

# 控制与决策

Control and Decision

## 基于生成对抗网络的大规模路网交通流预测算法

代亮, 梅洋, 钱超, 孟芸, 汪贵平

引用本文:

代亮, 梅洋, 钱超, 等. 基于生成对抗网络的大规模路网交通流预测算法[J]. *控制与决策*, 2021, 36(12): 2937–2945.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0333>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 区分交通流模式的混合服务路口信号控制策略

Signal control strategies of mixed service intersections to discriminate traffic flow patterns

*控制与决策*. 2021, 36(6): 1509–1515 <https://doi.org/10.13195/j.kzyjc.2019.1520>

### 基于生成对抗网络学习被遮挡特征的目标检测方法

Object detection via learning occluded features based on generative adversarial networks

*控制与决策*. 2021, 36(5): 1199–1205 <https://doi.org/10.13195/j.kzyjc.2019.1319>

### 基于FWADE-ELM的短时交通流预测方法

Short-term traffic flow forecasting based on hybrid FWADE-ELM

*控制与决策*. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

### 基于FWADE-ELM的短时交通流预测方法

Short-term traffic flow forecasting based on hybrid FWADE-ELM

*控制与决策*. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

### 基于改进萤火虫算法的区域交通信号配时优化

Timing optimization of regional traffic signals based on improved firefly algorithm

*控制与决策*. 2020, 35(12): 2829–2834 <https://doi.org/10.13195/j.kzyjc.2019.1835>

# 基于生成对抗网络的大规模路网交通流预测算法

代亮<sup>†</sup>, 梅洋, 钱超, 孟芸, 汪贵平

(长安大学 电子与控制工程学院, 西安 710064)

**摘要:** 对大规模路网交通流进行准确预测, 能够应用于区域交通协同控制与管理, 提高路网运行效率. 针对如何高精度地拟合大规模路网交通流时空分布并对其进行准确预测, 提出基于梯度惩罚的 Wasserstein 生成对抗网络 (Wasserstein generative adversarial network with gradient penalty, WGAN-GP) 的大规模路网交通流预测算法. 根据大规模路网交通流数据特点, 为了增加模型对时间相关性和远距离空间相关性特征的抽象能力, 采用残差 U 型网络作为生成器来增加网络深度; 采用多重判别器分别从时间和空间特征来对生成数据进行判别, 从而提高判别器的判别能力. 所提算法能够解决判别型深度学习模型仅能针对路网整体误差最小化, 而忽略各交通流观测点预测误差最小化原则的问题, 能够更好地满足现实交通场景需求. 实验结果表明, 所提算法能够有效地学习路网交通流数据内部多因素耦合特性, 具有更高的预测精度.

**关键词:** 大规模路网; 交通流预测; 生成对抗网络; 残差 U 型网络; 深度学习模型

中图分类号: U491

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0333

开放科学(资源服务)标识码(OSID):



**引用格式:** 代亮, 梅洋, 钱超, 等. 基于生成对抗网络的大规模路网交通流预测算法 [J]. 控制与决策, 2021, 36(12): 2937-2945.

## Traffic flow forecasting algorithm for large-scale road network based on GAN

DAI Liang<sup>†</sup>, MEI Yang, QIAN Chao, MENG Yun, WANG Gui-ping

(School of Electronics and Control Engineering, Chang'an University, Xi'an 710064, China)

**Abstract:** Accurate traffic flow forecasting can be applied to traffic control and management to improve operating efficiency of the large-scale road network. Aiming at how to fit the spatio-temporal distribution of traffic flow with high precision and accurate forecasting, an algorithm of large-scale road network traffic flow forecasting based on the Wasserstein generative adversarial network with gradient penalty is proposed. According to the characteristics of traffic flow data for large-scale road networks, the proposed algorithm uses the residual U-Net as a generator to increase the network depth for improving the ability of model to abstract the characteristics of temporal correlation and long-distance spatial correlation. The proposed algorithm can solve the problem that the discriminant deep learning models can only minimize the whole error of the road network while ignoring the error minimization of each observation point, then meet the demand of real traffic scenes better. Experimental results show that the proposed algorithm can learn the coupling characteristics of multi-factor inside the traffic flow data in large-scale road networks effectively and improve the prediction accuracy.

**Keywords:** large-scale road network; traffic flow forecasting; generative adversarial network; residual U-Net; deep learning model

## 0 引言

为了实现交通基础设施加速成网, 落实交通强国战略规划, 我国公路总里程及路网密度将进一步增加. 高效地对大规模路网交通流进行准确预测, 能够应用于区域交通协同控制与管理, 有效疏导交通流量, 平衡路网需求, 缓解道路拥塞, 提高路网运行效率.

传统的交通流预测方法可分为参数模型和非参数模型, 其中时间序列模型广泛地应用于参数模型中. 文献[1]考虑到交通流具有的周期性特征, 提出使用季节性自回归求和滑动平均模型来提高预测准确率; 文献[2]使用混合双卡尔曼滤波器进行短时交通流预测, 对传统卡尔曼滤波器和随机漫步模型预测

收稿日期: 2020-03-23; 修回日期: 2020-07-07.

基金项目: 国家重点研发计划项目(2018YFB1600600).

责任编辑: 阳春华.

<sup>†</sup>通讯作者. E-mail: ldai@chd.edu.cn.

