中国水产科学 2022 年 3 月, 29(3): 355–364
Journal of Fishery Sciences of China

研究论文

DOI: 10.12264/JFSC2021-0559

基于 Sentinel-2 多光谱遥感的低盐湖泊盐度反演——以西藏错鄂湖为例

毛智慧[1,2], 丁放[1,2], 袁立来[1], 李应仁[1,2], 何德奎[3], 刘明典[4], 王琳[1,2]

1. 中国水产科学研究院资源与环境研究中心, 北京 100141;
2. 农业农村部渔业遥感科学观测实验站, 北京 100141;
3. 中国科学院水生生物研究所, 湖北 武汉 430072;
4. 中国水产科学研究院长江水产研究所, 湖北 武汉 430223

摘要: 为探索遥感数据反演低盐湖盐度的能力, 以西藏错鄂湖为例, 利用 Sentinel-2 多光谱数据, 对比了可见光和近红外波段光谱反射率与水表盐度的相关性, 基于波段反射率和归一化水体指数(normalized difference water index, NDWI), 采用线性回归模型对西藏错鄂湖水表盐度进行反演研究。研究结果表明, 绿波段反射率与盐度的相关性高于其他波段, 当盐度低于 3 时, 近红外波段反射率与盐度相关性最高; 9 种变量组合的盐度反演模型中, NDWI 变量的加入能够提高模型的反演精度, 且 NDWI、近红外波段、蓝波段 3 个变量组合的线性回归模型反演盐度的精度最高, 平均绝对误差(the mean absolute error, MAE)为 0.103, 决定系数 R^2 最大, 为 0.5696, 说明盐度实测值和预测值拟合结果较好。从对全湖的预测结果看, 错鄂湖的水表盐度空间分布总体呈现出岸边、河口低, 湖泊内部高且分布较为均匀的格局, 预测盐度均值约 4.14, 与实测均值 4.15 十分接近, 验证了反演方法的有效性。研究结果表明多光谱遥感数据在预测错鄂湖泊水表盐度方面具有准确度高、快速便捷的优势, 对利用多光谱遥感数据进行低盐湖泊水表盐度反演具有指导意义, 对水生生物资源保护和可持续利用具有借鉴价值。

关键词: 盐度; 多光谱遥感; 反演; 错鄂湖
中图分类号: S931 **文献标志码:** A **文章编号:** 1005−8737−(2022)03−0355−10

盐度是自然水体的一个基本属性, 是描述水体理化性质的基本参数, 盐度变化会引起水体密度变化, 影响水循环和生态系统, 与水生生物生存繁衍密切相关[1-2]。传统盐度数据获取主要采用野外调查方式, 该方法投入大, 周期长, 效率低, 且只能获得点状数据, 难以实现水表盐度的时空连续观测。遥感技术凭借其快速、连续、非接触、远距离探测的优势, 在盐度遥感反演中应用广泛, 可对目标地物进行快速监测, 适合于大尺度范围的盐度分布特征研究。前人已提出一些利用遥感技术反演盐度的方法, 1982 年, Khorrom[3]基于 Landsat 多光谱扫描仪(MSS)数据和实测盐度数据, 采用线性回归模型建立了旧金山湾三角洲盐度反演模型并制图, 反演结果与同期文献中的盐度分布基本一致。此后, 基于遥感数据反演盐度的研究逐渐增多, 相关研究主要利用中分辨率成像光谱仪(moderate resolution imaging spectroradiometer, MODIS)反射率数据、数字高程模型、土壤水分和海洋盐度(soil moisture and ocean salinity, SMOS)卫星、中分辨率成像光谱仪(medium resolution

收稿日期: 2021-12-08; **修订日期:** 2022-02-23.
基金项目: 农业农村部财政专项“西藏重点水域渔业资源与环境调查”; 中国水产科学研究院基本科研业务费资助项目(2018HY- ZD0101); 中国水产科学研究院中央级公益性科研院所基本科研业务费专项资金资助项目(2020TD11).
作者简介: 毛智慧(1993–), 女, 硕士, 研究方向为渔业遥感. E-mail: maozhihui@cafs.ac.cn
通信作者: 王琳, 副研究员, 研究方向为渔业遥感. E-mail: angels121@cafs.ac.cn

imaging spectrometer, MERIS)卫星等数据，采用神经网络、最小二乘和地理加权、多元统计回归、随机森林等方法，在路易斯安那海岸近岸水域[4]、波罗的海[5]、太平洋中部[6]、巴拉望岛附近海域[7]、孟加拉湾[8]、香港海域[9]等海域开展了盐度反演研究。相关研究结果表明，盐度反演结果与实测值相似，模型反演精度较高，证明了遥感反演海湾和大洋水体盐度方法的有效性。除海湾和大洋水体外，在海陆相互作用的河口区域，如在长江口[10]、珠江口[11]等水域，国内相关学者也开展了水表盐度的反演研究，结果满足表层盐度定量反演需求。

上述研究主要是基于 MODIS、MERIS 和 Landsat 等中-低空间分辨率的卫星数据，而利用 Sentinel-2 较高空间分辨率卫星数据开展盐度反演研究的应用较少，目前主要针对海洋和河口等盐度较高的水域开展，对低盐湖泊水表盐度进行遥感反演的相关研究较少，且零星研究实例表明对该类型水域存在反演精度低的问题。例如，刘英等[12]在博斯腾湖进行了低盐度(<3)遥感反演初步研究，精度约为 1.1，误差较大，该研究同时指出利用光学遥感数据反演内陆水体的盐度时，需要水体盐度足够高。

盐湖是青藏高原的主要湖泊类型。据统计，在青藏高原面积≥1 km^2 湖泊中，盐湖数量约占四分之一，其中很多为典型的高原低盐度湖泊(盐度低于 8 的盐湖约 81 个)[13-14]。如何利用遥感反演方法获取这类湖泊大时空尺度连续分布的盐度数据，对研究青藏高原盐湖的生物地球化学循环及水生生物保护与可持续利用具有重要意义[15]。本研究以西藏错鄂湖水表盐度反演为例，利用 Sentinel-2 多光谱遥感数据和实测盐度数据，首先分析具有 10 m 空间分辨率的波段反射率与盐度值的相关性；其次基于经验统计模型，利用波段反射率和水体指数等多个变量，对比分析不同变量组合在盐度反演精度的差异性，以及盐度实测值和预测值之间的拟合关系；最后进一步对比错鄂水表盐度的空间分布情况，系统地研究多光谱遥感在低盐湖泊盐度反演方面的能力，以期验证光学遥感数据在低盐湖泊水表盐度反演结果中的有效性。

