

文章编号:1671-8879(2018)05-0139-07

高速公路突发事件恢复重建期交通量预测

赵 朋,王建伟,孙茂棚,周雅欣

(长安大学 经济与管理学院 陕西 西安 710064)

摘 要:为了提升高速公路突发事件应急管理能力,为突发事件恢复与重建施工及路网拥堵状况预判提供依据,提出一种高速公路突发事件恢复重建期路网交通量预测方法,利用扩散卷积和序列到序列学习框架模型,结合预定采样技术捕捉时间序列时空相关性,以高速公路联网收费数据为基础,建立路网交通量分配模型,实现对交通量时间精度下的分配;利用扩散卷积递归神经网络(DCRNN)构建高速公路路网交通量预测模型,运用扩散卷积运算来捕捉交通量的空间相关性,并使用预定采样编码器-解码器结构有效解决交通量的时间依赖问题,模型将交通的空间性建模为有向图上的扩散过程,而不是传统的网格划分;并选取自回归滑动平均模型(ARIMA)模型和机器学习 BP 神经网络模型对模型的准确性及有效性进行了验证。研究结果表明:将河北省石家庄高速公路路网发生突发事件后 15 d 交通量数据做训练集,后 7 d 数据进行验证,迭代 60 次时,测算每 15 min 间隔内的路网交通量的模型精度达到 0.95。提出的模型预测的平均绝对误差(MAE)和平均绝对百分比误差(MAPE)更低,能够有效弥补单一化神经网络预测模型仅能做出时序性预测的不足,可显著提高预测结果的精确性和实用性。

关键词:交通工程;高速公路;突发事件;DCRNN 模型;恢复重建期

中图分类号:U491.31

文献标志码:A

Traffic flow prediction of expressway traffic emergency recovery and reconstruction period

ZHAO Peng, WANG Jian-wei, SUN Mao-peng, ZHOU Ya-xin

(School of Economics and Management, Chang'an University, Xi'an 710064, Shaanxi, China)

Abstract: In order to improve the capacity of emergency management of expressway emergencies, provides references and help for emergency recovery and reconstruction or construction for prediction congestion. A method for predicting the traffic volume of an expressway road network during the recovery and reconstruction period after an expressway emergency was proposed, based on previous research results. Based on the diffusion convolution and a sequence-to-sequence learning framework, the proposed method captured the space-time correlation of a time series using a sampling technique. With this method, the distribution of the traffic volume time-accuracy was first realized by establishing a road network traffic volume distribution model based on highway network charging data, and the expressway road network traffic volume predictive model was then constructed using a diffusion convolution recurrent neural network (DCRNN).

收稿日期:2018-05-13

基金项目:国家自然科学基金项目(41301130)

作者简介:赵 朋(1966-),女,河北石家庄人,工学博士研究生,E-mail:18531100198@163.com。

The DCRNN model was used to capture the spatial correlation of the traffic volume, and effectively solved the time-dependent problem of the traffic volume by using the predetermined sampling encoder-decoder structure. The advantage of the model lies in modeling the spatial property of traffic as a directed graph diffusion process rather than as a traditional grid division, which clearly describes the randomness of the traffic dynamics. To verify the accuracy and validity of the model further, the widely used ARIMA model and the machine learning BP neural network model were selected to calculate and compare the same instance data. The results show that the first 15 days of data in the traffic volume after an emergency of a highway network in Hebei Province Shijiazhuang is used as the training set, and the data after 7 days is verified. When the number of iterations reached 60, the accuracy of the model that calculate the traffic volume per 15 minutes interval reached 0.95. The forecasting method has a lower mean absolute error (MAE) and mean absolute percentage error (MAPE), which can effectively compensate for the defects of the unitized neural network-forecasting model, which only creates a time series prediction. Therefore, the model has high accuracy and practicability. 4 tabs, 2 figs, 22 refs.

