

热红外发射率微米级宽谱带选取方法对高光谱重构的影响

邓志刚¹, 赵红梅², 曾庆轩¹, 汪晨薇², 潘平平³

1. 华东交通大学信息与软件工程学院,南昌,330013;

2. 江西师范大学鄱阳湖湿地与流域研究教育部重点实验室/地理与环境学院,南昌,330022;

3. 江西师范大学物理与通信电子学院,南昌,330022

摘要: 高光谱重构 (HSR, Hyperspectral Reconstruction) 是基于高光谱窄带—多光谱宽带之间函数关系的逆函数, 利用常见的多光谱信息进行高光谱模拟的技术。目前, HSR 研究多聚焦于可见光红外谱带, 针对热红外发射率 HSR 的研究几近空白。前期相关研究多利用现有的卫星多光谱波段, 关注 HSR 模型的优化, 对面向 HSR 的多光谱宽谱带划分和选取问题则很少涉略。本研究利用柏油路、大理石、灰色地砖、油漆表面、绿色地砖、石板路和砖混路面等 7 类地表覆盖类型共 727 条 8—14 μm 的实测热红外发射率高光谱数据, 突破传统等间隔和卫星谱带复刻等宽谱带划分的思路, 考虑温度—发射率病态耦合问题, 引入量子遗传算法 (QGA, Quantum Genetic Algorithm), 结合 HSR 模型, 提出温度—发射率相关系数聚类及基于 QGA-HSR 模型谱带选取方法, 在对热红外宽谱带进行优选的同时, 对比分析不同宽谱带划分方式影响下线性非正则化多重线性回归 (MLR, Multiple Linear Regression)、逐步线性回归 (SLR, Stepwise Linear Regression)、线性正则化岭回归 (RR, Ridge Regression)、LASSO 回归和弹性网络回归 (ENR, Elastic Network Regression), 以及非线性支持向量机回归 (SVM, Support Vector Machine Regression) 和神经网络回归 (NNR, Neural Network Regression) 等多种 HSR 模型的性能。研究发现: LASSO 和 ENR 模型对宽谱带划分方法敏感度不高, RR 对宽谱带划分方法则比较敏感; 线性正则化 RR 模型的平均误差最小, ENR 的最大误差最低; 热红外宽谱带划分方法通过其结果宽谱带中心波长和带宽影响 HSR 发射率在波长方向上的误差变化, 如, QGA-SLR 宽谱带优选结果可改进 HSR 发射率在波长方向上的误差差异, 进而提升 HSR 模型的整体性能。研究成果不仅可以提升热红外 HSR 模型的性能, 提高多源热红外遥感产品的可比性。同时, 优选的热红外宽谱带还可以为热红外遥感传感器的研发提供技术支撑。宽谱带选取方法和 HSR 模型的优化组合可为全谱带 HSR 提供方法支撑。

关键词: 高光谱重构, 热红外发射率, 宽谱带, 量子遗传算法, 机器学习方法

中图分类号: TP701

引用格式: 邓志刚, 赵红梅, 曾庆轩, 汪晨薇, 潘平平. XXXX. 热红外发射率微米级宽谱带选取方法对高光谱重构的影响. 遥感学报, XX(XX): 1-14

DENG Zhigang, ZHAO Hongmei, ZENG Qingxuan, WANG Chenwei, PAN Pingping. XXXX. The Influence of Micrometer-level Broadband Selection Method for Thermal Infrared Emissivity on Hyperspectral Reconstruction. National Remote Sensing Bulletin, DOI: 10.11834/jrs.20265424]

1 引言

高光谱重构 (HSR, Hyperspectral Reconstruction) 是基于宽—窄谱带之间的相关关系, 利用宽带多光谱数据模拟窄带高光谱数据。光谱重构理论和方法的探讨不仅能够解决某些应

用中光谱分辨率不足的缺陷, 还能在一定程度上辅助高光谱数据测量光谱仪的研发 (Du 等, 2024)。目前, 光谱重构多针对可见光红外谱带进行 (Zhang 等, 2022)。由于热红外高光谱遥感的缺失, 使得利用热红外宽谱带对热红外高光谱进行重构的研究几近空白。热红外发射率 HSR 研究

收稿日期: 2025-10-08; 预印本: XXXX-XX-XX

基金项目: 国家自然科学基金项目 (编号: 42161062, 42361066), 龙计划六期项目 (编号: ID95531)

第一作者简介: 邓志刚, 研究方向智能计算。E-mail: dzg@ecjtu.edu.cn

通信作者简介: 赵红梅, 研究方向环境遥感, E-mail: zhm8012@jxnu.edu.cn

的匮乏，又使得我们在多源宽谱带热红外遥感中未考虑谱带带宽、中心波长的差异而导致的发射率的差异（Coll等，1994）。以裸壤、岩石为例，8—12 μm 范围内发射率变化范围为0.7—1.0（Prabhakara和Dalu，1976）；而在5—8 μm 和12—14 μm 范围内变率则较小（Tang等，2011）。回顾ASTER（<https://search.earthdata.nasa.gov>）、GF-5（<https://grid.cpeos.org.cn>）、Landsat以及MODIS（<http://www.gscloud.cn>）等系列卫星上携带的热红外波段的光谱分辨率，基本上都在微米级以上，且已有卫星热红外谱带的带宽和中心波长各不相同。若不考虑谱带差异，使用几近相同的发射率进行温度反演，势必会降低多源热红外遥感反演产品之间的可比性。

针对不同的地物类型，谱带的波长范围不同，发射率的日变异幅度也不同（Ermida等，2020）。宽—窄谱带之间的关系随着光谱波段的变化亦具有明显的差异（Pinker和Ewing，1986）。热红外宽谱带的划分方式及其划分结果成为制约宽谱带发射率HSR的主要问题之一。等间隔划分的方式相对比较粗暴，且未考虑多个物种之间的光谱差异。众所周知，发射率和温度的病态耦合问题是制约热红外定量遥感的主要难题和关键问题之一。根据发射率和温度在不同波长处的耦合相关系数（Tang等，2014），采用聚类分析方法可一定程度上缓解发射率和温度耦合关系的不确定性带来的误差。近年来，随着机器学习方法的发展，基于机器学习方法的特征波段优选方法（Deng等，2024），亦可为热红外宽谱带的划分提供技术支撑。本研究拟使用多种地物实测热红外发射率高光谱信息，采用多种方式对8—14 μm 区间的高光谱发射率进行微米级宽谱带分隔，并模拟计算相应宽谱带的发射率，为宽—窄谱带之间的关系探索和热红外发射率HSR提供数据支撑。

宽谱带地表发射率可表述为分离通道发射率的线性组合（Palluconi等，1996），可利用线性组合法从窄谱带地表发射率提取宽谱带地表发射率（Ogawa等，2002；2003）。假定，地表发射率光谱可通过一个精确的线性函数加以描述，则宽谱带地表发射率可利用线性光谱发射率约束法提取（Wang等，2010）。De Zoysa等（2012）则利用辐射能量循环理论实现窄—宽谱带热发射能量的转

换。针对辐照度的窄—宽谱带之间的转换，可采用辐射传输模型（Liang，2001）及方程模拟方法（Wouter和Johnnes，2004）。本研究正是借鉴线性约束和辐射能量平衡理论，利用高光谱窄带发射率模拟计算宽谱带发射率。

