• 人工智能及识别技术 •

文章编号: 1000-3428(2011)14-0149-03

文献标识码: A

中图分类号: TP391

经 GA 优化的 WNN 在交通流预测中的应用

杨 超,王志伟

(华东交通大学载运工具与装备省部共建教育部重点实验室, 南昌 330013)

摘 要:针对城市交通流的复杂性、随机性、非线性等特点,利用遗传算法(GA)优化小波神经网络(WNN),以克服传统神经网络收敛速度慢、易陷入局部最小点等缺陷,在此基础上建立基于 GA-WNN 的城市交通流预测模型。利用 GA-WNN、GA-BP 和 WNN 模型对南昌市南京西路交通流进行仿真预测,实验结果表明,GA-WNN 模型的预测效果较好,相比 GA-BP 和 WNN 模型具有更高的预测精度和更快的收敛速度。

关键词:交通流预测;遗传算法;小波神经网络;预测模型

Application of Wavelet Neural Network Optimized by Genetic Algorithm in Traffic Volume Prediction

YANG Chao, WANG Zhi-wei

(Key Laboratory of Conveyance and Equipment, Ministry of Education, East China Jiaotong University, Nanchang 330013, China)

[Abstract] Considering the characteristics of complexity, randomness and nonlinear in urban traffic volume, Wavelet Neural Network(WNN) is optimized by Genetic Algorithm(GA) to overcome the problems of slow network convergence rate and falling into local minimum which exist in traditional Neural Network(NN), and prediction model of urban traffic volume based on GA-WNN is established. Simulation predictions for Nanjing West Road in Nanchang City are conducted with GA-WNN, GA-BP and WNN models, whose results show that GA-WNN model has better prediction effect, higher prediction accuracy and faster convergence speed than GA-BP and WNN models.

[Key words] traffic volume prediction; Genetic Algorithm(GA); Wavelet Neural Network(WNN); prediction model **DOI:** 10.3969/j.issn.1000-3428.2011.14.049

1 概述

准确预测城市交通流是实施交通控制和诱导的基础和关键,对解决城市的交通拥挤、交通事故和环境污染等问题具有重要的意义。但交通流在实际环境中具有高复杂性、随机性、模糊性和非线性等特点,利用传统基于数学模型的预测方法(如自回归滑动平均模型、自回归综合滑动平均模型、卡尔曼滤波^[1-3])很难满足实际应用中对交通流高精度预测的要求。随着智能交通系统在我国交通运输管理领域的发展,新的交通流预测方法孕育而生,如神经网络、模糊理论、混沌理论^[4-6]。

小波神经网络(Wavelet Neural Network, WNN)是在小波分析和神经网络的基础上发展起来的一种前馈型网络模型,兼具神经网络的自学习能力和小波变换良好的时频局部特性,具有更灵活的函数逼近能力以及更强的适应性。遗传算法(Genetic Algorithm, GA)是一种自适应全局优化概率搜索算法,其直接对结构对象进行操作,具有内在的隐并行性和更好的全局寻优能力;概率化的寻优方法能够自动获取和指导优化的搜索空间,自适应地调整搜索方向。

本文建立了一个基于小波神经网络的交通流预测模型, 并通过遗传算法对其结构参数进行优化,以进一步提高预测 性能,得到更好的预测结果。

2 小波神经网络

小波神经网络模型结构可分为两大类[7]:

(1)小波分析与神经网络的串联结构形式。小波分析仅作 为神经网络的前置处理手段,为神经网络提供输入特征向量, 即小波分析对神经网络的输入进行初步处理,使得输入神经网络的信息更便于神经网络进行处理,这类小波神经网络虽然有不错的预测效果,但其本质上仍然是神经网络的结构,并没有改变神经网络存在的一些固有缺陷。(2)用小波函数代替前馈神经网络的隐含层节点函数。网络输入层到隐含层的权值和阈值分别由小波函数的尺度参数和平移参数所代替,这种网络结构从根本上改变了网络模型的结构,是一种真正意义上的小波神经网络。图 1 所示的 3 层小波神经网络结构一般可以实现任意的非线性映射。

