

بر آورد عملکرد محصول با استفاده از تلفیق داده های سنجش از دور و مدل گیاهی

ساناز محمدی^{*}، ایمان حاجی راد^۲

*۱- دکتری گروه مهندسی و مدیریت آب دانشگاه تربیت مدرس، دانشکده کشاورزی، تهران، ایران.

۲- دانشجوی دکتری، گروه مهندسی آبیاری و آبادانی، دانشکدگان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران.

چکیده

پیش بینی عملکرد محصول در مقیاس منطقه ای از نظر مدیریت محصول، نظارت بر کشاورزی، ارزیابی امنیت غذایی در سطح ملی و سیاست گذاری مواد غذایی اهمیت بسیاری دارد. در سال های اخیر اهمیت پایش رشد محصول و پیش بینی عملکرد در مقیاس وسیع برجسته شده است چراکه اطلاعات دقیق در مورد رشد محصول و عملکرد آن برای مقابله به موقع با خطرات تغییر اقلیم، ارزیابی امنیت غذایی و توسعه استراتژیک تجارت غذایی مناسب ضروری است. مدل های گیاهی رشد محصول حاوی پارامترهای ورودی متعددی هستند که باید باتوجه به ویژگی های منطقه مطالعاتی بروزرسانی شوند که معمولاً عدم دسترسی به این پارامترها و وجود عدم قطعیت در آن ها منجر به بروز خطا در نتایج حاصل از مدل های گیاهی می شود. تحقیقات نشان داده است که تلفیق مدل های گیاهی رشد محصول و داده های سنجش از دور را می تواند موثرترین روش برای افزایش دقت تخمین عملکرد محصول باشد. در این مطالعه روش های مختلف تلفیق داده های سنجش از دور و مدل های گیاهی و مزایای هر یک بررسی می شود. نتایج تحقیقات مختلف نشان داده است که استفاده از داده های سنجش از دور مانند شاخص سطح برگ یا رطوبت خاک دقت برآورد عملکرد محصول توسط مدل های گیاهی را بهبود می بخشد.

واژگان کلیدی: پیش بینی عملکرد، رشد محصول، تصاویر ماهواره ای، عدم قطعیت.



پایش به موقع رشد گیاه و برآورد دقیق عملکرد محصول در مقیاس کوچک از اهمیت ویژه‌ای در مدیریت محصول و نظارت بر کشاورزی برخوردار است (Pan et al., 2019). در سال‌های اخیر اهمیت پیش رشد محصول و پیش‌بینی عملکرد در مقیاس وسیع برجسته شده است چرا که اطلاعات دقیق در مورد رشد محصول و عملکرد آن برای مقابله به موقع با خطرات تغییر اقلیم، ارزیابی امنیت غذایی و توسعه استراتژی تجارت غذایی مناسب، ضروری است (Franch et al., 2015).

اثرات ترکیبی تغییر اقلیم، رشد جمعیت، فرسایش خاک و تنوع طبیعی آب و هوا نیازمند روش‌هایی است که ارزیابی به موقع و دقیقی از رشد محصول و عملکرد آن ارائه دهد و به افزایش پایداری تولید مواد غذایی کشاورزی کمک کند (FAO, 2017; IPCC, 2018). داده‌های سنجش از دور نیز پتانسیل این را دارند که مشاهدات مکرر، به موقع و همیشه در دسترسی از سطح زمین را در طیف وسیعی از مقیاس-های مکانی ارائه دهند (Liang and Qin, 2008). مشاهدات ثبت شده توسط ماهواره‌ها نیاز به تفسیر برای ارائه استنباط در مورد پارامترهای بیوفیزیکی مورد نظر برای پیش سطح زمین (به ویژه زمین‌های زراعی) مانند رطوبت خاک (Dorigo et al., 2007)، شاخص سطح برگ (Yang et al., 2006)، تبخیر-تعرق (Mu et al., 2007)، نسبت جذب فعال فتوسنتزی (Knyazikhin et al., 1998) یا بیوماس روزمینی (Hu et al., 2016) دارند. همچنین پیشرفت‌های قابل توجهی در مدل‌سازی رشد محصول با مدل‌های گیاهی انجام شده است (Jones et al., 2003; Challinor et al., 2004; Hsiao et al., 2009; Holzworth et al., 2015). این مدل‌ها با شبیه‌سازی تبادل گازهای فتوسنتزی بین هوا و تاج گیاه، فنولوژی، رطوبت خاک و دما، رشد بیوماس و تشکیل عملکرد دانه، تکامل محصول را از کاشت تا برداشت پیش‌بینی کنند. مدل‌های گیاهی به ورودی‌های هواشناسی مانند تابش خورشیدی، دما، بارندگی و غیره نیاز دارند (Hoogenboom, 2000). هم‌چنین اطلاع از پارامترهای توصیف‌کننده فرآیندهای مختلف، گونه‌های گیاهی، شرایط خاک، شیوه‌های مدیریتی و غیره نیز نیاز می‌باشد. بنابراین مدل‌ها امکان برآورد کمی رشد محصول را از نظر جنبه‌های مختلف (سطح برگ، بیوماس رو زمینی، بیوماس ریشه، رطوبت خاک، عملکرد دانه و غیره) فراهم می‌کنند. اگرچه عملکرد مدل‌ها به خودی خود قابل قبول است، اما درک این نکته ضروری است که عملکرد آن‌ها با عدم قطعیت در پارامترسازی مدل، عدم قطعیت داده‌های هواشناسی و عدم قطعیت در توصیف ساده فرآیندهای مدل مختل می‌شود (Dorigo et al., 2007; Marin et al., 2017). هر دو روش مشاهدات زمینی حاصل از داده‌های ماهواره‌ای و مدل‌های رشد محصول دارای مزایا و معایبی هستند. مشاهدات زمینی حاصل از داده‌های ماهواره‌ای ممکن است دچار شکاف داده ایجاد شده به-دلیل پوشش ابر شوند (Whitcraft et al., 2015). هم‌چنین پارامترهای بازایی شده می‌توانند دارای عدم قطعیت‌های بزرگ و مهم و سوگیری‌های به‌خوبی مشخص نشده باشند (Huang et al., 2016). سنسورهای ماهواره‌ها فقط مجموعه محدودی از متغیرهای مورد نظر را اندازه‌گیری می‌کنند. از طرف دیگر پارامترسازی مناسب مدل‌های گیاهی برای استفاده در مقیاس‌های بزرگ (یعنی منطقه‌ای) دشوار است چراکه تنوع کشاورزی (انواع مختلف محصولات، تنوع در انواع خاک و شیوه‌های مدیریت محصول) بسیار زیاد است. علاوه بر این، عدم قطعیت داده‌های درون‌یابی شده ایستگاه هواشناسی که به‌عنوان ورودی در مدل گیاهی استفاده می‌شود، می‌تواند به‌طور قابل توجهی توانایی مدل را برای پیش‌بینی رشد محصول مختل کند (Hansen and Jones, 2000). بنابراین ترکیب مشاهدات زمینی حاصل از داده‌های ماهواره‌ای و مدل‌های گیاهی برای بهره‌برداری از آن‌ها بهترین حالت ممکن است. تکنیک داده‌گذاری یک روش رسمی و کاملاً قابل فهم برای ترکیب پیش‌بینی‌های مدل با مشاهدات ماهواره‌ای است که اجازه می‌دهد به تجزیه و تحلیلی برسیم که ترکیبی مطلوب از هر دو نوع ورودی است (Huang et al., 2019).

در راستای کاربرد کشاورزی دقیق، مدل‌های گیاهی می‌توانند به کشاورز در تصمیم‌گیری مربوط به مدیریت‌های خاص منطقه‌ای از نظر زمان و مقدار و هم‌چنین ارائه پیش‌بینی عملکرد محصول کمک کنند (Tewes et al., 2020). به‌طور معمول قابلیت اطمینان مدل‌های شبیه‌سازی رشد محصول بستگی به ارائه دقیق فرآیندهای فیزیولوژی گیاهی در مدل، انتخاب درست پارامترهای مدل و دقت داده‌های ورودی دارد (Waha et al., 2015). عملکرد مدل به‌علت عدم قطعیت این عوامل می‌تواند مختل شود (Huang et al., 2019).

مرور منابع

مدل‌های گیاهی قبل از استفاده برای شبیه‌سازی رشد محصول باید کالیبره یا واسنجی شوند (Huang et al., 2019). واسنجی مدل فرآیندی است که طی آن پارامترهای مدل برای دستیابی به نتایج دقیق تنظیم می‌شوند (Boote et al., 2013). باتوجه به این‌که عملکرد گیاه بستگی به اقلیم، تنوع و مدیریت زراعی دارد، در صورت تغییر قابل توجه هریک از این متغیرها واسنجی مدل ضروری خواهد بود (Boote et al., 2019). واسنجی معمولاً در چند مرحله انجام می‌شود تا با داده‌های مختلف مشاهداتی مانند فنولوژی و عملکرد محصول مطابقت داشته باشد و زمانی موفقیت آمیز خواهد بود که مدل با مجموعه داده‌های مستقل آزموده شده و حداقل باقی‌مانده مشاهده گردد (Gupta et al., 2006). علی‌رغم اهمیت، واسنجی مدل اغلب یک کار سخت و زمان‌بر است که نیاز به داده مشاهداتی، تخصص و ابزار پیچیده داده‌برداری دارد. واسنجی پارامترها بسته به در دسترس بودن داده‌ها و کیفیت آن‌ها محدود می‌شود و پارامترهای واسنجی شده ممکن است در نتیجه روش واسنجی یا حتی ترتیب واسنجی روشن و صریح نباشند که از مشکلات عمده در واسنجی مدل‌های گیاهی است (Seidel et al., 2018).

