

基于双空间共轭自编码器的多时相高光谱异常变化检测

李沙沙, 邢红杰, 李刚

引用本文

李沙沙, 邢红杰, 李刚. 基于双空间共轭自编码器的多时相高光谱异常变化检测[J]. 计算机科学, 2023, 50(12): 175-184.

LI Shasha, XING Hongjie, LI Gang. [Multi-temporal Hyperspectral Anomaly Change Detection Based on Dual Space Conjugate Autoencoder](#) [J]. Computer Science, 2023, 50(12): 175-184.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[联合ZINB模型与图注意力自编码器的自优化单细胞聚类](#)

Self-optimized Single Cell Clustering Using ZINB Model and Graph Attention Autoencoder
计算机科学, 2023, 50(12): 104-112. <https://doi.org/10.11896/jsjcx.221000167>

[使用RAP生成可传输的对抗网络流量](#)

Generate Transferable Adversarial Network Traffic Using Reversible Adversarial Padding
计算机科学, 2023, 50(12): 359-367. <https://doi.org/10.11896/jsjcx.221000155>

[基于迭代非对称盲点网络的低剂量CT重建算法](#)

Low-dose CT Reconstruction Algorithm Based on Iterative Asymmetric Blind Spot Network
计算机科学, 2023, 50(12): 221-228. <https://doi.org/10.11896/jsjcx.230300014>

[面向工业图像异常检测的连续密集标准化流模型](#)

Continuous Dense Normalized Flow Model for Anomaly Detection in Industrial Images
计算机科学, 2023, 50(12): 212-220. <https://doi.org/10.11896/jsjcx.221000183>

[基于特征融合与边界修正显著性目标检测](#)

Feature Fusion and Boundary Correction Network for Salient Object Detection
计算机科学, 2023, 50(12): 166-174. <https://doi.org/10.11896/jsjcx.221100203>

基于双空间共轭自编码器的多时相高光谱异常变化检测

李沙沙¹ 邢红杰¹ 李刚^{2,3}

1 河北大学数学与信息科学学院河北省机器学习与计算智能重点实验室 河北保定 071002

2 华北电力大学计算机系 河北保定 071003

3 复杂能源系统智能计算教育部工程研究中心 河北保定 071003

(lss96133@163.com)

摘要 高光谱异常变化检测能够从多时相高光谱遥感图像中找到数量稀少、与整体背景变化趋势不同、难以发现且令人感兴趣的异常变化。数据集规模较小、存在噪声干扰以及线性预测模型存在局限性等问题,极大地降低了传统高光谱异常变化检测方法的检测性能。目前,自编码器已被成功地应用于高光谱异常变化检测。然而,单个自编码器在处理多时相高光谱图像时,仅关注图像的重构质量,在获取瓶颈特征时往往忽略了图像中复杂的光谱变化信息。为了解决该问题,提出了一种基于双空间共轭自编码器的多时相高光谱异常变化检测(Multi-temporal Hyperspectral Anomaly Change Detection Based on Dual Space Conjugate Autoencoder, DSCAE)方法。所提方法包含两个共轭的自编码器,即它们从不同方向构造各自的潜在特征。在该方法的训练过程中,首先,两幅不同时刻的高光谱图像经过各自的编码器分别获得相应的潜在空间特征表示,再分别经过各自的解码器获得另一时刻的预测图像;其次,在样本空间和潜在空间中施加不同的约束条件,并在两个空间中最小化相应的损失函数;最后,两幅输入图像经过共轭自编码器后获得各自的异常损失图,对所得的两幅异常损失图采用取小运算得到最终的异常变化强度图,以便在减小输入图像间背景光谱差异的同时突出异常变化。在高光谱异常变化检测基准数据集上的实验结果表明,与10种相关方法相比,DSCAE展现了更优的检测性能。

关键词: 高光谱图像异常变化检测;自编码器;深度学习;异常检测;多时相高光谱图像

中图分类号 TP391.4

Multi-temporal Hyperspectral Anomaly Change Detection Based on Dual Space Conjugate Autoencoder

LI Shasha¹, XING Hongjie¹ and LI Gang^{2,3}

1 Hebei Key Laboratory of Machine Learning and Computational Intelligence, College of Mathematics and Information Science, Hebei University, Baoding, Hebei 071002, China

2 Department of Computer, North China Electric Power University, Baoding, Hebei 071003, China

3 Engineering Research Center of Intelligent Computing for Complex Energy Systems, Baoding, Hebei 071003, China

Abstract Hyperspectral anomaly change detection can find anomaly changes from multi-temporal hyperspectral remote sensing images. These anomaly changes are rare, different from the overall background change trend, difficult to be found, but very interesting. For the problems of small-sized data sets, existing noise disturbance, and limitation of linear prediction models, the detection performance of the conventional hyperspectral anomaly change detection methods are greatly degraded. At present, Autoencoder has been successfully applied to hyperspectral anomaly change detection. However, when processing multi-temporal hyperspectral images, a single autoencoder only focuses on the reconstruction quality of images, while usually ignores the complex spectral changes in these images as it obtains bottleneck features. To tackle this problem, the multi-temporal hyperspectral anomaly change detection based on dual space conjugate Autoencoder(DSCAE) method is proposed. The proposed method contains two conjugate autoencoders that construct their own latent features from different directions. In the training process of the proposed method, first, two hyperspectral images at different times respectively obtain their corresponding feature representation in the latent space by their encoders. Then, the predicted image at another time can be obtained by their decoders. Second, different constraints are

到稿日期:2022-11-14 返修日期:2023-02-15

基金项目:国家自然科学基金(61672205);河北省自然科学基金(F2017201020);河北大学高层次人才科研启动项目(521100222002);复杂能源系统智能计算教育部工程研究中心开放基金(ESIC202101)

This work was supported by the National Natural Science Foundation of China(61672205), Natural Science Foundation of Hebei Province, China (F2017201020), High-Level Talents Research Start-up Project of Hebei University(521100222002) and Open Foundation of Engineering Research Center of Intelligent Computing for Complex Energy Systems(ESIC202101).

通信作者:邢红杰(hjxing@hbu.edu.cn)

imposed in the sample space and the latent space, respectively. Moreover, the corresponding loss functions are minimized in the two spaces. Finally, the anomaly loss maps are obtained by the conjugate autoencoders for the two images. The minimization operation is conducted on the two obtained anomaly loss maps to derive the final anomaly change intensity maps to simultaneously decrease the background spectral difference between the two input images and highlight anomaly changes. Experimental results on the benchmark data sets for the hyperspectral anomaly change detection demonstrate that DSCAE achieves better detection performance in comparison with its 10 pertinent methods.

