

Hyperspectral Image Classification Based on Neighborhood Similarity and Spatial Spectral Joint Sparse Representation

Nuan Gao¹, Xiaoning Fu¹, Que Dong²

¹Xidian University, Xi'an Shaanxi

²Wuhan Guide Infrared Co., Ltd., Wuhan Hubei

Email: 2922467709@qq.com

Received: Feb. 13th, 2019; accepted: Feb. 25th, 2019; published: Mar. 4th, 2019

Abstract

The traditional sparse representation classification method only takes into account the sparsity of image data, and does not make use of the similarity and uniqueness between neighboring pixels. Therefore, a new method based on neighborhood similarity and spatial spectral joint sparse representation is proposed to improve the classification accuracy of hyperspectral image. The method combines pixel sparse features with neighborhood information, and uses the weight of spatial distance and spectral distance weight between pixels to measure the similarity between the center pixel Y and neighboring pixels, namely, calculate neighborhood weights, set similarity thresholds, select pixels with high similarity to pixel Y, and get the optimal neighborhood window. Finally, a class of pixel Y is determined by joint sparse representation. Experimental results show that this method can effectively improve classification accuracy and has good stability under different experimental data.

Keywords

Hyperspectral Image Classification, Joint Sparse Representation, Neighborhood Similarity, Weight

基于邻域相似性的空谱联合稀疏表示的高光谱图像分类

高 暖¹, 付小宁¹, 董 恣²

¹西安电子科技大学, 陕西 西安

²武汉高德红外股份有限公司, 湖北 武汉

Email: 2922467709@qq.com

收稿日期: 2019年2月13日; 录用日期: 2019年2月25日; 发布日期: 2019年3月4日

摘要

传统的稀疏表示分类方法仅考虑图像数据的稀疏特性，并未利用邻域像元间的相似性与独特性，因此提出一种基于邻域相似性的空谱联合稀疏表示的分类方法来提高高光谱图像分类精度。该方法将像元间的稀疏特性和邻域信息结合起来，利用像元间的空间距离权重与光谱距离权重度量待测中心像元 Y 与邻域像元的相似性，即计算邻域权重，设定相似度阈值，选取与像元 Y 相似度高的像元从而得到最优邻域窗口，最后通过联合稀疏表示来确定像元 Y 的类别。实验结果表明，该方法能够有效提高分类精度，且在不同实验数据下具备良好的稳定性。

关键词

高光谱图像分类，联合稀疏表示，邻域相似性，权重

Copyright © 2019 by author(s) and Hans Publishers Inc.

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

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



Open Access

1. 引言

随着光谱成像技术的日趋成熟，高光谱遥感在理论上、技术上、应用上发生了显著的变化[1]。高光谱图像(Hyperspectral Image, HSI) [2]中的每个像素由其对应的各种光谱带响应的矢量来表示，不同的材料在特定的波长下通常会反射不同的电磁能量。HSI 最重要的应用之一是图像分类[3]，现有的分类方法有神经网络(Artificial Neural Network, ANN)、支持向量机(Support Vector Machine, SVM)、最近邻(Nearest Neighbor, NN)分类等。近年来，基于稀疏表示(Sparse Representation, SR)的分类方法越来越多地被应用于高光谱图像的分类，文献[4]提出了一种基于类别关系的稀疏表示分类方法，该方法将像元间的相关性和欧式距离关系有效结合，提高地物分类效果。文献[5]在联合稀疏表示之前加入高光谱图像的主成分分析，提取其形态学特征，进而对局部空间区域新特征像元进行联合稀疏表示，提高了分类精度。文献[6]提出了一种残差融合分类方法，该算法有效利用图像数据的光谱信息和空间信息。文献[7]提出了一种融合稀疏表示和协同表示的分类算法，该算法通过融合残差值大小确定地物类别。

