

尺度知识引导的深度学习生态系统碳汇模拟

周咏杰^{1,2†}, 江昊^{3†}, 陈星^{1,2*}, 王旭辉^{3*}

1. 福州大学计算机与大数据学院, 福州 350108
2. 福建省网络计算与智能信息处理重点实验室, 福州 350108
3. 北京大学城市与环境学院, 北京 100871

† 同等贡献

* 联系人, E-mail: xuhui.wang@pku.edu.cn; chenxing@fzu.edu.cn

2024-06-14 收稿, 2024-09-28 修回, 2024-11-19 接受, 2025-02-06 网络版发表

国家自然科学基金(42041007, 42171096, 62072108)、福建省科技经济融合服务平台(2023XRH001)和福厦泉国家自主创新示范区协同创新平台项目(2022FX5)资助

摘要 深度学习方法因其优异的非线性拟合能力被越来越多地应用于陆地生态系统碳通量估算任务中。然而常用的“端到端”建模框架在全球模拟任务中虽然较好拟合陆地碳通量季节变化过程, 却存在低估年际变异的问题。因此, 明确已有建模框架是如何导致不同时间尺度碳通量模拟的不确定性, 是进一步提升深度学习模型的准确性和完善数据驱动建模方法的前提。基于净生态系统碳交换(NEE)在季节和年际尺度具有不同响应和变化规律这一先验知识, 本研究结合奇异谱分析(SSA)方法和长短时记忆(LSTM)模型提出了“知识引导”建模框架, 并使用FLUX-NET站点观测数据进行验证。结果表明, LSTM模型的表现优于其他基准方法, 同时“知识引导”框架显著提高了年际NEE模拟的性能。通过跨尺度应用已训练的季节和年际LSTM模型并结合小波分析, 进一步揭示了NEE季节动态和年际变异具有完全不同的响应规律。基于SHAP方法和模型响应评估结果表明, 辐射(46.9%)和温度(24.5%)分别是驱动NEE季节和年际尺度变化的主导贡献因子, 而饱和水汽压差(VPD)、降水和风速变化在年际LSTM模型中的影响高于季节LSTM模型。研究结果同时揭示了“端到端”框架的模型在训练过程中为季节分量主导, 并证明尺度知识引导是提高深度学习模型对生态系统NEE模拟精度的有效手段。

关键词 净生态系统碳交换, 年际变异, 季节动态, 深度学习, 气候变化, 全球陆地生态系统

全球陆地生态系统吸收了约30%人类活动所产生的碳排放, 对调节全球碳平衡起着重要作用^[1~3]。在全球极端气候事件日益频发和人类活动影响加剧的背景下, 陆地生态系统碳循环过程受到了较大影响^[1,2]。因此, 准确量化陆地生态系统的净生态系统碳交换(net ecosystem exchange, NEE)至关重要。由于碳循环过程涉及多元且复杂的生态学过程, 全球陆地生态系统NEE在季节和年际尺度上呈现出明显不同的模式^[3~7]。精准地估算不同时间尺度NEE的变化特征, 深入研究背后的气候效应和驱动机制, 是评估气候变化背景下

陆地生态系统碳汇功能的关键^[4~6,8]。然而, 受限于空间异质性和碳循环驱动过程的复杂性, 目前定量模拟方法对陆地生态系统NEE估算的不确定性较高, 提高生态系统尺度上模型模拟精度在气候变化背景下具有重要意义^[9~12]。

伴随着相关监测数据的累积, 数据驱动的碳通量模拟方法展现出相较于传统方法更高的准确性和空间泛化能力^[13~16]。相关研究使用了包括基于注意力的Transformer^[17]、卷积神经网络(convolutional neural network, CNN)^[18]、长短时记忆神经网络(long short-

引用格式: 周咏杰, 江昊, 陈星, 等. 尺度知识引导的深度学习生态系统碳汇模拟. 科学通报, 2025, 70: 2791~2804

Zhou Y, Jiang H, Chen X, et al. Scale knowledge guided deep learning for simulating ecosystem carbon fluxes (in Chinese). Chin Sci Bull, 2025, 70: 2791~2804, doi: [10.1360/TB-2024-0639](https://doi.org/10.1360/TB-2024-0639)

term memory, LSTM)^[19,20]在内的深度学习模型，并在站点上验证了深度学习模型对NEE模拟的准确性。FLUXCOM产品(<https://fluxcom.org/>)使用多元自适应回归样条(multivariate adaptive regression splines, MARS)、随机森林(random forest, RF)和人工神经网络(artificial neural network, ANN)模型，基于气象或遥感数据拟合站点碳通量变化，并进一步将站点模型外推生成全球NEE产品^[13,15]。以上研究中，深度学习模型均采用了端到端的有监督学习框架，也即使用初步处理的原始观测和特征训练模型，通过计算样本的损失函数和反向传播梯度更新模型参数。然而有研究发现尽管FLUXCOM产品的全球季节性NEE在变化趋势和量级上和过程模型以及大气反演模型较为一致^[19~21]，但是显著低估了全球NEE年际变异的量级^[6,13,20]。研究表明目前深度学习的NEE模拟方法在端到端框架下，未能区分不同尺度NEE的响应差异，影响了对年际变异过程的拟合。此外神经正切核等理论也指出，神经网络类模型在训练时，不同频率的信号的收敛速度和主导地位不同^[22~24]。如何解决深度学习模型中尺度混淆、估算精度有待提高等问题，对评估生态系统碳汇功能变化和揭示不同尺度NEE变异的主要驱动力具有重要意义。

通过指导特征工程、模型结构设计等方式将领域先验知识融合到深度学习模型中，是提高深度学习模型性能的有效手段^[14]。以往研究表明，陆地生态系统碳循环的驱动因子和机制在不同时间尺度上有显著差异^[6,7]。基于这一先验尺度知识，针对NEE的季节和年际变化选取对应特征能有效约束深度学习算法的搜索空间，从而提高算法的准确性和鲁棒性。同时在模型训练上，使用时序分解引导损失函数计算和梯度传播，可以抑制混合信号导致的不确定性。此外，生态系统对驱动因子的响应存在时间滞后与累积效应，并表现出记忆效应^[19,20]。因此，表征不同时间尺度下驱动因子的时滞和累积效应对于模拟NEE的准确度和定量归因至关重要。以LSTM为代表的时序神经网络相比RF或ANN等方法，能利用记忆-遗忘机制更充分表征复杂系统中的时变滞后响应和非线性关联^[19,20]。综上所述，以生态系统NEE的尺度效应和响应过程的记忆效应为先验知识引导深度学习模型，评估时序深度学习模型和先验知识融合的有效性，对提升生态系统NEE定量模拟的准确性有积极意义。

本研究为提升深度学习模型在陆地生态系统NEE

模拟和预测任务中的性能，探究先验知识与深度学习模型的融合路径并验证其有效性。方法上，以时序神经网络LSTM模型表征生态系统记忆效应，并引入时序分解技术来引导模型拟合NEE的季节性波动与年际波动过程。研究基于国际通量观测网络(FLUXNET, <https://fluxnet.org/>)数据集，首先对比多种机器学习模型分别在“端到端”框架和“知识引导”框架下对站点季节和年际NEE模拟的性能差异。随后设计跨尺度实验，并通过交叉小波分析和SHAP值(SHapley Additive exPlanations)计算比较不同时间尺度下LSTM模型的驱动机制和关键气象因子的异同。研究结果表明，无引导的模型在训练过程中受季节分量主导，导致对年际尺度的NEE响应过程拟合的不确定性，并证明尺度知识引导是提升深度学习NEE定量估算模型精度的有效方法。本研究通过优化深度学习NEE估算模型对不同时间尺度响应过程的拟合能力，为评估气候变化对碳循环过程影响提供有效的数值模拟方法和分析工具。

1 材料与方法

1.1 数据与预处理

本研究使用的数据来源于国际通量观测网络发布的FLUXNET 2015数据集(<https://fluxnet.fluxdata.org/data/fluxnet2015-dataset/>)。FLUXNET提供了具有高时间分辨率的气象和碳通量观测数据，并统一经过质量控制和处理。本研究选取风速(wind speed, WS)、降水量(precipitation, P)、空气温度(air temperature, TA)、净辐射(net radiation, NETRAD)、饱和水汽压差(vapor pressure deficit, VPD)的日值数据作为模型输入。本研究筛选出FLUXNET 2015数据集中提供超过5年连续通量观测数据的共94个站点(图1)。数据集一共包含399955条站点气象和NEE日值记录，其中NEE和辐射记录中分别有占总数3.6%和18.6%的缺失值，并使用相关站点对应儒略日的多年平均值来填补。按国际地圈生物圈计划(International Geosphere Biosphere Programme, IGBP; <http://www.igbp.net/>)土地利用分类方案划分为8类生态系统，分别为草地(GRA)站点17个、农田(CRO)站点11个、湿地(WET)站点4个、热带草原(SAV和WSA)站点5个、灌木地(OSH和CSH)站点7个、混交林(MF)站点4个、落叶阔叶林(DBF)站点15个和常绿林(ENF和EBF)站点31个。