1 材料与方法

1.1 研究区域

以西藏错鄂湖为研究区(图 1)，该研究区域位

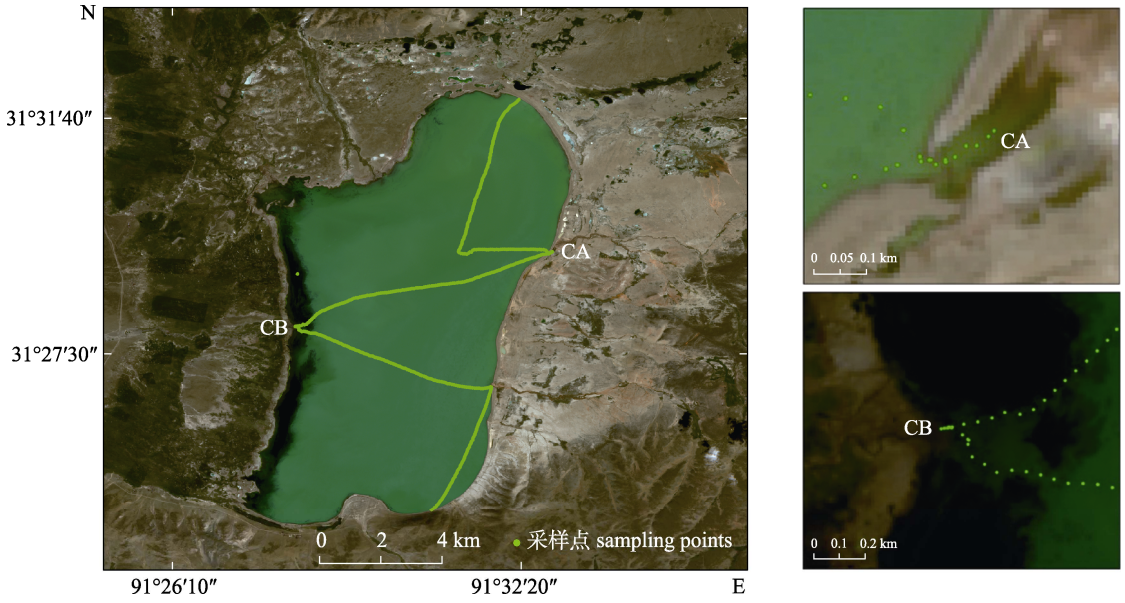

图 1 研究区域

图中 CA 和 CB 为入湖口.

Fig. 1 Study area in the research

CA and CB in the figure are lake inlets.

于西藏那曲县西部(31°24′N~31°32′N, 91°28′E~91°33′E), 湖面海拔约 4562 m, 湖泊面积约 82.02 km^2, 南北长约 15 km, 东西宽约 6 km。错鄂湖区属于高原亚寒带半干旱气候区, 高寒缺氧, 气候干燥, 湖水主要依靠地表径流补给, 属藏北高原内流湖泊。植被类型为高山草甸, 地带性植被为小蒿草草甸。

1.2　数据获取与处理

1.2.1　地面实测数据　2017 年 9 月 27 日利用英国 Valeport 公司的温盐深仪 MIDAS CTD plus[16]对错鄂湖水表盐度进行现场测量, 实测采样点如图 1 所示, CA 和 CB 为湖泊东岸和西岸的河流入河口区域。测量方式为将温盐深仪搭载在橡皮艇上进行走航式测量, 采样点均匀覆盖湖区。由于观测数据采样频率很高(1 Hz), 因此首先对数据进行均匀间隔的随机抽样, 提取其中 503 个采样点的盐度数据, 盐度平均值为 4.15, 与抽样前样点均值相同。

1.2.2　多光谱遥感数据　本研究使用的影像数据为与野外调查时间同一天(2017 年 9 月 27 日)的且能够完整覆盖研究区的 Sentinel-2 多光谱数据。Sentinel-2 卫星携带一枚多光谱成像仪, 卫星重访周期为 10 d, 从可见光和近红外到短波红外波段具有不同的空间分辨率, 包括 10 m、20 m 和 60 m。为了更准确地获取盐度信息, 本研究利用 10 m 空间分辨率的蓝(B)、绿(G)、红(R)和近红外(NIR)共 4 个波段(表 1), 对数据进行辐射定标、大气校正等数据预处理工作, 最终获得各波段的反射率数据[17]。

表 1　Sentinel-2 卫星波段光谱参数

Tab. 1　Sentinel-2 satellite band spectral parameters

波段 band	中心波长/nm central wavelength	波段宽度/nm band width	空间分辨率/m spatial resolution
蓝 blue	490	65	10
绿 green	560	35	10
红 red	665	30	10
近红外 near-infrared	842	115	10

1.3　盐度反演模型的构建

光谱反射率与指数是建立经验统计模型常用的光学遥感参数。水体指数利用了水体在近红外波段的强吸收特性以及植被和干土壤在该波长范围内的强反射特点提取水体信息, 也能够揭示水体细微特征。本研究选择蓝、绿、红和近红外波段反射率数据(分别为 ρ_B、ρ_G、ρ_R、ρ_{NIR})以及归一化水体指数(normalized difference water index, NDWI)[18](公式 1), 采用线性回归模型[19]对西藏错鄂湖水表盐度进行反演研究。

$$\mathrm{NDWI}=\frac{p(\mathrm{Green})-p(\mathrm{NIR})}{p(\mathrm{Green})+p(\mathrm{NIR})} \tag{1}$$

