

文章编号: 2095-2163(2020)04-0044-06

中图分类号: TP183

文献标志码: A

基于改进 CS-WNN 的短时交通流量预测

赵明姣, 张荣芬, 刘宇红

(贵州大学 大数据与信息工程学院, 贵阳 550025)

摘要: 城市交通流量具有非线性变化以及不确定性等特点。为了提高城市交通流量的预测精度, 提出一种改进的布谷鸟搜索算法优化小波神经网络(Improved Cuckoo Search - Wavelet Neural Network, ICS-WNN)预测模型。首先对交通流量原始数据进行降噪和归一化处理, 再通过基于自适应步长和发现概率的布谷鸟算法优化小波神经网络权值和小波收缩、平移因子并添加神经网络动量因子, 建立交通流量预测网络模型。实验仿真结果表明, ICS-WNN 预测算法相比几种主流的优化预测算法具有更高的拟合度和精确度。

关键词: 小波神经网络; 布谷鸟搜索算法; 交通流量预测; 自适应步长

Short-time traffic flow forecasting based on improved CS-WNN

ZHAO Mingjiao, ZHANG Rongfen, LIU Yuhong

(College of Big Data and Information Engineering, Guizhou University, Guiyang 550025, China)

[Abstract] Urban traffic flow has the characteristics of non-linear change and uncertainty. In order to improve the accuracy of urban traffic flow prediction, an Improved Cuckoo Search-Wavelet Neural Network (ICS-WNN) prediction model is proposed. Firstly, the original traffic flow data are denoised and normalized, then the weights of wavelet neural network and wavelet shrinkage and translation factors are optimized based on adaptive step size and detection probability of cuckoo algorithm, and the momentum factor of neural network is added to establish the traffic flow prediction network model. The simulation results show that ICS-WNN prediction algorithm has higher fitting accuracy and accuracy than several mainstream optimization prediction algorithms.

[Key words] wavelet neural network; cuckoo search algorithm; short-time traffic flow prediction; adaptive step-size

0 引言

随着我国经济不断发展, 城市化建设进步越来越明显, 与此同时城市交通拥堵也日益严重。城市交通系统是一个开放、实时、复杂的系统, 具有不确定性及非线性等特点, 单纯地依靠扩宽、新建道路和限行是无法解决由交通需求和交通供给之间的矛盾引起的交通拥堵难题。高效、可靠的交通流量预测方法可以为交通车辆优化调度和出行提供有效依据, 改善交通拥堵状况^[1]。

国内外学者提出了很多交通流量预测方法。例如: ARMA 模型^[2]与卡尔曼滤波模型^[3]的组合模型, 相对于 ARMA 模型及卡尔曼滤波模型单独预测该组合模型具有更高的预测精确度; 结合深度信念网络模型(DBN)与支持向量机(SVM), 对交通流量进行预测, 用 DBN 对交通流量进行学习并提取数据特征值, 用支持向量机模型对交通流量进行预测; 状态向量和距离度量相结合的方法, 形成 K-最近邻预

测模型, 该预测模型比只考虑时间维度的 k 邻近模型更准确的反映了交通流量的变化; 基于粒子群算法的小波神经网络预测算法, 用可变加速度因子使粒子群算法收敛于全局最优, 再去优化小波神经网络的各项参数, 构建了 PSO-WNN 预测模型; 遗传算法优化小波神经网络预测模型, 利用遗传算法的全局寻优及自适应随机搜索等特点, 优化 WNN 的各项参数; 谷鸟搜索算法, 优化 BP 神经网络预测算法, 将交通流序列进行相空间重构后进行网络学习, 再用 CS 算法搜索 BP 神经网络的最优参数进行交通流量预测, 预测结果较为准确反映了交通流量的变化趋势。

