

doi:10.3969/j.issn.1000-6362.2021.04.007

周宇,黄辉,张劲松,等.森林生态系统涡度相关法碳通量长时间连续性缺失数据插补方法的比较[J].中国农业气象,2021,42(4):330-343

森林生态系统涡度相关法碳通量长时间连续性缺失数据插补方法的比较*

周宇^{1,2,3}, 黄辉^{1,2,3}, 张劲松^{1,2,3**}, 孟平^{1,2,3}, 孙守家^{1,2,3}

(1.中国林业科学研究院林业研究所, 北京 100091; 2.国家林业和草原局林木培育重点实验室, 北京 100091; 3.南京林业大学南方现代林业协同创新中心, 南京 210037)

摘要: 针对森林通量观测站涡度相关法碳通量观测普遍存在的长时间连续性数据缺失情景, 为探究不同数据插补方法的有效性, 以华北低丘山地栓皮栎人工混交林生态系统为例, 以经 EddyPro 处理和质量控制的 2017 年 3 月 1 日-11 月 30 日 0.5h 尺度净生态系统碳交换 (NEE) 数据为基准数据集, 随机生成含有连续 1、3、7、15 和 31d 数据缺失的 5 类数据缺失集, 重复 10 次, 使用固定窗口平均昼夜变化法 (MDV)、可变窗口平均昼夜变化法 (MDC)、查表法 (LUT)、非线性回归法 (NLR)、边际分布采样法 (MDS)、人工神经网络法 (ANN) 对缺失数据集进行插补, 并将插补数据与实际观测数据进行对比, 通过分析统计参数来评估不同方法的插补精度和稳定性, 以评估不同方法的适用范围。结果表明: 日间, 当连续缺失少于 15d 时, ANN 方法插补数据与实测数据间的 R^2 (决定系数) 相对较高, NLR 方法的 R^2 较低; LUT 方法插补数据与实测数据间的相对均方根误差 (RRMSE) 较低, NLR 方法的 RRMSE 较高。当缺失达到连续 15d 时, 除 NLR 方法的 R^2 显著较低 ($P<0.05$) 外, 其它方法间 R^2 差异不显著; LUT 方法的 RRMSE 显著 ($P<0.05$) 较低, 其它方法间 RRMSE 差异不显著。当缺失达到连续 31d 时, 除 NLR 方法 R^2 显著较低 ($P<0.05$) 外, 各方法间 R^2 和 RRMSE 无显著差异; MDV 方法的平均绝对误差 (MAE) 出现较多异常值, 各方法间的 MAE 开始出现分化的趋势。随着缺失片段长度的增加, 除 MDV 方法外, 各方法的 R^2 呈下降趋势, 连续 1d 缺失与连续 31d 缺失情景下插补所得 NEE 与实测 NEE 的 R^2 差异显著 ($P<0.05$); MDV 和 MDS 方法的 RRMSE 呈增大趋势, 连续 1d 缺失与连续 31d 缺失情景下的 RRMSE 差异显著 ($P<0.05$), 其它方法的 RRMSE 差异相对不显著。夜间, 在各缺失情景下, ANN 方法的 R^2 较高, LUT 方法的 R^2 较低, 二者之间差异显著 ($P<0.05$); LUT 方法的 RRMSE 最高, 与其它方法存在显著差异 ($P<0.05$)。在连续缺失大于 31d 的情景下, 各方法的 RRMSE 差异均不显著。除 LUT 方法 MAE 显著 ($P<0.05$) 较高外, 其它方法的 MAE 无明显差异。随着缺失片段长度的增加, MDC、MDS 和 ANN 方法插补数据的 R^2 呈下降趋势, MDV 和 LUT 的 R^2 始终无显著差异; 各方法的 RRMSE 差异无显著变化。在对典型晴天 0.5h 尺度上 NEE 日变化趋势的还原方面, MDC 方法性能相对较优。综上, NLR 方法适用于气象数据完备、NEE 数据连续缺失少于 7d 的情景; MDV 或 MDC 方法适用于气象数据不可用或缺失严重、NEE 数据连续缺失少于 15d 的情景; LUT 和 MDS 方法则适用于气象数据缺失较少、NEE 数据连续缺失少于 15d 的情景; ANN 方法适用性相对较广, 可用于气象数据缺失较少、NEE 数据连续缺失长达 31d 的情景。

关键词: 涡度相关; 数据插补; 净生态系统碳交换; 固定窗口平均昼夜变化法 (MDV); 可变窗口平均昼夜变化法 (MDC); 查表法 (LUT); 非线性回归法 (NLR); 边际分布采样法 (MDS); 人工神经网络法 (ANN)

* 收稿日期: 2020-09-28

基金项目: 中央级公益性科研院所基本科研业务费专项资金项目 (CAFYBB2018ZA001; CAFYBB2017ZX002)

** 通讯作者: 张劲松, 研究员, 研究方向为林业气象, E-mail: zhangjs@caf.ac.cn

第一作者联系方式: 周宇, E-mail: zhouyucaf@126.com

Comparison of Gap-filling Methods for Long-term Continuous Missing Data in Carbon Flux Observation by Eddy Covariance Method of Forest Ecosystem

ZHOU Yu^{1,2,3}, HUANG Hui^{1,2,3}, ZHANG Jin-song^{1,2,3}, MENG Ping^{1,2,3}, SUN Shou-jia^{1,2,3}

(1. Research Institute of Forestry, Chinese Academy of Forestry, Beijing 100091, China; 2. Key Laboratory of Tree Breeding and Cultivation, National Forestry and Grassland Administration, Beijing 100091; 3. Co-Innovation Center for Sustainable Forestry in Southern China, Nanjing Forestry University, Nanjing 210037)

Abstract: There are often 20% to 65% data-missing in annual carbon flux observed by the eddy covariance method in the mountainous forest ecosystem, and there may also be continuous data-missing for a long period, as long as half a month, or even a month. To obtain complete and reliable flux data, reasonable imputation methods need to be adopted to impute the missing data. To explore the validity and performance of different gap-filling methods, five types of data-missing sets were generated with consequent 1 day, 3 days, 7 days, 15 days, 31 days data missing randomly and repeated 10 times, using the half-hourly NEE(Net Ecosystem Exchange) data in March 1st-November 30th, 2017 of a mixed *Quercus variabilis* plantation ecosystem in North China low-hills regions calculated by EddyPro as a benchmark dataset, then Mean Diurnal Variation with fixed window(MDV), Mean Diurnal Variation with variable window(MDC), Look-Up Table(LUT), Non-Linear Regression(NLR), Marginal Distribution Sampling(MDS), and Artificial Neural Network(ANN) were used to interpolate the artificial sets. By comparing the imputed data with the actual observed data, the interpolation accuracy, stability and scope of each method were evaluated through statistical parameters. The results indicated that the effect of interpolation at daytime was significantly better than that at night. During the daytime, when the consecutive missing was less than 15 days, the R^2 (coefficient of determination) between the interpolated NEE and the observed NEE of ANN was relatively higher, and that of NLR was lower, the Relative Root Mean Square Error(RRMSE) between the interpolated NEE and the observed NEE of LUT was lower, and that of NLR was higher. When the deletion reached 15 consecutive days, except for the significantly lower R^2 of NLR($P<0.05$), the difference of R^2 among other methods was not significant; the RRMSE of LUT was significantly lower ($P<0.05$), and the difference of RRMSE between other methods was not significant. When the deletion reached 31 consecutive days, except for the significantly lower R^2 of NLR($P<0.05$), there was no significant difference in R^2 and RRMSE among the methods. The Mean Absolute Error(MAE) of MDV had more outliers, and the MAE between the methods began to differentiate trend. As the length of the missing fragments increased, except for MDV, the R^2 of other methods showed a downward trend and there was a significant difference between the consecutive 1d-data-missing and 31d-data-missing scenarios($P<0.05$). Moreover, the RRMSE of MDV and MDS showed an increasing trend and there was a significant difference in RRMSE between the continuous 1d-data-missing and continuous 31d-data-missing scenarios($P<0.05$), while the difference of RRMSE of other methods was relatively insignificant. At night, in each data-missing scenario, the R^2 of ANN was higher, and that of LUT was lower, with a significant difference($P<0.05$); the RRMSE of LUT was the highest, which was significantly different from other methods($P<0.05$). In the scenario where the deletion was greater than 31 days, the difference of RRMSE of each method was not significant; except for LUT which had a significantly higher MAE($P<0.05$), there was no significant difference in the MAE of other methods. As the length of the missing fragment increased, the R^2 of MDC, MDS and ANN showed a downward trend, and there was always no significant difference in R^2 between MDV and LUT; moreover, there was no significant change in the RRMSE difference of each method. The performance of the MDC method was relatively optimal in terms of restoring the daily change trend of NEE on the 0.5h scale of a typical sunny day. Due to the difference in interpolation strategies, the effects of different gap-filling methods were different. ANN generally worked well, while the NLR performed relatively poorly;