در هنگام استفاده از مدل‌های گیاهی برای برآورد عملکرد محصول با دو منبع عدم قطعیت ناشی از اقلیم و عدم قطعیت مدل مواجه هستیم. پیش‌بینی ماهانه داده‌های هواشناسی عدم قطعیت مربوط به پارامترهای اقلیمی را کاهش می‌دهد و عدم قطعیت مربوط به مدل که ناشی از خطاها در ساختار مدل، فرضیات مدل و داده‌های جانبی و فرعی می‌باشد که در طی فصل رشد ثابت هستند را می‌توان به-کمک تکنیک داده‌گذاری^۱ مشاهدات ماهواره‌ای کاهش داد (Ines et al., 2013). داده‌گذاری متوالی می‌تواند برای بهبود عملکرد مدل گیاهی بدون تغییر ساختار آن با به‌روز رسانی دوره‌ای متغیرهای حالت در طی فصل رشد با مشاهدات سنجنش از دور مورد استفاده قرار گیرد. شاخص‌های گیاهی حاصل از سنجنش از دور و رطوبت خاک به‌دلیل تأثیری که بر رشد محصول و در نتیجه عملکرد آن دارند به-طور بالقوه برای داده‌گذاری متوالی مناسب هستند. پوشش زمانی و مکانی آن‌ها نیز امکان داده‌گذاری برای پیش‌بینی محصول در مقیاس منطقه‌ای را فراهم می‌کند (Ines et al., 2013).

مدل‌های رشد محصول مانند DSSAT، WOFOST و APSIM می‌توانند به‌صورت پویا فرآیندهای اساسی مانند فتوسنتز، تنفس، بیوماس و دینامیک خاک را توصیف کنند. اجرای این مدل‌ها نیازمند پارامترهای ورودی زیادی می‌باشد (آب و هوا، پارامترهای مدل و مدیریت کشاورزی) که اغلب در طی فصل رشد در مقیاس منطقه‌ای در دسترس نیستند. داده‌های سنجنش از دور می‌تواند نقش مهمی در کاهش عدم قطعیت نتایج شبیه‌سازی شده مدل در مقایسه منطقه‌ای داشته باشد (Jin et al., 2018). بنابراین وضعیت رشد محصول و عملکرد نهایی را نمی‌توان در مقیاس منطقه‌ای تنها با استفاده از مدل‌های گیاهی برآورد کرد و نیاز به استفاده از ابزارهای جانبی است. یکی از تکنیک‌های امیدوارکننده استفاده مشترک از یک مدل گیاهی با مشاهدات مزرعه‌ای یا داده‌های سنجنش از دور برای برآورد محصول است. تکنیک داده‌گذاری روشی است که به‌طور مطلوب مدل گیاهی را با داده‌های سنجنش از دور ترکیب می‌کند (Nearing et al., 2012).

Dente et al., (2008) داده‌های شاخص سطح برگ حاصل از سنجنش از دور با وضوح چندگانه را با مدل گیاهی CERES-Wheat تلفیق کردند تا پارامترهای مدل (تاریخ کشت، نقطه پژمردگی و ظرفیت زراعی خاک) دوباره راه‌اندازی شوند که نهایتاً خطای مدل را از ۴۶۰ کیلوگرم در هکتار به ۳۶۰-۴۲۰ کیلوگرم در هکتار کاهش داد. (Vazifedoust et al., 2009) یک چهارچوب داده‌گذاری را با استفاده از الگوریتم فیلترکالمن و داده‌های شاخص سطح برگ و تبخیر-تعرق حاصل از سنجنش از دور اجرا کردند. نتایج داده‌گذاری نشان داد که انحراف مقادیر برآوردی عملکرد گندم از ۳۹-۴۰٪ به کم‌تر از ۱۰٪ کاهش یافت. (Thorp et al., 2010) مقادیر شاخص سطح برگ اندازه-گیری شده را با استفاده از روش اجبار و به‌روز رسانی با مدل گیاهی DSSAT-CSM-Wheat تلفیق کردند. روش ساده داده‌گذاری آن‌ها در به حداقل رساندن خطاها در تبخیر-تعرق و وزن تاج گیاه موفق بود ولی در بهبود شبیه‌سازی عملکرد محصول با مشکل مواجه شد چرا که عملکرد محصول توسط عوامل دیگری جدا از شاخص سطح برگ کنترل می‌شود. (Ma et al., 2013) نیز شاخص سطح برگ تصحیح شده حاصل از ماهواره مودیس را با مدل گیاهی WOFOST برای اجرای مجدد تاریخ جوانه‌زنی، بیوماس اولیه و رطوبت اولیه قابل دسترس خاک و کاهش خطای RMSE برآورد عملکرد از ۹۸۳ kg/ha به ۶۶۷-۴۱۴ kg/ha تلفیق کردند.



Ines et al., (2013) برای بهبود پیش‌بینی عملکرد در مقیاس کلی یک چهارچوب مدل‌سازی گیاهی بر پایه داده‌گذاری ارائه کردند. پژوهشگران داده‌های رطوبت خاک و شاخص سطح برگ حاصل از سنجش از دور را به روش داده‌گذاری متوالی به دو شکل مستقل و هم‌زمان با مدل گیاهی ترکیب کردند. آن‌ها برای کنترل اجراهای مدل گیاهی، تلفیق داده‌های سنجش از دور و به‌روز رسانی متغیرهای حالت مدل از فیلتر کالمن مجموعه‌ای استفاده کردند. مدل گیاهی مورد استفاده آن‌ها DSSAT-CSM-Maize اصلاح شده بود. چهارچوب داده‌گذاری برای دوره سه ساله ذرت در آیوا آمریکا مورد بررسی قرار گرفت. نتایج نشان داد تلفیق داده‌های شاخص سطح برگ یا رطوبت خاک به‌طور مستقل همبستگی عملکرد محصول شبیه‌سازی شده و مشاهداتی را ($R=0.51, 0.5$) در مقایسه با شرایط بدون انجام داده‌گذاری ($R=0.47$) بهبود می‌بخشد. همبستگی عملکرد هنگامی که از داده‌های شاخص سطح برگ و رطوبت خاک به‌طور هم‌زمان برای داده‌گذاری استفاده گردید بیش‌تر بهبود یافت ($R=0.65$) و بیان‌گر رابطه علت و معلولی بین رطوبت خاک و شاخص سطح برگ است. نتایج نشان داد زمانی که شرایط مرطوب است تلفیق داده‌های شاخص سطح برگ به‌طور مستقل ترجیح داده می‌شود، در حالی که تلفیق هم‌زمان داده‌های شاخص سطح برگ و رطوبت خاک زمانی مناسب‌تر است که شرایط اسمی^۲ است. روش مورد استفاده باعث کاهش خطای RMSE به مقدار ۵۰۰ کیلوگرم در هکتار در برآورد عملکرد محصول نسبت به شرایطی که مدل بدون داده‌گذاری اجرا می‌شود، گردید.

بادیه‌نشین و همکاران (۱۳۹۳) برای بهبود برآورد عملکرد ذرت علوفه‌ای و چغندرقد در شبکه آبیاری قزوین با استفاده از مدل گیاهی SWAP از شاخص سطح برگ حاصل از داده‌های سنجش از دور استفاده کردند. نتایج نشان داد که برآورد عملکرد محصول چغندرقد و ذرت با مدل SWAP به‌روز رسانی شده با داده‌های سنجش از دور به‌ترتیب باعث بهبود ۱۳/۷ و ۱۴/۵ درصد در مقدار درصد خطا و ۳/۳ و ۱/۶ تن بر هکتار در مقدار آماره RMSE گردید. بنابراین به‌روز رسانی مدل گیاهی با استفاده از داده‌های ماهواره‌ای باعث کاهش خطاهای حاصل از داده‌های ورودی مدل و عدم قطعیت موجود در آن‌ها گردید و دقت برآورد عملکرد در سطح وسیع را افزایش داد. Chen et al., (2018) داده‌های شاخص سطح برگ و فنولوژی گیاهی حاصل از سنجش از دور را با مدل گیاهی گندم (MCWLA-Wheat) ترکیب کردند تا برآورد عملکرد گندم را در مقایسه منطقه‌ای بهبود بخشند. باتوجه به این که مقدار شاخص سطح برگ معمولاً کم برآورد می‌شود اما توزیع مکانی آن به‌خوبی با استفاده از سنجش از دور ثبت می‌گردد، لذا پژوهشگران در این تحقیق یک روش داده‌گذاری مکانی را توسعه دادند که به‌جای مقادیر مطلق شاخص سطح برگ از اختلافات مکانی آن در مدل گیاهی استفاده گردید. ابتدا اطلاعات مربوط به مراحل توسعه بحرانی گندم زمستانه از داده‌های سنجش از دور استخراج شد تا شبیه‌سازی فنولوژی توسط مدل گیاهی تنظیم گردد، سپس اختلاف مکانی شاخص سطح برگ حاصل از سنجش از دور با مدل گیاهی تلفیق گردید تا توانایی مدل برای برآورد شاخص سطح برگ و عملکرد گندم زمستانه در مقیاس منطقه‌ای بهبود یابد. در این روش نیازی به تصحیح داده‌های شاخص سطح برگ حاصل از سنجش از دور با استفاده از داده‌های اندازه‌گیری شده مزرعه‌ای با کیفیت بالا نیست. با استفاده از این روش داده‌گذاری عملکرد مدل گیاهی بهبود یافت به‌طوری که برآورد عملکرد محصول در مقیاس منطقه‌ای با دقت بالاتری ($R^2=0.42$) نسبت به حالت بدون داده‌گذاری ($R^2=0.3$) انجام شد.

