



استفاده از الگوریتم فراابتکاری کرم شب تاب در بهبود دقت طبقه بندی تصویر ماهواره ای، مطالعه موردی: شهر رفسنجان



حمید باقری^{*۱}

دریافت: ۱۴۰۰/۱۲/۱۶ / پذیرش: ۱۴۰۱/۰۴/۰۶ / دسترسی اینترنتی: ۱۴۰۴/۰۴/۳۱

چکیده

امروزه یکی از روش های تهیه نقشه کاربری و پوششی اراضی، استفاده از اطلاعات ماهواره ای و روش های سیستم اطلاعات مکانی است. داده های ماهواره ای به دلیل ارائه اطلاعات به روز و امکان پردازش تصاویر، در تهیه نقشه های پوششی اراضی از اهمیت بالایی برخوردارند. از سوی دیگر در سال های اخیر به طور وسیع و گسترده جهت طبقه بندی تصاویر ماهواره ای از روش های طبقه بندی پیشرفته از قبیل شبکه های عصبی مصنوعی، مجموعه های فازی و شبکه های هوشمند استفاده شده است. هدف از این تحقیق، بهبود دقت طبقه بندی تصویر ماهواره ای با استفاده از یک الگوریتم فراابتکاری است. در این تحقیق، یک روش طبقه بندی جدید مبتنی بر الگوریتم کرم شب تاب به عنوان یک الگوریتم یادگیری تحت نظارت معرفی شده است. بدین منظور ابتدا با استفاده از دو الگوریتم طبقه بندی شبکه عصبی مصنوعی و ماشین های بردار پشتیبان، تصویر مورد نظر طبقه بندی و نقشه ی پوششی اراضی آن تهیه شد. سپس مقادیر دقت و ضریب کاپا برای این دو الگوریتم محاسبه گردید.

حمید باقری^۱ (✉)


۱. مربی، گروه مهندسی عمران، دانشکده عمران و نقشه برداری، دانشگاه ملی مهارت، تهران، ایران

DOI: 10.30495/girs.2022.692233

پست الکترونیکی مسئول مکاتبات: h-bagheri@nus.ac.ir

در نهایت الگوریتم کرم شب تاب در نرم افزار پایتون برنامه نویسی شد و پس از ورود تصاویر به برنامه پایتون و مشاهده نتایج خروجی، مشخص شد که پارامترهای تابع هسته مرکزی روش بردار پشتیبان و تعداد نورون های روش شبکه عصبی مصنوعی بهبود داده شده است. در نهایت نتایج نشان داد که الگوریتم کرم شب تاب یک طبقه بندی کننده مناسب است و قابلیت رقابت با بقیه روش ها را دارد. دقت کلی حاصل از طبقه بندی برای سنجنده ASTER با این الگوریتم، در طبقه بندی شبکه عصبی به میزان ۱,۶ درصد و در طبقه بندی ماشین بردار پشتیبان به میزان ۳,۸ درصد افزایش یافت. همچنین مقایسه ضریب کاپا، دقت کاربر و دقت تهیه کننده برای روش های ذکر شده در بخش نتایج و تحلیل شرح داده شده است.

طرح مسئله: در دهه های اخیر، استخراج اطلاعات از تصاویر ماهواره ای پیشرفت های چشمگیری داشته است. الگوریتم های متعددی برای این منظور توسعه یافته اند که هر کدام دارای مزایا و محدودیت های خاص خود هستند. یکی از مهم ترین رویکردها در تحلیل تصاویر سنجش از دور، طبقه بندی است که نقش اساسی در شناسایی تغییرات کاربری و پوشش زمین ایفا می کند. طبقه بندی به معنای اختصاص دادن هر پیکسل از تصویر ماهواره ای به یک طبقه مشخص است. یکی از چالش های اصلی در این حوزه، انتخاب روشی برای طبقه بندی با دقت بالا، به ویژه برای تصاویر ماهواره ای با وضوح مکانی بالا است.



هدف: هدف این مطالعه، بهبود دقت طبقه‌بندی تصاویر ماهواره‌ای با استفاده از الگوریتم‌های فراابتکاری است. در این پژوهش از یک روش طبقه‌بندی نظارت‌شده بهره گرفته شده که با الگوریتم کرم شب‌تاب بهبود یافته است. در ابتدا، طبقه‌بندی با استفاده از دو روش شناخته‌شده شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) انجام شد. نقشه‌های پوشش زمین برای هر دو روش تولید گردید. برای ارزیابی عملکرد، دقت کلی و ضریب کاپا محاسبه شد. الگوریتم کرم شب‌تاب در محیط پایتون پیاده‌سازی شد تا تعداد نورون‌ها در ANN و پارامترهای هسته در SVM را بهینه‌سازی کند. به عنوان یک روش جست‌وجوی فراابتکاری نسبتاً جدید، الگوریتم کرم شب‌تاب توانایی بالایی در بخش‌بندی خودکار و بهبود عملکرد طبقه‌بندی در مقایسه با رویکردهای سنتی از خود نشان می‌دهد.

روش تحقیق: تصویر ماهواره‌ای مورد استفاده در این پژوهش از حسگر ASTER (رادیومتر بازتاب و گسیل حرارتی پیشرفته فضا‌برد) مستقر بر ماهواره TERRA به دست آمده است. این حسگر عمدتاً برای کاربردهای زمین‌شناسی طراحی شده و دارای توان تفکیک طیفی بالایی در محدوده مادون قرمز است. تصویر انتخابی مربوط به سال ۲۰۱۵ با ۱۴ باند طیفی است. مراحل پیش‌پردازش و طبقه‌بندی با استفاده از نرم‌افزار ENVI نسخه ۵.۳ انجام گرفت و نمونه‌های آموزشی از طریق Google Earth تعیین شدند. فرآیند بهینه‌سازی طبقه‌بندی با استفاده از الگوریتم کرم شب‌تاب در محیط پایتون توسعه یافت.

نتایج و بحث: پس از اجرای الگوریتم کرم شب‌تاب بر روی نتایج حاصل از طبقه‌بندی شبکه عصبی مصنوعی و ماشین بردار پشتیبان، نتایج دقت و ضریب کاپا به دست آمد. در حالت اولیه، دقت کلی طبقه‌بندی برای شبکه عصبی برابر با ۹۱٫۸۱٪ و ضریب کاپا برابر با ۸۸٫۷۸٪ بود. پس از اعمال الگوریتم کرم شب‌تاب، این مقادیر به ترتیب به ۹۵٫۶۱٪ و ۹۱٫۹۳٪ افزایش یافتند. در مورد ماشین بردار پشتیبان نیز، دقت کلی از ۹۴٫۳۳٪ به ۹۵٫۹۳٪ و ضریب کاپا از ۹۲٫۲۳٪ به ۹۳٫۴۳٪ افزایش یافت. این نتایج نشان‌دهنده بهبود

عملکرد طبقه‌بندی در هر دو روش با استفاده از الگوریتم کرم شب‌تاب است. همچنین، مقایسه با تحقیقات پیشین نشان می‌دهد که الگوریتم‌های فراابتکاری مانند ژنتیک، کلونی مورچه‌ها و ازدحام ذرات نیز توانایی افزایش دقت و ضریب کاپا را دارند. با این حال، اثربخشی آن‌ها وابسته به نوع الگوریتم طبقه‌بندی و ویژگی‌های تصویر ماهواره‌ای است.

نتیجه‌گیری: با انجام مقایسه‌ی دقت طبقه‌بندی حاصل از روش‌های مبتنی بر شبکه عصبی مصنوعی و ماشین بردار پشتیبان مشخص گردید که روش ماشین بردار پشتیبان با ضریب کاپای ۰٫۹۲۲۳ نسبت به روش شبکه عصبی مصنوعی با ضریب کاپای ۰٫۸۸۷۸ دارای دقت بیشتری است. در این تحقیق پس از بررسی نتایج مربوط به طبقه‌بندی این نتایج حاصل شد که برای تصویر موردنظر، دقت طبقه‌بندی ماشین بردار پشتیبان به اندازه ۲٫۵۲ درصد نسبت به طبقه‌بندی شبکه عصبی مصنوعی بهتر است. پس از اجرای الگوریتم کرم شب‌تاب بر روی تصویر ملاحظه شد که دقت طبقه‌بندی روش ماشین بردار پشتیبان به میزان حدود ۳٫۸ درصد و دقت طبقه‌بندی شبکه عصبی مصنوعی برای این تصویر به میزان حدود ۱٫۶ درصد بهبود داده شده است.

مقایسه عملکرد دو روش شبکه عصبی مصنوعی و ماشین بردار پشتیبان نشان داد که روش دوم با ضریب کاپای ۰٫۹۲۲۳ دقت بالاتری نسبت به روش اول با ضریب ۰٫۸۸۷۸ دارد. همچنین، پیاده‌سازی الگوریتم کرم شب‌تاب موجب افزایش دقت طبقه‌بندی در ماشین بردار پشتیبان به میزان حدود ۳٫۸٪ و در شبکه عصبی مصنوعی به میزان حدود ۱٫۶٪ گردید. این یافته‌ها نشان می‌دهند که الگوریتم کرم شب‌تاب می‌تواند به عنوان یک ابزار کارآمد در بهینه‌سازی فرآیند طبقه‌بندی تصاویر ماهواره‌ای مورد استفاده قرار گیرد.

واژگان کلیدی: طبقه‌بندی، الگوریتم کرم شب‌تاب، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، تصویر ماهواره‌ای

مقدمه

استخراج اطلاعات از تصاویر ماهواره‌ای در دهه‌های اخیر رشد چشمگیری داشته و در این راستا الگوریتم‌های مختلفی جهت استخراج اطلاعات از تصاویر ماهواره‌ای معرفی شده‌اند که هر کدام از این روش‌ها مزایا و معایبی دارند. یکی از روش‌های مهم در تفسیر تصاویر سنجش از دور، طبقه‌بندی تصاویر است که کاربرد زیادی در بررسی تغییرات زمین دارد. طبقه‌بندی و تهیه نقشه پوششی اراضی یکی از پرکاربردترین موارد در استفاده از داده‌های سنجش از دور است. با استفاده از طبقه‌بندی می‌توان عضویت یک پیکسل را به یک کلاس تعیین کرد. مسئله مهم، تعیین یک روش طبقه‌بندی با دقت مناسب برای تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالا است.

