

基于深度学习的草地生态系统净碳交换模拟

齐建东 黄俊尧

(北京林业大学信息学院, 北京 100083)

摘要: 为应用深度学习理论及技术对高寒地区草原生态系统净碳交换 (NEE) 进行模型模拟, 基于全球通量观测网络 (FLUXNET) 中内蒙古自治区锡林郭勒盟多伦县草原 2007—2008 年间的 CO₂ 通量数据, 采用深度学习中基于注意力机制的编码器-解码器框架对 NEE 进行模拟, 使用随机森林模型计算光量子通量密度 (PPFD)、土壤温度 (Ts)、空气温度 (Ta)、降水量 (P)、土壤含水率 (SWC) 和饱和水汽压差 (VPD) 与 NEE 关系的重要性得分, 并分析该关系的季节性差异。结果表明, 深度学习模型的均方根误差为 0.28 μmol/(m²·s), 决定系数为 0.93, 相比传统的人工神经网络与支持向量机模型, 分别减小 0.14、0.08 μmol/(m²·s) 和增加 0.29、0.34, 说明深度学习模型具有更高预测准确度; 在深度学习模型中引入注意力机制后, 10 次训练预测的标准差为 0.002 μmol/(m²·s), 相比普通深度学习编码器-解码器网络模型和长短期记忆网络分别减小 0.005 μmol/(m²·s) 和 0.036 μmol/(m²·s), 验证了注意力机制在预测稳定性上的优势。由随机森林模型计算的环境因子重要性得分显示, 由非生长季向生长季过渡的 3—4 月间, PPFD (33.5) 与 VPD (30.0) 对 NEE 的变化起主导作用; 进入生长季后的 5—6 月间, SWC (50.5) 是 NEE 变化的主要影响因素; 7 月 P (3.8) 较少, PPFD (26.8) 与 SWC (60.1) 协同作用 NEE 的变化; 8 月 PPFD (2.8) 与 SWC (6.9) 相对充足, VPD (41.5) 与 P (42.7) 成为影响 NEE 的主要因素; 9 月后 PPFD 与 P 均急剧减小, 并维持稳定, 温度系数 Q₁₀ 较生长季略增大, 并在 1 月达到最大值 5.96, 因此, 在非生长季 1—3 月 Ts (44.6) 与 10—12 月 Ts (54.2) 通过影响植物呼吸成为影响 NEE 的决定性因子。高寒地区草地生态系统生长季的 NEE 变化主要受辐射、温度和水分的影响, 非生长季主要受温度影响, 且辐射、温度、水分的影响程度存在明显季节性差异。与支持向量机等传统机器学习算法相比, 深度学习理论及技术在生态模型模拟领域具有更好的应用前景。

关键词: 草地生态系统; 净碳交换; 深度学习

中图分类号: Q148 **文献标识码:** A **文章编号:** 1000-1298 (2020) 06-0152-10

OSID:



Simulation of NEE in Grassland Ecosystems Based on Deep Learning

QI Jiandong HUANG Junyao

(School of Information Science and Technology, Beijing Forestry University, Beijing 100083, China)

Abstract: Aiming to apply deep learning theory and technology to model the net ecosystem exchange (NEE) of grassland ecosystems in the alpine region, based on the FLUXNET CO₂ flux data of the grassland in Duolun County, Xilinguole League, Inner Mongolia Autonomous Region, from 2007 to 2008, the attention-based encoder-decoder framework in deep learning was used to simulate NEE, and the random forest model was used to calculate the importance score of the relationship between NEE, which included the photosynthetic photon flux density (PPFD), soil temperature (Ts), air temperature (Ta), precipitation (P) and soil moisture content (SWC) and water pressure difference (VPD), and their seasonal differences in the relationship were analyzed. The result showed that the root mean square error (RMSE) of the deep learning model was 0.28 μmol/(m²·s), which was declined by 0.14 μmol/(m²·s) and 0.08 μmol/(m²·s), respectively, compared with ANN and SVM. The coefficient of determination was 0.93, which was increased by 0.29 and 0.34, respectively. With the attention mechanism, the RMSE standard deviation predicted by 10 times training was 0.002 μmol/(m²·s), which showed a reduction of 0.005 μmol/(m²·s) and 0.036 μmol/(m²·s) compared with Encoder-decoder network model and long short-term memory (LSTM). The attention mechanism model was more competitive in predicting stability. The importance score calculated by random forest model showed the variations of photon flux

收稿日期: 2019-07-12 修回日期: 2019-11-06

基金项目: 国家重点研发计划项目 (2017YFC0504400)

作者简介: 齐建东 (1976—), 男, 教授, 主要从事智能信息处理、生态系统过程监测与模拟研究, E-mail: qjjd@bjfu.edu.cn

density PPFD (33.5) and saturated vapor pressure VPD (30.0) played a leading role in the variations of NEE from March to April. During the period from May to June after the growing season, soil water content SWC (50.5) was the main influencing factor of NEE variations. The precipitation P (3.8) showed a process of decrease in July, and the photon flux density PPFD (26.8) and the soil water content SWC (60.1) were the collaborative decision of NEE. In August, PPFD (2.8) and SWC (6.9) were relatively abundant with plentiful rainfall. The saturated vapor pressure difference VPD (41.5) and rainfall P (42.7) became the main factors affecting NEE. After September, the photon flux density PPFD and rainfall were both decreased sharply and remained stable. The temperature coefficient Q_{10} was increased slightly compared with the growing season and reached a maximum value of 5.96 in January, so temperature was the decisive factor affecting NEE through plant respiration in non growing season, which is 44.6 between January to March and 54.2 between October and December. In conclusion, radiation, temperature and moisture remarkably affected NEE in the growing season of grassland ecosystems in alpine region, temperature was the main factor in non-growing season. Comparing with traditional machine learning algorithms such as support vector machines, deep learning theory and technology had better application prospects in the field of ecological model simulation.