Pan et al., (2019) داده‌های شاخص سطح برگ و رطوبت خاک به‌ترتیب حاصل از ماهواره سنتینل ۱ و ۲ را با مدل گیاهی WOFOST برای شبیه‌سازی عملکرد گندم زمستانه در مقیاس مزرعه‌ای و منطقه‌ای با الگوریتم فیلتر کالمن مجموعه‌ای تلفیق کردند. نتایج نشان داد که اولویت انتخاب متغیر برای داده‌گذاری شاخص سطح برگ می‌باشد و هنگامی که هر دو داده شاخص سطح برگ و رطوبت خاک در دسترس باشد داده‌گذاری مشترک عملکرد بهتری دارد چرا که این دو پارامتر دارای اثرات متقابل هستند. نتایج نشان داد که عملکرد مدل گیاهی با استفاده از داده‌گذاری مشترک به‌طور معنی‌داری در مقیاس مزرعه‌ای بهبود یافت. نسبت به شرایط بدون داده‌گذاری خطای RMSE برآورد عملکرد محصول در صورت تلفیق داده‌های شاخص سطح برگ ۶۹ kg/ha، در صورت تلفیق داده‌های رطوبت خاک ۳۹ kg/ha و در صورت تلفیق مشترک داده‌های شاخص سطح برگ و رطوبت خاک ۱۶۷ kg/ha کاهش یافت.



Hu et al., (2019) عملکرد سه روش داده‌گواری را از نظر سازگاری با مشاهدات شاخص سطح برگ و بازتولید تغییرات رطوبت خاک، رشد نیشکر و عملکرد ساقه نیشکر توسط مدل گیاهی SWAP-WOFOST مورد بررسی قرار دادند. نتایج حاکی از اهمیت انتخاب استراتژی‌های مناسب داده‌گواری بود. روش اجبار نتوانست تکامل زمانی پروفیل رطوبتی خاک را به دلیل عدم به‌روز رسانی پارامترهای خاک دقیق شبیه‌سازی کند و روش واسنجی منجر به کم‌برآورد شاخص سطح برگ قبل از برگ‌ریزی و بیش‌برآورد آن بعد از برگ‌ریزی شد. روش فیلتر کالمن مجموعه‌ای^۳ (EnKF) در برآورد رطوبت خاک، توسعه شاخص سطح برگ و عملکرد نیشکر بهترین کارایی را داشت چراکه عدم قطعیت شبیه‌سازی شده و مشاهداتی را تطبیق می‌داد. در نتیجه پژوهش انجام شده راهنمایی برای مدیریت آب مزرعه از طریق تشخیص وضعیت رطوبتی خاک و اثرات مرتبط با آن بر روی رشد نیشکر به کمک تکنیک داده‌گواری ارائه کرد.

Lu et al., (2021) یک چهارچوب داده‌گواری برای بهبود شبیه‌سازی ذرت با استفاده از مدل AquaCrop بدون واسنجی معمول پارامترها ارائه کردند. در این مطالعه مقادیر پارامترها یا از تنظیمات پیش‌فرض مدل گرفته شدند یا از طریق مقیاس‌بندی یکنواخت پارامترهای فنولوژیکی واسنجی شده برای ذرت با رقم‌های مختلف در مناطق متفاوت تعیین شدند. به‌طور کلی هدف پژوهش ارزیابی قابلیت داده-گواری برای کاهش مسئولیت واسنجی مدل و بهبود شبیه‌سازی ذرت و برآورد عملکرد با عدم قطعیت‌های موجود در پارامترها بود. نتایج نشان داد که استفاده مشترک از رطوبت خاک و پوشش تاج گیاه برای داده‌گواری، برآورد عملکرد کل را نسبت به شرایط بدون داده‌گواری بهبود و خطای RMSE در برآورد عملکرد را از ۲ ton/ha به حدود ۱/۲۴ ton/ha کاهش داد.

مدل گیاهی

محدودیت در دسترس بودن و کیفیت داده‌ها توانایی مدل‌های گیاهی را برای کمی‌سازی دقیق ناهمگونی مکانی و رشد محصول در نتیجه تاثیر آن بر دقت برآورد محصول در مقیاس منطقه‌ای به‌ویژه برای شبیه‌سازی توسعه تاج گیاه و رطوبت خاک محدود می‌کند (de Wit and van Diepen, 2007; Mignolet et al., 2007; Dente et al., 2008). شبیه‌سازی‌های منطقه‌ای می‌تواند ویژگی‌های متغیر زمانی و مکانی محصول را به کمک مدل‌های گیاهی منعکس کند اما برخی عوامل باعث ایجاد خطا می‌شوند: (۱) خطاهای ناشی از خود مدل‌های گیاهی، مدل‌ها نمی‌توانند اثرات بیماری‌های گیاهی، حشرات و آفات، برخی رخدادهای هواشناسی مانند تگرگ، باد شدید، دمای بالا و غیره را منعکس کنند. (۲) پارامترهای ژنتیکی خطاهای ارقام محصول، پارامترهای ژنتیکی در حال حاضر با روش آزمایش و خطا تعیین می‌شوند که برای برخی گونه‌های گیاهی یکسان در موقعیت‌های مکانی مختلف یا در موقعیت مکانی یکسان ولی زمان‌های مختلف نیز تفاوت‌هایی دارند. (۳) خطاهای ناشی از ادغام گونه‌ها و پارامترهای مدیریت منطقه‌ای، با توجه به میزان محدودیت داده‌های مکانی، گونه‌های ادغام شده و پارامترهای مدیریتی برای شبیه‌سازی مدیریت منطقه‌ای مورد استفاده قرار می‌گیرند. پارامترهای ادغام شده احتمالاً بهینه هستند یا نماینده گونه‌ها و پارامترهای مدیریتی منطقه هستند اما اختلاف زیادی با شرایط واقعی در منطقه دارند و نمی‌توانند تنوع گونه‌ها و مدیریت در منطقه را نشان دهند (Hansen and Jones, 2000). (۴) خطای داده‌های مکانی شامل داده‌های پارامترهای خاک، پارامترهای گیاهی، داده‌های هواشناسی، بررسی داده‌ها، پردازش داده‌ها و روش‌ها (مانند روش محاسبه رطوبت خاک، محاسبه شبکه و غیره). با توجه به تغییرات مکانی پارامترهای خاک و گیاه، اگر از داده‌های محیطی با دقت پایین برای اجرا و آزمایش مدل استفاده شود، دقت پیش‌بینی مدل تا حد زیادی کاهش می‌یابد. (۵) مدل‌های گیاهی معمولاً از آزمایش‌های نقطه‌ای حاصل شده و در مقیاس مزرعه‌ای مورد استفاده قرار می‌گیرند. فرضیات زیادی بر اساس شرایط یکنواخت رشد در مزرعه (مانند تولید محصول در شرایط پتانسیل و محدودیت آب) ایجاد می‌شوند، اما در حقیقت چندین عامل محدود کننده می‌تواند در مزرعه رخ دهد، به‌طوری‌که شرایط خارجی فراتر از شرایط مرزی محدوده موثر مدل است. این خطاهای مدل گیاهی دقت برآورد شاخص سطح برگ، بیوماس و عملکرد را در طی پردازش داده در مقیاس منطقه‌ای و جهانی تحت تاثیر قرار می‌دهد (Jin et al., 2018).

به‌منظور کاهش خطاهای مدل‌های گیاهی، روش‌های زیادی مورد استفاده قرار گرفته است که به‌شرح زیر می‌باشد: (۱) اثرات بیماری‌های گیاهی، آفات و حشرات و بلایای هواشناسی به‌منظور بهبود پاسخ رشد گیاه به بیماری‌ها و بلایای طبیعی باید در مدل‌های گیاهی اضافه

گردد. ۲) ترکیبی از روش های تجزیه و تحلیل حساسیت جهانی (مانند) و الگوریتم های بهینه سازی هوشمند (مانند زنجیره مارکوف مونت کارلو، الگوریتم ژنتیک،) برای بهینه سازی پارامترهای گیاهی مدل و بهبود دقت برآورد واسنجی و اعتبارسنجی مدل تحت شرایط محیطی مختلف (خصوصا شرایط تنش محیطی) مورد استفاده قرار گیرد. ۳) داده های سنجش از دور برای ارائه اطلاعات مکانی ویژگی های خاک، وضعیت رشد گیاه و داده های هواشناسی مورد استفاده قرار می گیرد. این اطلاعات برای افزایش دقت برآورد مدل های گیاهی در مقیاس منطقه ای در مدل ها وارد می شوند. ۴) مدل های گیاهی مختلف برای بهبود دقت شبیه سازی در مقیاس منطقه ای و جهانی توسط پروژه مقایسه و بهبود مدل های کشاورزی (AgMIP) مقایسه و ادغام خواهند شد (Jin et al., 2018).

