

基于机器学习的遥感蒸散发估算研究进展

陈图强^{1,2}, 李 晗^{1,2}, 黄津辉^{1,2}, 于宗远^{1,2}

(1. 南开大学环境科学与工程学院, 天津 300071; 2. 南开大学中加水与环境安全联合研发中心, 天津 300071)

摘要: 围绕机器学习在遥感蒸散发估算中的应用研究, 结合文献计量分析, 从多尺度回归预测、多源数据融合和物理机制耦合三方面系统梳理了基于机器学习的遥感蒸散发估算研究进展; 同时, 概述了目前常用的遥感反演参数, 阐述了各类主流机器学习模型的原理、优缺点和适用场景等。未来相关研究应提升输入数据质量, 降低遥感反演产品的不确定性, 推动可解释性机器学习算法的发展, 加强物理机制与机器学习模型的耦合, 进一步考虑气候变化背景下植被结构和生理调整给蒸散发估算带来的不确定性。

关键词: 蒸散发估算; 遥感; 气候变化; 机器学习; 物理机制

中图分类号: P426. 2 **文献标志码:** A **文章编号:** 1004 - 6933(2025)06 - 0095 - 10

Research progress on remote sensing-based evapotranspiration estimation using machine learning//CHEN Tuqiang^{1,2}, LI Han^{1,2}, HUANG Jinhui^{1,2}, YU Zongyuan^{1,2} (1. College of Environmental Science and Engineering, Nankai University, Tianjin 300071, China; 2. Sino-Canada Joint R&D Centre for Water and Environmental Safety, Nankai University, Tianjin 300071, China)

Abstract: Based on the application research of machine learning in remote sensing-based evapotranspiration estimation, combined with bibliometric analysis, this paper discusses the research progress of remote sensing-based evapotranspiration estimation using machine learning from three aspects: multi-scale regression prediction, multi-source data fusion, and physical mechanism coupling. At the same time, the commonly used remote sensing inversion parameters were outlined, and the principles, advantages and disadvantages, and applicable scenarios of various mainstream machine learning models were explained. Future related research should improve the quality of input data, reduce the uncertainty of remote sensing inversion products, promote the development of interpretable machine learning algorithms, strengthen the coupling between physical mechanisms and machine learning models, and further consider the uncertainty brought by vegetation structure and physiological adjustments to evapotranspiration estimation under the background of climate change.

Key words: evapotranspiration estimation; remote sensing; climate change; machine learning; physical mechanisms

蒸散发是全球陆地水文循环和能量收支的纽带, 约 50% 的净辐射通过蒸散转化为潜热通量, 60% 的降水通过蒸散返回大气^[1], 在干旱区这一比例甚至可达 90%^[2]。蒸散发主要由 3 部分组成: 土壤或水体的蒸发、植被表面截留的降水蒸发以及植被的蒸腾作用, 其中蒸腾约占蒸散发的 60%^[3]。自 20 世纪 80 年代以来, 全球陆地蒸散发呈上升趋势, 其变化与植被结构调整、土地利用变化以及大气 CO₂ 浓度的升高等密切相关^[4-5]。春季物候提前会增强植被蒸腾, 提高冠层对降水的截留, 并改变冠层与地表间的辐射分布, 从而相对减少地表蒸发^[6-7]。土地利用变化会影响植被截留能力、地表反照率、土

壤特性及植物蒸腾作用, 从而引起蒸散发的变化。CO₂ 浓度的升高通过施肥效应扩大叶面积, 改变植被蒸腾与林下土壤的蒸发^[3]。因此, 在气候变化背景下, 蒸散发受到多种生物物理因素的共同调控, 准确估算蒸散发对评估气候变化对水循环的影响、区域水资源管理以及精准灌溉优化等具有重要意义^[8], 但目前蒸散发估算仍存在较大不确定性。

相较于涡度相关、蒸渗仪和大孔径闪烁仪等传统观测手段^[9], 遥感技术的发展为区域乃至全球的蒸散发估算提供了低成本、高效率的解决方案。尽管蒸散发无法通过遥感直接测量, 但可借助短波、热红外和微波波段反演与蒸散发密切相关的参数, 为

基金项目: 国家重点研发计划项目(2021YFC3200404)

作者简介: 陈图强(1997—), 男, 博士研究生, 主要从事城市水文研究。E-mail: chentuqiang16@163.com

通信作者: 黄津辉(1969—), 女, 教授, 博士, 主要从事城市水文、生态水文及生态修复研究。E-mail: huangji@nankai.edu.cn

其估算提供支持^[1,10]。目前,基于遥感已经开发了多种蒸散发估算模型,主要包括物理过程模型和统计过程模型,其中物理过程模型主要包括 Penman-Monteith (PM) 或 Priestley-Taylor (PT) 模型、地表能量平衡模型、植被指数-地表温度空间模型^[11]。尽管这些模型已广泛应用于区域或全球的蒸散发估算,但其精度仍受到地表异质性、阻抗参数复杂性以及遥感数据误差的限制。

近年来,随着机器学习技术的不断发展,蒸散发的估算精度和效率得到了显著提升,其基本原理是通过建立观测蒸散发与各种输入变量间的线性或非线性关系,从而对蒸散发进行预测,有效减少了对输入参数和经验参数的依赖^[12-13]。目前有大量的地面与遥感观测数据积累,为机器学习在蒸散发估算领域的应用提供了有力支撑^[14]。尽管当前已有许多研究使用机器学习模型估算蒸散发,但对于机器学习在遥感蒸散发估算领域的应用进展依旧缺乏系统性的综述。鉴于此,本文从多尺度回归预测、多源数据融合和物理机制耦合三方面对现有研究进行归纳和总结,梳理当前常用的遥感反演参数,阐述主流机器学习模型的原理及优缺点,并指出当前在数据质量提升、算法优化和物理机理耦合等方面面临的挑战。

1 机器学习在蒸散发估算中的应用

机器学习模型在估算蒸散发的过程中并不需要依赖明确的物理机制^[15]。自 2010 年 Jung 等^[16]利用机器学习对全球通量塔数据进行建模估算蒸散发以来,机器学习在蒸散发研究中的应用受到了广泛关注。以“machine learning”和“evapotranspiration”为关键词,在 Web of Science 数据库进行检索,结果表明自 2019 年以来,相关研究的发文量快速增长(图 1)。此外,在不同类型的生态系统和气候区,使用机器学习模型进行蒸散发估算的决定系数普遍大于 0.80,均方根误差普遍小于 0.50 mm/d。部分研究表明,相较于传统方法,使用机器学习模型的估算精度提升幅度可达 13%~73%^[12]。依据现有研究,可以将机器学习在蒸散发估算中的应用分为 3 类:多尺度回归预测、多源数据融合、物理机制耦合。

