



شماره ۲

سنجش از دور و GIS ایران

سنجش از دور و GIS ایران سال چهاردهم، شماره دوم، تابستان ۱۴۰۱
Vol.14, No. 2, Summer 2022 Iranian Remote Sensing & GIS

۶۱-۷۴

مقاله پژوهشی



بهبود تخمین پارامتر LAI با استفاده از توابع هزینه جایگزین و راهکارهای چندجوابه

علی جعفر موسیوند^{۱*}، میثم شیرمحمدپور^۲، علی شمس‌الدینی^۳

۱. استادیار دانشکده علوم انسانی، دانشگاه تربیت مدرس
۲. کارشناس ارشد سنجش از دور و GIS، دانشگاه تربیت مدرس
۳. دانشیار دانشکده علوم انسانی، دانشگاه تربیت مدرس

تاریخ پذیرش مقاله: ۱۴۰۰/۱۱/۱۹

تاریخ دریافت مقاله: ۱۳۹۹/۱۰/۳۰

چکیده

پوشش گیاهی موتور محرک کره زمین است؛ تبادلات انرژی و آب بین اتمسفر و زمین را کنترل می‌کند و در چرخه‌های جهانی انرژی، اکسیژن، دی‌اکسید کربن و آب نقش مهمی دارد. پایش و مدیریت پوشش‌های گیاهی با استفاده از پارامترهای بیوفیزیکی و بیوشیمیایی آن، مانند LAI، انجام می‌پذیرد. شاخص سطح برگ (LAI) از مهم‌ترین پارامترهای پوشش گیاهی است که در اغلب مدل‌سازی‌ها مانند مدل‌سازی چرخه‌های آب، انرژی و کربن استفاده می‌شود. رویکردهای بازیابی متفاوتی، به منظور استخراج اطلاعات پارامترهای بیوفیزیکی از داده‌های سنجش از دوری، توسعه یافته است. در تحقیق حاضر، از روش فیزیکی معکوس مدل انتقال تابش PROSAIL، مبتنی بر جدول LUT، با هدف بازیابی متغیر LAI استفاده شده است. همچنین داده‌های زمینی برداشت‌شده طی کمپین SPARC ۲۰۰۳ برای ارزیابی صحت متغیر بازیابی‌شده به کار رفت. برای رفع مشکل ill-posed، چهار دسته از معیارهای هزینه با عنوان اندازه‌گیر اطلاعات (IM)، حداقل اختلاف (MC)، اندازه‌گیر زاویه (SAM) و خطای حداقل مربعات (LSE) به همراه نرمال‌سازی و میانگین بهترین جواب‌ها استفاده شد. نتایج بهبود تخمین متغیر LAI را با استفاده از معیار اندازه‌گیر اطلاعات (Kulbak-liebler)، به میزان ۱۲٪ و با استفاده از ۱۱٪ میانگین بهترین جواب‌ها نشان دادند. تابع هزینه LSE نیز در قیاس با حالت نرمال‌نشده، ۷٪ بهبود یافت.

کلیدواژه‌ها: شاخص سطح برگ (LAI)، مدل انتقال تابش، معیار هزینه، جدول LUT.

* نویسنده مکاتبه‌کننده: تهران، بزرگراه چمران، جلال آل‌احمد، دانشگاه تربیت مدرس، دانشکده علوم انسانی. تلفن: ۸۲۸۸۵۰۲۸-۰۲۱

۱- مقدمه

پوشش گیاهی موتور محرک کره زمین محسوب می‌شود و تمامی موجودات زنده به گونه‌ای به آن وابسته‌اند. پوشش گیاهی، ضمن دریافت آب و دی‌اکسید کربن و انرژی خورشید، اکسیژن و مواد مغذی را به محیط خود بازمی‌گرداند؛ بنابراین در بسیاری از فرایندهای تبادل ماده و انرژی بین اتمسفر و سطح زمین و لایه‌های زیر زمین نقش مهمی ایفا می‌کند (Mousivand, 2015) و از این رو شناخت وضعیت تکامل، کمیت و کیفیت پوشش گیاهی در طول زمان دارای اهمیت بسیاری است (Bacour et al., 2002). کسب اطلاعات دقیق از پوشش گیاهی از طریق اندازه‌گیری پارامترهای بیوفیزیکی و بیوشیمیایی آن مانند شاخص سطح برگ (LAI)، میزان محتوای رنگدانه‌های کلروفیل، محتوای آب برگ، شاخص FAPAR^۱، شاخص FVC که توصیفگر وضعیت سلامت و فراوانی پوشش‌های گیاهی‌اند، امکان‌پذیر است (Combal et al., 2003).

LAI از پارامترهای ساختاری پوشش گیاهی است که می‌تواند، با استفاده از داده‌های سنجنش از دوری، بازیابی شود. این پارامتر نشان می‌دهد سطح زمین با چه تراکمی از گیاه پوشیده شده است. LAI عبارت است از نسبت مساحت کل یک سمت برگ بر واحد سطح (CHEN and BLACK n.d.). اطلاعات زمانی- مکانی متغیر LAI برای بسیاری از مدل‌سازی‌ها همچون مدل‌های هیدرولوژی، آب‌وهواشناسی، تخمین زیست‌توده پوشش‌های گیاهی و کشاورزی دقیق ضروری است و کارایی چنین مدل‌هایی به دقت تخمین متغیرهای پوشش گیاهی بازمی‌گردد (Baret & Buis, 2008).

سنجنش از دور دانشی است که اطلاعات را با پوشش مستمر و وسیع، از سطح زمین کسب می‌کند و منحصربه‌فردترین ابزار بازیابی متغیرهای پوشش گیاهی است (Meroni et al., 2004). سنجنده‌های سنجنش از دوری اغلب از محدوده‌های اپتیک، یعنی مرئی و مادون قرمز انعکاسی (۴۰۰ تا ۲۵۰۰ نانومتر)، طیف

الکترومغناطیسی برای کسب اطلاعات از پوشش گیاهی استفاده می‌کنند. میزان بازتابندگی در این محدوده طیفی به ویژگی‌های شیمیایی و بیوفیزیکی پوشش گیاهی مرتبط است و می‌توان از این محدوده طیفی، برای بازیابی این ویژگی‌ها بهره برد. با توسعه نسل جدید سنجنده‌های ابرطیفی^۲ (مانند ماهواره کریس- پروبا^۳) که قادرند انرژی الکترومغناطیسی را با قدرت تفکیک طیفی بیشتر و پهنای باند باریک‌تر (۱ تا ۱۰ نانومتر) ثبت کنند، توانایی ویژه‌ای در بازیابی ویژگی‌های پوشش گیاهی ایجاد شده است (Gitelson et al., 2005).

روش‌های بازیابی پارامترهای پوشش گیاهی از داده‌های سنجنش از دوری در سه دسته کلی جای می‌گیرد. دسته نخست با عنوان روش‌های آماری/ تجربی شناخته می‌شود. در این روش‌ها، پارامترهای پوشش گیاهی از راه تعلیم مدلی پارامتریک یا ناپارامتریک براساس نمونه‌های جمع‌آوری شده زمینی و استفاده از مدل تعلیم‌یافته، به‌منظور تخمین پیکسل‌های مجهول تصویر، تخمین زده می‌شود. این دسته از روش‌ها با وجود سادگی و محاسبات بهینه، محدودیت‌هایی هم دارند؛ از جمله، اشباع‌شدن شاخص‌های پوشش گیاهی درمورد مقادیر بالای LAI، وابستگی به مکان سنجنده و محدودیت‌های برداشت داده زمینی.