هوش جمعی نوعی از روش‌های هوش مصنوعی مبتنی بر رفتارهای جمعی است که عامل‌ها، به‌طور محلی با یکدیگر و با محیط اطراف خود در تعامل هستند و چگونگی تعامل و تبادل اطلاعات بین عوامل متعدد در طبیعت را نشان می‌دهد (۳۶). رویکرد هوش جمعی کارایی خود را در بسیاری از مشکلات بهینه‌سازی که به دنبال بهترین راه‌حل مانند انتخاب ویژگی و سایر مشکلات هستند، ثابت کرده است. موفق‌ترین روش‌های هوش جمعی که تاکنون به وجود آمده‌اند، روش بهینه‌سازی کلونی مورچه‌ها (AntColony Optimization) (۱۸)، روش بهینه‌سازی اجتماع ذرات (Particle Swarm Optimization) (۲۴)، روش بهینه‌سازی زنبور عسل (BeeColony Optimization) (۱۲) و روش بهینه‌سازی کرم شب تاب (Firefly Optimization) است. از این الگوریتم‌ها در مسائل مربوط به انتخاب و اولویت‌بندی ویژگی‌ها استفاده می‌شود، اما به‌ندرت به‌عنوان طبقه‌بندی‌کننده معرفی شدند. هر الگوریتم با ایجاد یک جمعیت اولیه از راه‌حل‌های کاربردی آغاز می‌گردد و به‌صورت مکرر از نسلی به نسلی دیگر در جهت بهترین راه‌حل حرکت می‌کند. در تکرارهای موفق الگوریتم، انتخاب در مجموعه‌ای از راه‌حل‌ها انجام می‌گیرد (۳۰). هر کدام از این الگوریتم‌ها دارای ساختار پارامتری خاصی از جمله اندازه جمعیت، نرخ همگرایی، وزن‌های جستجوی محلی و نرخ

یادگیری هستند که در این پژوهش، تنظیم بهینه آن‌ها از طریق آزمون‌های تجربی صورت گرفته و در بخش روش تحقیق به‌طور کامل تشریح شده است. همچنین مجموعه ویژگی‌های مکانی، طیفی و بافتی استخراج‌شده از تصاویر ورودی نیز پس از نرمال‌سازی، به‌عنوان ورودی به مدل‌های ترکیبی داده شده‌اند.

در دهه‌ی گذشته، روش‌های آماری مانند نزدیک‌ترین همسایه (k-nearest Neighbor)، شبکه عصبی (Neural Network) (۴)، ماشین بردار پشتیبان (Support Vector Machine) (۱۷) و سایر تکنیک‌ها در طبقه‌بندی استفاده شده است. با توجه به این‌که انواع مختلفی از اطلاعات و ویژگی‌های مکانی را می‌توان از یک تصویر استخراج کرد، ضروری است که از یک الگوریتم بهینه‌سازی برای ارائه‌ی بهترین مجموعه ویژگی‌ها برای تشخیص تغییرات در مناطق شهری استفاده شود. در بین الگوریتم‌های بهینه‌سازی پیشنهادی، عملکرد الگوریتم‌های فراابتکاری که از جستجوهای جهانی و محلی استفاده می‌کنند، در مطالعات متعددی به اثبات رسیده است. این الگوریتم‌ها شامل الگوریتم‌های تکاملی مانند الگوریتم ژنتیک (Genetic Algorithm) و الگوریتم‌های هوش ازدحام مانند الگوریتم بهینه‌سازی اجتماع ذرات می‌باشند (۳۵). درحالی‌که کاربرد و عملکرد این دو الگوریتم در تشخیص تغییر مناطق شهری با استفاده از تصاویر با وضوح بالا ارزیابی شده است، ارزیابی روش‌های بهینه‌سازی جدید نیاز به بررسی بیشتر دارند (۷).

الگوریتم‌های بهینه‌سازی هر دو نوع مسائل بهینه‌سازی و کمینه‌سازی را پوشش می‌دهند. بهینه‌سازی کاربردهای زیادی در زمینه‌ی تخصیص منابع، زمان‌بندی‌ها و تصمیم‌گیری‌ها دارد. شیوه‌های سابق برای حل مشکلات بهینه‌سازی، مستلزم تلاش‌های محاسباتی بی‌شماری بودند، درحالی‌که الگوریتم‌های هوش جمعی تا حدی این مشکل را برطرف نموده‌اند. توسط این الگوریتم‌ها راه‌حل‌هایی پیدا می‌شوند که تقریباً به جواب نزدیک هستند (۲۶).

در میان روش‌های مبتنی بر جمعیت، از الگوریتم بهینه‌سازی اجتماع ذرات به صورت جداگانه و الگوریتم بهینه‌سازی اجتماع ذرات ترکیبی با یک عملگر جستجوی محلی برای روش شبکه عصبی مصنوعی به کار برده شده است (۲۰). سایر روش‌های هوش جمعی مانند بهینه‌سازی کلونی مورچه‌ها نیز استفاده شده است (۲۸). علاوه بر این، چن (Chen) (۸) یک الگوریتم ترکیبی جدید براساس الگوریتم ازدحام ماهی مصنوعی پیشنهاد کرد. الگوریتم ژنتیک (۱۹)، ارزیابی تفاضلی (۲۷)، الگوریتم مبتنی بر مکانیسم شبه الکترومغناطیس (Electromagnetism-like mechanism-based algorithm) (۳۱) و الگوریتم جستجوی هارمونی (۱۴) برخی از روش‌های مهم دیگری هستند که در سال‌های اخیر پیشنهاد شده‌اند.

در این مطالعه، برای ارزیابی دقت الگوریتم‌های پیشنهادی، معیارهایی مانند ضریب کاپا، دقت کلی، دقت تولید و دقت کاربر برای هر کلاس محاسبه شده‌اند. نتایج به دست آمده با مدل‌های پایه (مانند SVM و ANN بدون بهینه‌سازی) مقایسه شده‌اند تا میزان بهبود مدل‌ها به صورت عددی مشخص گردد. همچنین عملکرد الگوریتم‌های پیشنهادی از جنبه‌های مختلفی مانند پایداری، سرعت همگرایی و حساسیت به پارامترها نیز تحلیل شده است تا شفافیت علمی در ارزیابی آن‌ها فراهم شود. به طور کلی، پژوهش حاضر تلاش دارد تا با ترکیب الگوریتم هوش جمعی کرم شب‌تاب و روش‌های یادگیری ماشین، ضمن افزایش دقت طبقه‌بندی تصاویر ماهواره‌ای، رویکردی نوین برای تحلیل تغییرات شهری و زیست‌محیطی ارائه دهد. این در حالی است که شفافیت در تنظیمات الگوریتم‌ها، تحلیل دقیق عملکرد و مقایسه با روش‌های مرسوم از جمله مواردی هستند که در طراحی این تحقیق به صورت جدی مورد توجه قرار گرفته‌اند.

پیشینه تحقیق

کاربری اراضی توصیف نوع بهره‌برداری انسان برای یک یا چند هدف بر روی یک قطعه زمین است. آگاهی از نوع و

درصد کاربری‌های مختلف برای شناخت و مدیریت منابع طبیعی و زیست‌محیطی در سطح حوزه‌های آبخیز و سایر واحدهای کاری ضروری است (۲).

داده‌های ماهواره‌ای یکی از سریع‌ترین و کم‌هزینه‌ترین روش‌های در اختیار محققان جهت تهیه نقشه کاربری اراضی می‌باشد. تعیین کاربری اراضی یکی از اطلاعات پایه در ارزیابی منابع مختلف مانند قابلیت اراضی و خاکشناسی، مطالعات پوشش گیاهی، فرسایش و رسوب، مدیریت منابع طبیعی و محیط‌زیست، شناخت توان و استعداد اراضی و در کل مطالعات آبخیزداری و آمایش سرزمین است. معمولاً نقشه پوشش اراضی و نقشه پوششی اراضی به صورت ابهام‌آمیزی به جای همدیگر، البته نه همیشه، استفاده و معمولاً اطلاعات کاربری اراضی از نقشه پوشش زمین استخراج می‌شود (۸).

سنجش از دور با ارائه اطلاعات به هنگام، فراهم آوردن دید همه‌جانبه، استفاده از قسمت‌های مختلف طیف الکترومغناطیسی برای ثبت خصوصیات پدیده‌ها، پوشش‌های تکراری، سرعت انتقال و تنوع اشکال داده‌ها، کاهش هزینه و نیروی انسانی در مطالعات از ارزش زیادی برخوردار است (۹ و ۱۰).

با استفاده از تصاویر ماهواره‌ای می‌توان نقشه‌های پوششی اراضی را در سطوح مختلف تهیه و وضعیت موجود پوشش زمین/ کاربری اراضی را بررسی کرد. حسینی (۱۳۸۲) نقشه پوششی اراضی و تراکم پوشش گیاهی منطقه چمستان (مازندران) را با استفاده از تصاویر ETM و فیوژن (ادغام داد-های ماهواره‌ای) داده‌ها تهیه کرد (۱۰).

شتایی و عبدی (۱۳۸۷) قابلیت داده‌های سنجنده ETM را در تفکیک اراضی جنگلی زاگرس از سایر کاربری‌ها از طریق مقایسه با نقشه واقعیت زمینی نمونه‌برداری شده در حوزه سرخاب لرستان انجام و نتیجه گرفتند که تفکیک و طبقه‌بندی اراضی جنگلی از سایر طبقات کاربری با صحت ۱۰ درصد، مؤید کارایی این روش در تولید این نقشه‌هاست (۲۵).

علوی‌پناه و همکاران (۱۳۸۰) برای تهیه نقشه پوششی اراضی از منطقه کوهستانی موک استان فارس، از داده‌های

برای بهینه‌سازی خوشه‌بندی در داده‌های پیچیده بهره بردند و نتایج بهبود یافته‌ای را گزارش کردند (۱۲).

الگوریتم کرم شب‌تاب بر مبنای رفتار نوری کرم‌های شب‌تاب طراحی شده و به عنوان یک روش قدرتمند برای حل مسائل بهینه‌سازی چند-مکانی (multi-modal optimization) شناخته می‌شود. به عنوان مثال، سو و همکارانش با استفاده از الگوریتم کرم شب‌تاب و انتخاب باند مناسب، طبقه‌بندی تصاویر هایپر اسپکترال را بهبود داده‌اند و دقت طبقه‌بندی را به طور قابل توجهی افزایش دادند (۲۹). همچنین، چن و همکارانش در حوزه تفکیک تصویر از نسخه بهبود یافته این الگوریتم برای segmentation چندسطحی استفاده کردند که توانایی مقابله با نویز را نیز داشت (۷).

