

基于对数双曲余弦比差异图构造与多区域特征卷积极限学习机的合成孔径雷达图像变化检测

林志康¹, 刘伟^{1*}, 牛朝阳¹, 高贵², 卢万杰¹

¹战略支援部队信息工程大学数据与目标工程学院, 河南 郑州 450000;

²西南交通大学地球科学与环境工程学院, 四川 成都 611756

摘要 针对合成孔径雷达(SAR)图像变化检测中差异图质量不佳、检测精度偏低以及检测时间长等问题,提出了一种基于对数双曲余弦比(LHCR)差异图构造与多区域特征卷积极限学习机的无监督变化检测新方法。该方法主要由差异图生成和差异图分析两个阶段组成。在差异图生成阶段,利用各向异性扩散滤波器对同一地区不同时间的两幅SAR图像分别滤波,使用对数双曲余弦变换对滤波后的图像进行增强,通过对数比处理得到LHCR差异图,在抑制相干斑噪声的同时,增强差异图的对比度。在差异图分析阶段,应用分层模糊C均值聚类得到变化类、不变类和中间不确定类的预分类结果;进而从差异图、双时相SAR图像中获取多区域样本块,构成三通道数据输入卷积层进行特征提取。特征具有强调中心区域、抑制边缘噪声的特点;最后,使用变化类和不变类的特征向量进行极限学习机分类训练,再用训练好的模型对中间不确定类像素自动分类实现变化检测。Radarsat-2和高分三号数据集的实验结果表明了所提方法的有效性。

关键词 遥感与传感器; 合成孔径雷达图像; 变化检测; 差异图; 多区域特征; 对数双曲余弦变换; 极限学习机

中图分类号 TP751;TP79

文献标志码 A

DOI: 10.3788/AOS221491

1 引言

遥感图像变化检测旨在使用多时相遥感图像分析同一地理区域一段时间内发生的变化情况,可用于农业调查^[1]、城市规划^[2]、洪水监测^[3]和灾害评估^[4]。针对遥感图像变化检测,研究者已经做出了大量努力^[5-6]。合成孔径雷达(SAR)可以在全天时、全天候下以适当的空间和时间分辨率收集数据^[7]。然而,固有相干斑噪声的存在为SAR遥感图像变化检测带来了严峻挑战,急需研究既能检测变化区域,又能抑制相干斑噪声和不变区域背景干扰的变化检测新方法。

SAR图像变化检测通常由两个步骤组成。步骤一:差异图生成,利用多时相SAR图像构建差异图(DI);步骤二:差异图分析,即对差异图分类以区分变化或者不变的像素^[8-10]。对于步骤一,可以简单地让两幅SAR图像相减来获得DI^[11]。对数比(LR)^[12]是一种常用的算子,与简单减法算子相比,对乘性相干斑更具鲁棒性。文献[13]中的邻域比(NR)是一种比较邻域信息的差异图生成算子,虽然整体抑制了噪声,但同时模糊了整个图像,导致变化区域与背景区域对比度不大。文献[14]结合对数函数、减法算子和滤波器设计

了一种反正切算子,但该算子仍然需要人工设置参数才能适应不同数据集。文献[15-16]中,为了适应各种实际应用,改进了减法算子、比率算子,如平均滤波减法、对数比和平均比。然而,由此产生的DI通常容易受到低对比度或过度噪声的影响。理论上,所生成的DI预计能够最大限度地提高变化和不变类别之间的分辨能力,使得没有变化的像素表现为较小的灰度值,而变化像素在DI中表现为较大的灰度值。换句话说,生成的DI应该对图像中出现的非真实变化不敏感^[17]。然而,由于大气条件变化、光照变化和传感器校准等多种因素的影响,两幅图像中不变区域的像素值之间的差异可能会比较大。在这种情况下,由上述算子计算的不变区域中像素的DI值也可能相当大,从而影响变化检测的性能。对于步骤二,在获得DI的情况下,实现差异图二元分类以获得变化检测结果^[18]。近年来,研究者主要以特征提取和分类器为中心实现二元分类。深度学习网络分类器方面,文献[19-21]中通过改进卷积神经网络(CNN)进行变化检测,不断克服虚警,提升精度;文献[22]提出了一种多区域的空域与频域双域网络(DDNet),但这种多区域忽略边缘噪声的同时损失了表征变化的细节信息,且网络稍庸冗,耗时

收稿日期: 2022-07-18; 修回日期: 2022-08-21; 录用日期: 2022-09-22; 网络首发日期: 2022-09-30

基金项目: 国家自然科学基金(41822105)、中央高校基本科研业务费科技创新项目(2682020ZT34,2682021CX071)、地理信息工程国家重点实验室开放基金(SKLGIE2020-Z-3-1,SKLGIE2020-M-4-1)

通信作者: *greatliuliu@163.com

也较长。特征提取与分类器结合方面,文献[23]结合 Gabor 特征的主成分分析网络(PCANet)特征提取耗时较长。机器学习分类器方面,文献[13]中采用极限学习机(ELM)进行分类,分类效率高,但检测精度不够。此外,深度学习需要大量的训练数据和许多参数的设置,处理成本也很高。基于对现有研究成果的分析,目前 SAR 图像变化检测仍然具有下列两个挑战:

1) 差异图生成的鲁棒性。现有的差异图模糊,差异图中与变化像素具有相似灰度值的干扰像素较多,变化区域受背景信息影响较大;

2) 差异图分析的有效性。近年来基于 DI 的机器学习或者深度学习的无监督变化检测方法,通常使用图像样本块进行待分类像素的空间特征提取,或多或少会丢失表征变化信息的细节信息,且分类结果中虚警较多,效率不高。如果能充分利用各种特征、降低虚警和提高效率,将大大提高检测的性能。

