

<http://bhxb.buaa.edu.cn> jbuaa@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2024.0152

基于局部空间深度特征的 SAR 遥感图像变化检测方法

张益天¹, 赵晶^{2,*}, 陈蒋洋³, 罗喜伶^{4,5}

(1. 工业和信息化部网络安全产业发展中心(工业和信息化部信息中心), 北京 100846;

2. 北京航空航天大学 科学技术研究院, 北京 100191; 3. 中国久远高新技术装备有限公司, 北京 100094;

4. 北京航空航天大学 电子信息工程学院, 北京 100191; 5. 北京航空航天大学 杭州创新研究院, 杭州 310051)

摘要: 为提高卷积神经网络(CNN)在变化检测任务中的鲁棒性能和泛化能力, 提出一种基于拉普拉斯支持向量机(LapSVM)的卷积小波神经网络(CWNLSN)模型。通过样本标记方法, 获得高置信度的“伪标签”, 划分出网络训练集、分类训练集和待测集; 在CNN中, 引入离散小波池化, 用于提取局部空间深度特征; 设计基于LapSVM的局部空间深度特征分类(LSDC)模块, 对待测集进行分类, 判别待测集的变化情况; 设置对比实验和消融实验, 在多组真实遥感数据集上进行测试。结果表明, 所提方法获得了更显著的变化检测效果。

关键词: 变化检测; 卷积神经网络; 离散小波池化; 拉普拉斯支持向量机; 局部空间深度特征

中图分类号: TP751

文献标志码: A

文章编号: 1001-5965(2026)04-1129-10

遥感技术^[1]起源于20世纪60年代, 是指在不直接接触的情况下, 对目标或自然现象进行远距离探测和感知的综合性探测技术, 是采集时空信息的重要手段。变化检测^[2-3]是指对同一地区、不同时刻获取的遥感图像进行分析, 提取变化区域的过程。变化检测是遥感领域重要的研究方向, 作为监测地表状况的关键技术, 已被应用于城市变迁检测^[4]、农林监测^[5]、灾害监测^[6]、国土监测^[7]等诸多领域。

近年来, 随着计算技术、存储技术和网络技术的不断发展, 深度学习作为机器学习重要的分支发展迅速, 推动着变化检测进入人工智能时代。根据是否使用标签数据(即先验知识), 深度学习算法可分为监督、无监督和半监督学习。然而, 大量用于图像变化检测的多时相图像通常没有人工标记的标签, 限制了监督深度学习算法在变化检测领域的应用。为解决上述问题, 许多学者往往采用如下范

式: 首先, 生成两时相遥感图像的差异图; 其次, 采用无监督图像分割, 将差异图分为高概率变化区域、高概率不变区域和中间区域, 以构建用于训练深度学习模型的高置信度训练样本集和待测集; 最后, 通过监督训练深度学习模型, 对待测集进行判别, 确定变化区域和非变化区域。究其根本, 上述范式是一个由粗到细的检测框架, 存在3个难点: ①需要构建高置信度的样本集, 用于深度学习模型的监督训练; ②需要设计泛化能力和特征表征能力较强的深度学习模型, 对图像变化情况进行精细化甄别; ③需要尽可能抑制图像噪声, 降低其对变化检测效果的干扰。

在高置信度样本集的构建上, 诸多学者基于模糊C均值聚类(fuzzy C-means clustering, FCM)算法^[8], 并结合阈值法^[9]、显著性检测^[10]、稀疏学习^[11]等其他方法, 提出了多种样本标记方法。然而, 上

收稿日期: 2024-03-18; 录用日期: 2024-05-31; 网络出版时间: 2024-07-18 10:30

网络出版地址: link.cnki.net/urlid/11.2625.V.20240716.1533.001

*通信作者. E-mail: zhao_jing@buaa.edu.cn

引用格式: 张益天, 赵晶, 陈蒋洋, 等. 基于局部空间深度特征的 SAR 遥感图像变化检测方法 [J]. 北京航空航天大学学报, 2026, 52(4): 1129-1138. ZHANG Y T, ZHAO J, CHEN J Y, et al. SAR remote sensing image change detection method based on local space deep feature [J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(4): 1129-1138 (in Chinese).

述标记方法的结果生成主要依赖 FCM 算法的聚类过程,其他方法仅作为辅助手段,未直接完整地生成标记结果。对此,研究人员提出基于最大类间方差和 Gabor 小波特征聚类的样本标记 (Otsu and Gabor wavelet feature-based labeling, OGFL) 方法^[12],获得多组标记结果,再通过图像融合将多组标记结果结合,生成高置信度“伪标签”,从而提升训练集的构建质量。基于上述优势,本文通过上述方法设计训练集和待测集,为有监督模型提供训练样本。

在深度学习模型的搭建上,近年来,卷积神经网络 (convolutional neural network, CNN) 极大提高了许多视觉任务的性能,研究人员也设计了诸多基于 CNN 的变化检测方法^[13-15]。尽管基于 CNN 的变化检测方法取得了优异的性能,但其二值分类判别仅通过 Softmax 层的激活函数。CNN 模型的激活函数一旦选定,则无法根据给定的样本数据自适应调整,束缚了 CNN 模型的效果。为了弥补上述缺陷,本文设计判别模型,代替 Softmax 层的激活函数,对全连接层的输出特征进行判别,提升 CNN 模型的泛化能力。

在噪声干扰的抑制上, CNN 模型提取浅层的基本视觉特征,将其逐步累计形成后续深层的高级特征^[16]。如果训练样本中含有大量散斑噪声,则会出现噪声累计的情况,其高级特征无法更好地耦合变化检测任务。针对上述问题,本文在池化层中引入滤波机制,提升变化检测精度。

