

数据驱动的蒸散发遥感反演方法及产品研究进展

刘萌¹, 唐荣林^{2,3}, 李召良¹, 高懋芳¹, 姚云军⁴

1. 中国农业科学院农业资源与农业区划研究所 农业农村部农业遥感重点实验室, 北京 100081;

2. 中国科学院地理科学与资源研究所 资源与环境信息系统国家重点实验室, 北京 100101;

3. 中国科学院大学, 北京 100049;

4. 北京师范大学 地理科学学部 遥感科学国家重点实验室, 北京 100875

摘要: 蒸散发是水圈、大气圈和生物圈中水分循环和能量交换的纽带。在全球尺度上, 蒸散发约占陆地降水总量的60%; 作为其能量表达形式, 潜热通量约占地表净辐射的80%。随着通量观测技术的发展, 全球长期持续的观测数据得以获取和共享, 近年来基于数据驱动的蒸散发遥感反演方法取得了较好的研究进展。本文针对数据驱动的蒸散发遥感反演方法和产品, 从经验回归、机器学习和数据融合3个方面展开, 对现有的研究进展进行了梳理、归纳和总结, 并从驱动数据、反演方法、已有产品等方面指出目前仍存在的问题和不足。未来仍需开展数据驱动的高时空分辨率的蒸散发遥感反演方法的研究, 有效考虑地表温度和土壤水分等可以指示地表蒸散发短期变化的重要信息, 同时加强基于过程驱动的物理模型与数据驱动的结合, 使两类模型能互为补充、各自发挥所长, 共同推动蒸散发遥感反演研究水平的进步。

关键词: 蒸散发, 数据驱动, 地表温度, 经验方法, 机器学习, 数据融合, 遥感产品

引用格式: 刘萌, 唐荣林, 李召良, 高懋芳, 姚云军. 2021. 数据驱动的蒸散发遥感反演方法及产品研究进展. 遥感学报, 25(8): 1517-1537

Liu M, Tang R L, Li Z L, Gao M F and Yao Y J. 2021. Progress of data-driven remotely sensed retrieval methods and products on land surface evapotranspiration. National Remote Sensing Bulletin, 25(8): 1517-1537 [DOI: 10.11834/jrs.20211310]

1 引言

蒸散发ET (Evapotranspiration) 包括土壤水分蒸发、植被水分蒸腾、冠层截流蒸发和水体表面蒸发, 是陆地表面热量平衡和水量平衡的主要过程参量 (Wang 和 Dickinson, 2012)。在全球尺度上, 蒸散发约占陆地降水总量的60% (Oki 和 Kanae, 2006); 作为其能量表达形式, 潜热通量约占地表净辐射的80% (Trenberth 等, 2009)。作为陆地表层水循环过程中仅次于降水的第二大组分, 蒸散发却是水循环过程中最难估算的分量。随着卫星遥感技术的发展, 地表温度、植被指数、土壤水分等与地表水热通量密切相关的地表参数信息可以通过遥感反演获取, 遥感反演蒸散发也成为了高精度、高时效获取区域及全球尺度蒸散

发时空分布的有效方法 (Li 等, 2009; 唐荣林, 2011)。由于下垫面地表异质性、复杂的近地气象条件等空间异质性以及水热传输过程的动态多变性, 使得地表蒸散发的时空变化差异较大, 区域尺度的准确估算仍面临很大挑战 (Liu 等, 2016)。

已有的蒸散发遥感反演方法按原理机理可以分为基于导度的方法和基于温度的方法 (Chen 等, 2020), 按驱动数据可以分为基于短波波段数据、热红外波段数据 (姚云军 等, 2012) 以及微波波段数据的方法。本文按照模型驱动力将其归为两大类: 基于过程驱动的物理反演方法, 如能量平衡余项法 (Shuttleworth 和 Wallace, 1985; Norman 等, 1995; Bastiaanssen 等, 1998; Su, 2002; Allen 等, 2007; Vinukollu 等, 2011; Qiu 等, 2015;

收稿日期: 2021-05-10; 预印本: 2021-07-09

基金项目: 国家自然科学基金(编号: 42001310, 41922009, 42071332); 中央级科研院所基本科研业务费专项(编号: 1610132020007)

第一作者简介: 刘萌, 1990年生, 女, 助理研究员, 研究方向为地表蒸散发遥感反演。E-mail: liumeng01@caas.cn

通信作者简介: 李召良, 1964年生, 男, 研究员, 研究方向为热红外遥感。E-mail: lizhaoliang@caas.cn

Xiong等, 2015; Hu和Jia, 2015; Song等, 2016; Yao等, 2017a)、三角形/梯形特征空间法 (Moran等, 1994; Jiang和Islam, 1999; Tang等, 2010; Long等, 2012; Tang和Li, 2017)、基于Penman-Monteith或Priestley-Taylor公式的方法 (Cleugh等, 2007; Mu等, 2007, 2011; Fisher等, 2008; Yuan等, 2010; Zhang等, 2010; Wu等, 2012; Yao等, 2013; Zhang等, 2016; Zhang等, 2019)以及数据同化法 (Huang等, 2008; Xu等, 2011, 2019), 和基于数据驱动的反演方法, 包括经验回归方法、机器学习方法及数据融合方法。基于过程驱动的方法是在生物圈中光合作用、冠层传导、呼吸等理论和假设基础上, 利用简化的生态系统过程和组分组成既定的模型结构, 来模拟生态系统碳—水—能量交换的 (Jung等, 2011)。该类方法物理基础较好, 有高精度的输入数据时可以获得较高的估算精度。区域地表异质性、阻抗参数化的复杂性、数据累积误差等多种因素使得基于过程的物理方法应用到区域时估算复杂且具有局限性, 由于缺乏高质量的输入数据, 其区域推广受到限制, 难以获取理想的区域估算精度。

基于数据驱动的蒸散发遥感反演方法, 是指由蒸散发 (观测通量或者已有的蒸散发产品) 及其密切相关的特征参量等数据驱动, 通过建立数据之间的关系来获取蒸散发估算的方法。本文将基于数据驱动的方法划分为经验回归方法、机器学习方法和数据融合方法 (图1)。经验回归方法、机器学习方法通过直接构建遥感、气象、水文变量与ET参考真值 (如观测通量) 的经验关系来估算实际蒸散发, 而数据融合方法通过融合相同或不同时空分辨率的ET产品来提升ET精度或者时空分辨率。相关研究发现, 复杂的物理和解析方法未必比简单的经验和统计方法精度更高 (Kalma等, 2008), 而机器学习方法的推广应用更是大幅提高了地表参数估算精度 (Yuan等, 2020a)。数据驱动方法的优势在于它对数据关系敏锐的捕捉能力, 单单依靠数据就可以构建拟合度好误差小的回归关系来估算ET。与传统物理模型的区别是不用预知蒸散发过程发生的物理机制, 也不需要对其有影响的所有变量均可获取, 仅仅通过构建已获取的遥感、气象、观测通量等数据之间的关系就可以获取高精度的估算结果。

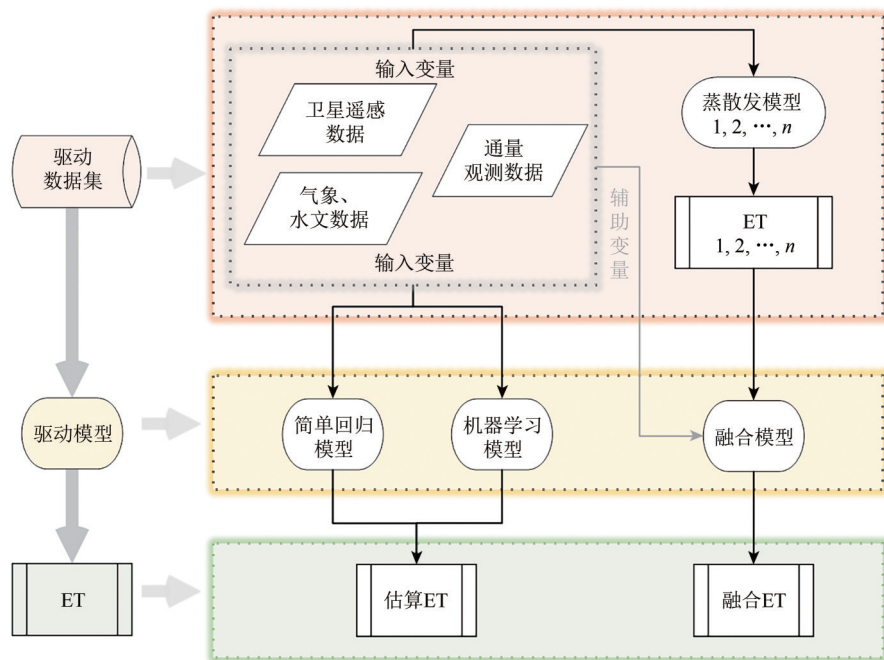


图1 数据驱动的蒸散发遥感反演方法整体流程图

Fig. 1 The overall flow chat of data-driven remotely sensed retrieval methods for ET

已有的文献综述大多侧重于基于过程的物理和解析方法 (Kalma等, 2008; Li等, 2009; Wang和Dickinson, 2012; Zhang等, 2016; 周侗

等, 2016; Chen等, 2020) 及相关产品 (李佳等, 2021)。随着全球通量观测网络的发展, 越来越多的通量观测数据得以共享和获取, 基于数据

驱动的方法得以快速发展。本文以此为切入点，全面、系统地综述了基于数据驱动的蒸散发遥感反演方法和产品的国内外研究进展，并从经验回归、机器学习和数据融合3个方面对相关方法/产品的基本原理、优势与不足等进行了梳理、归纳和总结，最后指明了基于数据驱动的蒸散发遥感反演研究的未来发展方向。

2 数据驱动的蒸散发遥感反演方法

考虑到卫星无法提供地表蒸散发的直接观测，而只能提供有限的信息，遥感的主要任务就是确定卫星可反演地表参数与地表蒸散发的关系(Wang等, 2010; 梁顺林等, 2013)。太阳辐射为蒸散发提供其所需能量来源(Trenberth等, 2009); 土壤水分可以直接为土壤蒸发提供水分供应, 其亏缺对蒸散发有胁迫作用(郑超磊等, 2021); 地气温差(地表温度和近地表空气温度之差)是蒸散发过程得以发生的温度条件, 地表温度可以指示表面土壤水分状态等信息(Anderson等, 2011); 风速、植被指数、植被覆盖度、叶面积指数等可以提供粗糙度、阻抗等地面异质性条件状况信息, 这些因素都会影响蒸散发过程(Wang等, 2007, 2010; 梁顺林等, 2012; Bai等, 2015)。蒸散发的估算可以看作是多种气象变量和遥感变量的复杂的非线性回归分析, 其一般形式可以表示为

$$ET = f(R_n, R_s, T_s, T_a, VI, WS, \dots) \quad (1)$$

式中, R_n 代表地表净辐射, R_s 代表入射短波辐射, T_s 代表地表温度, T_a 代表空气温度, VI 代表植被指数, WS 代表风速。

2.1 数据驱动的经验回归方法

早期的经验回归方法是利用地气温差和蒸散发及净辐射的非线性关系来估算地表蒸散发(Jackson等, 1977; Seguin等, 1982; Seguin和Itier, 1983)。

$$ET_d = (R_n)_d - B(T_s - T_a)_i^n \quad (2)$$

式中, 角标 $_d$ 和 $_i$ 分别代表日尺度和瞬时尺度, B 和 n 是统计回归系数, 依赖于表面粗糙度、大气稳定度、风速等因素(Seguin和Itier, 1983; Kalma等, 2008; Li等, 2009)。Carlson等(1995)从理论上分析了简化回归方法中系数的隐含意义, 将 B 定义

为日显热通量的平均整体传导度, 将 n 定义为非中性静态稳定度的校正参数, 二者与覆盖度密切相关。 B 的变化范围从裸土的0.015到完全植被覆盖的0.065, 指数 n 的变化范围从完全植被覆盖的0.65到裸土的1(Kalma等, 2008)。在日尺度上, 该方法的不确定度约为20%—30%(Kustas和Norman, 1996)或者 ± 1 mm/d(Kalma等, 2008; 唐荣林, 2011)。该经验回归法依赖于几点假设: 显热通量和净辐射的比值 H/R_n 在一整天内是恒定的; 日平均土壤热通量可以忽略不计; 正午瞬时显热通量可以充分表达当日可利用能量在湍流能量方面的分配(Kalma等, 2008; Li等, 2009; 唐荣林, 2011)。在20世纪遥感反演理论和ET研究不太成熟时, 这类方法在估算小范围区域ET方面发挥了重要作用, 在实际应用中可以为水分可利用性提供可靠信息(Seguin等, 1994)。由于其对地面观测数据的依赖, 难以应用于大区域的ET估算。

涡动相关系统(EC)可以获取较准确的地面通量观测, 随着基于涡动相关系统的通量观测网络的建立, 观测数据长期持续的大范围及全球获取, 尤其是Fluxnet和ARM等项目数据的开放共享, 促使各种表达形式的回归统计方法应运而生, 结合遥感产品、气象资料和通量观测来反演蒸散发的方法取得了较好的发展(Wang等, 2012)。经验回归方法不再只依赖于地气温差, 而是通过直接构建蒸散发与其关系密切的各种气象或遥感可反演参数的线性关系来进行蒸散发的估算。研究发现不需要大量的气象观测数据, 仅通过地表温度、植被指数、地表反照率等少量遥感可反演参数就能估算得到像元的蒸散发。但是, 利用少数站点的气象及通量观测构建的回归关系, 在区域移植时不确定性较大, 需要重新率定经验系数(Kalma等, 2008; Li等, 2009; Wang等, 2012; 唐荣林, 2011; Carter和Liang, 2018), 而适用性强、精度高的经验模型构建相对较难。为此, 经验回归方法的研究逐步发展到在物理模型基础上利用全球分布的多站点通量观测构建经验回归关系(Nagler等, 2005a, 2005b; Wang等, 2007; Wang和Liang, 2008; Wang等, 2010; Yao等, 2011; Yao等, 2015)。Wang等(2010)将地表蒸散发划分为辐射项和空气动力学项, 引入风速计算空气动力学阻抗, 结合地面观测数据、气象和