Keywords Hyperspectral image anomaly change detection, Autoencoder, Deep learning, Anomaly detection, Multi-temporal hyperspectral images

1 引言

高光谱图像具有较高的光谱分辨率,能够同时用于观测空间和光谱的信息,而多时相的高光谱图像是一组在不同时间获取同一地物的高光谱图像,常被用于分析地物的变化状态。高光谱图像已成为图像处理技术的重要数据源之一,其被广泛应用于图像分类^[1]、变化检测^[2]、异常检测^[3]等任务中。在上述任务中,高光谱图像分类的目标是依据样本特征为图像中的每个样本赋予类别标签^[4-5];高光谱图像变化检测识别不同时间同一地物的不同信息,是识别多时相高光谱图像之间差异性的主要方法^[6-8];高光谱图像异常变化检测^[9-11]相对于高光谱图像变化检测来说更加侧重于发现那些细小而罕见的变化,这些异常变化主要包括物体的遮挡、人为改变小体积物体的位置等。在实际生活中,当大气条件、光照等发生巨大变化且异常变化的区域非常小时,异常变化很容易被忽略,而高光谱图像异常变化检测可以突出显示具有异常变化的像素,以提醒分析人员进行检查,因此高光谱图像异常变化检测得到了广泛而深入的研究。

目前,大多数多时相高光谱图像检测方法都采用传统的浅层学习方式,上述方法可以分为以下3类^[12]:

(1)直接比较法。例如 Bovolo 等^[13]利用变化向量分析(Change Vector Analysis, CVA)直接对多时相高光谱图像中各个波段的数据进行差值运算,对每个像素在各个波段的变化量进行比较。然而,CVA对噪声过于敏感,在含噪声的多时相高光谱图像上不能取得令人满意的检测性能。

(2)线性变换法。例如 Pieper 等^[14]将主成分分析(Principal Component Analysis, PCA)应用于多时相高光谱图像异常变化检测。PCA是一种多维正交线性变换方法,其对不同时刻的高光谱图像分别进行PCA变换,提取单个主成分进行差值运算。然而,仅使用单个主成分不能获取高光谱图像间全部的异常变化信息。

(3)统计特征法。例如 Du 等^[15]提出的 ChrooChrome(CC)方法使用最小二乘线性回归模型对光谱差异进行检测。Schaum 等^[16]在CC方法的基础上提出了协方差均衡(Covariance Equalization, CE)方法,该方法对多时相高光谱图像进行白化处理^[17],消除高光谱图像中背景光谱的噪声,利用统计分布检测异常变化。这两种方法均通过抑制背景光谱来突出异常变化,但在地物较为复杂的情形下无法保证整体背景光谱的一致性。

随着大数据时代的到来,传统的浅层学习已不适用于处理大规模高光谱图像,因此,深度学习方法在高光谱图像异常

变化检测中受到了广泛关注。深度学习方法能够学习数据的多层次表示^[18-19],在降低维度的同时能够提取高光谱图像深层的光谱特征。根据学习方式的不同,基于深度学习的异常变化检测方法可以划分为有监督学习、半监督学习和无监督学习3种类型。有监督学习检测方法理论上可以通过标签数据获得优异的检测性能,但是高光谱图像数据量较大,存在数据标签不准确、人工标注费时费力等问题^[20]。半监督学习检测方法^[21-22]难以确定有标签数据和无标签数据在训练集中所占的恰当比例。而无监督学习检测方法^[23]有效地解决了训练数据较少、需要标签数据等问题,成为基于深度学习的异常变化检测方法的研究热点。在基于深度学习的无监督异常变化检测方法中,自编码器(Autoencoder, AE)^[24]是一种常用的网络结构,它利用神经网络对输入数据进行压缩和重构,在对潜在空间中的特征进行提取的过程中实现降维。自编码器在处理复杂高维数据和提取特征等应用中展现了优异的检测性能,其改进方法被广泛应用于高光谱图像领域^[25-27]。异常变化检测与变化检测密切相关,然而,与基于深度学习的变化检测方法相比,基于深度学习的异常变化检测方法的研究相对较少。Noh 等^[25]提出了基于图像重构损失的无监督变化检测(Unsupervised Change Detection Based on Image Reconstruction Loss, CDRL)方法,该方法将输入图像以及经过变换后的图像同时输入到基于编码器和解码器的网络中进行训练,他们在解码器后添加了判别器,防止训练过程中发生过拟合;此外,根据重构损失判断测试图像中发生变化的区域。Lei 等^[26]提出了基于对抗学习光谱映射的无监督高光谱变化检测(Spectral Mapping with Adversarial Learning for Unsupervised Hyperspectral Change Detection, UHCD)方法,该方法将光谱约束损失和对抗损失分别引入到对抗自编码器的图像空间和潜在空间中,以提高映射网络提取特征的能力。然而,当大气条件、光照等噪声对不同时刻高光谱图像间的背景光谱产生干扰时,CDRL和UHCD均难以发现图像间细小而罕见的异常变化。据此,Hu 等^[27]提出了基于自编码器的高光谱异常变化检测(Hyperspectral Anomaly Change Detection Based on Autoencoder, ACDA)方法,该方法利用两个自编码器获得两幅预测图像,最小化预测图像与另一时刻输入图像之间的均方误差,得到异常损失图,进而对异常损失图采用取小运算,最后对异常变化加以检测。然而,该方法忽略了潜在空间中潜在特征之间光谱值的差异对检测性能的影响。

为了弥补上述异常变化检测方法的不足并进一步提高检测性能,本文提出了一种基于双空间共轭自编码器的多时相高光谱异常变化检测(DSCAE)方法。该方法包含两个共轭

的自编码器,即它们从相反的方向构造各自的潜在特征和预测图像。在训练过程中,首先,两幅不同时刻的高光谱图像经过共轭编码器非线性地映射到潜在空间,获得各自的潜在空间特征表示,再分别经过共轭解码器获得另一时刻的预测图像;然后,最小化样本空间中预测图像和两幅输入图像的均方误差,以及最小化潜在空间中不同时刻潜在特征之间的均方误差,采用双空间进行联合训练,在提取关键特征的同时减小输入图像间背景光谱的差异;最后,两幅输入图像经过共轭自编码器进行双空间联合训练,对训练后所得的两幅异常损失图采用取小运算得到最终的异常变化强度图,利用异常变化强度图进行异常变化检测。

本文的主要贡献为:

(1)不同时刻的输入图像经过共轭自编码器从相反的方向构造各自的潜在特征和预测图像,使该网络能够有效地学习不同时刻输入图像的背景光谱。

(2)采用样本空间和潜在空间进行联合训练,能够在提取关键特征的同时减小输入图像间背景光谱的差异。

(3)对共轭自编码器获得的两幅异常损失图采用取小运算得到最终的异常变化强度图,在进行异常变化检测时,有效地抑制输入图像间的背景光谱,同时突出异常变化。

(4)对网络隐藏层单元的选取及损失参数进行了实验分析,并将所提方法和基于变化检测及基于异常变化检测的相关方法进行了实验比较,结果表明所提方法具有更优的检测性能。

本文第2章简要介绍了基于自编码器的异常检测方法;第3章详细介绍了所提方法的模型结构、问题公式化和算法实现;第4章通过实验验证了所提方法的有效性;最后总结全文并展望未来。