LUT performed significantly better during the day than at night, with an underestimation of NEE at night. There was no significant difference between MDV, MDC and MDS. What's more, the imputation effects of different gap-filling methods were related to the duration of continuous data missing. In conclusion, NLR is suitable for scenarios where weather data is complete and NEE data is missing for less than 7 days. MDV and MDC are suitable for weather data that is unavailable or missing severely, and NEE data is missing for less than 15 days, but MDC is preferred. LUT and MDS are suitable for weather scenarios where there are fewer data missing and NEE data missing continuously for less than 15 days. ANN has relatively wide applicability and can be used in scenarios where there are fewer meteorological data missing and NEE data missing continuously for up to 31 days. In addition to site factors, differences in time steps and window sizes selected by different gap-filling methods will also affect the result of the imputation of missing flux data, which in turn affects the applicability of each gap-filling method. As this study only considered a single site with one-year data of carbon flux, except winter, the actual missing distribution was ignored when constructing the artificial data-missing sets and the selected gap-filling methods had different time steps and window sizes, the result may not be applicable to all sites, but it can provide a reference for the selection of gap-filling methods for other sites. At the same time, the carbon flux data obtained by the above methods may be quite different from the actual, significantly overestimated, if the data-missing was caused by the influence of abnormal weather such as precipitation and dew, especially MDV and MDC which not considering meteorological factors. To accurately estimate this part of carbon flux, a better way may be combining the open-path eddy covariance observation system with the closed-path eddy covariance observation system to find out a corresponding data correction method.

Key words: Eddy covariance; Gap-filling; Net ecosystem carbon exchange; Mean Diurnal Variation(MDV) ; Look-Up Table(LUT) ; Non-Linear Regression(NLR) ; Marginal Distribution Sampling(MDS) ; Artificial Neural Network(ANN)

涡度相关法是目前测定大气与植被群落间净 CO_2 交换 (NEE) 最直接、理论与技术发展最为迅速的一种微气象学方法, 得到微气象学和生态学界的广泛接受和认可, 广泛应用于全球不同陆地生态系统的物质与能量交换研究中, 其观测数据也经常应用于各种模型的检验和验证^[1]。由于涡度相关观测仪器需要定期进行校准和维护, 观测过程中经常遇到难以避免的系统故障 (仪器故障或供电系统故障等) 和外界干扰 (暴雨、连续阴雨、雾霾等恶劣天气条件等), 涡度相关观测系统的原始数据往往会出现缺失; 而在对通量数据进行数据质量控制后, 如进行异常值剔除、低湍流条件 (如夜间大气层结稳定等) 下数据的剔除等, 观测数据又会出现新的缺失。最终, 年通量观测数据往往存在 20%~65% 的缺失, 其中还可能出现较长时段的连续缺失 (长达半个月, 甚至一个月)^[2-4]。为了获取完整和可靠的通量数据, 需要采取合理的插补方法对缺失数据进行插补^[5]。

目前, 常用的数据插补方法主要有平均昼夜变化法 (Mean Diurnal Variation, MDV)、查表法

(Look-Up Table, LUT)、非线性回归法 (Non-Linear Regression, NLR)、边际分布采样法 (Marginal Distribution Sampling, MDS) 和人工神经网络法 (Artificial Neural Network, ANN) 等^[3,6-15]。选择不同的插补方法会产生不同的结果^[1]。MDV 方法不依赖通量和环境变量的函数关系, 插补夜间数据适合 7d 的窗口, 而日间适合 14d 的窗口, 在极端晴天或阴天条件下容易产生估算偏差^[6]。LUT 方法通过气象变量建立索引表估计 NEE, 日间最适合使用气温, 夜间适合使用土壤温度, 而 NLR 方法则利用生态系统呼吸方程和光响应曲线估算 NEE。LUT 和 NLR 方法的各个环境变量的分组越详细, 插补效果越好, 但均受到建立索引表或回归方程时所选取的时间阶段、站点光响应曲线的离散性、云量和干旱等因素的影响^[6]。MDS 方法综合了 MDV 与 LUT 方法, 自动延长插补窗口, 不需假设环境响应方程和预设初始值, 被欧洲通量网和 FLUXNET (全球长期通量观测网络) 用作标准化处理^[10]。ANN 方法在处理不同数量级和非连续变量方面具有巨大

的优势, 可通过更多的变量对 NEE 进行插补, 但在某些情况下输出结果可能不稳定^[7]。是否进行 u^* 校正对计算结果影响很大, u^* 校正通常使年总 NEE 更偏正^[6]。保留 NEE 与气象变量间基本生态学响应关系的方法能够取得较为认同的插补结果。综上, 以往针对通量数据缺失插补方法的研究, 大多关注不同插值方法在较短时间缺失情景下的插补性能, 对不同方法在长时段且连续缺失情景下的插补精度和稳定性及其能够取得较好插补效果的缺失范围关注较少, 且一直未形成通用的缺失数据插补方案。

本研究以华北低丘山地栓皮栎人工混交林生态系统为例, 以基于涡度相关法观测得到的 NEE 数据为研究对象, 在随机生成连续 1、3、7、15 和 31d 数据缺失的情景下, 选取平均昼夜变化法 (MDV)、查表法 (LUT)、非线性回归法 (NLR)、边际分布采样法 (MDS) 和人工神经网络法 (ANN) 分别对 50 个缺失数据集进行 NEE 数据插补, 探究不同插值方法在不同缺失情景下的插补精度和稳定性, 并评估不同插值方法对缺失片段长度的敏感性, 探讨不同插补方法所适用的连续数据缺失时长, 以期为山地森林生态系统涡度相关法通量观测数据插补方法的选择提供参考, 为准确估算区域碳收支、预测气候变化对碳储存及碳汇的影响、深入量化净生态系统碳交换等提供理论基础。

1 数据与方法

1.1 基准数据集

通量观测地点位于黄河小浪底森林生态系统国家野外定位观测研究站南山观测区 (35°01'45"N, 112°28'08"E, 海拔 410m)。该站位于河南省济源市辖区, 地处太行山南麓与黄河中游的交错带。观测对象为栓皮栎 (*Quercus variabilis* Bl.)、侧柏 [*Platycladus orientalis* (L.) Franco] 和刺槐 (*Robinia pseudoacacia*) 人工混交林生态系统, 造林时间分别为 1972 年、1974 年和 1976 年, 平均株高分别为 10.5、8.2 和 9.3m, 主要树种为栓皮栎 (约占 80%)。研究区属暖温带亚湿润季风气候, 年平均气温为 12.4℃。历年平均降水量为 641.7mm, 受季风气候影响, 降水季节分配不均匀, 5–9 月平均降水量为 438.0mm, 占全年的 68.3%^[16]。生长季风向以东北偏东、西南方

向为主。

涡度相关通量观测系统由 CSAT3 型三维超声风速仪 (USA)、LI-7500A 型开路式 CO₂/H₂O 气体分析仪 (USA) 组成, 安装高度距地面 36m。数据采集器为 SmartFlux 型 (USA), 原始数据采样频率为 10Hz^[17]。

