



JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象图形学报

2021
05
VOL.26

ISSN1006-8961
CN11-3758/TB



参与介质渲染 P961



第26卷第5期 (总第301期)

2021年5月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿, 均视为同意在本刊网站及CNKI等全文数据库出版, 所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用, 所有内容, 未经许可, 不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院

主办单位 中国科学院空天信息创新研究院

中国图象图形学学会

北京应用物理与计算数学研究所

主 编 吴一戎

编辑出版 《中国图象图形学报》编辑部

通信地址 北京市海淀区北四环西路19号

邮 编 100190

电子信箱 jig@radi.ac.cn

电 话 010-58887035

网 址 www.cjig.cn

广告发布登记号 京朝工商广登字20170218号

总 发 行 北京报刊发行局

订 购 全国各地邮局

海外发行 中国国际图书贸易集团有限公司

(邮政信箱: 北京399信箱 邮编: 100048)

印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian

Monthly, Started in 1996

Superintended by Chinese Academy of Sciences

Sponsored by Aerospace Information Research Institute, CAS

China Society of Image and Graphics

Institute of Applied Physics and Computational Mathematics

Editor-in-Chief Wu Yirong

Editor, Publisher Editorial Office of Journal of
Image and Graphics

Address No. 19, North 4th Ring Road West, Haidian District,
Beijing, P. R. China

Zip code 100190

E-mail jig@radi.ac.cn

Telephone 010-58887035

Website www.cjig.cn

Distributed by Beijing Bureau for Distribution of Newspapers and Journals

Domestic All Local Post Offices in China

Overseas China International Book Trading Corporation

(P.O.Box 399, Beijing 100048, P.R.China)

Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB

ISSN 1006-8961

CODEN ZTTXFZ

国外发行代号 M1406

国内邮发代号 82-831

国内定价 60.00元



均匀参与介质的渲染方法研究(第0961页)



循环生成对抗网络的线稿图像自动提取(第1117页)



伪点云修正增强激光雷达数据(第1157页)

学者观点

均匀参与介质的渲染方法研究

王贝贝, 樊家辉 0961

布料仿真建模研究进展

靳雁霞, 张晋瑞, 贾瑶, 马博 0970

综述

中国图像工程:2020

章毓晋 0978

图像处理和编码

双阶段信息蒸馏的轻量级图像超分辨率网络

李明鸿, 常侃, 李恒鑫, 谭宇飞, 覃团发 0991

具有纹理感知能力的超像素分割方法

吴江, 刘春晓 1006

图像分析和识别

深度聚类注意力机制下的显著对象检测

陈庆文, 谢宏文, 查浩, 奚瑜, 张雪 1017

特征增强策略驱动的车标识别

贺敏雪, 余烨, 程茹秋 1030

医学图像处理

融合上下文和注意力的视盘视杯分割

刘洪普, 赵一浩, 侯向丹, 郭鸿湧, 丁梦园 1041

遥感图像处理

复杂背景下SAR近岸舰船检测

阮晨, 郭浩, 安居白 1058

对抗型长短期记忆网络的雷达回波外推算法

方巍, 庞林, 张飞鸿, 盛胜利 1067

混沌系统和DNA编码的并行遥感图像加密算法

周辉, 谢红薇, 张昊, 张慧婷 1081

激光雷达大会2020

图匹配算法激光扫描点云树干分割

徐姗姗 1095

多特征融合与残差优化的点云语义分割方法

杜静, 蔡国榕 1105

NCIG 2020

循环生成对抗网络的线稿图像自动提取

王素琴, 张加其, 石敏, 赵银君 1117

面向COVID-19疫情预测的图卷积神经网络时空数据学习

杨成意, 刘峰, 齐佳音, 段妍, 吕润倩, 肖子龙 1128

结合汉明码和图像矫正的彩色图像盲水印

刘得成, 苏庆堂, 袁子涵, 张雪婷 1138

密文域高嵌入率图像全方位可逆数据隐藏

周旭, 吴福虎, 陈志立, 任帅 1147

伪点云修正增强激光雷达数据

宋绪杰, 戴孙浩, 林春雨, 詹书涛, 赵耀 1157

前沿进展

中国遥感软件研制进展与发展方向——以像素专家PIE为例

刘东升, 廖通逵, 孙焕英, 任芳 1169

CONTENTS

JOURNAL OF IMAGE AND GRAPHICS



Survey of rendering methods for homogeneous participating media(P0961)



Image extraction of cartoon line art based on cycle-consistent adversarial networks(P1117)



LiDAR data enhancement via pseudo-LiDAR point cloud correction(P1157)

Scholar View

- Survey of rendering methods for homogeneous participating media
Wang Beibei, Fan Jiahui 0961
- Progress of cloth simulation modeling
Jin Yanxia, Zhang Jinrui, Jia Yao, Ma Bo 0970

Review

- Image engineering in China: 2020
Zhang Yujin 0978

Image Processing and Coding

- Lightweight image super-resolution network via two-stage information distillation
Li Minghong, Chang Kan, Li Hengxin, Tan Yufei, Qin Tuanfa 0991
- Superpixel segmentation with texture awareness
Wu Jiang, Liu Chunxiao 1006

Image Analysis and Recognition

- Salient object detection based on deep clustering attention mechanism
Chen Qingwen, Xie Hongwen, Zha Hao, Xi Yu, Zhang Xue 1017
- Vehicle logo recognition method based on feature enhancement
He Minxue, Yu Ye, Cheng Ruqiu 1030

Medical Image Processing

- Optic disc and cup segmentation by combining context and attention
Liu Hongpu, Zhao Yihao, Hou Xiangdan, Guo Hongyong, Ding Mengyuan 1041

Remote Sensing Image Processing

- SAR inshore ship detection algorithm in complex background
Ruan Chen, Guo Hao, An Jubai 1058
- Radar echo extrapolation algorithm based on adversarial long short-term memory network
Fang Wei, Pang Lin, Zhang Feihong, Sheng Victor S 1067
- Parallel remote sensing image encryption algorithm based on chaotic map and DNA encoding
Zhou Hui, Xie Hongwei, Zhang Hao, Zhang Huiting 1081

China LiDAR Conference 2020

- Tree stem segmentation of laser scanning point clouds based on graph matching algorithm
Xu Shanshan 1095
- Point cloud semantic segmentation method based on multi-feature fusion and residual optimization
Du Jing, Cai Guorong 1105

