



کاربرد تکنیک جنگل تصادفی در مدل سازی کربن تبادلی اندازه گیری شده به روش همبستگی پیچهای

حسن عباسیان^۱، عیسی سلگی^{۲*}، سید محسن حسینی^۳، سید حسین کیا^۴، سیمین خردمند^۵، پریسا عباسیان^۶

تاریخ دریافت: ۱۴۰۳/۱۱/۳۰

تاریخ پذیرش: ۱۴۰۴/۰۶/۳۱

چکیده

تبادل خالص بوم سازگان (NEE) به عنوان شاخصی مهم برای تعیین وضعیت انتقال دی اکسید کربن (CO₂) بین سطح زمین و اتمسفر، مخصوصاً در مبحث تغییر اقلیم به شمار می آید. علیرغم قابلیت تجهیزات اندازه گیری زمینی در سنجش تبادلات کربن، به دلیل محدودیت های زمانی و مکانی مشاهدات، از مدل سازی برای پیش بینی NEE استفاده می گردد. در این تحقیق، تغییرات روزانه NEE در چهار تیپ عملکردی گیاهی (PFTs) شامل جنگل پهن برگ (DBF)، جنگل سوزنی برگ (ENF)، جنگل آمیخته (MF)، و علفزار (GRA) مورد بررسی قرار گرفت. تکنیک جنگل تصادفی (RF) به عنوان یکی از روش های یادگیری ماشین با استفاده از چهار متغیر محیطی شامل تابش خورشید، دمای هوا، دمای خاک، و رطوبت نسبی به کار گرفته شد. مقادیر اندازه گیری شده و مدل سازی شده با استفاده از چهار شاخص آماری R²، NSE، Bias، و RMSE مقایسه شدند. بر اساس نتایج، DBF بهترین و GRA ضعیف ترین عملکرد را در مدل سازی داشتند. تحلیل اهمیت نسبی متغیرهای محیطی نیز نشان داد که شدت تابش خورشید بیشترین و رطوبت نسبی کمترین اهمیت را در تمام تیپ های عملکردی دارند. همچنین، در تیپ علفزار، تأثیر دمای خاک نسبت به دمای هوا در بهبود عملکرد مدل در مقایسه با تیپ های جنگلی بیشتر است. نتایج مدل سازی همچنین نشان داد که عدم قطعیت رخداد، یک چالش مهم در مراحل مختلف فنولوژیک در تمامی تیپ های عملکردی گیاهی محسوب می شود؛ به طوری که طبق تقویم میلادی، عدم قطعیت در فصول رشد و شکوفایی گیاهان طی روزهای ۱۴۰ تا ۲۲۰ در تیپ های جنگلی و روزهای ۱۲۰ تا ۲۱۰ در علفزار به اوج می رسد.

واژه های کلیدی: تبادل خالص بوم سازگان، تیپ عملکردی گیاهی، جنگل تصادفی، دی اکسید کربن، عدم قطعیت، فنولوژی

مقدمه

و در حال حاضر به ۴۱۴ پی پی ام رسیده است (CSIRO, 2024). از این رو، مطالعات مربوط به ترسیب کربن و تعیین راهکارهای لازم در خصوص کاهش غلظت گاز دی اکسید کربن اتمسفری بسیار حائز اهمیت می باشد. ترسیب کربن یک فرایندی است که با تثبیت CO₂ طی عمل فتوسنتز توسط

دی اکسید کربن (CO₂) یکی از گازهای مهم اتمسفر به شمار می آید که نقش مهمی در تعادل دمای سطح زمین دارد (Liang et al., 2020). غلظت CO₂ موجود در جو از ۲۷۷ پی پی ام پیش از انقلاب صنعتی حدود ۵۰ درصد افزایش یافته

^۴ استادیار، سنجش از دور اکولوژیک، دانشگاه آزاد اسلامی، واحد تهران شمال، تهران، ایران
^۵ دانشجوی دکتری علوم اقیانوسی، دانشگاه ویکتوریا، بریتیش کلمبیا، کانادا
^۶ دکتری جنگلداری، اکولوژی جنگل، اداره کل منابع طبیعی استان البرز، کرج، ایران

^۱ دکتری آلودگی محیط زیست، دانشکده منابع طبیعی و محیط زیست، دانشگاه ملایر و و شرکت مهندسی مشاور مهتاب قدس، تهران، ایران
^۲ استاد گروه علوم و مهندسی محیط زیست، دانشکده منابع طبیعی و محیط زیست، دانشگاه ملایر، ایران.
(*) نویسنده مسئول: (solgi@yahoo.com)
^۳ گروه علوم و مهندسی جنگل، دانشکده منابع طبیعی و علوم دریایی، دانشگاه تربیت مدرس، نور، مازندران، ایران.

نحوه ارجاع مقاله:

پارامترسازی آن، متغیرهای محیطی به ویژه پارامترهای اقلیمی و غیره می‌باشند (Kia and Milton, 2015؛ Chen et al., 2012؛ Xiao et al., 2012). در حال حاضر، روش مشخص و منسجمی برای تخمین دقیق NEE وجود ندارد و از رویکردهای مختلفی برای بهبود عملکرد مدل‌های کاربردی استفاده می‌شود (Ghosh et al., 2021؛ Sandor et al., 2020؛ Barzegar et al., 2018). امروزه، بسیاری از مدل‌های ریاضی و فرآیند محور برای پیش‌بینی NEE در سراسر جهان به کار گرفته شده است که یکی از پرکاربردترین آن‌ها روش یادگیری ماشین می‌باشد. در مطالعه فعلی نیز از مدل جنگل تصادفی استفاده گردید تا یک شبیه‌سازی از تغییرات NEE در PFTهای جنگلی و علفزار ارائه دهد. هدف کلی این پژوهش آن است تا عدم قطعیت پارامترسازی مدل در تیپ‌های عملکردی مختلف گیاهی کاهش یابد. بنابراین، ضمن کمی‌سازی تبادلات کربن در PFTها و تعیین عدم قطعیت، به تاثیر چرخه‌های فنولوژیک و اهمیت نسبی متغیرها در مدل‌سازی تبادلات کربن در PFTهای مختلف پرداخته می‌شود. به هر حال، یافته‌های این پژوهش افق تازه‌ای را برای پژوهشگران در حیطه‌ی مطالعات تغییرات اقلیمی می‌گشاید و امید می‌رود در مناطقی که فاقد تجهیزات اندازه‌گیری شار کربن می‌باشند با مدل‌سازی متغیرهای قابل اندازه‌گیری در ایستگاه‌های هواشناسی یا داده‌های سنجش از دور مانند محصولات MODIS، بتوان تغییرات NEE را پیش‌بینی نمود.

مواد و روش‌ها

معرفی منطقه و داده‌های مورد استفاده

در مطالعه‌ی حاضر از اطلاعات مربوط به چهار ایستگاه واقع در قاره‌ی اروپا استفاده گردید که مشخصات کامل آن‌ها ارائه شده است (جدول ۱). آمار ایستگاه‌های مورد مطالعه از مرکز اطلاعات شارهای تلاطم اروپا^۸ بدست آمده است. این

گیاهان و ذخیره آن به صورت زیست‌توده در پیکره‌های گیاهی صورت می‌گیرد (Booker et al., 2013). بوم سازگان‌های مختلف از طریق فرآیند فتوسنتز بر پویایی کربن جهانی تاثیر می‌گذارند که اغلب وابسته به شرایط آب و هوایی می‌باشند (Kia and Milton, 2015). اکوسیستم‌های جنگلی و علفزار که به عنوان مناطق هدف در این پژوهش مورد مطالعه قرار گرفته‌اند می‌توانند مقادیر زیادی کربن را در طولانی مدت جذب و سپس ذخیره‌سازی نمایند. با توجه به اهمیت موضوع، اندازه‌گیری نرخ تبادل کربن که به عنوان نرخ خالص تبادل CO₂ بوم‌سازگان^۱ نیز شناخته می‌شود، شناخت و درک مناسبی از کارکردهای بوم سازگان فراهم می‌نماید و توانایی ما را برای کاهش اثرات حاصل از تغییر آب و هوایی ارتقاء می‌دهد. در حال حاضر اندازه‌گیری NEE توسط برج‌های مبتنی بر همبستگی پیچیده‌ای^۲ یک روش مهم در مطالعات ترسیب کربن به شمار می‌آید. بنابر این، در این پژوهش اطلاعات برج‌های اندازه‌گیری زمینی مورد استفاده قرار گرفتند تا نوسانات زمانی شار کربن بین سطح خشکی و اتمسفر در چهار تیپ عملکردی گیاهی^۳ شامل جنگل پهن‌برگ خزان‌کننده^۴، جنگل سوزنی‌برگ^۵، جنگل آمیخته^۶ و علفزار^۷ مشخص گردد. علیرغم پیشرفت‌های چشمگیر در ابداع فناوری و تجهیزات اندازه‌گیری، کمیت دقیق شار کربن در PFTهای مختلف مشخص نمی‌باشد و کاهش عدم قطعیت در مطالعات پویایی کربن موضوعی است که همواره مورد توجه دانشمندان می‌باشد (Hilton et al., 2014؛ Xiao et al., 2011). شناسایی منابع عدم قطعیت در اندازه‌گیری و مدل‌سازی دی‌اکسیدکربن تبادلی بین بوم‌سازگان‌های خشکی و اتمسفر زمین از اولویت‌های تحقیقاتی در سطح جهان است که می‌توان به مطالعات گسترده در این زمینه پرداخت. عوامل متعددی در بروز عدم قطعیت در پیش‌بینی NEE در مقیاس‌های مکانی-زمانی وجود دارند که مهم‌ترین آن‌ها ویژگی‌های سطح زمین، ساختار مدل پیشنهادی و

^۶ Mixed Forest (MF)

^۷ Grassland (GRA)

^۸ European Fluxes Database Cluster (Available on: www.europe-fluxdata.eu)

^۱ Net Ecosystem Exchange (NEE) of CO₂

^۲ Eddy Covariance (EC)

^۳ Plant Functional Types (PFTs)

^۴ Deciduous Broadleaf Forest (DBF)

^۵ Evergreen Needle-leaf Forest (ENF)

ایستگاه‌ها در عرض‌های جغرافیایی مختلفی قرار گرفته‌اند و محدوده‌ی وسیعی را در بر می‌گیرند.