本文在 CS-WNN 短时交通流预测模型基础上, 提出一种改进的布谷鸟搜索算法优化小波神经网络预测模型。布谷鸟搜索算法到后期会有搜索速度慢及预测精度不高的缺点^[4], 根据迭代次数和适应度动态调整布谷鸟算法的步长 α 和发现概率 P_d 来优

基金项目: 贵州省科技计划项目(黔科合平台人才[2016]5707)。

作者简介: 赵明姣(1995-), 女, 硕士研究生, 主要研究方向: 深度学习及大数据应用; 张荣芬(1977-), 女, 博士, 教授, 主要研究方向: 嵌入式系统、机器视觉、智能算法与大数据应用; 刘宇红(1963-), 男, 硕士, 教授, 主要研究方向: 嵌入式通信系统、云计算与大数据应用。

通讯作者: 刘宇红 Email: 1693623574@qq.com.

收稿日期: 2019-10-25

化基本的布谷鸟算法。用改进的 CS 算法初始化小波神经网络的各项参数,并添加神经网络动量项预防收敛抖动、加快网络收敛速度,从而构建预测模型进行交通流量的预测。仿真结果验证了本文提出的预测模型与几种较为流行的交通流量预测模型相比,具有较好的拟合度和较高的精确度。

1 交通流量数据预处理

1.1 小波降噪

设备采集信号的过程中都会不同程度的受到噪声的污染,噪声的存在往往会掩盖信号本身所要表现的信息^[5],信号去噪的目的在于突出信号本身,而抑制噪声对信号本身的影响。本文采用小波变换对原始交通流量数据样本进行数据降噪^[6],小波去噪分为 3 个步骤:(1)对原始信号进行小波分解,得到信号的高频部分和低频部分;(2)对高频部分的噪声进行阈值处理;(3)用处理后的小波系数进行小波重构,得到去噪后的信号。本文采用启发式小波阈值去噪,使用小波工具箱中的 sym3 小波,分解层数为 2 层的小波变换对交通流量数据进行降噪,原始数据与降噪后的交通流量数据如图 1 所示。




图 1 原始数据与降噪后的数据

Fig. 1 Original data and denoised data

1.2 归一化处理

交通数据采集装置采集到的交通数据样本数量庞大而且大小不一,为了更加容易地正确收敛到最优解,需要对数据集进行归一化处理。本文使用 mapminmax 函数^[7]对原始数据进行归一化处理。数据经过归一化处理后,能提高模型收敛速度和最终的模型精度^[8]。Mapminmax 默认归一化到区间 $[-1, 1]$,计算公式(1)为:

$$y = \frac{(y_{\max} - y_{\min}) \times (x - x_{\min})}{x_{\max} - x_{\min}} + y_{\min} \quad (1)$$

其中, y 是归一化处理后的数据, $y_{\max} = 1$; $y_{\min} = -1$; x 为当前需要归一化的原始数据; x_{\max} 和 x_{\min} 分

别为数据样本中需要处理的原数据中的最大值与最小值。

处理过的数据经过网络训练以及预测模型后,用 mapminmax('reverse', 'y', 'ps') 函数将预测结果进行反归一化处理,根据已有给定的数据标准化处理映射 ps,将给定的标准化数据 y 反标准化,即可得到正常真实的交通流量预测数据。

2 交通流量预测模型

2.1 小波神经网络简介

小波神经网络是指沿用了神经网络的结构,并将网络中的激活函数替换成小波函数的一种有机结合^[9],即以 BP 神经网络拓扑结构为基础,把小波基函数作为隐含层节点的传递函数,信号前向传播的同时误差反向传播的一种神经网络。小波变换具有时频局部特性,而神经网络具有自学习、自适应、鲁棒性、容错性和推广能力^[10],怎样结合两者的优势一直都是学者们关注的热点。相对传统的神经网络来说,小波神经网络避免了在结构设计上的盲目性,它具有更强的学习能力、更快的收敛速度和更高的预测精度^[11]。小波神经网络(WNN)结构图如图 2 所示。