的差值进行建模,再通过估计两种模型预测误差的后验状态,利用对误差的校正来补偿之前的预测。由于非参数模型相较参数模型能更好地描述交通流非线性的特征,非参数模型成为解决交通流预测的有效方法。文献[3]采用了动态 $K$ 最近邻算法(KNN)来预测交通流,该算法的KNN参数具有自适应性,在未对模型参数进行训练的情况下,依然能保证算法的鲁棒性。文献[4]提出了支持向量回归(support vector regression, SVR)、随机森林和遗传算法的混合模型,利用随机森林及遗传算法对SVR模型进行优化来提高模型的预测精度。其中:随机森林算法用于选择显著的特征;遗传算法可以防止模型陷入局部最优解,并能够优化SVR模型的超参数。文献[5]基于改进的人工蜂群算法的径向基函数神经网络,有效地提高了对交通流时间序列预测的精度。神经网络浅层的结构无法表征特定函数族,因此难以捕捉交通流混沌性和随机性的特征<sup>[6]</sup>。文献[7]提出了一种基于烟花差分进化混合算法-极限学习机的短时交通流预测方法,该方法采用奇异谱分析方法对原始交通流数据进行降噪,进而用于训练极限学习机网络预测模型,确定极限学习机网络的结构和关键参数。

由于传统短时交通流预测模型较简单,难以高精度地拟合交通流多因素耦合的复杂非线性特征。近年来,深度学习技术推进了路网交通流预测的发展,其深层网络结构能够实现复杂且灵活的函数逼近,更精准地表达交通流数据内部的复杂结构<sup>[8]</sup>。文献[9]首次将深度学习应用于短时交通流预测领域中,该模型由底部的DBN和顶部的多任务回归层组成。DBN用于非监督的特征学习,输出学习到的数据特征作为回归层的输入,回归层对交通流进行回归预测,该模型的预测准确率较传统预测方法提高了5%。文献[10]构建多个不同深度、不同超参数的堆叠自编码器(stacked autoencoder, SAE),并利用AdaBoost集成学习算法降低模型预测偏差,提升集成模型的鲁棒性。DBN和SAE每次仅能对一个交通流观测点进行预测,无法高效地对大规模路网交通流进行预测。长短期记忆网络(long short-term memory, LSTM)能够处理具有长期依赖关系的时序数据,被广泛地应用于交通流预测领域中。如文献[11]为了捕捉路网交通数据的时空相关性提出了起讫点关联矩阵,该矩阵由路网中交通数据采集点间交通量的相关系数组成,具有空间相关性的起讫点关联矩阵作为参数,并利用LSTM处理时序数据长期依赖的能力,以此提高预测准确率,但LSTM网络本身无法捕获数据的空间特征,必须手工将空间信息编码作为网络的输

入。为了捕获交通流数据的时空相关性,文献[12]利用卷积神经网络(convolutional neural networks, CNN)对网格化数据的处理能力,提出使用三维CNN对路网交通流数据进行建模来捕捉路网交通数据的时空特征。文献[13]结合了CNN和门控循环单元(gated recurrent unit, GRU),CNN捕获路网交通数据的空间分布,GRU捕获数据短期分布的变化及长期依赖。CNN能够解决一次对整个路网的交通流数据进行预测的问题,但需要人工设计有效的损失函数,如何针对该问题进行有效的损失函数设计是一个难题。

上述基于判别型深度学习的路网交通流预测方法相比于传统预测方法提高了预测性能,但需为模型设计有效的损失函数,以确保深度模型通过学习使损失函数最小。对于大规模路网交通流预测,通过最小化预测值和真实值间的误差,模型通过学习趋向于使路网预测整体误差最小,但无法保证每个交通流观测点拟合该点的真实值,因此无法满足现实交通场景的需求。生成对抗网络(generative adversarial network, GAN)是训练生成模型的一种新的研究热点,能够解决概率计算的逼近问题<sup>[14]</sup>。文献[15-16]提出了基于GAN的短时路网交通流预测模型。文献[15]利用GAN生成相似于真实数据分布的能力,使预测模型生成与路网交通流数据分布相似的预测值。但GAN存在训练困难、模型难以收敛及模式坍塌的问题<sup>[17]</sup>。文献[16]中生成器和判别器分别由4层和5层的全连接层组成。相对于稀疏连接,该模型使用全连接需要更多的参数加以计算,导致训练过程需要更多的计算量,造成模型统计效率低下。此外,参数过多导致模型复杂度较高,增加了模型过拟合的风险,进一步限制了网络深度加深的可能,而更深的网络对提高数据高级特征的抽象能力具有重要意义。

针对上述研究现状及存在问题,本文提出基于WGAN-GP的路网交通流预测算法。该算法由一个生成器和两个判别器模型组成,其中生成器采用残差U型网络(residual U-Net, RU-Net),引入残差学习思想的RU-Net,有效地增强了捕捉路网交通流数据时空相关性的能力,能够学习到路网交通流数据的潜在分布,生成与真实数据分布近似的预测数据;两个判别器分别从路网交通流的空间和时间特性,判别从路网交通流真实值抽取的样本和预测值抽取的样本,提升模型的判别能力,进而增强生成器对路网交通流时空特征的抽象能力。本文提出的基于WGAN-GP的短时交通流预测算法,能够生成与真实路网交通流分布相似的预测结果,并有效避免GAN训练困难、模型难以

收敛及模式坍塌的问题发生,提高预测准确率.

### 1 梯度惩罚的Wasserstein生成对抗网络

GAN是训练生成模型的一种高效算法,目的是令生成器能够生成与真实数据分布近似的数据,达到以假乱真的效果<sup>[18]</sup>. 针对大规模路网交通流预测问题,通过训练使生成器学习路网交通流分布,对大规模路网交通流进行预测. 因此,训练后的生成器能够减小真实路网交通流数据和生成数据概率分布之间的差异,使判别器无法分辨生成数据的真伪.