2 基于AE的异常检测方法

AE是一种由编码器和解码器构成的前馈神经网络,具有较强的特征提取能力。AE使用其编码器将输入数据 x 映射到低维空间以获得潜在特征 z ,再经过解码器得到重构数据 \hat{x} ,且在训练过程中以尽可能小的误差对输入数据 x 进行重构。**AE**的训练过程如图1所示。

对于给定的输入数据 x ,编码器输出的潜在特征 z 可以表示为:

$$z = f_{\theta_e}(W_e x + b_e) \quad (1)$$

其中,编码器的网络参数为 $\theta_e = \{W_e, b_e\}$, W_e 和 b_e 分别为编码器的权重和偏差项, $f_{\theta_e}(\cdot)$ 为编码器的激活函数。




图1 自编码器的训练过程

Fig. 1 Training process of autoencoder

解码器输出的重构数据 \hat{x} 可以表示为:

$$\hat{x} = g_{\theta_d}(W_d z + b_d) \quad (2)$$

其中,解码器的网络参数为 $\theta_d = \{W_d, b_d\}$, W_d 和 b_d 分别为解码器的权重和偏差项, $g_{\theta_d}(\cdot)$ 为解码器的激活函数。

自编码器重构数据的能力主要取决于学习到的潜在特征,学习到的潜在特征越好,重构数据的能力越强,通过随机梯度下降(Stochastic Gradient Descent,SGD)^[28]算法最小化 x 和 \hat{x} 之间的重构损失 $L(x)$,以更新网络参数,从而使自编码器网络重构出与输入数据 x 尽可能相似的数据 \hat{x} ,即:

$$\min_{\theta_e, \theta_d} L(x) = \min_{\theta_e, \theta_d} \|x - \hat{x}\|^2 \quad (3)$$

在测试阶段,计算每个测试数据的重构误差。因为仅有正常数据参与训练过程中,所以AE只能学习正常数据的潜在特征。对于异常数据,AE的重构能力相对较差,因此产生了较大的重构误差。据此,基于AE的异常检测方法将重构误差作为测试数据的异常得分,即:

$$L(x) = \|x - \hat{x}\|^2 \quad (4)$$

当 $L(x)$ 的值大于预先设定的阈值时,则认为 x 是异常数据;否则认为 x 是正常数据。

3 基于双空间共轭自编码器的多时相高光谱异常变化检测

本章将从模型结构、问题公式化和算法实现3个方面对所提方法进行详细介绍。

3.1 模型结构

已有的多时相高光谱图像异常变化检测方法中往往假设背景不会发生变化。然而,由于不同时刻大气条件、光照等噪声的影响,背景光谱特征会发生微小的变化,为了减小不同时刻背景光谱的差异,同时更好地进行异常变化检测,本文提出了基于双空间共轭自编码器的多时相高光谱异常变化检测(DSCAE)方法。该方法由两个互为共轭的自编码器构成,从相反的方向构造不同时刻输入图像各自的潜在特征和预测图像,DSCAE中两个编码器的网络参数相同,两个解码器的网络参数亦相同,其模型结构如图2所示。

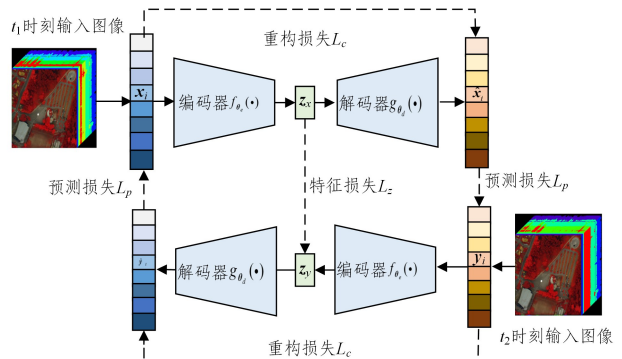


图2 DSCAE的模型结构

Fig. 2 Model structure of DSCAE

令 $X \in \mathbb{R}^{M \times N \times L}$ 和 $Y \in \mathbb{R}^{M \times N \times L}$ 分别表示 t_1 时刻和 t_2 时刻具有 $M \times N$ 个像素的 L 维高光谱图像,其中 $X = [x_1, x_2, \dots, x_{M \times N}]$, $Y = [y_1, y_2, \dots, y_{M \times N}]$,且 x_i 和 y_i 分别表示

样本空间中 \mathbf{X} 和 \mathbf{Y} 的第 i 个光谱向量。将不同时刻输入图像的光谱向量分别输入编码器中得到各自的潜在特征 $\mathbf{Z}_x = [z_{x_1}, z_{x_2}, \dots, z_{x_{M \times N}}]$ 和 $\mathbf{Z}_y = [z_{y_1}, z_{y_2}, \dots, z_{y_{M \times N}}]$, 其中 z_{x_i} 和 z_{y_i} 分别表示潜在空间中 \mathbf{X} 和 \mathbf{Y} 的第 i 个特征向量, \mathbf{Z}_x 和 \mathbf{Z}_y 经过编码器后会得到另一时刻的预测图像 $\hat{\mathbf{X}} = [\hat{x}_1, \hat{x}_2, \dots, \hat{x}_{M \times N}]$ 和 $\hat{\mathbf{Y}} = [\hat{y}_1, \hat{y}_2, \dots, \hat{y}_{M \times N}]$, 且 \hat{x}_i 和 \hat{y}_i 分别表示样本空间中 $\hat{\mathbf{X}}$ 和 $\hat{\mathbf{Y}}$ 的第 i 个光谱向量。因为无监督慢速特征分析 (Unsupervised Slow Feature Analysis, USFA)^[29-30] 方法能够提取多时相高光谱图像中不变的光谱信息, 所以我们在 DSCAE 的训练过程中利用 USFA 方法求取两组多时相高光谱图像的训练样本, 即 $\{x_1, x_2, \dots, x_S\}$ 和 $\{y_1, y_2, \dots, y_S\}$ 。

不同时刻的光谱向量在共轭编码器中的训练过程可以表示为:

$$z_{x_i} = f_{\theta_e}(\mathbf{W}_e x_i + b_e) \quad (5)$$

$$z_{y_i} = f_{\theta_e}(\mathbf{W}_e y_i + b_e) \quad (6)$$

其中, 编码器的网络参数为 $\theta_e = \{\mathbf{W}_e, b_e\}$, \mathbf{W}_e 和 b_e 分别表示权重和偏差项, $f_{\theta_e}(\cdot)$ 为编码器的激活函数。此外, 不同时刻的光谱特征在共轭解码器中的训练过程可以表示为:

$$\hat{x}_i = g_{\theta_d}(\mathbf{W}_d z_{x_i} + b_d) \quad (7)$$

$$\hat{y}_i = g_{\theta_d}(\mathbf{W}_d z_{y_i} + b_d) \quad (8)$$

其中, 解码器的网络参数为 $\theta_d = \{\mathbf{W}_d, b_d\}$, \mathbf{W}_d 和 b_d 分别表示权重和偏差项, $g_{\theta_d}(\cdot)$ 为解码器的激活函数。