Key words: grassland ecosystem; net ecosystem exchange; deep learning

0 引言

草地生态系统覆盖陆地面积约20%,其净初级生产力约占全球陆地生物区净初级生产力的1/3,在地球碳循环过程中具有重要的作用^[1]。受人类生产、生活以及环境变化影响,草地生态系统具有较大的不确定性,在生态系统生产力、群落结构和土壤的碳氮储量等方面,不同年份表现出较大的差异。因此,研究草原生态系统碳循环的主要过程以及影响机理是全球碳循环研究的关键问题之一^[2]。

迄今,大多数生态系统碳通量模型模拟及有关环境因子响应的研究主要依赖于复杂的生物和物理过程的模型^[3-4],但生态系统潜在的非线性和非平稳特征会降低这些机理模型的精确性和可靠性。文献^[5]认为,基于数据驱动模型比基于过程的生态学模型更具优势。伴随着生态监测数据的不断累积,机器学习理论及技术在生态模型模拟上的有效性已获得广泛认可^[6-8],机器学习在估算不同空间和时间尺度的碳通量方面比基于传统生态学过程的模型表现更好^[9]。如使用人工神经网络(Artificial neural network, ANN)对城市绿地生态系统的净碳交换(Net ecosystem exchange, NEE)进行模拟与分析^[10],使用支持向量机(Support vector machine, SVM)估算亚洲陆地生态系统的54个通量塔站点初级生产量(Gross primary productivity, GPP)和NEE^[11],使用随机森林(Random forest, RF)分析光利用效率在模拟生态系统初级生产量GPP中的重要性^[12],使用自适应神经模糊推理系统(Adaptive network-based fuzzy inference system, ANFIS)和广义回归神经网络(General regression neural network, GRNN)预测森林生态系统的日碳通量^[13],使用模

型树集合(Model tree ensemble, MTE)进行土地生物圈GPP的模拟^[14]等。

目前,已有研究主要使用传统机器学习算法,大多针对森林、农田生态系统,针对草地生态系统的研究较少。深度学习理论及技术作为当前机器学习领域最活跃的研究分支,在层次特征学习与表征上更具优势,但其在生态模型模拟领域的应用几乎为空白^[15]。从计算科学角度出发,生态领域中碳通量预测、插补等问题属于时间序列分析问题,而在时间序列预测方面,深度学习领域中长短期记忆网络(Long short-term memory, LSTM)的优秀性能已被证明^[16]。其中,注意力机制^[17]的引入进一步显著提升了时间序列分析效果。

本文对高寒地区草原生态系统NEE进行模拟,使用随机森林算法对影响其变化的各环境因子重要程度进行计算及分析,并验证深度学习理论及技术在生态模型模拟中的有效性。

1 材料和方法

1.1 研究区概况

研究地点位于内蒙古自治区与华北平原之间(42°27' N, 116°41' E, 海拔1380 m),属于半干旱农牧交错带典型地区。根据多伦气象站的长期气候资料(1994—2004年)显示,多伦年平均气温为3.3℃。年平均降水量为399 mm,集中分布在7—8月。年蒸发量为1600~1800 mm,平均蒸发量为1748.0 mm,是降水量的4~5倍。最低、最高的月平均气温为1月的-17.5℃和7月的18.9℃。土壤类型为栗钙土,土壤pH值为7.12,有机质含量(质量比)为12.28 g/kg,主要物种为克氏针茅(*Stipa krylovii*)^[18]。

多伦通量测量系统于 2005 年 6 月成立,利用涡动协方差技术测量 CO₂ 体积分数、含水率、显热通量和潜热通量。涡动协方差传感器包括 Li-7500 型 CO₂/H₂O 红外分析仪和 CSAT-3 型三维声波风速计。CO₂/H₂O 传感器头安装在声波风速计的下风向处,分析仪每 6 个月校准一次。用距离地面 3.5 m 的 CNR-1 型净辐射计测量净辐射。通过 LI-190SB 型 PAR 量子传感器测量光合有效辐射。用 HMP45C 型温度和相对湿度探头测量空气温度和相对湿度。将 CS616 型 TDR(时域反射)传感器插入 0~10 cm 土层测量土壤含水率,并用 3 个深度(5、10、20 cm)的热电偶测量土壤温度。用 3 个 HFT-3 型土壤热传感器在土壤表面以下 5 cm 处测定土壤热通量。用在地面以上 4 m 处的 TE525MM 型翻斗式雨量计测量降水量。用 CR23XI 型数据记录器以 30 min 的间隔记录小气候数据,以 10 Hz 对风速、声波温度、CO₂ 体积分数和含水率的波动进行采样,并通过 CR5000 型数据记录器记录^[19]。

