



引文格式:苏峰山,禄小敏,叶云会,等.基于图卷积自编码器的道路网相似度计算方法[J].武汉大学学报(信息科学版),2026, 51(2):391-402.DOI:10.13203/j.whugis20230303

Citation:SU Fengshan, LU Xiaomin, YE Yunhui, et al. A Road Network Similarity Calculation Method Based on Graph Convolutional Autoencoder[J]. Geomatics and Information Science of Wuhan University, 2026, 51(2): 391-402. DOI: 10.13203/j. whu- gis20230303

基于图卷积自编码器的道路网相似度计算方法

苏峰山^{1,2,3} 禄小敏^{1,2,3} 叶云会^{1,2,3} 李静^{1,2,3}

1 兰州交通大学测绘与地理信息学院,甘肃 兰州,730070

2 地理国情监测技术应用国家地方联合工程研究中心,甘肃 兰州,730070

3 甘肃省地理国情监测工程实验室,甘肃 兰州,730070

摘要:道路网空间相似关系计算在空间数据匹配与查询、空间数据多尺度表达与评价及地图综合质量评价等领域均有广泛应用。现有方法存在对空间信息利用不足且特征因子权重设定过于主观等问题,因此引入图卷积自编码器,通过自监督训练尽可能实现原始输入图的重构,克服传统方法局限,进一步提升相似度计算的准确性。基于图卷积自编码器的道路网相似度计算方法,首先进行道路网图建模及节点特征提取,通过交点转边、边转节点的方式建立道路网的对偶图,在此基础上遵循结构的整体与部分关系原则,从全局、局部及连接特征3个方面将道路网空间特征信息赋予对偶图节点,获取道路网图结构的量化表达;然后进行图自编码器学习,利用图卷积自编码器对道路网图的节点特征和结构信息进行聚合与更新,形成对道路网的深度认知,进而获取道路网空间信息的特征编码,实现道路网结构的量化表征;最后计算道路网相似度,通过平均池化将复杂的高维度特征空间映射至低维易度量空间,生成一组特征向量,并采用余弦相似度计算其相似性。试验结果表明,所提模型输出的相似度具有较高的敏感性与一致性,与道路网实际变化情况吻合度较好,且其评价结果与人类的空间认知规律较为吻合。

关键词:道路网;空间相似性;图卷积自编码器;地图综合

中图分类号:P208

文献标识码:A

收稿日期:2024-11-20

DOI:10.13203/j.whugis20230303

文章编号:1671-8860(2026)02-0391-12

A Road Network Similarity Calculation Method Based on Graph Convolutional Autoencoder

SU Fengshan^{1,2,3} LU Xiaomin^{1,2,3} YE Yunhui^{1,2,3} LI Jing^{1,2,3}

1 Faculty of Geomatics, Lanzhou Jiaotong University, Lanzhou 730070, China

2 National-Local Joint Engineering Research Center of Technologies and Applications for National Geographic State Monitoring, Lanzhou 730070, China

3 Gansu Provincial Engineering Laboratory for National Geographic State Monitoring, Lanzhou 730070, China

Abstract: Objectives: The calculation of spatial similarity relationship of road networks has wide applications in the fields of spatial data matching and querying, spatial data multi-scale expression and evaluation, and quality evaluation of cartographic generalization. However, the existing similarity calculation methods of road networks have the problems of insufficient utilization of spatial information and subjective setting of the weights of feature factors. **Methods:** This paper proposes a road network similarity calculation model based on graph convolutional autoencoder (GCAE). The proposed model employs a self-supervised training strategy to achieve end-to-end learning and strives to reconstruct the original input graph as accurately as possible. As a result, it effectively mitigates the limitations of conventional methods and further improves the accuracy of similarity computation. First, a dual graph of the road network is constructed by converting intersections to edges and edges to nodes. Following the principle of whole-part structural rela-

基金项目:国家自然科学基金(42161066,41930101,41801395)。

第一作者:苏峰山,硕士,研究方向为地图制图综合与空间相似关系。1833267945@qq.com

通信作者:禄小敏,博士,教授。935541825@qq.com

tionships, spatial feature information of the road network is assigned to the dual graph nodes from three aspects, including global, local, and connectivity features, thereby obtaining a quantitative representation of the road network graph structure. Then, GCAE is employed to aggregate and update the node features and structural information of the road network graph, forming a deep understanding of the road network. This process yields a feature encoding of the spatial information, achieving a quantifiable representation of the road network structure. Finally, the complex high-dimensional feature space is mapped by average pooling to a low-dimensional, easily measurable space, generating a set of feature vectors. Cosine similarity is then applied to compute the similarity between road networks. **Results:** The experimental results demonstrate that the similarity values generated by the proposed model exhibit high sensitivity and consistency, align closely with actual road network changes, and correspond well with human spatial cognitive patterns. **Conclusions:** The proposed model offers a high degree of automation and yields intuitive, well-founded results, effectively mitigating the need for handcrafted features and rule-based designs in road network similarity calculation.

Key words: road network; spatial similarity; graph convolutional autoencoder; cartographic generalization

空间相似关系作为空间关系的一个子集,在空间数据匹配、空间数据多尺度表达与评价、空间查询与搜索、地图综合质量评价等领域应用广泛^[1-4]。同时,空间相似关系判断与人类认知密切相关,对相似关系进行定量化表达,不仅能促进地理空间认知、完善空间关系理论,而且能为地图自动综合提供理论和技术支持。

道路网是地理信息科学研究领域的热门对象,作为地图中十分重要的地理要素,也是地理要素中变化最频繁的要素之一,广泛应用于导航、交通流量预测、城市形态分析等领域^[5],其相似关系研究是相似关系理论的重要组成部分。相似在本质上是指事物之间在特征方面一一对应,而道路网的相似度从集合学角度可定义为地理空间中两个道路网相似特征集的大小,若将其用相似度来衡量,则值域为 $[0, 1]$ ^[6]。

在已有的道路网相似性研究中,学者们大多从拓扑^[7-9]、语义^[10]、几何^[11-14]及多指标结合^[15-19]等角度计算其相似性,实现了更为科学、合理的度量方式,度量结果也与实际情况较为符合。但是,目前道路网的相似关系研究仍存在以下问题:已有相似性计算方法在计算过程中对道路网的几何、拓扑、分布特征及部分语义特征各有侧重,但尚未形成综合、全面的特征度量方法;多因子集成的方法虽取得了较为满意的结果,但因子间的权重设定过于主观。

深度学习可以通过反向传播来捕获高级特征^[20]。其中,图卷积神经网络是一种面向图结构数据的卷积神经网络,很好地继承了卷积神经网络在特征提取方面的优势,目前已应用于模式识别^[21-23]、形状检索^[24-26]、交通流预测^[27]和城市功能

区识别^[28-29]方面,并取得显著成效。因此,本文结合图卷积神经网络在特征提取方面的优势和自编码模型可以重构原始输入图的特点,构建一种基于图卷积自编码器网络的道路网相似度计算模型,以期得到符合人类认知的相似度计算结果。

1 算法流程与总体思路

道路网是一种不规则的图结构数据,图卷积神经网络是专门针对图数据的一种特征提取器。本文借助于图卷积神经网络在特征提取方面的优势,利用自编码器模型可最小化输入和输出间差异的特点,通过无监督的方式进行端到端训练,获取道路网的深层次特征编码并利用余弦相似度计算得到两个道路网之间的相似性。本文算法流程如图1所示,主要分为以下4个步骤:

1)图建模。借助于Python编程语言提取道路网样本交点,将道路网在交点处分割,以道路为节点,以道路网交点为边,通过交点转边、边转节点的方式建立道路网的对偶图。

2)图节点特征提取。设计并选取道路的特征描述参量,提取路段的描述特征作为图节点的属性特征。本文分别从全局、局部及层次连接性3个方面将空间特征信息赋予其对偶图节点,得到道路网图结构的定量化表达。

3)图卷积自编码器学习。构建基于图卷积神经网络的图卷积自编码器模型,该模型通过无监督的方式进行训练,旨在最小化输入和输出间的差异。利用图卷积自编码器对道路网图的节点特征信息和结构信息进行聚合和更新,得到道路网节点信息的编码表达。

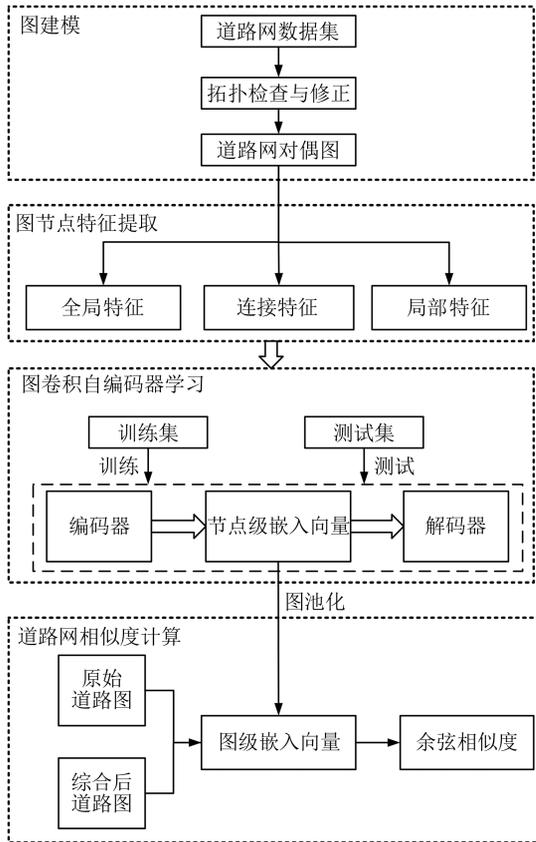


图 1 基于图卷积自编码器的道路网相似度计算流程
Fig. 1 Similarity Calculation Process of Road Network Based on Graph Convolutional Autoencoder

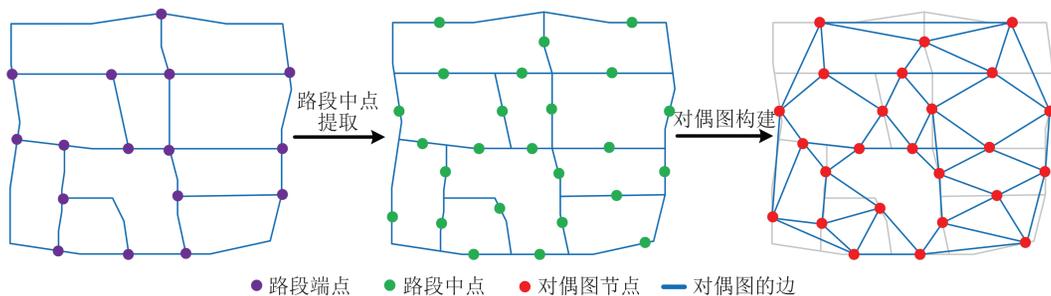


图 2 道路网图结构构建

Fig. 2 Construction of Dual Graph for Road Networks

2.2 特征提取

道路网对偶图的节点特征是本文相似度计算的重要依据,为使选取的特征能很好地反映道路网的特点,本文从其连接特征、全局结构特征和局部特征 3 个方面对道路网的图节点特征进行描述。

2.2.1 连接特征

节点的度源于一个复杂网络的概念,用于表示该节点和其他节点连接的数量^[31]。道路网形态结构复杂,节点的度不仅可以描述道路网的连通程度,也可反映道路网中相对重要的路段,节点的度越大,说明节点对应的路段的重要性越

4)道路网相似度计算。构建验证集数据,对前期训练得到的图卷积自编码器模型进行验证。模型的输出为节点级嵌入向量,借助于平均池化将其转换为图级嵌入向量,再利用余弦相似性计算相似度的大小。

2 道路网图结构构建与特征提取

2.1 图结构构建

道路网通常以节点-弧段的形式存储在数据库中,可将其当作弧段与节点两要素组成的二维平面网络^[30]。在道路网中,其主要信息多集中在边上,交点只反映路网的拓扑连接关系。通过将道路网转化为对偶图,可以使图中的节点囊括道路的属性特征,边用于描述道路网的连接关系。因此,道路网的对偶图可以较好地解决道路网边的存储问题,故本文通过将道路网转化为对偶图来建立图结构,将其特征提取问题转化为对偶图上节点特征的降维问题。首先,将道路网样本在交点处分割,通过路段转节点,交点转边的方式建立道路网的对偶图 $G = \{V, E, A\}$,其中, V 表示节点的集合, E 表示边的集合, A 表示图的邻接矩阵,构建方式如图 2 所示。

高,故本文使用节点的度来反映道路网的拓扑结构相似性。

2.2.2 全局特征

本文利用全局特征来表达道路网的整体结构,该方法并非将道路的每个端点孤立,而是将一条道路的两个端点与中心点联系起来,构成一个三角形。通过统计整个道路网中所有道路的夹角和距离差,可以得到夹角、距离差两个分布,即可整体描述道路网的结构特征。计算过程中需引入道路网样本的中心点,中心点即所有道路段中点的算术平均值,设第 i 个道路段的中点坐标为 $(X_i, Y_i), i = 1, 2, \dots, n$,道路网的几何中心

点 O 的计算式为:

$$(X_o, Y_o) = \left(\frac{1}{L} \sum_{i=1}^n \lambda_i X_i, \frac{1}{L} \sum_{i=1}^n \lambda_i Y_i \right) \quad (1)$$

式中, λ_i 为第 i 个道路弧段的长度; L 为所有道路弧段的总长度。由于道路网样本中不同道路弧段的长度不一, 因此在计算道路网样本中心点时, 将对应的道路弧段长度作为其权重, 并以总的弧段长度代替其数量。

以道路网样本的中心点为参考点, 分别计算中心点和道路的两个端点连线所形成夹角 α 和距离的差值 Δl , 如图3所示, 将道路网的中心点记为 O , 节点 P 对应的两个端点分别为 A 和 B , OA 的长度记为 L_1 , OB 的长度记为 L_2 , AB 的长度记为 L_3 , 则道路 AB 的全局特征计算式为:

$$\Delta l = L_1 - L_2 \quad (2)$$

$$\alpha = \arccos \left(\frac{L_1^2 + L_2^2 - L_3^2}{2L_1L_2} \right) \quad (3)$$

