DOI: 10.20103/j.stxb.202409132223

张泽凌,周莹,姜峻,王丽娜,邓旭,安志超,唐亚坤.基于生态知识-机器学习模型的黄土高原铁杆蒿草地生态系统碳水通量模拟及其影响机制研究.生态学报,2025,45(13): - .

Zhang Z L, Zhou Y, Jiang J, Wang L N, Deng X, An Z C, Tang Y K. Simulation and influencing mechanisms of carbon and water fluxes of *Artemisia sacrorum* grassland ecosystem in the Loess Plateau based on an ecological knowledge-machine learning model. Acta Ecologica Sinica, 2025, 45(13): - .

基于生态知识-机器学习模型的黄土高原铁杆蒿草地 生态系统碳水通量模拟及其影响机制研究

张泽凌^{1,2},周 莹³,姜 峻^{1,3},王丽娜⁴,邓 旭⁴,安志超⁵,唐亚坤^{1,3,*}

1 中国科学院教育部水土保持与生态环境研究中心,中国科学院水利部水土保持研究所,杨凌 712100

2 中国科学院大学,北京 100049

3 西北农林科技大学水土保持科学与工程学院,杨凌 712100

4 西北农林科技大学林学院,杨凌 712100

5 西北农林科技大学资源与环境学院,杨凌 712100

摘要:净生态系统 CO₂交换量(NEE)和蒸散(ET)是表征半干旱区生态系统碳水循环能力的重要指标。对碳水通量动态变化的准确模拟和驱动机制的深入分析,有助于明确黄土高原半干旱区草地生态系统的功能及其对气候变化的响应。基于黄土高原铁杆蒿草地生态系统 2018—2022 年日尺度通量观测数据,使用多元线性回归模型,机器学习模型(随机森林、支持向量机和人工神经网络模型)和融合生态学知识与机器学习的生态知识-机器学习(EML)模型分别对 NEE 和 ET 进行拟合。其中,有6种基于不同生态假设的 EML 模型用于拟合 NEE,7种基于不同生态假设的 EML 模型用于拟合 ET。最后构建拟合效果最好和解释能力最优的 EML 模型并探究环境和植被因素对 NEE 和 ET 的影响。结果表明:(1)包含了气象因素、土壤水分因素和植被因素的 NEE 和 ET 的影响。结果表明:(1)包含了气象因素、土壤水分因素和植被因素的 EML 模型对 NEE 和 ET 的拟合效果最好,R²和 RMSE 分别为 0.81和 0.70 g C m⁻² d⁻¹,0.83和 0.48 mm/d,MRE 和 MAE 分别为 1.72和 0.48 g C m⁻² d⁻¹,0.29和 0.30 mm/d。该模型在 NEE 和 ET 上的拟合能力较多元线性回归模型提升了 24.62%和 12.16%,较机器学习模型平均提升了 13.02%和 6.87%。(2)空气温度是 NEE 和 ET 的主要影响因素,重要性占比分别为 63.12%和 60.38%。6℃和 22℃是草地 NEE 日均空气温度的阈值,在 6—22℃之间 NEE 处于下降趋势,在 22℃后 NEE 变为平稳趋势。0℃和 22℃是草地 ET 日均空气温度的阈值,当空气温度大于 22℃后,ET 由上升趋势转变为平稳趋势。(3)土壤水分因素在 NEE 和 ET 的重要影响因素中的占比分别为 17.13%和 5.66%,NEE 对土壤水分的敏感性高于 ET。研究结果有助于完善半干旱区草地生态系统碳水通量的模拟方法,并明确其对环境和植被因素的响应。

关键词:碳水通量;半干旱区;黄土高原;草地生态系统;生态知识-机器学习模型;影响机制

Simulation and influencing mechanisms of carbon and water fluxes of *Artemisia sacrorum* grassland ecosystem in the Loess Plateau based on an ecological knowledge-machine learning model

ZHANG Zeling^{1, 2}, ZHOU Ying³, JIANG Jun^{1, 3}, WANG Lina⁴, DENG Xu⁴, AN Zhichao⁵, TANG Yakun^{1,3, *}

- 1 The Research Center of Soil and Water Conservation and Ecological Environment, Chinese Academy of Sciences and Ministry of Education; Institute of Soil and Water Conservation, Chinese Academy of Sciences and Ministry of Water Resources, Yangling 712100, China
- 2 University of Chinese Academy of Sciences, Beijing 100049, China

³ College of Soil and Water Conservation Science and Engineering, Northwest Agriculture and Forestry University, Yangling 712100, China

基金项目:陕西省自然科学基础研究计划(2023JC-XJ-24);国家自然科学基金项目(41977425)

收稿日期:2024-09-13; 网络出版日期:2025-00-00

^{*} 通讯作者 Corresponding author.E-mail: yktang@ nwsuaf.edu.cn

4 College of Forestry, Northwest Agriculture and Forestry University, Yangling 712100, China

5 College of Natural Resources and Environment, Northwest Agriculture and Forestry University, Yangling 712100, China

Abstract: Net ecosystem exchange (NEE) and evapotranspiration (ET) are important indicators for characterizing carbon and water cycling capacity in semi-arid areas ecosystems. This study presents an accurate modeling of the dynamics of carbon and water fluxes and an in-depth analysis of their driving mechanisms. It helps to clarify the functions of grassland ecosystems and their responses to climate change in the semi-arid regions of the Loess Plateau. Based on daily-scale flux observations of Artemisia sacrorum grassland ecosystem in the Loess Plateau from 2018 to 2022, we used a multiple linear regression model, machine learning models (Random Forest, Support Vector Machine and Artificial Neural Network model) and ecological knowledge-machine learning (EML) models to fit NEE and ET, respectively. Among EML models, six models based on different ecological assumptions were used to fit NEE, and seven models based on different ecological assumptions were used to fit ET. We then constructed the best-fitting and best-explained EML model and investigated the effects of environmental and vegetation factors on NEE and ET. The results showed that: (1) The EML model incorporating meteorological, soil moisture and vegetation factors had the best fit to NEE and ET. The R^2 and RMSE of the EML model were 0.81 and 0.70 g C m⁻² d⁻¹, 0.83 and 0.48 mm/d, and the MRE and MAE of the EML model were 1.72 and 0.48 g C $m^{-2} d^{-1}$, 0.29 and 0.30 mm/d, respectively. The fitting effect of this model on NEE and ET increased by 24.62% and 12.16% compared with the multiple linear regression model, and increased by 13.02% and 6.87% on average compared with machine learning models. (2) Air temperature was the primary influencing factor for NEE and ET, with importance values proportions being 63.12% and 60.38% respectively. 6°C and 22°C were the thresholds of the daily average air temperature of grassland NEE. NEE was in a downward trend between 6°C and 22°C, and became a stable trend after 22°C. 0° and 22° were the thresholds of daily average air temperature of grassland ET. When the air temperature was greater than 22°C, ET transitioned from an upward trend to a stable trend. (3) Soil moisture factors accounted for 17.13% and 5.66% of the importance values on NEE and ET respectively. NEE was more sensitive to soil moisture than ET. The results contribute to improving the simulation method of carbon and water fluxes, and clarifying their responses to environmental and vegetation factors in grassland ecosystems in semi-arid areas.