1.2 长短期记忆网络

LSTM^[20] 是一种全互连的神经网络,神经元间存在反馈连接,在学习新特征的同时能够记忆历史信息。每一个 LSTM 单元都由输入门、输出门、遗忘门和记忆单元组成。LSTM 通过这些门控单元来控制历史信息对当前信息的影响,使得模型能够较长时间地保存并传递信息。

t 时刻,LSTM 的输入门 i_t 、遗忘门 f_t 、输出门 o_t 、记忆单元的状态 c_t 、隐藏层信号 h_t 分别为

$$i_t = \sigma(W_i h_{t-1} + W_i X_t + b_i) \tag{1}$$

$$f_t = \sigma(W_f h_{t-1} + W_f X_t + b_f) \tag{2}$$

$$o_t = \sigma(W_o h_{t-1} + W_o X_t + b_o) \tag{3}$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_c h_{t-1} + W_c X_t + b_c) \tag{4}$$

$$h_t = o_t \tanh(c_t) \tag{5}$$

其中 $X_t = [x_1 \ x_2 \ \cdots \ x_n]$
式中 W_i 、 W_f 、 W_o 、 W_c ——输入门 i_t 、遗忘门 f_t 、输出门 o_t 和记忆单元状态 c_t 的权重矩阵

b_i 、 b_f 、 b_o 、 b_c ——输入门 i_t 、遗忘门 f_t 、输出门 o_t 和记忆单元状态 c_t 的偏移量

X_t —— t 时刻监测指标所构成的矩阵

结构如图 1 所示。

1.3 编码器-解码器模型

编码器-解码器网络^[21] 是一个 Seq2Seq 模型,编码器接受一个序列作为输入,并将输入序列中的信息编码作为中间表示,解码器将其解码输出另外一个序列。

在编码器层,将通量塔主要监测指标矩阵 $X_t =$




图 1 长短期记忆网络 LSTM

Fig. 1 Long short-term memory

$[x_1 \ x_2 \ \cdots \ x_n]$ 输入到编码器网络中

$$h_t = F_{\text{encoder}}(h_{t-1}, X_{t-1}) \tag{6}$$

其中 F_{encoder} 代表上述 e 个 LSTM 单元连接而成的网络,并将编码器层所有 LSTM 的输出信号汇总进行全连接输出语义向量

$$c = f(h_1, h_2, \cdots, h_t) \tag{7}$$

在解码器层,将编码器层的语义向量以及 $t-1$ 时刻的碳通量 y_t 输入到解码器网络中

$$s_t = F_{\text{decoder}}(s_{t-1}, y_{t-1}, c) \tag{8}$$

其中 F_{decoder} 表示上述 d 个 LSTM 单元连接而成的网络,将解码器层 LSTM 的输出信号以及编码器层的语义向量 c 进行全连接得到 t 时刻碳通量

$$y_t = F(s_t, c) \tag{9}$$

1.4 注意力机制

上述过程在式(7)中将历史信息映射为单一向量的行为造成了编解码过程中信息细节的大量丢失。注意力机制^[17] 根据编码器层 e 个 LSTM 的隐藏层信号 $h_j (j = 1, 2, \cdots, e)$ 计算 e 个语义向量 α_j ,并根据 $t-1$ 时刻解码器的输入信号 s_{t-1} ,与 $t-1$ 时刻的 NEE 值,得到解码器第 j 个解码器的输出 l_j 。

$$c_t = \sum_{j=1}^e \alpha_j h_j \tag{10}$$

$$\alpha_j = \frac{\exp l_j}{\sum_{k=1}^e \exp l_k} \tag{11}$$

$$l_j = f(s_{t-1}, h_t) \tag{12}$$

注意力机制打破了编码器-解码器结构在编解码时都依赖于内部一个固定长度向量的限制,结构如图 2 所示。

1.5 随机森林模型

随机森林^[22] 是一种由多棵决策树组成的组合模型。首先,对原始输入检测指标形成的样本矩阵利用自助重抽样(Bootstrap re-sampling)形成 n 个样本;其次,对每个样本分别建立较弱的分类回归树(Classification and regression tree, CART)^[23] 模型;最

后,以 n 棵回归树结果的平均值作为因变量的预测值。回归过程如图 3 所示。




图2 基于注意力机制的编码器-解码器网络
Fig.2 Attention-based encoder-decoder




图3 随机森林回归架构
Fig.3 Random forest regression framework

随机森林中使用二分递归分割技术 CART 作为基分类器,在每个节点(除叶节点外)将当前样本集分割为两个子集节点。通过每个节点的基尼杂质指数(Gini impurity)来计算监测指标的重要性评分(Variable importance measure, VIM)^[24]。

基尼杂质指数是一种基于杂度的属性分裂方法。杂度与可获取的有用信息呈负相关。杂度越小,变量的离散程度越差,得到的信息量越大。基尼

杂质指数的计算公式为

$$G(a) = 1 - \sum_{i=1}^c p_i^2 \tag{13}$$

式中 c ——样本类别数
 p_i ——特征中属性 a 对应的样本属于类别 i 的概率

1.6 基于注意力机制的 NEE 模拟分析模型

图 4 为基于注意力机制的 NEE 预测分析模型,包括输入层、模型层和输出层。输入层以内蒙古多伦草原通量塔各项监测指标为自变量,利用随机森林实现因子选择,并对数据归一化,划分训练集、测试集等;输出层实现数据反归一化,计算模型输出等;编码层将通量塔检测指标编码为若干个语义向量和历史碳通量数据共同输入解码层,自动挖掘监测指标和历史碳通量数据的相关特征并进行模拟,之后利用随机森林模型分析其各监测指标影响 NEE 的重要性。

2 实验结果与分析

实验数据来源于全球通量观测网络 FLUXNET 2015 数据集^[25]中国内蒙古多伦草原通量站点 2007 年 1 月 1 日至 2008 年 12 月 31 日的 30 min 监测数据,采用边缘分布抽样^[26](Marginal distribution sampling, MDS)进行数据插补,共计 731 d, 35 088 条数据,其中使用 23 494 条数据作为训练集,11 572 条数据作为测试集,去除无关指标、标志位指标以及不同计量的重复指标后,通过随机森林模型计算剩余监测指标的重要性得分,过滤掉潜热通量(H)、散热通量(LE)、大气压力(PA)和风速(WS)等重要性得分较低的监测指标后,选取重要性得分最高的 6 个监测指标,分别为土壤温度(Ts)(27.0)、光量子通量密度(PPFD)(19.9)、降雨量(P)(15.4)、土壤含水率(SWC)(17.6)、饱和水汽压差(VPD)(18.3)以及空气温度(Ta)(10.6),作为模型的输入。

