

中图法分类号: P208 文献标志码: A 文章编号: 1006-8961(2010)11-1688-08

检索信息: 欧阳俊, 陆锋, 刘兴权, 段滢滢. 基于多核混合支持向量机的城市短时交通预测[J]. 中国图象图形学报, 2010, 15(11): 1688-1695

基于多核混合支持向量机的城市短时交通预测

欧阳俊^{1),2)}, 陆锋¹⁾, 刘兴权²⁾, 段滢滢¹⁾

¹⁾ (中国科学院地理科学与资源研究所资源与环境信息系统国家重点实验室, 北京 100101)

²⁾ (中南大学地学与环境工程学院, 长沙 410083)

摘要: 城市道路交通的不确定性、非线性和时空相关性使得交通系统参数描述和知识获取极为困难, 从而使短时交通预测难以获得满意结果。利用多核混合支持向量机识别和处理不同类别输入数据的能力, 提出了一种基于多核混合支持向量机的城市短时交通预测方法。该方法在统计分析交通状态数据样本的基础上, 继承了支持向量机良好的泛化能力、全局最优和较强自适应性的特点, 并采用改进的粒子群算法对支持向量机的参数进行了优化选择。同时, 针对道路实时交通状态与历史平均交通状态较强的线性相关性、道路实时交通状态与前几时段交通状态及上下游路段实时交通状态的非线性相关性, 分别设计了线性核函数和非线性核函数对城市交通状态进行映射和拟合。该方法既考虑到交通状态历史规律对预测的指导意义, 又顾及交通的时变特征, 充分提取了交通系统相关参数的知识信息。实验结果表明, 本文提出的短时交通流预测方法具有准确性、鲁棒性和自适应性特点, 具有较好的实际应用价值。

关键词: 短时交通预测; 支持向量机; 多核; 粒子群算法

Short-term urban traffic forecasting based on multi-kernel SVM model

OU Yangjun^{1),2)}, LU Feng¹⁾, LIU Xingquan²⁾, DUAN Yingying¹⁾

¹⁾ (State Key Laboratory of Resources and Environmental Information System, Institute of Geographical Science and Natural Resources Research, CAS, Beijing 100101)

²⁾ (School of Geoscience and Environmental Engineering, Central South University, Changsha 410083)

Abstract: City road traffic system is characterized as a system of nonlinearity, uncertainty and spatial-temporal correlation, which makes traffic system parameters description and knowledge extraction difficult, and results in current short-term traffic forecast methods can not obtain satisfactory accuracy. This paper presents a hybrid multiple-kernel support vector machine model (MSVM) for conducting short-term traffic forecast. With statistical analysis of large amounts of traffic condition data samples, the proposed model not only has a capacity of recognizing and dealing with different types of input data separately, but also takes advantages of global optimization, generalization and adaptability of support vector machine. Moreover, the parameters of the hybrid model is optimized with an improved particle swarm algorithm (PSO). Aiming at the linear correlation between real time and historical traffic condition, the nonlinear correlation between real time and previous time period, and also up and downstream traffic condition, the proposed model uses a linear kernel to extract the linear pattern of traffic flow and a nonlinear kernel to map the nonlinear pattern of residuals from the linear kernel. Both the historical regularity and time-variation characteristics of city road traffic are considered in the MSVM model so as to obtain

基金项目: 国家自然科学基金项目(40871184); 国家高技术研究发展计划(863)项目(2007AA12Z241); 资源与环境信息系统国家重点实验室自主创新团队计划项目(088RA400SA)。

收稿日期: 2010-07-16; **改回日期:** 2010-09-06

第一作者简介: 欧阳俊(1985—), 男, 中南大学地学与环境工程学院硕士研究生。主要从事交通地理信息系统技术研究。E-mail: ouyj@reis.ac.cn。

the knowledge from the influential factors of real time traffic condition in order to improve forecast accuracy. The experimental results show that the proposed model behaves satisfactory performance and robustness, and has a good potential for applications.

Keywords: short-term traffic forecast; support vector machine; multiple kernels; particle swarm algorithm

0 引 言

及时准确的短时交通预测是交通诱导、信号自动配时优化的关键。短时交通预测是指预测道路 5 分钟至 1 小时以内的交通状态,包括交通流、行车速度变化等^[1]。交通状态受到出行者出行目的、行为习惯、实时思维调整和突发事件等因素影响。随着观测时间尺度的缩短,交通系统逐渐由确定性状态经非线性状态转化至混沌状态,最后演变成随机状态。因此,短时交通变化表现出高度的非线性、时变性和不确定性特征^[2],决定了短时交通预测方法必须具有实时性、泛化性、鲁棒性和自适应性。

