中图法分类号:TP751.1　　**文献标识码**:A　　**文章编号**:1006-8961(XXXX)XX-0001-19

论文引用格式:Jia Meng, Wang Pengcheng, Qiu Yuan, Shi Zhenghao, Lyu Zhiyong. Unsupervised heterogeneous remote sensing image change detection with a dendritic neuron cross-modal reconstruction network[J/OL]. Journal of Image and Graphics, XXXX:1-19. DOI: 10.11834/jig.260442. (贾萌, 王鹏程, 邱原, 石争浩, 吕志勇. 树突神经元跨模态重建网络的无监督异质遥感图像变化检测[J/OL]. 中国图象图形学报,XXXX:1-19. DOI: 10.11834/jig.260442.)[DOI:10.11834/jig.260442]

树突神经元跨模态重建网络的无监督异质遥感图像变化检测

贾萌,王鹏程,邱原,石争浩,吕志勇

西安理工大学计算机科学与工程学院,西安　710048

摘　要:**目的**　异质遥感图像由不同传感器获取,在成像机理、辐射响应和空间纹理等方面存在显著差异,为获取变化区域信息而进行直接比对易产生大量“伪变化”。同时,传统无监督跨模态学习未区分像素状态,真实变化像素参与全局对齐训练会干扰稳定模态映射关系,严重降低变化检测的区分精度与鲁棒性。**方法**　针对上述问题,本文提出一种融合树突神经元模型(dendritic neuron model,DNM)的跨模态重建无监督变化检测网络。该方法基于双边自编码器架构,构建多尺度卷积编码模块挖掘遥感图像多层级特征信息,并且创新性地引入仿生DNM建模复杂非对称的跨模态非线性重建关系,有效适配异质图像强模态差异。同时,设计动态区域掩码自适应约束机制,引导对抗损失与特征一致性损失约束稳定不变区域,规避变化像素对模态对齐学习的干扰,联合重建损失与结构相似性损失实现多约束协同优化。**结果**　在Italy、Gloucester、California和Texas等四组公开的异质遥感图像数据集上进行测试,结果表明所提方法的总体检测精度分别达到0.973 4、0.957 1、0.924 5和0.989 0,能够有效平衡误检与漏检水平。消融实验进一步验证了动态区域掩码机制的有效性与必要性。**结论**　所提算法能够在无人工标注条件下增强异质遥感图像的跨模态可比性,有效抑制“伪变化”和变化像素的学习干扰,提升无监督场景下异质遥感图像变化检测性能。本文已公开算法完整实现代码,开源地址为:https://cstr.cn/10441.11.sciencedb.j00240.0009x。

关键词:异质遥感图像;无监督变化检测;跨模态重建;树突神经元模型;动态区域掩码

Unsupervised heterogeneous remote sensing image change detection with a dendritic neuron cross-modal reconstruction network

Jia Meng, Wang Pengcheng, Qiu Yuan, Shi Zhenghao, Lyu Zhiyong

School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China

Abstract: **Objective** Heterogeneous remote sensing images acquired by different sensors exhibit substantial differences in imaging mechanisms, radiometric responses, spatial textures, and noise characteristics. Direct comparison of such images can generate numerous modality-induced pseudo changes. Moreover, existing unsupervised cross-modal learning methods often apply alignment constraints to the entire image without distinguishing changed pixels from unchanged pixels. Because genuinely changed pixels do not satisfy the stable cross-modal correspondence of unchanged regions, their participation in global alignment may disturb the learning of reliable modality mappings and reduce the separability between changed and unchanged regions. In addition, conventional transformation models have limited ability to represent complex and asymmet-

收稿日期:2026-07-20;**修回日期**:2026-10-30

基金项目:陕西省科技厅-陕西省自然科学基础研究计划(面上项目)(项目编号:2025JC-YBMS-747);广西重点研发计划(项目编号:桂科FN2600640542)

© 中国图象图形学报版权所有

ric nonlinear relationships between heterogeneous modalities. To address these problems, a dendritic neuron model-based cross-modal reconstruction network, termed DNM-CMR, is proposed for unsupervised heterogeneous remote sensing image change detection**Method** DNM-CMR transforms the direct comparison of heterogeneous images into reconstruction-error analysis in the target-modality domain. First, a dual-branch autoencoder architecture with a multiscale convolutional encoding module is constructed to extract hierarchical spatial features from the source-modality image. Local neighborhoods centered on individual pixels are then unfolded into contextual feature vectors containing central-pixel responses, surrounding textures, boundaries, and spatial information. These vectors are fed into a dendritic neuron model to reconstruct the corresponding target-modality responses. The DNM consists of synaptic, dendritic, membrane, and somatic layers. Multiple dendritic branches perform nonlinear modulation and multiplicative aggregation of local feature components, enabling the model to represent high-order interactions among different spatial features and establish complex nonlinear mappings between heterogeneous modalities. The responses of different dendritic branches are subsequently integrated to generate the target-modality reconstruction. Because unchanged regions generally preserve relatively stable relationships between the source and target modalities, they can be reconstructed with relatively small errors. In contrast, genuine changes disrupt the learned cross-modal correspondence and usually produce larger reconstruction residuals. Therefore, the absolute difference between the reconstructed image and the real target image is used to generate the change-intensity map. A dynamic region-mask mechanism is introduced to reduce the interference of genuinely changed pixels during network training. Reconstruction deviation is combined with the channelwise variance of encoded features to estimate the potential change degree of each pixel. After normalization and weighted fusion, K-means clustering divides the pixels into changed and unchanged candidate regions. An exponential moving average is then used to update the masks periodically, reducing fluctuations caused by unstable reconstruction and individual clustering results. The network is jointly optimized using reconstruction loss, structural similarity loss, adversarial loss, and feature consistency loss. The reconstruction and structural similarity losses preserve pixel responses and local spatial structures. The adversarial loss improves the distribution consistency between the reconstructed image and the real target image, whereas the feature consistency loss reduces cross-modal feature differences in unchanged regions. The dynamically estimated unchanged-region mask is applied to the adversarial and feature consistency terms, ensuring that these constraints mainly act on reliable unchanged regions and preventing genuinely changed pixels from being forcibly aligned. During the initial training stage, the network learns a basic cross-modal mapping through reconstruction and structural constraints. The dynamic region mask and consistency constraints are subsequently introduced to refine the mapping and improve change separability. **Result** Experiments were conducted on four publicly available heterogeneous remote sensing datasets, namely Italy, Gloucester, California, and Texas, covering lake expansion, flooding, and forest-fire events. The proposed method was compared with five representative unsupervised methods: SRGCAE, SCASC, RIEM, CDRL, and CFRL. The overall accuracies achieved by DNM-CMR on the four datasets were 0.973 4, 0.957 1, 0.924 5, and 0.989 0, respectively. DNM-CMR also obtained the highest Kappa coefficient and F1 score among the comparison methods on all four datasets. Visual results demonstrate that the proposed method effectively suppresses extensive background false alarms while preserving the principal structures of changed regions. Although several comparison methods achieved better individual AUC, false-positive, or false-negative values on specific datasets, DNM-CMR generally provided a more balanced tradeoff between false alarms and missed detections. Ablation experiments on the four datasets further verified the effectiveness of the proposed components. Applying adversarial and feature consistency losses to the entire image caused genuinely changed pixels to interfere with cross-modal consistency learning. Introducing an unchanged-region mask substantially improved the detection results, while dynamically updating the mask further enhanced its adaptability to the current reconstruction state. Replacing the DNM reconstruction module with a conventional convolutional decoder resulted in performance degradation on all four datasets, demonstrating the effectiveness of the DNM in representing complex nonlinear cross-modal relationships. **Conclusion** DNM-CMR establishes a nonlinear mapping between heterogeneous image modalities and extracts changes through target-domain reconstruction residuals rather than direct heterogeneous comparison. The dendritic neuron model enhances the representation of complex local feature relationships, while the dynamic region mask reduces the adverse influence of changed pixels on network optimization. Experimental results demonstrate that the proposed method can effectively suppress modality-induced pseudo

© 中国图象图形学报版权所有

changes and achieve accurate and balanced change detection without requiring manually labeled samples. The complete implementation code of the algorithm described in this paper has been made publicly available, and the open-source address is: https://cstr.cn/10441.11.sciencedb.j00240.0009x

Key words: heterogeneous remote sensing images; unsupervised change detection; cross-modal reconstruction; dendritic neuron model; dynamic region mask

论文引用格式: Jia Meng, Wang Pengcheng, Qiu Yuan, Shi Zhenghao, Lyu Zhiyong. Unsupervised heterogeneous remote sensing image change detection with a dendritic neuron cross-modal reconstruction network[J/OL]. Journal of Image and Graphics. DOI: 10.11834/jig.260442.（贾萌，王鹏程，邱原，石争浩，吕志勇. 树突神经元跨模态重建网络的无监督异质遥感图像变化检测[J/OL]. 中国图象图形学报. DOI: 10.11834/jig.260442.）

0 引　言

遥感图像变化检测旨在通过对比分析同一地理区域获取的不同时相遥感图像，进而识别地表覆盖物、城市扩张、灾害损毁和生态环境的变化信息，是遥感图像理解与智能解译领域的重要任务之一。传统变化检测方法多建立在同源遥感图像基础上，也就是说，假设双时相图像来自相同或相近传感器，并具有相对一致的辐射响应、空间分辨率和成像特性（Radke等，2005；Gong等，2016）。然而，在实际应急监测和长期地表观测中，受卫星重访周期、天气条件、数据可获得性和传感器差异等因素影响，研究者往往需要联合使用光学、合成孔径雷达（synthetic aperture radar，SAR）、多光谱或其他不同来源遥感图像开展变化检测（Mercier等，2008；Lyu等，2022）。异质遥感图像虽然能够增强地表观测的互补性，但不同传感器在成像机理、辐射特性、空间纹理和噪声分布方面存在显著差异，使得同一地物在不同时相图像中可能呈现完全不同的灰度、纹理或结构特性，进而导致直接差分、比值分析等传统方法难以区分真实变化与由模态差异引起的“伪变化”（Liu等，2018b；Wu等，2022）。因此，如何在无监督条件下削弱异质模态差异，并获得可比较、可分离的变化表征，成为异质遥感图像变化检测中的核心问题之一（Luppino等，2022；Jia等，2025）。

围绕上述问题，已有研究主要从特征变换、结构建模和深度跨模态映射等方向展开。早期方法通常通过统计建模、字典学习或像素变换将异质图像映射到相对一致的表达空间，例如Gong等人（2016）利用耦合字典学习挖掘多源数据之间的共享表示，Liu等人（2018b）提出同质像素转换方法以建立异质图像之间的像素映射关系。这类方法在一定程度上缓解了异质图像不可直接比较的问题，但对复杂非线性模态差异、局部结构错配和高维语义信息的表达能力仍然有限。随后，图模型与结构一致性方法被用于挖掘异质图像中相对稳定的空间结构关系，Sun等人（2021b）提出基于块相似性图矩阵和非局部块相似性的变化检测方法（Sun等，2021c），通过比较结构关系而非直接比较灰度值来降低辐射差异影响。进一步地，结构一致性图方法和迭代鲁棒图方法通过优化图结构或引入空间上下文提升变化检测稳定性，但这类方法通常依赖图构建质量，且在复杂纹理、大尺度场景或强噪声条件下存在计算代价高、参数敏感等问题（Sun等，2021a；Sun等，2022b）。近年来，深度学习方法通过卷积神经网络、自编码器和生成对抗网络学习跨模态映射关系，显著增强了异质图像的非线性表达能力。Wang等人（2024）通过高分辨率特征提取、Ghost模块和多层语义特征融合，提高了高分辨率遥感影像变化检测的精度与效率。Zhao等人（2017）利用耦合神经网络学习异质图像判别特征，Liu等人（2018a）构建深度卷积耦合网络以提升光学与雷达图像之间的变化检测能力。Niu等人（2019）利用条件生成对抗网络实现异质图像转换，Li等人（2021）构建基于深度图像翻译的光学-SAR变化检测网络，提高了跨模态生成和差异表达能力。Jia等人（2024）构建了嵌入聚类分析的双边对抗自编码网络，通过结构一致性约束和基于语义信息的对抗学习实现异质图像公共域转换，并降低变化区域对网络优化过程的干扰。Luppino等人（2022）提出基于亲和变化先验的深度图像转换方法和编码对齐自编码器方法，以结构先验或潜在编码一致性约束跨模态映射过程（Luppino等，2024）。