为消除不同性质、不同量纲的指标对综合评价结果的影响,需对各指标值采用(0,1)标准化方法




图4 基于注意力机制的 NEE 模拟分析模型
Fig.4 Attention based net ecosystem exchange model for forecasting and analysis

对数据进行归一化处理,即

$$x_{normal} = \frac{x - x_{min}}{x_{max} - x_{min}} \tag{14}$$

式中 x_{normal} ——归一化后数据
 x ——原始数据
 x_{min} —— x 最小值 x_{max} —— x 最大值

采用已在 NEE 预测方面广为使用的两种机器学习模型人工神经网络 (ANN) 与支持向量机 (SVM), 与 3 种在时间序列预测方面取得较好效果的深度学习模型递归神经网络 (Recurrent neural networks, RNN)、LSTM、编码器-解码器网络 (Encoder-decoder) 与注意力机制 (Attention) 进行模型预测效果的对比。

实验运行环境为:操作系统使用 Ubuntu 16.04 Server, GPU 为 GTX 1050ti, 处理器为 Intel i7-8750H, 内存为 8.0 GB。在注意力机制模型中, 设置输入历史序列窗口的大小 $T=10$, 编码器层 LSTM 隐藏层的大小为 128, 解码器层 LSTM 隐藏层的大小为 64, 初始学习率为 0.000 1, 共训练 100 个 epochs, 每 10 个 epoch 学习率衰减为原来的 90%, batch size 设置为 128。

以预测值和真实值的均方误差 (Mean square error, MSE)、平均绝对误差 (Mean absolute error, MAE) 以及决定系数 R^2 为损失函数分别执行 30 次实验, 结果表明, 以均方误差为损失函数的效果最好。因此选择均方误差为损失函数。

在 ANN 中, 为避免梯度消失, 设置隐藏层大小为 6, 激活函数为 sigmoid 函数, 训练 50 epochs。在 SVM 中, 设置惩罚因子为 1.0, 选择 RBF 核函数, 设置多项式次数为 3。

2.1 NEE 预测模拟结果

如图 5 所示, 深度学习模型均能在不同程度上较好地拟合 NEE, 预测变化趋势与实际值变化趋势较为一致, 但预测效果存在一定的差异。就整体预测结果而言, 加入注意力机制的预测结果比其他模型的拟合效果更好, 变化起伏更小, 预测效果更稳定, 全局无较大起伏的波动点。




图 5 各模型预测值与实际值对比

Fig. 5 Comparison of original and predictive values

加入注意力机制后预测效果比编码器-解码器网络略有提升, 长短期记忆网络只能够大致模拟出碳通量实际值的趋势。如图 6 所示, 各预测模型均不同程度地在 04:00—08:00 和 16:00—20:00 时段内呈现相对较大的起伏, 这是因为在这两个时段植物发生光合作用, 碳通量的变化幅度最大。由于碳通量随土壤温度等的变化具有延时性, 在变化幅度较大的时间段中, 预测的难度相对较大。




图 6 加入注意力机制后各模型预测值与实际值对比
Fig. 6 Comparison of original and predictive values after adding Attention mechanism

本文选择均方根误差 (Root mean square error, RMSE)、MAE、平均绝对百分误差 (Mean absolute percent error, MAPE)、 R^2 4 项指标评估模型预测的准确性。

如表 1 所示, 深度学习模型的精度指标相比传统机器学习模型 ANN、SVM 而言提升显著。而注意力机制模型 RMSE 为 $0.28 \mu\text{mol}/(\text{m}^2 \cdot \text{s})$, MAE 是 $0.18 \mu\text{mol}/(\text{m}^2 \cdot \text{s})$, R^2 为 0.93, 与普通深度学习模型长短期记忆网络和普通编码器-解码器网络相比更精确。

表 1 不同模型预测结果
Tab.1 Evaluation indices of different models

参数	Attention	Encoder-decoder	LSTM	RNN	ANN	SVM
RMSE/ ($\mu\text{mol} \cdot \text{m}^{-2} \cdot \text{s}^{-1}$)	0.28	0.37	0.38	0.58	0.42	0.36
MAE/ ($\mu\text{mol} \cdot \text{m}^{-2} \cdot \text{s}^{-1}$)	0.18	0.26	0.26	0.47	0.30	0.29
MAPE/%	11.87	13.02	17.16	24.65	98.63	35.07
R^2	0.93	0.66	0.64	0.12	0.64	0.59

2.2 NEE 预测稳定性结果

图 7 表明, 注意力机制的预测精度比普通深度学习模型编码器-解码器网络与长短期记忆网络更稳定。以多伦草原的 10 次预测结果 RMSE 为例, 标准差为 $0.002 \mu\text{mol}/(\text{m}^2 \cdot \text{s})$, 相比编码器-解码器网络和长短期记忆网络下降 0.005、0.036 $\mu\text{mol}/(\text{m}^2 \cdot \text{s})$ 。因此, 基于注意力机制的碳通量预测模型能够更稳定地进行预测。