本文提出基于局部空间深度特征的合成孔径雷达 (synthetic aperture radar, SAR) 遥感图像变化检测方法,融合深度学习模型和统计机器学习算法,实现了像素块级变化检测,为遥感科学技术应用提供了解决方案。首先,通过样本标记方法,构建网络训练集、分类训练集和待测集;然后,在 CNN 中,引入离散小波池化,提取局部空间深度特征;最后,设计基于拉普拉斯支持向量机 (Laplace support vector machines, LapSVM) 的局部空间深度特征分类 (local space deep feature classification, LSDC) 模块,判别待测集的变化情况,获得变化检测结果。

1 样本标记及样本数据集构成

通过 OGFL 方法^[12]获得样本数据的“伪标签”,构建网络训练集、分类训练集和待测集,分别用于深度学习模型的监督训练、分类器的半监督训练及待测区域的精细化判别,其流程如图 1 所示。

1.1 样本标记

对同一地区、不同时相获取的 2 张遥感图像进行去噪处理^[17-18],得到基于对数比算子^[19]的差

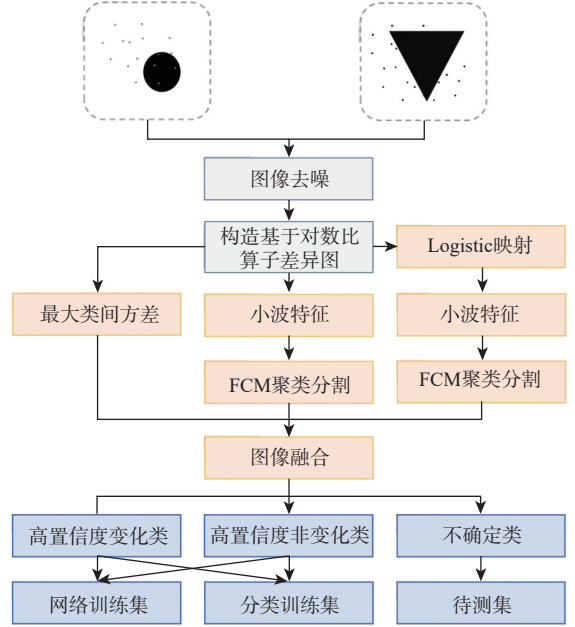


图 1 OGFL 方法流程

Fig. 1 Flow chart of OGFL method

异图。

通过最大类间方差^[20]提取灰度阈值,实现差异图的二值化分割,生成第 1 组低置信度标记结果 L_1 。

提取差异图的 Gabor 小波特征^[18] $\chi_1 = [x_1, x_2, \dots, x_{MN}]^T$,通过 FCM 算法^[8],生成第 2 组低置信度标记结果 L_2 。

提取 Logistic 映射后的差异图的 Gabor 小波特征^[18] $\chi_2 = [x_1, x_2, \dots, x_{MN}]^T$,通过 FCM 算法,生成第 3 组低置信度标记结果 L_3 。

将第 1 组低置信度标记结果 L_1 和第 2 组低置信度标记结果 L_2 相融合。若对于像素位置 (m, n) ,第 1 组低置信度标记结果 L_1 和第 2 组低置信度标记结果 L_2 均为变化类,则像素位置 (m, n) 属于变化类区域 Ω_c ;第 3 组低置信度标记结果 L_3 为非变化类,则像素位置 (m, n) 属于非变化类区域 Ω_u ;其他像素位置 (m, n) 属于不确定类区域 Ω_l 。综合上述结果,构成高置信度“伪标签”矩阵 Y 。上述过程表示如下:

$$Y_j = \begin{cases} 0 & (L_1^j L_2^j)^2 + (L_3^j)^2 = 0 \\ 1 & L_1^j + L_2^j = 2 \\ 0.5 & \text{其他} \end{cases} \quad (1)$$

式中: j 表示像素位置位于 $(m-1)M+n$ 的像素; L_j^j 为 L_j 中第 j 个像素的标记结果; Y_j 为 Y 中第 j 个像素的高置信度“伪标签”。

1.2 样本数据集构成

首先,在 1.1 节的 2 幅遥感图像中,以 Ω_u 和 Ω_c 区域里的像素位置 j 为中心,取长和宽均为 k 的像素块 p_j^1 和 p_j^2 ,将其级联成长和宽分别为 $2k \times k$ 的样本块

$$P_j = [p_j^1, p_j^2]$$

然后, 在样本块 P_j 中, 随机选取 500 个变化类和 500 个非变化类样本, 构成网络训练集 P_{HN} , 用于深度学习模型的训练; 再利用同样的方法生成分类训练集 P_{HC} , 用于半监督分类器的训练。如果变化类或非变化类真实样本数不足 500, 则生成虚拟样本 $P_k^{[14]}$, 将变化类或非变化类样本个数补至 500 个。同时, P_{HN} 和 P_{HC} 中的真实样本所对应的像素位置 j 不重叠。

最后, 在 1.1 节的 2 幅遥感图像中, 以 Ω_L 区域内的像素位置 j 为中心, 取长和宽均为 k 的像素块, 构成待测集 P_L 。

2 检测方法

本节重点研究统计机器学习算法和深度学习模型相结合的变化检测方法, 讨论 LapSVM 引入 CNN 模型的可能性。CNN 模型包括卷积层、最大池化层、全连接层和 Softmax 层, 可提取基本的视觉特征, 并实现特征分类。基于 LapSVM 的卷积小波神经网络 (convolutional-wavelet neural networks based on LapSVM, CWNLSN) 模型通过对 CNN 模型进行改进, 共包括 2 个部分: 卷积-小波特征提取 (convolutional-wavelet neural networks feature extraction, CWNNFE) 模型和基于 LapSVM 的 LSDC 模块, 分别用于特征提取和特征判别。CWNLSN 模型结构如图 2 所示。




