

# 实时交通流预测的并行 SVR 预测方法

杨际祥\*, 谭国真, 王 凡, 田 珠, 潘 东

(大连理工大学 计算机科学与技术学院, 辽宁 大连 116024)

**摘要:** 提高交通流预测的精度和实时性是智能交通系统(ITS)应用发展的一个重要问题. 与广义神经网络(GNN)方法相比, 支持向量回归(SVR)方法应用于交通流预测理论优势得以实现的前提是选取合适的回归参数. 分析、讨论了简单而实际的直接从训练集中选取 SVR 参数的方法, 给出了一个大规模路网交通流 SVR 预测模型和集群环境下的一种贪婪负载均衡并行算法(G-LB). 实验结果证明了基于 G-LB 算法的并行 SVR 方法(GLB-SVR)可获得比并行的 GNN 方法(P-GNN)更好的预测精度和实时性.

**关键词:** 并行计算; 负载均衡; 交通流预测; 支持向量回归(SVR); 广义神经网络(GNN)

**中图分类号:** TP301;U491 **文献标志码:** A

## 0 引 言

目前,许多学者已经对交通流的预测方法进行了研究,并已证明神经网络是其中应用最为广泛且效果较好的一种方法,其优于 Kalman 滤波模型和 ARIMA 模型<sup>[1]</sup>. 然而,传统神经网络中的神经元结构和功能比较单一,神经元内部采用固定的传递函数,仅仅具有信息处理能力,缺乏信息存储能力,从而造成整个网络的信息存储能力受限,导致其寻优速度慢、实时性差和推广能力低. 为了提高神经网络的信息存储能力,有关学者提出了广义神经网络理论<sup>[2]</sup>. 利用广义神经网络进行交通流预测,其收敛速度和预测精度较普通神经网络均有很大改善<sup>[3]</sup>.

然而,由于神经网络方法利用梯度下降法来调节权值使目标函数达到极小,且目标函数为各给定输入和相应输出差的平方和,导致神经网络过分强调学习错误而不可避免地出现过拟合现象,使得模型的泛化能力受到限制. 同时,神经网络的学习方法采用经验风险最小化原理,不能使期望风险最小化,在理论上存在缺陷,常会出现需要确定网络结构、过学习或欠学习以及局部极小点等问题. 针对神经网络方法的不足, Vapnik 等

提出了基于统计学理论框架下的支持向量机(support vector machine, SVM)方法<sup>[4]</sup>,它具有很强的泛化能力,较好地解决了以往困扰很多学习方法的小样本、过学习、高维数以及局部最小等实际难题,已应用于智能交通系统领域<sup>[5]</sup>. 支持向量回归(SVR)方法基于 SVM 的基本原理,探讨和解决回归分析问题,可应用于交通流预测<sup>[6,7]</sup>. SVR 模型的参数选择是预测性能好坏的关键因素,很多学者都认识到这个问题,并对此展开了深入的研究,但至今没有形成有效通用的理论和方法. SVR 模型主要有以下参数:不敏感损失系数、惩罚系数、核函数及其他参数,一些学者已提出了许多方法对其进行了相关研究<sup>[8~11]</sup>,但这些方法的缺点是计算量大,计算时间长,无法满足交通流预测的实时性要求.

本文基于 SVR 预测模型,分析、讨论简单而实际的直接从训练集中选取 SVR 参数的方法;根据交通网络特性建立路网实时交通流预测模型;给出一个贪婪负载均衡算法(G-LB);使用大连 SCOOT 系统的实时交通流数据在联想深腾 1800 集群上进行了 500、600 和 2 000 条路段的交通流并行预测实验.