图 2 小波神经网络结构图

Fig. 2 Structure of Wavelet Neural Network

WNN 结构分为 3 层:输入层、隐藏层和输出层,设输入层有 M 个节点,隐藏层有 n 个节点,输出层有 N 个节点。到目前为止,隐藏层的节点个数 n 没有科学和普遍的确切公式,只有根据试凑法来确定,试凑法公式(2)如下:

$$n = \sqrt{M + N} + a, \quad (2)$$

其中, a 的取值范围为 1 到 10 之间的整数,本文输入层节点 $M = 4$,输出层节点 $N = 1$ 。由公式(2)可知,隐藏层节点个数在 3 到 12 之间,具体的数值需要进行网络训练对比来确定,经网络训练测试比较,隐藏层节点个数 $n = 6$ 时,预测效果最好。

图 2 中 W_{ij} 表示输入层到隐含层之间的连接权值, W_{jk} 表示隐含层到输出层之间的连接权值, $\Phi(x)$

为小波函数。本文选取的神经元激励函数为 Morlet 小波,其数学表达式为公式(3):

$$\varphi(x) = \cos(1.75x) \exp(-x^2/2), \quad (3)$$

小波神经网络隐含层输出公式(4):

$$P(j) = \varphi\left(\left(\sum_{i=1}^M W_{ij}x_i - b_j\right)/a_j\right), j = 1, 2, \dots, n, \quad (4)$$

其中, $P(j)$ 是隐藏层第 j 个输出; $\Phi(\cdot)$ 是公式(3)中的小波基函数; a_j 是小波基函数的伸缩因子; b_j 是小波基函数的平移因子。

小波神经网络输出层的输出 $Y_p(k)$, 公式(5)为:

$$Y_p(k) = \sum_{j=1}^n W_{jk}P(j), k = 1, 2, \dots, N. \quad (5)$$

小波神经网络采用梯度下降法对小波基函数系数和网络连接权值进行优化修正^[12],其修正过程如下:

(a) 小波神经网络输出预测值 $Y_p(k)$ 和实际结果 $Y_r(k)$ 之间的误差为公式(6):

$$e_k = Y_p(k) - Y_r(k), \quad (6)$$

(b) 根据预测误差 e_k 调整输入层 - 隐含层之间连接的权值 W_{ij} 、隐含层 - 输出层之间的连接权值 W_{jk} 、小波函数的伸缩因子 a_j 和小波函数的平移因子 b_j , 公式(7) ~ 公式(10):

$$W_{ij}^{(d+1)} = W_{ij}^d + \Delta W_{ij}^{(d+1)}, \quad (7)$$

$$W_{jk}^{(d+1)} = W_{jk}^d + \Delta W_{jk}^{(d+1)}, \quad (8)$$

$$a_j^{(d+1)} = a_j^d + \Delta a_j^{(d+1)}, \quad (9)$$

$$b_j^{(d+1)} = b_j^d + \Delta b_j^{(d+1)}. \quad (10)$$

在公式(7) ~ (10)中,上标为 d 的项表示第 d 次训练的连接权值或者小波基函数的系数;上标带有 $(d+1)$ 的项代表第 $d+1$ 次训练的连接权值或者小波基函数系数; $\Delta W_{ij}^{(d+1)}$ 表示第 $d+1$ 次训练输入层与隐藏层之间的连接权值修正项; $\Delta W_{jk}^{(d+1)}$ 表示第 $d+1$ 次训练隐藏层和输出层之间连接权值修正项; $\Delta a_j^{(d+1)}$ 表示第 $d+1$ 次训练小波函数的伸缩因子修正项; $\Delta b_j^{(d+1)}$ 表示第 $d+1$ 次训练小波函数的平移因子修正项。各修正项是根据网络误差 e_k 计算的,公式(11) ~ 公式(14)如下,公式中 η 是学习速率:

