

基于卷积神经网络的地图符号空间冲突检测方法

戴涛¹, 蔡武宜¹, 秦晓莉², 范琰², 刘伟峰³

(1. 湖南省地质地理信息所(湖南省地质大数据中心), 湖南长沙 410007; 2. 湖南省国土资源规划院, 湖南长沙 410018;
3. 上海交通大学电子信息与电气工程学院, 上海 200241)

摘要: 地图尺度变化所产生的制图综合操作易导致符号空间冲突, 冲突类型分为线线冲突、线面冲突和面面冲突3种。检测冲突类型可确保地图在尺度变化后仍能有效传递空间信息。为此, 设计适用于符号空间冲突检测的卷积神经网络模型, 通过数据增强和均衡方法对小规模150×150分辨率的地图图像进行符号空间冲突分类。首先, 将3类冲突和无冲突的地图图像集转化为浮点数张量数据集, 并将其作为数据增强和均衡的对象以生成大规模张量数据集; 其次, 将大规模张量数据集输入由1个输入层、4个池化层、3个卷积层、1个平展层、1个全连接层和1个输出层组成的卷积神经网络进行训练, 得到适用于符号空间冲突检测的网络模型; 最后, 将待分类地图图像输入至训练好的网络模型中, 得到该图像的符号空间冲突类型。采用实际地图数据验证模型性能, 与传统检测方法相比, 所提方法具有更高的检测精度, 具备应用于实际检测场景的潜力。

关键词: 卷积神经网络; 符号空间冲突; 地图图像; 数据增强与均衡

DOI: 10.11907/rj.dk.232256

开放科学(资源服务)标识码(OSID):

中图分类号: TP183

文献标识码: A

文章编号: 1672-7800(2025)005-0194-06



Detection Method for Cartographic Symbol Space Conflict Based on Convolution Neural Network

DAI Tao¹, CAI Wuyi¹, QIN Xiaoli², FAN Yan², LIU Weifeng³

(1. Hunan Geological and Geographic Information Institute, Changsha 410007, China; 2. Hunan Provincial Institute of Land and Resources Planning, Changsha 410018, China; 3. Shanghai Jiaotong University, Shanghai 200241, China)

Abstract: The mapping synthesis operations caused by changes in map scale can easily lead to symbol space conflicts, which can be classified into three types: line line conflicts, line surface conflicts, and surface surface conflicts. Detecting conflict types can ensure that the map can still effectively transmit spatial information even after scale changes. Therefore, a convolutional neural network model suitable for symbol space conflict detection is designed to classify symbol space conflicts in small-scale map images with a resolution of 150×150 through data augmentation and equalization methods. Firstly, transform the map image sets of three types of conflicts and no conflicts into a floating-point tensor dataset, and use it as the object of data augmentation and equalization to generate a large-scale tensor dataset; Secondly, the large-scale tensor dataset is fed into a convolutional neural network consisting of one input layer, four pooling layers, three convolutional layers, one flattening layer, one fully connected layer, and one output layer for training, resulting in a network model suitable for symbol space conflict detection; Finally, input the map image to be classified into the trained network model to obtain the symbol space conflict type of the image. By using actual map data to verify the performance of the model, it was found that compared with traditional detection methods, the proposed method has higher detection accuracy and has the potential to be applied in practical detection scenarios.

Key Words: convolution neural network; symbol space conflict; cartographic image; data enhancement and balance

收稿日期: 2023-12-08

扫描二维码阅读全文:



基金项目: 国家重点研发计划项目(2019YFE0122600); 湖南省科技计划项目(2017TP1029); 湖南省重点领域研发计划项目(2019SK2101)

作者简介: 戴涛(1994-), 男, 硕士, 湖南省地质地理信息所(湖南省地质大数据中心)工程师, 研究方向为地图制图学与地理信息工程; 蔡武宜(1982-), 男, 湖南省地质地理信息所(湖南省地质大数据中心)高级工程师, 研究方向为地图制图学与地理信息工程; 秦晓莉(1979-), 女, 硕士, 湖南省国土资源规划院高级工程师, 研究方向为土地工程与地理信息系统; 范琰(1980-), 男, 硕士, 湖南省国土资源规划院高级工程师, 研究方向为土地工程与地理信息系统; 刘伟峰(1994-), 男, 博士, 上海交通大学电子信息与电气工程学院讲师, 研究方向为电气工程与智能信息处理。