相较于利用窄谱带发射率模拟宽谱带发射率而言，利用宽谱带发射率对窄带高光谱发射率进行重构则具有一定的挑战。问题的关键是解释宽谱带发射率与窄带高光谱发射率之间的关系。考虑到不同类型地物的高光谱发射率在不同波长区间的高频变异，常规全域的回归分析方法很难凑效。机器学习方法的发展为宽—窄谱带间相互关系的探索提供新的思路。线性非正则化的多重线性回归（MLR，Multiple Linear Regression）（Oukawa等，2022）和逐步线性回归（SLR，Stepwise Linear Regression）模型（Kokaly和Clark，1999；He，2023），以及线性正则化的LASSO、岭回归（RR，Ridge Regression）和弹性网络回归模型（ENR，Elastic Network Regression）（Wang等，2019；赵启东等，2020；Lu等，2021），以及非线性机器学习方法（随机森林（RF，Random Forest）、支持向量机回归（SVM，Support Vector Machine Regression）、神经网络回归算法（NNR，Neural Network Regression）等广泛用于构建生物地理参量与光谱特征之间的关系（Aires等，2022；Pan等，2021；Singhal等，2024；Tuerxun等，2025），亦可用于热红外发射率宽—窄谱带之间关系的探索。LASSO是一种成熟的稀疏表示变量选择方法，其性能依赖于正则化的参数值。LASSO与岭加同伦算法的结合，可以一定程度上克服LASSO的缺点（Li等，2022）。ENR结合LASSO和RR的思想，当多个特征和另一个特征相关时，ENR非常有用（Wang等，2019；赵启东等，2020；Lei等，2024）。ENR与奇异值分解技术、Kendall tau函数的特征筛选、连续投影（SPA）等技术结合，可用于高协变特征或高维特征的优化选择（Zou和Hastie，2005；Giglio和Brown，2018；Chamlal等，2024；Sun等，2024）。神经网络回归集成方法对于揭示局部和全局关系的机理，具有明显的优势（Pan等，2021；Balasubramaniam和Arnon，2022）。随着机器学习的发展，稀疏波段注意力网络（Zhang等，2024）、XGBoost算法（Shang等，2025）、长短期

记忆网络 (Neela 等, 2025)、超图理论 (Fu 等, 2024) 以及量子智能优化 (Deng 等, 2024; Lei 等, 2024) 等陆续应用于遥感高光谱波段优化选择中。近年来, 自适应正则化 (Kurokawa 等, 2011)、支持向量机回归和核岭回归等方法被用于不同物种的高光谱重构 (Rezaei 等, 2023)。考虑到多个物种高光谱发射率的光谱曲线不同, 宽—窄谱带间的相关关系亦具有多样性。本文拟使用多种回归模型, 采用动态思想实现宽谱带发射率到窄谱带发射率的重构。

本研究克服高光谱热红外卫星遥感缺乏的困境, 使用实测地表发射率高光谱数据, 首先采用等间隔法、温度和发射率相关系数法对微米级宽谱带进行划分, 并利用能量守恒模型计算微米级宽谱带发射率; 引入线性非正则化 (MLR 和 SLR)、线性正则化 (LASSO, RR 和 ENR) 以及非线性 SVM 和 NNR 模型, 探索热红外发射率宽—窄谱带之间的关系, 构建 HSR 模型; 然后利用相对优越的 HSR 模型, 借鉴量子遗传算法对热红外发射率的微米级宽谱带进行优化; 最后, 对比分析不同划分方法对热红外发射率 HSR 精度的影响 (图 1), 为热红外发射率 HSR 及热红外设备的研发, 提供数据和技术支撑。

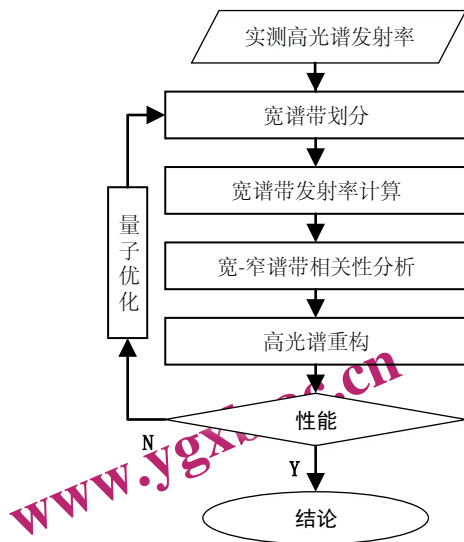


图1 技术流程图

Fig.1 Technical Flow

2 数据的获取与处理

2.1 高光谱热红外发射率

热红外发射率高光谱数据的测量仪器是便携式傅里叶变换热红外光谱仪 (FLIR 102F), 其光谱分辨率 $18\text{--}56\mu\text{m}$, $8\text{--}14\mu\text{m}$ 热红外发射率高光谱数据的光谱波长点数量为 188。数据预处理主要包括异常数据的剔除和基于高斯过程回归模型的发射率光谱光滑处理 (Deng 等, 2024)。本文采用的是经过预处理后的几种典型地表覆盖材料: 柏油路、大理石、灰色地砖、油漆表面、绿色地砖、石板路和砖混路面等的 $8\text{--}14\mu\text{m}$ 热红外发射率高光谱数据 (表 1)。实测上述地表覆盖材料的热红外发射率高光谱数据期间, 同步记录不同时刻不同材料的表面温度, 为后续温度—发射率关系的探索奠定数据基础。

表1 地表覆盖材料的热红外发射率高光谱数据样本数量和温度阈值列表

Table 1 Thermal infrared hyperspectral emissivity sample numbers and temperature range for land cover materials

类型	样本数量	温度变异/°C
柏油路	90	14.9—34.5
大理石	117	16.4—30.1
灰色地砖	115	25.1—43.8
油漆表面	121	22.6—41.0
绿色地砖	119	12.8—26.5
石板路	103	4.2—41.3
砖混路面	62	19—43.4

2.2 微米级宽谱带发射率的计算

据调查, 目前热红外卫星遥感中已有的热红外波段多为微米级宽谱带。本文利用上述实测热红外发射率的高光谱数据, 采用能量守恒原理 (公式 (1)), 同步计算获取微米级宽谱带发射率 (Tang 等, 2011), 为热红外发射率宽—窄谱带关系的探索奠定基础。

$$\varepsilon_{\lambda_1 \rightarrow \lambda_2} = \frac{\int_{\lambda_1}^{\lambda_2} \varepsilon_{\lambda} B_{\lambda}(T) d\lambda}{\int_{\lambda_1}^{\lambda_2} B_{\lambda}(T) d\lambda} \quad (1)$$

其中, $\varepsilon_{\lambda_1 \rightarrow \lambda_2}$ 是波长位于 λ_1 和 λ_2 之间的宽谱带发射率, λ_1 和 λ_2 是宽谱带对应的端点波长; ε_{λ} 是波

长 λ 处的发射率； $B_\lambda(T)$ 为温度 T 情况下波长 λ 处的黑体辐射。温度 T 相同的情况下，如果将分子分母中的黑体辐射相互约减，公式(1)可近似变形为宽谱带区间高光谱窄带发射率向宽谱带发射率转换的等面积计算公式(公式(2))。

$$\varepsilon_{\lambda_1 \rightarrow \lambda_2} = \frac{\int_{\lambda_1}^{\lambda_2} \varepsilon_\lambda d\lambda}{\int_{\lambda_1}^{\lambda_2} d\lambda} \quad (2)$$

3 方法

3.1 数据驱动的高光谱重构方法

考虑到宽—窄谱带发射率的回归关系随波长变化的情况，本文融合机器学习模型，引入动态回归思想，实现数据驱动的热红外发射率HSR。根据宽谱带自变量的数量，并借鉴前期的研究成果，本文拟引入多种正则化和非正则化的动态线性回归模型，包括多重线性回归(MLR)、逐步线性回归(SLR)、岭回归(RR)、LASSO、弹性网络(ENR)等，以及动态非线性支持向量机回归(SVM)和神经网络回归模型(NNR)，对比分析热红外发射率宽谱带的选取方法对HSR的影响。

$$\varepsilon_\lambda = \sum_{p=1}^6 f(\varepsilon_{b_p}) \quad (3)$$

其中 ε_λ 为波长 λ 处窄谱带发射率， ε_{b_p} 为第 p 个宽谱带发射率(对于8—14 μm 区间的微米级宽谱带发射率而言 $p=1, 2, \dots, 6$)， f 代表宽谱带发射率与窄谱带发射率之间的函数关系，包括上述7种模型。

