

生成对抗网络的无监督高光谱解混

靳淇文¹, 马泳^{1,2}, 樊凡^{1,2}, 黄珺^{1,2}, 李皞³, 梅晓光^{1,2}

1. 武汉大学 电子信息学院, 武汉 430072;
2. 武汉大学 宇航科学与技术研究院, 武汉 430079;
3. 武汉轻工大学 数学与计算机科学学院, 武汉 430023

摘要: 近年来, 基于深度学习中自编码器(AE)的方法在无监督的高光谱解混中受到了广泛的关注。由于AE的学习过程可以表述为通过训练找出一组低维的隐藏层(丰度), 并用其对应的权重(端元)进行组合来减少重构误差, 因而这种框架被广泛迁移并应用于高光谱的解混算法之中。然而, 现有基于AE的框架虽然能有效地处理无监督的解混场景, 却都存在着对噪声和初始化条件不鲁棒的问题, 且解混精度也有待进一步提升。针对以上问题本文提出了一种全新的基于对抗性自编码网络(AAE)的无监督解混网络框架。首先, 在网络的生成器中根据丰度和为一(ASC)及非负性(ANC)的物理意义, 设计了一个基于AE的端到端解混框架。然后, 在网络的判别器中本文采用初始化的丰度图作为真实值, 将生成器的隐藏层(丰度)与初始化的丰度进行对抗训练, 在重构误差与对抗误差的同步优化中提升框架解混性能。与传统的AE方法相比, 该方法通过引入对抗性过程, 在判别器中加入丰度的先验知识, 可以大大提高框架的性能和鲁棒性。仿真和真实的高光谱数据的实验表明, 该算法较现有方法相比具有更高的解混精度。

关键词: 遥感, 高光谱解混, 深度学习, 对抗自编码器, 高光谱图像

中图分类号: P2

引用格式: 靳淇文, 马泳, 樊凡, 黄珺, 李皞, 梅晓光. 2023. 生成对抗网络的无监督高光谱解混. 遥感学报, 27(8): 1964-1974

Jin Q W, Ma Y, Fan F, Huang J, Li H and Mei X G. 2023. Hyperspectral unmixing based on adversarial autoencoder network. National Remote Sensing Bulletin, 27(8): 1964-1974 [DOI: 10.11834/jrs.20210550]

1 引言

由于高光谱成像仪自身空间分辨率的不足、大气混合效应、地物种类的复杂多样性等原因, 使得每个像元可能同时包含了多个基本地物的光谱信息。该像元被称为混合像元(童庆禧等, 2016; 韩竹等, 2020; Jin等, 2019a)。大量混合像元的存在给高光谱图像像元级的精确解译、亚像元级的弱小目标探测与识别带来了很大的困难(Bioucas-Dias等, 2012; Jin等, 2019b; Ma等, 2019, 2021; Mei等, 2018)。因此解混对于提升高光谱遥感应用的精度、拓展其应用的广度和深度的具有关键性的意义。

线性光谱解混模型(LMM)以其简单高效、物理意义明确等优点是目前解混领域中研究的重

点。LMM假设的是高光谱图像中每个像素点是由若干个端元的谱线与其各自的丰度系数线性组合而成。其中基于几何以及统计的模型是传统解混的两大主流方法。基于几何的方法是将图像中的像元投影到若干子空间中, 并将单形体的顶点看做为图像端元。顶点分量分析VCA(Vertex Component Analysis), N-FINDR即为属于这一类的代表方法。这类方法简便快捷, 但是需要光谱数据满足纯端元的假设。对于空间分辨率相对较低的高光谱数据, 该类纯端元假设可能不成立。基于统计的解混模型框架不需满足图像中的纯端元假设, 因此也为传统方法的另一大主流模型。例如基于统计的贝叶斯方法可以通过利用统计假设和施加先验约束构造端元和丰度的最大后验概率同时实现端元的提取和丰度的反演的功能。作为

收稿日期: 2020-12-11; 预印本: 2021-07-01

基金项目: 国家自然科学基金(编号:61903279); 湖北省自然科学基金(编号:2019CFB162, 2018CFA006)

第一作者简介: 靳淇文, 研究方向为高光谱图像信息处理。E-mail: fruitsprince@whu.edu.cn

通信作者简介: 樊凡, 研究方向为红外图像处理、高光谱图像信息处理。E-mail: fanfan@whu.edu.cn

传统框架的主流方法，在解混的本质是一个种迭代的优化问题，因此所面临的主要挑战来自于混合像元数量、噪声以及异常值的鲁棒性的问题。这些因素都在很大程度上影响着模型收敛方向是否接近最优解以及收敛速度的快慢（Jin 等，2021）。

