

文章编号: 1002-0446(1999)05-0363-07

# 基于神经网络的自主车辆导航路径计算

周 捷 翟羽健

(东南大学仪器科学与工程系 南京 210018)

摘 要: 本文提出一种基于 Hopfield 神经网络的自主车辆的最短路径计算的新方法, 具有计算速度快、不需要改变神经网络结构的内部参数便能实时调整算法来适应网络边的费用及其图的拓扑关系的改变的特点. 适用于城市交通线路上自主车辆的智能导航系统.

关键词: Hopfield 神经网络; 最短路问题; 路径导航系统; 自主车辆

中图分类号: TP24 文献标识码: A

## 1 引言

自主车辆内的路径导航系统(Route Guidance System - RGS)是智能交通运输系统(Intelligent Transportation System - ITS)的重要研究课题之一<sup>[1,2]</sup>. 对于基于地图导航的自主车辆内的路径导航系统, 要求能够按照存储在其内部的数字地图的拓扑信息, 实时地规划出一条全局最优路径用于车辆的导航. 对于交通线路的地理网络, 传统的方法是以图论中的关联矩阵或邻接矩阵存储网络数据, 若网络结点为  $N$ , 则需要定义的矩阵. 一些经典的路径优化问题如 TSP(Travelling Salesman Problem), 其计算量随着  $N$  的增长而成指数增长, 当  $N$  较大时, 其运算速度难以满足自主导航的实时计算要求.

对于最短路径问题(Shortest Path Problem - SPP), 有一些经典的算法如适用于正费用的 Dijkstra 算法和适用于正负费用的 Ford、Fulkerson 算法<sup>[3,4]</sup>能有效地求出具有确定网络边费用的 SPP 的最优解. 但对于城市交通地理网络, 由于有上下班交通高峰期、每天某一时段的交通单行线以及某一时期的交通管制等等因素, 网络边(街道)的费用(以交通时间为量度)及网络的拓扑结构关系是动态变化的, 对于智能交通系统中的车辆路径导航系统, 采用上述的算法难以实时地适应这些变化.

神经网络是一个高度并行的分布式系统, 处理速度高, 因此近年来神经网络的研究已被人们引入到智能机器人及自主车辆的导航应用中. 采用并行算法的神经网络来解决此类问题已引起人们的兴趣和注意. 对于基于环境拓扑结构的 GIS 数字地图, 在给出目标后, 可利用 Hopfield 神经网络的能量函数的收敛得到一条最优路径<sup>[5,6]</sup>.

本文用基于 Hopfield 神经网络的路径优化算法对用邻接矩阵表示的地理网络的最短路径计算进行了研究分析, 神经网络中的每一神经元代表交通网络中的边(街道), 当网络趋于稳定时, 输出为“1”表示该网络边在最短路径上, 为“0”则反之. 仿真结果表明该算法能收敛到的最短路径与 Dijkstra 算法的结果是一致的. 本算法具有计算速度快、不需要改变神经网络结构的内部参数便能实时调整算法来适应网络边的费用及其图的拓扑关系的改变的特点. 适用于

城市交通线路上自主车辆的智能导航系统.

## 2 用 Hopfield 模型求解最短路问题算法

### 2.1 Hopfield 神经网络模型<sup>[7]</sup>

Hopfield 于 1984 年提出连续时间的 Hopfield 神经网络模型:

各神经元输出:

$$V_i = g_i(U_i) = \frac{1}{1 + e^{-\lambda U_i}} \quad (1)$$

模型的运动方程:

$$\frac{dU_i}{dt} = \sum_{j=1}^N T_{ij} V_j - \frac{U_i}{\tau} + I_i \quad (2)$$

式中:  $T_{ij}$  为神经元间的联接权重,  $I_i$  为阈值,  $\tau$  为模型电路的时间常数. 对于对称联接的权重, 即  $T_{ij} = T_{ji}$ , 当放大器增益足够大 ( $\lambda \rightarrow \infty$ ) 时, 定义如下的能量函数:

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N T_{ij} V_i V_j - \sum_{i=1}^N I_i V_i \quad (3)$$

