北京林业大学学报
JOURNAL OF BEIJING FORESTRY UNIVERSITY

MS-HyTimeXer：一种融合多尺度时序特征的树干液流预测模型

齐建东 郭忻怡 周梦颖 刘鹏 查天山

MS-HyTimeXer: a stem sap flow prediction model integrating multi-scale temporal features

Qi Jiandong, Guo Xinyi, Zhou Mengying, Liu Peng, Zha Tianshan

引用本文:
齐建东, 郭忻怡, 周梦颖, 刘鹏, 查天山. MS-HyTimeXer：一种融合多尺度时序特征的树干液流预测模型[J]. 北京林业大学学报, 2026, 48(7):139-153. doi: 10.12171/j.1000-1522.20260019
Qi Jiandong, Guo Xinyi, Zhou Mengying, Liu Peng, Zha Tianshan. MS-HyTimeXer: a stem sap flow prediction model integrating multi-scale temporal features[J]. Journal of Beijing Forestry University, 2026, 48(7):139-153. doi: 10.12171/j.1000-1522.20260019

在线阅读 View online: https://doi.org/10.12171/j.1000-1522.20260019

您可能感兴趣的其他文章
Articles you may be interested in

基于深度学习和上采样的杉木单木枯损模型构建
High-precision individual tree mortality prediction for Chinese fir using deep learning and oversampling
北京林业大学学报, 2025, 47(12): 39-47. https://doi.org/10.12171/j.1000-1522.20250103

面向钻蛀振动实时侦听的深度学习模型压缩
Deep learning model compression for real-time listening of boring vibration
北京林业大学学报, 2021, 43(6): 92-100. https://doi.org/10.12171/j.1000-1522.20200100

深度学习在林木全基因组选择中的应用与挑战：从高维特征到多目标优化
Deep learning for genomic selection in forest trees: applications and challenges from high-dimensional features to multi-objective optimization
北京林业大学学报, 2026, 48(6): 9-20. https://doi.org/10.12171/j.1000-1522.20260208

基于级联循环网络的林木生长参数预测
Prediction of tree growth parameters based on cascaded recurrent network
北京林业大学学报, 2023, 45(8): 94-108. https://doi.org/10.12171/j.1000-1522.20230027

坝上地区退化小叶杨树干液流特征及对环境因子的响应
Characteristics of sap flow of degraded *Populus simonii* in Bashang Area, Hebei Province of northern China and its response to environmental factors
北京林业大学学报, 2024, 46(7): 36-43. https://doi.org/10.12171/j.1000-1522.20230332

干旱胁迫下环境与生理因子对晋西黄土区刺槐人工林树干液流的影响
Impact of environmental and physiological factors during drought stress on sap flow in *Robinia pseudoacacia* plantations in the loess region of western Shanxi Province of northern China
北京林业大学学报, 2024, 46(4): 127-140. https://doi.org/10.12171/j.1000-1522.20230209

DOI:10.12171/j.1000−1522.20260019

MS-HyTimeXer: 一种融合多尺度时序特征的树干液流预测模型

齐建东[1]　郭忻怡[1]　周梦颖[1]　刘　鹏[2]　查天山[2]
（1. 北京林业大学信息学院，北京 100083；2. 北京林业大学水土保持学院，北京 100083）

摘要:【目的】树干液流是量化植物蒸腾过程和评估生态系统水分利用效率的重要指标，其变化受到环境因子、生理调控以及时间滞后效应的共同影响，传统预测方法难以有效刻画复杂非线性关系和中长期动态变化。针对现有时间序列预测模型在多尺度特征提取和植物水分传输滞后响应建模方面的不足，本文提出一种基于多尺度混合 Transformer 的树干液流中长期预测模型 MS-HyTimeXer。**【方法】**基于 SAPFLUXNET 数据库中加拿大东部白松树干液流观测数据，选取 2010 年 1 月 1 日至 2011 年 12 月 31 日期间 30 min 尺度连续观测数据，共 35 040 组样本开展实验。以 TimeXer 模型为基础，引入多尺度分块嵌入、LSTM 时序校准和多尺度卷积 3 个关键模块。其中，多尺度分块嵌入用于增强不同时间尺度特征表达能力，LSTM 时序校准用于捕获环境变化与树干液流响应之间的时间滞后关系，多尺度卷积用于提取局部突变和短时动态特征。选取 DLinear、Informer、PatchTST、iTransformer 和 TimeXer 5 种模型作为对比方法，对不同模型的预测性能进行评价。**【结果】**实验结果表明，MS-HyTimeXer 模型能够有效融合多尺度时间特征和环境因子信息，在树干液流中长期预测任务中取得最优性能。与基准 TimeXer 模型相比，MS-HyTimeXer 的均方误差（MSE）由 0.765 $cm^3/(cm^2·h)$ 降低至 0.312 $cm^3/(cm^2·h)$，降低 59.74%；决定系数（R^2）由 0.869 提高至 0.918；平均绝对百分比误差（MAPE）降低至 7.652%。在 6 种深度学习模型中，MS-HyTimeXer 获得最低的 MSE、MAE 和 MAPE，表现出更高的预测精度和稳定性。进一步分析表明，预测窗口长度为 512 时，该模型在中长期预测任务中仍保持较优性能。**【结论】**MS-HyTimeXer 通过融合多尺度时序表示、长期依赖建模和局部动态特征提取机制，有效提升了复杂生态环境条件下树干液流预测能力，为植被蒸腾估算、森林水资源管理以及生态系统智能监测提供了一种新的技术方法。

关键词：蒸腾；树干液流；Transformer；深度学习；多尺度特征融合；时间序列预测
中图分类号：S718.5；TP181　　**文献标志码：**A　　**文章编号：**1000−1522(2026)07−0139−15
引文格式：齐建东，郭忻怡，周梦颖，等. MS-HyTimeXer：一种融合多尺度时序特征的树干液流预测模型［J］. 北京林业大学学报，2026，48(7)：139−153. Qi Jiandong, Guo Xinyi, Zhou Mengying, et al. MS-HyTimeXer: a stem sap flow prediction model integrating multi-scale temporal features［J］. Journal of Beijing Forestry University, 2026, 48(7): 139−153.

MS-HyTimeXer: a stem sap flow prediction model integrating multi-scale temporal features

Qi Jiandong[1]　Guo Xinyi[1]　Zhou Mengying[1]　Liu Peng[2]　Zha Tianshan[2]
(1. School of Information, Beijing Forestry University, Beijing 100083, China;
2. School of Soil and Water Conservation, Beijing Forestry University, Beijing 100083, China)

Abstract:［**Objective**］Stem sap flow is a key indicator for quantifying plant transpiration and evaluating ecosystem water use efficiency. Its dynamics are jointly influenced by environmental factors, physiological regulation, and time-lag effects, making it difficult for conventional prediction methods to effectively characterize complex nonlinear relationships and medium- to long-term variations. To address the limitations

收稿日期: 2026−01−16　**修回日期:** 2026−05−08
基金项目: 国家自然科学基金项目（32071842），国家重点研发计划（2022YFD2200304）。
第一作者: 齐建东，博士，教授。主要研究方向：生态信息学、智能信息处理。Email: qijd@bjfu.edu.cn　地址：100083 北京市海淀区清华东路 35 号北京林业大学信息学院。
本刊网址: https://j.bjfu.edu.cn; https://journal.bjfu.edu.cn

of existing time series forecasting models in multi-scale feature extraction and modeling the lagged response of plant water transport, this paper proposes MS-HyTimeXer, a medium- to long-term stem sap flow prediction model based on a multi-scale hybrid Transformer. [**Method**] Based on stem sap flow observations of *Pinus strobus* in eastern Canada from the SAPFLUXNET database, continuous 30 min interval data from January 1, 2010 to December 31, 2011 were selected, yielding a total of 35 040 samples for the experiments. Built upon the TimeXer model, three key modules were introduced: multi-scale patch embedding, LSTM temporal calibration, and multi-scale convolution. Multi-scale patch embedding enhances the representation of features across different temporal scales; LSTM temporal calibration captures the time-lag relationship between environmental changes and sap flow response; and multi-scale convolution extracts local abrupt changes and short-term dynamic features. Five models, including DLinear, Informer, PatchTST, iTransformer and TimeXer, were chosen as baseline methods to evaluate the prediction performance of different models. [**Result**] Experimental results demonstrated that MS-HyTimeXer effectively integrated multi-scale temporal features and environmental factor information, achieving optimal performance in medium- to long-term stem sap flow prediction. Compared with the baseline TimeXer model, the mean squared error (MSE) of MS-HyTimeXer decreased from 0.765 $cm^3/(cm^2 \cdot h)$ to 0.312 $cm^3/(cm^2 \cdot h)$, a reduction of 59.74%; the coefficient of determination (R^2) increased from 0.869 to 0.918; and the mean absolute percentage error (MAPE) dropped to 7.652%. Among the six deep learning models, MS-HyTimeXer attained the lowest MSE, MAE, and MAPE, exhibiting superior prediction accuracy and stability. Further analysis revealed that the model still maintains competitive performance in medium- to long-term prediction tasks when the prediction window length reached 512. [**Conclusion**] By integrating multi-scale temporal representation, long-term dependency modeling, and local dynamic feature extraction mechanisms, MS-HyTimeXer effectively improves stem sap flow prediction capability under complex eco-environmental conditions, offering a new technical approach for plant transpiration estimation, forest water resource management, and intelligent ecosystem monitoring.

