

约束能量最小化变分自编码的高光谱目标检测

周琨¹, 徐洋^{1,2}, 魏洁¹, 吴泽彬^{1,2}, 韦志辉^{1,2}

1. 南京理工大学 计算机科学与工程学院, 南京 210094;

2. 南京理工大学 江苏省光谱成像与智能感知重点实验室, 南京 210094

摘要: 目标检测是高光谱领域中一个重要的研究方向, 高光谱目标检测 (hyperspectral target detection) 是根据目标的光谱特征将像素判断为背景或者目标。在过去的几十年中已经提出了很多的检测算法, 但是高光谱图像中背景样本的复杂性以及目标样本的有限性, 使得检测算法面临着很大的挑战。本文提出了一种基于背景重构的高光谱目标检测算法, 利用高光谱图像中背景样本占比较大的特点, 训练背景样本自表示模型, 然后重构出背景。同时利用约束能量最小化对残差图像进行检测, 将重构出的背景用于自相关矩阵计算, 避免目标样本参与计算影响目标样本的响应能量, 提高了检测的精确度。在真实的高光谱图像数据上结果明显优于对比实验, 验证了该方法的有效性和高效性。

关键词: 遥感, 高光谱, 目标检测, 背景重构, 约束能量最小化, 自相关矩阵

中图分类号: TP701/P2

引用格式: 周琨, 徐洋, 魏洁, 吴泽彬, 韦志辉. 2024. 约束能量最小化变分自编码的高光谱目标检测. 遥感学报, 28(1): 78-87

Zhou K, Xu Y, Wei J, Wu Z B and Wei Z H. 2024. Hyperspectral target detection based on constrained energy minimization variational autoencoder. National Remote Sensing Bulletin, 28(1): 78-87 [DOI:10.11834/jrs.20232225]

1 引言

高光谱图像 HSI (Hyperspectral Image) 是利用成像光谱仪在电磁波谱的紫外、可见光、近红外、短波红外甚至长波红外区域内成像, 其光谱分辨率高达纳米数量级, 光谱波段多达数百个, 且各个光谱波段间通常连续 (Tong 等, 2006)。高光谱图像是一个数据立方体, 每层图像对应一个光谱波段, 每个像素点对应一条光谱曲线, 对于地物的判别具有诊断的信息 (Liu, 2021)。目标检测是高光谱领域的一个重要研究方向。高光谱目标检测在给定先验目标光谱信息条件下, 将目标像元从复杂的背景中检测出, 因此可以近似看成二元分类的问题, 在民用和军用领域有着广泛的应用。高光谱图像数据具有“图谱合一”的特点 (He 等, 2009), 蕴含丰富的光谱信息。但是高光谱目标检测也面临一些挑战: (1) 高光谱图像光谱可变,

存在同物异谱现象, 其光谱特征受周围环境的影响; (2) 光谱冗余, 光谱维数可达几十到数百, 波段间的相关性高; (3) 训练样本少, 训练样本数量远远不能满足大量特征的学习, 如果没有充足的样本将面临“过拟合”的问题 (Ye 等, 2021)。

近些年, 已有一些学者对高光谱目标检测进行了研究。目前的主要方法可以分为四类: 第一类是基于光谱相似性度量的方法, 光谱角度匹配 SAM (Spectral Angle Mapper) (Kruse 等, 1993) 利用已知目标光谱向量, 与未知光谱向量计算夹角余弦, 角度越小, 则是目标的可能性越大。第二类是基于投影的方法, 典型的就是约束能量最小化 CEM (Constrained Energy Minimization) (Farrand 和 Harsanyi, 1997) 算法, 它设计一个有限脉冲响应线性滤波器, 在满足目标信号对滤波器响应为常数的条件下, 使背景样本通过滤波器的平均输出能量最小, 以及基于 CEM 改进的分层约束能量最

收稿日期: 2022-05-06; 预印本: 2023-01-05

基金项目: 国家自然科学基金(编号: 62071233, 61971223, 61976117); 江苏省自然科学基金(编号: BK20211570, BK20180018, BK20191409); 中央高校基金项目(编号: 30917015104, 30919011103, 30919011402, 30921011209)

第一作者简介: 周琨, 研究方向为高光谱目标检测。E-mail: kzhou@njust.edu.cn

通信作者简介: 徐洋, 研究方向为图像处理和机器学习。E-mail: xuyangth90@njust.edu.cn

小化 (hCEM) (Zou 和 Shi, 2016)。正交子空间投影 OSP (Orthogonal Subspace Projection) (Harsanyi 和 Chang, 1994) 将光谱向量投影到背景的正交子空间中。第三类是基于统计学的方法, 它假设背景和背景目标光谱分别服从不同的概率分布, 构造似然比检验。最经典的就是匹配滤波 MF (Matched Filter) (Robey 等, 1992)、自适应一致性/余弦估计器 ACE (Adaptive Coherent/Cosine Estimator) (Kraut 等, 2005) 和自适应匹配子空间检测器 AMSD (Adaptive Matched Subspace Detector) (Manolakis 等, 2001)。第四类是基于低秩和稀疏的算法。协同稀疏表示 CSCR (Combined Sparse and Collaborative Representation) (Li 等, 2015) 算法通过使用稀疏表示目标, 协同表示背景, 检测结果由两个表示之间的残差的能量响应得到。基于低秩正则化最小二乘模型 LRLS-MSD (Low-rank Regularized Least Squares-Matched Subspace Detector) (Xu 等, 2016) 在最小二乘模型中引入低秩正则化, 约束背景成分, 然后利用广义似然比检验生成结果。

传统高光谱目标检测的方法主要是利用目标与背景之间的光谱差异来检测目标, 但是这些方法也存在特征提取不充分、背景刻画存在误差等问题。近年来, 深度学习迅速发展起来, 它可以通过提取多层的表示来对复杂的数据集进行建模, 例如使用自编码器 AE (Autoencoder) 和生成对抗网络 GANs (Generative Adversarial Networks) 进行建模。Xie 等 (2020a) 提出了一种光谱波段选择的深度学习算法, 使用变分自编码网络对隐藏层选择出包含目标信息较多的波段, 组成新的图像进行目标检测。此外, Xie 等 (2022b) 设计基于异常突出正则项约束的背景记忆生成对抗网络模型, 扩大伪背景与伪异常之间的距离, 从而达到分离背景与异常的目的。进一步, 他们又提出了一种背景学习的深度学习算法 BLTSC (Background Learning Based on Target Suppression Constraint), 利用高光谱图像中背景像元分布较广的特点, 用背景样本训练网络, 重构背景实现检测。Zhang 等 (2020) 提出了一种 HTD-Net 的卷积神经网络用于高光谱目标检测, 借鉴 U-Net 思想生成目标样本, 将目标和背景构建像素对输入网络学习差异进行判断, 但是该方法未能充分刻画目标与背景之间的判别光谱特征。Zhu 等 (2021) 提出了双流的卷积神经网络, 利用合成方法生成训练样本, 解决了训练样

