

遥感影像中的深度学习变化检测 ——利用预生成深度变化显著图的方法

陈志兰¹

CHEN Zhilan

摘要

探索和验证一种新型的遥感影像变化检测方法——利用预生成深度变化显著图的方法 (PDACN)，以提高对复杂城市和自然环境中变化检测的准确性和效率。围绕 PDACN 模型的设计与实施，采用深度可分离卷积注意力机制 (PDA)，结合先进的编码器结构，有效地增强了模型对多时相遥感影像的特征提取和分析能力。通过在 SYSU-CD 数据集上的应用，与现有的 DSAMNet、BiDateNet 和 STANet 等方法进行了比较分析。研究结果显示，PDACN 模型在 F1 分数、精确度、召回率和交并比等关键性能指标上均显著优于对比方法。此外，模型展现出在处理更复杂场景变化时的高效性和鲁棒性，不仅提高了遥感影像变化检测的技术水平，还为未来相关领域的研究提供了新的思路和工具，具有重要的理论意义和实际应用价值。

关键词

遥感影像；深度学习；变化检测；显著图

doi: 10.3969/j.issn.1672-9528.2024.08.020

0 引言

随着遥感技术的快速发展，高分辨率遥感影像已成为监测地表变化的重要手段。遥感影像变化检测在城市规划、环境监测和灾害评估等领域具有广泛的应用。然而，传统的变化检测方法往往难以应对复杂场景下的细微变化，尤其是在自然环境和城市扩张等多变化类型的场景中。针对这一挑战，本研究提出了一种新型的深度学习方法——利用预生成深度变化显著图的遥感影像变化检测方法 (PDACN)。该方法通过深度可分离卷积注意力机制 (PDA)，有效提升了模型对遥感影像多时相数据的特征提取和变化检测能力。研究目的在于通过 PDACN 模型，实现对复杂城市和自然场景中变化的高精度、高效率检测，进一步推动遥感影像变化检测技术的发展，并为相关领域的应用提供强有力的技术支持。

1 多时相变化检测基础

多时相变化检测技术主要分为基于块结构的方法和逐像素分类的方法，块结构的方法通常将变化检测问题视为一种影像分类任务^[1]。

逐像素分类的方法常通过端到端的网络结构直接对特征图上的每个像素进行分类。该方法容易受到噪声的影响，可通过使用 LSTM 来处理影像匹配中的不准确问题，而基于时

空注意力的网络 (STANet) 则通过度量学习获得变化图，其使用的时空注意力机制能够获取更具判别力的时空特征。

2 PDACN 总体网络框架设计

PDACN 网络结构主要由三部分组成：编码器、解码器和分类头。编码器部分采用权重共享的特征提取器，自动从两张时相影像中抽取具有代表性的多尺度特征^[2]。其中不仅包含了影像的基本信息，还反映了影像间的细微差异。

解码器部分的设计旨在处理和融合来自不同时相的多尺度特征，通过精细的重建过程，恢复影像特征的同时，重建其细节部分，确保特征的完整性和一致性。此外，为了消除不同时期特征图上可能出现的语义误差，采用了预生成的深度可分离变化显著图注意力机制 (pre-generated depth wise separable change salient maps attention, PDA)。该机制生成的变化显著图用于进行初步的变化位置定位。分类头部分则通过多层卷积结构将特征图的通道数降低，区分出变化和未变化的两种状态，并通过 Argmax 操作生成最终的变化二值图。在涉及多分类问题时，网络能够输出与类别数量相对应的通道数，提供更细致的分类结果。该预生成深度变化显著图的遥感变化检测方法，即 pre-generated depth wise separable special-temporal attention change-detection networks (PDACN)，如图 1 所示。通过其创新的网络结构和算法设计，显著提高了遥感影像变化检测的精确度和实用性。