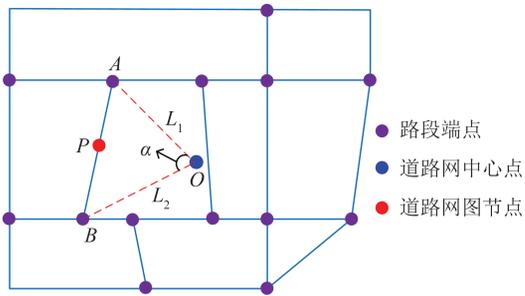


图3 道路网的全局特征提取

Fig. 3 Global Feature Extraction for Road Networks

2.2.3 局部特征

局部特征可以反映道路网中每条道路的具体形状。本文选取长度、曲折度、最小外接矩形长边方向和方向均值作为描述参量, 对样本中的每条道路进行编码, 精细化描述其局部特征。

1) 长度。可以较为直观地反映路段的形状特征, 是线要素最基本的特征。长度 L 的计算式为:

$$L = \sum_{i=1}^n \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (4)$$

2) 曲折度。路段的总长度与其首尾点连线长度的比值。

3) 最小外接矩形长边方向。单个线要素的方向一般分为整体方向和局部方向, 本文采用线要素最小外接矩形的长边方向代表道路的整体方向, 并用其方位角进行定量描述, 其原理如图4所示。

4) 方向均值。方向均值将长度作为权重因子, 综合考虑了方向和角度, 能较好地反映路段

的局部细节差异。本文以道路网中构成该道路的各折线段的长度与道路总长度的比值作为权重系数 w_i , 将每条道路中各折线段形成的方向角与对应的权重系数相乘, 得到经过加权后的方向角, 最后对其进行累加和即可求得方向均值, 其原理如图5所示。

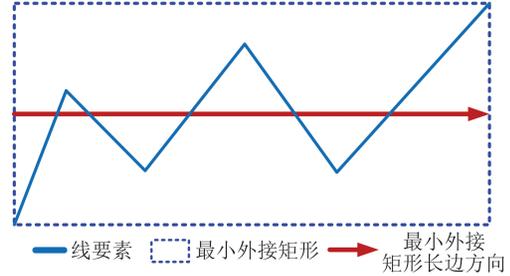


图4 最小外接矩形的长边方向

Fig. 4 Direction of Long Side of the Minimum Bounding Rectangle

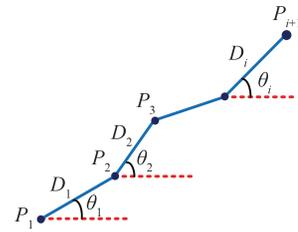


图5 方向均值的计算

Fig. 5 Calculation of Directional Mean

将整个道路的长度记为 L , 道路中第 i 个折线段的长度记为 D_i , 则长度系数的计算式为:

$$w_i = \frac{D_i}{L} \quad (5)$$

对于整条道路, 其方向均值 $\bar{\theta}$ 的计算式为:

$$\bar{\theta} = \sum_{i=1}^n w_i \theta_i \quad (6)$$

式中, θ_i 为第 i 个折线段与 x 轴正方向的夹角。

3 图卷积自编码器支持下的道路网相似度计算

3.1 图卷积神经网络

图卷积神经网络使用一阶切比雪夫多项式作为卷积核进行卷积运算, 将卷积操作限制在一步领域内进行, 并通过堆叠多个卷积层来调整感受野的大小, 进一步提取不同邻域范围内的空间特征^[32]。对于节点度分布非常广的图, 这种简化可以较好地避免局部邻域结构的过拟合问题。此外, 分层线性公式允许建立更深层次的模型, 在提高模型建模能力的同时, 能降低计算的复

杂度。

本文采用图卷积神经网络^[32]进行道路网特征提取,通过叠加多层卷积层来学习道路网的节点特征,形成道路网的深层次编码认知。卷积层之间传播公式为:

$$H^{(l+1)} = \sigma(\hat{D}^{-1/2} \hat{A} \hat{D}^{-1/2} H^{(l)} W^{(l)} + b^{(l)}) \quad (7)$$

式中, $\hat{A} = A + I$ 是添加了自环的邻接矩阵; \hat{D} 是 \hat{A} 的度矩阵,即对角矩阵; σ 表示 Sigmoid 非线性激活函数; $H^{(l)}$ 是第 l 层的节点特征矩阵, l 为 0 时 $H^{(0)}$ 为原始特征矩阵; $W^{(l)}$ 为图卷积层的可训练权重矩阵; $b^{(l)}$ 为图卷积神经网络中的偏置系数矩阵。

3.2 图卷积自编码器构建

自编码器主要由编码器和解码器构成,采用无监督的方式进行训练,通常用于学习原始数据的表示和有效编码,其学习目标是尽可能缩小原始样本和重建样本间的差异,且无需标签的重建^[33]。图卷积自编码器的编码器由多个图卷积层构成,通过编码器将输入图映射到某个向量空间中,形成道路网空间认知的向量化表达,解码器对原始输入图进行重建。编码器的输出变量是一个矩阵,矩阵中的每一行代表一个顶点的向量化表示,为了衡量图中顶点间的关联程度,深

度学习常使用向量内积来计算这些顶点向量之间的余弦相似度,此时,计算所有行向量对的内积,本质上就是在计算顶点间的相似度矩阵,该相似度矩阵可用于推导生成所需邻接矩阵。

本文采用图卷积自编码器模型^[34]进行道路网相似性计算,利用道路网训练集对模型进行训练学习,使模型提取的特征能较好地保留原始道路网的特征信息,为道路网的相似性计算提供支持。最终目标是获取道路网的图级嵌入向量,使用余弦相似度对其进行度量,故本文需对编码器的输出向量进行平均池化操作,将其转化为长度大小一致的一维向量。本文用于道路网相似度计算的图自编码器模型如图 6 所示,其中 A 为原始输入图的邻接矩阵, A' 为解码器重建后的邻接矩阵, Z 为编码器输出的节点级嵌入向量, σ 为 Sigmoid 激活函数,训练目标为最小化 A' 和 A 之间的差异。在编码器输出的节点级嵌入向量中,横向维度为每个节点所包含的特征数,纵向维度为节点数量,按纵向维度对节点数量求均值,即可得到道路网的图级嵌入向量。本文的图聚合不仅能获取道路网的整体特征,而且可以解决节点数不一致相似度计算困难的问题,并有效实现多尺度道路网相似度计算。

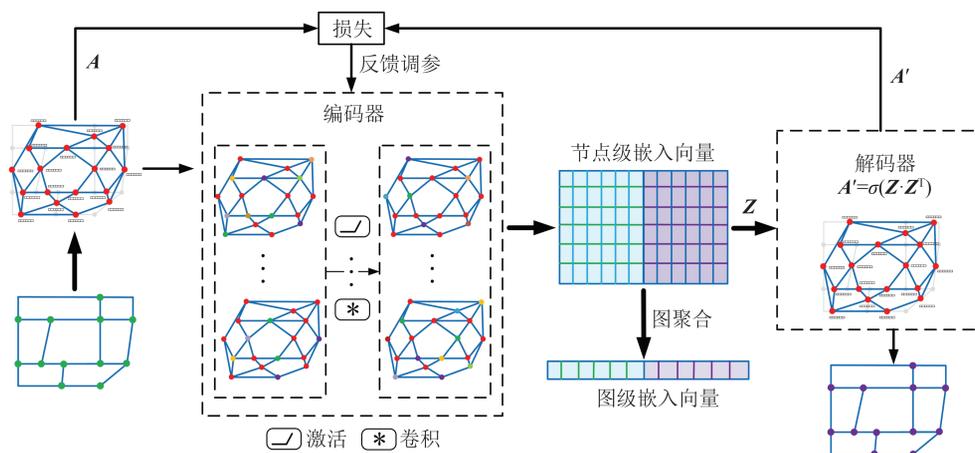


图 6 基于图卷积自编码器的道路网相似度计算模型

Fig. 6 Road Network Similarity Calculation Model Based on Graph Convolutional Autoencoder