因此,应同时考虑鲁棒性差异图和多样性特征提取,建立一个稳健快速的 SAR 变化检测模型。基于上述考虑,本文提出了基于对数双曲余弦比(LHCR)差异图构造与多区域卷积极限学习机(MRFCELM)的方法,分两个阶段进行了研究。

1) 差异图生成阶段。本文利用相干斑抑制各向异性扩散滤波器、对数双曲余弦变换、对数比函数以及中值滤波设计了一个新的 LHCR 差异图,在抑制相干斑噪声的同时,增强差异图的对比度,其鲁棒性较其他差异图大大提高。

2) 差异图分析阶段。本文利用多区域特征、卷积层、极限学习机设计了 MRFCELM 分类模型,该模型以差异图的分层模糊 C 均值聚类结果为基础,综合利用差异图、双时相 SAR 图像的特征,快速高效,性能稳定,无需后续任何处理。

2 SAR 图像变化检测方法

2.1 方法流程

给定在同一地理区域不同时间拍摄的两幅 SAR 图像 $im1$ 和 $im2$,目标是生成一幅二元变化图,其中变化的像素标记为“1”,不变的像素标记为“0”。本文提出了一种基于 LHCR 差异图构造与 MRFCELM 的无监督变化检测技术(LHCR_MRFCELM),其具体框架如图 1 所示,主要流程为:

1) 差异图构建。使用提出的 LHCR 差异图构建方法获取鲁棒性差异图。

2) 分层模糊 C 均值聚类(HFCM)^[21]分类。将差异图分为三类:变化类、不变类和中间不确定类。属于变化类和不变类的像素是可靠的像素,它们分别具有很高的变化或不变概率,中间不确定类中的像素需要进一步分类。

3) 样本选取与分类训练。以变化类像素点数量

为基准,使不变类样本和变化类样本的数量一致。分别选取以变化类和不变类像素点为中心的样本块,作为 MRFCELM 的训练样本。对于给定的像素,分别从 $im1$ 、 $im2$ 和其产生的差异图 DI 中提取以对应像素为中心的样本块。每个样本块的大小为 $r \times r$ (本研究中 $r=5$)。将三种样本块组合成一个新的训练样本块,大小为 $r \times r \times 3$ 。生成的新样本块被送入卷积层自动提取深层次特征,最后由极限学习机完成分类训练。

4) 中间不确定类像素分类识别。极限学习机训练完成后,以中间不确定类像素为中心的样本块将由 MRFCELM 进行分类,整个过程无监督。

2.2 LHCR 差异图

为减少 SAR 图像中固有的相干斑噪声对生成差异图的影响,通常可以对图像进行滤波处理,但是很多滤波算法在抑制相干斑的同时模糊了整个图像,使得不同地物间的边缘部分不明显。相干斑抑制各向异性扩散(SRAD)滤波器,能模糊相干斑噪声并增强变化区域边缘。首先应用 SRAD 滤波器处理两幅 SAR 图像,然后使用对数双曲余弦变换提升图像对比度,然后使用对数比算子得到差异图,再加以应用中值滤波和 SRAD 滤波得到最终差异图 DI。

对数比差异图在凸显变化区域的同时很大程度也凸显了存在的相干斑噪声,所以本文设计了一种既能凸显变化区域,又能抑制相干斑噪声的新差异图。首先,对原始 SAR 图像 $im1$ 和 $im2$ 应用 SRAD 滤波:

$$I_1 = f_{SRAD}(im1), \quad (1)$$

$$I_2 = f_{SRAD}(im2), \quad (2)$$

式中, $f_{SRAD}(\cdot)$ 表示 SRAD 滤波。为了突出滤波后图像中的不同地物,如陆地、水体等地物间的对比度,进一步对图像 I_1 和 I_2 应用对数双曲余弦变换^[24]:

$$X_1 = \frac{1}{2} \log_2 \cosh I_1, \quad (3)$$

$$X_2 = \frac{1}{2} \log_2 \cosh I_2, \quad (4)$$

式中, \cosh 表示双曲余弦变换。对数双曲余弦变换是一个非线性凸函数,实际上是一个对比度变换函数。

经过双曲余弦变换后图像中像素值整体增大,但像素值大的区域比像素值小的区域增大得多;再经过对数函数处理后,这种差距更加明显。SAR 图像中水体集中在像素值小的区域,陆地在像素值较大的区域,这正是对数双曲余弦变换能增强不同地物间对比度的原因。

在得到 X_1 和 X_2 后,应用对数比运算生成 LHCR 差异图 D_{LR} :

$$D_{LR} = \left| \ln \left(\frac{X_1 + 1}{X_2 + 1} \right) \right|. \quad (5)$$

此时, D_{LR} 不变区域内有大量与变化区域灰度值大小一样的噪点。为减少后续虚警和避免因窗口太大滤掉太多变化像素产生较多漏警,对 D_{LR} 进行 5×5 窗口尺