1. 福建省自然资源地理信息中心 福建福州 350001

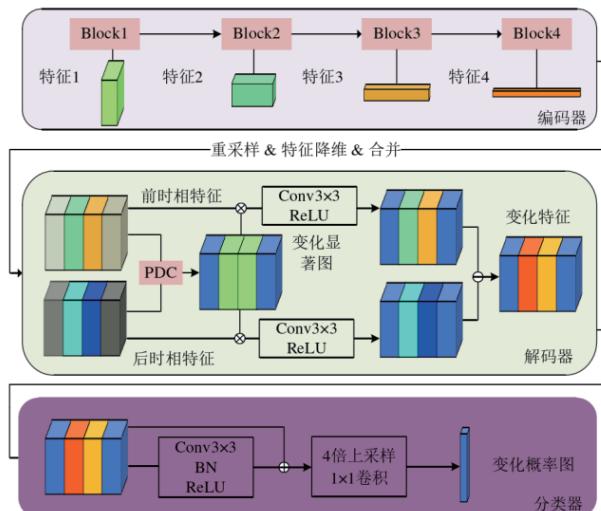


图 1 PDACN 总体网络结构设计

2.1 PDACN 解码方法

在遥感影像深度学习变化检测的 PDACN 模型中,解码器的设计至关重要,它能够从编码器提取的特征中恢复出更细致的影像细节,从而更精准地定位和识别变化区域^[3]。本部分详细介绍了 PDACN 模型中解码器的设计与实现方式,解码方法基于预生成深度变化显著图,使用了先进的网络结构来加强模型的解码效能。从模型容量角度分析,PDACN 模型采用了 ResNet18 和 Segformer 在内的多种预训练深度网络结构作为编码器。

2.2 分类头预处理

分类头通过一系列精细设计的操作,将复杂的特征图转化为最终的变化概率图。首先,分类头通过两层卷积操作处理融合后的特征图,以此降低通道数量,从而减少模型的计算负担,也优化了后续的分类过程。此外,为了增加模型的鲁棒性,这两层卷积之间构建了残差连接。残差连接有助于保持在深层网络中信息的流动,避免在训练深层网络时可能出现的梯度消失问题。

分类操作的最后一步是将处理过的特征图通过双三次线性插值方法重新采样到与原始遥感影像相同的分辨率^[4]。最终,使用 1*1 卷积来完成分类任务,输出最终的变化概率图。该方法不仅简化了分类头的结构,也提高了其执行效率,使得分类过程更加高效且准确。

2.3 损失函数选择

在 PDACN 模型的总体网络框架设计中,损失函数的选择对模型的训练效果和最终的变化检测性能具有决定性的影响^[5]。为了提高变化检测的精度,本模型综合采用了 Dice 损失函数和交叉熵损失函数。这两种损失函数各自针对模型训练的不同需求和挑战,优化了模型对遥感影像变化的识别能力。

首先, Dice 损失函数是基于集合的相似度度量,广泛应用于医学影像分割领域,特别适用于数据类别不平衡的情况。Dice 系数计算两个样本的交集大小的两倍与各自大小之和的比值,其公式表示为:

$$\text{Dice} = \frac{2 \times |Y \cap P|}{|Y| + |P|} \quad (1)$$

式中: Y 是真实标签, P 是预测结果。Dice 损失函数定义为 1-Dice 系数即:

$$\text{DiceLoss} = 1 - \frac{2 \times \sum_i^N p_i y_i + \epsilon}{\sum_i^N p_i + \sum_i^N y_i + \epsilon} \quad (2)$$

式中: p_i 和 y_i 分别是预测和真实标签在每个像素点的值, ϵ 是一个小常数,用于防止分母为 0。这种损失函数有助于直接优化分割区域的重叠度,对于变化检测任务中常见的小面积变化特征尤为有效。

其次,交叉熵损失函数是处理分类问题中最常用的损失函数之一,通过衡量实际输出与预测输出之间的差异来优化模型的参数。对于二分类问题,交叉熵损失函数的表达式为:

$$\text{Cross-entropyLoss} = -\frac{1}{N} \sum_i^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (3)$$