由于生成数据分布  $P_G$  和真实数据分布  $P_{data}$  间的差异无法通过计算得出,判别器通过数据采样来计算  $P_G$  和  $P_{data}$  的散度,以此判别两个数据分布间的差异. 判别器的目标函数为

$$V(G, D) = E_{\mathbf{x} \sim P_{data}}[\log D(\mathbf{x})] + E_{\mathbf{x} \sim P_G}[\log(1 - D(\mathbf{x}))]. \quad (1)$$

其中:  $E(\cdot)$  为数学期望,  $D(\cdot)$  为判别器输出结果.

最大化判别器的目标函数等价于生成数据和真实数据的Jensen-Shannon (JS) 散度<sup>[19]</sup>. 最优生成器通过最小化真实路网交通流数据与生成数据间分布的散度来达到预测目的. 最优生成器可表示为

$$G^* = \arg \min_G \max_D V(G, D). \quad (2)$$

GAN能够生成与真实数据分布近似的生成样本,但存在训练难度大、网络难收敛及模式坍塌问题,一些研究提出了GAN的变体来对模型加以改进<sup>[18]</sup>,如WGAN在生成数据和真实数据分布没有重叠时,两数据分布的JS散度恒为  $\log 2$ ,会导致梯度消失问题,使模型难以训练<sup>[17]</sup>. WGAN利用Wasserstein距离代替JS散度,作为度量生成数据和真实数据间分布差异的方法. Wasserstein距离为生成数据和真实数据联合分布下样本期望距离的下确界,通过该距离衡量分布间差异,能够使模型的训练更加稳定,并解决模式坍塌问题,保证生成模型输出数据的多样性. 为保证判别器目标函数满足Lipschitz条件,WGAN采取权重截断方法来限制权重参数取值范围,该方法会

造成网络梯度消失或梯度爆炸问题. 为了解决该问题,文献[20]在判别器目标函数中加入一项梯度惩罚来保证函数符合Lipschitz条件. 加入梯度惩罚后的目标函数为

$$V(G, D) = E_{\mathbf{x} \sim P_{data}}[D(\mathbf{x})] - E_{\mathbf{x} \sim P_G}[D(\mathbf{x})] - \lambda_{gp} E_{\mathbf{x} \sim P_{penalty}}[(\|\nabla_{\mathbf{x}} D(\mathbf{x})\|_2 - 1)^2]. \quad (3)$$

其中:  $\lambda_{gp}$  为权重参数;  $P_{penalty}$  为计算梯度惩罚的样本的概率分布;在  $P_{data}$  与  $P_G$  中分别采样一个点,两点连线上随机采样一点,作为该分布采样点<sup>[20]</sup>.

带有梯度惩罚的WGAN解决了梯度消失和梯度爆炸的问题,进一步提升了网络的训练速度,增加了训练的稳定性,有助于生成的预测数据拟合真实路网交通流数据分布. 路网交通流数据在不同的时段符合不同的数据分布,因此借鉴条件生成对抗网络向生成器和判别器输入额外的辅助信息来指导数据生成<sup>[21-22]</sup>. 本文所提出的交通流预测算法将利用历史交通流数据,使模型易于捕捉时序交通流的时间相关性以此辅助预测.

### 2 生成器和判别器网络设计

生成器的作用是生成与真实路网交通流分布相似的预测数据,达到使判别器无法区分真实数据与生成数据的目的;判别器网络用于对生成数据的真伪进行判别. 由于生成的路网交通流预测数据与历史数据有较强的时空相关性,充分捕捉路网交通流数据的时空相关性,便能够提升判别器的判别能力.

#### 2.1 生成器网络结构

为了应对大规模路网交通流预测问题,针对路网交通流数据网格化、低分辨率的特点,生成器采用RU-Net,其结构如图1所示. 由于RU-Net以卷积神经网络为基础,适合于处理网格化模式数据. 模型输入为路网中历史时空交通量组成的矩阵,输出为高维结构化张量型数据,可以一次性完成路网上所有交通流数据的预测,从而提高预测效率.

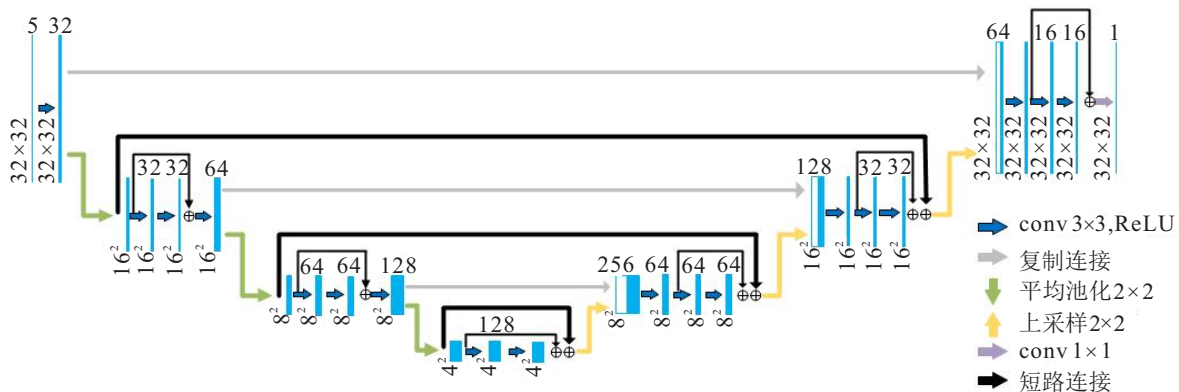


图1 RU-Net结构

RU-Net将残差学习和U-Net相结合.首先,通过将卷积层短路连接构成同层级残差结构来增加各堆叠卷积层数量,并在每两卷积层之间添加短路连接,从而可以解决卷积层加深时出现的系统退化问题<sup>[23]</sup>;其次,将对称池化层和上采样层之间短路连接构成对称式残差结构.如图1所示,这两种短路连接的作用是为了加深残差U型网络模型的深度.