3.3 损失函数

本文通过无监督的方式对模型进行训练,采用无标签的交叉熵损失函数计算损失。在机器学习中,交叉熵被广泛应用于评估真实概率分布与预测概率分布之间的差异。通过最小化交叉熵损失,模型可以尽可能地接近实际情况,提高其性能和准确性。

本文训练的最终目标是 minimized 输入和输出之间的差异,而非标签重建,故采用无标签的交

叉熵损失函数作为约束对模型进行优化,交叉熵的值越小,说明两个概率分布间的相似度越高,模型预测的效果越好。交叉熵损失的计算式为:

$$f_{\text{loss}} = -\frac{1}{N^2} \left[\mathbf{1}^T (A \odot \log(\sigma(\mathbf{Z} \cdot \mathbf{Z}^T))) + (1 - A) \odot \log(1 - \sigma(\mathbf{Z} \cdot \mathbf{Z}^T)) \right] \quad (8)$$

式中, \odot 为哈达玛积,即矩阵的逐元素相乘; N 为图中节点总数;通过 A 和 $1-A$ 实现对所有正负样本的精确、对称处理。

3.4 道路网相似度计算

本文模型的训练需借助编码器和解码器共同完成,而道路网的相似度计算仅使用编码器的输出向量。编码器的输出向量为节点级嵌入向量,需对其进行聚合操作,将其转化为图级嵌入向量,转化后的图级嵌入向量为长度固定的一维向量。此时,道路网 A 、 B 之间的相似度 s 为其对应的图级嵌入向量间的余弦相似度,计算式为:

$$s = \cos(a, b) = \frac{a \cdot b}{\|a\| \|b\|} = \frac{\sum_{i=1}^n (a_i \times b_i)}{\sqrt{\sum_{i=1}^n (a_i)^2} \times \sqrt{\sum_{i=1}^n (b_i)^2}} \quad (9)$$

式中, a 、 b 分别为道路网 A 、 B 的图级嵌入向量; a_i 、 b_i 分别对应向量的第 i 个元素; n 为向量的长度。

4 实验与讨论

4.1 实验环境与数据

本文实验的图卷积自编码器模型由Py-

thon3.7语言和PyTorch1.12深度学习框架实现,实验在NVIDIA GeForce RTX 3060+R7 5800H硬件平台下完成,操作系统为Microsoft Win10 64位,内存为32 GB,硬盘为1 024 GB。

本文所需实验数据集从OSM(OpenStreetMap)官网获取,将手动截取不同区域的道路网数据作为本次实验的初始样本。由于OSM的道路网数据规范性较差,需对初始数据集进行拓扑检查与修正,剔除伪节点和孤立路段,使构建的道路网对偶图不存在不连通现象,降低对实验结果的影响。此外,需对道路网的复杂交叉点进行化简,获取更为规范的道路网。本文实验共截取840个不同区域的路网数据,经过数据预处理等操作,获取了800个符合标准的数据集,其中700个用于训练模型,100个用于测试模型。

