

自动波竞争神经网络及其在单源最短路问题中的应用*

董继扬^{1,2)} 张军英²⁾ 陈 忠¹⁾

1) 厦门大学物理系, 福建省半导体照明工程技术研究中心, 厦门 361005)

2) 西安电子科技大学雷达信号处理国家重点实验室, 西安 710071)

(2006 年 11 月 27 日收到, 2006 年 12 月 30 日收到修改稿)

将竞争机理引入网络的自动波产生与传播过程中, 提出自动波竞争神经网络(ACNN)模型, 并成功地应用于求解单源最短路问题, 给出了基于 ACNN 的最短路求解算法. 与其他神经网络最短路算法相比, 基于 ACNN 的最短路算法具有网络所需的神经元数目少、神经元及网络的结构简单、易于软硬件的实现、以及全并行方式计算等特点, 可用于求解非对称赋权图的最短路径树问题, 且其计算时间(迭代次数)仅正比于最短路径上的跃点数, 与赋权图的复杂度、路径总长、边长的精度、通路总数等因素无关. 计算机仿真结果表明该算法的有效性和快速求解能力.

关键词: 单源最短路问题, 自动波竞争神经网络, 脉冲耦合神经网络

PACC: 0210, 0270

1. 引 言

现实生活中的交通、运输、通讯、计算机等各种复杂网络均可以抽象为一个赋权图模型. 最短路问题是网络理论中应用最广的问题之一, 例如日常生活中的交通运输路线选择、线路铺设、计算机网络路由选择及管道铺设等优化问题均可以转化成赋权图中最短路问题的求解. 自 1959 年 Dijkstra^[1]提出了第一个简单、实用的最短路径求解算法以来, 人们对最短路径问题进行了深入地研究, 提出各种最短路算法^[2-5], 但现有大多数算法的实用性、计算复杂度以及在硬件实现等方面还没有新的突破, 因此, 目前用得最多的还是传统的 Dijkstra 算法或其改进算法. 但随着研究问题的深入, 特别是目前正在兴起的复杂网络理论的研究^[6,7], 传统串行方式的 Dijkstra 算法的局限性日益突出, 因此, 有必要发展一种简单的、实用的、易于硬件实现的最短路径算法.

人工神经网络是近几十年发展起来的一类仿生的计算方法, 它具有内在的并行性, 可方便地用于大规模的复杂问题的求解^[8,9], 因而越来越受到研究者的重视. 自然地, 人们也将最短路径问题诉诸于人工神经网络方法, 而且取得了一些令人满意的成

果^[8-15]. 典型的是以 Hopfield 模型神经网络(简称 Hopfield NN)为代表的反馈型神经网络的最短路求解算法^[10]. Hopfield NN 本质是将最短路问题转化成优化问题, 即利用反馈网络在运行过程中, 其能量随时间不断下降这一特性, 将路径最短这一目的转化成约束条件, 构造网络的能量函数, 使得能量函数的全局极小点对应最短路的最优解. 给定初始状态, 网络依能量递减方向逐步收敛于最短路的解. 但是, 反馈网络能量函数的设计事实上需要很高的技巧, 能量函数若设计不好, 网络将容易落入能量的局部极小点, 从而得不到最优解, 而且, 即使网络能量函数设计得好, 随着待解决问题规模的增加, 网络也极易落入能量的局部极小点. 此外, Hopfield NN 在求解最短路问题时, 网络的规模较大(需要 n^2 个神经元, n 为最短路问题的节点数). 近年来虽然提出了多种改进的算法, 减小了网络规模, 但网络的能量局部极小的问题仍然得不到很好的解决, 问题最优解得不到保证. 此外, 这种反馈型网络收敛到能量极小点所需的迭代次数比较大. 因此这种基于量函数设计的反馈神经网络最短路算法仍有待于进一步的研究.

