

برآورد تغییرات سطح زیر کشت گندم و سویا با استفاده از طبقه بندی تصاویر ماهواره ای در غرب استان گلستان

Estimation of changes in land area under wheat and soybean cultivation using satellite images classification techniques in west of Golestan province

پریسا علی زاده^۱، بهنام کامکار^{۲*}، شعبان شتایی^۳ و حسین کاظمی^۴

۱. دانشجوی دکتری، دانشگاه علوم کشاورزی و منابع طبیعی گرگان- دانشکده تولید گیاهی- گروه زراعت
۲. استاد، دانشگاه علوم کشاورزی و منابع طبیعی گرگان- دانشکده تولید گیاهی- گروه زراعت. (نگارنده مسئول)
۳. استاد، دانشگاه علوم کشاورزی و منابع طبیعی گرگان- دانشکده علوم جنگل- گروه جنگلداری
۴. استادیار، دانشگاه علوم کشاورزی و منابع طبیعی گرگان- دانشکده تولید گیاهی- گروه زراعت

تاریخ دریافت: ۱۳۹۷/۰۱/۰۷ تاریخ پذیرش: ۱۳۹۷/۰۷/۲۹

چکیده

علی زاده، پ. کامکار، ب. شتایی، ش. کاظمی، ح. برآورد تغییرات سطح زیر کشت گندم و سویا با استفاده از طبقه بندی تصاویر ماهواره ای در غرب استان گلستان
نشریه پژوهش های کاربردی زراعی دوره ۳۱ - شماره ۳ - پایبند ۱۲۰ پائیز ۹۷: ۶۱-۴۱

برآورد سطح زیر کشت بر اساس شاخص های جنبی از جمله میزان بذر، کود و سم تحویل شده به کشاورزان و همچنین برآوردهای شرکت های مشاور کنترل می گردد که کاری زمان بر و پرهزینه می باشد. امروزه بهره گیری از داده های ماهواره ای بعنوان راهکاری جدید نه تنها کاستی های ناشی از روش های رایج برآورد سطح زیر کشت را کاهش می دهد، بلکه می تواند در امر برنامه ریزی های مختلف در حوزه کشاورزی نیز کارگشا باشد؛ بنابراین این مطالعه با هدف برآورد سطح زیر کشت دو محصول گندم و سویا در طی سال های ۲۰۰۰ تا ۲۰۱۶ با استفاده از تصاویر ماهواره لندست انجام شد. بعد از پیش پردازش و پردازش های لازم، و تهیه نمونه های تعلیمی مناسب از مزارع کشت سویا و گندم، طبقه بندی تصاویر با استفاده از دو روش طبقه بندی شبکه عصبی مصنوعی و ماشین بردار پشتیبان انجام شد و جهت طبقه بندی با هدف تفکیک این دو محصول زراعی داده های واقعیت زمینی، نقشه NDVI اراضی زراعی و شناسایی رفتار طیفی نقاط آموزشی گندم و سویا بکار برده شدند. نقشه های حاصل از طبقه بندی با استفاده از نقاط واقعیت زمینی مورد ارزیابی صحت قرار گرفتند. با توجه به نتایج به دست آمده از بررسی ضریب کاپا و صحت کلی، روش ماشین بردار پشتیبان برای طبقه بندی اراضی کشاورزی و تفکیک محصولات نسبت به روش شبکه عصبی موفق تر بود و در همه تصاویر مقدار صحت کلی محاسبه شده و ضریب کاپا به ترتیب بیشتر از ۸۰٪ و بیش از ۰/۸ می باشد که این نشان دهنده قابل اعتماد بودن نتایج طبقه بندی است. طبق نتایج، حدود ۹۳ درصد از نقاط برآورد شده سطح زیر کشت گندم و سویا در طی ۱۶ سال مورد مطالعه در محدوده حدود اطمینان ± 15 درصد قرار دارند که نشان می دهد این روش، روش مطمئنی برای تفکیک این دو محصول با استفاده از تصاویر اردیبهشت ماه (برای گندم) و شهریور ماه (برای سویا) می باشد.

واژه های کلیدی: سنجش از دور، طبقه بندی، شبکه عصبی مصنوعی، ماشین بردار پشتیبان

آدرس پست الکترونیکی نگارنده مسئول: behnam.kamkar@gmail.com

مقدمه

دقت طبقه بندی ها تلاش وسیع و گسترده ای را انجام داده اند و روش های شبکه عصبی مصنوعی^۱، منطق فازی^۲، ماشین بردار پشتیبان^۳، درخت تصمیم گیری^۴، طبقه بندی شیء گرا^۵ و سیستم های هوشمند^۶ را به عنوان روش های پیشرفته بیان کرده اند (Richards, 2013; Guo *et al.*, 2012; Lu & Weng, 2007). در مطالعه ای در تایلند به مقایسه روش های مختلف طبقه بندی تصاویر ماهواره ASTER جهت تهیه نقشه کاربری اراضی پرداختند و نتایج آن ها نشان داد که از بین روش های ماشین بردار پشتیبان، شبکه عصبی و حداکثر احتمال، روش ماشین بردار پشتیبان با صحت کلی ۹۴/۱۵ درصد دارای بالاترین کارایی می باشد (Brian *et al.*, 2011). همچنین در مطالعه ای دیگر در ترکیه برای طبقه بندی کاربری اراضی از تصاویر ماهواره لندست استفاده کردند. نتایج مطالعه با روش ماشین بردار پشتیبان (چند جمله ای و شعاعی) نشان داد که کرنل شعاعی دقت بالاتری نسبت به چند جمله ای دارد. همچنین دقت این روش با روش حداکثر احتمال مقایسه شد و نتایج نشان داد که ماشین بردار پشتیبان دارای دقت بیشتری بود (Kavzoglu & Colkesen, 2009). فودی و متور (Foody & Mathur, 2006) روش طبقه بندی ماشین بردار پشتیبان را جهت استخراج سه کلاس گندم، جو بهار و چغندر قند بر روی تصاویر سنجنده SPOT HR به کار بردند. نتایج این

کشاورزی یکی از منابع کلیدی در تأمین نیاز غذایی برای مردم هر کشور بوده و از اهمیت ویژه ای برخوردار است (Marsden *et al.*, 1999). همچنین استفاده بهینه از زمین های کشاورزی یکی از دغدغه های مسئولان کشوری و استانی می باشد که فواید استفاده از روش های کمی در برآورد واقعی سطح زیر کشت محصولات را مشخص می نماید. در سال های اخیر وضعیت برآورد سطح زیر کشت تا حدودی اصلاح شده و بر اساس شاخص های جنبی از جمله میزان بذر، کود و سم تحویل شده به کشاورزان و همچنین برآوردهای شرکت های مشاور کنترل می گردد، همچنین با توجه به مکانیزه نبودن تمامی اراضی کشاورزی شهرستان، وجود واسطه های فروش بذر، سم و کود، ذخیره سازی توسط کشاورزان و فروش در بازار آزاد برآورد سطح زیر کشت در سطح شهرستان کاری زمان بر و پرهزینه می باشد (Amini *et al.*, 2013). یکی از روش های مناسب، کم هزینه و سریع در تکمیل اطلاعات سطح زیر کشت محصولات کشاورزی استفاده از تصاویر ماهواره ای است (Zahedifard, 2002). طبقه بندی و تهیه نقشه کاربری های اراضی با استفاده از تصاویر ماهواره ای یکی از پرکاربردترین موارد استفاده از فن آوری سنجنش از دور می باشد. طبقه بندی کننده ها می توانند به دو دسته عمومی و پیشرفته تقسیم شوند. از روش های طبقه بندی عمومی می توان به روش حداکثر احتمال و کمترین فاصله اشاره کرد. محققان در راستای توسعه روش ها و تکنیک های پیشرفته طبقه بندی جهت بهبود

- 1 - Artificial Neural Network
- ۲ - Fuzzy logic
- 3 - Support Vector Machine
- 4 - Decision tree
- 5 - Object-oriented
- 6 - Intelligent systems

نتایج، دقت بالای طبقه بندی های شبکه عصبی مصنوعی و ماشین بردار پشتیبان با کرنل شعاعی، هر کدام به ترتیب با صحت کلی ۹۰/۶۷ و ۹۱/۶۷ درصد را نشان داد. همچنین در قسمت های مرزی بین کلاسه ها، روش ماشین بردار پشتیبان قابلیت جداسازی بهتری نسبت به روش شبکه عصبی مصنوعی داشت و مرز بین دو کلاس ملموس تر بود. در واقع دقت بالای ماشین بردار پشتیبان می تواند ناشی از مرز تصمیم گیری بهینه آن باشد، در حالی که شبکه عصبی نمی تواند این مرز را ایجاد کند.

همچنین با استفاده از شاخص های گیاهی SAVI و NDVI تصاویر ماهواره لندست ۷ به برآورد سطح زیر کشت در دشت بهار همدان پرداخته شده است و نتایج نشان داده است که سطح زیر کشت برآورد شده از اطلاعات سنجنش از دور به علت تاریخ مناسب تصویر انتخاب شده، مطابقت خوبی با آمار سازمان جهاد کشاورزی دارد (Amini Bazayani *et al.*, 2013).

سفیانیان و همکاران (Safiyanian *et al.*, 2011) جهت تهیه نقشه پوشش اراضی محصولات جو، یونجه و سیب زمینی در استان همدان از داده های رقومی ماهواره IRSP-6 استفاده کردند. جهت طبقه بندی تصویر از روش طبقه بندی شبکه عصبی مصنوعی پرسپترون سه لایه استفاده شد و ضریب کاپا و دقت کلی طبقه بندی به ترتیب ۸۶ و ۸۸ درصد برآورد شد. در تحقیق دیگری، با استفاده از تصاویر فراطیفی هایپرون سطح زیر کشت دو محصول گندم و جو را در زمین های کشاورزی جنوب تهران

بررسی نشان داد که صحت کلی نقشه طبقه بندی گندم و جو به ترتیب حدود ۸۰ و ۷۶ درصد بوده است. هانگ و همکاران (Hung *et al.*, 2002) میزان دقت روش طبقه بندی ماشین بردار پشتیبان که با کرنل های مختلف انجام شده بود را با روش های شبکه عصبی، حداکثر احتمال و درخت تصمیم گیری مقایسه کردند. با توجه به نتایج این مطالعه روش ماشین بردار پشتیبان در مقایسه با روش های دیگر بیشترین دقت و روش حداکثر احتمال، کمترین دقت را داشت.