هایلون شی (Hailun Xie) و همکاران در سال ۲۰۱۹ به بررسی بهبود دقت طبقه‌بندی K-means با الگوریتم کرم شب‌تاب پرداختند. نتایج تجربی در این تحقیق نشان داد که الگوریتم کرم شب‌تاب پیشنهادی از نظر آماری برتری قابل توجهی در اندازه‌گیری‌های فاصله و عملکرد در مقایسه با خوشه‌بندی معمولی دارد (۳۷).

یانگ از الگوریتم‌های کرم شب‌تاب و ازدحام ذرات استفاده کرده و آنها را برای توابع آزمایشی مختلف با هم مقایسه کرد و به این نتیجه رسید که الگوریتم کرم شب‌تاب نتایج بهتری نسبت به الگوریتم ازدحام ذرات و همچنین الگوریتم ژنتیک از نظر کارایی و میزان موفقیت به دست می‌آورد. همچنین مشخص شده است که توانایی پخش الگوریتم کرم شب‌تاب باعث همگرایی سریعتر به سمت بهینه‌سازی می‌شود (۳۴). در کار مشابهی توسط یانگ و دب (۳۷)، نتایج تجربی نشان داد که الگوریتم کرم شب‌تاب از سایر روش‌ها مانند ازدحام ذرات بهتر عمل می‌کند.

با توجه به موارد فوق، می‌توان دریافت که الگوریتم کرم شب‌تاب نسبت به سایر روش‌ها تأثیر بیشتری دارد و می‌توان با استفاده از آن به بررسی دقت مربوط به طبقه‌بندی تصاویر ماهواره‌ای پرداخت.

رقومی ماهواره لندست TM و سامانه‌های اطلاعاتی جغرافیایی استفاده کردند. آن‌ها از باندهای سه، چهار، پنج و هفت سنجنده TM و روش طبقه‌بندی نظارت‌شده حداکثر احتمال در تولید نقشه استفاده کردند و نقشه‌های شامل ۹ طبقه به دست آوردند که بدین شرح است: زراعت آبی، مرتع، اراضی شخم خورده، شالیزار، جنگل، باغ‌ها، تاکستان، زراعت دیم و اراضی زراعی برداشت شده. به دلیل پیایی بودن دقت طبقه‌بندی برای اراضی مسکونی و رودخانه، از دیگر لایه‌های اطلاعاتی در سامانه اطلاعات جغرافیایی برای تفکیک این دو طبقه استفاده شد. میزان دقت کلی نقشه تولیدشده، ۷/۹۴ درصد برآورد گردید (۲).

آرخی و ادیب‌نژاد (۱۳۹۰) در تحقیقی به ارزیابی کارایی الگوریتم‌های ماشین بردار پشتیبان جهت طبقه‌بندی پوششی اراضی با استفاده از داده‌های ماهواره لندست مربوط به سنجنده ETM در حوزه سد ایلام پرداختند. در این تحقیق طبقه‌بندی با استفاده از روش ماشین‌های بردار پشتیبان، به صورت خودکار و با استفاده از چهار نوع کرنل خطی، چندجمله‌ای، شعاعی و حلقوی اجرا شده است. صحت طبقه‌بندی پوششی اراضی برای روش‌های ماشین بردار پشتیبان و حداکثر احتمال به ترتیب ۹۵ و ۸۵ درصد و ضریب کاپا به ترتیب ۰,۷۹ و ۰,۹۴ برآورد گردید (۳).

رویکرد هوش جمعی کارآیی خود را در بسیاری از مشکلات بهینه‌سازی که به دنبال بهترین راه‌حل مانند انتخاب ویژگی و سایر مشکلات هستند، ثابت کرده است. کارابوگا (Karaboga) و آکای (Akay) نشان دادند که الگوریتم کلونی زنبور عسل نسبت به الگوریتم‌های ژنتیک و بهینه‌سازی اجتماع ذرات برای مجموعه بزرگی از توابع بهتر عمل می‌کند (۱۵). این الگوریتم در مسائل خوشه‌بندی و طبقه‌بندی تصاویر ماهواره‌ای کاربرد فراوان دارد. به طور مثال، در پژوهشی از ترکیب شبکه عصبی مصنوعی با الگوریتم زنبور مصنوعی برای تخمین ویژگی‌های محصولات کشاورزی (سیب رد دلشز) استفاده شده است که دقت قابل توجهی در پیش‌بینی نشان داد (۱). همچنین در مطالعه‌ای دیگر از الگوریتم زنبور مصنوعی

کاربری اراضی توصیف نوع بهره‌برداری انسان برای یک یا چند هدف بر روی یک قطعه زمین است. آگاهی از نوع و درصد کاربری‌های مختلف برای شناخت و مدیریت منابع طبیعی و زیست‌محیطی در سطح حوزه‌های آبخیز و سایر واحدهای کاری ضروری است (۲).

داده‌های ماهواره‌ای یکی از سریع‌ترین و کم‌هزینه‌ترین روش‌های در اختیار محققان جهت تهیه نقشه کاربری اراضی می‌باشد. تعیین کاربری اراضی یکی از اطلاعات پایه در ارزیابی منابع مختلف مانند قابلیت اراضی و خاکشناسی، مطالعات پوشش گیاهی، فرسایش و رسوب، مدیریت منابع طبیعی و محیط‌زیست، شناخت توان و استعداد اراضی و در کل مطالعات آبخیزداری و آمایش سرزمین است. معمولاً نقشه پوشش اراضی و نقشه پوششی اراضی به صورت ابهام‌آمیزی به جای همدیگر، البته نه همیشه، استفاده و معمولاً اطلاعات کاربری اراضی از نقشه پوشش زمین استخراج می‌شود (۸).

سنجش‌ازدور با ارائه اطلاعات به هنگام، فراهم آوردن دید همه‌جانبه، استفاده از قسمت‌های مختلف طیف الکترومغناطیسی برای ثبت خصوصیات پدیده‌ها، پوشش‌های تکراری، سرعت انتقال و تنوع اشکال داده‌ها، کاهش هزینه و نیروی انسانی در مطالعات از ارزش زیادی برخوردار است (۹ و ۱۰).

با استفاده از تصاویر ماهواره‌ای می‌توان نقشه‌های پوششی اراضی را در سطوح مختلف تهیه و وضعیت موجود پوشش زمین/ کاربری اراضی را بررسی کرد. حسینی (۱۳۸۲) نقشه پوششی اراضی و تراکم پوشش گیاهی منطقه چمستان (مازندران) را با استفاده از تصاویر ETM و فیوژن (ادغام داده‌های ماهواره‌ای) داده‌ها تهیه کرد (۱۰).

شتایی و عبدی (۱۳۸۷) قابلیت داده‌های سنجنده ETM را در تفکیک اراضی جنگلی زاگرس از سایر کاربری‌ها از طریق مقایسه با نقشه واقعیت زمینی نمونه‌برداری شده در حوزه سرخاب لرستان انجام و نتیجه گرفتند که تفکیک و طبقه‌بندی اراضی جنگلی از سایر طبقات کاربری با صحت ۱۰ درصد، مؤید کارایی این روش در تولید این نقشه‌هاست (۲۵).

علوی‌پناه و همکاران (۱۳۸۰) برای تهیه نقشه پوششی اراضی از منطقه کوهستانی موک استان فارس، از داده‌های رقومی ماهواره لندست TM و سامانه‌های اطلاعاتی جغرافیایی استفاده کردند. آن‌ها از باندهای سه، چهار، پنج و هفت سنجنده TM و روش طبقه‌بندی نظارت‌شده حداکثر احتمال در تولید نقشه استفاده کردند و نقشه‌های شامل ۹ طبقه به دست آوردند که بدین شرح است: زراعت آبی، مرتع، اراضی شخم خورده، شالیزار، جنگل، باغ‌ها، تاکستان، زراعت دیم و اراضی زراعی برداشت شده. به دلیل پیایی بودن دقت طبقه‌بندی برای اراضی مسکونی و رودخانه، از دیگر لایه‌های اطلاعاتی در سامانه اطلاعات جغرافیایی برای تفکیک این دو طبقه استفاده شد. میزان دقت کلی نقشه تولیدشده، ۷/۹۴ درصد برآورد گردید (۲).

ماشین بردار پشتیبان یکی از الگوریتم‌های مطرح در طبقه‌بندی داده‌ها است که به ویژه در حوزه تصاویر ماهواره‌ای برای تشخیص کاربری و پوشش زمین کاربرد گسترده دارد. به عنوان مثال، آرخی و ادیب‌نژاد با استفاده از SVM توانستند کاربری اراضی در منطقه ایلام را با دقت بالا طبقه‌بندی کنند (۳). لی و منجاسرین نسخه نرم SVM را معرفی کردند که انعطاف بیشتری در برابر داده‌های نویزی دارد (۱۷).

آرخی و ادیب‌نژاد (۱۳۹۰) در تحقیقی به ارزیابی کارایی الگوریتم‌های ماشین بردار پشتیبان جهت طبقه‌بندی پوششی اراضی با استفاده از داده‌های ماهواره لندست مربوط به سنجنده ETM در حوزه سد ایلام پرداختند. در این تحقیق طبقه‌بندی با استفاده از روش ماشین‌های بردار پشتیبان، به صورت خودکار و با استفاده از چهار نوع کرنل خطی، چندجمله‌ای، شعاعی و حلقوی اجرا شده است. صحت طبقه‌بندی پوششی اراضی برای روش‌های ماشین بردار پشتیبان و حداکثر احتمال به ترتیب ۹۵ و ۸۵ درصد و ضریب کاپا به ترتیب ۰٫۷۹ و ۰٫۹۴ برآورد گردید (۳).

رویکرد هوش جمعی کارایی خود را در بسیاری از مشکلات بهینه‌سازی که به دنبال بهترین راه‌حل مانند انتخاب ویژگی و سایر مشکلات هستند، ثابت کرده است. کارابوگا

باعث همگرایی سریعتر به سمت بهینه سازی می شود (۳۴). در کار مشابهی توسط یانگ و دب (۳۷)، نتایج تجربی نشان داد که الگوریتم کرم شب تاب از سایر روش ها مانند ازدحام ذرات بهتر عمل می کند.