# 1 支持向量机预测模型

## 1.1 $\epsilon$ -SVR 模型

SVR 方法主要基于如下思想:首先选择一非线性映射函数  $\Phi(x)$  把  $n$  维样本向量  $x \in \mathcal{X} = \mathbf{R}^n$  从输入空间中映射到高维特征空间,利用最大间隔法在此高维特征空间构造线性决策函数

$$f(x) = w \cdot \Phi(x) + b \quad (1)$$

已知训练集  $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\} \in \mathcal{X} \times Y$ , 其中  $x_i \in \mathcal{X} = \mathbf{R}^n, y_i \in \mathbf{R}, i = 1, 2, \dots, l$ . 利用 SVR 方法可以得到一个回归函数式(1), 其中  $w \in \mathbf{R}^n, b \in \mathbf{R}$ . 运用 SVR 方法的目的是求回归函数  $f(x)$ , 使得

$$R_{\text{reg}}(f) = C \sum_{i=1}^l \Gamma(f(x_i) - y_i) + \frac{1}{2} \|w\|^2 \quad (2)$$

最小. 这里,  $\Gamma(\cdot)$  是损失函数<sup>[4]</sup>,  $C$  是一个惩罚常量,

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \cdot \Phi(x_i) \quad (3)$$

把式(3)代入式(1), 得到  $f(x)$  的等价形式

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) (\Phi(x_i) \cdot \Phi(x)) + b = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (4)$$

式中用核函数  $K(x_i, x)$  取代点积  $\Phi(x_i) \cdot \Phi(x)$ .

核函数<sup>[4]</sup>可以将高维特征空间的内积运算转化为输入空间核函数的“维数灾难”等问题,从而为在高维特征空间解决复杂的分类和回归问题奠定理论基础.  $\epsilon$ -不敏感损失函数是最常用的损失函数<sup>[4]</sup>, 具体形式如下:

$$\Gamma(f(x) - y) = \begin{cases} |f(x) - y|; & |f(x) - y| \geq \epsilon \\ 0; & \text{其他} \end{cases} \quad (5)$$

通过求解上面的二次规划问题, 可得

$$\min_{\alpha^* \in \mathbf{R}^{2l}} \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) K(x_i, x_j) + \epsilon \sum_{i=1}^l (\alpha_i^* + \alpha_i) - \sum_{j=1}^l y_j (\alpha_j^* - \alpha_j) \quad (6)$$

$$\text{s. t.} \quad \sum_{i=1}^l (\alpha_i^* - \alpha_i) = 0; 0 \leq \alpha_i, \alpha_i^* \leq C, \\ i = 1, 2, \dots, l$$

利用序列最小最优化(sequential minimal

optimization, SMO) 算法<sup>[12]</sup> 求解式(6), 得到  $\alpha_i$  和  $\alpha_i^*$ . 其中只有  $\alpha_i$  和  $\alpha_i^*$  的非零值对应的训练数据称为支持向量. 式(2)中的常量  $C$  是惩罚因子, 主要是对误差的惩罚.  $C$  越大, 允许出现的误差将越小, 其泛化能力就越差. 如果  $C$  取无穷大, SVR 将不允许出现任何误差, 从而会导致模型复杂化. 相反,  $C$  的值越小, 允许的误差就越大, 泛化能力将越强.

把  $\alpha_i$  和  $\alpha_i^*$  的值代入式(3)可求出  $w$ , 下面只要求出  $b$  就可得到预测函数  $f(x)$ . 根据 KKT 条件<sup>[4]</sup>, 可得

$$\begin{aligned} \alpha_i (\epsilon + \zeta_i - y_i + w \cdot x_i + b) &= 0 \\ \alpha_i^* (\epsilon + \zeta_i^* - y_i + w \cdot x_i + b) &= 0 \\ (C - \alpha_i) \zeta_i &= 0 \\ (C - \alpha_i^*) \zeta_i^* &= 0 \end{aligned} \quad (7)$$

其中  $\zeta_i$  和  $\zeta_i^*$  是松弛变量. 如果  $\alpha_i, \alpha_i^* = 0$ , 可得  $\zeta_i, \zeta_i^* = 0$ . 对于其他的  $\alpha_i$  和  $\alpha_i^*$ , 即  $\alpha_i, \alpha_i^* \in (0, C)$ , 可得

$$\begin{aligned} b &= y_i - w \cdot x_i - \epsilon; & \alpha_i \in (0, C) \\ b &= y_i - w \cdot x_i + \epsilon; & \alpha_i^* \in (0, C) \end{aligned} \quad (8)$$

从上面的分析可知, 利用 SVR 方法来解决回归问题, 只要知道具体的核函数、惩罚参数  $C$  和  $\epsilon$  的值即可. Cherkassky 等提出了直接从训练集中选取参数  $C$  和  $\epsilon$  的方法<sup>[13]</sup>.

