

Passive IR Ranging Based on Ensemble Learning

Zhao Jing*, Xiaoning Fu

College of Electromechanical Engineering, Xidian University, Xi'an Shannxi
Email: *290247335@qq.com

Received: Feb. 25th, 2019; accepted: Mar. 13th, 2019; published: Mar. 20th, 2019

Abstract

To improve the practicability and accuracy of passive IR ranging, a new passive IR ranging method based on ensemble learning is proposed. The atmospheric transmittance data of 3.5 μm - 4.0 μm and 4.5 μm - 4.7 μm in different range are generated by MODTRAN, then these data are converted to voltage based on infrared transmission theory, using these voltages to establish single gbdt, xgboost and adaboost models under the framework of boosting, and then merge the three models with stacking method as the final model. At last, the accuracy of the model is tested by testing data. For comparison, average method is also used to merge the three models above. The result shows that stacking method can make further improvement of accuracy.

Keywords

Passive IR Ranging, Dual-Band, Infrared Radiation, Ensemble Learning

基于集成学习的红外双波段被动测距模型

景 钊*, 付小宁

西安电子科技大学机电工程学院, 陕西 西安
Email: *290247335@qq.com

收稿日期: 2019年2月25日; 录用日期: 2019年3月13日; 发布日期: 2019年3月20日

摘 要

为了提高红外被动测距模型的精度和实用性, 基于集成学习的方法, 提出了一种由数据驱动的红外被动测距模型。首先利用MODTRAN生成3.5 μm ~4.0 μm 和4.5 μm ~4.7 μm 波段下不同距离和高度角的大气透过率数据, 然后结合红外辐射传输理论将这些数据转换为红外探测器对应的电压值, 接着在集成学习的

*通讯作者。

boosting框架下, 利用这些电压数据分别建立gbdt、xgboost、adaboost测距模型, 并对模型参数进行了优化, 然后采用集成学习的stacking方法对上面建立的3种模型进行融合作为最终模型, 最后用测试数据检验了该模型的预测效果, 为了作对比, 论文还使用了average融合方法。结果表明, 采用stacking融合的模型能够实现很高精度的预测。

关键词

红外被动测距, 双波段, 红外辐射, 集成学习

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

红外被动测距技术由于不向外辐射能量, 具有极强的隐蔽性和军事价值。目前的红外被动测距技术主要有基于几何原理的被动测距[1] [2], 基于红外图像的被动测距[3]和基于光谱吸收的被动测距[4] [5] [6]等, 这些方法都是通过物理原理或数据分析的方式来建立具体的模型, 再利用算法估计模型参数, 最后实现测距。这些方法虽然都有着较强的理论基础, 但计算相对复杂且距离解算条件都比较苛刻。而机器学习属于一种数据驱动的方法, 它能够按照一定的策略, 自动地建立输入和输出数据的映射关系, 这为红外被动测距提供了一种新的思路。本文首先用 MODTRAN 获取了不同距离、温度和天顶角下的大气透过率数据, 然后结合红外辐射传输理论将这些数据转换为对应的探测器电压值, 最后基于这些电压值及其对应的距离建立了集成学习测距模型, 并用测试数据检验了模型的预测效果。

2. 红外被动测距原理

自然界中任何温度大于绝对 0 摄氏度, 物体都会发出红外辐射, 普朗克在 1900 年推导出了黑体辐射公式,

$$L_{bb}(\lambda, T) = \int_{\lambda_1}^{\lambda_2} \frac{C1}{\lambda^5} \left(\frac{1}{e^{\frac{c2}{\lambda T}} - 1} \right) d\lambda \quad (1)$$

其中 $L_{bb}(\lambda, T)$ 为黑体的光谱辐出度, 单位为: $W/(m^2 \cdot m)$, λ 为波长, 单位为 m , T 为黑体的温度, 单位为 K , $c1$ 为第一辐射常数, $c1 = 3.74 \times 10^{-16} W \cdot m^2$; $c2$ 为第二辐射常数, $c2 = 1.4398 \times 10^{-2} m \cdot K^2$ 。

