

融合自适应窗口显著性检测和改进超像素分割的高光谱异常检测

钱晓亮¹, 曾银凤¹, 林生², 张博³, 任航丽¹, 王慰¹

1. 郑州轻工业大学 电气信息工程学院, 郑州 450002;
2. 西安电子科技大学 空间科学与技术学院, 西安 710126;
3. 河南工业大学 信息科学与工程学院, 郑州 450001

摘要: 高光谱异常检测旨在识别与周围像素具有显著光谱差异的像素, 由于不需要先验光谱信息的特点, 其在军事和民用领域发挥重要价值。实现高光谱异常检测的一个重要手段是局部对比度计算, 现有方法通常采用双窗口法进行计算, 然而, 窗口尺寸通常依据经验值进行手工设定, 泛化能力不足。为了解决上述问题, 本文提出了一种融合自适应窗口显著性检测和改进超像素分割的高光谱异常检测方法。该方法先利用对抗自编码网络对高光谱图像进行降维, 以降低模型计算复杂度。其次, 引入正交投影散度来改进超像素分割中的光谱距离度量方式, 提升分割精度。然后, 提出一种自适应窗口显著性检测算法来初步定位异常目标, 该算法依据超像素分割结果来自适应确定双窗口, 提高显著性检测的精度和泛化能力。最后, 采用域变换递归滤波和阈值化操作对初始检测结果进行后处理, 降低虚警率。消融实验表明, 本文所提基于正交投影散度的改进超像素分割算法较基于传统光谱距离度量方式的算法性能更优, 所提自适应窗口显著性检测算法的性能优于传统手工设定窗口尺寸的算法; 与7种流行算法的主、客观对比实验表明, 本文方法在总检测精度和异常—背景像素分离度上均优于流行算法。综上所述, 本文所提改进超像素分割算法能提升现有高光谱图像超像素分割的效果, 以此为基础所设计的自适应窗口显著性检测算法不仅能克服现有双窗口算法泛化能力不足的问题, 还能获得优于流行算法的异常检测效果。

关键词: 异常检测, 高光谱图像, 正交投影散度, 超像素分割, 自适应窗口, 显著性检测

中图分类号: TP701/P2

引用格式: 钱晓亮, 曾银凤, 林生, 张博, 任航丽, 王慰. 2023. 融合自适应窗口显著性检测和改进超像素分割的高光谱异常检测. 遥感学报, 27(12): 2748–2761

Qian X L, Zeng Y F, Lin S, Zhang B, Ren H L and Wang W. 2023. Hyperspectral anomaly detection via combining adaptive window saliency detection and improved superpixel segmentation. National Remote Sensing Bulletin, 27(12): 2748–2761 [DOI: 10.11834/jrs.20222004]

1 引言

高光谱图像是将光谱与成像技术相结合形成的三维立体图, 它具有光谱波段宽, 光谱分辨率高和空间分辨率低的特点 (Bioucas-Dias 等, 2013; Liu 等, 2021; Qian 等, 2020)。在光谱维上, 高光谱图像具有数百个连续的光谱波段, 其中包含了大量有价值的光谱信息, 因此, 可以利用其光谱特性对特定目标进行辨别和定位。而高光谱异

常检测作为高光谱图像领域的研究热点之一, 其目的是挖掘出与背景区域具有明显光谱差异的目标区域, 该任务因不需要提供目标光谱的任何先验信息就能有效地标记出目标这一特点, 在病虫害检测 (Vanegas 等, 2018)、战场搜救 (Stein 等, 2002)、地物勘探 (Peyghambari 和 Zhang, 2021)、场景分类 (钱晓亮 等, 2018) 等领域得到广泛应用。

在高光谱图像中, 异常目标区域与背景区域

收稿日期: 2022-01-04; 预印本: 2022-02-25

基金项目: 国家自然科学基金 (编号: 62076223, 62003311); 河南省科技攻关项目 (编号: 232102211018); 河南省自然科学基金 (编号: 202300410503)

第一作者简介: 钱晓亮, 研究方向为模式识别与人工智能/遥感图像场景分类与目标检测。E-mail: qxl_sunshine@163.com

通信作者简介: 林生, 研究方向为高光谱图像异常检测/遥感图像目标检测。E-mail: ls1425854658@163.com

之间具有较大对比度,即显著性较强,根据对比度计算方式的不同,现有高光谱异常检测方法可大致分为两大类:基于全局的方法和基于局部的方法。在基于全局的方法中,高光谱图像是作为整体进行数据处理,该方法根据高光谱图像的所有数据计算背景统计量,实现对异常像素的检测。其中,最经典的全局方法是由Reed和Yu(1990)提出的Reed-Xiaoli(RX)算法,该方法假设高光谱图像背景特征服从多元高斯分布,它首先根据整幅图像计算背景特征的均值向量和协方差矩阵,然后利用马氏距离度量待测像素与参考背景统计特性的偏离程度,并以此作为判别异常的标准。然而,由于真实高光谱图像的复杂性,基于全局的高斯分布往往难以拟合真实的背景分布,并且在计算背景的均值向量和协方差矩阵时,易受到异常像素的干扰,因此,其他研究学者提出了多种基于RX的改进算法,如高斯混合模型方法(Stein等,2002)利用局部高斯分布、高斯混合和线性混合3种模型构建多元高斯分布的混合,对背景统计信息进行建模,并依据多个决策统计分布检测异常目标区域,从而提高检测性能。Guo等(2014)提出了Weighted-RX方法用于高光谱异常检测,该方法在RX方法基础上对背景进行建模,并对不同背景赋予不同权重,以减少RX方法中异常像素和噪声对背景信息估计的干扰。Kernel-RX(KRX)算法(Kwon和Nasrabadi,2005)是将原始光谱空间扩展到更高维的特征空间,并在高维特征空间中进行全局背景估计。其他基于RX的全局方法还有Subspace RX(SSRX)算法(Schaum,2004)和线性RX(Williams等,2013)等。此外,其他非RX的全局方法也获得了迅速发展。为了分离异常和背景像素,Kang等(2017)提出了一种基于属性和边缘保持滤波的异常检测方法,该方法先利用属性滤波和布尔映射的融合方法对具有特定区域特性和明显光谱差异的像素进行检测,得到初始检测结果;然后充分利用相邻像素之间的空间相关性,采用边缘保持滤波对初始检测结果进行优化。Du和Zhang(2011)提出了一种基于随机选择的异常检测方法,该方法在高光谱图像上随机选择背景像素并计算其统计信息,然后采用随机选择和融合的方法以避免背景统计数据受到污染,从而实现异常检测任务。Li等(2015)提出了基于背景联合稀疏表示(BJSR)的异常检

