

基于泛化竞争和局部渗透机制的 自组织网 TSP 问题求解方法

张军英 周 斌

(西安电子科技大学计算机学院 西安 710071)

摘 要 旅行商问题(TSP)是组合优化中最典型的 NP 完全问题之一,具有很强的工程背景和应用价值.文章在分析了标准 SOM(Self-Organizing Map)算法在求解 TSP 问题的不足和在寻求总体最优解的潜力的基础上,引入泛化竞争和局部渗透这两个新的学习机制,提出了一种新的 SOM 算法——渗透的 SOM(Infiltrative SOM, ISOM)算法.通过泛化竞争和局部渗透策略的协同作用:总体竞争和局部渗透并举、先倾向总体竞争后倾向局部渗透、在总体竞争基础上的局部渗透,实现了在总体路径寻优指导下的局部路径优化,从而使所得路径尽可能接近最优解.通过对 TSPLIB 中 14 组 TSP 实例的测试结果及与 KNIES、SETSP、Budinich 和 ESOM 等类 SOM 算法的比较,表明该算法既简单又能使解的质量得到很大提高,同时还保持了解的良好稳健特性.

关键词 TSP 问题;组合优化;自组织映射;全局优化;总体优化;局部优化

中图法分类号 TP18

Self Organizing Map with Generalized and Localized Parallel Competitions for the TSP

ZHANG Jun-Ying ZHOU Bin

(School of Computer Science and Engineering, Xidian University, Xi'an 710071)

Abstract As one of the most typical NP-complete combinational optimization problems, TSP (Traveling Salesman Problem), which has a diversity of applications in real world, has attracted extensive research interest. Recently, Self-Organizing Map(SOM) based approaches to this problem has been paid great attention for its simplicity and novelty. By analyzing drawbacks of standard SOM algorithm for solving TSP problem, it was found that the standard SOM has a great potential for finding overall optimal solution rather than globally optimal solution for a TSP problem. Based on this, the paper proposes a new SOM algorithm for solving TSP problem, the infiltrative SOM(ISOM), by introducing two new learning schemes, competition generalization and local infiltration. By the collaboration of the two learning schemes in that both the schemes work together in the whole learning process and initial learning focuses more on overall optimization, which is conducted by the competition generalization, while the afterward learning focuses more on local optimization, which is conducted by the local infiltration, the near-optimal solution is much more easy to be found. Experiments on public TSPLIB data show that not only the quality of the solutions is higher, but also the solutions are more robust, by the proposed method compared with those by several typical SOM-based methods such as the KNIES algorithms, the

SETSP, the SOM developed by Budinich, and the ESOM.

Keywords traveling salesman problem; combinational optimization; self-organizing map; global optimization; overall optimization; local optimization

1 引言

作为在 VLSI 芯片设计^[1]、网络路由^[2-3]、车辆选路^[4]等领域有着广泛应用的旅行商问题(Traveling Salesman Problem, TSP)^[5], 是 NP 完全问题中的最为典型的问题^[6]. 解决它对于解决所有 NP 完全问题具有重要的理论意义^[7], 所以长期以来一直吸引着众多领域的研究人员对其进行研究和算法改进. TSP 问题要求找到经过每个城市、每个城市只经过一次且路径最短的 Hamilton 回路. 对于一个 N 城市的 TSP 问题, 由于该问题一共存在 $(N-1)!/2$ 条可能的路径, 用穷举的办法显然是不能实现的. 譬如, 用穷举搜索法对 $N=50$ 的 TSP 问题进行求解, 即使采用每秒计算 1 亿次的超级计算机也需要运行 5×10^{48} 年^[8]. 可喜的是, 一些智能优化算法可用于获取 TSP 问题的次优解, 如模拟退火算法^[9]、遗传算法^[10]、禁忌搜索算法^[11]、蚁群算法^[12]和神经网络方法^[13-14]等. 本文则研究基于 SOM 神经网络的 TSP 问题求解方法.

1985 年, Hopfield 和 Tank^[13]首次将神经网络方法应用于 TSP 问题的求解, 从而开创了运用神经网络方法求解 TSP 问题的先河. 目前, 求解 TSP 问题的神经网络方法可分为 Hopfield 类算法^[13]和 SOM 类算法^[14-19]. 尽管 Hopfield 类算法能解决小规模和某些中等规模的 TSP 问题^[20], 但对普通的中等规模问题或者大规模的 TSP 问题, Hopfield 类算法仍不能胜任^[21]. SOM 类算法则不同, 它能以较小的计算代价解决大规模的 TSP 问题^[19]. SOM 类算法相对模拟退火、蚁群算法等算法而言, 其计算复杂度大幅降低而解的质量仅有所下降^[14], 因此, 以提高 TSP 问题解的质量为目标对 SOM 类算法进行改进已经吸引了大量的研究工作^[15-19].

