



نخستین شماره

GIS ایران

سال نهم، شماره دوم، تابستان ۱۳۹۶
Vol.9, No. 2, Summer 2017

سنجش از دور و GIS ایران
Iranian Remote Sensing & GIS

۱۱۷-۱۳۲



طبقه‌بندی تصاویر چندطیفی با قدرت تفکیک مکانی متوسط، با استفاده از شاخص‌های مکانی و حرارتی

علی شمس‌الدینی^{۱*} و شهریانو اسماعیلی^۲

۱. استادیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه تربیت مدرس، تهران
۲. دانشجوی کارشناسی ارشد سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران

تاریخ پذیرش مقاله: ۱۳۹۶/۶/۲۹

تاریخ دریافت مقاله: ۱۳۹۶/۳/۳۰



چکیده

در طبقه‌بندی تصاویر با قدرت تفکیک مکانی متوسط، مانند لندست، تمایز اراضی کشاورزی بدون پوشش گیاهی از زمین‌های بایر و همچنین، شناسایی زمین‌های بایر از مناطق ساخته‌شده معمولاً دشوار و همراه با خطاست. به همین علت در این مطالعه، ترکیب‌های متفاوتی از ویژگی‌های ورودی، به‌روش‌های طبقه‌بندی، به‌منظور بررسی امکان ارتقای دقت طبقه‌بندی مقایسه شد. داده‌های ورودی شامل باندهای طیفی تصویر لندست-۷، ویژگی‌های بافتی شامل ماتریس وقوع هم‌زمان گام‌های خاکستری و شاخص‌های حرارتی و مکانی پیشنهادی در این تحقیق است. در بررسی حاضر، به‌منظور طبقه‌بندی سناریوهای متفاوت، از سه روش طبقه‌بندی شامل بیشترین میزان شباهت، شبکه عصبی و ماشین بردار پشتیبان با هسته‌های متفاوت استفاده شد. نتایج نشان داد که ادغام تمامی داده‌های ورودی و استفاده از روش ماشین بردار پشتیبان با هسته پایه شعاعی، با صحت کلی ۹۸٪/۸۱ و ضریب کاپا ۰/۹۸/۲۵، ممکن است نتایجی بهتر از دیگر روش‌ها و سناریوها داشته باشد. همچنین، در تحلیل اهمیت متغیرهای ورودی، با استفاده از روش انتخاب ویژگی برپایه جنگل تصادفی، مشخص شد که شاخص‌های پیشنهادی در این مطالعه نقش مهمی در طبقه‌بندی با صحت بالا و کارآمد داشته‌اند.

کلیدواژه‌ها: لندست ۷، جنگل تصادفی، اطلاعات بافت، شاخص‌های مکانی، دمای روشنایی، ماشین بردار پشتیبان.

* نویسنده عهده‌دار مکاتبات: دانشگاه تربیت مدرس، دانشکده علوم انسانی، گروه سنجش از دور و سیستم اطلاعات جغرافیایی. تلفن: ۰۹۱۵۵۰۳۴۵۲۲.

۱- مقدمه

یکی از کاربردهای رایج تصاویر سنجش از دور استخراج اطلاعات کاربری زمین و پوشش زمین است (Lo & Chol, 2004). سنجش از دور قابلیت نظارت بر سطح زمین، با قدرت تفکیک مکانی، طیفی و زمانی متفاوتی، را دارد (Kavazoglu & Colkesen, 2009). طبقه‌بندی تصویر با صحت بالا توصیف الگوی توزیع و پراکندگی مکانی انواع گوناگونی از پوشش زمین است و نتایج حاصل از این طبقه‌بندی، در بسیاری از موضوعات تحقیقاتی مانند شناسایی و تحلیل تغییرات کاربری اراضی و پوشش زمین، کاربرد دارد. بدین منظور، روش‌های متنوعی از الگوریتم‌های طبقه‌بندی بسط و گسترش داده شده است (Yuan et al., 2009; Bastitella & Moran, 2007). طبقه‌بندی کاربری اراضی و پوشش زمین در مناطق ساخته‌شده شهری، به دلیل تنوع و نامتجانس بودن کاربری‌های اراضی و پوشش زمین در محیط شهری، از مباحث چالش‌برانگیز در طبقه‌بندی به‌شمار می‌رود (Lo & Chol, 2004). صحت طبقه‌بندی تصاویر ماهواره‌ای متأثر از ویژگی‌های طیفی و مکانی عوارض در تصاویر است. همچنین، ساده‌ترین و متداول‌ترین روش در طبقه‌بندی تصاویر ماهواره‌ای، به‌منظور استخراج کاربری‌های شهری و پوشش زمین، براساس اطلاعات طیفی پیکسل‌های موجود در تصاویر به حساب می‌آید. نتایج حاصل در این نوع طبقه‌بندی گاه صحت اندکی دارد و بحثی چالش‌برانگیز در مسئله تفکیک انواع کاربری‌های شهری و پوشش زمین مطرح کرده است (Fauvel et al., 2012; Lo & Chol, 2004; Kavazoglu & Colkesen, 2009; Tadesse et al., 2003).

یکی از وظایف مهم و اصلی طبقه‌بندی، در مناطق شهری، تشخیص مناطق شهری ساخته‌شده در زمین‌های بایر است (Li & Chen, 2014). این در حالی است که یکی از مشکلات موجود در طبقه‌بندی نظارت‌شده، براساس داده‌های طیفی، تفکیک مناطق ساخته‌شده از زمین‌های بایر است. در تحقیقات و

مطالعات صورت‌گرفته، نشان داده شده است که استفاده از شاخص‌هایی، مانند شاخص نرمال‌شده مناطق ساخته‌شده (NDBI) و شاخص مناطق جدید ساخته‌شده (NBI) با هدف استخراج ویژگی‌های زمین، به‌ویژه اگر دارای حد آستانه مناسب باشند، می‌تواند مؤثر باشد (Waqar et al., 2012). همچنین بدین‌منظور، در برخی از مطالعات، از شاخص اصلاح‌شده مناطق ساخته‌شده و اراضی بایر (EBBI)^۱ استفاده شده است که طول‌موج‌های ۰/۸۳ میکرومتر، ۱/۶۵ میکرومتر و ۱۱/۴۵ میکرومتر را هم‌زمان به کار می‌برد (As-syakur et al., 2012). بهبود در قدرت تفکیک مکانی باندهای طیفی الزاماً موجب افزایش دقت در طبقه‌بندی کلاس‌های شهری نمی‌شود (Shaban & Dikshit, 2001) بلکه نوع داده‌های ورودی بسیار اهمیت دارد. در صورتی که تعداد و نوع باندهای طیفی به‌درستی انتخاب شده باشند و تعداد نقاط آموزشی به‌درستی و متناسب با ویژگی‌های طیفی کلاس‌ها تعیین شوند، ممکن است دقت طبقه‌بندی افزایش یابد (Hughes, 1968). نتایج حاصل از طبقه‌بندی به عوامل متعددی ارتباط دارد؛ مانند نوع الگوریتم طبقه‌بندی، نوع داده‌های ورودی و انتخاب نمونه‌های آموزشی (Li et al., 2014).