Hopfield 证明网络将收敛到能量函数  $E$  的稳定状态, 目标函数达到它的局部最小值. 由 (2)、(3) 式, 第  $i$  个神经元的运动方程可描述如下:

$$\frac{dU_i}{dt} = -\frac{U_i}{\tau} = \frac{\partial E}{\partial V_i} \quad (4)$$

### 2.2 基于地图拓扑结构的城市交通地理网络的最短路径概念

在用于车辆自主导航系统的地理信息系统中, 常将空间事物抽象成具有拓扑关系的点、线、面等几何要素组成网络. 网络在几何上由边连成, 各条边的端点、交点组成网络的结点. 对于基于地图导航的自主车辆, 可以把交通道路网定义为几何上的“网”, 行车路线可定义成网络的“边”, 道路上各转向路口、交叉路口可以定义为网络上的“结点”. 这样就把现实世界中的客观对象抽象成 GIS 中的网络、结点和边之间的关系.

对于二维的平面数字地图, 定义一有向图  $G = (N, L, C)$ , 有  $n$  个结点,  $l$  个边, 每一个边  $(i, j)$  对应着一个非负的费用 (cost)  $C_{ij}$ . 设自主车辆从源结点  $s$  出发, 要求到达目标结点  $d$ , 定义一有向路径  $P^{sd} = (s, i, j, k, \dots, r, d)$ , 其路径长度  $L^{sd} = C_{si} + C_{ij} + C_{jk} + \dots + C_{rd}$ . 因此最短路径问题可归纳为: 找出具有最小  $L^{sd}$  的  $P^{sd}$ . 对于城市交通道路系统, 费用  $C_{ij}$  的含义有多种, 如道路的长度 (距离)、车辆沿此道路行驶完需要的时间 (如交通高峰期所需费用则大), 甚至可将费用定义为道路边  $(i, j)$  未被使用的概率, 若假定给定道路的使用概率与其它剩余道路的使用概率无关, 则按此费用求出的  $s-d$  的最短路径为最安全可靠的一条路. 另外, 城市交通网络中由于有某一时段的交通单行线以及某一时期的交通管制等等因素, 交通网络的拓扑结构关系是动态变化的.

### 2.3 最短路径的 Hopfield 神经网络算法

对于有  $n$  个结点有向图  $G = (N, L, C)$ , 我们定义邻接矩阵 ( $n \times n$ ), 删去矩阵中的对角线元素, 矩阵中每个元素对应一个神经元, 整个网络共需  $n \times (n-1)$  个神经元, 定义位于  $(x, i)$  的神经元的输出  $V_{xi}$  如下:

$$V_{xi} = \begin{cases} 1 & \text{若从结点 } x \text{ 到 } i \text{ 的边在最短路径上} \\ 0 & \text{其它} \end{cases} \quad (5)$$

我们还定义:

$$\rho_{xi} = \begin{cases} 1 & \text{若边}(x, i) \text{ 不存在} \\ 0 & \text{其它} \end{cases} \quad (6)$$

从(5)式可看出, 网络中的神经元  $V_{xi}$  代表地理网络中各结点之间的网络边, 当 Hopfield 网络趋于稳定时, 神经元输出为“1”表示该网络边在最短路径上, 为“0”则反之.

为了用 Hopfield 模型解决 SPP 问题, 综合网络的目标函数和约束条件, 定义网络的能量函数如下:

$$E = \frac{\mu_1}{2} \sum_{x=1}^n \sum_{\substack{i=1 \\ i \neq x}}^n C_{xi} V_{xi} + \frac{\mu_2}{2} \sum_{x=1}^n \sum_{\substack{i=1 \\ i \neq x}}^n \rho_{xi} V_{xi} + \frac{\mu_3}{2} \sum_{x=1}^n \left| \sum_{\substack{i=1 \\ i \neq x}}^n V_{xi} - \sum_{\substack{i=1 \\ i \neq x}}^n V_{ix} \right|^2 + \frac{\mu_4}{2} \sum_{i=1}^n \sum_{\substack{x=1 \\ x \neq i}}^n V_{xi} (1 - V_{xi}) + \frac{\mu_5}{2} (1 - v_{ds}) \quad (7)$$

