

内陆水体藻蓝蛋白遥感反演研究进展

吕丽丽^{1,2}, 宋开山^{1,3}, 刘阁¹, 温志丹¹, 尚盈辛¹, 李思佳¹

1. 中国科学院东北地理与农业生态研究所遥感中心,长春 130102;
2. 中国科学院大学,北京 100049;
3. 聊城大学 环境与规划学院,聊城 252000

摘要: 藻蓝蛋白 (PC), 作为蓝藻的标志性色素, 通常被用作进行蓝藻水华遥感监测的标志物。近年来, 内陆水体水质恶化, 富营养化加剧, 藻华频发, PC 遥感反演研究越来越受到关注。本文从 PC 光学特性、反演算法开发、卫星传感器应用等方面难点及干扰因素, 综合梳理了过去 30 a PC 遥感反演研究的发展历程和趋势, 以期理解国内外相关研究的新思路和新方法, 掌握未来 PC 遥感反演发展研究的新动态, 为水质和水资源的监管提供数据和理论基础。过去的 30 a 里, PC 遥感反演研究发文量持续走高, 并在算法上取得突破性进展, 先后出现了很多经典算法, 如波段比法、基线法、嵌套波段比法、生物光学模型、衍生算法和机器学习算法等, 成功地分离出 PC 特征吸收波段 (620 nm) 的光谱信息, 弱化了其他光学活性物质的影响, 获得了较可靠的精度。另外, 除高光谱航空/卫星影像数据 (Hyperion、HICO) 外, 多光谱卫星遥感平台的 PC 遥感反演研究也日趋成熟, 可选择的数据源种类较多, 如 Landsat 系列、MODIS、MERIS、Sentinel-2 MSI、Sentinel-3 OLCI, 其中 MERIS 和 Sentinel-3 OLCI 由于其辐射分辨率、空间分辨率和波段设置更适合用于 PC 遥感反演, 在 PC 遥感反演中被广泛使用。由于 PC 光谱信号较弱, 且易受叶绿素 a、悬浮颗粒物等的干扰, 想获得高精度的 PC 遥感估算, 仍然是个挑战, 未来 PC 遥感反演研究将向着 PC 测试方法的标准化、算法精细化、时空格局大尺度化及 PC 遥感反演应用深入化等方面发展。

关键词: 湖泊遥感, 内陆水体, 藻蓝蛋白, 光学特性, 反演算法, 卫星传感器

引用格式: 吕丽丽, 宋开山, 刘阁, 温志丹, 尚盈辛, 李思佳. 2022. 内陆水体藻蓝蛋白遥感反演研究进展. 遥感学报, 26(1): 32-48
Lyu L L, Song K S, Liu G, Wen Z D, Shang Y X and Li S J. 2022. Advances in remote sensing of phycocyanin for inland waters. National Remote Sensing Bulletin, 26(1):32-48[DOI:10.11834/jrs.20221276]

1 引言

相比海洋生态系统, 内陆水体 (湖泊、水库、河流) 生态系统与人类生产生活的关系更加密切。内陆水体中各浮游动植物、颗粒和溶解性有机物、无机物、微生物、碳源和氮源等物质相互作用, 共同维持着水体生物化学生态系统的平衡 (Duan 等, 2012; Song 等, 2019; Wen 等, 2019)。在内陆水体中浮游藻类, 因其含有的色素可以捕获太阳光并将其转化成能量, 充当着一切能量的提供者 (Hmimina 等, 2019)。有研究表明, 色素组成及其比例的不同是引起藻类间吸收光谱变化的主要原因 (Zhao 等, 2018)。藻蓝蛋白 PC (*Phycocyanin*), 是

蓝藻的标志性色素, 仅存在于蓝藻中, 可以指示蓝藻生物量, 具有吸收和传递光能的性质, 分子量约为 232 KDa, 具有荧光性, 呈亮蓝色, 属于胞内蛋白, 易溶于水、乙醇等极性溶剂 (Zhao 等, 2018)。PC 是天然光学活性物质, 在 620 nm 附近处有明显的特征吸收峰, 这正给遥感监测其浓度提供了理论依据。近年来, 内陆水体富营养化现象加剧, 蓝藻水华现象频发, 导致水生生态系统严重失衡, 有些蓝藻产生藻毒素, 严重威胁着人类和动物健康安全 (Matthews 等, 2010; Shi 等, 2015a; Song 等, 2021)。利用遥感技术监测 PC 浓度, 进而来监测水体中的蓝藻生物量, 是一种有效地、大尺度、快速精确地监测蓝藻水华的策略

收稿日期: 2021-04-30; 预印本: 2021-11-18

基金项目: 国家自然科学基金(编号:41730104)

第一作者简介: 吕丽丽, 1985 年生, 女, 博士研究生, 研究方向为内陆水体藻蓝蛋白浓度遥感反演。E-mail: lvlili@iga.ac.cn

通信作者简介: 宋开山, 1974 年生, 男, 研究员, 研究方向为内陆水体水质参数遥感反演。E-mail: songkaishan@iga.ac.cn

(Duan等, 2017; Miao等, 2020)。

PC第一次出现在遥感学科领域, 应归功于美国的Gordon学者, Gordon等(1980)首次阐述了PC的光谱特征, 标志着PC遥感应用的开端。20世纪90年代航空遥感传感器CAMS、CASI(Dekker等, 1991; Millie等, 1992; Dekker, 1993)被应用于监测PC浓度; 2000年以后随着各大卫星遥感平台数据的相继开放, MERIS以及欧空局的Sentinel-3OLCI等数据增设了620 nm波段, 加之3大分辨率的提升, 算法的不断优化, 大大提升了PC遥感监测技术在各个尺度和准实时监测的能力(Ogashawara, 2020; Yan等, 2018); 在随后的十几年内PC遥感研究处于爆发期, 无论是基础原理, 算法开发, 还是遥感平台的应用都得到了突飞猛进的发展, 遥感技术已成为蓝藻监测及水质管理领域中不可或缺的有效工具。然而, 与3大经典光学活性物质相比, PC的遥感研究相对较少, 因为其620 nm的吸收峰光学信号较弱、且易受到水体类型和叶绿素a、悬浮物等的影响。另外, PC实际浓度的测定尚没有一个标准方法可循, 目前主流的提取方法有手动研磨法、超声破壁法、冻融法、超声冻融联用法(Hunter等, 2010; Sarada等, 1999)。测定方法有吸光度法(Bennett和Bogorad, 1973)、荧光分光光度计标准曲线法(Lyu等, 2013)、酶联反应测定法(Zimba, 2012)、荧光探针测定法(Mishra等, 2009; Song等, 2013)。以上萃取和测定方法间PC的测定值存在差异, 尤其是在低浓度水体中, 想要做到高精度反演仍是一个挑战(Liu等, 2018)。

PC定量遥感反演研究的意义在于, 可利用PC与蓝藻生物量, 与藻毒素之间强烈的正相关关系, 定量监测水体中蓝藻生物量或藻毒素含量, 这对理解蓝藻暴发机制及其早期预警具有重要意义。基于这点, 关于PC光学性质(反射、吸收、荧光)、反演模型及应用拓展的研究, 都成为近年来水环境遥感研究领域的热点。国际上已有几篇综述性论文发表(Ogashawara, 2020; Ogashawara等, 2013; Yan等, 2018), 他们的侧重点或是反演算法对比或是文献统计分析, 缺少PC光学性质的全面概述, 缺少PC反演的影响因素分析等。因此, 本研究领域迫切需要一个从多角度、多维度、系统地综述论文来概括总结国内外PC遥感研究的发展趋势及取得的新成果。基于这点, 本综述更注

重对PC光学性质、反演算法开发和验证、影响因素以及多种卫星数据源应用的梳理, 并深入挖掘其未来的发展方向。

2 文献计量分析及概述

在过去的30 a里, PC遥感研究不断发展进步, 涉及到的研究区300余个, 遍布全球各地, 主要集中分布在欧美地区及中国境内, 还有少数分布在非洲、印度、韩国等地区。经文献查阅, 这些水体无论是湖泊、水库还是河流均属于富营养化或超富营养化水体类型。中国境内涉及的相关研究区多分布在南方富营养化较为严重的一些湖泊, 例如, 太湖、巢湖、滇池、洱海等。从PC遥感反演发文数量上看, 自1990年至今一直呈持续增加的趋势(图1), 增加趋势可分为3个阶段, 即2005年之前属于起步阶段, 零星有些研究, 2005年—2015年属于快速增加阶段, 以算法开发, 各数据源应用为主, 2015年之后属于稳定发展阶段。这3个阶段也充分体现了30 a来PC遥感反演研究的发展和日趋成熟。

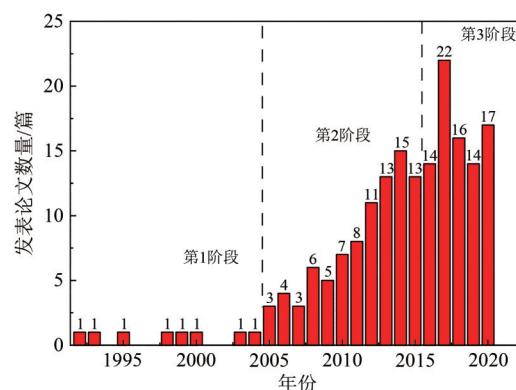


图1 PC反演研究自1990年以来的发文数量及其发展的3个阶段

Fig. 1 The number of papers published by PC inversion since 1990

PC遥感反演研究在国家尺度上的分布情况表明(图2), 美国在该领域研究中发文数量遥遥领先, 占研究发文总数量的40%; 中国位居第二, 占总数量的25%, 欧洲国家占总数量的21%, 韩国占总数量的8%, 而南非、印度、加拿大、巴西等国家在这方面的研究则很少。总体来看, 全球还有很多国家从来没有涉及PC遥感研究领域, 并且, 已有这些国家在此领域的发展极度不平衡, 按照排名顺序发文数量呈断崖式下降。可喜的是,

中国在此领域的研究数量超过了欧洲，但在文章质量和影响力上，中国离欧美还有一定差距。

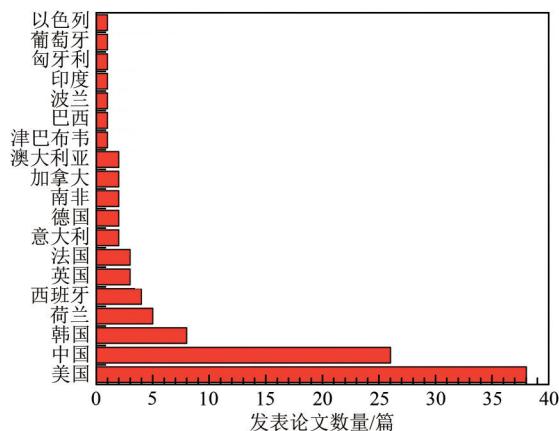


图2 自1992年以来所有PC反演研究发文数量在主要国家的分布情况

Fig. 2 Distribution of the number of papers published in PC inversion studies since 1992 in major countries