NCIG 2020

- Image extraction of cartoon line art based on cycle-consistent adversarial networks
Wang Suqin, Zhang Jiaqi, Shi Min, Zhao Yinjun 1117
- Spatiotemporal data learning of graph convolutional neural network for epidemic prediction of COVID-19
Yang Chengyi, Liu Feng, Qi Jiayin, Duan Yan, Lyu Runqian, Xiao Zilong 1128
- Blind color image watermarking method combining Hamming code with image correction
Liu Decheng, Su Qingtang, Yuan Zihan, Zhang Xueting 1138
- All bit planes reversible data hiding for images with high-embedding-rate in ciphertext field
Zhou Xu, Wu Fuhu, Chen Zhili, Ren Shuai 1147
- LiDAR data enhancement via pseudo-LiDAR point cloud correction
Song Xujie, Dai Sunhao, Lin Chunyu, Zhan Shutao, Zhao Yao 1157

Frontier

- Research progress and development direction of Chinese remote sensing software: taking PIE as an example
Liu Dongsheng, Liao Tongkui, Sun Huanying, Ren Fang 1169

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2021)05-1128-10

论文引用格式: Yang C Y, Liu F, Qi J Y, Duan Y, Lyu R Q and Xiao Z L. 2021. Spatiotemporal data learning of graph convolutional neural network for epidemic prediction of COVID-19. Journal of Image and Graphics, 26(05): 1128-1137 (杨成意, 刘峰, 齐佳音, 段妍, 吕润倩, 肖子龙. 2021. 面向 COVID-19 疫情预测的图卷积神经网络时空数据学习. 中国图象图形学报, 26(05): 1128-1137) [DOI: 10.11834/jig.200393]

面向 COVID-19 疫情预测的图卷积神经网络时空数据学习

杨成意^{1,2}, 刘峰^{1,3}, 齐佳音^{1*}, 段妍^{1,2}, 吕润倩^{1,2}, 肖子龙⁴

1. 上海对外经贸大学人工智能与变革管理研究院, 上海 200336; 2. 上海对外经贸大学统计与信息学院, 上海 201620;
3. 华东师范大学计算机科学与技术学院, 上海 200062; 4. 中山大学数据科学与计算机学院, 广州 510006

摘要: 当前的疾病传播研究主要集中于时序数据和传染病模型, 缺乏运用空间信息提升预测精度的探索和解释。在处理时空数据时需要分别提取时间特征和空间特征, 再进行特征融合得到较为可靠的预测结果。本文提出一种基于图卷积神经网络(graph convolutional neural network, GCN)的时空数据学习方法, 能够运用空间模型端对端地学习时空数据, 代替此前由多模块单元相集成的模式。**方法** 依据数据可视化阶段呈现出的地理空间、高铁线路、飞机航线与感染人数之间的正相关关系, 将中国各城市之间的空间分布关系和交通连接关系映射成网络图并编码成地理邻接矩阵、高铁线路直达矩阵、飞机航线直达矩阵以及飞机航线或高铁线路直达矩阵。按滑动时间窗口对疫情数据进行切片后形成张量, 依次分批输入到图深度学习模型中参与卷积运算, 通过信息传递、反向传播和梯度下降更新可训练参数。**结果** 在新型冠状病毒肺炎疫情数据集上的实验结果显示, 采用 GCN 学习这一时空数据的分布特征相较于循环神经网络模型, 在训练过程中表现出了更强的拟合能力, 在训练时间层面节约 75% 以上的运算成本, 在两类损失函数下的平均测试集损失能够下降 80% 左右。**结论** 本文所采用的时空数据学习方法具有较低的运算成本和较高的预测精度, 尤其在空间特征强于时间特征的时空数据中有着更好的性能, 并且为流行病传播范围和感染人数的预测提供了新的方法和思路, 有助于相关部门在公共卫生事件中制定应对措施和疾病防控决策。

关键词: 深度学习; 图卷积神经网络(GCN); 时空数据处理; 新冠肺炎; 疫情预测

Spatiotemporal data learning of graph convolutional neural network for epidemic prediction of COVID-19

Yang Chengyi^{1,2}, Liu Feng^{1,3}, Qi Jiayin^{1*}, Duan Yan^{1,2}, Lyu Runqian^{1,2}, Xiao Zilong⁴

1. Institute of Artificial Intelligence and Change Management, Shanghai University of International Business and Economics, Shanghai 200336, China;
2. School of Statistics and Information, Shanghai University of International Business and Economics, Shanghai 201620, China;
3. School of Computer Science and Technology, East China Normal University, Shanghai 200062, China;
4. School of Data and Computer Science, Sun Yat-sen University, Guangzhou, 510006, China

Abstract: Objective COVID-19 has caused a severe impact on the medical system and economic growth of countries all

收稿日期: 2020-09-18; 修回日期: 2020-11-04; 预印本日期: 2020-11-11

* 通信作者: 齐佳音 qijiayin@139.com

基金项目: 国家自然科学基金项目(72042004)

Supported by: National Natural Science Foundation of China(72042004)