Key Words: carbon and water fluxes; semi-arid area; Loess Plateau; grassland ecosystem; ecological knowledge-machine learning model; influencing mechanisms

碳与水循环是地球生态系统中物质和能量循环的基本过程,也是连接地圈、生物圈与大气圈的纽带^[1]。 由于人类工业活动导致全球气候变化,改变了碳水循环格局并显著影响了半干旱区生态系统的功能^[2]。虽 然,半干旱区占全球陆地面积的15%,但该区域在近50年全球碳汇能力的提升中贡献了57%^[3]。因此,准确 模拟半干旱区碳水通量并明确其驱动机制,对于深入理解生态系统的功能及其受全球气候变化的影响具有重 要的科学意义。

净生态系统 CO₂交换量 (Net Ecosystem Exchange, NEE) 是表征植被固碳能力和评估生态系统碳源/汇的指标^[4]。蒸散 (Evapotranspiration, ET) 是植被蒸腾与土壤蒸发之和,也是地表能量平衡的主要组成部 分^[5]。涡度相关系统在通量的观测中已被广泛使用^[6],结合该系统,前人提出了许多碳水通量的模拟方法^[7],主要分为以下三类:陆面过程模型,遥感驱动模型和数据驱动模型。其中,前两种方法是较为常用的模拟手段,然而生态系统碳水通量与影响因素之间的非平稳性和高维非线性为上述两种方法的精确模拟带来了 极大挑战^[8]。因此,更加灵活与精确的数据驱动模型在近些年被广泛应用。数据驱动模型可分为两类:一类 是具有解释性的白盒模型,如多元线性回归、聚类分析和主成分分析等,这类模型能够对碳水通量与影响因素 之间的关系进行判别与归类,但对其进行拟合的效果通常较差或无法对其进行拟合^[9]。另一类是以机器学 习为主的黑盒模型,如随机森林、支持向量机与人工神经网络等,这类模型拟合结果较好,但解释能力不如白

3

盒模型^[10]。常用的机器学习解释方法为重要性分析,而以博弈论为基础的 SHAP (SHapley Additive exPlanations)方法由于对全局和局部的解释具有准确性和一致性的优点,正逐渐被生态学领域使用^[11]。然而,尽管上述方法能在一定程度上揭示碳水通量与影响因素之间的关系,但该关系是基于数据本身的统计分析,缺乏生态学知识的解释^[12]。为了克服这种问题,Han 等^[13]将生态学知识结合机器学习模型,构建了评估中国生态系统呼吸(Ecosystem Respiration, RE)的智慧随机森林模型,该模型相比半经验模型和机器学习模型具有更强的拟合能力和解释能力。Tang 等^[14]和 Gu 等^[15]对碳水通量模型的研究表明,同时考虑了环境因素和植被因素的模型能够更好地模拟水分匮缺状态时 NEE 和 ET 的变化特征。另外,NEE 对空气温度(Air Temperature, Ta)的响应是由生态系统 CO₂交换量(Gross Ecosystem Exchange, GEE)和 RE 的相对变化引起的,这种响应普遍为峰值曲线模式,存在改变 NEE 变化趋势的阈值温度^[16]。Ta 阈值点在不同生态系统中存在较大差异,在温带湿润落叶阔叶林中 NEE 的阈值为 20℃,而在亚寒带常绿针叶林中 NEE 的阈值为 14℃^[16]。然而,目前仍缺乏关于半干旱区草地生态系统 NEE 和 ET 的主要影响因素的阈值点分析。因此在半干旱区构建融入环境和植被因素的生态知识的机器学习模型,明确 NEE 和 ET 的主要影响因素并量化改变其变化趋势的阈值,有助于准确模拟碳水通量和解释其对环境和植被因素的响应。

黄土高原是世界上水土流失最为严重的区域之一^[17]。上世纪末黄土高原半干旱区开展的"退耕还林 (草)"工程显著提升了植被生态系统的功能^[17]。随着工程的实施,草地已占黄土高原总面积的 32%,在提高 黄土高原水土保持和固碳释氧能力上发挥着重要的作用^[17]。近年来许多学者对黄土高原草地生态系统进行 了研究,王茜^[18]的研究表明 Ta 对 NEE 有着最大的贡献;Tang 等^[19]的研究表明 NEE 对降雨量和土壤含水量 更为敏感;Yue 等^[2]的研究发现 ET 与归一化植被指数 (Normalized Difference Vegetation Index, NDVI) 有较好 的相关性。然而,仍然缺乏该地区草地生态系统碳水通量的准确模拟以及影响机制方面的研究。本研究以黄 土高原安塞水土保持综合实验站 2018—2022 年草地生态系统 NEE 和 ET 为研究对象,构建融合生态学知识 与机器学习的生态知识-机器学习模型,并明确黄土高原草地碳水通量的影响机制。

1 材料与方法

1.1 研究区概况

研究区位于黄土高原中部的中国科学院安塞水土保持综合实验站山地实验地(36°51′30″N,109°19′23″ E,海拔1260 m)。该地区受暖温带半干旱大陆性季风气候的影响,2018—2022 年年平均空气温度(±SD)为(10.32±0.82)℃,年平均降雨量为(504.96±45.32) mm。该地区植被类型是以温带典型草地生态系统为主的 典型温性草原,在1990 年"退耕还林(草)"工程实施初期,植被群落的建群种为茵陈蒿(Artemisia capillaries)^[20]。经过约30 年的演替后,该地区草地群落以铁杆蒿(Artemisia sacrorum)为优势种,以茵陈蒿为 主要伴生种,两种植物的根系分布深度为0—60 cm^[19]。该地区的主要土壤类型为黄绵土,容重为1.32 g/ cm³,孔隙度为57.77%^[19]。

1.2 数据来源与处理

本研究的碳水通量观测系统建于 2011 年,隶属于中国通量观测研究网络(ChinaFLUX)。涡度相关系统 由开路红外 CO₂/H₂O 气体分析仪 LI-7500 (Li-Cor Inc, USA)和三维超声风速仪 CSAT3 (Campbell Scientific Inc, USA)组成,上述设备的安装高度为 2 m,用于观测水汽、CO₂和风速的脉动量。在通量塔距地面 2 m 处 架设气象传感器,包括用于观测 Ta,相对湿度(Relative Humidity, RH)和饱和水汽压差(Vapor Pressure Deficit, VPD)的温湿度传感器 HMP45C (Campbell Scientific Inc, USA);用于观测风速(Wind Speed, WS) 的风向/风速传感器 A100R (Vector Inc, UK);用于观测光合有效辐射(Photosynthetically Active Radiation, PAR)和净辐射(Net Radiation, Rn)的光量子传感器 LI-190SB (Li-Cor Inc, USA)和 CNR-1 (Kipp&Zonen Inc, Netherlands)。并在地表 20 cm 处安装翻斗式雨量桶 TR-525USW (Texas Electronics Inc, USA),用于观测 降雨量(Precipitation, P)。5、20 和 50 cm 深度的土壤含水量(Soil Moisture, SM)与土壤温度(Soil

45 卷

Temperature, Ts) 通过对应深度的土壤水分传感器 CS616-L (Campbell Scientific Inc, USA) 和热电偶 105T (Campbell Scientific Inc, USA) 观测。上述 10 Hz 通量数据,1 Hz 气象数据和 30 min 平均数据由 CR3000 (Campbell Scientific Inc, USA) 记录并储存。

本研究使用 ChinaFLUX 的通量数据处理流程^[21]。通过平面拟合法调整坐标轴使平均垂直风速为零,消除不规则气流或仪器倾斜对通量的影响;通过 WPL 校正消除 CO₂/H₂O 密度受大气水热条件变化的影响;通过在 10 d 数据窗口下剔除超出均值±3 倍标准差的数据,排除异常值对白天和夜间数据的干扰;通过剔除摩擦风速低于临界值的夜间通量数据,获得质量可靠的数据^[21]。在通量观测过程中,数据剔除、设备故障和天气状况等因素会使观测值出现缺失。当通量数据有小于连续 2 h 的缺失时,采用线性插值法插补缺失值;当通量数据有连续时间较短 (<7 天)的缺失时,采用平均日变化法插补缺失值;当通量数据有连续时间较长(\geq 7 天)的缺失时,使用有效通量数据和环境因素构建回归方程对 NEE 进行插补,白天使用 PAR 的Michaelis-Menten 直角双曲线方程^[22]计算缺失值,夜间使用 5 cm 深度 Ts 的 Van't Hoff 方程^[23]计算缺失值。对白天和夜间 ET 的连续时间较长的缺失值使用查表法进行插补^[24]。通量数据 2018—2022 年年均能量平衡率 (Energy Balance Ratio, EBR)为0.74±0.03,在全球通量网络 (FLUXNET) 各站点能量平衡率的范围内 (0.70—0.91)^[25]。

本研究使用 Google Earth Engine (https://earthengine.google.com) 平台上中分辨率成像光谱仪 (Moderate-resolution Imaging Spectroradiometer, MODIS) 的 MOD09GA 产品获取 2018—2022 年铁杆蒿草地生 态系统的 NDVI 遥感数据,其空间分辨率为 500 m,时间分辨率为 1 d。NDVI 对叶绿素具有高度敏感性,是评 估生态系统植被覆盖度的有效指标,能够准确反映植物的生长状态^[26—27]。目前该产品的 NDVI 数据已被广 泛应用于草地生态系统碳水通量的影响机制分析^[28]。