© 中国图象图形学报版权所有

Wu等人(2022)通过共同性自编码器学习异质图像中的公共特征,Liu等人(2025)进一步提出共同性特征表示学习框架,从多模态图像中提取可比较的潜在共同特征。

综合现有研究可以发现,异质遥感图像变化检测的关键并非单纯提高网络复杂度,而是在无监督条件下建立稳定的跨模态可比表征。当前方法仍面临以下难点:1)异质图像之间的对应关系具有明显的非线性和地物依赖性。同一地物在不同传感器中的响应不仅受到单一像素值影响,还与局部纹理、边缘及邻域空间结构密切相关,因此从源模态到目标模态的映射本质上需要描述多个局部特征分量之间的联合响应关系,简单的线性变换或加性映射难以充分刻画这种复杂对应关系(Mercier等,2008)。树突神经元模型通过非线性突触变换、树突分支内的乘性聚合以及多分支响应融合,能够描述不同输入特征之间的非线性交互关系(Todo等,2019;Jia等,2025),为复杂跨模态响应建模提供了适合的计算结构;2)变化区域会干扰跨模态重建或对抗学习过程,这是因为真实变化像素在语义上本就不应被强制对齐,若将其与不变区域共同参与模态一致性约束,容易削弱变化响应甚至造成过度平滑(Niu等,2019);3)仅依赖重建误差或单一差异度量难以获得稳定变化图,这是因为异质图像中的噪声、局部纹理差异、边缘错配和类别不平衡都可能被误判为变化(Wu等,2022;Tang等,2024)。Tang等人(2024)指出,增强图结构表达有助于提高异质变化检测中空间结构特征的利用能力;Liu等人(2025)则强调,从多模态图像中提取共同性特征是提升无监督变化检测性能的重要方向。因此,能否设计一种无监督学习方法,在完成异质图像跨模态重建的同时,动态削弱变化区域对网络训练的不利影响,并通过多重约束增强不变区域一致性和变化区域可分性?

针对以上问题,本文提出一种基于树突神经元模型的跨模态重建网络(dendritic neuron model-based cross-modal reconstruction network, DNM-CMR),用于在无标签条件下实现异质遥感图像之间的变化信息提取。该方法主要由跨模态特征编码模块、DNM非线性重建模块、动态区域约束模块和多损失联合优化组成。本文主要贡献如下:

1)构建了基于树突神经元非线性映射的跨模态重建框架。针对异质图像跨模态响应关系复杂、传统线性或加性映射难以充分描述局部特征交互的问题,本文将DNM作为跨模态重建解码器,通过突触非线性调制、树突分支乘性聚合和多分支融合,对源模态局部编码特征与目标模态响应之间的非线性关系进行建模。将异质图像变化检测任务转化为可通过定量表征重建差异的变化区域判别问题。

2)提出自适应动态区域约束学习策略。针对现有无监督方法未区分像素变化状态、全局对齐学习易受真实变化区域污染的缺陷,本文利用重建误差与深层编码特征联合判别像素属性,通过动态掩码机制将区域先验信息嵌入网络训练过程,约束不变区域的跨模态特征对齐,有效规避真实变化像素对模态一致性学习的干扰,显著提升变化与不变区域的特征可分性。

3)本文所提DNM-CMR算法在四组标准异质遥感图像基准数据集上完成测试,实验结果取得的检测性能与主流的异质遥感图像变化检测算法比较,获得了较优的性能。

1 本文研究方法

给定经过配准的双时相异质遥感图像分别为图像$\boldsymbol{X}$和图像$\boldsymbol{Y}$,本文通过学习由$\boldsymbol{X}$到$\boldsymbol{Y}$的非线性映射关系,将异质图像变化检测转化为目标模态重建误差分析问题。下面将对整体算法框架、DNM重建模块、动态区域掩码估计器和损失函数设计这四个部分进行介绍。

1.1 算法整体框架

给定经过配准的双时相异质遥感图像,源模态光学图像记为$\boldsymbol{X}\in\mathbf{R}^{H\times W\times C_x}$,目标模态图像记为$\boldsymbol{Y}\in\mathbf{R}^{H\times W\times C_y}$。这里,$H$和$W$分别表示图像高度和宽度,$C_x$和$C_y$分别表示源模态和目标模态的通道数,源模态和目标模态通道数取决于具体传感器及数据形式。本文方法的目标是在无监督条件下学习从多通道光学模态到单通道图像模态的非线性映射关系,并利用目标模态重建误差提取变化信息,因此本文设置C_y=1。DNM-CMR算法整体框架如图1所示。

具体而言,首先将图像$\boldsymbol{X}$输入跨模态特征编码器$E(\cdot)$,获得深层特征表示:

$$\boldsymbol{F}_X=E(\boldsymbol{X}) \tag{1}$$

式中,$\boldsymbol{F}_X$表示图像$\boldsymbol{X}$的编码特征,由于变化检测需要获得像素级预测结果,本文进一步以每个像素位置

© 中国图象图形学报版权所有

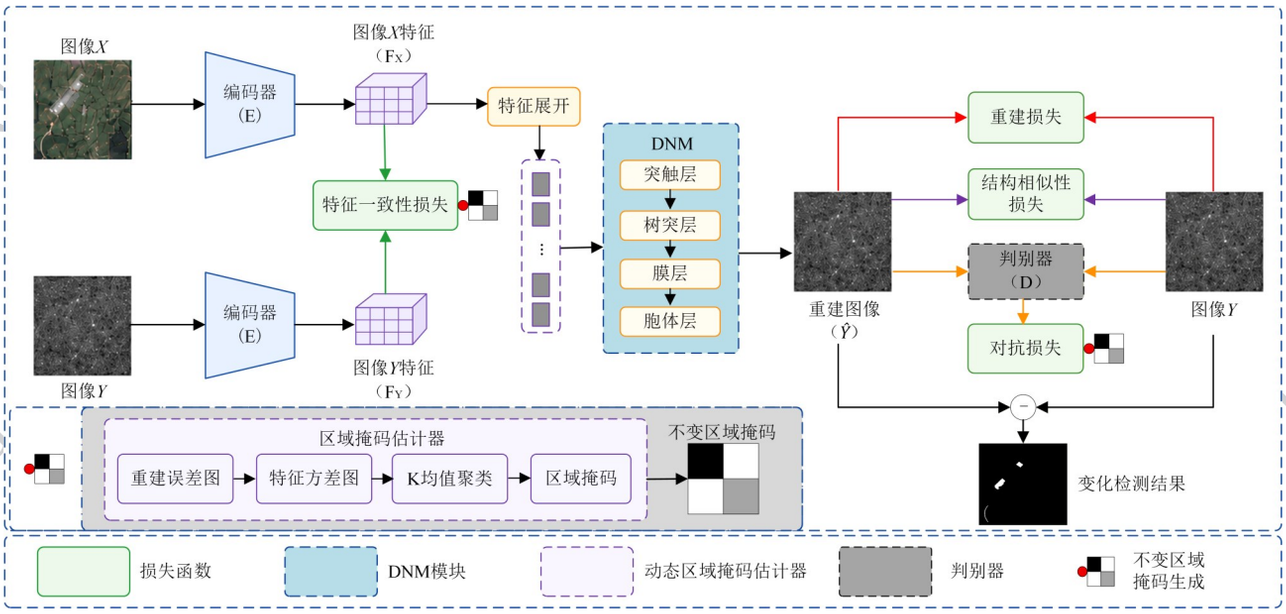


图1　DNM-CMR算法框架

Fig. 1　Framework of the DNM-CMR algorithm

为中心，从编码特征 $\boldsymbol{F}_x$ 中提取局部邻域特征块，并将其展开为一维特征向量

$$\boldsymbol{p}_i = \mathrm{Vec}(\theta_{w_s}(\boldsymbol{F}_x, i)) \tag{2}$$

式中，$\boldsymbol{p}_i$ 表示第 i 个像素对应的局部特征向量，$\theta_{w_s}(\boldsymbol{F}_x, i)$ 表示以第 i 个像素为中心、窗口大小为 $w_s \times w_s$ 的局部邻域特征，$\mathrm{Vec}(\cdot)$ 表示向量化操作。

将局部特征向量 $\boldsymbol{p}_i$ 输入DNM非线性重建模块 $\mathrm{DNM}(\cdot)$，得到对应位置的目标模态重建响应：

$$\hat{y}_i = \mathrm{DNM}(\boldsymbol{p}_i) \tag{3}$$

式中，$\hat{y}_i$ 为第 i 个像素位置的目标模态重建响应。对所有像素位置进行重建后，可得到完整的重建图像 $\hat{\boldsymbol{Y}}$。训练完成后，利用真实目标图像 $\boldsymbol{Y}$ 与重建图像 $\hat{\boldsymbol{Y}}$ 之间的差异生成差异图：

$$D_{\mathrm{diff}}(i) = |\boldsymbol{Y}(i) - \hat{\boldsymbol{Y}}(i)| \tag{4}$$

式中，$D_{\mathrm{diff}}(i)$ 表示第 i 个像素位置的差异值。一般而言，不变区域在跨模态重建后应具有较小差异，而变化区域因地物状态发生改变，往往产生较高重建差异，因此，差异图 $\boldsymbol{D}_{\mathrm{diff}}$ 可以作为变化检测的判别依据。为进一步提高训练过程对变化区域和不变区域的区分能力，本文在网络优化过程中引入动态区域掩码估计器，分别估计不变区域掩码 $\boldsymbol{M}_{\mathrm{u}}$ 和变化区域掩码 $\boldsymbol{M}_{\mathrm{c}}$，并将其用于约束对抗损失和特征一致性损失。这样可以在一定程度上削弱由传感器差异引起的伪变化，同时使真实地物变化在重建残差中得到更明确表达。最终，通过阈值分割获得二值变化检测结果图。

1.2　DNM重建模块

异质图像之间通常存在复杂的非线性响应关系，由于不同地物在两种模态中的响应机制不同，相同的单一特征变化并不一定产生固定的目标响应，其映射结果往往取决于纹理、边缘和邻域上下文等多个特征的联合状态。因此，跨模态重建并非简单的一维线性变换，而是一个具有局部条件依赖的多变量非线性映射问题。DNM的计算结构与上述映射特性具有较好的对应关系。已有研究表明，DNM通过非线性突触响应和树突内乘性计算描述多个输入之间的局部非线性交互，并将不同树突分支的响应在胞体处进行融合(Todo等，2019；Jia等，2025)。因此，本文将源模态图像的局部编码特征输入DNM，利用多树突分支的非线性调制与乘性聚合，学习源模态特征到目标模态响应之间的映射关系，并生成目标模态重建图像。该模块不直接判断像素是否变化，而是将异质图像之间的直接比较转化为目标模态空间中的重建误差分析。DNM的结构如图2所示。