图 2 CWNLSN 模型结构

Fig. 2 CWNLSN model structure

2.1 执行流程

首先, 以网络训练集 P_{HN} 为输入数据, 迭代训练基于卷积小波神经网络 (convolutional-wavelet neural networks, CWNN) 模型, 获得模型参数, 并将其作为 CWNNFE 模型参数在下一步使用。CWNN 模型与 CNN 模型的区别在于: CWNN 模型使用离散小波作为下采样方法, 进行池化操作, 而 CNN 模型使用最大池化法, 实现池化操作。

其次, 将分类训练集 P_{HC} 和待测集 P_L 输入已训练完成的 CWNNFE 模型中, 获取全连接层输出特征, 将其作为局部空间深度特征。

然后, 将分类训练集 P_{HC} 和待测集 P_L 的局部空间深度特征及部分分类训练集 P_{HC} 的“伪标签”输

入基于 LapSVM 的 LSDC 模块, 重复执行 T 次, 获得 T 组待测集的分类结果。

最后, 综合分析上述 T 组分类结果, 获得最终的变化检测结果。综合分析方法包括投票方法和均值方法。

2.2 卷积-小波特征提取模型

近年来, CNN 被广泛应用于变化检测中, 取得了良好的效果, 但仍存在 2 个局限: ① CNN 模型中的最大池化, 默认以矩形窗口中的最大值作为输出, 无法很好地捕捉前一层特征图的结构纹理, 导致丢失了图像的部分结构, 如边、端点、角等; ② 对于含有大量散斑噪声的遥感图像, 在 CNN 模型提取其深度特征的过程中会出现噪声累计的情况, 使其高级特征无法更好耦合变化检测任务。

针对上述局限, 小波变换^[21]是有效的解决方案。在提取图像特征时, 小波变换考虑了图像结构, 与人类视觉系统相匹配。低频子带中的小波系数越大, 代表平均亮度越高; 高频子带中的小波系数越大, 代表纹理和边缘越复杂。研究人员已将小波变化引入 CNN 模型, Duan 等^[22]提出基于双数复小波池化的图像分割方法, 通过双数复小波池化层代替 CNN 模型的最大池化层。Gao 等^[14]受此启发, 将双数复小波池化引入变化检测领域。双数复小波池化过程产生了 2 个低频子带分量, Duan 和 Gao^[14,22]等取其平均值作为下采样输出, 导致图像结构信息损失。相比之下, 离散小波池化仅产生 1 个低频子带分量, 其下采样输出可直接作为池化层输出, 保留了更加完整的结构信息。

基于上述分析, 设计 CWNNFE 模型。其以离散小波变换构造低通池化方式, 实现对深度网络中下采样操作的优化, 用于局部空间深度特征的提取。CWNNFE 模型的创新性在于: 通过离散小波池化代替 CNN 模型的最大池化, 保留了更多的结构信息, 抑制了散斑噪声对变化检测精度的影响。CWNNFE 模型中的离散小波池化过程如下:

通过离散小波对输入特征 x 实现行列滤波, 获得 4 个子带分量 L_L 、 L_H 、 H_L 、 H_H , 用于生成子带分量的离散小波的映射函数 $f(\cdot)$ 表达式, 如下:

$$\{L_L, L_H, H_L, H_H\} = f(x) \quad (2)$$

选择低频子带分量 L_L 作为小波池化层的输出, 原因有 2 点: ① 低频子带分量可保持输入样本的结构, 更好地表示输入样本; ② 提出高频子带分量, 可以有效地抑制散斑噪声。

综上, CWNNFE 模型可表示为 $\{I_1, C_2, W_3, C_4, W_5, F_6\}$ 。 I_1 为输入层, 所有输入样本集均被重新采样为 28×14 大小; C_2 为卷积层, 包含 6 个卷积核, 其

大小为 5×3 ; W_3 为小波池化层, 使用离散小波池化作为小波池化, 代替原有 CNN 模型的最大池化; C_4 为卷积层, 包含 12 个卷积核, 大小为 5×3 ; W_5 为小波池化层; F_6 为全连接层, 共 96 个单元。

2.3 基于 LapSVM 的 LSDC 模块

Chan 等^[23] 提出 PCANet 网络, 通过主成分分析 (principal component analysis, PCA) 代替卷积滤波器提取图像深度特征, 再引入支持向量机 (support vector machine, SVM) 作为监督分类器完成图像分类任务。Gao 等^[24] 受此启发, 提出一种基于 PCANet 的图像变化检测方法, 样本标记方法采用 Gabor 小波变换和 FCM 算法 (Gabor wavelet transform combined with FCM algorithm, GFCM), 特征提取方法采用 PCANet 网络, 特征判别方法采用 SVM 分类器, 取得了良好的变化检测效果。在特征提取环节, 与 PCANet^[24] 类似, CWNNFE 模型也是用于提取局部深度特征的网络, 可与分类器相结合, 实现变化检测任务。然而, 在样本标记环节, 与 GFCM 样本标记方法^[24] 不同, OGFL 方法^[12] 判别高置信度“伪标签”的条件更为苛刻, 可用于监督训练的高置信度“伪标签”样本数量相对较少, 不利于 SVM 等监督分类器的训练。因此, 在特征判别方法的设计上, 需要采用对标签样本数量不敏感的分类器, 以便更好地完成变化检测任务。