近年来，随着深度学习的发展，基于神经网络的解混框架逐渐在高光谱解混中受到了广泛的关注。例如，Palsson 等（2021）提出的基于空间光谱相似性的卷积神经网络框架 CNNAEU 以及 Borsoi 等（2020）所提出的基于变分编码器 VAE 的生成网络框架。受益为网络训练本身优秀的学习能力以及泛化性能，这些方法都较传统的解混方法在精度上有了很大的提升。近期基于深度学习中自编码器（AE）的方法在无监督的高光谱解混任务中逐渐成为了热点问题，由于该网络框架的训练过程可以简单地描述为通过最小化重构误差来学习图像的低维表示（即丰度系数），并用其对应的权重（端元）进行组合来减少重构误差。因此十分适合运用于非监督的解混任务中，以同时获得高光谱图像的端元和丰度。然而，这些基于学习的方法的一个显著缺点是训练过程更接近于一个黑盒机制，这导致该类方法很难像传统学习的方法一样将端元及丰度的先验知识融入进网络框架中进行训练。这样的缺点也往往导致网络的泛化和精度严重依赖于训练样本的数量和质量。对于现有的基于自动编码器的方法，网络的先验知识往往只是在满足丰度的物理意义（ANC 和 ASC）的前提下，通过基于端到端重建误差准则去找到网络误差最小的解。由于高光谱数据本身训练样本数量的限制，网络鲁棒性较差而且往往会产生异常且无意义的解混结果，模型也大多会出现过拟合现象。为了解决上述问题，现有的一些方法 DAEN（Su 等，2019），uDAS（Ying，2019）均采用基于纯像素端元提取算法 VCA 来直接初始化网络解码器的权值，即将提取得到的端元先验知识并入网络进行训练。然而，由于端元提取的不稳定性，网络对于噪声和初始条件的设置将极大地影响其解混性能。而生成性对抗网络（GANs）在一定程度上可以看作是一种增强模型（Goodfellow 等，2014）。与传统的非对抗模型相比，判别器相当于提供了一个自适应不同任务和数据集的损失项，可以有效提升网络对异常值和

噪声的鲁棒性。

因此，本文将在传统自动编码器的基础上，设计了一种全新的对抗自编码器（AAENet），通过在判别器中加入丰度的先验知识，将生成器的隐藏层（丰度）与初始化的丰度进行对抗训练而进一步提高整个网络解混性能。同时也避免了采用网络权重中直接进行端元初始化带来的次优化问题。

2 AAENet 网络框架

基于传统自编码器网络框架图如图 1 所示。 $Y \in R^{N \times B}$ 代表输入的高光谱图像（ N 表示像元的数量， B 表示图像的维度）， $\hat{Y}$ 代表由解码器重建的高光谱图像。根据 LMM 模型假设可知，光谱的混合方式可以描述为： $Y = AM + N_{\text{noise}}$ 。这里 N_{noise} 代表高斯噪声， A 表示为图像的丰度， M 表示为端元矩阵。因此对应图 1 的自编码器模型，我们可知编码器隐藏层的输出 A 即为图像的预估丰度，所求端元矩阵即为网络中解码器的权重矩阵。本文所设计的基于对抗自编码器网络 AAENet 框架流程图如图 2 所示。其中图 2 中 LeakyReLU，Linear，ReLU 均代表网络框架中所使用的激活函数。




图 1 基于自编码器的网络框架图

Fig. 1 Architecture of the autoencoder-based network

2.1 AAENet 自编码器网络架构

AAENet 框架中编码器各神经元具体细节如表 1 所示。其中 R 表示为图像中端元的维度数。由上表可以看出前 1—4 层神经元主要用于高光谱图像的降维（维度数由 $9R$ 至 R ），其转换形式可由以下函数表示：

$$\alpha^{(l)} = g(W^{(l)}\alpha^{(l-1)}) \quad (1)$$

式中， $\alpha^{(l)}$ 表示为隐藏层的输出， $\alpha^{(l-1)}$ 表示为前一隐藏层的输入， $W^{(l)}$ 即为该层的权重矩阵。第 5 层神经元表示为批标准化层（BN 层），主要为解决网络训练收敛速度过慢或“梯度爆炸”等问题且由 γ 及 β 两个参数控制，这里文本假设 $\alpha_i^{(5)} (i =$

1, ⋯, m) 为前一层神经元的输入, 则 BN 层的功能函数可以表述为以下形式:

$$\alpha_i^{(6)} = \text{BN}_{\gamma, \beta}(\alpha_i^{(5)}) = \gamma \alpha_i^{(5)} + \beta \tag{2}$$

式中, γ, β 为网络中的可学习参数, $\hat{\alpha}_i$ 如式 (3) 所示:

$$\hat{\alpha}_i^{(5)} = \frac{\alpha_i^{(5)} - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}}, \mu_B = \frac{1}{m} \sum_{i=1}^m \alpha_i^{(5)}$$
$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (\alpha_i^{(5)} - \mu_B)^2 \tag{3}$$