## 1.2 参数 $C$ 的选择

假设参数  $\epsilon$  是已知的, 不失一般性, 并假设 SVM 核函数在输入域中是有界的, 对于核函数 RBF, 满足<sup>[13]</sup>

$$K(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / 2\sigma^2) \quad (9)$$

在这些假设条件下, 能够将  $C$  值关联到训练集响应值的范围内. 在前面的分析中, 注意到参数  $C$  的取值范围定义为  $0 \leq \alpha_i, \alpha_i^* \leq C$ , 因此, 要选择一个好的  $C$  值, 其值应等于训练集输出(响应)值的范围, 然而这样的选择对异常值是非常敏感的, 为此, Cherkassky 等<sup>[13]</sup> 提出了下面的选择方法:

$$C = \max\{|\bar{y} + 3\sigma_y|, |\bar{y} - 3\sigma_y|\} \quad (10)$$

其中  $\bar{y}$  是训练集的  $y$  值均值,  $\sigma_y$  是训练集的  $y$  值标准差, 可以直接从训练集中求出  $\bar{y}$  和  $\sigma_y$  的值, 从而求得  $C$  值.

## 1.3 参数 $\epsilon$ 的选择

Cherkassky 等<sup>[14]</sup> 已阐明参数  $\epsilon$  与输入噪声水平  $\sigma$  成比例, 即  $\epsilon \propto \sigma$ . 这里假定  $\sigma$  是已知的, 或

者可从训练集中求出。然而，参数  $\epsilon$  的选择也依赖于训练样本的数量，Cherkassky 等<sup>[13]</sup> 更进一步地给出了  $\epsilon$  与  $\sigma$  的关系式：

$$\epsilon \propto \sigma / \sqrt{n} \tag{11}$$

当样本数量不大时，式(11)效果较好；当  $n$  较大时，从式(11)得到的  $\epsilon$  值将非常小，几乎为 0。因此，Cherkassky 等<sup>[13]</sup> 提出了一个如式(12)所示的经验依赖关系式：

$$\epsilon \propto \tau \sqrt{(\ln n)/n} \tag{12}$$

$\tau$  为常数因子。基于经验调整，Cherkassky 等<sup>[13]</sup> 发现当式(12)中的  $\tau = 3$  时，能够为各种训练集规模、噪声水平和 SVM 回归目标函数提供好的性能。 $\sigma$  和  $n$  可直接从训练集中求得，从而求得

$$\epsilon = 3\sigma \sqrt{(\ln n)/n} \tag{13}$$

## 2 路网交通流预测模型

根据交通流特性，设计了大规模网络交通流预测模型，可分为 3 个模块，分别是数据处理模块、训练模块和预测模块。

### 2.1 数据处理模块

如图 1 所示，它包括 4 个部分。

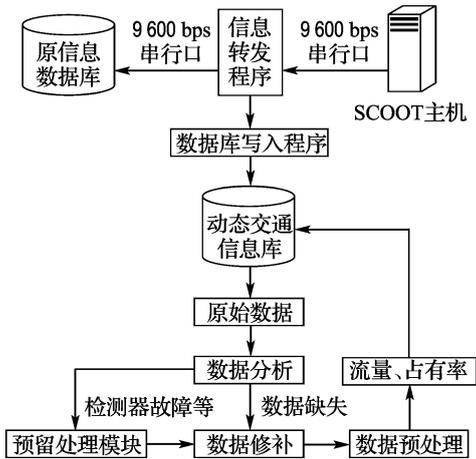


图 1 数据处理模块

Fig. 1 Data processing module

(1)对 SCOOT 系统采集的大规模实时数据进行信息中继和采集。交警支队原有的信息数据库通过 9 600 bps 的串行线从 SCOOT 系统的 VAX 主机获取实时交通信息。收到的信息分成两路：一路数据原封不动，发向原有的信息数据库，另一路数据存入用于实时处理的动态信息数据库。