物体发出的红外辐射在地球大气中传输时会受到大气的衰减, 这种衰减是由大气的吸收和散射共同造成的。假设目标黑体的初始辐照度为 $L_{bb}(\lambda, T)$, 则在距离 R 处目标的辐照度变为

$$E_R = \tau(\lambda, R) \frac{L_{bb}(\lambda, T)}{R^2} \quad (2)$$

其中 $\tau(\lambda, R)$ 为大气透过率[5], 是一个随波长和距离变化的物理量,

$$\tau(\lambda, R) = e^{-\mu(\lambda)R} \quad (3)$$

$\mu(\lambda)$ 为大气的消光系数, 由吸收系数和散射系数组成, 消光系数和大气的气象条件密切相关。大气透过率 $\tau(\lambda, R)$ 是一个与波长、距离气象条件等因素相关的量, 难以直接计算, 该数据可由 MODTRAN 软件仿真生成。

假设在距离目标 R 处有一个红外探测器, 探测器的电流响应率为 r_I , 单位为 $\text{mA} \cdot \text{W}$, 探测器的有效光敏面积为 A_s , 在不考虑背景和接受电路本身噪声干扰的前提下, 探测器最终的输出光电流为

$$I_{\text{sensor}} = \tau(\lambda, R) \frac{L_{bb}(\lambda, T)}{R^2} \cdot A_s \cdot r_I \quad (4)$$

得到光电流后可以通过 I/V 变换电路将光电流转换为适合的电压值, 再经过对电压放大、滤波等处理后, 送入 A/D 转换器转换为数字信号, 最后将数字信号送入微处理器如 DSP 中, 处理器通过一定的算法解算出最终距离。从上面分析可以知道, 处理器最终得到的数字电压值是一个和目标距离相关的量, 可以首先在实际中建立不同温度、天气和距离条件下对应电压值的数据库, 然后基于这些数据库采用数据驱动的方式建立测距模型。

3. 集成学习算法

集成学习是一种将多种学习器结合起来以提升预测效果的机器学习算法, 根据学习器集成方法的不同可分为 bagging、boosting 架构。

Bagging [7] 是一种并行的集成学习方法, 它首先对原始训练数据集进行有放回的抽样, 从而得到多份数据集, 然后对每一份数据集训练一个基模型, 这些基模型彼此是独立的, 最后采用投票法(分类问题)或平均法(回归问题), 将多个基模型的输出结果融合起来得到最终的输出。Boosting [8] 则是一种串行的训练策略, 它每轮迭代生成的模型都和前一轮的模型有一定的关系, 最终的模型为一系列模型的线性组合, 基于 boosting 架构的方法有 GBDT、xgboost、adaboost 等。

本文的测距模型主要采用了 Boosting 的策略, Boosting 中采用了 gbdt、adaboost、xgboost 这 3 种提升方法。gbdt 的全称是 Gradient Boosting Decision Tree, 是 Freeman [9] 提出的一种分步加性模型, 在每次迭代中通过用决策树来拟合损失函数的负梯度, 以此不断的减小误差, 最终模型由一系列决策树相加构成, 对于均方损失函数, 其负梯度就是真实值和预测值之间的残差。

Adaboost [10] 的全称是 adaptive boosting, 它通过给不同的样本赋予不同权值的方法来改变样本的分布, 每次给分类错误的样本较大的权重, 在训练过程中该样本会被更多的关注到, 并且每次训练中给予误差较大的模型较小的权重, 最终的模型为多个基模型的加权组合。

Xgboost 的全称为 extreme Gradient Boosting, 它是由陈天奇 [11] 提出的在 GBDT 基础上的一种改进算法, 利用了损失函数的一阶、二阶导信息, 同时为了防止过拟合, 在损失函数中引入了正则化项。Xgboost 引入了并行化的训练方法, 相对于 gbdt 有着更快的训练速度。

集成学习算法的基学习器采用了决策树, 预测时不需要复杂的数学运算, 所以相对神经网络, 集成学习具有更快的预测速度。本文首先基于仿真生成的数据集建立了上述 3 种模型, 并对每种模型的参数进行了优化, 最后采用了 stacking 策略将 3 种模型融合起来以提升测距精度。