over the world. Therefore, the epidemic information of each city has important reference value for governments and enterprises to formulate public health prevention and control measures and decisions in opening the economy. According to relevant research, the infectious disease model and time series model have played an important role in finding potential hosts, confirming human to human transmission, and estimating the basic reproductive number. Related research methods on disease transmission and confirmed case prediction have experienced a series of evolution, including demographic method, dynamic model, social network analysis, flight passenger volume estimation, data mining, and machine learning method. However, the prediction accuracy of these methods still needs to be improved by using spatial information in the study of epidemic transmission. In recent years, the boom of graph deep learning has provided new technologies and methods for the estimation of epidemic spread. From the iteration of trainable parameters in the way of information interaction in early time to the optimization of graph type, propagation mechanism, and output steps, this development process laid the foundation for the generation of graph convolutional neural network (GCN). The development of graph convolution network optimizes the performance of graph neural network in spectral domain and spatial domain by changing convolution kernel and information aggregation mode. The progress of representation learning improves the convenience of graph data processing. The rise of integrated framework realizes more accurate prediction in spatiotemporal data processing represented by traffic flow. **Method** Compared with traffic flow prediction, epidemic data prediction has stronger spatial attribute and weaker temporal attribute, which is the reason why GCN is used alone instead of integration approaches. First, according to the data visualization stage of the epidemic information and geographical location and traffic network between the positive correlation, the spatial distribution relationship and traffic connection relationship between affected cities in China are mapped into a graph network and encoded into geographic adjacency matrix, high-speed railway direct matrix, aircraft route direct matrix, and aircraft route or high-speed railway direct matrix. Four cities networks with different connection modes are formed by these four adjacent matrices, and the corresponding GCN model is constructed based on these cities networks, including geographical proximity graph convolutional neural network (GPGCN), airline graph convolutional neural network (ALGCN), high speed railway graph convolutional neural network (HSRGCN), airline and high speed railway graph convolutional neural network (ALHSRGCN). After dividing the training, validation, and test sets at a ratio of 6 : 2 : 2, the epidemic data were sliced according to the sliding time window to form a three-dimensional tensor with a size of $30 \times 327 \times 7$ as the test set, which was input into the graph deep learning model in batches to participate in convolution operation. The training parameters were updated by information transmission, back propagation, and gradient descent. **Result** The experimental results on the COVID-19 dataset demonstrated that the learning distribution features of spatiotemporal data by the GCN model showed stronger fitting ability than the recurrent neural network model in the training process. It could save more than 75% of the computation cost at the training time level, and the average test set loss on mean absolute error (MAE) and mean square error (MSE) decreased by about 80%. The value of loss would converge to a lower position and achieve a more stable training process so as to obtain more accurate prediction when MSE is chosen as the loss function. **Conclusion** The spatiotemporal data learning method in this study has lower operation cost and higher prediction accuracy, which shows better performance especially in the case of spatiotemporal data with stronger spatial characteristics than temporal characteristics. It provides new approaches and ideas for the prediction of epidemic spread range and number of infected people, which is conducive for relevant departments to formulate countermeasures for disease prevention and control decisions in public health events.

Key words: deep learning; graph convolutional neural network (GCN); spatiotemporal data processing; Coronavirus Disease 2019 (COVID-19); epidemic prediction

0 引 言

新型冠状病毒 (Covonavirus Disease 2019, COVID-19) 的传播和蔓延对世界各国的医疗体系与经济

增长造成了冲击。城市疫情信息的估计和预测对于政府和企业制定公共卫生防控措施和产业复工复产决策具有重要的参考价值。

Xu 等人 (2020) 将新型冠状病毒与 SARS (severe acute respiratory syndrome) 冠状病毒和中东呼

吸综合征冠状病毒(Middle East respiratory syndrome coronavirus, MERS-CoV)进行了比较,探寻新型冠状病毒的传播途径。Guo 等人(2020)引入病毒宿主预测(virus host prediction, VHP),使用深度学习算法预测病毒的潜在宿主。Wu 等人(2020)利用月度航班预订和城市的人员流动数据,建立传染病模型模拟中国各大城市的疫情。Li 等人(2020)研究了武汉市感染新型冠状病毒肺炎的前 425 例确诊病例,通过传播动力学和流行病学特征证实了早期人际传播的迹象。Zhou 等人(2020)基于 SEIR(susceptible exposed infections and recovered)模型对 COVID-19 的基本繁殖数进行估算,得出 COVID-19 可控的结论。Chen 等人(2020)针对 COVID-19 潜伏期传播特征引入隔离过程,提出时滞动力学模型,预测疫情趋势。

早期,疾病传播的研究聚焦于以微分方程理论为基础的传染病模型。May 等人(1988)把动力学模型与人口统计学因素相结合,探讨了 AIDS(acquired immune deficiency syndrome)的水平和垂直传播对总体人口增长率和年龄分布的影响。随着计算机性能的提升,传统的数学模型演变成微观模拟模型。Chao 等人(2010)考虑个体在现实社会中的接触网络,建立流感在人群中传播的随机模型 FluTE(influenza epidemic simulation)。Merler 等人(2011)构建了基于社会人口结构和流动模式的 SEIR 模型,解释了欧洲 H1N1 流感流行的时空动态。随着交通客运的便利化,疾病传播跨越了地理距离。Brockmann 和 Helbing 等人(2013)创新性地通过全球航班载人量测算有效距离,推测了疫情传播的起始城市和到达时间。随着机器学习方法开始涉足传染病领域,Fusco 等人(2020)利用数据挖掘与机器学习方法预测血吸虫病宿主媒介密度,从而推断其区域内传播风险。Fang 等人(2020)采用随机森林预测传染性腹泻发病率,更好地契合了疾病流行的动态特性。

图深度学习理论的兴起将神经网络拓展到了非欧几里得空间,为疫情传播的研究提供了新技术、新方法。本文提出了用于 COVID-19 预测的图卷积神经网络(graph convolutional neural network, GCN)时空数据学习方法,主要贡献可以归纳为:

1)将城市之间的拓扑关系映射成网络图并编码成矩阵,相较于传染病模型和包括循环神经网络

在内的时序模型获得了更多先验信息。

2)通过设置移动时间窗口和分批输入的方式实现时空数据的端对端学习,代替此前由多模块单元相集成的模式。

3)在新冠肺炎数据集上的实验表明,本文所用的图卷积神经网络训练方法相较于循环神经网络有着更高的训练效率和预测精度。

1 相关工作

图神经网络(Gori 等,2005)作为一种基于图数据的深度学习架构,在社交网络、推荐系统等领域得到了广泛应用(Zhou 等,2018)。早期研究采用迭代的方式,通过信息交互更新节点状态(Scarselli 等,2009)。随着在图的类型、传播机制和输出步骤等方面的优化,模型匹配的图类型由最初的无向图扩展到有向图(Kampffmeyer 等,2019)、异构图(Zhang 等,2018)、有边信息的图(Beck 等,2018)、随时间变化的动态图(Trivedi 等,2019)等。

受计算机视觉领域启发,图数据处理逐渐引入卷积运算(Wu 等,2021)。Bruna 等人(2014)基于谱图理论提出了频域和空域两种方法,借助傅里叶变换实现了图卷积。Duvenaud 等人(2015)提出 ChebNet,将 Chebyshev 多项式拟合成卷积核,降低了计算复杂度。Kipf 和 Welling(2016)采用一阶近似的 ChebNet,提出了对未来研究起到重要作用的图卷积神经网络。空域方法定义的图卷积采用中心节点和邻域的信息聚合(Wu 等,2021),具有代表性的有门控图神经网络(Li 等,2015)、图抽样聚合网络(Hamilton 等,2017)、混合模型网络(Monti 等,2017)等。