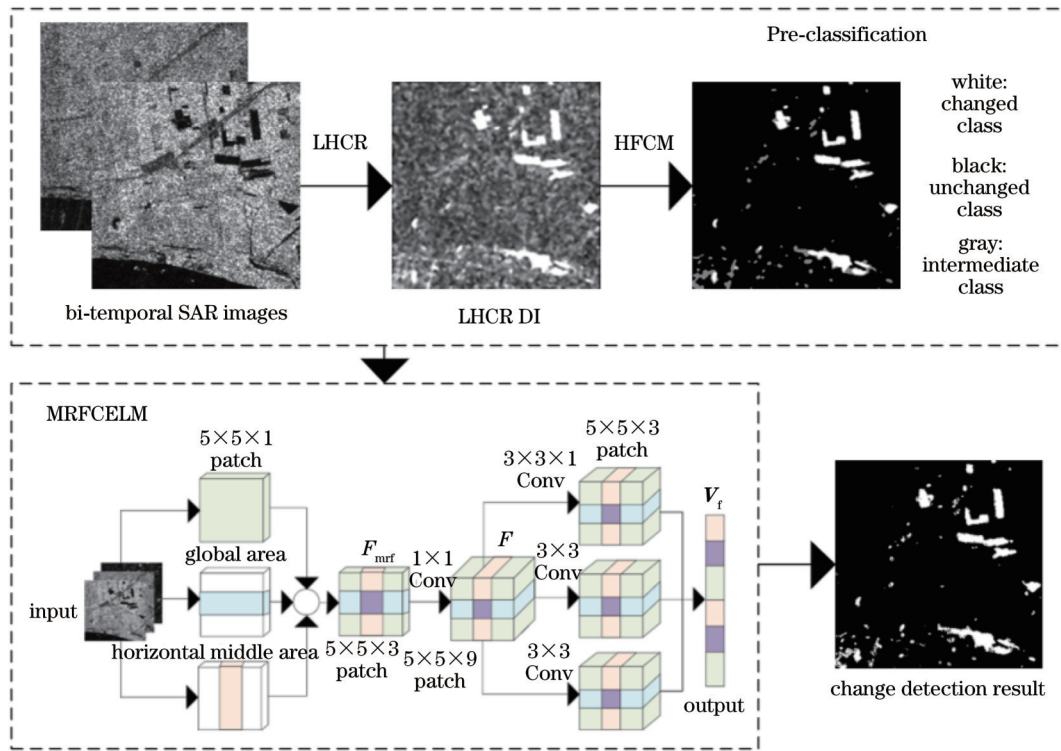


图 1 提出方法流程图

Fig. 1 Flow chart of proposed method

寸的中值滤波(MF)得到 D_{MF} , 此时仍然有小部分孤立噪点存在于 D_{MF} 中, 再进行 SRAD 滤波得到最终差异图 DI。

SRAD 滤波器在抑制相干斑噪声的同时也较好地克服了边缘模糊的缺点; 对数双曲余弦变换进一步提升了滤波后图像中地物的对比度, 两者结合, 很大程度上抑制了最后产生的 LHCR 差异图中的相干斑噪声, 同时也保留了变化细节。

图 2 给出了设计的差异图生成过程。从图 2 可以看出, I_1 和 I_2 较 $im1$ 和 $im2$ 图像模糊, 但边缘信息保留较好。经过对数双曲余弦变换后生成的 X_1 和 X_2 中陆地和水体对比度明显增大, 这样使得对数比函数处理后的 LR 差异图像变化细节信息更突出。LR 图像中有很多白色孤立噪点, 经过中值滤波后的 MF 图像, 大大减少了白色噪点, 再通过 SARD 滤波后, 残存的噪点被进一步去除, 变化区域边缘得到增强。




图 2 LHCR 差异图生成过程

Fig. 2 Generation process of log-hyperbolic cosine ratio (LHCR) difference image (DI)

2.3 MRFCELM

本节主要介绍多区域特征提取、极限学习机等算法。多区域特征提取主要通过卷积自动提取特征, 强调中心像素, 忽略边缘噪声, 实现多特征融合。极限学习机在保证精度的前提下能自动快速地分类训练。

2.3.1 多区域特征提取

现有方法通常采用固定大小的样本块 ($r \times r$) 作为训练样本, 本文多区域特征旨在特征提取时强调中心区域, 放弃一些边缘区域, 消除边缘区域中的噪声, 并且充分利用差异图中的变化信息。具体多区域特征

设计如下:

- 1) 全局区域:DI 样本块。
- 2) 水平中间区域:时相 1 图像样本块,顶部和底部的像素被置空。
- 3) 垂直中间区域:时相 2 图像样本块,左右两侧的像素被置空。

如果在卷积模型中考虑上述区域,将强调中心区域,并有效抑制边缘上的噪声像素,同时保留变化细节信息。给定一个样本块 $P \in \mathbb{R}^{r \times r \times 3}$,由 DI 全局区域特征 F_g ($r \times r$)、SAR 图像 1 水平中间区域特征 F_h ($r \times r$) 和 SAR 图像 2 ($r \times r$) 垂直中间区域特征 F_v 拼

接而成,多区域特征 $F_{\text{mrf}} \in \mathbb{R}^{r \times r \times (C/3)}$ 由下式表示:

$$F_{\text{mrf}} = \text{cat}(F_g, F_h, F_v), \quad (6)$$

式中, $\text{cat}()$ 表示拼接操作。将其送入 1×1 卷积层,生成新的特征映射 $F \in \mathbb{R}^{r \times r \times C}$,卷积被用来捕获中心像素的全局上下文信息。根据通道尺寸将 F 分为三组 F'_g 、 F'_h 和 F'_v 。因此, F'_g 、 F'_h 和 F'_v 的形状分别为 $(C/3) \times r \times r$ 。本文中 r 被设置为 5, C 被设置为 9,因此得到最终的空间融合特征,其大小为 $5 \times 5 \times 3$ 。然后将特征重塑为特征向量 V_f ,其长度为 $5 \times 5 \times 3 = 75$ 。因此,该向量具有全局上下文信息,并且中心区域信息得到了增强,图 3 展示了多区域特征提取过程。




图 3 多区域特征提取

Fig. 3 Multi-region feature extraction

2.3.2 ELM

在获得 DI 后,如果直接将 DI 分为两类,会有很大一部分像素分类错误,所以采用 HFCM 法^[21]先分为三类,然后采用对中间不确定类再分类的策略,可减少中间不确定类的影响,使获得的变化类和不变类更具鲁棒性。即获得变化类和不变类两者足够的代表性样本后,用极限学习机学习这两类特征,最后对中间不确定类再分类。