综上所述, 基于注意力机制的模拟模型在长期




图7 模型稳定性对比

Fig.7 Comparison of stability of models

NEE 预测上不仅在预测精度上表现出良好的性能，并且具有较强的稳定性，可以挖掘相对于传统机器学习模型更深尺度的特征信息。

2.3 NEE 主要环境因子响应过程

2.3.1 NEE 日变化及季节变化

本文选取生长季5—9月 NEE 的数据进行分析。如图8所示，在生长季 NEE 日进程呈现为单峰型，而在非生长季呈现为双峰型趋势^[27]。昼间的 NEE 为负值(碳汇)，夜间的 NEE 为正值(碳源)。各月之间存在显著差异，生长季初期5月昼间生态系统碳吸收与夜间生态系统的呼吸都较弱。在生长旺季的7、8月，昼间生态系统碳吸收与夜间的呼吸都达到最强。另外，生态系统碳吸收的最强值均出现在10:00—12:00，随后下降，18:00以后，NEE 逐渐变为正值，由碳吸收转变为碳排放。生态系统碳吸收的日最强值为净碳交换量 $-3.51 \mu\text{mol}/(\text{m}^2 \cdot \text{s})$ ，夜间 NEE 的最大值为 $2.05 \mu\text{mol}/(\text{m}^2 \cdot \text{s})$ 。




图8 生长季与非生长季不同时期 NEE 的日变化曲线

Fig.8 Net ecosystem exchange in day-scale of growing and non-growing seasons in 2007

各月 NEE 的变化曲线如图9所示，1—3月均表现为碳吸收，4—7月表现为碳排放，在7月初时达到一年中的最大值，为 $1.90 \mu\text{mol}/(\text{m}^2 \cdot \text{s})$ ，7—8月间

生态系统的 NEE 开始下降，逐渐由碳源转换为碳汇，8月初达到碳吸收的最大值，净碳交换量为 $-1.01 \mu\text{mol}/(\text{m}^2 \cdot \text{s})$ 。9月初出现碳排放的最高值，之后随着温度下降碳排放也逐渐降低。从全年来看，该草原生态系统表现为碳汇，全年的碳吸收量为 $19.06 \text{ g}/\text{m}^2$ 。




图9 2007年不同时期净 NEE 的月份变化曲线

Fig.9 Net ecosystem exchange in month-scale of growing and non-growing seasons in 2007

2.3.2 环境因子的季节变化

2007 年全年观测的光量子通量密度 (PPFD)、空气温度 (T_a)、土壤温度 (T_s)、饱和水汽压差 (VPD)、土壤含水率 (SWC) 和降雨量 (P) 的变化如图10、11所示。通常，PPFD 受太阳高度角、天气、海拔影响。5—7月太阳高度角较高，PPFD 达到峰值，最大达到 $700 \mu\text{mol}/(\text{m}^2 \cdot \text{s})$ 。6月受到降水影响，PPFD 略有降低。8月之后 PPFD 随着太阳高度角的降低而逐渐下降，在12月末达到最小值。空气温度和土壤温度具有相同的季节变化趋势，最高值出现在7月，最低值出现在1月，土壤温度比空气温度平均高 3.14°C ，空气温度和土壤温度变化幅度分别为 $-20.90 \sim 23.82^\circ\text{C}$ 与 $-12.48 \sim 26.16^\circ\text{C}$ ，年平均值分别为 3.71 、 6.85°C 。年总降雨量为 258.01 mm ，其中5—9月生长季的总降雨量为 227.64 mm ，占全年降雨量的88%左右。土壤含水率的变化主要受到降雨量的影响。在3—9月保持着较高的含水率。VPD 同样具有明显的季节趋势，在6月达到最高值，为 25.34 hPa ，在1月达到最低值，为 0.32 hPa 。

2.3.3 NEE 对辐射的响应

如图12所示，4—9月上、下午草原生态系统的 NEE 与 PPFD 的关系表明，草原生态系统的 NEE 与 PPFD 之间有很好的直角双曲线关系^[28]。而非生长季上、下午生态系统的 NEE 与 PPFD 之间没有明显的曲线关系。生长季各月上、下午 NEE 随 PPFD 的变化速率存在明显差异，各月都是上午的 NEE 对 PPFD 的响应强于下午。在植物生长初期的5月，NEE 随 PPFD 的变化较缓慢，上、下午生态系统净光合速率的差异较小。6月的净光合速率明显高于5月，上、下午的净光合速率差值与5月相当，但当 PPFD 超过 $1250 \mu\text{mol}/(\text{m}^2 \cdot \text{s})$ 时，上、下午的差值略




图 10 PPFD、Ta、Ts、VPD、SWC 和 P 的月份变化曲线

Fig. 10 Photosynthetic photon flux density, air temperature, soil temperature, vapor pressure deficit, soil water content and precipitation in month-scale of growing and non-growing seasons in 2007




图 11 PPFD、Ts、Ta、VPD 的日变化曲线

Fig. 11 Photosynthetic photon flux density, soil temperature, air temperature and vapor pressure deficit in day-scale of growing and non-growing seasons in 2007




图 12 NEE 对 PPFD 的响应

Fig. 12 Response of net ecosystem exchange to photosynthetic photon flux density

有增大。然而,在生长旺盛季节的7、8月,生态系统的净光合速率达到最大。9月上、下午生态系统的净光合速率与6月相似。

2.3.4 NEE 对温度的响应

NEE 与土壤温度的关系如图 13 所示。当土壤

温度在 0℃ 以下时,土壤微生物活性很低,NEE 随土壤温度的变化不大;土壤温度在 0 ~ 15℃ 时,碳排放整体随土壤温度的升高而增大;土壤温度在 15℃ 以上时,NEE 随着土壤温度的升高而急剧增加。如图 14 所示,非生长季温度系数 Q_{10} 明显大于生长

季,在1月达到最大值,为5.96。




图 13 NEE 对 Ts 的响应

Fig. 13 Response of net ecosystem exchange to soil temperature




图 14 温度系数 Q_{10} 的月度变化

Fig. 14 Change of temperature coefficient Q_{10} in month-scale

2.3.5 NEE 对水分的响应

图 15 为 NEE 与 VPD 的关系。在 VPD 小于 5 hPa 时,NEE 增加速率较大。VPD 为 5 ~ 20 hPa 时,NEE 增长速率稍缓。VPD 大于 20 hPa 时,NEE 随着 VPD 的增加而减少。




