



بهبود دقت شناسایی مزارع برنج با استفاده از تصاویر سری زمانی دمای سطح زمین ماهواره لندست-۸ و الگوریتم‌های یادگیری ماشین

رضا شاه حسینی^۲

مهديه فتحی^۱

تاریخ پذیرش مقاله: ۱۴۰۱/۱۲/۱۱

تاریخ دریافت مقاله: ۱۴۰۰/۰۵/۱۸

چکیده

برنج اصلی‌ترین محصول غذایی بیش از نیمی از مردم جهان است. نظارت بر سطح زیر کشت محصول برنج، نقش مهمی در برنامه‌ریزی‌های کشاورزی دارد. امروزه می‌توان با تکیه بر فناوری سنجش از دور و روش‌های یادگیری ماشین، روش‌های مدیریتی را بهبود بخشید. تحقیق حاضر با هدف شناسایی برنج در سال ۲۰۲۰ به کمک نقشه‌های سری زمانی شاخص‌های NDVI و LST استخراج شده از تصاویر لندست-۸، با الگوریتم SVM در ایالت کالیفرنیا، انجام گرفته است. یکی از انگیزه‌های اصلی این پژوهش، بررسی قابلیت‌های نقشه‌های سری زمانی شاخص LST در کنار نقشه‌های سری زمانی شاخص NDVI به منظور بهبود دقت شناسایی مزارع برنج، با الگوریتم SVM است. در گام اول از روش پیشنهادی پس از اخذ سری زمانی تصاویر لندست-۸ و انجام تصحیحات رادیومتری و اتمسفری، نقشه‌های سری زمانی دو شاخص NDVI و LST تولید شد. در گام دوم، شناسایی مزارع برنج با الگوریتم طبقه‌بندی SVM در دو سناریوی وجود یا عدم وجود نقشه‌ی سری زمانی LST در کنار نقشه‌ی سری زمانی NDVI پیشنهاد شد. در نهایت از الگوریتم‌های طبقه‌بندی نزدیک‌ترین همسایگی، درخت تصمیم‌گیری، رگرسیون لجستیک و پرسپکترون چند لایه برای مقایسه‌ی روش پیشنهادی استفاده شد. نتایج حاصل از شاخص پیشنهادی باعث بهبود دقت کلی به مقدار متوسط ۳/۵۷۲ درصد و ضریب کاپا به مقدار متوسط ۷/۱۱۲ درصد در روش‌های شناسایی مزارع برنج هنگام به کارگیری همزمان نقشه‌های سری زمانی شاخص LST و NDVI با کاهش خطای نوع اول به کمک استخراج ویژگی‌های فصل رشد حرارتی (حذف کلاس‌های غیر برنج همچون پنبه، لویبای سبز و ... از کلاس برنج) شد. همچنین الگوریتم ماشین بردار پشتیبان، بالاترین دقت کلی ۹۴/۲۸ درصد و ضریب کاپای ۸۸/۲۹ درصد را در شناسایی مزارع برنج از سایر مزارع کشاورزی، در مقایسه با سایر روش‌های مقایسه‌ای نشان داد. نتایج حاصل از روش‌های مقایسه‌ای کارآیی پایین الگوریتم درخت تصمیم‌گیری را در شناسایی لبه‌های مزارع برنج، نشان داد.

واژه‌های کلیدی: شناسایی برنج، لندست-۸، نقشه‌ی دمای سطح زمین، الگوریتم‌های یادگیری ماشین

۱- دانشجوی دکتری مهندسی فتوگرامتری- دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران
mahdiyehfathi96@gmail.com

۲- استادیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران (نویسنده مسئول) rshahosseini@ut.ac.ir

۱- مقدمه

برنج یکی از غذاهای اصلی بیش از نیمی از مردم جهان است. مزارع برنج برای رشد به آب و حرارت نیاز دارد. بنابراین مساحت و توزیع مکانی مزارع برنج علاوه بر امنیت غذایی و انتشار گازهای گلخانه‌ای، از لحاظ استفاده از آب به دلیل کمبود منابع آبی برای ما مهم است (Dong et al., 2016) با گسترش مزارع برنج، داده‌های سنجنش از دوری مانند تصاویر اپتیکی و راداری به منظور نظارت بر رشد برنج مورد استفاده قرار گرفته‌اند (Mosleh et al., 2015).

نقشه‌های سری زمانی شاخص‌های پوشش گیاهی استخراج شده از تصاویر ماهواره‌ای اپتیکی برای جداسازی مزارع برنج از سایر مزارع کشاورزی قابل استفاده می‌شود. فنولوژی (به معنی زمان و طول مدت رشد گیاه) استخراج شده از نقشه‌های سری زمانی تصاویر ماهواره‌ای نقش مهمی در نظارت و بهره‌وری محصول دارد، زیرا اطلاعاتی از مراحل رشد محصول در اختیار ما قرار می‌دهد (Dong et al., 2016) مراحل فنولوژی برنج با در نظر گرفتن تغییرات مقادیر شاخص‌های پوشش گیاهی استخراج شده از تصاویر اپتیکی یا تغییرات مقادیر بازپراکنش تصاویر راداری در طی یک دوره‌ی زمانی خاص مشخص می‌شود. مزارع برنج قبل از زمان کاشت غرقابی می‌شوند و در این تاریخ مقادیر شاخص پوشش گیاهی مزارع برنج در کمترین مقدار خود قرار می‌گیرد و با رشد و افزایش ارتفاع محصول، مقادیر شاخص پوشش گیاهی به بیشترین مقدار خود می‌رسد. با توجه به توضیحات فوق پارامترهای فنولوژی مانند شروع فصل رشد، پایان فصل رشد، بیشترین مقدار شاخص پوشش گیاهی و ... به کمک نقشه‌های سری‌های زمانی شاخص‌های استخراج شده از تصاویر اپتیکی، تخمین زده می‌شوند (J. Wang et al., 2015).

تاکنون روش‌های گوناگونی برای شناسایی برنج از تصاویر ماهواره‌ای ارائه شده است. به‌عنوان مثال اینو و همکارانش در سال ۲۰۲۰ برای شناسایی برنج از تصاویر

راداری و اپتیکی سنتینل-۲/۱ جنگل‌های تصادفی (RF)^۱ را پیشنهاد دادند. گام‌های این روش: ۱- تولید نقشه‌ی اولیه مزارع برنج به کمک طبقه‌بندی تصاویر سنتینل-۱ با الگوریتم جنگل‌های تصادفی و ۲- تولید نقشه‌ی نهایی مزارع برنج با حذف مزارع غیر برنج از نقشه‌ی اولیه با استفاده از نقشه‌های شاخص تفاضلی پوشش گیاهی نرمال‌شده (NDVI)^۲، شاخص رطوبت خاک (LSWI)^۳ و شاخص پوشش گیاهی بهبود یافته (EVI)^۴ استخراج شده از تصاویر سنتینل-۲ هستند (Inoue et al., 2020).