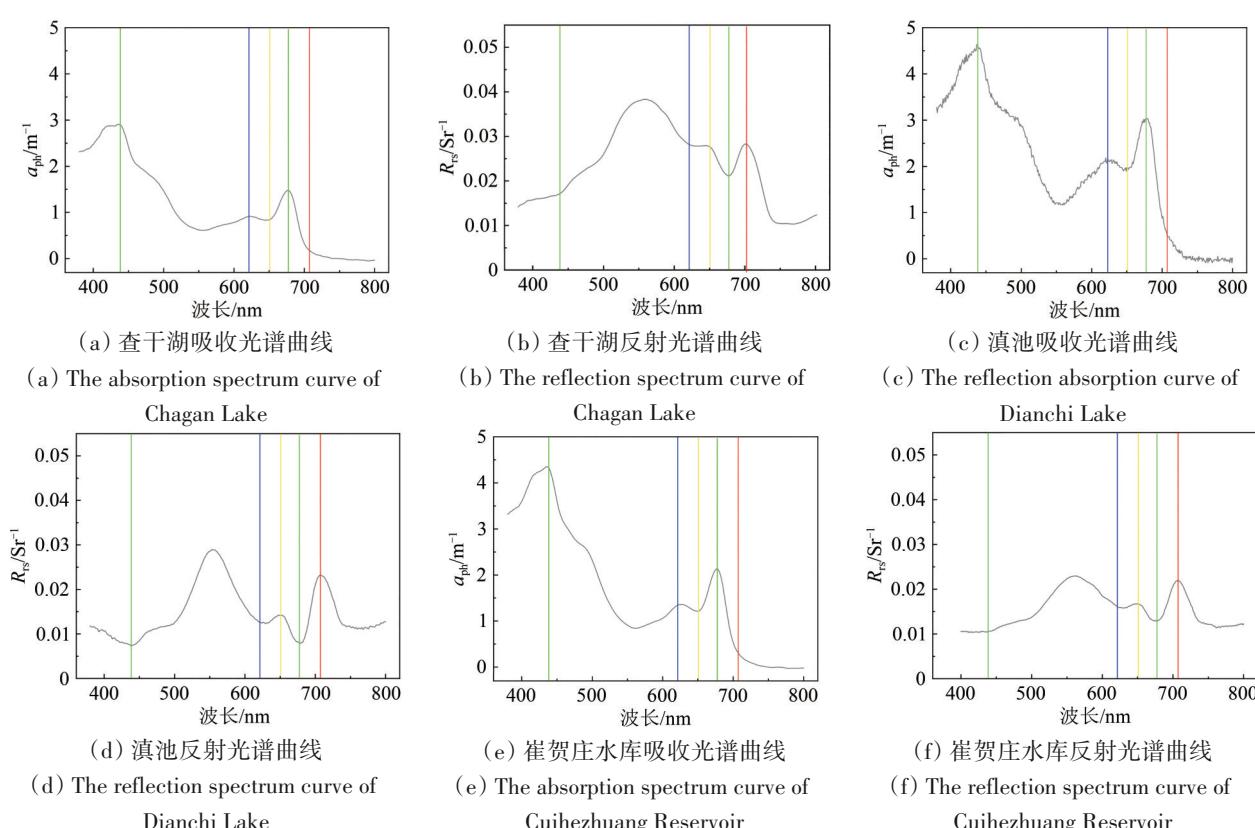
3 藻蓝蛋白的光学性质

3.1 藻蓝蛋白的吸收特性

PC的吸收系数一般表示为 $a_{\text{PC}}(620)$ ，以 $a_{\text{PC}}(620)$ 除以PC浓度来表示PC单位吸收系数，即 $a_{\text{PC}}^*(620)$ 。

这两个参数对定量遥感反演PC浓度都是至关重要的。从中国几个典型水体的藻类吸收光谱曲线（图3），可以看到3个明显的吸收峰，绿色线指示Chla的吸收峰（443 nm、675 nm），蓝色线指示了PC的吸收峰（620 nm）。相比于Chla的吸收峰，PC吸收信号较弱，大概只有Chla吸收峰强度的20% (Schalles 和 Yacobi, 2000)。所以要想在遥感上得到与Chla等效的光谱信号，需要较高的PC浓度 (Shi 等, 2015a; Yan 等, 2018)。

不同类型内陆水体的 $a_{\text{PC}}(620)$ 值差异较大， $a_{\text{PC}}(620)$ 在中国东部湖泊数值范围为0.05—1.56 m⁻¹ (Duan 等, 2012)，在荷兰北部湖泊为0.002—1.2 m⁻¹ (Simis 等, 2005)，在美国印第安纳州水库为0.008—1.25 m⁻¹ (Li 等, 2015)，这表明内陆水体 $a_{\text{PC}}(620)$ 有强烈的变异性。有研究表明， $a_{\text{PC}}(620)$ 会随着水体营养化等级的增加而增大 (Matthews 等, 2020)。另外， $a_{\text{PC}}(620)$ 也呈现季节性变化，一般是夏秋季较高，春冬季较低 (Schalles 和 Yacobi, 2000)。这些研究结果表明 $a_{\text{PC}}(620)$ 不仅具有时空变异性，同时也受水质类型的影响。



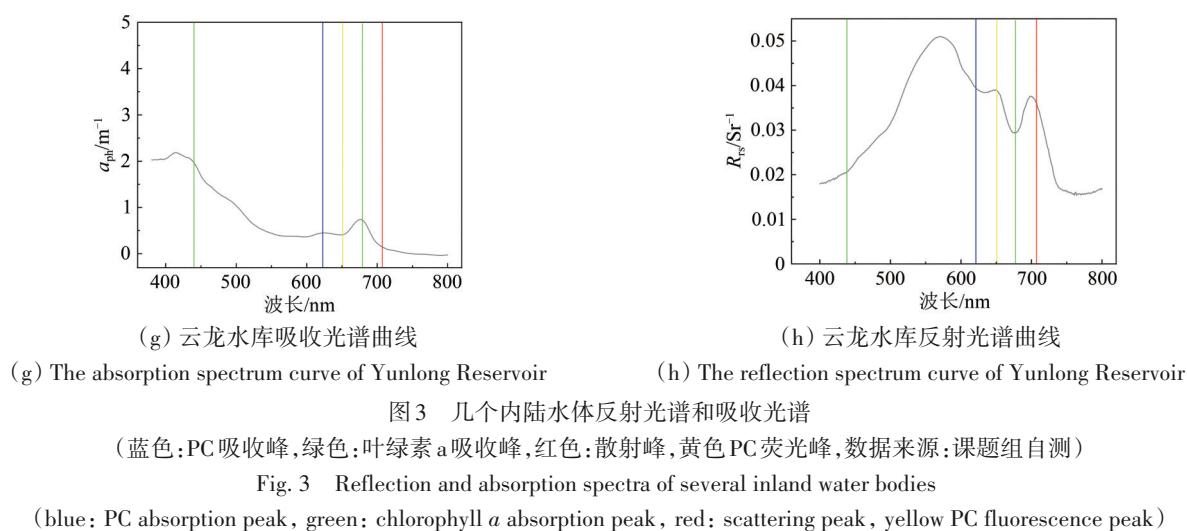


图3 几个内陆水体反射光谱和吸收光谱

(蓝色:PC吸收峰,绿色:叶绿素a吸收峰,红色:散射峰,黄色PC荧光峰,数据来源:课题组自测)

Fig. 3 Reflection and absorption spectra of several inland water bodies

(blue: PC absorption peak, green: chlorophyll a absorption peak, red: scattering peak, yellow PC fluorescence peak)

根据定义, PC 单位吸收 $a_{\text{PC}}^*(620)$ 可以反映 $a_{\text{PC}}(620)$ 与 PC 浓度的关系, 一般的 $a_{\text{PC}}^*(620)$ 与 PC 浓度呈负相关关系 (Duan 等, 2012; Shi 等, 2015a)。不同地区不同类型水体, $a_{\text{PC}}^*(620)$ 差别较大, 中国东部湖泊 $a_{\text{PC}}^*(620)$ 的范围为 0.001— $1.2 \text{ m}^2 \cdot \text{mg}^{-1}$ (Duan 等, 2012), 荷兰北部湖泊为 0.0088 — $0.1868 \text{ m}^2 \cdot \text{mg}^{-1}$ (Simis 等, 2005)。 $a_{\text{PC}}^*(620)$ 受多种因素影响, 包括细胞形态、光利用率、其他色素物质的干扰 (Simis 等, 2005)。同时, PC 浓度测定的不确定性也是 $a_{\text{PC}}^*(620)$ 强变异性的重要因素。利用生物光学模型精确反演 PC 的关键是选择一个合适的 $a_{\text{PC}}^*(620)$ 值, 因此 $a_{\text{PC}}^*(620)$ 的变异是不可忽略的 (Duan 等, 2012; Lyu 等, 2013; Ruiz-Verdú 等, 2008; Simis 等, 2005)。Simis 算法中将 $a_{\text{PC}}^*(620)$ 值固定为 $0.0095 \text{ m}^2 \cdot \text{mg}^{-1}$ (Simis 等, 2005), 但后来他们又调整到 $0.007 \text{ m}^2 \cdot \text{mg}^{-1}$ (Simis 等, 2007), 因为新的 PC 提取方法使 PC 的萃取效率提高了 28%。但是, Le 等 (2011) 和 Mishra 等 (2013) 等人认为 $0.007 \text{ m}^2 \cdot \text{mg}^{-1}$ 仍然偏高, 在研究中则使用了较低的 $a_{\text{PC}}^*(620)$, 如 $0.0043 \text{ m}^2 \cdot \text{mg}^{-1}$ (Jupp 等, 1994) 和 $0.0048 \text{ m}^2 \cdot \text{mg}^{-1}$ (Mishra 等, 2013), 甚至在有的研究中, 没有测定 $a_{\text{PC}}^*(620)$ 的值, 而是直接使用已报道的平均值 $0.0046 \text{ m}^2 \cdot \text{mg}^{-1}$ (Li 等, 2015)。基于 $a_{\text{PC}}^*(620)$ 易变的性质, Mishra 等 (2013) 利用同一组数据集, 考察了 3 种 $a_{\text{PC}}^*(620)$ (报道过的 $0.0048 \text{ m}^2 \cdot \text{mg}^{-1}$ 、平均值、模拟值) 对 PC 浓度反演精度的影响, 3 种情况下得到的 PC 估算平均相对误差在 10%—22% 变异。结果还表明, $a_{\text{PC}}^*(620)$ 随着 $R_{\text{rs}}(620)/R_{\text{rs}}(665)$ 的比值呈线性增加。总而言之

之, $a_{\text{PC}}^*(620)$ 值不是一个固定值, 受季节、细胞形态、蓝藻种类、色素浓度等多种因素影响。

3.2 藻蓝蛋白的反射光谱特性

在富含蓝藻的水体中, 反射光谱曲线具有 3 个明显的反射峰 (图 3), 第 1 个反射峰位于 500—600 nm, 是由藻类散射吸收引起的最大最宽的绿峰, 第 2 个峰位于 640—660 nm, 是由位于两边的 620 nm、670 nm 波段处的 PC 吸收, Chla 吸收, 共同作用形成的 (Hunter 等, 2008), 第 3 个峰位于 700—710 nm, 是由 Chla 强吸收和散射引起的。然而, 这些峰并不是孤立的, 固定不变的。有研究表明, PC 光谱特征的位置是随着 PC 浓度在 Chla 浓度比例中改变而变化的 (Hunter 等, 2010), 可能小于 620 nm 也可能大于 620 nm。在贫营养水体中, PC 浓度很低, 光谱曲线 620 nm 处没有明显的吸收谷, 导致低浓度时, PC 反演精度较低 (Li 等, 2012; Simis 等, 2007), 而在中营养、富营养水体中 620 nm 处有明显的吸收谷, 且 PC 浓度越高, 620 nm 的吸收谷越深。而在浮渣出现以后, 即水面被蓝藻覆盖, 光谱呈现典型植被特征 (光谱上 753 nm 反射峰高于 709 nm) 时, PC 反演算法已经没有意义, 此时应该考虑更换算法去检测浮渣蓝藻生物量 (Shi 等, 2019)。

与其他两个散射峰相比, 反映 PC 吸收的反射峰信号是最弱的, 这给遥感反演 PC 浓度带来了一定难度, 多数研究使用实测高光谱数据或高光谱航空遥感影像 (AISA、CASI、CHRIS), 以获得满意的离水辐亮度信号。对于多光谱卫星传感器,

含有620 nm波段设置的，也多被用于PC遥感反演研究。总之，结合PC光谱特征和其他峰、谷的分析，包括其量级的大小、位置、峰高、峰面积、求导等方法、开发各种PC反演算法。

4 藻蓝蛋白与叶绿素a、蓝藻生物量的关系

叶绿素a存在于所有藻类中，研究多以Chla为代理指示总藻的含量，PC只存在于蓝藻中，可以指示蓝藻生物量。藻毒素大多存在与藻蓝细胞中，随藻蓝生物量增加而增多。他们之间的关系不仅可以用于妥善处理PC反演精度的问题，还可以用于间接估算蓝藻生物量，藻毒素浓度等，拓展PC遥感反演的意义及实际应用价值。

一般的，内陆水体中，PC与Chla的关系有两种情况：第一，只有在蓝藻主导的水体中，他们之间才存在显著正相关性，例如南非的Hartbeespoort水库、韩国Baekje水库，PC与Chla均具有很好的正相关关系；而对于非蓝藻主导的水体，南非的Thee water skloof水库，两者相关性较弱。第二，只有在适宜的PC: Chla比值范围内，两者关系才成立，当PC: Chla<0.5时，两者关系较弱，当PC: Chla≥0.5时，两者关系增强(Hunter等, 2008; Li等, 2012; Simis等, 2005, 2007)。太湖PC浓度为7—50 μg·L⁻¹范围内时，PC与Chla高度相关(郭一洋等, 2016)。Ahn等(2007)利用两者的紧密关系，以PC代替Chla，提出了基于PC浓度的蓝藻预警系统，得出PC浓度为0.1 μg·L⁻¹、30 μg·L⁻¹和700 μg·L⁻¹时分别指示安全水平、警惕水平、警告水平。