1999 年, Caulfield 和 Kinser 将脉冲耦合神经网络(pulse-coupled neural network, PCNN)成功地应用于

* 国家自然科学基金(批准号: 10605019)和国家高技术研究发展计划(863)(批准号: 2006AA03A175)资助的课题.

迷宫问题的求解中^[8]。脉冲耦合神经网络是根据猫的大脑视觉皮层脉冲同步发放现象,提出的一种神经网络模型^[11]。PCNN 在运行过程中,神经元之间相互激励,引发同步点火现象,类似于物理上的波动在介质中的传播,通常用“自动波(Autowave)”描述 PCNN 的这种同步点火现象。迷宫问题是一种最短路的典型问题。Caulfield 和 Kinser 将迷宫路径的每一个单位长度(即最小单位距离)对应 PCNN 的一个神经元,让迷宫起点的神经元最先点火,即发放脉冲,产生自动波在迷宫上匀速传播。因此,离起点越近越先点火,而最先到达终点的自动波所走过的路径就是迷宫的最优解,即从起点到终点的最短路。这种算法的优点是网络神经元间的连接权不需要训练,只要阈值衰减函数的参数选择恰当,使得网络每次迭代,自动波向前传播一个最小单位距离,则网络所获得的解均为最优解。但该算法有以下三个方面的不足:一是网络规模特别大,因为网络神经元与迷宫路径上单位距离是一一对应的,即使是一个小型的迷宫问题,网络规模都将非常庞大而难于实现;二是网络的迭代次数特别大,由于匀速传播的需要,自动波每传播一个单位长度就需要一次的迭代,当迷宫路径较长时,网络的迭代次数也很大;三是算法不能用于具有负值权重的图的最短路搜索。上述缺点限制了 PCNN 方法在实际最短路问题中的应用。

PCNN 的方法虽然计算复杂度高,但它为最短路问题的求解提供了一种全新的思路。为了解决 PCNN 方法中网络规模大的问题,张军英等人^[12]在 PCNN 算法的基础上提出了一种基于自动波传播特性的网络模型——输出-阈值耦合神经网络(OTCNN)。OTCNN 的思想是构造一个与赋权图同构的网络,即顶点与神经元一一对应,神经元间的连接权与顶点间的连接权一一对应。用神经元间的耦合作用模拟自动波的传播特性,并让起始神经元首先点火,产生一个自动波沿各边方向传播开来,通过神经元阈值衰减特性的控制,使得自动波从一个神经元传到另一个神经元的时间正比于它们之间的连接权的大小。这样,离起始神经元越近的神经元越早点火。当所有神经元点火都后,通过路径回溯,就可以得到整个最短路径树了。该算法所需神经元数目仅为赋权图的顶点数(N),克服了反馈神经网络算法(N^2)和 PCNN 算法(迷宫总路径长度)在空间上的复杂度。但是,由于网络的离散性,该算法需要人工地选择自动波传播的时间步长 Δt ,步长太大可能造

成所求得解不是全局最优解,步长选择太小又会大大增加网络的迭代次数(即运行时间)。网络的最小迭代次数不仅与连接权的精度有关(精度越高运行时间越大),还与起始节点到终点间的最短路长度有关,路径越长运行时间也越大,此外,由于网络的时间特性使得该算法不能用于具有负值权重的图的最短路搜索。换句话说,OTCNN 只克服了 PCNN 中的空间复杂度问题,仍然遗留着时间复杂度问题,所以不太适用于大型网络。

顾晓东等人^[13]在 PCNN 的基础上提出了时延 PCNN(D-PCNN)模型。本质上,D-PCNN 与 OTCNN 是一致的,只是实现方法上略有区别。D-PCNN 是在信号传入神经元前加入时延(即让两个相连神经元之间的时延为这两个神经元之间的路径的长度),而 OTCNN 是通过神经元阈值衰减特性的控制达到时延的效果。在算法意义上,D-PCNN 和 OTCNN 具有相同的优缺点。此外,宋寅卯等人^[14]和纪其进^[15]也分别对 PCNN 做了适当的改进(mPCNN),并用于最短路的问题中,但其算法思想与 OTCNN,D-PCNN 没有本质上的区别,都是在神经元中引入时延,控制自动波的传播速度,使得自动波传播时间与路径长度成正比。迭代时间过长仍然是这些算法的缺点。