遥感数据,提出了基于Penman-Monteith方程的具有一定物理意义、适用于各种地表类型的半经验地表蒸散发通用估算模型。该方法已成功用于大区域及全球尺度的地表蒸散发遥感估算应用中,研究表明对不同地类该算法精度有差异(Yao等,2014;Feng等,2015;Liu等,2019)。Yao等(2011)在双源模型基础上,结合22个站点的通量观测数据构建回归关系,提出了一种简单的混合经验蒸散发估算模型,经地面观测验证精度较好,可应用于全球地表蒸散发估算(Yao等,2014)。如果针对不同地类分别重新拟合系数,经验算法精度应高于通用模型算法精度(Wang等,2012)。Yao等(2015)在Priestley-Taylor公式的基础上,利用全球240个Fluxnet站点观测数据针对不同地类分别率定系数,建立了适用于全球不同地类的经验估算方法。Yao等(2021)在该经验方法基础上进一步简化,用更易获取的入射短波辐射替代地表可利用能量,重新参数化了Priestley-Taylor公式的经验系数。依赖于地面观测数据的回归模型简单、易用、可操作性强,且相较于复杂模型具有相当的精度(Mueller等,2011)。由于热红外地表温度受云影响,适用于大区域或全球的简单回归方法多使用更容易获取的空气温度作为模型输入(表1),也仍有部分研究基于地表温度构建经验关系(Wang等,2007;Wang和Liang,2008)。Helman等(2015)利用16个通量观测站点,构建了仅利用植被指数和地表温度估算地表蒸散发的经验方法。Carter和Liang(2018)针对多种经验方法,就输入温度为地表温度或空气温度,分别重新率定了经验系数。Wang等(2007)对比研究表明,相较于空气温度日变化作为模型驱动,使用地表温度日变化时蒸散发估算精度更高,仅用每天的最大地表温度作为输入参数的经验模型也可获得与日平均地表温度作为输入的模型可对比的精度。

除了利用热红外和光学信息,还有研究利用与被动微波发射率的经验关系来估算蒸发比或实际蒸散发(Choudhury等,1991;Kustas等,1993)。Min和Lin(2006)构建了微波发射率差异植被指数与蒸发比的经验关系。Han等(2017)提出了利用22 GHz和37 GHz微波发射率估算年平均日蒸散发的经验方法,估算结果RMSE为0.27 mm/day。Liu等(2018)提出了利用先进微波扫描辐射计-地球观察系统传感器AMSR-E(Advanced Microwave

Scanning Radiometer-Earth Observing System sensor)被动微波数据36.5 GHz发射率估算年平均实际蒸散发的经验方法,并分析了其与年平均实际观测蒸散发和参考蒸散发比值之间的经验关系。

2.2 数据驱动的机器学习方法

从用少数几个站点的观测构建经验关系逐步发展到用全球分布站点的观测构建经验关系,简单的经验统计方法日渐难以满足实际应用的高精度需求。由于出色的分类和回归预测能力,机器学习方法开始被用于蒸散发的估算研究中。机器学习方法是基于包含在数据中的模式来构造经验模型,不需要规定任何函数形式,具有很好的数据自适应性(Jung等,2011),可以大幅提高回归预测精度,还可以从数据中挖掘出新信息,并推动新机制新认识的产生(Reichstein等,2019),已被广泛用于地表参数反演、地下水研究、降尺度、遥感图像融合等地学领域(Kaheil等,2008;Srivastava等,2013;Raghavendra和Deka,2014;Jajarmizadeh等,2015;Lm等,2016;Ke等,2016,2017;Zhao等,2019;Shen等,2019;Yuan等,2020a,2020b)。Kumar等(2002)是最早得到广泛关注的使用神经网络进行蒸散发估算的研究。Yang等(2006)使用支持向量机的方法基于遥感数据和22个AmeriFlux站点观测数据,利用地表温度、增强型植被指数、地表覆盖度结合入射短波辐射成功估算了美国本土8 d尺度的蒸散发。Jung等(2010)发表在Nature上的研究是近年来影响力最大的使用机器算法进行蒸散发估算的研究,利用模型树集成MTE(Model Tree Ensemble)的方法融合了表面气象数据、遥感数据和通量观测站点数据,评估了全球尺度的月蒸散发量。在此之后,尤其是近5年,出现了大批基于机器学习的相关研究。近年来出现的用于估算蒸散发的机器学习方法,包括且不仅限于:神经网络类(包括人工神经网络、广义回归神经网络、小波神经网络、多层感知神经网络等)(Kumar等,2002;Jiménez等,2009;Deo等,2015;Feng等,2016;Bai等,2021)、支持向量机(Yang等,2006;Kaheil等,2008;Shrestha和Shukla,2015;Wang等,2017;Liu等,2018)、模型树集成(Jung等,2010,2011;Zeng等,2014;Li等,2018)、随机森林(Feng等,2017;Fan等,2018;Li等,2018;Shir,2018)、极限学习机(Abdullah等,2015;Feng等,

2016, 2017), M5 模型树和梯度提升决策树 (Kisi, 2015; Lu 等, 2018), 模糊逻辑和模糊神经推理系统 (Goyal 等, 2014), 多元关联向量机和多层感知机 (Torres 等, 2011), K 最邻近算法 (Bai 等, 2021), 高斯过程回归 (Deo 和 Samui, 2017; Carter 和 Liang, 2019), 多元自适应回归样条函数 (Kisi, 2015; Mehdizadeh 等, 2017; Wang 等, 2017), 基因表达式编程 (Kisi 等, 2015)、Cubist (Xu 等, 2018) 和深度信念网络 (Xu 等, 2018; Li 等, 2018) 等。许多研究侧重于不同机器学习算法的对比评价, 不同的机器学习方法, 其估算结果差异不大, 这一点已被多数研究证实

(Tramontana 等, 2016; Li 等, 2008; Xu 等, 2008; Jung 等, 2019)。不同机器学习方法调参后获得最优参数, 其估算结果精度相当 (Wu 和 Ying, 2019)。机器算法的优点是模型的构建融合了观测数据, 类似于封装好的复杂经验算法, 模型模拟精度较高, 缺点是模型精度依赖于数据, 包括数据质量、数据处理方式、数据代表性及数据尺度问题。本文重点在于对机器学习方法在蒸散发反演中的应用进行归纳总结, 而不在于介绍各个机器学习方法的原理, 方法相关资料可查阅上述参考文献。

表1 大区域或全球适用的经验回归方法

Table 1 Empirical regression methods for large region or global application

模型出处	模型输入	观测时间范围	站点	模型时间尺度	验证结果	区域应用及精度
Wang 等 (2007)	地表净辐射、温度 (地表温度或空气温度)、植被指数	2002-01—2005-05	美国 8 个通量观测站点	16 d	$R^2=0.88-0.96$ RMSE=30 W/m ² 另外 6 个独立站点验证结果: $R^2=0.84-0.95$ RMSE=30—40W/m ²	—
Wang 和 Liang (2008)	地表净辐射、温度 (地表温度或空气温度)、植被指数、温度日变化	2001 年—2006 年	美国南大平原 12 个通量观测站点	16 d	$R^2=0.92$ RMSE=28.6 W/m ²	成功估算 1986 年—1995 年月尺度的全球 1° 地表蒸散发, 与陆面模型模拟结果对比, 其偏差为 4.5 W/m ² , R^2 为 0.82, RMSE 为 19.8 W/m ²
Wang 等 (2010)	植被指数、日平均风速、日平均相对湿度、下行短波辐射、水汽压逆差	1982 年—2002 年	全球 64 个通量观测站点	16 d	16 天: $R^2=0.94$ RMSE=17 W/m ²	成功估算了 1982 年—2002 年月尺度的全球 8 km 地表蒸散发
Yao 等 (2011)	植被指数、净辐射、空气温度 (最大、最小和平均)	2000 年—2008 年	12 个 ARM 站点, 7 个 Fluxnet 站点, 3 个中国通量观测站点	16 d	16 天: $R^2=0.84$ RMSE=14.74 W/m ²	成功估算了 2001 年—2002 年 4 月—9 月月尺度的全球 1° 地表蒸散发
Yao 等 (2015)	净辐射、空气温度、植被指数、相对湿度、水汽压逆差	2000 年—2009 年	240 个 Fluxnet 站点	每日	分地类 天: $R^2:0.68-0.87$ RMSE:11.5—20.9 W/m ² 月: $R^2:0.80-0.96$ RMSE:4.3—18.1 W/m ² 年: $R^2:0.71-0.94$ RMSE:2.1—5.8 W/m ²	成功估算了 2003 年—2005 年全球 0.05° 地表蒸散发
Yao 等 (2021)	入射短波辐射、植被指数、相对湿度	2000 年—2009 年	100 个 Fluxnet 站点	每日	分地类, 常绿阔叶林估算精度最高, 农田估算精度最差 天: $R^2:0.42-0.81$ RMSE:15.8—28.2 W/m ² 月: $R^2:0.58-0.86$ RMSE:11.7—23.9 W/m ²	基于 GF-1 卫星数据, 成功应用于怀来区域获取高空间分辨率地表蒸散发; 基于 GLASS 产品, 成功应用于三江源地区

归纳已有的基于各种机器学习方法的区域蒸散发估算研究,将已有研究分为两类:一类通过站点升尺度扩展来估算区域像元尺度蒸散发,另一类从像元或流域尺度扩展来开展区域像元尺度的蒸散发估算。

2.2.1 站点升尺度区域扩展

此类方法是利用站点观测通量数据作为像元真值构建模型,结合遥感产品和气候气象资料获取区域蒸散发。神经网络、核函数方法、树模型等各类机器学习方法已被用于观测区域乃至全球的升尺度研究中以获取蒸散发的时空分布。根据驱动数据来源可以划分为两类:(1)结合地面观测和全遥感产品作为模型驱动。基于中分辨率成像光谱仪MODIS (Moderate-resolution Imaging Spectroradiometer) 地表产品或者在此基础上结合全球陆表特征参量GLASS (Global land surface satellite)、全球能量与水循环实验-地表能量收支GEWEX-SRB (Global Energy and Water Exchanges-Surface Radiation Budget)、云和地球辐射能量系统CERES (Clouds and the Earth's Radiant Energy System) 或日本宇宙航空研究开发机构JAXA (Japan Aerospace Exploration Agency) 等项目或机构发布的遥感辐射产品,利用多种遥感指标作为驱动数据,构建机器学习升尺度模型反演区域地表蒸散发 (Yang等, 2006; Jiménez等, 2009; Tramontana等, 2016; Carter和Liang, 2019; Jung等, 2019)。(2)地面观测结合气象、气候资料和遥感产品作为模型驱动。从气象再分析资料或者气象站点插值获取区域气象指标,结合MODIS、GLASS遥感可反演地表参数,驱动模型升尺度估算区域地表蒸散发 (Jung等, 2011; Chen等, 2014; Tramontana等, 2016; Liu等, 2018; Xu等, 2018; Li等, 2018; Jung等, 2019)。将两类方法对比而言,由于气象驱动数据集本身具有不确定性,遥感结合气象数据驱动模型的不确定性大于全遥感作为数据驱动模型的不确定性 (Jung等, 2019)。遥感结合气象数据驱动模型的优点是,气象数据的输入使得可以反演获取时空连续的地表日蒸散发,但也降低了反演结果的空间分辨率。同时,由于其空间分辨率不高,不能有效考虑站点通量观测源区与格网气象数据或中分辨率遥感产品的空间尺度差异,降低了反演精度。Yao等 (2017b) 研究表明,基于站点数

据构建模型评估精度较好,但升尺度应用于MERRA (The Modern-Era Retrospective analysis for Research and Applications) 气象再分析数据后精度降低。通量观测源区与仪器观测高度、下垫面状况和大气湍流状况有关,且时刻变化 (Jia等, 2012; Liu等, 2016)。针对1 km分辨率的MODIS产品,Tramontana等 (2016) 采用通量站点附近3×3像元求平均的方法来减少位置误差,以求更好的代表涡动相关足迹源区,然而,涡动相关观测足迹大约范围在几百米 (Baldocchi, 2008), MODIS产品1 km空间分辨率大于通量观测足迹。另外,地表温度、地气温差作为传统蒸散发估算物理模型中的重要参数,在机器学习方法中应用较少 (图2)。在全球应用时,仅有个别研究 (Jiménez等, 2009; Tramontana等, 2016) 考虑了热红外地表温度作为驱动因子的影响。热红外地表温度可以为估算蒸散发提供表面土壤水分状态等有价值的信息 (Anderson等, 2011), Jiménez等 (2009) 指出没有热红外表面温度输入时,感热通量和潜热通量精度会明显降低。尽管仍存在一些不足之处,在现有的条件下,站点升尺度的方法有效利用全球通量观测网络的观测数据,充分发挥机器学习技术具有强大的回归预测能力的优势,融合了驱动数据的精度误差,提升了地表蒸散发遥感反演精度。




图2 1995年—2021年发表的主题包含蒸散发和机器学习以及蒸散发、机器学习和地表温度的文章数(基于Web of Science平台,统计时间截止2021-04-27)

Fig.2 Number of articles published each year whose topics include evapotranspiration and machine learning, as well as that include evapotranspiration, machine learning and land surface temperature from 1995 to 2021 (Web of Science, until April 27 in 2021)