DNM包含四层：突触层、树突层、膜层和胞体层。突触层通过非线性映射函数将外部输入信号转换为神经元输入信号。树突层接收来自突触层的信

© 中国图象图形学报版权所有

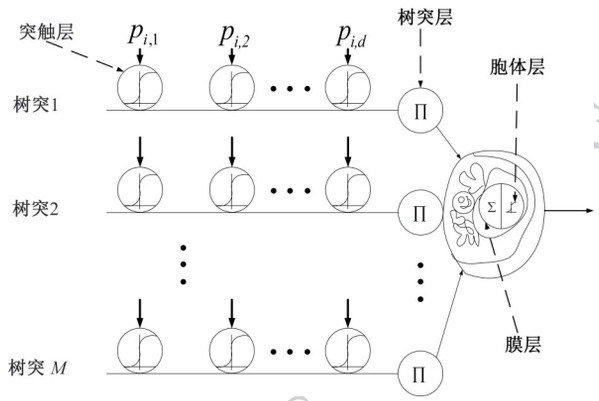


图2 DNM结构图

Fig. 2 Structure of the DNM

号，并在每个树突分支上对输入信号之间的相互作用进行表示。膜层则收集所有树突分支的信号并进行求和。最后，胞体层使用非线性函数对膜层的输出进行计算，生成信号传递给下一个神经元。这里，对于第i个像素位置，设其输入到DNM模块的局部特征向量为：

$$\boldsymbol{p}_i = \left[p_{i,1}, p_{i,2}, \cdots, p_{i,d}\right]^{\mathrm{T}} \tag{5}$$

式中，d表示局部邻域展开后的特征维度。与仅利用单个像素光谱值进行映射不同，$\boldsymbol{p}_i$同时包含中心像素及其邻域范围内的空间上下文信息，有助于DNM模块感知局部结构信息和地物边界信息。

首先，在突触层中，输入特征$\boldsymbol{p}_i$被分别送入多个树突分支，每个分支对输入特征的不同分量进行独立的非线性调制。设DNM共有M个树突分支，则第m个分支中第r个输入分量的突触响应定义为：

$$s_{i,m,r} = \frac{1}{1 + \exp\left[-\alpha\left(p_{i,r}\omega_{m,r} - b_{m,r}\right)\right]} \tag{6}$$

式中，$\omega_{m,r}$表示突触连接权重，$b_{m,r}$表示突触阈值，α为非线性响应函数的斜率系数。该层的作用是对输入特征进行分支相关的非线性变换，使不同树突分支能够关注不同的局部特征组合。对于跨模态重建任务而言，不同地物类型在源模态图像与目标模态图像之间的对应关系并不完全一致，单一线性映射难以充分描述这种复杂关系。突触层通过可学习的权重和阈值参数，对局部特征进行选择性增强或抑制，从而为后续树突分支建模提供更加灵活的特征响应。

随后，在树突层中，同一树突分支内的多个突触响应被联合聚合。第m个树突分支的输出可表示为：

$$d_{i,m} = \prod_{r=1}^{d} s_{i,m,r} \tag{7}$$

与简单加权求和不同，乘性聚合能够刻画输入特征分量之间的高阶耦合关系。当某些关键特征分量响应较弱时，该树突分支的整体输出会受到抑制；当多个相关特征同时具有较强响应时，分支输出则会被增强。这种机制有助于模型同时考虑局部纹理、边缘和空间上下文之间的关联关系，而不是仅依赖单一像素响应完成映射。

在膜层中，来自不同树突分支的输出被进一步汇聚，得到第i个像素位置的综合响应

$$u_i = \sum_{m=1}^{M} d_{i,m} \tag{8}$$

该步骤相当于对多个树突分支所学习到的局部映射模式进行融合。膜层通过累加不同分支的输出，将这些局部映射模式整合为统一的重建响应，从而提高模型对复杂地物类型和非线性模态差异的适应能力。

在胞体层中，综合响应u_i经过非线性激活得到中间输出

$$z_i = \frac{1}{1 + \exp\left[-\gamma\left(u_i - \tau\right)\right]} \tag{9}$$

式中，γ和τ分别表示胞体层激活函数的斜率和阈值参数。胞体层进一步压缩并调节细胞膜层的综合响应，使DNM输出具有更强的非线性表达能力。由于源模态图像和目标模态图像均经过归一化处理，为使重建结果与目标图像具有一致的数值范围，本文采用Sigmoid函数获得最终输出

$$\hat{y}_i = \mathrm{sigmoid}(z_i) \tag{10}$$

由此，DNM模块完成了从局部源模态编码特征$\boldsymbol{p}_i$到目标模态响应$\hat{y}_i$的非线性跨模态重建。对所有像素位置重复上述过程后，可以得到完整的目标模态重建图像$\hat{\boldsymbol{Y}}$。

该设计的关键在于，DNM在本文中并不是变化类别判别器，而是跨模态响应重建模型，从而避免了对人工标注变化样本的依赖。其作用是学习源模态编码特征与目标模态图像响应之间的非线性映射关系，即根据输入的局部特征$\boldsymbol{p}_i$预测对应位置在目标模态中的重建响应$\hat{y}_i$。同时，由于遥感变化检测任务中未变化区域通常占据图像主体，DNM在训练过程中能够优先捕获稳定地物区域的跨模态对应关

© 中国图象图形学报版权所有

系，为后续区域约束和网络优化提供更加可靠的重建基础。

1.3 动态区域掩码估计器

全图一致性约束会使真实变化像素参与跨模态对齐，导致网络同时拟合稳定模态差异和真实地物变化，从而削弱重建误差对变化信息的表达能力。针对这一问题，本文联合当前重建误差和源模态编码特征来估计像素状态，构建动态区域掩码，使对抗损失和特征一致性损失主要作用于可靠不变区域。该掩码仅用于限定网络训练中的约束范围，不直接作为最终变化检测结果。

具体而言，设真实目标图像为 $\boldsymbol{Y}$，DNM模块生成的目标模态重建图像为 $\hat{\boldsymbol{Y}}$。对于第 i 个像素位置，首先计算其重建偏差：

$$r_i = |y_i - \hat{y}_i| \tag{11}$$

式中，y_i 表示真实目标图像在第 i 个位置的像素值，$\hat{y}_i$ 表示DNM模块生成的对应重建响应。对于未变化区域，源模态特征与目标模态响应之间通常保持相对稳定的对应关系，因而重建误差较小；当地物状态发生变化时，该对应关系受到破坏，重建结果与真实目标响应之间的偏差随之增大。因此，r_i 可以反映当前像素位置的潜在变化程度。

仅依赖重建偏差进行区域划分，容易受到训练初期映射不稳定、传感器噪声以及局部纹理差异的影响。为提高区域估计的稳定性，本文进一步引入光学编码特征图的信息。设光学图像 $\boldsymbol{X}$ 经编码网络得到的特征图为 $\boldsymbol{F}$，对于第 i 个像素位置，设其在特征图 $\boldsymbol{F}$ 中对应的通道特征向量为：

$$\boldsymbol{f}_i = \left[f_{i,1}, f_{i,2}, \cdots, f_{i,C} \right]^{\mathrm{T}} \tag{12}$$

式中，C 为特征通道数。为了刻画该位置光学编码特征响应的离散程度，计算其通道方差：

$$v_i = \frac{1}{C} \sum_{c=1}^{C} (f_{i,c} - \bar{f}_i)^2 \tag{13}$$

式中，$\bar{f}_i$ 表示第 i 个像素位置在所有通道上的平均响应。特征方差能够从源模态特征空间反映局部响应的不稳定程度。对于地物边界、纹理复杂区域或潜在变化区域，其编码特征往往具有更强的通道响应差异，而对于均匀且稳定的不变区域，特征响应通常更加平滑。因此，将重建偏差与光学编码特征方差结合，可以降低单一重建误差带来的误判风险。

由于重建偏差和特征方差具有不同的数值范围，本文首先分别对二者进行归一化处理，并将其加权融合为区域估计响应

$$q_i = \lambda \tilde{r}_i + (1 - \lambda) \tilde{v}_i \tag{14}$$

式中，$\tilde{r}_i$ 表示归一化后的重建偏差，$\tilde{v}_i$ 表示归一化后的光学编码特征方差，λ 为权重系数。该融合方式以目标模态空间中的重建误差为主要依据，同时利用源模态特征空间中的局部响应变化作为辅助信息，从而提高区域估计对噪声和复杂纹理的鲁棒性。

在获得区域估计响应 q_i 后，本文采用K-means聚类将所有像素划分为两类。由于变化区域通常对应更大的重建偏差和更强的特征响应波动，因此将聚类均值较大的类别定义为变化候选区域，将另一类别定义为不变候选区域。据此得到当前训练阶段的变化区域掩码 $\boldsymbol{M}_{\mathrm{c}}^{t}$ 和不变区域掩码 $\boldsymbol{M}_{\mathrm{u}}^{t}$。与固定阈值分割相比，K-means聚类能够根据当前图像的融合特征分布，自适应确定区域划分边界，避免人工阈值设置对不同场景适应性不足的问题。

考虑到训练初期网络重建能力尚不充分，直接使用当前迭代得到的区域掩码可能导致掩码结果随网络参数变化而剧烈波动。为提高掩码估计的连续性和稳定性，本文采用指数滑动平均策略对区域掩码进行更新：

$$\bar{\boldsymbol{M}}_{\mathrm{c}}^{t} = \rho \bar{\boldsymbol{M}}_{\mathrm{c}}^{(t-1)} + (1 - \rho) \boldsymbol{M}_{\mathrm{c}}^{t} \tag{15}$$

$$\bar{\boldsymbol{M}}_{\mathrm{u}}^{t} = \rho \bar{\boldsymbol{M}}_{\mathrm{u}}^{(t-1)} + (1 - \rho) \boldsymbol{M}_{\mathrm{u}}^{t} \tag{16}$$

式中，ρ 为平滑系数，$\bar{\boldsymbol{M}}_{\mathrm{c}}^{t}$ 和 $\bar{\boldsymbol{M}}_{\mathrm{u}}^{t}$ 分别表示平滑后的变化区域掩码和不变区域掩码。该更新方式能够综合历史区域估计结果和当前区域划分结果，减少单次聚类误差或局部噪声对训练过程的影响，使掩码随着网络重建能力的提升逐步趋于稳定。

动态区域掩码估计器的作用主要体现在两个方面：

1）为无监督训练过程提供了可靠的区域信息，使模型能够在没有真实标签的条件下区分相对稳定的不变区域和潜在变化区域。

2）将不变区域信息引入后续损失约束，使跨模态重建网络更加侧重于学习不变区域中的稳定映射关系，避免真实变化像素被错误地作为一致性样本参与训练。通过这种动态估计与更新机制，模型能够在训练过程中逐步改善区域划分质量，并为后续多损失联合优化提供更加可靠的空间约束。

© 中国图象图形学报版权所有

1.4 多损失联合优化

为提高跨模态重建的稳定性，并增强重建结果对异质图像变化信息的表达能力，本文构建多损失联合优化策略，对编码网络和DNM跨模态重建模块进行联合训练。本文的生成端总体优化目标由重建损失、结构相似性损失、对抗损失和特征一致性损失共同构成：

$$L_{\mathrm{G}} = L_{\mathrm{rec}} + \lambda_{\mathrm{ssim}} L_{\mathrm{ssim}} + \lambda_{\mathrm{adv}} L_{\mathrm{adv}} + \lambda_{\mathrm{fc}} L_{\mathrm{fc}} \tag{17}$$

式中，λ_{ssim}、λ_{adv}和λ_{fc}分别表示各损失项的权重系数。训练初期，模型首先以重建损失和结构一致性损失为主学习基本跨模态映射关系，随后逐步引入对抗损失和特征一致性损失，以增强重建结果的目标模态真实性和特征表达稳定性。

