



(12) 发明专利申请

(10) 申请公布号 CN 115496202 A

(43) 申请公布日 2022. 12. 20

(21) 申请号 202211094177.3

(22) 申请日 2022.09.08

(71) 申请人 同济大学

地址 200092 上海市杨浦区四平路1239号

(72) 发明人 关佶红 孔令百 杨涵晨 李文根
张毅超

(74) 专利代理机构 上海德昭知识产权代理有限公司 31204

专利代理师 陈龙梅

(51) Int. Cl.

G06N 3/08 (2006.01)

G06N 3/04 (2006.01)

G08G 1/01 (2006.01)

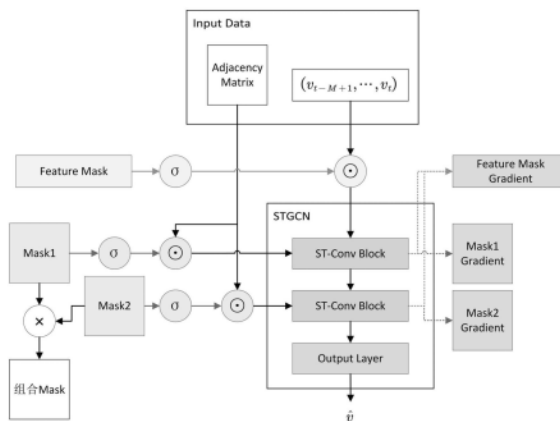
权利要求书2页 说明书13页 附图8页

(54) 发明名称

面向交通拥堵预测的可解释性时空分析方法

(57) 摘要

本发明提供一种面向交通拥堵预测的可解释性时空分析方法,从解释中提取得到引发拥堵事件的关键特征和道路间的深层联系。传统的数据挖掘方法往往从统计学角度探索交通时空数据间的相关性联系,难以充分揭示交通拥堵的深层联系和关键因素。因此本发明提出基于STGCN的时空解释生成模型,利用神经网络善于发现隐藏特征的特点,使用深度学习的可解释性技术提取神经网络关注的关键输入特征。模型使用基于扰动的解释方法生成掩膜(mask),使用基于梯度的解释方法生成掩膜的梯度映射;又鉴于空域掩膜粒度粗、针对性差的问题,提出分步掩膜方法降低解释粒度。如此,增加了对隐藏信息的有效提取,从而获得了更加准确全面的拥堵关键信息。



1. 一种面向交通拥堵预测的可解释性时空分析方法,其特征在于,包括以下步骤:

步骤S1,对被解释模型STGCN进行预训练;

步骤S2,构造时空解释生成模型,其包括:

经预训练的所述STGCN;

两张初始空域掩膜,用于在所述STGCN两次空域卷积过程中,对输入拓扑图的边进行遮盖,从而提取所述STGCN给出预测时的空间偏好;以及

初始时域掩膜,用于在训练过程中,对所述输入拓扑图的各节点的历史速度序列特征进行遮盖,从而提取所述STGCN给出预测时的时间偏好;

步骤S3,对所述时空解释生成模型进行训练,包括:

将训练数据输入所述时空解释生成模型,所述时空解释生成模型基于所述初始空域掩膜和所述初始时域掩膜,使用基于扰动的解释方法生成两个空域掩膜和多个时域掩膜,并使用基于梯度的解释方法获取各个所述空域掩膜和各个所述时域掩膜的梯度映射;

步骤S4,所述时空解释生成模型将两张所述空域掩膜组合成组合掩膜,用于分离二阶空间关系,并对多个所述时域掩膜进行谱聚类,得到平均时域掩膜;

步骤S5,将目标地区的交通数据输入训练好的所述时空解释生成模型得到预测结果,并利用所述组合掩膜、所述平均时域掩膜、所述交通数据中道路节点的POI信息从所述时空解释生成模型中提取道路拥堵关键信息。

2. 根据权利要求1所述的面向交通拥堵预测的可解释性时空分析方法,其特征在于:

其中,步骤S2中,所述初始空域掩膜的大小与所述输入拓扑图的邻接矩阵大小相同,用于对所述邻接矩阵的边权值进行遮盖,

所述初始时域掩膜的大小与所述输入拓扑图的节点特征向量大小相同,用于对各所述节点的输入进行遮盖,

步骤S3中,所述时空解释生成模型的目标是学习到所述空域掩膜M和所述时域掩膜F,使得:

$$\min_{\mathbf{M}} (\mathbf{Y} - \mathcal{G}(\mathbf{G}, \mathbf{X} | \mathbf{G} = \mathbf{G}_S, \mathbf{X} = \mathbf{X}_S))$$

式中,Y代表真实值,G代表STGCN给出的预测, \mathbf{G}_S 代表拓扑邻接矩阵经过空域掩膜M遮盖后的结果, \mathbf{X}_S 代表特征经过时域掩膜F遮盖后的结果。

3. 根据权利要求1所述的面向交通拥堵预测的可解释性时空分析方法,其特征在于:

其中,所述STGCN包括两个空域卷积块,所述时空解释生成模型训练两张独立的所述空域掩膜,分别为第一空域掩膜和第二空域掩膜,分别运用于两个所述空域卷积块的两次卷积操作中,

步骤S3中,对于第一个所述空域卷积块,对应的所述第一空域掩膜上某一条边 $e_1(v_i, v_j)$ 在训练中的变化值为:

$$\Delta e_1(v_i, v_j) = \sum_{v_t \in N(v_i) \cup N(v_j)} \frac{\partial (y - \hat{y}(v_t))}{\partial e(v_i, v_j)}$$

对于第二个所述空域卷积块,对应的所述第二空域掩膜上某一条边 $e_2(v_i, v_j)$ 在训练中的变化值为:

$$\nabla e_2(v_i, v_j) = \frac{\partial(y - \hat{y}(v_i))}{\partial e(v_i, v_j)} + \frac{\partial(y - \hat{y}(v_j))}{\partial e(v_i, v_j)}$$

式中, $N(v_i)$ 为节点 v_i 的邻居节点, $N(v_j)$ 为节点 v_j 的邻居节点, 经过训练, 所述第一空域掩膜学习到边对于二阶邻居节点的权重信息, 所述第二空域掩膜学习到边对于一阶邻居节点的权重信息,

所述二阶邻居节点之间的信息卷积权重表示为:

$$e_1(v_i, v_j) \cdot e(v_j, v_k)。$$

4. 根据权利要求3所述的面向交通拥堵预测的可解释性时空分析方法, 其特征在于:

其中, 步骤S4中, 计算所述第一空域掩膜和所述第二空域掩膜的矩阵乘积, 从而构造出所述组合掩膜:

$$M_3 = M_1 \times M_2$$

式中, M_1 为所述第一空域掩膜, M_2 为所述第二空域掩膜,

所述组合掩膜 M_3 中存在实际并不相连的边, 表示所述二阶邻居节点间对彼此的关键性权重。

5. 根据权利要求1所述的面向交通拥堵预测的可解释性时空分析方法, 其特征在于:

其中, 步骤S3中, 在所述时空解释生成模型训练过程中, 记录所述空域掩膜的梯度值作为所述空域掩膜权重重要性依据, 记录所述时域掩膜的梯度值作为所述时域掩膜权重重要性依据。

6. 根据权利要求1所述的面向交通拥堵预测的可解释性时空分析方法, 其特征在于:

其中, 步骤S4中, 度量各个所述时域掩膜的相似度, 并基于所述相似度使用谱聚类方法对多个所述时域掩膜进行聚类, 从而对所述输入拓扑图的各类节点的时域共性进行解释。

7. 根据权利要求6所述的面向交通拥堵预测的可解释性时空分析方法, 其特征在于:

其中, 步骤S4中, 计算两个所述时域掩膜 m_1 和 m_2 的相似度时, 采用指数加权移动平均法, 两个所述时域掩膜 m_1 和 m_2 在第一个时间片处的差异为:

$$d[1] = |m_1[1] - m_2[1]|$$

在第 i 个时间片处的差异为:

$$d[i] = 1.1 * d[i-1] + |m_1[i] - m_2[i]|$$

通过上述公式迭代计算, 得到两个所述时域掩膜 m_1 和 m_2 的差异值, 再使用高斯核函数将所述差异值转化为相似值。

面向交通拥堵预测的可解释性时空分析方法

技术领域

[0001] 本发明属于机器学习技术领域,具体涉及一种面向交通拥堵预测的可解释性时空分析方法。

背景技术

[0002] 随着社会经济的飞速发展和城市居民出行需求的不断增加,交通供需矛盾日益凸显。据调查显示,大多数交通拥堵事件都与拥堵关键点有关。因此,分析城市中的拥堵事件,挖掘拥堵事件中的关键要点就显得尤为重要。然而提取整个交通路网的拥堵关键点是一个有难度的任务,一方面路网中的道路复杂地交织在一起,使得道路间的影响关系高度耦合,分析过程中难以抓取重点;另一方面,影响道路拥堵的因素有很多维度,不同路段间既存在时间关系又存在空间关系,道路附近的POI等社会信息也会影响到拥堵事件的发展过程。