1.1 多尺度回归预测

1.1.1 站点升尺度区域蒸散发估算

站点升尺度蒸散发估算先利用机器学习算法,基于站点尺度的地面气象数据、植被参数和土壤观测数据等,构建这些环境变量与实测蒸散发之间的关联模型。当研究尺度扩展到区域时,利用再分析气象数据集和遥感反演参数等作为输入,基于已建




图 1 2006—2023 年发文统计

Fig. 1 Publication statistics from 2006 to 2023

立的模型估算更大范围的蒸散发。例如,在黑河流域使用 36 个观测站点的通量数据、遥感叶面积指数和再分析气象数据,采用人工神经网络 (artificial neural network, ANN)、Cubist、深度置信网络 (deep belief network, DBN)、随机森林 (random forest, RF) 和支持向量机 (support vector machine, SVM) 等算法,先在站点尺度建立了环境变量与蒸散发之间的模型,并利用建立好的模型估算了整个流域的蒸散发^[17]。该方法可将站点训练好的机器学习模型应用于其他缺乏观测数据的区域,并提高估算的时空分辨率。然而该方法也存在一些缺点,包括气象数据集本身的不确定性、通量观测能量不闭合以及通量塔观测源区与遥感反演参数的空间尺度不匹配等,这些因素都会影响蒸散发估算的精度^[12,18]。

1.1.2 像元尺度蒸散发估算

在像元尺度,将陆面模式通量产品或再分析蒸散发产品作为目标变量,利用与蒸散发过程密切相关的环境变量作为输入特征,训练机器学习模型。例如,Liu 等^[19]将气象变量(气温、降水量和潜在蒸散发)、遥感反演的归一化植被指数 (normalized difference vegetation index, NDVI) 和地表水储量 (terrestrial water storage, TWS) 等作为输入变量,以 GLDAS 产品的蒸散发为目标变量,使用 SVM 和 RF 等算法,构建输入变量与蒸散发之间的关系,从而实现蒸散发估算。Musyimi 等^[20]将从 Sentinel-1 SAR 和 Sentinel-3 SLSTR 获取的植被及气象参数作为输入,从 WaPOR 获取的蒸散发作为目标变量,利用梯度提升决策树 (gradient boosted decision tree, GBDT) 建立输入变量与目标变量之间的关系,进而估算了蒸散发。这类方法虽然解决了遥感反演参数与通量观测源区尺度不匹配的问题,但是以陆面模式蒸散发产品作为参考真值的准确性有待考究,不同产品的估算结果存在较大差异^[21]。

1.1.3 流域降尺度蒸散发估算

在利用机器学习模型对蒸散发空间降尺度估算时,将流域尺度的观测蒸散发数据(如基于水量平

衡法获得的蒸散发)作为目标变量,选取与蒸散过程密切相关的环境变量(如气温、饱和水汽压差、相对湿度、太阳辐射等气象要素以及 NDVI、叶面积指数(leaf area index, LAI)等植被指数)作为模型的输入特征,在流域尺度训练机器学习模型。然后利用训练好的模型,将像元尺度的环境变量作为输入进行预测,从而实现从流域尺度向像元尺度的蒸散发空间降尺度估算。例如,Zeng 等^[22]基于地表水量平衡法,利用降水量、河流径流量以及 GRACE 卫星的 TWS 数据,获取了 95 个流域的蒸散发数据,并采用模型树集成(model tree ensemble, MTE)算法构建辐射、温度、降水量、风速、植被指数与蒸散发之间的模型,从而估算全球像元尺度的蒸散发。虽然这类方法原理简单,而且能够有效解决空间尺度不匹配的问题,但各组分的准确测量存在一定挑战,尤其是地表径流和降水数据的不确定性较高,影响了估算的精度。

1.2 多源数据融合

随着卫星遥感技术和地面观测网络的快速发展,催生了许多区域或全球尺度的蒸散发产品,如 MOD16 的蒸散发产品^[23]、基于 MTE 方法的产品^[16]、基于 PT 模型的蒸散发产品^[24]等。然而,由于输入数据和算法本身的限制以及校准系数的差异,蒸散发产品的精度在不同区域存在明显差异。例如,MOD16 产品主要使用北美洲站点的涡度协方差数据进行校正^[23],在部分盆地区域的不确定性高达 25%^[25];GLEAM(global land evaporation Amsterdam model)的产品在低纬度森林区域的精度优于中纬度地区^[26]。传统的数据融合方法,如简单平均、经验正交函数、简单泰勒融合、贝叶斯平均等,已被广泛应用于区域或全球尺度的蒸散发产品融合^[27]。这些方法在一定程度上提高了蒸散发估算的精度,但无法捕捉不同产品之间的非线性关系,限制了融合模型的表现力和适应性。相比之下,机器学习模型可根据蒸散发产品的特点动态调整权重参数,因而展现出更大的优势^[28]。

1.2.1 相同时空分辨率融合

在相同的时空分辨率下,将多种蒸散发产品作为机器学习模型的输入特征,将观测的蒸散发或作为参考真值的蒸散发产品作为目标变量训练模型,进而获得区域尺度上更高精度的估算。若输入的蒸散发产品由物理过程模型估算得到,使用机器学习的数据融合方法,可综合物理过程模型物理机制明确和机器学习算法回归预测能力强大的优点。例如,Yao 等^[28]使用机器学习算法融合了 MOD16、PT-JPL 和 SEMI-PM 3 种蒸散发产品,融合后的精度显

著提高,不同植被类型下的蒸散发估算均方根误差降低了 0.20~0.30 mm/d。尽管数据融合方法能够综合不同蒸散发产品的优势,平衡产品间的差异,但融合的精度依赖于所使用数据产品本身的精度、所选融合方法以及通量观测数据集的准确性^[29]。

1.2.2 不同时空分辨率融合

通过机器学习算法,将高时间分辨率但低空间分辨率的蒸散发产品与高空间分辨率但低时间分辨率的蒸散发产品进行融合,可获得高时空分辨率的蒸散发产品^[18]。例如,Ke 等^[30]将时空融合方法和机器学习降尺度方法相结合,构建了 3 种时空降尺度方案,以获取分辨率为 8 d、30 m 的实际蒸散发。具体而言,该方法使用机器学习算法将低空间分辨率、高时间分辨率的 MODIS 蒸散发数据采样到高空空间分辨率,并通过将 MODIS 与 Landsat 数据结合,在 Landsat 数据不可用时,生成高时间分辨率的蒸散发数据集。然而,由于地表蒸散发的动态变化,时空融合依然面临较大挑战^[18]。