测算法,该方法先利用BJSR算法来估计自适应正交背景互补子空间,以自适应地选择最具代表性的背景基;然后,提出了一种无监督自适应子空间模型来抑制背景,同时突出异常分量。由于高光谱图像中背景是低秩的,异常目标是稀疏的,由此Chen和Yang(2014)提出了基于低秩表示(LRR)的异常检测方法,该方法本质是通过低秩表示对背景进行建模,并利用表示残差确定异常目标。Xu等(2016)提出了低秩稀疏表示(LRASR)模型来分离背景和异常。Niu和Wang(2016)通过学习词典改进了LRASR方法,并将张量分解应用于异常检测。

在地物场景比较复杂的高光谱图像中,异常目标通常只在局部范围内与背景之间具有较强对比度,根据全局方法计算对比度通常不准确,由此,研究者们对基于局部的异常检测方法展开研究,该方法通常采用双窗口法来计算待测像素与其局部邻域之间的对比度。Molero等(2013)提出了Local-RX(LRX)检测方法,该方法对高光谱图像中每个像素周围的单个局部窗口应用RX,并通过内外窗口间的像素来估计背景统计信息,实现高光谱异常检测。Li和Du(2015)提出了基于协同表示(CRD)的异常检测方法,该方法假设背景像素可以被其邻域内像素线性表示,而异常像素不能被其线性表示,通过对待测像素构建内外窗口,实现对测试像素的线性表示,并利用表示误差判别异常。在基于稀疏表示的异常检测方法(Paris等,2013;Bacher等,2017;Chen等,2011)中,假设背景字典由窗口外区域的像素组成,这可以很好地用字典表示背景,并对所表示的系数有不同的约束条件;相反,异常则无法很好地用背景字典表示。局部求和异常检测方法(Du等,2016)将待测像素周围相邻局部窗口的多个局部分布与空间—光谱特征相结合,充分考虑了待测像素周围邻域背景分布与局部空间邻域之间的关系,通过综合局部背景统计,实现异常目标检测。

尽管现有基于双窗口的局部对比度计算方法在高光谱异常检测中取得了较好的效果,但是,该类方法通常依据经验值来手工设定双窗口的尺寸,考虑到实际应用中异常目标的尺寸多样性,手工设定窗口尺寸的处理方式会显著降低此类方法的泛化能力。针对上述问题,本文

提出了一种融合自适应窗口显著性检测和改进超像素分割的高光谱异常检测方法 ISPS-AWSD (Hyperspectral Anomaly Detection via Combining Adaptive Window Saliency Detection and Improved Superpixel Segmentation)。如图 1 所示, 本文先利用对抗自编码网络对高光谱图像进行降维, 以降低算法计算的复杂度。其次, 提出一种改进的超像素分割算法对降维后的高光谱图像进行分割, 该算法引入正交投影散度 (Tu 等, 2019) 对超像素分割过程中光谱距离的度量方式进行改进。然

后, 提出了一种自适应窗口显著性检测算法来初步定位异常目标区域, 该算法依据超像素分割结果来自适应确定双窗口, 即: 以每个超像素块作为内窗, 将超像素块的外接四边形扩大后作为对应的外窗, 该设定方式能确保内窗中所有像素具有同质性, 这与异常目标区域内所有像素具有同质性相一致, 从而对异常目标的尺度变化进行自动匹配。最后, 采用域变换递归滤波和阈值化处理对初始检测结果进行后处理, 以获得具有较低虚警率的检测结果。




图1 融合自适应窗口显著性检测和改进超像素分割的高光谱异常检测方法总框图

Fig.1 The framework of hyperspectral anomaly detection via combining adaptive window saliency detection and improved superpixel segmentation

本文的主要贡献如下: (1) 提出了一种基于正交投影散度的高光谱图像超像素分割改进算法。在对高光谱图像进行超像素分割过程中涉及到光谱距离度量, 而常见的欧氏距离、光谱角距离以及光谱信息散度等度量方式受光照条件影响, 因此, 本文引入正交投影散度来改进超像素分割中光谱距离度量方式, 提升高光谱图像的分割精度, 为后续自适应窗口显著性检测提供依据。(2) 提出了一种自适应窗口显著性检测算法。现有的基于双窗口的显著性检测方法通常依据经验值来手工设定双窗口的尺寸, 在实际应用中难以适应异常目标的尺度变化, 因此, 本文提出依据超像素分割结果来自适应地确定双窗口, 确保内窗中所有像素具有同质性, 从而对异常目标的尺度变化进行自动匹配, 提升高光谱异常检测方法的精度和泛化能力。

2 融合自适应窗口显著性检测和改进超像素分割的高光谱异常检测方法 (ISPS-AWSD)

本文所提 ISPS-AWSD 方法总框图如图 1 所示,

该方法主要包含 4 个部分, 按照计算流程依次是: 基于对抗自编码网络的高光谱图像降维、基于正交投影散度的超像素分割、自适应窗口显著性检测以及后处理。

2.1 基于对抗自编码网络的高光谱图像降维

由于高光谱图像具有上百个光谱波段, 有的波段包含很多噪声或其他冗余信息, 不利于异常检测任务, 且逐像素逐波段计算的复杂度太高。

由此, 对高光谱图像进行降维处理十分重要。本文采用对抗自编码网络 (Jiang 等, 2020) 实现高光谱图像降维, 该网络在自编码器 (Larochelle 等, 2007) 的基础上, 通过引入对抗思想, 使重构图像更加逼近原始输入图像, 从而倒逼自编码网络的隐式特征尽可能多的包含原始高光谱图像信息。图 1 所示对抗自编码网络中的隐式特征 z_i 即为降维后的数据。具体细节如下。

整个对抗自编码网络包含两个子网络: 自编码器和判别器。其中自编码器由编码器和解码器共同构成, 分别用于高光谱图像的隐式特征提取和重构, 其数学表达式如下:

$$z_i = f_{\text{En}}(\mathbf{W}_{\text{En}} \mathbf{x}_i + \mathbf{b}_{\text{En}}), \mathbf{x}_i \in \mathbb{R}^{N_1}, z_i \in \mathbb{R}^{N_2} \quad (1)$$

$$\hat{\mathbf{x}}_i = f_{\text{De}}(\mathbf{W}_{\text{De}} z_i + \mathbf{b}_{\text{De}}), \hat{\mathbf{x}}_i \in \mathbb{R}^{N_1} \quad (2)$$

式中, $f_{\text{En}}(\cdot)$ 和 $f_{\text{De}}(\cdot)$ 分别表示编码器和解码器的映射函数, $\mathbf{x}_i$ 表示输入高光谱图像中第 i 个像素的光谱向量, N 表示像素总个数, N_1 表示光谱向量的维数, N_2 表示隐式特征的维数, $\mathbf{W}_{\text{En}}$ 和 $\mathbf{b}_{\text{En}}$ 分别表示编码层的权重和偏置, $\mathbf{W}_{\text{De}}$ 和 $\mathbf{b}_{\text{De}}$ 分别表示解码层的权重和偏置, $\hat{\mathbf{x}}_i$ 表示由 z_i 重构的光谱向量。

