

# 控制与决策

Control and Decision

基于协同聚类和权重注意力稀疏自编码网络的变化检测方法

韩敏, 林凯, 张成坤

引用本文:

韩敏, 林凯, 张成坤. 基于协同聚类和权重注意力稀疏自编码网络的变化检测方法[J]. *控制与决策*, 2021, 36(10): 2442–2450.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.1633>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

[基于聚类簇结构特性的自适应综合采样法在入侵检测中的应用](#)

Toward intrusion detection via cluster structure-based adaptive synthetic sampling approach

*控制与决策*. 2021, 36(8): 1920–1928 <https://doi.org/10.13195/j.kzyjc.2019.1672>

[基于批次图像化的卷积自编码故障监测方法](#)

Fault detection of batch image-based convolutional autoencoder

*控制与决策*. 2021, 36(6): 1361–1367 <https://doi.org/10.13195/j.kzyjc.2019.1342>

[基于自注意力生成对抗网络的图像超分辨率重建](#)

Image super-resolution reconstruction based on self-attention GAN

*控制与决策*. 2021, 36(6): 1324–1332 <https://doi.org/10.13195/j.kzyjc.2019.1290>

[Anchor-free的尺度自适应行人检测算法](#)

Anchor-free scale adaptive pedestrian detection algorithm

*控制与决策*. 2021, 36(2): 295–302 <https://doi.org/10.13195/j.kzyjc.2020.0124>

[基于分类特征约束变分伪样本生成器的类增量学习](#)

Class incremental learning based on variational pseudo-sample generator with classification feature constraints

*控制与决策*. 2021, 36(10): 2475–2482 <https://doi.org/10.13195/j.kzyjc.2020.0228>

# 基于协同聚类 and 权重注意力稀疏自编码网络的变化检测方法

韩敏<sup>†</sup>, 林凯, 张成坤

(大连理工大学 电子信息与电气工程学部, 辽宁 大连 116023)

**摘要:** 遥感变化检测对于监督和管理土地资源利用具有重要作用. 针对监督变化检测需要人为干预训练样本的劣势、不平衡数据问题以及基于像素变化检测中的“椒盐”现象, 提出基于协同聚类和权重注意力稀疏自编码网络的变化检测方法. 方法采用模糊  $c$  均值和  $K$ -means 对差异图协同聚类得到训练和待分类数据, 同时在样本中考虑灰度共生矩阵特征, 并利用合成少数过采样方法扩充变化样本以解决样本不平衡问题. 通过逐层权重注意力模块加强网络对正权重的学习和削弱负权重的影响, 自编码分类性能得到提升, 其分类结果在差异图超像素分割边界的映射空间中根据约束条件剔除“椒盐”噪声生成变化检测图. 所提出方法在变化检测中实现漏检测与误检测平衡, 达到了提高变化检测精度的同时减少人为干预的目的.

**关键词:** 变化检测; 权重注意力稀疏自编码; 协同聚类; 灰度共生矩阵; 超像素分割; 空间约束

中图分类号: TP753

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.1633

开放科学(资源服务)标识码(OSID):



**引用格式:** 韩敏, 林凯, 张成坤. 基于协同聚类和权重注意力稀疏自编码网络的变化检测方法[J]. 控制与决策, 2021, 36(10): 2442-2450.

## Change detection approach based on cooperative clustering and weighted-attention sparse autoencoder

HAN Min<sup>†</sup>, LIN Kai, ZHANG Cheng-kun

(Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology, Dalian 116023, China)

**Abstract:** Remote sensing change detection plays an important role in the supervision and management of land resource utilization. A change detection approach based on collaborative clustering and weighted-attention sparse autoencoders is proposed, which aims at the disadvantage of human intervention in training samples in supervision change detection, the problem of unbalanced data and the phenomenon of “salt and pepper” in change detection based on pixel-level. Fuzzy  $c$ -means and  $K$ -means are adopted to cluster difference image for training data and data to be classified. Meanwhile, the gray level co-occurrence matrix feature is considered in the samples, and the synthetic minority oversampling technique is utilized to expand the changed samples for solving issues of sample imbalance. Through the layer-wise weight-attention module that enhances the learning of positive weights and weakens the impact of negative weights, the classification performance of autoencoder is improved, and classification results of which in the mapping space of the superpixel segmentation boundary of the difference image eliminate “salt and pepper” noises for generation of change detection map according to the specific constraints. The change detection approach achieves the balance of missing detection and false detection, which increases the accuracy of change detection and reduces the human intervention at the same time.

**Keywords:** change detection; weighted-attention sparse autoencoder; collaborative clustering; gray level co-occurrence matrix; superpixel segmentation; spatial constraints

## 0 引言

自然环境的交替变更和人类的生产开发都会对地表产生一定变化,通过获取地球表面的变化信息有助于监督和管理地球资源的利用,从而为人类生活和

可持续发展作出保障.随着遥感技术的进步<sup>[1]</sup>,利用遥感影像提取地表变化逐渐替代耗费人力的外业勘察,变化检测是其中重要的手段.变化检测是一种分析和识别不同时相卫星影像中同一地理区域

收稿日期: 2019-11-23; 修回日期: 2020-10-12.

基金项目: 国家重点研发计划项目(2016YFC0400903); 中央高校基本科研业务费专项资金项目(DUT20LAB114, DUT2018TB06).

<sup>†</sup>通讯作者. E-mail: minhan@dlut.edu.cn.