4.2 模型训练和参数设置

模型训练期间,卷积层数量和卷积核大小等参数会对模型最终的性能产生影响,本文对其进行了进一步的分析,不同编码维度和不同卷积层数下的训练结果分别如图7和图8所示。

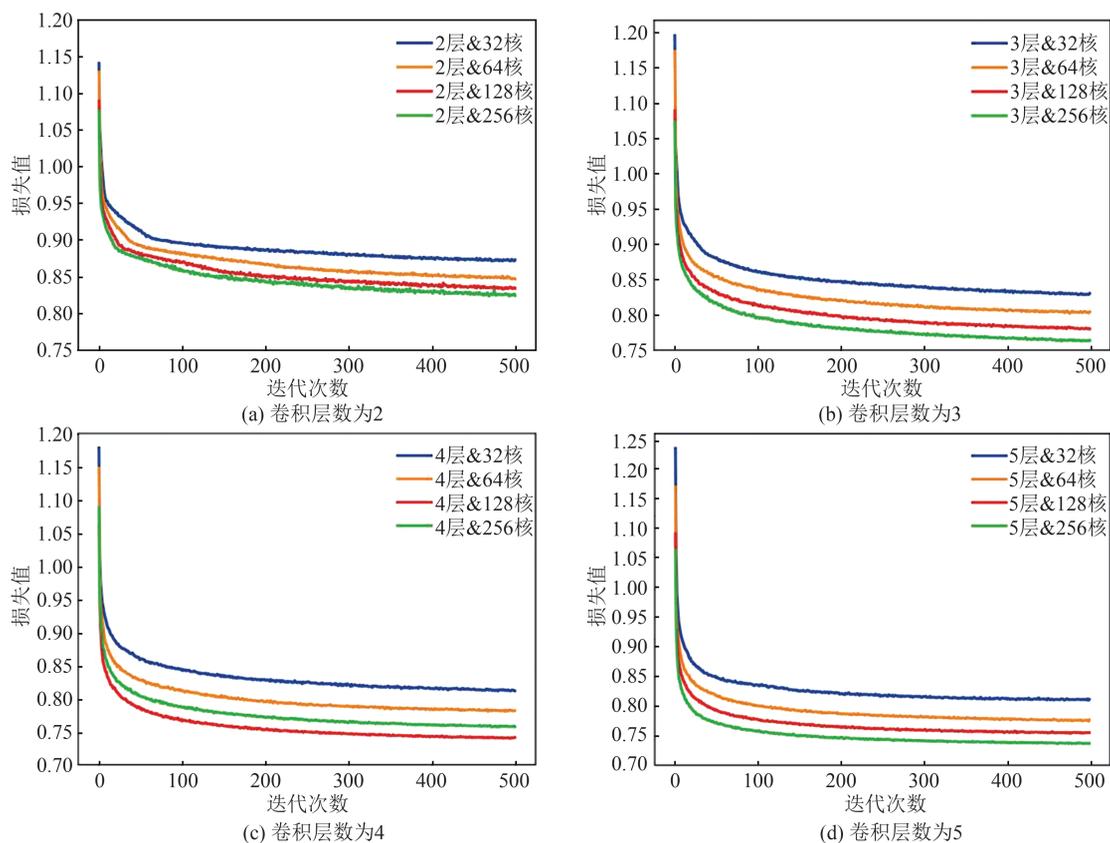


图7 不同编码维度下模型的训练损失曲线

Fig. 7 Training Loss Curves with Different Coding Dimensions

由图7的损失曲线可以看出,在卷积层数一定时,卷积核为128时的损失比卷积核为256时

更低(图7(c)),在其他情况下,随着嵌入维度的越大,损失均越来越小。由图8可以看出,当嵌入

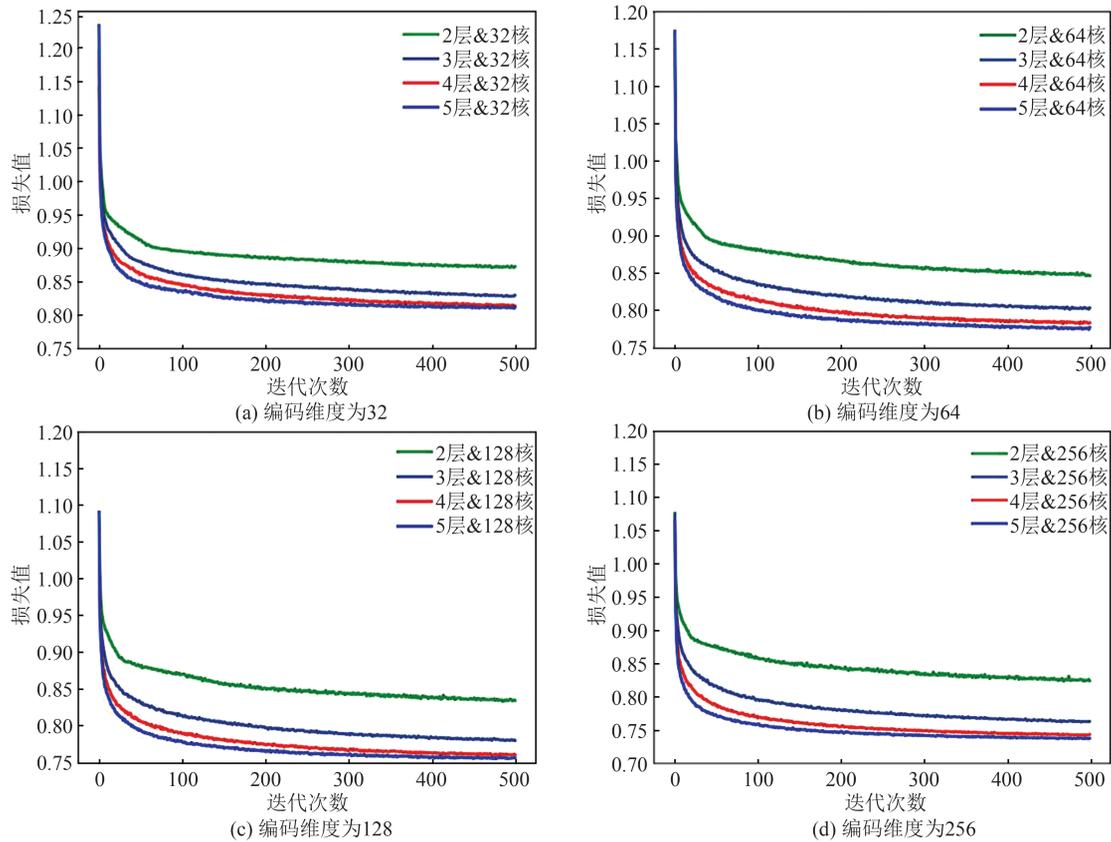


图 8 不同卷积层数下的训练损失曲线

Fig. 8 Training Loss Curves with Different Number of Convolutional Layers

维度相同时,卷积层数越多,损失越低,其中卷积层数为4层和5层时损失大致接近。较高的嵌入维度和卷积层数可以使模型获得更低的损失,其原因可能是嵌入维度越小,特征波动越大,越不利于模型对特征进行重构,而维度较高,特征则相对较为平滑,越利于其重构;同时,随着卷积层数的增加,捕获到的邻域特征信息则更丰富,对原始特征的重构则更为准确。更小的损失意味着模型重构的图和原始输入图更为接近,但不能说明其编码能力的优劣。但模型嵌入维度过高时,模型的信息压缩能力会降低,使模型通过简单的复制和映射即可完成重构,同时过多的卷积层数会增加计算负担,且易造成梯度消失和爆炸,从而影响模型性能。

结合上述分析,图卷积自编码器确定参数中卷积层数为4层,卷积核大小为128。编码器的第一层为输入层,输入特征向量维度为7,嵌入特征向量维度为128,激活函数为ReLU,第2~4层为隐藏层,在每一层中输入特征向量维度为128,嵌入特征向量维度为128,激活函数为ReLU。解码器通过计算内积的方式对原始输入图进行重构,并使用Sigmoid函数对内积值进行归一化,使其分布范围在(0,1)之间。基于此,进一步利用上

文提到的700个训练集和100个验证集对模型进行训练和验证。采用小批量梯度下降法进行训练,并结合Adam优化器对模型进行优化,最大迭代次数为500,训练批次为16,学习率为0.001,初始化权重参数,通过反向传播不断调整训练参数。图9为模型在训练集上损失值和验证集上的损失与准确度。

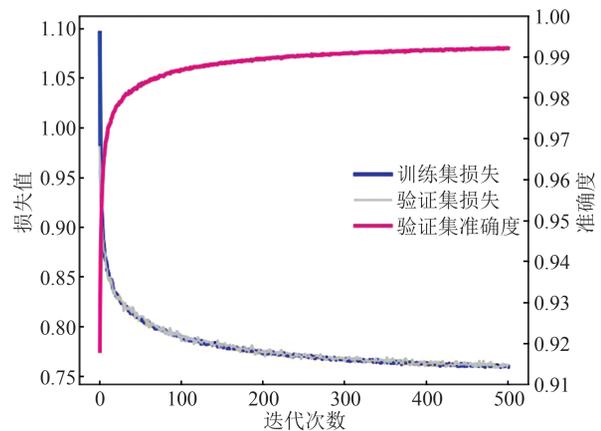


图 9 在训练集上损失和在验证集的损失与准确度

Fig. 9 Loss on Training Dataset and Loss and Accuracy on Validation Dataset

由图9可以看出,在迭代500次后,模型已基本收敛,其损失值稳定在0.75左右,在验证集上

的准确度达到了0.99左右,这进一步说明模型对原始输入图的重建精度较高,具备较好的泛化性能,可以为后续道路网的相似度计算提供支持。

4.3 道路网相似性度量实验

本文选取3处不同区域的1:1万道路网数据用于相似性度量实验,经过数据预处理等操作得到本次实验的原始道路网数据。为确保本次实验样本的多样性和合理性,由本专业多位具有丰富制图经验和从事相似性理论研究的人员对原始路网数据进行综合。第一步,构建道路网Stroke;第二步,按照Stroke的重要性大小对其进行排序;第三步,根据开方根定律对排序后的道路网Stroke进行尺度变换,分别得到1:2.5万、1:5万、1:10万、1:25万和1:50万比例尺下的道路网数据。原始路网共选取3处区域,每处区域综合5次,共计得到3组路网作为本次实验的验证数据。为验证本文方法的合理性,对上述验证数据进行相似性度量实验。图10为3处不同区域的多尺度道路网数据及其相似度计算结果,其中 R 代表该区域其他比例尺道路网与1:1万比例尺道路网对比所得相似度, R 取值范围为(0,1),值越大,表明相似性越高。

由图10可知,随着综合程度的不断加强,相似度不断递减,符合相似度随着综合程度增大而不断减小的理论。从3组数据实验结果可以看出,本文模型计算得到的不同比例尺道路网相似度结果和比例尺的跨度较为一致,充分说明了该模型的合理性,且同一比例尺计算得到的相似度差异较小,其存在差异的原因主要为:(1)3组数据源于3处不同区域。(2)同一区域中不同比例尺的验证数据由人工综合所得,其真实数据与对应的比例尺大小并非完全一致。

4.4 分析与讨论

4.4.1 心理认知实验

相似性是一种模糊的人类感知,为验证模型的相似度计算结果是否符合人类的认知,本文以第3组道路网样本为例,以问卷调查的方式进行心理认知调查实验,参与者以原始样本为参照,对综合后的路网进行相似度评分。考虑到人的认知在不同的场景下受诸多因素的影响,故本次问卷将相似度划分为6个区间供受访者选择,分别为(0.9,1]、(0.8,0.9]、(0.7,0.8]、(0.6,0.7]、(0.5,0.6]、 ≤ 0.5 。本次心理认知调查实验共收集420份问卷,其中专业人士占60%,非专业人士占40%。调查结果如图11所示。