式(7)中的  $\mu_1, \mu_2, \mu_3, \mu_4, \mu_5$  为惩罚系数. 右式中第一项为网络的目标函数, 它使路(网络边)的总费用最小; 第 2、3、4、5 项为网络的约束条件, 各自的含义如下:  $\mu_2$  项防止不存在的路被选进路径中;  $\mu_3$  项保障路径中的结点 (node) 有输入路径, 必有输出路径; 当  $V_{xi} \in \{0, 1\}$  时,  $\mu_4$  强迫神经网络的状态收敛到超立方体  $2^{n(n-1)}$  中的一个;  $\mu_5$  项强迫最短路径的结构源于  $s$ , 终点为  $d$ . 这样最终得到的解将包含二部分: (1) 从  $s \rightarrow d$  的有向路径; (2) 从  $d \rightarrow s$  直接连通的边. 若网络中没有零长度的循环路线,  $\mu_1$  和  $\mu_3$  将保证矩阵中的每一行、列至多有一个“1”.

对于用邻接矩阵表示的神经元, 考虑每个神经元有行、列两个系数, 重新改写(1)、(2)、(4)式如下:  $\forall (x, i) \in \bar{N} \times \bar{N} / x \neq i$ , 有:

$$V_{xi} = g_{xi}(U_{xi}) = \frac{1}{1 + e^{-\lambda_{xi} U_{xi}}} \quad (8)$$

$$\frac{dU_{xi}}{dt} = \sum_{y=1}^n \sum_{\substack{j=1 \\ j \neq y}}^n T_{xi, yi} V_{yj} - \frac{U_{xi}}{\tau} + I_{xi} \quad (9)$$

$$\frac{dU_{xi}}{dt} = - \frac{U_{xi}}{\tau} - \frac{\partial E}{\partial V_{xi}} \quad (10)$$

将(7)式代入(10)式, 得到神经网络的运动方程:

$$\begin{aligned} \frac{dU_{xi}}{dt} = & - \frac{U_{xi}}{\tau} - \frac{\mu_1}{2} C_{xi} (1 - \delta_{xd} \delta_{is}) - \frac{\mu_2}{2} \rho_{xi} (1 - \delta_{xd} \delta_{is}) - \mu_3 \sum_{\substack{y=1 \\ y \neq x}}^n (V_{xy} - V_{yx}) \\ & + \mu_3 \sum_{\substack{y=1 \\ y \neq i}}^n (V_{iy} - V_{yi}) - \frac{\mu_4}{2} (1 - 2V_{xi}) + \frac{\mu_5}{2} \delta_{xd} \delta_{is} \end{aligned} \quad (11)$$

式中  $\delta$  为 Kronecker 函数, 定义如下:

$$\delta_{ab} = \begin{cases} 1 & \text{若 } a = b \\ 0 & \text{其它} \end{cases} \quad (12)$$

比较(9)式和(11)式中的系数, 可得到如下的联接权重及偏置电流:

$$\begin{aligned} \forall (x \neq i), \forall (y \neq i) \\ T_{xi, yi} = & \mu_4 \delta_{xy} \delta_{ij} - \mu_3 \delta_{xy} - \mu_3 \delta_{ij} + \mu_3 \delta_{jx} + \mu_3 \delta_{iy} \\ I_{xi} = & - \frac{\mu_1}{2} C_{xi} (1 - \delta_{xd} \delta_{is}) - \frac{\mu_2}{2} \rho_{xi} (1 - \delta_{xd} \delta_{is}) - \frac{\mu_4}{2} + \frac{\mu_5}{2} \delta_{xd} \delta_{is} \end{aligned} \quad (13)$$

$$= \begin{cases} \frac{\mu_5}{2} - \frac{\mu_4}{2} & \text{若 } (x, i) = (d, s) \\ -\frac{\mu_1}{2} C_{xi} - \frac{\mu_2}{2} \rho_{xi} - \frac{\mu_4}{2} & \text{其它} \end{cases} \quad (14)$$