变化的遥感技术,其广泛应用于土地利用变化、自然灾害评估以及城市扩张等领域<sup>[2]</sup>。

变化检测根据是否需要真实的样本数据可以分为无监督变化检测和监督变化检测。前者主要基于差异变化向量分析或者利用差异图得到变化检测结果<sup>[3]</sup>, Bovolo等<sup>[4]</sup>提出了基于极坐标表示的变化向量分析方法(change vector analysis, CVA),从理论上分析了在一定假设条件下变化和未变化像素在极坐标域的分布,为CVA方法提供了理论分析和框架; Celik<sup>[5]</sup>采用主成分分析从差异图的像素块中提取特征向量,并利用K-means聚类和欧氏距离生成变化检测图,该方法简单有效,解决了合成孔径雷达影像相干斑噪声的问题; Gong等<sup>[6]</sup>将改进的基于局部信息的模糊聚类算法应用于融合后的差异图,在抑制差异图中噪声的同时加强变化区域的识别; Hou等<sup>[7]</sup>采用基于离散小波变换的融合策略生成差异图,并利用压缩投影提取像素块的特征,最后通过K-means聚类获得变化检测图,所提出方法保持了变化区域的细节,减少了非变化区域的噪声; Kusetogullari等<sup>[8]</sup>将并行二进制粒子群优化算法应用到多时相影像的差异图中,通过最小化代价函数得到变化检测结果,实验结果表明在小、中和大规模数据集上均有效完成了变化检测任务; Liu等<sup>[9]</sup>对压缩变化向量分析<sup>[10]</sup>进行了扩展,通过集成考虑多尺度变化信息解决了多类变化检测问题; Yang等<sup>[11]</sup>提出了一种基于加权协作表示的无监督变化检测框架,通过鲁棒字典学习抑制离群值和噪声点。监督变化检测主要以基于分类的框架为主,如分类后变化检测<sup>[12-13]</sup>、直接分类变化检测<sup>[14]</sup>等。近些年,随着深度学习在语音、视频和图像中的突出表现,其在监督变化检测中也得到了广泛应用。Gong等<sup>[15]</sup>省去了生成差异图的过程,直接设计深度神经网络对两时相影像进行联合分类得到变化检测图; Zhang等<sup>[16]</sup>将堆栈降噪自编码器无监督特征提取和映射神经网络的特征变化分析相结合,解决了多分辨率遥感图像变化检测的问题; Gong等<sup>[17]</sup>为了挖掘有效的光谱信息识别变化区域,提出基于超像素的特征提取和深度神经网络差异表示学习方法; Li等<sup>[18]</sup>通过模糊聚类生成样本来训练卷积神经网络,避免了生成差异图的预处理过程。

自编码网络(autoencoder, AE)作为深度学习中有有效的无监督特征学习网络,逐渐发展较多变种形式,如稀疏自编码网络(sparse autoencoder, SAE)<sup>[19]</sup>、降噪自编码网络(denoising autoencoder, DAE)<sup>[20]</sup>、非

负约束稀疏自编码网络(sparse autoencoders with nonnegativity constraints, NCAE)<sup>[21]</sup>、变分自编码网络(variational autoencoder, VAE)<sup>[22]</sup>和生成式自编码网络(adversarial autoencoder, AAE)<sup>[23]</sup>等。最近,注意力机制模型以其效仿人类视觉在大量信息中筛选重要信息的模式在深度学习中得到了成功的应用<sup>[24-25]</sup>。受到Hu等<sup>[24]</sup>将空间特征压缩为实数作为全局感受野的启发,同时为了解决监督变化检测出现的不平衡样本问题以及需要人为干预训练样本的缺点,本文提出一种基于权重注意力稀疏自编码网络和协同聚类的遥感变化检测方法,创新点如下:

1) 提出结合合成少数类过采样(SMOTE)的协同聚类方法用于无监督生成变化检测训练数据。对Landsat 8影像利用CVA方法生成差异图,对SAR影像利用log差分生成差异图,利用协同模糊c均值(fuzzy c-means, FCM)和K-means算法对差异图进行聚类获得变化和非变化训练样本。为了降低不平衡数据对分类产生的影响,采用SMOTE按照一定比率对少数样本扩充,同时融合差异图的灰度共生矩阵(gray level co-occurrence matrix, GLCM)特征用于后续神经网络训练。

2) 提出一种权重注意力稀疏自编码网络(weight-attention sparse autoencoder, WASAE),在稀疏自编码网络的每一层中引入注意力机制模块,该模块对网络的正、负权重分别进行特征压缩,通过非线性单元归一化后分别与正、负权重进行加权操作。注意力模块通过对正、负权重的加强和削弱,增强网络对正权重的注意力,从而提升网络分类性能。

3) 提出基于超像素分割的空间约束方法用于降低基于像素分类的变化检测中的“椒盐”噪声。采用简单线性迭代聚类(simple linear iterative clustering, SLIC)对差异图进行分割,将超像素分割边界映射到神经网络的二值变化检测分类结果中,在不同像素块空间内根据约束条件对变化检测图中孤立的噪声像素过滤,提高变化检测精度。

## 1 WASAE网络模型

一个两层的AE可以分为编码层和解码层,编码层将输入模式压缩为抽象的特征表示;解码层将特征表达重构得到输出模式,通过无监督学习过程使得输出模式近似输入模式。SAE在隐藏层中引入Kullback-Leibler散度限制激活值,可以学习输入模式更稀疏的特征表示。同时,为了避免过拟合,在代价函数中加入 $L_2$ 范数约束,整体代价函数表示如下:

$$C_{SAE}(\mathbf{W}, \mathbf{b}) = \frac{1}{2N} \sum \|\mathbf{x} - \hat{\mathbf{x}}\|^2 + p \sum_{i=1}^n \alpha \log \frac{\alpha}{\hat{\alpha}_i} + (1 - \alpha) \log \frac{1 - \alpha}{1 - \hat{\alpha}_i} + \frac{r}{2} \sum_{s=1}^2 \sum_{j=1}^{l_s} \sum_{k=1}^{l_{s+1}} (w_{jk}^{(s)})^2. \quad (1)$$

其中:  $N$  为样本个数,  $\mathbf{x}$  和  $\hat{\mathbf{x}}$  分别为输入和重构后的输出,  $p$  为稀疏约束的惩罚系数,  $\alpha$  为稀疏参数,  $\hat{\alpha}_i$  为隐藏层第  $i$  个节点的平均激活值,  $r$  为正则化参数,  $l_s$  和  $l_{s+1}$  分别为第  $s$  层和第  $s+1$  层网络节点个数,  $w_{jk}$  为相邻两层第  $j$  和第  $k$  个节点的连接权重.