式中, p(Green)代表绿光波段的反射率, p(NIR)代表近红外波段的反射率。

首先, 将 4 变量(ρ_B、ρ_G、ρ_R、ρ_{NIR})和 5 变量(ρ_B、ρ_G、ρ_R、ρ_{NIR}、NDWI)分别与实测盐度建立反演模型, 进行水表盐度反演研究。其次, 采用进入法将各变量对模型的重要程度进行重要性排序, 通过排序筛选出不同变量组合分别对错鄂水表盐度进行反演。根据自变量数量的不同, 线性回归模型分为多元和一元回归, 如公式 2 所示。

$$y=\sum_{i=1}^{n}a_i x_i+b \tag{2}$$

式中, y 代表反演的盐度值。a_i 和 b 为模型系数。x_i代表参与反演的变量, 当 n=1 时为一元回归, 代表仅由一个变量参与反演; 当 n>1 时为多元回归, 代表由多个变量同时参与反演。

1.4　精度验证

为验证盐度反演模型的有效性, 分别从 503 个实测样本中随机选取 60%的调查数据进行模型构建, 另外 40%的数据进行模型的反演精度评价, 采用平均绝对误差(MAE)[20]进行反演精度的定量评价, 计算公式如下:

$$\mathrm{MAE}=\frac{\sum_{i=1}^{n}\left|V_i-S_i\right|}{n} \tag{3}$$

式中, V_i 为反演模型对盐度的预测值, S_i 为盐度的实测值, n 为样本数量。MAE 越小, 表明模型的反演精度越高, 反演结果越可靠。

对比分析不同波段反射率与盐度的关系时, 采用决定系数(coefficient of determination)进行评价。决定系数用 R^2 表示, 表示自变量和因变量之间的相关密切程度。R^2 越接近于 1, 表明方程中

自变量对因变量的解释能力越强，散点多集中于回归线附近；而 R^2 值越小，表明变量间的相关程度越小。

2 结果与分析

2.1 反射率与盐度的关系

水体各波段光谱反射特征不同，分析不同波段反射率与水表盐度的关系，可了解各波段反射率对盐度的敏感性。图 2 为建模样本各波段反射率与盐度之间的关系，由图可知，随着波长变长，低盐湖泊的光学波段反射率呈现先增大后减小的趋势。在绿光波段，水体的反射率最大时约为 0.1664；在红光和近红外波段逐渐降低，在近红外波段反射率最低时趋于 0。从决定系数 R^2 看，绿波段与盐度的 R^2 最大，为 0.4940；蓝波段次之，R^2 为 0.4408。在波长较长的红和近红外波段，反射率与盐度之间的决定系数很小，与水体在近红外波段的强吸收特性有关。

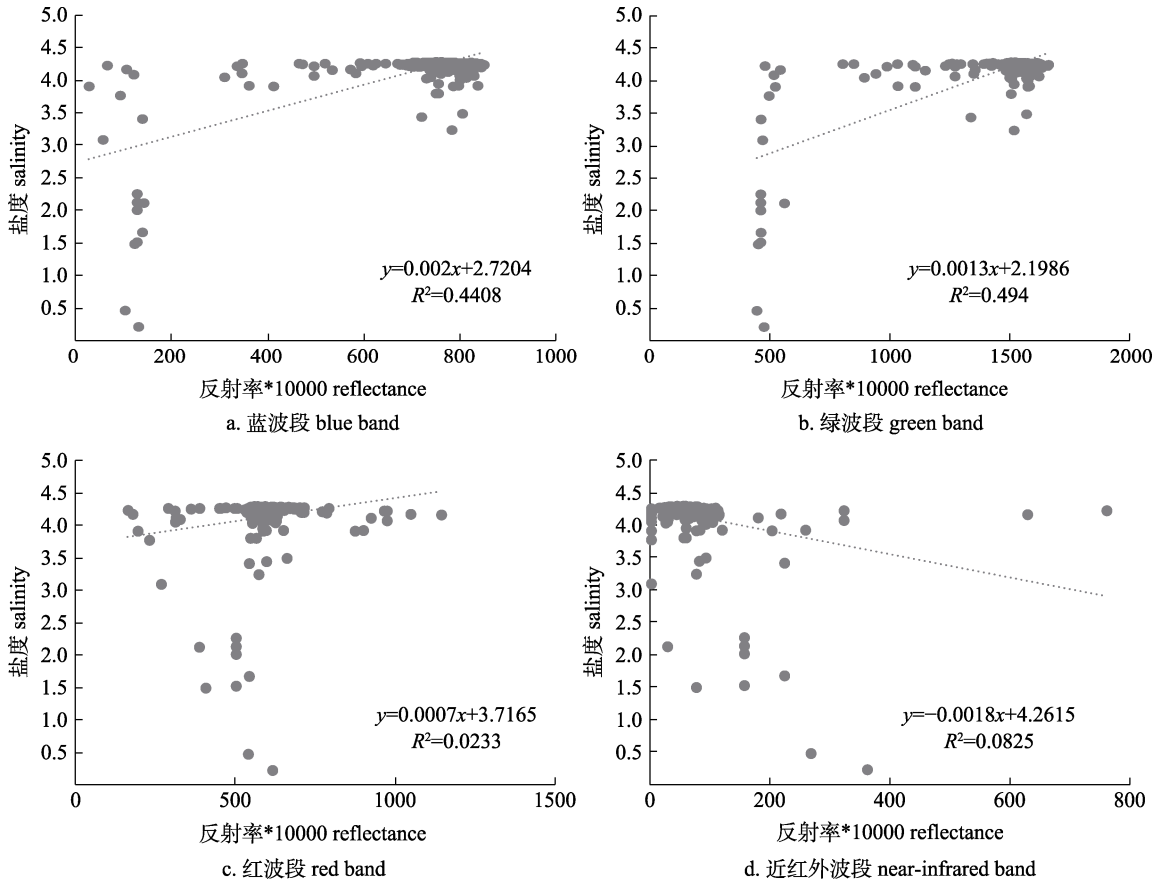

图 2 不同波段反射率与西藏错鄂湖水表盐度的关系

Fig. 2 The relationship between reflectance of different bands and surface salinity of the Co Ngoin Lake in Tibet

