doi:10.3772/j.issn.1002-0470.2021.09.004

数据缺失下的短时交通流预测^①

徐东伟②*** 彭 鹏** 何德峰**

(*浙江工业大学网络空间安全研究院 杭州 310023)
 (**浙江工业大学信息工程学院 杭州 310023)

摘 要 在实际交通数据收集过程中,采集设备故障、维修等问题均易导致采集到的交通 数据存在一定的缺失。针对交通数据缺失情况下的交通流预测问题,本文提出了一种基 于生成式对抗网络的短时交通流预测模型。该模型由生成网络和判别网络两部分组成。 其中,生成网络由全连接层和门控循环单元(GRU)构成,以编码-解码的形式完成对未来 交通状态的预测输出;判别网络由多层全连接层构成,通过 Wasserstein 距离的计算完成 对真假样本的有效判断。实验结果表明,本文提出的模型不仅适用于不同比例数据缺失 下的短时交通流预测,而且其预测表现优于其他对比模型。

关键词 生成对抗网络(GAN);门控循环单元(GRU);交通数据缺失;短时交通流预测

0 引言

随着城市交通出行需求的不断增长,快速而有效的未来交通状态评估对于缓解交通拥堵、提高交通路网运行效率等具有着重要意义。短时交通流预测作为一种有效的未来交通状态评估方法,其预测结果不仅能够帮助人们规划更为合理的出行路线,还可以帮助交通管理部门制定更为科学的交通治理 方案和采取更为有效的交通管控手段。

为了实现实时、准确的短时交通流预测,国内外研究学者们提出了大量的交通流预测方法和模型。这些预测模型通常可以分为参数模型和非参数模型。常见的参数模型有自回归差分移动平均模型^[1]、卡尔曼滤波模型^[2]、隐马尔可夫模型^[3]等。相比于参数模型,非参数模型没有固定模型参数和固定模型结构的约束,因此有着更优秀的数据学习能力和表达能力。常见的非参数模型有支持向量机(support vector machine, SVM)模型^[4]、K最近邻(k-nearest neighbor,KNN)模型^[5]、决策树模型^[6]、神经网络模型^[79]、深度学习模型^[10]等。

相比于其他模型,深度学习模型不仅有着灵活 的模型设计,还有着强大的海量数据深层特征学习 能力。因此,越来越多的深度学习模型被提出并用 于解决短时交通流预测问题。文献[11]基于深度 信念网络(deep belief networks, DBN)实现了交通流 的多种任务预测。文献[12]构建堆栈自编码 (stacked auto encoder, SAE)模型,实现了大数据下 的短期交通流预测。文献[13]提出了一种基于长 短期记忆神经网络(long short-term memory, LSTM) 的短期交通流预测模型。文献[14]提出了一种基 于卷积神经网络 (convolutional neural network, CNN)的短期交通流预测模型。文献[15]提出了一 种基于图卷积网络(graph convolutional network, GCN)的交通流预测模型。文献[16]使用时空注意 力神经网络完成了短时交通流的预测。除此之外, 人们还提出了一些组合模型来进一步提高交通流的 预测精度。文献[17]将一维卷积与 LSTM 相结合, 提出了基于卷积-长短期记忆神经网络(convolutional LSTM, Conv-LSTM)的短期交通流预测模型。文 献[18]提出了一种 CNN 与支持向量回归(support

① 国家自然科学基金(61903334)和浙江省自然科学基金(LQ16E080011)资助项目。

② 男,1985年生,博士,讲师;研究方向:智能交通系统;联系人,E-mail: dongweixu@zjut.edu.cn (收稿日期:2020-05-15)

vector regression, SVR)相组合的交通流预测模型。 文献[19]将 CNN 与 LSTM 相组合,进一步提高了 LSTM 的短时交通流预测精度。

随着人们的不断研究,交通流预测模型的预测 精度相比过去已经有了较大的提高,但是这些模型 是以完整交通流数据为研究前提的。在实际生产生 活中,检测器故障、服务器检修等现象均可导致不等 程度的交通数据缺失问题。针对上述问题,主要采 用的解决方法为先数据修复然后再预测,但是该方 法相比于直接预测而言过程较为复杂且数据修复的 质量将直接影响模型的预测精度。

