

SSCST-Net: 基于空谱通道选择和Transformer的高光谱图像分类模型

傅彬涛

上海理工大学光电信息与计算机工程学院, 上海

收稿日期: 2025年4月20日; 录用日期: 2025年5月13日; 发布日期: 2025年5月20日

摘要

近年来, 基于Transformer的深度学习模型在高光谱图像分类任务中取得了显著的性能提高, 但是由于高光谱图像具有丰富且连续的光谱特征, 不可避免地存在光谱特征冗余问题, 从而导致分类精度下降, 同时Transformer对局部空间特征的提取存在一定的改善空间。为此, 文章提出了一种基于空谱通道选择和Transformer的高光谱图像分类网络。首先, 利用自适应的空谱通道选择方法来提取类别边缘特征, 并保留具有高度类别特征表达能力的光谱通道, 从而解决Transformer对局部空间特征关注不足和特征冗余的问题, 再利用Transformer来提取空间光谱特征并进行分类。实验结果表明, 该模型在Indian Pines和University of Pavia上分别取得98.45%和99.62%的整体分类精度。

关键词

高光谱图像分类, 空谱通道选择, Transformer

SSCST-Net: Hyperspectral Image Classification Model Based on Spatial-Spectral Channel Selection and Transformer

Bintao Fu

School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Apr. 20th, 2025; accepted: May 13th, 2025; published: May 20th, 2025

文章引用: 傅彬涛. SSCST-Net: 基于空谱通道选择和 Transformer 的高光谱图像分类模型[J]. 建模与仿真, 2025, 14(5): 569-578. DOI: 10.12677/mos.2025.145415

Abstract

In recent years, Transformer-based deep learning models have achieved remarkable performance improvements in hyperspectral image classification tasks. However, due to the rich and continuous spectral characteristics of hyperspectral images, spectral feature redundancy inevitably exists, leading to reduced classification accuracy. Additionally, Transformer architecture still has room for improvement in extracting local spatial features. To address these issues, this paper proposes a hyperspectral image classification network based on spatial-spectral channel selection and Transformer. First, an adaptive spatial-spectral channel selection method is employed to extract class-discriminative edge features while preserving spectral channels with high class-specific representational capacity. This approach mitigates both the insufficient attention to local spatial features in the Transformer and the feature redundancy problem. Subsequently, the Transformer is utilized to capture spatial-spectral features for classification. Experimental results demonstrate that the proposed model achieves overall classification accuracies of 98.45% and 99.62% on the Indian Pines and University of Pavia datasets, respectively.

Keywords

Hyperspectral Image Classification, Spatial-Spectral Channel Selection, Transformer

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

高光谱图像凭借其“图谱合一”的特性和宽广的波段覆盖范围(通常包含数百个连续窄波段),能够精确捕捉不同地物类别的细微光谱特征。这种独特优势使其在以下领域发挥着关键作用:在农业领域[1],它可用于精准监测农作物生长状况、病虫害侵袭以及土壤肥力分布等,助力农业精细化管理,提升农作物产量与质量。在医疗方面,HSI能够辅助疾病诊断,通过分析人体组织或病变部位的光谱特征,实现早期疾病筛查与精准诊断。在遥感领域,可用于地质勘探,识别不同矿物质类型[2]与分布;在军事领域[3],则有助于目标探测与识别等。

在过去的几十年里,已经发展了一系列的特征提取方法。其中,线性变化模型,如主成分分析法(PCA)[4]、线性判别分析法(LDA)[5]等被广泛应用于高光谱图像的光谱特征提取。近些年,基于深度学习的分类方法被逐步应用于高光谱图像分类中。常见的网络模型有深度置信网络、堆叠式自动编码器、稀疏自编码器。但这类方法没有考虑高光谱图像目标的空间信息,影响了分类精度。基于卷积神经网络的高光谱分类方法中,最早由 Hu 等人[6]提出了一维卷积神经网络模型,直接在光谱区域中对高光谱图像进行分类;之后 Zhao 等人[7]提出了二维卷积神经网络,首先用 PCA 或者其他方法进行降维,再将数据输入到模型中,这些数据通过 2D CNN 来提取空间信息,最后结合光谱。由于 2D CNN 和 1D CNN 对空间特征和光谱特征的提取是分开进行的,为了能同时利用高光谱图像目标的空间信息和光谱信息,三维卷积神经网络(3D CNN)被提出[8]-[10],其用于学习目标的空间光谱联合特征。