U-Net是深度学习领域中广泛应用于图像处理的图像特征提取工具<sup>[24]</sup>,而图像构成的矩阵相比路网交通流数据所能构成的矩阵大.因此,对于解决路网交通流数据的预测问题,输入矩阵较小,则通过较少池化层下采样后,可能出现输入数据信息丢失的问题.增加与对称池化层和上采样层之间的短路连接后,在增加模型深度的同时,不会造成输入数据信息丢失的问题.这有助于将路网交通流数据在时间域的相关性和空间域的上下文语义信息相结合,使模型更容易发现数据的时空相关性.

对于半封闭、封闭特征的道路结构,如高速公路、隧道及城市快速干道等,远距离观测点间空间相关性可以用来增加大规模路网交通流数据的预测准确率<sup>[25]</sup>.由于一层卷积层受限于核的大小,其只能提取到近距离空间相关性.卷积层间的短路连接可以增加卷积层深度,而不会造成网络退化问题,以此来捕捉到路网交通数据的远距离空间相关性.

## 2.2 多重判别器网络结构

结合路网交通流数据的时空特性,本文所提出的大规模路网交通流预测算法改进了传统GAN中采用单一判别器的局限,使用时间判别器和空间判别器从不同侧面对生成数据进行判别,以提高判别器的判别能力.判别器的输入为历史路网交通流、待预测时刻的真实路网交通流及其预测值.为了判别路网中局部区域细节信息,采用PatchGAN结构令判别器输出 $N \times N$ 的矩阵,该矩阵中每个元素代表路网交通流预测结果中一个较大的感受野,即对某个局部区域的判别结果.由表1可知,当判别器输出矩阵尺寸为 $4 \times 4$ 时,模型预测性能最佳.

表1 判别器输出矩阵对预测结果的影响

输出矩阵尺寸	1×1	2×2	4×4	8×8	16×16	32×32
RMSE	15.0409	13.7867	11.0318	12.9423	12.2993	15.5797
MAPE	4.6387	4.4064	3.4188	4.1231	3.7283	5.3439

如图2所示,空间判别器由多层CNN构成,堆叠的CNN能够捕捉到路网交通流预测结果的空间特征. $L_1$ 至 $L_3$ 层中卷积核尺寸为 $3 \times 3$ ,步长为2,能够对数据降维,增大感受野,使网络捕捉到更大范围空间

域的上下文信息; $L_4$ 至 $L_7$ 层增加了网络深度,使网络更有效地捕捉到路网交通流远距离空间相关性.因此,空间判别器关注于对路网交通流空间特征的判别能力.




图2 空间判别器网络结构

如图3所示,时间判别器由卷积长短期记忆网络(ConvLSTM)和CNN组成.ConvLSTM将LSTM的全连接方式改为稀疏连接,有利于模型对时空特征的提取<sup>[26]</sup>.将历史时空交通量矩阵和待判别空间交通量矩阵依时序作为模型输入,根据ConvLSTM对时序特征的捕捉能力得出判别结果.利用时间判别器对时序交通流数据的处理能力来增强对路网交通流时间特征的判别能力.

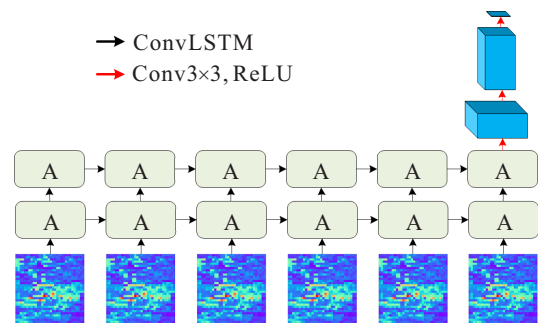


图3 时间判别器网络结构

生成网络能够根据路网交通流时空特性,将历史交通流数据样本映射到预测交通流数据空间.时间判别器和空间判别器能够从路网交通流的时空特征对生成数据的真伪进行判别,进而训练生成网络降低真实交通流数据与预测数据间分布的差异,增强生成网络对路网交通流时空特征信息的抽象能力,使生成的预测数据接近真实数据的分布.

## 3 损失函数

本文所提出的路网交通流数据预测算法是基于WGAN-GP的算法,WGAN-GP的损失函数 $L_{WGAN}$ 能够减少预测数据与真实数据的概率分布差异,从而使生成器生成的预测数据更准确地拟合真实数据分布. $L_{WGAN}$ 可定义为

$$L_{WGAN_i}(G, D) = E_{\mathbf{x} \sim P_{\text{data}}} [D_i(\mathbf{x}|\mathbf{h})] - E_{\mathbf{x} \sim P_G} [D_i(\mathbf{x}|\mathbf{h})] - \lambda_{\text{gp}} E_{\mathbf{x} \sim P_{\text{penalty}}} [(\|\nabla_{\mathbf{x}} D_i(\mathbf{x}|\mathbf{h})\|_2 - 1)^2]. \quad (4)$$

其中: $D_i(\cdot)$ 表示判别器 $i$ , $\mathbf{h}$ 表示历史路网交通流数

据.

在GAN的损失函数中添加传统损失函数,能够提升生成器生成数据的准确性<sup>[27]</sup>.生成器的作用不仅是生成能够欺骗判别器的数据,同时生成的数据应足够接近真实数据.由于路网交通流预测是一个回归问题,在损失函数中加入L2距离作为损失函数,能够惩罚预测值与真实值间的极端误差.该损失函数 $L_{MSE}$ 定义为

$$L_{MSE}(G) = E_{\mathbf{x} \sim P_{data}} [\|\mathbf{x} - G(\mathbf{h})\|_2], \quad (5)$$

其中 $\|\cdot\|_2$ 为二范数.