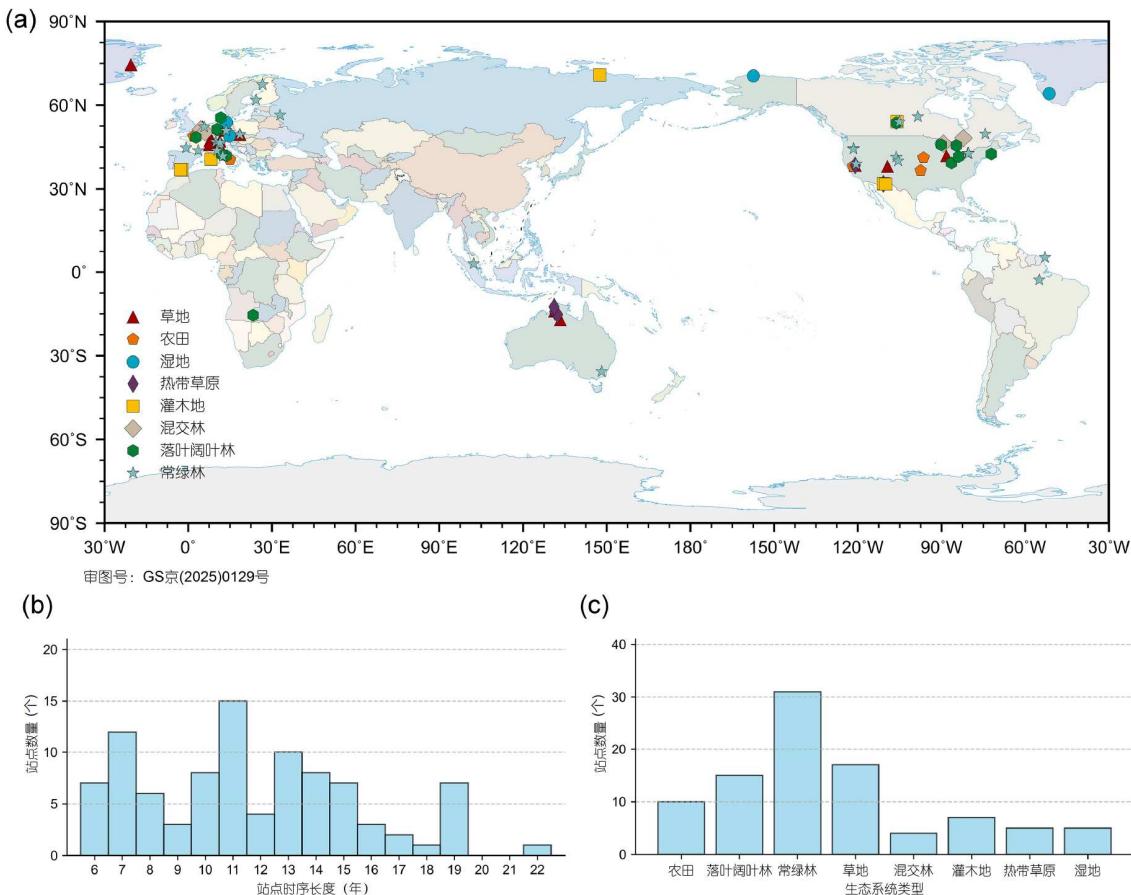


图 1 研究选取94个通量站的分布和统计信息. (a) 通量站的空间分布; (b) 通量站的时序长度信息; (c) 不同生态系统的通量站数量

Figure 1 Distribution of the 94 flux stations worldwide covering eight main landscape types. (a) Spatial distribution of flux stations. (b) Timing length information of flux stations. (c) Number of flux stations in different ecosystems

1.2 尺度知识引导的建模方法

长期观测的NEE时序数据中包含了具有不同的时频特征的季节和年际分量. 为将尺度先验知识引入深度学习训练框架, 本研究采用了奇异谱分析方法(singular spectrum analysis, SSA)来分离站点NEE观测数据中的季节和年际分量^[6], 并引导各自时间尺度深度学习模型的训练. SSA是一种有效的时间序列分解方法, 其主要优势在于无参数化, 不需要对数据生成过程进行任何先验假设, 有助于开展年际、季节性等趋势的分离. 基于相关研究, 在SSA分析中基于信号周期分离NEE和气象要素的季节(<16个月)、年际(16~128个月)和长期趋势(>128个月)分量(附录S1).

针对生态系统中的记忆效应, 本研究使用LSTM构建NEE模型. LSTM是一种特殊的循环神经网络, 在其

递归过程中时序信息能被有选择地保留和遗忘, 是被广泛用于时间序列建模的深度学习技术^[25]. 该模型的基本LSTM单元由前一时刻的细胞状态 c_{t-1} 、输出 h_{t-1} 和当前的输入 x_t 生成当前的细胞状态 c_t 和输出 h_t , 用于控制细胞中的信息流(细胞状态 c_t 和输出 h_t)(图2). 这一过程由遗忘门 f_t 、输入门 i_t 和输出门 o_t 组成的门控机制实现, 通过生成的权重向量以确定保留的历史信息以及向后传递的信息.

本研究基于生态系统划分站点集合, 分别以无知识引导的“端到端”框架和“知识引导”框架构建和训练LSTM模型. 其中无知识引导的“端到端”框架在本研究中特指不对输入和样本做时序分解的建模方式, 该方式构建模型以下简称为无引导模型. 实验中所有模型使用相同的“输入层-LSTM层-输出层”结构(图2). 模型输入层接收365日连续的气象观测数据, 并使用年积日