(2)对实时采集到的原始数据进行存储。本文利用 Oracle 10g 数据库存储采集的实时数据。

(3)对原始数据进行分析。在原始数据采集过程中，由于检测器的故障、维护和损坏导致传输过程中的数据丢失，以及数据接收端的错误等原因，需要对数据进行修补。数据分析处理的方法将是下一步重点研究的课题之一。

(4)对数据进行预处理。针对原始数据的问题，采取相应的措施予以解决，使其尽可能保持与真实的交通流相似。本文的预处理方法主要有缺失值修补、数据修正等手段。

### 2.2 训练模块

建立路网实时交通流预测模型，为实时交通流预测提供最优的预测模型。训练模块如图 2 所示，它包括两个部分。

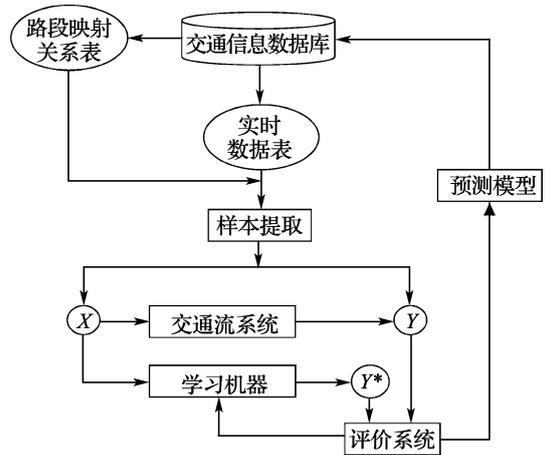


图 2 训练模块

Fig. 2 Training module

#### (1)样本提取

大规模路网的路段上交通流量与本路段前几个时段的交通流量有着必然的联系，同时本路段与其上下游路段之间也存在着联系。提取样本的方法有两种：第一种方法简单，容易实现，缺点是没有考虑路段上下游的相关关系；第二种方法充分考虑了相关路段及其对应时段的关系，但是其实现和分析比较复杂。可以根据实际的交通状况和预测的性能要求选取其中方法之一进行样本的选取。

#### (2)模型训练

目前交通流预测方法很多，但是任何单一的方法仅仅对某一交通特性或者对某些路段时段预测较好。因此，本文在建立模型时，考虑综合模型，

即在本文的训练模型中,学习机器是个综合的学习模型.在图2中,评价系统的主要任务是根据神经网络、模糊控制、遗传算法、自适应控制及自组织控制等技术的特点,融合各种交通流预测模型,研发相应的模型算法.同时,根据在线分析技术,对交通流的影响因素进行动态辨识,并对短时交通流预测模型进行校正,最终得到某一路段某个时段的最优交通流训练模型.本文不考虑使用综合模型作为学习机器方法,主要利用SVR方法进行交通流预测.图3给出了利用SVR进行交通流训练的流程.

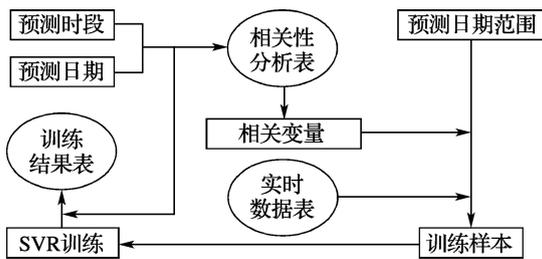


图3 SVR训练流程图

Fig. 3 SVR training flow chart

### 2.3 预测模块

利用交通流训练模型得到的预测模型对路网的每个路段进行实时预测,包括两部分:实时采集每个路段的数据;利用相应的预测模型(如图4所示)进行实时交通流的预测.