常规的极限学习机,能高效分类但需要手动提取特征。本文用卷积提取特征作为极限学习机的输入,完成特征的自动提取,从而实现了高效的分类训练。ELM 是只有一个隐藏层和一个线性输出层的神经网络。训练样本表示为 $\{x_j, y_j\}_{j=1}^{N_i}$,其中 $x \in \mathbb{R}^d$ 和 $y \in \mathbb{R}^d$, N_i 是样本数。给定输入样本,具有 L 个隐藏节点的 ELM 的输出由下式计算:

$$y_j = \sum_{i=1}^L \beta_i h(w_i x_j + b_i), \quad j = 1, \dots, N_i, \quad (7)$$

式中: β_i 表示将第 i 个隐藏节点连接到输出节点的权重向量; $h(\cdot)$ 是一个非线性激活函数; w_i 表示将第 i 个隐藏节点连接到输入节点的权重向量; b_i 是第 i 个隐藏节点的偏差。计算目标权重如下式所示:

$$\beta = H^\dagger Y, \quad (8)$$

式中: H^\dagger 是向量 h 组成的矩阵 H 的摩尔-彭若斯广义逆; $Y = [y_1, y_2, \dots, y_{N_i}]^T$ 。

ELM 算法首先随机选择输入权重 $\{w_1, w_2, \dots, w_{N_i}\}$,并将值随机分配给偏差 $\{b_1, b_2, \dots, b_{N_i}\}$,然后计算隐藏层输出矩阵 H ,从而计算输出权重 $\beta = H^\dagger Y$,最后针对多区域特征卷积形成的变化类和不变类的特征向量进行分类学习,再用训练好的模型对预分类结果中的中间不确定类像素自动分类成变化类和不变类,更新预分类结果,实现变化检测。

3 实验结果与分析

3.1 实验数据集

本文实验采用四组实测数据,由于原始尺寸太大,无法完全显示详细信息,因此选取了四个典型区域,黄河数据集 A、黄河数据集 B、郑州水灾数据集 C、郑州水灾数据集 D 作为实验数据集测试本文方法,所有数据集都有参考图像,如图 4 所示。其中,黄河数据集 A 变化区域相对较小,黄河数据集 B 变化区域在土地和水的边缘,背景稍复杂。郑州水灾数据集 C 中的内陆水域变化区域集中且规律性强,郑州水灾数据集 D 中变化区域相对小但数量多,受背景噪声影响大。黄河数

数据集 A 和 B 为分辨率为 8 m 的数据集, 发生的变化包括水体退去和水体淹没变化, 由 Radarsat-2 卫星 2008 年和 2009 年拍摄于中国黄河。郑州水灾数据集 C 和 D 为高分三号在 2021 年 7 月 20 日和 7 月 24 日在郑州发生洪涝灾害时采集(分辨率为 5 m)。郑州水灾数据集 C 有内陆洪涝灾害变化, 郑州水灾数据集 D 有边缘水体退去变化和内陆农田水体灌溉变化, 数据集参数信息如表 1 所示。本文为无标记样本的无监督变化检

测, 不同数据集训练样本来源于原始数据本身, 伪标签来源于 HFCM 预分类结果。HFCM 分类结果中包含白色变化类、黑色不变类, 以及灰色中间类三类。由于不变类样本通常大于变化类样本, 本文以变化类样本量为基准, 同时选取不变类中与变化类相等的样本量作为训练集, 中间类为测试集, 对不同数据集产生的预分类结果中的中间类进行再分类, 进而得到只包含变化类和不变类的变化检测结果。




图 4 多时相 SAR 图像及其变化参考。第一行是黄河数据集 A, 第二行是黄河数据集 B, 第三行是郑州水灾数据集 C, 第四行是郑州水灾数据集 D。(a) 时间 1 的图像; (b) 时间 2 的图像; (c) 变化参考图

Fig. 4 Multi-temporal SAR images and their change references. The first row is Yellow River dataset A, the second row is Yellow River dataset B, the third row is Zhengzhou flood dataset C, and the fourth row is Zhengzhou flood dataset D. (a) Images at time 1; (b) images at time 2; (c) change reference images

3.2 评估指标

变化检测结果的定量分析评估指标设置如下: 漏警(FN)为未检测到的变化像素, 虚警(FP)为错误检测为变化的未变化像素。总误差数(OE)是 FN 和 FP 的总和。正确分类百分比(PCC)由式(9)计算, 其中, TP 是正确检测为变化类的像素数, 即在参考图像和检测结果中均为变化区域的像素数。TN 是正确检测为

不变类的像素数, 即在参考图像和检测结果中均为未改变区域的像素数。 k 表示 Kappa 系数, 由式(10)计算。对于准确度评估, Kappa 统计量是基于误差矩阵和机会一致性之间的差异来衡量准确度或一致性, 它比 PCC 更具有说服力。其中, PRE 表示“实际与预测数量的乘积之总和”除以“样本总数的平方”, 由式(11)计算。PCC 和 Kappa 系数在实验中以百分比的形式表

表 1 SAR 数据集参数
Table 1 SAR dataset parameters

Dataset	Yellow River dataset A	Yellow River dataset B	Zhengzhou flood dataset C	Zhengzhou flood dataset D
Sensor	Radarsat-2	Radarsat-2	Gaofen-3	Gaofen-3
Location	Yellow River, China	Yellow River, China	Zhengzhou, China	Zhengzhou, China
Data	2008. 06 2009. 06	2008. 06 2009. 06	2021. 07. 20 2021. 07. 24	2021. 07. 20 2021. 07. 24
Size	296×184	233×356	300×300	300×300
Change	Water fades	Water flooding and water fades	Flood disaster	Water fades and farm irrigation

