

基于GA-PSO混合优化的BPNN车速预测方法

刘吉超^{a, b, c}, 陈阳舟^{*a, b, c}

(北京工业大学 a. 城市交通学院; b. 北京市交通工程重点实验室; c. 北京城市交通协同创新中心, 北京 100124)

摘要: BP神经网络(BPNN)已经用于车速预测方面的研究.针对BPNN不同的初始权值和阈值会影响车速预测精度的问题,提出一种基于GA-PSO混合优化的BPNN车速预测方法.以北工大西门到百葛桥为研究路径,构建基于BPNN的车速预测模型;将遗传算法(GA)和粒子群算法(PSO)的寻优过程进行融合,通过逐次迭代取最优的方式确定BPNN的最优初始权值和阈值,以此设计基于GA-PSO混合优化的BPNN车速预测方法.最后,以所选路径为对象,利用基于GA-BPNN的预测法、基于PSO-BPNN的预测法,以及提出的方法对车速进行了实验预测.结果表明,相较于前两种车速预测改进方法,本文方法的平均车速预测误差分别降低了37.1%和24.1%,有效地提高了车速的预测精度.

关键词: 城市交通;车速预测;BP神经网络;遗传算法;粒子群算法

A BPNN-based Speed Prediction Method with GA-PSO Optimization Algorithm

LIU Ji-chao^{a, b, c}, CHEN Yang-zhou^{*a, b, c}

(a. College of Metropolitan Transportation; b. Beijing Key Laboratory of Transportation Engineering; c. Beijing Collaborative Innovation Center for Metropolitan Transportation, Beijing University of Technology, Beijing 100124, China)

Abstract: The BP neural network (BPNN) is used to research on the speed prediction. For the problem that the different initial weights and thresholds of the BPNN can influence the speed prediction accuracy, a speed prediction method based on the BPNN with GA-PSO optimization algorithm is proposed. A route from Beigongdaximen to Baigeqiao is selected as the research path; then the speed prediction model based on the BPNN is established. Based on the optimization process between the genetic algorithm (GA) and particle swarm optimization (PSO), the speed prediction method based on the BPNN with GA-PSO optimization algorithm is designed through the method that the optimal weights and thresholds of the BPNN are determined by using the iteratively optimal method. Finally, based on the selected route, the GA-BPNN-based, the PSO-BPNN-based and the proposed speed prediction methods are used to achieve speed prediction, respectively. The result indicates that, compared with the other two optimal methods on the BPNN, the average speed errors of the proposed method are reduced by 37.1% and 24.1%, respectively. The proposed method can effectively improve the accuracy of the speed prediction.

Keywords: urban traffic; speed prediction; BP neural network; genetic algorithm; particle swarm optimization

收稿日期:2017-05-22

修回日期:2017-08-24

录用日期:2017-09-05

基金项目:国家自然科学基金/National Natural Science Foundation of China(61573030).

作者简介:刘吉超(1986-),男,江苏东海人,博士生.

*通信作者: yzchen@bjut.edu.cn

0 引言

准确的车速预测对行车安全及车辆能源优化管理至关重要^[1].城市交通系统的混沌特性增加了车速预测的难度.由于反向传播神经网络(Back Propagation Neural Network, BPNN)对混沌系统具有较强的非线性拟合能力,因此已经被用于车速预测方面的研究^[2].

目前,基于BPNN的车速预测法主要分为2类:以道路几何特征为主体的BPNN车速预测法(以下称:第1类方法)、以车辆运动信息为主体的BPNN车速预测法(以下称:第2类方法).第1类方法的主要特点是根据道路线形、曲率半径、坡度等特征建立与车速之间的映射关系,从而实现对速度的预测.解少博等^[3]、王栋等^[4]分别针对不同地域的高速公路,利用多种道路特征建立了基于BPNN的车速预测模型.第2类方法的主要特点是根据车辆当前速度、加速度等信息,利用通过样本训练得到的车速预测模型预测下一时刻或位置的车速.欧阳等^[5]结合6种标准工况的平均车速、加速度等信息对BPNN进行了训练,目的是获得适应城市工况的车速预测模型.总体上,以上所述的方法基本可以实现不同道路条件下的车速预测.