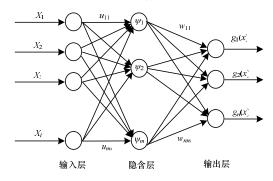


图 1 小波神经网络结构

基金项目: 载运工具与装备省部共建教育部重点实验室开放基金资助项目

作者简介: 杨 超(1969-), 男, 副教授、博士, 主研方向: 智能交通, 设备监测和控制; 王志伟, 硕士研究生

收稿日期: 2010-12-24 **E-mail:** yangchao_69@163.com

在图 1 中, $X_1 \sim X_l$ 为网络的输入量,l 为单元输入个数; $u_{11} \sim u_{ml}$ 为输入层到隐含层的网络连接权值; $\psi_1 \sim \psi_m$ 为隐含层的激励函数,m 为网络小波基的个数; $w_{11} \sim w_{nm}$ 为隐含层到输出层的网络连接权值; $g_1(x) \sim g_n(x)$ 为小波神经网络输出量,n 为单元输出个数。

小波神经网络中输出量 $g_n(x)$ 可以用小波函数 $\psi(x)$ 进行 拟合:

$$g_n(x) = \sum_{i=1}^{m} w_{nk} \psi[(\sum_{i=1}^{l} u_{ki} x(i) - b_k) / a_k]$$
 (1)

其中, a_k 为小波基函数伸缩因子; b_k 为小波基函数平移因子; w_{nk} 为隐含层到输出层的网络连接权值。

隐含层节点函数采用以 Morlet 为母小波的小波基函数: $\psi(x) = \cos(1.75x)\exp(-x^2/2)$

输出层节点函数采用 sigmoid 函数:

 $g(x)=1/[1+\exp(-x)]$

网络的误差能量和函数为:

$$E = \frac{1}{2} \sum_{j=1}^{n} [g_j(x) - y_j]^2, j = 1, 2, \dots, n$$
 (2)

其中, y_i 为网络期望输出量; g_j(x)为网络实际输出量。

一般情况下,为了使误差和函数达到最小或满足指定的范围,网络的连接权值及平移伸缩因子采用梯度下降法来调整。梯度下降法在一定程度上限制了参数的优化方向,使得整个网络的学习收敛速度较慢并且容易陷入局部最小,而遗传算法是一种自适应全局优化概率搜索算法,可以很好地找到全局最优解,弥补了梯度下降法的缺陷。因此,本文通过利用遗传算法对小波神经网络的连接权值及平移伸缩因子进行优化来提高网络预测精度。

3 经遗传算法优化的小波神经网络

在遗传算法对小波神经网络的优化过程中,优化参数包括输入层到隐含层的网络权值 u_{ml} 、隐含层到输出层的连接权值 w_{nm} 、小波基函数的伸缩因子 a_k 以及平移因子 b_k 。对优化参数进行编码,形成染色体,并对染色体进行复制、交叉及变异操作,使染色体不断进化,最终产生代表问题最优解的染色体,即优化的小波神经网络连接权值和伸缩平移因子。具体实施步骤如下:

(1)编码方式选择

对于小波神经网络,由于需要优化的网络参数比较多, 因此本文遗传算法采用实数编码,解码时直接把每个基因值 赋给相应的网络参数。

(2)适应度函数确定

设小波神经网络输出值与期望之间误差的平方和为网络误差 E,取个体适应度函数 f(r)为: f(r)=1/E。

(3) 选择算子

本文采用最常用的轮盘赌选择法,各个体的选择概率及 其适应度值成比例。选择概率为:

$$p_s = f(r) / \sum_{k=1}^{R} f(r), r=1,2,\dots,R$$
 (3)

其中, p_s 为个体的选择概率;R为整个种群的大小。

(4)交叉算子

本文采用算术交叉,假设 2 个个体为 G_A 和 G_B ,则交叉运算后产生的 2 个新个体 G'_A 和 G'_B 为: $G'_A=\alpha G_B+(1-\alpha)G_A$, $G'_B=\alpha G_A+(1-\alpha)G_B$,其中, α 为每一对父染色体产生的随机数, $0<\alpha<1$ 。交叉概率采用自适应调整规则:

$$p_{c} = \begin{cases} \beta_{1} (f_{\text{max}} - f') / (f_{\text{max}} - \overline{f}) & f' \geqslant \overline{f} \\ \beta_{2} & f' < \overline{f} \end{cases}$$
(4)