جدول ۱- مشخصات عمومی ایستگاه‌های مورد مطالعه

Table 1 – General characteristics of the stations

PFT	DBF	ENF	MF	GRA
Site	Hampshire	Oberbärenburg	Mehrstedt	Vall d'Alinyà
Code	UK-Ham	DE-Obe	DE-Meh	ES-VDA
latitude	51° 09' 13" N	50° 47' 12" N	51° 16' 31" N	42° 09' 04" N
longitude	0° 51' 30" W	13° 43' 16" E	10° 39' 19" E	01° 26' 50" E
Annual Precipitation (mm)	779	996	570	669
Annual Mean Temperature (°C)	9.6	5.5	7.8	13
Elevation (m)	76	734	286	1770

می‌باشد. در تمامی این ایستگاه‌ها از مدل فتوسنتز- تنفس گیاهی^۱ (Mahadevan et al., 2008) استفاده به عمل آمد تا تبادل خالص کربن در مقیاس زمانی مشخص گردد. این مدل یک رویکرد ساده‌ی مبتنی بر راندمان استفاده از نور می‌باشد که با استفاده از سنجش از دور، اطلاعات مربوط به متغیرهای دما، رطوبت و فنولوژی را فراهم می‌نماید. علیرغم سادگی، VPRM به خوبی می‌تواند گردش روزانه و سالانه CO₂ را بررسی نماید. در این مدل، NEE حاصل تفریق دو جریان کربن یعنی تولید ناخالص اولیه و تنفس اکوسیستمی می‌باشد.

$$NEE = -GPP + R_{eco} \quad (1)$$

$$GPP = -\varepsilon_{max} \times PAR \times fPAR \times W_s \times T_s \quad (2)$$

در معادلات فوق، ε_{max} ماکزیمم کارایی استفاده از نور (g C m⁻² MJ⁻¹ APAR) بدون عوامل استرس محیطی، PAR تابش فعال فتوسنتزی^۲ (MJ m⁻²) در بازه‌ی زمانی روزانه، fPAR^۳ (درصد جذب شده تابش فعال فتوسنتزی توسط گیاهان در طول موج ۴۰۰-۷۰۰ نانومتر)، W_s بردار رطوبت، T_s بردار دما می‌باشد. پارامترهای T_s و W_s به ترتیب بیانگر اثرات محدود کننده‌ی دما و رطوبت می‌باشند که هر دو از صفر تا یک (0-1) متغیرند. بر خلاف مدل فتوسنتزی گیاهی، تنفس اکوسیستمی به عنوان تابع نمایی دمای هوا یا خاک در نظر گرفته می‌شود (Lloyd and Taylor, 1994).

$$R_{eco} = R_{ref} e^{E_0 \left(\frac{1}{T_{ref} - T_0} - \frac{1}{T - T_0} \right)} \quad (3)$$

طبق طبقه‌بندی سیستم اقلیمی دومارتن گسترش یافته (Khalili et al., 2022)، ایستگاه UK-Ham در طبقه‌ی خیلی مرطوب معتدل، DE-Obe در طبقه‌ی نیمه مرطوب سرد، DE-Meh در طبقه‌ی مرطوب معتدل و ES-VDA در طبقه‌ی خیلی مرطوب سرد قرار می‌گیرند. اطلاعات دریافتی بیانگر تنوع داده‌های آماری در سری‌های زمانی مختلف است که به غیر از غلظت و شار دی‌اکسید کربن، متغیرهای دیگری از قبیل شدت تابش خورشیدی، دمای هوا، رطوبت هوا، بارندگی، دمای خاک، گرمای نهان، غلظت متان و غیره را شامل می‌شوند.

روش پژوهش و تجزیه و تحلیل داده‌ها

در این مطالعه، از یک طرف مقایسه‌ای بین انتشار گاز CO₂ در PFTهای مختلف به عمل می‌آید و از طرفی هم با استفاده از متغیرهای محیطی، نرخ تبادل CO₂ در تیپ‌های عملکردی گیاهی با مدل‌سازی پیش‌بینی می‌شوند. مدل‌سازی با روش جنگل تصادفی صورت گرفته است تا وضعیت NEE روزانه در PFTهای مختلف مورد ارزیابی قرار گیرد. از طرفی دیگر، انتظار می‌رود متغیرهای محیطی مورد استفاده اهمیت متفاوتی در خصوص مدل‌سازی داشته باشند. از این‌رو، آنالیز حساسیت صورت می‌گیرد تا اهمیت نسبی آن‌ها در قابلیت پیش‌بینی مدل در تیپ‌های عملکردی گیاهی مختلف مشخص گردد. دلیل مطالعه در این مناطق، تراکم بالای برج‌های اندازه‌گیری، داده‌های طولانی مدت و تنوع PFTها

³ Fraction of Photo-synthetically Active Radiation (fPAR)

^۱ Vegetation Photosynthesis Respiration Model (VPRM)

^۲ Photo-synthetically Active Radiation (PAR)

متغیرهای مورد استفاده در مدل

در مدل‌سازی تلاش بر آن بوده که مناسب‌ترین متغیرهای محیطی به عنوان ورودی انتخاب شوند تا بهترین خروجی حاصل شود. برای انتخاب متغیرهای مدل، دو معیار در نظر گرفته شد. اولاً، آن دسته از متغیرهایی که مستقیماً شار کربن را کنترل می‌کنند (Xiao et al., 2014؛ Xu et al., 2018) و ثانیاً، آن‌هایی که اغلب توسط تجهیزات معمول هواشناسی نیز قابل اندازه‌گیری می‌باشند. فرض بر این است که این متغیرها را می‌توان برای پیش‌بینی NEE در جایی که اندازه‌گیری‌های شار کربن وجود ندارد، استفاده نمود. به هر حال، شناسایی و درک فاکتورهای تاثیرگذار بر میزان تبدلات دی‌اکسید کربن بین اکوسیستم‌های جنگلی و اتمسفر و در نهایت تولید خالص اکوسیستمی، از موارد بسیار مهم و حائز اهمیت برای شناخت و ارزیابی تاثیر PFTها بر تغییر اقلیم می‌باشد (Baldocchi et al., 2001). ضرورت دارد مطالعات بیشتری انجام گیرد تا مشخص گردد که چه اطلاعاتی در مورد انتشارات کربن نیاز است تا بهترین مدل‌سازی صورت گیرد. مقادیر شار کربن ارتباط بسیار بالایی با دمای هوا (T_a)، دمای خاک (T_s) و شدت تابش فتوسنتزی (PAR) دارند و این متغیرها تاثیرگذارترین پارامترها روی شار کربن هستند (Dou et al., 2018). از این رو، در این مطالعه متغیرهای فوق به انضمام رطوبت نسبی هوا (Rh) در سه حالت به عنوان متغیرهای ورودی مدل مورد استفاده قرار گرفتند (جدول ۱).

جدول ۱- ترکیبات مختلف متغیرهای محیطی به عنوان ورودی مدل

Table 2- Input combinations of environmental variables

Input Combinations	Model
T_a , PAR, Rh	RF1
T_s , PAR, Rh	RF2
T_a , T_s , PAR, Rh	RF3

برای مقایسه مقادیر NEE اندازه‌گیری شده و مقادیر حاصل از مدل‌سازی از چهار شاخص آماری ضریب تبیین^۳، ضریب ناش ساتکلیف^۴، بایاس^۵ و خطای میانگین مربعات^۶ استفاده به عمل آمد. این شاخص‌ها برای ارزیابی صحت

که در این معادله، R_{ref} تنفس مرجع اکوسیستمی در دمای ۱۰ درجه سانتی‌گراد، E_0 انرژی فعال‌سازی ($50.0^\circ C$)، T_{ref} دمای مرجع معادل ۱۰ درجه سانتی‌گراد، T_{air} دمای هوا و T_0 مقدار ثابت $46/02$ - درجه سانتی‌گراد می‌باشد. از معادله‌ی فوق استنتاج می‌گردد، R_{ref} یک مقدار غیر منفی است و دامنه‌ی آن $[0-20 \text{ g C m}^{-2} \text{ day}^{-1}]$ تعیین شده است. در نهایت، پس از تعیین تمام موارد فوق، می‌توان NEE را محاسبه نمود. مقادیر منفی NEE بیانگر جذب کربن و مقادیر مثبت هم بیانگر آزادسازی کربن به داخل اتمسفر می‌باشند. عبارتی دیگر، مقادیر منفی بیانگر آن است که اکوسیستم CO_2 موجود در جو را جذب می‌نماید و به عنوان یک مخزن جذب کربن عمل می‌نماید و در حالت مثبت هم در واقع CO_2 به داخل جو رهاسازی می‌گردد که به عنوان منبع انتشار کربن در نظر گرفته می‌شود.