1.3 物理机制耦合

机器学习无需考虑复杂的物理机制,可直接建立观测蒸散发与各种输入变量之间的线性或非线性关系来估算蒸散发^[15]。然而,也正因缺乏物理机制约束,如在极端热浪、干旱和植被稀疏等情况下,可能导致模型的估算精度和泛化能力降低^[31-32]。因此,将物理机制与机器学习耦合,可有效提高模型的泛化能力和可解释性^[14]。

1.3.1 耦合 PM 模型

在 PM 模型中,地表阻抗是影响蒸散发估算精度的关键参数,但难以直接测量^[33],这成为 PM 模型不确定性的主要来源^[34]。对此,目前已有部分研究采用机器学习算法对 PM 模型中地表阻抗进行估算^[14,31]。例如,使用深度神经网络(deep neural network, DNN)和 LightGBM 等算法预测地表阻抗,然后将预测的地表阻抗代入 PM 模型,替换传统的地表阻抗参数,从而实现机器学习算法与物理过程模型的耦合^[12,32],耦合后的模型精度显著提高,且在极端事件中表现良好。然而该方法也存在一些缺点:研究区通量观测站点分布不均导致使用数据的空间代表性不足,影响模型的泛化能力;物理定律与机器学习协作的过程存在不确定性,如物理模型的简化或输入不完备使推算结果偏离真实值以及机器学习模型可能存在过拟合问题;复杂数据源带来的不确定性,如气象站点和卫星观测等多源输入数据间的偏差。

1.3.2 耦合 PT 模型

PT 模型的物理机制较弱,其系数 α 受下垫面类

型和植被类型的影响较大,限制了蒸散发估算的精度。部分研究使用 DNN 用于预测该系数,并将预测的系数代入 PT 模型中进行蒸散发估算。例如,Chen 等^[35]将该方法应用于我国 480 个城市地区的蒸散发估算,取得了平均决定系数为 0.85、均方根误差为 0.33 mm/d 的较好效果,克服了传统 PT 模型在高异质性下垫面中估算精度有限的问题。此外,也可以使用机器学习模型替代 PT 模型中的子模块^[14,35],如使用 LightGBM 算法对 PT 模型中的土壤蒸发组分进行估算,均方根误差降低了 0.59 mm/d,Kling-Gupta 效率系数提高了 0.56^[32]。这种方法降低了阻抗参数给蒸散发估算带来的不确定性,且增强了计算不同蒸散发组分的能力,同时模型具有较强的泛化能力。

1.3.3 耦合能量平衡模型

地表能量平衡模型主要利用热红外传感器观测的地表温度来估算显热通量,将蒸散发计算为能量平衡余项^[36]。模型中的热传导阻力参数(r_h)通常被表示为地表粗糙度、植被和土壤变量的函数,其值在不同气候区和地表类型间的差异较大,是影响模型精度的重要因素。针对该问题,可使用机器学习模型估算 r_h ,然后将其代入显热通量计算公式,随后用于蒸散发估算。有研究表明,虽然耦合后的模型与原始机器学习模型相比,估算结果的精度相当,但可实现地表能量的闭合^[8]。此外,DNN 还被用于预测地表粗糙度,并将其代入 SEBS (surface energy balance system)模型中估算蒸散发,以减少能量不守恒带来的误差^[37]。

1.3.4 耦合特征空间模型

植被指数-地表温度空间模型的干湿边界确定难度较大,且随植被覆盖度呈非线性变化^[38]。在双源梯形模型中,土壤蒸发和植被蒸腾的变异率被假设为相同,然而由于植物根系水分利用来源的差异,两者通常表现出不同的变异率。对此,Hao 等^[39]提出了一种将梯形模型与 RF 模型耦合的解决方案。梯形模型基于地表温度和植被覆盖度的梯形空间,通过干湿边温度的划分,计算混合像元的土壤蒸发和植被蒸腾,并输出潜在蒸腾、冠层阻力等参数;RF 模型将遥感数据(如 MODIS 反演的地表温度和 LAI)、气象数据(如气温、风速)及梯形输出的参数作为输入,以通量塔观测的潜热通量为目标变量,对模型进行训练,实现了蒸散发的估算。

2 机器学习模型估算蒸散发的输入参数

蒸散发估算模型的构建依赖于地面观测数据和遥感反演数据,地面观测可提供较准确的蒸散发值,

而遥感反演弥补了地面观测空间范围较小的不足,是建立物理过程模型和机器学习模型的重要数据源^[10,32]。

2.1 地面观测数据

图 2 为 2006—2023 年机器学习模型中常用的地面观测数据和遥感反演参数使用情况,包括 NDVI、气温 T_a 、LAI、相对湿度 (relative humidity, RH)、风速 V_w 、降水量 P 、辐射 R_n 、增强植被指数 (enhanced vegetation index, EVI)、饱和水汽压差 (vapor pressure deficit, VPD)、土壤湿度 (soil moisture, SM)、地表温度 (land surface temperature, T_s)、光合有效辐射比例 (fraction of photosynthetically active radiation, FPAR)、大气二氧化碳浓度 C_{CO_2} 、数字高程模型 (digital elevation model, DEM)、土地利用和土地覆盖 (land use and land cover, LULC)、地表反照率 α 、日照时数 (sunshine duration, SSD)、植被高度 h_v 、地表储水量 TWS、植被类型 (plant functional type, PFT)、植被光学深度 (vegetation optical depth, VOD)。由图 2 可见, R_n 、 T_a 、 V_w 、RH、VPD、 P 等是蒸散发建模中最常用的地面观测数据。其中, R_n 为蒸散过程提供必要的能量条件,影响水分的蒸发和植物的蒸腾作用; T_a 影响气体扩散和水分蒸发,升高可加速水分的蒸发过程,同时在植被温度响应阈值之下促进蒸腾; VPD 表征空气的干燥程度,影响植物气孔的闭合,从而控制植物蒸腾、光合等生理过程,对生态系统蒸散过程有着重要影响; P 影响土壤和植物的水分供应,进而影响蒸发和蒸腾的速率。目前,地面观测数据可通过气象站、FLUXNET 观测网络等途径获取。此外,ERA5 和 MERRA2 等再分析数据集也提供了建模过程中常用的输入参数。