根据文献[21]阐述的负权重不利于帮助学习稀疏特征, 引入注意力机制模块削弱负权重的作用, 加强网络对正权重的学习. 对于连接权重  $w_{jk} \in \mathbf{W}$ , 有

$$\mathbf{W} = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1l_{s+1}} \\ w_{21} & w_{22} & \cdots & w_{2l_{s+1}} \\ \vdots & \vdots & & \vdots \\ w_{l_s 1} & w_{l_s 2} & \cdots & w_{l_s l_{s+1}} \end{bmatrix}. \quad (2)$$

注意力机制模块分别将正、负权重进行特征压缩, 压缩后的权重分别代表正值权重和负值权重的全局特征, 特征压缩过程表示如下:

$$F(\mathbf{W}) = \begin{cases} \frac{\sum_{k=1}^{l_{s+1}} w_{jk} \text{sgn}(w_{jk})}{\sum_{k=1}^{l_{s+1}} \text{sgn}(w_{jk})}, & w_{jk} > 0; \\ \frac{\sum_{k=1}^{l_{s+1}} w_{jk} \text{sgn}(-w_{jk})}{\sum_{k=1}^{l_{s+1}} \text{sgn}(-w_{jk})}, & w_{jk} < 0. \end{cases} \quad (3)$$

其中:  $j = 1, 2, \dots, l_s$ ;  $\text{sgn}(\cdot)$  为符号函数, 当函数中自变量大于0时, 函数值为1, 反之函数值为0. 为削弱网络中负值权重的作用, 加强网络对正值权重的学习, 注意力模块将压缩后的特征通过非线性单元进行归一化, 进而再与权重进行加权得到新的权值  $w_{jm}^{\text{new}}$ , 有

$$\zeta(\mathbf{W}, F(\mathbf{W})) = \text{sgn}(w_{jm}) w_{jm} \delta \left( \frac{\sum_{k=1}^{l_{s+1}} w_{jk} \text{sgn}(w_{jk})}{\sum_{k=1}^{l_{s+1}} \text{sgn}(w_{jk})} \right) + \text{sgn}(-w_{jm}) w_{jm} \delta \left( \frac{\sum_{k=1}^{l_{s+1}} w_{jk} \text{sgn}(-w_{jk})}{\sum_{k=1}^{l_{s+1}} \text{sgn}(-w_{jk})} \right). \quad (4)$$

其中:  $m = 1, 2, \dots, l_{s+1}$ ,  $\delta(x) = \frac{1}{1 + e^{-x}}$ .

如式(3)和(4)所示, 正、负权重的全局特征经过非线性归一化单元能够得到两类不同的数值, 分别接近于1和0. 当其与正、负权重分别进行加权时, 正权重相维持在一定范围, 而负权重向数值0靠近. 相对于负权重而言, 正权重得到了加强, 负权重进行了削弱. 相比文献[21]直接对正权值赋0操作, 本文提出的方法保留了正、负权重的信息.

WASAE网络模型如图1所示. 在所提出方法WASAE网络的每一层均增加注意力机制模块, 对影像进行分类时用到此模块. 模块对网络的正、负权重分别进行特征压缩, 通过非线性单元归一化后分别与正、负权重进行加权操作. 注意力模块通过对正、负权重的加强和削弱, 增强网络对正权重的注意力, 从而提升网络的分类性能.

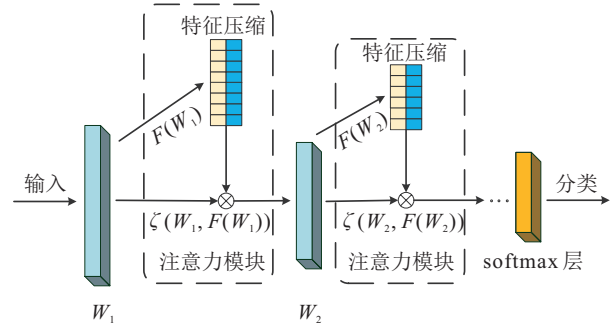


图1 WASAE网络结构

## 2 基于协同聚类 and 空间约束的变化检测

监督变化检测往往需要人为选择变化或非变化的训练样本, 然而真实地物标签的收集需要耗费人力和时间, 有时甚至是很难获得的. 为了解决人为干预训练样本的问题, 本文提出了结合SMOTE方法<sup>[26]</sup>的协同聚类获取遥感训练数据. 对于两时相影像  $I^{t1} = [B_1^{t1}, B_2^{t1}, \dots, B_d^{t1}]$  和  $I^{t2} = [B_1^{t2}, B_2^{t2}, \dots, B_d^{t2}]$ , 采用CVA方法可获得差异图元素

$$d_i = \sqrt{\sum_{j=1}^D (b_{ij}^{t1} - b_{ij}^{t2})^2}, \quad i = 1, 2, \dots, n. \quad (5)$$