داده های ماهواره ای

سنجش از دور تحت عنوان تابع اجبار^۴ یا فرمان شبیه سازی^۵ با مدل گیاهی تلفیق می شود. تابع اجبار متغیرهای حالت شبیه سازی شده مدل را با مشاهدات سنجش از دور جایگزین می کند، در حالی که فرمان شبیه سازی برای راه اندازی مجدد (به عنوان مثال تاریخ کشت، تراکم کشت) یا پارامتربندی کردن دوباره (به عنوان مثال پارامترهای رشد و تاج گیاه) مدل گیاهی استفاده می شود به نحوی که اختلاف بین داده های اندازه گیری شده و شبیه سازی شده را به حداقل می رساند. مثال هایی از روش فرمان شبیه سازی در کارهای تحقیقاتی پیشین دیده می شود (Ines et al., 2013). زمانی که از داده های سنجش از دور برای جایگزینی مقادیر یک متغیر حالت شبیه سازی شده توسط مدل یا استنتاج برخی ویژگی های پیوسته خاک-گیاه-اتمسفر استفاده می شود، فرض بر این است که داده های سنجش از دور عاری از خطا هستند یا این که دارای سطح خطای قابل قبول برای انتشار در مدل شبیه سازی هستند (Fang et al., 2008). در فرآیند ادغام، داده های سنجش از دور اغلب برای بهبود دقت برآورد مدل های گیاهی مورد استفاده قرار می گیرند. مزیت تکنیک های سنجش از دور این است که می تواند به طور مداوم انواع اطلاعات مفید گیاهی را در مقیاس های مکانی مختلف ارائه دهد. پایش فرآیند رشد گیاه کلید برداشت محصولات کشاورزی است، شاخص های کلیدی شامل شاخص سطح برگ، پوشش تاج گیاه، میزان کلروفیل، میزان رطوبت خاک در محدوده توسعه ریشه گیاه، میزان رطوبت موجود در پوشش تاج گیاه و عوامل تنش زا می باشد. در حال حاضر، شاخص های گیاهی حاصل از سنجش از دور به سختی می توانند الزامات مدل های گیاهی را برآورده کنند. سنجش از دور کمی با مشکلات زیادی رو به رو است از جمله مشکلات جهت، اثرات مقیاس و تبدیل مقیاس و استراتژی و روش بازایی. این عوامل بر دقت برآورد متغیرهای حالت تاج گیاه با استفاده از داده های سنجش از دور در فرآیند داده گزاری تاثیر می گذارند (Jin et al., 2018).

روش های داده گزاری

مدل های رشد محصول به طور گسترده برای توصیف فرآیند رشد محصول و پیش بینی عملکرد مورد استفاده قرار می گیرند. شبیه سازی دقیق متغیرهای حالت مانند شاخص سطح برگ (LAI) و رطوبت خاک منطقه توسعه ریشه گیاه در برآورد عملکرد محصول از اهمیت بالایی برخوردار است. داده گزاری یک تکنیک جذاب برای ترکیب یک مدل گیاهی و مشاهدات بیرونی (که اغلب از داده های سنجش از دور حاصل می شود) برای بهبود متغیرهای حالت شبیه سازی شده محصول و در نتیجه خروجی های مدل مانند بیوماس کل، آب مصرفی و عملکرد دانه است. علارغم اثربخشی این تکنیک، استفاده از روش داده گزاری برای پایش رشد محصول در مقیاس منطقه ای به دلیل نبود داده های ماهواره ای با وضوح زمانی و مکانی بالا که با اندازه کوچک مزارع کشاورزی مطابقت داشته باشد، همچنان چالش برانگیز است. امروزه با وجود تصاویر رایگان ماهواره سنتینل، امکان دستیابی به داده ها با وضوح زمانی و مکانی بالا (۱۰-۳۰ متر و ۵-۶ روز) وجود دارد که فرصت خوبی برای توصیف رشد محصول است.

به طور کلی توانایی مدل های گیاهی بستگی زیادی به در دسترس بودن پارامترهای مدل، شرایط اولیه، داده های فاکتورهای محیطی و کفایت ساختاری مدل دارد (Hu et al., 2017). تلفیق داده یا داده گزاری یک رویکرد جذاب است که با ترکیب مشاهدات با شبیه سازی

مدل به بهبود دقت مدل کمک می‌کند. رویکرد داده‌گواری سه مزیت مهم نسبت به روش‌های مدل‌سازی کلاسیک قطعی دارد. اول اینکه روش‌های داده‌گواری نیازی به واسنجی مدل از قبل ندارند که در صورت ناکافی بودن داده‌های قبلی دشوار و حتی غیرممکن است. دوم این که روش‌های داده‌گواری می‌توانند از تمامی داده‌های مستقیم و غیرمستقیم تا زمانی که با متغیرهای موردنظر در ارتباط باشند استفاده کنند (Shi et al., 2015). سوم این که برخی از روش‌های داده‌گواری قادر به تصمیم‌گیری در زمان واقعی برای مدیریت کشاورزی بر اساس داده‌های مشاهداتی تاریخی و فعلی هستند. در دهه‌های گذشته انواع مختلفی از تکنیک داده‌گواری برای برآورد عملکرد محصول توسعه یافته است که شامل دو استراتژی اصلی برای کاهش اختلاف بین داده‌های سنجش از دور و شبیه‌سازی می‌شود. این استراتژی‌ها یا از طریق راه‌اندازی مجدد و پارامترسازی مجدد با استفاده از الگوریتم‌های بهینه‌سازی (Fang et al., 2011) یا با تنظیم متغیرهای حالت مدل به‌طور مستقیم از طریق تکنیک داده‌گواری متوالی کار می‌کنند (Ma et al., 2013).

داده‌گواری متوالی یک روش مناسب برای ترکیب داده‌های سنجش از دور و مدل‌های گیاهی است تا عدم قطعیت حالت مدل‌سازی شده به حداقل رسیده و برآورد عملکرد محصول بهبود یابد چراکه داده‌گواری استفاده از اطلاعات خطا بین مدل و مشاهدات را افزایش می‌دهد. مطالعات زیادی تکنیک داده‌گواری را برای پایش رشد محصول و برآورد عملکرد مورد استفاده قرار داده‌اند از قبیل فیلتر کالمن (EnKF) به کار رفته در مدل هیدرولوژی برای پایش خشکسالی کشاورزی (Han et al., 2014)، فیلتر ذره (PF) به کار رفته در مدل DSSAT-CERES برای افزایش دقت برآورد عملکرد محصول (Li et al., 2014) و داده‌گواری وردشی چهاربعدی (4DVar) به کار رفته در مدل WOFOST برای بهبود برآورد عملکرد محصول منطقه‌ای (Huang et al., 2016). در بین الگوریتم‌های داده‌گواری روش فیلتر کالمن به دلیل سهولت اجرا، کارایی محاسباتی و عملکرد مطلوب بیش‌تر در مدل‌های گیاهی مورد استفاده قرار می‌گیرد (Wu et al., 2011). اغلب مطالعات در رابطه با داده‌گواری مدل‌های گیاهی به ترکیب یک متغیر حالت مانند شاخص سطح برگ (Fang et al., 2013; Ma et al., 2013; Wang et al., 2013; Chen et al., 2018; Kang and Ozdogan, 2019; Pan et al., 2019; Tewes et al., 2020) شاخص‌های گیاهی مختلف (Fang et al., 2008; Xie et al., 2017)، پوشش تاج گیاه نسبی (Linker and Ioslovich, 2017) برای بهبود شبیه‌سازی توسعه تاج گیاه می‌پردازند. مطالعات دیگری نیز برای بهبود شبیه‌سازی رطوبت خاک از طریق داده‌گواری مشاهدات رطوبت خاک (Zhang et al., 2020; Zhua et al., 2019; Ines et al., 2013; Chakrabarti et al., 2014; Batts et al., 2008) یا شاخص‌های رطوبت خاک (De Wit and Van Diepen, 2007)، یا بهبود شبیه‌سازی بیوماس مستقیماً از طریق داده‌گواری مشاهدات بیوماس (Betbeder et al., 2016; Linker and Isolovich, 2017; Jin et al., 2020) انجام شده است.

از بین الگوریتم‌های متعدد (مثل فیلتر ذره، فیلتر کالمن) که قادر به داده‌گواری برای به‌روز رسانی متغیرهای حالت مدل و پارامترها هستند، فیلتر کالمن مجموعه‌ای مبتنی بر مونت کارلو الگوریتمی است که به‌طور گسترده استفاده می‌شود (Evensen, 2003). فیلتر کالمن مجموعه‌ای به دلیل سهولت پیاده‌سازی، کارایی محاسباتی و عملکرد مطلوب توجه زیادی را در علوم زمین‌شناسی داشته است. مطالعات زیادی فیلتر کالمن مجموعه‌ای را برای تلفیق داده‌های سنجش از دور در مدل‌های هواشناسی و هیدرولوژیکی با موفقیت زیادی پیاده‌سازی کرده‌اند (Crow and Wood, 2003; Mohanty, 2006; Das et al., 2008; Duune and Entekhabi, 2005; Evensen, 2003).