本文在传统 SOM^[14]算法的基础上, 通过引入泛化竞争和局部渗透这两个新的策略, 提出了一种新的 SOM 算法, 称为渗透的 SOM(Infiltrative SOM, ISOM)算法. 该算法以输入城市为中心, 强化距其远的神经元之间的总体竞争作用, 强化距其近的神经元向输入城市局部渗透的作用, 并以学习初

期更强调总体竞争、学习末期更强调局部渗透、学习过程中总体竞争和局部渗透相结合的学习机制, 实现了一种先总体后局部的优化策略. 同时, 该算法结合传统 SOM 学习策略总体路径寻优的特点, 以及新策略在局部路径优化上的优势, 实现了总体优化与局部优化的融合, 获得了高质量的全局优解. 针对来自 TSPLIB^[3]的 14 组 TSP 实例的实验结果显示, ISOM 算法得到了对应于这 14 组数据的 11 个最接近最优的解, 其中对应实例 lin105 的结果就是最优解, 并且 ISOM 算法以最小的平均偏离最优率(偏离最优路径长度的百分率)3.4558% 胜过其余典型的类 SOM 算法, 如 KNIES 算法^[15-16]、SETSP 算法^[17]、Budinich 算法^[18]以及 ESOM 算法^[19], 表明了所提算法的有效性.

2 基于标准 SOM 求解 TSP 的基本原理和存在问题

2.1 SOM 求解 TSP 问题的基本原理

SOM 作为一种从输入空间到输出空间的拓扑保序映射^[22], 已被广泛应用于高维数据的聚类分析、降维和在低维空间中的可视化表示, 其网络结构通常选为线性结构、栅格结构、立方体结构等. 根据 TSP 问题要求找出最短 Hamilton 回路的要求, Kohonen^[14]提出的运用 SOM 求解 TSP 问题的基本思想是, 设置网络结构为一维环形结构(如图 1 所示), 将输入空间中的城市位置作为激励学习网络, 通过由 SOM 所实现的从城市位置到网络输出的拓扑保序映射, 即在输入空间中相邻的城市其所激活




图 1 一维环形 SOM 的结构

的网络上的神经元也相邻,获得 TSP 问题的解.

SOM 通过竞争合作、自适应机制学习输入空间到神经元的拓扑保序映射,其中,基于欧氏距离最小的竞争机制表现为在竞争中获胜的神经元为

$$i(X) = \operatorname{argmin}_j \|X - W_j(n)\|, j = 1, 2, \dots, M \tag{1}$$

其中, M 表示神经元的总数. 建立在网络结构基础上的合作机制表现在: 获胜神经元及其邻域神经元的修正强度(即邻域函数为高斯函数)为

$$h_{j,i(X)}(n) = \exp\left(-\frac{d_{j,i}^2}{2\sigma^2(n)}\right) \tag{2}$$

而自适应学习机制表现在神经元依其修正强度以如下公式进行的修正上:

$$W_j(n+1) = W_j(n) + \eta(n)h_{j,i(X)}(n)(X - W_j(n)) \tag{3}$$


其中, $W_j(n)$ 为 n 时刻神经元 j 与输入结点的连接权矢量, $d_{j,i}$ 为神经元 j 与获胜神经元 i 之间在映射空间中的距离, $\eta(n)$ 为学习率. 实际上,在用 SOM 求解 TSP 问题的过程中,每输入一个城市,通过竞争使其最近的神经元获胜,该神经元及其邻域神经元依据修正强度以移位量 $\eta(n)h_{j,i(X)}(n)(X - W_j(n))$ 移向该输入城市,这一过程不断进行,最终通过合作半径 $\sigma(n)$ 和学习率 $\eta(n)$ 随迭代次数不断减小:

$$\sigma(n) = \sigma_0 \exp\left(-\frac{n}{\tau_1}\right), n = 0, 1, 2, \dots \tag{4}$$

$$\eta(n) = \eta_0 \exp\left(-\frac{n}{\tau_2}\right), n = 0, 1, 2, \dots \tag{5}$$

实现学习过程的最终收敛.