图 2 2006—2023 年机器学习模型输入参数使用次数
Fig.2 Usage frequency of input parameters for machine learning models from 2006 to 2023

2.2 遥感反演

2.2.1 光学遥感反演

地表温度作为地表与大气间长波辐射和湍流热

通量交换的关键驱动力,与地表水分状况密切相关^[1,40]。地表温度的反演方法主要包括辐射传输方程反演法、单通道算法和分裂窗算法。目前,MODIS、Landsat 和 Sentinel 等卫星的红外或热红外波段已被广泛应用于地表温度的反演。然而,由于地表植被覆盖、地形起伏和土壤特性等因素在空间上的高度异质性,地表温度的反演依旧面临较大的挑战。与其他遥感反演参数相比,热红外遥感获取的地表温度通常空间分辨率较低,限制了其在高精度能量平衡估算中的应用。此外,地表反照率也常被作为蒸散发估算模型中的一个关键变量,反映了地表对短波辐射的反射能力,间接影响地表辐射能的可用量,进而影响蒸散发过程^[15,41]。自然地表反照率范围较广,通常为 0.04~0.80^[1]。

植被的结构特征、生长阶段以及生理状态对蒸散发过程有着显著影响。因此在大尺度蒸散发估算中,植被参数的遥感反演是关键环节。NDVI、LAI 和 EVI 等已被广泛应用于蒸散发估算建模^[1,41-42]。NDVI 通过近红外波段和红光波段的反射率计算得到,主要用来衡量地表植被的覆盖程度和生长活力,但容易受背景土壤颜色、大气条件、云量分布以及叶冠阴影等因素的干扰;EVI 是 NDVI 的改进指数,有效减少了大气气溶胶和土壤背景散射的干扰,尤其在高密度植被覆盖区域,对植被动态变化的检测灵敏度有了显著提升;LAI 作为表征植被生长状况和冠层结构的关键生物物理参数,是单位地表面上植物绿色叶片的单面面积总和,被广泛应用于地表蒸散、光合作用与碳汇过程的模拟^[43]。然而在高大且冠层结构复杂的森林中,叶片之间的相互遮荫会影响 LAI 反演的准确性。尽管这些通过遥感反演得到的植被参数对蒸散发估算至关重要,但实际反演过程中,误差来源却较为复杂。传感器自身的噪声、云层覆盖的干扰、大气条件的影响、阴影效应的存在、时空分辨率的限制以及卫星观测角度等因素,都会在不同程度上给植被参数的反演带来误差^[1]。

2.2.2 微波遥感反演

SM 是影响蒸散发及其时空分布的关键因素之一。依据传感器类型和电磁波频段的不同,可利用光学遥感和微波遥感对 SM 进行监测。在可见光-近红外波段,利用 Landsat 或 MODIS 等多光谱遥感数据构建干旱指数或植被指数,以反映土壤含水量的变化^[44]。与光学遥感相比,微波遥感具有一定的穿透能力,不受云层和大气的影 响,如 SMAP 和 SMOS 土壤水分产品^[45]。然而,当前各类遥感土壤水分产品在时空分辨率和精度上差异较大,光学遥感易受天气条件制约,微波遥感受大气干扰小,却受

限于自身分辨率,难以捕捉小尺度水分异质性。此外,SM 本身受土壤理化性质、植被生理特性、气象因子等多种因素的影响,目前还缺乏定量评估这些因素对蒸散发估算精度影响的研究。除了土壤含水量,植被自身的水分状况也不容忽视。植被含水量通过调控气孔开闭直接影响蒸腾过程,而 VOD 作为一个关键参数,恰好能表征植物体内的水分含量。例如,Koppa 等^[13]的研究将 VOD 作为 GLEAM 中的水分胁迫因子,在全球尺度蒸散发估算中取得了较好效果。但需要注意的是,茂密的植被冠层可能导致 VOD 反演出现偏差。

2.2.3 基于重力遥感的水量平衡推算

在水量平衡法中,借助 GRACE 卫星反演的 TWS 数据,可以同时结合降水量、径流量等数据来估算区域蒸散发^[46-47]。然而,由于观测方式以及搭载传感器本身的局限性,TWS 数据不可避免地存在多种误差。一方面,重力场误差是较为突出的问题,这种误差在高阶项球谐系数上体现得尤为明显,而且随着球谐系数阶数不断升高,误差还会进一步加大;另一方面,GRACE 卫星通过监测南北方向上两颗轨道卫星之间的距离变化来获取数据,这种独特的观测机制使得数据中不可避免地出现南北方向的条带噪声^[48-49]。

3 常用于蒸散发估算的机器学习算法及其原理

在蒸散发估算中,使用到的机器学习模型包括:RF、LightGBM、SVM、DBN、ANN、DNN、GBDT、卷积神经网络(convolutional neural network, CNN)、K 近邻算法(K-nearest neighbors, KNN)、LASSO 回归、长短期记忆网络(long short-term memory network, LSTM)、循环神经网络(recurrent neural network, RNN)、极端梯度提升(extreme gradient boosting, XGBoost)、Cubist 递归分割规则模型(Cubist)、极限学习机(extreme learning machine, ELM)、高斯过程回归(Gaussian process regression, GPR)、广义回归神经网络(generalized regression neural networks, GRNNs)、M5 模型树(M5 model tree, M5)、多元自适应回归样条(multivariate adaptive regression splines, MARS)、多层感知器(multilayer perceptron, MLP)、多元线性回归(multiple linear regression, MLR)、MTE、径向基函数网络(radial basis function network, RBF)等。图 3 为 2006—2023 年机器学习模型的使用次数,图 4 为 2014—2023 年机器学习模型的相对使用率。本文针对高频使用的机器学习模型的原

理、优缺点、适用场景及评价指标进行进一步讨论。




图 3 2006—2023 年机器学习模型的使用次数
Fig. 3 Usage frequency of machine learning models from 2006 to 2023




图 4 2014—2023 年部分机器学习模型的相对使用率
Fig. 4 Relative usage rate of part of machine learning models from 2014 to 2023