本受限的问题在提出的双流网络中, 学习先验目标和目标样本或者背景样本之间细微差异检测目标。Shi 等 (2019) 提出了一种提取宏观和微观特征的高光谱目标检测方法, 提取空间和光谱特征, 利用宏观和微观的结构, 更有效地提取出目标的特征。

但是这些方法的输入网络中样本不能保证是纯粹的样本, 在刻画背景像元时, 会存在目标信息的干扰, 背景与目标分离不够彻底。同时, 相比于文献中 (Xie 等, 2020b) 使用的对抗自编码, 变分自编码更容易训练, 易于收敛。在本文中, 我们使用高光谱图像中背景像元分布广泛的特征, 预提取背景样本并将提取的背景样本放入变分自编码器网络中进行训练, 重构出背景成分。BLTSC 中计算原图与重构背景的光谱角, 光谱角越小表示相同地物的可能性越大, 但是如果亚像素目标存在, 光谱角较小, 但是光谱幅度差异较大。为了有效刻画背景像元, 在变分自编码模型中引入约束能量最小化正则项, 使得重构的背景更加的真实, 为背景的自相关矩阵提供更加准确的估计值。本文中对原始图像与重构背景作差进行检测, 突出目标的特征, 利用重构出的真实背景计算背景的自相关矩阵, 有效地解决了目标像元参与自相关矩阵计算导致的目标丢失或者模糊, 提高了检测的精确度。

2 所提的模型及算法

2.1 约束能量最小化目标检测

假设给定的高光谱图像由 N 个像素和 L 个波段组成, 记 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$, 其中 $\mathbf{x}_i \in \mathbb{R}^{L \times 1}$, $i = 1, 2, \dots, N$, 已知先验目标信号 $\mathbf{d} \in \mathbb{R}^{L \times 1}$ 。约束能量最小化是通过设计一个有限脉冲响应线性滤波器 $\mathbf{w} = [w_1, w_2, \dots, w_L]^T$, 在满足已知先验目标信号 \mathbf{d} 对滤波器的响应为常数的条件下, 使背景样本通过滤波器的平均输出能量最小 (Yin 等, 2012):

$$\min_{\mathbf{w}} \mathbf{w}^T \mathbf{R} \mathbf{w} \quad \text{s.t.} \quad \mathbf{w}^T \mathbf{d} = 1 \quad (1)$$

式中, \mathbf{d} 先验目标信号已知, 背景样本的平均输出能量可以表示为

$$\begin{aligned} \frac{1}{N} \|\mathbf{y}\|_2^2 &= \frac{1}{N} \|\mathbf{w}^T \mathbf{X}\|_2^2 = \\ &= \frac{1}{N} \mathbf{w}^T \mathbf{X} \mathbf{X}^T \mathbf{w} = \\ &= \mathbf{w}^T \mathbf{R} \mathbf{w} \end{aligned} \quad (2)$$

式中, $\mathbf{R} = (1/N)\mathbf{X}(\mathbf{X})^T$ 表示自相关矩阵, $\mathbf{y} = [y_1, y_2, \dots, y_N] \in \mathbb{R}^{1 \times N}$ 表示检测器的输出。上述的优化问题可以用拉格朗日乘子法进行求解得:

$$\mathbf{w} = \frac{\mathbf{R}^{-1}\mathbf{d}}{\mathbf{d}^T\mathbf{R}^{-1}\mathbf{d}} \quad (3)$$

利用所求得滤波器即可对待检测样本进行检测, 越接近目标光谱, 则其光谱响应值 $\mathbf{w}^T\mathbf{X}$ 越大, 越接近背景光谱, 则其光谱响应值越小。

2.2 变分自编码背景重构

本文所提算法流程如图1所示, 首先对图像进行粗检测获得训练的背景样本, 将背景样本输入到变分自编码器中进行训练, 重构出背景, 将原始图像与重构背景作差得到3D残差, 再使用约束能量最小化对残差进行检测, 检测过程中使用背景自相关矩阵, 最后加权得到最终的检测结果。

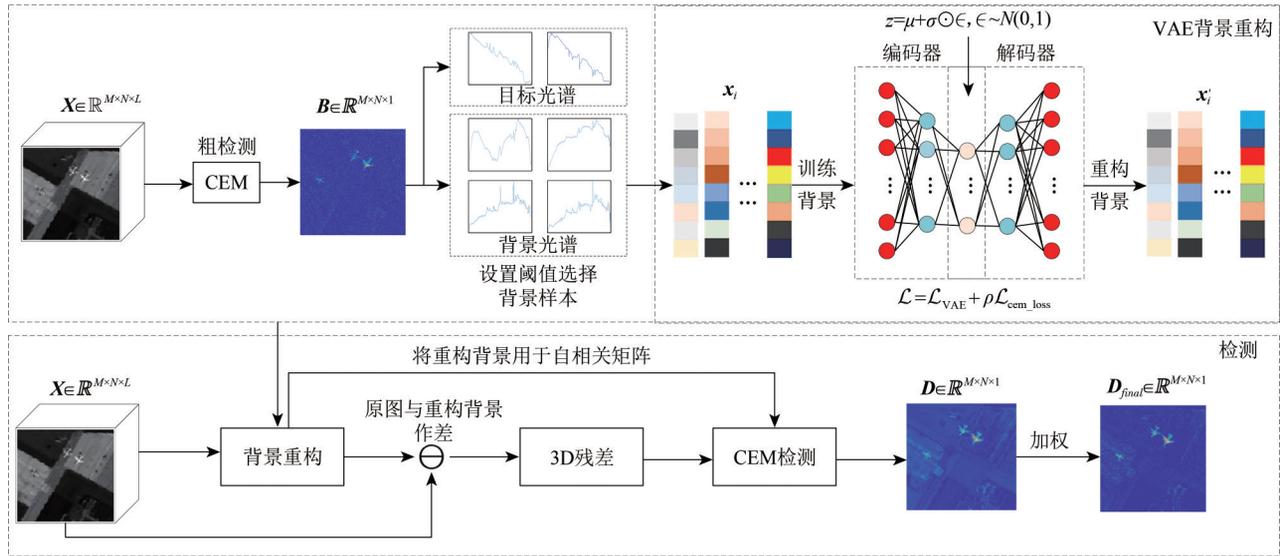


图1 算法流程图(选择背景样本训练网络, 重构出背景与原图作差得到残差后使用CEM检测, 加权得到最终结果)