式中: N 是样本的总数。损失函数对每个像素的分类错误提供了直接的梯度更新,有助于模型在处理大规模遥感数据时,快速准确地学习区分变化与未变化区域。

3 实验结果分析

3.1 SYSU-CD 数据集

SYSU-CD 数据集是专门为深度学习变化检测研究而设计的,包含 20 000 对航拍影像,这些影像记录了 2007 年至 2014 年间香港地区的城市扩张、更新以及自然变化等多种类型的变化。每幅影像的大小为 256 像素 × 256 像素,分辨率达到 0.3 m,能够提供极高的细节清晰度。该数据集的设计旨在挑战并推动变化检测技术的发展,尤其是在自然变化类型的检测方面,这些变化通常更加复杂和微妙。整个 SYSU-CD 数据集按照 6:2:2 的比例划分为训练集、验证集和测试集。具体而言,数据集中 12 000 张影像用于模型训练,4 000 张影像用于验证模型的泛化能力,另外 4 000 张影像用于最终的性能测试,确保检测结果的可靠性和准确性^[6]。这种划分方式有助于科研人员在不同阶段评估模型的效果,从而进行迭代优化。

表 1 展示了 SYSU-CD 数据集与 LEVIR-CD 数据集的基本信息对比。LEVIR-CD 数据集包含 637 对影像,每幅影像的分辨率为 0.5 m,大小为 1024 像素 × 1024 像素,其训练集、验证集和测试集的划分比例与 SYSU-CD 不同,反映了两个数据集在设计上的差异。

表 1 SYSU-CD 数据集与 LEVIR-CD 数据集的基本信息对比

数据集名称	波段数	影像对数量	分辨率/m	影像大小	训练集/验证集/测试集
SYSU-CD	3	20 000	0.3	256×256	12 000/4000/4000
LEVIR-CD	3	637	0.5	1024×1024	445/64/128

3.2 模型迭代训练

本实验采用的算法模型基于 PyTorch 框架, 在 Ubuntu20.04 操作系统上利用 10 个 NVIDIA Tesla V100 GPU 进行混合精度训练, 以提高训练效率并减少计算资源的消耗^[7]。模型中使用的编码器分为两种类型: 一种基于 ResNet, 使用 Torchvision 提供的官方预训练权重; 另一种基于 Segformer, 使用在 Citispaces 数据集上训练的预训练权重。网络结构中的其他模块采用随机初始化的方式。为了增强模型对遥感数据的泛化能力, 训练数据在处理过程中以 0.5 的概率进行随机水平翻转、垂直翻转和随机旋转 (90°、180°、270°) 进行数据增广。根据影像的大小不同, 训练过程中的批处理大小 (Batchsize) 也有所不同。具体而言, 大小为 1024×1024 的影像批处理大小为 2, 而 256×256 的影像批处理大小为 16。模型的训练计划设置为进行 300 个训练周期 (Epoch), 使用带权重衰减 (0.01) 的 AdamW 优化器进行训练^[8]。学习率从 3e-2 开始, 随着训练周期的进行线性降低至 0。每个训练周期结束后, 模型在验证集上进行性能评估, 保存在验证集上表现最好的模型权重作为最终结果。

3.3 结果分析

本文采用的 PDACN 方法在 SYSU-CD 数据集上与其他算法进行了比较, 以验证所提方法在复杂场景下的有效性。SYSU-CD 数据集包含了复杂的城市扩张和自然变化类型, 这对变化检测算法的精确性和鲁棒性提出了更高的要求。实验中使用的定量评价指标包括 F_1 分数、精确度 (Precision)、召回率 (Recall) 和交并比 (IoU), 如表 2 所示。

表 2 SYSU-CD 测试集上的定量分析结果

方法	F_1 /%	精确度/%	召回率/%	交并比/%
BiDateNet	76.94	81.84	72.60	62.52
STANet	77.37	70.76	85.33	63.09
DSAMNet	78.18	74.81	81.86	64.18
PDACN-R18S4	79.09	83.08	75.46	65.40
PDACN-R18S3	80.20	81.76	78.69	66.94
PDACN-Segb0	82.55	84.63	80.57	70.28

