

文章编号:1007-6735(2013)06-0552-05

基于灰色神经网络的道路权重确定方法

蔡 强, 陈 亚, 李海生, 曹 健

(北京工商大学 计算机与信息工程学院, 北京 100048)

摘要: 提出了一种基于灰色神经网络的道路权重确定方法. 首先利用灰色预测模型少数据建模和人工神经网络模型非线性逼近的优点, 将两种模型有机结合, 实现对交通流的模拟预测; 其次利用交通流量-行驶速度以及行驶速度-行驶时间的关系确定交通流量与行驶时间的关系模型; 最后结合前两部分建立的模型构建基于灰色神经网络的路阻函数模型, 从而确定路段的权重. 实验结果表明, 该方法具有较高的精度, 且模型利用少量的数据就可以确定路段的路阻函数, 为路段权值的确定提供了一种有效可行的方法, 可用于智能交通的路径规划等应用中.

关键词: 交通阻抗; 路径规划; 灰色模型; 神经网络

中图分类号: N 941.5; TP 183 **文献标志码:** A

Road Weight Evaluation Method Based on Grey Neural Network

CAI Qiang, CHEN Ya, LI Hai-sheng, CAO Jian

(College of Computer and Information Engineering, Beijing Technology and Business University, Beijing 100048, China)

Abstract: A road weight evaluation method based on grey neural network was proposed. The advantages of grey forecasting model, which is simple and needs less original data, and neural network were synthesized to establish the grey neural network model of traffic flow. The relationships between traffic flow, velocity and density were used to determine the relational model of flow and time. On these bases, the impedance function model and the weight of road sections were achieved. The experiment results show that the model has higher accuracy and only a few measurement data are needed to confirm the impedance function model of road sections. The model is an effective, feasible and convenient method for getting the weight of road sections. It can be applied in the road planning of intelligent transportation system.

Key words: traffic impedance; road planning; grey model; neural network

在智能交通系统中, 道路权值的确定将直接影响到最优路径选择的确定. 行驶时间作为反映交通状况的重要指标之一, 简单而直观, 便于理解与沟

通, 被交通专业人员和社会公众普遍接受和使用. 现以行驶时间最短为最优目标, 将表征路段行驶时间与交通流量之间关系的路阻函数作为道路权重.

收稿日期: 2012-10-30

基金项目: 北京市自然科学基金资助项目(4112016); 北京市属高等学校人才强教计划资助项目(PHR201008239)

第一作者: 蔡 强(1969-), 男, 教授. 研究方向: 计算机图形学、计算几何、科学可视化、智能信息处理.

E-mail: caiq@th.btbu.edu.cn

目前,国内外学者对于路阻函数提出了不同的函数模型,其中,较有代表性的有:美国联邦公路局 FHWA 模型——BPR (Bureau of Public Roads) 模型,该模型的优点是函数形式简单、通用性好,缺点是当路段上的实际交通流量超出路段的通行能力时,实测数据极少,难以进行回归分析^[1]; Davidson 建立的阻抗函数弥补了 BRP 函数缺乏渐进性的不足,但由于其参数标定的复杂和繁琐,所以,在一定程度上限制了 Davidson 函数的应用^[2];日本和德国交通部门提出的路阻函数模型,是在大量调查数据的基础上进行回归分析得到的,在使用之前必须要有大量的实际调查数据为前提.因此,研究如何利用少量的实测数据得到符合实际情况的路阻函数,从而确定路段的权值,是非常有意义的.

道路交通系统是一个有人参与的、时变的复杂系统,它的显著特点之一就是具有高度的不确定性^[3].这种不确定性不仅包括来自自然界环境的不确定性,如能见度、风向和温度等;而且有来自人为因素的原因,如交通事故、突发事件、司机的个人心理状态等.这说明道路交通系统是一个高度不确定性系统,这就给交通流的预测带来了困难.灰色系统理论主要研究的是信息量少的不确定性系统,主要通过少量有效数据信息的生成、开发提取有价值的信息,而且算法简单^[4].因此,本文利用灰色人工神经网络组合模型来模拟预测交通流量,再利用交通流量-行驶时间的关系确定路段的路阻函数.

1 灰色预测方法与人工神经网络

1.1 灰色 GM(1,1)模型

灰色系统理论是邓聚龙教授于 20 世纪 80 年代提出的一种新理论,利用数据生成的方法寻找潜在在数据中的规律,利用已知小样本、贫信息等不确定系统为研究对象来预测系统未知的信息,建模的精度较高,可保持原系统的特征,能较好地反映系统的实际情况,其灰色预测模型——GM(1,1)适于揭示对象发展变化的总趋势.现简述 GM(1,1)模型建模原理及方法^[5-6].