随着表征学习的发展,Niepert 等人(2016)对输入图的节点生成局部规范化的邻域表示,将图结构数据转化成卷积神经网络实现高效处理。Du 等人(2017)提出了拓扑自适应图卷积网络(topology adaptive graph convolutional networks, TAGCN),设计了固定大小的可学习滤波器,从而不需要对卷积进行近似。Li 等人(2018)提出的自适应图卷积网络(adaptive graph convolutional neural network, AGCN)可以将任意图结构数据作为输入,通过计算节点之间的成对距离构造的残差图来扩充图。Yu 等人(2018)提出了基于图卷积单元的图时空网络,图卷

积层和卷积神经网络分别捕获空间与时间的变化。

此后,集成框架开始兴起,Manessi 等人(2020)结合图卷积单元和长短期记忆网络(long short-term memory, LSTM)对动态图进行分类。Zhao 等人(2020)提出时间图卷积网络(temporal graph convolutional network, T-GCN)模型学习城市路网拓扑结构,将带有空间特征的时间序列输入门控递归单元得到预测结果。Geng 等人(2019)提出了时空多图卷积网络(spatiotemporal multi-graph convolution network, ST-MGCN),通过多个图卷积的聚合运算,更精准地预测了区域网约车需求。Guo 等人(2019)提出的基于注意力机制的时空图卷积网络(attention based spatial-temporal graph convolutional networks, ASTGCN),对交通流的3个时间特性进行了包含时空卷积和注意力机制的独立建模,最后对3个分量进行加权融合生成预测结果。

图深度学习经历了从卷积核优化到模型集成的演进历程。在时空数据处理问题中,更常用的是将时序信息和空间信息分配给两类不同模型学习的方式。然而,本文方法通过设置时间窗口和分批输入代替了以往时序模型和空间模型相集成的方式,通过调整邻接矩阵的定义方式代替多图卷积的聚合运算,并增加了对比实验观察网络图边数变化的影响,简化了设计框架和运算步骤,在疫情预测这一回归问题上取得较为高效的预测结果。

2 方法

2.1 问题定义

本文用 $G(V, E)$ 描述城市网络的拓扑结构, V 表示有确诊病例城市的集合, E 表示城市之间边的集合。列向量 $\mathbf{x}^{(t)}$ 代表各城市第 t 天的累积确诊人数,则各城市前 T 时刻的确诊人数形成了基于空间分布的时间序列 $[\mathbf{x}^{(t-T)}, \mathbf{x}^{(t-T-1)}, \dots, \mathbf{x}^{(t)}]$ 。拟通过图卷积神经网络学习时空分布规律,输出第 $t+1$ 时刻各城市的预测确诊人数为

$$\mathbf{x}^{(t+1)} = GCN([\mathbf{x}^{(t-T)}, \mathbf{x}^{(t-T-1)}, \dots, \mathbf{x}^{(t)}]), \quad (1)$$

$$0 \leq T \leq t$$

将城市之间的空间关联信息映射成网络图,通过边来描述城市节点之间的地理和交通联系。采用地理邻接关系图 $\mathbf{G}_{GP} = (V, \mathbf{A}_{GP})$ 、高铁直达关系图 $\mathbf{G}_{HSR} = (V, \mathbf{A}_{HSR})$ 、飞机直达关系图 $\mathbf{G}_{AL} = (V,$

$\mathbf{A}_{AL})$ 、飞机或高铁直达图 $\mathbf{G}_{ALHSR} = (V, \mathbf{A}_{ALHSR})$ 分别表示城市之间的空间接壤关系、高速铁路连接关系、飞机航线连接关系、高铁或航线连接关系。 $V = \{v_1, v_2, \dots, v_N\}$ 是城市节点的集合, N 是节点的总数, $\mathbf{A}_{GP}, \mathbf{A}_{HSR}, \mathbf{A}_{AL}, \mathbf{A}_{ALHSR}$ 表示邻接矩阵。

2.2 邻接矩阵表示

1) 地理邻接矩阵。根据城市 i 与城市 j 之间是否在地理上构成相邻关系,可以构建邻接矩阵

$$A_{GP,ij} = \begin{cases} 1 & \text{相邻} \\ 0 & \text{其他} \end{cases} \quad (2)$$

2) 交通邻接矩阵。交通航运技术的进步使得城市之间跨越了地理空间意义上的距离。因此,有必要将直达高铁线路(high-speed railway, HSR)和飞机航线(aircraft line, AL)的连接同等考虑在内,可构建如下的邻接矩阵

$$A_{HSR,ij} = \begin{cases} 1 & \text{高铁可以直达} \\ 0 & \text{其他} \end{cases} \quad (3)$$

$$A_{AL,ij} = \begin{cases} 1 & \text{飞机航线可以直达} \\ 0 & \text{其他} \end{cases} \quad (4)$$

$$A_{ALHSR,ij} = \begin{cases} 1 & \text{飞机或高铁可以直达} \\ 0 & \text{其他} \end{cases} \quad (5)$$

2.3 数据描述

本文的数据来源是各省市卫生健康委员会(卫健委)每日发布的新型冠状病毒肺炎新增确诊人数。由于卫健委自2020年1月21日起开始公布疫情信息,本文选用2020年1月21日至2020年3月10日这50天内有确诊病例的全部327个城市的累计确诊人数作为研究对象。

通过查阅国内各地级市的地理信息,以及高铁线路和飞机航班开设情况,标注了在2.2节中定义的4个邻接矩阵。每个矩阵都是满足对称性且尺寸为 327×327 的2维张量。为了让卷积运算包含自身特征,每个节点都添加了自环,可以表示为 $\mathbf{A} = \mathbf{A} + \mathbf{I}_N$ 。其中 N 是节点总数, $\mathbf{A} \in \mathbf{R}^{N \times N}$ 是带自环的邻接矩阵, $\mathbf{I}_N \in \mathbf{R}^{N \times N}$ 是一个单位矩阵。