综合上述分析可见,PCNN,OTCNN,D-PCNN 及 mPCNN 的自动波均有沿连接边匀速传播的特点,正是这个匀速传播机理,使得网络的迭代时间正比于路径的长度和精度,从而导致网络的迭代次数多、计算复杂度高问题。为此,本文在 OTCNN 的基础上,进一步改进了网络自动波的产生与传播机理,提出了自动波竞争神经网络模型(autowave-competed neural network, ACNN)。首先,ACNN 继承了 OTCNN 构造的方法,即网络的拓扑结构与待求赋权图同构,从而最大限度地降低了网络结构复杂度。其次,ACNN 抛弃了 OTCNN 对神经元点火次数的限制,引入了自动波竞争机理。即在网络运行过程中,神经元可以多次点火,但神经元是否点火则由自动波之间的竞争结果决定;此外,ACNN 抛弃了 OTCNN 中自动波沿连接边匀速传播的思想,引入了自动波的路径累积思想。即网络迭代一次,自动波传播一条边的距离,并让自动波在传播过程中进行路径累积,从而大大地减少了网络的运行时间。基于 ACNN 的最短路算法以并行的方式运行,理论和实验都证明了它能以极少的迭代次数获得全局最优解。值得一提的是,基于 ACNN 的最短路算法还可以求解具有

负权的正有向圈图的最短路问题,这是 PCNN, OTCNN, D-PCNN 等其他神经网络方法无法实现的。

本文第 2 节描述单源最短路问题的一些基本概念,第 3 节给出 ACNN 的神经元模型、ACNN 的运行机理及基于 ACNN 的最短路算法;第 4 节给出几个最短路的例子,用计算机模拟的方法,对基于 ACNN 和基于 OTCNN 两种最短路算法进行比较与分析,最后对基于 ACNN 的最短路算法进行一些总结与讨论。

2. 单源最短路径问题

一个有向赋权图可记为 $G=(V,E,W)$,其中 $V=\{v\}$ 为顶点集、 E 为有向边集、 $W=[w_{ij}]$ 为权重矩阵。 w_{ij} 表示边 (i,j) 上的权值,它不但可以取正值,还可以取负值。在实际应用中,正权值常用于表示损失,而负权值表示收益。对于有向赋权图, w_{ij} 不必等于 w_{ji} , 此时 W 为非对称矩阵。本文用 $w_{ij}=\infty$ 表示顶点 i,j 之间没有边相连的情况。

单源最短路问题是最典型、最常见的最短路问题,它是寻找从源节点 r 到其他节点的最短路径。所谓的“最短”,可以是路径中包含的边的数目最少,也可以是路径中的所有边的权重之和最小等不同的含义。但一般的最短路问题都可以转换成“权值之和最小”的最短路问题,不失一般性,本文只讨论这一类型的最短路问题。

设 $v \in V$ 为源节点 r 的可达节点, $P(r,v)=\{p(r,v)\}$ 为 r 到 v 的路径集,设 $P^*(r,v)$ 为最短路,其距离为 $dis(v)$, 则有

$$dis(v) = \min \left\{ \sum_{(i,j) \in p(r,v)} w_{ij} \mid p(r,v) \in P(r,v) \right\}. \tag{1}$$