为提高高光谱图像的分类精度，有效融合邻域像元间的相似性与独特性，本文提出一种基于邻域相似性的空谱联合稀疏表示的分类方法。

2. 联合稀疏表示算法模型

稀疏表示分类(Sparse Representation Classification, SRC)方法中每个像元都用稀疏向量表示，计算像元和各类训练样本的最小残差，确定待测像元类别。在高光谱图像中，相邻的像元极有可能属于同一类地物[8]，因此可以加入空间邻域信息，使邻域内的所有像元共用同一个稀疏表示模型，即联合稀疏表示模型。该模型中待测像元的类别由待测像元及邻域内其他像元共同决定。假设高光谱图像中有 C 类不同的地物，每类均有 n 个训练样本，则由所有训练样本构成的字典可以表示为 $A=[A_1, A_2, \dots, A_C]$ ，其中， A_C 为第 C 类字典。待测中心像元与其邻域像元可以表示为 $Y=[y_1, y_2, \dots, y_T]$ ，其中， T 为邻域； y_1 为待测中心像元；其余像元为 y_1 的邻域像元。因此在联合稀疏表示模型中， Y 可以表示为：

$$Y=[A\alpha_1, A\alpha_2, \dots, A\alpha_T]=AS \quad (1)$$

式中, $S = [\alpha_1, \alpha_2, \dots, \alpha_T]$ 为稀疏矩阵, α_i 为 S 中第 i 个像元的稀疏向量 ($i = 1, 2, \dots, T$)。则稀疏矩阵 S 可通过如下联合稀疏重构模型求得:

$$\hat{S} = \arg \min_s \|AS - Y\|_F, s.t. \|S\|_{row,0} \leq K \quad (2)$$

式中, $\|\cdot\|_F$ 表示取 F 范数; $\|S\|_{row,0}$ 表示稀疏矩阵中非零行的个数, K 为稀疏度。求得稀疏系数矩阵 S 后, 待测中心像元便可以根据重构残差被区分出来, 其表达式为

$$class(y) = \arg \min_{c=1,2,\dots,C} r_c(Y) \quad (3)$$

式中, $r_c(Y) = \|Y - A_c \hat{S}_c\|_F$ 为第 c 类残差, A_c 为第 c 类训练样本组成的字典, \hat{S}_c 表示第 c 类字典对应的重构系数。

3. 基于邻域相似度的空谱联合稀疏表示的分类方法

在实际的地物情况中, 邻域内的地物往往存在多种类别, 若在地物种类复杂区域直接进行联合稀疏表示, 分错的概率很高。光谱相似性测度是高光谱影像分类和信息提取的基础, 光谱匹配模型即是通过将像元光谱与参考光谱的比较, 求算光谱向量之间的相似性或差异性, 以有效提取光谱维信息, 对地物性质进行详细的分析。为提升地物分类性能, 充分利用邻域间像元间的相似性与独特性, 本文提出在待测像元的邻域内的所有像元中, 选择与待测像元相似性高的像元, 构建最优邻域窗口, 再利用 JSR 模型分析待测像元的地物类别。

高光谱图像包含了丰富的光谱信息, 且不同类别的地物对各个波段的光谱响应不同。几何空间匹配方法是一种较为成熟的光谱相似性度量算法, 其将光谱向量看成高维特征空间中的一个点, 则两条光谱曲线之间的相似性可以用二者的空间距离来表示。兰氏距离可以有效的计算两个样本集的相似程度, 同时也可以用来比较两个向量的相似度。因此可以将像元光谱向量间的兰氏距离作为空间距离权重 G_{y_1, y_i} , 对于待测像元 y_1 的像元集 $Y = [y_1, y_2, \dots, y_T]$, 两个像元 y_1, y_i 之间的空间距离权重为:

$$G_{y_1, y_i} = \exp(-L(y_1, y_i)) \quad (4)$$

$L(y_1, y_i)$ 为像元 y_1, y_i 之间的兰氏距离, 定义为:

$$L(y_1, y_i) = \frac{1}{b} \sum_{j=1}^b \frac{|y_{1j} - y_{ij}|}{y_{1j} + y_{ij}} \quad (5)$$

式中, y_{1j} 和 y_{ij} 分别是待测中心像元光谱和邻域像元光谱第 j 波段的光谱值, b 为波段数。空间距离权重和距离度量相反, 距离越小, 空间距离权重越大, 距离越大, 空间距离权重越小。

在高光谱图像中, 由于每种地物边界部分均可能存在多种混合地物, 若仅仅利用兰氏距离作为邻域相似度判别的唯一标准, 极大可能造成类别的错分。针对以上问题本文引入光谱距离权重 A_{y_1, y_i} 来平衡像元的稀疏相似性和邻域相似性, 其表达式为:

$$A_{y_1, y_i} = \exp\left(-\frac{\|y_1 - y_i\|_2^2}{2\mu_s^2}\right) \quad (6)$$