本文引入的线性回归模型的主要差异是：解决多个微米级宽谱带发射率与窄谱带发射率之间的共线性问题的途径不同。MLR和RR中所有微米级宽谱带均作为自变量进行回归分析，其系数均为非0；而SLR和LASSO回归则自动选择最重要的宽谱带变量来放进MLR模型，有可能将不重要的宽谱带发射率的系数压缩为0。ENR则综合了RR和LASSO回归方法两种回归方法的正则化规范，解决多重共线性的问题。考虑到宽谱带发射率与窄谱带发射率可能存在非线性关系的问题，为了探索非线性HSR模型的适用性，尽可能提升热红外发射率HSR精度，并保障算法复杂性的可比性，本研究还引入了与线性回归模型具有一定可比性的浅层NNR(3—5层)(Balasubramaniam和Arnon,

2022)和SVM(Rezaei等, 2023)模型。浅层NNR模型采用三种激活函数(双曲正切激活函数(Tanh)、线性整流函数(ReLU)、逻辑激活函数(Sigmoid))或不采用任何激活函数(None)，SVM模型则采用三种核函数(线性(Linear)、多项式(Polynomial)、径向基(RBF))。通过基于NNR和SVM模型的热红外发射率HSR重构误差的对比分析，选取相对优越的激活函数和核函数(4.1)。

3.2 热红外微米级(μm)宽谱带的选取方法

宽—窄谱带之间的转化，首先需要解决热红外发射率高光谱谱带归类或划分的问题。本文一方面利用现有卫星热红外传感器携带的热红外宽谱带和常规等间隔方式对热红外发射率的高光谱窄带进行宽谱带划分(3.2.1)；另一方面根据发射率—温度相关系数进行聚类，确定谱带(3.2.2)；最后，引入量子遗传算法(QGA)，结合HSR中相对理想的多基因线性回归方法，对微米级热红外宽谱带进行优化(3.2.3)。

3.2.1 卫星谱带和等波长间隔谱带划分(EI, Equal Interval)

目前常用的热红外传感器包括ASTER、GF—5 VIMS、Landsat TIR以及MODIS等。ASTER和GF—5 VIMS在8—14 μm 波段范围内包含5个热红外宽谱带；Landsat TIR和MODIS则分别包含10—12.5 μm 区间内1—2个热红外波段。本文以ASTER的5个热红外宽谱带为基础，结合Landsat TIR和MODIS热红外宽谱带的最大波长值，将8—12.5 μm 划分为6个宽谱带(图6 SAT)。

等波长间隔谱带划分方法则是利用预处理后的热红外发射率高光谱数据，采用等波长间距法，结合能量守恒的等面积公式(2)，确定8—14 μm 波长区间内等间隔的6个 $1\mu\text{m}$ 带宽的宽谱带发射率值。

3.2.2 基于发射率—温度相关系数(ETR, Relationship between Emissivity and Temperature)的聚类方法

利用实测时的表面温度和同步获取的热红外发射率高光谱数据，计算每个高光谱区间温度和发射率的相关系数。然后，计算物种的相关系数(R_λ^t)矩阵及物种间不同波长处温度与发射率相关

系数的标准差 (σR_λ)。最后, 将波长矩阵分别与相关系数矩阵和标准差矩阵结合, 利用K-Mean聚类方法 (Ding 等, 2019), 按波长分为6个微米级宽谱带。

$$R_\lambda^k = \frac{\sum_{i=0}^n (T_i^k - \bar{T}^k)(\varepsilon_{\lambda i}^k - \bar{\varepsilon}_\lambda^k)}{\sqrt{\sum_{i=0}^n (T_i^k - \bar{T}^k)^2 \sum_{i=0}^n (\varepsilon_{\lambda i}^k - \bar{\varepsilon}_\lambda^k)^2}} \quad (4)$$

其中, R_λ^k 为第 k 个物种在波长 λ 处发射率与温度的相关系数, T_i^k 为物种 k 第 i 个样本对应的实测温度, \bar{T}^k 为物种 k 所有样本对应的温度均值, $\varepsilon_{\lambda i}^k$ 为物种 k 第 i 个实测光谱样本波长 λ 处的发射率, $\bar{\varepsilon}_\lambda^k$ 为物种 k 所有实测样本在波长 λ 处的发射率均值。

$$\sigma R_\lambda = \sqrt{\frac{1}{N} \sum_{k=1}^N (R_\lambda^k - \bar{R}_\lambda)^2} \quad (5)$$

其中, σR_λ 为波长 λ 处多个物种温度与发射率相关系数的标准差, \bar{R}_λ 为波长 λ 处, N 个物种温度与发射率相关系数的均值, 本文 $N=7$ 。

3.2.3 基于QGA-HSR优化方法

量子遗传算法 (QGA, Quantum Genetic Algorithm) 在基于高光谱数据的物种分类特征波段选取中取得良好的效果 (Deng 等, 2024)。本文引入QGA算法, 并改进QGA参数初始化值, 组合染色体中的6基因 (GN=6) 的HSR模型, 获取最优波长点。考虑到基因选点的随机性, 本文采用多次循环获取每个物种的20组最优波长组合, 共120个波长组合。集成7种不透水面覆盖材料的最优波长分布数据 (共 $7 \times 120 = 840$ 个波长组合), 采用四分位数统计方法, 将位于第一和第三分位数之间的热红外波长区间确定为热红外发射率的最优谱带。本研究参照4.2部分多种HSR模型的精度, 选取非正则化的MLR、SLR和正则化的ENR三种光谱重构模型, 引入QGA优化模型, 对基于上述三种HSR模型的优化波长, 进行四分位统计, 最终确定优化的微米级宽谱带 (图2)。

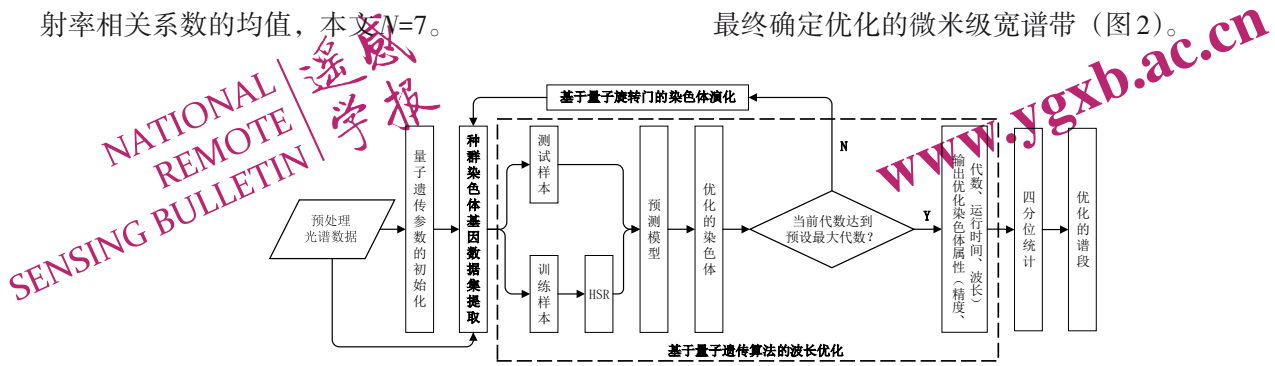


图2 基于QGA-HSR模型的宽谱带优选方法技术流程

Fig.2 Technical flowchart of QGA-HSR optimization method for broadband selection

QGA-HSR算法与基于量子遗传模型的特征波段选取方法 (Deng 等, 2024) 的主要区别是种群染色体基因数据集提取中参数的设置、集成的HSR模型和训练样本的选取等。

(1) QGA-HSR算法中涉及到种群染色体基因数据集的相关参数: 根据已有热红外卫星遥感波段分布数量, 将GN设置为6 (3.2.1)。以物种热红外HSR发射率误差为依据 (3.3), 考虑模型的性能和计算复杂度, 通过对比实验确定种群规模 (NC) 和最大遗传代数 (MGG) (4.1)。