2.2.2 像元或流域尺度扩展

(1) 像元尺度区域蒸散发估算方法。结合已有陆面模式通量产品或再分析产品,构建像元尺

度遥感变量遥感与产品通量的关系，直接获取区域蒸散发 (Jiménez 等, 2009)。这种方法有效解决了空间尺度的匹配问题，然而模型构建以陆面模式产品通量作为真值，陆面模式的通量准确性有待考究。不同的陆面模式产品的能量通量在量级和分布上有较大的不确定性 (Jiménez 等, 2011)。虽然不同模式产品、再分析产品及遥感产品已有许多，但目前尚未有一套精度完全可靠的产品可作为真值参考，不同产品的估算结果差异较大 (熊育久 等, 2021)。第二次全球土壤湿度计划 GSWP-2 (The Global Soil Wetness Project-2) 对比了 15 种模型全球蒸散发的估算结果，发现全球年蒸散发在 272—441 mm/a 范围内变化 (Dirmeyer 等, 2006; Yuan 等, 2010)。通过对比 1985 年—1995 年全球 41 种陆表蒸散发产品数据集，研究发现全球年平均陆表蒸散发约为 1.59 ± 0.19 mm/d (46 ± 5 W/m²)，IPCC 第四次评估报告 IPCC AR4 (IPCC Fourth Assessment Report) 全球气候模型的模拟标准差 0.16 mm/d (4.6 W/m²) 低于参考数据集的标准差，而全球土壤湿度计划陆面模型 GSWP LSMs (The Global Soil Wetness Project land surface models) 数据集的标准差 0.12 mm/d (3.6 W/m²) 比 IPCC AR4 还要低 (Mueller 等, 2011)。Wang 和 Dickinson (2012) 对比了全球 17 种陆表蒸散发产品，研究发现全球的陆表蒸散发年平均变化范围为 24.1—42.0 W/m²，遥感产品的年平均 ET 值稍低，再分析资料的年平均 ET 值稍高。故而，该方法获取的区域 ET 存在较大的不确定性。

(2) 流域降尺度区域蒸散发估算方法。该方法是结合流域蒸散发，构建流域变量与流域蒸散发的关系，降尺度获取像元尺度蒸散发。Zeng 等 (2014) 基于地表水量平衡方法从雨量筒观测站的降雨数据，水文观测站的河流径流量，结合重力恢复与气候实验 GRACE (Gravity Recovery and Climate Experiment) 地球水储量距平 TWSA (Terrestrial Water Storage Anomaly) 数据获取了全球 95 个流域月尺度的蒸散发，利用模型树集成的方法，将辐射、气温、降雨、风速和植被指数等变量与月尺度的流域蒸散发建立联系，利用空间化的气象和卫星数据估算了全球的月尺度蒸散发。这种方法有效解决了空间尺度的匹配问题，能够获得较高精度的流域尺度月蒸散发，但却无法表征流域内蒸散发的时空 (如不同天之间、不同格网之间)

异质性，不能准确获取高精度的日蒸散发。

2.3 数据驱动的数据融合方法

本文将数据驱动的蒸散发数据融合方法分为两类：同一时空分辨率的融合和不同时空分辨率的融合。

2.3.1 同一时空分辨率的融合

同一时空分辨率的融合指的是采用数据驱动的方法，建立单一相同时空分辨率的多模型 ET 与通量观测数据或者当作参考真值的 ET 产品数据之间的关系，通过多模型数据融合获取更高精度的 ET 估算。不同原理的 ET 估算方法优缺点以及适用条件均不相同，靠单一算法获取高精度 ET 有很大局限性。考虑到不同算法各有优缺点，为了提高 ET 估算精度，多算法融合的研究已成为蒸散发定量遥感研究的新趋势。例如，简单平均、贝叶斯平均、经验正交函数法、泰勒融合模型、机器学习方法等模型均已应用于蒸散发多模型 ET 融合研究中 (Yao 等, 2014; Chen 等, 2015; Feng 等, 2016; Ke 等, 2016, 2017; Yao 等, 2017b; Liu 等, 2019; Bai 等, 2021)。基于数据驱动的多模型 ET 融合方法结合了物理模型具有坚实的物理机理和数据驱动方法具有强大的回归预测能力的优势，综合考虑了多种算法的优缺点，并直接融合了观测数据，避免了仅利用数据驱动的方法反演蒸散发所造成的物理机制缺乏或者仅利用物理模型反演蒸散发所造成的精度低的问题，获得较可靠 ET 估算结果的同时可以一定程度上提高估算精度。然而由于数据驱动的方法依赖于所融合模型本身的精度，融合模型的精度仍受到所融合的独立模型的精度限制。当前蒸散发反演研究中出现的数据驱动的同—时空分辨率多模型 ET 融合方法可以归为两类：多模型 ET 显式融合和多模型 ET 隐式融合。

(1) 多模型 ET 显式融合。多模型 ET 显式融合是指被融合的 ET 模型和所采用的融合方法都可以显式表达。顾名思义，显式融合的特点是融合模型 (包括被融合的模型和融合方法) 可以利用显式公式来表达，容易操作，便于复现。使用简单平均、贝叶斯平均或者简单泰勒融合的方法融合基于过程的物理模型和数据驱动的经验回归模型是目前常见的多模型显式融合的方法 (Yao 等,

2014; Zhu 等, 2016; Yao 等, 2017c)。贝叶斯平均或简单泰勒融合方法的本质是加权平均, 基于贝叶斯模型或者简单泰勒模型评估不同待融合模型的得分赋予权重。其通用表达式如下:

$$ET = w_1 ET_1 + w_2 ET_2 + \dots + w_n ET_n \quad (3)$$

$$ET_n = f_n(v_{n1}, v_{n2}, \dots, v_{ni}, \dots, v_{nm}) \quad (4)$$

式中, w_n 代表第 n 个待融合模型的权重, ET_n 是第 n 个待融合模型, f_n 表示第 n 个待融合模型的方程表达式, v_{ni} 代表第 n 个待融合模型的第 i 个模型驱动因子。在使用该方法进行多模型融合时, 多模型的选择比较重要, 需要平衡选择高估和低估的模型数量。该方法的优点是可以将不同算法的高估和低估进行平衡, 减少其高估或低估的程度以提高算法精度; 缺点是融合精度高度依赖于所融合模型本身的精度, 融合模型本质上权重配比的不确定性限制着其广泛应用。

(2) 多模型ET隐式融合。多模型ET隐式融合是指被融合的ET模型或所采用的融合方法不可以显式表达, 即所融合的模型包括无法用显式公式表达的估算方法(如机器学习方法、同化方法、模式方法等)(Chen 等, 2015; Yao 等, 2016; Yang 等, 2021), 或者使用无法用显式公式表达的方法(如机器学习方法等)作为融合方法来进行基于过程的物理模型或经验回归模型的多模型融合研究(Yao 等, 2017b; Liu 等, 2019; Bai 等, 2021), 或者被融合的模型和融合方法均不可显式表达。多模型隐式融合的本质是产品融合, 即需要先使用待融合的多个模型分别估算得到各自的ET值, 再使用融合方法进行站点或区域产品的融合。其通用表达式如下:

$$ET = f(ET_1, ET_2, \dots, ET_n) \quad (5)$$

式中, ET_n 是第 n 个待融合模型估算结果, f 表示融合方法。与传统物理模型和显示融合相比, 隐式融合的方法提高了估算精度; 与经验回归方法和机器学习方法相比, 由于物理机理模型的参与, 该类方法在区域扩展时, 尤其是在观测数据缺乏或难以获取的区域, 其可靠性优于经验回归方法和机器学习方法。同时, 对于植被覆盖度不佳单使用机器学习站点升尺度难以获取可靠高精度ET估算的区域, 模型融合的方法仍能获取可靠的精度较好的ET估算结果。该方法的不足之处与多模型ET显式融合相似, 融合精度仍受限于所融合的

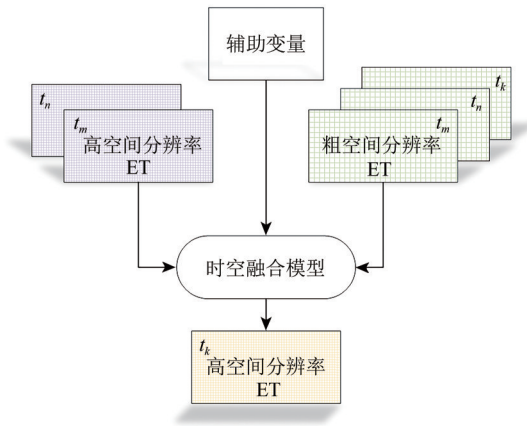
算法本身的精度以及所选取模型之间的异同性, 融合模型复杂的结构也影响其计算效率。

2.3.2 不同时空分辨率的融合

不同时空分辨率的融合是指采用数据驱动的方法建立数据之间的联系, 实现对蒸散发产品的时空融合或降尺度, 以获取高时空分辨率的ET产品, 从而解决由单源遥感数据无法直接获取高时空分辨率地表蒸散发的问题。时空融合和降尺度过程相似(Yuan 等, 2020a), 其核心都在于建立数据之间的联系(LeCun 等, 2015), 而数据驱动的方法其优势就是可以较好地捕捉、构建数据之间的关系。ET时空融合是将高时间分辨率低空间分辨率的ET产品和高空间分辨率低时间分辨率的ET产品进行融合以获取高时空分辨率的ET产品(图3(a)); ET降尺度是建立高空间分辨率过程参量与低空间分辨率ET产品的关系, 进而降尺度得到高空间分辨率的ET产品(图3(b))。

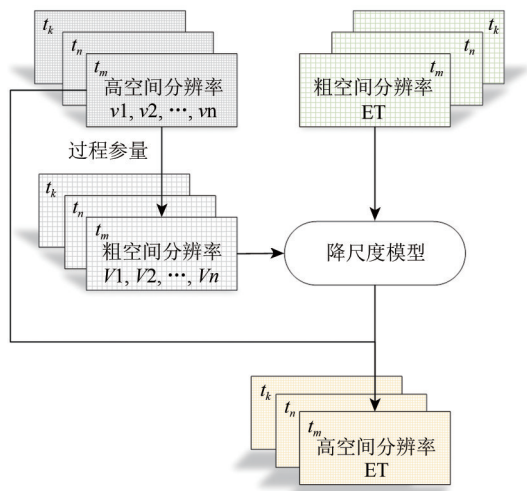
现阶段直接融合不同时空分辨率地表蒸散发产品的研究较少, 不同于变化缓慢的地表反射率等参数, 地表蒸散发是动态变化的, 其时空融合难度较大(Wang 等, 2019; Xu 等, 2019)。已有数据驱动的ET降尺度研究将高空间分辨率的驱动因子通过特定的方法升尺度到较粗尺度, 使用数据驱动的方法(如机器学习方法)在粗尺度即低空间分辨率上建立蒸散发与驱动因子的非线性关系, 而后将此非线性关系用于高空间分辨率的驱动因子上, 得到高空间分辨率的蒸散发(Kaheil 等, 2008; Ke 等, 2016)。Ke 等(2017)将时空融合方法和机器学习降尺度方法相结合, 构建了3种方案的时空降尺度方法以获取8天30m的实际蒸散发产品, 3种方法分别是: (1) 利用 t_1 时刻 Landsat、MODIS 和 t_2 时刻 MODIS 表面反射率融合后反演得到 t_2 时刻 Landsat 尺度的植被指数, 结合 t_1 时刻 Landsat、MODIS 和 t_2 时刻 MODIS 地表温度融合得到的 t_2 时刻 Landsat 地表温度, 以及 t_2 时刻 MODIS ET 产品, 利用机器学习降尺度方法得到 t_2 时刻 Landsat 尺度的蒸散发; (2) 利用 t_1 时刻 Landsat、MODIS 和 t_2 时刻 MODIS 表面反射率分别反演得到两个时刻不同分辨率的植被指数后, 融合得到 t_2 时刻 Landsat 尺度的植被指数, 其余步骤同(1); (3) 利用 t_1 时刻 Landsat 反演得到 t_1 时刻的植被指数和地表温度, 以及 t_1 时刻 MODIS ET 产

品，使用机器学习降尺度方法得到 t_1 时刻 Landsat 尺度的蒸散发，之后结合 t_1 时刻和 t_2 时刻 MOD16 ET 产品，时空融合得到 t_2 时刻 Landsat 尺度的蒸散发。



(a) 蒸散发时空融合

(a) Spatio-temporal data fusion of ET



(b) 蒸散发降尺度

(b) Downscaling of ET

图3 不同时空分辨率蒸散发数据融合原理示意图

Fig.3 Schematic diagram of data fusion on ET with different spatial and temporal resolutions

通过基于数据驱动的时空融合和降尺度来获取蒸散发的方法，在现有条件下有效解决了由单源遥感数据无法直接获取高时空分辨率的地表蒸散发的问题，结合数据驱动方法在数据关系构建上的优势，可以获取相对高时空分辨率且高精度的区域蒸散发融合结果。不足之处在于融合精度高度依赖于低分辨率ET产品的精度。现有研究多基于MOD16产品，而许多研究表明MOD16产品精

度不够理想 (Kim 等, 2012; Chen 等, 2014, 2015; Hu 等, 2015)。没有高精度的单源遥感蒸散发产品，增加了数据驱动的时空融合或降尺度ET结果的不确定性。

3 数据驱动的蒸散发遥感反演产品

利用基于过程驱动模型，国内外学者已经生产了不同时空分辨率的全球蒸散发遥感反演产品，如数字地球动态模拟研究组 (NTSG) 发布的产品 (下文简称 NTSG 产品) (Zhang 等, 2010)、MOD16 产品 (Mu 等, 2011)、ETwatch 产品 (吴炳方, 2011; Wu 等, 2012)、SSEBop 产品 (Senay 等, 2013)、ETMonitor 产品 (Hu 和 Jia, 2015)、BESS 产品 (Jiang 和 Ryu, 2016)、GLEAM 产品 (Martens 等, 2017) 和 PML-V2 产品 (Zhang 等, 2019) 等。同具有物理机理的基于过程的蒸散发产品相似，已有的基于数据驱动的蒸散发产品，空间分辨率高的产品时间分辨率较粗，时间分辨率高的产品空间分辨率较粗；缺乏高时空分辨率的产品。对应于本文中对数据驱动的方法的归类，基于数据驱动的蒸散发产品也将从3方面展开介绍：基于经验回归的ET产品、基于机器学习方法的ET产品和基于数据融合的ET产品。