$$\Delta W_{ij}^{(d+1)} = -\eta \cdot e / \partial W_{ij}^{(d)}, \quad (11)$$

$$\Delta W_{jk}^{(d+1)} = -\eta \cdot \partial e / \partial W_{jk}^{(d)}, \quad (12)$$

$$\Delta a_j^{(d+1)} = -\eta \cdot \partial e / \partial a_j^{(d)}, \quad (13)$$

$$\Delta b_j^{(d+1)} = -\eta \cdot \partial e / \partial b_j^{(d)}. \quad (14)$$

考虑第 $d-1$ 次权重对第 d 次权重的影响,在神经网络中加入动量项,有效地抑制网络陷于局部极小值。加入动量项后,首次迭代训练网络中的各项连接权值及小波函数系数的计算公式仍使用公式(11) ~ (14),当训练次数大于等于 2 时,各网络连接权值和小波基函数系数采用公式(15) - (18) 进行计算:

$$W_{ij}^{(d+1)} = W_{ij}^d + \Delta W_{ij}^{(d+1)} + \alpha(W_{ij}^d - W_{ij}^{(d-1)}), \quad (15)$$

$$W_{jk}^{(d+1)} = W_{jk}^d + \Delta W_{jk}^{(d+1)} + \alpha(W_{jk}^d - W_{jk}^{(d-1)}), \quad (16)$$

$$a_j^{(d+1)} = a_j^d + \Delta a_j^{(d+1)} + \alpha(a_j^d - a_j^{(d-1)}), \quad (17)$$

$$b_j^{(d+1)} = b_j^d + \Delta b_j^{(d+1)} + \alpha(b_j^d - b_j^{(d-1)}). \quad (18)$$

2.2 CS 及 ICS 算法简介

2.2.1 CS 算法

布谷鸟搜索算法是一种通过模拟某些种属布谷鸟的寄生育雏,有效地求解最优化问题的算法^[13]。布谷鸟搜索算法需要设定 3 个理想状态:

- (1) 每次每只布谷鸟只下一个布谷鸟蛋,并将蛋随机地放在一个鸟巢中;
- (2) 布谷鸟蛋最好的那个鸟巢会被保留到下一代;
- (3) 鸟巢的数量是固定的,鸟巢中布谷鸟蛋被发现的概率是 P_a ,取值范围为 $(0, 1)$ 。

可理解为:鸟窝 = 卵蛋 = 解,布谷鸟寻找鸟窝产蛋的过程就是搜索解的过程,鸟窝的质量代表着解的好坏。

同时,布谷鸟搜索算法位置更新采用相关的 Levy 飞行随机路径机制^[14],Levy 飞行生成随机数应包含两个步骤:随机方向的选择和服从莱维分布的步长生成,方向的随机分布应该服从均匀分布,生成步长最有效且直接的方法是使用 Mantegna 算法来实现对称的 levy 稳定分布。莱维飞行更新鸟窝位置的公式(19)定义为:

$$X_{t+1} = X_t + \alpha \otimes Levy(\beta), \quad (19)$$

其中, X_t 表示第 t 代的鸟巢位置; X_{t+1} 表示第 $t+1$ 代的鸟巢位置; α 表示步长缩放因子; $Levy(\beta)$ 表示莱维随机路径,莱维随机路径与时间 t 的关系服从莱维分布,公式(20):

$$levy(\beta) \sim u = t^{-\lambda}, 1 < \lambda \leq 3. \quad (20)$$

另外,一部分宿主鸟以概率 P_a 发现布谷鸟蛋后,弃巢新建窝的位置路径选用偏好随机游动的方式,其计算公式(21)为:

$$X_i^{t+1} = X_i^t + r \otimes (X_j^t - X_k^t). \quad (21)$$

其中, X_i^{t+1} 是第 $t+1$ 代的第 i 个鸟巢位置, X_i^t 是第 t 代的第 i 个鸟巢位置, X_j^t 和 X_k^t 分别是第 t 代的两个随机鸟巢位置, r 是服从均匀分布的随机数。