3.2 问题公式化

DSCAE 的训练目标是捕获不同时刻输入图像在样本空间和潜在空间内的分布, 最小化样本空间和潜在空间中的损失函数以进行双空间联合训练, 从而学习输入图像的背景光谱特征, 同时减小不同时刻输入图像之间背景光谱的差异。一般情况下, 高光谱图像中的背景光谱占比较大, 为了充分学习样本空间中不同时刻输入图像的背景光谱, 可将预测图像与该时刻输入图像之间的均方误差作为重构损失, 通过最小化该重构损失来提高样本空间中预测图像与该时刻输入图像背景光谱的相似性。因此, 样本空间中的重构损失 L_c 可表示为:

$$\begin{aligned} L_c &= L_{c_x} + L_{c_y} \\ &= \frac{1}{S} \sum_{i=1}^S (\|x_i - \hat{x}_i\|^2) + \frac{1}{S} \sum_{i=1}^S (\|y_i - \hat{y}_i\|^2) \end{aligned} \quad (9)$$

由于不同时刻大气条件、光照等噪声的影响, 高光谱图像之间的背景光谱会发生微小的变化, 但是在进行多时相高光谱图像异常变化检测时, 图像间的背景光谱应相同。因此, DSCAE 不仅要学习输入图像各自的背景光谱, 还需减小不同时刻高光谱图像间背景光谱的差异, 以提高预测图像与另一时刻输入图像之间背景光谱的相似性。因此, DSCAE 方法在样本空间中引入预测损失 L_p , 用于计算预测图像与另一时刻输入图像之间的均方误差, 表示为:

$$\begin{aligned} L_p &= L_{p_x} + L_{p_y} \\ &= \frac{1}{S} \sum_{i=1}^S (\|\hat{x}_i - y_i\|^2) + \frac{1}{S} \sum_{i=1}^S (\|\hat{y}_i - x_i\|^2) \end{aligned} \quad (10)$$

此外, 低维的潜在空间包含更丰富的光谱信息, 两幅输入图像经过各自的编码器得到各自的深层潜在特征, 为了使

不同时刻高光谱图像之间背景的光谱特征更为相似, DSCAE 方法在潜在空间中引入特征损失 L_z , 用于计算不同时刻潜在特征之间的均方误差, 表示为:

$$L_z = \frac{1}{S} \sum_{i=1}^S (\|z_{x_i} - z_{y_i}\|^2) \quad (11)$$

综上, 采用样本空间和潜在空间的 3 个损失 L_c, L_p, L_z 对网络进行约束, 使 DSCAE 能够充分学习不同时刻高光谱图像的背景光谱, 且减小图像之间因噪声产生的背景光谱差异。最终 DSCAE 双空间联合训练的总损失为:

$$L = \lambda_1 L_c + \lambda_2 L_p + \lambda_3 L_z \quad (12)$$

其中, $\sum_{i=1}^3 \lambda_i = 1$, 在经过实验分析后设置为 $\lambda_1 = \lambda_2 = 0.2$ 和 $\lambda_3 = 0.6$ 。

给定两幅不同时刻的高光谱图像, 经过共轭自编码器后可得两幅相应的异常损失图 I_1 和 I_2 , 对这两幅异常损失图采用取小运算得到最终的异常变化强度图, 即 $I = \min(I_1, I_2)$ 。在进行异常变化检测时, 异常变化强度图 I 可以有效抑制输入图像间背景光谱的差异, 同时突出异常变化。需要指出的是, 对异常变化强度图采用取小运算的原因在于:

(1) 若高光谱图像中的像素属于异常变化, 那么模型得到的两幅异常损失图中的异常强度值都会较大, 这种情况下采用取小运算后异常强度值依然较大, 异常信息会得以保留。

(2) 若高光谱图像中的像素没有发生异常变化, 那么得到的两幅异常损失图中的异常强度值都很小, 这种情况下采用取小运算后得到的值依然较小, 背景发生异常变化的可能性会降低。

(3) 若两幅异常损失图中的异常像素是由于大气条件、光照等噪声影响造成时, 采用取小运算可以减少噪声的干扰。

3.3 算法实现

DSCAE 的训练过程和异常变化检测过程分别如算法 1 和算法 2 所示。

算法 1 DSCAE 的训练过程

输入: 利用 USFA 求取不同时刻的训练样本 $\mathbf{X} = \{x_i\}_{i=1}^S$ 和 $\mathbf{Y} = \{y_i\}_{i=1}^S$

输出: 编码器 $f_{\theta_e}(\cdot)$ 和解码器 $g_{\theta_d}(\cdot)$

初始化: 编码器 $f_{\theta_e}(\cdot)$ 和解码器 $g_{\theta_d}(\cdot)$ 的参数 θ_e, θ_d

1. for $i \leftarrow 1$ to S do

2. 通过式(5)和式(6)计算 x_i 和 y_i 经过各自编码器后的潜在特征 z_{x_i} 和 z_{y_i}

3. 通过式(7)和式(8)计算 z_{x_i} 和 z_{y_i} 经过各自解码器后的重构向量 \hat{x}_i 和 \hat{y}_i

4. 通过式(9)、式(10)和式(11)计算 L_c, L_p 和 L_z

5. 通过式(12)得到 L

6. 使用随机梯度下降法更新 $f_{\theta_e}(\cdot)$ 和 $g_{\theta_d}(\cdot)$ 的参数 θ_e, θ_d

7. end for

算法 2 DSCAE 的异常变化检测过程

输入: 不同时刻高光谱图像的测试图像 $\mathbf{X} = \{x_i\}_{i=1}^{M \times N}$ 和 $\mathbf{Y} = \{y_i\}_{i=1}^{M \times N}$

输出: 异常变化强度图 I

1. 通过式(12)分别计算 x_i 和 y_i 的异常损失图 I_1 和 I_2

2. 通过式 $I = \min(I_1, I_2)$ 计算得到最终的异常变化强度图 I

3. return I

4 实验结果

为了验证所提 DSCAE 的性能,在多时相高光谱图像数据集中进行了大量实验。首先介绍所选取的多时相高光谱图像数据集;其次,对损失函数参数以及共轭自编码器中隐藏单元数量的选取进行了分析;再次,将 DSCAE 与相关的异常变化检测方法以及变化检测方法进行了比较;最后,通过消融实验进一步验证了 DSCAE 的有效性。