4. 训练数据的获取与处理

本文中用来建模的数据是通过仿真生成的, 假设目标发热物体是标准黑体, 由公式(1)可知, 只要知道发热物体的温度和对应的波段, 就可以计算出物体的光谱辐出度, 本文中设置目标的温度范围为 273 K~373 K, 其中温度增加的步长为 5 K, 所以总共有 21 个温度段。3 μm ~5 μm 的中波波段有较高的大气透过率, 同时又可以携带很高的能量, 所以本实验用到的 2 个波段分别为 3.5 μm ~4.0 μm 、4.5 μm ~4.7 μm , 通过公式(1)可以计算出不同温度段, 对应波段的光谱辐出度。公式(2)中的大气透过率数据由 MODTRAN 生成, MODTRAN 是由美国空军地球物理实验室研发的一款专业的大气辐射传输模拟软件包 [12]。本文在 MODTRAN 中设置的波长范围为 3.5 μm ~4.7 μm , 波长增加的步长为 0.0016448 μm 。天顶角范围为 5~90 度,

天顶角的增加步长为 5 度, 季节分别为中纬度夏季和冬季, 每个季节又分为 3 种气溶胶条件, 乡村 23 km, 城市 5 km, 以及海洋 23 km, 距离增加范围为 500 m~23 km, 增加步长为 50 m, 具体设置如图 1 所示。

Figure 1. The setting of MODTRAN
图 1. MODTRAN 的设置

在 MODTRAN 中分别按照上面的距离段设置好参数, 然后运行得到不同距离和天顶角下对应的透过率, 再结合公式(2)可以计算出不同经过大气衰减后的辐出度。假设探测系统的光伏探测器选用滨松的 P-13243, 其有效光敏面积为 0.7×0.7 mm, 电流响应率为 4.5 mA/W。再按照公式(4)可以计算出不同距离条件下 2 个波段的光电流值 $I_{sensor1}$ 和 $I_{sensor2}$, 然后在后级处理电路中将 I_{sensor} 放大一定的倍数作为采集到 A/D 转换器的电压值 U_1 和 U_2 的放大倍数为 $1e6$, U_1 和 U_2 以及目标的高度角在实际中都是可测的, 把它们作为训练数据的特征, 距离作为预测值, 为了增加模型的准确性, 将 $\frac{u1-u2}{u1+u2} * 100$ 也作为训练数据的一个特征, 最终用于训练的数据格式如下表 1。

Table 1. The format of training data
表 1. 用来训练的数据格式

3.5 um~4.0 um 波段电压 $u1$	4.5 um~4.7 um 波段电压 $u2$	高度角	$u1-u2/u1+u2$	距离: m
4050	4460	80	4.81	1500
4020	4300	90	3.36	1500
3750	3960	5	2.72	1550
3740	3900	10	2.09	1550
⋮	⋮	⋮	⋮	⋮
160	200	90	11.11	16,400

5. 本文建模的流程与预测结果

本文建模时采用了 python 的 scikit-learn 库, scikit-learn 是一款基于 python 的第三方开源机器学习库, 它涵盖了几乎所有的主流机器学习算法, 并且提供了易于使用的 python 接口。本论文中用到的集成学习模型有 gbdt、xgboost、adaboost, 这些模型在 scikit-learn 库都有对应的接口函数, 分别为 GradientBoostingRegressor、XGBRegressor 以及 AdaBoostRegressor。




Figure 2. The flow chart of stacking model
图 2. stacking 融合建模的流程图

本文建模的流程图如图 2 所示, 首先将第三节中生成的数据集划分为训练集和测试集 2 部分, 其中训练集占 70%, 测试集占 30%。然后利用训练集分别建立 gbdt、xgboost 和 adaboost 模型, 因为预测距离属于回归问题, 所以模型迭代时的损失函数为均方损失, 即

$$\varphi(F_i(x), Y_i) = \frac{(Y_i - F_i(x))^2}{2} \tag{5}$$

在建立单模型时, 采用网格搜索+5 折交叉验证的方式对每个模型的参数进行调整以保证单个模型达到最优。在得到单模型后, 再采用 stacking 的方式将所有模型融合。Stacking 是由 Wolpert 于 1992 年提出的一种模型融合方法[13] [14] [15], 它一般由多层模型组成, 将前一层模型的输出作为后一层模型的输入, 最后一层的模型为最终的输出结果。Stacking 的流程如图 3 所示。