最终算法损失函数为上述两种函数的加权和,即

$$L_{total} = \sum_{i=1,2} L_{WGAN_i}(G, D_i) + \lambda_{mse} L_{MSE}(G), \quad (6)$$

其中 $\lambda_{mse}$ 为权重参数.

## 4 算法流程

基于WGAN-GP的大规模路网交通流预测算法训练步骤如下所示.

**算法1** 大规模路网交通流预测算法.

1) 初始化算法生成器 $G$ 和两个判别器 $D_1$ 、 $D_2$ ; 设置生成器优化器Adam学习率 $\alpha$ 、判别器的优化器RMSProp学习率 $\beta$ 、训练迭代次数 $n$ 、批大小 $m$ 、权重参数等超参数.

2) for each  $i \in [1, n]$  do

3) 从真实数据分布 $P_{data}(\mathbf{x})$ 中采样 $m$ 个样本 $\{\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^m\}$ , 及对应的历史数据 $\{\mathbf{h}^1, \mathbf{h}^2, \dots, \mathbf{h}^m\}$ .

4) 计算生成数据 $\{\tilde{\mathbf{x}}^1, \tilde{\mathbf{x}}^2, \dots, \tilde{\mathbf{x}}^m\}$ ,  $\tilde{\mathbf{x}}^i = G(\mathbf{h}^i)$ .

5) 利用真实数据和生成数据计算得到 $P_{penalty}$ 的采样样本 $\{\mathbf{x}_p^1, \mathbf{x}_p^2, \dots, \mathbf{x}_p^m\}$ .

6) 训练 $D_1$ 更新模型参数

$$g_{\theta_{d_1}} = \nabla_{\theta_{d_1}} \frac{1}{m} \sum_{i=1}^m [D_1(\mathbf{x}^i | \mathbf{h}) - D_1(\tilde{\mathbf{x}}^i | \mathbf{h}) - \lambda_{gp} [\|\nabla_{\mathbf{x}_p} D_1(\mathbf{x}_p^i | \mathbf{h})\|_2 - 1]^2],$$

$$\theta_{d_1} \leftarrow \theta_{d_1} + \beta_1 \text{RMSProp}(\theta_{d_1}, g_{\theta_{d_1}}).$$

7) 训练 $D_2$ 更新模型参数

$$g_{\theta_{d_2}} = \nabla_{\theta_{d_2}} \frac{1}{m} \sum_{i=1}^m [D_2(\mathbf{x}^i | \mathbf{h}) - D_2(\tilde{\mathbf{x}}^i | \mathbf{h}) - \lambda_{gp} [\|\nabla_{\mathbf{x}_p} D_2(\mathbf{x}_p^i | \mathbf{h})\|_2 - 1]^2],$$

$$\theta_{d_2} \leftarrow \theta_{d_2} + \beta_2 \text{RMSProp}(\theta_{d_2}, g_{\theta_{d_2}}).$$

8) 训练 $G$ 更新模型参数

$$g_{\theta_g} = \nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m -D[G(\mathbf{h}^i)] + \|\mathbf{x}^i - G(\mathbf{h}^i)\|_2,$$

$$\theta_{d_1} \leftarrow \theta_{d_1} - \alpha \text{Adam}(\theta_g, g_{\theta_g}).$$

9) end for

## 5 实验与分析

### 5.1 实验数据描述

实验验证采用英国政府发布的英格兰高速公路交通流数据集<sup>[28]</sup>.如图4所示,在该数据集中选取伦敦市及周边1024个交通量观测点,将其构造为 $32 \times 32$ 的交通量矩阵,选取2013年1月1日至2013年6月30日共181天的交通量数据,共17793024条记录,对本文所提出的基于WGAN-GP的大规模路网交通流数据预测算法进行性能验证.

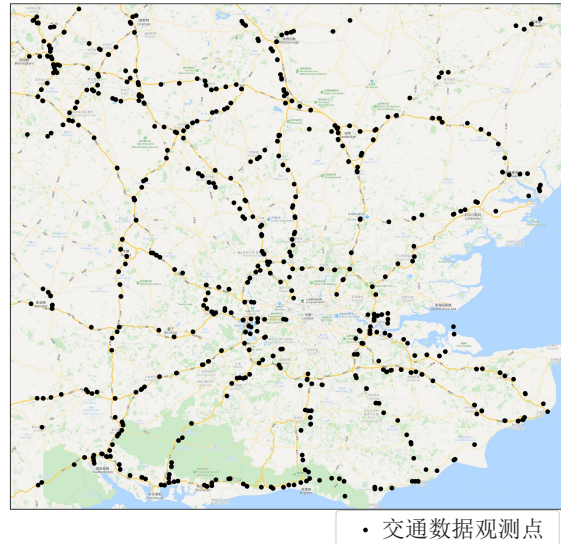


图4 伦敦交通数据观测点

### 5.2 数据预处理

RU-Net以卷积神经网络为基本元素,是一种用来处理具有类似网络结构拓扑数据的神经网络,可以处理时序数据.在本文中,为了充分捕获大规模路网交通流数据的时空相关性,根据1024个交通流观测点的空间位置将其转化为 $32 \times 32$ 的交通量矩阵.图5(a)和5(b)分别展示了2013年6月1日8点和20点的路网交通量矩阵,可以看出两个时间点路网交通量数据具有相似的分布.此外,图6选择了编号100至119共20个交通信息采集点交通量的皮尔逊相关系数矩阵,20个采集点中相关系数最低为0.81,这表明采集点之间具有空间相关性.

交通量数据具有周期性的特点,在实验中将待进行交通量预测时间点的前两周同一时间点的路网交通量矩阵作为路网时间交通量矩阵.为了处理路网中交通突发事件,获取时序交通流数据的时间相关性,将待进行预测时间点的前3个观测间隔路网交通量矩阵叠加至路网时间交通量矩阵.以上5个时间点的交通量矩阵构成了一个 $32 \times 32 \times 5$ 的路网时空交通量矩阵作为模型的输入,使本文所研究的路网交通流预测模型可以简单有效地获得路网交通量的时间相关性.