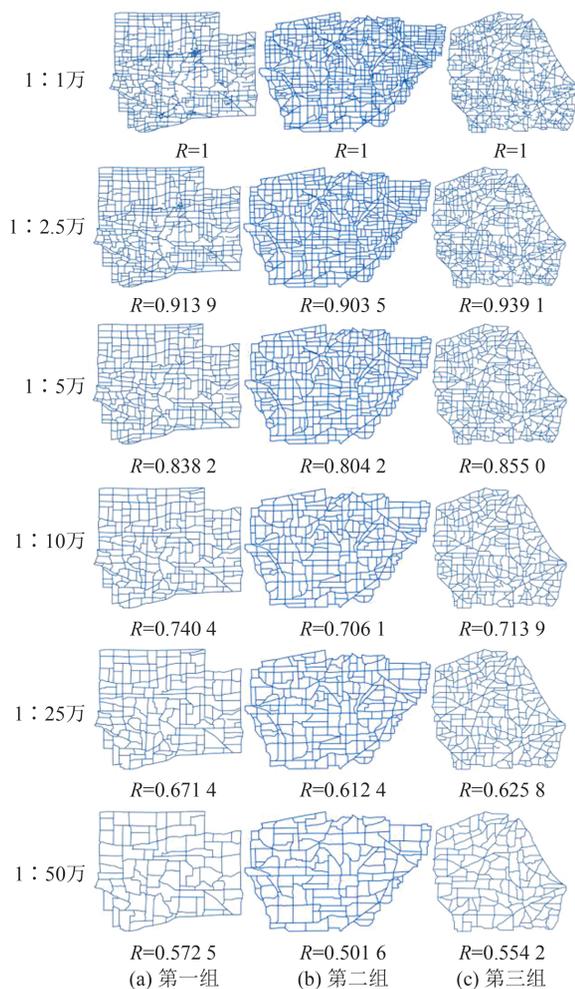


图10 道路网的可视化及本文模型的相似度计算结果
Fig. 10 Visualization of Road Networks and Similarity Calculation Results of the Proposed Model

由图11可知,在参与心理认知调查实验的人群中,非专业人员对5次尺度变换前后道路网之间的相似度分别更倾向于(0.9,1]、(0.8,0.9]、(0.7,0.8]、(0.6,0.7]、(0.5,0.6],相似性认知实验结果与本文计算实验结果保持了较高的一致性。其中1:1万~1:50万道路网间的相似度分布范围,选择 ≤ 0.5 的人数也较多,与选择(0.6,0.7]相似度分布范围的人数差别较小,这主要是由于非专业人员进行相似度判断时,更注重对线要素密度变化的直观感受,当综合程度较大时,非专业人员在相似度判断时会倾向于选择更低的相似度区间。专业人员进行相似度判断时,不仅会考虑到线要素的密度变化,还会对道路网局部特征、全局特征和拓扑关系等方面进行综合考量。

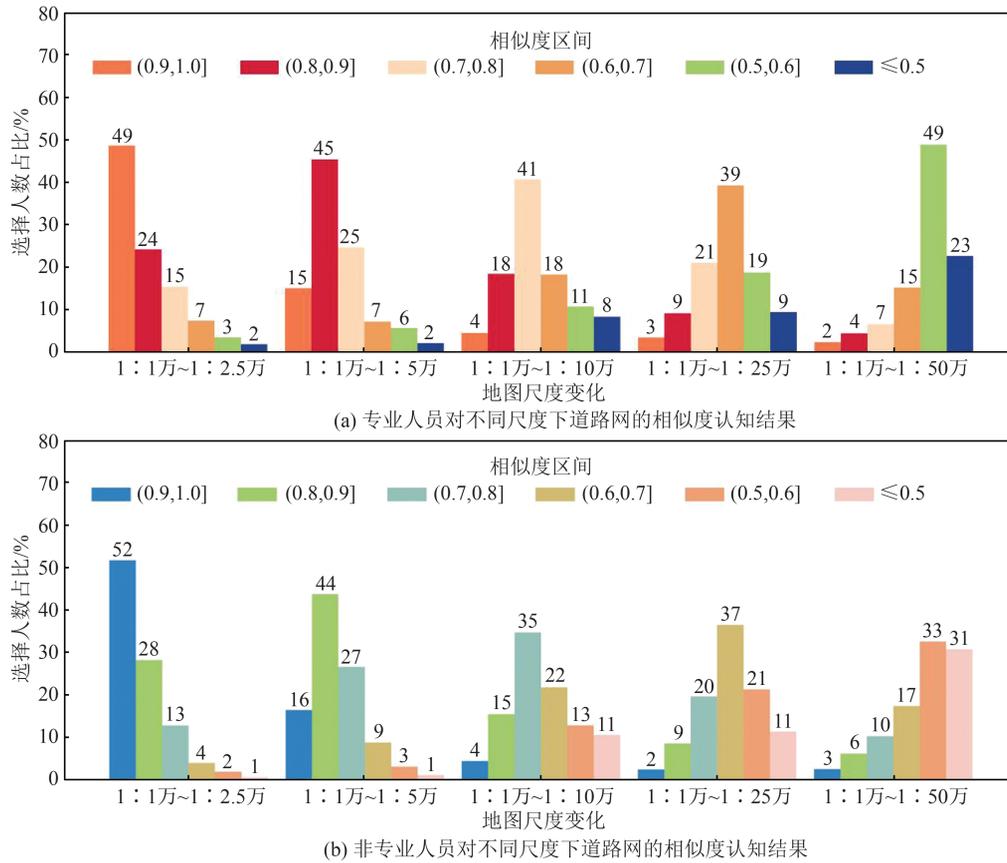


图 11 第 3 组道路网样本心理认知调查结果

Fig. 11 Psychological and Cognitive Survey Results of the 3rd Sample Road Network

4.4.2 对比实验

为了对比本文模型的相似度计算结果与其他方法之间的差异,选取 TENE 模型^[35]和 ASNE 模型^[36]两种图嵌入方法和基于拓扑与几何的方法来计算不同尺度下的道路网间的相似性,结果见表 1。

由表 1 可知,TENE 模型计算的相似度整体偏高,不同比例尺道路网之间的相似度均达到 0.8

以上,且相似度随着综合程度的增大,仅有少量道路网符合递减规律;ASNE 模型计算的相似度在随着比例尺增大时,整体符合递减规律,但部分相邻比例尺间的道路网相似度值比较接近,相似度也不具备较好的层次递减性。结合上文的心理认知调查结果可以得出,TENE 和 ASNE 两种模型计算的相似度结果与人的认知存在较大的偏差,不同比例尺道路网的相似度计算吻合度