در ایران نیز رحیم زادگان و پورغلامی (Rahimzadegan & Pourgholami, 2017) جهت شناسایی سطح زیر کشت محصول زعفران در شهرستان تربت حیدریه با استفاده از تصاویر ماهواره ای لندست به مقایسه روش های طبقه بندی شبکه عصبی مصنوعی، ماشین بردار پشتیبان، حداکثر احتمال^۷، حداکثر فاصله^۸ و متوازی السطوح^۹ پرداختند؛ و نتایج آن ها نشان داد سطح زیر کشت زعفران در طبقه بندی ماشین های بردار پشتیبان با صحت کلی ۹۵ درصد، ضریب کاپای ۰/۹ و خطای ۱۸ درصدی در مقایسه با آمار سازمان جهاد کشاورزی به عنوان بهترین روش قابل اعتماد است. همچنین، مختاری و نجفی (Mokhtari & Najafi, 2015) در استان مازندران به مقایسه کارایی دو الگوریتم طبقه بندی برای طبقه بندی پوشش زمین برای برآورد تغییرات با دو روش شبکه عصبی مصنوعی و ماشین بردار پشتیبان با استفاده از تصاویر ماهواره لندست پرداختند.

7 - Maximum Likelihood

8 - Maximum distance

9 - Parallelepiped

مساحت دارد و در مختصات $36^{\circ} 35'$ تا $38^{\circ} 8'$ عرض شمالی و $53^{\circ} 51'$ تا $56^{\circ} 22'$ طول شرقی قرار گرفته است. ارتفاع استان از سطح دریا در دامنه ۲۷۱- تا ۳۸۲۱ متر قرار دارد که از سمت جنوب به سمت شمال استان روند کاهشی دارد. میانگین بلند مدت بارش و دمای هوا به ترتیب ۵۰۰ میلی متر و ۱۸ درجه سانتی گراد است (<http://www.ganrrc.org.ir>).

منطقه مورد مطالعه در ۶ شهرستان آق قلا، گرگان، علی آباد، کردکوی و بندر گز و بندر ترکمن قرار دارد که مساحت اراضی کشاورزی در این محدوده حدوداً ۳۰۷ هزار هکتار می باشد (شکل ۱). در این استان، سالانه به طور متوسط ۳۵۹ هزار هکتار از اراضی زراعی به کشت گندم اختصاص می یابد که از این مقدار ۱۲۰ هزار هکتار در محدوده مورد مطالعه می باشد. همچنین از ۴۹ هزار هکتار سطح زیر کشت سویا در استان، حدود ۳۵ هزار هکتار مربوط به ۶ شهرستان ذکر شده می باشد (Ministry of Agriculture Jihad, 2016).

داده های مورد استفاده

اطلاعات مورد استفاده در منطقه مورد مطالعه شامل تصاویر طیف نوری ماهواره لندست، لایه کاربری اراضی زراعی، آمار و اطلاعات مربوط به محصولات کشاورزی منطقه به ویژه گندم و سویا و تقویم زراعی می باشد. با توجه به اینکه رفتار طیفی محصولات کشاورزی مختلف در طول دوره رشد (تقویم زراعی) متفاوت است، در یک زمان خاص نمی توان تمامی محصولات را در وضعیت یکسان از دوره رشد، در تصویر مشاهده نمود.

با ارزیابی روش های طبقه بندی نظارت شده ماشین بردار پشتیبان، حداکثر احتمال و کمترین فاصله ارزیابی کردند. براساس نتایج، ماشین های بردار پشتیبان با صحت کلی ۹۵ درصد و ضریب کاپای ۹۰ درصد نسبت به روش های دیگر دقت بالاتری داشتند (Fahimnejad et al., 2008).

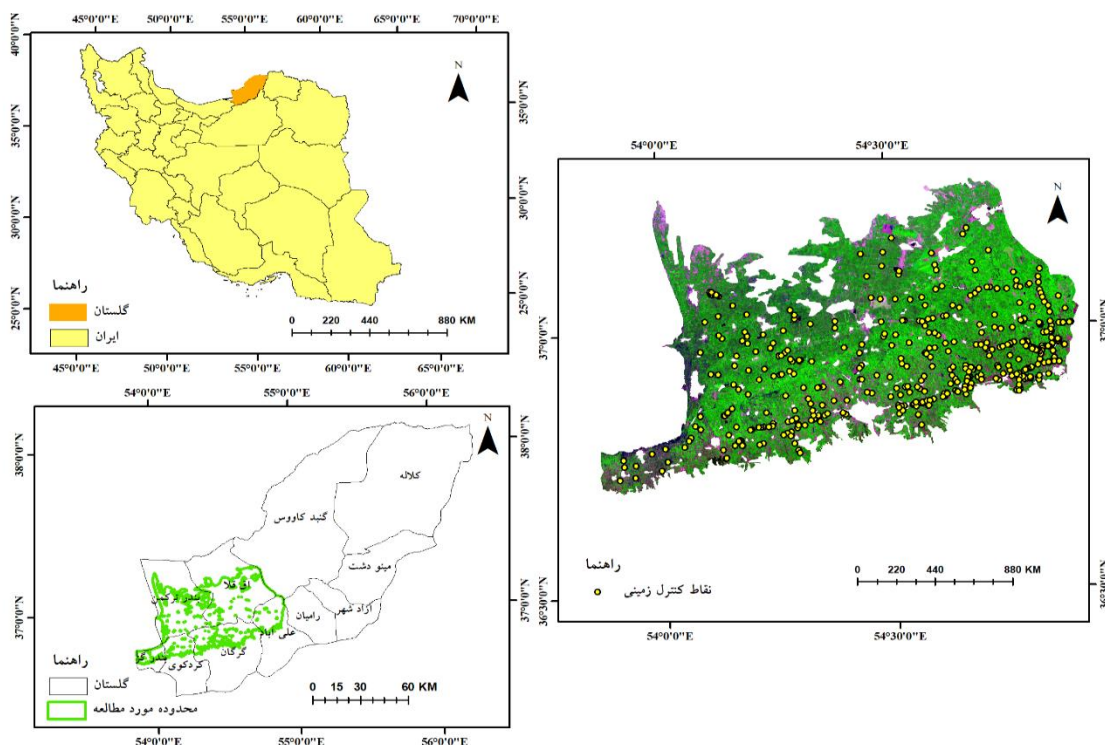
جهت تعیین سطح زیر کشت محصول گندم از تصویر ماهواره TERRA در استان خراسان رضوی استفاده شد و در این مطالعه از تصاویر ۱۶ روزه NDVI سنجنده MODIS برای برآورد استفاده کردند. نتیجه کار نشان داد که سنجنده مذکور قابلیت برآورد سطح زیر کشت را داشته است (Sanaiee Nejad, 2008). قاسم لو و همکاران (Qasemlou et al., 2009) با استفاده از ویژگی های طیفی و شبکه عصبی مصنوعی و تصویر هایپریون، اقدام به تشخیص گیاه یونجه در اراضی کشاورزی جنوب تهران کردند.

در مطالعه حاضر سعی بر آن است تا با بهره گیری از دو روش پیشرفته طبقه بندی، ماشین بردار پشتیبان و شبکه عصبی مصنوعی، نقشه پراکندگی و سطح زیر کشت دو محصول عمده گندم و سویا در غرب استان گلستان با استفاده از تصاویر ماهواره ای لندست تهیه گردد و لایه کاربری به دست آمده از این مطالعات به عنوان لایه ای پایه جهت ارزیابی بوم نظام های کشاورزی و طراحی الگوی کشت مناسب این گیاهان مورد استفاده قرار گیرد.