1.3 数据分析方法

前人的研究表明^[4-5,29],影响 NEE 和 ET 的环境和植被因素包括:(1) 气象因素:Ta、Ts、VPD、RH、P、 PAR、Rn 和 WS;(2) 土壤水分因素:5 cm 土壤含水量(SM_5cm)、20 cm 土壤含水量(SM_20cm)和 50 cm 土 壤含水量(SM_50cm);(3) 植被因素:NDVI。本研究使用上述天尺度环境和植被因素,采用(1) 具有可解释 性的多元线性回归模型,(2) 具有拟合能力的机器学习模型,(3) 同时具有可解释性和拟合能力的融合生态 学知识与机器学习的生态知识-机器学习模型,对黄土高原草地生态系统碳水通量的动态变化进行模拟,并分 析其影响因素,揭示该地区草地生态系统碳水通量的驱动机制。

1.3.1 多元线性回归模型

多元线性回归(Multiple Linear Regression, MLR)是使用多个自变量构建线性函数来拟合因变量的模型,该模型具有明确的函数形式和良好的可解释性^[9]。本研究中,该模型使用上述观测的全部环境和植被因素(Ta、Ts、VPD、RH、P、SM_5cm、SM_20cm、SM_50cm、PAR、Rn、WS和NDVI)作为自变量,通过逐步法自行筛选合适的变量参与模型的拟合。

1.3.2 机器学习模型

机器学习是一项能够自动学习数据的特征,并进行良好的预测与拟合的数据科学技术^[10]。机器学习模型使用观测的全部环境和植被因素作为自变量,通过随机森林(Random Forest, RF)、支持向量机(Support Vector Machine, SVM)和人工神经网络(Artificial Neural Network, ANN)对NEE和ET进行拟合。首先,对通量的观测数据进行随机划分,70%的观测数据作为训练集,30%的观测数据作为测试集^[4]。接着,使用上述3种机器学习模型在训练集上进行训练,通过学习曲线确定最佳超参数,随后在测试集上评估拟合效果。在拟合过程中,各模型将自行筛选变量。

RF 是将集成学习与随机子空间相结合的一种模型,通过 Bagging 将单棵独立的决策树基模型集成为性能更强的模型^[7]。RF 的决策树数量设为 230,节点分裂的最小样本数设为 2,叶节点的最小样本数设为 1,其他超参数设为默认值。SVM 建立在统计学 VC 维理论和结构风险最小原理的基础上,通过核技巧使数据升

维,在高维空间中构造决策平面进行回归^[7]。SVM 的核函数设为径向基函数,惩罚系数设为 20,其他超参数 设为默认值。ANN 能充分学习变量的细节特征与分布形态,通过激活函数与节点建立起输入与输出之间的 非线性关系^[7]。ANN 的激活函数设为 ReLU 函数,隐藏层层数设为 2,分别有 256 和 16 个节点,学习率设为 0.001,最大迭代次数设为 10000,其他超参数设为默认值。

1.3.3 生态知识-机器学习模型

鉴于多元线性回归模型拟合能力不足,同时机器学习模型缺乏解释能力,因此本研究将生态学知识和机器学习融合,构建生态知识-机器学习模型(Ecological knowledge-machine learning, EML),该模型能够通过环境和植被因素拟合碳水通量,并对碳水通量与影响因素之间的响应关系具有更好的解释能力。基于前人研究中的生态学理论,影响 NEE 的途径分别为:Ta 控制着植被细胞的酶活性,对植被的光合作用、呼吸代谢和土壤异养呼吸有着重要影响,SM、P 和 PAR 是植被光合作用的底物与条件^[18—19]。同时,影响 ET 的途径分别为:Ta 对于植被的生理活动和土壤蒸发有着重要影响,VPD 和 SM 影响着植被水分的蒸腾与吸收,Rn 是太阳向陆面与植被输送能量的过程,WS 对大气水汽输送和水分蒸发速率有影响^[2,5]。NDVI 是生态系统植被覆盖度的指标,也是影响 NEE 和 ET 的重要植被因素^[27]。

根据上述 NEE 和 ET 的生态学知识,分别提出如下假设,NEE:(1) 受 Ta 的影响(EML_N1);(2) 受 Ta 和 P 的共同影响(EML_N2);(3) 受 Ta、SM_20cm 和 SM_50cm 的共同影响(EML_N3);(4) 受 Ta 和 PAR 的 共同影响(EML_N4);(5) 受 Ta 和 NDVI 的共同影响(EML_N5);(6) 受上述环境(Ta、P、SM_20cm、SM_50cm、PAR) 和植被因素(NDVI)的共同影响(EML_N6)。ET:(1) 受 Ta 的影响(EML_E1);(2) 受 Ta 和 VPD 的共同影响(EML_E2);(3) 受 Ta、SM_5cm 和 SM_20cm 的共同影响(EML_E3);(4) 受 Ta 和 Rn 的共同影响(EML_E4);(5) 受 Ta 和 WS 的共同影响(EML_E5);(6) 受 Ta 和 NDVI 的共同影响(EML_E6);(7) 受上述环境(Ta、VPD、SM_5cm、SM_20cm、Rn、WS)和植被因素(NDVI)的共同影响(EML_E7)。

将基于生态学知识的各组假设结合机器学习方法进行建模。每组假设中影响 NEE 或 ET 的因素将作为 自变量输入 1.3.2 中的最佳机器学习模型,以此将生态学知识融入机器学习并构建 EML 模型。每组假设的 EML 模型将在训练集上进行训练,在测试集上评估最终的拟合效果和模拟的准确度。例如,1.3.2 中的最佳模 型是 RF,并假设 NEE 只受 Ta 的影响。在这种情况下,将训练集中的 Ta 数据作为 RF 模型的变量用于拟合 NEE,构建得到 EML_N1 模型。然后使用未纳入建模的测试集 Ta 数据输入 EML_N1 模型,得到该模型的 NEE 拟合值,最后计算模型的评价指标,比较模型的优劣。

1.3.4 模型评价方法

本研究通过决定系数(Coefficient of determination, R^2)和均方根误差(Root Mean Square Error, RMSE) 评价不同模型对 NEE 或 ET 的拟合效果;通过平均相对误差(Mean Relative Error, MRE)和平均绝对误差 (Mean Absolute Error, MAE)评价不同模型拟合值相较于实际观测值的准确度。 R^2 为评价中的主要指标,其 值越接近1代表模型拟合效果越好。RMSE、MRE 和 MAE 从不同角度对误差进行评价,三种指标越接近0代 表模型的预测越准确。上述四种评价指标均使用 30%的测试集数据进行计算。最后使用极坐标图绘制各模 型的 R^2 、RMSE、MRE 和 MAE 指标,对模型进行综合对比评价。

1.3.5 影响因素分析方法

本研究使用皮尔逊相关系数探究影响因素与 NEE 或 ET 的相关程度,并利用 T 检验检测相关系数的显著性。同时选用 NEE 和 ET 的各组生态知识假设中拟合效果最好的模型,通过计算模型中各个因素及其交互项的 SHAP 值,衡量因素分别对 NEP 和 ET 变化量的贡献^[11]。以主要影响因素与 NEE 和 ET 的偏依赖图为基础,将两端斜率发生突变的点作为阈值点,分析 NEE 和 ET 随主要影响因素响应变化的机制。

本研究使用 MATLAB 2019 完成通量数据处理,使用 SPSS 27.0 完成数据统计检验,使用 Python 3.9 完成数据建模,并在 Python 环境中使用 shap 软件包完成影响因素分析。本研究使用 shap 软件包绘制影响因素 SHAP 值蜂群图,使用 Origin 2021 绘制模型拟合效果极坐标图、主要影响因素偏依赖图以及其余的图像。

2 结果与分析

2.1 环境和植被因素及碳水通量的变化特征

草地生态系统 2018—2022 年的日均 Ta 为(10.32±9.82)℃,日均 NDVI 为 0.23±0.16(图 1)。Ta 和 NDVI 均呈现出单峰型季节特征,但两者的峰值时间不同,Ta 的峰出现在 7 月下旬,NDVI 的峰较 Ta 滞后约 15 d。 日均 PAR 为(21.54±9.78) µmol m⁻² d⁻¹,变化范围为 1.31—45.52 µmol m⁻² d⁻¹,日均 Rn 为(12.77±5.80) W m⁻² d⁻¹,变化范围为 0.13—25.69 W m⁻² d⁻¹。日均 SM_50cm 最大 (0.15±0.01)%,日均 SM_5cm 最小 (0.09± 0.00)%。