小气候梯度观测系统包括 7 层 HMP155 型温湿度传感器 (安装高度分别为 5、8、11、14、18、26 和 32m), 6 层 WindSonic 型二维超声风速计 (安装高度分别为 5、8、11、14、18 和 26m), CNR1 型四分量辐射计 (安装高度为 17m), 3 层土壤温湿度传感器 (安装深度分别为 5、10 和 20cm), 土壤热通量计 2 个 (分别位于塔的东西两侧)^[18]。数据采集器为 CR1000 型, 数据存储间隔为 10min。

选取 2017 年 3 月 1 日–11 月 30 日 10Hz 通量观测数据, 经涡度协方差数据分析软件 EddyPro (USA) 处理后, 剔除数据质量标记为不可用的数据^[19–20], 使用 R Package ‘REddyProc’ (<https://github.com/bgctw/REddyProc>) 计算摩擦风速阈值^[10,21–22], 剔除低湍流条件 (摩擦风速小于 0.22m·s⁻¹) 下的观测数据^[23], 将最终获得的 0.5h 尺度净生态系统碳交换量 (NEE) 数据作为基准数据集。NEE 基准数据集共有 13200 条数据, 数据缺失率为 39%, 其中白天 ($R_g > 20 \text{ W} \cdot \text{m}^{-2}$) 数据缺失率为 32%, 夜间 ($R_g \leq 20 \text{ W} \cdot \text{m}^{-2}$) 数据缺失率为 48%。将小气候观测系统 10min 气象数据聚合为 30min, 数据缺失率为 9%, 小于 2h 的缺失数据用线性内插法插补, 大于 2h 的缺失数据采用平均昼夜变化法 (MDV) 进行插补, 选择 18m 位置处气温 (T_a)、饱和水汽压差 (VPD)、17m 处总辐射 (R_g) 作为气象基准数据集, 用于数据插补。

1.2 数据缺失情景

为评估不同插值方法对缺失片段长度的敏感性, 随机生成缺失片段重复次数不同, 但缺失总数大致相同, 以连续 1、3、7、15 和 31d 数据为缺失片段的 5 类数据缺失情景 (表 1), 各缺失片段分布均服从随机分布, 每类缺失约占基准数据集的 10%。为提高数据利用率, 保证计算结果的准确性和稳定性, 各类情景随机重复 10 次, 并与基准数据集相叠加, 生成 50 个缺失数据集。

表 1 五类数据缺失情景

Table 1 Description of five gap scenarios

缺失片段长度 Unit gap length(d)	单位缺失片段包含 0.5h 尺度数据点个数 Nr. of data-points on the 0.5h scale in unit gap	缺失片段重复次数 Nr. of unit gap in scenario	总 0.5h 尺度缺失数据点个数 Nr. of data-points on the 0.5h scale in scenario
1	48	30	1440
3	144	10	1440
7	336	4	1344
15	720	2	1440
31	1488	1	1488

1.3 数据插补方法

1.3.1 平均昼夜变化法

平均昼夜变化法 (MDV) 使用邻近一段时间内相同时段的观测平均值来代替缺失值, 分为独立窗口法和滑动窗口法^[6]。独立窗口法使用特定窗口内任一时间点在该时刻所有有效观测数据的平均值来代替缺失值 (一般要求窗口内至少有 4 个有效观测数据), 滑动窗口法则使用缺失数据周围指定大小窗口内的所有有效观测数据的平均值来代替缺失值。窗口大小通常为 4~15d。采用独立窗口法, 即

$$\bar{X}_{h,i} = \bar{X}_{h,k=n(i-1)+1,\dots,ni} \quad (1)$$

式中, $h(1, \dots, 48)$ 为一天中每 0.5h 的索引, $i[1, \dots, \text{integer}(d/n)+1]$ 为平均窗口的索引, n 为窗口大小, d 为一年的天数, k 为一中间变量, 上划线表示排除缺失数据后对该上滑线下的子集进行算术平均, 下划线表示消除子集中缺失值后的索引。窗口大小选择: (1) 固定窗口大小为 15d, 在连续缺失长达 31d 情景下扩大为 30d; (2) 可变窗口, 先以 7d 为窗口插补数据, 若还有数据缺失, 则逐步扩大窗口为 14d、21d、28d..., 直至完成全部缺失数据插补。分别使用 Excel 和 R Package 'REddyProc' sEddyProc_sFillMDC 命令基于窗口 (1) 和 (2) 进行缺失 NEE 数据插补, 分别记为 MDV 和 MDC。

1.3.2 查表法

查表法 (LUT) 基于 6 个双月或 4 个季节时段, 建立特定站点各种气象条件下的 NEE 索引表, 根据缺失数据时段的气象条件在 NEE 索引表中查找相似环境下的 NEE 来代替缺失数据^[6]。通常选取光强和温度作为索引因子, 光强以 $100\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$ 的间隔从 0 渐增至 $2200\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$, 温度以 2°C 的间隔从可能最低温度到可能最高温度, 缺失 NEE 数据用线性内插法生成。使用 R Package 'REddyProc'

sEddyProc_sFillLUT 命令建立季节索引表进行数据插补, 记为 LUT。

1.3.3 非线性回归法

非线性回归法 (NLR) 基于参数化非线性方程, 通过建立一定时间内有效 NEE 观测值与相关环境因子 (如温度和光强) 的经验方程, 根据缺失时段的环境因子估算缺失的 NEE^[3,6,14]。通常, 将日间与夜间的 NEE 数据分开处理, 使用呼吸方程来计算夜间 NEE (等于夜间生态系统呼吸), 使用光响应方程结合日间生态系统呼吸来计算日间 NEE; 进行回归分析的时段无明确限定。使用 R Package 'Nonlinear Least Squares' nls 命令拟合 Lloyd & Taylor 方程和 Michaelis-Menten 方程进行数据插补, 记为 NLR。

呼吸方程, 即 Lloyd & Taylor 方程为^[6,24]

$$F_{\text{RE},\text{night}} = F_{\text{RE},T_{\text{ref}}} \exp \left[E_0 \left(\frac{1}{T_{\text{ref}} - T_0} - \frac{1}{T_k - T} \right) \right] \quad (2)$$

式中, $F_{\text{RE},\text{night}}$ 为夜间生态系统呼吸 (等于夜间的 NEE, $\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$, 以 CO_2 物质的量计); E_0 是常量, 常设为 309K; T_{ref} 是参考温度 (K), 一般为 298.16K; $F_{\text{RE},T_{\text{ref}}}$ 为参考温度下的生态系统呼吸 ($\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$, 以 CO_2 物质的量计); T_0 是生态系统呼吸为 0 时的温度 (K); T_k 为空气或土壤温度 (K)。参数 T_0 和 $F_{\text{RE},T_{\text{ref}}}$ 通过观测数据回归拟合得到。

光响应方程, 即 Michaelis-Menten 方程为^[6,25]

$$\text{NEE} = \frac{\alpha' Q_{\text{PPFD}}}{1 - \left(\frac{Q_{\text{PPFD}}}{2000} \right) + \left(\frac{\alpha' Q_{\text{PPFD}}}{F_{\text{GPP,opt}}} \right)} - F_{\text{RE},\text{day}} \quad (3)$$

式中, Q_{PPFD} 为光量子通量密度 ($\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$); α' 为生态系统量子效率 ($\mu\text{molCO}_2\cdot\mu\text{mol}^{-1}\text{ quanta}$); $F_{\text{GPP,opt}}$ 是最佳光照条件下的总初级生产力 ($\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$, 以 CO_2 物质的量计); $F_{\text{RE},\text{day}}$ 是日间的生态系统呼吸 ($\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$, 以 CO_2 物质的量计)。

参数 α' 和 $F_{GPP,opt}$ 通过观测数据回归拟合得到。

1.3.4 边际分布采样法

边际分布采样法 (MDS) 是平均昼夜变化法和查表法的综合使用, 在气温 (T_a)、总辐射 (R_g) 和饱和水汽压差 (VPD) 观测数据均可用时, 在一定的时间窗口 (缺失数据前后 14~28d) 内, 分别以 2.5°C 、 $50\text{W}\cdot\text{m}^{-2}$ 和 0.5kPa 的变异范围约束 T_a 、 R_g 和 VPD 进行数据插补; 在仅 R_g 数据可用时, 将插补的时间窗口缩小至前后 14d; 在气象观测要素全部缺失时, 则使用平均昼夜变化法对缺失数据进行插补; 若仍有缺失则扩大时间窗口重复上述步骤, 直至完成对全部缺失数据的插补^[10]。使用 R Package ‘REddyProc’ sEddyProc_sMDSGapFill 命令对缺失数据进行插补, 记为 MDS。