آقای یونزاوا و همکارانش در سال ۲۰۲۰ برای شناسایی برنج از باند L تصاویر اپتیکی SAR روش‌های مبتنی بر آستانه‌گذاری را ارائه دادند (Yonezawa & Watanabe, 2020). آقای چانگ و همکارانش در سال ۲۰۲۱ برای شناسایی برنج از تصاویر راداری سنتینل-۱ روش تصمیم‌گیری مبتنی بر ویژگی^۵ را با استفاده از تفاوت‌های بازپراکنش^۶، فاصله‌ی زمانی^۷، نرخ تغییرات بازپراکنش^۸، میانگین بازپراکنش نرمال‌شده^۹ و بیشترین مقدار بازپراکنش^{۱۰} تصاویر سنتینل-۱ ارائه کردند (Chang et al., 2021). آقای لیو و همکارانش در سال ۲۰۲۰ روش مبتنی بر فنولوژی^{۱۱} را برای شناسایی مزارع برنج از تصاویر سنتینل-۲ و مدل ارتفاعی منطقه معرفی کردند (Liu et al., 2020). در این تحقیق به‌منظور شناسایی برنج از روش‌های آستانه‌گذاری^{۱۲} بر روی شاخص رطوبت خاک (LSWI)، شاخص پوشش گیاهی بهبود یافته (EVI)، شاخص زردی (YI)^{۱۳} و شیب منطقه استفاده کردند.

- 1- Random Forest
- 2- Normalized Difference Vegetation Index
- 3- Land Surface Water Index
- 4- Enhanced Vegetation Index
- 5- Feature-based decision method
- 6- Backscatter Difference
- 7- Time Interval
- 8- Backscatter Variation Rate
- 9- Average Normalized Backscatter
- 10- Maximum Backscatter
- 11- Phenology-based method
- 12- Thresholding methods
- 13- Yellowness Index

دادند (Mansaray et al., 2017). آقای تالما و همکارانش در سال ۲۰۲۰ گام‌های زیر را معرفی کردند:

۱- استخراج مقادیر بازپراکنش زمانی^۷ کانال‌های دریافت افقی (VV) و عمودی (VH) مزارع برنج و سایر پوشش‌ها،

۲- استفاده از مدل طبقه‌بندی‌کننده درخت تصمیم‌گیری (DT)^۸ به منظور تفکیک کلاس برنج از سایر پوشش‌ها و

۳- به‌کارگیری شاخص تفاضلی پوشش گیاهی نرمال‌شده (NDVI) و شاخص تفاضلی آب نرمال‌شده بهبود یافته (MNDWI)، به منظور بهبود دقت طبقه‌بندی و شناسایی مزارع برنج از تصاویر سنتینل-۱/۲ (Talema & Hailu, 2020).

آقای ژان و همکارانش در سال ۲۰۲۱ برای شناسایی برنج الگوریتم درخت تصمیم‌گیری (DT) را به کمک ویژگی‌های فنولوژیکی استخراج شده از تصاویر سنتینل-۱ پیشنهاد کردند (Zhan et al., 2021). چن و همکارانش در سال ۲۰۲۰ استفاده از ویژگی‌های بازپراکنش کانال‌های دریافت افقی (VV) و عمودی (VH) و شاخص‌های تفاضلی پوشش گیاهی نرمال‌شده (NDVI)، رطوبت خاک (LSWI)، پوشش گیاهی بهبود یافته‌ی (EVI) استخراج شده از سنتینل-۱/۲ را به‌عنوان ورودی الگوریتم جنگل‌های تصادفی (RF) برای شناسایی مزارع برنج پیشنهاد دادند (Chen et al., 2020).

آقای یانگ و همکارانش در سال ۲۰۱۷ برای شناسایی مزارع برنج از تصاویر رادارست-۲ و HJ-1A/B گام‌های زیر را پیشنهاد دادند:

۱- استخراج ویژگی‌های پلاریمتریکی و شاخص‌های پوشش گیاهی از تصاویر راداری و اپتیکی،^۲ انتخاب ویژگی‌های بهینه با الگوریتم مونت کارلو^۹ و شرط همبستگی (MCCL)^{۱۰} و^۳ تهیه نقشه برنج به کمک ویژگی‌های بهینه به‌عنوان ورودی الگوریتم‌های آنالیز فوریه^{۱۱}،

لی و همکارانش در سال ۲۰۲۰ برای شناسایی برنج الگوریتم‌های مبتنی بر فنولوژی را با استفاده از تصاویر سنتینل-۱ ارائه دادند (Li et al., 2020). در این تحقیق پس از استخراج مناطق احتمالی برنج به کمک آستانه‌گذاری بر روی مقادیر بازپراکنش آب‌های دائمی، به کمک ویژگی‌های فنولوژیکی استخراج شده از منحنی‌های سری زمانی مانند تاریخ شروع فصل رشد، تاریخ بیشترین مقدار بازپراکنش فصل اوج رشد و طول مدت فصل رشد، نقشه‌ی نهایی مزارع برنج را تهیه کردند.

آقای دیانگ و همکارانش در سال ۲۰۲۰ برای شناسایی برنج از تصاویر لندست-۸/۷ و مادیس الگوریتم‌های مبتنی بر فنولوژی را پیشنهاد دادند (Ding et al., 2020). در این تحقیق پس از ادغام مکانی زمانی تصاویر لندست-۸ و مادیس، مزارع برنج را به کمک ویژگی‌های دوره‌ی آبیاری^۱ شناسایی کردند. آقای وانگ و همکارانش در سال ۲۰۲۰ تصاویر مادیس و SMAPL4 برای شناسایی مزارع برنج پیشنهاد کردند (Y. Wang et al., 2020). در این تحقیق نقشه‌های سری زمانی شاخص تفاضلی شده‌ی پوشش گیاهی نرمال‌شده (NDVI)، شاخص پوشش گیاهی بهبود یافته (EVI)، شاخص رطوبت خاک (LSWI)، شاخص پوشش گیاهی نسبی (RVI)^۲ و پارامترهای فنولوژیکی را به‌عنوان ورودی الگوریتم جنگل‌های تصادفی (RF) برای شناسایی مزارع برنج استفاده کردند.

