

تعیین بهترین الگوریتم طبقه‌بندی به منظور تخمین سطح زیر کشت نخیلات با استفاده از تصاویر ماهواره لندست ۸

سحر رهنما^۱ - محمد مهدی مهارلوئی^{۲*} - محمد علی رستمی^۳ - حسین مقصودی^۴

تاریخ دریافت: ۱۳۹۶/۰۶/۲۳

تاریخ پذیرش: ۱۳۹۷/۰۵/۰۱

چکیده

محصول خرما یکی از ارزشمندترین محصولات باغبانی در ایران به‌شمار می‌آید که ۱۶٪ کل صادرات جهانی را شامل می‌شود. استان کرمان دومین رتبه در سطح زیر کشت خرما در ایران را دارا است. به همین منظور تعیین سطح زیر کشت خرما اهمیت پیدا کرده است. برخی از سازمان‌ها برای تعیین سطح زیر کشت از سرشماری استفاده می‌کنند که معایب آن هزینه بالا و اتلاف وقت و نیاز به نیروی انسانی زیاد برای پوشش‌دهی کل کشور است. هدف از این تحقیق سنجش توانایی ماهواره لندست ۸ با سنجه OLI در شناسایی و تعیین سطح زیر کشت نخلستان‌ها است. برای پی بردن به بهترین روش برای شناسایی نخلستان‌ها چهار روش طبقه‌بندی نظارت‌شده Maximum Likelihood Classifier (MLC)، Support Vector Machines (SVM)، Neural Network (NN)، Mahalanobis Distance Classifier (MDC) (K-Means) مورد ارزیابی قرار گرفت. نتایج طبقه‌بندی‌ها نشان داد که دقت کلی طبقه‌بندی ۹۹/۱۰٪ (ضریب کاپا ۰/۹۸) با استفاده از NN، ۹۸/۷۷٪ (ضریب کاپا ۰/۹۷۵) با استفاده از MLC، ۹۸/۶۶٪ (ضریب کاپا ۰/۹۷۳) با استفاده از SVM، ۹۸/۵۲٪ (ضریب کاپا ۰/۹۷) با استفاده از MDC و ۶۶/۵۲٪ (ضریب کاپا ۰/۳۱) با استفاده از K-Means است. خطای تخمین مساحت نخیلات با استفاده از (RMSE) در روش NN (۰)، در روش MLC (۰/۲)، در روش MDC (۰/۰۶)، در روش SVM (۰) و در روش K-Means (۰) محاسبه شد. پس از تحلیل داده‌ها بهترین روش طبقه‌بندی برای شناسایی نخلستان‌ها روش NN شناخته شد. در پژوهش حاضر، با بررسی انجام‌شده بر روی داده‌ها در ماتریس آشفتگی مشخص شد که SVM قدرت بالاتری برای شناسایی نخلستان با تشخیص ۱۰۰٪ سامانه (تولیدکننده) نسبت به MLC را داشت و همچنین K-Means نیز می‌تواند نخلستان خرما را شناسایی کند اما مناطقی که به رنگ قهوه‌ای تیره هستند را نیز به‌عنوان نخلستان شناسایی کرده است. در مجموع می‌توان گفت هر چهار روش طبقه‌بندی نظارت‌شده با دقت قابل قبولی می‌توانند نخلستان را شناسایی کنند.

واژه‌های کلیدی: شبکه عصبی، طبقه‌بندی نظارت شده، طبقه‌بندی نظارت نشده، ماشین بردار پشتیبان، نخلستان خرما

مقدمه

به سطح زیر کشت محصولات از سرشماری استفاده می‌کنند. یکی از معایب سرشماری هزینه‌بر بودن و همچنین نیروی انسانی زیاد برای پوشش‌دهی کل کشور است. کم بودن سطح سواد بیش از دو میلیون نفر از کشاورزان نیز باعث کاهش دقت در سرشماری شده است (Statistical Center of Iran, 2015). نبود آمار صحیح و دقیق در بخش کشاورزی تصمیم‌گیری و تدوین سیاست‌های اقتصادی و اجتماعی در کشور را تحت تاثیر قرار داده است (Gomez et al., 2016). با استفاده از فناوری‌های نوین برای تعیین سطح زیر کشت می‌توان نقشه‌ی پوشش زمین را بدون بازدید حضوری شناسایی و تهیه کرد. علاوه بر این می‌توان بدون دست خوردن به نقشه‌ی اصلی آن را با تغییرات به‌روز منطقه تکمیل نمود (Büttner, 2014). سنجش‌ازدور می‌تواند بهترین و مناسب‌ترین روش برای ثبت تغییرات منطقه و نقشه‌برداری با جزئیات از مناطق وسیع باشد (Hussain et al., 2013; Tewkesbury et al., 2015). این امر باعث شده است

تولید خرما ۱۵٪ تولید و ۱۶٪ صادرات جهانی را به خود اختصاص داده است (Azizi and Yazdani, 2008)، به همین دلیل تعیین سطح زیر کشت خرما اهمیت پیدا کرده است. سازمان‌ها برای پی بردن

۱- دانشجوی کارشناسی ارشد بخش مهندسی مکانیک بیوسیستم، دانشگاه شهید باهنر کرمان، کرمان، ایران

۲- استادیار بخش مهندسی مکانیک بیوسیستم دانشگاه شهید باهنر کرمان، کرمان، ایران

۳- استادیار پژوهش، بخش تحقیقات فنی و مهندسی کشاورزی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان کرمان، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرمان، ایران

۴- استادیار بخش مهندسی مکانیک بیوسیستم، دانشگاه شهید باهنر کرمان، کرمان، ایران

*- نویسنده مسئول: (Email: maharlooie@uk.ac.ir)

DOI: 10.22067/jam.v9i2.67310

دارد، به همین دلیل است که از روش طبقه‌بندی نظارت‌شده بیشتر استفاده می‌شود (Khatami et al., 2016).

در طی پژوهشی در ایران و استان گلستان با استفاده از تصاویر لندست با سنجنده‌های TM و ETM⁺ و ترکیب روش‌های طبقه‌بندی نظارت‌شده و نظارت‌نشده توانستند با استفاده از ماتریس آشفتگی^۷، دقت کلی و ضریب کاپا، این طبقه‌بندی ترکیبی را با دقت کلی ۹۸/۲٪ اندازه‌گیری کنند (Mohammady et al., 2015). یکی دیگر از پژوهش‌ها با استفاده از تصاویر لندست برای تجزیه و تحلیل چگونگی تغییرات در جنگل‌های اریتره با استفاده از طبقه‌بندی نظارت‌شده از روش MLC با ضریب کاپای ۰/۹۴ و دقت کلی ۹۶٪ آن‌ها را شناسایی کرد (Ghebregabher et al., 2016).

در پژوهش دیگری که با استفاده از تصاویر ماهواره‌ای چند طیفی لندست TM و با ۴ روش مختلف طبقه‌بندی نظارت‌شده از جمله Minimum Distance (MD), Parallelepiped Method (PM), Spectral Angle Mapping (SAP), Support Vector Machine (SVM) انجام شد، روش PM با ضریب کاپا ۵۰/۸ و دقت کلی ۹۰٪ بهترین نتیجه را به خود اختصاص داده و علاوه بر شناسایی مزرعه پنبه، بوته‌های پنبه بیمار را نیز تشخیص داده و شناسایی شدند (Wanga et al., 2015).

در تحقیقی دیگر بر روی مناطق جنگلی در شهر Miyun کشور چین با استفاده از تصاویر لندست 8 OLI برای آزمون طبقه‌بندی نظارت‌شده از روش‌های PM, MD, MLC و SVM استفاده شد که در نتیجه SVM با دقت کلی ۷۸/۸۹٪ و ضریب کاپای ۸۵/۲۴ بالاترین دقت و روش PM با دقت کلی ۷۴٪ و ضریب کاپای ۰/۶۹ پایین‌ترین دقت را داشتند (Gong et al., 2016).

بر اساس نتایج پژوهش‌های انجام‌شده در زمینه سنسجش از دور و با توجه به اهمیت محصول خرما و پایش نخلستان‌ها، انتظار می‌رود که بتوان از تصاویر ماهواره لندست ۸ با سنجنده OLI برای شناسایی و جداسازی نخلستان‌ها و تعیین سطح زیر کشت آن‌ها استفاده نمود. هدف از این تحقیق امکان‌سنجی شناسایی نخلستان‌های خرما و همچنین جداسازی نخلستان از علوفه و خاک در سطح نخلستان در تصاویر سنجنده لندست با استفاده از روش‌های نظارت‌شده و نظارت‌نشده می‌باشد که دلیل آن، تخمین دقیق‌تر سطح زیر کشت خرما است. یکی دیگر از اهداف این پژوهش بررسی قدرت تشخیص و جداسازی چهار روش قدرتمند از روش‌های طبقه‌بندی نظارت‌شده (K-^۱، SVM^{۱۰}، MLC^۹، NN^۸) و طبقه‌بندی نظارت‌نشده (K-

که در جمع‌آوری اطلاعات هزینه و وقت کمتری صرف شود و همچنین اطلاعات به‌دست‌آمده دارای دقت بیشتر و قابل استنادتر باشد.