استخراج اطلاعات بافت^۲ مربوط به توزیع آماری و الگوی مکانی سطوح خاکستری عوارض در تصویر برای شناسایی عوارض و یا منطقه مورد مطالعه در یک تصویر مفید و کاربردی است (Zhu, 1996; Chen & Young, 1982; Haralick et al., 1973). بافت منبع بسیار مهمی در استخراج اطلاعات مکانی کلاس‌های مورد نظر در تصاویر ماهواره‌ای به‌شمار می‌رود (Zhang et al., 2014)؛ به‌گونه‌ای که تحلیل بافت توصیفی از ساختار الگوی ناهمگون و توزیع آماری کلاس‌هاست (Ruiz et al., 2004). رویکرد دیگری که در طبقه‌بندی

1. enhanced built-up and bareness index
2. texture

(۲۰۰۸)، در طبقه‌بندی شش باند طیفی لندست-۷، عملکرد بهتر ماشین بردار پشتیبان با هسته تابع پایه شعاعی را در مقایسه با روش‌های طبقه‌بندی، نشان دادند. همچنین، کاوزوگلو و کولکسن^{۱۱} (۲۰۰۹) الگوریتم‌های طبقه‌بندی حداکثر شباهت و ماشین بردار پشتیبان با هسته‌های^{۱۲} چندجمله‌ای^{۱۳} و تابع پایه شعاعی^{۱۴} در تصاویر لندست ETM+ و استر^{۱۵} را مقایسه کردند و نتایج نشان داد ماشین بردار پشتیبان با هسته تابع پایه شعاعی صحتی بیشتر از دیگر الگوریتم‌های طبقه‌بندی دارد.

از مشکلات چالش‌برانگیزی که در استفاده از داده‌های چندطیفی با قدرت تفکیک مکانی متوسط، به‌منظور طبقه‌بندی کلاس‌های شهری و نواحی اطراف آن، مطرح است تفکیک‌نشدن مناسب اراضی کشاورزی، به‌ویژه اراضی کشاورزی بدون پوشش گیاهی (مانند اراضی آیش)، از زمین‌های بایر و همچنین تفکیک‌نشدن مناسب مناطق ساخته‌شده شهری از مناطق بایر است (Raval & Shamsoddini, 2014; As-). به همین علت، هدف کلی این مطالعه طرح راهکاری برای تفکیک اراضی کشاورزی فاقد پوشش گیاهی از اراضی بایر و نیز، تفکیک مناطق شهری از زمین‌های بایر است. به همین منظور، شاخص‌های فاصله و شاخص‌های حاصل از تصاویر حرارتی مطرح شده تا با استفاده از آنها و سناریوهای گوناگون برای داده‌های ورودی، پس از تعیین اهمیت ویژگی‌های ورودی، صحت طبقه‌بندی برای تفکیک نواحی یادشده از هم افزایش یابد.

مطرح و استفاده می‌شود ادغام اطلاعات طیفی و بافتی استخراج‌شده از ساختار و الگوهای مکانی ثبت‌شده عوارض در تصاویر سنجش از دور است. این روش کاربرد بسیار زیادی در طبقه‌بندی کلاس‌های پوشش زمینی دارد و نیز، ادغام این اطلاعات به افزایش صحت طبقه‌بندی کمک می‌کند (Gao et al., 2016; Eiumnoh & Shrestha, 2000; Hulchinson, 1982).

وجود کاربری‌ها و پوشش‌های متنوع و متعدد سبب کاهش صحت طبقه‌بندی در تفکیک کلاس‌های کاربری زمین، در تصاویری با قدرت تفکیک مکانی متوسط، مانند لندست TM/ETM+^۱ می‌شود. به همین منظور، تحقیقات و مطالعات فراوانی برای بهبود صحت طبقه‌بندی در کاربری اراضی و پوشش زمین صورت گرفته است (Kavazoglu & Colkesen, 2009). لو و ونگ^۲ (۲۰۰۵)، با استفاده از تصاویر لندست-۷ در هشت سناریوی متفاوت، برای داده‌های ورودی و با استفاده از روش حداکثر شباهت^۳، اقدام به طبقه‌بندی کاربری اراضی و پوشش زمینی در مناطق شهری و نواحی اطراف آن کردند. نتایج ایشان نشان داد که با ادغام اطلاعات طیفی و بافتی استخراج‌شده از تصویر پانکروماتیک لندست-۷، صحت کلی ۷۸٪ و ضریب کاپای^۴ ۷۲/۹۰٪ برای نقشه‌های طبقه‌بندی حاصل می‌شود. چو و همکاران^۵ (۲۰۱۲)، با استفاده از اطلاعات بافتی تصاویر TM و SAR^۶ و ادغام این داده‌ها و اعمال روش الگوریتم ژنتیک، برای انتخاب داده‌های ورودی مناسب به الگوریتم طبقه‌بندی ماشین بردار پشتیبان^۷، نقشه‌ای با صحت کلی ۹۶/۴۷٪ و ضریب کاپای ۸۱٪ پدید آوردند. ژانگ و همکاران^۸ (۲۰۱۴)، با هدف تهیه نقش کاربری اراضی، اطلاعات طیفی و اطلاعات بافتی حاصل از پنجره با اندازه ۷×۷ از تصاویر لندست TM/ETM+ را ادغام کردند و با استفاده از الگوریتم طبقه‌بندی ماشین بردار پشتیبان ضریب کاپای ۸۴/۴۹٪ و صحت کلی^۹ ۹۲/۳۵٪، برای تصویر طبقه‌بندی‌شده، به‌دست آمد. اومن^{۱۰} و همکاران

1. thematic mapper and enhancement thematic mapper
2. Lu and Weng
3. Maximum Likelihood
4. Kappa coefficient
5. Chu et al.
6. advanced land observing SATELLITE
7. support vector machine
8. Zhang et al.
9. overall accuracy
10. Oommen
11. Kavzoglu and Colkesen
12. kernel
13. polynomial
14. radial basis founction
15. ASTER

۲- الگوریتم‌های طبقه‌بندی

همان‌گونه که در جدول ۱ آمده است (Melgani & Bruzzone, 2004; Cristianini & Taylor, 2000; Bishop, 2007; Afifi, 2014; Devadas et al., 2012; Richards, 2013; Hughes, 1968; Ruiz et al., 2004; Shi & Xue, 2016)، در این تحقیق از الگوریتم‌های طبقه‌بندی نظارت‌شده شامل بیشترین میزان شباهت، شبکه عصبی^۱، ماشین بردار پشتیبان با هسته‌های خطی^۲ درجه اول و دوم، چندجمله‌ای درجه اول و دوم و تابع پایه شعاعی، به‌منظور طبقه‌بندی تصاویر و مقایسه این روش‌ها، استفاده شده است.

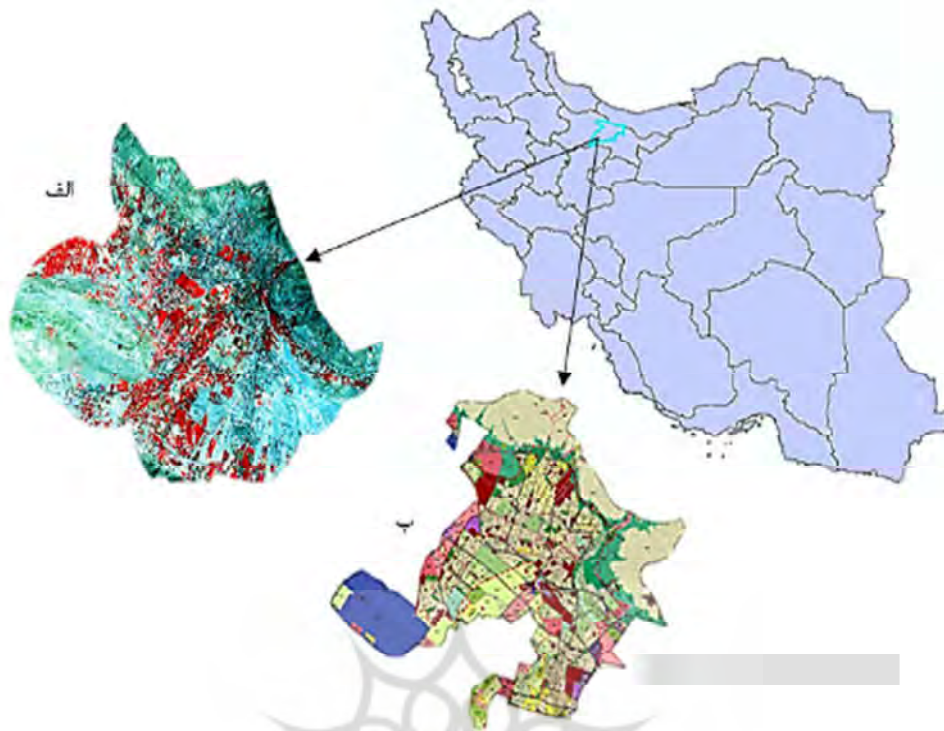
۳- مواد و روش‌ها

شهر کرج در موقعیت جغرافیایی $35^{\circ} 41'$ عرض شمالی واقع شده است. کرج از کلان‌شهرهای بزرگ ایران محسوب می‌شود. این شهر، پس از تهران و مشهد و اصفهان، چهارمین شهر پرجمعیت ایران به‌شمار می‌رود. همان‌گونه که شکل ۱ منطقه مورد مطالعه را روی تصویر چندطبقه لندست-۷ نشان می‌دهد، کلاس‌های مهم مشخص روی این تصاویر شامل کلاس مناطق ساخته‌شده، کلاس زمین‌های بایر، کلاس زمین‌های کشاورزی و باغ‌ها و فضای سبز، و کلاس آب است.