半监督学习是无监督学习和监督学习相结合的一种学习方法, 通过少量标签数据和大量无标签数据进行学习。当标签数据有限时, 通过半监督学习, 可以获得更准确的分类结果, 大量无标签数据也可改进半监督学习的性能, 有效提升变化检测方法的泛化能力, 适合样本标记结果质量高、数量少的特点。因此, 在特征判别方法的设计上, 将半监督学习引入 SVM 分类器, 降低训练分类器过程中对标签数据的依赖。LapSVM 是一种半监督学习方法, 由拉普拉斯流形正则化和传统 SVM 组成, 通过构建图拉普拉斯算子, 从训练样本的空间分布中进行估算, 表示标签和无标签数据的关系, 具有对标签样本数目不敏感的特点, 适用于对 CWNNFE 模型输出的局部空间深度特征进行半监督分类。

基于上述分析, 设计基于 LapSVM 的 LSDC 模块。LSDC 模块以 LapSVM 为半监督分类器, 用于二值化判别由 CWNNFE 模型提取的图像深度特征, 其与 CWNNFE 模型共同构成 CWNLSN 模型, 创新性在于: LSDC 模块代替了 CNN 模型的 Softmax 层, 解决了激活函数无法根据给定的样本数据自适应调整的局限, 可对 F_6 层输出的局部空间深度特征进行半监督分类, 提升了变化检测精度, 增强了方法

的泛化能力。LSDC 模块的执行流程如下:

首先, 选取 w_1 个有标签数据 $\{(a_i, b_i), 1 \leq i \leq w_1\}$, 其中, a 为在分类训练集 P_{HC} 中选取的局部空间深度特征, b 为其对应的“伪标签”; 选取 w_u 个无标签数据 $\{a_i, w_1 \leq i \leq w_1 + w_u\}$, 其中, a 为在全部待测集 P_L 和部分分类训练集 P_{HC} 中选取的局部空间深度特征。选取的有标签数据和无标签数据中的局部空间深度特征 a 来自于分类训练集 P_{HC} 中不同的训练样本。

然后, 将选取的有标签数据和无标签数据作为 LapSVM 输入数据, 训练半监督分类器。如果训练过程所用的有标签数据发生变化, 可能导致分类器的模型参数和待测集的分类结果也发生变化。因此, 设置 T 为分类判决执行次数, 以随机的方式选取有标签数据 T 次, 分别执行 T 次分类判决, 共获取 T 组待测集 P_L 的分类结果。

最后, 基于 T 组分类结果, 结合“伪标签”矩阵 Y_L 中的变化区域和非变化区域, 获取最终的变化检测结果。具体而言, T 组分类结果的分析方法有 2 种:

1) 投票方法。半监督学习的分类结果易受少量标签数据的影响, 产生差异化的分类结果。因此, 引入集成学习思想, 对 LapSVM 的待测集 P_L 分类结果进行投票表决, 进一步提升变化检测的效果, 其流程如图 3 所示。基于 LapSVM 的 LSDC 模块的投票流程如下:

以待测集 P_L 的像素位置 (m, n) 为单位, 统计 T 组待测集 P_L 的分类结果, 设置阈值比例 τ , 进行投票表决, 获得像素位置 (m, n) 的变化检测结果 $Y_{CD}(m, n)$ 。当某一像素位置 (m, n) 所有的分类结果 $y_{cd}(m, n)$ 为变化类的比例大于阈值比例 τ 时, 判定像素位置 (m, n) 的变化检测结果为变化类; 否则, 判定为非变化类。上述方法如图 3 所示。

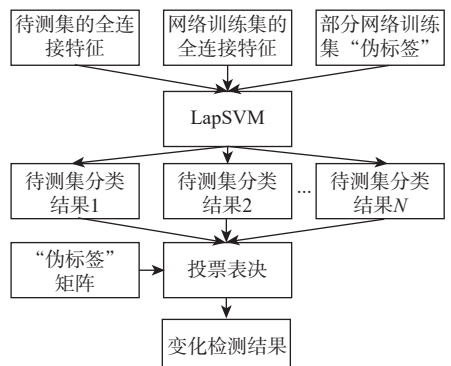


图 3 基于 LapSVM 的 LSDC 模块的投票方法执行流程

Fig. 3 The execution process of voting method for local space deep feature classification module based on LapSVM

$$Y_{CD}(m, n) = \begin{cases} 1 & \sum_{k=1}^T y_{cd}^k(m, n)/T \geq \tau \\ 0 & \text{其他} \end{cases} \quad (3)$$

取“伪标签”矩阵 Y_L 中的变化区域、非变化区域及待测集 P_L 投票结果 Y_{CD} 的并集, 构成最终的变化检测结果, 其结果包括 1 张二值结果图和 6 种客观评价指标结果。

2) 均值方法。基于 T 组待测集 P_L 的分类结果, 结合“伪标签”矩阵, 生成 T 组变化检测结果, 每组包括 1 张二值结果图和 6 种客观评价指标结果, 再取上述 T 组结果的均值作为变化检测结果, 其流程如图 4 所示。

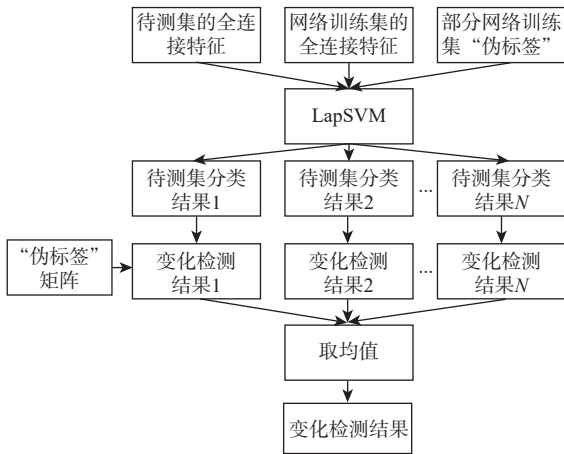


图 4 基于 LapSVM 的 LSDC 模块的均值方法执行流程

Fig. 4 The execution process of the mean method for local space deep feature classification module based on LapSVM