در طی چند سال اخیر نقشه پوشش اراضی با استفاده از داده‌های لندست تولیدشده است (Frey and Smith, 2007; Fritz et al., 2010). داده‌های لندست^۱ با سنجنده‌های (TM^۳، ETM^۴ و OLI^۴) داده‌های استاندارد هستند که برای طبقه‌بندی پوشش گیاهی زمین (Cohen and Goward, 2004) و تشخیص تغییرات سطح زمین کاربرد دارند (Wulder et al., 2008a). در پژوهشی در ایالات متحده منطقه وسیعی از پوشش گیاهی، درختان و زمین‌های بایر مورد بررسی قرار گرفت که با استفاده از تصاویر لندست عوارض شناسایی و جداسازی شدند (Hansen et al., 2011).

یکی از روش‌های تفکیک و تشخیص عوارض از یکدیگر، استفاده از انواع طبقه‌بندی است. نوع داده‌ها، توزیع آماری دسته‌ها، دقت هدف، سهولت استفاده، سرعت و مقایسه‌پذیری؛ چندین مسئله مهم هستند که در انتخاب نوع طبقه‌بندی موردنظر قرار می‌گیرند. برخی از الگوریتم‌ها برای کلاس‌بندی عوارض بر اساس شباهت ویژگی‌هایشان بدون دخالت و تصمیم‌گیری انسان استفاده می‌شوند که به این نوع طبقه‌بندی، طبقه‌بندی نظارت‌نشده^۵ می‌گویند. با وجود جذابیت‌های این طبقه‌بندی به دلیل خودکار بودن آن، زمانی که حجم داده‌ها زیاد باشد این فرآیند طولانی خواهد بود (Chen and Gong, 2013)، علاوه بر این، دقت دسته‌بندی‌ها به‌مراتب کاهش خواهد یافت. همچنین در این دسته‌ها می‌توان عوارضی را پیدا کرد که از نظر ویژگی هیچ ارتباطی باهم نداشته باشند (Loveland et al., 2000).

روش دیگر طبقه‌بندی، طبقه‌بندی نظارت‌شده^۶ است که در این روش چندین نمونه تعلیمی با دقت بالا از تصویر انتخاب‌شده و به نرم‌افزار معرفی می‌شود، کیفیت خوب نمونه و همچنین تعداد کافی آن بسیار مهم و ضروری است (Bruzzone and Demir, 2014; Shao and Lunetta, 2012) هرچه تعداد و کیفیت نمونه‌ها بیشتر و بهتر باشد می‌تواند دقت دسته‌بندی بالاتر رود (Radoux et al., 2014). این روش‌ها نیز مانند روش‌های دیگر خالی از خطا نیست و نمی‌توانند برخی از عوارض را در طبقه خود قرار دهند (Pal and Mather, 2006). تحقیقات و مطالعات انجام‌شده در زمینه نقشه‌های پوشش گیاهی در مساحتی وسیع نشان داده است که روش طبقه‌بندی نظارت‌شده نسبت به روش طبقه‌بندی نظارت‌نشده ارجحیت و برتری

- 1- LANDSAT
- 2- Thematic Mapper (TM)
- 3- Enhanced Thematic Mapper Plus (ETM)
- 4- Operational Land Imager (OLI)
- 5- Unsupervised Classification
- 6- Supervised Classification

7- Confusion Matrix

8- Neural Network

9- Maximum Likelihood Classifier

10- Support Vector Machines

11- Mahalanobis Distance Classifier

(Means) و همچنین مقایسه عملکرد آن‌ها است.

مواد و روش‌ها

منطقه مورد مطالعه و پیش‌پردازش تصاویر

مکان مورد مطالعه شهرستان بم و بروات واقع در ۲۰۰ کیلومتری جنوب شرق کرمان با ۱۰۵۰ متر ارتفاع از سطح دریا و موقعیت (E: 58° 21' 00", N: 29° 04' 28") می‌باشد که در شکل ۱ قابل مشاهده است. این شهرستان مرکز عمده‌ی تولید خرما در استان کرمان است.

در این پژوهش از تاریخ ۹۵/۴/۱۳ تا تاریخ ۹۵/۱۱/۸ به‌صورت پیوسته هر ۱۶ روز تصاویر لندست ۸ با سنجنده OLI از وبگاه اینترنتی^۱ لندست اخذ شد (USGS, 2016/2017) تصاویر، مربوط به تابستان، پاییز و زمستان سال ۹۵ هستند که ۲ ساعت بعد از تصویربرداری بر روی سایت سازمان زمین‌شناسی آمریکا^۲ قرار گرفته و سپس با وارد کردن موقعیت جغرافیایی موردنظر می‌توان تصویر را از سایت دریافت کرد. تصاویر لندست دارای قدرت تفکیک مکانی ۳۰ متر و باند تک طیفی ۱۵ متر است که دوره بازگشت آن ۱۶ روزه می‌باشد. واسنجی دقیق و هماهنگی رادیومتریک توسط سنجنده لندست انجام می‌شود. از ویژگی‌های آن، نقشه‌بردار موضوعی دقیق (TM)، نقشه‌بردار فوق پیشرفته (ETM+) و تصویربردار کارآمد از سطح زمین است که واسنجی و توانایی استفاده از داده‌های این تصاویر باعث شده است که آرشیو تصاویر لندست جزئی از نمونه‌ای قوی در تصاویر ماهواره‌ای باشد (Wulder *et al.*, 2008b). تصحیحات رادیومتریک و هندسی اولیه بر روی این تصاویر توسط سازمان زمین‌شناسی آمریکا انجام شده و بر روی وبگاه قرار داده شده است. در میان تصاویر، تصویرهای برداشت‌شده در تاریخ‌های (۹۵/۱۱/۸ و ۹۵/۱۰/۶، ۹۵/۹/۴، ۹۵/۷/۱۶) اصطلاحاً سوخته و هیچ اطلاعاتی در آن‌ها قابل‌برداشت نبود. در میان تصاویر باقی‌مانده تصویر اخذ شده در تاریخ ۹۵/۱۰/۲۲ مورد استفاده و مطالعه قرار گرفت؛ زیرا در این فصل به دلیل احتمال سرمازدگی یونجه، کشاورزان محصول را برداشت نکرده و یونجه در این فصل به‌خوبی قابل‌شناسایی است. طرح‌واره مراحل دریافت و پردازش تصاویر در شکل ۲ نشان داده شده است.

همان‌طور که در شکل ۲ قابل‌مشاهده است، پس از دریافت تصاویر از وبگاه، تصاویر در نرم‌افزار ENVI نسخه ۳-۵ باز و تصحیحات رادیومتریک و سپس اتمسفری روی این تصاویر اعمال شد. برای تصحیح هندسی از نرم‌افزار ArcGis10.3 استفاده و به کمک سامانه مکان‌یابی جهانی (GPS) ۱۰ نقطه از منطقه مورد نظر

برداشت شده و پس از وارد نمودن به نرم‌افزار، تصحیحات هندسی بر روی تصویر انجام شد، مقدار دقت آن ۰/۴۵ پیکسل محاسبه شد.

طبقه‌بندی عوارض

پس از تصحیحات اولیه بر روی عکس مورد مطالعه برای انجام این پژوهش، پوشش سطحی زمین به ۳ کلاس خرما، علوفه و خاک تقسیم‌بندی شد. برای هر یک از کلاس‌ها ۳۲ نمونه توسط GPS نمونه‌برداری شد. مجموع تعداد کل پلات‌های آموزشی هر ۳ کلاس ۹۶ پلات بود. ویژگی‌های پلات‌های آموزشی در کلاس خرما به‌صورت کاملاً متراکم نمونه‌برداری شد همچنین در کلاس‌های دیگر از نظیر علوفه پلات‌ها به‌صورت کامل پوشیده از یونجه بودند و آخرین پلات نیز مربوط به کلاس خاک است که از زمین‌های بایر بدون پوشش گیاهی نمونه‌برداری شد و سپس در نرم‌افزار ArcGis به فرمت قابل‌نمایش^۳ در هر دو نرم‌افزار ENVI و ArcGis تبدیل شدند. این فرمت از نوع داده‌های برداری^۴ می‌باشد که می‌تواند فایل نقاط^۵، فایل‌های خطی^۶ و سطحی^۷ را در خود ذخیره‌سازی کند. برای انتخاب روش‌های مورد استفاده در این پژوهش، تصویر مورد مطالعه توسط تمامی روش‌ها طبقه‌بندی شد. در طبقه‌بندی نظارت شده از میان تمامی روش‌ها، روش‌های NN، SVM، MLC، MDC بالاترین دقت را برای شناسایی ۳ کلاس به‌دست آوردند و در طبقه‌بندی نظارت نشده نیز از بین دو روش موجود در نرم‌افزار از جمله ISO data و K-Means، روش K-Means نسبت به روش دیگر نتایج بهتری را به‌دست آورد.