تکنیک جنگل تصادفی

جنگل تصادفی یک الگوریتم یادگیری نظارت شده محسوب می‌شود و همان طور که از نام آن پیداست، این الگوریتم جنگلی را به طور تصادفی می‌سازد (Breiman, 2001). جنگل ساخته شده در واقع گروهی از درخت‌های تصمیم است. اغلب اوقات، ساخت جنگل با استفاده از درخت‌ها به روش کیسه‌گذاری^۱ انجام می‌شود. ایده اصلی روش کیسه‌گذاری آن است که ترکیبی از مدل‌های یادگیری، نتایج کلی مدل را افزایش می‌دهد. به بیان دیگر، جنگل تصادفی چندین درخت تصمیم ساخته و آن‌ها را ادغام می‌کند تا پیش‌بینی‌های بهتری حاصل شوند. یکی از مزایای جنگل تصادفی قابل استفاده بودن آن، هم برای مسائل دسته‌بندی و هم رگرسیون است که اغلب سیستم‌های یادگیری ماشینی کنونی را تشکیل می‌دهند. این مدل با تمرکز بر کاهش مقدار واریانس موجب کاهش خطاها می‌شود. شایان ذکر است، در این مطالعه اهمیت نسبی متغیرها در مدل جنگل تصادفی با استفاده از تکنیک کاهش بعد^۲ (Fodor, 2002) به دست آمد.

^۳ Nash-Sutcliffe Efficiency (NSE)

^۵ Bias Error (Bias)

^۶ Root Mean Square Error (RMSE)

^۱ Bagging

^۲ Dimension Reduction Technique

^۳ Coefficient of Determination (R2)

NSE به عدد یک نزدیک تر باشند، نشان دهنده‌ی رابطه‌ی قوی بین داده‌ها و تناسب بیشتر مدل و پارامترهای آن با شرایط منطقه است و هر چه Bias و RMSE به صفر نزدیک‌تر شوند بیانگر پیش‌بینی بهتر مدل است.

جدول ۳- ارزیابی عملکرد توسط شاخص

Table 3- Performance evaluation by NSE index

NSE	Result
0.75 < NSE < 1	Very Good
0.65 < NSE < 0.75	Good
0.5 < NSE < 0.65	Acceptable
NSE < 0.5	Not Acceptable

نتایج و بحث

مقادیر اندازه‌گیری شده روزانه NEE در چهار ایستگاه متعلق به تیپ‌های عملکردی گیاهی DBF، ENF، MF و GRA به طور جداگانه مورد بررسی و مطالعه قرار گرفته‌اند. شکل ۱ تغییرات روزانه NEE در PFTهای مختلف را نشان می‌دهد. همان طوری که قبلاً نیز اشاره گردید، مقادیر منفی NEE بیانگر انتقال گاز CO₂ از اتمسفر به سطح زمین است که طی فرایند فتوسنتز صورت می‌گیرد و سیستم به عنوان مخزن کربن عمل می‌نماید. مقادیر مثبت NEE هم نشان دهنده‌ی انتقال CO₂ از سطح زمین به داخل اتمسفر است که طی فعالیت تنفس اتفاق می‌افتد و سیستم به عنوان منبع انتشار کربن عمل می‌نماید. رفتار PFTها از نظر جذب و یا انتشار گاز CO₂ در ایام مختلف سال تغییر می‌نماید و تغییرات محرز سالانه و سالانه- فصلی به راحتی قابل تشخیص می‌باشند (شکل ۱). تیپ‌های عملکردی گیاهی مورد مطالعه به طور دائم و پیوسته به عنوان مکانی برای جذب و یا انتشار کربن عمل نمی‌کنند و کارکرد آنها تابع تغییرات فنولوژیک می‌باشد. مقادیر fPAR و شاخص سطح برگ^۱ هر دو در فصل بهار افزایش می‌یابند و انتظار می‌رود این روند در مناطق معتدله تا نیمه‌های تابستان ادامه یابد. تغییرات زمانی LAI در نوسانات شار CO₂ بسیار موثر است؛ حتی در مناطق قطبی هم NEE با LAI ارتباط دارد و پارامترهای مدل را تحت تاثیر قرار می‌دهد (Stoy et al., 2013; Jia et al., 2018). وقتی این پارامترها افزایش می‌یابند، CO₂ بیشتری طی فعالیت فتوسنتز

مدل‌سازی در بسیاری از مطالعات از جمله پیش‌بینی کربن تبدالی مورد استفاده قرار می‌گیرند.

$$R^2 = \left[\frac{\sum_{i=1}^N (x_{o,i} - \bar{x}_o)^2 (x_{m,i} - \bar{x}_m)}{\sqrt{\sum_{i=1}^N (x_{o,i} - \bar{x}_o)^2 \sum_{i=1}^N (x_{m,i} - \bar{x}_m)^2}} \right]^2 \quad (4)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (x_{o,i} - \bar{x}_{m,i})^2}{\sum_{i=1}^N (x_{o,i} - \bar{x}_o)^2} \quad (5)$$

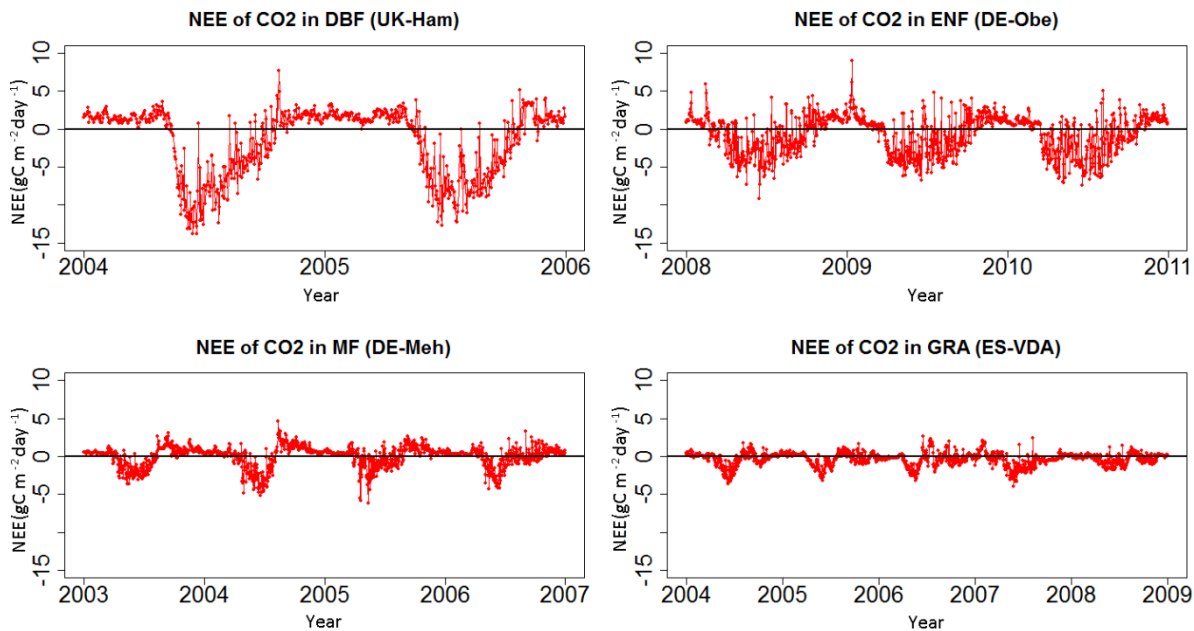
$$Bias = \frac{\sum_{i=1}^N (x_{m,i} - x_{o,i})}{N} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_{o,i} - x_{m,i})^2}{N}} \quad (7)$$

ضریب تبیین میزان ارتباط و همبستگی خطی بین دو متغیر را نشان می‌دهد که مقادیر آن بین ۱- (همبستگی کامل منفی) و ۱+ (همبستگی کامل مثبت) تغییر می‌نماید. مقدار صفر نشان می‌دهد که هیچ‌گونه ارتباط خطی بین دو متغیر وجود ندارد. ضریب تبیین قویا تحت تاثیر اندازه‌ی نمونه می‌باشد. ضریب ناش سائکلیف ضریبی است که اختلاف نسبی بین مقادیر مشاهده شده و شبیه‌سازی شده را نشان می‌دهد. محدوده‌ی عملکرد و ارزیابی شاخص ناش سائکلیف مطابق جدول ۳ می‌باشد (Kult et al., 2014). بایاس یک شاخص آماری برای اندازه‌گیری خطای سیستماتیک بین NEE اندازه‌گیری شده توسط برج‌ها و مقادیر پیش‌بینی شده مدل است. مقدار صفر به معنای آن است که هیچ خطایی سیستماتیک وجود ندارد، مقدار مثبت بیانگر آن است که NEE مدل شده بیشتر از مقدار اندازه‌گیری شده است و مقدار منفی هم یعنی آنکه NEE مدل از مقدار اندازه‌گیری شده کمتر برآورد گردیده است. خطای میانگین مربعات: یک شاخص آماری است تا مشخص شود مقادیر NEE اندازه‌گیری شده و مدل تا چه حدی به هم نزدیک می‌باشند؛ هرچه میزان آن کمتر باشد بیانگر اختلاف کمتر است. در معادلات فوق x_o و x_m به ترتیب مقادیر مشاهده‌ای و مدل‌سازی شده شار روزانه کربن در زمان معین، \bar{x}_o و \bar{x}_m به ترتیب میانگین مقادیر مشاهده‌ای و مدل‌سازی شده شار روزانه کربن در زمان معین و N تعداد مشاهدات می‌باشد. بدیهی است هر چه R^2 و

^۱ Leaf Area Index (LAI)

جذب می‌شود و این پدیده با جهت دادن NEE به سمت نقطه‌ی عطف (مقادیر منفی حداکثری) در تابستان، بالاترین پتانسیل جذب کربن را برای اکوسیستم فراهم می‌نماید.