从图 2 中进一步观察发现，当湖泊水表盐度值高于 3 时，其蓝、绿、红、近红外波段的光谱反射率差异均大于水表盐度低于 3 时的反射率差异。如蓝波段在水表盐度高于 3 时，光谱反射率介于 0.00~0.09 之间，反射率均值约为 0.07；绿波段光谱反射率差异最大，介于 0.05~0.17，且表现出显著不同于淡水水体的强反射特征(反射率均值约 0.15)；红波段反射率介于 0.02~0.11，表现为中等吸收特征；近红外波段反射表现出强吸收特征，反射率均值接近 0。而当水表盐度低于 3 时，其蓝、绿波段的光谱反射率虽然仍呈现出不同于淡水水体的绿波段反射率高于蓝波段反射率特征，但反射率值几乎不随盐度的变化而变化，分别集中分布在 0.01 和 0.05 附近；红、近红外波段相比蓝、绿波段，不同盐度水体的光谱反射率稍有差异，但仍远低于盐度大于 3 的水体。

图 3 为盐度低于 3 时, 不同波段反射率与水表盐度的关系。绿光波段反射率与盐度的相关性最低, 决定系数 R^2 为 0.0774; 而近红外波段与盐度的相关性最高, R^2 为 0.6018。

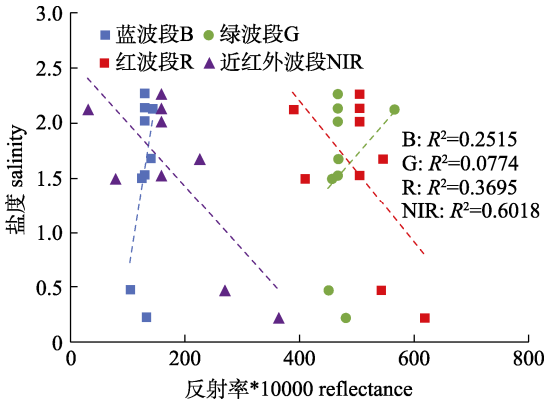

图 3　盐度小于 3 时不同波段反射率与西藏错鄂湖水表盐度的关系

B、G、R、NIR 分别表示蓝、绿、红和近红外波段.

Fig. 3　The relationship between reflectance of different bands and surface salinity of the Co Ngoin Lake in Tibet when salinity is less than 3

B、G、R、NIR represent blue band, green band, red band and near infrared band respectively.

2.2　盐度反演结果分析

4 变量(ρ_B、ρ_G、ρ_R、ρ_{NIR})模型预测的变量重要性从高到低分别为绿波段、红波段、近红外波段和蓝波段, 绿波段重要性最高, 与 **2.1** 中绿波段与盐度的相关性最高结果吻合; 而 5 变量(ρ_B、ρ_G、ρ_R、ρ_{NIR}、NDWI)模型的变量重要性从高到低依次为 NDWI、近红外波段、蓝波段、红波段和绿波段。按变量重要性排序依次逐个增加变量, 分别建立单变量和多元线性回归模型, 进行精度评价, 并分析 9 种组合 MAE 的变化趋势。表 2 和表 3 分别为不同变量组合反演盐度的线性回归方程和反演精度, 以 a~i 对各个组合进行编号。

由表 3 可知, 9 个模型中, 各模型反演盐度的 MAE 均较小, 误差不超过 0.15, 反演精度较高。其中, NDWI、近红外波段和蓝波段 3 变量组合的盐度反演模型精度最高, MAE 为 0.103。包括 NDWI 的反演模型精度高于不含 NDWI 的模型, 可见 NDWI 在反演盐度时发挥了重要作用。在不包括 NDWI 变量的 4 模型中, 绿波段和红波段组合的模型反演盐度精度最高, MAE 为 0.126。9 个模型中, 绿波段、红波段、近红外波段和蓝波段共 4 个变量组合的模型反演精度最低, MAE 为 0.142。

表 2　不同变量组合反演错鄂湖水表盐度的线性回归模型

Tab. 2　Linear regression models for inversion of surface salinity in the Co Ngoin Lake with different variable combinations

组合 combination	公式 formula
a	y=13.4ρ_G+2.199
b	y=14.87ρ_G−8.444ρ_R+2.484
c	y=15.93ρ_G−11.94ρ_R+5.42ρ_{NIR}+2.5
d	y=−16.34ρ_B+27.03ρ_G−15.76ρ_R+10.78ρ_{NIR}+2.229
e	y=2.631NDWI+1.764
f	y=76ρ_{NIR}+6.934NDWI−2.649
g	y=4.278ρ_B+67.91ρ_{NIR}+6.196NDWI−2.229
h	y=2.562ρ_B+4.202ρ_R+64.95ρ_{NIR}+6.277NDWI−2.408
i	y=−1.284ρ_B+3.182ρ_G+2.451ρ_R+65.36ρ_{NIR}+6.127NDWI−2.361

表 3　9 种线性回归模型的盐度反演精度

Tab. 3　Salinity inversion accuracy based on nine linear regression models

组合 combination	变量 variable	平均绝对误差 MAE
a	*G*	0.128
b	*G*, *R*	0.126
c	*G*, *R*, NIR	0.128
d	*G*, *R*, NIR, *B*	0.142
e	NDWI	0.117
f	NDWI, NIR	0.106
g	NDWI, NIR, *B*	0.103
h	NDWI, NIR, *B*, *R*	0.106
i	NDWI, NIR, *B*, *R*, *G*	0.105

a~i 组合的盐度反演模型获取的错鄂湖水表盐度预测值与实测值的拟合结果如图 4 所示。观察发现, 绝大部分样点的预测值和实测值随机分布在回归线两侧, 总体拟合结果较好。前述 NDWI、NIR 和 B 三变量的组合模型反演精度最高的 R^2 也最大, 为 0.5696 (图 4g)。除 e 组合外, 其他组合实测值和预测值的拟合斜率均在 1 附近, 说明尽管包括 NDWI 的反演模型精度高于不含 NDWI 的模型, 但仅凭 NDWI 单变量拟合并不能得到十分理想的反演效果。图 4a~d 对应的 4 变量(ρ_B、ρ_G、ρ_R、ρ_{NIR})组合反演结果中, 整体上看, 当盐度低于