[0003] 近年来,在交通拥堵数据挖掘领域国内外研究者做出了很多工作。一种流行的方法是对道路进行聚类分析,通过将路况序列相似的路段聚集到一类从中寻找拥堵的共性;另一种流行的方法是提取路段间的关联规则,得到不同道路间的影响关系,从而推断道路拥堵的关键发生点和传播点。

[0004] 深度学习的可解释性方法能够为交通预测模型的预测生成解释,解释中包含了影响交通拥堵的关键信息,也可以作为数据挖掘的一种方式。可解释性技术可以分为事前解释和事后解释两大方面。事前解释技术是指在神经网络中设计部署更多的可解释性机制,例如设计正则化技术以增强可解释性;事后解释技术保持原有模型结果,解释过程与预测过程的耦合度很低,解释过程不会降低被解释模型的准确率,但是解释结论通常并不完全忠实于原有模型。目前的可解释性研究大多集中于事后解释,尤其是事后解释中的显著性方法。在图神经网络中,可以进一步将事后解释技术分解为基于梯度和特征的方法、基于扰动的方法、基于分解的方法和基于代理的方法。在基于梯度和特征的方法中,输入数据内不同特征的重要性由梯度或特征值表示。基于扰动的方法考察输入发生变化时对模型输出结果的扰动情况,对模型的输出影响越大输入数据越重要。分解方法使用数学分解手段(如展开式近似)将模型输出结果进行展开分解,并将分解依次反向传播到隐层神经节点直至输入数据,输入数据的分解结果即为其在解释性分析中的重要性度量。代理方法是指基于被解释模型的行为基础,在各个分类标准下的各个样例的生成数据集上训练一个更加简单的代理模型,代理模型相较于被解释模型具有更强的可解释性,最终通过解释代理模型完成对被解释模型的解释分析。

[0005] 交通聚类难以结合时空信息,所得到的结果大多是地理上的划分,无法精确地反映出拥堵的关键点,并且聚类结果与城市功能规划同质,结论往往需要社会科学知识的支撑,这使得聚类方法难以发现有价值的拥堵关键信息。关联分析方法无法充分聚合路段间的拓扑关系和路段时空特征,在模型复杂度上无法比拟人工神经网络,因此还不能充分揭示交通拥堵的深层联系与关键因素。而对于神经网络的可解释性方法领域中,大多数研究都是针对分类问题,而交通预测属于回归问题,在其上进行的可解释性研究很少。交通预测

的可解释性研究方法大多是借助注意力机制对模型进行解释,没有发挥图神经网络模型抽取路网空间信息的优势,因此作出的解释并不深入。

[0006] 因此,亟需设计一种能够克服上述缺陷的技术方案。

发明内容

[0007] 本发明是为解决上述问题而进行的,目的在于提供一种可准确对交通拥堵情况进行预测、且具有可解释性的分析方法,本发明采用了如下技术方案:

[0008] 本发明提供了一种面向交通拥堵预测的可解释性时空分析方法,其特征在于,包括以下步骤:

[0009] 步骤S1,对被解释模型STGCN进行预训练;

[0010] 步骤S2,构造时空解释生成模型,其包括:

[0011] 经预训练的所述STGCN;

[0012] 两张初始空域掩膜,用于在所述STGCN两次空域卷积过程中,对输入拓扑图的边进行遮盖,从而提取所述STGCN给出预测时的空间偏好;以及

[0013] 初始时域掩膜,用于在训练过程中,对所述输入拓扑图的各节点的历史速度序列特征进行遮盖,从而提取所述STGCN给出预测时的时间偏好;

[0014] 步骤S3,对所述时空解释生成模型进行训练,包括:

[0015] 将训练数据输入所述时空解释生成模型,所述时空解释生成模型基于所述初始空域掩膜和所述初始时域掩膜,使用基于扰动的解释方法生成两个空域掩膜和多个时域掩膜,并使用基于梯度的解释方法获取各个所述空域掩膜和各个所述时域掩膜的梯度映射;

[0016] 步骤S4,所述时空解释生成模型将两张所述空域掩膜组合成组合掩膜,用于分离二阶空间关系,并对多个所述时域掩膜进行谱聚类,得到平均时域掩膜;

[0017] 步骤S5,将目标地区的交通数据输入训练好的所述时空解释生成模型得到预测结果,并利用所述组合掩膜、所述平均时域掩膜、所述交通数据中道路节点的POI信息从所述时空解释生成模型中提取道路拥堵关键信息。

[0018] 本发明提供的面向交通拥堵预测的可解释性时空分析方法,还可以具有这样的技术特征,其中,步骤S2中,所述初始空域掩膜的大小与所述输入拓扑图的邻接矩阵大小相同,用于对所述邻接矩阵的边权值进行遮盖,所述初始时域掩膜的大小与所述输入拓扑图的节点特征向量大小相同,用于对各所述节点的输入进行遮盖,步骤S3中,所述时空解释生成模型的目标是学习到所述空域掩膜M和所述时域掩膜F,使得:

$$[0019] \quad \min_M (Y - \mathcal{G}(G, X | G = G_S, X = X_S))$$

[0020] 式中,Y代表真实值, \mathcal{G} 代表STGCN给出的预测, G_S 代表拓扑邻接矩阵经过空域掩膜M遮盖后的结果, X_S 代表特征经过时域掩膜F遮盖后的结果。

[0021] 本发明提供的面向交通拥堵预测的可解释性时空分析方法,还可以具有这样的技术特征,其中,所述STGCN包括两个空域卷积块,所述时空解释生成模型训练两张独立的所述空域掩膜,分别为第一空域掩膜和第二空域掩膜,分别运用于两个所述空域卷积块的两次卷积操作中,步骤S3中,对于第一个所述空域卷积块,对应的所述第一空域掩膜上某一条边 $e_1(v_i, v_j)$ 在训练中的变化值为:

$$[0022] \quad \Delta e_1(v_i, v_j) = \sum_{v_t \in N(v_i) \cup N(v_j)} \frac{\partial(y - \hat{y}(v_t))}{\partial e(v_i, v_j)}$$

[0023] 对于第二个所述空域卷积块,对应的所述第二空域掩膜上某一条边 $e_2(v_i, v_j)$ 在训练中的变化值为:

$$[0024] \quad \nabla e_2(v_i, v_j) = \frac{\partial(y - \hat{y}(v_i))}{\partial e(v_i, v_j)} + \frac{\partial(y - \hat{y}(v_j))}{\partial e(v_i, v_j)}$$

[0025] 式中, $N(v_i)$ 为节点 v_i 的邻居节点, $N(v_j)$ 为节点 v_j 的邻居节点。

[0026] 经过训练,所述第一空域掩膜学习到边对于二阶邻居节点的权重信息,所述第二空域掩膜学习到边对于一阶邻居节点的权重信息,所述二阶邻居节点之间的信息卷积权重表示为:

$$[0027] \quad e_1(v_i, v_j) \cdot e(v_j, v_k)。$$

[0028] 本发明提供的面向交通拥堵预测的可解释性时空分析方法,还可以具有这样的技术特征,其中,步骤S4中,计算所述第一空域掩膜和所述第二空域掩膜的矩阵乘积,从而构造出所述组合掩膜:

$$[0029] \quad M_3 = M_1 \times M_2$$

[0030] 式中, M_1 为所述第一空域掩膜, M_2 为所述第二空域掩膜,

[0031] 所述组合掩膜 M_3 中存在实际并不相连的边,表示所述二阶邻居节点间对彼此的关键性权重。

[0032] 本发明提供的面向交通拥堵预测的可解释性时空分析方法,还可以具有这样的技术特征,其中,步骤S3中,在所述时空解释生成模型训练过程中,记录所述空域掩膜的梯度值作为所述空域掩膜权重重要性依据,记录所述时域掩膜的梯度值作为所述时域掩膜权重重要性依据。

[0033] 本发明提供的面向交通拥堵预测的可解释性时空分析方法,还可以具有这样的技术特征,其中,步骤S4中,度量各个所述时域掩膜的相似度,并基于所述相似度使用谱聚类方法对多个所述时域掩膜进行聚类,从而对所述输入拓扑图的各类节点的时域共性进行解释。