شکل ۱- تغییرات روزانه NEE در تیپ‌های عملکردی گیاهی مختلف

Figure 1- NEE daily variation in different plant functional types

برای قضاوت در خصوص پتانسیل جذب و یا انتشار کربن بر اساس میانگین سالیانه NEE می‌باشد که در DBF معادل $-1/74$ گرم کربن بر مترمربع در روز است ولی در MF، ENF و GRA به ترتیب معادل $-0/77$ ، $+0/1$ و $-0/37$ گرم کربن بر مترمربع در روز اندازه‌گیری شده است (جدول ۴). این موضوع جایگاه و اهمیت جنگل‌های پهن‌برگ خزان‌کننده را در جذب و ترسیب کربن اتمسفری نشان می‌دهد.

در عوض، جذب CO_2 در پاییز کاهش می‌یابد و اکوسیستم در این دوره از مخزن جذب CO_2 به منبع انتشار آن تبدیل می‌گردد. در زمستان، به دلیل رهاسازی CO_2 به اتمسفر، NEE مثبت می‌شود. در این مطالعه، جنگل پهن‌برگ خزان‌کننده حدود ۴۰ درصد ایام سال را به عنوان پذیرنده‌ی کربن عمل نموده است؛ در حالی که این وضعیت در جنگل سوزنی‌برگ، جنگل آمیخته و علفزار به ترتیب حدود ۵۰ درصد، ۳۲ درصد، و ۶۳ درصد می‌باشد. ولی نکته‌ی مهم و حائز اهمیت

جدول ۴- مشخصات عمومی ایستگاه‌ها از نظر پتانسیل جذب یا انتشار کربن بر حسب مقادیر NEE

Table 4- General characteristics of sites in terms of sink or source potential of NEE

PFT	Site	Years	Max Absorption ($gC\ m^{-2}\ day^{-1}$)	Max Emission ($gC\ m^{-2}\ day^{-1}$)	Mean ($gC\ m^{-2}\ day^{-1}$)	Number of Days Act as a Sink (%)
DBF	UK-Ham	2004-2005	-13.88	+7.72	-1.74	41.04
ENF	DE-Obe	2008-2010	-9.20	+9.01	-0.77	49.73
MF	DE-Meh	2003-2006	-6.20	+4.62	+0.01	32.10
GRA	ES-VDA	2004-2008	-3.95	+2.66	-0.37	62.73

بهار و سایر فاکتورهای موثر بر فنولوژیک، نقش بسزایی در تبادلات سالانه کربن یک منطقه جنگلی دارند (Goulden et al., 1998; Lindroth et al., 2008). جذب کربن سالانه جنگل‌ها به شدت به ذوب برف وابسته است و مواقعی که ذوب برف کمتر است طول دوره‌ی رشد افزایش می‌یابد و در نتیجه جذب CO₂ کمتر می‌شود. مضافاً، حدود ۷۰ درصد تولید ناخالص اولیه وابسته به ذوب برف است و درختان حتی در اواخر فصل رشد (آگوست) به شدت به آب ذوب برف متکی می‌باشند (Hu et al., 2010).

ارتباط بین NEE و متغیرهای محیطی

همانطور که قبلاً اشاره گردید از متغیرهای محیطی برای پیش‌بینی تبادلات کربن استفاده به عمل آمد. معادلات خطی ساده نمی‌توانند به درستی منعکس کننده‌ی ارتباط NEE و متغیرهای محیطی باشند و انتظار می‌رود روابط غیر خطی بین این متغیرها ترجمان بهتری از تاثیرگذاری پارامترهای محیطی بر وضعیت NEE باشند. از این رو، برای درک بهتر روابط بین متغیرهای مذکور از مدل یادگیری ماشین استفاده به عمل آمده است تا نتایج قابل اعتمادتری برای شبیه‌سازی رفتار روزانه NEE حاصل گردد. نتایج عملکرد مدل جنگل تصادفی برای ارزیابی کربن تبدالی روزانه در تیپ‌های عملکردی گیاهی در دوره‌ی تست نشان داده شده است (جدول ۵).


احتمالاً دلیل اصلی تفاوت در تولید خالص PFTهای مختلف این است که NEE اختلاف کوچکی از دو آیتم بزرگ یعنی تولید ناخالص اولیه و تنفس می‌باشد (Puche et al., 2019; Tramontana et al., 2020). بنابراین، انتظار می‌رود تغییری اندک در هر یک از آن دو آیتم، تاثیر بزرگی بر میزان NEE خواهد داشت. رتبه‌بندی PFTها از نظر میزان متوسط NEE سالانه در آمریکای شمالی به ترتیب شامل جنگل‌های خزان‌کننده (۱۶/۵±۱/۷- تراگرم کربن)، جنگل‌های سوزنی‌برگ (۹/۳±۰/۳- تراگرم کربن)، جنگل‌های آمیخته (۰/۳±۰/۱- تراگرم کربن) و جنگل‌های تالابی (۳/۹±۷/۴- تراگرم کربن) می‌باشد (Xiao et al., 2014). نکته‌ی حائز اهمیت این است که نه تنها PFTهای مختلف رفتار متفاوتی دارند بلکه در میان یک PFT هم توده‌های مختلف می‌توانند رفتار مختص به خود را داشته باشند که بر حسب سن توده، پوشش سطح برگ، میزان تاج پوشش، میزان نفوذ نور و غیره تغییر می‌کنند (Xiao et al., 2011). در جنگل‌های اروپا عرض جغرافیایی می‌تواند معرف خوبی از تغییرات NEE در مناطق مختلف باشد ولی نمی‌توان گفت که کدام فاکتور عامل اصلی بروز این پدیده با عرض جغرافیایی می‌باشد (Lindroth et al., 2008). مطالعاتی که طی سال‌های متوالی روی جنگل‌های شمالی صورت گرفت نشان داد که میزان ترسیب سالانه‌ی کربن تا حد زیادی وابسته به این است که ذوب برف‌ها و گرم شدن خاک در چه زمانی اتفاق می‌افتد. شروع گرم‌ها در فصل

جدول ۵- مقایسه‌ی عملکرد مدل با متغیرهای ورودی متفاوت در دوره تست در PFTهای چهارگانه در پیش‌بینی NEE (گرم کربن بر مترمربع در روز)

Table 5- Comparisons of model's efficiency with different input combinations in the testing period for net ecosystem exchange (NEE, gC m⁻²day⁻¹) in the different PFTs.

Model	RF1				RF2				RF3			
	R ²	NSE	Bias (gC m ⁻² day ⁻¹)	RMSE (gC m ⁻² day ⁻¹)	R ²	NSE	Bias (gC m ⁻² day ⁻¹)	RMSE (gC m ⁻² day ⁻¹)	R ²	NSE	Bias (gC m ⁻² day ⁻¹)	RMSE (gC m ⁻² day ⁻¹)
DBF	0.91	0.67	0.07	2.65	0.97	0.84	-0.13	1.84	0.97	0.82	0.01	1.82
ENF	0.97	0.77	0.01	1.20	0.94	0.73	0.01	1.37	0.97	0.83	-0.04	1.06
MF	0.82	0.56	0.11	0.94	0.86	0.55	0.05	0.87	0.84	0.60	-0.03	0.87
GRA	0.64	0.36	0.05	0.70	0.72	0.43	-0.04	0.64	0.72	0.48	0.01	0.64

شروع کاهش برگ و کاهش فتوسنتزی و در نهایت به مرحله‌ی خواب و بدون فعالیت گیاه اشاره نمود (شکل ۲). نتایج شکل ۳ نشان می‌دهد عدم قطعیت در طول سال با نوساناتی همراه است ولی در برخی از ایام سال به میزان حداکثری می‌رسد. مقادیر اندازه‌گیری شده و پیش‌بینی شده در اواخر پاییز و زمستان هم‌پوشانی بیشتری با یکدیگر دارند ولی در ایام اوج رشد و شکوفایی^۲، عدم قطعیت در همه‌ی PFTها به بالاترین میزان خود می‌رسد (شکل ۳). این پدیده نشان می‌دهد که عدم قطعیت تابع مراحل فنولوژیک جوامع گیاهی می‌باشد.