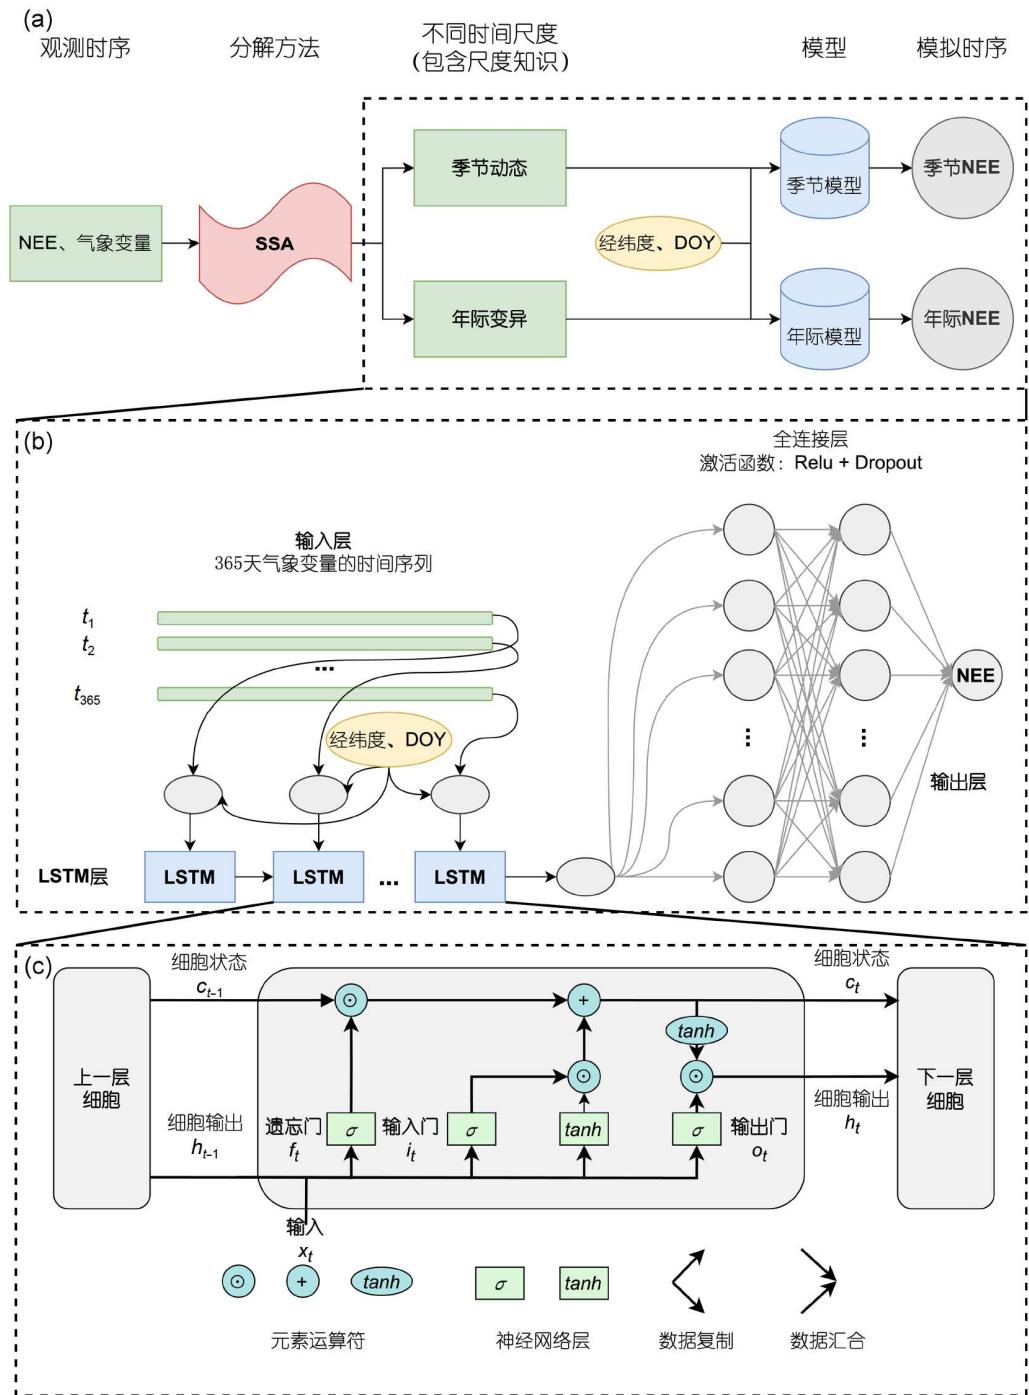


图 2 “知识引导”和LSTM时序模型框架图. (a) 结合时序分解的知识引导过程; (b) LSTM模型模拟NEE变化的数据流; (c) LSTM单元的详细结构

Figure 2 The architecture of the LSTM-based simulator. (a) Framework of providing guidance by temporal decomposition; (b) pipeline of the LSTM model; (c) detailed structure of the LSTM cell

(date of year, DOY)、经纬度作为辅助信息输入模型(图2). 训练过程中, 季节和年际尺度引导的LSTM模型

输入的气象因子也各自使用SSA方法分解时序分量(图S1, S2); 而无引导模型则使用未处理的气象观测数据

作为模型输入,在后续评价中则结合SSA方法进一步分解模拟NEE的季节和年际分量以评估模型性能。本研究将每个站点的时间序列(包括NEE、气象变量及辅助信息)划分成两部分:前80%数据作为训练集,用于超参数搜索和模型训练;后20%数据作为测试集。本研究采用开源的Python库Pytorch和NVIDIA TITAN RTX(24G显存)作为训练设备实现模型构建和训练。同时使用随机搜索算法为每一类生态系统单独进行五折交叉验证(Cross-Validation)以搜索合适的超参数组合(附录S2)。模型训练过程中采用Adam优化器优化损失函数,以实现训练过程中学习率和动量等参数的动态调整防止过拟合。

1.3 模型评估方法

本研究首先对比LSTM模型在模拟NEE任务中相对其他机器学习方法的性能差异。三种常用机器学习模型(包括LASSO、支持向量回归SVR和随机森林RF)以及一种深度学习模型(前馈神经网络FNN)作为对比方法,并使用相同的训练集和知识引导框架训练,随后在测试集中计算RMSE(root mean square error), MAE(mean absolute error), R^2 和LCS(lack of correlation weighted by the standard deviations)指标对比性能。MAE定义如下:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i|, \quad (1)$$

其中, y_i 表示观测值, y'_i 表示模拟值。本研究使用相关系数 r (correlation coefficient)的平方计算 R^2 , 相关系数 r 定义如下:

$$r = \frac{\sum_{i=1}^n [(x_i - \bar{x})(y_i - \bar{y})]}{(SD_s SD_m)}. \quad (2)$$

LCS^[26]定义如下:

$$\text{LCS} = 2SD_s SD_m (1 - r), \quad (3)$$

其中, SD_s 表示模拟值的标准差, SD_m 表示观测值的标准差, r 表示模拟值与观测值之间的相关系数。LCS越大, 表明模型模拟结果和观测序列的波动模式越不一致。

为评估尺度知识引导下的季节和年际LSTM模型是否捕捉到了尺度特异的气象驱动机制, 本研究进一步使用跨尺度实验和SHAP方法揭示不同尺度模型的响应特征和因子重要性。跨尺度实验中, 通过交换训练所得季节和年际LSTM模型的应用尺度, 进而对比跨尺度模拟结果在RMSE等性能指标的变化。然后, 使用交

叉小波变换方法计算小波功率谱和小波凝聚谱^[27~29], 以分析模拟序时序和观测时序的相干性和相位特征(附录S3)。

为了进一步评估不同气象因子对季节和年际NEE模拟的重要性, 本研究基于训练的季节和年际LSTM模型使用shap包计算了每个样本中对应气象因子的SHAP值。SHAP值是一种源自博弈论研究的因子贡献量化方法, 在保证因子贡献可加性的同时量化每个输入特征对预测值贡献^[30]。在本研究中使用了Gradient-SHAP这一基于梯度的模型无关方法^[30,31], 通过添加扰动估计LSTM模型输入特征的SHAP值(附录S4)。

2 结果与分析

2.1 NEE拟合性能对比

研究结果表明基于知识引导的深度学习模型能有效提升季节和年际NEE的模拟精度。本研究首先对比了多类数据驱动的回归模型在“端到端”框架和“知识引导”框架下的模拟性能。在分别模拟季节NEE、年际NEE和未分解的NEE任务中, LSTM模型在测试集上的RMSE分别为1.11、0.336和1.563 gC m⁻² d⁻¹, 并综合相关性和LCS指标表明其性能整体上优于LASSO、SVR、RF和FNN方法构建的回归模型(表1)。

而缺乏尺度知识引导的深度学习模型对NEE的年际变异估算不确定性更高。以图3展示的NEE拟合性能变化所示, 无引导的LSTM模型在不同生态系统中拟合季节NEE的性能和尺度知识引导的季节LSTM没有显著差异。然而, 在年际NEE的拟合任务中, 具有尺度知识引导的年际LSTM在多数的生态系统中显著优于无引导的LSTM模型。尤其在热带草原(SAV和WSA)站点中, 年际LSTM相比无引导的LSTM模型 R^2 提升0.42。此外, 通过额外实验发现在季节NEE和年际NEE模拟中, 增加NEE的长期趋势对季节和年际NEE的模拟性能影响并不显著(表S1)。

2.2 季节LSTM和年际LSTM模型响应差异

为验证季节和年际LSTM模型捕捉到不同尺度下特异的驱动机制, 本研究进一步设计了跨尺度实验对比训练所得季节和年际LSTM模型之间的响应差异。结果表明, 无论是将季节LSTM应用在年际尺度还是将年际LSTM模型应用在季节尺度, 性能指标在不同生态系统中都显著恶化(图4)。其中季节和年际NEE预测的误

表1 测试集性能比较^{a)}

Table 1 Comparison of test performance

模型	未分解NEE				季节NEE				年际NEE			
	RMSE	R ²	LCS	MAE	RMSE	R ²	LCS	MAE	RMSE	R ²	LCS	MAE
LSTM	1.563	0.634	2.152	1.005	1.110	0.706	1.106	0.728	0.336	0.181	0.092	0.222
LASSO	2.097	0.342	3.213	1.459	1.562	0.419	1.912	1.082	0.370	0.016	0.075	0.235
SVR	1.682	0.577	2.506	1.068	1.235	0.637	1.398	0.785	0.375	0.035	0.103	0.246
RF	1.660	0.588	2.489	1.022	1.200	0.657	1.316	0.741	0.416	0.010	0.156	0.263
FNN	1.630	0.604	2.384	1.028	1.203	0.656	1.345	0.753	0.381	0.042	0.119	0.245

a) 各模型模拟测试集中NEE季节动态和年际变异的性能指标. RMSE、LCS和MAE的单位均为 $\text{gC m}^{-2} \text{d}^{-1}$. 未分解NEE指的是未经过SSA方法分解的NEE, 其中包含了NEE的季节、年际及长期趋势分量