2.4 构建城市网络

根据定义的邻接矩阵和数据描述,城市之间空间相邻信息和交通连接状况可映射成4幅城市网络图。每个网络的节点数都为327,代表327个有确诊病例的城市,总边数按照包括自环在内的有向边方式计量,具体参数如表1所示。

根据 $\mathbf{A}_{AL}$ 和 $\mathbf{A}_{HSR}$ 形成的交通发达程度,以及到

表 1 城市网络图的参数

Table 1 Parameters of city network diagram

网络图	总边数	特征向量中心度 Top5 城市
G_{GP}	1 909	九江、上饶、池州、黄冈、宜春
G_{AL}	5 533	北京、上海、成都、西安、广州
G_{HSR}	6 633	北京、上海、长沙、郑州、济南
G_{ALHSR}	10 523	北京、上海、广州、西安、长沙

注:特征向量中心度复杂网络中节点重要程度的度量,其值越高意味着该节点连接到更多得分较高的节点从而显得更加重要。

武汉的距离和累积确诊人数三者之间的关系,得到的城市网络图如图 1 和图 2 所示。图 1 和图 2 的 X 轴和 Z 轴是相同的,差别仅限于 Y 轴按照高铁线路连接城市数或者按照飞机航班连接城市数的计量方式。




图 1 疫情城市间的高铁发达程度与位置信息图
Fig. 1 Graph of high speed railway development and location information among affected cities




图 2 疫情城市间的航线发达程度与位置信息图
Fig. 2 Graph of airline development and location information among affected cities

可以观测到疫情最严重的区域主要分布在中心城市武汉的 10^6 m 测地线距离以内,形成了第 1 阶梯的城市群,在图 1 和图 2 中用蓝色和绿色表示。余下受疫情影响的城市信息在图中用红色和黄色表示,形成了第 2 阶梯的城市集合。可以观测到交通线路连接外部城市多的城市,其累积确诊人数远高于交通不发达城市的这一指标。上述观测表明疫情影响城市的累积确诊人数与其交通便利程度,以及相邻城市的疫情严重程度存在正相关关系。

2.5 模型构建

选取了 327 个城市 50 天的确诊人数作为输入特征,形成了尺寸为 327×50 的 2 维张量。按照 $6:2:2$ 的比例划分训练集、验证集和测试集,得到尺寸为 327×30 、 327×10 、 327×10 的 3 个 2 维张量。为了让测试集数据符合 GCN 模型的训练框架,以及让 RNN(recurrent neural network)和 LSTM 能够用同样的数据进行对照实验,进行区间切片如图 3 所示。

训练集的输入记为 $X_1, X_2, \dots, X_{23}$, $X_i \in \mathbf{R}^{327 \times 7}$, i 代表批次号。其中 $X_1 = [x^{(1)}, x^{(2)}, \dots, x^{(7)}]$, $X_2 = [x^{(2)}, x^{(3)}, \dots, x^{(8)}]$, $\dots$, $X_{23} = [x^{(23)}, x^{(24)}, \dots, x^{(29)}]$, $X^{(i)} \in \mathbf{R}^{327 \times 1}$ 是一个列向量。验证集的输入记为 $V_1, \dots, V_3$, $V_i \in \mathbf{R}^{327 \times 7}$, 测试集的输入记为 $T_1, \dots, T_3$, $T_i \in \mathbf{R}^{327 \times 7}$ 。其中 $V_1 = [x^{(31)}, x^{(32)}, \dots, x^{(37)}]$, $\dots$, $V_3 = [x^{(33)}, x^{(34)}, \dots, x^{(39)}]$, $T_1 = [x^{(41)}, x^{(42)}, \dots, x^{(47)}]$, $\dots$, $T_3 = [x^{(43)}, x^{(44)}, \dots, x^{(49)}]$ 。训练集的标签由列向量组 $x^{(8)}, x^{(9)}, \dots, x^{(30)}$ 组成,验证集和测试集的标签分别由列向量组 $x^{(38)}, x^{(39)}, x^{(40)}$ 和 $x^{(48)}, x^{(49)}, x^{(50)}$ 组成。



图 3 按时间序列的数据切片

Fig. 3 Slicing data by time series

本文吸纳了拓扑自适应图卷积(Du 等,2017)和谱图分解卷积(Kipf 和 Welling,2016)的思想,将图卷积神经网络前向传播过程通过矩阵运算的形式描述为

$$\mathbf{H}^{(l+1)} = \text{Agg}_{k=0}^K (\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{X}^{(l)} \boldsymbol{\Theta}_k^{(l)}) \quad (6)$$

$$\mathbf{X}^{(l+1)} = \text{ReLU}(\mathbf{H}^{(l+1)}) \quad (7)$$

式中, Agg 代表聚合运算, $l = 0, 1, 2, \dots$, 是当前所在层数, K 是图卷积聚合周围节点信息的总跳数, $\boldsymbol{\Theta}$ 是一个可学习的参数矩阵, $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_N$ 是一个带自环的邻接矩阵, $\tilde{\mathbf{D}} = \sum \tilde{\mathbf{A}}$ 是 $\tilde{\mathbf{A}}$ 的度矩阵, $\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}}$ 是拉普拉斯矩阵 $\tilde{\mathbf{L}}$ 的正则化形式。

3 实验及结果分析

3.1 实验设计

实验的任务可归纳为通过 GCN 模型学习一个 $f: \mathbf{X}^{[V \times T]} \rightarrow \hat{\mathbf{Y}}^{[V \times 1]}$ 的映射。依次输入前 T 时刻的状态 $\mathbf{x}^{(t-T)}, \mathbf{x}^{(t-T+1)}, \dots, \mathbf{x}^{(t)}$, 预测下一时刻的状态, 通过调整可学习参数使得 $t+1$ 时刻的预测值 $\hat{\mathbf{x}}^{(t+1)}$ 与真实值 $\mathbf{x}^{(t+1)}$ 之间的误差尽可能小。

如图 4 所示, 将 2 维张量 $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_{23}$ 依次输入 GCN 模型后, 张量在第 1 次卷积中聚合了 2 跳邻居节点的信息扩张为 327×21 的矩阵。通过线性模块将尺寸转换为 327×14 , 以适应隐藏层神经元个数。在第 2 层卷积时, 张量的最后一维聚合的 2 跳邻居节点信息达到了 42, 最后通过全连接层输出尺寸为 327×1 的矩阵作为 327 个城市状态信息的回归预测值。