شکل ۲- تغییرات سالانه میزان GPP بر حسب مراحل مختلف فنولوژیک در جوامع گیاهی (Wang et al., 2020)
Figure 2- GPP annual variation in terms of phenological stages of plants (Wang et al., 2020)

مطالعه‌ای که در سه منطقه جنگلی واقع در کانادا نیز صورت گرفت افزایش عدم قطعیت در هنگام اوج شکوفایی پوشش گیاهی را تأیید نموده است (Dou et al., 2018). زمانی که GPP حداقل معادل ۱۰ درصد تفاوت حداکثر و حداقل سالیانه باشد به عنوان فصل رشد فتوسنتزی تلقی می‌گردد و زمانی که این اختلاف حداقل به ۷۰ درصد می‌رسد در واقع دوره‌ی بلوغ و اوج شکوفایی جوامع گیاهی را نشان می‌دهد (Wang et al., 2020). در این مطالعه، بازه‌های زمانی تغییرات فنولوژیک در تیپ‌های جنگلی شامل روزهای ۱۴۰-۸۰ یعنی شروع برگ‌دهی و افزایش فتوسنتز، روزهای ۲۲۰-۱۴۰ فصل بلوغ و اوج شکوفایی پوشش گیاهی و روزهای ۳۱۰-۲۲۰ کاهش تدریجی برگ‌ها و افت فتوسنتز می‌باشد.

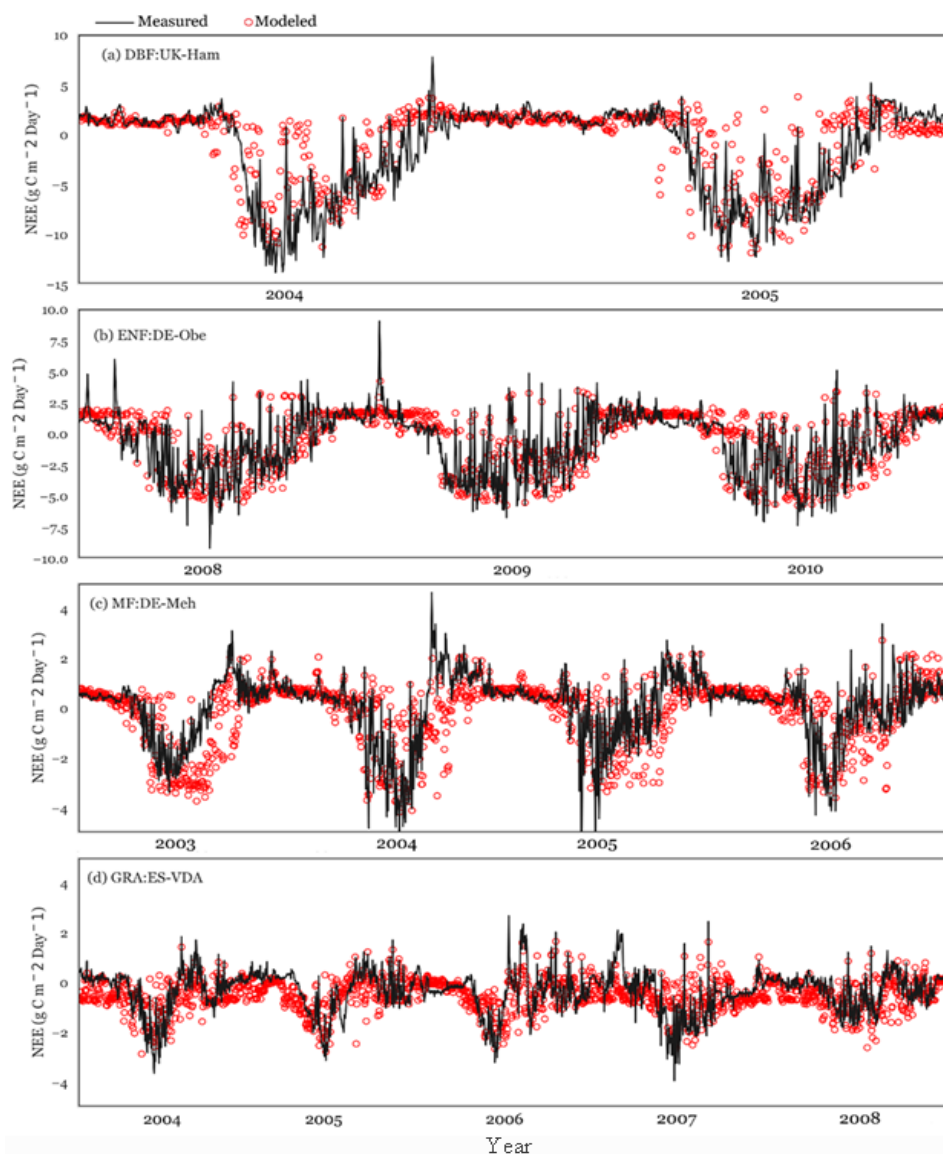
چهار متغیر محیطی شامل دمای هوا (T_a)، دمای خاک (T_s)، شدت تابش خورشیدی (PAR) و رطوبت نسبی هوا (Rh) به عنوان ورودی‌های مدل در سه حالت مورد ارزیابی قرار گرفتند. نتایج جدول فوق نشان می‌دهد، در هر چهار PFT بهترین عملکرد مربوط به حالتی است که بیشترین متغیرهای ورودی (ترکیبی که شامل دمای هوا، دمای خاک، تابش خورشیدی و رطوبت نسبی هوا است) استفاده شده‌اند. در دو حالت دیگر که سه متغیر ورودی به کار گرفته شده است، مدل‌ها در تمام PFTها عملکرد ضعیف‌تری نشان می‌دهند. این نتایج همچنین نشان می‌دهند کارایی عملکرد PFTها در پاسخ به مدل، به ترتیب شامل DBF، ENF، MF و GRA می‌باشد و مناطق جنگلی نسبت به علفزار عملکرد بهتری به مدل‌سازی نشان داده‌اند. مطالعه‌ی وضعیت تبخیر و تعرق در حوزه‌ی آبریز رودخانه هی‌هی^۱ واقع در جنوب شرقی کشور چین با استفاده از روش‌های یادگیری ماشین نشان داد اولاً جنگل تصادفی بهترین نتیجه را به همراه دارد و ثانیاً مدل‌سازی‌ها در مناطقی که پوشش گیاهی متراکم است عملکرد بهتری نشان می‌دهند. در واقع، در قسمت‌هایی که خاک لخت است و یا تراکم پوشش گیاهی کمتر است قابلیت پیش‌بینی مدل کاهش یافته است (Xu et al., 2018).

وضعیت عدم قطعیت در مراحل مختلف رویش گیاهی

برای مقایسه‌ی مقادیر اندازه‌گیری شده شار تلاطم توسط ایستگاه‌های ثابت زمینی و مقادیر مدل‌سازی شده، بررسی جداگانه‌ای صورت گرفت تا مشخص گردد موارد تخمین بیش از حد و یا کمتر از حد در چه ایامی از سال اتفاق می‌افتند. با بررسی این موضوع می‌توان دریافت آیا موارد بروز عدم قطعیت که تخمین بیش از حد و یا کمتر از حد مشاهده می‌گردد الگوهای یکسانی دارند یا این که رفتارهای نامنظمی از خود نشان می‌دهند. به عبارتی دیگر، آیا این مغایرت‌ها در ایام خاصی از سال مشاهده می‌شوند یا خیر. از نظر تغییرات رویش گیاهی، چند بازه‌ی زمانی مجزا در طول سال وجود دارد که می‌توان به دوره‌ی شروع رشد و برگ‌دهی، فصل اوج شوفایی،

^۲ Maturity Period

^۱ Heihe River Basin



شکل ۳- مقایسه مقادیر اندازه‌گیری شده و مدل‌سازی شده NEE (گرم کربن بر مترمربع در روز) در دوره تست
Figure 3- Comparison of measured and predicted daily NEE ($\text{g C m}^{-2} \text{ day}^{-1}$) during the tested period

اتفاق می‌افتند. به عنوان مثال، در این مطالعه اوج شکوفایی و بلوغ در علفزار نسبت به مناطق جنگلی حدود ۲۰ روز زودتر می‌باشد. دو دلیل احتمالی برای افزایش عدم قطعیت در فصل رشد می‌توان در نظر گرفت. اول اینکه تنفس شبانه، کربن آلی محلول و خطاهای فیلترینگ ممکن است باعث عدم قطعیت NEE در اندازه‌گیری‌های میدانی شوند. تنفس شبانه تحت تاثیر عوامل زمین‌شناسی و اقلیمی منطقه منجر به عدم قطعیت می‌شوند. در طول روز، تنفس معمولاً به درستی ثبت می‌شود؛ ولی در طول شب، به دلیل کاهش سرعت باد، عوارض

مابقی ایام سال هم دوره‌ی خواب و بدون فعالیت زیستی گیاه به شمار می‌آید. در علفزار هم، روزهای ۱۲۰-۷۰ شروع برگ‌دهی و افزایش فتوسنتز، روزهای ۲۱۰-۱۲۰ مرحله‌ی بلوغ و اوج شکوفایی گیاه و روزهای ۳۳۰-۲۱۰ کاهش تدریجی برگ‌ها و افت فتوسنتز می‌باشد. مابقی ایام سال هم دوره‌ی خواب و بدون فعالیت زیستی گیاه به شمار می‌آید. این ارقام نشان می‌دهند مراحل رویشی و چرخه‌های زیستی در مناطق جنگلی و علفزار از نظر الگوی زمانی کمی متفاوت‌اند و تغییرات فنولوژیک علفزار نسبت به مناطق جنگلی زودتر

می‌تواند متاثر از شرایط جغرافیایی منطقه، تصحیحات اتمسفری و اثرات زاویه دید باشد (Zhou et al., 2019).

