

基于 Landsat 8 卫星的黄河悬浮泥沙浓度高精度反演： 物理机理与深度学习的融合

周政^{1,2,3,4}, 黄建雄⁵, 关昊哲⁴, 冶运涛^{1,4}, 顾晶晶⁴,
曹引⁴, 蒋云钟^{1,4}

1. 兰州交通大学 测绘与地理信息学院, 兰州 730070;

2. 地理国情监测技术应用国家地方联合工程研究中心, 兰州 730070;

3. 甘肃省测绘科学与技术重点实验室, 兰州 730070;

4. 中国水利水电科学研究院, 北京 100038;

5. 潮州市潮安区土地整备中心, 潮州 521000

摘要: 全面准确分析黄土高原河段高含沙水沙变化规律对黄河流域水沙调控、防洪安全和生态保护具有重要意义。传统地面监测难以反映泥沙的时空动态变化, 为此本研究基于2013年—2023年黄河干流12个典型水文站点实测泥沙浓度SSC (Suspended Sediment Concentration) 数据与Landsat 8多光谱遥感影像, 构建了引入光谱比因子红光—近红外与短波红外归一化比值指数RANS (Red and Near-Infrared to All Shortwave Infrared Normalized Ratio) 的多任务卷积神经网络模型, 并采用贝叶斯优化实现超参数自适应搜索, 以提升模型在高含沙水体中的泛化能力和稳定性。结果表明, 多任务自优化CNN模型的 $\ln(SSC)$ 决定系数 R^2 达0.837, SSC的RMSE降至1256.75 mg/L, 优于单任务CNN和未优化的多任务模型。基于反演结果揭示了2013年—2023年黄河干流SSC的时空动态变化: 空间上, 中游龙门至潼关段在丰水期单位距离变化率可达12.3 mg/(L·km) (远高于多年平均6.42 mg/(L·km)), 下游小浪底至花园口段在汛期出现-31.97 mg/(L·km)负梯度。综上, 多任务深度学习结合贝叶斯优化可有效提升高含沙河流SSC遥感反演精度, 为未来大流域水沙演变监测、模型耦合及水沙调控策略优化提供方法基础与数据支撑。

关键词: 黄河中游, 高含沙水体, 悬浮泥沙反演, 卷积神经网络模型, 多任务学习, 贝叶斯优化, Landsat 8 遥感影像

中图分类号: TP79/P2

引用格式: 周政, 黄建雄, 关昊哲, 冶运涛, 顾晶晶, 曹引, 蒋云钟. 2026. 基于 Landsat 8 卫星的黄河悬浮泥沙浓度高精度反演: 物理机理与深度学习的融合. 遥感学报, 30(7): 2025–2041

Zhou Z, Huang J X, Guan H Z, Ye Y T, Gu J J, Cao Y and Jiang Y Z. 2026. High-precision retrieval of suspended sediment concentration in the Yellow River based on Landsat 8: Integration of physical mechanisms and deep learning. National Remote Sensing Bulletin, 30(7): 2025–2041 [DOI:10.11834/jrs.20265534]

1 引言

黄河具有水少沙多、水沙关系不协调的显著特征, 以水沙灾害严重闻名于世 (胡春宏等, 2020), 黄河流域水土流失面积超过45万 km^2 , 其中黄土高原是黄河泥沙的主要来源区 (刘晓燕, 2020)。在气候变化与人类活动共同作用下, 黄河水沙过

程的时空格局发生了显著调整, 准确获取悬浮泥沙浓度SSC (Suspended Sediment Concentration) 的时空分布特征是认识黄河水沙演变机制、支撑流域水沙调控与生态保护的重要基础。

SSC的变化直接影响河道输沙能力、河床演变和水资源调度过程, 同时与水体浑浊度、水生态系统健康及入海泥沙通量密切相关 (Li等, 2020)。

收稿日期: 2025-12-25; 预印本: 2026-05-11

基金项目: 国家自然科学基金面上基金 (编号: 52279031); 国家重点研发计划 (编号: 2023YFC3209302-03); 国家自然科学基金青年基金 (编号: 52309040)

第一作者简介: 周政, 研究方向为水资源遥感研究。E-mail: 794236463@qq.com

通信作者简介: 冶运涛, 研究方向为水文水资源、智慧水利研究。E-mail: yeyuntao@iwhr.com

围绕SSC的遥感反演,国际上已形成较为系统的研究体系,早期研究为经验模型,通过单波段或波段比值建立SSC与光谱反射率之间的统计关系,在全球尺度逐步构建了标准化数据基础(Dethier等, 2022)。随着遥感数据与计算能力的发展,半分析模型及机器学习方法被引入SSC反演研究,例如利用半分析框架开展湖泊与近岸水体悬浮物反演(Lymburner等, 2016),基于卷积神经网络实现高时间分辨率SSC估计(Xie等, 2024),在一定程度上提升了模型精度。国内SSC遥感反演研究亦取得了丰富成果,研究对象涵盖近岸海域、湖泊水库及主要河流,多源卫星数据被广泛用于经验模型与机器学习建模(陈燕等, 2014; 侯雪姣, 2020),随机森林等非参数模型在部分水域表现出较好的反演性能(方馨蕊等, 2019; 杨传训等, 2023)。

尽管上述研究推动了SSC遥感反演的发展,但在高含沙水体条件下,现有方法仍面临挑战。研究表明,当SSC超过一定阈值后,红光与近红外波段反射率随浓度增加逐渐趋于饱和甚至下降,而短波红外波段受水体强吸收控制呈现持续衰减特征,导致光谱对SSC变化的敏感性降低(Doxaran等, 2002),同时悬浮泥沙颗粒增强后向散射,使可见光和近红外波段反射率整体抬升,并与泥沙粒径组成、矿物成分及有机质含量等因素产生复杂耦合(Wang等, 2023; Peterson等, 2020)。针对黄河流域,Qiu等基于Landsat系列影像构建了覆盖1986年—2022年的SSC经验模型(Qiu等, 2024),生成了目前时间跨度最长的黄河干支流SSC产品,为黄河泥沙长期变化研究提供了重要支撑,但该类研究多依赖经验模型或单任务回归框架,即直接建立光谱特征到SSC数值的映射关系,在高含沙条件下,这类方法仍难以缓解光谱非线性和饱和效应带来的系统偏差,不同河段和不同时期的反演精度存在一定差异,尤其在高浓度区间和复杂水沙背景下,模型泛化能力仍有提升空间。

近年来,深度学习方法被引入SSC遥感反演,在整体精度上取得一定提升,但现有研究多采用单任务学习框架,仅以SSC回归作为优化目标,模型训练缺乏对泥沙敏感光谱结构或物理机理的显式约束,在高浑浊、高噪声环境下,这类模型易过度依赖样本分布特征,导致跨河段或时间迁移应用稳定性下降。多任务学习MTL(Multi-task Learning)作为深度学习的重要范式,近年来在计

算机视觉、水质监测及遥感解译等领域得到广泛应用(裴启立, 2024; 朱盼盼等, 2021)。相关研究表明,MTL通过在共享特征表示基础上联合多个相关任务协同优化,有效利用任务间的内在关联性引导模型关注具有稳定判别力的关键特征,从而抑制过拟合并提升泛化能力。鉴于高含沙水体光谱非线性和饱和效应的问题,引入光谱比因子RANS(Red and Near-Infrared to All Shortwave Infrared Normalized Ratio)作为辅助任务,因为其基于物理机理(红/近红外散射增强与短波红外吸收抑制的相对关系),利用其能有效捕捉跨谱段特征差异的特点提供显式约束,优于传统单波段或经验指数;为克服单任务框架的过拟合问题,引用多任务CNN进行建模,其以共享表示和任务协同优化充分利用RANS与SSC的相关性提升模型鲁棒性,尤其适用于样本分布不均的高浑浊环境(Yan等, 2025; Rahat等, 2023)。此外,为避免超参数人工调优的主观性和低效性,本文采用贝叶斯优化实现自适应搜索,该方法基于高斯过程代理模型刻画目标函数及其不确定性,并通过采集函数实现探索-利用权衡,从而逐步引导采样点向全局最优区域收敛,适用于深度学习黑箱优化(李亚茹等, 2022),从而增强模型在高含沙条件下的稳定性和泛化能力。