相比于Chla，PC与蓝藻生物量间的关系更加稳定，据报道两者相关关系高达0.7—0.8(表1)。但也有研究表明，不同种类蓝藻含有PC浓度是不同的。例如PC在*Planktothrix agardhi*藻中比在*Lemmmaniella sp*藻中的含量低4倍多，(Mishra等, 2013)。另外，PC也可以作为桥梁连接Chla和蓝藻生物量，从而实现大量的Chla反演算法被应用于蓝藻生物量监测的目的(Pyo等, 2020)。值得一提的是，PC: Chla比值赋有特别的意义，即可以指示总藻中蓝藻的比例，这对早期蓝藻水华预警以及理解内陆水体中浮游生物群落结构具有重要意义。

PC与藻毒素关系研究不多。Shi等(2015b)

通过两步估算法，利用藻毒素与Chla、Chla与MODIS指数这两个紧密的关系，反演得到2003到2013年的藻毒素浓度年际变化规律。其他研究也发现藻毒素浓度与PC浓度强烈正相关(Hunter等, 2008; Sridhar和Vincent, 2007)。由于藻毒素不是光学活性物质，理论上不能直接与遥感反射率(R_{rs})数据建立关系，所以，这些关系为二步法反演藻毒素提供了理论基础。

表1 藻蓝蛋白与叶绿素a、蓝藻生物量、藻毒素的关系

Table 1 The relationship between phycocyanin, chlorophyll a, cyanobacteria, and microcystin

| 关系式 | 参考文献 |
|--|------------------------|
| $C_{PC} = 8.7 \times C_{Chla}^{0.74}, R^2 = 0.87$ | Matthews等, 2020 |
| $\log(C_{Chla}) = 0.375 \times \log(C_{PC}) + 0.914, R^2 = 0.83$ | Pyo等, 2017 |
| $C_{PC} = 4.7 \times C_{Chla}^{0.4199}, R^2 = 0.32$ | Matthews等, 2020 |
| $\log(C_{CY}) = 1.705 \times \log(C_{PC}) + 1.606, R^2 = 0.73$ | Kudela等, 2015 |
| $C_{CY} = 109, 98.2 \times C_{PC} - 150.2, R^2 = 0.6$ | Torbick和Corbiere, 2015 |
| $C_{CY} = 3.558 \times C_{PC} + 110.11, R^2 = 0.79$ | Li等, 2010 |
| $C_{PC} = 0.001 \times C_{CY} + 2.4263, R^2 = 0.99$ | Mishra等, 2013 |
| $C_{PC} = 0.004 \times C_{CY} + 1.7287, R^2 = 0.99$ | Mishra等, 2013 |
| $C_{MC} = 0.0796 \times C_{Chla}, R^2 = 0.83$ | Shi等, 2015b |
| $C_{MC} \propto C_{PC}, R^2 = 0.90$ | Hunter等, 2008 |

注： C_{PC} 代表藻蓝蛋白浓度，单位μg·L⁻¹； C_{Chla} 代表叶绿素a浓度，单位μg·L⁻¹； C_{CY} 代表蓝藻生物量，单位cells/mL； C_{MC} 代表藻毒素，单位μg·L⁻¹。

5 藻蓝蛋白的遥感反演算法

5.1 经验算法

经验算法是直接使用统计回归方法，建立实测PC浓度与实测光谱反射率或各种光学传感器观测的反射率数据之间的关系，此方法很少考虑辐射原理，操作简单，是PC定量遥感反演研究中使用较多的算法(表2)，但此算法具有空间局限性，只适用于选定研究区的当次数据集(Yan等, 2018)。在经验算法中，波段比算法能消除一些干扰因素，如大气的影响，例如 $R_{rs}(710)/R_{rs}(620)$ (Seppälä等, 2007)， $R_{rs}(709)/R_{rs}(620)$ (Chi等,

2016; Kwon 等, 2020), $R_{\text{rs}}(747)/R_{\text{rs}}(665)$ (Sòria-Perpinyà 等, 2020), $R_{\text{rs}}(700)/R_{\text{rs}}(600)$ (Mishra 等, 2009), $R_{\text{rs}}(764)/R_{\text{rs}}(628)$ (Schalles 和 Yacobi, 2000)。可以看出, 这些算法的反演精度均较高。Mishra 等 (2009) 认为使用 600 nm 替代 620 nm, 可以有效消除 Chla 的影响, 反演精度得到提高。Millie 等 (1992) 基于 CAMS 影像的 Orange/red 与 PC 浓度建立经验回归关系, 但由于实测 PC 浓度值准确度的问题, 反演精度不高)。Vincent 等 (2004) 在美国 Lake Erie, 基于 Landsat TM 数据, 利用多个波段比为自变量, PC 浓度为因变量, 进行多元线性回归, 取得较好的反演精度。Medina-Cobo 等 (2014) 在西班牙的几个湖泊中, 基于 MERIS 数据的 B9 和 B6

波段的差与和之比, 成功反演 PC 浓度。Varunan 和 Shanmugam (2017) 在印度富营养化湖泊中, 利用实测光谱数据开发了波段比 $R_{\text{rs}}(620)/R_{\text{rs}}(652)$ 算法, 反演出 $a_{\text{PC}}(620)$ 的值, 然后利用固定 $a_{\text{PC}}^*(620) = 0.0072$, 成功反演 PC 浓度值, 然后将算法应用到 HICO 影像, 同样获得了较高反演精度。Torbick 等 (2018) 在英格兰北部湖泊, 基于 Landsat 7 ETM+, Landsat OLI 数据, 利用 NIR/green+NIR/blue 算法, 反演了 PC 浓度, 并利用 GIS 空间分析方法将 PC 浓度与肌肉萎缩病联系起来, 建立了肌肉萎缩病风险因子评价体系。Sòria-Perpinyà 等 (2020) 基于 Sentinel-2 MSI 影像数据, 利用 B_5 和 B_4 比值算法, 成功反演 PC 浓度。

表 2 PC 遥感算法汇总
Table 2 PC remote sensing algorithm summary

| 算法 | 研究区 | 数据源 | PC/($\mu\text{g}\cdot\text{L}^{-1}$) | 模型/算法 | 验证精度 | 参考文献 |
|------------|--------------------------------|--------------------------------|--|---|---|----------------------|
| 经验算法 | Vecht Lakes | 实测 CASI | | $\text{PC} = -24.6 + 13686 \left(0.5(R(0^-)_{600} + R(0^-)_{648}) - R(0^-)_{624} \right)$ | $R^2=0.99$, RMSE=2.34 $\mu\text{g}\cdot\text{L}^{-1}$, N=17 | Dekker, 1993 |
| | | CAESAR | | | | |
| 基线法 | Lakes in Spain, Netherlands | 实测 | 50—200 | | $R^2=0.46$, RMSE=119.66 $\mu\text{g}\cdot\text{L}^{-1}$, N=64 | Ruiz-Verdú 等, 2008 |
| 互补 橙线高法 | Lake Loosdrecht | Landsat 8 OLI | 0.01—329.41 | $R_{\text{rs}}^{\text{orange}} = 2.2861 (\pm 0.1303) R_{\text{rs}}^{\text{pan}} - 0.9467 (\pm 0.0611) R_{\text{rs}}^{\text{green}} - 0.1989 (\pm 0.0712) R_{\text{rs}}^{\text{red}}$ $\text{PC} \propto R_{\text{rs}}^{\text{orange}}$ | RMSE% = 5.39%, N=132 | Castagna 等, 2020 |
| 波段比 | Mississippi impoundments | CAMS | 22.5—1343.8 | $\text{Log}(\text{PC} + 1) = 3.3 - 0.02 \times \frac{\text{Ch3}}{\text{Ch4}}, \frac{\text{orange}}{\text{red}}$ | $R^2=0.35$, SE=0.6, N=24 | Millie, 1992 |
| | Lake Carter | 实测 | 10—530 | $\text{Log}(\text{PC}) = -117.8 - 99.61 \times \left(\frac{R_{647}}{R_{628}} \right)^2 + 218.5 \times \left(\frac{R_{647}}{R_{628}} \right)$ | $R^2=0.62$, SE=30.92, N=80 | Schalles 等, 2000 |
| 波段比 | Lake Erie | Landsat 5 TM Landsat 7 ETM+ | 0.9—5 | $\text{PC} = 47.7 - 9.21 \frac{B_3}{B_1} + 29.7 \frac{B_4}{B_1} - 118 \frac{B_4}{B_3} - 6.81 \frac{B_5}{B_3} + 41.9 \frac{B_7}{B_3} - 14.7 \frac{B_7}{B_4}$ | $R^2=0.77$, N=30 | Vincent 等, 2004 |
| | Barton Broad | CASI-2 | 36.62—138.76 | $\text{Log}(\text{PC}) = 1.29 + 4.12 \times \text{Log} \left(\frac{R_{710}}{R_{620}} \right)$ | $R^2=0.95$, RMSE=11.9 $\mu\text{g}\cdot\text{L}^{-1}$ | Hunter 等, 2008 |
| 波段比 | Laboratory cultured | 实测 | | $\text{PC} = b + a \left(\frac{R_{700}}{R_{600}} \right)$ | $R^2=0.97$, N=79 | Mishra 等, 2009 |
| | Oneida Lake | 实测 | 0.5—5 | $\text{PC} = -1.6 + 6.8 \left(\frac{R_{\text{rs}}(710)}{R_{\text{rs}}(620)} \right)$ | $R^2=0.71$, N=22 | Effler 等, 2012 |
| 波段比 | Funil Reservoir, Catfish Ponds | 实测 | | | $R^2=0.7$, RMSE% = 18.49%, N=5 | Ogashawara 等, 2013 |
| | Spanish | MERIS | 17.1—456.51 | $\text{PC} = 46.478 e^{5.186((B9 - B6)/(B9 + B6))}$ | | Medina-Cobo, 等, 2014 |
| 波段比 | Lake Taihu | 实测 | 158—580 | $\text{PC} = 585.7 \frac{R_{\text{rs}}(709)}{R_{\text{rs}}(620)} - 667.6$ | $R^2=0.75$, N=54 | Chi 等, 2016 |