Fig. 1 Algorithm flowchart. Select background sample and train (Use CEM to detect residual making the difference between the original image and the reconstructed background and then get result by weighting)

2.2.1 获取背景样本

首先对高光谱图像 (HSI) 进行预处理, 由于图像中背景样本分布很广泛, 但是目标样本分布较少, 通常只有几十到几百个像素, 而背景占据了图像的绝大部分, 所以首先通过CEM对高光谱图像进行粗检测, 得到用于背景训练的样本。具体做法为: 对CEM的输出响应设置一个阈值 τ , 大于阈值的认为是目标样本, 小于阈值的认为是背景样本:

$$Coarse(i,j) = \begin{cases} 1, & t \geq \tau \\ 0, & t < \tau \end{cases} \quad (4)$$

式中, t 为第 (i, j) 位置的像元CEM的粗检验结果, $Coarse(i, j)$ 为粗检测结果。根据粗检验得到的空间坐标知道对应的像素点。然后根据像素点坐标在原图像中找到对应背景样本光谱, 并取其中75%的背景样本作为训练集, 记为 $\mathbf{B} = [\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_n]$, 其中 $\mathbf{b}_i \in \mathbb{R}^{1 \times L}$, $i = 1, 2, \dots, n$ 。

2.2.2 背景重构

变分自编码不仅具有自编码的重构输入的功能, 而且还可以生成和原始输入相近的数据, 用隐藏层紧凑的数据揭示数据底层的结构特征。在得到训练的背景样本之后, 使用变分自编码器网络进行训练, 学习背景像元的自表示模型。变分自编码器是在自编码器的基础上发展而来的。自编码器主要是由编码器和解码器组成的, 编码器将输入层数据 \mathbf{x} 映射隐藏层中, 解码器将隐藏层 \mathbf{z} 通过非线性激活函数映射到输出层得到重构 \mathbf{x}' , 最小化下面的损失函数:

$$\mathcal{L}_{recon} = \|\mathbf{x} - \mathbf{x}'\|_2 \quad (5)$$

变分自编码器使用编码器网络 $q(\mathbf{z}|\mathbf{x})$ 来近似潜在空间的后验分布, 并使用解码器网络 $p(\mathbf{x}|\mathbf{z})$ 对输入的似然性进行建模, 我们使用 $q(\mathbf{z}|\mathbf{x})$ 来近似贝叶斯公式 $p(\mathbf{z}|\mathbf{x})$, 即最小化两个分布之间的KL散度, 推导之后可得:

$$\mathcal{L}_{\text{VAE}} = -D_{\text{KL}}(q(z|\mathbf{x})\|p(z)) + \|\mathbf{x} - \mathbf{x}'\|_2 \quad (6)$$

变分自编码假设先验服从正态分布, 解码器从这些正态分布中采样, 生成隐向量。但是在采样的过程中无法为随机采样进行反向传播, 因此用到“重参数化”技巧, 即隐向量 z 先从标准正态分布中采样, 进行变换: $z = \boldsymbol{\mu} + \boldsymbol{\sigma} \odot \boldsymbol{\epsilon}$, 因此需要对编码器的输出均值 $\boldsymbol{\mu}$ 和方差 $\boldsymbol{\sigma}$ 加以约束:

$$\mathcal{L}_{\text{VAE}} = -\frac{1}{2} \sum_{j=1}^J \left(1 + \log((\sigma_j)^2) - (\mu_j)^2 - (\sigma_j)^2 \right) + \|\mathbf{x} - \mathbf{x}'\|_2 \quad (7)$$

式中, J 表示隐向量 z 的维度。由于相对于目标样本来说, 背景样本数量较多, 所以我们选择用背景样本进行训练。为了使得重构的样本仅保留背景信息, 无目标样本的特征, 重构背景更加真实, 我们在变分自编码网络引入一个约束能量最小化正则项, 使得背景样本能够准确重构, 而非背景样本的重构误差较大, 具体的计算公式为

$$\mathcal{L}_{\text{cem_loss}} = \sum_i \left(\frac{\mathbf{R}^{-1} \mathbf{d}}{\mathbf{d}^T \mathbf{R}^{-1} \mathbf{d}} \right)^T \mathbf{x}'_i \quad (8)$$

即对重构计算通过滤波器输出响应, 对变分自编码输出进行约束。使得网络的表示更加符合CEM算法的表示, 即背景像元表示更准确, 非背景像元表示不准确。对损失函数不断进行优化, 损失函数的值越低, 则说明重构出来背景越来越好, 而对目标样本则无法进行有效重构。

在计算约束能量最小化正则项的时候, 自相关矩阵 \mathbf{R} 计算涉及到求逆的运算, 但是奇异矩阵可能不能进行求逆, 所以加了正则化参数 λ :

$$\mathbf{R}' = \mathbf{R} + \lambda \mathbf{I} \quad (9)$$

相当于在目标函数中添加了L2范数惩罚 $\lambda \|\mathbf{w}\|_2^2$, 即“Tikhonov正则化”, 是解决病态回归问题的经典方法, 确保 \mathbf{R}' 可逆以及数据的稳定性(Zhao等, 2019)。

所以网络中的损失函数由两部分组成, 通过梯度下降优化模型:

$$\mathcal{L} = \mathcal{L}_{\text{VAE}} + \rho \mathcal{L}_{\text{cem_loss}} \quad (10)$$

式中, ρ 是超参数。

2.2.3 基于重构残差的目标检测

通过变分自编码器训练背景样本得到重构背景 $\mathbf{X}' = [\mathbf{x}'_1, \mathbf{x}'_2, \dots, \mathbf{x}'_N]$, 将原图像与重构背景作差得到一个3D残差, 通过作差之后, 可以凸显目标, 提高后续的目标检测精度。

在得到3D残差后, 我们采用CEM对残差进行检测。为了避免其他非背景像元对背景自相关矩阵的影响, 本文采用重构的背景进行自相关矩阵的计算, 其计算公式为

$$\mathbf{R}_b = (1/N) \mathbf{X}'(\mathbf{X}')^T \quad (11)$$

检测结果为

$$\mathbf{D} = \left(\frac{\mathbf{R}_b^{-1} \mathbf{d}}{\mathbf{d}^T \mathbf{R}_b^{-1} \mathbf{d}} \right)^T \mathbf{X}_{\text{resi}} \quad (12)$$