30@327×7 30@327×21 30@327×14 30@327×42 30@327×1




图 4 分批图卷积运算过程的张量图示

Fig. 4 Diagram of tensors when graph convolution operates in batches

由于疫情数据具有无周期、不可逆的特性, 本文在验证集上进行多次探索性实验代替交叉验证调优超参数。选择 1 150 次作为总训练次数, ReLU 为卷积层的激活函数, 输入层、隐藏层、输出层的神经元个数分别为 7、14、1。确定 0.001 学习率下的 Adam

优化函数能让损失值稳定下降, 采用双卷积层的 GCN 有较好的泛化能力。GCN 均采用 Glorot 和 Bengio(2010)提出的 Xavier 初始化, 卷积层的聚合阶数 K 默认为 2 跳, 每层图卷积都不经过池化运算。

验证集上的调优实验表明, RNN、GRU (gated recurrent unit) 和 LSTM 的损失函数对于输入层、输出层、隐藏层神经元个数的微调不敏感, 故将三者同样设置为 7、14、1。隐藏层层数为 2 能够兼顾预测精度和运算成本, 0.001 学习率下的 Adam 优化器性能优于其他选择。所有的神经网络模型都在 pytorch 1.4.0 上部署和实现, 实验所用配置为 32 GB 2 400 MHz DDR4 内存和 2.3 GHz 八核 Intel Core i9 处理器。

3.2 实验方法

3.2.1 训练过程比较

图 5 和图 6 分别展示了平均绝对误差 (mean absolute error, MAE)、均方误差 (mean square error, MSE) 作为损失函数, 训练不同深度学习模型时的变化过程。可以观测到:

- 1) MAE 在训练过程中会因为新批次特征的加入显著反弹; 而 MSE 在训练过程中能更平稳地下降。
- 2) 任意一个 GCN 模型的损失函数收敛速度都快于循环神经网络方法, 且其训练误差趋于一致。
- 3) GCN 模型相较于 RNN、GRU 和 LSTM 有更强的拟合能力, 在 MSE 训练下拟合效果更好。




图 5 MAE 在训练不同模型时的变化过程

Fig. 5 Changes of MAE when training different models

3.2.2 测试结果比较

图 7 和图 8 展示了不同模型经 MAE、MSE 训练后的测试集平均误差和总训练时长。在本实验条件下可以观测到:




图6 MSE在训练不同模型时的变化过程

Fig. 6 Changes of MSE when training different models




图7 MAE训练后的性能测试结果

Fig. 7 Performance on test set after training based on MAE




图8 MSE训练后的性能测试结果

Fig. 8 Performance on test set after training based on MSE

1) 在训练时长上, 循环神经网络中用时最少的 RNN 约为图卷积神经网络中用时最多的 ALHSRGCN 的 4 倍。

2) 在测试集损失上, 分别以 MAE 和 MSE 为损失函数训练后, 4 个 GCN 中最高测试集损失仅为 RNN、GRU、LSTM 中最低测试集损失的 13% 和 23% 左右。

3) 在网络图边数上, ALHSRGCN 分别是 ALGCN

和 HSRGCN 的 1.9 倍和 1.58 倍, 但训练时长没有显著增加。测试集的 MAE 因为边数的增加而减少了 50% 以上, 但 RMSE (root mean squared error) 误差作为 MSE 的算术平方根反而增加了 15% 以上。

3.3 结果分析

上述观测表明, 采用 GCN 学习和预测时空序列数据, 与擅长处理时序问题的 RNN、GRU、LSTM 相比有着更好的性能。不仅能够得到更小的测试损失, 还能大幅降低训练时间和运算成本。尽管增加网络图边数带来的运算成本较小, 但该方法并不能显著提升预测精度。

从统计学和张量运算的观点解释, GCN 优于循环神经网络的原因可以归纳为以下两点: 1) 后者直接将 3 维张量作为输入; 而本文设计分批将 2 维张量输入 GCN 的方式, 实现了数据层面上的降维, 从而减少了训练成本; 2) 后者只能学习张量中各元素之间的顺序特征, 而 GCN 将 2 维特征张量中每个节点之间的空间关系都编码成邻接矩阵, 获得了更多的先验信息, 从而提升了预测的精度。

在疫情确诊人数预测中, 拓扑空间分布的影响通常强于时间增长带来的影响。在时空数据处理问题上, 这一特性为采用图卷积神经网络对疫情信息进行端到端学习和精准估计创造了条件。因此, 本文没有沿用流行病传播问题中最普遍的传染病模型或者时序模型的方法, 以及以交通流量预测为代表的时空模型相集成的方法。以上实验和分析探索并解释了考虑空间信息对于提升预测精度的重要性, 在公共卫生和疫情防控领域对挖掘空间信息的价值具有启发性作用。

3.4 模型分析

本文所用模型的本质是根据邻近城市前 7 天的累积确诊人数预测中心城市第 8 天的累积确诊人数。归一化的拉普拉斯矩阵 $\tilde{L}$ 包含了城市网络的拓扑空间信息, 将特征矩阵中的邻居节点信息聚合到中心节点。可训练参数 Θ 描述了每个邻近城市特征相对于中心城市特征的重要程度。模型的运算方式是先通过仿射变换对每个城市的特征进行加权, 通过拉普拉斯矩阵将邻近城市的信息聚合到中心城市, 形成了输入特征与预测值之间的映射关系。

本文重新定义了拉普拉斯矩阵 $\tilde{L}$, 认为不仅地理上相邻的两座城市互为邻居, 高铁线路和飞机航

班能够直达的城市也互为邻近城市。尽管随着疫情防控措施的升级,城际间交通流量对于疾病传播的影响不断变弱,疫情逐渐转化为本地化发展。但是在统一的防控政策下,中心城市与邻近城市的医疗资源条件和人口流量变化仍是相近的,因此通过拓扑空间和样本信息预测每个城市的疫情变化仍然可行。3~7天潜伏期的影响具有普遍性和连续性,包含在每个城市的确诊人数中。而在邻近城市和中心城市之间都具有的相似条件已在模型的考虑范围内。由于累积确诊人数数据量比较稀疏,更多地考虑空间信息能够达到更好的预测效果。