جدول ۱. الگوریتم‌های طبقه‌بندی مورد استفاده در این تحقیق

<ul style="list-style-type: none"> • تصمیم‌گیری مبتنی بر احتمال است. • احتمال حضور یک پیکسل را در هر کلاس بررسی می‌کند. • روشی آماری و پارامتریک است. • در تفکیک کردن کلاس‌ها در طبقه‌بندی، از حد آستانه استفاده می‌کند. • الگوریتمی خطی است و برای تصاویر با باند زیاد مناسب نیست. 	بیشترین شباهت
<ul style="list-style-type: none"> • از طبقه‌بندی‌کننده‌های غیرپارامتریک است و نیازی به پیش‌فرض در مورد کلاس‌ها ندارد زیرا ویژگی‌های درونی داده‌ها را براساس نمونه‌های آزمایشی محاسبه می‌کند. • در طبقه‌بندی داده‌های آموزشی از یک بازپخش^۳ استاندارد بهره می‌گیرد. • قابلیت یادگیری و تعمیم دارد. 	شبکه عصبی
<ul style="list-style-type: none"> • از الگوریتم‌های یادگیری و بهینه‌سازی مبتنی بر هسته به‌شمار می‌رود. • تابع هسته فضایی را ایجاد می‌کند که فرایند جست‌وجو براساس یادگیری باشد و از کلاس‌های خطی مجزا در مشخص کردن مرز بین طبقات استفاده می‌شود. • ابرصفحه بهینه به‌صورتی تعریف می‌شود که فاصله بین نزدیک‌ترین نمونه آموزشی و ابرصفحه جداکننده بیشتر شود. این منجر به بیشترین میزان تفکیک بین طبقات می‌شود. • حساسیت کمتری به پدیده‌های هیوز^۴ دارد (پدیده هیوز به کاهش دقت طبقه‌بندی، بر اثر افزایش تعداد ویژگی‌های ورودی، به‌دلیل داشتن داده‌های آموزشی محدود، اطلاق می‌شود). 	ماشین بردار پشتیبان

1. neural network
2. linear
3. backforward
4. Hughes



شکل ۱. الف) ترکیب رنگی کاذب حاصل از باندهای ۴،۳،۲ تصویر ماهواره‌ای لندست-۷، دریافتی در ژوئیه ۲۰۰۰؛ ب) نقشه‌ای از موقعیت شهر کرج (منبع: شهرداری کرج)

بخش‌های متفاوت تصویر انتخاب شوند و توزیعی مناسب در سطح منطقه مورد مطالعه داشته باشند. بر این اساس، تعداد نمونه‌های آموزشی برای کلاس آب ۷۲ پیکسل، کلاس زمین‌های بایر ۵۸۸۰ پیکسل، کلاس مناطق ساخته‌شده ۲۱۳۸ پیکسل و کلاس زمین‌های کشاورزی، باغ‌ها و فضای سبز ۸۱۹۵ پیکسل انتخاب شدند. تعداد پیکسل‌های آزمایشی، برای ارزیابی صحت طبقه‌بندی، در کلاس آب ۶۹ پیکسل، کلاس زمین‌های بایر ۱۶۲۹ پیکسل، کلاس مناطق ساخته‌شده ۱۶۷۱ پیکسل و کلاس زمین‌های کشاورزی، باغ‌ها و فضای سبز ۱۶۹۴ پیکسل در نظر گرفته شد. اندک‌بودن تعداد پیکسل‌های آموزشی و آزمایشی کلاس آب به دلیل وسعت کم این کلاس در سطح منطقه مورد مطالعه بود.

در این تحقیق، برای طبقه‌بندی تصاویر ماهواره‌ای، از تصویر چندطیفی لندست-۷ مربوط به تاریخ ۲۵ ژوئیه ۲۰۰۰ استفاده شد. محدوده منطقه مورد مطالعه شهر کرج و شعاع پنج کیلومتری اطراف آن است. در این پژوهش، باندهای مرئی و فروسرخ نزدیک و میانی، به روش تفریق تاریکی^۱، و باندهای حرارتی شامل باند حرارتی تصویر اخذشده در ۲۵ ژوئیه، به روش رگرسیون نرمال‌شده^۲، از نظر تأثیر اتمسفر در نرم‌افزار ENVI 5.1 تصحیح شدند. پس از آماده‌سازی تصاویر و بررسی اولیه تصویر منطقه، چهار کلاس شهری و حومه شامل کلاس مناطق ساخته‌شده، کلاس زمین‌های بایر، کلاس زمین‌های کشاورزی و باغ‌ها و فضای سبز و کلاس آب، با هدف طبقه‌بندی، در نظر گرفته شد. برای انتخاب داده‌های آموزشی، از نقشه کاربری اراضی با مقیاس ۱:۲۵۰۰۰ و عکس‌های هوایی دریافتی سازمان جغرافیایی نیروهای مسلح استفاده شد. همچنین، سعی شد نمونه‌های آموزشی و آزمایشی انتخاب‌شده از

1. dark object subtraction
2. normalized regression

مکانی ۶۰ متر است. در سال ۲۰۱۰، ناسا تصاویر حرارتی را، برای انطباق با دیگر باندهای مرئی و فروسرخ نزدیک و میانی، به پیکسل‌هایی با اندازه ۳۰ متر تبدیل کرده است و به همین علت، تصاویر بارگیری شده در باند حرارتی پیکسل‌هایی با اندازه ۳۰ متر داشتند (سایت USGS). دلیل استفاده از باندهای حرارتی به دست آمده در فصل‌های گوناگون متفاوت بودن مقدار گسیلمندی^۴، در زمین‌های کشاورزی بدون پوشش گیاهی و دارای پوشش گیاهی، با زمین‌های بایر است و این سبب می‌شود دمای روشنایی متفاوتی به دست آید. سپس حداقل^۵، حداکثر^۶، دامنه^۷ و انحراف معیار^۸ پیکسل‌های همسایه در هریک از تصاویر حاصل از دمای روشنایی محاسبه شد و برای طبقه‌بندی منطقه مورد مطالعه به کار رفتند.

- در سناریوی چهارم، اطلاعات طیفی و بافتی با یکدیگر ادغام شدند تا، پس از مقایسه نتایج حاصل در این سناریو با نتایج حاصل از سناریوهای اول و دوم، اهمیت ادغام این دو دسته از اطلاعات، در زمان طبقه‌بندی تصاویر با قدرت تفکیک متوسط، مشخص شود.

- هدف از اجرای سناریوی پنجم استفاده از شاخص‌های مکانی در فرایند طبقه‌بندی و ارزیابی کارایی این شاخص‌ها بود. در واقع در این تحقیق، شاخص‌های مکانی طبق این فرض تعریف شده‌اند که پیکسل‌های نزدیک به هر عارضه بیشترین شباهت را به آن عارضه خواهند داشت و هر چه پیکسل‌ها از این

با توجه به نوع هدف مطالعه، ارزیابی صحت و کارایی داده‌های ورودی و الگوریتم‌های طبقه‌بندی، به منظور تفکیک زمین‌های کشاورزی و نیز مناطق ساخته شده از زمین‌های بایر، شش سناریو تعریف شد و الگوریتم‌های طبقه‌بندی بحث شده در این مطالعه روی شش سناریو اعمال شد تا کارآمدترین داده ورودی و الگوریتم طبقه‌بندی شناسایی شود.