مواد و روش ها

منطقه مورد مطالعه

استان گلستان حدود ۲۰۴۳۸ کیلومتر مربع

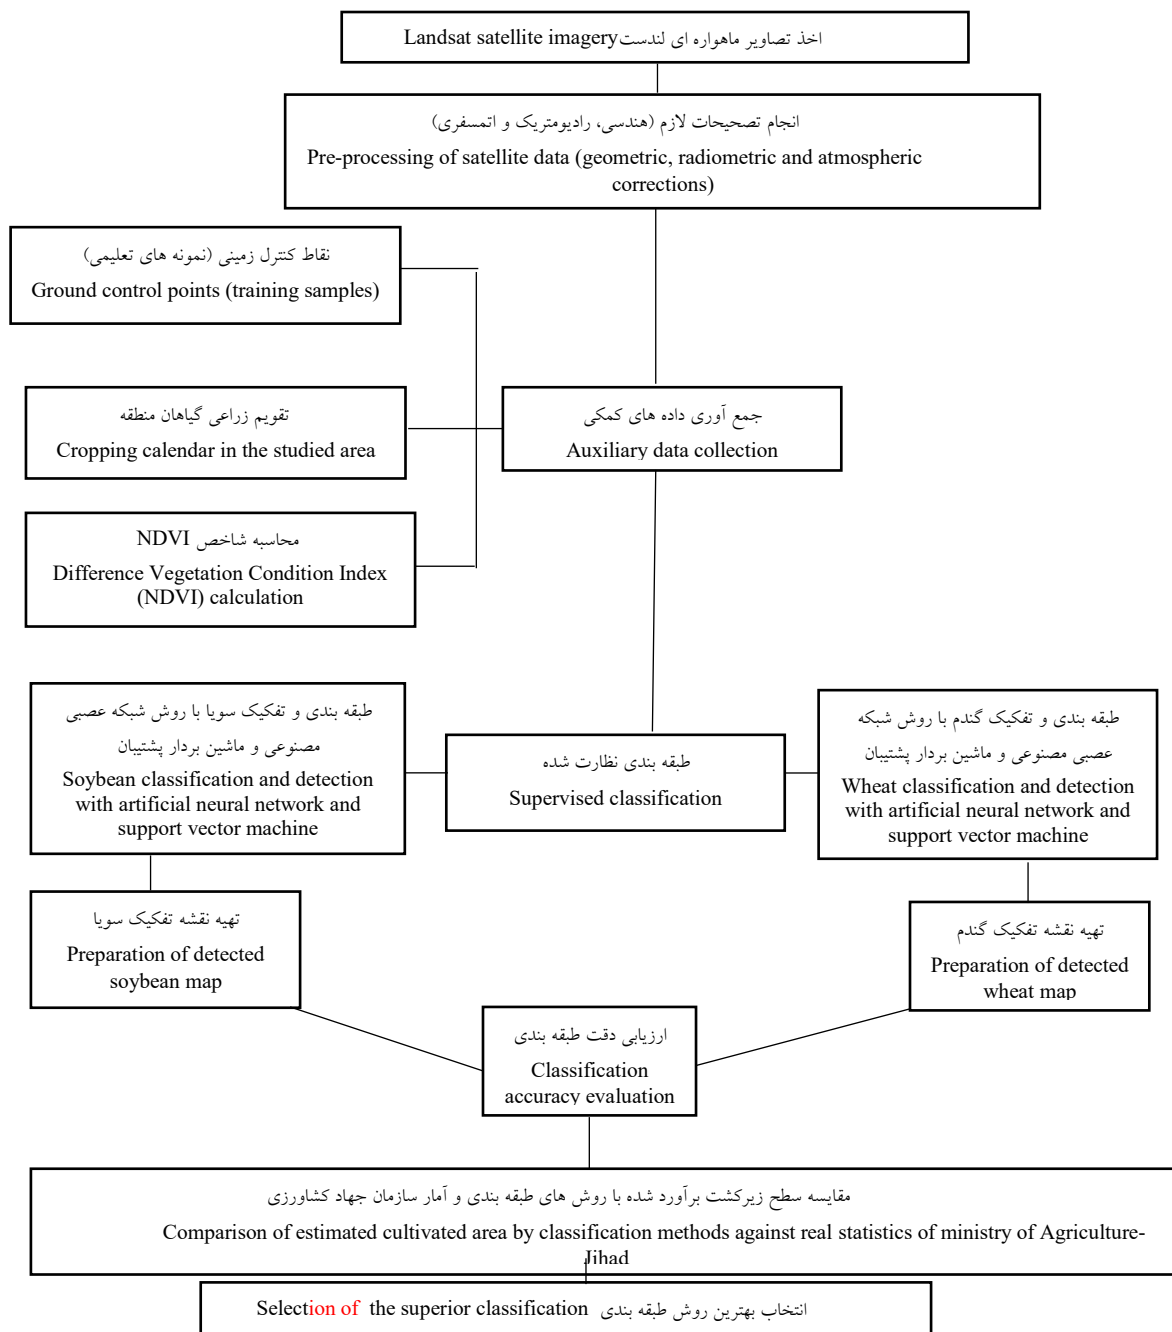


شکل ۱- محدوده منطقه مورد مطالعه، اراضی زراعی و نقاط کنترل زمینی مورد استفاده در تحقیق
Figure 1. The range of the studied area, farming lands and ground control points

با بیشترین سبزیگی مربوط به محصولات گندم و سویا شناسایی شده و تصاویر ماه اردیبهشت که گندم در اوج رشد خود قرار دارد برای تفکیک محصول گندم و تصاویر ماه شهریور برای تفکیک محصول سویا در هر سال انتخاب گردید و همه تصاویر بعد از انجام تصحیحات لازم به اندازه لایه اراضی زراعی محدوده مورد مطالعه برش زده شدند تا آشکارسازی پدیده‌ها در همه سال‌ها در محدوده یکسانی انجام پذیرد. لازم به ذکر است به دلیل ابری بودن تصاویر و عدم وجود تصاویر مناسب برای تاریخ‌های مورد نظر در زمان کشت گندم و سویا برخی از سال‌های بازه زمانی مورد مطالعه مورد بررسی قرار نگرفت. روند کلی مراحل انجام پژوهش در شکل ۲ ارائه شده است.

در این تحقیق از تصاویر ماهواره‌های لندست ۵، ۷ و ۸ با شماره ردیف و گذر ۱۶۲ و ۳۴ از سال ۲۰۰۰ میلادی تا سال ۲۰۱۶ از سایت سازمان زمین شناسی آمریکا (USGS) استفاده شد. علت انتخاب تصاویر ماهواره لندست قدرت تفکیک زمانی و مکانی نسبتاً مناسب، در دسترس و رایگان بودن آن‌ها و پراکنش زمانی مناسبی با دوره رشد گیاه گندم و سویا بود. برای استفاده از سری زمانی تصاویر ماهواره‌ای و تعیین دامنه زمانی مناسب به منظور استفاده از تصاویر، ابتدا با مراجعه به منطقه و پیمایش میدانی، با کمک کشاورزان و مالکان اراضی و کارشناسان سازمان جهاد کشاورزی به جمع‌آوری اطلاعات مربوط به تقویم زراعی محصولات مختلف منطقه پرداخته شد. بازه‌های زمانی

10 - The United States Geological Survey



شکل ۲- الگوریتم مراحل کار
Figure 2. Flowchart of methodology steps

برف و آب دارای انعکاس بیشتری در طیف قرمز نسبت به مادون قرمز می‌باشند. مقادیر این پدیده‌ها در تصویر NDVI منفی می‌شود. بازتاب خاک در محدوده مادون قرمز و قرمز مشابه است، بنابراین در تصویر NDVI دارای ارزشی نزدیک به صفر هستند. مناطق با پوشش گیاهی متراکم دارای بازتاب بیشتری در طیف مادون قرمز بوده و این مناطق در تصویر NDVI بزرگتر از صفر است (Pôças *et al.*, 2013).

طبقه بندی تصاویر ماهواره ای

جهت طبقه بندی تصاویر ابتدا ۵۸۸ نمونه واقعیت زمینی از منطقه مورد مطالعه با استفاده از بازدید میدانی و برداشت نقاط کشت سویا و گندم با دستگاه GPS دستی و اطلاعات سازمان جهاد کشاورزی تهیه شدند (شکل ۱). ۷۰ درصد از داده ها جهت آموزش و طبقه بندی تصاویر ماهواره ای و ۳۰ درصد برای ارزیابی صحت نتایج بدست آمده از دو طبقه بندی ماشین بردار پشتیبان و شبکه عصبی مصنوعی به طور یکسان بکار گرفته شده است.

طبقه بندی نظارت شده ماشین بردار پشتیبان

(SVM¹²)

ماشین بردار پشتیبان یک گروه از الگوریتم های طبقه بندی نظارت شده یادگیری ماشینی بر مبنای نظریه یادگیری آماری هستند که در زمینه سنجش از دور مورد بررسی قرار گرفته اند (Foody & Mathur, 2006). ایده اساسی این طبقه بندی کننده، یافتن یک ابر صفحه بهینه به عنوان سطح تصمیم گیری و به گونه ای می باشد که فاصله بین دو کلاس را بیشینه کند.

12 -Support Vector Machine

پیش پردازش تصاویر ماهواره ای

جهت تصحیحات هندسی، تصاویر ماهواره لندست ۵ و ۷ با استفاده از ۲۵ نقطه کنترل و میزان خطای ریشه مربعات ۰/۱۹ تا ۰/۲۵ با تصاویر ماهواره لندست ۸ تطابق هندسی نسبی داده شدند. تصاویر لندست ۸ با توجه به سطح تصحیحات ارتو نیازی به تصحیحات هندسی مجدد نداشتند. جهت انجام تصحیح رادیومتریک، از ابزارهای radiometric calibration و gapfill در نرم افزار ENVI 5.3 استفاده شد. تصحیحات اتمسفری تصاویر ماهواره ای نیز با تبدیل (DN digital number) یا همان ارزش رقومی به میزان انرژی بازتابش و سپس انعکاس (reflectance) با استفاده از الگوریتم FLASH در نرم افزار ENVI 5.3 صورت گرفت.

پردازش تصاویر

ایجاد شاخص گیاهی^{۱۱} NDVI

این شاخص از مشهورترین شاخص های گیاهی است که در بیشتر تحقیقات و بررسی های ماهواره ای برای تعیین شدت و ضعف پوشش گیاهی استفاده شده است. در این شاخص محدوده طیفی مادون قرمز نزدیک و قرمز بکار گرفته شده است (Pôças *et al.*, 2013)، که این شاخص از رابطه ۱ بدست می آید.

رابطه (۱)

$$NDVI = \frac{(NIR - R)}{(NIR + R)}$$

که در این رابطه NIR تابش ثبت شده در باند مادون قرمز نزدیک ماهواره و RED تابش ثبت شده در باند مادون قرمز ماهواره است. دامنه تغییرات این شاخص بین ۱ و -۱ می باشد. ابرها، Normalized Difference Vegetation Index - 11

یک پارامتر از قبل تعریف شده برای این کرنل در این مطالعه فقط از کرنل شعاعی استفاده گردید (Guo *et al.*, 2012; Jiang *et al.*, 2011; Petropoulos *et al.*, 2011).

طبقه بندی شبکه عصبی مصنوعی (ANN¹⁸)

برای طبقه بندی شبکه عصبی از پرسپترون چند لایه استفاده شد. تعداد ۷ نرون ورودی شامل ۷ باند طیفی در نظر گرفته شد. بر اساس یافته های قبلی شبکه هایی با یک لایه پنهان برای طبقه بندی مناسب تر هستند و تعداد نرون های پنهان با آزمون و خطا تعیین و غالباً سه برابر تعداد نرون های ورودی انتخاب می شوند (Petropoulos *et al.*, 2011). نرون های خروجی نیز به تعداد ۴ عدد به منزله تعداد کلاس های طبقه بندی در نظر گرفته شد. همچنین جهت ایجاد شبکه بهینه برای طبقه بندی تصاویر در این مطالعه سرعت یادگیری ۰/۲ و گشتاور ۰/۵ برای شبکه در نظر گرفته شد.

ارزیابی صحت

به منظور ارزیابی صحت طبقه بندی در این تحقیق از ضریب صحت کلی^{۱۹} و ضریب کاپا^{۲۰} استفاده شد. صحت کلی یکی از ساده ترین پارامترهای دقت است که نیاز به عملیات پیچیده ای برای محاسبه نداشته و برآوردی کلی از دقت طبقه بندی یا به اصطلاح دقیق تر، میانگینی از دقت طبقه بندی است. یکی دیگر از پارامترهای دقت که از ماتریس خطا^{۲۱} استخراج می شود ضریب کاپا است که دقت طبقه بندی را

داده های نزدیک تر به ابر صفحه، بردار های پشتیبان^{۱۳} نامیده می شوند. در صورتی که داده ها به صورت خطی جداپذیر نباشند، داده ها با کرنلی غیرخطی به فضای با ابعاد بالاتر منتقل می شود و ابر صفحه بهینه در آن فضا تعیین می شود (Kavzoglu & Colkesen, 2009; Samadzadegan & Hassani, 2012).

فرض کنید I داده های آموزشی موجود می باشد که هر یک با (xi, yi) نشان داده می شود، xi بردار ویژگی n بعدی و yi ∈ {-1, 1} برچسب آن می باشد. هدف، یافتن ابر صفحه است که دو کلاس با برچسب ۱ و -۱ را با بیشترین حاشیه از هم جدا کند. این ابر صفحه را می توان با رابطه ۲ بیان کرد.