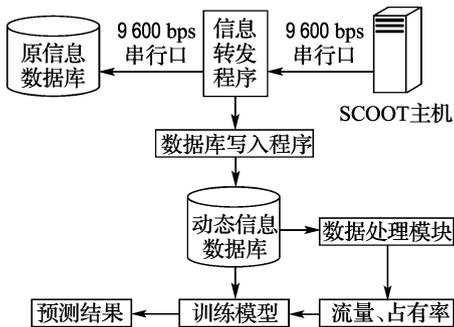


图4 预测模块

Fig. 4 Forecasting module

## 3 并行计算

如果同时训练和预测2 000条路段,若忽略计算节点间的通信时间等开销,串行预测时间将是并行预测时间的近2 000倍,不仅耗费大量的

时间,而且资源浪费严重,无法满足实时性要求.因此,对大规模路网进行并行计算将大大提高预测的实时性.每个路段在预测时可以被看成是独立的计算单元,并可忽略由于并行计算带来的额外通信时间开销.

为了提高计算速度和计算规模,可以采用并行计算方式.传统的并行方式通常只是简单地将计算任务平均分配给各个处理器,并且默认假设参与计算的各个处理器是同构的、非多用户使用的.由于具有较高的性能价格比,通常通过集群系统来获得并行计算性能.然而,集群系统中各个处理器通常是以不同的速度、负载特征和利用率运行的,并且在多用户集群系统中的其他进程竞争使用共享计算资源将导致负载的动态变化.因此,将计算任务平均地分配给各个处理器不能保证得到理想解<sup>[15]</sup>,尤其是当可用计算资源变化较大时简单地将任务平均分配给各个处理器进行计算将会导致较低的综合计算效率.

考虑一个具有 $P$ 个处理器的集群系统,设 $t_i$ 表示第 $i$ 个处理器完成所分配任务需要的计算时间, $t_{\min} = \min\{t_i\}$ , $t_{\max} = \max\{t_i\}$ , $1 \leq i \leq P$ .对于同构和专用的集群系统,若将一个问题平均划分为 $N$ 个子任务(其中 $N \gg P$ ),并将这 $N$ 个子任务简单地平均分配给各个处理器,则 $t_{\min} = t_{\max} = t_i = t_0$ .其中 $t_0$ 为一个固定常数.对于异构或非专用的共享式集群系统,通常情况下有 $t_i \neq t_j$ , $1 \leq j \leq P$ .不失一般性,可设 $t_i = t_{\max} > t_j = t_{\min}$ .即对于处理器 $i$ 和处理器 $j$ ,通过简单地平均分配任务操作之后,其计算任务量相等,但由于可用计算资源较少,致使处理器 $i$ 的计算时间 $t_i$ 大于 $t_j$ .为了提高计算速度,需要将处理器 $i$ 上的部分任务动态均衡到处理器 $j$ 上.本文给出一个贪婪思想的负载均衡算法来实现这个动态的均衡分配过程,简称G-LB.

本文给出的G-LB算法的基本思想就是通过将总的计算任务量划分为 $N$ 个子任务, $N \gg P$ ,然后将这 $N$ 部分的任务分配给各处理器.在任务动态重分配过程中,在考虑如何将计算任务分配到处理器上时,首先考虑将负载最重的处理器上的一部分任务分配给负载最轻或可用计算资源最多的处理器.G-LB算法的复杂度为 $O(N \log N)$ .

### 算法1 G-LB Algorithm

```

begin
Data:  $V_i$ ; //任务集合
 $V_p$ ; //处理器集合
 $G_p$ ; //处理器背景负载
Result:  $P: V_i \rightarrow V_p$  //任务映射
Tasks  $\leftarrow$  NumTask;
TaskHeap taskHeap(Tasks + 1); //构建任务堆
MinHeap cpuHeap(P); //构建最小堆
//处理器的初始负载初始化为背景负载
 $G_p \rightarrow$  cpuHeap;
for  $i \leftarrow 1$  to Tasks do
 $t \leftarrow$  taskHeap.deleteMax(); //获得最重任务
taskDonor  $\leftarrow$  cpuHeap.deleteMin(); //最闲
处理器
 $t \rightarrow$  taskDonor; //分配任务给处理器
taskDonor.load += t;
cpuHeap.Heapify(); //堆调整
end for
end