其中, f_{max} 为群体中个体适应度最大的值; \overline{f} 为群体适应度平均值;f'为双亲适应度中的较大者; β_1 、 β_2 为交叉概率的调整系数。

(5)变异算子

变异算子具有补偿群体多样性损失的重要作用,使群体继续优化。变异概率的自适应调整规则为:

$$p_{m} = \begin{cases} \lambda_{1} (f_{\text{max}} - f) / (f_{\text{max}} - \bar{f}) & f \ge \bar{f} \\ \lambda_{2} & f < \bar{f} \end{cases}$$
 (5)

其中,f 为变异个体的适应值; λ_1 、 λ_2 为变异概率的调整系数。 经过上述 5 步运算,将得到的新个体引入种群中,并计 算其适应度,如果适应度最大的个体满足精度要求或达到最 大迭代步数,结束优化过程,否则,继续优化,直到满足网 络要求为止。将优化的网络参数进行解码之后作为小波神经 网络的连接权值以及伸缩平移因子,再通过小波神经网络对 样本进行训练,最终获得经遗传算法优化的小波神经网络 模型。

4 交通流预测仿真实例

本文以南昌市南京西路段为研究对象,利用建立的模型预测其交通流大小。南京西路属于南昌市市中心的主干道,每天的交通流比较大,尤其是早晚高峰时段(7:00-9:00 和17:00-19:00),图 2 为南京西路交叉路口图。根据交通流理论可知,当前时刻 t 的交通流大小不仅与过去时刻的交通流大小有关,而且还受上下游路口交通流大小的影响。因此,下一时刻的交通流大小可以用当前时刻的交通流、过去时刻的交通流以及上下游路口段交通流的大小来预测,即:

$$Q_{t+1}=f(Q_t, Q_{t-1}, Q_{t-2}, \dots, q_1, q_2, q_3)$$

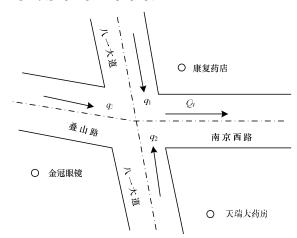


图 2 南昌市南京西路交叉路口

实验选取南京西路口在 t、t-1、t-2、t-3 时刻的交通流 Q_t 、 Q_{t-1} 、 Q_{t-2} 、 Q_{t-3} 以及上下游路口当前 t 时刻的交通流 q_1 、 q_2 、 q_3 预测 t+1 时刻交通流 Q_{t+1} 的大小。这样建立的网络模型的输入单元数为 7,输出单元数为 1,对于隐含层单元数,通过仿真分析得出,当其为 15 时,网络可以达到最佳的预测性能。采用南京西路 2010 年 5 月 24 日的交通流历史数据,时间段为 6:00-20:00,时间间隔为 Δt = 3 min,共有交通流记录数据 280 组(某一时刻的交通流及此时刻上下游路口的交通流组成一组记录数据)。根据预测模型,可组成 276 组样本数据,从中随机选取 200 组作为网络的训练数据样本,剩余的 76 组作为网络的测试数据样本。利用遗传算法优化小波神经网络参数时,种群规模取 50,交叉概率为 0.6,变异概率为 0.05,遗传代数为 200,网络的目标误差为 0.01。训练好网络之后,

输入测试数据,得到的 GA-WNN 交通流预测结果如图 3 所示。同时,利用经遗传算法优化的 BP 网络(GA-BP)、未经遗传算法优化的小波神经网络对相同样本的交通流数据进行了建模和预测,预测结果如图 4 和图 5 所示。