其中:  $b_{ij}^{t1} \in B_j^{t1}$ ;  $b_{ij}^{t2} \in B_j^{t2}$ ;  $D$  和  $n$  分别为影像的波段数量和像素总数. 对于SAR影像而言, 采用log差分方法可以获得差异图元素. 设两幅图像分别为  $X_1$  和  $X_2$ , 其差异图为

$$D = |\log(X_1) - \log(X_2)|. \quad (6)$$

为了获得可靠的训练样本, 采用FCM<sup>[27]</sup>和K-means协同对差异图聚类获得变化和非变化类别的训练数据以及待分类类别的测试数据. FCM属于软聚类算法, 通过隶属度矩阵计算差异图元素属于3种类别的

相似度,而  $K$ -means 属于硬聚类算法,计算差异图元素与各类别簇的欧氏距离从而决定簇的划分. 对于差异图  $DI = \{d_1, d_2, \dots, d_n\}$ , FCM 通过最小化如下目标函数得到聚类后的3种类别:

$$J(\mathcal{S}, \mathcal{C}) = \sum_{i=1}^3 \sum_{j=1}^n s_{ij}^\beta \|d_j - c_i\|^2. \quad (7)$$

其中:  $s_{ij} \in [0, 1]$ ,  $\sum_{i=1}^3 s_{ij} = 1$ ,  $j = 1, 2, \dots, n$ , 且有

$$s_{ij} = \frac{1}{\sum_{k=1}^3 \left( \frac{\|d_j - c_i\|}{\|d_j - c_k\|} \right)^{\frac{2}{\beta-1}}}, \quad (8)$$

$$c_i = \frac{\sum_{j=1}^n s_{ij}^m d_j}{\sum_{j=1}^n s_{ij}^m}, \quad (9)$$

$\beta$  为模糊权重指数,  $c_i$  为聚类中心,  $s_{ij}$  为差异图第  $j$  个元素属性与第  $i$  个聚类中心的隶属度. 通过下式可以得到差异图第  $j$  个元素的第  $i$  个类别:

$$l_{\text{FCM}} = \arg \max_j s_{ij}. \quad (10)$$

对于  $K$ -means 算法,从差异图中随机选择3个元素作为初始质心,通过最小化如下目标函数得到类别  $i$ :

$$l_{K\text{-means}} = \arg \min_i \|d_j - o_i\|^2. \quad (11)$$

其中  $o_i$  为质心,更新如下:

$$o_i = \frac{\sum_{j=1}^n L(l_{K\text{-means}} = i) d_j}{\sum_{j=1}^n L(l_{K\text{-means}} = i)}. \quad (12)$$

在  $L(\cdot)$  函数中,当变量真时为1,反之为0. FCM 和  $K$ -means 按照下式进行协同聚类获得数据标签:

$$l_{\text{data}} = \frac{(l_{\text{FCM}} \oplus l_{K\text{-means}})(l_{\text{FCM}} + l_{K\text{-means}})}{2}. \quad (13)$$

其中:待分类数据标签为0,变化数据标签为1,非变化数据标签为2,  $\oplus$  为异或算子.

在变化检测中,变化区域是少量的,因此变化和非变化数据是不均衡的. 现有的监督变化检测中很少考虑到数据不平衡问题,而数据不平衡会导致分类器产生错误分类. 本文引入 SMOTE 方法对协同聚类结果中变化类数据进行样本扩充. 已知变化类样本  $DI_c = \{d_{c_1}, d_{c_2}, \dots, d_{c_q}, DI_c \in DI\}$ , 每次从  $DI_c$  的每个元素中取出  $t$  个近邻样本  $DI_{c_{\text{near}}} = \{d_{c_1}, d_{c_2}, \dots, d_{c_t}\}$ . 对于  $i \in \{1, 2, \dots, q\}$ ,  $j \in \{1, 2, \dots, t\}$ , 从  $DI_{c_{\text{near}}}$  中重复  $N$  次随机抽取一个样本  $d_{c_j}$  按照如下

规则产生  $N$  个新样本:

$$d_{c_z}^{\text{new}} = d_{c_i} + \text{rand}(0, 1)(d_{c_j} - d_{c_i}). \quad (14)$$

其中:  $z \in \{1, 2, \dots, N\}$ ,  $\text{rand}(\cdot, \cdot)$  用于产生变量间的随机数. 通过对容量为  $q$  的  $DI_c$  样本集进行扩充,最终的样本数目达到  $Nq$ .

由于得到的变化和非变化样本仅具有单一像素特征,为了包含差异图更多的信息,将差异图的 GLCM 特征<sup>[28]</sup>与单一像素特征进行融合,从而组成多特征表示的样本数据. GLCM 通过统计的方法描述图像灰度的空间相关性,其是特定空间关系下灰度像素对的联合概率分布的矩阵表示. 对于纹理变化缓慢的图像, GLCM 中对角线的数值较大;而纹理变化剧烈的图像,对角线两侧的值较大. 本文从差异图中提取4种不同的 GLCM 特征,分别是角二阶矩、熵、对比度和均质性. 它们分别描述了差异图纹理变化均匀程度、纹理信息量、清晰度以及均匀程度. 以上4种特征可以表示为

$$\text{ASM} = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} m(i, j)^2, \quad (15)$$

$$\text{Ent} = - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} m(i, j) \log m(i, j), \quad (16)$$

$$\text{Con} = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i - j)^2 m(i, j), \quad (17)$$

$$\text{Hom} = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{m(i, j)}{1 + |i - j|}. \quad (18)$$

其中

$$m(i, j) = \begin{cases} \frac{M(i, j)}{H(H-1)}, & \theta = 0, \frac{\pi}{2}; \\ \frac{M(i, j)}{(H-1)^2}, & \theta = \frac{\pi}{4}, \frac{3\pi}{4}. \end{cases} \quad (19)$$

ASM、Ent、Con 和 Hom 分别为角二阶矩、熵、对比度和均质性;  $H$  为被边界填充后差异图的长或宽;  $G$  为压缩后差异图的灰度等级;  $M(i, j)$  为灰度等级对  $i$  和  $j$  在一定距离和方向  $\theta$  下的累积次数;  $m(i, j)$  为归一化后的概率.