0 引言

空间数据质量主要涵盖数据来源的可靠性、属性数据的准确性、位置数据的精确度、语义的清晰度、数据的完整性、逻辑的一致性以及时态信息的精确性等方面^[1]。地图的抽象概括、分类分级和符号化易使地图符号的形状、大小和位置等发生变化,由此产生的符号空间冲突错误地表达了地图信息,对空间数据质量、可视化造成了负面影响^[2-3]。本质上,符号空间冲突主要由地图尺度变化所产生的制图综合操作导致,按图形输出的层次关系可分为线面冲突、面面冲突和线线冲突几类^[4-5]。这些冲突使得地图符号及其相间关系违背了符号语言规则,有必要对其进行检测及分类,以便作为自动制图综合技术的基础^[6]。

依赖空间数据库生成小比例尺地图易发生符号要素重叠或相距过近的情况。空间冲突检测通常聚焦于阅图者的感兴趣区域,及时排查符号空间冲突类型,以便调用相关修复算法进行校正。例如,文献[7]以线目标真值为中心建立圆状缓冲区,如果线目标间的缓冲区发生重叠则判定为符号空间冲突,但这是一种简单的冲突搜索算法,未能辨识具体类别。文献[8]以交通网络的线线冲突为研究对象,提出一种基于拓扑一致性的多尺度交通网空间冲突检测方法,可检测到人工难以辨识的空间冲突。文献[9]为区别山脊点与山谷点,提出基于局部坐标系的矢量投影法,可用于分析地貌单元的变化规律。上述研究适用于特定场景的符号空间冲突检测,对于普适性场景的精度不高、适应性差且依赖人工经验,难以适应大数据任务。

近年来,人工智能技术在空间冲突检测领域有一定应用,其可基于点、线之间的潜在关系来辨识符号空间冲突类型,进而以较高的准确率识别空间冲突的从属关系^[10-12]。区别于完全连接的神经网络,卷积神经网络(Convolutional Neural Networks, CNN)的卷积层和池化层可有效降低数据维度,减少计算复杂度,在符号空间冲突检测方面有较好效果^[13]。例如,文献[14]提出基于稀疏像素的CNN训练方法,可解决空间冲突的训练数据稀缺问题。文献[15]提出基于CNN的地图相似度匹配方法,可以从海量地图图片中检索出某一类地图。文献[16]将语义分割后的地图与环境信息联合起来作为CNN的输入,实现了智能车的自动定位与巡航。上述基于CNN的地图识别方法需要较为理想的训练数据集,将其应用于现实场景中的符号空间冲突检测任务时常会因训练数据质量不高而导致检测效果不达预期。

联结拓扑与方向关系冲突、基于规则的检测算法等是进行符号空间冲突检测的典型要素,依托此构建的冲突检测流程虽然取得了一定成效,但缺乏通用性和演化能力^[17]。自适应应用场景、不断趋优的符号空间冲突检测的难点在于低维检测规则中综合的点、线目标对象大多只能

考虑实体本身,对综合实体间模糊关系的建模能力较弱,从而限制了查询、分析和推理的上限^[18]。作为在图像识别领域应用广泛的深度学习算法,CNN在提取模糊的暗知识特征和数据泛化方面具有一定优势^[19]。理论上讲,将符号空间冲突检测视为分类问题,通过合理设计CNN的输入层、卷积层、池化层和输出层,可实现高精度、强泛化的符号空间冲突检测^[20]。如图1所示,地图图像在转换为一定规模的张量后,输入至已训练的CNN黑箱模型,可获得该地图图像具体属于哪类符号空间冲突类型。其中,CNN的输入层作为外部数据接口,负责将地图图像转化为合适的图像格式;卷积层作为模型核心,在大量计算下负责抽取图像特征;池化层被配置于连续的卷积层之间,旨在减少数据和参数的规模;全连接层用于进行非线性组合,得出符号空间冲突的分类结果,即从线线冲突、线面冲突、面面冲突和无冲突中选一类作为解。