در دسته دوم که با عنوان روش‌های فیزیکی شناخته می‌شوند، برای استخراج اطلاعات پارامترهای پوشش گیاهی با استفاده از مدل‌های معکوس، در حالت مستقیم^۴ بازتابندگی‌های بالای اتمسفر تاج پوشش با در نظر گرفتن پارامترهای ورودی از طریق مدل انتقال تابش^۵ شبیه‌سازی می‌شود و سپس در حالت معکوس^۶،

1. Fraction of Absorbed Photosynthetically Active Radiation
2. Hyperspectral
3. Chrisproba
4. Forward Problem
5. Radiative Transfer Model (RTM)
6. Inverse Problem

جدول‌های متفاوتی ذخیره می‌شود و پارامتر پوشش گیاهی، از طریق کمینه‌سازی اختلاف بین بازتابندگی اندازه‌گیری شده و بازتابندگی‌های ذخیره شده در LUT با استفاده از یک تابع هزینه تخمین زده می‌شود. این تابع هزینه ممکن است تابع فاصله^۳، ارزش^۴، معیار^۵ و یا تابع واگرایی^۶ باشد (Rivera et al., 2013). تکنیک‌های بهبودسازی متفاوتی به منظور تخمین متغیرها از جدول LUT روش توسعه یافته است که از آن جمله می‌توان به این موارد اشاره کرد: (۱) استفاده از دانش قبلی درباره پارامترهای مدل؛ (۲) استفاده از بهترین پاسخ‌های جدول LUT^۷؛ (۳) افزودن نویز به دلیل فقدان اطمینان در مدل و اندازه‌گیری‌ها برای شبیه‌سازی داده‌های واقعی؛ (۴) نرمال‌سازی داده‌ها (Rivera et al., 2013)؛ (۵) استفاده از توابع هزینه جایگزین.

موارد فقدان اطمینان در داده‌های سنجش از دوری سبب تبدیل فرایند بازیابی پارامترهای پوشش گیاهی به مسئله‌ای چالش‌برانگیز شده است. یکی از مهم‌ترین مشکلات این خطاها مشخص نبودن توزیع مقادیر آنهاست. در بیشتر مطالعاتی که تا کنون در زمینه بازیابی متغیرهای پوشش گیاهی انجام شده، از توابع LSE^۸، به‌منزله تابع هدف برای بهینه‌سازی استفاده شده است. این در حالی است که استفاده از چنین توابعی، زمانی که اختلاف بازتابندگی‌ها توزیع نرمال نداشته نباشد و نیز داده‌های پرت و غیرخطی وجود داشته باشد، احتمالاً باعث بروز نتایج اشتباه در بازیابی می‌شود. مطالعات اخیر نشان می‌دهد که اگر اختلاف بازتابندگی‌های شبیه‌سازی شده و اندازه‌گیری شده از توزیع نرمال تبعیت نکند، چه بسا استفاده از توابع هزینه متفاوت روشی مناسب برای بازیابی متغیرها و مقابله

پارامترهای پوشش گیاهی از کمینه‌سازی اختلاف بین بازتابندگی اندازه‌گیری شده و شبیه‌سازی شده استخراج می‌شود (Baret & Buis, 2008). این روش به‌طور کلی از چهار مؤلفه تشکیل شده است: (۱) داده‌های سنجش از دوری؛ (۲) مدل انتقال تابش؛ (۳) الگوریتم بهینه‌سازی؛ (۴) تابع هزینه (Mousivand et al., 2015). تابع هزینه در مقایسه بازتابندگی شبیه‌سازی شده و بازتابندگی اندازه‌گیری شده کاربرد دارد (Leonenko et al., 2012; Verrelst et al., 2013; Rivera et al., 2013a).

دسته سوم آمیزه‌های از روش‌های آماری/تجربی و روش‌های فیزیکی است. در این روش‌ها، خروجی مدل‌های فیزیکی به‌منزله ورودی روش‌های یادگیری ماشین استفاده می‌شود.

براساس نظریه‌های هادامارد^۱ مدل‌های ریاضی پدیده‌های فیزیکی را هنگامی می‌توان به‌صورت ریاضی معکوس‌سازی کرد که پاسخ‌های مسئله معکوس وجود داشته باشد، یگانه باشد و به‌صورت پیوسته به داده‌ها وابسته باشد. بازیابی پارامترهای پوشش گیاهی از داده‌های سنجش از دوری، با استفاده از معکوس‌سازی مدل‌های انتقال تابش، در ذات خود مسئله‌ای ill-posed شمرده می‌شود (Baret & Buis, 2008b). فقدان اطمینان‌های (نویز و خطا) داده‌های سنجش از دوری و ساده‌سازی موجود در مدل‌سازی باعث شده است ترکیبات گوناگون پارامترهای ورودی مدل RTM اثر جبرانی در هم داشته باشند؛ در نتیجه، بازتابندگی‌های شبیه‌سازی شده شبیه هم باشد و شروط هادامارد نقض شود.

روش‌های متفاوتی برای حل مشکل ill-posed توسعه یافته است که از میان این روش‌ها، جدول مرجع^۲، به‌علت بهینه‌سازی سریع و حجم محاسبات به‌صرفه‌اش، در مطالعات گوناگون کاربردی گسترده دارد (Darvishzadeh et al., 2008; Leonenko et al., 2013a; Leonenko et al., 2013b; Rivera et al., 2013; Verrelst et al., 2012). در این روش، بازتابندگی‌های شبیه‌سازی شده با مدل RTM در

1. Hadamard
2. Look-up Table (LUT)
3. Distance Function
4. Merit Function
5. Metric Function
6. Divergence Function
7. Multiple Best Solution (MBS)
8. Least Square Error

معرف بازتابندگی‌های جدول LUT است (همچنین λ بیانگر تعداد باند است).

دسته اول توابع به کاررفته در مطالعه حاضر مربوط به توابع اندازه‌گیر اطلاعات است که اولین بار از سوی کولبک^۵ و لیبلر^۶ مطرح شد. این دسته از توابع فاصله بین دو توزیع احتمالاتی را اندازه می‌گیرند و از آنها با عنوان اندازه‌گیر واگرایی نیز یاد می‌شود. این توابع در بسیاری از زمینه‌ها همچون طبقه‌بندی چندرسانه‌ای، دانش عصب‌شناسی، بهینه‌سازی عملکرد روش‌های تخمین چگالی و تحلیل خوشه‌ها کاربرد گسترده دارند (Leonenko et al., 2013a). برای استفاده از این توابع، بازتابندگی باید به صورت تابعی احتمالاتی (مجموع احتمالات برابر با ۱) در نظر گرفته شود. در این مطالعه، از تابع واگرایی کولبک-لیبلر استفاده شده است.

$$D[P, Q] = \sum_{\lambda_i=1}^{\lambda_n} p(\lambda_i) \ln \left(\frac{p(\lambda_i)}{q(\lambda_i)} \right) \quad (1)$$

دسته دوم توابع با عنوان تخمین‌گرهای M شناخته می‌شوند. این دسته از تخمین‌گرها مجموعه بزرگی از توابع را شامل می‌شوند. حرف M، در ابتدای این توابع، نشان‌دهنده تخمین‌گرهای بیشترین شباهت است. این توابع بازتابندگی را به صورت یک تابع رگرسیون غیرخطی در نظر می‌گیرد (Leonenko, et al., 2013b; Verrelst et al., 2012).

