J. Lake Sci.(湖泊科学), 2026, 38(2):000-000
DOI 10.18307/2026.0243

青藏高原湖泊表层水温的非线性协同驱动机制：基于深度学习+SHAP 融合分析框架*

石海韵[1]，祁　毅[2]，李婉宁[1]，沈　吉[1]，倪天华[1**]

（1：南京大学地理与海洋科学学院，南京 210023）

（2：南京大学建筑与城市规划学院，南京 210023）

摘 要：青藏高原是全球气候变化敏感区，其高海拔湖泊水温（LSWT）的演变对区域生态安全具有重要指示意义。在探究影响湖泊水温变化的因素时，涉及气象条件、地形地貌等多种影响因子。然而，传统方法对多因子非线性交互效应的定量解析能力有限。本研究以青藏高原 106 个大中型湖泊为对象，构建基于长短期记忆网络（LSTM）的深度学习模型，结合 SHAP（SHapley Additive exPlanation）可解释性方法，分别从整体与个体湖泊尺度上，定量分析了气温、降水、向下长波辐射、向下短波辐射、气压、比湿和风速 7 项因子对 LSWT 的影响。具体而言，研究系统解析了各驱动因子的独立作用效应、因子间的交互作用效应，以及这些效应在不同湖泊间的差异性，进而揭示了 LSWT 变化的驱动机制及其协同作用模式。结果表明：（1）向下长波辐射和向下短波辐射是 LSWT 的主导驱动因子，在整体与个体尺度贡献度分别位列前两位（全局 SHAP 值占比>80%），且与 LSWT 呈显著正相关；气温、比湿次之，降水和风速影响最小。（2）因子间交互效应普遍存在，识别出四类主导协同驱动模式：线型（如向下长波辐射-气温，67.92%湖泊）、倒 U 型（如比湿-气温，51.89%湖泊）、效应交叉型（如风速-比湿，70.75%湖泊）及阈值约束型（如降水-气压，100%湖泊）。（3）SHAP 方法有效量化了协同驱动的非线性特征，揭示了高原湖泊对辐射因子的高度敏感性，归因于稀薄大气下太阳辐射的高渗透性。本研究创新性地融合深度学习与可解释性分析，为高海拔湖泊水温的复杂驱动机制提供了定量化解析框架，对预测气候变化下的水温响应及制定差异化调控策略具有切实科学意义。
关键词：湖泊表层水温；深度学习；SHAP 可解释性；协同驱动机制；阈值效应；青藏高原

Nonlinear Synergistic Driving Mechanisms of Surface Water Temperature in Lakes on the Qinghai-Tibet Plateau: A Deep Learning + SHAP Integrated Analytical Framework

Shi Haiyun[1], Qi Yi[2], Li Wanning[1], Shen Ji[1] & Ni Tianhua[1**]

(1: School of Geography and Ocean Science, Nanjing University, 210023, Nanjing，P.R.China)

(2: School of Architecture and Urban Planning, Nanjing University, 210023, Nanjing,P.R.China)

Abstract: The Tibetan Plateau, a region highly sensitive to global climate change, exhibits significant evolution in lake surface water temperature (LSWT), which has profound implications for regional ecological security. Investigations into the drivers of LSWT changes involve multiple factors, including meteorological conditions and topographic features. However, conventional approaches possess limited capability to quantitatively resolve nonlinear interactions among these drivers. This study examined 106 large and medium-sized lakes across the Tibetan Plateau, employing a deep learning model based on Long Short-Term Memory (LSTM) networks combined with SHapley Additive exPlanations (SHAP) interpretability analysis. This framework quantitatively disentangles the individual and interactive contributions of seven drivers—air temperature, precipitation, downward longwave radiation, downward shortwave radiation, air pressure, specific humidity, and wind speed—to LSWT variations at both regional and individual lake scales, thereby systematically elucidating driving mechanisms and synergistic patterns. Key findings include: (1) Longwave and shortwave radiation were identified as the dominant drivers, collectively accounting for over 80.0% of global SHAP values across scales and showing strong positive correlations with LSWT. Air temperature and specific humidity exerted secondary influences, whereas precipitation and wind speed had minimal effects. (2) Widespread interactive effects revealed four primary synergistic modes: a linear pattern (e.g., downward longwave radiation and air temperature, affecting 67.92% of lakes), an inverted U-shape pattern (e.g., specific humidity and air temperature, 51.89% of lakes), an effect cross-driven pattern (e.g., wind speed and specific humidity, 70.75% of lakes), and a threshold-constrained pattern (e.g., precipitation and air pressure, 100% of lakes). (3) The SHAP methodology effectively

*2025-03-24 收稿稿；2025-06-17 收修改稿。

国家自然科学基金项目（42230507）赞助

**通信作者；E-mail：thni@nju.edu.cn

quantified nonlinear synergistic behaviors, highlighting the heightened sensitivity of plateau lakes to radiative factors due to high solar radiation permeability under thin atmospheric conditions. This study innovatively integrates deep learning with interpretability analysis to establish a quantitative framework for unraveling complex driving mechanisms behind high-altitude LSWT dynamics. The results offer critical insights for predicting thermal responses under ongoing climate change and for developing differentiated management strategies, thereby holding substantial scientific and practical relevance.
Keywords: Lake surface water temperature; Deep learning; SHapley Additive exPlanation; Synergistic driving mechanisms; Threshold effects; Tibetan Plateau

湖泊是对全球气候变化响应的重要指示器，而高海拔湖泊尤为敏感。随着全球气候变暖的加剧，高海拔湖泊面临的生态风险显著增加[1]。湖泊表层水温（LSWT）是湖泊最重要的属性指标之一，反映湖泊与大气之间的能量和物质交换特征[2]，影响着湖泊物理、化学及生物过程，成为湖泊水质、生态系统结构与功能演变的关键因素[3]。近 30 年来，全球大多数湖泊的水温以每十年 0.34℃的速度上升[4]，导致了热分层加剧[5]、藻类爆发[6]、水体缺氧、生物种群变化[7]等一系列湖泊生态环境问题。

深入认知 LSWT 变化的驱动因素，对预判未来气候变化对高海拔湖泊生态系统的影响，制定合理调控对策具有重要而迫切的科学意义。LSWT 的变化由地理、气象和水文等多种因素综合决定[8, 9]，其中，气象因子无论在线性的单因子独立影响，还是在非线性的因子间交互影响方面都具有最重要的影响[10]。例如，气温变化不仅通过能量传递与热量交换直接影响 LSWT，还会增强大气向下长波辐射并增加向湖泊表层的感热通量[11]；低气压系统常伴随降水过程，通过改变湖泊的水量收支与水体热容量间接调节水温[12]；比湿的变化会影响水汽蒸发与凝结过程，通过调节降水概率与太阳辐射吸收作用于水温[13, 14]；风速则通过驱动湖水的湍流运动与湖面热量交换速率影响水温[15]。目前，众多学者运用统计模型[16]、确定性模型[17]和混合模型[18]等方法在湖泊水温的驱动机制方面开展了大量工作，相关成果为理解湖泊水温影响机制提供了坚实基础。然而，现有的经典模型方法对于因子间复杂的交互效应缺乏有效的定量解译和阐释能力。其中，传统的统计模型主要基于线性回归，这种方法通常假设各因子独立作用，忽视了因子间潜在的交互效应[19]。确定性模型侧重于物理过程模拟，虽能准确描述单个因子作用，但在多因子相互作用时，因模型假设简化，难以充分考虑动态反馈[20, 21]。混合模型结合了统计和确定性模型的优点，但在定量分析因子交互效应时仍存在局限性，尤其在处理多个非线性交互因子时，模型的解释能力和预测精度会受到较大影响[22-24]。

深度学习作为复杂回归关系的定量解析和提取工具，以“大数据”为驱动，以“最小化预测误差”为目标，已经在海量、高维和复杂数据处理方面显示出了先进性能[25]。特别是在处理非线性回归问题时，通过对训练集进行学习使得模型在非线性关系的解译和表达中更具优势[26]。近年来，深度学习在地学领域的回归预测与机理探析方面应用日益广泛[27, 28]，但在湖泊表层水温的研究中，多数研究仅使用深度学习进行湖泊表层水温的预测[29-33]，缺乏对湖泊表层水温因子交互及驱动机制的深入解析。长短期记忆网络（LSTM）是深度学习的代表性模型，因擅长处理长时间序列预测问题而被广泛应用于识别驱动因素与水温趋势预测中[34, 35]。同时，随着 SHapley Additive exPlanation（SHAP）等解释方法的出现，使得深度学习模型的机理可解释性显著改善[36, 37]。SHAP 是一种将博弈论和局部解释相结合的可加性特征归因方法，能够解释机器学习模型的决策机理[38]。SHAP 不仅能解析单因子对目标变量的独立影响贡献度，亦能定量阐释因子间交互效应对目标变量的协同驱动作用。此外，在 SHAP 方法框架下，预测模型不同特征（即输入因子）的局部 SHAP 值和全局 SHAP 值能够解释各因子在个体和整体尺度分别对目标因子驱动贡献的重要性，帮助在不同尺度上深入地理解模型的预测行为和特征重要性[39, 40]。

青藏高原是对全球气候变化最敏感的地区之一[41]，其变暖速率高出全球变暖速率的一倍[42]。青藏高原被称为“亚洲水塔”，是全球海拔最高、面积最大以及数量最多的高原内陆湖区，拥有的高海拔湖泊面积达到 5×10^4 km^2，占中国湖泊总面积的 57.2%[43]。近 40 年来，该区域绝大多数湖泊的表层温度均呈上升趋势，升温速率约每 10 年 0.01℃~0.47℃[44]。青藏高原湖泊不仅是亚洲重要江河的发源地，更对区域乃至全球气候调节、生物多样性维持具有不可替代的战略意义。然而，在全球气候变暖背景下，高海拔湖泊的水温很可能率先出现剧烈变化，为湖泊生态系统的结构与功能带来显著的不确定性。因此，深入探讨高原型湖泊水温的关键影响因子和非线性的协同驱动机制，对于系统理解青藏高原湖泊水温变化机制与趋势，制定更有效的湖泊生态环境保护对策具有迫切的理论与现实意义。