بحث داده‌گواری اولین بار توسط چارنی و همکاران مطرح شد (Charey et al., 1969). از آن پس به تدریج در مدل‌های گردش جوی مانند پیش‌بینی عددی آب و هوا (Dee et al., 2011)، مدل‌های گردش اقیانوس (Carton and Giese, 2008) و مدل‌های سطح زمین (Yang et al., 2007) مورد استفاده قرار گرفت. به‌طور کلی هدف از داده‌گواری ادغام زمانی و مکانی متغیرهای حالت تاج گیاه با اطلاعات مختلف، با استفاده از روش‌های سنجش از دور برای بهینه‌سازی پارامترهای گیاه در مدل‌های گیاهی است. در طی فرآیند داده‌گواری ابتدا باید متغیرهای مشاهداتی (از منابع سنجش از دور)، متغیرهای حالت (از یک مدل کامل گیاهی)، پارامترهای مدل (روابط تعریف شده بین متغیرهای مشاهداتی و متغیرهای حالت) و متغیرهای خروجی (عملکرد محصول در اغلب داده‌گواری‌ها) تعیین و مشخص شود. در شکل (۱) نمای شماتیک یک سیستم داده‌گواری ارائه شده است که از یک مدل گیاهی به‌عنوان مدل پویای رشد محصول استفاده می‌شود. اولین مرحله شامل جمع‌آوری داده‌های میدانی برای بومی‌سازی یا واسنجی مدل گیاهی برای یک منطقه خاص است. باتوجه به این که مدل فقط تقریبی از فرآیندهای واقعی را شبیه‌سازی می‌کند و دارای تعداد قابل توجهی پارامتر است که اندازه‌گیری



دقیق آن‌ها دشوار می‌باشد، یک واسنجی اولیه پارامترسازی مدل را انجام می‌دهد که هدف آن سازگاری با اندازه‌گیری‌های میدانی (و عدم قطعیت آن‌ها) است. سپس مدل واسنجی شده قادر به پیش‌بینی و برآورد رشد محصول خواهد بود. پس از واسنجی، مدل بومی‌سازی شده و آماده استفاده است. اجرای مدل، پیش‌بینی تعداد زیادی از پارامترها مانند شاخص سطح برگ، رطوبت خاک، تبخیر-تعرق، بیوماس روزمینی و توسعه گیاه را ارائه می‌دهد. مشاهدات زمینی پتانسیل این را دارد که برآوردهای مستقل از این مقادیر را در مناطق وسیع ارائه دهد. روش‌های داده‌گذاری به‌دنبال بروز رسانی پیش‌بینی‌های مشخص مدل شامل شاخص سطح برگ، رطوبت خاک و غیره برای مطابقت با مشاهدات نامشخص است، به‌طوری‌که تابع چگالی احتمال پارامتر/حالت با مدل و مشاهدات سازگار باشد و تصحیحی برای تکامل مدل واسنجی‌شده با داده‌های محدود در مقیاس مزرعه ارائه می‌دهد (Huang et al., 2019).

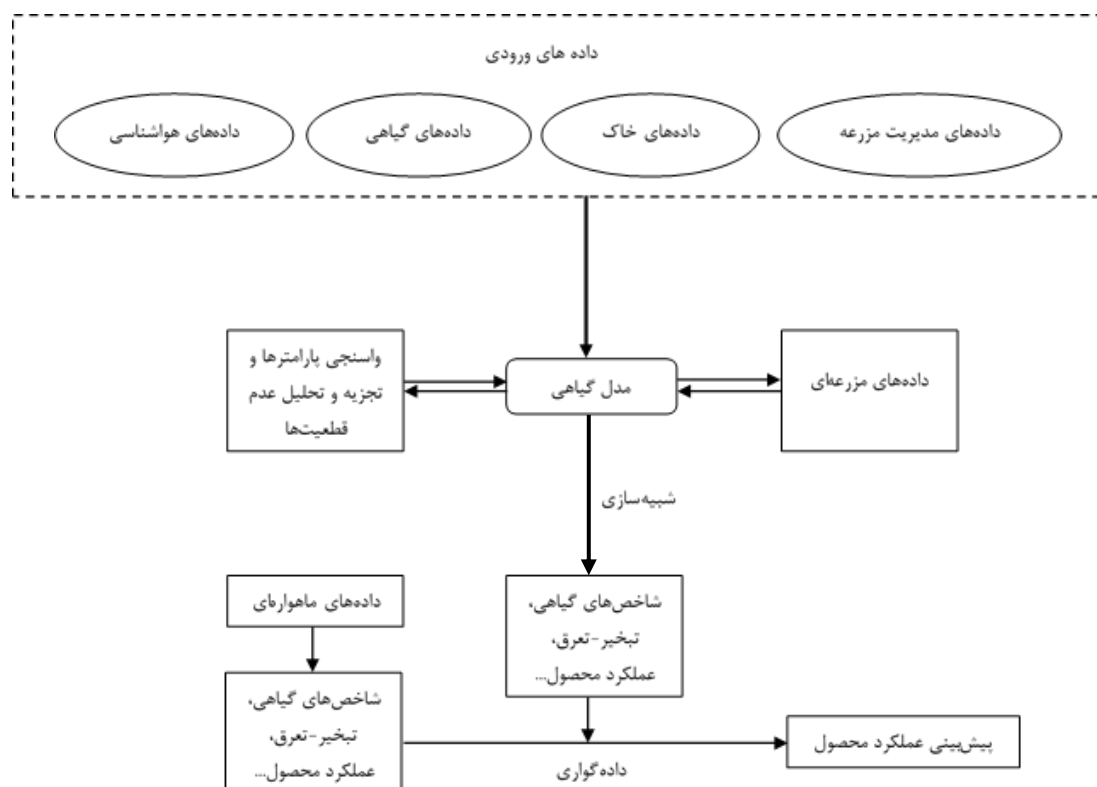
روش‌های داده‌گذاری مختلفی توسط پژوهشگران مورد استفاده قرار گرفته است از قبیل روش واسنجی، روش اجبار و روش بروز رسانی که در شکل (۲) ارائه شده است (Dorigo et al., 2007; Liang et al., 2013).

روش واسنجی

یکی از روش‌های متداول کاربردی روش واسنجی مجدد می‌باشد که گاهی اوقات به پارامترسازی مجدد^۶ و مقداردهی مجدد^۷ تفکیک می‌شود. مقادیر اولیه و پارامترهای مدل‌های گیاهی از طریق کمینه کردن یک تابع هزینه که فاصله بین متغیرهای حالت شبیه‌سازی شده و متغیرهای مشاهداتی را اندازه‌گیری می‌کند، به‌طور مکرر تغییر می‌کنند. بنابراین در این روش مجموعه جدیدی از پارامترها یا مقادیر اولیه به‌دست می‌آید بنابراین شبیه‌سازی حاصل می‌شود که بیش‌تر به مشاهدات نزدیک و همانند است. اگرچه این روش اغلب پیش‌بینی‌های عملکرد مدل را بهبود می‌بخشد اما دو نقص دارد، اول این‌که تنظیمات واسنجی مجدد ممکن است غیرواقعی باشد یا نشان‌دهنده تنظیمات یک پارامتر غیرقابل اعتماد باشد. دوم این‌که واسنجی مجدد می‌تواند از نظر محاسباتی سنگین باشد چراکه نیازمند چندین بار اجرای مجدد مدل است که کاربرد در مقیاس‌های بزرگ‌تر را با مشکل مواجه می‌کند (Wanger et al., 2020). روش واسنجی برای به حداقل رساندن اختلاف بین داده‌های سنجش از دور و داده‌های شبیه‌سازی شده مدل گیاهی با استفاده از الگوریتم‌های بهینه‌سازی استفاده می‌گردد (Jin et al., 2018).

⁶. Re-parameterization

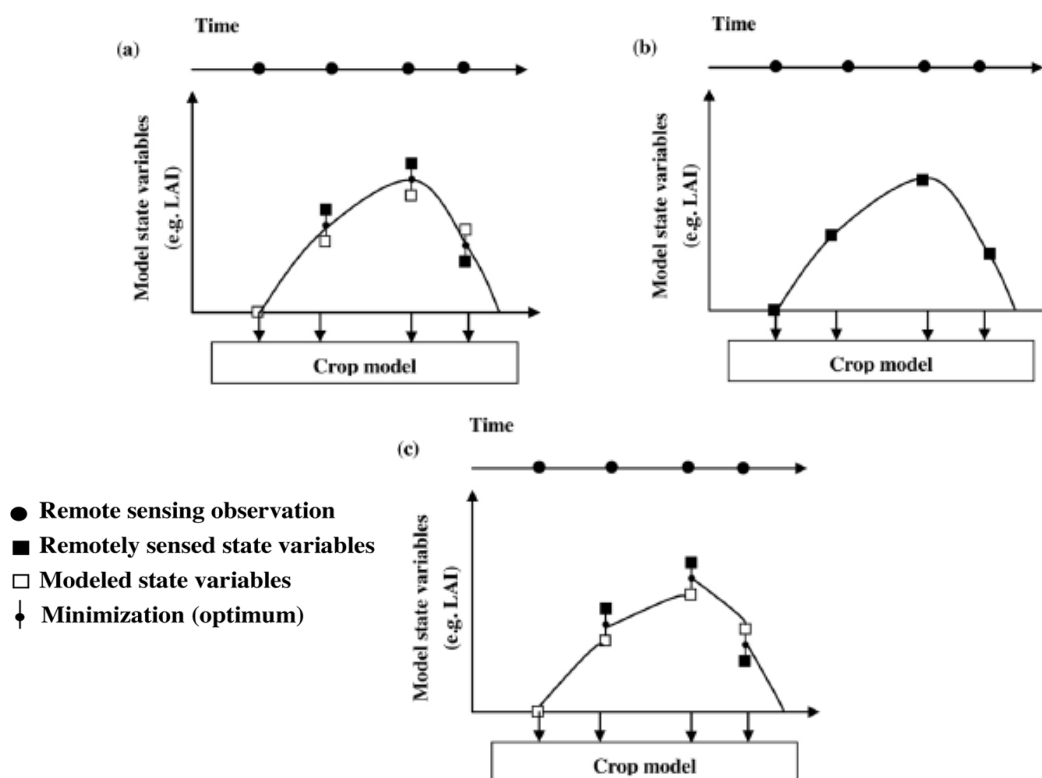
¹¹. Re-initialization



شکل ۱. نمای شماتیک از یک سیستم داده گواری معمول.