تابع LSE یکی از روش‌های رگرسیونی شناخته شده در این دسته است که در مطالعات گوناگون، استفاده بسیار دارد. این تابع توزیع خطای داده‌ها را به صورت گوسی در نظر می‌گیرد و بنابراین زمانی که توزیع خطاها به صورت نرمال باشد، عملکرد بسیار خوبی از خود نشان می‌دهد. در غیر این صورت، نتایج این تابع عدم اطمینان بسیاری خواهد داشت (Leonenko et al., 2013; Rivera et al., 2013).

$$D[P, Q] = \sum_{\lambda_i=1}^{\lambda_n} (p(\lambda_i) - q(\lambda_i))^2 \quad (2)$$

1. Information Measures (IM)
2. M-Estimates (ME)
3. Minimum Contrast (MC)
4. Spectral Angle Measures (SAM)
5. Kullback
6. Leibler

با مشکلات پارامتریک غیرخطی باشد. در تحقیق حاضر، چهار دسته از توابع که هر یک از زمینه‌های متفاوت آماری و ریاضی است، در بهینه‌سازی به کار رفته و از روش‌های بهبودسازی میانگین بهترین جواب‌های LUT و نرمال‌سازی داده‌ها، به منظور تخمین متغیر LAI از داده‌های ابرطیفی کریس-پروبا استفاده شده است.

۲- داده و روش

۲-۱- توابع هزینه

رویکرد حل عددی مسئله معکوس سبب تنظیم پارامترهای مدل به گونه‌ای می‌شود که مقادیر پیش‌بینی شده مدل با مقادیر اندازه‌گیری شده بیشترین مطابقت را داشته باشد. مطابقت بین خروجی مدل و داده‌ها معمولاً از طریق کمینه‌سازی حداقل مربعات انجام می‌پذیرد (مانند RMSE) ولی در مطالعات گوناگون، روش‌های دیگری با عنوان استفاده از توابع جایگزین، برای به دست آوردن برآوردهای بهتر، معرفی شده است (Leonenko et al., 2013a; Rivera et al., 2012; Verrelst et al., 2012).

از بین توابع پرکاربرد موجود، چهار تابع که نتایج مورد قبولی در مطالعات گوناگون به دست داده‌اند، به منظور بهینه‌سازی استفاده شده است. این توابع برخاسته از زمینه‌های متنوع ریاضی و آماری‌اند و هر یک از منطق خاصی در اندازه‌گیری اختلاف استفاده می‌کند؛ از این رو کاربرد فراوانی در دانش‌های گوناگون همچون پردازش تصویر، علوم مهندسی، پزشکی و نظریه کد دارند (Leonenko et al., 2013a). به طور کلی توابع هزینه منتخب را می‌توان در چهار گروه اندازه‌گیر اطلاعات^۱، تخمین‌گرهای M^۲، حداقل اختلاف^۳ و اندازه‌گیر زاویه بردار طیفی^۴ قرار داد.

برای استفاده از توابع جایگزین $D[P, Q]$ به عنوان فاصله‌ی بین دو بازتابندگی است که در آن $P = (p(\lambda_1), \dots, p(\lambda_n))$ بیانگر بازتابندگی اندازه‌گیری شده از طریق سنجنده و $Q = (q(\lambda_1), \dots, q(\lambda_n))$

جمع‌آوری شده در کمپین SPARC 2003 مقایسه شده است. در این کمپین، علاوه بر داده‌های زمینی از مزارع و پوشش‌های گیاهی گوناگون، داده‌های ماهواره کریس- پروبا هم‌زمان با برداشت زمینی در تاریخ ۲۰۰۳/۰۷/۱۲ از منطقه باراکس^۱ گرد آمده است. باراکس منطقه‌ای کشاورزی در جنوب اسپانیا (30°3'N, 6°2'W)، با تنوع انواع کشت‌های دیم و آبی است که کمپین‌های بسیاری به منظور کالیبراسیون و اعتبارسنجی تصاویر ماهواره‌ای در آن‌جا صورت گرفته است. این منطقه، به‌لحاظ ناهمواری، هموار (اختلاف ارتفاع تا ۲ متر) است. مزارع گیاهی بزرگ و متنوع (مانند یونجه، ذرت، سیب‌زمینی، چغندرقد، پیاز و سیر) با طیف گسترده‌ای از LAI (از ۰.۵ تا ۶.۵) که در این منطقه متمرکز شده است، طی سالیان متمادی، در زمینه تحقیقات سنجش از دور کشاورزی مورد توجه بوده است. کمپین SPARC، به سفارش سازمان فضایی اروپا، از دوازدهم تا چهاردهم ژوئیه ۲۰۰۳ و به منظور تحقیقات در زمینه کشاورزی در منطقه باراکس اسپانیا اجرا شد.

در طول کمپین SPARC، پارامترهای گیاهی گوناگونی همچون محتوای آب برگ CW، زیست‌توده برگ Cm، محتوای کلروفیل (a + b) Chl و LAI در منطقه باراکس به صورت زمینی اندازه‌گیری شد. اندازه‌گیری LAI با استفاده از LAI-2000 (LI-COR Biosciences) انجام شد. تعداد ۷۹ داده LAI، از کل LAI‌های برداشت‌شده از منطقه مورد نظر، به‌منظور ارزیابی عملکرد مدل معکوس استفاده شد که اطلاعات درباره این داده‌ها در جدول ۱ آمده است.

دسته سوم توابع حداقل اختلاف هستند که بازتابندگی را تابع چگالی طیفی در نظر می‌گیرند؛ بنابراین، از آن‌جا که داده‌های سنجش از دوری در قالب طیفی برداشت می‌شوند، استفاده از این توابع به‌منظور پردازش داده‌های سنجش از دوری انتخابی معقول به نظر می‌رسد (Leonenko et al., 2013b; Rivera et al., 2013).

این دسته از توابع به کلاس تخمین‌گرهای شباهت-گوسی بسیار نزدیک است و اساس این توابع در کمینه‌سازی فاصله بین مدلی پارامتریک و یک چگالی طیفی ناپارامتریک است. این دسته از توابع در تحلیل‌های سری-زمانی در فضای فرکانسی و به‌صورت خاص، در مدل‌های میانگین متحرک و رگرسیون خودکار، کاربرد گسترده‌ای دارند (Leonenko et al., 2013a).

