

## تخمین توزیع مکانی-زمانی شاخص سطح برگ با استفاده از تصاویر ماهواره‌ای Sentinel-2 (مطالعه موردی: مزارع ذرت علوفه‌ای جنوب تهران)

الهه اکبری<sup>۱</sup>، علی درویشی بلورانی<sup>۲\*</sup>، نجمه نیسانی سامانی<sup>۳</sup>، سعید حمزه<sup>۴</sup>، سعید صوفی زاده<sup>۵</sup>، استفانو پیگناتی<sup>۶</sup>

تاریخ دریافت: ۱۳۹۹/۱/۲۴ تاریخ پذیرش: ۱۳۹۹/۲/۳۰

### چکیده

شاخص سطح برگ (LAI)، در مطالعات هیدرولوژی، کشاورزی و مدیریت آبیاری اراضی، نقش مهمی را ایفا می‌کند. به منظور دستیابی به الگوریتم مناسب، با دقت و استوار یا پایدار (robust) برای تخمین توزیع مکانی-زمانی LAI با استفاده از تصاویر Sentinel-2، الگوریتم‌های رگرسیون بردار پشتیبان (SVR)، Kernel Ridge Regression (KRR)، Relevance Vector Machines (RVM) و رگرسیون فرآیند گوسی (GPR)، کالیبره و مورد ارزیابی قرار گرفتند. داده‌های این تحقیق، از مزارع ذرت علوفه‌ای شهرستان قلعه‌نو در استان تهران، در کل دوره رشد آن در تابستان ۱۳۹۷، از طریق اندازه‌گیری تخریبی و نیز عکسبرداری نیم‌کره‌ای، جمع‌آوری شد. نتایج تحقیق با الگوریتم‌های متداول در این حوزه؛ جنگل تصادفی (RF) و شبکه عصبی مصنوعی (ANN)، مقایسه گردیدند. نتایج نشان می‌دهد که الگوریتم GPR، نه تنها از دقت (در گروه بانندی بیست متری،  $R^2 = 0.913$  و  $RMSE = 0.641$ )، سرعت و پایداری بالاتری در تخمین LAI برخوردار بوده، بلکه قابلیت منحصر به فرد ایجاد نقشه پیکسل مبنای عدم اطمینان (عدم اطمینان و عدم اطمینان نسبی، به ترتیب، به مساحت ۹۶٪ و ۷۴٪ از کل منطقه کمتر از ۰/۷ و ۳۰٪) را داراست. با در نظر گرفتن مقادیر  $R^2$  و  $RMSE$ ، SVR دومین الگوریتم با دقت برای برآورد LAI و بعد از آن، RVM، KRR، RF و ANN، به ترتیب می‌باشند. مقایسه LAI تخمین زده شده و میدانی در دفعات نمونه‌برداری با  $RMSE = 0.276$  و  $Bias = 0.099$ ، و سایر مزایای مطرح شده، بر کارایی الگوریتم GPR در تخمین توزیع مکانی-زمانی LAI دلالت دارد.

**واژه‌های کلیدی:** الگوریتم کرنل مینا، شاخص سطح برگ، عکسبرداری نیم‌کره‌ای، مطالعه منطقه‌ای، نقشه پیکسل مینا

### مقدمه

تخمین توزیع مکانی - زمانی پارامتر بیوفیزیکی شاخص سطح برگ<sup>۶</sup> (LAI) در مزارع کشاورزی، بیانگر چگونگی کاربرد استراتژی-

های مدیریت مزرعه از جمله برنامه‌ریزی آبیاری و یکنواختی توزیع آب در مزرعه است (گوینده نجف آبادی و همکاران، ۱۳۹۷). LAI بیانگر مجموع سطح برگ‌های گیاه نسبت به واحد سطح زمین است (Watson, 1947) و در طی فصل رشد گیاهان، برآورد این پارامتر بیوفیزیکی برای نظارت بر خصوصیات محصول (Campos-Taberner et al., 2015)، مدل‌سازی رشد محصول و پیش‌بینی عملکرد آن (Jin et al., 2015)، بهینه‌سازی تولید محصولات کشاورزی (Kross et al., 2015)، تنظیم نمودن مدل‌های جهانی اقلیمی، هیدرولوژی، اکولوژی و اکوسیستم کشاورزی (Mousivand et al., 2015) و نیز تخمین تبخیر-تعرق پوشش گیاهی (Verrelst et al., 2012b) مهم و ضروری است.

LAI به طور سنتی از طریق روش‌های مستقیم مخرب و زمان‌بر تخمین زده می‌شود، اما سنسجش از دور با امکان بازیابی یکپارچه و با دید وسیع از منطقه، سهولت دسترسی به داده، دقت بالا و صرفه‌جویی در زمان، بر سایر روش‌ها ارجحیت دارد (Kross et al., 2015). در

- ۱- دانشجوی دکتری سنسجش از دور، گروه سنسجش از دور و GIS، دانشکده جغرافیا، دانشگاه تهران
  - ۲- دانشیار گروه سنسجش از دور و GIS، دانشکده جغرافیا، دانشگاه تهران
  - ۳- دانشیار گروه سنسجش از دور و GIS، دانشکده جغرافیا، دانشگاه تهران
  - ۴- دانشیار گروه سنسجش از دور و GIS، دانشکده جغرافیا، دانشگاه تهران
  - ۵- استادیار گروه آگرواکولوژی، موسسه تحقیقاتی علوم محیطی، دانشگاه شهید بهشتی
  - ۶- موسسه روش‌شناسی برای تحلیل‌های محیطی (CNR IMAA)، C.da S.Loja snc, 85050 Tito (Potenza) ایتالیا  
(Email: ali.darvishi@ut.ac.ir) \* نویسنده مسئول
- 6- Leaf Area Index

این موضوع در مراحل ابتدایی خود است و ضرورت کالیبره نمودن این الگوریتم‌ها و ایجاد مدل با دقت برای تخمین پارامترهای بیوفیزیکی، احساس می‌شود. تا به امروز، این روشها برای تخمین پارامتر LAI در مطالعات محدودی از جمله Verrelst et al. 2012a,b; 2013; 2015b; 2016; Mateo-Sanchis et al., 2018; Azadbakht et al., 2019 ارزیابی شده‌اند. در این تحقیقات، از داده‌های شبیه‌سازی شده Sentinel-2 (S2) و یا سایر داده‌ها و تصاویر ماهواره‌ای، استفاده شده و در الگوریتم GPR، به میزان دقت در حدود ۰/۹۱- $R^2$  در ۰/۸۷۹ و ۰/۶۷-۰/۴۹ در RMSE، برای بازیابی LAI دست یافته‌اند. تنها در دو تحقیق و رلست و همکاران به مقایسه الگوریتم‌های مورد مطالعه در این تحقیق برای برآورد LAI در گیاهان مختلف با نمونه‌برداری از یک مرحله از رشد آنها پرداخته‌اند و بیان نموده‌اند که الگوریتم GPR نسبت به سایر الگوریتم‌ها در اولویت اول از نظر دقت و پس از آن، SVR، KRR، RVM، RF و ANN به ترتیب قرار دارند (Verrelst et al. 2012b; 2015b). با توجه به نقاط ضعف داده شبیه‌سازی شده و مغایرت با داده واقعی، محققین به لزوم بررسی الگوریتم‌های کارا و مناسب برای تخمین پارامترهای بیوفیزیکی در تصاویر واقعی و غیر شبیه‌سازی شده Sentinel-2 در دوره کامل رشد گیاه اذعان نموده‌اند. بنابراین، لزوم بررسی کارایی این الگوریتم‌ها در بازیابی کمی و مکانی-زمانی LAI در دوره کامل رشد گیاه و در سری زمانی تصاویر ماهواره‌ای Sentinel-2 بصورت منطقه‌ای و عملیاتی، منجر به تحقیق کاربردی حاضر شده است.

در تحقیقات عملیاتی و کاربردی برای تخمین پارامترهای بیوفیزیکی، این نکته همچنان وجود دارد که کدامیک از الگوریتم‌های MLA منجر به دقت بالاتر، پایداری بیشتر و زمان پردازشی کمتر خواهند شد. داده Sentinel-2، نیز داده نوظهور و ارزشمندی برای نظارت بر زمین است (Houborg and McCabe, 2018) که برای دستیابی به دقت بالاتر در تخمین پارامترهای بیوفیزیکی، بایستی روش‌های بازیابی کمی و پیوسته مکانی-زمانی در استفاده از این داده‌ها، مورد ارزیابی و تحقیق قرار گیرند (Verrelst et al., 2015b). بنابراین، با در نظر گرفتن این دو نکته و اهمیت مطالعه در دوره کامل رشد گیاه، تحقیق حاضر برای دستیابی به اهداف، ۱- مقایسه و ارزیابی الگوریتم‌های غیرخطی یادگیری ماشین کرنل مبنا شامل رگرسیون بردار پشتیبان<sup>۵</sup> (SVR)، KRR، RVM و GPR برای دستیابی به الگوریتم با دقت بالا و پایدار در تخمین LAI، ۲- مقایسه نتایج الگوریتم‌های کرنل مبنا با الگوریتم‌های متداول و مرسوم در تحقیقات عملیاتی در این حوزه، یعنی الگوریتم‌های جنگل تصادفی<sup>۶</sup> (RF) و شبکه عصبی مصنوعی<sup>۷</sup> (ANN)، ۳- بازیابی توزیع

