

# پایش محصولات زراعی با استفاده از تصاویر پلاریمتریک اینترفرومتریک سار

مریم صالحی<sup>۱</sup>، علی محمدزاده<sup>۲\*</sup>، یاسر مقصودی<sup>۳</sup>

<sup>۱</sup> دانشجوی دکتری سنجش از دور - دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی  
msalehi@mail.kntu.ac.ir

<sup>۲</sup> دانشیار دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی  
almoh2@gmail.com

<sup>۳</sup> استادیار دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی  
ymagsoudi@kntu.ac.ir

(تاریخ دریافت اسفند ۱۳۹۶، تاریخ تصویب اردیبهشت ۱۳۹۷)

## چکیده

افزایش تولید محصولات کشاورزی با توجه به شرایط آب و هوایی، محدودیت منابع آبی و نیز محدودیت زمین‌های دارای پتانسیل تولید، همچنین محدودیت‌های مالی در کشور با مشکلات فراوانی روبرو می‌باشد. بنابراین برای تأمین مواد غذایی باید بهره‌وری از عوامل تولید به ویژه آب و خاک افزایش و ضایعات کشاورزی تا حد امکان کاهش یابد. این امر نیازمند پایش منظم محصولات می‌باشد. سنجش از دور یکی از مهمترین تکنیک‌های مورد استفاده در پایش محصولات کشاورزی محسوب می‌شود. امروزه توسعه روش‌های پایش در مقیاس وسیع، مساله‌ای مهم برای اجرای مدیریتی معقول و منطقی در ارتباط با منابع طبیعی زمین بویژه برای کشورهای پرجمعیت که متکی به محصولات کشاورزی هستند، به شمار می‌رود. هدف از این تحقیق پایش و بازیابی برخی پارامترهای محصولات کشاورزی با استفاده از تصاویر پلاریمتریک اینترفرومتریک سار (PolInSAR) می‌باشد. روش مورد استفاده بر مبنای ویژگی‌هایی حاصل از مدل تجزیه پیشنهادی و روش‌های رگرسیون مینا می‌باشد. در مدل پیشنهادی ابتدا پایه پلاریزاسیون بهینه که در آن همبستگی بین دو تصویر پایه و پیرو بیشینه است محاسبه می‌شود، سپس در آن پایه تجزیه مقدار ویژه بر روی ماتریس کواریانس پلاریمتریک اینترفرومتریک اعمال شده، و با بدست آوردن مقادیر و بردارهای ویژه ویژگی‌هایی همانند انترپوی و آلفا محاسبه می‌شود. برخی از این ویژگی‌ها وابستگی خطی بالایی با ارتفاع، زیست‌توده و فنولوژی محصولات دارند و برخی نیز اطلاعات مفیدی برای بهبود عملکرد بازیابی فراهم می‌آورند. نهایتاً بازیابی پارامترهای محصول براساس ۱۳ ویژگی PolInSAR و دو روش شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان انجام می‌شود. نتایج پیاده‌سازی بر روی دو محصول گندم و جو با استفاده از تصاویر سری زمانی سنجنده E-SAR از منطقه DEMMIN در آلمان نشان‌دهنده عملکرد مناسب روش پیشنهادی می‌باشد. هر دو روش مورد استفاده به منظور بازیابی نهایی شامل شبکه عصبی و رگرسیون بردار پشتیبان برآوردهای خوبی از پارامترهای محصول داشته و می‌توانند برای پایش محصولات مورد استفاده قرار گیرند. به عنوان نمونه نتایج نشانگر جذر میانگین مربعات خطا (RMSE) ۰/۲۱، ۰/۵۹ و ۰/۲۱. با استفاده از شبکه عصبی و جذر میانگین مربعات خطا (RMSE) ۰/۲۱، ۰/۵۲ و ۰/۴۶. با استفاده از رگرسیون بردار پشتیبان به ترتیب در بازیابی ارتفاع، زیست‌توده و فنولوژی محصول گندم می‌باشد.

**واژگان کلیدی:** پایش محصول، بازیابی پارامتر، داده سری زمانی، پلاریمتریک اینترفرومتریک، مقدار ویژه

## ۱- مقدمه

بدون شک اهمیت غذا و امنیت غذایی به عنوان یکی از چالش‌های عصر حاضر و آینده بر کسی پوشیده نیست. افزایش جمعیت جهان و افزایش قیمت غذا، توسعه بیشتر فقر و گرسنگی را به دنبال دارد. فراهم کردن محصولات غذایی و همچنین محصولات غیر غذایی کافی و با کیفیت و هزینه مناسب برای این جمعیت و جلوگیری از مهاجرت به شهرها، اقداماتی مانند افزایش بازدهی محصولات کشاورزی از زمین‌های کوچکتر با بکارگیری تکنولوژی‌های پیشرفته را می‌طلبد. علاوه بر این، پایش محصولات کشاورزی شامل پایش مراحل رشد و مشاهده وضعیت آنها، ضروری می‌باشد و برای کشاورزان امکان انجام صحیح فعالیت‌های زراعی را در طول فصل رشد فراهم می‌آورد. در راستای چنین اهدافی بود که دانشمندان، کشاورزی دقیق [۱] را به عنوان یکی از نوین‌ترین راهکارها در مدیریت مزارع مطرح کردند تا با ایجاد شیوه‌های نوین علاوه بر بهینه‌سازی مصرف نهاده‌های تولید محصول (کودها و مواد شیمیایی) و حفظ محیط زیست و منابع انرژی (منابع آبی و ...)، عملکرد را نیز افزایش داده و در نهایت بازده اقتصادی را بالا ببرند.

