evolutionary optimization versus particle swarm optimization: philosophy and performance differences[C]. In:Evolutionary Programming VII, 1998: 601-610.
- [11] 李宁, 刘飞, 孙德宝. 基于带变异算子的粒子群优化算法的约束布局研究[J]. 计

- 计算机学报. 2004, 27(7): 897-903.
- [12] 吕艳萍, 李绍滋, 陈水利, 等. 自适应扩散混合变异机制微粒群算法[J]. 软件学报. 2007, 18(11): 2740-2751.
- [13] 王丽芳, 曾建潮. 以模拟退火算法为收敛判据的混合微粒群算法[J]. 计算机工程与科学. 2006, 28(5): 77-79.
- [14] 高鹰, 谢胜利. 免疫粒子群优化算法[J]. 计算机工程与应用. 2004, 40(6): 4-6.
- [15] Suganthan P N. Particle swarm optimiser with neighbourhood operator [C]. Proceedings of the 1999 Congress on Evolutionary Computation. Piscataway, NJ:IEEE Service Center, 1999: 1958-1962.
- [16] J Kennedy , R. Mendes. Topological Structure and Particle Swarm Performance. Proceedings of the Fourth Congress on Evolutionary Computation (CEC-2002), IEEE Computer Society, 2002: 1671-1676.
- [17] Mendes R, Kenedy J. The Full Informed Particle Swarm: Simpler, Maybe Better[J]. IEEE Transactions on Evolutionary Computation, 2004,8(3): 204-210.
- [18] 邢万波, 杨圣奇, 王树平, 陈文杰. 一种改进的自适应邻域粒子群优化算法[J]. 计算机应用. 2008, 28(12): 3055-3088.
- [19] Bask S , Suganthan P N . A Novel Concurrent Particle Swarm Optimization[C] . Proceedings of the 2004 Congress on Evolutionary Computation. Piscataway, NJ: IEEE Press, 2004: 792-796.
- [20] Parsopoulos K.E, Vrahatis M N. Particle Swarm Optimization method in multiobjective problems, Proceedings ACM Symposium on Applied Computing (SAC 2002), 2002: 603-607.
- [21] J Riget, Jakob S. Vesterstrom. A Diversity-Guided Particle Swarm Optimizer-the ARPSO[OL]. [http://citeseer.nj.nec.com/riget02diversity guided.html](http://citeseer.nj.nec.com/riget02diversity%20guided.html), 2002-02.
- [22] 介婧, 曾建潮, 韩崇昭. 基于群体多样性反馈控制的自组织微粒群算法[J]. 计算机研究与发展. 2008, 45(3): 464-471.
- [23] Zeng Jianchao, Cui Zhihua. A guaranteed global convergence particle swarm optimizer [J]. Journal of Computer Research and Development, 2004, 41(8): 1333-1338.
- [24] 沈林成, 霍霄华, 牛轶峰. 离散粒子群优化算法研究现状综述[J]. 系统工程与电

- 子技术. 2008, 30(10): 1986-1994.
- [25] 曾建潮, 介婧, 崔志华. 微粒群算法 [M]. 北京: 科学出版社, 2004-05.
- [26] Clerc M. Discrete particle swarm optimization[M]. In:Onwubolu G C,Babu B V.New Optimization Techniques in Engineering. Springer-Verlag, 2004: 219-240.
- [27] KangPing Wang, Lan Huang, Chun-Guang Zhou, etl. Particle Swarm Optimization for Traveling Salesman Problem[C]. Proceedings of the 2nd International Conference on Machine Learning and Cybernetics, Xi'an, 2003: 1583-1585,
- [28] F van Den Bergh. An Analysis on Particle Swarm Pptimizer:[D]. University of Pretoria, 2001.
- [29] 姚耀中, 徐如玉. 粒子群优化算法分析[J]. 哈尔滨工程大学学报. 2008, 28(11): 1242-1246.
- [30] 窦全胜, 周春光,马铭. 粒子群优化的两种改进策略[J]. 计算机研究与发展. 2005, 42(5): 897-904.
- [31] Lee W.C, Hluchyi M.G., Humblet P.A. Routing subject to quality of service constraints integrated communication networks [J]. IEEE Network, 1995, 9(4): 46-55.
- [32] Yaghmaei M, Baradaran M., Talebian H. A Fuzzy QoS Routing Algorithm for communication networks [C]. 2006 10TH IEEE SINGAPORE INTERNATIONAL CONFERENCE ON COMMUNICATION SYSTEMS. 2006: 275-279.
- [33] Yuan X. On the extended Bellman-Ford algorithm to solve two-constrained quality of service routing problems[C]. Park, E.K., ed. Proceedings of the 8th International Conference on Computer Communications and Networks (IC3N' 99). Boston, MA: IEEE Communication Society, 1999: 304-310.
- [34] Chen S, Nahrstedt K. On finding multi-constrained paths [C]. Proceedings of the IEEE International Conference on Communications (ICC' 98). Atlanta: IEEE Communication Society, 1998: 874-879.
- [35] Shaikh A, Rexford J, Shin K.G.. Evaluating the impact of stale link state on quality-of-service routing[J]. IEEE/ACM Transactions on Networking, 2001, (9): 162-176.
- [36] Wang B, Hou J C. Multicast routing and its QoS extension: problems, algorithms, and protocols[J]. IEEE Network, 2000, 14(1): 22-36.