رابطه (۲)

$$W^T \phi(X) + b = 0$$

در این رابطه، بردار وزن w، برداری عمود برابر صفحه و b بردار بایاس (اریبی) می باشد که به منظور اندازه گیری فاصله ابر صفحه تا مبدأ استفاده می شود و $\phi(\cdot)$ کرنلی برای انتقال داده به فضای با ابعاد بالاتر می باشد (شکل ۳).

بطور کلی چهار نوع کرنل برای طبقه بندی ماشین بردار پشتیبان به نام های خطی^{۱۴}، چند جمله ای^{۱۵}، شعاعی^{۱۶} و سیگموئیدی^{۱۷} وجود دارند. در این تحقیق با توجه به استفاده وسیع در طبقه بندی اراضی و مطالعه تغییر کاربری اراضی با داده های ماهواره ای، عملکرد بهتر کرنل شعاعی نسبت به کرنل های دیگر و نیاز به فقط

13 - Support Vector

14 - Linear

15 - Polynomial

16 - Radial Basic Function

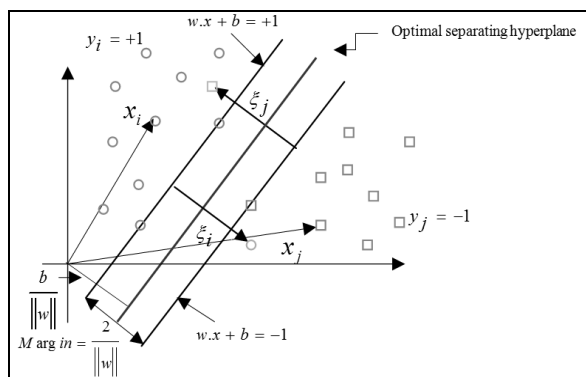
17 - Sigmoid

18 - Artificial Neural Networks

19 - Overall Accuracy

20 - Kapa Coefficient

21 - Matrix Confusion



شکل ۳ - طبقه‌بندی توسط ماشین‌های بردار پشتیبان برای داده‌هایی که به صورت خطی جداپذیر نیستند.

Figure 3. The vector support machine method of classification for data that are not linearly separable (Samadzadegan and Hassani, 2012).


طبقه‌بندی و ۳۰ درصد نیز برای صحت سنجی استفاده شد.

نتایج و بحث

در مطالعه حاضر به دلیل عدم دسترسی به نقاط کنترل زمینی محصولات در منطقه مورد مطالعه برای سال‌های اول دوره مورد مطالعه با ترکیب باندی مناسب از طریق تفسیر تصاویر رنگی کاذب و مناطقی که بر اساس اطلاعات سازمان جهاد کشاورزی در طی زمان تغییر نکرده‌اند، استفاده شد. با توجه به این که هر پدیده‌ای طول موج انعکاسی خاصی دارد با بررسی این طول موج‌ها می‌توان محدوده را شناسایی کرد که در آن پدیده یا گیاه مورد نظر از حداکثر انعکاس یا حداقل انعکاس برخوردار است. به بیان دیگر هر گیاهی می‌تواند منحنی انعکاسی طیفی ویژه‌ای داشته باشد که با گیاهان دیگر متفاوت است (Rangzan et al., 2011). تفاوت دوره رشد گیاهان در شناسایی رفتار طیفی آن‌ها مؤثر می‌باشد. در شکل ۴ تفاوت بازتاب طیفی دو محصول سویا و گندم در اوج دوره رشد با نقاط کنترلی بر روی تصاویر لندست ماه اردیبهشت و

نسبت به یک طبقه‌بندی کاملاً تصادفی محاسبه می‌کند و در واقع نشان‌دهنده توافق به دست آمده از طبقه‌بندی با داده‌های واقعیت زمینی می‌باشد. دامنه ضریب کاپا بین ۰ و ۱ می‌باشد که عدد یک بیانگر توافق صد در صد طبقه‌بندی با واقعیت زمینی می‌باشد (Mather, 2009). چووانگا و همکاران (Chuang et al., 2011) بیان کردند که چنانچه صحت کلی در نقشه‌های تولیدشده بیش از ۷۰ درصد باشد صحت نقشه‌های تولیدی قابل اعتماد است.

به منظور برآورد سطح زیر کشت دو محصول گندم و سویا ابتدا محدوده زراعی با استفاده از نقشه کاربری اراضی از تصاویر منطقه مورد مطالعه برای هر سال جدا شد. سپس در مرحله بعد شاخص NDVI هر سال تهیه شد. به دلیل اینکه تصاویر انتخاب شده در مرحله اوج رشد گیاه گندم و سویا بوده‌اند، مقادیر بیشتر از ۰/۲ انتخاب و از تصویر NDVI جدا شد. برای طبقه‌بندی از نقاط کنترل زمینی (ثابت شده با GPS) برای محصولات مختلف استفاده شد؛ بطوریکه ۷۰ درصد از آن‌ها برای روند



شکل ۴- نمودار رفتار طیفی گندم و سویا در دوره اوج سبزیگی بر روی تصاویر لندست ۸
Figure 4. Spectral behavior of wheat and soybean during the maximum vegetation growth on Landsat8 images.

محصول گندم با اعمال طبقه‌بندی کننده های شبکه عصبی مصنوعی و ماشین بردار پشتیبان از تصاویر اردیبهشت ماه تفکیک شد. دلیل انتخاب این روش نتایج قابل قبول در تحقیقات قبلی بوده است (Mokhtari & Najafi, 2015). تصاویر به ۴ کلاس گندم، جو، کلزا و سایر محصولات تفکیک گردید. سپس با استفاده از شاخص اعتبارسنجی کاپا و دقت کلی، صحت طبقه‌بندی تصاویر بررسی شد. چون هدف تفکیک گندم از سایر محصولات بوده، بنابراین دقت طبقه‌بندی کلاس گندم بسیار حائز اهمیت بوده و پس از صحت سنجی، کلاس گندم از بقیه جدا شد. تقویم زراعی محصولات کشاورزی در منطقه مورد مطالعه نشان می‌دهد که محصولات کلزا و جو دوره رشد نزدیک به گیاه گندم را دارند؛ بنابراین انتخاب درست زمان تصاویر استفاده شده بر دقت کار بسیار مؤثر است. تصاویر انتخاب شده مربوط به زمانی است (اردیبهشت ماه) که گندم در اوج سبزیگی خود قرار دارد و دو گیاه جو و کلزا دوران سبزیگی خود را سپری کرده و در مرحله زرد

شهریور سال ۲۰۱۶ برای نمونه مشاهده می‌شود. بر اساس شکل ۴ مشاهده می‌شود نمودار رفتار طیفی هر دو محصول در دوره اوج سبزیگی شبیه به هم بوده، اما در محدوده طیفی ماورای بنفش و آبی و به میزان ناچیزی در محدوده مادون قرمز میانی باهم تفاوت دارند.

در جدول ۱ دوره رشد گیاهان منطقه مورد مطالعه ارائه شده است. با توجه به تقویم زراعی منطقه محصول گندم، جو و کلزا در گیاهان پاییزه و برنج، سویا و ذرت در گیاهان تابستانه دوره شخم و کاشت یکسانی دارند، اما دوره اوج سبزیگی متفاوتی دارند و همین امر باعث عدم به وجود آمدن مشکلاتی نظیر بازتاب متفاوت مزارع محصولات مختلف در یک تصویر شده است.

همچنین نحوه کشت دو محصول گندم و سویا در منطقه مورد مطالعه به نوعی است که اکثر زمین‌های زراعی زیر کشت گندم پس از برداشت، به کشت سویا اختصاص می‌یابد، بنابراین تشخیص صحیح مناطق کشت گندم در تفکیک سویا نیز مؤثر است. بدین منظور، ابتدا

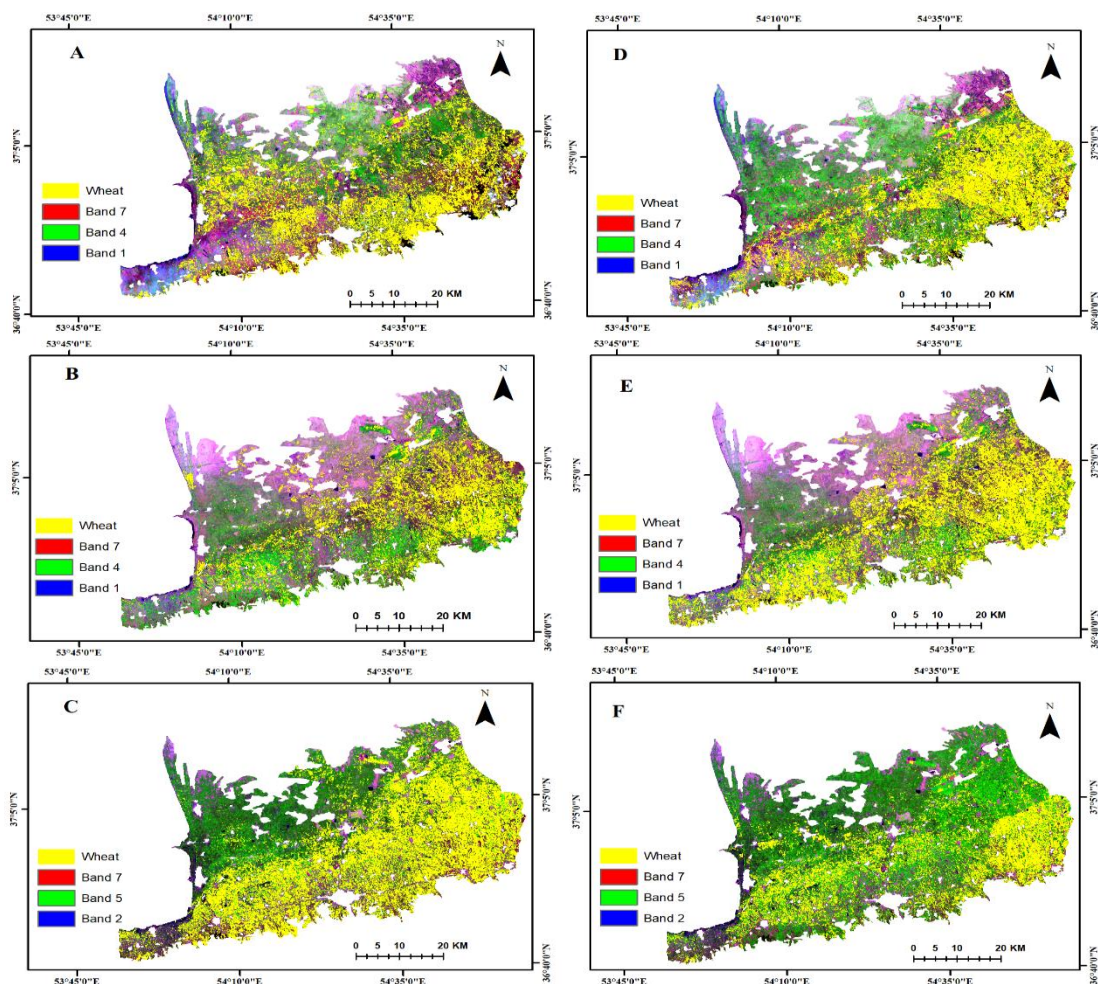
جدول ۱- تقویم زراعی محصولات کشاورزی در منطقه مورد مطالعه