این راستا، پتانسیل و قابلیت سنجش از دور اپتیکی در بازیابی کمی و پیوسته مکانی-زمانی از ویژگی‌های اصلی کانوپی گزارش شده است (به عنوان مثال، Houborg and Boegh, 2008; Gray and Song, 2012; Verrelst et al., 2012a, b, 2015b; Wu et al., 2015; Mousivand et al., 2015). در تحقیقات مربوط به برآورد پارامترهای بیوفیزیکی مورد پذیرش قرار گرفته که روش‌های تجربی شاخص مبنا، کاملاً وابسته به منطقه بوده و در مناطق مطالعاتی مختلف، ناپایدار هستند (Verrelst et al., 2010; 2012b). علاوه بر این، عوامل مختلفی مانند ساختار پوشش گیاهی و پس زمینه در سطح کانوپی به طور قابل توجهی بر روی شاخص‌های پوشش گیاهی<sup>۱</sup> (VIs) و نیز دقت برآورد پارامترها تأثیر می‌گذارند (Verrelst et al., 2012a). در این راستا، فرید حسینی و همکاران (۱۳۹۱)، بادیه‌نشین و همکاران (۱۳۹۳)، آبکار و همکاران (۱۳۹۴)، مختاری و همکاران (۱۳۹۶)، با استفاده از شاخص‌های پوشش گیاهی به برآورد میزان LAI گیاهان مختلف با استفاده از سنجش از دور پرداخته‌اند. در این تحقیقات به دقت برآورد در حدود ۱/۵۷ در RMSE و ۰/۵۳ الی ۰/۷۸ در  $R^2$  دست یافته‌اند. از طرفی، روش‌های فیزیک مبنا مانند معکوس کردن مدل انتقال تابش<sup>۲</sup> (RT) به محاسبات پیچیده و نیز اطلاعات اختصاصی منطقه مطالعاتی، برای تنظیم نمودن پارامترهای مدل نیاز دارند که همیشه این اطلاعات در دسترس، دقیق و به روز نیست (Verrelst et al., 2012b). همچنین، اعمال فرضیات هنگام استفاده از این روش، منجر به کاهش دقت شده و این نکات باعث می‌شود در مطالعات جهانی و منطقه‌ای با محدودیت مواجه شوند (آبکار و همکاران، ۱۳۹۴). از آنجایی که اغلب بین انعکاس ثبت شده در تصاویر چند طیفی و ابرطیفی با پارامترهای بیوفیزیکی، روابط غیرخطی وجود دارد (Verrelst et al., 2015a)، الگوریتم‌های یادگیری ماشین<sup>۳</sup> (MLA)، نه تنها به تنظیم نمودن تعداد پارامتر محدودی نیاز دارند، بلکه قابلیت محاسبه این ارتباط غیرخطی و تهیه نقشه پارامترهای بیوفیزیکی را دارا هستند (Verrelst et al., 2012b; 2013).

در سنجش از دور، روش‌های رگرسیون فرآیند گوسی<sup>۴</sup> (GPR) مورد توجه خاص هستند، زیرا نه تنها پیش‌بینی‌های پیکسل مبنا را ارائه می‌دهند، بلکه در حال حاضر تنها روش MLA می‌باشند که فواصل اطمینان یا نقشه‌های عدم اطمینان را برای پیش‌بینی‌ها ایجاد می‌کنند. برآورد این عدم اطمینان، اطلاعاتی تکمیلی در مورد قابلیت بسط یک مدل آموزش دیده محلی به سایر مناطق مطالعاتی را نیز ارائه می‌دهد (Verrelst et al., 2015a, b). هنوز تحقیقات مرتبط با

5- Support Vector Regression  
6- Random Forest  
7- Artificial Neural Network

1- Vegetation Index  
2- Radiative transfer model  
3- Machine Learning Algorithm  
4- Gaussian Process Regression

آوری داده LAI، پرداخته و سپس میانگین نتایج دو پروتکل بدست آمد. تعداد دفعات نمونه‌برداری با فواصل زمانی ۱۰ الی ۱۵ روزه (۶ بار در هر ESU)، با در نظر گرفتن فنولوژی ذرت علوفه‌ای در کل دوره رشد و پوشش دادن زمان‌های مهم فنولوژی گیاه شامل سه تا چهار برگ، هشت تا نه برگ، دوازده برگ، گلدهی، شکل‌گیری دانه و شروع پر شدن دانه لحاظ شده است.

پروتکل تخریبی (محاسبه LAI با استفاده از چیند گیاه): نمونه‌های گیاهی ذرت علوفه‌ای به طور همزمان با برداشت تصویر Sentinel-2 در طی فصل رشد آن، جمع‌آوری شد. در هر ESU چهار بوته چیده و طول و عرض هر برگ به صورت دستی اندازه‌گیری شد. مساحت هر برگ جداگانه بر اساس طول × عرض حداکثر هر برگ × ۰/۷۵ محاسبه شد. LAI با تقسیم سطح برگ کل برگ‌های چهار بوته بر مساحت منطقه نمونه‌برداری محاسبه گردید (مساحت منطقه نمونه‌برداری: تعداد نمونه‌های تخریبی × فاصله ردیف × فاصله بین بوته‌ها در هر ردیف) (Gao et al., 2010; Munz et al., 2014; Xia et al., 2016).

پروتکل عکسبرداری نیم‌کروی: به طور همزمان با برداشت تصویر Sentinel-2 در طی فصل رشد ذرت علوفه‌ای، عکسبرداری نیم‌کروی در هر ESU به منظور جمع‌آوری و محاسبه داده fCover بصورت سری زمانی و منطبق بر زمان‌های مهم فنولوژی گیاه صورت گرفت. طرح نمونه‌برداری در هر ESU با تعداد دفعات ۶ بار، منطبق بر دستورالعمل‌ها و توصیه‌های پروتکل اعتبارسنجی از طریق ابزارهای سنسجس از دور در اروپا<sup>۵</sup> (VALERI) انجام شد (http://w3.avignon.inra.fr/valeri/; Baret et al., 2005). ابعاد هر ESU سازگار با اندازه پیکسل Sentinel-2 در حدود ۲۰ × ۲۰ متر است، موقعیت آنها دور از مرز زمین کشاورزی (حداقل ۳۰ متر به سمت داخل مزارع) برای رفع اثر مرز واقع شده و مرکز ESU با استفاده از GPS برای تطبیق با پیکسل تصویر ماهواره‌ای اندازه‌گیری شد. به منظور محاسبه و در نظر گرفتن تغییرپذیری مکانی در هر ESU، بین ۹ الی ۱۲ عکس DHP بر اساس برنامه عکاسی پیشنهاد شده برای کانوی همگن (مشابه ذرت) در (ESA, 2005)، عکسبرداری شد. در این منطقه، تعداد ۱۸۰ گروه عکس DHP (گروه عکس DHP: بین ۹ الی ۱۲ عکس در هر ESU)، در کل دوره رشد گیاه ذرت علوفه‌ای، با دوربین Canon 5d mark ii مجهز به لنز فیش آی FC-E8 عکسبرداری شده است.

مکانی-زمانی پارامتر بیوفیزیکی LAI بصورت پیکسل مبنای منطقه‌ای، و ایجاد نقشه پیکسل مبنای مقادیر عدم اطمینان مرتبط با آنها، انجام شده است. این اهداف، در دو گروه باندی با قدرت تفکیک مکانی ۱۰ و ۲۰ متری سری زمانی تصاویر Sentinel-2 در کل دوره رشد گیاه ذرت علوفه‌ای، تحت بررسی قرار گرفتند. داده‌های مورد استفاده برای این بررسی از مزارع ذرت علوفه‌ای شهرستان قلعه نو واقع در تهران، مطابق با فنولوژی ذرت علوفه‌ای در تابستان ۱۳۹۷، از طریق اندازه‌گیری تخریبی<sup>۱</sup> و نیز عکسبرداری رقومی نیم‌کروی<sup>۲</sup> (DHP) در هر واحد نمونه‌برداری اولیه<sup>۳</sup> (ESU) در مزرعه، جمع‌آوری شده است.