将(13)、(14)式中的  $T_{xi, yi} I_{xi}$  的表达式代入(9)式, 然后交替求解网络的运动方程(9)和代数方程(8), 当神经网络趋于稳态时, 就可得到一个优化解。

根据 Hopfield 网络的能量函数及(13)、(14)式, 我们可看出本算法除了具有神经网络并行算法计算速度快的特点外, 另外主要有二个优点: (1) 网络的拓扑结构信息是以  $\rho_{xi}$  项表现出来的, 因此网络拓扑关系的改变能灵活地映射在  $\rho_{xi}$  项中; (2) 在偏置电流  $I_{xi}$  中, 网络边的费用  $C_{xi}$  被线性地表达出来。因此, 通过偏置电流  $I_{xi}$  的改变, 便能映射网络边的费用和网络的拓扑信息的改变。即算法不必要改变神经网络结构的内部参数而能适应网络边费用和网络的拓扑关系的改变, 这使得本文的算法适合于交通线路上车辆自主导航的最短路径实时运算, 不必因为路费用及拓扑关系的改变而改变算法中的神经网络结构。

### 3 仿真算例

将一交通地理网络简化为图1的有向图及其邻接矩阵, 设图中有6个结点, 依次标号为0—5, 结点之间存在有向路径时, 其邻接矩阵的对应元素填上该路径的费用, 若结点之间无联接, 则费用为无穷大, 结点自身的费用为零。有向图中的单向箭头的路径可理解为现实社会中交通网络中的道路单行线。

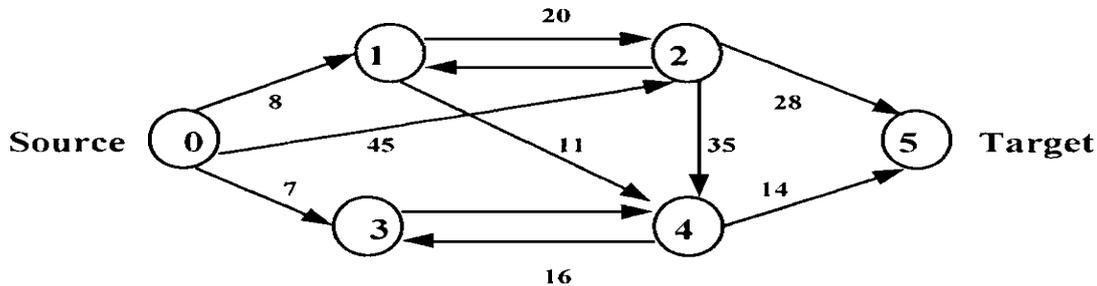


图1 交通地理网络的简化有向图

图1的有向图可用如下的邻接矩阵表示:

$$\begin{pmatrix} 0 & 8 & 45 & 7 & \infty & \infty \\ \infty & 0 & 20 & \infty & 11 & \infty \\ \infty & 20 & 0 & \infty & 35 & 28 \\ \infty & \infty & \infty & 0 & 16 & \infty \\ \infty & \infty & \infty & 16 & 0 & 14 \\ \infty & \infty & \infty & \infty & \infty & 0 \end{pmatrix} \quad (15)$$

设源结点为标号0, 目标结点为标号5。我们先用经典的 Dijkstra 算法对结点标号为0的源点作单源最短路径计算, 即求出结点0到其余所有各结点的最短路径及费用。得到的各最短路径及费用分别为: 结点0→1: 所需费用8; 结点0→1→2: 费用28; 结点0→3: 费用7; 结点0→1→4: 费用19; 结点0→1→4→5: 费用33。

用 Hopfield 神经网络对以上的有向图进行仿真计算, 我们选取各惩罚系数如下:  $\mu_1 = 1000$ ;  $\mu_2 = \mu_5 = 3000$ ;  $\mu_3 = 1600$ ;  $\mu_4 = 500$ . 网络的时间常数  $\tau = 1$ . 并假定每个神经元的具有相同的传递函数, 即  $g_{xi} = g$ ;  $\lambda_{xi} = \lambda$ . 网络的初始电压  $U_{xi} = 0$ . 对图 1 的有向图进行仿真计算, 其神经网络的最终输出结果如图 2 所示.