式中, \mathbf{d} 代表已知的目标光谱, \mathbf{R}_b 是背景自相关矩阵, $\mathbf{X}_{\text{resi}} = \mathbf{X} - \mathbf{X}'$ 是3D残差。这样做的目的是在计算自相关矩阵时只采用纯净的背景样本, 避免目标样本参与计算, 从而损失目标信号的响应输出。同时, 待检测的输入是3D残差, 这样可以使得目标样本更加凸显, 便于检测。

在得到检测图 \mathbf{D} 之后, 为了能进一步抑制背景, 对检测图中的每个像素设置一个权重。该权重是通过粗检测结果进行非线性映射得到。通过抑制函数保留较大的输出响应, 抑制较小的输出响应, 在最终的检测结果中, 不需要的背景会被抑制, 而目标得到保留, 具体公式如下:

$$q(x) = \begin{cases} 1 - e^{-\alpha x}, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (13)$$

式中, x 是粗检测结果, α 是一个参数。得到对应坐标上的权重 $q(x)$ 之后, 将每个像素权重乘对应像素坐标的检测图 \mathbf{D} 值得到最终的检测结果:

$$\mathbf{D}_{\text{final}} = q(x) \mathbf{D} \quad (14)$$

基于约束能量最小化变分自编码的高光谱目标检测代码如下:

输入: 高光谱图像HSI记为 \mathbf{X} , 已知先验目标光谱 \mathbf{d} , 参数 λ 和 α ;

初始化 $\lambda = 10^{-6}, \alpha > 0$;

步骤1: 用约束能量最小化粗检测得到背景样本 \mathbf{B} ;

步骤2: 用变分自编码器训练背景样本;

for each epoch do

 最小化损失函数 \mathcal{L} ;

end

步骤3: 用变分自编码器重构背景 \mathbf{X}' , 与原图像作差得到残差;

步骤4: 残差进行约束能量最小化检测得到检测图, 使用重构背景计算自相关矩阵 $\mathbf{R}_b = (1/N) \mathbf{X}'(\mathbf{X}')^T$;

步骤5: 对粗检测结果使用非线性函数得到 $q(x)$, 检测图和 $q(x)$ 相乘得到最终的结果;

输出: 最终检测结果 $\mathbf{D}_{\text{final}}$ 。

3 实验结果及分析

为了验证本文方法的有效性, 本文选用了真实的高光谱数据进行了实验验证。利用 Python 3.8 完成变分自编码器训练背景的部分, TensorFlow 版本为 2.2.0, 使用 matlab R2020a 完成高光谱目标检测的部分。

3.1 数据集

实验中采用的高光谱数据是公开的数据集, 主要有两个部分: 第一部分是机载可见光/红外成像光谱仪 (AVIRIS) 拍摄的, 这个探测器收集主要从 400—2500 nm 之间的 224 个波段, 其中 EI Segundo 数据集共 224 个波段, 空间大小为 250×300, 空间分辨率是 7.1 m, 目标像素是炼油厂的建设, 共占 2048 个像素。Sandiego 数据集有 224 个波段, 是圣地亚哥机场地区, 去除水蒸气吸收和噪声波段, 共有 186 个波段保留下来, 空间大小为 100×100, 空间分辨率大概为 3.5 m, 目标像素是飞机, 共占 120 和 57 个像素。第二部分是 ABU (Airport-Beach-Urban) (Kang 等, 2017) 数据集, 空间大小为 100×100, 这些数据集大部分是由 (AVIRIS) 探测器拍摄的, 还有一个是由 ROSIS-03 (Reflective Optics System Imaging Spectrometer) 拍摄, 并且这些数据集都已经把噪声波段去除了, Groundtruth 是借助 ENVI (Environment for Visualizing Images) 软件标注。实验中已知的目标光谱是随机选取 5 个目标光谱取平均所生成的。

3.2 评价指标

对于高光谱目标检测来说, 我们使用 ROC (Receiver Operating Characteristic) 曲线 (Du 等, 2013) 来衡量检测的效果, ROC 曲线描述了每个阈值 (τ) 下的真阳性率 (P_D) 和假阳性率 (P_F) 的检测性能, (P_F, P_D) 曲线描述了检测率与虚警率之间的关系。我们计算 ROC 曲线下的面积, 记为 AUC (Area Under Curve) (Manolakis 和 Shaw, 2002) 值, AUC (P_F, P_D) 越大, 则说明检测效果越好。 P_D 和 P_F 的计算为

$$P_D = \frac{TP}{TP + FN}, P_F = \frac{FP}{FP + TN} \quad (15)$$

式中, TP (True Positive) 是正确检测目标像素数, FP (False Positive) 是虚警像素数, FN (False Negative) 是漏检像素目标数, TN (True Negative)

是正确检测背景数。

3.3 实验结果

对上述高光谱数据集进行检测, 给出了不同方法的检测结果的对比图, 包括 BLTSC 基于目标抑制约束的背景学习 BLTSC (Background Learning Based on Target Suppression Constraint)、深度网络框架的高光谱目标检测 HTD-net (Hyperspectral Target Detection Framework Using A Deep Network)、约束能量最小化 CEM (Constrained Energy Minimization)、基于低秩正则化最小二乘模型 LRLS-MSD (Low-rank Regularized Least Squares-Matched Subspace Detector)、分层约束能量最小化 hCEM (Hierarchical Constrained energy minimization) 和自适应一致性/余弦估计器 ACE (Adaptive Coherent/Cosine Estimator), 如图 2 所示。可以从图 2 中看出, 本文方法检测出的目标较亮, 检测结果明显, 可以清楚看清目标, 而且周围的背景不明显。

本文在自编码器网络中新增加了一个约束能量最小化正则项用来将背景与目标分离, 更好地重构背景。因此我们分析了超参数 ρ 的取值, 对于不同的超参数, cem_loss 的效果是不同的。如图 2 所示, 当 $\rho = 1E - 4$ 时, 检测率最高。然而在 $\rho = 1E - 3$ 时, 检测率就会下降很多, 这是因为在训练的过程中, 正则项比重过大, 会导致重构的效果变差。当 $\rho = 0$ 时, 即不加 cem_loss 时, 效果会降低。相比于不加正则项, 合适的超参数 ρ 可以使得 AUC 有所提高。如图 3 所示。除了超参数 ρ 的设置, 将变分自编码隐藏层节点设置为 20。由于样本数相对来说较少, 如果训练次数太多, 很容易产生过拟合的现象, 因此数据集只需要训练几百个 epoch 就可以达到最优的效果。在使用非线性抑制函数时, 参数 α 用来抑制背景凸出目标, 如果 α 越大, 那么曲线越靠近左上角, 根据经验设置了最佳的 α 值。