[0034] 本发明提供的面向交通拥堵预测的可解释性时空分析方法,还可以具有这样的技术特征,其中,步骤S4中,计算两个所述时域掩膜 m_1 和 m_2 的相似度时,采用指数加权移动平均法,两个所述时域掩膜 m_1 和 m_2 在第一个时间片处的差异为:

$$[0035] \quad d[1] = |m_1[1] - m_2[1]|$$

[0036] 在第 i 个时间片处的差异为:

$$[0037] \quad d[i] = 1.1 * d[i-1] + |m_1[i] - m_2[i]|$$

[0038] 通过上述公式迭代计算,得到两个所述时域掩膜 m_1 和 m_2 的差异值,再使用高斯核函数将所述差异值转化为相似值。

[0039] 发明作用与效果

[0040] 根据本发明的面向交通拥堵预测的可解释性时空分析方法,通过STGCN提取道路间的深层影响因素和时空关系,能够揭示交通拥堵的关键因素;在时空解释生成模型训练结束时,STGCN模型对交通预测的准确率也一同达到最高,间接完成了对解释结果的有效性

检验;将基于梯度和基于扰动的解释方法相结合,因此可获取STGCN模型的多角度解释;使用两张独立的空域掩膜,分别运用于STGCN的两次卷积操作中,即使用分步掩膜方法,将路网节点间的一阶关系与二阶关系分离,从而降低了解释粒度,提高了解释性能。

附图说明

- [0041] 图1是本发明实施例中的面向交通拥堵预测的可解释性时空分析方法的流程图;
- [0042] 图2是本发明实施例中基于STGCN的时空解释生成模型的原理图;
- [0043] 图3是本发明实施例中STGCN模型的原理图;
- [0044] 图4是本发明实施例中STGCN训练集损失下降曲线图;
- [0045] 图5是本发明实施例中STGCN验证集损失下降曲线图;
- [0046] 图6是本发明实施例中时空解释生成模型训练集损失下降曲线图;
- [0047] 图7是本发明实施例中时空解释生成模型验证集损失下降曲线图;
- [0048] 图8是本发明实施例中通过第一空域mask筛选边的结果图;
- [0049] 图9是本发明实施例中通过第二空域mask筛选边的结果图;
- [0050] 图10是本发明实施例中通过组合mask筛选边的结果图;
- [0051] 图11是在图10中标识聚焦区的示意图;
- [0052] 图12是本发明实施例中第一空域mask梯度映射图;
- [0053] 图13是本发明实施例中第二空域mask梯度映射图;
- [0054] 图14是本发明实施例中时域mask平均图;
- [0055] 图15是本发明实施例中各类时域mask的示意图;
- [0056] 图16是本发明实施例中各类时域mask梯度映射图;
- [0057] 图17是本发明实施例中POI信息统计的柱形图。

具体实施方式

[0058] 为了使本发明实现的技术手段、创作特征、达成目的与功效易于明白了解,以下结合实施例及附图对本发明的面向交通拥堵预测的可解释性时空分析方法作具体阐述。

[0059] <实施例>

[0060] 图1是本实施例中面向交通拥堵预测的可解释性时空分析方法的流程图。

[0061] 如图1所示,面向交通拥堵预测的可解释性时空分析方法包括以下步骤:

[0062] 步骤S1,对被解释模型STGCN进行预训练;

[0063] 步骤S2,基于预训练的STGCN构建时空解释生成模型;

[0064] 步骤S3,利用交通数据对时空解释生成模型进行训练,模型学习得到两张空域mask(掩膜),多张时域mask;

[0065] 步骤S4,时空解释生成模型将两张空域mask组合成组合mask,用于分离二阶空间关系,并对多张时域mask进行谱聚类,得到平均时域mask;

[0066] 步骤S5,将目标地区的交通数据输入时空解释生成模型得到预测结果,并利用组合mask、平均时域mask、道路节点的POI信息从时空解释生成模型中提取道路拥堵关键信息。

[0067] 以下将详细说明各步骤。

[0068] 步骤S1,利用交通数据对被解释模型STGCN进行预训练。

[0069] STGCN的时空卷积核能够充分提取交通数据中的时空信息并将时空信息记录至其隐层参数中。

[0070] 图3是本实施例中STGCN模型的原理图。

[0071] 如图3所示,STGCN主要分为三层,分别是两个时空卷积块(ST-Conv Block)和一个输出全连接层(Output Layer)。每个时空卷积块包含两个时域门控卷积层和中间的一个空域图卷积层,在每个模块(即时空卷积块)内部应用残差连接。时空交通数据由时空卷积块统一处理,充分提取时空特征,最终由输出全连接层集成综合特征,生成最终预测。STGCN模型损失函数使用masked_mse,仅计算预测结果不为0的节点预测值与其真实值之间的差值并返回整体差异平均值。

[0072] STGCN的空域卷积过程中在拉普拉斯矩阵上进行的。设邻接矩阵为A,拉普拉斯矩阵可定义为: $L=D-A$,其中D是A的度矩阵,在STGCN模型中对拉普拉斯矩阵采用了标准化的方法: $L=I-D^{-1/2}WD^{-1/2}$ 。然后对矩阵进行正交对角化,得到一个正交矩阵P和一个对角矩阵D,使得 $L=PDP^{-1}=PDP^T$ 。其中P的列向量为L的特征向量 u_1, \dots, u_n ,D中的对角元素是对应的特征值 $\lambda_1, \dots, \lambda_n$ 。

[0073] 由卷积定理可知,函数卷积的傅里叶变换是函数傅里叶变换的卷积,即节点特征 $f(t)$ 和卷积核 $h(t)$ 两者的卷积是其函数傅里叶变换乘积的逆变换:

$$[0074] \quad f * h = \mathcal{F}^{-1}[f(\omega)\hat{h}(\omega)] = \frac{1}{2\pi} \int f(\omega)\hat{h}(\omega)e^{i\omega t} d\omega$$

[0075] 将卷积定理推广到图上可得:

$$[0076] \quad (f * h)_G = P \begin{pmatrix} \hat{h}(\lambda_1) & & \\ & \ddots & \\ & & \hat{h}(\lambda_n) \end{pmatrix} P^T f$$

[0077] 构造 $\hat{h}(\lambda_l)$ 为 $\sum_{j=0}^K \alpha_j \lambda_l^j$,其中 α 是神经网络定义的参数,则有:

$$[0078] \quad (f * h)_G = P \begin{pmatrix} \sum_{j=0}^K \alpha_j \lambda_1^j & & \\ & \ddots & \\ & & \sum_{j=0}^K \alpha_j \lambda_n^j \end{pmatrix} P^T f = P \sum_{j=0}^K \alpha_j D^j P^T f = \sum_{j=0}^K \alpha_j P D^j P^T f = \sum_{j=0}^K \alpha_j L^j f$$

[0079] 这样构造卷积核使得拉普拉斯矩阵不需要做谱分解也可以完成卷积操作,另一方面卷积核具有良好的空间特征,超参数K表明了卷积核的感受野,即每次卷积操作将对节点的K阶邻居的向量进行加权求和。

[0080] 为了减少参数的数量、优化STGCN模型计算性能,切比雪夫多项式近似可以将卷积核限制为关于拉普拉斯矩阵L的多项式:

$$[0081] \quad \theta(L) = \sum_{k=0}^{K-1} \theta_k L^k$$

[0082] 式中, $\theta \in \mathbb{R}^k$ 是多项式系数矩阵,K是图卷积核的大小,它决定了中央节点的卷积的

最大半径(感受野)。用k阶的切比雪夫多项式 $T_k(\cdot)$ 近似表示特征值矩阵: $T_k(\tilde{L})$,其中L需要进行平均归一化,因为切比雪夫多项式的定义域为 $[-1, 1]$ 。平均归一化过程如下:已知拉普拉斯矩阵是半正定矩阵,特征值非负,因此可以用最大特征值除拉普拉斯矩阵,将拉普拉斯矩阵放缩到 $[0, 1]$,然后乘2减去单位阵变换到 $[-1, 1]$,即: $\tilde{L} = 2L/\lambda_{max} - I$,将其应用到卷积函数中得到:

$$[0083] \quad (f * h)_G = \sum_{j=0}^{K-1} \alpha_j T_j(\tilde{L}) f$$

[0084] 切比雪夫多项式的递推公式为: $T_0(\tilde{L}) = I, T_1(\tilde{L}) = \tilde{L}, T_k(\tilde{L}) = 2\tilde{L}T_{k-1}(\tilde{L}) - T_{k-2}(\tilde{L})$,指定超参数K可以由递推公式计算得到指定阶数的切比雪夫多项式近似卷积核。因此,通过切比雪夫近似,减少了卷积核中参数的数量,降低了复杂度,提高了STGCN模型的性能。