寻找 r 到 v 之间的最短路 $P^*(r,v)$ 可以形象地描述为如下的线形规划问题:

$$\text{最小化} \quad \sum_{i=1}^n \sum_{j=1}^n w_{ij} x_{ij}, \tag{2}$$

$$\text{满足} \quad \sum_{j=1}^n x_{ij} - \sum_{i=1}^n x_{ik} = \begin{cases} 1 & k=r, \\ 0, & \text{其他}, \\ -1, & k=v, \end{cases} \tag{3}$$

$$x_{ij} \in \{0,1\}, \quad i,j \in V.$$

(2) 式为目标函数,即路径最短,(3) 式为约束条件, x_{ij} 称为决策变量,其含义为:如果边 (i,j) 在所求的路径上,则 $x_{ij}=1$, 否则 $x_{ij}=0$ 。(3) 式保证了所求

路径的每一段均为图 G 中的一条且仅有一条边。我们可以用标准的线性规划方法求解最短路问题,但随着问题规模的增大,求解代价也不断增加,甚至得不到问题的最优解。

从源节点 r 到图中其他各节点的最短路构成一棵树,称为最短路径树,记为 T_r , 即

$$T_r = \bigcup_{v \in V} P^*(r,v),$$

称源节点 r 为最短路径树 T_r 的根(root)。可见, T_r 是图 G 的子图,即 $T_r \subset G$ 。

大部分的单源最短路算法都能求得以源节点 r 为根的最短路径树 T_r , 因此,大部分的文献中均不区分最短路和最短路径树问题。

3. 自动波竞争神经网络及最短路算法

针对单源最短路问题,借鉴 PCNN 与 OTCNN 的自动波产生与传播的思想,并引入自动波的竞争机理,提出了自动波竞争神经网络模型。下面借助自动波的概念,介绍自动波竞争神经网络的设计思想。

自动波竞争神经元是自动波的产生与整合(竞争)的地方,如图 1 所示。神经元模型包括三个部分:输入整合器、点火发生器和阈值更新器。

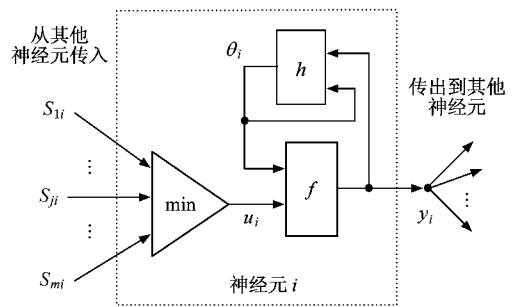


图 1 自动波竞争神经元模型

一是输入整合器:其功能是对周围神经元传播来的自动波 $\{s_{1i}, \dots, s_{mi}\}$ 进行整合,具有最小强度的自动波作为该神经元的内部激活势 u_i , 即

$$u_i(t) = \min_{j \in V} \{s_{ji}(t)\}. \tag{4}$$

这一过程相当于 t 时刻到达神经元 i 的自动波相互竞争,具有最小强度的自动波将获得胜利,并继续传播到神经元 i 的内部。

二是点火发生器:其功能是对神经元的内部激活势 u_i 和阈值 θ_i 进行比较,比较结果决定该神经元

是否点火,即

$$y_i(t) = f(\theta_i(t-1), u_i(t)) = \begin{cases} u_i(t), & u_i(t) < \theta_i(t-1) \\ \infty, & u_i(t) \geq \theta_i(t-1), \end{cases} \quad (5)$$

f 为神经元的激活函数. y_i 等于一个有限值时,表示神经元 i 处于激活状态(点火), $y_i = \infty$ 表示神经元处于抑制状态(在软件或硬件实现时,可选择一个特殊值或充分大的值来表示神经元的抑制状态).

这一过程相当于:若进入神经元 i 的自动波 $u_i(t)$ 的强度小于阈值 $\theta_i(t-1)$,则神经元 i 被激活,神经元 i 将作为一个新的自动波波源产生强度为 $y_i(t) = u_i(t)$ 的自动波向外传播;否则自动波 $u_i(t)$ 将在神经元 i 内部消亡.而此处的阈值 $\theta_i(t-1)$ 正是上一次激活该神经元的自动波的强度(见阈值更新器的说明)因而“ $u_i(t)$ 与 $\theta_i(t-1)$ 的比较”也可视为“当前到达的自动波与上一次通过的