图 1 草地生态系统 2018—2022 年主要环境和植被因素的季节变化



Ta:空气温度 Air Temperature; NDVI:归一化植被指数 Normalized Difference Vegetation Index; PAR: 光合有效辐射 Photosynthetically Active Radiation; Rn:净辐射 Net Radiation; SM:土壤含水量 Soil Moisture

草地生态系统的日均 NEE 为(-0.12±1.63) g C m⁻² d⁻¹,变化范围为-5.26—2.67 g C m⁻² d⁻¹;日均 ET 为 (1.32±1.14) mm/d,变化范围为 0.01—5.47 mm/d (图 2)。NEE 和 ET 均呈现出明显的单峰型季节特征,NEE 在夏季较低冬季较高,ET 呈相反的季节变化趋势。NEE 的最低峰出现在 6 月中旬—7 月中旬,ET 的最高峰 出现在 5 月初—6 月初。NEE 年累计值的最高值和最低值分别为-37.45 g C m⁻² d⁻¹(2020 年)和-54.60 g C m⁻² d⁻¹(2021 年),ET 年累计值的最高值和最低值分别为 549.33 mm/d (2021 年)和 435.82 mm/d (2019 年)。

2.2 多元线性回归模型的拟合结果

通过多元线性回归模型, NEE 拟合方程的 R^2 和 RMSE 分别为 0.65 和 0.97 g C m⁻² d⁻¹, ET 拟合方程的 R^2 和 RMSE 分别为 0.74 和 0.59 mm/d (表 1)。多元线性回归模型对 ET 的拟合能力高于 NEE。



图 2 草地生态系统 2018—2022 年 NEE 和 ET 的季节变化

Fig.2 Seasonal dynamics of NEE and ET in grassland ecosystem from 2018 to 2022

NEE:净生态系统 CO2交换量 Net Ecosystem Exchange; ET:蒸散 Evapotranspiration

表1 多元线性回归模型的拟合结果

fable 1	Simulated	results o	f multiple	linear	regression	model
---------	-----------	-----------	------------	--------	------------	-------

拟合目标 Simulated trget	回归方程 Regression equation	决定系数 R ²	均方根误差 RMSE
净生态系统 CO ₂ 交换量 NEE	NEE = -0.10Ts+0.76VPD-0.02RH-0.02P+4.21SM_5cm+ 4.46SM_20cm-0.06PAR-0.04Rn+2.11	0.65	$0.97 \mathrm{g} \ \mathrm{C} \ \mathrm{m}^{-2} \ \mathrm{d}^{-1}$
蒸散 ET	ET = 0.02Ta + 0.42VPD + 0.02RH + 0.02P + 2.63SM_5cm - 7.29SM_20cm + 3.45SM_50cm + 0.03PAR + 0.04Rn + 0.25WS+1.14NDVI-1.73	0.74	0.59mm/d

NEE:净生态系统 CO₂交换量 Net ecosystem exchange;ET:蒸散 Evapotranspiration;R²:决定系数 Coefficient of determination;RMSE:均方根误差 Root Mean Square Error;Ta:空气温度 Air Temperature;Ts:土壤温度 Soil Temperature;VPD:饱和水汽压差 Vapor Pressure Deficit;RH:相对湿度 Relative Humidity;P:降雨量 Precipitation;SM:土壤含水量 Soil Moisture;PAR:光合有效辐射 Photosynthetically active radiation;Rn:净辐射 Net Radiation;WS:风速 Wind Speed;NDVI:归一化植被指数 Normalized difference vegetation index

根据标准化回归系数(表 2),影响 NEE 的重要因素(前 4 个影响程度最高的因素)分别为 Ts(-0.60), PAR(-0.37),VPD(0.26)和 RH(-0.26),影响 ET 的重要因素分别为 RH(0.37),PAR(0.23),VPD(0.21) 和 SM_20cm(-0.21)。在回归方程的环境和植被因素中,VPD,SM_5cm 和 SM_20cm 与 NEE 呈正相关,其余 环境和植被因素与 NEE 呈负相关,而 SM_20cm 与 ET 呈负相关,其余环境和植被因素与 ET 呈正相关。

表 2 多元线性回归模型的标准化回归系数

Table 2 Standardized regression coefficients of multiple linear regression model					
	标准化回归系数 Standardized regression coefficient			标准化回归系数	
影响田孝			影响用素	Standardized regression coefficient	
彩門凶系 Influencing factor	净生态系统 CO ₂ 交换量 NEE	蒸散 ET	影响凶系 Influencing factor	净生态系统 CO ₂ 交换量 NEE	蒸散 ET
空气温度 Ta	—	0.15	20cm 土壤含水量 SM_20cm	0.09	-0.21
土壤温度 Ts	-0.60	_	50cm 土壤含水量 SM_50cm	—	0.11
饱和水汽压差 VPD	0.26	0.21	光合有效辐射 PAR	-0.37	0.23
相对湿度 RH	-0.26	0.37	净辐射 Rn	-0.15	0.19
降雨量 P	-0.05	0.06	风速 WS	—	0.12
5cm 土壤含水量 SM_5cm	0.11	0.10	归一化植被指数 NDVI	—	0.16

"一"表示该环境或植被因素被逐步法排除,不参与到回归方程中

http://www.ecologica.cn

7

2.3 机器学习模型的拟合结果

在 3 种机器学习模型 RF、SVM 和 ANN 中, RF 模拟 NEE 和 ET 时均表现出最好的拟合效果 (R^2 = 0.81, RMSE = 0.70 g C m⁻² d⁻¹和 R^2 = 0.83, RMSE = 0.48 mm/d) (表 3)。SVM 对 NEE 和 ET 的拟合效果次之, 且高 于 ANN。RF 对 NEE 和 ET 的拟合效果相对于 SVM, R^2 提高了 19.12% 和 7.79%, RMSE 降低了 22.22% 和 14.29%; 相对于 ANN, R^2 提高了 22.73% 和 13.70%, RMSE 降低了 23.91% 和 21.31%。表明 RF 能很好地模拟 NEE 和 ET 的季节变化。

Table 3 Simulated results of machine learning model			
	机器学习模型	决定系数	均方根误差
Simulated target	Machine learning model	R ²	RMSE
净生态系统 CO2交换量 NEE	RF	0.81	$0.70 \text{ g C m}^{-2} \text{ d}^{-1}$
	SVM	0.68	$0.90 \text{ g C m}^{-2} \text{ d}^{-1}$
	ANN	0.66	$0.92 \text{ g C m}^{-2} \text{ d}^{-1}$
蒸散 ET	RF	0.83	0.48 mm/d
	SVM	0.77	0.56 mm/d
	ANN	0.73	0.61 mm/d

表 3 机器学习模型的拟合结果

RF:随机森林 Random Forest;SVM:支持向量机 Support Vector Machine;ANN:人工神经网络 Artificial Neural Network

2.4 生态知识-机器学习模型的拟合结果

根据 2.3 的拟合结果, RF 是模拟 NEE 和 ET 季节变化的最佳模型。因此, 基于 RF 模型, 使用 6 种 NEE 的生态学假设和 7 种 ET 的生态学假设, 建立融合生态学知识和机器学习的 EML 模型。

假设 NEE 主要受 Ta 的影响,其模型 EML_N1 的 R²和 RMSE 分别为 0.46 和 1.17 g C m⁻² d⁻¹(表 4)。在 EML_N1 模型的基础上,其余环境和植被因素的加入均能使模型的拟合效果有不同程度的提升,各因素加入 后 R²的提升程度代表着对 NEE 的影响程度。SM_20cm 和 SM_50cm 的加入对模型的解释能力提升最大 (31%);P 的加入对模型的解释能力提升最小 (12%)。PAR 和 NDVI 对模型的提升程度位于上述因素之间,