自编码器的重构损失函数 L_{re} 表达式为

$$L_{\text{re}} = \|\mathbf{x}_i - \hat{\mathbf{x}}_i\|_2 \quad (3)$$

在对抗学习阶段, 自编码器作为生成器 G , 与判别器 D 共同构成生成式对抗网络, 判别器的两个输入分别为原始光谱向量 $\mathbf{x}_i$ 和重构光谱向量 $\hat{\mathbf{x}}_i$ 。生成器生成的重构光谱向量试图愚弄判别器, 而判别器则努力将 $\hat{\mathbf{x}}_i$ 判别为假, 两者互相博弈, 其对抗损失函数 L_{GAN} 表达式如下:

$$L_{\text{GAN}} = \min_G \max_D \mathbb{E}[\log D(\mathbf{x}_i)] + \mathbb{E}[\log(1 - D(\hat{\mathbf{x}}_i))] \quad (4)$$

式中, $\mathbb{E}$ 表示数学期望。

对抗自编码网络的总损失函数 L 为

$$L = L_{\text{re}} + \alpha \cdot L_{\text{GAN}} \quad (5)$$

式中, α 表示重构损失和生成对抗损失的权衡参数。对抗自编码网络的自监督训练完成后, 将高光谱图像各像素的光谱向量依次输入自编码器中, 获取隐式特征 z_i , 并将所有隐式特征合并, 得到降维后的高光谱图像 Z , 作为后续超像素分割操作的输入。

2.2 基于正交投影散度的超像素分割

为了充分利用高光谱图像中的光谱信息, 尽可能地将异常像素聚合, 本文对降维后的高光谱图像 XZ 进行超像素分割。在现有的超像素分割算法中, 简单线性迭代聚类 SLIC (Simple Linear Iterative Clustering) (Achanta 等, 2012) 具有速度快、分割效率高且边界保持性好的特点, 是目前最常用的超像素分割方法。在高光谱图像 SLIC 超像素分割过程中涉及光谱距离的度量, 现有的度量方式主要采用欧氏距离、光谱角距离或光谱信息散度等, 然而这些方式需要假设像素的光谱值与光照条件之间是线性关系, 但在实际情况中, 这种线性关系往往并不成立, 光谱值会受多种环境因素影响 (Su 等, 2012)。

针对上述问题, 本文提出了一种基于正交投影散度的高光谱图像超像素分割改进算法, 该算法采用正交投影散度来度量光谱距离, 这种度量方式不需要以像素光谱值与光照条件之间存在线性关系为前提。改进后的高光谱图像超像素分割算法具体流程如下:

第一步, 设定超像素块个数 K , 并根据设定的超像素块个数初始化聚类中心。

第二步, 计算 $2S \times 2S$ ($S = \sqrt{N/K}$, 其中 N 为像素总数) 邻域内所有像素与该邻域内所有聚类中心之间的距离, 该距离包括空间距离和光谱距离, 其表达式如下:

$$d_{\text{spatial}}(p_i^Z, p_j^Z) = \sqrt{(r_i^Z - r_j^Z)^2 + (c_i^Z - c_j^Z)^2} \quad (6)$$

$$d_{\text{spectral}}(p_i^Z, p_j^Z) = [(\mathbf{x}_i^Z)^T \mathbf{P}_s^\perp \mathbf{x}_i^Z + (\mathbf{x}_j^Z)^T \mathbf{P}_s^\perp \mathbf{x}_j^Z]^{1/2} \quad (7)$$

$$\mathbf{P}_s^\perp = \mathbf{I} - \mathbf{s}(\mathbf{s}^T \mathbf{s})^{-1} \mathbf{s}^T \quad (\mathbf{s} = \mathbf{x}_i^Z \mathbf{x}_j^Z)$$

$$d_{\text{sum}}(p_i^Z, p_j^Z) = \omega \times d_{\text{spatial}}(p_i^Z, p_j^Z) + (1 - \omega) \times d_{\text{spectral}}(p_i^Z, p_j^Z) \quad (8)$$

式中, p_i^Z 和 p_j^Z 分别表示降维后的高光谱图像 Z 中第 i 和第 j 个像素点, $d_{\text{spatial}}(p_i^Z, p_j^Z)$, $d_{\text{spectral}}(p_i^Z, p_j^Z)$ 和 $d_{\text{sum}}(p_i^Z, p_j^Z)$ 分别代表 p_i^Z 与 p_j^Z 之间的空间距离, 光谱距离以及空间—光谱总距离, (r_i^Z, c_i^Z) 和 (r_j^Z, c_j^Z) 分别表示 p_i^Z 和 p_j^Z 的空间坐标, $\mathbf{x}_i^Z$ 和 $\mathbf{x}_j^Z$ 分别表示 p_i^Z 和 p_j^Z 的光谱向量, $\mathbf{P}_s^\perp$ 表示 $\mathbf{s}$ 的正交子空间, $\mathbf{I}$ 表示单位矩阵, ω 是用于平衡空间距离和光谱距离的权重参数。

第三步, 将所有像素分配至距离其最近的聚类中心, 然后计算每个聚类所有像素的均值, 并以该聚类中距离均值最近的像素作为新的聚类中心, 重复步骤二和三, 直至聚类中心不再变化, 最终得到超像素分割结果 $\text{SP} = \{sp_1, \dots, sp_g, \dots, sp_K\}$ 。

图 2 给出了采用 4 种不同光谱距离度量方式的超像素分割图, 与其他 3 种光谱距离度量方法相比, 基于正交投影散度的超像素分割算法具有更好的分割效果, 即: 更有效度量异常目标与背景之间的差异, 为后续自适应窗口显著性检测提供依据。

2.3 自适应窗口显著性检测

Itti 等 (1998) 指出与局部邻域具有较强对比度的图像区域往往能吸引人眼注意, 即: 具有较强显著性, 而在高光谱图像中, 异常目标区域与其邻域通常也具有较强对比度, 因此, 本文提出通过显著性检测来检测异常目标区域。




图2 4种不同光谱距离的超像素分割图

Fig.2 Superpixel segmentation diagram of four different spectral distances

受 Itti 等 (1998) 启发, 如图 3 所示, 本文采用双窗口法来计算高光谱图像的显著性, 即: 以内窗与其邻域 (内外窗之间的区域) 之间的对比度来定义显著性, 但现有双窗口的设计方式存在缺陷, 本文因此提出了一种自适应窗口显著性检测算法。具体细节如图 3 所示。




图3 传统方法与本文方法的双窗口设计方式对比
Fig.3 Comparison of dual window design method between traditional method and this method

如图 3(a) 所示, 传统待测像素的局部窗口通常由矩形内外窗构成, 这种双窗口设计方式是以待测像素为中心, 内窗尺寸 R_{inner} 和外窗尺寸 R_{outer} 是依据经验值来手工设定, 在实际应用中难以适