1.3.5 人工神经网络法

人工神经网络 (ANN) 是基于计算机网络还原人脑或生物神经的网络结构和激励行为的并行非线性计算系统^[7,26-28], 通过建立经验非线性回归模型进行数据插补。目前, 较常使用的人工神经网络是在监督训练程序下能够还原各环境因子间复杂关系的误差反传、信息前馈神经网络 (Feed-forward back-propagation neural network, BP 网络)。在气象样本数据信号 (通常经过标准化处理转换为 $[0, 1]$) 由输入层进入 BP 神经网络各结点后, 各输入变量都被乘以分配给该结点的权重值, 并经转换函数反复修正各层神经元之间的连接权重, 使误差评价函数最优, 实现网络实际输出与期望输出的误差最小化。以气温 (T_a)、饱和水汽压差 (VPD)、总辐射 (R_g) 作为输入变量, 以 70% 的数据作为训练集 (training set)、15% 的数据作为验证集 (validation set)、15% 的数据作为检验集 (testing set), 使用 Matlab Neural Net Fit 工具箱构建具有 10 个隐含神经元、基于 Bayesian Regularization 的 BP 神经网络来进行数据插补, 记为 ANN。

1.4 统计参数

使用决定系数 (R^2)、相对均方根误差 (RRMSE) 和平均绝对误差 (MAE) 评估各插补方法的性能。

$$R^2 = \frac{[\sum (p_i - \bar{p})(o_i - \bar{o})]^2}{\sum (p_i - \bar{p})^2 \sum (o_i - \bar{o})^2} \quad (4)$$

$$\text{RRMSE} = \sqrt{\frac{\sum (p_i - o_i)^2}{\sum (o_i)^2}} \quad (5)$$

$$\text{MAE} = \frac{1}{N} \sum |p_i - o_i| \quad (6)$$

式中, p_i 为各插补方法预测的 NEE ($\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$), o_i 为实际观测的 NEE ($\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$), \bar{p} 为各插补方法预测 NEE 的均值 ($\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$), \bar{o} 为实际观测 NEE 的均值 ($\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$), 均以 CO_2 物质的量计; N 为样本数。

由于基准数据集中昼夜缺失比率不同, 在对插补方法进行比较时, 若将日间和夜间整合分析, 白天和黑夜对统计指标的贡献权重的差异会影响最终的结果, 带来一定的偏差。因此, 单独计算和分析日间和夜间的统计参数。

使用 SPSS 25 对统计参数进行方差分析 (ANOVA) 和多重比较。使用 Origin 2021 作图。

2 结果与分析

2.1 不同方法日间数据插补效果的比较

如图 1a 所示, 在 5 类缺失情景下, 不同方法插补所得日间 NEE 与实测 NEE 间的 R^2 均在 0.5 以下; NLR (非线性回归法) 的 R^2 最低, 始终在 0.2 以下; LUT (查表法) 在连续 1d 和 3d 缺失情景下极差较小 (极差在 0.12 以下), 在连续缺失达到 7d 时极差明显增大 (极差始终大于 0.18)。MDV (固定窗口平均昼夜变化法) 和 MDC (可变窗口平均昼夜变化法) 的 R^2 在连续 1、3 和 7d 缺失情景下波动较小, 结果相对稳定, 在连续 15 和 31d 缺失情景下变异系数显著增大; MDS (边际分布采样法) 和 ANN (人工神经网络法) 的 R^2 在连续 1、3、7 和 15d 缺失情景下波动较为稳定 (极差在 0.2 左右), 在连续 31d 缺失情景下极差开始增大, 分布更为离散, 获得结果的稳定性趋于减弱。

由表 2 可知, 在连续 1d 缺失情景下, ANN 方法的 R^2 最高, NLR 方法的 R^2 最低, 与其它方法存在显著差异 ($P < 0.05$); 在连续 3 和连续 7d 缺失情景下, NLR 方法的 R^2 仍显著最低, ANN 方法的 R^2 较高, 但与 MDV 方法差异不显著 ($P < 0.05$); 当缺失达到连续 15d 时, NLR 方法的 R^2 最低, 与其它方法差异显著 ($P < 0.05$), 而其它方法间 R^2 差异不显著。随着缺失片段长度的增加, 除 MDV 方法外, 各方法的 R^2 均呈下降趋势, MDS 方法的 R^2 在连续 15d 缺失与连续 31d 缺失情景下的 R^2 差异显著 ($P < 0.05$); MDC 和 NLR 方法的 R^2 在连续 7d 缺失与连续 31d 缺失情景下的 R^2 差异显著 ($P < 0.05$); LUT




图 1 五类缺失情景下不同方法插补所得日间 NEE 数据集的统计参数 (2017 年 3 月 1 日–11 月 30 日, $R_g > 20 \text{ W} \cdot \text{m}^{-2}$, 0.5h 数据间隔)

Fig. 1 Statistical parameters of the daytime NEE datasets obtained by six gap-filling methods in five types of gap scenarios (Mar. 1st–Nov. 30th, 2017, $R_g > 20 \text{ W} \cdot \text{m}^{-2}$, 0.5h data interval)

注: NEE 为净生态系统碳交换量 ($\mu\text{mol} \cdot \text{m}^{-2} \cdot \text{s}^{-1}$, 以 CO_2 物质的量计), R_g 为总辐射 ($\text{W} \cdot \text{m}^{-2}$)。 R^2 为插补所得 NEE 与实测 NEE 的决定系数, RRMSE 为相对均方根误差, MAE 平均绝对误差。 MDV 为固定窗口平均昼夜变化法, MDC 为可变窗口平均昼夜变化法, LUT 为查表法, NLR 为非线性回归法, MDS 为边际分布采样法, ANN 为人工神经网络法。 IQR 为四分位距, 25%~75% 表示介于上下四分位数 (Q_3 和 Q_1) 区间内的数据落于矩形内, 上下边缘分别为 $Q_3+1.5\text{IQR}$ 和 $Q_1-1.5\text{IQR}$ 。下同。

Note: NEE is net ecosystem carbon exchange ($\mu\text{mol} \cdot \text{m}^{-2} \cdot \text{s}^{-1}$, based on the amount of CO_2 substances), R_g is global radiation ($\text{W} \cdot \text{m}^{-2}$), R^2 is coefficient of determination between measured NEE and predicted NEE, RRMSE is relative root mean squared error, MAE is mean absolute error, MDV is mean diurnal variation with fixed window, MDC is mean diurnal variation with variable window, LUT is look-up table, NLR is non-linear regression, MDS is marginal distribution sampling, ANN is artificial neural network. IQR is interquartile range, and 25%–75% shows that the data between the upper and lower quartiles (Q_3 and Q_1) fall within the rectangle, and the upper and lower edges are $Q_3+1.5\text{IQR}$ and $Q_1-1.5\text{IQR}$, respectively. The same as below.

表 2 五类缺失情景下不同方法插补所得日间 NEE 数据集 R^2 多重比较表 (Duncan 法)

Table 2 The multiple comparison of R^2 of the daytime NEE datasets obtained by six gap-filling methods in five types of gap scenarios (Duncan method)

缺失片段长度 Gap(d)	MDV	MDC	LUT	NLR	MDS	ANN
1	0.305bA	0.317bA	0.311bA	0.076cAB	0.298bA	0.370aA
3	0.298abA	0.238cB	0.280abcA	0.098dA	0.246bcAB	0.326aAB
7	0.283abA	0.263abAB	0.253bAB	0.070cAB	0.235bB	0.313aABC
15	0.250aA	0.226aBC	0.258aAB	0.037bBC	0.210aB	0.284aBC
31	0.222aA	0.154aC	0.189aB	0.016bC	0.146aC	0.239aC

注: 同一行小写字母表示同一缺失情景下不同插补方法间在 0.05 水平上的差异显著性; 同一列大写字母表示同一插补方法在不同缺失情景下在 0.05 水平上的差异显著性。下同。

Note: Lowercase in the same row indicates the significance of difference at 0.05 level between different gap-filling methods under the same deletion scenario, while uppercase in the same column indicates the significance of difference at 0.05 level of the same gap-filling method under different deletion scenarios. The same as below.