با توجه به موارد فوق، می توان دریافت که الگوریتم کرم شب تاب نسبت به سایر روش ها تأثیر بیشتری دارد و می توان با استفاده از آن به بررسی دقت مربوط به طبقه بندی تصاویر ماهواره ای پرداخت.

با وجود مزایای استفاده از الگوریتم های هوش مصنوعی همچون کرم شب تاب در بهبود دقت طبقه بندی تصاویر ماهواره ای، این تحقیق با محدودیت هایی نیز مواجه بوده است. نخست آنکه دسترسی به داده های میدانی دقیق و به روز برای ارزیابی صحت طبقه بندی در تمامی کلاس های کاربری محدود بود که می تواند بر صحت ارزیابی تأثیر بگذارد. همچنین، تنظیم بهینه پارامترهای الگوریتم کرم شب تاب به دلیل ماهیت تصادفی آن، نیازمند آزمون های مکرر و صرف زمان بالا بود. محدودیت در دسترسی به تصاویر با وضوح بالاتر در بازه های زمانی مختلف نیز از دیگر چالش ها به شمار می رفت که امکان بررسی تغییرات زمانی پوشش اراضی را محدود کرد. در نهایت، مقایسه عملکرد الگوریتم با سایر روش های بهینه سازی تنها در یک منطقه انجام شد و تعمیم نتایج به مناطق دیگر نیازمند بررسی های بیشتر است.

روش تحقیق

منطقه مورد مطالعه

شهرستان رفسنجان در جنوب شرق ایران و در شمال غربی استان کرمان قرار دارد (شکل ۱). این شهرستان با جمعیت حدود ۱۶۱۹۰۹ نفر در سرشماری سال ۱۳۹۵ (۳۹) یکی از قطب های اقتصادی و کشاورزی استان محسوب می شود. فاصله رفسنجان تا مرکز استان کرمان حدود ۱۱۵ کیلومتر است. این شهر به دلیل دارا بودن بزرگ ترین باغات پسته جهان و موقعیت استراتژیک اقتصادی، از نظر کاربری اراضی و پوشش گیاهی ویژگی های خاصی دارد. آب و هوای نیمه بیابانی، میانگین بارش

(Karaboga) و آکای (Akay) نشان دادند که الگوریتم کلونی زنبور عسل نسبت به الگوریتم های ژنتیک و بهینه سازی اجتماع ذرات برای مجموعه بزرگی از توابع بهتر عمل می کند (۱۵). این الگوریتم در مسائل خوشه بندی و طبقه بندی تصاویر ماهواره ای کاربرد فراوان دارد. به طور مثال، در پژوهشی از ترکیب شبکه عصبی مصنوعی با الگوریتم زنبور مصنوعی برای تخمین ویژگی های محصولات کشاورزی (سیب رد دلشیز) استفاده شده است که دقت قابل توجهی در پیش بینی نشان داد (۱). همچنین در مطالعه ای دیگر از الگوریتم زنبور مصنوعی برای بهینه سازی خوشه بندی در داده های پیچیده بهره بردند و نتایج بهبود یافته ای را گزارش کردند (۱۲).


الگوریتم کرم شب تاب بر مبنای رفتار نوری کرم های شب تاب طراحی شده و به عنوان یک روش قدرتمند برای حل مسائل بهینه سازی چند-مکانی (multi-modal optimization) شناخته می شود. به عنوان مثال، سو و همکارانش با استفاده از الگوریتم کرم شب تاب و انتخاب باند مناسب، طبقه بندی تصاویر هایپراسپکترال را بهبود داده اند و دقت طبقه بندی را به طور قابل توجهی افزایش دادند (۲۹). همچنین، چن و همکارانش در حوزه تفکیک تصویر از نسخه بهبود یافته این الگوریتم برای segmentation چندسطحی استفاده کردند که توانایی مقابله با نویز را نیز داشت (۷).

هایلون شی (Hailun Xie) و همکاران در سال ۲۰۱۹ به بررسی بهبود دقت طبقه بندی K-means با الگوریتم کرم شب تاب پرداختند. نتایج تجربی در این تحقیق نشان داد که الگوریتم کرم شب تاب پیشنهادی از نظر آماری برتری قابل توجهی در اندازه گیری های فاصله و عملکرد در مقایسه با خوشه بندی معمولی دارد (۳۷).

یانگ از الگوریتم های کرم شب تاب و ازدحام ذرات استفاده کرده و آنها را برای توابع آزمایشی مختلف با هم مقایسه کرد و به این نتیجه رسید که الگوریتم کرم شب تاب نتایج بهتری نسبت به الگوریتم ازدحام ذرات و همچنین الگوریتم ژنتیک از نظر کارایی و میزان موفقیت به دست می آورد. همچنین مشخص شده است که توانایی پخش الگوریتم کرم شب تاب

شهری، زمین‌های بایر، پوشش گیاهی، راه‌ها و باغات پسته در منطقه مورد مطالعه نشان داده شده است.

سالانه حدود ۱۰۰ میلی‌متر، و ارتفاع متوسط ۱۵۲۸ متر از سطح دریا (۴۰)، از مهم‌ترین ویژگی‌های اقلیمی این منطقه هستند. در شکل ۱ انواع کاربری‌های اراضی از جمله سکونتگاه‌های



شکل ۱. منطقه مورد مطالعه

Fig 1. Study area

استفاده قرار گرفت. به منظور افزایش دقت طبقه‌بندی، الگوریتم کرم شب‌تاب (Firefly Algorithm)، که یکی از الگوریتم‌های بهینه‌سازی الهام‌گرفته از طبیعت است (۳۴)، با استفاده از زبان برنامه‌نویسی Python توسعه داده شد. این الگوریتم به صورت سفارشی‌سازی شده برای بهینه‌سازی معیارهای شباهت طیفی بین کلاس‌ها مورد استفاده قرار گرفت. نقاط کنترل زمینی (GCP) از طریق هم‌مرجع‌سازی با تصاویر Google Earth و بازبینی میدانی محدود به صورت دستی استخراج شدند. تطابق هندسی تصویر نیز با استفاده از مدل RST و ضرایب تعیین شده در نرم‌افزار ENVI انجام گرفت. دقت طبقه‌بندی نهایی با استفاده از ماتریس خطا (Error Matrix) و شاخص

داده‌ها و روش‌ها

در این پژوهش به منظور طبقه‌بندی پوشش/کاربری اراضی منطقه، از تصویر ماهواره‌ای سنجنده‌ی ASTER متعلق به ماهواره‌ی Terra استفاده شد. این سنجنده، که به طور خاص برای مطالعات زمین‌شناسی طراحی شده است، دارای ۱۴ باند طیفی با وضوح‌های متفاوت می‌باشد (۳۸). داده‌های مربوط به سال ۲۰۱۵ از پایگاه داده NASA Earthdata تهیه و اعتبارسنجی آن براساس مقایسه با تصاویر Google Earth و منابع زمینی صورت گرفت. برای پیش‌پردازش داده‌ها و اجرای الگوریتم‌ها از نرم‌افزار ENVI 5.3 استفاده شد. نرم‌افزار گوگل ارث به منظور استخراج و بررسی نمونه‌های آموزشی مورد

است که قبلاً بر روی آن تصحیح هندسی صورت گرفته باشد (۵). رایج ترین روش غیرپارامتری انجام تطابق هندسی، استفاده از نقاط کنترل زمینی است. برای انجام عملیات زمین مرجع کردن، ۳۰ نقطه‌ی کنترل در منطقه مورد مطالعه در تقاطع جاده ها، آبراهه ها و جاده ها مشخص گردید و در تصاویر متناظر علامت زده شد، سپس با نمونه برداری مجدد و روش نزدیکترین همسایه مقدار خطای جذر مربعات میانگین، ۰٫۴۵، بدست آمد. در مرحله‌ی بعد اقدام به تهیه‌ی نقشه واقعیت زمینی شد. این نقشه با بهره گیری از تصویر ماهواره‌ای موجود در نرم افزار گوگل ارث تهیه شده است که در شکل ۲ نشان داده شده است. برای بالا بردن دقت کار و پایین آوردن درصد اشتباه در پیکسل های تصویر، سعی شد بین ۸ تا ۱۵ نمونه از هر کلاس انتخاب گردد.

کاپا (Kappa Coefficient) ارزیابی شد. برای اعتباربخشی نتایج، ۳۰ درصد از داده ها به صورت تصادفی به عنوان نمونه آزمون اختصاص یافتند و صحت کلی (Overall Accuracy) نیز گزارش شد. گردش کار کلی پروژه در شکل ۲ به صورت شماتیک نشان داده شده است که شامل مراحل: (۱) پیش پردازش تصویر، (۲) استخراج نمونه های آموزشی، (۳) پیاده سازی الگوریتم کرم شب تاب، (۴) اجرای طبقه بندی، و (۵) ارزیابی دقت است.

پیش پردازش تصاویر ماهواره ای

اولین و یکی از مهم ترین مراحل در تجزیه و تحلیل سنجش از دور، مرحله‌ی پیش پردازش است که شامل اصلاحات هندسی و رادیومتری است. به طور کلی منظور از تصحیح هندسی یک تصویر، تغییر سیستم مختصات اجزای سازنده تصویر و انطباق آن با نقشه های نظیر و یا تصویری




الف



ب



ج



د

شکل ۲. کلاس کاربری های مشخص شده بر روی تصویر گوگل ارث

الف. جاده، ب. زمین بایر، ج. مسکونی و شهری، د. پوشش گیاهی

Fig 2. The user class specified on the Google Earth image
a. Road, b. Barren land, c. Residential and urban, d. Vegetation

طبقه‌بندی نظارت شده

بعد از پردازش‌های اولیه و با استفاده از تصاویر رنگی کاذب و تصویر حاصل از گوگل ارث و همچنین بازدیدهای صحرائی، انواع پوشش‌های مختلف منطقه به شرح جدول ۱ شناسایی گردید. به منظور طبقه‌بندی تصویر، نمونه‌های آموزشی به عنوان الگوی مشخص طبقه براساس عملیات میدانی، تصاویر رنگی و تصاویر گوگل ارث انتخاب شدند. در نهایت برای طبقه‌بندی تصویر از دو روش طبقه‌بندی نظارت شده شبکه عصبی مصنوعی و ماشین بردار پشتیبان استفاده شد.