应异常目标的尺度变化, 因此, 为了提高检测精度和泛化能力, 本文提出了一种自适应窗口显著性检测算法。如图 3(b) 所示, 对任意待测像素, 将包含该像素的超像素块作为其内窗 (绿色实线框), 寻找该超像素块的外接四边形 (绿色虚线框) 并以特定尺寸进行放大, 获取该像素的外窗 (红色实线框), 内外窗间距为 R 。显然, 本文设计的内外窗是由超像素分割结果自适应确定, 该设计思路能确保内窗中所有像素具有同质性, 这与异常目标区域内所有像素具有同质性相一致, 从而对异常目标的尺度变化进行自动匹配。

在内外窗确定后, 高光谱图像的显著性计算 (Goferman 等, 2012; Tan 等, 2014) 如下:

$$d_{\text{spectral}}(p_i, p_h^{sp_g}) = \arccos \left(\frac{\langle \mathbf{x}_i, \mathbf{x}_h^{sp_g} \rangle}{|\mathbf{x}_i| \cdot |\mathbf{x}_h^{sp_g}|} \right), p_i \in sp_g, h \in [1, H] \quad (9)$$

$$d_{\text{position}}(p_i, p_h^{sp_g}) = \sqrt{(r_i - r_h^{sp_g})^2 + (c_i - c_h^{sp_g})^2} \quad (10)$$

$$d_{\text{contrast}}(p_i, p_h^{sp_g}) = \frac{d_{\text{spectral}}(p_i, p_h^{sp_g})}{1 + C \cdot d_{\text{position}}(p_i, p_h^{sp_g})} \quad (11)$$

$$d_{\text{saliency}}(p_i) = \frac{\sum_{h=1}^H d_{\text{contrast}}(p_i, p_h^{sp_g})}{H} \quad (12)$$

式中, p_i 表示高光谱图像中第 i 个像素点 (位于超像素块 sp_g 内), $p_h^{sp_g}$ 表示 sp_g 对应邻域内第 h 个像素点, H 表示 sp_g 对应邻域内像素点的数量, $\mathbf{x}_i$ 和 $\mathbf{x}_h^{sp_g}$ 分别表示 p_i 和 $p_h^{sp_g}$ 的光谱向量, $\langle \cdot \rangle$ 表示内积运算, $|\cdot|$ 表示向量的模, (r_i, c_i) 和 $(r_h^{sp_g}, c_h^{sp_g})$ 分别表示 p_i 和 $p_h^{sp_g}$ 的空间坐标, C 为常量, $d_{\text{spectral}}(p_i, p_h^{sp_g})$, $d_{\text{position}}(p_i, p_h^{sp_g})$ 和 $d_{\text{contrast}}(p_i, p_h^{sp_g})$ 分别表示 p_i 和 $p_h^{sp_g}$ 之间的光谱角距离, 欧氏距离和对比度, $d_{\text{saliency}}(p_i)$ 表示 p_i 的显著值。根据式 (12) 将所有像素点的显著值计算完成后, 可得到高光谱图像的显著图, 以此作为高光谱异常检测的初始检测结果 IR 。

2.4 后处理

为了降低虚警率, 本文对初始检测结果 IR 进行后处理, 后处理操作主要包括两部分: 图像滤波和阈值化处理。图像滤波部分, 本文采用域变换递归滤波方法 (Gastal 和 Oliveira, 2011); 阈值化处理部分, 本文采用 OTSU 算法 (Otsu, 1979) 来自适应地选择阈值, 进而获取二值化结果并用于排除较大的异常目标。

(1) 域变换递归滤波。为了滤波后的图像不失真, 通常采用具有边缘保持特性的滤波方法, 常用的边缘保持滤波方法有双边滤波器 (Tomasi 和 Manduchi, 1998) 和各向异性扩散 (Perona 和 Malik, 1990) 等, 前者需要变换至高维空间进行计算, 后者需要迭代计算, 均具有较高的计算复杂度。本文采用的域变换递归滤波既有边缘保持特性, 又具有较低的计算复杂度。

以初始检测结果 IR 作为输入图像, 以降维后的高光谱图像 Z 作为引导图像, 则域变换递归滤波后的图像 J 可由下式获取 (Gastal 和 Oliveira, 2011):

$$\begin{aligned} J_i &= (1 - a^b)IR_i + a^b J_{i-1} \\ a &= e^{-\sqrt{2}/\sigma_s} \\ b &= \frac{\sigma_s}{\sigma_r} \|\mathbf{x}_i^Z - \mathbf{x}_{i-1}^Z\|_1 \end{aligned} \quad (13)$$

式中, IR_i 表示 IR 中第 i 个像素点的值, J_i 和 J_{i-1} 分别表示 J 中第 i 和第 $i-1$ 个像素点的值, a 表示反馈系数, b 表示相邻像素间的相似性, σ_s 和 σ_r 用于控制滤波平滑度的参数。

(2) 阈值化处理。为了进一步降低虚警率, 本文对滤波后的图像 J 进行阈值化处理:

$$ER_i = \begin{cases} 1, & J_i \geq TH \\ 0, & \text{其他} \end{cases} \quad (14)$$

式中, ER_i 表示二值化结果 ER 第 i 个像素点的值, TH 是采用 OTSU 算法 (Otsu, 1979) 获取的阈值。最后, 利用二值化结果 ER , 排除图像 J 中较大的异常目标 (Kang 等, 2017)。


3 实验结果与分析

3.1 实验设置

3.1.1 数据集

本文采用 San Diego- I (Chen 和 Yang, 2014), San Diego- II (Tomasi 和 Manduchi, 1998), Bay Champagne (Williams 等, 2013), Cat Island (Xie 等, 2019) 和 Los Angeles (Williams 等, 2013) 5 个数据集进行实验对比。

(1) San Diego- I 数据集是由机载可见光/红外成像光谱仪 (AVIRIS) 传感器采集的高光谱影像。该传感器的空间分辨率为 3.5 m, 该高光谱影像像素为 400×400, 覆盖了美国加利福尼亚州的圣地亚哥机场区域。最初的波段数为 224 个, 分布在 370—2510 nm 波长范围内, 去除无用的波段后仍保留 189 个波段。该数据集中的异常之处在于机场上有几架飞机, 如图 4(a) 所示。



(a) San Diego- I 数据集 (b) San Diego- II 数据集 (c) Cat Island 数据集 (d) Bay Champagne 数据集 (e) Los Angeles 数据集
(a) San Diego- I dataset (b) San Diego- II dataset (c) Cat Island dataset (d) Bay Champagne dataset (e) Los Angeles dataset

图 4 5 个公开数据集的伪彩图和真值图

Fig.4 The pseudo color maps and ground truth of five public datasets

(2) San Diego- II 数据集是由机载可见光/红外成像光谱仪 (AVIRIS) 传感器采集的高光谱影像。该数据集像素大小为 100×100, 具有 189 个有效频谱波段, 排除了低信噪比或其他不良波段, 波长范围为 370—2510 nm, 其中 3 架白色飞机被选为预