[0085] 切比雪夫多项式近似要求先将拉普拉斯矩阵平均归一化,其中需要用到拉普拉斯矩阵的最大特征值,原模型计算了拉普拉斯矩阵的所有特征值,无用计算多。下面将介绍使用幂迭代法直接获取最大特征值近似值的优化方法。根据谱图理论可知,拉普拉斯矩阵一定可以进行谱分解,假设给定一拉普拉斯矩阵L,其特征值为 $\lambda_1, \dots, \lambda_n$,对应的特征向量为 u_1, \dots, u_n ,其中 u_1, \dots, u_n 构成一组正交基。此时引入任意n维向量x,可以用正交基 u_1, \dots, u_n 对x进行表示: $x = \alpha_1 u_1 + \alpha_2 u_2 + \dots + \alpha_n u_n$,然后做矩阵乘法:

$$[0086] \quad Lx = L\alpha_1 u_1 + L\alpha_2 u_2 + \dots + L\alpha_n u_n = \lambda_1 \alpha_1 u_1 + \lambda_2 \alpha_2 u_2 + \dots + \lambda_n \alpha_n u_n$$

[0087] 迭代以上操作k次,可得:

$$[0088] \quad L^k x = \lambda_1^k \alpha_1 u_1 + \lambda_2^k \alpha_2 u_2 + \dots + \lambda_n^k \alpha_n u_n$$

[0089] 设 $\lambda_m = \max(\lambda_1, \dots, \lambda_n)$,则变换上式如下:

$$[0090] \quad \frac{L^k x}{\lambda_m^k} = \left(\frac{\lambda_1}{\lambda_m}\right)^k \alpha_1 u_1 + \left(\frac{\lambda_2}{\lambda_m}\right)^k \alpha_2 u_2 + \dots + \alpha_m u_m + \dots + \left(\frac{\lambda_n}{\lambda_m}\right)^k \alpha_n u_n$$

[0091] 当 $k \rightarrow \infty$ 时 $L^k x / \lambda_m^k \rightarrow \alpha_m u_m$,也就是说在向x做L的迭代乘法时,其结果将收敛至与L的最大特征值对应的特征向量的方向,此时有: $L^k x / L^{k-1} x \rightarrow \lambda_m^k \alpha_m u_m / \lambda_m^{k-1} \alpha_m u_m = \lambda_m$,这样便可以得到L的最大特征值。

[0092] STGCN的时空卷积块包含一个一维卷积操作,该卷积操作使用 K_t 大小的卷积核,其后加入了一个门控线性单元(GLU)提供非线性性。对于拓扑图中的每一个节点,时空卷积块读取了输入元素的 K_t 阶邻居,由于卷积过程没有添加padding,因此每一次卷积将使时间序列减少 $K_t - 1$ 长度。如此,每个节点的时间卷积的输入可以被视为一个长度为M,通道数为 C_i 的序列: $Y \in \mathbb{R}^{M \times C_i}$;卷积核 $\Gamma \in \mathbb{R}^{K_t \times C_i \times 2C_0}$ 将输入Y映射到单个输出元素 $[P \ Q] \in \mathbb{R}^{(M-K_t+1) \times (2C_0)}$,其中 $[P \ Q]$ 将结果分为通道数相同的一半。由此可得时域门控卷积的表示: $\Gamma_{*T} Y = P \odot \sigma(Q) \in \mathbb{R}^{(M-K_t+1) \times C_0}$,其中P,Q是GLU的输入,Sigmoid门 $\sigma(Q)$ 控制当前状态输入P的哪些部分有助于发现时间序列中的组成结构和动态差异,非线性门也有助于利用堆叠时间层的输

入,并在堆叠时域卷积层之间实现了残差连接。

[0093] 步骤S2,基于预训练的STGCN构建时空解释生成模型。

[0094] 图2是本实施例中时空解释生成模型的原理图。

[0095] 如图2所示,本实施例中,时空解释生成模型基于预训练的STGCN构建,其核心功能是生成时空mask,时空解释生成模型包括经预训练的STGCN、两张可学习的初始空域mask、一张可学习的初始时域mask。

[0096] 由于交通数据属于时空数据,因此需要在时间和空间上分别构建mask。

[0097] 在空间域,时空解释生成模型使用两张与输入拓扑图的邻接矩阵大小相同的空域mask对邻接矩阵的边权值进行遮盖,并分别应用至STGCN的两个时空卷积块中,提取STGCN给出预测时的空间偏好。

[0098] 在时间域,使用一张与输入拓扑图的节点特征向量大小相同的时域mask对输入拓扑图的各个节点的输入进行遮盖,提取出STGCN给出预测时的时间偏好。

[0099] 最终,通过空域mask和时域mask得到交通拥堵的关键信息。

[0100] 时空解释生成模型需要在初始化时载入STGCN的预训练结构与输入参数,然后根据STGCN的预训练结果初始化其参数,之后构造两张可学习的初始空域mask和一张可学习的初始时域mask。初始空域mask、初始时域mask均初始化为0,表示不选择任何特征,之后在时空解释生成模型的训练过程中完成空域mask、时域mask的学习,提取关键特征。时空解释生成模型的正向传播与损失函数均调用STGCN的对应函数。各个mask及其梯度信息的保存在时空解释生成模型的析构函数中完成。

[0101] 时空解释生成模型在STGCN上学习得到空域mask,对其输入拓扑图上的边进行遮盖,从而识别出对STGCN最有影响的图模式;在STGCN上学习得到时域mask,对输入拓扑图的各个节点的历史速度序列特征进行遮盖,从而识别出对STGCN最有影响的时间模式。

[0102] 步骤S3,利用交通数据对时空解释模型进行训练。

[0103] 即,将训练用的交通数据输入时空解释模型进行训练,时空解释模型基于初始空域mask和初始时域mask,使用基于扰动的解释方法生成两个空域mask和多个时域mask,并使用基于梯度的解释方法获取各个空域mask和时域mask的梯度映射。

[0104] 对于交通网络中的节点集 V ,时空解释生成模型的目标是学习到空域mask M 和时域mask F ,使得 $\min_M(Y - \mathcal{G}(G, X | G = G_S, X = X_S))$,其中 Y 代表真实值, \mathcal{G} 代表STGCN神经网络给出的预测, G_S 代表拓扑邻接矩阵经过 M 遮盖后的结果, X_S 代表特征经过 F 遮盖后的结果。

[0105] 在实际的时空解释生成模型中,由于交通网络是无向图,所以需要保证空域mask是一个对称阵,解决方法是计算空域mask与其转置的平均。此外还希望空域mask对于特征的选取二分化,所以再加入一个sigmoid函数激活,最终将原有空域mask处理为 $\text{Sigmoid}((M + M^T) / 2)$ 再去与邻接矩阵做哈达玛积(Hadamard product)。同理,时域mask也要经过sigmoid函数的激活再去遮盖输入序列特征。

[0106] 下面仅关注空域mask的数据流过程,设某一节点为 v ,其输入特征为 x_v , $N(v)$ 表示 v 的邻居节点,由于空域卷积设置的感受野仅包括节点的一阶邻居节点,可以将空域卷积抽象概括为:

$$[0107] \quad y_v = \frac{1}{\text{count}(N(v))} \sum_{v_i \in N(v)} x_{v_i}$$

[0108] 则输入数据在经过包含两个时空卷积块的STGCN神经网络后可以抽象表示为:

$$[0109] \quad y_v = \frac{1}{\text{count}(N(v))} \sum_{v_i \in N(v)} \frac{1}{\text{count}(N(v_i))} \sum_{v_j \in N(v_i)} x_{v_j}$$

[0110] 则在损失反向传播的过程中,一部分损失通过两个时空卷积块反向传播到 $e(v_i, v_j)$,另一部分损失通过第二个时空卷积块传播到 $e(v, v_i)$ 。则对于 $e(v_i, v_j)$,在训练过程中其变化值为:

$$[0111] \quad \Delta e(v_i, v_j) = \frac{\partial(y - \hat{y}(v_i))}{\partial e(v_i, v_j)} + \frac{\partial(y - \hat{y}(v_j))}{\partial e(v_i, v_j)} + \sum_{v_t \in N(v_i) \cup N(v_j)} \frac{\partial(y - \hat{y}(v_t))}{\partial e(v_i, v_j)}$$

[0112] 这表明,最终训练得到的空域mask中的一条边,不仅表示了该边对于其两端节点(边的一阶邻居节点)的关键性,还包含了改变对于其两端节点的邻居节点(边的二阶邻居节点)的关键性。因此在对解释结果进行分析时,难以明确指出某一条边对其附近节点的影响因素,导致了空域mask粒度粗,解释针对性差。为了解决这一问题,提出了分步mask的解决方案。