现有黄河SSC时空变化分析研究多集中于利用基于多源遥感数据揭示了黄河SSC在长期尺度上的变化趋势及典型区域的季节差异(Song等, 2025),仅将空间分布作为结果展示,缺乏对SSC空间异质性及其随季节和河段变化的精细量化分析。对于高含沙水体,SSC的空间不稳定性不仅是水沙过程的重要表征形式,也是制约遥感反演模型稳定性和泛化能力的关键因素。因此,有必要从空间角度对黄河SSC的分布特征及其梯度变化进行系统化,以更全面地认识其时空演变规律。

基于此,本研究针对黄河高含沙水体中红光—近红外散射增强与短波红外强吸收并存的典型光谱特征,构建具有明确物理意义的光谱结构指数RANS,并将其引入多任务学习框架,作为辅助任务约束模型对泥沙敏感光谱结构的特征学习过程;同时,为降低模型性能对人工经验设定参数的依赖,引入贝叶斯自优化方法,对多任务模型的关键超参数自适应寻优,提升模型在高含沙、强非线性条件下的稳定性和泛化能力;并在此基础上,构建2013年—2023年黄河干流SSC长时间序列遥

感产品，开展时空联合分析，以期揭示 SSC 的空间分异特征及时间演变规律，为黄河水沙调控和智慧管理提供科学依据。

2 研究区概况与数据处理

2.1 研究区概况

黄河干流发源于青海省巴颜喀拉山北麓，最终注入渤海，全长约 5464 km，流域面积约 79.1 万 km² (卢金发和刘爱霞, 2002)。流域气候复杂，上游属于高原山地气候，降水量少且主要集中在夏季；中游为黄土高原气候，降水集中且年内分布不均；下游为温带季风气候，降水相对稳定且河道宽阔。河道形态上，上游多峡谷和高山河段，坡度陡、流速快；中游河道蜿蜒，泥沙输移显著；下游河道平缓，泥沙易沉积。研究区水文条件受季节性降雨和冰雪融水影响明显，SSC 呈现显著的时空变化规律，为基于遥感影像和站点数据的黄河泥沙反演研究提供了典型的自然条件和科学依据。




图1 黄河流域研究区及悬浮泥沙监测站点在 Landsat 8 影像中的空间分布

Fig. 1 Spatial distribution of the Yellow River study area and suspended sediment monitoring stations over Landsat 8 imagery

2.2 数据来源

水文站泥沙数据主要来源多个权威机构和公开数据平台。用于悬浮泥沙反演模型构建的日尺度输沙量、径流量数据来自国家地球系统科学数据中心 (<https://www.geodata.cn> [2025-12-25])；用于长时序特征分析的月尺度输沙量、径流量数据来源于《黄河泥沙公报》。综合考虑数据完整性和研究目标，选取黄河干流 12 个典型水文站

2013 年—2023 年相关数据开展研究。遥感数据为美国国家航空航天局 (NASA) 和美国地质调查局 (USGS) 联合研制的 Landsat 8 卫星影像数据，Landsat 8 影像包含 11 个波段，本研究选取波段 B_1 — B_7 用于水体及悬浮泥沙反演。

2.3 数据预处理

2.3.1 遥感数据预处理

为保证 Landsat 8 多光谱影像与地面 SSC 数据的一致性和可用性，按照下述步骤对数据进行预处理。

(1) 影像裁剪与数据筛选：使用 Landsat 8 OLI Surface Reflectance (SR) collection2 产品，时间范围为每年非冻结期的 3—11 月，以避免冰冻对光谱的影响。影像在 GEE 平台按采集日期筛选，初筛条件为云覆盖率 < 20%；对筛选后的影像采用 pixel_qa 字段进行云/云影掩膜，并以 0.0001 的比例因子将 SR 波段数值换算为地表反射率。为构建稳定时间序列悬浮泥沙产品开展年际、季节变化分析，对同月内的多幅有效影像取水体像元的中位反射率作为该月代表值，降低单幅影像噪声的影响。

(2) 遥感影像预处理：为确保数据的一致性、可比性，所有影像的辐射定标、大气校正与几何校正均通过 GEE 平台的标准化 SR 产品自动完成，采用统一的地理坐标基准。经预处理获得的地表反射率数据质量高、时空一致性好。

(3) 水体提取：使用水体指数方法 (NDWI) 对裁剪后的影像进行水体分割 (McFeeters, 1996)，对每幅影像生成二值水体掩膜，将非水体像素剔除，只保留河道及水域部分，在河岸带、桥梁等复杂区域采用局部手动校验，确保水体像素与地面 SSC 站点位置对应。

(4) 影像匹配：遥感影像与泥沙浓度数据的时间配对遵循“同日优先、邻近补充”的原则，影像采集当日存在有效日尺度观测数据时，直接进行同日匹配；当日数据在质量控制后存在缺测时，在影像采集日前后 ± 3 d 内选取时间最接近的有效观测值进行匹配，若时间间隔超过 3 d，则剔除该样本。空间上，以水文站点坐标为中心提取 3×3 像元窗口内的水体反射率，采用中位值作为代表特征，同时要求窗口内通过水体掩膜判定的像

元比例不低于70%，否则不纳入样本。通过上述筛选流程获得676个高质量样本用于模型训练与评估。

2.3.2 泥沙数据预处理

选取黄河干流中、下游12个基本具备连续十年的日尺度观测数据的典型水文站作为泥沙资料来源。对原始水文资料进行质量控制，剔除明显异常值并识别缺测时段，基于日尺度输沙量与径流量数据，采用质量守恒关系计算得到对应的日尺度SSC，用于遥感影像的时间匹配及反演模型构建。日尺度SSC根据式(1)计算：

$$C = \frac{Q_s \cdot 10^3}{Q_w} \quad (1)$$

式中， C 为日均含沙量，mg/L； Q_s 为断面输沙量日均值，kg； Q_w 为对应的日均径流量， m^3 。

样本选择注重时空匹配和高含沙代表性，筛选676样本SSC范围为12.04—19621.46 mg/L，其中约60%样本>1000 mg/L，聚焦高含沙区间；低SSC样本(<100 mg/L)占15%，反映黄河泥沙典型分布。

3 研究方法

3.1 多任务卷积神经网络

卷积神经网络(CNN)是一类以卷积运算为核心的深度学习模型(LeCun等, 1989)，通过局部感受野、权值共享和池化操作提取输入数据的空间特征，核心结构包括卷积层(Convolutional Layer)、池化层(Pooling Layer)和全连接层(Fully Connected Layer)。

与传统CNN仅针对单一目标输出相比，多任务CNN通过共享卷积特征提取层，输出多个相关任务结果，能够充分利用任务间的相关性提高模型的泛化能力(张钰等, 2020)。多任务CNN的目标函数通常采用各任务损失的加权和形式：

$$L_{total} = \sum_{i=1}^T \alpha_i L_i(\hat{y}_i, y_i) \quad (2)$$

式中， T 为任务数， $\hat{y}_i$ 和 y_i 分别为第 i 个任务的预测值和真实值， L_i 为该任务的损失函数， α_i 为权重系数。

3.2 贝叶斯自优化策略

贝叶斯优化是一种基于概率模型的全局优化

方法，可用于自动调节深度学习模型的超参数，如卷积核大小、学习率、层数等。本研究利用贝叶斯优化自动寻找多任务CNN的最优超参数，其核心思想是利用先验分布对目标函数 $f(x)$ 建模，通过更新后验分布引导搜索最优超参数 x^* ：

$$x^* = \arg \max_{x \in X} f(x) \quad (3)$$

式中， X 为超参数空间。贝叶斯优化通常包含以下步骤：

构建代理模型：利用高斯过程GP(Gaussian Process)对目标函数进行建模，假设目标函数服从GP分布：

$$f(x) \sim GP(\mu(x), k(x, x')) \quad (4)$$

式中， $\mu(x)$ 为均值函数； $k(x, x')$ 为协方差核函数。

定义采集函数(Acquisition Function)：通过平衡探索(Exploration)与利用(Exploitation)选择下一个评估点 x_{next} ，常用采集函数包括期望改进(EI(Expected Improvement))：

$$\alpha_{EI}(x) = \begin{cases} (\mu(x) - f(x^*))\Phi(z) + \sigma(x)\Phi(z), & \sigma(x) > 0 \\ 0, & \sigma(x) = 0 \end{cases} \quad (5)$$