图 15 NEE 对 VPD 的响应

Fig. 15 Response of net ecosystem exchange to vapor pressure deficit

3 讨论

3.1 辐射对 NEE 的影响

光合辐射是生态系统进行光合作用的能源。总体上,生长季 NEE 随着 PPFD 的增加而增加,呈现直线双曲线趋势^[29]。5 月生长初期,由于植物尚未发育完全,NEE 随 PPFD 的变化较缓慢。在 6—7 月,上午 NEE 随着 PPFD 的增加而增加,在午后,生态系统 NEE 随着 PPFD 的增加呈升高趋势,这是温度与辐射共同作用的结果,并且生态系统逐渐从碳排放转化为碳吸收。高原上的强辐射会使植物的光合器官受损^[30],为避免这种状况发生,植物的对策是被动关闭气孔,导致光合速率下降,造成植物的

“午休”现象^[31]。在 7 月,PPFD 处于一年的峰值,可以看到下午的 NEE 在午后同比上午有所减少。在 8—9 月,在相同的 PPFD 条件下,生态系统光合速率随着温度的升高而升高,碳吸收受到 PPFD 的作用最强,但与此同时,呼吸作用也随着温度的升高而增强,因此下午的碳吸收相比于上午略减弱。10 月后非生长季 PPFD 开始逐渐回落,并失去双曲线趋势。

3.2 温度对 NEE 的影响

温度同时影响生态系统的光合作用和呼吸作用。多伦草原海拔较高,生态系统的温度相对较低,在生长旺季的 7 月日平均温度为 20.00℃,而在生长淡季日最低温度可达到 -20.91℃。低温环境导致植物分解速率变慢,土壤中有有机碳含量通常较高^[32]。

除此之外,多伦草原生态系统的昼夜温差大,有利于生态系统的碳积累^[33-34]。在生长旺季 7—8 月,昼夜温差可达到约 23℃。其中 6 月植被未发育完全,相对受 PPFD 的影响较小,上下午温度差距显著,下午温度可达到 25℃左右,NEE 相比增加。

午后温度的升高在增加光合作用的同时也增加呼吸作用^[35]。其中由图 10 可知,在 9 月,此时温度与 8 月基本持平,但 PPFD 有下降的趋势,因此相比光合作用呼吸作用的效果体现得更强,因此碳吸收的效果相较 8 月而言明显减弱。

3.3 水分对 NEE 的影响

水分是影响碳收支的重要因素之一。本研究的年总降雨量为 258.01 mm,且主要集中于生长季 5—9 月。由图 10 可知,该期间土壤含水率(SWC)一直维持稳定水平,因此,在生长季水分不是影响生态系统 NEE 的主要因素。VPD 是空气中水汽含量的描述,VPD 较少时,NEE 随着 VPD 的增加而增加,而当 VPD 达到一定程度时,NEE 的增加速率放缓。VPD 继续增加,致使植物气孔关闭阻塞,影响植物呼吸,NEE 随着 VPD 的增加而迅速减少^[36]。

多伦草原辐射较强,而温度和 VPD 相对较低。一年中生长季 5—9 月的辐射、温度、VPD 处于高值。根据图 11 可知,午后的温度和 VPD 均处于较高水平,有利于生态系统的光合作用,但同时温度的升高也加剧系统的呼吸作用。

3.4 NEE 环境因子重要性的季节性变化

各环境因子共同影响生态系统的碳收支相互制约。图 16 为各环境因子之间对 NEE 影响重要性的月份变化曲线。可以看到,由非生长季向生长季过渡的 3—4 月间,PPFD(33.5)与 VPD(30.0)对 NEE 的变化起主导作用。进入生长季后的 5—6 月间,对比图 10 可以发现此时 P(5.4)相对较少,因此 SWC

(50.5)是 NEE 的变化主要影响因素。进入 7 月, P(3.8)依然较少,因此 PPFD(26.8)与 SWC(60.1)协同作用 NEE 的变化。8 月 PPFD(2.8)与 SWC(6.9)由于 7 月底的降雨而变得相对充足,因此 VPD(41.5)与 P(42.7)成为影响 NEE 的主要因素。9 月后 PPFD 与 P 均急剧减少并维持稳定,并且根据图 14 可知,非生长季温度系数 Q_{10} 较生长季高,因此非生长季 NEE 主要与生态系统的呼吸




图 16 各环境因子对 NEE 影响重要性的月度变化曲线

Fig. 16 Changes of importance of environment factors effects on net ecosystem exchange in month-scale

直接关联,在非生长季 1—3 月 T_s (44.6)与 10—12 月 T_s (54.2)通过影响植物呼吸成为影响 NEE 的决定性因子。

4 结论

(1)在内蒙古多伦草原生态系统的实验结果表明,深度学习模型在日尺度、月尺度与年尺度上的特征学习与拟合效果均优于传统机器模型。同时,注意力机制模型在预测稳定性上较编码器-解码器网络模型与长短期记忆网络这些普通深度学习模型更具优势。

(2)全年来看,内蒙古多伦草原生态系统表现为微弱的碳汇,碳吸收能力远低于世界上其他草原生态系统^[37],其中,在生长季 4—7 月表现为碳源,而生长季 8—9 月以及非生长季表现为碳汇^[38]。

(3)内蒙古多伦草原生态系统的 NEE 主要受辐射、温度、土壤含水率和降雨量的影响。

参 考 文 献

[1] 耿元波,董云社,齐玉春. 草地生态系统碳循环研究评述[J]. 地理科学进展,2004,23(3):74-81.
GENG Yuanbo,DONG Yunshe,QI Yuchun. Review on the carbon cycle of grassland ecosystems[J]. Advance in Earth Sciences, 2004,23(3):74-81. (in Chinese)

[2] FRANK A B,DUGAS W A. Carbon dioxide fluxes over a northern,semiarid,mixed-grass prairie[J]. Agricultural and Forest Meteorology,2001,108(4):317-326.