本研究针对青藏高原 106 个大中型湖泊，通过构建基于 LSTM 多层神经网络的 LSWT 深度学习预测模型，集成 SHAP 归因解释分析方法，开展湖泊 LSWT 的单因子影响梯度性、因子间交互效应与协同驱动模式的创新研究，重点聚焦于 LSWT 的因子交互效应定量化解译、协同驱动模式识别及其状态转变阈值条件判别等。我们期望本研究为系统理解高海拔地区湖泊的水温驱动机制以及科学调控提供新颖的见解与决策支持。

1 材料和方法

1.1 研究区域

本文选取研究区内海拔超过 4000m，湖泊面积大于 50km^2 的 106 个大中型湖泊（图 1），湖泊命名采用 HydroLAKES 数据库中 Hylak_id 的命名方式(https://www.hydrosheds.org/page/hydrolakes)。

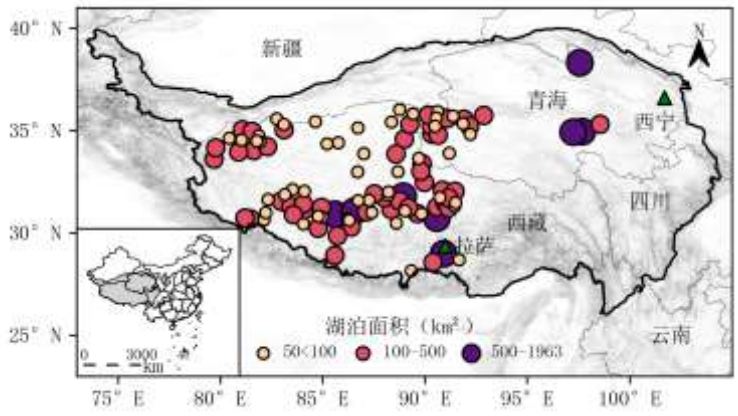

图 1 青藏高原区位与 106 个湖泊分布图*

*该图基于自然资源部标准地图服务网站下载的审图号为 GS(2020)4619 号的标准地图制作，底图无修改

Fig.1 Location of the Tibetan Plateau and Distribution of 106 Lakes*

This map was created based on the standard map (Approval No. GS(2020)4619) downloaded from the Standard Map Service Website of the Ministry of Natural Resources, China, with no modifications to the base map.

1.2 数据来源

本研究收集了 1979-2018 年青藏高原 106 个湖泊的水温、气象要素及基本地理信息数据。水温数据来源于中国区域湖泊表层水温数据集（1950-2100）[45]，该数据由与卫星数据耦合的 CSFLake 得到。Wang 等人[11]利用超过 17 万个卫星观测数据在 10 个湖泊中验证 CSFLake 模型能够显著提升湖泊水温的模拟精度，使均方根误差从 4.46°C（FLake）降低至 1.39°C。气象数据来自第三极地区长时间序列高分辨率地面气象要素驱动数据集（TPMFD, 1979-2023）[46]，该数据集相比于目前主流的再分析数据具有更高的精度，因此被广泛应用于第三极地区气候分析和陆面、水文、生态相关的模型输入[47, 48]。地理信息数据包括海拔、面积、经纬度，来自国家基础地理信息中心（https://www.webmap.cn/）和 HydroLAKES (https://www.hydrosheds.org/products/hydrolakes)。

1.3 模型构建及预测结果解释

为了全面认知湖泊群体与个体在水温演变驱动机制上可能的差异性，应用在时间依赖关系学习解译有独特优势的 LSTM 神经网络[37]。分别在全体湖泊（将 106 个湖泊作为一个整体）和单个湖泊两种尺度上构建 107 个深度学习预测模型，开展驱动机制研究。基于前人经验[30, 49]和本研究的特点，气温（TEMP，单位：K）、降水（PREC，单位：mm）、向下长波辐射（LRAD，单位：W m^{-2}）、向下短波辐射（SRAD，单位：W m^{-2}）、气压（PRES，单位：Pa）、比湿（SHUM，单位：kg kg^{-1}）和风速（WIND，单位：m s^{-1}）共 7 项自然因子被选入模型的输入因子集，LSWT 是模型输出的目标因子。样本数据时间尺度为日尺度。

在本研究中，神经网络模型框架由一个 LSTM 层，两个全连接层（FC）以及时间增强器构成（图 2），增强对时间变化特征的提取[50]。其中，TS（Timestamp）指的是输入的时间戳排序变量，即时间标签；DOY（Day of Year）代表的是一年中的某一天，即日序；h_{t-1}，h_t，X_t，C_{t-1},C_t分别表示上一个单元状态的输出、当前单元状态的最终输出、当前单元状态的输出、上一个时间步的单元状态和当前时间步的单元状态；σ 和$tan\,h$分别指 sigmoid 和 tanh 函数，二者用于遗忘门、输入门和输出门的激活；预测网络的 FC 层和时间增强器的输出逐个元素相乘，结果是模型的最终输出（即 LSWT 的预测值）。所有模型均使用 TensorFlow 深度学习框架和 Keras 库在 Python 3.7 中执行模型构建和训练。

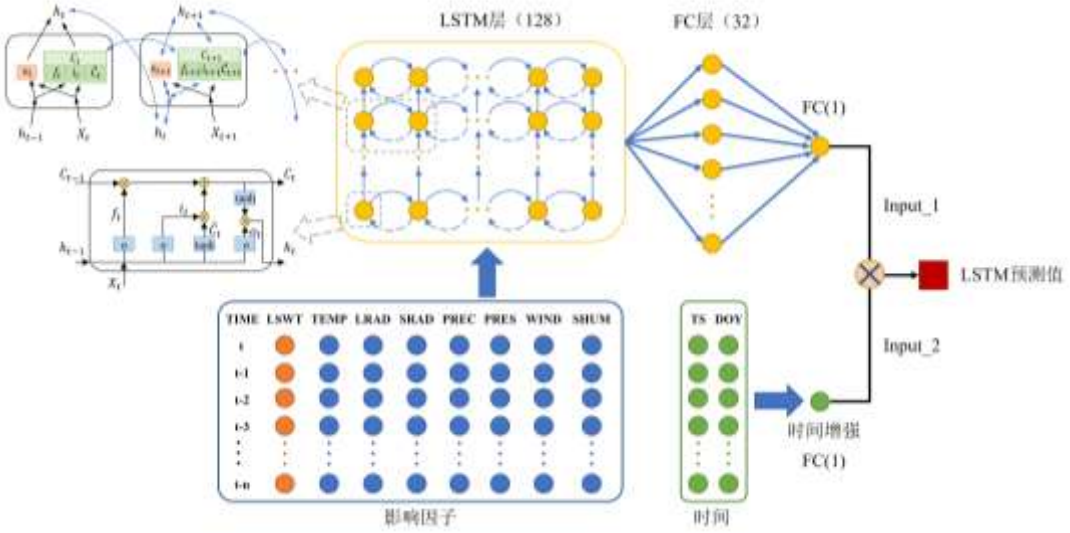

图 2 LSTM 神经网络模型结构图

Fig.2 Structure Diagram of LSTM Neural Network Model

所使用的数据来源于 1979-2018 年的逐日 14609 条数据样本，采用 min-max 方法对数据进行归一化处理，并将数据按 70%、10%、20%的比例分为训练集、验证集和测试集。为每个模型设置不同的训练周期、时间滞后和最优激活函数。应用 20%的固定 dropout 以防止模型过拟合，初始学习率为 0.001 以防止梯度爆炸，迭代次数为 100。采用 Nash-Sutcliffe efficiency（NSE）和 RMSE-observations standard deviation ratio（RSR）[51]对模型性能水平进行评估（表 1），同时采用均方误差（MSE）和平均绝对误差（MAE）并指导模型参数的调整和优化。

表 1 模型性能评估标准

Tab.1 Model Performance Evaluation Criteria

性能等级	RSR	NSE	MSE 与 MAE
非常好	0.00<RSR≤0.50	0.75<NSE≤1.00	真实值与预测值越接近，MSE 与 MAE 的值接近于 0[52]
良好	0.50<RSR≤0.60	0.65<NSE≤0.75	
一般	0.60<RSR≤0.70	0.50<NSE≤0.65	
较差	RSR>0.70	NSE≤0.50	

本研究中，SHAP 方法将模型输出的预测结果解释为所有因子对应特征的贡献累积，其中每个输入因子（特征）的 SHAP 值代表了其对目标因子的驱动贡献程度以及正负相关性[37]。单因子独立驱动贡献、因子间交互驱动效应及其方向性均可通过 SHAP 值来表征与解释。SHAP 值的计算方法如下：

$$g(z') = \Phi_0 + \sum_{f=1}^{M} \Phi_{fz'_f}$$

其中，g 是解释模型；M 为输入因子的个数；z'_f指示输入特征 F 是否出现（$z'_f = 0$或 1）；Φ_f表示要素的贡献幅度f。$\Phi_f > 0$表示该特征加强结果；$\Phi_f < 0$表示该特征降低结果。

1.4 LSWT 深度学习预测模型训练有效性检验

在单个模型性能水平上，106 个单体湖泊与总体尺度对应的共 107 个深度学习预测模型性能均达到优良水平。图 3 展示了序号为 1382 的邦达错湖泊 LSWT 的深度学习预测模型训练的有效性。训练集和测试集的 Loss 均呈现逐渐下降的趋势，最终在训练 100 个周期后达到最小值。从拟合曲线图可以看出，测试集上的预测值和真实值表现出优秀的一致性。其他的模型均按同样方法完成构建和训练。