对于原始数据序列 $x^{(0)} = \{x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)\}$, GM(1,1)模型的一阶微分方程为

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = b \quad (1)$$

式中, a, b 为待辨识参数.

记方程的参数向量 $\hat{a} = [a, b]^T$, 按最小二乘法

原理求解,得

$$\hat{a} = \begin{bmatrix} a \\ b \end{bmatrix} = (B^T B)^{-1} B^T Y_n \quad (2)$$

其中

$$Y_n = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \vdots \\ x^{(0)}(n) \end{bmatrix}, \quad B = \begin{bmatrix} -z^{(1)}(2) & 1 \\ -z^{(1)}(3) & 1 \\ \vdots & \vdots \\ -z^{(1)}(n) & 1 \end{bmatrix} \quad (3)$$

式中, $z^{(1)}$ 为紧邻均值序列.

利用求解出的待辨识参数解微分方程,其离散事件相应函数为

$$\hat{x}^{(1)}(k+1) = \left(x^{(0)}(1) - \frac{b}{a}\right)e^{-ak} + \frac{b}{a}, \quad k = 1, 2, \dots, n \quad (4)$$

由于该模型是利用生成数据构建的模型,因此,必须对 $\hat{x}^{(1)}(k+1)$ 进行逆运算,还原为模拟数列 $\hat{x}^{(0)}(k), k = 1, 2, \dots, n$. 其中

$$\hat{x}^{(0)}(k+1) = \hat{x}^{(1)}(k+1) - \hat{x}^{(1)}(k) \quad (5)$$

由此可以得到残差序列为 $\epsilon = \{\epsilon(1), \epsilon(2), \dots, \epsilon(n)\}$.

$$\epsilon(k) = x^{(0)}(k) - \hat{x}^{(0)}(k) \quad (6)$$

灰色预测方法的优点是建模时所需样本数据少,不需要计算统计特征量,运算方便.实际上,在宏观能量系统中,指数增长规律是一种较常见的规律.因此,GM(1,1)模型在许多领域,尤其在不确定性明显(如农业、生态环境)和数据较少(如地震预报)的情况下得到了重视和应用.但是,灰色预测方法理论上只适合预测呈近似指数增长规律的数据序列,存在理论误差,许多文献曾经对此进行讨论和改进^[7-8].

1.2 人工神经网络

人工神经网络(ANN)是由大量称为神经元或节点的简单信息处理元件组成的,用以模拟人脑行为的复杂网络系统.多层节点与误差反向传播(BP)算法是目前一种比较成熟而又应用最广泛的人工神经网络模型. BP 网络是 Rumelhart 等于 1985 年提出的前馈型网络模型,采用一种有教师指导的学习过程.图 1(见下页)是一个 3 层 BP 网络,该网络由输入层、隐含层和输出层构成.整个训练过程由正向和反向传播过程组成.

BP 算法的学习规则是网络的输出误差判定采用最小二乘法,各层加权系数的调整基于梯度下降法.而隐含层的神经元一般采用 Sigmoid 函数作为激励函数. BP 算法的学习过程主要分为两个阶段^[9]:




图1 BP神经网络3层结构

Fig.1 BP neural network of three layers structure

第一阶段为信号的正向传播过程. 给定输入信息, 通过输入层经隐含层逐层计算, 最后计算出每个单元的实际输出值.

第二阶段为误差的反向传播过程. 若在输出层未能得到期望的输出值, 则逐层递归地计算实际输出与期望输出之间的误差均方差, 用于调节各层的加权系数, 即从输出层开始往前逐层采用梯度下降法修改加权系数, 以使输出的误差信号最小.

BP神经网络算法的流程框图如图2所示.




图2 BP神经网络算法计算流程框图

Fig.2 Flow diagram of the BP neural network algorithm

1.3 灰色 GM(1,1)模型与 BP 神经网络模型的互补性

虽然人工神经网络和灰色预测方法存在较大差异, 但是, 根据它们各自的特点, 又存在以下互补性^[10]:

a. 人工神经网络的优点是具有逼近任意函数的能力, 但有时会因过分逼近交通流曲线上的细节而影响泛化能力. 灰色预测方法不适合逼近复杂的非线性函数, 但能较好地预测交通流变化的总体趋势.

b. 人工神经网络虽然理论上具有逼近任意函数的能力, 但前提条件是有足够多的隐节点; 而较多的隐节点会导致神经网络参数增多, 相应地需要更多样本来训练神经网络. 在样本数量相对较少的情况下, 人工神经网络的优点难以充分发挥, 而灰色预测方法则能够利用少样本进行建模和预测.