سنجش از دور یکی از مهمترین تکنیک‌های مورد استفاده در کشاورزی دقیق در پایش پوشش گیاهی سطح زمین محسوب می‌شود. پایش محصولات کشاورزی با بکارگیری روش‌های سنجش از دوری به علت اثرات اقتصادی و اجتماعی آنها با اهمیت می‌باشد. امروزه توسعه روش‌های پایش محصولات کشاورزی در مقیاس وسیع، مساله‌ای مهم برای اجرای مدیریتی معقول و منطقی در ارتباط با منابع طبیعی زمین بویژه برای کشورهای پرجمعیت که متکی به محصولات کشاورزی هستند، به شمار می‌رود.

توانایی سنجنده‌های پلاریمتریک سار (PolSAR)<sup>۱</sup> نسبت به سایر سنجنده‌های راداری و همچنین سنجنده‌های نوری برای فراهم کردن تصاویر در کانال‌های پلاریزاسیون مختلف با دقت مکانی بالا و پوشش وسیع، قابلیت نفوذ، حساسیت به زبری و رطوبت، و تصویربرداری در روز و شب و تمام شرایط آب و هوایی، آن را به عنوان ابزاری کلیدی برای کاربردهای کشاورزی تبدیل کرده است. برای نمونه، به

علت حساسیت پلاریزاسیون به ساختار محصول (اندازه، شکل و جهت‌گیری برگ‌ها، ساقه‌ها و میوه‌ها)، ویژگی‌های دی‌الکتریک پوشش گیاهی (مربوط به محتوای آب)، که به نوع محصول وابسته است، و ویژگی‌های فیزیکی خاک زیرین (زبری و رطوبت)، بازیابی فنولوژی محصولات کشاورزی بوسیله اندازه‌گیری‌های پلاریمتریک سار کاربردی مهم از این تکنولوژی محسوب می‌شود.

تصاویر سری زمانی PolSAR با مزیت بکارگیری اطلاعات زمانی علاوه بر اطلاعات مکانی، دید جزئی‌تری در مورد مکانیزم‌های پراکندگی ارائه می‌دهد و با بسط فضای مشاهدات بازیابی پارامتر دقیق‌تر و قابل اطمینان‌تری را فراهم می‌کند. با بکارگیری این تصاویر در ساختار اطلاعات پلاریمتریک اینترفرومتریک سار (PolInSAR)<sup>۲</sup> اندازه‌گیری‌های بالارزشی از اطلاعات شدت، پلاریزاسیون و اینترفرومتری فراهم می‌شود. اطلاعات شدت، که قدرت بازپراکنش موج راداری را منعکس می‌کند، امکان طبقه‌بندی پراکنده‌سازهای با مقادیر شدت مختلف را ایجاد می‌کند [۲،۳]. اطلاعات پلاریمتریک، که مربوط به ویژگی‌های هندسی و مواد تشکیل‌دهنده می‌شود، امکان تفکیک مکانیزم‌های پراکندگی مختلف درون یک پیکسل را فراهم می‌کند [۴-۶]. اطلاعات اینترفرومتریک، که مشخصات توپوگرافیک را منعکس می‌کند، امکان تشخیص تغییرات را در ارتفاع فراهم می‌کند [۷-۱۱]. در تحقیقات پیشین بیشتر به بررسی پتانسیل اطلاعات شدت و پلاریمتریک مانند ضرایب بازپراکنش، نسبت و همبستگی بین کانال‌های پلاریزاسیون و ویژگی‌های حاصل از الگوریتم‌های تجزیه در پایش پارامترهای محصول پرداخته شده است [۱۱-۱۸]. هدف این تحقیق بررسی پتانسیل سری زمانی از تصاویر PolInSAR در پایش و بازیابی ارتفاع، زیست‌توده و فنولوژی محصول می‌باشد، که در ادامه روش پیشنهادی به این منظور شرح داده می‌شود و نتایج آن مورد بررسی قرار می‌گیرد.

## ۲- مروری بر ماتریس کواریانس PolInSAR مورد استفاده

میدان الکتریکی یک موج الکترومغناطیس در نقطه  $x$  به طور کلاسیک با یک بردار مختلط تصادفی  $E(x)$  نشان

<sup>۲</sup> Polarimetric interferometric synthetic aperture radar

<sup>۱</sup> Polarimetric synthetic aperture radar

### ۳- روش پیشنهادی

شمای کلی روش پیشنهادی در شکل ۱ نشان داده شده است. در روش پیشنهادی به منظور پایش و بازیابی، ابتدا پایه پلاریزاسیون بهینه که در آن همبستگی بین دو تصویر پایه و پیرو (رابطه ۵) بیشینه است محاسبه می‌شود [۲۰]:

$$\gamma^2 = \frac{4}{3} \left[ \frac{tr(\gamma^2)}{(tr \gamma)^2} - \frac{1}{4} \right] \quad (5)$$

در این رابطه  $\gamma$  از رابطه ۴ حاصل شده و  $tr$  نماد مجموع عناصر قطر اصلی<sup>۳</sup> ماتریس مورد نظر است. سپس در پایه پلاریزاسیون بهینه ماتریس کواریانس PolInSAR که تنها وابسته به پلاریزاسیون ارسالی و مشخصات عارضه هدف می‌باشد از رابطه (۴) بدست می‌آید. با اعمال تجزیه مقدار ویژه [۲۱] بر روی این ماتریس ۱۳ ویژگی PolInSAR مانند انترویی شانون، انترویی و آلفا که در جدول ۱ ارائه شده‌اند، استخراج می‌شود. سپس مقادیر این ویژگی‌ها در هر پیکسل مورد بررسی برای بازیابی پارامترهای محصول مورد استفاده قرار می‌گیرد. لازم به ذکر است که در جدول ۱،  $\lambda$  مقدار ویژه و  $e$  بردار ویژه می‌باشد.