Table 1. Cropping calendar in the studied area

محصول Crop	شخم Plowing	کاشت Sowing	اوج سبزیگی Maximum vegetation growth	زرد شدن Leaves senescing	برداشت Harvest
گندم Wheat	آبان و آذر November- December	آبان و آذر November- December	اواخر فروردین - اردیبهشت Late April-May	خرداد June	خرداد June
جو Barley	آبان و آذر November- December	آبان و آذر November- December	فروردین April	اردیبهشت May	اردیبهشت - خرداد May- June
کلزا Rapeseed	مهر و آبان-گاهی آذر October and November- Sometimes December	مهر -آبان October- November	فروردین April	اردیبهشت May	اردیبهشت - خرداد May- June
برنج Rice	خرداد- تیر June-July	خرداد- تیر June-July	مرداد August	شهریور -مهر September- October	شهریور - مهر September- October
سویا Soybean	خرداد- تیر June-July	خرداد- تیر June-July	اواخر مرداد- شهریور Late August- September	مهر -آبان October- November	مهر -آبان October- November
ذرت Maize	خرداد- تیر June-July	خرداد- تیر June-July	مرداد August	شهریور -مهر September- October	آبان -آذر November- December

با توجه تعدد تصاویر استفاده شده در این تحقیق در شکل های ۵ و ۶ نقشه های به دست آمده از دو روش طبقه بندی شده سه سال ۲۰۰۰، ۲۰۰۸ و ۲۰۱۶ (به ترتیب ابتدا، وسط و انتهای دوره مورد مطالعه) به طور نمونه برای گندم و سویا آورده شده است که کلاس تفکیک شده گندم و سویا با رنگ زرد نشان داده شده است. همچنین جهت بارزسازی گندم و سویا به منظور تشخیص در تصاویر مختلف از ترکیب های باندهای مختلف استفاده شد. بطوریکه باند ۱ محدوده طیفی آبی، باند ۲ محدوده طیفی سبز، باند ۴ محدوده طیفی مادون قرمز نزدیک، باند ۵ محدوده طیفی مادون قرمز میانی و باند ۷ محدوده طیفی مادون قرمز دور را نشان می دهند.

شدن می باشند؛ بنابراین منطقی است که بیشترین بازتاب در محدوده طیفی مادون قرمز مربوط به گندم می باشد. در میان محصولات تابستانه سویا دوره کشت نزدیک به محصولات برنج و ذرت دارد؛ اما اوج سبزیگی محصولات برنج و ذرت در ماه مرداد است، در حالی که اوج سبزیگی سویا اواخر مرداد و اوایل شهریور است و به همین دلیل تصاویر شهریورماه به عنوان مبنای طبقه بندی (۴ کلاس سویا، برنج، ذرت و سایر گیاهان) و تفکیک مورد استفاده قرار گرفتند. از آنجاکه بیشتر مناطق کشت شده سویا در دوره کشت قبل خود زیر کشت گندم بوده اند تصاویر طبقه بندی شده اردیبهشت ماه هم در بازبینی طبقه بندی سویا مورد استفاده قرار گرفتند.



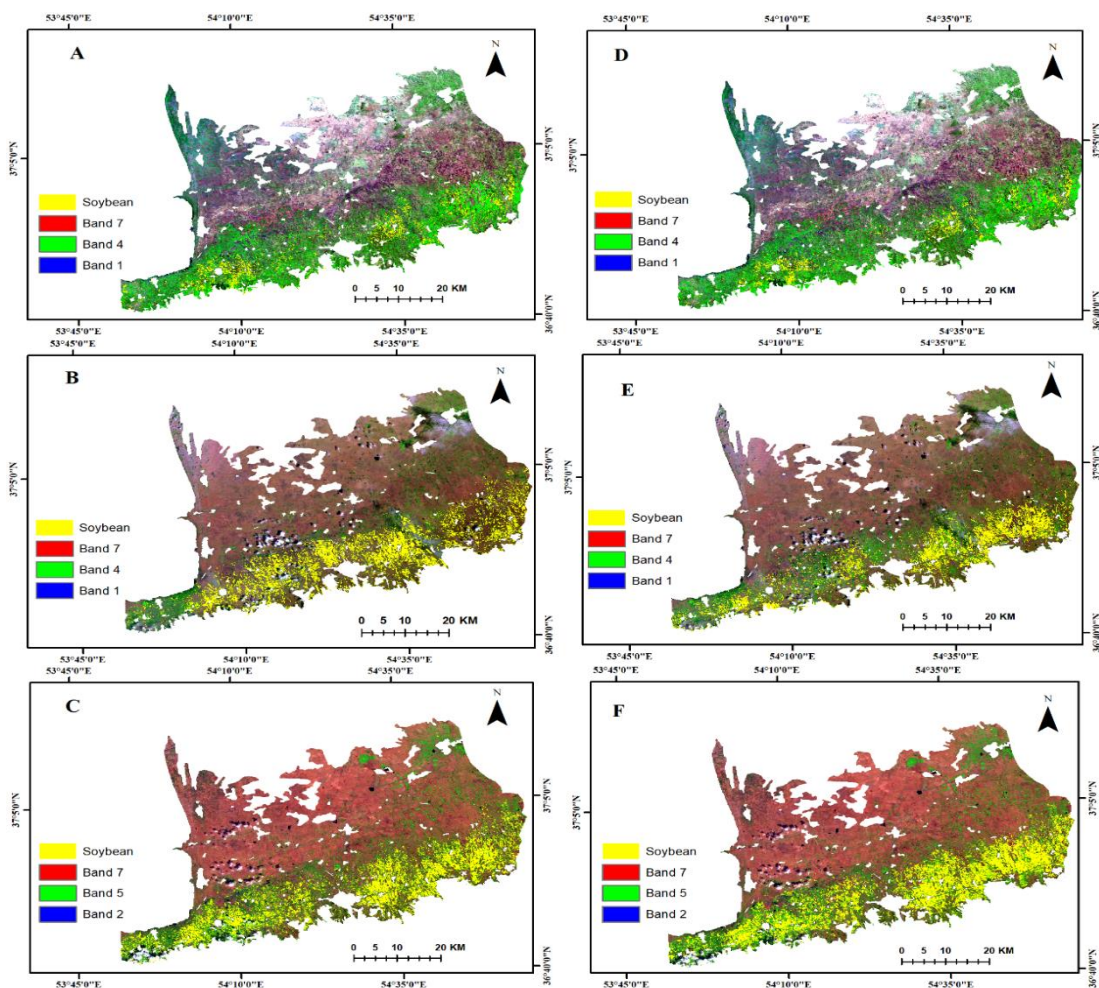
شکل ۵- نقشه طبقه بندی گندم با روش ماشین بردار پشتیبان سال ۱۳۷۹ (A)، سال ۱۳۸۶ (B) و سال ۱۳۹۵ (C)، طبقه بندی گندم با روش شبکه عصبی مصنوعی سال ۱۳۷۹ (D)، سال ۱۳۸۶ (E) و سال ۱۳۹۵ (F) (باند ۱: محدوده طیفی آبی، باند ۲: محدوده طیفی سبز، باند ۴: محدوده طیفی مادون قرمز نزدیک، باند ۵: محدوده طیفی مادون قرمز میانی (SWIR1) و باند ۷: محدوده طیفی مادون قرمز دور (SWIR2))

Figure 5. wheat-grown fields detection map with support vector machine (A:2000, B:2008,C:2016) and artificial neural network (D:2000, E:2008,F:2016) in three years. (band1:visible blue, band 2: visible green, band 4: near-infrared, band 5: short-wave infrared (SWIR1), band 7: short-wave infrared (SWIR2))

از عملکرد قابل قبولی برخوردار هستند و در تفکیک پدیده هایی که رفتار طیفی نزدیک به هم دارند بسیار موفق عمل می کنند. نتایج نشان داد که هر دو روش با اندکی تفاوت در مقدار عددی معیار های ارزیابی، تفکیک مناسبی روی دو محصول مورد بررسی نشان دادند.

مقایسه دقت دو مدل نشان داد در سال های ۲۰۰۱، ۲۰۰۶ و ۱۵۲۰ کارایی روش طبقه

با توجه به اینکه در این تحقیق هدف تفکیک محصولات گندم و سویا بود فقط از ضریب کاپا و صحت کلی استفاده شد و ماتریس خطای دیگر کلاس ها آورده نشد، چرا که دقت این کلاس ها تأثیری بر نتایج کار نخواهد داشت. طبق اطلاعات مندرج در جداول ۲ و ۳، هر دو روش طبقه بندی ماشین بردار و شبکه عصبی برای استخراج دو محصول گندم و سویا



شکل ۶- نقشه طبقه‌بندی سویا با روش ماشین بردار پشتیبان سال ۱۳۷۹ (A)، سال ۱۳۸۶ (B) و سال ۱۳۹۵ (C)، طبقه‌بندی سویا با روش شبکه عصبی مصنوعی سال ۱۳۷۹ (D)، سال ۱۳۸۶ (E) و سال ۱۳۹۵ (F) (باند ۱: محدوده طیفی آبی، باند ۲: محدوده طیفی سبز، باند ۴: محدوده طیفی مادون قرمز نزدیک، باند ۵: محدوده طیفی مادون قرمز میانی (SWIR1) و باند ۷: محدوده طیفی مادون قرمز دور (SWIR2))

Figure 6. Soybean-grown fields detection map with support vector machine (A:2000, B:2008, C:2016) and artificial neural network (D:2000, E:2008, F:2016) in three years. (band 1: visible blue, band 2: visible green, band 4: near-infrared, band 5: short-wave infrared (SWIR1), band 7: short-wave infrared (SWIR2))

مصنوعی در بعضی از قسمت های محدوده ی مورد مطالعه مشخص شد گیاهان به خوبی از هم تفکیک نشده بودند و در این مکان ها پیکسل هایی دیده می شد که مربوط به گندم یا سویا بودند، اما در طبقه سایر گیاهان که با این دو گیاه همزمانی دوره رشد داشتند در نظر گرفته شده بودند. برای تعیین و مقایسه دقت دو روش مورد استفاده، از تصاویر برگرفته شده از گوگل

بندی شبکه عصبی در تفکیک محصول گندم از روش طبقه‌بندی ماشین بردار پشتیبان بالاتر می‌باشد. همچنین در سال های ۲۰۰۵، ۲۰۰۹، ۲۰۱۳ و ۲۰۱۵ در تفکیک محصول سویا نیز بهتر عمل کرده است؛ اما در بقیه سال‌ها روش ماشین بردار پشتیبان دقت بهتری نشان داده است. در برخی از سال ها با وجود بالاتر بودن دقت کلی و ضریب کاپا برای طبقه بندی شبکه عصبی

جدول ۲- نتایج ارزیابی جداسازی مزارع گندم با استفاده از روش طبقه بندی نظارت شده در فواصل سال های ۲۰۰۰ تا ۲۰۱۶

Table 2. The evaluation results for wheat-grown fields detection by supervised classification method from 2000 to 2016.