- در این تحقیق، شش باند تصویر ماهواره لندست ETM+ ژوئیه^۱ به منزله داده‌های طیفی (شامل باندهای مرئی آبی در محدوده ۰/۴۵-۰/۵۲ میکرومتر، سبز در محدوده ۰/۶۰-۰/۵۲ میکرومتر، قرمز در محدوده ۰/۶۹-۰/۶۳ میکرومتر، فروسرخ نزدیک در محدوده ۰/۹۰-۰/۷۷ میکرومتر و باندهای فروسرخ با طول موج‌های کوتاه در دو محدوده طیفی ۱/۷۵-۱/۵۵ و ۲/۲۳-۲/۰۹ میکرومتر)، با عنوان سناریوی اول برای داده‌های ورودی در طبقه‌بندی، به کار رفت.

- سناریوی دوم داده‌های ورودی حاصل از استخراج اطلاعات بافت به روش ماتریس وقوع هم‌زمان گام‌های خاکستری (GLCM)^۲ است. این اطلاعات از ویژگی‌های بافت عوارض در تصویر استخراج می‌شود و برای بهبود صحت طبقه‌بندی، در چند سال گذشته، کاربرد گسترده‌ای داشته است (Gao et al., 2016). در سناریوی دوم، اطلاعات بافت شامل بیشینه احتمال^۳، میانگین^۴، واریانس^۵، کنتراست^۶، همگنی^۷، همبستگی^۸، فقدان شباهت^۹، انحراف معیار^{۱۰} با ابعاد پنجره ۳×۳ از باندهای طیفی استخراج شدند.

- در سناریوی سوم، دمای روشنایی تصاویر حرارتی به دست آمده در چهار فصل زمستان، بهار، تابستان، پاییز (معادل ماه‌های میلادی مارس^{۱۱}، مه^{۱۲}، ژوئیه، اکتبر^{۱۳}) از سنجنده لندست-۷ منطقه مورد مطالعه محاسبه شد. تصاویر حرارتی مربوط به سنجنده ETM+ ماهواره لندست دارای قدرت تفکیک

1. july	2. gray level co-occurrence matrix
3. entropy	4. mean
5. variance	6. contrast
7. homogeneity	8. correlation
9. dissimilarity	10. second moment
11. march	12. may
13. october	14. emissivity
15. minimum	16. maximum
17. range	18. stanandard deviation

روش جنگل تصادفی روشی غیرخطی است و با هدف گزینش ویژگی‌های مهم برای طبقه‌بندی، بدین صورت اجرا می‌شود (Nguyen et al., 2015):

۱. روش جنگل تصادفی، برای داده‌های مورد نظر، به‌منظور طبقه‌بندی داده‌ها برآزش داده می‌شود.
۲. پس از برآزش جنگل تصادفی در هر تکرار، خطای مربوط به طبقه‌بندی برای هر درخت محاسبه می‌شود.
۳. با استفاده از جایگشت^۲، اهمیت هر یک از ویژگی‌های مستقل انتخاب‌شده در هر درخت تعیین می‌شود.
۴. با توجه به اهمیت تعیین‌شده برای هر ویژگی، خصیصه‌های کم‌اهمیت‌تر با نسبتی از پیش تعیین‌شده (معمولاً ۲۰٪ ویژگی‌ها) حذف می‌شوند.
۵. مرحله ۱ تا ۴، به‌جز مرحله ۳، تکرار می‌شود تا کمترین تعداد ویژگی‌های مستقل، با بیشترین صحت ممکن، در طبقه‌بندی حاصل شود.

پارامترهای قابل تنظیم به‌منظور اجرا روش انتخاب ویژگی با استفاده از الگوریتم جنگل تصادفی تعداد درختان و نیز تعداد متغیرها برای جداسازی در هر یک از گره‌ها که این مقدار همیشه کوچک‌تر از بعد فضایی داده‌های ورودی است. افزایش تعداد درختان تا جایی ادامه می‌یابد که خطا کاهش پیدا کند و معمولاً تعداد متغیرها برای جداسازی در هر یک از گره‌ها را برابر با مقدار پیش‌فرض (جذر یا لگاریتم تعداد ویژگی‌های ورودی) قرار می‌دهند (Belgiu & Dragut, 2016). در این پژوهش، تعداد متغیرها برای جداسازی در هر یک از گره‌ها برابر با جذر تعداد ویژگی‌های ورودی در هر سناریوست. به‌قصد یافتن تعداد درخت مناسب، بین ۱۰۰ تا ۱۰۰۰ مورد برای هر سناریو انتخاب و بهترین‌ترین تعداد درخت در هر سناریو استخراج شد. تعداد ویژگی‌های ورودی برای سناریوی نخست، ۶ ویژگی؛ برای سناریوی دوم، ۴۸ ویژگی؛ برای سناریوی سوم، ۲۰ ویژگی؛ برای سناریوی چهارم، ۵۴ ویژگی؛ برای سناریوی پنجم، ۵۶ ویژگی؛ برای سناریوی ششم، ۷۶ ویژگی را شامل می‌شود.

1. normalized difference vegetation index
2. permutation

عوارض فاصله بگیرند، میزان شباهت عوارض به پیکسل‌های بیانگرشان کمتر می‌شود. با توجه به مشکلات بیان‌شده در مقدمه، در این تحقیق، دو شاخص مکانی تعریف شد. مشکل نخست تفکیک اراضی کشاورزی فاقد پوشش گیاهی از اراضی بایر بود. به‌منظور استخراج فاصله اراضی مجاور، از اراضی کشاورزی دارای پوشش گیاهی، ابتدا شاخص گیاهی تفاضل نرمال‌شده پوشش گیاهی (NDVI)^۱ از داده‌های طیفی به‌دست آمد و با اعمال فاصله‌ای اقلیدسی، فاصله نواحی دیگر با نواحی دارای پوشش گیاهی از تصویر استخراج شد. همچنین، برای بررسی امکان کاهش یا برطرف کردن مشکل تفکیک‌نشدن برخی از پیکسل‌های کلاس شهری از اراضی بایر، شاخص مکانی دیگری، شامل فاصله از مناطق ساخته‌شده، تعریف شد. به‌منظور تفکیک و استخراج فاصله از مناطق ساخته‌شده، نخست، شاخص اصلاح‌شده مناطق ساخته‌شده و زمین‌های بایر (EBBI)، مطابق رابطه (1) به‌دست آمد (Raval & Shamsoddini, 2014; As-syakur et al., 2012).

$$\text{EBBI} = \frac{\text{Band5} - \text{Band4}}{10\sqrt{\text{Band5} + \text{Band6}}} \quad (1)$$

در معادله بالا Band5، Band4 و Band6 به‌ترتیب باند ۵، باند ۴، و باند ۶ تصویر لندست‌اند. پس از آن، با اعمال فاصله اقلیدسی، فاصله مناطق ساخته‌شده تا زمین‌های مجاور از تصویر استخراج شد. این دو شاخص مکانی با داده‌های طیفی و بافتی ادغام شدند و در طبقه‌بندی منطقه مورد مطالعه به‌کار رفتند.

- در سناریوی ششم، تمامی داده‌ها شامل داده‌های طیفی، داده‌های بافتی، داده‌های مکانی و داده‌های حرارتی- به‌منظور طبقه‌بندی منطقه مورد مطالعه به‌کار رفتند.
- به‌منظور ارزیابی درستی روش‌های طبقه‌بندی، که در این تحقیق به آنها اشاره شده، از ضریب کاپا (Sim Wright, 2005) و صحت کلی (Stehman, 1997) استفاده شد.