由于 T 张二值结果图的均值无法构成二值图像, 均值方法的输出结果中不含二值结果图。均值方法的均值结果包括 6 种客观评价指标结果, 主要用于评估方法的平均性能。

3 实验设置与结果分析

本文方法的硬件测试平台为处理器为 Intel(R) Core(TM) i7-6700K、主频为 4.00 GHz、内存为 32.0 GB 的台式机, 软件测试平台为 Windows 操作系统和 MATLAB 软件。

3.1 客观评价指标

为评估本文方法的性能, 选取错检数、漏检数、准确率、 F_1 分数、Kappa 系数和用时等 6 种评估变化检测效果的指标, 其具体含义如下:

- 1) 错检数是指变化检测方法的预测结果为变化类, 而地面真实变化情况为非变化类的像素总数。
- 2) 漏检数是指地面真实变化情况为变化类, 而变化检测方法的预测结果为非变化类的像素总数。

3) 准确率是指变化检测方法预测结果正确的样本数量与总样本数量的百分比。

4) Kappa 系数用于衡量变化检测方法的检测效果, 其数值越趋近于 1, 检测结果与地面真实情况越接近; 其数值越趋近于 0, 则反之。

5) F_1 分数是统计学中用于评估二分类问题精确度的综合指标, 平衡了二分类问题的准确率和召回率。

6) 用时是评估变化检测方法效率的指标, 自方法执行时开始计时, 至获得变化检测结果为止。

3.2 实验方法

本文选取的对比方法包括 PCAK^[25]、PCANet^[24]、CDWNN^[14]、TFCDWNN^[18]、SCapsNet^[12] 等。同时, 为了更好地验证 CWNLSN 模型的性能, 将最大池化、双数复小波池化和离散小波池化等 3 种池化方式, 以及激活函数和 LapSVM 等 2 种特征分类方式交叉组合, 构成 CNN 及其改进模型, 如表 1 所示。

表 1 CNN 及其改进模型

Table 1 CNN model and improved CNN models

序号	模型	池化方式	特征分类方式
1	CNN	最大池化	激活函数
2	CDWNN	双数复小波池化	激活函数
3	CWNN	离散小波池化	激活函数
4	CNLSN	最大池化	LapSVM
5	CDWNLSN	双数复小波池化	LapSVM
6	CWNLSN	离散小波池化	LapSVM

表 1 中的 CNLSN、CDWNLSN、CWNLSN 模型均包括投票方法和均值方法, 下文以“模型名称-方法名称”表示模型的具体方法, 如 CNLSN 模型的均值方法表示为“CNLSN-mean”。

3.3 数据集

SAR 图像作为一种遥感图像, 受雷达回波特性的限制, 存在较多的散斑噪声^[26], 有效抑制噪声是一项有挑战性的工作。为了检验变化检测方法的性能, 选取多组 SAR 图像数据集, 简要介绍如下:

1) 旧金山数据集^[24]是由欧洲 ERS-2 资源遥感卫星拍摄的 SAR 图像, 记录了美国旧金山地区在经受洪水淹没前后的地表变化情况, 分别拍摄于 2003 年 8 月和 2004 年 5 月。

2) 黄河数据集^[9]是由 Radarsat-2 号雷达卫星在中国黄河口地区拍摄的 2 幅 SAR 图像, 拍摄时间分别为 2008 年 6 月和 2009 年 6 月。选取 2 个代表性区域, 分别命名为黄河海岸线数据集和黄河农田数据集。第 1 个数据集记录了由于河水冲击导致的河道形状的改变, 第 2 个数据集记录由于农田耕种活动导致的地表覆盖情况的变化情况。

3) 贵州数据集^[27]是由 COSMO-SkyMed 卫星传感器采集的联合配准和几何校正的 SAR 图像, 分别于 2016 年 6 月 10 日和 2017 年 4 月 26 日获得。原始图像中包括丘陵、平原和建筑物等不同景观, 明显存在散斑噪声。

3.4 参数设置

为获得准确率随邻域大小的变化曲线, 设置变化曲线横坐标邻域大小为 3、5、7、9、11 和 13, 分类判决执行次数 T 设为 20, 阈值比例 τ 设为 0.5, 取 CWNLSN-vote 投票结果中的准确率为变化曲线纵坐标结果, 如图 5 所示。




图 5 CWNLSN-vote 投票结果准确率随邻域大小的变化曲线

Fig. 5 Curves of the accuracy of CWNLSN-vote with neighborhood size

在旧金山、黄河农田和贵州数据集上, 准确率均随邻域扩大而升高, 当邻域大小为 13 时, 准确率取得最优解。而在黄河海岸线数据集上, 准确率均随邻域扩大先升高后下降, 当邻域大小为 5 时, 准确率取得最优解。

因此, 为发挥方法的最佳性能, 获得最佳参数, 对于旧金山、黄河农田和贵州数据集, 设置邻域大

小为 13; 对于黄河海岸线数据集, 设置邻域大小为 5。

3.5 对比实验

基于 3.4 节参数设置, 开展对比实验, 实验结果如图 6 和表 2 所示。

在旧金山数据集上, PCANet、TFCDWNN 的结果中存在大量错检像素, PCAK、CDWNN 的结果中存在大量漏检像素。SCapsNet 丢失了部分细节信息, 相比于 CWNLSN-vote, 其精度指标略低, 用时明显更少。与 CDWNN、TFCDWNN 相比, CWNLSN-vote 在 F_1 分数上分别提升 15.37%、8.49%, 在 Kappa 系数上分别提升 19.93%、9.02%, 在用时上分别降低 0.59%、提升 27.43%。