图 2 自动波竞争神经网络的构造 (a)待求问题的图;(b)自动波竞争神经网络

自动波传播规则:对于最短路径问题,我们希望自动波在网络的传播过程中,能体现该自动波传播路径的长短,因此,我们让自动波在传播的过程中进行路径累积.如图 2 所示,在神经元的连接边上加入路径累积器,让自动波通过该连接边时进行路径累积,即增强该自动波的强度,

$$s_{ji}(t) = \begin{cases} y_j(t-1) + w_{ji}, & y_j(t-1) < \infty, \\ \infty, & \text{其他.} \end{cases} \quad (7)$$

我们称由上述网络为 ACNN. 基于 ACNN 的最短路径求解算法如下:

步骤 1 初始化:即设 $u_i(0) = \infty$, $y_i(0) = \infty$, $\theta_i(0) = \infty$, $\forall i \in V(G)$;

步骤 2 网络激活:让 $y_r(1) = 0$, $\theta_r(1) = 0$,使起始神经元 r 点火,网络开始运行;

步骤 3 自动波传播:按(4),(5),(6)(7)式

自动波的竞争”.

三是阈值更新器:其功能是用阈值 θ_i 保存被激活神经元的输出 y_i . 若当前时刻神经元 i 被激活,则用其输出值更新阈值,否则保持阈值不变,即

$$\theta_i(t) = h(y_i(t), \theta_i(t-1)) = \begin{cases} y_i(t), & y_i(t) < \infty, \\ \theta_i(t-1), & \text{其他,} \end{cases} \quad (6)$$

其中 h 称为阈值更新函数. 由于被激活神经元的输出等于通过该神经元的自动波强度 $y_i(t) = u_i(t)$,因此(6)式表明阈值 θ_i 的作用是记录最近一次通过神经元 i 的自动波的强度.

(4)式(5)式和(6)式描述了自动波竞争神经元的功能,即自动波的产生和竞争的规则.在求解单源最短路径问题时,可将上述神经元按待求问题的拓扑结构连接成一个网络,这时,我们还需规定自动波在连接边上的传播规则.

计算神经元的状态,并以迭代的方式进行;

步骤 4 结束条件:重复步骤 3,直到网络不再有神经元点火为止;

步骤 5 路径回溯:若神经元 i 的阈值与神经元 j 的阈值满足 $\theta_i = \theta_j + w_{ji}$,则让 $x_{ji} = 1$,否则让 $x_{ji} = 0$. 这样便能求得最短路径树 T_r .

下面借用 PCNN 中的自动波概念,解释 ACNN 求解最短路径树问题的物理思想.

(4)式和(7)式可以解释为:1)当自动波从神经元 j 传播到神经元 i 时,其强度增大了 w_{ji} . 若将连接权 w_{ji} 解释为节点 j 到节点 i 的路径长度,则说明,自动波在传播的过程中进行了路径的累积,而如果自动波产生时的初始强度为 0,则网络中自动波的强度就是该自动波所走过的路径长度. 2)在同一时刻,若有多列自动波传播到神经元 i ,则它们发生竞争,强度最小(即所传播的总路径最短)的自动波获

胜 获胜的自动波强度作为神经元 i 的内部激活势 , 而其他自动波就消亡了 .

(5)式表明 ,在竞争中获胜的自动波能否激活神经元 i 并继续往前传播 ,取决于该自动波的强度是否比神经元 i 的阈值小 . 若神经元 i 被激活 ,则神经元 i 输出的大小就是该自动波的强度 ,自动波便沿着与神经元 i 相连的各条前向边 ,继续往其他神经元传播 ;若神经元 i 不被激活 ,则输出为无穷大 (相当于自动波的传播路径在神经元 i 处断开) .

