

基于改进 ACGAN 算法的车道排队车辆估计及其分类^①

郭海锋^{②*} 杨宪赞^{*} 金峻臣^{**}

(^{*}浙江工业大学信息工程学院 杭州 310023)

(^{**}银江股份智慧交通研究院 杭州 310030)

摘要 针对传统模型驱动的排队车辆研究中构建概率分布困难、建模繁琐等问题,结合双向长短时记忆(Bi-LSTM)网络和辅助分类器生成对抗网络(ACGAN)的特点,提出一种数据驱动的车道级排队车辆估计算法。该算法无需对交叉口空间关系建模,其生成器采用 Bi-LSTM 结构,以速度序列为输入,根据速度与排队车辆的时间相关性,生成最小、最大排队车辆。判别器来自 ACGAN,在区分真假样本的同时实现排队车辆到拥堵等级标签的分类。同时,为避免网络训练不稳定、梯度消失的问题,舍弃原 ACGAN 的真假二分类任务,引入 Wasserstein 散度来衡量真实序列与生成序列的分布距离,并对相应的目标函数进行优化。结果表明,与其他算法相比,该算法在分类准确率方面提高了 3.96% ~ 9.62%,同时总体估计误差最小,验证了利用速度估计车道排队车辆的可行性。

关键词 辅助分类器生成对抗网络(ACGAN); 双向长短时记忆(Bi-LSTM); Wasserstein 散度; 车道级排队车辆估计; 分类

0 引言

在交通需求日益增长的情况下,及时准确地获取当前或未来时刻的交通状态,对交通治理和管控具有重要意义。在已有研究中,通常用车流密度的高低^[1]、延误时间的长短^[2]、行车速度的快慢^[3]、交通流量的大小^[4]等来表征交通状态。相比于这些宏观的交通流指标,交叉口排队车辆数可更直观地表征交通状态,尤其是车道级的排队车辆数具有更微观、更细致的表征能力,可直接用于交通控制及交通态势分析。

传统的排队车辆研究大都采用模型驱动的方法,如二流理论^[5]、排队理论^[6]、集散波理论^[7]等。随着估计算法与检测技术的发展,一些学者开始寻求其他方法和途径对排队车辆进行研究。文献[8]根据各流向的时空相关性,利用神经网络和最大期

望算法对排队车辆进行估计,但所用的检测器数据易缺失。文献[9]通过分析视频图像像素距离到物理距离的转换关系对车辆排队长度进行检测,但实际中许多交叉口视频监控的安装位置和角度并不理想。文献[10]根据时间占有率和空间占有率的关系,利用指数平滑递推算法对路段车辆数进行估计,但前提是检测器要位于路段中间位置。文献[11]利用浮动车数据建立基于队尾浮动车位置的排队长度估计模型,但方法过于繁琐且计算复杂。

由于交通环境的复杂性和多变性,现实中无法明确交通数据的时空关系和真实概率分布,这使得以模型驱动的排队车辆估计方法难以建立理想状态下的物理模型。并且由于检测器易损坏、覆盖率低等原因造成的数据缺失问题也使得这类研究方法应用困难。

生成对抗网络(generative adversarial networks,

^① 浙江省自然科学基金(LY20E080023)和浙江省教育科学规划(2016SCG241)资助项目。

^② 男,1977 年生,博士,副教授;研究方向:智能交通系统,车联网;联系人,E-mail: guohf@zjut.edu.cn
(收稿日期:2019-11-02)

GAN)作为一种新兴的生成式模型,无需构建复杂概率分布,可直接对样本进行采样和推断,避免了马尔可夫链的学习机制,即使在概率密度不可计算的情况下,仍可根据真实数据的潜在分布直接生成同分布的样本,大大降低了计算成本。

目前,GAN 已在图像视觉、时间序列处理^[12,13]中取得成功应用。基于此,一些学者将其应用于交通数据修复^[14]、交通数据增强^[15]、交通空间建模^[16]及平行交通系统^[17]中,但其或只是作为辅助手段,没有真正用于交通状态的估计与预测,或没有从微观层面给出具体的分析细节。

本文从微观的车道级交通状态角度出发,考虑现实中获取数据的成本及方法的普适性,采用速度数据,根据速度变化序列与排队车辆的对应关系,借助双向长短时记忆(bi-directional long short-term memory,Bi-LSTM)网络处理时间序列的能力和辅助分类器生成对抗网络(auxiliary classifier generative adversarial network,ACGAN)^[18]数据生成与分类的能力,实现从速度到车道排队车辆数的估计与分类。最后通过仿真实验与其他算法进行对比,验证了本文算法的性能和优势。