在实验配置上, 本文采用基于 PyTorch 的深度可分离卷积注意力机制 (PDA) 来增强多时相影像数据的特征信息。此外, 与 DSAMNet 方法的比较显示, DSAMNet 依靠通道和空间注意力机制增强特征, 而 PDACN 方法通过 PDA 机

制处理更为复杂的变化检测任务^[9]。在编码器的选择上, PDACN 模型测试了两种不同的编码器: 基于 Segformer-b0 和基于 ResNet18 的两种结构 (PDACN-R18S4 和 PDACN-R18S3)。

在 SYSU-CD 测试数据集的基础上, 其最终实验结果如图 2 所示, 其中黑色代表误检、灰色代表漏检部, 同时选取了测试集中具有代表性的变化类型, 并采取对比分析, 其中包括植被变化 (01536)、建造前地基工程 (01524)、海上建筑 (00028)、城区扩展 (00101)、新建建筑物 (00503)、道路扩展 (00147) 等^[10]。最终防线设计的 PDACN 方法在 Transformer 架构下 Segb0 检测结果最好, 对复杂变化场景具备更好的泛化能力。

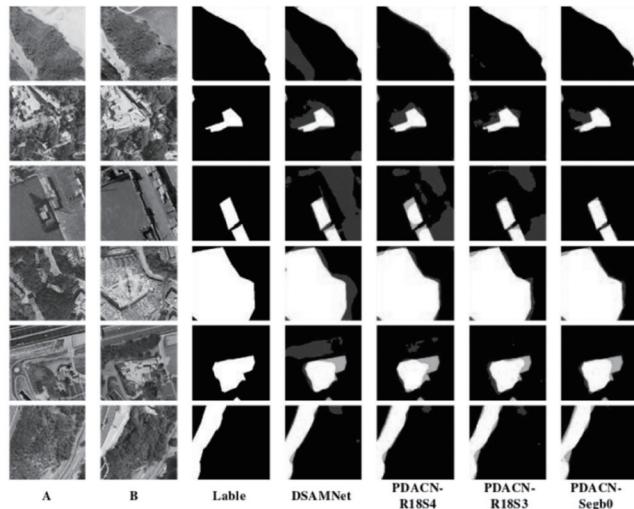


图 2 不同方法在 SYSU-CD 数据集上的变化检测显示图

4 结语

在本研究中, 深入探讨了遥感影像中的深度学习变化检测技术——利用预生成深度变化显著图的方法, 针对多时相遥感数据进行了系统的研究与分析。通过构建一个基于深度可分离卷积注意力机制 (PDA) 的 PDACN 模型, 成功提高了遥感影像变化检测的准确性和效率。该模型利用先进的编码器和注意力机制, 有效地处理了来自复杂城市和自然变化场景的遥感数据, 特别是在 SYSU-CD 数据集上显示出较传统方法更优的性能。实验结果表明, 与其他现有技术如 DSAMNet、BiDateNet 和 STANet 相比, PDACN 模型在各项性能指标上均有显著提升。尤其是在处理复杂变化场景时, PDACN 模型展现出其强大的特征提取和分类能力, 这归功于其独特的结构设计和混合精度训练策略。随着遥感技术和深度学习算法的不断进步, PDACN 模型将可以进一步优化和扩展, 以适应更多种类的遥感数据和更复杂的变化检测任务。此外, 模型的实时处理能力和对小型变化的敏感度亦是未来研究的重点, 期望通过改进模型架构和训练策略, 进一步提高其在实际应用中的表现。