(6)式表明神经元的阈值是否更新取决于该神经元是否被激活 . 若神经元被激活 ,则其阈值就等于神经元的输出值 (即通过该神经元的自动波的强度) ,否则阈值不被更新 . 而(5)式已表明 ,神经元是否被激活取决于到达该神经元的自动波的强度是否比原阈值小 . 这说明了神经元在 t 时刻的阈值记录了“在 t 时刻之前通过该神经元的最小强度的自动波 .”

ACNN 与传统意义上的神经网络 (如多层感知机)存在如下差异 :首先 ,在 ACNN 中 ,神经元输入是其他神经元的输出与它们之间连接权的累积 ,而在传统神经网络中 ,神经元的输入是其他神经元的输出与它们之间连接权的乘积 ;其次 ,在 ACNN 中 ,当神经元有多个输入时 ,这些输入进行竞争 ,幅值最小

的输入获胜 ,并作为该神经元的内部激活 ,而在传统神经网络中 ,神经元的内部激活是所有输入权重的总和 ;此外 ,在 ACNN 中 ,神经元的阈值随时间改变 ,阈值的功能是记录神经元最近一次点火的强度 (输出值) ,而在传统神经网络中 ,神经元的阈值不随时间改变 .

4. 实验与结果

大量的计算机仿真结果表明 ,采用基于 ACNN 的最短路求解算法 ,可以迅速而准确地找到源节点到图中所有其他节点间的最短路径 ,即 T_i . 图 3 是仿真中的一个例子 ,该图是一个具有 17 个顶点、25 条边的赋权无向图 ,边上的数字为与边对应的路径的长度 ,圆圈代表节点 ,圆圈中的数字代表节点标号 . 现在用基于 ACNN 的最短路求解算法 ,求图 3 (a)中节点 1 到其他节点的最短路径 ,结果如图 3 (b)所示 .

我们以图 3(a)为例 ,对基于 ACNN 和基于 OTCNN 的最短路求解算法进行计算机仿真实验 ,比较结果如表 1 所示 . 其中 ,OTCNN 的迭代步长按文献 [11] 的选取规则 ,取路径长度的精度的一半 ,即 $\Delta t = 0.5$.




图 3 (a) 一个赋权图 ;(b) ACNN 的搜索结果

表 1 图 3(a)中以节点 1 为源的最短路求解结果比较

源节点	目的节点	最短路	路径长度	OTCNN 迭代次数	ACNN 迭代次数
1	4	1→2→3→4	18	40	4
1	14	1→7→11→12→14	17	39	5
1	15	1→15	8	17	2
1	9	1→7→8→9	21	46	4

注 :虽然神经网络是以并行方式运行的 ,但在仿真程序中却是以串行方式运行的 ,而且两者之间的耗时区别与路径图的具体结构有关 . 因此 ,以仿真程序的迭代次数做比较 ,而不以程序运行的具体耗时做比较 .

从表 1 可见,基于 ACNN 和基于 OTCNN 两种最短路算法都能准确地找到所有的最短路. 基于 ACNN 的最短路算法所需的迭代次数等于最短路径的跃点数,而与路径的长度以及长度的精度无关,因此,基于 ACNN 的算法完成最短路径树 T_1 的搜索仅

需 5 次迭代,见图 3(b). 而基于 OTCNN 的最短路算法的迭代次数与路径的长度成正比,而且精度越高,迭代次数也越大. 表 1 结果显示,ACNN 比 OTCNN 的迭代次数少得多.