为了减少基于像素的分类结果中“椒盐”现象,提出基于 SLIC 超像素分割<sup>[29]</sup>的空间约束方法. 将差异图进行超像素分割得到超像素块的空间边界集合,有

$$E = \{e_1, e_2, \dots, e_c\}, \quad (20)$$

其中  $c$  为超像素块个数,集合中的元素包含不同超像素块的空间边界. 已知 WASAE 分类后的变化检测图表示为  $CD = \{v_1, v_2, \dots, v_n\}$ , 通过空间映射  $\Phi$  将超

像素块的边界  $E$  映射到变化检测图 CD 中,可以得到变化检测图的像素块集合,有

$$\Phi(E, CD) = \{\phi_1, \phi_2, \dots, \phi_c\} = \underbrace{\{v_1, v_2, \dots, v_k\}, \dots, \{v_\gamma, v_{\gamma+1}, \dots, v_n\}}_c \quad (21)$$

对于每一个超像素块集合,通过如下约束对“椒盐”噪声进行移除:

$$v_j^{\text{new}} = 255 \times (L(v_j = 0)v_j + 1),$$

$$0 < \frac{\sum_{j=1}^{\varepsilon} L(v_j = 0)}{\#\phi_i} \leq T, v_j \in \phi_i, i = 1, 2, \dots, c. \quad (22)$$

其中:像素值 0 和 255 分别为变化和非变化像素, # 用于计算集合中元素个数,  $T$  为变化像素在超像素块中的比例.

整体变化检测框架如图 2 所示. 多光谱影像通过 CVA 方法生成差异图, SAR 影像通过 log 差分方法生成差异图,利用 FCM 和  $K$ -means 协同聚类获得变化、非变化和待分类数据. 同时,从差异图中提取 GLCM 特征融合到样本数据中. 随后,变化区域的样本采用 SMOTE 进行数据扩充,并与非变化区域样本共同训练 WASAE. 最终,网络的分类结果经过空间约束后得到变化检测图.

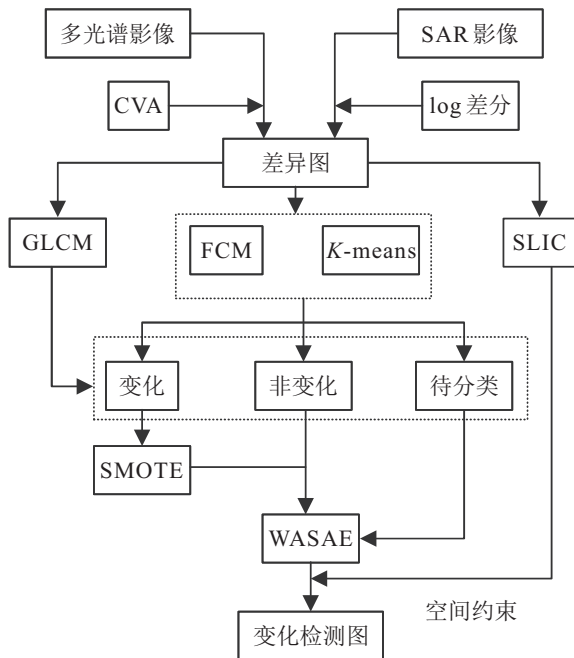


图 2 变化检测框架

### 3 仿真实验

仿真实验由 3 部分组成,分别是无监督训练过程、Landsat 8 遥感数据的变化检测实验以及 SAR 数据的变化检测实验.

#### 3.1 无监督训练过程

为了验证监督训练的有效性,对所提出方法以及对比方法进行无监督训练,训练数据集为本文所使用的 Landsat 8 影像和 SAR 影像. 首先使用无监督方法对数据进行预训练,然后进行有监督的微调,从而提高模型的分类能力. 表 1 和表 2 分别为两个数据集的无监督训练结果. 实验参数设置为  $p = 3, \alpha = 0.1, r = 3e - 3$ . 所提出网络主要与 SAE、DAE 以及对 NCAE 进行对比,其中 DAE 添加 20% 的随机噪声.

表 1 Landsat 8 影像无监督训练结果

方法	FP	FN	MA	FA	Kappa	OA
SAE	<b>2985</b>	7247	0.3410	0.6814	0.3652	0.8689
DAE	4932	6185	0.3824	0.2892	0.5890	0.9336
NCAE	6503	6589	0.4129	0.3324	0.5346	0.9497
本文方法	4104	<b>3245</b>	<b>0.2527</b>	<b>0.1854</b>	<b>0.7159</b>	<b>0.9740</b>

表 2 SAR 影像无监督训练结果

方法	FP	FN	MA	FA	Kappa	OA
SAE	2498	282	0.2442	0.7410	0.3739	0.9693
DAE	3026	152	0.3229	0.6792	0.4021	0.9714
NCAE	1050	<b>56</b>	<b>0.0485</b>	0.9053	0.1527	0.8835
本文方法	<b>186</b>	481	0.4165	<b>0.2163</b>	<b>0.6653</b>	<b>0.9926</b>

从训练结果可以看出, WASAE 在无监督分类的精度高于其他方法,体现了更稳定的优势,且 FA 和 Kappa 也达到了最优. 在后续引入注意力模块后,网络加强了正权值的学习,在无监督学习过程中显著提升了分类性能.


#### 3.2 Landsat 8 遥感数据

遥感数据来自美国地质调查局官网中的 Landsat 8 卫星,经过配准、融合和裁剪后,影像包含 7 个波段,空间分辨率为 15 m,大小为  $490 \times 580$ . 影像感兴趣区域为辽宁省大连市荣兴水库附近,获取时间分别是 2014 年 5 月 26 日和 2017 年 6 月 3 日,具体图像如图 3 所示.