1 问题描述

图 1 是杭州市一典型的十字交叉口,其中 1~17 为各车道检测器编号,也可代表车道编号。在估

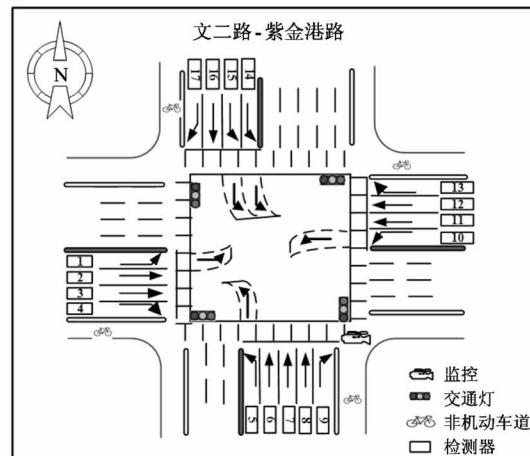


图 1 城市单交叉口路网

计时,首先对每个方向进行功能车道划分,不考虑不受相位控制的右转车道,该交叉口有 8 个功能车道,然后以所有功能车道的特征数据为条件输入,同时估计所有功能车道的排队车辆数,即以整个交叉口为估计对象。

为获得车流集结和消散情况,对信号周期内的最小、最大排队车辆数进行估计。绿灯结束时刻排队车辆数最小,红灯结束时刻排队车辆数最大。本文将影响排队车辆数的几个指标,如信号周期时长、绿灯时长、绿灯运行时刻、红灯时长、红灯运行时刻、车道平均速度作为多重输入指标,以提高估计精度。在每个信号周期,对每个功能车道分别取红灯和绿灯结束时刻往前 T 个时间步长(s)的对应指标,如图 2 所示。

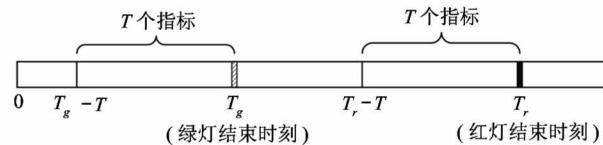


图 2 红绿灯期间的多时刻指标

设第 t 个步长时所有功能车道的多重指标矩阵为 $\mathbf{I}_t = [\mathbf{Y}_1^t, \mathbf{Y}_2^t, \dots, \mathbf{Y}_n^t]$, 其中 n 为功能车道数, \mathbf{Y}_n^t 为第 t 个步长时第 n 个车道的特征矩阵, 表示如下:

$$\mathbf{Y}_n^{(t)} = [p_n^{(t)}, d_{n,g}^{(t)}, d_{n,r}^{(t)}, m_{n,g}^{(t)}, m_{n,r}^{(t)}, v_{n,g}^{(t)}, v_{n,r}^{(t)}] \quad (1)$$

式中, $p_n^{(t)}$ 、 $d_{n,g}^{(t)}$ 、 $d_{n,r}^{(t)}$ 、 $m_{n,g}^{(t)}$ 、 $m_{n,r}^{(t)}$ 、 $v_{n,g}^{(t)}$ 、 $v_{n,r}^{(t)}$ 分别为第 t 个步长时第 n 个车道的信号周期时长、绿灯时长、红灯时长、绿灯运行时刻、红灯运行时刻、绿灯运行时刻平均车速、红灯运行时刻平均车速。

则构建的输入矩阵表示如下:

$$\mathbf{I} = [\mathbf{I}_1, \mathbf{I}_2, \dots, \mathbf{I}_t] \quad (2)$$

输入矩阵的维数为 $t \times (n \times 7)$, 对应的输出为 $t+1$ 时刻所有功能车道的最小、最大排队车辆数矩阵 \mathbf{Q}'_{t+1} , 其维数为 $n \times 2$, 表示如下:

$$\mathbf{Q}'_{t+1} = [\mathbf{q}_1^{(t+1)}, \mathbf{q}_2^{(t+1)}, \dots, \mathbf{q}_n^{(t+1)}] \quad (3)$$

式中, $\mathbf{q}_n^{(t+1)}$ 为 $t+1$ 时刻第 n 个车道的排队车辆矩阵, 包括最小排队车辆数 $q_{n,\min}^{(t+1)}$ 和最大排队车辆数 $q_{n,\max}^{(t+1)}$ 。

本文将预先根据拥堵等级对最小、最大排队车

辆数进行类别划分,所以在估计排队车辆数的同时,会加一个分类任务,分类结果是红绿灯结束时刻的拥堵情况类别,这样结合排队车辆数和类别标签更能充分地表征车道拥堵情况。速度到排队车辆,再到标签的对应关系为 $I \rightarrow Q'_{t+1} \rightarrow C_{t+1}$, C_{t+1} 表示如下:

$$C_{t+1} = [c_1^{(t+1)}, c_2^{(t+1)}, \dots, c_n^{(t+1)}] \quad (4)$$

式中, $c_n^{(t+1)}$ 为 $t+1$ 时刻第 n 个车道的排队车辆标签矩阵,包括最小排队标签 $c_{n,\min}^{(t+1)}$ 和最大排队标签 $c_{n,\max}^{(t+1)}$, 即每个功能车道的多重指标序列都有对应的 2 个标签。

2 ACGAN 算法

GAN 由 Goodfellow 等人^[19] 提出,模型框架包括 2 个相互对抗的多层感知机,即生成器(G)和判别器(D)。G 接收噪声 z 并尽可能学习真实数据 X_{real} 的分布,D 的目的是将生成数据 X_{fake} 与真实数据区分开来,为了在博弈中胜出,2 个网络不断进行优化,最终实现一个纳什均衡。