生成式对抗网络(generative adversarial network, GAN)作为一种新型的生成式深度学习模型,其通 过数据分布学习与博弈机制即可生成图片^[20]、对话 文本^[21]等内容,具有强大的数据生成能力。为此, 本文采用 GAN 主体框架,以缺失交通流数据作为输 入,借助全连接层、门控循环单元(gated recurrent unit, GRU)层的数据生成能力与多层全连接层的判 别能力,实现数据缺失下短时交通流的直接预测。

1 GAN

1.1 原始 GAN

2014年,文献[22]提出了一种基于博弈思想的 生成式模型,即生成式对抗网络 GAN。该模型为日 后各种 GAN 的变体模型的提出奠定了深厚的基础, 因此人们也将该模型称之为原始 GAN。GAN 作为 一种新型的深度学习模型,其主要由生成网络 G 和 判别网络 D 两部分组成。GAN 的模型框架结构如 图 1 所示。



图 1 GAN 模型框架结构图

在 GAN 中,生成网络主要负责数据的生成,而 判别网络 D 则主要负责生成数据 x' 与真实数据 x 间的区分。当噪声样本 z 输入到 GAN 中时,首先生 成网络 G 基于噪声 z 输出生成数据 x', 然后将生成 数据 x' 与真实数据 x 输入判别网络 D 进行真假数 据的判别。

为了保证 GAN 生成数据的质量, GAN 的模型 损失函数在生成网络 *G* 与判别网络 *D* 的博弈训练 过程中对两者均进行了考虑。生成网络损失函数 *L_g*、判别网络损失函数 *L_p* 计算方式分别如下:

 $L_{G} = \min \mathbf{E}_{z \sim p_{z}(z)} \left[\log(1 - D(G(z))) \right]$ (1)

 $L_D = \max \mathbf{E}_{x \sim p_{data}(x)} \left[\log D(x) \right]$

+ $\mathbf{E}_{z \sim p_{z}(z)} \left[\log(1 - D(G(z))) \right]$ (2)

其中,z为随机噪声,x为真实数据。当两个网络达 到纳什平衡时,则 GAN 模型训练完成。

虽然原始 GAN 早期在图像生成领域展现了出 色的表现,但是依旧存在训练过程中纳什平衡难以 维持、无法准确反映模型训练程度、模型生成的数据 样本单一等问题。为了有效解决原始 GAN 的上述 问题,人们对 GAN 的结构、损失函数等进行了改进, 提出了一系列的 GAN 的变体模型。

1.2 WGAN

针对原始 GAN 存在的问题,文献[23]对原始 GAN 进行改进,提出了 Wasserstein GAN(WGAN)。 相比与原始 GAN,WGAN 的改变主要包含以下几个 方面。

首先,在真假数据相似度衡量上,WGAN 采用 Wasserstein 距离代替了 GAN 中原有的 JS 散度或 KL 散度。Wasserstein 距离计算方式如下:

$$W(P_{r}, P_{g}) = \inf_{\gamma \sim \Pi(P_{r}, P_{g})} E_{(x, x') \sim \gamma} || x - x' ||$$
(3)

其中, $\Pi(P_r, P_g)$ 为 P_r 和 P_g 的联合分布的集合。 相比 JS 散度或 KL 散度, Wasserstein 距离在数据样 本分布无重叠时依旧可以通过计算来反映两个数据 分布之间的有效距离。

其次,在网络结构上,WGAN 将 GAN 中判别网 络中输出层的激活函数 sigmoid 进行了删除,使得判 别网络可以直接根据 Wasserstein 距离计算衡量数 据分布间的相似度,并有效避免了 sigmoid 函数潜在 的梯度消失问题。

最后,在模型训练上, WGAN 在模型损失函数 — 935 —

计算时不再进行 log 计算,在判别网络参数更新过 程添加了权重裁剪,并推荐使用 RMSProp 优化器进 行模型参数的求解。根据 WGAN 的改变,WGAN 生 成网络损失函数 L_c、判别网络损失函数 L_p 的计算 方式分别如下:

$$L_{G} = \min - D(G(z))$$
(4)

$$L_D = \min D(G(z)) - D(x)$$
(5)