بعد از انتخاب ترکیب رنگی کاذب (باندهای ۱ و ۲ و ۳)

برای تصویر، اقدام به طبقه‌بندی تصویر در پنج طبقه‌ی شهری، جاده، پوشش گیاهی، زمین‌های بایر و کوه شد که پس از آن نمونه‌های آموزشی از سطح منطقه با استفاده از تصاویر گوگل ارث و تفسیر بصری به دست آمد. به منظور طبقه‌بندی تصویر، نمونه‌های آموزشی به عنوان الگوی مشخصات طبقه براساس عملیات میدانی انتخاب شد. کلاس‌های کاربری در نظر گرفته شده برای طبقه‌بندی تصویر به شرح جدول ۱ می‌باشند. با توجه به نوع پیکسل‌های تصویر تعداد نمونه‌های انتخابی متفاوت انتخاب گردید.

جدول ۱. کلاس کاربری‌های در نظر گرفته شده برای طبقه‌بندی نظارت شده

Table 1. Usage class intended for classification

نام کلاس	شرح	تعداد نمونه
جاده	خیابان، کوچه، بزرگ راه و آزاد راه	۱۵
زمین بایر	مناطق بایر و دارای پوشش گیاهی بسیار اندک که به شکل خاک یا زمین برهنه هستند	۸
شهری	مناطق مسکونی، تجاری و صنعتی	۸
کوه	مناطق کوهستانی	۱۲
پوشش گیاهی	انواع پوشش‌های گیاهی و فضای سبز	۱۳

روش طبقه‌بندی نظارت شده شبکه عصبی مصنوعی

از اواخر دهه ۱۹۸۰، شبکه‌های عصبی مصنوعی برای آنالیز داده‌های سنجش از دور در کاربردهای گوناگون مانند طبقه‌بندی پوشش اراضی، آشکارسازی ابر و مانند اینها به کار گرفته شده است (۳۲). شبکه‌های عصبی مصنوعی، روش‌های مطلوبی برای طبقه‌بندی کاربری و پوشش اراضی به شمار می‌آیند به طور کلی سه مرحله در طبقه‌بندی شبکه عصبی مصنوعی وجود دارد. مرحله اول، فرایندی آموزشی با استفاده از داده‌های ورودی است. مرحله دوم، فاز اعتبارسنجی و مرحله‌ی آخر، طبقه‌بندی است که نقشه طبقه‌بندی شده پوشش یا کاربری اراضی را ایجاد می‌کند (۳۳).

روش طبقه‌بندی نظارت شده ماشین بردار پشتیبان

ماشین بردار پشتیبان یک روش پیشرفته است که برای طبقه‌بندی مورد استفاده قرار می‌گیرد و تحقیقات مختلف نشان داده است که دقت و مزایای محاسباتی بهتری نسبت به سایر روش‌های طبقه‌بندی سنتی دارد (۱۳). از زمان معرفی ماشین بردار پشتیبان، ثابت شده است که در طبقه‌بندی تصاویر سنجش از دور، تجزیه و تحلیل و پیش‌بینی تغییرات کاربری اراضی شهری بسیار کارآمدتر شده است (۲۱). با توجه به توانایی ماشین بردار پشتیبان برای مدل‌سازی داده‌های دنیای واقعی پیچیده، در مقایسه با مدل‌های مبتنی بر عامل که در ارزیابی محدودیت‌ها و نتایج مدل ناتوانی هستند، مدل‌های پیش‌بینی نسبتاً بهتری می‌باشند (۲۲ و ۲۳).

الگوریتم بهینه سازی کرم شب تاب Firefly Algorithm

الگوریتم کرم شب تاب در ابتدا توسط یانگ (۳۶) در اواخر سال ۲۰۰۷ به عنوان یک روش مبتنی بر جمعیت برای حل مسائل بهینه سازی توسعه یافت که ایده اصلی آن، از ارتباط نوری میان کرم های شب تاب الهام گرفته شده است. کرم های شب تاب کم نور به راحتی توسط کرم های شب تاب روشن تر جذب می شوند و روشنایی کرم شب تاب تحت تأثیر محیط مورد نظر قرار می گیرد.

الگوریتم کرم شب تاب از سه قانون پیروی می کند:

- کرم شب تاب باید تک جنسیت باشد.

- کرم های شب تاب کم نورتر به طور تصادفی توسط کرم های شب تاب پرنور جذب می شوند.

- روشنایی هر کرم شب تاب نشان دهنده کیفیت راه حل است.

در این الگوریتم، شکل تابع جذابیت یک کرم شب تاب با

رابطه ۱ نشان داده می شود:

$$\beta(r) = \beta_0 \exp(-\gamma r^2) \quad [1]$$

در این رابطه، r فاصله بین هر دو کرم شب تاب است، β_0

مقدار جاذبه ی اولیه در $r = 0$ و γ یک ضریب جذب است که

کاهش شدت نور را کنترل می کند (در این تحقیق مقدار آن

برابر ۱ در نظر گرفته می شود).

فاصله بین هر دو کرم شب تاب i و j به ترتیب در موقعیت های x_i و x_j می تواند به صورت فاصله دکارتی یا اقلیدسی به صورت رابطه ۲ تعریف شود:

$$r_{ij} = \|x_i - x_j\| = \sqrt{\sum_{k=1}^d (x_{i,k} - x_{j,k})^2} \quad [2]$$


که در آن، d ابعاد مسئله داده شده است. حرکت یک کرم شب تاب i که توسط یک کرم شب تاب درخشان تر j جذب می شود، با رابطه ۳ نشان داده می شود:

$$X_i = X_i + \beta_0 \times \exp(-\gamma r_{ij}^2) \times (X_j - X_i) + \alpha \times (rand - \frac{1}{2}) \quad [3]$$

که در آن، عبارت اول موقعیت فعلی کرم شب تاب است، از عبارت دوم برای در نظر گرفتن جذب کرم شب تاب نسبت به شدت نور شب تاب های همسایه استفاده می شود و عبارت سوم برای حرکت تصادفی یک کرم شب تاب زمانی که نمی تواند هیچ گونه کرم درخشان تر را ببیند، استفاده می شود.

ضریب α یک پارامتر تصادفی است که توسط مسئله مورد نظر تعیین می شود، در حالی که $rand$ یک مولد اعداد تصادفی است که به طور پیوسته در فضا توزیع شده است (۱۱).

شبکه عصبی احتمالی از ۴ لایه تشکیل شده است. ورودی، الگو، تجمیع و خروجی که در شکل ۴ نشان داده شده است.




شکل ۴. لایه های روش شبکه عصبی احتمالی (۴۵)

Fig 4. Layers of probabilistic neural network methods (45)

خروجی آخرین لایه‌ای می‌باشد که شامل یک کلاس است، زیرا معمولاً تنها یک خروجی درخواست می‌شود. همانطور که در شکل ۵ نشان داده شده است، این روش از وزن‌های اولیه شروع می‌شود که به طور تصادفی توسط مدل طبقه‌بندی شبکه عصبی احتمالی اصلی ایجاد می‌شوند. سپس مقادیر داده‌های ورودی در وزن‌های مناسب $w(ij)$ ضرب می‌شوند که این وزن‌ها توسط الگوریتم شبکه عصبی احتمالی تعیین می‌گردند.

لایه ورودی، لایه اولیه نورون‌ها است. هر نورون ورودی یک ویژگی جداگانه را در مجموعه داده‌های آموزشی نشان می‌دهد (به عنوان مثال، از x_1 تا x_n). تعداد ورودی‌ها برابر با تعداد ویژگی‌های مجموعه داده است. در نهایت، مقادیر داده‌های ورودی در وزن‌های مناسب $w(ij)$ ضرب می‌شوند و همانطور که توسط الگوریتم شبکه عصبی مصنوعی احتمالی نشان داده شده است به لایه الگو منتقل می‌گردند. لایه‌ی



شکل ۵. نمایش وزن‌های اولیه (۴۵)
Fig 5. Displays of initial weights (45)

مرحله انتخاب ویژگی که وظیفه کاهش ویژگی‌ها و انتخاب مفیدترین ویژگی‌ها را بر عهده دارد، مرحله ساخت مدل که مسئول انتخاب ارائه‌دهندگان کلاس کرم شب‌تاب است. مرحله استفاده و پیش‌بینی مدل که مسئول تخصیص نمونه‌های آموزشی دیده نشده در کلاس‌های نسبی با استفاده از ارائه‌دهندگان کلاس است.

مبانی روش پیشنهادی
الگوریتم کرم شب‌تاب را می‌توان از مظاهر هوش ازدحام (Swarm Intelligence) دانست که در آن از همکاری اعضای ساده و کم‌هوش، مرتبه بالاتری از هوشمندی ایجاد می‌شود که قطعاً توسط هیچ یک از اجزا قابل حصول نیست. فرایند کامل الگوریتم پیشنهادی شامل سه مرحله است.


حال نقاط بهینه به دست آمده‌اند و این نقاط در روند بالا دوباره مورد استفاده قرار می‌گیرد، اما این بار فقط با یک تکرار کلیه فواصل برای تمام پیکسل‌ها و نسبت به نقاط بهینه محاسبه شده و فواصل در مرحله ۲ محاسبه می‌شوند که این فواصل، بهینه هستند. حال طبقه‌بندی براساس این فواصل بهینه به دست خواهد آمد.


نتایج و بحث

برای طبقه‌بندی تصویر از دو روش شبکه عصبی مصنوعی و ماشین بردار پشتیبان استفاده شد که در شکل ۶ نشان داده شده‌اند. بعد از انجام طبقه‌بندی با نرم‌افزار انوی ۵/۳ پارامترهای ماتریس خطا (Error Matrix) طبقه‌بندی نظارت شده به دست آمد که در جداول ۲ و ۳ مشاهده می‌شود.

الگوریتم کرم شبتاب عملیات جستجو را با توجه به رفتارهای تغذیه کرم شبتاب انجام می‌دهد. در الگوریتم کرم شبتاب، دسته‌ای از کرم شبتاب به طور تصادفی شروع می‌شود و هر کرم شبتاب یک محلول اولیه را نشان می‌دهد. در الگوریتم کرم شبتاب روند کار بدین صورت است که هر کرم شبتاب با تک تک کرم‌های شبتاب دیگر مقایسه می‌شود. اگر کرم شبتاب نور کمتری نسبت به کرم شبتاب مقایسه‌شونده داشته باشد به سمت کرم شبتاب با نور بیشتر (مسئله‌ی پیدا کردن نقطه ماکزیمم) حرکت می‌کند. این عمل باعث می‌شود که ذرات به اطراف ذره‌ای که نور بیشتری دارد متمرکز شود و اگر در تکرار بعدی الگوریتم، ذره‌ای با نور بهتر وجود داشته باشد ذرات دوباره به سمت ذره با نور بیشتر حرکت می‌کند. این الگوریتم به تعداد تکرارهای زیادی برای رسیدن به نقطه بهینه نیاز دارد. این مراحل آنقدر تکرار می‌شوند که به حداکثر تکرار برسد و نقاط بهینه به دست آیند.