[3] WALKER A P,ZAEHLE S,MEDLYN B E,et al. Predicting long-term carbon sequestration in response to CO₂ enrichment: how and why do current ecosystem models differ? [J]. Global Biogeochemical Cycles,2015,29(4):476-495.

[4] 董恒,郭宏,袁艳斌. 基于日光诱导叶绿素荧光的陆地生态系统 GPP 估算研究[J/OL]. 农业机械学报,2019,50(2):205-211.
DONG Heng,GUO Hong,YUAN Yanbin. Estimation of terrestrial ecosystem GPP based on sun-induced chlorophyll fluorescence [J/OL]. Transactions of the Chinese Society for Agricultural Machinery,2019,50(2):205-211. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20190223&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2019.02.023. (in Chinese)

[5] SCHINDLER D E,HILBORN R. Prediction,precaution,and policy under global change[J]. Science,2015,347:953-954.

[6] CRISCI C,GHATTAS B,PERERA G. A review of supervised machine learning algorithms and their applications to ecological data[J]. Ecological Modelling,2012,240:113-122.

[7] MICHENER W K,JONES M B. Ecoinformatics: supporting ecology as a data-intensive science[J]. Trends in Ecology & Evolution,2012,27(2):85-93.

[8] PETERS D P C,HAVSTAD K M,CUSHING J,et al. Harnessing the power of big data: infusing the scientific method with machine learning to transform ecology[J]. Ecosphere,2014,5(6):1-15.

[9] HUNTZINGER D N,POST W M,WEI Y,et al. North American Carbon Program (NACP) regional interim synthesis: terrestrial biospheric model intercomparison[J]. Ecological Modelling,2012,232:144-157.

[10] 齐建东,黄金泽,贾昕. 基于 XGBoost-ANN 的城市绿地净碳交换模拟与特征响应[J/OL]. 农业机械学报,2019,50(5):269-278.
QI Jiandong,HUANG Jinze,JIA Xin. Simulation of NEE and characterization of urban green-land ecosystem responses to climatic controls based on XGBoost-ANN [J/OL]. Transactions of the Chinese Society for Agricultural Machinery,2019,50(5):269-278. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20190531&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2019.05.031. (in Chinese)

[11] ICHII K,UEYAMA M,KONDO M,et al. New data-driven estimation of terrestrial CO₂ fluxes in Asia using a standardized database of eddy covariance measurements, remote sensing data, and support vector regression[J]. Journal of Geophysical Research: Biogeosciences,2017,122(4):767-795.

[12] WEI S,YI C,FANG W,et al. A global study of GPP focusing on light-use efficiency in a random forest regression model[J]. Ecosphere,2017,8(5):e01724.

[13] DOU X,YANG Y,LUO J. Estimating forest carbon fluxes using machine learning techniques based on eddy covariance measurements[J]. Sustainability,2018,10(1):203.

[14] JUNG M,REICHSTEIN M,BONDEAU A. Towards global empirical upscaling of FLUXNET eddy covariance observations: validation of a model tree ensemble approach using a biosphere model[J]. Biogeosciences,2009,6(10):2001-2013.

[15] LIU Z,PENG C,WORK T,et al. Application of machine-learning methods in forest ecology: recent progress and future challenges[J]. Environmental Reviews,2018,26(4):339-350.

[16] GAMBOA J C B. Deep learning for time-series analysis[J]. arXiv preprint arXiv:1701.01887,2017.