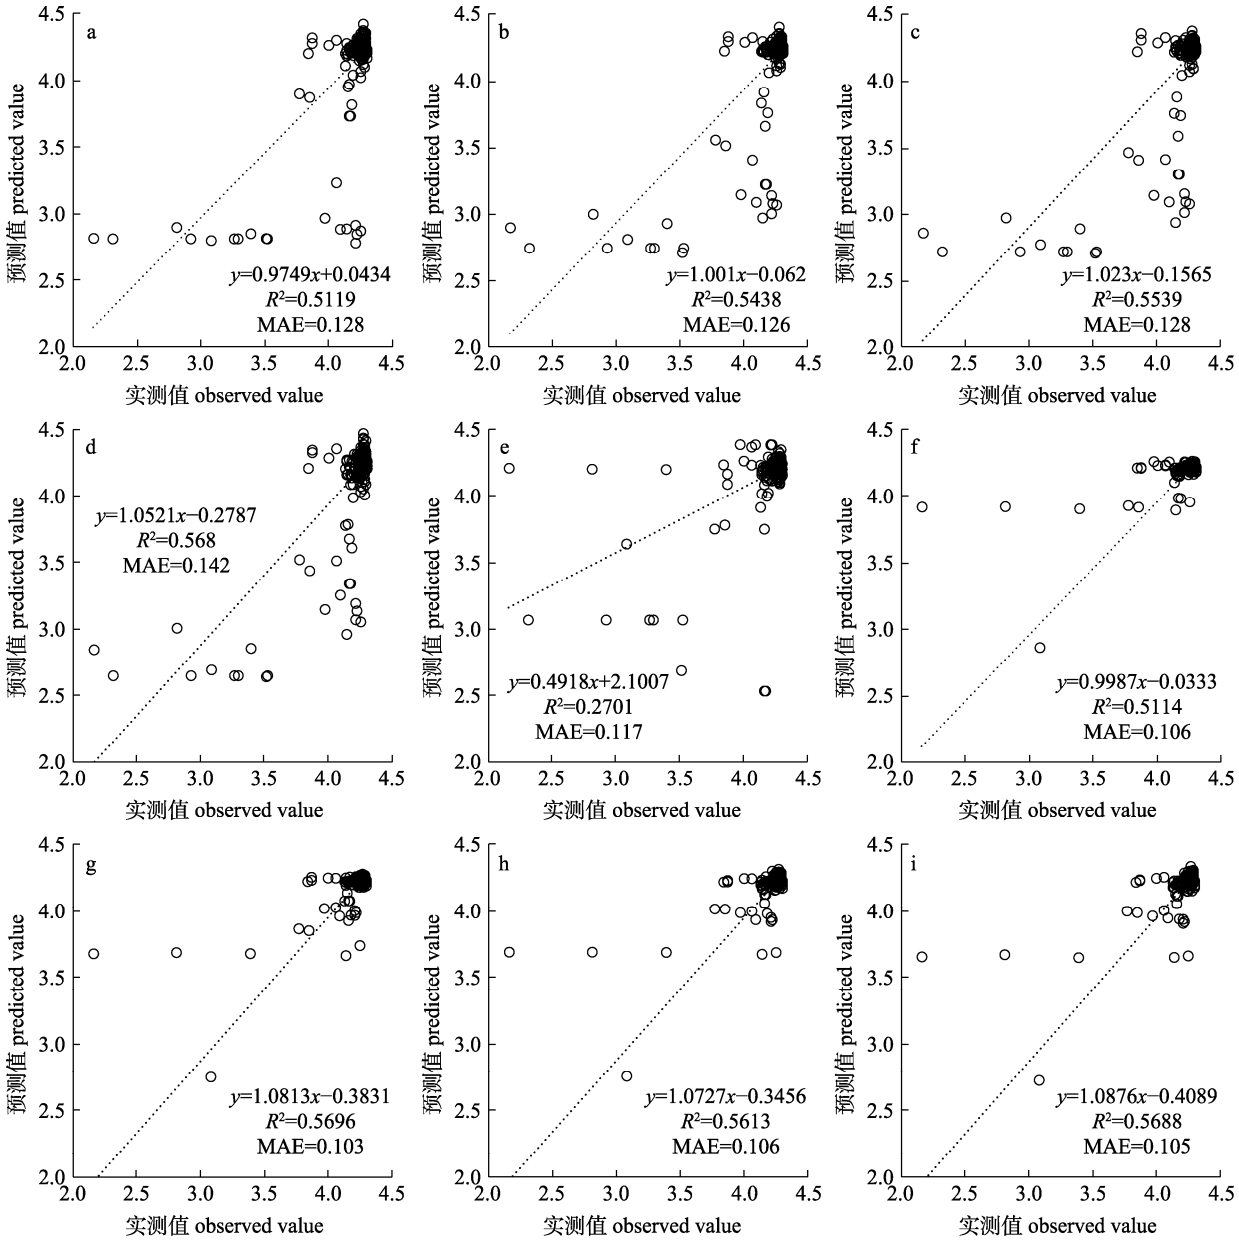

图 4 错鄂湖水表盐度实测值和预测值拟合图

a–i. 不同变量组合反演盐度预测值和实测值的拟合图. 图 a–i 分别对应 a–i 组合.

Fig. 4 Fitting diagram of observed surface salinity values and predicted values of the Co Ngoin Lake in Tibet

a–i. Fitting diagram of predicted and observed salinity retrieved by different variable combinations. Figure a–i correspond to a–i combination respectively.

3 时, 存在一定程度的高估情况, 而当盐度介于 3~4 之间时, 普遍存在低估情况; 图 4f~i 对应的 5 变量(ρ_B、ρ_G、ρ_R、ρ_{NIR}、NDWI)模型的反演结果中, 当盐度低于 3 时存在少部分样点预测值高估的情况。

2.3 盐度空间分布

通过多元线性回归反演得到了错鄂湖水表盐度的空间分布图(图 5)。图 5a 为 5 变量(ρ_B、ρ_G、ρ_R、ρ_{NIR}、NDWI)模型中精度最高的 NDWI、NIR 和 *B* 波段组合(g 组合)的反演结果, 图 5b 为 4 变量(ρ_B、ρ_G、ρ_R、ρ_{NIR})模型中拟合精度最优的 G 和 R 波段组合(b 组合)的反演结果, 两种反演结果的盐度空间分布格局相似, 均表现出湖泊西岸沿岸带盐度低, 由外到内呈现增大趋势, 整体湖面内部则表