显然,用一维环形 SOM 进行 TSP 问题的求解有如下的优越性:一维环形结构的网络结构与 TSP 问题要求的最短 Hamilton 路径在结构上有很好的匹配;一维环形结构的 SOM 易于构建,如下式



(a) lin105的城市位置和最优路径

$$d_{j,i} = \min\{|j - i|, M - |j - i|\} \tag{6}$$


其中 $d_{j,i}$ 表示邻域函数中兴奋神经元 j 与获胜神经元 i 在输出空间中的距离. 与之相反,其它一些映射方法,如同样用于数据聚类的 GTM^[23],就很难做出类似的结构.

2.2 直接用标准 SOM 算法求解 TSP 问题的主要问题和潜力

尽管一维环形 SOM 网络在求解 TSP 问题上有其相当的合理性,但笔者认为标准 SOM 算法所获得的实际上是 TSP 问题的总体最优解而非全局最优解.

众所周知,SOM 具有很好的拓扑保序特性,即输入空间中样本的距离和邻近特性在输出空间中将得到尽可能的保留. 当用两维栅格作为输出空间时,这一性质常常用于数据的聚类 and 可视化分析. 然而,仿真实验表明,网络对低密度数据区表达有过,而对高密度数据区表达不足^[22],这也就是为什么在数据聚类分析过程中通常用比数据聚类数目多得多的神经元所构成的 SOM 实现对数据的聚类.

用环形 SOM 进行 TSP 问题求解也存在同样的问题. 这里列出 105 个神经元的环形 SOM 求解 lin105(如图 2(a)所示)所获得的收敛结果如图 2(b)所示. 在图 2 中,三角表示 TSP 问题中的城市位置,圆点表示 SOM 收敛后的神经元位置. 从图 2(b)中可以看到:(1) SOM 收敛到了一组虚拟城市(即神经元,用圆点表示)上,这些虚拟城市的位置并不是真实城市(即输入城市,用三角形表示)的位置;(2) SOM 所给出的收敛路径是这组虚拟城市 TSP 问题的最优解;(3) 这组虚拟城市与真实城市之间似乎难以建立一个一一对应的关系,因此从这组虚拟城市 TSP 问题的最优解中无法获得真实城市的 TSP 问题的最优解.



(b) lin105用105个神经元的环形SOM求解所获得的收敛结果

图 2

由此可见,用标准 SOM 算法所获得的是虚拟城市 TSP 问题的最优解,该最优解实际上仅是真实

城市 TSP 问题解的一个轮廓,我们称其为原 TSP 问题的总体最优解. 从这一点上看,SOM 求解 TSP

问题是非常有特点的：所获得的解是虚拟城市 TSP 问题的全局最优解，也称是真实城市 TSP 问题的总体最优解。注意到我们的目标是寻找真实城市 TSP 问题的全局最优解，而非其总体最优解。本文试图将总体寻优和局部寻优有机结合起来，即在很好利用 SOM 进行总体寻优的潜力基础上，通过嵌入局部寻优的机制，获得真实城市 TSP 问题的全局最优解，这就是本文的目的所在。

3 ISOM 算法

3.1 泛化竞争机制和局部渗透机制

实际上，用标准 SOM 算法求解 TSP 问题的过程为：随机初始化神经元（虚拟城市）的位置，并由真实城市不断激励得到获胜神经元，神经元依据学习算法不断向真实城市移位，最终收敛到神经元的位置不再移动为止。然而这样的学习过程仅仅能够得到原 TSP 问题的总体最优解，而非全局最优解。为尽可能获得真实城市 TSP 问题的最优解，本节在标准 SOM 学习算法的基础上，提出了两个新的学习机制：泛化竞争和局部渗透，并将其融入标准 SOM 的学习算法中。

从 TSP 问题的求解要求看：（1）当输入城市与获胜神经元之间的距离较大时（表明尽管该神经元获胜，但仍不一定将该城市映射到该神经元上），应使获胜神经元及其邻域神经元向输入城市的位移量减少，从而允许各个神经元更加公平地参与竞争，我们称这一机制为泛化竞争机制；（2）当输入城市与获胜神经元之间的距离较小时（表明应该将城市映射到该神经元上），应使获胜神经元及其邻域神经元向输入城市的位移量增大，从而弱化其他神经元对当前输入城市的竞争而强化获胜神经元及其邻域神