برای $K(x) = \log x + \frac{1}{x}$ تابع حداقل اختلاف بدین صورت تعریف می‌شود:

$$D[P, Q] = \sum_{\lambda_i=1}^{\lambda_n} \left\{ \log \left(\frac{q(\lambda_i)}{p(\lambda_i)} \right) + \frac{p(\lambda_i)}{q(\lambda_i)} \right\} - 1 \quad \text{رابطه (۳)}$$

تابع اندازه‌گیر زاویه بردار طیفی SAM چهارمین تابعی است که در این مطالعه به کار رفته است. این تابع زاویه بین دو بردار طیفی را اندازه‌گیری می‌کند و در مباحثی مانند طبقه‌بندی، استفاده فراوان دارد.

$$D[P, Q] = \cos^{-1} \left\{ \frac{\sum_{i=1}^n p_i q_i}{\sqrt{\sum_{i=1}^n p_i^2 \sum_{i=1}^n q_i^2}} \right\} \quad \text{رابطه (۴)}$$

۲-۲- داده‌های زمینی گردآوری شده در کمپین زمینی SPARC

به‌منظور ارزیابی عملکرد مدل‌های بازیابی شاخص LAI در این مطالعه، نتایج حاصل با مجموعه داده زمینی

جدول ۱. اطلاعات آماری داده‌های برداشت‌شده زمینی

پیاز	سیر	چغندرقد	گوچه	ذرت	یونجه	تعداد
۱۵	۱۱	۱۰	۱۱	۱۶	۱۶	
۱/۳۴	۰/۴	۲/۹۸	۴/۸۲	۲/۴۳	۱/۲۲	حداقل اندازه‌گیری شده
۲/۸۸	۰/۸	۴/۹۱	۶/۲	۴/۱۳	۳/۷۲	حداکثر اندازه‌گیری شده
۱/۹	۰/۵۶	۴/۰۹	۵/۳۷	۳/۳۷	۲/۶۹	میانگین اندازه‌گیری شده

۲-۳- ماهواره کریس- پروبا

این ماهواره ۲۲ اکتبر ۲۰۰۱ در مدار قرار داده شد. کریس- پروبا سنجنده‌ای ابرطیفی و چندزاویه‌ای، با قدرت تفکیک مکانی بالا دارد که نسل جدیدی از داده‌های سنجنش از دور را برای پردازش و بهره‌برداری، در اختیار قرار می‌دهد. تصاویر این سنجنده در پنج Mode و با زاویه اوج 0، ± 36 و ± 55 و از محدوده ۴۰۰ تا ۱۰۵۰ نانومتر، در ۶۲ باند طیفی با قدرت تفکیک طیفی حدود ده‌نانومتری برداشت می‌شود. تصحیحات هندسی و رادیومتریکی روی داده‌های این سنجنده اعمال شده است. اطلاعات درباره ویژگی‌های سنجنده کریس- پروبا در جدول ۲ بیان شده است. در مطالعه حاضر، تصاویر Mode A سنجنده کریس- پروبا که با زاویه اوج سنجنده نادیر در ساعت ۱۱:۳۲ (به وقت محلی) و طی دوازدهم ژوئیه ۲۰۰۳ برداشت شده، به کار رفته است. مشخصات قرارگیری هندسی ماهواره و خورشید نسبت به هدف در تاریخ یادشده، در شکل ۱ آمده است

۲-۴- محاسبه جدول‌های LUT

برای شبیه‌سازی جدول‌های LUT، از مدل انتقال تابش PROSAIL استفاده شده است. PROSAIL یک مدل انتقال تابش فیزیک- پایه است که در شبیه‌سازی بازتابندگی سطحی پوشش گیاهی، کاربردی گسترده دارد (Jacquemoud et al., 2009). این مدل، به‌منظور شبیه‌سازی بازتابندگی تاج پوشش، از ترکیب مدل‌های PROSPECT برگ (Jacquemoud & Baret, 1990) و مدل SAIL تاج پوشش (Verhoef, 1984) استفاده می‌کند. پارامترهای ورودی مدل PROSAIL، به‌همراه دامنه تغییرات مقادیر آنها که در شبیه‌سازی جدول LUT به کار رفته، در جدول ۳ آمده است.

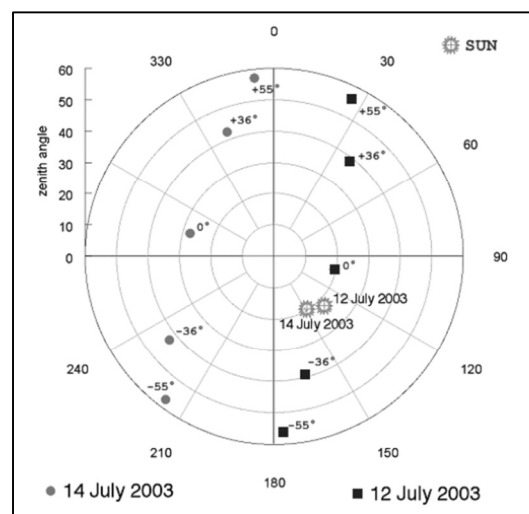
شکل ۲ نمای کلی از ساختار مدل PROSAIL را نشان می‌دهد. حروف اختصاری متغیرهای ورودی مدل PROSAIL در جدول ۳ بیان شده است. در این شکل، ρ میزان بازتابندگی و τ میزان عبور برای برگ (l)، خاک (s) و تاج پوشش (c) است که طبق زاویه اوج خورشید (θ_s) و نظاره‌گر یا سنجنده (θ_o) و زاویه آزیموت نسبی (ϕ_r) تعیین می‌شود.

مدل PROSPECT میزان بازتابندگی و عبور جهتی- نیم‌کره‌ای را در مورد محدوده طیفی ۲۵۰۰-۴۰۰ نانومتر، با قدرت تفکیک طیفی ۱ نانومتر، شبیه‌سازی می‌کند. پارامترهای ورودی مدل PROSPECT عبارت‌اند از پارامتر ضخامت برگ (N) (توصیف‌گر متوسط تعداد «لایه‌ها» و فضای خالی بین آنها داخل مزوفیل است)، میزان ماده خشک برگ (Cdm) (بیانگر مولکول‌های دیواره سلولی، مانند سلولز و لیگنین برگ است)، محتوای رطوبتی برگ (Cw)، کلروفیل برگ (Cab a+b)، محتوای رنگدانه‌های کارتونید (Car) و محتوای رنگدانه‌های قهوه‌ای برگ (Cbp) (نشان‌دهنده رنگدانه‌های پلی فنول برگ است که عامل پیری در برگ محسوب می‌شوند).

4SAIL به‌روزترین نسخه خانواده مدل SAIL محسوب می‌شود؛ در واقع، این مدل انتقال تابش تاج توسعه یافته مدل اولیه suits است. ساختار تاج پوشش


جدول ۲. اطلاعات قدرت تفکیک سنجنده کریس- پروبا

اندازه تصویر	۱۴*۱۴ کیلومتر (۷۴۸*۷۴۸ پیکسل)
محدوده طیفی	۴۱۰ تا ۱۰۵۰ نانومتر
قدرت تفکیک طیفی	۶۳ باند با قدرت تفکیک ۱/۳ نانومتر
قدرت تفکیک مکانی	۳۶ متر



شکل ۱. اطلاعات هندسی قرارگیری ماهواره و خورشید داده‌های برداشت شده کریس- پروبا، در دوازدهم و چهاردهم ژوئیه ۲۰۰۳