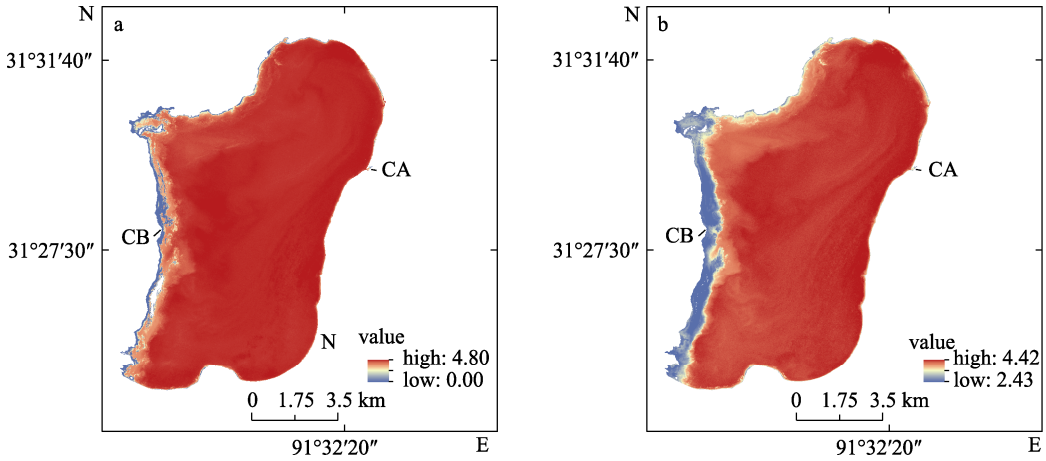

图 5　错鄂湖水表盐度空间分布

a. g 组合(NDWI, NIR, *B* 变量)反演结果; b. b 组合(*G*, *R* 变量)反演结果. CA, CB 为入湖口.

Fig. 5　Spatial distribution of surface salinity in the Co Ngoin Lake

a. The inversion results of g combination (NDWI, NIR and *B* variable); b. The inversion results from b combination (*G* and *R* variable). CA and CB are lake inlets.

现出较为均匀同质的盐度分布特征。g 组合和 b 组合反演的错鄂湖泊水表盐度均值分别为 4.14 和 4.09, 与实测样点的盐度均值 4.15 相比, g 组合结果更为接近。

对比研究区中东岸 CA 和西岸 CB 两个湖口区域实测值和反演结果发现, 对于 CA 区域, 实测盐度均值为 3.99, 最大为 4.23, 最小为 3.77。从图 3 反演结果分析发现, g 组合反演结果中盐度均值为 3.67, 最大值为 3.93, 最小值为 3.08; b 组合反演结果中盐度均值为 3.43, 最大值为 3.67, 最小值为 3.12, g 组合结果更接近实测值, 反演精度高。对于 CB 区域, 由于岸边植被覆盖度较高, 盐度较低, 低于 CA 区域, 实测盐度均值为 2.35, 最小值仅为 0.23, 最大值为 3.52。g 和 b 的反演结果中均值分别为 1.60 和 2.72, b 组合在 2.63~2.82 之间, 盐度波动范围小, g 组合反演结果在 0.84~3.01 之间, 更接近实测值。

3　讨论

3.1　不同变量组合对盐度反演结果的影响探讨

Qing 等[21]对渤海盐度(26.09~32.28)的研究表明, 560 nm 波段反射率与盐度相关性最大, 而 490 nm 次之, 这与本研究的分析结果一致, 即绿波段反射率与盐度的相关性最大, 其次为蓝波段, 红波段较低。同时本研究的应用分析进一步表明, 加入 NDWI 参与的盐度反演模型比不包含 NDWI 的反演精度更高。值得注意的是, 研究结果表明尽管加入 NDWI 参数的盐度反演模型精度高于不含 NDWI 的模型, 但仅凭 NDWI 单变量拟合并不能得到十分理想的反演效果(如图 4e); 而当加入 NIR 波段后, 模型反演精度进一步提高, MAE 由 0.117 降低到了 0.106, 可见 NIR 波段在反演中发挥了作用。虽然 NIR 波段反射率与总体实测盐度的拟合 R^2 极低(图 2d, R^2 仅约 0.08), 但当仅观察盐度低于 3 的盐度空间分布时(图 3), 近红外波段反射率与盐度则呈现出较强的负相关关系, R^2 为 0.60, 明显高于其他波段反射率与盐度的相关性。NDWI 指数具有突出反映盐湖在绿波段强反射和近红外波段强吸收的特点, 而且 NIR 波段在更低盐度空间与水表盐度呈现较强的负相关, 这可能是导致模型反演精度进一步提升的原因。

3.2　不同盐度水平对盐度反演结果的影响探讨

目前, 对于高盐度的海域水表盐度反演研究较多[22-24], 且精度较高, 而对低盐湖泊盐度反演研究较少。刘英等[12]利用黄色物质(CDOM)反演博斯腾湖水表盐度的精度为 1.1, 误差较大,认为反演精度低与博湖整体水表盐度偏低(<3)有关。为进一步探索不同盐度水平对反演结果的影响, 本研究剔除实测盐度值中低于 3 的样本点后, 采用 NDWI、近红外和蓝波段进行水表盐度反演的

MAE 进一步提升为 0.059; 而仅选择盐度低于 3 样本点的 MAE 则下降为 0.648, 表明不同盐度水平确实会对反演结果产生影响。本研究对错鄂湖整体水表盐度的最佳反演结果误差为 0.103, 反演均值 4.14 与实测均值 4.15 非常接近, 表明对盐度变化梯度有较为全面的采样点覆盖时, 对低盐湖泊同样可获得较高的反演精度。