سال مورد مطالعه Year	مصنوعی روش شبکه عصبی Artificial neural network		روش ماشین بردار پشتیبان Support vector machine	
	ضریب کاپا Kappa coefficient	صحت کلی Overall accuracy	ضریب کاپا Kappa coefficient	صحت کلی Overall accuracy
	2000	0.83	85.7	0.88
2001	0.88	91.1	0.87	89.2
2004	0.84	87.5	0.92	93.6
2005	0.89	91.1	0.92	94.2
2006	0.90	90.2	0.87	89.8
2008	0.88	90.8	0.90	92.0
2009	0.78	82.1	0.88	90.5
2010	0.86	89.2	0.88	90.5
2011	0.82	84.6	0.89	90.9
2012	0.85	90.3	0.87	89.4
2013	0.81	84.3	0.84	87.1
2014	0.85	86.2	0.85	87.8
2015	0.85	87.1	0.84	86.9
2016	0.81	84.4	0.87	89.9

جدول ۳- نتایج ارزیابی جداسازی مزارع سویا با استفاده از روش طبقه بندی نظارت شده در فواصل سال های ۲۰۰۰ تا ۲۰۱۶

Table 3. The evaluation results for soybean-grown fields detection by supervised classification method from 2000 to 2016.

سال مورد مطالعه Year	مصنوعی روش شبکه عصبی Artificial neural network		روش ماشین بردار پشتیبان Support vector machine	
	ضریب کاپا Kappa coefficient	صحت کلی Overall accuracy	ضریب کاپا Kappa coefficient	صحت کلی Overall accuracy
	2000	0.86	82.3	0.88
2001	0.77	87.6	0.9	82.4
2003	0.81	86.2	0.88	90.9
2004	0.79	83.6	0.90	92.3
2005	0.88	90.2	0.84	87.9
2006	0.84	88.2	0.9	82.6
2008	0.81	82.3	0.86	88.5
2009	0.88	91.6	0.88	90.5
2010	0.86	86.1	0.86	88.6
2011	0.75	80.4	0.85	88.4
2012	0.80	85.4	0.90	92.0
2013	0.90	91.1	0.86	88.6
2014	0.85	88.2	0.88	90.2
2015	0.86	87.3	0.88	89.9
2016	0.89	90.6	0.87	90

ارث، نقاط کنترل زمینی (ثبت شده با GPS) و نظرات کارشناسی استفاده شد. نتایج نشان داد که طبقه بندی کننده ماشین بردار پشتیبان در شناسایی دقیق پدیده ها بهتر عمل کرده است و با ضریب کاپای بین ۰/۸۴ تا ۰/۹۲ برای محصول گندم و ۰/۸۴ تا ۰/۹۱ برای محصول سویا به عنوان الگوریتم موفق تر انتخاب گردید.

نتایج بدست آمده نشان داد که صحت طبقه بندی تصاویر از لحاظ تمامی شاخص های مورد نظر با توجه به نمونه های آموزشی و آزمایشی استفاده شده قابل قبول می باشد. از آنجایی که هدف این مطالعه تعیین سطح زیر کشت دو محصول گندم و سویا به عنوان محصولات دارای ارزش اقتصادی برای استان گلستان از نقشه های طبقه بندی شده به روش شبکه عصبی مصنوعی و ماشین بردار پشتیبان بود، نقشه های طبقه بندی محصولات به کمک دو روش مذکور به محیط GIS انتقال یافت و مساحت زمین های تحت کشت این دو محصول در سال های مختلف محاسبه شد؛ و در نهایت مساحت های محاسبه شده از نقشه طبقه بندی شده به هر دو روش مذکور با آمار سطح زیر کشت ارائه شده توسط سازمان جهاد کشاورزی مقایسه شد (جدول ۴). آمار سطح زیر کشت برآورد شده از فرآیند طبقه بندی با روش ماشین بردار پشتیبان نشان دهنده دقت بالای طبقه بندی و تطابق آمار سطح زیر کشت ارائه شده توسط سازمان جهاد کشاورزی و تصاویر ماهواره ای است. بیشترین مقدار خطای نسبی این روش در برآورد سطح زیر کشت برای دو محصول گندم و سویا در مقایسه با آمار های سازمان جهاد

کشاورزی به ترتیب معادل ۱۵ و ۱۴ درصد بود؛ اما در برخی از سال ها میزان سطح زیر کشت استخراج شده از تصاویر کمتر از مقدار ارائه شده توسط جهاد کشاورزی و در برخی سال ها بیشتر می باشد. برای مثال مقدار سطح زیر کشت سویا در سال ۲۰۰۰ به میزان ۱۷۴۹ هکتار بیشتر تخمین زده شده است، در حالی که در سال ۲۰۱۶ به میزان ۲۷۲۶ هکتار کمتر محاسبه شده است؛ اما در مورد هر دو محصول باید به این نکته توجه کرد که اندازه هر پیکسل ۳۰ متر می باشد و سطح پوشش هر پیکسل معادل ۹۰۰ متر مربع می باشد که برای زمین های زراعی عدد بزرگی محسوب می شود؛ بنابراین آمیختگی سایر محصولات، به ویژه قطعات کمتر از مساحت هر پیکسل غیر قابل اجتناب می باشد. نتایج این مطالعه بطور کلی تصدیق کننده مطالعات پیشین می باشد که در آن ها الگوریتم ماشین بردار پشتیبان در برآورد سطح زیر کشت دقیق تر از روش های شبکه عصبی مصنوعی و دیگر الگوریتم های بررسی شده است (Yung et al., 2003; Xu et al., 2005; Chubey et al., 2006; Mokhtari & Najafi, 2015; Rahimzadegan & Pourgholam, 2017).

شکل ۷ وضعیت برآورد سطح زیر کشت گندم و سویا با روش ماشین بردار پشتیبان را نشان می دهد. طبق نتایج (شکل ۷)، حدود ۹۳ درصد از نقاط برآورد شده سطح زیر کشت گندم و سویا در طی ۱۶ سال مورد مطالعه در محدوده حدود اطمینان ± 15 درصد قرار دارند. بر اساس این نتایج استفاده از روش ماشین بردار پشتیبان برای برآورد سطح زیر کشت رضایت

جدول ۴- مقایسه سطح زیر کشت گندم از نتایج طبقه بندی و آمار سازمان جهاد کشاورزی. علامت ↓ درصد کم برآوردی و علامت ↑ درصد بیش برآوردی سطح زیر کشت در مقایسه با آمار گزارش شده توسط سازمان جهاد کشاورزی را نشان می دهند.

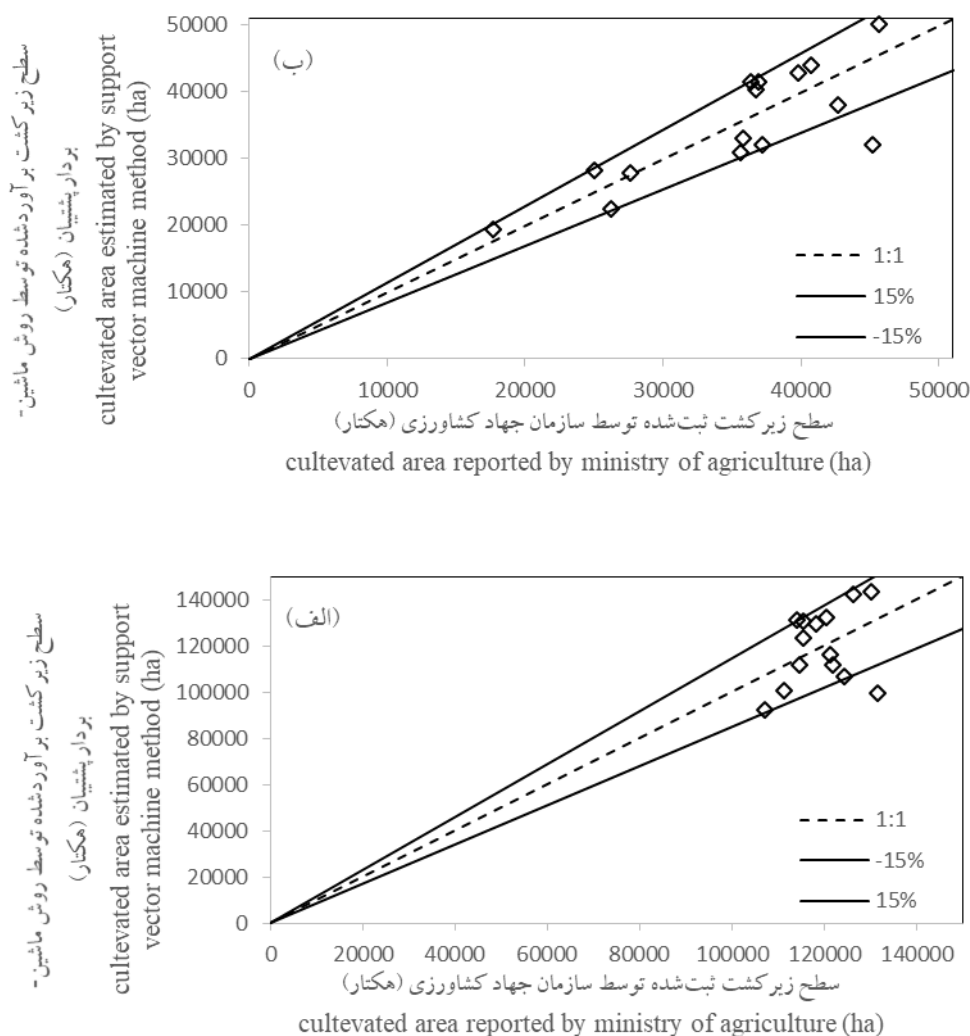
Table 4. Comparison of wheat cultivated area obtained from supervised classification method classification and statistics reported by ministry of Agriculture-Jihad. ↓ and ↑, indicate under- and over- estimations for cultivated area compared to statistics of ministry of Agriculture-Jihad, respectively.