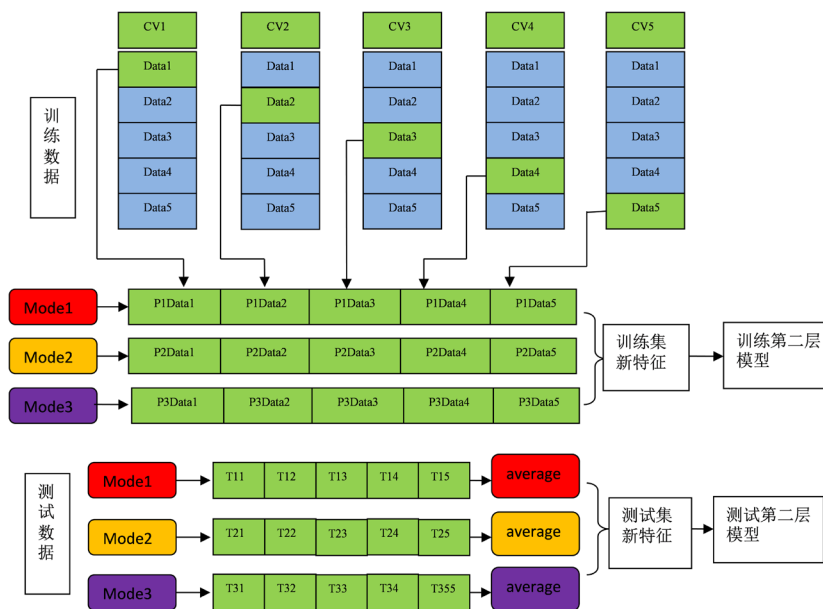


Figure 3. The schematic diagram of stacking method
图 3. stacking 方法原理图

首先将训练数据分成 5 份, 分别为 Data1、Data2、Data3、Data4 和 Data5, 在 cv1 步骤, 使用 Data1 作为测试集, 其余四份数据作为训练集, 训练 Model1, 然后用 Model1 预测 Data1 得到 P1Data1, 同时用 Model1 预测测试数据得到 T11。在 cv2 步骤, 使用 Data2 作为测试集, 其余四份数据作为训练集, 训练 Model1, 然后用 Model1 预测 Data2 得到 P1Data2, 再用 Model1 预测测试数据得到 T12, 以此类推, 将每个 cv 的 Model1 对测试集预测的结果 P1Data1、P1Data2...P1Data5 堆成一列作为下个模型的一个训练集特征, 同时将 5 个 cv 对测试数据的预测结果 T11、T12...T15 取平均作为下一个模型测试集的特征。对 model2

和 model3 重复上述的步骤, 可以得到下个模型测试集和训练集剩余的特征。然后用新得到的测试集和训练集训练第二层的模型, 该模型的输出为最终的预测结果, 本文中第二层模型选用了 GBDT 算法。为了与 stacking 融合作对比, 本文还使用了 average 融合的方式, average 融合流程如图 4 所示。




Figure 4. The flow chart of average model

图 4. average 融合建模的流程图

Average 融合的算法相对于 stacking 较为简单, 它只是将所有基模型的输出结果取平均后作为最终结果。

以下是按照上述方法建立的模型对中纬度夏季 - 乡村能见度 23 km 的测试数据集进行预测的结果, 测试数据集总共有 43,246 个点, 距离范围 500 m~23 km。