تاکنون در تحقیقات متعددی آنالیزهای رگرسیون مبنا در بررسی ارتباط بین ویژگی‌های بدست آمده از داده SAR و پارامترهایی مانند زیست‌توده، فنولوژی و رطوبت در زمین‌های کشاورزی مورد بررسی قرار گرفته‌اند [۲۲-۲۴]. به دلیل خطا در اندازه‌گیری و عدم قطعیت‌های موجود در داده زمینی، پیچیدگی‌های منطقه کشاورزی (به دلیل وجود پس‌زمینه خاک و ...)، و در دسترس نبودن داده با بیس‌لاین مکانی مناسب (برخلاف کاربردهای جنگل) استفاده از روش‌های رگرسیون استاندارد و مدل‌های فیزیکی با وجود سادگی نتایج قابل اطمینانی را در فرآیند بازیابی پارامتر فراهم نمی‌آورد. از این رو استفاده از روش‌هایی مانند شبکه عصبی پیشنهاد می‌شود [۲۵، ۲۶].

در این تحقیق نیز به منظور بازیابی نهایی پارامترهای ارتفاع، زیست‌توده و فنولوژی و اعتبارسنجی روش پیشنهادی از شبکه عصبی و رگرسیون بردار پشتیبان استفاده شده است. شرح مختصری از دو روش در ادامه ارائه می‌شود.

داده می‌شود. این میدان با یک تقریب خوب به طور محلی مربوط به یک موج صفحه‌ای می‌باشد، بنابراین می‌توان آنرا در دو بعد به صورت  $E(x) = [E_X(x), E_Y(x)]^T$  نمایش داد که در آن  $T$  ترانهاده است.

از طرفی دیگر موج پراکنده شده از عارضه هدف برحسب ماتریس پراکندگی و موج ارسالی را می‌توان براساس رابطه زیر توصیف کرد [۱۹]:

$$\begin{bmatrix} E_X(x) \\ E_Y(x) \end{bmatrix} = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \begin{bmatrix} E_X^0(x) \\ E_Y^0(x) \end{bmatrix} \quad (1)$$

در این رابطه موج ارسالی با یک بردار جونز واحد به صورت زیر قابل تعریف است:

$$\begin{bmatrix} E_X^0 \\ E_Y^0 \end{bmatrix} = \begin{bmatrix} \cos \phi & -\sin \phi \\ \sin \phi & \cos \phi \end{bmatrix} \begin{bmatrix} \cos \tau \\ j \sin \tau \end{bmatrix} \quad (2)$$

که در آن  $\phi \in [-(\pi/2), (\pi/2)]$  و  $\tau \in [-(\pi/4), (\pi/4)]$  به ترتیب زاویه توجیه<sup>۱</sup> و زاویه بیضویت<sup>۲</sup> هستند که توصیفگر وضعیت پلاریزاسیون موج ارسالی هستند.

همبستگی بین نقاط  $x_1$  و  $x_2$  از بردارهای تصادفی مختلط  $E(x_1)$  و  $E(x_2)$  را می‌توان بوسیله ماتریس کواریانس  $\Omega(x_1, x_2)$  نمایش داد [۲۰]:

$$\begin{aligned} \Omega(x_1, x_2) &= \langle E(x_2) E^\dagger(x_1) \rangle \\ &= \begin{bmatrix} \langle E_X(x_2) E_X^*(x_1) \rangle & \langle E_X(x_2) E_Y^*(x_1) \rangle \\ \langle E_Y(x_2) E_X^*(x_1) \rangle & \langle E_Y(x_2) E_Y^*(x_1) \rangle \end{bmatrix} \end{aligned} \quad (3)$$

که  $\langle \rangle$  متوسط‌گیری آماری و \* ترانهاده مزدوج را نشان می‌دهد. ماتریس  $\Omega$  وابسته به هر دو مشخصات پلاریمتریک و اینترفرومتریک است. ماتریس همبستگی استاندارد مربوط به حالت  $x_1 = x_2$  است. ماتریس همبستگی را ماتریس پلاریزاسیون نیز می‌نامند که متناظر خواهد بود با  $\Gamma(x_i) = \Omega(x_i, x_i)$ . نهایتاً ماتریس کواریانس پلاریمتریک اینترفرومتریک از رابطه زیر محاسبه می‌شود:

$$\gamma = \begin{pmatrix} \Gamma(x_1) & \Omega(x_1, x_2) \\ \Omega^\dagger(x_1, x_2) & \Gamma(x_2) \end{pmatrix} \quad (4)$$

<sup>۳</sup> trace

<sup>۱</sup> Orientation  
<sup>۲</sup> Ellipticity

### ۳-۱- شبکه عصبی مصنوعی (ANN)<sup>۱</sup>

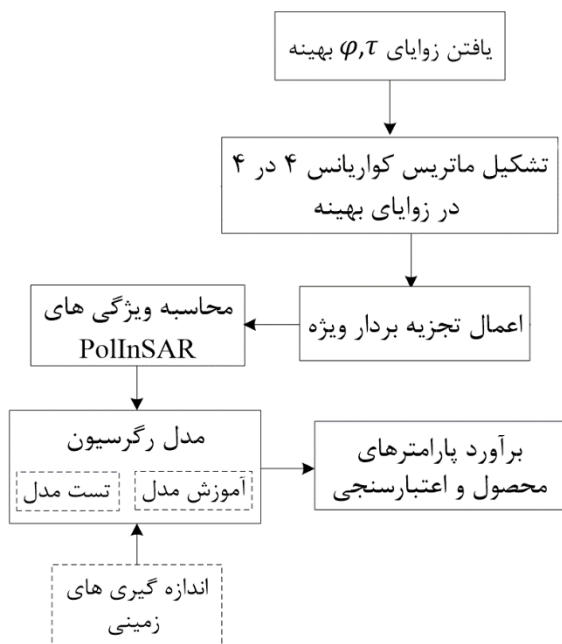
شبکه عصبی مصنوعی نوعی مدل آماری است که براساس کارکرد مغز انسان طراحی شده است. این نوع مدل با توانایی یادگیری که در اختیار دارد می‌تواند ورودی‌های معینی را دریافت کند و طی یک سری پردازش‌های موجود در مدل، نتیجه مطلوب را ارائه دهد. شبکه‌های عصبی از واحدهای ساده‌ای به نام نورون ساخته می‌شوند که در یک شبکه بوسیله اتصالات وزنی به یکدیگر متصل می‌شوند [۲۸،۲۹].