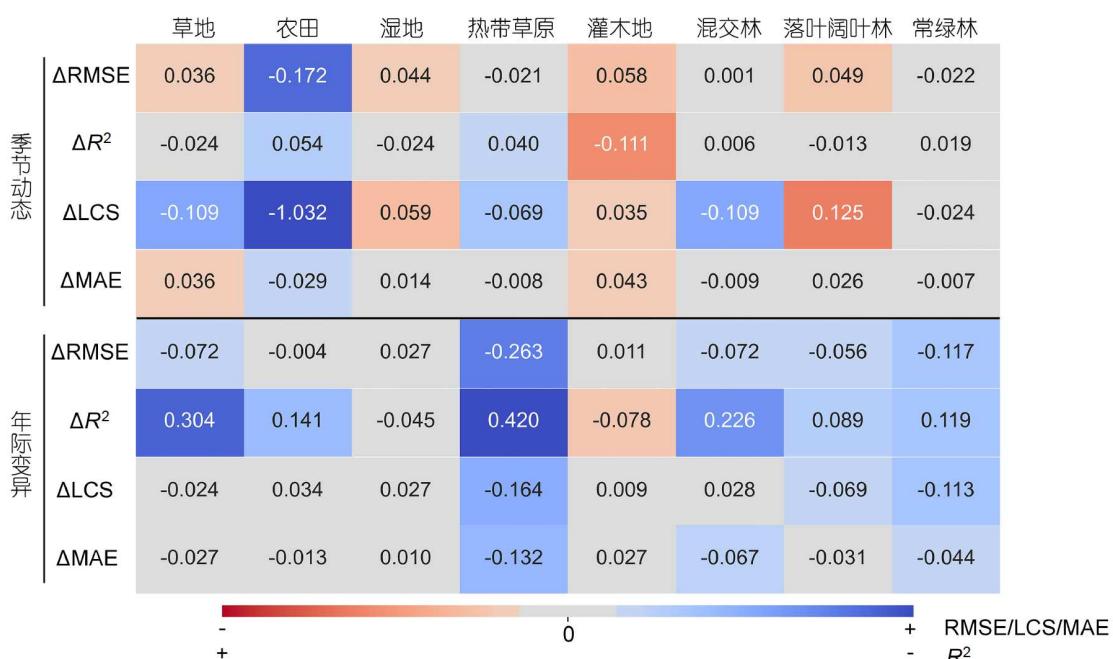


图3 “知识引导”框架和无引导框架性能差异. 蓝色表示在测试集中, 具有尺度知识引导的LSTM模型性能指标优于无引导LSTM模型. ΔRMSE 、 ΔLCS 和 ΔMAE 单位均为 $\text{gC m}^{-2} \text{d}^{-1}$

Figure 3 Performance differences between “knowledge-guided” and unguided frameworks. Blue indicates that the LSTM model with scale knowledge guidance outperforms the unguided LSTM in terms of performance metrics in the simulated site seasonal or IAV NEE tasks in the test set. The units of ΔRMSE , ΔLCS , and ΔMAE are $\text{gC m}^{-2} \text{d}^{-1}$

差RMSE指标在跨尺度之后, 在所有生态系统中均有升高, 表明跨尺度应用之后模型模拟数值的绝对偏差增大. 当使用 R^2 指标评价时, 季节LSTM模型模拟对应季节NEE为0.706, 而跨尺度使用年际LSTM模型的模拟季节NEE的 R^2 为0, 表明跨尺度年际LSTM模型和季节NEE不存在线性关系, 也表明年际LSTM模型的驱动关系和季节NEE有显著差异(表2). 类似地, 年际引导的LSTM模型的 R^2 指标为0.181, 但是当季节LSTM跨尺度应用于年际NEE预测时测试集上的总体 R^2 则接近0, 表

明跨尺度应用模型模拟结果和观测值不存在显著的线性相关性, 也证明季节LSTM模型的驱动关系和年际NEE不同(表2).

跨尺度实验中, 不同尺度模型在站点模拟结果的变化也十分显著. 基于图5展示的站点模拟性能指标分布可知, 使用正确尺度的LSTM模型模拟结果在相关性和绝对误差方面总体优于跨尺度模型. 进一步基于小波分析的跨尺度实验结果表明, 季节和年际LSTM模型在跨尺度应用之后模拟的NEE在振幅和相位角等时频

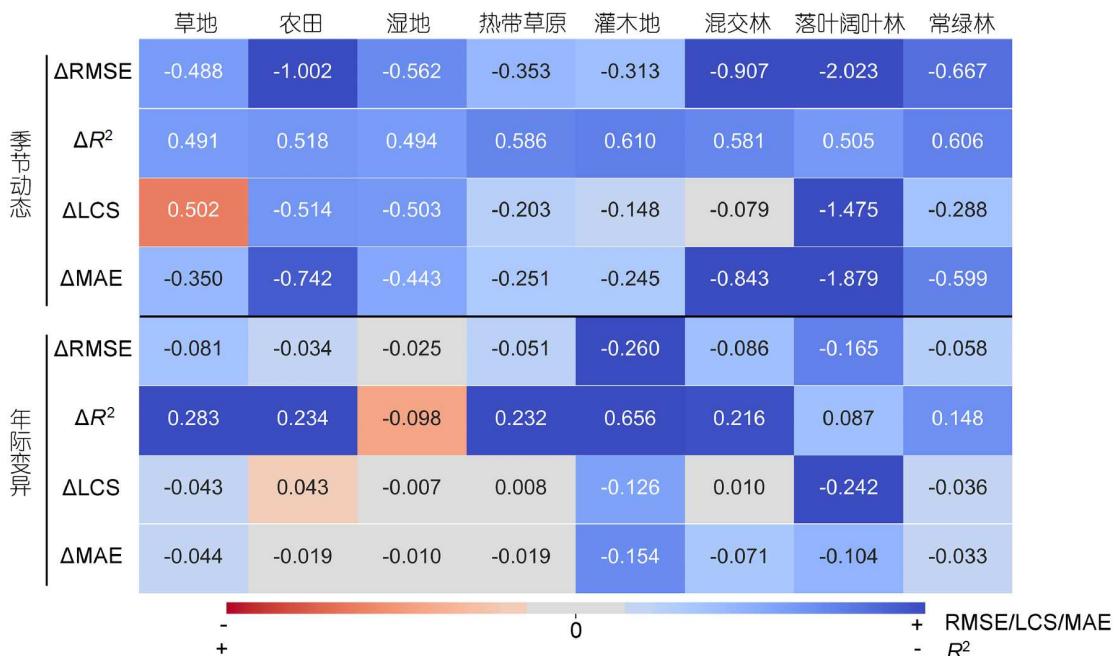


图 4 跨尺度实验中生态系统拟合结果。蓝色表示跨尺度实验中正确尺度构建的LSTM模型性能指标优于跨尺度LSTM模型。 ΔRMSE 、 ΔLCS 和 ΔMAE 单位均为 $\text{gC m}^{-2} \text{d}^{-1}$

Figure 4 Changes of performance in the cross-scale experiment. Blue indicates that the LSTM model with proper timescale outperforms the cross-scale applied LSTM. The units of ΔRMSE , ΔLCS , and ΔMAE are $\text{gC m}^{-2} \text{d}^{-1}$

表 2 跨尺度应用的性能^{a)}

Table 2 Performance of the cross-scale application

性能指标	模拟季节NEE		模拟年际NEE	
	季节LSTM	年际LSTM	季节LSTM	年际LSTM
RMSE	1.110	2.103	0.429	0.336
R^2	0.706	0.000	0.000	0.181
LCS	1.106	1.993	0.164	0.092
MAE	0.728	1.521	0.276	0.222

a) 跨尺度应用的季节和年际LSTM模型在测试集的模拟性能。RMSE、LCS和MAE的单位均为 $\text{gC m}^{-2} \text{d}^{-1}$

性质上均发生了显著变化。具体以FR-Gri典型站点为例可知，该站点的季节和年际NEE分别在128~512和360~1500 d的时间尺度上显示出较强的功率(图S3)。当在该站点使用季节和年际LSTM模型分别模拟对应尺度的季节和年际NEE时，模拟和观测数据的共轭周期和相位角均高度一致(图S4)。但跨尺度应用季节LSTM模型模拟年际NEE时，其模拟结果和观测的年际NEE只在季节尺度内(256~512 d)有显著的共振周期，相位角则不一致且显著提前(图S4)。当跨尺度应用年际LSTM模拟季节NEE变化时，模拟结果在所有特征周期内都与站点观测年际NEE没有显著关系(图S4)。以上结

果均表明，生态系统NEE的响应规律在年际和季节尺度有极大差异，然而无引导模型学习到的规律为季节尺度所主导。

2.3 模拟不同尺度NEE的气象因子重要性

深度学习模型由于抽象程度高、信息处理过程复杂常被称为“黑箱”模型，为评估不同尺度LSTM模型中的关键气象因子，本研究使用SHAP方法量化评估气象因子输入的贡献和重要性。基于SHAP计算结果显示，不同尺度下的气象因子对NEE模拟的贡献存在显著差异(图6)。其中，辐射和温度是对季节LSTM模拟贡献最