3.1 基于决策树的算法

2001 年, Breiman^[50] 提出了 RF 算法, 核心思想是将多个彼此相对独立的决策树(即弱学习器)集合起来对数据进行分类或回归。RF 算法会综合多个决策树的预测结果, 通过求平均值(用于回归)或者投票(用于分类)的方式得出最终结果, 使模型的预测性能得到提升。RF 算法不需要对数据分布做任何假设, 对噪声、离群值和缺失数据具有较强的鲁棒性。凭借出色的复杂模式学习能力, RF 算法被广泛应用于蒸散发估算^[1, 17]。多项研究表明, 在使用 ANN、Cubist、深度置信网络、RF 和 SVM 等机器学习算法估算蒸散发时, RF 算法在估算精度上表现最佳^[15, 17, 51]。虽然 RF 算法结构相对简单且易于实现, 但若构建模型时决策树数量太多, 或者输入变量之间相关性太强, 则容易出现过拟合的问题^[1]。Granata^[52] 的研究表明, RF 算法在不同输入参数条件下, 蒸散发估算精度可能会出现较大差异, 表明在使用 RF 算法时输入变量的选择和调参过程至关重要。

GBDT 算法通过对一系列较小的决策树进行迭代, 每次迭代都会拟合上一轮模型产生的残差, 逐步优化模型的整体性能, 并非像 RF 算法中通过对多个决策树的结果取均值。XGBoost 在 GBDT 的基础上做了改进, 引入了正则化技术对模型进行约束, 提升了模型的泛化能力^[53]。此外, LightGBM 作为 GBDT 的改进版本, 采用了基于直方图的学习方法、Leaf-wise 生长策略, 还支持并行计算、分布式处理, 并且能直接处理类别特征, 提高了模型的训练速度和性能^[54]。部分研究表明, GBDT、XGBoost、LightGBM 模型能够获得比 ANN 和 RF 更优的精度^[55-56]。但也有一些研究指出, 使用这些 GBDT 算法估算蒸散发时精度提升并不明显^[8, 12, 57]。

3.2 基于支持向量的算法

SVM 的基本原理是要找到一个超平面, 利用这个超平面把数据集清晰地划分成两个类别, 让每个类别的数据都处于超平面的一侧^[58]。核函数的引入可使样本能够映射到更高维的空间, 从而解决原始空间中线性不可分的问题。常见的核函数包括线性核、多项式核、RBF 核和 Sigmoid 核。核函数的选择会影响最终的预测结果, 许多研究表明, RBF 核通常能够提供更为准确的估算蒸散发^[59]。在实际应用中, SVM 对数据噪声和异常值具有较强的稳定性, 且能通过正则化参数控制模型的复杂性, 有效降低过拟合风险^[60]。多项研究采用 SVM 对蒸散发进行估算获得了较高的精度^[61-62]。然而, SVM 的性能依赖于合适的超参数调整, 且在处理大型数据集时, 对计算资源和时间的需求较高, 这给模型的应用带来了一定的挑战^[1]。

3.3 基于神经网络的算法

ANN 的结构通常包含输入层、隐藏层和输出层, 每层由多个神经元构成。神经元通过学习权重对输入信号进行加权计算, 并使用激活函数引入非线性特征。ANN 的工作过程可以分为两部分: 在前向传播时, 输入数据会逐层传递到输出层以产生预测结果; 随后进入反向传播阶段, 算法会根据预测误差, 反过来调整各层的连接权重, 通过不断迭代来缩小预测值与真实值之间的差距, 从而实现对复杂数据关系的学习^[10]。传统的 ANN 通常有 1~2 个隐藏层, MLP 是最早的 ANN 之一; 若在 ANN 的基础上引入更多隐藏层, 便形成了 DNN。DNN 的隐藏层数量从十几个到数百个不等, 能在处理大规模和高维数据时展现出较强的能力。多项研究表明, 在蒸散发估算中, 采用 ANN、MLP、DNN 等方法能够显著提升蒸散发估算的精度^[35, 58, 63]。然而, 这些算法普遍存在模型结构复杂、可解释性较差以及易发生过拟合

等问题。此外,对计算资源和内存的需求较高,训练过程往往依赖于大规模样本,导致训练时间较长且成本较高^[1]。

由于不同机器学习模型在输入变量适配性、数据规模要求以及区域特征响应等方面各有差异,选择最优模型已成为影响蒸散发估算精度的关键环节。因此,有必要对多种机器学习模型的预测性能进行系统评估,以筛选最适用于目标区域的模型。常用的评价指标包括决定系数、均方根误差、平均绝对误差、偏差、纳什效率系数、综合性能指数、Kling-Gupta 效率系数等。其中,决定系数、纳什效率系数、综合性能指数、Kling-Gupta 效率系数的值越接近 1,表示模型对数据的拟合能力越强;均方根误差、平均绝对误差和偏差的值越小表示预测误差越低,模型精度越高。通过对不同模型的评价指标进行对比,能更有效地选择出最适合区域尺度蒸散发估算的最优模型。

4 现存问题及展望

4.1 数据层面

a. 数据质量问题。数据质量始终是传统物理模型与机器学习模型在蒸散发估算中面临的共性难题。不同于物理模型具有物理机制约束,机器学习模型对输入数据的完整性和准确性更为敏感,数据误差可能会被进一步放大。例如,再分析气象数据在不同区域的精度参差不齐,而涡度相关法测得的数据常因仪器噪声、数据处理不确定性以及下垫面异质性等因素出现能量不闭合现象,将直接影响模型的可靠性。对此,需要推动高质量地面观测网络的布局,通过强化数据共享机制,提升观测数据在时空维度上的覆盖度和连续性。针对再分析数据的区域适应性问题,可结合本地观测数据进行校准修正。此外,对于涡度相关观测中的能量不闭合问题,除了运用能量余项法、波文比法等进行数据修正,还需进一步深入研究其影响机制。

b. 尺度效应与转换。在将站点尺度的通量观测数据拓展至遥感像元尺度时,两者的尺度差异往往会引入误差。当地表下垫面相对均质时,直接采用通量观测仪器实测数据或周边像元平均值作为输入,估算误差通常较小,但当下垫面空间异质性较大时,误差可能显著增大。对此,一方面可借助遥感数据尺度转换与重采样技术,调整像元分辨率或构建多尺度数据融合框架,在空间上实现遥感数据与站点观测数据的尺度匹配;另一方面可使用通量足迹模型对观测点周边不同区域赋予不同的贡献权重,精准量化各区域对通量观测值的实际影响。

c. 遥感产品真实性检验不足。作为蒸散发估算模型的核心输入数据,地表温度、土壤湿度、植被指数等遥感产品的准确性直接关系到估算结果的可靠性。然而,受陆面过程复杂性、卫星产品多样性及动态变化特征的影响,目前用于验证这些遥感数据的地面观测数据仍存在不足,尤其在非均匀下垫面的区域^[64]。因此,未来可深入分析地面观测数据的空间代表性,优化地面通量站点布设,覆盖典型的非均匀下垫面区域,并建立星、机、地一体化的观测网络,以提高数据的准确性和可靠性。