همچنین شبکه‌های عصبی از مجموعه لایه‌هایی تشکیل می‌شوند که لایه اول شامل ورودی‌ها و لایه آخر شامل خروجی‌ها می‌باشد. لایه‌های نهان نیز بین لایه‌های ورودی و خروجی قرار می‌گیرند. فرآیند آنالیز داده‌ها با ورود پارامترهای تنظیم به لایه اول نورون‌ها آغاز می‌گردد و سپس داده‌ها برای تنظیمات بیشتر به نورون‌های لایه دوم انتشار می‌یابند. سپس نتایج به لایه بعدی منتقل می‌گردد و این فرآیند ادامه می‌یابد تا به لایه داده‌های خروجی برسد. در اتصال بین لایه‌ای، دو نوع عمده از اتصالات بین نورون‌های شبکه وجود دارند که عبارتند از Feedforward Network و Feedback Network. در شبکه Feedforward سیگنال‌ها تنها در یک جهت از لایه ورودی به سمت لایه‌های نهان و در نهایت لایه خروجی جریان می‌یابند. در شبکه Feedback سیگنال‌ها می‌توانند در نورون‌های یک لایه یکسان یا در لایه‌های قبلی جریان یابند. هدف شبکه‌های عصبی یادگیری براساس اتصالات منطقی بین الگوهای پارامترهای ورودی و خروجی، تحلیل و یا یافتن ساختار الگوهای پارامترهای ورودی می‌باشد. با فراهم کردن شبکه‌های عصبی با داده‌های موجود، شبکه آموزش دیده از طریق اصلاح وزن‌های اتصالاتی بین نورون‌ها بدست می‌آید.

### ۳-۲- رگرسیون بردار پشتیبان (SVR)<sup>۲</sup>

شبکه‌های عصبی مصنوعی با محدودیت‌ها و مشکلاتی در تعیین ساختار بهینه شبکه مواجه هستند. به منظور بهبود عملکرد شبکه‌های عصبی، روش‌های یادگیری دیگری که یکی از مهمترین آنها ماشین بردار پشتیبان [۳۰] است ارائه

شده است. توسعه ماشین بردار پشتیبان براساس رگرسیون نیز در سال ۱۹۹۵ توسط Vapnik به نتیجه رسید [۳۱]. ماشین بردار پشتیبان مبتنی بر کمینه کردن ساختاری ریسک می‌باشد که از نظریه آموزش آماری گرفته شده است [۳۲]. مدل‌های ماشین بردار پشتیبان به دو گروه عمده مدل طبقه‌بندی ماشین بردار پشتیبان و مدل رگرسیون بردار پشتیبان تقسیم‌بندی می‌شوند. از مدل طبقه‌بندی ماشین بردار پشتیبان جهت حل مسائل طبقه‌بندی داده‌هایی که در کلاس‌های مختلف قرار می‌گیرند استفاده می‌گردد و مدل رگرسیون بردار پشتیبان در حل مسائل پیش‌بینی و تخمین کاربرد دارد. منظور از رگرسیون بدست آوردن یک ابرصفحه است که بر داده‌های مورد نظر برازش داده می‌شود. فاصله هر نقطه از این ابرصفحه نشان‌دهنده خطای آن نقطه خاص است. بهترین روشی که تاکنون برای رگرسیون خطی پیشنهاد شده است روش حداقل مربعات می‌باشد. با این وجود برای مسائل رگرسیون، این امکان وجود دارد که استفاده از برآورد کننده کمترین مربعات در حضور داده‌های پرت بطور کامل شدنی نباشد و در نتیجه رگرسور عملکرد ضعیفی را از خود به نمایش بگذارد. بنابراین میبایست یک برآورد کننده نیرومند را که نسبت به تغییرات کوچک در مدل حساس نباشد توسعه داد. در واقع، یک تابع جریمه به صورت زیر تعریف می‌شود:



شکل ۱- شمای کلی الگوریتم بازیابی پیشنهادی

<sup>۱</sup> Artificial neural network

<sup>۲</sup> Support vector regression

جدول ۱- ویژگی‌های PolInSAR مورد استفاده در بازیابی

ویژگی	رابطه
انتروپی	$H = - \sum_{i=1}^4 P_i \log_4 P_i, P_i = \frac{\lambda_i}{\sum_{j=1}^4 \lambda_j}$
آلفا	$\alpha = \sum_{i=1}^4 P_i \cos^{-1}(e_i^1), P_i = \frac{\lambda_i}{\sum_{j=1}^4 \lambda_j}$
آلفای ماکزیمم	$\alpha_{max} = \cos^{-1}(e_1^1)$
ناهمسانگردی	$A_{ij} = \frac{\lambda_i - \lambda_j}{\lambda_j + \lambda_j}$
انتروپی شانون	$SE = \log \{\pi^4 e^4 \det(\Upsilon)\}$
درجه همبستگی TSF [۲۷]	$\mu_{TSF}^2 = \frac{tr[\Omega(x_1, x_2)\Omega^\dagger(x_1, x_2)]}{tr[F(x_1)]tr[F(x_2)]}$
نسبت مینیمم مقدار ویژه به ماکزیمم مقدار ویژه	$\lambda_{min}/\lambda_{max}$
نسبت مینیمم مقدار ویژه به مجموع مقادیر ویژه	$\lambda_{min}/\sum_{j=1}^4 \lambda_j$

پایه شعاعی (RBF) یا گوشین و تابع سیگموئید می‌باشند که به ترتیب در رابطه (۸) ارائه شده‌اند.