اهمیت نسبی متغیرهای محیطی در مدل‌سازی

برای آن که میزان تاثیرگذاری و نقش عوامل محیطی در مدل‌سازی PFTهای مختلف مشخص گردد اهمیت نسبی متغیرهای ورودی به عنوان نمونه در مدل جنگل تصادفی مورد تجزیه و تحلیل قرار گرفت. نتایج این بررسی نشان می‌دهد که تابش خورشیدی در تمام تیپ‌های عملکردی گیاهی بیشترین تاثیر بر پیش‌بینی NEE دارد. دمای هوا و دمای خاک هم در مناطق جنگلی از اهمیت تقریباً مشابهی برخوردارند؛ در حالی که در علفزار، دمای خاک عامل تعیین‌کننده‌تری برای تخمین تبادلات کربنی اکوسیستم می‌باشد (جدول ۶).

ناهموار زمینی (مثلاً محدوده‌های کوهستانی شیب‌دار) و شرایط بد آب و هوایی به درستی ثبت نمی‌گردد و باعث می‌شود کمتر از مقدار واقعی ثبت گردد. خطاهای فیلترینگ متاثر از تاثیر درجه حرارت، تابش خورشیدی و سرعت باد نیز باعث بروز عدم قطعیت در تخمین NEE می‌شوند. بعد از تهیه داده‌های خام از برج‌های اندازه‌گیری، در گام نخست با فواصل زمانی ۳۰ دقیقه‌ای پردازش می‌شوند و سپس با QA تکمیل می‌گردند. به هر حال، در فرایند پردازش ممکن است دماهای بالا حجم CO₂ را افزایش دهند که منجر به کاهش تراکم CO₂ می‌شود و در نتیجه NEE دست کم گرفته خواهد شد. دومین دلیل، مربوط به شاخص‌های LAI و fPAR حاصل از MODIS است. الگوریتم‌های غیر خطی باعث می‌شوند LAI سنجنده‌ی MODIS دست کم گرفته شود. به علاوه، عدم قطعیت‌های حاصل از تصحیح و بازیابی LAI و fPAR

جدول ۶- اهمیت نسبی متغیرهای محیطی در PFTها در تخمین NEE با مدل جنگل تصادفی

Figure 6- Relative importance of the environmental variables in different PFTs based on random forest model

PFT	Environmental Variables			
	PAR (MJ m ⁻²)	Air Temperature (°C)	Soil Temperature (°C)	Relative Humidity (%)
DBF	0.45	0.22	0.25	0.08
ENF	0.62	0.13	0.14	0.11
MF	0.63	0.12	0.12	0.13
GRA	0.40	0.15	0.28	0.17

و آمیخته تاثیر تقریباً بینابینی دارد. اما، می‌توان با اطمینان اظهار نمود که در تمامی پوشش‌های گیاهی تحت این مطالعه، تابش خورشیدی اولین پارامتر تاثیرگذار می‌باشد. مطالعه‌ی پنج PFTs شامل CRO^۱، EBF^۲، DBF، ENF و GRA با استفاده از مدل RF نشان داد در تمام تیپ‌های گیاهی، تابش خورشیدی بیشترین همبستگی را با GPP دارد. در جنگل‌های خزان‌کننده، مناطق کشاورزی و علفزارها که برگ‌های فصلی مشاهده می‌شوند، دمای هوا به عنوان دومین عامل تاثیرگذار است؛ در حالی که در جنگل‌های همیشه سبز خشکی هوا و یا خاک نقش مهم‌تری دارند (Moreaux et al., 2020). مطالعه‌ای در آیداهو صورت گرفت تا با استفاده از روش جنگل تصادفی تغییرات مکانی-زمانی NEE را در دو محدوده پیش‌بینی نمایند. نتایج نشان داد که تابش خورشیدی،

همان گونه که در جدول ۶ نشان داده شده است، از میان چهار فاکتور محیطی استفاده شده بیشترین حساسیت مدل به شدت تابش خورشیدی است که در مورد همه‌ی PFTها صدق می‌نماید. به عبارت دیگر، تابش خورشیدی مهم‌ترین فاکتور تاثیرگذار بر میزان تبادلات کربن اکوسیستم در PFTهای مورد مطالعه به شمار می‌آید. لازم به ذکر است، اهمیت نسبی این پارامتر در جنگل‌های سوزنی برگ و جنگل‌های آمیخته بیشتر از جنگل‌های پهن‌برگ خزان‌کننده و علفزار است. دمای هوا و دمای خاک در مناطق جنگلی اهمیت نسبی تقریباً مشابهی دارند؛ ولی در علفزار اهمیت نسبی دمای خاک تقریباً دو برابر دمای هوا می‌باشد. رطوبت نسبی در جنگل‌های پهن‌برگ و علفزار به ترتیب کمترین و بیشترین تاثیر را نشان می‌دهد ولی در جنگل‌های سوزنی‌برگ

^۲ - Evergreen Broadleaf Forest (EBF)

^۱ - Cropland (CRO)

شاخص سطح برگ و رطوبت خاک مهم‌ترین پارامترهای تاثیرگذار بر مدل‌سازی می‌باشند (Zhou et al., 2019). استفاده از متغیرهای اقلیمی که نوسانات بالایی دارند مانند بارندگی، درجه حرارت و تابش خورشیدی برای مدل‌سازی اهمیت بیشتری دارند و در کاهش عدم قطعیت موثرند (Zhu and Zhuang, 2015). تجزیه و تحلیل همدوسی متقابل^۱ و مدل RF هر دو تغییر در میزان اهمیت عوامل اقلیمی را بر روی NEE، GPP و R_{eco} ، با کاهش فرکانس زمانی تایید نموده‌اند. شواهد نشان می‌دهد که برای نمایش تغییرات شار CO_2 در فرکانس پایین باید متغیرهای محیطی بیشتری معرفی شوند؛ به ویژه در مکان‌هایی مانند جنگل‌های پهن‌برگ و مناطق کشاورزی که چرخه فصلی مشخصی ندارند (Moreaux et al., 2020). در مناطق مختلف جنگلی تأثیر مستقیم عوامل هیدروکلیماتیک بر شارهای تاج پوشش، به ویژه NEE، در مقیاس‌های زمانی طولانی‌تر به واسطه اثرات دینامیکی تاج پوشش، سازگاری گرمایی فتوسنتزی و اختلالات بوم‌سازگانی کم رنگ جلوه می‌دهند (Ouyang et al., 2014؛ Delpierre et al., 2012؛ Urbanski et al., 2007). متغیرهای اقلیمی تا ۸۰ درصد نوسانات شار CO_2 را در فرکانس بالا (متوسط شار ۳۰ دقیقه‌ای) نشان می‌دهند (Loescher، Hollinger et al., 2004؛ Moffat et al., 2010؛ et al., 2003). اما وقتی که فواصل زمانی طولانی‌تر می‌شوند تا ۵۰ درصد کاهش می‌یابد (Law، Luysaert et al., 2007b؛ et al., 2002). کاهش میزان شار CO_2 در فرکانس پایین تحت عنوان کنترل شار CO_2 توسط عوامل بیولوژیکی و تأثیر الگوهای آب و هوایی سینوپتیک تعبیر می‌شود؛ تا جایی که ۴۰ درصد واریانس NEE سالانه مدل‌سازی شده را به تغییر در محرک‌های محیطی و ۵۵ درصد به تغییر محرک‌های زیستی نسبت می‌دهند (Richardson et al., 2007). در علفزار هم، ضروری است که دمای خاک در مدل‌سازی مورد توجه قرار گیرد. در این مطالعه، دمای خاک به طور جداگانه در کنار دمای هوا مورد ارزیابی قرار گرفت تا تأثیر آن بر عملکرد مدل مشخص گردد. تبادلات کربنی خاک در مقایسه با فتوسنتز حساسیت بیشتری به درجه حرارت و کمبود رطوبت دارند