4.2 算法层面

a. 机器学习算法的黑箱特性。当模型复杂度较高时,其预测过程往往呈现较强的不透明性,尤其是在面对极端气候事件导致的异常数据时,难以解释误差来源。此外,在训练过程中,模型容易因数据噪声或参数设置等问题陷入局部最优或出现过拟合现象,导致模型泛化能力下降,稳定性不足。对此,近年来的研究开始关注可解释性技术的引入,通过结合可解释性机器学习算法或通用解释工具,采用 LIME (local interpretable model-agnostic explanations) 局部解释框架和 SHAP (Shapley additive explanations) 值进行归因分析等提高模型的透明度,使模型的决策过程更易理解。

b. 物理机制不足。当前,多数耦合模型的研究是对建模过程中的某个环节进行耦合,如将物理过程模型的输出直接作为机器学习的输入特征,或在物理模型的某个具体模块中嵌入机器学习算法。尽管这类方法在一定程度上结合了物理机制的约束性与机器学习的灵活性,但该领域仍处于初级阶段^[65]。未来研究可尝试在建模的全生命周期中,通过迭代优化的方式将机器学习深度融入物理过程模型,形成“机理指导-数据拟合-机制反推”的闭环迭代模式。

4.3 机制层面

缺乏气候变化对植被生理影响的考虑。在蒸散发的构成中,植被蒸腾是驱动陆地水分循环占比超过 60%的关键过程。然而,当前模型在考虑气候变化影响时,对植被生理机制的考虑不足。极端热浪、干旱等气候事件频发背景下,植物根系的水分吸收效率、导管运输阻力等水力学过程会发生显著改变,将直接影响植物的蒸腾,进而改变区域水分平衡。然而,现有模型尚未充分考虑植物水力学过程。在未来的模型架构中,可引入基于植物生理指标的动态反馈机制,如使用机器学习算法捕捉水力学过程与环境因子的复杂耦合关系。

5 结 语

机器学习在遥感蒸散发估算中应用广泛,相关

探索不仅拓展了蒸散发估算的技术路径,也在区域乃至全球尺度的水分循环研究中展现出重要的意义。通过挖掘站点气象数据、再分析气象数据及遥感反演参数与蒸散发间的关联,各类机器学习模型建立起了数据驱动的蒸散发估算框架。当前基于机器学习的蒸散发估算主要有 3 种类型:多尺度回归预测、多源数据融合、耦合物理机制。这些方法不仅为大范围蒸散发估算提供了可行方案,更通过捕捉复杂非线性关系,提升了极端气候条件下的模型泛化能力。随着机器学习算法的进步,对高数据体量的处理效率大幅提升,为气候变化下蒸散过程的复杂响应提供了技术支撑。然而,目前仍面临数据质量不高、算法黑箱特性和植被生理机制耦合不足的挑战。未来研究应聚焦于提升数据质量与观测网络建设,采用可解释性算法提高模型透明度,并将植物生理过程纳入模型。

参考文献:

[1] AMANI S, SHAFIZADEH-MOGHADAM H. A review of machine learning models and influential factors for estimating evapotranspiration using remote sensing and ground-based data[J]. *Agricultural Water Management*, 2023, 284: 108324.

[2] ALLEN R G, TASUMI M, TREZZA R. Satellite-based energy balance for mapping evapotranspiration with internalized calibration (METRIC)-model[J]. *Journal of Irrigation and Drainage Engineering*, 2007, 133 (4): 380-394.

[3] YANG Yuting, RODERICK M L, GUO Hui, et al. Evapotranspiration on a greening earth [J]. *Nature Reviews Earth & Environment*,2023,4(9):626-641.

[4] ZHANG Wenmin, KOCH J L, WEI Fangli, et al. Soil moisture and atmospheric aridity impact spatio-temporal changes in evapotranspiration at a global scale[J]. *Journal of Geophysical Research: Atmospheres*, 2023, 128 (8): e2022JD038046.

[5] PAN Shufen, TIAN Hanqin, DANGAL S R S, et al. Responses of global terrestrial evapotranspiration to climate change and increasing atmospheric CO₂ in the 21st Century[J]. *Earth's Future*,2015,3(1):15-35.

[6] GU Hongshuang, QIAO Yuxin, XI Zhenxiang, et al. Warming-induced increase in carbon uptake is linked to earlier spring phenology in temperate and boreal forests [J]. *Nature Communications*,2022,13(1):3698.

[7] LI Yang, ZHANG Wen, SCHWALM C R, et al. Widespread spring phenology effects on drought recovery of Northern Hemisphere ecosystems[J]. *Nature Climate Change*,2023,13(2):182-188.

[8] CHEN Han, GHANI RAZAQPUR A, WEI Yizhao, et al. Estimation of global land surface evapotranspiration and its

trend using a surface energy balance constrained deep learning model [J]. *Journal of Hydrology*, 2023, 627: 130224.

[9] ZHANG Z, TIAN F, HU H, et al. A comparison of methods for determining field evapotranspiration: photosynthesis system, sap flow, and eddy covariance [J]. *Hydrology and Earth System Sciences*,2014,18(3):1053-1072.

[10] CHIA M Y, HUANG Y F, KOO C H, et al. Recent advances in evapotranspiration estimation using artificial intelligence approaches with a focus on hybridization techniques:a review[J]. *Agronomy*,2020,10(1):101.

[11] ZHANG Ke, KIMBALL J S, RUNNING S W. A review of remote sensing based actual evapotranspiration estimation [J]. *WIREs Water*,2016,3(6):834-853.

[12] CHEN Han, HUANG J J, DASH S S, et al. A hybrid deep learning framework with physical process description for simulation of evapotranspiration[J]. *Journal of Hydrology*, 2022,606:127422.

[13] KOPPA A, RAINS D, HULSMAN P, et al. A deep learning-based hybrid model of global terrestrial evaporation [J]. *Nature Communications*, 2022, 13 (1): 1912.

[14] REICHSTEIN M, CAMPS-VALLS G, STEVENS B, et al. Deep learning and process understanding for data-driven earth system science [J]. *Nature*, 2019, 566 (7743): 195-204.