آقای مانسارای و همکارانش در سال ۲۰۱۷ ویژگی‌های بازپراکنش کانال‌های دریافت افقی (VV)^۳ و عمودی (VH)^۴ تصاویر سنتینل-۱، و شاخص پوشش گیاهی بهبود یافته (EVI) و شاخص تفاضلی آب نرمال‌شده بهبود یافته (MNDWI)^۵ استخراج شده از لندست-۸ و سنتینل-۱ را به‌عنوان ورودی الگوریتم‌های جنگل‌های تصادفی (RF) و ماشین بردار پشتیبان (SVM)^۶، برای شناسایی برنج ارائه

1- Flooding

2- Ratio Vegetation Index

3- Horizontal Received

4- Vertically Received

5- Modified Normalized Difference Water Index

6- Support Vector Machine

7- Temporal Backscatter

8- CART decision tree classifier

9- Monte Carlo experiments

10- Correlation Limitation

11- Fourier analysis

مورد استفاده در پژوهش حاضر از تصاویر ماهواره‌ای لندست-۸ با قدرت تفکیک مکانی ۳۰ متر انتخاب شده‌اند. جدول ۱ تصاویر چندطیفی مورد استفاده و جدول ۲ و نگاره ۱ مناطق مورد مطالعه در این تحقیق را نشان می‌دهند. نقشه‌ی سری شاخص دمای سطح زمین (LST) و نقشه‌ی سری زمانی شاخص تفاضلی پوشش گیاهی نرمال شده- (NDVI) این داده‌ها به همراه نقشه‌ی واقعیت زمینی در نگاره ۲ ارائه شده است. با توجه به نگاره ۳ مزارع برنج در ایالت کالیفرنیا از اواخر ماه مه کاشته شده و تا اواخر ماه اکتبر برداشت می‌شود. نقشه‌ی واقعیت زمینی منطقه‌ی مورد مطالعه از دپارتمان کشاورزی ایالت متحده اخذ شده که دارای قدرت تفکیک مکانی ۳۰ متر است و با استفاده از الگوریتم درخت تصمیم‌گیری (DT) تهیه شده است. ابعاد هر یک از نقشه‌های سری زمانی NDVI و LST $512 \times 512 \times 9$ پیکسل است.

۳- روش پیشنهادی

در این تحقیق، به منظور تفکیک کشت برنج از سایر کشت‌ها به ویژه کشت‌های دیمی و کاهش خطای نوع اول (حذف پیکسل‌های غیر هدف از نقشه‌ی نهایی)، نقشه‌های سری زمانی دمای سطح زمین (LST) در کنار نقشه‌های سری زمانی شاخص تفاضلی پوشش گیاهی نرمال شده (NDVI) با توجه به پدیده‌ی تبخیر و تعرق محصولات کشاورزی، به کمک الگوریتم طبقه‌بندی SVM بررسی می‌شوند. در نهایت روش پیشنهادی با استفاده از الگوریتم‌های طبقه‌بندی نزدیک‌ترین همسایگی، درخت تصمیم‌گیری، رگرسیون لجستیک و پرسپکترون چند لایه مقایسه می‌شوند. فلوچارت نگاره ۴ روند کلی راهکار پیشنهادی را نشان می‌دهد.

آنالیز موجک^۱، نزدیک‌ترین همسایگی (KNN)^۲، ماشین بردار پشتیبان (SVM) و درخت تصمیم‌گیری (DT) (Yang et al., 2017)

شناسایی محصول برنج همانند سایر محصولات کشاورزی با چالش‌هایی همچون، پوشش ابر در مناطق کاشت برنج هنگام استفاده از تصاویر اپتیک، عدم شناسایی مزارع برنج با وسعت کوچک‌تر از قدرت تفکیک مکانی سنجنده‌ی مورد استفاده، عدم شناسایی مزارع برنج در مناطق شیب‌دار هنگام استفاده از تصاویر راداری، دقت پایین شناسایی مزارع برنج از تصاویر راداری در مقایسه با تصاویر اپتیک، تفکیک مزارع برنج از کشت‌های دیمی، شباهت طیفی برنج با سایر کلاس‌ها، برنج با گونه‌های مختلف و پیکسل‌های مخلوط روبه‌رو است. بنابراین برای غلبه بر چالش‌های فوق می‌توان از تلفیق تصاویر راداری با تصاویر اپتیک با قدرت تفکیک بالا و نقشه‌های سری زمانی دمای سطح زمین (LST)^۳ به منظور تفکیک کشت‌های دیمی و آبی استفاده کرد.

در این مطالعه، ما تأثیر نقشه‌های دمای سطح زمین را به منظور بهبود شناسایی مزارع برنج از سری زمانی تصاویر لندست-۸ در ایالت کالیفرنیا به کمک الگوریتم SVM مورد بررسی قرار می‌دهیم.

مقاله پیش رو در پنج بخش نگارش شده است. بعد از بخش نخست به عنوان مقدمه، در بخش دوم منطقه‌ی مورد مطالعه و داده‌های تحقیق معرفی شده است. بخش سوم روش پیشنهادی، بخش چهارم نتایج و بحث و در نهایت در بخش پنجم به نتیجه‌گیری و طرح پیشنهادات آتی اختصاص دارد.

۲- منطقه مطالعاتی و داده‌های تحقیق

برای انجام آزمون‌های این تحقیق ایالت کالیفرنیا انتخاب شده است. ایالت کالیفرنیا به دلیل دارا بودن منابع طبیعی بالقوه، برای کشت برنج مناسب است. داده‌های چندطیفی