- [17] BAHDANAU D, CHO K, BENGIO Y, et al. Neural machine translation by jointly learning to align and translate[C] // 3rd International Conference on Learning Representations, San Diego, 2015.
- [18] 郭群, 李胜功, 胡中民, 等. 内蒙古温带草原典型草地生态系统生产力对水分在不同时间尺度上的响应[J]. 中国沙漠, 2015, 35(3): 616–623.
GUO Qun, LI Shengong, HU Zhongmin, et al. Response of gross primary productivity to water availability at different temporal scales in a typical steppe in Inner Mongolia temperate steppe[J]. Journal of Desert Research, 2015, 35(3): 616–623. (in Chinese)
- [19] CHEN S, CHEN J, LIN G, et al. Energy balance and partition in Inner Mongolia steppe ecosystems with different land use types[J]. Agricultural and Forest Meteorology, 2009, 149(11): 1800–1809.
- [20] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735–1780.
- [21] SUTSKEVER I, VINYALS O, LE Q V. Sequence to sequence learning with neural networks[C] // Advances in Neural Information Processing Systems, 2014: 3104–3112.
- [22] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45(1): 5–32.
- [23] BREIMAN L, FRIEDMAN J H, OLSHEN R A, et al. Classification and regression trees. Belmont, CA: Wadsworth[J]. International Group, 1984, 432: 151–166.
- [24] MENZE B H, KELM B M, MASUCH R, et al. A comparison of random forest and its Gini importance with standard chemometric methods for the feature selection and classification of spectral data[J]. BMC Bioinformatics, 2009, 10: 213.
- [25] FRIEDMAN A D, ARNETH A, KIANG N Y, et al. FLUXNET and modelling the global carbon cycle[J]. Global Change Biology, 2007, 13(3): 610–633.
- [26] REICHSTEIN M, FALGE E, BALDOCCHI D, et al. On the separation of net ecosystem exchange into assimilation and ecosystem respiration: review and improved algorithm[J]. Global Change Biology, 2005, 11(9): 1424–1439.
- [27] 李琪, 王云龙, 胡正华, 等. 基于涡度相关法的中国草地生态系统碳通量研究进展[J]. 草业科学, 2010, 27(12): 38–44.
LI Qi, WANG Yunlong, HU Zhenghua, et al. Research progress on carbon flux of grassland ecosystem based on the eddy covariance method in China[J]. Pratacultural Science, 2010, 27(12): 38–44. (in Chinese)
- [28] 张法伟, 李英年, 曹广民, 等. 青海湖北岸高寒草甸草原生态系统 CO₂ 通量特征及其驱动因子[J]. 植物生态学报, 2012, 36(3): 187–198.
ZHANG Fawei, LI Yingnian, CAO Guangmin, et al. CO₂ fluxes and their driving factors over alpine meadow grassland ecosystems in the northern shore of Qinghai Lake, China[J]. Chinese Journal of Plant Ecology, 2012, 36(3): 187–198. (in Chinese)
- [29] 刘允芬, 宋霞, 孙晓敏, 等. 千烟洲人工针叶林 CO₂ 通量季节变化及其环境因子的影响[J]. 中国科学: D 辑, 2004, 34(2): 109–117.
LIU Yunfen, SONG Xia, SUN Xiaomin, et al. Seasonal changes of CO₂ flux in artificial coniferous forest in Qianyanzhou and the impact of environmental factors[J]. Science in China Series D—Earth Sciences, 2004, 34(2): 109–117. (in Chinese)
- [30] 周志勇. 土地利用方式对内蒙古农牧交错区草地生态系统的影响[D]. 北京: 中国科学院植物研究所, 2006: 41–45.
ZHOU Zhiyong. Effects of land-use change on grassland ecosystems in an agro-pastoral ecotone of Inner Mongolia[D]. Beijing: Institute of Botany, the Chinese Academy of Sciences, 2006: 41–45. (in Chinese)
- [31] 师生波, 韩发, 贲桂英. 高寒矮嵩草草甸群落光合作用的“午休”现象[J]. 植物生理学报, 1997, 23(4): 405–409.
SHI Shengbo, HAN Fa, BEN Guiying. “Lunch break” in photosynthesis of *Kobresia pygmaea* meadow community[J]. Plant Physiology Journal, 1997, 23(4): 405–409. (in Chinese)
- [32] KATO T, TANG Y, GU S, et al. Carbon dioxide exchange between the atmosphere and an alpine meadow ecosystem on the Qinghai–Tibetan Plateau, China[J]. Agricultural and Forest Meteorology, 2004, 124(1–2): 121–134.
- [33] 朱志鹏, 马耀明, 胡泽勇, 等. 青藏高原那曲高寒草甸生态系统 CO₂ 净交换及其影响因子[J]. 高原气象, 2015, 34(5): 1217–1223.
ZHU Zhikun, MA Yaoming, HU Zeyong, et al. Net ecosystem carbon dioxide exchange in alpine meadow of Nagchu region over Qinghai–Xizang plateau[J]. Plateau Meteorology, 2015, 34(5): 1217–1223. (in Chinese)
- [34] 赵亮, 徐世晓, 李英年, 等. 青藏高原矮嵩草草甸和金露梅灌丛草甸 CO₂ 通量变化与环境因子的关系[J]. 西北植物学报, 2006, 26(1): 139–148.
ZHAO Liang, XU Shixiao, LI Yingnian, et al. Relations between carbon dioxide fluxes and environmental factors of *Kobresia humilis* meadows and *Potentilla fruticosa* meadows[J]. Acta Botanica Boreali-Occidentalia Sinica, 2006, 26(1): 139–148. (in Chinese)
- [35] 马骏, 唐海萍. 内蒙古农牧交错区不同土地利用方式下土壤呼吸速率及其温度敏感性变化[J]. 植物生态学报, 2011, 35(2): 167–175.
MA Jun, TANG Haiping. Variations of soil respiration rate and its temperature sensitivity among different land use types in the agro-pastoral ecotone of Inner Mongolia[J]. Chinese Journal of Plant Ecology, 2011, 35(2): 167–175. (in Chinese)
- [36] 张利平, 王新平, 刘立超, 等. 沙坡头主要建群植物油蒿和柠条的气体交换特征研究[J]. 生态学报, 1998, 18(2): 23–27.
ZHANG Liping, WANG Xiping, LIU Lichao, et al. Study on gas exchange characteristics of main constructive plants *A. ordosica* and *C. korshinskii* in shapou region[J]. Acta Ecologica Sinica, 1998, 18(2): 23–27. (in Chinese)
- [37] 吴力博, 古松, 赵亮, 等. 三江源地区人工草地的生态系统 CO₂ 净交换、总初级生产力及其影响因子[J]. 植物生态学报, 2010, 34(7): 770–780.
WU Libo, GU Song, ZHAO Liang, et al. Variation in net CO₂ exchange, gross primary production and its affecting factors in the planted pasture ecosystem in Sanjiangyuan Region of the Qinghai–Tibetan Plateau of China[J]. Chinese Journal of Plant Ecology, 2010, 34(7): 770–780. (in Chinese)
- [38] 孔玉华, 姚风军, 鹏爽, 等. 不同利用方式下草地土壤碳积累及汇/源功能转换特征研究[J]. 草业科学, 2010, 27(4): 44–49.
KONG Yuhua, YAO Fengjun, PENG Shuang, et al. Study on the characteristics of soil carbon accumulation and conversion of carbon sink and source of grassland under different land use types[J]. Pratacultural Science, 2010, 27(4): 44–49. (in Chinese)