4.1 数据集

为了验证所提方法的性能,在以下实验中选用了 Viareggio 2013 数据集^[31],其中不同时刻图像对应的伪彩色图像示例如图 3 所示。D1F12H1 和 D1F12H2 的伪彩色图像示例分别如图 3(a)和图 3(b)所示,它们是在 2013 年 5 月 8 日的不同时刻采集的,此外,它们的成像条件非常相似,均在阴天环境下获取。D2F22H2 的伪彩色图像示例如图 3(c)所示,它是在 2013 年 5 月 9 日采集的,且在晴天环境下获取,其部分区域有明显阴影,如图 3(c)中的白色矩形区域。这 3 幅图像大小都是 450×375 像素,且具有 127 个光谱波段。将 Viareggio 2013 数据集分成两对,“D1F12H1-D1F12H2”图像对组成 EX1,采集时只有 15 min 的时间间隔且光照条件相似,“D1F12H1-D2F22H2”图像对组成 EX2,有将近一天的时间间隔且光照条件不同。




图 3 Viareggio 2013 数据集中的伪彩色图像示例

Fig. 3 Examples of pseudo color images in Viareggio 2013 dataset

选择经过预处理后的高光谱图像进行实验,包括采用多元线性回归处理以消除条纹噪声;采用噪声白化技术对噪声方差进行归一化处理;通过对 4 个连续的光谱取平均操作以降低随机噪声。图 4(a)和图 4(b)分别为 EX1 和 EX2 对应的真值图,它们能够显示高光谱图像中所有异常变化的像素,因此,将这两幅真值图用作异常变化检测的参考图。



(a) EX1

(b) EX2

图 4 EX1 和 EX2 的真值图

Fig. 4 Ground-truth map of EX1 and EX2

4.2 评价准则

在评估所提 DSCAE 及相关方法的性能时,异常变化

强度图能够定性地展示异常变化检测的性能,而接受者操作特征曲线(Receiver Operating Characteristic Curve, ROC)和 ROC 曲线下面积(Area Under Curve, AUC)则能定量地评估异常变化检测的性能。3 种评价准则的具体描述如下:

(1)异常变化强度图用于描述高光谱图像在视觉上的检测效果。如果异常变化强度图中背景像素被抑制的同时异常像素明显突出,且背景像素和异常像素能被正确直观地区分,则证明该方法具有优异的检测性能。

(2)ROC 曲线用于描述在不同阈值下的真正例率和假正例率之间的关系。ROC 曲线以真正例率为纵坐标,假正例率为横坐标,通过调整阈值获得每个样本的检测结果,形成 ROC 曲线。如果一个检测器的 ROC 曲线高于另一个检测器的 ROC 曲线,且更加靠近左上角(0,1),则表明该检测器的检测效果更好。

(3)通过计算 ROC 曲线下的整个面积得到 AUC 值。AUC 值越接近 1,说明该方法的检测性能越好。此外,当 ROC 曲线相互交叉时,利用 AUC 值能够进一步评估两个检测器的性能,AUC 值越大,检测器的检测效果越好。

4.3 参数分析

在 DSCAE 模型中,共轭自编码器各包含 3 个隐藏层,并使用 ReLU 激活函数,权重和偏差项的初始化方式与文献[32]相同,使用 Adam 优化器^[33]并设置学习率为 0.001 对模型进行优化,训练阶段最大迭代次数为 200。本节对共轭自编码器中隐藏层单元数量的选取以及损失函数 L 中权重参数的选取进行了分析。

对共轭自编码器隐藏层单元数量的选取进行分析时,固定损失函数的权重参数为 $\lambda_1 = \lambda_2 = 0.2, \lambda_3 = 0.6$ 。每个自编码器各包含 3 个隐藏层,如图 5 所示,第一个隐藏层单元的数量是 h_1 ,第二个隐藏层单元的数量是 h_2 ,第三个隐藏层单元的数量是 h_3 ,实验过程中设定 $h_1 = h_3 > h_2$ 。当隐藏层单元的数量较少时将导致欠拟合,数量过多时可能会引发过拟合且增加训练时间,导致难以达到预期的效果。因此,选取恰当的隐藏层单元的数量对 DSCAE 模型至关重要。




图 5 DSCAE 模型中自编码器的网络结构

Fig. 5 Network structure of autoencoder in DSCAE model

最佳的隐藏层单元的数量是通过大量实验对参数进行微调获取到的。 h_1 和 h_2 的取值范围分别设置为 $\{120, 100, 80, 60, 40\}$ 和 $\{100, 80, 60, 40, 20\}$,在 EX1 和 EX2 数据集上进行隐藏层单元数量选取实验得到的 AUC 值如表 1 和表 2 所列。当 h_1 较大且 h_2 较小时,维度相差较大,会导致在特征转换过程中出现差异,从而丢失部分重要特征并降低模型的检测性能。此外,隐藏层本质上起到了降维的作用,试图以更小的维度去描述原始数据且尽量不破坏原始数据,第一个隐藏层学习较多低阶的特征,然后将其送入第二个隐藏层中,提取出

较高阶的特征。实验结果显示,当 $h_1 = 100, h_2 = 80$ 时, DS-CAE 模型在 EX1 和 EX2 数据集上 AUC 值取得最大值, 分别为 0.8502 和 0.8716。因此选取 $h_1 = 100, h_2 = 80$ 作为 DS-CAE 模型在 EX1 和 EX2 数据集上最佳的隐藏层单元数量。

表 1 在 EX1 数据集上 DSCAE 模型选取不同 h_1 和 h_2 值得到的 AUC 值

Table 1 AUC values obtained by selecting different h_1 and h_2 values for DSCAE model on EX1 dataset

h_2	h_1				
	120	100	80	60	40
100	0.8489	—	—	—	—
80	0.8423	0.8502	—	—	—
60	0.8353	0.8439	0.8398	—	—
40	0.8359	0.8480	0.8320	0.8376	—
20	0.8322	0.8329	0.8292	0.8309	0.8305

注: 由于实验中要求 $h_1 > h_2$, 因此“—”表示未计算相应的 AUC 值。

表 2 在 EX2 数据集上 DSCAE 模型选取不同 h_1 和 h_2 值得到的 AUC 值

Table 2 AUC values obtained by selecting different h_1 and h_2 values for DSCAE model on EX2 dataset

h_2	h_1				
	120	100	80	60	40
100	0.8672	—	—	—	—
80	0.8661	0.8716	—	—	—
60	0.8653	0.8707	0.8642	—	—
40	0.8678	0.8593	0.8604	0.8606	—
20	0.8615	0.8645	0.8562	0.8434	0.8552


在对损失函数 L 中的权重参数的选取进行分析时, 固定隐藏层单元的数量为 $h_1 = 100, h_2 = 80$ 。设置 $\lambda_1 + \lambda_2 + \lambda_3 = 1$, 由于 L_p 与 L_c 是对样本空间中的损失函数进行约束, 且潜在空间更能提取重要的光谱特征, 因此选取 $\lambda_1 = \lambda_2 < \lambda_3$ 。对 λ_3 进行参数变化实验, 在 EX1 和 EX2 数据集上得到的 AUC 值分别如图 6(a) 和图 6(b) 所示, 可发现当 $\lambda_1 = \lambda_2 = 0.2, \lambda_3 = 0.6$ 时, DSCAE 模型在 EX1 和 EX2 数据集上的 AUC 值取得了最大值, 分别为 0.8502 和 0.8716。因此选取 $\lambda_1 = \lambda_2 = 0.2, \lambda_3 = 0.6$ 作为 DSCAE 模型在 EX1 和 EX2 数据集上损失函数 L 最佳的权重参数设置。