目前为止,国内外业界已经提出了几十种短时交通预测方法,从早期的历史平均模型(HP)^[3]、时间序列法(如 ARIMA)^[4]、卡尔曼滤波(Kalman filtering)^[5],逐渐发展到近期的非参数回归(nonparametric regression)^[6]、人工神经网络(ANN)^[7]、动态交通分配(dynamic traffic assignment)^[8]、灰色模型(GM)^[9]、支持向量机(SVM)^[10]、混沌理论(chaos theory)^[11]等预测方法。常见的短时交通预测方法大致可以分成 3 类^[12]:线性模型方法、非线性模型方法和混合方法。

基于线性模型的短时交通预测方法力求利用交通流历史数据建立确定性统计模型来推断短期未来交通状态。其方法简单,可以预测交通状态的整体变化趋势,但当预测时间尺度变短时,随着道路交通变化不确定性的增强,模型的预测性能逐渐变差,难以反映城市交通的时变特性。

自 1993 年 Vythoulkas^[13]首次提出用 ANN 进行城市道路网络交通状态预测以来,ANN、SVM 等非线性模型引起了业界的广泛重视,并应用于短时交通预测过程。同线性模型方法方法相比,非线性模型方法考虑了交通流的多维性和时空相关性,表现出较高的整体预测精度和较强的自适应能力。但当交通流处于平稳状态时,非线性模型方法预测精度反而偏低,甚至可能出现整体偏移真实值的现象。

道路交通系统具有历史规律性、时变性和空间非线性相关性。线性和非线性模型方法均不能完全反映交通流的本质特征^[14]。因此,混合方法逐渐成为研究热点。文献[15]使用了 RBF-NN 和 SVM 组合模型,虽然预测精度较高,但组合参数的确定需要大量数据的训练,且各个模型相互独立,残差互补性差,导致预测精度不稳定;文献[16]利用小波理论,先把交通流数据分解成多个平稳向量,分别用 SVM 模型预测,最后对分量预测结果进行数据重构,虽然提高了预测精度,但融合后的模型极其复杂、计算量大;文献[17]尝试先用 ARIMA 模型进行线性预测,用 ANN 模型进行非线性预测,发挥两种模型的优势,从而提高预测准确度。但由于 ARIMA 模型的自适应较 ANN 模型差,不能保证这类混合模型参数更新的同步性,自适应能力较弱。此外,这种组合模型存在着线性理论方法的 1 维参数输入和非线性理论方法的多维参数输入的不一致、模型融和性差的缺陷。

总的来说,目前基于组合预测理论和各模型混合的短时交通预测方法,在一定程度上能有效改善模型的拟合能力,提高预测精度,但却增加了模型的复杂度,牺牲了模型效率,难以保证短时交通预测的实时性和自适应性。

鉴于此,本文提出了一种基于多核混合支持向量机(MSVM)的短时交通预测方法,兼顾交通状态的历史规律性和时变性特征。该方法在统计分析交通状态数据样本的基础上,继承了 SVM 良好的泛化能力、全局最优和较强自适应性的特点,并采用改进的粒子群算法对 MSVM 的参数进行了优化。同时,针对道路实时交通状态与历史平均交通状态较强的线性相关性,及其道路实时交通状态与前几时段的交通状态及上下游路段实时交通状态的非线性相关性,分别设计了线性核和非线性核函数进行映射和回归,构建 MSVM。该模型既考虑到交通状态历史规律对预测的指导意义,又顾及了实时交通的时变性,充分提取各参数的知识信息,实现了短时交通变化的自适应预测。

1 多核混合支持向量机与参数优化

1.1 支持向量机

SVM 是 1995 年 Vapnik 提出的针对分类和回归问题的统计学习理论^[18]。SVM 基于结构风险最小化原则,与其他的非线性预测模型相比,可以避免易陷入局部最优的缺陷,具有良好的泛化性和严密的统计学理论基础,正成为机器学习、模式分类和预测的研究热点。给定 l 个样本集 $\{(\mathbf{x}_i, y_i) \mid \mathbf{x}_i \in \mathbf{R}^p, y_i \in \mathbf{R}\}_{i=1}^l$, \mathbf{x}_i 是一个 p 维样本输入实数向量, y_i 是对应输出实数, SVM 的基本思想是通过核函数 $k(\mathbf{x})$ 把输入样本向量映射到 N 维特征空间,在特征空间构造最优决策函数,

$$f(\mathbf{x}) = \sum_{i=1}^N \omega_i k(\mathbf{x}, \mathbf{x}_i) + b \quad (1)$$