实验中,协同聚类后变化样本数目为 11901,非变化样本数量为 231274,扩充后变化样本数目为 130911. 为了包含不同角度的纹理信息,实验将角二阶矩、熵、对比度和均质性特征分别取均值和方差并与像素特征进行融合,进而得到样本特征为 9 维. 对比实验选择经典无监督变化检测方法 CVA- $K$ -means 和基于所提出变化检测框架的神经网络分类方法,其中包含 SAE、DAE 和 NCAE.



(a) 2014年5月26日



(b) 2017年6月3日

图3 两时相影像图像

实验结果如图4所示. 与CVA-K-means结果相比, 基于所提出变化检测框架的神经网络分类方法均有效减少了“椒盐”噪声. SAE和DAE能够识别出大部分变化区域, 但是仍然有很多变化区域未检测. 与图4(b)、(d)和(e)相比, DAE存在较多分类错误的变化区域. 本文方法与NCAE生成的变化检测图相比其他方法具有良好的效果, 在相同框架下其主要优势源于自编码负值权重的处理. 其中, NCAE约束负值权

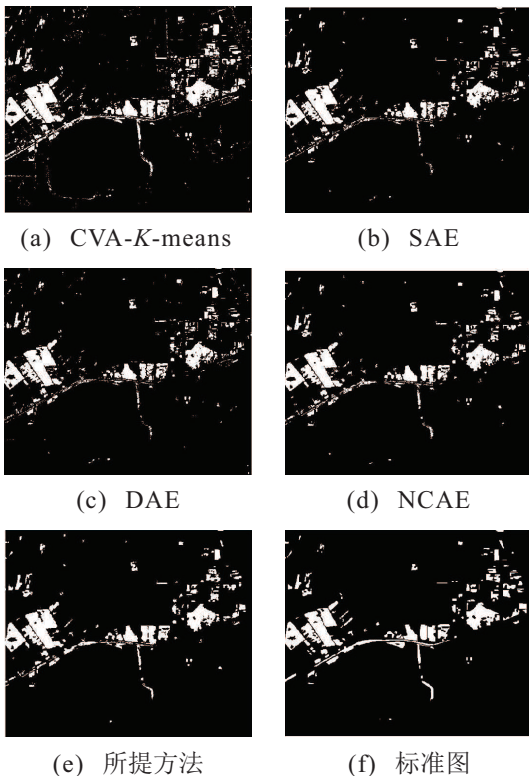


图4 Landsat 8图像变化检测结果

重, 本文方法通过权重注意力加强正权重的学习, 削弱负权重的影响. 值得注意的是, 本文方法在变化区域细节保持方面相比NCAE表现出色, 同时出现错误分类区域较少, 但是仍有少部分区域未能识别.

为了定量评估变化检测精度, 本文引入假阳(false positive, FP)、假阴(false negative, FN)、漏检率(missing alarm, MA)、误检率(false alarm, FA)、Kappa系数和总体精度(overall accuracy, OA). FP为真实未变化样本被判定为变化样本的数量; FN为真实变化样本被判定为未变化样本的数目; MA和FA分别为FN占真实变化样本中的比例以及FP与实验中识别出变化样本的比值; Kappa系数代表与标准图的一致程度, 系数越接近于1一致性越好.

变化检测精度如表3所示, CVA-K-means具有较低FN的同时FP较高, 主要是变化检测图中“椒盐”噪声和过检测导致的, 因此Kappa系数不高. SAE相比DAE具有较低的漏检和错误检测率, Kappa系数和总体精度均高于DAE. 本文方法和NCAE的Kappa系数达到了0.8以上, 表明两种方法与标准图具有良好的一致性. NCAE的FN低于SAE和DAE, 但是FP相对较高. 在所有方法中, 本文方法在FP、FA、Kappa和OA指标中达到了最优, FN和FA达到了次优, 表明本文方法在错误检测和遗漏检测方面做到了良好的平衡.

表3 Landsat 8影像变化检测精度

方法	FP	FN	MA	FA	Kappa	OA
CVA-K-means	7623	<b>2930</b>	<b>0.1379</b>	0.2936	0.7558	0.9627
SAE	3100	5250	0.2470	0.1622	0.7766	0.9705
DAE	3221	5322	0.2504	0.1681	0.7717	0.9698
NCAE	3260	4380	0.2061	0.1618	0.8002	0.9730
本文方法	<b>2948</b>	3888	0.1830	<b>0.1450</b>	<b>0.8219</b>	<b>0.9758</b>

为了评价神经网络对于变化检测的分类性能, 利用真阳率(true positive rate, TPR)和假阳率(false positive rate, FPR)绘制ROC曲线, 同时用曲线下面积(area under curve, AUC)定量分析. 其中: TPR为实验中被分类为变化样本占所有变化样本的比例, FPR为实验中被分类为非变化样本在所有非变化样本的比例.

实验曲线如图5所示, SAE和DAE的ROC曲线较为接近, 其AUC分别为0.8651和0.8635, SAE分类性能高于DAE. NCAE的AUC为0.8862, 分类能力高于SAE和DAE. WASAE的ROC曲线在所有方法曲线的上方且更靠近左上角, 其AUC为0.9007, 表明

WASAE通过逐层权重注意力学习提高了分类性能, 具有较好的差异表示能力.