Key words: traffic engineering; expressway; emergency; DCRNN model; reconstruction

0 引 言

随着中国社会经济的发展,高速公路路网里程和密度的日益增加,安全出行已成为人们关注的热点话题,高速公路突发事件的应急处置是行业研究的重点。高速公路发生突发事件后,一方面需在有效时间内,尽快开展及时有效的应急处置和应急营救是应急管理的首要工作。与此同时,高速公路突发事件常伴随对公路基础设施的破坏^[1],导致部分基础设施尤其是道路不能正常使用,甚至要持续数月完成修复工作,重建过程中交通量的预测对于整个路网以及重建工作均具有重要意义,如何获得精确的交通量预测结果是高速公路交通安全应急管理领域的难题之一。

关于沿海受台风威胁地区高速公路受到天气影响导致突发事件状态下的处置研究较多^[2]。也有在智慧公路交通背景下,提出基于智能公路基础设施的应急疏散方案^[3];针对事故描述不完整,事故属性不清楚,计划匹配不准确等状况下的公路交通应急预案匹配问题^[4],突发事件需要对基础设施进行充分的脆弱性评价^[5]。Murray-Tuite 等综述了近 10 年来高速公路突发事件下的推演建模与仿真,指出突发事件后期处置跨学科的研究缺乏,如医疗研究等,使用新技术利用实时数据发布交通状况信息、补充数据收集,进一步优化模型改进和验证^[6],地震^[7]以及洪水^[8]等造成破坏后的配送中心位置选址,规划车辆救援路径和应急道路维修作业。

中国针对高速公路突发事件的应急处置的研究

起步较晚,王少飞等提出了长大公路隧道火灾事故专项应急预案的编制流程、核心要素和主要内容^[9],并将高速公路划分为不同交通控制区段和交通控制单元,在发生火灾事故时,遵循“先内后邻”、“由远及近”的原则实施联动控制^[10]。张海波等基于公共政策的视角,对应急预案体系进行了优化^[11]。在隧道突发事件处置研究方面:邓月生以岑梧高速公路的牛岭界隧道为例,对其消防设计中的建筑消防、安全疏散、灭火系统、通风排烟系统和火灾自动报警系统等 5 个方面进行了探讨^[12]。在救援效果评价方面,马兆等有构建了高速公路紧急事件危害风险的多级模糊评价模型,并结合事发时的特定环境,可以综合评价事件危害的风险等级^[13]。在交通流组织方面,高建平提出“点-层”辐射的多级响应、逐级控制应急救援模式,并建立突发事件协同应急救援模型^[14]。王少飞等从系统工程的角度提出了防火救灾对策,即按照“防灾→减灾→救灾”的思路展开,形成一个环环相扣的安全链^[15]。李巧如等根据高速公路应急疏散的特点,在交通分配中应用了改进蚁群算法模型,利用仿真试验验证了该算法不仅可以加快搜索速度,而且可以优化全局最优解,从而得到系统最优的可视化疏散路径^[16]。张富荣等提出环隧应急交通研究思路,给出环隧火灾的车辆疏散时间以及安全度判定^[17]。刘德海等以高速公路突发事件应急能力评价为研究对象,提出了基于最小偏差组合权重的评价模型^[18]。贾献卓基于微观交通仿真,对京港澳高速京石段彭家庄枢纽互通的 3 种施工组织方案进行评估,实现了施工组织的优化,避

免了改扩建施工期间带来交通拥堵,节省了施工经费,高效完成了改扩建交通组织的实施^[19]。方宪武开展了包括突发事件的事前预防措施、应急演练、应急响应等施工现场应急研究^[20]。