示。本文所提方法程序都是在配备 Intel Core i7-10875 2.30 GHz CPU 和 32 GB RAM 的计算机上使用 Matlab 2020b 编程语言执行的。

$$P_{CC} = (S_{TP} + S_{TN}) / (S_{TP} + S_{FP} + S_{TN} + S_{FN}), \quad (9)$$

$$k = (P_{CC} - P_{RE}) / (1 - P_{RE}), \quad (10)$$

$$P_{RE} = [(S_{TP} + S_{FP})(S_{TP} + S_{FN}) + (S_{FN} + S_{TN})(S_{FP} + S_{TN})] / (S_{TP} + S_{TN} + S_{FP} + S_{FN})^2. \quad (11)$$

3.3 实验结果

本文利用邻域比差异图的 NR_ELM^[13]、Gabor 特征和 PCANet 结合的 GaborPCANet^[23]、小波变换改进池化层的卷积小波神经网络(CWNN)^[21]以及空域和

频域结合的双域网络 DDNet^[22]四种方法与本文所提方法进行了四组数据集上的实验对比分析,以证明 LHCR_MRFCELM 的性能。

对于黄河数据集 A,图 5 显示了五种方法的最终检测结果图。除了本文提出的方法外,其余检测结果都有较多的白色虚警,DDNet [图 5(d)]表现一般。这组数据集很明显地体现了本文方法在去除虚警上的作用。由表 2 可知,本文提出的 LHCR_MRFCELM 方法的 Kappa 值(86.44%)显著优于其余对比方法,且其耗时也很少(20.7 s)。




图 5 黄河数据集 A 的最终变化检测图像。(a) NR_ELM; (b) GarborPCANet; (c) CWNN; (d) DDNet; (e) LHCR_MRFCELM; (f) 变化参考图像

Fig. 5 Final change detection images of Yellow River dataset A. (a) NR_ELM; (b) GarborPCANet; (c) CWNN; (d) DDNet; (e) LHCR_MRFCELM; (f) change reference image

对于黄河数据集 B,图 6 显示了五种方法的最终检测结果图。图 6(c)和 6(d)白色虚警最多,说明 CWNN 和 DDNet 这两种方法不适用于这组数据集,由表 2 可知,本文方法的 Kappa 值最高(78.82%),耗时较少(21.7 s),NR_ELM 的 Kappa 值次之(74.73%)。

郑州水灾数据集 C 的结果如图 7 所示,可以观察到图 7(e)结果中的虚警相对较多,但是表 2 显示漏警 FN 值最少,凸显了本文方法在保留细节降低漏警方面的优势。其余方法虽然虚警较少,但是漏警较多。

本文方法在这组数据集上 Kappa 值达到最优为 86.37%,耗时较少(19.6 s)。

郑州水灾数据集 D 的结果如图 8 所示,定量分析数据如表 2 所示。这组数据集的变化区域小而多,甚至有一小部分农田变化不明显,其像素值很接近背景值,较难检测。图 8(c)和 8(d)中出现大量白色噪点,说明 CWNN 和 DDNet 这两种方法不适用于这组变化区域小而多的数据集。本文设计方法的 Kappa 值达到了 69.50%,耗时最少(21.2 s)。NR_ELM




图 6 黄河数据集 B 的最终变化检测图像。(a) NR_ELM; (b) GarborPCANet; (c) CWNN; (d) DDNet; (e) LHCR_MRFCELM; (f) 变化参考图像

Fig. 6 Final change detection images of Yellow River dataset B. (a) NR_ELM; (b) GarborPCANet; (c) CWNN; (d) DDNet; (e) LHCR_MRFCELM; (f) change reference image




图 7 郑州水灾数据集 C 的最终变化检测图像。(a) NR_ELM; (b) GarborPCANet; (c) CWNN; (d) DDNet; (e) LHCR_MRFCELM; (f) 变化参考图像

Fig. 7 Final change detection images of Zhengzhou flood dataset C. (a) NR_ELM; (b) GarborPCANet; (c) CWNN; (d) DDNet; (e) LHCR_MRFCELM; (f) change reference image

(59.67%) 和 GarborPCANet (59.38%) 方法的 Kappa 值次之, 但是耗时依然很长 (1593.9 s), CWNN、DDNet 两种方法均出现了较多漏警。

3.4 差异图的生成过程分析

本节围绕差异图生成过程中各步骤的必要性开展讨论, 图 9 显示了原始图像生成差异图各个步骤的分

析, 本文对生成过程中缺少一个步骤、两个步骤以及三个步骤进行比较。其中, 完整的 LHCR 差异图在每组数据集中达到的 Kappa 值最大, 这说明了差异图各步骤的必要性; 无前期 SRAD 滤波的 Kappa 值低的原因是原始 SAR 图像中含有大量相干斑噪声, 这直接导致检测结果中大量的虚警; 前三组数据无对数双曲余弦




图 8 郑州水灾数据集 D 的最终变化检测图像。(a) NR_ELM; (b) GarborPCANet; (c) CWNN; (d) DDNet; (e) LHCR_MRFCELM; (f) 变化参考图像

Fig. 8 Final change detection images of Zhengzhou flood dataset D. (a) NR_ELM; (b) GarborPCANet; (c) CWNN; (d) DDNet; (e) LHCR_MRFCELM; (f) change reference image