روش اجبار

روش های اجبار از داده های سنجش از دور برای جایگزینی داده های شبیه سازی شده توسط مدل استفاده می کنند. داده های سنجش از دور مستقیماً برای تعیین داده های شبیه سازی شده مدل مورد استفاده قرار می گیرند که نیازمند امکان پذیر بودن داده های سنجش از دور در هر گام زمانی مدل گیاهی است که در اکثر مدل ها روزانه، هفتگی یا ماهانه است. در شرایط عادی دوره زمانی عبور ماهواره کم تر از گام زمانی اجرای مدل است. برای به دست آوردن داده های سنجش از دور در گام زمانی مشابه با مدل گیاهی، درون یابی خطی، تبدیل سریع فوری و روش های wavelet استفاده می شود تا شکاف بین داده های مشاهداتی سنجش از دور را پر کنند. شاخص سطح برگ حاصل از سنجش از دور عمدتاً به عنوان متغیر حالت در مدل های گیاهی به کار می رود. پژوهشگران زیادی مقادیر شاخص سطح برگ را با استفاده از داده های مختلف سنجش از دور برآورد کرده و نتایج شبیه سازی مدل های گیاهی مستقیماً توسط شاخص سطح برگ برآورد شده جایگزین می شود تا شاخص سطح برگ شبیه سازی شده، بیوماس و عملکرد محصول یا تعرق گیاه توسط مدل بهبود یابد (Hadria et al., 2006; Throp et al., 2010; Tripathy et al., 2013; Yao et al., 2015).



شکل ۲. نمای شماتیکی از روش‌های مختلف داده‌گذاری برای متغیرهای حالت مدل گیاهی حاصل از داده‌های سنجش از دور: (a) واسنجی مدل گیاهی (b) روش‌های اجبار (c) روش‌های به‌روز رسانی (Jin et al., 2018).

بر اساس روش اجبار، داده‌گذاری مدل گیاهی و سنجش از دور آسان است اما به‌طور دقیق روش‌های داده‌گذاری را شامل نمی‌شود. متغیرهای حالت شبیه‌سازی شده یا داده‌های ورودی اولیه مدل گیاهی با متغیرهای حالت برآورد شده یا داده‌های اولیه ورودی سنجش از دور جایگزین می‌شوند. سنجش از دور متغیرهای حالت را با دقت بالا ارائه می‌دهد و نتایج حاصل خوب می‌باشد (Jin et al., 2018). این روش بسیار کارآمد و آسان است اما چندین اشکال دارد. اول اینکه برای هر مرحله شبیه‌سازی نیاز به داده‌های اندازه‌گیری می‌باشد (مثلاً مشاهدات روزانه) که اغلب در دسترس نیستند یا نیاز به درون‌یابی دارند. هنگام تلفیق داده‌های سنجش از دور نوری، پوشش مکرر ابر می‌تواند تعداد مشاهدات موجود را به‌شدت کاهش دهد حتی با زمان گذر کوتاه‌تر مانند سنتینل ۲. دوما روش اجبار حلقه شبیه‌سازی را موثرتر تجزیه می‌کند چراکه نتایج واسط را با ورودی‌های خارجی جایگزین می‌کند (Rembold et al., 2013). سوماً عدم قطعیت داده‌های اندازه‌گیری شده را در نظر نمی‌گیرد و بنابراین مستقیماً خطاها را به مدل منتقل می‌کند. باتوجه به این اشکالات، مطالعات کم‌تری اخیراً از این روش استفاده می‌کنند (Wanger et al., 2020).

روش به‌روز رسانی

روش به‌روز رسانی در طی شبیه‌سازی فرآیند داده‌گذاری را فقط در صورت وجود مشاهدات انجام می‌دهد. بنابراین حتی در صورت وجود مشاهدات اندک و نادر نیز به‌خوبی عمل می‌کند و زمان پردازش را در مقایسه با روش واسنجی کاهش می‌دهد. علاوه بر این روش به‌روز رسانی اجازه می‌دهد تا عدم قطعیت در شبیه‌سازی و داده‌های ادغام شده مورد بررسی قرار گیرد (Dorigo et al., 2007). این روش بر این فرضیه استوار است که داده‌های شبیه‌سازی بهتر در روز t باعث افزایش دقت داده‌های شبیه‌سازی شده در روز بعد می‌شود. روش به‌روز رسانی معمولاً داده‌گذاری نامیده می‌شود و الگوریتم‌های زیادی برای تلفیق داده‌های سنجش از دور و مدل‌های گیاهی استفاده می‌-



شود (Jin et al., 2018). در روش اجبار، مدل های گیاهی اطلاعات خود را استفاده نمی کنند ولی متغیرهای حالت مشاهده شده را دنبال می کنند که شامل برخی خطاها می باشد. داده های سنجنش از دور دارای خطاهایی هستند که در صورت داده گواری با روش اجبار این خطاها به مدل گیاهی وارد می شوند. روش های واسنجی و به روز رسانی انعطاف پذیری بیش تری دارند و خطاهای کمینه سازی آن ها هنگام استفاده از داده های سنجنش از دور وارد مدل گیاهی می شود. در روش بهینه سازی امید است که پارامترهای گیاهی و روی زیادی به مدل وارد شوند و دقت برآورد مدل را بهبود بخشند (Nouvellon et al., 2001).

در مقایسه با روش های اجبار و به روز رسانی، از نظر تئوری روش واسنجی بهتر می باشد اما اشکال اصلی این روش این نیازمند تکرارهای بهینه سازی زیادی است که در نتیجه زمان محاسبات را بیش تر می کند. در مقایسه با روش واسنجی، روش به روز رسانی زمان محاسبات را به میزان قابل توجهی کاهش می دهد زیرا فقط مدل گیاهی اجرا می شود. با این حال این روش نیز دارای اشکال است زیرا به گران ترین عدم قطعیت محاسبات و اندازه گیری نیاز دارد. هم چنین روش به روز رسانی نیازمند تنظیم متغیرهای پارامتر مدل هنگام اجرای مدل گیاهی می باشد (Walker et al., 2001).

نتیجه گیری

برآورد به موقع و دقیق وضعیت رشد محصول امکان تصمیم گیری درمورد مدیریت های مزرعه را فراهم می کند. برآورد عملکرد محصول توسط مدل های گیاهی همراه با عدم قطعیت هایی است که ناشی از تنوع زیاد پارامترهای ورودی، استفاده از فرضیات ساده سازی در فرآیند مدل سازی، مقیاس زمانی و مکانی مورد استفاده، تنوع بیولوژیکی، تغییرات اقلیمی و تصمیمات مدیریتی می باشد. بنابراین برآیند عدم قطعیت های موجود در مدل باعث بروز خطا و کاهش دقت نتایج خروجی مدل خواهد شد. امروزه محققان برای کاهش عدم قطعیت مدل های گیاهی و افزایش دقت خروجی مدل ها استفاده از روش تلفیق داده های سنجنش از دور با مدل های گیاهی را پیشنهاد می کنند. به عبارتی داده های سنجنش از دور با ایجاد با فراهم کردن داده های مشاهداتی پیوسته از سطح زمین در طول دوره رشد گیاه مانند شاخص سطح برگ یا رطوبت لایه سطحی خاک باعث افزایش دقت برآورد عملکرد محصول توسط مدل گیاهی می شوند. با تلفیق ویژگی وضوح مکانی و زمانی بالای داده های حاصل از تصاویر ماهواره ای و قابلیت تخمین عملکرد محصول در مدل های گیاهی، تصمیم گیرندگان می توانند به درک جامع و دقیقی از پویایی رشد محصول، عوامل تنش زا و پیش بینی عملکرد با دقت بالا دست یابند. استفاده از این رویکرد تلفیقی نه تنها قابلیت اطمینان شبیه سازی ها و پیش بینی ها را افزایش می دهد بلکه امکان استفاده از استراتژی های مدیریتی دقیق را نیز فراهم می کند که می تواند منجر به استفاده بهینه از منابع آب و خاک، کشاورزی پایدار، انعطاف پذیری در برابر تغییرات اقلیم، افزایش بهره وری و امنیت غذایی گردد. در این راستا در مطالعه حاضر به معرفی سه روش مختلف تلفیق داده های سنجنش از دور با مدل های رشد گیاهی شامل روش واسنجی، روش اجبار و روش بروز رسانی و مزایا و معایب هر روش پرداخته شد.