```

## 4 实验

本实验在大连理工大学的联想深腾 1800 集群上进行,该集群具有 63 个计算节点,一个管理节点,每节点具有 2 个 CPU,每个 CPU 配置为 Intel Xeon 2.8 GHz 1 MB L2 Cache,每节点内存大小为 4 GB,节点间通过 Myrinet 网络连接。

### 4.1 GNN 与 SVR 方法的预测精度比较

根据交通流量时间序列的变化规律,路段上的交通流量与前几个时段的流量有着一定的联系,这样就可以利用路段前几个时段的交通流量数据去预测未来时段的交通流量。设  $v_i(t)$  为路段  $i$  上  $t$  时刻的交通流量, $v_i(t-1)$  为路段  $i$  上  $t-1$  时刻的交通流量。在实验中,采用当前时段和前  $n$  个时段的交通流量作为样本的输出和输入,对未来时段的交通流量进行预测<sup>[7]</sup>。

由于晚上 10 点到凌晨 6 点的交通流量较少,发生拥塞的可能性很小,预测时段为早上 6 点到晚上 10 点。利用大连市 SCOOT 系统采集的实时数据进行交通流预测,对 2007-01-16~2007-01-21 的大连市鞍山路和联合路的交叉口的 N14111F 检测器采集的实时数据进行交通流预测分析。数据经处理后,按 5 min 为一个时段统计流量,对流量数据进行异常值修正和噪声处理后,得到可用的流量数据作为样本,共有 795 组数据。

为了能够清楚地分析 SVR 方法与 GNN 方法预测结果的性能,引入以下 3 个评价指标:

(1) 平均相对误差

$$RME = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - Y_i^*}{Y_i} \right|$$

(2) 均方根误差

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left( \frac{Y_i - Y_i^*}{Y_i} \right)^2}$$

(3) 最大相对误差

$$MAXRER = \max \left\{ \left| \frac{Y_i - Y_i^*}{Y_i} \right| \right\}$$

其中  $Y_i$  代表实际值, $Y_i^*$  表示预测值。

对训练样本进行归一化处理,先采取 GNN 法进行预测。它由 3 层神经元组成,其中输入层由 6 个神经元组成,隐含层由 6 个神经元组成,输出层由 1 个神经元组成,而且隐含层和输出层由智能神经元组成,智能神经元的激活函数采用带参数的 Sigmoid 函数,输入经线性函数扩展,采用的收敛条件是均方误差大于  $10^{-6}$ 。预测结果见表 1 和图 5。

对于参数选择的 SVR 方法,利用本文直接从训练集中选取参数的方法(式(10)、(13)),根据交通流实时数据的特点,取噪声为 1。预测 2007-01-19 的流量信息时,取  $C = 11.586586$ 、 $\epsilon = 0.3022379$  和 RBF 核函数。预测 2007-01-21 的流量信息时,取  $C = 11.586586$ 、 $\epsilon = 0.3022379$  和 RBF 核函数。预测的结果见表 1 和图 6。

表 1 GNN 和 SVR 方法的性能比较

Tab. 1 Performance comparison for GNN and SVR methods

方法	日期	RME/%	RMSE/%	MAXRER/%	预测时间/s	泛化性能	收敛性
GNN	2007-01-19	7.57	10.51	39.91	72.04	一般	局部
GNN	2007-01-21	7.90	14.01	89.30	72.53	一般	局部
SVR	2007-01-19	5.36	7.83	40.49	5.09	强	全局
SVR	2007-01-21	5.00	6.87	27.49	5.06	强	全局