Key words: transpiration; stem sap flow; Transformer; deep learning; multi-scale feature fusion; time series forecasting

水资源是支撑人类社会生产生活与自然生态系统可持续发展的核心要素，针对陆地水循环过程的研究工作始终是重点和热点。作为陆地水循环的重要组成部分，全球蒸散发年通量可达 6.5 万～7.5 万 km^3[1]，其中植物蒸腾作为陆生植被水分耗散的主要形式，约占陆地蒸散发总量的 80%～90%[2]，是构成陆地最大水分通量之一。

蒸腾作用受气象、土壤及植物生理等多因子共同调控，各因素间存在非线性关系，难以通过精确计算得出[3]。树干液流作为植物在蒸腾作用驱动下经茎干横截面输送水分的现象，可反映约 90% 的蒸腾量，被广泛视为植物蒸腾量的表征指标，同时树干液流也是土壤–植物–大气连续体中的关键环节，其动态变化直接体现植物体内水分运输状况[4]。通过测量树干液流可精确估算树木蒸腾量，为评估区域植被的蒸腾水平、理解水资源管理在陆地生态系统中的循环与利用效率提供了重要依据[5]。因此准确预测树干液流对于评估树木蒸腾量和区域植被水分消耗具有重要意义，尤其是在水资源管理、城市森林建设及其智能管理等生态功能领域[6]。

树干液流测量的传统方法包括染料法、同位素示踪法、重量法、磁流体力学法、快速称重法和热技术等[7−8]。其中，由 Granier [9]开发的热耗散探头（thermal dissipation probes，TDP）是目前广泛采用的热技术方法，即通过插入树干测量上下探头之间的电压来估算树干液流流速，因其结构简单，易于部署，得到了广泛的应用。Burgess 等[10]在 2001 年提出的热比率法（heat ratio method，HRM），通过精确测量热脉冲后的温度比率，不仅提升了测量精度，还成功解决了低流速乃至夜间反向流的测量难题，扩展了热脉冲技术的应用范围。然而传统的直接测量方法，虽具有明确物理机制，但普遍存在操作复杂、成本高昂等局限[11]，且数据预处理和校准步骤繁琐[12]，难以应对大尺度、中长时序的生态系统监测需求。

为克服传统测量手段在空间尺度和时间序列上监测的局限性，更好地挖掘树干液流与环境因子之间的非线性关系，研究焦点开始转向基于数据驱动的预测模型。人工智能算法快速发展，其在处理大

量复杂数据和进行精确模拟方面展现出优势[13]，给树干液流预测研究带来了新的发展。通过整合气象观测、地面观测数据等多源数据，结合机器学习和深度学习等技术进行大数据分析，挖掘环境变量与树干液流的非线性关系，实现树干液流预测，展现出更强的空间适应性和计算效率。在应用机器学习方法预测树干液流的研究中，2019 年，Tu 等[14]采用反向传播神经网络（back propagation neural network，BPNN）预测树干液流，并引入时间滞后因子，预测精度显著优于线性模型。2021 年，Junior 等[15]使用线性回归模型实现了对幼龄可可树的树干液流的精准预测。2023 年，Nalevanková等[16]对欧洲山毛榉（*Fagus sylvatica*）的树干液流建模技术进行了比较评估，使用了线性模型（linear model，LM）、随机森林（random forest，RF）、极限梯度提升机（extreme gradient boosting machine，XGBM）和神经网络（neural network，NN）4 种方法，研究[17]发现，在特定条件下 LM 对山毛榉树的整体树干液流预测能力最优。Liu 等[18]在超干旱地区中，利用随机森林模型和未来气候数据，分析了红枣（*Ziziphus jujuba*）和核桃（*Juglans regia*）2 种经济作物的树干液流变化特征及其与太阳辐射、温度、相对湿度和水汽压差四个环境因素的关系。

近些年，深度学习快速发展，研究人员已广泛利用深度学习模型来提高预测精度和效率。2022 年，Li 等[19]提出了 CGRU（convolutional gated recurrent unit）混合深度学习方法，针对单步预测场景（预测窗口为 1）预测新西兰贝壳杉（*Agathis australis*）的树干液流，并与多种模型进行比较，显示 CGRU 具有更高的准确性。随后 Li 等[20]基于上述研究结果，又提出一个改进的时间序列预测模型，该模型结合了卷积神经网络（convolutional neural network，CNN）、门控循环单元（gated recurrent unit，GRU）和双向长短期记忆网络（bidirectional long short term memory，BiLSTM），在同样的单步预测情况下，结合因子分析法对环境变量进行降维处理，结果表明 CNN-GRU-BiLSTM 模型优于其他对比模型。与此同时，Zhang 等[21]利用 K 邻近算法（k-nearest neighbors，KNN）、RF、BPNN 和 LSTM，以上海城市绿地的白玉兰（*Michelia* × *alba*）为研究对象，成功实现了树干液流的间接测量，其中 LSTM 模型在预测树干液流速度方面表现出更高的可靠性。2025 年，Li 等[22]对 PatchMixer 进行了改进，设计深度学习模型 Patch-TS，在长期预测任务中具有较强的鲁棒性。2025 年，Wang 等[23]开发了 SAPFLOWER 工具，该工具集成了多种机器学习和深度学习模型，旨在自动化树干液流数据预处理、模型训练、数据填充和分析。

树干液流作为森林生态系统土壤−植被−大气连续体水分传输的核心生理过程，本身具有较强的时序依赖性、非线性以及滞后效应。现有研究证实[24]，机器学习和深度学习在树干液流预测中能够拟合环境因子与树干液流变化之间的复杂非线性关系[25]，在小时尺度上的树干液流预测上取得了较大进展[17]，但当前存在以下关键问题亟待解决：一是由于缺乏对动态时序的有效建模，现有模型在中长期预测中表现不佳，进行连续多步预测时，预测误差会迅速积累；二是模型对多尺度时间模式的感知能力不足，现有模型通常以单一固定的时间尺度处理序列数据，难以全面捕捉树干液流数据中蕴含的多尺度动态模式，导致特征表征不完整，预测精度低。

本研究聚焦于树干液流中长期预测任务，在温带大陆性湿润气候背景下，通过时间序列深度学习模型分析树木生理响应中的全局规律与局部瞬时脉冲特征，旨在为植被蒸腾量的精确估算及区域水资源管理提供更优的技术支持。针对树干液流数据所呈现的非线性和滞后效应，本文提出了一种名为 Multi-Scale Hybrid TimeXer（MS-HyTimexer）的模型，在输入层采用多尺度分块嵌入策略，将原始时间序列分解为不同时间粒度的特征表示，从而全面捕捉树干液流的日内高频波动变化和昼夜规律。模型的主体结构融合了 Transformer 编码器与 LSTM 网络：Transformer 部分负责提取时间序列中环境因子的长期趋势；LSTM 时序校准层进一步拟合植物水分传输中的物理滞后、全局依赖和生理机制。通过内置的注意力机制与自适应门控单元，模型能够动态整合全局信息，实现二者优势互补。为增强对复杂时间模式的局部特征提取能力，在模型末端加入多尺度卷积层，强化对脉冲式水文事件引发的局部突变特征的提取能力。通过多尺度输入设计、全局与局部信息的高效融合，MS-HyTimexer 能够更准确地模拟树干液流变化的内在机制，采用 192（96 h）的预测步长，为中长期、高精度的树干液流预测任务提供了一种新的有效方法。

1　研究方法

1.1　数据源

本研究使用的数据来自 SAPFLUXNET[26]。SAPFLUXNET 收录了 202 个分布于全球的植物树干液流数据集，提供了 174 种、2 714 株植物的树干液流数据以及多种气象因子数据，数据来源覆盖多种生态气候带，旨在推动对植物蒸腾生态学的研究，本文使用的是该数据库的最新稳定版本（0.1.5 版本）。

选取的数据集站点位于加拿大南安大略省（42°42′36″N，80°21′36″W），海拔约 184 m，该观测站点地势平坦，土壤以排水良好的砂壤土为主，监测树种为东部白松（*Pinus strobus*），树龄为 71 ~ 72 年。在树干液流的测定方法上，该站点采用 TDP 进行连续监测，原数据集包含从 2009 年 1 月 1 日到 2017 年 1 月 1 日共 140 254 条树干液流数据。原始数据集中树干液流和环境因子数据普遍存在因天气突变、传感器故障等原因引起的缺失和异常数据，未做数据插补、异常值处理，因此本文选取了数据质量相对稳定且连续性相对较好的 2010—2011 年的数据，时间间隔为半小时，共计 35 040 条观测数据。数据集还包含 9 项环境参数：温度（T_a）、饱和水汽压差（VPD）、风速（WS）、光合光子通量密度（PPFD）、深层土壤含水量（SWC_deep）、浅层土壤含水量（SWC_shallow）、短波入射辐射（SW）、相对湿度（RH）和大气外辐射（Ext_Rad）。例如 2010 年的树干液流和各环境因子变化趋势如图 1、2 所示。

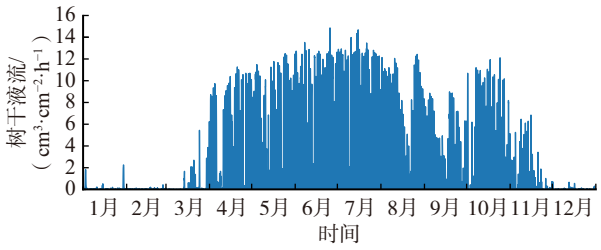


图 1 树干液流数据

Fig. 1 Stem sap flow data

1.2 数据处理

为保证选取出的树干液流和环境因子数据的可靠性和完整性，本文预处理操作基于训练集完成，采用了样条插值与三倍标准差结合[27]的方法对原始数据进行异常值处理和插补。树干液流存在降雨响应、昼夜波动等生态特征，本研究未直接剔除极端值，仅将由传感器故障等非生态因素导致的明显偏离正常波动范围的值判定为异常。使用三倍标准差法（3σ）辅助进行异常值检测，超出区间 $[\mu-3\sigma, \mu+3\sigma]$（$\mu$ 为均值，σ 为标准差）的数据均视为异常值，并将其标记为空值，并结合液流昼夜规律与环境因子协同变化规律进行人工核对。使用样条插补法填充空缺值，样条插值是一种基于分段多项式的插值方法，将时间序列按照时间顺序划分为多个小区间，每个区间用一个低次多项式（本文为 3 次）进行拟合，保留时序连续性与波动趋势。最终共插补原始空缺值 1 967 条（包含 9 个环境因子与树干液流数据），并处理异常值 2 768 条。

不同的环境因子的数据范围可能差异大，这会导致模型重点关注数值大的特征，忽略数值小的特征，造成实验结果不准确，本研究采用最大最小归一化（min-max normalization）的方法将所有数据映射到 [0,1] 之间，消除数据量级差距过大造成的影响，提高模型的收敛速度和预测精度，具体的公式如下：