4 结 论

针对传染病模型和时间序列方法在流行病传播预测中缺乏利用空间信息提升预测精度的问题,本文提出了一种基于图卷积神经网络的时空数据学习方法,能够在时空数据中以端对端的方式提取时间和空间特征。将中国国内各城市之间的空间邻接关系和交通直达关系映射成网络图,通过矩阵运算的方式实现节点状态的更新和传递过程。按时间窗口对数据切片后形成特征张量,并依次分批输入,使得数据在符合 GCN 框架的同时保留了输入特征的时空分布规律。实验结果表明,该方法学习城市疫情这一时空数据,相较于擅长处理时间序列问题的循环神经网络,不仅能节约训练时间和运算成本,更能提升城市网络中各节点状态的预测精度。

本文通过4个代表城市间关系的邻接矩阵构建了图卷积神经网络,与3个常用的循环神经网络模型进行了比较。主要侧重于说明 GCN 在疫情预测领域的合理性和可行性,在 MAE 和 RMSE 衡量下的测试集损失值已经低至 1.5% 以下,因而不详细探讨与其他图神经网络算法或者多模型集成方法的对比。下一步的工作将致力于探索图深度学习方法在处理时空数据问题上的更广泛应用,并对 GCN 模型用于回归问题时的性能优化展开研究,为多领域的工商业应用提供理论依据和技术支撑。

参考文献 (References)


Beck D, Haffari G and Cohn T. 2018. Graph-to-sequence learning using gated graph neural networks//Proceedings of the 56th Annual Meet-

- ing of the Association for Computational Linguistics. Melbourne, Australia: ACL; 273-283 [DOI: 10.18653/v1/P18-1026]
- Brockmann D and Helbing D. 2013. The hidden geometry of complex, network-driven contagion phenomena. *Science*, 2013, 342(6164): 1337-1342 [DOI: 10.1126/science.1245200]
- Bruna J, Zaremba W, Szlam A and LeCun Y. 2014. Spectral networks and locally connected networks on graphs [EB/OL]. [2020-09-03]. <https://arxiv.org/pdf/1312.6203.pdf>
- Chao D L, Halloran M E, Obenchain V J and Longini Jr I M. 2010. FluTE, a publicly available stochastic influenza epidemic simulation model. *PLoS Computational Biology*, 2010, 6(1): #e1000656 [DOI: 10.1371/journal.pcbi.1000656]
- Chen Y, Cheng J, Jiang Y and Liu K J. 2020. A time delay dynamical model for outbreak of 2019-nCoV and the parameter identification [EB/OL]. [2020-09-13]. <https://arxiv.org/pdf/2002.00418.pdf>
- Du J, Zhang S H, Wu G H, Moura J M F and Kar S. 2017. Topology adaptive graph convolutional networks [EB/OL]. [2020-09-03]. <https://arxiv.org/pdf/1710.10370.pdf>
- Duvenaud D, Maclaurin D, Aguilera-Iparraguirre J, Gómez-Bombarelli R, Hirzel T, Aspuru-Guzik A and Adams R. 2015. Convolutional networks on graphs for learning molecular fingerprints//Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal, Canada: NIPS; 2224-2232 [DOI: 10.5555/2969442.2969488]
- Fang X Y, Liu W D, Ai J, He M K, Wu Y, Shi Y Y, Shen W Q and Bao C J. 2020. Forecasting incidence of infectious diarrhea using random forest in Jiangsu Province, China. *BMC Infectious Diseases*, 2020, 20(1): #222 [DOI: 10.1186/s12879-020-4930-2]
- Fusco T, Bi Y X, Wang H Y and Browne F. 2020. Data mining and machine learning approaches for prediction modelling of schistosomiasis disease vectors: epidemic disease prediction modelling. *International Journal of Machine Learning and Cybernetics*, 11(6): 1159-1178 [DOI: 10.1007/s13042-019-01029-x]
- Geng X, Li Y G, Wang L Y, Zhang L Y, Yang Q, Ye J P and Liu Y. 2019. Spatiotemporal multi-graph convolution network for ride-hailing demand forecasting//Proceedings of the 33rd AAAI Conference on Artificial Intelligence. Honolulu, USA: AAAI; 3656-3663 [DOI: 10.1609/aaai.v33i01.33013656]
- Glorot X and Bengio Y. 2010. Understanding the difficulty of training deep feedforward neural networks//Proceedings of the 13th International Conference on Artificial Intelligence and Statistics. Sardinia, Italy: JMLR.org; 249-256
- Gori M, Monfardini G and Scarselli F. 2005. A new model for learning in graph domains//Proceedings of 2005 IEEE International Joint Conference on Neural Networks. Montreal, Canada: IEEE; 729-734 [DOI: 10.1109/IJCNN.2005.1555942]
- Guo Q, Li M, Wang C H, Wang P H, Fang Z C, Tan J, Wu S F, Xiao Y H and Zhu H Q. 2020. Host and infectivity prediction of Wuhan