3.1 基于经验回归的ET产品

经验回归方法，模型简单、易用、可操作性强。部分适用于全球的模型虽然具有产品生产能力，模型作者也将其用于全球估算获取了ET数据集 (表1)，但相关数据集未见公开发布。由于其简单易操作，经验回归方法被许多研究采用用于区域及全球尺度蒸散发估算研究中，且通过地面验证及产品对比，发现经验模型精度较好，对于许多地类而言其估算精度优于物理模型 (Yao 等, 2014; Chen 等, 2014, 2015; Feng 等, 2015; Mao 等, 2016; Yao 等, 2017b; Carter 和 Liang, 2018)。

3.2 基于机器学习的ET产品

由于其在回归预测方面出色的表现，机器学习方法近十年被逐渐应用于全球蒸散发产品的研制研究中。目前已发表的产品见表2。

MTE (MTE-upscaling) 产品是利用模型集成算法 (MTE) 将 FLUXNET 的观测数据进行尺度

上推, 生产了1982年—2010年的总初级生产力GPP、陆地生态系统呼吸TER、净生态系统交换NEE、潜热通量LE和显热通量H产品, 空间分辨率为 $0.5^{\circ} \times 0.5^{\circ}$, 时间分辨率为月尺度。该算法首先利用潜在的解解释变量对MTE进行训练, 然后将建立好的MTE算法应用于全球尺度。在MTE训练中共使用了29种解释变量, 其中有遥感指标(光

合有效辐射比例FPAR)、气候数据、气象数据和植被类型信息等。交叉验证结果表明, 该方法预测站点尺度ET的模型效率高达0.84(Jung等, 2011)。该产品发布后影响较大, 已被多次用于水分平衡、大气交互以及陆面模式结果验证等研究中(Stegehuis等, 2013; Springer等, 2014; Barman等, 2014; Swenson等, 2014; Draper等, 2018)。

表2 已有的机器学习全球蒸散发产品

Table 2 Global ET products by machine learning

产品	参考文献	方法	精度	时间分辨率	空间分辨率/($^{\circ}$)	时间跨度/年	获取方式
MTE	Jung等(2010, 2011)	MTE	RMSE: 1.29 MJ/m ² /day	月	0.5	1982—2008	—
WB-MTE	Zeng等(2014)	MTE	流域验证精度: R: 0.78 RMSE: 26.7 mm/月	月	0.5	1982—2009	—
RDF-half-hourly	Bodesheim等(2018)	RF	半小时 RMSE: 2.5— 3.94 $\mu\text{mol} \cdot \text{m}^{-2} \cdot \text{s}^{-1}$ 月平均半小时RMSE: 1.62—2.97 $\mu\text{mol} \cdot \text{m}^{-2} \cdot \text{s}^{-1}$	半小时, 月平均 半小时	0.5	2001—2014	https://doi.org/10.17871/BACI.224[2021-05-10]
FLUXCOM	Jung等(2019)	9 ML(RS) 3 ML(RS+ METEO)	—	8天 天	0.0833 0.5	2001—2015 1980—2019	http://www.fluxcom.org [2021-05-10]

WB-MTE (MTE-Downscaling) 产品利用来自雨量筒观测站的降雨数据, 来自水文观测站的河流径流量, 来自GRACE地球重力卫星的TWSA数据, 基于地表水量平衡方法计算月尺度流域的ET值(含95条大流域、5824个月), 然后利用MTE算法将一系列潜在驱动变量(如辐射、气温、降雨、风速和植被指数)与地表水量平衡方法获得的ET建立联系, 进而利用空间化的气象和卫星数据将MTE算法推广到全球尺度(Zeng等, 2014)。WB-MTE全球ET产品, 在干燥季节估算结果与前人研究结果一致, 且在描述水量平衡算法获得的ET数据方面精度高于MOD16、MTE和NTSG等3个全球蒸散发产品, 但是在湿润季节尤其是热带区域估算结果有较大差异(郑涵, 2016)。

RDF-half-hourly产品是利用随机森林(RF)方法, 基于全球222个FLUXNET通量站点半小时观测数据, 结合MODIS产品和气候研究中心CRU-NCEPv63以及美国国家环境预报中心NCEP的6小时再分析数据集, 构建日尺度遥感和气象变量、仅依赖于时间和太阳角度的半小时潜在辐射及其一阶时间衍生变量与半小时观测数据的回归关系, 生产

了2001年—2014年全球 0.5° 的日循环(半小时)GPP、NEE、LE和H产品集, 并在此基础上提供了4种变量的月平均日循环产品集(Bodesheim等, 2018)。值得一提的是, 这是一套考虑了日、夜地表温度季节循环的半小时尺度产品。

FLUXCOM系列产品共包含149组能量通量产品(净辐射、潜热通量和感热通量), 其中全遥感驱动产品63套, 遥感结合气象数据驱动产品84套(Jung等, 2019)。基于3种能量平衡校正(未校正、波文比校正、余项法校正)的全球224个站点观测数据和MODIS产品(MOD11A2、MCD12Q1、MOD15A2、MCD43B4): 全遥感驱动的产品使用九种机器学习方法(9ML)结合JAXA发布的环境研究卫星监测(JASMES)入射短波辐射产品来驱动模型, 生产了潜热通量产品27套; 遥感结合气象驱动的产品使用3种机器学习方法(3ML)结合4套气象资料: ERA-interim、GSWP3、CRU-NCEPv8、CERES辐射数据结合全球降雨气候计划(GPCP)降雨数据, 分植被覆盖类型驱动模型, 生产了潜热通量产品36套。FLUXCOM系列产品也考虑了日、夜地表温度季节循环。

已有的基于数据驱动的机器学习方法所获取的蒸散发产品（表2），时空分辨率普遍较粗，日蒸散发产品较少，分析其原因主要包括以下两方面：（1）没有高空间分辨率的气象数据。现有研究方法大多依赖于气象输入，已有的全球再分析产品分辨率较粗，最新的ERA-5再分析产品分辨率为 0.25° ；（2）没有高时空分辨率且时空连续的可获取遥感数据。已有的利用全遥感反演全球日蒸散发的方法研究（Tramontana等，2016；Carter和Liang，2019），以时间分辨率高的MODIS产品为数据源，其最高空间分辨率为250 m。中、粗分辨率蒸散发产品仅适用于国家和全球尺度的水分和能量循环研究，难以满足田间尺度的水分平衡精细量化和水分利用效率评估等研究需求（Ke等，2017）。

3.3 基于数据融合的ET产品

GLASS ET产品，是基于贝叶斯多模型融合的

方法，结合AVHRR、MODIS和MERRA再分析数据生产的覆盖全球陆表空间连续的潜热通量遥感产品。Yao等（2014）针对不同地表覆被类型，使用贝叶斯平均的方法融合了两种基于Penman-Monteith的过程模型、两种基于Priestley-Taylor的过程模型以及一种数据驱动的半经验模型，该方法作为GLASS产品陆表蒸散发的官方算法用于产品生产。该产品时间分辨率为8 d，基于AVHRR的产品其最高空间分辨率为 0.05° ，基于MODIS的产品其最高空间分辨率为1 km（表3）。较之所融合的五种蒸散发算法产品，不同地类融合之后的GLASS蒸散发产品精度均明显提高，更接近于地面观测真实值。相比于基于机器学习方法的产品，该产品的优点在于所融合的模型具有物理机理，在无通量观测数据的区域相对可靠；不足在于融合精度受到被融合算法精度的限制。

表3 已有的多模型融合的全球蒸散发产品

Table 3 Global evapotranspiration products by integrating multiple models

产品	参考文献	方法	精度	时间分辨率	空间分辨率	时间跨度/年	获取方式
GLASS ET	Yao等(2014); Liang等(2021)	贝叶斯平均	$R^2:0.72$ RMSE:42.2 W/m ²	8 d	1982年— 2018年: $0.05^\circ, 0.5^\circ$; 2000年— 2018年:1 km	1982— 2018	http://www.glass.umd.edu/Download.html [2021-05-10] http://www.geodata.cn/thematicView/GLASS.html [2021-05-10]
Hi-GLASS ET	Yao等(2017c)	泰勒能力 权重	$R^2:0.65$ RMSE:23.8 W/m ²	16 d	30 m	2013— 2018	—
SynthesisET	Elnashar等(2021)	简单平均 + 组合	RMSE:20.95— 30.12 mm/月	月	1 km	1982— 2019	https://doi.org/10.7910/DVN/ZGOUED [2021-05-10] https://elnashar.users.earthengine.app/view/synthesizedet [2021-05-10]

Hi-GLASS ET产品，是基于泰勒能力权重融合方法，结合Landsat和MERRA再分析数据生产的高空间分辨率的全球陆表潜热通量遥感产品。Yao等（2017c）采用泰勒能力权重的方法融合了一种基于Penman-Monteith的过程模型、一种双源模型、两种基于Priestley-Taylor的过程模型以及一种数据驱动的经验模型，该方法作为Hi-GLASS产品陆表蒸散发的官方算法用于产品生产。该产品其时间分辨率为16 d，空间分辨率为30 m（表3）。Hi-GLASS蒸散发产品精度优于融合的统一算法。其产品优缺点与GLASS算法类似。

Synthesis ET产品，是基于简单平均加组合的方法生产的月尺度1 km分辨率的遥感产品组合数据集。Elnashar等（2021）选取了12套蒸散发产品，利用全球645个通量观测站点的涡动相关观测数据，对选取的产品进行了地面验证构建了评价矩阵，通过排序选取精度表现最优的遥感模型进行简单平均和产品组合。最终，1982年—2000年选用NTSG产品（通过最近邻重采样降尺度到1 km）；2001年—2002年，将MOD16A2(V105)和NTSG产品进行简单平均；2003年—2017年，将PML产品（通过像元平均升尺度到1 km）和

SSEBop 产品进行简单平均, 2018 年—2019 年选用 SSEBop 产品; 共同组合构成了 Synthesis ET 产品。该产品综合了几种集成产品的优点, 为用户提供了一套精度相对可靠、不用对比可直接使用的综合产品, 然而, 不同空间分辨率的产品其像元代表的空间尺度不同, 不考虑通量观测源区直接验证对比进行精度排序缺乏合理性。

4 结 语

过去三十年, 尤其是近十年, 数据驱动的蒸散发遥感反演取得了迅速的发展。从最初的利用与地气温差和净辐射的非线性关系来估算地表蒸散发, 逐渐发展为基于大量观测数据在物理模型基础上构建半经验回归关系, 再到机器学习、深度学习方法的广泛应用, 数据驱动的方法形式越来越多样化, 数据驱动的蒸散发反演精度也逐步提升, 同时涌现出多种数据驱动的全球蒸散发产品。但是目前仍面临一些困难。

(1) 缺乏高时空分辨率的蒸散发产品。高时空分辨率的 ET 能够更好地刻画其时空变化差异, 对于更精准的水分平衡量化和田间尺度水资源管理具有重要意义。已有的数据驱动的产品, 难以同时兼顾高时间和高空间分辨率的特征, 仅有尚未发布的 Hi-GLASS-ET 产品具有较高的空间分辨率 (30 m) 但其时间分辨率较低 (16 d), 而时间分辨率高的产品空间分辨率很粗 (0.5°), 其余大多数产品均具有较粗的时空分辨率 (8 d, 0.05° 及以上)。对于全遥感驱动的反演方法, 缺乏高时空分辨率且时空连续的可获取遥感数据; 依赖于气象数据的产品, 已有的全球再分析产品分辨率较粗, 降低了估算结果的空间分辨率; 不同气象资料的差异性和区域气象数据的不确定性, 也增加了估算精度的不确定性。

(2) 空间尺度不匹配的问题。站点观测源区与卫星像元之间存在空间尺度差异。虽然 LAS 能够获取像元尺度的蒸散发观测, 但是 LAS 观测站点少, 不足以用于构建大尺度及全球的估算模型。现有研究多基于 EC 观测数据, 建立观测通量与气象观测或中分辨率遥感产品的关系来获取国家或全球尺度蒸散发, 由于遥感及气象驱动数据空间分辨率不高, 使得不能有效考虑站点通量观测源区与格网气象数据或中分辨率遥感产品的空间尺度差异, 从而降低了反演精度。

(3) 物理机理不足, 空间扩展性有限。经验方法或者机器学习方法基于有限的 (几百个) 站点观测构建模型, 在有观测数据的区域精度较好, 但数据代表性不足限制了模型的泛化性, 使得其空间扩展性有待考究。由于全球气候差异, 地形起伏、地表异质性等原因, 有限的站点无法代表全球所有地表情况, 例如沙漠、湿地等缺乏观测数据的区域, 其估算精度无法保证。

(4) 地表温度、土壤湿度等蒸散发重要驱动因素考虑不足。热红外地表温度可以为估算蒸散发提供表层土壤水分状态等有价值的信息, 能更好的指示蒸散发的时空异质性。微波遥感能直接提供土壤湿度信息, 现有的方法其湿度输入因子多考虑的是水汽压亏缺和相对湿度, 没有有效考虑对蒸散发有直接影响的土壤湿度信息。已有研究多使用植被指数等遥感变量, 虽然可以较好的反应蒸散发的长期变化, 但不能很好的监测短期的变化。

(5) 观测数据质量问题。虽然在现有的数据基础和条件下, 数据驱动的方法可以一定程度提高 ET 估算精度, 但高精度的反演结果高度依赖于高质量的驱动数据。数据驱动的方法多采用通量观测数据来驱动模型, 全球应用广泛的 EC 观测通量存在着能量不闭合的问题, 据报道全球平均能量不闭合率约为 0.8 (Wang 和 Dickinson, 2012), 在使用数据驱动的方法反演 ET 时, 是否需要能量平衡闭合校正仍存在争议, 部分研究仍从校正和不校正两方面开展工作。