根据布谷鸟搜索算法设定的 3 个理想状态, 布谷鸟搜索算法流程图如图 3 所示;

$$c = \frac{t}{T} \times \ln\left(\frac{P_{amin}}{P_{amax}}\right), \quad (23)$$

$$\alpha_i(t) = n \left[\alpha_{max} - \frac{t}{T} (\alpha_{max} - \alpha_{min}) \right] \times \frac{f_i}{\sum_{j=1}^n f_j}. \quad (24)$$

其中, $P_{a,i}(t)$ 表示第 t 代第 i 个鸟巢被发现的概率, 最大发现概率 P_{amax} 、最小发现概率 P_{amin} , 令 $P_{amax} = 1, P_{amin} = 0.005$; T 表示最大迭代次数, t 是当前迭代次数, n 是鸟巢数量; $\alpha_i(t)$ 是第 t 代第 i 个鸟巢位置更新步长, α_{max} 和 α_{min} 分别为最大步长和最小步长, 令 $\alpha_{min} = 0.05, \alpha_{max} = 0.5$; f_i 是第 i 个鸟巢的适应值, f_j 是任意一个鸟巢的适应值。

ICS-WNN 算法的基本步骤如下:

(1) 导入原始交通流量数据进行预处理, 将处理过的数据拆分为训练数据和测试数据;

(2) 初始化小波神经网络的各项参数, 进行多次神经网络训练, 最终确定各项参数值并设神经网络最大迭代次数为 500 次;

(3) 初始化鸟巢数 N_{nest} 、 P_a 采用指数递减方式动态调整, 最大迭代次数 T_{max} 设为 150 次, 每个鸟巢位置 W_i 都有 l ($l = M \times n + N \times n + n + n, M$ 为输入层节点个数, n 为隐含层节点个数, N 为输出层节点个数) 个参数。采用线性递减的步长策略对位置和路径进行更新, 根据各参数的初始值进行训练, 计算每个鸟巢的预测值和预测误差, 找到 N_{nest} 个鸟巢中预测误差最小的鸟巢位置, 标记为最佳鸟巢 W_{best} 并保留到下一代;

(4) 在下一训练次中, 对 3) 中除了最佳鸟巢 W_{best} 以外的鸟巢进行位置和路径更新。通过小波神经网络计算鸟巢位置预测值和实际值之间的误差 e_{k+1} , 与上次训练结果中其他鸟巢的预测误差 e_k 对比, 如果 e_{k+1} 大于 e_k , 则保留第 k 次的鸟巢位置; 若 e_{k+1} 小于 e_k , 则保留第 $k+1$ 次训练的鸟巢位置, 从而寻到当代最佳鸟巢位置 W_{new} ;

(5) 若随机数 $r > P_a$, 则舍弃这组鸟巢的位置, 建造新鸟巢的位置和路径, 更新方式采用偏好随机游动方式。通过小波神经网络计算预测误差, 与第 4) 步中较佳鸟巢位置 W_{new} 中的各预测误差进行对比, 预测误差较小的鸟巢位置则代替预测误差较大的鸟巢位置, 从而得到当代更优鸟巢位置 W'_{new} ;

(6) W'_{new} 中的最优鸟巢位置标记为 W_{best} , 若没有达到迭代次数或者预测精度, 则返回第 4) 步继续寻优, 反之输出当前 W_{best} ;