基于以上的研究,本文提出一种基于空谱通道选择和 Transformer 的高光谱图像分类网络,该方法能有效提取高光谱图像的光谱和空间特征。

2. 基于空谱通道选择和 Transformer 的高光谱图像分类模型

本文所提出的 SSCST 网络整体框架图如图 1 所示, 将原始高光谱图像数据 $A \in R^{H \times W \times B}$, 其中 H 、 W 、 B 分别为高、宽和光谱通道数, 使用滑动窗口切分为一个个小的三维立方体作为输入数据 $X \in R^{w \times w \times B}$, 其中 w 为滑窗大小。输入数据经过空谱通道选择后, 将具有类别空间 - 光谱特征表达能力的通道作为 Transformer 编码器的输入, 并经过一个线性输出最终分类结果。




Figure 1. Overall framework diagram of the SSCST network

图 1. SSCST 网络整体框架图

2.1. 空谱通道选择(SSCS)




Figure 2. Structure diagram of the spectral-spatial channel selection module

图 2. 空谱通道选择模块结构图




Figure 3. (a) Conventional neighborhood embedding; (b) Adaptive neighborhood embedding

图 3. (a) 普通邻域嵌入; (b) 自适应邻域嵌入

空谱通道选择模块结构图如图 2 所示, 采用奇异谱分析的方式对高光谱数据高维通道数进行降维处理, 可以分为嵌入 - 分解 - 分组 - 重构四个步骤。在嵌入部分, 联合嵌入空间特征和光谱特征信息对于提高高光谱图像分类精度尤为重要, 尤其是空间特征信息。为此, 本文采用一种基于空间相似度的自适应嵌入窗口来进行空间信息嵌入, 其结构图如图 3(b)所示, 其中虚线表示不同地物类别的边界。

以输入数据的某个空间位置内所有通道的像素 $x_i \in R^{B \times 1} (i=1, 2, \dots, w \times w)$ 为中心, $k \times k$ 大小为搜索区域, 在该区域内以归一化欧式距离为度量标准, 选取与 x_i 具有高度光谱相似度的 L 个像素构成矩阵 $M_i \in R^{L \times B}$, 并将其转换为轨迹张量 T , 可以用以下公式来表示:

$$T = \sum_{i=1}^{ww} T(:, i, :) = \{M_1, \dots, M_i, \dots, M_{ww}\} \in R^{L \times ww \times B} \quad (1)$$

所得到的轨迹张量包含了高光谱图像完整的空间和光谱特征信息, 同时还保留并增强了关于 X 低秩特征。采用这种自适应嵌入方法, 可以在不同地物目标类别边缘区域有效选取同类地物的像素值, 筛选掉不同地物类别像素值, 保证了类间差异。在分解阶段对 T 的光谱通道进行离散傅里叶变换, 并进行 SVD 分析和逆傅里叶变换, 其过程可以用以下公式来表示:

$$D = \text{fft}(X, [], B) \quad (2)$$

$$[U_i, S_i, V_i] = \text{SVD}(D[:, :, i]), \quad i = 1, \dots, B \quad (3)$$

$$\bar{U}(:, :, i) = U_i; \bar{S}(:, :, i) = S_i; \bar{V}(:, :, i) = V_i \quad (4)$$

$$U = \text{ifft}(\bar{U}, [], B); S = \text{ifft}(\bar{S}, [], B); V = \text{ifft}(\bar{V}, [], B) \quad (5)$$

其中, U_i 、 S_i 和 V_i 分别表示 $D(:, :, i)$ 的左奇异向量矩阵、奇异值和右奇异向量矩阵。在分组阶段对得到的 U_i 、 S_i 和 V_i 进行张量管道秩 r_{tubal} 截断来最大程度上剔除无用特征和利用张量的低秩和稀疏特征, 其中 $r_{\text{tubal}}(T) \ll \min(L, ww)$, 可以用以下公式来表示:

$$U' = U(:, 1:r_{\text{tubal}}, :) \quad (6)$$

$$S' = S(1:r_{\text{tubal}}, 1:r_{\text{tubal}}, :) \quad (7)$$

$$V' = V(:, 1:r_{\text{tubal}}, :) \quad (8)$$

在重构阶段, 将 U' 、 S' 和 V' 重构为 $T_r \in R^{L \times ww \times B}$, 并采用平均化的方式将其重映射为 $y \in R^{w \times w \times B}$, 可以用以下公式来表示:

$$T_r = U' * S' * V'^T \quad (9)$$

$$y = \text{Reshape}(T_r) \quad (10)$$

将 B 个光谱通道进行相邻通道划分, 分为 N 组, 每一组内的不同通道具有高度的光谱相关性, 但这对后续利用 Transformer 编码器来进行特征提取可能造成特征冗余问题, 因此采用归一化匹配滤波[11]的方法从每一组内选取一个高信噪比、高特征表达的通道来构建新的输入 $Z \in R^{w \times w \times N}$, 其过程可以用以下公式表示:

$$z = \text{Concat}(MF(y_1), MF(y_2), \dots, MF(y_N)) \quad (11)$$

其中 MF 为归一化滤波函数; Concat 表示在通道维度上进行拼接。

2.2. Transformer 编码器(TE)

Transformer 编码器的结构图如图 1 右侧所示, 主要包含一个多头自注意力机制模块、一个 MLP 层

和两个 Norm 层, 将带有语义标记和位置信息的 patch 展平作为输入, 采用自注意力机制(Self-Attention, SA)有效地捕获特征序列之间的相关性。预先初始化三个可学习权重矩阵 W_Q 、 W_K 和 W_V , 并由此产生查询(Q)和键值对(K, V), SA 的计算公式如下:

$$SA = \text{attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (12)$$

其中 d_k 表示 K 的维度。多头自注意力允许模型从不同的表示子空间和不同的位置共同关注信息, 使用相同的操作得到多头注意力值, 并将每个头部注意力的结果都连接在一起, 这个过程可以表示为:

$$MSA(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h)W \quad (13)$$

$$\text{head}_i = SA_i \quad (14)$$

其中 h 为头的数量, W 是参数矩阵, $W \in R^{h \times d_i \times d_w}$, 其中 $d_w = W$ (W 为 tokens 的数量)。

多层感知机制模块由两个全连接层和一个非线性激活层组成, 随后经过一个 LN 层改善梯度消失问题, 最后通过一个线性层和 softmax 函数得到最终分类结果。

3. 实验结果与分析

3.1. 数据集的介绍及划分

Table 1. The numbers of training and testing samples for each class of targets in the Indian Pines and University of Pavia datasets
表 1. Indian Pines 和 University of Pavia 数据集中每类目标训练和测试样本的数量

NO	India Pines			University of Pavia		
	Class	Training	Test	Class	Training	Test
1	Alfalfa	4	42	Asphalt	331	6300
2	Corn-notill	142	1286	Meadows	932	17717
3	Corn-mintill	83	747	Gravel	104	1995
4	Corn	23	214	Trees	153	2911
5	Grass Pasture	48	435	Metal sheets	67	1278
6	Grass Tree	73	657	Bare soil	251	4778
7	Grass pasture Mowed	2	26	Bitumen	66	1264
8	Hay Windrowed	47	431	Bricks	184	3498
9	Oats	2	18	Shadows	47	900
10	Soybean-notill	97	875			
11	Soybean-mintill	245	2210			
12	Soybean Clean	59	534			
13	Wheat	20	185			
14	Woods	126	1139			
15	Buildings Grass Trees	38	348			
16	Stone Steel	9	84			
	Total	1081	9231	Total	2135	40641

为公平比较不同模型的分类性能,选取两个公开的高光谱数据集: Indian Pines (IP)和 Pavia University (PU)来进行对比实验。

Indian Pines: 著名的 IP 数据集,其覆盖美国印第安纳州西北部,由 AVIRIS 传感器获取,光谱范围为 0.4~2.5 μm 。场景大小为 145×145 像素,空间分辨率为 20 m,光谱波段为 220 个。

Pavia of University: PU 数据集通过反射式光学光谱成像光谱仪(ROSIS)捕获,光谱范围为 0.43~0.86 μm 。包含 103 个波段,大小为 610×340 像素,空间分辨率为每像素 1.3 m。