۴- نتایج

کاپای ۹۸/۲۵، چندان تفاوتی ندارد. اگرچه روش ماشین بردار پشتیبان با هسته خطی درجه اول پایین‌ترین صحت را در میان روش‌های گوناگون برای سناریوی نخست دارد؛ در مجموع و برای دیگر سناریوها، روش بیشترین شباهت دارای کمترین میزان درستی است. روند کلی در مورد سناریوهای به‌کاررفته در این تحقیق نشان می‌دهد اضافه‌شدن شاخص‌های مکانی و حرارتی مطرح‌شده در این تحقیق ممکن است، به مقدار زیادی، بر صحت طبقه‌بندی تصاویر بیفزاید. در این زمینه، روش بیشترین شباهت تا حدودی از روند کلی پیروی نمی‌کند و بهترین نتیجه طبقه‌بندی با این روش زمانی حاصل شده است که فقط از باندهای طیفی به‌منزله ورودی استفاده شده است.

با توجه به هدف این تحقیق، روش‌های طبقه‌بندی اشاره‌شده با ورودی‌های بیان‌شده برای هر سناریو، به‌منظور طبقه‌بندی تصویر ماهواره‌ای منطقه مورد مطالعه، به‌کار رفتند و نتایج حاصل از آن در شکل‌های ۲ و ۳ نشان داده شده است. طبق این شکل‌ها، ماشین بردار پشتیبان با هسته تابع پایه شعاعی بیشترین صحت در طبقه‌بندی را برای سناریوهای اول تا پنجم دارد. همچنین در سناریوی ششم، اگرچه عملکرد ماشین بردار پشتیبان با هسته چندجمله‌ای درجه دوم، با صحت کلی ۹۸/۸۳ و ضریب کاپای ۹۸/۲۷، بهتر بوده است؛ عملکرد این روش با روش ماشین پشتیبان با هسته تابع پایه شعاعی، با صحت کلی ۹۸/۸۱ و ضریب

جدول ۲. ماتریس خطای کلاس‌های مورد مطالعه با الگوریتم طبقه‌بندی ماشین بردار پشتیبان خطی درجه اول، برای سناریوی نخست

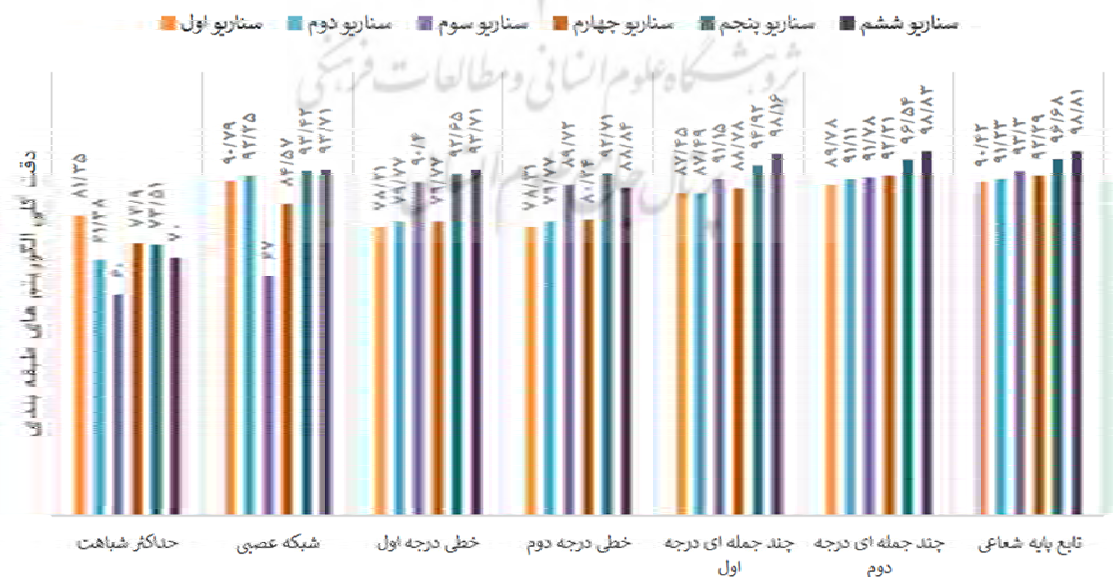
دقت کاربر	دقت تولیدکننده	کلاس‌های تعیین‌شده در این پژوهش
۸۴/۰۸	۴۴/۷۵	زمین‌های بایر
۸۸/۸۰	۹۳/۹۵	مناطق ساخته‌شده
۶۷/۶۲	۹۴/۵۶	زمین‌های کشاورزی، باغ‌ها و فضای سبز
۱۰۰	۸۵/۵۰	آب

جدول ۳. ماتریس خطای کلاس‌های مورد مطالعه با الگوریتم طبقه‌بندی ماشین بردار پشتیبان با هسته پایه شعاعی

کلاس‌های تعیین‌شده در این پژوهش				
آب	زمین‌های کشاورزی، باغ‌ها و فضای سبز	مناطق ساخته‌شده	زمین‌های بایر	سناریوهای به‌کاررفته در این پژوهش
۸۴/۰۶	۹۶/۰۴	۹۲/۹۴	۸۲/۲۶	دقت تولیدکننده
۹۸/۳۱	۸۴/۵۶	۹۸/۶۷	۸۸/۹۸	دقت کاربر
۹۷/۱۰	۹۶/۴۶	۹۲/۸۲	۸۳/۹۲	دقت تولیدکننده
۱۰۰	۸۸/۹۵	۹۶/۰۴	۸۸/۵۴	دقت کاربر
۶۵/۲۲	۸۹/۲۶	۹۵/۶۹	۹۴/۴۱	دقت تولیدکننده
۸۱/۸۲	۹۱/۱۹	۹۸/۷۰	۸۸/۹۰	دقت کاربر
۱۰۰	۹۶/۸۱	۹۴/۴۹	۸۵/۰۲	دقت تولیدکننده
۹۸/۵۷	۹۸/۱۸	۹۷/۰۵	۹۰/۷۰	دقت کاربر
۹۲/۷۵	۹۹/۱۱	۹۷/۱۳	۹۳/۸۶	دقت تولیدکننده
۱۰۰	۹۵/۴۵	۹۸/۱۹	۹۶/۳۵	دقت کاربر
۱۰۰	۹۹/۲۳	۹۹/۲۸	۹۷/۸۵	دقت تولیدکننده
۱۰۰	۹۸/۶۵	۹۹/۲۲	۹۸/۵۲	دقت کاربر

انتخاب روش طبقه‌بندی در تفکیک کلاس‌های متفاوت را بازگو می‌کند. با توجه به جدول ۳، اگرچه در روش ماشین بردار پشتیبان با هسته پایه شعاعی، استفاده از اطلاعات بافتی (در سناریوی دوم) تا حدودی موجب افزایش صحت کلاس‌های متفاوت می‌شود؛ شکل‌های ۲ و ۳ نشان می‌دهند که اضافه‌شدن اطلاعات بافتی به اطلاعات طیفی در سناریوی چهارم، در مقایسه با آنچه در سناریوی اول و دوم به‌دست آمده، چندان در بهبود نتایج طبقه‌بندی کلاس‌های مورد نظر در این تحقیق مؤثر نبوده است. درحالی‌که طبق جدول ۳، اضافه‌شدن ویژگی‌های پیشنهادی در این مطالعه، در قالب سناریوی ششم، موجب افزایش بسیار صحت تولیدکننده و کاربر، تا ۱۵٪، به‌ویژه برای تفکیک کلاس زمین‌های بایر و کلاس اراضی کشاورزی و باغ‌ها و فضای سبز می‌شود. این نتایج به‌همراه نتایج مطرح‌شده در شکل‌های ۲ و ۳، اهمیت ویژگی‌های پیشنهادی در این مطالعه را، برای افزایش صحت طبقه‌بندی کلاس‌های متفاوت در تصاویر لندست، بیان می‌کند.