	0	1	2	3	4	5
0	X	1	0	0	0	0
1	0	X	0	0	1	0
2	0	0	X	0	0	0
3	0	0	0	X	0	0
4	0	0	0	0	X	1
5	1	0	0	0	0	X

图 2 神经网络仿真结果

当 Hopfield 网络模型趋于稳定时, 我们得到如图 2 所示的神经网络输出结果, 可以看出, 输出结果为“1”的网络边分别为:  $0 \rightarrow 1$ 、 $1 \rightarrow 4$ 、 $4 \rightarrow 5$  以及  $5 \rightarrow 0$ . 其中  $5 \rightarrow 0$  是算法模型中构成自封闭的从目标结点到源结点的假定的网络边, 而其余稳定结果为“1”的网络边都应在最短路径上. 因此可得出从结点 0 到结点 5 的最短路径为:  $0 \rightarrow 1 \rightarrow 4 \rightarrow 5$ , 这与用 Dijkstra 算法得出的结果是一致的.

若网络的拓扑关系和网络边的费用改变为如图 3 所示, 设图中的交通网络边  $1 \rightarrow 4$ 、 $2 \rightarrow 1$  由于某种原因(如交通管制、城建施工、严重塞车、实行单行线等等)不复存在, 而网络边的费用(车辆行驶时间)由于各街道的车流量的改变而随着变化. 本算法中认为网络边的费用的改变是一个离散时间过程, 即每天各个交通时段各道路具有不同的费用, 但对于同一道路同一时段中的费用是固定的.

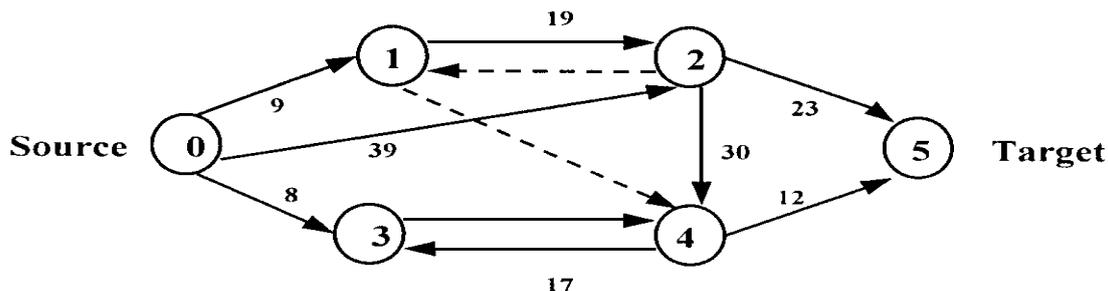


图 3 拓扑结构和费用有所改变的有向图

对于从图 1 演变到图 3 的有向图, 若采用经典的 Dijkstra 算法求最短路径, 则需要重新构造有向图的邻接矩阵如公式(16), 这将给实时运算带来困难.

$$\begin{vmatrix}
 0 & 9 & 39 & 8 & \infty & \infty \\
 \infty & 0 & 19 & \infty & \infty & \infty \\
 \infty & \infty & 0 & \infty & 30 & 23 \\
 \infty & \infty & \infty & 0 & 17 & \infty \\
 \infty & \infty & \infty & 17 & 0 & 12 \\
 \infty & \infty & \infty & \infty & \infty & 0
 \end{vmatrix} \quad (16)$$

利用本文的Hopfield网络模型,当网络边 $1 \rightarrow 4$ 、 $2 \rightarrow 1$ 不复存在时,我们只需将其对应的 $\rho_{14}$ 、 $\rho_{21}$ (公式(6))置为“1”即可.各网络边的费用的改变也只需将其代入相应的 $C_{xi}$ 项,由于 $\rho_{xi}$ 、 $C_{xi}$ 、只在网络的偏置电流 $I_{xi}$ (公式(14))中出现,因此不需要改变神经网络的内部结构就能得到网络稳态时的输出结果,如图4所示.