(2) 集成的HSR模型: 包括MLR, SLR和ENR三种HSR模型。

(3) 训练样本和测试样本的设定: 根据前期实验发现, 随着训练样本百分比数量的增加, 机器学习方法的精度会得到明显提升, 训练样本达

到30%以上误差变化趋缓 (图3)。但考虑热红外高光谱数据测量对外界环境要素要求相对苛刻, 获取难度较高, 大样本量机器学习模型会对实测样本的数量提出苛刻的要求, 进而降低模型的适用性。本文主要探索适用于少样本的机器学习方法。因此, 本研究根据每个物种样本总量, 剔除实测温度的极端温度值的影响, 按实测时温度10%和90%分位数值, 及两个温度分位数中间的数值自低至高均匀选取总样本的10%作为训练样本; 总样本中剩余的90%实测光谱作为测试样本。如果某物种总样本数量的10%的整数值为 n , 则选取温度10%和90%分位处的样本外, 在10%和90%温度分位数中间均匀选取 $n-2$ 个样本。

3.3 性能评估方法

为了评估不同HSR模型影响下多种宽谱带划

分方法的性能, 本文采用某个物种 HSR 发射率波长方向误差 (公式 (6)) 和平均绝对误差 (简称“绝对误差”) (公式 (7))、多个 HSR 模型的平均误差 (公式 (8)), 和相对误差 (公式 (9)) (简称“平均误差”和“相对误差”) 作为评估上述 HSR 模型性能的主要指标。

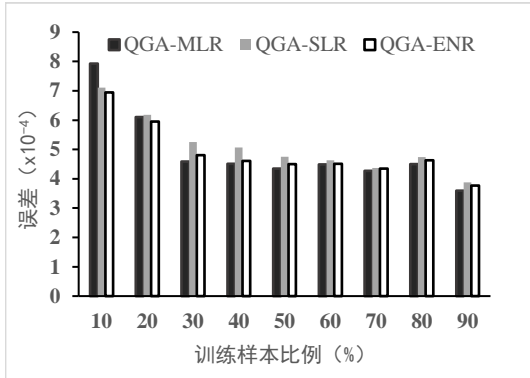


图3 训练样本比例与误差的变化关系

Fig.3 The relationship between the proportion of training samples and prediction error

$$\alpha_{\lambda_i}^s = \varepsilon_{\lambda_i} - \tilde{\varepsilon}_{\lambda_i}^s \quad (6)$$

$$\bar{\alpha}^s = \frac{1}{Nn} \sum_{\lambda=1}^n \sum_{i=1}^N |\alpha_{\lambda_i}^s| \quad (7)$$

$$\bar{\alpha} = \frac{1}{m} \sum_{s=1}^m \bar{\alpha}^s \quad (8)$$

$$\bar{\alpha}^s = \bar{\alpha}^s - \bar{\alpha} \quad (9)$$

其中, $\alpha_{\lambda_i}^s$ 为采用 HSR 模型 s 情况下某个物种第 i 个测试样本在波长 λ 处的误差, $\bar{\alpha}$ 为某个物种 m 个 HSR 模型的绝对平均误差的均值 (模型的平均误差), $\bar{\alpha}^s$ 为使用 HSR 模型 s 的情况下某个物种在 8–14 μm 区间内的平均绝对误差, ε_{λ_i} 为波长 λ 处第 i 个测试样本发射率的观测值, $\tilde{\varepsilon}_{\lambda_i}^s$ 为使用 HSR 模型 s 情况下某个物种第 i 个测试样本在波长 λ 处 HSR 发射率值, m 为 HSR 模型的数量, n 为波长 8–14 μm 区间内波长数量, N 为某物种测试样本的数量, $\bar{\alpha}^s$ 为 HSR 模型 s 的相对绝对平均误差, 即“相对误差”。

4 结果

4.1 非线性数据驱动模型和 QGA-HSR 模型参数的选取结果

对比三种激活函数三个层次的 NNR 模型 7 个物种发射率 HSR 的误差可以发现, 激活函数为 Relu 时误差最小, 且 NNR 层次越高误差越大。因此, 本研究中 NNR 模型的激活函数为 Relu, 层次设为 3。对比三种核函数的 SVM 模型 7 个物种发射率 HSR 的误差则可以发现: 多项式核函数 (Polynomial) 在三种核函数中误差最小, 默认为 3 次多项式回归 (图 4)。

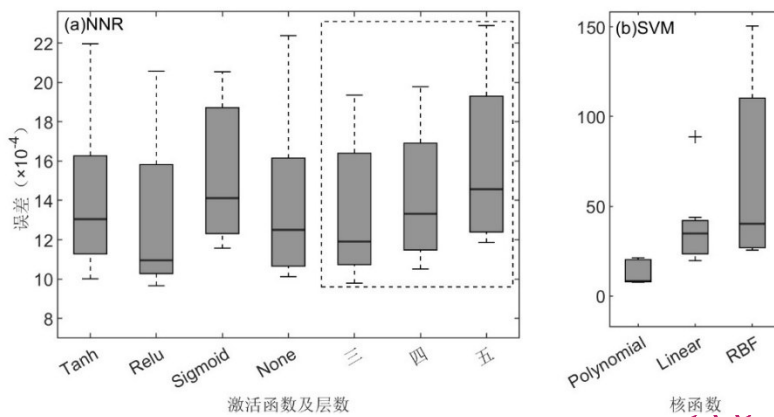


图4 四种激活函数三个网络层次(虚线框内)的 NNR 模型和三种核函数的 SVM 模型预测误差对比图

Fig.4 Prediction error comparison between NNR models with four activation functions and three network levels (in dash box) and SVM models with three kernel functions

以大理石为例, 同一种 QGA-HSR 模型的预测误差由于种群规模 (NC) 和最大遗传代数 (MGG) 的变化而导致的变化范围, 远小于 NC 和 MGG 相同时三种 QGA 模型 (QGA-MLR、QGA-

ENR 和 QGA-SLR) 之间的预测误差 (表 2)。NC=100、MGG \in [10, 100] 时, QGA-MLR、QGA-ENR 和 QGA-SLR 模型的预测误差的差异分别为 0.27×10^{-4} 、 0.22×10^{-4} 和 0.29×10^{-4} ; MGG=20、NC \in

[50, 1000] 时, QGA-MLR、QGA-ENR 和 QGA-SLR 模型的预测误差的差异分别为 0.42×10^{-4} 、 0.12×10^{-4} 和 0.16×10^{-4} 。NC 相同 MGG 变化时, 不同 QGA-HSR 模型之间的差异最小为 0.79×10^{-4} (表 2)。随着 NC 和 MGG 参数的增大, 基于 QGA-HSR

模型的运算时间大幅增加 (图 5 (a) 和图 5 (b))。为了控制运行时间且不影响最终模型间的对比结果, 后文是 NC=100, MGG=20 时的实验结果。

表 2 NC 和 MGG 变化时 QGA-HSR 模型预测误差 ($\times 10^{-4}$)

Table 2 Prediction error of QGA-HSR model due to changes of NC and MGG ($\times 10^{-4}$)

	MGG						V_{MC}	NC					
	10	20	40	60	80	100		50	100	200	500	1000	V_{NC}
QGA-MLR	7.53	7.4	7.4	7.39	7.37	7.26	0.27	7.55	7.5	7.27	7.25	7.14	0.42
QGA-ENR	7.23	7.26	7.13	7.05	7.10	7.07	0.22	7.26	7.24	7.22	7.14	7.16	0.12
QGA-SLR	8.15	8.05	8.06	8.08	7.98	7.86	0.29	8.04	8.16	8.00	8.12	8.15	0.16
RMo	0.92	0.79	0.92	1.03	0.88	0.79	-	0.78	0.92	0.78	0.98	1.01	-

注: 备注: V_{MC} 和 V_{NC} 分别指 MGG 和 NC 变化而导致的 QGA-HSR 模型预测误差的差异; RMo 则是指随着 QGA-HSR 模型变化而导致的 QGA-HSR 模型预测误差的差异。




图 5 QGA-HSR 及 HSR 模型运行时间

Fig.5 Run time of QGA-HSR and HSR models

(a)MGG 变化时 QGA-HSR 模型的运行时间; (b)NC 变化时 QGA-HSR 模型的运行时间; (c)HSR 模型运行时间的箱型统计图

(a) Run time of QGA-HSR models when MGG changes; (b) Run time of QGA-HSR models when NC changes; (c) Run time box plot of HSR models