图2 AAENet网络框架图
Fig. 2 Architecture of the proposed AAENet

第6层神经元为动态阈值层, 考虑到丰度图像的稀疏性, 这里本文使用动态阈值 α 置于每一层的末端单元处作为可学习参数来实现丰度的稀疏性约束。其功能函数可以表示为以下形式:

$$\alpha^{(7)} = \max(0, \alpha^{(6)} - \alpha) \tag{4}$$

式中, $\alpha^{(6)}$ 表示前一层神经元输入, α 为 $R \times 1$ 向量。后续实验表明, 采用一个可学习的网络参数 α 作为动态阈值来控制丰度图的稀疏性限制比在目标函数中加入 l_1 及 l_{21} 正则项具有更高的解混精度。

由于 LeakyReLU 函数本身具有的非负特性, 为保证隐藏层所输出丰度的具有物理意义, 我们只需在编码器的第7层神经元输出加入一个 ASC 限制, 其功能函数可以表示为: $\alpha_i^{(8)} = \alpha_i^{(7)} / \sum_{j=1}^R \alpha_j^{(7)}$ 。因此 AAENet 的隐含层中所得到的输入将会自动满足丰度和为一的物理意义。

对于解码器部分, 由于本文主要考虑高光谱的线性组合模型 (LMM), 即观测到的光谱应为端

元和其各自的丰度系数线性组合。因此本文使用 Linear 作为解码器的激活函数以满足 LMM 模型框架的假设。而由于偏置单元在网络的训练中往往会产生很大负值导致收敛性的问题, 在本文的网络中所有的偏置单元均置为初始 0 值。

表1 生成器网络层架构及激活函数
Table 1 The layer type and activation function used in the generator

编号(#)	网络层类型	激活函数	维度数
1	输入层 Y	—	B
2	全连接层	LeakyRelu	9R
3	全连接层	LeakyRelu	6R
4	全连接层	LeakyRelu	3R
5	全连接层	LeakyRelu	R
6	批标准层 (BN 层)	Utility	R
7	阈值层	Relu	R
8	ASC	Utility	R
9	隐藏层丰度	—	R
10	全连接层	Linear	B
11	输出层 $\hat{Y}$	—	B

2.2 AAENet 判决器网络架构及损失函数

生成对抗网络 (GANs) 的概念是由 Goodfellow 等人提出 (Goodfellow 等, 2014)。GANs 的训练过程可以看作寻找判决器 D 与生成器 G 两个网络层之间的极小极大的博弈最优点。判决器 D 的训练误差为判定输入样本的真伪损失, 生成器 G 的训练误差则为生成足够逼真的样本欺骗判决器。整个网络的训练损失可以描述为以下形式:

$$\min_G \max_D E_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x})} (\log D(\mathbf{x})) + E_{\mathbf{z} \sim p(\mathbf{z})} (\log (1 - D(\mathbf{z}))) \quad (5)$$

式中, $p_{\text{data}}(\mathbf{x})$ 为判决器中接收的真实样本数据, 输入 $\mathbf{x}$ 则为从真实的数据分布 $p_{\text{data}}(\mathbf{x})$ 中获取, $p(\mathbf{z})$ 则为生成器所对应生成的样本数据。

如图 1 中所示, AAENet 网络中生成器 G 由自编码器的编码器层构成, 编码器层的输出 (隐含层 A) 即为生成器中产生的样本。判决器 D 由 3 个全连接的网络层构成, 其目的是被训练用来最大限度区分样本是来自隐含层 A 的生成样本或是包含丰度先验信息的 VCA-FCLS (Heinz 和 Chein-I-Chang, 2001) 初始化真实样本, 而生成器 G 则需生成相似的样本最大限度地欺骗判决器。假设 K 为网络训练的批量大小, 则生成器 G 以高光谱图像中采样的 K 个样本 $\mathbf{y}_i (i \in 1, \dots, K)$ 作为输入, 其输出结果需要尽量模仿并生成与初始化丰度图相似的样本数据。两个网络在相互对抗中不断调整参数, 最终使得网络可以充分学习丰度的先验知识并生成包含物理意义且使重构误差最小的丰度数据。

AAENet 框架中判决器各神经元具体细节如表 2 所示, 所用的判决器 Loss_D 和生成器 Loss_G 的损失熵函数可以依次表示为以下形式:

$$\text{Loss}_D = -\frac{1}{K} \sum_{i=0}^{K-1} \log D(\mathbf{y}_i) - \frac{1}{K} \sum_{j=K}^{2K-1} \log (1 - D(\mathbf{y}_j)) \quad (6)$$

$$\text{Loss}_G = \frac{1}{K} \sum_{i=0}^{K-1} \log (1 - D(\mathbf{y}_i)) \quad (7)$$