4.4 结果与分析


如上所述, DSCAE 模型的参数分别设置为 $h_1 = 100, h_2 = 80, \lambda_1 = \lambda_2 = 0.2, \lambda_3 = 0.6$, 并与相关的异常变化检测方法以及变化检测方法在 EX1 和 EX2 数据集上进行比较。相关方法包括 PCA、CVA、多元变化检测 (Multivariate Alteration Detection, MAD)^[34]、迭代重加权的多元变化检测 (Iterative Reweight Multivariate Alteration Detection, IRMAD)^[35]、基于光谱角加权的局部绝对距离方法 (Spectral Angle Weighted-based Local Absolute Distance, SALA)^[36]、基于绝对距离的方法 (Absolute Distance, AD)^[37]、基于对应分析的方法 (Correspondence Analysis, CA)、ACDA、基于神经网络的头顶图像变化检测方法 (Change Detection in Overhead Imagery Using Neural Networks, CDNN)^[27,38] 以及基于 Transformers 的遥感图像变化检测方法 (Remote Sensing Image Change Detection With Transformers, RSCDT)^[39]。具体含义如下:

(1) PCA 方法对不同时刻的高光谱图像分别进行 PCA

变换, 对累计贡献率为 75% 的成分进行差值运算, 进行 10 次迭代取平均值得到最终结果。



(a) EX1



(b) EX2

图 6 当 λ_3 取不同值时, DSCAE 在 EX1 和 EX2 数据集上取得的 AUC 值

Fig. 6 AUC values of DSCAE on EX1 and EX2 datasets at different λ_3

(2) CVA 方法直接对不同时刻高光谱图像中各个波段的数据进行差值运算, 进行 10 次迭代取平均值得到最终结果。

(3) MAD 方法利用不同时刻高光谱图像的特征值方差来确定各个像素是否发生变化。IRMAD 方法在 MAD 方法的基础上进行迭代重加权操作, 将各个像素的初始权重设置为 1, 在迭代过程中更新权重, 根据权重判断像素变化的区域。设置最大迭代次数为 10, 选取最后一次迭代得到的结果作为最终结果。

(4) CA 方法通过计算不同时刻的高光谱图像中各个像素的 χ^2 距离, 进而确定像素变化的区域, 得到最终结果。

(5) AD 方法采用逐像素分析的方法, 通过简单相加的方式将不同时刻高光谱图像中各波段的变化信息进行整合, 对整合后的单一波段进行检测, 得到最终结果。

(6) SALA 方法采用局部像素分析的方法, 通过加权组合的方式将不同时刻高光谱图像中各波段的变化信息整合为单一波段, 通过引导滤波算法将检测结果进行校正得到最终结果。其中外窗口大小设置为 3, 内窗口大小设置为 1。

(7) ACDA 方法将不同时刻的高光谱图像输入到各自的自编码器中得到另一时刻的预测图, 对获取的异常损失图取小运算作为最终的异常变化强度图。隐藏层单元的数量设置为 $h_1 = 60, h_2 = 40$, 设置最大迭代次数为 200, 选取迭代过程的最大值作为最终结果。

(8) CDNN 方法中输入图像经过一个三层全连接神经网络后得到另一时刻的预测图像, 根据输入图像和预测图像像素值之间的差异, 判断各个像素是否发生异常变化。隐藏层单元的数量设置为 $h_1 = 127, h_2 = 200$, 设置最大迭代次数为 200, 选取迭代过程的最大值作为最终结果。

(9) RSCDT 方法首先对 ResNet 网络提取的不同时刻

高光谱图像的特征进行拼接,再经过编码器和解码器得到不同时刻的预测特征,最后通过预测得到变化检测结果。设置最大迭代次数为 200,选取迭代过程的最大值作为最终结果。

DSCAE 模型与相关方法在 EX1 和 EX2 数据集上的异常变化强度图分别如图 7 和图 8 所示。图 7(d)和图 8(d)分别为 EX1 和 EX2 数据集对应的真值图,亮区对应异常变化像素。PCA,CVA,CA,AD 以及 SALA 方法在 EX1 数据集的异常变化强度图中存在伪干扰和大量的噪声,说明这 5 种方法容易受噪声影响。MAD 和 IRMAD 的异常变化强度图如图 7(c)和图 7(d)所示,虽然未发生变化的背景像素得到一定

的抑制,但是异常变化的像素非常模糊。而 DSCAE 相较于 ACDA,CDNN 以及 RSCDT 方法来说能够在抑制背景像素的同时突出显示异常变化。同样地,观察图 8 中在 EX2 数据集上得到的异常变化强度图可以发现,PCA,CVA,CA,AD 以及 SALA 方法的异常变化并不突出,且背景像素没有得到有效的抑制,此外,异常变化强度图上还能够看出由于大气条件、光照等噪声影响而产生的阴影。MAD 和 IRMAD 的异常变化强度图中异常变化的像素较为模糊。相较于 ACDA,CDNN 以及 RSCDT 方法来说,DSCAE 背景得到了很好的抑制,且异常变化像素清晰明显,体现出更优异的变化检测性能。




图 7 不同方法在 EX1 数据集上取得的异常变化强度图

Fig. 7 Anomaly change intensity maps of different methods on EX1 dataset




图 8 不同方法在 EX2 数据集上取得的异常变化强度图

Fig. 8 Anomaly change intensity maps of different methods on EX2 dataset


DSCAE模型与相关方法的AUC值如表3所列。在EX1数据集上,只关注样本空间的ACDA方法取得了次优的检测性能,其AUC值为0.8362,而DSCAE模型既关注样本空间又关注潜在空间,其AUC值为0.8502,取得了最优的检测性能。在EX2数据集上,ACDA方法同样取得了次优的检测性能,其AUC值为0.8400,DSCAE模型取得了最优的检测性能,其AUC值为0.8716。此外,DSCAE模型在EX1和EX2数据集上的平均AUC值取得了最大值,为0.8609,优于ACDA方法。10种相关方法在EX1和EX2数据集上的AUC值都较低,原因是它们对

异常变化像素不敏感,且不能有效抑制不变的背景像素。综合来看,所提DSCAE模型在EX1和EX2数据集上展现了最优异的检测性能。图9给出了DSCAE模型和相关方法在EX1和EX2数据集上取得的ROC曲线图。在EX1数据集上ACDA方法与DSCAE模型性能较为接近,但DSCAE更靠近左上角,曲线最平滑,且表3中DSCAE模型的AUC值更高。在EX2数据集上,DSCAE模型比其余10种相关方法的ROC曲线都更靠近左上角且位于最上方,曲线也最平滑。因此,由表3和图9可发现DSCAE模型展现了更优的检测性能。