3.3 不同模型对盐度反演结果的影响探讨

在盐度反演研究中, 线性回归和随机森林模型[25]应用较多。随机森林是基于统计学理论的机器学习算法, 由多决策树构成, 通过有放回的抽样以及构建子决策树, 最终输出结果。在海表盐度反演中, Wong 等[26]对比了多元线性回归和主成分分析反演盐度的精度, 发现多元线性回归的模型误差约为 1.6 (盐度均值约 28.5), 精度较高, 表明简单的多元线性回归模型也可得到较高的反演精度。Urquhart 等[27]对比了 8 种统计模型对海湾盐度反演的结果, 广义加性模型精度最高时误差约为 1.82 (盐度均值 16.5), 而采用随机森林时误差约 2.06。但吴芳芳等[28]利用随机森林对墨西哥湾海表盐度(均值约 35.554)反演精度较高, 误差约为 0.335。上述研究表明不同模型对反演结果存在一定影响。鉴于此, 本研究采用相同变量对比了线性回归和随机森林方法反演结果的差异, 发现随机森林模型精度(MAE=0.108)低于线性回归模型(MAE=0.103), 表明在错鄂湖盐度反演中, 采用适当变量组合的简单线性回归模型即可获得精度较高的反演结果, 与 Wong 等[26]的研究结果相似。由于不同水域的盐度反演中模型选择会对反演结果产生影响, 因此针对不同区域水体开展盐度遥感反演时, 应对模型进行对比并选择最优的方法。

4 结论

本研究以西藏错鄂湖为例, 基于 Sentinel-2 卫星数据, 利用多光谱遥感技术探索了低盐湖泊的盐度反演方法。研究优化了遥感反演模型, 利用 9 种变量对错鄂湖泊的水表盐度进行反演, 结果表明包含 NDWI 的变量组合模型反演精度更高, NDWI 和近红外以及蓝波段组合时, 线性回归模型反演精度最高。NDWI 变量主要突出反映了盐湖在绿波段的强反射和近红外波段的强吸收特点, 而同时加入近红外波段时由于捕捉到盐度低于 3 时水表盐度与近红外波段的负相关关系特点, 进一步提升了模型的拟合精度。西藏错鄂湖泊的水表盐度空间分布总体呈现出岸边、河口低, 湖泊内部高且分布较为均匀的空间格局。基于多变量线性回归模型的光学遥感盐度反演结果与实测盐度接近, 反演精度高, 验证了方法的有效性, 为低盐湖泊的水表盐度反演提供了参考。下一步将尝试开展更大规模的内陆盐湖水表盐度反演方法研究, 研制出可适用于复杂水表盐度变化且能够自适应的湖泊水表盐度反演模型。

参考文献

[1] Terray L, Corre L, Cravatte S, et al. Near-surface salinity as nature's rain gauge to detect human influence on the tropical water cycle[J]. Journal of Climate, 2012, 25(3): 958-977.

[2] Geiger E F, Grossi M D, Trembanis A C, et al. Satellite-derived coastal ocean and estuarine salinity in the Mid-Atlantic[J]. Continental Shelf Research, 2013, 63: S235-S242.

[3] Khorram S. Remote sensing of salinity in the San francisco bay delta[J]. Remote Sensing of Environment, 1982, 12(1): 15-22.

[4] Wang J, Deng Z Q. Development of a MODIS data based algorithm for retrieving nearshore sea surface salinity along the northern Gulf of Mexico coast[J]. International Journal of Remote Sensing, 2018, 39(11): 3497-3511.

[5] Łukawska-Matuszewska K, Urbański J A. Prediction of near-bottom water salinity in the Baltic Sea using Ordinary Least Squares and Geographically Weighted Regression models[J]. Estuarine, Coastal and Shelf Science, 2014, 149: 255-263.

[6] Zhao H, Li C J, Yin Y H. Forecast Sea surface salinity using statistic model based on SMOS data[J]. Periodical of Ocean University of China, 2016, 46(8): 141-146. [赵红, 李长军, 殷一浩. 海表面盐度的统计预测模型[J]. 中国海洋大学学报(自然科学版), 2016, 46(8): 141-146.]

[7] Dai S B, Wang Y H. Sea surface salinity inversion near Palawan Island by remote sensing[J]. Remote Sensing Information, 2017, 32(2): 131-136. [代松波, 王艳慧. 巴拉望岛附近海域盐度遥感反演[J]. 遥感信息, 2017, 32(2): 131-136.]

[8] He Z K, Wang X D, Chen Z Q, et al. Reconstructing salinity profile using temperature profile and sea surface salinity[J].

Journal of Tropical Oceanography, 2021, 40(6): 41-51. [何子康, 王喜冬, 陈志强, 等. 利用海洋温度剖面与海表盐度反演盐度剖面方法研究[J]. 热带海洋学报, 2021, 40(6): 41-51.]

[9] Jiang J L, Liu X N, Liu M L, et al. Remote sensing retrieval model of sea surface salinity in Hong Kong waters based on the random forest[J]. Marine Science Bulletin, 2014, 33(3): 333-341. [江佳乐, 刘湘南, 刘美玲, 等. 基于随机森林的香港海域海表盐度遥感反演模型[J]. 海洋通报, 2014, 33(3): 333-341.]

[10] Niu Y. Comparison and application of sea surface salinity retrieval by remote sensing in the Yangtze estuarine waters[D]. Shanghai: East China Normal University, 2019: 102].[牛莹. 长江口表层盐度遥感反演方法比较及应用研究[D]. 上海: 华东师范大学, 2019: 102.]

[11] He Y Q, Feng Y B, Fu Q H, et al. A study on optical remote sensing inversion of sea surface salinity in the Pearl River Estuary[J]. Geography and Geo-Information Science, 2020, 36(6): 40-47. [何颖清, 冯佑斌, 扶卿华, 等. 珠江河口海水表层盐度光学遥感反演研究[J]. 地理与地理信息科学, 2020, 36(6): 40-47.]

[12] Liu Y, Bao A M, Chen X. Measuring salinity of low salinity lake by optical remote sensing: A case study of Bosten Lake[J]. Journal of Remote Sensing, 2014, 18(4): 902-911. [刘英, 包安明, 陈曦. 低盐湖泊水体盐度光学遥感反演研究——以博斯腾湖为例[J]. 遥感学报, 2014, 18(4): 902-911.]

[13] Jia Q X, Liu X F, Wang H P, et al. Bio-ecological resources of saline lakes in Tibet and their economic prospect[J]. Science & Technology Review, 2017, 35(12): 19-26. [贾沁贤, 刘喜方, 王洪平, 等. 西藏盐湖生物与生态资源及其开发利用[J]. 科技导报, 2017, 35(12): 19-26.]