然而,BPNN是通过训练权值和阈值来实现自我学习的,不同的初始权值和阈值会导致训练出的网络的预测效果不同^[6].为了寻找最优初始权值和阈值从而提高BPNN的车速预测精度,部分参数寻优算法被利用在BPNN中.李松等^[7]在对BPNN训练之前,采用遗传算法(Genetic Algorithm, GA)对权值和阈值的初始化值进行了寻优处理;在此基础上,卢建中等^[8]提出了基于模拟退火算法改进的GA,对权值和阈值的初始化值做了进一步的优化;同时,李松等^[9]利用改进型粒子群算法(Particle Swarm Optimization, PSO)对权值和阈值的初始化值进行了优化处理.文献[7-9]中提出的方法已经用于基于BPNN的短时交通流预测.按此思想,谢浩^[10]分别将GA和PSO应用到基于BPNN的车速预测模型中,根据不同的工况选择不同的优化算法对网络初始参数进行优化.然而,由于GA和PSO采用不同的寻优机理,导

致两者得到的最终优化结果也不尽相同.

因此,为了进一步提高BPNN的车速预测精度,提出一种基于GA-PSO混合优化的BPNN车速预测方法.其基本思想是将GA和PSO的寻优过程进行融合,通过逐次迭代取两者最优结果的方式确定网络的最优初始权值和阈值,以此提高BPNN的车速预测精度.

1 基于BPNN的车速预测模型构建

由于BPNN利用样本完成网络训练,因此需要确定样本的信息结构,在此基础上构建车速预测模型.

1.1 样本信息获取

相较于高速公路和郊区公路,城市道路的交通状况更为复杂,一般性更强,因此选择城市道路作为研究对象.选择的路线来自北京市路网,如图1所示,从北工大西门到百葛桥,路径由街道、城市环路及城际高速组成,全程 $L=44.9$ km.



图1 选择的路线

Fig. 1 The selected route

由于交通状态的影响,车辆从路径的起点到终点,每个行车周期所用的时间是不一样的;换句话说,很难从时间序列的角度分析车速的周期特性.相反,由于路径距离是固定的,因此可以从空间序列角度分析车速的循环特性.由此需要对路径在空间域内进行建模,具体如下.

(1) 路径划分.

路径划分的目的是降低路径分析的复杂度,提高车速的预测精度和效率.路径划分的基本思想:

① 针对城市环路及城际高速,利用两个相邻的匝道口进行划分,如图2(a)所示;

② 针对街道路,利用两个相邻的红绿灯进行划分,如图2(b)所示.

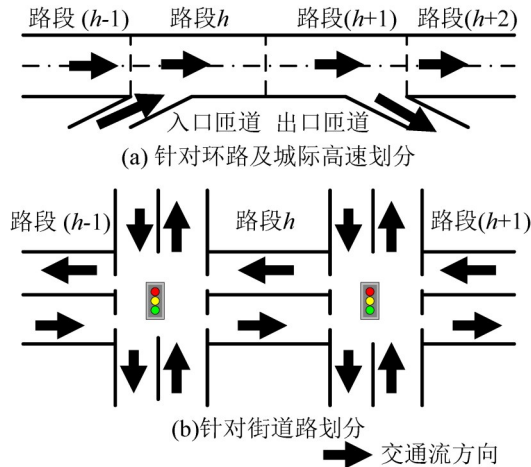


图2 路径划分思想

Fig. 2 The dividing rules of the route

忽略匝道口交织区及红绿灯路口的距离影响,按照上述思想,总长为 L 的路径可表示为

$$L = \sum_{h=1}^m L_h \quad (1)$$

式中: L_h 为第 h 个路段的长度; m 为路段总数.

(2) 路径距离离散化.

路径距离离散的目的是获取车辆位置的空间序列.为了保证离散精度,设定GPS速度数据采集周期 T 内车速 v 保持不变,由式(1)可得离散步长 b 需满足以下条件:

$$l \leq b \leq \min(\min(L_1, L_2, \dots, L_m), v \cdot T) \quad (2)$$

式中: l 表示车辆长度;通过这种方式将整个路径离散为 D 个点.