	Table 4 Simulated results of EML mod	del	
拟合目标 Simulated target	生态知识-机器学习模型 Ecological knowledge-machine learning model	决定系数 <i>R</i> ²	均方根误差 RMSE
净生态系统 CO2交换量 NEE	EML_N1	0.46	1.17 g C m ⁻² d ⁻¹
	EML_N2	0.58	$1.04 \text{ g C m}^{-2} \text{ d}^{-1}$
	EML_N3	0.77	$0.77 \text{ g C m}^{-2} \text{ d}^{-1}$
	EML_N4	0.63	$0.97 \ \mathrm{g} \ \mathrm{C} \ \mathrm{m}^{-2} \ \mathrm{d}^{-1}$
	EML_N5	0.61	$0.99 \ \mathrm{g} \ \mathrm{C} \ \mathrm{m}^{-2} \ \mathrm{d}^{-1}$
	EML_N6	0.81	$0.70 \ \mathrm{g} \ \mathrm{C} \ \mathrm{m}^{-2} \ \mathrm{d}^{-1}$
蒸散 ET	EML_E1	0.48	0.84 mm/d
	EML_E2	0.63	0.71 mm/d
	EML_E3	0.69	0.65 mm/d
	EML_E4	0.71	0.63 mm/d
	EML_E5	0.66	0.68 mm/d
	EML_E6	0.66	0.68 mm/d
	EML_E7	0.83	0.48 mm/d

表 4	生态知识-机器学习模型的拟合结果

EML:生态知识-机器学习 Ecological knowledge-machine learning;EML_N1:通过 Ta 拟合 NEE;EML_N2:通过 Ta 和 P 拟合 NEE;EML_N3:通过 Ta 、SM_20cm 和 SM_50cm 拟合 NEE;EML_N4:通过 Ta 和 PAR 拟合 NEE;EML_N5:通过 Ta 和 NDVI 拟合 NEE;EML_N6:通过 Ta、P、SM_20cm、SM _50cm、PAR 和 NDVI 拟合 NEE;EML_E1:通过 Ta 拟合 ET;EML_E2:通过 Ta 和 VPD 拟合 ET;EML_E3:通过 Ta、SM_5cm 和 SM_20cm 拟合 ET; EML_E4:通过 Ta 和 Rn 拟合 ET;EML_E5:通过 Ta 和 WS 拟合 ET;EML_E6:通过 Ta 和 NDVI 拟合 ET;EML_E7:通过 Ta、VPD、SM_5cm、SM_ 20cm、Rn、WS 和 NDVI 拟合 ET 加入后的模型 *R*²分别为 0.63 和 0.61。包含了温度(Ta)、水分(P)、土壤水分(SM_20cm 和 SM_50cm)、辐射(PAR)与植被(NDVI)因素的 EML_N6 模型具有最高的拟合能力(*R*²=0.81, RMSE=0.70 g C m⁻² d⁻¹)。

假设 Ta 是控制 ET 的主要因素,其 EML_E1 模型的 R²和 RMSE 分别为 0.48 和 0.84 mm/d (表 4)。Rn 对 ET 的影响程度最大,模型加入 Rn 后对 ET 的解释能力提升了 23%; VPD 对 ET 的影响程度最小,模型加入 VPD 后对 ET 的解释能力提升了 15%。使用了温度(Ta)、水分(VPD)、土壤水分(SM_5cm 和 SM_20cm)、辐射(Rn)、气象(WS)和植被(NDVI)因素的 EML_E7 模型具有最高的拟合能力(R² = 0.83, RMSE = 0.48 mm/d)。

2.5 碳水通量模型的评价

通过极坐标图,对多元线性回归、机器学习和 EML 模型在测试集上的评价指标进行了定量对比,其中包含拟合能力指标(*R*², RMSE)和拟合准确度指标(MRE, MAE)(图 3)。在模型拟合能力上, EML_N6和 RF 模型对 NEE 拟合能力最强,二者模型的*R*²和 RMSE 均为 0.81和 0.70 g C m⁻² d⁻¹, EML_E7和 RF 模型对 ET 拟合能力最强,二者模型的*R*²和 RMSE 均为 0.83和 0.48 mm/d。而 EML_N3和 SVM 模型对 NEE 和 ET 的拟合能力均次之,两个模型的*R*²相较于最佳模型的*R*²分别下降了 4.94%和 7.23%。EML_N1和 EML_E1 模型对 NEE 和 ET 的拟合能力最次,模型 *R*²均低于 0.50。







R²:决定系数 Coefficient of determination;RMSE:均方根误差 Root Mean Square Error;MRE:平均相对误差 Mean Relative Error;MAE:平均绝对 误差 Mean Absolute Error;MLR:多元线性回归 Multiple Linear Regression;RF:随机森林 Random Forest;SVM:支持向量机 Support Vector Machine;ANN:人工神经网络 Artificial Neural Network;EML:生态知识-机器学习 Ecological knowledge-machine learning;EML_N1:通过Ta 拟合 NEE;EML_N2:通过Ta 和 P 拟合 NEE;EML_N3:通过Ta、SM_20cm 和 SM_50cm 拟合 NEE;EML_N4:通过Ta 和 PAR 拟合 NEE;EML_N5:通 过Ta 和 NDVI 拟合 NEE;EML_N6:通过Ta、P、SM_20cm、SM_50cm、PAR 和 NDVI 拟合 NEE;EML_E1:通过Ta 和 WS 拟合 ET;EML_E2:通过Ta 和 VPD 拟合 ET;EML_E3:通过Ta、SM_5cm 和 SM_20cm 拟合 ET;EML_E4:通过Ta 和 Rn 拟合 ET;EML_E5:通过Ta 和 WS 拟合 ET;EML_E6: 通过Ta 和 NDVI 拟合 ET;EML_E7:通过Ta、VPD、SM_5cm、SM_20cm、Rn、WS 和 NDVI 拟合 ET

9

在模型拟合准确度上, EML_N6 模型对 NEE 的拟合最准确(MRE=1.72, MAE=0.48 g C m⁻² d⁻¹), 同时, EML_E7 和 RF 模型均对 ET 拟合的准确度最高(MRE=0.29, MAE=0.30 mm/d)。RF 和 SVM 模型在 NEE 和 ET 上的拟合准确度次之, 其 MRE 相较于最佳模型分别增加了 0.05 和 0.08。EML_N1 和 EML_E1 模型的拟合 准确度最低, 其 MRE 分别为 3.46 和 0.62。

因此,在同时考虑拟合能力和拟合准确度后,NEE的最佳拟合模型为EML_N6模型(R²=0.81,RMSE=0.70gCm⁻²d⁻¹,MRE=1.72,MAE=0.48gCm⁻²d⁻¹),ET的最佳拟合模型为EML_E7和RF模型(R²=0.83,RMSE=0.48 mm/d,MRE=0.29,MAE=0.30 mm/d)。在拟合能力和拟合准确度上,EML_N6模型相较于多元线性回归模型提升了24.62%和19.95%,相较于机器学习模型平均提升了13.02%和39.92%;EML_E7和RF模型相较于多元线性回归模型提升了12.16%和58.33%,相较于机器学习模型平均提升了6.87%和19.91%。 2.6 基于生态知识-机器学习模型的影响因素分析

图 4 左侧为通过显著性检验的影响因素重要性排序图(P<0.001),因素的重要性从上往下依次降低。 NEE 的重要影响因素为 Ta、SM_50cm、PAR 和 SM_20cm,其重要性占比分别为 63.12%、9.63%、8.99% 和 7.50%。ET 的重要影响因素为 Ta、Rn、NDVI 和 SM_5cm,其重要性占比分别为 60.38%、15.73%、6.15% 和 5.66%。图 4 右侧为影响因素 SHAP 值蜂群图,NEE 的 SHAP 值随 Ta、PAR、NDVI 和 P 的增加而降低,表明上 述因素对 NEE 存在抑制作用。同理,Ta、Rn、NDVI、SM_5cm 和 WS 对 ET 有促进作用,而 SM_20cm 和 VPD 对 ET 有抑制作用。





Fig.4 Factor importance value and SHAP value of NEE and ET in EML model

P:降雨量 Precipitation; WS:风速 Wind Speed; VPD:饱和水汽压差 Vapor Pressure Deficit; *** 表示因素与 NEE 或 ET 相关程度的显著性 P <0.001, 虚线表示 SHAP 值为 0, 圆点代表每个因素单个样本对 NEE 或 ET 的贡献