基于上述改进, WGAN 不仅有效解决了 GAN 在训练过程中存在的不稳定问题, 明确了一个合理 的数值去反映 GAN 的训练进程, 还基本解决了 GAN 的模式单一问题, 提高了生成数据的多样性。

2 模型设计

2.1 模型结构设计

GAN 及其变体在图像、文本、视频等诸多领域 的成功不仅证明了其强大的数据生成能力,还说明 其具有一定的普适性。基于以上特性,针对数据缺 失下的短时交通流预测问题,本文提出了一种基于 Wasserstein 生成式对抗网络的短时交通流预测模 型。该模型的框架结构如图2所示。



图 2 本文预测模型框架结构图

模型主要由生成网络 *G* 和判别网络 *D* 两部分 共同构成,其输入为数据缺失的交通流时空矩阵 *x*, 输出为修复后的交通流时刻矩阵 *x'* 和预测的交通 流量数据 *y'*。假设第 *m* 条路段在第 *t* 时刻的真实交 通流数据为 x_{mt} , 修复后的交通流数据为 x'_{mt} , 第 *m* 条路段在第 t + p 时刻的交通流预测值为 x''_{mt+p} , 那 么 *x*, *x'* 和 *y'* 分别表示如下:

$$\mathbf{x} = \begin{bmatrix} x_{11} & x_{21} & \cdots & x_{m1} \\ x_{12} & x_{22} & \cdots & x_{m2} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ x_{1t} & x_{2t} & \cdots & x_{mt} \end{bmatrix}$$
(6)
$$\mathbf{x}' = \begin{bmatrix} x'_{11} & x'_{21} & \cdots & x'_{m1} \\ x'_{12} & x'_{22} & \cdots & x'_{m2} \\ \vdots & \vdots & \vdots & \vdots \\ x'_{1t} & x'_{2t} & \cdots & x'_{mt} \end{bmatrix}$$
(7)

$$\mathbf{y}' = \begin{bmatrix} x''_{1t+1} & x''_{2t+1} & \cdots & x''_{mt+1} \\ x''_{1t+2} & x''_{2t+2} & \cdots & x''_{mt+2} \\ \cdots & \cdots & \cdots \\ x''_{1t+p} & x''_{2t+p} & \cdots & x''_{mt+p} \end{bmatrix}$$
(8)

其中,m 表示路段的数量,t 表示交通流历史数据窗口的大小,p 表示交通流预测的窗口大小。

在该模型中,生成网络 *G* 主要由输入层、全连 接层、GRU 层和输出层构成,其具体结构设计如图 3 所示。其中,输入层、输出层分别负责接收历史交通 流数据和输出交通流预测结果,全连接层 1 负责交 通流数据的编码,GRU 层负责交通流编码结果的特 征提取,全连接层 2 负责 GRU 层特征提取结果下的 解码。假设第 *t* 时刻的交通流数据集合为 $x_t = \{x_{1t}, x_{2t}, \dots, x_{mt}\}$,那么生成网络 *G* 计算过程的数 学表达式如下:

$$e_t = W_e x_t + b_t \tag{9}$$

$$r_{\iota} = \sigma(W_r \cdot [h_{\iota-1}, e_{\iota}])$$
(10)

$$z_{t} = \sigma(W_{z} \cdot [h_{t-1}, e_{t}])$$
(11)

$$\tilde{h}_{t} = g(W_{\tilde{h}} \cdot [r_{t} * h_{t-1}, e_{t}])$$
(12)

$$h_{t} = (1 - z_{t}) * h_{t-1} + z_{t} * h_{t}$$
(13)

 $\boldsymbol{x}' = \boldsymbol{W}_{x'}\boldsymbol{h}_t + \boldsymbol{b}_{x'}$

$$\mathbf{y}' = W_{\mathbf{y}}h_{\mathbf{t}} + b_{\mathbf{y}} \tag{(}$$

其中, · 表示矩阵乘法运算, []表示向量相连操作, *表示矩阵的点乘运算, e_i 表示全连接层1编码输 出, r_i 、 z_i 、 h_i 和 \tilde{h}_i 分别表示 GRU 层中重置门、更新 门、隐藏层和候选隐藏层的输出。