在 India Pines 数据集中,将每个类别 10%的高光谱子图作为训练集样本,其余的高光谱子图作为测试集样本。在 University of Pavia 数据集中,随机选取每个类别 5%的高光谱子图作为训练集样本,其余的高光谱子图作为测试集样本。表 1 中详细列出了 Indian Pines 和 University of Pavia 数据集中每一类目标训练和测试样本的数目。

3.2. 对比模型

本文采用 3D CNN [12]、2D CNN [13]、HybridSN [14]、SpectralFormer [15]和 GAHT [16]等 5 种方法作为对比实验。比较方法的详细情况列举如下:

3D CNN: 由两个 3D 卷积块(一个三维卷积层,一个批量重正化层和一个 ReLU 函数)和两个全连接层组成,直接对高光谱数据立方体(空间 - 光谱三维结构)进行三维卷积操作,同步提取空谱联合特征[12]。

2D CNN: 主要是在高光谱图像的二维空间维度上进行卷积操作,通常将光谱信息视为通道信息,侧重于提取空间特征,对光谱特征的利用相对有限[13]。

HybridSN: 是一种结合了 3D CNN 和 2D CNN 的混合网络。先使用 3D CNN 从光谱波段堆栈中提取联合空间 - 光谱特征,然后在其顶部使用 2D CNN 进一步学习更抽象的空间表示,以降低模型复杂度。

SpectralFormer: 基于 Transformer 架构,利用自注意力机制建模光谱序列长程依赖关系。作为 HSI 的第一个变换网络,其采用分块版本,分块大小为 7×7 [15]。通过使用 Transformer 和层间 shortcut 来捕获高光谱图像波段之间的谱序列信息,增强对高光谱图像的分类能力。

GAHT: 该模型由三个卷积层、三个变压器、一个 GAP 层和一个用于分类的线性层组成。

3.3. 实验设置

为了与实验中使用到的对比模型进行公平比较,本章所有实验都在相同 Pytorch 环境、相同设备下进行,使用的处理器为 Intel·Core·i5-12400F,内存为 32 G,显卡是 NVIDIA·RTX·3060·12 G。采用 Adam 优化算法来寻求损失函数最小值,将初始学习率设为 $5e-4$ 并随着每十个 epoch 后以 0.9 来衰减,为保持一致性,在三个数据集上将 epoch 设置为 200,批次大小设置为 128。以 Indian Pines 数据集为例,实验输入为原始数据立方体样本,其尺寸为 $12 \times 12 \times 200$ 。

3.4. 评价指标

采用了三种评价指标分析实验结果的准确性,分别为 OA、AA 和 Kappa 系数,都是通过建立混淆矩阵来反映真实结果与检测结果的一致性,计算公式分别为:

$$OA = \frac{\sum_{i=1}^N M_{ii}}{\sum_{i=1}^N \sum_{j=1}^N M_{ij}} \quad (15)$$

$$AA = \frac{1}{N} \sum_{i=1}^N \frac{M_{ij}}{\sum_{j=1}^N M_{ij}} \quad (16)$$

$$P = \frac{\sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N M_{ik} M_{kj}}{\left(\sum_{i=1}^N \sum_{j=1}^N M_{ij} \right)^2} \quad (17)$$

$$\text{Kappa} = \frac{\text{OA} - P}{1 - P} \quad (18)$$

3.5. 结果分析

3.5.1. 定量分析

Table 2. Classification accuracies obtained by each comparative classification network model using 10% of the training samples on the Indian Pines dataset.

表 2. 各对比分类网络模型在 Indian Pines 数据集上使用 10%训练样本取得的分类精度

Class	Convolution Based Networks			Transformer Based Networks		
	2D CNN	3D CNN	HybridSN	SpectralFormer	GAHT	SSCST
1	100	89.19	94.59	63.41	81.08	94.59
2	88.02	87.93	93.79	84.12	96.68	98.08
3	88.22	89.61	93.67	73.76	94.88	96.69
4	85.45	95.26	97.89	72.30	99.47	100
5	93.56	91.45	99.22	91.72	95.34	97.41
6	98.48	98.12	97.60	91.32	95.55	97.6
7	100	72.73	100	68	100	100
8	97.44	99.74	98.43	99.07	100	100
9	5.56	6.25	25	50	50	68.75
10	86.97	88.95	96.40	81.14	95.76	97.30
11	90.59	93.23	96.23	91.67	98.68	99.64
12	78.84	90.53	90.95	61.42	97.89	96.84
13	94.05	99.39	99.39	95.68	94.51	99.39
14	93.06	99.01	99.31	95.26	99.9	99.90
15	87.90	91.91	93.85	84.44	98.06	98.38
16	98.81	97.30	100	98.81	86.49	97.30
OA (%)	90.17	92.83	96.02	86.34	97.23	98.45
AA (%)	86.68	86.91	92.27	81.38	92.77	96.37
Kappa	88.81	91.82	95.47	84.39	96.84	98.23