式中, $\mathbf{y}_i$ 表示为输入像元值, $\hat{\mathbf{y}}_i$ 表示经由自编码器的重构像元值。同时, 在自编码器的重构误差上, 本文以光谱角距离 (SAD) 来作为损失函数进行度量。其他基于自动编码器的方法也有采用均方根误差 (RMSE) 作为重构误差。然而实验中我们发现, RMSE 对数据幅值的大小变化较为敏感, 当训练数据发生仅基于其绝对大小进行缩放时, 采用

RMSE 进行训练可能导致更高的重建误差。而将具有尺度缩放不变性的 SAD 作为目标函数可以提供更好的解混性能。值得注意的是尽管这种尺度不变的特性可能会导致估计的端元在幅值的比例上产生变化, 但是只要在网络框架中加入了丰度的 ASC 和 ANC 物理限制, 最终获得端元的相对尺度就不会受到影响。此外, 为了使自编码器可以更快地收敛, 本文在损失函数中对解码器的权重矩阵 (端元) 加入了一项正则化项。自编码器的损失函数可以表示为

$$\text{Loss}_{\text{AE}} = \frac{1}{K} \left(\sum_i^K \text{SAD}(\mathbf{y}_i, \hat{\mathbf{y}}_i) \right) + \lambda \frac{1}{R} (\text{SAD}(\mathbf{m}_j^{\text{est}}, \mathbf{m}_j^{\text{vea}})) \quad (8)$$

式中, $\mathbf{m}_j^{\text{est}}, \mathbf{m}_j^{\text{vea}}$ 分别表示 AAENet 生成的端元矩阵以及通过 VCA 算法得到的初始化端元矩阵。SAD 算法可以表示为以下形式:

$$\text{SAD}(\mathbf{x}^i, \mathbf{x}^j) = \cos^{-1} \left(\frac{\mathbf{x}^i \mathbf{x}^j}{\|\mathbf{x}^i\|_2 \|\mathbf{x}^j\|_2} \right) \quad (9)$$

式中, $\mathbf{x}^i, \mathbf{x}^j$ 分别表示为度量的两个向量样本。由于整个框架的损失可以看做为自编码器的重构误差的基础上加入了生成器和判决器的对抗损失项, 因此整个 AAENet 框架的损失函数可以表述为以下形式:

$$\text{Loss} = \text{Loss}_{\text{AE}} + \text{Loss}_D + \text{Loss}_G \quad (10)$$

式中, $\text{Loss}_{\text{AE}}, \text{Loss}_D$ 以及 Loss_G 分别由式 (8), (6) 及 (7) 所示。

表 2 判决器网络层架构及激活函数

Table 2 The layer type and activation function used in the discriminator

编号 (#)	网络层类型	激活函数	维度数
1	隐藏层	Relu	$\max\{[B/4], R+2\} + 3$
2	隐藏层	Relu	$\max\{[B/10], R+1\}$
3	输出层	Sigmoid	1

3 实验与讨论

在本文中, 我们分别在基于传统算法以及深度网络算法中挑选了近期最新提出的解混方法进行比较, 分别为: SCM (Spatial Compositional Model) (Zhou 等, 2016), FCLS (Fully Constrained Least Squares) (Heinz 和 Chein-I-Chang, 2001), NCM (Normal Compositional Model) (Eches 等, 2010),

DAEN (Su 等, 2019) 以及 uDAS (Ying, 2019)。其中 SCM 通过充分挖掘图像的局部空间信息, 在丰度中加入平滑和稀疏先验约束, 进而提升解混的精度。FCLS 为传统基于最小二乘的算法。NCM 代表对端元变异进行建模的概率模型算法, DAEN 和 uDAS 为近期提出的基于 AE 的方法。

在以下实验的实施细节上, AAENet 在判别器中采用了 VCA-FCLS 算法所求得的丰度图作为网络的先验知识进行初始化, 并将其作为网络的真实输入进行对抗训练。由于网络的损失函数中已经加入了对解码器的权重矩阵 (端元) 的正则化项, 为防止网络的过拟合的问题, 生成器及解码器的权重则均采用了随机初始值的方法进行初始化。值得注意的是, 为了保证各算法的公平比较, 以下其他对比算法也均采用了同样的 VCA-FCLS 算法结果进行丰度及端元初始化 (除 NCM 作为监督算法,

需要将整个端元库作为已知输入对端元变异的概率模型进行建模采用)。在丰度误差的定量比较中本文选用了 RMSE 算法, 其数学形式可以表述为

$$\text{RMSE} = \left(\frac{1}{N} \sum_n \left| \alpha_{nj}^{GT} - \alpha_{nj}^{est} \right|^2 \right)^{1/2} \quad (11)$$