为了进一步验证 ACNN 最短路算法,我们采用




图 4 (a) 100 个顶点的无向图;(b) 源节点在中间的最短路树;(c) 源节点在右下方的最短路树

文献 [12] 的例子,即搜索随机生成的图的最短路径树. 图的生成方法是在一个边长为 D 的正方形内以均匀分布随机生成 N 个点作为图的顶点,每一顶点仅与那些与其距离小于等于 $25\% D$ 的顶点有边相连,且边的权为对应顶点之间的几何距离(欧氏距离). 图 4(a) 为边长 $D = 50$ 的正方形内随机均匀分布 100 个顶点的连接图,距离的精度取 0.1,以图中任一顶点为起始点,用 ACNN 算法搜索该图的最短路径树,图 4(b) 为起始点在图中间的一个最短路径树例子,所得的最短路径树与文献 [12] 的结果相同,但 OTCNN 需要 473 次的迭代才能完成搜索,而 ACNN 只需要 6 次迭代就完成了搜索;图 4(c) 为起始点在右下方的一个最短路径树例子,所得的最短路径树也与文献 [12] 的结果相同,但 OTCNN 需要 738 次的迭代才完成搜索,而 ACNN 只需要 10 次迭代就完成了搜索. 可见 ACNN 比 OTCNN 快得多.

5. 总结与讨论

本文改进了 PCNN 和 OTCNN 的自动波传播特性,提出基于累积-竞争的自动波传播思想,并在此基础上建立了自动波竞争神经网络模型,给出基于自动波竞争神经网络的最短路径树搜索算法,解决了 PCNN 在搜索赋权图最短路径树时所存在的空间和时间复杂性问题. 与其他神经网络方法相比,利用 ACNN 搜索赋权图最短路径树的算法具有如下特点:

1. 在搜索赋权图最短路时,PCNN,OTCNN,D-

PCNN 和 ACNN 等网络都不同程度地利用了自动波的产生与传播特性:PCNN 是用神经元之间的点火激励来产生自动波,并用神经元见的点火接力来模拟自动波的匀速传播,因此,用 PCNN 的求解最短路径问题时,需要在每条路径上排满神经元,这使得网络的规模非常大,网络的迭代次数也非常大;OTCNN 则是通过对神经元阈值函数线性衰减特性的设计,并适当地选择步长 Δt ,使得神经元 i 的点火后,经过网络的 $w_{ij}/\Delta t$ 次迭代神经元 j 也点火,即通过网络的迭代运行来模拟自动波在边权上的传播过程. 与 PCNN 相比,OTCNN 省掉了每条路径上的神经元,因此,网络规模大大减小了,但迭代次数没有得到改善;D-PCNN 和 mPCNN 与 OTCNN 在本质上是相同的,因此,求解最短路时仍需要很多的迭代次数. 而在 ACNN 中,自动波不是依图的边权匀速传播,而是通过神经元的“通过-抑制”特性的设计实现波的传播,波动从一个顶点传播到与其相邻的下一个顶点只需一次迭代,因此,网络的规模和迭代次数都大大地降低了.

2. 基于 ACNN 的最短路算法所需的迭代次数仅与最短路所包含的节点数有关,而与图的结构复杂性,如图的顶点数目、边的数目、边权的大小和精度、图中的路径总数等参数无关,更不必考虑迭代步长 Δt 的选择问题. 而基于 PCNN,OTCNN,DPCNN 或 mPCNN 等算法所需的迭代次数均与最短路的路程成正比,因此,ACNN 搜索算法的迭代次数要比其他算法少得多.

3. ACNN 网络是以全并行方式运行的,且由于 ACNN 网络与所求解的问题对象,即赋权图 G 同构,

因此,与其他神经网络算法(如 Hopfield 网络, OTCNN, PCNN 等)相比,ACNN 算法不管在时间复杂度上(迭代次数),还是在空间复杂度上(网络结构)都是最小的。

4. 在交通、通讯、运输等实际网络中,拓扑结构参数经常会发生变化,如何快速地获得变化后的最短路径树这个问题得到了越来越多的重视。利用本文方法无需重新搜索整个最短路路径树,而只需对最短路路径树进行局部修改。

5. ACNN 易于硬件实现。PCNN 神经元是基于积

分-点火的特性,其阈值函数为指数衰减函数,因此在神经元的构造上需要积分器。OTCNN 神经元是基于阈值衰减的点火特性,其阈值函数为线性衰减函数,因此在神经元的构造上也有一定的困难。D-PCNN 则需要在每条路径上设计一个与路径长度相关的延时器,网络复杂且可移植性不好。然而 ACNN 的神经元阈值与时间无关,仅需要一个数值累加器,显然 ACNN 神经元的结构要比 PCNN, OTCNN 及 D-PCNN 等网络的神经元结构简单和易于实现,且可移植性好。