表3 不同方法在EX1和EX2数据集上取得的AUC值

Table 3 AUC values of different methods on EX1 and EX2 datasets

datasets	PCA	CVA	MAD	IRMAD	CA	AD	SALA	ACDA	CDNN	RSCDT	DSCAE
EX1	0.6697	0.6676	0.6065	0.6836	0.6609	0.6236	0.6900	0.8362	0.7810	0.8066	0.8502
EX2	0.5165	0.5319	0.5089	0.5333	0.5505	0.5968	0.6352	0.8400	0.8133	0.8228	0.8716
AVG	0.5931	0.5998	0.5577	0.6085	0.6057	0.6102	0.6626	0.8381	0.7972	0.8147	0.8609



(a) EX1



(b) EX2

图9 不同方法在EX1和EX2数据集上取得的ROC曲线图

Fig. 9 ROC curves of different methods on EX1 and EX2 datasets

4.5 消融研究

为了分析样本空间和潜在空间中的约束以及异常变化强度图的选取对异常变化检测结果的影响,在EX1和EX2数据集上对所提DSCAE模型进行了消融研究,结果如表4所列。

表4 在EX1和EX2数据集上DSCAE模型使用不同网络结构得到的AUC值

Table 4 AUC values of DSCAE model with different network structures on EX1 and EX2 datasets

datasets	DSCAE-W/ L_p	DSCAE-W/ OL_z	DSCAE
EX1	0.8300	0.7524	0.8502
EX2	0.8414	0.7133	0.8716
AVG	0.8357	0.7329	0.8609

表4中列出了3种情况:第一种情况只考虑样本空间中的预测图像与另一时刻输入图像之间的约束,记为DSCAE-W/ L_p ,这种结构与ACDA方法类似,训练阶段仅使用样本空间中的预测损失,两种方法的区别在于对隐藏层单元数量的设置不同,ACDA隐藏层单元数量设置为 $h_1=60, h_2=40$,在EX1和EX2数据集上AUC值分别为0.8300和0.8414;第二种情况是在使用预测损失对样本空间进行约束的同时引入重构损失,记为DSCAE-W/ OL_z ,在EX1和EX2数据集上AUC值分别为0.7524和0.7133;第三种情况为DSCAE


模型,除对样本空间进行约束外,还在潜在空间引入特征损失,以便能够提取重要的光谱特征,在EX1和EX2数据集上AUC值分别为0.8502和0.8716。实验结果表明,第3种情况的AUC值和平均AUC值都取得了最大值,这表明对样本空间和潜在空间进行约束能够使模型展现最优的检测性能。

此外,不同时刻输入图像经过DSCAE后可获得两幅异常损失图,如图2所示,将 t_1 时刻输入图像经过共轭自编码器后得到的重构图像与 t_2 时刻输入图像得到的异常损失图标记为异常损失图1,将 t_2 时刻输入图像经过共轭自编码器后得到的重构图像与 t_1 时刻输入图像得到的异常损失图标记为异常损失图2。异常损失图的选取有5种情况,如表5所列。第一种情况:将异常损失图1作为最终的异常变化强度图,在EX1和EX2数据集上AUC值分别为0.8421和0.8664。第二种情况:将异常损失图2作为最终的异常变化强度图,在EX1和EX2数据集上AUC值分别为0.8418和0.8651。第三种情况:对异常损失图1和异常损失图2取大运算得到最终的异常变化强度图,在EX1和EX2数据集上AUC值分别为0.8494和0.8642。第四种情况:对异常损失图1和异常损失图2取平均运算得到最终的异常变化强度图,在EX1和EX2数据集上AUC值分别为0.8418和0.8663。第五种情况:DSCAE模型所选取的方法,即对异常损失图1和异常损失图2取小运算得到最终的异常变化强度


图,在 EX1 和 EX2 数据集上 AUC 值取得最大值,分别为 0.8502 和 0.8716。可以观察到,第五种情况的平均 AUC 值取得了最大值,为 0.8609。图 10 是在 EX1 和 EX2 数据集上选取不同异常损失图的 ROC 曲线图,DSCAE 模型的 ROC 曲线图位于最上方,进一步验证了所提 DSCAE 模型的有效性。

表 5 在 EX1 和 EX2 数据集上选取不同异常损失图得到的 AUC 值
Table 5 AUC values obtained by choosing different anomaly loss maps on EX1 and EX2 datasets

datasets	只有 损失图 1	只有 损失图 2	取大运算	取平均 运算	DSCAE
EX1	0.8421	0.8418	0.8494	0.8418	0.8502
EX2	0.8664	0.8651	0.8642	0.8663	0.8716
AVG	0.8543	0.8535	0.8568	0.8541	0.8609



(a) EX1



(b) EX2

图 10 在 EX1 和 EX2 数据集上选取不同异常损失图得到的 ROC 曲线图

Fig. 10 ROC curves obtained by selecting different anomaly loss maps on EX1 and EX2 datasets

结束语 为了提高多时相高光谱异常变化检测的性能,提出了一种基于双空间共轭自编码器的多时相高光谱异常变化检测方法。首先,不同时刻的输入图像经过共轭自编码器后获得另一时刻的预测图像;其次,最小化样本空间和潜在空间中的损失函数以学习输入图像的背景光谱,同时减小图像间背景光谱的差异;最后,对 DSCAE 模型获得的两幅异常损失图取小运算得到最终的异常变化强度图,根据异常变化强度图进行异常变化检测。在 Viareggio 2013 数据集上进行了大量实验,结果表明,DSCAE 模型在多时相高光谱异常变化检测领域具有优异的检测性能。

尽管 DSCAE 模型在 Viareggio 2013 数据集上取得了优异的检测性能,但目前多时相高光谱异常变化检测领域的公开数据集较少,该模型尚未在其他数据集得到验证,同时,我们没有测试 DSCAE 模型在存在扰动的数据集上的性能。在今后的研究工作中,首先需要使用更多的多时相高光谱异常变化检测的数据集来验证该模型的有效性。其次,对模型采用对抗训练的方式,提高模型对抗扰动的能力。