式中， $f(x^*)$ 表示现有的最大值， $\Phi(\cdot)$ 表示正态分布累积分布函数。EI函数球的是为支点函数值比 $f(x^*)$ 大的期望， $z = \frac{\mu(x) - f(x)}{\sigma(x)}$ 是对当前最优值取值的归一化。

迭代更新：在选择的 x_{next} 上计算目标函数值，更新GP后验，重复上述过程直至满足停止条件。

3.3 高含沙水体泥沙遥感模型构建

围绕高含沙水体光谱退化显著、散射增强、非线性耦合等，构建了高含沙水体的SSC遥感反演模型框架(图2)，该框架由“遥感影像光谱特征提取—多任务CNN模型构建—悬浮泥沙含量反演”3部分组成。

在遥感影像光谱特征提取部分，以Landsat 8 OLI反射率产品为基础，经大气校正、几何校正、云雾去除和水体掩膜等预处理，将处理过的遥感影像提取 B_1 — B_7 共7个波段的反射率作为输入特征，为复杂高浑浊场景提供稳定输入。

多任务深度学习模型构建是框架的核心部分，由训练样本数据集与模型输入数据集双通道共同驱动。其中，训练样本由实测SSC数据和其对应的

遥感光谱组合而成，在模型中引入光谱比 RANS 作为模型学习“红光/近红外—短波红外光谱结构特征”的辅助任务，RANS 定义为

$$\text{RANS} = \frac{B_4 + B_5}{B_2 + B_3 + B_6 + B_7} \quad (6)$$

式中， B_2 、 B_3 为蓝光、绿光波段； B_4 为红光波段； B_5 为近红外波段； B_6 、 B_7 为短波红外波段。

RANS 针对高含沙水体典型光谱响应，通过归一化比值放大散射—吸收差异，提供物理约束辅助任务，显著优于无约束模型。多任务 CNN 框架的选择基于其在水质反演中的泛化优势，能抑制高浓度区间误差放大，贝叶斯优化则因其高效全局搜索特性，被用于超参数自适应，避免传统方法（如网格搜索）的计算负担和经验依赖。




图2 融合物理机理约束的多任务 CNN 悬浮泥沙反演模型结构示意图

Fig. 2 Architecture of the physics-constrained multi-task CNN for suspended sediment inversion

RANS 的设计基于高含沙水体的关键光谱机理：红光（Red）与近红外（NIR）波段随 SSC 升高出现显著散射增强，而短红外（SWIR）波段则因水体强吸收而呈现单调衰减，是区分不同浓度区间的有效结构性指标。因此，该比值能够同时放大“增散射（ B_4+B_5 ）”与“减反射（ B_6+B_7 ）”之间的跨波段特征差异，增强高浓度水体光谱形态的一致性表达，并有效抑制高浑浊环境中由噪声、底质和悬浮物粒径差异引起的光谱漂移。已有研

究表明，相似的跨波段比值在复杂浑浊水体的 SSC 反演中具有显著的稳健性与泛化优势（Kabir 和 Ahmari, 2020），因此，将 RANS 作为辅助任务能够使深度网络同时学习“浓度变化规律”与“跨光谱结构规律”，从而在高含沙条件下显著提升模型鲁棒性。

优化目标设定为最小化验证集主任务损失（ val_main_loss ），通过加权损失函数兼顾辅助任务 RANS 的信息约束，实现多任务联合优化。

$$\text{Loss} = \text{MSE}_{\text{main}} + 0.3\text{MSE}_{\text{rans}} \quad (7)$$

式中, MSE_{main} 和 MSE_{rans} 分别是主任务和辅助任务的均方误差; 0.3 是辅助任务损失的权重系数。

联合损失通过加权系数 0.3 控制辅助任务在总损失中的重要性, 确保主任务主导训练过程, 辅助任务在提供光谱信息约束的同时避免对主任务产生干扰, 适当的加权策略能够平衡多任务间的优化目标, 防止单一任务梯度过大导致训练不稳定 (Kingma 和 Ba, 2017)。近年研究表明, 多任务网络可将物理先验 (如光谱比) 与主任务联合学习, 提升水质参数反演的稳定性与泛化性 (Graffeuille 等, 2024), 因此, 将 RANS 作为辅助任务并以 0.3 加权, 作为抑制高浓度区域非线性漂移的有效策略。

基于 TensorFlow 框架构建多任务 CNN。模型输入为 Landsat 8 的 7 个波段地表反射率 (B_1 — B_7)。网络结构共 8 层, 包括 1 个输入层、两个一维卷积层 (Conv1D)、1 个展平层 (Flatten) 和 4 个全连接层 (Dense)。卷积层提取波段间的局部相关特征, 全连接层实现非线性映射与高层特征融合; 所有隐藏层采用 ReLU 激活函数, 在全连接隐藏层后加入 L2 正则化 (权重衰减系数 0.0001) 和 Dropout (丢弃率 0.2), 以有效抑制过拟合。

在模型内部, SSC (以 $\ln(\text{SSC})$ 形式) 和 RANS 被设计为双输出任务, 通过共享卷积特征实现联合学习。输出层分为两个独立分支, 分别预测主任务 $\ln(\text{SSC})$ 和辅助任务 RANS。数据集划分采用 70% 用于训练、30% 用于验证, 以验证集主任务损失 (val_main_loss) 作为模型性能的主要评估指标。

模型训练采用 Adam 优化器, 权重初始值随机均匀分布于 $[-0.07, 0.07]$, 偏置初始化为 0。训练过程中启用早停机制 (EarlyStopping, $\text{patience}=10$, 监控 val_main_loss) 和学习率自适应衰减 (ReduceLROnPlateau, $\text{factor}=0.5$, $\text{patience}=5$), 以提升收敛效率和稳定性。关键超参数 (卷积层滤波器数量、卷积核大小、全连接层神经元数量及学习率) 通过 Keras Tuner 的贝叶斯优化方法在预定义搜索空间内自动搜索最优组合。若当前模型在验证损失上未达到预期, 则进行超参数搜索流程; 搜索完成后, 若性能满足要求, 即输出的 SSC 反演模型。

悬浮泥沙含量反演中, 训练完成的多任务 CNN 模型用于对目标区域的 SSC 进行反演。模型同时生成主任务 SSC 与辅助任务 RANS 的预测结

果, 并通过损失加权策略确保主任务优先优化。反演结果进一步与独立的验证样本对比, 采用偏差、RMSE、 R^2 等指标开展精度评价, 以检验模型在高含沙水体中的应用可靠性, 若模型反演精度良好, 则输出 SSC 时空分布结果。

3.4 精度评价及模型分析

采用多种指标和分析方法全面评估模型的预测精度, 评价指标包括偏差 (BIAS)、均方根误差 RMSE (Root Mean Square Error)、平均绝对百分比误差 MAPE (Mean Absolute Percentage Error) 和决定系数 (R^2), 用于量化模型预测误差大小、偏差方向及拟合优度。结合 K-Fold 交叉验证 (李正良等, 2022)、残差分析与蒙特卡洛方法 (Zheng 和 Han, 2016), 对模型的稳健性、误差特征及预测不确定性分析, 确保反演结果的可靠性和可解释性。