[15] TALIB A, DESAI A R, HUANG Jingyi, et al. Evaluation of prediction and forecasting models for evapotranspiration of agricultural lands in the midwest US [J]. *Journal of Hydrology*,2021,600:126579.

[16] JUNG M, REICHSTEIN M, CIAIS P, et al. Recent decline in the global land evapotranspiration trend due to limited moisture supply [J]. *Nature*,2010,467(7318):951-954.

[17] XU Tongren, GUO Zhixia, LIU Shaomin, et al. Evaluating different machine learning methods for upscaling evapotranspiration from flux towers to the regional scale [J]. *Journal of Geophysical Research: Atmospheres*, 2018,123(16):8674-8690.

[18] 刘萌,唐荣林,李召良,等.数据驱动的蒸散发遥感反演方法及产品研究进展 [J]. *遥感学报*, 2021, 25 (8): 1517-1537. (LIU Meng, TANG Ronglin, LI Zhaoliang, et al. Progress of data-driven remotely sensed retrieval methods and products on land surface evapotranspiration [J]. *National Remote Sensing Bulletin*, 2021, 25 (8): 1517-1537. (in Chinese))

[19] LIU Yuan, YUE Qimeng, WANG Qianyang, et al. A framework for actual evapotranspiration assessment and projection based on meteorological, vegetation and hydrological remote sensing products [J]. *Remote Sensing*,2021,13(18):3643.

[20] MUSYIMI P K, SAHBENI G, TIMÁR G, et al. Actual evapotranspiration estimation using sentinel-1 SAR and

- sentinel-3 SLSTR data combined with a gradient boosting machine model in Busia County, Western Kenya [J]. *Atmosphere*, 2022, 13(11):1927.
- [21] JIMÉNEZ C, PRIGENT C, MUELLER B, et al. Global intercomparison of 12 land surface heat flux estimates[J]. *Journal of Geophysical Research: Atmospheres*, 2011, 116(D2):D02102.
- [22] ZENG Zhenzhong, WANG Tao, ZHOU Feng, et al. A worldwide analysis of spatiotemporal changes in water balance-based evapotranspiration from 1982 to 2009[J]. *Journal of Geophysical Research: Atmospheres*, 2014, 119(3):1186-1202.
- [23] MU Qiaozhen, ZHAO Maosheng, RUNNING S W. Improvements to a MODIS global terrestrial evapotranspiration algorithm [J]. *Remote Sensing of Environment*, 2011, 115(8):1781-1800.
- [24] MARTENS B, MIRALLES D G, LIEVENS H, et al. GLEAM v3:satellite-based land evaporation and root-zone soil moisture[J]. *Geoscientific Model Development*, 2017, 10(5):1903-1925.
- [25] VELPURI N M, SENAY G B, SINGH R K, et al. A comprehensive evaluation of two MODIS evapotranspiration products over the conterminous United States:using point and gridded FLUXNET and water balance ET[J]. *Remote Sensing of Environment*, 2013, 139:35-49.
- [26] SALAZAR-MARTÍNEZ D, HOLWERDA F, HOLMES T R H, et al. Evaluation of remote sensing-based evapotranspiration products at low-latitude eddy covariance sites[J]. *Journal of Hydrology*, 2022, 610:127786.
- [27] SHANG Ke, YAO Yunjun, LIANG Shunlin, et al. DNN-MET:a deep neural networks method to integrate satellite-derived evapotranspiration products, eddy covariance observations and ancillary information [J]. *Agricultural and Forest Meteorology*, 2021, 308-309:108582.
- [28] YAO Yunjun, LIANG Shunlin, LI Xianglan, et al. Improving global terrestrial evapotranspiration estimation using support vector machine by integrating three process-based algorithms[J]. *Agricultural and Forest Meteorology*, 2017, 242:55-74.
- [29] ZHANG Caiyun, BRODYLO D, RAHMAN M, et al. Using an object-based machine learning ensemble approach to upscale evapotranspiration measured from eddy covariance towers in a subtropical wetland [J]. *Science of the Total Environment*, 2022, 831:154969.
- [30] KE Yinghai, IM J H, PARK S Y, et al. Spatiotemporal downscaling approaches for monitoring 8-day 30 m actual evapotranspiration[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 126:79-93.
- [31] ZHAO Wenli, GENTINE P, REICHSTEIN M, et al. Physics-constrained machine learning of evapotranspiration [J]. *Geophysical Research Letters*, 2019, 46(24):14496-14507.
- [32] SHANG Ke, YAO Yunjun, DI Zhenhua, et al. Coupling physical constraints with machine learning for satellite-derived evapotranspiration of the Tibetan Plateau [J]. *Remote Sensing of Environment*, 2023, 289:113519.
- [33] BIFTU G F, YEW GAN T. Assessment of evapotranspiration models applied to a watershed of Canadian prairies with mixed land-uses [J]. *Hydrological Processes*, 2000, 14(7):1305-1325.
- [34] STEWART J B. Modelling surface conductance of pine forest [J]. *Agricultural and Forest Meteorology*, 1988, 43(1):19-35.
- [35] CHEN Han, WEI Yizhao, HUANG Jinhui. Altered landscape pattern dominates the declined urban evapotranspiration trend[J]. *Journal of Hydrology*, 2023, 627:130296.
- [36] 李晗, 陈晗, 黄津辉, 等. 区域遥感双源蒸散发模型研究进展[J]. *水资源保护*, 2022, 38(4):87-94. (LI Han, CHEN Han, HUANG Jinhui, et al. Research progress on dual-source evapotranspiration models based on regional remote sensing[J]. *Water Resources Protection*, 2022, 38(4):87-94. (in Chinese))
- [37] HU Xiaolong, SHI Liangsheng, LIN Guang, et al. Comparison of physical-based, data-driven and hybrid modeling approaches for evapotranspiration estimation [J]. *Journal of Hydrology*, 2021, 601:126592.
- [38] CHEN Han, HUANG J J, DASH S S, et al. A non-linear theoretical dry/wet boundary-based two-source trapezoid model for estimation of land surface evapotranspiration [J]. *Hydrological Sciences Journal*, 2023, 68(11):1591-1609.
- [39] HAO Pengyu, DI Liping, GUO Liying. Estimation of crop evapotranspiration from MODIS data by combining random forest and trapezoidal models [J]. *Agricultural Water Management*, 2022, 259:107249.
- [40] CHEN J M, LIU J. Evolution of evapotranspiration models using thermal and shortwave remote sensing data [J]. *Remote Sensing of Environment*, 2020, 237:111594.
- [41] CARTER C, LIANG Shunlin. Evaluation of ten machine learning methods for estimating terrestrial evapotranspiration from remote sensing [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2019, 78:86-92.
- [42] ZHANG Chen, LUO Geping, HELLWICH O, et al. A framework for estimating actual evapotranspiration at weather stations without flux observations by combining data from MODIS and flux towers through a machine learning approach [J]. *Journal of Hydrology*, 2021, 603:127047.
- [43] FANG Hongliang, BARET F, PLUMMER S, et al. An overview of global leaf area index (LAI): methods, products, validation, and applications [J]. *Reviews of Geophysics*, 2019, 57(3):739-799.