سال مورد مطالعه Year	سطح زیر کشت سازمان جهاد کشاورزی (هکتار) Statistics of ministry of Agriculture- Jihad (ha)	روش ماشین بردار پشتیبان Support vector machine		روش شبکه عصبی مصنوعی Artificial neural network	
		سطح زیر کشت (هکتار)	خطای نسبی (درصد)	سطح زیر کشت (هکتار)	خطای نسبی (درصد)
		Cultivated area (ha)	Relative error (%)	Cultivated area (ha)	Relative error (%)
2000	114729	111834	3 ↓	135368	18 ↑
2001	115626	130779	13 ↑	105525	9 ↓
2004	126386	142577	13 ↑	141552	12 ↑
2005	121861	111924	8 ↓	138921	14 ↑
2006	121407	116226	4 ↓	135747	12 ↑
2008	107193	92186	14 ↓	120056	12 ↑
2009	114123	131241	15 ↑	84451	26 ↓
2010	118184	129726	10 ↑	132366	12 ↑
2011	111278	100612	10 ↓	126971	14 ↑
2012	120509	132560	10 ↑	138585	15 ↑
2013	131654	123749	6 ↓	118488	10 ↓
2014	124432	107012	14 ↓	110744	11 ↓
2015	115416	99668	14 ↑	92332	20 ↓
2016	130331	143364	10 ↑	113388	13 ↓

جدول ۵- مقایسه سطح زیر کشت سویا از نتایج طبقه بندی و آمار سازمان جهاد کشاورزی. علامت ↓ درصد کم برآوردی و علامت ↑ درصد بیش برآوردی سطح زیر کشت در مقایسه با آمار گزارش شده توسط سازمان جهاد کشاورزی را نشان می دهند.

Table 5. Comparison of soybean cultivated area obtained from supervised classification method classification and statistics reported by ministry of Agriculture-Jihad. ↓ and ↑, indicate under- and over- estimations for cultivated area compared to statistics of ministry of Agriculture-Jihad, respectively.

سال مورد مطالعه Year	سطح زیر کشت سازمان جهاد کشاورزی (هکتار) Statistics of ministry of Agriculture- Jihad (ha)	روش ماشین بردار پشتیبان Support vector machine		روش شبکه عصبی مصنوعی Artificial neural network	
		سطح زیر کشت (هکتار)	خطای نسبی (درصد) Relative error (%)	سطح زیر کشت (هکتار) Cultivated area (ha)	خطای نسبی (درصد) Relative error (%)
		Cultivated area (ha)		Cultivated area (ha)	
2000	17632	19381	10 ↑	15164	14 ↓
2001	25026	28279	13 ↑	19758	21 ↓
2003	26238	22522	14 ↓	29386	12 ↑
2004	36380	41473	14 ↑	28746	21 ↓
2005	37152	32106	14 ↓	33437	10 ↓
2006	40718	43975	8 ↑	45604	12 ↑
2008	35581	31016	13 ↓	29544	17 ↓
2009	45177	41556	8 ↓	39756	12 ↓
2010	39758	42938	8 ↑	45722	15 ↑
2011	45641	50205	10 ↑	55682	22 ↑
2012	42648	38129	11 ↓	35398	17 ↓
2013	36942	32049	13 ↓	40636	10 ↑
2014	36718	40389	10 ↑	39655	8 ↑
2015	27665	27941	1 ↑	23238	16 ↓
2016	35833	33107	8 ↓	39416	10 ↑



۷- نحوه پراکنش داده‌های سطح زیر کشت گندم (الف) و سویا (ب) ثبت شده توسط سازمان جهاد کشاورزی در برابر سطح زیر کشت برآورد شده توسط روش ماشین بردار پشتیبان در حدود اطمینان ۱۵ درصد

Figure 7. Wheat and soybean cultivated area reported by ministry of Agriculture-Jihad versus estimated wheat and soybean cultivated area by support vector machine method within the range of 15% confidence level.

بردار پشتیبان، حداکثر احتمال و شبکه عصبی مصنوعی برای تولید نقشه کاربری اراضی کشاورزی پرداختند. نتایج این محققان نشان داد روش ماشین بردار پشتیبان با ضریب کاپای ۹۴/۱۵ دقیق‌ترین روش بوده و بعد از آن روش حداکثر احتمال قرار داشته است. همچنین نتایج مطالعه‌ای جهت شناسایی سطح زیر کشت محصول زعفران در شهرستان تربت حیدریه نشان داد سطح زیر کشت زعفران در طبقه

بخش بود که نشان‌دهنده برآورد صحیح سطح زیر کشت و تصدیق‌کننده کارایی این روش در برآورد سطح زیر کشت گندم و سویا می‌باشد. در بیشتر تحقیقاتی که در زمینه مقایسه الگوریتم‌های طبقه‌بندی تصاویر ماهواره‌ای می‌باشند، روش ماشین بردار پشتیبان به عنوان روشی موفق در زمینه استخراج اراضی کشاورزی معرفی شده است. برایان و همکاران (Brian et al., 2011) به مقایسه سه روش ماشین

به طور مستقیم به هزینه و زمان لازم برای انجام این مطالعه پرداخته نشده، اما آنچه مسلم است عدم نیاز به مراجعه مستمر به اراضی کشاورزی و انجام پرسش و پاسخ و پیمایش میدانی باعث صرفه‌جویی در هزینه و زمان خواهد شد. قدمت زمانی تصاویر ماهواره لندست نسبت به سایر ماهواره‌ها بیشتر و همچنین به صورت رایگان در دسترس کاربران می‌باشد؛ اما با پیشرفت سنجش از دور و روی کار آمدن ماهواره‌هایی چون سنتینل با قدرت تفکیک مکانی بالاتر، برای مناطقی مانند گرگان که سطح زیر کشت اراضی کشاورزی بسیار زیاد می‌باشد و آماربرداری آن هزینه‌های زمانی و مالی زیادی در بردارد، پیشنهاد می‌شود از این تصاویر نیز به شکل مقایسه‌ای جهت برآورد سطح زیر کشت محصولات استفاده شود. همچنین روش ماشین بردار پشتیبان با سایر روش‌های پیشرفته طبقه بندی مانند درخت تصمیم و روش شیء گرا مورد مقایسه قرار گیرد.

بندی ماشین‌های بردار پشتیبان با صحت کلی ۹۵ درصد و ضریب کاپای ۹۰ درصد به عنوان بهترین روش قابل اعتماد است (Rahimzadegan *et al.*, 2015).

نتیجه‌گیری

در این مطالعه سعی شده است تا با بهره‌گیری از تصاویر ماهواره‌ای، فناوری‌های سنجش از دور و روش‌های جدید طبقه بندی با خطای کمتری به تولید آمار و اطلاعات کشاورزی پرداخته شود. با توجه به نتایج این مطالعه به نظر می‌رسد اخذ تصویر در اردیبهشت‌ماه برای برآورد سطح زیر کشت گندم و در شهریورماه برای سویا معقول می‌باشد و تصاویر ماهواره‌ای در صورتی که در زمان مناسب انتخاب شوند از قابلیت بالایی برای تفکیک محصولات زراعی و تهیه نقشه پراکندگی و برآورد سطح زیر کشت با دقت مناسب برخوردار است. با توجه به نتایج، هر دو روش ماشین بردار پشتیبان و شبکه عصبی روش‌های دقیقی برای استخراج محصولات زراعی از کاربری کشاورزی هستند و در تفکیک پدیده‌هایی که رفتار طیفی نزدیکی دارند کارآمد می‌باشند، اما در تفکیک و برآورد سطح زیر کشت گندم و سویا روش ماشین بردار پشتیبان به علت تفکیک واضح مرزهای بین کلاسه‌ها، بهتر از روش شبکه عصبی مصنوعی عمل کرد. نتایج نقشه‌های سطح زیر کشت استخراج شده از تصاویر ماهواره‌ای در این مطالعه، به عنوان لایه پایه برای مدلسازی‌های منطقه‌ای، تهیه لایه خلاء عملکرد، محاسبه نیاز آبی، طراحی الگوی کشت و غیره می‌تواند مورد استفاده قرار گیرند. هرچند در این مطالعه

References

- Amini Bazyani, S., Akbari, M., and Zare Abyane, H. 2013. Assessment of Cropped Area, and Cropping Intensity in Hamedan–Bahar Plain Using Remote Sensing Data. *Iranian Journal of Irrigation and Drainage*, 7 (1), 36-48 (In Persian with English Summary).
- Brian, W. S., Qi, C., and Michael, B. 2011. A comparison of classification techniques to support land cover and land use analysis in tropical coastal zones. *Applied Geography*, 31: 525-532.
- Chuang, W.C., Lina, C.Y., Chien, C.H., and Choub, W.C. 2011. Application of Markov-chain model for vegetation restoration assessment at landslide areas caused by a catastrophic earthquake in Central Taiwan. *Ecological Modelling*, 222 (2011), 835- 845.
- Chubey, M.S., Franklin, S.E., Wulder, M.A. 2006. Object-based analysis of Ikonos-2 imagery for extraction of forest inventory parameters. *Photogrammetric Engineering & Remote Sensing*, 72(4), 383-394.
- Fahimnejad, H., Sofbof, S., Ali Mohammadi, A., and Valadan Zagh, M. 2008. Detection of agricultural crop using Hyperion Data. In: Geomatics Conference, Tehran, Iran, 11-14 March 2008, p. 91-96 (In Persian).
- Foody, M. G., and Mathur, A. 2006. The use of small training sets containing mixed pixels for accurate hard classification: Training on mixed spectral response for classification by SVM. *Remote Sensing of Environment*, 103 (2), 179-189.
- Golestan agricultural and natural resources research and education center. 2017. Available at Web site <http://www.ganrrc.org.ir> (accessed 5 September 2017).
- Guo, Y., De Jong, K., Liu, F., Wang, X., and Li, C. 2012. A Comparison of Artificial Neural Networks and Support Vector Machines on Land Cover Classification, Springer-verlag Berlin Heidelberg. CCIS, 316: 531 -539.
- Huang, C. L., Davis, S., and Townshend, J.R.G. 2002. An assessment of support vector machines for land cover classification, *International Journal of Remote Sensing*, 23(4), 725-749.
- Jiang, X., Lin, M., and Zhao, J. 2011. Woodland cover change assessment using decision trees, support vector machines and artificial neural networks classification algorithms. In: Fourth Workshop on Intelligent Computation Technology and Automation, China, 20-23 April 2011, p. 312-315.
- Kavzoglu, T., and Colkesen, I. 2009. A kernel functions analysis for support vector machines for land cover classification, *International Journal of Applied Earth Observation and Geoformation*, 11: 352-359.