针对 GAN 学习模式过于自由导致训练过程不可控的问题,条件生成对抗网络^[20] (conditional generative adversarial network, CGAN) 在生成器和判别器中加入标签信息,将无监督的 GAN 模型变为有监督模型。ACGAN^[18] 在 CGAN 的基础上作了进一步改进,它只有生成器接收标签信息,判别器除了判别样本真假外,还增加了一个辅助分类器(C)用来输出样本标签的后验概率估计,其结构如图 3 所示。

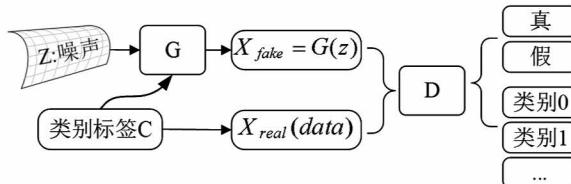


图 3 ACGAN 网络结构

判别器的一个输出通过 Sigmoid 激活函数将数据映射到 0、1 之间,用于真假判断;另一个输出通过 Softmax 多分类器得到类别后验概率,用于分类预测。故目标函数包括真假数据对数似然损失 L_s 和

预测类别的对数似然损失 L_c 2 部分,分别表示如下:

$$\begin{aligned} L_s &= E[\log P(S = real | X_{real})] \\ &\quad + E[\log P(S = fake | X_{fake})] \end{aligned} \quad (5)$$

$$\begin{aligned} L_c &= E[\log P(C = c | X_{real})] \\ &\quad + E[\log P(C = c | X_{fake})] \end{aligned} \quad (6)$$

在训练过程中,判别器的目标是最大化 $L_s + L_c$,生成器的目标是最大化 $L_c - L_s$ 。

3 改进的 ACGAN 算法

本文中,要将训练好的判别器提取出来用于分类,所以在训练时,判别器的输入中应避免出现标签数据,ACGAN 正符合本文思路。在此基础上,利用循环神经网络(recurrent neural network, RNN) 中 Bi-LSTM 的特点,构建其与 ACGAN 结合的结构 RACGAN-JS(目标函数基于 JS 散度),进一步引入 Wasserstein 散度代替 JS 散度来衡量生成序列与真实序列的距离,并对目标函数进行优化,提出改进算法 WRACGAN-div。

3.1 模型结构

原始的 ACGAN 网络并不适用于时间序列数据,Bi-LSTM 在处理时序数据上具有优异的性能,它赋予网络一种“记忆”功能,可根据历史的前后顺序信息捕获数据随时间发展的趋势。借此优点,将 Bi-LSTM 作为 ACGAN 网络的生成器,其模型结构如图 4 所示。

图 4 中,本文用构建的多重输入指标代替原始 ACGAN 的随机噪声和标签作为生成器的条件输入,来指导排队车辆数的生成。Bi-LSTM 接收多重指标 $I = [I_1, I_2, \dots, I_t]$,在每一个时刻,根据当前输入 I_t 和上一个时刻的隐藏状态,正向计算得到前向层隐藏特征 h_t ,反向计算得到后向层隐藏特征 h'_t ,然后从 h_t, h'_t 中提取输出特征 o_t ,再经一个全连接层得到生成器的输出 $G(I)$,即 $t+1$ 时刻的排队车辆数估计值 $Q'_{t+1} \circ o_t, Q'_{t+1}$ 表示如下:

$$o_t = f(w_1 \cdot h_t + w_2 \cdot h'_t) \quad (7)$$

$$Q'_{t+1} = G(I) = \delta \times (w_3^T \cdot o_t + b_0) \quad (8)$$

式中, $f(\cdot)$ 表示 Bi-LSTM 输出, w_1, w_2 为隐藏层之

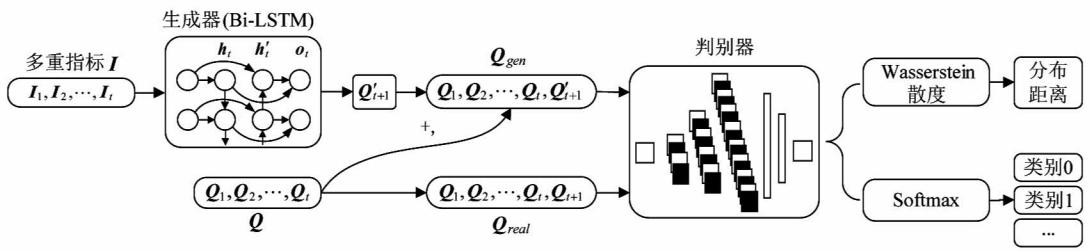


图 4 WRACGAN-div 网络结构

间的权重, w_3, b_0, δ 为全连接层的权重、偏置、激活函数, · 表示矩阵之间的点乘。

在判别前, 将 Q'_{t+1} 、真实排队车辆 Q_{t+1} 分别与前 t 个时刻的排队序列 $Q = [Q_1, Q_2, \dots, Q_t]$ 进行拼接, 得到生成样本 $Q_{gen} = [Q_1, Q_2, \dots, Q_t, Q'_{t+1}]$ 和真实样本 $Q_{real} = [Q_1, Q_2, \dots, Q_t, Q_{t+1}]$, 然后分别输入给判别器。这样做的原因是判别器为了捕获序列的相关性, 需要对整个序列分布进行判别, 若仅输入单个时刻的 Q'_{t+1} 与 Q_{t+1} , 则无法学习真实排队序列的潜在分布。