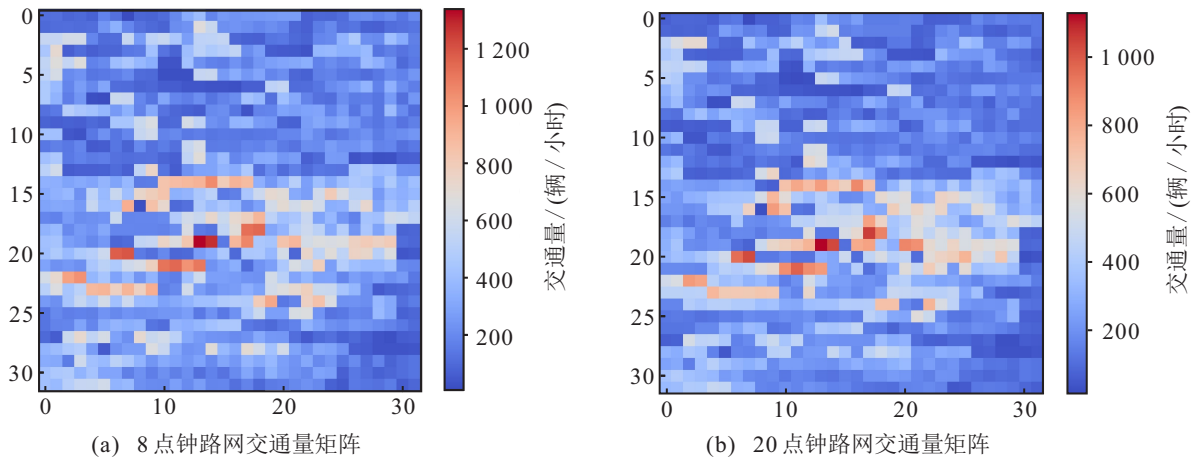


图5 交通量矩阵




图6 观测点交通量相关系数矩阵

5.3 评价指标

为了评估本文所述大规模路网交通流数据预测算法的性能,选用均方根误差(RMSE)、平均绝对误差(MAE)、平均绝对百分误差(MAPE)对所提算法进行性能评估,其中

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\tilde{x}^i - x^i)^2}, \quad (7)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |\tilde{x}^i - x^i|, \quad (8)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\tilde{x}^i - x^i}{\tilde{x}^i} \right|. \quad (9)$$

其中:  $\tilde{x}^i$  为交通流数据预测值,  $x^i$  为交通流数据观测值,  $N$  为交通流观测点数量.

### 5.4 实验设置

在实验中,将1024个交通流信息采集点网格化后,根据位置关系转换为 $32 \times 32$ 规格的路网空间位置矩阵,其中80%的交通量数据用于训练集,10%的交通量数据用于验证集,剩余交通量数据作为测试集.网络训练时卷积核初始化为Glorot均匀分布,偏差权值初始化为0.模型采用批量训练,每批训练数据量为64.生成器学习率为 $2 \times 10^{-4}$ ,优化器采用Adam算法,输入矩阵尺寸为 $32 \times 32 \times 5$ ,输出矩阵尺寸为 $32 \times 32 \times 1$ ;判别器学习率为 $8 \times 10^{-4}$ ,空间判别器和时间判别器中优化器分别采用Adam和RMSprop算法,输入矩阵尺寸为 $32 \times 32 \times 6$ ,输出矩阵尺寸为 $4 \times 4 \times 1$ .对比不同损失函数权重值模型的预测性能,取 $\lambda_{gp} = 5, \lambda_{mse} = 10$ .为了减少随机性对实验结果的影响,选取5次预测结果的平均值作为最终实验结果.

### 5.5 实验分析

图7是5种模型对路网交通量预测误差的对比结果.以RMSE、MAE和MAPE三个评价指标对比,本文所提出的带有时空双重判别器的WGAN-GP模型(WGAN-DST)预测结果均优于其他4种预测模型.从图7可以看到,WGAN-DST的平均绝对误差与均方根误差较低,表明该模型预测值的总离差较小,出现异常极端预测值的可能较小,较低的平均绝对百分误差表明该模型的预测精度更高.

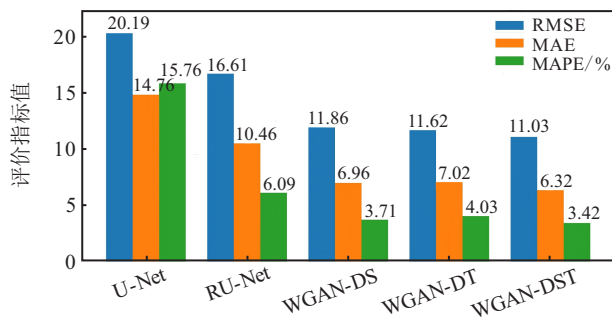


图7 各评价指标预测效果对比

从U-Net与RU-Net的预测结果对比可以看出,RU-Net预测值的均方根误差较U-Net减小17.73%,平均绝对百分误差减小61.36%,表明在U-Net的基础上引入了残差网络后,RU-Net能够在保证网络得到有效训练的基础上增加网络深度,增强模型对路网交通数据特征的抽象能力.相较于仅有时间判别器的WGAN-GP模型(WGAN-DT)和仅有空间判别器的WGAN-GP模型(WGAN-DS),WGAN-DST较二者的预测性能有进一步的提升.判别器分别从时空特征对生成的路网交通流数据进行判别,相较于单个判


别器的判别能力更强,能够驱使生成器生成与真实数据分布更接近的预测数据,从而减小预测值偏差,提高预测精度.