4 结果与分析

4.1 光谱分析及 RANS 分析

4.1.1 泥沙光谱分析

从 676 个采集点位中选择出 12 条典型点位采集的光谱曲线 (图 3), 提取典型光谱曲线均来自于 Landsat 8 OLI 遥感影像, 以黄河干流中、下游 12 个水文站控制断面为中心, 在对应影像中选取稳定水体像元, 提取多波段表面反射率作为代表性光谱特征, 相应的 SSC 数据来源于水文站发布的日输沙量与日径流量数据, 通过质量守恒关系计算获得, 上述处理保证了光谱信息与 SSC 数据在时间和空间尺度上的一致性。图中展示了不同 SSC 与 Landsat 8 所获取的 7 个波段反射率的关系, 横轴为波长 (nm), 纵轴为波段反射率。由图 3 可见 12 条曲线分别代表 12 个不同的泥沙浓度, 浓度从 17 mg/L 到 21647 mg/L 不等, 依次用不同颜色标识。通过分析 Landsat 8 的 7 个波段 (B_1 — B_7) 反射率与 SSC 的关系可知: 蓝绿波段 (B_1 — B_3) 反射率随 SSC 增加略升, 但变化平缓, 敏感性较低; 红光波段 (B_4) 和近红外波段 (B_5) 反射率随 SSC 明显上升, 尤其在高浓度样本中峰值突出, 是 SSC 预测的核心特征; 短波红外波段 (B_6 — B_7) 虽升幅较小, 但可增强高 SSC 样本识别能力并抑制水体背景干扰。总体来看, 低 SSC 样本反射率较低且接近, 高 SSC 样本在红光和 NIR 波段差异最大, SWIR 波段对高浓度样本亦有一定区分能力。




图3 Landsat 8 OLI多光谱波段及其对高含沙水体悬浮泥沙的响应特征示意

Fig. 3 Spectral bands of Landsat 8 OLI and their responses to suspended sediment in highly turbid waters

4.1.2 RANS有效性分析

为定量验证RANS与SSC之间的关系，计算了RANS与 $\ln(\text{SSC})$ 之间的皮尔森相关系数，并绘制散点图及回归拟合曲线。图4展示了训练集468个样本的RANS与 $\ln(\text{SSC})$ 的关系。结果表明，二者之间呈显著正相关（皮尔森相关系数 $r=0.901$ ），其线性回归决定系数为 $R^2=0.81$ ，说明RANS能够有效反映水体中SSC的变化特征。




图4 高含沙水体RANS与 $\ln(\text{SSC})$ 的相关关系及线性拟合结果

Fig. 4 Correlation and linear regression between RANS and $\ln(\text{SSC})$ under high sediment concentration conditions

相较于其他常用光谱指数，传统NIR/Red比率常用于中等浊度水体SSC估计但高SSC时易出现反射率饱和，导致敏感性显著下降，简单可见光带比率易受底质和粒径干扰，相关性通常在0.7—0.8，

RANS通过归一化引入短波红外（SWIR）波段，能有效缓解高浓度区间的饱和效应，并放大红/近红外散射增强与SWIR吸收抑制的相对差异。该指数在测试集中的皮尔森相关系数、线性回归系数显著优于多数传统比率，表明其在高含沙水体条件下具有更强的稳健性和判别能力。将RANS作为多任务学习的辅助任务，能为模型提供更可靠的光谱结构约束，提升整体反演精度和泛化性能，总体而言，高RANS值对应较高的 $\ln(\text{SSC})$ ，低RANS值对应较低的 $\ln(\text{SSC})$ ，进一步验证了将RANS作为与SSC高度相关的辅助特征输入CNN模型的合理性。

4.2 模型性能与验证

4.2.1 模型稳定性分析

为全面验证多任务CNN模型在高含沙水体SSC反演中的性能，本研究从训练收敛性、超参数优化效果及预测不确定性3个方面进行评估，损失函数变化如图5（a）所示。可见模型在前几个轮次内快速收敛，随后在约150—200次迭代后趋于稳定，验证损失保持低位且未出现过拟合，说明卷积结构与正则化策略配置合理。验证损失略低于训练损失与辅助任务RANS的损失权重设置有关，表明多任务机制能够向主任务提供额外光谱约束，增强学习稳定性并减少损失波动。

在此基础上，通过贝叶斯优化对卷积核数量、卷积核大小、全连接层规模及学习率等关键超参数进行自动搜索，优化后的模型表现出更快的收敛速度和更低的训练、验证损失，提升了网络在复杂非线性光谱—SSC关系下的表达能力，多任务结构与贝叶斯优化的结合有效提高了模型的泛化能力，在高浑浊水体场景中表现更佳。

为进一步量化模型预测的稳定性，开展了30次独立训练的蒙特卡洛实验，结果如图5（b）所示。可见多任务模型相较单任务CNN具有更窄的95%误差置信区间，说明共享特征表示能够有效降低随机初始化和样本扰动引起的预测波动。贝叶斯优化的多任务CNN在整个迭代范围内误差带最稳定、分布最集中，表现出最低的不确定性水平，证明优化后的模型对高含沙水体高噪声光谱环境具有更强的稳定性。整体而言，蒙特卡洛评估验证了模型在不同初始条件下的重复性与稳定性，进一步支持所构建的高含沙水体SSC反演模型具有较高的可靠性与应用价值。




图5 多任务CNN模型训练与验证过程特征

Fig. 5 Features of the training and validation process of a multi-task CNN model

4.2.2 模型对比

为评估不同模型在黄河高含沙水体SSC遥感反演中的性能，对比分析了单任务CNN、多任务CNN以及采用贝叶斯优化的多任务自优化CNN 3类模型在独立测试集上的预测精度。3类模型测试集的预测值与实测值的拟合关系如图6所示。

由图6 (a) 可见，单任务CNN模型在 $\ln(\text{SSC})$ 尺度下表现出较高的拟合精度 ($R^2=0.793$, $\text{RMSE}=0.641$, $\text{MAPE}=8.35\%$, $\text{Bias}=-0.034$)，预测点整体分布接近1:1参考线。然而，当转换至原始SSC尺度后，模型性能显著下降 ($R^2=0.004$, $\text{RMSE}=2561.20 \text{ mg/L}$, $\text{MAPE}=60.63\%$, $\text{Bias}=194.29 \text{ mg/L}$)，显示出严重的系统性高估，尤其在高浓度区间拟合效果较差。

由图6 (b) 可见，相比之下，在传统单任务CNN结构基础上引入RANS光谱比辅助任务的多任务CNN模型显著改善了预测性能：在 $\ln(\text{SSC})$ 尺度下， $R^2=0.835$, $\text{RMSE}=0.619$, $\text{MAPE}=8.58\%$, $\text{Bias}=-0.016$ ；在原始SSC尺度下， R^2 提升至0.710， RMSE 降低至1374.33 mg/L， $\text{MAPE}=57.73\%$, $\text{Bias}=-129.21 \text{ mg/L}$ 。与单任务CNN相比，多任务模型在 $\ln(\text{SSC})$ 尺度下 R^2 提高约5%， RMSE 降低约3.4%， Bias 绝对值减少约一半；在原始SSC尺度下， R^2 由几乎为零(0.004)大幅提高至0.710， RMSE 降低约46.3%， MAPE 降低约2.9个百分点， Bias 由明显正偏(+194.29 mg/L)转变为幅度更小的轻微负偏(-129.21 mg/L)，高浓度样本区域的系统性高估现象明显缓解。

性能提升主要来源于多任务结构与RANS辅助任务的协同作用：一方面，多任务CNN通过硬参数共享机制，使卷积主干特征提取网络同时服务于SSC与RANS2项回归任务，迫使模型从原始光谱中提取对SSC变化更敏感、对环境噪声和光照条件更鲁棒的共享特征，从而减弱了单任务模型在高浓度区因光谱饱和和样本不平衡导致的特征退化与偏置；另一方面，RANS光谱比与SSC在研究水体中具有近似单调且物理上可解释的对应关系，相较于绝对反射率，其对观测几何和辐照度变化更不敏感，将其作为辅助预测任务等效于在损失函数中引入具有光学机理约束的正则化项，抑制了对数逆变换后高浓度样本误差的放大，提升了模型在原始浓度尺度上的稳定性与泛化能力。