(6) 缺乏基于数据的蒸发蒸腾分离方法。全球范围上植被蒸腾约占表面净辐射的 30%—40% (Schlesinger 和 Jasechko, 2014), 约占蒸散发的 56%—74% (Good 等, 2015)。土壤蒸发和植被蒸腾的分离相比于整体, 更具有科学意义和应用价值, 对于旱半干旱地区农田灌溉、农田水分利用效率的提升具有重要意义 (宋立生等, 2016)。尽管已有全球分布的 200 多个观测站点开展植被叶流计蒸腾观测试验, 但是其观测得到的蒸腾空间尺度有限, 在大区域进行像元尺度的蒸发蒸腾分离时存在尺度不匹配的问题 (Xu 等, 2021)。目前仅有个别数据驱动的单独评估蒸腾的研究 (Fan 等, 2021), 仍缺乏通用的基于数据驱动的蒸发蒸腾分离方法。

综上所述, 本文在充分总结已有研究成果的

基础上,对现有的数据驱动的蒸散发遥感反演方法进行了梳理,从经验回归、到机器学习的广泛应用、到数据融合和降尺度,从方法和现有全球产品两方面归纳了现有方法的优势及存在的问题。如今的大数据时代,信息收集速度远大于我们所能理解的速度,提取并解读信息是当下面临的挑战,基于数据驱动的方法是挑战中的机遇。归根结底,数据驱动的蒸散发遥感反演,其核心问题仍是数据的问题。一方面,由于数据驱动(机器学习)方法强大的回归能力,即使驱动数据出现错误,也可能获取精度较好的估算结果,而另一方面,当数据的时空代表性极其有限时,巧妇也难为无米之炊。考虑到基于数据驱动(机器学习)的方法可以大幅提高回归预测精度,一个重要的发展方向是数据驱动方法与物理模型的深度融合,而现有的数据驱动方法与物理模型的结合严重不足。虽然现有的数据驱动的同—时空分辨率的蒸散发融合,已与物理模型相结合开展多模型融合研究,但力度仍显不足,且主要是从外部结合,即利用机器学习方法作为融合模型来融合物理方法,而缺乏内部结合,即用机器学习方法估算蒸散发物理模型中难以获取的输入参数,通过提高物理模型中复杂参数(如地表粗糙度)的估算精度来提高物理模型的精度。值得一提的是,虽然数据驱动的反演模型可以获取高精度蒸散发,但是并不能替代物理模型。相比于数据驱动的模式,一些物理模型对特定的输入参数较敏感,在全球尺度上获取高精度的输入参数存在较大困难,导致物理模型的估算精度难以优于数据驱动的方法。而相比于物理模型,多数基于数据驱动的方法缺乏对蒸散发过程的解释能力,使得对估算结果进行分析时其可解释性有限。在目前高精度高时空分辨率驱动数据匮乏的情况下,基于数据驱动的方法与物理模型应该紧密结合,各取所长,相辅相成,互相促进,使得机理与高精度并存,共同提升蒸散发遥感反演精度,以获取精度高可拓展性好的蒸散发遥感产品。

参考文献(References)

- Abdullah S S, Malek M A, Abdullah N S, Kisi O and Yap K S. 2015. Extreme Learning Machines: a new approach for prediction of reference evapotranspiration. *Journal of Hydrology*, 527: 184-195 [DOI: 10.1016/j.jhydrol.2015.04.073]
- Allen R G, Tasumi M and Trezza R. 2007. Satellite-based energy balance for mapping evapotranspiration with internalized calibration (METRIC)-Model. *Journal of Irrigation and Drainage Engineering*, 133(4): 380-394 [DOI: 10.1061/(ASCE)0733-9437(2007)133:4(380)]
- Anderson M C, Kustas W P, Norman J M, Hain C R, Mecikalski J R, Schultz L, González-Dugo M P, Cammalleri C, d'Urso G, Pimstein A and Gao F. 2011. Mapping daily evapotranspiration at field to continental scales using geostationary and polar orbiting satellite imagery. *Hydrology and Earth System Sciences*, 15(1): 223-239 [DOI: 10.5194/hess-15-223-2011]
- Bai J, Jia L, Liu S M, Xu Z W, Hu G C, Zhu M J and Song L S. 2015. Characterizing the footprint of eddy covariance system and large aperture scintillometer measurements to validate satellite-based surface fluxes. *IEEE Geoscience and Remote Sensing Letters*, 12(5): 943-947 [DOI: 10.1109/LGRS.2014.2368580]
- Bai Y, Zhang S, Bhattarai N, Mallick K, Liu Q, Tang L L, Im J, Guo L and Zhang J H. 2021. On the use of machine learning based ensemble approaches to improve evapotranspiration estimates from croplands across a wide environmental gradient. *Agricultural and Forest Meteorology*, 298-299: 108308 [DOI: 10.1016/j.agrformet.2020.108308]
- Baldocchi D. 2008. 'Breathing' of the terrestrial biosphere: lessons learned from a global network of carbon dioxide flux measurement systems. *Australian Journal of Botany*, 56(1): 1-26 [DOI: 10.1071/BT07151]
- Barman R, Jain A K and Liang M L. 2014. Climate-driven uncertainties in modeling terrestrial energy and water fluxes: a site-level to global-scale analysis. *Global Change Biology*, 20(6): 1885-1900 [DOI: 10.1111/gcb.12473]
- Bastiaanssen W G M, Menenti M, Feddes R A and Holtslag A A M. 1998. A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. *Journal of Hydrology*, 212-213: 198-212 [DOI: 10.1016/S0022-1694(98)00253-4]
- Bodesheim P, Jung M, Gans F, Mahecha M D and Reichstein M. 2018. Upscaled diurnal cycles of land-atmosphere fluxes: a new global half-hourly data product. *Earth System Science Data*, 10(3): 1327-1365 [DOI: 10.5194/essd-10-1327-2018]
- Carlson T N, Capehart W J and Gillies R R. 1995. A new look at the simplified method for remote sensing of daily evapotranspiration. *Remote Sensing of Environment*, 54(2): 161-167 [DOI: 10.1016/0034-4257(95)00139-R]
- Carter C and Liang S L. 2018. Comprehensive evaluation of empirical algorithms for estimating land surface evapotranspiration. *Agricultural and Forest Meteorology*, 256-257: 334-345 [DOI: 10.1016/j.agrformet.2018.03.027]
- Carter C and Liang S L. 2019. Evaluation of ten machine learning methods for estimating terrestrial evapotranspiration from remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 78: 86-92 [DOI: 10.1016/j.jag.2019.01.020]

- Chen J M and Liu J. 2020. Evolution of evapotranspiration models using thermal and shortwave remote sensing data. *Remote Sensing of Environment*, 237: 111594 [DOI: 10.1016/j.rse.2019.111594]
- Chen Y, Xia J Z, Liang S L, Feng J M, Fisher J B, Li X, Li X L, Liu S G, Ma Z G, Miyata A, Mu Q Z, Sun L, Tang J W, Wang K C, Wen J, Xue Y J, Yu G R, Zha T G, Zhang L, Zhang Q, Zhao T B, Zhao L and Yuan W P. 2014. Comparison of satellite-based evapotranspiration models over terrestrial ecosystems in China. *Remote Sensing of Environment*, 140: 279-293 [DOI: 10.1016/j.rse.2013.08.045]
- Chen Y, Yuan W P, Xia J Z, Fisher J B, Dong W J, Zhang X T, Liang S L, Ye A Z, Cai W W and Feng J M. 2015. Using Bayesian model averaging to estimate terrestrial evapotranspiration in China. *Journal of Hydrology*, 528: 537-549 [DOI: 10.1016/j.jhydrol.2015.06.059]
- Choudhury B J. 1991. Passive microwave remote sensing contribution to hydrological variables. *Surveys in Geophysics*, 12(1): 63-84 [DOI: 10.1007/BF01903412]
- Cleugh H A, Leuning R, Mu Q Z and Running S W. 2007. Regional evaporation estimates from flux tower and MODIS satellite data. *Remote Sensing of Environment*, 106(3): 285-304 [DOI: 10.1016/j.rse.2006.07.007]
- Crow W T, Kustas W P and Prueger J H. 2008. Monitoring root-zone soil moisture through the assimilation of a thermal remote sensing-based soil moisture proxy into a water balance model. *Remote Sensing of Environment*, 112(4): 1268-1281 [DOI: 10.1016/j.rse.2006.11.033]
- Dente L, Satalino G, Mattia F and Rinaldi M. 2008. Assimilation of leaf area index derived from ASAR and MERIS data into CERES-Wheat model to map wheat yield. *Remote Sensing of Environment*, 112(4): 1395-1407 [DOI: 10.1016/j.rse.2007.05.023]
- Deo R C and Şahin M. 2015. Application of the Artificial Neural Network model for prediction of monthly Standardized Precipitation and Evapotranspiration Index using hydrometeorological parameters and climate indices in eastern Australia. *Atmospheric Research*, 161-162: 65-81 [DOI: 10.1016/j.atmosres.2015.03.018]
- Deo R C and Samui P. 2017. Forecasting evaporative loss by least-square support-vector regression and evaluation with genetic programming, Gaussian process, and minimax probability machine regression: case study of Brisbane city. *Journal of Hydrologic Engineering*, 22(6): 05017003 [DOI: 10.1061/(ASCE)HE.1943-5584.0001506]
- Dirmeyer P A, Gao X, Zhao M, Guo Z C, Oki T and Hanasaki N. 2006. GSWP-2: multimodel analysis and implications for our perception of the land surface. *Bulletin of the American Meteorological Society*, 87(10): 1381-1398 [DOI: 10.1175/BAMS-87-10-1381]
- Draper C S, Reichle R H and Koster R D. 2018. Assessment of MERA-2 land surface energy flux estimates. *Journal of Climate*, 31(2): 671-691 [DOI: 10.1175/JCLI-D-17-0121.1]
- Elnashar A, Wang L J, Wu B F, Zhu W W and Zeng H W. 2021. Synthesis of global actual evapotranspiration from 1982 to 2019. *Earth System Science Data*, 13: 447-480 [DOI: 10.5194/essd-13-447-2021]
- Fan J L, Yue W J, Wu L F, Zhang F C, Cai H J, Wang X K, Lu X H and Xiang Y Z. 2018. Evaluation of SVM, ELM and four tree-based ensemble models for predicting daily reference evapotranspiration using limited meteorological data in different climates of China. *Agricultural and Forest Meteorology*, 263: 225-241 [DOI: 10.1016/j.agrformet.2018.08.019]
- Fan J L, Zheng J, Wu L F and Zhang F C. 2021. Estimation of daily maize transpiration using support vector machines, extreme gradient boosting, artificial and deep neural networks models. *Agricultural Water Management*, 245: 106547 [DOI: 10.1016/j.agwat.2020.106547]
- Feng F, Chen J Q, Li X L, Yao Y J, Liang S L, Liu M, Zhang N N, Guo Y, Yu J and Sun M M. 2015. Validity of five satellite-based latent heat flux algorithms for semi-arid ecosystems. *Remote Sensing*, 7(12): 16733-16755 [DOI: 10.3390/rs71215853]
- Feng F, Li X L, Yao Y J, Liang S L, Chen J Q, Zhao X, Jia K, Pinter K and McCaughey J H. 2016a. An empirical orthogonal function-based algorithm for estimating terrestrial latent heat flux from eddy covariance, meteorological and satellite observations. *PLoS One*, 11(7): e0160150 [DOI: 10.1371/journal.pone.0160150]
- Feng Y, Cui N B, Gong D Z, Zhang Q W and Zhao L. 2017a. Evaluation of random forests and generalized regression neural networks for daily reference evapotranspiration modelling. *Agricultural Water Management*, 193: 163-173 [DOI: 10.1016/j.agwat.2017.08.003]
- Feng Y, Cui N B, Zhao L, Hu X T and Gong D Z. 2016b. Comparison of ELM, GANN, WNN and empirical models for estimating reference evapotranspiration in humid region of Southwest China. *Journal of Hydrology*, 536: 376-383 [DOI: 10.1016/j.jhydrol.2016.02.053]
- Feng Y, Peng Y, Cui N B, Gong D Z and Zhang K D. 2017b. Modeling reference evapotranspiration using extreme learning machine and generalized regression neural network only with temperature data. *Computers and Electronics in Agriculture*, 136: 71-78 [DOI: 10.1016/j.compag.2017.01.027]
- Fisher J B, Tu K P and Baldocchi D D. 2008. Global estimates of the land-atmosphere water flux based on monthly AVHRR and ISLSCP-II data, validated at 16 FLUXNET sites. *Remote Sensing of Environment*, 112(3): 901-919 [DOI: 10.1016/j.rse.2007.06.025]
- Good S P, Noone D and Bowen G. 2015. Hydrologic connectivity constrains partitioning of global terrestrial water fluxes. *Science*, 349(6244): 175-177 [DOI: 10.1126/science.aaa5931]
- Goyal M K, Bharti B, Quilty J, Adamowski J and Pandey A. 2014. Modeling of daily pan evaporation in sub tropical climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS. *Expert Systems with Applications*, 41(11): 5267-5276 [DOI: 10.1016/j.eswa.2014.02.047]
- Guzinski R and Nieto H. 2019. Evaluating the feasibility of using Sentinel-2 and Sentinel-3 satellites for high-resolution evapotranspiration