بهبود تخمین پارامتر LAI با استفاده از توابع هزینه جایگزین و راهکارهای چندجوابه



شکل ۲. ساختار مدل PROSAIL

منبع: Hadi, 2015

جدول ۳. متغیرهای ورودی مدل PROSAIL

پارامتر	مفهوم فارسی	واحد	توزیع	محدوده تغییرات
N	ضخامت برگ	-	یکنواخت	۱/۵-۲/۵
LCC	محتوای کلروفیل برگ (a+b)	$\mu\text{g}/\text{cm}^2$	یکنواخت	۰-۷۰
Cdm	محتوای ماده خشک برگ	g/cm^2	یکنواخت	۰/۰۰۱-۰/۰۳
Cw	محتوای رطوبت برگ	cm	یکنواخت	۰/۰۰۲-۰/۰۵
LAI	شاخص سطح برگ	m^2/m^2	یکنواخت	۰-۶
soil	بازتابندگی خاک	-	-	۰-۱
ALA	تابع توزیع زوایای برگ	درجه	یکنواخت	۴۰-۷۰
Hotspot	پارامتر نقطه داغ	m/m	-	۰/۰۵
Skyl	نسبتی برای توصیف شار تابشی پخش شده	-	-	۰/۰۵
theta_s	زاویه اوج خورشید	درجه	-	۲۲/۴
theta_v	زاویه اوج نظاره گر	درجه	-	۵۶/۲۴
phi_r	زاویه آزیموت نسبی	درجه	-	۱۳۷/۲۱

با استفاده از آنها بازتابندگی جهتی محاسبه می‌شود. در تنظیم دامنه و توزیع مقادیر متغیرهای ورودی مدل PROSAIL، از مطالعات مشابه استفاده شده است (D'Urso et al., 2004).

به منظور بهبود دادن جدول LUT، از روش‌های میانگین بهترین پاسخ‌ها و نرمال‌سازی داده‌ها استفاده

در این مدل با پارامترهای LAI، LIDF و پارامتر هات‌اسپات^۱ مشخص می‌شود. اطلاعات طیفی خاک با مدل خاکی تعریف می‌شود که هم می‌تواند از طریق نمونه‌برداری زمینی از محیط باشد و هم از داده‌های ماهواره‌ای اضافه شود. در این مطالعه، از طیف خاک لامبرتی استاندارد که در داخل مدل ذخیره شده بود، در ترکیب با ضریب روشنایی خاک (bf) که بین خاک روشن و تاریک مقیاس‌بندی شده، استفاده شده است. سه زاویه اوج خورشید (θ_s)، اوج سنجنده (θ_o) و زاویه آزیموت نسبی (ϕ_r) برای قرارگیری هندسی خورشید-سنجنده-زمین تعریف می‌شود. مدل SAIL به‌منزله خروجی، چهار نوع شار تابشی r_{dot} ، r_{sot} ، r_{sdt} ، r_{ddt} را محاسبه می‌کند. در گام نخست، r_{dot} و r_{sot}

1. Hot-Spot (hs)
2. Hemispherical-Directional Reflectance Factor in Viewing Direction
3. Bi-Directional Reflectance Factor
4. Directional-Hemispherical Reflectance Factor for Solar Incident Flux
5. Bi-Hemispherical Reflectance Factor

به همراه نرمال سازی داده‌ها، به منظور بهبود دادن تخمین متغیر LAI به کار رفت. برای ارزیابی عملکرد توابع منتخب، از شاخص‌های آماری میانگین مجذور خطاها^۱، خطای جذر میانگین مربعات، خطای جذر میانگین مربعات نرمال شده^۲، ضریب تعیین^۳ و انحراف معیار^۴ استفاده شده است. در هر یک از شکل‌ها و نمودارها، حروف اختصاری بدین مفهوم به کار رفته است:

LSE: Least Square Error;
MC: Minimum Contrast;
KL: Kulbak-Leibler;
SAM: Spectral Angle Mapper.

۳-۱- نتایج توابع هزینه گوناگون


در شکل ۳، به ترتیب، نمودار RMSE درصدی در متفاوت بهترین پاسخ‌ها را برای داده‌های نرمال شده و نرمال نشده نشان می‌دهد. محور افقی این نمودارها بیانگر درصدی متفاوت بهترین جواب‌ها و محور عمودی میزان RMSE به دست آمده، در مقایسه با داده‌های زمینی است.

نمودارهای شکل ۳ روندی منطقی از عملکرد مدل معکوس در بازیابی پارامتر LAI را نشان می‌دهد.


شده است؛ بدین صورت که با استفاده از توابع گوناگون در هر دو حالت (داده‌های نرمال شده و نرمال نشده)، بازتابندگی‌های اندازه‌گیری شده با بازتابندگی‌های جدول LUT مقایسه شده است. در نهایت، میانگین ۱ تا ۱۰۰٪ پاسخ‌های مرتب شده جدول LUT (از بهترین تا بدترین)، از طریق شاخص خطای جذر میانگین مربعات^۱، با داده زمینی مقایسه شده و میانگین درصدی که RMSE پایین‌تری داشته به منزله پاسخ نهایی انتخاب شده است. برای نرمال سازی داده‌ها، از شیوه نرمال سازی خطی استفاده شده که آن را معرفی کرده است. در این روش، بازتابندگی هر یک از باندهای طیفی بر مجموع بازتابندگی‌های همه باندها تقسیم می‌شود؛ در این صورت، مجموع بازتابندگی باندها پس از نرمال سازی، برابر با یک خواهد بود.

۳-۲ نتایج

در تحقیق پیش رو، از چهار تابع هدف برای بهینه سازی استفاده شد و روش‌های میانگین بهترین پاسخ‌ها



ب



الف

شکل ۳. عملکرد توابع گوناگون در مورد درصدی متفاوت جواب‌ها: داده‌های نرمال نشده (الف)؛ داده‌های نرمال شده (ب). محور افقی این نمودارها میانگین درصدی متفاوت بهترین پاسخ‌ها را نشان می‌دهد و محور عمودی نشان دهنده خطای RMSE هر یک از درصدها با داده اندازه‌گیری شده زمینی است

1. Root Mean Square Error (RMSE)
2. Mean Absolute Error (MAE)
3. Normalized Root Mean Square Error (NRMSE)
4. R-Square (R2)
5. Standard Deviation (STD)

نرمال نشده، بدترین عملکرد را (با NRMSE برابر با ۲۰٪ و R2 برابر با ۰/۸۵) داشته ولی درمورد داده‌های نرمال شده، NRMSE به میزان ۸٪ بهبود یافته است. تابع MC نیز، در مقایسه با داده‌های نرمال نشده، ۴٪ بهبود یافته است. نرمال سازی درمورد تابع LSE تأثیری به مراتب بیشتر از توابع دیگر داشته است. با توجه به اینکه توزیع غیرنرمال خطاهای موجود در داده‌ها به نقض فرض اساسی توابع LSE منجر می‌شود و انتظار می‌رود شاهد عملکرد ضعیف چنین توابعی در این شرایط باشیم، می‌توان اذعان داشت خطای موجود در داده‌های تحقیق حاضر به توزیع غیرنرمال تمایل داشته‌اند و استفاده از فضای نرمال سازی شده داده‌ها تا حد بسیاری توانسته اثر این خطاها را کاهش دهد و باعث بهبود عملکرد توابع LSE و MC شود.

در حالت کلی، نرمال سازی داده‌ها درمورد همه توابع، اثر مثبت داشته و باعث بهبود نتایج تخمین آنها شده است. البته باید خاطر نشان کرد تابع KL نیز از نرمال سازی بهره می‌برد زیرا برای استفاده از این توابع، بازتابندگی باید به صورت توزیعی احتمالاتی در نظر گرفته شود. نکته شایان توجه عملکرد مستقل از نرمال سازی تابع SAM است و به نظر می‌رسد توابعی که به اندازه گیری زاویه بین دو بردار طیفی می‌پردازند از نرمال سازی داده‌ها تأثیر نمی‌پذیرند.