[0113] 分步mask是指训练两张独立的空域mask,分别运用于两次卷积操作中,从而将边对于其一阶节点邻居和对于其二阶节点邻居的权重分离,减小粒度,提高解释性能。依然使用上文定义的符号说明:对于第一个空域卷积块的空域mask(记作第一空域mask),其上某一条边 $e_1(v_i, v_j)$ 在训练中的变化值为:

$$[0114] \quad \Delta e_1(v_i, v_j) = \sum_{v_t \in N(v_i) \cup N(v_j)} \frac{\partial(y - \hat{y}(v_t))}{\partial e(v_i, v_j)}$$

[0115] 对于第二个空域卷积块的空域mask(记作第二空域mask),其上某一条边 $e_2(v_i, v_j)$ 在训练中的变化值为:

$$[0116] \quad \Delta e_2(v_i, v_j) = \frac{\partial(y - \hat{y}(v_i))}{\partial e(v_i, v_j)} + \frac{\partial(y - \hat{y}(v_j))}{\partial e(v_i, v_j)}$$

[0117] 因此,第一空域mask学习到了边对于二阶邻居节点的权重信息,第二空域mask学习到了边对于一阶邻居节点的权重信息。

[0118] 此外,时空解释生成模型通过记录模型训练过程中mask的梯度值来作为mask权重重要性依据。梯度映射的依据在于,如果某个参数的历史梯度都比较大,那么说明当该参数发生变化时对预测结果的扰动大,相应地,该参数也就更重要,从而具有解释意义。

[0119] 步骤S4,时空解释生成模型将两张空域mask组合成组合mask,用于分离二阶空间关系,并对多个时域mask进行谱聚类,得到平均时域mask。

[0120] 对于空域mask,如上所述,第一空域mask学习到了边对于二阶邻居节点的权重信息,第二空域mask学习到了边对于一阶邻居节点的权重信息。但是,对于第一空域mask而言,其某一条边 $e_1(v_i, v_j)$ 表示的可能是交通信息从 v_i 流向 $v_k, k \in N(v_j)$,这样对于最终的解

释并不直观,因为更希望用 $e(v_i, v_k)$, $k \in N(v_j)$ 来直接表示交通信息的传递权重。考察卷积过程,第一次卷积将 v_i 节点的信息卷积到了 v_j 上,第二次卷积过程又进一步将交通信息从 v_j 卷积到了 v_k 上,所以可以用 $e_1(v_i, v_j) \cdot e(v_j, v_k)$ 表示二阶邻居间的信息卷积权重,而由 v_i 传播到 v_k 的过程中可能会经过多种不同的中间节点,因此,最终可以计算两张分步mask的矩阵乘积,构造出一个新的组合mask: $M_3 = M_1 \times M_2$ 。 M_3 中存在很多实际并不相连的边,表示了二阶邻居间的对彼此的关键性权重。

[0121] 对于时域mask,在时空解释生成模型训练完成后,时空解释生成模型将会给每一个节点学习到一个时域mask,本实施例中,整个路网拓扑图中共有4500个节点,因此生成的时域mask的大小为 4500×12 ,是一个巨大的矩阵,这样很难对时域mask进行有效的分析,因此考虑将时域mask聚类,再在不同类别的层次上进行分析。

[0122] 在时域mask聚类过程中,首先要生成时域mask的相似矩阵,由于时域mask的平均向量显示,STGCN模型整体上更偏好最近的历史数据,因此在计算两个不同时域mask的相似程度时,采用指数加权移动平均法,越是靠前的mask差异,其权值更大,可用如下公式表示:

[0123] 设有两个时域mask: m_1 和 m_2 ,其在第一个时间片处的差异为 $d[1] = |m_1[1] - m_2[1]|$,在第 i 个时间片处的差异为: $d[i] = 1.1 * d[i-1] + |m_1[i] - m_2[i]|$,如此迭代计算,可以计算出两个时域mask的差异值,为了得到相似性矩阵还需要使用再使用高斯核函数将差异值转化为相似值。经过指数加权移动平均,最终将优先把在前几个时间片上权值相似的时域mask归为一类。然后在相似矩阵上完成谱聚类,谱聚类是一种基于图论的聚类方法,该算法根据给定的相似矩阵,并计算矩阵的特征值和特征向量,然后选择合适的特征向量聚类不同的数据点。

[0124] 步骤S5,将目标地区的交通数据输入训练好的时空解释生成模型得到预测结果,并利用组合mask、平均时域mask、交通数据中道路节点的POI信息从该预测结果中提取道路拥堵关键信息。

[0125] 本实施例中,采用上述方法在上海市交通路况数据集上进行实验。数据来自于高德地图开放平台和OSM(Open Street Map)开源地图平台,其中,高德地图开放平台为实验提供了交通路况历史数据和POI信息,OSM为实验提供了上海市路网的地理信息。采集数据完成后,进行数据的清洗,包括去除丢失值过多的数据、将各条道路的路况信息拼接为光栅图、生成交通路网拓扑图、将历史路况序列与交通路网拓扑图组合为时空数据结构Spatial Maps。

[0126] 首先,按步骤S1完成STGCN的预训练,batch size设置为64,训练50次,学习率为0.001。模型训练过程中在训练集上的损失下降曲线、在验证集上的损失下降曲线、和训练结果分别如图4、图5、表1所示。

[0127] 表1 STGCN训练结果表

time steps	MAE	MSE	RMSE	masked	masked	masked	masked	R2	EVAR
	MAE	MAPE	MSE	RMSE					
1	2.382102	16.991486	4.122073	2.306485	0.075482	14.696645	3.833620	0.870067	0.870218
2	2.556620	19.775135	4.446924	2.475774	0.080860	17.206638	4.148088	0.848619	0.848747
3	2.687374	22.528753	4.746447	2.603721	0.084576	19.821224	4.452103	0.826911	0.826960
4	2.788898	24.992134	4.999213	2.700757	0.087843	22.000170	4.690434	0.809120	0.809138
5	2.893265	27.661303	5.259401	2.801468	0.091245	24.409216	4.940568	0.788378	0.788650
6	3.006762	30.549232	5.527136	2.909965	0.094954	26.994223	5.195597	0.765468	0.766309
7	3.101566	32.536957	5.704117	2.999169	0.098296	28.669760	5.354415	0.751576	0.753096
8	3.196598	34.544258	5.877436	3.092093	0.101555	30.543175	5.526588	0.735310	0.737569
9	3.289267	36.544193	6.045179	3.176581	0.104547	32.086697	5.664512	0.721641	0.724554
10	3.381734	38.428364	6.199061	3.264225	0.107858	33.608418	5.797276	0.706623	0.710646
11	3.469676	40.315033	6.349412	3.345131	0.110837	35.062790	5.921384	0.692616	0.697618
12	3.558973	42.108410	6.489100	3.427486	0.113716	36.468822	6.038942	0.680125	0.686036

[0128] 由图4的损失下降曲线可以看出,STGCN模型在训练集上的损失值随着训练次数的增加而下降,在第35次训练后下降曲线趋于平稳。由图5可以看出,STGCN模型在验证集上的损失值波动较大,但总体呈下降趋势,在第35次训练后损失值收敛到22附近。最终训练结果如表1所示,对预测未来2个时间片的预测的MSE在20以内,对未来5个时间片的预测的MSE在30以内,预测结果较好。

[0130] 然后,按步骤S2构建时空解释生成模型,再按步骤S3固定STGCN的参数载入时空解释生成模型进行训练,训练过程中设置训练次数为10,这是因为更多的训练次数会导致损失值大幅度震荡而不收敛。时空解释生成模型训练过程中在训练集上的损失下降曲线、在验证集上的损失下降曲线、训练结果分别如图6、图7和表2所示。

[0131] 表2时空解释生成模型训练结果表

time steps	MAE	MSE	RMSE	masked	masked	masked	masked	R2	EVAR
	MAE	MAPE	MSE	RMSE					
1	3.381689	26.70907	5.168082	3.277515	0.100451	23.77352	4.87581	0.795757	0.799048
2	3.563776	30.04757	5.481567	3.46038	0.104947	26.96669	5.192946	0.769983	0.776265
3	3.784265	33.957	5.827263	3.682184	0.109638	30.79266	5.549113	0.739108	0.75104
4	4.003617	39.3993	6.276886	3.90218	0.114656	36.15005	6.012491	0.699084	0.716442
5	4.187274	44.5428	6.674039	4.086467	0.119297	41.17066	6.416437	0.659226	0.680273
6	4.320596	48.60022	6.971385	4.217685	0.123033	44.96475	6.705576	0.626887	0.648496
7	4.42399	52.35124	7.235415	4.318167	0.126194	48.4682	6.961911	0.600292	0.620927
8	4.52337	55.77242	7.468094	4.414835	0.129176	51.6545	7.187107	0.572653	0.592574
9	4.606215	58.10379	7.622584	4.489581	0.131785	53.51726	7.315549	0.557421	0.576137
10	4.693918	60.66229	7.7886	4.572846	0.134806	55.72772	7.4651	0.53688	0.553285
11	4.779348	63.36325	7.960104	4.653078	0.137391	58.09935	7.622293	0.516884	0.532367
12	4.855057	65.12591	8.070063	4.724016	0.139669	59.57265	7.718332	0.505274	0.519852