-
- [1] Dijkstra E W 1959 *Operations Research* **17** 395
- [2] Floyd R 1962 *Commun. ACM* **5** 345
- [3] Abram J, Rhodes I 1982 *IEEE Trans. on AC* **27** 570
- [4] Araujo F, Ribeiro B, Rodrigues L 2001 *IEEE Trans. on NN* **12** 1067
- [5] Xu D, Chen Y, Xiong Y *et al* 2006 *IEEE/ACM Trans. on Networking* **14** 147
- [6] Zhao W, He H S, Lin Z C *et al* 2006 *Acta Phys. Sin.* **55** 3906 (in Chinese) [赵 伟、何红生、林中材等 2006 物理学报 **55** 3906]
- [7] Li Y, Shan X M, Ren Y 2004 *Acta Phys. Sin.* **53** 3695 (in Chinese) [李 山、山秀明、任 勇 2004 物理学报 **53** 3695]
- [8] Caulfield H J, Kinser J M 1999 *IEEE Trans. on NN* **10** 604
- [9] Xiong T, Zhang B, Chang S *et al* 2005 *Acta Phys. Sin.* **54** 2435 (in Chinese) [熊 涛、张便利、常胜江等 2005 物理学报 **54** 2435]
- [10] Ahn C W, Ramakrishna R S, Kang C *et al* 2001 *Electronics Letters* **37** 1176
- [11] John J L, Ritter D 1993 *J. Opt. Lett.* **18** 1253
- [12] Zhang J, Wang D, Shi M 2003 *Sci. in China Ser. E* **33** 522 (in Chinese) [张军英、王德峰、石美红 2003 中国科学 E 辑 **33** 522]
- [13] Gu X, Yu D, Zhang L 2004 *Acta Elect. Sin.* **32** 1441 (in Chinese) [顾晓东、余道衡、张立明 2004 电子学报 **32** 1441]
- [14] Song Y, Yuan D 2005 *J. Cir. and Sys.* **10** 72 (in Chinese) [宋寅卯、袁端磊 2005 电路与系统学报 **10** 72]
- [15] Ji Q 2005 *Mini-Micro Sys.* **26** 826 (in Chinese) [纪其进 2005 小型微型计算机系统 **26** 826]

Autowave-competition neural network and its application to the single-source shortest-paths problem *

Dong Ji-Yang^{1,2)} Zhang Jun-Ying²⁾ Chen Zhong¹⁾

¹ *Department of Physics, Fujian Engineering Research Center for Solid-State Lighting, Xiamen University, Xiamen 361005, China*

² *National Key Laboratory for Radar Signal Processing, Xidian University, Xi'an 710071, China*

(Received 27 November 2006 ; revised manuscript received 30 December 2006)

Abstract

In this paper, the competitive mechanism is introduced to the production and propagation processes of the autowave of neural network. The autowave-competition neural network (ACNN) is proposed to successfully resolve the problem of single-source shortest paths (SSSP). The algorithm for shortest paths based on ACNN is presented. Compared with other neural network based approaches, the new algorithm has the following advantages: less number of neurons needed, simple structure of neurons and networks, readily available software and hardware. When ACNN is employed to resolve the shortest path problem, the computational complexity is only related to the hop number of the shortest path, but independent of the complexity of path graph, the number of the existing paths in the graph and the precision of the length of edges. Simulations show that the proposed algorithm is plausible and effective.

Keywords : single-source shortest path, autowave-competition neural network, pulse-coupled neural network

PACC : 0210, 0270

* Project supported by the National Natural Science Foundation of China (Grant No. 10605019) and the " 863 " Project of National Ministry of Science and Technology (Grant No. 2006AA03A175).