参考文献

- [1] FANG L, LIU G, LI S, et al. Hyperspectral Image Classification with Squeeze Multibias Network [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 57(3): 1291-1301.
- [2] WANG Q, YUAN Z, DU Q, et al. GETNET: A General end-to-end 2-D CNN Framework for Hyperspectral Image Change Detection [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 57(1): 3-13.
- [3] STEIN D W J, BEAVEN S G, HOFF L E, et al. Anomaly Detection from Hyperspectral Imagery [J]. IEEE Signal Processing Magazine, 2002, 19(1): 58-69.
- [4] CAMPS-VALLS G, TUIA D, BRUZZONE L, et al. Advances in Hyperspectral Image Classification: Earth Monitoring with Statistical Learning Methods [J]. IEEE Signal Processing Magazine, 2013, 31(1): 45-54.
- [5] FAUVEL M, TARABALKA Y, BENEDIKTSSON J A, et al. Advances in Spectral-spatial Classification of Hyperspectral Images [J]. Proceedings of the IEEE, 2012, 101(3): 652-675.
- [6] SINGH A. Review Article Digital Change Detection Techniques using Remotely-sensed Data [J]. International Journal of Remote Sensing, 1989, 10(6): 989-1003.
- [7] LU D, MAUSEL P, BRONZIO E, et al. Change Detection Techniques [J]. International Journal of Remote Sensing, 2004, 25(12): 2365-2401.
- [8] COPPIN P, JONCKHEERE I, NACKAERTS K, et al. Review Article Digital Change Detection Methods in Ecosystem Monitoring: A Review [J]. International Journal of Remote Sensing, 2004, 25(9): 1565-1596.
- [9] EISMANN M T, MEOLA J, STOCKER A D, et al. Airborne Hyperspectral Detection of Small Changes [J]. Applied Optics, 2008, 47(28): 27-45.
- [10] RESTA S, ACITO N, DIANI M, et al. Detection of Small Changes in Airborne Hyperspectral Imagery: Experimental Results over Urban Areas [C] // 2011 6th International Workshop on the Analysis of Multi-temporal Remote Sensing Images (Multi-Temp). Trento: IEEE, 2011: 5-8.
- [11] ACITO N, DIANI M, ROSSI A, et al. Hyperspectral Anomalous Change Detection in the Presence of Non-stationary Atmospheric/Illumination Conditions [C] // Image and Signal Processing for Remote Sensing XX. Amsterdam: SPIE, 2014: 254-263.
- [12] WU C, DU B, ZHANG L. Hyperspectral Anomalous Change Detection Based on Joint Sparse Representation [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 146: 137-150.
- [13] 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, 2006, 45(1): 218-236.
- [14] PIEPER M, MANOLAKIS D, COOLEY T, et al. New Insights and Practical Considerations in Hyperspectral Change Detection [C] // 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Milan: IEEE, 2015: 4161-4164.
- [15] DU Q, YOUNAN N, KING R. Change Analysis for Hyperspec-

- tral Imagery[C]//2007 International Workshop on the Analysis of Multi-temporal Remote Sensing Images. Leuven:IEEE,2007:1-4.
- [16] SCHAUM A P,STOCKER A. Hyperspectral Change Detection and Supervised Matched Filtering Based on Covariance Equalization[C]//Algorithms and technologies for multispectral, Hyperspectral, and Ultraspectral Imagery X. Orlando; SPIE, 2004:77-90.
- [17] MAYER R, BUCHOLTZ F, SCRIBNER D. Object Detection by Using “Whitening/Dewhitening” to Transform Target Signatures in Multitemporal Hyperspectral and Multispectral Imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2003,41(5):1136-1142.
- [18] KRIZHEVSKY A,SUTSKEVER I,HINTON G E. Imagenet Classification with Deep Convolutional Neural Networks[J]. Communications of the ACM,2017,60(6):84-90.
- [19] LECUN Y,BENGIO Y,HINTON G. Deep Learning[J]. Nature,2015,521(7553):436-444.
- [20] ZARE A,JIAO C,GLENN T. Discriminative Multiple Instance Hyperspectral Target Characterization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(10):2342-2354.
- [21] JIANG K,XIE W,LI Y, et al. Semi-supervised Spectral Learning with Generative Adversarial Network for Hyperspectral Anomaly Detection[J]. IEEE Transactions on Geoscience and Remote Sensing,2020,58(7):5224-5236.
- [22] XIE W,LIU B,LI Y, et al. Autoencoder and Adversarial-learning-based semi-supervised Background Estimation for Hyperspectral Anomaly Detection[J]. IEEE Transactions on Geoscience and Remote Sensing,2020,58(8):5416-5427.
- [23] BARLOW H B. Unsupervised Learning [J]. Neural Computation,1989,1(3):295-311.
- [24] HINTON G E,SALAKHUTDINOV R R. Reducing the Dimensionality of Data with Neural Networks [J]. Science, 2006, 313(5786):504-507.
- [25] NOH H,JU J,SEO M, et al. Unsupervised Change Detection Based on Image Reconstruction Loss[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans:IEEE,2022:1352-1361.
- [26] LEI J,LI M,XIE W, et al. Spectral Mapping with Adversarial Learning for Unsupervised Hyperspectral Change Detection[J]. Neurocomputing,2021,465:71-83.
- [27] HU M,WU C,ZHANG L, et al. Hyperspectral Anomaly Change Detection Based on Autoencoder[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021,14:3750-3762.
- [28] ROBBINS H,MONRO S. A Stochastic Approximation Method [J]. The Annals of Mathematical Statistics,1951,22(3):400-407.
- [29] WU C,DU B,ZHANG L. Slow Feature Analysis for Change Detection in Multispectral Imagery[J]. IEEE Transactions on Geoscience and Remote Sensing,2013,52(5):2858-2874.
- [30] WU C,ZHANG L,DU B. Hyperspectral Anomaly Change Detection with Slow Feature Analysis[J]. Neurocomputing,2015,151(1):175-187.
- [31] ACITO N, MATTEOLI S,ROSSI A, et al. Hyperspectral Airborne “Viareggio 2013 Trial” Data Collection for Detection Algorithm Assessment[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing,2016,9(6):2365-2376.
- [32] HE K,ZHANG X,REN S, et al. Delving Deep into Rectifiers: Surpassing Human-level Performance on Imagenet Classification [C]// Proceedings of the IEEE International Conference on Computer Vision. Santiago:IEEE,2015:1026-1034.
- [33] KINGMA D P,BA J. Adam:A Method for Stochastic Optimization[C]// International Conference on Learning Representations. San Diego:IEEE,2015:1-15.
- [34] NIELSEN A A,CONRADSEN K,SIMPSON J J. Multivariate Alteration Detection (MAD) and MAF Postprocessing in Multispectral, Bitemporal Image Data: New Approaches to Change Detection Studies[J]. Remote Sensing of Environment, 1998, 64(1):1-19.
- [35] NIELSEN A A. The Regularized Iteratively Reweighted MAD Method for Change Detection in Multi-and Hyperspectral Data [J]. IEEE Transactions on Image processing,2007,16(2):463-478.
- [36] HOU Z,LI W,LI L, et al. Hyperspectral Change Detection Based on Multiple Morphological Profiles[J]. IEEE Transactions on Geoscience and Remote Sensing,2021,60:1-12.
- [37] DU P,LIU S,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.
- [38] CLIFTON C. Change Detection in Overhead Imagery Using Neural Networks[J]. Applied Intelligence, 2003, 18(2):215-234.
- [39] CHEN H,QI Z,SHI Z. Remote Sensing Image Change Detection with Transformers[J]. IEEE Transactions on Geoscience and Remote Sensing,2021,60:1-14.



LI Shasha, born in 1996, postgraduate. Her main research interests include novelty detection, autoencoder and deep learning.



XING Hongjie, born in 1976, Ph.D, professor, Ph.D supervisor. His main research interests include kernel methods, neural networks, novelty detection, and ensemble learning.