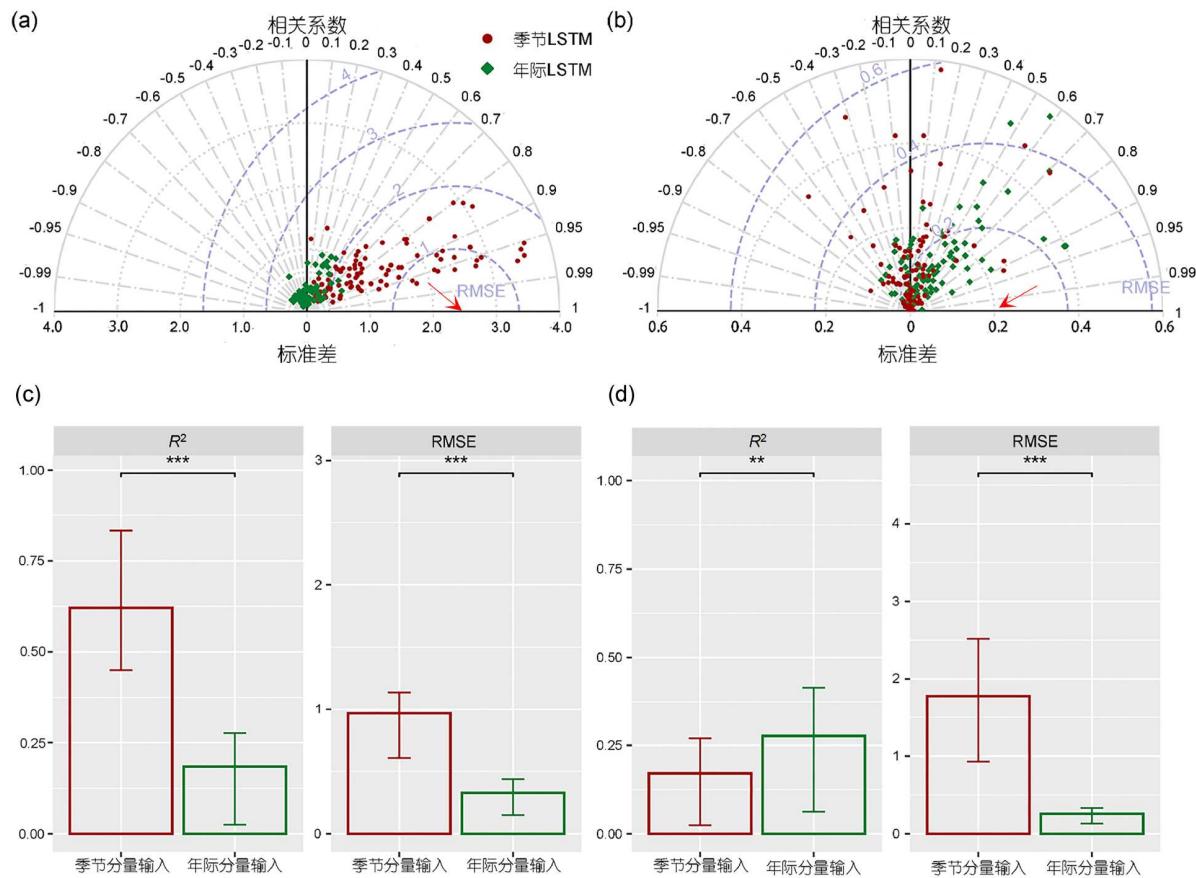


图 5 跨尺度实验中站点模拟性能指标变化. 使用气象因子的季节和年际分量输入训练的季节和年际LSTM模型得到的泰勒图(a, b)以及站点性能指标分布(c, d). 泰勒图中红色箭头表示越靠近所指处性能越好. 柱状图中的柱形代表所有站点 R^2 和RMSE指标的均值, 误差棒表示所有站点 R^2 和RMSE指标的25%和75%分位数. 使用 t 检验站点性能差异的显著性, **表示 $P<0.01$, ***表示 $P<0.001$. RMSE的单位为 $\text{gC m}^{-2} \text{d}^{-1}$

Figure 5 Results of cross-scale experiments. The Taylor diagrams (a, b) were generated using seasonal and interannual components of meteorological factors as input to train seasonal and interannual LSTM models, along with the distribution of site performance indicators (c, d). In the Taylor diagrams, the red arrows indicate that performance improves as one gets closer to the pointed location. The bars in the histogram represent the mean R^2 and RMSE indicators for all sites, while the error bars indicate the 25th and 75th percentiles of R^2 and RMSE indicators across all sites. The t -test was conducted to assess the significance of performance differences among sites, where *** indicates $P<0.01$ and ** indicates $P<0.001$. The units of RMSE are $\text{gC m}^{-2} \text{d}^{-1}$

大的气象因子, 其所有站点平均贡献率分别达到46.9%和34.8%, 并且辐射对大部分生态系统生长期內季节NEE变化有主导地位(图S5), 而降水、VPD和风速因子对季节NEE的贡献相对较低. 对于年际LSTM模型, 辐射因子的重要性明显下降, 温度成为最关键的气象因子, 其平均贡献率为24.5%. 此外VPD、降水和风速的平均贡献在年际LSTM模型中也显著高于季节LSTM模型, 体现了年际NEE变化更为复杂的驱动机制.

2.4 模拟不同生态系统NEE对气象因子变化的响应

通过控制气象因子输入区间, 本研究实现借助尺

度引导的LSTM模型对不同尺度下的因子间的交互作用进行定量分析. 本实验主要验证草地、落叶阔叶林、常绿林三类站点数量相对较多的生态系统, 保证知识引导模型训练能接触更多样的样本分布, 减少随机误差. 实验结果表明, 温度和辐射对这三类生态系统的季节NEE有典型的协同效应, 当温度和辐射因子增加或减少时的季节NEE变化方向一致(图7). 同时在草地生态系统观察到了阈值效应, 也即辐射和温度超过一定阈值后会减弱草地生态系统的碳汇功能. 对于年际LSTM模型, 在控制实验中发现模型输出年际NEE和气象因子的交互关系更加复杂, 气象因子在不同区间的变化会产生不同的影响. 例如在落叶阔叶林中, 温度降

低在-0.6°C及以上区间会减低碳汇，但当温度变化低过-0.6°C后会一定程度上增加碳汇功能(图7). 以上结果

表明，年际NEE和气象因子之间的交互关系更加复杂和多样.

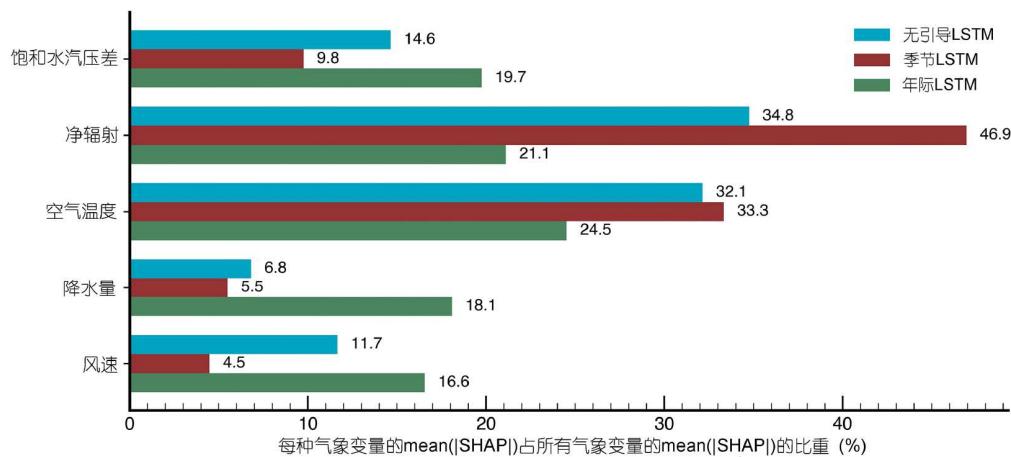


图 6 基于SHAP值的气象因子重要性. 基于不同生态系统构建LSTM模型以均值聚合计算

Figure 6 Importance of meteorological factors based on SHAP values. The contributions were calculated by aggregating results from LSTM models trained for different ecosystems