منابع

۱. مهرپرور، م.، گل محمدی، م. و اصغری، ک. (۲۰۱۹). کاهش خطای شبیه سازی فرآیند بارش-رواناب با بکارگیری تکنیک داده گواری در مدل هیدرولوژیکی SWAT. تحقیقات منابع آب ایران. ۱۴(۵): ۸۵-۱۰۲.
۲. بادیه نشین، ع.، نوری، ح. و وظیفه دوست، م. (۱۳۹۳). بهبود برآورد عملکرد محصول در مدل شبیه سازی SWAP با استفاده از داده های ماهواره ای. تحقیقات آب و خاک ایران. ۴۵(۴): ۳۷۹-۳۸۸.
3. Batts, C., & Kaleita, A. L. (2008). Data assimilation of near-surface in-situ soil moisture using the DSSAT crop model. In 2008 Providence, Rhode Island, June 29–July 2, 2008 (p. 1). American Society of Agricultural and Biological Engineers.
4. Betbeder, J., Fieuzal, R., & Baup, F. (2016). Assimilation of LAI and dry biomass data from optical and SAR images into an agro-meteorological model to estimate soybean yield. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 9(6), 2540-2553.
5. Boote, K. (2019). Advances in crop modelling for a sustainable agriculture. Burleigh Dodds Science Publishing.
6. Boote, K. J., Jones, J. W., White, J. W., Asseng, S., & Lizaso, J. I. (2013). Putting mechanisms into crop production models. Plant, cell & environment, 36(9), 1658-1672.

7. Carton, J. A., & Giese, B. S. (2008). A reanalysis of ocean climate using Simple Ocean Data Assimilation (SODA). *Monthly weather review*, 136(8), 2999-3017.
8. Chakrabarti, S., Bongiovanni, T., Judge, J., Zotarelli, L., & Bayer, C. (2014). Assimilation of SMOS soil moisture for quantifying drought impacts on crop yield in agricultural regions. *IEEE journal of selected topics in applied earth observations and remote sensing*, 7(9), 3867-3879.
9. Chen, Y., Zhang, Z., & Tao, F. (2018). Improving regional winter wheat yield estimation through assimilation of phenology and leaf area index from remote sensing data. *European Journal of Agronomy*, 101, 163-173.
10. Crow, W. T., & Wood, E. F. (2003). The assimilation of remotely sensed soil brightness temperature imagery into a land surface model using ensemble Kalman filtering: A case study based on ESTAR measurements during SGP97. *Advances in Water Resources*, 26(2), 137-149.
11. Das, N. N., Mohanty, B. P., Cosh, M. H., & Jackson, T. J. (2008). Modeling and assimilation of root zone soil moisture using remote sensing observations in Walnut Gulch Watershed during SMEX04. *Remote Sensing of Environment*, 112(2), 415-429.
12. De Wit, A. D., & Van Diepen, C. A. (2007). Crop model data assimilation with the Ensemble Kalman filter for improving regional crop yield forecasts. *Agricultural and Forest Meteorology*, 146(1-2), 38-56.
13. Dee, D. P., Uppala, S. M., Simmons, A. J., Berrisford, P., Poli, P., Kobayashi, S., ... & Vitart, F. (2011). The ERA-Interim reanalysis: Configuration and performance of the data assimilation system. *Quarterly Journal of the royal meteorological society*, 137(656), 553-597.
14. Dente, L., Satalino, G., Mattia, F., & Rinaldi, M. (2008). Assimilation of leaf area index derived from ASAR and MERIS data into CERES-Wheat model to map wheat yield. *Remote sensing of Environment*, 112(4), 1395-1407.
15. Dorigo, W. A., Zurita-Milla, R., de Wit, A. J., Brazile, J., Singh, R., & Schaepman, M. E. (2007). A review on reflective remote sensing and data assimilation techniques for enhanced agroecosystem modeling. *International journal of applied earth observation and geoinformation*, 9(2), 165-193.
16. Evensen, G. (2003). The ensemble Kalman filter: Theoretical formulation and practical implementation. *Ocean dynamics*, 53(4), 343-367.
17. Fang, H., Liang, S., & Hoogenboom, G. (2011). Integration of MODIS LAI and vegetation index products with the CSM-CERES-Maize model for corn yield estimation. *International Journal of Remote Sensing*, 32(4), 1039-1065.
18. Fang, H., Liang, S., Hoogenboom, G., Teasdale, J., & Cavigelli, M. (2008). Corn-yield estimation through assimilation of remotely sensed data into the CSM-CERES-Maize model. *International Journal of Remote Sensing*, 29(10), 3011-3032.
19. FAO, 2017. *Aquacrop Update and New Features: Version 6.0*. Food and Agriculture Organization of the United Nations, Rome, Italy.
20. Franch, B., Vermote, E. F., Becker-Reshef, I., Claverie, M., Huang, J., Zhang, J., ... & Sobrino, J. A. (2015). Improving the timeliness of winter wheat production forecast in the United States of America, Ukraine and China using MODIS data and NCAR Growing Degree Day information. *Remote Sensing of Environment*, 161, 131-148.
21. Gupta, H. V., Beven, K. J., & Wagener, T. (2006). Model calibration and uncertainty estimation. *Encyclopedia of hydrological sciences*.
22. Hadria, R., Duchemin, B., Lahrouni, A., Khabba, S., Er-Raki, S., Dedieu, G., ... & Oliso, A. (2006). Monitoring of irrigated wheat in a semi-arid climate using crop modelling and remote sensing data: Impact of satellite revisit time frequency. *International Journal of Remote Sensing*, 27(6), 1093-1117.
23. Han, E., Crow, W. T., Holmes, T., & Bolten, J. (2014). Benchmarking a soil moisture data assimilation system for agricultural drought monitoring. *Journal of Hydrometeorology*, 15(3), 1117-1134.
24. Hansen, J. W., & Jones, J. W. (2000). Scaling-up crop models for climate variability applications. *Agricultural Systems*, 65(1), 43-72.
25. Holzworth, D. P., Snow, V., Janssen, S., Athanasiadis, I. N., Donatelli, M., Hoogenboom, G., ... & Thorburn, P. (2015). Agricultural production systems modelling and software: current status and future prospects. *Environmental Modelling & Software*, 72, 276-286.
26. Hsiao, T. C., Heng, L., Steduto, P., Rojas-Lara, B., Raes, D., & Fereres, E. (2009). AquaCrop—the FAO crop model to simulate yield response to water: III. Parameterization and testing for maize. *Agronomy Journal*, 101(3), 448-459.
27. Hu, S., Shi, L., Huang, K., Zha, Y., Hu, X., Ye, H., & Yang, Q. (2019). Improvement of sugarcane crop simulation by SWAP-WOFOST model via data assimilation. *Field Crops Research*, 232, 49-61.
28. Hu, S., Shi, L., Zha, Y., Williams, M., & Lin, L. (2017). Simultaneous state-parameter estimation supports the evaluation of data assimilation performance and measurement design for soil-water-atmosphere-plant system. *Journal of Hydrology*, 555, 812-831.
29. Hu, T., Su, Y., Xue, B., Liu, J., Zhao, X., Fang, J., & Guo, Q. (2016). Mapping global forest aboveground biomass with spaceborne LiDAR, optical imagery, and forest inventory data. *Remote Sensing*, 8(7), 565.