由图6 (c) 可见，贝叶斯优化进行超参数自适应的多任务自优化CNN模型在3类模型中表现出整体最优性能。在 $\ln(\text{SSC})$ 尺度下，该模型取得最高的 R^2 (0.835) 和几乎为零的系统偏差 ($\text{Bias}=-0.001$)， $\text{RMSE}=0.614$, $\text{MAPE}=8.62\%$ ；在原始SSC尺度下， R^2 进一步提升至0.837， RMSE 进一步降低至1256.75 mg/L， $\text{MAPE}=58.33\%$, $\text{Bias}=-137.53 \text{ mg/L}$ 。相较于未优化的多任务CNN，贝叶斯优化主要通过自适应搜索卷积层数、卷积核大小及学习率等超参数，在保持多任务结构与RANS辅助任务所带来核心收益的基础上，进一步平衡了拟合精度与模型复杂度，使原始SSC尺度下的 RMSE 额外降低约8.6%，模型在两种尺度下均实现了最佳的综合精度与一致性。




图6 不同模型的黄河SSC反演结果与实测值对比(测试集)

Fig. 6 Comparison of Yellow River suspended sediment concentration inversion results from different models with measured values (test set)

3种模型在ln(SSC)尺度下的预测性能均显著优于原始SSC尺度,这种系统性差异主要源于SSC浓度的强右偏态分布特征:高浓度样本的绝对误差在原始尺度上呈指数级放大效应,而对数变换有效压缩了极端值的相对影响,使误差分布更加对称、模型拟合更趋稳定。在此基础上,多任务CNN及其自优化版本通过RANS辅助任务进一步削弱了高浓度样本误差放大的不利影响,使原始SSC尺度下的 R^2 和RMSE得到实质性改善,即便Bias的绝对值略有波动,其对整体模型性能的影响远小于RMSE和MAPE显著改善所带来的收益。

综上所述,多任务自优化CNN模型在黄河高含沙水体SSC遥感反演中展现出最优异的预测能力,与单任务CNN相比,该模型显著缓解了高浓度区的系统偏差问题;与普通多任务CNN相比,通过贝叶斯优化进一步提升了超参数适应性和预测精度,在ln(SSC)和原始SSC这两种尺度下均实现了最高的 R^2 、最低的RMSE以及更可控的偏差,该模型在复杂高含沙水体浓度遥感反演应用中具有更高的可靠性和潜在实用价值。

4.2.3 模型验证

为全面验证多任务自优化卷积神经网络模型的准确性、可靠性及适用边界,从交叉验证稳定性、浓度分层适用性及光学条件泛化能力3个维度进行系统评估。

通过残差分布特征比较可以得知,多任务自优化CNN模型的残差分布最为集中,呈现明显的窄峰形态,残差值主要聚集在0附近,极端正负偏差显著减少,表明其对异常样本的鲁棒性更高;多任务CNN模型次之,相比之下,单任务CNN的残差分布最为分散,尾部范围更宽,极值偏差幅度更大,反映出其在高浑浊场景中更易受到光谱非线性和噪声的影响。从三者对比可见,多任务学习能够有效压缩残差分布,提高反演稳定性,而在此基础上引入贝叶斯自优化进一步提升了模

型对参数空间的自适应搜索能力,使得模型在高含沙水体中呈现出更佳的误差控制效果。

研究所采用的五折交叉验证是在全流域、全时段混合样本基础上的随机划分:676个样本同时覆盖了黄河干流上、中、下游12个水文站点,以及2013年—2023年非冰冻期(3—11月)的多年月际变化,SSC范围为12.04—19621.46 mg/L,且高含沙样本占比约60%。在此基础上,各折交叉验证的精度指标波动幅度较小($R^2=0.655\pm0.059$, RMSE=1620±192 mg/L),表明模型在不同河段、不同年份与季节、以及不同含沙水平下均能保持较为稳定的预测性能。从应用角度看,这一结果说明多任务自优化CNN模型不仅在整体样本上具有较高精度,而且对训练—测试样本划分方式不敏感,能够在黄河干流水沙条件时空差异较大的背景下维持稳定的反演能力,具有较好的工程实用性和推广潜力。

为明确模型在不同SSC浓度范围内的预测能力,将全部样本按浓度划分为4个区间,分别进行五折交叉验证,结果如表1所示,结果表明模型在不同浓度区间的预测性能存在差异。在500—5000 mg/L的中高浓度区间,模型表现最优($R^2>0.76$, MAPE<23%),这与该区间样本充足且光谱—浓度关系处于近似线性响应阶段有关。在低浓度区间(<500 mg/L),由于训练样本相对不足(仅占14.9%)且水体光学信号较弱,模型精度有所下降($R^2=0.621$, MAPE=35.2%)。在极高浓度区间(>5000 mg/L),受光谱饱和效应影响, RMSE绝对值较大,但相对误差(MAPE=26.1%)仍维持在可接受范围,表明RANS辅助任务在一定程度上缓解了高浓度区的光谱饱和问题。基于上述分析,本模型的最佳适用区间为500—10000 mg/L的高含沙水体;对于SSC<300 mg/L的低浓度水体,应补充该区间样本进行再训练或采用针对性模型;对于SSC>15000 mg/L的极端高浓度条件,则应结合实测数据进行局部校准。

表1 不同SSC区间下模型五折交叉验证性能评估结果

Table1 Model performance evaluated by five-fold cross-validation across different suspended sediment concentration intervals					
浓度区间/(mg/L)	样本数	占比/%	MAPE	RMSE/(mg/L)	适用性评价
<500	101	14.9	0.621±0.087	94.2±18.6	一般
500—2000	158	23.4	0.762±0.054	298.5±45.2	良好
2000—5000	234	34.6	0.814±0.041	652.3±89.4	最优
>5000	183	27.1	0.773±0.062	1724.6±312.5	良好

为进一步评估模型对不同水体光学条件的适应能力，采用 K-means 聚类方法对样本的光谱特征 (B_1 — B_7 波段反射率) 进行无监督分组，将全部样本划分为 3 个光谱类型簇，分别代表低反射率清水型、中等反射率浑浊型和高反射率强浑浊型水体。随后采用“留一簇验证”策略，即以两个簇的样本训练、第 3 簇样本验证，结果如表 2 所示。可见模型在 3 种光谱类型间均保持较好的预测能力 ($R^2>0.7$)，其中对中等反射率浑浊型水体的预测精

度最高 ($R^2=0.856$ ， $MAPE=21.8\%$)。低反射率清水型水体由于光学信号较弱、样本占比较低，模型精度略有下降；高反射率强浑浊型水体的 RMSE 绝对值较大，但这主要源于该区间 SSC 基数较高 (平均 >8000 mg/L)。结果表明，模型通过多任务学习机制习得的特征表示对不同光学条件具有较好的鲁棒性，能够适应黄河干流复杂多变的水体光学环境。

表 2 不同光谱特征分组条件下模型反演性能的验证结果
Table2 Validation results of model performance under different spectral feature groupings

光谱类型	特征描述	样本数	R^2	RMSE/(mg/L)	MAPE/%
簇 1	低反射率(清水型)	281	0.812	456.2	38.1
簇 2	中等反射率(浑浊型)	334	0.856	1087.5	24.6
簇 3	高反射率(强浑浊型)	61	0.734	2894.1	41.7

训练样本来源于黄河干流 12 个典型水文站，覆盖上游、中游、下游不同河段，SSC 范围为 12—19621 mg/L，光谱特征变化幅度较大，较好地代表了黄河干流高含沙水体的典型光学条件。综合验证结果，本模型在 2000—5000 mg/L 的中高反射率浑浊水体中表现出最佳性能，表明其最适用于该浓度区间的高浊度河流环境。