	0	1	2	3	4	5
0	X	0	0	1	0	0
1	0	X	0	0	0	0
2	0	0	X	0	0	0
3	0	0	0	X	1	0
4	0	0	0	0	X	1
5	1	0	0	0	0	X

图4 拓扑结构和费用改变后的神经网络输出结果

从图4输出结果可看出,网络边 $0 \rightarrow 3$ 、 $3 \rightarrow 4$ 、 $4 \rightarrow 5$ 以及 $5 \rightarrow 0$ 在最短路径上,总费用为37,这与实际情况是相吻合的.

#### 4 结束语

本文提出一种基于Hopfield神经网络的最短路径计算的新方法,与传统的Dijkstra算法相比,具有不需要改变神经网络结构的内部参数便能实时调整算法来适应网络边的费用及其图的拓扑关系的改变的特点.仿真结果表明,该算法适用于拓扑结构和费用都在动态变化的城市交通线路上自主车辆的智能导航系统.本方法只是人工神经网络在城市交通地理网络的路径导航系统中的初步尝试,有一些问题(比如,如何对各惩罚系数的规律性选取问题等等)有待进一步研究.

#### 参 考 文 献

- 1 徐爱功等. 车辆自动定位导航系统的基本模式与技术问题. 测绘通报, 1996. 4
- 2 David E Kaufman, Jason Nonis, Robert L Smith. A Mixed Integer Linear Programming Model for Dynamic Route Guidance. Transpn Res B, 1998, 32(6): 431- 440
- 3 朱战立, 李文. 数据结构- 使用C语言. 西安交通大学出版社, 1997
- 4 Dijkstra E W. A Note on two Problems in Connection with Graphs. Numerical Mathematics 1995, 1: 269- 271
- 5 Roy Glasius, Andrzej Komoda. Stan C A M Gielen. Neural Network Dynamic for Path Planning and Obstacle Avoidance. Neural Network, 1995, 8(1)
- 6 Ali H K, Kamoun F. Neural Networks for Shortest Path Computations and Routing in Computer Networks. IEEE Trans on Neural Networks, 1993, 4(6): 941- 953

7 焦李成. 神经网络计算. 西安电子科技大学出版社, 1995

## NEURAL-BASED ALGORITHM FOR AUTONOMOUS VEHICLE ROUTE GUIDANCE SYSTEMS

ZHOU Jie ZHAI Yujian

(*Department of Instrument Science and Engineering, Southeast University, Nanjing 210018*)

**Abstract:** This paper presents a new algorithm for the autonomous vehicles' shortest path computing based on the Hopfield neural networks. Besides the higher computation speed, the algorithm can adapt in real time to changes in network topology and link costs without modifying the internal parameters of the neural network architecture. It can be applied to autonomous vehicles for urban route guidance systems.

**Key words:** Hopfield neural networks; shortest path problem; route guidance systems; autonomous vehicle.

作者简介:

周 捷 (1969-), 博士. 研究领域: 神经网络、车辆导航等.

---

(上接第 362 页)

## OPTIMAL CONTROL OF NONHOLONOMIC MOTION OF SPACE MANIPULATORS USING GENETIC ALGORITHM BASED ON WAVELET APPROXIMATION

ZHANG Qi-zhi GE Xin-sheng

(*Beijing Institute of Machinery, Beijing 100085*)

LIU Yan-zhu

(*Shanghai Jiaotong University, Shanghai 200030*)

**Abstract:** The problem of nonholonomic motion planning of space manipulator system is discussed, and it is transformed into optimal control of nonlinear system. The control input rule is approximated by wavelet. The genetic algorithm of optimal control for nonholonomic motion planning of space manipulator is proposed. Numerical simulation indicates that the union of wavelet approximation and genetic algorithm is effective for optimal control problem.

**Key words:** Optimal control; wavelet; genetic algorithm; space manipulator

作者简介:

张奇志 (1963-), 男, 副教授. 研究领域: 机械臂模型与控制.

戈新生 (1957-), 男, 教授. 研究领域: 多体系统动力学与控制.