式中, $\boldsymbol{\omega} = (\omega_1, \omega_2, \omega_3, \dots, \omega_N)^T$ 为线性权值向量, b 为阈值。如果采用不敏感损失函数 $L_\varepsilon(\mathbf{x}_i, y_i, f) = \max\{0, |y_i - f(\mathbf{x}_i)| - \varepsilon\}$ ($\mathbf{x}_i \in \mathbf{R}^p$ 是第 i 个输入, $y_i \in \mathbf{R}$ 对应的期望输出), 并引入非负的松弛变量, 其约束化问题可表示为

$$\begin{cases} \min \frac{1}{2}(\boldsymbol{\omega} \cdot \boldsymbol{\omega}) + \frac{C}{l} \sum_{i=1}^n (\varepsilon_i + \varepsilon'_i) \\ \text{s. t. } [\omega_i k_i(\mathbf{x}) + b] - y_i \leq \varepsilon + \varepsilon'_i \\ y_i - [\omega_i k_i(\mathbf{x}) + b] \leq \varepsilon + \varepsilon'_i \\ \varepsilon_i, \varepsilon'_i \geq 0 \end{cases} \quad (2)$$

式中, C 为惩罚系数, ε 为不敏感损失系数。该式优化问题可通过引入拉格朗日函数将其转化为对偶问题,通过对偶问题得到式(1)的解:

$$f(\mathbf{x}) = \sum_{i=1}^N (\beta_i - \beta'_i) k(\mathbf{x}, \mathbf{x}_i) + b \quad (3)$$

式中, β_i 和 β'_i 分别为两个松弛变量对应的拉格朗日系数。

1.2 多核混合支持向量机 (MSVM)

在 SVM 进行回归预测时,核函数首先会把样本向量从原空间利用核函数映射到高维线性空间,然后在高维线性空间中构造最优逼近函数。常见的核函数有:

线性核函数: $k(\mathbf{x}, \mathbf{x}_i) = \mathbf{x} \cdot \mathbf{x}_i$

Sigmoid 核函数

$$k(\mathbf{x}, \mathbf{x}_i) = 1/1 + \exp[\beta(\mathbf{x} \cdot \mathbf{x}_i) + b]$$

高斯核函数

$$k(\mathbf{x}, \mathbf{x}_i) = \exp[-\|\mathbf{x} - \mathbf{x}_i\|^2 / 2\lambda^2]$$

核函数的类型会影响模型预测的精度,而核函数的选取取决于样本数据的分布和样本输入变量与预测输出变量的关系^[19]。在 SVM 中,由于不同特征空间中数据的分布不同,支持向量机的性能很大程度上取决于核函数的选择。但是,目前却没有一种核函数的选择方法可以获得理论上的支持。而且传统的支持向量机只采用一个核函数,这样它就不足以解决一些涉及多个不同数据源的复杂问题。

Cristianini 针对这个问题,对单核核函数进行拓展,提出构造适合不同样本数据类型输入的多核混合核函数^[20]:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \sum_{m=1}^M \sigma_m k_m(\mathbf{x}_i, \mathbf{x}_j) \quad (4)$$

式中, M 是核的数目, $\{\sigma_m\}_{m=1}^M$ 是凸组合约束下 $\sigma_m \geq 0, 1 \leq m \leq M$ 的系数。

MSVM 可以针对不同作用类型的样本输入,分别采用不同的核函数进行映射,充分利用各种不同类型的输入变量的信息知识,提高模型的预测精度。

1.3 基于粒子群算法的 SVM 参数优化

SVM 模型参数的选择对预测精度有着重要的影响^[21]。惩罚系数 C 控制回归模型的鲁棒性;不敏感损失系数 ε 决定模型支持向量的数目,也间接影响拟合的精度。不敏感损失函数参数 ε 、误差惩罚参数 C 和核函数 $\phi(x)$ 的类型和参数是影响模型预测性能的关键。目前还没有严格的理论来直接确定这 3 个参数,常用的 SVM 参数选择方法有经验确定法、网格搜索法和遗传算法等智能优化方法。目前,用于 SVM 参数选择的智能优化方法已经成为共识^[22]。本文采用一种改进的粒子群算法进行 SVM 参数优化。

粒子群优化算法 (PSO) 是由 Eberhart 和 Kennedy 提出的一种源于对鸟群捕食的行为模拟的进化计算方法^[23]。针对离散问题的优化应用,在 1997 年, Eberhart 等相继提出二进制 PSO 算法^[24]。

在 PSO 中,将每个粒子看做是搜索空间中的一点,所有的粒子都有一个表示当前在搜索空间中位置的属性 $\boldsymbol{\chi} = (\chi_1, \chi_2, \chi_3, \dots, \chi_n)^T$, $\boldsymbol{\chi}$ 是优化参数向量, n 为优化参数的个数,并由评价函数计算其适应度,每个粒子的速度 $\mathbf{v} = (v_1, v_2, v_3, \dots, v_n)$ 决定它们优化运动的方向和距离。粒子之间通过共享当前最优粒子的信息进行搜索。

$$\begin{aligned} v_i(t+1) &= \omega v_i(t) + c_1 r_1 (p_i - \chi_i(t)) + \\ & c_2 r_2 (p_g - \chi_i(t)) \end{aligned} \quad (5)$$

$$\chi_i(t+1) = \chi_i(t) + v_i(t+1) \quad (6)$$

式(5)是粒子 i 从第 t 次至 $t+1$ 次的速度更新公式, $p_i = (p_i^1, p_i^2, p_i^3, \dots, p_i^n)$ 表示粒子 i 的局部最优值, $p_g = (p_g^1, p_g^2, p_g^3, \dots, p_g^n)$ 表示整个粒子群的全局最优值。 c_1 和 c_2 是两个正常数, 分别为局部学习因子和全局学习因子。式(6)是粒子的位置更新公式。