4.2 微米级热红外宽谱带划分结果

图 6 绘出了 3.2 部分所提到的各种宽谱带选取方法的谱带划分结果。等波长间隔宽谱带划分相对比较简单, 宽谱带区间根据高光谱波长范围等分为 6 份, 相邻两谱带的边界波长连续。基于温度与波长发射率的相关系数, 采用 K-Means 聚类获取的微米级宽谱带波长区间, 亦具有一定的谱带连续性。基于 HSR 模型, 采用 QGA 优化算法所选取的宽谱带则具有一定的离散特征: 相邻宽谱带端点波长不具有连续性 (图 7 (a)、(b) & (c))。

随着集成的 HSR 模型不同, 其谱带区间亦具有一定的差异: 基于 QGA-ENR 和 QGA-SLR 的谱带划分结果相似度较高, 而基于 QGA-MLR 的谱带划分结果与前两种模型的结果差异较大 (图 6)。离散型宽谱带主要出现在 8-14 μm 谱带的两端, 即 8-9 μm 和 13-14 μm 之间。

4.3 热红外高光谱重构模型的精度

为了评估上述 7 种宽谱带划分方法的性能, 本部分采用 MLR、SLR、SVM、NNR、RR、LASSO 和 ENR 等 7 种热红外发射率 HSR 模型, 并计算了

不同 HSR 模型影响下谱带划分的相对绝对平均误差 (图 8 (a) — (g)) , 以及多种 HSR 模型的平均误差 (图 8 (h)) 。

均误差 (图 8 (h)) 。

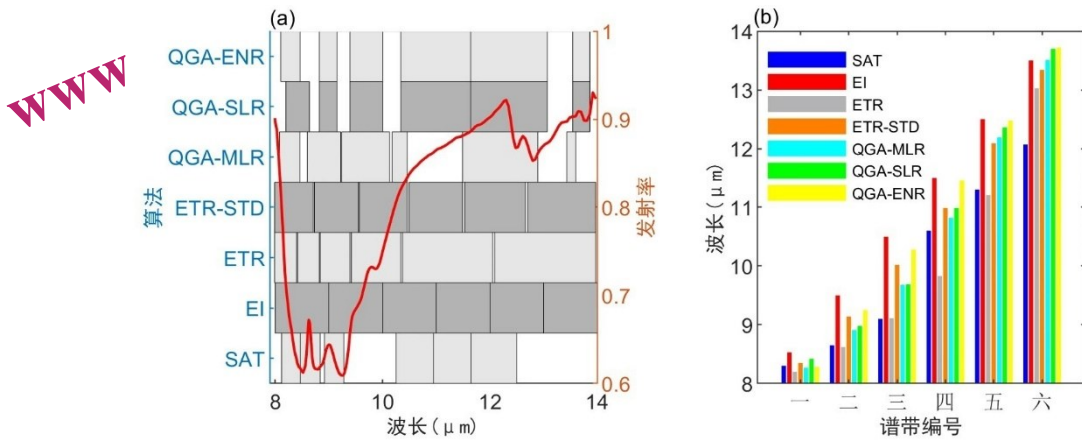


图 6 所提方法划分的热红外微米级宽谱带分布图

Fig.6 Micrometer-level thermal infrared broadband partitioning results of the proposed methods

(a) 谱带分布与大理石发射率曲线对比图; (b) 宽谱带中心波长对比图。备注: SAT 代表现有热红外遥感卫星搭载的宽谱带; EI 是指等波长间隔法划分的微米级宽谱带; ETR 为根据温度和发射率的相关性系数矩阵, 进行聚类后划分的宽谱带; ETR-STD 是根据多个物种温度和发射率的相关性系数的均方差矩阵, 聚类后划分的宽谱带; QGA-MLR 是利用 QGA 和 MLR 组合的方法, 进行四分位统计后得到的宽谱带; QGA-SLR 是利用 QGA 和 SLR 组合的方法, 进行四分位统计后得到的宽谱带; QGA-ENR 是利用 QGA 和 ENR 组合的方法, 进行四分位统计后得到的宽谱带。

(a) Comparison of Broadband Distribution and Marble Emissivity Curve; (b) Center Wavelength of Broadband

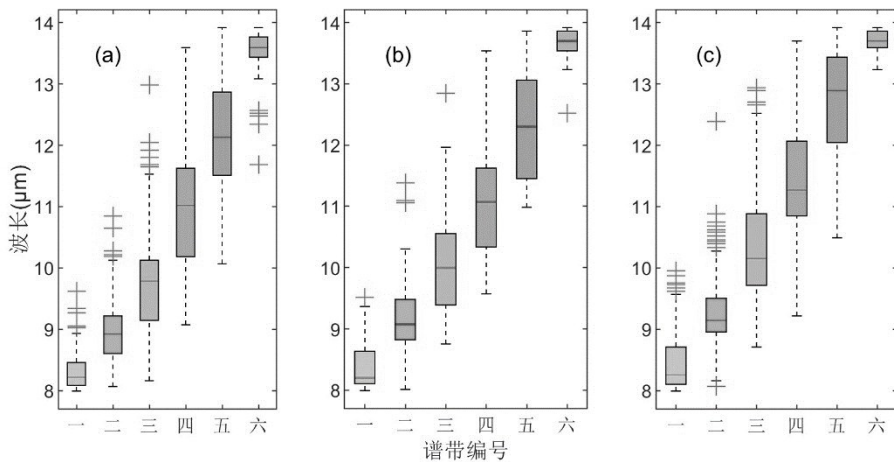


图 7 基于 QGA-HSR 组合模型的宽谱带

Fig.7 Thermal infrared broadband based on QGA-HSR Models

(a) QGA-MLR (b) QGA-SLR (c) QGA-ENR

对比上述 7 种热红外发射率 HSR 模型的相对误差, 不难发现: 非线性的 HSR 模型 SVM 和 NNR 的相对误差最大, 正则化线性 HSR 模型的相对误差较小。SVM 模型的相对误差位于 $0-10 \times 10^{-4}$, NNR 模型的相对误差位于 $2-6 \times 10^{-4}$ 之间 (图 8 (c) 和 (d))。线性 MLR 和 SLR 重构模型的相对误差绝大部分位于 4×10^{-4} 和 2×10^{-4} 以下, 但存在少量高误差的离散点 (图 8 (a) 和 (b))。相对而

言, 正则化线性 RR、LASSO 以及 ENR 模型的相对误差位于 0.0001 以下 (图 8 (e)、(f) 和 (g)) , 但 RR 模型存在少量高于 0.0001 的相对误差点, 多个物种相对误差分布相对离散 (图 8 (e)) 。

从多个物种 HSR 热红外发射率平均误差的均值来看: 利用现有卫星搭载的热红外宽谱带进行热红外发射率 HSR 的平均误差是最高的; 基于 QGA-SLR 及 QGA-ENR 优化方法选取的宽谱带,

能有效提高HSR热红外发射率的平均精度;同时, QGA-ENR优化选择方法可有效降低热红外发射率

HSR的最大误差(图8(h))。




图8 基于不同HSR模型的相对和平均物种误差箱型图

Fig.8 Box plots of relative and average species errors based on seven HSR models

备注:MLR为多重线性回归,SLR为逐步线性回归,SVM为支持向量机回归,NNR为神经网络回归,RR为岭回归,ENR为弹性网络回归。EI为等波长间隔宽谱带划分方法,SAT为现有热红外卫星宽谱带,ETR是根据发射率和温度的相关系数聚类划分的方法,ETR-STD是根据发射率和温度的相关系数标准差聚类划分方法,QGA-MLR是基于QGA优化算法和MLR的波段划分方法,QGA-SLR是基于QGA优化算法和SLR的波段划分方法,QGA-ENR是基于QGA优化算法和ENR的波段划分方法。

5 分析与讨论

7种宽谱带划分结果确认以后,采用多种HSR模型,对本文采用的727条光谱曲线中90%的测试样本进行HSR的运算时间箱型统计图见图5(c)。宽谱带划分结果不同时,同一种HSR模型的运行时间变化较小;但不同HSR模型间运算时间具有一定的差异,SLR和NNR运算时间相对较高,但均在可比范围内。因此本部分宽谱带选取方法对HSR的影响不再考虑运算时间和复杂度的影响,仅从如下两个方面进行分析:一是宽谱带选取结果应用于HSR发射率后的平均绝对误差,可以从总体上评估该宽谱带划分方法的性能;二是宽谱带选取结果应用于HSR后不同波长处的误差,该误差可以分析应用不同谱带划分方法后,在高光谱波长方向上误差的详细差异。