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \tag{1}$$

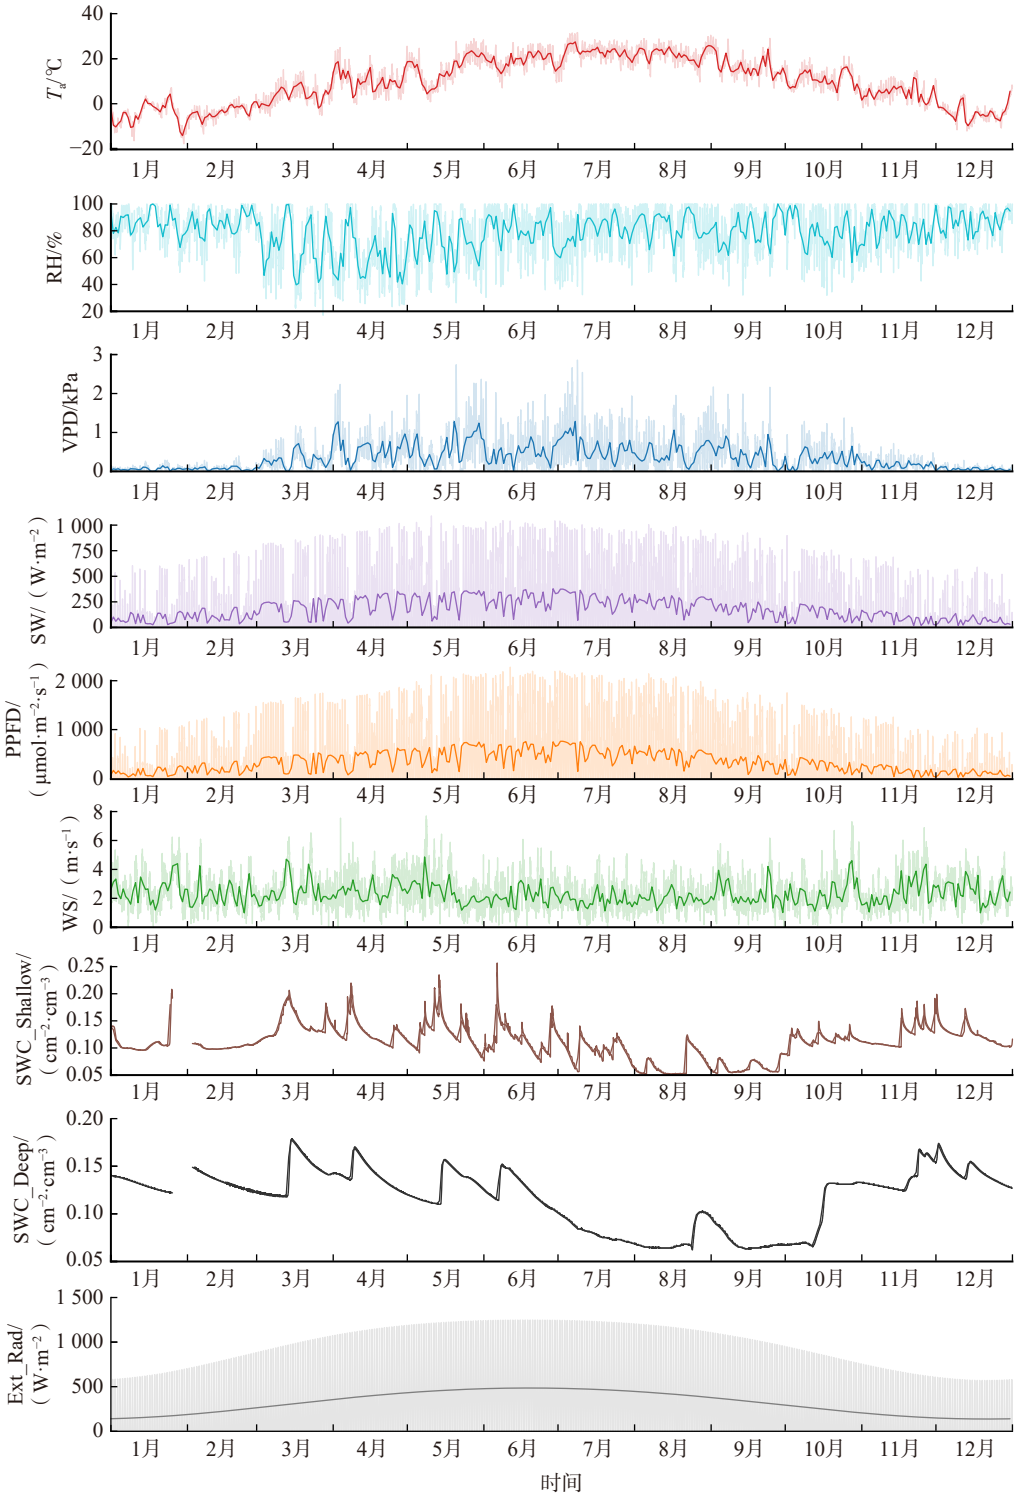
式中 X'表示归一化后的值，X 为原始数据，$X_{\min}$ 和 $X_{\max}$ 分别表示原始数据中的最小值和最大值。

1.3 预测方法

在树干液流预测研究中，传统的水文模型[7−8]在处理多维气象因子与树干液流之间复杂的非线性关系时能力有限，难以充分挖掘时间序列数据中蕴含的动态规律，尽管现有的深度学习模型，特别是基于 Transformer 的架构，在捕捉时间序列的长期依赖性方面具有显著优势，但它们通常采用单一分块来分析序列，这使得模型难以捕捉到多尺度动态特征，此外注意力机制多针对全局相关性或局部相关性，而树干液流序列往往同时包含瞬时响应和缓慢变化，现有模型难以同时兼顾这两种特性。为克服单一尺度感知局限性，并增强模型对局部精细特征的提取能力，更好地捕捉树干液流数据与环境因子之间的复杂非线性关系，本文提出了 MS-HyTimexer（Multi-Scale Hybrid TimeXer）模型。

MS-HyTimeXer 模型如图 3 所示，它是基于 TimeXer 网络模型[28]架构，针对其在处理复杂时间序列单一分块尺度和特征提取能力的局限性，通过引入多尺度分块嵌入（multi-scale patch embedding）、LSTM 时序校准（LSTM timing calibration）和多尺度卷积（multi-scale convolution）3 个核心模块进行了架构改进，以便更全面地捕捉多变量时间序列中的复杂模式和动态特征。

在时间序列分析中，分块（patching）通过将一维时间序列映射为 token 序列，有助于模型捕捉序列的局部信息，并降低自注意力机制的计算复杂度。树干液流表现出较强的昼夜周期规律，如夜间微弱、午间达到峰值等特征。传统的基于 Transformer 的模型（包括 TimeXer）多采用单一且固定的分块长度，导致模型在不同时间尺度上动态模式感知受限，难以兼顾短期高频的生理响应与长期低频趋势。为克服这一局限，MS-HyTimeXer 模型引入了多尺度分块嵌入机制，并行采用一组不同长度（patch_len = 8、patch_len = 16、patch_len = 24）的分块对输入序列进行划分，用于精准捕捉高频的瞬时生理响应、突变特征和昼夜周期性规律，并为每个尺度配置独立的线性嵌入层，从而在统一框架下融合多尺度时序信息，



T_a：温度，RH：相对湿度，VPD：饱和水汽压差，SW：短波入射辐射，PPFD：光合光子通量密度，WS：风速，SWC_Shallow：浅层土壤含水量，SWC_Deep：深层土壤含水量，Ext_Rad：大气外辐射。图中每个子图中浅色线代表原始每半小时数据，深色线代表日均值。

图 2　环境因子数据

Fig. 2　Environmental factor data

得到表征式(2)。

$$Z = \mathrm{Concat}(Z_1, Z_2, \cdots, Z_k) \in \mathbb{R}^{(\sum_{i=1}^{k} N_i) \times d} \tag{2}$$

式中：$Z_i(i = 1, 2, \cdots, k)$表示第 i 个时间尺度对应的 Patch 表征，Concat 表示沿序列维度的拼接操作，N_i 表示第 i 个尺度生成的 Patch 数量，d 为嵌入维度，k 为多尺度数量。

TimeXer 模型利用自注意力机制能够并行地捕捉序列中的全局长距离依赖，但其固有的置换性会削弱对时间序列严格的、连续的顺序信息感知，编码器输出的特征表示对相邻时间之间的约束较弱，可能呈现出离散的特征状态。相比之下，LSTM 作为一

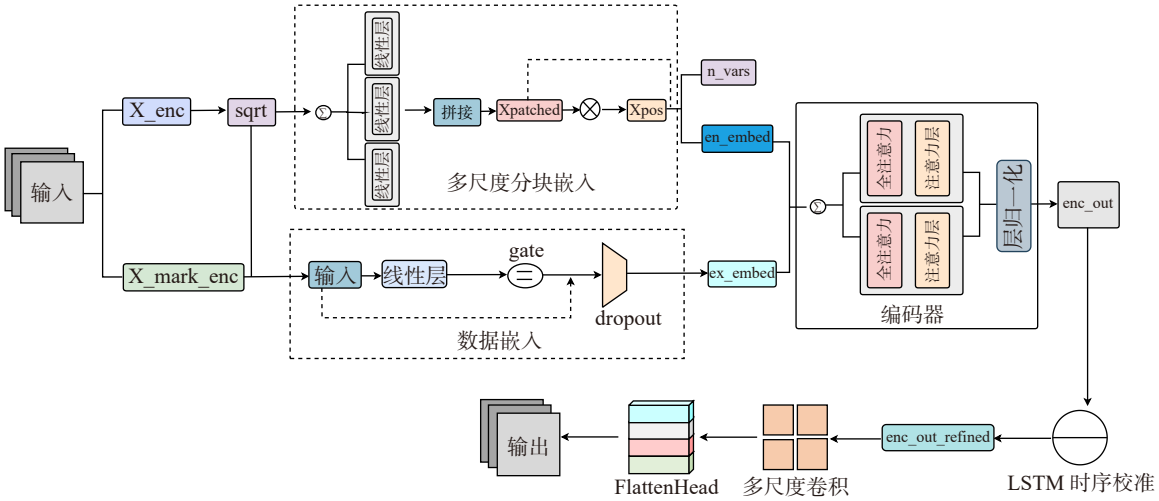


图 3 MS-HyTimeXer 模型图

Fig. 3 MS-HyTimeXer model diagram

种循环神经网络，专门用于缓解传统 RNN 在长序列处理中面临的梯度消失和爆炸问题，它通过输入门、遗忘门与输出门对信息进行选择性写入、保留与读出，从而长期维护关键信息，有效捕捉长时序依赖关系以及序列的连续模式。在植物水分传输的物理过程中，在蒸腾初期由植物内部提供水分，导致树干液流变化晚于冠层的蒸腾需求，形成滞后性。为更好地捕捉序列的时间演化规律，在 MS-HyTimeXer 模型中，设计了一个 LSTM 时序校准模块，该模块如图 4 所示，将其置于 TimeXer 编码器后，该模块在编码器的嵌入空间(d_model = 256)中操作，接收经过多尺度分块嵌入和注意力机制处理后的高维特征表示，通过 LSTM 顺序校准、深度特征融合、自适应调整权重 3 个阶段，对编码器输出的特征表示进行提炼和增强。利用 LSTM 的顺序处理能力，增强特征表示在时间维度上的连续性约束，较精准捕捉环境变量与液流响应之间的时滞性，进一步捕捉特征表示在时间维度上细微的、连续的动态变化，实现对时序变化特征的准确提炼。为进一步实现 TimeXer 全局特征表示与 LSTM 时序增强特征表示的有效融合，该模块内部设计了自适应注意力融合机制，并结合了多头注意力(multi-head attention)机制，多头注意力通过并行计算多个独立的自注意力，并将结果进行拼接，提高模型的表示能力。