4.3 时间序列验证

为验证基于 Landsat 8 遥感数据反演的 SSC 产品在时空尺度上的适用性，对黄河干流 12 个典型站点的反演结果进行了对比分析。根据实测含沙量的时间序列特征，选取上游兰州站、中游头道拐站和下游花园口站作为代表，3 个站点分别反映了不同河段的泥沙浓度水平与水体光学特性，能够较全面地体现流域泥沙输移的空间差异。

从 2013 年—2023 年的月均含沙量与估算 SSC 对比结果 (图 7) 可以看出，两者的时间变化趋势总体一致，模型反演结果能较好地捕捉 SSC 的时序变化特征。然而在部分时段或站点存在一定偏差 (在花园口站 RMSE 达 1829.08 mg/L)，这可能与模型训练样本中低浓度泥沙数据相对不足有关，导致模型在低含沙水体条件下的预测精度略低于高含沙情形。

基于 2013 年—2023 年 Landsat 8 遥感影像的反

演结果，分别计算春季 (3—5 月)、夏季 (6—8 月) 和秋季 (9—11 月) 3 季的多年平均 SSC，结果如图 8 所示。可见整体上，黄河干流 SSC 在时间上呈现显著的季节性差异，在空间上表现为由上游向中下游逐渐升高的分布格局，符合实际情况。

其中，春季 (3—5 月) SSC 整体处于较低水平，唐乃亥至兰州河段水体清澈，泥沙浓度相对较小，主要受该时段降水量有限、径流过程平稳及植被恢复初期地表扰动较弱等因素影响；夏季 (6—8 月) SSC 显著增大，尤其在头道拐至龙门河段出现高值区，是全年泥沙浓度最高的时段。此现象与该季节集中降雨及上游支流汇入引发的高径流过程密切相关，反映出丰水期强烈的水动力条件和流域侵蚀作用；秋季 (9—11 月) SSC 较夏季有所下降，但中游河段仍维持相对较高水平，表明受前期洪水冲刷后泥沙再悬浮与滞留效应的共同影响。下游河段在水库调节与径流衰减作用下，SSC 进一步降低，水体逐渐恢复至较为清澈状态。综上所述，黄河干流 SSC 在年内变化中表现出典型的“春季较低—夏季显著升高—秋季逐渐回落”的季节性特征，说明泥沙浓度主要受季节性降雨与径流变化的控制。各季节空间分布格局基本一致，表明泥沙输移过程的空间分异特征具有较强的稳定性，而季节差异主要体现在整体浓度水平及中游高值区的范围变化上。




图7 3个水文站Landsat反演与实测SSC的月均时间序列比较
Fig. 7 Comparison of the monthly average time series of Landsat-inverted and measured SSC at three hydrological stations




图8 黄河干流SSC 2013年—2023年平均季尺度反演结果
Fig. 8 Seasonal-scale spatial distribution of SSC in the mainstem of the Yellow River averaged from 2013 to 2023

4.4 空间分布特征

为揭示黄河干流 SSC 的总体空间分布特征，基于 2013 年—2023 年反演结果计算了多年平均 SSC，并绘制沿河空间分布图（图 9）。由图 9 可知，SSC 总体呈现“上游较低—中游最高—下游降低”的典型格局。其中：上游唐乃亥至头道拐段 SSC 较低，

平均约为 1697 mg/L；中游头道拐至潼关段 SSC 显著升高，达到峰值区间（平均约 14434.48291 mg/L），反映出黄土高原地区强烈的侵蚀与支流汇入效应；下游潼关至花园口段 SSC 明显下降，平均为 5126 mg/L，表明下游拦沙与库区蓄水对输沙过程具有显著削弱作用。




图 9 黄河干流 SSC 2013 年—2023 年平均空间分布图

Fig. 9 Average spatial distribution of SSC in the main stream of the Yellow River from 2013 to 2023

多年平均空间分布图中，区域（I）—（III）表现的是该河段河流的年平均 SSC。可见 3 个区域的年平均 SSC 都呈现出较为明显的变化。其中：区域（I）为上游与中游的交界处，可以看出区域（I）年均 SSC 在 2013 年处于较高水平并逐年下降，在 2019 年后又开始上升至稳定；区域（II）为黄河中游潼关站至下游三门峡站区间，从图中可以看出从 2013 年起年均 SSC 不断升高，升高到峰值即 2021 年后开始稍微下降；区域（III）为黄河下游花园口站附近区域，从图可以看出该区域从

2013 年—2023 年呈现缓慢上升趋势，但是整体变化范围不大。

为了进一步量化黄河干流沿程泥沙变化，本研究在多年平均 SSC 的基础上，对各站点间的 SSC 变化率及单位距离泥沙变化率进行了计算并进行了可视化，如图 10 所示。为计算沿河距离（Distance_km），基于各典型水文站的经纬度坐标采用 Haversine 球面距离公式计算其相对距离（樊东卫等，2019），结果以唐乃亥站为基准点（0 km），依次累加得到各站点的沿程距离。




图10 黄河干流站点2013年—2023年空间分析

Fig. 10 Spatial analysis of mainstream stations of the Yellow River from 2013 to 2023

由图10可见沿程SSC总体呈现出典型的“上游较低—中游显著升高—下游波动变化”的空间分布格局。其中：上游河段泥沙浓度总体偏低，唐乃亥站SSC为465.8 mg/L，兰州站升至575.8 mg/L，石嘴山站达到1708.2 mg/L，沿程变化率逐渐增大，对应单位距离泥沙变化率从0.33 mg/(L·km)增至2.57 mg/(L·km)，整体变化相对平缓。该河段地势较高、水流湍急，但集沙面积有限，受控流区间短，泥沙主要来源于天然侵蚀和局部支流补给，说明上游泥沙输移过程较为稳定；进入中游后，SSC显著升高，是全流域泥沙浓度变化最剧烈的区域。头道拐站泥沙浓度为2331 mg/L，龙门站急剧升至5616 mg/L，达到全程峰值，单位距离泥沙变化率高达6.42 mg/(L·km)；潼关站略增至5689 mg/L，

变化幅度减小至1.29%。这一段河流流经陕北黄土高原，支流众多、侵蚀强烈，大量泥沙汇入干流，使中游成为黄河泥沙汇集与输移的主控区；下游河段泥沙浓度波动明显，呈“急降—缓升—再降”的复杂特征。三门峡站SSC为7341 mg/L，至小浪底站骤降至4406 mg/L，变化率-22.5%，单位距离梯度达-31.97 mg/(L·km)，表明水库的拦沙与调控作用显著。随后花园口站3631 mg/L，高村站回升至4760 mg/L（变化率31.1%，单位距离梯度8.14 mg/(L·km)），艾山和利津站再次下降至5395 mg/L和4527 mg/L，显示下游泥沙输移受水库调蓄、人为调控及局部回沙等多重因素影响。整体来看，下游泥沙浓度变化剧烈且波动性强，单位距离梯度在-31.97至8.14 mg/(L·km)之间交替变化，反映泥沙输移的不稳定性与空间异质性。

总体来看，黄河干流泥沙浓度空间分布具有显著的分段性特征：上游泥沙含量较低且变化平稳，中游泥沙浓度显著升高并达到峰值，是泥沙汇集的主控区；下游在多级水库调蓄作用下，泥沙浓度明显降低但波动性增强。单位距离泥沙变化率从上游的0.33 mg/(L·km)增至中游的6.42 mg/(L·km)，随后在下游呈现正负交替变化，揭示出下游泥沙输移的不稳定性与空间异质性，这一变化格局反映了中游强烈的地貌侵蚀与泥沙汇入效应，以及下游水利工程对泥沙输移过程的显著调节作用。