和 ANN 方法的 R^2 在连续 3d 缺失与连续 31d 缺失情景下的 R^2 差异显著 ($P<0.05$)；MDV 方法的 R^2 始终无显著差异。

如图 1b 所示，在连续缺失 ≤ 15 d 时，LUT 方法插补所得日间 NEE 与实测值 NEE 间的 RRMSE（相对均方根误差）明显低于其它方法，平均值在 0.4 左右，极差相对较小，分布较为集中，但在连续 31d 缺失情景下，极差显著增大，分布较为离散；MDV、MDC 和 MDS 方法的 RRMSE 在连续 1、3 和 7d 缺失情景下波动较小，在连续 15d 和连续 31d 缺失情景下极差显著增大；NLR 和 ANN 方法的 RRMSE 波动范围相对平稳，在连续 31d 缺失情景下，极差有增大趋势，分布开始更为离散。

由表 3 可知，在连续 1d 缺失情景下，LUT 方法的 RRMSE 最低，NLR 方法的 RRMSE 最高，与其它方法存在显著差异 ($P<0.05$)；在连续 3d 和连续

7d 缺失情景下，LUT 方法的 RRMSE 仍最低，NLR 方法的 RRMSE 较高，但与 MDS 方法差异不显著，与 MDV、ANN 方法差异显著 ($P<0.05$)；当缺失达到连续 15d 时，LUT 方法的 RRMSE 较低，与其它方法有显著差异($P<0.05$)，而其它方法间 RRMSE 差异不显著；当缺失达到连续 31d 时，各方法间 RRMSE 无显著差异。随着缺失片段长度的增加，MDV 和 MDS 方法的 RRMSE 呈增大趋势，连续 1d 缺失与连续 31d 缺失情景下的 RRMSE 差异显著 ($P<0.05$)；其它方法的 RRMSE 差异相对不显著。

如图 1c 所示，在连续缺失 <15 d 时，各插补方法所得日间 NEE 与实测值 NEE 间的 MAE（平均绝对误差）无明显差异，分布较为集中；在连续缺失 31d 情景下，MDV 方法的 MAE 出现较多异常值，各方法之间的 MAE 开始出现分化的趋势。

表 3 五类缺失情景下不同方法插补所得日间 NEE 数据集 RRMSE 多重比较表（Duncan 法）

Table 3 The multiple comparison of RRMSE of the daytime NEE datasets obtained by six gap-filling methods in five types of gap scenarios (Duncan method)

缺失片段长度 Gap(d)	MDV	MDC	LUT	NLR	MDS	ANN
1	0.615bcB	0.615bcB	0.385dB	0.707bA	0.639bB	0.584cB
3	0.622bcB	0.665abAB	0.403dB	0.689aA	0.663abB	0.592cB
7	0.641bcB	0.652bcAB	0.453dAB	0.718aA	0.679abB	0.615cAB
15	0.639aB	0.658aAB	0.454bAB	0.710aA	0.688aB	0.615aAB
31	0.748aA	0.721aA	0.606aA	0.740aA	0.770aA	0.675aA

2.2 不同方法夜间通量插补效果的比较

如图 2a 所示，与日间通量插补结果不同，在 5 类缺失情景下，夜间通量插补所得 NEE 与实测 NEE 间的 R^2 普遍较小，不同插补方法的 R^2 始终在 0.2 以下。LUT（查表法）的 R^2 始终很小，分布集中且趋近于 0；MDV（固定窗口平均昼夜变化法）的 R^2 相对稳定，随连续缺失片段的增加无明显变化；ANN（人工神经网络法）的 R^2 均值相对较高，但始终存在较大波动，稳定性较差，随着连续缺失片段的增加分布趋于集中；在连续缺失片段增加到 7d 时，各方法的平均 R^2 趋于相等，差异越来越小；在连续缺失片段增加到 15d 时，MDC（可变窗口平均昼夜变化法）、MDS（边际分布采样法）和 NLR（非线性相关法）的 R^2 趋于稳定。

由表 4 可知，在各缺失情景下，ANN 方法的 R^2 较高，LUT 方法的 R^2 较低，二者之间差异显著 (P

<0.05)；在连续缺失片段长度大于 3d 的情景下，ANN 与 MDV、NLR 方法的 R^2 的差异不再显著；在连续缺失片段达到 15d 的情景下，ANN 与 MDS 方法的 R^2 出现显著差异 ($P<0.05$)；而在连续缺失片段达到 31d 时，ANN 与 MDC 方法的 R^2 出现显著差异 ($P<0.05$)。随着缺失片段长度的增加，MDC、MDS 和 ANN 方法的 R^2 呈下降趋势，MDC 和 MDS 方法在连续 7d 缺失与连续 31d 缺失情景下的 R^2 差异显著 ($P<0.05$)，ANN 方法在连续 1d 和连续 3d 缺失与连续 15 和连续 31d 缺失情景下的 R^2 差异显著 ($P<0.05$)，MDV 与 LUT 方法的 R^2 始终无显著差异。

如图 2b 所示，在各类缺失情景下，LUT 方法插补所得夜间 NEE 与实测 NEE 间的 RRMSE（相对均方根误差）明显高于其它方法，平均值始终在 0.9 以上，且极差相对较大，分布较为离散；NLR 和 MDS 方法的 RRMSE 在连续 1d 和连续 3d 缺失情景下波动

较小, 在连续缺失达到 7d 时分布开始趋于离散; 与 MDV 方法不同, MDC 和 ANN 方法的 RRMSE 波动相对平稳, 在各缺失情景下具有相似的极差。

由表 5 可知, 在 5 类缺失情景下, LUT 方法的 RRMSE 最高, 与其它方法存在显著差异 ($P < 0.05$)。除 LUT 方法外, 在连续缺失 ≤ 15 d 的情景下, ANN 方法的 RRMSE 显著低于 MDC 方法 ($P < 0.05$), 而在连续缺失大于 31d 的情景下, 各方法的 RRMSE 差异均不显著。随着缺失片段长度的增加, 各方法的 RRMSE 差异无显著变化。

如图 2c 所示, 夜间不同方法插补所得夜间 NEE 与实测 NEE 间的 MAE (平均绝对误差) 远低于日间; LUT 方法的 MAE 始终为正, 明显高于其它方法, 且分布较为离散, 在连续缺失 1d 情景下极差约为其它方法的 2 倍; 在连续缺失片段长度达到 7d 时, 除 LUT 方法外, 其它方法的 MAE 开始出现较大的波动, 分布趋于离散; 在 5 类缺失情景下, 除 LUT 方法外, 其它方法的 MAE 无明显差异; 与其它方法相比, MDV 方法的 MAE 更趋近于 0, NLR、MDS 和 ANN 方法的 MAE 趋近于负值。




图 2 五类缺失情景下不同方法插补所得夜间 NEE 数据集的统计参数 (2017 年 3 月 1 日–11 月 30 日, $R_g \leq 20 \text{ W} \cdot \text{m}^{-2}$, 0.5h 数据间隔)
Fig. 2 Statistical parameters of the nighttime NEE datasets obtained by six gap-filling methods in five types of gap scenarios (Mar. 1st–Nov. 30th, 2017, $R_g \leq 20 \text{ W} \cdot \text{m}^{-2}$, 0.5h data interval)

表 4 五类缺失情景下不同方法插补所得夜间 NEE 数据集 R^2 多重比较表 (Duncan 法)

Table 4 The multiple comparison of R^2 of the nighttime NEE datasets obtained by six gap-filling methods in five types of gap scenarios (Duncan method)