将图1所示的路径按照上述方式进行建模,得到的路段数 $m=21$,各路段参数如表1所示;其中, $L_1 \sim L_8$ 为街道路, $L_9 \sim L_{17}$ 为环路, $L_{18} \sim L_{21}$ 为城际高速;路径离散步长 $b=25$ m,离散点数 $D=1\,797$.

表1 路段参数

Table 1 The parameters of the road sections

路段名称	距离/km	路段名称	距离/km
北工大西门—北工大路	$L_1 = 0.44$	团结湖—亮马桥	$L_{12} = 1.87$
北工大路—南磨房路	$L_2 = 0.62$	亮马桥—三元桥	$L_{13} = 1.37$
南磨房路—大郊亭中街	$L_3 = 0.54$	三元桥—太阳宫桥	$L_{14} = 2.47$
大郊亭中街—大郊亭北街	$L_4 = 0.39$	太阳宫桥—安贞桥	$L_{15} = 2.17$
大郊亭北街—广渠路	$L_5 = 0.26$	安贞桥—马甸桥	$L_{16} = 2.37$
西大望路—九龙山路	$L_6 = 0.48$	马甸桥—裕民路	$L_{17} = 0.57$
九龙山路—黄木厂路	$L_7 = 0.56$	裕民路—健翔桥	$L_{18} = 1.77$
黄木厂路—东三环中路辅路	$L_8 = 0.52$	健翔桥—清河收费站	$L_{19} = 3.17$
双井桥—国贸桥	$L_9 = 1.73$	清河收费站—上清桥	$L_{20} = 1.37$
国贸桥—京广桥	$L_{10} = 1.28$	上清桥—百葛桥	$L_{21} = 19.37$
京广桥—团结湖	$L_{11} = 1.68$	总路径	$L = 44.9$

城市交通环境下,车速不仅受到车辆运动状态的影响,也受到路段交通状态的影响.当前研究阶段,车辆运动状态用车辆当前位置的速度 v 和加速度 a 来表征;路段交通状态用路段平均交通流速度 \bar{v}_h 来表征.通过以上分析,对行驶在图1所示路径上的车辆的 v 、 a ,以及 \bar{v}_h 进行了采集.采集时间为2016-08-01至2016-08-10,时间段为早高峰(7:00-9:00),具体数据如图3所示,其中 v 、 a 由车载GPS采集, \bar{v}_h 由北京城市交通协同创新中心提供.

1.2 基于BPNN的车速预测模型构建

结合图3所示的样本信息,基于BPNN的车速

预测模型的构建思想为:根据车辆当前位置的 v 、 a 、 \bar{v}_h 预测下一个位置的 v ,网络输入量与输出量的映射关系可以表述为

$$v(p+1) = f(v(p), a(p), \bar{v}_h(p)) \quad (3)$$

式中: $v(p)$ 和 $a(p)$ 分别表示第 p 个位置的车速和加速度, $p=1,2,\dots,D-1$; $\bar{v}_h(p)$ 表示位置 p 所处路段 h 的交通流速度.根据式(3)所示的输入量和输出量的个数关系,选定3层网络结构:1个输入层、1个隐层、1个输出层.隐层神经元个数为5个,输出层神经元个数为1个,如图4所示.




图3 样本信息

Fig. 3 The sample data




图4 车速预测模型网络结构

Fig. 4 The network structure for the speed prediction model

图4所示的网络各层之间通过网络权值建立联系,各个神经元的输入信号与权值和自身阈值相关^[6].选择tansig函数作为隐层神经元的传递函数,则隐层第*i*个神经元的信号传递关系为

$$f(\text{net}_i) = (1 - e^{-\beta \cdot \text{net}_i}) / (1 + e^{-\beta \cdot \text{net}_i}), i = 1, 2, \dots, 5 \quad (4)$$

式中:学习速率 $\beta > 0$.设训练样本总量为 G ,若将式(3)的输入量表示为 $X_\tau = [x_{1\tau}(p), x_{2\tau}(p), x_{3\tau}(p)]^T$, $\tau = 1, 2, \dots, G$,则隐层第*i*个神经元的输入信号 net_i 可以表示为

$$\text{net}_i = X_\tau \cdot W_i - \theta_i \quad (5)$$

式中: W_i 和 θ_i 分别为第*i*个神经元的连接权值和阈值.输出层神经元传递函数选择purelin,即

$$f(\text{net}) = \text{net} \quad (6)$$

其输入信号net的表示方式和隐层神经元一致.