续表

| 算法 | 研究区 | 数据源 | PC/($\mu\text{g}\cdot\text{L}^{-1}$) | 模型/算法 | 验证精度 | 参考文献 |
|---------------------------|----------------------------------|---|---|--|--|------|
| Daechung Reservoir | 实测无人机 | 0.39—803.01 | PC = $a \frac{R_{\text{rs}}(709)}{R_{\text{rs}}(620)} + b$ | $R^2=0.87\text{--}0.94$, RMSE=14.45 $\mu\text{g}\cdot\text{L}^{-1}$, N=96 | Kwon等, 2020 | |
| Northern New England | Landsat 7 ETM+ Landsat 8 OLI | 10—100, >100 | PC $\propto \frac{\text{NIR}}{\text{Green}} + \frac{\text{NIR}}{\text{Blue}}$ | $R^2=0.86$, RMSE=11.92 $\mu\text{g}\cdot\text{L}^{-1}$, N=305 | Torbick等, 2018 | |
| Sentinel-2 MSI | | 10—1287.96 | PC = $a \frac{B5}{B4} + b$ | $R^2=0.84$, RMSE=40%, N=21 | Sòria-Perpinyà等, 2020 | |
| Lakes in Netherlands | 实测 | 50—200 | PC = $\left(\frac{R_{\text{rs}}(709)}{R_{\text{rs}}(620)} - 0.97 \right) \times 1096.5$ | $R^2=0.21$, RMSE=135.47 $\mu\text{g L}^{-1}$, N=64 | Ruiz-Verdú等, 2008 | |
| Lake Champlain | Landsat 8 OLI | 0—21 | PC = $-2.85 + B1(0.013) + B3(-0.43) + B4(0.76)$ | $R^2=0.83$, RMSE=1.33 $\mu\text{g L}^{-1}$, N=42 | Torbick和Corbiere, 2015 | |
| 波段组合 回归 | Lake Champlain | CHRIS | 0—21 | PC = $6.2 + B2(334.8) + B6(-1644.3) + B8(203.16) + B11(-709.4) + B14(-1324.3)$ | $R^2=0.88$, RMSE=1.02 $\mu\text{g L}^{-1}$ | |
| Lake Champlain | Rapid Eye | 0—21 | PC = $-56.13 + B3(0.12) + B1/B3(9.94)$ | $R^2=0.77$, RMSE=1.52 $\mu\text{g L}^{-1}$ | | |
| Laboratory cultured | CCD | 0—600 | mNDI = $\frac{R_{\text{band1}} - R_{\text{band2}}}{R_{\text{band1}} + R_{\text{band2}} - 2 \times R_{\text{band3}}}$ | $R^2=0.96$, RMSE=23.16 $\mu\text{g L}^{-1}$ | Hmimina等, 2019 | |
| Guarapiranga Reservoir | Landsat 5 TM Landsat 7 ETM+ | 0.5—40 | PC = $\left(A - \left(B \left(\frac{B3}{B1} \right) \right) + \left(C \left(\frac{B4}{B1} \right) \right) - \left(D \left(\frac{B4}{B3} \right) \right) - \left(E \left(\frac{B5}{B3} \right) \right) - \left(F \left(\frac{B7}{B3} \right) \right) - \left(G \left(\frac{B7}{B4} \right) \right) \right)$ Log(PC) = $k_0 + k_1 R_{\text{rs}}(B1) + k_2 R_{\text{rs}}(B2) + k_3 R_{\text{rs}}(B3) + k_4 R_{\text{rs}}(B4) + k_5 R_{\text{rs}} \left(\frac{B4}{B3} \right) + k_6 R_{\text{rs}} \left(\frac{B4}{B2} \right) + k_7 R_{\text{rs}} \left(\frac{B4}{B1} \right) + k_8 R_{\text{rs}} \left(\frac{B3}{B2} \right) + k_9 R_{\text{rs}} \left(\frac{B3}{B1} \right) + k_{10} R_{\text{rs}} \left(\frac{B2}{B1} \right)$ | $R^2=0.96$, N=6 | Ogashawara等, 2013 | |
| 多元线性 回归 | Lake Dianchi | Landsat 5 TM Landsat 7 ETM+ Landsat 8 OLI | 77.6—754.9 | $R^2>0.97$, RMSE<10%, N=14 | Sun等, 2015 | |
| Chao Hu | MODIS | 6.57—4807.72 | PC = $\beta_0 + \beta_1 T_1 + \beta_2 T_2 + \beta_3 T_3 + \beta_4 T_4$ | $R^2=0.6$, RMSE=57%, N=15 | Tao等, 2017 | |
| Taihu Lake, ChaoHu Lake | 实测 MERIS | 3.26—804.11 | PC = $(89.1711 \times B5 - 262.292 \times B6 + 221.193 \times B7 - 1.7065 \times B8 - 26.1116 \times B9 + 0.363418) \times 100\%$ | $R^2=0.72$, RMSE=7.56, N=50 | Jin等, 2017 | |
| Culture ponds, Taihu Lake | 实测 | 77—3032.47 | PC $\propto a_{\text{gaus}}(\lambda)$ $a_{\text{ph}}(\lambda) = \sum_{i=1}^n a_{\text{gus}}(\lambda_i) \exp \left(-0.5 \left(\frac{\lambda - \lambda_i}{\sigma_i} \right)^2 \right)$ σ_i 和 $a_{\text{gus}}(\lambda_i)$ 是第 i 个高斯波段中心波段的宽度和量级 | $R^2=0.94$, RMSE=26%, N=40 | Wang等, 2016 | |
| Lakes in USA | HICO MODIS | 0—200 | | $R^2=0.93$, UPAD=34%, N=56 | Wang等, 2017 | |
| 半分析算 法嵌套波 段比法 | Lake Loosdrecht, Lake IJsselmeer | 21.7—79.8 0.8—64.8 | $a_{\text{pc}}(620) = \left(\left(\frac{R_{\text{rs}}(709)}{R_{\text{rs}}(620)} \right) \times (a_w(709) + b_b) \right) - \left(b_b - a_w(620) \right) \times \delta^{-1} - (\varepsilon \times a_{\text{Chla}}(665))$ [PC] = $a_{\text{pc}}(620)/a_{\text{pc}}^*(620)$ | $R^2=0.94$, RMSE=6.5 $\mu\text{g}\cdot\text{L}^{-1}$, N=34 | Simis等, 2005 | |
| Netherlands | MERIS | | | | Simis等, 2007 | |

续表

| 算法 | 研究区 | 数据源 | PC/($\mu\text{g}\cdot\text{L}^{-1}$) | 模型/算法 | 验证精度 | 参考文献 |
|-------------------|---|---------------------|--|---|---|---------------------------------|
| | Spain, Netherlands | 实测 | 50—200 | 同上 | $R^2=0.92$, RMSE= $47.48 \mu\text{g}\cdot\text{L}^{-1}$, N=56 | Ruiz-Verdú等, 2008 |
| | Geist Reservoir, Morse Reservoir | 实测 | 2.1—185.1 | 同上 | $R^2=0.85$, RMSE= $19.54 \mu\text{g}\cdot\text{L}^{-1}$, N=64 | Randolph等, 2008 |
| | Albufera | MERIS | | 同上 | $R^2=0.99$, RMSE= $28.84 \mu\text{g}\cdot\text{L}^{-1}$, N=38 | Guanter等, 2010 |
| | Valmayor reservoir, Lake Ontario | OCM MERIS | 3.2—200 | 同上 | $R^2=0.75$, RMSE= $36.92 \mu\text{g}\cdot\text{L}^{-1}$, N=62 | Dash等, 2011 |
| | Geist Reservoir, Morse Reservoir Eagle, Creek Reservoir | 实测 | 1.4—146.1 | 同上 同上 | $R^2=0.86$, RMSE%= 31.4%, N=37 | Li等, 2012 |
| | Ge Hu, Dongjiu Hu, Tai Hu | 实测 | 0.09—7.71 | 同上 | $R^2=0.88$, RMSE=0.56 $\mu\text{g}\cdot\text{L}^{-1}$ | Duan等, 2012 |
| | Lake Champlain | Quick Bird MERIS | 4.1—105 | | $R^2=0.68$, N=68 | Wheeler等, 2012 |
| | Lake Taihu | 实测 | | 同上 | $R^2=0.55$, RMSE= $58.89 \mu\text{g}\cdot\text{L}^{-1}$, N=52 | Lyu等, 2013 |
| | Lake Chivero, Lake Manyame | MERIS | 32—114.6 | | | Chawira等, 2013 |
| | Baekje reservoir | AISA | | 同上 | RMSE=14.57 $\mu\text{g}\cdot\text{L}^{-1}$, N=45 | Pyo等, 2018 |
| | Lake Balaton | MERIS | | 同上 | $R^2=0.75$, RMSE= $11.8 \mu\text{g}\cdot\text{L}^{-1}$, N=36 | Riddick等, 2019 |
| | Muttukadu coastal | 实测 HICO | 32.7—273.7 | 同上 | $R^2=0.89$, RMSE= $0.3 \mu\text{g}\cdot\text{L}^{-1}$, N=42 | Varunan 和 Shan- mugam, 2017 |
| | Lake Erie | 实测 | 0.1—5.5 | 同上 | $R^2=0.88$, N=28 | Ortiz等, 2013 |
| 基于吸 收的反 演模型 | Chennai coastal | | $a_{\text{PC}}(620) = a_{\text{ph}}(620) -$ 155.62—222.64 | $\left(\omega \times Chla^{-1} \times \left(\frac{R_{\text{rs}}(620)}{R_{\text{rs}}(652)} \right)^{-1} \times (R_{\text{rs}} 713 - R_{\text{rs}} 652)^{-1} \right)$ | $R^2=0.85$, RMSE=0.1 $\mu\text{g}\cdot\text{L}^{-1}$, N=25 | Varunan 和 Shanmugam, 2017 |
| | Lake Taihu | 实测 | 5—68 | | $R^2=0.76$, SD=12.58, N=20 | Yang等, 2005 |
| 三波段 | Geist Reser- voir, Morse Reservoir, Eagle Creek Reservoir | 实测 | 0.73—370.95 | 同上 | $R^2=0.81$, rRMSE% = 33.60% | Li等, 2015 |
| | Taihu Lake | OLCI | | $a_{\text{PC}}(620) = \frac{\varphi_1 a_{\text{ph}}(620) - a_{\text{ph}}(665)}{\varphi_1 - \varphi_2}$ | $R^2=0.69$, N=148 | Miao等, 2020 |
| | Loskop Dam, Hartbeespoort Dam, Theewa- terskloof Dam | 实测 | 0.5—4.8 | $a_{\text{PC}}(620) = a_{\text{ph}}(620) - 0.24 \times a_{\text{ph}}(665)$ | $R^2=0.95$, RMSE=0.41 $\mu\text{g}\cdot\text{L}^{-1}$ | Matthews等, 2020 |
| | Loch Leven, Esthwaite Water | CASI-2 AISA | 58.1—93.7 5.74—24.9 | $PC = a \left(\frac{1}{R_{\text{rs}}(\lambda_1)} - \frac{1}{R_{\text{rs}}(\lambda_3)} \right) R_{\text{rs}}(\lambda_3) + b$ | $R^2=0.98$, RMSE=3.98 $\mu\text{g}\cdot\text{L}^{-1}$, N=56 | Hunter等, 2010 |
| | Lake Taihu | 实测 | | | | Zhang等, 2015 |
| | Eagle Creek Reservoir | 实测 | 0.7—234.3 | 同上 | $R^2=0.73$, RMSE= 7.31 $\mu\text{g}\cdot\text{L}^{-1}$, N=222 | Song等, 2013 |

续表

| 算法 | 研究区 | 数据源 | PC/($\mu\text{g}\cdot\text{L}^{-1}$) | 模型/算法 | 验证精度 | 参考文献 |
|-------------------|--|-------------------|--|---|---|------------------|
| aquaculture-ponds | 实测 | 68.13—3032.47 | | 同上 | $R^2=0.99$, RMSE=30.70%, N=38 | Mishra 等, 2013 |
| 四波段 | Lake Taihu | 实测 | 0.13—90.96 | $\text{PC} = \left(\frac{1}{R_{\text{rs}}(625)} - \frac{1}{R_{\text{rs}}(650)} \right) \left(\frac{1}{R_{\text{rs}}(730)} - \frac{1}{R_{\text{rs}}(695)} \right)$ | $R^2=0.86$, RMSE=6.8 $\mu\text{g}\cdot\text{L}^{-1}$, N=62 | Le 等, 2011 |
| | Lake Dianchi | 实测 | 0—350 | $\text{PC} = \left(\frac{1}{R_{\text{rs}}(\lambda_1)} - \frac{\eta}{R_{\text{rs}}(\lambda_2)} - \frac{1-\eta}{R_{\text{rs}}(\lambda_3)} \right) R_{\text{rs}}(\lambda_4)$ | $R^2=0.69$, RMSE=27.69 $\mu\text{g}\cdot\text{L}^{-1}$, N=68 | Liu, 2018 |
| 准分析模型 | Lake Erie | MODIS | | QAA | | Becker 等, 2009 |
| | Culture ponds | 实测 | 68.13—3032.47 | QAA | RMSE%=10.06%, N=44 | Mishra 等, 2013 |
| 机器学习算法 | Morse Reservoir | 实测 AISA | 1.4—371.0 | 遗传算法(GA) | $R^2=0.88$, RMSE=18.6 $\mu\text{g}\cdot\text{L}^{-1}$, N=61 | Song 等, 2012a |
| | Lake Taihu, Lake Chaohu, Lake Dianchi | 实测 | | 支持向量机(SVR Machine) | $R^2=0.9$, RMSE=53.1 $\mu\text{g}\cdot\text{L}^{-1}$, N=824 | Sun 等, 2013 |
| 衍生算法光谱形状 | Lake Alexandrina, Eagle Creek Reservoir | 实测 | 0.3—220.7 | 偏最小二乘—神经网络(PLS-ANN) | $R^2=0.92$, RMSE=15.24 $\mu\text{g}\cdot\text{L}^{-1}$, N=376 | Song 等, 2014 |
| | Geum River | Aisa FENIX | | 人工神经网络(ANN) | | Park 等, 2017 |
| 机器学习算法 | Baekje Reservoir | 实测 AISA | 0.02—280.87 | 叠堆自编码神经网络(SAE-DNN) | $R^2=0.87$, RMSE=14.45 $\mu\text{g}\cdot\text{L}^{-1}$ | Yim 等, 2020 |
| | Baekje Reservoir | 实测 AISA | 0.19—150.9 | 卷积神经网络(CNN) | $R^2=0.86$, RMSE<10, N=45 | Pyo 等, 2019 |
| 衍生算法光谱形状 | Meramec River, Carlye Lake, Lake Decatur | 实测 | 0.1—6 | 多元线性回归(MLR) 偏最小二乘(PLSR) 高斯函数 | $R^2=0.78$, RMSE=1.586 $\mu\text{g}\cdot\text{L}^{-1}$, N=60 $R^2=0.96$, RMSE=0.92 $\mu\text{g}\cdot\text{L}^{-1}$ $R^2=0.97$, RMSE=0.886 $\mu\text{g}\cdot\text{L}^{-1}$ | Peterson 等, 2019 |
| | Baekje Reservoir | 实测 AISA | 0.19—146.9 | 支持向量机(SVR) 极端机器学习(ELR) | $R^2=0.96$, RMSE=0.79 $\mu\text{g}\cdot\text{L}^{-1}$ $R^2=0.97$, RMSE=0.86 $\mu\text{g}\cdot\text{L}^{-1}$ | Pyo 等, 2020 |
| PCI 指数 | Michigan lake, Huron Lake, Bear Lake | 实测 | | $\text{SS}(\lambda) = \text{reflect}(\lambda) - \text{reflect}(\lambda^-) - (\text{reflect}(\lambda^+) - \text{reflect}(\lambda^-)) \times \frac{(\lambda - \lambda^-)}{\lambda^+ - \lambda^-}$ | | Wynne 等, 2008 |
| | Lake Erie | MERIS | | | | Wynne 等, 2010 |
| PCI 指数 | Lake Erie | 实测 | 0—514.2 | | | Sayers 等, 2019 |
| | Taihu Lake | MERIS | 1—300 | $\text{PCI} = R'_{\text{rs}}(620) - R_{\text{rs}}(620)$ $R'_{\text{rs}}(620) = R_{\text{rs}}(560) + \frac{620 - 560}{665 - 560} \times (R_{\text{rs}}(665) - R_{\text{rs}}(560))$ | $R^2=0.79$, RMSE%=58%, N=37 | Qi 等, 2014 |
| | Pinto Lake, Kelly Lake, UCSB Lagoon | 实测 HICO MASTER | 12.8—156.7, 0—261.5 | | $R^2=0.24$, N=20 | Kudela 等, 2015 |