经元对当前输入城市的竞争，我们称这一机制为局部渗透机制。以上位移量的减少或增大均相对标准的 SOM 算法而言。

泛化竞争是使各个神经元处于更为公平竞争的机制，而局部渗透则是使获胜神经元及其邻域神经元具有更为优越的局部竞争能力的机制，前者强化总体寻优，后者强化局部寻优。

3.2 泛化竞争和局部渗透的实现

为实现泛化竞争和局部渗透机制，我们引入渗透半径 λ 作为输入城市与获胜神经元之间距离大小的判断门限，一旦它们之间的距离大于 λ ，则采用泛化竞争机制；反之则采用局部渗透机制。为此，将神经元向输入城市的移位由原来的 $\eta(n)h_{j,i(X)}(n)(X(n) - w_j(n))$ 调整为 $Z(d_{X,i(X)}; \lambda)\eta(n)h_{j,i(X)}(n)(X(n) - w_j(n))$ ，即将式(3)调整为如下的公式：

$$w_j(n+1) = w_j(n) + Z(d_{X,i(X)}; \lambda(n)) \cdot \eta(n)h_{j,i(X)}(n)(X(n) - w_j(n)) \quad (7)$$

其中， $Z(n, d_{X,i(X)}, \lambda(n))$ 用于神经元权值移位量的调节，并按式(8)取值：

$$Z(d_{X,i(X)}; \lambda(n)) = \exp\left(-\frac{d_{X,i(X)}^2}{2\lambda^2(n)}\right) \quad (8)$$

其中 $d_{X,i(X)}$ 为输入空间中输入城市 X 到获胜神经元 $i(X)$ 的欧氏距离。显然，这样的设置将使 $d_{X,i(X)} > \lambda$ 时所乘的系数 Z 的数值较小，从而保证获胜神经元及其邻域神经元以较小的移位量移向输入城市，达到泛化竞争的目的；而当 $d_{X,i(X)} < \lambda$ 时所乘的系数 Z 的数值较大，从而保证获胜神经元及其邻域神经元以较大的位移量移向输入城市，达到局部渗透的目的。我们将离输入城市 X 小于 λ 的区域称为输入城市 X 的渗透区域 $\Phi(X)$ 。

注意到当 $d_{X,i(X)} > \lambda$ 时，获胜神经元 i 及其邻域神经元仅以较小的移位量移向输入城市 X ，如





图 3 TSP 问题求解的泛化竞争机制和局部渗透机制

图 3(a)所示,从而不过早建立获胜神经元与输入城市之间的一一对应关系,而是允许其它神经元参与进一步的竞争;当 $d_{X,i(X)} < \lambda$ 时,获胜神经元 i 及其邻域神经元将以较大的移位量移向输入城市 X ,如图 3(b)所示,这样的位移极有可能造成获胜神经元及其邻域神经元向输入城市以较大移位量移位(渗透)的现象:在获胜神经元 i 的邻居神经元 $i+1$ 被拽向输入城市 X 的同时,也以较大步伐靠近了输入城市 X 的邻近城市 Y ;与此同时,由于城市 Y 与输入城市 X 离得很近,神经元 $i+1$ 也被拽入 $\Phi(Y)$. 在接下来针对城市 Y 的竞争中,神经元 $i+1$ 因其在城市 Y 的 $\Phi(Y)$ 内从而将极有可能获胜并与城市 Y 建立一一映射关系. 由此, $Y \Rightarrow X$ 的路径很可能被选上. 城市 Z 的情况也类似,城市 X 到城市 Z 的路径很可能被选择而最终形成 $Y \Rightarrow X \Rightarrow Z$ 的路径. 以此类推,两两离得很近的城市将不断地被映射成为路径上的两个相邻神经元,从而形成一条神经元分布紧凑的路径. 在这个过程中,一连串神经元是以递进的方式逐步实现与一条子路径的匹配的,“渗透”由此得名.

3.3 总体寻优基础上的局部寻优

TSP 问题与最短路问题不同,最短路问题的全局最优路径中每一局部路径都是局部最优的,但局部最优路径却不保证解的全局最优性. TSP 问题则复杂的多,其全局最优路径不能保证其局部路径的局部最优性,其局部最优路径也不能保证解的全局最优性. TSP 问题的这种复杂性,使得它成为较之最短路问题困难得多的问题: TSP 的计算复杂度为 $O((N-1)!)$,最短路问题的计算复杂度不超过 $O(N^3)$,这里 N 为城市数. 为此,我们提出对 TSP 问题的如下策略:先总体优化后局部优化、在总体优化的基础上进行局部优化,使总体优化与局部优化有机结合以寻求全局最优解的学习机制.