5.1 基于平均绝对误差的影响分析

相对理想的宽谱带选取方法随着HSR模型的变化而变化。考虑到非线性HSR模型相对误差较大(图8(c)和图8(d)),本部分主要针对正则化和非正则化的线性HSR模型开展。在MLR光谱重构中,QGA-SLR方法划分的谱带可以明显的提

升HSR发射率的精度(图8(a))。SLR光谱重构中,基于QGA-MLR的谱带优化结果,可以在一定程度上提升HSR发射率的精度(图8(b))。在RR光谱数据重构模型中,现有的卫星波段划分则可有效减小HSR发射率的平均误差(图8(e))。等波长间隔的谱带划分在LASSO和ENR模型中,尤其是ENR模型中表现相对突出。基于温度和发射率相关系数的谱带划分方法,包括ETR和ETR-STD,可以有效降低基于LASSO模型的HSR发射率中多物种的平均误差(图8(f)和图8(g))。基于QGA谱带优化的三种方法(QGA-MLR、QGA-SLR和QGA-ENR),在RR光谱重构中,可以有效控制多物种的平均误差(图8(e)),在ENR模型中则可以控制物种的最大误差(图8(g))。整体来看,EN宽谱带划分方法应用于ENR光谱重构模型时,取得了较理想的结果;现有的卫星宽谱带应用于RR光谱重构时,各物种的平均误差最小。

5.2 基于物种波长方向误差的影响分析

从不同物种波长方向误差分布和发射率光谱曲线的对比中不难发现:误差偏大的区域位于发射率随波长陡升陡降的区域,详见大理石和建筑

油漆在不同波长处的误差分布图(图9)。其中,大理石的发射率在不同波长的变异较大,误差较大的区域相对集中。因此,本节以大理石为例,对比分析不同谱带划分方法,应用于RR或ENR光谱重构时,在波长方向产生的误差差异(图10(a)和图10(b))。

针对特定的波长区间,如13—14 μm 之间不同谱带选取方法产生的误差差异较大。同一种宽谱带选取方法分别应用于多个线性正则化的HSR模型时,HSR发射率在波长方向上的相对误差差异不大(图10)。第一和第六谱带的分布特征对8—14 μm 两端的误差分布影响显著。

第一谱带的中心波长越靠近高光谱重构的波长边界,边界处的误差越小。ETR划分的第一谱带的中心波长8.2 μm ,是6种谱带划分方法中第一谱带中心波长的最小值(图5(b))。该方法应用于RR和ENR模型进行光谱重构时,在8—8.28 μm 之间产生的误差最小(图10(a)和(b))。QGA-ENR划分的第六谱带的中心波长是13.72 μm ,为6种谱带划分方法中第六谱带中心波

长的最大值,亦最接近8—14 μm 区间的最大波长。该方法的宽谱带划分结果应用于RR和ENR模型进行发射率HSR时,在13.6—13.9 μm HSR发射率的误差最小。现有的卫星热红外宽谱带应用于ENR重构模型时,获得整体最优值。然而,由于缺少靠近14 μm 的谱带,基于SAT和ENR模型的HSR在13—14 μm 之间产生最大误差(图10(a)和(b))。

8—14 μm 端点部位带宽的大小亦可能影响HSR发射率的精度。EI、ETR-STD和ETR等方法划分的宽谱带覆盖8—14 μm 整个波段,但8 μm 端EI宽谱带带宽大于ETR-STD的带宽,ETR的宽谱带带宽最小,且中心波长接近于发射率的峰值区,8 μm 端的HSR发射率误差EI>ETR-STD>ETR。14 μm 端EI、ETR-STD和ETR的谱带带宽依次增加,其HSR发射率误差依次增加。14 μm 端QGA-SLR和QGA-ENR的谱带带宽相似,且均小于上述三种方法的谱带带宽,基于QGA-SLR和QGA-ENR的HSR发射率精度亦高于上述三种方法(图6和图8)。

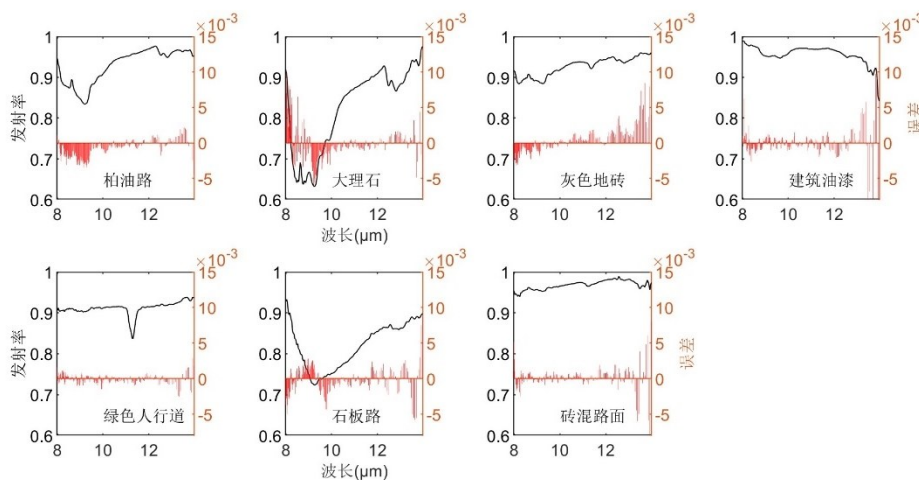



图9 基于EI宽谱带和ENR光谱重构方法的不同物种发射率(黑色折线)及HSR发射率误差(红色柱状图)对比图

Fig.9 Comparison of emissivity (black line) and HSR emissivity error (red bar) of different species based on EI broadband and ENR HSR model



www.yg

遥感学报

图10 基于多种宽谱带划分方法的RR和ENR模型的HSR发射率的误差分布对比图(以大理石为例)
 Fig. 10 Error Distributions Comparison of HSR Emissivity Using RR and ENR Models Based on Multiple Broadband Partitioning Methods(taking marble as an example)
 (a) RR;(b)ENR

6 结论

本研究突破传统等间隔、卫星谱带复刻等单一热红外宽谱带划分思路，基于7种不透水地表材料的热红外发射率高光谱观测数据，考虑温度—发射率耦合关系，引入QGA，提出了结合物理属性（温度耦合）和量子智能优化（QGA）的热红外谱带优化选取方法，构建了完整的高光谱数据获取—模型构建—精度验证研究框架。该研究不仅为热红外HSR模型的选择与优化提供理论支撑，还对热红外传感器设计和遥感应应用均有重要的参考价值。主要结论包括：

(1) 在HSR模型一定的情况下，宽谱带选取方法直接影响到HSR发射率的精度。同时，同一种宽谱带选择方法，随着HSR模型的变化HSR发射率的精度会发生变化。

(2) 综合目前常用的7种HSR模型：非线性和线性非正则化的HSR模型的性能普遍较差；线性正则化的HSR模型效果相对理想。

(3) 对比同一种HSR模型多种宽谱带选取方法影响下的HSR发射率的整体精度，可以发现：LASSO和ENR重构热红外发射率的精度相对稳定，

对宽谱带划分方式不敏感；RR重构模型则取得了最高的平均精度，且对宽谱带划分方法比较敏感。引入QGA算法组合SLR模型的宽谱带优选方法，能够明显提高热红外发射率HSR的整体精度。

(4) 在微米级宽谱带选取方法和HSR模型一定的情况下，HSR发射率在波长方向上的误差受发射率光谱波形的影响较大。某些宽谱带选取方法通过改进中心波长和带宽可以提高特定波形区间HSR发射率的精度。