图 2 所示的是每个方法的检测效果, 从图 2 中可以看出本文提出的方法能够比较清楚地检测出目标, 检测出来的目标更加突出。而 BLTSC 的方法虚警率较低, 背景不明显, 本文的方法检测出的目标效果更好。相比于其他对比实验的效果, 本方法的目标检测效果要更好一些。

表 1 列出了每种方法的 AUC 值, 可以看到本文方法比大部分的方法的值都要高很多, 并且平

均值也比较高。相比于传统的CEM算法, 本文方法提高了大概2%左右, 这是因为不仅使用了约束能量最小化算法, 而且还使用变分自编码进行背景重构以及计算背景自相关矩阵。从表1中看出, 对比实验hCEM相较于CEM是有提升的, 而且hCEM平均检测结果仅次于本文方法。检测图中也

可以看到本文方法可以将目标很好地检测出来, 这是因为获得3D残差可以更好地凸显出目标, 并且利用非线性抑制函数来抑制背景信息。对于abu-urban-2数据集中, HTD-net方法比本文方法要高一点, 从图2中看出HTD-net可以将目标像素很好的检测出来, 本文方法比其低了0.6%。

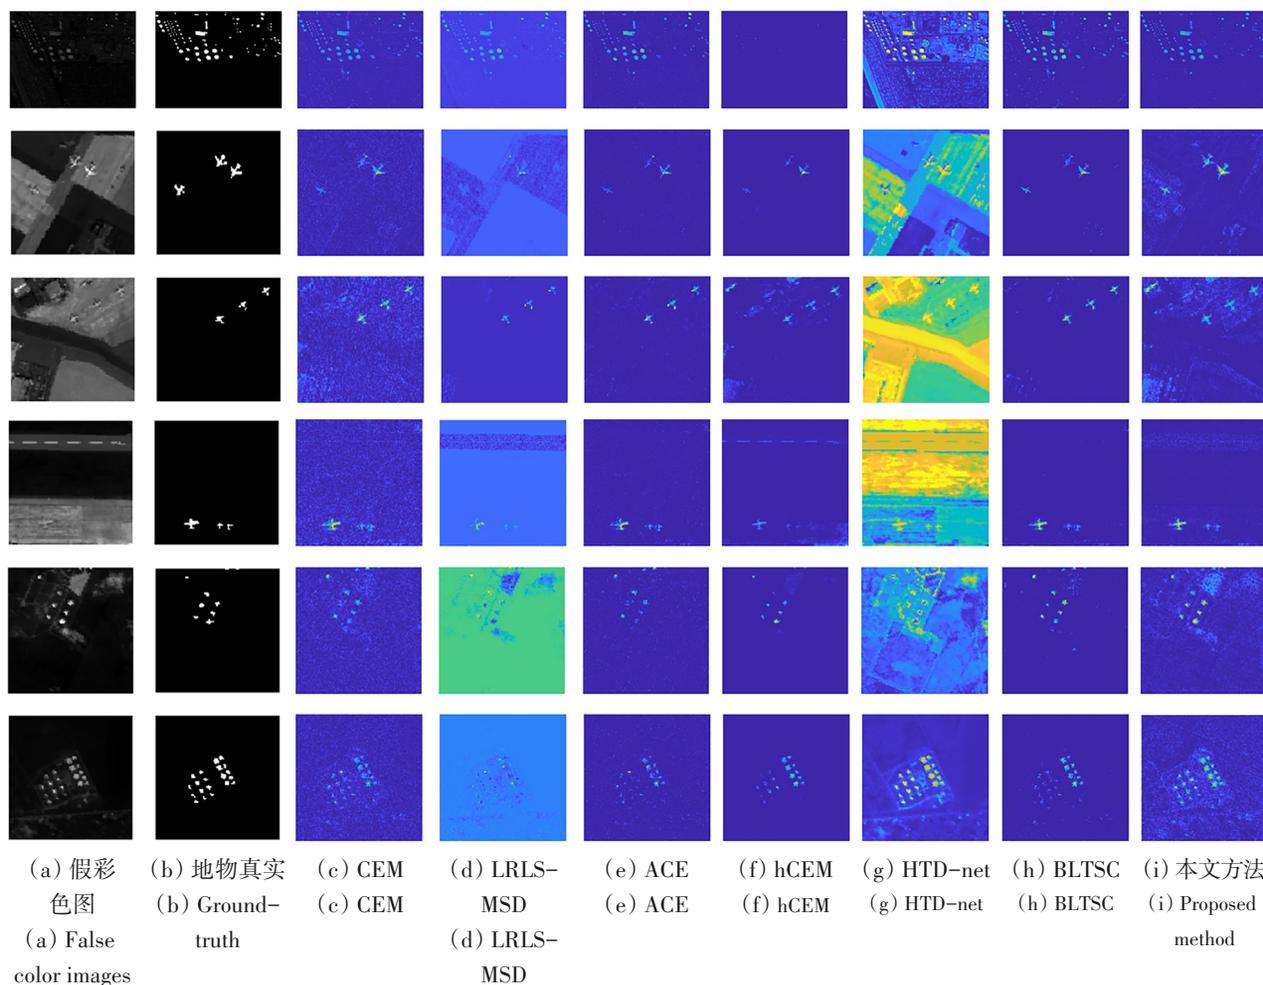


图2 各个方法结果对比

Fig. 2 Detection consequence of diverse methods

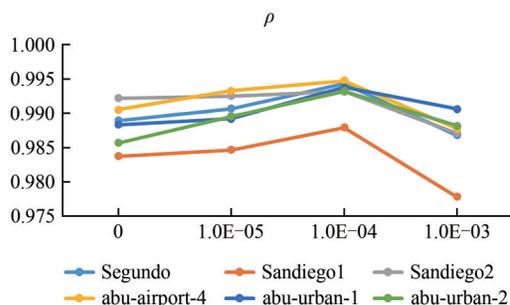


图3 约束能量最小化正则项影响

Fig. 3 Influence of Constrained Energy Minimization Regularization

表2列出的消融实验, 本文提出将自相关矩阵换成背景自相关矩阵来进行求解。第1行是移除背景自相关矩阵使用残差自相关矩阵求解得到的结果, 可以看到相比于提出的方法相差较多, 由此可以得出本方法的有效性。第2行是移除非线性抑制函数之后的结果, 即不进行加权, 可以看到和最终的结果相差不大, 这也从侧面说明了所提出方法的有效性。第3行是本文完整的方法, 性能进一步提升。