الگوریتم MDC یکی از توابع مبتنی بر فاصله به‌شمار می‌آید که از حد طبقه‌بندی کران‌های پایین‌تر برای طبقه‌بندی زیرمجموعه‌های خود استفاده می‌کند (De Maesschalck *et al.*, 2000).

الگوریتم MLC یک روش پارامتریک است زیرا بر اساس توزیع احتمالی مقادیر، پیکسل‌ها را دسته‌بندی می‌کند (Kirchhof *et al.*, 1980). در طبقه‌بندی با این روش، کلاسی به پیکسل مورد نظر انتساب داده می‌شود که بیشترین احتمال تعلق پیکسل به آن کلاس وجود دارد (Fazeli-farsani *et al.*, 2015).

الگوریتم‌های SVM و NN نیز روش‌های غیر پارامتریک هستند که تشخیص الگو از طریق هوش مصنوعی صورت می‌گیرد و قابلیت تعمیم دارند (Huang *et al.*, 2002). روش SVM یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده کرده و به یک جواب بهینه کلی منجر می‌گردد (Ghorbani *et al.*, 2016).

3- Shape file (*.shp)

4- Vector


5- Point shape file

6- Line shape file

7- Polygon shape file

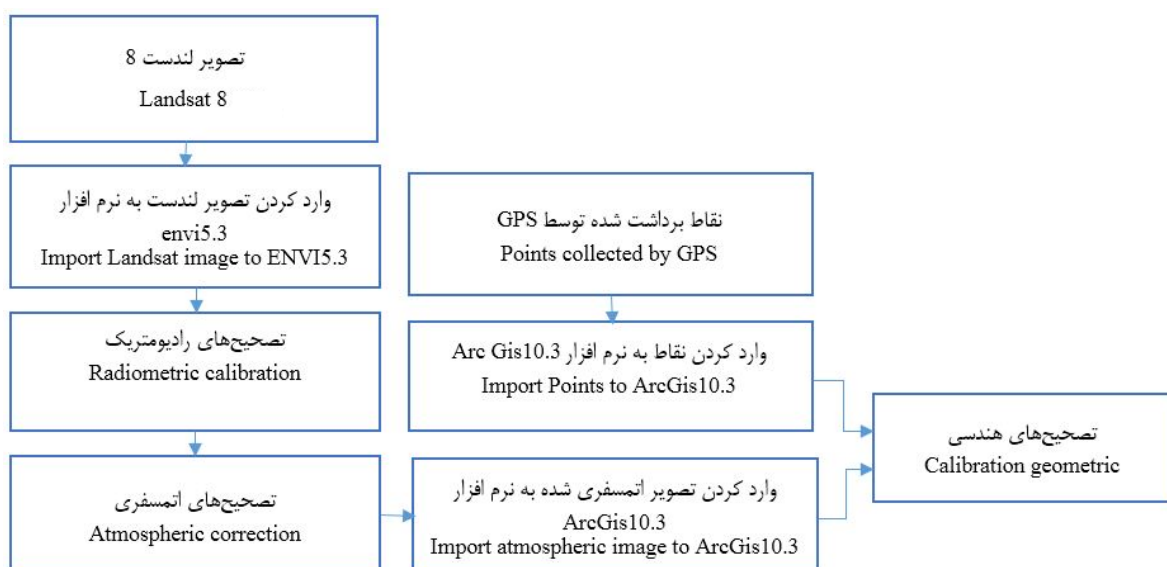
1- Earthexplorer.usgs.gov

2- U.S. Geological Survey (USGS)



شکل ۱- تصویر Landsat8 از منطقه مورد مطالعه بم- بروات با تفکیک مکانی ۱۵ متر (A). پوشش غالب مزارع یونجه (a)، ترکیب مزارع یونجه و نخلستان‌های خرما (b)، پوشش غالب نخلستان‌های خرما (c)

Fig.1. Landsat 8 Images of the Bam-Baravat study region with 15-m spatial resolution (A). The dominant coverage of alfalfa farms (a), Combination of alfalfa farms and Palm date (b), The dominant coverage of palm date (c)



شکل ۲- نمودار پیش‌پردازش تصاویر Landsat8
Fig. 2. Landsat8 image pre-processing flow chart

ضرب شدن در وزن‌های ارتباط‌دهنده‌ی نرون‌ها، وارد لایه‌های میانی می‌شوند. در هر نرون از لایه‌های میانی، یک تابع فعالیت بر روی ورودی‌ها اعمال شده و مقادیر محاسبه شده به لایه‌های خروجی فرستاده می‌شود. در این مرحله، خروجی شبکه با مقدار مطلوبی که از

جذابیت ماشین بردار پشتیبان در قابلیت آن در حداقل کردن ریسک ساختاری یا خطای طبقه‌بندی هنگام حل مسئله‌ی طبقه‌بندی است (Vapnik, 1995). در ساختار الگوریتم NN برای آموزش شبکه، نمونه‌های آموزشی از طریق ورودی وارد شبکه شده و بعد از

Rostami and Afzali, 2016) که ویژگی‌های پلات‌های ارزیابی همانند پلات‌های آموزشی در کلاس خرما به‌صورت کاملاً متراکم، در کلاس علوفه تمامی پلات‌ها پوشیده از یونجه و در کلاس خاک زمین‌های عاری از پوشش گیاهی هستند. برای اعتبارسنجی و بررسی دقت طبقه‌بندی از معیارهای ضریب کاپا و دقت کلی با استفاده از روش ماتریس آشفتگی استفاده شد. دقت کلی ماتریس آشفتگی مربوط به درصد تعداد پیکسل‌هایی است که درست کلاس‌بندی شده و ضریب کاپا نشان‌دهنده میزان انطباق طبقه‌بندی نرم‌افزار و نمونه‌های آموزشی است (Richards, 1995).

کومار و همکاران در سال ۲۰۱۵ میلادی در تحقیق خود برای اعتبارسنجی طبقه‌بندی از ماتریس آشفتگی استفاده کردند. به این صورت که ورودی‌های نرم‌افزار ENVI5.3 تصویر طبقه‌بندی شده از هر الگوریتم و ۹۶ پلات ارزیابی منطقه‌ی مورد مطالعه است که ورودی‌های روش ماتریس آشفتگی هستند؛ خروجی این روش جدولی است با عناوین دقت کلی، ضریب کاپا، صحت تولیدکننده^۳ و صحت کاربر^۴ می‌باشد که نماینده درستی و جابه‌جایی پیکسل‌ها در هر کلاس هستند. در ماتریس آشفتگی به دلیل جابه‌جایی بین کلاس‌ها در طبقه‌بندی‌ها مواردی از تصویر مرجع و تصویر طبقه‌بندی شده مطابقت ندارد. این عدم انطباق به دلیل دو اشتباه در طبقه‌بندی است که این اشتباه در ماتریس آشفتگی نشان داده می‌شود. اولین اشتباه خطای تولیدکننده (سیستم)^۵ است. این خطا زمانی اتفاق می‌افتد که در یک روش طبقه‌بندی، پیکسل‌ها را به یک کلاس خاص اختصاص دهند که در واقع متعلق به آن نیستند. همچنین مقدار اشتباهات سیستم توسط دقت تولیدکننده نشان داده می‌شود و دقت تولیدکننده نیز از تعداد پیکسل‌های که به‌درستی در یک کلاس شناسایی شده‌اند بر تعداد کل پیکسل‌های کلاس در تصویر مرجع به‌دست می‌آید. دومین اشتباه، خطای کاربر^۶ است، این خطا زمانی رخ می‌دهد که پیکسل‌هایی که در واقع متعلق به یک کلاس هستند در کلاس دیگری قرار می‌گیرند. دقت کاربر شاخص دیگری است که میزان اشتباهات کاربر را مشخص می‌کند و از تعداد پیکسل‌های صحیح شناسایی‌شده در یک کلاس بر تعداد کل پیکسل‌های کلاس در تصویر طبقه‌بندی شده به‌دست می‌آید. که هر کدام از این فاکتورهای تشکیل‌دهنده ماتریس آشفتگی در علوم آماری نیز مورد استفاده قرار می‌گیرد که نام‌های دیگری را به خود اختصاص داده‌اند (Powers, 2011; SammutWebb, 2012; Powers, 2012). زمانی که تعداد نمونه‌ها بیشتر می‌شود با استفاده از ماتریس آشفتگی می‌توان خطا را به حداقل رساند. برای دستیابی به ماتریس آشفتگی از دستور

شبکه انتظار می‌رود مقایسه شده و مقدار خطای موجود از روش‌های مختلف با تغییر در وزن‌های ارتباط‌دهنده‌ی نرون‌ها در شبکه، تعدیل می‌شود (Fatemi-talab *et al.*, 2015).