1.4.1 跨模态重建损失

重建损失用于约束目标模态重建图像与真实目标图像在像素上的一致性。对于包含$\mathbf{N}$个像素的图像，重建损失定义为均方误差形式

$$L_{\mathrm{rec}} = \frac{1}{\mathbf{N}} \sum_{i=1}^{\mathbf{N}} (\hat{y}_i - y_i)^2 \tag{18}$$

式中，$\hat{y}_i$和y_i分别表示第i个像素位置的$\hat{\boldsymbol{Y}}$和$\boldsymbol{Y}$。该损失直接约束跨模态重建结果的像素级精度，使DNM模块能够学习光学编码特征到目标模态之间的基本映射关系。与区域掩码约束不同，重建损失作用于整幅图像，用于保证模型具备全局重建能力。

1.4.2 结构相似性损失

单通道目标图像所包含的光谱信息相对有限，局部边缘、纹理及空间结构因而成为重建质量的重要判据，单纯采用像素均方误差难以充分保持这些信息。为增强重建图像与目标图像在局部结构上的一致性，本文引入结构相似性损失：

$$L_{\mathrm{ssim}} = 1 - \mathrm{SSIM}(\hat{\boldsymbol{Y}}, \boldsymbol{Y}) \tag{19}$$

式中，SSIM为结构相似性指数。该损失能够从亮度、对比度和结构三个方面约束重建图像，使其在局部空间组织上接近真实目标图像，从而减小结构失真产生的伪变化。

1.4.3 对抗损失

为增强重建结果在目标模态中的分布一致性，本文引入判别器D对增强重建结果在目标模态中的分布一致性和目标模态重建图像进行判别。判别器以y_i和$\hat{y}_i$为输入，学习区分真实目标模态分布与生成目标模态分布。判别器损失定义为：

$$L_{\mathrm{D}} = \frac{1}{2\mathbf{N}} \sum_{i=1}^{\mathbf{N}} \left[\mathrm{BCE}(D(y_i), 0.9) + \mathrm{BCE}(D(\hat{y}_i), 0) \right] \tag{20}$$

式中，BCE(·)表示二元交叉熵损失。真实样本标签采用0.9而非1，是为了进行标签平滑，缓解判别器过强导致的训练不稳定问题。

对应地，生成端的对抗损失用于缩小目标模态重建响应与真实目标数据之间的分布差异。考虑到变化区域中的地物状态已经发生改变，若强制其参与对抗约束，可能会使网络错误拟合真实变化响应。因此，本文利用不变区域掩码$\boldsymbol{M}_{\mathrm{u}}$对生成端对抗损失进行加权约束

$$L_{\mathrm{adv}} = \frac{1}{\mathbf{N}} \sum_{i=1}^{\mathbf{N}} M_{\mathrm{u}}(i) \mathrm{BCE}(D(\hat{y}_i), 1) \tag{21}$$

式中，$M_{\mathrm{u}}(i)$表示第i个像素位置的不变区域掩码值。该损失使不变区域内的重建响应更加接近真实目标模态分布，同时降低变化区域对生成端训练过程的干扰。

1.4.4 特征一致性损失

异质图像虽然在成像机理和灰度分布上存在显著差异，但在未发生变化的区域，两种模态仍对应相同的地物目标。因此，在特征空间中，不变区域的源模态特征与目标模态特征应具有相对一致的表达。为此，本文将光学图像$\boldsymbol{X}$和单通道目标图像$\boldsymbol{Y}$输入共享编码器，分别得到编码特征图$\boldsymbol{F}_X$和$\boldsymbol{F}_Y$。对于第i个像素位置，首先计算二者在通道维度上的平均绝对特征差异

$$\Delta_i^F = \frac{1}{C} \sum_{c=1}^{C} |F_X^c(i) - F_Y^c(i)| \tag{22}$$

式中，表示特征通道数，$F_X^c(i)$和$F_Y^c(i)$分别表示源模态图像与目标模态图像在第i个位置、第C个通道上的编码特征响应。随后，在动态不变区域掩码的约束下，特征一致性损失定义为

$$L_{\mathrm{fc}} = \frac{\sum_{i=1}^{\mathbf{N}} M_{\mathrm{u}}(i) \Delta_i^F}{\sum_{i=1}^{\mathbf{N}} M_{\mathrm{u}}(i) + \varepsilon} \tag{23}$$

式中，ε为防止分母为零的极小常数。该损失约束不变区域内异质图像的深层特征表达，使共享编码网络在稳定地物区域中学习更加一致的跨模态表示。由于变化区域被$\boldsymbol{M}_{\mathrm{u}}$抑制，真实地物变化不会被强制拉近，从而避免网络将变化区域错误地对齐为不变区域。

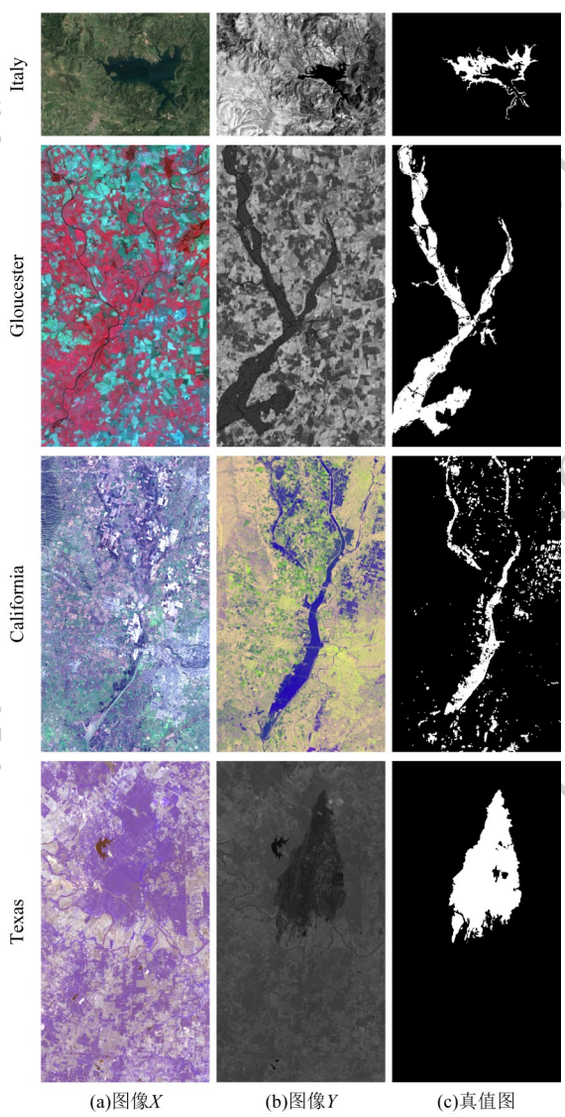
© 中国图象图形学报版权所有

2 实验结果与分析

2.1 实验数据

为测试所提出DNM-CMR变化检测方法的性能，本文在四组公开的异质遥感图像数据集进行实验测试，分别是Italy数据集（Sun等，2021b）、Gloucester数据集（Liu等，2022）、California数据集（Luppino等，2019）和Texas数据集（Volpi等，2015）。

这些数据集由不同传感器在不同时相获取，涵盖湖泊溢出、洪水和森林火灾等典型地表变化事件，具有较明显的模态差异、成像条件差异和空间结构变化。图3给出了这四组数据集的双时相图像和变化结果的真值图。



((a)image X;(b)image Y;(c)ground truth map)

图3 四组实验数据集

Fig. 3 Four experimental datasets

1)Italy数据集。来源于意大利撒丁岛区域，由1995年9月和1996年7月获取的双时相遥感图像组成。该数据集包含Landsat-5和Google Earth图像，图像尺寸为412×300，使用波段数为3/1，空间分辨率为30米。该区域的主要变化事件为湖泊扩张，变化区域在空间上呈现较明显的连续分布。

2)Gloucester数据集。记录了英国格洛斯特地区1999年10月至2000年10月期间的洪水变化情况。该数据集由SPOT图像和NDVI图像组成，图像尺寸为990×554，使用波段数为3/1，空间分辨率约为25米。该数据集中的变化区域主要由洪水淹没造成，表现为细长、不规则的空间分布形态。

3)California数据集。来源于美国加利福尼亚州地区，描述了2017年1月至2017年2月期间的洪水变化事件。该数据集由Landsat-8和Sentinel-1A图像组成，图像尺寸为875×500，使用波段数为11/1，空间分辨率约为15米。其变化区域主要由洪水淹没造成，空间分布不规则。

4)Texas数据集。来源于美国德克萨斯地区，描述了2011年8月至2011年9月期间的森林火灾变化。该数据集由Landsat-5和EO-1 ALI图像组成，图像尺寸为1 534×808，使用波段数为7/1，空间分辨率为30米。该数据集中的变化事件为森林火灾，变化区域具有较复杂的纹理和不规则边界。

2.2 实验设置和评价指标

本文实验在统一硬件和软件环境下完成，实验平台配置为：显卡为NVIDIA GeForce RTX 5070，显存容量为12GB。算法基于Python和PyTorch深度学习框架实现，训练和推理过程均在同一实验环境下完成。在网络结构设置方面，编码器由3层卷积编码单元组成，每个卷积单元依次包含卷积层、批归一化层、LeakyReLU激活函数和Dropout正则化操作。在DNM跨模态重建模块中，树突分支数量M设置为40。编码特征经局部窗口展开后输入DNM模块，局部窗口大小w_s设置为3。编码器和DNM模块的学习率均设置为1×10^{-4}，优化器采用Adam优化方法。训练轮数均设置为100，预训练轮数设置为20，在预训练阶段，网络主要通过重建损失和结构相似性损失学习基本跨模态映射关系；预训练阶段结束后，引入对抗损失、特征一致性损失和动态区域掩码，以进

© 中国图象图形学报版权所有

一步增强目标模态重建结果的真实性和不变区域特征一致性，动态区域掩码每20轮更新一次。损失函数权重设置为：重建损失权重为1，结构相似性损失权重λ_{ssim}为20，特征一致性损失权重λ_{fc}为0.2。对抗损失权重λ_{adv}为0.3。上述参数在四组实验数据集上保持一致。

为全面评价所提方法的变化检测性能，本文采用ROC（receiver operating characteristic）曲线下面积（area under the curve，AUC）、总体精度（overall accuracy，OA）、Kappa系数、F1分数（F1 score）、假正例（false positive，FP）和假负例（false negative，FN）作为定量评价指标。其中，ROC的曲线下面积AUC用于评价差异图在不同阈值条件下区分变化区域与未变化区域的整体能力；OA用于衡量整体检测精度；Kappa系数用于评价检测结果与参考真值之间的一致性（Cohen等，1960）；F1分数为精确率（precision）与召回率（recall）的调和均值，能够综合反映变化类别的检测准确性与完整性；FP表示未变化像素被误检为变化像素的数量；FN表示真实变化像素被漏检为未变化像素的数量。

2.3 消融分析

为验证不同损失约束及区域掩码策略对模型性能的影响，本文在保持编码器、DNM结构、训练轮数、优化器和后处理方式不变的条件下，设置五组消融实验。各模型的具体组成如下：模型1为基础重建模型，采用DNM作为跨模态重建模块，仅使用重建损失和结构相似性损失；模型2在模型1基础上加入对抗损失和特征一致性损失，但不引入区域掩码，即相关约束作用于整幅图像；模型3采用完整的4项损失，并引入静态不变区域掩码，掩码生成后在后续训练过程中保持固定；模型4即本文完整模型DNM-CMR，在模型3基础上将静态掩码替换为周期更新的动态区域掩码；模型5保持DNM-CMR的损失函数、动态掩码、编码器和训练策略不变，仅将DNM非线性重建模块替换为常规卷积解码器，用于分析DNM重建结构对跨模态映射性能的贡献。设损失1-4分别表示重建损失、结构相似性损失、对抗损失和特征一致性损失，具体每组设置如表1所示。