- tion estimations. *Remote Sensing of Environment*, 221: 157-172 [DOI: 10.1016/j.rse.2018.11.019]
- Han X J, Duan S B, Leng P, Wang W and Li Z L. 2017. Estimation of annual daily averaged evapotranspiration across China during 1996-2015 using passive microwave observations//2017 Progress in Electromagnetics Research Symposium - Spring (PIERS). St. Petersburg, Russia: IEEE: 2150-2154 [DOI: 10.1109/PIERS.2017.8262107]
- Helman D, Givati A and Lensky I M. 2015. Annual evapotranspiration retrieved from satellite vegetation indices for the eastern Mediterranean at 250 m spatial resolution. *Atmospheric Chemistry and Physics*, 15(21): 12567-12579 [DOI: 10.5194/acp-15-12567-2015]
- Hu G C and Jia L. 2015. Monitoring of evapotranspiration in a semi-arid inland river basin by combining microwave and optical remote sensing observations. *Remote Sensing*, 7(3): 3056-3087 [DOI: 10.3390/rs70303056]
- Hu G C, Jia L and Menenti M. 2015. Comparison of MOD16 and LSA-SAF MSG evapotranspiration products over Europe for 2011. *Remote Sensing of Environment*, 156: 510-526 [DOI: 10.1016/j.rse.2014.10.017]
- Huang C L, Li X, Wang J M and Gu J. 2008. Assimilation of remote sensing data products into common land model for evapotranspiration forecasting//Proceedings of the 8th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences. Shanghai: [s.n.]: 234-241
- Im J, Park S, Rhee J, Baik J and Choi M. 2016. Downscaling of AMSR-E soil moisture with MODIS products using machine learning approaches. *Environmental Earth Sciences*, 75(15): 1120 [DOI: 10.1007/s12665-016-5917-6]
- Jackson R D, Reginato R J and Idso S B. 1977. Wheat canopy temperature: a practical tool for evaluating water requirements. *Water Resources Research*, 13(3): 651-656 [DOI: 10.1029/WR013i003p00651]
- Jajarmizadeh M, Lafdani E K, Harun S and Ahmadi A. 2015. Application of SVM and SWAT models for monthly streamflow prediction, a case study in South of Iran. *KSCE Journal of Civil Engineering*, 19(1): 345-357 [DOI: 10.1007/s12205-014-0060-y]
- Jia Z Z, Liu S M, Xu Z W, Chen Y J and Zhu M J. 2012. Validation of remotely sensed evapotranspiration over the Hai River Basin, China. *Journal of Geophysical Research: Atmospheres*, 117: D13113 [DOI: 10.1029/2011JD017037]
- Jiang C Y and Ryu Y. 2016. Multi-scale evaluation of global gross primary productivity and evapotranspiration products derived from Breathing Earth System Simulator (BESS). *Remote Sensing of Environment*, 186: 528-547 [DOI: 10.1016/j.rse.2016.08.030]
- Jiang L and Islam S. 1999. A methodology for estimation of surface evapotranspiration over large areas using remote sensing observations. *Geophysical Research Letters*, 26(17): 2773-2776 [DOI: 10.1029/1999GL006049]
- Jiménez C, Prigent C and Aires F. 2009. Toward an estimation of global land surface heat fluxes from multisatellite observations. *Journal of Geophysical Research: Atmospheres*, 114: D06305 [DOI: 10.1029/2008JD011392]
- Jiménez C, Prigent C, Mueller B, Seneviratne S I, McCabe M F, Wood E F, Rossow W B, Balsamo G, Betts A K, Dirmeyer P A, Fisher J B, Jung M, Kanamitsu M, Reichle R H, Reichstein M, Rodell M, Sheffield J, Tu K and Wang K. 2011. Global intercomparison of 12 land surface heat flux estimates. *Journal of Geophysical Research: Atmospheres*, 116: D02102 [DOI: 10.1029/2010JD014545]
- Jung M, Koirala S, Weber U, Ichii K, Gans F, Camps-Valls G, Papale D, Schwalm C, Tramontana G and Reichstein M. 2019. The FLUXCOM ensemble of global land-atmosphere energy fluxes. *Scientific Data*, 6: 74 [DOI: 10.1038/s41597-019-0076-8]
- Jung M, Reichstein M, Ciais P, Seneviratne S I, Sheffield J, Goulden M L, Bonan G, Cescatti A, Chen J Q, de Jeu R, Dolman A J, Eugster W, Gerten D, Gianelle D, Gobron N, Heinke J, Kimball J, Law B E, Montagnani L, Mu Q Z, Mueller B, Oleson K, Papale D, Richardson A D, Rouspard O, Running S, Tomelleri E, Viovy N, Weber U, Williams C, Wood E, Zaehle S and Zhang K. 2010. Recent decline in the global land evapotranspiration trend due to limited moisture supply. *Nature*, 467(7318): 951-954 [DOI: 10.1038/nature09396]
- Jung M, Reichstein M, Margolis H A, Cescatti A, Richardson A D, Arain M A, Arneeth A, Bernhofer C, Bonal D, Chen J Q, Gianelle D, Gobron N, Kiely G, Kutsch W, Lasslop G, Law B E, Lindroth A, Merbold L, Montagnani L, Moors E J, Papale D, Sottocornola M, Vaccari F and Williams C. 2011. Global patterns of land-atmosphere fluxes of carbon dioxide, latent heat, and sensible heat derived from eddy covariance, satellite, and meteorological observations. *Journal of Geophysical Research: Biogeosciences*, 116: G00J07 [DOI: 10.1029/2010JG001566]
- Kaheil Y H, Rosero E, Gill M K, McKee M and Bastidas L A. 2008. Downscaling and forecasting of evapotranspiration using a synthetic model of wavelets and support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 46(9): 2692-2707 [DOI: 10.1109/TGRS.2008.919819]
- Kalma J D, McVicar T R and McCabe M F. 2008. Estimating land surface evaporation: a review of methods using remotely sensed surface temperature data. *Surveys in Geophysics*, 29(4/5): 421-469 [DOI: 10.1007/s10712-008-9037-z]
- Ke Y H, Im J, Park S and Gong H L. 2016. Downscaling of MODIS one kilometer evapotranspiration using Landsat-8 data and machine learning approaches. *Remote Sensing*, 8(3): 215 [DOI: 10.3390/rs8030215]
- Ke Y H, Im J, Park S and Gong H L. 2017. Spatiotemporal downscaling approaches for monitoring 8-day 30 m actual evapotranspiration. *ISPRS Journal of Photogrammetry and Remote Sensing*, 126: 79-93 [DOI: 10.1016/j.isprsjprs.2017.02.006]
- Kim H W, Hwang K, Mu Q Z, Lee S O and Choi M. 2012. Validation of MODIS 16 global terrestrial evapotranspiration products in various climates and land cover types in Asia. *KSCE Journal of Civil*

- Engineering, 16(2): 229-238 [DOI: 10.1007/s12205-012-0006-1]
- Kisi O. 2015. Pan evaporation modeling using least square support vector machine, multivariate adaptive regression splines and M5 model tree. *Journal of Hydrology*, 528: 312-320 [DOI: 10.1016/j.jhydrol.2015.06.052]
- Kisi O, Sanikhani H, Zounemat-Kermani M and Niazi F. 2015. Long-term monthly evapotranspiration modeling by several data-driven methods without climatic data. *Computers and Electronics in Agriculture*, 115: 66-77 [DOI: 10.1016/j.compag.2015.04.015]
- Kumar M, Raghuvanshi N S, Singh R, Wallender W W and Pruitt W O. 2002. Estimating evapotranspiration using artificial neural network. *Journal of Irrigation and Drainage Engineering*, 128(4): 224-233 [DOI: 10.1061/(ASCE)0733-9437(2002)128:4(224)]
- Kustas W P and Norman J M. 1996. Use of remote sensing for evapotranspiration monitoring over land surfaces. *Hydrological Sciences Journal*, 41(4): 495-516 [DOI: 10.1080/02626669609491522]
- Kustas W P, Schmugge T J, Humes K S, Jackson T J, Parry R, Weltz M A and Moran M S. 1993. Relationships between evaporative fraction and remotely sensed vegetation index and microwave brightness temperature for semiarid rangelands. *Journal of Applied Meteorology and Climatology*, 32(12): 1781-1790 [DOI: 10.1175/1520-0450(1993)032<1781:RBEFAR>2.0.CO;2]
- LeCun Y, Bengio Y and Hinton G. 2015. Deep learning. *Nature*, 521(7553): 436-444 [DOI: 10.1038/nature14539]
- Li J, Xin X Z, Peng Z Q and Li X J. 2021. Remote sensing products of terrestrial evapotranspiration: comparison and outlook. *Remote Sensing Technology and Application*, 36(1): 103-120 (李佳, 辛晓洲, 彭志晴, 李小军. 2021. 地表蒸散发遥感产品比较与分析. *遥感技术与应用*, 36(1): 103-120) [DOI: 10.11873/j.issn.1004-0323.2021.1.0103]
- Li X, Liu S M, Li H X, Ma Y F, Wang J H, Zhang Y, Xu Z W, Xu T R, Song L S, Yang X F, Lu Z, Wang Z Y and Guo Z X. 2018. Inter-comparison of six upscaling evapotranspiration methods: from site to the satellite pixel. *Journal of Geophysical Research: Atmospheres*, 123(13): 6777-6803 [DOI: 10.1029/2018JD028422]
- Li Z L, Tang R L, Wan Z M, Bi Y Y, Zhou C H, Tang B H, Yan G J and Zhang X Y. 2009. A review of current methodologies for regional evapotranspiration estimation from remotely sensed data. *Sensors*, 9(5): 3801-3853 [DOI: 10.3390/s90503801]
- Liang S L, Cheng J, Jia K, Jiang B, Liu Q, Xiao Z Q, Yao Y J, Yuan W P, Zhang X T, Zhao X and Zhou J. 2021. The Global Land Surface Satellite (GLASS) product suite. *Bulletin of the American Meteorological Society*, 102(2): E323-E337 [DOI: 10.1175/BAMS-D-18-0341.1]
- Liang S L, Li X W and Wang J D. 2013. *Quantitative Remote Sensing: Concepts and Algorithms*. Beijing: Science Publishing Press (梁顺林, 李小文, 王锦地. 2013. 定量遥感: 理念与算法. 北京: 科学出版社)
- Liu M, Tang R L, Li Z L, Mao H R, Zhou F C and Yan G J. 2018a. Estimation of annual averaged evapotranspiration by using passive microwave observations//2018 IEEE International Geoscience and Remote Sensing Symposium. Valencia, Spain: IEEE: 791-794 [DOI: 10.1109/IGARSS.2018.8518728]
- Liu M, Tang R L, Li Z L and Yan G J. 2019. Integration of two semi-physical models of terrestrial evapotranspiration using the China meteorological forcing dataset. *International Journal of Remote Sensing*, 40(5/6): 1966-1980 [DOI: 10.1080/01431161.2018.1482026]
- Liu M, Tang R L, Li Z L, Yao Y J and Yan G J. 2018b. Global land surface evapotranspiration estimation from meteorological and satellite data using the support vector machine and semiempirical algorithm. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(2): 513-521 [DOI: 10.1109/JSTARS.2017.2788462]
- Liu S M, Xu Z W, Song L S, Zhao Q Y, Ge Y, Xu T R, Ma Y F, Zhu Z L, Jia Z Z and Zhang F. 2016. Upscaling evapotranspiration measurements from multi-site to the satellite pixel scale over heterogeneous land surfaces. *Agricultural and Forest Meteorology*, 230-231: 97-113 [DOI: 10.1016/j.agrformet.2016.04.008]
- Long D and Singh V P. 2012. A two-source trapezoid model for evapotranspiration (TTME) from satellite imagery. *Remote Sensing of Environment*, 121: 370-388 [DOI: 10.1016/j.rse.2012.02.015]
- Lu X H, Ju Y, Wu L F, Fan J L, Zhang F C and Li Z J. 2018. Daily pan evaporation modeling from local and cross-station data using three tree-based machine learning models. *Journal of Hydrology*, 566: 668-684 [DOI: 10.1016/j.jhydrol.2018.09.055]
- Mao Y, Wang K C, Liu X M and Liu C M. 2016. Water storage in reservoirs built from 1997 to 2014 significantly altered the calculated evapotranspiration trends over China. *Journal of Geophysical Research: Atmospheres*, 121(17): 10097-10112 [DOI: 10.1002/2016JD025447]
- Martens B, Miralles D G, Lievens H, van der Schalie R, de Jeu R A M, Fernández-Prieto D, Beck H E, Dorigo W A and Verhoest N E C. 2017. GLEAM v3: satellite-based land evaporation and root-zone soil moisture. *Geoscientific Model Development*, 10(5): 1903-1925 [DOI: 10.5194/gmd-10-1903-2017]
- Mehdizadeh S, Behmanesh J and Khalili K. 2017. Using MARS, SVM, GEP and empirical equations for estimation of monthly mean reference evapotranspiration. *Computers and Electronics in Agriculture*, 139: 103-114 [DOI: 10.1016/j.compag.2017.05.002]
- Min Q L and Lin B. 2006. Remote sensing of evapotranspiration and carbon uptake at Harvard Forest. *Remote Sensing of Environment*, 100(3): 379-387 [DOI: 10.1016/j.rse.2005.10.020]
- Monteith J L. 1965. Evaporation and environment. *Symposia of the Society for Experimental Biology*, 19: 205-234
- Moran M S, Clarke T R, Inoue Y and Vidal A. 1994. Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index. *Remote Sensing of Environment*, 49(3): 246-263 [DOI: 10.1016/0034-4257(94)90020-5]
- Mu Q Z, Heinsch F A, Zhao M S and Running S W. 2007. Development of a global evapotranspiration algorithm based on MODIS and global meteorology data. *Remote Sensing of Environment*,