式中, A_{y_1, y_i} 表示待测中心像元与邻域像元的光谱相似权重; y_1, y_i, μ_s 分别表示待测中心像元的光谱值、邻域像元的光谱值以及光谱标准差; μ_s 由文献[9]得知为 3500。

为了同时利用图像数据稀疏特性和邻域信息, 提升各类地物的区分性, 本文将光谱距离权重引入空谱联合稀疏表示图像分类理论中, 利用计算光谱距离权重获取相邻像素的相似度, 剥离相似度较低的邻

域像素，将剩余像素应用于空谱联合稀疏表示模型进行高光谱影像分类。空间距离权重与光谱距离权重相结合用于度量待测中心像元与邻域像元的相似性，即计算邻域权重 W_{y_1, y_i} ，其表达式为：

$$W = \lambda * G_{y_1, y_i} * A_{y_1, y_i} \quad (7)$$

式中， λ 为比重参数，用来平衡空间距离权重和光谱距离权重。设定相似度阈值 τ ，当权重 W_{y_1, y_i} 大于 τ 时，像元的光谱相似度较高，尤其对于边界区域的像元，其邻域内的像元类别复杂。JSRC 算法假定邻域内各像元对中心像元的影响权重相同，在分类时必定对分类结果产生影响，因此选择邻域内与中心像元相似度高的像元就显得尤为重要。

由于邻域像元距离待测中心像元越近，属于同一地物的可能性就越大，即权重 W_{y_1, y_i} 越大，因此，当邻域范围达到一定范围时，距离待测像元越远的邻域像元与待测像元基本不属于同一地物，基于高光谱图像的这一特性，考虑到时间复杂度以及数据集上地物的分布特点，在计算最优邻域前将所有待测像元的邻域大小均设置为 15×15 。通过式(4)~式(7)可以计算得到权重 W_{y_1, y_i} ，从而得到每个待测中心像元的最优邻域 T ，求每个待测中心像元最优邻域的基本流程如图 1 所示。

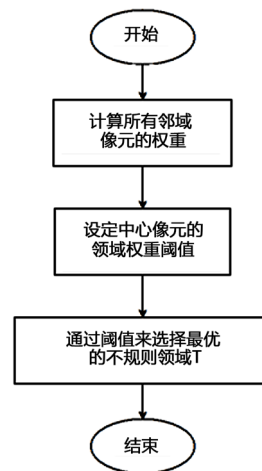


Figure 1. Obtaining the best neighbor window flow chart

图 1. 求取最优邻域窗口流程图

由图 1 可知，此算法不同于 JSRC 分类算法以待测像元为中心的取周围的 $n \times n$ 像元作为邻域窗口大小，而是通过空谱相结合算法计算每个待测中心像元的邻域像元权重来选择邻域窗口。根据以上权重公式计算得到的每个待测中心像元与邻域像元的权重 W_{y_1, y_i} 的大小来选择最优邻域 T 的大小，最终通过联合稀疏表示模型计算出如下所示的重构残差来得出待测中心像元 y 为

$$class(y) = \arg \min_{c=1,2,\dots,C} r_c(Y) = \|YW - A_c \hat{S}_c\|_2 \quad (8)$$

通过此算法计算每个待测中心像元的邻域像元权重来选取的邻域窗口是不规则且大小不同的窗口，并且每个邻域窗口都是此算法下的最优邻域。基于邻域相似性的空谱联合稀疏表示的分类算法(WJSRC)步骤如下：

输入 在图像中每个类别中随机选取一定数量的像元作为训练样本构成结构化字典 $A = [A_1, A_2, \dots, A_C]$

输出 测试样本的类别

初始化 初始化归一化字典 A

循环 对于高光谱图像中的每一个像元 y

- 1) 计算邻域权重 W_{y_1, y_i} , 其中 $n = 15 \times 15$, 并选取邻域权重 W_{y_1, y_i} 中大于 τ 的邻域像元为最优邻域窗口 T ;
 - 2) 构建联合信号矩阵 $Y = [y_1, y_2, \dots, y_T] \in R^{B \times T}$, 并且归一化联合信号矩阵 Y ;
 - 3) 通过式(2)计算得到稀疏矩阵 S ;
 - 4) 通过式(8)计算残差 $r_c(Y)$, 得到测试样本 y 的类别;
- 结束