الف





شکل ۶. طبقه‌بندی تصویر با روش

الف. شبکه عصبی مصنوعی ب. ماشین بردار پشتیبان

Fig 6. Image classification by method
a. Artificial neural network with. Support vector machine

جدول ۲. ماتریس خطای طبقه‌بندی نظارت شده روش شبکه عصبی

Table 2. Neural network method classification error matrix

	شهری	پوشش گیاهی	کوه	زمین‌های بایر	جاده	مجموع سطرها
شهری	۸۰۱	۰	۲	۲۰۸	۷	۱۰۱۸
پوشش گیاهی	۱۵	۱۹۷۵	۰	۰	۲	۱۹۹۲
کوه	۶۲	۰	۸۹۵	۴	۱۲	۹۷۳
زمین‌های بایر	۱۶	۴	۰	۴۶۵	۰	۴۸۵
جاده	۷	۰	۵۴	۰	۲۶۷	۳۲۸
مجموع ستون‌ها	۹۰۱	۱۹۷۹	۹۵۱	۶۷۷	۲۸۱	۴۷۹۶

جدول ۳. ماتریس خطای طبقه بندی نظارت شده به روش ماشین بردار پشتیبان

Table 3. Support vector machine method classification error matrix

مجموع سطرها	جاده	زمین های بایر	کوه	پوشش گیاهی	شهری	
۱۰۰۲	۹	۱۵۴	۱۲	۰	۸۲۷	شهری
۱۹۸۱	۲	۰	۰	۱۹۷۴	۵	پوشش گیاهی
۹۸۲	۱۶	۰	۹۳۹	۰	۲۷	کوه
۵۶۸	۰	۵۲۳	۰	۵	۴۰	زمین های بایر
۲۶۳	۲۶۱	۰	۰	۰	۲	جاده
۴۷۹۶	۲۸۸	۶۷۷	۹۵۱	۱۹۷۹	۹۰۱	مجموع ستون ها

لازمه استفاده از هر نوع اطلاعات موضوعی، آگاهی از درستی و صحت آن است. بعد از طبقه بندی تصاویر ماهواره ای، با استفاده از نمونه های آموزشی که در روند طبقه بندی دخالت داده نشده اند، اقدام به ارزیابی صحت تصویر طبقه بندی شده می گردد.

برای تعیین میزان دقت طبقه بندی، لازم است پیکسل های نمونه برداری شده به طور تصادفی انتخاب شوند. از مهم ترین معیارهای ارزیابی صحت طبقه بندی می توان به ضریب کاپا و دقت کلی اشاره کرد. برای محاسبه دقت کلی در طبقه بندی تصویر، جمع پیکسل های عناصر قطر اصلی ماتریس خطا بر تعداد کل پیکسل ها تقسیم می شود. دقت کلی بیانگر میزان اعتبار طبقه بندی انجام شده است و در نقشه های کاربری استخراج شده از تصاویر ماهواره ای باید بیش از ۸۵ درصد باشد. ضریب کاپا تکنیک چندمتغیره ی گسسته ای است، به این

صورت که اگر یک ماتریس خطا تفاوت معناداری با دیگری داشته باشد، در ارزیابی صحت برای تصمیم گیری آماری مورد استفاده قرار می گیرد. شاخص k یا ضریب کاپا در واقع معرف اختلاف بین توافق واقعی در داده های مرجع و یک طبقه بندی کننده خودکار و همچنین یک توافق بین داده های مرجع و طبقه بندی کننده ی تصادفی است.

مقایسه دقت کاربر و دقت تولیدکننده برای کلاس های مختلف در هر دو روش انجام گردید و در نتیجه ارزیابی صحت کلاس های مختلف در جدول ۴ نشان داده شده است. بر همین اساس دقت کاربر (user accuracy) احتمال قطعیت درست طبقه بندی شدن یک پیکسل و دقت تولیدکننده (Producer Accuracy) احتمال آنکه یک نمونه ی برداشت شده بر روی تصویر مرتبط با آن کلاس خاص باشد، در این جدول نمایش داده شده است.

جدول ۴. مقایسه دقت کاربر و دقت تهیه کننده برای کلاس های مختلف پوشش زمین

Table 4. Compare user accuracy and manufacturer accuracy for different classes

ارزیابی صحت کلاس ها	دقت تهیه کننده (ماشین بردار پشتیبان)	دقت کاربر (ماشین بردار پشتیبان)	دقت تهیه کننده (شبکه عصبی)	دقت کاربر (شبکه عصبی)
جاده	۹۷/۵۴	۹۳/۰۸	۹۲/۳۷	۸۷/۵۴
کوه	۹۳/۸۱	۸۸/۸۹	۸۸/۳۷	۶۵/۵۲
مسکونی و شهری	۱۰۰	۸۵/۷۹	۷۷/۱۹	۷۰/۹۷
پوشش گیاهی	۱۰۰	۹۸/۲۰	۸۸/۲	۸۵/۶۶


۸۰/۴۴	۸۴/۳۵	۷۹/۳۷	۸۶/۹۶	زمین‌های بایر
۶۹/۵۷	۸۵/۱۱	۸۳/۰۸	۹۳/۱	جاده
دقت کلی =	ضریب کاپا =	دقت کلی =	ضریب کاپا =	
۹۱/۸۱%	۰/۸۸۷۸	۹۴/۳۳%	۰/۹۲۲۳	


جدول ۴ و ۵ مربوط به ماتریس خطای طبقه‌بندی شبکه عصبی مصنوعی و ماشین بردار پشتیبان با الگوریتم کرم شبتاب در زیر ارائه شده‌اند.

مقایسه بین دقت کاربر و دقت تهیه‌کننده پس از اعمال الگوریتم کرم شبتاب برای کلاس‌های مختلف در جدول ۷ نشان داده شده است.

الگوریتم کرم شبتاب در نرم‌افزار پایتون برنامه‌نویسی شد و بعد از آن تصاویر هر دو روش طبقه‌بندی به عنوان ورودی به برنامه نوشته شده داده شد. پس از ورود تصاویر به برنامه پایتون و مشاهده نتایج خروجی، مشخص شد که پارامترهای تابع هسته مرکزی روش بردار پشتیبان و تعداد نوروهای روش شبکه عصبی مصنوعی بهبود داده شده است. در نهایت تصویر طبقه‌بندی شده با الگوریتم کرم شبتاب برای تصاویر بدست آمد که در شکل ۷ نشان داده شده است.

الف





شکل ۷. طبقه بندی تصویر با الگوریتم کرم شبتاب برای

الف. شبکه عصبی ب. ماشین بردار پشتیبان

Fig 7. Image classification with firefly algorithm for
a. Artificial neural network b. Support vector machine

جدول ۵. ماتریس خطای طبقه بندی نظارت شده به روش شبکه عصبی مصنوعی با الگوریتم کرم شبتاب

Table 5. Error classification matrix of artificial neural network method with firefly algorithm

	شهری	پوشش گیاهی	کوه	زمین های بایر	جاده	مجموع سطرها
شهری	۸۲۱	۰	۲	۱۹۲	۸	۱۰۳۸
پوشش گیاهی	۱۲	۱۹۷۵	۰	۰	۵	۱۹۸۹
کوه	۵۳	۰	۹۰۹	۳	۸	۹۷۰
زمین های بایر	۸	۴	۰	۴۸۲	۰	۴۹۴
جاده	۷	۰	۴۰	۰	۲۶۷	۳۱۴
مجموع ستون ها	۹۰۱	۱۹۷۹	۹۵۱	۶۷۷	۲۸۱	۴۷۹۶

جدول ۶. ماتریس خطای طبقه‌بندی روش ماشین بردار پشتیبان با الگوریتم کرم شب‌تاب

Table 6. Classification error matrix Support Vector Machine method with Firefly algorithm

مجموع سطرها	جاده	زمین‌های بایر	کوه	پوشش گیاهی	شهری	
۱۰۰۰	۱۰	۱۴۰	۱۵	۰	۸۲۵	شهری
۱۹۸۲	۲	۰	۰	۱۹۷۵	۵	پوشش گیاهی
۹۷۶	۱۷	۰	۹۳۶	۰	۲۳	کوه
۵۷۷	۰	۵۳۷	۰	۴	۳۶	زمین‌های بایر
۲۶۱	۲۵۹	۰	۰	۰	۲	جاده
۴۹۷۶	۲۸۸	۶۷۷	۹۵۱	۱۹۷۹	۹۰۱	مجموع ستون‌ها

جدول ۷. جدول مقایسه دقت کاربر و دقت تهیه‌کننده برای کلاس‌های مختلف

Table 7. Comparison table of user accuracy and manufacturer accuracy for different classes

ارزیابی صحت کلاس‌ها	دقت تهیه‌کننده (ماشین بردار پشتیبان)	دقت کاربر (ماشین بردار پشتیبان)	دقت تهیه‌کننده (شبکه عصبی)	دقت کاربر (شبکه عصبی)
جاده	۹۸/۳۲	۹۵/۲۲	۹۳/۳۷	۸۸/۴۴
کوه	۹۴/۱۱	۸۹/۳۳	۸۸/۴۴	۶۶/۱۳
مسکونی و شهری	۱۰۰	۸۷/۱۱	۷۸/۲۹	۷۱/۵۵
پوشش گیاهی	۱۰۰	۹۸/۴۳	۸۹/۳	۸۵/۷۷
زمین‌های بایر	۸۹/۳۳	۸۰/۴۴	۸۵/۲۲	۸۲/۳۳
جاده	۹۴/۳	۸۵/۳۳	۸۶/۲۱	۷۰/۴۴
	ضریب کاپا = ۰/۹۳۴۳	دقت کلی = ۹۵/۹۳%	ضریب کاپا = ۰/۹۱۹۳	دقت کلی = ۹۵/۶۱%

برای بررسی اینکه آیا تفاوت بین دقت‌های به‌دست‌آمده از دو الگوریتم طبقه‌بندی SVM و ANN در سطح معناداری آماری قابل تأیید است یا خیر، از آزمون آماری کای-دو (Chi-Square Test) استفاده شد. در این آزمون، فرض صفر (H_0) بیان می‌کند که بین عملکرد دو الگوریتم اختلاف معناداری وجود ندارد و فرض مقابل (H_1) نشان می‌دهد که تفاوت معناداری بین آن‌ها وجود دارد.