期的异常目标, 如图 4(b) 所示。

(3) Cat Island 数据集也是由 AVIRIS 传感器采集的猫岛场景, 该数据集的空间像素为 100×100, 光谱波段为 193, 原始图像中的噪声带已被移除。图像的主要背景是海洋和岛屿, 而在这个场景中

有19个空间像素的船被视为异常,伪彩色图像和真值图如图4(c)所示。

(4) Bay Champagne 数据集是由 AVIRIS 传感器采集的高光谱影像,该影像的空间分辨率为4.4 m,包含188个波段,场景覆盖区域的像素为100×100,异常共由11个像素组成,对应的伪彩图和真值图如图4(d)所示。

(5) Los Angeles 数据集是由机载可见光/红外成像光谱仪(AVIRIS)传感器获得的洛杉矶场景,具有205个波段和7.1 m的空间分辨率,场景由100×100像素组成,异常目标为建筑物,总共占据272个像素,伪彩图和真值图如图4(e)所示。

3.1.2 评估指标

本文采用3个最常用的指标来定量评估本文所提方法的性能。

(1) 受试者工作特征曲线 ROC (Receiver Operating Characteristic Curve) (Bradley, 1997)。ROC 由基于真值图的各种阈值 τ 下的真阳性率 (TPR) 和假阳性率 (FPR) 绘制,该指标可以从检测精度和虚警率两个方面来评估检测性能。在相同的虚警条件下,当检测概率高于其他检测器时,异常检测器的性能更好。

(2) AUC (Area Under Roc Curve) (Flach 等, 2011)。AUC 是 ROC 曲线下的面积。AUC 值越接近1,说明检测性能越好。

(3) 异常背景可分性箱线图 (Manolakis 和 Shaw, 2002)。该指标得出的是可分性范围,它表示不同检测方法从背景中提取异常的能力,检测方法越好,异常和背景之间的分离越明显。

3.1.3 对比算法

本文与7种主流的异常检测方法进行对比,主要包括 RX (Reed 和 Yu, 1990)、LRX (Molero 等, 2013)、CRD (Li 等, 2015)、LSMAD (Zhang 等, 2016)、LRASR (Xu 等, 2016)、AED (Kang 等, 2017) 和 LSDM-MoG (Li 等, 2021)。其中, RX 通过计算测试像素和图像背景之间的马氏距离实现异常目标的检测,是无监督异常检测领域中广泛使用的检测方法; LRX 通过计算测试像素和局部图像背景之间的距离来检测异常,是基于 RX 改进的方法; CRD 使用相邻像素进行协同表示,以实现异常检测; LSMAD 和 LRASR 是两种典型的基

于低秩和稀疏表示的异常检测方法; AED 是基于形态学的异常检测方法; LSDM-MoG 在低秩稀疏分解模型中引入混合噪声模型,从而更准确的描述复杂的背景分布。

3.1.4 实验细节

2.1 节中,自编码器包含5层,节点数分别为(200, 80, 40, 80, 200),判别器包含4层,节点数分别为(200, 80, 40, 1),激活函数均采用 Leaky ReLU,负值斜率为0.2;对抗自编码网络的优化器采用 Adam,自编码器和判别器的学习率分别为 $1E-3$ 和 $1E-4$,总迭代次数为500次。2.1 节中,式(1)中 N_z 设置为40;式(5)中 α 设置为0.1。2.2 节中,超像素块数量 $K=300$;式(8)中 w 设置为0.1。2.3 节中,内外窗间距 $R=6$ 。2.4 节中,式(9)中 C 设置为1。

对抗自编码网络的处理过程均在 GeForce RTX2080Ti 显卡上,其运行环境为 python 3.6.13、Pytorch 1.8.2 以及 CUDA 10.2。同时,所有对比算法运行环境均在 MATLAB R2017b。

3.2 实验结果对比及分析

3.2.1 主观对比

本文方法与7种流行方法的主观对比结果如图5所示。如图5(a)所示,LRX 的结果完全未检测出异常目标,LRASR 和 AED 的异常检测效果相对较好,但是本文方法检测效果最佳,即:异常目标区域与背景区域之间对比度最高,异常目标的位置和轮廓定位最准。如图5(b)所示,LRX 仍然未检测出异常目标,AED 和本文方法对异常目标的检测效果更好,但 AED 的检测结果中有其他被误检的背景目标,本文方法既能精确地检测出异常目标,同时在背景区域又具有较低的误检率。如图5(c)和(d)所示,LRASR 在两个数据集上都将沙滩、海面等背景误检为异常,AED 和本文方法对异常目标的检测效果一如既往的稳定,异常目标的位置明确,但是在 Cat Island 数据集上,AED 还是误检出部分背景,本文方法依然具有较低的误检率。如图5(e)所示,LRX、CRD 和 LSMAD 的异常检测结果很差,仍然是 AED 检测效果更好,但与本文方法相比,存在漏检异常目标的问题。总体来看,在7种流行方法中,AED 的检测效果相

对较好, 但本文方法相比 AED 检测效果更好, 主要体现在两个方面: 对于异常目标, 本文方法漏检更少, 且异常目标区域与背景区域之间具有更高对比度; 在背景区域, 本文方法误检更少。




图5 本文方法与7种流行方法在5个数据集上的主观对比
Fig.5 Subjective comparisons between the proposed method and 7 state-of-the-art methods on five datasets

3.2.2 客观对比

如表1所示, 本文方法在5个数据集上的AUC结果均为第一, 综合表现最好; 在7种流行方法中, AED的AUC结果在4个数据集上排名第二,

1个数据集上排名第三, 综合表现仅次于本文方法, 这与主观对比的结论一致。观察图6可以得到同样的结论, 即: 本文方法的ROC曲线最高, AED次之。

表1 本文方法与7种流行方法在5个数据集上的AUC对比

检测算法	数据集				
	San Diego- I	San Diego- II	Cat Island	Bay Champagne	Los Angeles
RX	0.9403	0.9111	0.9807	0.9999	0.9887
LRX	0.8428	0.6929	0.9956	0.9995	0.8081
CRD	0.9412	0.9791	0.9916	0.9998	0.9794
LSMAD	0.9701	0.9731	0.9661	0.9997	0.9814
LRASR	0.8950	0.9853	0.4203	0.7536	0.8748
AED	0.9846	0.9979	0.9974	0.9997	0.9912
LSDM-MoG	0.9339	0.9320	0.9942	0.9996	0.9745
ISPS-AWSD	0.9850	0.9996	0.9999	0.9999	0.9934

注: 黑色粗体为最优的AUC结果。

为了进一步比较本文方法与7种异常检测方法的检测性能, 图7分别绘制了5个数据集上各检测方法的异常背景可分性箱线图。与其他7种异常检

测方法相比, 本文方法在各数据集上的红框下限和绿框上限之间的距离更大, 表明本文方法对异常目标区域与背景区域的可分性更好。




图6 本文方法与7种流行方法在5个数据集上的ROC曲线对比

Fig.6 Comparisons of ROC curves between the proposed method and seven state-of-the-art methods on five datasets