4. 实验及结果分析

4.1. 实验数据集

实验中使用 Indian Pines 高光谱遥感数据集和 Pavia University 高光谱遥感数据集进行验证。

Indian Pines 数据集: 该数据集是由 AVIRIS 传感器获得的, 共有 220 个波段, 图像大小为 145×145 , 包含 16 个地面真理类, 如图 2(a)所示。在实验中, 通过去除 20 个吸水带, 波段数减少到 200。对于每一类, 随机选择约 10% 的标记样本进行训练, 并使用剩余的 90% 进行测试, 如表 1 所示。




Figure 2. (a) Indian Pines hyperspectral imaging; (b) Pavia University hyperspectral imaging
图 2. (a) Indian Pines 高光谱影像; (b) Pavia University 高光谱影像

Table 1. 16 Ground-Truth classes in Indian Pines

表 1. Indian Pines 图像中的 16 个真实类

No	Name	Train	Test
1	Alfalfa	6	43
2	Corn-notill	144	1161
3	Corn-min	84	675
4	Corn	24	189
5	Grass/Pasture	50	402
6	Grass/Tree	75	604
7	Grass/Pasture-mowed	3	20
8	Hay-windrowed	49	396
9	Oats	2	16
10	Soybeans-notill	97	783
11	Soybeans-min	247	1998
12	Soybeans-clean	62	496
13	Wheat	22	171
14	Woods	130	1047
15	Building-Grass-Trees-Drives	38	307
16	Stone-steel Towers	10	76

Pavia University 数据集: Pavia University 图像是在 2001 年通过 ROSIS 传感器获得的, 图像大小为 610×340 个像素, 共有 115 个波段, 除去其中水吸收和噪声波段去掉, 剩下其中 103 个波段, 该图像总共包含 9 个类别地物分别为: 沥青(Asphalt), 草地(Meadows), 砾石(Gravel), 树(Trees), 金属板材(Painted metal sheets), 裸露土壤(Bare Soil), 柏油屋顶(Bitumen), 自挡砖(Self-Blocking Bricks), 阴影(Shadows), 如图 2(b)所示。对于每一类, 随机选择约 10% 的标记样本进行训练, 并使用剩余的 90% 进行测试, 如表 2 所示。

Table 2. 9 Ground-Truth classes in Pavia University

表 2. Pavia University 图像中的 9 个真实类

No	Name	Train	Test
1	Alfalfa	663	5968
2	Meadows	1865	16784
3	Gravel	210	1889
4	Trees	307	2757
5	Painted metal sheets	135	1210
6	Bare Soil	503	4526
7	Bitumen	369	961
8	Self-Blocking Bricks	49	3633
9	Shadows	95	852

4.2. 实验设置

本文试验环境: 软件为 Matlab R2017a, 操作系统为 Windows 8, 处理器 Intel Core i5-4200u 1.6 GHz。使用待测像元的总体分类精度(Overall Accuracy, OA)与 Kappa 系数两个指标衡量各算法的性能。为验证本文算法的有效性, 选取 SVM, SRC, JSRC 和 WJSRC 算法进行对比, 其中 WJSRC 为本文提出的基于邻域相似性的空谱联合稀疏表示的分类方法。

为确定比重参数 λ 和相似度阈值 τ , 分别选取比重参数 $\lambda = 1.5, 1.8, 2.1, 2.4, 2.7, 3.0, 3.3, 3.6$ 和相似度阈值 $\tau = 0.75, 0.80, 0.85, 0.90, 0.95$ 进行实验。实验结果如图 3 所示。

由图 3(a)可知, Indian Pines 地区比重参数 $\lambda = 2.1$ 且 $\tau = 0.85$ 时精度最优。随着比重参数的增大, 分类精度提高, 在比重参数 $\lambda = 2.1$ 时最优; 当比重参数大于 2.1 时, 分类精度随着比重参数的增大而降低。 $\tau = 0.85$ 时分类精度最优, 当阈值低于或超过 0.85 时, 分类精度随着阈值的减小或增大而降低。