5 结论

针对高含沙水体SSC遥感反演精度不高、模型稳定性偏弱、光谱非线性强等存在的问题，提出了一种融合光谱敏感因子RANS和贝叶斯优化的多任务CNN高含沙水体SSC反演模型，提升了高含沙水体SSC反演可靠性与泛化能力。主要结论如下：（1）RANS指数能够有效表征黄河高含沙水体的光谱结构特征，与 $\ln(SSC)$ 具有较强相关性（ $R^2=0.81$ ），为高浓度悬浮泥沙遥感反演提供了有效的物理约束信息。（2）融合RANS辅助任务和贝叶斯优化的多任务CNN模型提升了SSC反演精度与稳定性，测试集精度 $R^2=0.837$ ，较传统CNN缓解了高浓度区间的系统偏差问题。（3）2013年—2023年黄河干流SSC总体呈现“上游低、中游高、下游降”的空间分布格局和“春低、夏高、秋降”的季节变化特征，中游黄土高原河段是泥沙汇集与输移的核心区域。

下一步研究针对低含沙样本不足、Landsat 8 时空分辨率对高频过程刻画能力有限，以及模型尚未显示融合泥沙输移和水动力等物理过程约束等问题，可通过引入多源高分辨率遥感数据（如 Sentinel-2 等），在深度学习框架中融合物理过程约束，进一步提升高含沙水体 SSC 遥感反演的精度与稳定性。

参考文献(References)

- Chen Y, Kong J L, Sun X M, Du D and Chen P. 2014. Retrieval of sea surface suspended sediment concentration in Bohai gulf offshore area based on semi-analysis model. *Geography and Geo-Information Science*, 30(3): 33-36, 55 (陈燕, 孔金玲, 孙晓明, 杜东, 陈彭. 2014. 基于半分析模型的渤海湾近岸海域悬浮泥沙浓度遥感反演. *地理与地理信息科学*, 30(3): 33-36, 55) [DOI: 10.3969/j.issn.1672-0504.2014.03.008]
- Dethier E N, Renshaw C E and Magilligan F J. 2022. Rapid changes to global river suspended sediment flux by humans. *Science*, 376 (6600): 1447-1452 [DOI: 10.1126/science.abn7980]
- Doxaran D, Froidefond J M, Lavender S and Castaing P. 2002. Spectral signature of highly turbid waters: application with SPOT data to quantify suspended particulate matter concentrations. *Remote Sensing of Environment*, 81(1): 149-161 [DOI: 10.1016/S0034-4257(01)00341-8]
- Fan D W, He B L, Li C H, Han J, Xu Y F and Cui C Z. 2019. Research on spherical distance computation and accuracy comparison. *Astronomical Research and Technology*, 16(1): 69-76 (樊东卫, 何勃亮, 李长华, 韩军, 许允飞, 崔辰州. 2019. 球面距离计算方法及精度比较. *天文研究与技术*, 16(1): 69-76) [DOI: 10.14005/j.cnki.issn1672-7673.20180523.001]
- Fang X R, Wen Z F, Chen J L, Wu S J, Huang Y Y and Ma M H. 2019. Remote sensing estimation of suspended sediment concentration based on Random Forest Regression Model. *Journal of Remote Sensing (in Chinese)*, 23(4): 756-772 (方馨蕊, 温兆飞, 陈吉龙, 吴胜军, 黄远洋, 马茂华. 2019. 随机森林回归模型的悬浮泥沙浓度遥感估算. *遥感学报*, 23(4): 756-772) [DOI: 10.11834/jrs.20197498]
- Graffeuille O, Koh Y S, Wicker J and Lehmann M. 2024. Remote sensing for water quality: a multi-task, metadata-driven hypernetwork approach//*Proceedings of the Thirty-Third International Joint Conference on Artificial Intelligence*. Jeju: [s. n.]: 7287-7295 [DOI: 10.24963/ijcai.2024/806]
- Hou X J. 2020. Remote Sensing-Based Spatial-Temporal Dynamics of Sediment Concentrations and its Relationship with Wetland Vegetation Coverage in Large Lakes and Reservoirs of the Middle and Lower Reaches of the Yangtze River. Wuhan: Wuhan University (侯雪姣. 2020. 基于遥感的长江中下游大型湖库悬浮泥沙浓度时空动态及其与湿地植被覆盖的关系研究. 武汉: 武汉大学) [DOI: 10.27379/d.cnki.gwhdu.2020.000639]
- Hu C H, Zhang X M and Zhao Y. 2020. Cause analysis of the centennial trend and recent fluctuation of the Yellow River sediment load. *Advances in Water Science*, 31(5): 725-733 (胡春宏, 张晓明, 赵阳. 2020. 黄河泥沙百年演变特征与近期波动变化成因解析. *水科学进展*, 31(5): 725-733) [DOI: 10.14042/j.cnki.32.1309.2020.05.009]
- Kabir S M I and Ahmari H. 2020. Evaluating the effect of sediment color on water radiance and suspended sediment concentration using digital imagery. *Journal of Hydrology*, 589: 125189 [DOI: 10.1016/j.jhydrol.2020.125189]
- Kingma D P and Ba J. 2017. Adam: a method for stochastic optimization. *Proceedings of the 3rd International Conference on Learning Representations (ICLR)*, 2015.: 1412.6980 [DOI: 10.48550/arXiv.1412.6980]
- LeCun Y, Boser B, Denker J S, Henderson D, Howard R E, Hubbard W and Jackel L D. 1989. Backpropagation applied to handwritten zip code recognition. *Neural Computation*, 1(4): 541-551 [DOI: 10.1162/neco.1989.1.4.541]
- Li L, Ni J R, Chang F, Yue Y, Frolova N, Magritsky D, Borthwick A G L, Ciais P, Wang Y C, Zheng C M and Walling D E. 2020. Global trends in water and sediment fluxes of the world's large rivers. *Science Bulletin*, 65(1): 62-69 [DOI: 10.1016/j.scib.2019.09.012]
- Li Y R, Zhang Y L and Wang J C. 2022. Survey on Bayesian optimization methods for hyper-parameter tuning. *Computer Science*, 49(S1): 86-92 (李亚茹, 张宇来, 王佳晨. 2022. 面向超参数估计的贝叶斯优化方法综述. *计算机科学*, 49(S1): 86-92) [DOI: 10.11896/jsjcx.210300208]
- Li Z L, Peng S S and Wang T. 2022. A sequential sampling method of surrogate model based on k-fold cross validation. *Chinese Journal of Computational Mechanics*, 39(2): 244-249 (李正良, 彭思思, 王涛. 2022. 基于k-fold交叉验证的代理模型序列采样方法. *计算力学学报*, 39(2): 244-249) [DOI: 10.7511/jslx20201110001]
- Liu X Y. 2020. The water and sediment situation and countermeasure. *Yellow River*, 42(9): 34-40 (刘晓燕. 2020. 关于黄河水沙形势及对策的思考. *人民黄河*, 42(9): 34-40) [DOI: 10.3969/j.issn.1000-1379.2020.09.007]
- Lu J F and Liu A X. 2002. Relationships between grain size of suspended sediment and rainfall characteristics in the middle reaches of the Yellow River Basin. *Scientia Geographica Sinica*, 22(5): 552-556 (卢金发, 刘爱霞. 2002. 黄河中游降雨特性对泥沙粒径的影响. *地理科学*, 22(5): 552-556) [DOI: 10.13249/j.cnki.sgs.2002.05.007]
- Lymburner L, Botha E, Hestir E, Anstee J, Sagar S, Dekker A and Malthus T. 2016. Landsat 8: providing continuity and increased precision for measuring multi-decadal time series of total suspended matter. *Remote Sensing of Environment*, 185: 108-118 [DOI: 10.1016/j.rse.2016.04.011]
- McFeeters S K. 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7): 1425-1432 [DOI: 10.1080/01431169608948714]
- Pei Q L. 2024. Research and Device Design of Intelligent Monitoring