Figure 5. The error of GBDT model

图 5. 使用单 GBDT 模型预测误差




Figure 6. The error of xgboost model

图 6. 使用单 xgboost 模型预测误差




Figure 7. The error of adaboost model

图 7. 使用单 adaboost 模型预测误差




Figure 8. The error of stacking model

图 8. 将三种模型 stacking 融合的预测结果

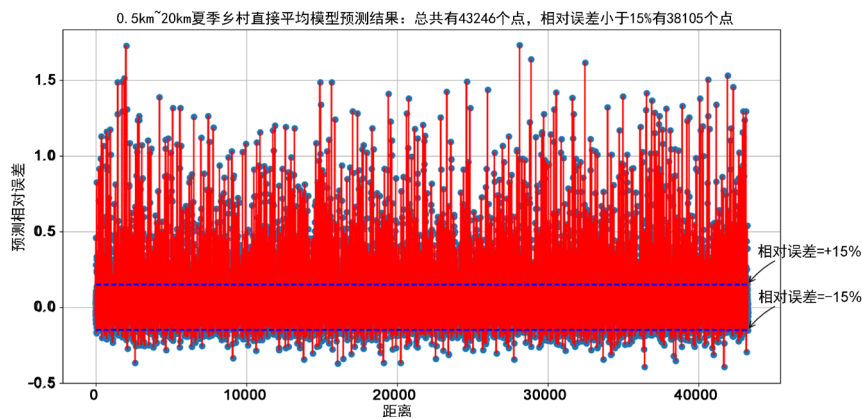


Figure 9. The error of average model

图 9. 将三种模型 average 融合的预测结果

上面的图 5~9 为分别采用单 gbdt、单 xgboost、单 adaboost、stacking 融合以及 average 融合的预测误差, 纵轴表示的是相对误差。从图中可以看出, 在单模型预测中, xgboost 的预测正确率最高, 其次是 GBDT 模型, 但 GBDT 模型预测的方差较大, 采用 average 融合的错误率可能高于单个模型, 但 average 的模型预测的数据比较稳定, 而采用 stacking 融合预测的结果是所有模型中准确率最高的。

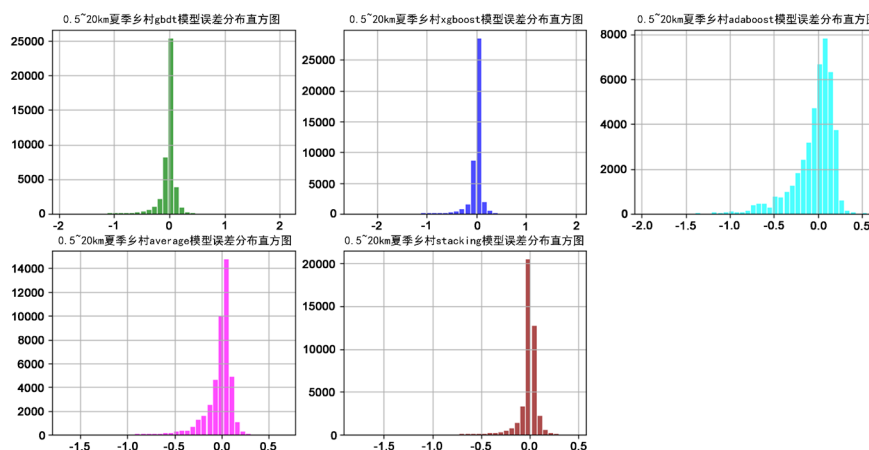
Table 2. The statistical characteristics of the five models' predicting error**表 2.** 5 种模型的预测误差统计表

	Error	Mean	Median	Var
Gbdt	0.1089	-0.0203	0.0047	0.0238
Xgboost	0.0838	-0.0173	0.0003	0.0201
Adaboost	0.2188	-0.0379	0.0273	0.0549
Average	0.1189	-0.0252	0.0149	0.0239
Stacking	0.0706	-0.0136	0.0054	0.0148

其中 Error: 相对误差小于 15% 的点所占比例, Mean: 所有测试数据相对误差均值; Median: 所有测试数据相对误差中位数; Var: 所有测试数据相对误差的方差。

表 2 为 5 种模型预测相对误差的统计特性, 从表中能看出 stacking 模型的错误率和方差都是最小的, 这说明该模型的准确率和稳定性都比较好, 其次是 xgboost 模型, average 融合和 adaboost 预测的错误率较高, 但预测较为稳定, 该结论从下面的误差分布图也能看出来。


几种模型预测的误差分布直方图 (X轴: 误差范围, Y轴: 范围内的数量)



231: 单 gbdt 模型预测误差分布; 232: 单 xgboost 模型预测误差分布; 233: 单 adaboost 预测误差分布; 233: average 融合的误差分布; 234: stacking 融合的误差分布。

Figure 10. The histogram of the five models' predicting error**图 10.** 几种模型的预测误差分布图