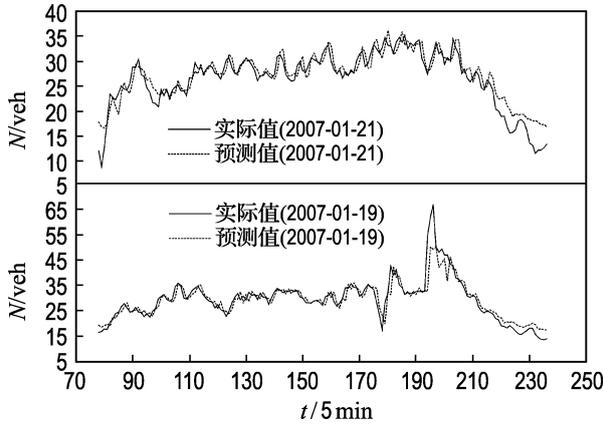


图 5 基于 GNN 方法的交通流预测结果

Fig. 5 Traffic flow forecasting results based on GNN method

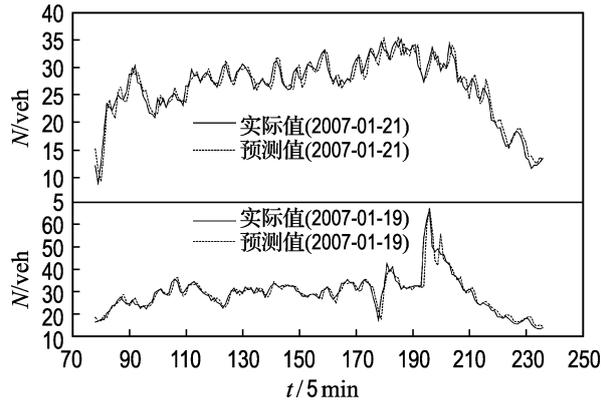


图 6 基于 SVR 方法的交通流预测结果

Fig. 6 Traffic flow forecasting results based on SVR method

### 4.2 大规模路网多路段并行计算时间的比较

为了比较 GLB-SVR、P-SVR(SVR 的并行化版本,未使用负载均衡策略)和 P-GNN 三种并行算法的性能,使用这 3 种算法分别对 500、600 和 2 000 条路段的交通流进行预测,比较其运行时间,研究它们的并行计算性能。其中,每条路段在预测时可被看做是独立的计算单元,每条路段的交通流预测方法同上节所述。对于每一种预测算法,在对多路段交通流进行并行预测的过程中,其中每一条路段的预测精度和单路段串行预测方法的精度相同,并行算法不改变串行预测的精度。3 种并行算法预测 500、600 和 2 000 条路段交通流的运行时间比较结果如图 7 和 8 所示( $n$  代表处理器个数)。

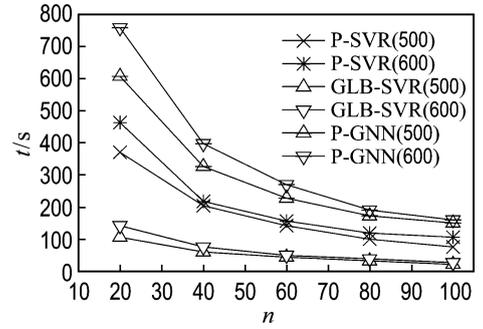


图 7 500 和 600 条路段的并行预测结果

Fig. 7 The computing results for 500 and 600 road links

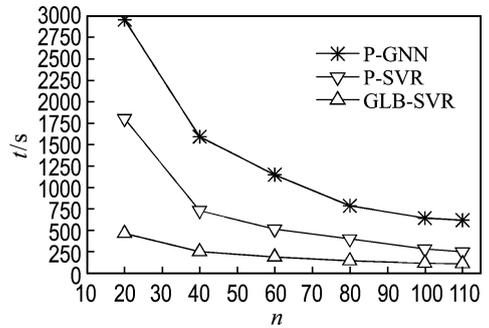


图 8 2 000 条路段的并行预测结果

Fig. 8 The computing results for 2 000 road links

## 5 结 语

实验结果表明,和 GNN 预测方法相比,SVR 预测精度与实时性更高,并且并行化的 SVR 方法结合 G-LB 算法的 GLB-SVR 预测方法可进一步提高预测的实时性,可满足大规模交通网络实时交通流预测的精度和实时性要求。