$$\begin{aligned} k(x, x_i) &= (1 + x^T \cdot x_i)^d \\ k(x, x_i) &= \exp\{-\gamma \times |x - x_i|^2\} \\ k(x, x_i) &= \tanh(1 + x^T \cdot x_i) \end{aligned} \quad (8)$$

کرل گوشین یکی از رایج‌ترین و جامع‌ترین توابع کرل می‌باشد که تنها یک پارامتر  $\gamma$  دارد. معمولاً برای تعیین  $C$  و  $\gamma$  در روش جستجوی شبکه‌ای ابتدا بازه‌ای از اعداد مانند  $\{C \in \{2^{-7}, 2^{-6}, \dots, 2^7\}; \gamma \in \{2^{-7}, 2^{-6}, \dots, 2^7\}\}$  در نظر گرفته می‌شود. سپس هر ترکیب از پارامترها با استفاده از روش اعتبارسنجی k-fold cross validation بررسی و پارامترها با بهترین دقت انتخاب می‌شوند.

#### ۴- ارزیابی روش

##### ۴-۱- مجموعه داده

به منظور ارزیابی عملکرد روش پیشنهادی، سری زمانی از تصاویر پلاریمتریک سار سنجنده E-SAR از منطقه DEMMIN در آلمان در باند C مورد استفاده قرار گرفته است. منطقه مطالعاتی به همراه موقعیت داده‌های زمینی در شکل ۲ نشان داده شده است. این منطقه در


$$L^\varepsilon(x, y, f) = \begin{cases} 0 & \text{if } |y - f(x)| \leq \varepsilon \\ |y - f(x)| - \varepsilon & \text{otherwise} \end{cases} \quad (6)$$

مجموعه داده آموزشی به صورت  $S = \{(x_1, y_1), \dots, (x_l, y_l)\}$  و کلاس تابع به صورت  $f(x) = \{w^T x + b, w \in R^m, b \in R\}$  می‌باشد. در صورتی که داده‌ها از مقدار  $\varepsilon$  تخطی نمایند میبایست متناسب با مقدار تخطی متغیر کمبود تعریف شود. مطابق با تابع جریمه اشاره شده کمینه‌سازی به صورت زیر تعریف می‌گردد.

$$\begin{aligned} \text{Min } \Phi(w, \xi_i) &= \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i; i = 1, 2, \dots, l \\ \text{Subject To: } & y_i(w^T x_i + b) \geq 1 - \xi_i; \xi_i \geq 0; i = 1, 2, \dots, l \end{aligned} \quad (7)$$

که  $\|w\|^2$  نرم بردار وزن،  $\xi_i$  متغیر کمبود کمکی و پارامتر  $C$  ضریب تعادل پیچیدگی میان ماشین و تعداد نقاط تفکیک‌ناپذیر است که با سعی و خطا بدست می‌آید. یکی از روش‌های متداول برای حل مسائل غیرخطی استفاده از توابع کرل می‌باشد که براساس ضرب داخلی داده‌ها تعریف می‌شود. در واقع با یک تبدیل غیرخطی از فضای ورودی به فضایی با ابعاد بیشتر (حتی نامتناهی) می‌توان مسائل را به صورت خطی تفکیک‌پذیر ساخت. سه تابع کرل که به طور متداول مورد استفاده قرار می‌گیرند تابع چندجمله‌ای، تابع

۱ Radial basis function



24-May


11-May




21-Jun

13-Jun


شکل ۴- نمایشی از مراحل رشد محصول گندم



الف



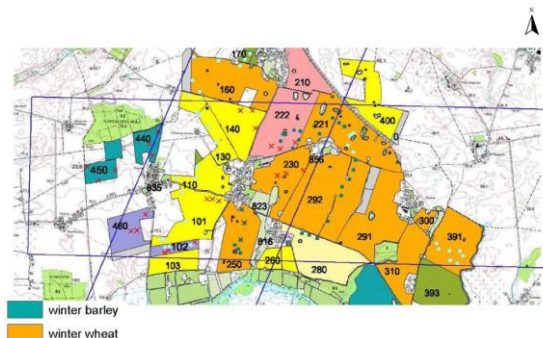
ب



ج

شکل ۵- اندازه‌گیری‌های زمینی الف) زیست‌توده، ب) ارتفاع و ج) فنونلژی


ناحیه ۳۳ شمالی با طول جغرافیایی ۱۳/۲۸ درجه و عرض جغرافیایی ۵۳/۹۹ درجه قرار دارد. بیس لاین مکانی داده مورد استفاده به صورت اسمی صفر است و داده‌ای مناسب برای بازیابی ارتفاع بوسیله مدل‌های فیزیکی مانند RVOG<sup>۱</sup> [۳۳] نمی‌باشد. بازه زمانی اخذ داده ۱۱ می تا ۵ جولای ۲۰۰۶ می‌باشد. منطقه مورد مطالعه شامل محصولات کشاورزی مختلف می‌باشد که با توجه به داده‌های زمینی موجود، در این تحقیق دو محصول گندم و جو مورد استفاده قرار گرفته‌اند. تصاویری از مراحل رشد این دو محصول در شکل‌های ۳ و ۴، و همچنین نمونه‌ای از اندازه‌گیری‌های زمینی ارتفاع، زیست‌توده و فنونلژی محصولات در طول فصل رشد در شکل ۵ نشان داده شده است. عملیات زمینی به منظور برداشت داده‌های زمینی همزمان با رشد گیاه صورت پذیرفته است.