表 2 不同方法在四个数据集的评估指标

Table 2 Evaluation metrics of different methods on four datasets

Method	Yellow River dataset A					
	FN	FP	OE	PCC /%	<i>k</i> /%	<i>t</i> /s
NR_ELM ^[13]	9	926	935	98.28	55.04	3.9
GarborPCANet ^[23]	3	2078	2081	96.19	35.34	1755.3
CWNN ^[21]	9	1667	1676	96.92	40.24	281.4
DDNet ^[22]	21	2492	2513	95.39	30.19	287.8
LHCR_MRFCELM	65	100	165	99.70	86.44	20.7
Method	Yellow River dataset B					
	FN	FP	OE	PCC /%	<i>k</i> /%	<i>t</i> /s
NR_ELM ^[13]	944	221	1165	98.60	74.73	8.6
GarborPCANet ^[23]	178	2049	2227	97.32	68.34	3472.8
CWNN ^[21]	111	10162	10273	87.62	29.99	259.7
DDNet ^[22]	151	4856	5007	93.96	48.28	312.1
LHCR_MRFCELM	603	696	1299	98.43	75.82	21.7
Method	Zhengzhou flood dataset C					
	FN	FP	OE	PCC /%	<i>k</i> /%	<i>t</i> /s
NR_ELM ^[13]	3127	16	3143	96.51	76.44	5.6
GarborPCANet ^[23]	3257	13	3270	96.37	75.29	1593.9
CWNN ^[21]	1989	108	2097	97.67	85.37	282.4
DDNet ^[22]	2886	112	2998	96.67	77.98	266.4
LHCR_MRFCELM	1633	390	2023	97.75	86.37	19.6
Method	Zhengzhou flood dataset D					
	FN	FP	OE	PCC /%	<i>k</i> /%	<i>t</i> /s
NR_ELM ^[13]	3388	537	3925	95.63	59.67	5.8
GarborPCANet ^[23]	3385	374	3759	95.82	59.38	1537.3
CWNN ^[21]	433	15282	15715	82.54	36.08	319.4
DDNet ^[22]	730	7136	7866	91.26	54.63	352.6
LHCR_MRFCELM	2065	1362	3427	96.19	69.50	21.2

变换的 Kappa 值较高,这是因为这三组数据中变化区域数量少且集中,且地物对比度较高,受双曲余弦变换影响较小;而郑州水灾数据集 D 的无双曲余弦变换的 Kappa 值较低,这是因为郑州水灾数据集 D 中包含的区域小而多,且某些变化区域与背景区域对比度接近,这就导致生成的差异图中这部分区域很容易与背景区域混合,最终导致检测结果中这部分成为了漏警。无中值滤波时,四组数据集的 Kappa 值都达到了最低,说明适当的中值滤波必不可少;四组数据集无后期 SRAD 滤波的 Kappa 值比完整的 LHCR 差异图产生的 Kappa 值小,是因为这部分 SRAD 滤除了经中值滤波后的细小不明显的噪点,直接提高了差异图的质量,减少了最后检测结果的虚警。同时无中值滤波和无后期 SARD 滤波与同时无对数双曲余弦变换、无中值滤波和无后期 SARD 滤波的 Kappa 值偏低,更说明了本文的差异图生成步骤的必要不可缺性。最后,从图 9 中的差异可以看出,本文差异图生成中的步骤重要性排序从高到低依次为完整步骤(Kappa 值最高)、中值滤波步骤(缺中值滤波 Kappa 值最低)、后期 SRAD 滤波单步骤、前期 SRAD 滤波单步骤、对数双曲余弦变换单步骤。

图 10 给出了三种差异图生成方法的结果,图 10(a)是本文提出的 LHCR 差异图(无后续中值滤波和 SRAD 滤波),图 10(b)是对数比差异图,图 10(c)是邻域比差异图。从图中可以看出,对数比差异图中




图 10 三种差异图生成结果图。(a)提出的 LHCR 差异图;(b)对数比差异图;(c)邻域比差异图
Fig. 10 Results of three DI. (a) Proposed LHCR DI; (b) log-ratio DI; (c) neighborhood-based ratio DI

3.5 样本块尺寸 r 分析

本节为对参数 r 的测试, r 代表多区域特征提取中的邻域大小。邻域大小是影响最终变化检测结果的一个重要参数。在四组实测 SAR 数据集上进行了实验,并以 Kappa 值作为判据。如图 12 所示,分别设置 r 为 3、5、7、9、11、13、15 和 17,以测试 r 和 Kappa 值之间的关系。很明显,随着尺寸 r 的增大,四组数据集 Kappa 值整体都呈现先增大后减小的趋势。ELM 分类器需要一个合适的邻域块来进行特征学习,如果 r 设为 3,由于邻域尺寸小,参与的像素数量少,则结果对邻域噪声敏感,Kappa 值低;当 r 尺寸变大时,会增大计算负担,且可能引入噪声信息,影响变化检测性能。当 r 设置为 5 时,所提出的方法在四组数据集上已达最佳性

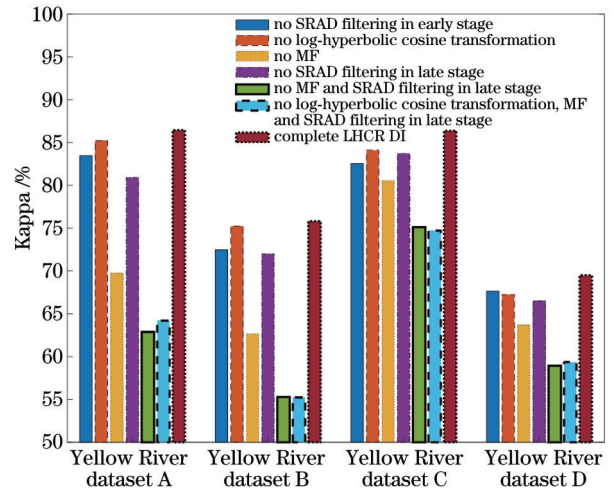


图 9 差异图分析图

Fig. 9 Difference image analysis chart

变化区域被凸显的同时,背景噪声也被凸显(很多白色噪点);邻域比差异图^[13]变化区域连同噪声一块被模糊,一些小的变化细节信息被忽略(图像模糊);而本文提出的 LHCR 差异图在凸显变化区域保留细节信息的同时,也抑制了噪声。此外,图 11 给出了三种差异图生成方式下的 NR_ELM 和 MRFCELM 图像变化检测结果和对应的 Kappa 值。本文的方法在图 11(d)中以 0.6950 的 Kappa 值取得最优,通过对比分析可知,本文的差异图质量明显更高,同时,本文的 MRFCELM 也具有一定的优势。