因此, 将人工神经网络和灰色预测方法结合起来, 使它们互相取长补短, 构造性能更好的交通流预测方法是可行的.

2 基于灰色神经网络的路阻函数模型

现已提出的路阻函数多数采用经验回归模型. 对某一个具体路段, 通过大量观测数据回归确定其参数, 从而建立计算模型. 由于每个路段都有各自的模型参数, 若对每个路段都进行实际观测, 通过回归分析建立各自的路阻函数模型, 进度能满足, 但工作量很大. 虽然这种方法能够满足工程要求, 但是, 它的通用性差. 因此, 本文试图将灰色 GM(1,1)模型及神经网络的理论方法应用到路阻函数模型的研究中, 利用少量的实测数据, 建立路段的路阻函数模型, 从而确定该路段的权值.

2.1 建模思路

应用组合预测^[11-12]的思想, 将交通流量的灰色 GM(1,1)模型与残余信息的神经网络模型有机结合, 利用 GM(1,1)模型来模拟事件的发展趋势, 利用 BP 神经网络对 GM(1,1)模型的残差进行修正, 组合生成交通流的灰色神经网络模型^[13]. 再利用行驶时间-行驶速度、行驶速度-车流密度以及交通流量-车流密度-行驶速度之间的关系确定行驶时间与交通流量之间的关系. 模型的建模过程如图3所示.

2.2 路阻函数

设研究的路段长度为 L , 以路段行驶时间作为路阻, 则路段的路阻函数为

$$T = \frac{L}{V(Q)} \quad (7)$$

式中, Q 为交通流量; $V(Q)$ 是交通流量为 Q 时所




图3 基于灰色神经网络的路阻函数模型建模过程

Fig.3 Modeling process of the road resistance function model based on grey neural network

对应的路段平均行驶速度; T 为交通流量为 Q 时通过路段 L 所需行驶时间.

求解该模型的关键就是求出交通流量 Q 与路段平均行驶速度 V 之间的关系. 交通流量 Q 、行车速度 V 、车流密度 K 是表征交通流特性的 3 个基本参数, 其基本关系为

$$Q = VK \quad (8)$$

在通常的交通状态下, 速度和密度之间的关系可以利用 1933 年 Green 提出的线性模型^[14]来表示.

$$K = K_m - \frac{K_m}{V_m} V \quad (9)$$

式中, V_m 为畅行速度, K_m 为阻塞密度.

通过式(8)和式(9)可以推出

$$Q = K_m V - \frac{K_m}{V_m} V^2 \quad (10)$$

当流量 Q 满足 $0 \leq Q \leq \frac{V_m K_m}{4}$ 时, 可以推出速度 V 与流量 Q 之间的关系为

$$V = \frac{V_m}{2} \pm \frac{1}{2} \sqrt{V_m^2 - \frac{4V_m}{K_m} Q} \quad (11)$$

将交通流量当成一个统计指标, 按照行驶时间先后顺序排列形成一个序列 $\{Q(k)\}$, 其中, $k = 1, 2, \dots, n$. 交通流量的灰色 BP 神经网络模型为

$$\hat{Q}_k = \hat{Q}_k^{(0)} + \hat{\epsilon}_k \quad (12)$$

式中, $\hat{Q}_k$ 为交通流量模拟值; $\hat{Q}_k^{(0)}$ 表示交通流量的灰色 GM(1,1) 模型部分, 可认为是从原序列提取的交通流量的趋势信息; $\hat{\epsilon}_k$ 代表神经网络模拟部分,

可认为是交通流量的随机摆动信息.

利用灰色神经网络组合模型的建模方法可以得到交通流的模拟预测结果, 如式(12)所示, 再结合式(7), 即可得到基于灰色神经网络的路阻函数模型为

$$T_k = \frac{2L}{V_m \pm \sqrt{V_m^2 - \frac{4V_m}{K_m} \hat{Q}_m}} \quad (13)$$

式中, T_k 为 k 时间段内通过路段 L 所需行驶时间.

3 实例分析

3.1 源数据

选取由 Federal Highway Administration 提供的 2006 年 11 月 7 日 Peachtree Street 11 号路段由南向北方向 8 个行驶时间点的交通流量作为实验数据, 用 veh/15min 来表示 15 min 内通过该路段的车辆数单位, 如表 1 所示.