原始 ACGAN 真假判别目标函数存在的缺陷是, 当判别器最优(近似)时, 网络训练目标等价于最小化真实样本分布 S_{real} 与生成样本分布 S_{gen} 之间的 JS 散度, 若 2 个分布没有交集, 就会导致生成器梯度消失。相比 JS 散度, Wasserstein 距离在衡量分布距离上具有优越的平滑特性, 即使 2 个分布没有重叠部分, 它也可以反映二者的远近。

文献[21]以 Wasserstein 距离作为目标函数, 很好地解决了训练不稳定的问题。但 Wasserstein 距离受 Lipschitz 连续条件的限制, 即导函数不能超过某个值, 作者通过把判别器的权重裁剪到某个范围内的方法, 强制满足 Lipschitz 条件, 但该方式过于粗暴, 限制了判别器的拟合能力。Wasserstein 距离的对偶式表示如下:

$$W(S_{real}, S_{gen}) = \sup_{\|f\|_L \leq 1} E_{x \sim S_{real}}[f(x)] - E_{x \sim S_{gen}}[f(x)] \quad (9)$$

式中, $f(\cdot)$ 为连续函数, \sup 表示取上界, $\|f\|_L \leq 1$ 为 Lipschitz 条件。

文献[22]在此基础上提出了 Wasserstein 散度的概念, 既摆脱了 Lipschitz 条件的限制, 又保证了 Wasserstein 距离的优点。Wasserstein 散度表示如下:

$$\begin{aligned} W_{\gamma, \eta}(S_{real}, S_{gen}) &= \inf_{f \in \Omega} E_{x \sim S_{real}}[f(x)] - E_{\tilde{x} \sim S_{gen}}[f(\tilde{x})] \\ &\quad + \gamma \times E_{\tilde{x} \sim S_{com}}[\|\nabla f(\tilde{x})\|^{\eta}] \end{aligned} \quad (10)$$

式中, \inf 表示取下界, Ω 为一阶可微函数空间, γ, η 为可调参数, $\nabla f(\cdot)$ 为函数的梯度, S_{com} 为前 2 个分布的线性插值。

式(10)中没有 Lipschitz 条件约束, $W_{\gamma, \eta}$ 是真正意义上的散度, 前 2 项就是 Wasserstein 距离, 这意味着当对散度取下界, 并且最小化前 2 项训练生成器时, 是真正在缩小 2 个分布的距离, 且不会有梯度消失的问题, 保存了 Wasserstein 距离的优点。

以 Wasserstein 散度衡量分布距离, 属于回归任务, 故去掉原 ACGAN 真假判别中的 Sigmoid 函数。判别器采用卷积网络以提高特征提取能力和分类性能, 网络的一个全连接层输出一维标量用来计算 Wasserstein 散度, 另一个全连接层输出类别概率值用来计算多分类交叉熵。

3.2 目标函数

引入 Wasserstein 散度后, 由于生成样本 Q_{gen} 和真实样本 Q_{real} 除最后时刻的数据外, 前边所有时刻的信息都一致, 这可能会导致训练完后两者的整体 Wasserstein 距离很接近, 但最后时刻的排队车辆数差距较大。为避免这类情况, 在生成器损失中加入了 Q'_{t+1} 与 Q_{t+1} 的均方误差 G_{mse} 。根据式(10), 判别器的目标是最大化 Wasserstein 散度, 散度最后一项与生成器无关, 它的目标是最小化前 2 项的 Wasserstein 距离。则本文算法样本生成部分判别器的损失函数 D_s 、生成器的损失函数 G_s 分别表示如下:

$$\begin{aligned} D_s &= \max E_{G(\tilde{x}) \sim Q_{gen}}[D(G(\tilde{x}))] - E_{x \sim Q_{real}}[D(x)] \\ &\quad - k E_{\tilde{x} \sim Q_{com}}[\|\nabla_x D(\tilde{x})\|^p] \end{aligned} \quad (11)$$

$$G_s = G_w + G_{mse} \quad (12)$$

$$G_w = \min E_{G(\tilde{x}) \sim Q_{gen}} [D(G(\tilde{x}))] - E_{x \sim Q_{real}} [D(x)] \quad (13)$$

$$G_{mse} = \min \frac{1}{n} \sum_{i=1}^n (Q_{t+1,i} - Q'_{t+1,i})^2 \quad (14)$$

式中, G_w 为 Wasserstein 距离损失。

分类目标函数与原 ACGAN 一样,不作修改,则总的判别器损失为最大化 $D_s + L_c$,生成器损失为最小化 $G_s - L_c$ 。

4 实验过程

4.1 数据准备

为验证模型的可靠性,本文选取杭州市解放东路-富春路交叉口作为测试对象,该路口信号周期为 169 s,进口方向都为 5 车道,根据图 5(a)、图 6 和表 1,在 SUMO 仿真器中搭建仿真路网。车辆到达率设置在 0~0.5 辆/s 之间随机采样,每 25 个周期变化一次。仿真运行 3 000 个周期,运行过程如图 5(b)所示,获取每秒所有车道的平均速度和排队车辆数。