Figure 3. The influence of specific gravity and similarity thresholds on classification accuracy; (a) Indian Pines; (b) Pavia University

图 3. 比重参数 λ 和相似度阈值对分类精度的影响; (a) Indian Pines; (b) Pavia University

由图 3(b)可知, Pavia University 地区比重参数 $\lambda = 2.4$ 且 $\tau = 0.85$ 时精度最优。随着比重参数的增大,

分类精度提高, 在比重参数 $\lambda = 2.4$ 时最优; 当比重参数大于 2.4 时, 分类精度随着比重参数的增大而降低。 $\tau = 0.85$ 时分类精度最优, 当阈值低于或超过 0.85 时, 分类精度随着阈值的减小或增大而降低。

4.3. 分类结果

Indian Pines 测试集共有 16 种地物, 实验从选出的样本数据集中随机抽取每类样本的 10% 作为训练样本, 其余 90% 作为测试样本。图 4 为各算法的实验结果, 比重参数 $\lambda = 2.1$, 相似度阈值 $\tau = 0.85$ 。




Figure 4. (a)SVM; (b) SRC; (c) JSRC; (d) WJSRC

图 4. (a) SVM; (b) SRC; (c) JSRC; (d) WJSRC

表 3 为 Indian Pines 图像在 10% 比例字典情况下, 不同算法的总体精度 OA 和 Kappa 系数, 从表 3 中可以看出基于邻域相似性的空谱联合稀疏表示算法 WJCSR 在 10% 比例字典时总体分类精度比 SVM 算法、SRC 算法和 JSRC 算法分别高 12.64%、13.05% 和 4.29%。由此可知, 高光谱图像的空间信息和光谱信息对高光谱图像分类具有十分重要的意义。

Table 3. OA and Kappa coefficients of Indian Pines under the 10% ratio dictionary

表 3. Indian Pines 在 10% 比例字典下的 OA 和 Kappa 系数

字典原子比例		SVM	SRC	JSRC	WJSRC
10%	OA	0.7504	0.7463	0.8339	0.8768
	Kappa	0.7143	0.5818	0.8107	0.8542

Pavia University 测试集共有 9 种地物, 同样随机抽取每类样本的 10% 作为训练样本, 其余 90% 作为测试样本。图 5 为各算法的实验结果, 比重参数 $\lambda = 2.4$, 相似度阈值 $\tau = 0.85$ 。




Figure 5. (a)SVM; (b) SRC; (c) JSRC; (d) WJSRC

图 5. (a) SVM; (b) SRC; (c) JSRC; (d) WJSRC

表 4 为 Pavia University 在 10%比例字典情况下,不同算法的总体精度 OA 和 Kappa 系数,从表 4 中可以看出,基于邻域相似性的空谱联合稀疏表示算法 WJCSR 在 10%比例字典时总体分类精度比 SVM 算法、SRC 算法和 JSRC 算法分别高 18.06%、26.11%和 17.19%,依然保持着较好的分类结果。以上实验结果显示, WJSRC 在不同的高光谱图像数据下依然保持着较高的分类精度,证明了本文算法具有良好的稳定性。

Table 4. OA and Kappa coefficients of Indian Pines under the 10% ratio dictionary

表 4. Pavia University 在 10%比例字典下的 OA 和 Kappa 系数

字典原子比例		SVM	SRC	JSRC	WJSRC
10%	OA	0.7895	0.7090	0.7982	0.9701
	Kappa	0.6744	0.5914	0.7351	0.9602

综合表 3 与表 4 的分类结果和图 4 与图 5 的分类效果可知:

1) 在两个数据集上对比于其他算法,本文提出的 WJSRC 算法展现了更好的分类效果,且得到的分类图中本文算法的图像分布较为平滑。由此更加验证了本文算法的有效性和可行性。

2) 在 Indian Pines 数据集上 WJSRC 算法比 JSRC 的分类结果并不是高很多,而在 Pavia University 数据集上分类结果则有比较明显的提高,主要原因在于 Indian Pines 数据集上地物更集中,在一定的邻域范围内,距离待测中心像元越近权重越大更有利于提高分类精度,而 Pavia University 数据集上的地物较之为分散。