(a) Z 关于 d 的曲线图

为实现这一学习策略,显然渗透区域应是随时间由小到大逐步扩张的. 为此,这里设

$$\lambda(n) = \lambda_0 \left(\frac{1}{1 + \exp(-an)} - \frac{1}{2} \right) \tag{9}$$


其中 λ_0 和 a 为常量,本文的实验取 $\lambda_0 = cd/4$, $a = \frac{1}{2}$, cd 为一距离常量,其值选为神经元初始化矩形框的对角线长度.

这样,我们求解 TSP 问题的渗透 SOM 算法的步骤如下:

算法 1.

1. 确定神经元数目 M (一般为 2~3 倍城市数),将神经元有序分布在城市外围的矩形框上;
2. 从输入空间随机取样本 X 作为输入城市;
3. 依据式(1)确定 n 时刻的获胜神经元 $i(X)$;
4. 通过式(7)更新神经元权值,其中 $Z(n, d_{X,i(X)}, \lambda(n))$ 和 $\lambda(n)$ 由式(8)和(9)计算得到;
5. $n+1 \rightarrow n$,继续步 2~4 直到邻域函数宽度 $\sigma(n) \leq 1$ (其初值取 $\sigma_0 = M/4$);
6. 由已与城市建立一一映射关系的神经元的顺序确定访问路径. 若有城市未被一一映射,回到步 1 并增大神经元数量 M .

图 4(a)示出了 $Z(d_{X,i(X)}; \lambda(n))$ 与 $d_{X,i(X)}$ 之间的关系,可以看到大的 $d_{X,i(X)}$ 对应小的位移量,从而强化总体竞争,小的 $d_{X,i(X)}$ 对应大的位移量,从而强化神经元 $i(X)$ 附近的局部渗透;图 4(b)示出了 $\lambda(n)$ 与 n 之间的关系曲线,可以看到渗透区域的半径是随算法的运行不断变化的:初始时半径小,从而强化总体竞争;随着算法的运行渗透半径逐渐增加,强化局部渗透. 我们就是在 SOM 中引入这样的机制实现总体竞争和局部渗透并举、先倾向总体竞争后倾向局部渗透、在总体竞争基础上的局部渗透,从而实现在总体优化的基础上进行局部优化、使总体优化与局部优化有机结合以寻求全局最优解的学习策略的.



(b) λ 关于 n 的曲线图

相对标准 SOM 算法和目前已有的基于 SOM 的 TSP 问题求解方法^[14-19]而言,上述算法的计算复杂度仍保持为 2 次. 本文所提出的算法采用了文献[17]中已被证实有效的神经元初始化方式:将神经元有序地分布在城市外围的矩形框上(如图 5(a)所示).

4 实验与结果

本文针对 TSPLIB^[3] 中的 TSP 实例进行了大量的求解实验,并与 TSPLIB 中公布的路径长度及文献[16-17,29]中所公布的其他方法所获得的路径长度进行了比较,以“偏离最优率 μ ”(即所得路径的长度超出 TSPLIB 公布的最优路径长度的百分率)作为评价解的质量的指标, μ 越小表明解的质量越高. 注意到 TSPLIB 公布的路径长度由每条边四舍五入取整后累加得到^①,因而所有的路径长度都是整数. 然而很多文献并没有对任何长度值取整,以便于和同类方法作比较,本文在实验中也不做取整处理. 本文针对 50~1655 个城市的 14 组 TSP 实例进行的实验结果及与其他方法的比较示于表 1 中,其中 ISOM_20 栏对应 ISOM 算法 20 次运行所得的平均路径长度的 μ 值,ISOM 栏为这些运行所获得的最好结果的 μ 值,其它栏对应各个方法所得最好结果的 μ 值. 表 1 中质量最好即 μ 最小的数值已经用