1- Wavelet analysis

2- K-Nearest Neighbor

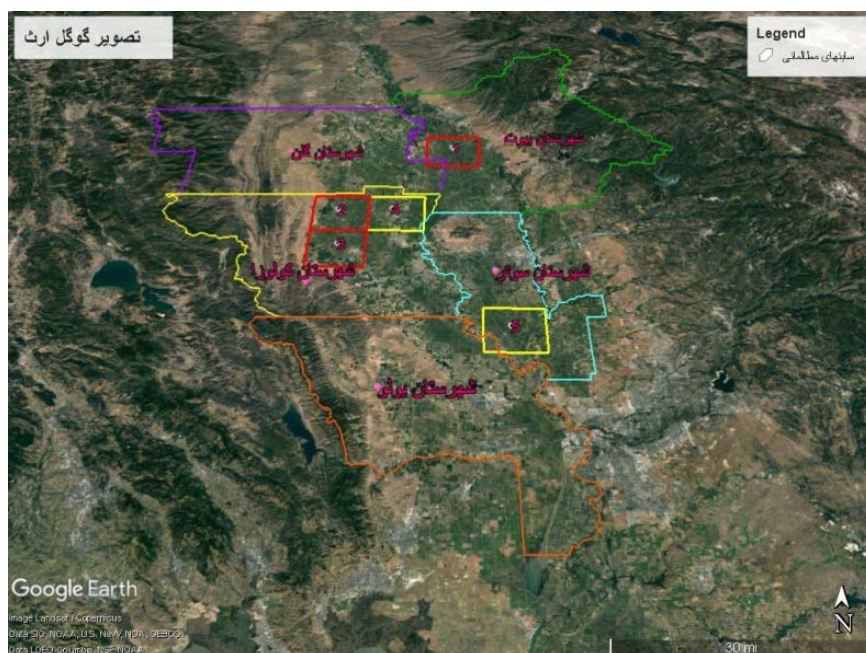
3- Land Surface Temperature

جدول ۱: داده‌های اخذ شده

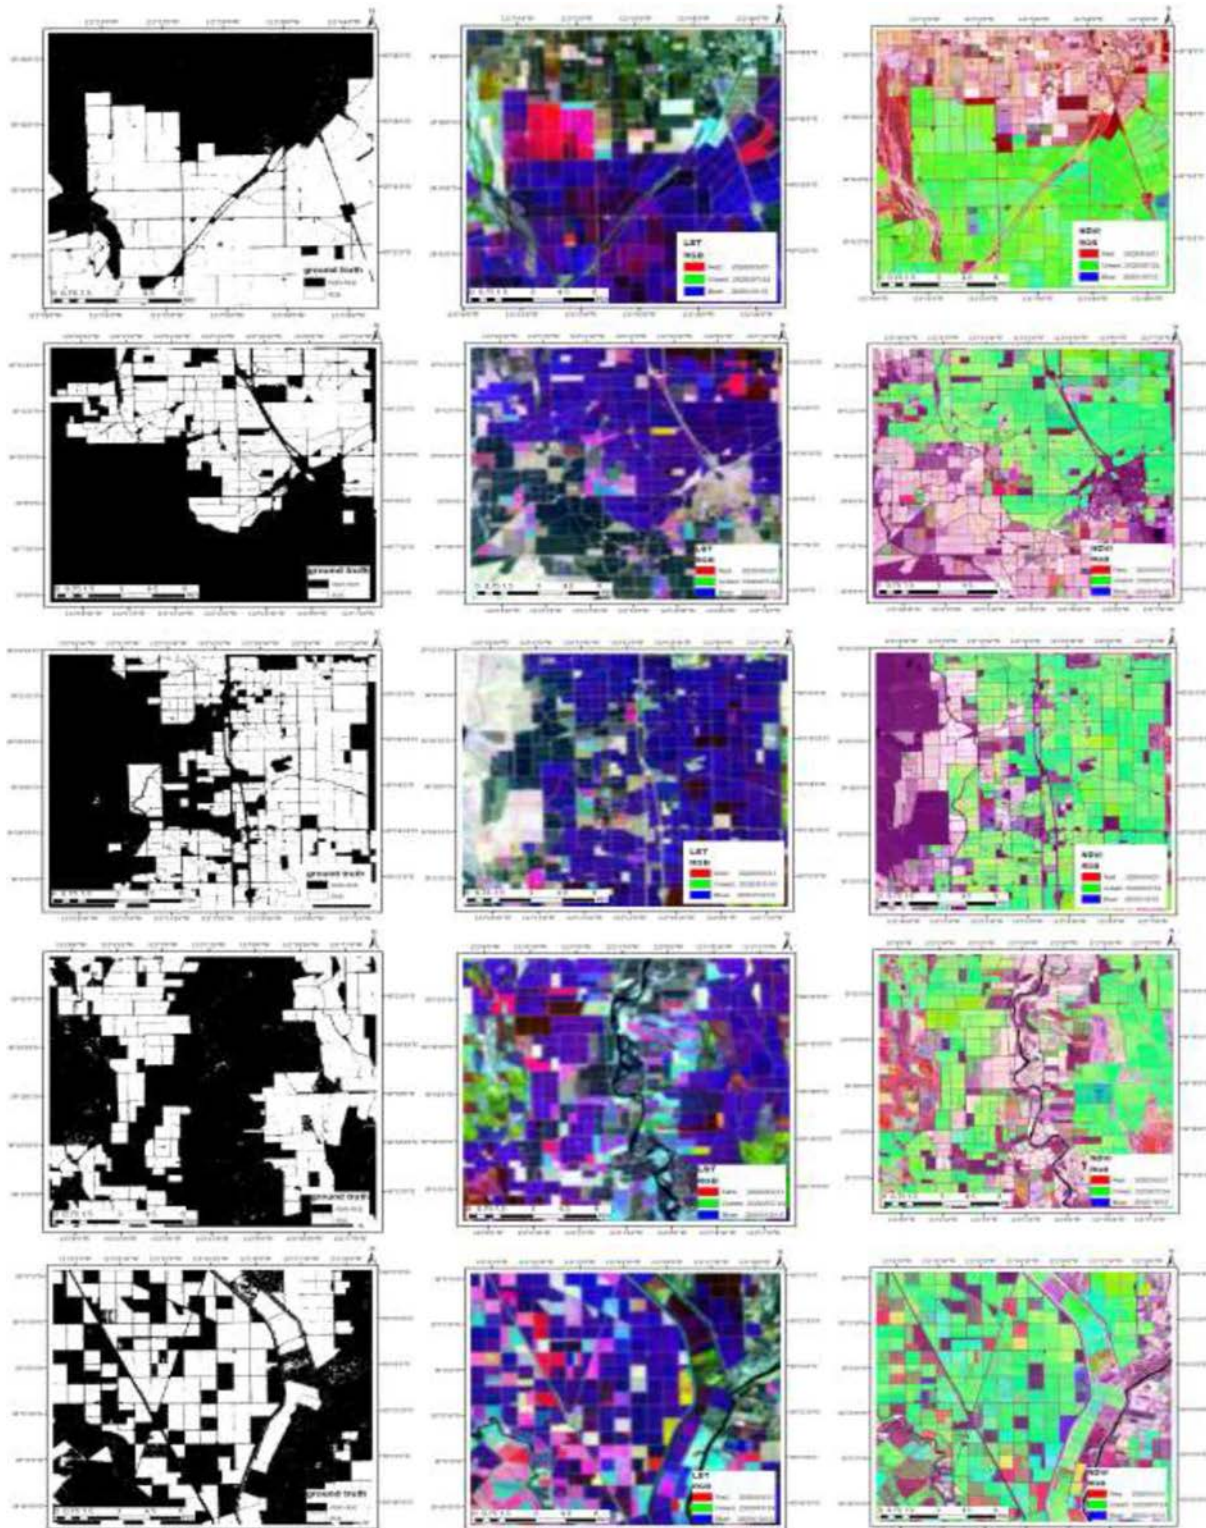
منطقه‌ی مورد مطالعه	تاریخ اخذ	نوع تصویر
ایالت کالیفرنیا	۲۰۲۰-۰۴-۰۳	لندست-۸
ایالت کالیفرنیا	۲۰۲۰-۰۵-۲۱	لندست-۸
ایالت کالیفرنیا	۲۰۲۰-۰۶-۰۶	لندست-۸
ایالت کالیفرنیا	۲۰۲۰-۰۶-۲۲	لندست-۸
ایالت کالیفرنیا	۲۰۲۰-۰۷-۰۸	لندست-۸
ایالت کالیفرنیا	۲۰۲۰-۰۷-۲۴	لندست-۸
ایالت کالیفرنیا	۲۰۲۰-۰۸-۰۹	لندست-۸
ایالت کالیفرنیا	۲۰۲۰-۱۰-۱۲	لندست-۸
ایالت کالیفرنیا	۲۰۲۰-۱۰-۲۸	لندست-۸

جدول ۲: مختصات سایت‌های مطالعاتی

منطقه‌ی مطالعاتی	طول جغرافیایی (شمالی)	عرض جغرافیایی (غربی)
۱ (سایت آموزشی) شهرستان بیوت و شهرستان گلن	39°34'7.03"	121°50'57.89"
۲ (سایت آموزشی) شهرستان کولوزا	39°17'25.83"	122°12'44.57"
۳ (سایت آموزشی) شهرستان کولوزا	39°9'40.22"	122°12'55.87"
۴ (سایت ارزیابی) شهرستان کولوزا	39°17'54.35"	122°2'14.35"
۵ (سایت ارزیابی) شهرستان سوتر و شهرستان یولو	38°52'40.46"	121°41'12.13"