通过绘制模型 MAE、MSE、NSE、RSR 的云雨图，结合各参数分级评估标准可以直观地反映模型对湖泊水温驱动机制问题的整体适应性[53]。从图 4 可以看出，在总体水平上，所有 107 个 LSWT 预测模型的性能水平能都达到了“非常好”的等级（NSE>0.75 和 RSR≤0.50）。

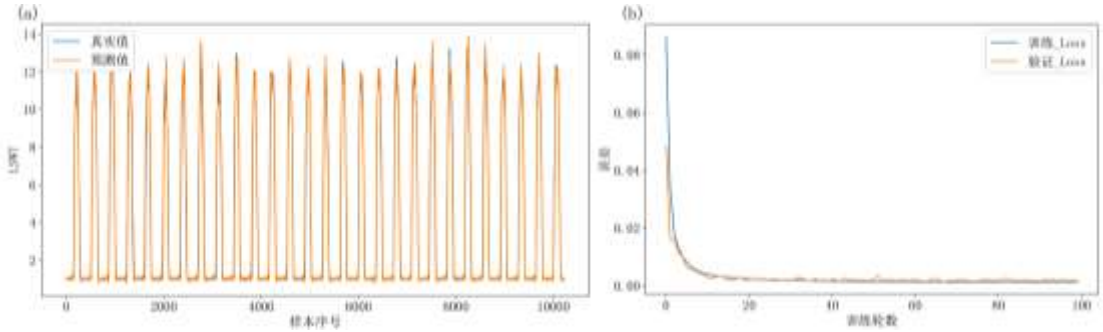

图 3 邦达错 LSWT 的预测模型训练效果

(a) 为模型的预测值与真实值拟合结果，（b）为模型训练集和测试集的 loss 值

Fig.3 Training Performance of the LSWT Prediction Model for Bangda Co

(a) Fitting results between predicted values and true values; (b) Loss values of the training and test sets.

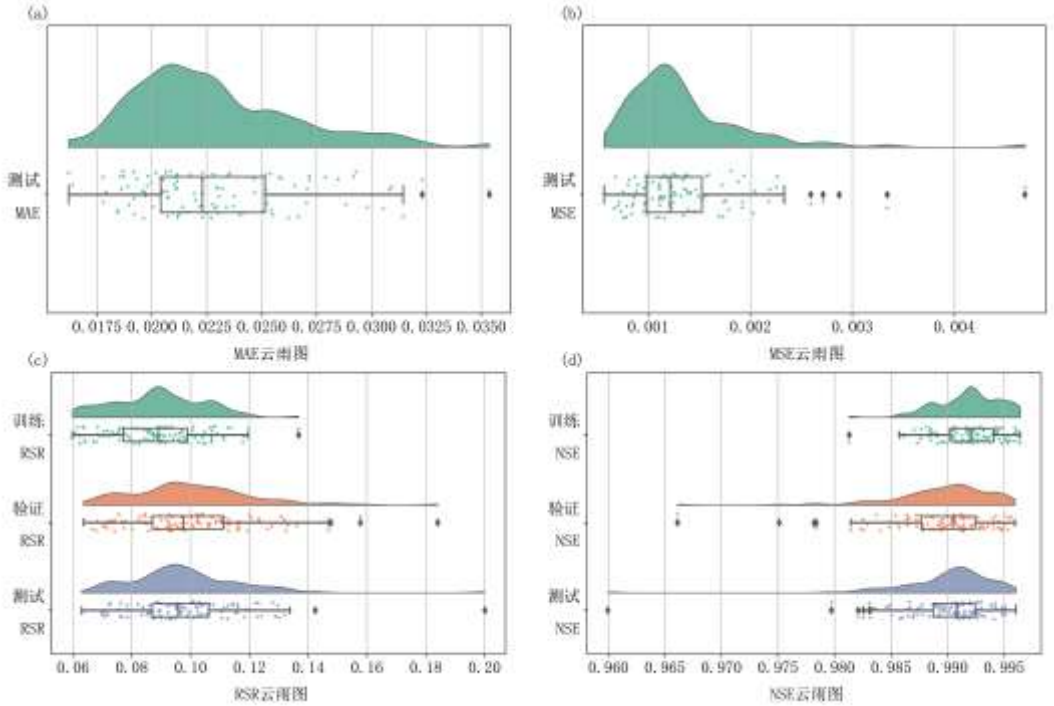

图 4 107 个模型的指标结果云雨图

（a）MAE 云雨图，（b）MSE 云雨图，（c）RSR 云雨图，（d）NSE 云雨图

Fig.4. Raincloud Plots of Evaluation Metrics for 106 Models

(a) MAE raincloud plot; (b) MSE raincloud plot; (c) RSR raincloud plot; (d) NSE raincloud plot.

2 结果

2.1 单因子对 LSWT 的独立驱动贡献梯度性和方向性

本研究中 7 个因子对 LSWT 的驱动贡献重要性各有不同，但在单个湖泊和整体尺度上的总体趋势较为一致（如图 5 所示）。在单个湖泊尺度上（图 5-a），依据局部 SHAP 值，可观察到在 106 个湖泊中各因子对 LSWT 驱动贡献排序最高且占比最大是顺序是 LRAD（91.50%）,SRAD（83.02%）,TEMP（51.89%）,SHUM（43.40%）,PRES（72.64%）,WIND(72.64%)和 PREC(85.85%)，括号内的排序为该因子对应的排序占比（例如 TEMP 排第三的占比 51.89%）。在整体的尺度上（图 5-b），依据全局 SHAP 值，可观察到各因子对 LSWT 驱动贡献从大到小排序为 LRAD，SRAD，TEMP，SHUM，PRES，WIND 和 PREC。可以看出，无论是在个体还是整体尺度上，LRAD、SRAD 的驱动贡献相对最为重要，分别稳定排在第一和第二的位置。WIND 和 PREC 的 PREC 的驱动贡献相对最低，分别排在第

六和第七的位置。TEMP，SHUM 和 PRES 三因子的驱动贡献均处于中间水平且排序略有波动。在整体尺度上，PRES 的作用显得更为突出，这是由于 PRES 的变化通常与大尺度的气候系统和天气模式相关联，如气压槽和高压脊，这些现象在大范围内影响天气状况。因此当对多个湖泊进行整体研究时，气压可能通过影响这些气候变量间接地对湖泊表层水温产生更广泛的效应。

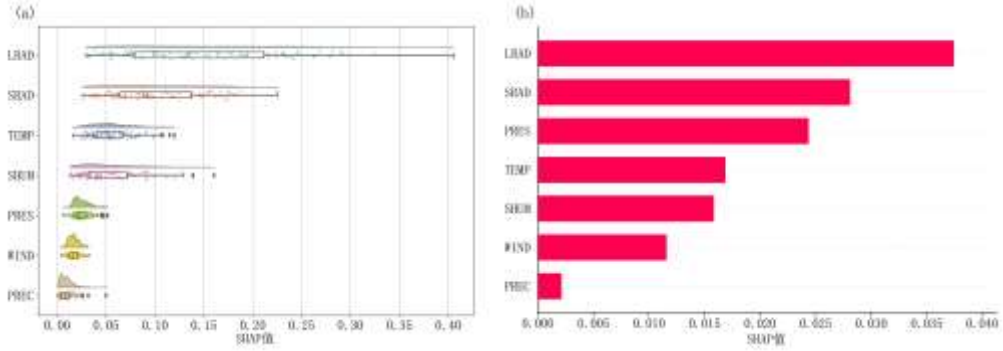

图 5 单因子的 SHAP 值

(a）为 106 个湖泊中各因子 SHAP 值分布的云雨图，(b)为整体尺度中各因子 SHAP 值

Fig.5 SHAP Values of Single Factors

(a) Raincloud plots of SHAP value distributions for individual factors across 106 lakes; (b) SHAP values of factors at the aggregate level.

同时，不同因子对 LSWT 的驱动效应具有差异化的正、负方向性。在单个湖泊尺度上，在 106 个湖泊中，超过 80%的 LSWT 分别受到 LRAD（95.28%）、SHUM（93.40%）、SRAD（90.57%）和 TEMP（81.13%）的显著正向驱动。此外，超过一半的湖泊受到 PREC（56.60%）的正向驱动，但有 34.91%的趋势不明显。而 PRES（54.72%）和 WIND（71.70%）分别对 LSWT 的驱动效应没有明确的正负性趋势。在整体尺度上，所有因子都表现出更为一致的方向性影响，除了 PRES 和 TEMP 两个因子对 LSWT 的驱动效应方向与其在个体尺度上的表现略有不同外，其余因子都呈现出对与个体尺度上的方向性较为一致（图 6)。

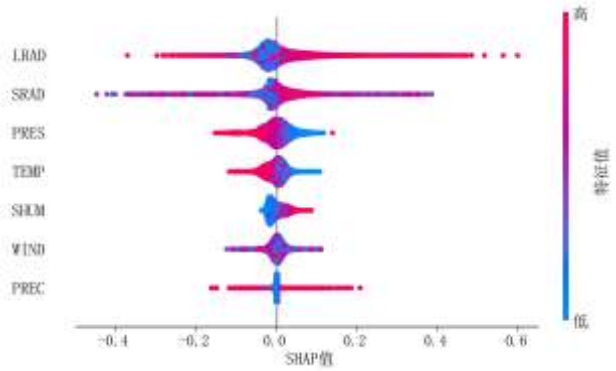

图 6 总体尺度上不同驱动因素对 LSWT 的正负影响

Fig.6 Positive and Negative Effects of Different Driving Factors on LSWT at the Aggregate Level

2.2 因子间交互效应的协同驱动模式

大多数因子对 LSWT 除了具有独立影响外，往往还与其他因子产生交互效应并表现出特定的协同驱动模式。本研究中，通过 SHAP 分析计算得到 TEMP、PREC、LRAD、SRAD、PRES、SHUM 和 WIND 这 7 个因子两两组合的 21 对交互作用的 SHAP 值。虽然每组因子对不同湖泊的表层水温可能具有不同的交互作用，但在整体上呈现出特定的协同驱动模式。50%以上的湖泊中都观察到线型、倒 U 型、效应交叉型、阈值约束型等涉及 14 组因子交互效应的四类主导协同驱动模式(表 2)。