所有被选取用于对比的分类网络模型在 Indian Pines 数据集上的分类精度如表 2 所示。本章所提出的 SSCST 分类网络模型在 Grass-Pasture-Mowed、Hay Windrowed 和 Corn 类别上的分类精度都达到了 100%。GAHT 分类网络模型在 Grass-Pasture-Mowed 和 Hay Windrowed 类别上也取得了 100% 的分类精度，然而在 Corn 类别上的分类精度只有 99.47%。HybridSN 分类模型在 Grass-Pasture-Mowed 类别上的分类精度达到了 100%，但在 Hay Windrowed 和 Corn 类别上的分类精度只有 97.89% 和 98.43%。

通过分析各个对比分类网络模型在 Indian Pines 数据集上的分类结果可以发现, SSCST 分类网络模型在 Grass-Pasture-Mowed、Hay Windrowed 和 Corn 类别上都取得了更优的分类结果。整体来说, SSCST 在 Indian Pines 数据集上的 OA、AA 和 Kappa 系数都高于 3D CNN、2D CNN、HybridSN、SpectralFormer 和 GAHT 网络模型, SSCST 在 Indian Pines 数据集上的 OA、AA 和 Kappa 系数分别提升了 8.28%、14.99% 和 13.84%。

Table 3. Classification accuracies obtained by each comparative classification network model using 5% of the training samples on the University of Pavia dataset.

表 3. 各对比分类网络模型在 University of Pavia 数据集上使用 5%训练样本取得的分类精度

Class	Convolution Based Networks			Transformer Based Networks		
	2D CNN	3D CNN	HybridSN	SpectralFormer	GAHT	SSCST
1	98.48	98.20	99.69	96.38	99.94	99.59
2	99.73	99.90	99.97	99.95	100	99.98
3	94.65	93.58	98.65	91.34	99.74	99.03
4	99.31	98.23	94.75	96.98	97.82	98.56
5	100	99.43	99.76	100	99.92	100
6	99.69	98.10	100	98.59	99.96	100
7	94.65	93.87	100	90.14	100	99.92
8	95.68	96.81	98.58	93.98	98.22	98.86
9	98.24	99.20	95.98	95.57	96.37	97.28
OA (%)	98.72	98.51	99.28	97.69	99.58	99.62
AA (%)	97.83	97.48	98.60	95.88	99.11	99.25
Kappa	98.30	98.02	99.04	96.93	99.44	99.49

本文提出的 SSCST 分类网络模型在 Bare Soil 和 Metal Sheets 类别上取得了最高的分类精度。在 Bricks 类别的分类结果中, SSCST 分类网络模型得到的分类精度最高为 98.86%, 通过分析各个对比分类网络模型在 University of Pavia 数据集上的分类结果, 如表 3 所示。可以发现, SSCST 在 University of Pavia 数据集上的 OA、AA 和 Kappa 系数都高于 2D CNN、3D CNN、HybridSN、SpectralFormer 和 GAHT。

3.5.2. 可视化分析




Figure 4. Classification maps of target pixels in the Indian Pines hyperspectral image by different comparative network models: (a) Pseudo-color image of the IP dataset; (b) True image; (c) 2D CNN; (d) 3D CNN; (e) GAHT; (f) HybridSN; (g) SpectralFormer; (h) Classification map obtained by SSCST

图 4. 各对比分类网络模型对 Indian Pines 高光谱图像中目标像元的分类映射图: (a) IP 数据集的伪彩色图像; (b) 真实图像; (c) 2D CNN; (d) 3D CNN; (e) GAHT; (f) HybridSN; (g) SpectralFormer; (h) SSCST 得到的分类图