式中, α_{nj}^{GT} , α_{nj}^{est} 分别表示丰度图的真实数据以及 AAENet 生成的丰度数据。而在预估端元的对比上我们选用光谱角距离 (SAD) 来作为损失函数进行度量, 其数学形式如式 (8) 中所示。

3.1 模拟数据集实验

根据文献 (Zhou 等, 2018), 本文从 ASTER 光谱库中选择 5 个光谱范围为 0.4—14 μm 的端元合成了一副大小为 60×60 模拟数据集。其端元及 RGB 图像如图 3 所示。其中该实验中对于端元的正则化项 λ 参数设定为 0.5。




图 3 模拟数据集 RGB 图像及端元光谱

Fig. 3 The color images and endmembers of the synthetic dataset

图 4 表示了在该模拟数据集在 SNR=20 dB 时的各算法丰度对比图。其中 AAENet 与其他对比算法中丰度图占优的部分在图中由红色方框标注, 可以明显对比看出标注范围内 AAENet 的丰度图更加贴近于真实丰度的分布。各算法端元结果 SNR=20 dB 时的对比如图 5 中所示。可以很明显的看出在丰度以及端元的解混结果中, AAENet 算法都更加接近模拟数据集的真实数据。

为了验证该方法相对于传统的自动编码器框架的优越性和有效性, 在本模拟数据集实验中, 我们在去除网络的判别器后, 即不采用初始化丰度图进行对抗训练框架时测试了 AAENet 的解混性能。最终得到的丰度图的如图 4 最后 1 列所示 (AAENet 非对抗)。对比 AAENet 的性能, 我们可

以清楚地发现在 asphalt 及 limestone 材料的丰度图中出现了许多离散点和孤立点。由于在初始化实验设置中, 所有算法都采用了相同的 VCA-FCLS 初始化设置, 因此我们可以将同样在该初始化条件下传统的自动编码器框架 (DAEN, uDAS 及 AAENet 非对抗) 的解混性能进行对比分析, 其不同噪声水平下的丰度及端元的解混定量结果如表 3 中所示, AAENet 解混精度均有较为明显的提升。因此, 可以证明, 将丰度图的初始化值作为丰富的先验知识来通过网络进行对抗训练, 可以有效提高网络的性能。

结合表 3 中信噪比由 SNR10 dB 至 30 dB 时的不同算法的丰度及端元的定量误差结果, 我们可以分析比较算法在不同噪声下的解混鲁棒性。从表 3

中可以看出所有的算法当噪声水平相对较高时 (SNR=10 dB, 20 dB), 解混精度都有所下降。这种不稳定性的结果主要与VCA初始化在不同噪声水平下不稳定有关。由于NCM需要将整个端元库作为已知输入对端元变异的概率模型进行建模, 因此NCM在不同噪声水平下的性能相对稳定, 且作为一种监督算法在进预估端元的对比时未将其考虑其中。对于DAEN算法, 观察到其在低噪声水

平 (SNR=30 dB) 下性能相当好。然而, 当噪声设置得相对较高时, 解混精度下降的较为明显。对于uDAS算法, 由于在网络的构造中加入了去噪约束, 因此当信噪比为SNR=30 dB时, 解混精度较高。然而, 其整体表现相对较差。AAENet在各SNR下丰度估计和端元估计方面都表现出了更高的解混精度及对噪声的鲁棒性, 同时也证明了该算法的有效性。




图4 模拟数据集中各算法丰度对比

Fig. 4 Abundance map comparisons for the synthetic dataset

3.2 真实数据集实验

本文选取的真实数据集为大小100×100, 光谱范围为0.4—2.5 μm, 光谱波段数为198的jasper数据集。该数据集由AVIRIS传感器获取, 且包含4种端元 (Road, Soil, Water, Tree), 其真实丰度图及立体高光谱图如图6所示。其中该实验中对于

端元的正则化项λ参数设定为0.1。此外由于该jasper数据中缺少真实的丰度及端元的信息进行定量比较, 我们与以上对比算法一样, 采用 (Zhu, 2014) 中上传的数据作为真实丰度及端元进行定量分析。图7表示了各算法在jasper数据集的丰度对比图, 其中AAENet与其他对比算法中丰度图占

优的部分在图中由红色方框标注,可以明显对比看出无论是从丰度图的大小形状以及杂乱点分布的情况来对比,AAENet算法都更加贴切与丰度图真实数据,该数据集RMSE定量解混精度值在表4中所示。所有的数据都表明在提出的AAENet网络

框架中,通过在自编码器中引入对抗损失,将初始化丰度作为先验知识,能有效地处理现存AE框架中对噪声和初始化条件不鲁棒的问题,充分发挥深度学习的网络优势从而进一步提高丰度的解混精度。