## مواد و روش‌ها

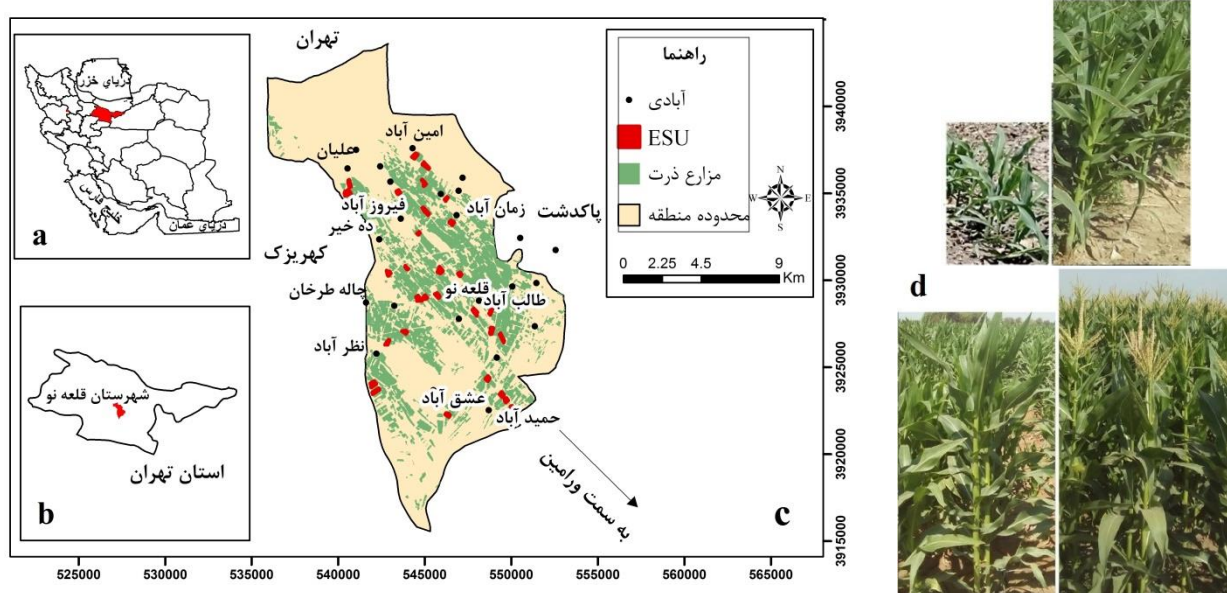
### منطقه مورد مطالعه

مزارع مطالعاتی ذرت علوفه‌ای در طی فصل رشد آن در سال ۱۳۹۷، متعلق به شهرستان قلعه‌نو در استان تهران می‌باشد (۳۶' N ۳۵° - ۲۳' و ۳۵° E ۳۵' - ۵۱° ۲۴' (شکل ۱). حداقل و حداکثر دما و میانگین بارش سالانه به ترتیب ۴-، ۲۴ درجه سانتی‌گراد و ۲۰۰ میلی‌متر است (IRIMO, 2018). منطقه مورد مطالعه با مورفولوژی دشت، به وسعت ۲۲ کیلومتر × ۱۰ کیلومتر و اغلب با مزارع کشاورزی ذرت علوفه‌ای (۷۵۰۰ هکتار) وسعت یافته است. دو رقم محلی ذرت علوفه‌ای (سینگل کراس ۷۰۴ و ۷۰۶) از اواسط خرداد تا اواسط تیر ۱۳۹۷ کاشته شده و از اواسط شهریور تا اواسط مهر همان سال برداشت گردید. منبع آب آبیاری مزارع شامل آب قنات، چاه و فاضلاب تصفیه نشده شهری و سیستم آبیاری بارانی و غرقابی می‌باشد. در این مطالعه، مزارع مطالعاتی شامل ۳۰ مزرعه تحت کشت ذرت علوفه‌ای می‌باشد که نمونه‌برداری و اندازه‌گیری‌های مربوطه در هر واحد ESU انجام شده است.

### داده میدانی

به منظور پوشش دادن هر چه بیشتر تغییرپذیری منطقه مورد مطالعه، بر اساس نقشه نوع کشت منطقه، بافت خاک و اطلاعات ارائه شده توسط کشاورزان در آغاز فصل رشد ذرت علوفه‌ای، نمونه‌برداری طبقه‌بندی شده<sup>۴</sup> برای انتخاب ESU (تعداد ۳۰ محل نمونه‌برداری) برداری) با احتساب گونه‌های مختلف ذرت علوفه‌ای و تاریخ کاشت متفاوت آنها، در نظر گرفته شد. نمونه‌برداری در فصل رشد ذرت علوفه‌ای در سال ۱۳۹۷ انجام شد و با استفاده از دو پروتکل به جمع-

- 1- Destructive measurement
- 2- Digital Hemispherical Photography
- 3- Elementary Sampling Unit
- 4- Stratified sampling



شکل ۱- (a و b) موقعیت منطقه مورد مطالعه در ایران و استان تهران، (c) مزارع ذرت علوفه‌ای در شهرستان قلعه‌نو و مزارع ESU تحت مطالعه، (d) عکس از اراضی کشاورزی در مراحل مختلف رشد گیاه

الی ۱۸ مهر ۱۳۹۷ استفاده شده است. این تصاویر، بر اساس فنولوژی گیاه ذرت علوفه‌ای در کل دوره رشد و منطبق بر زمان نمونه‌برداری زمینی انتخاب شده است. جفت ماهواره‌های S2 دارای سنجنده چند طیفی (MSI) با قدرت تفکیک زمانی ۵ روزه است. اطلاعات چند طیفی از ۱۳ باند که حاوی مرئی - مادون قرمز نزدیک (VNIR)، مادون قرمز کوتاه (SWIR) است که شامل چهار، شش و سه باند به ترتیب با قدرت تفکیک مکانی ۱۰، ۲۰ و ۶۰ متر، و به طور خاص، S2 شامل سه باند جدید در منطقه red-edge است (جدول ۱). با استفاده از افزونه Sen2Cor، تصحیح اتمسفری و رادیومتریک داده‌های Sentinel-2 در نرم‌افزار SNAP (Sentinel Application Platform) انجام شده و با تبدیل Top of Atmosphere Level-1C از Level-2A محصول Bottom of Atmosphere تولید می‌گردد. در این نرم‌افزار، از الگوریتم ATCOR<sup>4</sup> برای تصحیح اتمسفری استفاده می‌شود.

#### روش تحقیق

به منظور تخمین مکانی-زمانی LAI، از روش‌های کرنل مبنای MLAs؛ SVR، KRR، RVM، GPR، استفاده شد و نیز کارایی آنها با الگوریتم‌های مرسوم و متداول در تحقیقات مشابه (الگوریتم جنگل تصادفی و شبکه عصبی مصنوعی) مقایسه گردید. این الگوریتم‌ها برای دستیابی به الگوریتم با دقت بالا و پایدار به

براساس کلوری و همکاران، برای کاهش خطاها در برآورد کسری گپ جهتی<sup>۱</sup>، دوربین در بالای سه پایه تلسکوپی قرار گرفت تا جهت مشاهده به سمت پایین و فاصله کانوپی تا سنسور (۱/۵ متر) ثابت باشد (Claverie et al., 2012). برای محاسبه fCover از پردازشگر CAN-EYE (<http://www4.paca.inra.fr/can-eye>) استفاده شده است. این پردازشگر، امکان به دست آوردن پارامترهای بیوفیزیکی کانوپی از قبیل fCover، FAPAR<sup>۲</sup> و ALIA<sup>۳</sup> را براساس برآورد gap fraction و با استفاده از معکوس مدل Poisson، فراهم می‌کند. در این روش، با استفاده از Look Up Table، با محدوده زاویه زینت مختلف، مقادیر موردنظر برآورد می‌شود (ESA, 2005). برای محاسبه LAI، از مدل Ritchie بهره گرفته شد:  $fCover = 1 - \exp(-K \cdot LAI)$  که در آن K ضریب میرایی به میزان ۰/۵ برای ذرت مطابق با (Cavero et al., 2000; Battude et al., 2016) در نظر گرفته شد.

#### تصویر ماهواره‌ای

در طی فصل رشد ذرت علوفه‌ای در منطقه مورد مطالعه در سال ۱۳۹۷، از ۱۵ تصویر Sentinel-2 A / B (S2) بدون ابر (دانلود تصاویر ماهواره‌ای: <https://scihub.copernicus.eu/dhus/#/home>) متعلق به ۲۱ تیر

- 1- directional gap fraction
- 2- Fraction of Absorbed Photo-synthetically Active Radiation
- 3- Average Leaf Inclination Angle

4- Atmospheric/Topographic Correction for Satellite Imagery

منظور بازبایی توزیع مکانی-زمانی پارامتر بیوفیزیکی LAI بصورت پیکسل مبنای در مقیاس منطقه‌ای، کالیبره و مورد بررسی و مقایسه قرار می‌گیرند.

جدول ۱- مشخصات باندهای تصویر ماهواره‌ای Sentinel-2 (Verrelst et al., 2012b)

باند	Coastal aerosol	Blue	Green	Red	Red-Edge	Red-Edge	Red-Edge	NIR	NIR - Narrow	Water vapor	SWIR-Cirrus	SWIR	SWIR
مرکز باند (nm)	۴۴۳	۴۹۰	۵۶۰	۶۶۵	۷۰۵	۷۴۰	۷۸۳	۸۴۲	۸۶۵	۹۴۵	۱۳۷۵	۱۶۱۰	۲۱۹۰
عرض باند (nm)	۲۰	۶۵	۳۵	۳۰	۱۵	۱۵	۲۰	۱۱۵	۲۰	۲۰	۳۰	۹۰	۱۸۰
وضوح مکانی (m)	۶۰	۱۰	۱۰	۱۰	۲۰	۲۰	۲۰	۱۰	۲۰	۶۰	۶۰	۲۰	۲۰

شدند. علاوه بر این، پس از یافتن الگوریتم کارا تر، نقشه پیکسل مبنای تخمین LAI و نیز نقشه پیکسل مبنای مقادیر عدم اطمینان مرتبط با آنها از طریق مقدار عدم اطمینان ( $SD^6$ ) و عدم اطمینان نسبی (با استفاده از ضریب تغییر  $CV^7$ ) ایجاد می‌شود. دقت مقادیر تخمین زده شده پیکسل مبنای LAI در دفعات نمونه برداری در مزرعه نیز از طریق RMSE و Bias محاسبه می‌شود. شکل ۲، فلوجارت نحوه اجرای تحقیق حاضر را ارائه می‌دهد.