缺失片段长度 Gap(d)	MDV	MDC	LUT	NLR	MDS	ANN
1	0.031bcAB	0.051abA	0.012cA	0.040bcA	0.051abA	0.082aAB
3	0.040bcA	0.053bA	0.015cA	0.059bA	0.071bA	0.108aA
7	0.025abAB	0.032abAB	0.014bA	0.034abA	0.040abAB	0.047aBC
15	0.036abAB	0.025abcBC	0.009cA	0.021abcA	0.018bcBC	0.039aC
31	0.017abB	0.006bC	0.005bA	0.031aA	0.004bC	0.033aC

表 5 五类缺失情景下不同方法插补所得夜间 NEE 数据集 RRMSE 多重比较表 (Duncan 法)

Table 5 The multiple comparison of RRMSE of the nighttime NEE datasets obtained by six gap-filling methods in five types of gap scenarios (Duncan method)

缺失片段长度 Gap(d)	MDV	MDC	LUT	NLR	MDS	ANN
1	0.683bcA	0.711bAB	0.958aA	0.677bcA	0.626bcBC	0.614cA
3	0.661bcAB	0.698bAB	0.945aA	0.645cA	0.617cdC	0.587dA
7	0.702bA	0.693bAB	1.025aA	0.667bcA	0.646bcABC	0.615cA
15	0.628bcB	0.669bB	0.982aA	0.630bcA	0.672bAB	0.597cA
31	0.667bAB	0.738bA	1.037aA	0.673bA	0.693bA	0.664bA

2.3 不同方法典型晴天日变化数据插补效果的比较

为探究不同方法在 0.5h 尺度上日变化的插值效果, 以在 5 类缺失情景中均涉及的生长稳定的典型晴天 2017 年 5 月 25 日 NEE 数据(数据缺失率为 8%)

为例, 对比插补 NEE 与实测 NEE 的差异, 分析各方法在不同缺失情景下对 NEE 日变化趋势的还原效果 (图 3)。

由图 3 可见, MDV (固定窗口平均昼夜变化法)

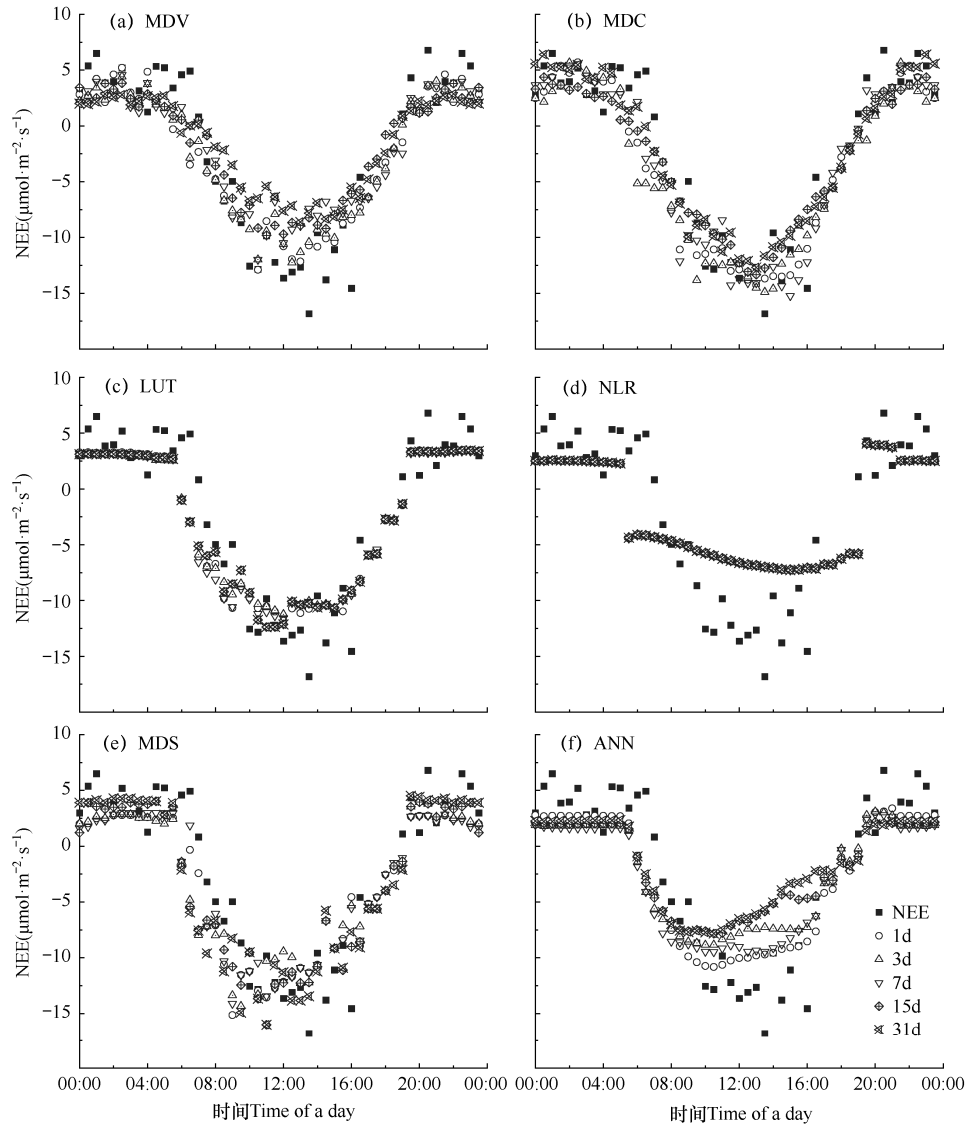


图 3 典型晴天不同插补方法在五类缺失情景下 NEE 的日变化 (2017 年 5 月 25 日, 0.5h 数据间隔)

Fig. 3 Variation curve of the daily change of NEE filled by six gap-filling methods under five types of gap scenarios in a typical sunny day (May 25, 2017, 0.5h data interval)

在 1d、3d 连续缺失情景下,对 0.5h 尺度 NEE 插值效果相对较好,但当连续缺失达到 7d 时,对夜间 0.5h 尺度 NEE 开始出现较为明显的低估,对日间 0.5h 尺度 NEE 开始出现较为明显的高估,不能准确预测日间 CO₂ 的吸收峰值。

MDC (可变窗口平均昼夜变化法)对 0.5h 尺度 NEE 插值效果相对最优,在不同连续缺失情景下均能较好地还原 NEE 的日变化。

LUT (查表法)对夜间 0.5h 尺度 NEE 存在明显且稳定的低估,在不同连续缺失情景下无明显差异,对日间 0.5h 尺度 NEE 预测效果相对较好,在 6:00–9:30 存在一定程度的低估,在 10:00–16:00 存在一定程度的高估,使得日变化曲线在 12:00–15:00 时出现不明显的“上凸”现象。

NLR (非线性回归法)在不同缺失情景下,插补效果相对稳定,但对夜间 0.5h 尺度 NEE 存在明显低估,对日间 0.5h 尺度 NEE 存在明显高估,“U”型曲线不明显,对 NEE 日变化趋势的还原效果最差。

与 MDV 和 MDC 方法类似,MDS (边际分布采样法)能够在一定程度上还原夜间 0.5h 尺度 NEE 的波动,但还原效果会随着连续缺失片段长度的增加而降低;与 MDV 和 MDC 方法不同,MDS 方法对日间 0.5h 尺度 NEE 曲线的还原具有明显的左偏现象,在 9:00 左右会出现一个极小值。

与 LUT 和 NLR 方法类似,ANN (人工神经网络法)对夜间 0.5h 尺度 NEE 预测相对较差,存在明显的低估,不能捕捉到夜间 NEE 的波动。同时,ANN 方法对日间 NEE 存在高估,预测 NEE 最小值出现的时间比实际观测提前 4h (由 14:00 提前至 10:00),与实际 NEE 曲线相比在 10:00–16:00 存在明显“上凸”现象。随着缺失片段长度的增加,ANN 方法对夜间 NEE 的低估和对日间 NEE 的高估程度呈增加趋势。

3 讨论与结论

3.1 讨论

3.1.1 日间和夜间 NEE 插补效果的差异

在对缺失 NEE 数据进行插补时,日间和夜间插补效果存在显著差异,日间不同方法插补所得 NEE 数据与实测数据的 R^2 明显高于夜间,RRMSE (相对均方根误差)明显低于夜间,插补效果明显优于夜间。