نگاره ۱: موقعیت سایت‌های آموزش (قرمز) و ارزیابی (زرد) بر روی تصویر گوگل ارث




نقشه‌ی واقعیت زمینی

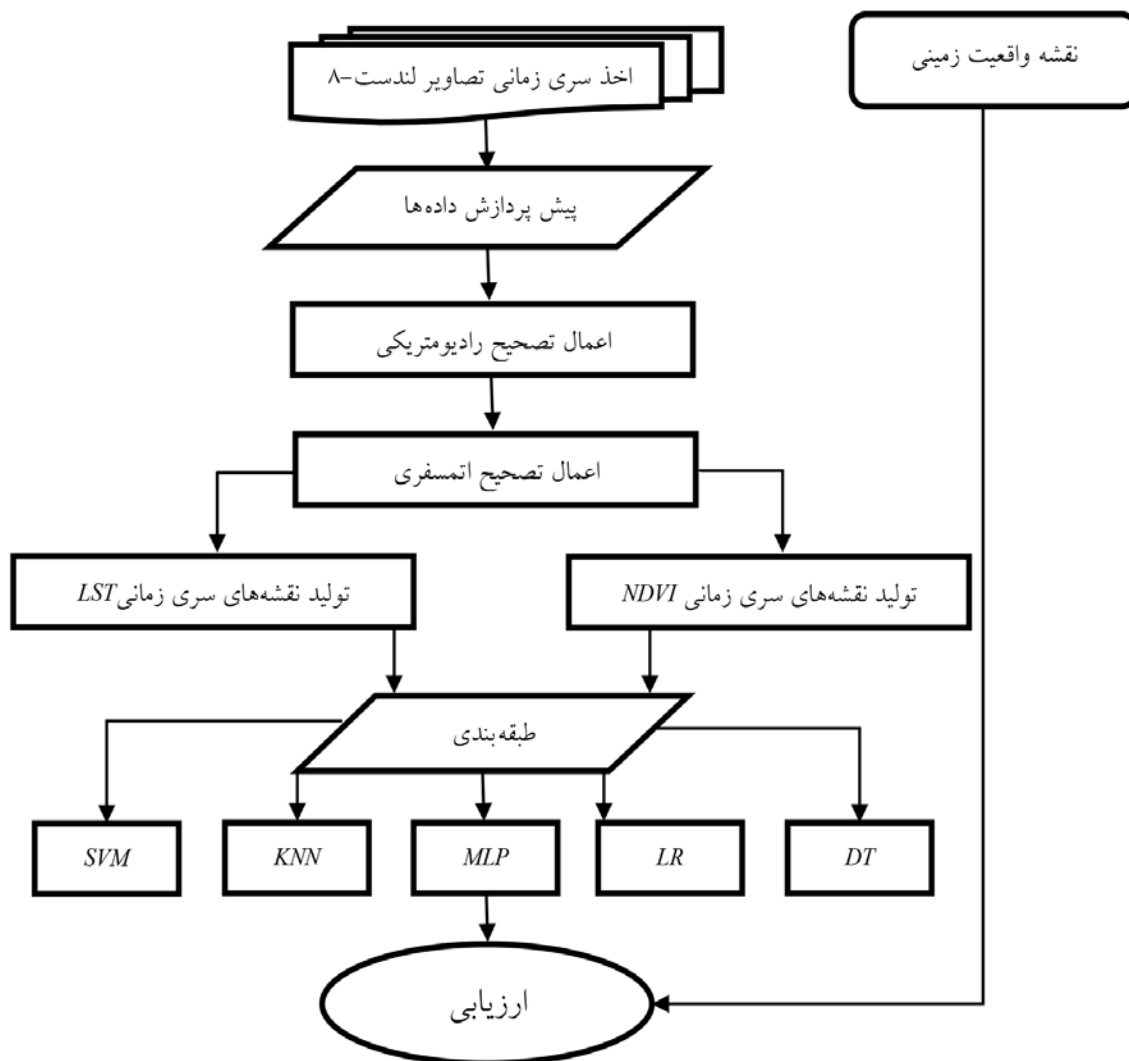
تصویر رنگی کاذب نقشه‌ی سری زمانی
 شاخص *LST*

تصویر رنگی کاذب نقشه‌ی سری زمانی
 شاخص *NDVI*

نگاره ۲: داده‌های مورد استفاده



نگاره ۳: تغییرات شاخص NDVI در دوره‌ی کاشت تا برداشت برنج



نگاره ۴: فلوچارت روش پیشنهادی

۱-۳- پیش پردازش داده‌ها

در روابط ارائه شده، L_{λ} رادیانس طیفی بالای اتمسفر، M_L ضریب کسب باند مربوطه، Q_{cal} عدد رقومی باند ۱۰، A_L عدد بایاس باند ۱۰، O_i ضریب تصحیح برای باند ۱۰، P مقادیر بازتابندگی، TB دمای درخشندگی و ε مقدار گسیلمندی است. در این تحقیق از باند ۱۰ حرارتی تصویر ماهواره لندست-۸ (مربوط به سنجنده‌ی TIRS) برای تهیه‌ی نقشه‌ی دمای سطح زمین استفاده می‌شود.

با توجه به فلوچارت نگاره ۴ اولین اقدام پس از اخذ سری زمانی تصاویر لندست-۸، اعمال پارامترهای کالیبراسیون رادیومتریکی و انجام تصحیحات اتمسفری است. تصحیحات رادیومتریکی برای باندهای طیفی و حرارتی و تصحیحات اتمسفری برای باندهای طیفی با الگوریتم (QUAC) اعمال می‌شود.

۳-۳- شناسایی مزارع برنج با الگوریتم‌های یادگیری ماشین در این تحقیق، به منظور تفکیک مزارع برنج از مزارع دیگر و کاهش خطای نوع اول در مناطق مورد مطالعه و تهیه‌ی نقشه‌ی برنج به کمک ویژگی‌های انتخاب شده، از الگوریتم SVM استفاده می‌شود. همچنین به منظور مقایسه‌ی روش پیشنهادی الگوریتم‌های متنوع طبقه‌بندی نظارت شده تصاویر ماهواره‌ای مانند نزدیک‌ترین همسایگی (KNN)، درخت تصمیم‌گیری (DT) رگرسیون لجستیک (LR) و پرسپکترون چند لایه (MLP) بررسی می‌شوند (Dreiseitl & Ohno-Machado, 2002; Guo et al., 2003; Murtagh, 1991; Priyam et al., 2013; Yue et al., 2003). در نهایت نتایج حاصل از طبقه‌بندی‌های انجام گرفته با تعیین ضریب کاپا و دقت کلی هر یک از الگوریتم‌ها، با یکدیگر مقایسه می‌شوند.