شکل ۲- منطقه مطالعاتی به همراه موقعیت داده‌های زمینی



24-May



11-May



21-Jun








13-Jun

شکل ۳- نمایشی از مراحل رشد محصول جو

<sup>۱</sup> Random volume over ground

## ۴-۲- نتایج و بحث

تغییر زمانی دو ویژگی انتروپی شانون و آلفای PolInSAR حاصل از روش پیشنهادی برای دو نمونه از محصولات گندم و جو در شکل ۶ نشان داده شده است. به صورت کلی با رشد گیاه، مقدار هر دو ویژگی افزایش می‌یابد تا گیاه به بیشینه رشد خود برسد. این دو ویژگی عملکرد بهتری نسبت به بقیه ویژگی‌ها داشته و برای پایش محصولات مناسب‌تر تشخیص داده می‌شود.



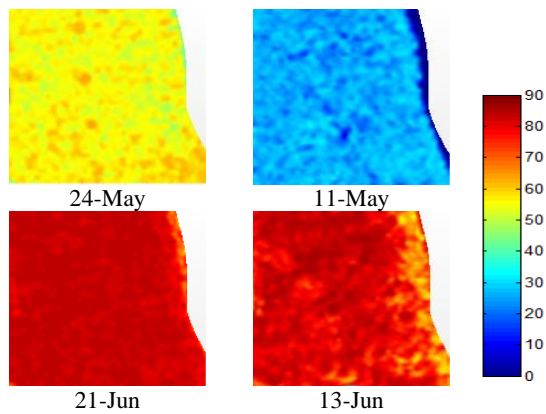
شکل ۶- تغییر زمانی دو ویژگی (الف) انتروپی شانون و (ب) آلفا

شکل ۷- ارتباط خطی بین انتروپی شانون و پارامترهای محصول (الف) فنولوژی، (ب) ارتفاع و (ج) زیست‌توده


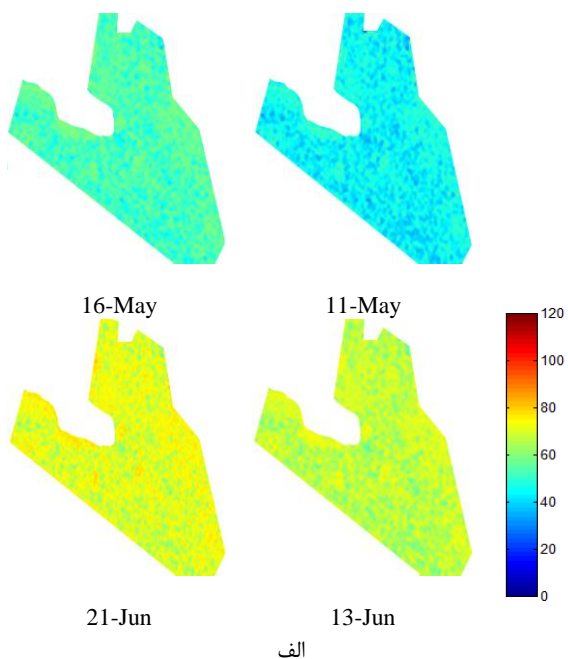
نتایج پیاده‌سازی‌های صورت گرفته نشان می‌دهد که با وجود خطا در اندازه‌گیری‌های زمینی و تاثیر پذیرفتن مقادیر ویژگی‌ها از ترکیبی از پارامترهای مختلف مرتبط با محصول، وابستگی‌های خطی بالایی بین برخی ویژگی‌ها و برخی پارامترهای محصول مانند ارتفاع وجود دارد. برای نمونه در شکل ۷ این روابط برای چند نمونه در نظر گرفته شده از محصول گندم ارائه شده است. رابطه افزایشی مشاهداتی بین ویژگی انتروپی شانون و داده زمینی موجود از پارامترهای محصول را می‌توان با معادلات رگرسیون نمایش داده شده بر روی اشکال نشان داد.

در ادامه نتایج بازیابی نهایی با استفاده از دو مدل شبکه عصبی و رگرسیون بردار پشتیبان ارائه شده است. به‌منظور پیاده‌سازی شبکه عصبی، با توجه به عملکرد مطلوب تابع کرنل پایه شعاعی در بررسی‌های انجام شده بر روی داده مورد استفاده از آن برای ایجاد مدل بازیابی استفاده شد. شبکه عصبی طراحی شده شامل پنج لایه می‌باشد. تعداد نرون لایه ورودی برابر با تعداد ویژگی‌ها در نظر گرفته شده است. پارامترهای رگرسیون بردار پشتیبان نیز با روش سعی و خطا تنظیم شده است. براساس این تنظیمات، برای دو پارامتر C و ۷ به ترتیب مقادیر ۲ و ۰/۰۱ انتخاب شد. جداول ۲ تا ۴ نتایج حاصل از بررسی رابطه بین مقدار




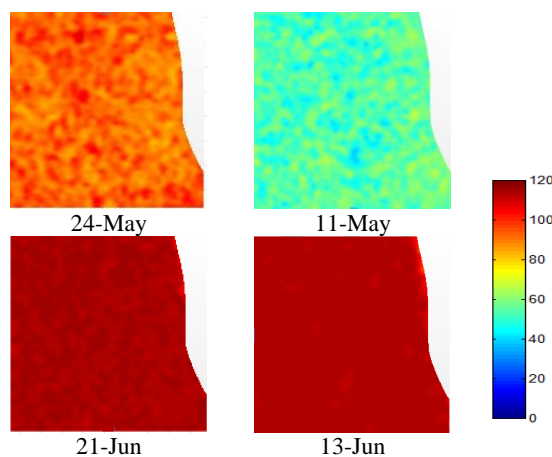


شکل ۸- نقشه‌های بازیابی زمین جو برای پارامترهای الف) ارتفاع، ب) زیست‌توده، ج) فنولوژی



پارامترهای محصول اندازه‌گیری شده و مقادیر پیش‌بینی شده آنها را با استفاده از روش‌های شبکه عصبی و رگرسیون بردار پشتیبان ارائه می‌دهد. این نتایج برحسب سه معیار ریشه میانگین مربعات خطا (RMSE)<sup>۱</sup>، میانگین قدر مطلق خطا (MAE)<sup>۲</sup> و ضریب همبستگی R<sup>۳</sup> ارائه شده است.