样本和网络结构确定以后,BPNN就可以通过网络学习算法^[6]不断对权值和阈值进行学习、修正,以此实现对网络模型的训练.

2 基于GA-PSO混合优化的BPNN车速预测方法

2.1 GA与PSO的寻优机制

由以上建立的预测模型知,BPNN初次训练需

要对权值和阈值进行初始化赋值,而不同的初始权值和阈值会导致训练出来的网络的预测效果不同.为了寻找最优初始权值和阈值从而提高网络的预测精度,GA和PSO两种参数寻优算法被相继利用在BPNN中^[7-10],两者均通过迭代的方式实现最优值的搜索.

首先,GA和PSO均需要把权值和阈值按照实数编码的方式生成个体、形成种群;并建立用于评价个体优劣的适应度函数,具体如下:

① 将权值和阈值按实数编码进行组合,编码组中的每个待优化的参数代表一个基因,每个编码组代表一个个体,一个含有 S 个个体的种群记为 $H = (H_1, H_2, \dots, H_S)$,第 u 个个体的基因组 $H_u = (H_{u1}, H_{u2}, \dots, H_{u\sigma})$, σ 表示权值和阈值的总个数.

② 由于网络训练的最终目的是使计算值 y 和真实值 b 无限逼近,因此将适应度函数确定为

$$F = \sum_o |y_o - b_o| \quad (7)$$

其次,GA和PSO采用不同的种群更新机制更新种群.GA通过选择、交叉、变异形成新的种群,而PSO通过更新个体的空间位置和移动速度来更新种群,具体如下:

(1) GA种群更新过程.

① 选择操作:采用轮盘赌法^[7]实现个体选择操作,个体 u 被选择的概率为

$$p_u = (1/F_u) / \sum_{v=1}^S (1/F_v) \quad (8)$$

② 交叉操作:对个体 u 的基因组 H_u 和个体 γ 的基因组 H_γ 的第 i 个位置的基因进行交叉操作:

$$\begin{cases} H_{ui} = H_{ui} \cdot (1 - \kappa) + H_{\gamma i} \cdot \kappa \\ H_{\gamma i} = H_{\gamma i} \cdot (1 - \kappa) + H_{ui} \cdot \kappa \end{cases} \quad (9)$$

式中: κ 是 $[0, 1]$ 之间的随机数.

③ 变异操作:选取个体 u 的基因组 H_u 的第 i 个位置的基因 H_{ui} 进行变异操作:

$$H_{ui} = \begin{cases} H_{ui} + (H_{ui} - H_{\max}) \cdot r_a \cdot (1 - g/G_{\max})^2, & v_a > 0.5 \\ H_{ui} + (H_{\min} - H_{ui}) \cdot r_a \cdot (1 - g/G_{\max})^2, & v_a \leq 0.5 \end{cases} \quad (10)$$

式中: $[H_{\min}, H_{\max}]$ 为基因 H_{ui} 的取值范围; g 为当前迭代次数; G_{\max} 为迭代总次数; r_a 为随机数; v_a 为 $[0, 1]$ 之间的随机数.

(2) PSO种群更新过程.

个体 u 根据自身的空间位置信息、移动速度,以及种群中适应度值最优的个体的空间位置信息,更新个体 u 的移动速度和位置信息,即

$$\begin{cases} V_u^{k+1} = \omega \cdot V_u^k + c_1 \cdot r_1 \cdot (P_u^k - H_u^k) + c_2 \cdot r_2 \cdot (P_g^k - H_u^k) \\ H_u^{k+1} = H_u^k + \alpha \cdot V_u^{k+1} \end{cases} \quad (11)$$

式中: V_u^k 和 H_u^k 分别表示第 k 次迭代时个体 u 的移动速度和位置信息; P_u^k 为个体 u 在 k 次迭代过程中适应度值最优时的位置信息; P_g^k 为第 k 次迭代时种群中适应度值最优的粒子的位置信息; c_1, c_2 为非负加速因子; r_1, r_2, α 为分布于 $[0, 1]$ 之间的随机数; ω 为惯性权重因子.