图 4 显示了 2D CNN、3D CNN、HybridSN、SpectralFormer、GAHT 和 SSCST 分类模型在 Indian Pines 数据集上的分类映射图。图中可以看出 SSCST 在 Indian Pines 高光谱图像各类目标区域的分类映射图中，目标区域边缘比其他分类网络模型分类映射图更为完整。各个类别的目标区域中被错误分类为相邻类别目标的区域较少，因此说明 SSCST 可以有效地对相邻类别目标区域进行分类，从而有效地解决由于相邻类别目标之间光谱信息的高相似性导致网络模型分类性能受限的问题。




Figure 5. Classification maps of target pixels in the University of Pavia hyperspectral image by different comparative network models: (a) Pseudo-color image of the PU dataset; (b) True image; (c) 2D CNN; (d) 3D CNN; (e) GAHT; (f) HybridSN; (g) SpectralFormer; (h) Classification map obtained by SSCST

图 5. 各对比分类网络模型对 University of Pavia 高光谱图像中目标像元的分类映射图：(a) PU 数据集的伪彩色图像；(b) 真实图像；(c) 2D CNN；(d) 3D CNN；(e) GAHT；(f) HybridSN；(g) SpectralFormer；(h) SSCST 得到的分类图

从图 5 可以看出，在 SSCST 对 University of Pavia 高光谱图像各类目标区域的分类映射图中，分散目标区域中被错误分类的数量更少。除此之外，各个类别的目标区域中被正确分类的目标数量更多，并且各个类别的目标区域边界更加完整，因此可以有效地统一高光谱图像中各个目标区域多样的空间信息，从而能够有效地解决由于相同类别目标之间空间信息多样性导致的网络模型分类性能受限的问题。

本文方法在 2 个数据集上的 OA、AA 和 Kappa 系数均为最高，相比于对比方法提升明显。

3.6. 消融实验

为验证 SSCST 网络中两个模块的有效性，在 University of Pavia 数据集上进行消融实验，实验结果如表 4 所示。第一组实验中采用 SVM 来进行分类，第二组实验中只采用 Transformer 编码器和线性层进行分类，第三组实验采用空谱通道选择后利用 SVM 来进行分类，第四组实验为完整的 SSCST 模型分类。结果表明，第四组取得了最佳分类效果，验证了空谱通道选择模块结合 Transformer 编码模块的有效性。

Table 4. Ablation experiments conducted on University of Pavia dataset

表 4. 在 University of Pavia 数据集上进行消融实验

Cases	Component Metric				
	SSCS	TE	OA (%)	AA (%)	K (%)
1	×	×	82.75	77.73	80.68
2	×	√	84.85	82.68	83.12
3	√	×	92.43	86.71	91.86
4	√	√	98.45	96.37	98.23

4. 实验结论

为充分挖掘高光谱图像中包含的空谱信息，本文提出了一种基于空谱通道选择和 Transformer 的高光谱图像分类网络。首先，利用自适应的空谱通道选择方法来提取类别边缘特征并保留具有高度类别特征

表达能力的光谱通道, 从而解决 Transformer 对局部空间特征关注不足和特征冗余的问题, 再利用 Transformer 来提取空间光谱特征并进行分类。在 Indian Pines (IP) 和 University of Pavia 数据集上进行了实验, 并与 2D CNN、3D CNN、HybridSN、SpectralFormer、GAHT 等方法进行对比分析。结果表明, 与其他分类的方法相比较, 本文提出的方法在精度上达到了最高, 有效地证明了本文方法的实用性。