综上所述,针对高速公路突发事件的处置,在专项应急预案的编制流程、核心要素和主要内容,救援效果评价,交通流组织以及重点桥隧方面都进行了大量研究,但是针对破坏较大,后期需要较长时间进行恢复重建的研究较少。突发事件发生后由于道路破坏导致的部分道路封闭,通行道路交通量与破坏前差异显著并易造成拥堵,且由于事件的突然性,缺乏历史交通量数据参考,增加了通行道路的交通量预测难度,同时,因训练集时间较短,传统预测方法难以达到其精度要求^[21]。

本文在现有研究成果的基础上,提出基于神经网络扩散卷积递归神经网络(DCRNN)的预测方法,对高速公路突发事件恢复重建期的交通量进行预测,该模型的优势在于交通量突然增大且训练集较少的情况下,其依然能够兼顾时空特征,精准获取路网交通量特征,保证预测精度。

1 模型建立

1.1 问题描述

高速公路突发事件发生后,在最短的时间内,及时有效的应急处置和应急营救是应急管理的首要工作,随着势态发展,可能会引发二次事件并导致事件危害和影响扩大,表现形式主要有道路基础设施遭到破坏,车辆损坏造成交通阻塞,重大人员伤亡和财产损失等,随着应急救援工作的深入开展,突发事件得到控制,对高速公路系统的破坏力削弱,交通运行逐渐恢复正常。因此,交通突发事件发展态势先后经历了控制、减弱、影响消除与交通恢复的过程。交通突发事件控制和减弱阶段的主要任务是交通诱导、疏散、救援等,目前已经形成了成熟的研究体系。交通突发事件恢复阶段的主要任务是完成被破坏基础设施的修复工作,这一时期路网内的应急处置和营救工作已基本完成,但仍然需要持续数十天乃至数月的修复与重建,这一时期如能实现路网交通量的精准预测,可以为恢复与重建工作施工提供支持,同时也可以预判路网拥堵状况,提前采取相应的措施。

DCRNN将交通流动力学建模成一个扩散过程,用扩散卷积解释交通流的空间相关性^[22]。该模型利用扩散卷积和序列到序列学习框架,结合预定

采样技术来捕捉时间序列间时空相关性。模型将交通的空间性建模为有向图上的扩散过程,而不是传统的网格划分,明确表述了交通动力学的随机性。首先,将路网建立成一个加权有向图,建立的加权有向图能够更加真实的反映路网状况,在此基础上,利用双向图随机游走定义卷积,同时进一步将其与序列到序列的学习框架和预定抽样组合建模进行交通量预测。模型适用于交通量大且训练集时间较短的路网,符合高速公路突发事件后路网交通量的特征。

1.2 DCRNN 交通量预测模型

本文提出在构建完成的高速公路路网模型的基础上,设定采样间隔为15 min,然后计算每个采样间隔当前时刻高速公路路段交通量,该结果能够真实还原高速公路路网交通流状态,并根据路段实测数据,利用DCRNN模型对高速公路路网交通量进行预测。

1.2.1 路网

设 G 为共有 N 个节点的路网, $G=(V,E,W)$, V 为高速公路节点集合,本文通过高速公路收费站划分路段,节点即高速公路收费站; $V=\{v_1,v_2,\dots,v_i,v_{i+1},\dots,v_N\}$; E 为高速公路路段集合; W 为节点邻近度的加权邻接矩阵,即高速公路路网的距离函数。

W_{ij} 为 v_i,v_j 之间路段的权重值, $W \in R^{(N \times N)}$,路网 G 上的交通流 $X \in R^{(N \times P)}$ 。设 X^t 为 t 时刻的观测值, $h(\cdot)$ 表示高速公路路网交通量预测模型的学习公式,该公式映射历史图数据 T' 到未来的图数据 T ,预测过程可表示为

$$[X^{(t-T'+1)}, \dots, X^t; G] \xrightarrow{h(\cdot)} [X^{(t+1)}, \dots, X^{(t+T)}] \quad (1)$$