图4给出了这五组实验得到的变化图的视觉结果，表2为定量结果。根据结果，可以看出模型1仅采用重建损失和结构相似性损失，作为基础模型，该模型能够定位4组数据集中的主要变化区域，但背景抑制能力有限，在Italy和Gloucester数据集上比较明显，背景中检测出大量伪变化，模型1在4组数据集上的Kappa分别为0.552 4、0.442 0、0.473 9和0.890 8，表明像素重建与结构约束能够建立基本跨模态映射，但难以充分抑制由模态差异引起的背景响应。模型2在模型1的基础上加入对抗

表1 消融实验设置

Table 1 Ablation experiment settings

	损失1	损失2	损失3	损失4	掩码策略
模型1	√	√			无
模型2	√	√	√	√	无
模型3	√	√	√	√	静态掩码
DNM-CMR	√	√	√	√	动态掩码
模型5	替换DNM-CMR的DNM模块为卷积解码器				

损失和特征一致性损失，并将两项约束作用于整幅图像。视觉结果显示，部分背景误检有所减少，但变化区域出现不同程度的收缩，尤其是Italy数据集的湖泊边缘和Texas数据集的火烧区域内部产生了较明显漏检。定量上，模型2在Gloucester和California数据集上的Kappa有所提高，但在Italy和Texas数据集上分别下降至0.390 4和0.782 1。该结果反映出，全图一致性约束虽然能够改善部分未变化背景的映射，却会使真实变化像素也参与跨模态对齐，从而削弱应当保留的变化响应。模型3采用与模型2相同的损失设置，并通过静态掩码限制对抗损失和特征一致性损失的作用范围。加入区域筛选后，模型2中受到抑制的变化主体得到明显恢复，背景虚警也有所减少，Gloucester数据集的狭长结构和Texas数据集的大面积变化区域均表现出更好的完整性。其在4组数据集上的Kappa分别提高至0.741 0、0.752 9、0.488 5和0.944 9，均高于模型2，验证了不变区域筛选对减少真实变化像素干扰的作用。DNM-CMR在模型3的基础上将静态掩码替换为动态掩码。动态掩码根据当前重建误差和编码特征响应周期性更新，并通过平滑策略降低掩码波动。与模型3相比，DNM-CMR进一步减少了背景中的误检，主体变化区域的轮廓也更加稳定，DNM-CMR在4组数据集上的AUC、Kappa和OA均为各组模型中的最高值，说明静态掩码已经排除了大部分变化像素干扰，而动态更新能够进一步修正不变区

© 中国图象图形学报版权所有

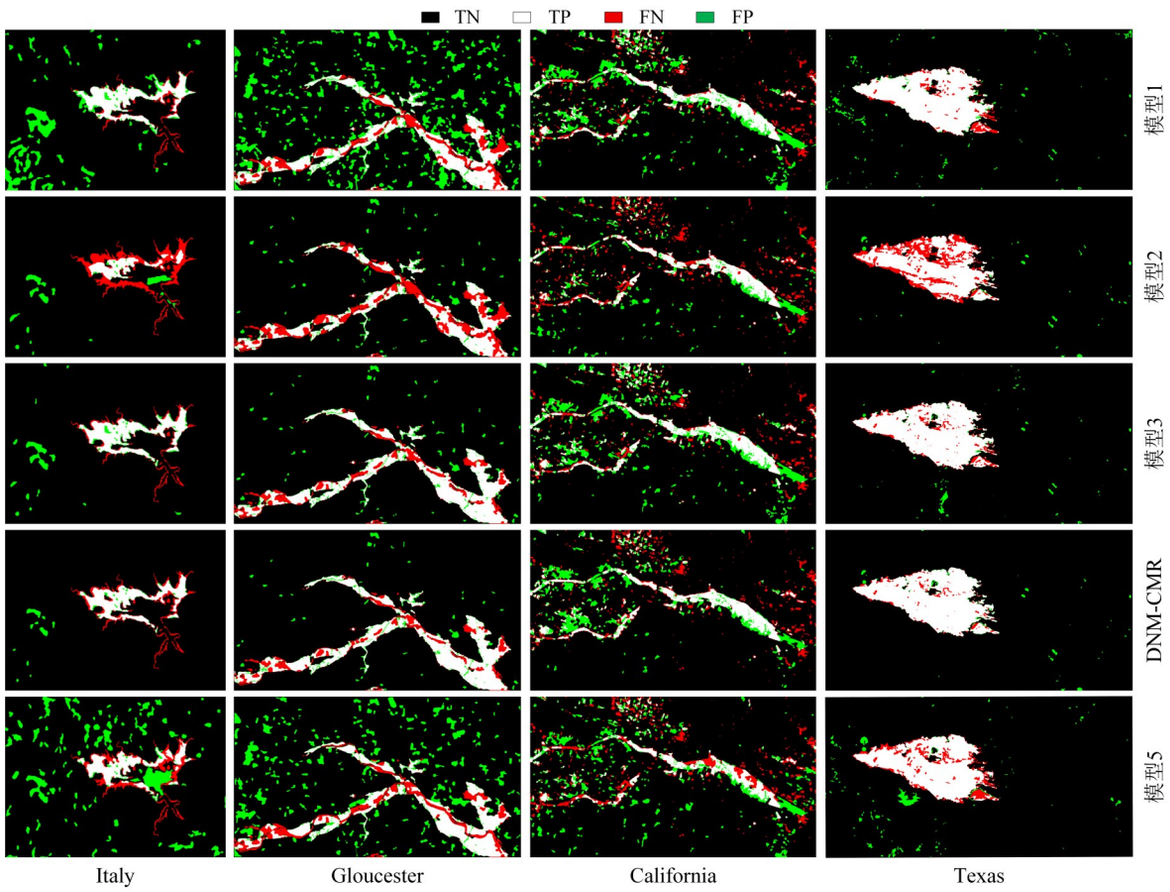


图4　五组实验在四个数据集上的可视化对比

Fig. 4　Visual comparison of the five experimental groups on the four datasets dataset((a)model one;(b)model two;(c)model three;(d)DNM-CMR;(e)model five)

域范围，使区域约束与模型当前的重建能力保持一致。模型5保留DNM-CMR中的完整损失函数和动态掩码，仅使用常规卷积解码器替代DNM，可视化结果表明，Italy、Gloucester和California数据集中的背景误检明显增加，部分变化边缘和细窄结构也出现缺失，在4组数据集上的Kappa分别降至0.356 8、0.507 5、0.371 7和0.838 4，AUC和OA也均低于DNM-CMR，由于两组实验的损失函数、区域掩码和训练策略保持一致，性能差异主要来自重建模块。常规卷积解码器能够完成基本目标模态映射，但对复杂局部特征交互关系的描述相对有限；DNM利用多树突分支和乘性聚合建模特征分量之间的高阶关系，因此在背景伪变化抑制和变化结构保持方面表现出更好的适应性。

综合来看，对抗损失和特征一致性损失可以抑制大量伪变化的产生，但只有在可靠区域约束下才能发挥积极作用，直接将其施加于全图会抑制真实变化响应。静态掩码能够显著缓解这一问题，而动态掩码通过持续更新可靠不变区域，进一步提高了差异图可分性和最终检测结果的一致性。除此以外，模型5的结果验证了DNM重建模块并非可以由普通卷积解码器等效替代，其非线性多分支结构是提升跨模态重建和变化检测性能的重要因素。

2.3.1　动态区域掩码演化分析

为进一步验证动态区域掩码估计的准确性及其更新机制的有效性，本文分别在Italy、Gloucester、California和Texas四组数据集上分析不同训练阶段生成的不变区域掩码与参考不变区域之间的空间一致性。由于动态掩码采用指数滑动平均进行更新，其数值表示像素属于不变区域的连续置信度，而非严格的二值分类结果，因此采用软交并比(soft intersection over union，Soft IoU)评价动态不变区域掩码与参考不变区域之间的重合程度。参考真值仅用于训练过程的事后定量分析，并未参与掩码生成及网

© 中国图象图形学报版权所有

络参数优化，因此不改变本文方法的无监督性质。

图5给出了四组数据集在第20、40、60和80轮训练时动态不变区域掩码的Soft IoU变化曲线。可以看出，随着训练进行，四组数据集上的Soft IoU均呈持续上升趋势。Italy数据集由第20轮的0.548 9提高至第80轮的0.732 4；Gloucester数据集由0.630 6提高至0.782 1；California数据集由0.586 4提高至0.808 7；Texas数据集的提升最为明显，由0.407 2提高至0.937 2。不同数据集的Soft IoU增长幅度存在一定差异，说明动态掩码的收敛过程会受到场景复杂度、模态差异及变化区域空间分布等因素影响。

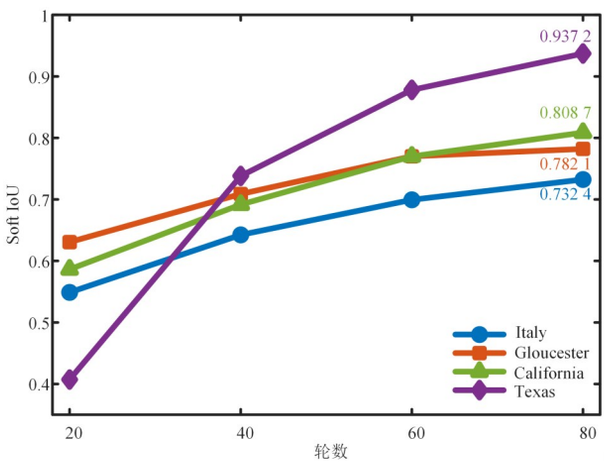


图5　四组数据集不同训练轮数下动态不变区域掩码的Soft IoU变化曲线

Fig. 5　Soft IoU curves of dynamic unchanged-region masks on four datasets at different training epochs

但四组数据集均表现出随训练轮数增加而逐步提高的共同趋势，表明随着跨模态重建关系逐渐稳定，动态区域掩码能够根据当前网络状态持续修正不变区域估计，使其与真实地物状态之间的空间一致性不断增强，从而验证了动态区域掩码更新机制的有效性。

2.4　对比实验分析

为验证本文所提出的方法在无监督异质遥感图像变化检测任务中的有效性，选取5种具有代表性的无监督异质变化检测方法进行对比，分别为SRGCAE、SCASC、RIEM、CDRL和CFRL。其中，SRGCAE通过结构关系图卷积自编码器学习异质图像中的模态无关结构关系，并利用结构关系差异提取变化信息（Chen等，2022）。SCASC基于稀疏约束

表2　五组实验在四个数据集上的定量比较

Table 2　Quantitative comparison of the five experimental groups on the four datasets

	Italy			Gloucester			California			Texas		
	AUC	Kappa	OA	AUC	Kappa	OA	AUC	Kappa	OA	AUC	Kappa	OA
模型1	0.939 2	0.552 4	0.931 2	0.859 4	0.442 0	0.853 0	0.894 1	0.473 9	0.905 4	0.984 7	0.890 8	0.979 3
模型2	0.782 0	0.390 4	0.944 5	0.890 9	0.623 7	0.930 7	0.860 0	0.481 5	0.924 1	0.989 4	0.782 1	0.963 4
模型3	0.947 9	0.741 0	0.969 4	0.952 5	0.752 9	0.950 4	0.897 9	0.488 5	0.909 2	0.992 6	0.940 7	0.984 7
DNM-CMR	**0.955 3**	**0.756 2**	**0.973 4**	**0.978 1**	**0.786 9**	**0.957 1**	**0.900 9**	**0.503 8**	**0.924 5**	**0.993 3**	**0.941 6**	**0.989 0**
模型5	0.866 8	0.356 8	0.897 2	0.818 8	0.507 5	0.881 0	0.824 3	0.371 7	0.897 4	0.979 8	0.838 4	0.970 2