۲-۳- استخراج ویژگی از سری زمانی تصاویر لندست-۸ در این تحقیق، برای بررسی تفکیک‌پذیری مزارع برنج از سایر مزارع، نقشه‌ی سری زمانی دمای سطح زمین (LST) و نقشه‌ی سری زمانی شاخص تفاضلی پوشش گیاهی نرمال شده (NDVI) به عنوان ویژگی‌های ورودی الگوریتم SVM بررسی می‌شوند. بر این اساس چگونگی محاسبه‌ی شاخص‌های NDVI (Rouse et al., 1974) و LST (Artis & Carnahan, 1982) از تصاویر لندست-۸ در روابط ۱-۶ نشان داده شده است.

$$NDVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}} \quad \text{رابطه (۱)}$$

$$L_{\lambda} = M_L \times Q_{cal} + A_L - O_i \quad \text{رابطه (۲)}$$

$$TB = \frac{K_2}{\ln\left(\frac{K_1}{L_{\lambda}} + 1\right)} - 273.15 \quad \text{رابطه (۳)}$$

$$PV = \left(\frac{NDVI - \min_{NDVI}}{\max_{NDVI} - \min_{NDVI}}\right)^2 \quad \text{رابطه (۴)}$$

$$\varepsilon = 0.004 \times PV + 0.986 \quad \text{رابطه (۵)}$$

$$LST = \frac{TB}{1 + \left(\frac{\lambda \times TB}{p}\right) \times \ln \varepsilon} \quad \text{رابطه (۶)}$$

$$p = 1.438 \times 10^{-2} mk$$

۴- نتایج و بحث

با استخراج ویژگی‌های مورد اشاره از تصاویر لندست-۸ مجموع ۱۸ ویژگی شامل نقشه‌های شاخص تفاضلی پوشش گیاهی نرمال شده (NDVI) و نقشه‌های دمای سطح زمین (LST) برای ۹ زمان مختلف تولید و در دو سناریوی وجود یا عدم وجود نقشه‌ی سری زمانی دمای سطح زمین (LST) در کنار نقشه‌ی سری زمانی شاخص تفاضلی پوشش گیاهی نرمال شده (NDVI) به عنوان ورودی در فرآیند طبقه‌بندی مورد بررسی قرار گرفتند. لازم به ذکر است ویژگی‌های انتخاب شده به منظور بهبود نتایج طبقه‌بندی و افزایش تفکیک‌پذیری در بازه‌ی ۰ و ۱ نرمال‌سازی می‌شود.

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (۳۳)

بهبود دقت شناسایی مزارع برنج با استفاده از تصاویر سری زمانی دمای سطح زمین ماهواره ... / ۶۱

جدول ۳: تعداد نمونه‌های استفاده شده به منظور آموزش و

ارزیابی روش پیشنهادی

کلاس غیر برنج	کلاس برنج	
۴۱۵۹۸۰	۳۷۰۴۵۲	تعداد پیکسل‌های آموزش
۳۰۴۲۵۵	۲۲۰۰۳۳	تعداد پیکسل‌های ارزیابی

نتایج طبقه‌بندی برای الگوریتم‌های مختلف در جداول ۴ تا ۶ نمایش داده شده است.



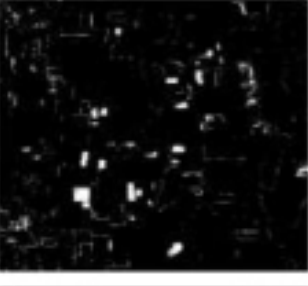



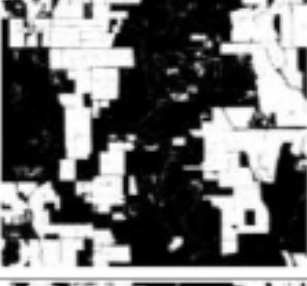





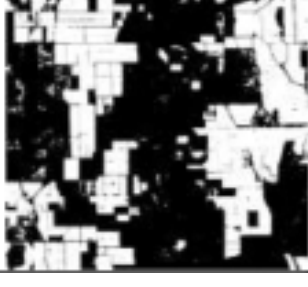


با توجه به نتایج بصری جداول ۵ و ۶ و مقایسه‌ی نتایج به‌دست آمده از الگوریتم روش پیشنهادی با نقشه‌های واقعیت زمینی، استفاده از نقشه‌ی سری زمانی دمای سطح زمین (LST) در کنار نقشه‌ی سری زمانی شاخص تفاضلی پوشش گیاهی نرمال شده (NDVI)، باعث حذف پیکسل‌های کلاس آب به‌دلیل غرقابی بودن مزارع برنج و در نتیجه شباهت آن با کلاس آب، در طبقه‌بندی‌کننده‌های ماشین بردار پشتیبان (SVM)، نزدیک‌ترین همسایگی (KNN) و پرسپکترون چندلایه (MLP) شد.

برای اجرای فرآیند طبقه‌بندی، شبکه‌ی پرسپکترون چند لایه (MLP) با یک لایه‌ی ورودی، دو لایه‌ی پنهان شامل: ۱- لایه‌ی اول با ۶۰ نرون، ۲- لایه‌ی دوم با ۳۰ نرون و ۳- تابع فعال سازی Relu و یک لایه خروجی شامل: ۱- ۱ نرون و ۲- تابع فعال‌سازی Sigmoid، طراحی شد. لازم به ذکر است مقادیر اولیه وزن و بایاس شبکه با روش uniform تعیین و با تابع هزینه کراس آنتروپی مقادیر وزن و بایاس محاسبه شدند (Thimm & Fiesler, 1995; Zhang & Sabuncu, 2018). در نهایت شبکه برای ۱۵۰ تکرار با الگوریتم ADAM آموزش داده شد (Wahlberg et al., 2012). برای الگوریتم نزدیک‌ترین همسایگی (KNN)، متریک مینکوفسکی و ۱۶ پیکسل مجاور را و از کرنل RBF برای طبقه‌بندی با الگوریتم ماشین بردار پشتیبان (SVM) استفاده شد. پس از تعیین ویژگی‌های مناسب و انتخاب روش‌های طبقه‌بندی، برای تهیه‌ی نقشه‌ی برنج از میان پنج سایت مورد مطالعه، سایت‌های ۱، ۲ و ۳ به‌عنوان داده‌های آموزشی به الگوریتم‌ها معرفی شدند و در نهایت با استفاده از سایت‌های مطالعاتی ۴ و ۵ مدل‌های آموزش دیده مورد ارزیابی قرار گرفتند. در جدول ۳ تعداد پیکسل‌های آموزشی و ارزیابی کلاس برنج و غیر برنج نشان داده شده است.