Fig. 1 Principle of utilizing CNN

图1 CNN的应用思路

基于以上研究内容,针对实际地图在不同比例尺伸缩时产生的符号空间冲突问题,本文提出基于CNN的符号空间冲突检测方法,用于提升其检测精度和鲁棒性,主要贡献包括:①提出适用于符号空间冲突检测的CNN模型框架,合理设计了输入层、卷积层、池化层和连接层等关键要素,可为CNN大规模应用于该领域提供参考;②针对训练数据质量不高和稀缺等问题,通过随机水平翻转、颜色变化和仿射变换等数据增强和均衡方法,有效提升了符号空间冲突的检测精度。

1 检测模型构建

构建CNN模型包括制定CNN框架和构建训练数据集两个关键步骤。前者旨在设计CNN内部卷积层和池化层的数量、顺序及其3D张量,后者旨在对标签化的地图图像进行数据预处理、增强与均衡。

1.1 CNN框架

对于具有较大尺寸和复杂点线关系的地图图像,需协同多个卷积层和池化层来增大CNN的网络容量和减小地图图像尺寸,以便实现地图图像的有效分类。训练CNN的框架如图2所示。

具体来说,小规模带标签的地图图像集经过数据增强与均衡操作后,得到大规模的浮点数张量数据集,以此作为CNN的输入。CNN由1个输入层(内核为卷积层)、4个




Fig. 2 Framework for training CNN

图2 训练CNN的框架

池化层、3个卷积层、1个平展层、1个全连接层、1个输出层（内核为全连接层）组成，卷积层和池化层括号内的数值依次表示该层的高度、宽度和通道数量，其中宽度和高度会随着网络的加深而变小，通道数量和参数规模则逐步增大；平展层和全连接层括号内的数值表示向量维度。具体参数如表1所示。

Table 1 CNN network parameter settings

表1 CNN网络参数设置

网络层	参数规模
输入层(148, 148, 32)	896
池化层(74, 74, 32)	0
卷积层(72, 72, 64)	18 496
池化层(36, 36, 64)	0
卷积层(34, 34, 128)	73 856
池化层(17, 17, 128)	0
卷积层(15, 15, 128)	147 584
池化层(7, 7, 128)	0
平展层(6272)	0
全连接层(512)	321 776

需要说明的是，CNN的超参数主要决定卷积层—池化层组合数量，输出层、输出层、平展层和全连接层的规模则适应性地进行调整。具体策略为：在指定区间进行参数遍历，以式(1)所示的综合精度 P_c 作为评价指标，寻找卷积层层数与池化层的最优组合。其中，指定卷积层—池化层组合数量的区间为 $[2, 6]$ 。

$$P_c = (P_{L-L} + P_{L-S} + P_{S-S} + P_{None})/4 \quad (1)$$

式中： P_{L-L} 、 P_{L-S} 、 P_{S-S} 和 P_{None} 分别为地图图像集中线线冲突、线面冲突、面面冲突和无冲突的检测精度。

输入层输入150×150尺寸的浮点数据，卷积核设置为3×3，以匹配图像的RGB参数。边界效益使得该层的输出张量为(148, 148, 32)的特征图，其物理意义为计算32个包含148×148的数值网格过滤器。

为避免梯度消失现象并提高泛化能力，卷积层通常采用ReLU激活函数，但其在梯度为0时可能导致神经元失效，故本文采用Leaky-ReLU函数来克服该弊端。表示为：

$$f(x) = \begin{cases} x, & \text{if } x > 0 \\ ax, & \text{if } x \leq 0 \end{cases} \quad (2)$$

式中： a 表示负半轴斜率，为很小的常数。

本质上，符号空间冲突是视觉世界中的空间层次结构异常。CNN中的卷积层用于学习空间层次结构，首个卷积层学习较小的局部模式（如边缘），下个卷积层学习由上个特征组成的更大模式，依次递进。如此以来，CNN可学习到越来越复杂和抽象的空间层次结构。

池化层旨在对特征图进行采样，需确保密集的特征图并实现子图块的最大激活，故使用2×2窗口和2步幅的最大池化运算，既可减少处理特征图的元素个数，又能放大连续卷积层的观察窗口，从而实现空间过滤器的层级结构。