注：加粗字体为每列最优值。

© 中国图象图形学报版权所有

自适应结构一致性进行无监督图像回归，通过保持源图像的结构信息并将其映射到目标图像域，从而实现异质图像变化检测(Sun等，2022a)。RIEM的核心思想是在不直接比较两时相异质图像的情况下，通过规则诱导方式构建变化判别依据，从而降低不同传感器成像差异对变化检测结果的影响(Sun等，2025)。CDRL通过跨域差异表示学习构建风格无关、内容可比较的特征空间，并结合变化检测网络学习变化与未变化区域的差异表达(Zhan等，2025)。CFRL通过共同性特征表示学习挖掘多模态图像之间的潜在共有特征，并利用共有特征差异生成变化强度图(Liu等，2025)。为保证实验对比的公平性，各对比算法均采用其原文或公开代码中的推荐参数设置，并在相同实验数据集和参考真值图上进行定量与定性评价。

2.4.1 Italy数据集

图6给出了各个方法在Italy数据集上的变化检测结果。该数据集的变化主要表现为湖泊溢出造成的水体扩张，变化区域整体连通性较强，但主体轮廓不规则，边缘处存在细窄分支和不规则轮廓。

从图6的变化图对比反映出各方法在背景抑制方面存在明显差异。SRGCAE虽然覆盖了大部分真实变化区域，但未变化背景中出现了大范围密集误检，部分伪变化与湖泊主体相连，降低了变化区域的可辨识性。CDRL同样受到异质模态差异的影响，

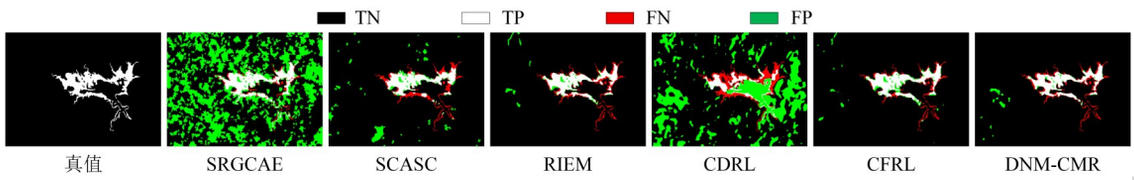


图6 Italy数据集上的变化图视觉比较

Fig. 6 Visual comparison of change maps on the Italy dataset

表3 Italy数据集上的定量比较

Table 3 Quantitative comparison on the Italy dataset

方法	AUC	Kappa	OA	F1	FP	FN
SRGCAE	0.843 8	0.136 3	0.653 0	0.228 2	74 368	**1 284**
SCASC	0.889 5	0.607 4	0.953 0	0.632 4	3 177	2 630
RIEM	0.917 1	0.730 1	0.971 1	0.745 3	**1 159**	2 408
CDRL	0.634 3	0.087 7	0.761 5	0.176 3	25 009	4 472
CFRL	0.954 2	0.750 7	0.971 8	0.765 7	1 555	1 931
DNM-CMR	**0.955 3**	**0.756 2**	**0.973 4**	**0.770 2**	1 181	2 110

注：加粗字体为每列最优

背景中形成较多块状误检。SCASC有效减少了大面积噪声，但左下部村落区域仍被错误识别为变化区域，同时湖泊边缘和细长分支存在不同程度的缺失。RIEM的背景较为干净，但主体周围出现连续漏检，检测轮廓表现出一定的收缩倾向。CFRL和DNM-CMR的结果与参考真值较为接近，其中DNM-CMR对主体内部、边缘轮廓及部分细窄结构的恢复更加完整，其余的漏检区域主要集中在下部的湖泊边界。

从表3可以看出，DNM-CMR在Kappa、OA和F1

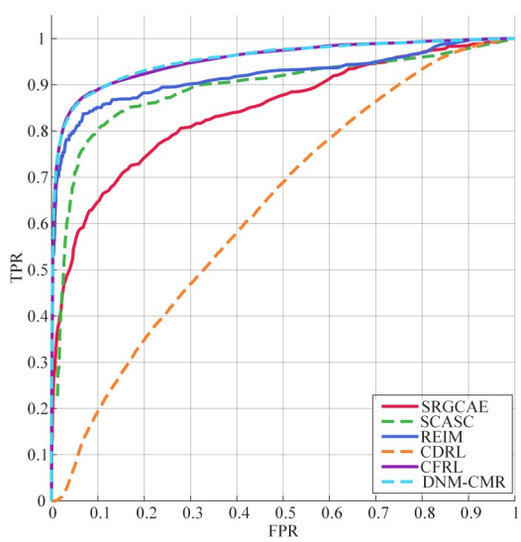


图7 Italy数据集上获得的ROC曲线对比

Fig. 7 ROC curve comparison on the Italy dataset

上分别达到0.756 2、0.973 4和0.770 2，均为所有方法中的最高值，说明其不仅获得了较高的总体精度，也在变化类与非变化类之间保持了更合理的判别平衡。其FP为1 181，仅略高于RIEM的1 159，明显低于其余对比方法，说明其在抑制背景伪变化方面具有较为稳定的表现，此外DNM-CMR的误检像

© 中国图象图形学报版权所有

素总数(FP+FN)比其他5种方法都要少,表明该方法并非单纯通过降低某一类错误获得较高精度,而是在误检与漏检之间实现了更合理的权衡,这也与其取得最高Kappa值的结果相一致。这6种方法的差异图的ROC曲线如图7所示,DNM-CMR与CFRL在多数阈值范围内均位于其他方法上方AUC分别为0.955 3和0.954 2,二者整体判别能力接近。综上所述,该方法在Italy数据集上的主要改进是减弱复杂背景和跨模态差异引起的伪变化,同时保持变化区域的主体结构;其不足则集中在细小分支和边缘区域的漏检。

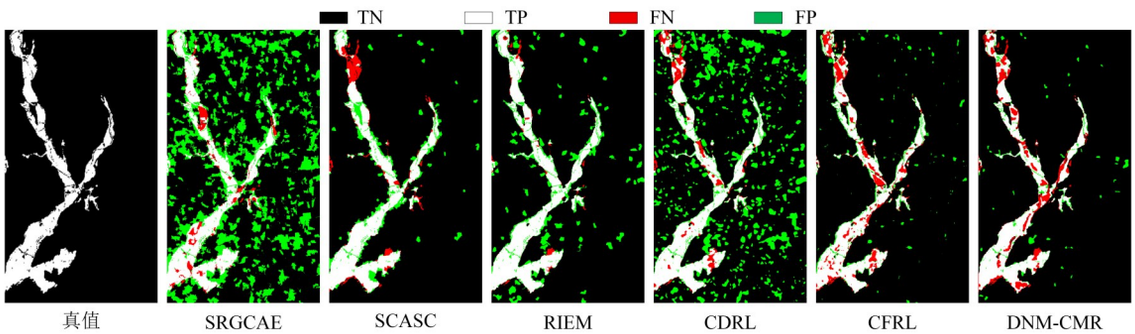


图8 Gloucester数据集上的变化图视觉比较

Fig. 8 Visual comparison of change maps on the Gloucester dataset

表4 Gloucester数据集上的定量比较

Table 4 Quantitative comparison on the Gloucester dataset

方法	AUC	Kappa	OA	F1	FP	FN
SRGCAE	0.865 7	0.353 0	0.751 9	0.466 1	360 868	**8 413**
SCASC	0.934 2	0.762 1	0.946 7	0.792 5	19 627	9 601
RIEM	**0.981 5**	0.756 2	0.939 8	0.790 2	29 784	3 239
CDRL	0.914 9	0.504 6	0.854 1	0.584 1	70 706	9 260
CFRL	0.976 5	0.766 3	0.951 4	0.793 8	12 528	14 122
DNM-CMR	0.978 1	**0.786 9**	**0.957 1**	**0.811 0**	**8 528**	14 984

注:加粗字体为每列最优值。

2.4.2 Gloucester数据集

该数据集主要记录洪水淹没造成的地表变化,变化区域主要呈狭长带状分布,主体结构纵向贯穿图像,并包含多处宽度变化、局部分叉和不规则边界。与大面积块状变化相比,此类细长变化目标对空间连续性和边缘定位提出了更高要求,算法既需要保持主体区域的整体连通性,又要避免将周围复杂背景及异质影像间的表征差异误判为真实变化。

从图8中错误区域的空间分布可以看出,SRGCAE和CDRL两种方法均在洪水主体周围产生大量绿色伪变化,其中部分误检与真实变化区域相互连接,弱化了狭长变化区域目标的边界。SCASC基本保持了洪水主干的连续性,但在上部边缘、交叉位置和细小分支处仍有红色漏检。RIEM能够较好恢复主体结构,并明显减少背景噪声,但上部边界和中部狭窄区域仍存在局部断裂。CFRL进一步降低了背景干扰,其变化轮廓较为平滑,但部分细线结构因响应不足而发生收缩。DNM-CMR获得了较为干净的背景,较好保持了洪水区域的细长形态,尤其是在中部交叉结构和下部扩展区域具有较好的

轮廓一致性。不过,其在图像上部及部分低对比度边缘仍存在一定漏检,说明该方法对弱边界和窄小结构的恢复仍不充分。图9的ROC曲线显示,RIEM取得最高AUC,为0.981 5,DNM-CMR和CFRL分别为0.978 1和0.976 5,三者在多数阈值范围内均保持较高的真正例率(true positive rate,

© 中国图象图形学报版权所有

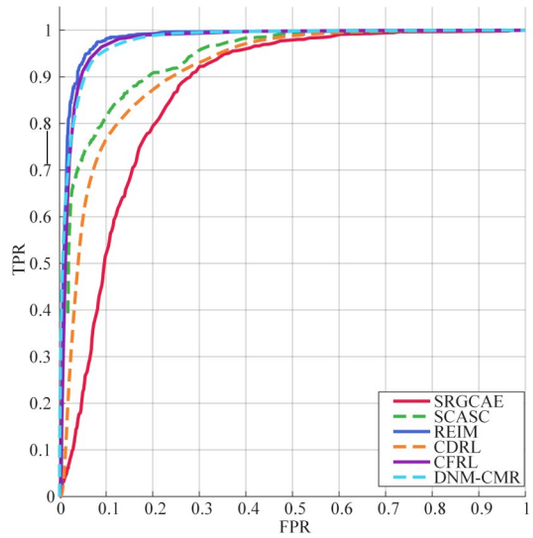


图9　Gloucester数据集上获得的ROC曲线比较

Fig. 9　ROC curve comparison on theGloucester dataset

TPR)。从表4中可以看出，DNM-CMR在该数据集的Kappa、OA和F1指标上分别达到0.786 9、0.957 1和0.811 0，均取得所有方法中的最高值。FP仅为8 528，为所有方法中的最低值，明显低于RIEM的29 784、CFRL的12 528以及其他对比方法，说明该方法在整体分类精度以及变化区域与背景区域之间的判别方面具有优势，能够有效抑制背景伪变化总体来看，DNM-CMR在Gloucester数据集上的主要优势是有效抑制复杂背景中的伪变化，并保持狭长变化区域的主体连通结构，其不足主要表现为对上部边缘、细窄分支仍存在一定漏检。