برای اینکه تأثیر استفاده از سناریوهای متفاوت برای ویژگی‌های ورودی دقیق‌تر بررسی شود، با استفاده از ماتریس‌های خطای مربوط به هر یک از روش‌ها، صحت تولیدکننده و کاربر کلاس‌های گوناگون محاسبه و در جدول‌های ۲ و ۳ نشان داده شد. با توجه به این جدول‌ها، درحالی‌که روش ماشین بردار پشتیبان خطی درجه اول، با استفاده از نخستین سناریو، ضعیف‌ترین روش طبقه‌بندی با صحت تولیدکننده ۴۴/۷۵٪ شناخته شد که قادر به تفکیک پیکسل‌های اراضی بایر از کلاس‌های دیگر نیست؛ انتخاب روش ماشین بردار پشتیبان با هسته پایه شعاعی، با استفاده از نخستین سناریو، می‌تواند صحت تولیدکننده را تا ۸۲/۲۶٪ برای کلاس اراضی بایر افزایش دهد. همچنین، جدول ۲ نشان می‌دهد که روش ماشین بردار پشتیبان با هسته خطی درجه اول نمی‌تواند نقشه‌ای مطمئن برای کلاس‌های زمین‌های کشاورزی، باغ‌ها و فضای سبز، با صحت کاربر ۶۷/۶۲٪ ایجاد کند. این در حالی است که استفاده از هسته پایه شعاعی این صحت را به ۸۴/۶۰٪ می‌رساند. به‌طور کلی، مقایسه جدول‌های یادشده تأثیر



شکل ۲. صحت کلی الگوریتم‌های طبقه‌بندی



شکل ۳. ضریب کاپای الگوریتم‌های طبقه‌بندی

تصادفی، شاخص‌های مکانی شامل شاخص فاصله از اراضی دارای پوشش گیاهی و شاخص فاصله از مناطق ساخته‌شده، میانگین، اطلاعات طیفی و واریانس، به‌ترتیب، ویژگی‌هایی مهم‌تر از دیگر ویژگی‌ها شناخته شدند. در مورد ویژگی‌های به‌کاررفته در سناریوی ششم، شاخص فاصله از اراضی دارای پوشش گیاهی، کمترین میزان دمای روشنایی در چهار ماه انتخاب‌شده در این مطالعه، شاخص فاصله از مناطق ساخته‌شده، میانگین، اطلاعات طیفی و نیز تصاویر حرارتی شامل بیشترین میزان دمای روشنایی در ماه‌های مارس، مه، ژوئیه و اکتبر - و دمای روشنایی ماه‌های مارس، مه و ژوئیه، به‌ترتیب، دارای بیشترین اهمیت و تأثیرگذاری در طبقه‌بندی محسوب می‌شوند. در مجموع، با توجه به نتایج بیان‌شده در جدول ۴، می‌توان ویژگی‌های پیشنهادی در این مطالعه را مواردی کارآ در طبقه‌بندی تصویر لندست، با هدف جداسازی کلاس کشاورزی از زمین‌های بایر و کلاس مناطق ساخته‌شده از زمین‌های بایر، معرفی کرد.

۵- بحث

متطابق مطالب این تحقیق، روش بیشترین میزان

همان‌گونه که در بخش ۳ توضیح داده شد، برای اینکه عملکرد ویژگی‌های مطرح‌شده در این مطالعه را ارزیابی کنیم، صحت طبقه‌بندی را تعیین کردیم. افزون بر آن، از روش انتخاب ویژگی با استفاده از جنگل تصادفی، برای تعیین درجه اهمیت هر یک از ویژگی‌های مستقل به‌کاررفته در سناریوهای متفاوت، استفاده شد که نتایج آن در جدول ۴ آمده است. همان‌گونه که بیان شد، در سناریوی اول و دوم و نیز چهارم، از ویژگی‌های متداولی استفاده شد که تا کنون در مقالات دیگر هم بدانها اشاره شده است. ویژگی‌های مطرح‌شده در این مطالعه در سناریوهای سوم، پنجم و ششم به‌کار رفتند. بر این اساس، در سناریوی سوم که فقط از ویژگی‌های حرارتی را به‌کار گرفته است، نتایج انتخاب ویژگی نشان می‌دهد که دمای روشنایی، کمترین و بیشترین میزان دمای روشنایی در چهار ماه منتخب در این مطالعه و دامنه دمای روشنایی در ماه‌های مه، ژوئیه و اکتبر و نیز، انحراف معیار در می و ژوئیه ویژگی‌های مهم شناسایی شده بوده‌اند. در سناریوی پنجم، داده ورودی برای طبقه‌بندی شامل داده‌های حاصل از ادغام اطلاعات طیفی، اطلاعات بافتی و شاخص‌های مکانی‌اند. پس از اعمال روش انتخاب ویژگی با استفاده از جنگل

متفاوت، ضعف عملکردی این روش را همراه با افزایش ویژگی‌های ورودی، می‌توان ناشی از این دانست که این روش برای ویژگی‌های ورودی بسیار، همان‌گونه که در جدول ۱ اشاره شد، عملکرد مناسبی نشان نمی‌دهد (Shi & Xue, 2016). همچنین، طبق این تحقیق، عملکرد روش طبقه‌بندی ماشین بردار پشتیبان کاملاً به نوع هسته‌ای مرتبط است که در آن به کار می‌رود (Otukey & Blaschke, 2010) و در این میان، هسته پایه شعاعی بهترین عملکرد را از خود نشان داد.

شباهت، به‌استثنای سناریوی اول که در آن فقط از ویژگی‌های طیفی استفاده شده بود، عملکرد مطلوبی نداشت و حتی با افزایش تعداد ویژگی‌های ورودی، درستی نقشه‌های طبقه‌بندی حاصل از این روش کاهش یافت. عملکرد مطلوب روش حداکثر شباهت در زمان استفاده از باندهای طیفی به‌منزله ویژگی‌های مستقل، در مطالعات دیگر نیز، تأیید شده است (Shi & Xue, 2016). اگرچه دقت طبقه‌بندی الگوریتم حداکثر شباهت با دقت بالا در انتخاب کلاس‌های آموزشی تعیین می‌شود، با توجه به یکسان بودن کلاس‌های آموزشی منتخب برای روش‌های

جدول ۴. انتخاب ویژگی داده‌های ورودی با استفاده از روش جنگل تصادفی و ترتیب اهمیت آنها

سناریوی اول	سناریوی دوم	سناریوی سوم	سناریوی چهارم	سناریوی پنجم	سناریوی ششم
باند ۳	میانگین	دمای روشنایی ماه‌های مه، ژوئیه، مارس، اکتبر	میانگین	شاخص فاصله از زمین‌های کشاورزی دارای پوشش گیاهی	شاخص فاصله از زمین‌های کشاورزی دارای پوشش گیاهی
باند ۵	واریانس	حداقل دمای روشنایی ماه‌های مه، ژوئیه، مارس، اکتبر	شش باند طیفی (به همان ترتیب سناریوی اول)	شاخص فاصله از مناطق ساخته‌شده	حداقل دمای روشنایی ماه‌های مه، مارس، ژوئیه
باند ۷	کنتراست	ماه‌های مارس، ژوئیه، مه، اکتبر	واریانس	میانگین	شاخص فاصله از مناطق ساخته‌شده
باند ۱	فقدان شباهت	دامنه دمای روشنایی ماه‌های مه، ژوئیه و اکتبر	کنتراست	شش باند طیفی (به همان ترتیب سناریوی اول)	میانگین
باند ۲	_____	انحراف معیار دمای روشنایی ماه‌های مه، ژوئیه	فقدان شباهت	واریانس	شش باند طیفی (به همان ترتیب سناریوی اول)
باند ۴	_____	_____	_____	_____	حداکثر دمای روشنایی ماه‌های مارس، مه، ژوئیه، اکتبر
_____	_____	_____	_____	_____	دمای روشنایی ماه‌های مارس، مه، ژوئیه