平展层将3D张量展平为值向量，使其可作为全连接层的输入。全连接层将前面层级提取到的地图图像特征综合起来，将其映射到样本标记空间，仍采用Leaky-ReLU激活函数。

输出层作为一种特殊的全连接层，起到分类作用。其根据历史学习的知识将地图图像类别划分为线线冲突、线面冲突、面面冲突或无冲突，即使用sigmoid激活函数选出预测类型。计算公式为：

$$S(x) = 1/(1 + e^{-x}) \quad (3)$$

鉴于CNN的最后一层为sigmoid单元，通常使用二元交叉熵作为损失函数，使CNN的参数更新更快。表示为：

$$H(p, q) = -\sum_x P(x) \log(q(x)) \quad (4)$$

式中： $p(x)$ 为真实概率； $q(x)$ 为sigmoid的输出。

1.2 数据集训练

1.2.1 数据预处理

将预训练或待辨识的地图图像输入 CNN 前,需将数据格式化为浮点数张量。地图图像通常为 JPEG 格式,转换为 150×150 分辨率后的数据预处理步骤为:

(1) 标签化预训练地图图像,即对图像事先标注线线冲突、线面冲突、面面冲突或无冲突类型;待辨识地图图像则无需经历该步骤。

(2) 将 JPEG 格式的地图图像解码为 RGB 像素网格。

(3) 将 0~255 区间的像素值归一化。公式为:

$$x' = x/255$$
 (5)

式中: x 和 x' 分别为原始值和归一化值。

1.2.2 数据增强与均衡

为提升 CNN 的泛化性和精度,分别进行数据增强和数据均衡操作。考虑到预训练地图图像的数量有限,为避免过拟合现象,通过可信的随机旋转、随机上下平移、随机错切角度、随机缩放和随机翻转等操作来增加预训练地图图像数量,使 CNN 可观察到更多地图图像,增强其泛化性。数据增强实例如图 3 所示。




Fig. 3 Examples of data enhancement for horizontal-horizontal conflict

图 3 面面冲突的数据增强实例

为避免预训练地图图像集中符号空间冲突图样过多,使得 CNN 即使乱判也能获取较高的精度,对数据进行均衡操作。具体步骤为:①按顺序排列所有地图符号空间冲突类别;②在 CNN 分批训练时,每批按索引顺序选取两个同类图像进行叠加处理,生成合并样本以强化特征学习。需

要说明的是,通过数据增强随机增加的图样对于避免上述不足也有改善作用。若训练地图图像集较小,可考虑在平展层与全连接层之间添加 Dropout 层,以避免过拟合。

2 验证实验

2.1 实验方法

算例在 Keras 深度学习框架下进行,通过 TensorFlow 在 CPU 和 GPU 下运行,计算机配置为 Intel Core I7 9th Gen,模型训练费时约 546 s。

以湖南省地理空间矢量数据为数据源,其典型样式如图 4 所示。将符号空间冲突地图图像分为训练集、验证集和测试集。在训练集中,线线冲突、线面冲突、面面冲突和无冲突的地图图像均为 1 000 张;在验证集与测试集中,4 类地图图像均为 100 张。



Fig. 4 Style of map image
图 4 地图图像样式

2.2 实验结果与分析

2.2.1 CNN 性能

区别于其他难以解释的黑盒模型,受益于视觉概念的表达,CNN 的学习进程支持可视化。图 5 为 CNN 连续层对图 3(a)的变换进程,即卷积层和池化层输出的前几层特征图。可以看出,层数加深会使激活更抽象,即图像视觉信息变少、类别信息变多,表明所设计的 CNN 框架能表示高层次概念,适合作为信息蒸馏管道来过滤无关地图图像信息,同时放大、细化有价值的类别信息。

经过数据增强与均衡,所提 CNN 模型在训练集和验证集上的精度和损失如图 6 所示。可以看出,CNN 模型的训练和验证精度整体随时间线性增加,训练精度接近 90%,而验证精度在 75% 左右;训练损失逐步减小至 0.08,而验证损失在第 23 轮达到最小。很明显,模型出现了轻微的过拟合现象,原因是各个类别的训练样本数较少(1 000