#### الگوریتم‌های کرنل مبنای ANN و RF، MLA و SVR

روش SVR رابطه غیر خطی در فضای ورودی بازتاب‌ها را بر اساس بردارهای پشتیبان بصورت تابع زیر تعریف می‌کند:

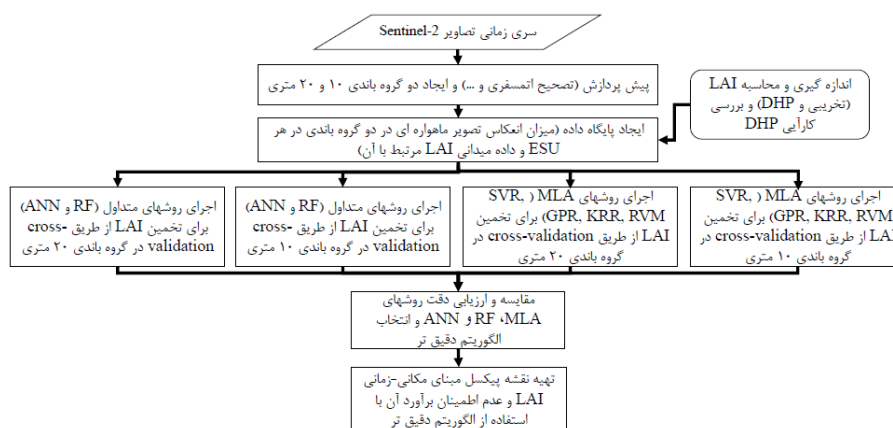
$$\hat{y}_i = \sum_{j=1}^n (\alpha_j - \alpha_j^*) K(x_i, x_j) + b \quad (1)$$

که در آن،  $K$  و  $\alpha_j$  به ترتیب تابع کرنل و ضریب لاگرانژ هستند. تابع کرنل در ایجاد رابطه غیرخطی نقش اساسی ایفا می‌کند که در این تحقیق، از تابع کرنل Gaussian (RBF<sup>5</sup>) استفاده شد  $K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$  برای اجرای SVR، سه پارامتر باید تنظیم شوند: پارامتر تنظیم  $C$ ، مقدار تلورانس  $\epsilon$  و پارامتر کرنل  $\sigma$  (Verrelst et al. 2012b). در این تحقیق، برای تنظیم پارامترهای الگوریتم SVR از دستور optimizparameters به صورت اتوماتیک، استفاده شده است. در روش KRR، پیش‌بینی برای یک مجموعه داده تست  $x^*$  به عنوان تابعی از وزن‌های دوگانه  $\alpha = [\alpha_1, \dots, \alpha_n]^T$  (هر یک برای یک نمونه) بدست می‌آید:

برای دستیابی به این تخمین و ایجاد ارتباط بین بازتاب طیفی S2 و مقادیر اندازه‌گیری شده میدانی LAI، داده‌ها (میزان انعکاس ثبت شده در تصویر ماهواره‌ای در هر ESU در زمان‌های نمونه‌برداری در دوره کامل رشد گیاه و LAI میدانی مرتبط با آن) به دو دسته داده آموزشی و اعتبارسنجی تقسیم می‌شوند. در این تحقیق، با در نظر گرفتن دو گروه باندی با قدرت تفکیک مکانی ۱۰ و ۲۰ متری سری زمانی تصاویر Sentinel-2، میزان LAI تخمین زده شده و در این دو گروه باندی مقایسه گردیدند. دو گروه باندی Sentinel-2 به طور مجزا به مجموعه داده‌های آموزشی و اعتبارسنجی تقسیم می‌شوند، دو گروه باندی یعنی S2-10m؛ قدرت تفکیک مکانی ۱۰ متر، ۴ باند و S2-20m؛ ۲۰ متر، ۱۰ باند (یعنی باندهایی با اندازه پیکسل ۲۰ متر و باندهایی با اندازه پیکسل ۱۰ متر که به ۲۰ متر تغییر یافته‌اند). اعتبار روش‌های MLA بر اساس روش اعتبارسنجی متقاطع<sup>۱</sup> k-fold (۱۰-fold) ارزیابی گردید. در این روش، مجموعه داده به طور تصادفی به زیر مجموعه‌های داده با اندازه برابر تقسیم می‌شود.  $K-1$  زیر مجموعه، به عنوان مجموعه داده آموزشی انتخاب می‌شوند و  $k$  امین زیر مجموعه به عنوان یک مجموعه داده اعتبارسنجی برای ارزیابی مدل استفاده می‌شود. فرآیند اعتبارسنجی متناوب برای استفاده از تمام زیر مجموعه‌های داده به عنوان یک مجموعه داده اعتبارسنجی، تکرار می‌شود و سپس نتایج  $k$  بار برای تولید یک مقدار تخمین واحد، میانگین گرفته می‌شود. عملکرد مدل یا قدرت پیش‌بینی مدل‌های توسعه یافته با جذر میانگین مربعات خطا<sup>۲</sup> (RMSE) برای بررسی دقت و ضریب تبیین<sup>۳</sup> ( $R^2$ ) برای محاسبه میزان انطباق مدل<sup>۴</sup> ارزیابی

- 1- cross-validation
- 2- Root Mean Square Error
- 3- Coefficient of determination
- 4- Goodness of fit

- 5- Standard Deviation
- 6- Coefficient of Variation
- 7- Radial Basis Function



شکل ۲- فلوجارت فرآیند اجرای تحقیق

پارامترهای بیشتر؛ نمایی مربعی جهتی<sup>۱</sup> (SE)، می تواند به طور موثر مورد استفاده باشد. پارامترهای این کرنل، یعنی  $\theta$  عامل مقیاس گذاری (مقیاس سیگنال)،  $\sigma_n$  انحراف معیار نویز و  $\sigma_b$  پارامتر مقیاس - طول<sup>۲</sup> برای هر باند (ویژگی) ورودی، با حداکثر کردن احتمال حاشیه‌ای<sup>۳</sup> در داده آموزشی، بهینه‌سازی می‌شوند (Rasmussen and Williams, 2006).

در این تحقیق، به منظور ارزیابی استواری الگوریتم GPR به صورت پیکسل مینا، علاوه بر ارزیابی مقدار عدم اطمینان (SD)، عدم اطمینان نسبی نیز از طریق ضریب تغییر (CV) محاسبه می‌شود. به طور مثال، مقدار عدم اطمینان ۵ برای مقدار میانگین تخمین زده شده  $5 \text{ m}^2/\text{m}^2$  نسبت به  $15 \text{ m}^2/\text{m}^2$  خطای بیشتری محسوب می‌شود، لذا CV ابزار تفسیر معنی‌داری را فراهم می‌کند (Verrelst et al., 2013):

$$CV = \frac{\sigma}{\mu} * 100 \quad (۶)$$

الگوریتم RF روش یادگیری گروهی است که ترکیبی از K درخت تصمیم در طبقه‌بندی باینری و رگرسیون<sup>۴</sup> (CART) را تشکیل می‌دهد، که در آن هر درخت با استفاده از یک الگوریتم یادگیری منحصر به فرد در زیر مجموعه‌های متغیرهای ورودی ایجاد می‌گردد که این زیر مجموعه‌ها با استفاده از شاخص جینی تفکیک می‌شوند (Breiman, 2001). با تغییر در تعداد درختان و محاسبه خطای پیش-بینی، مقداری به عنوان بهینه برای تعداد درختان انتخاب گردید که با افزایش تعداد درختان، تغییری در کاهش میزان خطا مشاهده نشود. پرسپترون چند لایه با استفاده از الگوریتم تعلیمی انتشار بازگشتی از رایج‌ترین شبکه‌های عصبی مصنوعی است. این الگوریتم از سه لایه

$$f(x^*) = K(x^*, x)(K(x, x) + \frac{1}{c} I)^{-1}y = K(x^*, x)\alpha \quad (۲)$$

که فقط برای ایجاد تشابه بین داده آموزشی و مقادیر خروجی، از تابع کرنل استفاده می‌شود (تابع RBF در این تحقیق). در KRR، پارامتر C و پارامترهای تابع کرنل باید تنظیم شوند (Shawe-Taylor and Cristianini, 2004). RVM and Cristianini روش یادگیری ماشین است که از استنباط بی‌زوی برای بدست آوردن راه حل‌های ممکن در رگرسیون استفاده می‌کند.

$$k'(x, x^*) = \sum_{j=1}^N \frac{1}{\alpha_j} K(x, x_j)K(x^*, x_j) \quad (۳)$$

که در آن K تابع کرنل (تابع RBF در این تحقیق)،  $\alpha_j$  واریانس مقدماتی بر روی بردار وزن  $w \sim N(0, \alpha^{-1} I)$  و  $x_1, \dots, x_N$  بردارهای ورودی مجموعه آموزشی هستند (Tipping, 2001). الگوریتم‌های KRR و RVM، مورد استفاده در این تحقیق، از cross-validation نیز در داخل خود الگوریتم برای ایجاد ساختار مدل استفاده می‌کنند، با این حال، برای تنظیم نمودن بهتر مدل و کم کردن وابستگی مدل به پارامترها، با چند بار اجرای این الگوریتم‌ها و محاسبه میانگین نتایج، نتایج نهایی بدست آمده است.

مدل رگرسیون فرآیند گوسی (GPR)، نیز همانند روش‌های دیگر یادگیری ماشین، ارتباطی بین ورودی (طیف‌های مختلف)  $x \in R_B$  و متغیر خروجی (به طور مثال پارامتر LAI)  $y \in R$  برقرار می‌کند. برای پیش‌بینی مقدار نامعلوم، GPR با محاسبه توزیع پسین گوسی بر روی خروجی نامعلوم  $y^*$ ؛  $p(y^* | x^*, D) = N(y^* | \mu_{GP^*}, \sigma_{GP^*}^2)$  که در آن  $D \equiv \{x_n, y_n | n=1, \dots, N\}$  داده‌های آموزشی است، بدست می‌آید. میانگین و واریانس (فاصله اطمینان یا سطح عدم اطمینان) مقادیر پیش‌بینی‌ها به ترتیب با توابع ۴ و ۵ قابل تخمین است:

$$\mu_{GP^*} = k_*^T (K + \sigma_n^2 I)^{-1} y \quad (۴)$$

$$\sigma_{GP^*}^2 = k_{**} - k_*^T (K + \sigma_n^2 I)^{-1} k_* \quad (۵)$$

که در آنها،  $k_*$  ترم کوواریانس نقطه آزمون  $k_*(x_*, x_1)$ ،  $k_{**} = (k(x_*, x_1), \dots, k(x_*, x_n))^T$  و  $k(x_*, x_n)$  کرنل با

- 1- anisotropic squared exponential
- 2- Length-scale
- 3- marginal likelihood
- 4- Classification And Regression Trees

الگوریتم‌های کرنل مینا، از دقت محاسباتی و پایداری بالاتری با داشتن  $R^2$  بالاتر و انحراف معیار کمتر و نیز RMSE پایین‌تر در دو گروه بانندی، برخوردار است. این الگوریتم، نشان می‌دهد که با ترکیب ۴ باند، امکان تخمین با دقت LAI را داراست، با این حال، اضافه نمودن باندها در محدوده red-edge و SWIR، میزان انطباق و دقت را بهبود می‌دهد. در بین تمام الگوریتم‌ها در دو گروه بانندی در نظر گرفته شده، GPR، در گروه بانندی بیست متری با  $R^2$  و RMSE به ترتیب  $0/913$  و  $0/641$  و انحراف معیار  $R^2$  به میزان  $0/031$ ، از دقت و پایداری بالاتری برخوردار است. SVR با دقت و استواری بالاتر و RMSE پایین‌تر در مرتبه دوم دقت برآورد LAI در هر دو گروه بانندی قرار دارد. تنها در گروه بانندی ده متری، دو الگوریتم RF و ANN نسبت به GPR، با در نظر گرفتن  $R^2$  مقادیر پیش‌بینی شده در K-fold مختلف، از تشابه بیشتری برخوردار بوده، اما دقت محاسباتی این الگوریتم‌ها نسبت به الگوریتم‌های کرنل مینا در دو گروه بانندی، کمتر بوده است. علاوه بر این، عملکرد الگوریتم‌ها در گروه بانندی بیست متری با دارا بودن باندهایی در محدوده red-edge و SWIR، نسبت به گروه بانندی ده متری، منجر به افزایش  $R^2$  کاهش RMSE و بهبود دقت تخمین LAI شده است.