1.2.2 预测模型

DCRNN通过将交通流与扩散过程联系起来,建立空间依赖关系模型。该扩散过程的特点是 G 上具有重启概率 $\alpha \in [0,1]$ 的随机游走。扩散过程的平稳分布可表示为 G 上无限随机游动的加权组合,并以封闭形式计算

$$p = \sum_{k=0}^{+\infty} \alpha(1-\alpha)^k (D_0^{-1}W)^k \quad (2)$$

式中: p 为加权组合结果; k 为扩散步骤,在扩散过程中使用有限 K 阶截断,给每阶分配一个可训练的权重,在反向扩散过程中同理,使得可以同时捕捉上下游的影响; $D_0^{-1}W$ 为状态的转移矩阵, $D_0 = \text{diag}(W_1)$ 为出度对角线矩阵, $I \in R^N$ 代表第1个向量;模型收敛于平稳分布 $p \in R^{N \times N}$, $p_i \in R^N$ 为从节点 $v_i \in V$ 扩散的概率。

(1) 扩散卷积:

图 G 上交通流 $X \in R_i^{N \times P}$ 的扩散卷积以及滤波器 f_θ 的运算定义

$$X_{(i,p)} \dot{a}G f_\theta = \sum_{k=0}^{k-1} \theta_{k,1} (D_0^{-1} \mathbf{W})^k + \theta_{k,2} (D_1^{-1} \mathbf{W}^T)^k X_{i,p} \quad p \in \{1, 2, \dots, P\} \quad (3)$$

式中: $\dot{a}G$ 为定义的扩散卷积; $\theta \in R^{K \times 2}$ 为滤波器的参数; $(D_0^{-1} \mathbf{W})^k, (D_1^{-1} \mathbf{W}^T)^k$ 分别为扩散过程的转移矩阵和反向矩阵。

(2) 扩散卷积层

式(4)定义了扩散卷积的运算,这里建立一个将 p 维特征向量映射到 q 维输出的扩散卷积层, $\theta \in R^{Q \times P \times K \times 2} = [\theta]_{q,p}$ 为参数张量,其中 $\theta_{q,p,i,j} \in R^{K \times 2}$ 表示参数化第 p 个输入和第 q 个输出的卷积滤波器, $q \in \{1, 2, \dots, Q\}$ 。因此,扩散卷积层公式为

$$H_{i,q} = a \left(\sum_{p=1}^P X_{i,p} \dot{a}G f_{q,p,i,j} \right) \quad (4)$$

式中: $X \in R^{N \times P}$ 为输入; $H_{i,q} \in R^{N \times Q}$ 为输出; $\{f_{q,p,i,j}\}$ 为滤波器; a 为激励函数(如 ReLu, Sigmoid 函数)。

利用递归神经网络(RNN)的时间依赖性,本文采用变异的 RNN 门控递归单元(GRU)神经网络进行计算。用扩散卷积替换 GRU 的矩阵乘法,使用扩散卷积门控单元(DCGRU)如下

$$r^{(t)} = \sigma(\theta_r \dot{a}G(X^{(t)}, H^{(t-1)} + b_r)) \quad (5)$$

$$u^{(t)} = \sigma(\theta_u \dot{a}G(X^{(t)}, H^{(t-1)} + b_u)) \quad (6)$$

$$C^{(t)} = \tan(h(\theta_c \dot{a}G(X^{(t)}, (r^{(t)} \odot H^{(t-1)})) + b_c)) \quad (7)$$

$$H^{(t)} = u^{(t)} \odot H^{(t-1)} + (1 - u^{(t)}) \odot C^{(t)} \quad (8)$$

式中: $X^{(t)}, H^{(t)}$ 分别为 t 时刻的输入和输出; $C^{(t)}$ 为输出前的复位值; $r^{(t)}, u^{(t)}$ 分别为 t 时刻的复位门和更新门; $\theta_r, \theta_u, \theta_c$ 为相对应的滤波器参数; b_r, b_u, b_c 为常量。