- 111(4): 519-536 [DOI: 10.1016/j.rse.2007.04.015]
- Mu Q Z, Zhao M S and Running S W. 2011. Improvements to a MODIS global terrestrial evapotranspiration algorithm. *Remote Sensing of Environment*, 115(8): 1781-1800 [DOI: 10.1016/j.rse.2011.02.019]
- Mueller B, Seneviratne S I, Jimenez C, Corti T, Hirschi M, Balsamo G, Ciais P, Dirmeyer P, Fisher J B, Guo Z, Jung M, Maignan F, McCabe M F, Reichle R, Reichstein M, Rodell M, Sheffield J, Teuling A J, Wang K, Wood E F and Zhang Y. 2011. Evaluation of global observations-based evapotranspiration datasets and IPCC AR4 simulations. *Geophysical Research Letters*, 38: L06402 [DOI: 10.1029/2010GL046230]
- Nagler P L, Cleverly J, Glenn E, Lampkin D, Huete A and Wan Z M. 2005a. Predicting riparian evapotranspiration from MODIS vegetation indices and meteorological data. *Remote Sensing of Environment*, 94(1): 17-30 [DOI: 10.1016/j.rse.2004.08.009]
- Nagler P L, Scott R L, Westenburg C, Cleverly J R, Glenn E P and Huete A R. 2005b. Evapotranspiration on western U.S. rivers estimated using the Enhanced Vegetation Index from MODIS and data from eddy covariance and Bowen ratio flux towers. *Remote Sensing of Environment*, 97(3): 337-351 [DOI: 10.1016/j.rse.2005.05.011]
- Norman J M, Kustas W P and Humes K S. 1995. Source approach for estimating soil and vegetation energy fluxes in observations of directional radiometric surface temperature. *Agricultural and Forest Meteorology*, 77(3/4): 263-293 [DOI: 10.1016/0168-1923(95)02265-Y]
- Oki T and Kanae S. 2006. Global hydrological cycles and world water resources. *Science*, 313(5790): 1068-1072 [DOI: 10.1126/science.1128845]
- Penman H L. 1948. Natural evaporation from open water, bare soil and grass. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 193(1032): 120-145 [DOI: 10.1098/rspa.1948.0037]
- Priestley C H B and Taylor R J. 1972. On the assessment of surface heat flux and evaporation using large-scale parameters. *Monthly Weather Review*, 100(2): 81-92 [DOI: 10.1175/1520-0493(1972)100<0081:OTAOSH>2.3.CO;2]
- Qiu G Y, Li C and Yan C H. 2015. Characteristics of soil evaporation, plant transpiration and water budget of *Nitraria* dune in the arid Northwest China. *Agricultural and Forest Meteorology*, 203: 107-117 [DOI: 10.1016/j.agrformet.2015.01.006]
- Raghavendra N S and Deka P C. 2014. Support vector machine applications in the field of hydrology: a review. *Applied Soft Computing*, 19: 372-386 [DOI: 10.1016/j.asoc.2014.02.002]
- Reichstein M, Camps-Valls G, Stevens B, Jung M, Denzler J, Carvalhais N and Prabhat. 2019. Deep learning and process understanding for data-driven earth system science. *Nature*, 566(7743): 195-204 [DOI: 10.1038/s41586-019-0912-1]
- Schlesinger W H and Jasechko S. 2014. Transpiration in the global water cycle. *Agricultural and Forest Meteorology*, 189-190: 115-117 [DOI: 10.1016/j.agrformet.2014.01.011]
- Seguin B, Baelz S, Monget J M and Petit V. 1982. Utilisation de la thermographie IR pour l'estimation de l'évaporation régionale II. - Résultats obtenus à partir des données de satellite. *Agronomie*, 2(2): 113-118 [DOI: 10.1051/agro:19820202]
- Seguin B, Courault D and Guéris M. 1994. Surface temperature and evapotranspiration: application of local scale methods to regional scales using satellite data. *Remote Sensing of Environment*, 49(3): 287-295 [DOI: 10.1016/0034-4257(94)90023-X]
- Seguin B and Itier B. 1983. Using midday surface temperature to estimate daily evaporation from satellite thermal IR data. *International Journal of Remote Sensing*, 4(2): 371-383 [DOI: 10.1080/01431168308948554]
- Shen H F, Jiang M H, Li J, Yuan Q Q, Wei Y C and Zhang L P. 2019. Spatial-spectral fusion by combining deep learning and variational model. *IEEE Transactions on Geoscience and Remote Sensing*, 57(8): 6169-6181 [DOI: 10.1109/TGRS.2019.2904659]
- Shiri J. 2018. Improving the performance of the mass transfer-based reference evapotranspiration estimation approaches through a coupled wavelet-random forest methodology. *Journal of Hydrology*, 561: 737-750 [DOI: 10.1016/j.jhydrol.2018.04.042]
- Shrestha N K and Shukla S. 2015. Support vector machine based modeling of evapotranspiration using hydro-climatic variables in a sub-tropical environment. *Agricultural and Forest Meteorology*, 200: 172-184 [DOI: 10.1016/j.agrformet.2014.09.025]
- Shuttleworth W J and Wallace J S. 1985. Evaporation from sparse crops-an energy combination theory. *Quarterly Journal of the Royal Meteorological Society*, 111(469): 839-855 [DOI: 10.1002/qj.49711146910]
- Song L S, Kustas W P, Liu S M, Colaizzi P D, Nieto H, Xu Z W, Ma Y F, Li M S, Xu T R, Agam N, Tolck J A and Evett S R. 2016. Applications of a thermal-based two-source energy balance model using Priestley-Taylor approach for surface temperature partitioning under advective conditions. *Journal of Hydrology*, 540: 574-587 [DOI: 10.1016/j.jhydrol.2016.06.034]
- Song L S, Liu S M, Xu T R, Xu Z W and Ma Y F. 2017. Soil evaporation and vegetation transpiration: remotely sensed estimation and validation. *Journal of Remote Sensing*, 21(6): 966-981 (宋立生, 刘绍民, 徐同仁, 徐自为, 马燕飞. 2017. 土壤蒸发和植被蒸腾遥感估算与验证. *遥感学报*, 21(6): 966-981) [DOI: 10.11834/jrs.20176391]
- Springer A, Kusche J, Hartung K, Ohlwein C and Longuevergne L. 2014. New estimates of variations in water flux and storage over Europe based on regional (Re)analyses and multisensor observations. *Journal of Hydrometeorology*, 15(6): 2397-2417 [DOI: 10.1175/JHM-D-14-0050.1]
- Srivastava P K, Han D W, Ramirez M R and Islam T. 2013. Machine learning techniques for downscaling SMOS satellite soil moisture using MODIS land surface temperature for hydrological application. *Water Resources Management*, 27(8): 3127-3144 [DOI: 10.1007/s11269-013-0337-9]

- Stegehuis A I, Teuling A J, Ciais P, Vautard R and Jung M. 2013. Future European temperature change uncertainties reduced by using land heat flux observations. *Geophysical Research Letters*, 40(10): 2242-2245 [DOI: 10.1002/grl.50404]
- Su Z. 2002. The Surface Energy Balance System (SEBS) for estimation of turbulent heat fluxes. *Hydrology and Earth System Sciences*, 6(1): 85-100 [DOI: 10.5194/hess-6-85-2002]
- Swenson S C and Lawrence D M. 2014. Assessing a dry surface layer-based soil resistance parameterization for the Community Land Model using GRACE and FLUXNET-MTE data. *Journal of Geophysical Research: Atmospheres*, 119(17): 10299-10312 [DOI: 10.1002/2014jd022314]
- Tang R L. 2011. Retrieval of Land Surface Evapotranspiration from Remotely Sensed Surface Temperature-Fractional Vegetation Cover Characteristic Space. Beijing: Chinese Academy of Sciences (唐荣林. 2011. 基于地表温度—植被覆盖度特征空间的地表蒸发遥感反演方法研究. 北京: 中国科学院研究生院)
- Tang R L and Li Z L. 2017a. An end-member-based two-source approach for estimating land surface evapotranspiration from remote sensing data. *IEEE Transactions on Geoscience and Remote Sensing*, 55(10): 5818-5832 [DOI: 10.1109/TGRS.2017.2715361]
- Tang R L and Li Z L. 2017b. An improved constant evaporative fraction method for estimating daily evapotranspiration from remotely sensed instantaneous observations. *Geophysical Research Letters*, 44(5): 2319-2326 [DOI: 10.1002/2017GL072621]
- Tang R L, Li Z L and Tang B H. 2010. An application of the T_s -VI triangle method with enhanced edges determination for evapotranspiration estimation from MODIS data in arid and semi-arid regions: implementation and validation. *Remote Sensing of Environment*, 114(3): 540-551 [DOI: 10.1016/j.rse.2009.10.012]
- Torres A F, Walker W R and McKee M. 2011. Forecasting daily potential evapotranspiration using machine learning and limited climatic data. *Agricultural Water Management*, 98(4): 553-562 [DOI: 10.1016/j.agwat.2010.10.012]
- Tramontana G, Jung M, Schwalm C R, Ichii K, Camps-Valls G, Ráduly B, Reichstein M, Arain M A, Cescatti A, Kiely G, Merbold L, Serrano-Ortiz P, Sickert S, Wolf S and Papale D. 2016. Predicting carbon dioxide and energy fluxes across global FLUXNET sites with regression algorithms. *Biogeosciences*, 13: 4291-4313 [DOI: 10.5194/bg-13-4291-2016]
- Trenberth K E, Fasullo J T and Kiehl J. 2009. Earth's global energy budget. *Bulletin of the American Meteorological Society*, 90(3): 311-324 [DOI: 10.1175/2008BAMS2634.1]
- Vinukollu R K, Wood E F, Ferguson C R and Fisher J B. 2011. Global estimates of evapotranspiration for climate studies using multi-sensor remote sensing data: evaluation of three process-based approaches. *Remote Sensing of Environment*, 115(3): 801-823 [DOI: 10.1016/j.rse.2010.11.006]
- Wang K C and Dickinson R E. 2012. A review of global terrestrial evapotranspiration: observation, modeling, climatology, and climatic variability. *Reviews of Geophysics*, 50(2): (RG2005) [DOI: 10.1029/2011RG000373]
- Wang K C, Dickinson R E, Wild M and Liang S L. 2010. Evidence for decadal variation in global terrestrial evapotranspiration between 1982 and 2002: 1. Model development. *Journal of Geophysical Research: Atmospheres*, 115(D20): D20112 [DOI: 10.1029/2009JD013671]
- Wang K C, Li Z Q and Cribb M. 2006. Estimation of evaporative fraction from a combination of day and night land surface temperatures and NDVI: A new method to determine the Priestley-Taylor parameter. *Remote Sensing of Environment*, 102(3/4): 293-305 [DOI: 10.1016/j.rse.2006.02.007]
- Wang K C and Liang S L. 2008. An improved method for estimating global evapotranspiration based on satellite determination of surface net radiation, vegetation index, temperature, and soil moisture. *Journal of Hydrometeorology*, 9(4): 712-727 [DOI: 10.1175/2007JHM911.1]
- Wang K C, Wang P C, Li Z Q, Cribb M and Sparrow M. 2007. A simple method to estimate actual evapotranspiration from a combination of net radiation, vegetation index, and temperature. *Journal of Geophysical Research: Atmospheres*, 112: D15107 [DOI: 10.1029/2006JD008351]
- Wang T, Tang R L, Li Z L, Jiang Y Z, Liu M and Niu L. 2019. An improved spatio-temporal adaptive data fusion algorithm for evapotranspiration mapping. *Remote Sensing*, 11(7): 761 [DOI: 10.3390/rs11070761]
- Wang X Y, Yao Y J, Zhao S H, Jia K, Zhang X T, Zhang Y H, Zhang L, Xu J and Chen X W. 2017. MODIS-based estimation of terrestrial latent heat flux over North America using three machine learning algorithms. *Remote Sensing*, 9(12): 1326 [DOI: 10.3390/rs9121326]
- Wu B F, Xiong J and Yan S S. 2011. ETWatch: models and methods. *Journal of Remote Sensing*, 15(2): 224-239 (吴炳方, 熊隽, 闫姗姗. 2011. ETWatch的模型与方法. 遥感学报, 15(2): 224-239) [DOI: 10.11834/jrs.20110297]
- Wu B F, Yan N, Xiong J, Bastiaanssen W G M, Zhu W W and Stein A. 2012. Validation of ETWatch using field measurements at diverse landscapes: a case study in Hai Basin of China. *Journal of Hydrology*, 436-437: 67-80 [DOI: 10.1016/j.jhydrol.2012.02.043]
- Wu H and Ying W M. 2019. Benchmarking machine learning algorithms for instantaneous net surface shortwave radiation retrieval using remote sensing data. *Remote Sensing*, 11(21): 2520 [DOI: 10.3390/rs11212520]
- Xin X and Liu Q. 2010. The Two-layer Surface Energy Balance Parameterization Scheme (TSEBPS) for estimation of land surface heat fluxes. *Hydrology and Earth System Sciences*, 14(3): 491-504 [DOI: 10.5194/hess-14-491-2010]
- Xiong Y J, Feng F G, Fang Y Z, Qiu G Y, Zhao S H and Yao Y J. 2021. Critical problems when applying remotely sensed evapotranspiration products. *Remote Sensing Technology and Application*, 36(1): 121-131 (熊育久, 冯房观, 方奕舟, 邱国玉, 赵少华, 姚云军. 2021. 蒸散发遥感反演产品应用关键问题浅议. 遥感技术与应