2.2.1 线型模式 线型模式的总体特征是在因子强度均较弱时，两者交互效应与 LSWT 为负相关，但是这种负相关作用随着交互因子强度的增强而逐渐减弱，达到临界值时则转变为正相关，然后再随着因子强度的进一步增加，正相关作用则逐渐趋于稳定。在 21 组交互因子中有 4 组对 LSWT 的协同驱动模式呈现为线型特征。其中 TEMP-LRAD 和 SRAD-PRES 两组最为广泛，分别在 67.92%（图 7-b）和 53.77%（图 7-d）的湖泊中都表现为该类模式。以编号为 1440 和 14954 湖泊为例，其因子交互作用的 SHAP 值

与同类特征湖泊的空间分布如图7所示。以图7-a所示的编号1440的湖泊为例，当LRAD>240~250 W/m²、TEMP>272.5~275K时，LRAD与TEMP的交互效应转变为正相关，随之逐渐趋于稳定。SARD与PRES（图 7-c）的交互效应及其对 LSWT 协同驱动模式与前者类似，不过状态转换的临界值范围更宽一些（SRAD>100~270 W/m²、PRES>53400~53800 Pa）。在高强度的LRAD与SRAD状态下，湖泊系统趋于热平衡，进一步增加因子强度对LSWT的影响减弱，正相关作用趋于稳定。

表 2 青藏高原 106 个湖泊中主导的协同驱动模式

Tab.2 Dominant Synergistic Driving Patterns of 106 Lakes on the Tibetan Plateau

协同驱动模式	因子 1	因子 2	数量*（%）	协同驱动模式	因子 1	因子 2	数量*（%）
线型模式	TEMP	LRAD	72(67.92%)	阈值约束模式	PREC	PRES	106(100%)
	SRAD	PRES	57(53.77%)		PREC	WIND	105(99.06%)
倒 U 型模式	SHUM	TEMP	55(51.89%)		PREC	LRAD	101(95.28%)
	SHUM	PRES	55(51.89%)		PREC	SHUM	98(92.45%)
效应交叉型模式	WIND	SHUM	75(70.75%)		PRES	TEMP	65(61.32%)
	WIND	SRAD	65(61.32%)		PRES	WIND	58(54.72%)

注：*表格里面只显示了在 106 个湖泊中的占比超过 50%的协同驱动模式

Note: The table only shows the driving patterns that account for more than 50% in 106 lakes.

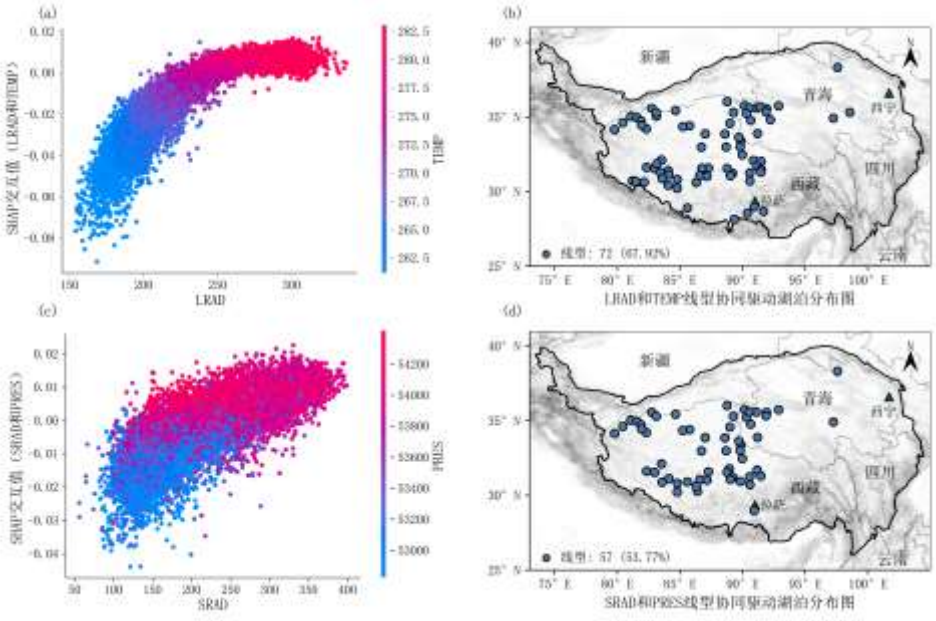

图 7 线型协同驱动模式

(a），(c)分别为 LRAD 与 TEMP、SRAD 与 PRES 之间交互作用的 SHAP 交互值，以及相应的线型协同驱动模式。(b)，(d)为每种模式下湖泊的空间分布情况。红色表示 SHAP 值较高，而蓝色表示 SHAP 值较低。

Fig.7 Linear synergistic driving pattern

(a) and (c) are respectively the SHAP interaction values between TEMP and LRAD, SRAD and PRES, and their corresponding linear synergistic driving patterns. (b) and (d) show the spatial distribution of lakes under each pattern. Red indicates higher SHAP values, while blue denotes lower SHAP values.

2.2.2 倒 U 型模式 倒 U 型交互效应的 SHAP 值会在某一临界条件时出现明显的曲线拐点，表明交互效应开始发生转变。在 21 组交互因子中，有 5 组对 LSWT 的协同驱动模式呈现为倒 U 型特征。其中，SHUM 分别与 TEMP、PRES 的交互作用最具代表性，都存在于 51.89%的湖泊中（图 8-b, 图 8-d）。以编号为 14940 和 1367 湖泊为例的因子交互作用 SHAP 值与同类特征湖泊的总体空间分布如图 8 所示。以图 8-a 中编号 14940 的湖泊为例，SHUM 与 TEMP 对 LSWT 总体表现出负向的协同驱动效应。该效应先随着 SHUM 与 TEMP 的增强而减弱。当 SHUM 的浓度达到 0.002 kg kg^{-1} 及 TEMP 达到 265~270 K 时达到最

小值而出现拐点。经过拐点后，负向的协同效应则开始持续增强，但强度变化速率不如拐点前。图 8-c 所示的编号为 1367 的湖泊呈现出相似的协同驱动模式。当 SHUM>0.002 kg/kg 且 PRES>57000~57200 Pa 时，SHUM 与 PRES 对 LSWT 的协同驱动效应出现拐点。

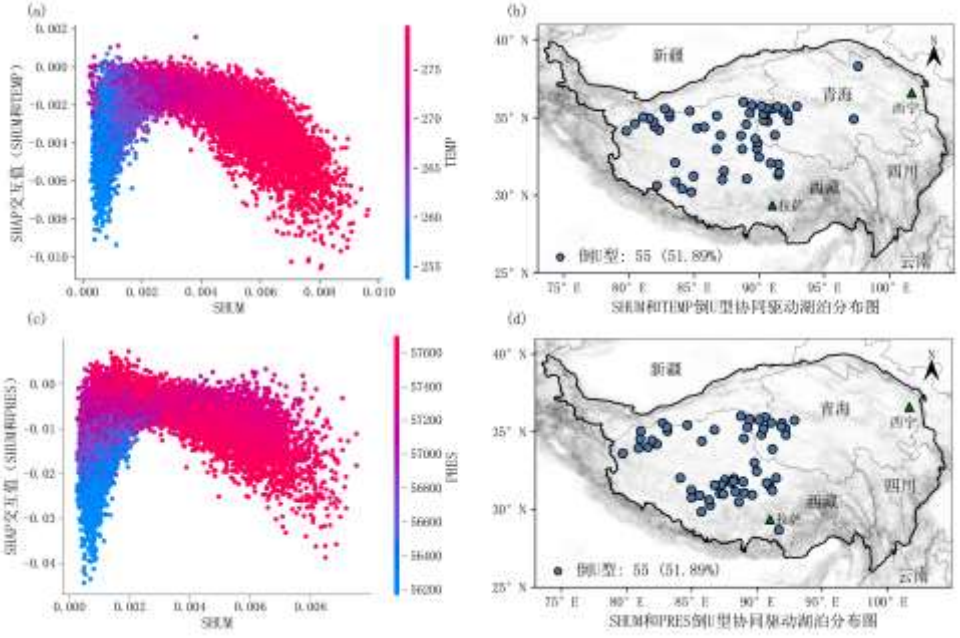

图 8 倒 U 型协同驱动模式

(a）和(c)分别是 SHUM 与 TEMP、SHUM 与 PRES 之间的 SHAP 交互值，以及相应的倒 U 形协同驱动模式。(b)和(d)是每种模式下湖泊的空间分布情况。

Fig.8 Inverted U-shaped synergistic driving pattern

(a) and (c) are respectively the SHAP interaction values between SHUM and TEMP, SHUM and PRES, and their corresponding inverted U-shaped synergistic driving patterns. (b) and (d) show the spatial distribution of lakes under each pattern.