选用基于二进制编码的 PSO 算法进行 SVM 参数优化。以高斯核函数 $K(x, x_i) = \exp(-\|x - x_i\|^2/2\lambda^2)$ 为例, 需要优化的参数有: 核参数 λ 、不敏感损失函数参数 ε 和误差惩罚参数 C 。即参数 λ 、 ε 和 C 均表示成二进制位串的粒子 $(\lambda, \varepsilon, C)^T$, 编码如图 1 所示。




图 1 SVM 参数粒子编码

Fig. 1 Particle codes of the SVM parameters

粒子的适应度函数用每次迭代后 SVM 回归的平均绝对误差表示:

$$E_{\text{fitness}} = \sqrt{\sum_{i=1}^n (Y_i - Y_i^*)^2} / n \quad (7)$$

式中, n 为样本数, Y_i^* 为样本预测值, Y_i 为样本实际值。

2 城市道路短时交通预测过程

城市交通系统是一个有人参与的、动态的和开放的复杂系统。道路的实时交通变化趋势不仅与当前时段的历史平均交通状态、上一时段甚至前几时段的实时交通状态相关; 而且与上下游路段同方向车流的交通状态相关。对罗马、伦敦和佛罗里达州的城市道路行车速度数据统计表明, 行车速度数据近似服从高斯分布^[25-27]。道路行车速度在时间维上具有线性稳定性和历史规律性, 在空间维上具有孤波、三角激波和扭状孤立波特征, 道路上下游间的实时行车速度具有非线性相关性^[28]。

本文在构建预测模型输入变量时, 以路段历史平均速度、前几个时刻的行车速度及其上游路段前几个时刻的行车速度作为参数输入, 采用回溯系数为 p 进行指标选取, 即考虑前 p 个时段对预测路段实时行车速度的影响。设路段 i 的上游路段有路段 j, k, \dots, m , $V(i, t-1)$ 为路段 i 上的 $t-1$ 时刻的

车速度, $V_{\text{aver}}(i, t-1)$ 为路段 i 上的 $t-1$ 时刻的历史平均速度, $V(j, t-1)$ 为路段 i 的其上游路段 j 上的 $t-1$ 时刻的行车速度。预测当前时刻 $V(i, t)$ 样本的行车速度的样本输入如表 1 所示。

表 1 模型变量输入

Tab. 1 Representation of input variables

上游值		自身值	历史平均值
$V(j, t-1)$	\dots $V(m, t-1)$	$V(i, t-1)$	$V_{\text{aver}}(i, t-1)$
$V(j, t-2)$	\dots $V(m, t-2)$	$V(i, t-2)$	$V_{\text{aver}}(i, t-2)$
\dots	\dots	\dots	\dots
$V(j, t-p)$	\dots $V(m, t-p)$	$V(i, t-p)$	$V_{\text{aver}}(i, t-p)$

针对不同数据类型的变量输入, 采用 MSVM, 首先用线性核对交通数据样本进行线性映射和拟合以提取交通状态的线性稳定部分, 然后用非线性核对线性核拟合的残差部分进行非线性映射和拟合获取交通状态的非线性部分, 公式如下:

$$H = L + N \quad (8)$$

式中, L, N 为混合模型预测的短时交通状态的线性、非线性部分, H 为最终的预测值。

基于粒子群优化的 MSVM 模型的训练流程如图 2 所示。具体步骤如下:

- 1) 初始化粒子群环境参数;
- 2) 对线性核参数粒子和高斯核参数粒子进行初始化和编码;

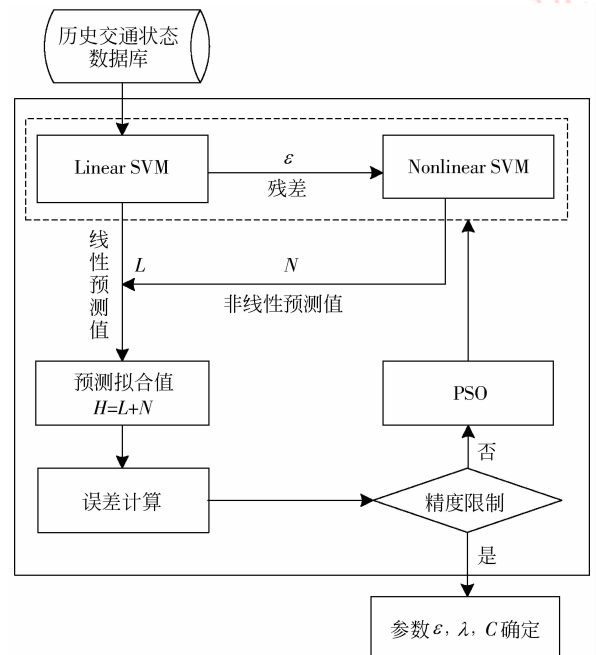


图 2 MSVM 模型训练流程

Fig. 2 Training of the MSVM model

3) 由历史交通流数据库输入样本数据,通过线性核 (LSVM-PSO) 进行映射和回归;