مقادیر دقت کاربر و دقت تهیه‌کننده برای کلاس‌های مختلف به‌عنوان مبنای آزمون قرار گرفتند. برای اجرای آزمون، ماتریس‌های خطا (confusion matrices) برای هر الگوریتم استخراج و تعداد پیکسل‌های صحیح و ناصحیح برای هر کلاس شمارش شد. سپس با استفاده از تابع آزمون کای-دو در نرم‌افزار Python ماژول تفاوت آماری بین طبقه‌بندی‌ها تحلیل شد. جدول ۸ نتایج آزمون کای دو را نشان می‌دهد.

نتایج آزمون کای دو:

جدول ۸. نتایج آزمون کای دو

Table 8. Chi-square test results

نتیجه آزمون	سطح معناداری (p-value)	آماره کای دو	مقایسه بین الگوریتم‌ها
معنادار	0.030	12.36	دقت تهیه‌کننده
معنادار	0.017	15.21	دقت کاربر

صحت کلی و ضریب کاپا برای دو روش طبقه‌بندی با الگوریتم کرم شبتاب و بدون آن به شرح جداول ۹ و ۱۰ ارائه شده است.

بعد از به دست آوردن تصاویر طبقه‌بندی برای دو روش شبکه عصبی مصنوعی و ماشین بردار پشتیبان با استفاده از الگوریتم کرم شبتاب، برای تصویر ASTER و جداول ماتریس طبقه‌بندی مربوط به آنها، در نهایت جداول مربوط به

جدول ۹. صحت کلی و ضریب کاپا روش شبکه عصبی، قبل و بعد از اعمال الگوریتم

Table 9. Overall accuracy and kappa coefficient of the neural network method, before and after applying the algorithm

طبقه بندی شبکه عصبی با اعمال الگوریتم کرم شبتاب	طبقه بندی با روش شبکه عصبی	
%۶۱/۹۵	%۸۱/۹۱	دقت کلی
۰/۹۱۹۳	۰/۸۸۷۸	ضریب کاپا

جدول ۱۰. صحت کلی و ضریب کاپا روش ماشین بردار پشتیبان، قبل و بعد از اعمال الگوریتم

Table 10. Overall accuracy and kappa coefficient of the Support Vector Machine method, before and after applying the algorithm

طبقه بندی ماشین بردار پشتیبان با اعمال الگوریتم کرم شبتاب	طبقه بندی با روش ماشین بردار پشتیبان	
%۹۵/۹۳	%۹۴/۳۳	دقت کلی
۰/۹۳۴۳	۰/۹۲۲۳	ضریب کاپا

های مختلف تعداد پیکسل‌هایی که درست طبقه‌بندی شده‌اند افزایش یافته است. این افزایش تعداد پیکسل‌های صحیح نشان از بهبود دقت طبقه‌بندی با اعمال الگوریتم کرم شبتاب دارد.

در روش شبکه عصبی، دقت کلی طبقه‌بندی از ۹۱/۸۱ درصد در طبقه‌بندی بدون الگوریتم کرم شبتاب، به ۹۵/۶۱ درصد در طبقه‌بندی با اعمال الگوریتم رسید و در طبقه‌بندی ماشین بردار پشتیبان از ۹۴/۳۳ به ۹۵/۹۳ افزایش یافت و این بدین معنی است که الگوریتم کرم شبتاب دقت طبقه‌بندی را در هر دو روش بهبود داده است.

با مقایسه‌ی جداول ۹ و ۱۰ مشاهده می‌شود که دقت طبقه‌بندی در تصویر برای دو روش شبکه عصبی مصنوعی و ماشین بردار پشتیبان به ترتیب ۹۱/۸۱ و ۹۴/۳۳ دست آمد که نشان از برتری روش ماشین بردار پشتیبان نسبت به روش شبکه عصبی مصنوعی دارد.

همچنین با مشاهده جداول ۲ و ۴ مشاهده می‌شود که به طور مثال هم در روش شبکه عصبی مصنوعی و هم در روش ماشین بردار پشتیبان در طبقه‌بندی با الگوریتم کرم شبتاب نسبت به طبقه‌بندی بدون الگوریتم کرم شبتاب، برای پوشش-

بحث و نتیجه‌گیری

در این پژوهش، به منظور استخراج نقشه پوشش/کاربری اراضی شهرستان رفسنجان، دو الگوریتم یادگیری ماشین شامل ماشین بردار پشتیبان (SVM) و شبکه عصبی مصنوعی (ANN) بر روی تصویر سنجنده ASTER با تاریخ اخذ سال ۲۰۱۵ به کار گرفته شد. برای بهبود عملکرد هر دو روش، الگوریتم کرم شب تاب (Firefly Algorithm) به عنوان یک راهکار فراابتکاری جهت بهینه‌سازی طبقه‌بندی استفاده شد. پردازش‌ها در محیط ENVI 5.3 و برنامه‌نویسی در Python انجام شد.

مقایسه نتایج طبقه‌بندی نشان داد که روش ماشین بردار پشتیبان، پس از اعمال الگوریتم کرم شب تاب، با ضریب کاپای ۰٫۹۳۴۳ و دقت کلی ۹۵٫۹۳ درصد عملکرد بهتری نسبت به شبکه عصبی مصنوعی با ضریب کاپای ۰٫۹۱۹۳ و دقت کلی ۹۵٫۶۱ دارد. تحلیل آماری آزمون کای دو برای بررسی معناداری اختلاف دقت بین کلاس‌ها نیز نشان داد که تفاوت بین نتایج دو روش در سطح اطمینان ۹۵ درصد معنادار است.

بررسی دقت کاربر و دقت تهیه‌کننده برای کلاس‌های مختلف نیز نشان داد که روش SVM در طبقه‌بندی کلاس‌هایی مانند مناطق مسکونی و پوشش گیاهی، نسبت به شبکه عصبی عملکرد بهتری دارد. با این حال، در برخی کلاس‌ها مانند

زمین‌های بایر و کوهستان، تفاوت دقت دو روش کمتر محسوس بود.

در روش SVM از کرنل RBF با تنظیمات بهینه‌سازی شده (پارامترهای C و گاما) استفاده شد. برای شبکه عصبی نیز ساختار چندلایه با یک لایه پنهان و تابع فعال‌سازی سیگموئید پیاده‌سازی شد. یکی از چالش‌های عمده، انتخاب نمونه‌های آموزشی با کیفیت و نمایا برای هر کلاس بود که می‌تواند بر عملکرد نهایی تأثیرگذار باشد. همچنین، نبود داده‌های مرجع میدانی دقیق برای اعتبارسنجی، یکی از محدودیت‌های پژوهش به شمار می‌رود.

پیشنهاد می‌شود در تحقیقات آتی از روش‌های یادگیری عمیق (Deep Learning) مانند شبکه‌های عصبی کانولوشنی (CNN) برای افزایش دقت طبقه‌بندی استفاده گردد.

✓ بهره‌گیری از داده‌های چندزمانه و ترکیب تصاویر ماهواره‌ای مختلف می‌تواند در بهبود تشخیص پوشش اراضی مؤثر باشد.

✓ توسعه سیستم‌های نیمه‌خودکار برای انتخاب نمونه‌های آموزشی می‌تواند خطای انسانی را کاهش دهد.

✓ پیشنهاد می‌شود ارزیابی عملکرد روش‌ها با معیارهای بیشتری همچون شاخص F1، حساسیت و ویژگی تکمیل شود.

منابع مورد استفاده

1. Abbaspour-Gilandeh, Y., Sabzi, S., Benmouna, B., García-Mateos, G., Hernández-Hernández, J. L., & Molina-Martínez, J. M. (2020). Estimation of the constituent properties of red delicious apples using a hybrid of artificial neural networks and artificial bee colony algorithm. *Agronomy*, 10(2), 267.
2. Alavipanah, K, M, Masoudi.2001. Land use Mapping Preparation Using TM satellite imaging Data and GIS (A case Study: Mork region of Fars province Natural Resources and Agricultural Journal.
3. Arekhi Saleh and Adibnejad. Mostafa, 2011, Evaluation of the efficiency of support vector machine algorithms for land use classification using Landsat ETM +satellite imagery (case study :Ilam Dam), Natural Resources Department, Agriculture Sciences Faculty, University of Ilam, Scientific Journal of Research Pasture and Desert of Iran, Volume 18, Number 3, Page 420-440. (In Persian).
4. Baban, S. J. and M. Wan Yusof. (2001) Mapping land use/ cover distribution on a mountainous tropical island using remote sensing and GIS, *International Journal Remote Sensing*, 22:10, 1909–1918.
5. Barrett, E.C, and Curtic, L. F (1992). Introduction to Environmental Remote Sensing, Chapman & Hall, London.
6. Chen, K., Zhou, Y., Zhang, Z., Dai, M., Chao, Y., & Shi, J. (2016). Multilevel image segmentation based on an improved firefly algorithm. *Mathematical Problems in Engineering*.
7. Chen, Q., Chen, Y., & Jiang, W. (2016). Genetic particle swarm optimization–based feature selection for very-high-resolution remotely sensed imagery object change detection. *Sensors*, 16(8), 1204.
8. Chen, X., Wang, J., Sun, D., & Liang, J. (2008, October). A novel hybrid Evolutionary Algorithm based on PSO and AFSA for feedforward neural network training. In 2008 4th International