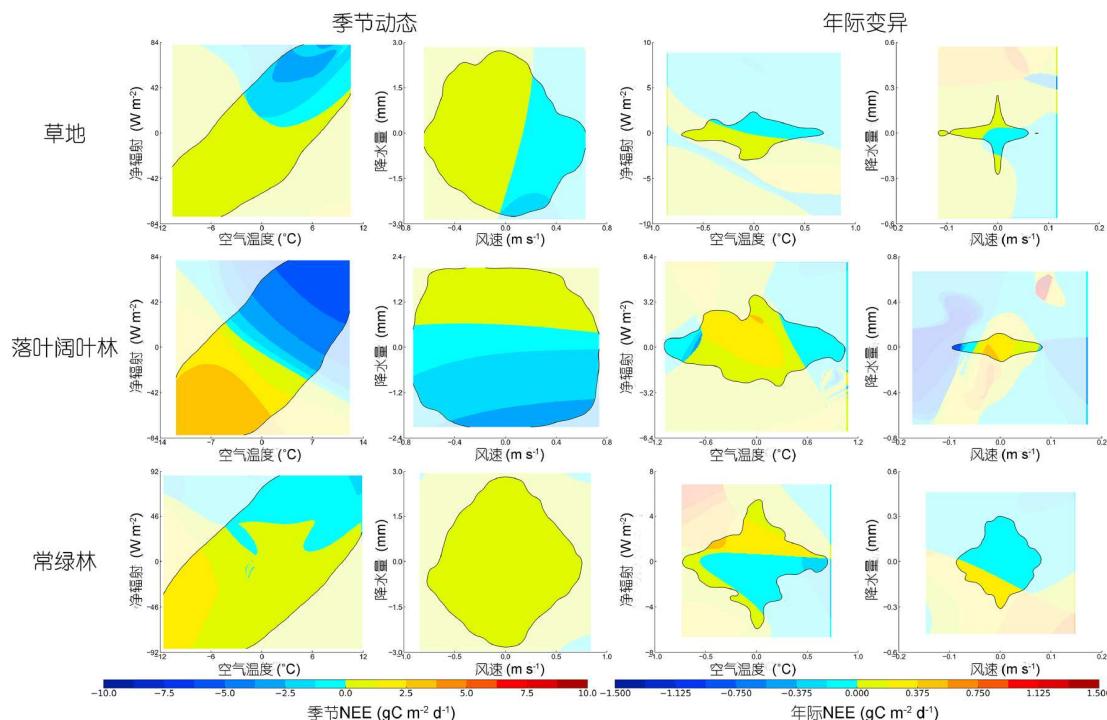


图 7 模拟不同时间尺度NEE的气象响应. 选择在草地(GRA)、落叶阔叶林(DBF)、常绿林(ENF+EBF)站点构建的知识引导LSTM模型, 模拟在不同温度和辐射、风速和降水条件下, 季节性NEE响应和年际性NEE 的响应. 图中白色阴影代表样本分布低密度区域, 为核函数估计的样本密度低于10%分位数区域

Figure 7 Relationship between NEE and meteorological variables. The figure shows the NEE responses simulated by knowledge-guided LSTM models for grassland (GRA), deciduous broadleaf forest (DBF), and evergreen forest (ENF+EBF) sites under varying conditions of temperature, radiation, wind speed, and precipitation. The white shaded areas indicate low-density regions, where the estimated density from the kernel function is below the 10th percentile

3 讨论

陆地生态系统NEE受到多种驱动因子的影响，同时驱动因子之间也存在复杂的交互作用，受限于观测站点和可利用数据的稀疏性，对NEE变化的定量归因是当前研究中的瓶颈问题^[7,8]。深度学习模型能由历史观测中学习复杂因子关联特征，具有从浅层到深层，从具象到抽象的学习机制，并借助大尺度时空信息进行空间外推，为全球生态系统NEE估算提供新的方法和依据。由于数据驱动的深度学习算法依赖于训练数据质量和分布，容易受到样本偏差和过拟合问题的影响，因此如何提升深度学习算法在不同生态系统站点的准确性对后续应用至关重要。知识引导已被证明是提高深度学习模型性能和泛化能力的有效策略^[32,33]。物理信息神经网络(physics-informed neural networks, PINNs)将偏微分方程描述的物理定律和损失函数结合，以有监督范式将物理知识嵌入神经网络模型^[34~36]。也有研究提出将领域知识以规则、约束或特定信息流的形式引导模型结构设计，例如时间序列模型中为捕捉不同频域特征而设计的多通道结构^[37~39]。本研究结合生态系统NEE具有典型季节和年际尺度变化特征这一先验知识，提出结合频率信号分解方法以引导深度学习模型对不同时间尺度NEE变化特征进行有效学习。

现有研究发现深度学习方法在站点和全球外推任务中存在低估NEE年际变异的问题，但尚不明确其具体成因^[13,15]。本研究结果表明，表征生态系统记忆效用和尺度特征有助于提高站点NEE模拟的准确性。首先对比LSTM模型和不具备时序结构的RF、SVM等模型可知，拥有记忆-遗忘结构的LSTM能更好表征生态系统记忆效应和气象因子的时间滞后作用，站点NEE模拟的准确性更高。比较无引导和知识引导模型发现，缺乏尺度知识引导的模型在训练中对季节NEE变化过拟合，混淆了年际NEE对气象因子变化的响应规律。本研究结合跨尺度实验和SHAP分析结果证明，尺度知识引导下构建的季节LSTM模型和年际LSTM模型具有完全不同的响应规律，另一方面无引导的端到端LSTM模型学习到的关键因子更接近季节LSTM模型，并低估了水分相关因子引发的变化。例如在FR-Gri站点中，无引导框架下训练的模型其模拟结果无论是在训练集还是测试集都不包含有效的年际成分(图S6)。随着生态系统记忆效应表征的重要性得到认识，使用LSTM时序神经网络作为底层架构的碳通量模拟方法开始受到关注^[19,20]。然而以往研究中尽管融合了额外的遥感观测

产品^[19,20]，无引导的LSTM模型在站点尺度或生态系统尺度上估算NEE年际变异的RMSE和 R^2 指标均未超过本研究(图S7)。在Besnard等人^[19]的研究中，虽然引入了额外的遥感信息作为数据源，但站点NEE年际变异的拟合性能不佳，整体 R^2 仅为0.09，低于本研究。Liu等人^[20]的研究进一步融合了多源遥感数据作为输入特征，尽管在年尺度上计算的年际变异和本文仅使用气象因子估算结果的 R^2 指标相近，但RMSE指标相对更高。以上对比表明以往研究中，LSTM模型受限于无引导框架，对气象因子的驱动过程未能充分表征。而增加NEE的长期趋势对季节和年际NEE的模拟性能影响不明显，可能受限于FLUXNET2015数据集的观测长度(站点平均观测长度为11年)，SSA方法分解的长期趋势变化尚不明显，模型学习到的有效信息不足。

本研究中，知识引导模型在不同生态系统中的性能提升存在差异，例如湿地(WET)和灌木地(OSH和CSH)生态系统中没有观察到显著的拟合性能变化。一方面原因是不同类型生态系统，乃至不同地区的相同生态系统，其NEE的碳循环及气候与非气候效应的影响存在较大差异。而本研究使用的气候因子尚不能充分表征植被类型等生物因子的作用。有研究表明对于湿地生态系统植物功能类型与营养条件等非气候效应的对碳循环过程影响大于气候效应^[40]。另一方面，本实验中湿地(WET)和热带草原(SAV和WSA)站点数量相对较少并且空间分布稀疏，样本数量和代表性不足会导致模型处于欠拟合状态并且不确定性升高。

深度学习模型由于嵌套层数高内部机制不易直观解释，常被称为“黑箱”模型。本研究应用SHAP和控制变量实验方法利用LSTM模型揭示不同时间尺度NEE变化的关键气象驱动因子及其贡献，实现基于深度学习模型的定量归因分析，提高了深度学习模型的可解释性。在本研究选取的站点中，辐射和温度是最主要的驱动因素，两者共同贡献了81.7%的NEE变化。太阳辐射是光合作用的能量来源，温度对植物生理活动有普遍影响，二者在季节尺度上的变化会直接影响生态系统植被光合或呼吸作用强度，因此主导生态系统NEE的季节变化^[4,41~43]。在年际尺度上，降水和VPD等水分相关因素以及风速的贡献率显著提升，表明在年际NEE的模拟中，风速和水分条件同样不可忽视。其中风速变化会影响生态热量和水汽的交换速率，植物的生长速率和叶片形态，植物气孔水汽交换等过程，导致NEE的年际变异^[44]。水分条件也是植物进行生理活动

的重要保障，干旱胁迫导致的植被气孔闭合会阻碍光合作用，并减弱生态系统净碳吸收^[45,46]。该结果和相关研究一致表明了在全球陆地生态系统中NEE年际变异受到多种因子的综合作用的重要影响^[47]。

4 结论

本研究基于FLUXNET站点观测数据，通过引入NEE在不同时间尺度具有不同变化特征这一先验知识，结合SSA分解和具有时序模拟能力的LSTM模型评估深度学习模型对不同时间尺度NEE模拟的不确定性来源，揭示了无引导模型训练过程由季节尺度主导，证明合理的“知识引导”框架对提升深度学习NEE模拟准确性至关重要，并得到如下结论：(1) 模型性能评估表明，本研究使用的LSTM模型在多种NEE模拟任务中均优

于其余模型，同时使用“知识引导”建模框架对季节和年际NEE分量的模拟准确性高于“端到端”框架，特别是显著提高了年际NEE模拟的性能。(2) 跨尺度实验结果表明，季节和年际LSTM模型所学习到的NEE响应规律有显著差异，应用季节模型模拟年际变化或者用年际模型模拟季节变化，会使模拟结果的振幅、共振周期和相位等性质不准确，最终导致性能的显著恶化。(3) 气象因子重要性分析表明，季节和年际LSTM模型的关键因子和驱动机制也存在显著差异。基于SHAP和控制变量实验结果，表明辐射和温度是调控季节NEE的关键因子，并且在森林生态系统中具有典型的协同作用；年际NEE模拟中，温度是最重要的输入因子，并且降水和VPD等水分相关的因子对年际NEE的贡献率也高于季节NEE。