能。因此,本文设置 $r=5$ 。

4 结 论

本文提出了一种基于 LHCR 差异图构造与 MRFCELM 的无监督变化检测方法。该方法利用 SRAD 滤波器和 LHCR、中值滤波来生成鲁棒性强的差异图,采用快速高效的 MRFCELM 来提高分类的精度和效率。对数双曲余弦变换是一种对比度增强函数,用于提升图像中变化区域与背景区域的对比度,尤其是对比度不明显的边缘部分。在生成差异图后,以差异图生成的 HFCM 结果为标签,从双时相 SAR 图像和差异图中选取样本块,设计了 MRFCELM 自动进行特征提取和分类。通过实验验证了该方法的效果,




图 11 三种差异图生成方式下的 NR_ELM 和 MRFCELM 变化检测结果。(a) LHCR_ELM, Kappa 值为 0.6364; (b) LR_ELM, Kappa 值为 0.6473; (c) NR_ELM, Kappa 值为 0.5967; (d) LHCR_MRFCELM, Kappa 值为 0.6950; (e) LR_MRFCELM, Kappa 值为 0.3973; (f) NR_MRFCELM, Kappa 值为 0.6454

Fig. 11 Change detection results of NR_ELM and MRFCELM for three DI generation methods. (a) LHCR_ELM, Kappa value is 0.6364; (b) LR_ELM, Kappa value is 0.6473; (c) NR_ELM, Kappa value is 0.5967; (d) LHCR_MRFCELM, Kappa value is 0.6950; (e) LR_MRFCELM, Kappa value is 0.3973; (f) NR_MRFCELM, Kappa value is 0.6454

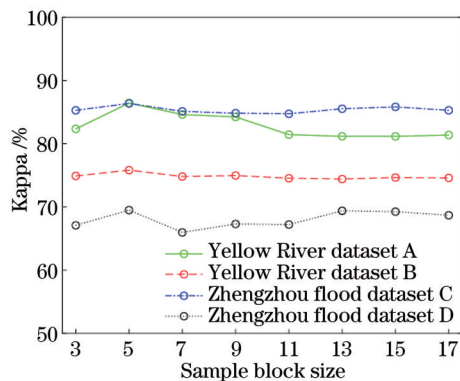


图 12 不同样本块尺寸大小与 PCC 之间的关系

Fig. 12 Relationship between different sample block sizes and PCC

比 NR_ELM、GaborPCANet、CWNN、DDNet 等无监督变化检测方法具有更好的性能。本文方法没有复杂的特征提取步骤和过多的参数设置,易于使用,快速稳定,具有工程应用的潜力。

参 考 文 献

[1] Mishra P K, Rai A, Rai S C. Land use and land cover change detection using geospatial techniques in the Sikkim Himalaya, India[J]. The Egyptian Journal of Remote Sensing and Space Science, 2020, 23(2): 133-143.

[2] Touati R, Mignotte M, Dahmane M. Anomaly feature learning for unsupervised change detection in heterogeneous images: a deep sparse residual model[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 588-600.

[3] Lê T T, Froger J L, Minh D H T. Multiscale framework for rapid change analysis from SAR image time series: case study of flood monitoring in the central coast regions of Vietnam[J].

Remote Sensing of Environment, 2022, 269: 112837.

- [4] Pulvirenti L, Squicciarino G, Fiori E. A method to automatically detect changes in multitemporal spectral indices: application to natural disaster damage assessment[J]. Remote Sensing, 2020, 12(17): 2681.
- [5] 韩星, 韩玲, 李良志, 等. 基于深度学习的高分辨率遥感图像建筑物变化检测[J]. 激光与光电子学进展, 2022, 59(10): 1001003.
- Han X, Han L, Li L Z, et al. Building change detection in high-resolution remote-sensing images based on deep learning[J]. Laser & Optoelectronics Progress, 2022, 59(10): 1001003.
- [6] 常振良, 杨小冈, 卢瑞涛, 等. 基于改进DeepLabv3+的高分辨率遥感影像变化检测研究[J]. 激光与光电子学进展, 2022, 59(12): 1228006.
- Chang Z L, Yang X G, Lu R T, et al. High-resolution remote sensing image change detection based on improved DeepLabv3+ [J]. Laser & Optoelectronics Progress, 2022, 59(12): 1228006.
- [7] Jiang X, Li G, Liu Y, et al. Change detection in heterogeneous optical and SAR remote sensing images via deep homogeneous feature fusion[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 1551-1566.
- [8] 慕彩红, 霍利利, 刘逸, 等. 基于小波融合和PCA-核模糊聚类的遥感图像变化检测[J]. 电子学报, 2015, 43(7): 1375-1381.
- Mu C H, Huo L L, Liu Y, et al. Change detection for remote sensing images based on wavelet fusion and PCA-kernel fuzzy clustering[J]. Acta Electronica Sinica, 2015, 43(7): 1375-1381.
- [9] Liu L Y, Jia Z H, Yang J, et al. SAR image change detection based on mathematical morphology and the K-means clustering algorithm[J]. IEEE Access, 2020, 7: 43970-43978.
- [10] Liu R C, Wang R N, Huang J J, et al. Change detection in SAR images using multiobjective optimization and ensemble strategy[J]. IEEE Geoscience and Remote Sensing Letters, 2021, 18(9): 1585-1589.
- [11] Rignot E J M, van Zyl J J. Change detection techniques for ERS-1 SAR data[J]. IEEE Transactions on Geoscience and Remote Sensing, 1993, 31(4): 896-906.
- [12] Bazi Y, Bruzzone L, Melgani F. Automatic identification of the number and values of decision thresholds in the log-ratio image for change detection in SAR images[J]. IEEE Geoscience and