综上所述，对宽谱带优选方法进行组合，可能会提升全谱带发射率的重构精度。同时，宽谱带选取方法一定的情况下，对HSR模型进行组合，亦可以提升全谱带重构精度。因此，未来的研究可以通过对宽谱带选取方法和HSR模型分别进行组合优化，进一步提升热红外发射率HSR的精度。另外，研究中所采用的非线性模型是相对简单的浅层NNR模型和多项式SVM模型，仅对部分参数进行了调校，不排除非线性HSR模型中存在欠拟合的问题。如果不考虑HSR模型复杂性，未来可以通过对非线性HSR模型的参数进行详细调校，进而论证其在热红外发射率HSR中的适用性。该研究所获取的相对理想的宽谱带划分方式，不仅

可以提升HSR模型的性能,还可以为热红外多光谱传感器的研发提供方法支撑。全谱带HSR发射率精度的提升,又可以为不同热红外波段发射率的精确赋值提供方法支撑,改进热红外定量遥感反演精度,提升多源热红外遥感反演产品的可比性。

参考文献(Reference)

- Aires U R V, da Silva D D, Filho E I F, Rodrigues L N, Uliana E M, Amorim R S S, da Melo Ribeiro C B and Campos J A. 2022. Modeling of surface sediment concentration in the Doce River basin using satellite remote sensing. *Journal of Environmental Management*, 323: 16207 [DOI: 10.1016/j.jenvman.2022.116207]
- Balasubramaniam G M and Arnon S. 2022. Regression-based neural network for improving image reconstruction in diffuse optical tomography. *Biomedical Optics Express*, 13(4): 2006-2017 [DOI: 10.1364/BOE.449448]
- Chamlal H, Benzmane A and Ouadchiman T. 2024. Elastic net-based high dimensional data selection for regression. *Expert Systems with Applications*, 244: 122958 [DOI: 10.1016/j.eswa.2023.122958]
- Coll C, Caselles P and Schmugge T J. 1994. Imation of land surface emissivity differences in the split-window channels of AVHRR. *Remote Sensing of Environment*, 48(2): 127-134 [DOI: 10.1016/0034-4257(94)90135-X]
- De Zoysa M, Asano T, Mochizuki K, Oskooi A, Inoue T and Noda S. 2012. Conversion of broadband to narrowband thermal emission through energy recycling. *Nature Photonics*, 6(8): 535 [DOI: 10.1038/nphoton.2012.146]
- Deng Z G, Zhao H M, Zha W X, Tang L L and Tian Y. 2024. A hyperspectral vegetation feature band selection based on quantum genetic spectral angle mapper algorithm. *Spectroscopy and Spectral Analysis*, 44(11): 3258-3265 (邓志刚, 赵红梅, 查文娟, 汤林玲, 田野. 2024. 基于量子遗传光谱角分类算法的高光谱植被特征波段选取. *光谱学与光谱分析*, 44(11): 3258-3265 [DOI: 10.3964/j.issn.1000-0593(2024)11-3258-08])
- Ding S, Yue Z, Yang S, Niu F, Zhang X. 2019. A novel trust model based overlapping community detection algorithm for social networks. *IEEE Transactions on Knowledge and Data Engineering*, 32(11): 2101-2114 [DOI: 10.1109/TKDE.2019.2914201]
- Du X, Wang Y, Cui Y, Rao G, Huang J, Chen X, Zhou T, Wu C Y, Yang Z Y, Cui H X, Zhao Y C and Xiong J. 2024. A microspectrometer with dual-signal spectral reconstruction. *Nature Electronics*, 7(11): 984-990 [DOI: 10.1038/s41928-024-01242-9]
- Ermida S L, Trigo I F, Hulley G and DaCamara C C. 2020. A multi-sensor approach to retrieve emissivity angular dependence over desert regions. *Remote Sensing of Environment*, 237: 111559 [DOI: 10.1016/j.rse.2019.111559]
- Fu B, Sun X, Cui C, Zhang J and Shang X. 2024. Structure-preserved and weakly redundant band selection for hyperspectral imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17: 12490-12504 [DOI: 10.1109/JSTARS.2024.3425906]
- Giglio C and Brown S D. 2018. Using elastic net regression to perform spectrally relevant variable selection. *Journal of Chemometrics*, 32(8): e3034 [DOI: 10.1002/cem.3034]
- He Z. 2023. Refining time-space traffic diagrams: A simple multiple linear regression model. *IEEE Transactions on Intelligent Transportation Systems*, 25(2): 1465-1475 [DOI: 10.1109/TITS.2023.3316593]
- Kokaly R F and Clark R N. 1999. Spectroscopic determination of leaf biochemistry using band-depth analysis of absorption features and stepwise multiple linear regression. *Remote Sensing of Environment*, 67(3): 267-287 [DOI: 10.1016/S0034-4257(98)00084-4]
- Kurokawa U, Choi B I and Chang C C. 2011. Filter-Based Miniature Spectrometers: Spectrum Reconstruction Using Adaptive Regularization. *IEEE Sensors Journal*, 11(7): 1556-1563 [DOI: 10.1109/JSEN.2010.2103054]
- Lei L, Zheng Q, Dong L, Mo Y, Wang C, Zhang J and Liang B. 2024. Improving the frequency resolution of distribution of relaxation times by integrating elastic net regularization and quantum particle swarm optimization. *International Journal of Hydrogen Energy*, 84: 457-467 [DOI: 10.1016/j.ijhydene.2024.08.173]
- Li H, Dai J, Xiao J, Zou X, Chen T and Holmose M. 2022. Spectral variable selection based on least absolute shrinkage and selection operator with ridge-adding homotopy. *Chemometrics and Intelligent Laboratory Systems*, 221: 104487 [DOI: 10.1016/j.chemolab.2021.104487]
- Liang S. 2001. Narrowband to broadband conversions of land surface albedo I: Algorithms. *Remote Sensing of Environment*, 76 (2): 213-238 [DOI: 10.1016/S0034-4257(00)00205-4]
- Lu J S, Eitel J U, Engels M, Zhu J, Ma Y, Liao F, Zheng H B, Wang X, Yao X, Cheng T, Zhu Y, Cao W X and Tian Y. 2021. Improving Unmanned Aerial Vehicle (UAV) remote sensing of rice plant potassium accumulation by fusing spectral and textural information. *International Journal of Applied Earth Observation and Geoinformation*, 104: 102592 [DOI: 10.1016/j.jag.2021.102592]
- Neela N, Veerakumar T, Panda M K, Subudhi B N, Esakkirajan S and Bouwmans T. 2025. Hybridgt: An integration of graph transformer and lstm for effective hyperspectral band selection. *International Journal of Remote Sensing*, 46(3): 1403-1431 [DOI: 10.1080/01431161.2024.2437744]
- Ogawa K, Schmugge T, Jacob F and French A. 2002. Estimation of broadband land surface emissivity from multi-spectral thermal infrared remote sensing. *Agronomie*, 22(6): 695-696 [DOI: 10.1051/agro:2002055]
- Ogawa K, Schmugge T, Jacob F, French A. 2003. Estimation of land surface window (8-12 μm) emissivity from multi-spectral thermal infrared remote sensing - A case study in a part of Sahara Desert. *Geophysical Research Letters*, 30(2): 1067 [DOI: 10.1029/2002GL016354]