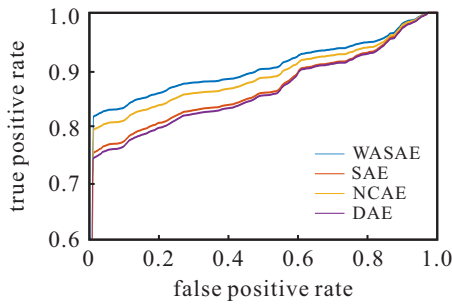


图5 ROC曲线(Landsat 8遥感数据)

### 3.3 SAR数据

为了验证所提出方法的泛化性, 在 Landsat 8 影像实验的基础上增加一组 SAR 数据. 本文 SAR 数据来自于 Berne, 拍摄于 1999 年 4 月和 1999 年 5 月, SAR 数据对降噪的要求较高, 因此本文采用超像素分割的空间约束减少斑点. 图 6 为 SAR 影像图像的原始图像.





图6 SAR影像图像

实验的变化检测精度评估方法与第 3.2 节相同. 变化检测精度如表 4 所示. SAR 图像变化检测结果如图 7 所示. 实验结果表明, 在所有方法中本文方法的 FP、FA、Kappa 和 OA 指标达到了最优, 与第 3.2 节得到的结果相同, 因此可以证明本文方法在 Landsat 8 影像和 SAR 影像数据中均适用, 在错误检测和遗漏检测方面具有很好的平衡性.

SAR 数据 ROC 曲线如图 8 所示. DAE 的 AUC 最低, 为 0.693 3. SAE 分类性能高于 DAE, 其 AUC 为

0.889 5. 可以看出, NCAE 的 AUC 为 0.924 6, 其分类能力高于 SAE 和 DAE. WASAE 的 ROC 曲线在所有方法曲线的上方且更靠近左上角, 其 AUC 为 0.930 4, 表明 WASAE 通过逐层权重注意力学习提高了分类性能, 具有较好的差异表示能力.

表4 SAR图像变化检测精度

方法	FP	FN	MA	FA	Kappa	OA
CVA-K-means	2172	41	0.035 5	0.951 2	0.070 3	0.759 8
SAE	3260	71	0.061 5	0.750 5	0.381 8	0.963 2
DAE	2256	92	0.079 7	0.679 7	0.465 1	0.974 1
NCAE	2928	141	0.122 1	0.742 8	0.385 8	0.966 1
本文方法	186	319	0.276 2	0.216 3	0.803 2	0.992 6
消融实验	2064	90	0.077 9	0.659 6	0.487 7	0.976 2

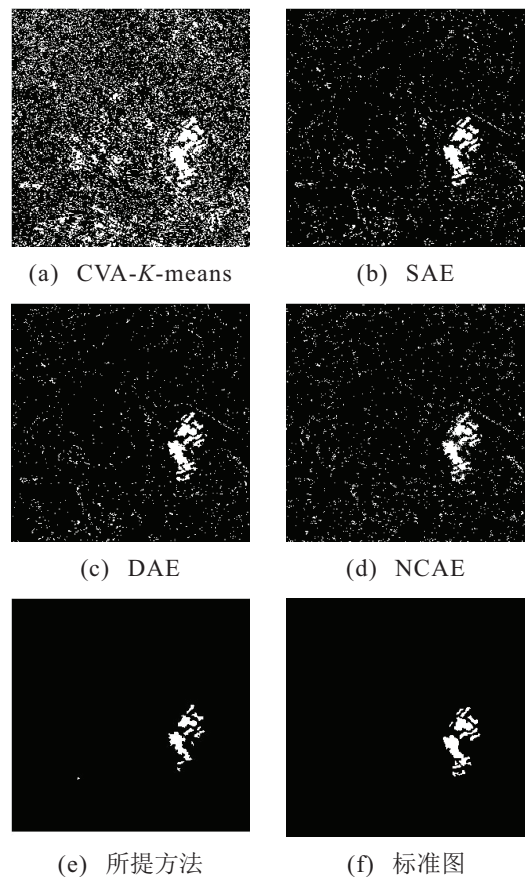


图7 SAR图像变化检测结果

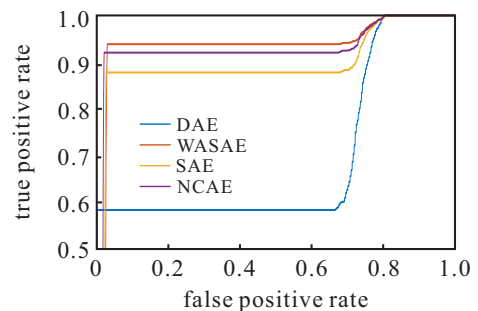


图8 ROC曲线(SAR数据)

### 3.4 参数设置和敏感性分析

考虑到实验中神经网络隐藏层节点设置对实验结果具有一定影响,将样本按照7:3的比例分为训练和测试数据,并分别对神经网络进行训练和测试,利用OA与网络结构的关系设置隐藏层的节点数目,其中 $p = 3, \alpha = 0.1, r = 3e - 3$ . 如表5所示,网络结构为9-60-40-2时OA精度最高,因此实验中按照此设置隐藏层网络节点.

表5 OA-网络结构关系

隐藏层参数	20	40	60	80	100
20	0.9263	0.9458	0.9655	0.9584	0.9210
40	0.9658	0.9513	<b>0.9882</b>	0.9750	0.9267
60	0.9527	0.8638	0.9807	0.9436	0.9105
80	0.9589	0.8621	0.9123	0.8725	0.9556
100	0.9036	0.8553	0.9715	0.9510	0.9317

实验中空间约束比率 $T$ 需要人为设置,为了评估其对变化检测的敏感性,按照 $1/T$ 的不同取值绘制出其与Kappa系数的关系,如图9所示. 由图9可见,当 $1/T$ 设置在2后,Kappa系数稳定在0.81以上,验证了理论中 $T$ 取值应该大于0.5,同时表明所提框架不需要繁复的人工调参也能达到较好的效果,这也实现了从样本收集到变化检测结果生成中减少人为干预的目的.