2.2.3 *效应交叉型模式* 在效应交叉型模式下，随着两个因子强度增强，会出现交互效应的强度和方向在特定的临界值范围（拐点）实现交叉变化的趋势。在 21 组交互因子中，有 6 组对 LSWT 的协同驱动模式呈现为效应交叉型特征。其中，WIND 分别与 SRAD、SHUM 的交互效应最为典型，分别呈现于 70.75%（图 9-b）和 61.32%（图 9-d）的湖泊中。在整体尺度上，PRES 与 WIND 对 LSWT 的协同驱动模式也表现同类模式。以编号为 1419 和 1448 湖泊为例的因子交互作用 SHAP 值与同类特征湖泊的总体空间分布如图 9 所示。以图 9-a 所示编号为 1419 的湖泊为例，当 SHUM 与 WIND 的强度都较弱时，该交互效应为负相关，随着因子的增强，交互效应的强度逐渐减弱。但当 SHUM 与 WIND 的强度超过临界值范围，即 SHUM 超过 0.004~0.005 kg kg-1，WIND 超过 4.0~5.0 m s^{-1} 时，交互效应依旧为负相关并逐渐增强。相反，当 SHUM 的强度较弱，而 WIND 的强度较强时，该交互效应为正相关，随着 SHUM 的增强而 WIND 减弱时，交互效应的强度逐渐减弱。当 SHUM 的强度超过临界值范围，WIND 小于临界值范围时，交互效应也为正相关并逐渐增强。图 9-c 所示编号为 1448 的湖泊中 SRAD 与 WIND 的交互作用对 LSWT 亦表现出类似的模式，其临界值出现在 SRAD 为 210~230 W m^{-2} 及 WIND 为 3.0~4.0 m s^{-1} 时。

3.2.4 *阈值约束型模式* 在阈值约束型模式下，一个因子只有在特定的取值范围内才与另外一个因子形成显著的协同驱动效应。在单个湖泊尺度上，在 21 组交互因子中，有 12 组对 LSWT 的协同驱动模式呈现为阈值约束型模式。其中，PREC 与 PRES、WIND、LRAD、SHUM 和 TEMP 的这种协同驱动模式分别在 100%、99.06%、95.28%、92.45%和 90.57%的湖泊中被观察到。PRES 与 LRAD、TEMP 和 WIND 的交互作用则分别在 63.21%、61.32%和 54.72%的湖泊中表现出一致的模式。在整体尺度上，PREC 与其他因子的交互作用亦呈现出阈值约束型驱动模式特征。以编号为 1472、15062 和 1401 湖泊为例的因子交互作用 SHAP 值与不同模式湖泊的总体空间分布如图 10 所示。图 10-a 为编号 1472 的湖泊，其 PRES 强度在 57000-57500 Pa 之间时，因子之间的正向协同驱动最为显著。而如图 10-b，在编号为 15062 的湖泊中，PRES 强度在 55500~56000 Pa 之间时，则是负向协同驱动最为显著。图 10-c 为编号 1401 的湖泊，其 PRES 与 PREC 的交互特征则是协同驱动方向不清，在同样的阈值范围内，同时表现出正负向协同驱动。PRES 与 TEMP、SHUM、LRAD 的交互作用中，在阈值范围内，皆表现出负向协同驱动。

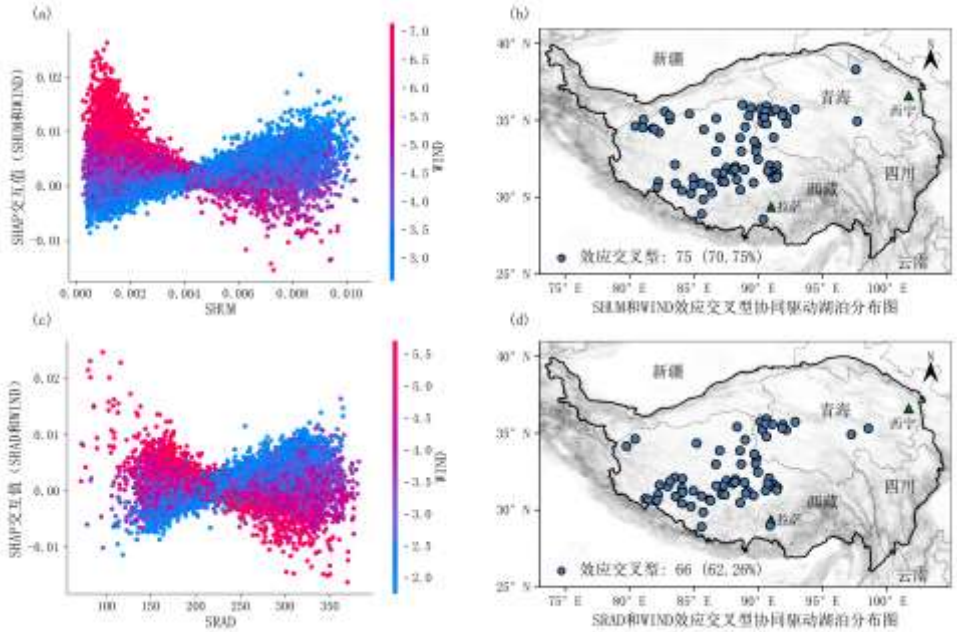

图 9 效应交叉型协同驱动模式((a）和(c)分别是 SHUM 与 WIND、SRAD 与 WIND 之间的 SHAP 交互值，以及相应的效应交叉型协同驱动模式。(b)和(d)是每种模式下湖泊的空间分布情况)

Fig.9 Effect cross-driven pattern

(a) and (c) are respectively the SHAP interaction values between SHUM and WIND, SRAD and WIND, and their corresponding effect cross-driven pattern patterns. (b) and (d) show the spatial distribution of lakes under each pattern.

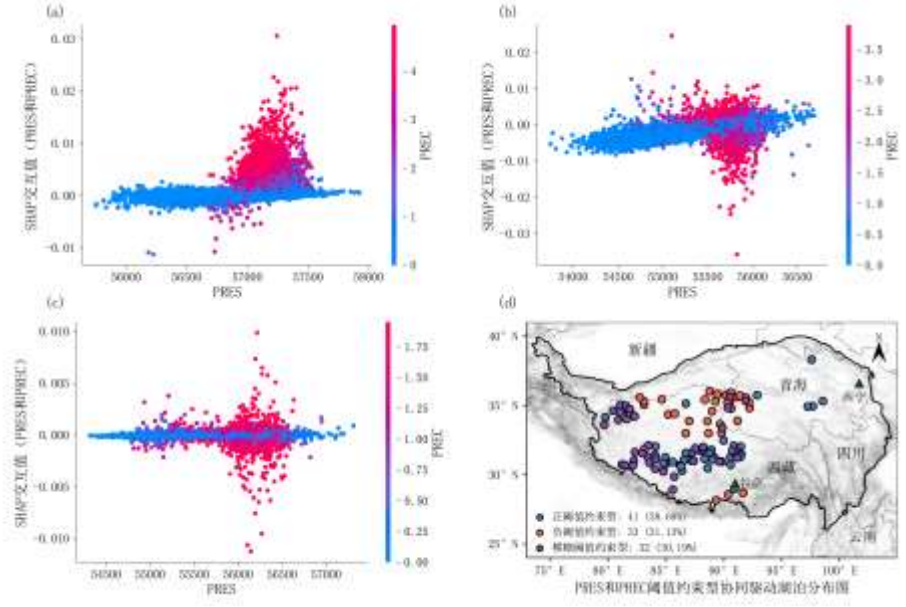

图 10 阈值约束型驱动模式

(a）、(b)和(c)分别表示 PRES 与 PREC 之间相互作用的 SHAP 值，以及相应的阈值约束协同驱动模式。(a)为正阈值约束驱动模式，(b)为负阈值约束驱动模式，(c)为模糊阈值约束驱动模式，(d)展示了呈现每种模式的湖泊的空间分布情况。

Fig.10 Threshold-constrained driving pattern

(a), (b) and (c) are respectively the SHAP interaction values between PRES and PREC, and their corresponding threshold-constrained driving pattern patterns. (a) Positive threshold-constrained driving pattern; (b) Negative threshold-constrained driving pattern; (c) Fuzzy threshold-constrained driving pattern; (d) Spatial distribution of lakes exhibiting each pattern.

3 讨论

诸多研究表明，在全球气候变化的大背景下全球范围内的 LSWT 总体呈现上升态势[54, 55]。但已有的多数研究主要聚焦于探究单一因子在湖泊表层水温变化进程中的驱动作用，鲜少有聚焦于因子间交互效应定量解析及其协同驱动模式识别。本研究通过深度学习算法+SHAP 归因解释方法的融合分析，在深入理解高原湖泊表层水温的驱动机制方面取得了新颖的见解。

3.1 向下长波辐射和向下短波辐射是影响高原湖泊表层水温的主导驱动因子

在驱动因素方面，气象条件被视为影响湖泊表层水温最直接的驱动力。各种气象要素对湖泊表层水温驱动贡献的差异也是已有大多数研究关注的主要问题[56-58]。其中，气温被认为是最重要的影响因子之一[59, 60]。在研究对象方面，平原和高原地区的湖泊都有丰富的研究和报道。但是，大多数高海拔地区的湖泊远离人类活动的直接干扰，与平原地区相比，在区域气温水平、太阳辐射条件和云层覆盖特征等方面存在显著差异。高海拔地区湖泊表层水温的独特性、敏感性及其背后可能的驱动机制差异性尚未得到系统探讨。

大量国内外研究成果显示，受地理环境与气候条件差异影响，平原与高原地区湖泊表层水温的主导驱动因子存在显著分异特征。在平原地区，由于大气层较厚且气溶胶、水汽等物质含量相对较高，太阳辐射在传输过程中被强烈削弱，致使其对湖泊水体的热量输入受限，进而显著降低了辐射对湖水的增温效应。例如，Woolway 等人[61]对 1996-2011 年间 732 个大型湖泊的月均表层水温数据进行深度剖析，并报告称，对于其中 60%的湖泊，温度对湖泊表层水温的影响比太阳辐射和近地表风速更为重要。Noori 等人[62]对芬兰一个平原湖泊的研究发现，在夏季时对湖泊表层水温变化影响最大的因子是气温。白等人[63]则通过皮尔逊相关分析研究了中国西南部的洞庭湖，得出湖泊表层水温与同期平均气温之间的相关性最强。