图7 本文方法与7种流行方法在5个数据集上的异常背景可分性箱线图对比

Fig.7 Comparisons of abnormal background separability boxplot between the proposed method and seven state-of-the-art methods on five datasets

基于上述分析, 可以确认本文方法总体性能优于对比的 7 种方法, 是一种非常有竞争力的异常检测方法。

3.2.3 消融实验

本节对引言中所提的两个创新点进行逐一验证。

(1) 基于正交投影散度的高光谱图像超像素分割改进算法的有效性验证。表 2 将超像素分割改

进算法中采用的正交投影散度与欧氏距离、光谱角距离以及光谱信息散度这 3 种常用光谱距离度量方式在 5 个数据集上进行了 AUC 值对比, 为保证实验的公平性, 除光谱距离度量方式外, 其余设置均保持一致。如表 2 所示, 采用正交投影散度的 AUC 值在 5 个数据集上均优于其他 3 种光谱距离度量方式。这表明采用正交投影散度来度量光谱距离可以有效提升超像素分割的效果。

表 2 本文方法在 4 种不同光谱距离下的 AUC 值

Table 2 The AUC values of the proposed method at four different spectral distances

数据集	度量方式			
	欧氏距离	光谱角距离	光谱信息散度	正交投影散度
San Diego- I	0.9840	0.9840	0.9843	0.9850
San Diego- II	0.9976	0.9976	0.9978	0.9996
Cat Island	0.9947	0.9948	0.9962	0.9999
Bay Champagne	0.9952	0.9952	0.9963	0.9999
Los Angeles	0.9902	0.9902	0.9916	0.9934

注: 黑色粗体为最优的 AUC 结果。

(2) 自适应窗口显著性检测算法的有效性验证。表 3 将采用自适应窗口与 4 种手工设定尺寸的双窗口在 5 个数据集上进行了 AUC 值对比, 为保证实验的公平性, 除内窗尺寸外 (外窗由内窗按照固定间距 R 扩充所得, 如图 3 所示), 其余设置

均保持一致。如表 3 所示, 采用自适应窗口的 AUC 值在 5 个数据集上均优于四种手工设定尺寸的双窗口的 AUC 值, 尤其在 Los Angeles 数据集上, 与第二名得分相比提升了 10 个百分点。上述分析充分表明本文所提自适应窗口显著性检测算法的有效性。

表 3 本文方法在 2 种不同窗口设置下的 AUC 值

Table 3 The AUC values of the proposed method under two different window settings

数据集	内窗尺寸				
	3	5	7	9	自适应
San Diego- I	0.9763	0.9782	0.9803	0.9821	0.9850
San Diego- II	0.9968	0.9971	0.9960	0.9950	0.9996
Cat Island	0.9921	0.9872	0.9826	0.9795	0.9999
Bay Champagne	0.9876	0.9896	0.9920	0.9823	0.9999
Los Angeles	0.8924	0.8696	0.8642	0.8539	0.9934

注: 黑色粗体为最优的 AUC 结果。

3.3 参数分析

本节将与算法性能密切相关的超像素块数量 K 、内外窗间距 R 以及域变换递归滤波中的平滑度参数 σ_s 和 σ_r 进行参数分析。

图 8 给出了 AUC 值随 K 值变化的曲线, 在 4 个公开的数据集上 (除 Cat Island 外), AUC 值均呈现先上升后下降的趋势, 且均在 $K=300$ 时取得最大值; Cat Island 数据集在 $K=300$ 时的 AUC 取值与最

大值较为接近。综合分析, $K=300$ 时本文方法取得最佳效果。

图 9 给出了 AUC 值随 R 值变化的曲线, 在 San Diego-I 和 Los Angeles 数据集上, AUC 均在 $R=6$ 时取得最大值; 其余 3 个数据集的 AUC 值对 R 的变化不敏感。综合分析, $R=6$ 时本文方法取得最佳效果。

图 10 给出了 AUC 值随 σ_s 和 σ_r 值变化的三维立

体图, 在 San Diego-I 和 Los Angeles 数据集上, AUC 均在 $\sigma_s=1$ 时取得最大值, 其中 San Diego-I 数据集在 $\sigma_r=20$ 时 AUC 值最大, Los Angeles 数据集在 $\sigma_r=$

20 和 30 时 AUC 值接近; 其余 3 个数据集对 σ_s 和 σ_r 的变化不敏感。综合分析, $\sigma_s=1$, $\sigma_r=20$ 时本文方法取得最佳效果。




图8 超像素块数量 K 对检测性能的影响

Fig.8 Effect of superpixel block number K on detection performance




图9 内-外框间距 R 对检测性能的影响

Fig.9 Effect of inner-outer frame spacing R on detection performance




图10 域变换递归滤波的平滑度参数 σ_s 和 σ_r 对检测性能的影响

Fig. 10 Influence of smoothness parameters σ_s and σ_r of domain transform recursive filtering on detection performance.

4 结 论

本文提出了一种融合自适应窗口显著性检测和改进超像素分割的高光谱异常检测方法并得到以下结论:

(1) 现有高光谱图像超像素分割算法常采用欧氏距离、光谱角距离或光谱信息散度等方式进行光谱距离度量, 然而这些方式需要假设像素的光谱值与光照条件之间是线性关系, 但实践中这种假设一般不成立。本文采用的正交投影散度能

突破上述假设的限制, 消融实验结果表明, 基于正交投影散度的改进超像素分割算法优于现有超像素分割算法的表现。

(2) 现有基于局部对比度的高光谱异常检测方法通常采用双窗口法, 但该类方法通常根据经验值来设置双窗口尺寸, 难以适应异常目标的尺度变化, 泛化能力不足。考虑到异常目标区域内像素间的同质性, 本文在超像素分割的基础上自适应地设定双窗口尺寸, 确保内窗中所有像素具有同质性, 从而自动匹配异常目标的尺度变化, 解决了传统双窗口法泛化能力不足的问题。消融实验结果表明, 自适应窗口显著性检测算法的性能优于现有双窗口算法。

(3) 在5个公开的数据集上与7种流行方法的主观对比结果表明, 本文方法对异常目标的漏检更少, 在背景区域的误检更低, 且异常目标区域与背景区域之间具有更强对比度; 客观对比结果表明, 本文方法的总体检测精度和异常背景可分性均优于7种流行方法, 充分验证了本文方法的优越性。

在内、外窗尺寸确定后, 本文和流行方法通常采用空间和光谱距离来度量内窗区域的显著性, 并据此进行高光谱异常检测。随着深度学习技术的快速发展, 后续研究将尝试利用内、外窗区域的深度学习特征来度量内、外窗区域之间的对比度, 并以此定义内窗区域的显著性。