参考文献

- [1] Yan, Y., Ren, J., Tschannerl, J., Zhao, H., Harrison, B. and Jack, F. (2021) Nondestructive Phenolic Compounds Measurement and Origin Discrimination of Peated Barley Malt Using Near-Infrared Hyperspectral Imagery and Machine Learning. *IEEE Transactions on Instrumentation and Measurement*, **70**, 1-15. <https://doi.org/10.1109/tim.2021.3082274>
- [2] Fox, N., Parbhakar-Fox, A., Moltzen, J., Feig, S., Goemann, K. and Huntington, J. (2017) Applications of Hyperspectral Mineralogy for Geoenvironmental Characterisation. *Minerals Engineering*, **107**, 63-77. <https://doi.org/10.1016/j.mineng.2016.11.008>
- [3] Zare, A., Jiao, C. and Glenn, T. (2018) Discriminative Multiple Instance Hyperspectral Target Characterization. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **40**, 2342-2354. <https://doi.org/10.1109/tpami.2017.2756632>
- [4] Zabalza, J., Ren, J., Yang, M., Zhang, Y., Wang, J., Marshall, S., et al. (2014) Novel Folded-PCA for Improved Feature Extraction and Data Reduction with Hyperspectral Imaging and SAR in Remote Sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, **93**, 112-122. <https://doi.org/10.1016/j.isprsjprs.2014.04.006>
- [5] Bandos, T.V., Bruzzone, L. and Camps-Valls, G. (2009) Classification of Hyperspectral Images with Regularized Linear Discriminant Analysis. *IEEE Transactions on Geoscience and Remote Sensing*, **47**, 862-873. <https://doi.org/10.1109/tgrs.2008.2005729>
- [6] Hu, W., Huang, Y., Wei, L., Zhang, F. and Li, H. (2015) Deep Convolutional Neural Networks for Hyperspectral Image Classification. *Journal of Sensors*, **2015**, Article ID: 258619.
- [7] Zhao, W. and Du, S. (2016) Learning Multiscale and Deep Representations for Classifying Remotely Sensed Imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, **113**, 155-165. <https://doi.org/10.1016/j.isprsjprs.2016.01.004>
- [8] Chen, Y., Jiang, H., Li, C., Jia, X. and Ghamisi, P. (2016) Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks. *IEEE Transactions on Geoscience and Remote Sensing*, **54**, 6232-6251. <https://doi.org/10.1109/tgrs.2016.2584107>
- [9] Luo, F., Du, B., Zhang, L., Zhang, L. and Tao, D. (2019) Feature Learning Using Spatial-Spectral Hypergraph Discriminant Analysis for Hyperspectral Image. *IEEE Transactions on Cybernetics*, **49**, 2406-2419. <https://doi.org/10.1109/tcyb.2018.2810806>
- [10] Lu, T., Li, S., Fang, L., Bruzzone, L. and Benediktsson, J.A. (2016) Set-to-Set Distance-Based Spectral-Spatial Classification of Hyperspectral Images. *IEEE Transactions on Geoscience and Remote Sensing*, **54**, 7122-7134. <https://doi.org/10.1109/tgrs.2016.2596260>
- [11] Ji, L., Wang, L. and Geng, X. (2019) An Automatic Bad Band Pre-Removal Method for Hyperspectral Imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **12**, 4985-4994. <https://doi.org/10.1109/jstars.2019.2944930>
- [12] Yang, X., Ye, Y., Li, X., Lau, R.Y.K., Zhang, X. and Huang, X. (2018) Hyperspectral Image Classification with Deep Learning Models. *IEEE Transactions on Geoscience and Remote Sensing*, **56**, 5408-5423. <https://doi.org/10.1109/tgrs.2018.2815613>
- [13] Yue, J., Zhao, W., Mao, S. and Liu, H. (2015) Spectral-Spatial Classification of Hyperspectral Images Using Deep Convolutional Neural Networks. *Remote Sensing Letters*, **6**, 468-477. <https://doi.org/10.1080/2150704x.2015.1047045>
- [14] Roy, S.K., Krishna, G., Dubey, S.R. and Chaudhuri, B.B. (2020) HybridSN: Exploring 3-D-2-D CNN Feature Hierarchy for Hyperspectral Image Classification. *IEEE Geoscience and Remote Sensing Letters*, **17**, 277-281. <https://doi.org/10.1109/lgrs.2019.2918719>
- [15] Hong, D., Han, Z., Yao, J., Gao, L., Zhang, B., Plaza, A., et al. (2022) Spectralformer: Rethinking Hyperspectral Image Classification with Transformers. *IEEE Transactions on Geoscience and Remote Sensing*, **60**, 1-15. <https://doi.org/10.1109/tgrs.2021.3130716>
- [16] Mei, S., Song, C., Ma, M. and Xu, F. (2022) Hyperspectral Image Classification Using Group-Aware Hierarchical Transformer. *IEEE Transactions on Geoscience and Remote Sensing*, **60**, 1-14. <https://doi.org/10.1109/tgrs.2022.3207933>