相比于生成网络 G, 判别网络 D 主要负责生成 交通流数据与真实交通流数据的区分,其主要由多 层全连接层构建而成。判别网络 D 的结构设计如 图 4 所示。其中, d 和 d'分别表示在真实交通流数 据和生成数据下判别网络 D 的判别输出。



2.2 模型损失函数设计

本文模型的损失函数设计主要包含生成网络和 判别网络两部分。生成网络损失函数主要用于保证 生成网络输出的交通流预测数据与真实的交通流数 据在数据分布上尽可能地相似,而判别网络损失函 数则主要用于保证生成数据与真实交通流数据的有 效区分。

(14)

15)

生成网络损失函数主要由基本生成损失函数、 预测损失函数和数据修复损失函数3部分组成。基 本生成损失函数主要用于促使生成网络尽可能地生 成判别网络无法区分真假的数据样本。而预测损失 函数可以在一定程度上保证生成的交通流数据的预 测质量。此外,在一定程度上,对于数据修复损失函 数的考虑可以进一步提高模型的预测性能。因此, 生成网络损失函数表示如下:

$$L_{G} = \min - D(y') + (y' - y)^{2} + (x' - \tilde{x})^{2}$$
(16)

其中, \mathbf{x}' 表示修复后的交通流时刻矩阵, \mathbf{x} 表示完整的交通流时刻矩阵, y 表示交通流数据的真实值, \mathbf{y}' 表示交通流数据的预测值, $-D(\mathbf{y}')$ 为基本生成损失函数, $(\mathbf{y}' - \mathbf{y})^2$ 为预测损失函数, $(\mathbf{x}' - \mathbf{x})$ 为修复损失函数。

判别网络损失函数主要是对数据相似度的衡量,其表示如下:

$$L_D = \min D(\mathbf{y}') - D(\mathbf{y}) \tag{17}$$

3 实验过程及结果分析

3.1 实验数据

本文的实验数据来自美国加州交通运输性能测 量系统。该系统包含了全加州高速公路中部署的 15 000 多个交通检测器的数据,这些数据包括交通 流量、速度、饱和度等重要交通参数。本文选取了其 中4 个检测器 2016 年4 月 1 日至4 月 30 日工作日 的交通流量数据作为实验数据,数据采样时间间隔 为5 min。其中,前 80% 的实验数据作为模型的训 练集,剩余的实验数据作为模型的测试集。

3.2 数据预处理

为了减少实验数据的实际量纲对模型训练速度 和预测性能的影响,本文对实验数据进行了标准化 处理,将数据量纲控制在[0,1]之间。本文采用的 数据标准化计算方式如下:

$$x^{*} = \frac{x - \min(x)}{\max(x) - \min(x)}$$
(18)

其中,*x* 表示原始数据, *x*^{*} 表示标准化的数据, min(*x*) 与 max(*x*) 分别表示原始数据中的最小值 — 937 —

和最大值。

本文原始实验数据为完整的交通流量数据。为 了有效模拟交通流数据不同程度的缺失,本文对原 始实验数据进行了随机的数据缺失处理。数据缺失 处理过程如图5所示。



首先根据各检测器历史交通流数据构建完整时 空矩阵 x_c ,然后构建与交通流时空矩阵大小相同的 掩码矩阵m,最后将 x_c 与m进行点乘运算,从而生 成数据缺失下的交通流时空矩阵 x_o 其中,掩码矩 阵m中的0表示数据缺失,1表示数据完整,0与1 的分布比例由实际的数据缺失率决定。为保证更好 地模拟数据缺失过程,数据缺失处理过程中的数据 损失率集合设定为 $\{0.2, 0.4, 0.6, 0.8\}$,且构建的 m均为随机生成。

3.3 模型参数

本文涉及的模型参数主要分为生成网络、判别 网络、模型训练这3部分。在生成网络部分,全连接 层1、GRU层、全连接层2的神经元个数分别设置为 64、32、4。在判别网络部分,采用4层全连接层,其 每层神经元个数分别设置为32、16、8、1。在模型训 练部分,生成网络与判别网络均采用 RMSProp 优化 器进行训练,学习率设置为0.00001,批次大小为 128,单次迭代下判别网络训练次数设置为5,判别 网络的权重裁剪范围设置为[-0.01,0.01]。此 外,本文的交通流历史数据窗口大小t设置为12,交 通流预测窗口大小p即预测步长设置为1。