核心计算公式如下

$$F_{\text{fused}} = \phi([F_{\text{lstm}}; F_{\text{attn}}]) \tag{3}$$

$$H_{\text{enhance}} = \lambda \odot H_{\text{enc}} + (1-\lambda) \odot F_{\text{fused}} \tag{4}$$

$$\lambda = \sigma(W_\lambda F_{\text{fused}} + b_\lambda) \tag{5}$$

式中：F_{attn} 是以 F_{lstm} 为查询、H_{enc} 为键和值的多头注意力(MHA)输出，F_{lstm} 是 LSTM 对编码器输出进行增强后的表示，F_{fused} 是融合了 LSTM 信息和注意力重采样的特征表示，H_{enc} 是 TimeXer 编码器的输出特征表示，λ 是一个由模型学习产生的自适应权重门，其值介于 0 和 1 之间，H_{enhance} 是增强后的特征表示，σ 是 sigmoid 激活函数，W_λ 和 b_λ 是门控单元的权重

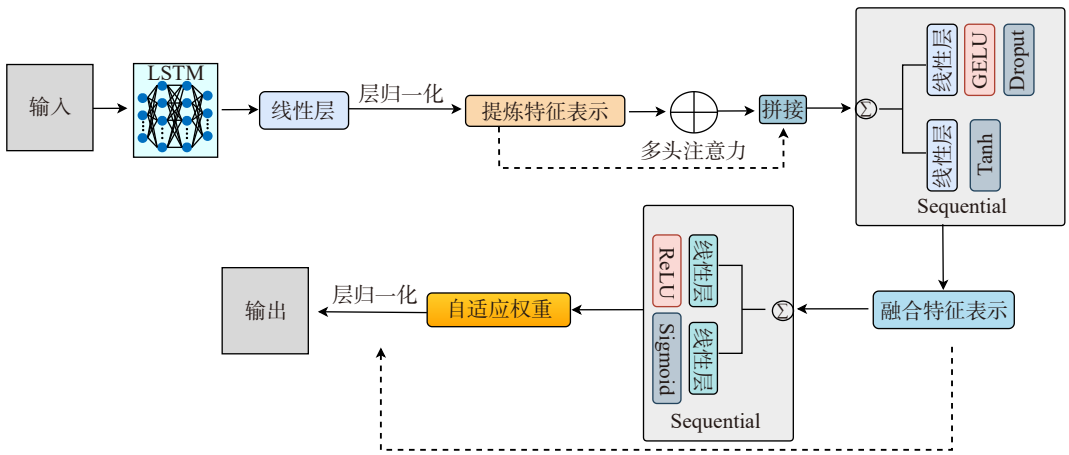


图 4 LSTM 时序校准层模块图

Fig. 4 Module diagram of LSTM timing calibration layer

和偏置。

为提高模型对多粒度局部模式的表征能力，在 LSTM 时序校准模块后，进一步引入多尺度卷积模块。白松的树干液流不仅包含稳定的日间蒸腾，还会受骤雨等瞬时气象突变引发的生理响应。为拟合这种复杂的动态过程，并行地使用一组大小各异的卷积核对 LSTM 时序校准模块输出的特征表示序列进行卷积操作。其中小尺寸卷积核专注于捕捉序列中尖锐、高频的瞬时变化，反映了植物面对突发性气象变化时快速的气孔开闭；大尺寸卷积核则能够覆盖更长的时间跨度，用于提取更为平滑、持续时间更长的趋势性模式，反映植物的水分响应。该模块将输入的特征表示序列并行送入多个独立的卷积分支，每个分支包含一个一维卷积层（conv1d）、批归一化（batchnorm）和激活函数（gelu），各分支提取的特征表示在通道维度上被拼接起来，形成一个包含丰富多尺度局部信息的特征表示，随后一个轻量级的融合网络负责对拼接后的特征表示进行信息交互与整合。为确保特征提取过程的稳定性，并允许模型自适应地选择性使用卷积特征，采用了一个门控残差连接（gated residual connection），通过一个由输入特征表示和卷积输出共同决定的门控权重，动态地将卷积模块输出特征表示与门控单元输入特征表示进行加权融合，增强模型的表达能力和鲁棒性。

该模块核心计算公式如下。

$$F_{\text{fused}} = \phi_{\text{conv}}(F_{\text{concat}}) \tag{6}$$

$$\gamma = \sigma\left(W_{\gamma}[H_{\text{enhance}}; F_{\text{fused}}] + b_{\gamma}\right) \tag{7}$$

$$H_{\text{out}} = \gamma \odot F_{\text{fused}} + (1-\gamma) \odot H_{\text{enhance}} \tag{8}$$

式中：F_{concat} 是在通道维度拼接后的多尺度特征表示，ϕ_{conv} 是用于特征融合的 MLP 网络，γ 是门控单元计算出的自适应融合权重，W_{γ}、b_{γ} 是门控单元的可学习参数，H_{out} 是该模型最终输出的、融合了多尺度局部信息的特征表示。

1.4　基准预测方法

为验证 multi-scale hybrid TimeXer 模型在数据集上的预测效果，选用了 5 种预测模型作为基准预测方法，其中包括了在时间序列数据预测较新、效果较好的研究成果 TimeXer、iTransformer[29]、PatchTST[30]、Informer[31]和 DLinear[32]。

1.4.1　TimeXer 模型

TimeXer 模型是一种基于 Transformer 的、用于时间序列预测的模型，其核心设计在于有效融合外生变量，采用独特的编码器结构，包含一个自注意力模块和一个交叉注意力模块，使得 TimeXer 能够更好地利用多源信息，在保留主序列自身动态的同时，充分利用外部因素的影响，从而提升预测的准确性。

1.4.2　iTransformer 模型

iTransformer 模型是一种创新的 Transformer 架构，转换了注意力机制和前馈网络的作用。该模型通过将每个单一变量的整个时间序列作为一个独立的 token，并分析变量间的相关性和时序特征，提高了时序数据的预测性能。

1.4.3　PatchTST 模型

PatchTST 模型基于 Transformer 架构，通过分块与独立通道两大设计优化了长序列预测。分块将序列划分为子序列块作为输入，以捕捉局部模式并降低计算复杂度，通道让各变量独立通过共享权重的编码器，使模型专注于学习单个序列的时序规律，从而在长序列预测上实现了精准预测。

1.4.4　Informer 模型

Informer 模型是一种基于 Transformer 的长序列时间序列预测模型，通过 ProbSpares 自注意力机制降低计算复杂度，并结合蒸馏操作提取关键信息，从而在高效建模长时依赖的同时保持预测精度，适用于大规模多变量预测任务。

1.4.5　DLinear 模型

DLinear 模型是一种基于分解思想的时间序列预测方法，它将时间序列数据分解为趋势和季节成分，并通过单层线性网络进行建模和预测，最终输出预测结果。因此，DLinear 能够有效捕捉长期趋势与周期性模式，并在模型保持简洁高效的同时提升预测性能。

1.5　评价指标

为了验证模型的拟合效果和预测精度，本研究选择决定系数（R^2）、均方误差（MSE）、均方根误差（root mean squared error，RMSE）、平均绝对误差（mean absolute error，MAE）、平均绝对百分比误差（mean absolute percentage wrror，MAPE）对不同预测方法的预测树干液流值与实测值进行统计比较，以评估预测结果准确性和性能。

R^2 用来衡量回归模型对数据的解释能力和拟合度，其取值范围是 0 到 1，越接近 1，表示模型对数据的解释能力越强。MSE 和 RMSE 分别反映预测误差的平方平均水平及其标准差。MAE 表示预测结果与真实值之间误差的绝对值的平均值。通过计算 MAE、RMSE、MAE，能够量化预测方法在预测树干液流值方面的效果，较小的 MAE、RMSE、MAE 值，表示预测结果与真实值更接近，表明预测方法具有较高的准确性和良好的性能。MAPE 进一步从相对误差的角度评估预测精度，计算公式见（9）。

$$\mathrm{MAPE}=\frac{100\%}{n}\sum_{i=1}^{n}\left|\frac{y_i-\hat{y}_i}{y_i}\right| \tag{9}$$

式中：y_i是真实值，$\hat{y}_i$是预测值，$\bar{y}_i$是真实值的均值。

1.6 环境及参数配置

本研究基于 PyTorch1.13.1 深度学习框架，硬件依托于 InterE5-2678 处理器和 RTX2080super 显卡，并配置 32GB 物理内存。系统编译环境为 Ubuntu20.04 和 Python3.8 环境。为保证不同时间序列深度学习模型对预测效果的公平性，在参数初始化中，5 种模型均使用相同的超参数。各模型参数细节详见表 1。

在数据集的构建与划分阶段，观测样本按时间顺序 8∶2 的比例划分为模型训练集与测试集，实验设定多个不同的未来预测步长进行拟合和参数寻优，最终确定预测窗口为 192，对中长期树干液流的变化趋势进行预测拟合。