- [44] 潘宁,王帅,刘焱序,等. 土壤水分遥感反演研究进展[J]. 生态学报,2019,39(13):4615-4626. (PAN Ning, WANG Shuai, LIU Yanxu, et al. Advances in soil moisture retrieval from remote sensing[J]. Acta Ecologica Sinica, 2019,39(13):4615-4626. (in Chinese))
- [45] 何涯舟,张珂,晁丽君,等. 基于多源卫星遥感产品的土壤湿度融合与降尺度研究[J]. 河海大学学报(自然科学版),2022,50(6):40-46. (HE Yazhou, ZHANG Ke, CHAO Lijun, et al. Study on soil moisture merging and downscaling based on multi-source satellite remote sensing products[J]. Journal of Hohai University (Natural Sciences), 2022,50(6):40-46. (in Chinese))
- [46] ZHAO Meng, GERUO A, LIU Yanlan, et al. Evapotranspiration frequently increases during droughts[J]. Nature Climate Change,2022,12(11):1024-1030.
- [47] 鞠艳,张珂,李炳锋,等. 金沙江流域实际蒸散发时空分布特征及其影响因子[J]. 水资源保护,2022,38:104-110. (JU Yan, ZHANG Ke, LI Bingfeng, et al. Spatiotemporal distribution of actual evapotranspiration and its influencing factors in the Jinsha River Basin[J]. Water Resources Protection, 2022,38(6):104-110. (in Chinese))
- [48] 冯哲颖,岳林蔚,沈焕锋. 基于多源水文数据融合的GRACE水储量精度校正[J]. 遥感技术与应用,2021,36(3):605-617. (FENG Zheyang, YUE Linwei, SHEN Huanfeng. Accuracy correction of GRACE water storage based on multi-source hydrological data[J]. Remote Sensing Technology and Application, 2021,36(3):605-617. (in Chinese))
- [49] SOLTANI S S, ATAIE-ASHTIANI B, SIMMONS C T. Review of assimilating GRACE terrestrial water storage data into hydrological models: advances, challenges and opportunities[J]. Earth-Science Reviews, 2021, 213: 103487.
- [50] BREIMAN L. Random forests[J]. Machine Learning, 2001,45(1):5-32.
- [51] PAGANO A, AMATO F, IPPOLITO M, et al. Machine learning models to predict daily actual evapotranspiration of citrus orchards under regulated deficit irrigation[J]. Ecological Informatics,2023,76:102133.
- [52] GRANATA F. Evapotranspiration evaluation models based on machine learning algorithms:a comparative study[J]. Agricultural Water Management,2019,217:303-315.
- [53] ZHANG Ping, JIA Yiqiao, SHANG Youlin. Research and application of XGBoost in imbalanced data[J]. International Journal of Distributed Sensor Networks, 2022,18(6):155013292211069.
- [54] ANGHEL A, PAPANDREOU N, PARNELL T, et al. Benchmarking and optimization of gradient boosting decision tree algorithms[J]. ArXiv,2018,1809:04559.
- [55] HE Xinlei, LIU Shaomin, XU Tongren, et al. Improving predictions of evapotranspiration by integrating multi-source observations and land surface model[J]. Agricultural Water Management,2022,272:107827.
- [56] STAPLETON A, EICHELMANN E, ROANTREE M. A framework for constructing machine learning models with feature set optimisation for evapotranspiration partitioning[J]. Applied Computing and Geosciences, 2022, 16: 100105.
- [57] FILGUEIRAS R, ALMEIDA T S, MANTOVANI E C, et al. Soil water content and actual evapotranspiration predictions using regression algorithms and remote sensing data[J]. Agricultural Water Management, 2020, 241: 106346.
- [58] BAI Yun,ZHANG Sha,BHATTARAI N,et al. On the use of machine learning based ensemble approaches to improve evapotranspiration estimates from croplands across a wide environmental gradient[J]. Agricultural and Forest Meteorology,2021,298-299:108308.
- [59] DOU Xianming, YANG Yongguo. Evapotranspiration estimation using four different machine learning approaches in different terrestrial ecosystems[J]. Computers and Electronics in Agriculture,2018,148:95-106.
- [60] GOYAL P, KUMAR S, SHARDA R. A review of the Artificial intelligence (AI) based techniques for estimating reference evapotranspiration;current trends and future perspectives[J]. Computers and Electronics in Agriculture,2023,209:107836.
- [61] WANG Xuanyu, YAO Yunjun, ZHAO Shaohua, et al. MODIS-based estimation of terrestrial latent heat flux over north america using three machine learning algorithms[J]. Remote Sensing,2017,9(12):1326.
- [62] SHRESTHA N K, SHUKLA S. Support vector machine based modeling of evapotranspiration using hydro-climatic variables in a sub-tropical environment[J]. Agricultural and Forest Meteorology,2015,200:172-184.
- [63] LIU Yan,ZHANG Sha,ZHANG Jiahua,et al. Assessment and comparison of six machine learning models in estimating evapotranspiration over croplands using remote sensing and meteorological factors[J]. Remote Sensing, 2021,13(19):3838.
- [64] 孟莹,姜鹏,董巍. 基于遥感的地表蒸散发研究进展[J]. 遥感技术与应用,2022,37(4):839-853. (MENG Ying, JIANG Peng, DONG Wei. Progress in the evapotranspiration estimation using remotely sensed data[J]. Remote Sensing Technology and Application,2022,37(4):839-853. (in Chinese))
- [65] CHEN Min, QIAN Zhen, BOERS N, et al. Iterative integration of deep learning in hybrid earth surface system modelling[J]. Nature Reviews Earth & Environment, 2023,4(8):568-581.

(收稿日期:2025-01-02 编辑:王芳)