除了波段比使用较多外, 由 Dekker (1993) 提出的基线法, 也经常用于 PC 遥感反演, Ruiz-Verdú 等人在西班牙荷兰水体中, 对比了基线法和 Simis 嵌套法对 PC 反演的效果, 两个算法都取得较高精度, Simis 嵌套法精度更高一些 (Ruiz-Verdú 等, 2008)。另外, Castagna 等 (2020) 基于 Landsat 8 OLI 互补色橙线高算法, 成功反演 PC 浓度。Tao 等 (2017) 基于 MODIS 影像, 利用多元线性回归, 成功地反演了中国巢湖 PC 浓度。Sun 等 (2015) 在中国巢湖, 基于 Landsat 系列卫星, 利用可见光、近红外及两者之比, 进行多元线性回归, 成功反演 PC 浓度。除这些算法外, 还有高斯函数 (Wang 等, 2016, 2017), 正交函数 (Soja-Woźniak 等, 2017), 波段差 (Beck 等, 2017) 等经验算法用于 PC 浓度的遥感估算。

5.2 半分析算法

为了克服上述经验算法的缺点, 近年来基于水体固有光学特性 (IOPs) 结合一些经验关系及水体辐射传输理论, 提出的半分析方法受到更多关注。一般的, 半分析算法包括: 三波段算法、四波段算法、嵌套波段比算法、准分析算法 (QAA)、衍生算法 (光谱形状算法 SS) 等。这些算法主要致力于解决以下 3 个问题: 大气校正、620 nm 处藻类吸收的分解和足够的光谱分辨率 (Yan 等, 2018)。未来的半分析算法将致力于最小化其他色素对 PC 反演的影响。

嵌套波段比算法最早由 Simis 等 (2005) 开发出来, 此算法基于 3 个假设: 第一, $a_{\text{ph}}(\lambda) = a_{\text{Chla}}(\lambda) + a_{\text{PC}}(\lambda)$; 第二, 固定 $a_{\text{Chla}}(665)$ 对 $a_{\text{Chla}}(620)$ 的贡献; 第三, 固定单位吸收 $a_{\text{PC}}^*(620)$ 的值, 此算法在其特定研究区内, 反演精度很高。然而, 在其他研究区, 第二和第三假设引起的误差较大, 因为这两个值都不是固定的, 是随地域和时间变异的。后来, 以此算法为基础的各种变体算法被广泛用于各个地区的 PC 反演研究。其中, Randolph 等 (2008) 将算法的 $a_{\text{PC}}^*(620)$ 更改为 0.007, 应用于美国印第安那州的 3 个富营养化的水库, 取得很好的反演精度。Duan 等 (2012) 和 Yin 等 (2011) 将此算法应用于中国太湖, 取得较高反演精度。Wheeler 等 (2012) 则是将此算法应用到法国 Champlain 湖, 利用 Quick Bird 和 MERIS 数据, 获得良好的反演精度。Lyu 等 (2013) 是以

高度富营养化的太湖为研究对象, 改进了算法中两个系数, 并用非线性幂函数来代替固定的 $a_{\text{PC}}^*(620)$, 并阐述了总悬浮颗粒物 (TSM) 对反演结果的影响。Chawira 等 (2013) 和 Zhang 等 (2015) 利用此算法, 基于 MERIS 数据分别对非洲津巴布韦和美国大部分湖泊进行了 PC 反演。除嵌套波段比算法, 一些从遥感反射率估算 $a_{\text{PC}}(620)$ 的半分析算法不断涌现 (Li 等, 2015; Matthews 等, 2020; Miao 等, 2020)。这些算法主要是从总吸收中分离出 PC 在 620 nm 的吸收, 消除了 Chla、CDOM 和非 PC 物质的干扰。另一种是基于准分析模型 (QAA) 来分离各组分的吸收系数, 将 QAA 算法的波段修改后, 应用于 $a_{\text{PC}}(620)$ 的估算, 修改的算法成功的从总藻类吸收中分离出 $a_{\text{PC}}(620)$ 。该算法的优点在于没有忽略 CDOM 和非藻类颗粒物吸收的贡献 (Mishra 等, 2013; Lee 等, 2002)。

三波段和四波段算法最早被发明用与 Chla 的遥感反演研究。Hunter 等 (2010) 将算法中的 Chla 特征吸收波段更改为 PC 特征吸收波段, 第一次将此算法引入到 PC 遥感反演研究中, 并获得较高的反演精度。后来 Song 等 (2012a) 对比了三波段和波段比模型对 PC 反演的效果, 发现三波段算法优于波段比算法。Le 等 (2011) 是将算法中的 Chla 特征吸收波段更改为 PC 特征吸收波段, 第一次将四波段算法引入到 PC 遥感反演研究中, 随后 Liu 等 (2018) 将修改后的四波段算法应用滇池。

QAA 算法最早由 Lee 等 (2002) 提出, 其优点是基于表观光学量 AOPs 和经验关系, 将水体中 3 大光学活性物质 CDOM、藻类、非藻类颗粒物在总吸收的贡献中分解成每个独立的变量, 最后, 依据各物质吸收系数实现其浓度的定量反演。QAA 算法可以最大程度的减少各物质间的干扰, 但需要大量实测数据。QAA 算法多用于 3 大光学活性物质定量遥感反演, 很少应用于 PC 遥感反演。Becker 等 (2009) 和 Mishra 等 (2013) 将 QAA 算法中相关波段修改成 PC 特征波段, 分别基于 MODIS 和实测高光谱数据, 实现了 PC 遥感估算。

5.3 衍生算法

衍生算法最早由 Wynne 等 (2008) 提出, 又叫做光谱形状算法 SS (λ), 此算法是基于光谱曲线中 PC 特征吸收谷和其他峰或谷的位置形成特定

的光谱形状, 可用波段有 620 nm、560 nm、654 nm、681 nm、714 nm 等。Wynne 等 (2008) 和 Wynne 等 (2010) 基于实测光谱数据和 MERIS 影像, 利用 SS (681) 算法对美国密歇根湖和伊利湖 PC 浓度进行遥感估算。Qi 等 (2014) 将其修改的光谱形状算法称之为 PCI 指数基于实测光谱, 在太湖 PC 遥感反演中取得较好精度, 随后 PCI 指数多次被用于 PC 遥感估算 (Kudela 等, 2015; Sayers 等, 2019)。

5.4 基于机器学习的算法

近年来, 随着计算机技术的迅速发展, 遥感反演研究算法开发越来越依赖计算机, 以期获得高精度反演结果。机器学习是一门多领域交叉学科, 涉及概率论、统计学、逼近论、凸分析、算法复杂度理论等多门学科。他是人工智能的核心, 在全球人工智能浪潮的背景下, 遥感算法开发也融入了机器学习算法, 先后出现了遗传算法 (Song 等, 2012b)、支持向量机算法 (Sun 等, 2013)、人工神经网络算法 (Park 等, 2017; Song 等, 2014)、堆叠自编码算法 (Yim 等, 2020)、机器学习 (Peterson 等, 2019; Pyo 等, 2020)。尤其是近两年, 机器学习算法大量地出现在 PC 遥感反演研究中, 与上述几种算法相比, 这类算法遥感估算精度很高, $R^2 > 0.88$, RMSE 较低, 且其适用多种数据源。但是, 这类算法过多地依赖数理分析, 缺少与水体固有光学特性和表观光学特性关联的机理研究。所以, 未来 PC 算法的发展还是会以机理研究为主, 机器学习为辅。

5.5 间接估算方法

上述反演算法多数是利用遥感反射率数据或影像直接与实测 PC 浓度建立关系, 然而一些利用中间桥梁, 如浊度、漫衰减系数 K_d , 经二步法间接实现 PC 遥感估算的方法也鲜有报道。Gitelson 发现 PC 浓度与 K_d 值相关性很好 (Gitelson 等, 1995), 虽然文中并没有利用这个关系反演 PC 浓度, 但这一发现为未来间接反演 PC 奠定了基础。另外, Richard Beck 研究发现, PC 浓度与浊度的关系为良好的正相关关系, 并借助浊度与遥感反射率的关系, 成功反演了 PC 浓度 (Beck 等, 2019)。

6 卫星传感器

PC 遥感反演算法开发的最终目的是可以将这

些算法成功地应用到卫星影像上, 以期进行水体中 PC 浓度在时间空间的遥感估算, 为相关部门水质监管提供技术支撑。目前, PC 反演算法的开发、验证多使用实测高光谱数据或航空影像 (CASI-2、AISA Eagle), 然而, 为满足一定空间和频次上的 PC 浓度分布需要, 多使用卫星影像数据源。首先, 对于多光谱卫星数据, 只有 MERIS、Sentinel-3 OLCI 影像数据具有 PC 敏感波段, 是应用于 PC 遥感反演研究最多的数据源。对于一些不具备 PC 敏感波段的传感器, 如 Landsat 系列、MODIS 等, 则可以通过构建多参数模型算法来弥补其波段设置的缺点。除多光谱传感器外, 高光谱卫星影像数据 (如 Hyperion、HICO) 也被用于 PC 空间反演研究中。

6.1 Landsat 系列数据

Landsat 数据具有较高的空间分辨率 (30 m) 和较长时间跨度 (1980 年代), 但其波段设置没有覆盖 PC 特征吸收波段 (620 nm)。尽管如此, 一些研究者仍然开发了一些巧妙的算法利用 Landsat 数据, 成功进行 PC 反演制图。Vincent 等 (2004) 等利用 Landsat 5 TM, Landsat 7 ETM+, 结合多个波段比线性回归算法 B3/B1、B4/B1、B4/B3、B5/B3、B7/B3、B7/B4 对美国伊利湖 PC 浓度进行反演并制图, 适用于 PC 浓度范围为 $0.9\text{--}5 \mu\text{g}\cdot\text{L}^{-1}$ 。Torbick 等 (2018) 利用 Landsat 7 ETM+ 数据和 Landsat 8 OLI 数据, 结合 NIR/green 和 NIR/blue 波段比回归模型对英格兰北部湖泊 PC 含量进行反演并制图 (Torbick 等, 2018)。Sun 等 (2015) 利用相同的方法在滇池进行了 PC 浓度制图。最有趣的是, Castagna 等 (2020) 利用 Landsat 8 OLI 波段互补色与 PC 浓度建立关系, 提出橙线高 Orange Line Height (OLH) 算法, 成功的反演 PC 浓度。