همچنان که انتظار می‌رود، همه توابع در هر دو حالت داده‌های نرمال شده و نرمال نشده، درمورد تکراه حل^۱ و درصدهای کمتر بهترین پاسخ‌ها، نتایج ضعیفی داشته است اما با افزایش درصد میانگین بهترین جواب‌ها، همه توابع در حدود ۱۰٪ به حالت بهینه دست یافته‌اند.

همچنین با افزایش درصد بهترین جواب‌ها، شاهد افزایش میزان خطای RMSE هستیم. به طور کلی تابع KL با میزان ۱۱٪ بهترین پاسخ‌ها و RMSE برابر با ۰/۷۲ نتیجه مطلوبی را در بین توابع مذکور داشته است. نرمال سازی داده‌ها تأثیر بسیاری در نتیجه توابع LSE و MC داشته است؛ این در حالی است که تابع SAM کمتر تحت تأثیر نرمال سازی قرار گرفته است.

جدول ۳ نتایج استفاده از توابع گوناگون به منظور تخمین متغیر LAI را نشان می‌دهد. در این جدول، توابعی که نرمال سازی بر آنها اعمال شده با علامت * مشخص شده است.

استفاده از رویکرد توابع منتخب به همراه میانگین بهترین پاسخ‌ها و نرمال سازی داده‌ها توانسته است تخمین متغیر LAI را به میزان ۱۰٪ بهبود ببخشد. در بین توابع منتخب، تابع اندازه گیر اطلاعات کولبک-لیبلر (با NRMSE برابر با ۱۲٪ و R2 برابر با ۰/۸۹) بهترین عملکرد و تابع LSE، درمورد داده‌های

جدول ۴. نتایج توابع آماری در بازیابی پارامتر LAI
توابع نرمال شده با علامت ستاره (*) مشخص شده‌اند

تابع	MBS%	R2	NRMSE	RMSE	MAE	STD
LSE	۷	۰/۸۵	۰/۲۰	۱/۲	۱/۰۳	۱/۴۲
LSE*	۶	۰/۸۶	۰/۱۳	۰/۷۶	۰/۵۶	۱/۴۴
MC	۴	۰/۸۸	۰/۱۷	۱/۰۱	۰/۷۷	۱/۲۱
MC*	۱۳	۰/۸۸	۰/۱۳	۰/۷۹	۰/۶۱	۱/۳۳
KL	۱۱	۰/۸۹	۰/۱۲	۰/۷۲	۰/۵۵	۱/۳۴
SAM	۴	۰/۸۶	۰/۱۳	۰/۷۸	۰/۵۸	۱/۴۲
SAM*	۴	۰/۸۶	۰/۱۳	۰/۷۹	۰/۵۸	۱/۴۲

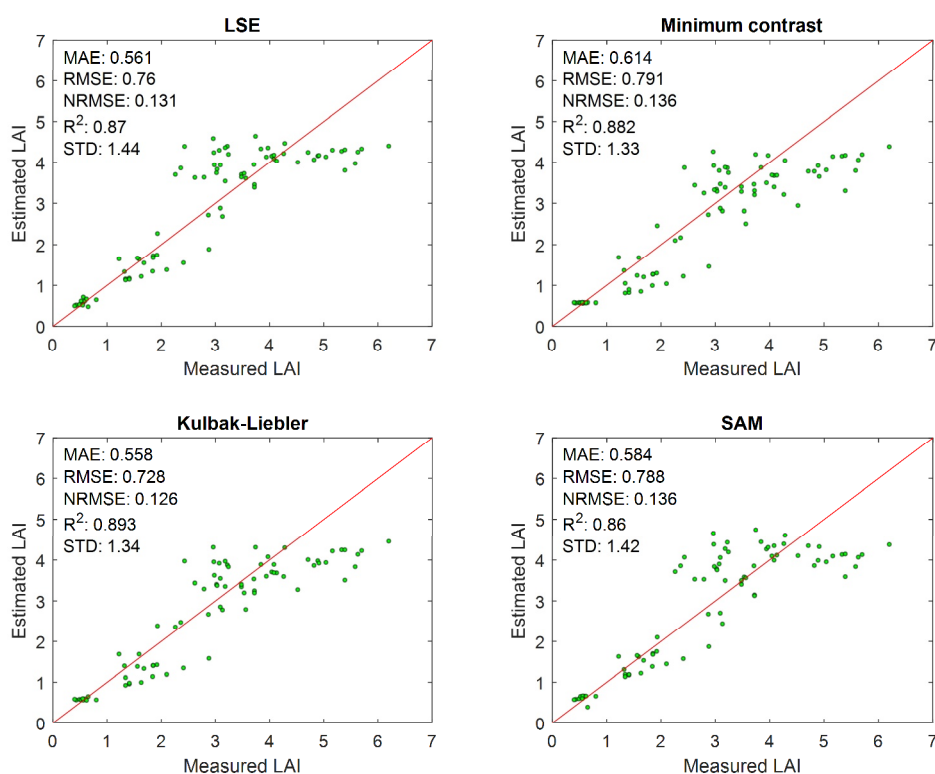
1. Single Best Solution

عامل اصلی ناهمگونی در تخمین موفق نبودن مدل PROSAIL در شبیه‌سازی تاج‌پوشش‌های چندگانه باشد که در پژوهش درویش‌زاده^۱ و همکاران (۲۰۰۸) نیز بدان اشاره شده است.

۳-۲- نقشه‌های بازیابی شده LAI

نقشه‌های انحراف معیار بیانگر فقدان اطمینان در تخمین LAI هریک از پیکسل‌هاست. انحراف معیار کمتر، برای پیکسل‌ها، معرف پراکندگی کمتر مقادیر LAI در درصدهای بهترین پاسخ‌های آنهاست. نقشه‌های انحراف معیار هریک از توابع (شکل ۵) نشان می‌دهد بیشترین نبود اطمینان به تخمین مقادیر بالای LAI (پوشش‌های متراکم) بازمی‌گردد. در مورد مقادیر


نمودار پراکندگی LAI تخمین‌زده شده و اندازه‌گیری شده، در مورد هریک از توابع، در شکل ۵ نشان داده شده است. رفتار همه توابع در تخمین LAI تا حدودی مشابه هم بوده اما نکته درخور توجه عملکرد مدل معکوس، در بازیابی LAI تاج‌پوشش‌های متفاوت است؛ به طوری که در مورد مقادیر پایین LAI با اشباع‌شدگی، در مورد مقادیر حدود ۱.۵ با کم تخمینی، در مورد مقادیر حدود ۳ با بیش تخمینی و بار دیگر در مورد مقادیر بالاتر LAI با کم تخمینی همراه بوده است. این ناهمگونی در تخمین ممکن است از عوامل متفاوتی، از جمله اشباع‌شدگی باندهای محدوده مرئی برای مقادیر بالاتر LAI و موارد فقدان اطمینان در خود داده‌های زمینی ناشی شده باشد. اما به نظر می‌رسد



شکل ۴. نمودار پراکندگی LAI اندازه‌گیری شده و تخمین‌زده شده با استفاده از توابع *LSE، *MC، *KL، *SAM