- 2019 novel coronavirus using deep learning algorithm [EB/OL]. [2020-01-21]. <https://www.biorxiv.org/content/10.1101/2020.01.21.914044v2.full.pdf>
- Guo S N, Lin Y F, Feng N, Song C and Wan H Y. 2019. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting//Proceedings of the 33rd AAAI Conference on Artificial Intelligence. Honolulu, USA: AAAI; 922-929 [DOI: 10.1609/aaai.v33i01.3301922]
- Hamilton W L, Ying R and Leskovec J. 2017. Inductive representation learning on large graphs//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: NIPS; 1025-1035 [DOI: 10.5555/3294771.3294869]
- Kampffmeyer M, Chen Y B, Liang X D, Wang H, Zhang Y J and Xing E P. 2019. Rethinking knowledge graph propagation for zero-shot learning//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE; 11479-11488 [DOI: 10.1109/CVPR.2019.01175]
- Kipf T N and Welling M. 2016. Semi-supervised classification with graph convolutional networks [EB/OL]. [2020-08-18]. <https://arxiv.org/pdf/1609.02907v4.pdf>
- Li Q, Guan X H, Wu P, Wang X Y, Zhou L, Tong Y Q, Ren R Q, Leung K S M, Lau E H Y, Wong J Y, Xing X S, Xiang N J, Wu Y, Li C, Chen Q, Li D, Liu T, Zhao J, Liu M, Tu W X, Chen C D, Jin L M, Yang R, Wang Q, Zhou S H, Wang R, Liu H, Luo Y B, Liu Y, Shao G, Li H, Tao Z F, Yang Y, Deng Z Q, Liu B X, Ma Z T, Zhang Y P, Shi G Q, Lam T T Y, Wu J T, Gao G F, Cowling B J, Yang B, Leung C M and Feng Z J. 2020. Early transmission dynamics in Wuhan, China, of novel coronavirus - infected pneumonia. *New England Journal of Medicine*, 382 (13): 1199-1207 [DOI: 10.1056/NEJMoa2001316]
- Li R Y, Wang S, Zhu F Y and Huang J Z. 2018. Adaptive graph convolutional neural networks//Proceedings of the 32nd AAAI Conference on Artificial Intelligence. New Orleans, USA: AAAI; 3546-3553
- Li Y J, Tarlow D, Brockschmidt M and Zemel R. 2015. Gated graph sequence neural networks [EB/OL]. [2020-08-18]. <https://arxiv.org/pdf/1511.05493.pdf>
- Manessi F, Rozza A and Manzo M. 2020. Dynamic graph convolutional networks. *Pattern Recognition*, 97: #107000 [DOI: 10.1016/j.patcog.2019.107000]
- May R M, Anderson R M and McLean A R. 1988. Possible demographic consequences of HIV/AIDS epidemics. I. Assuming HIV infection always leads to AIDS. *Mathematical Biosciences*, 90 (1-2): 475-505 [DOI: 10.1016/0025-5564(88)90079-X]
- Merler S, Ajelli M, Pugliese A and Ferguson N M. 2011. Determinants of the spatiotemporal dynamics of the 2009 H1 N1 pandemic in Europe: implications for real-time modelling. *PLoS Computational Biology*, 7 (9): # e1002205 [DOI: 10.1371/journal.pcbi.1002205]
- Monti F, Boscaini D, Masci J, Rodolà E, Svoboda J and Bronstein M M. 2017. Geometric deep learning on graphs and manifolds using mixture model CNNs//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE; 5425-5434 [DOI: 10.1109/CVPR.2017.576]
- Niepert M, Ahmed M, Kutzkov K. 2016. Learning convolutional neural networks for graphs//Proceedings of the 33rd International Conference on Machine Learning (ICML). New York, USA: JMLR; 2014-2023. [DOI: abs/10.5555/3045390.3045603]
- Scarselli F, Gori M, Tsoi A C, Hagenbuchner M and Monfardini G. 2009. The graph neural network model. *IEEE Transactions on Neural Networks*, 20 (1): 61-80 [DOI: 10.1109/TNN.2008.2005605]
- Trivedi R, Farajtabar M, Biswal P and Zha H Y. 2019. Dyrep: learning representations over dynamic graphs//Proceedings of the 7th International Conference on Learning Representations. New Orleans, USA: OpenReview.net; 1-25
- Wu J T, Leung K and Leung G M. 2020. Nowcasting and forecasting the potential domestic and international spread of the 2019-nCoV outbreak originating in Wuhan, China: a modelling study. *The Lancet*, 395 (10225): 689-697 [DOI: 10.1016/S0140-6736(20)30260-9]
- Wu Z H, Pan S R, Chen F W, Long G D, Zhang C Q and Yu P S. 2021. A comprehensive survey on graph neural networks. *IEEE Transactions on Neural Networks and Learning Systems*, 32(1): 4-24 [DOI: 10.1109/TNNLS.2020.2978386]
- Xu X T, Chen P, Wang J F, Feng J N, Zhou H, Li X, Zhong W and Hao P. 2020. Evolution of the novel coronavirus from the ongoing Wuhan outbreak and modeling of its spike protein for risk of human transmission. *Science China Life Sciences*, 63 (3): 457-460 [DOI: 10.1007/s11427-020-1637-5]
- Yu B, Yin H T and Zhu Z X. 2018. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting//Proceedings of the 27th International Joint Conference on Artificial Intelligence. Stockholm, Sweden: IJCAI; 3634-3640 [DOI: 10.24963/ijcai.2018/505]
- Zhang Y Z, Xiong Y, Kong X N, Li S S, Li J H and Zhu Y Y. 2018. Deep collective classification in heterogeneous information networks//Proceedings of 2018 World Wide Web Conference. Lyon, France: ACM; 399-408 [DOI: 10.1145/3178876.3186106]
- Zhao L, Song Y J, Zhang C, Liu Y, Wang P, Lin T, Deng M and Li H F. 2020. T-GCN: a temporal graph convolutional network for traffic prediction. *IEEE Transactions on Intelligent Transportation Systems*, 21(8): 3848-3858 [DOI: 10.1109/ITITS.2019.2935152]
- Zhou J, Cui G Q, Zhang Z Y, Yang C, Liu Z Y, Wang L F, Li C C and Sun M S. 2018. Graph neural networks: a review of methods and applications [EB/OL]. [2020-08-18]. <https://arxiv.org/pdf/1812.08434.pdf>
- Zhou T, Liu Q H, Yang Z M, Liao J Y, Yang K X, Bai W, Lu X and

Zhang W. 2020. Preliminary prediction of the basic reproduction number of the Wuhan novel coronavirus 2019-nCoV. *Journal of Evidence - Based Medicine*, 13 (1): 3-7 [DOI: 10.1111/jebm.12376]

作者简介



杨成意, 1994年生, 男, 硕士研究生, 主要研究方向为深度学习的理论和应用、图数据挖掘。

E-mail: 19349034@suibe.edu.cn



齐佳音, 通信作者, 女, 教授, 主要研究方向为信息系统决策、区块链理论和应用。

E-mail: qijiayin@139.com

刘峰, 男, 博士研究生, 主要研究方向为区块链、卷积神经网络。E-mail: lsttoy@163.com

段妍, 女, 硕士研究生, 主要研究方向为时间序列数据建模与预测。E-mail: 19349002@suibe.edu.cn

吕润倩, 女, 硕士研究生, 主要研究方向为复杂网络建模、时间序列数据处理。E-mail: 19349006@suibe.edu.cn

肖子龙, 男, 博士研究生, 主要研究方向区块链、金融科技、数据科学。E-mail: shenciyou@gmail.com