DCGRU 可以建立递归神经网络层,通过时间的反向传播进行训练。

图 1 为时空交通量预测的扩散卷积递归神经网络的系统结构。图 1 中,每个基本单元并不是简单地时间序列,而是每个时刻都是一个有关空间的向量图,模型同时包含空间依赖和时间序列关系。在训练中,将历史时间序列输入到编码器中,并使用其最终状态来初始化解码器。解码器根据先前的真实值生成预测。在测试时,模型产生的预测值取代真实值,同时会导致性能下降。为了缓解训练和测试在输入分布之间的差异,将预定抽样集成到模型中,在模型预测中真实值的概率 ϵ_I ,第 I 次迭代时的概率为 $1 - \epsilon_I$ 。在训练过程中 ϵ_I 逐渐减少到 0 以允许模型学习测试分布。




图 1 扩散卷积递归神经网络

Fig. 1 Diffusion convolutional recurrent neural networks

1.3 预测结果性能评价指标

为了验证预测模型的可行性及精准性,需要利用性能评价指标对模型的预测结果进行评判。常用的性能评价指标一般为平均方差(MSE)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)。本文

采取 MAE 和 MAPE 作为预测结果的评价指标, MAE 能直观反映真实值与预测值的偏差; MAPE 能反映测量的误差水平及可信程度,其计算分别为

$$M_{AE} = \frac{1}{N'} \sum_{i=1}^{N'} |y'_i - \hat{y}'_i| \quad (9)$$

$$M_{APE} = \frac{1}{N'} \sum_{i=1}^{N'} \frac{|y_{i'} - \hat{y}_{i'}|}{y_{i'}} \times 100\%$$

(10)

式中, $y_{i'}$ 为*i'*时刻实际交通量; $\hat{y}_{i'}$ 为*i'*时刻预测交通量; N' 为预测值的总数; M_{AE} 、 M_{APE} 分别为 MAE 和 MAPE 的计算值。

2 算例分析

以河北省石家庄高速公路路网交通量数据为例,该地区发生突发事件后,部分路段中断交通流量发生变化,本文用其事发前 15 d 的数据进行 DCRNN 模型的训练,用事发后 7 d 的数据进行交通流预测。将数据导入到 MySQL 数据库,根据制定的清洗规则进行清洗,具体如下:①筛选出需要计算的高速公路路网数据;②剔除字段内容重复的数据,只保留其中一条;③剔除路段号、站编码不在规

定范围内的异常数据;④剔除入口与出口为同一高速公路的同一收费站数据;⑤剔除距离数为 0、1 km 的数据;⑥剔除行驶时间小于 3 min 的数据。

数据清洗完成后,构建邻接矩阵(29×29),矩阵元素为 2 个节点间的距离,邻接矩阵数据见表 1。高速公路路网最短路径输出结果如表 2 所示。

模型通过 TensorFlow 实现,并使用具有学习率退火的 ADAM 优化器进行训练。在验证数据集上使用树结构 Parzen 估计器(TPE)选择最佳的超参数,最终确定高速公路路网交通量预测模型参数如表 3 所示。

用前 15 d 高速公路路段流量的数据对 DCRNN 模型进行训练,模型训练过程中画出 accuracy 曲线能够更加直观的观察训练状态,以便更好的优化训练质量,DCRNN 模型的训练结果如图 2 所示。