2 结果与分析

2.1 环境相关性分析

在本实验中共测量了 9 个环境因子，通过皮尔逊相关分析法对树干液流流量与各环境因子进行了相关性分析，结果如图 5 所示。根据 Profillidis 等[33]的研究，当皮尔逊相关系数在 0～0.3 时表明 2 个变量成弱相关，因此将皮尔逊相关系数为 0.3 设为环境因子与树干液流量相关性的临界点。研究结果表明，树干液流与 WS、土壤含水量（soil water content，SWC）的相关性较弱，WS 相关性系数为 0.17，SWC_SHALLOW 和 SWC_DEEP 的相关性系数分别为 0.14 和 0.19，未达到显著相关水平。在生态水文机制中，SWC 通过非线性的限制作用影响蒸腾，但本研究的加拿大白松生长环境处于温带大陆性湿润气候，区域降水相对充足，土壤含水量并未触发显著的非线性气孔限制作用，影响较弱。

树干液流对环境因子存在时序滞后、非线性关联与阈值响应，保留较完整气象因子可让模型充分学习交互关系，提升中长期预测稳定性。因此在构建模型时，结合统计学相关性和站点特定的生态学机制，尽量避免变量冗余和噪声干扰，剔除了 WS、SWC_shallow 和 SWC_deep 3 个指标，最终本文选取了 T_a、VPD、PPFD、SW、RH、Ext_Rad 6 个指标作为模型输入变量。

2.2 消融实验

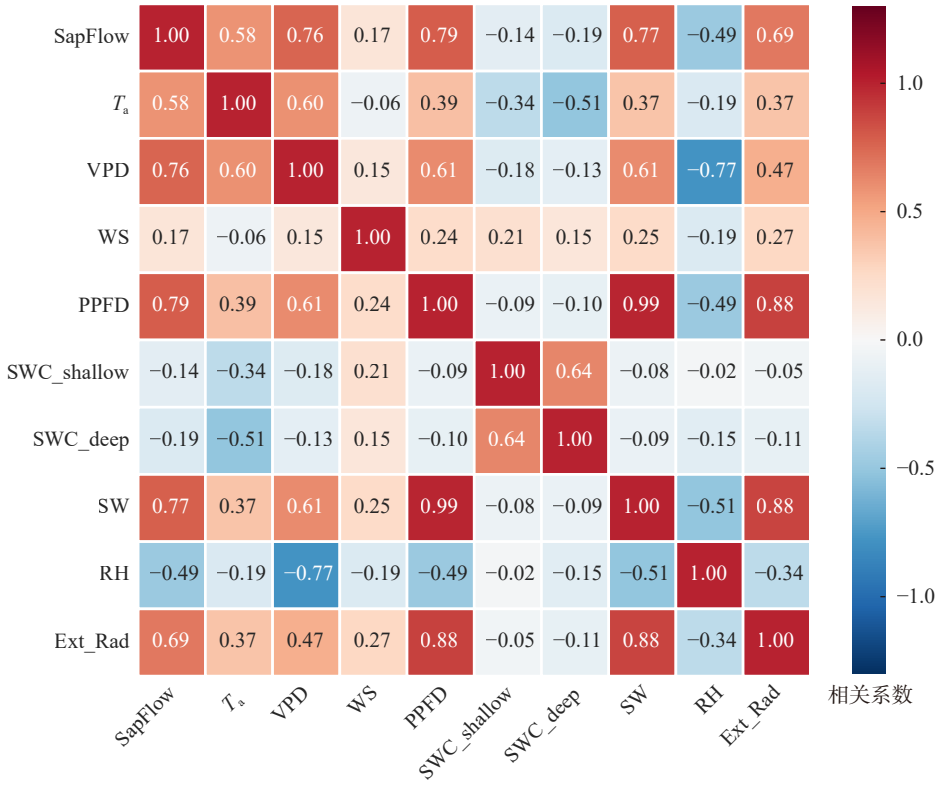
本研究旨在通过系统性消融研究，验证多尺度分块嵌入、LSTM 时序校准和多尺度卷积模块对增强模型的有效性和稳健性的必要性。实验以 TimeXer 为基础，通过分别独立引入上述三大核心模块，以及最终添加所有模块形成 MS-HyTimeXer 模型，并对比各架构下的预测结果评价指标，量化评估每个模块对模型整体性能的贡献。实验方案与结果如表 2 所示。

由表 2 结果分析可知，与基础模型 TimeXer 相比，在引入多尺度分块嵌入后，模型的 MSE 从 0.765 $cm^3/(cm^2·h)$显著降低至 0.663 $cm^3/(cm^2·h)$，降幅达到 14.29%，同时 MAE 也降低了 1.85%，R^2 从 0.869 提升至 0.880，这表明，通过在不同尺度上对时间序列进行分块处理，模型能够更有效地提取多粒度时序特征，从而增强基础模型的特征表征能力。引入 LSTM 时序校准模块时，模型在所有单项改进中取得了较显著的性能提升，MSE 从 0.765 $cm^3/(cm^2·h)$ 降低至 0.501 $cm^3/(cm^2·h)$，降幅达到 35.06%，同时 MAPE 也从 9.851% 降至 9.353%，R^2 从 0.869 提升至 0.895，验证了 LSTM 结构在捕捉序列长期依赖关系和自适应融合时序特征表示方面的优势，对提升

表 1 模型主要超参数设置

Tab. 1 Main settings of the model's key parameters

模型	超参数	设定值
DLinear，Informer，PatchTST，iTransformer，TimeXer MS-HyTimeXer	top_k	5∈{3, 5, 8}
	e_layers, d_layers	2, 4
	d_model, d_ff	256, 512∈{128, 256, 512}
	mask_rate	0.25
	activation	GELU
	batch_size	32
	learning_rate	0.001
	epoch	10
	seq_len	336, 512, 720
	pred_len	192



红色区域代表正相关，蓝色区域代表负相关，深色区域表示强相关，浅色区域表示弱相关。

图 5　环境因子分析

Fig. 5　Environmental factor analysis

表 2　消融实验结果

Tab. 2　Results of ablation experiment

模型	MSE/($cm^3 \cdot cm^{-2} \cdot h^{-1}$)	MAE/($cm^3 \cdot cm^{-2} \cdot h^{-1}$)	R^2	RMSE/($cm^3 \cdot cm^{-2} \cdot h^{-1}$)	MAPE/%
TimeXer	0.765	0.543	0.869	0.875	9.851
TimeXer + Multi-Scale Patch Embedding	0.663	0.526	0.882	0.814	9.484
TimeXer + LSTM Timing Calibration	0.501	0.487	0.895	0.707	9.353
TimeXer + Multi-Scale Convolution	0.690	0.616	0.876	0.831	9.627
MS-HyTimeXer	0.312	0.391	0.918	0.559	7.652

模型预测精度具有关键作用。结合多尺度卷积模块时，MSE 降低了 10.39%，R^2 从 0.869 提升至 0.882，说明通过并行使用不同大小的卷积核以增强局部时间模式提取能力，可提高模型的预测准确性。

选取 2011 年 8 月夏季一段时间序列进行如图 6 的直观展示，最终的 MS-HyTimexer 模型在各项性能指标达到最优，与基准 TimeXer 相比，其 MSE 从 0.77$cm^3/(cm^2 \cdot h)$降至 0.31$cm^3/(cm^2 \cdot h)$，降幅达到 59.74%，MAE 从 0.54 $cm^3/(cm^2 \cdot h)$降至 0.39 $cm^3/(cm^2 \cdot h)$，降幅为 27.78%。R^2 从 0.87 提升至 0.92，同时 MAPE 也取得了最低值 7.65%，相较基准模型下降了 2.2 个百分点，这表明将多尺度分块嵌入、LSTM 时序校准和多尺度卷积模块结合，能够产生较显著的协同效应，有效克服了单一策略在复杂树干液流时序预测中的局限性，实现了模型精度和鲁棒性的全面提升。

2.3　不同模型在树干液流预测的性能比较

为了验证并比较时间序列模型对树干液流预测的性能，本研究在中长期预测任务中进行了对比分析，试验选取了 6 个环境因子作为输入，评估各模型在预测精度和稳定性方面的表现。

表 3 展示了中长期预测的试验结果，从各项评估指标来看，6 种深度学习模型在预测性能上存在明显差异。其中 MS-HyTimeXer 模型的性能最优，其 MSE 为 0.312 $cm^3/(cm^2 \cdot h)$，MAE 为 0.391 $cm^3/(cm^2 \cdot h)$，RMSE 为 0.559 $cm^3/(cm^2 \cdot h)$，MAPE 为 7.652%，在所有模型中均为最低，同时其 R^2 达到了 0.918，这表明该模型在拟合能力和预测准确性方面较优于其他模

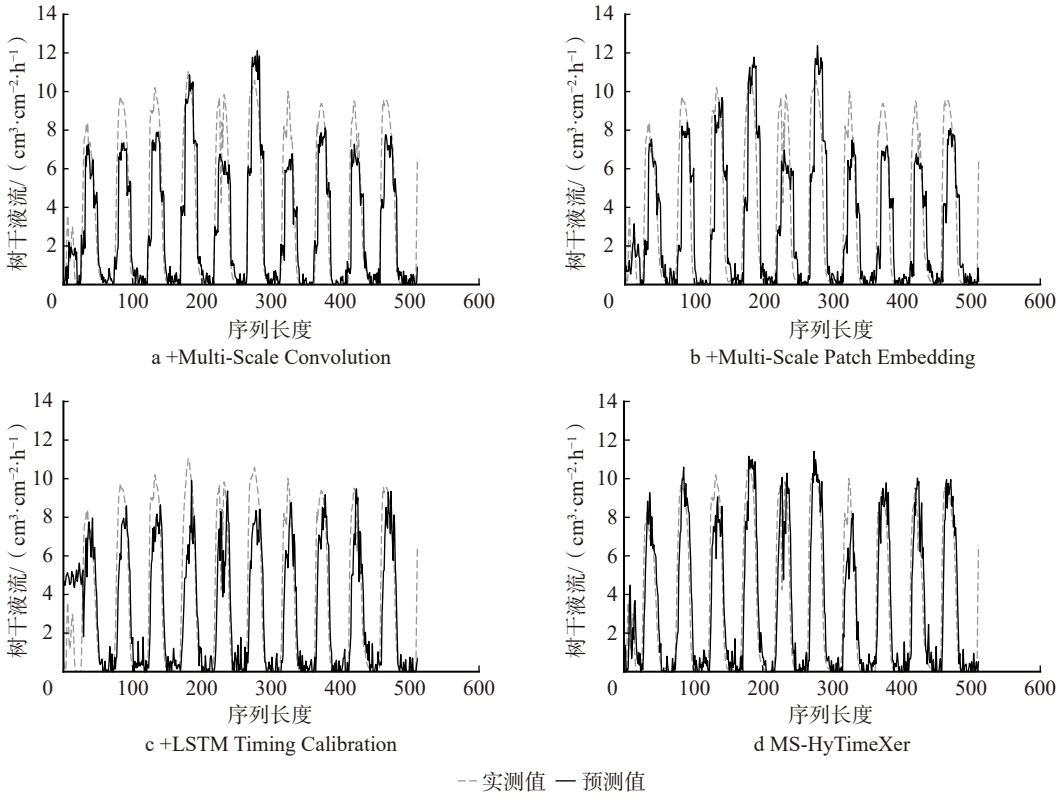


图 6 消融实验预测图

Fig. 6 Prediction graph of ablation experiments

表 3 模型对比实验结果

Tab. 3 Results of model comparison experiments

模型	MSE/(cm³·cm⁻²·h⁻¹)	MAE/(cm³·cm⁻²·h⁻¹)	R^2	RMSE/(cm³·cm⁻²·h⁻¹)	MAPE/%
DLinear	2.950	0.968	0.752	1.718	11.852
Informer	0.916	0.631	0.827	0.957	10.950
PatchTST	0.807	0.561	0.841	0.898	10.869
iTransformer	0.786	0.544	0.843	0.887	10.109
TimeXer	0.765	0.543	0.869	0.875	9.851
MS-HyTimexer	0.312	0.391	0.918	0.559	7.652