(7) 将最终确定的 W_{best} 分别拆分为各连接权

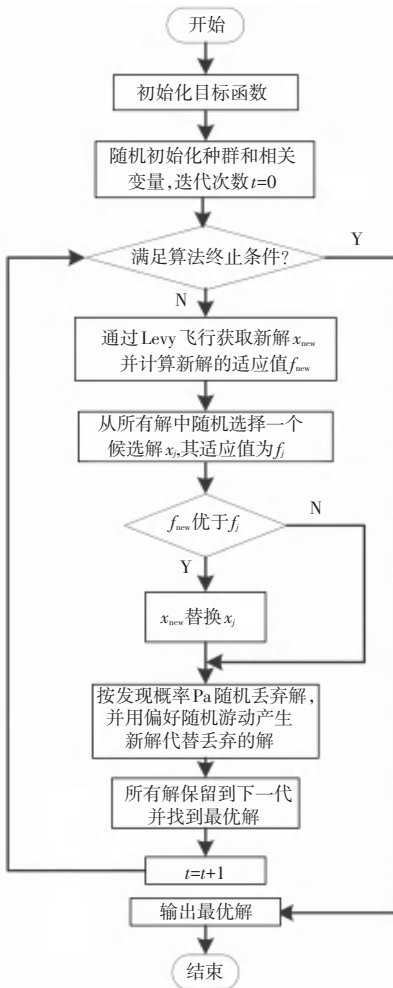


图 3 布谷鸟搜索算法流程图

Fig. 3 Flow chart of Cuckoo Search Algorithm

2.2.2 ICS-WNN 算法

基本的布谷鸟搜索算法在前期的全局搜索能力很强, 但却削弱了局部搜索能力, 在后期又容易收敛于局部极值^[15], 导致搜索速度变慢和预测精度不高。为了提高预测精度, 本文动态调整步长和发现概率, 步长和发现概率随着算法迭代次数变化而变化^[16]。采用式(22)~式(24)对发现概率和步长进行更新:

$$P_{a,i}(t) = n P_{amax} \times \exp(c) \times \frac{f_i}{\sum_{j=1}^n f_j}, \quad (22)$$

值、小波基函数的伸缩因子和平移因子。将处理过的数据导入小波神经网络并进行网络训练,当满足条件时,停止网络训练,保存此时的各项参数值。训练结束的条件为:达到最大迭代次数或达到预测精度;

(8) 输入测试数据,进行实际交通流量预测。将预测的交通流量结果与实际交通流量进行对比,计算各评价指标值。

3 仿真实验与分析

3.1 实验仿真介绍

实验硬件平台为四核第七代酷睿 i7 处理器,8GB DDR4 内存,软件环境为 MATLAB R2014b。实验数据选用美国加利福尼亚州圣华金县斯托克顿某车道车流量数据,记录时间为 2011 年 4 月 4 日至 2011 年 4 月 15 日共 10 个工作日、时间间隔为 15 分钟一组的交通流数据集。

在预测模型中各项连接权值学习速率为 0.01、小波函数的平移因子和伸缩因子学习速率为 0.0015、动量因子为 0.4、鸟巢数为 20、Pa 采用指数递减的方式动态调整、步长采用线性递减的策略。

为了分析本文提出的预测模型,选用 4 种评价指标对预测结果进行分析,分别为平均绝对百分比误差 (MAPE)、平均绝对误差 (MAE)、均等系数 (EC) 和均方根误差 (RMSE)。

平均绝对百分比误差 (MAPE) 计算公式 (25):

$$MAPE = \frac{1}{N} \sum_t \left| \frac{Y_p(t) - Y_r(t)}{Y_r(t)} \right| \times 100\%, \quad (25)$$

平均绝对误差 (MAE) 计算公式 (26):

$$MAE = \sum_t |Y_p(t) - Y_r(t)| / N, \quad (26)$$

均等系数 (EC) 计算公式 (27):

$$EC = 1 - \frac{\sqrt{\sum_t (Y_p(t) - Y_r(t))^2}}{\sqrt{\sum_t (Y_p(t))^2} + \sqrt{\sum_t (Y_r(t))^2}}, \quad (27)$$