- [37] Younis Ossama, Fahmy Sonia. Constraint-Based Routing in the Internet: Basic Principles and Recent Research [J]. IEEE Communications Surveys and Tutorials, 2003, 5(1): 2-13.
- [38] Jing Liu, Jun Sun, Wenbo Xu. QoS Multicast Routing Based on Particle Swarm Optimization[C]. E. Corchado et al. (Eds.): IDEAL 2006, LNCS 4224, 2006: 936-943.
- [39] 王楷, 肖诗松, 赵锦元. Ad Hoc 网络中基于粒子群优化的 QoS 多播路由研究[J]. 微电子学与计算机. 2006, 23(9): 41-43.
- [40] Jun Sun, Jing Liu, Wenbo Xu. QPSO-Based QoS Multicast Routing Algorithm[C]. Springer-Verlag Berlin Heidelberg 2006. Wang et al. (Eds.): SEAL 2006, LNCS 4247, 2006: 261-268.
- [41] Xing Jin, Lin Bai, Yuefeng Ji, Yongmei Sun. Probability Convergence based Particle Swarm Optimization for Multiple Constrained QoS Multicast Routing[C]. Fourth International Conference on Semantics, Knowledge and Grid.2008: 412-415.
- [42] Xihuang Zhang, Wenbo Xu. QoS Based Routing in Wireless Sensor Network with Particle Swarm Optimization. Z. Shi and R. Sadananda (Eds.): PRIMA 2006, LNAI 4088, 2006: 602-607.
- [43] 杨明, 李陶深. 一种基于粒子群优化的多 QoS 约束选播路由算法[J]. 微电子学与计算机. 2008, 25(9): 43-49.
- [44] 潘达儒, 杜明辉. 基于粒子群优化的 QoS 组播路由算法[J]. 计算机工程与应用. 2006, 42(1): 138-140.
- [45] Rong B, Bennani M, Kadoch M, et al. Traffic engineering extension for traditional QoS multicast routing algorithms[C]. IEEE ICC' 05. [S.l.]: IEEE Press, 2005: 208-212.
- [46] Analoui M, Jamali S. A conceptual framework for bio-inspired congestion control in communication networks[C]. Proceedings of the 1st international conference on Bio inspired models of network, information and computing systems. New York: ACM Press, 2006: 1-5.
- [47] 庞巍, 王康平, 周春光, 等. 模糊离散粒子群优化算法求解旅行商问题. 小型微型计算机系统. 2005, 26(8): 1331-1334.
- [48] Calvert K I, Doar M B, Zegura E W. Modeling internet topology[J]. IEEE

Communications Magazine. 1997, 35(6): 160-163.

- [49] 何小燕, 费翔, 罗军舟, 吴介一. Internet 中一种基于遗传算法的 QoS 路由选择策略[J].计算机学报. 2000, 23(11): 1171-1178.

致谢

在论文完成之际，特向我的导师史健芳教授、秦勇教授致以真挚的谢意。我今天的成绩是和导师的悉心关怀和精心指导分不开的。

在攻读硕士学位的三年时间里，导师在学业上给予了耐心的指导，使我顺利完成了研究生阶段的学习。尤其是秦勇导师渊博的知识、严谨的治学风范、积极的人生态度、勤奋工作和无私的奉献精神使我深受启迪；其实事求是的科研精神、不断开拓创新的学术思维和高度的责任感使我终生受益；其正直、善良与风趣幽默的谈吐给我留下了深刻印象。从尊敬的导师身上，我不仅学到了扎实、宽广的专业知识，也学到了做人的道理。在此，谨向秦老师表示我崇高的敬意和衷心的感谢！

感谢茂名学院网络中心老师，在研究生最后阶段的学习生活中给我有益的指导和帮助，他们的指导和帮助使我扩大了眼界、丰富了知识，获得了许多宝贵的经验，所有这些都使我受益匪浅。

感谢太原理工大学和茂名学院关心支持我的老师、同学们，他们给我很多重要的学习意见和建议，对我的研究工作起了很大的帮助。

最后，感谢我的家人和朋友，在我漫长的求学生涯中所给予的关怀和帮助。感谢所有关心和帮助过我的人。

攻读学位期间发表的学术论文目录

- [1] 宋继光, 秦勇, 史健芳等. 粒子群算法及其在路由优化中的研究进展. 计算机工程与设计 (2010-5 第 9 期 中文核心)
- [2] 秦勇,梁本来,贾云富,宋继光. 多重链路网络中基于 QPAS 的并行算法的研究.南京理工大学学报(自然科学版), 2009,33(5):632-637. (EI 索引号: 20094912531537)
- [3] 蔡昭权,宋继光,秦勇. 约束集并行 QoS 选择机制及负载平衡方法.华中科技大学学报(自然科学版).2010,38(2):16-20. (EI 源刊)
- [4] 秦勇, 宋继光, 蔡昭权等. 基于关系矩阵编码的粒子群负载均衡算法研究. 计算机应用与软件 (已录用 中文核心)