[14] Zheng X Y, Zhang M G, Xu X, et al. Saline Lake of China[M]. Beijing: Science Press, 2002: 415. [郑喜玉, 张明刚, 徐昶 , 等. 中国盐湖志[M]. 北京: 科学出版社, 2002.]

[15] Brooks K M. The effects of water temperature, salinity, and currents on the survival and distribution of the infective copepodid stage of sea lice (*Lepeophtheirus salmonis*) originating on Atlantic salmon farms in the broughton archipelago of British *Columbia*, Canada[J]. Reviews in Fisheries Science, 2005, 13(3): 177-204.

[16] Weththasinghe S, Ratnayake A, Dushyantha N, et al. Structures of water column and sediment sub-bottom in the Tangalle Bay, Sri Lanka[C]//Proceedings of ISERME, Wadduwa, SriLanka, 2017: 73-74.

[17] Hagolle O, Huc M, Pascual D V, et al. A multi-temporal method for cloud detection, applied to FORMOSAT-2, VENμS, LANDSAT and SENTINEL-2 images[J]. Remote Sensing of Environment, 2010, 114(8): 1747-1755.

[18] McFeeters S K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features[J]. International Journal of Remote Sensing, 1996, 17(7): 1425-1432.

[19] Pocewicz A, Vierling L A, Lentile L B, et al. View angle effects on relationships between MISR vegetation indices and leaf area index in a recently burned ponderosa pine forest[J]. Remote Sensing of Environment, 2007, 107(1-2): 322-333.

[20] Willmott C J, Matsuura K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance[J]. Climate Research, 2005, 30: 79-82.

[21] Qing S, Zhang J, Cui T W, et al. Retrieval of sea surface salinity with MERIS and MODIS data in the Bohai Sea[J]. Remote Sensing of Environment, 2013, 136: 117-125.

[22] Marghany M, Hashim M, Cracknell A P. Modelling Sea surface salinity from MODIS satellite data[M]//Computational Science and Its Applications – ICCSA 2010. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010: 545-556.

[23] Hu J Y, Liu B J, Peng S H. Forecasting salinity time series using RF and ELM approaches coupled with decomposition techniques[J]. Stochastic Environmental Research and Risk Assessment, 2019, 33(4-6): 1117-1135.

[24] Chen S L, Hu C M. Estimating Sea surface salinity in the northern Gulf of Mexico from satellite ocean color measurements[J]. Remote Sensing of Environment, 2017, 201: 115-132.

[25] Ho T K. The random subspace method for constructing decision forests[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, 20(8): 832-844.

[26] Wong M S, Lee K H, Kim J, et al. Modeling of suspended solids and sea surface salinity in Hong Kong using aqua/MODIS satellite images[J]. Korean Journal of Remote Sensing, 2007, 23: 161-169.

[27] Urquhart E A, Zaitchik B F, Hoffman M J, et al. Remotely sensed estimates of surface salinity in the Chesapeake Bay: A statistical approach[J]. Remote Sensing of Environment, 2012, 123: 522-531.

[28] Wu F F, Fu Z Y, Hu L S, et al. Retrieval of sea surface salinity in the Gulf of Mexico based on random forest method[J]. Acta Oceanologica Sinica, 2021, 43(9): 126-136. [吴芳芳, 傅智一, 胡林舒, 等. 基于随机森林方法反演墨西哥湾海表盐度[J]. 海洋学报(中文版), 2021, 43(9): 126-136.]

Salinity inversion of a low salinity lake based on sentinel-2 multispectral remote sensing: A case study of the Co Ngoin Lake in Tibet

MAO Zhihui[1, 2], DING Fang[1, 2], YUAN Lilai[1], LI Yingren[1, 2], HE Dekui[3], LIU Mingdian[4], WANG Lin[1, 2]

1. Fishery Resource and Environment Research Center, Chinese Academy of Fishery Sciences, Beijing 100141, China;
2. Scientific Observing and Experimental Station of Fishery Remote Sensing, Ministry of Agriculture and Rural Affairs, Beijing 100141, China;
3. Institute of Hydrobiology, Chinese Academy of Sciences, Wuhan 430072, China;
4. Yangtze River Fisheries Research Institute, Chinese Academy of Fishery Sciences, Wuhan 430223, China

Abstract: Salinity is an important parameter to characterize the physical properties of water bodies. In order to explore the ability of remote sensing data to measure the salinity of low-salt lakes, this study used remote sensing reflectance data in blue, green, red, and near-infrared bands with 10 m spatial resolution of sentinel-2 to analyze the relationship between measured surface salinity and reflectance in the Co Ngoin Lake. Based on different combinations of variables, which included the reflectance of four bands and normalized difference water index (NDWI), a linear regression model was constructed with salinity data, and the accuracy evaluated. The model was also used to invert the surface salinity of the Co Ngoin Lake. The results showed that the correlation between reflectance and salinity in the green band was higher than that in other bands. However, the near-infrared band reflectivity had the highest correlation with salinity, when the salinity was lower than 3. Among the 9 models with the combination of variables, the addition of the NDWI variable improved the accuracy of model inversion, which was higher than the accuracy of the model without the NDWI variable. The linear regression model of the three variable combinations of NDWI, near-infrared band and blue band had the highest accuracy of salinity inversion. The mean absolute error (MAE) was 0.103, and the salinity observed value and predicted value correlated well. In the combination without NDWI variable, the salinity inversion accuracy of the green band and red band was high, with MAE of 0.126. The spatial distribution of water surface salinity of the Co Ngoin Lake generally presented a spatial pattern of low salinity at the shore and estuary, and high and relatively uniform distribution within the lake. From the inversion results, the average salinity of the Co Ngoin Lake was approximately 4.14, which was very close to the measured average (4.15). The results verified the effectiveness of the multispectral remote sensing method, which has the advantages of being fast, convenient and highly accurate in predicting the water surface salinity of the Co Ngoin Lake. This study has guiding significance for low lake surface salinity inversion using high-resolution multi-spectral remote sensing data. In addition, it has significant value for the protection and sustainable use of aquatic biological resources.

Key words: salinity; multispectral remote sensing; inversion; the Co Ngoin Lake

Corresponding author: WANG Lin. E-mail: angels121@cafs.ac.cn