Fig. 5 Activation effect visualization of CNN

图5 CNN激活效果的可视化

个),增加训练数据规模可改善模型效果。调参后的CNN通过卷积层自动学习数据特征,利用局部连接和参数共享减少模型复杂度,同时通过多层结构提取复杂特征,能够从原始数据中直接提取有用信息,具备良好的泛化能力。


2.2.2 不同方法比较

在测试集上将基于缓冲区的方法^[21]和基于栅格的方法^[7]与本文方法进行比较,结果如表2所示。可以看出,相较于其他两种检测方法,所提方法可以较高的精度检测符号空间冲突类型,除面面冲突精度稍逊色外,其他符号空间类型的检测精度均优于对照方法。

CNN在本文算例上的测试精度不如在其他领域的检测效果,可能是由于小规模训练集的缘故。若地图图像规范,相关机构不断提供训练素材,或将本文训练的CNN开源作为国内首个符号空间冲突类型的预训练网络,以供后续研究者不断在此基础上精进,其检测精度将进一步提升。


3 结语

实际地图在不同比例尺伸缩时易产生符号空间冲突,明晰其冲突类型是校正的前提。传统检测方法对新兴场景适应性差且依赖人工经验调参,不合适大数据任务。为此,本文以150×150分辨率地图图像为研究对象,提出适用于符号空间冲突检测的CNN模型,并通过数据增强和均衡方法较好地解决了训练数据质量不高和稀缺的问题,有效提升了符号空间冲突检测精度。然而,由于不同场景的点、线关系复杂,小规模训练数据集很难穷尽,过拟合是桎梏模型检测精度的关键原因。构建开放、自生长的符号空



(a) Training accuracy and validation accuracy

(a) 训练精度和验证精度



(b) Training loss and validation loss

(b) 训练损失和验证损失

Fig. 6 Accuracy and loss of CNN models on training and validation sets

图6 CNN模型在训练集和验证集上的精度和损失

Table 2 Accuracy performance of different methods

表2 不同方法精度比较

方法	综合精度	线线冲突 精度	线面冲突 精度	面面冲突 精度	无冲突 精度
本文方法	0.805 0	0.880 0	0.870 0	0.720 0	0.750 0
基于缓冲区的方法	0.747 5	0.710 0	0.750 0	0.810 0	0.720 0
基于栅格的方法	0.725 0	0.690 0	0.730 0	0.780 0	0.700 0

间冲突类型数据库是CNN实现高精度检测的要素,国内尚缺乏相关研究,后续将尝试建立。

参考文献:

- [1] CUI T J. Principles of geospatial database [M]. Beijing: Science Press, 2010.
崔铁军. 地理空间数据库原理[M]. 北京: 科学出版社, 2010.
- [2] LIU W Z. Automatic detection method for spatial conflicts in GIS database updates [M]. Beijing: Surveying and Mapping Press, 2009.
刘万增. GIS数据库更新中空间冲突自动检测方法[M]. 北京: 测绘出版社, 2009.