对于高原地区的湖泊，由于其海拔的影响，辐射因子相较于平原地区更为强烈，已有学者表明辐射因子对于湖泊表层水温的影响显著于气温。Wen 等人[64]通过使用一维湖泊热模型研究高原上的鄂陵湖，发现向下长波辐射对湖泊表层水温的影响占总影响的 40%以上。Wang 等人[11]使用一维湖泊模型 Flake 研究了中国不同地区的 168 个湖泊，横向对比中国五个不同的湖泊分区，仅有青藏高原地区，其向下长波辐射是影响湖泊表层水温上升的主要因子。Huang 等人[65]对中国大型湖泊表层水温变化的贡献研究表明，在青藏高原以及蒙古高原地区受到辐射影响的占比与其他地区相比更大。此外，Lazhu 等人[66]研究表明，在目前的湖泊物理模型中很大程度上忽略了太阳辐射在湖冰中的传输过程关键参数，他们发现在青藏高原湖冰消融末期普遍存在湖温跃升现象，并强调了太阳辐射透过冰层加热湖水的重要性。青藏高原地区湖泊还面临着湖泊冰盖的持续退缩，这会导致湖泊表面反照率降低，进而使太阳辐射吸收增加，湖泊变暖更为明显[67]。

在本研究中，无论是在总体层面还是单个湖泊层面，在几十年的时间跨度内或是全年的四个季节中，向下长波辐射和短波辐射都是对青藏高原湖泊表层水温驱动贡献最大的前两个因子。一般而言，气温、比湿和气压对湖泊表层水温的贡献相对较低。大多数高原湖泊和平原湖泊所呈现出的这种差异，很可能是由于高原地区海拔高、大气稀薄。在整体尺度上，气压的作用显得更为突出，这是由于气压的变化通常与大尺度的气候系统和天气模式相关联。青藏高原湖泊分布广泛，气压值之间差异较大，因而当对多个湖泊进行整体研究时，气压可能通过影响这些气候变量间接地对湖泊表层水温产生更广泛的效应。向下短波和向下长波辐射受大气的衰减作用较小，能够大量到达湖面，成为湖水的关键热源，从而主导着水温的变化，本研究中涉及的青藏高原湖泊就是这种情况[11, 68]。

3.2 高原湖泊水温变化存在四种主导协同驱动模式

与单一因子的独立作用相比，因子之间的非线性相互作用对湖泊表层水温有着更为复杂且显著的协同驱动效应[10, 69]。然而，经典的研究方法在这方面通常缺乏有效解译手段。例如，尽管原位观测方法能够反映最准确的湖水温度及其变化情况[11]，但这种方法成本高、效率低，而且获取的数据量非常有限，难以描述湖泊的完整空间范围和长期变化情况。尽管卫星遥感具有观测和分析大空间区域的能力[34]，但它很容易受到时空分辨率、云层覆盖和太阳辐射等因子的限制。尽管确定性机理模型在很长一段时间内一直是应用最广泛且被认可的方法[70]，但其有效性在很大程度上受到对湖水温度变化物理过程的理解程度、数据质量、模型参数和边界条件等因素的影响。

在本研究结果表明，深度学习模型+SHAP 的融合分析方法，能有效实现对湖泊表层水温变化复杂驱动机制的定量解译和可视化识别。我们研究发现，无论是在总体层面还是个体层面，在青藏高原湖泊表层水温的演变过程中，因子之间的交互效应是普遍存在的。在 106 个湖泊中，21 种交互作用中的 14 种（占比 67%）在超过 50%的湖泊中都有被观察到，分别包括线型、倒 U 型、效应交叉型和阈值约束型模式。其中，线型模式以向下长波辐射-气温（67.92%）、向下短波辐射-气压（53.77%）为主导。高原地区空气密度较低，导致向下长波辐射通量相对较高，使得气温升高与长波辐射增强之间形成正反馈机制。

此外，高气温常伴随更多水汽和云量，进一步强化长波辐射与气温交互的增温效应，因此该模式在空间上具有较高一致性。而短波辐射-气压因受云量、气溶胶干扰[71, 72]，呈现更强空间异质性。倒 U 型模式主要由比湿-气温（70.75%）和比湿-气压（65.32%）驱动。低比湿时湖面蒸发加速[73]导致水温下降，交互作用呈负效应；比湿升高至临界值时水汽扩散受阻，负效应减弱；超过阈值后气候条件剧变（如风速增加或云量增多），水温再次降低；高比湿时系统趋近热力学平衡[74]，效应增强速率减缓。效应交叉型模式突出表现为比湿-风速（70.75%）和短波辐射-风速（61.32%）。高风速增强湖水垂直混合[75]：冬季低比湿/辐射条件下，深层暖水提升表层温度，交互作用呈正效应但随因子增强递减；夏季高比湿/辐射时表层水温高于深层，交互作用转为负效应。低风速环境呈现反向规律。阈值约束型模式中，90%湖泊受降水与多因子交互影响。正阈值约束及模糊阈值约束集中于太阳辐射更强的南部[76]（占比78.05%/65.63%），负阈值约束集中于北部（90.91%），产生此作用是由于强太阳辐射使南部湖泊对气压-降水交互更敏感。

综上，无论协同模式的类型如何，因子之间相互作用的强度和方向都与各因子的状态密切相关，在交互效应中均存在常见的阈值约束。此外，不同因子与其他因子相互作用的“能力”也存在显著差异。例如，独立驱动作用最强的长波辐射，在各种协同模式中也广泛存在，这意味着它不仅独立影响着高原湖泊的水温，还擅长与其他因子以协同的方式相互关联。上述结果为进一步理解高原湖泊水温复杂的多因子协同驱动机制，制定湖泊生态环境综合管控措施提供了新的支持。

3.3 不足与展望

然而，受研究时间与方法限制，仍存在可进一步拓展的方向。其一，尽管本研究已关注到高原湖泊的独特性，但未将人为影响、湖泊形态、补给类型（如冰川融水、降水、地下水等）及周边生态环境等纳入考量指标，后续研究可以通过更精细化的研究加以验证这些因素对湖泊水温的影响。其二，在湖泊属性研究层面，未来可通过聚类分析、对比实验等方法，针对海拔、面积、补给类型等关键属性开展分组探讨，这将有助于进一步挖掘不同类型湖泊水温变化的共性规律与特性差异，例如冰川融水补给型湖泊对气温变化的敏感性、降水补给型湖泊与气象要素的关联机制等，从而为区域生态管理提供更具针对性的理论支撑。

4 结论

单个因子因其自身特性，对 LSWT 的驱动贡献度各不相同。LRAD 和 SRAD 对青藏高原的 LSWT 有着显著优先的主导影响，而 WIND 和 PREC 的影响则最小；TEMP、SHUM 和 PRES 产生的影响程度适中。这些因子的影响在大小和方向上各有不同，其中 LRAD、SHUM、SRAD、TEMP 与 LSWT 呈现出强烈的正相关关系，它们共同解释了湖泊表层水温变化中超过 80%的部分。总体而言，除了 PRES 和 WIND 的贡献度存在细微偏波动外，其他因子在整体和单个湖泊的尺度上的均表现一致趋势。

因子之间还通过交互效应和特定的协调驱动模式影响着高原湖泊的表层水温变化。在青藏高原，无论是从整体还是单个湖泊尺度来看，因子间交互效应都广泛存在。这些交互效应对因子各自取值变化较为敏感，会随着阈值范围变化而表现出动态的驱动贡献度和正、负方向性。同时，不同湖泊之间的因子间协同驱动模式存在显著差异。四类主导模式表现为线型模式、倒 U 型模式、效应交叉型模式和阈值约束型模式。其中，线型模式表明随着影响因子取值的变化，交互效应保持稳定一致；而其他模式则表明，在协同驱动过程中存在趋势变化的拐点和相应的阈值条件。

本研究提出的深度学习与 SHAP 可解释性分析融合框架，突破了传统物理模型的参数依赖与认知局限，为湖泊表层水温的研究提供新的视角。同时通过因子间交互作用及阈值的量化分析，揭示了气象因子影响水温过程中的非线性特征与协同效应，为青藏高原湖泊管理提供科学依据与决策支持。

致谢　数据来源于“国家青藏高原科学数据中心”(http://data.tpdc.ac.cn)

5 参考文献

[1] Zhu LP, Zhang GQ, Yang RM et al. Lake Variations on Tibetan Plateau of Recent 40 Years and Future Changing Tendency. *Bulletin of Chinese Academy of Sciences*, 2019, 34(11): 1254-1263. DOI: 10.16418/j.issn.1000-3045.2019.11.008. [朱立平,张国庆,杨瑞敏等. 青藏高原最近 40 年湖泊变化的主要表现与发展趋势.中国科学院院刊, 2019, 34(11): 1254-1263.]

[2] Zhou J, Leavitt P R, Rose K C, et al. Controls of thermal response of temperate lakes to atmospheric warming. *Nature Communications*, 2023, **14**(1): 6503. DOI: 10.1038/s41467-023-42262-x.

[3] Liu X, Feng J, Wang Y. Chlorophyll a predictability and relative importance of factors governing lake phytoplankton at different timescales. *Science of The Total Environment*, 2019, **648**: 472-480. DOI: 10.1016/j.scitotenv.2018.08.146.

[4] O'reilly C M, Sharma S, Gray D K, et al. Rapid and highly variable warming of lake surface waters around the globe. *Geophysical Research Letters*, 2015, **42**(24): 10,773-10,781. DOI: 10.1002/2015gl066235.