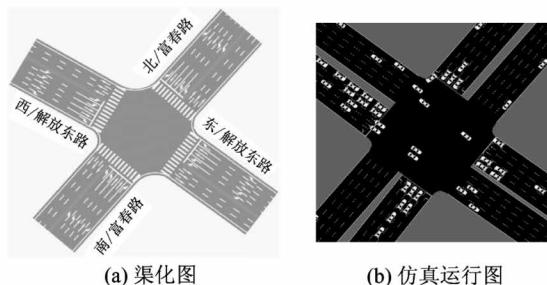


图 5 交叉路口

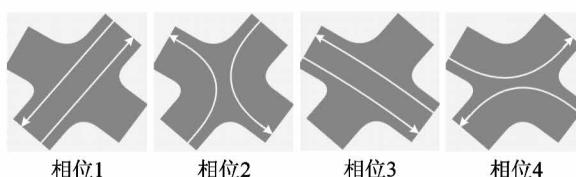


图 6 相位信息

表 1 控制方案信息

0	相位 1	相位 2	相位 3	相位 4
方向	南北直行	南北左转	东西直行	东西左转
时长(s)	46	42	42	39

不考虑不受相位控制的右转车道,根据车道功能,对各车道数据进行聚合。为加快网络的收敛速度,对每个车道所有周期的特征进行标准化处理,以消除特征数据之间的量纲影响,表示如下:

$$Y_{n,j}^{norm} = \frac{Y_{n,j} - \mu_{n,j}}{\sigma_{n,j}} \quad (15)$$

式中, $Y_{n,j}$ 为第 n 个车道的第 j 列特征矩阵, $\mu_{n,j}$ 、 $\sigma_{n,j}$ 分别为该车道第 j 列的均值和方差。

统计排队车辆的数据分布,再结合交通情况,将最小、最大排队分别分成 4 类并打上标签。表 2 内容为各类别的车辆数范围,其中 0 至 3 类分别表示畅通、缓行、拥挤、拥堵。

表 2 排队车辆数分类区间

排队(辆)	0类	1类	2类	3类
最小	0	[1,3]	[4,9]	≥ 10
最大	[0,4]	[5,10]	[11,20]	≥ 21

4.2 训练细节

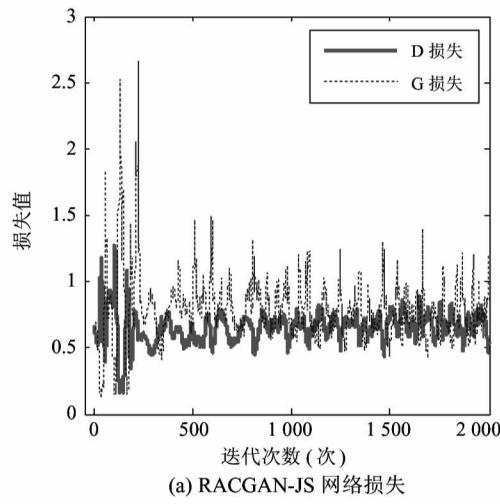
随机划分数据集,80% 为训练集,20% 为测试集,批尺寸 (batchsize) 设为 32,网络训练 2 000 次。生成器采用双层网络,隐藏层包含 128 个神经元,根据相位中最小的绿灯时长设置步长为 38 s;判别器采用 4 层卷积神经网络,每一层都使用 Leaky ReLU 激活函数,除第 1 层外,其他层设置批标准化 (batch normalization, BN),损失函数中 γ 设为 2, η 设为 6。2 个网络均采用 Adam 优化器,学习率为 0.0001。为防止训练时出现过拟合现象,为生成器和判别器设置神经元失活,失活率 Dropout 为 0.25。

4.3 实验结果与分析

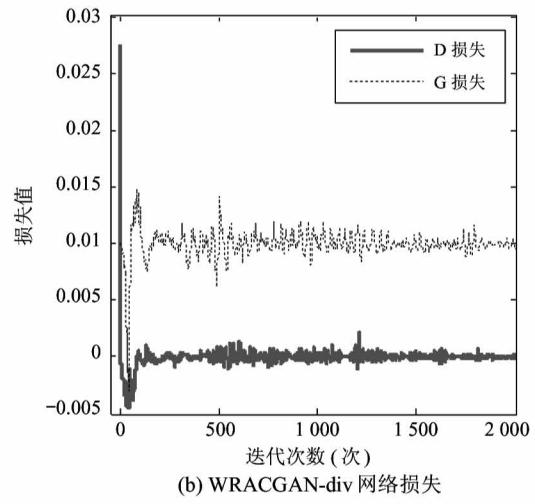
为了解网络的对抗过程,作出目标函数修改前后的网络损失变化曲线。图 7(a)为 RACGAN-JS 的网络损失变化过程,图 7(b)为本文引入 Wasserstein 散度后的网络损失变化过程。可看出,图 7(a)在训练初期出现了剧烈的震荡,尽管慢慢趋于稳定,但网络仍有较大的震荡幅度;而图 7(b)不管是在初始对抗期还是收敛期都只有小幅的波动,显示出了良好的稳定性。在收敛速度方面,图 7(a)在迭代约 500 次后趋于稳定,图 7(b)在迭代约 250 次后便快速收敛,这说明以 Wasserstein 散度为目标函数加快了网