- System for Aquaculture Water Quality. Yangzhou: Yangzhou University (裴启立. 2024. 养殖水质智能监控系统研究及装置设计. 扬州: 扬州大学) [DOI: 10.27441/d.cnki.gyzdu.2024.002234]
- Peterson K T, Sagan V and Sloan J J. 2020. Deep learning-based water quality estimation and anomaly detection using Landsat-8/Sentinel-2 virtual constellation and cloud computing. *GIScience and Remote Sensing*, 57(4): 510-525 [DOI: 10.1080/15481603.2020.1738061]
- Qiu Z Q, Liu D, Duan M W, Chen P P, Yang C, Li K Y and Duan H T. 2024. Four-decades of sediment transport variations in the Yellow River on the Loess Plateau using Landsat imagery. *Remote Sensing of Environment*, 306: 114147 [DOI: 10.1016/j.rse.2024.114147]
- Rahat S H, Steissberg T, Chang W N, Chen X, Mandavya G, Tracy J, Wasti A, Atreya G, Saki S, Bhuiyan M A E and Ray P. 2023. Remote sensing-enabled machine learning for river water quality modeling under multidimensional uncertainty. *Science of the Total Environment*, 898: 165504 [DOI: 10.1016/j.scitotenv.2023.165504]
- Song G X, Jiang Y J, Lei X Y and Zhai S Y. 2025. Measurement of suspended sediment concentration at the outlet of the Yellow River canyon: using Sentinel-2 images and machine learning. *Remote Sensing*, 17(14): 2424 [DOI: 10.3390/rs17142424]
- Wang D, Xiang X Y, Ma R H, Guo Y Q, Zhu W Y and Wu Z H. 2023. A novel atmospheric correction for turbid water remote sensing. *Remote Sensing*, 15(8): 2091 [DOI: 10.3390/rs15082091]
- Xie J B, Feng X R, Wang Z F, Wan K, Gao T H and Yin B S. 2024. Application of deep learning in predicting suspended sediment concentration: a case study in Jiaozhou Bay, China. *Marine Pollution Bulletin*, 201: 116255 [DOI: 10.1016/j.marpolbul.2024.116255]
- Yan H, Fu H Y, Chen Z, Liao A R, Shen M Y, Tao Y, Wu Y H and Hu H Y. 2025. A multi-task deep neural network reveals inflowing river impacts for predictive lake management. *Environmental Science and Ecotechnology*, 26: 100592 [DOI: 10.1016/j.es.2025.100592]
- Yang C X, Li Y, Yang J and Shu S J. 2023. Remote sensing inversion and regularity analysis of suspended sediment in Pearl River Estuary based on machine learning model. *Bulletin of Surveying and Mapping*, (9): 117-123 (杨传训, 李勇, 杨骥, 舒思京. 2023. 机器学习模型的珠江口悬浮泥沙遥感反演与规律分析. 测绘通报, (9): 117-123) [DOI: 10.13474/j.cnki.11-2246.2023.0275]
- Zhang Y, Liu J W and Zuo X. 2020. Survey of multi-task learning. *Chinese Journal of Computers*, 43(7): 1340-1378 (张钰, 刘建伟, 左信. 2020. 多任务学习. 计算机学报, 43(7): 1340-1378) [DOI: 10.11897/SP.J.1016.2020.01340]
- Zheng Y and Han F. 2016. Markov Chain Monte Carlo (MCMC) uncertainty analysis for watershed water quality modeling and management. *Stochastic Environmental Research and Risk Assessment*, 30(1): 293-308 [DOI: 10.1007/s00477-015-1091-8]
- Zhu P P, Li S P, Zhang L Q and Li Y. 2021. Multitask learning-based building extraction from high-resolution remote sensing images. *Journal of Geo-Information Science*, 23(3): 514-523 (朱盼盼, 李帅朋, 张立强, 李洋. 2021. 基于多任务学习的高分辨率遥感影像建筑提取. 地球信息科学学报, 23(3): 514-523) [DOI: 10.12082/dqxxkx.2021.190805]

High-precision retrieval of suspended sediment concentration in the Yellow River based on Landsat 8: Integration of physical mechanisms and deep learning

ZHOU Zheng^{1,2,3,4}, HUANG Jianxiong⁵, GUAN Haozhe⁴, YE Yuntao^{1,4}, GU Jingjing⁴, CAO Yin⁴, JIANG Yunzhong^{1,4}

1. Faculty of Geomatics, Lanzhou Jiaotong University, Lanzhou 730070, China;

2. National-Local Joint Engineering Center for Geographical National Condition Monitoring Technology Application, Lanzhou 730070, China;

3. Gansu Provincial Key Laboratory of Surveying and Mapping Science and Technology, Lanzhou 730070, China;

4. China Institute of Water Resources and Hydropower Research, Beijing 100038, China;

5. Land Consolidation Center of Chao'an District, Chaozhou City, Guangdong 521000, China

Abstract: The Yellow River is characterized by hyperconcentrated sediment loads and highly imbalanced water – sediment relationships, making accurate retrieval of Suspended Sediment Concentration (SSC) essential for water – sediment regulation, flood control, and ecological protection. However, remote sensing retrieval of SSC in hyperconcentrated waters remains challenging because of spectral saturation in the red and near-infrared bands, attenuation in shortwave infrared bands, and complex nonlinear relationships between optical signals and sediment properties. To address these challenges, this study developed a physics-constrained multitask Convolutional Neural Network (CNN) framework for SSC retrieval and investigated the spatiotemporal dynamics of SSC along the Yellow River mainstem during 2013–2023. Based on daily SSC observations from 12 hydrological stations and corresponding Landsat 8 OLI imagery, 676 high-quality matched samples were constructed. A novel spectral index, termed the red and near-infrared to all shortwave infrared normalized ratio (RANS), was proposed to characterize the relative relationship between scattering enhancement in the red/near-infrared bands and

absorption suppression in the shortwave infrared bands under high-turbidity conditions. RANS showed a strong correlation with $\ln(\text{SSC})$ (Pearson $r=0.901$, $R^2=0.81$). To incorporate this physically meaningful spectral information, RANS was introduced as an auxiliary regression task within a multitask CNN framework. Bayesian optimization based on a Gaussian process surrogate model was further employed to automatically optimize model hyperparameters. Results demonstrated that the proposed multitask self-optimizing CNN outperformed both the single-task CNN and the non-optimized multitask CNN. In the $\ln(\text{SSC})$ domain, the model achieved $R^2=0.843$ and $\text{RMSE}=0.614$, while in the original SSC domain it achieved $R^2=0.837$ and $\text{RMSE}=1256.75$ mg/L, substantially improving upon the single-task CNN. Five-fold cross-validation confirmed stable generalization capability ($R^2=0.655\pm0.059$, $\text{RMSE}=1620\pm192$ mg/L). The highest retrieval accuracy was observed within the 2000—5000 mg/L concentration range ($R^2>0.81$, $\text{MAPE}<23\%$). Monte Carlo experiments further demonstrated superior model robustness and reduced uncertainty. The reconstructed SSC dataset revealed pronounced spatiotemporal heterogeneity along the Yellow River mainstem. Spatially, SSC exhibited a distinct pattern of low values upstream, peak concentrations in the middle reaches, and declining concentrations downstream. The Longmen-Tongguan reach showed the strongest sediment accumulation, whereas the Xiaolangdi-Huayuankou reach displayed significant sediment reduction during flood periods. Seasonally, SSC consistently remained low in spring, peaked in summer, and gradually declined in autumn. These results indicate that integrating the RANS spectral index with multitask learning and Bayesian optimization effectively improves SSC retrieval in hyperconcentrated waters. The proposed framework provides both a reliable methodology and long-term dataset support for large-scale sediment monitoring, hydrological modeling, and water – sediment management in sediment-laden river systems.

Key words: the middle reaches of the Yellow River, hyperconcentrated sediment-laden water, suspended sediment concentration retrieval, Convolutional Neural Network (CNN), multi-task learning, Bayesian optimization, Landsat 8 multispectral imagery

Supported by National Natural Science Foundation of China (No. 52279031); National Key Research and Development Program of China (No. 2023YFC3209302-03); National Natural Science Foundation of China Youth Program (No. 52309040)