- [3] ZHAN C S. Research on automatic detection of spatial conflicts in multi-scale database: taking line features as an example[D]. Zhengzhou: Information Engineering University, 2012.
詹陈胜. 多尺度数据库中空间冲突自动检测方法研究——以线要素为例[D]. 郑州:解放军信息工程大学, 2012.
- [4] WANG J Y, SUN Q, WANG G X, et al. Principles and methods of cartography[M]. Beijing: Science Press, 2005.
王家耀, 孙群, 王光霞, 等. 地图学原理与方法[M]. 北京: 科学出版社, 2005.
- [5] MACKANESS W, FISHER P F. Automatic recognition and resolution of spatial conflicts in geographic symbolization[C]//Proceedings of Auto-Carto, 1987: 709–718.
- [6] CHEN M H, ZHANG X C. Automatic detection handling method of spatial conflict in spatial data dynamic updating [J]. Geospatial Information, 2013, 11(3): 37–39.
陈明辉, 张新长. 空间数据动态更新的空间冲突的自动检测处理方法[J]. 地理空间信息, 2013, 11(3): 37–39.
- [7] LIU J P. Handling of features' relationships in the process of the graphic output of cartographic data base [J]. Journal of Geodesy and Geoinformation Science, 1994(3): 222–228.
刘纪平. 地图数据库图形输出中要素关系处理[J]. 测绘学报, 1994(3): 222–228.
- [8] SHAO X, SHI L Y, ZHANG L. Method of spatial conflict detection for multi-scale transportation network based on topological consistency [J]. Geomatics & Spatial Information Technology, 2020, 43(6): 59–61, 66.
邵轩, 时绿艳, 张良. 基于拓扑一致性的多尺度交通网空间冲突检测方法[J]. 测绘与空间地理信息, 2020, 43(6): 59–61, 66.
- [9] LI Z H, WEI B, ZHOU X D, et al. Research on efficient detection method of spatial conflicts between contours and single-line rivers [J]. Science of Surveying and Mapping, 2018, 43(11): 137–141, 164.
李振豪, 魏斌, 周校东, 等. 等高线与单线河空间冲突的高效检测方法研究[J]. 测绘科学, 2018, 43(11): 137–141, 164.
- [10] ZHANG X C, HE X J, SUN Y, et al. Advance and future development of the multi-scale spatial data linkage updating [J]. Journal of Geodesy and Geoinformation Science, 2022, 51(7): 1520–1535.
张新长, 何显锦, 孙颖, 等. 多尺度空间数据联动更新技术研究现状及展望[J]. 测绘学报, 2022, 51(7): 1520–1535.
- [11] TAN Z, GUO X L, LI J Z, et al. Multi-scale convolutional neural network model for pipeline leak detection [J]. Journal of Hydraulic Engineering, 2023, 54(2): 220–231.
谭震, 郭新蕾, 李甲振, 等. 基于多尺度卷积神经网络的管道泄漏检测模型研究[J]. 水利学报, 2023, 54(2): 220–231.
- [12] AI T H. Some thoughts on deep learning enabling cartography [J]. Journal of Geodesy and Geoinformation Science, 2021, 50(9): 1170–1182.
艾廷华. 深度学习赋能地图制图的若干思考[J]. 测绘学报, 2021, 50(9): 1170–1182.
- [13] DHRUV P, NASKAR S. Image classification using convolutional neural network (CNN) and recurrent neural network (RNN): a review [J]. Machine Learning and Information Processing, 2020, 34: 367–381.
- [14] LABAN N, ABDELLATIF B, EBEID H M, et al. Sparse pixel training of convolutional neural networks for land cover classification [J]. IEEE Access, 2021, 9: 52067–52078.
- [15] WANG Z, LIU J P, CHE X H, et al. Research on map similarity matching method based on convolutional neural network [J]. Science of Surveying and Mapping, 2022, 47(7): 169–175.
王铮, 刘纪平, 车向红, 等. 基于卷积神经网络的地图相似度匹配方法研究[J]. 测绘科学, 2022, 47(7): 169–175.
- [16] LIU Z J, ZHAO Y B, LI L H, et al. A method for semantic simultaneous localization and map construction based on convolutional neural networks [J]. Science Technology and Engineering, 2019, 19(9): 148–153.
刘智杰, 赵一兵, 李琳辉, 等. 基于卷积神经网络的语义同时定位以及地图构建方法[J]. 科学技术与工程, 2019, 19(9): 148–153.
- [17] DENG G Q, XIAO X N, MA X P, et al. On the technology for automatic digital topographic map generation from fundamental geographic information dataset: symbol conflicts and detection [J]. Standardization of Surveying and Mapping, 2011, 27(1): 17–21.
邓国庆, 肖学年, 马晓萍, 等. 基础地理信息数据集自动生成数字地形图技术研究——符号冲突与检测[J]. 测绘标准化, 2011, 27(1): 17–21.
- [18] CHEN H, QI X, YU L, et al. DCAN: deep contour-aware networks for accurate gland segmentation [C]//Las Vegas: 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [19] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks [C]//17th International Conference on Engineering Applications of Neural Networks, 2016: 213–226.
- [20] MURUGAN P. Feed forward and backward run in deep convolution neural network [DB/OL]. <http://arxiv.org/abs/1711.03278>.
- [21] PERKAL J. Michigan inter-university community of mathematical cartographers [M]. Ann Arbor: Institute of Mathematical Geography, 1966.

(责任编辑:尹晨茹)