为了分析模型中生成器RU-Net的两种残差结构对预测模型的影响,表2展示了仅具有同层级残差结构(Rpeer)或对称式残差结构(Rsym)生成器的预测性能.表2中Rpeer预测性能较低,缺少了对称式残差结构的生成器使模型对下采样次数的适应性降低,随着模型深度的增加,历史路网交通流数据信息丢失的风险也随之增加.Rsym预测性能的降低表明,缺少了同层级残差结构增加了模型的训练难度,容易造成网络退化问题.此外,实验中Rsym模型收敛速度较慢.


表2 不同残差结构模型预测性能

	Rpeer	Rsym	Rsym+Rpeer
RMSE	18.03	17.24	11.03
MAE	12.13	11.27	6.32
MAPE/%	6.30	5.75	3.42


图8展示对路网中1024个交通流观测点预测结果的箱线图,能够反映预测结果的分布特征.从各评价指标的分布特征能够看出,直接训练RU-Net和训练生成器为RU-Net的WGAN-GP模型对比,基于



(a) RMSE评价指标预测效果对比



(b) MAE评价指标预测效果对比



(c) MAPE评价指标预测效果对比

图8 各评价指标预测效果对比箱线图

WGAN-GP的预测模型的预测值偏差更小,精度更高.另外,RU-Net的预测偏差分布更离散,波动更大,表明基于WGAN-GP的预测模型预测结果更稳定,生成的预测数据分布更近似于真实路网数据分布,而非仅最优化整个路网预测值的评价指标,这对于大规模路网交通流预测的现实场景具有重要意义.

图9为对编号AL3149A交通数据采集点6月27日及28日两天的交通量预测结果.图9(a)中的U-Net和图9(b)中的RU-Net,两个模型都能较好地追踪真实交通量的变化趋势,但RU-Net模型的预测误差更小,并且预测值中更少出现极端误差值的情况.从整体来看,WGAN-DST模型预测误差最小.当交通量值出现急剧变化的场景时,交通流的随机性加强,预测值会产生较大的波动,容易出现预测精度下降的问题,而WGAN-DST模型仍具有较好的适应性,能够准确地预测下一个观测时间点的交通量.当交通量处于高峰时,由于此时交通量将会出现较大的随机性,并且出现转折变化,准确预测的难度较大.WGAN-DST模型在高峰时也能够准确地描述数据的分布,并具有更低的预测误差,能够更准确地预测出交通高峰的极值及其转折变化.这表明WGAN-DST能够生成与真实路网交通流分布更近似的预测结果.

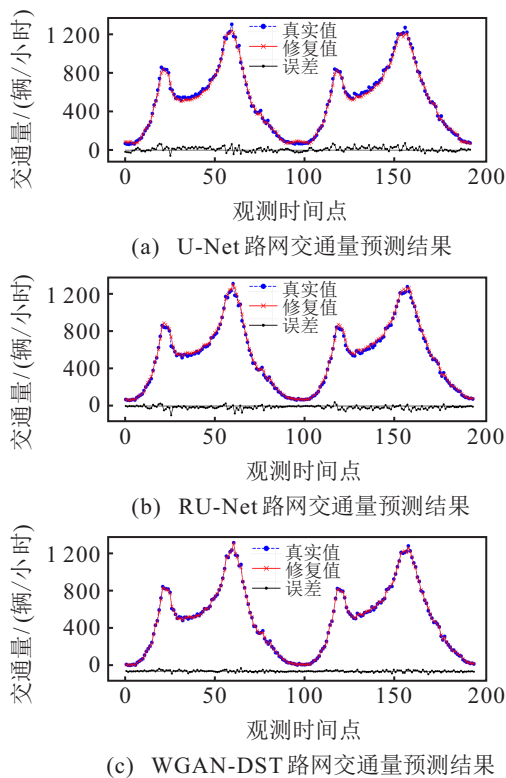


图9 路网交通量预测结果

## 6 结论

本文提出的基于WGAN-GP的大规模路网交通流预测算法,能够满足大规模路网交通流预测需求,

生成近似于真实数据分布的预测数据.该模型解决了通过最小化整体误差,而忽略了各观测点预测误差最小化原则的问题.此外,模型的生成器采用RU-Net,在网络不发生退化的前提下能够有效地增加网络深度.在大规模路网交通预测场景下,该结构对远距离空间相关性的捕捉具有重要意义.模型的判别器采用双重判别器,分别从时空相关性两个侧面对生成的预测数据进行判别,能够有效地增强判别能力,驱使模型生成与真实数据分布更近似的预测数据.实验结果表明,本文提出的基于WGAN-GP的路网交通流预测,能够高效地应对大规模路网交通流数据的预测,预测结果具有更小的误差,并且误差分布离散度更低,表明路网交通流预测数据与真实数据分布更相近.