日间大气层结不稳定,热量交换频繁,对流作

用较强,适合湍流交换,基本满足利用涡度相关观测系统进行通量观测的要求,经过数据质量控制后数据缺失较少。而夜间辐射冷却导致大气层结稳定,对流较弱,抑制湍流混合,涡度相关法通量观测结果较差,在剔除不满足通量观测条件的值后,往往会产生较多的缺失。同时,夜间经常发生平流、泄流效应,垂直方向上湍流运动倾向于向高频移动,以小涡运动占优势,开路式涡度相关系统传感器的分离等会造成观测仪器响应的不足,进而引起对夜间通量的低估,引入选择性系统误差^[1]。在对 NEE 数据进行插补时,由于夜间可用样本数远低于日间,再加上夜间涡度相关法更倾向于低估 NEE 的特性,使得夜间 NEE 插补效果远低于日间。

3.1.2 不同插补方法 NEE 插补效果的差异

不同插补方法的通量插补效果存在差异。不管是日间还是夜间,ANN (人工神经网络法)往往总能取得相对较好的插补结果,而 NLR (非线性相关法)则相对表现较差;LUT (查表法)在日间的表现明显优于夜间;MDV (固定窗口平均昼夜变化法)、MDC (可变窗口平均昼夜变化法)和 MDS (边际分布采样法)之间差异不显著。

与 Moffat 等^[29–30]的研究结果相比,本站点各方法对 NEE 数据插补结果的 R^2 相对较低。这可能与站点因素有关,本研究所用通量观测数据来源于山地丘陵林区,下垫面相对较为复杂,与农田和草地相比,对通量观测和数据插补的要求更高。

与 Ooba 等^[12,29,31]的结果类似,ANN 方法在连续缺失小于 7d 时,数据插补结果的 R^2 较稳定,高于其它方法,RRMSE (相对均方根误差)也相对较低,表现出较好的插值效果。ANN 方法对 0.5h 尺度 NEE 的日变化还原较差,倾向于高估中午时分的 NEE,一方面源于统计平均效应,另一方面也与输入参数的数量有关。除将总辐射、气温、饱和水汽压作为输入参数外,进一步增加土壤温湿度、风速等气象因子,并引入季节、生长期等非连续变量,可以进一步提高 ANN 方法的精度。

NLR 方法在夜间通量插补中表现出较高的 R^2 和较低的 RRMSE,但在日间通量插补中则相反,与 Moffat 等^[29,32]NLR 方法在日间仍表现相对较好的结果存在差异。这可能与环境响应方程的选择和拟合方程时所选择的时段有关,不同物候期内栓皮栎人工林可能具有不同的光响应曲线,使用单月或更为

精确的物候分期分段拟合环境响应方程或先将观测数据按温度分组后再利用环境响应方程进行回归模拟可能取得更好的插补效果。

LUT 方法在日间通量插补中表现出较高的 R^2 和较低的 RRMSE, 在夜间通量插补中则相反。夜间可用实测 NEE 的数据量远少于日间, 绝对值也较日间低, 在以季节为单位建立索引表时, 较多的缺失会引起 LUT 方法倾向于低估夜间 NEE, 带来难以避免的系统误差。

MDV、MDC 和 MDS 方法具有一定的相似性, 3 种方法均使用缺失数据周围一段时间内相关数据的均值来代替缺失值。但 MDV 和 MDC 方法并未考虑气象因素, MDS 方法则以气温、总辐射和饱和水汽压差梯度为限制条件; MDV 方法的窗口大小是固定的, MDC 和 MDS 方法的窗口则是动态变化的。与 Falge 等^[6,29-30,32]的研究结果一致, 在连续缺失 15d 以下情景时, MDV 方法技术具有较好的性能。但在统计平均效应的作用下, 当连续缺失大于 15d 时, MDV 方法会对日间 NEE 产生高估。在数据连续缺失 $\leq 15d$ 时, MDV、MDC 和 MDS 方法的 R^2 和 RRMSE 无显著差异, 都能较好地还原 0.5h 尺度 NEE 的日变化, 但 MDC 方法还原性能更好。

3.1.3 不同插补方法的适用性

不同 NEE 插补方法的插补效果与数据缺失的持续时间有关。随着数据缺失时间的延长, 各插补方法所得日间 NEE 结果的稳定性一般会越来越差。各通量插补方法一般有其适用范围, 即在一定限度的连续缺失时间内具有较好的插补效果, 超过此限度后插补效果会显著降低。ANN (人工神经网络法) 适用范围较广, 即使是 31d 的连续缺失, 往往也能取得较好的插补效果, 但在连续缺失少于 7d 时能获得更好的结果; LUT (查表法)、MDV (固定窗口平均昼夜变化法)、MDC (可变窗口平均昼夜变化法) 和 MDS (边际分布采样法) 的适用限度均在 15d 以内; NLR (非线性相关法) 表现相对较差, 更适合 7d 内的缺失插补。

Moffat 等^[29,31]发现, ANN 方法在连续缺失少于 7d 时能获得非常好的结果, 在连续 12d 缺失时, 仍保持最优的插补效果。即使缺失时间延长至 31d, ANN 方法仍能取得较优的插补结果。与 Falge 等^[6,29-30,32]的研究结果一致, 在缺失 3~7d, 甚至是 12d 左右时, MDV 方法仍保持较好的性能, 但在缺失时间继续延

长时, 其稳定性会大幅下降。Moffat 等^[29-30]发现在连续缺失少于 12d 时, MDS 方法具有较好的插补性能, 与本研究 MDS 方法在连续缺失达到 15d 时插补性能出现下降且稳定性开始变差略有差异。这可能与站点特性有关, Moffat 等^[29]分析对象为欧洲典型森林, 而 Du 等^[30]关注的则是退化草地和玉米农田, 与本研究所探讨的暖温带落叶阔叶林存在较大差异, 站点的差异影响了不同插补方法的适用性及稳定性。

在对缺失 NEE 数据进行插补时, 当 NEE 数据缺失 $< 15d$ 且气象数据不可用或缺失严重时, 可以使用 MDV 或 MDC 方法; 而当 NEE 数据缺失 $< 15d$, 且气象数据可用时, 则优先使用 LUT、ANN 和 MDS 方法; 在 NEE 数据缺失 $\geq 15d$ 时, 多次利用 ANN 方法进行插值并取均值可能是比较好的选择。在关注 NEE 日变化趋势时, 可优先使用 MDC 方法。在数据缺失比较严重, 可用数据量较少时, NLR 方法会有较大的误差。

除站点因素外, 不同插补方法选取的时间步长和窗口大小的差异等也会影响缺失通量数据插补效果, 进而影响各插补方法的适用性, 本研究仅考虑了单一站点一年 (除冬季) 的通量数据, 在构建人工缺失集时忽略了实际缺失的分布, 所选插补方法在进行插补时所选用的时间步长和窗口大小也不尽相同, 其结果可能并不适用于所有站点, 但可为其它站点数据插补方法的选择提供参考。同时, 部分通量数据的缺失源于降水、露水等异常天气的影响, 通过上述方法插补所得的通量数据可能与实际通量有较大差异 (显著高估), 尤其是不考虑气象因素的 MDV 和 MDC 方法, 要准确估计这部分通量, 还需与闭路式涡度相关观测系统相结合, 进行相应的数据校正研究。

3.2 结论

(1) 在对缺失 NEE 数据进行数据插补时, 由于湍流稳态因素和开路式涡度相关观测系统传感器分离等的影响, 日间插补效果显著优于夜间。由于插值策略的差异, 不同插补方法的插补效果存在差异。ANN (人工神经网络法) 插值效果总体较好, 而 NLR (非线性相关法) 则相对表现较差; LUT (查表法) 在日间的表现明显优于夜间, 对夜间 NEE 存在低估现象; MDV (固定窗口平均昼夜变化法)、MDC (可变窗口平均昼夜变化法) 和 MDS (边际分布采样法)