表 1 邻接矩阵数据

Tab. 1 Adjacency matrix data

m

节点	10-3	10-5	10-7	10-9	...	79-13	79-15	79-3	79-5	79-7	79-9
10-3	0	9 000	24 000	37 000	...	53 000	56 000	15 000	25 000	34 000	41 000
10-5	9 000	0	15 000	28 000	...	62 000	65 000	24 000	34 000	43 000	50 000
10-7	24 000	15 000	0	14 000	...	70 000	73 000	38 000	49 000	51 000	58 000
10-9	37 000	28 000	14 000	0	...	83 000	86 000	52 000	62 000	64 000	71 000
⋮	⋮	⋮	⋮	⋮		⋮	⋮	⋮	⋮	⋮	⋮
79-13	53 000	62 000	70 000	83 000	...	0	4 000	40 000	29 000	20 000	13 000
79-15	56 000	65 000	73 000	86 000	...	4 000	0	43 000	32 000	23 000	16 000
79-3	15 000	24 000	38 000	52 000	...	40 000	43 000	0	12 000	21 000	28 000
79-5	25 000	34 000	49 000	62 000	...	29 000	32 000	12 000	0	9 000	16 000
79-7	34 000	43 000	51 000	64 000	...	20 000	23 000	21 000	9 000	0	8 000
79-9	41 000	50 000	58 000	71 000	...	13 000	16 000	28 000	16 000	8 000	0

表 2 最短路径输出结果

Tab. 2 Shortest path output results

起点	终点	最短路径	长度/m
10-3	10-3		0
10-3	10-5	10-3、10-5	9 000
10-3	10-7	10-3、10-5、10-7	24 000
10-3	10-9	10-3、10-5、10-7、10-9	37 000
⋮	⋮	⋮	⋮
116-9	79-13	116-9、116-8、116-7、116-6、116-5-116-4、116-3、1-2、79-7、79-8、79-13	75 000
116-9	79-15	116-9、116-8、116-7、116-6、116-5-116-4、116-3、1-2、79-7、79-8、79-13、79-15	78 000
116-9	79-7	116-9、116-8、116-7、116-6、116-5-116-4、116-3、1-2、79-7	55 000

通过图 2 可以看出,DCRNN 模型训练结果良好,曲线未存在过于平滑,在迭代 60 次时,模型的精度达到 0.95,未显示出过拟合状态。利用训练好的模型对实际高速公路交通量进行预测,其预测值与实际值相差不大。

为了进一步验证模型的准确性及有效性,本文应用其他预测方法对相同的实例数据进行计算并对比。分别选取传统的基于卡尔曼滤波的自回归集成移动平均模型模型和机器学习 BP 神经网络模型对高速公路路网交通量进行预测。ARIMA模型广泛

表 3 DCRNN 模型参数确认

Tab. 3 Validation of DCRNN model parameters

参数	内容
编码器-解码器递归层	2
每个递归层中单元数	5
初始学习率	10^{-2}
目标函数	MSE
优化函数	adam
随机游走最大步长/K	3
激励函数	ReLu




图 2 DCRNN 模型交通量预测训练结果

Fig. 2 DCRNN model traffic volume prediction training results
应用于时间序列,BP 神经网络模型为误差反向传播算法,是交通量预测中比较常用的神经网络,而且不断在改进。预测仍采用后 7 d 数据进行验证,将 MAE 及 MAPE 作为性能评价指标,结果如表 4 所示。本文各模型的参数设置如下:

(1)ARIMA 模型,本文建立 ARIMA(1,2,2)模型,即自回归项确定为 1,差分次数确定为 2,移动平均项确定为 2。

(2)BP 模型,BP 神经网络模型中隐含层为 8,迭代次数为 5 000。

(3)DCRNN 模型,编码器和解码器都包含 2 个递归层。在每个递归层中,有 5 个单元,从第 20 个周期时开始每 10 个迭代减少到 10/1,并在验证数据集上使用早期停止。随机游动的最大步长为 3。预定采样中控制收敛速度的参数设置为 3 000。