络的收敛。另外,图 7(b)中判别器损失稳定在 0 附近,这说明生成数据与真实数据的分布距离已非常

小,判别器无法区分它们,生成器已能生成与真实排队车辆分布近似的样本。



(a) RACGAN-JS 网络损失

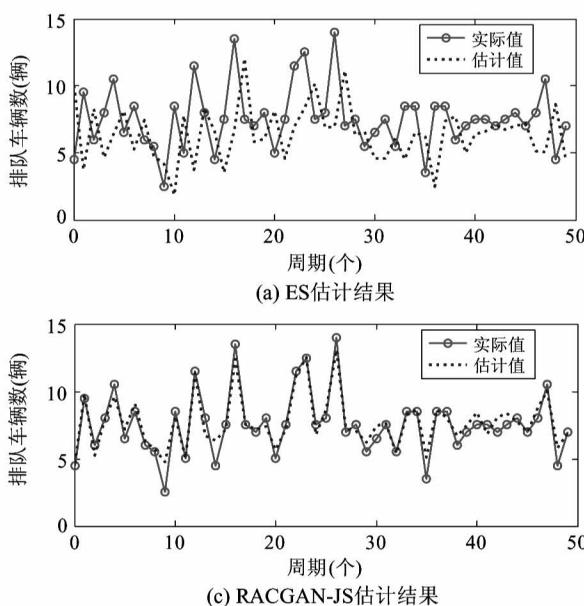


(b) WRACGAN-div 网络损失

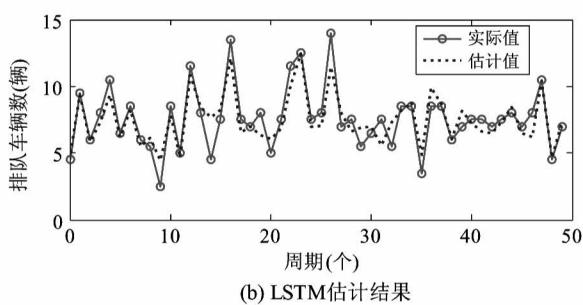
图 7 目标函数修改前后的网络损失变化曲线

训练完成后,将生成器提取出来评估其估计性能,在测试集上将其与文献[10]中模型驱动的指数平滑(exponential smoothing, ES)递推方法、LSTM 算法、RACGAN-JS 算法进行对比。图 8 为这 4 种算法对功能车道 1 的最大排队车辆估计结果,选取 50 个周期展示。可以看出,ES 方法虽然能跟踪排队车辆的变化趋势,但受递推算法的限制,其估计结果有较强的滞后性。LSTM、RACGAN-JS、WRACGAN-div 的估计滞后性都较小,并且精度均优于 ES 递推方法,

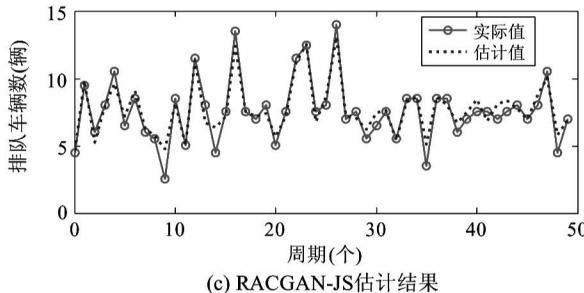
这说明与固定不变的物理模型相比,采用数据挖掘的方式能更准确、高效地跟踪交通态势。与 LSTM 相比,本文算法结构在优化前后均有更高的精度,这得益于生成对抗网络对真实数据的复制能力。另外,虽然图 8(c)和(d)显示采用 Wasserstein 散度与采用 JS 散度都能达到较高的精度,但从图 7 可知,引入 Wasserstein 散度后,网络的收敛速度与稳定性得到了提升,保证了生成数据的质量。



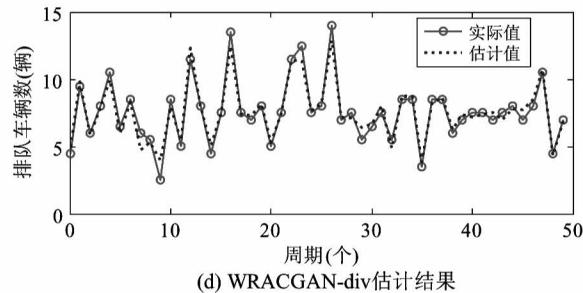
(a) ES 估计结果



(b) LSTM 估计结果



(c) RACGAN-JS 估计结果



(d) WRACGAN-div 估计结果

图 8 车道 1 最大排队车辆估计结果

表 3 为各功能车道排队车辆数估计值的均方误差,加粗的数字为最小误差,表示对应的算法性能最佳。可以看出,无论是最大还是最小排队车辆,WRACGAN-div 算法均在超过半数的车道上获得了