3) 对比 JSRC 算法,本文提出 WJSRC 算法在空间距离权重的基础上加入了光谱距离权重,对邻域像元特别是边界的不同地物像元的判别有了很大改进,并对每个待测像元求邻域权重通过设定相似度阈值来确定最优邻域大小,因此分类结果较好。

5. 结论

针对传统的稀疏表示分类算法仅利用数据的稀疏相似性,未考虑将数据的邻域信息利用到分类过程中的问题,本文提出了一种新的基于稀疏特性和邻域相似度量的分类方法。该方法通过将兰氏距离作为空间距离权重,并引入光谱距离权重来改善对边界像元分类不完全的不足,二者结合并用于度量待测中心像元与邻域像元的相似性,设定相似度阈值,选取与待测像元相似度高的像元进行联合稀疏表示,最后根据最小残差准则确定待测中心像元的类别,较好地提升了高光谱图像的分类精度。实验结果表明,本文算法能够较好地提高高光谱图像的分类精度,且在不同的试验数据下具备良好的稳定性,进一步验证邻域相似度及空谱结合在联合稀疏表示分类中的必要性。

但是本文算法在求解邻域相似性时存在引入异类地物的风险,对于分布过于密集的区域,存在较多的异类地物,并且其光谱距离相近,此时邻域信息的引入易造成错误分类。基于此,在后续的研究中将考虑寻找更加合适的相似度平衡方法,进一步优化权重,为实现多种特性融合分类打下基础。

参考文献

- [1] Du, B., Huang, Z.-Q., Wang, N., *et al.* (2018) Joint Weighted Nuclear Norm and Total Variation Regularization for Hyperspectral Image Denoising. *International Journal of Remote Sensing*, **39**, 334-355. <https://doi.org/10.1080/01431161.2017.1382742>
- [2] Li, X., Zhang, L.-P., Du, B., *et al.* (2017) Iterative Reweighting Heterogeneous Transfer Learning Framework for Supervised Remote Sensing Image Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **10**, 2022-2035. <https://doi.org/10.1109/JSTARS.2016.2646138>
- [3] 杜培军, 夏俊士, 薛朝辉, 等. 高光谱遥感影像分类研究进展[J]. 遥感学报, 2016, 20(2): 236-256.

-
- [4] Luo, F.-L., Huang, H., Liu, J.-M., *et al.* (2017) Fusion of Graph Embedding and sparse representation for Feature Extraction and Classification of Hyperspectral Imagery. *Photogrammetric Engineering and Remote Sensing*, **83**, 37-46. <https://doi.org/10.14358/PERS.83.1.37>
- [5] 王佳宁. 基于联合稀疏表示与形态特征提取的高光谱图像分类[J]. 激光与电子学进展, 2016, 53(8): 802-804.
- [6] Sparrer, S. and Fischer, R.F.H. (2015) MMSE-Based Version of OMP for Recovery of Discrete-Valued Sparse Signals. *Electronics Letters*, **52**, 75-77. <https://doi.org/10.1049/el.2015.0924>
- [7] Wright, J., Yang, A.Y., Ganesh, A., *et al.* (2009) Robust Face Recognition via Sparse Representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **31**, 210. <https://doi.org/10.1109/TPAMI.2008.79>
- [8] Fang, L., Li, S., Kang, X., *et al.* (2015) Spectral-Spatial Classification of Hyperspectral Images with a Supercpixel-Based Discriminative Sparse Model. *IEEE Transactions on Geoscience and Remote Sensing*, **53**, 4186-4201. <https://doi.org/10.1109/TGRS.2015.2392755>
- [9] Wang, Z., Nasrabadi, N.M. and Huang, T.S. (2015) Semisupervised Hyperspectral Classification Using Task-Driven Dictionary Learning with Laplacian Regularization. *IEEE Transactions on Geoscience & Remote Sensing*, **53**, 1161-1173. <https://doi.org/10.1109/TGRS.2014.2335177>

知网检索的两种方式:

1. 打开知网页面 <http://kns.cnki.net/kns/brief/result.aspx?dbPrefix=WWJD>
下拉列表框选择: [ISSN], 输入期刊 ISSN: 2161-8801, 即可查询
2. 打开知网首页 <http://cnki.net/>
左侧“国际文献总库”进入, 输入文章标题, 即可查询

投稿请点击: <http://www.hanspub.org/Submission.aspx>

期刊邮箱: csa@hanspub.org