30. Huang, J., Gómez-Dans, J. L., Huang, H., Ma, H., Wu, Q., Lewis, P. E., ... & Xie, X. (2019). Assimilation of remote sensing into crop growth models: Current status and perspectives. *Agricultural and forest meteorology*, 276, 107609.
31. Huang, J., Sedano, F., Huang, Y., Ma, H., Li, X., Liang, S., ... & Wu, W. (2016). Assimilating a synthetic Kalman filter leaf area index series into the WOFOST model to improve regional winter wheat yield estimation. *Agricultural and Forest Meteorology*, 216, 188-202.
32. Ines, A. V., Das, N. N., Hansen, J. W., & Njoku, E. G. (2013). Assimilation of remotely sensed soil moisture and vegetation with a crop simulation model for maize yield prediction. *Remote Sensing of Environment*, 138, 149-164.
33. IPCC, (2018). Summary for policymakers. In: Masson-Delmotte, V., Zhai, P., Pörtner, H.-O., Roberts, D., Skea, J., Shukla, P., Pirani, A., Moufouma-Okia, W., Péan, C., Pidcock, R., Connors, S., Matthews, J., Chen, Y., Zhou, X., Gomis, M., Lonnoy, E., Maycock, T., Tignor, M., Waterfield, T. (Eds.), *Global Warming of 1.5 °C. An IPCC Special Report on the impacts of global warming of 1.5 °C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty*. World Meteorological Organization, Geneva, Switzerland 32 pp.
34. Jin, X., Kumar, L., Li, Z., Feng, H., Xu, X., Yang, G., & Wang, J. (2018). A review of data assimilation of remote sensing and crop models. *European Journal of Agronomy*, 92, 141-152.
35. Jin, X., Li, Z., Feng, H., Ren, Z., & Li, S. (2020). Estimation of maize yield by assimilating biomass and canopy cover derived from hyperspectral data into the AquaCrop model. *Agricultural Water Management*, 227, 105846.
36. Jones, J. W., Hoogenboom, G., Porter, C. H., Boote, K. J., Batchelor, W. D., Hunt, L. A., ... & Ritchie, J. T. (2003). The DSSAT cropping system model. *European journal of agronomy*, 18(3-4), 235-265.
37. Kang, Y., & Özdoğan, M. (2019). Field-level crop yield mapping with Landsat using a hierarchical data assimilation approach. *Remote Sensing of Environment*, 228, 144-163.
38. Knyazikhin, Y., Martonchik, J. V., Myneni, R. B., Diner, D. J., & Running, S. W. (1998). Synergistic algorithm for estimating vegetation canopy leaf area index and fraction of absorbed photosynthetically active radiation from MODIS and MISR data. *Journal of Geophysical Research: Atmospheres*, 103(D24), 32257-32275.
39. Li, Y., Zhou, Q., Zhou, J., Zhang, G., Chen, C., & Wang, J. (2014). Assimilating remote sensing information into a coupled hydrology-crop growth model to estimate regional maize yield in arid regions. *Ecological modelling*, 291, 15-27.
40. Liang, S., & Qin, J. (2008). Data assimilation methods for land surface variable estimation. In *Advances in Land Remote Sensing* (pp. 313-339). Springer, Dordrecht.
41. Liang, S., Li, X., & Xie, X. (2013). *Land surface observation, modeling and data assimilation*. World Scientific.
42. Linker, R., & Ioslovich, I. (2017). Assimilation of canopy cover and biomass measurements in the crop model AquaCrop. *Biosystems engineering*, 162, 57-66.
43. Lu, Y., Chibarabada, T. P., Ziliani, M. G., Onema, J. M. K., McCabe, M. F., & Sheffield, J. (2021). Assimilation of soil moisture and canopy cover data improves maize simulation using an under-calibrated crop model. *Agricultural Water Management*, 252, 106884.
44. Ma, H., Huang, J., Zhu, D., Liu, J., Su, W., Zhang, C., & Fan, J. (2013). Estimating regional winter wheat yield by assimilation of time series of HJ-1 CCD NDVI into WOFOST-ACRM model with Ensemble Kalman Filter. *Mathematical and Computer Modelling*, 58(3-4), 759-770.
45. Marin, F., Jones, J. W., & Boote, K. J. (2017). A stochastic method for crop models: including uncertainty in a sugarcane model. *Agronomy Journal*, 109(2), 483-495.
46. Mignolet, C., Schott, C., & Benoît, M. (2007). Spatial dynamics of farming practices in the Seine basin: Methods for agronomic approaches on a regional scale. *Science of the total environment*, 375(1-3), 13-32.
47. Mu, Q., Heinsch, F. A., Zhao, M., & Running, S. W. (2007). Development of a global evapotranspiration algorithm based on MODIS and global meteorology data. *Remote sensing of Environment*, 111(4), 519-536.
48. Nearing, G. S., Crow, W. T., Thorp, K. R., Moran, M. S., Reichle, R. H., & Gupta, H. V. (2012). Assimilating remote sensing observations of leaf area index and soil moisture for wheat yield estimates: An observing system simulation experiment. *Water Resources Research*, 48(5).
49. Nouvellon, Y., Moran, M. S., Seen, D. L., Bryant, R., Rambal, S., Ni, W., ... & Qi, J. (2001). Coupling a grassland ecosystem model with Landsat imagery for a 10-year simulation of carbon and water budgets. *Remote Sensing of Environment*, 78(1-2), 131-149.
50. Pan, H., Chen, Z., de Wit, A., & Ren, J. (2019). Joint assimilation of leaf area index and soil moisture from Sentinel-1 and Sentinel-2 data into the WOFOST model for winter wheat yield estimation. *Sensors*, 19(14), 3161.
51. Rembold, F., Atzberger, C., Savin, I., & Rojas, O. (2013). Using low resolution satellite imagery for yield prediction and yield anomaly detection. *Remote Sensing*, 5(4), 1704-1733.
52. Seidel, S. J., Palosuo, T., Thorburn, P., & Wallach, D. (2018). Towards improved calibration of crop models—Where are we now and where should we go?. *European Journal of Agronomy*, 94, 25-35.

53. Shi, L., Song, X., Tong, J., Zhu, Y., & Zhang, Q. (2015). Impacts of different types of measurements on estimating unsaturated flow parameters. *Journal of Hydrology*, 524, 549-561.
54. Tewes, A., Montzka, C., Nolte, M., Krauss, G., Hoffmann, H., & Gaiser, T. (2020). Assimilation of sentinel-2 estimated LAI into a crop model: Influence of timing and frequency of acquisitions on simulation of water stress and biomass production of winter wheat. *Agronomy*, 10(11), 1813.
55. Thorp, K. R., Hunsaker, D. J., & French, A. N. (2010). Assimilating leaf area index estimates from remote sensing into the simulations of a cropping systems model. *Transactions of the ASABE*, 53(1), 251-262.
56. Tripathy, R., Chaudhari, K. N., Mukherjee, J., Ray, S. S., Patel, N. K., Panigrahy, S., & Parihar, J. S. (2013). Forecasting wheat yield in Punjab state of India by combining crop simulation model WOFOST and remotely sensed inputs. *Remote sensing letters*, 4(1), 19-28.
57. Vazifedoust, M., Van Dam, J. C., Bastiaanssen, W. G. M., & Feddes, R. A. (2009). Assimilation of satellite data into agrohydrological models to improve crop yield forecasts. *International Journal of Remote Sensing*, 30(10), 2523-2545.
58. Waha, K., Huth, N., Carberry, P., & Wang, E. (2015). How model and input uncertainty impact maize yield simulations in West Africa. *Environmental Research Letters*, 10(2), 024017.
59. Walker, J. P., Willgoose, G. R., & Kalma, J. D. (2001). One-dimensional soil moisture profile retrieval by assimilation of near-surface observations: a comparison of retrieval algorithms. *Advances in Water Resources*, 24(6), 631-650.
60. Wang, J., Li, X., Lu, L., & Fang, F. (2013). Estimating near future regional corn yields by integrating multi-source observations into a crop growth model. *European journal of Agronomy*, 49, 126-140.
61. Whitcraft, A. K., Vermote, E. F., Becker-Reshef, I., & Justice, C. O. (2015). Cloud cover throughout the agricultural growing season: Impacts on passive optical earth observations. *Remote sensing of Environment*, 156, 438-447.
62. Wu, S., Huang, J., Liu, X., Fan, J., Ma, G., & Zou, J. (2011, October). Assimilating MODIS-LAI into crop growth model with EnKF to predict regional crop yield. In *International Conference on Computer and Computing Technologies in Agriculture* (pp. 410-418). Springer, Berlin, Heidelberg.
63. Xie, Y., Wang, P., Bai, X., Khan, J., Zhang, S., Li, L., & Wang, L. (2017). Assimilation of the leaf area index and vegetation temperature condition index for winter wheat yield estimation using Landsat imagery and the CERES-Wheat model. *Agricultural and Forest Meteorology*, 246, 194-206.
64. Yang, K., Watanabe, T., Koike, T., Li, X., Fujii, H., Tamagawa, K., ... & Ishikawa, H. (2007). Auto-calibration system developed to assimilate AMSR-E data into a land surface model for estimating soil moisture and the surface energy budget. *Journal of the Meteorological Society of Japan. Ser. II*, 85, 229-242.
65. Yang, W., Tan, B., Huang, D., Rautiainen, M., Shabanov, N. V., Wang, Y., ... & Myneni, R. B. (2006). MODIS leaf area index products: From validation to algorithm improvement. *IEEE Transactions on Geoscience and Remote Sensing*, 44(7), 1885-1898.
66. Yao, F., Tang, Y., Wang, P., & Zhang, J. (2015). Estimation of maize yield by using a process-based model and remote sensing data in the Northeast China Plain. *Physics and Chemistry of the Earth, Parts A/B/C*, 87, 142-152.
67. Zhang, Z., Li, Z., Chen, Y., Zhang, L., & Tao, F. (2020). Improving regional wheat yields estimations by multi-step-assimilating of a crop model with multi-source data. *Agricultural and Forest Meteorology*, 290, 107993.

Estimation of crop yield using the integration of remote sensing data and crop growth model

Sanaz Mohammadi^{1*}, Iman Hajirad²

1. PhD, Water Management and Engineering Department, Collage of Agriculture, Tarbiat Modares University, Tehran, Iran,
2. Ph.D. Candidate, Department of Irrigation and Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran,

Abstract

Forecasting crop yield at the regional scale is very important in terms of crop management, agricultural monitoring, food safety assessment at the national level, and food policy. In recent years, the importance of crop growth monitoring and crop yield prediction on a large scale has been highlighted because accurate information about crop growth and yield is essential for timely response to climate change risks, food security assessment, and the strategic development of appropriate food business. Crop growth models contain several input parameters that must be updated according to the characteristics of the study area. Usually, the lack of access to these parameters and the presence of uncertainty in them lead to errors in the results of crop growth models. Researches have shown that the integration of crop growth models and remote sensing data can be the most effective method to increase the accuracy of crop yield estimation. In this study, different methods of combining remote sensing data and crop growth models, and the advantages and disadvantages of each are examined. The results of various research studies have shown that the use of remote sensing data such as leaf area index or soil moisture improves the accuracy of crop yield estimation by models.

Keywords: Yield Forecasting, Crop Growth, Uncertainty, Satellite