由表 4 可知,本文模型的 MAE 和 MAPE 都低于其他 2 种代表性模型。DCRNN 模型对高速公路突发事件恢复重建期交通量预测准确性及有效性较好。

3 结 语

(1)在现有研究基础上,提出基于机器学习的高速公路重建期路网流量预测模型,为恢复与重建施工与预判路网拥堵状况提供参考和帮助。

表 4 几种预测模型的误差分析表

Tab. 4 Error analysis of several prediction models

模型	MAE 值	MAPE 值/%
ARIMA 模型	32.23	8.81
BP 模型	31.40	19.32
DCRNN 模型	18.56	5.79

(2)模型首先将路网建立一个加权有向图,反映路网状况,以突发事件发生后高速公路联网收费数据为基础,利用双向图随机游走定义卷积,将其与序列到序列的学习框架和预定抽样组合起来建模进行交通量预测,建立基于神经网络 DCRNN 的交通量预测模型。

(3)DCRNN 模型训练结果良好,模型的精度达到 0.95,同时未显示出过拟合状态。应用传统的 ARIMA 模型和机器学习 BP 神经网络模型对相同的实例数据进行计算,选取 MAE 和 MAPE 作为性能评价指标进行验证和对比,结果显示本文模型 MAE 和 MAPE 都低于其他 2 种模型,具有良好的准确性及实用性。

(4)本文模型同样适用于其他交通量预测,模型适用于训练集时间较短且交通量大的路网,满足高速公路突发事件恢复重建期的特征,后续应考虑预测发生拥堵时的交通量缓解拥堵方法和策略研究。

参考文献:

References:

[1] AN Ji-wen,BAI Xian-fu,XU Jing-hai,et al. Prediction of highway blockage caused by earthquake-induced landslides for improving earthquake emergency response[J]. Natural Hazards,2015,79(1):511-536.
[2] NASER M H. A dynamic meso-scopic simulation approach to modeling emergency evacuations[D]. Fargo; North Dakota State University,2009.
[3] WEIGLE M C,OLARIU S. Intelligent highway infrastructure for planned evacuations[C]//IEEE. Performance, Computing, and Communications Conference. New York:IEEE,2007:594-599.
[4] CHAI G,HUANG M M,HAN J,et al. Matching method for emergency plans of highway traffic based on fuzzy sets and rough sets[J]. Journal of Intelligent & Fuzzy Systems,2015,29(6):2421-2427.
[5] MUNTASIR BILLAH A H M,SHAHRIA ALAM M. Seismic fragility assessment of highway bridges:A state-of-the-art review[J]. Structure and Infrastructure Engineering,2015,11(6):804-832.
[6] MURRAY-TUITE P, WOLSHON B. Evacuation