- Conference on Wireless Communications, Networking and Mobile Computing (pp. 1-5). IEEE.
9. Jansen L. J.M. and A. Di Gregorio. (2004) Obtaining land-use information from a remotely sensed land cover map: results from a case study in Lebanon, International Journal of Applied Earth Observation and Geoinformation, 5: 141-157.
10. Hossieni, S. 2002. Investigation on ability of ETM+ satellite image Data for land use mapping preparation (A case Study: Mazandaran province, Chamestan region). Msc Thesis, Tehran University.
11. Hung, H. J., O'Neill, R. T., Bauer, P., & Kohne, K. (1997). The behavior of the p-value when the alternative hypothesis is true. Biometrics, 11-22.
12. Hussain, S. F., Pervez, A., & Hussain, M. (2020). Co-clustering optimization using Artificial Bee Colony (ABC) algorithm. Applied Soft Computing, 97, 106725.
13. Huang, J., Lu, J., & Ling, C. X. (2003, November). Comparing naive Bayes, decision trees, and SVM with AUC and accuracy. In Third IEEE International Conference on Data Mining (pp. 553-556). IEEE.
14. Kattan, A., & Abdullah, R. (2011, January). A parallel & distributed implementation of the harmony search based supervised training of artificial neural networks. In 2011 Second International Conference on Intelligent Systems, Modelling and Simulation (pp. 277-283). IEEE.
15. Karaboga, D., & Akay, B. (2009). A comparative study of artificial bee colony algorithm. Applied mathematics and computation, 214(1), 108-132.
16. Karnan, S. M. (2014). Medical image segmentation using firefly algorithm and enhanced bee colony optimization. Bonfring Int. J. Adv. Image Process, 316-321.
17. Lee, Y. J., & Mangasarian, O. L. (2001). SSVM: A smooth support vector machine for classification. Computational optimization and Applications, 20(1), 5-22.
18. Liu, L., Zhao, D., Yu, F., Heidari, A. A., Li, C., Ouyang, J., ... & Pan, J. (2021). Ant colony optimization with Cauchy and greedy Levy mutations for multilevel COVID 19 X-ray image segmentation. Computers in biology and medicine, 136, 104609.
19. Montana, D. J., & Davis, L. (1989, August). Training feedforward neural networks using genetic algorithms. In IJCAI (Vol. 89, pp. 762-767).
20. Omran, M. G. (2009). Using opposition-based learning with particle swarm optimization and barebones differential evolution. Particle Swarm Optimization, 23, 343-384.
21. Okwuashi, O., & Ndehedehe, C. (2017). Tide modelling using support vector machine regression. Journal of Spatial Science, 62(1), 29-46.
22. Pirra, M., & Diana, M. (2019). A study of tour-based mode choice based on a support vector machine classifier. Transportation Planning and Technology, 42(1), 23-36.
23. Poursaee, A. (2018). Application of agent-based paradigm to model corrosion of steel in concrete environment. Corrosion Engineering, Science and Technology, 53(4), 259-264.
24. Ren, Z., Liu, T., & Liu, G. (2021). Classification and discrimination of real and fake blood based on photoacoustic spectroscopy combined with particle swarm optimized wavelet neural networks. Photoacoustics, 100278.
25. Shataee, Sh and A, Abdi, 2007. Land use mapping preparation in Zagros mountain region using ETM+ satellite images Data (A case study: Sarkan Watershed of Lorestan). Natural Resources and Agricultural Sciences Journal: 1(4):129-138.
26. Shilane, D., Martikainen, J., Dudoit, S., & Ovaska, S. J. (2008). A general framework for statistical performance comparison of evolutionary computation algorithms. Information Sciences, 178(14), 2870-2879.
27. Slowik, A., & Bialko, M. (2008, May). Training of artificial neural networks using differential evolution algorithm. In 2008 conference on human system interactions (pp. 60-65). IEEE.
28. Socha, K., & Blum, C. (2007). An ant colony optimization algorithm for continuous optimization: application to feed-forward neural network training. Neural computing and applications, 16(3), 235-247.
29. Su, H., Cai, Y., & Du, Q. (2016). Firefly-algorithm-inspired framework with band selection and extreme learning machine for hyperspectral image classification. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 10(1), 309-320.
30. Vallada, E., & Ruiz, R. (2010). Genetic algorithms with path relinking for the minimum tardiness permutation flowshop problem. Omega, 38(1-2), 57-67.
31. Wang, X. J., Gao, L., & Zhang, C. Y. (2008, September). Electromagnetism-like mechanism based algorithm for neural network training. In International Conference on Intelligent Computing (pp. 40-45). Springer, Berlin, Heidelberg.
32. Wijaya, A., 2005, Application of Multi-Stage Classification to Detect Illegal Logging with the Use of MultiSource Data, MSc. Thesis, ITC, Enschede, The Netherlands.
33. Xie, H., Zhang, L., Lim, C. P., Yu, Y., Liu, C., Liu, H., & Walters, J. (2019). Improving K-means clustering with enhanced firefly algorithms. Applied Soft Computing, 84, 123-134.
34. Yang, X. S. (2009, October). Firefly algorithms for multimodal optimization. In International symposium on stochastic algorithms (pp. 169-178). Springer, Berlin, Heidelberg.

35. Yang, X. S. (2010). Engineering optimization: An introduction with metaheuristic applications (pp. 1–273). John Wiley & Sons.
36. Yang, X. S., & He, X. (2015). Swarm intelligence and evolutionary computation: overview and analysis. Recent advances in swarm intelligence and evolutionary computation, 1-23.
37. Yang, X. S., & Deb, S. (2010). Eagle strategy using Lévy walk and firefly algorithms for stochastic optimization. In Nature inspired cooperative strategies for optimization (NICSO 2010) (pp. 101-111). Springer, Berlin, Heidelberg.
38. Yamaguchi, Y., Kahle, A. B., Tsu, H., Kawakami, T., & Pniel, M. (1998). Overview of advanced spaceborne thermal emission and reflection radiometer (ASTER). IEEE Transactions on Geoscience and Remote Sensing, 36(4), 1062–1071
۳۹. مرکز آمار ایران. (۱۳۹۵). نتایج سرشماری عمومی نفوس و مسکن سال ۱۳۹۵. تهران: مرکز آمار ایران.
۴۰. سازمان هواشناسی کشور. (۱۳۹۹). گزارش اقلیم‌شناسی شهرستان رفسنجان. تهران: وزارت راه و شهرسازی.



Use of firefly meta-heuristic algorithm in improving the accuracy of satellite image classification, Case study: Rafsanjan

Hamid Bagheri^{1*}

Received: 2022-03-07 / Accepted: 2022-06-27 / Published: 2025-07-22

Abstract

Today, the use of satellite information and Geographic Information Systems (GIS) plays a crucial role in preparing land use and land cover maps. Satellite data provide up-to-date, digital information and enable advanced image processing techniques. In recent years, advanced classification methods such as artificial neural networks, fuzzy sets, and intelligent algorithms have been widely applied for satellite image classification. This study aims to improve the classification accuracy of satellite imagery using a metaheuristic optimization algorithm. A novel supervised classification approach based on the firefly algorithm is proposed. Two neural network classification algorithms and support vector machines were used for land use map classification. Then, the overall accuracy and kappa coefficient for these classifiers were calculated. Finally, the firefly algorithm was implemented in Python to optimize the parameters of the support vector machine kernel function and the number of neurons in the neural network.

Hamid Bagheri¹(✉)

1. Instructor, Department of Civil Engineering, Faculty of Civil and Surveying, Technical and Vocational University (TVU), Tehran, Iran

DOI: 10.30495/girs.2022.692233

e-mail: h-bagheri@nus.ac.ir

The classification accuracy for ASTER sensor images increased by 1.6% in the neural network classification and by 3.8% in the support vector machine classification after applying this algorithm. The results demonstrate that the firefly algorithm is an effective optimizer and a competitive classifier compared to other methods.

Extended Abstract

Problem Statement

In recent decades, the extraction of information from satellite imagery has experienced significant advancements. Numerous algorithms have been developed for this purpose, each offering distinct advantages and limitations. Among the most critical approaches in remote sensing image analysis is classification, which plays a vital role in land cover and land use change detection. Classification involves assigning each pixel in a satellite image to a specific category. A major challenge in this domain is selecting a classification method with high accuracy, especially for high-resolution satellite imagery.

Objective

This study aims to improve the classification accuracy of satellite imagery using metaheuristic algorithms. A supervised classification method enhanced by the Firefly Algorithm was employed. Initially, classification was performed using two

established methods: Artificial Neural Networks (ANN) and Support Vector Machines (SVM). Land cover maps were generated for both approaches. To assess performance, overall accuracy and the Kappa coefficient were calculated. The Firefly Algorithm was implemented in Python to optimize the number of neurons in ANN and kernel parameters in SVM. As a relatively recent metaheuristic search method, the Firefly Algorithm demonstrates promising potential in automatic segmentation and classification performance enhancement compared to conventional approaches.

Methodology

The satellite image used in this study was acquired from the ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) sensor onboard the Terra satellite, designed primarily for geological applications with strong spectral resolution in the infrared range. The 2015 ASTER image with 14 spectral bands was selected for analysis. Preprocessing and classification were conducted using ENVI 5.3 software, and training samples were collected through Google Earth. The

By comparing the classification accuracy of the methods based on artificial neural network and support vector machine, it was found that the support vector machine method with kappa coefficient of 0.9223 is more accurate than the artificial neural network method with kappa coefficient of 0.8788. In this study, after reviewing the results related to the classifications, it was concluded that for the desired image, the classification accuracy of the support vector machine is 2.52% better than the classification of the artificial neural network. After executing the firefly algorithm on the image, it was observed that the classification accuracy of the support vector machine method has been improved by about 3.8% and the classification accuracy of the artificial

classification optimization process using the Firefly Algorithm was developed in Python.

Results and Discussion

The image was classified using ANN and SVM, both with and without the integration of the Firefly Algorithm. The initial ANN classification resulted in an overall accuracy of 91.81% and a Kappa coefficient of 0.8878. After applying the Firefly Algorithm, these values improved to 95.61% and 0.9193, respectively. Similarly, for the SVM approach, overall accuracy increased from 94.33% to 95.93%, and the Kappa coefficient improved from 0.9223 to 0.9343. These outcomes demonstrate that the Firefly Algorithm significantly enhances classification accuracy in both classifiers. When compared with previous studies involving other metaheuristic algorithms such as genetic algorithms, ant colony optimization, and particle swarm optimization, the Firefly Algorithm shows competitive or superior performance, although its effectiveness still depends on the classifier type and image characteristics.

Conclusion

neural network for this image has been improved by about 1.6%.

The comparison between ANN and SVM indicates that SVM performs better with a Kappa coefficient of 0.9223, compared to 0.8878 for ANN. Applying the Firefly Algorithm resulted in an improvement of approximately 3.8% in classification accuracy for SVM and about 1.6% for ANN. These findings highlight the potential of the Firefly Algorithm as a powerful tool for enhancing satellite image classification.

Keywords: Classification, Firefly Algorithm, Artificial Neural Network, Support Vector Machine, Satellite Image