الگوریتم K-Means از روش‌های تجزیه و تحلیل خوشه‌ای^۱ است که با استفاده از واریانس هر پیکسل بر اساس ویژگی‌های طیفی هر باند از تصویر ماهواره‌ای آن‌ها را در یک گروه دسته‌بندی می‌کند (Zobeiry and Majd, 2013).

برای این طبقه‌بندی‌ها ابتدا تصویر تصحیح شده و پلات‌های آموزشی به نرم‌افزار ENVI5.3 معرفی شدند، سپس با استفاده از هر یک از الگوریتم‌ها تصویر طبقه‌بندی شد.

پس از طبقه‌بندی، مساحت هر یک از باغات مورد آزمایش به کمک نتایج ماتریس آشفتگی^۲ که بر روی هر یک از پلات‌های ارزیابی اعمال شد، تعیین گردید. ماتریس آشفتگی نشان‌دهنده میزان جابه‌جایی بین پیکسل‌ها در کلاس‌ها و همچنین میزان تشخیص درصد صحیح پیکسل‌ها در کلاس‌ها است (Lillesand *et al.*, 2014; Rostami *et al.*, 2014). با استفاده از این جداول می‌توان تعداد پیکسل‌های جابه‌جا شده در هر کلاس را محاسبه و با داشتن این پیکسل‌ها مساحت دقیق نخلستان‌ها را محاسبه کرد و با داشتن اندازه پیکسل تصویر و مقدار پیکسل‌های صحیح تشخیص داده شده هر یک از پلات‌های ارزیابی، مساحت هر یک از پلات‌ها را به‌دست آورد. برای مقایسه‌ی روش تعیین مساحت با استفاده از روش ماتریس آشفتگی با مساحت به‌دست آمده با روش میدانی که با استفاده از GPS به‌دست آمد منحنی رگرسیون خطی بین دو دسته داده یاد شده ترسیم گردید.

برای طبقه‌بندی نظارت‌نشده نیز ۳ کلاس همانند روش طبقه‌بندی نظارت‌شده و ۵ بار تکرار برای هر طبقه‌بندی در نظر گرفته شد و سپس مساحت نخلستان به‌دست آمد که همانند روش قبل منحنی رگرسیون خطی بین داده‌های مساحت به‌دست آمده از روش ماهواره‌ای و روش میدانی ترسیم شد.

اعتبارسنجی

جهت دستیابی به نتایج کارایی الگوریتم‌ها نسبت به تعداد نمونه‌های آموزشی در روش‌های مختلف طبقه‌بندی نظارت شده از آنالیز حساسیت استفاده شد. داده‌های آموزشی به ۴ دسته ۸۰ درصد، ۶۰ درصد، ۴۰ درصد، ۲۰ درصد داده‌های آموزشی تقسیم‌بندی (Shahosseini *et al.*, 2009) و نمودار بر اساس درصد خطای هر دسته رسم شد.

در ارزیابی دقت طبقه‌بندی تصاویر، برای هر یک از کلاس‌ها، ۳۲ پلات ارزیابی مورد استفاده قرار گرفت (Rostami *et al.*, 2014;)

3- Producer accuracy (Recall or Sensitivity)

4- User accuracy or Precision

5- Omission error

6- Commission error

1- Cluster Analysis

2- Confusion Matrix

ENVI confusion matrix using ground truth rois استفاده شد

فاکتور دیگری که برای ارزیابی الگوریتم‌ها استفاده شد F-score است که نشان‌دهنده‌ی رابطه بین دو فاکتور دقت تولیدکننده و دقت کاربر در ماتریس آشفتگی است و از رابطه (۱) محاسبه می‌شود.

$$F - score = \frac{2}{\left(\frac{1}{recall} + \frac{1}{precision}\right)} \quad (1)$$

برای بررسی میزان خطای تخمین سطح زیر کشت نیز از معیار خطای مربع میانگین^۱ استفاده شد. مساحت باغات (نخلستان‌ها) ارزیابی بر روی تصاویر طبقه‌بندی شده در ArcGis محاسبه و سپس با در دست داشتن مساحت واقعی باغات که با روش میدانی اندازه‌گیری شده بود و با استفاده از نرم‌افزار اکسل خطای مربع میانگین محاسبه شد.

نتایج و بحث

نتایج اجرای الگوریتم‌های طبقه‌بندی نظارت‌شده (NN, MLC, SVM and MDC) در منطقه‌ی مورد مطالعه در شکل ۳ و همچنین نتایج طبقه‌بندی نظارت‌نشده K-Means و چند نمونه از تشخیص نادرست عارضه‌ی خرما در دو منطقه‌ی متفاوت در شکل ۴ قابل مشاهده است.

نتایج آنالیز حساسیت در انواع طبقه‌بندی‌های نظارت شده نسبت به تعداد نمونه‌های آموزشی در شکل ۵، نشان داده شده است. این نتایج نشان داد با افزایش تعداد نمونه‌ها آموزشی دقت کلی طبقه‌بندی بالا می‌رود. طبق تحقیقات گذشته شاه حسینی و همکاران روند کاهش مشابهی را در نمودار آنالیز حساسیت بر روی الگوریتم ماشین بردار پشتیبان مشاهده کردند (Shahosseini et al., 2009). در مجموع روند نزولی افزایش تعداد نمونه‌ها و کاهش خطا در همه الگوریتم‌ها مشابه بود.

نمونه‌ای از ماتریس آشفتگی از روش طبقه‌بندی NN در جدول ۱ و نتایج تمامی روش‌ها به صورت خلاصه در جدول ۲ آورده شده است. نتایج جدول ۲ نشان می‌دهد که روش NN، بالاترین دقت کلی ۹۹/۱٪ و ضریب کاپا ۰/۹۸ را به خود اختصاص داده است و کمترین دقت، مربوط به روش MDC، با دقت کلی ۹۸/۵۲٪ و ضریب کاپا ۰/۹۷ است. در جدول ۱ می‌توان به این نکته اشاره کرد که درصد اشتباهات تولیدکننده (سیستم) در اثر جابه‌جایی بین کلاس‌ها در کلاس خرما ۰٪ و کاربر ۱/۴۴٪ است. کمترین خطای تولیدکننده (سیستم) در کلاس خرما، مربوط به روش SVM، NN، با مقدار ۰٪ و بیشترین خطا با مقدار ۱/۳۵٪ و خطای کاربر نیز ۰٪ در روش MLC

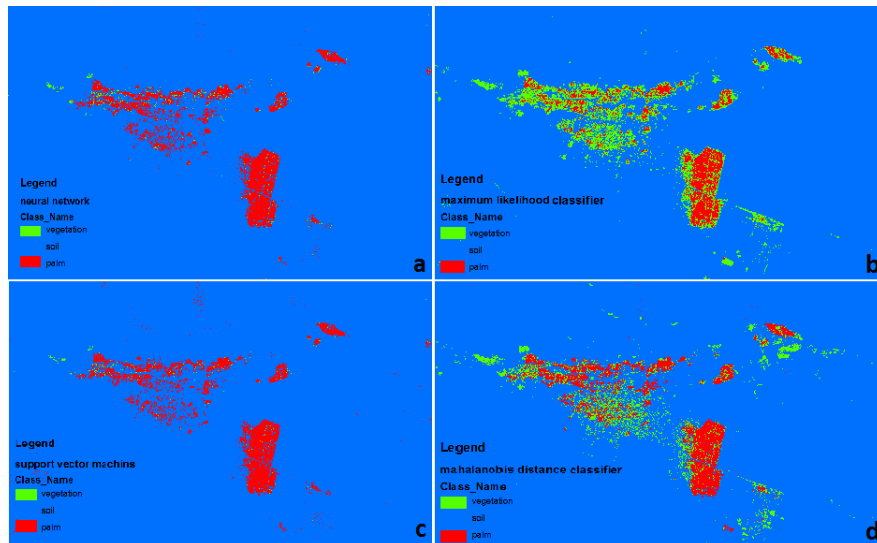
به‌دست آمد. بررسی‌ها برای قدرت تشخیص کلاس‌های دیگر نشان‌دهنده آن است که در کلاس خاک بیشترین خطای تولیدکننده (سیستم) مربوط به روش MDC با ۲/۳۲٪ و کمترین خطا مربوط به MLC با مقدار ۰/۶۴ می‌باشد. برای کلاس علوفه نیز کمترین خطای تولیدکننده (سیستم) مربوط به روش MDC با ۴/۹۲٪ و بیشترین خطا مربوط به روش SVM با ۳۷/۰۷٪ خطا محاسبه شد. پس می‌توان نتیجه گرفت که NN با ۱۰۰٪ قدرت تشخیص نخلستان، بهترین روش شناخته شد. در مطالعات قبلی نیز نتایج مشابهی دیده شد (Petropoulos et al., 2010; Alipour et al., 2014). ولی نتایج تحقیق دیگری که در منطقه‌ای از هند بر روی چند محصول کشاورزی انجام شد نشان داد که SVM قدرت شناسایی بهتری نسبت به NN داشت (Kumar et al., 2015).