通过 NEE 和 ET 对主要影响因素 Ta 响应变化的阈值分析可知(图 5),整体上,Ta 的升高使 NEE 和 ET 分别呈下降和上升趋势。其中,当 Ta 在 0—6℃范围内,Ta 的升高使 NEE 呈现微弱的上升趋势。当 Ta 超过 6℃后,NEE 随 Ta 的升高而降低,直至 Ta 达到 22℃的阈值,此时 NEE 最低(-2.15 g C m⁻² d⁻¹)。而随 Ta 的 持续上升,NEE 逐渐趋于稳定。

0℃是 ET 随 Ta 响应变化的阈值点,低于 0℃时 ET 稳定在(0.45±0.01) mm/d,几乎不受 Ta 变化的影响。

11

当 Ta 大于 0℃后,ET 开始随 Ta 的升高而增加。而当 Ta 升高到 22℃时,ET 达到最大值 (2.39 mm/d)。在 Ta 大于 22℃后,Ta 的升高导致 ET 呈下降趋势,并逐渐稳定在(2.34±0.02) mm/d。



图 5 生态知识-机器学习模型中空气温度对 NEE 和 ET 的偏依赖图

Fig.5 Partial dependence plot of air temperature on NEE and ET in EML model

图下方的灰色区域表示空气温度的概率密度,黑色实线上下的灰色区域表示空气温度对 NEE 和 ET 偏依赖曲线的 90% 置信区间,虚线为 NEE 和 ET 随空气温度变化曲线的阈值点

3 讨论

3.1 生态知识-机器学习模型具有高拟合与解释能力

多元线性回归模型的解释能力强于机器学习和 EML 模型,但拟合能力较差。多元线性回归模型可以表明环境和植被因素对 NEE 或 ET 的影响程度、促进或抑制作用,还可以通过拟合方程的自变量系数明确环境或植被因素的变化对 NEE 或 ET 的影响。但多元线性回归模型对环境和植被因素的解释依赖数据统计的结果,缺乏生态学知识的解释^[12],如 Ta 和 NDVI 没有被考虑到 NEE 回归方程中,PAR 相比 Rn 对 ET 的影响力更强(表 2),其结果和生态学基本理论相违背^[30]。机器学习模型的拟合能力强于多元线性回归和 EML 模型,不需要预先设定公式就能获得较好的拟合结果。但机器学习模型内部因素的关系被视为黑箱,且模型中易混入对 NEE 和 ET 影响较低的冗余因素,导致该模型难以明确分析环境和植被因素对 NEE 和 ET 的关系^[7]。

因此,同时具有高拟合与解释能力的 EML 模型较多元线性回归和机器学习模型更优。一方面,EML 模型的影响因素是根据生态学理论得到的,虽然 EML_E7 模型的拟合能力与 RF 模型相同,但该模型的因素数量为 7 个,约为 RF 模型的一半 (12 个),剔除了意义较小的冗余因素;另一方面,通过对不同生态学假设的检验,EML 模型中的环境和植被因素具有明确的生态意义。Han 等^[13]使用了类似的方法将生态系统 RE 的机理知识结合机器学习模型,通过变量的对比与筛选构建了有效的融合模型,分析了中国陆地生态系统 RE 的空间格局及其影响因素。正如 Reichstein 等^[8]所指出的,将生态学知识与机器学习相结合可以改进模型性能,压缩冗余的因素范围,在生态规律上具有更好的解释性,更能够适应数据变化。总的来说,EML 模型对半干旱区铁杆蒿草地生态系统碳水通量与环境和植被因素的拟合具有更高的精确性和解释能力。

3.2 空气温度是 NEE 和 ET 的主要影响因素

草地生态系统 NEE 与 Ta 存在显著负相关关系 (*P*<0.001),这与王茜^[18] 对半干旱区的研究结果一致。 Ta 的升高会增加光合作用的酶活性、植被的气孔导度和细胞间的 CO₂浓度,进而增强植被的光合作用,提高 草地生态系统的固碳能力同时降低 NEE^[31]。另外,GEE 和 RE 对 Ta 的响应存在差异性,在呼吸底物维持恒 定或较小变化时,Ta 与 RE 呈线性促进作用,而与 GEE 呈二次函数抑制作用^[32]。本研究中铁杆蒿草地生态 系统作为"退耕还林 (草)"工程的一部分,无人类活动的干扰,呼吸底物较为恒定,导致 GEE 的下降幅度大于 RE 的上升幅度,进而使 NEE 随 Ta 的升高而降低。 在季节时间尺度上,NEE 呈现出在夏季低冬季高的特征(图2)。这是因为夏季是黄土高原草地植被生 长的旺盛时期,较高的 Ta,相对充足的降水和适宜的日照时长与强度能够增强植物的光合能力,且光合作用 强度超越了同期的呼吸作用,导致草地生态系统表现为碳汇^[33],此时 NEE 的负值达到峰值。而进入冬季后, 光合作用和呼吸作用几乎停止,土壤呼吸作用增强成为 CO₂升高的主要原因,同时 NEE 的值在 0 以上并呈现 出近似直线的稳定状态,表示草地生态系统转变为微弱的碳源^[33]。

本研究中 NEE 由上升转变为下降趋势的温度阈值为 6℃,相较于 Xie 等^[34]研究的黄土高原生长季的温度阈值高 1℃,这可能是由于 GEE 对 Ta 存在滞后效应。大于 6℃后草地生态系统光合作用吸收 CO₂的能力大 于呼吸作用释放 CO₂的能力,使得 NEE 由上升趋势转变为下降趋势。随着 Ta 的升高,其对植被生长的时间 累积效应逐渐增加^[35]。22℃是草地 NEE 从下降趋势转为上升趋势的阈值点,这归因于黄土高原草地 RE 对 Ta 敏感,而 GEE 主要对土壤含水量敏感^[36]。这使得在高温条件下 RE 升高的程度相较于 GEE 降低的程度更 大,表现为 NEE 逐渐升高^[36]。Li 等^[37]的研究同样证明了这一点,GEE 的主要影响因素是植被,RE 的变化则 主要受土壤碳库的有效性和微生物活性的共同影响。因此在高温条件下,RE 的增加使 NEE 呈现出上升的 趋势。

Ta 对草地的生理活性与土壤蒸发有直接影响,且与 ET 呈显著正相关关系(P<0.001)。本研究中 ET 对于 Ta 的变化更敏感,这与 Liaqat 等^[5]的研究结果相同。Ta 能够通过影响大气中的水分调控植被的生理活动,且较高的 Ta 会升高空气的 VPD,进而增加植被的气孔导度并增加 ET^[38]。此外,Ta 的升高还能促进土壤蒸发。然而,在高温条件下,植被将采取适应性策略,关闭气孔减少水分的流失,削弱了植被的蒸腾量并导致 ET 降低^[38]。

ET 具有明显的季节性分布特征,夏季高冬季低(图2)。夏季期间植被生长旺盛,较高的 Ta 通过增加植 被蒸腾和土壤水分蒸发进而增强 ET,使其在夏季达到峰值^[38]。冬季草地植被进入休眠期,较弱的生理活动 和较低的叶面积使蒸腾作用几乎停止。同时,低温条件可能导致土壤产生冻结的现象,从而抑制了土壤的蒸 发作用,使 ET 在冬季维持在一个相对较低的稳定水平。

当 Ta 大于 0℃后,土壤中冻结的水分融化,较高的土壤含水量和较低的地表反照率同时加速了土壤的蒸发,导致 ET 开始增加^[39]。随着 Ta 持续升高,适宜的环境温度促进了植被的生长,草地植被的叶面积和蒸腾量也随之增加。然而,Ta 大于 22℃后 ET 的上升趋势转为下降趋势,这可能主要是由于高温下植被蒸腾作用下降的量大于土壤的蒸发量导致的。Kimura 等^[40]对黄土高原草地的研究表明,生长季草地的蒸腾量占主导地位,约为土壤蒸发的 1.5 倍。Li 等^[41]在全球范围内对草地生态系统开展的研究也印证了这一发现,其研究指出草地植被的蒸腾作用在 ET 中占 56%。因此在 Ta 较高时,主导 ET 变化的植被蒸腾量呈现更剧烈的下降趋势,导致 ET 表现出逐渐降低的变化规律。

3.3 NEE 对土壤水分的敏感性高于 ET

土壤水分是本研究中铁杆蒿草地生态系统 NEE 和 ET 的重要限制因素。整体上 SM 的增加会使 NEE 降低,但过高的 SM 也会使草地出现水分胁迫现象,导致其根系功能发生障碍并抑制微生物活性,进而降低植被 光合作用导致 NEE 升高^[42]。浅层 SM 的增加通过提高土壤表层蒸发界面的活跃程度加速土壤蒸发速率,而 深层 SM 的增加有利于植被根系吸收水分,促进蒸腾作用进而提高 ET^[5]。