[5] Woolway R I, Sharma S, Weyhenmeyer G A, et al. Phenological shifts in lake stratification under climate change. *Nature Communications*, 2021, **12**(1): 2318. DOI: 10.1038/s41467-021-22657-4.
[6] Zhao QH, Sun GD, W JJ et al. Coupling effect of water temperature and light energy on the algal growth in Lake Taihu. *Journal of Lake Sciences*， 2018, **30**(02): 385-393. [赵巧华, 孙国栋, 王健健等. 水温、光能对春季太湖藻类生长的耦合影响. 湖泊科学, 2018, **30**(02): 385-393.]
[7] Wang JQ, Song YZ and Huang J.Effects of Increasing Water Temperature on Water Properties and Aquatic Organisms: A Critical Review. *Journal of Hydroecology*， 2020, **41**(01): 100-109. DOI: 10.15928/j.1674-3075.2020.01.014. [王锦旗, 宋玉芝, 黄进. 水温升高对水体性质及水生生物的影响研究进展. 水生态学杂志, 2020, **41**(01): 100-109.]
[8] Winslow L A, Leach T H, Rose K C. Global lake response to the recent warming hiatus. *Environmental Research Letters*, 2018, **13**(5): 054005. DOI: 10.1088/1748-9326/aab9d7.
[9] Sun F, He B, Liu C, et al. Comparison of Hydrological Patterns between Glacier-Fed and Non-Glacier-Fed Lakes on the Southeastern Tibetan Plateau. *Remote Sensing*, 2021, **13**(20): 4024. DOI: 10.3390/rs13204024.
[10] Zhu S, Ptak M, Choiński A, et al. Exploring and quantifying the impact of climate change on surface water temperature of a high mountain lake in Central Europe. *Environmental Monitoring and Assessment*, 2019, **192**(1): 7. DOI: 10.1007/s10661-019-7994-y.
[11] Wang X, Shi K, Zhang Y, et al. Climate change drives rapid warming and increasing heatwaves of lakes. *Science Bulletin*, 2023, **68**(14): 1574-1584. DOI: 10.1016/j.scib.2023.06.028.
[12] Xu L, Liu H, Mammarella I, et al. Characteristics of Energy Fluxes and Cold Frontal Effects on Energy Exchange over a Boreal Lake. *Advances in Atmospheric Sciences*, 2025, **42**(2): 357-372. DOI: 10.1007/s00376-024-3214-y.
[13] Van D J, Fernandez A, Bernasconi S M, et al. Spatial pattern of super-greenhouse warmth controlled by elevated specific humidity. *Nation Geoscience*. 2020, **13**(11): 739-744. DOI: 10.1038/s41561-020-00648-2.
[14] Xu H, Sheng LF and Chai YC. Variation of Surface Total Solar Radiation and Influencing Factors in Qingdao. *Periodical of Ocean University of China,* 2014, **44**(05):25-31. DOI: 10.16441/j.cnki.hdxb.2014.05.004. [徐华, 盛立芳, 柴艺淳. 青岛地面太阳总辐射变化特征及影响因子分析. 中国海洋大学学报(自然科学版). 2014, 44(05): 25-31.]
[15] Yang Y, Wang Y, Zhang Z, et al. Diurnal and Seasonal Variations of Thermal Stratification and Vertical Mixing in a Shallow Fresh Water Lake. *Journal of Meteorological Research*, 2018, **32**(2): 219-232. DOI: 10.1007/s13351-018-7099-5.
[16] Shinohara R, Matsuzaki S-I S, Watanabe M, et al. Heat Waves Can Cause Hypoxia in Shallow Lakes. *Geophysical Research Letters*, 2023, **50**(8): e2023GL102967. DOI: 10.1029/2023GL102967.
[17] Laura M V S, Maria D C C. Deterministic modelling of freshwater lakes and reservoirs: Current trends and recent progress. *Environmental Modelling & Software*, 2021, **144**: 105143. DOI: 10.1016/j.envsoft.2021.105143.
[18] Piccolroaz S, Toffolon M, Majone B. A simple lumped model to convert air temperature into surface water temperature in lakes. *Hydrology and Earth System Sciences*, 2013, **17**(8): 3323-3338. DOI: 10.5194/hess-17-3323-2013.
[19] Laanaya F, St-Hilaire A, and Gloaguen E. Water temperature modelling: comparison between the generalized additive model, logistic, residuals regression and linear regression models. *Hydrological Sciences Journal,* 2017, **62**(7): 1078-93. DOI: 10.1080/02626667.2016.1246799.
[20] Layden A, Maccallum SN, Merchant CJ. Determining lake surface water temperatures worldwide using a tuned one-dimensional lake model (FLake, v1). *Geoscientific Model Development,* 2016, **9**(6): 2167-2189. DOI: 10.5194/gmd-9-2167-2016.
[21] Kallel H, Thiboult A, Mackay MD, et al. Modeling Heat and Water Exchanges between the Atmosphere and an 85-km2 Dimictic Subarctic Reservoir Using the 1D Canadian Small Lake Model. *Journal of Hydrometeorology*. 2024, **25**(5): 689-707. DOI: 10.1175/JHM-D-22-0132.1.
[22] Piotrowski AP, Napiorkowski JJ, Zhu S, et al. Novel air2water model variant for lake surface temperature modeling with detailed analysis of calibration methods. *IEEE*, 2023, **16**: 553-569. DOI: 10.1109/JSTARS.2022.3226516.
[23] Toffolon M, Yousefi A and Piccolroaz S. Estimation of the thermally reactive layer in lakes based on surface water temperature. *Water Resources Research*, 2022, **58**(6): e2021WR031755. DOI: 10.1029/2021WR031755.
[24] Zhu S, Piotrowski A P, Ptak M, et al. How does the calibration method impact the performance of the air2water model for the forecasting of lake surface water temperatures?. *Journal of Hydrology,* 2021, **597**: 126219. DOI: 10.1016/j.jhydrol.2021.126219.
[25] Lecun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, **521**(7553): 436-444. DOI: 10.1038/nature14539.
[26] Guo Q, Jin S, Li M, et al. Application of deep learning in ecological resource research: Theories, methods, and challenges. *Science China Earth Sciences*, 2020, **63**(10): 1457-1474. DOI: 10.1007/s11430-019-9584-9.
[27] Brodrick P G, Davies A B, Asner G P. Uncovering Ecological Patterns with Convolutional Neural Networks. *Trends in Ecology & Evolution*, 2019, **34**(8): 734-745. DOI: 10.1016/j.tree.2019.03.006.
[28] Reichstein M, Camps-Valls G, Stevens B, et al. Deep learning and process understanding for data-driven Earth system science. *Nature*, 2019, **566**(7743): 195-204. DOI: 10.1038/s41586-019-0912-1.
[29] Jia X, Willard J, Karpatne A, et al. Physics-Guided Machine Learning for Scientific Discovery: An Application in Simulating Lake Temperature Profiles. *Association for Computing Machinery*, 2021, **2**(3). DOI: 10.1145/3447814.
[30] Willard J D, Read J S, Topp S, et al. Daily surface temperatures for 185,549 lakes in the conterminous United States estimated using deep learning (1980–2020). *Limnology and Oceanography Letters*, 2022, **7**(4): 287-301. DOI: 10.1002/lol2.10249.
[31] Wang L, Xu B, Zhang C, et al. Surface water temperature prediction in large-deep reservoirs using a long short-term memory model. *Ecological Indicators*, 2022, **134**: 108491. DOI: 10.1016/j.ecolind.2021.108491.
[32] Nunno FD, Zhu S, Ptak M, et al. A stacked machine learning model for multi-step ahead prediction of lake surface water temperature. *Science of The Total Environment*, 2023, **890**: 164323. DOI: 10.1016/j.scitotenv.2023.164323.
[33] Piccolroaz S, Zhu S, Ladwig R, et al. Lake Water Temperature Modeling in an Era of Climate Change: Data Sources, Models, and Future Prospects. *Reviews of Geophysics*, 2024, **62**(1): e2023RG000816. DOI: 10.1029/2023RG000816.
[34] Yu Z, Yang K, Luo Y, et al. Research on the Lake Surface Water Temperature Downscaling Based on Deep Learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, **14**: 5550-5558. DOI: 10.1109/JSTARS.2021.3079357
[35] Qiu R, Wang Y, Rhoads B, et al. River water temperature forecasting using a deep learning method. *Journal of Hydrology*, 2021, **595**: 126016. DOI: 10.1016/j.jhydrol.2021.126016..
[36] Liu C, Qi Y, Wang Z, et al. Deep learning: To better understand how human activities affect the value of ecosystem services-A case study of Nanjing. *PLOS ONE*, 2020, **15**(10): e0238789. DOI: 10.1371/journal.pone.0238789