均方根误差 (RMSE) 计算公式 (28):

$$RMSE = \sqrt{\sum_t (Y_p(t) - Y_r(t))^2 / N}. \quad (28)$$

公式 (25) ~ (28) 中, $Y_p(t)$ 表示 t 时刻网络预测值, $Y_r(t)$ 表示 t 时刻实际交通流量值, N 表示预测数据样本数量组数。为了验证本文提出算法的预测效果,选用 PSO-WNN 算法、GA-WNN 算法、CS-BPNN 算法、CS-WNN 算法和本文提出的算法进行交通流量预测结果比较,结果如表 1 所示。

3.2 预测结果分析

由表 1 可知,本文提出算法的 MAPE 为 5.7737%, 平均绝对误差 MAE 为 10.5213, 均方根误差

RMSE 为 12.8466, 这 3 个评价指标值均低于 CS-WNN 算法、PSO-WNN 算法、GA-WNN 算法和 CS-BPNN 算法所对应的各项评价指标值。因此,本文提出的模型具有更高的预测精度。

表 1 不同模型评价指标比较

Tab. 1 Comparison of evaluation indexes of different models

模型	MAPE/%	MAE	RMSE	EC
ICS-WNN	5.773 7	10.521 3	12.846 6	0.973 86
CS-WNN	6.598 5	11.201 7	14.456 6	0.970 77
PSO-WNN	7.306 6	12.183 0	15.305 0	0.969 13
GA-WNN	7.850 5	13.055 9	16.131 3	0.967 47
CS-BPNN	8.898 5	13.889 0	17.404 1	0.965 03

表中几种算法的均等系数 (拟合度) 都在 0.95 以上, 拟合度越高表示预测效果越好, 因此利用这几种算法预测结果都是比较有意义的。本文提出算法的拟合度为 0.97386, 在几种预测算法中拟合度值最高, 说明本文提出的算法预测效果优于其他几种主流预测算法。

图 4 和图 5 为几种模型交通流量预测结果比较图, 其中, 图 5 是图 4 仿真结果的局部放大图。由图 4、图 5 可以看出, 本文提出预测模型的预测结果相对于另外 4 种模型的预测结果来说, 偏离程度较小。结合表 1、图 4 和图 5 来看, 本文提出的预测算法具有更高的精确度和拟合度。




图 4 各模型交通流量预测结果图

Fig. 4 Traffic flow prediction results of various models

图 6 为 CS-WNN 算法和 ICS-WNN 算法预测结果对比图, 从图中可以看出 ICS-WNN 算法预测结果和 CS-WNN 算法的预测结果走势相似, 但整体上 ICS-WNN 的预测更贴近实际车流量走势。从表 1 中也可以看出, 相对于 CS-WNN 算法, ICS-WNN 算法的平均绝对百分比误差降低了 0.824 8%, 平均绝对误差降低了 0.680 4, 均方根误差降低了 1.61。结