6.2 MERIS/Sentinel 3 OLCI 数据

MERIS 影像数据具有 300 m 空间分辨率, 2—3 d 的重访周期, 15 个波段设置, 较高的信噪比。对比于其他卫星, MERIS 数据在 615—905 nm 具有更多的波段, 这个区域覆盖了多个反射率特征用于 PC 遥感估算。大多数研究使用 MERIS 数据进行 PC 反演, 已经证明其良好的辐射、空间、时间、光谱分辨率。Simis 等 (2005) 基于 MERIS 影像数据结合嵌套波段比算法, 获得较高 PC 反演精度。

Guanter 等 (2010) 基于 MERIS 影像数据结合嵌套波段比算法, 对欧洲 75 个湖泊的 PC 浓度进行遥感估算。Wynne 等 (2010) 基于 MERIS 数据, 利用光谱形状算法, 对伊利湖进行了 PC 浓度遥感估算。不幸的是, MERIS 数据在 2012 年停止提供, 但欧空局的 Sentinel-3 OLCI 数据继承了 MERIS 数据的配置和优点, 继续被用于 PC 遥感反演研究。Miao (2020) 基于 OLCI 影像结合半分析算法, 反演太湖、巢湖 PC 浓度。Song 等 (2013) 利用实测光谱数据模拟 OLCI 波段, 采用三波段算法, 很好的估算了 PC 浓度。Beck 等 (2019) 利用同一套数据对比了多个传感器, WorldView-2/3、Sentinel-2 MSI、Landsat 8 OLI、MODIS、MERIS、OLCI 对 PC 估算的能力, 结果表明, 相比于其他传感器, OLCI 具有与 MERIS 一样的高精度。OLCI 数据也被用于其他卫星传感器反演结果的验证 (Castagna 等, 2020)。

6.3 MODIS 数据

MODIS 数据具有 2 景/d 影像的高重访时间, 前两个波段具有相对高的空间分辨率 250 m, 然而 MODIS 波段设置没有覆盖 PC 特征吸收波段。基于这个特点, 大多数利用 MODIS 数据进行 PC 反演的研究, 通常使用经验算法, 如多项式拟合, 多元线性回归 (Tao 等, 2017), 高斯函数 (Wang 等, 2017) 等。

7 结语

本综述通过文献计量方法, 从多角度系统地对当前藻蓝蛋白光学特性 (吸收特性和反射特性)、反演算法、与其他水质参数的关系、多源遥感影像应用的研究、发展趋势及取得的新成果进行了梳理。结果表明, PC 的光学特性随营养等级、季节、空间变异。目前已开发了多种 PC 反演算法, 包括经验模型, 半分析模型、生物光学模型等, 应用多种遥感数据源对水体进行了 PC 空间反演, 对富营养化水体蓝藻生物量估算、水环境检测与保护具有重要意义。本综述注重对 PC 光学性质、反演算法开发和验证、影响因素分析的梳理, 并指出当前研究的难点和未来的发展方向。在研究难点方面, 首先, PC 的萃取测试方法无统一标准, 导致多个报道中实测 PC 浓度无法进行对比和引用, 使得基于文献收集的最大尺度, 例如全国尺度、或

全球尺度的 PC 遥感反演建模难以建立, 另外, PC 光谱信号弱, 易受大气和其他光学活性物质的干扰。PC: Chla 比值作为蓝藻在总藻中的相对比例, 是对 PC 估算干扰最大的因素 (Hunter 等, 2008; Li 等, 2015; Simis 等, 2005)。另外, 由于非藻类颗粒物后向散射可以掩盖 PC 光谱信号, 所以 PC: TSM 比值是对 PC 估算干扰的第二大因素。有些报道称, 根据 Chla、TSM 取值范围, 对水体进行分类后, 再反演 PC, 可以有效消除二者的干扰 (郭一洋等, 2016)。因此, 合理处理这些干扰因素, 正是准确反演 PC 的关键。

基于上述分析, PC 遥感反演未来的发展方向, 归纳为以下几个方面: (1) 在 PC 萃取测试方面, 急需一个国际通用标准化方法; (2) 算法的发展, 坚持与固有光学量相关的机理研究, 并融合机器学习算法, 以期带来较高反演精度; (3) 研究区水体在空间、时间尺度上的发展, 未来会向着更大地理空间尺度, 更长时间序列历史追溯和未来预测方向发展; 四是在应用方面的扩展, PC 遥感反演不仅局限于蓝藻生物量的定量估算, 未来将更多的与藻毒素、相关疾病等建立关系, 实现基于遥感的水体风险因子评级体系。

志 谢 此论文感谢温志丹副研究员、刘阁副研究员、尚盈辛特别研究助理等老师们在文章写作构思上的指导和帮助, 同时还感谢陶慧、王翔、蒲静、王强、侯俊斌、徐世琦、陈方方等同学们在数据查找收集过程中的帮助。

参考文献(References)

- Ahn C Y, Joung S H, Yoon S K and Oh H M. 2007. Alternative alert system for cyanobacterial bloom, using phycocyanin as a level determinant. *Journal of Microbiology*, 45(2): 98-104]
- Beck R, Xu M, Zhan S G, Johansen R, Liu H X, Tong S S N, Yang B, Shu S, Wu Q S, Wang S J, Berling K, Murray A, Emery E, Reif M, Harwood J, Young J, Nielson C, Macke D, Martin M, Stillings G, Stumpf R, Su H B, Ye Z X and Huang Y. 2019. Comparison of satellite reflectance algorithms for estimating turbidity and cyanobacterial concentrations in productive freshwaters using hyperspectral aircraft imagery and dense coincident surface observations. *Journal of Great Lakes Research*, 45(3): 413-433 [DOI: 10.1016/j.jglr.2018.09.001]
- Beck R, Xu M, Zhan S G, Liu H X, Johansen R A, Tong S S N, Yang B, Shu S, Wu Q S, Wang S J, Berling K, Murray A, Emery E, Re-

- if M, Harwood J, Young J, Martin M, Stillings G, Stumpf R, Su H B, Ye Z X and Huang Y. 2017. Comparison of satellite reflectance algorithms for estimating phycocyanin values and cyanobacterial total biovolume in a temperate reservoir using coincident hyperspectral aircraft imagery and dense coincident surface observations. *Remote Sensing*, 9(6): 538 [DOI: 10.3390/rs9060538]
- Becker R H, Sultan M I, Boyer G L, Twiss M R and Konopko E. 2009. Mapping cyanobacterial blooms in the Great Lakes using MODIS. *Journal of Great Lakes Research*, 35(3): 447-453 [DOI: 10.1016/j.jglr.2009.05.007]
- Bennett A and Bogorad L. 1973. Complementary chromatic adaptation in a filamentous blue-green-alga. *Journal of Cell Biology*, 58(2): 419-435 [DOI: 10.1083/jcb.58.2.419]
- Castagna A, Simis S, Dierssen H, Vanhellemont Q, Sabbe K and Vyverman W. 2020. Extending Landsat 8: retrieval of an orange *contra-band* for inland water quality applications. *Remote Sensing*, 12(4): 637 [DOI: 10.3390/rs12040637]
- Chawira M, Dube T and Gumindoga W. 2013. Remote sensing based water quality monitoring in Chivero and Manyame lakes of Zimbabwe. *Physics and Chemistry of the Earth, Parts A/B/C*, 66: 38-44 [DOI: 10.1016/j.pce.2013.09.003]
- Chi G Y, Ma J, Shi Y and Chen X. 2016. Hyperspectral remote sensing of cyanobacterial pigments as indicators of the iron nutritional status of cyanobacteria-dominant algal blooms in eutrophic lakes. *Ecological Indicators*, 71: 609-617 [DOI: 10.1016/j.ecolind.2016.06.014]
- Dash P, Walker N D, Mishra D R, Hu C M, Pinckney J L and D'Sa E J. 2011. Estimation of cyanobacterial pigments in a freshwater lake using OCM satellite data. *Remote Sensing of Environment*, 115(12): 3409-3423 [DOI: 10.1016/j.rse.2011.08. (Dekker A G, Malthus T J and Seyhan E. 1991. Quantitative modeling of inland water quality for high-resolution MSS systems. *IEEE Transactions on Geoscience and Remote Sensing*, 29(1): 89-95) [DOI: 10.1109/36.103296]
- Dekker A G. 1993. Detection of Optical Water Quality Parameters for Eutrophic Waters by High Resolution Remote Sensing. Amsterdam: Vrije Universiteit Amsterdam
- Duan H T, Ma R H and Hu C M. 2012. Evaluation of remote sensing algorithms for cyanobacterial pigment retrievals during spring bloom formation in several lakes of East China. *Remote Sensing of Environment*, 126: 126-135 [DOI: 10.1016/j.rse.2012.08.011]
- Duan H T, Tao M, Loiselle S A, Zhao W, Cao Z G, Ma R H and Tang X X. 2017. MODIS observations of cyanobacterial risks in a eutrophic lake: implications for long-term safety evaluation in drinking-water source. *Water Research*, 122: 455-470 [DOI: 10.1016/j.watres.2017.06.022]
- Effler S W, Strait C M, Perkins M G and O'Donnell D M. 2012. Optical characterization and tests of closure for Oneida Lake, New York, USA. *Inland Waters*, 2(4): 211-228 [DOI: 10.5268/iw-2.4.503]
- Gitelson A A, Laorawat S, Keydan G P and Vonshak A. 1995. Optical properties of dense algal cultures outdoors and their application to remote estimation of biomass and pigment concentration in *Spirulina platensis* (cyanobacteria). *Journal of Phycology*, 31(5): 828-834 [DOI: 10.1111/j.0022-3646.1995.00828.x]
- Gordon H R, Clark D K, Mueller J L and Hovis W A. 1980. Phytoplankton pigments from the nimbus-7 coastal zone color scanner: comparisons with surface measurements. *Science*, 210(4465): 63-66 [DOI: 10.1126/science.210.4465.63]
- Guanter L, Ruiz-Verdú A, Odermatt D, Giardino C, Simis S, Estellés V, Heege T, Antonio Domínguez-Gómez J and Moreno J. 2010. Atmospheric correction of ENVISAT/MERIS data over inland waters: validation for European lakes. *Remote Sensing of Environment*, 114(3): 467-480 [DOI: 10.1016/j.rse.2009.10.004]
- Guo Y Y, Zhu L, Wu C Q, Li J S and Zhang F F. 2016. The retrieval of phycocyanin concentrations in Taihu Lake based on water reflectance spectra classification. *Acta Scientiae Circumstantiae*, 36(8): 2905-2910 (郭一洋, 朱利, 吴传庆, 李俊生, 张方方. 2016. 基于水面反射率光谱分类的太湖藻蓝蛋白浓度反演. 环境科学学报, 36(8): 2905-2910) [DOI: 10.13671/j.hjkxxb.2015.0740]
- Hmimina G, Hulot F D, Humbert J F, Quiblier C, Tambosco K, Lemaire B J, Vinçon-Leite B, Audebert L and Soudani K. 2019. Linking phytoplankton pigment composition and optical properties: a framework for developing remote-sensing metrics for monitoring cyanobacteria. *Water Research*, 148: 504-514 [DOI: 10.1016/j.watres.2018.09.055]
- Hunter P D, Tyler A N, Carvalho L, Codd G A and Maberly S C. 2010. Hyperspectral remote sensing of cyanobacterial pigments as indicators for cell populations and toxins in eutrophic lakes. *Remote Sensing of Environment*, 114(11): 2705-2718 [DOI: 10.1016/j.rse.2010.06.006]
- Hunter P D, Tyler A N, Willby N J and Gilvear D J. 2008. The spatial dynamics of vertical migration by *Microcystis aeruginosa* in a eutrophic shallow lake: a case study using high spatial resolution time-series airborne remote sensing. *Limnology and Oceanography*, 53(6): 2391-2406 [DOI: 10.4319/lo.2008.53.6.2391]
- Jin Q, Lyu H, Shi L, Miao S, Wu Z M, Li Y M and Wang Q. 2017. Developing a two-step method for retrieving cyanobacteria abundance from inland eutrophic lakes using MERIS data. *Ecological Indicators* 81: 543-554 [DOI: 10.1016/j.ecolind.2017.06.027]
- Jupp D L B, Kirk J T O and Harris G P. 1994. Detection, identification and mapping of cyanobacteria-using remote sensing to measure the optical quality of turbid inland waters. *Australian Journal of Marine and Freshwater Research*, 45(5): 801-828 [DOI: 10.1071/mf9940801]
- Kudela R M, Palacios S L, Austerberry D C, Accorsi E K, Guild L S and Torres-Perez J. 2015. Application of hyperspectral remote sensing to cyanobacterial blooms in inland waters. *Remote Sensing of Environment*, 167: 196-205 [DOI: 10.1016/j.rse.2015.01.025]
- Kwon Y S, Pyo J, Kwon Y H, Duan H T, Cho K H and Park Y. 2020.