之间差异不显著,但 MDC 方法对半小时通量变化的还原性能更好。

(2) 不同 NEE 插补方法的插补效果与连续数据缺失的持续时间有关。随着连续缺失时间的延长,各插补方法所得结果的稳定性一般会越来越差。NLR 方法适用于气象数据完备、NEE 数据连续缺失少于 7d 的情景;MDV 或 MDC 方法适用于气象数据不可用或缺失严重、NEE 数据连续缺失少于 15d 的情景,优先选用 MDC 方法;LUT 和 MDS 方法则适用于气象数据缺失较少、NEE 数据连续缺失少于 15d 的情景;ANN 方法适用性相对较广,可用于气象数据缺失较少、NEE 数据连续缺失长达 31d 的情景。

参考文献 References

- [1] 于贵瑞,孙晓敏.陆地生态系统通量观测的原理与方法(第二版)[M].北京:高等教育出版社,2017.
Yu G R,Shun X M.Principles of flux measurement in terrestrial ecosystems(Second Edition)[M].Beijing:Higher Education Press,2017.(in Chinese)
- [2] Loescher H W,Law B E,Mahrt L,et al.Uncertainties in, and interpretation of,carbon flux estimates using the eddy covariance technique[J].Journal of Geophysical Research: Atmospheres,2006,111(D21).
- [3] Richardson A D,Braswell B H,Hollinger D Y,et al.Comparing simple respiration models for eddy flux and dynamic chamber data[J].Agricultural and Forest Meteorology, 2006,141(2):219-234.
- [4] 苏荣瑞,刘凯文,耿一风,等.江汉平原稻-油连作系统冠层 CO₂ 通量变化特征[J].中国农业气象,2012,33(3):362-367.
Su R R,Liu K W,Geng Y F.CO₂ flux variation over canopy rice rape succession system in jiangnan plain[J].Chinese Journal of Agrometeorology,2012,33(3):362-367.(in Chinese)
- [5] 徐小军,周国模,杜华强,等.缺失数据插补方法及其参数估计窗口大小对毛竹林 CO₂ 通量估算的影响[J].林业科学,2015,51(9):141-149.
Xu X J,Zhou G M,Du H Q,et al.Effects of interpolation and window sizes in phyllostachys edulis forest for parameter estimation on calculation of CO₂ flux[J].Scientia Silvae Sinicae,2015,51(9):141-149.(in Chinese)
- [6] Falge E,Baldocchi D,Olson R,et al.Gap filling strategies for defensible annual sums of net ecosystem exchange[J].Agricultural and Forest Meteorology,2001,107(1):43-69.
- [7] Papale D,Valentini R.A new assessment of European forests carbon exchange by eddy fluxes and artificial neural network spatialization[J].Global Change Biology,2003,9(4): 525-535.
- [8] Barr A G,Black T A,Hogg E H,et al.Inter-annual variability in the leaf area index of a boreal aspen-hazelnut forest in relation to net ecosystem production[J].Agricultural and Forest Meteorology,2004,126(3):237-255.
- [9] Hollinger D,Aber J B,Davidson E,et al.Spatial and temporal variability in forest-atmosphere CO₂ exchange[J]. Global Change Biology,2004,(10):1689-1706.
- [10] Reichstein M,Falge E,Baldocchi D 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.
- [11] Desai A R,Bolstad P V,Cook B D,et al.Comparing net ecosystem exchange of carbon dioxide between an old-growth and mature forest in the upper Midwest,USA[J]. Agricultural and Forest Meteorology,2005,128(1-2):33-55.
- [12] Ooba M,Hirano T,Mogami J I,et al.Comparisons of gap-filling methods for carbon flux dataset:a combination of a genetic algorithm and an artificial neural network[J]. Ecological Modelling,2006,198(3):473-486.
- [13] Stauch V J,Jarvis A J.A semi-parametric gap-filling model for eddy covariance CO₂ flux time series data[J].Global Change Biology,2006,12(9):1707-1716.
- [14] Noormets A,Chen J,Crow T R.Age-dependent changes in ecosystem carbon fluxes in managed forests in Northern Wisconsin,USA[J].Ecosystems,2007,10(2):187-203.
- [15] 张琨,朱高峰,白岩,等.基于人工神经网络的涡度相关仪观测蒸散量的数据插补方法[J].兰州大学学报(自然科学版),2014,50(3):348-355.
Zhang K,Zhu G F,Bai Y,et al.Gap filling for evapotranspiration based on BP artificial neural networks[J].Journal of Lanzhou University(Natural Sciences),2014,50(3):348-355. (in Chinese)
- [16] 原文文,同小娟,张劲松,等.黄河小浪底人工混交林生长季能量平衡特征[J].生态学报,2015,35(13):4492-4499.
Yuan W W,Tong X J,Zhang J S,et al.Characteristics of energy balance of a mixed plantation in the Xiaolangdi area in the growing season.Acta Ecologica Sinica,2015,35(13): 4492-4499.(in Chinese)

- [17] Tong X J, Meng P, Zhang J S, et al. Ecosystem carbon exchange over a warm-temperate mixed plantation in the lithoid hilly area of the North China[J]. *Atmospheric Environment*, 2012, 49: 257-267.
- [18] 原文文, 张劲松, 孟平, 等. 开路与闭路涡度相关系统对森林生态系统甲烷通量观测的比较[J]. *中国农业气象*, 2019, 40(11): 669-677.
- Yuan W W, Zhang J S, Meng P, et al. Comparison of CH₄ flux measurement by open-and close-path eddy covariance system[J]. *Chinese Journal of Agrometeorology*, 2019, 40(11): 669-677. (in Chinese)
- [19] Foken T, Göckede M, Mauder M, et al. Post-field data quality control[M]. Berlin, GER: Springer, 2004.
- [20] 王春林, 周国逸, 王旭, 等. 复杂地形条件下涡度相关法通量测定修正方法分析[J]. *中国农业气象*, 2007, 28(3): 33-240.
- Wang C L, Zhou G Y, Wang X, et al. Analysis of correction method on eddy flux measurement over complex terrain[J]. *Chinese Journal of Agrometeorology*, 2007, 28(3): 233-240. (in Chinese)
- [21] Wutzler T, Moffat A, Migliavacca M, et al. REdyProc: enabling researchers to process eddy-covariance data[C]. Egu General Assembly Conference, 2017.
- [22] Wutzler T, Lucas-Moffat A, Migliavacca M, et al. Basic and extensible post-processing of eddy covariance flux data with REdyProc[J]. *Biogeosciences*, 2018, 15(15): 5015-5030.
- [23] Aubinet M, Grelle A, Ibrom A, et al. Estimates of the Annual Net Carbon and Water Exchange of Forests: The EUROFLUX Methodology[J]. *Advances in Ecological Research*, 2000, 30(1): 113-175.
- [24] Lloyd J, Taylor J A. On the temperature dependence of soil respiration[J]. *Functional Ecology*, 1994(8): 315-323.
- [25] Michaelis L, Menten M L. Die kinetik der invertinwirkung[J]. *Biochemische Zeitschrift*, 1913(49): 333-369.
- [26] Bishop C M. Neural networks for pattern recognition[M]. Oxford, UK: Oxford University Press, 1995.
- [27] Rojas R. Neural networks[M]. Berlin, GER: Springer, 1996.
- [28] Hagan M T, Beale M, Beale M. Neural network design[M]. Boston, USA: PWS Publishing Company, 2002.
- [29] Moffat A M, Papale D, Reichstein M, et al. Comprehensive comparison of gap-filling techniques for eddy covariance net carbon fluxes[J]. *Agricultural and Forest Meteorology*, 2007, 147(3): 209-232.
- [30] Du Q, Liu H Z, Feng J W, et al. Effects of different gap filling methods and land surface energy balance closure on annual net ecosystem exchange in a semiarid area of China[J]. *Science China Earth Sciences*, 2013, 57(6): 1340-1351.
- [31] Dragomir C M, Klaassen W, Voiculescu M, et al. Estimating annual CO₂ flux for lutjewad station using three different gap-filling techniques[J]. *The Scientific World Journal*, 2012, (2012): 842-893. doi.org/10.1100/2012/842893.
- [32] Zhao X S, Yao H. A comparison of three gap filling techniques for eddy covariance net carbon fluxes in short vegetation ecosystems[J]. *Advances in Meteorology*, 2015, 75(3): 1-12.