- Oukawa G Y, Krecl P and Targino A C. 2022. Fine-scale modeling of the urban heat island: A comparison of multiple linear regression and random forest approaches. *Science of the Total Environment*, 815: 152836 [DOI: 10.1016/j.scitotenv.2021.152836]
- Palluconi F, Hoover G, Alley R, Nilsen M J and Thompson T. 1996. An atmospheric correction method for ASTER thermal radiometry over land. ASTER Algorithm Theoretical Basis Document (ATBD) Revision 2. Jet Propulsion Laboratory, Pasadena, CA.
- Pan L, Novák L, Lehký D, Novák D and Cao M. 2021. Neural network ensemble-based sensitivity analysis in structural engineering: Comparison of selected methods and the influence of statistical correlation. *Computers & Structures*, 242: 106376 [DOI: 10.1016/j.compstruc.2020.106376]
- Pinker R T, Ewing J A. 1986. Effect of surface properties on the narrow to broadband spectral relationship in clear sky satellite observations. *Remote Sensing of Environment*, 20(3): 267-282 [DOI: 10.1016/0034-4257(86)90047-7]
- Prabhakara C, Dalu G. 1976. Remote sensing of the surface emissivity at 9 μ m over the globe. *Journal of Geophysical Research*, 81(21): 3719-3724 [DOI: 10.1029/JC081i021p03719]
- Rezaei I, Amirshahi S H and Mahbadi A A. 2023. Utilizing support vector and kernel ridge regression methods in spectral reconstruction. *Results in Optics*, 11: 100405 [DOI: 10.1016/j.rio.2023.100405]
- Shang X, Cui C, Sun X, Wang X and Zhang J. 2025. Classification task-driven hyperspectral band selection via interpretability from XGBoost. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 18: 13733-13754 [DOI: 10.1109/JSTARS.2025.3572278]
- Singhal G, Choudhury B U, Singh N and Goswami J. 2024. An enhanced chlorophyll estimation model with a canopy structural trait in maize crops: Use of multi-spectral UAV images and machine learning algorithm. *Ecological Informatics*, 83: 102811 [DOI: 10.1016/j.ecoinf.2024.102811]
- Sun S, Bao W, Qu K, Feng W, Ma X and Zhang X. 2024. Hyperspectral-multispectral image fusion using subspace decomposition and Elastic Net Regularization. *International Journal of Remote Sensing*, 45(12): 3962-3991 [DOI: 10.1080/01431161.2024.2357840]
- Tang B H, Wu H, Li C and Li Z L. 2011. Estimation of broadband surface emissivity from narrowband emissivities. *Optics Express*, 19(1): 185-192 [DOI: 10.1364/OE.19.000185]
- Tang L L, Chen X L, Wang J, Zhao H M and Huang Q T. 2014. A study of the coupling relationship between concrete surface temperature and concrete surface emissivity under natural conditions. *Spectroscopy and Spectral Analysis*, 34(11): 1766-1741 [DOI: 10.3964/j.issn.1000-0593(2014)07-1736-06]
- Tuerxun N, Naibi S, Zheng J, Wang R, Wang L, Lu B and Yu D. 2025. Accurate estimation of lujube leaf chlorophyll content using optimized spectral indices and machine learning methods integrating geospatial information. *Ecological Informatics*, 85: 102980 [DOI: 10.1016/j.ecoinf.2024.102980]
- Wang N, Wu H, Nerry F, Li C and Li Z L. 2010. Temperature and emissivity retrievals from hyperspectral thermal infrared data using linear spectral emissivity constraint. *IEEE Transactions on Geoscience and Remote Sensing*, 49(4):1291-1303 [DOI: 10.1109/TGRS.2010.2062527]
- Wang S, Chen Y, Wang M and Li J. 2019. Performance comparison of machine learning algorithms for estimating the soil salinity of salt-affected soil using field spectral data. *Remote Sensing*, 11(22): 2605 [DOI: 10.3390/rs11222605]
- Wouter G and Johannes O. 2004. Narrowband-to-broadband albedo conversion for glacier ice and snow: equations based on modeling and ranges of validity of the equations. *Remote Sensing of Environment*, 89(1): 95-105 [DOI: 10.1016/S0034-4257(02)00024-X]
- Zhang J, Su R, Fu Q, Ren W, Heide F and Nie Y. 2022. A survey on computational spectral reconstruction methods from RGB to hyperspectral imaging. *Scientific Reports*, 12(1): 11905 [DOI: 10.1038/s41598-022-16223-1]
- Zhang L, Wei Y, Liu J, Wu J and An D. 2024. A hyperspectral band selection method based on sparse band attention network for maize seed variety identification. *Expert Systems with Applications*, 238: 122273 [DOI: 10.1016/j.eswa.2023.122273]
- Zhao Q D, Ge X Y, Ding J L, Wang J Z, Zhang Z H, Tian M L. 2020. Combination of fractional order differential and machine learning algorithms for spectral estimation of soil organic carbon content. *Laser & Optoelectronics Progress*, 57(15): 153001 (赵启东, 葛翔宇, 丁建丽, 王敬哲, 张振华, 田美玲. 2020. 结合分数阶微分技术与机器学习算法的土壤有机碳含量光谱估测, 激光与光电子学进展, 57(15): 153001 [DOI: 10.3788/LOP57.153001])
- Zou H and Hastie T. 2005. Addendum: regularization and variable selection via the elastic net. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 67(5): 768-768 [DOI: 10.1111/j.1467-9868.2005.00527]

The Influence of Micrometer-level Broadband Selection Method for Thermal Infrared Emissivity on Hyperspectral Reconstruction

DENG Zhigang¹, ZHAO Hongmei², ZENG Qingxuan¹, WANG Chenwei², PAN Pingping³

1.School of Information and Software Engineering, East China Jiaotong University, Nanchang, Jiangxi, 330013, P.R. China;
2.Key Laboratory of Wetland and Watershed Research/School of Geography and Environment, Ministry of Education, Jiangxi

Normal University, Nanchang, Jiangxi, 330022, P.R. China;

3.School of Physics and Communication Electronics, Jiangxi Normal University, Nanchang, Jiangxi, 330022, P.R. China

Abstract: Objective Hyperspectral reconstruction (HSR) from multi-spectral information is an ill-posed inverse problem. At present, hyperspectral reconstruction mainly focuses on the visible and near infrared spectral bands, and there is almost no research on thermal infrared HSR due to the absence of hyperspectral thermal infrared remote sensing data, which limits the development of thermal infrared remote sensing. Simultaneously, previous studies often utilize existing satellite multispectral band and focus on the study of HSR models, while the issues of multispectral partitioning and band selection for HSR is seldom focused. We aim to explore the ideal thermal infrared multispectral partitioning and band selection method with a certain HSR model to improve the hyperspectral reconstruction precision of thermal infrared. Method We use in-situ measured 727 hyperspectral thermal infrared emissivity samples of seven land surface cover materials, inc. asphalt roads, marble, gray ground tiles, painted surfaces, green ground tiles, slate paths, and brick-concrete pavements and so on, in this study. The broadband thermal infrared emissivity is calculated from hyperspectral thermal infrared emissivity using energy conservation law, after the broadband range is determined by the following proposed method. We proposed several broadband partitioning methods, such as, traditional equal wavelength interval method, cluster analysis method based on the correlation coefficient between temperature and emissivity and optimization method based on Quantum Genetic Algorithm (QGA) and HSR model. Simultaneously, total seven HSR model, such as non-regular multiple linear regression (MLR) and stepwise linear regression (SLR), regularized ridge regression (RR), LASSO regression, and elastic network regression (ENR), non-linear Support Vector Machine regression (SVM) and neural network regression (NNR) are introduced to compare and analyze the effects of different broad band partitioning methods on above seven HSR models. Result Non-linear HSR models and non-regularized linear HSR models have the higher error than the linear regularized HSR models for the thermal infrared emissivity HSR. LASSO and ENR models are not sensitive to broadband partitioning methods, while RR is more sensitive to broadband partitioning methods. The average error of the linear regularized RR model is the smallest, and the maximum error of ENR is the lowest for the seven land cover material. The distribution of thermal infrared broadband affect the error variation of HSR results at the wavelength direction through the changes of central wavelength and band width. For example, the QGA-SLR broadband optimization results can improve the error difference of HSR at the wavelength direction and enhance the overall performance of HSR. Conclusion The performance of a certain HSR model could be improved by the optimal broadband selection method, which changes with the changes of HSR model. Simultaneously, the ideal thermal infrared broadband not only improve the comparability of multi-source thermal infrared remote sensing products but provide technical support for the research and development of thermal infrared remote sensing sensors. The optimized combination of broadband selection methods and HSR models provides methodological support for full band HSR.

Key words: Hyperspectral Reconstruction, Thermal Infrared Emissivity, Broadband, Quantum Genetic Algorithm, Machine Learning Method

Supported by Supported by the Natural Science Foundation of China (No. 42161062, 42361066) , Dragon 6 Program (ID 95531)

www.ygxb.ac.cn

NATIONAL
REMOTE
SENSING BULLETIN | 遥感学报