图5 模拟数据集中各算法端元对比

Fig. 5 The endmember estimation results for the synthetic dataset

值得注意的是由于本文为避免网络过拟合而导致的鲁棒性问题,框架的编码层及解码层都采用的是随机值进行初始化。而生成对抗自编码器本身作为一种增强模型其判决器虽相当于提供了一个自适应不同任务和数据集的损失项,但在实际训练过程中收敛速度相对较慢,作者实验发现通过加入端元正则化项可以在一定程度上加快网

络的收敛速度。在具体实验中,本文的端元正则化项系数可以在 $[0,1]$ 的区间内进行取值,由于端元的正则化项采用的是基于纯像素端元提取算法VCA来提取图像端元,在噪声或混合端元相对较多的图像中,VCA端元提取方法本身的不稳定性可能会导致端元提取精度较差,应降低该正则化项对网络训练的惩罚,推荐选择较小的端元正

则化系数（ $[0,0.5]$ ）会得到更好的实验结果。对于图像中存在较多纯净端元且信噪比也较高的图

像中，在 $[0.5,1]$ 区间之间进行取值可以得到更稳定的实验结果。

表 3 模拟数据集的解混精度对比

Table 3 Unmixing evaluation on synthetic dataset

噪声 SNR= 10 dB($\times 10^{-4}$)	RMSE(丰度误差)							SAD(端元误差)						
	AAENet	SCM	DAEN	NCM	uDAS	FCLS	AAENet 非对抗	AAENet	SCM	DAEN	NCM	uDAS	FCLS	AAENet 非对抗
Limestone	580	1469	1533	632	2112	1100	1658	162	243	945	—	660	1090	925
Basalt	297	658	620	308	524	460	678	184	258	574	—	355	456	434
Concrete	370	980	913	413	1058	1258	482	287	591	2712	—	714	126	681
Conifer	270	513	469	258	435	494	591	112	505	740	—	572	499	625
Asphalt	265	538	662	297	695	304	973	42	175	290	—	304	304	276
平均误差	356	832	839	382	965	723	834	157	355	1050	—	521	722	325

噪声 SNR= 20 dB($\times 10^{-4}$)	RMSE(丰度误差)							SAD(端元误差)						
	AAENet	SCM	DAEN	NCM	uDAS	FCLS	AAENet 非对抗	AAENet	SCM	DAEN	NCM	uDAS	FCLS	AAENet 非对抗
Limestone	320	855	784	903	1194	3473	940	142	140	718	—	183	421	408
Basalt	150	1194	1752	1193	1300	4298	421	179	125	627	—	205	211	309
Concrete	167	1354	2120	866	1930	1689	225	145	353	2930	—	480	212	892
Conifer	135	838	1552	877	1584	1189	363	108	347	593	—	283	168	154
Asphalt	201	1061	1552	960	1502	2662	680	45	980	246	—	128	102	114
平均误差	195	532	748	381	468	392	526	124	213	1023	—	256	223	375

噪声 SNR= 30 dB($\times 10^{-4}$)	RMSE(丰度误差)							SAD(端元误差)						
	AAENet	SCM	DAEN	NCM	uDAS	FCLS	AAENet 非对抗	AAENet	SCM	DAEN	NCM	uDAS	FCLS	AAENet 非对抗
Limestone	260	713	234	632	908	610	677	68	107	211	—	289	342	179
Basalt	130	205	429	309	288	270	360	53	95	168	—	150	211	262
Concrete	125	508	224	413	347	301	169	85	245	334	—	454	533	295
Conifer	123	221	156	258	152	162	370	69	271	271	—	153	148	519
Asphalt	150	212	179	297	396	270	382	42	75	117	—	123	112	185
平均误差	158	372	234	382	418	323	392	63	159	220	—	234	269	288

注：黑体表示最优精度。




图6 Jasper数据集3D立方图及端元光谱

Fig. 6 3D cube image and endmembers of the jasper dataset




图7 Jasper数据集中各对比算法丰度图

Fig. 7 Abundance map comparisons for the Jasper dataset




图8 Jasper数据集中各算法端元对比图

Fig. 8 Abundance map comparisons for the Jasper dataset

表 4 Jasper 数据集的解混精度对比
Table 4 Unmixing evaluation on jasper dataset

端元种类 ($\times 10^{-4}$)	RMSE(丰度误差)							SAD(端元误差)						
	AAENet	SCM	DAEN	NCM	uDAS	FCLS	AAENet非对抗	AAENet	SCM	DAEN	NCM	uDAS	FCLS	AAENet非对抗
Road	790	855	784	903	1194	1085	750	308	444	517	—	599	901	474
Soil	939	1194	1752	1193	1300	2035	1772	196	713	1010	—	1167	1166	2068
Water	417	1354	2120	866	1930	2841	1702	1094	976	3341	—	1146	2622	633
Tree	723	838	1552	877	1584	1718	2682	302	442	1827	—	1979	1534	1233
平均误差	726	1061	1552	960	1502	1920	1726	504	644	1674	—	1156	1556	1102