表 1 对比实验及相似度计算结果

Table 1 Comparison Experiments and Similarity Calculation Results

相似度	方法	1:2.5万	1:5万	1:10万	1:25万	1:50万
第一组	TENE	0.914 8	0.925 2	0.920 6	0.893 0	0.900 5
	ASNE	0.862 7	0.776 5	0.769 8	0.661 2	0.649 1
	基于拓扑和几何的方法	0.932 3	0.841 2	0.769 1	0.706 3	0.614 9
	图自编码器	0.913 9	0.838 2	0.740 4	0.671 4	0.572 5
第二组	TENE	0.908 0	0.897 3	0.866 2	0.908 7	0.924 5
	ASNE	0.806 9	0.650 4	0.626 7	0.611 6	0.587 9
	基于拓扑和几何的方法	0.909 5	0.817 5	0.789 1	0.687 5	0.613 9
	图自编码器	0.903 5	0.804 2	0.706 1	0.612 4	0.501 6
第三组	TENE	0.876 6	0.920 9	0.897 8	0.913 8	0.914 8
	ASNE	0.890 1	0.838 5	0.835 0	0.773 6	0.652 6
	基于拓扑和几何的方法	0.951 8	0.877 3	0.804 8	0.773 8	0.650 4
	图自编码器	0.939 1	0.855 0	0.713 9	0.625 8	0.554 2

较低。在基于拓扑与几何的方法中,随着比例尺不断减小,相似度也逐渐降低,符合比例尺跨度增大、相似度不断递减的规律,计算结果较为符合人类认知,本文模型计算结果与其一致性较高。其中,在比例尺为1:2.5万和1:5万时该方法与本文计算结果较为接近,其余比例尺的相似度结果均略高于本文。但是,拓扑与几何方法在相似度计算过程中特征因子权重审定过于主观,不同权重设置所得结果均不相同。

相较于拓扑与几何方法,本文计算的相似度值随着比例尺跨度增大,具备较好的层次递减性,相似度的递减规律和比例尺跨度的变化保持了较高的一致性。该方法在节点特征因子选取时,结合道路网的全局、局部及其连接特征。同时,图卷积自编码器模型能较好地提取道路网特征,获取丰富的节点信息,并通过无监督方式对模型进行训练,形成对道路网更深层次的认知,且有效规避了权重审定难、设定过于主观这一缺点,最终相似度计算结果也更为符合人类认知。但该方法也存在不足,具体表现为:相似度计算过程中对于细微变化的感知不够灵敏,如利用本文模型计算某处道路网的相似度时,若少量增删路段,其结果有时并非完全符合递减规律,主要是由于该模型主要针对单个图的节点信息去重构原始图结构,模型训练过程中易产生过拟合现象,但相似度计算结果总体呈现递减的变化规律,与人的认知保持较高的一致性。

5 结 语

针对空间相似关系计算这一复杂且与人类认知紧密相关的问题,本文基于图自编码器模型,将图卷积神经网络在特征提取方面的优势和自编码器对原始输入图重建的有效性相结合,并将其应用于道路网的相似度计算。试验结果表明,该方法自动化程度高,计算结果合理直观,极大地减少了人工特征和规则的设计,通过心理认知实验与对比实验,进一步验证了该算法具备较高的灵敏度,计算结果与实际的道路网变化程度保持了较高的一致性,也与人类认知较为吻合。

本文方法的不足之处主要表现在:(1)节点特征提取过程未涉及道路网的语义信息;(2)模型在相似度计算过程中倾向于捕捉全局一致性,对细微变化的感知不够灵敏;(3)该模型旨在基于编码器所生成的潜在空间表示,重构出尽可能接近原始输入图的数据,若模型容量与训练数据

规模失配,则可能导致模型倾向于精确记忆训练样本的细节特征,而非学习其本质的统计规律与结构特征,易出现过拟合现象,将损害模型在未见数据上的泛化能力。在未来研究中,可尝试在模型中融入图的节点和全局间的交互信息,并借助于知识图谱引入道路语义信息,从而获取更为准确、全面的相似度计算结果,并将其运用于地图综合质量评价,指导地图综合过程控制和综合结果质量评定。

参 考 文 献

- [1] 闫浩文, 褚衍东. 多尺度地图空间相似关系基本问题研究[J]. 地理与地理信息科学, 2009, 25(4): 42-44.
YAN Haowen, CHU Yandong. On the Fundamental Issues of Spatial Similarity Relations in Multi-Scale Maps[J]. *Geography and Geo-Information Science*, 2009, 25(4): 42-44.
- [2] 王荣, 闫浩文, 禄小敏. Douglas-Peucker算法全自动化的多尺度空间相似关系方法[J]. 地球信息科学学报, 2021, 23(10): 1767-1777.
WANG Rong, YAN Haowen, LU Xiaomin. Automation of the Douglas-Peucker Algorithm Based on Spatial Similarity Relations[J]. *Journal of Geo-Information Science*, 2021, 23(10): 1767-1777.
- [3] 杜世宏, 雒立群, 赵文智, 等. 多尺度空间关系研究进展[J]. 地球信息科学学报, 2015, 17(2): 135-146.
DU Shihong, LUO Liqun, ZHAO Wenzhi, et al. Research Progress in Multi-Scale Spatial Relations[J]. *Journal of Geo-Information Science*, 2015, 17(2): 135-146.
- [4] YAN H W, LI J. Concepts of Spatial Similarity Relations in Multiscale Map Spaces[M]//Spatial Similarity Relations in Multi-Scale Map Spaces. Cham: Springer, 2014: 45-80.
- [5] 郭漩. 基于知识学习与推理的道路网智能选取方法研究[D]. 郑州: 信息工程大学, 2022.
GUO Xuan. Research on Road Network Intelligent Selection Based on Knowledge Learning and Reasoning [D]. Zhengzhou: Information Engineering University, 2022.
- [6] 马京振, 孙群, 温伯威, 等. 结合轨迹数据的混合多特征道路网选取方法[J]. 武汉大学学报(信息科学版), 2022, 47(7): 1009-1016.
MA Jingzhen, SUN Qun, WEN Bowei, et al. A Hybrid Multi-feature Road Network Selection Method Based on Trajectory Data [J]. *Geomatics and Information Science of Wuhan University*, 2022, 47