参考文献

- 1 Reichstein M, Bahn M, Ciais P, et al. Climate extremes and the carbon cycle. *Nature*, 2013, 500: 287–295
- 2 Roebroek C T J, Duveiller G, Seneviratne S I, et al. Releasing global forests from human management: how much more carbon could be stored? *Science*, 2023, 380: 749–753
- 3 Wehr R, Munger J W, McManus J B, et al. Seasonality of temperate forest photosynthesis and daytime respiration. *Nature*, 2016, 534: 680–683
- 4 Barford C C, Wofsy S C, Goulden M L, et al. Factors controlling long- and short-term sequestration of atmospheric CO₂ in a mid-latitude forest. *Science*, 2001, 294: 1688–1691
- 5 Mahecha M D, Reichstein M, Jung M, et al. Comparing observations and process-based simulations of biosphere-atmosphere exchanges on multiple timescales. *J Geophys Res*, 2010, 115: 2009JG001016
- 6 Piao S, Wang X, Wang K, et al. Interannual variation of terrestrial carbon cycle: issues and perspectives. *Glob Change Biol*, 2020, 26: 300–318
- 7 Wang K, Bastos A, Ciais P, et al. Regional and seasonal partitioning of water and temperature controls on global land carbon uptake variability. *Nat Commun*, 2022, 13: 3469
- 8 Piao S, Niu B, Zhu J, et al. Responses and feedback of the Tibetan Plateau's alpine ecosystem to climate change (in Chinese). *Chin Sci Bull*, 2019, 64: 2842–2855 [朴世龙, 张宪洲, 汪涛, 等. 青藏高原生态系统对气候变化的响应及其反馈. 科学通报, 2019, 64: 2842–2855]
- 9 He H, Li H, Fu Y, et al. Interannual characteristics and driving mechanism of CO₂ fluxes in alpine shrubland ecosystem during growing season at the southern foot of Qilian Mountains (in Chinese). *Chin Sci Bull*, 2022, 67: 173–183 [贺慧丹, 李红琴, 符义稳, 等. 祁连山南麓高寒灌丛生态系统生长季CO₂通量动态年际特征及环境驱动. 科学通报, 2022, 67: 173–183]
- 10 Piao S, Sitch S, Ciais P, et al. Evaluation of terrestrial carbon cycle models for their response to climate variability and to CO₂ trends. *Glob Change Biol*, 2013, 19: 2117–2132
- 11 Li M Q. A study on refined attribution of the interannual variations of global land carbon sink (in Chinese). Master Thesis. Nanjing: Nanjing Normal University, 2022 [李曼青. 陆地生态系统碳汇年际变化的精细化归因研究. 硕士学位论文. 南京: 南京师范大学, 2022]
- 12 Shao J J. The interannual variability of net ecosystem CO₂ exchange and its underlying mechanisms in terrestrial ecosystems (in Chinese). Doctor Dissertation. Shanghai: Fudan University, 2016 [邵钧炯. 陆地生态系统CO₂净交换的年际变异及其机制研究. 博士学位论文. 上海: 复旦大学, 2016]
- 13 Jung M, Schwalm C, Migliavacca M, et al. Scaling carbon fluxes from eddy covariance sites to globe: synthesis and evaluation of the FLUXCOM approach. *Biogeosciences*, 2020, 17: 1343–1365
- 14 Reichstein M, Camps-Valls G, Stevens B, et al. Deep learning and process understanding for data-driven Earth system science. *Nature*, 2019, 566: 195–204
- 15 Tramontana G, Jung M, Schwalm C R, et al. Predicting carbon dioxide and energy fluxes across global FLUXNET sites with regression algorithms. *Biogeosciences*, 2016, 13: 4291–4313
- 16 Tan X X. Research and application of deep learning methods in net ecosystem carbon exchange simulation (in Chinese). Master Thesis. Beijing:

- Beijing Forestry University, 2022 [谭新新. 深度学习方法在净生态系统碳交换量模拟中的研究及应用. 硕士学位论文. 北京: 北京林业大学, 2022]
- 17 Mazumder S, Prasad A. Modeling the variability of terrestrial carbon fluxes using transformers. In: the 25th EGU General Assembly, 2023. Vienna: EGU General Assembly Conference Abstracts, 2023. EGU-582
 - 18 Yu P, Zhou T, Luo H, et al. Global pattern of ecosystem respiration tendencies and its implications on terrestrial carbon sink potential. *Earth's Future*, 2022, 10: e2022EF002703
 - 19 Besnard S, Carvalhais N, Arain M A, et al. Memory effects of climate and vegetation affecting net ecosystem CO₂ fluxes in global forests. *PLoS One*, 2019, 14: e0211510
 - 20 Liu W, He H, Wu X, et al. Importance of the memory effect for assessing interannual variation in net ecosystem exchange. *Agric For Meteor*, 2023, 341: 109691
 - 21 Chen Z Q, Chen J M, Zheng X G, et al. Optimizing photosynthetic and respiratory parameters based on the seasonal variation pattern in regional net ecosystem productivity obtained from atmospheric (in Chinese). *Chin Sci Bull*, 2015, 60: 3397 [陈卓奇, 陈镜明, 郑小谷, 等. 基于大气反演陆地碳通量季节变化信息的模型参数优化研究. 科学通报, 2015, 60: 3397]
 - 22 Xu R, Wang D, Li J, et al. A hybrid deep learning model for air quality prediction based on the time–frequency domain relationship. *Atmosphere*, 2023, 14: 405
 - 23 Rahaman N, Baratin A, Arpit D, et al. On the spectral bias of neural networks. In: proceedings of the 36th International Conference on Machine Learning, 2019. Long Beach: Proc Machine Learn Res, 2019, 97: 5301–5310
 - 24 Dias A G, Leite J, Sánchez-Vega B L, et al. Dynamical symmetry breaking and fermion mass hierarchy in the scale-invariant 3-3-1 model. *Phys Rev D*, 2020, 102: 015021
 - 25 Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Computation*, 1997, 9: 1735–1780
 - 26 Kobayashi K, Salam M U. Comparing simulated and measured values using mean squared deviation and its components. *Agronomy J*, 2000, 92: 345–352
 - 27 Liu Z F, Liu Y C, Hao Y H, et al. Multi-time scale cross-wavelet transformation between runoff and climate factors in the upstream of Heihe River (in Chinese). *Arid Land Geogr*, 2014, 37: 1137–1146 [刘志方, 刘友存, 郝永红, 等. 黑河出山径流过程与气象要素多尺度交叉小波分析. 干旱区地理, 2014, 37: 1137–1146]
 - 28 Chang Y W, Wu Y H, Liu X, et al. Periodic variations of soil moisture in desert steppe based on wavelet analysis (in Chinese). *Chin J Grassl*, 2023, 45: 87–97 [常耀文, 吴一晗, 刘霞, 等. 基于小波分析的荒漠草原土壤湿度周期变化特征. 中国草地学报, 2023, 45: 87–97]
 - 29 Xiong L J, Wang F W, Zhou S J, et al. Global mean sea level change and ONI index multiscale characteristics based on local mean decomposition and cross wavelet (in Chinese). *J Ocean Technol*, 2023, 42: 28–35 [熊璐杰, 王奉伟, 周世健, 等. 基于局部均值分解和交叉小波的全球平均海平面变化与ONI指数多尺度特征研究. 海洋技术学报, 2023, 42: 28–35]
 - 30 Lundberg S M, Lee S I. A unified approach to interpreting model predictions. In: Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017. New York: NIPS'17, 2017. 4768–4777
 - 31 Meng C, Trinh L, Xu N, et al. Interpretability and fairness evaluation of deep learning models on MIMIC-IV dataset. *Sci Rep*, 2022, 12: 7166
 - 32 Wu Y, Pan C, Wang G, et al. Learning semantic-aware knowledge guidance for low-light image enhancement. In: 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver: CVPR, 2023. 1662–1671
 - 33 Han H G, Wang Y S, Liu Z, et al. Knowledge-data-driven cooperative optimal control for wastewater treatment denitrification process (in Chinese). *Acta Automa Sin*, 2024, 50: 1–13 [韩红桂, 王玉爽, 刘峥, 等. 知识和数据驱动的污水处理反硝化脱氮过程协同优化控制. 自动化学报, 2024, 50: 1–13]
 - 34 Cai S, Wang Z, Wang S, et al. Physics-informed neural networks for heat transfer problems. *J Heat Transfer*, 2021, 143: 060801
 - 35 He Q Z, Barajas-Solano D, Tartakovsky G, et al. Physics-informed neural networks for multiphysics data assimilation with application to subsurface transport. *Adv Water Resour*, 2020, 141: 103610
 - 36 Fu L, She L J, Yan D L, et al. Fatigue damage prediction framework of the boom system based on embedded physical information and attention mechanism BiLSTM neural network (in Chinese). *J Mech Eng*, 2024, 60: 205–215 [付玲, 余玲娟, 颜镀镭, 等. 基于内嵌物理信息与注意力机制BiLSTM神经网络的臂架系统疲劳损伤预测模型. 机械工程学报, 2024, 60: 205–215]
 - 37 Guo Q, Fang L, Wang R, et al. Multivariate time series forecasting using multiscale recurrent networks with scale attention and cross-scale guidance. *IEEE Trans Neural Netw Learn Syst*, 2025, 36: 540–554
 - 38 Wang J, Jiang W, Li Z, et al. A new multi-scale sliding window LSTM framework (MSSW-LSTM): a case study for GNSS time-series prediction. *Remote Sens*, 2021, 13: 3328
 - 39 Duan X Y, Fu Y, Wang K, et al. Network traffic anomaly detection method based on multi-scale characteristic (in Chinese). *J Commun*, 2022, 43: 65–76 [段雪源, 付钰, 王坤, 等. 基于多尺度特征的网络流量异常检测方法. 通信学报, 2022, 43: 65–76]
 - 40 Adkinson A C, Syed K H, Flanagan L B. Contrasting responses of growing season ecosystem CO₂ exchange to variation in temperature and water