注:黑体表示最优精度。

4 结 论

本文提出了一种新的基于对抗式自动编码器 (AAENet) 的高光谱解混方法, 可以有效的同时获取图像的端元特征及其丰度分数。AAENet 主要有两部分构成。第一部分为端到端基于重构误差的解混框架, 第二部分是采用对抗性训练的方法, 将初始化丰度作为先验知识, 生成器和判决器的对抗损失项可以充分学习丰度的先验并加速网络的收敛。在模拟及真实高光谱数据上的实验表明, AAENet 与现有方法相比, 该算法具有更好的解混性能与精度。

参考文献(References)

Bioucas-Dias J M, Plaza A, Dobigeon N, Parente M, Du Q, Gader P and Chanussot J. 2012. Hyperspectral unmixing overview: geometrical, statistical, and sparse regression-based approaches. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2): 354-379 [DOI: 10.1109/JSTARS.2012.2194696]

Borsoi R A, Imbiriba T and Bermudez J C M. 2020. Deep generative endmember modeling: an application to unsupervised spectral unmixing. *IEEE Transactions on Computational Imaging*, 6: 374-384 [DOI: 10.1109/tci.2019.2948726]

Eches O, Dobigeon N, Mailhes C and Tournet J Y. 2010. Bayesian estimation of linear mixtures using the normal compositional model. Application to hyperspectral imagery. *IEEE Transactions on Image Processing*, 19(6): 1403-1413 [DOI: 10.1109/TIP.2010.2042993]

Goodfellow I J, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, Courville A and Bengio Y. 2014. Generative adversarial nets//*Proceedings of the 27th International Conference on Neural Information Processing Systems*. Montreal: MIT Press: 2672-2680.

Han Z, Gao L R, Zhang B, Sun X and Li Q T. 2020. Nonlinear hyperspectral unmixing algorithm based on deep autoencoder networks. *Journal of Remote Sensing*, 24(4): 388-400 (韩竹, 高连如, 张兵,

孙旭, 李庆亭. 2020. 高分五号高光谱图像自编码网络非线性解混. *遥感学报*, 24(4): 388-400 [DOI: 10.11834/jrs.20209188]

Heinz D C and Chein-I-Chang. 2001. Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39(3): 529-545 [DOI: 10.1109/36.911111]

Jin Q W, Ma Y, Mei X G, Dai X B, Li H, Fan F and Huang J. 2019a. Gaussian mixture model for hyperspectral unmixing with low-rank representation//*Proceedings of 2019 IEEE International Geoscience and Remote Sensing Symposium*. Yokohama: IEEE: 294-297 [DOI: 10.1109/IGARSS.2019.8898410]

Jin Q W, Ma Y, Mei X G, Li H and Ma J Y. 2021. UTDN: an unsupervised two-stream dirichlet-net for hyperspectral unmixing//*Proceedings of 2021 IEEE International Conference on Acoustics, Speech and Signal Processing*. Toronto: IEEE: 1885-1889 [DOI: 10.1109/ICASSP39728.2021.9414810]

Jin Q W, Ma Y, Pan E T, Fan F, Huang J, Li H, Sui C H and Mei X G. 2019b. Hyperspectral unmixing with gaussian mixture model and spatial group sparsity. *Remote Sensing*, 11(20): 2434 [DOI: 10.3390/rs11202434]

Ma Y, Fan G H, Jin Q W, Huang J, Mei X G and Ma J Y. 2021. Hyperspectral anomaly detection via integration of feature extraction and background purification. *IEEE Geoscience and Remote Sensing Letters*, 18(8): 1436-1440 [DOI: 10.1109/LGRS. 2020.2998809]

Ma Y, Jin Q W, Mei X G, Dai X B, Fan F, Li H and Huang J. 2019. Hyperspectral unmixing with Gaussian mixture model and low-rank representation. *Remote Sensing*, 11(8): 911 [DOI: 10.3390/rs11080911]

Mei X G, Ma Y, Li C, Fan F, Huang J and Ma J Y. 2018. Robust GBM hyperspectral image unmixing with superpixel segmentation based low rank and sparse representation. *Neurocomputing*, 275: 2783-2797 [DOI: 10.1016/j.neucom.2017.11.052]

Palsson B, Ulfarsson M O and Sveinsson J R. 2021. Convolutional autoencoder for spectral-spatial hyperspectral unmixing. *IEEE Transactions on Geoscience and Remote Sensing*, 59(1): 535-549 [DOI: 10.1109/tgrs.2020.2992743]