从图 10 可以看出, adaboost 和 average 模型融合的误差范围比较集中, 这说明预测较为稳定, 但误差较低时对应的样本数量不多, 所以错误率较高。Xboost 和 GBDT 模型的正确率较高, 但误差分布范围较大, 而 stacking 融合模型的误差分布范围小, 而且正确率很高。

**Figure 11.** The comparison of stacking and average model**图 11.** average 和 stacking 融合的预测距离对比

从图 11 可以看出, stacking 预测的结果更加接近真实的距离值。

6. 结论

本文首先用 MODTRAN 生成了不同季节和能见度条件下的大气透过率和距离数据, 然后结合红外辐射传输理论将这些数据转换为不同距离下双波段探测器的输出电压, 然后用这些数据分别建立了 GBDT 和 xgboost 以及 adaboost 集成学习测距模型, 并对模型参数进行优化, 最后通过 stacking 的方法将 3 种模型融合起来, 实现了更高精度的预测, 并与 average 融合结果作了对比, 该方法具有一定的理论和实用价值。但本文的训练数据是通过软件生成的理想数据, 在计算时没有考虑探测系统的噪声和背景干扰, 而在实际应用过程中, 一方面传感器测得的数据可能包含着噪声等因素, 需要在现场进行标定, 重新计算模型参数, 另一方面为了提升模型的精度, 需要建立更加精确的数据库。

参考文献

- [1] 赵洪宇, 何建伟, 王卫红. 针对海面目标的机载红外单站几何定位技术[J]. 中国电子科学研究院学报, 2017, 12(4): 410-413.
- [2] 李盈, 马宁, 贾鹏, 等. 机载远程红外双站测距研究[J]. 激光与红外, 2017, 47(8): 982-986.
- [3] 杨德贵, 黎湘, 肖顺平. 基于单站双波段红外图像的面目标被动测距研究[J]. 信号处理, 2010, 26(5): 714-718.
- [4] 安永泉, 王志斌, 李晋华, 等. 基于 O₂ 吸收特性单站被动测距机理研究[J]. 红外与激光工程, 2015, 44(1): 310-316.
- [5] 飞行器尾焰红外辐射及其被动测距[J]. 红外与激光工程, 2013, 42(7): 1660-1664.
- [6] 冯国强, 邹强, 李伟仁. 单站双波段红外被动测距算法研究[J]. 红外技术, 2005, 27(4): 295-298.
- [7] Drucker, H. (1997) Improving Regressors Using Boosting Techniques. In: *14th International Conference on Machine Learning*, Morgan Kaufmann Publishers Inc., 107-115.
- [8] Friedman, J., Hastie, T. and Tibshirani, R. (2000) Additive Logistic Regression: A Statistical View of Boosting (With Discussion and a Rejoinder by the Authors). *Annals of Statistics*, **28**, 337-374. <https://doi.org/10.1214/aos/1016218223>
- [9] Friedman, J.H. (2001) Greedy Function Approximation: A Gradient Boosting Machine. *Annals of Statistics*, **29**, 1189-1232. <https://doi.org/10.1214/aos/1013203451>
- [10] Freund, Y. and Schapire, R.E. (1995) A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting.
- [11] Chen, T. and Guestrin, C. (2016) XGBoost: A Scalable Tree Boosting System. In: *ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, ACM, New York, 785-794.
- [12] 马鹤. 基于 MODTRAN 的复杂大气条件下红外系统作用距离计算[D]: [硕士学位论文]. 南京: 南京航空航天大学, 2013.
- [13] Wang, S.Q., Yang, J. and Chou, K.C. (2006) Using Stacked Generalization to Predict Membrane Protein Types Based on Pseudo-Amino Acid Composition. *Journal of Theoretical Biology*, **242**, 941. <https://doi.org/10.1016/j.jtbi.2006.05.006>
- [14] Wolpert, D.H. (1992) Stacked Generalization. *Neural Networks*, **5**, 241-259. [https://doi.org/10.1016/S0893-6080\(05\)80023-1](https://doi.org/10.1016/S0893-6080(05)80023-1)
- [15] Freund, Y. (1995) Boosting a Weak Learning Algorithm by Majority. *Information & Computation*, **121**, 256-285. <https://doi.org/10.1006/inco.1995.1136>

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