4) 计算 LSVM-PSO 回归后的残差,通过非线性核 (NSVM-PSO) 对残差部分进行映射和回归;

5) 根据式(7),计算粒子适应度值;

6) 根据式(5)(6),更新粒子的速度和二进制值;

7) 针对每个编码粒子依次按步骤2)~6)进行;

8) 重复步骤3)~7),使线性核参数粒子和非线性核参数粒子不断的更新,直到训练样本误差控制在精度范围内,得到模型参数的最优解并输出。

基于 MSVM 的短时交通预测模型框架包括训练模块和预测模块,首先从历史交通状态数据中提取训练样本通过 MSVM 模型进行训练,确定模型参数和系数;然后根据输入的实时交通状态数据进行预测并输出。当预测误差超过精度限制,历史交通状态数据对实时交通状态数据的预测失去指导作用时,模型自适应地进行重新训练和参数更新。

3 实例

3.1 实验数据

实验数据为北京市四环内周期为 5 min 的浮动车采集的路段行车速度数据。实例中首先选取阜成路由西向东车行道为测试路段,其上游有阜成路南一街、阜成路北三街;然后选取官园桥、朝阳门桥和远大桥等 5 个区域的平安里西大街、朝阳门内大街、远大路、白纸坊西街和阜成路路段,进行平均相对误差对比试验。选择 2007 年 7 月 2 日至 2007 年 8 月 4 日共 5 周的 05:00—21:00 数据作为训练样本,对 2007 年 8 月 9 日即星期四的 05:00—21:00 行车速度进行预测和验证。

对北京市四环内的环线、主干道和次干道进行分层抽样统计,图 3 为抽样一天的实测行车速度与历史平均速度样本散点图,图 4 为道路周一至周五的 08:00、12:00 和 18:00 时刻的行车速度值的概率分布统计。

由图 3 样本数据,计算时间段 06:00—09:00、11:00—14:00 和 18:00—21:00 3 组 36 个样本点的相关系数分别为 $r_1 = 0.753$ 、 $r_2 = 0.427$ 和 $r_3 = 0.671$,在显著水平 $\alpha = 0.01$,自由度 $n = 36 - 2$ 时,根据 t 检验法查表可得,相关系数临界值 $r_{\alpha(34)} = 0.413$ 。由于 r_1 、 r_2 、 r_3 均大于 0.413,因此 $P < 0.01$,3 组样本均拒绝线性无关的假设。可以看出,北京




图 3 实时行车速度与历史平均速度关系

Fig. 3 Comparison of the real-time and historical average speed

市道路行车速度与历史平均速度线性相关,表现出一定的线性稳定性。

图 4 中 08:00、12:00 和 18:00 时刻的道路行车速度值的概率分布统计图的偏度系数和峰度系数依次为 0.189 和 -0.1302、0.032 和 0.417、-0.071 和 -0.4163,均小于 1。可以看出北京市道路实时行车速度呈现非线性,近似服从高斯分布。因此本文 MSVM 模型的核函数选用线性核 (LSVM) 和高斯核函数 (NLSVM),其预测结果由 LSVM 和 NLSVM 两者预测的结果组合而成。




图 4 固定时刻点道路行车速度概率密度

Fig. 4 A probability distribution of section vehicles speed at fixed time

另外,分别选取了 HP 方法、BP 神经网络方法 (BP-NN) 和标准的 SVM 方法与本文模型进行对比。为了更好地比较模型预测结果和分析模型预测性能,引入表 2 评价指标。

表 2 模型性能指标

Tab.2 Performance indexes for the forecasting model

序号	指标	公式
1	平均绝对百分误差	$MAPE = \frac{\sum_{i=1}^n (Y_i - Y_i^*) / Y_i }{n}$
2	平均绝对误差	$MSE = \frac{\sum_{i=1}^n (Y_i - Y_i^*)^2}{n}$
3	相关系数	$R = \frac{\sum (Y - \bar{Y})(Y^* - \bar{Y}^*)}{\sqrt{\sum (Y - \bar{Y})^2 \sum (Y^* - \bar{Y}^*)^2}}$