型。其他基于 Transformer 架构的模型（Informer、PatchTST、iTransformer、TimeXer）也表现出良好的预测能力：TimeXer 和 iTransformer 的综合性能较优，MSE 分别为 0.765 cm³/(cm²·h)和 0.786 cm³/(cm²·h)，误差控制表现良好；PatchTST 模型的预测精度相较于其他 Transformer 类模型略低，但 R^2 仍达到 0.841，维持在较高水平；Informer 模型在 MSE(0.916 cm³/(cm²·h))和 MAE(0.631 cm³/(cm²·h))方面表现适中，整体预测能力可靠。相比之下，DLinear 模型的表现较差，其 MSE(2.950 cm³/(cm²·h))显著高于其他模型，R^2 也为 6 个模型中最低，说明其在本数据集中的预测精度和对数据趋势的捕捉能力较为有限。

图 7 对预测结果进行了可视化展示，并综合 5 项指标可知，基于 Transformer 架构的模型整体表现稳定，具备较高的预测精度，其中 iTransformer 和 TimeXer 的综合性能较优，MS-HyTimeXer 模型在所有评估指标上优于其他模型，展现了优异的综合预测性能和稳定性，是本研究中最具优势的树干液流预测模型。

2.4 不同滑动窗口下的性能

滑动窗口和预测窗口的时长是模型构建的关键参数，本研究通过分析不同滑动窗口长度对 MS-HyTimexer 模型性能的影响。在模型构建过程中，旨在单一变量控制原则下，采用 6 个环境因子作为输入避免冗余变量干扰，其余参数保持不变，仅将滑动窗口长度设置为唯一变量进行实验，最终为同一个预测窗口构建了多个不同滑动窗口长度。评估指标如表 4 所示，并在图 8 做了可视化呈现，结果表明，

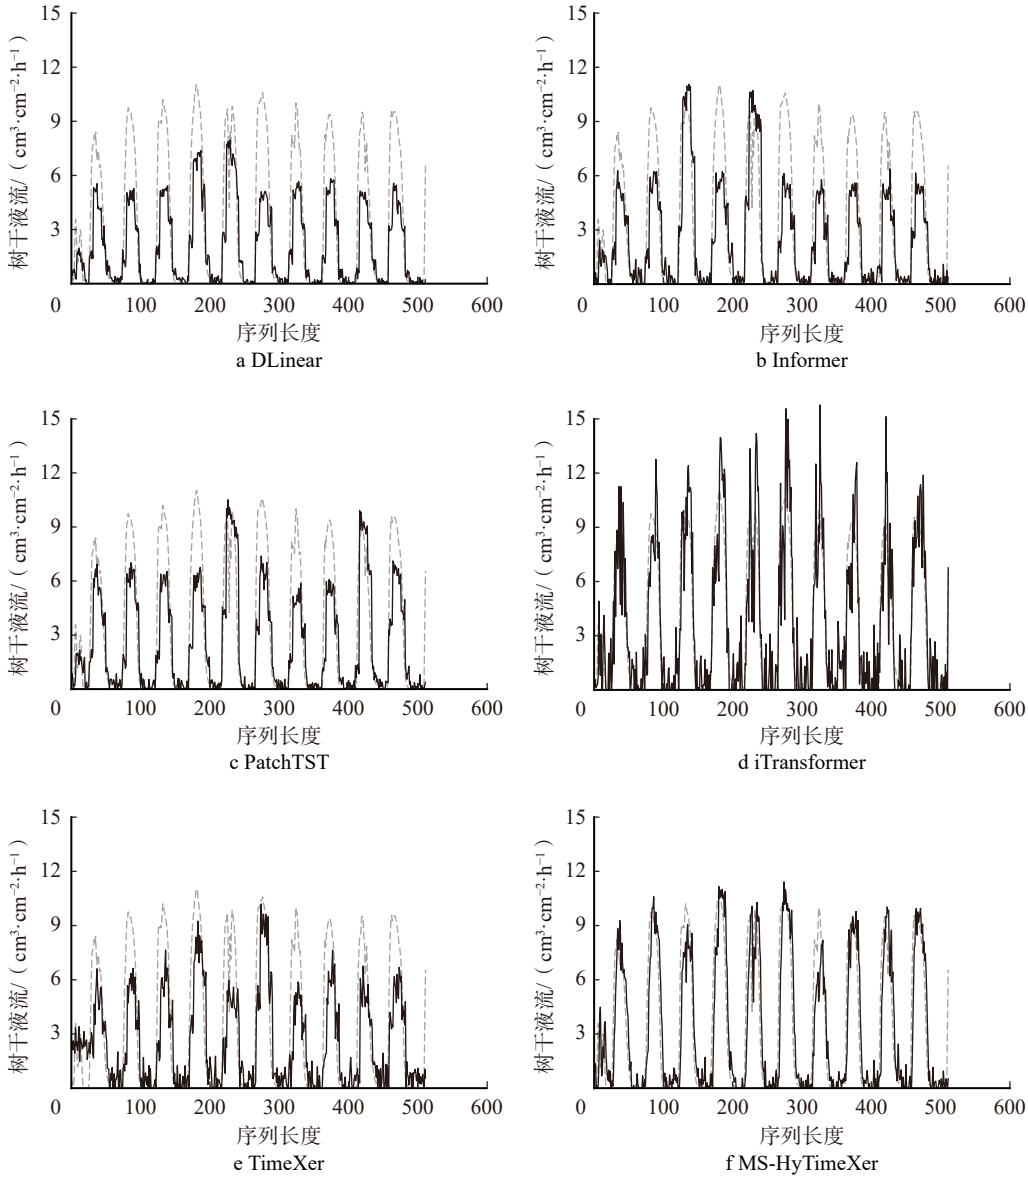


图 7　模型对比预测图

Fig. 7　Prediction chart of model comparison

表 4　不同滑动窗口的评估指标

Tab. 4　Evaluation metrics for different sliding windows

长度	MSE/（$cm^3 \cdot cm^{-2} \cdot h^{-1}$）	MAE/（$cm^3 \cdot cm^{-2} \cdot h^{-1}$）	R^2	RMSE/（$cm^3 \cdot cm^{-2} \cdot h^{-1}$）	MAPE/%
48	2.564	0.987	0.801	1.601	12.020
96	0.968	0.625	0.856	0.984	10.783
144	0.570	0.553	0.879	0.755	9.364
336	0.436	0.496	0.892	0.660	7.864
480	0.457	0.501	0.881	0.676	8.003
512	0.312	0.391	0.918	0.559	7.652
720	0.362	0.436	0.904	0.602	7.760

滑动窗口会显著影响模型对树干液流的预测效果，从图 8 可知，随着滑动窗口增加到 512，模型性能呈现出提升趋势，当滑动窗口为 512 时，模型的预测效果最佳，R^2 达到 0.918，MSE 和 MAE 分别降至 0.312 $cm^3/(cm^2 \cdot h)$和 0.391 $cm^3/(cm^2 \cdot h)$，MAPE 为 7.652%，预测误差较小且预测性能趋于稳定。当滑