- Drone-based hyperspectral remote sensing of cyanobacteria using vertical cumulative pigment concentration in a deep reservoir. *Remote Sensing of Environment*, 236: 111517 [DOI: 10.1016/j.rse.2019.111517]
- Le C F, Li Y M, Zha Y, Wang Q, Zhang H and Yin B. 2011. Remote sensing of phycocyanin pigment in highly turbid inland waters in Lake Taihu, China. *International Journal of Remote Sensing*, 32(23): 8253-8269 [DOI: 10.1080/01431161.2010.533210]
- Lee Z P, Carder K L and Arnone R A. 2002. Deriving inherent optical properties from water color: a multiband quasi-analytical algorithm for optically deep waters. *Applied Optics*, 41(27): 5755-5772 [DOI: 10.1364/ao.41.005755]
- Li L, Sengpiel R E, Pascual D L, Tedesco L P, Wilson J S and Soyeux E. 2010. Using hyperspectral remote sensing to estimate chlorophyll-*a* and phycocyanin in a mesotrophic reservoir. *International Journal of Remote Sensing*, 31(15): 4147-4162 [DOI: 10.1080/01431161003789549]
- Li L H, Li L, Shi K, Li Z C and Song K S. 2012. A semi-analytical algorithm for remote estimation of phycocyanin in inland waters. *Science of the Total Environment*, 435-436: 141-150 [DOI: 10.1016/j.scitotenv.2012.07.023]
- Li L H, Li L and Song K S. 2015. Remote sensing of freshwater cyanobacteria: an extended IOP Inversion Model of Inland Waters (IIMIW) for partitioning absorption coefficient and estimating phycocyanin. *Remote Sensing of Environment*, 157: 9-23 [DOI: 10.1016/j.rse.2014.06.009]
- Liu G, Simis S G H, Li L, Wang Q, Li Y M, Song K S, Lyu H, Zheng Z B and Shi K. 2018. A four-band semi-analytical model for estimating phycocyanin in inland waters from simulated MERIS and OLCI data. *IEEE Transactions on Geoscience and Remote Sensing*, 56(3): 1374-1385 [DOI: 10.1109/tgrs.2017.2761996]
- Lyu H, Wang Q, Wu C Q, Zhu L, Yin B, Li Y M and Huang J Z. 2013. Retrieval of phycocyanin concentration from remote-sensing reflectance using a semi-analytic model in eutrophic lakes. *Ecological Informatics*, 18: 178-187 [DOI: 10.1016/j.ecoinf.2013.09.002]
- Matthews M W, Bernard S, Evers-King H and Lain L R. 2020. Distinguishing cyanobacteria from algae in optically complex inland waters using a hyperspectral radiative transfer inversion algorithm. *Remote Sensing of Environment*, 248: 111981 [DOI: 10.1016/j.rse.2020.111981]
- Matthews M W, Bernard S and Winter K. 2010. Remote sensing of cyanobacteria-dominant algal blooms and water quality parameters in Zeekoevlei, a small hypertrophic lake, using MERIS. *Remote Sensing of Environment*, 114(9): 2070-2087 [DOI: 10.1016/j.rse.2010.04.013]
- Medina-Cobo M, Domínguez J A, Quesada A and de Hoyos C. 2014. Estimation of cyanobacteria biovolume in water reservoirs by MERIS sensor. *Water Research*, 63: 10-20 [DOI: 10.1016/j.watres.2014.06.001]
- Miao S, Li Y Y, Wu Z M, Lyu H, Li Y M, Bi S, Xu J, Lei S H, Mu M and Wang Q. 2020. A semianalytical algorithm for mapping proportion of cyanobacterial biomass in Eutrophic Inland Lakes based on OLCI data. *IEEE Transactions on Geoscience and Remote Sensing*, 58(7): 5148-5161 [DOI: 10.1109/tgrs.2020.2973400]
- Millie D F, Baker M C, Tucker C S, Vinyard B T and Dionigi C P. 1992. High-resolution airborne remote sensing of bloom-forming phytoplankton. *Journal of Phycology*, 28(3): 281-290 [DOI: 10.1111/j.0022-3646.1992.00281.x]
- Mishra S, Mishra D R, Lee Z and Tucker C S. 2013. Quantifying cyanobacterial phycocyanin concentration in turbid productive waters: a quasi-analytical approach. *Remote Sensing of Environment*, 133: 141-151 [DOI: 10.1016/j.rse.2013.02.004]
- Mishra S, Mishra D R and Schluchter W M. 2009. A novel algorithm for predicting phycocyanin concentrations in cyanobacteria: a proximal hyperspectral remote sensing approach. *Remote Sensing*, 1(4): 758-775 [DOI: 10.3390/rs1040758]
- Ogashawara I. 2020. Determination of phycocyanin from space-a bibliometric analysis. *Remote Sensing*, 12(3): 567 [DOI: 10.3390/rs12030567]
- Ogashawara I, Mishra D R, Mishra S, Curtarelli M P and Stech J L. 2013. A performance review of reflectance based algorithms for predicting phycocyanin concentrations in inland waters. *Remote Sensing*, 5(10): 4774-4798 [DOI: 10.3390/rs5104774]
- Ortiz J D, Witter D L, Ali K A, Fela N, Duff M and Mills L. 2013. Evaluating multiple colour-producing agents in Case II waters from Lake Erie. *International Journal of Remote Sensing*, 34(24): 8854-8880 [DOI: 10.1080/01431161.2013.853892]
- Park Y, Pyo J, Kwon Y S, Cha Y, Lee H, Kang T and Cho K H. 2017. Evaluating physico-chemical influences on cyanobacterial blooms using hyperspectral images in inland water, Korea. *Water Research*, 126: 319-328 [DOI: 10.1016/j.watres.2017.09.026]
- Peterson K T, Sagan V, Sidike P, Hasenmueller E A, Sloan J J and Knouft J H. 2019. Machine learning-based ensemble prediction of water-quality variables using feature-level and decision-level fusion with proximal remote sensing. *Photogrammetric Engineering and Remote Sensing*, 85(4): 269-280 [DOI: 10.14358/pers.85.4.269]
- Pyo J C, Duan H T, Baek S, Kim M S, Jeon T, Kwon Y S, Lee H and Cho K H. 2019. A convolutional neural network regression for quantifying cyanobacteria using hyperspectral imagery. *Remote Sensing of Environment*, 233: 111350 [DOI: 10.1016/j.rse.2019.111350]
- Pyo J C, Duan H T, Ligaray M, Kim M, Baek S, Kwon Y S, Lee H, Kang T, Kim K, Cha Y K and Cho K H. 2020. An integrative remote sensing application of stacked autoencoder for atmospheric correction and cyanobacteria estimation using hyperspectral imagery. *Remote Sensing*, 12(7): 1073 [DOI: 10.3390/rs12071073]
- Pyo J C, Ligaray M, Kwon Y S, Ahn M H, Kim K, Lee H, Kang T, Cho S B, Park Y and Cho K H. 2018. High-Spatial Resolution Monitoring of Phycocyanin and Chlorophyll-*a* Using Airborne Hyperspectral Imagery. *Remote Sensing*, 10(8): 1180 [DOI: 10.3390/rs10081180]
- Pyo J C, Pachepsky Y, Baek S S, Kwon Y S, Kim M J, Lee H, Park S, Cha Y, Ha R, Nam G, Park Y and Cho K H. 2017. Optimizing

- semi-analytical algorithms for estimating *Chlorophyll-a* and *Phycocyanin* concentrations in inland waters in Korea. *Remote Sensing*, 9(6): 542 [DOI: 10.3390/rs9060542]
- Qi L, Hu C M, Duan H T, Cannizzaro J and Ma R H. 2014. A novel MERIS algorithm to derive cyanobacterial phycocyanin pigment concentrations in a eutrophic lake: theoretical basis and practical considerations. *Remote Sensing of Environment*, 154: 298-317 [DOI: 10.1016/j.rse.2014.08.026]
- Randolph K, Wilson J, Tedesco L, Li L, Pascual D L and Soyeux E. 2008. Hyperspectral remote sensing of cyanobacteria in turbid productive water using optically active pigments, chlorophyll *a* and phycocyanin. *Remote Sensing of Environment*, 112(11): 4009-4019 [DOI: 10.1016/j.rse.2008.06.002]
- Riddick C A L, Hunter P D, Dominguez Gomez J A, Martinez-Vicente V, Presing M, Horvath H, Kovacs A W, Voros L, Zsigmond E and Tyler A N. 2019. Optimal Cyanobacterial Pigment Retrieval from Ocean Colour Sensors in a Highly Turbid, Optically Complex Lake. 11(13): 1613 [10.3390/rs11131613]
- Ruiz-Verdú A, Simis S G H, de Hoyos C, Gons H J and Peña-Martínez R. 2008. An evaluation of algorithms for the remote sensing of cyanobacterial biomass. *Remote Sensing of Environment*, 112(11): 3996-4008 [DOI: 10.1016/j.rse.2007.11.019]
- Sarada R, Pillai M G and Ravishankar G A. 1999. Phycocyanin from *Spirulina* sp: influence of processing of biomass on phycocyanin yield, analysis of efficacy of extraction methods and stability studies on phycocyanin. *Process Biochemistry*, 34(8): 795-801 [DOI: 10.1016/s0032-9592(98)00153-8]
- Sayers M J, Bosse K R, Shuchman R A, Ruberg S A, Fahnstiel G L, Leshkevich G A, Stuart D G, Johengen T H, Burtner A M and Paladino D. 2019. Spatial and temporal variability of inherent and apparent optical properties in western Lake Erie: implications for water quality remote sensing. *Journal of Great Lakes Research*, 45(3): 490-507 [DOI: 10.1016/j.jglr.2019.03.011]
- Schalles J F and Yacobi Y Z. 2000. Remote detection and seasonal patterns of phycocyanin, carotenoid and chlorophyll pigments in eutrophic waters. *Limnology and Lake Management : Arch. Hydrobiol. Spec. Issues Advanc. Limnol.* 55 : 153-168 (Seppälä J, Ylöstalo P, Kaitala S, Hällfors S, Raateoja M and Maunula P. 2007. Ship-of-opportunity based phycocyanin fluorescence monitoring of the filamentous cyanobacteria bloom dynamics in the Baltic Sea. *Estuarine, Coastal and Shelf Science*, 73(3/4): 489-500) [DOI: 10.1016/j.ecss.2007.02.015]
- Shi K, Zhang Y L, Li Y M, Li L, Lv H and Liu X H. 2015a. Remote estimation of cyanobacteria-dominance in inland waters. *Water Research*, 68: 217-226 [DOI: 10.1016/j.watres.2014.10.019]
- Shi K, Zhang Y L, Qin B Q and Zhou B T. 2019. Remote sensing of cyanobacterial blooms in inland waters: present knowledge and future challenges. *Science Bulletin*, 64(20): 1540-1556 [DOI: 10.1016/j.scib.2019.07.002]
- Shi K, Zhang Y L, Xu H, Zhu G W, Qin B Q, Huang C C, Liu X H, Zhou Y Q and Lv H. 2015b. Long-term satellite observations of microcystin concentrations in Lake Taihu during cyanobacterial bloom periods. *Environmental Science and Technology*, 49(11): 6448-6456 [DOI: 10.1021/es505901a]
- Simis S G H, Peters S W M and Gons H J. 2005. Remote sensing of the cyanobacterial pigment phycocyanin in turbid inland water. *Limnology and Oceanography*, 50(1): 237-245 [DOI: 10.4319/lo.2005.50.1.0237]
- Simis S G H, Ruiz-Verdú A, Antonio Domínguez-Gómez J, Peña-Martínez R, Peters S W M and Gons H J. 2007. Influence of phytoplankton pigment composition on remote sensing of cyanobacterial biomass. *Remote Sensing of Environment*, 106(4): 414-427 [DOI: 10.1016/j.rse.2006.09.008]
- Soja-Woźniak M, Craig S E, Kratzer S, Wojtasiewicz B, Darecki M and Jones C T. 2017. A novel statistical approach for ocean colour estimation of inherent optical properties and cyanobacteria abundance in optically complex waters. *Remote Sensing*, 9(4): 343 [DOI: 10.3390/rs9040343]
- Song K S, Fang C, Jacinthe P A, Wen Z D, Liu G, Xu X F, Shang Y X and Lyu L. 2021. Climatic versus anthropogenic controls of decadal trends (1983-2017) in algal blooms in lakes and reservoirs across China. *Environmental Science and Technology*, 55(5): 2929-2938 [DOI: 10.1021/acs.est.0c06480]
- Song K S, Li L, Li S, Tedesco L, Hall B and Li Z C. 2012a. Hyperspectral retrieval of phycocyanin in potable water sources using genetic algorithm-partial least squares (GA-PLS) modeling. *International Journal of Applied Earth Observation and Geoinformation*, 18: 368-385 [DOI: 10.1016/j.jag.2012.03.013]
- Song K S, Li L, Tedesco L, Clercin N, Hall B, Li S, Shi K, Liu D W and Sun Y. 2013. Remote estimation of phycocyanin (PC) for inland waters coupled with YSI PC fluorescence probe. *Environmental Science and Pollution Research*, 20(8): 5330-5340 [DOI: 10.1007/s11356-013-1527-y]
- Song K S, Li L, Tedesco L P, Li S, Clercin N A, Hall B E, Li Z C and Shi K. 2012b. Hyperspectral determination of eutrophication for a water supply source via genetic algorithm-partial least squares (GA-PLS) modeling. *Science of the Total Environment*, 426: 220-232 [DOI: 10.1016/j.scitotenv.2012.03.058]
- Song K S, Li L, Tedesco L P, Li S, Hall B E and Du J. 2014. Remote quantification of phycocyanin in potable water sources through an adaptive model. *ISPRS Journal of Photogrammetry and Remote Sensing*, 95: 68-80 [DOI: 10.1016/j.isprsjprs.2014.06.008]
- Song K S, Shang Y X, Wen Z D, Jacinthe P A, Liu G, Lyu L and Fang C. 2019. Characterization of CDOM in saline and freshwater lakes across China using spectroscopic analysis. *Water Research*, 150: 403-417 [DOI: 10.1016/j.watres.2018.12.004]
- Sòria-Perpinyà X, Vicente E, Urrego P, Pereira-Sandoval M, Ruíz-Verdú A, Delegido J, Miguel Soria J and Moreno J. 2020. Remote sensing of cyanobacterial blooms in a hypertrophic lagoon (Albufera of València, eastern Iberian Peninsula) using multitemporal Sentinel-2 images. *Science of the Total Environment*, 698: 134305 [DOI: 10.1016/j.scitotenv.2019.134305]