3.2 参数设置和优化

为了便于对比分析, BP-NN、SVM 和 MSVM 模型选用相同的变量输入。BP-NN 选用 3 层结构, 隐含层结点的数目为 $2N + 1$, 其中 N 为输入结点的数目。标准 SVM 模型的核函数选用单核的高斯核函数。SVM 和 MSVM 进行训练参数优化时, 粒子群算法的参数均设置相同。在训练阶段, 初始化回溯系数 p 为 3, 通过粒子群算法分别优化 SVM 和 MSVM 中的 LSVM 和 NLSVM 的参数如表 3 所示。

表 3 SVM 参数优化值

Tab.3 Optimized parameters with the improved PSO

模型	λ	C	ε
SVM-PSO	0.016 6	0.737 4	0.471 1
LSVM-PSO	0	0.37	0.991 5
NLSVM-PSO	0.02	307.89	0.049

在 MSVM-PSO 模型中, 设定上表优化的 λ 、 C 和 ε 值, 然后调节不同的回溯系数 p 值, 进行样本训练和预测验证, 计算预测平均相对误差 MAPE 和样本训练时间 T 如表 4 所示。

表 4 不同 p 值的预测性能指标表

Tab.4 Errors and training time according to different p

p	1	2	3	4	5	6	7
MAPE/%	19.67	14.45	11.18	11.07	11.40	12.17	12.38
T/s	120	171	221	296	355	440	515

从上表可以看出, MAPE 随着 p 值的增长而逐渐变小最后趋于平稳, 样本训练时间 T 随着 p 值的增长而快速增加。综合模型的训练效率和预测精度两个指标的考量, 本文确定模型回溯系数 p 优化值为 3。

3.3 结果和分析

首先选取阜成路为测试路段, 各种模型预测的实验结果如图 5 所示。预测结果性能比较见表 5。

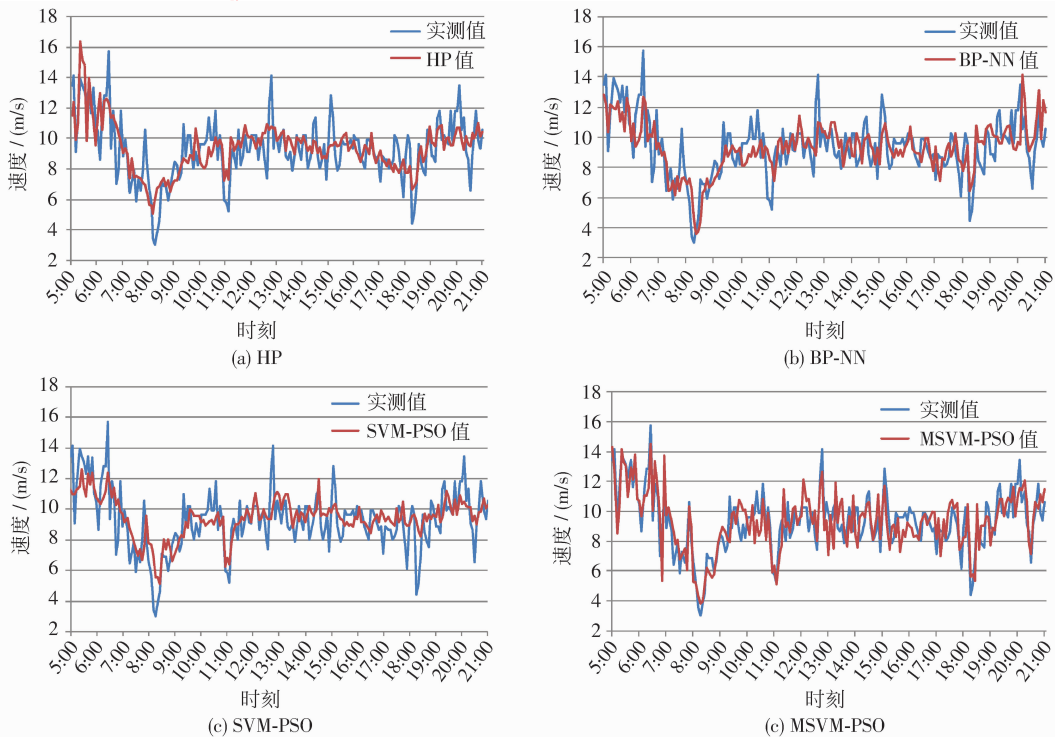


图 5 行车速度短时预测结果

Fig.5 Comparison of the forecast results with HP, BP-NN, SVM-PSO and MSVM-PSO

结果表明,基于 MSVM 的短时交通模型误差最小,相关系数最大。

表 5 模型预测性能对比

Tab.5 Performance comparison of HP, BP-NN, SVM-PSO and MSVM-PSO

模型	MAPE/%	MSE	R
HP	13.566	1.441	0.707
BP-NN	14.688	1.538	0.664
SVM-PSO	13.555	1.420	0.725
MSVM-PSO	10.963	1.032	0.837

同时,针对一天 05:00—21:00 间隔为 5 min 的 193 个时间点的行车速度,对各种预测模型的 MAPE 进行了统计,如图 6 所示。HP、BP-NN、SVM 和 MSVM 的预测值 MAPE 在 0~7.126%、7.126%~14.252% 两个区间的个数依次为 127、104、132 和 149,比率依次为 65.81%、53.87%、68.39% 和 77.20%。可以看出,与其他模型相比,MSVM 的预测值 MAPE 较多集中在 0~14.252% 之间,整体预测精度更高,有较强的泛化能力。