[0133] 由图6的损失下降曲线可以看出,时空解释生成模型在训练集上的损失下降曲线在第3次训练后趋于平稳,即损失值趋于平稳。由图7可以看出,时空解释生成模型在验证集上的损失下降曲线在第5次训练后趋于平稳,损失值稳定在45左右。最终训练结果如表2所示,时空解释生成模型对预测未来2个时间片的预测的MSE在30以内,对未来5个时间片的预测的MSE在45以内,相较于STGCN有较大幅度的下滑。这是因为在不改变STGCN参数的前提下,加入mask后的数据不可能与初始数据一致,因此预训练的参数与加入mask的数据不匹配,导致时空解释生成模型的损失值大大提升。虽然将STGCN引入解释生成模型后模型整体的性能下降了,但是固定STGCN的参数能够保证其模型结构不发生变化,保证解释信息不被耦合到STGCN中,使得解释结果忠于原始模型,因此后面的分析在固定STGCN参数的时空解释生成模型的训练结果上进行。

[0134] 接着分析空域mask。图8是通过第一空域mask筛选出权值大于0.5的边的结果图;图9是通过第二空域mask筛选出权值大于0.5的边的结果图。从图8-9可以发现,第一空域mask提取的平均权值要比第二空域mask的更小,权值大于0.5的边数也更少。这表明STGCN更关注来自于第二次卷积过程的信息,这是因为第二次卷积过程中包含第一次卷积的聚合信息,因此可以得到二阶邻居节点的历史路况,更多的信息提升了STGCN的预测性能。

[0135] 图10是通过组合mask筛选出权值大于0.4的边的结果图,图11是在图10基础上标识聚集区的示意图。从图10-11可以发现,组合mask的高权重路段存在小范围聚集的现象,比较明显的有市区西南的徐汇区、市区中心的静安区、黄浦江中段两岸的陆家嘴和杨浦区、浦东的金桥镇和浦南的三林镇。这些路段要么是区位中心,要么是工业经济区,这些地点对周围的交通有重要的影响,因此在解决城市拥堵时要重视具有城市副中心功能或进行集中工业生产的区域内的路段,以防拥堵辐射传播。

[0136] 图12和图13分别是两张空域mask的梯度映射图,绘图时选择梯度值大于0.1的边。从图12-13可以发现第一空域mask的梯度映射的平均值比第二空域mask的更大,大于0.1的边数也更多。这表明第一次卷积过程中的边对于STGCN准确率的影响要更大,分析原因为:第一次卷积过程中的路段路况信息能够传播到更远的范围,因此路段在第一次卷积的影响力要更大,此外还能够看到图中标明的路段大多数短程路段而非环城高架或高速路,这表明城内短程路对于交通的扰动能力要高于长程路,这可能是由于短程路的车况更复杂易堵,短程路的连接点更多、拥堵更易传播。因此在研究城市拥堵时要关注对周围环境更有影响力的短程道路,或连接点较多的道路。

[0137] 接着分析时域mask。图14是将所有路段的时域mask求平均的结果图,观察图14可知,从总体上讲,STGCN对当前时刻做出预测时,更关注于更近的历史数据(前15分钟内的时间片数据),尤其是前5~10分钟内第1个时间片,这说明在预测车速时,前5~10分钟的信息的参考性最大。此外还可以发现STGCN对于前7~9个时间片数据关注度也较高。从中能够发现路况的传播存在周期性,在前0~2个时间片内传播的是一阶邻居的路况,而前7~9个时间片传播的是二阶邻居的路况,因此推断路况通过路段传播到下一个路段的过程需要约35分钟。因此交通拥堵问题在时间上的关键点为前10分钟内和前35分钟的历史信息,拥堵事件在一条道路上的平均扩散时间为35分钟。

[0138] 图15是将时域mask聚类为四类后的各类平均时域mask的结果图,其中,四类平均时域mask中包含的时域mask个数分别为1270、1157、985、1087。仅通过观察图15可以发现,

第0类中前两个时间片的权值最大,类内的路段平均发生了67.6次拥堵;第1类在1~7范围内的时间片的权值都较大,类内路段平均发生了91.7次拥堵;第2类在所有时间片上的权值都较小,类内路段平均发生了53.2次拥堵;第三类仅在第0个时间片上有较大权值,类内路段平均发生了61.4次拥堵。图16是各类时域mask梯度映射的平均值,各类的差异并不明显,但却表现出较为一致的共性:在第0~6个之间片内梯度映射值表现为接近0的正值,而在第7个时间片后梯度映射普遍为负,尤其是最后一个时间片的梯度映射值明显小,这表明前几个时间片的数据发生变换对于STGCN模型准确率的影响较小,而后几个时间片对准确率的影响更大,这表明在研究道路拥堵关键点时主要研究前半个小时内的历史路况,更远的时间片信息要谨慎利用,因为过度重视半小时后的历史数据可能会导致对道路拥堵关键点的误判。

[0139] 之后统计各类的POI信息,结果如图17所示,整体上讲上述各类平均时域mask在各个POI上的平均分布的差别很小,这是因为城市中的各类设施总是均匀分布的,不可能出现差异很大的专用地块。但从相对较小的差异中仍然可以解释出有意义的信息:第0类节点在餐饮服务、购物服务、住宿服务上突出,路况主要受到10分钟内历史的影响,这表明具有消费类POI信息的路段的路况影响持续时间短;第1类节点在生活服务和公司企业上突出,并且是最容易发生拥堵的一类,其时域mask信息表明该类道路对于前1~7个时间片的历史数据敏感,对于第0个时间片反而没有那么重视,这可能是由于生活服务和公司企业是容易发生早高峰和晚高峰的地点,发生拥堵时拥堵范围更广,持续时间更长,所以路况影响持续时间较长,导致STGCN偏好更久远的历史信息;第2类节点在餐饮服务和政府机构及社会团体上突出,且是拥堵次数最少的一类,时域mask表明模型对于过去时间片普遍无喜好,这可能是由于该类路段路况普遍平稳,因此不需要关注过多信息即可对路况进行预测;第3类节点在购物服务和交通设施服务上突出,时域mask表明模型更关注最近的时间片,尤其是上一个时间片,这说明这类路段的路况数据影响力不持久,路况变化频繁,这与购物服务和交通设施附近的道路设施发达,路况复杂有关。

[0140] 实施例作用与效果

[0141] 根据本实施例提供的面向交通拥堵预测的可解释性时空分析方法,通过STGCN提取道路间的深层影响因素和时空关系,能够揭示交通拥堵的关键因素;在时空解释生成模型训练结束时,STGCN模型对交通预测的准确率也一同达到最高,间接完成了对解释结果的有效性检验;将基于梯度和基于扰动的解释方法相结合,因此可获取STGCN模型的多角度解释;使用两张独立的空域mask,分别运用于STGCN的两次卷积操作中,即使用分步mask方法,将路网节点间的一阶关系与二阶关系分离,从而降低了解释粒度,提高了解释性能。

[0142] 进一步,时空解释生成模型训练过程中,记录mask的梯度值来作为mask权重重要性依据。如果某个参数的历史梯度都较大,那么说明当该参数发生变化时对预测结果的扰动大,相应地,该参数也就更重要,从而具有解释意义。

[0143] 进一步,计算两张空域mask的矩阵乘积,构造出组合mask,其中存在很多实际并不相连的边,表示二阶邻居节点间对彼此的关键性权重,从而能够使得交通信息的传递权重的解释更为直观。

[0144] 进一步,由于解释生成模型将会给每一个节点学习一个时域mask,路网中节点数量多,因此生成的时域mask是一个巨大的矩阵,因此将时域mask进行谱聚类,再在不同类别