表1 Peachtree Street 11 号路段交通流量

Tab.1 Traffic flow of Peachtree Street 11

时间序号	时间段	交通流量/(veh · 15 min ⁻¹)
1	5:30—5:45	40
2	5:45—6:00	50
3	6:00—6:15	62
4	6:15—6:30	74
5	6:30—6:45	96
6	6:45—7:00	109
7	7:00—7:15	140
8	7:15—7:30	161
9	7:30—7:45	164
10	7:45—8:00	171
11	8:00—8:15	186
12	8:15—8:30	202
13	8:30—8:45	220

3.2 模型求解

设 $Q^{(0)}$ 为交通流量的行驶时间序列.

$$Q^{(0)} = (40, 50, 62, 74, 96, 109, 140, 161, 164, 171, 186, 202, 220)$$

根据 GM(1,1) 模型的建模方法建立交通流量的 GM(1,1) 模型为

$$\hat{Q}^{(0)}(k) = 63.93207e^{0.10898(k-1)} \quad (14)$$

式中, $k = 2, 3, \dots, n$.

根据该模型求出交通流量的灰色拟合值, 从中提取出灰色模型的残余信息, 得到残差序列 ϵ , 其中, $\epsilon(k) = Q^{(0)}(k) - \hat{Q}^{(0)}(k)$. 再对该残差序列进

行预处理得到新的数据序列 e , 其中, $e(k) = \frac{\varepsilon(k) - \bar{\varepsilon}}{\sigma_{\varepsilon}}$, $\bar{\varepsilon}$ 为残差序列的均值, σ_{ε} 为残差序列的均方差.

调用 Matlab 工具箱中有关 BP 神经网络函数, 编写网络训练程序, 对序列 e 进行仿真, 得到的仿真结果如图 4 和图 5 所示. 从图 4 中可以看出, 未经训练的 BP 网络与期望输出之间差距很大, 逼近效果很不理想, 而对 BP 网络训练之后的输出可以较精确地逼近目标期望, 且从图 5 可以看出, BP 网络的训练次数约 23 次, 网络的输出目标误差就达到了精度要求, 收敛速度很快.

将仿真得到的交通流量带入式(13), 可得到该路段的路阻函数, 即可确定该路段的道路权值.




图 4 序列 e 训练前后网络仿真结果比较

Fig.4 Comparison of network simulation results before and after the training of sequence e




图 5 BP 网络训练过程误差曲线

Fig.5 Error curve of BP network training process

3.3 结果分析比较

为了进行比较, 本文还用 GM(1,1) 模型和同样结构的神经网络对该路段的交通流量进行模拟预测. 这 3 种预测方法的模拟误差统计如表 2 所示, 仿真结果如图 6 所示. 由表 2 和图 6 可以看出, 灰色神经网络组合模型具有较好的拟合和预测能力, 能够取得比单一的 BP 神经网络或灰色 GM(1,1) 模型有

更好的拟合结果.

表 2 3 种方法对交通流量仿真的平均相对误差

Tab.2 Average relative error of traffic flow

simulation with the three methods (%)

模 型	平均相对误差	最大相对误差	最小相对误差
灰色 GM(1,1)	11.957 1	42.586 4	0.301 7
BP 神经网络	1.279 4	5.083 1	0.003 0
灰色 BP 神经网络	0.045 7	0.231 6	0.000 1




图 6 3 种模型仿真结果比较

Fig.6 Comparison of the simulation results with three kinds of models

4 结论与展望

针对智能交通系统路径规划中权值确定问题, 提出了一种基于灰色神经网络模型的道路权值确定方法. 实例结果表明, 与单一的灰色 GM(1,1) 模型和同结构的 BP 网络仿真结果比较, 运用灰色神经网络模型进行交通流量预测, 总体上具有更高的拟合精度, 说明将灰色神经网络模型应用在交通流量预测上是有效可行的. 在建立基于灰色神经网络的路阻函数模型时, 需要的数据量少, 而且计算简单, 这说明利用少量的实测数据就可得到符合实际情况的路阻函数, 从而确定路段的权值. 这为今后解决道路权值问题提供了一种新的思路.

由于路网中的道路交通流信息不断, 利用本文提出的灰色神经网络模型只适用于短期内的交通流预测, 因此, 下一阶段要解决的问题之一就是如何在模型中及时地补充和利用新的信息, 解决长期的交通流预测问题. 另外, 在建立路阻函数时, 本文只考虑在通常的车流密度条件下, 行驶速度与车流密度之间的关系, 没有考虑交通流密度很大或是很小的情况, 因此, 这也是下一步研究的重点.