基于 TextCNN 的地震新闻标题分类方法

白 灵^{1,2} 黄 猛^{1,2} 刘 帅^{1,2}
BAI Ling HUANG Meng LIU Shuai

摘要

当破坏性地震发生后，大量的信息产出，网上的地震新闻信息更是大量汇集。高效精准地识别与自动分类地震新闻，可使地震应急部门及时搜集各方面的应急态势，缓解面对海量新闻的压力，减少获取信息的时间成本。首先论述了地震新闻标题数据集的建设，然后实验对比分析了深度学习模型对地震新闻标题文本的分类效果。实验表明，采用 Word2vec 进行文本表示的 TextCNN 分类模型效果比较好，准确率达到了 92.03%。

关键词

地震新闻标题；文本分类；数据集建设；TextCNN

doi: 10.3969/j.issn.1672-9528.2024.08.021

0 引言

我国地震频发，且强度大、范围广，其造成的经济损失及人员伤亡居于自然灾害的首位。地震发生后，如果能在黄金救援 72 h 内做出恰当的应急响应，则可降低各种损失、减少人员伤亡。若想做出恰当的响应，需要对各种信息进行综合的研判。突发地震事件信息量巨大，应急人员面对大量的

信息，若能在短时间内对各类信息进行分类、分析及研判，则可提升救援效率。

新闻标题蕴含着新闻的关键信息，新闻标题短文本的自动化分类为地震应急部门快速获取及分类地震新闻信息提供了强有力的手段。本文介绍了地震新闻标题数据集建设、模型研究及改进、对比实验及分析等。

1 地震新闻标题数据集建设

针对地震新闻标题带标签数据集建设问题，本文做了以下工作。①获取了 1900 年至 2023 年地震目录中的震中位置信息，分析了地震新闻中和地震应急信息相关的关键字，应

1. 防灾科技学院 河北三河 065201

2. 河北省高校智慧应急应用技术研发中心 河北三河 065201

[基金项目] 廊坊市 2022 年科学技术研究与发展计划项目
(2022011029)

参考文献：

- [1] 陈婕, 刘纪平, 徐胜华. 增强边缘信息的全卷积神经网络遥感影像建筑物变化检测 [J]. 测绘通报, 2023(6):61-67.
- [2] 柳思聪, 都科丞, 郑永杰, 等. 人工智能时代的遥感变化检测技术: 继承、发展与挑战 [J]. 遥感学报, 2023, 27(9):1975-1987.
- [3] 徐志红, 关元秀, 王善华, 等. 融合对象影像分析和 OCNN 的耕地变化检测 [J]. 遥感信息, 2022, 37(5):15-22.
- [4] 姚沫风, 翁露洋, 李柏鹏, 等. 基于 CAR-Siamese 网络的高分辨率遥感图像建筑物变化检测 [J]. 中国科学院大学学报, 2023, 40(3):380-387.
- [5] 王佳, 刘锦秀, 李晓民, 等. 深度学习支持下的智能化信息提取技术在青海省自然资源变化监测中的应用 [J]. 青海国土资源, 2021(5):61-67.
- [6] 董志鹏. 基于卷积神经网络的高分辨率遥感影像目标检测方法研究 [J]. 测绘学报, 2023, 52(9):1613.
- [7] 毕卫华, 杨化超. 基于深度学习和 Cesium 的煤矿区地表变化检测方法研究 [J]. 能源技术与管理, 2023, 48(5):171-174.
- [8] 孙斌, 李俊鹏, 罗哲轩, 等. 基于 GF-3 影像的金沙江堰塞湖电网受灾区域提取 [J]. 航天返回与遥感, 2021, 42(5):96-107.
- [9] 麻连伟, 宇卫远, 焦利伟, 等. 基于 U-Net 卷积神经网络的遥感影像变化检测方法研究 [J]. 能源与环保, 2022, 44(11):102-106.
- [10] 魏汝兰, 王洪飞, 盛森, 等. 基于深度学习的卫星影像耕地变化检测方法及系统应用 [J]. 软件导刊, 2023(11):29-34.

【作者简介】

陈志兰 (1974—), 女, 福建龙岩人, 本科, 高级工程师, 研究方向: 遥感影像与自然资源信息化研究和应用。

(收稿日期: 2024-05-24)