合表 1 与图 6 来看, 本文提出的算法优于 CS-WNN 算法。




图 5 各模型交通流量预测结果局部图

Fig. 5 Partial graphs of traffic flow prediction results of various models




图 6 CS-WNN 和 ICS-WNN 预测结果图

Fig. 6 CS-WNN and ICS-WNN prediction results

图 7 是实际交通流量与本文提出的预测模型预测的交通流量结果图, 从图中可以看出, 除个别时间点外, 本文提出的模型预测结果比较贴近实际交通车流量走势。

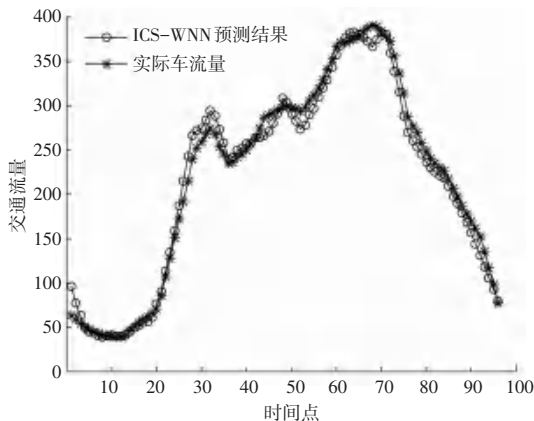


图 7 实际车流量与 ICS-WNN 预测结果图

Fig. 7 Actual traffic flow and ICS-WNN prediction results

4 结束语

利用自调整步长和发现概率优化布谷鸟搜索算法, 克服了布谷鸟搜索算法在后期精度不高和搜索速度慢等缺点; 再利用改进的 CS 算法初始化小波神经网络的各连接权值与小波函数的伸缩因子和平移因子, 使神经网络不容易陷入局部极小值; 其次在小波神经网络训练的时候, 加入动量因子避免网络训练时发生震荡, 从而构建了 ICS-WNN 预测模型。对比几种预测算法的各项评价指标值, 验证了本文提出的预测模型具有更高的预测精度和更好的拟合能力。交通流量特别容易受到外界环境的影响, 下一步工作将考虑更多输入参数的预测算法研究, 进一步提高交通流量的预测精度。

参考文献

- [1] HAMROUNI T, SLIMANI S, CHARRADA F B. A data mining correlated patterns-based periodic decentralized replication strategy for data grids[J]. Journal of Systems and Software, 2015, 110: 10-27.
- [2] 卢志义, 聂惟聪, 陈丽珍. 基于 ARMA 模型的城市轨道交通客流量预测[J]. 河南科学, 2018, 36(5): 12-17.
- [3] 郭海峰, 方良君, 俞立. 基于模糊卡尔曼滤波的短时交通流量预测方法[J]. 浙江工业大学学报, 2013, 41(2): 218-221.
- [4] 牛海帆, 宋卫平, 宁爱平, 等. 混沌布谷鸟搜索算法在谐波估计中的应用[J]. 计算机应用, 2017, 37(1): 239-243.
- [5] 张小丽. 利用小波变换进行高噪背景下的信号提取[D]. 西安: 陕西师范大学, 2007.
- [6] DONOHO D L, JOHNSTONE I M. Threshold selection for wavelet shrinkage of noisy data[C]// International Conference of the IEEE Engineering in Medicine & Biology Society. IEEE, 2002.
- [7] 孙雪, 张琳. BP 神经网络在基坑变形预测中的应用及改进[J]. 勘察科学技术, 2017(1): 47-51.
- [8] 徐勤军, 周同驰, 周琳, 等. 概率隐含语义分析模型在行为识别中的编码与归一化方法研究[J]. 信号处理, 2018(7): 766-775.
- [9] 万建, 徐德民, 贺昱曜. 一种小波神经网络结构及其学习算法研究[J]. 系统工程与电子技术, 2002, 24(3).
- [10] 徐志敏. 小波网络的研究及其应用[D]. 济南: 山东师范大学.
- [11] 赵道利, 谷伟豪, 冯亚平. 基于小波神经网络的短时交通流量预测[J]. 微型机与应用, 2017, 36(23): 80-83.
- [12] 蔡崇国. 小波分析在大功率交流伺服系统中的应用研究[D]. 南京: 南京理工大学, 2015.
- [13] 凌巍高. 基于混沌的布谷鸟优化算法研究及应用[D]. 2015.
- [14] 郝军军, 郝五零. Levy 飞行查找算法[C]// 第五届全国复杂网络学术会议论文(摘要)汇集. 2009.
- [15] 马卫, 孙正兴, 李俊楼. 基于 Powell 局部搜索策略的全局优化布谷鸟算法[J]. 计算机应用研究, 2015, 32(6): 1667-1675.
- [16] VALIAN E, MOHANNA S, TAVAKOLI S. Improved cuckoo search algorithm for global optimization[J]. International Journal of Communications and Information Technology, 2011, 1(1): 31-44.