土壤水分在 NEE 和 ET 的重要因素中的占比分别为 17.13% 和 5.66%,相较于 ET, NEE 对土壤水分的响应更敏感。Zhang 等^[6]在半干旱草地进行的实验发现了同样的结论, SM 的增加大幅降低了 NEE,但对 ET 的影响较小。NEE 对 SM 的敏感性来源于 GEE 和 RE 对 SM 的差异性响应。He 等^[43]的研究表明, SM 的不足会抑制植被细胞的分裂和生长,升高草地的 GEE,一定范围内 SM 增加则会通过促进植被根系的生长和土壤微生物的活动降低 GEE。ET 对 SM 的敏感性弱,一方面可能来源于土壤水分滞后效应。Mu 等^[44]的研究发现,在半干旱地区上一个雨季留存的深层土壤水分对当前旱季的 ET 仍有影响。而在该区域 NEE 对 SM 的滞后效应不足 2 个月^[45],且随着 SM 的增加滞后程度逐渐减弱^[46]。另一方面可能因为 SM 对草地植被生长的促

进作用增加了生态系统植被覆盖度和蒸腾量,同时减少了土壤裸地的面积和土壤蒸发量^[6],导致 ET 对 SM 的 敏感性更弱。因此,深层土壤水分的季节滞后和植被蒸腾与土壤蒸发的相互制约,共同削弱了 ET 对 SM 的敏 感性。

4 结论

本研究分析了黄土高原半干旱区草地生态系统 2018—2022 年碳水通量的变化特征,构建了既有优良拟 合能力又有准确解释能力的 EML 模型,并使用该模型结合 SHAP 方法明确了环境和植被因素对 NEE 和 ET 的影响机制。主要结论如下:

(1)融合了生态学知识和机器学习的 EML 模型可适用于半干旱区铁杆蒿草地生态系统 NEE 和 ET 的模拟, NEE 和 ET 的准确模拟需要同时考虑环境和植被因素。

(2) Ta 是半干旱区铁杆蒿草地生态系统 NEE 和 ET 的主要影响因素,对 NEE 的影响存在显著负效应,对 ET 的影响存在显著正效应。6℃和 22℃是草地 NEE 随 Ta 升高而下降的区间,超过 22℃后草地 NEE 轻微上 升并逐渐稳定。22℃也是草地 ET 增长最高的阈值点,当 Ta 继续升高后 ET 将呈现下降趋势并趋于稳定。

(3)半干旱区铁杆蒿草地生态系统的 NEE 对 SM 的敏感性高于 ET。

本研究对 SM 的非线性特征如何影响 NEE 和 ET 的分析仍有不足,需要未来继续深入讨论。研究结果有助于理解半干旱区草地生态系统环境和植被因素对碳水通量的影响机制,也能够为生态系统的结构功能和应 对全球气候变化的策略提供科学依据。

参考文献(References):

- [1] 于贵瑞, 王秋凤, 于振良. 陆地生态系统水-碳耦合循环与过程管理研究. 地球科学进展, 2004, 5: 831-839.
- [2] Yue P, Zhang Q, Zhang L, Li H Y, Yang Y, Zeng J, Wang S. Long-term variations in energy partitioning and evapotranspiration in a semiarid grassland in the Loess Plateau of China. Agricultural and Forest Meteorology, 2019, 278: 107671.
- [3] Ahlström A, Raupach M R, Schurgers G, Smith B, Arneth A, Jung M, Reichstein M, Canadell J G, Friedlingstein P, Jain A K, Kato E, Poulter B, Sitch S, Stocker B D, Viovy N, Wang Y P, Wiltshire A, Zaehle S, Zeng N. The dominant role of semi-arid ecosystems in the trend and variability of the land CO₂ sink. Science, 2015, 348(6237): 895-899.
- [4] 袁静芳,周海丽,张星烁,刘晓曼.京津风沙源治理区植被固碳能力估算及归因分析.生态学报, 2024, 44(15): 6731-6743.
- [5] Liaqat U W, Choi M, Awan U K. Spatio-temporal distribution of actual evapotranspiration in the Indus Basin Irrigation System. Hydrological Processes, 2015, 29(11): 2613-2627.
- [6] Zhang J Y, Yang Z L, Qiao D Y, Su L. Increasing precipitation during first half of growing season enhances ecosystem water use efficiency in a semiarid grassland. Frontiers in Plant Science, 2023, 14: 1119101.
- [7] 李慧杰, 王兵, 牛香, 梁咏亮, 李静尧. 机器学习技术在生态学中的应用进展. 生态学杂志, 2023, 42(11): 2767-2775.
- [8] Reichstein M, Camps-Valls G, Stevens B, Jung M, Denzler J, Carvalhais N, Prabhat. Deep learning and process understanding for data-driven Earth system science. Nature, 2019, 566(7743): 195-204.
- [9] Li Y B, Gao Z Q, Li D, Chen F, Yang Y J, Sun L. An update of non-iterative solutions for surface fluxes under unstable conditions. Boundary-Layer Meteorology, 2015, 156(3): 501-511.
- [10] Ruiz-Álvarez M, Gomariz-Castillo F, Alonso-Sarría F, López-Ballesteros A. Estimation of actual evapotranspiration using TDTM model and MODIS derived variables. Geocarto International, 2022, 37(25): 9242-9260.
- [11] Wang H, Yan S J, Ciais P, Wigneron J P, Liu L B, Li Y, Fu Z, Ma H L, Liang Z, Wei F L, Wang Y Y, Li S C. Exploring complex water stress-gross primary production relationships: Impact of climatic drivers, main effects, and interactive effects. Global Change Biology, 2022, 28 (13): 4110-4123.
- [12] Karpatne A, Atluri G, Faghmous J H, Steinbach M, Banerjee A, Ganguly A, Shekhar S, Samatova N, Kumar V. Theory-guided data science: a new paradigm for scientific discovery from data. IEEE Transactions on Knowledge and Data Engineering, 2017, 29(10): 2318-2331.
- [13] Han L, Yu G R, Chen Z, Zhu X J, Zhang W K, Wang T J, Xu L, Chen S P, Liu S M, Wang H M, Yan, J H, Tan J L, Zhang F W, Zhao F H, Li Y N, Zhang Y P, Sha L Q, Song Q H, Shi P L, Zhu J J, Wu J B, Zhao Z H, Hao Y B, Ji X B, Zhao L, Zhang Y C, Jiang S C, Gu F X, Wu Z X, Zhang Y J, Li Z, Tang Y K, Jia B R, Dong G, Gao Y H, Jiang Z D, Sun D, Wang J L, He Q H, Li X H, Wang F, Wei W X, Deng Z M,

Hao X X, Liu X L, Zhang X F, Mo X G, He Y T, Liu X W, Du H, Zhu Z L. Spatiotemporal Pattern of Ecosystem Respiration in China Estimated by Integration of Machine Learning With Ecological Understanding. Global Biogeochemical Cycles, 2023, 36(11): e2022GB007439.