نکته حائز اهمیت دیگر برای اینکه یک الگوریتم بتواند به صورت کاندید موفق در چرخه عملیاتی و کاربردی تخمین پارامترهای بیوفیزیکی در منطقه وسیع عمل کند، سرعت پردازش می‌باشد. محاسبات زمان پردازش ارائه شده در جدول ۲، از طریق سیستمی با مشخصات Windows 8.1 Intel® Core™i7-2640M CPU @ 2.80GHz, 4.00 GB RAM در محیط متلب است.

در مقایسه زمان پردازشی الگوریتم‌ها برای تخمین LAI، الگوریتم KRR، سریعترین الگوریتم و در مقابل، الگوریتم SVR، به زمان بیشتری برای توسعه مدل نیاز دارد. برای ایجاد ساختار مدل در الگوریتم KRR، تنها یک پارامتر تنظیم می‌شود و به این دلیل، نسبت به سایر الگوریتم‌ها ساده‌تر است. با وجودی که الگوریتم RVM نسبت به KRR، سرعت پردازشی پایین‌تری دارد، اما از نظر دقت تخمین LAI، تقریباً مشابه عمل نموده‌اند. الگوریتم GPR، در مرتبه دوم زمان پردازشی است و با وجود سرعت پردازش بالا و دقت بالاتر آن، کارایی محاسباتی بالاتری را در تخمین LAI داراست. نسبت به الگوریتم‌های RF و ANN، سرعت پردازش الگوریتم GPR و نیز دقت آن، بالاتر بوده، بنابراین، در تحقیقات کاربردی و در مناطق وسیع، کارتر عمل می‌کند. علت این برتری را می‌توان وجود تابع کرنل در الگوریتم‌های کرنل مینا و به ویژه GPR دانست، چرا که تابع کرنل، توانسته ارتباطات غیرخطی را با دقت بهتری تخمین زند. برتری GPR نسبت به سایر الگوریتم‌های کرنل مینا نیز مؤید دقت بالاتر روش بهینه‌سازی پارامترها در این الگوریتم نسبت به SVR نبود روش بهینه‌سازی در KRR و RVM است.

ورودی، پنهان و خروجی تشکیل شده (Kanellopoulos and Wilkinson, 1997)، و در این تحقیق، با توجه به کم بودن طبقات خروجی، تنها از یک لایه پنهان استفاده شد. علاوه بر این، از تابع Levenberg-Marquardt برای آموزش شبکه عصبی استفاده شده است.


## نتایج و بحث

### مقایسه و ارزیابی نتایج الگوریتم‌های کرنل مینا، RF و ANN در تخمین LAI


در این تحقیق، کارایی روش عکسبرداری نیم‌کره‌ای برای محاسبه و اندازه‌گیری LAI در مقایسه با روش تخریبی ارزیابی شد. شکل ۳، دو نمونه از عکس‌های DHP اخذ شده در دو تاریخ فنولوژی مهم گیاه ذرت علوفه‌ای را نشان می‌دهد. شکل ۴، نمودار ارتباط بین LAI اندازه‌گیری شده بصورت تخریبی و عکسبرداری DHP را ارائه می‌دهد. همانطور که در شکل نیز مشهود است، ارتباط معنی‌داری بین LAI اندازه‌گیری شده از طریق این دو روش با  $R^2 = 0.91$  و  $RMSE = 0.804$  بدست آمده که دلالت بر کارایی روش اندازه‌گیری LAI از طریق عکسبرداری DHP در مزارع ذرت علوفه‌ای در این منطقه دارد. در عکسبرداری DHP، امکان تمایز بین ساقه و برگ در پردازش وجود ندارد و در مرحله‌ای که میزان ساقه‌ها افزایش یافته، اختلاف بین LAI محاسبه شده از طریق روش‌های DHP و تخریبی، تا حدی افزایش یافته است.

بررسی رابطه بین مقادیر LAI اندازه‌گیری شده و انعکاس ثبت شده در باندهای دو گروه بانندی ده و بیست متری Sentinel-2، ارتباط غیر خطی را نشان می‌دهد، بنابراین در این تحقیق، از الگوریتم‌های ناپارامتریک غیرخطی برای تخمین LAI استفاده شد، همچنان که ورلست و همکاران، سائیسیدو و همکاران و ورلست و همکاران نیز اذغان نموده‌اند که الگوریتم‌های خطی مانند PLSR<sup>1</sup> و PCR<sup>2</sup> نمی‌توانند چنین ارتباط‌های غیرخطی را برآورد کنند (Verrelst et al., 2012b; Caicedo et al., 2014; Verrelst et al., 2015a, b). نتایج  $R^2$  و RMSE در تخمین LAI از طریق الگوریتم‌های مختلف کرنل مینای مورد بررسی در این تحقیق در مقایسه با RF و ANN، در جدول ۲ ارائه شده است. از آنجایی که از روش cross-validation برای اعتبارسنجی الگوریتم‌ها استفاده گردید، بنابراین این نتایج بصورت میانگین و انحراف معیار 10 fold ارائه شده است. مطابق با ورلست و همکاران، مقادیر انحراف معیار کمتر  $R^2$ ، دلالت بر پایداری بیشتر الگوریتم موردنظر دارد (Verrelst et al., 2015b). طبق جدول ۲، الگوریتم GPR در مقایسه با سایر

1- Partial Least Squares Regression  
2- Principle Component Regression



شکل ۳- عکس‌های DHP اخذ شده از مزارع ذرت علوفه‌ای برای محاسبات LAI در مرحله ۵-۴ برگ‌ی و دوازده برگ‌ی به ترتیب از راست به چپ



شکل ۴- ارتباط بین LAI اندازه‌گیری شده بصورت تخریبی و DHP

جدول ۲- ارزیابی الگوریتم‌های کرنل مینا در مقایسه با RF و ANN در تخمین LAI (دو گروه بانندی ده و بیست متری)

الگوریتم	گروه بانندی 10-m				گروه بانندی 20-m			
	RMSE <sub>cv</sub>		R <sup>2</sup> <sub>cv</sub>		RMSE <sub>cv</sub>		R <sup>2</sup> <sub>cv</sub>	
	σ	μ	σ	μ	σ	μ	σ	μ
GPR	۰/۰۴۸	۰/۶۹۴	۰/۱۵۳	۰/۸۹۷	۰/۰۳۱	۰/۶۴۱	۰/۱۱۹	۰/۹۱۳
SVR	۰/۰۵۲	۰/۷۳۱	۰/۱۵۳	۰/۸۸۶	۰/۰۶۲	۰/۷۰۸	۰/۱۷۲	۰/۸۹۱
RVM	۰/۰۵۹	۰/۷۵۶	۰/۱۹۸	۰/۸۷۸	۰/۰۶۹	۰/۷۱۷	۰/۱۹۰	۰/۸۸۶
KRR	۰/۰۵۷	۰/۷۶۱	۰/۲۰۱	۰/۸۷۶	۰/۰۶۸	۰/۷۱۶	۰/۲۰۱	۰/۸۸۷
RF	۰/۰۳۸	۰/۷۸۱	۰/۱۲۴	۰/۸۷۳	۰/۰۴۹	۰/۷۴۳	۰/۱۴۷	۰/۸۸۳
ANN	۰/۰۳۳	۰/۸۶۷	۰/۰۸۸	۰/۸۴۵	۰/۰۵۷	۰/۷۸۶	۰/۱۸۲	۰/۸۶۸

CV (cross-validation)