1. Darvishzadeh

بهبود تخمین پارامتر LAI با استفاده از توابع هزینه جایگزین و راهکارهای چندجوابه




شکل ۵. نقشه‌های انحراف معیار مقادیر بازیابی شده LAI با توابع هزینه گوناگون

۴- بحث و بررسی

استفاده از توابع هزینه جایگزین به همراه رویکردهای بهینه‌سازی یکی از روش‌های رفع مشکل ill-posed مدل‌های معکوس مبتنی بر LUT است. در مطالعه حاضر نیز، از چهار نوع تابع هزینه به همراه میانگین درصدهایی از بهترین پاسخ‌های LUT و نرمال‌سازی خطی داده‌ها استفاده شده و دقت تخمین LAI به میزان ۱۲٪ بهبود یافته است. شایان ذکر است دقت ۱۰٪ مورد انتظار GMES، با استفاده از داده‌های SPARC ۲۰۰۳، تا کنون در کمتر مطالعه‌ای با روش مشابه به دست آمده است. البته باید توجه داشت مطالعاتی که به دقت‌های بسیار بهتر دست یافته‌اند اغلب بر بازیابی نوع خاصی از پوشش‌های گیاهی تأکید داشته‌اند. برای نمونه، در پژوهش ریشتر^۱ و همکاران (۲۰۱۱)، دقت حدود ۱۰٪ برای چغندر قند و گندم حاصل شد. در این مطالعه، دقت بازیابی برای ذرت ۱۹٪ گزارش شده است. طبق پژوهش درویش زاده و همکاران (۲۰۰۸) و ریشتر و همکاران (۲۰۰۹) دستیابی به دقت‌های بالا، هنگام استفاده از مدل PROSAIL و روش LUT، فقط در

پایین‌تر LAI (خاک لخت)، هریک از توابع رفتار متفاوت‌تری داشته است و به‌طور کلی تابع MC و KL به ترتیب بیشترین و کمترین انحراف معیار را در مورد مقادیر پایین‌تر LAI ارائه داده‌اند. نقشه LAI که به تفکیک هریک از توابع بازیابی شده، در شکل ۶ نشان داده شده است. برای مقایسه بهتر، از نقشه NDVI تصویر رنگی کاذب منطقه استفاده شده است. با توجه به نقشه NDVI و تصویر کاذب منطقه، می‌توان نتیجه گرفت که مدل معکوس، علاوه بر عملکرد مناسب و مطلوبی، هم در بازیابی شکل زمین‌های کشاورزی و هم در بازیابی تغییرات داخل زمین‌های کشاورزی داشته است. زمین‌های کشاورزی دایره‌ای شکل مناطقی با LAI بالای ۳/۵ هستند که به شیوه آبیاری شده کشت می‌شوند و در نقشه NDVI، مقادیر بالای ۰/۷ دارند. مناطقی که با LAI کمتر از ۱/۵ بازیابی شده‌اند اصولاً زمین‌های خاکی و یا زمین‌هایی‌اند که محصولات آنها برداشت شده است (مانند گندم و جو). این مناطق با NDVI کمتر از ۰/۴ مشخص شده‌اند. در بین توابع گوناگون، تابع MC در مورد مقادیر میانی و پایین LAI رفتاری یکنواخت داشته است. به‌طور کلی همه توابع در تخمین زمین‌های خاکی موفق نبوده‌اند؛ با این حال تابع SAM تا حدودی بر این مشکل فائق آمده است.

1. Richter



شکل ۶. نقشه LAI توابع هزینه متفاوت به همراه تصویر کاذب و NDVI منطقه مورد مطالعه

دربر داشته و در مطالعات متنوعی، استفاده آن پیشنهاد شده است؛ مثلاً پژوهش ریورا^۱ و همکاران (۲۰۱۳) مشخص کرد استفاده از نرمال سازی، در بازیابی پارامتر کلروفیل برگ، باعث بهبود نتیجه تخمین می شود اما در بازیابی متغیر LAI موفقیت آمیز نیست. دلیل موفقیت نداشتن نرمال سازی داده ها، در زمینه پارامتر LAI، فشردگی داده ها در نتیجه فرایند نرمال سازی است. این کار در سنجنده های چندطیفی، به دلیل پهنای باند بزرگ تر، باعث بروز اختلال در اندازه گیری تطابق بین بازتابندگی های شبیه سازی شده و اندازه گیری شده می شود اما، در مطالعه حاضر که از داده های فراطیفی بهره برده، نرمال سازی باعث افزایش

بازیابی یک نوع گیاه امکان پذیر است زیرا مدل PROSAIL برای معکوس سازی چند نوع پوشش گیاهی با مشکل مواجه می شود؛ بنابراین دستیابی به دقت های بهتر در این گونه روش ها به نوع مدل استفاده شده برای معکوس سازی (مثلاً مدل های یک بعدی یا 1D تا مدل های سه بعدی یا 3D)، تنظیم صحیح پارامترهای مدل و صحت داده های زمینی برداشت شده بازمی گردد (Combal et al., 2003). در حالت کلی، دستیابی به دقت NRMSE به میزان ۱۵٪ تا ۲۰٪ در مورد بازیابی متغیر LAI، دقتی مورد قبول است (Baret, 2010).

نرمال سازی داده ها، در مطالعات گوناگون و در زمینه بازیابی پارامترهای پوشش گیاهی، نتایج خوبی

1. Rivera

- Combal, B., Baret, F., Weiss, M., Trubuil, A., Macé, D., Pragnère, A., Myneni, R.B., Knyazikhin, Y. & Wang, L.B., 2003, **Retrieval of Canopy Biophysical Variables from Bidirectional Reflectance Using Prior Information to Solve the Ill-Posed Inverse Problem**, Remote Sensing of Environment, 84(1), PP. 1-15.
- D'Urso, G., Dini, L., Vuolo, F., Alonso, L. & Guanter L., 2004, **Retrieval of Leaf Area Index by Inverting Hyper-Spectral, Multi-Angular CHRIS/Proba Data from Sparc 2003**, European Space Agency, (Special Publication) ESA SP, (578), PP. 58-63.
- Darvishzadeh, R., Skidmore, A., Schlerf, M. & Atzberger, C., 2008, **Inversion of a Radiative Transfer Model for Estimating Vegetation LAI and Chlorophyll in a Heterogeneous Grassland**, Remote Sensing of Environment, 112(5), PP. 2592-2604.
- Dashti Ahangar A.H., Darvishzadeh R., Matkan A.A., Hajeb M. **Inversion of a Radiative Transfer Model for Estimation of Rice Canopy Chlorophyll Content and ALOS Imagery**, Iranian Journal of Remote Sensing & GIS, Vol.3, No.2, Summer 2011.
- Gitelson, A.A., Viña, A., Ciganda, V., Rundquist, D.C. & Arkebauer, T.J., 2005, **Remote Estimation of Canopy Chlorophyll Content in Crops**, Geophysical Research Letters, 32(8), PP. 1-4.
- Hadi, H., 2015, **Multivariate Statistical Analysis for Estimating Grassland Leaf Area Index and Chlorophyll Content Using Hyperspectral Data**, PhD Dissertation, (June).
- Jacquemoud, S. & Baret, F., 1990, **PROSPECT: A Model of Leaf Optical Properties Spectra**, Remote Sensing of Environment, 34(2), PP. 75-91.
- Jacquemoud, S., Verhoef, W., Baret, F., Bacour, C., Zarco-Tejada, P.J., Asner, G.P., François, C. & Ustin, S.L., 2009, **PROSPECT + SAIL Models: A Review of Use for Vegetation Characterization**, Remote Sensing of Environment, 113(SUPPL. 1).