GA 和 PSO 根据建立的个体、种群,以及适应度函数,通过各自的种群更新机制不断产生新的种群,依靠个体的适应度值来最终确定出种群中的最优个体;然后将其作为 BPNN 的初始权值和阈值实现对网络的训练.

2.2 基于 GA-PSO 混合优化的 BPNN 车速预测方法

GA 和 PSO 采用不同的种群更新机制容易导致两者的寻优结果不同.为了进一步提高搜寻结果的最优性,提出将 GA 和 PSO 的寻优过程进行交叉融合的算法.其基本思想是:在每一步寻优过程中,基于同一个规模为 S 个个体的父辈种群,两者分别按照各自的种群更新机制产生规模为 S 的新种群,并计算各自新种群的适应度值;依照适应度值,从两个新种群的 $2 \cdot S$ 个个体中选择出适应度值较优的 S 个个体重新组合成新种群,并将其与父辈种群进行优劣对比,选择优的种群作为两者下一次迭代的共同的父辈种群,如此反复直至满足终止条件;最后,将满足条件的种群中的最优个体对应的权值和阈值赋值给 BPNN,完成网络训练.由此,基于 GA-PSO 混合优化的 BPNN 车速预测方法的实现过程如图 5 所示.

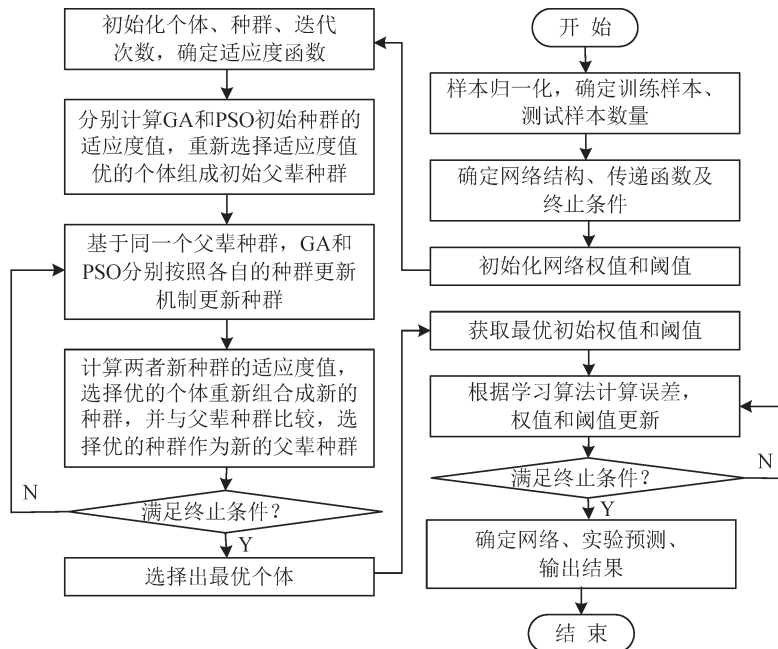


图5 基于 GA-PSO 混合优化的 BPNN 车速预测方法流程图

Fig. 5 The flow chart of the proposed method

3 实验验证

3.1 实验条件

(1) 实验基本参数.

1) BPNN 参数选取.

① 样本分配.为了保证训练效果,Matlab 默认训练、测试样本分别占总样本的70%、30%,当前亦按此比例分配.

② 样本归一化.

$$z = (Z - Z_{min}) / (Z_{max} - Z_{min}) \tag{12}$$

式中: z 为实际值 Z 的量化值; $Z \in [Z_{min}, Z_{max}]$.

③ 训练目标.为了保证BPNN的学习速度和精度,一般情况学习速率 $\beta \in (0, 1]$ 、训练目标 $E \in (0, 1]$,当前取 $\beta = 0.05$ 、 $E \leq 0.000\ 1$.