### برآورد توزیع مکانی-زمانی LAI و نقشه پیکسل مبنای عدم

#### اطمینان آن با استفاده از روش GPR

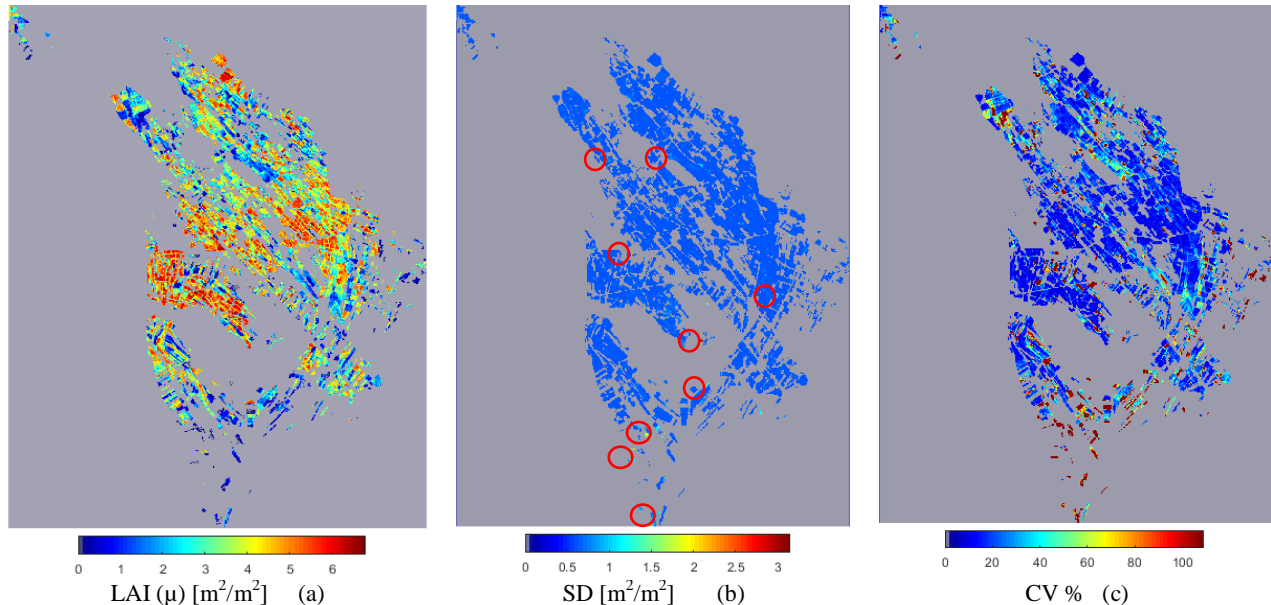
علاوه بر دقت و پایداری بالاتر الگوریتم GPR، توانایی آن در فراهم نمودن اطلاعات در مورد عدم قطعیت یا عدم اطمینان برآورد پارامترهای بیوفیزیکی به صورت پیکسل مبنای بسیار حائز اهمیت است. با توجه به برآورد دقت و پایداری بالاتر الگوریتم GPR در گروه بانندی بیست متری Sentinel-2، از این الگوریتم برای تخمین پیکسل مبنای LAI (میانگین) در مزارع ذرت علوفه‌ای، عدم اطمینان پیرامون آن (انحراف معیار SD) و عدم اطمینان نسبی (CV) در سطح منطقه‌ای استفاده شده است (شکل ۵). در این شکل، به علت رعایت حجم مقاله، تنها پردازش مربوط به تصویر Sentinel-2 تاریخ ۴ شهریور ۱۳۹۷ در زمان شروع گلدهی برخی از مزارع ذرت علوفه‌ای

نتایج تحقیق حاضر با در نظر گرفتن کل دوره رشد گیاه ذرت علوفه‌ای و داده واقعی Sentinel-2، در تحقیقات وولست و همکاران با استفاده از داده شبیه‌سازی شده Sentinel-2 در منطقه باراکس اسپانیا در گیاهان مختلف با نمونه‌برداری از یک مرحله از رشد آنها، نیز تایید شده و الگوریتم‌های کرنل مینا و به ویژه GPR را به عنوان جایگزینی برای ANN در بسیاری از برنامه‌های عملیاتی و کاربردی معرفی نموده‌اند (Verrelst et al., 2012b; 2015b). علاوه بر این، تحقیقات انجام شده در برآورد میزان LAI با استفاده از شاخص‌های پوشش گیاهی، نظیر فرید حسینی و همکاران (۱۳۹۱)، بادیه‌نشین و همکاران (۱۳۹۳)، آبکار و همکاران (۱۳۹۴)، مختاری و همکاران (۱۳۹۶)، با میزان دقت در حدود ۱/۵۷ در RMSE و ۰/۵۳ الی ۰/۷۸ در R<sup>2</sup>، نسبت به تحقیق حاضر از دقت کمتری برخوردار بوده است.



زراعی مدنظر، آیش شده‌اند. در شکل b ۵، تغییر پذیری مکانی عدم اطمینان (انحراف معیار یا SD) تخمین LAI به صورت پیکسل مینا، ارائه شده است. میزان انحراف معیار یا عدم اطمینان اکثریت اراضی (مساحت ۹۶٪) کمتر از ۰/۷ و ۵۴٪ از این مساحت، به میزان ۰/۶۵ بدست آمده و تنها در نواحی که با دایره در شکل b ۵ نشان داده شده، به میزان ۴ درصد از مزارع، مقادیر SD بالاتر از ۰/۷ بدست آمده است.

ارائه شده که در انتهای خرداد یا اوایل تیر کشت کرده‌اند. البته به علت عدم همزمانی در زمان کشت، برخی مزارع دیرتر به زیر کشت رفته و هنوز به مرحله گلدهی نرسیده‌اند. تغییرپذیری مکانی مقادیر LAI، در شکل کاملاً مشخص است، بطوری که مزارع دارای LAI بالاتر با مقدار ۳ >، به مساحت ۵۹/۵٪، بیشتر در نواحی مرکزی منطقه به چشم می‌خورند (شکل a ۵). مزارع با LAI کم، عمدتاً یا دیرتر به زیر کشت رفته‌اند یا مزارع با مقادیر نزدیک به صفر، در سال



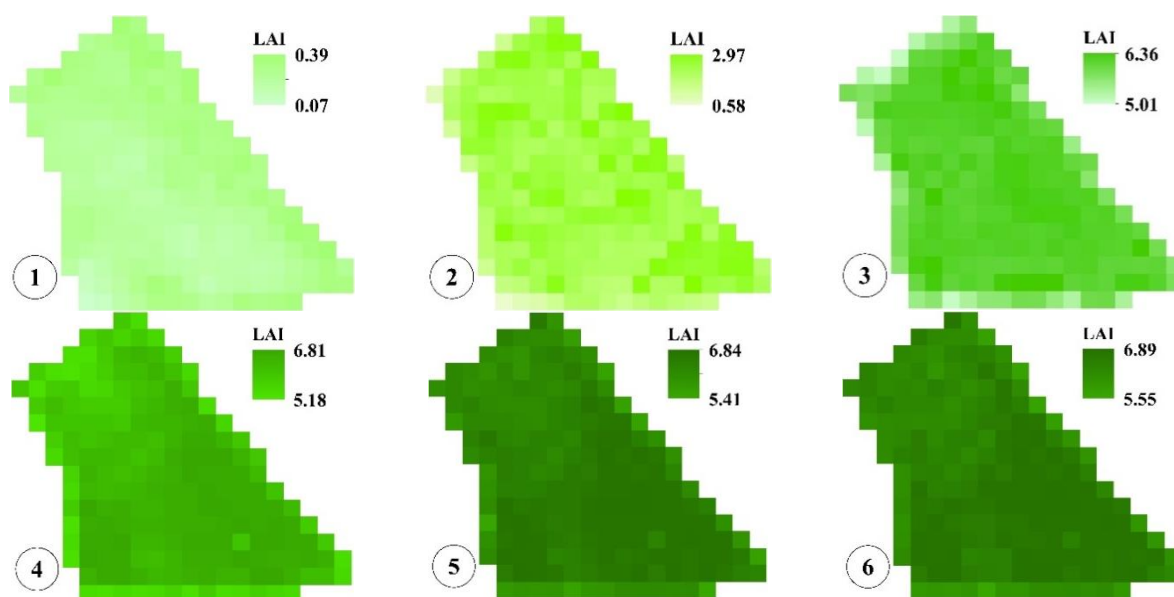
شکل ۵- نقشه پیکسل مینای LAI (میانگین) (a)، عدم اطمینان پیرامون آن (انحراف معیار SD) (b) (دوایر قرمز مشخص کننده موقعیت نواحی دارای مقادیر SD بالاتر از ۰/۷ می‌باشند) و عدم اطمینان نسبی (CV) (c) از طریق الگوریتم GPR در گروه باندی بیست متری Sentinel-2 (۴ شهریور ۱۳۹۷)

همکاران و متئو-سانچز و همکاران، برای تخمین پارامترهای بیوفیزیکی ارزیابی شده ( Verrelst et al., 2012b; 2013; Caicedo et al., 2014; Campos-Taberner et al., 2015; Verrelst et al., 2015b; 2016; Mateo-Sanchis et al., 2018) و نتایج تحقیق حاضر نیز مؤید تحقیقات پیشین است و کارایی آن را اذعان می‌کند.

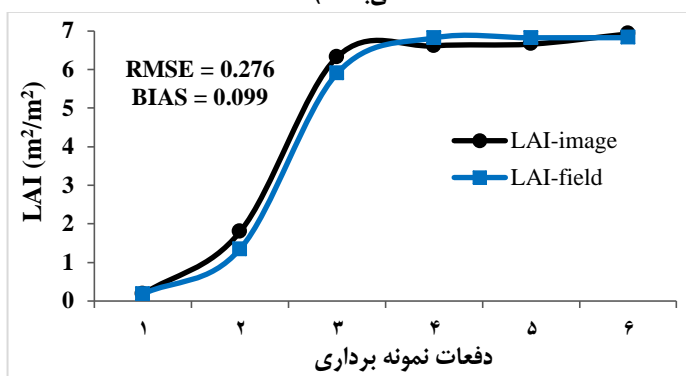
شکل ۶ و ۷، تغییرات مکانی-زمانی پیکسل مینای LAI محاسبه شده از طریق الگوریتم GPR در سری زمانی تصاویر ماهواره‌ای در یکی از اراضی تحت بررسی و نمودار مقایسه آن با مقادیر LAI میدانی در ESU در نظر گرفته شده را نشان می‌دهد. به دلیل رعایت حجم مقاله، تنها در یکی از اراضی، نتایج تغییرات LAI در سری زمانی نمونه‌برداری ارائه شده است. مطابق نمودار، میزان اختلاف مقادیر LAI محاسبه شده و میدانی برابر با  $RMSE = 0.276$  و  $Bias = 0.099$  بدست آمده که بر اختلاف اندک آنها دلالت دارد.