2.4.3　California数据集

图10给出了各方法在California数据集上的变化检测结果。该数据集中的变化主要由洪水淹没引起，真实变化区域沿河道及其周边呈不规则带状和斑块状分布，既包含连续的大范围变化，也包含数量较多的离散小区域。因此，该数据集不仅要求算法保持主要变化区域的连通性，还要求其识别零散变化斑块，并抑制复杂地表背景引起的误检。

从变化图的可视化结果看，SRGCAE能够覆盖部分主要变化区域，但在图像背景中产生了大面积、密集分布的绿色误检，尤其是在主体变化区域周围及图像右侧表现突出，导致真实变化结构被大量伪响应干扰。CDRL同样存在较明显的背景误检，但相较SRGCAE有所减弱，其结果中仍可观察到较多

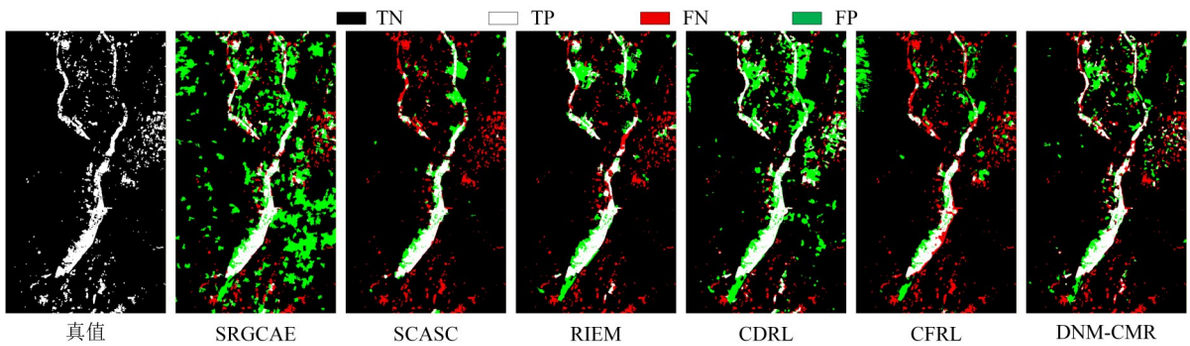


图10　California数据集上的变化图视觉比较

Fig. 10　Visual comparison of change maps on the California dataset

表5　California数据集上的定量比较

Table 5　Quantitative comparison on the California dataset

方法	AUC	Kappa	OA	F1	FP	FN
SRGCAE	0.766 9	0.262 4	0.815 4	0.349 3	335 070	14 858
SCASC	0.867 9	0.486 0	**0.930 7**	0.522 4	**10 362**	19 952
RIEM	0.901 0	0.498 3	0.925 0	0.539 1	15 469	17 345
CDRL	**0.906 6**	0.470 4	0.892 0	0.526 4	36 944	**10 283**
CFRL	0.818 5	0.358 2	0.909 9	0.406 4	16 380	23 038
DNM-CMR	0.900 9	**0.503 8**	0.924 5	**0.545 0**	16 746	16 292

注：加粗字体为每列最优值

© 中国图象图形学报版权所有

块状绿色区域，同时对部分真实变化区域的覆盖相对充分。SCASC显著减少了大范围背景噪声，但在部分狭窄边界和离散变化区域出现漏检。RIEM的背景较为干净，能够较好恢复主要变化结构，但部分零散变化斑块和边界未被完整识别。CFRL虽然抑制了多数背景响应，但红色漏检分布较广，尤其在图像上部、右侧及主体边缘较为明显。相比之下，DNM-CMR在保持主要带状变化区域的同时，背景中的大范围误检得到较好控制，整体空间分布与真值较为接近。不过，图像上部及右侧的部分离散斑块仍存在漏检，表明其对零散小目标变化区域的识别仍不充分。表5中的定量结果显示，DNM-CMR的Kappa和F1分别达到0.503 8和0.545 0，均为所有方法中的最高值，说明其对变化类的综合识别以

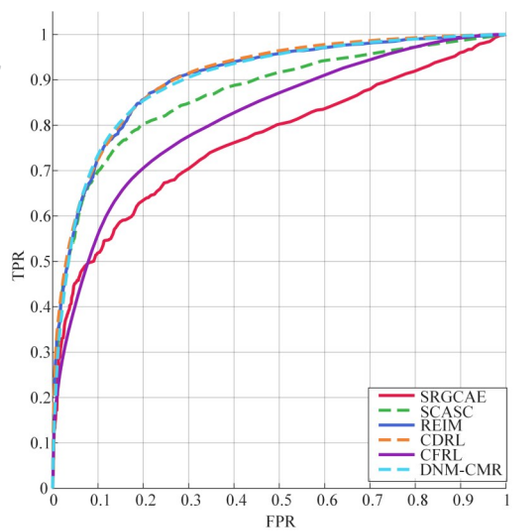


图11　California数据集上获得的ROC曲线比较

Fig. 11　ROC curve comparison on the California dataset

及两类像素之间的一致性相对较好。其FP为16 746，明显低于SRGCAE的335 070和CDRL的36 944，但高于SCASC的10 362和RIEM的15 469，FN为16 292，低于SCASC、RIEM和CFRL，但高于CDRL的10 283。因此，DNM-CMR的优势并非来源于单独取得最低FP或FN，而是在两类错误检测之间形成了相对合理的平衡，从而获得最高的F1和Kappa。图11的ROC曲线显示，CDRL取得最高AUC值0.906 6，RIEM和DNM-CMR分别为0.901 0和0.900 9，三者整体判别能力较为接近。DNM-CMR并未在全阈值范围内取得最优结果，其优势主要体现在获得了更高的Kappa和F1，而CDRL虽然具有更高的AUC和更低的FN，但却伴随更多背景误检。

结合以上分析，DNM-CMR在California数据集上较好地平衡了背景伪变化与真实变化区域，但该方法的OA为0.924 5，低于SCASC的0.930 7，从空间分布看，误差主要集中在图像上部、右侧离散变化斑块以及部分弱边界区域。这表明，当真实变化目标尺度较小、空间分布较分散，或变化响应与周围背景差异较弱时，当前基于固定局部邻域的跨模态重建可能出现特征表达不足。

2.4.4　Texas数据集

Texas数据集的变化由森林火灾引起，火烧区域面积较大且整体连通，但边界不规则，内部还包含未充分变化或低响应区域。与此同时，图像尺寸较大，未变化背景占据较高比例，因此算法既要保持火烧区域的主体轮廓，也要避免将背景中的跨传感器辐射差异和纹理波动误判为变化。

图12给出了各方法在Texas数据集上的变化检测结果。从变化图的可视化结果看，SRGCAE虽然识别出了主体变化区域，但火烧区域内部存在明显漏检，同时背景中产生了密集且范围较广的绿色误检。CDRL同样产生了大量背景误检，且绿色伪变化与真实变化主体相互连接，严重误检了变化区域的空间轮廓。SCASC显著减少了背景中的大面积误检，能够基本恢复变化主体的整体形态，但在火烧区域内部、顶部边界仍存在较多红色漏检。RIEM的变化区域覆盖较为充分，主体内部的白色真阳性区域明显增加，但其主体边缘和下部背景中仍残留一定绿色误检。CFRL的检测结果整体较为干净，背景误检较少，且主体轮廓与真值具有较高一致性，但变化区域内部及部分边界存在较连续的红色漏检。相比之下，DNM-CMR较好地恢复了主体变化区域及其内部结构，同时将背景误检控制在较低水平，尤其在主体边缘和底部细窄区域表现出较好的综合效果。不过，其顶部局部边界和内部少量区域仍存在漏检。

表6给出了各方法的定量比较结果。DNM-CMR

在Kappa、OA和F1的指标分别为0.941 6、0.989 0和0.947 8，均为所有方法中的最高值，说明其在整体分类准确性、类别一致性以及变化类识别方面取得了最优的综合表现。其FP为5 220，为所有方法中的最低值，DNM-CMR通过局部非线性重建学习不同传感器间的稳定映射关系，并利用动态

© 中国图象图形学报版权所有

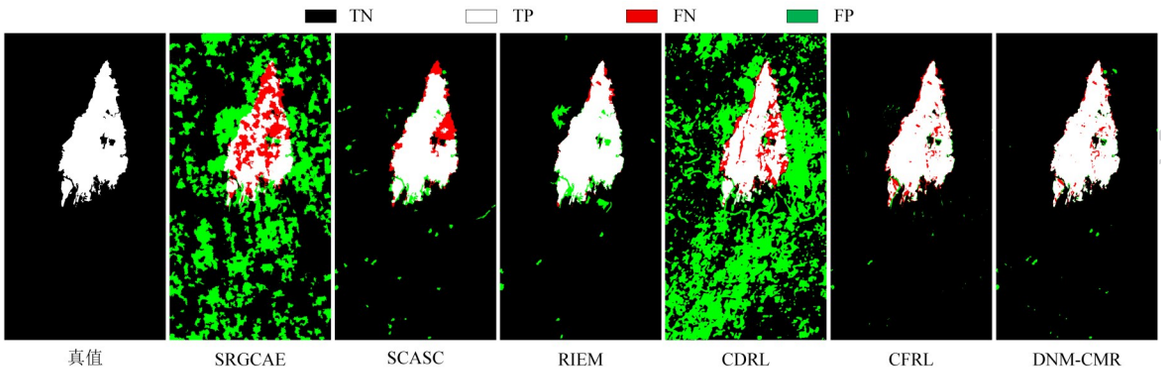


图 12　Texas 数据集上的变化图视觉比较

Fig. 12　Visual comparison of change maps on the Texas dataset

表 6　Texas 数据集上的定量比较

Table 6　Quantitative comparison on the Texas dataset

方法	AUC	Kappa	OA	F1	FP	FN
SRGCAE	0.695 4	0.158 2	0.689 2	0.294 2	772 474	51 733
SCASC	0.984 8	0.848 1	0.971 6	0.863 9	14 606	20 482
RIEM	0.994 1	0.905 4	0.981 1	0.916 0	19 046	**4 334**
CDRL	0.772 8	0.169 9	0.627 8	0.312 0	43 298	27 446
CFRL	**0.996 5**	0.918 7	0.984 9	0.927 1	5 232	13 410
DNM-CMR	0.993 3	**0.941 6**	**0.989 0**	**0.947 8**	**5 220**	8 389

注：加粗字体为每列最优值。

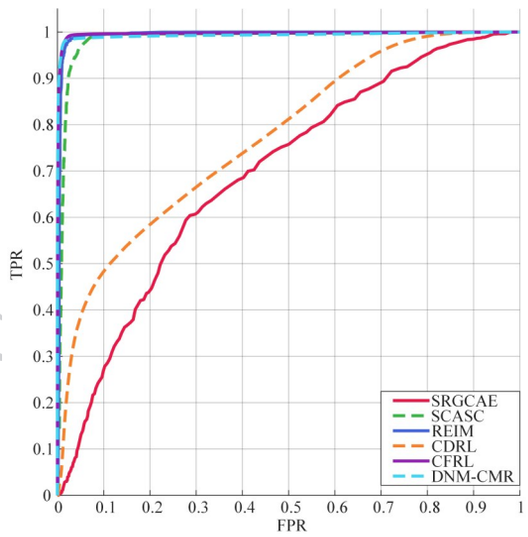


图 13　Texas 数据集上获得的 ROC 曲线比较

Fig. 13　ROC curve comparison on the Texas dataset

不变区域约束降低背景辐射差异的影响，因此能够显著减少误检。DNM-CMR 在 Texas 数据集上检测的总错误像素数为 13 609，低于 CFRL 的 18 642 和 RIEM 的 23 380，说明其在误检和漏检之间取得了更合理的平衡。图 13 的 ROC 曲线显示，CFRL 取得最高 AUC，为 0.996 5，RIEM 和 DNM-CMR 分别为 0.994 1 和 0.993 3，说明其连续差异图均具有较强可分性，整体判别能力较为接近。