نتایج پتانسیل بالای روش پیشنهادی را در پایش و بازیابی پارامترهای محصولات مورد نظر نشان می‌دهد. عملکرد بازیابی روش پیشنهادی برای ارتفاع و فنولوژی نسبت به زیست‌توده بهتر ارزیابی می‌شود. همچنین در اغلب موارد اختلافات زیادی بین دو روش رگرسیون وجود ندارد. لازم به ذکر است که استفاده از شبکه عصبی در فرآیند بازیابی هزینه محاسباتی نسبتاً بالاتری به دنبال داشت. نقشه‌های بازیابی مربوط به پارامترهای فنولوژی، ارتفاع و زیست‌توده در زمین‌های جو و گندم به ترتیب در شکل ۸ و ۹ ارائه شده است.




۱ Root mean square error  
 ۲ Mean absolute error  
 ۳ Pearson's correlation coefficient



راداری در بازیابی برخی پارامترهای محصول مانند ارتفاع عملکرد مناسبی ندارد. با این حال، اطلاعات اینترفرومتریک می‌تواند نقش خوبی در پایش و بازیابی این پارامترها در طی فصل رشد ایفا نماید. در مطالعه حاضر روشی جدید برای پایش و بازیابی پارامتر محصولات زراعی با استفاده از تصاویر سری زمانی پلاریمتریک اینترفرومتریک سار بکار گرفته شد. ویژگی‌های پیشنهادی حاصل از تجزیه مقدار ویژه به روش شرح داده شده در ترکیب با شبکه‌های عصبی و یا رگرسیون بردار پشتیبان عملکرد مناسبی را در این کاربرد نشان می‌دهند. روش پیشنهادی می‌تواند جایگزین مناسبی برای مدل‌های تجربی و فیزیکی موجود در بازیابی پارامترهایی مانند ارتفاع به شمار رود، که با توجه به در اختیار نداشتن داده‌ها با بیس‌لاین‌های مکانی مناسب امکان استفاده از آنها وجود ندارد.

### سپاسگزاری

مولفان این مقاله از آژانس فضایی اروپا به خاطر همکاری در جهت اخذ داده‌های راداری AGRISAR کمال تشکر و سپاسگزاری را دارند.



شکل ۹- نقشه‌های بازیابی زمین گندم برای پارامترهای الف) ارتفاع، ب) زیست‌توده، ج) فنولوژی

### ۵- نتیجه‌گیری

سری زمانی از داده پلاریمتریک سار شامل اطلاعات شدت، پلاریمتریک و اینترفرومتریک می‌شود که اطلاعات زیادی از محصولات مختلف منعکس می‌کند. اطلاعات حاصل از داده اپتیک و اطلاعات شدت و پلاریمتریک حاصل از داده

جدول ۲- ارزیابی عملکرد روش‌های شبکه عصبی و رگرسیون بردار پشتیبان در تخمین پارامتر فنولوژی

SVR			ANN			نوع محصول
RMSE	MAE	R	RMSE	MAE	R	
0.2944	0.3721	0.902	0.255	0.2401	0.9472	جو
0.4637	0.4206	0.9005	0.212	0.1711	0.9702	گندم

جدول ۳- ارزیابی عملکرد روش‌های شبکه عصبی و رگرسیون بردار پشتیبان در تخمین پارامتر زیست‌توده

SVR			ANN			نوع محصول
RMSE	MAE	R	RMSE	MAE	R	
0.471	0.426	0.6584	0.6339	0.5133	0.429	جو
0.5251	0.4096	0.8052	0.5923	0.4594	0.7949	گندم

جدول ۴- ارزیابی عملکرد روش‌های شبکه عصبی و رگرسیون بردار پشتیبان در تخمین پارامتر ارتفاع

SVR			ANN			نوع محصول
RMSE	MAE	R	RMSE	MAE	R	
0.5972	0.4832	0.8475	0.5772	0.4755	0.8614	جو
0.2148	0.1932	0.9457	0.21	0.1831	0.9631	گندم