نتایج نشان داد که روش SVM دومین روش قدرتمند برای شناسایی نخلستان‌ها بود، بر اساس نتایج به‌دست آمده این روش نیز توانست بدون خطا نخلستان‌ها را شناسایی کند. از بررسی جداول ماتریس آشفتگی می‌توان این نتیجه را گرفت که تنها نمی‌توان بر اساس دو شاخص دقت کلی و ضریب کاپا نسبت به برتری روش‌ها در یک کلاس به‌خصوص نظر داد و روش‌ها را مقایسه کرد. همان‌طور که نتایج نشان می‌دهند روش SVM نسبت به روش MLC کمترین درصد دقت کلی و ضریب کاپا را دارا است اما بهتر توانسته باغات خرما را شناسایی کند و در مقابل توانایی تشخیص روش MLC در دیگر کلاس‌ها برخلاف کلاس باغات خرما نسبت به روش SVM بالاتر بوده است. همین عامل باعث شده است که SVM در مجموع، دقت کلی و ضریب کاپای پایین‌تری را به خود اختصاص دهد. در روش K-Means با توجه به ضریب کاپا ۰/۳۱ از کیفیت طبقه‌بندی خوبی برخوردار نیست، اما با توجه به کلاس‌ها و پلات‌های ارزیابی برای بررسی این طبقه‌بندی توانست با ۱۰۰٪ دقت، به‌درستی نخلستان‌ها را نسبت به نمونه‌های انتخابی شناسایی کند، اما این مطلب را نیز باید در نظر داشت که نسبت به کل طبقه‌بندی انجام‌شده در تصویر، علاوه بر نخلستان‌ها، زمین‌های غیرزراعی و کوهستان‌ها را نیز، به‌عنوان نخلستان شناسایی کرده است که به‌طور مثال نمونه‌ای از اشتباهات این روش در شکل ۴ نشان داده شده است؛ که خود دلیل نامطمئن بودن و بی‌دقتی این روش می‌باشد و در هر سه کلاس این بی‌دقتی قابل مشاهده است.

نتایج فاکتور F-score شاخص متوسط اندازه‌گیری از دو عامل تشکیل‌دهنده در جدول ماتریس آشفتگی در الگوریتم NN، MLC، SVM، MDC و K-Means به ترتیب ۹۹/۳۲، ۹۹/۳۷، ۹۸/۸۴، ۹۹/۳۵ و ۸۲/۶۷ به‌دست آمده است. نتایج نشان می‌دهند یکی از عوامل کاهش‌دهنده‌ی این شاخص در الگوریتم‌های NN و SVM نسبت به دو الگوریتم طبقه‌بندی نظارت شده دیگر، خطای کاربر است زیرا خطای سیستم در این دو الگوریتم کمترین میزان خود را نسبت

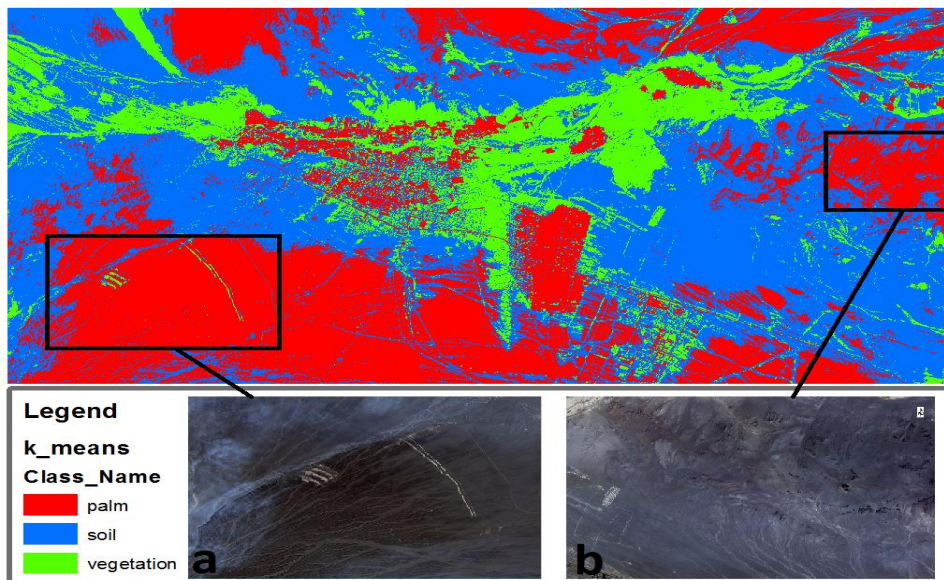
1- Root mean square error

به سایر الگوریتم‌ها داشته است.



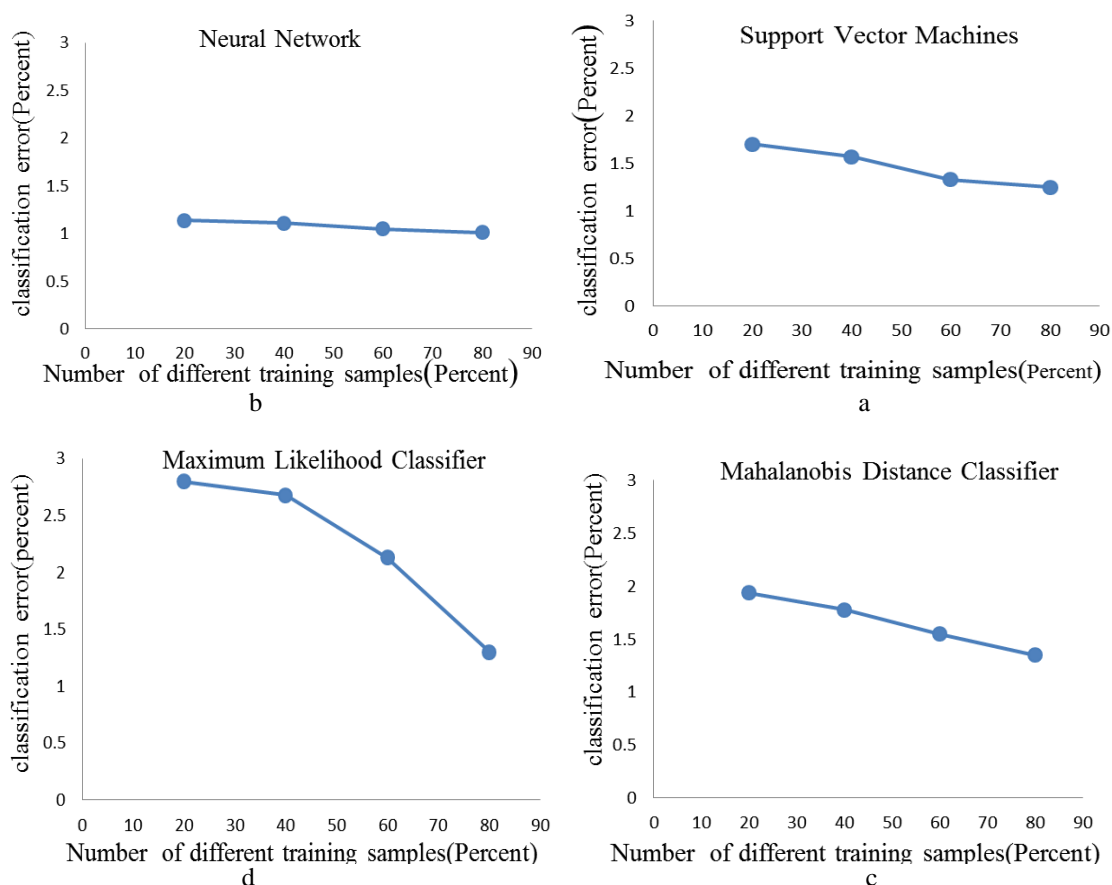
شکل ۳- نتایج تشخیص نخلستان خرما و دو کلاس دیگر با استفاده از الگوریتم‌های طبقه‌بندی نظارت‌شده (a) روش NN، (b) روش MLC، (c) روش SVM و (d) روش MDC در منطقه‌ی مورد مطالعه. نقاط قرمز رنگ نشان‌دهنده مناطق با کلاس نخلستان خرما، نقاط سبز رنگ مزارع یونجه و نقاط آبی رنگ خاک است.

Fig. 3. The results of diagnosed date palm orchard and two other classes using supervised classifications a) NN, b) MLC, c) SVM and d) MDC in the studied area. Red, green and blue points show date palm, alfalfa fields and soil, respectively.