的层次上进行分析,从而可对时域mask进行有效分析。

[0145] 上述实施例仅用于举例说明本发明的具体实施方式,而本发明不限于上述实施例的描述范围。

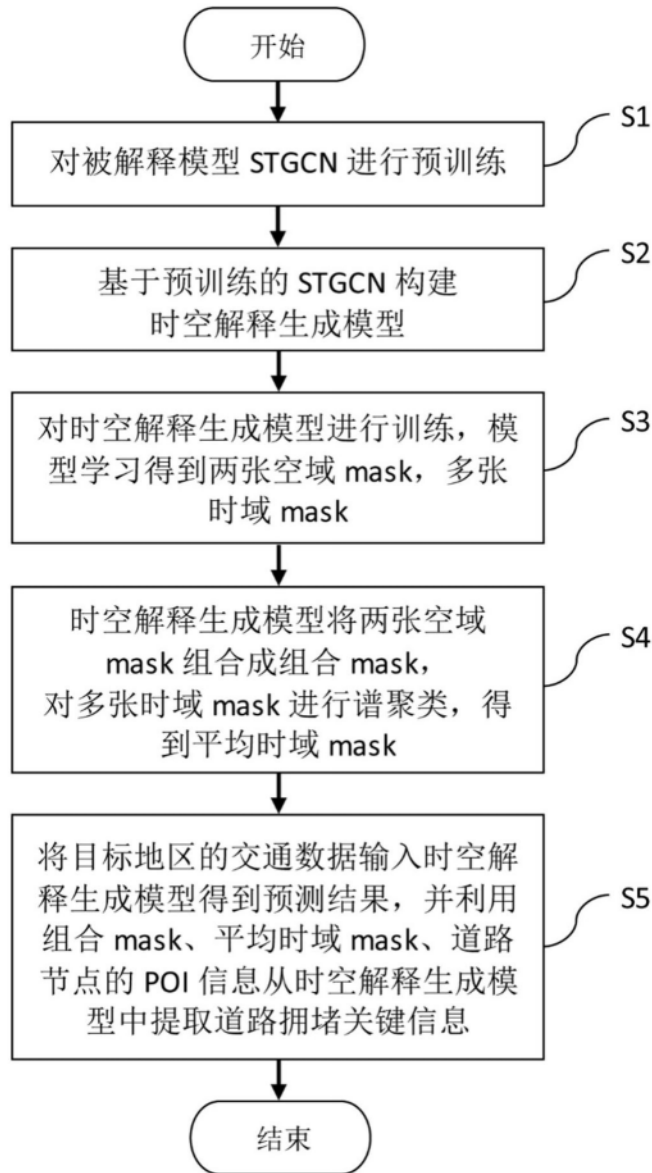


图1

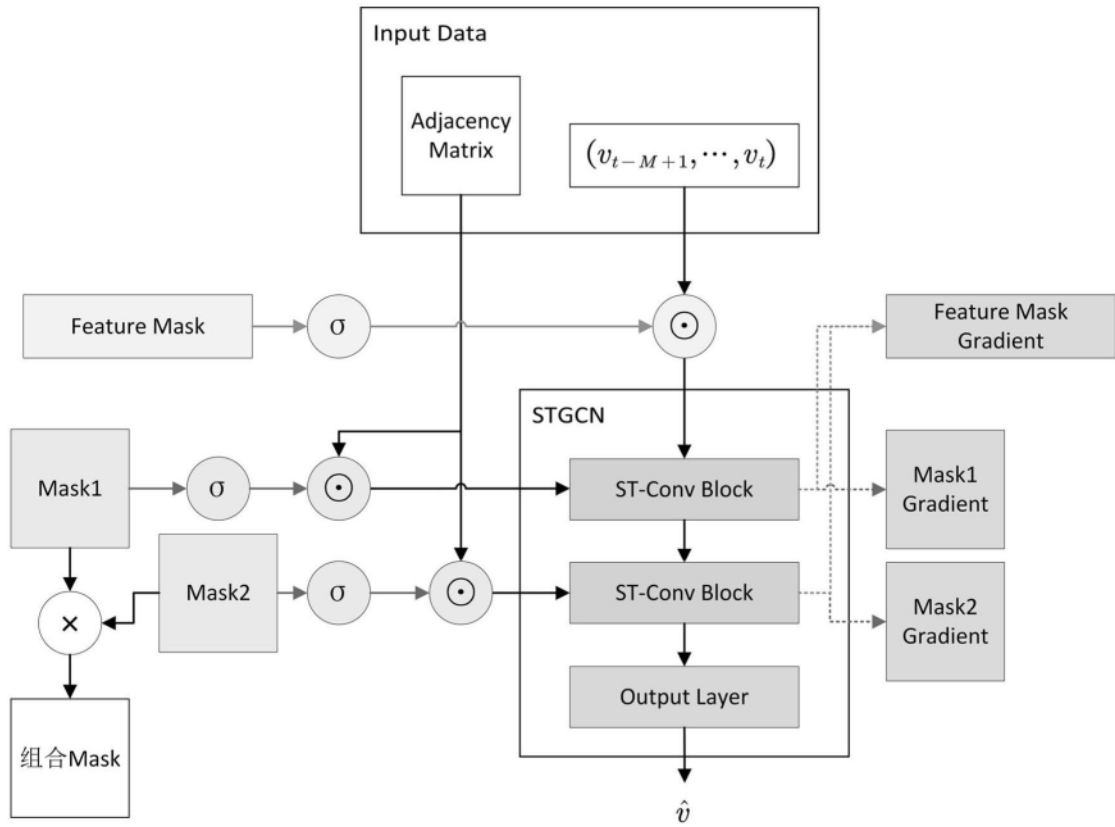


图2

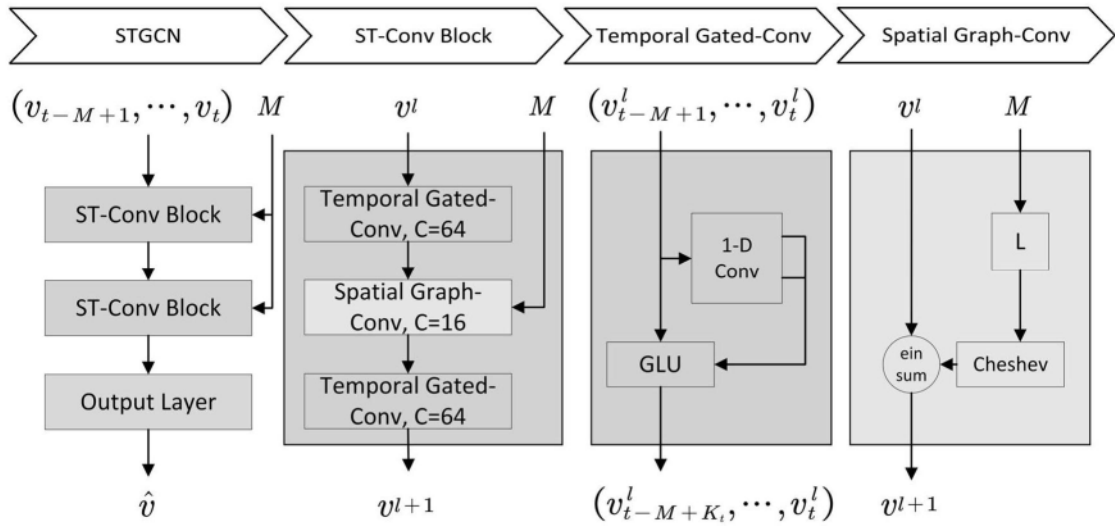


图3

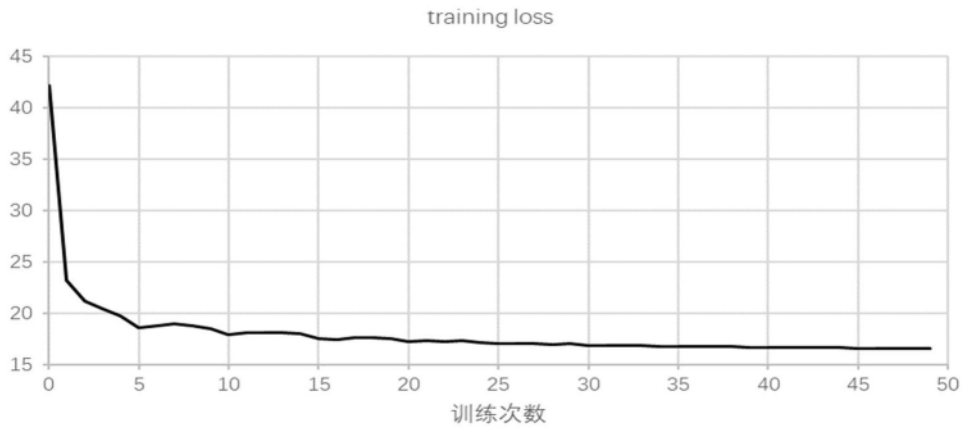


图4

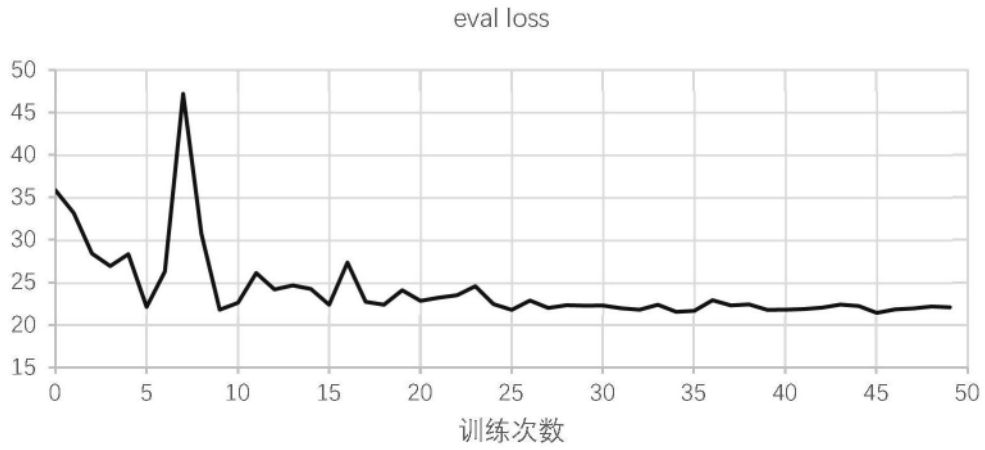