2006). این مسئله ممکن است دلیل عملکرد مؤثر شاخص‌های حرارتی استفاده‌شده در این تحقیق، برای تفکیک کلاس‌های شهری و اراضی بایر از یکدیگر، محسوب شود. در واقع، توجه به پاسخ‌های حرارتی متفاوت در میان انواع پوشش زمین ممکن است در بهبود دقت طبقه‌بندی تأثیر بسزایی داشته باشد و اطلاعات دما نیز ممکن است به طبقه‌بندی کاربری اراضی و پوشش زمینی کمک کند (Lu & Weng, 2005). گسیلمندی سطح یکی از مهم‌ترین عوامل تعیین‌کننده دمای سطح است که به عوامل بسیاری مانند نوع پوشش سطح، چگالی، ساختار و زبری ارتباط دارد. برای نمونه، گسیلمندی در خاک به عواملی همچون ترکیبات آلی خاک و رطوبت خاک وابسته است و گسیلمندی در پوشش‌های گیاهی، افزون‌بر رطوبت گیاه، به گونه‌های متفاوت گیاهی و تراکم آنها نیز مرتبط است (Jin & Liang, 2006; Snyder et al., 1998). پوشش گیاهی متراکم بیشترین گسیلمندی را دارد و زمین بایر دارای گسیلمندی اندک حدود ۰/۹۲ است (Jin & Liang, 2006). با توجه به مطالب مطرح‌شده، اراضی بایر در مقایسه با اراضی کشاورزی فاقد پوشش گیاهی معمولاً سطح مواد آلی و رطوبت کمتری دارند و در نتیجه، با اراضی کشاورزی فاقد پوشش گیاهی تفاوت دمایی دارند. خود این نکته می‌تواند دلیل اصلی عملکرد مطلوب شاخص‌های حرارتی در این مطالعه، به‌منظور تفکیک کلاس‌های کشاورزی و اراضی بایر از هم، به‌شمار رود.

۶- نتیجه‌گیری

مقایسه سناریوهای متفاوت برای ویژگی‌های ورودی شامل ویژگی‌های طیفی، بافتی، مکانی و حرارتی برای طبقه‌بندی کردن کلاس شهر و اطراف آن در تصویر لندست-۷ هدف این تحقیق قرار گرفت. در این زمینه، الگوریتم‌های طبقه‌بندی نظارت‌شده حداکثر شباهت، شبکه عصبی، ماشین بردار پشتیبان با هسته‌های گوناگون با ویژگی‌های ورودی متفاوت مقایسه شدند. در

بافت، اطلاعات و روابط مکانی عوارض کلاس‌ها را در تصاویر ماهواره‌ای به‌خوبی نشان می‌دهد و در نتیجه، استفاده از آن را، در افزایش دقت طبقه‌بندی کلاس‌های محیط شهری و حومه آن در تصاویر ماهواره‌ای لندست-۷، منطقی و توجیه‌پذیر می‌نماید (Shaban & Dikshit, 2001). اهمیت بافت هنگامی مشخص می‌شود که عوارض مورد نظر دارای توزیع گام‌های خاکستری مشابه باشند. در این هنگام، ادغام اطلاعات بافتی با اطلاعات طیفی یا داده‌های کمکی دیگر می‌تواند مشکل شباهت میان کلاس‌ها و تنوع کلاس‌ها را برطرف کند و دقت طبقه‌بندی تصویر را بهبود بخشد (Kurosu et al., 2001; Chen & Young, 1982; Lu & Weng, 2005; Shaban & Dikshit, 2001). در این تحقیق، از شاخص EBDI به‌منظور تفکیک مناطق ساخته‌شده از زمین‌های بایر استفاده شده است. در باند ۵ مناطق ساخته‌شده، به‌نسبت مناطق دارای پوشش گیاهی، بیشترین بازتاب را دارد (Herold et al., 2003). به همین علت، استفاده از شاخص فاصله از مناطق ساخته‌شده شاخصی مکانی در نظر گرفته شد که توانست تا حدی مشکل تمایز نداشتن مناطق ساخته‌شده با اراضی بایر را، با استفاده از تعیین فاصله و اصل بیشترین شباهت میان عوارض نزدیک به هم، در سناریوهای پنجم و ششم، برطرف کند. استفاده از اصل بیشترین شباهت میان عوارض نزدیک به هم در ایجاد شاخص فاصله از اراضی کشاورزی دارای پوشش نیز، با هدف تفکیک اراضی کشاورزی فاقد پوشش از اراضی بایر، در سناریوی پنجم و ششم، طبق جدول ۴ مؤثر واقع شد.

افزون‌بر شاخص‌های مکانی مورد استفاده در این تحقیق، شاخص‌های حرارتی نیز به‌کار رفتند که در سناریوی ششم، جزء ویژگی‌های مؤثر برای افزایش صحت طبقه‌بندی تصاویر انتخاب شدند (جدول ۴). طبق تحقیقات انجام‌شده، در مناطق شهری دما ۱۰- ۱۲ درجه سانتی‌گراد بیشتر از مناطق دارای پوشش گیاهی و چشم‌اندازهای طبیعی است (Lu & Weng, 2005).

Belgiu, M. & Dragut, L., 2016, Random Forest in Remote Sensing: A Review of Application and Future Directions, ISPRS Journal of Photogrammetry and Remote Sensing, 114, PP., 24-31.

Bishop, C.M., 2007, Pattern Recognition and Machine Learning, Springer. USA, Chapter 3.

Chen, C.H. & Young, G.K., 1982, A Study of Texture Classification Sensing Spectral Features, Human Factors Engineering & Man Machine System, 19(22), PP. 1-14.

Chu, H.T., Ge, L., Ng, A.H.N. & Rizos, C., 2012, Application of Genetic Algorithm and Support Vector machine in Classification of Multisource Remote Sensing Data, International Journal Remote Sensing Applications, 2(2), PP.1-11.

Cristianini, N. & Taylor, J.S., 2000, An Introduction to Support Vector Machines and Other Kernel-based Learning Methods, Cambridge University, USA, Chapter 6.

Devadas, R., Denham, R.J. & Pringle, M., 2012, Support Vector Machine Classification of Object-Based Data for Crop Mapping, Using Multi-Temporal Landsat Imagery, International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXIX-B7, 2012 XXII ISPRS Congress, 25 August – 01 September 2012, Melbourne, Australia.

Eiumnoh, A. and Shrestha, R.P., 2000, Application of DEM Data to Landsat Image Classification: Evaluation In a Tropical Wet-Dry Landscape of Thailand, Photogram. Eng. Remote Sensing, 66, PP. 297-1304.

Fauvel, M., Chanussot, J. & Benediktsson, J.A., 2012, A Spatial-Spectral Kernel-Based Approach for the Classification of Remote-Sensing Images, Pattern Recognition, 45(1), PP. 381-392.

Otukei, J.R. & Blaschke, B., 2010, Land Cover Change Assessment Using Decision Trees, Support Vector Machines and Maximum Likelihood Classification Algorithms, International Journal of Applied Earth Observation and Geoinformation, 12S, PP. S27-S31.

مجموع، می‌توان یافته‌های این تحقیق را بدین صورت بیان کرد:

- از میان الگوریتم‌های طبقه‌بندی نظارت‌شده، الگوریتم طبقه‌بندی ماشین بردار پشتیبان با هسته پایه شعاعی ممکن است نتایجی بهتر از دیگر روش‌ها داشته باشد.
- روش حداکثر شباهت روشی متداول در طبقه‌بندی است که، فقط هنگام استفاده از داده‌های طیفی، عملکرد مطلوبی خواهد داشت و با افزایش تعداد ویژگی‌های ورودی به این روش، درستی نقشه‌های حاصل از آن کاهش می‌یابد.
- درحالی‌که سناریوهای گوناگون برای داده‌های ورودی ممکن است به نتایج متفاوتی در طبقه‌بندی تصاویر منجر شود، بهترین نتیجه در زمان ادغام اطلاعات طیفی، بافتی، مکانی و حرارتی در قالب سناریوی ششم به‌دست آمد.
- شاخص‌های مکانی و حرارتی پیشنهادی در این تحقیق چه بسا نتایج مطلوبی در تفکیک کلاس مناطق ساخته‌شده از اراضی بایر و نیز کلاس کشاورزی، شامل اراضی کشاورزی بدون پوشش گیاهی، از کلاس زمین‌های بایر داشته باشد.