2) 优化算法参数.

① σ 选取.如图4所示的网络结构:3个输入、1个输出、隐层含5个神经元,则 $\sigma = 3 \times 5 + 5 \times 5 \times 1 + 1 = 26$.

② S 和 G_{max} 选取.理论上, S 和 G_{max} 越大越好,但随之增加了搜寻时间;在保证 $E \leq 0.000\ 1$ 的前提下,考虑到实际应用,设定 $S = 10$ 、 $G_{max} = 50$.

③ 其他参数选取. $c_1, c_2, r_1, r_2, \alpha, \omega$ 是为了调节寻优效果而引入的调节因子,一般根据 E 进行人为调节,当前设定 $c_1 = c_2 = 1.5$,其他参数均取1.

(2) 误差判断标准.

预测结果采用4种误差评价:绝对误差AE、平均绝对误差MAE、均方误差MSE、平均相对误差MRE,计算公式如下:

$$\begin{cases} AE = y_i - d_i \\ MAE = \frac{1}{N} \cdot \sum_{i=1}^N |y_i - d_i| \\ MSE = \frac{1}{N} \cdot \sum_{i=1}^N (y_i - d_i)^2 \\ MRE = \frac{1}{N} \cdot \sum_{i=1}^N \left| \frac{y_i - d_i}{d_i} \right| \end{cases} \tag{13}$$

式中: N 为测试数据个数; y_i 和 d_i 分别为预测值和真实值.

3.2 车速预测及精度分析

结合图3所示的样本信息,分别利用基于BPNN的预测法(方法1)、基于GA-BPNN的预测法^[10](方法

2)、基于PSO-BPNN的预测法^[10](方法3),以及基于GA-PSO混合优化的BPNN预测方法(方法4)得出4种速度预测模型.其中方法2、3、4对应的网络模型训练完成后,得到的种群平均适应度值曲线如图6所示.

由于篇幅限制,当前阶段,利用4种方法对2016-08-11~12的车速进行预测.真实速度与预测速度的曲线如图7所示;两者之间的AE如图8所示;MAE、MSE、MRE如表2所示.




图6 种群平均适应度值变化曲线

Fig. 6 The changing curves of the average fitness value of the population

表2 预测误差

Table 2 The prediction errors

日期	方法	MAE	MSE	MRE
2016-08-11	方法1	1.420 4	0.042 8	0.033 6
	方法2	0.594 6	0.019 0	0.014 5
	方法3	0.556 3	0.018 5	0.013 4
	方法4	0.408 2	0.014 3	0.010 2
2016-08-12	方法1	2.064 4	0.063 5	0.043 2
	方法2	0.946 6	0.033 8	0.021 8
	方法3	0.696 8	0.025 5	0.016 1
	方法4	0.633 2	0.021 2	0.013 2

首先,如图6所示,与方法2、3相比,由于方法4将GA和PSO的寻优过程进行融合,并通过逐次迭代取两者最优种群的方式实现参数寻优,因此方法4每次迭代得到的种群的平均适应度值均比方法2、3小,使得最终得到的最优个体也比两者更优.




图7 2016-08-11~12 速度预测

Fig. 7 The predicted speeds from 2016-08-11 to 2016-08-12




图8 真实速度与预测速度的AE

Fig. 8 AE between the real speeds and predicted speeds

其次,如图7所示,2个行车周期内,4种方法预测的车速变化趋势均可以跟随真实速度的变化趋势;图8给出了4种方法预测的车速与真实速度之间的AE,在3594个预测点中,方法1、2、3、4对应的速度误差范围分别为 $[-8.12 \text{ km/h},$

$9.05 \text{ km/h}]$ 、 $[-4.69 \text{ km/h}, 4.95 \text{ km/h}]$ 、 $[-4.57 \text{ km/h}, 3.2 \text{ km/h}]$ 、 $[-3.54 \text{ km/h}, 3.04 \text{ km/h}]$;结合表2给出的MAE、MSE、MRE可以得出:①相对于方法1,加入寻优算法的方法2、3、4的速度预测误差得到了不同程度的减小;②相对于方法2、3,方法4的平均车速预测误差分别降低了37.1%和24.1%。