图5

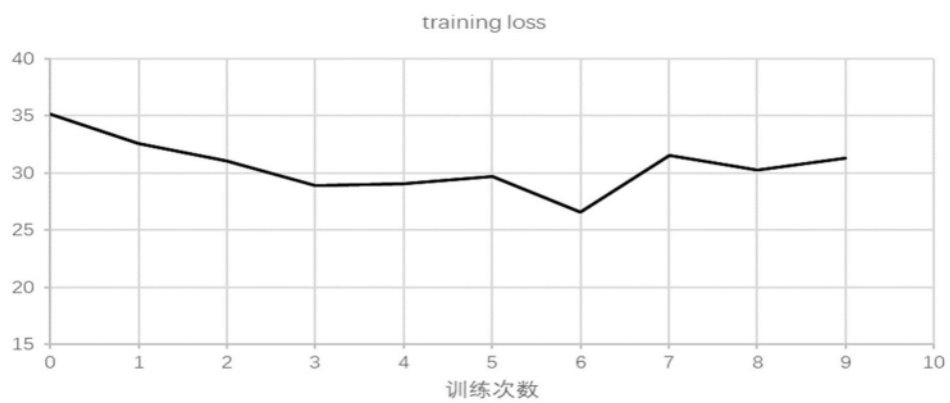


图6

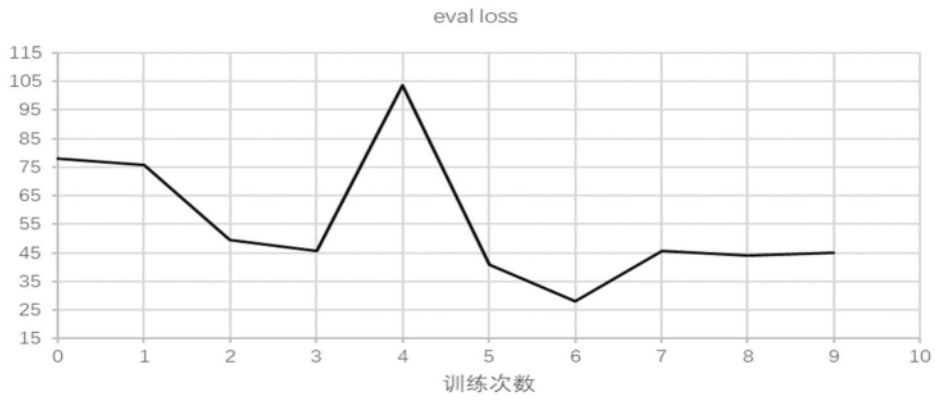


图7

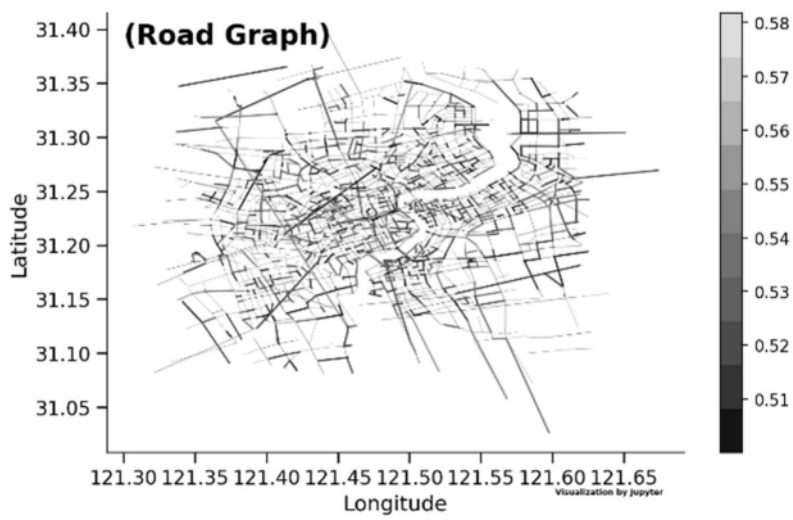


图8




图9




图10

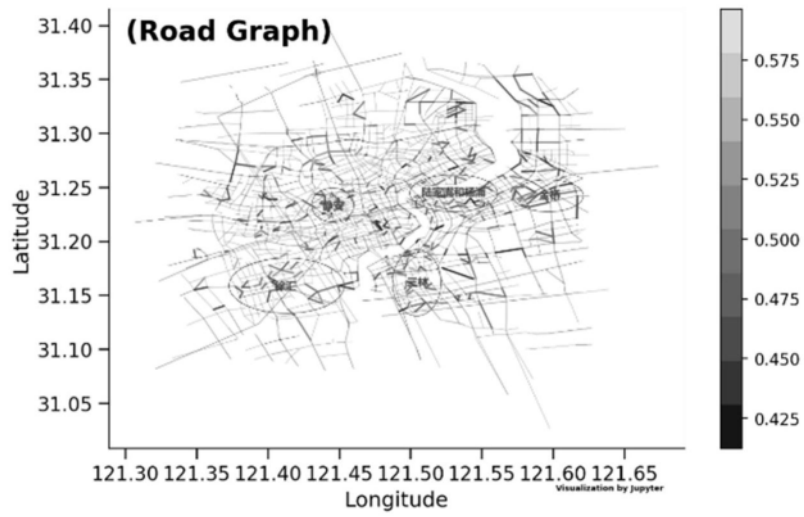


图11




图12




图13




图14




图15




图16

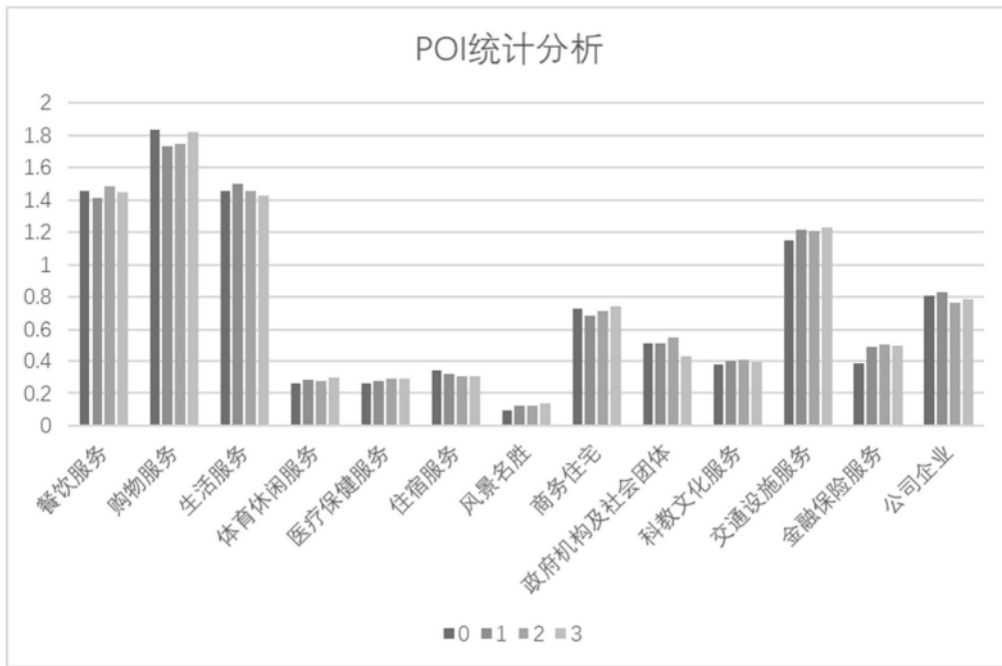


图17