最小的误差,总体估计性能要优于其他 3 种方法。另外,从 ES 算法到本文算法,整体误差是在不断减小的,这说明数据驱动的估计算法比模型驱动的传统估计算法有更好的普遍性和适用性。

表 3 各方法排队车辆估计误差

误差	方法	车道 1	车道 2	车道 3	车道 4	车道 5	车道 6	车道 7	车道 8
最大 排队 MSE	ES	2.283	2.604	3.233	1.705	2.893	1.847	2.744	1.131
	LSTM	1.877	1.524	2.725	1.622	1.925	1.689	1.727	1.411
	RACGAN-JS	1.246	1.662	1.169	1.404	1.472	1.176	1.758	1.463
	WRACGAN-div	0.822	1.557	1.397	0.836	0.775	0.653	1.047	1.156
最小 排队 MSE	ES	0.482	0.273	0.326	0.286	0.394	0.197	0.228	0.315
	LSTM	0.217	0.114	0.196	0.127	0.232	0.100	0.162	0.096
	RACGAN-JS	0.165	0.062	0.088	0.154	0.103	0.122	0.073	0.114
	WRACGAN-div	0.071	0.069	0.053	0.090	0.074	0.109	0.086	0.049

在测试集上评估判别器的分类性能,用准确率(Acc)、精确率(Pr)、召回率(Re)、 $F1$ 值、kappa 系数(Kc)作为综合评价指标,各指标均是越高越好,分别表示如下:

$$Acc = \frac{\sum_0^i T_i}{\sum_0^i n_i} \times 100\% \quad (16)$$

$$Pr = \frac{T_i}{T_i + F_i} \quad (17)$$

$$Re = \frac{T_i}{n_i} \quad (18)$$

$$F1 = \frac{2 \times Pr \times Re}{Pr + Re} \quad (19)$$

$$Kc = \frac{Acc - (\sum_0^i T_i n_i) / (\sum_0^i n_i)^2}{1 - (\sum_0^i T_i n_i) / (\sum_0^i n_i)^2} \quad (20)$$

式中, T_i 、 F_i 、 n_i 分别为正确预测为第 i 类的个数、错误预测为第 i 类的个数、第 i 类实际的个数。

分类报告见表 4,从中可看出,每个类别的精确率、召回率、 $F1$ 值都达到了 90% 左右,总体分类准确率为 93.29%, kappa 系数为 0.91。这表明本文算法对每类交通拥堵情况都能比较精准的确定,可满足绝大部分的交通需求。

表 5 是本文算法与 K 最近邻(k-nearest neighbor, KNN)、支持向量机(support vector machine, SVM)、朴素贝叶斯(naive Bayesian, NB)、LSTM 4 种机器学习分类算法的比较结果,从中可看出前 4 种

算法分类精度都不到 90%,本文算法分类精度与之相比分别高出 3.96% ~ 9.62%,分类性能明显占优。

表 4 WRACGAN-div 算法分类报告

类别	Pr	Re	F1	Acc	Kc
类别 0	0.96	0.99	0.98		
类别 1	0.95	0.92	0.94		
类别 2	0.86	0.92	0.89	93.29%	0.91
类别 3	0.94	0.87	0.90		

表 5 不同算法的分类准确率

分类方法	分类准确率
KNN	84.00%
SVM	83.67%
NB	86.85%
LSTM	89.33%
WRACGAN-div	93.29%

5 结 论

本文从车道级的交通状态角度出发,以整体交叉口为目标,实现了从速度到功能车道排队车辆数的估计与分类。该思路使用完整性较好的速度数据,避免了流量估计排队车辆时数据易缺失的问题,对交通数据的挖掘与多样运用有一定的帮助。另

外,结合车道排队车辆数和拥堵类别可更细致地表征交通状态,有利于具体相位的控制方案调整,可提高信号优化效率。

针对传统排队车辆研究建模困难的问题,本文结合 Bi-LSTM 和 ACGAN 的特点,提出一种数据驱动模型,并引入 Wasserstein 散度对原始 ACGAN 算法进行改进。该算法无需对交叉口空间关系建模,采用数据生成数据的方式估计交通状态。实验结果表明,所提算法具有较好的稳定性和收敛速度,估计与分类性能均优于其他对比算法,验证了利用速度估计车道排队车辆数的可行性,可满足绝大部分的交通需求。