دقت بازیابی شده است. به نظر می‌رسد استفاده از روش‌های نرمال‌سازی و تبدیل داده‌ها از فضای طیفی به حالت نرمال‌شده داده‌ها، در داده‌های فراطیفی، تأثیر موارد فقدان اطمینان در داده‌ها را کاهش چشمگیری می‌دهد.


۵- نتیجه‌گیری

در این تحقیق، چهار دسته از توابع که هر کدام از مناطق خاصی برای مقایسه توضیح‌های آماری بهره می‌گیرند، جهت بازیابی پارامتر LAI مورد ارزیابی قرار گرفت. نتایج نشان داد نرمال‌سازی داده‌های فراطیفی تأثیر بسیاری در تخمین متغیر LAI دارد. در حالت کلی، تابع اندازه‌گیر اطلاعات (کولبک-لیبلر) در زمینه تخمین متغیر LAI نتایج مطلوبی داشت. تابع LSE که معمولاً در مطالعات استفاده می‌شود، در مورد داده‌های نرمال‌نشده نتیجه خوبی ارائه نداد اما در مورد داده‌های نرمال‌شده، بهبود چشمگیری داشت. در مطالعه حاضر، تابع SAM به این علت که زاویه بین دو بردار را اندازه‌گیری می‌کند، از نرمال‌سازی داده‌ها تأثیر اندکی پذیرفته است.

۶- منابع

- Bacour, C., Jacquemoud, S., Tourbier, Y., Dechambrec, M. & Frangi, J.-P., 2002, **Design and Analysis of Numerical Experiments to Compare Four Canopy Reflectance Models**, Remote Sensing of Environment, 79(1), PP. 72-83.
- Baret, F., 2010, **Biophysical Vegetation Variables Retrieval from Remote Sensing Observations**, Proceedings of Remote Sensing for Agriculture, Ecosystems, and Hydrology XII, 7824, PP. 17-19.
- Baret, F. & Buis, S., 2008, **Estimating Canopy Characteristics from Remote Sensing Observations: Review of Methods and Associated Problems**, In Advances in land Remote Sensing, Springer; PP. 173-201.
- Chen, J.M. & Black, T.A., 1992, **Defining Leaf Area Index for Non-Flat Leaves**, Plant, Cell & Environment, 15(4), PP. 421-29.

- Leonenko, G., Los, S.O. & North, P.R.J., 2013a., **Retrieval of Leaf Area Index from MODIS Surface Reflectance by Model Inversion Using Different Minimization Criteria**, Remote Sensing of Environment, 139, PP. 257-70.
<http://dx.doi.org/10.1016/j.rse.2013.07.012>.
- , 2013b, **Statistical Distances and Their Applications to Biophysical Parameter Estimation: Information Measures, m-Estimates, and Minimum Contrast Methods**, Remote Sensing, 5(3), PP. 1355-88.
- Meroni, M., Colombo, R. & Panigada, C., 2004, **Inversion of a Radiative Transfer Model with Hyperspectral Observations for LAI Mapping in Poplar Plantations**, Remote Sensing of Environment, 92(2), PP. 195-206.
- Mousivand, A.J., 2015a. **Retrieval of Vegetation Properties Using Top of Atmosphere Radiometric Data: A Multi-Sensor Approach**,
<http://repository.tudelft.nl/view/ir/uuid:8c367e85-91e4-4377-8e39-65c8c36605ac/>.
- Mousivand, A.J., Menenti, M., Gorte, B. & Verhoef, W., 2015, **Multi-Temporal, Multi-Sensor Retrieval of Terrestrial Vegetation Properties from Spectral-Directional Radiometric Data**, Remote Sensing of Environment, 158, PP. 311-30.
- Richter, K., Atzberger, C., Vuolo, F., Weihs, P. & D'Urso, G., 2009, **Experimental Assessment of the Sentinel-2 Band Setting for RTM-Based LAI Retrieval of Sugar Beet and Maize**, Canadian Journal of Remote Sensing, 35(3), PP. 230-47.
- Richter, K., Atzberger, C., Vuolo, F. & D'Urso, G., 2011, **Evaluation of Sentinel-2 Spectral Sampling for Radiative Transfer Model Based LAI Estimation of Wheat, Sugar Beet, and Maize**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 4(2), PP. 458-64.
- Rivera, J.P., Verrelst, J., Leonenko, G. & Moreno, J., 2013, **Multiple Cost Functions and Regularization Options for Improved Retrieval of Leaf Chlorophyll Content and LAI through Inversion of the PROSAIL Model**, Remote Sensing, 5(7), PP. 3280-3304.
<http://www.mdpi.com/2072-4292/5/7/3280>
 (January 3, 2020).
- Verhoef, W., 1984, **Light Scattering by Leaf Layers with Application to Canopy Reflectance Modeling: The SAIL Model**, Remote Sensing of Environment. 16(2). PP. 125-41.
- Verrelst, J., Rivera, G.P., Leonenko, G., Alonso, L. & Moreno, J., 2012, **Optimizing LUT-Based Radiative Transfer Model Inversion for Retrieval of Biophysical Parameters Using Hyperspectral Data**, International Geoscience and Remote Sensing Symposium (IGARSS), PP. 7325-28.
- , 2014, **Optimizing LUT-Based RTM Inversion for Semiautomatic Mapping of Crop Biophysical Parameters from Sentinel-2 and -3 Data: Role of Cost Functions**, IEEE Transactions on Geoscience and Remote Sensing, 52(1), PP. 257-69.



Combining Multiple Solution and Cost Function for Better LAI Estimation

Mousivand A.J.^{1*}, Shirmohammadpour M.², Shamsoddini A.³

1. Assistant Prof., Faculty of Humanities, Dep. of Remote Sensing (GIS), Tarbiat Modarres University
2. Master Student of Remote Sensing and GIS, Tarbiat Modarres University
3. Associate Prof., Faculty of Humanities, Dep. of Remote Sensing (GIS), Tarbiat Modarres University

Abstract

Vegetation is a key component of the earth planet, which controls the energy and water exchanges between atmosphere and the Earth surface and plays an important role in the global energy cycles, such as oxygen, carbon dioxide, and water. Monitoring and management of vegetation are done using its biophysical and biochemical parameters such as LAI. Leaf area index (LAI) is one of the most important vegetation parameters that used in most of the applications such as water and carbon cycles modeling.

Remote sensing in terms of their continuous and extensive cover is a unique tool for generating vegetation variables. Different retrieval approaches have been developed to extract biophysical parameters information from remote sensing data, which is divided into two broad classes, the statistical/experimental approaches and the physical approach. In the present study, the PROSAIL RT model (Radiation Transfer Model) based on the LUT table have been used to retrieve the LAI variable. Ground reference data collected during the SPARC 2003 campaign were also used to evaluate the accuracy of the retrieved variable. To drawback, the ill-posed problem, four categories of cost functions have been used: Information Measurement (IM), Minimum contrast (MC), Angle Measurement (SAM) and Least Square Error (LSE) and used the multiple Best solution instead of Single best solution. The results showed improvement in the LAI estimation of up to 12% for the multi-species canopy.

Keywords: Leaf area index, Radiative transfer model, Cost function, Look up table.