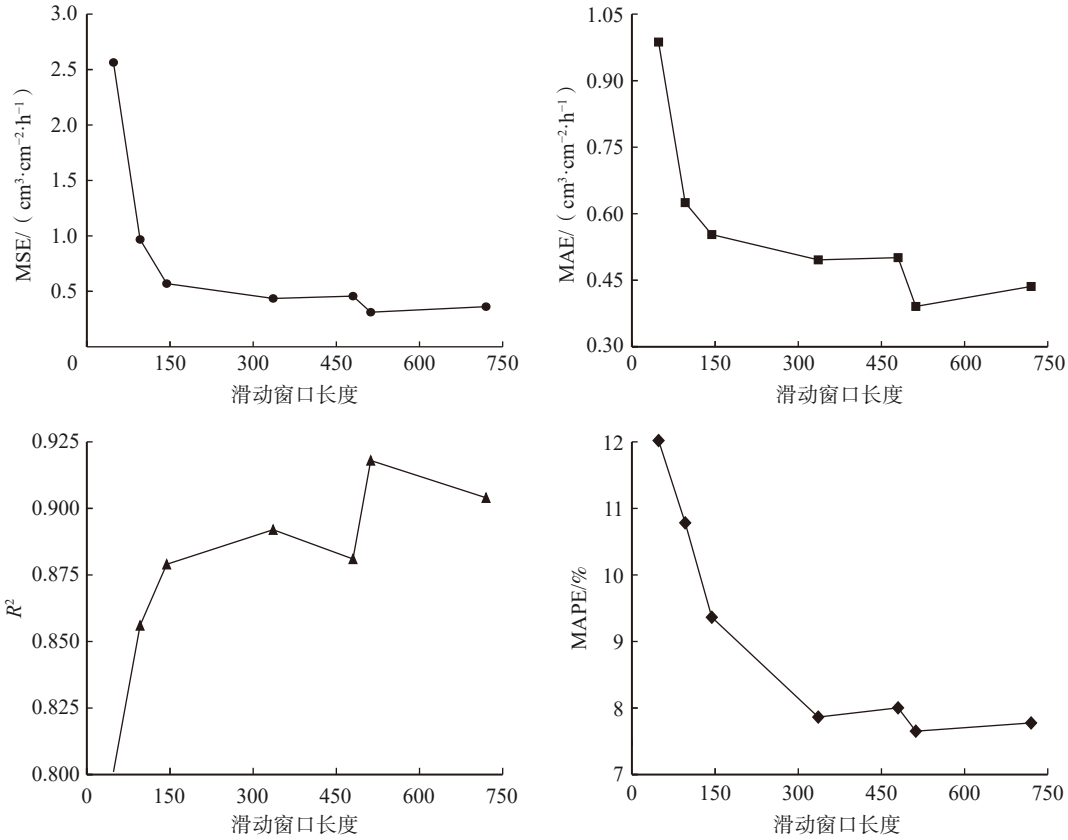


图 8 评价指标变化趋势

Fig. 8 Changing trends of evaluation metrics

动窗口继续增加至 720 时，模型性能略有下降，R^2 降至 0.904，MSE 升至 0.362 $cm^3/(cm^2·h)$，MAE 升至 0.436 $cm^3/(cm^2·h)$，MAPE 升至 7.760%，表明过长的滑动窗口可能引入冗余信息，反而影响模型性能。但随着滑动窗口下降至 48，模型性能大幅下降，R^2 下降到 0.801，MSE 和 MAE 分别为 2.564 $cm^3/(cm^2·h)$ 和 0.987 $cm^3/(cm^2·h)$，预测误差显著增大。

上述结果表明，滑动窗口长度过短会导致 MS-HyTimexer 模型对树干液流的预测准确性明显下降，这是因为较短的滑动窗口难以捕捉环境因子与树木树干液流之间的长期时序依赖关系，使得模型无法充分提取历史时刻的有效特征信息。而适度的滑动窗口长度能够在保留关键历史信息与避免信息冗余之间取得平衡，从而优化模型的预测性能，因此本研究将 512 设为默认滑动窗口长度。

3 讨 论

树木液流的准确预测对树木蒸腾量估算、土壤含水量分析、水资源管理及树木健康状况评估等具有重要意义，已有研究表明[34]，VPD、RH、T_a 等环境因子是驱动树干液流变化的主要因素，但这些环境因子与树干液流之间存在复杂的非线性耦合关系，因此本研究提出的 MS-HyTimeXer 模型，提升了预测性能，并验证了其可行性与优势。

3.1 MS-HyTimeXer 模型性能与其他模型性能比较

目前多数关于环境因素对树干液流预测的研究多采用机器学习方法，线性模型、随机森林、XGBoost 等模型的精度有待提升。深度学习中时间序列模型应用较少，而树干液流的数据本身就呈现一定时序性，因此本文改进并构建了 MS-HyTimXer 模型，融合了多尺度分块嵌入、LSTM 时序校准和多尺度卷积 3 大模块。实验数据显示，该模型的预测性能较优于 TimeXer 模型，TimeXer 模型的 MSE 和 R^2 分别为 0.765 $cm^3/(cm^2·h)$和 0.869，改进后的 MS-HyTimeXer 模型 MSE 和 R^2 分别为 0.312 $cm^3/(cm^2·h)$和 0.918，MSE 降低了 59.74%，R^2 提升了 5.75%。同时，本研究还对比了 4 种时间序列模型：DLinear、Informer、PatchTST 和 iTransformer，其 R^2 值分别为 0.752、0.827、0.841、0.843，均低于 MS-HyTimeXer 模型。这种差异源于基于 Transformer 的模型虽然擅长捕捉全局依赖性，但在处理时间序列时，会忽略局部特征和严格的时序顺序性，MS-HyTimeXer 则融合了多尺度卷积的局部感知能力与 LSTM 网络的时序依赖建模优势。白松树干内部具有蓄水组织，蒸腾初期所需要的水分先从树干内部提供，导致树干液流对辐射和 VPD 的响应存在延迟，

LSTM 时序校准模块通过 LSTM 的顺序处理能力将全局特征表示映射回具备严格先后顺序的时间流中。同时树干液流会对环境因子做出瞬时响应，也会随物候变化产生季节性趋势，多尺度分块嵌入通过对不同长度的分块并行处理，强化模型对树干液流的局部瞬时特征和昼夜周期趋势的联合建模。而多尺度卷积模块通过其局部连接和权重共享机制，提取树干液流数据的关键局部模式和脉冲式波动，如峰值和突变特征等，这与 Li 等[20]的研究结论相一致。这些共同弥补了 TimeXer 模型在捕捉时序连续性上的不足，使其提升预测精度。

本研究的重点区域是加拿大白松的生长环境，为温带大陆性湿润气候，具有季节性温差，降雨主要集中在树木的生长季，这会导致树干液流不仅在整体上具有季节性变化，在部分生长季内也会呈现较大波动范围。图 9 截取了受脉冲式水文事件影响，具有典型较高波动特征的时间序列，在此期间液流在短时间内发生上升和下降，相比 DLinear、PatchTST 和 TimeXer 模型，MS-HyTimeXer 模型能凭借其混合架构，有效提取复杂特征，精准捕捉此类由脉冲式水文事件引发的高频变化，预测精度较高。同时 MS-HyTimeXer 的性能提升还体现在分析生态响应机制的可靠性，DLinear 等时序模型在处理时会存在削弱峰值的现象，MS-HyTimeXer 则可以较为精准的还原液流的瞬时峰值与下降趋势，并且通过 LSTM 时序校准模块可有效解决环境驱动与液流响应之间的滞后性，消除模型因时序滞后引入的错误关联，反映植物的水分利用策略。结果表明，MS-HyTimeXer 的混合架构更擅长捕捉此温带大陆性湿润气候中季节性强、脉冲式水文事件，因此模型结构的选择必须与局地气候水文过程的具体特征相匹配。

3.2　模型局限性与未来改进方向

本研究构建的 MS-HyTimeXer 模型在树干液流时序预测中表现出较高精度，但模型会受到测量误差与时空尺度的约束，存在一定局限性。

本研究使用的树干液流观测数据基于 TDP 方式获取，该方法可能存在探针安装位置差异、边材厚度误差、径向液流剖面分布不均等不确定性影响。在模型较高精度拟合下，预测结果可能与真实值存在系统偏差，但较高的 R^2 也反映了模型对传感器所捕捉的信号具有相对较强的拟合能力，可一定程度上学习 TDP 仪器的系统偏差。在未来研究中，应通过引入边材面积动态模型等对输入数据进行物理校正，避免模型对测量偏差的过度拟合，从植物生理方面增强结果解释的可靠性。

MS-HyTimeXer 模型的预测能力与时空尺度适用性有待拓展。目前基于 30 min 的尺度对单一树种进行建模，实现对未来 192 个步长的预测，可较强捕

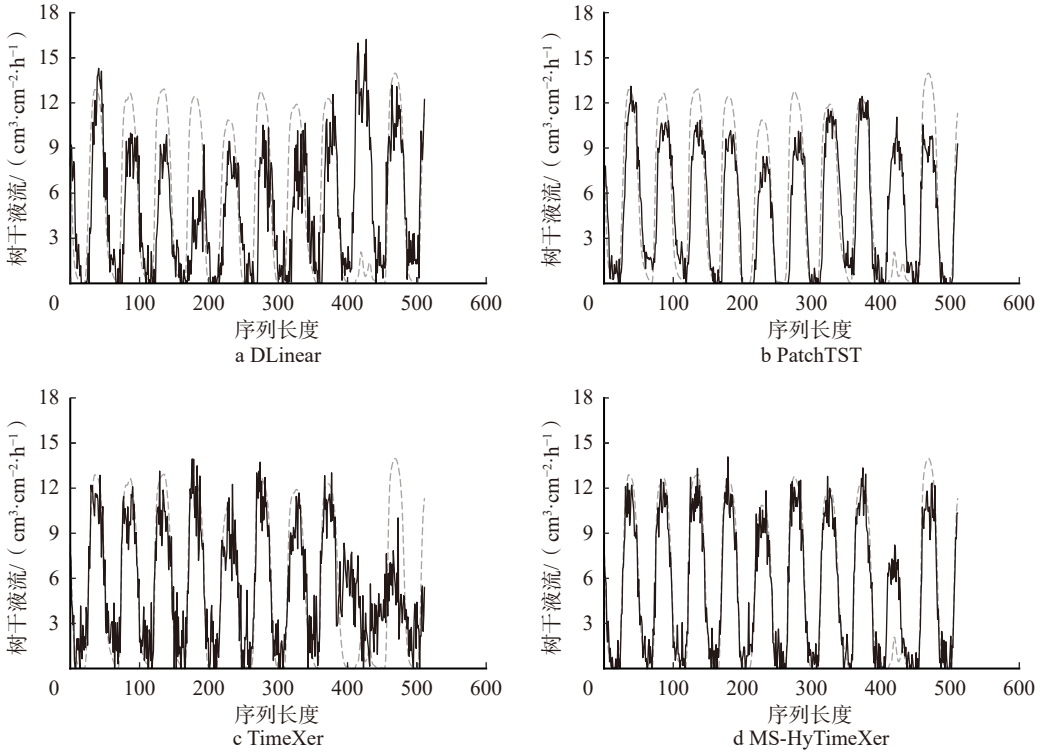


图 9　模型对比预测图

Fig. 9　Prediction chart of model comparison

捉植物生理响应，但在季、年尺度的应用情境下，树木的树干液流受物候环境、叶面积指数等调控影响，MS-HyTimeXer 模型虽能通过 LSTM 捕捉时序依赖，但对于跨季节和跨树种的非平稳信号提取仍有待加强。

未来可从 3 方面进一步完善：(1)引入测量误差分析，量化 TDP 观测的不确定性对模型拟合的影响；(2)构建更多维度的长期环境约束，探究模型在季尺度、年尺度估算中的适用性，并在多树种、多气候区站点开展验证，增强模型的通用性。

4 结　　论

本研究旨在实现对植物树干液流的精准预测，在 TimeXer 模型基础上进行改进，融合了多尺度分块嵌入、LSTM 时序校准和多尺度卷积 3 大模块，提出 MS-HyTimeXer 模型。通过系统性的实验评估与对比分析，得出如下结论：消融实验验证了各核心模块均对模型性能具有重要贡献，三者协同作用，使模型能够有效捕捉不同时间尺度下的时序特征、全局依赖关系与局部时间模式，从而全面提升了预测能力；MS-HyTimeXer 在 192 个步长的中长期树干液流预测任务中表现优异，各项评估指标均优于 DLinear、Informer、PatchTST、iTransformer、TimeXer 等 5 种基准模型，其 R^2 达到 0.918，MSE 为 0.312 $cm^3/(cm^2 \cdot h)$，MAE 为 0.391 $cm^3/(cm^2 \cdot h)$，该 96 h 预测窗口可覆盖典型天气的演变周期，在典型温带大陆性湿润气候环境下表现出优异的拟合能力与预测精度，为该气候带植物水文过程研究、林业智能灌溉决策及监测数据缺失提供了有力的技术支撑与解决方案。

本研究存在一定局限性：仅针对单一树种进行分析研究，模型在其他气候类型中的泛化能力有待进一步验证，因此未来研究可以引入不同气候带的树种数据进行季、年尺度验证，进一步提升模型的泛化能力与应用范围；在变量筛选阶段，结合皮尔逊相关法与站点的环境特征，未将 SWC 纳入最终模型，但在干旱气候条件下，SWC 对树木蒸腾的限制作用需要关注，未来模型应用在跨区域时，需考虑是否纳入研究中。

参 考 文 献

[1] Oki T, Kanae S. Global hydrological cycles and world water resources [J]. Science, 2006, 313: 1068−1072.