- 用, 36(1): 121-131 [DOI: 10.11873/j.issn.1004-0323.2021.1.0121]
- Xiong Y J, Zhao S H, Tian F and Qiu G Y. 2015. An evapotranspiration product for arid regions based on the three-temperature model and thermal remote sensing. *Journal of Hydrology*, 530: 392-404 [DOI: 10.1016/j.jhydrol.2015.09.050]
- Xu J, Yao Y J, Liang S L, Liu S M, Fisher J B, Jia K, Zhang X T, Lin Y, Zhang L L and Chen X W. 2019a. Merging the MODIS and Landsat terrestrial latent heat flux products using the multiresolution tree method. *IEEE Transactions on Geoscience and Remote Sensing*, 57(5): 2811-2823 [DOI: 10.1109/TGRS.2018.2877807]
- Xu T R, Guo Z X, Liu S M, He X L, Meng Y F Y, Xu Z W, Xia Y L, Xiao J F, Zhang Y, Ma Y F and Song L S. 2018. Evaluating different machine learning methods for upscaling evapotranspiration from flux towers to the regional scale. *Journal of Geophysical Research: Atmospheres*, 123(16): 8674-8690 [DOI: 10.1029/2018JD028447]
- Xu T R, He X L, Bateni S M, Auligne T, Liu S M, Xu Z W, Zhou J and Mao K B. 2019b. Mapping regional turbulent heat fluxes via variational assimilation of land surface temperature data from polar orbiting satellites. *Remote Sensing of Environment*, 221: 444-461 [DOI: 10.1016/j.rse.2018.11.023]
- Xu T R, Liang S L and Liu S M. 2011. Estimating turbulent fluxes through assimilation of geostationary operational environmental satellites data using ensemble Kalman filter. *Journal of Geophysical Research: Atmospheres*, 116: D09109 [DOI: 10.1029/2010JD015150]
- Xu Z W, Zhu Z L, Liu S M, Song L S, Wang X C, Zhou S, Yang X F and Xu T R. 2021. Evapotranspiration partitioning for multiple ecosystems within a dryland watershed: seasonal variations and controlling factors. *Journal of Hydrology*, 598: 126483 [DOI: 10.1016/j.jhydrol.2021.126483]
- Yang F, White M A, Michaelis A R, Ichii K, Hashimoto H, Votava P, Zhu A X and Nemani R R. 2006. Prediction of continental-scale evapotranspiration by combining MODIS and AmeriFlux data through support vector machine. *IEEE Transactions on Geoscience and Remote Sensing*, 44(11): 3452-3461 [DOI: 10.1109/TGRS.2006.876297]
- Yang Y, Sun H W, Xue J, Liu Y, Liu L G, Yan D and Gui D W. 2021. Estimating evapotranspiration by coupling Bayesian model averaging methods with machine learning algorithms. *Environmental Monitoring and Assessment*, 193: 156 [DOI: 10.1007/s10661-021-08934-1]
- Yao Y J, Cheng J, Zhao S H, Jia K, Xie X H and Sun L. 2012. Estimation of farmland evapotranspiration: a review of methods using thermal infrared remote sensing data. *Advances in Earth Sciences*, 27(12): 1308-1318 (姚云军, 程洁, 赵少华, 贾坤, 谢先红, 孙亮. 2012. 基于热红外遥感的农田蒸散发估算方法研究综述. *地球科学进展*, 27(12): 1308-1318) [DOI: 10.11867/j.issn.1001-8166.2012.12.1308]
- Yao Y J, Di Z H, Xie Z J, Xiao Z Q, Jia K, Zhang X T, Shang K, Yang J M, Bei X Y, Guo X Z and Yu R Y. 2021. Simplified Priestley-Taylor model to estimate land-surface latent heat of evapotranspiration from incident shortwave radiation, satellite vegetation index, and air relative humidity. *Remote Sensing*, 13(5): 902 [DOI: 10.3390/rs13050902]
- Yao Y J, Liang S L, Cheng J, Liu S M, Fisher J B, Zhang X D, Jia K, Zhao X, Qing Q M, Zhao B, Han S J, Zhou G S, Zhou G Y, Li Y L and Zhao S H. 2013. MODIS-driven estimation of terrestrial latent heat flux in China based on a modified Priestley-Taylor algorithm. *Agricultural and Forest Meteorology*, 171-172: 187-202 [DOI: 10.1016/j.agrformet.2012.11.016]
- Yao Y J, Liang S L, Li X L, Chen J Q, Liu S M, Jia K, Zhang X T, Xiao Z Q, Fisher J B, Mu Q Z, Pan M, Liu M, Cheng J, Jiang B, Xie X H, Grünwald T, Bernhofer C and Rouspard O. 2017b. Improving global terrestrial evapotranspiration estimation using support vector machine by integrating three process-based algorithms. *Agricultural and Forest Meteorology*, 242: 55-74 [DOI: 10.1016/j.agrformet.2017.04.011]
- Yao Y J, Liang S L, Li X L, Chen J Q, Wang K C, Jia K, Cheng J, Ji-ang B, Fisher J B, Mu Q Z, Grünwald T, Bernhofer C and Rouspard O. 2015. A satellite-based hybrid algorithm to determine the Priestley-Taylor parameter for global terrestrial latent heat flux estimation across multiple biomes. *Remote Sensing of Environment*, 165: 216-233 [DOI: 10.1016/j.rse.2015.05.013]
- Yao Y J, Liang S L, Li X L, Hong Y, Fisher J B, Zhang N N, Chen J Q, Cheng J, Zhao S H, Zhang X T, Jiang B, Sun L, Jia K, Wang K C, Chen Y, Mu Q Z and Feng F. 2014. Bayesian multimodel estimation of global terrestrial latent heat flux from eddy covariance, meteorological, and satellite observations. *Journal of Geophysical Research: Atmospheres*, 119(8): 4521-4545 [DOI: 10.1002/2013JD020864]
- Yao Y J, Liang S L, Li X L, Liu S M, Chen J Q, Zhang X T, Jia K, Ji-ang B, Xie X H, Munier S, Liu M, Yu J, Lindroth A, Varlagin A, Raschi A, Noormets A, Pio C, Wohlfahrt G, Sun G, Domec J C, Montagnani L, Lund M, Eddy M, Blanken P D, Grünwald T, Wolf S and Magliulo V. 2016. Assessment and simulation of global terrestrial latent heat flux by synthesis of CMIP5 climate models and surface eddy covariance observations. *Agricultural and Forest Meteorology*, 223: 151-167 [DOI: 10.1016/j.agrformet.2016.03.016]
- Yao Y J, Liang S L, Li X L, Zhang Y H, Chen J Q, Jia K, Zhang X T, Fisher J B, Wang X Y, Zhang L L, Xu J, Shao C L, Posse G, Li Y N, Magliulo V, Varlagin A, Moors E J, Boike J, Macfarlane C, Kato T, Buchmann N, Billesbach D P, Beringer J, Wolf S, Papuga S A, Wohlfahrt G, Montagnani L, Ardö J, Paul-Limoges E, Emmel C, Hörtnagl L, Sachs T, Gruening C, Gioli B, López-Ballesteros A, Steinbrecher R and Gielen B. 2017c. Estimation of high-resolution terrestrial evapotranspiration from Landsat data using a simple Taylor skill fusion method. *Journal of Hydrology*, 553: 508-526 [DOI: 10.1016/j.jhydrol.2017.08.013]
- Yao Y J, Liang S L, Qin Q M, Wang K C and Zhao S H. 2011. Monitoring global land surface drought based on a hybrid evapotranspiration model. *International Journal of Applied Earth Observation*

- and Geoinformation, 13(3): 447-457 (DOI: 10.1016/j.jag.2010.09.009)
- Yao Y J, Liang S L, Yu J, Chen J Q, Liu S M, Lin Y, Fisher J B, McVicar T R, Cheng J, Jia K, Zhang X T, Xie X H, Jiang B and Sun L. 2017a. A simple temperature domain two-source model for estimating agricultural field surface energy fluxes from Landsat images. *Journal of Geophysical Research: Atmospheres*, 122(10): 5211-5236 [DOI: 10.1002/2016JD026370]
- Yuan Q Q, Shen H F, Li T W, Li Z W, Li S W, Jiang Y, Xu H Z, Tan W W, Yang Q Q, Wang J W, Gao J H and Zhang L P. 2020a. Deep learning in environmental remote sensing: achievements and challenges. *Remote Sensing of Environment*, 241: 111716 [DOI: 10.1016/j.rse.2020.111716]
- Yuan Q Q, Xu H Z, Li T W, Shen H F and Zhang L P. 2020b. Estimating surface soil moisture from satellite observations using a generalized regression neural network trained on sparse ground-based measurements in the continental U.S. *Journal of Hydrology*, 580: 124351 [DOI: 10.1016/j.jhydrol.2019.124351]
- Yuan W P, Liu S G, Yu G R, Bonnefond J M, Chen J Q, Davis K, Desai A R, Goldstein A H, Gianelle D, Rossi F, Suyker A E and Verma S B. 2010. Global estimates of evapotranspiration and gross primary production based on MODIS and global meteorology data. *Remote Sensing of Environment*, 114(7): 1416-1431 [DOI: 10.1016/j.rse.2010.01.022]
- Zeng Z Z, Wang T, Zhou F, Ciais P, Mao J F, Shi X Y and Piao S L. 2014. A worldwide analysis of spatiotemporal changes in water balance-based evapotranspiration from 1982 to 2009. *Journal of Geophysical Research: Atmospheres*, 119(3): 1186-1202 [DOI: 10.1002/2013JD020941]
- Zhang K, Kimball J S, Nemani R R and Running S W. 2010. A continuous satellite-derived global record of land surface evapotranspiration from 1983 to 2006. *Water Resources Research*, 46(9): W09522 [DOI: 10.1029/2009WR008800]
- Zhang K, Kimball J S and Running S W. 2016. A review of remote sensing based actual evapotranspiration estimation. *Wiley Interdisciplinary Reviews: Water*, 3(6): 834-853 [DOI: 10.1002/wat2.1168]
- Zhang Y Q, Kong D D, Gan R, Chiew F H S, McVicar T R, Zhang Q and Yang Y T. 2019. Coupled estimation of 500 m and 8-day resolution global evapotranspiration and gross primary production in 2002-2017. *Remote Sensing of Environment*, 222: 165-182 [DOI: 10.1016/j.rse.2018.12.031]
- Zhao W, Duan S B, Li A N and Yin G F. 2019. A practical method for reducing terrain effect on land surface temperature using random forest regression. *Remote Sensing of Environment*, 221: 635-649 [DOI: 10.1016/j.rse.2018.12.008]
- Zheng C L, Hu G C, Chen Q T and Jia L. 2021. Impact of remote sensing soil moisture on the evapotranspiration estimation. *Journal of Remote Sensing*, 25(4): 990-999 (郑超磊, 胡光成, 陈琪婷, 贾立. 2021. 遥感土壤水分对蒸散发估算的影响. *遥感学报*, 25(4): 990-999) [DOI: 10.11834/jrs.20210038]
- Zheng H. 2016. *Research on the Spatial Variation in Actual Evapotranspiration of Terrestrial Ecosystems*. Beijing: University of Chinese Academy of Sciences (郑涵. 2016. 陆地生态系统实际蒸散量的空间格局及其形成机制研究. 北京: 中国科学院大学)
- Zhou T, Peng Z Q, Xin X Z and Li F G. 2016. Remote sensing research of evapotranspiration over heterogeneous surfaces: a review. *Journal of Remote Sensing*, 20(2): 257-277 (周倜, 彭志晴, 辛晓洲, 李福根. 2016. 非均匀地表蒸散遥感研究综述. *遥感学报*, 20(2): 257-277) [DOI: 10.11834/jrs.20165030]
- Zhu G F, Li X, Zhang K, Ding Z Y, Han T, Ma J Z, Huang C L, He J H and Ma T. 2016. Multi-model ensemble prediction of terrestrial evapotranspiration across north China using Bayesian model averaging. *Hydrological Processes*, 30(16): 2861-2879 [DOI: 10.1002/hyp.10832]

Progress of data-driven remotely sensed retrieval methods and products on land surface evapotranspiration

LIU Meng¹, TANG Ronglin^{2,3}, LI Zhaoliang¹, GAO Maofang¹, YAO Yunjun⁴

1. Key Laboratory of Agricultural Remote Sensing, Ministry of Agriculture and Rural Affairs, Institute of Agricultural Resources and Regional Planning, Chinese Academy of Agricultural Sciences, Beijing 100081, China;

2. State Key Laboratory of Resources and Environment Information System, Institute of Geographic Sciences and Natural Resources Research, Chinese Academy of Sciences, Beijing 100101, China;

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

4. State Key Laboratory of Remote Sensing Science, Faculty of Geographical Science, Beijing Normal University, Beijing 100875, China

Abstract: Evapotranspiration (ET) links the water cycle and energy exchange in hydrosphere, atmosphere, and biosphere. From a global perspective, ET accounts for approximately 60% of the total land precipitation, and the latent heat accompanying ET accounts for approximately 80% of the total surface net radiation energy. With the development of eddy covariance technology, global long-term and

continuous observed meteorological and flux data are publicly available online. In last decade, data-driven remotely sensed ET retrieval methods have achieved rapid development. In terms of data-driven remotely sensed retrieval ET, this paper reviews and summarizes the existing researches on empirical regression methods, machine learning methods, data fusion methods and their corresponding products, then points out the existing problems and deficiencies on the driven data, retrieval methods, and available products. To be specific, these problems include: (1) There are few data-driven remotely sensed ET products with high precision and high spatiotemporal resolution; (2) The spatial scale mismatch between satellite pixel and in situ measurements makes the data-driven remotely sensed ET estimates challenging; (3) The lack of physical mechanisms for the data-driven remotely sensed retrieval ET methods and the insufficient regional representativeness for observed data from hundreds of sites, the spatial application of the ET model is limited; (4) Several important driving factors of ET, such as land surface temperature and soil moisture, were not sufficiently considered in previous studies; (5) The energy balance at flux measurement sites that based on eddy covariance method is not closed with about 0.8 unclosed rate globally, whether carry out energy balance closure correction before modeling is still a controversy; (6) The partitioning between soil evaporation and vegetation transpiration is of great significance, but the data-driven remotely sensed models that could estimate soil evaporation and vegetation transpiration respectively were not well studied. In the era of big data, as a double-edged sword, data-driven approaches are not only opportunities but also challenges, and several suggestions for future studies are proposed at the end. To begin with, the data-driven remotely sensed retrieval ET methods with high spatiotemporal resolution should be proposed. The observed source area should be introduced into the model constructing to solve the mismatch between satellite pixel and the measurements so as to improve the estimated ET accuracy. In addition, some important information, such as land surface temperature and soil moisture, which has an important effect on ET process should be taken into consideration effectively. Although vegetation index could indicate the long-term change of ET, land surface temperature could better indicate its short-term change. At the same time, soil moisture deficit would produce water stress on ET. Effective consideration of land surface temperature and soil moisture may improve the estimation accuracy of ET. Last but not least, it's important to emphasize that data-driven empirical approaches will not replace process-driven physical models, but strongly supplement and enrich the ET estimation methods. The combination of process-driven physical models and data-driven empirical approaches should be strengthened in order to obtain more reliable and accurate ET estimation by remote sensing. One suggestion is that, in future studies, data-driven approaches should be used to estimate important variables that closely related to ET but unavailable directly from remote sensing satellite at present, then physical models could be used for ET estimation. So as to the two kinds of models can fully play their roles respectively, jointly promote the research level of remotely sensed retrieval ET.

Key words: land surface evapotranspiration, data-driven, land surface temperature, empirical method, machine learning, data fusion, remote sensing products

Supported by National Natural Science Foundation of China (No. 42001310, 41922009, 42071332); Fundamental Research Funds for Central Non-profit Scientific Institution (No.1610132020007)