شکل ۴- نتایج تشخیص نخلستان خرما با استفاده از طبقه‌بندی نظارت‌نشده K-Means در منطقه‌ی مورد مطالعه. a و b دو نمونه از تشخیص نادرست نخلستان خرما توسط طبقه‌بندی نظارت‌نشده K-Means

Fig. 4. The results of diagnosed date palm orchard using unsupervised classification in studied area (K-Means). (a and b) two examples of incorrect palm date recognition by unsupervised classification (K-Means)



شکل ۵- آنالیز حساسیت خطای طبقه‌بندی در الگوریتم‌های نظارت شده نسبت به تعداد نمونه‌های آموزشی

Fig. 5. Sensitivity Analysis of classification Errors in supervised algorithms respect to the number of training samples

جدول ۱- ماتریس آشفتگی بر اساس تعداد پیکسل (Neural network)

Table 1- Neural network Confusion matrix Ground Truth (Pixels)

کلاس Class	خرما Palm	علوفه Vegetation	خاک Soil	جمع Sum	صحت کاربر User accuracy (%)
خرما (Palm)	1708	4	21	1733	98.56
علوفه (Vegetation)	0	44	0	44	100
خاک (Soil)	0	13	2417	2484	99.48
جمع (Sum)	1708	61	2492	4261	
صحت تولیدکننده (Producer accuracy) (%)	100	72.13	99.16		

ضریب تبیین^۱ ۰/۹۹۹۵ و بعد از آن روش SVM با ضریب تبیین ۰/۹۹۸۶ برای شناسایی نخلستان‌ها، دقیق‌تر از سایر روش‌ها بوده‌اند که نتایج نمودارها تصدیق‌کننده‌ی نتایج ماتریس آشفتگی در مطالب ذکر شده است.


شکل ۶ منحنی‌های همبستگی بین مساحت باغات خرما به روش میدانی و مساحت محاسبه شده به وسیله طبقه‌بندی، توسط نرم‌افزار را نشان می‌دهد. نتایج این نمودارها همان‌طور که در شکل ۶ مشاهده می‌شود بسیار نزدیک هستند. این مطلب بیانگر آن است که هر چهار روش، برای بررسی و شناسایی نخلستان‌های خرما قابل اعتماد هستند، اما زمانی که دقت کار مطرح شود می‌توان گفت روش NN با

1- Coefficient of determination (R^2)

جدول ۲- خطاهای ماتریس آشفتگی در کلیه روش‌های طبقه‌بندی نظارت شده و نظارت نشده

Table 2- Confusion matrix error in all supervised classification and unsupervised classification methods

		Palm خرما	Vegetation علوفه	Soil خاک	Overall accuracy دقت کلی	Kappa coefficient ضریب کاپا
Neural networks	Commission	1.44	0.00	0.52	%99.10	0.98
	Omission	0.00	27.87	0.84		
Maximum likelihood classifier	Commission	0.00	43.43	0.60	%98.77	0.975
	Omission	1.35	21.31	0.64		
Support vector machines	Commission	2.29	0.00	0.69	%98.66	0.973
	Omission	0.00	36.07	1.40		
Mahalanobis distance classifier	Commission	1.16	41.41	0.08	%98.52	0.97
	Omission	0.12	4.92	2.33		
k-means	Commission	29.54	4.69	97.85	%52.66	0.31
	Omission	0.00	79.61	54.10		



شکل ۶- نمودار رابطه بین مساحت نخلستان خرما حاصل از ۴ روش طبقه‌بندی نظارت شده و اندازه‌گیری مساحت به صورت میدانی

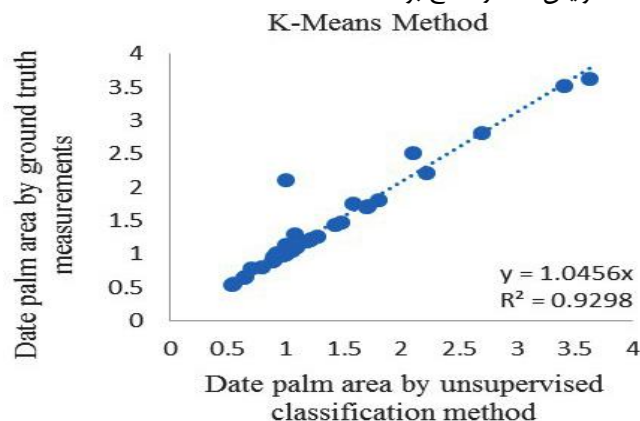
Fig. 6. Charts the relation between date palm area 4 methods supervised classification and field measurements

با مساحت همان نمونه در طبقه‌بندی صادق است نه برای کل تصویر. همچنین ضمن مشاهده شکل ۴ باید توجه داشت، خاک‌هایی که کمی تیرگی داشته‌اند نیز در کلاس نخلستان‌ها قرار گرفته‌اند که خود دلیل دقت بسیار پایین این روش برای تشخیص کلاس خرما نسبت به دیگر کلاس‌ها است. برای دسترسی به جوابی دقیق‌تر در شکل ۷ تفاوت بین نمودار طیفی نخلستان‌ها و محل اشتباه طبقه‌بندی شده نشان داده شده است.

خطای مربع میانگین در تخمین مساحت باغات خرما به‌وسیله الگوریتم‌های SVM و NN مقدار صفر و به‌وسیله الگوریتم‌های MLC و MDC به ترتیب ۰/۲ و ۰/۰۶ محاسبه شد. در روش بدون ناظر K-Means نیز همبستگی مناسبی بین مساحت نمونه‌های اندازه‌گیری شده میدانی و محاسبه‌شده توسط نرم‌افزار وجود داشت (شکل ۷). مقدار RMSE در محاسبه مساحت در نمونه‌های ارزیابی صفر بود که این نتیجه تنها برای مساحت نمونه‌های اندازه‌گیری شده

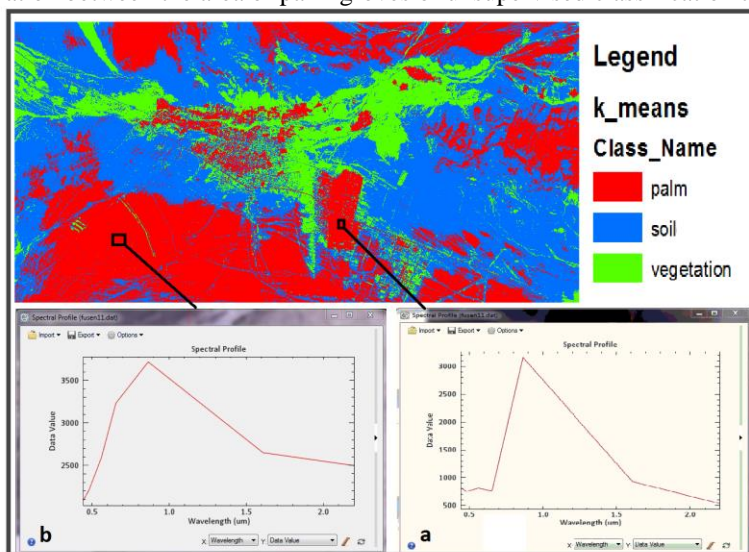
شده و در نتیجه برگ می‌سوزد. در محدوده‌ی مادون قرمز طول موج کوتاه هرچه عارضه دارای رطوبت بالاتری باشد درصد جذب این امواج بیشتر است. در نمودار b در شکل ۸ مشاهده می‌شود که امواج مرئی و مادون قرمز به صورت صعودی بازتابشان افزایش یافته و در طول موج مادون قرمز نزدیک جذب صورت گرفته است (Zobeiry and Majd, 2013). این رفتارهای طیفی مطابق رفتار طیفی گیاه و خاک در کتابخانه‌ی طیفی می‌باشد که در شکل ۹ قابل مشاهده است. در کتابخانه‌ی طیفی محققان رفتار طیفی هر پدیده را به صورت مجزا با جزئیات برداشت کرده‌اند تا در مواقعی که در علم سنجش از دور پدیده قابل شناسایی نبود از طریق رفتار طیفی، آن را شناسایی کنند. در شکل ۸ به دلیل تشابه اندکی که بین رفتار طیفی در دو نمودار a و b وجود دارد نرم‌افزار این دو پدیده را یکی در نظر گرفته است که خود دلیل بر نامطمئن بودن این روش است.