۷- منابع

Afifi, A., 2014, Laguerre Kernels – Based SVM for Image Classification, International Journal of Advanced Computer Science and Applications, 5(1), PP. 15-23.

As-syakur, A.R., Adnyana, I.W.S., Arthana, I.W., Nuarsa, I.W., 2012, Enhanced Built-Up and Bareness Index (EBBI) for mapping Built-Up and Bare Land in an Urban Area, Remote Sensing, 10(4), PP. 2957-2970.

Bastitella, D.L.U. & Moran, E., 2007, Land-Cover Classification in the Brazilian Amazon with the integration of Landsat ETM+ and Radarsat data, International Journal of Remote Sensing, 28(24), PP. 5447-5479.

- Gao, J., Xu, L. & Huang, F., 2016, A Spectral-Textural Kernel-Based Classification Method of Remotely Sensed Images, *Neural Computing and Applications*, 27(2), PP. 431-446.
- Hughes, G.F., 1968, On the Mean Accuracy of Statistical Pattern Recognizers, *IEEE Trans. on Information Theory*, 14(1), PP. 55-63.
- Haralick, R., Shanmugam, K. & Dinstein, I., 1973, Textural Features for Image Classification, *IEEE Transactions on Systems, Man, and Cybernetics*, 3(6), PP. 610-621.
- Hulchinson, C.K., 1982, Techniques for Combining Landsat and Ancillary Data for Digital Classification Improvement, *Photogram, Eng. Remote Sensing*, 48, PP. 123-130.
- Herold, M., Gardner, M.E. & Roberts, D.A., 2003, Spectral Resolution Requirements for Mapping Urban Areas, *IEEE Trans. Geosci. Remote Sensing*, 41(9), PP. 1907-1919.
- Jin, M. & Liang, Sh., 2006, An Improved Land Surface Emissivity Parameter for Land Surface Models Using Global Remote Sensing Observations, *American Meteorological Society*, 19(12), PP. 2867-2881.
- Kavazoglu, T. & Colkesen, I., 2009, A Kernel Functions Analysis for Support Vector Machines for Land Cover Classification, *International Journal of Applied Earth Observation and Geoinformation*, 11(5), PP. 352-359.
- Kurosu, T., Yokoyama, S., Fujita, M. & Chiba, K., 2001, Land Use Classification with Textural Analysis and the Aggregation Technique Using Multi-Temporal JERS1-1 L-band SAR images, *International Journal of Remote Sensing*, 22(4), PP. 595-613.
- Li, S. & Chen, X., 2014, A New Bare-Soil Index for Rapid Mapping Developing Areas Using Landsat, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 14-16 May. Suzhou, China.
- Lu, D. & Weng, Q., 2006, Use of Impervious Surface in Urban Land-Use Classification, *Remote Sensing of Environment*, 102(1), PP. 146-160.
- Lo, C.P. & Chol, J., 2004, A Hybrid Approach to Urban Land Use/Cover Mapping Using Landsat 7 Enhanced Thematic Mapper Plus (ETM+) Images, *Int.J. Remote Sensing*, 125(4), PP. 2687-2700.
- Lu, D. & Weng, Q., 2005, Urban Classification Using Full Spectral Information of Landsat ETM+ Imagery in Marion County, Indiana, *Photogrammetric Engineering and Remote Sensing*, 71(11), PP. 1275-1284.
- Li, C., Wang, J., Wang, L., Hu, L. & Cong, P., 2014, Comparison of Classification Algorithms and Training Sample Sizes in Urban Land Classification with Landsat Thematic Mapper Imagery, *Remote Sensing*, 6(2), PP. 964-983.
- Melgani, G. & Bruzzone, L., 2004, Classification of Hyperspectral Remote Sensing Images with Support Vector Machines, *IEEE Transactions on Geoscience and Remote Sensing*, 42(8), PP. 1778-1790.
- Nguyen, T., Huang, J.Z. & Nguyen, T., 2015, Unbiased Feature Selection in Learning Random Forests for High-Dimensional Data, *The Scientific World Journal*, 2015, PP. 1-18.
- Oommen, T., Misra, D., Twarakavi, N., Prakash, A., Sahoo, B. & Bandopadhyay, S., 2008, An Objective Analysis of Support Vector Machine Based Classification for Remote Sensing, *Mathematical Geosciences*, 40, PP. 409-424.
- Raval, S. & Shamsoddini, A., 2014, A Monitoring Framework for Land Use Around Kaoli Mining Areas Through Landsat TM Images, *Earth Sci Information*, 7(3), PP. 153-163.
- Richards, J.A., 2013, *Remote Sensing Digital Image Analysis*, Springer, Springer-Verlag Berlin Heidelberg, Chapter 8.
- Ruiz, L.A., Sarria, A.F. & Recio, J.A., 2004, Texture Feature Extraction for Classification of Remote Sensing Data Using Wavelet Decomposition: A Comparative Study, 20th ISPRS Congress. 12 to 23 July. Istanbul, Turkey.
- Snyder, W.C., Wan, Z., Zhang, Y. & Feng, Z., 1998, Classification-Based Emissivity for Land Surface Temperature Measurement from Space, *International Journal Remote Sensing*, 19(14), PP. 2753-2774.

- Shaban, M. & Dikshit, O., 2001, Improvement of Classification in Urban Areas by the Use of Textural Features: The Case Study of Lucknow City, Uttar Pradesh, International Journal Remote Sensing, 22(4), PP. 565-593.
- Stehman, S.V., 1997, Estimating Standard Errors of Accuracy Assessment Statistics under Cluster Sampling, Remote Sensing of Environment, 60(3), PP. 258-269.
- Sim, J. & Wright, C.C., 2005, The Kappa Statistic in Reliability Studies: Use, Interpretation, and Sample Size Requirements, Phys Ther, 85(3), PP. 257-268
- Tadesse, W., Coleman, T.L. & Tsegaye, T.D., 2003, Improvement of Land Use and Land Cover Classification of an Urban Area Using Image Segmentation from Landsat ETM Data, Proceedings of the 30th International Symposium on Remote Sensing of the Environment, November 10-14. Honolulu, Hawaii.
- Waqar, M.M., Miraza, J.F., Mumtaz, R. & Hussain, E., 2012, Development of New Indices for Extraction of Built-Up Area & Bare Soil From Landsat Data, Scientific Reports, 1(1), PP. 2- 4.
- https://www.usgs.gov/faqs/what-are-band-designations-landsat-satellites-0?qt-news_science_products=7#qt-news_science_products.
- Shi, X., & Xue, B., 2016, Parallelizing Maximum Likelihood Classification on Computer Cluster and Graphics Processing Unit for Supervised Image Classification, International Journal of Digital Earth, PP.1-12.
- Yuan, H.F.C., Wlele, V. & Khorram, S., 2009, An Automated Artificial Neural Network System for Land Use/Land Cover Classification from Landsat TM Imagery, Remote Sensing, 1(1), PP. 243-265.
- Zhang, J., Li, P. & Wang, J., 2014, Urban Built-Up Area Extraction from Landsat TM/ETM+ Images Using Spectral Information and Multivariate Texture, Remote Sensing, 6, PP. 7339-7359.
- Zhu, C., 1996, Remote Sensing Image Texture Analysis and Classification with Wavelet Transform, International Archives of Photogrammetry and Remote Sensing, 19(16), 12-18 July, Vienna, Austria.