[37] Li W, Ma D, Fu J, et al. A quantitative exploration of the interactions and synergistic driving mechanisms between factors affecting regional air quality based on deep learning. *Atmospheric Environment*, 2023, **314**: 120077. DOI: 10.1016/j.atmosenv.2023.120077.
[38] Lundberg S M, Lee S I. A Unified Approach to Interpreting Model Predictions; proceedings of the 31st Annual Conference on Neural Information Processing Systems (NIPS), Long Beach, CA, F Dec 04-09, 2017
[39] Tang Y, Duan A, Xiao C, et al. The Prediction of the Tibetan Plateau Thermal Condition with Machine Learning and Shapley Additive Explanation. *Remote Sensing*, 2022, **14**(17): 4169. DOI: 10.3390/rs14174169.
[40] García Vm, Aznarte JL. Shapley additive explanations for NO2 forecasting. *Ecological Informatics*, 2020, **56**: 101039. DOI: 10.1016/j.ecoinf.2019.101039.
[41] Hao J, Li JX, Lian ZX, et al. Analysis on Variation of Lakes and Its Influencing Drivers for the Qinghai-Tibet Plateau. *Journal of China Hydrology*, 2024, 44(01): 112-118. DOI: 10.19797/j.cnki.1000-0852.20220432. [郝洁，李靖瑄，连子旭等. 青藏高原湖泊面积变化规律及影响要素分析. 水文, 2024, **44**(01): 112-118.]
[42] Zhang G, Yao T, Xie H, et al. Response of Tibetan Plateau lakes to climate change: Trends, patterns, and mechanisms. *Earth-Science Reviews*, 2020, **208**: 103269. DOI: 10.1016/j.earscirev.2020.103269.
[43] Zhang G, Yao T, Xie H, et al. Lakes' state and abundance across the Tibetan Plateau. *Chinese Science Bulletin*, 2014, **59(**24): 3010-3021. DOI: 10.1007/s11434-014-0258-x.
[44] Guo L, Zheng H, Wu Y, et al. An integrated dataset of daily lake surface water temperature over Tibetan Plateau. *Earth System Science Data*, 2021, **14**(7): 3411-3422. DOI: 10.5194/essd-2021-151.
[45] Shi, K., Wang, X. Dataset of lake surface water temperature in China (1950-2100). *National Tibetan Plateau*, 2022. DOI: 10.11888/Terre.tpdc.300662. [施坤，王溪雯. 中国区域湖泊表层水温数据集（1950-2100）. 国家青藏高原数据中心, 2022.]
[46] Yang K, Jiang Y, Tang W, et al. A high-resolution near-surface meteorological forcing dataset for the Third Pole region（TPMFD, 1979-2023）. *National Tibetan Plateau,* 2023. DOI: https://doi.org/10.11888/Atmos.tpdc.300398. [阳坤，姜尧志，唐文君等. 第三极地区长时间序列高分辨率地面气象要素驱动数据集（TPMFD, 1979-2023）. 国家青藏高原数据中心, 2023.]
[47] Ye T, Yang H and Huo J. Change trends of runoffs in major river basins in Tibetan Autonomous Region and their causes. *Journal of Hydroelectric Engineering*, 2023, **42**(09): 46-57. [叶汀，杨汉波，霍军军. 西藏主要流域年径流的变化趋势及其原因. 水力发电学报. 2023, 42(09): 46-57.]
[48] She W, Yang Q, Yang K, et al. Spatiotemporal variation characteristics of snowfall- precipitation ratio on the Tibetan Plateau. *Advances in Water Science,* 2024, **35**(02): 348-356. DOI: 10.14042/j.cnki.32.1309.2024.02.015. [佘王康，杨勤丽，阳坤等. 青藏高原雪水比例时空变化特征. 水科学进展. 2024, **35**(02): 348-356.]
[49] Azadeh Y, Marco T. Critical factors for the use of machine learning to predict lake surface water temperature. *Journal of Hydrology*, 2022, **606**: 127418. DOI: 10.1016/j.jhydrol.2021.127418.
[50] Wang C, Qi Y, Zhu G. Deep learning for predicting the occurrence of cardiopulmonary diseases in Nanjing, China. *Chemosphere*, 2020, **257**: 127176. DOI: 10.1016/j.chemosphere.2020.127176.
[51] N. Moriasi D, G. Arnold J, W. Van Liew M, et al. Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. *Transactions of the ASABE*, 2007, **50**(3): 885-900. DOI: 10.13031/2013.23153.
[52] Wen J. Comparison of the Effects of MSE and MAE on Machine Learning Performance Optimization. Information & Computer, 2018, (15): 42-43. [文洁. MSE 与 MAE 对机器学习性能优化的作用比较. 信息与电脑(理论版), 2018, (15): 42-43.]
[53] Allen M, Poggiali D, Whitaker K, et al. Raincloud plots: a multi-platform tool for robust data visualization. *Wellcome Open Research*, 2019, **4**: 63. DOI: 10.12688/wellcomeopenres.15191.1
[54] Grant L, Vanderkelen I, Gudmundsson L, et al. Attribution of global lake systems change to anthropogenic forcing. *Nature Geoscience*, 2021, **14**(11): 849-854. DOI: 10.1038/s41561-021-00833-x.
[55] Woolway R I, Jennings E, Shatwell T, et al. Lake heatwaves under climate change. *Nature*, 2021, **589**(7842): 402-407. DOI: 10.1038/s41586-020-03119-1.
[56] Chappelle E W, Kim M S, Mcmurtrey J E. Ratio analysis of reflectance spectra (RARS): An algorithm for the remote estimation of the concentrations of chlorophyll A, chlorophyll B, and carotenoids in soybean leaves. *Remote Sensing of Environment*, 1992, **39**(3): 239-247. DOI: 10.1016/0034-4257(92)90089-3.
[57] Piccolroaz S, Zhu S, Ladwig R, et al. Lake Water Temperature Modeling in an Era of Climate Change: Data Sources, Models, and Future Prospects. *Reviews of Geophysics*, 2024, **62**(1): e2023RG000816. DOI: 10.1029/2023RG000816.
[58] Shi Y, Huang A, Ma W, et al. Drivers of Warming in Lake Nam Co on Tibetan Plateau Over the Past 40 Years. *Journal of Geophysical Research: Atmospheres*, 2022, **127:** e2021JD036320. DOI: 10.1029/2021JD036320.
[59] Ptak M, Tomczyk A M, Wrzesiński D. Effect of Teleconnection Patterns on Changes in Water Temperature in Polish Lakes. *Atmosphere*, 2018, **9**(2): 66. DOI: 10.3390/atmos9020066.
[60] Yang K, Yu Z, Luo Y, et al. Spatial-Temporal Variation of Lake Surface Water Temperature and Its Driving Factors in Yunnan-Guizhou Plateau. *Water Resources Research*, 2019, **55**(6): 4688-4703. DOI: 10.1029/2019WR025316.
[61] Woolway R I, Jennings E, Carrea L. Impact of the 2018 European heatwave on lake surface water temperature. *Inland Waters*, 2020, **10**(3): 322-332. DOI: 10.1080/20442041.2020.1712180.
[62] Noori R, Woolway R I, Jun C, et al. Multi-decadal change in summer mean water temperature in Lake Konnevesi, Finland (1984–2021). *Ecological Informatics*, 2023, **78**: 102331. DOI: 10.1016/j.ecoinf.2023.102331.
[63] Bai QQ, Liang EH, Wang T et al. Variation Characteristics of Surface Water Temperature and Their Response to Climate Change in Dongting Lake. *Acta Scientiarum Naturalium Universitatis Pekinensis*, 2022, **58**(02): 345-353. DOI: 10.13209/j.0479-8023.2022.004. [白倩倩，梁恩航，王婷等. 洞庭湖表层水温变化特征及其对气候变化的响应. 北京大学学报(自然科学版), 2022, **58**(02): 345-353.]
[64] Wen L, Wang C, Li Z, et al. Thermal Responses of the Largest Freshwater Lake in the Tibetan Plateau and Its Nearby Saline Lake to Climate Change. *Remote Sensing*, 2022, **14**(8): 1774. DOI: 10.3390/rs14081774.
[65] Huang L, Wang X, Yan Y, et al. Attribution of Lake Surface Water Temperature Change in Large Lakes Across China Over Past Four Decades. Journal of Geophysical Research: Atmospheres, 2023, **128**(21): e2022JD038465. DOI: 10.1029/2022JD038465.
[66] Lazhu, Yang K, Hou J, et al. A new finding on the prevalence of rapid water warming during lake ice melting on the Tibetan

Plateau. *Science Bulletin*, 2021, **66**(23): 2358-2361. DOI: 10.1016/j.scib.2021.07.022.
[67] Wu Y, Huang A, Li X, et al. Thermal Response of Large Seasonally Ice-Covered Lakes Over Tibetan Plateau to Climate Change. 2024, **129**(8): e2023JD039935. DOI: 10.1029/2023JD039935.
[68] Wen L, Lyu S, Kirillin G, et al. Air–lake boundary layer and performance of a simple lake parameterization scheme over the Tibetan highlands. *Tellus A: Dynamic Meteorology and Oceanography*, 2016, **68**(1): 31091. DOI: 10.3402/tellusa.v68.31091.
[69] Noori R, Woolway R I, Saari M, et al. Six Decades of Thermal Change in a Pristine Lake Situated North of the Arctic Circle. *Water Resources Research*, 2022, **58**(9): e2021WR031543. DOI: 10.1029/2021WR031543.
[70] Ma X, Yang K, La Z, et al. Importance of Parameterizing Lake Surface and Internal Thermal Processes in WRF for Simulating Freeze Onset of an Alpine Deep Lake. *Journal of Geophysical Research: Atmospheres*, 2022, **127**(18): e2022JD036759. DOI: 10.1029/2022JD036759..
[71] Nie X, Mao Q. Study on shortwave radiative transfer characteristics in polydisperse aerosols in a clear sky. *Infrared Physics & Technology*, 2021, **118**: 103903. DOI: 10.1016/j.infrared.2021.103903
[72] Zhou J, Zuo Z, He Q. Influence of Eurasian Spring Snowmelt on Surface Air Temperature in Late Spring and Early Summer %J Journal of Climate. *J. Climate*, 2021, **34**(20): 8191-8204. DOI: 10.1175/JCLI-D-21-0111.1
[73] Zhou J, Zhi R, Li Y, et al. Possible causes of the significant decrease in the number of summer days with light rain in the east of southwestern China. *Atmospheric Research*, 2020, **236**: 104804. DOI: 10.1016/j.atmosres.2019.104804.
[74] Tu J, Lu E. Relative importance of water vapor and air temperature in the interannual variation of the seasonal precipitation: a comparison of the physical and statistical methods. *Climate Dynamics*, 2020, **54**(7): 3655-3670. DOI: 10.1007/s00382-020-05197-3.
[75] Koue J, Shimadera H, Matsuo T, et al. Numerical Analysis of Sensitivity of Structure of the Stratification in Lake Biwa, Japan by Changing Meteorological Elements. *Water*, 2018, **10**(10): 1492. DOI: 10.3390/w10101492.
[76] Zhang L, Gao L, Zhao L, et al. Spatial And Temporal Characteristics Of Global Solar Radiation Over Qinghai-Tibetan Plateau Based On Itpcas Datase. *Acta Energiae Solaris Sinica,* 2019, 40(09): 2521-2529. DOI: 10.19912/j.0254-0096.2019.09.017. [张乐乐，高黎明，赵林等. 基于 ITPCAS 数据的青藏高原太阳总辐射时空变化特征. 太阳能学报. 2019, **40**(09): 2521-2529.