- Remote Sensing Letters, 2006, 3(3): 349-353.
- [13] Gao F, Dong J Y, Li B, et al. Change detection from synthetic aperture radar images based on neighborhood-based ratio and extreme learning machine[J]. Journal of Applied Remote Sensing, 2016, 10(4): 046019.
- [14] Atasever U H, Gunen M A. Change detection approach for SAR imagery based on arc-tangential difference image and k-means[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 3509605.
- [15] Zheng Y G, Zhang X R, Hou B, et al. Using combined difference image and k-means clustering for SAR image change detection[J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(3): 691-695.
- [16] Du P J, Liu S C, Gamba P, et al. Fusion of difference images for change detection over urban areas[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5(4): 1076-1086.
- [17] Hou B, Wei Q, Zheng Y G, et al. Unsupervised change detection in SAR image based on Gauss-log ratio image fusion and compressed projection[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(8): 3297-3317.
- [18] Li Y Y, Liu G Y, Li T T, et al. Application of data driven optimization for change detection in synthetic aperture radar images[J]. IEEE Access, 2019, 8: 11426-11436.
- [19] Li Y Y, Peng C, Chen Y Q, et al. A deep learning method for change detection in synthetic aperture radar images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(8): 5751-5763.
- [20] 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.
- [21] 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.
- [22] Qu X F, Gao F, Dong J Y, et al. Change detection in synthetic aperture radar images using a dual-domain network[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 4013405.
- [23] 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.
- [24] Le Q V, Karpenko A, Ngiam J, et al. ICA with reconstruction cost for efficient overcomplete feature learning[C]//NIPS'11: Proceedings of the 24th International Conference on Neural Information Processing Systems, December 12-14, 2011, Granada, Spain. New York: ACM Press, 2011: 1017-1025.

Synthetic Aperture Radar Image Change Detection Based on Difference Image Construction of Log-Hyperbolic Cosine Ratio and Multi-Region Feature Convolution Extreme Learning Machine

Lin Zhikang¹, Liu Wei^{1*}, Niu Chaoyang¹, Gao Gui², Lu Wanjie¹

¹*School of Data and Target Engineering, PLA Strategic Support Force Information Engineering University, Zhengzhou 450000, Henan, China;*

²*Faculty of Geosciences and Environmental Engineering, Southwest Jiaotong University, Chengdu 611756, Sichuan, China*

Abstract

Objective The current synthetic aperture radar (SAR) image change detection still faces the following two challenges. (1) Robustness of difference image (DI) generation. The existing DIs are blurred, and there are more interfering pixels with the same gray value as the change pixels in the DIs. The change regions are influenced by the background information. (2) Effectiveness of DI analysis. In recent years, DI-based unsupervised machine learning or deep learning methods for change detection usually use image sample blocks for spatial feature extraction of pixels to be classified, which lose the detailed information characterizing change information, and there are many false alarms in the classification results, which is not efficient. If we can make full use of various features, reduce false alarms, and improve efficiency, the performance of detection will be greatly improved. Therefore, both robust DIs and diversity feature extraction should be considered to build a robust and fast SAR change detection model. Therefore, this study proposes a new unsupervised change detection method based on the DI of the log-hyperbolic cosine ratio (LHCR) and multi-region feature convolution extreme learning machine (MRFCELM), namely, LHCR_MRFCELM, to solve the problems of poor quality, low detection accuracy, and long detection time in SAR image change detection.

Results and Discussions In this study, four methods are experimentally compared and analyzed with the proposed method on four datasets to demonstrate the performance of LHCR_MRFCELM. Figure 5 shows the images of the final detection results of the five methods. Except for the method proposed in this study, all the detection results have many white false alarms. The Kappa value of the LHCR_MRFCELM method (86.44%) as shown in Table 2 is significantly

better than that of the rest comparison methods, and the method also takes very little time (20.7 s). In addition, the necessity of each step in the generation process of DIs is discussed. Figure 9 shows the analysis of each step of the DIs generated from the original images, and the situations when one, two, or three steps are missing in the generation process are compared. Among them, the complete DI of LHCR achieves the largest Kappa value in each dataset, which illustrates the necessity of each step of DIs. The neighborhood size r in multi-region feature extraction is also discussed and it is demonstrated that the proposed method has the best performance on four datasets when r is set to 5.

Conclusions In this study, we propose an unsupervised change detection technique using LHCR_MRFCELM. The method uses the speckle reducing anisotropic diffusion filter, LHCR, and median filtering to generate robust DIs and a fast and efficient MRFCELM to improve the accuracy and efficiency of classification. The log-hyperbolic cosine transformation is a contrast enhancement function used to enhance the contrast between change region and background region in an image, especially the edges where the contrast is not obvious. After DI generation, the HFCM results generated from the DI are used as labels to select sample blocks from the dual-temporal SAR images and the DI, and an MRFCELM is designed to automatically perform feature extraction and classification. Experiments validate the effectiveness of the method, which has better performance than unsupervised change detection methods such as NR_ELM, GaborPCANet, CWNN, and DDNet. The proposed method has no complicated feature extraction steps and no excessive parameter settings, which is easy to use, fast, and stable and has potential for engineering applications.

Key words remote sensing and sensors; synthetic aperture radar image; change detection; difference image; multi-region features; log-hyperbolic cosine transformation; extreme learning machine