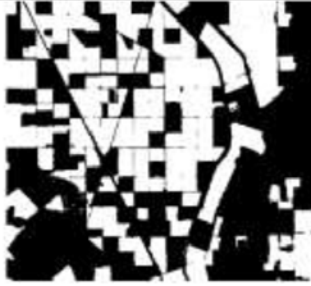



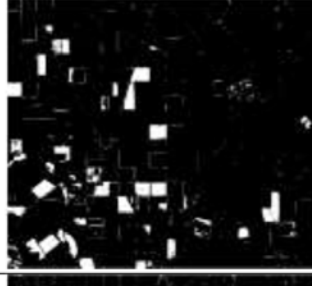

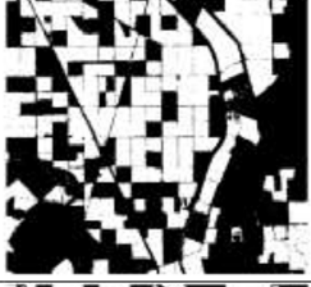

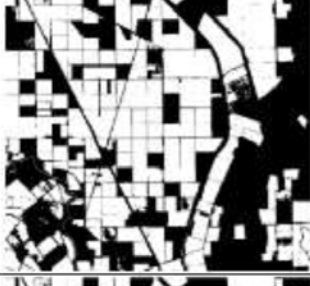





جدول ۴: ارزیابی الگوریتم‌های پیشنهادی

NDVI		NDVI+LST		ویژگی
ضریب کاپا	دقت کلی	ضریب کاپا	دقت کلی	روش پیشنهادی
۸۰/۷۳	۹۰/۴۹	۸۸/۲۱	۹۴/۲۶	MLP
۸۰/۸۲	۹۰/۵۰	۸۸/۲۹	۹۴/۲۸	SVM
۷۹/۲۰	۸۹/۶۸	۸۷/۰۸	۹۳/۷۱	KNN
۷۵/۵۰	۸۷/۸۲	۸۳/۵۴	۹۱/۹۶	LR
۷۷/۲۸	۸۸/۷۳	۸۱/۹۷	۹۱/۳۱	DT
			+۳/۵۷۲	مقدار میانگین افزایش دقت کلی
		+۷/۱۱۲		مقدار میانگین افزایش ضریب کاپا

جدول ۵: ارزیابی بصری روش پیشنهادی در سایت اول

ویژگی مورد استفاده روش طبقه بندی	نقشه‌های سری زمانی <i>NDVI</i>	نقشه‌های سری زمانی <i>NDVI</i> و <i>IST</i>	تفاضل دو نقشه حاصل از طبقه بندی با ویژگی‌های مختلف
شبکه پرسپکترون چندلایه (<i>MLP</i>)			
ماشین بردار پشتیبان (<i>SVM</i>)			
نزدیکترین همسایگی (<i>KNN</i>)			
رگرسیون لجستیک (<i>LR</i>)			
درخت تصمیم گیری (<i>DT</i>)			

جدول ۶: ارزیابی روش پیشنهادی در سایت پنجم

ویژگی مورد استفاده روش طبقه بندی	نقشه‌ی سری زمانی <i>NDVI</i>	نقشه‌ی سری زمانی <i>NDVI</i> و <i>LST</i>	تفاضل دو نقشه حاصل از طبقه بندی با ویژگی‌های مختلف
شبکه پرسپکترون چندلایه (<i>MLP</i>)			
ماشین بردار پشتیبان (<i>SVM</i>)			
نزدیکترین همسایگی (<i>KNN</i>)			
رگرسیون لجستیک (<i>LR</i>)			
درخت تصمیم گیری (<i>DT</i>)			

کاپای ۸۸/۲۹ درصد، ۲- بهبود دقت کلی و ضریب کاپای روش‌های شناسایی مزارع برنج در زمان به‌کارگیری همزمان نقشه‌های سری زمانی LST و NDVI به ترتیب به مقدار متوسط ۳/۵۷۲ و ۷/۱۱۲ درصد و ۳- دقت بالای روش‌های ماشین بردار پشتیبان (SVM)، پرسپکترون چند لایه (MLP) و نزدیک‌ترین همسایگی (KNN) نسبت به روش‌های رگرسیون لجستیک (LR) و درخت تصمیم‌گیری (DT)، اشاره نمود.

۵- نتیجه‌گیری

در این تحقیق تأثیر نقشه‌ی سری زمانی شاخص دمای سطح زمین استخراج شده از تصاویر لندست-۸، در بهبود دقت شناسایی مزارع برنج از سایر مزارع کشاورزی برنج به دلیل فرآیند تبخیر و تعرق به کمک الگوریتم‌های یادگیری ماشین مورد بررسی قرار گرفت. نتایج حاصل، اثر بخشی شاخص پیشنهادی را در بهبود دقت شناسایی مزارع برنج نشان داد. یکی از دلایل بهبود دقت شناسایی مزارع برنج استخراج ویژگی‌های فصل رشد حرارتی از نقشه‌های سری زمانی دمای سطح زمین (LST) به همراه منحنی فنولوژی برنج می‌باشد. از مزایای روش پیشنهادی علاوه بر بهبود دقت کلی و ضریب کاپا می‌توان به مواردی همچون:

- ۱- تفکیک کشت برنج به دلیل غرقابی بودن مزارع برنج از کشت‌های دیمی به کمک استخراج ویژگی‌های فصل رشد حرارتی از نقشه‌ی سری زمانی دمای سطح زمین،
- ۲- کاهش نویز نقشه‌ی مزارع برنج با حذف مزارع غیر برنج،
- ۳- کاهش قابل ملاحظه‌ی ابعاد بردار ویژگی به دلیل استفاده از دو نقشه‌ی سری زمانی NDVI و LST در مقابل ۷ باند طیفی لندست-۸ و

- ۴- عدم استفاده از روش‌های مبتنی بر آستانه گذاری به دلیل وابستگی به منطقه (مانند الگوریتم‌های فنولوژی مبنا) اشاره نمود. در مطالعات آینده، با توجه به اینکه امکان عدم شناسایی مزارع برنج با وسعت کوچک‌تر هنگام استفاده از تصاویر لندست-۸ وجود دارد، به منظور غلبه بر چالش فوق و

بر اساس ارزیابی بصری، هنگام استفاده از نقشه‌های شاخص تفاضلی پوشش گیاهی نرمال شده (NDVI)، برخی از مزارع کشاورزی مانند کلاس‌های مربوط به کشت پنبه، لوبیای سبز، گوجه فرنگی، ذرت، و زمین‌های آیش، که در کلاس برنج قرار گرفتند، به کمک نقشه‌ی سری زمانی شاخص پیشنهادی و با استفاده از طبقه‌بندی‌کننده‌های یادگیری ماشین از نقشه‌ی نهایی مزارع برنج حذف شدند. به‌عنوان مثال با توجه به نگاره ۵ مزارع برنج قبل از کاشت غرقابی می‌شوند. در زمان قبل از غرقابی بودن، مزارع برنج با توجه به ویژگی گسیلمندی متفاوت آب با خاک، اختلاف دمای ۸ درجه با کلاس آب دارند. زمانی که مزارع برنج غرقابی می‌شوند دمای آب و مزارع برنج به یکدیگر نزدیک می‌شوند و با برداشت محصول برنج تفاوت دمایی ۴ درجه بین دمای کلاس آب و مزارع برنج مشاهده می‌شود. ویژگی فوق با کاهش خطای نوع اول باعث بهبود دقت شناسایی مزارع برنج می‌شود. علاوه بر این، در میان طبقه‌بندی‌کننده‌های یادگیری ماشین، الگوریتم درخت تصمیم‌گیری (DT)، عملکرد نامناسبی در لبه‌ها نشان داد.