## 参考文献:

[1] YUN S Y, NAMKOONG S. A performance evaluation of neural network models in traffic volume forecasting [J]. **Mathematical and Computer Modeling**, 1998, **27**(6):293-310

[2] HU R M, XU Z Q, YAO T R, *et al.* Generalized information storing principle and higher-order generalized neural network [J]. **Acta Elemonica Sinica**, 1996, **24**(7):59-65

[3] TAN G Z, YUAN W J, DING H. Traffic flow prediction based on generalized neural network [C] // **Proceedings of the 7th IEEE ITS**. Washington: IEEE CS Press, 2004:406-409

[4] 邓乃扬,田英杰. 数据挖掘中的新方法——支持向量

- 机[M]. 北京:科学出版社, 2004
- [5] REN J T, OU X L, ZHANG Y, *et al.* Research on network level traffic pattern recognition [C] // **Proceedings of the 5th IEEE ITS**. Washington: IEEE CS Press, 2004:500-504
- [6] WU C H, WEI C C, CHANG M. Travel time prediction with support vector regression [J]. **IEEE Transaction on Intelligent Transportation Systems**, 2004, **5**(12):276-281
- [7] 杨兆生, 王媛, 管青. 基于支持向量机方法的短时交通流量预测方法[J]. 吉林大学学报(工学版), 2006, **36**(6):881-884
- [8] XANG X, QIN C H, GUI W H. Parameter selection of support vector regression based on hybrid optimization algorithm and its application [J]. **Journal of Control Theory and Application**, 2005, **3**(4):372-376
- [9] FRIEDRICH S F, IGEL C. Evolutionary tuning of multiple SVM parameters [J]. **Neural Computing**, 2005, **64**(1):107-117
- [10] CHAPPELLE O, VAPNIK V, BOUSQUET O, *et al.* Choosing multiple parameters for support vector machines [J]. **Machine Learning**, 2002, **46**(1):131-159
- [11] CHANG M W, LIN C H. Leave-one-out bounds for support vector regression model selection [J]. **Neural Computation**, 2005, **17**(5):1188-1222
- [12] PLATT J C. Fast training of support vector machines using sequential minimal optimization [C] // **Advances in Kernel Method-Support Vector Learning**. Cambridge:MIT Press, 1999:185-208
- [13] CHERKASSKY V, MA Y Q. Practical selection of SVM regression parameters and noise estimation for SVM regression [J]. **Neural Networks**, 2004, **17**(1):113-126
- [14] CHERKASSKY V, MULIER F. **Learning from Data: Concepts, Theory, and Methods** [M]. New York:Wiley, 2007
- [15] HUANG J, LEE S Y. A heterogeneity-aware approach to load balancing of computational tasks: a theoretical and simulation study [J]. **Cluster Computing**, 2008, **11**(2):133-149

## A parallel SVR approach to real-time traffic flow forecasting

YANG Ji-xiang\*, TAN Guo-zhen, WANG Fan, TIAN Zhu, PAN Dong

(School of Computer Science and Technology, Dalian University of Technology, Dalian 116024, China)

**Abstract:** Accurate and real-time traffic flow forecasting is a key problem to the application development of intelligent transportation systems (ITS). Comparing with generalized neural network (GNN) method, the theoretical advantage of applying support vector regression (SVR) method to traffic flow forecasting highly depends on good parameter selection. Simple yet practical approach to SVR parameters setting directly from the training set is analyzed and discussed, and a traffic flow SVR forecasting model for large-scale road network and a greedy load balancing (G-LB) algorithm in cluster environment are proposed. Experimental results demonstrate that it can better satisfy real-time and accurate demands of traffic flow forecasting using parallel SVR approach based on G-LB (GLB-SVR) algorithm than using parallel GNN (P-GNN) method.

**Key words:** parallel computing; load balancing; traffic flow forecasting; support vector regression (SVR); generalized neural network