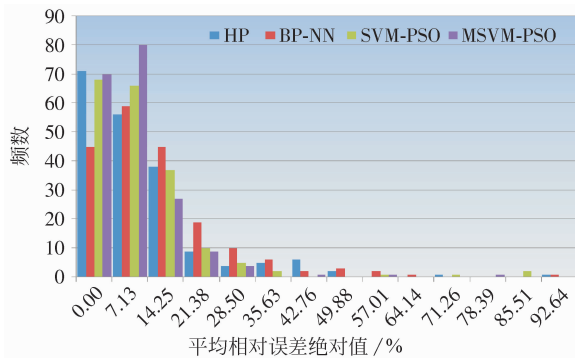


图 6 预测模型平均相对误差绝对值分布对比

Fig. 6 Absolute percentage error histogram of HP, BP-NN, SVM-PSO and MSVM-PSO

然后,随机选取 5 个区域进行平均相对误差对比试验。预测 MAPE 性能对比见图 7。结果表明,不同区域的 MSVM-PSO 模型的预测 MAPE 值均最好。由此说明 MSVM-PSO 模型同时具有时间和空间的可移植性。

最后,统计了 MSVM-PSO 模型运算的平均训练时间和平均预测时间如表 6。MSVM-PSO 模型的平均预测时间是 0.015s,具有快速计算能力,可以满足短时交通预测的实时性的要求。




图 7 5 个不同区域的预测模型平均相对误差绝对值对比

Fig. 7 Forecasting error comparison of the four methods for five different road links

表 6 MSVM-PSO 模型预测效率/s

Tab.6 Forecasting efficiency of MSVM-PSO/s

模型	平均训练	平均预测
MSVM-PSO	194	0.015

此外,同其他混合模型相比,MSVM 模型结构简单,线性核和高斯核均有相同的变量输入,可以进行统一的重新训练和参数更新,有较强的自适应能力,能满足短时交通状态的时变性对预测模型快速自我调整能力的要求。

4 结 论

道路交通系统具有历史规律性、时变性和空间非线性相关性。短时交通预测不仅需顾及时交通状态对预测时段的直接影响,也要顾及交通状态的历史规律性。而道路实时交通状态的历史线性稳定性、自相关性和上下游道路实时交通状态非线性相关性的差异性,使得难以用统一的模型兼容和充分获取各参数的知识信息。本文提出的基于多核混合支持向量机的城市短时交通预测方法,在继承支持向量机良好的泛化能力、全局最优和较强自适应特点的基础上,充分利用了 MSVM 对不同类别输入数据分别进行处理的能力,分别选用线性核函数和非线性核函数进行映射和拟合,既考虑了交通状态历史规律先验知识对短时交通预测的指导意义,又顾及了交通的时变特征和交通状态的空间相互作用,充分提取了交通系统相关参数的知识信息,从而获得了更准确的预测结果。本文提出的基于 MSVM 的短时交通流预测方法具有较好的鲁棒性和自适应性,及其较好的实际应用价值。

参考文献 (References)