نگاره ۵: تغییرات دمای سطح زمین برای ۴ کلاس آب، پنبه، برنج و لوبیای خشک

از نتایج عددی تحقیق فوق می‌توان به مواردی همچون:

- ۱- دقت بالای روش ماشین بردار پشتیبان (SVM) نسبت به سایر روش‌ها با دقت کلی ۹۴/۲۸ درصد و ضریب

series supplemented by Sentinel-2 images on Google Earth Engine. *Remote Sensing*, 12(10), 1622.

9- Li, H., Fu, D., Huang, C., Su, F., Liu, Q., Liu, G., & Wu, S. (2020). An Approach to High-Resolution Rice Paddy Mapping Using Time-Series Sentinel-1 SAR Data in the Mun River Basin, Thailand. *Remote Sensing*, 12(23), 3959.

10- Liu, L., Huang, J., Xiong, Q., Zhang, H., Song, P., Huang, Y., Dou, Y., & Wang, X. (2020). Optimal MODIS data processing for accurate multi-year paddy rice area mapping in China. *GIScience & Remote Sensing*, 57(5), 687–703. <https://doi.org/10.1080/15481603.2020.1773012>

11- Mansaray, L. R., Huang, W., Zhang, D., Huang, J., & Li, J. (2017). Mapping rice fields in urban Shanghai, southeast China, using Sentinel-1A and Landsat 8 datasets. *Remote Sensing*, 9(3), 257.

12- Mosleh, M. K., Hassan, Q. K., & Chowdhury, E. H. (2015). Application of remote sensors in mapping rice area and forecasting its production: A review. *Sensors*, 15(1), 769–791.

13- Murtagh, F. (1991). Multilayer perceptrons for classification and regression. *Neurocomputing*, 2(5–6), 183–197.

14- Priyam, A., Abhijeeta, G. R., Rathee, A., & Srivastava, S. (2013). Comparative analysis of decision tree classification algorithms. *International Journal of Current Engineering and Technology*, 3(2), 334–337.

15- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA Special Publication*, 351(1974), 309.

16- Talema, T., & Hailu, B. T. (2020). Mapping rice crop using sentinels (1 SAR and 2 MSI) images in tropical area: A case study in Fogera wereda, Ethiopia. *Remote Sensing Applications: Society and Environment*, 18, 100290.

17- Thimm, G., & Fiesler, E. (1995). Neural network initialization. *International Workshop on Artificial Neural Networks*, 535–542.

18- Wahlberg, B., Boyd, S., Annergren, M., & Wang, Y. (2012). An ADMM Algorithm for a Class of Total Variation Regularized Estimation Problems*. *IFAC*

به‌کارگیری شاخص دمای سطح زمین تلفیق تصاویر سنتینل-۲ و لندست-۸ و همچنین برای غلبه بر مناطق مزارع برنج پوشیده از ابر تلفیق تصاویر لندست-۸ و سنتینل-۲/۱ با الگوریتم‌های یادگیری عمیق به‌منظور بهبود دقت شناسایی مزارع برنج پیشنهاد می‌شود.

۶- منابع و مأخذ

1- Artis, D. A., & Carnahan, W. H. (1982). Survey of emissivity variability in thermography of urban areas. *Remote Sensing of Environment*, 12(4), 313–329.

2- Chang, L., Chen, Y.-T., Wang, J.-H., & Chang, Y.-L. (2021). Rice-Field Mapping with Sentinel-1A SAR Time-Series Data. *Remote Sensing*, 13(1), 103.

3- Chen, N., Yu, L., Zhang, X., Shen, Y., Zeng, L., Hu, Q., & Niyogi, D. (2020). Mapping paddy rice fields by combining multi-temporal vegetation index and synthetic aperture radar remote sensing data using google earth engine machine learning platform. *Remote Sensing*, 12(18), 2992.

4- Ding, M., Guan, Q., Li, L., Zhang, H., Liu, C., & Zhang, L. (2020). Phenology-based rice paddy mapping using multi-source satellite imagery and a fusion algorithm applied to the Poyang Lake Plain, Southern China. *Remote Sensing*, 12(6), 1022.

5- Dong, J., Xiao, X., Menarguez, M. A., Zhang, G., Qin, Y., Thau, D., Biradar, C., & Moore, B. (2016). Mapping paddy rice planting area in northeastern Asia with Landsat 8 images, phenology-based algorithm and Google Earth Engine. *Remote Sensing of Environment*, 185, 142–154. <https://doi.org/10.1016/j.rse.2016.02.016>

6- Dreiseitl, S., & Ohno-Machado, L. (2002). Logistic regression and artificial neural network classification models: A methodology review. *Journal of Biomedical Informatics*, 35(5–6), 352–359.

7- Guo, G., Wang, H., Bell, D., Bi, Y., & Greer, K. (2003). KNN model-based approach in classification. *OTM Confederated International Conferences” On the Move to Meaningful Internet Systems”*, 986–996.

8- Inoue, S., Ito, A., & Yonezawa, C. (2020). Mapping Paddy fields in Japan by using a Sentinel-1 SAR time

- noisy labels. 32nd Conference on Neural Information Processing Systems (NeurIPS). Proceedings Volumes, 45(16), 83–88. <https://doi.org/10.3182/20120711-3-BE-2027.00310>
- 19- Wang, J., Huang, J., Wang, X., Jin, M., Zhou, Z., Guo, Q., Zhao, Z., Huang, W., Zhang, Y., & Song, X. (2015). Estimation of rice phenology date using integrated HJ-1 CCD and Landsat-8 OLI vegetation indices time-series images. *Journal of Zhejiang University-SCIENCE B*, 16(10), 832–844.
- 20- Wang, Y., Zang, S., & Tian, Y. (2020). Mapping paddy rice with the random forest algorithm using MODIS and SMAP time series. *Chaos, Solitons & Fractals*, 140, 110116.
- 21- Yang, Z., Shao, Y., Li, K., Liu, Q., Liu, L., & Brisco, B. (2017). An improved scheme for rice phenology estimation based on time-series multispectral HJ-1A/B and polarimetric RADARSAT-2 data. *Remote Sensing of Environment*, 195, 184–201.
- 22- Yonezawa, C., & Watanabe, M. (2020). Analysis of the applicability of multi-temporal full polarimetric airborne L-band SAR scattering to paddy rice field mapping. *International Journal of Remote Sensing*, 41(7), 2500–2516.
- 23- Yue, S., Li, P., & Hao, P. (2003). SVM classification: Its contents and challenges. *Applied Mathematics-A Journal of Chinese Universities*, 18(3), 332–342.
- 24- Zhan, P., Zhu, W., & Li, N. (2021). An automated rice mapping method based on flooding signals in synthetic aperture radar time series. *Remote Sensing of Environment*, 252, 112112.
- 25- Zhang, Z., & Sabuncu, M. R. (2018). Generalized cross entropy loss for training deep neural networks with

COPYRIGHTS

©2023 by the authors. Published by National Geographical Organization. This article is an open access article distributed under the terms and conditions of the Creative Commons [Attribution-NoDerivs 3.0 Unported \(CC BY-ND 3.0\)](https://creativecommons.org/licenses/by-nd/3.0/)