3.4 性能评价指标

为了更为有效地评估预测结果,本文选取了均 方根误差(RMSE)、绝对平均误差(MAE)和平均绝 对百分比误差(MAPE)这3个性能指标来衡量模型 的预测表现。其计算方式分别如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (\tilde{y}_i - y_i)^2}$$
(19)
- 938 —

$$MAE = \frac{1}{n} \sum_{i=1}^{n} |\tilde{y}_i - y_i|$$
 (20)

$$MAPE = \frac{1}{n} \sum_{i=1}^{n} \left| \frac{\tilde{y}_i - y_i}{y_i} \right|$$
(21)

其中, y_i 表示交通流量的真实值, \tilde{y}_i 表示交通流量数据的预测值。

3.5 实验结果与分析

为有效了解和分析所提模型的交通流预测表现,本文首先对数据缺失率为0.2 情况下的模型预测结果进行分析。

以4月27日为例,提出模型的各路段预测结果 如图6所示。从预测整体结果来看,所提模型具有 较好的预测性能,其不仅可以有效捕捉交通流的变 化趋势,还能够较好地贴合交通流数据的真实值。 此外,相比于高峰期的交通流预测而言,该模型在非 高峰期的交通流预测有着更大的优势和精准度。

为了进一步验证提出模型的预测性能,本文还 对模型在其余数据缺失率情况下的交通流预测进行 了实验,并将提出模型的预测表现与 KNN、SVR、反 向传播神经网络(back propagation, BP)、LSTM、 GRU、SAE、Conv-LSTM 进行了对比。各模型在不同 数据缺失情况下的预测结果性能指标分析如表1~ 表3所示。

从表1~表3中可知,在不同程度的数据缺失 下,本文提出的模型预测性能均高于其他对比模型。 在数据缺失率为 0.2 时,本文模型在 RMSE、MAE、 MAPE 上分别改善了 11.95% ~40.08%、12.07% ~ 43.55% 和 13.53% ~ 39.26%; 在数据缺失率为 0.4 时,本文模型在 RMSE、MAE、MAPE 上分别改善了 9.28%~52.85%、9.87%~58.31%和10.60%~ 48.12%;在数据缺失率为0.6时,本文模型在RMSE、 MAE、MAPE 上分别改善了 11. 12% ~ 63. 31%、 11.93%~68.20%和11.01%~56.75%;在数据缺 失率为0.8 时,本文模型在 RMSE、MAE、MAPE 上 分别改善了 4.74% ~ 64.35% 、5.67% ~ 69.18% 和 7.80%~54.19%。在对比模型中, KNN 预测表现 最差.SVR 的非线性空间映射使其预测表现要优于 BP和 SAE, LSTM和 GRU 因其优秀的时间特征处理 能力而有着较好的预测表现,而 Conv-LSTM 对交通 数据时空特征的有效处理使其预测表现要远优于其



他对比模型。

表1 各模型 RMSE 性能指标分析

| 模型 | 数据缺失率 | | | |
|-----------|-------|-------|-------|--------|
| | 0.2 | 0.4 | 0.6 | 0.8 |
| KNN | 51.27 | 73.11 | 98.85 | 124.00 |
| SVR | 41.97 | 45.32 | 47.10 | 48.90 |
| BP | 44.08 | 47.05 | 47.69 | 49.10 |
| LSTM | 41.50 | 43.41 | 46.69 | 48.30 |
| GRU | 36.57 | 41.13 | 45.10 | 48.40 |
| SAE | 43.36 | 46.29 | 46.95 | 49.00 |
| Conv-LSTM | 34.89 | 38.00 | 40.8 | 46.40 |
| 本文模型 | 30.72 | 34.47 | 36.26 | 44.20 |

表 2 各模型 MAE 性能指标分析

| 模型 | 数据缺失率 | | | |
|-----------|-------|-------|-------|--------|
| | 0.2 | 0.4 | 0.6 | 0.8 |
| KNN | 40.11 | 60.19 | 84.26 | 107.30 |
| SVR | 31.81 | 34.76 | 36.23 | 37.61 |
| BP | 33.22 | 35.76 | 36.46 | 37.55 |
| LSTM | 30.79 | 32.81 | 35.31 | 36.89 |
| GRU | 27.05 | 30.65 | 34.03 | 37.08 |
| SAE | 32.70 | 35.26 | 35.76 | 37.26 |
| Conv-LSTM | 25.75 | 27.84 | 30.42 | 35.06 |
| 本文模型 | 22.64 | 25.09 | 26.79 | 33.07 |