表1 各个方法的AUC值

Table 1 AUC values of different methods

数据集	本文方法	BLTSC	HTD-net	CEM	LRLS-MSD	hCEM	ACE
Segundo	0.9943821	0.9913325	0.9921344	0.9915728	0.98198	0.9371363	0.9741528
Sandiego1	0.9879251	0.9055714	0.6983856	0.930307	0.7655651	0.9785838	0.8835412
Sandiego2	0.9931937	0.9893172	0.8056095	0.987124	0.9879233	0.9892572	0.9848867
abu-airport-4	0.9947778	0.9772024	0.5716935	0.9807629	0.8753085	0.97209	0.9815837
abu-urban-1	0.993816	0.9751822	0.854064	0.9670749	0.2801862	0.9903413	0.9166422
abu-urban-2	0.9932669	0.9404361	0.9993758	0.9639555	0.4568876	0.9977152	0.872935
average	0.9928936	0.96317363	0.82021046	0.9701328	0.72464178	0.9775206	0.9356236

注: 黑色粗体表示最优结果。

表2 消融实验

Table 2 Ablation study

实验条件	Segundo	Sandiego1	Sandiego2	abu-airport-4	abu-urban-1	abu-urban-2
不使用背景自相关矩阵	0.9521652	0.9858515	0.9885435	0.9596697	0.9073577	0.9246603
去掉非线性抑制函数	0.9868324	0.9933198	0.9928452	0.962863	0.9918476	0.9968663
本文方法	0.9943821	0.9879251	0.9931937	0.9947778	0.993816	0.9932669

注: 黑色粗体表示最优结果。

为了分析本文方法与对比方法在噪声情况下的鲁棒性, 我们对原图增加了 10 dB 的噪声。由表 3 可以看出, 在 4 个数据集上本文方法仍然表现的最优, 在另外的两个数据集上, 虽然 HTD-net 表现的最好, 但是本文方法的平均精度远高于 HTD-net

方法。相较于不加入噪声的情况下, 本文方法的 AUC 值有所下降, 这主要是因为添加噪声之后, 先验目标光谱与待检测目标存在着噪声的干扰, 导致检测的准确度下降。

表3 10 dB 噪声下各个方法的 AUC 值

Table 3 AUC values of each method under 10 dB Gaussian noise

数据集	本文方法	BLTSC	HTD-net	CEM	LRLS-MSD	hCEM	ACE
Segundo	0.9749391	0.9708542	0.9851977	0.968061	0.9706595	0.9556282	0.9749171
Sandiego1	0.9678623	0.9348414	0.8338074	0.9290688	0.5028492	0.7534164	0.9232203
Sandiego2	0.9810181	0.9785461	0.8175222	0.9727861	0.7237235	0.8108367	0.9732881
abu-airport-4	0.9803303	0.9780357	0.9729443	0.9750729	0.9616859	0.9527113	0.9612676
abu-urban-1	0.9890265	0.9748374	0.9822595	0.9717736	0.8349982	0.7720023	0.9754001
abu-urban-2	0.9874336	0.979055	0.9988801	0.9777627	0.9718596	0.732895	0.9940825
average	0.98010165	0.9693616	0.9317685	0.9657542	0.8276293	0.8295817	0.9670293

注: 黑色粗体表示最优结果。

表 4 列出了所提出方法以及对比方法运行时间的对比, 所计算的时间包括训练时间和测试时间。可以看出: 与两种深度学习的方法对比, 大部分时间都花在训练模型上面, 所以消耗的时间也比传统的方法要多, 但是不同的是, 本文方法相较于两种深度学习的方法, 可以更快的收敛, 主要是因为采用了变分自编码器这种网络结构, 比 GAN 网络更容易收敛。

ROC 曲线图可以更加直观的看出本文方法的有效性, ROC 曲线越靠近左上角, 则说明方法越

好。对于 Segundo 来说, 本文方法始终表现比其他对比实验要好。对于 Sandiego1 来说, 我们的方法一开始并不是最好的, 后面曲线逐渐赶上并且始终在最上面。对于 Sandiego2 数据集 ROC 曲线也是第一个达到 1。对于 abu-airport-4 和 abu-urban-1 来说, 曲线一开始表现第二, 后面逐渐赶上并始终保持最上面的位置。对于 abu-urban-2 数据集来说, HTD-net 曲线始终处于领先的位置。除了最后一个数据集, 其他所有的数据集都是第一个达到 1 的。所有方法的 ROC 曲线如图 4 所示。

表4 各个方法的运行总时间
Table 4 The runtime of each method

数据集	本文方法	BLTSC	HTD-net	CEM	LRLS-MSD	hCEM	ACE
Segundo	316.314989	1881.00262	528.366541	0.092039	23.427125	1.357625	0.2997
Sandiego1	47.958097	292.496817	247.906592	0.011395	2.585365	0.80412	0.034502
Sandiego2	47.444776	302.072687	262.771695	0.011739	2.538894	0.795272	0.037313
abu-airport-4	46.620593	311.112907	252.729801	0.011749	2.609799	0.809141	0.038015
abu-urban-1	50.617554	330.20815	296.391502	0.013748	2.596172	0.803393	0.049958
abu-urban-2	139.698726	338.622231	257.473332	0.015084	2.584645	0.848455	0.042285