زمانی که امواج الکترومغناطیسی به سطح برگ می‌رسند بخشی از آن جذب و بخشی دیگر بازتاب می‌شوند. مجموعه این بازتاب‌ها جمع‌آوری و سپس منحنی طیفی رسم می‌شود. این منحنی طیفی در گیاهان سالم نسبت به خاک دارای فراز و فرودهای بیشتری است. به این معنا که عوامل مؤثر در بازتاب طیفی خاک، در بازتاب طیفی گیاه نقش کمتری دارند. علاوه بر مطالب گفته‌شده بازتاب منحنی طیفی نسبت به محدوده‌ی مورد مطالعه همچنین واکنش پدیده به محدوده‌ی مورد مطالعه از اهمیت زیادی برخوردار است (Alavipanah, 2017). در مجموع نمودار a در شکل ۸ نشان‌دهنده جذب در طیف‌های مرئی آبی و قرمز با طول موج‌های متوسط ۴۵۰ و ۶۵۰ نانومتر و بازتاب در طیف سبز است. به همین دلیل پوشش گیاهی و برگ‌ها به رنگ سبز دیده می‌شوند. به دلیل اینکه برگ انرژی خود را برای فتوسنتز و تبخیر و تعرق از امواج مرئی جذب کرده است امواج فروسرخ را بازتاب می‌کند و لذا اگر بازتاب صورت نگیرد باعث افزایش دما در سطح برگ



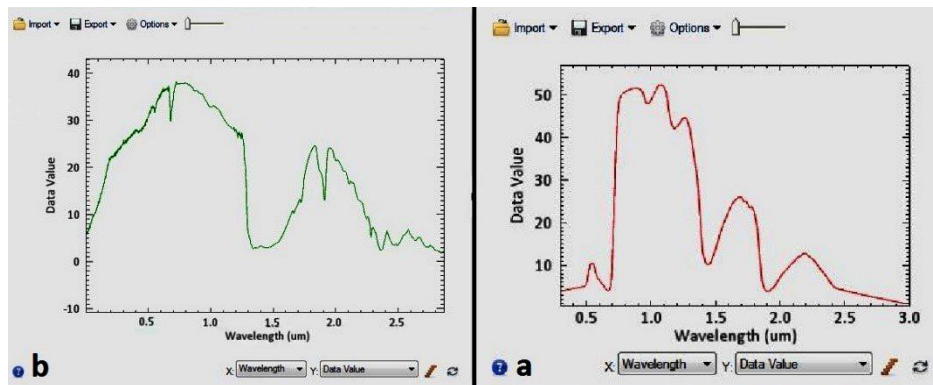
شکل ۷- رابطه بین مساحت نخلستان خرما حاصل از برآورد طبقه‌بندی نظارت‌نشده و اندازه‌گیری میدانی

Fig. 7. Charts the relation between the area of palm groves of unsupervised classification and measurement field



شکل ۸- مقایسه بین دو نمودار طیفی از یک کلاس در روش طبقه‌بندی نظارت‌نشده

Fig. 8. Comparing the two spectral graphs of a class in unsupervised classification method



شکل ۹- نمودار طیفی a: گیاه و b: خاک در کتابخانه طیفی

Fig. 9. Spectral signatures for a) vegetation and b) soil in spectral library

نتیجه‌گیری

در این پژوهش انواع روش‌های طبقه‌بندی به‌منظور شناسایی نخلستان‌های خرما مورد ارزیابی قرار گرفت. نتایج نشان داد تمامی روش‌های طبقه‌بندی نظارت‌شده نتایج قابل قبولی را برای تمایز گذاشتن بین کلاس نخلستان‌های خرما و دو کلاس دیگر به‌دست آوردند. روش NN و SVM از روش‌های طبقه‌بندی نظارت‌شده توانستند بدون خطا کلاس خرما را تشخیص دهند در صورتی که روش طبقه‌بندی نظارت‌نشده K-Means نیز توانست بدون خطا نسبت به نمونه‌ها، نخلستان را تشخیص دهد اما باید دانست اولین فاکتور برای

انتخاب قدرتمندترین روش برای طبقه‌بندی، دقت کلی و ضریب کاپا می‌باشد. لازم به ذکر است تنها این فاکتور پاسخگوی تشخیص قدرتمندترین روش نیست، بلکه فقط دیدی کلی به ما می‌دهد که بتوانیم از بین روش‌ها، ضریب‌ها و درصد دقت‌های مورد قبول را انتخاب کنیم. سپس از بین روش‌های انتخاب‌شده در مرحله اول گزینش، قدرتمندترین روش در کلاس مورد نظر را با استفاده از جابجایی پیکسل‌ها در کلاس‌های مختلف در ماتریس آشفتگی شناسایی کنیم.

References

1. Alavipanah, S. K. 2017. Application of Remote Sensing in the Earth sciences (soil). (In Farsi).
2. Alipour, F., M. H. Aghakhani, M. H. Abasspour-Fard, and A. Sepehr. 2014. Demarcation and Estimation of Agricultural Lands Using ETM+ Imagery Data (Case study: Astan Ghods Razavi Great Farm). Journal of Agricultural Machinery 4 (2): 244-254. (In Farsi).
3. Azizi, J., and S. Yazdani. 2007. Investigation Stability Income of Export Date of Iran. Journal of Agricultural Sciences 13: 1-19. (In Farsi).
4. Bannari, A., A. Pacheco, K. Staenz, H. McNairn, and K. Omari. 2006. Estimating and mapping crop residues cover on agricultural lands using hyperspectral and IKONOS data. Remote Sensing of Environment 104: 447-459.
5. Bruzzone, L., and B. Demir. 2014. A review of modern approaches to classification of remote sensing data. Pages 127-143. Land Use and Land Cover Mapping in Europe, Springer.
6. Büttner, G. 2014. CORINE land cover and land cover change products. Pages 55-74. Land Use and Land Cover Mapping in Europe, Springer.
7. Chen, Y., and P. Gong. 2013. Clustering based on eigenspace transformation-CBEST for efficient classification. ISPRS Journal of Photogrammetry and Remote Sensing 83: 64-80.
8. De Maesschalck, R., D. Jouan-Rimbaud, and D. L. Massart. 2000. The mahalanobis distance. Chemometrics and intelligent laboratory systems 50: 1-18.
9. Detailed results of in the country Agricultural General Census. 2015. Statistical Center of Iran. (In Farsi).
10. Fatemi-talab, S. R., M. Madani pour, and S. A. Hashemi. 2015. Estimating the land coverage changes in Rudsar Jungles using NN and MLC methods. Journal of Remote sensing and GIS in Natural Resources 6 (2). (In Farsi).
11. Fazeli-farsani, A., R. Ghazavi, and M. A. Farzaneh. 2015. Evaluation of land use classification algorithms using image integration method. Journal of Remote sensing and GIS in Natural Resources 6 (1). (In Farsi).
12. Frey, K. E., and L. C. Smith. 2007. How well do we know northern land cover? Comparison of four global vegetation and wetland products with a new ground-truth database for West Siberia. Global Biogeochemical Cycles 21.
13. Fritz, S., L. See, and F. Rembold. 2010. Comparison of global and regional land cover maps with statistical information for the agricultural domain in Africa. International Journal of Remote Sensing 31: 2237-2256.
14. Ghebregabher, M. G., T. Yang, X. Yang, X. Wang, and M. Khan. 2016. Extracting and analyzing forest and