به منظور تفسیر معنی‌دارتر عدم اطمینان برآورد LAI و بررسی استواری الگوریتم GPR به صورت پیکسل مینا، تغییرپذیری مکانی عدم اطمینان نسبی (CV) در شکل c ۵ ارائه شده است. حد آستانه عدم قطعیت پیشنهاد شده توسط GCOS<sup>1</sup> به میزان کمتر از ۲۰٪ می‌باشد (GCOS, 2011). در این منطقه و با استفاده از این روش، عدم قطعیت برآورد شده در ۵۷٪ اراضی کمتر از ۲۰٪ و در ۷۴٪ کمتر از ۳۰٪، بدست آمده که بر استواری بالای این الگوریتم دلالت دارد. تنها ۷ درصد از اراضی، میزان CV بالاتر از ۱۰۰٪ را به خود اختصاص داده‌اند که دلالت بر آیش بودن آنهاست. در سایر مزارع نیز که دیرتر به زیر کشت رفته‌اند و علاوه بر گیاه، خاک در پس زمینه مشهود است، افزایش میزان عدم اطمینان نسبی به چشم می‌خورد. این قابلیت الگوریتم GPR در تحقیقات اندکی نظیر ورسلت و همکاران، سائیدو و همکاران، کامپوز-تینر و همکاران، ورسلت و

1- Global Climate Observing System



شکل ۶- تغییرات مکانی-زمانی پیکسل مبنای LAI ( $m^2/m^2$ ) محاسبه شده در سری زمانی تصاویر ماهواره‌ای در یکی از اراضی تحت بررسی (اعداد ۱ الی ۶، به ترتیب ۲۱ تیر، ۵ و ۲۰ مرداد، ۴، ۱۴ و ۱۹ شهریور است که تاریخ‌های نمونه برداری در زمین ارائه شده می‌باشد).



شکل ۷- نمودار مقایسه تغییرات LAI محاسبه شده با مقادیر میدانی آن در ESU در نظر گرفته شده در یکی از اراضی تحت بررسی

## نتیجه گیری

الگوریتم‌ها بدست آورد، بلکه نتایج نشان می‌دهد که این الگوریتم با داشتن انحراف معیار کم و سرعت محاسباتی بالا، روشی سریع و پایدار در برآورد این پارامتر بیوفیزیکی است. علاوه بر این، اضافه نمودن باندهای red-edge و SWIR، مزیت افزایش دقت برآورد LAI، را به همراه داشته است، به نحوی که موجب افزایش دقت در GPR بیست متری نسبت به ده متری به میزان  $R^2=1/78\%$  و  $RMSE=7/64\%$  شده و دقت الگوریتم GPR در گروه باندی بیست متری،  $R^2=0/913$  و  $RMSE=0/641$  می‌باشد. الگوریتم SVR در مرتبه دوم دقت برآورد LAI و دو الگوریتم KRR و RVM با عملکرد تقریباً مشابه از نظر دقت محاسباتی، در مرتبه اولویت بعد از آن قرار دارند. الگوریتم‌های RF و ANN، نسبت به الگوریتم‌های کرنل مینا از سرعت و دقت محاسباتی کمتری برخوردار بودند. علاوه بر دقت بالای الگوریتم GPR، این الگوریتم امکان برآورد مقادیر عدم

در این تحقیق، به دلیل وجود ارتباط غیرخطی بین LAI و انعکاس ثبت شده در تصویر ماهواره‌ای، الگوریتم‌های کرنل مبنای GPR، KRR، RVM و SVR در تخمین LAI با دو گروه باندی ۱۰ و بیست متری Sentinel-2 ارزیابی و مقایسه شده‌اند. برای دستیابی به مقایسه با تحقیقات متداول در این حوزه، کارایی الگوریتم‌های RF و ANN از نظر دقت و سرعت محاسباتی نیز بررسی گردید. داده میدانی به دو روش تخریبی و DHP در مزارع ذرت علوفه‌ای شهرستان قلعه‌نو در استان تهران، در کل دوره رشد گیاه سال ۱۳۹۷، اندازه‌گیری و کارایی روش DHP برای اندازه‌گیری LAI در مزارع کشاورزی نیز بررسی شد. GPR نه تنها دقت بهتری را برای تخمین LAI نسبت به سایر

مختاری، ع.، نوری، ح.، وظیفه دوست، م. و نازی قمشلو، آ. ۱۳۹۶. برآورد شاخص سطح برگ محصولات گندم و جو با استفاده از شاخص‌های گیاهی مستخرج از تصاویر ماهواره‌ای. نشریه آبیاری و زهکشی ایران. ۱۱. ۲: ۲۰۹-۲۱۸.

Azadbakht, M., Ashourloo, D., Aghighi, H., Radiom, S., and Alimohammadi, A. 2019. Wheat leaf rust detection at canopy scale under different LAI levels using machine learning techniques. *Computers and Electronics in Agriculture*. 156: 119-128.

Baret, F., Weiss, M., Allard, D., Garrigues, S., Leroy, M., Jeanjean, H., Fernandes, R., Myneni, R., Privette, J., Morisette, J. and Bohbot, H., 2005. VALERI: a network of sites and a methodology for the validation of medium spatial resolution land satellite products. *Remote Sensing of Environment*. 76. 3: 36-39.

Battude, M., Al Bitar, A., Morin, D., Cros, J., Huc, M., Sicre, C.M., Le Dantec, V. and Demarez, V. 2016. Estimating maize biomass and yield over large areas using high spatial and temporal resolution Sentinel-2 like remote sensing data. *Remote Sensing of Environment*. 184. 668-681.

Breiman, L.E.O., 2001. Random Forests. *Mach. Learn.* 45: 5-32.

Caicedo, J.P.R., Verrelst, J., Muñoz-Marí, J., Moreno, J., and Camps-Valls, G. 2014. Toward a semiautomatic machine learning retrieval of biophysical parameters. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 7. 4: 1249-1259.

Campos-Taberner, M., García-Haro, F.J., Moreno, A., Gilabert, M.A., Sanchez-Ruiz, S., Martinez, B., and Camps-Valls, G. 2015. Mapping leaf area index with a smartphone and Gaussian processes. *IEEE Geoscience and Remote Sensing Letters*. 12. 12: 2501-2505.

Cavero, J., Farre, I., Debaeke, P., and Faci, J.M. 2000. Simulation of maize yield under water stress with the EPIC phase and CROPWAT models. *Agronomy Journal*. 679-690. doi:10.2134/agronj2000.924679x.

Claverie, M., Demarez, V., Duchemin, B., Hagolle, O., Ducrot, D., Marais-Sicre, C., Dejoux, J.F., Huc, M., Keravec, P., Béziat, P. and Fieuzal, R. 2012. Maize and sunflower biomass estimation in southwest France using high spatial and temporal resolution remote sensing data. *Remote Sensing of Environment*. 124: 844-857.

ESA, 2005. SPARC 2004, Contract No. 18307/04/NL/FF, SPARC Data Acquisition Report.

Gao, Y., Duan, A., Qiu, X., Sun, J., Zhang, J., Liu, H., and Wang, H. 2010. Distribution and use efficiency of photosynthetically active radiation in strip intercropping of maize and soybean. *Agronomy*

اطمینان در کنار میانگین مقادیر پیش‌بینی شده یک پارامتر بیوفیزیکی را به صورت پیکسل مینا فراهم می‌کند. در این تحقیق، میزان عدم اطمینان و عدم اطمینان نسبی (CV)، به ترتیب، به مساحت ۹۶٪ و ۷۴٪ از کل منطقه کمتر از ۰/۷ و ۳۰٪، برآورد شده که بر استواری الگوریتم GPR در برآورد LAI دلالت دارد. میزان LAI تخمین زده شده و میدانی در دفعات نمونه‌برداری در ESU در نظر گرفته شده در یکی از اراضی، مقایسه شده و برآورد  $RMSE = 0.276$  و  $RMSE = 0.099$  = Bias، بر اختلاف اندک آنها دلالت دارد.

این مزایا منجر به انتخاب الگوریتم GPR نسبت به RF و ANN، به عنوان کاندیدی برای تخمین پارامتر بیوفیزیکی LAI در چرخه پردازش عملیاتی و منطقه‌ای از طریق Sentinel-2 می‌شود. با استفاده از الگوریتم GPR و سنسجش از دور، می‌توان به ارزیابی تغییرپذیری مکانی-زمانی LAI در اراضی کشاورزی و بررسی پیکسل مبنای عدم اطمینان مرتبط با آن (تنها الگوریتم موجود که تاکنون این قابلیت را دارد)، با صرف هزینه و زمان کمتر و نیز دقت قابل قبول دست یافت. با بهبود نحوه بهینه‌سازی پارامترهای الگوریتم GPR از طریق الگوریتم‌های بهینه‌سازی فراابتکاری نظیر الگوریتم بهینه‌سازی ازدحام ذرات (PSO)، می‌توان میزان دقت برآورد LAI را افزایش داد تا در پروژه‌های عملیاتی در مناطق وسیع‌تر، بتوان با اطمینان بیشتری از آن برای تخمین پارامترهای بیوفیزیکی بهره جست.

## منابع

آبکار، ع. ا.، صفدری‌نژاد، ع. ر.، زمانی، م.، صوف باف، س.ر.، غلامی بیدخانی، ن. و غفاری، ا. ۱۳۹۴. تحلیل و مدل‌سازی همبستگی بین LAI و شاخص‌های گیاهی از مشاهدات طیف‌سنجی. سنسجش از دور و GIS ایران. ۲۰۷: ۶۹-۸۸.