在黄河海岸线数据集上, PCAK、PCANet、CDWNN 方法受散斑噪声影响较大, 尽管其变化检测结果中的错检像素较少, 但均含有大量的漏检像素, 因此, 主观视觉效果较差; 而 TFCDWNN、SCapsNet、CWNLSN-vote 方法的错检像素和漏检像素均较少, 取得了良好主观视觉效果。与 TFCDWNN、SCapsNet 相比, CWNLSN-vote 在 F_1 分数上分别提升 0.80%、0.33%, 在 Kappa 系数上分别提升 0.82%、0.33%, 但在用时上分别提升 21.49%、611.30%。

在黄河农田数据集, PCAK、PCANet、CDWNN 的错检数或漏检数较高, 视觉效果较差。SCapsNet、CWNLSN-vote 取得了良好的视觉效果, 但与 SCapsNet 相比, CWNLSN-vote 在准确率、 F_1 分数、Kappa 系数上均略低, 在用时上更高。从整体上看, CWNLSN-vote 取得次优效果。

在贵州数据集上, TFCDWNN、SCapsNet、CWNLSN-vote 方法的漏检和错检像素之和远小于 PCAK、PCANet、CDWNN 方法的检像素。相比于




图 6 在旧金山数据集、黄河海岸线数据集、黄河农田数据集、贵州数据集中不同变化检测方法的可视化结果

Fig. 6 Visualization results of different change detection methods in the San Francisco dataset, Yellow River coastline dataset, Yellow River farmland dataset, and Guizhou dataset

表 2 对比实验中多个数据集上变化检测结果的客观评估

Table 2 Objective evaluation of change detection results on multiple datasets in comparative experiments

方法	错检数				漏检数				准确率/%			
	旧金山	黄河海岸线	黄河农田	贵州	旧金山	黄河海岸线	黄河农田	贵州	旧金山	黄河海岸线	黄河农田	贵州
PCA ^[25]	2 047	0	490	99	4 033	38 217	1 279	38 768	94.47	69.67	98.01	75.71
PCANet ^[24]	5 122	4	1 345	106	720	28 335	201	31 990	94.69	77.51	98.26	79.94
CDWNN ^[14]	226	51	734	383	13 647	20 258	969	19 069	87.39	83.88	98.09	87.84
TFCDWNN ^[18]	5 849	137	811	324	54	152	213	701	94.63	99.77	98.85	99.36
SCapsNet ^[12]	4 241	171	771	450	723	96	173	451	95.49	99.79	98.94	99.44
CWNSLN-vote	3 929	192	473	582	592	61	560	153	95.95	99.80	98.84	99.54

方法	F_1 分数/%				Kappa系数/%				用时/s			
	旧金山	黄河海岸线	黄河农田	贵州	旧金山	黄河海岸线	黄河农田	贵州	旧金山	黄河海岸线	黄河农田	贵州
PCA ^[25]	79.68	6.59	84.39	75.71	76.50	4.62	83.33	4.98	0.3	0.5	0.2	0.7
PCANet ^[24]	75.18	8.66	83.54	79.94	72.32	6.76	82.64	6.28	1 262.3	2 491.7	994.2	2 717.5
CDWNN ^[14]	66.46	11.33	84.19	87.84	59.67	9.50	83.18	8.65	607	618	590.8	642.1
TFCDWNN ^[18]	73.34	89.34	89.70	99.36	70.58	89.22	89.09	69.18	473.5	492.4	446.3	225
SCapsNet ^[12]	79.67	89.81	90.50	99.44	77.19	89.71	89.95	69.53	99.8	84.1	204.4	248.6
CWNSLN-vote	81.83	90.14	90.28	99.54	79.60	90.04	89.66	71.01	603.4	598.2	579.2	692.5

TFCDWNN、SCapsNet、CWNSLN-vote 在 Kappa 系数上分别提升 1.83%、1.48%，在 F_1 分数上分别提升 0.18%、0.10%，但在用时上分别增加 207.78%、178.56%。

综上，CWNSLN-vote 方法抑制了散斑噪声，变化检测精度较高，但耗时相对较长。

3.6 消融实验

根据是否采用离散小波池化和基于 LapSVM 的

LSDC 模块，构成 CNN、CWNN、CNLSN、CWNSLN 等 4 种变化检测模型，如表 1 所示。消融实验选择 CNN、CWNN、CWNSLN 模型的均值方法 (CWNSLN-mean)、CNLSN 模型的均值方法 (CNLSN-mean)，检验在 CNN 模型中引入离散小波池化和基于 LapSVM 的 LSDC 模块是否能分别提升变化检测精度。消融实验的实验结果如表 3 所示。

表 3 消融实验中多个数据集上变化检测结果的客观评估

Table 3 Objective evaluation of change detection results on multiple datasets in ablation experiments

方法	错检数			漏检数			准确率/%			F_1 分数/%			Kappa系数/%		
	旧金山	黄河农田	贵州	旧金山	黄河农田	贵州	旧金山	黄河农田	贵州	旧金山	黄河农田	贵州	旧金山	黄河农田	贵州
CNN	4 378	864	463	515	239	603	95.55	98.76	99.33	79.68	88.88	65.88	77.25	88.22	65.54
CWNN	4 284	852	416	500	215	515	95.65	98.80	99.42	80.19	89.23	69.80	77.82	88.59	69.51
CNLSN-mean	3 996	498	622	559	575	141	95.86	98.79	99.52	81.39	89.89	69.46	79.11	89.25	69.23
CWNSLN-mean	3 837	489	579	559	534	154	96.00	98.85	99.54	82.15	90.34	71.35	79.95	89.73	71.13