- [1] Vlahogianni E I, Golias J C, Karlaftis, M G. Short-term traffic forecasting: overview of objectives and methods [J]. *Transport Review*, 2004, 24(5) : 533-557.
- [2] Xun Lunhui, Fu Hui. *Intelligent Prediction Theory and Methods of Traffic Information* [M]. Beijing: Science Press, 2009: 23-39. [许论辉, 傅惠. 交通信息智能预测理论与方法 [M]. 北京: 科学出版社, 2009: 23-39.]
- [3] Stephanedes Y J, Michalopoulos P G, Plum R A. Improved estimation of traffic flow for real-time control [J]. *Transportation Research Record*, 1981, 79(5) : 28-39.
- [4] Nancy L Nihan, Kjell O Holmesland. Use of the box and Jenkins time series technique in traffic forecasting [J]. *Transportation*, 1980, 9(2) : 125-143.
- [5] Okutani Iwao, Stephanedes Yorgos J. Dynamic Prediction of traffic volume through Kalman filtering theory [J]. *Transportation Research Part B : Methodological*, 1984, 18(1) : 1-11.
- [6] Davis Gary A, Nihan Nancy L. Nonparametric regression and short-term freeway traffic forecasting [J]. *Journal of Transportation Engineering*, 1991, 117(2) : 178-188.
- [7] Smith B L, Demetsky M J. Short-term traffic flow prediction: neural network approach [J]. *Transportation Research Record*, 1994, 145(3) : 98-104.
- [8] Mechant D K, Nemhauser G L. A model and an algorithm for the dynamic traffic assignment problems [J]. *Transportation Science*, 1978, 12(3) : 183-199.
- [9] Liu Shutang. The fuzzy prognosis of cumulative traffic volume for rebuilt highway [J]. *Journal of Highway and Transportation Research and Development*, 1997, 3(7) : (111-117).
- [10] Wu Chun Hsin, Wei Chaichen, Su Dachun, et al. Travel-time prediction with support vector regression [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2004, 5(4) : 276-281.
- [11] Dendrinos D S. Traffic-flow dynamics: a search for chaos [J]. *Chaos, Solitons and Fractal*, 1994, 4(4) : 605-617.
- [12] Lu Haiting, Zhang Ning, Huang Wei, et al. Research progress of short term traffic flow prediction methods [J]. *Journal of Transportation Engineering and Information*, 2009, 7(4) : 84-91. [陆海亭, 张宁, 黄卫, 等. 短时交通流预测方法研究进展 [J]. *交通运输工程与信息学报*, 2009, 7(4) : 84-91.]
- [13] Vythoulkas P C. Alternative approaches to short term traffic forecasting for use in driver information [C] // *University of Oxford 12th International Symposium on the Theory of Traffic Flow and Transportation: Transportation and Traffic Theory*. Amsterdam: Elsevier Science, 1993: 485-506.
- [14] Bates J M, Granger C. The combination of forecast [J]. *Operation Research Quarterly*, 1969, 20(6) : 451-468.
- [15] Zhang Yang, Liu Yuncai. Application of combined forecasting models to intelligent transportation systems [J]. *Studies in Computational Intelligence*, 2009, 214(10) : 181-186.
- [16] Li Yuancheng, Li Bo, Fang Tingjian. Nonlinear combination forecasting method based on wavelet support vector machines [J]. *Information and Control*, 2004, 33(3) : 30-306. [李元诚, 李波, 方延建. 基于小波支持向量机的非线性组合预测方法研究 [J]. *信息与控制*, 2004, 33(3) : 30-306.]
- [17] Tan Manchun, Feng Luobin, Xu Jianmin. Traffic flow prediction based on hybrid ARIMA and ANN model [J]. *China Journal of Highway and Transport*, 2007, 20(4) : 118-121. [谭满春, 冯荣斌, 徐建闽. 基于 ARIMA 与神经网络组合模型的交通流预测 [J]. *中国公路学报*, 2007, 20(4) : 118-121.]
- [18] Vapnik V, Vladimir N. *The Nature of Statistical Learning Theory* [M]. New York, USA: Springer-Verlag, 1995: 14-35.
- [19] Muller K R, Smola A J, Ratsch G, et al. Predicting time series with support vector machines [J]. *Artificial Neural Networks*, 1997, 1327(4) : 999-1004.
- [20] Cristianini N, Shawe-Taylor J, Campbell C. *Dynamically adapting kernels in support vector machines* [C] // *Proceedings of the 1998 Conference on Advances in Neural Information Processing Systems II*. Cambridge, MA, USA: MIT Press, 1998: 204-210.
- [21] Vapnik V, Golowich S E, Smola A. Support vector method for function approximation, regression estimation, and signal processing [C] // *Proceedings of the 10th Annual Conference on Neural Information Processing Systems*. Cambridge, MA, USA: MIT Press, 1997: 281-287.
- [22] Frohlich H, Chapelle O. Feature selection for support vector machines by means of genetic algorithms [C] // *Proceedings of the 15th IEEE International Conference on Tools with Artificial Intelligence*. Sacramento, CA, USA: IEEE Press, 2003: 142-148.
- [23] Kennedy J, Eberhart R C. Particle swarm optimization [C] // *Proceedings of IEEE International Conference on Neural Networks*. Piscataway, NJ: IEEE Press, 1995: 1942-1948.
- [24] Kennedy J, Eberhart R C. A discrete binary version of the particle swarm algorithm [C] // *Proceedings of the World Multiconference on Systemics, Cybernetics and Informatics*. Piscataway, NJ: IEEE Press, 1997: 4104-4109.
- [25] Corrado de Fabritiis, Roberto Ragona, Gaetano Valenti. Traffic estimation and prediction based on real time floating car data [C] // *Proceedings of the 11th International IEEE Conference on Intelligent Transportation Systems*. New York: IEEE Press, 2008: 197-203.
- [26] The United Kingdom Department for Transport. *The Reliability Sub-Objective* [R]. London: Transport Analysis Guidance Unit, 2007.
- [27] US Florida Department of Transportation. *The Florida Reliability Method in Florida's Mobility Performance Measures Program* [R]. US Florida: US Florida Department of Transportation, 2000.
- [28] Lia Z P, Liu Y C. Analysis of stability and density waves of traffic flow model in an ITS environment [J]. *The European Physical Journal B*, 2006, 53(5) : 367-374.