Su Y C, Li J, Plaza A, Marinoni A, Gamba P and Chakravortty S. 2019. DAEN: deep autoencoder networks for hyperspectral unmixing. *IEEE Transactions on Geoscience and Remote Sensing*,

- 57(7): 4309-4321 [DOI: 10.1109/tgrs.2018.2890633]
- Tong Q X, Zhang B and Zhang L F. 2016. Current progress of hyperspectral remote sensing in China. *Journal of Remote Sensing*, 20(5): 689-707 (童庆禧, 张兵, 张立福. 2016. 中国高光谱遥感的前沿进展. *遥感学报*, 20(5): 689-707) [DOI: 10.11834/jrs.20166264]
- Ying Q and Qi H R. 2019. uDAS: an untied denoising autoencoder with sparsity for spectral unmixing. *IEEE Transactions on Geoscience and Remote Sensing*, 57(3): 1698-1712 [DOI: 10.1109/tgrs.2018.2868690]
- Zhou Y, Rangarajan A and Gader P D. 2016. A spatial compositional model for linear unmixing and endmember uncertainty estimation. *IEEE Transactions on Image Processing*, 25(12): 5987-6002 [DOI: 10.1109/tip.2016.2618002]
- Zhou Y, Rangarajan A and Gader P D. 2018. A Gaussian mixture model representation of endmember variability in hyperspectral unmixing. *IEEE Transactions on Image Processing*, 27(5): 2242-2256 [DOI: 10.1109/TIP.2018.2795744]
- Zhu F. Hyperspectral unmixing datasets and ground truths. 2014

Hyperspectral unmixing based on adversarial autoencoder network

JIN Qiwen^{1,2}, MA Yong^{1,2}, FAN Fan^{1,2}, HUANG Jun^{1,2}, LI Hao³, MEI Xiaoguang^{1,2}

1. Electronic Information School, Wuhan University, Wuhan 430072, China;

2. Institute of Aerospace Science and Technology, Wuhan University, Wuhan 430079, China;

3. College of Mathematics and Computer Science, Wuhan Polytechnic University, Wuhan 430023, China

Abstract: Due to the limitations associated with the spatial resolution of instruments and complex natural surfaces, spectral mixing (SU), which identifies the proportion (abundance) of the basic component spectrum (endmember) in the sub-pixel level, has become an important topic in the deep development of hyperspectral image analysis. Given that the training procedure can be explained as finding a set of low-dimensional representations (abundance) that reconstruct the data with their corresponding bases (endmembers), the autoencoder (AE)-based method has received much attention in unsupervised hyperspectral unmixing. However, although the existing AE methods can effectively deal with unsupervised unmixing scenarios, their performance has not been satisfactory, and noise and initialization conditions greatly affect their unmixing performance.

In this paper, we propose AAENet, a novel network for unsupervised unmixing that is based on the adversarial autoencoder network. First, we design the generator as an end-to-end unmixing network based on AE to obtain the meaningful abundance subjected to Abundance Nonnegative Constraint (ANC) and Abundance Sum-to-one Constraint (ASC). Second, we take the adversarial training process to map the abundance prior to the hidden code vector (abundance), which is equivalent to providing an adaptive training error to correct the AAENet converging toward a highly accurate and interpretable unmixing solution.

Experiments on simulated and real hyperspectral data (Jasper dataset) demonstrate that the proposed algorithm can outperform the state-of-the-art methods. The synthetic data are polluted by Gaussian noise at different levels, where the SNR varies from 10 dB to 30 dB with an interval of 10 dB. Each algorithm is run 10 times, and the average and standard deviation are reported. With an increasing noise level, the proposed algorithm exhibits higher robustness in both the abundance and endmember estimations and achieves the best or comparable results in all cases. In experiments on real datasets, AAENet not only shows sparse abundances for the region but also interprets the boundary as a combination of neighboring materials. The best results are obtained in highly mixed scenes.

Compared with the traditional AE method, the proposed algorithm can greatly enhance the performance and robustness of the model by using the adversarial procedure and incorporating the abundance prior to the framework. The discrimination network is designed to allow the transfer of the potentially intrinsic properties of the abundance prior information. As its main purpose, the proposed method takes an adversarial training process to impose a prior on the hidden code vector of the autoencoder. The output of the hidden code vector is then guided to produce meaningful samples. Experiments on simulated and real hyperspectral data demonstrate that the proposed algorithm can achieve a better unmixing performance compared with state-of-the-art methods.

Key words: remote sensing, hyperspectral unmixing, deep learning, adversarial autoencoder, hyperspectral image

Supported by National Natural Science Foundation of China (No. 61903279); Natural Science Foundation of Hubei Province (No. 2019CFB162, 2018CFA006)