参考文献(References)

- Achanta R, Shaji A, Smith K, Lucchi A, Fua P and Süsstrunk S. 2012. SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(11): 2274-2282 [DOI: 10.1109/TPAMI.2012.120]
- Bacher R, Meillier C, Chatelain F and Michel O. 2017. Robust control of varying weak hyperspectral target detection with sparse non-negative representation. *IEEE Transactions on Signal Processing*, 65(13): 3538-3550 [DOI: 10.1109/TSP.2017.2688965]
- Bioucas-Dias J M, Plaza A, Camps-Valls G, Scheunders P, Nasrabadi N and Chanussot J. 2013. Hyperspectral remote sensing data analysis and future challenges. *IEEE Geoscience and Remote Sensing Magazine*, 1(2): 6-36 [DOI: 10.1109/MGRS.2013.2244672]
- Bradley A P. 1997. The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30(7): 1145-1159 [DOI: 10.1016/S0031-3203(96)00142-2]
- Chen J H and Yang J. 2014. Robust subspace segmentation via low-rank representation. *IEEE Transactions on Cybernetics*, 44(8): 1432-1445 [DOI: 10.1109/TCYB.2013.2286106]
- Chen Y, Nasrabadi N M and Tran T D. 2011. Simultaneous joint sparsity model for target detection in hyperspectral imagery. *IEEE Geoscience and Remote Sensing Letters*, 8(4): 676-680 [DOI: 10.1109/LGRS.2010.2099640]
- Du B and Zhang L P. 2011. Random-selection-based anomaly detector for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 49(5): 1578-1589 [DOI: 10.1109/TGRS.2010.2081677]
- Du B, Zhao R, Zhang L P and Zhang L F. 2016. A spectral-spatial based local summation anomaly detection method for hyperspectral images. *Signal Processing*, 124: 115-131 [DOI: 10.1016/j.sigpro.2015.09.037]
- Flach P, Hernández-Orallo J and Ferri C. 2011. A coherent interpretation of AUC as a measure of aggregated classification performance//*Proceedings of the 28th International Conference on International Conference on Machine Learning*. Bellevue: Omnipress: 657-664
- Gastal E S L and Oliveira M M. 2011. Domain transform for edge-aware image and video processing. *ACM Transactions on Graphics*, 30(4): 69 [DOI: 10.1145/2010324.1964964]
- Goferman S, Zelnik-Manor L and Tal A. 2012. Context-aware saliency detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(10): 1915-1926 [DOI: 10.1109/TPAMI.2011.272]
- Guo Q D, Zhang B, Ran Q, Gao L R, Li J and Plaza A. 2014. Weighted-RXD and linear filter-based RXD: improving background statistics estimation for anomaly detection in hyperspectral imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6): 2351-2366 [DOI: 10.1109/JSTARS.2014.2302446]
- Itti L, Koch C and Niebur E. 1998. A model of saliency-based visual attention for rapid scene analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(11): 1254-1259 [DOI: 10.1109/34.730558]
- Jiang T, Li Y S, Xie W Y and Du Q. 2020. Discriminative reconstruction constrained generative adversarial network for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 58(7): 4666-4679 [DOI: 10.1109/TGRS.2020.2965961]
- Kang X D, Zhang X P, Li S T, Li K L, Li J and Benediktsson J A. 2017. Hyperspectral anomaly detection with attribute and edge-preserving filters. *IEEE Transactions on Geoscience and Remote Sensing*, 55(10): 5600-5611 [DOI: 10.1109/TGRS.2017.2710145]
- Kwon H and Nasrabadi N M. 2005. Kernel RX-algorithm: a nonlinear anomaly detector for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 43(2): 388-397 [DOI: 10.1109/TGRS.2004.841487]
- Larochelle H, Erhan D, Courville A, Bergstra J and Bengio Y. 2007. An empirical evaluation of deep architectures on problems with many factors of variation//*Proceedings of the 24th International Conference on Machine Learning*. Corvallis: Association for Computing Machinery: 473-480 [DOI: 10.1145/1273496.1273556]
- Li J Y, Zhang H Y, Zhang L P and Ma L. 2015. Hyperspectral anomaly