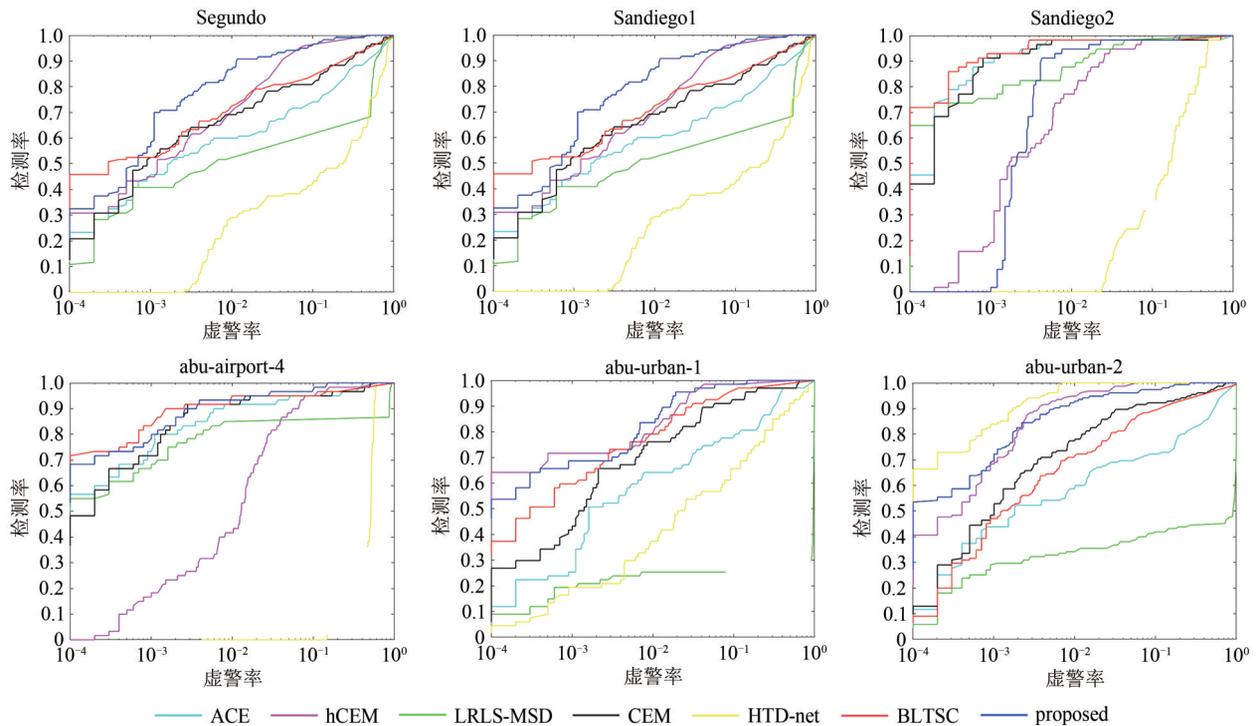


图4 ROC曲线图

Fig. 4 ROC curves

4 结论

本文提出了一种基于约束能量最小化变分自编码的高光谱目标检测, 不同于传统的约束能量最小化算法, 本文利用背景计算自相关矩阵, 解决了目标像元参与自相关矩阵计算导致的目标丢失或者模糊的问题。该算法利用高光谱图像背景像元分布较多的特点, 首先使用粗检测得到用于训练的背景样本, 然后利用变分自编码器训练背景自表示模型, 重构出背景。为了使重构样本仅保留背景信息, 引入了约束能量最小化正则项, 使得背景样本能够准确重构, 而非背景样本的重构误差较大。同时在使用约束能量最小化对残差图像进行检测时, 使用背景自相关矩阵参与计算, 避免

非背景像元参与计算, 损失目标信号输出相应。

在真实的高光谱数据集上的实验结果表明, 该算法结果优于其他的对比实验结果, 并且通过消融实验说明了背景自相关矩阵的有效性。然而模型比较依赖背景重构的效果, 如果背景重构的效果较好, 那么检测率也会很高。因此今后需要考虑如何提高背景重构的稳定性, 并且在实际场景下如何有效地使用该算法。

参考文献 (References)

- Du B, Zhang L P, Tao D C and Zhang D Y. 2013. Unsupervised transfer learning for target detection from hyperspectral images. *Neuro-computing*, 120: 72-82 [DOI: 10.1016/j.neucom.2012.08.056]
- Farrand W H and Harsanyi J C. 1997. Mapping the distribution of

- mine tailings in the Coeur d'Alene River Valley, Idaho, through the use of a constrained energy minimization technique. *Remote Sensing of Environment*, 59(1): 64-76 [DOI: 10.1016/S0034-4257(96)00080-6]
- Harsanyi J C and Chang C I. 1994. Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection approach. *IEEE Transactions on Geoscience and Remote Sensing*, 32(4): 779-785 [DOI: 10.1109/36.298007]
- He L, Pan Q, Di W and Li Y Q. 2009. Research advance on target detection for hyperspectral imagery. *Acta Electronica Sinica*, 37(9): 2016-2024 (贺霖, 潘泉, 邸韡, 李远清. 2009. 高光谱图像目标检测研究进展. *电子学报*, 37(9): 2016-2024) [DOI: 10.3321/j.issn:0372-2112.2009.09.024]
- 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]
- Kraut S, Scharf L L and Butler R W. 2005. The adaptive coherence estimator: a uniformly most-powerful-invariant adaptive detection statistic. *IEEE Transactions on Signal Processing*, 53(2): 427-438 [DOI: 10.1109/TSP.2004.840823]
- Kruse F A, Lefkoff A B, Boardman J W, Heidebrecht K B, Shapiro A T, Barloon P J and Goetz A F H. 1993. The spectral image processing system (SIPS)—interactive visualization and analysis of imaging spectrometer data. *Remote Sensing of Environment*, 44(2/3): 145-163 [DOI: 10.1016/0034-4257(93)90013-N]
- Li W, Du Q and Zhang B. 2015. Combined sparse and collaborative representation for hyperspectral target detection. *Pattern Recognition*, 48(12): 3904-3916 [DOI: 10.1016/j.patcog.2015.05.024]
- Liu Y N. 2021. Development of hyperspectral imaging remote sensing technology. *National Remote Sensing Bulletin*, 25(1): 439-459 (刘银年. 2021. 高光谱成像遥感载荷技术的现状与发展. *遥感学报*, 25(1): 439-459) [DOI: 10.11834/jrs.20210283]
- 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]
- Manolakis D, Siracusa C and Shaw G. 2001. Hyperspectral subpixel target detection using the linear mixing model. *IEEE Transactions on Geoscience and Remote Sensing*, 39(7): 1392-1409 [DOI: 10.1109/36.934072]
- Robey F C, Fuhrmann D R, Kelly E J and Nitzberg R. 1992. A CFAR adaptive matched filter detector. *IEEE Transactions on Aerospace and Electronic Systems*, 28(1): 208-216 [DOI: 10.1109/7.135446]
- Shi Y Z, Li J J, Yin Y P, Xi B B and Li Y S. 2019. Hyperspectral target detection with macro-micro feature extracted by 3-D residual auto-encoder. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(12): 4907-4919 [DOI: 10.1109/JSTARS.2019.2939833]
- Tong Q X, Zhang B and Zheng L F. 2006. *Hyperspectral Remote Sensing—Principle, Technology and Application*. Beijing: Higher Education Press: 218-238 (童庆禧, 张兵, 郑兰芬. 2006. 高光谱遥感——原理、技术与应用. 北京: 高等教育出版社: 218-238)
- Xie W Y, Lei J, Yang J, Li Y S, Du Q and Li Z. 2020a. Deep latent spectral representation learning-based hyperspectral band selection for target detection. *IEEE Transactions on Geoscience and Remote Sensing*, 58(3): 2015-2026 [DOI: 10.1109/TGRS.2019.2952091]
- Xie W Y, Zhang X, Li Y S, Wang K Y and Du Q. 2020b. Background learning based on target suppression constraint for hyperspectral target detection. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 5887-5897 [DOI: 10.1109/JSTARS.2020.3024903]
- Xie W Y, Zhong J P and Li Y S. 2022. A background memory model for hyperspectral anomaly detection. *National Remote Sensing Bulletin*: 1-13 (谢卫莹, 钟佳平, 李云松. 2022. 面向高光谱异常检测的背景记忆模型. *遥感学报*: 1-13) [DOI: 10.11834/jrs.20221241]
- Xu Y, Wu Z B, Xiao F, Zhan T M and Wei Z H. 2016. A target detection method based on low-rank regularized least squares model for hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 13(8): 1129-1133 [DOI: 10.1109/LGRS.2016.2572090]
- Ye Z, Bai L and He M Y. 2021. Review of spatial-spectral feature extraction for hyperspectral image. *Journal of Image and Graphics*, 26(8): 1737-1763 (叶珍, 白璠, 何明一. 2021. 高光谱图像空谱特征提取综述. *中国图象图形学报*, 26(8): 1737-1763) [DOI: 10.11834/jig.210198]
- Yin J H, Sun J Y, Wang Y S and Gao C. 2012. Sample weighting constrained energy minimization algorithm. *Acta Electronica Sinica*, 40(4): 788-792 (尹继豪, 孙建颖, 王义松, 高超. 2012. 样本加权约束能量最小化算法. *电子学报*, 40(4): 788-792) [DOI: 10.3969/j.issn.0372-2112.2012.04.027]
- Zhang G G, Zhao S Z, Li W, Du Q, Ran Q and Tao R. 2020. HTD-Net: a deep convolutional neural network for target detection in hyperspectral imagery. *Remote Sensing*, 12(9): 1489 [DOI: 10.3390/rs12091489]
- Zhao R, Shi Z W, Zou Z X and Zhang Z. 2019. Ensemble-based cascaded constrained energy minimization for hyperspectral target detection. *Remote Sensing*, 11(11): 1310 [DOI: 10.3390/rs11111310]
- Zhu D H, Du B and Zhang L P. 2021. Two-stream convolutional networks for hyperspectral target detection. *IEEE Transactions on Geoscience and Remote Sensing*, 59(8): 6907-6921 [DOI: 10.1109/TGRS.2020.3031902]
- Zou Z X and Shi Z W. 2016. Hierarchical suppression method for hyperspectral target detection. *IEEE Transactions on Geoscience and Remote Sensing*, 54(1): 330-342 [DOI: 10.1109/TGRS.2015.2456957]