表 3 各模型 MAPE(%)性能指标分析

| 模型 - | 数据缺失率 | | | |
|-----------|-------|-------|-------|-------|
| | 0.2 | 0.4 | 0.6 | 0.8 |
| KNN | 19.15 | 25.52 | 33.46 | 41.52 |
| SVR | 19.07 | 21.11 | 22.48 | 24.17 |
| BP | 16.94 | 19.51 | 20.88 | 22.14 |
| LSTM | 16.16 | 17.78 | 19.47 | 20.58 |
| GRU | 14.14 | 16.56 | 18.86 | 21.70 |
| SAE | 17.67 | 19.94 | 20.66 | 21.25 |
| Conv-LSTM | 13.45 | 14.81 | 16.26 | 20.63 |
| 本文模型 | 11.63 | 13.24 | 14.47 | 19.02 |

此外,为探究数据修复函数对于本文模型的预 测表现影响,本文对不含数据修复损失函数的预测 模型进行了实验分析,其分析结果如表4所示。

将有无数据修复损失函数的模型预测性能进行 对比,可以发现本文模型在缺乏对数据修复损失函 数考虑后,其预测性能出现了一定的下降。因此,在 本文模型损失函数设计过程中对数据修复损失函数 进行考虑并使用具有一定的合理性。虽然本文模型 的预测性能在不考虑数据修复损失函数时会出现一

— 939 —

定的下降,但是依旧要优于其他对比预测模型。

表 4 无数据修复损失函数下的模型预测结果分析

| 从他长行 | 数据缺失率 | | | |
|-----------|--------|--------|--------|--------|
| 111月11月1小 | 0.2 | 0.4 | 0.6 | 0.8 |
| RMSE | 31.74 | 34.61 | 39.56 | 45.4 |
| MAE | 23.64 | 25.15 | 29.06 | 34.94 |
| MAPE | 12.86% | 13.57% | 15.94% | 20.35% |

4 结论

本文旨在解决数据缺失下的短时交通预测问 题,以实现交通数据缺失下更直接、更精准的短时交 通流预测。为实现这一目标,本文基于生成式对抗 网络提出了一种以缺失数据为输入、未来交通流状 态为输出的端到端的预测模型。在模型生成网络部 分,本文利用全连接层和 GRU 层实现缺失数据中重 要特征的提取和预测结果的输出;在模型判别网络 部分,本文采用多层全连接层完成对生成数据与真 实数据的区分。在模型损失函数设计上,本文对 WGAN 损失函数进行了改进,在其基础上添加了数 据修复损失函数。实验结果表明,本文提出的模型 在不同的数据缺失下均有着较好的预测表现且预测 性能也均优于其他对比模型。此外,本文通过有无 数据修复损失函数下的模型预测表现对比,验证了 模型损失函数改进的可行性和有效性。本文以高速 路为实验对象,其网络结构复杂度相对较低,在未来 的研究中可以对更为复杂的城市道路的短时交通流 预测进行研究。

参考文献

- [1] Kumar S V, Vanajakshi L. Short-term traffic flow prediction using seasonal ARIMA model with limited input data
 [J]. European Transport Research Review, 2015, 7(3):
 1-9
- [2] 钱伟,杨慧慧,孙玉娟.相空间重构的卡尔曼滤波交通流预测研究[J].计算机工程与应用,2016(14): 37-41
- [3] Qi Y, Ishak S. A hidden Markov model for short term prediction of traffic conditions on freeways[J]. Transportation Research Part C: Emerging Technologies, 2014,