(下转第 562 页)

- technology for tracking construction materials using a fuzzy decision model[J]. Journal of Civil Engineering and Management, 2012, 18(1): 43 - 59.
- [10] Ruey S, Chen C, Yan B, et al. Using RFID technology in food produce traceability[J]. WSEAS Transactions on Information Science and Applications, 2008, 5(11): 1551 - 1560.
- [11] Lhomme P, Chehbouni A. Comments on dual-source vegetation-atmosphere transfer models[J]. Agric for Meteorol, 1999, 9(4): 111 - 115.
- [12] Sébastien P, Daniel S. Traceability, liability and incentives for food safety and quality[J]. American Journal of Agricultural Economics, 2008, 90(1): 15 - 27.
- [13] Regattieri A, Gamberi M, Manzini R. Traceability of food products: general framework and experimental evidence[J]. Journal of Food Engineering, 2007, 81(2): 347 - 356.
- [14] 刘云浩. 物联网导论[M]. 北京: 科学出版社, 2012.
- [15] 胡红伟. 物流商抢占冷链市场遭遇尴尬[J]. 中外物流, 2007(6): 30 - 31.
- [16] 秦立公, 吴娇, 董津津, 等. 基于物联网的冷链物流设备管控研究[J]. 安徽农业科学, 2012, 40(18): 9942 - 9950.
- [17] 李斌, 李文峰. WSN 与 RFID 技术的融合研究[J]. 计算机工程, 2008, 34(9): 127 - 130.
- [18] 陈永庆, 范炳全, 马晓旦. 地理信息系统(GIS)在土地利用与交通系统研究中的应用[J]. 上海理工大学学报, 1998, 20(18): 81 - 85.
- [19] 任守纲, 徐焕良, 黎安, 等. 基于 RFID/GIS 物联网的肉品跟踪及追溯系统设计及实现[J]. 农业工程学报, 2010, 26(10): 229 - 235.

(编辑: 丁红艺)

(上接第 556 页)

参考文献:

- [1] 王素欣, 王雷震, 高利. BPR 路阻函数的改进研究[J]. 武汉理工大学学报, 2009, 33(3): 446 - 449.
- [2] 毛保华, 曾会欣, 袁振洲. 交通规划模型及其应用[M]. 北京: 中国铁道出版社, 1999.
- [3] 马君, 刘小冬, 孟颖. 基于神经网络的城市交通流预测研究[J]. 电子学报, 2009, 37(5): 1092 - 1094.
- [4] Wang Yuhong, Dang Yaoguo, Pu Xujin. Improved unequal interval grey model and its applications[J]. Systems Engineering and Electronics, 2011, 22(3): 445 - 451.
- [5] Deng Julong. A novel grey model GM(1, 1 | τ, r): generalizing GM(1, 1) [J]. The Journal of Grey System, 2001, 13(1): 1 - 8.
- [6] 包磊, 秦小麟. 数据库时空选择性查询的灰色预测法[J]. 华中科技大学学报(自然科学版), 2010, 38(12): 223 - 227.
- [7] 张大海, 江世芳, 史开泉. 灰色预测公式的理论缺陷及改进[J]. 系统工程理论与实践, 2002, 22(8): 140 - 142.
- [8] 李希灿. 灰色 GM(1, 1) 模型适用范围拓广[J]. 系统工程理论与实践, 1999, 19(1): 97 - 101.
- [9] 毕晓君. 信息智能处理技术[M]. 北京: 电子工业出版社, 2010.
- [10] 张大海, 毕研秋, 毕研霞, 等. 基于串联灰色神经网络的电力负荷预测方法[J]. 系统工程理论与实践, 2004, 24(5): 128 - 132.
- [11] 周四清, 王坚强. 基于多准则优化的组合预测方法[J]. 系统工程与电子技术, 2009, 31(7): 1651 - 1654.
- [12] 张林峰, 范炳全, 吕智林, 等. 公共交通工具最优组合模型及算法研究[J]. 上海理工大学学报, 2003, 25(2): 172 - 175.
- [13] 林锦顺, 姚俭. 基于 BP 神经网络的组合预测及在电力负荷的应用[J]. 上海理工大学学报, 2005, 27(5): 451 - 456.
- [14] 孙宇星, 陈德望, 吴建平. 北京市快速环路速度 - 密度模型研究[J]. 北京交通大学学报, 2004, 28(6): 70 - 73.

(编辑: 石 瑛)