通过分析表 3 可知，在旧金山、黄河农田和贵州数据集上，CNN 的 Kappa 系数平均结果为 77.00%，CWNN 的 Kappa 系数平均结果为 78.64%，CNLSN-mean 的 Kappa 系数平均结果为 79.20%，CWNSLN-mean 的 Kappa 系数平均结果为 80.27%。离散小波池化的引入，使 CWNN 相比于 CNN，在 Kappa 系数上提升了 1.64%；使 CWNSLN-mean 相比于 CNLSN-mean，在 Kappa 系数上提升了 1.07%。LSDC 模块的引入，使 CWNSLN-mean 相比于 CWNN，在 Kappa 系数上提升了 1.63%；使 CNLSN-mean 相比于 CNN，在 Kappa 系数上提升了 2.20%。

综上，在 CNN 模型中引入的离散小波池化和基于 LapSVM 的 LSDC 模块均可提升变化检测精度。

3.7 不同池化模块的对比实验

选择采用最大池化的 CNN、CNLSN-mean，采用双数复小波池化的 CDWNN、CDWNSLN-mean，采用离散小波池化的 CWNN、CWNSLN-mean 等 6 种变化检测方法，设置邻域大小为 3、5、7、9、11 和 13，得到不同变化检测结果的 Kappa 系数和 F_1 分数随邻域大小变化的柱状图，如图 7~图 9 所示。当邻域大小为 3~13 时，取不同方法的平均




图7 旧金山数据集上不同变化检测方法的 Kappa 系数和 F_1 分数随邻域大小的变化

Fig. 7 Kappa coefficients and F_1 scores for different change detection methods on the San Francisco dataset as a function of neighborhood size




图8 黄河农田数据集上不同变化检测方法的 Kappa 系数和 F_1 分数随邻域大小的变化

Fig. 8 Kappa coefficients and F_1 scores for different change detection methods on the Yellow River farmland dataset as a function of neighborhood size

Kappa 系数和 F_1 分数, 结果如图 10 所示。

由图 7 可知, 在旧金山数据集中, 当邻域较大时, CWNN 的变化检测效果明显优于 CDWNN 和 CNN 方法, CWNN-mean 的变化检测效果明显优于 CDWNLSN-mean 和 CNN-mean 方法。

由图 8 可知, 在黄河农田数据集中, 当邻域大小较小时, CWNN 的变化检测效果明显优于 CDWNN 和 CNN 方法; 当邻域大小较小或较大时, CWNN-mean 的变化检测效果明显优于 CDWNLSN-mean 和 CNN-mean 方法。

由图 9 可知, 在贵州数据集中, CWNN 的变化检测效果均明显优于 CDWNN 和 CNN 方法, CWNN-mean 的变化检测效果明显优于 CDWNLSN-mean 和 CNN-mean 方法。

从图 10 可知, CWNLSN-mean 的变化检测效果明显优于 CDWNLSN-mean 和 CNLSN-mean 方法, 在 Kappa 系数上分别平均提升 0.63%、0.93%, 在 F_1 分数上分别平均提升 0.61%、0.91%; CWNN 的变化检测效果明显优于 CDWNN 和 CNN 方法, 在 Kappa 系数上分别平均提升 0.96%、1.47%, 在 F_1 分数上分别平均提升 0.93%、1.44%。

因此, 相比于最大池化和双数复小波池化, 离




图9 贵州数据集上不同变化检测方法的 Kappa 系数和 F_1 分数随邻域大小的变化

Fig. 9 Kappa coefficients and F_1 scores of different change detection methods on the Guizhou dataset as a function of neighborhood size




图 10 不同数据集上不同变化检测方法的平均 Kappa 系数和 F_1 分数

Fig. 10 Average Kappa coefficients and F_1 scores for different change detection methods on different datasets

散小波池化对散斑噪声的鲁棒性能更佳。

4 结 论

本文提出基于局部空间深度特征的 SAR 遥感图像变化检测方法, 实现了像素块级变化检测, 结论如下:

- 1) 使用 OGFL 方法, 获得高置信度训练样本, 为实现监督学习模型的有监督训练奠定基础。
- 2) 设计了 CWNFE 模型, 通过离散小波池化代替 CNN 模型的最大池化, 使池化过程保留了更多基本结构信息, 抑制 SAR 图像中的散斑噪声对变化检测精度的影响。
- 3) 设计了 LSDC 模块, 通过 LapSVM 代替 Softmax 层, 解决了激活函数无法根据给定的样本数据自适应调整的局限, 提升了变化检测精度, 增强了变化检测方法的泛化能力。

参考文献 (References)

[1] 杨刚. 基于特征学习与聚类分析的 SAR 图像变化检测研究[D]. 成都: 西南交通大学, 2021.
 YANG G. SAR image change detection based on feature learning and clustering analysis[D]. Chengdu: Southwest Jiaotong University, 2021(in Chinese).

[2] 刘国强, 房胜, 李哲. 用于遥感图像变化检测的全尺度特征聚合

网络[J]. 北京航空航天大学学报, 2022, 48(8): 1464-1470.

LIU G Q, FANG S, LI Z. A full-scale feature aggregation network for remote sensing image change detection[J]. Journal of Beijing University of Aeronautics and Astronautics, 2022, 48(8): 1464-1470 (in Chinese).

[3] 周圆, 李祥瑞, 杨晶. 基于混合网络的异源遥感图像变化检测[J]. 北京航空航天大学学报, 2021, 47(3): 451-460.
 ZHOU Y, LI X R, YANG J. Heterogeneous remote sensing image change detection based on hybrid network[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(3): 451-460 (in Chinese).

[4] SUN Y L, LEI L, LI X, et al. Nonlocal patch similarity based heterogeneous remote sensing change detection[J]. Pattern Recognition, 2021, 109: 107598.