黑体标出. 从表 1 可知,14 组 TSP 实例中有 11 组可通过 ISOM 得到更优的解,其中 lin105 的最好解与 TSPLIB 公布的最优路径完全一致,如图 2(a)所示;对于其余 3 组数据,ISOM 也得到了比较好的结果. 从表中我们可以得出,ISOM 最终能以 3.4558% 这个最小的平均偏离最优率展示其可行性和有效性. 同时,ISOM 运行 20 次的平均值也不差,从而可以看出该方法还具有一定的稳健性,即相对其他算法而言,本文算法每次运行都得到相对较好的路径. 我们对 1002 个城市、1173 个城市和 1165 个城市的实验结果已列于表中,然而,对于 KG、KL、KD 和 SETSP 方法,由于问题规模过大,文献中没能给出他们的方法对这个城市规模的实验结果,即使与给出结果的 Budinich 方法和 ESOM 方法相比,用我们方法得到结果的性能也优越很多,表明了我们方法的有效性.

图 5 给出了 ISOM 算法对 eil51 进行 TSP 问题的求解过程,由此可以看到本文的渗透机制的意义:基本上找出了最优路径上的凹槽路径,从而最终所获得的路径是较优的.

图 6 给出了本文算法运行时间与城市数量的关系,从该图可以看出,运行时间基本上是按照城市数量的二次关系递增的,由此 ISOM 算法保持了 SOM 算法具有较低计算复杂度的优良特点.

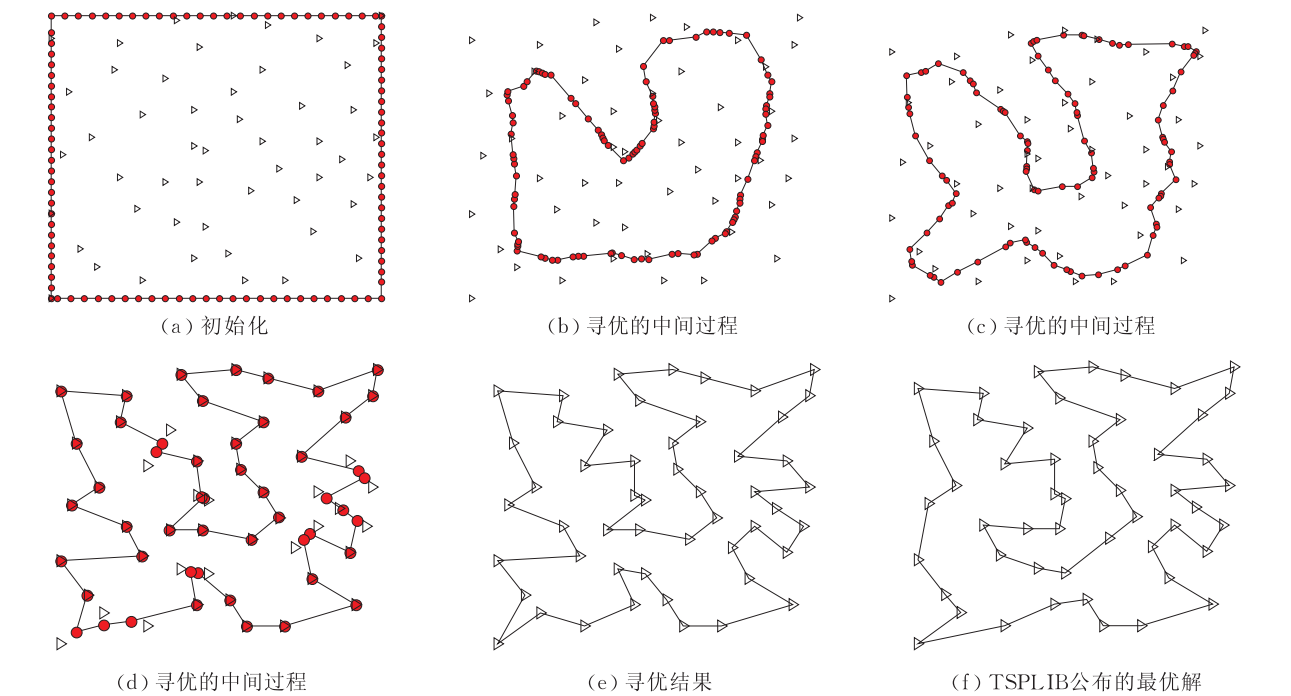


图 5 eil51 的寻优过程

① Reinelt G. TSPLIB95. Available from: <http://www.informatik.uni-heidelberg.de/groups/comopt/software/TSPLIB95/DOC.PS>