- Sridhar B B M and Vincent R K. 2007. Spectral reflectance measurements of a *Microcystis* bloom in Upper Klamath Lake, Oregon. *Journal of Great Lakes Research*, 33(1): 279-284 [DOI: 10.3394/0380-1330(2007)33[279:SRMOAM]2.0.CO;2]
- Sun D Y, Hu C M, Qiu Z F and Shi K. 2015. Estimating phycocyanin pigment concentration in productive inland waters using Landsat measurements: a case study in Lake Dianchi. *Optics Express*, 23(3): 3055-3074 [DOI: 10.1364/oe.23.003055]
- Sun D Y, Li Y M, Wang Q, Gao J, Le C F, Huang C C and Gong S Q. 2013. Hyperspectral remote sensing of the pigment C-phycocyanin in turbid inland waters, based on optical classification. *IEEE Transactions on Geoscience and Remote Sensing*, 51(7): 3871-3884 [DOI: 10.1109/tgrs.2012.2227976]
- Tao M, Duan H T, Cao Z G, Loiselle S A and Ma R H. 2017. A hybrid EOF algorithm to improve MODIS cyanobacteria phycocyanin data quality in a Highly Turbid Lake: bloom and Nonbloom condition. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(10): 4430-4444 [DOI: 10.1109/jstas.2017.2723079]
- Torbick N and Corbiere M. 2015. A multiscale mapping assessment of Lake Champlain cyanobacterial harmful algal blooms. *International Journal of Environmental Research and Public Health*, 12(9): 11560-11578 [DOI: 10.3390/ijerph120911560]
- Torbick N, Ziniti B, Stommel E, Linder E, Andrew A, Caller T, Haney J, Bradley W, Henegan P L and Shi X. 2018. Assessing cyanobacterial harmful algal blooms as risk factors for amyotrophic lateral sclerosis. *Neurotoxicity Research*, 33(1): 199-212 [DOI: 10.1007/s12640-017-9740-y]
- Varungan T and Shanmugam P. 2017. An optical tool for quantitative assessment of phycocyanin pigment concentration in cyanobacterial blooms within inland and marine environments. *Journal of Great Lakes Research*, 43(1): 32-49 [DOI: 10.1016/j.jglr.2016.11.001]
- Vincent R K, Qin X M, McKay R M L, Miner J, Czajkowski K, Savino J and Bridgeman T. 2004. Phycocyanin detection from LAND-SAT TM data for mapping cyanobacterial blooms in Lake Erie. *Remote Sensing of Environment*, 89(3): 381-392 [DOI: 10.1016/j.rse.2003.10.014]
- Wang G Q, Lee Z, Mishra D R and Ma R H. 2016. Retrieving absorption coefficients of multiple phytoplankton pigments from hyperspectral remote sensing reflectance measured over cyanobacteria bloom waters. *Limnology and Oceanography: Methods*, 14(7): 432-447 [DOI: 10.1002/lom3.10102]
- Wang G Q, Lee Z and Mouw C. 2017. Multi-spectral remote sensing of phytoplankton pigment absorption properties in cyanobacteria bloom waters: a regional example in the western Basin of Lake Erie. *Remote Sensing*, 9(12): 1309 [DOI: 10.3390/rs9121309]
- Wen Z D, Song K S, Liu G, Shang Y X, Fang C, Du J and Lyu L. 2019. Quantifying the trophic status of lakes using total light absorption of optically active components. *Environmental Pollution*, 245: 684-693 [DOI: 10.1016/j.envpol.2018.11.058]
- Wheeler S M, Morrissey L A, Levine S N, Livingston G P and Vincent W F. 2012. Mapping cyanobacterial blooms in Lake Champlain's Mississquoi Bay using QuickBird and MERIS satellite data. *Journal of Great Lakes Research*, 38: 68-75 [DOI: 10.1016/j.jglr.2011.06.009]
- Wynne T T, Stumpf R P, Tomlinson M C and Dyble J. 2010. Characterizing a cyanobacterial bloom in western Lake Erie using satellite imagery and meteorological data. *Limnology and Oceanography*, 55(5): 2025-2036 [DOI: 10.4319/lo.2010.55.5.2025]
- Wynne T T, Stumpf R P, Tomlinson M C, Warner R A, Tester P A, Dyble J and Fahnenstiel G L. 2008. Relating spectral shape to cyanobacterial blooms in the Laurentian Great Lakes. *International Journal of Remote Sensing*, 29(12): 3665-3672 [DOI: 10.1080/01431160802007640]
- Yan Y E, Bao Z J and Shao J G. 2018. Phycocyanin concentration retrieval in inland waters: a comparative review of the remote sensing techniques and algorithms. *Journal of Great Lakes Research*, 44(4): 748-755 [DOI: 10.1016/j.jglr.2018.05.004]
- Yang D T, Pan D L, Zhang X Y, Zhang X F, He X Q and Li S Q. 2005. Retrieval of water quality parameters by hyperspectral remote sensing in lake TaiHu, China. *Conference on Optical Technologies for Atmospheric, Ocean, and Environmental Studies*. Beijing, PEOPLES R CHINA. Oct 18-22. 5832: 431-439.
- Yim I, Shin J, Lee H, Park S, Nam G, Kang T, Cho K H and Cha Y. 2020. Deep learning-based retrieval of cyanobacteria pigment in inland water for in-situ and airborne hyperspectral data. *Ecological Indicators*, 110: 105879 [DOI: 10.1016/j.ecolind.2019.105879]
- Yin B, Lü H, Li Y M, Wu C Q, Zhu L and Wang Y F. 2011. Retrieve phycocyanin concentrations based on semi-analytical model in the Dianchi Lake, China. *Environmental Science*, 32(2): 472-478 (尹斌, 吕恒, 李云梅, 吴传庆, 朱利, 王彦飞. 2011. 基于半分析模型的滇池藻蓝蛋白浓度反演. 环境科学, 32(2): 472-478 [DOI: 10.13227/j.hjkx.2011.02.039])
- Zhang F, Lee J, Liang S and Shum C K. 2015. Cyanobacteria blooms and non-alcoholic liver disease: evidence from a county level ecological study in the United States. *Environmental Health*, 14: 41 [DOI: 10.1186/s12940-015-0026-7]
- Zhao Q H, Sun G D , Wang J J, Yu G Z and Jiang B. 2018. Coupling effect of water temperature and light energy on the algal growth in Lake Taihu. *Journal of Lake Sciences*, 30(2) : 385-393 [DOI: 10.18307/2018.0210] (赵巧华, 孙国栋, 王健健, 于志国, 姜勃. 2018. 水温、光能对春季太湖藻类生长的耦合影响. 湖泊科学, 30(2) : 385-393) [DOI: 10.18307/2018.0210]
- Zhou B T, Shang M S, Wang G Y, Zhang S, Feng L, Liu X N, Wu L and Shan K. 2018. Distinguishing two phenotypes of blooms using the normalised difference peak-valley index (NDPI) and Cyanophyta index (CCI). *Science of the Total Environment*, 628-629: 848-857 [DOI: 10.1016/j.scitotenv.2018.02.097]
- Zimba P V. 2012. An improved phycobilin extraction method. *Harmful Algae*, 17: 35-39 [DOI: 10.1016/j.hal.2012.02.009]

Advances in remote sensing of phycocyanin for inland waters

LYU Lili^{1,2}, SONG Kaishan^{1,3}, LIU Ge¹, WEN Zhidan¹, SHANG Yingxin¹, LI Sijia¹

1. Northeast Institute of Geography and Agroecology, Chinese Academy of Sciences, Changchun 130102, China;

2. University of Chinese Academy of Sciences, Beijing 100049, China;

3. School of Environment and Planning, Liaocheng University, Liaocheng 252000, China

Abstract: Phycocyanin (PC), as the signature pigment of cyanobacteria, is usually used for remote sensing monitoring of cyanobacteria bloom. In recent years, the water quality of inland water has deteriorated, the eutrophication has intensified, and the algal blooms frequently occur. The research of remote sensing inversion of PC has attracted more and more attention. Therefore, it is urgent to sort out and write a comprehensive overview paper. In this paper, 178 relevant literatures were reviewed, and the development history and trend of PC remote sensing inversion research of PC in the past 30 years (1990—2020) were comprehensively summarized from the perspectives of PC optical characteristics, development of inversion algorithms, application of satellite sensors, difficulties and interference factors of quantitative remote sensing inversion of PC. This paper helps us to understand the new ideas and new methods emerging at home and abroad, master the new development trends of PC remote sensing inversion in the future, and provide data basis for the monitoring and management of water environment, water quality and water resources. Over the past 30 years, PC remote sensing inversion study number rising, and a breakthrough in the algorithm, has a lot of classic algorithms, such as band ratio method, the baseline method, nested band ratio method, biological optical model, derivative algorithm and machine learning algorithms, algorithm successfully isolated PC spectral characteristic of absorption coefficients at wavelength of 620 nm. Decreased the influence of other optically active substances (Chla, TSM) and obtained the high precision of inversion and validation. In addition, the development of PC inversion algorithms mostly based on in situ hyperspectral data or aerial images (CASI-2, AISA Eagle). In order to meet the needs of PC concentration distribution in a certain space and frequency, satellite image data sources are mostly used. PC. There are many types of multi-spectral satellite data sources to choose, such as Landsat series, MODIS, MERIS, Sentinel-2 MSI, Sentinel-3 OLCI, etc. However, due to the more appropriate band setting, MERIS and Sentinel-3 OLCI are still the most used data sources for PC remote sensing inversion research. Because PC spectrum signal is weak, and vulnerable to the interference of chlorophyll a, TSM, there is still a major difficult to get an accurate estimation result. Based on the above analysis, the future development direction of PC remote sensing inversion can be summarized as the following aspects: first, an international standard measurement method is urgently needed in PC extraction testing; secondly, the development of algorithm, adhere to the mechanism research related to the inherent optical properties, and the integrating machine learning algorithm to bring higher inversion accuracy; third, the scale of study area water body in space and time will toward a larger geographical space scale, longer time series history tracing and future prediction; fourth, at the aspect of the expansion of application, PC remote sensing inversion is not limited to the quantitative estimation of cyanobacteria biomass, but will predict distribution of algal toxins and related diseases based on the relationships between these parameters and PC concentration, furtherly establish a water risk factor rating system based on remote sensing in the future.

Key words: lake remote sensing, inland waters, phycocyanin, optical properties, inversion algorithm, satellite sensor

Supported by National Natural Science Foundation of China (No. 41730104)