- transportation modeling: An overview of research, development, and practice[J]. Transportation Research Part C, 2013, 27: 25-45.
- [7] VAHDANI B, VEYSMORADI D, SHEKARI N, et al. Multi-objective, multi-period location-routing model to distribute relief after earthquake by considering emergency roadway repair[J]. Neural Computing and Applications, 2016, 30(3): 1-20.
- [8] LERTWORAWANICH P. Highway network restoration after the great flood in Thailand[J]. Natural hazards, 2012, 64(1): 873-886.
- [9] 王少飞, 刘桂强, 曾磊, 等. 长大公路隧道火灾事故专项应急预案编制[J]. 消防科学与技术, 2012, 31(2): 197-200.
- WANG Shao-fei, LIU Gui-qiang, ZENG Lei, et al. Working-out special emergency response plan of long and large road tunnel fire accidents[J]. Fire Science and Technology, 2012, 31(2): 197-200.
- [10] 王少飞, 刘桂强, 曾磊, 等. 火灾事故下公路隧道群路段-互通式立交协调交通控制策略[J]. 现代隧道技术, 2012, 49(5): 23-28.
- WANG Shao-fei, LIU Gui-qiang, ZENG Lei, et al. Transportation coordination control strategy for expressway tunnel group-open section-interchange during a fire[J]. Modern Tunneling Technology, 2012, 49(5): 23-28.
- [11] 张海波, 童星. 中国应急预案体系的优化——基于公共政策的视角[J]. 上海行政学院学报, 2012, 13(6): 23-37.
- ZHANG Hai-bo, TONG Xing. The optimization of Chinese public emergency system: A perspective of public policy[J]. The Journal of Shanghai Administration Institute, 2012, 13(6): 23-37.
- [12] 邓月生. 岑梧高速公路牛岭界隧道的消防设计探讨[J]. 广西民族大学学报: 自然科学版, 2008, 27(增): 749-751.
- DENG Yue-sheng. Fire protection design of Niulingjie Tunnel in Cenwu Highway[J]. Journal of Guangxi University for Nationalities: Natural Science Edition, 2008, 27(S): 749-751.
- [13] 马兆有, 王长君, 刘君. 基于危害风险评价的高速公路紧急事件分级[J]. 重庆交通大学学报: 自然科学版, 2010, 29(5): 776-780.
- MA Zhao-you, WANG Chang-jun, LIU Jun. Classification of highway emergencies based on risk evaluation[J]. Journal of Chongqing Jiaotong University: Natural Science Edition, 2010, 29(5): 776-780.
- [14] 高建平, 吕勇衡, 张人文, 等. 高速公路建设期突发事件路网协同救援模型研究[J]. 安全与环境学报, 2016, 16(3): 202-206.
- GAO Jian-ping, LYU Yong-heng, ZHANG Ren-wen, et al. Incident emergency rescue model in the process of freeway construction based on the synergetic theory[J]. Journal of Safety and Environment, 2016, 16(3): 202-206.
- [15] 王少飞, 李科, 蒋彪, 等. 高速公路特殊路段防火救灾对策[J]. 公路, 2013(10): 159-165.
- WANG Shao-fei, LI Ke, JIANG Biao, et al. Counter-measures for fire proofing of freeway special cut section[J]. Highway, 2013(10): 159-165.
- [16] 李巧茹, 张倩, 陈亮, 等. 基于改进蚁群算法的高速公路疏散路径研究[J]. 重庆交通大学学报: 自然科学版, 2015, 34(3): 86-92.
- LI Qiao-ru, ZHANG Qian, CHEN Liang, et al. Study on highway evacuation route based on improved ant colony algorithm[J]. Journal of Chongqing Jiaotong University: Natural Science Edition, 2015, 34(3): 86-92.
- [17] 张富荣, 华高英. 地下交通联系隧道火灾下应急交通疏散研究[J]. 消防科学与技术, 2018, 37(4): 480-483.
- ZHANG Fu-rong, HUA Gao-ying. Fire-based emergency traffic evacuation of urban traffic link tunnel[J]. Fire Science and Technology, 2018, 37(4): 480-483.
- [18] 刘德海, 于倩, 马晓南, 等. 基于最小偏差组合权重的突发事件应急能力评价模型[J]. 中国管理科学, 2014, 22(11): 79-86.
- LIU De-hai, YU Qian, MA Xiao-nan, et al. Combination weight model of emergency ability evaluation with minimum deviation[J]. Chinese Journal of Management Science, 2014, 22(11): 79-86.
- [19] 贾献卓. 基于微观交通仿真的枢纽互通建设交通组织方案实例研究[J]. 公路, 2017(2): 153-159.
- JIA Xian-zhuo. Research on traffic organization scheme of hub interchange based on microscopic traffic simulation[J]. Highway, 2017(2): 153-159.
- [20] 方宪武. 风力发电工程施工安全及应急救援管理[J]. 中国安全生产科学技术, 2017, 13(增2): 80-84.
- FANG Xian-wu. Construction safety and emergency rescue management of wind power projects[J]. Journal of Safety Science and Technology, 2017, 13(S2): 80-84.
- [21] CLARK S. Traffic prediction using multivariate non-parametric regression[J]. Journal of Transportation Engineering, 2003, 129(2): 161-168.
- [22] LU Y, DUAN Y, KANG W, et al. Traffic flow prediction with big data: A deep learning approach[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(2): 865-873.