通过在数据集上的对比结果可知，DNM-CMR 在 Texas 数据集上的主要优势是能够在抑制复杂背景伪变化的同时，较完整地恢复大面积不规则变化主体及其局部细节；其不足主要体现在部分弱边界和内部低响应区域仍存在少量漏检。

3　结　论

本文围绕异质遥感图像难以直接比较以及真实变化区域易干扰跨模态学习的问题，提出了基于树突神经元模型的跨模态重建网络 DNM-CMR。该方法不直接比较双时相异质图像，而是利用 DNM 对局部编码特征进行多分支非线性组合，建立源模态到目标模态的重建关系，并由目标模态空间中的重建偏差表征地物变化。在此基础上，通过重建偏差和

© 中国图象图形学报版权所有

编码特征响应动态估计不变区域，使对抗约束和特征一致性约束集中作用于相对可靠的像素，从而避免将真实变化错误地纳入模态对齐过程。该设计为无标签条件下同时处理模态差异和变化像素干扰提供了一种可行思路。提出算法DNM-CMR在四组数据集上均获得了较好的性能，说明在连续水体扩张、狭长洪水区域、离散变化斑块以及大面积森林火灾等不同场景中，能够较好地抑制背景伪变化，并在误检与漏检之间保持较为合理的平衡。

尽管提出方法在多数异质遥感图像变化检测任务中表现出色，但在极端模态差异的场景下动态掩码对重建结果存在一定的依赖关系，对于尺度较小、空间分布离散或边界响应较弱的变化目标，当前方法的检测能力受到一定限制，检测精度仍有提升空间。本文实验数据主要覆盖光学跨传感器及光学-SAR等异质组合，尚未进一步验证高维异质模态，后续工作将针对多异质传感器组合进行模型改进，扩展并验证算法的适用范围。此外，单向重建尚未充分利用双时相图像之间的互补关系。后续可从多尺度自适应邻域、基于不确定性的软掩码更新以及双向重建约束等方面展开研究，以进一步提高复杂场景下区域估计的可靠性和细粒度变化的检测能力。

参考文献(References)

Chen H R, Yokoya N, Wu C and Du B. 2022. Unsupervised multimodal change detection based on structural relationship graph representation learning. IEEE Transactions on Geoscience and Remote Sensing, 60: #5635318 [DOI: 10.1109/TGRS.2022.3229027]

Cohen J. 1960. A coefficient of agreement for nominal scales. Educational and Psychological Measurement, 20(1): 37-46 [DOI: 10.1177/001316446002000104]

Gong M G, Zhang P, Su L and Liu J. 2016. Coupled dictionary learning for change detection from multisource data. IEEE Transactions on Geoscience and Remote Sensing, 54(12): 7077-7091 [DOI: 10.1109/TGRS.2016.2594952]

Jia M, Zhao Q and Lu X F. 2024. Bipartite adversarial autoencoder network for unsupervised detection of changes in heterogeneous remote sensing images. Journal of Image and Graphics, 29(8): 2188-2204 (贾萌, 赵秦, 鲁晓锋. 2024. 双边对抗自编码网络的无监督异质遥感图像变化检测. 中国图象图形学报, 29(8): 2188-2204) [DOI: 10.11834/jig.230497]

Jia M, Lou X Y, Zhao Z Q and Lu X F. 2025. Dendritic computing with differential evolution for unsupervised synthetic aperture radar image change detection. International Journal of Remote Sensing, 46(14): 5280-5302 [DOI: 10.1080/01431161.2025.2516691]

Li X H, Du Z S, Huang Y Y and Tan Z Y. 2021. A deep translation (GAN) based change detection network for optical and SAR remote sensing images. ISPRS Journal of Photogrammetry and Remote Sensing, 179: 14-34 [DOI: 10.1016/j.isprsjprs.2021.07.007]

Liu J, Gong M G, Qin K and Zhang P Z. 2018a. A deep convolutional coupling network for change detection based on heterogeneous optical and radar images. IEEE Transactions on Neural Networks and Learning Systems, 29(3): 545-559 [DOI: 10.1109/TNNLS.2016.2636227]

Liu T F, Zhang M Y, Gong M G, Zhang Q F, Jiang F L, Zheng H H, et al. 2025. Commonality feature representation learning for unsupervised multimodal change detection. IEEE Transactions on Image Processing, 34: 1219-1233 [DOI: 10.1109/TIP.2025.3539461]

Liu Z G, Li G, Mercier G, He Y and Pan Q. 2018b. Change detection in heterogenous remote sensing images via homogeneous pixel transformation. IEEE Transactions on Image Processing, 27(4): 1822-1834 [DOI: 10.1109/TIP.2017.2784560]

Liu Z G, Zhang Z W, Pan Q and Ning L B. 2022. Unsupervised change detection from heterogeneous data based on image translation. IEEE Transactions on Geoscience and Remote Sensing, 60: #4403413 [DOI: 10.1109/TGRS.2021.3097717]

Luppino L T, Bianchi F M, Moser G and Anfinsen S N. 2019. Unsupervised image regression for heterogeneous change detection. IEEE Transactions on Geoscience and Remote Sensing, 57(12): 9960-9975 [DOI: 10.1109/TGRS.2019.2930348]

Luppino L T, Kampffmeyer M, Bianchi F M, Moser G, Serpico S B, Jenssen R, et al. 2022. Deep image translation with an affinity-based change prior for unsupervised multimodal change detection. IEEE Transactions on Geoscience and Remote Sensing, 60: #4700422 [DOI: 10.1109/TGRS.2021.3056196]

Luppino L T, Hansen M A, Kampffmeyer M, Bianchi F M, Moser G, Jenssen R, et al. 2024. Code-aligned autoencoders for unsupervised change detection in multimodal remote sensing images. IEEE Transactions on Neural Networks and Learning Systems, 35(1): 60-72 [DOI: 10.1109/TNNLS.2022.3172183]

Lyu Z Y, Huang H T, Li X H, Zhao M H, Benediktsson J A, Sun W W, et al. 2022. Land cover change detection with heterogeneous remote sensing images: review, progress, and perspective. Proceedings of the IEEE, 110(12): 1976-1991 [DOI: 10.1109/JPROC.2022.3219376]

Mercier G, Moser G and Serpico S B. 2008. Conditional copulas for change detection in heterogeneous remote sensing images. IEEE Transactions on Geoscience and Remote Sensing, 46(5): 1428-1441 [DOI: 10.1109/TGRS.2008.916476]

Niu X D, Gong M G, Zhan T and Yang Y L. 2019. A conditional adversarial network for change detection in heterogeneous images. IEEE

© 中国图象图形学报版权所有

Geoscience and Remote Sensing Letters, 16(1): 45-49 [DOI: 10.1109/LGRS.2018.2868704]

Radke R J, Andra S, Al-Kofahi O and Roysam B. 2005. Image change detection algorithms: a systematic survey. IEEE Transactions on Image Processing, 14(3): 294-307 [DOI: 10.1109/TIP.2004.838698]

Sun Y L, Lei L, Guan D D and Kuang G Y. 2021a. Iterative robust graph for unsupervised change detection of heterogeneous remote sensing images. IEEE Transactions on Image Processing, 30: 6277-6291 [DOI: 10.1109/TIP.2021.3093766]

Sun Y L, Lei L, Li X, Sun H and Kuang G Y. 2021b. Nonlocal patch similarity based heterogeneous remote sensing change detection. Pattern Recognition, 109: #107598 [DOI: 10.1016/j.patcog.2020.107598]

Sun Y L, Lei L, Li X, Tan X and Kuang G Y. 2021c. Patch similarity graph matrix-based unsupervised remote sensing change detection with homogeneous and heterogeneous sensors. IEEE Transactions on Geoscience and Remote Sensing, 59(6): 4841-4861 [DOI: 10.1109/TGRS.2020.3013673]

Sun Y L, Lei L, Guan D D, Li M and Kuang G Y. 2022a. Sparse-constrained adaptive structure consistency-based unsupervised image regression for heterogeneous remote-sensing change detection. IEEE Transactions on Geoscience and Remote Sensing, 60: #4405814 [DOI: 10.1109/TGRS.2021.3110998]

Sun Y L, Lei L, Li X, Tan X and Kuang G Y. 2022b. Structure consistency-based graph for unsupervised change detection with homogeneous and heterogeneous remote sensing images. IEEE Transactions on Geoscience and Remote Sensing, 60: #4700221 [DOI: 10.1109/TGRS.2021.3053571]

Sun Y L, Lei L, Li Z, Kuang G Y and Yu Q F. 2025. Detecting changes without comparing images: rules induced change detection in heterogeneous remote sensing images. ISPRS Journal of Photogrammetry and Remote Sensing, 230: 241-257 [DOI: 10.1016/j.isprsjprs.2025.09.009]

Tang Y Q, Yang X, Han T, Zhang F Y, Zou B and Feng H H. 2024. Enhanced graph structure representation for unsupervised heterogeneous change detection. Remote Sensing, 16(4): #721 [DOI: 10.3390/rs16040721]

Todo Y, Tang Z, Todo H, Ji J and Yamashita K. 2019. Neurons with multiplicative interactions of nonlinear synapses. International Journal of Neural Systems, 29(8): #1950012 [DOI: 10.1142/S0129065719500126]

Volpi M, Camps-Valls G and Tuia D. 2015. Spectral alignment of multi-temporal cross-sensor images with automated kernel canonical correlation analysis. ISPRS Journal of Photogrammetry and Remote Sensing, 107: 50-63 [DOI: 10.1016/j.isprsjprs.2015.02.005]

Wang X, Li Y Y and Zhang X L. 2024. Ghost-guided UNet++ for high-resolution remote sensing image change detection. Journal of Image and Graphics, 29(5): 1460-1478 (王鑫, 李莹莹, 张香梁. 2024. Ghost引导UNet++的高分遥感影像变化检测. 中国图象图形学报, 29(5): 1460-1478) [DOI: 10.11834/jig.230212]

Wu Y, Li J, Yuan Y, Qin A K, Miao Q G and Gong M G. 2022. Commonality autoencoder: learning common features for change detection from heterogeneous images. IEEE Transactions on Neural Networks and Learning Systems, 33(9): 4257-4270 [DOI: 10.1109/TNNLS.2021.3056238]

Zhan T, Lan J, Zhu Y Y, Dang Q L and Gong M G. 2025. Cross-domain difference representation learning for unsupervised heterogeneous change detection. IEEE Transactions on Geoscience and Remote Sensing, 63: #5630217 [DOI: 10.1109/TGRS.2025.3584073]

Zhao W, Wang Z, Gong M and Liu J. 2017. Discriminative feature learning for unsupervised change detection in heterogeneous images based on a coupled neural network. IEEE Transactions on Geoscience and Remote Sensing, 55(12): 7066-7080 [DOI: 10.1109/TGRS.2017.2739800]

作者简介

贾萌，女，副教授，主要研究方向为遥感影像理解与解译、模式识别和深度学习。E-mail：jiameng112@163.com

王鹏程，男，硕士研究生，主要研究方向为遥感图像变化检测。E-mail：wpchaize5168@163.com

邱原，男，讲师，主要研究方向为遥感图像变化检测、模式识别和深度学习。E-mail：Qiuyuan@xaut.edu.cn

石争浩，男，教授，主要研究方向为图像处理、计算机视觉和人工智能。E-mail：ylshi@xaut.edu.cn

吕志勇，男，教授，主要研究方向为多模态遥感影像处理与变化监测应用。E-mail：zhiyongLyu@xaut.edu.cn

© 中国图象图形学报版权所有