- table depth in two peatlands in northern Alberta, Canada. *J Geophys Res*, 2011, 116: G01004
- 41 Wofsy S C, Goulden M L, Munger J W, et al. Net exchange of CO₂ in a mid-latitude forest. *Science*, 1993, 260: 1314–1317
- 42 Niu X D, Sun P S, Liu X J, et al. Net ecosystem carbon dioxide exchange in an oak (*Quercus aliena*) forest at transitional zone from subtropics to warm temperate, China (in Chinese). *Acta Ecol Sin*, 2020, 40: 5980–5991 [牛晓栋, 孙鹏森, 刘晓静, 等. 中国亚热带-暖温带过渡区锐齿栎林净生态系统碳交换特征. 生态学报, 2020, 40: 5980–5991]
- 43 Wang J Y, Li G D, Ren X J, et al. Carbon flux characteristics and responses to environmental factors in the evergreen-deciduous broadleaf mixed forest of the North-South transitional zone (in Chinese). *Acta Ecol Sin*, 2024, 44: 6243–6253 [王靖钰, 李国栋, 任晓娟, 等. 南北过渡带常绿落叶阔叶混交林碳通量特征及其对环境因子的响应. 生态学报, 2024, 44: 6243–6253]
- 44 Zhang T, Xu X, Jiang H, et al. Wind mediates the responses of net ecosystem carbon balance to climatic change in a temperate semiarid steppe of Northern China. *Environ Res Lett*, 2023, 18: 075007
- 45 Jung M, Reichstein M, Schwalm C R, et al. Compensatory water effects link yearly global land CO₂ sink changes to temperature. *Nature*, 2017, 541: 516–520
- 46 Humphrey V, Zscheischler J, Ciais P, et al. Sensitivity of atmospheric CO₂ growth rate to observed changes in terrestrial water storage. *Nature*, 2018, 560: 628–631
- 47 Humphrey V, Berg A, Ciais P, et al. Soil moisture–atmosphere feedback dominates land carbon uptake variability. *Nature*, 2021, 592: 65–69

补充材料

附录S1 奇异谱分析方法(SSA)计算过程

附录S2 LSTM模型超参数

附录S3 交叉小波变换(cross wavelet transform, XWT)计算过程

附录S4 SHAP值计算过程

表S1 增加NEE长期趋势对模拟性能的影响

图S1 典型站点FR-Gri通量站(CRO)上, NEE及气象变量的观测值、季节分量、年际分量和长期趋势

图S2 典型站点FR-LBr通量站(ENF + EBF)上, NEE及气象变量的观测值、季节分量、年际分量和长期趋势

图S3 FR-Gri通量站NEE分量的小波功率谱

图S4 跨尺度实验结果

图S5 基于生态系统和生长期的气象因子重要性

图S6 在典型FR-Gri通量站(CRO)上对比“单一模型/端到端”框架和“频率知识引导”框架模拟结果的差异

图S7 对比年尺度上不同生态系统站点模拟年际NEE和观测差异

本文以上补充材料见网络版csb.scichina.com. 补充材料为作者提供的原始数据, 作者对其学术质量和内容负责.

Summary for “尺度知识引导的深度学习生态系统碳汇模拟”

Scale knowledge guided deep learning for simulating ecosystem carbon fluxes

Yongjie Zhou^{1,2†}, Hao Jiang^{3†}, Xing Chen^{1,2*} & Xuhui Wang^{3*}

¹ College of Computer and Data Science, Fuzhou University, Fuzhou 350108, China

² Fujian Provincial Key Laboratory of Networking Computing and Intelligent Processing, Fuzhou University, Fuzhou 350108, China

³ College of Urban and Environmental Sciences, Peking University, Beijing 100871, China

† Equally contributed to this work

* Corresponding authors, E-mail: xuhui.wang@pku.edu.cn; chenxing@fzu.edu.cn

Deep learning methods have increasingly been applied to simulate carbon fluxes in terrestrial ecosystems, owing to their superior fitting capabilities for complex systems. However, widely used “end-to-end” modeling frameworks, while effective at capturing seasonal variations in net ecosystem carbon exchange (NEE), tend to underestimate the magnitudes of interannual variability. This limitation may stem from spectral bias during the training process, as these models primarily rely on raw observational signals and tend to prioritize smoother temporal components of the time series data. To improve the accuracy of deep learning models for estimating ecosystem carbon fluxes, this study aims to clarify how the modeling frameworks contribute to uncertainties in carbon flux modeling.

This study introduces a novel “knowledge-guided” modeling framework that leverages prior knowledge about the memory effects of ecosystems and the distinct responses of NEE at seasonal and interannual scales. By integrating nonparametric Singular Spectrum Analysis (SSA), this framework facilitates the temporal decomposition of seasonal and interannual signals, thereby guiding the modeling of unique NEE responses across timescales. The recurrent neural network Long Short-Term Memory (LSTM) is employed to capture the cumulative impacts of climate change and accurately represent state changes within the ecosystem. Utilizing observational data from FLUXNET sites, the study conducts validations across various ecosystems. Performance assessments demonstrate that the implemented LSTM model effectively captures the nonlinear responses of NEE to meteorological factors, outperforming baseline models, including LASSO regression, Random Forest, Support Vector Machines, and Feedforward Neural Networks. Simulations based on historical climate conditions also reveal that the “end-to-end” LSTM model overlooks NEE responses at the interannual scale, while the “knowledge-guided” models better reproduce both seasonal and interannual variations. According to SHAP (SHapley Additive exPlanations) values derived from these models, radiation and temperature are identified as the driving factors for both the “end-to-end” LSTM and seasonal LSTM models. Therefore, the “end-to-end” deep learning framework is predominantly driven by seasonal processes, while the “knowledge-guided” models improve the representation of scale-specific patterns under the guidance of scale knowledge.

The distinct mechanisms of NEE response across scales can be further elucidated through the “knowledge-guided” models. Cross-scale experiments and wavelet analyses reveal significant differences in the NEE response patterns captured by seasonal versus interannual LSTM models. Using a seasonal model to simulate interannual variations or an interannual model for seasonal changes leads to inaccuracies in signal properties such as amplitude, resonance periods, and phase, ultimately resulting in degraded performance. According to SHAP values derived from “knowledge-guided” models, radiation and temperature are identified as primary drivers of seasonal NEE changes, accounting for 46.9% and 24.5% of seasonal variation, respectively. At the interannual scale, temperature emerges as the most influential factor, contributing 24.5% to changes, while the contribution of radiation decreases to 21.1%. Additionally, the contributions of precipitation, vapor pressure deficit (VPD), and wind speed all exceed 15%. Factorial simulations conducted with the trained “knowledge-guided” models reveal the synergistic effects of rising temperature and radiation on seasonal NEE, while the interactions at the interannual scale prove to be more complex. These findings underscore the importance of integrating prior knowledge into deep learning models to mitigate uncertainties and enhance interpretability. Overall, this study optimizes the modeling framework of deep learning models to enhance their fitting capabilities for NEE responses at different timescales, providing effective numerical simulation methods and analytical tools for assessing the impact of climate change on the terrestrial carbon cycle.

net ecosystem exchange, interannual variability, seasonal dynamics, deep learning, climate change, global terrestrial ecosystems

doi: [10.1360/TB-2024-0639](https://doi.org/10.1360/TB-2024-0639)