[5] NAVARRO A, ROLIM J, MIGUEL I, et al. Crop monitoring based on SPOT-5 Take-5 and Sentinel-1A data for the estimation of crop water requirements[J]. Remote Sensing, 2016, 8(6): 525.

[6] OTHMAN A A, GLOAGUEN R. River courses affected by landslides and implications for hazard assessment: a high resolution remote sensing case study in NE Iraq-W Iran[J]. Remote Sensing, 2013, 5(3): 1024-1044.

[7] GONG M G, ZHOU Z Q, MA J J. Change detection in synthetic aperture radar images based on image fusion and fuzzy clustering[J]. IEEE Transactions on Image Processing, 2012, 21(4): 2141-2151.

[8] BEZDEK J C. Pattern recognition with fuzzy objective function algorithms[M]. New York: Plenum Press, 1981.

[9] GONG M G, ZHAO J J, LIU J, et al. Change detection in synthetic aperture radar images based on deep neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 27(1): 125-138.

[10] LI M K, LI M, ZHANG P, et al. SAR image change detection using PCANet guided by saliency detection[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(3): 402-406.

[11] WANG S N, WANG Y N, LIU Y, et al. SAR image change detection based on sparse representation and a capsule network[J]. Remote Sensing Letters, 2021, 12(9): 890-899.

[12] 张益天, 罗喜伶, 王宇鹏. 基于轻量胶囊网络的自监督图像变化检测方法[J]. 北京航空航天大学学报, 2025, 51(5): 1705-1715.
 ZHANG Y T, LUO X L, WANG Y P. Self-supervised image change detection method based on lightweight capsule network[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(5): 1705-1715(in Chinese).

[13] LIU F, JIAO L C, TANG X, et al. Local restricted convolutional neural network for change detection in polarimetric SAR images[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(3): 818-833.

[14] GAO F, WANG X, GAO Y H, et al. Sea ice change detection in SAR images based on convolutional-wavelet neural networks[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(8): 1240-1244.

[15] WANG Q, YUAN Z H, DU Q, et al. GETNET: a general end-to-end 2-D CNN framework for hyperspectral image change detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(1): 3-13.

- [16] 刘过. 基于深度学习的 SAR 图像变化检测研究[D]. 重庆: 重庆大学, 2020.
LIU G. Study on deep learning-based SAR images change detection[D]. Chongqing: Chongqing University, 2020(in Chinese).
- [17] D'HAeyer J P F. Gaussian filtering of images: a regularization approach[J]. *Signal Processing*, 1989, 18(2): 169-181.
- [18] ZHANG X Z, SU H, ZHANG C, et al. Robust unsupervised small area change detection from SAR imagery using deep learning[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 173: 79-94.
- [19] BOVOLO F, BRUZZONE L. A detail-preserving scale-driven approach to change detection in multitemporal SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(12): 2963-2972.
- [20] OTSU N. A threshold selection method from gray-level histograms[J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1979, 9(1): 62-66.
- [21] MALLAT S G. A theory for multiresolution signal decomposition: the wavelet representation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1989, 11(7): 674-693.
- [22] DUAN Y P, LIU F, JIAO L C, et al. SAR image segmentation based on convolutional-wavelet neural network and Markov random field[J]. *Pattern Recognition*, 2017, 64: 255-267.
- [23] CHAN T H, JIA K, GAO S H, et al. PCANet: a simple deep learning baseline for image classification[J]. *IEEE Transactions on Image Processing*, 2015, 24(12): 5017-5032.
- [24] GAO F, DONG J Y, LI B, et al. Automatic change detection in synthetic aperture radar images based on PCANet[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(12): 1792-1796.
- [25] CELIK T. Unsupervised change detection in satellite images using principal component analysis and K-means clustering[J]. *IEEE Geoscience and Remote Sensing Letters*, 2009, 6(4): 772-776.
- [26] BAZI Y, BRUZZONE L, MELGANI F. An unsupervised approach based on the generalized Gaussian model to automatic change detection in multitemporal SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(4): 874-887.
- [27] ZHANG X Z, LIU G, ZHANG C, et al. Two-phase object-based deep learning for multi-temporal SAR image change detection[J]. *Remote Sensing*, 2020, 12(3): 548.

SAR remote sensing image change detection method based on local space deep feature

ZHANG Yitian¹, ZHAO Jing^{2,*}, CHEN Jiangyang³, LUO Xiling^{4,5}

- (1. Cyber Security Industry Development Center (Information Center), Ministry of Industry and Information Technology, Beijing 100846, China;
2. Institute of Science and Technology, Beihang University, Beijing 100191, China;
3. China Jiuyuan High-Tech Equipment Corporation, Beijing 100094, China;
4. School of Electronic and Information Engineering, Beihang University, Beijing 100191, China;
5. Hangzhou Innovation Institute, Beihang University, Hangzhou 310051, China)

Abstract: This research offers an image change detection strategy based on convolutional-wavelet neural networks based on Laplace support vector machine (LapSVM) (CWNLSN) to enhance the generalization and robustness of convolutional neural network (CNN) in change detection applications. Firstly, by using the sample labeling method, high confidence "pseudo labels" are obtained, and the network training set, classification training set, and test set are divided. Secondly, discrete wavelet pooling is used to retrieve local space deep characteristics in CNN. Then, design a local space deep feature classification (LSDC) module based on LapSVM to classify the deep features and distinguish the changed information in the test set. Finally, comparative experiments and ablation experiments were conducted on multiple sets of real remote sensing datasets for testing. The results indicate that the proposed method achieved a more significant change detection effect.

Keywords: change detection; convolutional neural network; discrete wavelet pooling; Laplace support vector machine; local space deep features