## مراجع

- [1] Srinivasan, A. 2006, Handbook of Precision Agriculture, Haworth, Philadelphia, Pa.
- [2] C. J. Oliver and S. Quegan, Understanding Synthetic Aperture Radar Images. New York: Artech House, 1998.
- [3] D. H. Hoekman, M. A. M. Vissers, and T. N. Tran, "Unsupervised full-polarimetric SAR data segmentation as a tool for classification of agricultural areas," IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens. (JSTARS), vol. 4, no. 2, pp. 402–411, 2011.
- [4] S. R. Cloude and K. P. Papathanassiou, "Polarimetric SAR interferometry," IEEE Transactions on Geoscience and Remote Sensing, vol. 36, no. 5, pp. 1551–1565, Sep. 1998.
- [5] J. S. Lee, S. R. Cloude, K. P. Papathanassiou, M. R. Grunes, and I. H. Woodhouse, "Speckle filtering and coherence estimation of polarimetric SAR interferometry data for forest application," IEEE Transactions on Geoscience and Remote Sensing, vol. 41, no. 10, pp. 2254–2263, Oct. 2003.
- [6] M. Jäger, M. Neumann, S. Guillaso, and A. Reigber, "A self-initializing PolInSAR classifier using interferometric phase differences," IEEE Transactions on Geoscience and Remote Sensing, vol. 45, no. 11, pp. 3503–3518, Nov. 2007.
- [7] K. Papathanassiou and S. R. Cloude, "Single-baseline polarimetric SAR interferometry," IEEE Transactions on Geoscience and Remote Sensing, vol. 39, no. 11, pp. 2352–2363, Nov. 2001.
- [8] V. Alberga, "Volume decorrelation effects in polarimetric SAR interferometry," IEEE Transactions on Geoscience and Remote Sensing, vol. 42, no. 11, pp. 2467–2478, Nov. 2004.
- [9] L. Ferro-Famil, F. Kugler, E. Pottier, and J. S. Lee, "Forest mapping and classification at L band using Pol-inSAR optimal coherence set statistics," in Proc. EUSAR, Dresden, Germany, May 16–18, 2006.
- [10] S. Sauer, L. Ferro-Famil, A. Reigber, and E. Pottier, "Physical parameter extraction over urban areas using L-band PolSAR data and interferometric baseline diversity," in Proc. IGARSS, Barcelona, Spain, pp. 5045–5048, Jul. 23–28, 2007.
- [11] J. M. Lopez-Sanchez, J. D. Ballester-Berman, and I. Hajnsek, "First results of rice monitoring practices in Spain by means of time series of TerraSAR-X dual-Pol images," IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens. (JSTARS), vol. 4, no. 2, pp. 412–422, 2011.
- [12] J. Betbeder, R. Fieuzal, and F. Baup, 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.
- [13] J. Lopez-Sanchez, S. Cloude, and J. Ballester, 2011, "Rice phenology monitoring by means of SAR Polarimetry at X-band," IEEE Transaction on Geoscience and Remote Sensing, vol. 50, no. 7, pp. 2695-2709.
- [14] J. Lopez-Sanchez, J. Ballester, F. Vicente-Guijalba, and S. Cloude, 2013, "Estimating phenology of agricultural crops from space," Proceedings of ESA Living Planet Symposium, September 9-13, Edimburg, UK.
- [15] J. Lopez-Sanchez, F. Vicente-Guijalba, J. Ballester, and S. Cloude, 2014, "Polarimetric Response of Rice Fields at C-Band: Analysis and Phenology Retrieval," IEEE Transaction on Geoscience and Remote Sensing, vol. 50, no. 5, pp. 2977-2993.
- [16] L. Mascolo, J. Lopez-Sanchez, F. Vicente-Guijalba, G. Mazzarella, F. Nunziata, and M. Migliaccio, 2014, "On the sensitivity of Polarimetric SAR observables to phenological stages of crops in Barrax, Spain: First results at C-band," Proceedings of the IEEE GOLD Conference 2014, June 5-6, Belrin, Germany.
- [17] L. Mascolo, J.M. Lopez-Sanchez, F. Vicente-Guijalba, G. Mazzarella, F. Nunziata, and M. Migliaccio, 2015, "Retrieval of phenological stages of onion fields during the first year of growth by means of C-band polarimetric SAR measurements," International Journal of Remote Sensing, 36:12, 3077-3096.

- [18] G. Wiseman, H. McNairn, S. Homayouni, J. Shang, 2014, "RADARSAT-2 polarimetric SAR response to crop biomass for agricultural production monitoring," IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 7(11): 4461-4471.
- [19] F. Shang, and A. Hirose, "Averaged Stokes Vector Based Polarimetric SAR Data Interpretation," IEEE Transactions on Geoscience and Remote Sensing, vol. 53, no. 8, Aug. 2015.
- [20] A. Luis, "Degree of coherence for vectorial electromagnetic fields as the distance between correlation matrices," J. Opt. Soc. Amer. A, Opt. Image Sci., vol. 24, pp. 1063–1068, Apr. 2007.
- [21] M. Salehi, Y. Maghsoudi, A. Mohammadzadeh, "Assessment of the Potential of H/A/Alpha Decomposition for Polarimetric Interferometric SAR data," IEEE Transactions on Geoscience and Remote Sensing, Nov. 2017.
- [22] R. Mathieu, M. Sbih, A. Viau, F. Anctil, L. Parent, and J. Boisvert, "Relationships between RADARSAT SAR data and surface moisture content of agricultural organic soils," Int. J. Remote Sens., vol. 24, no. 24, pp. 5265–5281, 2003.
- [23] R. D. De Roo, Y. Du, F. T. Ulaby, and M. C. Dobson, "A semi-empirical backscattering model at L-band and C-band for a soybean canopy with soil moisture inversion," IEEE Trans. Geosci. Remote Sens., vol. 39, no. 4, pp. 864–872, Apr. 2001.
- [24] K. C. Kornelsen and P. Coulibaly, "Advances in soil moisture retrieval from synthetic aperture radar and hydrological applications," J. Hydrol., vol. 476, pp. 460–489, 2013.
- [25] C. M. Bishop, Neural Networks for Pattern Recognition. Oxford, U.K.: Clarendon Press, 1995.
- [26] B. Schölkopf, A. J. Smola, R. C. Williamson, and P. L. Bartlett, "New support vector algorithms," Neural Comput., vol. 12, no. 5, pp. 1207–1245, 2000.
- [27] J. Tervo, T. Setälä, and A. T. Friberg, "Degree of coherence of electromagnetic fields," Opt. Express 11, 1137–1142, 2003.
- [28] C. G. Looney, Pattern recognition using neural networks: Theory and algorithms for engineers and scientists. Oxford University Press Inc. 1997.
- [29] S. S. Haykin, Neural networks and learning machines (Vol. 3). New York: Prentice Hall, 2009.
- [30] B.E. Boser, I.M. Guyon, and V.N. Vapnik, A training algorithm for optimal margin classifiers. In D.Haussler, editor, 5th Annual ACM Workshop on COLT , pages 144-152, Pittsburgh, PA, 1992.
- [31] V. Vapnik, The Nature of Statistical Learning Theory. Springer, New York, 1995.
- [32] V.N. Vapnik, Statistical Learning Theory. Wiley, New York. p. 736, 1998.
- [33] R. N. Treuhaft, S. Madsen, M. Moghaddam, J. J. van Zyl, 1996, Vegetation characteristics and underlying topography from interferometric data, Radio Sci., vol. 31, no. 6, pp. 1449–1495.