图9 1/T-Kappa关系曲线

## 4 结论

本文提出了基于协同聚类和权重注意力稀疏自编码网络的变化检测方法,该方法采用结合SMOTE的协同聚类方法无监督生成样本,解决了监督变化检测中不平衡数据问题和人为干预样本的劣势. 所提出方法引入了权重注意力稀疏自编码,通过逐层削弱负权重的作用和加强正权重的学习在遥感数据中表现出良好的分类性能和稳定性. 同时,变化检测框架中空间约束条件的加入明显降低了“椒盐”现象,在漏检测和误检测中达到了较好的平衡,获得了较高的Kappa系数和总体精度. 所提出方法从变化检测样本

采集到生成变化检测结果中实现较少人为干预的目的同时提高了变化检测精度,具有实际意义.

### 参考文献(References)

- [1] 赵泉华, 李红莹, 李玉. 区域化模糊C均值高分辨率彩色遥感影像分割方法[J]. 控制与决策, 2015, 30(9): 1706-1710.  
(Zhao Q H, Li H Y, Li Y. Regionalized fuzzy C-means algorithm for segmentation of color remote sensing image[J]. Control and Decision, 2015, 30(9): 1706-1710.)
- [2] Lu D, Mausel P, Brondizio E, et al. Change detection techniques[J]. International Journal of Remote Sensing, 2004, 25(12): 2365-2401.
- [3] Saha S, Bovolo F, Bruzzone L. Unsupervised deep change vector analysis for multiple-change detection in VHR images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(6): 3677-3693.
- [4] Bovolo F, Bruzzone L. A theoretical framework for unsupervised change detection based on change vector analysis in the polar domain[J]. IEEE Transactions on Geoscience and Remote Sensing, 2007, 45(1): 218-236.
- [5] 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.
- [6] 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.
- [7] 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.
- [8] Kusetogullari H, Yavariabdi A, Celik T. Unsupervised change detection in multitemporal multispectral satellite images using parallel particle swarm optimization[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(5): 2151-2164.
- [9] Liu S L, Du Q H, Tong X H, et al. Multiscale morphological compressed change vector analysis for unsupervised multiple change detection[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(9): 4124-4137.
- [10] Bovolo F, Marchesi S, Bruzzone L. A framework for automatic and unsupervised detection of multiple changes in multitemporal images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(6):

- 2196-2212.
- [11] Yang G, Li H C, Wang W Y, et al. Unsupervised change detection based on a unified framework for weighted collaborative representation with RDDDL and fuzzy clustering[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(11): 8890-8930.
- [12] Peiman R. Pre-classification and post-classification change-detection techniques to monitor land-cover and land-use change using multi-temporal Landsat imagery: A case study on Pisa Province in Italy[J]. *International Journal of Remote Sensing*, 2011, 32(15): 4365-4381.
- [13] Wu C, Du B, Cui X H, et al. A post-classification change detection method based on iterative slow feature analysis and Bayesian soft fusion[J]. *Remote Sensing of Environment*, 2017, 199: 241-255.
- [14] Bruzzone L, Cossu R, Vernazza G. Detection of land-cover transitions by combining multirate classifiers[J]. *Pattern Recognition Letters*, 2004, 25(13): 1491-1500.
- [15] 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.
- [16] Zhang P Z, Gong M G, Su L Z, et al. Change detection based on deep feature representation and mapping transformation for multi-spatial-resolution remote sensing images[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, 116: 24-41.
- [17] Gong M G, Zhan T, Zhang P Z, et al. Superpixel-based difference representation learning for change detection in multispectral remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(5): 2658-2673.
- [18] 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.
- [19] Ng A. Sparse autoencoder[J]. *CS294A Lecture Notes*, 2011, 72: 1-19.
- [20] Vincent P, Larochelle H, Bengio Y, et al. Extracting and composing robust features with denoising autoencoders[C]. *Proceedings of the 25th International Conference on Machine Learning*. New York: ACM, 2008: 1096-1103.
- [21] Hosseini-Asl E, Zurada J M, Nasraoui O. Deep learning of part-based representation of data using sparse autoencoders with nonnegativity constraints[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 27(12): 2486-2498.
- [22] Kingma D P, Welling M. Auto-encoding variational bayes[J]. 2013, arXiv: 1312.6114.
- [23] Makhzani A, Shlens J, Jaitly N, et al. Adversarial autoencoders[J]. 2015, arXiv: 1511.05644.
- [24] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE, 2018: 7132-7141.
- [25] 李旭, 姚春龙, 范丰龙, 等. 结合注意力机制的循环神经网络复述识别模型[J]. *控制与决策*, 2021, 36(1): 152-158.  
(Li X, Yao C L, Fan F L, et al. Recurrent neural networks based paraphrase identification model combined with attention mechanism[J]. *Control and Decision*, 2021, 36(1): 152-158.)
- [26] Chawla N V, Bowyer K W, Hall L O, et al. SMOTE: Synthetic minority over-sampling technique[J]. *Journal of Artificial Intelligence Research*, 2002, 16: 321-357.
- [27] Bezdek J C, Ehrlich R, Full W. FCM: The fuzzy *c*-means clustering algorithm[J]. *Computers & Geosciences*, 1984, 10(2/3): 191-203.
- [28] Soh L K, Tsatsoulis C. Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1999, 37(2): 780-795.
- [29] Achanta R, Shaji A, Smith K, et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(11): 2274-2282.

## 作者简介

韩敏(1959—),女,教授,博士生导师,从事复杂工业系统建模与控制、智能技术及优化算法等研究, E-mail: minhan@dlut.edu.cn;

林凯(1994—),男,硕士生,从事遥感影像分类和变化检测的研究, E-mail: linkai0522@163.com;

张成坤(1990—),男,博士生,从事高光谱影像提取和分类的研究, E-mail: zhangchengkundon@mail.dlut.edu.cn.

(责任编辑: 郑晓蕾)