- woodland cover change in Eritrea based on landsat data using supervised classification. *The Egyptian Journal of Remote Sensing and Space Science* 19: 37-47.
15. Ghorbani, M. A., F. Azani, and L. Naghipour. 2016. Comparing SVM and other supervised classification methods in simulating rainfall and run-off. *Research Journal of Aquifers Management* 13.
 16. Gómez, C., J. C. White, and M. A. Wulder. 2016. Optical remotely sensed time series data for land cover classification: A review. *ISPRS Journal of Photogrammetry and Remote Sensing* 116: 55-72.
 17. Gong, W., L. Yuan, W. Fan, X. Wang, and P. Stott. 2016. Comparison to supervised classification modelling in land use cover using Landsat 8 OLI data: an example in Miyun county of North China. *Nature Environment and Pollution Technology* 15: 243.
 18. Huang, C., L. S. Davis, and J. R. Townshend. 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing* 23: 725-749.
 19. Hansen, M. C., A. Egorov, D. P. Roy, P. Potapov, J. Ju, S. Turubanova, I. Kommareddy, and T. R. Loveland. 2011. Continuous fields of land cover for the conterminous United States using Landsat data: First results from the Web-Enabled Landsat Data (WELD) project. *Remote Sensing Letters* 2: 279-288.
 20. Hashemi Tangestani, M., S. Beyranvand, and M. H. Tayebi. 2013. Detection of changes in Bakhtegan lake at time intervals from 1956 to 2007. *Journal of Environmental Studies* 39: 189-199. (In Farsi).
 21. Hussain, M., D. Chen, A. Cheng, H. Wei, and D. Stanley. 2013. Change detection from remotely sensed images: From pixel-based to object-based approaches. *ISPRS Journal of Photogrammetry and Remote Sensing* 80: 91-106.
 22. Khan, A. A., N. Minallah, and S. Khan. 2015. on the performance of supervised classifiers for crop identification and estimation using multi-spectral imagery. *Journal of Engineering and Applied Sciences* 34.
 23. Khatami, R., G. Mountrakis, and S. V. Stehman. 2016. A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote Sensing of Environment* 177: 89-100.
 24. Kirchhof, W., P. Haberäcker, E. Krauth, G. Kritikos, and R. Winter. 1980. A rapid method to generate spectral theme classification of Landsat imagery. *Acta Astronautica* 7: 243-253.
 25. Kumar, P., D. K. Gupta, V. N. Mishra, and R. Prasad. 2015. Comparison of support vector machine, artificial neural network, and spectral angle mapper algorithms for crop classification using LISS IV data. *International Journal of Remote Sensing* 36: 1604-1617.
 26. Lillesand, T., R. W. Kiefer, and J. Chipman. 2014. *Remote sensing and image interpretation*. John Wiley & Sons.
 27. Loveland, T. R., B. C. Reed, J. F. Brown, D. O. Ohlen, Z. Zhu, L. Yang, and J. W. Merchant. 2000. Development of a global land cover characteristics database and IGBP DISCover from 1 km AVHRR data. *International Journal of Remote Sensing* 21: 1303-1330.
 28. NASA. 2017. Landsat Project Description. <https://landsat.usgs.gov/landsat-project-statistics>.
 29. Pal, M., and P. Mather. 2006. Some issues in the classification of DAIS hyperspectral data. *International Journal of Remote Sensing* 27: 2895-2916.
 30. Petropoulos, G. P., K. P. Vadrevu, G. Xanthopoulos, G. Karantounias, and M. Scholze. 2010. A comparison of spectral angle mapper and artificial neural network classifiers combined with Landsat TM imagery analysis for obtaining burnt area mapping. *Sensors* 10: 1967-1985.
 31. Powers, D. M. 2011. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation.
 32. Powers, D. M. 2012. The problem with kappa. Pages 345-355. *Proceedings of the 13th Conference of the European Chapter of the Association for Computational Linguistics: Association for Computational Linguistics*.
 33. Radoux, J., C. Lamarche, E. Van Bogaert, S. Bontemps, C. Brockmann, and P. Defourny. 2014. Automated training sample extraction for global land cover mapping. *Remote Sensing* 6: 3965-3987.
 34. Richards, J. A. 1999. *Remote sensing digital image analysis*. Springer.
 35. Rostami, M. A., and H. Afzali. 2016. Remote Sensing of Residue Management in Farms using Landsat 8 Sensor Imagery. *Journal of Agricultural Machinery* 7 (2): 388-400. (In Farsi).
 36. Rostami, M. A., M. H. Raoufat, A. A. Jafari, M. Loghavi, M. Kasraei, and S. M. R. Nazemsadat. 2014. Monitoring of Conservation Tillage and Tillage Intensity by Ground and Satellite Imagery. *Journal of Agricultural Machinery* 4 (2): 255-265. (In Farsi).
 37. Sammut, C., and G. I. Webb. 2011. *Encyclopedia of machine learning*. Springer Science & Business Media.
 38. Shahosseini, R., S. Homayouni, and M. R. Sarajian. 2009. classification remote sensing images using support vector machines. *Geometric*. (In Farsi).
 39. Shao, Y., and R. S. Lunetta. 2012. Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points. *ISPRS Journal of Photogrammetry and Remote Sensing* 70: 78-87.
 40. Tewkesbury, A. P., A. J. Comber, N. J. Tate, A. Lamb, and P. F. Fisher. 2015. A critical synthesis of remotely sensed optical image change detection techniques. *Remote Sensing of Environment* 160: 1-14.
 41. Vapnik V. 1995. *The nature of statistical learning theory*, Springer-Verlag, New York. 314 pp.

42. Wanga, Q., B. Chena, J. Wang, F. Wanga, H. Hana, S. Li, K. Wang, C. Xiaod, and J. Daid. 2015. Four supervised classification methods for monitoring cotton field of verticillium wilt using TM image. *Journal of Animal and Plant Sciences* 25: 5-12.
43. Wulder, M. A., J. C. White, M. Cranny, R. J. Hall, J. E. Luther, A. Beaudoin, D. G. Goodenough, and J. A. Dechka. 2008a. Monitoring Canada's forests. Part 1: Completion of the EOSD land cover project. *Canadian Journal of Remote Sensing* 34: 549-562.
44. Wulder, M. A., J. C. White, S. N. Goward, J. G. Masek, J. R. Irons, M. Herold, W. B. Cohen, T. R. Loveland, and C. E. Woodcock. 2008b. Landsat continuity: Issues and opportunities for land cover monitoring. *Remote Sensing of Environment* 112: 955-969.
45. Zobeiry, M., and A. R. Majd. 2013. *An Introduction to Remote Sensing Technology and natural resources*. University of Tehran press. (In Farsi).

Determining the Best Classification Algorithm in order to Estimate the Area under Date Palm Cultivation using LANDSAT 8 Satellite Imagery

S. Rahnama¹- M. Maharlooei^{2*}- M. Rostami³- H. Maghsoodi⁴

Received: 14-09-2017

Accepted: 23-07-2018

Introduction

Date palm is one of the most valuable horticultural products in Iran, which includes 16% of non-oil exports to the world. Kerman province has the second rank for the cultivation area of date palm in Iran. Having information about the exact cultivated area has gained importance for further decision makings. To determine the cultivated area, organizations usually use census which has the disadvantages of high cost, wasting time and labor intensive. The aim of this research was to study the feasibility of using Landsat 8 OLI images to identify and classify the area under date palm cultivation. To accomplish this purpose, four supervised classification methods (Maximum Likelihood Classifier (MLC), Support Vector Machines (SVM), Neural Network (NN), and Mahalanobis Distance Classifier (MDC)) and one unsupervised classification method (K-Means) were evaluated.

Materials and Methods

The study area was in Bam region located at 200 km southeast of Kerman province. In this research, a total of 14 images of Landsat8 OLI satellite from the study area during fall and winter were downloaded from Landsat official web page. After preliminary inspections for interested classes (Date palm gardens, Lands covered with bare soil and forage crop fields), one of the images that was taken on Jan 14, 2017, was selected for further analysis. After initial corrections and processing, 32 images of alfalfa farms, 32 images of date palm gardens and 32 images of lands covered with bare soil, were selected using GPS data points collected in study area scouting. Shape files of all selected fields were created and utilized for supervised classification training set. The same process was also done for the unsupervised classification method. To evaluate the classification methods confusion matrix and Kappa coefficient were used to determine the true and miss-classified area under date palm cultivation. It is worth mentioning that these factors alone cannot identify the most powerful method for classification and they just give us a general overview to choose acceptable methods among all available methods. To identify the most powerful method among selected methods, confusion matrix and investigating the pixel transfers between classes is the crucial method.

Results and Discussion

Results of classifications revealed that the overall classification accuracy by using NN, MLC, SVM, MDC, and K-Means were 99.10% (kappa 0.973), 98.77% (kappa 0.975), 98.66% (kappa 0.973), 98.52% (kappa 0.97), and 52.66% (kappa 0.31) respectively. Concerning the confusion matrix in the NN method, the percentage of producer accuracy error in date palm class was 0% and in user, accuracy error was 1.44%. In the review of other methods, the lowest producer accuracy error value in date palm class obtained by NN and SVM methods was 0% and the highest producer accuracy error belonged to MLC method which was 1.35%. Checking the recognition power of other classes showed that in the soil class, the highest producer accuracy error was 2.32% by MDC method and the least one was 0.64% by MLC. For forage class, the highest producer accuracy error was calculated 37.07% by SVM and the least accurate one was 4.92% by MDC. Although the K-Means method with Kappa Coefficient of 0.31 did not have a good classification quality, concerning classes and samples, it successfully could identify date palm according to selective samples with 100% accuracy. Results of calculated date palm area using supervised classification methods versus actual area measurements showed that NN and

1- Graduate Student of Mechanical Engineering of Biosystems, Shahid Bahonar University of Kerman, Kerman, Iran

2- Assistant Professor, Dept. of Mechanical Engineering of Biosystems, Shahid Bahonar University of Kerman, Kerman, Iran

3- Assistant Professor of Agricultural Engineering Research Department, Kerman Agricultural and Resource Research and Education Center, AREEO, Kerman, Iran

4- Assistant Professor, Dept. of Mechanical Engineering of Biosystems, Shahid Bahonar University of Kerman, Kerman, Iran

(*- Corresponding Author Email: maharlooei@uk.ac.ir)

SVM methods with the coefficient of determination (R^2) of 0.9995% and 0.9986% had the highest coefficients. K-Means method with R-square of 0.9228% had a good correlation.

In general, all supervised classification methods obtained acceptable results for distinguishing between date palm classes and two other classes. NN and SVM methods could successfully recognize date palm class. K-Means method also could recognize date palm class but the recognition included some errors such as dark clay soil textures which were classified as the date palm.

Conclusions

In general, overall accuracy and kappa Coefficient alone cannot identify the most powerful method for classifying and these methods just give us a general overview to choose an acceptable percentage of accuracy coefficients among available methods. After the initial selection, to identify the most powerful method of classification the pixel transfer calculations in a confusion matrix would be an acceptable technique.

Keywords: Date palm, Neural networks, Support vector machines, Supervised classification, Unsupervised classification