بادیه نشین، ع.ر.، نوری، ح. و وظیفه دوست، م. ۱۳۹۳. واسنجی معادلات برآورد شاخص سطح برگ محصولات ذرت و چغندرقد با استفاده از داده‌های ماهواره‌ای سنجنده مودیس (شبکه آبیاری قزوین). تحقیقات آب و خاک ایران. ۲۰۴۵: ۱۵۵-۱۶۵.

فرید حسینی، ع. ر.، آستارایی، ع. ر.، ثنایی نژاد، س. ح.، و میرحسینی موسوی، پ. ۱۳۹۱. تخمین شاخص سطح برگ با استفاده از داده‌های ماهواره‌ای IRS در منطقه نیشابور. نشریه پژوهش‌های زراعی ایران. ۱۰. ۳: ۵۸۲-۵۷۷.

گوینده نجف‌آبادی، م.، میرلطیفی، س. م. و اکبری، م. ۱۳۹۷. برآورد شاخص سطح برگ ذرت با استفاده از دوربین دیجیتال اصلاح شده. نشریه آبیاری و زهکشی ایران، ۱۲. ۶: ۱۴۰۶-۱۳۹۶.

- interactions between cropping pattern, maize cultivar and the local environment in strip-intercropping systems. *Agricultural and Forest Meteorology*. 195: 152-164.
- Rasmussen, C.E., and Williams, C.K.I. 2006. *Gaussian Processes for Machine Learning*. The MIT Press, New York.
- Shawe-Taylor, J., and Cristianini, N. 2004. *Kernel Methods for Pattern Analysis*: Cambridge University Press.
- Tipping, Michael E. 2001. Sparse Bayesian learning and Relevance Vector Machine. *Journal of Machine Learning Research*. 1: 211-244.
- Verrelst, J., Schaepman, M.E., Malenovsky, Z., and Clevers, J.G.P.W. 2010. Effects of woody elements on simulated canopy reflectance: Implications for forest chlorophyll content retrieval. *Remote Sensing of Environment*. 114. 3: 647-656.
- Verrelst, J., Alonso, L., Camps-Valls, G., Delegido, J., and Moreno, J. 2012a. Retrieval of vegetation biophysical parameters using Gaussian process techniques. *IEEE Transactions on Geoscience and Remote Sensing*. 50. 5: 1832-1843.
- Verrelst, J., Muñoz, J., Alonso, L., Delegido, J., Rivera, J.P., Camps-Valls, G., and Moreno, J. 2012b. Machine learning regression algorithms for biophysical parameter retrieval: Opportunities for Sentinel-2 and-3. *Remote Sensing of Environment*. 118: 127-139.
- Verrelst, J., Rivera, J., Moreno, J., Camps-Valls, G. 2013. Gaussian processes uncertainty estimates in experimental Sentinel-2 LAI and leaf chlorophyll content retrieval. *ISPRS J. Photogramm. Remote Sens.* 86: 157-167.
- Verrelst, J., Camps-Valls, G., Muñoz-Marí, J., Rivera, J. P., Veroustraete, F., Clevers, J.G., and Moreno, J. 2015a. Optical remote sensing and the retrieval of terrestrial vegetation bio-geophysical properties—A review. *ISPRS Journal of Photogrammetry and Remote Sensing*. 108: 273-290.
- Verrelst, J., Rivera, J.P., Veroustraete, F., Muñoz-Marí, J., Clevers, J.G., Camps-Valls, G., and Moreno, J. 2015b. Experimental Sentinel-2 LAI estimation using parametric, non-parametric and physical retrieval methods—A comparison. *ISPRS Journal of Photogrammetry and Remote Sensing*. 108: 260-272.
- Verrelst, J., Rivera, J. P., Gitelson, A., Delegido, J., Moreno, J., and Camps-Valls, G. 2016. Spectral band selection for vegetation properties retrieval using Gaussian processes regression. *International Journal of Applied Earth Observation and Geoinformation*. 52: 554-567.
- Watson D.J. 1947. Comparative physiological studies in *Journal*. 102. 4: 1149-1157.
- GCOS, 2011. Systematic Observation Requirements for Satellite-Based Products for Climate, 2011 Update, Supplemental Details to the Satellite-Based Component of the Implementation Plan for the Global Observing System for Climate in Support of the UNFCCC (2010 update, GCOS-154): 138. <<http://www.wmo.int/pages/prog/gcos/Publications/gcos-154.pdf>>.
- Gray, J., and Song, C. 2012. Mapping leaf area index using spatial, spectral, and temporal information from multiple sensors. *Remote Sensing of Environment*. 119: 173-183.
- Houborg, R., and Boegh, E. 2008. Mapping leaf chlorophyll and leaf area index using inverse and forward canopy reflectance modeling and SPOT reflectance data. *Remote Sensing of Environment*. 112. 1: 186-202.
- Houborg, R., and McCabe, M.F. 2018. A hybrid training approach for leaf area index estimation via Cubist and random forests machine-learning. *ISPRS Journal of Photogrammetry and Remote Sensing*. 135: 173-188.
- IRIMO [WWW Document], (2018). URL [www.irimo.ir](http://www.irimo.ir) (accessed 9.30.18).
- Jin, X., Yang, G., Xu, X., Yang, H., Feng, H., Li, Z., Shen, J., Zhao, C. and Lan Y. 2015. Combined multi-temporal optical and radar parameters for estimating LAI and biomass in winter wheat using HJ and RADARSAR-2 data. *Remote Sensing*. 7. 10: 13251-13272. doi:10.3390/rs71013251.
- Kanellopoulos, I., and Wilkinson, G. 1997. Strategies and best practice for neural network image classification. *International Journal of Remote Sensing*. 18. 4: 711-725.
- Kross, A., McNairn, H., Lapen, D., Sunohara, M., and Champagne, C. 2015. Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops. *International Journal of Applied Earth Observation and Geoinformation*. 34: 235-248.
- Mateo-Sanchis, A., Muñoz-Marí, J., Pérez-Suay, A., and Camps-Valls, G. 2018. Warped Gaussian Processes in remote sensing parameter estimation and causal inference. *IEEE Geoscience and Remote Sensing Letters*. 99: 1-5.
- Mousivand, A., Menenti, M., Gorte, B., and Verhoef, W. 2015. Multi-temporal, multi-sensor retrieval of terrestrial vegetation properties from spectral-directional radiometric data. *Remote Sensing of Environment*. 158: 311-330
- Munz, S., Feike, T., Chen, Q., Claupein, W., and Graeff-Hönninger, S. 2014. Understanding

- and temporal data fusion model. *Computers and Electronics in Agriculture*. 115: 1-11.
- Xia, T., Miao, Y., Wu, D., Shao, H., Khosla, R., and Mi, G. 2016. Active optical sensing of spring maize for in-season diagnosis of nitrogen status based on nitrogen nutrition index. *Remote Sensing*. 8. 7: 605.
- the growth of field crops. I. Variation in net assimilation rate and leaf area between species and varieties, and within and between years. *Annals of Botany* 11: 41-76.
- Wu, M., Wu, C., Huang, W., Niu, Z., and Wang, C. 2015. High-resolution Leaf Area Index estimation from synthetic Landsat data generated by a spatial

## Estimating the Spatial-Temporal Distribution of Leaf Area Index Using Sentinel-2 Satellite Images (Case Study: Silage Maize Farms of South of Tehran)

E. Akbari<sup>1</sup>, A. Darvishi Bolorani<sup>2\*</sup>, N. Neysani Samany<sup>3</sup>, S. Hamzeh<sup>4</sup>, S. Soufizadeh<sup>5</sup>, S. Pignatti<sup>6</sup>

Received: Jan.10, 2020

Accepted: Feb.21, 2020

### Abstract

Leaf area index (LAI) plays an important role in hydrological, agricultural, and land irrigation management studies. In order to adopt an appropriate, accurate, and robust algorithm to estimate the spatial-temporal distribution of LAI using Sentinel-2 images, the Support Vector Regression (SVR), Kernel Ridge Regression (KRR), Relevance Vector Machines (RVM), and Gaussian Process Regression (GPR) were calibrated and investigated. The research data were collected from silage maize farms in Ghaleh-Now country in Tehran province during the whole growing season in summer 2018 through destructive measurement and hemispherical photography. Our results were compared with the conventional algorithms in this field, i.e. random forest (RF) and artificial neural network (ANN). The results revealed that the GPR algorithm not only has higher accuracy (in 20-m band group,  $R^2=0.913$  and  $RMSE=0.641$ ), speed, and robustness to estimate the LAI, but also it has the unique ability to generate uncertainty pixel-based map (uncertainty and relative uncertainty were less than 0.7 and 30% by 96% and 74% of the total area, respectively). Based on  $R^2$  and RMSE, SVR is the second accurate technique for LAI estimation followed by RVM, KRR, RF and ANN, respectively. Comparison of the estimated and field LAI at sampling times with  $RMSE=0.276$  and  $bias=0.099$  and other superiorities indicated the efficiency of GPR algorithm to estimate the spatial-temporal distribution of LAI.

**Keywords:** Kernel-based algorithm, Leaf Area Index, Hemispherical photography, Regional study, Pixel-based map

1- Ph.D. Student of Remote Sensing, Department of Remote Sensing and GIS, Faculty of Geography, University of Tehran

2- Associate Professor in Remote Sensing, Department of Remote Sensing and GIS, Faculty of Geography, University of Tehran

3- Associate Professor, Department of Remote Sensing and GIS, Faculty of Geography, University of Tehran

4- Associate Professor, Department of Remote Sensing and GIS, Faculty of Geography, University of Tehran

5- Assistant Professor, Department of Agro-ecology, Environmental Sciences Research Institute, Shahid Beheshti University, G.C.

6- Institute of Methodologies for Environmental Analysis (CNR IMAA), C.da S.Loja snc, 85050 Tito (Potenza), Italy

(\*- Corresponding Author Email: ali.darvishi@ut.ac.ir)