- [14] Tang Y K, Wen X F, Sun X M, Chen Y M, Wang H M. Contribution of environmental variability and ecosystem functional changes to interannual variability of carbon and water fluxes in a subtropical coniferous plantation. IForest-Biogeosciences and Forestry, 2016, 9(3): 452-460.
- [15] Gu L H, Pallardy S G, Yang B, Hosman K P, Mao J F, Ricciuto D, Shi X Y, Sun Y. Testing a land model in ecosystem functional space via a comparison of observed and modeled ecosystem flux responses to precipitation regimes and associated stresses in a Central U.S. forest. Journal of Geophysical Research: Biogeosciences, 2016, 121(7): 1884-1902.
- [16] Niu S L, Luo Y Q, Fei S F, Yuan W P, Schimel D, Law B E, Ammann C, Altaf Arain M, Arneth A, Aubinet M, Barr A, Beringer J, Bernhofer C, Andrew Black T, Buchmann N, Cescatti A, Chen J Q, Davis K J, Dellwik E, Desai A R, Etzold S, Francois L, Gianelle D, Gielen B, Goldstein A, Groenendijk M, Gu L H, Hanan N, Helfter C, Hirano T, Hollinger D Y, Jones M B, Kiely G, Kolb T E, Kutsch W L, Lafleur P, Lawrence D M, Li L H, Lindroth A, Litvak M, Loustau D, Lund M, Marek M, Martin T A, Matteucci G, Migliavacca M, Montagnani L, Moors E, William Munger J, Noormets A, Oechel W, Olejnik J, Kyaw Paw U, Pilegaard K, Rambal S, Raschi A, Scott R L, Seufert G, Spano D, Stoy P, Sutton M A, Varlagin A, Vesala T, Weng E S, Wohlfahrt G, Yang B, Zhang Z D, Zhou X H. Thermal optimality of net ecosystem exchange of carbon dioxide and underlying mechanisms. New Phytologist, 2012, 194(3): 775-783.
- [17] 袁梓裕,张路,廖李容,王杰,雷石龙,刘国彬,方怒放,张超.黄土高原草地植物多样性与群落稳定性的关系及其驱动因素.生态学报, 2023,43(1):60-69.
- [18] 王茜. 黄土高原生态系统时空差异及其驱动因素研究[D]. 西安: 长安大学, 2022.
- [19] Tang Y K, Jiang J, Chen C, Chen Y M, Wu X. Rainfall pulse response of carbon fluxes in a temperate grass ecosystem in the semiarid Loess Plateau. Ecology and Evolution, 2018, 8(22): 11179-11189.
- [20] 刘宝军,赵晓光,党小虎,王国梁,袁子成.陕北黄土丘陵区退耕地植物群落演替特征.中国水土保持科学, 2012, 10(5): 77-83.
- [21] 李春,何洪林,刘敏,苏文,伏玉玲,张雷明,温学发,于贵瑞. ChinaFLUX CO₂ 通量数据处理系统与应用. 地球信息科学, 2008, 5: 557-565.
- [22] Falge E, Baldocchi D, Olson R, Anthoni P, Aubinet M, Bernhofer C, Burba G, Ceulemans R, Clement R, Dolman H, Granier A, Gross P, Grünwald T, Hollinger D, Jensen N O, Katul G, Keronen P, Kowalski A, Chun T L, Law B E, Meyers T, Moncrieff J, Moors E, William Munger J, Pilegaard K, Rannik Ü, Rebmann C, Suyker A, Tenhunen J, Tu K, Verma S, Vesala T, Wilson K, Wofsy S. Gap filling strategies for long term energy flux data sets. Agricultural and Forest Meteorology, 2001, 107(1): 71-77.
- [23] 马文婧,李英年,张法伟,韩琳.青海湖北岸草甸草原 CO2通量年际动态及其驱动机制.生态学报, 2023, 43(3): 1102-1112.
- [24] Kang M, Kwon H, Cheon J H, Kim J. On estimating wet canopy evaporation from deciduous and coniferous forests in the Asian monsoon climate. Journal of Hydrometeorology, 2012, 13(3): 950-965.
- [25] Cui W H, Chui T F M. Temporal and spatial variations of energy balance closure across FLUXNET research sites. Agricultural and Forest Meteorology, 2019, 271: 12-21.
- [26] Fan X Y, Gao P, Tian B Q, Wu C X, Mu X M. Spatio-Temporal Patterns of NDVI and Its Influencing Factors Based on the ESTARFM in the Loess Plateau of China. Remote Sensing, 2023, 15(10): 2553.
- [27] Huete A, Didan K, Miura T, Rodriguez E P, Gao X, Ferreira L G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. Remote Sensing of Environment, 2002, 83(1/2): 195-213.
- [28] Luo X P, Wang K L, Jiang H, Sun J, Zhu Q L. Estimation of summer land surface evapotranspiration using remotely sensed data over the Heihe river basin. Proceedings of 2011 4th IEEE International Conference on Computer Science and Information Technology, 2011, 4: 460-463.
- [29] Chen Y, Xu Y M, Chen T Y, Zhang F, Zhu S Y. Exploring the spatiotemporal dynamics and driving factors of net ecosystem productivity in China from 1982 to 2020. Remote Sensing, 2024, 16(1): 60.
- [30] Shao Y M, Liu H Z, Du Q, Liu Y, Sun J H, Li Y H, Li J L. Impact of sky conditions on net ecosystem productivity over a "floating blanket" wetland in southwest China. Advances in Atmospheric Sciences, 2024, 41(2): 355-368.
- [31] 李泽卿,黄永梅,潘莹萍,陈慧颖,胡广荣,杨崇曜.高山嵩草气孔导度对环境因子的响应模拟.生态学报, 2020, 40(24): 9094-9107.
- [32] Yvon-Durocher G, Caffrey J M, Cescatti A, Dossena M, del Giorgio P, Gasol J M, Montoya J M, Pumpanen J, Staehr P A, Trimmer M, Woodward G, Allen A P. Reconciling the temperature dependence of respiration across timescales and ecosystem types. Nature, 2012, 487(7408): 472-476.
- [33] Nakano T, Shinoda M. Interannual variation in net ecosystem CO₂ exchange and its climatic controls in a semiarid grassland of Mongolia. Journal of Agricultural Meteorology, 2018, 74(2): 92-96.
- [34] Xie B N, Jia X X, Qin Z F, Shen J, Chang Q R. Vegetation dynamics and climate change on the Loess Plateau, China: 1982—2011. Regional Environmental Change, 2016, 16(6): 1583-1594.

- [35] 高越,布仁仓,熊在平,齐丽,刘洪顺.基于气候时滞效应和空间异质性对中国植被总初级生产力的模拟.生态学报,2024,44(17): 7615-7630.
- [36] Zhang X T, Bi J R, Zhu D, Meng Z Z. Seasonal variation of net ecosystem carbon exchange and gross primary production over a Loess Plateau semiarid grassland of northwest China. Scientific Reports, 2024, 14(1): 2916.
- [37] Li X Q, Yan Y, Fu L J. Effects of rainfall manipulation on ecosystem respiration and soil respiration in an alpine steppe in northern Tibet plateau. Frontiers in Ecology and Evolution, 2021, 9: 708761.
- [38] Liu H Z, Feng J W. Seasonal and interannual variations of evapotranspiration and energy exchange over different land surfaces in a semiarid area of China. Journal of Applied Meteorology and Climatology, 51(10): 1875-1888.
- [39] 田晓晖, 张立锋, 张翔, 陈之光, 赵亮, 李奇, 唐艳鸿, 古松. 三江源区退化高寒草甸蒸散特征及冻融变化对其的影响. 生态学报, 2020, 40(16): 5649-5662.
- [40] Kimura R, Fan J, Zhang X C, Takayama N, Kamichika M, Matsuoka N. Evapotranspiration over the grassland field in the Liudaogou basin of the Loess Plateau, China. Acta Oecologica, 2006, 29(1): 45-53.
- [41] Li X, Gentine P, Lin C J, Zhou S, Sun Z, Zheng Y, Liu J, Zheng C M. A simple and objective method to partition evaporanspiration into transpiration and evaporation at eddy-covariance sites. Agricultural and Forest Meteorology, 2019, 265: 171-182.
- [42] Nemeskéri E, Helyes L. Physiological responses of selected vegetable crop species to water stress. Agronomy, 2019, 9(8): 447.
- [43] He P X, Zeng Y Y, Wang N F, Han Z M, Meng X Y, Dong T, Ma X L, Ma S Q, Ma J, Sun Z J. Early evidence that soil dryness causes widespread decline in grassland productivity in China. Land, 2023, 12(2): 484.
- [44] Mu Y M, Yuan Y, Jia X, Zha T S, Qin S G, Ye Z Q, Liu P, Yang R Z, Tian Y. Hydrological losses and soil moisture carryover affected the relationship between evapotranspiration and rainfall in a temperate semiarid shrubland. Agricultural and Forest Meteorology, 2022, 315: 108831.
- [45] Jobbagy E G, Sala O E. Controls of grass and shrub aboveground production in the Patagonian steppe. Ecological Applications, 2000, 10(2): 541.
- [46] Wei X N, He W, Zhou Y L, Ju W M, Xiao J F, Li X, Liu Y B, Xu S H, Bi W J, Zhang X Y, Cheng N. Global assessment of lagged and cumulative effects of drought on grassland gross primary production. Ecological Indicators, 2022, 136: 108646.