下一步工作将利用具体的交通环境对本文算法的适用性进行验证。

参考文献

- [1] 张驰远, 陈阳舟, 郭宇奇. 基于卡尔曼滤波的城市快速路交通密度估计与拥堵识别[J]. 交通信息与安全, 2017, 35(5): 55-61,82
- [2] 赵晨, 常玉林, 张鹏, 等. 基于预信号控制的交叉口车辆延误分析[J]. 公路, 2019, 64(6): 136-142
- [3] 唐克双, 梅雨, 李克平. 基于浮动车数据的交通状态估计精度仿真评价[J]. 同济大学学报(自然科学版), 2014, 42(9): 1347-1351,1407
- [4] Maria S G J, Evangelos M, Panagiotis T, et al. Multi-source data framework for road traffic state estimation [J]. *Journal of Advanced Transportation*, 2018, 2018: 1-9
- [5] 姚荣涵, 王殿海, 曲昭伟. 基于二流理论的拥挤交通流当量排队长度模型[J]. 东南大学学报(自然科学版), 2007(3): 521-526
- [6] 代磊磊, 姜桂艳, 裴玉龙. 饱和信号交叉口排队长度预测[J]. 吉林大学学报(工学版), 2008(6): 1287-1290
- [7] 王进, 白玉, 杨晓光. 关联信号交叉口排队长度计算模型[J]. 同济大学学报(自然科学版), 2012, 40(11): 1634-1640
- [8] 祁宏生, 王殿海. 信号控制交叉路口车辆排队长度[J]. 吉林大学学报(工学版), 2009, 39(6): 1457-1462
- [9] 杨良义, 谢飞, 陈涛. 基于视频的交叉路口车辆排队长度检测方法研究[J]. 重庆理工大学学报(自然科
- 学), 2018, 32(6): 169-174
- [10] Vigos G, Papageorgiou M. A simplified estimation scheme for the number of vehicles in signalized links[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2010, 11(2): 312-321
- [11] 刘泽, 王武宏, 郭宏伟, 等. 基于浮动车数据的信号交叉口排队长度估计[J]. 道路交通与安全, 2016, 16(4): 7-11
- [12] Ramponi G, Protopapas P, Brambilla M, et al. T-CGAN: conditional generative adversarial network for data augmentation in noisy time series with irregular sampling [EB/OL]. <https://arxiv.org/>: Cornell University, 2019
- [13] Bharadhwaj H, Park H, Lim B. RecGAN: recurrent generative adversarial networks for recommendation systems [C] // Proceedings of the 12th ACM Conference on Recommender Systems, Vancouver, Canada, 2018: 372-376
- [14] Li M, Wang L, Yan J Q, et al. The study of traffic flow information completion based on GAN algorithm [C] // 2018 IEEE 7th Data Driven Control and Learning Systems Conference, Enshi, China, 2018: 1185-1190
- [15] Koeswiady A, Karray F. New results on multi-step traffic flow prediction [EB/OL]. <https://arxiv.org/>: Cornell University, 2018
- [16] Albert A, Strano E, Kaur J, et al. Modeling urbanization patterns with generative adversarial networks [C] // 2018 IEEE International Geoscience and Remote Sensing Symposium, Valencia, Spain, 2018: 2095-2098
- [17] Lv Y S, Chen Y Y, Li L, et al. Generative adversarial networks for parallel transportation systems[J]. *IEEE Intelligent Transportation Systems Magazine*, 2018, 10(3): 4-10
- [18] Odena A, Olah C, Shlens J. Conditional image synthesis with auxiliary classifier GANs [C] // Proceedings of the 34th International Conference on Machine Learning, Sydney, Australia, 2017: 2642-2651
- [19] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets [C] // Proceedings of the 27th International Conference on Neural Information Processing Systems, Montreal, Canada, 2014: 2672-2680
- [20] Mirza M, Osindero S. Conditional generative adversarial nets [EB/OL]. <https://arxiv.org/>: Cornell University, 2014
- [21] Arjovsky M, Chintala S, Bottou L. Wasserstein GAN

[EB/OL]. <https://arxiv.org/>; Cornell University, 2017
 [22] Wu J Q, Huang Z W, Thoma J. Wasserstein divergence

for GANs[C] // The 15th European Conference on Computer Vision, Munich, Germany, 2018: 673-688

Lane queue vehicles estimation and classification based on improved ACGAN algorithm

Guo Haifeng^{*}, Yang Xianzan^{*}, Jin Junchen^{**}

(* College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023)

(** Institute of Intelligent Transportation, Enjoyor Co., Ltd, Hangzhou 310030)

Abstract

Considering the difficulty of constructing probability distribution and modeling in traditional model-driven queue vehicle researches, a data-driven estimation algorithm for lane-level queue vehicles combining bi-directional long short-term memory (Bi-LSTM) network and auxiliary classifier generative adversarial network (ACGAN) is proposed, in which the intersection spatial relation model is not required. The generator turns velocity sequence into queue vehicles by Bi-LSTM according to the time correlation between them. The discriminator comes from ACGAN, categorizing the queue vehicles to congestion level labels while distinguishing true and false samples. To avoid training instability and gradient disappearance, the original ACGAN's true-false binary classification task is abandoned, and Wasserstein divergence is introduced to measure the distribution distance between the true and false sequences, with the corresponding objective function optimized. The results show that compared with other algorithms, the classification accuracy of the proposed algorithm increases by 3.96% – 9.62% with the minimal overall error, which verifies the feasibility of estimating lane queue vehicles by velocity.

Key words: auxiliary classifier generative adversarial network (ACGAN), bi-directional long short-term memory (Bi-LSTM), Wasserstein divergence, lane-level queue vehicles estimation, classification