Hyperspectral target detection based on constrained energy minimization variational autoencoder

ZHOU Kun¹, XU Yang^{1,2}, WEI Jie¹, WU Zebin^{1,2}, WEI Zhihui^{1,2}

1. Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing 210094, China;
2. Jiangsu Key Laboratory of Spectral Imaging & Intelligent Sense, Nanjing University of Science and Technology, Nanjing 210094, China

Abstract: Target detection is an important research direction in the hyperspectral field. Hyperspectral target detection aims to distinguish pixels as background or target according to the spectral characteristics of the target. Several detection algorithms have been proposed in the past few decades. However, the complexity of background samples in hyperspectral images and the limited number of target samples lead to considerable challenges in detection algorithms. A hyperspectral target detection algorithm based on background reconstruction is proposed in this paper. Taking advantage of the large proportion of background samples in hyperspectral images, the self-representation model of the background samples is trained, and then the background is reconstructed. Simultaneously, the constrained energy minimization is used to detect the residual image, and the reconstructed background is used for the calculation of the correlation matrix. Therefore, the target sample is not involved in the calculation to affect the response energy of the target sample, and the detection accuracy is improved. Results on real hyperspectral image data are better than those of comparison experiments, which verify the effectiveness of this method.

Obtaining numerous training sets of artificially labeled hyperspectral data is difficult. Therefore, using limited samples to train deep neural networks is the largest difficulty in applying deep learning to hyperspectral target detection. When calculating the average output energy of the background, the calculation of the correlation matrix of all samples is used. Therefore, the target pixel also participates in the calculation, causing a certain degree of damage to the target spectrum. The background is used as a training sample to train the entire network to solve the above problems, and the reconstructed background is utilized for constrained energy minimization detection to reduce the impact on the target spectrum during the detection process.

This paper proposes a hyperspectral target detection based on constrained energy minimization variational autoencoder. First, the image is roughly detected to obtain the training background sample. The background sample then is inputted into the variational autoencoder for training. The network introduces a constraint energy minimization regularization to remove the characteristics of the target sample and help the reconstructed sample retain only the background information. The 3D residual is acquired by calculating the difference between the original image and the reconstructed background. Thus, the constraint energy minimization is used to detect the residual. The background correlation matrix is employed in the detection process to replace the residual correlation matrix. Finally, the final detection result is obtained by weighting.

Compared with other comparative experiments, the proposed method achieved good detection results. The AUC table shows that most of the six hyperspectral datasets performed better than the comparison experiments, and most of the AUC values reached more than 99%. The detection map reveals that the target part is well detected. A close ROC curve to the upper left corner yields satisfactory effects. The curve of the proposed method performs well compared with other methods.

Overall, a hyperspectral target detection based on constrained energy minimization variational autoencoder is proposed. The algorithm utilizes the characteristics of the large distribution of background pixels in hyperspectral images. First, the coarse detection is used to obtain the background samples for training. The variational autoencoder then trains the background self-representation model and reconstructs its background. A constraint energy minimization regularization is introduced to help the reconstructed samples retain only the background information. Simultaneously, when using the constraint energy minimization to detect the residual image, the background correlation matrix contributes to the calculation to prevent the participation of non-background pixels in the calculation and lose the target signal output. Experimental results on real hyperspectral datasets show that the algorithm outperforms other comparative experimental results. However, the model is highly dependent on the effect of background reconstruction. If the effect of background reconstruction is superior, then the detection rate will be high. Therefore, improving the stability of background reconstruction in the future is necessary.

Key words: hyperspectral, target detection, background reconstruction, constrained energy minimization, correlation matrix

Supported by National Natural Science Foundation of China (No. 62071233, 61971223, 61976117); Natural Science Foundation of Jiangsu Provincial, China (No. BK20211570, BK20180018, BK20191409); Fundamental Research Funds for the Central Universities (No. 30917015104, 30919011103, 30919011402, 30921011209)