表 1 7 种方法求解 14 组 TSP 实例的结果

实例名称	城市规模	偏离最优路径的比率 $\mu/\%$							
		KG	KL	KD	SETSP	Budinich	ESOM	ISOM	ISOM_20
eil51	51	2.86	2.86	3.50	2.22	3.10	2.10	2.5604	3.8132
st70	70	2.33	1.51	3.67	1.60	1.70	2.09	1.3291	2.1104
eil76	76	5.48	4.98	6.49	4.23	5.32	3.89	3.4540	4.6264
rd100	100	2.62	2.09	4.89	2.60	3.16	1.96	1.4096	3.4011
lin105	105	1.29	1.98	2.18	1.30	1.71	0.25	0.0278	0.2420
pr107	107	0.42	0.73	10.83	0.41	1.32	1.48	0.2212	0.8731
pr136	136	5.15	4.53	1.93	4.40	5.20	4.31	3.3820	3.6710
pr152	152	1.29	0.97	3.24	1.17	2.04	0.89	1.2364	2.0846
rat195	195	11.92	12.24	8.35	11.19	11.48	7.13	5.5575	7.8338
kroA200	200	6.57	5.72	5.66	3.12	6.13	2.91	2.7479	3.2617
pcb442	442	10.45	11.07	8.00	10.16	8.43	7.43	6.5343	8.1955
11 组实例的平均偏离率		4.5800	4.4255	5.3400	3.8545	4.5082	3.1309	2.5873	3.6466
pr1002	1002	7.60		7.08		8.75	5.93	3.4809	5.0090
pcb1173	1173					11.38	9.87	7.5303	8.5804
d1655	1655					15.18	11.35	8.9519	10.0452
14 组实例的平均偏离率						6.0643	4.3993	3.4558	4.5534

注 1. 方法 KL(KNIES_TSP_Local)、KG(KNIES_TSP_Global)、KD(KNIES_DECOMPOSE)的结果引自文献[16];SETSP(SOM efficiently applied to the TSP)的结果引自文献[17];Budinich(Budinich's SOM)和 ESOM(Expending SOM)的结果引自文献[19]. 黑体数字说明该数值在同行数据中最小.




图 6 ISOM 运行时间关于城市数的折线图

5 结 论

本文提出了一种改进的 SOM 算法,该算法通过在标准 SOM 学习的基础上引入新的学习机制:泛化竞争机制和局部渗透机制,实现了路径的总体优化与局部优化的融合,从而能够找到更加接近全局最优的解.实验表明,尽管 ISOM 算法很简单,在求解精度上它已经超越了如 KNIES、SETSP、Budinich 和 ESOM 这些典型的 SOM 算法,同时算法还保持了较低的计算复杂度,且解还具有良好的稳健性.

参 考 文 献

[1] Dorigo M, Gambardella L M. Ant colony system: A cooperative learning approach to the traveling salesman problem. *IEEE Transactions on Evolutionary Computation*, 1997, 1(1): 53-66

[2] Ascheuer N, Jünger M, Reinelt G. A branch and cut algorithm for the asymmetric traveling salesman problem with precedence constraints. *Computational Optimization and Applications*, 2000, 17(1): 61-84

[3] Reinelt G. TSPLIB—A traveling salesman problem library. *ORSA Journal on Computing*, 1991, 3: 376-384

[4] Laporte G. The vehicle routing problem: An overview of exact and approximate algorithms. *European Journal of Operational Research*, 1992, 59: 345-358

[5] Potvin J-Y. The traveling salesman problem: A neural network perspective. *ORSA Journal on Computing*, 1993, 5: 328-348

[6] Garey M R, Johnson D S. *Computers and Intractability: A Guide to the Theory of NP-Completeness*. San Francisco: Freeman W H, 1979

[7] Jiao Li-Cheng. *Neural Computation*. Xi'an: Xidian University Press, 1996: 195-196(in Chinese)

[8] Wang Wei. *Artificial Neural Network: Theory and Application*. Beijing: Beijing University of Aeronautic and Astronautic Science and Technology Press, 1995(in Chinese)

[9] Kirkpatrick S G, Gelatt Jr C D, Vecchi M P. Optimization by simulated annealing. *Science*, 1983, 220: 671-680

[10] Goldberg D E. *Genetic Algorithms in Search, Optimization and Machine Learning*. MA: Addison-Wesley, 1989

[11] Knox J. Tabu search performance on the symmetric traveling salesman problem. *Computers and Operations Research*, 1994, 21(8): 867-876