نتیجه‌گیری

تکنیک‌های یادگیری ماشین به عنوان روش‌های بدون مکانیسم در نظر گرفته می‌شوند که قابلیت کمی‌سازی شار کربن را از مقیاس محلی تا جهانی دارند. مدل‌های مکانیسم محور از قبیل روش‌های بیولوژیکی، شیمیایی و فیزیکی به دلیل انعطاف‌پذیری کمتر، در پیش‌بینی فرآیندهای مهم اکولوژیکی محدودیت دارند. روش‌های یادگیری ماشین در موضوعات متعددی مورد استفاده قرار می‌گیرند. به تازگی، این روش در مسائل اکولوژیکی و دینامیک کربن در خصوص افزایش مقیاس از سطح پایه به مقیاس‌های منطقه‌ای و جهانی و تکمیل مواردی که خلا داده‌ای و یا فقدان اندازه‌گیری توسط برج‌ها وجود دارند مورد توجه محققین قرار گرفته‌اند. به عنوان یک روش مورد قبول، می‌توانند مدل‌های پیش‌بینی را بدون مفروضات خاص یا نمایش ریاضی در مورد فرآیند مهم اکولوژیکی و فعل و انفعالات در طبیعت ارائه دهند. با استناد به مطالعات صورت گرفته جنگل تصادفی از جمله مدل‌هایی است که در میان روش‌های یادگیری ماشین عملکرد بسیار خوبی نشان می‌دهد. بکارگیری و انتخاب متغیرهای محیطی برای مدل‌سازی نیز مقوله‌ی مهمی است که در پیش‌بینی NEE و کاهش عدم قطعیت نقش اساسی بازی می‌کنند. معروف است که NEE ارتباط بالایی با تابش خورشیدی و دمای هوا دارد و مدل واکنش نور-دما می‌تواند پیش‌بینی خوبی از تبادلات کربنی داشته باشد. مطالعه‌ی چهار تیپ عملکردی گیاهی در این مطالعه نشان داد که DBF بالاترین میانگین جذب کربن در مقایسه با ENF، MF و GRA دارد که این موضوع اهمیت حفاظت و نگهداشت جنگل‌های پهن‌برگ مناطق معتدله در جهت مقابله با اثرات تغییرات

^۱ Wavelet Coherence Approach

^۲ Respiration of Ecosystem

- sequestration on arid rangelands in the United States? *Global Environmental Change*, 23(1), 240-251.
- Breiman, L. 2001. Random Forests. *Machine Learning* 45 (1), 5-32.
- Chen, B., Coops, N.C., Fu, D., Margolis, H.A., Amiro, B.D., Black, T.A., Arain, M.A., Barr, A.G., Bourque, C.P.A., Flanagan, L.B. and Lafleur, P.M. 2012. Characterizing spatial representativeness of flux tower eddy-covariance measurements across the Canadian Carbon Program Network using remote sensing and footprint analysis. *Remote Sensing of Environment*, 124, 742-755.
- CSIRO, The Commonwealth Scientific and Industrial Research Organization. Available on, www.csiro.au
- Delpierre, N., Soudani, K., François, C., Le Maire, G., Bernhofer, C., Kutsch, W., Misson, L., Rambal, S., Vesala, T. and Dufrene, E., 2012. Quantifying the influence of climate and biological drivers on the interannual variability of carbon exchanges in European forests through process-based modelling. *Agricultural and Forest Meteorology*, 154, 99-112.
- Dou, X., Yang, Y. and Luo, J., 2018. Estimating forest carbon fluxes using machine learning techniques based on eddy covariance measurements. *Sustainability*, 10(1), 203.
- Fodor, I.K., 2002. A survey of dimension reduction techniques (No. UCRL-ID-148494). Lawrence Livermore National Lab., CA (US).
- Ghosh, B. and Mukhopadhyay, S., 2021. Erosion susceptibility mapping of sub-watersheds for management prioritization using MCDM-based ensemble approach. *Arabian Journal of Geosciences*, 14(1), 1-18.
- Goulden, M.L., Wofsy, S.C., Harden, J.W., Trumbore, S.E., Crill, P.M., Gower, S.T., Fries, T., Daube, B.C., Fan, S.M., Sutton, D.J. and Bazzaz, A., 1998. Sensitivity of boreal forest carbon balance to soil thaw. *Science*, 279(5348), 214-217.
- Hollinger, D.Y., Aber, J., Dail, B., Davidson, E.A., Goltz, S.M., Hughes, H., Leclerc, M.Y., Lee, J.T., Richardson, A.D., Rodrigues, C. and Scott, N.A., 2004. Spatial and temporal variability in forest-atmosphere CO₂ exchange. *Global Change Biology*, 10(10), 1689-1706.
- Hu, J.I.A., Moore, D.J., Burns, S.P. and Monson, R.K., 2010. Longer growing seasons lead to less carbon sequestration by a subalpine forest. *Global Change Biology*, 16(2), 771-783.
- Jia, X., Zha, T., Gong, J., Zhang, Y., Wu, B., Qin, S. and Peltola, H., 2018. Multi-scale dynamics and environmental controls on net ecosystem CO₂ exchange over a temperate semiarid shrubland. اقلیمی را نشان می‌دهد. عملکرد مدل جنگل تصادفی با استناد به شاخص‌های آماری در علفزار از همه ضعیف تر می‌باشد. لازم به ذکر است، عملکرد ضعیف مدل در مناطق علفزار و یا توام با پوشش گیاهی تنک ناشی از ضعف مدل نیست بلکه این پدیده به دلیل سیگنال ناقص پوشش گیاهی، تاثیر قوی‌تر خاک در داده‌های سنجش از دوری استفاده شده و همچنین ناهمگنی بیشتر سطح زمین در این مناطق می‌باشد. از طرفی علفزار در مقایسه با سایر PFTها عملکرد بهتری در خصوص تاثیر دمای خاک به عنوان یکی از مولفه های ورودی مدل سازی از خود نشان می‌دهد و استفاده از این متغیر کارایی مدل را تا حد قابل قبولی افزایش می‌دهد. تغییرات روزانه و میانگین سالانه دمای خاک در علفزار نسبت به سایر PFTها رفتار مشابه تری دارند و الگوهای نسبتا یکسانی را نشان می‌دهند. دلیل این پدیده می‌تواند به واسطه‌ی تاج پوشش همگن تر علفزار در مقایسه با مناطق جنگلی باشد. هر چه به سمت اوج سبزی‌نگی مراتع (اواسط فصل رشد) پیش می‌رود نوسانات روزانه دما در ایستگاه‌های مختلف همگن تر می‌شود. یعنی تاج پوشش علفزار اجازه تغییرات دمایی را به خاک نمی‌دهد و باعث می‌شود خاک علفزار کمتر تحت تاثیر قرار گیرد. اما در تیپ‌های جنگلی به دلیل ساختار چند اشکوبی و فضای خالی بین تاج پوشش‌ها امکان نفوذ نور به کف جنگل وجود دارد و در نتیجه تغییرات روزانه دمایی آنها بیشتر مشهود است.

منابع

- Baldocchi, D., Falge, E., Gu, L., Olson, R., Hollinger, D., Running, S., Anthoni, P., Bernhofer, C., Davis, K., Evans, R. and Fuentes, J. 2001. FLUXNET, A new tool to study the temporal and spatial variability of ecosystem-scale carbon dioxide, water vapor, and energy flux densities. *Bulletin of the American Meteorological Society*, 82(11), 2415-2434.
- Barzegar, R., Moghaddam, A.A., Adamowski, J. and Ozga-Zielinski, B., 2018. Multi-step water quality forecasting using a boosting ensemble multi-wavelet extreme learning machine model. *Stochastic environmental research and risk assessment*, 32(3), 799-813.
- Booker, K., Huntsinger, L., Bartolome, J.W., Sayre, N.F. and Stewart, W., 2013. What can ecological science tell us about opportunities for carbon