- (7): 1009-1016.
- [7] 安晓亚, 杨云, 刘平芝, 等. 基于拓扑谓词的空间拓扑关系相似性度量模型与应用[J]. 地球信息科学学报, 2013, 15(2): 159-165.
AN Xiaoya, YANG Yun, LIU Pingzhi, et al. Similarity Measurement Model of Spatial Topological Relations Based on Topological Predicates and Its Application[J]. *Journal of Geo-Information Science*, 2013, 15(2): 159-165.
- [8] 刘闯, 钱海忠, 王骁, 等. 顾及上下级空间关系相似性的道路网联动匹配方法[J]. 测绘学报, 2016, 45(11): 1371-1383.
LIU Chuang, QIAN Haizhong, WANG Xiao, et al. A Linkage Matching Method for Road Networks Considering the Similarity of Upper and Lower Spatial Relation[J]. *Acta Geodaetica et Cartographica Sinica*, 2016, 45(11): 1371-1383.
- [9] 黄博华, 钟巍, 翟仁健, 等. 城市道路网匹配的层次化面域剖分模型[J]. 测绘学报, 2018, 47(11): 1526-1536.
HUANG Bohua, ZHONG Wei, ZHAI Renjian, et al. Hierarchical Area Partitioning Method of Urban Road Networks Matching[J]. *Acta Geodaetica et Cartographica Sinica*, 2018, 47(11): 1526-1536.
- [10] 王玉竹, 闫浩文, 禄小敏. 面向路网匹配的层次化语义相似性度量模型[J]. 地球信息科学学报, 2023, 25(4): 714-725.
WANG Yuzhu, YAN Haowen, LU Xiaomin. Hierarchical Semantic Similarity Metric Model Oriented to Road Network Matching[J]. *Journal of Geo-Information Science*, 2023, 25(4): 714-725.
- [11] 刘慧敏, 邓敏, 徐震, 等. 线要素几何信息量度量方法[J]. 武汉大学学报(信息科学版), 2014, 39(4): 500-504.
LIU Huimin, DENG Min, XU Zhen, et al. Geometric Information Content Measurement of Individual Line Feature[J]. *Geomatics and Information Science of Wuhan University*, 2014, 39(4): 500-504.
- [12] 安晓亚, 孙群, 肖强, 等. 一种形状多级描述方法及在多尺度空间数据几何相似性度量中的应用[J]. 测绘学报, 2011, 40(4): 495-501.
AN Xiaoya, SUN Qun, XIAO Qiang, et al. A Shape Multilevel Description Method and Application in Measuring Geometry Similarity of Multi-Scale Spatial Data[J]. *Acta Geodaetica et Cartographica Sinica*, 2011, 40(4): 495-501.
- [13] 李兆兴, 翟京生, 武芳. 线要素综合的形状相似性评价方法[J]. 武汉大学学报(信息科学版), 2019, 44(12): 1859-1864.
LI Zhaoxing, ZHAI Jingsheng, WU Fang. A Shape Similarity Assessment Method for Linear Feature Generalization[J]. *Geomatics and Information Science of Wuhan University*, 2019, 44(12): 1859-1864.
- [14] 刘海龙, 钱海忠, 王骁, 等. 采用层次分析法的道路网整体匹配方法[J]. 武汉大学学报(信息科学版), 2015, 40(5): 644-651.
LIU Hailong, QIAN Haizhong, WANG Xiao, et al. Road Networks Global Matching Method Using Analytical Hierarchy Process[J]. *Geomatics and Information Science of Wuhan University*, 2015, 40(5): 644-651.
- [15] 张建辰, 王艳慧, 赵文吉. 全局与局部寻优相结合的道路网匹配方法[J]. 武汉大学学报(信息科学版), 2018, 43(8): 1166-1171.
ZHANG Jianchen, WANG Yanhui, ZHAO Wenji. Matching Road Networks Based on Combination of Global and Local Optimization[J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(8): 1166-1171.
- [16] 张彦平, 张凤录, 殷勇, 等. 一种顾及居民地约束的道路网选取方法[J]. 北京测绘, 2025, 39(2): 145-152.
ZHANG Yanping, ZHANG Fenglu, YIN Yong, et al. A Road Network Selection Method Considering Residential Area Constraints[J]. *Beijing Surveying and Mapping*, 2025, 39(2): 145-152.
- [17] 秦育罗, 宋伟东, 张在岩, 等. 顾及几何特征和拓扑连续性的道路网匹配方法[J]. 测绘通报, 2021(8): 55-60.
QIN Yuluo, SONG Weidong, ZHANG Zaiyan, et al. Matching Method for Road Networks Considering Geometric Features and Topological Continuity[J]. *Bulletin of Surveying and Mapping*, 2021(8): 55-60.
- [18] CHU T S, YAN H W, LI P B, et al. A Similarity Calculation Model of Road Network and Its Application in Map Generalization Quality Evaluation[J]. *Spatial Cognition & Computation*, 2024, 24(1): 6-31.
- [19] YAN H W. Quantifying Spatial Similarity for Use as Constraints in Map Generalisation[J]. *Journal of Spatial Science*, 2024, 69(1): 23-42.
- [20] LECUN Y, BENGIO Y, HINTON G. Deep Learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [21] 王米琪, 艾廷华, 晏雄锋, 等. 图卷积网络模型识别道路正交网格模式[J]. 武汉大学学报(信息科学版), 2020, 45(12): 1960-1969.
WANG Miqi, AI Tinghua, YAN Xiongfang, et al. Grid Pattern Recognition in Road Networks Based

- on Graph Convolution Network Model[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(12): 1960-1969.
- [22] YANG M, JIANG C J, YAN X F, et al. Detecting Interchanges in Road Networks Using a Graph Convolutional Network Approach [J]. *International Journal of Geographical Information Science*, 2022, 36(6): 1119-1139.
- [23] YAN X F, AI T H, YANG M, et al. A Graph Convolutional Neural Network for Classification of Building Patterns Using Spatial Vector Data [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, 150: 259-273.
- [24] YAN X F, AI T H, YANG M, et al. Graph Convolutional Autoencoder Model for the Shape Coding and Cognition of Buildings in Maps[J]. *International Journal of Geographical Information Science*, 2021, 35(3): 490-512.
- [25] 李安平, 翟仁健, 殷吉崇, 等. 顾及空间结构关系的居民地自动合并方法[J]. 武汉大学学报(信息科学版), 2024, 49(9): 1723-1733.
LI Anping, ZHAI Renjian, YIN Jichong, et al. Automatic Aggregation of Building Considering Spatial Structure[J]. *Geomatics and Information Science of Wuhan University*, 2024, 49(9): 1723-1733.
- [26] 晏雄锋, 袁拓, 杨敏, 等. 建筑物形状特征分析表达与自适应化简方法[J]. 测绘学报, 2022, 51(2): 269-278.
YAN Xiongfeng, YUAN Tuo, YANG Min, et al. An Adaptive Building Simplification Approach Based on Shape Analysis and Representation [J]. *Acta Geodaetica et Cartographica Sinica*, 2022, 51(2): 269-278.
- [27] YU B, YIN H T, ZHU Z X. Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting [EB/OL]. [2017-09-04]. <https://arxiv.org/abs/1709.04875>
- [28] XU Y Y, JIN S, CHEN Z L, et al. Application of a Graph Convolutional Network with Visual and Semantic Features to Classify Urban Scenes[J]. *International Journal of Geographical Information Science*, 2022, 36(10): 2009-2034.
- [29] HU S, GAO S, WU L, et al. Urban Function Classification at Road Segment Level Using Taxi Trajectory Data: A Graph Convolutional Neural Network Approach[J]. *Computers, Environment and Urban Systems*, 2021, 87: 101619.
- [30] YAN H W. Fundamental Theories of Spatial Similarity Relations in Multi-Scale Map Spaces[J]. *Chinese Geographical Science*, 2010, 20(1): 18-22.
- [31] 王艳红. 基于节点相似度的复杂网络社区发现算法的研究[D]. 西安:西安电子科技大学, 2014.
WANG Yanhong. The Research of Finding Community Structure of Complex Network Based on Node Similarity [D]. Xi'an: Xidian University, 2014.
- [32] KIPF T N, WELLING M. Semi-Supervised Classification with Graph Convolutional Networks [EB/OL]. [2016-02-14]. <https://arxiv.org/abs/1609.02907>
- [33] DENG L, YU D. Deep Learning: : Methods and Applications[J]. *Foundations and Trends in Signal Processing*, 2014, 7(3/4): 197-387.
- [34] KIPF T N, WELLING M. Variational Graph Auto-Encoders [EB/OL]. [2016-07-03]. <https://arxiv.org/abs/1611.07308>
- [35] YANG S, YANG B. Enhanced Network Embedding with Text Information[C]//The 24th International Conference on Pattern Recognition (ICPR), Beijing, China, 2018.
- [36] LIAO L Z, HE X N, ZHANG H W, et al. Attributed Social Network Embedding [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2018, 30(12): 2257-2270.