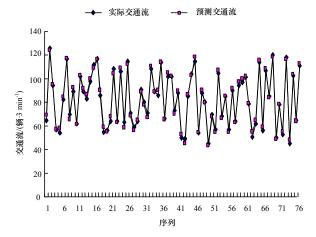


图 3 GA-WNN 交通流预测结果

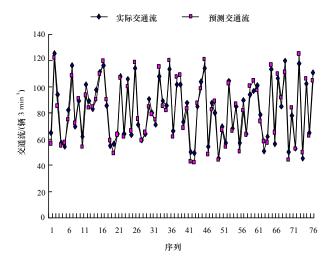


图 4 GA-BP 交通流预测结果

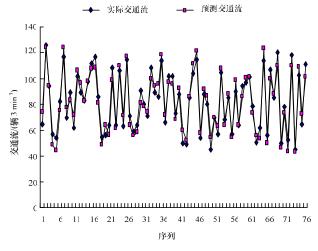


图 5 WNN 交通流预测结果

为了比较 GA-WNN、GA-BP 和 WNN 3 种模型的预测效果,引入了交通流预测性能的评价标准,主要包括网络训练

次数、最大绝对误差、最小绝对误差、平均绝对误差和拟合 度。3种网络模型的预测性能对比如表1所示。

表 1 3 种网络模型的预测性能对比

模型	训练 次数	最大绝 对误差/ (辆·3 min ⁻¹)	最小绝 对误差/ (辆·3 min ⁻¹)	平均绝 对误差/ (辆·3 min ⁻¹)	拟合度
GA-WNN	650	10.6	0.005	2.12	0.988
GA-BP	1 420	19.8	0.021	4.97	0.969
WNN	1 760	21.7	0.034	5.53	0.961

由图 3 可以看出,除个别预测点误差偏大以外,GA-WNN 网络的交通流预测值与实际值很接近,可以很好地拟合实际中的交通流,其拟合度达到了 0.988。对比图 3~图 5,GA-BP和 WNN 网络预测值的误差显然大于 GA-WNN 网络,由表 1也可以看出,GA-WNN 网络的平均绝对误差为 2.12,而 GA-BP和 WNN 网络的平均绝对误差分别是 4.97和 5.53,GA-WNN 的预测误差明显较小。此外,GA-WNN 网络训练次数仅 650 步即达到了设定的目标误差,远少于 GA-BP和 WNN 网络的训练次数 1 420 步和 1 780 步,从而缩短了网络运行时间。可见,GA-WNN 网络对于实际交通流的预测具有更优越的预测性能,在减少网络运行时间的同时提高了网络的预测精度。

5 结束语

本文根据城市交通流理论,利用建立的遗传优化小波神经网络模型对实际的交通流进行了仿真预测。与 GA-BP 及WNN 网络模型的对比实验结果表明,GA-WNN 拥有更高的收敛速度和更高的预测精度。本文仅讨论了交叉路口简单形式交通流的预测,即单个交叉路口、一个出口的形式,对于较复杂的路口,依照本文的方法可建立相应的 GA-WNN 网络进行交通流预测。

参考文献

- [1] Hamed M M, Al-Masaeid H R, Bani Z M. Short-term Prediction of Traffic Volume in Urban Arterials[J]. Transportation Engineering, 1995, 121(3): 249-254.
- [2] Lee Sang Soo, Fambro D B. Application of Subset Autoregressive Integrated Moving Average Model for Short-term Freeway Traffic Volume Forecasting[J]. Journal of the Transportation Research Board, 1999, 1678: 179-188.
- [3] Gazis D, Liu Chiu. Kalman Filtering Estimation of Traffic Counts for Two Network Links in Tandem[J]. Transportation Research Part B, 2003, 37(8): 737-745.
- [4] 张敬磊, 王晓原. 基于非线性组合模型的交通流预测方法[J]. 计算机工程, 2010, 36(5): 202-204.
- [5] Quek C, Pasquier M, Lim B B S. Pop-Traffic: A Novel Fuzzy Neural Approach to Road Traffic Analysis and Prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2006, 7(2): 133-146.
- [6] 臧利林, 贾 磊. 交通流实时预测的混沌时间序列模型[J]. 中国公路学报, 2007, 20(6): 68-72.
- [7] 丁 勇, 刘守生, 胡寿松. 一种广义小波神经网络的结构及其优化方法[J]. 控制理论与应用, 2003, 20(1): 125-128.

编辑 张 帆