- ecosystem responses to climatic controls using artificial neural networks. *Global change biology*, 16(10), 2737-2749.
- Moreaux, V., Longdoz, B., Berveiller, D., Delpierre, N., Dufrêne, E., Bonnefond, J.M., Chipeaux, C., Joffre, R., Limousin, J.M., Ourcival, J.M. and Klumpp, K., 2020. Environmental control of land-atmosphere CO₂ fluxes from temperate ecosystems, a statistical approach based on homogenized time series from five land-use types. *Tellus B, Chemical and Physical Meteorology*, 72(1), 1-25.
- Norman, J.M., Garcia, R. and Verma, S.B., 1992. Soil surface CO₂ fluxes and the carbon budget of a grassland. *Journal of Geophysical Research, Atmospheres*, 97(D17), 18845-18853.
- Ouyang, Z., Chen, J., Becker, R., Chu, H., Xie, J., Shao, C. and John, R., 2014. Disentangling the confounding effects of PAR and air temperature on net ecosystem exchange at multiple time scales. *Ecological Complexity*, 19, 46-58.
- Puche, N., Senapati, N., Flechard, C.R., Klumpp, K., Kirschbaum, M.U. and Chabbi, A., 2019. Modeling carbon and water fluxes of managed grasslands, Comparing flux variability and net carbon budgets between grazed and mowed systems. *Agronomy*, 9(4), 183.
- Richardson, A.D., Hollinger, D.Y., Aber, J.D., Ollinger, S.V. and Braswell, B.H., 2007. Environmental variation is directly responsible for short-but not long-term variation in forest-atmosphere carbon exchange. *Global Change Biology*, 13(4), 788-803.
- Sándor, R., Ehrhardt, F., Grace, P., Recous, S., Smith, P., Snow, V., Soussana, J.F., Basso, B., Bhatia, A., Brill, L. and Doltra, J., 2020. Ensemble modelling of carbon fluxes in grasslands and croplands. *Field Crops Research*, 252, 107791.
- Stoy, P.C., Dietze, M.C., Richardson, A.D., Vargas, R., Barr, A.G., Anderson, R.S., Arain, M.A., Baker, I.T., Black, T.A., Chen, J.M. and Cook, R.B., 2013. Evaluating the agreement between measurements and models of net ecosystem exchange at different times and timescales using wavelet coherence, an example using data from the North American Carbon Program Site-Level Interim Synthesis. *Biogeosciences*, 10(11), 6893-6909.
- Tramontana, G., Migliavacca, M., Jung, M., Reichstein, M., Keenan, T.F., Camps-Valls, G., Ogee, J., Verrelst, J. and Papale, D., 2020. Partitioning net carbon dioxide fluxes into photosynthesis and respiration using neural networks. *Global change biology*, 26(9), 5235-5253.
- Agricultural and Forest Meteorology, 259, 250-259.
- Khalili, A., Bazrafshan, J. and Cheraghizadeh, M., 2022. A Comparative study on climate maps of Iran in extended de Martonne classification and application of the method for world climate zoning. *Journal of Agricultural Meteorology*, 10(1), pp.3-16.
- Kia, S. H. Milton, E. J. 2015. Hyper-Temporal Remote Sensing for Scaling between Spectral Indices and Flux Tower Measurements. *Applied Ecology and Environmental Research* 13(2), 465-487.
- Kult, J., Choi, W. and Choi, J., 2014. Sensitivity of the Snowmelt Runoff Model to snow covered area and temperature inputs. *Applied Geography*, 55, pp.30-38.
- Law, B.E., Falge, E., Gu, L.V., Baldocchi, D.D., Bakwin, P., Berbigier, P., Davis, K., Dolman, A.J., Falk, M., Fuentes, J.D. and Goldstein, A., 2002. Environmental controls over carbon dioxide and water vapor exchange of terrestrial vegetation. *Agricultural and Forest Meteorology*, 113(1-4), 97-120.
- Liang, J., Guo, Q., Zhang, Z., Zhang, M., Tian, P. and Zhang, L., 2020. Influence of Complex Terrain on Near-Surface Turbulence Structures over Loess Plateau. *Atmosphere*, 11(9), 930.
- Lindroth, A., Lagergren, F., Aurela, M., Bjarnadottir, B., Christensen, T., Dellwik, E., Grelle, A., Ibrom, A., Johansson, T., Lankreijer, H. and Launiainen, S., 2008. Leaf area index is the principal scaling parameter for both gross photosynthesis and ecosystem respiration of Northern deciduous and coniferous forests. *Tellus B, Chemical and Physical Meteorology*, 60(2), 129-142.
- Loescher, H.W., Oberbauer, S.F., Gholz, H.L. and Clark, D.B., 2003. Environmental controls on net ecosystem-level carbon exchange and productivity in a Central American tropical wet forest. *Global Change Biology*, 9(3), 396-412.
- Luyssaert, S., Janssens, I.A., Sulkava, M., Papale, D., Dolman, A.J., Reichstein, M., Hollmen, J., Martin, J.G., Suni, T., Vesala, T. and Loustau, D., 2007b. Photosynthesis drives anomalies in net carbon-exchange of pine forests at different latitudes. *Global Change Biology*, 13(10), 2110-2127.
- Mahadevan, P., Wofsy, S.C., Matross, D.M., Xiao, X., Dunn, A.L., Lin, J.C., Gerbig, C., Munger, J.W., Chow, V.Y. and Gottlieb, E.W., 2008. A satellite-based biosphere parameterization for net ecosystem CO₂ exchange, Vegetation Photosynthesis and Respiration Model (VPRM). *Global Biogeochemical Cycles*, 22(2).
- Moffat, A.M., Beckstein, C., Churkina, G., Mund, M. and Heimann, M., 2010. Characterization of

- regional carbon fluxes, A model-data fusion approach. *Agricultural and Forest Meteorology*, 189, 175-186.
- Xiao, J., Davis, K.J., Urban, N.M., Keller, K. and Saliendra, N.Z., 2011. Upscaling carbon fluxes from towers to the regional scale, Influence of parameter variability and land cover representation on regional flux estimates. *Journal of Geophysical Research, Biogeosciences*, 116(G3).
- Xu, T., Guo, Z., Liu, S., He, X., Meng, Y., Xu, Z., Xia, Y., Xiao, J., Zhang, Y., Ma, Y. and Song, L., 2018. Evaluating different machine learning methods for upscaling evapotranspiration from flux towers to the regional scale. *Journal of Geophysical Research, Atmospheres*, 123(16), 8674-8690.
- Zhou, Q., Fellows, A., Flerchinger, G.N. and Flores, A.N., 2019. Examining interactions between and among predictors of net ecosystem exchange, A machine learning approach in a semi-arid landscape. *Scientific reports*, 9(1), 1-11.
- Zhu, Q., and Zhuang, Q., 2015. Ecosystem biogeochemistry model parameterization, Do more flux data result in a better model in predicting carbon flux? *Ecosphere*, 6(12), 1-20.
- Urbanski, S., Barford, C., Wofsy, S., Kucharik, C., Pyle, E., Budney, J., McKain, K., Fitzjarrald, D., Czikowsky, M. and Munger, J.W., 2007. Factors controlling CO₂ exchange on timescales from hourly to decadal at Harvard Forest. *Journal of Geophysical Research, Biogeosciences*, 112(G2).
- Wang, L., Tian, F., Huang, K., Wang, Y., Wu, Z. and Fensholt, R., 2020. Asymmetric patterns and temporal changes in phenology based seasonal gross carbon uptake of global terrestrial ecosystems. *Global Ecology and Biogeography*, 29(6), 1020-1033.
- Wu, S.H. and Jansson, P.E., 2012. Modelling soil temperature and moisture and corresponding seasonality of photosynthesis and transpiration in a boreal spruce ecosystem. *Hydrology and Earth System Sciences Discussions*, 9(5).
- Xiao, J., Chen, J., Davis, K.J. and Reichstein, M., 2012. Advances in upscaling of eddy covariance measurements of carbon and water fluxes. *Journal of Geophysical Research, Biogeosciences*, 117(G1).
- Xiao, J., Davis, K.J., Urban, N.M. and Keller, K., 2014. Uncertainty in model parameters and



Application of random forest technique for modelling Carbon Exchanges rate measured by eddy covariance measurement

H. Abbasian¹, E. Solgi^{2*}, S. M. Hosseini³, S. H. Kia⁴, S. Kheradmand⁵, P. Abbasian⁶

Received: 18/02/2025

Accepted: 22/09/2025

Abstract

Net ecosystem exchange (NEE) serves as an important indicator for assessing how carbon dioxide (CO₂) flows between the land surface and the atmosphere, particularly in the context of climate change. Although in situ instruments are available for monitoring carbon exchanges, but the temporal and spatial scale limitations of these observations' attempts have been made to develop models for NEE prediction. This study examined daily NEE variations across four plant functional types (PFTs): Deciduous broadleaf forest (DBF), Coniferous forest (ENF), Mixed Forest (MF), and Grassland (GRA). Using the, a machine learning approach, namely random forest (RF) method. Four meteorological variables including solar radiation, air temperature, soil temperature, and relative humidity were used as inputs for the model. The measured and predicted values were evaluated using four statistical indices of R², NSE, Bias, and RMSE. The results indicated that DBF had the most accurate modeling performance, whereas GRA had the least. An analysis of the relative significance of environmental variables revealed that solar radiation was the most important and relative humidity the least important across all PFTs. Additionally, soil temperature improved the model performance in grasslands more significantly compared to air temperature, unlike the results in forest functional types. The study also highlighted that uncertainty remains a significant issue during different phenological stages across all PFTs; with the highest uncertainty between days 140-220 in forest types and 120-210 in grassland, according to the Julian calendar.

Keywords: Carbon Dioxide (CO₂), Net Ecosystem Exchange (NEE), Phenology, Plant Functional Types (PFTs), Random Forest (RF), Uncertainty



¹ Ph.D. of Environmental Pollution, Faculty of Natural Resources and Environment, Malayer University, and MahabGhodss Consulting Engineering Co, Tehran, Iran

² Professor Department of Environmental Sciences and Engineering, Faculty of Natural Resources and Environment, Malayer University, Malayer, Iran

(*Corresponding Author Email Address: s.golestani@uk.ac.ir)

³ Department of Forest Science and Engineering, Faculty of Natural Resources, Tarbiat Modares University, Noor, Mazandaran, Iran

⁴ Assistant Professor, Ecological Remote Sensing, Islamic Azad University, North Branch, Tehran, Iran

⁵ Ph.D. Student of Ocean Sciences, Victoria University, BC, Canada

⁶ Ph.D. in Forestry, General Department of Natural Resources and Watershed Management of Alborz Province, Karaj, Iran

نحوه ارجاع مقاله:

عباسیان، ح.، سلگی، ع.، حسینی، س. م.، کیا، س. ح.، خردمند، س.، عباسیان، پ. ۱۴۰۵. کاربرد تکنیک جنگل تصادفی در مدل سازی کربن تبادلی

اندازه گیری شده به روش همبستگی پیچهای. نشریه هواشناسی کشاورزی، ۱۳(۲)، ۲۸-۱۵. DOI: 10.22125/agmj.2024.459793.1169

Abbasian, H., Solgi, E., Hosseini, S. M., Kia, S. H., Kheradmand, S. Abbasian, P. 2026. Application of random forest technique for modelling Carbon Exchanges rate measured by eddy covariance measurement. Journal of Agricultural Meteorology, 13(2), 15-28. DOI: 10.22125/agmj.2024.459793.1169