[2] Rodell M, Famiglietti J S, Wiese D N, et al. Emerging trends in global freshwater availability [J]. Nature, 2018, 557: 651−659.

[3] 吴慧杰, 汪海娇, 许行, 等. 不同降水梯度下黄土高原油松人工林蒸腾特征及其生物物理响应 [J]. 北京林业大学学报, 2025, 47(10): 42−53.
Wu H J, Wang H J, Xu H, et al. Transpiration characteristics and biophysical response of *Pinus tabuliformis* plantations on the Loess Plateau of northern China under different precipitation gradients [J]. Journal of Beijing Forestry University, 2025, 47(10): 42−53.

[4] Oogathoo S, Houle D, Duchesne L, et al. Vapour pressure deficit and solar radiation are the major drivers of transpiration of balsam fir and black spruce tree species in humid boreal regions, even during a short-term drought [J]. Agricultural and Forest Meteorology, 2020, 291: 108063.

[5] 王彪, 陈立欣, 吴应明, 等. 干旱胁迫下环境与生理因子对晋西黄土区刺槐人工林树干液流的影响 [J]. 北京林业大学学报, 2024, 46(4): 127−140.
Wang B, Chen L X, Wu Y M, et al. Impact of environmental and physiological factors during drought stress on sap flow in *Robinia pseudoacacia* plantations in the loess region of western Shanxi Province of northern China [J]. Journal of Beijing Forestry University, 2024, 46(4): 127−140.

[6] 刘彩霞, 陈俊辉, 秦华, 等. 有机无机肥长期配施对毛竹林土壤固碳和固氮微生物的影响 [J]. 林业科学, 2022, 58(7): 82−92.
Liu C X, Chen J H, Qin H, et al. Effects of long-term combined application of organic and inorganic fertilizers on soil CO_2- and N_2-fixing microorganisms in a subtropical bamboo forest [J]. Scientia Silvae Sinicae, 2022, 58(7): 82−92.

[7] Marshall D C. Measurement of sap flow in conifers by heat transport [J]. Plant Physiology, 1958, 33(6): 385−396.

[8] Feng D U, Suo L Z, Lun S, et al. Evapotranspiration measurements of community using weighting method [J]. Acta Botanica Boreali-Occidentalia Sinica, 2003, 23(8): 1411−1415.

[9] Granier A. A new method of sap flow measurement in tree stems [J]. Annals of Forest Science, 1985, 42(2): 193−200.

[10] Burgess S S O, Adams M A, Turner N C, et al. An improved heat pulse method to measure low and reverse rates of sap flow in woody plants [J]. Tree Physiology, 2001, 21(9): 589−598.

[11] 任启文, 王玉忠, 徐振华, 等. 基于水量平衡的华北落叶松人工林承载密度研究 [J]. 北京林业大学学报, 2024, 46(7): 1−8.
Ren Q W, Wang Y Z, Xu Z H, et al. Carrying density of *Larix principis-rupprechtii* plantations based on water balance [J]. Journal of Beijing Forestry University, 2024, 46(7): 1−8.

[12] 彭思乐, 贾文丽, 邓鹏飞, 等. 基于环境参数和深度学习模型的毛竹液流密度预测 [J]. 农业工程学报, 2025, 41(5): 201−208.
Peng S L, Jia W L, Deng P F, et al. Prediction of moso bamboo sap flow based on environmental parameters and deep learning models [J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2025, 41(5): 201−208.

[13] 张延文, 王子瑄, 孙志虎, 等. 基于随机森林的长白落叶松树干液流影响因素研究 [J]. 温带林业研究, 2022, 5(3): 21−28.
Zhang Y W, Wang Z X, Sun Z H, et al. Recognition of dominant factors behind sap flow of *Larix olgensis* based on random forest ethod [J]. Journal of emperate Forestry Research, 2022, 5(3): 21−28.

[14] Tu J, Wei X, Huang B, et al. Improvement of sap flow estimation by including phenological index and time-lag effect in back-

propagation neural network models [J]. Agricultural and Forest Meteorology, 2019, 276−277(9): 107608.

[15] Junior L S F, Vellame L M, Oliveira A S D, et al. Transpiration of young cocoa trees under soil water restriction [J]. Scientia Agricola, 2021, 78(2): e20190093.

[16] Nalevanková P, Fleischer P, Jr. , Mukarram M, et al. Comparative assessment of sap flow modeling techniques in European beech trees can linear models compete with random forest, extreme gradient boosting, and neural networks [J]. Water, 2023, 15(14): 2525.

[17] 姚琴娟，王伟博，胡云昊，等. 基于改进时间全卷积网络的中短期树干液流预测 [J]. 中南林业科技大学学报, 2026, 46(1): 104−114.
Yao Q J, Wang W B, Hu Y H, et al. Enhanced temporal fully convolutional network for short-and mediumterm sap flow prediction [J]. Journal of Central South University of Forestry & Technology, 2026, 46(1): 104−114.

[18] Liu Y F, Gui D W, Chen X P, et al. Sap flow characteristics and water demand prediction of cash crop in hyper-arid areas [J]. Agricultural Water Management, 2024, 295: 108767.

[19] Li Y, Ye J, Xu D, et al. Prediction of sap flow with historical environmental factors based on deep learning technology [J]. Computers and Electronics in Agriculture, 2022, 202: 107400.

[20] Li Y, Guo L, Wanag J, et al. An improved sap flow prediction model based on CNN-GRU-BiLSTM and factor analysis of historical environmental variables [J]. Forests, 2023, 14(7): 1310.

[21] Zhang B, Zhang D, Feng Z, et al. Assessment of the potential of indirect measurement for sap flow using environmental factors and artificial intelligence approach: a case study of *Magnolia denudata* in Shanghai urban green spaces [J]. Forest, 2023, 14(9): 1768.

[22] Li Y, Hu Y, Wang W, et al. Patch-TS: a fast and accurate patch mixer-based model for medium- and long-term sap low prediction with environmental factors [J]. Forests, 2025, 16(4): 606.

[23] Wang J, Renninger H J. SapFlower: an automated tool for sap flow data preprocessing, gap‐filling, and analysis using deep learning [J]. New Phytologist, 2025, 246(5): 2324−2345.

[24] 付照琦, 胡旭, 田沁瑞, 等. 晋西黄土区 2 种典型森林树种夜间液流特征及对环境因子的响应 [J]. 植物生态学报, 2024, 48(9): 1128−1142.
Fu Z Q, Hu X, Tian Q R, et al. Nocturnal sapflow characteristics of two typical forest tree species and responses to environmental factors in the loess region of West Shanxi, China [J]. Chinese Journal of Plant Ecology, 2024, 48(9): 1128−1142.

[25] 马世杰, 焦炳忠, 韩磊, 等. 基于 BP 神经网络优化模型的不同退化程度刺槐树干液流动态模拟 [J]. 水土保持研究, 2026, 33(2): 333−344.
Ma S J, Jiao B Z, Han L, et al. Simulation of stem sap flow dynamics of *Robinia pseudoacacia* with different degrees of degradation based on BP neural network optimized model [J]. Research of Soil and Water Conservation, 2026, 33(2): 333−344.

[26] Poyatos R, Granda V, Flo V, et al. Global transpiration data from sap flow measurements: the SAPFLUXNET database [J]. Earth System Science Data, 2020, 13(6): 2607−2649.

[27] Lai L O, Kaplan J O. A fast mean-preserving spline for interpolating interval data [J]. Journal of Atmospheric and Oceanic Technology, 2022, 39: 503−512.

[28] Wang Y, Wu H, Dong J, et al. TimeXer: empowering transformers for time series forecasting with exogenous variables [J]. Advances in Neural Information Processing Systems, 2024, 37: 469−498.

[29] Liu Y, Hu T G, Zhang H R, et al. Itransformer: inverted transformers are effective for time series forecasting[J]. arXiv preprint arXiv: 2310.06625, 2023.

[30] Nie Y Q, Nguyen N H, Sinthong P, et al. A time series is worth 64 words: long-term forecasting with transformers[J]. arXiv preprint arXiv: 2211.14730, 2022.

[31] Zhou H, Zhang S, Peng J, et al. Informer: beyond efficient transformer for long sequence time-series forecasting [J]. Proceedings of the AAAI Conference On Artificial Intelligence, 2021, 35(12): 11106−11115.

[32] Zeng A, Chen M, Zhang L, et al. Are transformers effective for time series forecasting? [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(9): 11121−11128.

[33] Profillidis V A, Botzoris G A. Modeling of transport demand: analyzing, calculating, and forecasting transport demand[M]. Oxford: Elsevier, 2018.

[34] Efrosinin D, Kochetkova I, Stepanova N, et al. The Fourier series model for predicting sapflow density flux based on tree talker monitoring system [J]. InInternational Conference on Next Generation Wired/Wireless Networking, 2020, 12044: 198−209.

（责任编辑　李　契
责任编委　张会儒）