- detection by the use of background joint sparse representation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6): 2523-2533 [DOI: 10.1109/JSTARS.2015.2437073]
- Li L, Li W, Du Q and Tao R. 2021. Low-rank and sparse decomposition with mixture of gaussian for hyperspectral anomaly detection. *IEEE Transactions on Cybernetics*, 51(9): 4363-4372 [DOI: 10.1109/TCYB.2020.2968750]
- Li S T, Zhang K Z, Hao Q B, Duan P H and Kang X D. 2018. Hyperspectral anomaly detection with multiscale attribute and edge-preserving filters. *IEEE Geoscience and Remote Sensing Letters*, 15(10): 1605-1609 [DOI: 10.1109/LGRS.2018.2853705]
- Li W and Du Q. 2015. Collaborative representation for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 53(3): 1463-1474 [DOI: 10.1109/TGRS.2014.2343955]
- Liu Z X, Ma L and Du Q. 2021. Class-wise distribution adaptation for unsupervised classification of hyperspectral remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 59(1): 508-521 [DOI: 10.1109/tgrs.2020.2997863]
- Manolakis D and Shaw G. 2002. Detection algorithms for hyperspectral imaging applications. *IEEE Signal Processing Magazine*, 19(1): 29-43 [DOI: 10.1109/79.974724]
- Molero J M, Garzon E M, Garcia I and Plaza A. 2013. Analysis and optimizations of global and local versions of the RX algorithm for anomaly detection in hyperspectral data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(2): 801-814 [DOI: 10.1109/JSTARS.2013.2238609]
- Niu Y B and Wang B. 2016. Hyperspectral anomaly detection based on low-rank representation and learned dictionary. *Remote Sensing*, 8(4): 289 [DOI: 10.3390/rs8040289]
- Otsu N. 1979. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1): 62-66 [DOI: 10.1109/TSMC.1979.4310076]
- Paris S, Mary D and Ferrari A. 2013. Detection tests using sparse models, with application to hyperspectral data. *IEEE Transactions on Signal Processing*, 61(6): 1481-1494 [DOI: 10.1109/TSP.2013.2238533]
- Perona P and Malik J. 1990. Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(7): 629-639 [DOI: 10.1109/34.56205]
- Peyghambari S M and Zhang Y. 2021. Hyperspectral remote sensing in lithological mapping, mineral exploration, and environmental geology: an updated review. *Journal of Applied Remote Sensing*, 15(3): 031501 [DOI: 10.1117/1.JRS.15.031501]
- Qian X L, Li J, Cheng G, Yao X W, Zhao S N, Chen Y B and Jiang L Y. 2018. Evaluation of the effect of feature extraction strategy on the performance of high-resolution remote sensing image scene classification. *Journal of Remote Sensing*, 22(5): 758-776 (钱晓亮, 李佳, 程焱, 姚西文, 赵素娜, 陈宜滨, 姜利英. 2018. 特征提取策略对高分辨率遥感图像场景分类性能影响的评估. *遥感学报*, 22(5): 758-776) [DOI: 10.11834/jrs.20188015]
- Qian X L, Lin S, Cheng G, Yao X W, Ren H L and Wang W. 2020. Object detection in remote sensing images based on improved bounding box regression and multi-level features fusion. *Remote Sensing*, 12(1): 143 [DOI: 10.3390/rs12010143]
- Reed I S and Yu X. 1990. Adaptive multiple-band cfar detection of an optical pattern with unknown spectral distribution. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 38(10): 1760-1770 [DOI: 10.1109/29.60107]
- Schaum A. 2004. Joint subspace detection of hyperspectral targets// *Proceedings of the 2004 IEEE Aerospace Conference. Big Sky: IEEE*: 1818-1824 [DOI: 10.1109/AERO.2004.1367963]
- Stein D W J, Beaven S G, Hoff L E, Winter E M, Schaum A P and Stocker A D. 2002. Anomaly detection from hyperspectral imagery. *IEEE Signal Processing Magazine*, 19(1): 58-69 [DOI: 10.1109/79.974730]
- Su H J, Du P J and Du Q. 2012. Semi-supervised dimensionality reduction using orthogonal projection divergence-based clustering for hyperspectral imagery. *Optical Engineering*, 51(11): 111715 [DOI: 10.1117/1.OE.51.11.111715]
- Tan K, Li E Z, Du Q and Du P J. 2014. Hyperspectral image classification using band selection and morphological profiles. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(1): 40-48 [DOI: 10.1109/JSTARS.2013.2265697]
- Tomasi C and Manduchi R. 1998. Bilateral filtering for gray and color images//*Proceedings of the Sixth International Conference on Computer Vision. Bombay: IEEE*: 839-846 [DOI: 10.1109/ICCV.1998.710815]
- Tu B, Zhang X F, Kang X D, Zhang G Y and Li S T. 2019. Density peak-based noisy label detection for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 57(3): 1573-1584 [DOI: 10.1109/TGRS.2018.2867444]
- Vanegas F, Bratanov D, Powell K, Weiss J and Gonzalez F. 2018. A novel methodology for improving plant pest surveillance in vineyards and crops using UAV-based hyperspectral and spatial data. *Sensors*, 18(1): 260 [DOI: 10.3390/s18010260]
- Williams J P, Bihl T J and Bauer K W. 2013. Towards the mitigation of correlation effects in anomaly detection for hyperspectral imagery. *The Journal of Defense Modeling and Simulation: Applications, Methodology, Technology*, 10(3): 263-273 [DOI: 10.1177/1548512912473679]
- Xie W Y, Lei J, Liu B Z, Li Y S and Jia X P. 2019. Spectral constraint adversarial autoencoders approach to feature representation in hyperspectral anomaly detection. *Neural Networks*, 119: 222-234 [DOI: 10.1016/j.neunet.2019.08.012]
- Xu Y, Wu Z B, Li J, Plaza A and Wei Z H. 2016. Anomaly detection in hyperspectral images based on low-rank and sparse representation. *IEEE Transactions on Geoscience and Remote Sensing*, 54(4): 1990-2000 [DOI: 10.1109/TGRS.2015.2493201]
- Zhang Y X, Du B, Zhang L P and Wang S G. 2016. A low-rank and sparse matrix decomposition-based mahalanobis distance method for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 54(3): 1376-1389 [DOI: 10.1109/TGRS.2015.2479299]

Hyperspectral anomaly detection via combining adaptive window saliency detection and improved superpixel segmentation

QIAN Xiaoliang¹, ZENG Yinfeng¹, LIN Sheng², ZHANG Bo³, REN Hangli¹, WANG Wei¹

1.College of Electric and Information Engineering, Zhengzhou University of Light Industry, Zhengzhou 450002, China;

2.School of Aerospace Science and Technology, Xidian University, Xi'an 710126, China;

3.College of Information Science and Engineering, Henan University of Technology, Zhengzhou 450001, China

Abstract: Hyperspectral anomaly detection is used to identify pixels with significant spectral contrast to their surrounding pixels. It plays a valuable role in military and civilian fields due to the characteristic that the priori spectral information is not required. The existing local contrast-based methods usually adopt dual rectangular window scheme for hyperspectral anomaly detection. However, they empirically set the size of dual window, which limits their generalization capability.

A hyperspectral anomaly detection method via combining adaptive window saliency detection and improved superpixel segmentation is proposed in this study to address the abovementioned issue. An adversarial autoencoder is first introduced to reduce the dimension of the hyperspectral image for decreasing the computation complexity of the proposed method. Second, the dimension-reduced hyperspectral image is segmented by improved superpixel segmentation. The existing spectral distance measurements used in the superpixel segmentation are effective when the relationship between the spectral value and the intensity of each pixel is linear. However, this condition cannot be guaranteed in practical applications. The improved superpixel segmentation adopts the orthogonal projection divergence to measure the spectral distance for solving the aforementioned problem. Thereafter, an adaptive window-based saliency detection algorithm is proposed and used to obtain the initial detection results. Specifically, the size of the inner window is adaptively determined by the superpixels, which ensures that the pixels belonging to the same inner window are homogeneous. The outer window can be obtained by enlarging the inner window with fixed size. Finally, the domain transform recursive filter and thresholding operation are employed to optimize the initial detection results for reducing the false alarm rate.

The comparisons between the orthogonal projection divergence and three common spectral distance measurements (Euclidean distance, spectral angular mapping, and spectral information divergence) in terms of AUC show that the orthogonal projection divergence-based method achieves the highest score on all five datasets. The comparisons between the adaptive window and traditional manual setting dual window in terms of AUC show that the adaptive window-based method achieves the highest score on all five datasets. Comprehensive comparisons between the proposed method and seven state-of-the-art methods on five public datasets are implemented to validate the overall performance of the proposed method. Specifically, the subjective comparisons show that the anomalous pixels detected by the proposed method are more precise and have stronger contrast to background regions. The objective comparisons demonstrate that the proposed method obtains the highest overall detection accuracy and offers the best separability between the anomalous and background pixels.

Three conclusions can be derived from this study. First, the improved superpixel segmentation algorithm can enhance the segmentation results, and the proposed adaptive window scheme can increase the performance of saliency detection. Second, the proposed method has excellent detection accuracy, false alarm rate, and separability between the anomalous and background pixels. Finally, the overall performance of the proposed method is superior to that of state-of-the-art methods.

Key words: anomaly detection, hyperspectral image, orthogonal projection divergence, superpixel segmentation, adaptive window, saliency detection

Supported by National Natural Science Foundation of China (No. 62076223, 62003311); Key Science and Technology Program of Henan Province (No. 232102211018); Natural Science Foundation of Henan Province (No. 202300410503)