- Khajehedin, S.J., and Pourmanafi, P. 2008. Determination of paddy cultivate area of Zayandehrud brink with the data of IRS11 satellite sensors in Isfahan, *Journal of Sciences and Technology of Agriculture and Natural Resources*, 1: 513-528 (In Persian).
- Lu, D., and Q. Weng. 2007. A survey of image classification methods and techniques for improving classification performance. *Remote Sensing*, 28 (5), 823-87.
- Marsden, T., Murdoch, J., and Morgan, K. 1999. Sustainable agriculture, food supply chains and regional development: editorial introduction. *International Planning Studies*, 4 (3), 301-295.
- Mather, P.M., and Tso, B. 2009. *Classification Methods for Remotely Sensed Data*. CRC Press, New York.
- Ministry of Agriculture Jihad. 2016. *Agricultural Statistics First Volume - Crop Products*. Center for Statistics and Information (In Persian).
- Mokhtari, M.D., and Najafi, a. 2015. Comparison of support vector machine and artificial neural network classification methods for land user utilization from Landsat TM satellite imagery. *Journal of Sciences and Technology of Agriculture and Natural Resources*, 19 (72), 35-44 (In Persian).
- Petropoulos, G., Kontoes, P., and Keramitsoglou, C. 2011. Burnt area delineation from a unitemporal perspective based on Landsat TM imagery classification using support vector machines. *International Journal of Applied Earth Observation and Geoinformation*, 13(1), 70-80.
- Pôças, I., Cunha, M., Pereira, L.S., and Allen, R.G. 2013. Using remote sensing energy balance and evapotranspiration to characterize montane landscape vegetation with focus on grass and pasture lands. *International Journal of Applied Earth Observation and Geoinformation*, 21:172-159 .
- Qasemlou, N., Mobashari, M., and Rezaei, Y. 2009. Detection of Plant Type Using Spectral Properties and Artificial Neural Networks. In: *Geomatics Conference*, Tehran, Iran, 15-18 February 2009, p. 10-15 (In Persian).
- Rahimzadegan, M., and Pourgholam. M. 2017. Identification of the area under cultivation of Saffron using Landsat-8 temporal satellite images (Case study: Torbat Heydarieh). *RS & GIS for Natural Resources*, 7 (4), 97-115 (In Persian).
- Richards J., A. 2013. *Remote sensing digital image analysis*. springer.
- Rngzan, K., Esfandiari, A., and Taghizadeh, A. 2011. Detection and determination of sugarcane cultivated area on Hyperion Images. In: *Geomatics Conference*, Tehran, Iran, 15-18 February 2011, p. 40-45 (In Persian).
- Safiyanian, A., Mohammadi Tofigh, A., khodakarami, L., and Amiri. F. 2011. Preparation of land use map using Artificial Neural Network method (Case

- Study: Kabudarahang Basin, Razan and Khonjin - Talkhab, Hamedan Province). *Journal of Applied RS and GIS Techniques in Natural*, 2 (1), 1-12 (In Persian).
- Samadzadegan, F., and Hassani, H. 2012. Determination of Optimal Support Vector Machines in the Classification of hyperspectral Images Based on Genetic Algorithm. *Journal of Information and Communication Technology*, 13: 9-24 (In Persian).
- Sanaiei Nejad, H., Sadr Abadi Haghighi, R., Klarostaqi, Kiumars., and Shah Tahmasebi, A. 2008. Estimation of wheat cultivated area using TERRA satellite imagery in Khorasan Razavi province. *Agricultural science and technology*, 21(2), 67-74 (In Persian).
- Xu, M., Watanachaturaporn, P., Varshney, P.K., and Arora, M.K. 2005. Decision tree regression for soft classification of remote sensing data. *Remote Sensing of Environment*, 97(3), 322- 336.
- Yang, C.C., Prasher, S.O., Enright, P., Madramootoo, C., Burgess, M., Goel, P.K, and Callum, I. 2003. Application of decision tree technology for image classification using remote sensing data. *Agricultural Systems* 76(3), 1101-1117.
- Zadehdifard, N. 2002. Preparation of land use map using satellite data in Baft drainage basin. MSc Disseration, Faculty of Agriculture, Isfahan University of Technology, Iran (In Persian with English Summary).
- Ziaecian-Firoozabadi, P., Sayad-Bydhndy, L., and Eskandari-Nodeh, M. 2009. Mapping and estimating the area under rice cultivation in Sari city using satellite images Radarst. *Geography Research Natural*, 68: 45-58 (In Persian).

Estimation of changes in land area under wheat and soybean cultivation using satellite images classification techniques in west of Golestan province

P. Alizadeh, B. Kamkar, S. Shataee, H. Kazemi

1. Ph.D. student of Department of Agriculture, Faculty of Plant Production, Gorgan University of Agricultural Sciences and Natural Resources
2. Professor of Agronomy Dept., Gorgan University of Agricultural Sciences and Natural Resources . (Corresponding author)
3. Professor of Gorgan University of Agricultural Sciences and Natural Resources
4. Assistant Professor of Gorgan University of Agricultural Sciences and Natural Resources

Received: March 2018 Accepted: October 2018

Extended Abstract

Alizadeh, P., Kamkar, B., Shataee, S., Kazemi, H., Estimation of changes in land area under wheat and soybean cultivation using satellite images classification techniques in west of Golestan province
Applied Research in Field Crops Vol 31, No. 3, 2018 Page:7-9: 41-61(in Persian)

Introduction: Estimating the land area under crop cultivation based on peripheral aspects of production including seeding rate, fertilizer and the amount of chemical inputs delivered to farmers as well as evaluations by consulting firms is time consuming and cost intensive. Nowadays, using satellite data as a new solution not only reduces the drawbacks of conventional estimation methods of cultivated land areas, but also can be beneficial for various planning aims in the agricultural sphere. Land cover mapping is important for many of processes related to plan-making and activities associated with crop production management. Today, satellite images and remote sensing techniques are extensively used in all sectors, including agriculture and natural resources because they have high analytical abilities and are capable of providing up-to date information and data. It is one of the fastest and most cost-effective methods available to researchers to map lands dedicated to crop production. In recent years, satellite imagery and different detection methods have aided researches to detect the features at a lower cost and at lesser time duration. Different methods are available for this purpose. Each method offers some advantages and disadvantages. Artificial neural network, fuzzy logic, support vector machine, decision tree, object-oriented classification and intelligent systems can be considered as advanced classification methods (Guo *et al.*, 2012).

Email address of the corresponding author: behnam.kamkar@gmail.com

In this study, we made attempts to detect wheat and soybean-grown fields with two advanced classification methods (i.e. support vector machine (SVM) and artificial neural network (ANN)) in west of Golestan province, Iran. All the cultivated areas were determined from the maps extracted from satellite images with the purpose of using them as the base layer for other research goals.

Materials and Methods: The current research was conducted to estimate the wheat- and soybean-grown areas during a 16-year period from 2000 to 2016 using Landsat satellite imagery. For this purpose, two classification methods e.g. support vector machine and artificial neural network were used. In order to classify and detect the two aforementioned crops, ground control points (GCPs), the normalized difference vegetation index (NDVI) for agricultural lands, and spectral behavior of wheat and soybean training GCPs were employed. In order to validate the results of classification, the generated maps were checked by GCPs (coordinated with GPS).

Results and Discussion: Wheat and soybeans were at the maximum vegetative growth in May and September, and were well-detected from other crops. Therefore, the images of these two months were used for detection in the all studied years. According to the results of previous studies, support vector machine and artificial neural network could be used as two reliable image classification methods for detecting the crops vegetation cover (Rahimzadegan & Pourgholam ,2017; Mokhtari & Najafi, 2015). The accuracy of image classification was assessed using kappa coefficient and overall accuracy. Kappa coefficient and overall accuracy showed the support vector machine method was superior than artificial neural network method in classifying agricultural lands and detecting studied wheat-and soybean-grown fields. In the all images, the calculated overall accuracy coefficient was more than 80% (0.84 to 0.92 for wheat; and 0.84 to 0.90 for soybean) and kappa coefficient was greater than 0.8, indicating the reliability of the classification outputs. According to comparisons of satellite image-based estimations and real recorded statistics, about 93% of the estimated areas of wheat - and soybean grown fields in the 16 consecutive years of study were within the range of 15% confidence level, which indicates that this method is reliable to detect these two crops using images of April (for wheat) and September (for soybean).

Conclusions: The support vector machine method of classification was identified as the superior method. wheat- and soybean-grown fields maps extracted from satellite images can be used as a base layer for regional modeling, providing yield gap layer, calculating the water requirement, designing crop pattern etc.

Keywords: Remote sensing, classification, Artificial neural networks, Support vector machine.

References

- Guo, Y., De Jong, K., Liu, F., Wang, X., and Li, C. 2012. A Comparison of Artificial Neural Networks and Support Vector Machines on Land Cover Classification, Springer-verlag Berlin Heidelberg. CCIS, 316: 531 -539.
- Mokhtari, M.D., and Najafi, a. 2015. Comparison of support vector machine and artificial neural network classification methods for land user utilization from Landsat TM satellite imagery. *Journal of Sciences and Technology of Agriculture and Natural Resources*, 19 (72), 35-44 (In Persian).
- Rahimzadegan, M., and Pourgholam. M. 2017. Identification of the area under cultivation of Saffron using Landsat-8 temporal satellite images (Case study: Torbat Heydarieh). *RS & GIS for Natural Resources*, 7 (4), 97-115 (In Persian).