## 参考文献(References)

- [1] Williams B M, Hoel L A. Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: Theoretical basis and empirical results[J]. Journal of Transportation Engineering-asce, 2003, 129(6): 664-672.
- [2] Zhou T, Jiang D Z, Lin Z Z, et al. Hybrid dual Kalman filtering model for short-term traffic flow forecasting[J]. IET Intelligent Transport Systems, 2019, 13(6): 1023-1032.
- [3] Sun B, Cheng W, Goswami P, et al. Short-term traffic forecasting using self-adjusting  $k$ -nearest neighbours[J]. IET Intelligent Transport Systems, 2018, 12(1): 41-48.
- [4] Zhang L Z, Alharbe N R, Luo G, et al. A hybrid forecasting framework based on support vector regression with a modified genetic algorithm and a random forest for traffic flow prediction[J]. Tsinghua Science and Technology, 2018, 23(4): 479-492.
- [5] Chen D W. Research on traffic flow prediction in the big data environment based on the improved RBF neural network[J]. IEEE Transactions on Industrial Informatics, 2017, 13(4): 2000-2008.
- [6] Bengio Y, LeCun Y. Scaling learning algorithms towards AI[M]. Large-Scale Kernel Machines. Cambridge: MIT Press, 2007: 321-359.
- [7] 陈如清, 李嘉春, 俞金寿. 基于FWADE-ELM的短时交通流预测方法[J]. 控制与决策, 2021, 36(4): 925-932. (Chen R Q, Li J C, Yu J S. Short-term traffic flow forecasting based on hybrid FWADE-ELM[J]. Control and Decision, 2021, 36(4): 925-932.)
- [8] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [9] Huang W H, Song G J, Hong H K, et al. Deep architecture for traffic flow prediction: Deep belief networks with multitask learning[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(5): 2191-2201.
- [10] Zhou T, Han G Q, Xu X M, et al.  $\delta$ -agree

- AdaBoost stacked autoencoder for short-term traffic flow forecasting[J]. *Neurocomputing*, 2017, 247: 31-38.
- [11] Zhao Z, Chen W H, Wu X M, et al. LSTM network: A deep learning approach for short-term traffic forecast[J]. *IET Intelligent Transport Systems*, 2017, 11(2): 68-75.
- [12] Guo S N, Lin Y F, Li S J, et al. Deep spatial-temporal 3D convolutional neural networks for traffic data forecasting[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 20(10): 3913-3926.
- [13] Wu Y K, Tan H C, Qin L Q, et al. A hybrid deep learning based traffic flow prediction method and its understanding[J]. *Transportation Research Part C: Emerging Technologies*, 2018, 90: 166-180.
- [14] 安珊, 林树宽, 乔建忠, 等. 基于生成对抗网络学习被遮挡特征的目标检测方法[J]. *控制与决策*, 2021, 36(5): 1199-1205.  
(An S, Lin S K, Qiao J Z, et al. Object detection via learning occluded features based on generative adversarial networks[J]. *Control and Decision*, 2021, 36(5): 1199-1205.)
- [15] Zhang Y, Wang S, Chen B, et al. GCGAN: Generative adversarial nets with graph CNN for network-scale traffic prediction[C]. *Proceedings of the International Joint Conference on Neural Networks (IJCNN)*. New York: IEEE, 2019: 1-8.
- [16] Lin Y L, Dai X Y, Li L, et al. Pattern sensitive prediction of traffic flow based on generative adversarial framework[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 20(6): 2395-2400.
- [17] Arjovsky M, Bottou L. Towards principled methods for training generative adversarial networks[C]. *Proceedings of the International Conference on Learning Representations*. Toulon: ICLR, 2017: 1-17.
- [18] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[C]. *Proceedings of the 27th International Conference on Neural Information Processing Systems*. Lake Tahoe: ACM, 2014: 2672-2680.
- [19] Arjovsky M, Chintala S, Bottou L. Wasserstein generative adversarial networks[C]. *Proceedings of the 34th International Conference on Machine Learning*. Lake Tahoe: ACM, 2017: 214-223.
- [20] Gulrajani I, Ahmed F, Arjovsky M, et al. Improved training of wasserstein gans[C]. *Proceedings of the 30th International Conference on Neural Information Processing Systems*. Lake Tahoe: ACM, 2017: 5767-5777.
- [21] Mirza M, Osindero S. Conditional generative adversarial nets[J]. 2014, arXiv: 1411.1784.
- [22] 赵海霞, 石洪波, 武建, 等. 基于条件生成对抗网络的不平衡学习研究[J]. *控制与决策*, 2021, 36(3): 619-628.  
(Zhao H X, Shi H B, Wu J, et al. Research on imbalanced learning based on conditional generative adversarial networks[J]. *Control and Decision*, 2021, 36(3): 619-628.)
- [23] He K M, Zhang X Y, Ren S, et al. Deep residual learning for image recognition[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. New York: IEEE, 2016: 770-778.
- [24] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation[C]. *Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*. Berlin: Springer, 2015: 234-241.
- [25] Zhang J, Zheng Y, Qi D. Deep spatio-temporal residual networks for citywide crowd flows prediction[C]. *Proceedings of the 31st AAAI Conference on Artificial Intelligence*. San Francisco: AAAI, 2016: 1655-1661.
- [26] Shi X J, Chen Z R, Wang H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting[C]. *Proceedings of the 28th International Conference on Neural Information Processing Systems*. Lake Tahoe: ACM, 2015: 802-810.
- [27] Pathak D, Krahenbuhl P, Donahue J, et al. Context encoders: Feature learning by inpainting[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. New York: IEEE, 2016: 2536-2544.
- [28] Highways England: Highways agency network journey time and traffic flow data[EB/OL]. (2017-09-01)[2020-02-01]. <https://data.gov.uk/dataset/dft-eng-srn-routes-journey-times/>.

## 作者简介

代亮(1981—), 男, 副教授, 博士, 从事车联网理论与应用、交通数据处理与分析等研究, E-mail: ldai@chd.edu.cn;

梅洋(1992—), 男, 硕士生, 从事交通数据处理与分析的研究, E-mail: itsmeiyang@outlook.com;

钱超(1984—), 男, 副教授, 博士, 从事交通管理与控制、交通数据处理与挖掘技术等研究, E-mail: qianchao@chd.edu.cn;

孟芸(1987—), 女, 副教授, 博士, 从事智能交通系统、无线通信系统等研究, E-mail: mengyun@chd.edu.cn;

汪贵平(1963—), 男, 教授, 博士, 从事智能交通系统、智能测控技术和嵌入式系统等研究, E-mail: gpwang@chd.edu.cn.

(责任编辑: 齐 霖)