基于此,相较于另外两种基于BPNN的预测优化方法,本文提出的方法可以有效地提高车速的预测精度。

4 结 论

本文针对BPNN不同的初始权值和阈值会影响车速预测精度的问题,提出了一种基于GA-PSO混合优化的BPNN车速预测方法.该方法以实际道路为研究对象,与已提出的基于优化算法的BPNN车速预测方法(基于GA-BPNN的预测法、基于PSO-BPNN的预测法)进行了速度预测实验对比.结果显示,相较于已有的BPNN优化预测方法,提出的方法的平均车速预测误差得到了不同程度的降低.说明,提出的方法可以进一步提高车速的预测精度。

参考文献:

- [1] ZOU Y, LIU T, LIU D X, et al. Reinforcement learning-based real-time energy management for a hybrid tracked vehicle[J]. Applied Energy, 2016(171): 372-382.
- [2] SOON-IL JEON, SUNG-TAE JO, YEONG-IL PARK, et al. Multi-mode driving control of a parallel hybrid electric vehicle using driving pattern recognition[J]. Journal of Dynamic Systems Measurement and Control, 2002, 124(1): 141-149.
- [3] 解少博, 阿比旦, 魏朗. 公路运行车速预测模型对比分析[J]. 长安大学学报(自然科学版), 2013, 33(6): 81-85. [XIE S B, A B D, WEI L. Comparative analysis of prediction model for vehicle operating speed[J]. Journal of Chang'an University(Natural Science Edition), 2013, 33(6): 81-85.]
- [4] 王栋, 邓北川, 仇建华, 等. 山区高速公路直线段车速预测方法[J]. 交通科学与工程, 2014, 30(3): 81-86. [WANG D, DENG B C, QIU J H, et al. The method of the straight section speed prediction on the mountainous freeway[J]. Journal of Transport Science and Engineering, 2014, 30(3): 81-86.]
- [5] 欧阳, 周舟, 唐国强, 等. 自适应路况的插电式混合动力汽车能量管理策略[J]. 中国公路学报, 2016, 29(9): 152-157. [OU Y, ZHOU Z, TANG G Q, et al. Control strategy for plug-in hybrid electric vehicle based on self-adaptive road condition[J]. China Journal of Highway and Transport, 2016, 29(9): 152-157.]
- [6] 朱大奇, 史慧. 人工神经网络原理及应用[M]. 北京: 科学出版社, 2006. [ZHU D Q, SHI H. Principle and application of artificial neural network[M]. Beijing: Science Press, 2006.]
- [7] 李松, 刘力军, 解永乐. 遗传算法优化BP神经网络的短时交通流混沌预测[J]. 控制与决策, 2010, 26(10): 1581-1585. [LI S, LIU L J, XIE Y L. Chaotic prediction for short-term traffic flow of optimized BP neural network based on genetic algorithm[J]. Control and Decision, 2010, 26(10): 1581-1585.]
- [8] 卢建中, 程浩. 改进GA优化BP神经网络的短时交通流预测[J]. 合肥工业大学学报(自然科学版), 2015, 38(1): 127-131. [LU J Z, CHEN H. Short-term traffic flow forecast based on modified GA optimized BP neural network[J]. Journal of Hefei University of Technology (Natural Science Edition), 2015, 38(1): 127-131.]
- [9] 李松, 刘力军, 翟曼. 改进粒子群算法优化BP神经网络的短时交通流预测[J]. 系统工程理论与实践, 2012, 32(9): 2045-2049. [LI S, LIU L J, ZHAI M. Prediction for short-term traffic flow based on modified PSO optimized BP neural network[J]. System Engineering-Theory & Practice, 2012, 32(9): 2045-2049.]
- [10] 谢浩. 基于BP神经网络及其优化算法的汽车车速预测[D]. 重庆: 重庆大学, 2014. [XIE H. Prediction of driving speed based on BP neural network and optimization algorithm[D]. Chongqing: Chongqing University, 2014.]