[12] Baraglia R, Hidalgo J I, Perego R. A hybrid heuristic for the traveling salesman problem. *IEEE Transactions on Evolutionary Computation*, 2001, 5(6): 613-622

[13] Hopfield J J, Tank D W. Neural computation of decisions in optimization problems. *Biological Cybernetics*, 1985, 52(3): 141-152

[14] Kohonen T. *Self-Organizing Maps*. New York: Springer-Verlag, 1997

[15] Aras N, Oommen B J, Altinel K. Kohonen network incorporating explicit statistics and its application to the traveling

- salesman problem. *Neural Networks*, 1999, 12(9): 1273-1284
- [16] Aras N, Altinel I K, Oommen B J A. Kohonen-like decomposition method for the Euclidean traveling salesman problem—KNIES_DECOMPOSE. *IEEE Transactions on Neural Networks*, 2003, 14(1): 869-890
- [17] Vieira F C, Neto A D D. An efficient approach to the traveling salesman problem using self-organizing maps. *International Journal of Neural Systems*, 2003, 13(2): 59-66
- [18] Budinich M. A self-organizing neural network for the traveling salesman problem that is competitive with simulated annealing. *Neural Computation*, 1996, 8: 416-424
- [19] Leung K S, Jin H D, Xu Z B. An expanding self-organizing neural network for the traveling salesman problem. *Neurocomputing*, 2004, 62: 267-292
- [20] Abe S. Convergence acceleration of the Hopfield neural network by optimization integration step sizes. *IEEE Transactions on System, Man and Cybernetics—Part B: Cybernetics*, 1996, 26(1): 194-201
- [21] Smith K A. An argument for abandoning the traveling salesman problem as a neural network benchmark. *IEEE Transactions on Neural Networks*, 1996, 7(6): 1542-1544
- [22] Haykin S. *Neural Networks: A Comprehensive Foundation*. 2nd Edition. New Jersey: Prentice Hall, 1999: 444-460
- [23] Bishop C M, Svensen M, Williams C K I. GTM: The generative topographic mapping. *Neural Computation*, 1998, 10(1): 215-234



ZHANG Jun-Ying, born in 1961, Ph.D., professor, Ph.D. supervisor. Her research interests focus on intelligent information processing, including machine learning and its application to cancer related bioinformatics, image processing radar automatic target recog-

nition, and pattern recognition.

ZHOU Bin, born in 1982, master. His research interests focus on artificial networks for combinational optimization problems.

Background

Traveling salesman problem (TSP) is one of the most typical NP-hard combinatorial optimization problems, which has various applications in diversity of fields. Developing algorithms for solving such TSPs, especially large scale TSPs, is of a great significance in both theory and applications.

From the notice that solving this problem is of great difficulty, brings great challenges, and possesses much potential in theory, methods and algorithms, it is seen that (a) it is extremely difficult and even impossible for developing an algorithm for finding the globally optimal solution of a large scale TSP problem in an acceptable time and space; (b) the overall optimal solution rather than the globally optimal solution of a TSP can be found with standard self-organizing map (SOM) neural network. Hence, based on the fact of standard SOM for searching for overall optimal solution of a TSP, in this paper, two learning schemes are introduced and embedded into the SOM algorithm, competition generalization and local infiltration. By the collaboration of the two learning schemes in that both the schemes work together in the whole learning process and initial learning focuses more on overall optimization, which is conducted by the competition generali-

zation, while the afterward learning focuses more on local optimization, which is conducted by the local infiltration, the near-optimal solution is much more easy to be found compared with many other SOM-based methods. Experiments on public TSPLIB data show that not only the quality of the solutions is higher, but also the solutions are more robust, by the proposed method compared with those by several typical SOM-based methods such as the KNIES algorithms, the SETSP, the SOM developed by Budinich, and the ESOM.

The research group has been working on combinatorial optimization problems for many years. They have published more than 50 papers in recent three years, in *Science in China*, *Progress in Natural Science*, *Chinese Journal of Computers*, *Acta Physica Sinica*, *System Engineering and Electronics*, *Digital Signal Processing*, *Chinese Journal of Electronics*, etc. and we get the second order Scientific Research Award of Shaanxi Province Government.

Their work was and is being supported by the Chinese National Science Foundation under grant Nos. 60574039, 97946223, 69971018, 60071026 and by the Sino-Italy Joint Foundation under grand No. 200625617.