43:95-111

- [4] 康军,段宗涛,唐蕾,等.一种LS-SVM 在线式短时交通流预测方法[J].计算机应用研究,2018,35(10):91-94
- [5] Xu D W, Wang Y D, Peng P, et al. Real-time road traffic state prediction based on kernel-KNN[J]. Transportmetrica A: Transport Science, 2020, 16(1): 104-118
- [6] 薛红军,陈广交,李鑫民,等.基于决策树理论的交 通流参数短时预测[J].交通信息与安全,2016,34
 (3):64-71
- [7] Zhu J Z, Cao J X, Zhu Y. Traffic volume forecasting based on radial basis function neural network with the consideration of traffic flows at the adjacent intersections
 [J]. Transportation Research Part C: Emerging Technologies, 2014, 47: 139-154
- [8] 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
- [9] Tang J J, Liu F, Zou Y J, et al. An improved fuzzy neural network for traffic speed prediction considering periodic characteristic [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 18(9): 2340-2350
- [10] Lecun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553): 436-444
- [11] 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
- [12] Lv Y S, Duan Y J, Kang W W, et al. Traffic flow prediction with big data: a deep learning approach [J].
 IEEE Transactions on Intelligent Transportation Systems, 2014, 16(2): 865-873
- [13] Zhao Z, Chen W H, Wu X X, et al. LSTM network: a deep learning approach for short-term traffic forecast[J]. IET Intelligent Transport Systems, 2017, 11(2): 68-75
- [14] Zhang W B, Yu Y H, Qi Y, et al. Short-term traffic flow prediction based on spatio-temporal analysis and CNN deep learning[J]. Transportmetrica A: Transport Science, 2019, 15(2): 1688-1711
- [15] Yu B, Lee Y J, Sohn K. Forecasting road traffic speeds by considering area-wide spatio-temporal dependencies based on a graph convolutional neural network (GCN)

— 940 —

[J]. Transportation Research Part C: Emerging Technologies, 2020, 114: 189-204

- [16] Do L N N, Vu H L, Vo B Q, et al. An effective spatialtemporal attention based neural network for traffic flow prediction [J]. Transportation Research Part C: Emerging Technologies, 2019, 108: 12-28
- [17] Liu Y P, Zheng H F, Feng X X, et al. Short-term traffic flow prediction with Conv-LSTM[C] // Proceedings of the 9th International Conference on Wireless Communications and Signal Processing, Nanjing, China, 2017: 1-6
- [18] 罗文慧, 董宝田, 王泽胜. 基于 CNN-SVR 混合深度学 习模型的短时交通流预测[J]. 交通运输系统工程与 信息, 2017, 17(5): 68-74
- [19] Duan Z T, Yang Y, Zhang K, et al. Improved deep hybrid networks for urban traffic flow prediction using trajec-

tory data[J]. IEEE Access, 2018, 6: 31820-31827

- [20] Parimala K, Channappayya S. Quality Aware Generative Adversarial Networks[C] // Proceedings of the 32th International Conference on Neural Information Processing Systems, Montreal, Canada, 2019: 2944-2954
- [21] Zhang Y Z, Gan Z, Fan K, et al. Adversarial feature matching for text generation [C] // Proceedings of the 34th International Conference on Machine Learning, Sydney, Australia, 2017: 4006-4015
- [22] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets [C] // Proceedings of the 27th International Conference onNeural Information Processing Systems, Montreal, Canada, 2014: 2672-2680
- [23] Arjovsky M, Chintala S, Bottou L. Wasserstein gan[EB/ OL]. https://arxiv.org: Cornell University, 2017

Short-term traffic flow prediction with missing data

Xu Dongwei****, Peng Peng**, He Defeng**

(* Institute of Cyberspace Security, Zhejiang University of Technology, Hangzhou 310023)

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

Abstract

In the process of actual traffic data collection, problems such as equipment failure and maintenance are likely to cause traffic data missing. Aiming at the problem of traffic flow prediction with missing data, a short-term traffic flow prediction model based on generative adversarial networks is proposed. The model is composed of two parts: generating network and discriminating network. The generation network is composed of the fully connected layer and the gated recurrent unit (GRU), which completes the prediction output of the future traffic flow in the form of encoding-decoding; the discriminant network is composed of multiple fully connected layers, which discriminates the real traffic data and fake data by the compute of Wasserstein distance. The experimental results show that the proposed model is not only suitable for short-term traffic flow prediction with different proportions of data missing, but also has a better prediction performance than other comparative models.

Key words: generative adversarial network (GAN), gated recurrent unit (GRU), traffic data missing, short-term traffic flow prediction